



**TESIS-KS185411**

**MODEL HYBRID MULTIVARIATE GSTARX-RNN  
UNTUK PERAMALAN DATA SPACE-TIME**

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

**Vania Orva Nur Laily  
NRP. 062118 5001 0005**

**DOSEN PEMBIMBING**  
**Dr. Suhartono, S.Si., M.Sc.**  
**R. Mohammad Atok, M.Si., Ph.D**

**Program Magister  
Departemen Statistika  
Fakultas Sains dan Analitika Data  
Institut Teknologi Sepuluh Nopember  
Surabaya  
2020**



**TESIS-KS185411**

**MODEL HYBRID MULTIVARIATE GSTARX-RNN  
UNTUK PERAMALAN DATA SPACE-TIME  
(Studi Kasus: Data Inflow dan Outflow Bank Sentral di Jawa)**

**Vania Orva Nur Laily  
NRP. 062118 5001 0005**

**DOSEN PEMBIMBING  
Dr. Suhartono, S.Si., M.Sc.  
R. Mohammad Atok, M.Si., Ph.D**

**Program Magister  
Departemen Statistika  
Fakultas Sains dan Analitika Data  
Institut Teknologi Sepuluh Nopember  
Surabaya  
2020**





THESIS - KS185411

**A HYBRID MULTIVARIATE GSTARX-RNN MODEL  
FOR FORECASTING SPACE-TIME DATA  
(Case Study: Inflow and Outflow Central Bank in Java)**

Vania Orva Nur Laily  
SN. 062118 5001 0005

SUPERVISORS

Dr. Suhartono, S.Si., M.Sc.  
R. Mohammad Atok, M.Si., Ph.D

Magister Program  
Department of Statistics  
Faculty of Science and Data Analytics  
Institut Teknologi Sepuluh Nopember  
Surabaya  
2020



## LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar  
**Magister Statistika (M.Stat)**  
di  
**Institut Teknologi Sepuluh Nopember**

Oleh:  
**VANIA ORVA NUR LAILY**  
**NRP: 06211850010005**

Tanggal Ujian : 29 Juli 2020  
Periode Wisuda : September 2020

Disetujui oleh:  
**Pembimbing:**

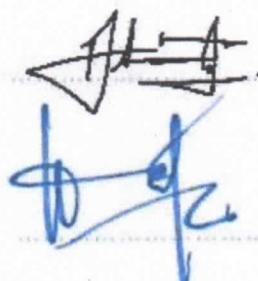
1. Dr.Suhartono, M.Sc.  
NIP. 19710929 1991512 1 001



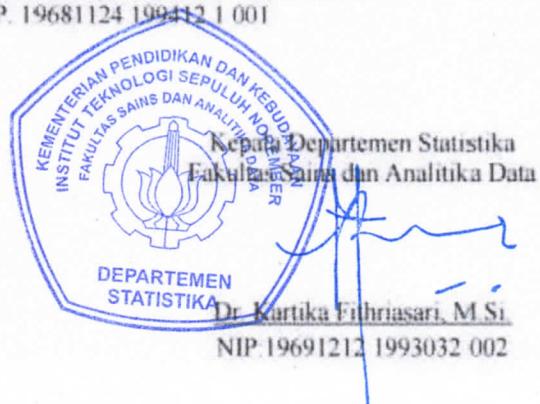
2. R. Mohammad Atok, M.Si., Ph.D  
NIP. 19710915 199702 1 001

**Pengaji :**

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



2. Dr. Bambang Widjanarko Otok, M.Si.  
NIP. 19681124 199412 1 001





# **Model Hybrid Multivariate GSTARX-RNN untuk Peramalan Data Space-Time (Studi Kasus: Data Inflow dan Outflow Bank Sentral di Jawa)**

Nama Mahasiswa : Vania Orva Nur Laily  
NRP : 062118 5001 0005  
Pembimbing : Dr. Suhartono, S.Si., M.Sc.  
Co-pembimbing : R. Mohammad Atok, M.Si., Ph.D.

## **ABSTRAK**

Data memiliki dimensi waktu dan dimensi ruang yang disebut data *space-time*. *Generalized Spaced-time Autoregressive* (GSTAR) adalah salah satu model yang dapat digunakan untuk menganalisa data *space-time*. Model GSTAR dengan variabel eksogen dikenal dengan GSTARX. Salah satu pengembangan untuk model ini adalah *Multivariate Generalized Spaced-time Autoregressive* (MGSTARX) yaitu model dengan lebih dari satu variabel pada setiap lokasi. Model MGSTARX dikembangkan untuk menangkap pola linier pada data, sehingga dapat dikombinasikan dengan model lain untuk menangkap pola nonlinier pada data. Penelitian ini bertujuan mengembangkan model *hybrid* MGSTARX-RNN, dengan model MGSTARX sebagai komponen linier dan *Recurrent Neural Network* sebagai komponen nonlinier. Data yang digunakan dalam penelitian ini adalah data *inflow* dan *outflow* Uang Pecahan Besar (UPB) yaitu nominal Rp100.000, Rp50.000, Rp20.000 di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, dan Jakarta. Hasil perbandingan akurasi ramalan menunjukkan bahwa model terbaik untuk masing-masing pecahan adalah MGSTARX untuk data *outflow* Rp50.000, ARIMAX untuk data *outflow* Rp20.000 dan Rp100.000, GSTARX untuk data *inflow* Rp50.000 dan Rp100.000, dan GSTARX-ERNN untuk data *inflow* Rp20.000.

**Kata Kunci:** GSTARX, *Hybrid*, MGSTARX-RNN, *Inflow*, *Outflow*, *Space-Time*.

*Halaman ini sengaja dikosongkan*

# **A Hybrid Multivariate GSTARX-RNN Model for Forecasting Space-Time Data**

## **(Case Study: Inflow and Outflow Central Bank in Java)**

Name : Vania Orva Nur Laily  
Student Number : 062118 5001 0005  
Supervisor : Dr. Suhartono, S.Si., M.Sc.  
Co-Supervisor : R. Mohammad Atok, M.Si., Ph.D.

## **ABSTRACT**

Data which has time and space dimensions is called space-time data. GSTAR is one of the models that can be used to analyze space-time data. The Model GSTAR with an exogenous variable is known as GSTARX. The development for this model is Multivariate Generalized Space-time Autoregressive (MGSTARX) which is a model with more than one variables at each location. The MGSTARX model is developed to capture linear data patterns, so it can be combined with other models to capture nonlinear data patterns. The goal of the study was to develop a hybrid MGSTARX-RNN model, with the MGSTARX model as a linear component and the RNN as a nonlinear component. The data used in this research is inflow and outflow of UPB i.e. nominal IDR 100.000, IDR 50.000, and IDR 20.000. Comparison of the forecast accuracy shows that the best model for each nominal is MGSTARX for outflow IDR 50.000, ARIMAX for outflow IDR 20.000 and IDR 100.000, GSTARX for inflow IDR 50.000 and IDR 100.000, and GSTARX-ERNN for inflow IDR 20.000.

**Keywords:** GSTARX, Hybrid, MGSTARX-RNN, Inflow, Outflow, Space-Time,

*Halaman ini sengaja dikosongkan*

## KATA PENGANTAR

Puji dan syukur Alhamdulillah penulis panjatkan atas rahmat dan hidayah yang diberikan Allah SWT sehingga penulis dapat menyelesaikan laporan tesis dengan judul

### **“Model Hybrid Multivariate GSTARX-RNN untuk Peramalan Data Space-Time (Studi Kasus: Data Inflow dan Outflow Bank Sentral di Jawa)”.**

Laporan Tesis ini dapat diselesaikan dengan baik tidak terlepas dari dukungan berbagai pihak oleh karena itu pada kesempatan ini penulis ingin mengucapkan terima kasih pada pihak-pihak yang telah membantu penulis yaitu sebagai berikut.

1. Bapak Dr. Suhartono, M.Sc. dan Bapak R. Mohammad Atok, M.Si., Ph.D. selaku dosen pembimbing tesis, yang telah meluangkan banyak waktu dan dengan penuh kesabaran memberikan bimbingan, saran, dan motivasi selama penyusunan tesis.
2. Bapak Dr.rer.pol. Dedy Dwi Prastyo, M.Si selaku Kepala Program Studi Pascasarjana Departemen Statistika ITS sekaligus dosen penguji yang telah memberikan banyak masukan dan arahan kepada penulis sehingga tesis ini dapat diselesaikan dengan baik.
3. Bapak Dr. Bambang Widjanarko Otok, M.Si selaku dosen penguji yang telah memberikan masukan dan arahan kepada penulis sehingga tesis ini dapat diselesaikan dengan baik.
4. Ibu Dr. Dra. Kartika Fithriasari, M.Si. selaku Kepala Departemen Statistika Fakultas Sains dan Analitika Data Institut Teknologi Sepuluh Nopember Surabaya
5. Ibu Santi Wulan Purnami, M.Si., Ph.D selaku Sekretaris Departemen I (Bidang Akademik, Kemahasiswaan, Penelitian, dan Pengabdian Kepada Masyarakat)
6. Ibu Dr. Vita Ratnasari, M.Si. selaku Sekretaris Departemen II (Bidang Sumber Daya Keuangan, Sumber Daya Manusia, dan Sarana Prasarana)

7. Bapak Prof. Nur Iriawan, M.Ikom, Ph.D selaku dosen wali yang telah memberikan motivasi dan arahan dalam proses perkuliahan di Pascasarjana Statistika.
8. Seluruh dosen Departemen Stasistika ITS, atas ilmu yang telah diberikan selama penulis menempuh pendidikan, serta seluruh karyawan Departemen Stasistika ITS.
9. Kedua orang tua, Ayah Isnaeni Irianto dan Ibu Nurul Ain, atas segala do'a, kasih sayang, dan dukungan yang diberikan kepada penulis.
10. Seluruh Keluarga Besar Djati Kusuma dan Syahid yang telah memberikan dukungan penuh serta doa untuk penulis selama pembuatan Laporan Tugas Akhir.
11. Teman-teman Fazah, Endah, Retno, Mbak Luluk, Mbak Mita yang telah memberikan saran dan semangat kepada penulis dalam penyusunan tesis ini.
12. Teman-teman seperjuangan S2 Statistika ITS angkatan 2018 yang telah memberikan pengalaman dan kebersamaan yang sangat berharga.
13. Semua pihak yang telah membantu dan memberikan dukungan dalam penyusunan tesis ini.

Semoga tesis ini dapat memberikan sumbangan informasi ilmiah dan memberikan manfaat bagi masyarakat. Penulis menyadari bahwa masih banyak kesalahan dalam penulisan tesis ini. Oleh karena itu kritik dan saran dari berbagai pihak sangat penulis harapkan agar nantinya menjadi koreksi untuk penelitian yang akan datang.

Surabaya, Agustus 2020

Vania Orva Nur Laily

## DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL .....</b>	i
<b>TITLE PAGE .....</b>	iii
<b>LEMBAR PENGESAHAN .....</b>	v
<b>ABSTRAK .....</b>	vii
<b>ABSTRACT .....</b>	ix
<b>KATA PENGANTAR .....</b>	xi
<b>DAFTAR ISI .....</b>	xiii
<b>DAFTAR GAMBAR .....</b>	xvi
<b>DAFTAR TABEL .....</b>	xxi
<b>BAB 1 PENDAHULUAN</b>	
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	6
1.3 Tujuan Penelitian .....	6
1.4 Manfaat Penelitian .....	7
1.5 Batasan Masalah .....	7
<b>BAB 2 TINJAUAN PUSTAKA</b>	
2.1 Model <i>Autoregressive Integrated Moving Average</i> (ARIMA).....	9
2.2 Regresi <i>Time Series</i> .....	10
2.3 Variasi Kalender .....	11
2.4 <i>Multivariate Time Series</i> .....	12
2.4.1 Model <i>Space Time Autoregressive</i> (STAR) .....	16
2.4.2 Model <i>Generalized Space Time Autoregressive</i> (GSTAR).....	17
2.4.3 Model <i>Multivariate Generalize Space Time Autoregressive</i> .....	28
2.5 Uji Terasvirta .....	36
2.6 <i>Artificial Neural Network</i> (ANN) .....	37
2.7 <i>Recurrent Neural Network</i> (RNN) .....	39
2.8 Model <i>Hybrid MGSTARX-RNN</i> .....	46
2.9 Pemilihan Model Terbaik .....	47

2.10 <i>Inflow</i> dan <i>Outflow</i> Uang Kartal .....	47
---	----

### **BAB 3 METODOLOGI PENELITIAN**

3.1 Kajian Simulasi .....	51
3.2 Kajian Terapan .....	52
3.2.1 Sumber Data .....	52
3.2.2 Variabel Penelitian .....	53
3.2.3 Struktur Data .....	56
3.2.4 Langkah Analisis .....	57

### **BAB 4 ANALISIS DAN PEMBAHASAN**

4.1 Pemodelan Data Simulasi .....	63
4.1.1 Pemodelan Data Simulasi Skenario 1 .....	63
4.1.2 Pemodelan Data Simulasi Skenario 2 .....	65
4.2 Karakteristik Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	66
4.3 Pemodelan <i>Time Series Regression</i> Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	70
4.4 Pemodelan ARIMAX Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	74
4.5 Pemodelan GSTARX Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	79
4.5.1 Pemodelan GSTARX Pecahan Rp100.000.....	85
4.5.2 Pemodelan GSTARX Pecahan Rp50.000.....	88
4.5.3 Pemodelan GSTARX Pecahan Rp20.000.....	91
4.6 Pemodelan GSTARX-ERNN Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	94
4.6.1 Pemodelan GSTARX-ERNN Pecahan Rp100.000.....	96
4.6.2 Pemodelan GSTARX-ERNN Pecahan Rp50.000.....	100
4.6.3 Pemodelan GSTARX-ERNN Pecahan Rp20.000.....	104
4.7 Pemodelan GSTARX-JRNN Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	108
4.7.1 Pemodelan GSTARX-JRNN Pecahan Rp100.000 .....	109
4.7.2 Pemodelan GSTARX-JRNN Pecahan Rp50.000 .....	113

4.7.3 Pemodelan GSTARX-JRNN Pecahan Rp20.000 .....	116
4.8 Pemodelan <i>Multivariate GSTARX (MGSTARX)</i> Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	121
4.9 Pemodelan MGSTARX-ERNN Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa.....	131
4.10 Pemodelan MGSTARX-JRNN Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa.....	142
4.11 Perbandingan Hasil Pemodelan <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa.....	149
4.12 Peramalan Data <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa.....	152

## **BAB 5 KESIMPULAN DAN SARAN**

5.1 Kesimpulan.....	161
5.2 Saran .....	163

## **DAFTAR PUSTAKA .....** 165

## **LAMPIRAN**

## DAFTAR GAMBAR

	Halaman	
Gambar 2.1	Contoh Plot MCCF untuk Tiga Variabel .....	14
Gambar 2.2	Peta Pulau Jawa.....	20
Gambar 2.3	Fungsi <i>Hyperbolic Tangent</i> .....	38
Gambar 2.4	Arsitektur Model ERNN dengan Satu <i>Hidden Layer</i> .....	40
Gambar 2.5	Arsitektur Model ERNN dengan Satu <i>Neuron</i> pada <i>Hidden Layer</i> .....	43
Gambar 2.6	Arsitektur Model JRNN dengan Satu <i>Hidden Layer</i> .....	45
Gambar 2.7	Arsitektur Model JRNN dengan Satu <i>Neuron</i> pada <i>Hidden Layer</i> .....	46
Gambar 2.8	Alur Peredaran Uang di Indonesia.....	48
Gambar 2.9	Nominal Uang Pecahan Besar (UPB) .....	48
Gambar 2.10	Jaringan Distribusi Persebaran Uang Bank Indonesia.....	49
Gambar 3.1	Diagram Alir Tahapan Pemodelan Secara Keseluruhan.....	61
Gambar 3.2	Pemodelan <i>Hybrid-MGSTARX</i> dengan <i>Elman RNN</i> .....	62
Gambar 3.3	Pemodelan <i>Hybrid-MGSTARX</i> dengan <i>Jordan RNN</i> .....	62
Gambar 4.1	Plot Perbandingan Rata-Rata Nilai RMSE Hasil Pemodelan MGSTAR dan <i>hybrid</i> MGSTAR-RNN pada Skenario 1 .....	64
Gambar 4.2	Model Terbaik Setiap Variabel dan Lokasi pada Skenario1 .....	65
Gambar 4.3	Plot Perbandingan Rata-Rata Nilai RMSE Hasil Pemodelan MGSTAR dan <i>hybrid</i> MGSTAR-RNN pada Skenario 2 .....	65
Gambar 4.4	Model Terbaik Setiap Variabel dan Lokasi pada Skenario 2 .....	66
Gambar 4.5	Diagram Perkembangan <i>Inflow</i> pecahan Rp100.000 Setiap Tahun KPw Bank Sentral Provinsi di Jawa .....	68
Gambar 4.6	Diagram Perkembangan <i>Outflow</i> pecahan Rp100.000 Setiap Tahun KPw Bank Sentral Provinsi di Jawa .....	69
Gambar 4.7	<i>Time Series</i> Plot Data <i>Inflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	69
Gambar 4.8	<i>Time Series</i> Plot Data <i>Outflow</i> UPB KPw Bank Sentral Provinsi	

di Jawa.....	70
Gambar 4.9 Perbandingan Data Aktual <i>Inflow</i> pecahan Rp100.000 (a), Rp50.000 (b), Rp20.000 (c) KPw Bank Sentral Jakarta dengan Prediksi Hasil Pemodelan TSR <i>in sample</i> (kiri) dan <i>out sample</i> (kanan) .....	74
Gambar 4.10 Perbandingan Data Aktual <i>Inflow</i> pecahan Rp100.000 (a), Rp50.000 (b), Rp20.000 (c) KPw Bank Sentral Jakarta dengan Prediksi Hasil Pemodelan TSR <i>in sample</i> (kiri) dan <i>out sample</i> (kanan) .....	76
Gambar 4.11 <i>Time Series Plot Residual Model TSR Inflow</i> Rp100.000 di Lima KPw Bank Sentral.....	81
Gambar 4.12 <i>Time Series Plot Residual Model TSR Inflow</i> Rp50.000 di Lima KPw Bank Sentral.....	82
Gambar 4.13 <i>Time Series Plot Residual Model TSR Inflow</i> Rp20.000 di Lima KPw Bank Sentral.....	82
Gambar 4.14 Plot MCCF Residual Model TSR <i>Inflow</i> dan <i>Outflow</i> Rp100.000.....	83
Gambar 4.15 Plot MPCCF Residual Model TSR <i>Inflow</i> dan <i>Outflow</i> Rp100.000.....	83
Gambar 4.16 Perbandingan Data Aktual <i>Inflow</i> Rp100.000 dengan Prediksi Hasil Model GSTARX Bobot Seragam <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	87
Gambar 4.17 Perbandingan Data Aktual <i>Inflow</i> Rp50.000 dengan Prediksi Hasil Model GSTARX Bobot Seragam <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	90
Gambar 4.18 Perbandingan Data Aktual <i>Inflow</i> Rp20.000 dengan Prediksi Hasil Model GSTARX Bobot Seragam <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	93
Gambar 4.19 Arsitektur Model GSTARX-ERNN <i>Inflow</i> Rp100.000 .....	98
Gambar 4.20 Perbandingan Data Aktual <i>Inflow</i> Rp100.000 dengan Prediksi Hasil Model GSTARX-ERNN(20,1,1) Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan) .....	99

Gambar 4.21	Arsitektur Model GSTARX-ERNN <i>Inflow</i> Rp50.000.....	101
Gambar 4.22	Perbandingan Data Aktual <i>Inflow</i> Rp50.000 dengan Prediksi Hasil Model GSTARX-ERNN(20,2,1) Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	103
Gambar 4.23	Arsitektur Model GSTARX-ERNN <i>Inflow</i> Rp20.000.....	105
Gambar 4.24	Perbandingan Data Aktual <i>Inflow</i> Rp20.000 dengan Prediksi Hasil Model GSTARX-ERNN(20,2,1) Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	107
Gambar 4.25	Arsitektur Model GSTARX-JRNN <i>Inflow</i> Rp100.000.....	110
Gambar 4.26	Perbandingan Data Aktual <i>Inflow</i> Rp100.000 dengan Prediksi Hasil Model GSTARX-JRNN(20,1,1) Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	111
Gambar 4.27	Arsitektur Model GSTARX-JRNN <i>Inflow</i> Rp50.000.....	113
Gambar 4.28	Perbandingan Data Aktual <i>Inflow</i> Rp50.000 dengan Prediksi Hasil Model GSTARX-JRNN(20,1,1) Bobot Seragam <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	114
Gambar 4.29	Arsitektur Model GSTARX-JRNN <i>Inflow</i> Rp20.000.....	118
Gambar 4.30	Perbandingan Data Aktual <i>Inflow</i> Rp20.000 dengan Prediksi Hasil Model GSTARX-JRNN(20,3,1) Bobot Seragam <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	118
Gambar 4.31	Plot MPCCF residual Model TSR <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	121
Gambar 4.32	Perbandingan Data Aktual <i>Outflow</i> Rp100.000 dengan Prediksi Hasil Model MGSTARX Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	127
Gambar 4.33	Perbandingan Data Aktual <i>Outflow</i> Rp50.000 dengan Prediksi Hasil Model MGSTARX Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	128
Gambar 4.34	Perbandingan Data Aktual <i>Outflow</i> Rp20.000 dengan Prediksi Hasil Model MGSTARX Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan).....	129
Gambar 4.35	Arsitektur Model MGSTARX-ERNN(90,2,1) Data <i>Outflow</i> .....	136

Gambar 4.36	Perbandingan Data Aktual <i>Outflow</i> Rp100.000 dengan Prediksi Hasil Model MGSTARX-ERNN(90,2,1) Bobot Seragam <i>in sample</i> (kiri) dan <i>out sample</i> (kanan) .....	138
Gambar 4.37	Perbandingan Data Aktual <i>Outflow</i> Rp50.000 dengan Prediksi Hasil Model MGSTARX-ERNN(90,2,1) Bobot Seragam <i>in sample</i> (kiri) dan <i>out sample</i> (kanan) .....	139
Gambar 4.38	Perbandingan Data Aktual <i>Outflow</i> Rp20.000 dengan Prediksi Hasil Model MGSTARX-ERNN(90,2,1) Bobot Seragam <i>in sample</i> (kiri) dan <i>out sample</i> (kanan) .....	140
Gambar 4.39	Arsitektur Model MGSTARX-JRNN(90,2,1) Data <i>Outflow</i> .....	144
Gambar 4.40	Perbandingan Data Aktual <i>Outflow</i> Rp100.000 dengan Prediksi Hasil Model MGSTARX-JRNN(90,2,1) Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan) .....	144
Gambar 4.41	Perbandingan Data Aktual <i>Outflow</i> Rp50.000 dengan Prediksi Hasil Model MGSTARX-JRNN(90,2,1) Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan) .....	146
Gambar 4.42	Perbandingan Data Aktual <i>Outflow</i> Rp20.000 dengan Prediksi Hasil Model MGSTARX-JRNN(90,2,1) Bobot Korelasi Silang <i>in sample</i> (kiri) dan <i>out sample</i> (kanan) .....	147
Gambar 4.43	Perbandingan Aktual dan Fit Model MGSTARX, MGSTARX-ERNN, MGSTARX-JRNN dengan Model Terbaik <i>Inflow</i> Rp100.000 pada Lima KPw Bank Sentral di Jawa .....	149
Gambar 4.44	Perbandingan Aktual dan Fit Model MGSTARX, MGSTARX-ERNN, MGSTARX-JRNN dengan Model Terbaik <i>Outflow</i> Rp100.000 pada Lima KPw Bank Sentral di Jawa.....	150
Gambar 4.45	Peramalan <i>Inflow</i> Rp100.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada Lima KPw Bank Sentral Provinsi di Jawa.....	152
Gambar 4.46	Peramalan <i>Inflow</i> Rp50.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada Lima KPw Bank Sentral Provinsi di Jawa.....	153
Gambar 4.47	Peramalan <i>Inflow</i> Rp20.000 dengan Model MGSTARX,	

MGSTARX-ERNN, dan MGSTARX-JRNN pada Lima KPw Bank Sentral Provinsi di Jawa .....	154
Gambar 4.48 Peramalan <i>Outflow</i> Rp100.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada Lima KPw Bank Sentral Provinsi di Jawa .....	155
Gambar 4.49 Peramalan <i>Outflow</i> Rp50.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada Lima KPw Bank Sentral Provinsi di Jawa .....	156
Gambar 4.50 Peramalan <i>Outflow</i> Rp20.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada Lima KPw Bank Sentral Provinsi di Jawa .....	157
Gambar 4.51 Nilai sMAPE setiap Langkah Peramalan Data <i>Out Sample</i> <i>Inflow</i> Pecahan Rp100.000 dengan Model MGSTARX, MGSTARX-ERNN dan MGSTARX-JRNN .....	158
Gambar 4.52 Nilai sMAPE setiap Langkah Peramalan Data <i>Out Sample</i> <i>Outflow</i> Pecahan Rp100.000 dengan Model MGSTARX, MGSTARX-ERNN dan MGSTARX-JRNN .....	159

## DAFTAR TABEL

	Halaman
Tabel 2.1 Jarak antar KPw Bank Sentral Wilayah Jawa (km) .....	21
Tabel 2.2 Contoh <i>Activation Function</i> .....	38
Tabel 3.1 Variabel Penelitian (dalam miliar rupiah).....	53
Tabel 3.2 Tanggal Hari Raya Idul Fitri .....	55
Tabel 3.3 Struktur Data Pemodelan Data <i>Inflow</i> dengan MGSTARX-RNN ....	56
Tabel 3.4 Struktur Data Pemodelan Data <i>Outflow</i> dengan MGSTARX-RNN .	57
Tabel 4.1 Statistika Deskriptif Data (miliar Rp) <i>Inflow</i> dan <i>Outflow</i> UPB pada KPw Bank Sentral Provinsi di Jawa .....	67
Tabel 4.2 Nilai RMSE dan sMAPE Pemodelan <i>Inflow</i> UPB dengan Model TSR.....	74
Tabel 4.3 Hasil Uji <i>Ljung Box</i> Residual TSR <i>Inflow</i> dan <i>Outflow</i> UPB pada KPw Bank Sentral Provinsi di Jawa .....	75
Tabel 4.4 Model ARIMAX <i>Inflow</i> dan <i>Outflow</i> Setiap UPB KPw Bank Sentral Provinsi di Jawa .....	76
Tabel 4.5 Nilai RMSE dan sMAPE Pemodelan ARIMAX <i>Inflow</i> dan <i>Outflow</i> Setiap UPB .....	78
Tabel 4.6 Koefisien Korelasi Data <i>Inflow</i> dan <i>Outflow</i> Setiap UPB di lima KPw Bank Sentral Provinsi di Jawa .....	80
Tabel 4.7 Model GSTARX <i>Inflow</i> dan <i>Outflow</i> Setiap UPB KPw Bank Sentral Provinsi di Jawa .....	84
Tabel 4.8 Nilai RMSE Pemodelan GSTARX <i>Inflow</i> Setiap UPB Lima KPw Bank Sentral Provinsi di Jawa .....	84
Tabel 4.9 Nilai sMAPE Pemodelan GSTARX <i>Inflow</i> Setiap UPB	

Lima KPw Bank Sentral Provinsi di Jawa.....	85
Tabel 4.10 Estimasi Parameter GSTARX <i>Inflow</i> Rp100.000 Bobot Seragam....	85
Tabel 4.11 Estimasi Parameter GSTARX <i>Inflow</i> Rp50.000 Bobot Seragam.....	89
Tabel 4.12 Estimasi Parameter GSTARX <i>Inflow</i> Rp20.000 Bobot Seragam.....	92
Tabel 4.13 Hasil Uji <i>Terasvirta</i> Data <i>Inflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	95
Tabel 4.14 Hasil Uji <i>Terasvirta</i> Data <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	96
Tabel 4.15 Nilai Rata-Rata RMSE Model GSTARX-ERNN <i>Inflow</i> Rp100.000 KPw Bank Sentral Provinsi di Jawa .....	97
Tabel 4.16 Nilai Rata-Rata sMAPE Model GSTARX-ERNN <i>Inflow</i> Rp100.000 KPw Bank Sentral Provinsi di Jawa .....	97
Tabel 4.17 Nilai Rata-Rata RMSE Model GSTARX-ERNN <i>Inflow</i> Rp50.000 KPw Bank Sentral Provinsi di Jawa .....	100
Tabel 4.18 Nilai Rata-Rata sMAPE Model GSTARX-ERNN <i>Inflow</i> Rp50.000 KPw Bank Sentral Provinsi di Jawa .....	100
Tabel 4.19 Nilai Rata-Rata RMSE Model GSTARX-ERNN <i>Inflow</i> Rp20.000 KPw Bank Sentral Provinsi di Jawa .....	104
Tabel 4.20 Nilai Rata-Rata sMAPE Model GSTARX-ERNN <i>Inflow</i> Rp20.000 KPw Bank Sentral Provinsi di Jawa .....	104
Tabel 4.21 Nilai Rata-Rata RMSE Model GSTARX-JRNN <i>Inflow</i> Rp100.000 KPw Bank Sentral Provinsi di Jawa .....	108
Tabel 4.22 Nilai Rata-Rata sMAPE Model GSTARX-JRNN <i>Inflow</i> Rp100.000 KPw Bank Sentral Provinsi di Jawa .....	109
Tabel 4.23 Nilai Rata-Rata RMSE Model GSTARX-JRNN <i>Inflow</i> Rp50.000 KPw Bank Sentral Provinsi di Jawa .....	112
Tabel 4.24 Nilai Rata-Rata sMAPE Model GSTARX-JRNN <i>Inflow</i> Rp50.000 KPw Bank Sentral Provinsi di Jawa .....	112
Tabel 4.25 Nilai Rata-Rata RMSE Model GSTARX-JRNN <i>Inflow</i> Rp20.000 KPw Bank Sentral Provinsi di Jawa .....	116
Tabel 4.26 Nilai Rata-Rata sMAPE Model GSTARX-JRNN <i>Inflow</i> Rp20.000 KPw Bank Sentral Provinsi di Jawa .....	116

Tabel 4.27 Koefisien Korelasi Data <i>Inflow</i> dan <i>Outflow</i> antar Uang Pecahan Besar (UPB) KPw Bank Sentral Provinsi di Jawa .....	120
Tabel 4.28 Nilai RMSE Model MGSTARX <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	121
Tabel 4.29 Nilai sMAPE Model MGSTARX <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	122
Tabel 4.30 Estimasi Parameter Model MGSTARX <i>Outflow</i> dengan Bobot Korelasi Silang .....	123
Tabel 4.31 Nilai Rata-Rata RMSE Model MGSTARX-ERNN <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	135
Tabel 4.32 Nilai Rata-Rata sMAPE Model MGSTARX-ERNN <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	135
Tabel 4.33 Nilai Rata-Rata RMSE Model MGSTARX-JRNN <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	141
Tabel 4.34 Nilai Rata-Rata sMAPE Model MGSTARX-JRNN <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	142
Tabel 4.35 Nilai Rata-Rata sMAPE Pemodelan <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	148
Tabel 4.36 Model Terpilih Pemodelan <i>Inflow</i> dan <i>Outflow</i> UPB KPw Bank Sentral Provinsi di Jawa .....	148

*Halaman ini sengaja dikosongkan*

# BAB 1

## PENDAHULUAN

### 1.1 Latar Belakang

Deret waktu (*Time Series*) adalah serangkaian observasi yang diambil secara berurutan dalam suatu waktu tertentu (Wei, 2006). Peramalan data *time series* dapat dilakukan dengan pendekatan *univariat* maupun *multivariat*. Salah satu model *univariat* adalah model *Autoregressive Integrated Moving Average* (ARIMA) yang dikembangkan oleh Box dan Jenkins (Box, Jenkins, dan Reinsel, 2008). Peramalan kini tidak hanya mempertimbangkan faktor waktu, tetapi juga pengaruh dari variabel yang lain. Karena itu banyak penelitian yang melakukan peramalan dengan pendekatan *multivariate*. Salah satu model dengan pendekatan *multivariate* adalah *Vector Autoregressive* (VAR). Model VAR mengalami perkembangan sejak ditemukan oleh Quenouille (1957) dalam Goojier dan Hyndman (2006). Model ini dapat menjelaskan hubungan antara variabel tertentu di suatu waktu dengan pengamatan pada variabel itu sendiri pada waktu-waktu sebelumnya, dan juga keterkaitannya dengan pengamatan pada variabel lain pada waktu-waktu sebelumnya.

Data *time series* tidak hanya berdimensi waktu namun juga mempunyai dimensi ruang yang biasa disebut dengan data *space-time*. Model *space time* pertama kali diperkenalkan oleh Cliff dan Ord (1975) dikenal dengan model *Space Time Autoregressive* (STAR) dan model *Space Time Autoregressive Moving Average* (STARMA). Model STARMA merupakan model dengan adanya pengaruh waktu sebelumnya pada model *autoregressive* maupun *moving average* baik dalam ruang atau waktu dan digunakan untuk pemodelan yang menunjukkan adanya autokorelasi spasial (Pfeifer & Deutsch, 1980). Model STAR mengasumsikan setiap lokasi homogen dan menghasilkan nilai parameter sama untuk setiap lokasi sehingga belum dapat menjelaskan hubungan pada lokasi dan waktu yang berbeda pada data *space-time*.

Ruchjana (2002) mengembangkan model STAR menjadi model *Generalized Space Time Autoregressive* (GSTAR) yang mengasumsikan parameter model bervariasi pada setiap lokasi. Sehingga parameter model GSTAR lebih fleksibel

untuk diterapkan pada lokasi yang heterogen. Pengkajian dan pengembangan teori GSTAR telah dilakukan oleh beberapa peneliti diantaranya, Borovkova, Lopuhaa, dan Nurani (2002) mengkaji model GSTAR dengan menggunakan bobot eksperimental. Hal ini dilakukan untuk meneliti penentuan bobot lokasi yang optimal. Selanjutnya penelitian yang dilakukan oleh Suhartono dan Subanar (2006) mengenai penentuan bobot optimal dalam model GSTAR dengan menggunakan inferens statistik dari korelasi silang (*cross correlation*) antar lokasi pada waktu yang bersesuaian. Beberapa penelitian tentang penerapan GSTAR di berbagai bidang seperti Wutsqa dan Suhartono (2010) mengaplikasikan model VAR-GSTAR pada data wisata mancanegara di Yogyakarta dan Bali, dan penelitian Setiawan, Suhartono dan Prastuti (2016) yang melakukan pemodelan GSTAR dengan estimasi menggunakan metode GLS (*Generalized Least Square*) pada data simulasi dan data kedatangan wisatawan di empat lokasi di Indonesia yaitu Jakarta, Bali, Surabaya dan Surakarta.

Pemodelan GSTAR belum dapat digunakan untuk pengamatan di berbagai lokasi dengan beberapa variabel yang berbeda di lokasi yang sama. Padahal dimungkinkan suatu variabel di suatu lokasi dipengaruhi oleh variabel lainnya di lokasi yang sama. Penelitian pemodelan kasus *multivariate* dengan kasus *space-time* dilakukan oleh Ma, Chen dan Chen (2017) memodelkan frekuensi kecelakan berdasarkan tingkat cedera yang diderita di sebagian besar jalan tol di Colorado yang memberikan hasil bahwa model *multivariate space-time* mempunyai performa yang lebih baik dibandingkan alternatif model lainnya. Nahdliyah, Suhartono dan Akbar (2019) melakukan penelitian dengan menggunakan *Multivariate GSTAR* (MGSTAR) untuk meramalkan data pada tiga stasiun SUF dan dua variabel pencemar yaitu CO dan PM<sub>10</sub> di Surabaya.

Aktivitas peramalan dalam praktiknya baik kasus *univariate* maupun *multivariate* sering melibatkan variabel eksogen atau prediktor yang biasa disebut model ARIMAX untuk pendekatan *univariate* dan VARX untuk *multivariate*, sedangkan untuk data *space-time* dikembangkan model GSTARX. Variabel eksogen tersebut dapat berupa *series* data berskala numerik atau dapat berupa variabel *dummy* berskala kategorik. Penelitian model GSTARX pernah dilakukan oleh Suhartono, Gazali, & Prastyo (2018) mengenai pemodelan VARX dan

GSTARX pada data *inflow* dan *outflow* di Bali, Nusa Tenggara Timur, dan Nusa Tenggara Barat dengan menggunakan variabel *dummy* berupa efek variasi kalender yang terdiri dari kejadian Hari Raya Idul Fitri, Hari Raya Galungan, dan Hari Raya Nyepi. Prosedur pada penelitian tersebut diawali dengan regresi *time series* menggunakan variabel-variabel *dummy* sebagai variabel prediktor. Kemudian, residual dari model regresi *time series* dimodelkan dengan menggunakan GSTAR.

Tidak menutup kemungkinan bahwa suatu data terbentuk dari struktur linier dan nonlinier sekaligus (Zhang, 2003). Kemudian diperkenalkan oleh Zhang (2003) suatu model *hybrid* dengan mengombinasikan ARIMA sebagai komponen linier dan ANN sebagai komponen nonlinier yang memberikan hasil bahwa model *hybrid* ARIMA-ANN dapat meningkatkan akurasi ramalan. Begitupun dengan GSTAR juga dapat dikembangkan dengan model *hybrid*. Beberapa penelitian dengan model *hybrid* diantaranya, Suhartono, Prastyo, Kuswanto, & Lee (2018) membandingkan performa pemodelan VAR, GSTAR, VAR-FFNN, dan GSTAR-FFNN pada data produksi minyak di Jawa Timur, penelitian oleh Diani, Setiawan & Suhartono (2013) mengenai peramalan curah hujan di Kabupaten Malang dengan menggunakan VAR-FFNN dan GSTAR-FFNN. Penelitian dengan variabel lebih dari satu di setiap lokasi dilakukan oleh Pusporani, Suhartono, & Prastyo (2018) yang mengembangkan model MGSTAR-ANN pada kasus polusi udara di Surabaya. Penelitian-penelitian tersebut memberikan hasil yang menunjukkan bahwa model *hybrid* nonlinier yaitu VAR-FFNN, GSTAR-FFNN, dan MGSTAR-ANN memberikan hasil yang lebih akurat daripada pemodelan individu berupa VAR, GSTAR, dan MGSTAR. Model *hybrid* nonlinier dengan data *space-time* berkembang dengan melibatkan variable eksogen seperti penelitian yang dilakukan oleh Suhartono, Dana, & Rahayu (2019) yang mengembangkan model GSTARX-NN pada kasus *inflow* dan *outflow* Bank Sentral di Jawa Timur.

Salah satu model NN selain FFNN (*Feedforward Neural Network*) adalah *Recurrent Neural Network* (RNN). RNN adalah jaringan yang mempunyai koneksi *feedback*. Pada model RNN, *neuron* dihubungkan kembali dengan neuron yang lain dan arah informasi menjadi multidireksional sehingga aktivasi *neuron*

dapat mengalir dalam system *loop* (Lewis, 2016). Arsitektur yang biasa digunakan pada RNN diantaranya *Elman Recurrent Neural Network (ERNN)* dan *Jordan Recurrent Neural Network (JRNN)*.

*Elman Recurrent Neural Network (ERNN)* adalah jaringan syaraf tiruan yang memiliki koneksi umpan balik sederhana dari lapisan tersembunyi menuju lapisan konteks (*context layer*) yang terdiri dari operator-operator *unit time delays* (Haykin, 2009). *Context layer* pada model RNN berperan untuk mengingat *state* sebelumnya yang berasal dari *hidden layer*, sehingga *hidden layer* memiliki peran untuk memetakan kedua jaringan yaitu menuju ke *output layer* dan *input* dari *context layer* (Elman, 1990). Penelitian menggunakan model ERNN dilakukan oleh Suhartono & Endharta (2009) yang berkaitan tentang peramalan konsumsi listrik jangka pendek dengan membandingkan performa *Double Seasonal ARIMA* dan Elman RNN. Hasil penelitian menunjukkan bahwa model Elman RNN cenderung menghasilkan peramalan yang lebih baik pada peramalan konsumsi listrik ini. Selain ERNN model *recurrent* lainnya adalah *Jordan Recurrent Neural Network (JRNN)*. Model JRNN memiliki pola kerja yang sama dengan ERNN, namun perbedaannya adalah *neuron* pada *context layer* dialiri informasi melalui *output layer* bukan *hidden layer* seperti pada ERNN (Lewis, 2016). Pada sebuah penelitian yang dilakukan oleh Putri, Firdaus, & Sabilla (2018) menggunakan JRNN untuk peramalan jangka pendek konsumsi listrik yang menghasilkan bahwa akurasi peramalan JRNN lebih baik dibandingkan model FFNN.

Bank Sentral sebagai satu-satunya lembaga yang berwenang mengedarkan uang kartal kepada masyarakat harus mampu melakukan pengelolaan kebutuhan uang kartal di masyarakat, termasuk pengelolaan *inflow* dan *outflow* uang kartal (Bank Indonesia, 2012). Salah satu bentuk pengelolaan uang kartal adalah perencanaan mengenai kebutuhan uang dimasa mendatang dengan melakukan *forecasting* atau peramalan terhadap *inflow* dan *outflow*. Indonesia sebagai negara dengan mayoritas penduduk Muslim menyebabkan banyak data ekonomi 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, sementara kalender Islam memengaruhi *inflow* dan *outflow* pada bulan sekitar Hari Raya Idul Fitri.

Penelitian mengenai peramalan *inflow* dan *outflow* uang kartal telah banyak dilakukan, baik secara univariat maupun multivariat. Peramalan *inflow* dan *outflow* uang kartal secara univariat telah dilakukan oleh Suhartono dkk., (2018) dengan menggunakan *hybrid Quantile Regression Neural Network* (QRNN) pada data *inflow* dan *outflow* nasional. Sedangkan peramalan *inflow* dan *outflow* secara multivariat yang melibatkan efek *spatio-temporal* telah dilakukan oleh Suhartono, Gazali, & Prastyo (2018) dengan menggunakan metode VARX dan GSTARX untuk data *inflow* dan *outflow* di Bali, Nusa Tenggara Timur, dan Nusa Tenggara Barat. Hasil penelitian menunjukkan bahwa perkembangan *inflow* dan *outflow* dipengaruhi oleh efek Hari Raya Idul Fitri seperti yang telah dijelaskan Sigalingging, Setiawan, & Sihaloho (2004) bahwa faktor hari raya keagamaan mempengaruhi pertumbuhan *inflow* dan *outflow*.

Selama periode Ramadan dan Idul Fitri, sebaran *outflow* tertinggi berada di Pulau Jawa non Jakarta, dilihat secara pecahan, *outflow* untuk uang pecahan besar mencapai 92,9%, sedangkan uang pecahan kecil mencapai 7,1% (Media Indonesia, 2018). Untuk sebaran wilayah *outflow* tertinggi yaitu di Jawa Barat, Jawa Tengah dan Jawa Timur mencapai 38,4%. Sebaran uang kartal Jabodetabek sebesar 22,8%, Sumatera 19,9% dan kawasan timur 18,9% (Media Indonesia, 2018). Karena itu, studi kasus yang digunakan dalam penelitian ini adalah data *inflow* dan *outflow* Uang Pecahan Besar (UPB) di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, dan Jakarta.

Dengan demikian, pada penelitian ini digunakan metode utama yaitu *Hybrid Multivariate GSTARX-RNN* untuk meramalkan data *inflow* dan *outflow* Uang Pecahan Besar (UPB) di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, dan Jakarta. Metode *Multivariate GSTARX* digunakan sebagai pemodelan *space-time* yang melibatkan variabel eksogen yaitu efek variasi kalender Hari Raya Idul Fitri yang telah diketahui mempengaruhi pemodelan *inflow* dan *outflow*. Sedangkan metode RNN digunakan untuk meningkatkan akurasi model karena pola data *inflow* dan *outflow* yang cenderung berpola nonlinier.

## **1.2 Rumusan Masalah**

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah yang dikaji dalam penelitian ini adalah sebagai berikut:

1. Bagaimana kebaikan model *hybrid MGSTAR-RNN* dibandingkan dengan model MGSTAR dalam memodelkan data simulasi berupa data *time series* multivariat lokasi dan variabel?
2. Bagaimanakah model *Multivariate GSTARX*, *hybrid Multivariate GSTARX-ERNN*, dan *hybrid Multivariate GSTARX-JRNN* dalam peramalan data *inflow* dan *outflow* uang kartal pecahan besar (UPB) di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta?
3. Bagaimana hasil dan perbandingan akurasi ramalan menggunakan model *hybrid Multivariate GSTARX-ERNN* dan *hybrid Multivariate GSTARX-JRNN* pada data *inflow* dan *outflow* uang kartal pecahan besar (UPB) di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta?

## **1.3 Tujuan Penelitian**

Tujuan yang ingin dicapai dalam penelitian ini berdasarkan uraian rumusan masalah adalah sebagai berikut:

1. Mendapatkan hasil kebaikan model *hybrid MGSTAR-RNN* melalui kajian simulasi data *time series* multivariat lokasi dan variabel
2. Mendapatkan model *Multivariate GSTARX*, *hybrid Multivariate GSTARX-ERNN*, dan *hybrid Multivariate GSTARX-JRNN* dalam peramalan data *inflow* dan *outflow* uang kartal pecahan besar KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta.
3. Mendapatkan hasil dan membandingkan akurasi ramalan menggunakan model *hybrid Multivariate GSTARX-ERNN* dan *hybrid Multivariate GSTARX-JRNN* pada data *inflow* dan *outflow* uang kartal pecahan besar di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta.

## **1.4 Manfaat Penelitian**

Hasil penelitian ini diharapkan mampu memberikan manfaat bagi berbagai pihak, diantaranya:

1. Dapat menambah pengetahuan dan wawasan keilmuan penerapan metode statistika, khususnya peramalan *spatio temporal* data yang melibatkan variable eksogen berupa efek variasi kalender menggunakan model *hybrid* dengan tujuan meningkatkan akurasi.
2. Dapat menjadi rekomendasi bagi Bank Indonesia, khususnya KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta dalam monitoring peredaran uang kartal pecahan besar.

## **1.5 Batasan Masalah**

Batasan masalah dalam penelitian adalah sebagai berikut

1. Kajian simulasi yang dilakukan untuk mengetahui performa model MGSTAR-RNN dibanding model MGSTAR dan menggunakan data *in sample*
2. Sumber data yang digunakan adalah data *inflow* dan *outflow* uang kertas pecahan besar (UPB) yaitu pecahan senilai Rp 100.000,00; Rp 50.000,00 dan Rp 20.000,00
3. Lokasi yang dipilih sebagai pengamatan adalah KPw Bank Sentral di Pulau Jawa yaitu Surabaya, Semarang, Yogyakarta, Bandung, Jakarta.
4. Variabel prediktor yang digunakan untuk pemodelan MGSTARX berupa efek variasi kalender hari raya Idul Fitri.
5. Orde spasial yang digunakan adalah orde satu yang mengasumsikan bahwa wilayah kerja KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta berdekatan secara langsung.
6. Pada pemodelan *hybrid* dengan Elman RNN dan Jordan RNN jumlah neuron yang digunakan pada *hidden layer* adalah 1, 2, 3, 4, 5, 10, 15.
7. Fungsi aktivasi yang digunakan pada pemodelan *hybrid* dengan Elman RNN dan Jordan RNN adalah fungsi *Hyperbolic Tangent* untuk *hidden layer* dan fungsi linier untuk *output layer*.

*Halaman ini sengaja dikosongkan*

## BAB 2

### TINJAUAN PUSTAKA

Bagian ini akan menjelaskan teori yang berkaitan dengan analisis penelitian yang meliputi model ARIMA, regresi *time series*, model GSTAR, model *Multivariate GSTAR*, model RNN, model *hybrid*.

#### 2.1 Model Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA merupakan suatu model *univariate time series* yang dapat digunakan pada data berpola tren, musiman atau non musiman, Model ARIMA terdiri dari model *Autoregressive* (AR) dan *Moving Average* (MA).

##### 1. Model *Autoregressive* (AR)

Model AR merepresentasikan suatu proses  $Z_t$  yang berhubungan dengan  $Z$  pada waktu ke- $k$  sebelumnya ( $Z_{t-k}$ ) ditambah nilai residual ( $a_t$ ). Model AR ditulis pada persamaan 2.1 dan 2.2

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t \quad (2.1)$$

atau

$$\phi_p(B) \dot{Z}_t = a_t \quad (2.2)$$

dengan  $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$  dan  $\dot{Z}_t = Z_t - \mu$ ,  $a_t$  merupakan residual yang sudah memenuhi asumsi *white noise* yaitu  $E(a_t) = 0$  dan  $Var(a_t) = \sigma_a^2$

##### 2. Model *Moving Average* (MA)

Model MA merupakan representasi proses  $Z_t$  dengan nilai residual  $a_t$  pada waktu  $t$  sebelumnya. Persamaan model MA ditulis pada persamaan 2.3 dan 2.4

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.3)$$

atau

$$\dot{Z}_t = \theta_q(B) a_t \quad (2.4)$$

dengan  $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$  dan  $a_t$  adalah residual yang memenuhi asumsi *white noise*.

### 3. Model Autoregressive Moving Average (ARMA)

Model ARMA adalah gabungan dari model AR dan MA dengan model seperti pada persamaan 2.5 dan 2.6

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.5)$$

atau

$$\phi_p(B) \dot{Z}_t = \theta_q(B) a_t \quad (2.6)$$

dengan

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \text{ dan } \theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q),$$

$a_t$  adalah residual yang memenuhi asumsi *white noise*.

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

Bentuk umum dari model ARIMA  $(p,d,q)$  adalah seperti pada persamaan 2.7 (Wei, 2006):

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

dengan

$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$  adalah koefisien komponen AR non musiman dengan orde  $p$

$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$  adalah koefisien komponen MA non musiman dengan orde  $q$

$(1-B)^d = \text{differencing}$  dengan orde  $d$

$a_t = \text{nilai residual pada waktu ke-}t \text{ yang sudah memenuhi asumsi white noise}$

## 2.2 Regresi Time Series

Data *time series* memiliki pola komponen historis yang dapat digunakan dalam penyusunan ramalan. Komponen-komponen tersebut seperti *trend*, *cycle*, variasi musiman, dan fluktuasi tidak teratur (Bowerman, O'Connell, dan Koehler, 2005). Ada tiga komponen utama yang sering digunakan dalam pemodelan regresi

*time series*, seperti yang ditulis pada persamaan 2.8 (Bowerman dan O'Connell, 1993)

$$Y_t = T_t + S_t + \varepsilon_t \quad (2.8)$$

dengan

$Y_t$  : nilai observasi data *time series* pada periode ke- $t$

$T_t$  : nilai komponen *trend* pada periode ke- $t$

$S_t$  : nilai komponen musiman pada periode ke- $t$

$\varepsilon_t$  : nilai *error* pada periode ke- $t$

Salah satu cara memodelkan pola musiman yaitu dengan menggunakan variable *dummy*. Komponen musiman didefinisikan dalam persamaan 2.9

$$y_t = \beta_0 + \beta_1 S_{1,t} + \beta_2 S_{2,t} + \dots + \beta_s S_{s,t} + a_t \quad (2.9)$$

dengan  $S_{1,t}, S_{2,t}, \dots, S_{s,t}$  merupakan variable *dummy* dan  $\beta_{1,t}, \beta_{2,t}, \dots, \beta_{s,t}$  parameter variabel *dummy*. Misalkan pola musiman adalah bulanan maka akan ada 12 variabel *dummy*. Jika data memiliki pola komponen *trend*, maka persamaan regresi ditulis pada persamaan 2.10

$$y_t = \beta + \beta_1 t + a_t \quad (2.10)$$

dengan  $a_t$  adalah *error* komponen yang diasumsikan identic, indepependen, dan berdistribusi normal dengan nilai rata-rata 0 dan varians  $\sigma_a^2$ .

### 2.3 Variasi Kalender

Model variasi kalender adalah model *time series* yang digunakan untuk meramalkan data berdasarkan pola musiman dengan periode bervariasi. Untuk 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).

Model variasi kalender dapat dimodelkan dengan menggunakan regresi dengan menambahkan variable *dummy*. Model regresi untuk data dengan variasi kalender ditulis pada persamaan 2.11

$$y_t = \beta_0 + \beta_1 CV_{1,t} + \beta_2 CV_{2,t} + \dots + \beta_p CV_{p,t} + a_t \quad (2.11)$$

dengan  $CV_{p,t}$  adalah variable *dummy* untuk efek variasi kalender ke- $p$ . Banyaknya efek kalender variasi dapat diidentifikasi berdasarkan pola dari data tersebut (Lee, Suhartono, dan Hamzah, 2010).

Secara umum, model variasi kalender berdasarkan metode regresi jika terdapat komponen *trend*, *seasonal*, dan *dummy* efek variasi kalender pada data maka dapat ditulis pada persamaan 2.12

$$y_t = \delta t + \gamma_1 S_{1,t} + \gamma_2 S_{2,t} + \dots + \gamma_s S_{s,t} + \beta_1 CV_{1,t} + \beta_2 CV_{2,t} + \dots + \beta_p CV_{p,t} + \varepsilon_t \quad (2.12)$$

dengan  $\beta$  adalah koefisien dari efek variasi kalender,  $\delta$  adalah koefisien komponen *trend*, dan  $\gamma$  adalah koefisien komponen *seasonal*.

## 2.4 Multivariate Time Series

*Multivariate time series* merupakan analisis data *time series* yang mempertimbangkan variabel *time series* lainnya secara simultan (Tsay, 2014). Seperti pada *univariate time series*, analisis dalam *multivariate time series* mensyaratkan stasioneritas data yang dapat dilihat dari plot *Matrix Cross Correlation Function* (MCCF) dan *Matrix Partial Cross Correlation Function* (MPCCF). Jika plot MCCF turun secara lambat maka dapat dikatakan data belum stasioner dalam rata-rata sehingga perlu dilakukan *differencing*. Sedangkan stasioneritas dalam varians dilihat dari plot Box-Cox, jika data belum stasioner maka perlu dilakukan transformasi data hingga data memenuhi asumsi stasioner terhadap varians (Wei, 2006).

### a. Matrix Cross Correlation Function (MCCF)

Suatu vektor *time series* dengan observasi sebanyak  $n$ , yaitu  $Z_1, Z_2, \dots, Z_n$  dapat dihitung matrik korelasi sampelnya seperti persamaan 2.13 (Wei, 2006).

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)] \quad (2.13)$$

dengan  $\hat{\rho}_{ij}(k)$  adalah sampel korelasi silang pada komponen *series* ke- $i$  dan ke- $j$  yang dinyatakan dalam persamaan 2.14

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,t+k} - \bar{Z}_j)}{\left[ \sum_{t=1}^n (Z_{i,t} - \bar{Z}_i)^2 \sum_{t=1}^n (Z_{j,t} - \bar{Z}_j)^2 \right]^{1/2}} \quad (2.14)$$

$\bar{Z}_i$  dan  $\bar{Z}_j$  adalah rata-rata sampel yang bersesuaian dengan komponen *series*. Hannan (1970) dalam Wei (2006) menunjukkan untuk proses stasioneritas sebuah vektor,  $\hat{\rho}(k)$  adalah estimator konsisten yang berdistribusi asimtotik normal. Bartlett (1966) dalam Wei (2006) telah menurunkan varians dan kovarians dari besaran korelasi silang yang diperoleh dari sampel. Jika dua *series*  $Z_i$  dan  $Z_j$  tidak berkorelasi atau  $\hat{\rho}_{ij}(k)=0$  untuk  $|k|>q$  maka didapatkan persamaan 2.15

$$Var[\hat{\rho}_{ij}(k)] \approx \frac{1}{n-k} \left[ 1 + 2 \sum_{s=1}^q \rho_{ii}(s) \rho_{jj}(s) \right] \quad (2.15)$$

Ketika  $Z_i$  dan  $Z_j$  adalah suatu deret yang *white noise*, maka akan diperoleh persamaan 2.16 dan 2.17

$$\text{cov}[\hat{\rho}_{ij}(k), \hat{\rho}_{ij}(k+s)] \approx \frac{1}{n-k} \quad (2.16)$$

dan

$$\text{var}[\hat{\rho}_{ij}(k)] \approx \frac{1}{n-k} \quad (2.17)$$

untuk ukuran sampel yang besar,  $(n-k)$  dalam persamaan 2.17 biasanya diganti dengan  $n$ .

MCCF digunakan untuk mengidentifikasi orde MA (*Moving Average*). Namun bentuk matriks dan grafik akan semakin kompleks seiring dengan meningkatnya dimensi vektor. Untuk mengatasi hal tersebut Tiao dan Box (1981) dalam Wei (2006) memperkenalkan sebuah metode untuk mempermudah analisis korelasi dari sampel. Metode yang digunakan menggunakan simbol (+), (-) dan (.) pada baris ke- $i$  dan kolom ke- $j$ . Ketentuan metode yang digunakan adalah sebagai berikut

1. Simbol (+) menunjukkan komponen  $(i, j)$  mempunyai korelasi yang positif dengan nilai  $\hat{\rho}_{ij}(k)$  lebih besar dari 2 kali nilai estimasi *standard error* (SE).
2. Simbol (-) menunjukkan komponen  $(i, j)$  mempunyai korelasi yang negatif dengan nilai  $\hat{\rho}_{ij}(k)$  lebih kecil dari  $-2$  kali nilai estimasi *standard error* (SE).
3. Simbol (.) menunjukkan komponen  $(i, j)$  mempunyai korelasi dengan nilai  $\hat{\rho}_{ij}(k)$  berada diantara  $\pm 2$  kali nilai estimasi *standard error* (SE).

Data *series* dianggap telah stasioner ketika plot MCCF yang terbentuk mempunyai tanda (+) dan (-) serta hampir semua tanda bersimbol (.) .

Variabel	Lag		
	0	1	2
$z_1$	++.	+++	...-
$z_2$	+++	.+.	.-.
$z_3$	.++	.+.	...

**Gambar 2.1** Contoh Plot MCCF untuk Tiga Variabel

### b. Matrix Partial Cross Correlation Function (MPCCF)

Identifikasi pada model AR (*Autoregressive*) dalam *univariate time series* adalah dengan menggunakan PACF (*Partial Autocorrelation Function*). Tiao dan Box (1981) dalam Wei (2006) melakukan generalisasi dari konsep PACF ke dalam bentuk vektor *time series*. Matriks *autoregressive* parsial lag  $k$  yang dinotasikan dengan  $\mathbf{P}(k)$  merupakan koefisien matriks terakhir ketika data diterapkan pada proses *vector autoregressive* dengan orde  $k$ . Dalam regresi linier *multivariate*  $\mathbf{P}(k)$  dinotasikan dengan  $\Phi_{k,k}$ , seperti pada persamaan 2.18

$$\mathbf{Z}_{t+k} = \Phi_{k,1}\mathbf{Z}_{t+k-1} + \Phi_{k,2}\mathbf{Z}_{t+k-2} + \dots + \Phi_{k,k}\mathbf{Z}_t + \mathbf{e}_{k,t+k}. \quad (2.18)$$

Heyse dan Wei (1985a, b) dalam Wei (2006) memperluas definisi parsial autokorelasi univariat menjadi vektor *time series* dan memperoleh matrik korelasi antara  $\mathbf{Z}_t$  dan  $\mathbf{Z}_{t+k}$  setelah menghilangkan dependensi linier dari masing-masing  $\mathbf{Z}_{t+1}, \mathbf{Z}_{t+2}, \dots, \mathbf{Z}_{t+k-1}$ . Matrik korelasi yang didefinisikan sebagai korelasi antar vektor *residual* memiliki persamaan 2.19 dan 2.20

$$\begin{aligned}\mathbf{u}_{k-1,t+k} &= \mathbf{Z}_{t+k} - \mathbf{a}_{k-1,1} \mathbf{Z}_{t+k-1} - \cdots - \mathbf{a}_{k-1,k-1} \mathbf{Z}_{t+1} \\ &= \begin{cases} \mathbf{Z}_{t+k} - \sum_{l=1}^{k-1} \mathbf{a}_{k-1,l} \mathbf{Z}_{t+k-l}, & k \geq 2, \\ \mathbf{Z}_{t+1}, & k = 1, \end{cases} \quad (2.19)\end{aligned}$$

$$\begin{aligned}\mathbf{v}_{k-1,t} &= \mathbf{Z}_t - \mathbf{\beta}_{k-1,1} \mathbf{Z}_{t+1} - \cdots - \mathbf{\beta}_{k-1,k-1} \mathbf{Z}_{t+k-1} \\ &= \begin{cases} \mathbf{Z}_t - \sum_{l=1}^{k-1} \mathbf{\beta}_{k-1,l} \mathbf{Z}_{t+l}, & k \geq 2, \\ \mathbf{Z}_t, & k = 1. \end{cases} \quad (2.20)\end{aligned}$$

Matriks koefisien regresi linier multivariat  $\alpha_{k-1,l}$  dan  $\beta_{k-1,l}$  diminimalisasi menjadi

$E[\mathbf{u}_{k-1,t+k}]^2$  dan  $E[\mathbf{v}_{k-1,t}]^2$ . dengan persamaan minimumnya adalah persamaan

2.21 dan 2.22

$$\begin{aligned}\mathbf{A}(k) \mathbf{a}'(k) &= \mathbf{c}(k) \\ \mathbf{A}(k) \mathbf{\beta}'(k) &= \mathbf{b}(k) \quad (2.21)\end{aligned}$$

$$\left[ \begin{array}{cccc} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(k-2) \\ \Gamma(1) & \Gamma(0) & \cdots & \Gamma'(k-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(k-2) & \Gamma(k-3) & \cdots & \Gamma(0) \end{array} \right] \left[ \begin{array}{c} \mathbf{a}'_{k-1,1} \\ \mathbf{a}'_{k-1,2} \\ \vdots \\ \mathbf{a}'_{k-1,k-1} \end{array} \right] = \left[ \begin{array}{c} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(k-1) \end{array} \right] \quad (2.22)$$

untuk  $k \geq 2$ , didapatkan nilai  $\mathbf{A}(k)$ ,  $\mathbf{b}(k)$ ,  $\mathbf{c}(k)$  dan  $\mathbf{a}'(k)$  serta  $\mathbf{\beta}'(k)$  sebagai berikut

$$\begin{aligned}\mathbf{A}(k) &= \left[ \begin{array}{cccc} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(k-2) \\ \Gamma(1) & \Gamma(0) & \cdots & \Gamma'(k-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(k-2) & \Gamma(k-3) & \cdots & \Gamma(0) \end{array} \right], \quad \mathbf{b}(k) = \left[ \begin{array}{c} \Gamma'(k-1) \\ \Gamma'(k-2) \\ \vdots \\ \Gamma'(1) \end{array} \right], \\ \mathbf{c}(k) &= \left[ \begin{array}{c} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(k-1) \end{array} \right] \text{ dan } \mathbf{a}(k) = \left[ \begin{array}{c} \mathbf{a}'_{k-1,1} \\ \mathbf{a}'_{k-1,2} \\ \vdots \\ \mathbf{a}'_{k-1,k-1} \end{array} \right] \text{ serta } \mathbf{\beta}(k) = \left[ \begin{array}{c} \mathbf{\beta}'_{k-1,k-1} \\ \mathbf{\beta}'_{k-1,k-2} \\ \vdots \\ \mathbf{\beta}'_{k-1,1} \end{array} \right].\end{aligned}$$

sehingga  $\text{var}(\mathbf{u}_{k-1,t+k})$  dapat ditulis sebagai  $\mathbf{V}_u(k)$ ,  $\text{var}(\mathbf{v}_{k-1,t})$  adalah  $\mathbf{V}_v(k)$  dan  $\text{cov}(\mathbf{v}_{k-1,t}, \mathbf{u}_{k-1,t+k})$  sebagai  $\mathbf{V}_{vu}(k)$ . Ketika  $k=1$  maka  $\mathbf{V}_u(1) = \mathbf{V}_v(1) = \Gamma(0)$  dan  $\mathbf{V}_{uv}(k) = \Gamma(1)$  karena tidak ada vektor yang berpengaruh antara  $\mathbf{Z}_t$  dan  $\mathbf{Z}_{t+1}$ .

Heyse dan Wei (1985a, 1985b) dalam Wei (2006) mendefinisikan persamaan untuk matriks autokorelasi lag parsial pada lag  $s$  pada persamaan 2.23

$$\mathbf{P}(k) = [\mathbf{D}_v(k)]^{-1} \mathbf{V}_{uv}(k) [\mathbf{D}_u(k)]^{-1} \quad (2.23)$$

dengan  $\mathbf{D}_v(k)$  dan  $\mathbf{D}_u(k)$  adalah matriks diagonal yang mana elemen diagonal ke- $i$  merupakan akar dari elemen diagonal ke- $i$  dari  $\mathbf{V}_v(k)$  dan  $\mathbf{V}_u(k)$ .

Tiao dan Box (1981) dalam Wei (2006) menotasikan nilai MPCCF dengan simbol (+), (-) dan (.). Ketika nilai MPCCF lebih besar dari pada  $2/\sqrt{n}$  maka simbol yang digunakan adalah (+). Simbol (-) ketika nilai MCCF kurang dari  $-2/\sqrt{n}$  dan simbol (.) ketika nilai MPCCF berada diantara  $-2/\sqrt{n}$  dan  $2/\sqrt{n}$ .

#### 2.4.1 Model Space Time Autoregressive (STAR)

Cliff dan Ord (1975) pertama kali mengembangkan model *space-time* yang dikenal dengan STAR (*Space Time Autoregressive*) dan STARMA (*Space Time Autoregressive Moving Average*). Sama seperti model VAR, model STAR juga mempunyai karakteristik dependensi linier dalam lokasi dan waktu.

Jika  $\mathbf{Z}_t$  adalah sebuah vektor dari pengamatan waktu ke- $t$  yang berukuran  $(N \times 1)$ , maka model STARMA dari Pfeiffer dan Deustch (1980a) adalah seperti persamaan 2.24

$$\dot{\mathbf{Z}}_t = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \phi_{kl} \mathbf{W}^{(l)} \dot{\mathbf{Z}}_{t-k} - \sum_{k=1}^q \sum_{l=0}^{m_k} \theta_{kl} \mathbf{W}^{(l)} \mathbf{a}_{t-k} + \mathbf{a}_t \quad (2.24)$$

dengan,

- $p$  : orde *autoregressive*,
- $q$  : orde *moving average*,
- $\lambda_k$  : orde spasial dari struktur *autoregressive* ke- $k$ ,
- $m_k$  : orde spasial dari struktur *moving average* ke- $k$ ,
- $\phi_{kl}$  : parameter *autoregressive* pada lag waktu  $k$  dan lag spasial  $l$ ,
- $\theta_{kl}$  : parameter *moving average* pada lag waktu  $k$  dan lag spasial  $l$ ,
- $\mathbf{W}^{(l)}$  : matriks bobot berukuran  $(N \times N)$  pada orde spasial  $l$ ,
- $\mathbf{a}(t)$  : vektor error pada waktu  $t$  yang berdistribusi normal multivariat, dengan

$$E[\mathbf{a}_t] = 0 \text{ dan } E[\mathbf{a}_t \mathbf{a}'_{t+k}] = \begin{cases} \sigma^2 \mathbf{I}, & k = 0 \\ 0, & k \neq 0 \end{cases}$$

Menurut Pfeifer dan Deutsch (1980a) jika  $p=0$  maka model STARMA  $(p_{\lambda_1, \lambda_2, \dots, \lambda_p}, q_{m_1, m_2, \dots, m_q})$  akan berubah menjadi model *Space Time Moving Average* (STMA) dan jika orde  $q=0$  menjadi model *Space Time Autoregressive* (STAR). Model STAR orde  $(p_1)$ , yang berarti orde spasial adalah 1 dan orde waktu adalah  $p$ , atau bisa ditulis STAR  $(p_1)$  dirumuskan pada persamaan 2.25

$$\dot{\mathbf{Z}}_t = \sum_{k=1}^p \phi_{k0} \mathbf{W}^{(0)} \dot{\mathbf{Z}}_{t-k} + \phi_{k1} \mathbf{W}^{(1)} \dot{\mathbf{Z}}_{t-k} + \mathbf{a}_t \quad (2.25)$$

dan ketika persamaan 2.25 mempunyai orde AR (1) dengan lima lokasi atau dapat ditulis dengan model STAR  $(1_1)$  maka didapatkan persamaan 2.26

$$\begin{bmatrix} \dot{\mathbf{Z}}_{1,t} \\ \dot{\mathbf{Z}}_{2,t} \\ \dot{\mathbf{Z}}_{3,t} \\ \dot{\mathbf{Z}}_{4,t} \\ \dot{\mathbf{Z}}_{5,t} \end{bmatrix} = \phi_{10} \begin{bmatrix} \dot{\mathbf{Z}}_{1,t-1} \\ \dot{\mathbf{Z}}_{2,t-1} \\ \dot{\mathbf{Z}}_{3,t-1} \\ \dot{\mathbf{Z}}_{4,t-1} \\ \dot{\mathbf{Z}}_{5,t-1} \end{bmatrix} + \phi_{11} \begin{bmatrix} 0 & w_{12} & w_{13} & w_{14} & w_{15} \\ w_{21} & 0 & w_{23} & w_{24} & w_{25} \\ w_{31} & w_{32} & 0 & w_{34} & w_{35} \\ w_{41} & w_{42} & w_{43} & 0 & w_{45} \\ w_{51} & w_{52} & w_{53} & w_{54} & 0 \end{bmatrix} \begin{bmatrix} \dot{\mathbf{Z}}_{1,t-1} \\ \dot{\mathbf{Z}}_{2,t-1} \\ \dot{\mathbf{Z}}_{3,t-1} \\ \dot{\mathbf{Z}}_{4,t-1} \\ \dot{\mathbf{Z}}_{5,t-1} \end{bmatrix} + \begin{bmatrix} a_{1,t} \\ a_{2,t} \\ a_{3,t} \\ a_{4,t} \\ a_{5,t} \end{bmatrix} \quad (2.26)$$

#### 2.4.2 Model *Generalized Space Time Autoregressive* (GSTAR)

Model *Generalized Space Time Autoregressive* merupakan suatu model yang dapat mengatasi kelemahan pada model *Space Time Autoregressive* (STAR) yaitu parameter model yang tidak berubah untuk setiap lokasi. Sehingga pada model GSTAR setiap lokasi mempunyai parameter yang berbeda karena kenyataannya sering ditemukan fenomena lokasi yang heterogen. Berbeda dengan model STAR yang hanya dapat digunakan jika lokasi penelitian bersifat homogen, model GSTAR lebih fleksibel dari model STAR yang juga merupakan spesifikasi dari model VAR (Borovkova, Lopuhaa, dan Ruchjana, 2002).

Jika diberikan sebuah deret  $\{Z_t : t = 0, \pm 1, \pm 2, \dots, T\}$  adalah deret *multivariate* yang mengandung kasus *spatio-temporal* di  $N$  lokasi, maka model GSTAR  $(p : \lambda_1, \lambda_2, \dots, \lambda_p)$  dengan orde AR( $p$ ) dan orde spasial  $\lambda_1, \lambda_2, \dots, \lambda_p$  dapat ditulis pada persamaan 2.27 (Wutsqa, Suhartono, dan Sutijo, 2010)

$$\mathbf{Z}_t = \sum_{k=1}^p \left( \boldsymbol{\Phi}_{k0} + \sum_{l=1}^{\lambda_k} \boldsymbol{\Phi}_{kl} \mathbf{W}^{(l)} \right) \mathbf{Z}_{t-k} + \mathbf{a}_t \quad (2.27)$$

dengan  $\boldsymbol{\Phi}_{s0} = \text{diag}(\phi_{s0}^1, \phi_{s0}^2, \dots, \phi_{s0}^N)$  dan  $\boldsymbol{\Phi}_{sk} = \text{diag}(\phi_{sk}^1, \phi_{sk}^2, \dots, \phi_{sk}^N)$  adalah matriks parameter waktu dan spasial,  $\mathbf{W}^{(l)}$  merupakan pembobot spasial yang mempunyai syarat  $w_{ii}^{(l)} = 0$  dan  $\sum_{j \neq 1} w_{ij}^{(l)} = 1$  serta  $\mathbf{a}_t$  merupakan vektor residual yang independent, identic, berdistribusi normal multivariat dengan mean nol dan varians-kovarians  $\sigma^2 \mathbf{I}_N$ . Model GSTAR (1<sub>1</sub>) yang berarti model mempunyai orde waktu dan spasial 1 dituliskan pada persamaan 2.28

$$\mathbf{Z}_t = \boldsymbol{\Phi}_{10} \mathbf{Z}_{t-1} + \boldsymbol{\Phi}_{11} \mathbf{W}^{(1)} \mathbf{Z}_{t-1} + \mathbf{a}_t \quad (2.28)$$

Sebagai contoh persamaan model GSTAR untuk orde waktu dan orde spasial satu, GSTAR(1<sub>1</sub>) dengan menggunakan lima lokasi yang berbeda seperti persamaan 2.29,

$$\begin{bmatrix} \dot{Z}_{1,t} \\ \dot{Z}_{2,t} \\ \dot{Z}_{3,t} \\ \dot{Z}_{4,t} \\ \dot{Z}_{5,t} \end{bmatrix} = \begin{bmatrix} \phi_{10}^1 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^1 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^1 & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^1 & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^1 \end{bmatrix} \begin{bmatrix} \dot{Z}_{1,t-1} \\ \dot{Z}_{2,t-1} \\ \dot{Z}_{3,t-1} \\ \dot{Z}_{4,t-1} \\ \dot{Z}_{5,t-1} \end{bmatrix} + \begin{bmatrix} \phi_{11}^1 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^1 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^1 & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^1 & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^1 \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} & w_{14} & w_{15} \\ w_{21} & 0 & w_{23} & w_{24} & w_{25} \\ w_{31} & w_{32} & 0 & w_{34} & w_{35} \\ w_{41} & w_{42} & w_{43} & 0 & w_{45} \\ w_{51} & w_{52} & w_{53} & w_{54} & 0 \end{bmatrix} \begin{bmatrix} \dot{Z}_{1,t-1} \\ \dot{Z}_{2,t-1} \\ \dot{Z}_{3,t-1} \\ \dot{Z}_{4,t-1} \\ \dot{Z}_{5,t-1} \end{bmatrix} + \begin{bmatrix} a_{1,t} \\ a_{2,t} \\ a_{3,t} \\ a_{4,t} \\ a_{5,t} \end{bmatrix} \quad (2.29)$$

Untuk mengidentifikasi orde model GSTAR, orde spasial pada umumnya dibatasi pada orde satu karena orde yang lebih tinggi akan sulit untuk diinterpretasikan (Wutsqa, Suhartono, dan Sutijo, 2010). Sedangkan untuk orde waktunya dapat diketahui dengan menggunakan nilai *Akaike Information Criterion* AIC. Namun nilai AIC belum dapat menangkap pola seasonal dari data sehingga untuk memprediksi orde waktu juga dapat menggunakan plot MCCF dan MPCCF.

Apabila data yang mengandung pola musiman, maka model GSTAR yang digunakan adalah model GSTAR musiman. Model umum GSTAR  $(p, \lambda_1, \lambda_2, \dots, \lambda_p)^s$  untuk pola data musiman adalah pada persamaan 2.30

$$\mathbf{Z}_t = \sum_{k=1}^p \left[ \Phi_{k0}^s \mathbf{Z}_{t-s} + \sum_{l=1}^{\lambda_k} \Phi_{kl}^s \mathbf{W}^{(l)} \mathbf{Z}_{t-s} \right] + \mathbf{a}_t, \quad (2.30)$$

dengan,

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

$\Phi_{kl}^s$  :  $diag(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(N)})$  merupakan matriks parameter spasial musiman  $s$ ,

$\mathbf{a}_t$  : vektor *noise* berukuran  $(N \times 1)$  yang independen, identik, berdistribusinormal multivariat dengan *mean* nol dan matriks varians-kovarian  $\sigma^2 \mathbf{I}_N$ .

Nilai pembobot dipilih sedemikian hingga, sampai memenuhi syarat  $w_{ii}^{(l)} = 0$  dan  $\sum_{j \neq i} w_{ij}^{(l)} = 1$ . Misal, pada model GSTAR musiman dengan orde musiman 1 dan periode musiman 12 ( $s = 12$ ) dan orde spasial 1 adalah persamaan 2.31

$$\mathbf{Z}_t = [\Phi_{10}^{12} \mathbf{Z}_{t-12} + \Phi_{11}^{12} \mathbf{W}^1 \mathbf{Z}_{t-12}] + \mathbf{a}_t. \quad (2.31)$$

## 1. Penentuan Bobot Lokasi

Terdapat berbagai cara menentukan bobot lokasi pada model GSTAR diantaranya dengan menggunakan bobot seragam (*uniform*), bobot invers jarak, bobot normalisasi korelasi silang dan lain-lain (Suhartono dan Subanar, 2006). Sebagai ilustrasi, diberikan peta lokasi Pulau Jawa pada Gambar 2.2 berikut:



**Gambar 2.2.** Peta Pulau Jawa

a. **Bobot Seragam (*Uniform*)**

Lokasi-lokasi yang digunakan diasumsikan mempunyai karakteristik yang homogen dan jarak yang sama antar lokasi. Sehingga persamaan untuk mendapatkan bobot seragam adalah persamaan 2.32

$$w_{ij} = \frac{1}{s_i} \quad (2.32)$$

dengan  $w_{ij}$  merupakan bobot yang didapat untuk setiap lokasi dan  $s_i$  merupakan banyaknya lokasi yang berdekatan dengan lokasi ke- $i$ . Matriks pembobot yang terbentuk untuk lima lokasi pengamatan seperti berikut:

$$W = \begin{bmatrix} 0 & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} \\ \frac{1}{4} & 0 & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} \\ \frac{1}{4} & \frac{1}{4} & 0 & \frac{1}{4} & \frac{1}{4} \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & 0 & \frac{1}{4} \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & 0 \end{bmatrix}.$$

b. **Bobot Invers Jarak**

Pembobotan invers jarak dilakukan berdasarkan jarak sebenarnya antar lokasi pengamatan. Kemudian nilai bobot diperoleh dari normalisasi hasil *invers* jarak sebenarnya. Bobot invers jarak diperoleh dengan persamaan 2.33

$$w_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_{j=1}^{s_i} \frac{1}{d_{ij}}}, \quad i \neq j \quad (2.33)$$

dengan  $d_{ij}$  adalah jarak sebenarnya antara lokasi ke- $i$  dan ke- $j$ . Berikut ini jarak antar lokasi KPw Bank Indonesia di Pulau Jawa (km).

**Tabel 2.1** Jarak antar KPw Bank Indonesia Wilayah Jawa (km)

<b>Lokasi</b>	<b>Lokasi</b>				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Surabaya	0	$d_{12} = 353$	$d_{13} = 329$	$d_{14} = 779$	$d_{15} = 790$
Semarang	$d_{21} = 353$	0	$d_{23} = 131$	$d_{24} = 437$	$d_{25} = 450$
Yogyakarta	$d_{31} = 329$	$d_{32} = 131$	0	$d_{34} = 557$	$d_{35} = 569$
Bandung	$d_{41} = 779$	$d_{42} = 437$	$d_{43} = 557$	0	$d_{45} = 156$
Jakarta	$d_{51} = 790$	$d_{52} = 450$	$d_{53} = 569$	$d_{54} = 156$	0

Bobot antar lokasi KPw Bank Sentral di Pulau Jawa diperoleh dengan contoh perhitungan seperti berikut:

$$w_{12} = \frac{\frac{1}{d_{12}}}{\frac{1}{d_{12}} + \frac{1}{d_{13}} + \frac{1}{d_{14}} + \frac{1}{d_{15}}} = \frac{\frac{1}{353}}{\frac{1}{353} + \frac{1}{329} + \frac{1}{779} + \frac{1}{790}} = 0,33637$$

$$w_{13} = \frac{\frac{1}{d_{13}}}{\frac{1}{d_{12}} + \frac{1}{d_{13}} + \frac{1}{d_{14}} + \frac{1}{d_{15}}} = \frac{\frac{1}{329}}{\frac{1}{353} + \frac{1}{329} + \frac{1}{779} + \frac{1}{790}} = 0,36091$$

$$w_{14} = \frac{\frac{1}{d_{14}}}{\frac{1}{d_{12}} + \frac{1}{d_{13}} + \frac{1}{d_{14}} + \frac{1}{d_{15}}} = \frac{\frac{1}{779}}{\frac{1}{353} + \frac{1}{329} + \frac{1}{779} + \frac{1}{790}} = 0,15242$$

$$w_{15} = \frac{\frac{1}{d_{15}}}{\frac{1}{d_{12}} + \frac{1}{d_{13}} + \frac{1}{d_{14}} + \frac{1}{d_{15}}} = \frac{\frac{1}{790}}{\frac{1}{353} + \frac{1}{329} + \frac{1}{779} + \frac{1}{790}} = 0,15030 ; \text{dst.}$$

Sehingga matriks pembobot yang terbentuk untuk lima lokasi pengamatan adalah sebagai berikut:

$$\mathbf{W} = \begin{bmatrix} 0 & 0,33637 & 0,36091 & 0,15242 & 0,15030 \\ 0,18915 & 0 & 0,50969 & 0,15279 & 0,14838 \\ 0,21366 & 0,53660 & 0 & 0,12620 & 0,12354 \\ 0,10899 & 0,19429 & 0,15244 & 0 & 0,54427 \\ 0,10860 & 0,19065 & 0,15078 & 0,54996 & 0 \end{bmatrix}.$$

### c. Bobot Normalisasi Korelasi Silang

Pembobotan dengan metode normalisasi korelasi silang merupakan pembobotan menggunakan korelasi silang yang dinormalisasi antara satu lokasi dengan lokasi lainnya pada lag yang bersesuaian (Suhartono dan Atok, 2006). Persamaan korelasi silang silang suatu kejadian antara lokasi ke-*i* dan lokasi ke-*j* pada lag waktu ke-*k* atau dapat ditulis dengan  $\text{corr}[Z_{i,t}, Z_{j,t-k}]$  adalah persamaan 2.34

$$\rho_{ij}^k = \frac{\gamma_{ijk}^k}{\sigma_i \sigma_j}, \quad k = 0, \pm 1, \pm 2, \dots \quad (2.34)$$

dengan  $\gamma_{ijk}$  adalah kovarians silang antara kejadian di lokasi ke-*i* dan ke-*j* pada waktu ke-*k* dan  $\sigma_i$  serta  $\sigma_j$  secara berturut-turut adalah standar deviasi dari kejadian di lokasi ke-*i* dan ke-*j*. Nilai dari korelasi silang dapat dihitung dengan persamaan 2.35.

$$r_{ij}^k = \frac{\sum_{t=k+1}^n [Z_{i,t} - \bar{Z}_i][Z_{j,t-k} - \bar{Z}_j]}{\sqrt{\left( \sum_{t=k+1}^n [Z_{i,t} - \bar{Z}_i]^2 \right) \left( \sum_{t=k+1}^n [Z_{j,t-k} - \bar{Z}_j]^2 \right)}} \quad (2.35)$$

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 ( $l_1$ ) seperti pada persamaan 2.36.

$$w_{ij} = \frac{r_{ij}^k}{\sum_{j \neq i} |r_{ij}^k|}, \quad i \neq j. \quad (2.36)$$

## 2. Estimasi Model GSTAR

Salah satu metode yang digunakan untuk mengestimasi model GSTAR adalah *Ordinary Least Square* (OLS). Metode OLS merupakan metode estimasi dengan meminimumkan jumlah kuadrat simpangannya (Borovkova, Lopuhaa, dan Ruchjana, 2008). Jika terdapat model GSTAR(1<sub>1</sub>) sesuai dengan persamaan (2.39) dengan  $\Phi_{10}$  dan  $\Phi_{11}$  merupakan parameter regresi waktu dan spasial dan  $\mathbf{W}^{(l)}$  adalah bobot lokasi maka model tersebut juga ditulis seperti persamaan 2.37.

$$\mathbf{Y}_t = \mathbf{A}\mathbf{Z}_{t-1} + \mathbf{a}_t \quad (2.37)$$

dengan  $\mathbf{A} = \Phi_{10} + \Phi_{11}\mathbf{W}$ , dimana  $\Phi_{10}$  dan  $\Phi_{11}$  adalah matriks diagonal dari parameter autoregressi untuk waktu dan lokasi serta  $\mathbf{W}$  adalah matriks pembobot. Model ini dapat diterapkan pada model GSTAR (1<sub>1</sub>) yang dapat dituliskan seperti persamaan 2.38.

$$\begin{bmatrix} Z_{1,1} \\ Z_{1,2} \\ \vdots \\ Z_{1,T} \\ \vdots \\ Z_{N,1} \\ Z_{N,2} \\ \vdots \\ Z_{N,T} \end{bmatrix} = \begin{bmatrix} Z_{1,0} & \dots & 0 & FZ_{1,0} & \dots & 0 \\ Z_{1,1} & \dots & 0 & FZ_{1,1} & \dots & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ Z_{1,T-1} & \dots & 0 & FZ_{1,T-1} & \dots & 0 \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & Z_{N,0} & 0 & \dots & FZ_{N,0} \\ 0 & \dots & Z_{N,1} & 0 & \dots & FZ_{N,1} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & Z_{N,T-1} & 0 & \dots & FZ_{N,T-1} \end{bmatrix} \begin{bmatrix} \phi_{10} \\ \phi_{N0} \\ \phi_{11} \\ \vdots \\ \phi_{N1} \end{bmatrix} + \begin{bmatrix} a_{1,1} \\ a_{1,2} \\ \vdots \\ a_{1,T} \\ \vdots \\ a_{N,1} \\ a_{N,2} \\ \vdots \\ a_{N,T} \end{bmatrix} \quad (2.38)$$

dengan  $FZ_{i,t} = \sum_{j \neq i} w_{ij} Z_{j,t}$ . Selanjutnya persamaan 2.38 dapat dituliskan menjadi

persamaan 2.39.

$$\mathbf{Y} = \mathbf{X}\beta + \mathbf{a} \quad (2.39)$$

dengan

$$\mathbf{Y} = \begin{bmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_N \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} \mathbf{X}_1 & 0 & \dots & 0 \\ 0 & \mathbf{X}_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{X}_N \end{bmatrix}, \quad \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_N \end{bmatrix} \text{ dan } \mathbf{a} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_N \end{bmatrix}$$

Jika  $i = 1, 2, \dots, N$  maka struktur model linier GSTAR( $p_1$ ) adalah sebagai berikut

$$\mathbf{Y}_i = \begin{bmatrix} Z_{i,p} \\ Z_{i,p+1} \\ \vdots \\ Z_{i,N} \end{bmatrix}, \quad \mathbf{X}_i = \begin{bmatrix} Z_{i,p-1} & \dots & Z_{i,1} & FZ_{i,p-1} & \dots & FZ_{i,1} \\ Z_{i,p} & \dots & Z_{i,2} & FZ_{i,p} & \dots & FZ_{i,2} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ Z_{i,N-1} & \dots & Z_{i,N-p} & FZ_{i,N-1} & \dots & FZ_{i,N-p} \end{bmatrix} \text{ dan } \boldsymbol{\beta} = \begin{bmatrix} \phi_{10} \\ \phi_{p0} \\ \phi_{11} \\ \vdots \\ \phi_{p1} \end{bmatrix}$$

Sehingga struktur model GSTAR (1<sub>1</sub>) akan menjadi persamaan 2.40

$$\mathbf{Y}_i = \mathbf{X}_i \boldsymbol{\beta}_i + \mathbf{a}_i \quad (2.40)$$

dengan

$$\mathbf{Y}_i = \begin{bmatrix} Z_{i,1} \\ Z_{i,2} \\ \vdots \\ Z_{i,N} \end{bmatrix}, \quad \mathbf{X}_i = \begin{bmatrix} Z_{i,0} & FZ_{i,0} \\ Z_{i,1} & FZ_{i,1} \\ \vdots & \vdots \\ Z_{i,N-1} & FZ_{i,N-1} \end{bmatrix}, \quad \boldsymbol{\beta}_i = \begin{bmatrix} \phi_{10} \\ \phi_{11} \\ \vdots \\ \phi_{N0} \\ \phi_{N1} \end{bmatrix}, \quad \mathbf{a}_i = \begin{bmatrix} a_{i,1} \\ a_{i,2} \\ \vdots \\ a_{i,T} \end{bmatrix} \text{ dan } FZ_{i,t} = \sum_{j \neq i} w_{ij} Z_{j,t}$$

Berdasarkan uraian persamaan di atas nilai estimasi dari  $\boldsymbol{\beta} = (\phi_{10}, \phi_{11}, \phi_{20}, \phi_{21}, \dots, \phi_{N0}, \phi_{N1})'$  dengan  $T \rightarrow \infty$  dapat dihitung menggunakan estimator *least square* menjadi  $\hat{\boldsymbol{\beta}} = (\hat{\phi}_{10}, \hat{\phi}_{11}, \hat{\phi}_{20}, \hat{\phi}_{21}, \dots, \hat{\phi}_{N0}, \hat{\phi}_{N1})'$  sehingga menjadi persamaan 2.41

$$\begin{aligned} \mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} &= \mathbf{X}'\mathbf{Y} \\ &= \mathbf{X}'(\mathbf{X}\boldsymbol{\beta} + \mathbf{a}) \\ &= \mathbf{X}'\mathbf{X}\boldsymbol{\beta} + \mathbf{X}'\mathbf{a} \\ \mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} - \mathbf{X}'\mathbf{X}\boldsymbol{\beta} &= \mathbf{X}'\mathbf{a} \\ \mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}) &= \mathbf{X}'\mathbf{a} \end{aligned} \quad (2.41)$$

Elemen-elemen dari matriks  $\mathbf{X}'\mathbf{X}$  adalah

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} \mathbf{X}'_1\mathbf{X}_1 & 0 & \dots & 0 \\ 0 & \mathbf{X}'_2\mathbf{X}_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{X}'_N\mathbf{X}_N \end{bmatrix} \text{ dengan } \mathbf{X}'_i\mathbf{X}_i = \begin{bmatrix} \sum_{t=0}^{T-1} Z_{i,t}^2 & \sum_{t=0}^{T-1} Z_{i,t} FZ_{i,t} \\ \sum_{t=0}^{T-1} Z_{i,t} FZ_{i,t} & \sum_{t=0}^{T-1} FZ_{i,t}^2 \end{bmatrix}$$

$$\text{dan } FZ_{i,t} = \sum_{j \neq i} w_{ij} Z_{j,t}$$

Dengan demikian metode *least square* pada estimasi parameter model dapat dilakukan dengan meminimumkan fungsi persamaan 2.42

$$\mathbf{a}'\mathbf{a} = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \quad (2.42)$$

sehingga estimator  $\boldsymbol{\beta}$  dapat diperoleh dengan persamaan 2.43

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} \quad (2.43)$$

untuk  $i = 1, 2, \dots, N$ , vektor parameter  $\phi_{i0}$  dan  $\phi_{il}$  adalah persamaan 2.44

$$\hat{\boldsymbol{\phi}}_i = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}_i \quad (2.44)$$

Metode lain untuk mengestimasi model GSTAR adalah dengan menggunakan *Generalized Least Square* (GLS). GLS adalah penduga parameter regresi yang memperhatikan adanya korelasi dari residual antar persamaan, dengan nilai residual diperoleh dari penaksiran OLS. 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). Secara umum model SUR dapat dituliskan sebagai persamaan 2.45.

$$\begin{aligned} Z_{1t} &= \beta_{10} + \beta_{11}X_{1t,1} + \beta_{12}X_{1t,2} + \dots + \beta_{1K_1}X_{1t,K_1} + a_{1t} \\ Z_{2t} &= \beta_{20} + \beta_{21}X_{2t,1} + \beta_{22}X_{2t,2} + \dots + \beta_{2K_2}X_{2t,K_2} + a_{2t} \\ &\vdots \\ Z_{Nt} &= \beta_{N0} + \beta_{N1}X_{Nt,1} + \beta_{N2}X_{Nt,2} + \dots + \beta_{NK_N}X_{Nt,K_N} + a_{Nt} \end{aligned} \quad (2.45)$$

dengan  $t = 1, 2, \dots, T$ , dimana  $T$  merupakan jumlah pengamatan,  $K$  adalah jumlah variabel bebas,  $N$  menyatakan jumlah persamaan dalam sistem, dan banyak persamaan dalam sistem dengan  $a_{1t}, a_{2t}, \dots, a_{Nt}$  saling berkorelasi. Model SUR dapat dituliskan seperti persamaan 2.46.

$$\mathbf{Y}_i = \mathbf{X}_i\boldsymbol{\beta}_i + \mathbf{a}_i \quad (2.46)$$

yang dituliskan dalam bentuk matriks pada persamaan 2.47.

$$\begin{bmatrix} \mathbf{Y}_1 \\ \vdots \\ \mathbf{Y}_N \end{bmatrix}_{(T \times 1)} = \begin{bmatrix} \mathbf{X}_1 & 0 & \dots & 0 \\ 0 & \mathbf{X}_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{X}_2 \end{bmatrix}_{(T \times 1)} \begin{bmatrix} \boldsymbol{\beta}_1 \\ \vdots \\ \boldsymbol{\beta}_N \end{bmatrix}_{(k \times 1)} + \begin{bmatrix} \mathbf{a}_1 \\ \vdots \\ \mathbf{a}_N \end{bmatrix}_{(T \times 1)} \quad (2.47)$$

Persamaan model SUR dengan estimasi GLS memiliki beberapa asumsi yang harus dipenuhi yaitu  $E(\mathbf{a})=0$  dan  $E(\mathbf{a}_i, \mathbf{a}'_j) = \sigma_{ij}\mathbf{I}$ . Zellner (1962) mengasumsikan bahwa struktur matriks varians-kovarians pada sistem persamaan model SUR diperoleh dengan persamaan 2.48.

$$E[\mathbf{a}_i, \mathbf{a}'_j] = E\left[\begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_N \end{pmatrix} (a_1 \ a_2 \ \dots \ a_N)\right] \quad (2.48)$$

Persamaan 2.48 dapat diuraikan menjadi persamaan 2.49.

$$\begin{aligned} E[\mathbf{a}_i, \mathbf{a}'_j] &= E\left[\begin{array}{cccc} (a_1, a_1) & (a_1, a_2) & \dots & (a_1, a_N) \\ (a_2, a_1) & (a_2, a_2) & \dots & (a_2, a_N) \\ \vdots & \vdots & \ddots & \vdots \\ (a_N, a_1) & (a_N, a_2) & \dots & (a_N, a_N) \end{array}\right] \\ &= \begin{bmatrix} E(a_1, a_1) & E(a_1, a_2) & \dots & E(a_1, a_N) \\ E(a_2, a_1) & E(a_2, a_2) & \dots & E(a_2, a_N) \\ \vdots & \vdots & \ddots & \vdots \\ E(a_N, a_1) & E(a_N, a_2) & \dots & E(a_N, a_N) \end{bmatrix} \end{aligned} \quad (2.49)$$

Jika diketahui  $E(\mathbf{a}_i, \mathbf{a}'_j) = \sigma_{ij}\mathbf{I}$  maka  $E(a_1, a_1) = \sigma_{11}\mathbf{I}$ ,  $E(a_1, a_2) = \sigma_{12}\mathbf{I}$  hingga  $E(a_N, a_N) = \sigma_{NN}\mathbf{I}$  sehingga persamaan 2.49 dapat dituliskan menjadi persamaan 2.50.

$$\begin{aligned}
E[\mathbf{a}_i, \mathbf{a}'_j] &= \begin{bmatrix} \sigma_{11}\mathbf{I} & \sigma_{12}\mathbf{I} & \dots & \sigma_{1N}\mathbf{I} \\ \sigma_{21}\mathbf{I} & \sigma_{22}\mathbf{I} & \dots & \sigma_{1N}\mathbf{I} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1}\mathbf{I} & \sigma_{N1}\mathbf{I} & \dots & \sigma_{NN}\mathbf{I} \end{bmatrix} \\
&= \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{1N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N1} & \dots & \sigma_{NN} \end{bmatrix} \otimes \mathbf{I} \\
&= \boldsymbol{\Sigma} \otimes \mathbf{I} \\
&= \boldsymbol{\Omega}
\end{aligned} \tag{2.50}$$

dengan  $\mathbf{I} = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}$  dan  $\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N1} & \dots & \sigma_{NN} \end{bmatrix}$

$\boldsymbol{\Sigma}$  adalah varians-kovarians dari *error*. Seperti yang dibahas sebelumnya bahwa model SUR dapat diestimasi dengan menggunakan GLS yaitu dengan meminimumkan persamaan fungsi  $\mathbf{a}'\mathbf{a} = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'\boldsymbol{\Omega}^{-1}(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})$  sehingga diperoleh estimator  $\hat{\boldsymbol{\beta}}$  dengan persamaan 2.51.

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\boldsymbol{\Omega}^{-1}\mathbf{X})^{-1}\mathbf{X}'\boldsymbol{\Omega}^{-1}\mathbf{Y} \tag{2.51}$$

Ruchjana (2002) menyatakan bahwa model GSTAR khususnya GSTAR(1<sub>1</sub>) merupakan versi terbatas dari model VAR. Hal ini menyebabkan kondisi stasioner pada model GSTAR dapat diperoleh dari kestasioneritas model VAR, maka dari itu model GSTAR(1<sub>1</sub>) yang dapat dituliskan dengan persamaan  $\mathbf{Z}_t = [\boldsymbol{\Phi}_{10} + \boldsymbol{\Phi}_{11}\mathbf{W}^{(1)}]\mathbf{Z}_{t-1} + \mathbf{a}_t$ , dapat diwakili dengan persamaan model VAR(1) seperti  $\mathbf{Z}_t = \boldsymbol{\Phi}_1\mathbf{Z}_{t-1} + \mathbf{a}_t$ , dengan persamaan 2.52.

$$\boldsymbol{\Phi}_1 = [\boldsymbol{\Phi}_{10} + \boldsymbol{\Phi}_{11}\mathbf{W}^{(1)}] \tag{2.52}$$

Secara umum model GSTAR dikatakan proses stasioner adalah jika semua *eigenvalue* dari  $[\boldsymbol{\Phi}_{10} + \boldsymbol{\Phi}_{11}\mathbf{W}^{(1)}]$  memenuhi syarat  $|\lambda| < 1$ .

Suhartono dan Subanar (2007) menyatakan bahwa kondisi stasioner pada model GSTAR, khususnya untuk parameter pada model GSTAR(1<sub>1</sub>) dapat

menggunakan syarat  $< 1$  yang disajikan dalam model VAR(1). Bentuk umum peramalan model GSTAR dapat dituliskan seperti persamaan 2.53.

$$\hat{Z}_t = \sum_{k=1}^p \left[ \Phi_{k0} Z_{t-s} + \sum_{l=1}^{\lambda_k} \Phi_{kl} W^{(l)} Z_{t-s} \right] \quad (2.53)$$

#### 2.4.3 Model *Multivariate Generalized Space Time Autoregressive* (MGSTAR)

Model *Multivariate GSTAR (MGSTAR)* merupakan pengembangan model GSTAR dan VAR. Model MGSTAR diperkenalkan oleh Nahdliyah, Suhartono dan Akbar (2018) untuk data *space-time* dengan lebih dari satu variabel pengamatan di setiap lokasi. Bentuk persamaan dari model MGSTAR tiga lokasi dengan dua variable di setiap lokasi adalah persamaan 2.54a

$$Z_{i,t}^k = \Phi_{i,0} Z_{i,t-1}^k + \Phi_{i,0}^* Z_{i,t-1}^k + \Phi_{i,1} W Z_{i,t-1}^k + \Phi_{i,1}^* W^* Z_{i,t-1}^k + a_{i,t}^k \quad (2.54a)$$

atau bisa dituliskan dengan persamaan matriks 2.54b

$$\begin{bmatrix} Z_{1,t}^1 \\ Z_{2,t}^1 \\ Z_{3,t}^1 \\ Z_{1,t}^2 \\ Z_{2,t}^2 \\ Z_{3,t}^2 \end{bmatrix} = \begin{bmatrix} \phi_{10}^1 & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^1 & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^1 & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{10}^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{20}^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{30}^2 \end{bmatrix} \begin{bmatrix} Z_{1,t-1}^1 \\ Z_{2,t-1}^1 \\ Z_{3,t-1}^1 \\ Z_{1,t-1}^2 \\ Z_{2,t-1}^2 \\ Z_{3,t-1}^2 \end{bmatrix} + \begin{bmatrix} \phi_{10}^{1*} & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{1*} & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{1*} & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{10}^{2*} & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{20}^{2*} & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{30}^{2*} \end{bmatrix} \begin{bmatrix} Z_{1,t-1}^2 \\ Z_{2,t-1}^2 \\ Z_{3,t-1}^2 \\ Z_{1,t-1}^1 \\ Z_{2,t-1}^1 \\ Z_{3,t-1}^1 \end{bmatrix} + \begin{bmatrix} \phi_{11}^1 & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^1 & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^1 & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{11}^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{21}^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{31}^2 \end{bmatrix} \begin{bmatrix} w_{12} & w_{13} & 0 & 0 & 0 & 0 \\ w_{21} & 0 & w_{23} & 0 & 0 & 0 \\ w_{31} & w_{32} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & w_{12} & w_{13} \\ 0 & 0 & 0 & w_{21} & 0 & w_{23} \\ 0 & 0 & 0 & w_{31} & w_{32} & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-1}^1 \\ Z_{2,t-1}^1 \\ Z_{3,t-1}^1 \\ Z_{1,t-1}^2 \\ Z_{2,t-1}^2 \\ Z_{3,t-1}^2 \end{bmatrix} + \begin{bmatrix} \phi_{11}^{1*} & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{1*} & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{1*} & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{11}^{2*} & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{21}^{2*} & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{31}^{2*} \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 & w_{12} & w_{13} & 0 \\ 0 & 0 & 0 & w_{21} & 0 & w_{23} \\ 0 & 0 & 0 & w_{31} & w_{32} & 0 \\ 0 & w_{12} & w_{13} & 0 & 0 & 0 \\ w_{21} & 0 & w_{23} & 0 & 0 & 0 \\ w_{31} & w_{32} & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} Z_{1,t-1}^1 \\ Z_{2,t-1}^1 \\ Z_{3,t-1}^1 \\ Z_{1,t-1}^2 \\ Z_{2,t-1}^2 \\ Z_{3,t-1}^2 \end{bmatrix} \begin{bmatrix} a_{1,t}^1 \\ a_{2,t}^1 \\ a_{3,t}^1 \\ a_{1,t}^2 \\ a_{2,t}^2 \\ a_{3,t}^2 \end{bmatrix} \quad (2.54b)$$

dengan  $\phi_{i0}^k$  dan  $\phi_{i0}^{k*}$  merupakan parameter yang menjelaskan keterkaitan lag antara variabel yang sama pada lokasi yang sama dan variabel yang beda pada lokasi yang sama serta  $\phi_{il}^k$  dan  $\phi_{il}^{k*}$  merupakan parameter yang menjelaskan keterkaitan lag antara variabel yang sama pada lokasi berbeda dan variabel yang berbeda pada lokasi yang berbeda, dengan  $i=1, 2, 3$  dan  $k=1, 2$ . Sedangkan

model MGSTAR dengan orde waktu dan spasial 1 dengan lima lokasi dan di setiap lokasi terdapat tiga variabel pengamatan dituliskan pada persamaan 2.55.

$$\begin{aligned}
\begin{bmatrix} \dot{\mathbf{Z}}_t^1 \\ \dot{\mathbf{Z}}_t^2 \\ \dot{\mathbf{Z}}_t^3 \end{bmatrix} &= \begin{bmatrix} \Phi_0^1 & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \Phi_0^2 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \Phi_0^3 \end{bmatrix} \begin{bmatrix} \dot{\mathbf{Z}}_{t-1}^1 \\ \dot{\mathbf{Z}}_{t-1}^2 \\ \dot{\mathbf{Z}}_{t-1}^3 \end{bmatrix} + \begin{bmatrix} \Phi_0^{1*} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \Phi_0^{2*} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \Phi_0^{3*} \end{bmatrix} \begin{bmatrix} \dot{\mathbf{Z}}_{t-1}^2 \\ \dot{\mathbf{Z}}_{t-1}^3 \\ \dot{\mathbf{Z}}_{t-1}^1 \end{bmatrix} + \\
&\quad \begin{bmatrix} \Phi_0^{1**} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \Phi_0^{2**} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \Phi_0^{3**} \end{bmatrix} \begin{bmatrix} \dot{\mathbf{Z}}_{t-1}^3 \\ \dot{\mathbf{Z}}_{t-1}^1 \\ \dot{\mathbf{Z}}_{t-1}^2 \end{bmatrix} + \begin{bmatrix} \Phi_1^1 & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \Phi_1^2 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \Phi_1^3 \end{bmatrix} \begin{bmatrix} \mathbf{W} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{W} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{W} \end{bmatrix} \begin{bmatrix} \dot{\mathbf{Z}}_{t-1}^1 \\ \dot{\mathbf{Z}}_{t-1}^2 \\ \dot{\mathbf{Z}}_{t-1}^3 \end{bmatrix} + \\
&\quad \begin{bmatrix} \Phi_1^{1*} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \Phi_1^{2*} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \Phi_1^{3*} \end{bmatrix} \begin{bmatrix} \mathbf{0} & \mathbf{W} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{W} \\ \mathbf{W} & \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \dot{\mathbf{Z}}_{t-1}^1 \\ \dot{\mathbf{Z}}_{t-1}^2 \\ \dot{\mathbf{Z}}_{t-1}^3 \end{bmatrix} + \\
&\quad \begin{bmatrix} \Phi_1^{1**} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \Phi_1^{2**} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \Phi_1^{3**} \end{bmatrix} \begin{bmatrix} \mathbf{0} & \mathbf{0} & \mathbf{W} \\ \mathbf{W} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{W} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \dot{\mathbf{Z}}_{t-1}^1 \\ \dot{\mathbf{Z}}_{t-1}^2 \\ \dot{\mathbf{Z}}_{t-1}^3 \end{bmatrix} + \begin{bmatrix} \mathbf{a}_t^1 \\ \mathbf{a}_t^2 \\ \mathbf{a}_t^3 \end{bmatrix} \tag{2.55}
\end{aligned}$$

dengan

$$\begin{aligned}
\dot{\mathbf{Z}}_t^1 &= \begin{bmatrix} \dot{Z}_{1,t}^1 \\ \dot{Z}_{2,t}^1 \\ \dot{Z}_{3,t}^1 \\ \dot{Z}_{4,t}^1 \\ \dot{Z}_{5,t}^1 \end{bmatrix}, \quad \dot{\mathbf{Z}}_t^2 = \begin{bmatrix} \dot{Z}_{1,t}^2 \\ \dot{Z}_{2,t}^2 \\ \dot{Z}_{3,t}^2 \\ \dot{Z}_{4,t}^2 \\ \dot{Z}_{5,t}^2 \end{bmatrix}, \quad \dot{\mathbf{Z}}_t^3 = \begin{bmatrix} \dot{Z}_{1,t}^3 \\ \dot{Z}_{2,t}^3 \\ \dot{Z}_{3,t}^3 \\ \dot{Z}_{4,t}^3 \\ \dot{Z}_{5,t}^3 \end{bmatrix}, \quad \Phi_0^1 = \begin{bmatrix} \phi_{10}^1 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^1 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^1 & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^1 & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^1 \end{bmatrix}, \\
\Phi_0^2 &= \begin{bmatrix} \phi_{10}^2 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^2 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^2 & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^2 & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^2 \end{bmatrix}, \quad \Phi_0^3 = \begin{bmatrix} \phi_{10}^3 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^3 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^3 & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^3 & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^3 \end{bmatrix}, \\
\Phi_0^{1*} &= \begin{bmatrix} \phi_{10}^{1*} & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{1*} & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{1*} & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{1*} & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{1*} \end{bmatrix}, \quad \Phi_0^{2*} = \begin{bmatrix} \phi_{10}^{2*} & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{2*} & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{2*} & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{2*} & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{2*} \end{bmatrix},
\end{aligned}$$

$$\begin{aligned}
\Phi_0^{3*} &= \begin{bmatrix} \phi_{10}^{3*} & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{3*} & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{3*} & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{3*} & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{3*} \end{bmatrix}, \quad \Phi_0^{1**} = \begin{bmatrix} \phi_{10}^{1**} & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{1**} & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{1**} & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{1**} & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{1**} \end{bmatrix}, \\
\Phi_0^{2**} &= \begin{bmatrix} \phi_{10}^{2**} & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{2**} & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{2**} & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{2**} & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{2**} \end{bmatrix}, \quad \Phi_0^{3**} = \begin{bmatrix} \phi_{10}^{3**} & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{3**} & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{3**} & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{3**} & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{3**} \end{bmatrix}, \\
\Phi_1^1 &= \begin{bmatrix} \phi_{11}^1 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^1 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^1 & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^1 & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^1 \end{bmatrix}, \quad \Phi_1^2 = \begin{bmatrix} \phi_{11}^2 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^2 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^2 & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^2 & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^2 \end{bmatrix}, \\
\Phi_1^3 &= \begin{bmatrix} \phi_{11}^3 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^3 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^3 & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^3 & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^3 \end{bmatrix}, \quad \Phi_1^{1*} = \begin{bmatrix} \phi_{11}^{1*} & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{1*} & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{1*} & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{1*} & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{1*} \end{bmatrix}, \\
\Phi_1^{2*} &= \begin{bmatrix} \phi_{11}^{2*} & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{2*} & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{2*} & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{2*} & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{2*} \end{bmatrix}, \quad \Phi_1^{3*} = \begin{bmatrix} \phi_{11}^{3*} & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{3*} & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{3*} & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{3*} & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{3*} \end{bmatrix}, \\
\Phi_1^{1**} &= \begin{bmatrix} \phi_{11}^{1**} & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{1**} & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{1**} & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{1**} & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{1**} \end{bmatrix}, \quad \Phi_1^{2**} = \begin{bmatrix} \phi_{11}^{2**} & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{2**} & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{2**} & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{2**} & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{2**} \end{bmatrix},
\end{aligned}$$

$$\Phi_1^{3**} = \begin{bmatrix} \phi_{11}^{3**} & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{3**} & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{3**} & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{3**} & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{3**} \end{bmatrix}, \mathbf{0} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix},$$

$$\mathbf{W} = \begin{bmatrix} 0 & w_{12} & w_{13} & w_{14} & w_{15} \\ w_{21} & 0 & w_{23} & w_{24} & w_{25} \\ w_{31} & w_{32} & 0 & w_{34} & w_{35} \\ w_{41} & w_{42} & w_{43} & 0 & w_{45} \\ w_{51} & w_{52} & w_{53} & w_{54} & 0 \end{bmatrix}, \mathbf{a}_t^1 = \begin{bmatrix} a_{1,t}^1 \\ a_{2,t}^1 \\ a_{3,t}^1 \\ a_{4,t}^1 \\ a_{5,t}^1 \end{bmatrix}, \mathbf{a}_t^2 = \begin{bmatrix} a_{1,t}^2 \\ a_{2,t}^2 \\ a_{3,t}^2 \\ a_{4,t}^2 \\ a_{5,t}^2 \end{bmatrix}, \text{ dan } \mathbf{a}_t^3 = \begin{bmatrix} a_{1,t}^3 \\ a_{2,t}^3 \\ a_{3,t}^3 \\ a_{4,t}^3 \\ a_{5,t}^3 \end{bmatrix}$$

dengan  $\phi_{i0}^k$  adalah parameter yang menjelaskan keterkaitan lag variabel yang sama pada lokasi yang sama,  $\phi_{i0}^{k*}$  dan  $\phi_{i1}^{k**}$  adalah parameter yang menjelaskan keterkaitan lag variabel berbeda pada lokasi yang sama,  $\phi_{i1}^k$  adalah parameter yang menjelaskan keterkaitan lag variabel sama pada lokasi yang berbeda,  $\phi_{i1}^{k*}$  dan  $\phi_{i1}^{k**}$  adalah parameter yang menjelaskan keterkaitan lag variabel yang berbeda pada lokasi yang berbeda dengan  $i = 1, 2, 3, 4, 5$  dan  $k = 1, 2, 3$  serta  $w_{ij}$  adalah bobot spasial antara lokasi ke- $i$  dan ke- $j$ .

### a. Estimasi Model MGSTAR

Estimasi model MGSTAR dapat dilakukan dengan menggunakan metode *Ordinary Least Square* (OLS). Persamaan (2.54a) dapat ditulis menjadi persamaan 2.56.

$$\mathbf{Z} = [\mathbf{V}_1 \quad \mathbf{V}_2 \quad \mathbf{V}_3 \quad \mathbf{V}_4] \begin{bmatrix} \Phi_{i0}^k \\ \Phi_{i0}^{k*} \\ \Phi_{i1}^k \\ \Phi_{i1}^{k*} \end{bmatrix} + \mathbf{a} \quad (2.56)$$

dengan

$$\mathbf{Z} = \begin{bmatrix} \mathbf{Z}_{1,t}^1 \\ \mathbf{Z}_{2,t}^1 \\ \mathbf{Z}_{3,t}^1 \\ \mathbf{Z}_{1,t}^2 \\ \mathbf{Z}_{2,t}^2 \\ \mathbf{Z}_{3,t}^2 \end{bmatrix},$$

$$\mathbf{V}_2 = \begin{bmatrix} \mathbf{Z}_{1,t-1}^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & \mathbf{Z}_{2,t-1}^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & \mathbf{Z}_{3,t-1}^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & \mathbf{Z}_{1,t-1}^1 & 0 & 0 \\ 0 & 0 & 0 & 0 & \mathbf{Z}_{2,t-1}^1 & 0 \\ 0 & 0 & 0 & 0 & 0 & \mathbf{Z}_{3,t-1}^1 \end{bmatrix},$$

$$\mathbf{V}_3 = \begin{bmatrix} F\mathbf{Z}_{1,t-1}^1 & 0 & 0 & 0 & 0 & 0 \\ 0 & F\mathbf{Z}_{2,t-1}^1 & 0 & 0 & 0 & 0 \\ 0 & 0 & F\mathbf{Z}_{3,t-1}^1 & 0 & 0 & 0 \\ 0 & 0 & 0 & F\mathbf{Z}_{1,t-1}^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & F\mathbf{Z}_{2,t-1}^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & F\mathbf{Z}_{3,t-1}^2 \end{bmatrix},$$

$$\mathbf{V}_4 = \begin{bmatrix} F\mathbf{Z}_{1,t-1}^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & F\mathbf{Z}_{2,t-1}^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & F\mathbf{Z}_{3,t-1}^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & F\mathbf{Z}_{1,t-1}^1 & 0 & 0 \\ 0 & 0 & 0 & 0 & F\mathbf{Z}_{2,t-1}^1 & 0 \\ 0 & 0 & 0 & 0 & 0 & F\mathbf{Z}_{3,t-1}^1 \end{bmatrix},$$

$$\Phi_{i0}^k = \begin{bmatrix} \phi_{10}^1 \\ \phi_{20}^1 \\ \phi_{30}^1 \\ \phi_{10}^2 \\ \phi_{20}^2 \\ \phi_{30}^2 \end{bmatrix}, \quad \Phi_{i0}^{k*} = \begin{bmatrix} \phi_{10}^{1*} \\ \phi_{20}^{1*} \\ \phi_{30}^{1*} \\ \phi_{10}^{2*} \\ \phi_{20}^{2*} \\ \phi_{30}^{2*} \end{bmatrix}, \quad \Phi_{i1}^k = \begin{bmatrix} \phi_{11}^1 \\ \phi_{21}^1 \\ \phi_{31}^1 \\ \phi_{11}^2 \\ \phi_{21}^2 \\ \phi_{31}^2 \end{bmatrix}, \quad \Phi_{i1}^{k*} = \begin{bmatrix} \phi_{11}^{1*} \\ \phi_{21}^{1*} \\ \phi_{31}^{1*} \\ \phi_{11}^{2*} \\ \phi_{21}^{2*} \\ \phi_{31}^{2*} \end{bmatrix}, \text{ dan } \mathbf{a} = \begin{bmatrix} \mathbf{a}_{1,t}^1 \\ \mathbf{a}_{2,t}^1 \\ \mathbf{a}_{3,t}^1 \\ \mathbf{a}_{1,t}^2 \\ \mathbf{a}_{2,t}^2 \\ \mathbf{a}_{3,t}^2 \end{bmatrix}$$

$$\begin{aligned}
F\mathbf{Z}_{1,t-1}^1 &= \begin{bmatrix} w_{12}Z_{2,0}^1 + w_{13}Z_{3,0}^1 \\ w_{12}Z_{2,1}^1 + w_{13}Z_{3,1}^1 \\ \vdots \\ w_{12}Z_{2,T-1}^1 + w_{13}Z_{3,T-1}^1 \end{bmatrix}, \quad F\mathbf{Z}_{2,t-1}^1 = \begin{bmatrix} w_{21}Z_{1,0}^1 + w_{23}Z_{3,0}^1 \\ w_{21}Z_{1,1}^1 + w_{23}Z_{3,1}^1 \\ \vdots \\ w_{21}Z_{1,T-1}^1 + w_{23}Z_{3,T-1}^1 \end{bmatrix}, \\
F\mathbf{Z}_{3,t-1}^1 &= \begin{bmatrix} w_{31}Z_{2,0}^1 + w_{32}Z_{2,0}^1 \\ w_{31}Z_{2,1}^1 + w_{32}Z_{2,1}^1 \\ \vdots \\ w_{31}Z_{2,T-1}^1 + w_{32}Z_{2,T-1}^1 \end{bmatrix}, \quad F\mathbf{Z}_{1,t-1}^2 = \begin{bmatrix} w_{12}Z_{2,0}^2 + w_{13}Z_{3,0}^2 \\ w_{12}Z_{2,1}^2 + w_{13}Z_{3,1}^2 \\ \vdots \\ w_{12}Z_{2,T-1}^2 + w_{13}Z_{3,T-1}^2 \end{bmatrix}, \\
F\mathbf{Z}_{2,t-1}^2 &= \begin{bmatrix} w_{21}Z_{1,0}^2 + w_{23}Z_{3,0}^2 \\ w_{21}Z_{1,1}^2 + w_{23}Z_{3,1}^2 \\ \vdots \\ w_{21}Z_{1,T-1}^2 + w_{23}Z_{3,T-1}^2 \end{bmatrix}, \quad F\mathbf{Z}_{3,t-1}^2 = \begin{bmatrix} w_{31}Z_{2,0}^2 + w_{32}Z_{2,0}^2 \\ w_{31}Z_{2,1}^2 + w_{32}Z_{2,1}^2 \\ \vdots \\ w_{31}Z_{2,T-1}^2 + w_{32}Z_{2,T-1}^2 \end{bmatrix},
\end{aligned}$$

Sehingga dapat ditulis sebagai  $F\mathbf{Z}_{i,t-1}^k = \begin{bmatrix} FZ_{i,0}^k \\ FZ_{i,1}^k \\ \vdots \\ FZ_{i,T-1}^k \end{bmatrix}$  dengan  $FZ_{i,t}^k = \sum_{j \neq i} w_{ij} Z_{j,t}^k$  lalu

persamaan (2.52) dapat ditulis menjadi  $\mathbf{Z}_i^k = \mathbf{V}_i^k \boldsymbol{\beta} + \mathbf{a}_i^k$ . Hal ini menyebabkan estimasi  $\boldsymbol{\beta} = (\phi_{10}^1, \dots, \phi_{30}^2, \phi_{10}^{1*}, \dots, \phi_{30}^{2*}, \phi_{11}^1, \dots, \phi_{31}^2, \phi_{11}^{1*}, \dots, \phi_{31}^{2*})'$  dengan  $T \rightarrow \infty$ , dapat dihitung dengan estimator *least square*, estimasinya akan menjadi  $\hat{\boldsymbol{\beta}} = (\hat{\phi}_{10}^1, \dots, \hat{\phi}_{30}^2, \hat{\phi}_{10}^{1*}, \dots, \hat{\phi}_{30}^{2*}, \hat{\phi}_{11}^1, \dots, \hat{\phi}_{31}^2, \hat{\phi}_{11}^{1*}, \dots, \hat{\phi}_{31}^{2*})'$ , sehingga persamaan 2.57.

$$\begin{aligned}
\mathbf{V}' \hat{\boldsymbol{\beta}}_T &= \mathbf{V} \mathbf{Z} \\
&= \mathbf{V}'(\mathbf{V} \boldsymbol{\beta} + \mathbf{a}) \\
&= \mathbf{V}' \mathbf{V} \boldsymbol{\beta} + \mathbf{V}' \mathbf{a} \\
\mathbf{V}' \hat{\boldsymbol{\beta}}_T - \mathbf{V}' \boldsymbol{\beta} &= \mathbf{V}' \mathbf{a} \\
\mathbf{V}' \mathbf{V}(\hat{\boldsymbol{\beta}}_T - \boldsymbol{\beta}) &= \mathbf{V}' \mathbf{a}
\end{aligned} \tag{2.57}$$

dengan demikian estimasi parameter model dengan metode *least square* dilakukan dengan meminimumkan fungsi

$$\mathbf{a}' \mathbf{a} = (\mathbf{Z} - \mathbf{V} \boldsymbol{\beta})' (\mathbf{Z} - \mathbf{V} \boldsymbol{\beta}) \tag{2.58}$$

Selanjutnya estimator  $\boldsymbol{\beta}$  dapat diperoleh dengan persamaan 2.59.

$$\hat{\beta} = (\mathbf{V}'\mathbf{V})^{-1}\mathbf{V}'\mathbf{Z} \quad (2.59)$$

maka untuk  $i=1,2,\dots,N$ , vektor parameter  $\phi_{i0}^k$ ,  $\phi_{i0}^{k*}$ ,  $\phi_{i1}^k$ , dan  $\phi_{i1}^{k*}$  adalah persamaan 2.60.

$$\phi_i^k = (\mathbf{V}'\mathbf{V})^{-1}\mathbf{V}'\mathbf{Z}_i^k \quad (2.60)$$

Selain metode OLS, model MGSTAR juga dapat diestimasi menggunakan metode *Generalized Least Square* (GLS). Persamaan model ditulis pada persamaan 2.61.

$$\mathbf{Z}_i^k = \mathbf{V}_i^k \beta_i^k + \mathbf{a}_i^k \quad (2.61)$$

atau dapat ditulis dalam bentuk matriks seperti persamaan 2.62.

$$\begin{bmatrix} \mathbf{Z}_1 \\ \vdots \\ \mathbf{Z}_N \end{bmatrix}_{(T \times 1)} = \begin{bmatrix} \mathbf{V}_1 & 0 & \dots & 0 \\ 0 & \mathbf{V}_2 & \dots & 0 \\ \dots & \dots & \ddots & \dots \\ 0 & 0 & \dots & \mathbf{V}_N \end{bmatrix}_{(T \times 1)} \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_N \end{bmatrix}_{(k \times 1)} + \begin{bmatrix} \mathbf{a}_1 \\ \vdots \\ \mathbf{a}_N \end{bmatrix}_{(T \times 1)} \quad (2.62)$$

Asumsi yang harus dipenuhi dalam menggunakan metode GLS yaitu  $E(\mathbf{a}) = 0$  dan  $E(\mathbf{a}_i, \mathbf{a}_j') = \sigma_{ij} \mathbf{I}$ . Struktur matriks varians-kovarians pada persamaan model SUR diperoleh dengan persamaan 2.63.

$$E[\mathbf{a}_i^k, \mathbf{a}_j^{l'}] = E \left[ \begin{pmatrix} a_1^1 \\ a_2^1 \\ a_3^1 \\ a_1^2 \\ a_2^2 \\ a_3^2 \end{pmatrix} \left( \begin{matrix} a_1^1 & a_2^1 & a_3^1 & a_1^2 & a_2^2 & a_3^2 \end{matrix} \right) \right] \quad (2.63)$$

dapat diuraikan menjadi persamaan 2.64.

$$\begin{aligned}
E[\mathbf{a}_i^k \mathbf{a}_j^{l'}] &= \begin{bmatrix} E(a_1^1 a_1^1) & E(a_1^1 a_2^1) & \dots & E(a_1^1 a_3^2) \\ E(a_2^1 a_1^1) & E(a_2^1 a_2^1) & \dots & E(a_2^1 a_3^2) \\ \vdots & \vdots & \ddots & \vdots \\ E(a_3^2 a_1^1) & E(a_3^2 a_2^1) & \dots & E(a_3^2 a_3^2) \end{bmatrix} \\
&= \begin{bmatrix} \sigma_1^1 \sigma_1^1 \mathbf{I} & \sigma_1^1 \sigma_2^1 \mathbf{I} & \dots & \sigma_1^1 \sigma_3^2 \mathbf{I} \\ \sigma_2^1 \sigma_1^1 \mathbf{I} & \sigma_2^1 \sigma_2^1 \mathbf{I} & \dots & \sigma_2^1 \sigma_3^2 \mathbf{I} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_3^2 \sigma_1^1 \mathbf{I} & \sigma_3^2 \sigma_2^1 \mathbf{I} & \dots & \sigma_3^2 \sigma_3^2 \mathbf{I} \end{bmatrix} \\
&= \boldsymbol{\Sigma} \otimes \mathbf{I} \\
&= \boldsymbol{\Omega}
\end{aligned} \tag{2.64}$$

sehingga estimasi model GLS dapat dilakukan dengan meminimumkan persamaan fungsi  $\mathbf{a}'\mathbf{a} = (\mathbf{Z} - \mathbf{V}\boldsymbol{\beta})'\boldsymbol{\Omega}^{-1}(\mathbf{Z} - \mathbf{V}\boldsymbol{\beta})$  dan diperoleh estimator  $\boldsymbol{\beta}$  dengan persamaan 2.65.

$$\hat{\boldsymbol{\beta}} = (\mathbf{V}'\boldsymbol{\Omega}^{-1}\mathbf{V})^{-1}\mathbf{V}'\boldsymbol{\Omega}^{-1}\mathbf{Z} \tag{2.65}$$

Diketahui bahwa beberapa kriteria estimator yang baik adalah tidak bias dan efisien. Suatu estimator  $\hat{\boldsymbol{\beta}}$  dikatakan tidak bias jika seperti pada persamaan 2.66.

$$E(\hat{\boldsymbol{\beta}}) = \boldsymbol{\beta} \tag{2.66}$$

Berdasarkan kriteria ini jika diketahui estimator untuk  $\boldsymbol{\beta}$  dengan metode OLS adalah  $\hat{\boldsymbol{\beta}}_{OLS}$  dan dengan metode GLS adalah  $\hat{\boldsymbol{\beta}}_{GLS}$  maka estimator ini adalah estimator yang tak bias jika seperti persamaan 2.67 dan 2.68.

$$\begin{aligned}
E(\hat{\boldsymbol{\beta}}_{OLS}) &= E((\mathbf{V}'\mathbf{V})^{-1}\mathbf{V}'\mathbf{Z}) \\
&= (\mathbf{V}'\mathbf{V})^{-1}\mathbf{V}'E(\mathbf{Z}) \\
&= (\mathbf{V}'\mathbf{V})^{-1}\mathbf{V}'\mathbf{V}\boldsymbol{\beta} \\
&= \mathbf{I}\boldsymbol{\beta} \\
&= \boldsymbol{\beta}
\end{aligned} \tag{2.67}$$

dan

$$\begin{aligned}
E(\hat{\boldsymbol{\beta}}_{GLS}) &= E((\mathbf{V}'\boldsymbol{\Omega}^{-1}\mathbf{V})^{-1}\mathbf{V}'\boldsymbol{\Omega}^{-1}\mathbf{Z}) \\
&= (\mathbf{V}'\boldsymbol{\Omega}^{-1}\mathbf{V})^{-1}\mathbf{V}'\boldsymbol{\Omega}^{-1}E(\mathbf{Z}) \\
&= (\mathbf{V}'\boldsymbol{\Omega}^{-1}\mathbf{V})^{-1}\mathbf{V}'\boldsymbol{\Omega}^{-1}\mathbf{V}\boldsymbol{\beta} \\
&= \mathbf{I}\boldsymbol{\beta} \\
&= \boldsymbol{\beta}
\end{aligned} \tag{2.68}$$

Terdapat banyak estimator yang tak bias untuk satu parameter  $\beta$  dan bahkan mungkin tak berhingga. Jika terdapat lebih satu parameter yang tak bias maka estimator terbaik dapat dipilih dengan kriteria efisien. Estimator  $\hat{\beta}_{GLS}$  dikatakan lebih baik dari estimator  $\hat{\beta}_{OLS}$  jika seperti persamaan 2.69.

$$\begin{aligned} \text{var}(\hat{\beta}_{GLS}) &< \text{var}(\hat{\beta}_{OLS}) \\ \frac{\text{var}(\hat{\beta}_{GLS})}{\text{var}(\hat{\beta}_{OLS})} &< 1 \end{aligned} \quad (2.69)$$

Varian dari estimator  $\hat{\beta}_{GLS}$  dan  $\hat{\beta}_{OLS}$  adalah persamaan 2.70 dan 2.71.

$$\begin{aligned} \text{var}(\hat{\beta}_{OLS}) &= \text{var}((\mathbf{V}'\mathbf{V})^{-1}\mathbf{V}'\mathbf{Z}) \\ &= (\mathbf{V}'\mathbf{V})^{-1}\mathbf{V}' \text{var}(\mathbf{Z})(\mathbf{V}')(\mathbf{V}'\mathbf{V})^{-1} \\ &= (\mathbf{V}'\mathbf{V})^{-1}\mathbf{V}'\sigma^2\mathbf{I}\mathbf{V}(\mathbf{V}'\mathbf{V})^{-1} \\ &= \sigma^2(\mathbf{V}'\mathbf{V})^{-1}\mathbf{V}'\mathbf{I}\mathbf{V}(\mathbf{V}'\mathbf{V})^{-1} \\ &= \sigma^2(\mathbf{V}'\mathbf{V})^{-1} \end{aligned} \quad (2.70)$$

dan

$$\begin{aligned} \text{var}(\hat{\beta}_{GLS}) &= \text{var}((\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1}\mathbf{V}'\Omega^{-1}\mathbf{Z}) \\ &= ((\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1}\mathbf{V}'\Omega^{-1}) \text{var}(\mathbf{Z}) ((\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1}\mathbf{V}'\Omega^{-1})' \\ &= (\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1}\mathbf{V}'\Omega^{-1}\sigma^2\Omega\Omega^{-1}\mathbf{V}(\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1} \\ &= \sigma^2(\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1}\mathbf{V}'\Omega^{-1}\Omega\Omega^{-1}\mathbf{V}(\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1} \\ &= \sigma^2(\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1}\mathbf{V}'\Omega^{-1}\mathbf{V}(\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1} \\ &= \sigma^2(\mathbf{V}'\Omega^{-1}\mathbf{V})^{-1} \end{aligned} \quad (2.71)$$

## 2.5 Uji Terasvirta

Sebelum melakukan analisis dengan metode nonlinier terlebih dahulu dilakukan pengujian linieritas pada data *time series* yang digunakan. Uji Terasvirta yang dikembangkan oleh Terasvirta, dkk (1993) merupakan pengujian yang menunjukkan apakah antara variabel respon dan variabel prediktor memiliki hubungan linier atau tidak. 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  $\chi^2$  atau uji  $F$ . Prosedur untuk mendapatkan uji  $F$  adalah sebagai berikut,

1. Meregresikan  $Z_t$  dengan  $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$ , kemudian hitung nilai residual  $\hat{u}_t$  dan jumlah kuadrat residual  $SSE_0 = \sum \hat{u}_t^2$ .
2. Meregresikan  $\hat{u}_t$  dengan  $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$  dan  $m$  prediktor tambahan, kemudian hitung nilai residual  $\hat{v}_t = \hat{u}_t - \hat{\hat{u}}_t$  serta jumlah kuadrat residual  $SSE_1 = \sum \hat{v}_t^2$ .
3. Menghitung nilai statistik uji  $F = \frac{(SSE_0 - SSE_1)/m}{SSE_1/(n-1-p-m)}$  dengan  $m$  merupakan jumlah prediktor tambahan,  $n$  merupakan banyak pengamatan dan  $p$  merupakan jumlah prediktor pada regresi awal.

Tolak  $H_0$  jika  $F > F_{\alpha, m, (n-1-p-m)}$  atau  $P\text{-value} < \alpha$  yang berarti perlu dibangun model nonlinier untuk mengestimasi model yang lebih sesuai.

## 2.6 Artificial Neural Network

Jaringan syaraf tiruan atau yang biasa disebut *Artificial Neural Network (ANN)* merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk menstimulasi proses pembelajaran pada otak manusia tersebut (Kusumadewi, 2003). *Neural network* dibentuk sebagai generalisasi model matematika dari jaringan syaraf biologi dengan asumsi bahwa (Siang, 2005):

1. Pemrosesan informasi terjadi pada banyak elemen sederhana (*neuron*).
2. Sinyal dikirimkan diantara *neuron* melalui penghubung.
3. Penghubung antar *neuron* memiliki bobot yang akan memperkuat atau memperlemah sinyal.
4. Untuk menentukan *output*, setiap *neuron* menggunakan fungsi aktivasi (biasanya bukan fungsi linier) yang dikenakan pada jumlahan *input* yang diterima. Besarnya *output* ini selanjutnya dibandingkan dengan suatu batas ambang.

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). Berbagai macam *activation function* yang digunakan untuk mendapatkan *output* antara lain dapat dilihat pada Tabel 2.2.

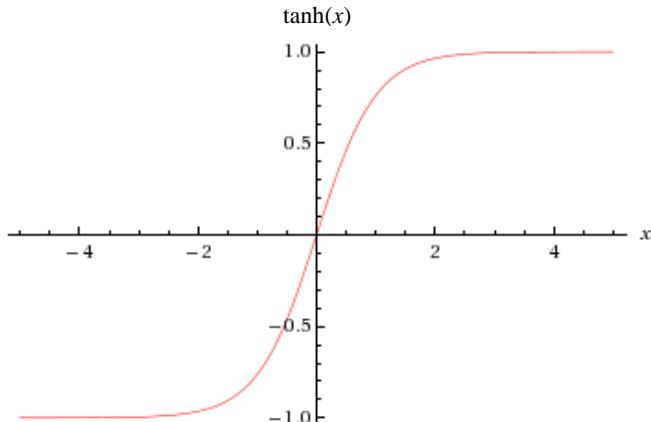
**Tabel 2.2** Contoh Activation Function

Activation Function	Persamaan
Linear atau Identity	$f(x) = x$
Hyperbolic Tangent	$f(x) = \tanh(x)$
Sigmoid	$f(x) = (1 + \exp(-x))^{-1}$

Fungsi aktivasi pada *output layer* yang digunakan pada penelitian ini berupa fungsi linier, sedangkan pada *hidden layer* menggunakan fungsi *hyperbolic tangent* ( $\tanh$ ), yaitu:

$$f^h(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} = \frac{1 + e^{-2x}}{1 - e^{-2x}}.$$

Fungsi ini menghasilkan nilai berkisar antara -1 sampai 1 seperti Gambar 2.3.



**Gambar 2.3** Fungsi *Hyperbolic Tangent*

Sebelum melakukan pemodelan dengan menggunakan ANN maka perlu dilakukan uji linieritas. Pada penelitian ini, pengujian linieritas akan dilakukan dengan uji Terasvirta. Apabila terdapat pola nonlinieritas pada data, maka model ANN dapat digunakan. Dalam ANN terdapat istilah arsitektur yang terdiri atas *layer* pemodelan yang terdiri *input layer*, *hidden layer* dan *output layer*. Terdapat beberapa jenis desain arsitektur ANN, diantaranya *back-propagation (feed forward)*, *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).

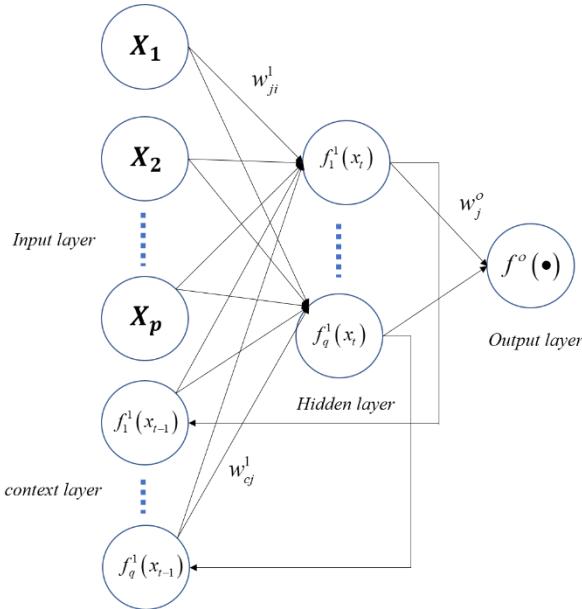
## 2.7 Recurrent Neural Network

*Recurrent Neural Network* adalah jaringan syaraf yang mempunyai koneksi *feedback*. Menurut Kusumadewi (2004), jaringan *recurrent* adalah jaringan yang mengakomodasi *output* jaringan untuk menjadi *input* pada jaringan itu lagi dalam rangka menghasilkan *output* jaringan berikutnya. Pada model RNN, *neuron* dihubungkan kembali dengan neuron yang lain dan arah informasi menjadi multidireksional sehingga aktivasi *neuron* dapat mengalir dalam sistem *loopi* (Lewis, 2016).

Arsitektur RNN memiliki suatu *layer* yang berbeda dengan FFNN yaitu *context layer*. *Context layer* ini berisi *delay neuron* yang merupakan *neuron* penyimpan memori nilai-nilai aktivasi pada proses sebelumnya. *Delay neuron* juga akan melepaskan kembali nilai-nilai yang disimpan untuk langkah selanjutnya pada jaringan. Ada dua jenis RNN diantaranya *Elman Recurrent Neural Network (ERNN)* dan *Jordan Recurrent Neural Network (JRNN)*.

### a. *Elman Recurrent Neural Network (ERNN)*

*Elman Recurrent Neural Network* adalah jaringan syaraf tiruan yang memiliki koneksi umpan balik sederhana dari lapisan tersembunyi menuju lapisan konteks (*context layer*) yang terdiri dari operator-operator *unit time delays* (Haykin, 2009). Pada ERNN jumlah *neuron context layer* sama dengan jumlah *neuron* pada *hidden layer* dan masing-masing *neuron context layer* terhubung ke masing-masing *neuron* pada *hidden layer*. *Neuron-neuron* pada *context layer* berinteraksi secara eksklusif dengan neuron lain pada internal jaringan dan bukan menuju output secara langsung (Elman, 1990). Arsitektur ERNN dengan satu *hidden layer* diberikan pada Gambar 2.4



**Gambar 2.4.** Arsitektur Model ERNN dengan Satu *Hidden Layer*

Persamaan model ERNN berdasarkan Gambar 2.4 adalah persamaan 2.72.

$$\hat{Y}_t = f^o \left[ \sum_{j=1}^q \left[ w_j^o f_j^1 \left( \sum_{i=1}^p w_{ji}^1 x_{i(t)} + \sum_{c=1}^q w_{jc}^1 f_j^1 x_{i(t-1)} \right) \right] \right] \quad (2.72)$$

dengan

- $\hat{Y}_t$  = nilai estimasi dari variabel *output*
- $x_i$  = variabel *input*, ( $i = 1, 2, \dots, p$ )
- $f^o$  = fungsi aktivasi *neuron* di *output layer*
- $w_j^o$  = bobot dari *input* ke- $j$  di *hidden layer* menuju *neuron* pada *output layer*, ( $j = 1, 2, \dots, q$ )
- $f_j^1$  = fungsi aktivasi *neuron* ke- $j$  pada *hidden layer*
- $w_{ji}^1$  = bobot dari *input* ke- $i$  menuju *neuron* ke- $j$  pada *hidden layer*
- $w_{jc}^1$  = bobot dari *input* ke- $c$  dari *context layer* menuju *neuron* ke- $j$  pada *hidden layer*
- $f_j^1 x_{i(t-1)}$  = *context layer*

Terdapat beberapa macam algoritma dalam ANN, salah satunya adalah algoritma *backpropagation*. Algoritma *back-propagation* memaksimalkan hasil

*training* dengan meminimumkan nilai *error* yang dilakukan dengan modifikasi bobot yang digunakan dalam perhitungan. Ketika ditemukan bobot baru, proses training akan dilakukan kembali. Proses ini akan dilakukan secara berulang-ulang dan akan berhenti pada saat didapatkan *error* yang telah memenuhi uji syarat berhenti. Berikut ini merupakan urutan langkah-langkah dalam algoritma *backpropagation* yang digunakan pada jaringan ERNN adalah sebagai berikut (Fausett, 1994).

Langkah 1: Inisiasi bobot.

Langkah 2: Selama kondisi berhenti salah, kerjakan langkah berikut.

**a) Fase 1 (Perambatan Maju/*Feedforward*)**

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

Langkah 4: Tiap *hidden layer* ( $y_j, j=1,2,\dots,q$ ) menjumlahkan bobot sinyal *input* seperti pada persamaan 2.73

$$y\_in_{(1)j} = w_{0j} + \sum_{i=1}^p x_i w_{ij}. \quad (2.73)$$

Dengan menerapkan fungsi aktivasi hitung pada persamaan 2.74.

$$y_{(1)j} = f(y\_in_{(1)j}). \quad (2.74)$$

Apabila fungsi aktivasi yang digunakan adalah *hyperbolic tangent*, maka hasil keluaran yang didapat pada *hidden layer* seperti persamaan 2.75.

$$y_{(1)j} = \tanh(y\_in_{(1)j}). \quad (2.75)$$

Tiap neuron konteks ( $C_c, c=1,2,\dots,q$ ) menerima sinyal dan meneruskan sinyal ke *hidden layer*. Sinyal yang diterima neuron konteks adalah hasil dari aktivasi sinyal dari *hidden layer* yang dirumuskan dalam persamaan 2.76.

$$C_c = y_{(1)j}. \quad (2.76)$$

Neuron konteks kemudian mengirimkan kembali sinyal ke neuron *hidden layer* yang dirumuskan dalam persamaan 2.77.

$$y\_in_{(2)j} = \sum_{j=1}^q C_j w_{jc}. \quad (2.77)$$

Tiap neuron pada *hidden layer* ( $y_j, j=1,2,\dots,q$ ) menjumlahkan sinyal-sinyal *input* terbobot yang diperoleh dari lapisan *input* dan neuron konteks. Penjumlahan sinyal ini dirumuskan dalam persamaan 2.78.

$$y\_in_j = y\_in_{(1)j} + y\_in_{(2)j} \quad (2.78)$$

Kemudian mengirimkan isyarat ini pada unit *output*.

Langkah 5: Unit *output* ( $z$ ) menjumlahkan isyarat masukan berbobot dengan persamaan 2.79.

$$z\_in = v_0 + \sum_{j=1}^q y_j v_j. \quad (2.79)$$

Dengan menerapkan fungsi aktivasi hitung seperti persamaan 2.80.

$$z = f(z\_in). \quad (2.80)$$

### b) Fase 2 (Perambatan Mundur / Backpropagation)

Langkah 6: Unit *output* ( $z$ ) menerima pola pelatihan masukannya dan menghitung *error* informasinya seperti pada persamaan 2.81, dengan  $tr$  merupakan *output* target

$$\delta = (tr - z) f'(z\_in). \quad (2.81)$$

Hitung koreksi bobot dan biasnya dengan persamaan 2.82 dan 2.83.

$$\Delta v_j = \eta \delta z_j. \quad (2.82)$$

$$\Delta v_0 = \eta \delta. \quad (2.83)$$

dengan  $\eta$  = laju percepatan.

Langkah 7: Tiap *hidden layer* ( $y_j, j=1,2,\dots,q$ ) menghitung delta masukannya dengan persamaan 2.84 (dari unit-unit yang berada pada lapisan atasnya).

$$\delta\_in_j = \delta v_j. \quad (2.84)$$

Hitung *error* informasinya dengan persamaan 2.85.

$$\delta_j = \delta_{in_j} f'(y_{in_j}). \quad (2.85)$$

Hitung koreksi bobot dan biasnya dengan persamaan 2.86 dan 2.87.

$$\Delta w_{ij} = \eta \delta_j x_i. \quad (2.86)$$

$$\Delta w_{jc} = \eta \delta_j C_c. \quad (2.87)$$

### c) Fase 3 (Perubahan Bobot)

Langkah 8: Neuron *output* ( $z$ ) memperbarui bobot dan bias dengan persamaan 2.88 dan 2.89.

$$v_0(baru) = v_0(lama) + \Delta v_0. \quad (2.88)$$

$$v_j(baru) = v_j(lama) + \Delta v_j. \quad (2.89)$$

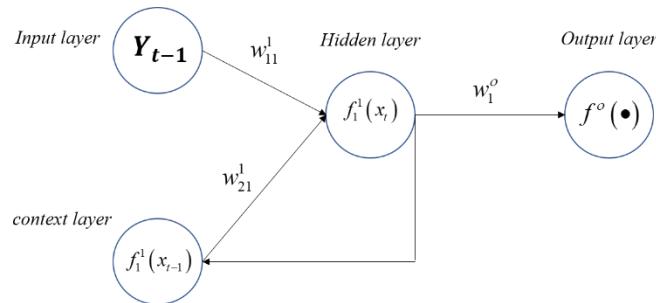
Tiap *hidden layer* ( $y_j, j=1,2,\dots,q$ ) memperbarui bobot dan biasnya dengan persamaan 2.90 dan 2.91.

$$w_{ij}(baru) = w_{ij}(lama) + \Delta w_{ij}. \quad (2.90)$$

$$w_{jc}(baru) = w_{jc}(lama) + \Delta w_{jc}. \quad (2.91)$$

Langkah 9: Uji syarat berhenti, jika nilai *error* < target *error* yang digunakan.

Diberikan ilustrasi model Elman RNN dengan satu *input* yang digunakan yaitu  $Y_{t-1}$  dan satu *neuron* pada *hidden layer*. Fungsi aktivasi pada *hidden layer* adalah fungsi nonlinier *tanh* dan fungsi aktivasi pada *output layer* adalah fungsi linier. Ilustrasi tersebut diberikan pada Gambar 2.5 berikut:



**Gambar 2.5.** Arsitektur Model ERNN dengan satu *neuron* pada *hidden layer*  
Persamaan untuk Gambar 2.4 dituliskan pada persamaan 2.92.

$$\hat{Y}_t = w_1^o f_{1,t}^1(\bullet) \quad (2.92)$$

Dengan persamaan 2.93.

$$f_{1,t}^1(\bullet) = \tanh(w_{11}^1 Y_{t-1} + w_{21}^1 f_{1,t-1}^1(\bullet)) \quad (2.93)$$

Jika diketahui  $\hat{Y}_{t-1} = Y_{t-1} - a_{t-1}$  maka dengan substitusi pada persamaan 2.92

diperoleh persamaan 2.94.

$$\begin{aligned} Y_{t-1} - a_{t-1} &= w_1^o f_{1,t-1}^1(\bullet) \\ f_{1,t-1}^1(\bullet) &= \frac{Y_{t-1}}{w_1^o} - \frac{a_{t-1}}{w_1^o} \end{aligned} \quad (2.94)$$

Sehingga menjadi persamaan 2.95.

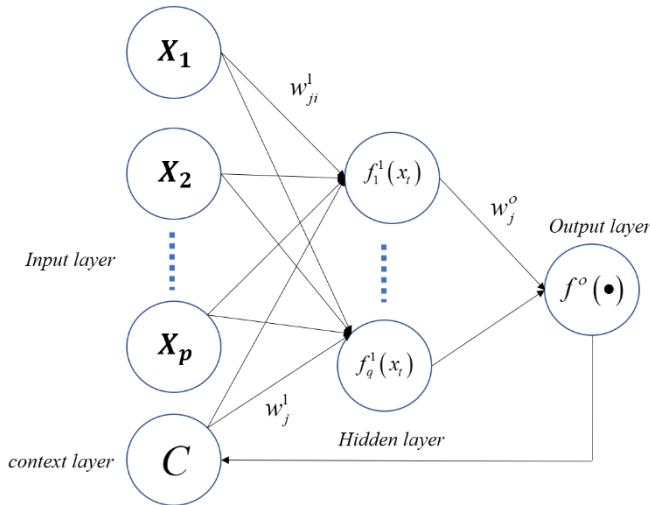
$$\begin{aligned} f_{1,t}^1(\bullet) &= \tanh\left(w_{11}^1 Y_{t-1} + w_{21}^1 \left(\frac{Y_{t-1}}{w_1^o} - \frac{a_{t-1}}{w_1^o}\right)\right) \\ &= \tanh\left(w_{11}^1 Y_{t-1} + \frac{w_{21}^1}{w_1^o} (Y_{t-1} - a_{t-1})\right) \\ &= \tanh\left(\left(w_{11}^1 + \frac{w_{21}^1}{w_1^o}\right) Y_{t-1} - \frac{w_{21}^1}{w_1^o} a_{t-1}\right) \end{aligned} \quad (2.95)$$

Jadi persamaan 2.92 dituliskan menjadi persamaan 2.96.

$$\hat{Y}_t = w_1^o \times \tanh\left(w_{11}^1 Y_{t-1} + w_{21}^1 \left(\frac{Y_{t-1}}{w_1^o} - \frac{a_{t-1}}{w_1^o}\right)\right) \quad (2.96)$$

### b. *Jordan Recurrent Neural Network (JRNN)*

*Jordan Recurrent Neural Network* memiliki pola kerja yang sama dengan ERNN, akan tetapi terdapat perbedaan antara JRNN dan ERNN. Perbedaan antara kedua arsitektur tersebut adalah *neuron* pada *context layer* dialiri informasi melalui *output layer* bukan *hidden layer* seperti pada ERNN (Lewis, 2016). Hasil dari *output layer* akan disalin ke *context layer* sehingga bobot unit pada *context layer* akan tetap bernilai satu. Kemudian nilai dari *context layer* akan masuk dalam jaringan kembali (Jordan, 1997). Gambar 2.6 menunjukkan arsitektur JRNN dengan satu *hidden layer*.



**Gambar 2.6.** Arsitektur Model JRNN dengan Satu *Hidden Layer*

Persamaan model JRNN berdasarkan Gambar 2.6 adalah persamaan 2.97.

$$\hat{Y}_t = f^o \left[ \sum_{j=1}^q \left[ w_j^o f_j^l \left( \sum_{i=1}^p w_{ji}^l x_{i(t)} + w_j^l C_{(t)} \right) \right] \right] \quad (2.97)$$

dengan

$\hat{Y}_t$  = nilai estimasi dari variable *output*

$x_i$  = variable *input*, ( $i = 1, 2, \dots, p$ )

$f^o$  = fungsi aktivasi *neuron* di *output layer*

$w_j^o$  = bobot dari *input* ke- $j$  di *hidden layer* menuju *neuron* pada *output layer*,  
( $j = 1, 2, \dots, q$ )

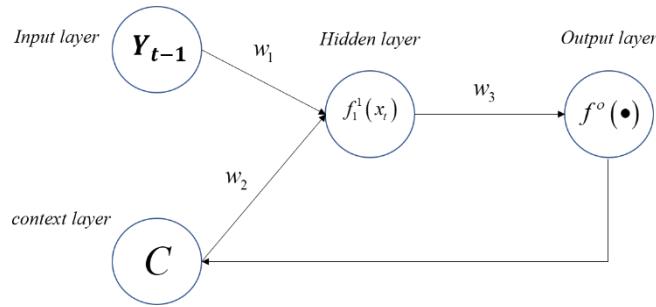
$f_j^l$  = fungsi aktivasi *neuron* ke- $j$  pada *hidden layer*

$w_{ji}^l$  = bobot dari *input* ke- $I$  menuju *neuron* ke- $j$  pada *hidden layer*

$w_j^l$  = bobot dari *context layer* menuju *neuron* ke- $j$  pada *hidden layer*

$C_{(t)} = \hat{Y}_{(t-1)}$  = *Context layer* yang selanjutnya menjadi *input*

Contoh pemodelan JRNN dengan satu *input* yang digunakan yaitu  $Y_{t-1}$  dan satu *neuron* pada *hidden layer*. Arsitektur yang terbentuk adalah sebagai berikut



**Gambar 2.7.** Arsitektur Model JRNN dengan satu *neuron pada hidden layer*

Berdasarkan Gambar 2.7 dapat dituliskan model JRNN pada persamaan 2.98.

$$\hat{Y}_t = f^o \left( w_3 f^h \left( w_1 Y_{t-1} + w_2 \hat{Y}_{t-1} \right) \right) \quad (2.98)$$

Jika diketahui  $\hat{Y}_{t-1} = Y_{t-1} - a_{t-1}$  maka persamaan 2.98 menjadi persamaan 2.99.

$$\hat{Y}_t = f^o \left( w_3 f^h \left( w_1 Y_{t-1} + w_2 (\hat{Y}_{t-1} - a_{t-1}) \right) \right) \quad (2.99)$$

Selanjutnya diperoleh persamaan 2.100.

$$\hat{Y}_t = f^o \left( w_3 f^h \left( (w_1 + w_2) Y_{t-1} - w_2 (a_{t-1}) \right) \right) \quad (2.100)$$

## 2.8 Model Hybrid MGSTARX-RNN

Zhang (2003) pertama kali memperkenalkan model *Hybrid* untuk menambah tingkat akurasi dari suatu *forecast*. Zhang (2003) mengembangkan model ini karena beberapa alasan. Pertama, susahnya pemilihan metode *forecasting* yang dapat memenuhi situasi unik dari data. Kedua, suatu data *time series* di kehidupan tidak murni mempunyai pola linier atau nonlinier saja dan yang ketiga banyak penelitian menyatakan bahwa belum terdapat suatu metode yang baik digunakan untuk setiap situasi. Secara matematis model *hybrid* yang menggabungkan dua komponen yaitu komponen linier dan nonlinier dapat dituliskan sebagai persamaan 2.101.

$$Y_t = L_t + N_t + \varepsilon_t \quad (2.101)$$

dengan  $L_t$  adalah komponen linier dan  $N_t$  adalah komponen nonlinier. Komponen nonlinier dari suatu data dapat diketahui dengan cara memodelkan residual dengan menggunakan ANN. 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 MGSTAR-RNN yang digunakan pada penelitian ini yaitu MGSTAR-ERNN, dan MGSTAR-JRNN.

## 2.9 Pemilihan Model Terbaik

Pemilihan model terbaik menggunakan kriteria *Root Mean Square Error (RMSE)* dengan membandingkan nilai RMSE terkecil. Nilai RMSE dari suatu model dapat diperoleh melalui perhitungan seperti pada persamaan 2.102.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{M} \sum_{l=1}^M (Z_{n+l} - \hat{Z}_n(l))^2} \quad (2.102)$$

Selain itu, juga digunakan *Symmetric Mean Absolute Percentage Error (sMAPE)* sebagai kriteria kebaikan model. sMAPE merupakan bentuk simetrik dari MAPE dengan persamaan 2.103 (De Gooijer & Hyndman, 2006):

$$sMAPE = \left( \frac{1}{M} \sum_{l=1}^M \frac{2|Z_{n+l} - \hat{Z}_n(l)|}{|Z_{n+l} + \hat{Z}_n(l)|} \right) \times 100\% \quad (2.103)$$

dengan

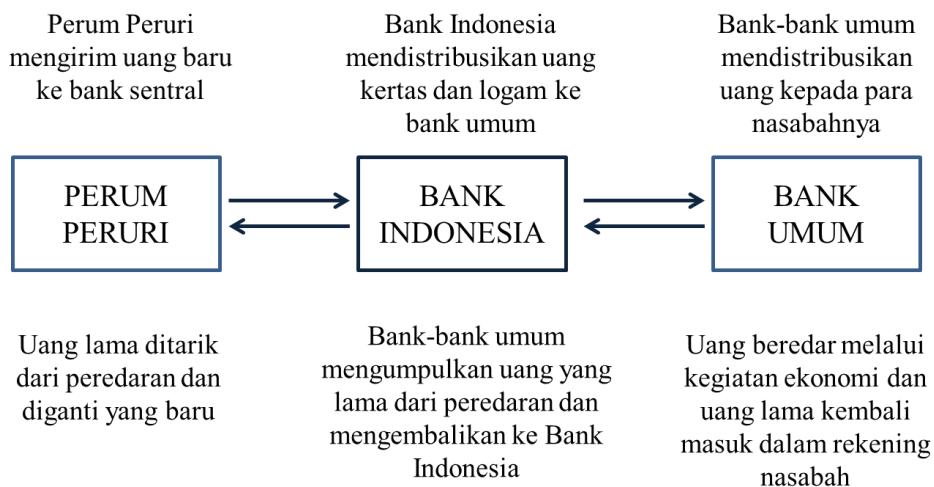
$Z_{n+l}$  = data *out sample* yang ke- $l$  ( $l = 1, 2, \dots, M$ )

$\hat{Z}_n(l)$  = ramalan untuk data *out sample* yang ke- $l$

$M$  = panjang data *out sample*

## 2.10 Inflow dan Outflow Uang Kartal

*Inflow* uang kartal adalah aliran uang kertas dan uang logam yang masuk dari perbankan dan masyarakat ke Bank Sentral, terdiri dari setoran 56 bank dan non-bank, penukaran masuk dari loket Bank Sentral dan kas keliling, serta transaksi masuk kas titipan. Sedangkan *outflow* uang kartal merupakan aliran uang kertas dan uang logam yang keluar dari Bank Sentral kepada perbankan dan masyarakat, terdiri dari bayaran bank dan non-bank, penukaran keluar dari loket Bank Sentral dan kas keliling, serta transaksi keluar kas titipan (Bank Indonesia, 2017). Aliran uang di Indonesia ditunjukkan pada alur peredaran uang pada Gambar 2.8.



**Gambar 2.8** Alur Peredaran Uang di Indonesia

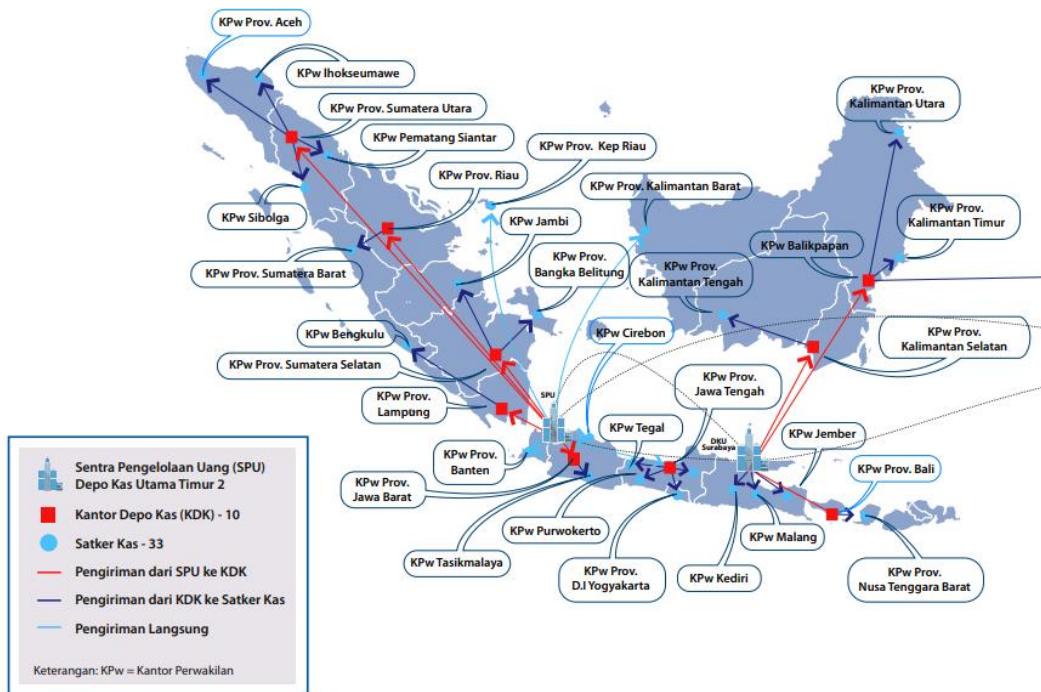
Uang kartal yang diedarkan (UYD) berdasarkan pecahan (denominasi) merupakan pengklasifikasian uang berdasarkan jenis pecahannya, yang terdiri dari uang kertas (UK) berupa pecahan Rp1000, Rp2000, Rp5000, Rp10.000, Rp20.000, Rp50.000, dan Rp100.000 serta uang logam (UL) yang terdiri dari Rp1, Rp2, Rp5, Rp25, Rp50, Rp100, Rp200, Rp500, dan Rp1000. Pengklasifikasiannya denominasi rupiah juga dapat terdiri dari Uang Pecahan Besar (UPB) yang berisi Rp20.000 ke atas dan Uang Pecahan Kecil (UPK) yaitu Rp10.000 ke bawah (Bank Indonesia, 2017). Uang kertas yang masuk dalam UPB akan ditunjukkan pada Gambar 2.9.



**Gambar 2.9.** Nominal Uang Pecahan Besar (UPB)

Perkembangan *inflow* dan *outflow* 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 (Sigalingging dkk, 2004). Aktivitas peredaran uang kartal di provinsi DKI Jakarta sepanjang triwulan II 2019 mengalami *net outflow*. Hal ini berarti jumlah aliran uang yang keluar dari kas Bank Sentral lebih tinggi dibandingkan dengan jumlah uang masuk ke Bank Sentral. *Net outflow* pada triwulan II 2019 mencapai Rp24,5 triliun lebih tinggi dibandingkan dengan *net outflow* pada triwulan sebelumnya.



Sumber: Bank Indonesia

**Gambar 2.10** Jaringan Distribusi Persebaran Uang Bank Sentral

Aliran uang kartal di Kantor Perwakilan Bank Sentral Provinsi Jawa Barat pada triwulan II 2019 menunjukkan posisi *net inflow* sebesar Rp 3,01 triliun. Posisi *net inflow* tercatat lebih rendah dibandingkan triwulan I 2019 yang mencapai Rp 14,54 triliun. Penurunan *net inflow* sesuai dengan historis *seasonal* di mana aliran *inflow* uang cenderung menurun selama periode Ramadhan hingga Lebaran seiring dengan meningkatnya aktivitas konsumsi masyarakat.

Pada triwulan II 2019, aliran uang kartal di Jawa tengah dalam posisi *net inflow*. Posisi *net inflow* tercatat sebesar Rp3,77 triliun, mengalami penurunan dibandingkan triwulan sebelumnya yang mengalami *net inflow* sebesar Rp10,85 triliun. posisi aliran uang kartal dari perbankan dan masyarakat ke Bank Sentral (*inflow*) meningkat 30,33%. Pada periode yang sama, aliran uang kartal dari Bank

Sentral (*outflow*) juga mengalami peningkatan 68,52% seiring dengan peningkatan kebutuhan masyarakat terhadap uang kartal selama periode Ramadhan dan Lebaran. Posisi uang kartal pasca Lebaran cenderung berada pada posisi *net inflow*, sering dengan pola konsumsi masyarakat yang kembali normal.

Untuk DI Yogyakarta secara umum pada triwulan II 2019 mengalami *net outflow*. Hal ini merupakan faktor siklikal, sebagai dampak peningkatan permintaan uang perbankan karena faktor liburan Idul Fitri dan liburan sekolah tahun 2019 sesudah Idul Fitri. *Net outflow* DIY tercatat sebesar Rp1,7 Triliun, menjadi *net outflow* tertinggi dalam 2 tahun terakhir. Sementara itu nominal *inflow* sebesar Rp5,9 Triliun, turun sebesar -3,57% (yoY) dibanding rata-rata triwulan II tahun sebelumnya.

Pergerakan *inflow* (uang masuk) dan *outflow* (uang keluar) di Jawa Timur pada triwulan II 2019, 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. Selain itu posisi *net outflow* tersebut juga disebabkan oleh meningkatnya *outflow* dari semula Rp16,4 triliun (triwulan I) menjadi Rp36,1 triliun pada triwulan II 2019 atau meningkat 119,6%. Sementara itu jumlah *inflow* hanya meningkat 19,4% dari Rp27,8 triliun (triwulan I) menjadi Rp33,2 triliun pada triwulan II 2019.

## BAB 3

### METODOLOGI PENELITIAN

#### 3.1 Kajian Simulasi

Studi simulasi ini bertujuan untuk mengetahui performa model MGSTAR-RNN berdasarkan kriteria RMSE. Studi simulasi pada penelitian ini menggunakan data simulasi pada penelitian sebelumnya, yaitu bangkitan data yang mengikuti model *Vector Autoregressive* (VAR). Persamaan model untuk tiga lokasi dengan dua variabel adalah sebagai berikut.

$$\begin{bmatrix} Z_{1,t}^1 \\ Z_{2,t}^1 \\ Z_{3,t}^1 \\ Z_{1,t}^2 \\ Z_{2,t}^2 \\ Z_{3,t}^2 \end{bmatrix} = \begin{bmatrix} 0.45 & 0.25 & 0.15 & 0.25 & -0.15 & -0.15 \\ 0.40 & 0.20 & 0.20 & -0.10 & 0.10 & -0.10 \\ 0.20 & 0.30 & 0.35 & -0.10 & -0.10 & 0.20 \\ 0.20 & -0.15 & -0.10 & 0.25 & 0.15 & 0.10 \\ -0.10 & 0.20 & -0.15 & 0.25 & 0.40 & 0.25 \\ -0.15 & -0.10 & 0.25 & 0.40 & 0.25 & 0.35 \end{bmatrix} \begin{bmatrix} Z_{1,t-1}^1 \\ Z_{2,t-1}^1 \\ Z_{3,t-1}^1 \\ Z_{1,t-1}^2 \\ Z_{2,t-1}^2 \\ Z_{3,t-1}^2 \end{bmatrix} + \begin{bmatrix} a_{1,t}^1 \\ a_{2,t}^1 \\ a_{3,t}^1 \\ a_{1,t}^2 \\ a_{2,t}^2 \\ a_{3,t}^2 \end{bmatrix}$$

dengan koefisien parameter yang digunakan sesuai dengan syarat model VAR yaitu nilai mutlak dari *eigen value* bernilai kurang dari 1. Model pada persamaan di atas telah memenuhi persyaratan tersebut dengan nilai *eigen* yang diperoleh yaitu 0,87171; 0,72406; 0,52364; 0,34258; -0,26675 dan -0,19526. Terdapat 2 skenario simulasi yang dilakukan dengan keterangan sebagai berikut.

##### a. Skenario 1

Pada skenario ini matriks varians-kovarians yang digunakan menunjukkan bahwa residual mempunyai hubungan antar variabel yang sama dengan lokasi yang berbeda dengan  $a_t \sim MN(0, \Sigma)$ . Matriks varians-kovariansnya sebagai berikut :

$$\Sigma = \begin{bmatrix} 1 & 0.65 & 0.50 & 0 & 0 & 0 \\ 0.65 & 1 & 0.45 & 0 & 0 & 0 \\ 0.50 & 0.45 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0.55 & 0.40 \\ 0 & 0 & 0 & 0.55 & 1 & 0.35 \\ 0 & 0 & 0 & 0.40 & 0.35 & 1 \end{bmatrix}$$

##### b. Skenario 2

Skenario kedua menggunakan model dengan persamaan yang sama namun dengan  $a_t \sim MN(0, \Sigma)$  yang menunjukkan adanya hubungan pada

residual ketika variabel berbeda namun berada di lokasi yang sama. Matriks varians-kovarians dalam scenario 2 adalah sebagai berikut :

$$\Sigma = \begin{bmatrix} 1 & 0 & 0 & 0.35 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0.50 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0.25 \\ 0.35 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0.50 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0.25 & 0 & 0 & 1 \end{bmatrix}$$

Langkah-langkah yang dilakukan pada kajian simulasi ini adalah sebagai berikut.

1. Mendapatkan data lag pertama dari data simulasi  $Z_{i,t}^k$  yaitu  $Z_{i,t-1}^k$  dan  $F_{i,t-1}^k$  yang merupakan perkalian bobot lokasi dengan data  $Z_{i,t-1}^k$ , pada simulasi ini bobot yang digunakan merupakan bobot seragam.
2. Melakukan pemodelan MGSTAR dan *hybrid* MGSTAR-RNN, yaitu MGSTAR-Elman RNN (MGSTAR-ERNN) dan MGSTAR-Jordan RNN (MGSTAR-JRNN).
3. Lakukan langkah 1 dan 2 pada 10 replikasi data simulasi.
4. Hitung rata-rata RMSE dari 10 replikasi masing-masing pemodelan.
5. Lakukan perbandingan model MGSTAR dan MGSTAR-RNN pada data simulasi untuk menentukan model terbaik.
6. Ulangi langkah 1 hingga 5 untuk setiap skenario yang digunakan.

## 3.2 Kajian Terapan

### 3.2.1 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari Bank Sentral dapat dilihat pada Lampiran 1. Data yang digunakan adalah data *inflow* dan *outflow* uang kartal pecahan besar (UPB) di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta. Periode data yang digunakan adalah Januari 2000 sampai dengan Juni 2019 dan dibagi menjadi dua bagian yaitu data *in sample* dan data *out sample*. Data *in sample* mulai Januari 2000 sampai Desember 2017 sedangkan data *out sample* mulai Januari 2018 hingga Juni 2019.

### 3.2.2 Variabel Penelitian

Berdasarkan studi kasus dan tujuan penelitian, maka variabel penelitian yang akan digunakan pada penelitian ini adalah sebagai berikut:

**Tabel 3.1** Variabel Penelitian (dalam miliar rupiah)

Data	Variabel	Keterangan
<i>Inflow</i>	$Z_{1,t}^1$	pecahan Rp 100.000,- di KPw Surabaya
	$Z_{1,t}^2$	pecahan Rp 50.000,- di KPw Surabaya
	$Z_{1,t}^3$	pecahan Rp 20.000,- di KPw Surabaya
	$Z_{2,t}^1$	pecahan Rp 100.000,- di KPw Semarang
	$Z_{2,t}^2$	pecahan Rp 50.000,- di KPw Semarang
	$Z_{2,t}^3$	pecahan Rp 20.000,- di KPw Semarang
	$Z_{3,t}^1$	pecahan Rp 100.000,- di KPw Yogyakarta
	$Z_{3,t}^2$	pecahan Rp 50.000,- di KPw Yogyakarta
	$Z_{3,t}^3$	pecahan Rp 20.000,- di KPw Yogyakarta
	$Z_{4,t}^1$	pecahan Rp 100.000,- di KPw Bandung
	$Z_{4,t}^2$	pecahan Rp 50.000,- di KPw Bandung
	$Z_{4,t}^3$	pecahan Rp 20.000,- di KPw Bandung
	$Z_{5,t}^1$	pecahan Rp 100.000,- di KPw Jakarta
	$Z_{5,t}^2$	pecahan Rp 50.000,- di KPw Jakarta
	$Z_{5,t}^3$	pecahan Rp 20.000,- di KPw Jakarta
<i>Outflow</i>	$Y_{1,t}^1$	pecahan Rp. 100.000,- di KPw Surabaya
	$Y_{1,t}^2$	pecahan Rp. 50.000,- di KPw Surabaya
	$Y_{1,t}^3$	pecahan Rp. 20.000,- di KPw Surabaya
	$Y_{2,t}^1$	pecahan Rp. 100.000,- di KPw Semarang
	$Y_{2,t}^2$	pecahan Rp. 50.000,- di KPw Semarang
	$Y_{2,t}^3$	pecahan Rp. 20.000,- di KPw Semarang
	$Y_{3,t}^1$	pecahan Rp. 100.000,- di KPw Yogyakarta
	$Y_{3,t}^2$	pecahan Rp. 50.000,- di KPw Yogyakarta
	$Y_{3,t}^3$	pecahan Rp. 20.000,- di KPw Yogyakarta
	$Y_{4,t}^1$	pecahan Rp. 100.000,- di KPw Bandung

**Tabel 3.1** Variabel Penelitian (dalam miliar rupiah) (Lanjutan)

Data	Variabel	Keterangan
<i>Outflow</i>	$Y_{4,t}^2$	pecahan Rp. 50.000,- di KPw Bandung
	$Y_{4,t}^3$	pecahan Rp. 20.000,- di KPw Bandung
	$Y_{5,t}^1$	pecahan Rp. 100.000,- di KPw Jakarta
	$Y_{5,t}^2$	pecahan Rp. 50.000,- di KPw Jakarta
	$Y_{5,t}^3$	pecahan Rp. 20.000,- di KPw Jakarta

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

1. Variabel *dummy trend* dan kebijakan Bank Sentral

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

$D_{i,t}$  : *dummy* kebijakan Bank Sentral 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 Sentral pada periode ke- $i$ .

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

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

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

⋮

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

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 Idul Fitri ( $t$ ), dan satu bulan setelah lebaran Idul Fitri ( $t + 1$ ). Efek satu bulan sebelum lebaran Idul Fitri, yaitu

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

⋮

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

Efek pada bulan Lebaran Idul Fitri, yaitu

$$CV_{1,t} = \begin{cases} 1, & \text{bulan saat Idul Fitri yang terjadi pada minggu ke-1,} \\ 0, & \text{bulan lainnya,} \end{cases}$$

⋮

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

Efek satu bulan setelah lebaran Idul Fitri, yaitu

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

⋮

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

Periode terjadinya hari raya Idul Fitri dapat dilihat pada Tabel 3.2 dan sesuai dengan ketentuan minggu berdasarkan peraturan Bank Sentral seperti berikut:

Minggu ke-1 : tanggal 1 sampai tanggal 7

Minggu ke-2 : tanggal 8 sampai tanggal 15,

Minggu ke-3 : tanggal 16 sampai tanggal 23,

Minggu ke-4 : tanggal 24 sampai dengan tanggal terakhir pada bulan tersebut.

**Tabel 3.2** Tanggal Hari Raya Idul Fitri

Tahun	Hari Raya Idul Fitri		
		Tanggal Hari Raya	Minggu terjadinya Hari Raya
2000	8-9	Januari	Minggu ke-2
2000	27-28	Desember	Minggu ke-4
2001	17-18	Desember	Minggu ke-3
2002	6-7	Desember	Minggu ke-1
2003	25-26	November	Minggu ke-4
2004	14-15	November	Minggu ke-2

**Tabel 3.2** Tanggal Hari Raya Idul Fitri (lanjutan)

Tahun	Hari Raya Idul Fitri		
	Tanggal	Hari Raya	Minggu terjadinya Hari Raya
2005	3-4	November	Minggu ke-1
2006	23-24	Okttober	Minggu ke-4
2007	12-13	Okttober	Minggu ke-2
2008	1-2	Okttober	Minggu ke-1
2009	20-21	September	Minggu ke-3
2010	10-11	September	Minggu ke-2
2011	30-31	Agustus	Minggu ke-4
2012	19-20	Agustus	Minggu ke-3
2013	8-9	Agustus	Minggu ke-2
2014	28-29	Juli	Minggu ke-4
2015	17-18	Juli	Minggu ke-3
2016	6-7	Juli	Minggu ke-1
2017	26-27	Juni	Minggu ke-4
2018	15-16	Juni	Minggu ke-2
2019	5-6	Juni	Minggu ke-1
2020	24-25	Mei	Minggu ke-4
2021	13-14	Mei	Minggu ke-2

### 3.2.3 Struktur Data

Struktur untuk data *inflow* disajikan pada Tabel 3.3 dan Tabel 3.4 untuk data *outflow*. Efek variasi kalender membuat data *inflow* cenderung tinggi satu bulan setelah hari raya Idul Fitri ( $CV_{i,t+1}$ ) sedangkan *outflow* cenderung tinggi satu bulan sebelum hari raya Idul Fitri ( $CV_{i,t-1}$ ).

**Tabel 3.3** Struktur Data Pemodelan Data *Inflow* dengan MGSTARX-RNN

Bulan-tahun	<i>Inflow</i>			<i>Dummy</i>											
	$Z_{1,t}^1$	...	$Z_{5,t}^3$	$t$	$D_1$	$tD_1$	$S_{1,t}$	...	$S_{12,t}$	$CV_{1,t}$	...	$CV_{4,t}$	$CV_{1,t+1}$	...	$CV_{4,t+1}$
Jan-00	$Z_{1,1}^1$	...	$Z_{5,1}^3$	1	0	0	1	...	0	1	...	0	0	...	0
Feb-00	$Z_{1,2}^1$	...	$Z_{5,2}^3$	2	0	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Des-00	$Z_{1,12}^1$	...	$Z_{5,12}^3$	12	0	0	0	...	1	1	...	0	0	...	0
Jan-01	$Z_{1,13}^1$	...	$Z_{5,13}^3$	13	0	0	1	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Jun-19	$Z_{1,240}^1$	...	$Z_{5,240}^3$	240	0	1	0	...	0	1	...	0	0	...	0

**Tabel 3.4** Struktur Data Pemodelan Data *Outflow* dengan MGSTARX- RNN

Bulan-tahun	Outflow			Dummy											
	$Y_{1,t}^1$	...	$Y_{5,t}^3$	$t$	$D_1$	$tD_1$	$S_{1,t}$	...	$S_{12,t}$	$CV_{1,t-1}$	...	$CV_{4,t-1}$	$CV_{1,t}$	...	$CV_{4,t}$
Jan-00	$Y_{1,1}^1$	...	$Y_{5,1}^3$	1	0	0	1	...	0	1	...	0	0	...	0
Feb-00	$Y_{1,2}^1$	...	$Y_{5,2}^3$	2	0	0	0	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Des-00	$Y_{1,12}^1$	...	$Y_{5,12}^3$	12	0	0	0	...	1	1	...	0	0	...	0
Jan-01	$Y_{1,13}^1$	...	$Y_{5,13}^3$	13	0	0	1	...	0	0	...	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Jun-19	$Y_{1,240}^1$	...	$Y_{5,240}^3$	240	0	1	0	...	0	1	...	0	0	...	0

### 3.2.4 Langkah Analisis

Langkah analisis yang dilakukan pada penelitian ini adalah sebagai berikut

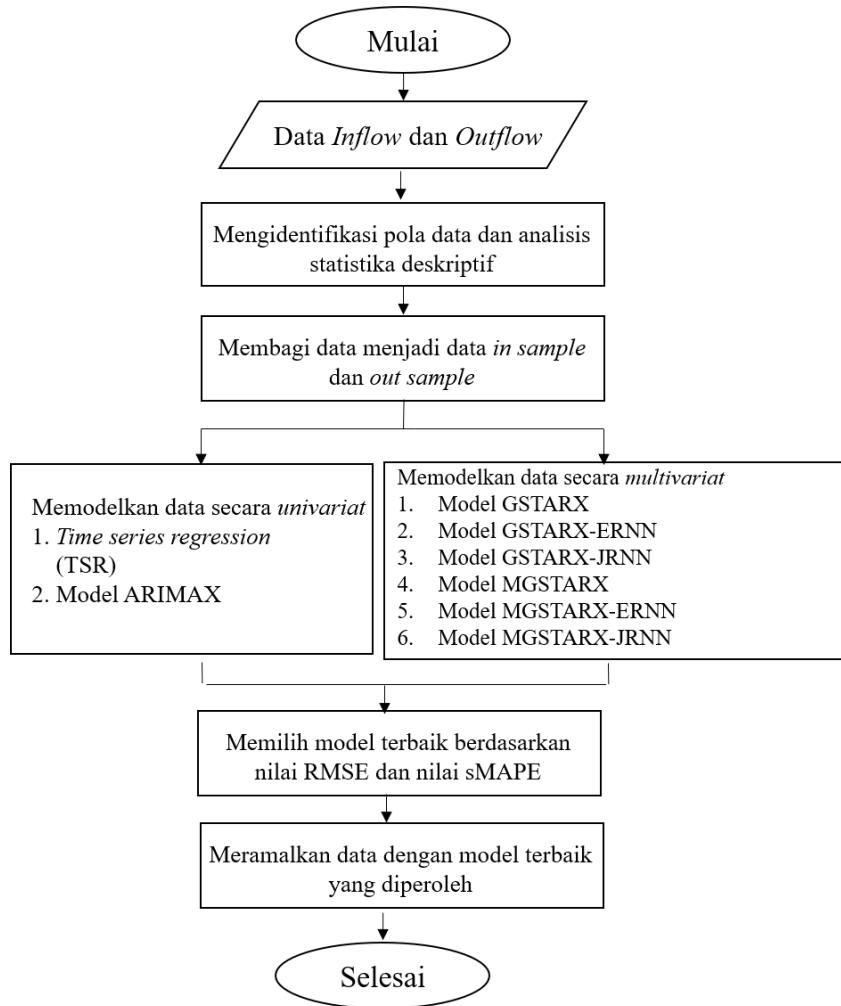
1. Melakukan analisis deskriptif terhadap data *inflow* dan *outflow* uang pecahan besar di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta
2. Mengidentifikasi pola data *inflow* dan *outflow* uang pecahan besar di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta menggunakan *time series plot*.
3. Melakukan pemodelan data *in sample inflow* dan *outflow* uang pecahan besar di lima KPw Bank Sentral secara *univariate* setiap lokasi dan variabel pecahan dengan model *time series regression*. Variabel prediktor yang digunakan adalah variabel *dummy tren*, musiman bulan, dan efek variasi kalender berupa hari raya Idul Fitri.
4. Melakukan pemodelan data *in sample inflow* dan *outflow* uang pecahan besar di lima KPw Bank Sentral secara *univariate* setiap lokasi dan variabel pecahan menggunakan model ARIMAX dengan tahapan seperti berikut

- a. Meregresikan data *in sample* dari *inflow* dan *outflow* dengan variabel *dummy* dan mendapatkan model TSR.
  - b. Melakukan uji *white noise* pada residual model TSR menggunakan uji Ljung-Box. Jika residual memenuhi asumsi *white noise*, maka model yang digunakan adalah model *time series regression* dan dilanjutkan ke langkah 4e.
  - c. Melakukan pemodelan menggunakan model ARIMA dari residual hasil model TSR yang belum memenuhi asumsi *white noise* dengan prosedur sebagai berikut:
    - i. Menentukan orde ARIMA melalui plot ACF dan PACF.
    - ii. Melakukan estimasi parameter model dugaan.
    - iii. Menguji signifikansi parameter model dugaan.
    - iv. Melakukan cek diagnose pada residual ARIMA apakah telah *white noise* dan mengikuti distribusi normal.
  - d. Mendapatkan model ARIMAX
  - e. Melakukan peramalan dengan model ARIMAX dan menghitung nilai residual
5. Melakukan pemodelan data *in sample inflow* dan *outflow* uang pecahan besar di lima KPw Bank Sentral per variabel pecahan secara *multivariate* menggunakan GSTARX dengan tahapan sebagai berikut
- a. Tahap pertama: Pemodelan *time series regression* dengan meregresikan data *in sample* dari *inflow* dan *outflow* dengan variabel *dummy* yang sudah ditentukan. Selanjutnya mengidentifikasi korelasi residual hasil pemodelan *time series regression* antar lokasi pada masing-masing data *inflow* dan *outflow*.
  - b. Tahap kedua : Melakukan pemodelan residual model TSR menggunakan model GSTAR dengan tahapan sebagai berikut
    - i. Memeriksa stasioneritas data *in sample* dari *inflow* dan *outflow* masing-masing lokasi menggunakan plot MCCF.
    - ii. Apabila data belum stasioner, maka dilakukan *differencing* hingga data stasioner
    - iii. Melakukan identifikasi order model AR menggunakan plot MPCCF.

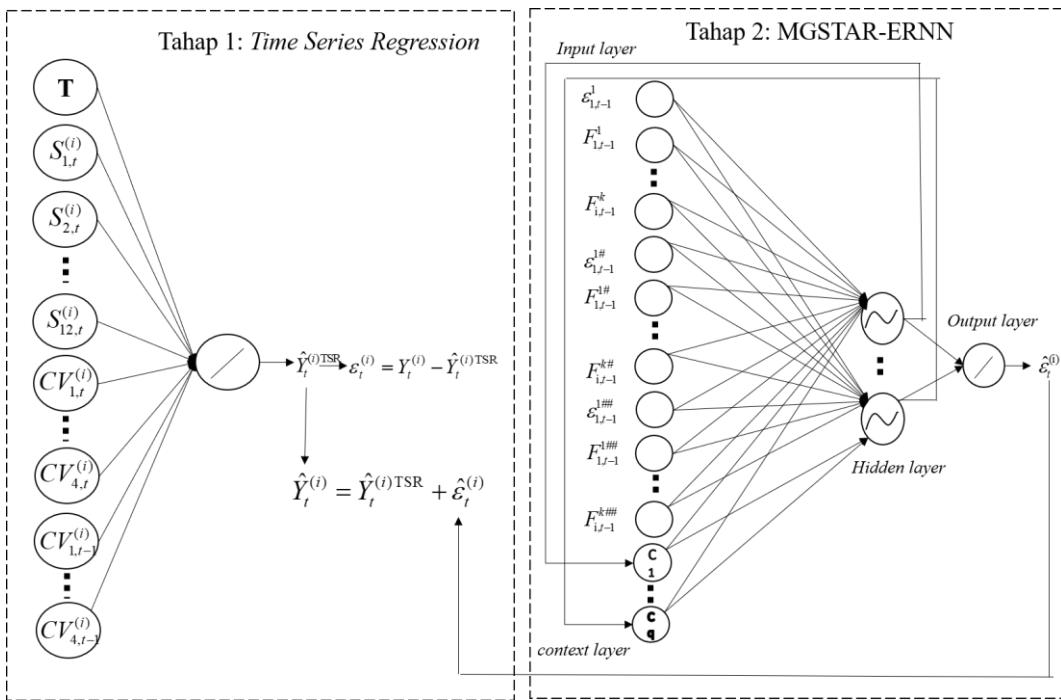
- iv. Menentukan nilai pembobot spasial yang digunakan.
  - v. Melakukan estimasi dan pengujian signifikansi parameter GSTAR( $p$ ).
  - c. Mendapatkan model GSTARX yang merupakan penjumlahan dari hasil model TSR dengan model GSTAR dari residual TSR.
  - d. Melakukan peramalan untuk data *out sample* berdasarkan model GSTARX yang sudah didapatkan
6. Melakukan pemodelan data *in sample inflow* dan *outflow* uang pecahan besar di lima KPw Bank Sentral per variabel pecahan secara *multivariate* menggunakan GSTARX-RNN dengan prosedur berikut
- a. Melakukan pemodelan *time series regression* dengan meregresikan data *in sample* dari *inflow* dan *outflow* dengan variabel *dummy* yang sudah ditentukan.
  - b. Menentukan *lag* data untuk input dalam model RNN berdasarkan orde pada model GSTARX yang sudah didapatkan.
  - c. Melakukan penghitungan bobot GSTAR yang digunakan sebagai input dalam model *hybrid* GSTARX-RNN.
  - d. Melakukan estimasi parameter dengan arsitektur *Elman* RNN dan *Jordan* RNN
  - e. Mendapatkan model *hybrid* GSTARX-ERNN yang merupakan penjumlahan dari model TSR dengan model GSTAR-ERNN dari residual.
  - f. Mendapatkan model *hybrid* GSTARX-JRNN yaitu penjumlahan dari model TSR dengan model GSTAR-JRNN dari residual.
  - g. Menentukan *neuron* model terbaik dari kedua model *hybrid* GSTARX-RNN berdasarkan RMSE dan SMAPE terkecil
7. Melakukan pemodelan data *in sample inflow* dan *outflow* uang pecahan besar di lima KPw Bank Sentral secara *multivariate* menggunakan *Multivariate GSTARX* (MGSTARX) dengan tahapan sebagai berikut
- a. Tahap pertama: Pemodelan *time series regression* dengan meregresikan data *in sample* dari *inflow* dan *outflow* dengan variabel *dummy* yang sudah ditentukan. Selanjutnya

- mengidentifikasi korelasi residual hasil pemodelan *time series regression* antar lokasi pada masing-masing data *inflow* dan *outflow*.
- b. Tahap kedua: Melakukan pemodelan residual model *time series regression* menggunakan model MGSTAR dengan tahapan sebagai berikut
    - i. Memeriksa stasioneritas data *in sample* dari *inflow* dan *outflow* masing-masing lokasi menggunakan plot MCCF.
    - ii. Apabila data belum stasioner, maka dilakukan *differencing* hingga data stasioner
    - iii. Melakukan identifikasi order model AR menggunakan plot MPCCF.
    - iv. Menentukan nilai pembobot spasial yang digunakan.
    - v. Melakukan estimasi dan pengujian signifikansi parameter MGSTAR.
  - c. Mendapatkan model MGSTARX yang merupakan penjumlahan dari hasil model TSR dengan model MGSTAR dari residual TSR.
  - d. Melakukan peramalan untuk data *out sample* berdasarkan model MGSTARX yang sudah didapatkan
8. Melakukan pemodelan data *in sample inflow* dan *outflow* uang pecahan besar di lima KPw Bank Sentral secara *multivariate* menggunakan *hybrid Multivariate GSTARX-RNN* dengan prosedur seperti langkah 6 dengan estimasi parameter MGSTAR.
  9. Menghitung nilai RMSE dan sMAPE dari masing-masing pemodelan yang sudah dilakukan pada data *inflow* dan *outflow* untuk data *in sample* dan *out sample*
  10. Membandingkan nilai RMSE dan sMAPE yang didapatkan pada masing-masing pemodelan, dan menentukan model yang memiliki *performance* terbaik dalam memodelkan data *inflow* dan *outflow* uang pecahan besar di KPW Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta
  11. Meramalkan data *inflow* dan *outflow* uang pecahan besar di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta.

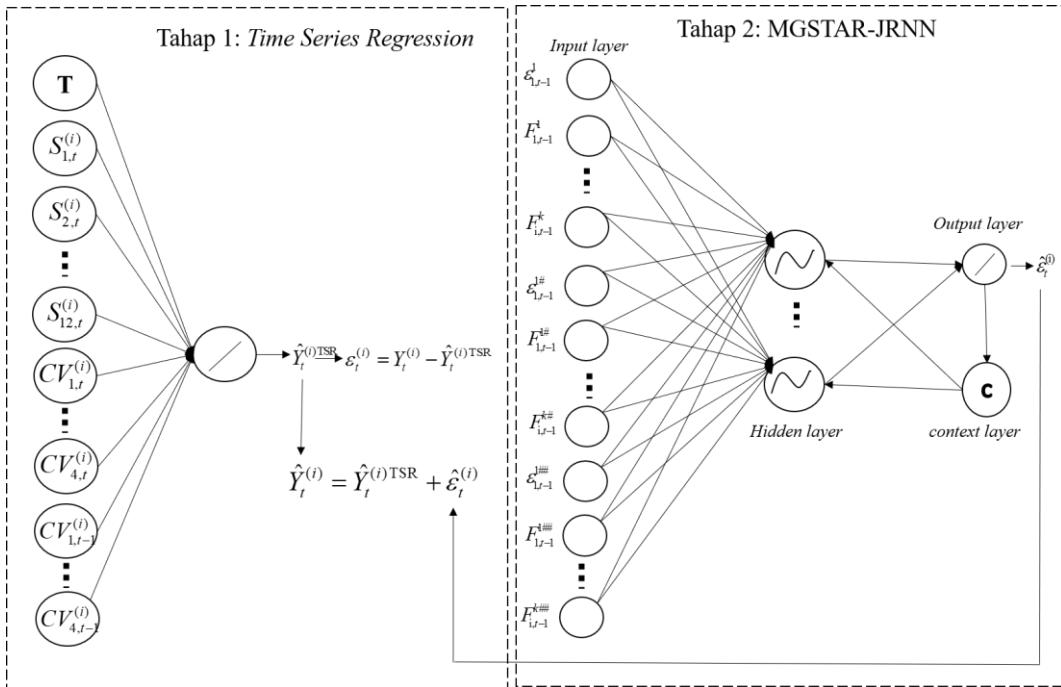
Tahapan pemodelan *inflow* dan *outflow* uang pecahan besar di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, Jakarta ditunjukkan pada gambar berikut



**Gambar 3.1.** Diagram Alir Tahapan Pemodelan Secara Keseluruhan



**Gambar 3.2.** Pemodelan *Hybrid MGSTARX* dengan *Elman RNN*



**Gambar 3.3.** Pemodelan *Hybrid MGSTARX* dengan *Jordan RNN*

## BAB 4

### ANALISIS DAN PEMBAHASAN

Pada bab ini akan dibahas dua kajian penelitian yaitu kajian simulasi dan kajian terapan. Kajian simulasi dilakukan untuk mengetahui performa model MGSTAR-RNN berdasarkan kriteria RMSE. Sedangkan kajian terapan akan membahas hasil penelitian dan analisis tentang pemodelan *inflow* dan *outflow* uang kartal pecahan besar (UPB) di Pulau Jawa yang terdiri dari lima Kantor Perwakilan Bank Sentral yaitu Surabaya, Semarang, Yogyakarta, Bandung dan Jakarta.

#### 4.1 Pemodelan Data Simulasi

Kajian simulasi pada penelitian ini menggunakan dua skenario dengan perbedaan pada hubungan residual model VAR, yaitu hubungan pada residual dengan variabel sama lokasi berbeda serta hubungan pada residual ketika variabel berbeda lokasi sama.

##### 4.1.1 Pemodelan Data Simulasi Skenario 1

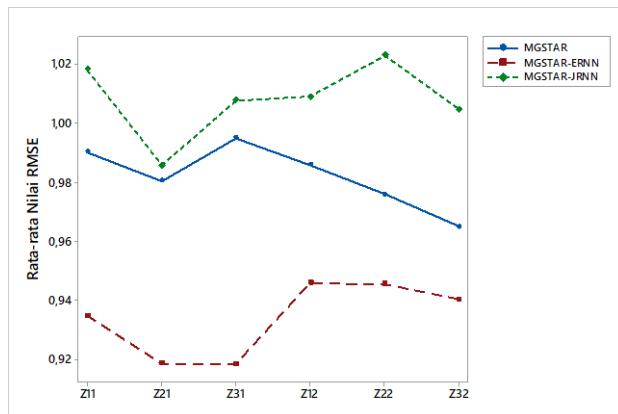
Pada skenario 1 menggunakan dua variabel yang terletak pada tiga lokasi pengamatan serta hubungan pada residual terdapat di variabel sama dengan lokasi berbeda. Selanjutnya data simulasi dimodelkan dengan MGSTAR dan MGSTAR-RNN. Untuk mengetahui kebaikan model maka akan dilihat nilai RMSE kedua model tersebut. Pada penelitian ini MGSTAR-RNN terbagi menjadi dua, yaitu MGSTAR-ERNN dan MGSTAR-JRNN dengan *neuron hidden layer* adalah satu hingga sepuluh. Input yang digunakan pada MGSTAR-ERNN dan MGSTAR-JRNN sebanyak 24 parameter dengan struktur input sebagai berikut.

$$\mathbf{N}_{1,t-1}^1 = \begin{bmatrix} \mathbf{N}_{1,t-1}^1 \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \mathbf{F}_{1,t-1}^1 = \begin{bmatrix} w_{12}\mathbf{N}_{2,t-1}^1 + w_{13}\mathbf{N}_{3,t-1}^1 \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \mathbf{F}_{3,t-1}^2 = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{21}\mathbf{N}_{1,t-1}^2 + w_{22}\mathbf{N}_{2,t-1}^2 \end{bmatrix}$$

$$\mathbf{N}_{1,t-1}^{1\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{N}_{1,t-1}^1 \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \mathbf{F}_{1,t-1}^{1\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{12}\mathbf{N}_{2,t-1}^1 + w_{13}\mathbf{N}_{3,t-1}^1 \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix} \text{ dan } \mathbf{F}_{3,t-1}^{2\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{21}\mathbf{N}_{1,t-1}^2 + w_{22}\mathbf{N}_{2,t-1}^2 \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}$$

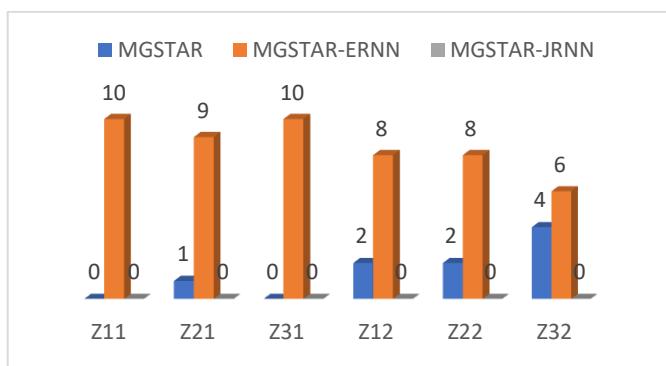
$\mathbf{N}_{1,t-1}^1$  merupakan input yang menunjukkan hubungan *lag* variabel yang sama dan lokasi sama,  $\mathbf{F}_{1,t-1}^1$  merupakan input yang menunjukkan hubungan *lag* variabel sama pada lokasi berbeda. Sedangkan  $\mathbf{N}_{1,t-1}^{1\#}$  menunjukkan hubungan *lag* variabel berbeda pada lokasi sama dan  $\mathbf{F}_{1,t-1}^{1\#}$  merupakan input yang menunjukkan hubungan *lag* variabel berbeda pada lokasi yang berbeda.

Hasil perbandingan rata-rata RMSE pemodelan MGSTAR dan *hybrid* MGSTAR-RNN dapat dilihat pada Gambar 4.1.



**Gambar 4.1** Plot Perbandingan Rata-Rata Nilai RMSE Hasil Pemodelan MGSTAR dan *hybrid* MGSTAR-RNN pada Skenario 1

Berdasarkan Gambar 4.1 diketahui model MGSTAR-ERNN memiliki nilai RMSE paling kecil jika dibandingkan dengan model MGSTAR dan MGSTAR-JRNN untuk setiap variabel dan lokasi. Jadi, model terbaik untuk skenario 1 adalah model MGSTAR-ERNN. Hal ini dapat dilihat juga pada diagram perbandingan model pada 10 pengulangan setiap variabel dan lokasi yang ditunjukkan pada Gambar 4.2.

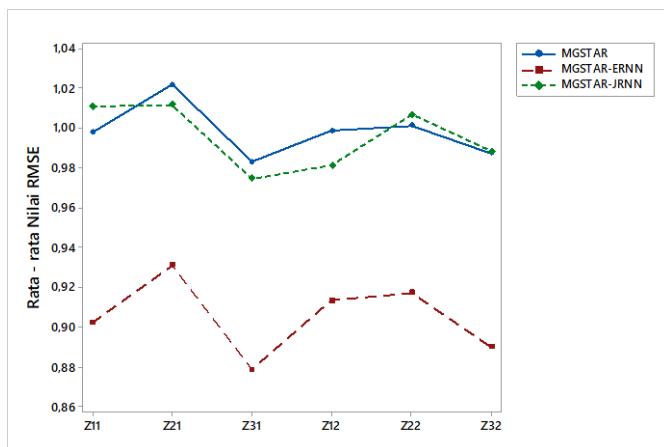


**Gambar 4.2** Model Terbaik Setiap Variabel dan Lokasi pada Skenario 1

Gambar 4.2 menunjukkan bahwa untuk data variabel 1 di lokasi 1 dan lokasi 3 model MGSTAR-ERNN menjadi model terbaik pada setiap pengulangan. Sedangkan untuk varabel 1 di lokasi 2 model MGSTAR-ERNN menjadi model terbaik untuk 9 dari 10 pengulangan dan 1 pengulangan model MGSTAR. Namun, untuk model MGSTAR-JRNN bukan merupakan model terbaik di setiap pengulangan. Secara umum, model terbaik untuk skenario 1 adalah model MGSTAR-ERNN.

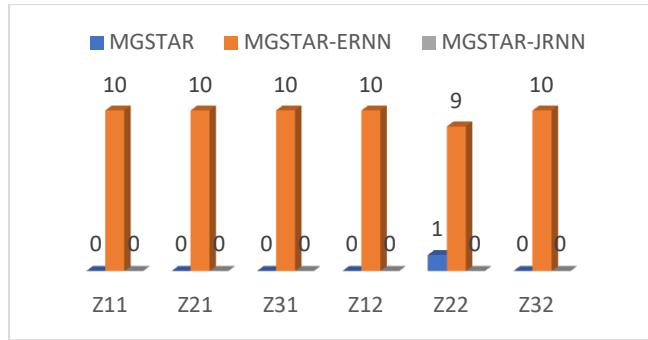
#### 4.1.2 Pemodelan Data Simulasi Skenario 2

Skenario 2 juga menggunakan dua variabel dan tiga lokasi namun dengan hubungan pada residual terdapat di variabel yang berbeda dan lokasi sama. Pemodelan dilakukan seperti pada skenario 1 dengan jumlah input dan jumlah *neuron* pada MGSTAR-ERNN dan MGSTAR-JRNN juga sama seperti pada skenario 1. Perbandingan nilai RMSE dari model MGSTAR, MGSTAR-ERNN, dan MGSTAR-JRNN dapat dilihat pada Gambar 4.3.



**Gambar 4.3** Plot Perbandingan Rata-Rata Nilai RMSE Hasil Pemodelan MGSTAR dan *hybrid* MGSTAR-RNN pada Skenario 2

Gambar 4.3 menunjukkan bahwa model *hybrid* MGSTAR-RNN yaitu model MGSTAR-ERNN dan MGSTAR-JRNN memiliki rata-rata nilai RMSE lebih kecil dibandingkan dengan model MGSTAR. Khususnya model MGSTAR-ERNN yang memiliki nilai RMSE paling kecil diantara yang lain sehingga model terbaik untuk skenario 2 adalah model MGSTAR-ERNN. Jika dilihat dari performa setiap data dengan 10 kali replikasi perbandingan modelnya sebagai berikut.



**Gambar 4.4** Model Terbaik Setiap Variabel dan Lokasi pada Skenario 2

Berdasarkan Gambar 4.4 dapat diketahui bahwa model yang mendominasi yaitu model MGSTAR-ERNN dimana model tersebut menjadi model terbaik pada setiap replikasi untuk semua varibel dan lokasi kecuali data variabel kedua pada lokasi kedua. Sedangkan model MGSTAR-JRNN tidak menjadi model terbaik untuk setiap replikasi pada masing-masing data. Secara umum, model *hybrid* MGSTAR-RNN menjadi model terbaik pada skenario 2 dibandingkan dengan model MGSTAR.

## 4.2 Karakteristik Data *Inflow* dan *Outflow* UPB KPw BANK SENTRAL

### Provinsi di Jawa

Pemodelan pada kajian terapan dilakukan dalam dua tahap. Tahap pertama memodelkan pola tren, musiman, dan variasi kalender menggunakan *Time Series regression* (TSR). Tahap kedua dilakukan pemodelan residual tahap pertama dengan GSTAR, MGSTAR, *hybrid* MGSTAR-ERNN, dan *hybrid* MGSTAR-JRNN. Sebelum melakukan pemodelan, dilakukan eksplorasi data untuk mengetahui karakteristik masing-masing KPw Bank Sentral Provinsi di Pulau Jawa.

Statistika deskriptif data *inflow* dan *outflow* untuk masing-masing pecahan pada KPw Bank Sentral Provinsi di Pulau Jawa diberikan pada Tabel 4.1.

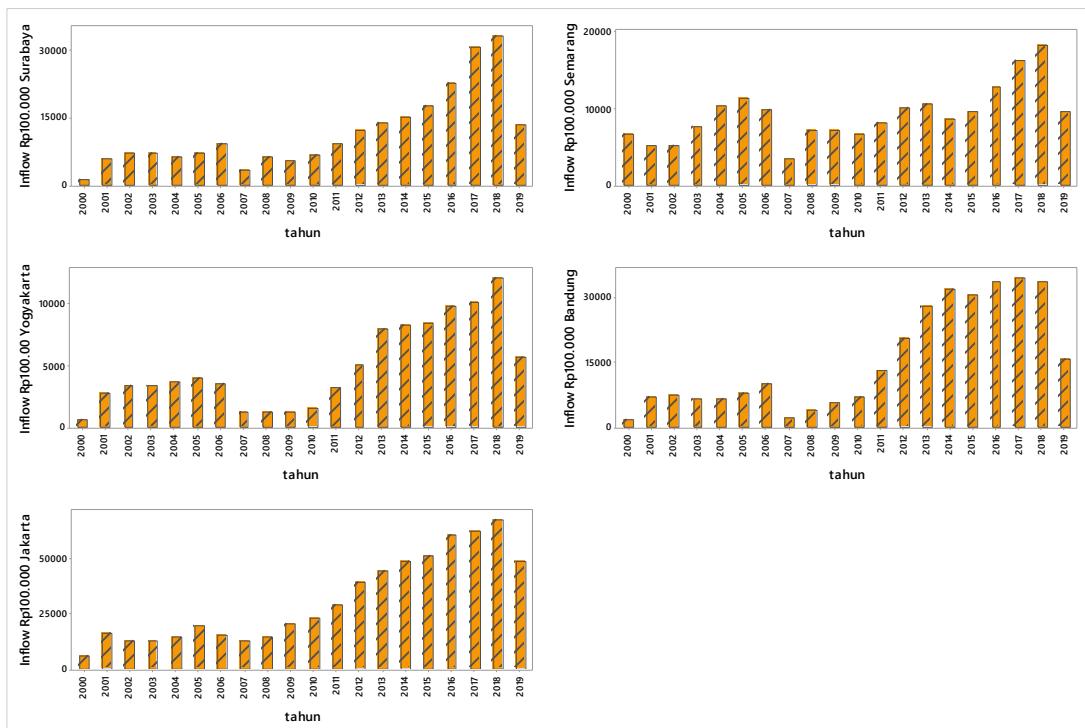
Berdasarkan Tabel 4.1 diketahui bahwa KPw Bank Sentral Jakarta memiliki rata-rata *inflow* dan *outflow* tertinggi untuk setiap pecahan, sedangkan rata-rata terendah di KPw Bank Sentral Yogyakarta baik *inflow* maupun *outflow*. Selanjutnya perkembangan *inflow* dan *outflow* pecahan Rp100.000 dari Januari 2000 hingga Juni 2019 di masing-masing KBANK SENTRAL akan ditunjukkan pada Gambar 4.1 dan Gambar 4.2.

**Tabel 4.1** Statistika Deskriptif Data (miliar Rp) *Inflow* dan *Outflow* UPB pada KPw Bank Sentral Provinsi di Jawa

Data	KPw	Pecahan	Mean	Standar Deviasi	Minimum	Maksimum
Inflow	Surabaya	Rp 20.000	64,166	43,659	8,514	256,623
		Rp 50.000	805,704	497,346	118,097	3499,827
		Rp 100.000	1016,649	974,302	1,512	6559,396
	Semarang	Rp 20.000	47,562	28,970	16,090	196,043
		Rp 50.000	630,157	449,173	40,392	3020,407
		Rp 100.000	841,662	866,553	0,065	6019,394
	Yogya	Rp 20.000	28,015	22,783	5,848	152,091
		Rp 50.000	316,281	230,705	14,055	1378,234
		Rp 100.000	424,035	391,693	4,476	2382,520
Outflow	Bandung	Rp 20.000	77,704	52,327	17,069	399,423
		Rp 50.000	1102,620	725,834	51,954	548,440
		Rp 100.000	1334,677	1214,216	6,491	6739,811
	Jakarta	Rp 20.000	190,951	129,613	64,472	1088,198
		Rp 50.000	2683,693	1474,71	548,440	8517,362
		Rp 100.000	2703,097	2510,014	222,876	16277,904
	Surabaya	Rp 20.000	61,687	86,217	0,646	596,959
		Rp 50.000	820,238	605,944	72,720	4394,899
		Rp 100.000	962,504	902,186	28,068	6113,626
	Semarang	Rp 20.000	45,850	51,947	0,564	352,768
		Rp 50.000	398,738	376,740	1,734	2635,279
		Rp 100.000	598,813	720,115	0,133	5286,758
	Yogya	Rp 20.000	29,989	31,545	0,156	194,588
		Rp 50.000	281,918	272,115	0,738	1896,583
		Rp 100.000	403,919	392,586	0,876	2788,997
	Bandung	Rp 20.000	56,669	65,840	1,330	466,520
		Rp 50.000	609,476	576,413	0,306	4241,468
		Rp 100.000	882,543	1010,925	0,209	7798,991
	Jakarta	Rp 20.000	290,548	281,378	2,723	1886,927
		Rp 50.000	3994,538	2408,260	187,402	15792,907
		Rp 100.000	4308,778	3840,353	231,241	25819,783

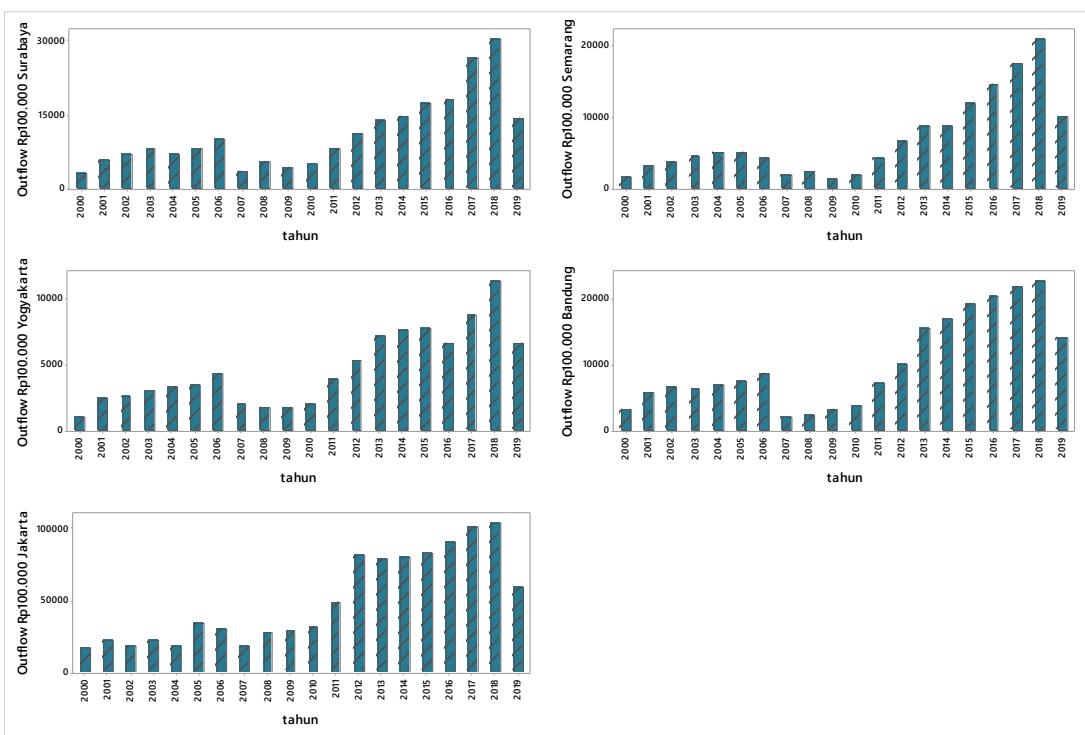
Berdasarkan Gambar 4.5 dan 4.6 diketahui bahwa inflow *dan* outflow mengalami peningkatan setiap tahunnya. Pada tahun 2007 hingga 2010 terjadi penurunan karena adanya kebijakan Bank Sentral mengenai pembatasan penyetoran untuk Uang yang Tidak Layak Edar (UTLE) dan Uang yang masih Layak Edar (ULE). Selain itu Bank Sentral memberlakukan ULE dikelola melalui Transaksi Uang Kartal Antar Bank (TUKAB). Pada tahun 2011 pola data kembali menunjukkan kenaikan yang cukup besar dikarenakan sejak tahun tersebut Bank Sentral kembali menerima penyetoran UTLE dan ULE. Rendahnya inflow dan outflow pada tahun 2019 bukan karena terjadi penurunan namun data yang digunakan hanya sampai Bulan Juni 2019.

Pola perkembangan bulanan inflow dan outflow UPB pada lima KPw Bank Sentral provinsi di Jawa dapat divisualisasikan dengan *time series* plot seperti pada Gambar 4.7 dan Gambar 4.8.

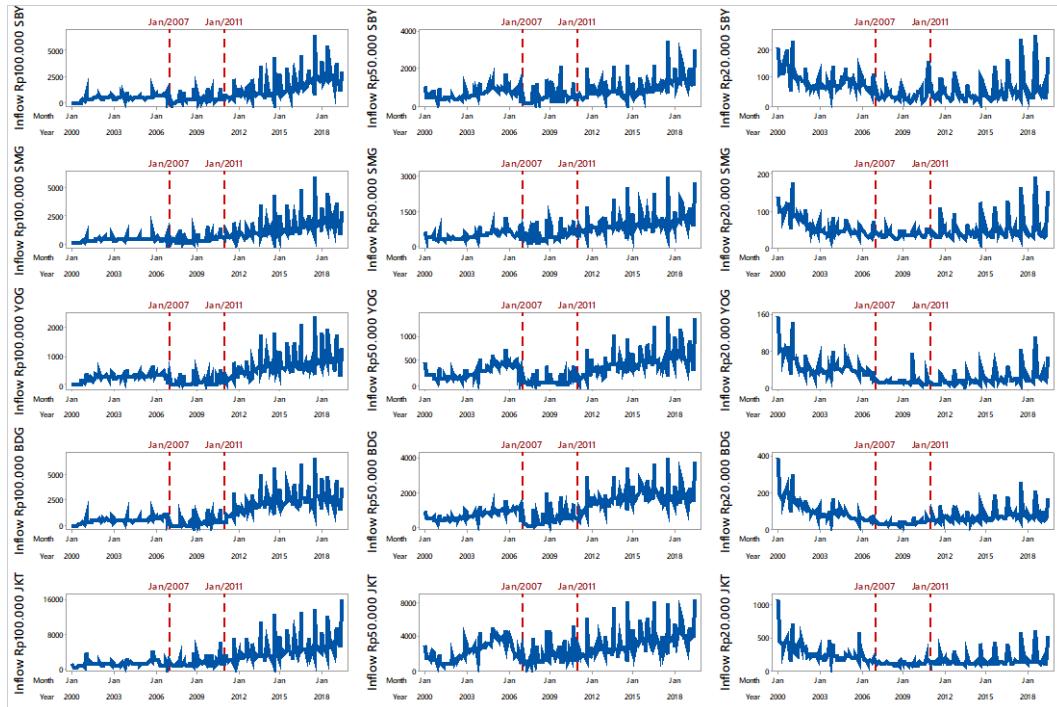


**Gambar 4.5** Diagram Perkembangan *Inflow* pecahan Rp100.000 Setiap Tahun

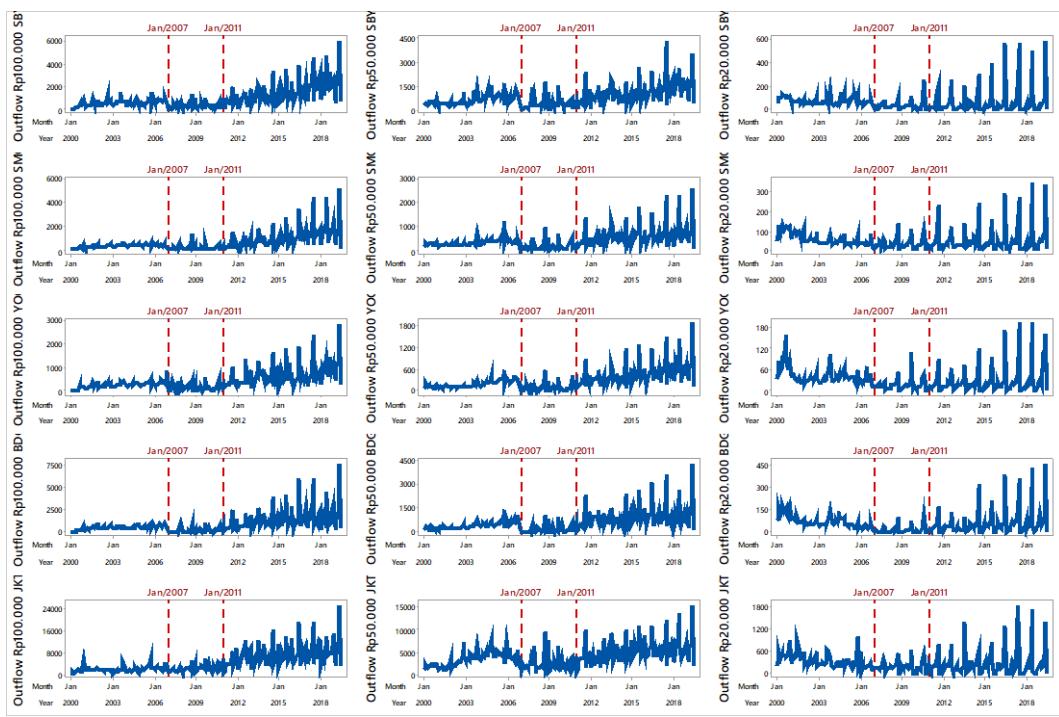
Pada Lima KPw Bank Sentral Provinsi di Pulau Jawa



**Gambar 4.6** Diagram Perkembangan *Outflow* pecahan Rp100.000 Setiap Tahun  
Pada Lima KPw Bank Sentral Provinsi di Pulau Jawa



**Gambar 4.7** *Time Series Plot* data *Inflow* Uang Pecahan Besar pada Lima  
KPw Bank Sentral Provinsi di Pulau Jawa



**Gambar 4.8 Time Series Plot** data *Outflow* Uang Pecahan Besar pada Lima KPw Bank Sentral Provinsi di Pulau Jawa

Berdasarkan Gambar 4.7 dan Gambar 4.8 diketahui data *inflow* dan *outflow* memiliki tren yang fluktuatif, terjadi penurunan pada tahun 2007 karena adanya perubahan kebijakan. Selebihnya pola data cenderung meningkat dan tinggi pada titik-titik waktu tertentu yang diindikasi merupakan efek variasi kalender yaitu dipengaruhi oleh bulan Hari Raya Idul Fitri. Hari Raya Idul Fitri mempengaruhi pola data *inflow* pada bulan terjadinya hari raya dan bulan setelah hari raya. Sedangkan pola data *outflow* cenderung akan naik pada bulan sebelum hari raya dan bulan terjadinya hari raya. Kejadian Hari Raya Idul Fitri tidak bisa dikatakan sebagai pola musiman karena Hari Raya Idul Fitri terjadi tidak selalu pada bulan yang sama setiap tahunnya.

### 4.3 Pemodelan *Time Series Regression* Data *Inflow* dan *Outflow* UPB di KPw Bank Sentral Provinsi Pulau Jawa

Pemodelan *Time Series Regression* (TSR) merupakan pemodelan univariat dengan menggunakan metode estimasi *Ordinary Least Square* (OLS). Model TSR menggunakan variable *dummy* dari komponen tren, musiman, dan variasi kalender sebagai variabel prediktor. Hasil estimasi parameter dari masing-masing UPB di setiap lokasi dapat dilihat pada Lampiran 2. Berdasarkan nilai estimasi parameter

yang diperoleh maka dapat dituliskan persamaan TSR untuk data *inflow* masing-masing UPB di setiap lokasi sebagai berikut.

a. Pecahan Rp100.000 di KPw Surabaya

$$\hat{Z}_{1,t}^1 = 9,36t - 363,33D_1 - 964,78D_2 - 2,80tD_1 + 2,83tD_2 + 484,37S_1 + 38,14S_2 - 82,64S_3 - 94,87S_4 - 20,12S_5 - 149,83S_6 + 321,62S_7 + 257,29S_8 - 51,96S_9 + 148,29S_{10} - 142,89S_{11} - 330,92S_{12} + 1257,51CV_{1,t} + 784,13CV_{2,t} + 566,10CV_{3,t} - 423,18CV_{4,t} + 119,56CV_{1,t+1} + 139,18CV_{2,t+1} + 310,76CV_{3,t+1} + 1799,77CV_{4,t+1} + \varepsilon_{1,t}^1$$

b. Pecahan Rp50.000 di KPw Surabaya

$$\hat{Z}_{1,t}^2 = 3,13t - 611,79D_1 + 110,16D_2 + 2,55tD_1 - 2,01tD_2 + 690,85S_1 + 425,51S_2 + 353,69S_3 + 381,03S_4 + 401,65S_5 + 333,23S_6 + 564,77S_7 + 546,78S_8 + 439,12S_9 + 587,86S_{10} + 394,10S_{11} + 261,16S_{12} + 922,47CV_{1,t} + 733,27CV_{2,t} + 105,19CV_{3,t} - 239,73CV_{4,t} + 128,31CV_{1,t+1} + 172,16CV_{2,t+1} + 460,28CV_{3,t+1} + 1108,78CV_{4,t+1} + \varepsilon_{1,t}^2$$

c. Pecahan Rp20.000 di KPw Surabaya

$$\hat{Z}_{1,t}^3 = -0,23t - 89,40D_1 - 18,80D_2 + 0,47tD_1 - 0,02tD_2 + 115,85S_1 + 94,65S_2 + 90,55S_3 + 88,35S_4 + 87,11S_5 + 82,67S_6 + 99,92S_7 + 113,36S_8 + 99,75S_9 + 100,28S_{10} + 104,32S_{11} + 87,64S_{12} + 34,68CV_{1,t} + 27,45CV_{2,t} - 16,02CV_{3,t} - 31,95CV_{4,t} + 45,50CV_{1,t+1} + 36,57CV_{2,t+1} + 44,22CV_{3,t+1} + 86,65CV_{4,t+1} + \varepsilon_{1,t}^3$$

d. Pecahan Rp100.000 di KPw Semarang

$$\hat{Z}_{2,t}^1 = 8,26t - 183,82D_1 - 1559,12D_2 - 2,44tD_1 + 8,30tD_2 + 199,26S_1 - 103,86S_2 - 101,84S_3 - 119,78S_4 - 180,89S_5 - 274,20S_6 + 218,28S_7 + 39,40S_8 - 290,353S_9 - 61,53S_{10} - 211,41S_{11} - 473,56S_{12} + 1289,27CV_{1,t} + 872,40CV_{2,t} + 743,19CV_{3,t} - 352,87CV_{4,t} + 56,30CV_{1,t+1} + 184,71CV_{2,t+1} + 450,07CV_{3,t+1} + 1652,29CV_{4,t+1} + \varepsilon_{2,t}^1$$

e. Pecahan Rp50.000 di KPw Semarang

$$\hat{Z}_{2,t}^2 = 3,81t - 388,90D_1 - 239,81D_2 + 1,76tD_1 + 1,40tD_2 + 365,40S_1 + 126,01S_2 + 156,15S_3 + 181,16S_4 + 110,82S_5 + 38,62S_6 + 269,29S_7 + 230,52S_8 + 67,29S_9 + 161S_{10} + 123,94S_{11} - 75,70S_{12} + 829,81CV_{1,t} + 535,89CV_{2,t} + 250,91CV_{3,t} - 278,42CV_{4,t} + 139,55CV_{1,t+1} + 246,92CV_{2,t+1} + 375,49CV_{3,t+1} + 993,74CV_{4,t+1} + \varepsilon_{2,t}^2$$

f. Pecahan Rp20.000 di KPw Semarang

$$\hat{Z}_{2,t}^3 = -0,12t - 36,63D_1 - 31,92D_2 + 0,17tD_1 + 0,17tD_2 + 73,36S_1 + 60,38S_2 + 62,25S_3 + 60,59S_4 + 56,92S_5 + 51,95S_6 + 61,39S_7 + 68,84S_8 + 65,25S_9 + 63,88S_{10} + 61,03S_{11} + 55,57S_{12} + 16,61CV_{1,t} + 12,38CV_{2,t} - 2,92CV_{3,t} - 20,36CV_{4,t} + 28,16CV_{1,t+1} + 23,51CV_{2,t+1} + 42,56CV_{3,t+1} + 70,39CV_{4,t+1} + \varepsilon_{2,t}^3$$

g. Pecahan Rp100.000 di KPw Yogyakarta

$$\begin{aligned}\hat{Z}_{3,t}^1 = & 3,46t - 112,3D_1 - 1488D_2 - 2,4tD_1 + 8,70tD_2 + 245,70S_1 + 59,9S_2 + 63,66S_3 + \\ & 42,14S_4 + 62,28S_5 + 36,18S_6 + 228,2S_7 + 156,3S_8 - 22,05S_9 + 82,19S_{10} - \\ & 2,93S_{11} - 93,42S_{12} + 612,1CV_{1,t} + 392CV_{2,t} + 345,7CV_{3,t} - 190,3CV_{4,t} + \\ & 0,06CV_{1,t+1} + 55,83CV_{2,t+1} + 66,42CV_{3,t+1} + 578,1CV_{4,t+1} + \varepsilon_{3,t}^1\end{aligned}$$

h. Pecahan Rp50.000 di KPw Yogyakarta

$$\begin{aligned}\hat{Z}_{3,t}^2 = & 1,79t - 182,57D_1 - 638,86D_2 - 0,98tD_1 + 3,34tD_2 + 269,15S_1 + 140,72S_2 + 154,49S_3 + \\ & 144,68S_4 + 159,61S_5 + 144,47S_6 + 240,86S_7 + 197,29S_8 + 140,17S_9 + 157,39S_{10} + \\ & 107,55S_{11} + 68,39S_{12} + 380,29CV_{1,t} + 335,64CV_{2,t} + 46,75CV_{3,t} - 166,92CV_{4,t} + \\ & 33,22CV_{1,t+1} + 111,66CV_{2,t+1} + 31,22CV_{3,t+1} + 371,74CV_{4,t+1} + \varepsilon_{3,t}^2\end{aligned}$$

i. Pecahan Rp20.000 di KPw Yogyakarta

$$\begin{aligned}\hat{Z}_{3,t}^3 = & -0,18t - 42,82D_1 - 73,89D_2 + 0,19tD_1 + 0,40tD_2 + 62,77S_1 + 53,26S_2 + 54,43S_3 + \\ & 52S_4 + 50,51S_5 + 48,26S_6 + 52,66S_7 + 52,39S_8 + 53,23S_9 + 52,39S_{10} + \\ & 47,62S_{11} + 46,20S_{12} + 12,74CV_{1,t} + 21,92CV_{2,t} + 10,04CV_{3,t} - 12,01CV_{4,t} + \\ & 13,03CV_{1,t+1} + 20,17CV_{2,t+1} + 16,68CV_{3,t+1} + 41,36CV_{4,t+1} + \varepsilon_{3,t}^3\end{aligned}$$

j. Pecahan Rp100.000 di KPw Bandung

$$\begin{aligned}\hat{Z}_{4,t}^1 = & 13,51t - 831,72D_1 - 4846,91D_2 - 2,21tD_1 + 29,96tD_2 + 314,35S_1 - 143,69S_2 - 109,66S_3 - \\ & 202,76S_4 - 157,35S_5 - 212,26S_6 + 200,08S_7 + 207,96S_8 - 69,85S_9 - 51,21S_{10} - \\ & 255,06S_{11} - 540,62S_{12} + 1542,23CV_{1,t} + 714,40CV_{2,t} + 681,82CV_{3,t} - 538,70CV_{4,t} + \\ & 59,44CV_{1,t+1} + 226,85CV_{2,t+1} + 583,88CV_{3,t+1} + 1693,96CV_{4,t+1} + \varepsilon_{4,t}^1\end{aligned}$$

k. Pecahan Rp50.000 di KPw Bandung

$$\begin{aligned}\hat{Z}_{4,t}^2 = & 7,85t - 1108,56D_1 - 1916,26D_2 + 3,63tD_1 + 11,53tD_2 + 540,61S_1 + 250,60S_2 + 291,71S_3 + \\ & 237,68S_4 + 291,85S_5 + 242,36S_6 + 460,38S_7 + 435,31S_8 + 300,42S_9 + 328,98S_{10} + \\ & 181,80S_{11} - 47,82S_{12} + 1180,42CV_{1,t} + 515,26CV_{2,t} + 316,37CV_{3,t} - 379,73CV_{4,t} + \\ & 110,20CV_{1,t+1} + 274,54CV_{2,t+1} + 478,44CV_{3,t+1} + 1111,39CV_{4,t+1} + \varepsilon_{4,t}^2\end{aligned}$$

l. Pecahan Rp20.000 di KPw Bandung

$$\begin{aligned}\hat{Z}_{4,t}^3 = & -0,25t - 124,79D_1 - 94,13D_2 + 0,59tD_1 + 0,46tD_2 + 137,74S_1 + 115,06S_2 + 119,18S_3 + \\ & 112,36S_4 + 111,11S_5 + 107,41S_6 + 127,42S_7 + 128,63S_8 + 116,64S_9 + 113,93S_{10} + \\ & 103,49S_{11} + 101,87S_{12} + 33,20CV_{1,t} + 59,81CV_{2,t} - 0,98CV_{3,t} - 32,38CV_{4,t} + \\ & 23,05CV_{1,t+1} + 40,92CV_{2,t+1} + 64,39CV_{3,t+1} + 99,58CV_{4,t+1} + \varepsilon_{4,t}^3\end{aligned}$$

m. Pecahan Rp100.000 di KPw Jakarta

$$\hat{Z}_{5,t}^1 = 23,05t - 1550,73D_1 - 3805,62D_2 + 3,31tD_1 + 21,87tD_2 + 1170,89S_1 + 51,42S_2 - 88,37S_3 - 259,35S_4 - 130,77S_5 - 355,95S_6 + 560,02S_7 + 535,66S_8 - 98,58S_9 - 100,65S_{10} - 761,45S_{11} - 1347,92S_{12} + 3916,27CV_{1,t} + 2811,23CV_{2,t} + 2875,83CV_{3,t} - 895,31CV_{4,t} + 111,38CV_{1,t+1} + 290,52CV_{2,t+1} + 342,29CV_{3,t+1} + 4344,01CV_{4,t+1} + \varepsilon_{5,t}^1$$

n. Pecahan Rp50.000 di KPw Jakarta

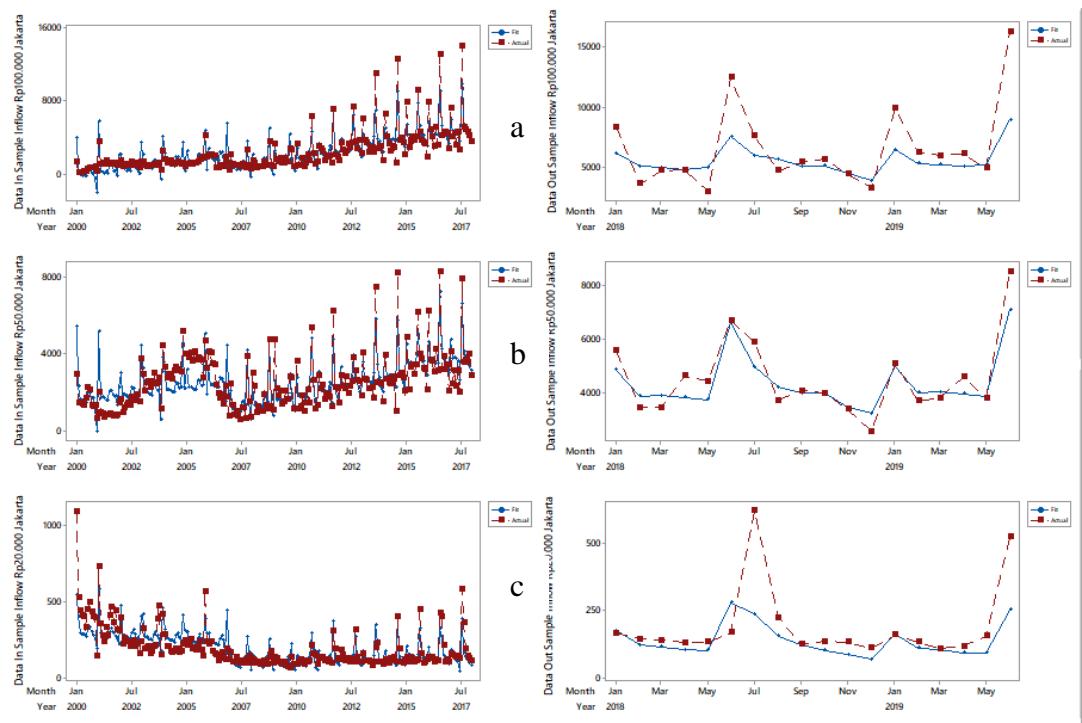
$$\hat{Z}_{5,t}^2 = 10,67t - 2106D_1 - 2268,33D_2 + 8,53tD_1 + 10,03tD_2 + 2566,10S_1 + 1573,70S_2 + 1592,64S_3 + 1516,88S_4 + 1414,88S_5 + 1400,15S_6 + 1895,81S_7 + 1844,04S_8 + 1611,69S_9 + 1609,81S_{10} + 1057,22S_{11} + 823,17S_{12} + 3225,82CV_{1,t} + 2856,31CV_{2,t} + 1185,50CV_{3,t} - 996,65CV_{4,t} + 274,14CV_{1,t+1} + 707,55CV_{2,t+1} + 145,98CV_{3,t+1} + 2492,16CV_{4,t+1} + \varepsilon_{5,t}^2$$

o. Pecahan Rp20.000 di KPw Jakarta

$$\hat{Z}_{5,t}^3 = -0,82t - 213,83D_1 - 177,17D_2 + 0,89tD_1 + 0,82tD_2 + 352,38S_1 + 300,50S_2 + 296,40S_3 + 284,60S_4 + 284,11S_5 + 275,05S_6 + 318,65S_7 + 338,93S_8 + 309,33S_9 + 287,61S_{10} + 272,50S_{11} + 257,36S_{12} + 170,35CV_{1,t} + 187,02CV_{2,t} - 17,94CV_{3,t} - 61,52CV_{4,t} + 91,86CV_{1,t+1} + 102,07CV_{2,t+1} + 139,56CV_{3,t+1} + 236,46CV_{4,t+1} + \varepsilon_{5,t}^3$$

Selanjutnya plot perbandingan data prediksi berdasarkan model TSR sebelumnya dengan data aktual setiap UPB di KPw Bank Sentral Jakarta divisualisaikan pada Gambar 4.9. Secara keseluruhan *time series* plot menunjukkan bahwa model TSR yang dihasilkan mampu mengikuti pola komponen tren, musiman dan variasi kalender pada data *inflow* UPB KPw Bank Sentral Provinsi di Pulau Jawa. Namun, pada data *out sample* hasil prediksi model TSR belum mengikuti pola data dengan nilai yang tepat. Sehingga model TSR belum cukup baik untuk meramalkan data *inflow* UPB KPw Bank Sentral Provinsi di Pulau Jawa.

Hasil perhitungan RMSE dan sMAPE untuk data *inflow* dan *outflow* setiap UPB pada lima KPw Bank Sentral Provinsi di Jawa ditunjukkan pada Tabel 4.2. Nilai RMSE dan sMAPE yang diperoleh masih relatif cukup besar terutama pada data *out sample*. Hal ini dikarenakan model yang dihasilkan belum mampu melakukan prediksi dengan tepat sehingga memiliki residual yang besar.



**Gambar 4.9.** Perbandingan Data Aktual *Inflow* pecahan Rp100.000 (a), Rp50.000 (b), Rp20.000 (c) KPw Bank Sentral Jakarta dengan Prediksi Hasil Pemodelan TSR *in sample* (kiri) dan *out sample* (kanan)

**Tabel 4.2.** Nilai RMSE dan sMAPE Pemodelan *Inflow* UPB dengan Model TSR

Lokasi	Data	Pecahan					
		Rp100.000		Rp50.000		Rp20.000	
		RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE
Surabaya	<i>In Sample</i>	424,073	45,726%	244,436	26,840%	25,180	28,881%
	<i>Out Sample</i>	942,489	24,510%	453,040	19,732%	51,690	28,837%
Semarang	<i>In Sample</i>	397,211	53,993%	198,380	28,294%	18,199	25,898%
	<i>Out Sample</i>	781,873	25,313%	590,604	15,141%	62,094	35,020%
Yogyakarta	<i>In Sample</i>	162,345	44,508%	92,346	32,502%	12,654	32,021%
	<i>Out Sample</i>	361,569	27,841%	164,379	19,400%	23,527	52,605%
Bandung	<i>In Sample</i>	439,116	47,485%	267,714	25,821%	34,672	30,026%
	<i>Out Sample</i>	909,171	27,665%	490,469	23,599%	37,003	23,331%
Jakarta	<i>In Sample</i>	1006,015	42,263%	795,097	25,899%	79,083	26,092%
	<i>Out Sample</i>	2441,860	22,308%	576,032	9,944%	117,562	30,315%

#### 4.4 Pemodelan ARIMAX Data *Inflow* dan *Outflow* UPB di KPw Bank

##### Sentral Provinsi Pulau Jawa

Model ARIMAX merupakan pemodelan *hybrid* univariat dengan dua tahap pemodelan. Tahap pertama dilakukan pemodelan TSR dan diperoleh residual dari masing-masing UPB di setiap lokasi. Selanjutnya menguji asumsi white noise

residual model TSR menggunakan uji *Ljung Box*, jika belum memenuhi asumsi *white noise* maka residual tersebut dimodelkan lagi dengan model ARIMA. Hasil uji *Ljung Box* residual TSR data inflow masing-masing UPB dapat dilihat pada tabel berikut.

**Tabel 4.3.** Hasil Uji *Ljung Box* Residual TSR *Inflow* dan *Outflow* UPB KPw Bank Sentral Provinsi di Jawa

Inflow	Rp100.000			Rp50.000			Rp20.000		
	KpW	Lag	X <sup>2</sup>	Pvalue	Lag	X <sup>2</sup>	Pvalue	Lag	X <sup>2</sup>
Surabaya	6	13,502	0,036	6	65,677	≈0,000	6	86,930	≈0,000
	12	48,607	≈0,000	12	96,359	≈0,000	12	127,313	≈0,000
	18	54,507	≈0,000	18	97,033	≈0,000	18	138,954	≈0,000
	24	62,851	≈0,000	24	107,52	≈0,000	24	153,416	≈0,000
	30	76,477	≈0,000	30	149,18	≈0,000	30	187,653	≈0,000
Semarang	6	15,724	0,015	6	5,279	0,509	6	355,793	≈0,000
	12	60,038	≈0,000	12	31,106	0,002	12	533,989	≈0,000
	18	67,533	≈0,000	18	34,604	0,011	18	565,571	≈0,000
	24	78,938	≈0,000	24	49,240	0,002	24	571,470	≈0,000
	30	83,483	≈0,000	30	53,936	0,005	30	578,335	≈0,000
Yogyakarta	6	13,646	0,034	6	61,636	≈0,000	6	173,163	≈0,000
	12	58,111	≈0,000	12	84,980	≈0,000	12	219,737	≈0,000
	18	71,824	≈0,000	18	89,594	≈0,000	18	223,540	≈0,000
	24	79,055	≈0,000	24	92,829	≈0,000	24	234,073	≈0,000
	30	86,018	≈0,000	30	103,261	≈0,000	30	249,976	≈0,000
Bandung	6	11,921	0,064	6	6,122	0,410	6	416,625	≈0,000
	12	50,629	≈0,000	12	8,912	0,710	12	642,875	≈0,000
	18	54,470	≈0,000	18	20,477	0,307	18	691,753	≈0,000
	24	62,872	≈0,000	24	32,043	0,126	24	700,552	≈0,000
	30	64,841	≈0,000	30	38,324	0,142	30	702,015	≈0,000
Jakarta	6	12,594	0,050	6	149,867	≈0,000	6	137,346	≈0,000
	12	49,591	≈0,000	12	236,373	≈0,000	12	178,486	≈0,000
	18	59,033	≈0,000	18	242,84	≈0,000	18	190,609	≈0,000
	24	69,410	≈0,000	24	245,366	≈0,000	24	204,380	≈0,000
	30	73,524	≈0,000	30	271,957	≈0,000	30	210,637	≈0,000
Outflow	Rp100.000			Rp50.000			Rp20.000		
KpW	Lag	X <sup>2</sup>	Pvalue	Lag	X <sup>2</sup>	Pvalue	Lag	X <sup>2</sup>	Pvalue
Surabaya	6	15,235	0,018	6	19,592	0,003	6	11,753	0,067
	12	47,327	≈0,000	12	29,572	0,003	12	79,137	≈0,000
	18	68,789	≈0,000	18	31,616	0,024	18	94,369	≈0,000
	24	96,381	≈0,000	24	53,187	0,001	24	116,337	≈0,000
	30	105,363	≈0,000	30	64,646	≈0,000	30	122,528	≈0,000
Semarang	6	14,675	0,023	6	6,993	0,321	6	77,767	≈0,000
	12	53,692	≈0,000	12	21,882	0,039	12	133,509	≈0,000
	18	61,773	≈0,000	18	34,152	0,012	18	144,301	≈0,000
	24	83,288	≈0,000	24	64,158	≈0,000	24	156,644	≈0,000
	30	93,982	≈0,000	30	71,332	≈0,000	30	158,258	≈0,000

**Tabel 4.3.** Hasil Uji Ljung Box Residual TSR *Inflow* dan *Outflow* UPB KPw Bank Sentral Provinsi di Jawa (lanjutan)

Outflow	Rp100.000			Rp50.000			Rp20.000		
	KpW	Lag	X <sup>2</sup>	Pvalue	Lag	X <sup>2</sup>	Pvalue	Lag	X <sup>2</sup>
Yogyakarta	6	15,192	0,019	6	11,557	0,073	6	56,007	≈0,000
	12	51,183	≈0,000	12	38,935	≈0,000	12	70,374	≈0,000
	18	72,228	≈0,000	18	49,634	≈0,000	18	84,628	≈0,000
	24	110,877	≈0,000	24	73,817	≈0,000	24	99,879	≈0,000
	30	115,916	≈0,000	30	80,780	≈0,000	30	103,971	≈0,000
Bandung	6	29,602	≈0,000	6	7,428	0,283	6	67,703	≈0,000
	12	81,846	≈0,000	12	44,275	≈0,000	12	105,707	≈0,000
	18	103,486	≈0,000	18	56,859	≈0,000	18	110,333	≈0,000
	24	138,273	≈0,000	24	89,776	≈0,000	24	129,508	≈0,000
	30	144,298	≈0,000	30	97,586	≈0,000	30	138,080	≈0,000
Jakarta	6	13,921	0,031	6	51,955	≈0,000	6	4,618	0,594
	12	49,038	≈0,000	12	89,695	≈0,000	12	32,723	0,001
	18	60,577	≈0,000	18	92,836	≈0,000	18	33,900	0,013
	24	92,191	≈0,000	24	104,036	≈0,000	24	46,287	0,004
	30	98,482	≈0,000	30	114,682	≈0,000	30	48,734	0,016

Berdasarkan tabel 4.3 diketahui bahwa residual model TSR dari setiap UPB di KPw Bank Sentral Provinsi di Pulau Jawa belum memenuhi uji asumsi *white noise* karena nilai *p-value* kurang dari nilai  $\alpha = 0,05$ . Sehingga dilakukan pemodelan ARIMA dengan prosedur *Box-Jenkins* pada residual TSR setiap UPB. Penentuan orde pada model ARIMA diidentifikasi dengan plot ACF dan PACF dari data residual TSR. Berdasarkan identifikasi orde tersebut diketahui model-model ARIMA dari data *inflow* dan *outflow* masing-masing UPB di setiap lokasi sebagai berikut.

**Tabel 4.4** Model ARIMAX *Inflow* dan *Outflow* Setiap UPB KPw Bank Sentral Provinsi di Jawa

Inflow				
Lokasi	Pecahan	Model ARIMA	White Noise	Uji Normal
Surabaya	Rp100.000	ARIMA ([6,12,35],0,0)	Tidak	Ya
	Rp50.000	ARIMA ([2,3,12,15],0,0)	Ya	Ya
	Rp20.000	ARIMA ([1,11,23,24,36],0,0)	Ya	Ya
Semarang	Rp100.000	ARIMA ([1,6,12,35],0,0)	Ya	Tidak
	Rp50.000	ARIMA ([1,12,23],0,0)	Ya	Ya
	Rp20.000	ARIMA ([1,2,11,36],0,0)	Ya	Ya
Yogyakarta	Rp100.000	ARIMA ([11],0,0)	Tidak	Tidak
	Rp50.000	ARIMA ([1,2,12],0,0)	Ya	Ya
	Rp20.000	ARIMA (1,2,3,12,13],0,0)	Ya	Tidak

**Tabel 4.4** Model ARIMAX *Inflow* dan *Outflow* Setiap UPB KPw Bank Sentral Provinsi di Jawa (lanjutan)

<i>Inflow</i>				
Lokasi	Pecahan	Model ARIMA	White Noise	Uji Normal
Bandung	Rp100.000	ARIMA ([6,12,23,31],0,0)	Ya	Ya
	Rp50.000	ARIMA ([15,23,24],0,0)	Ya	Ya
	Rp20.000	ARIMA ([1,3],0,0)	Tidak	Tidak
Jakarta	Rp100.000	ARIMA ([1,12,23,35],0,0)	Ya	Ya
	Rp50.000	ARIMA ([1,2,3,12,15,23,24],0,0)	Ya	Ya
	Rp20.000	ARIMA ([1,3],0,0)	Ya	Tidak
<i>Outflow</i>				
Lokasi	Pecahan	Model ARIMA	White Noise	Uji Normal
Surabaya	Rp100.000	ARIMA ([6,10,12,13,15,23],0,0)	Ya	Ya
	Rp50.000	ARIMA ([2,3,12,22,23],0,0)	Ya	Ya
	Rp20.000	ARIMA ([2,10,12,13],0,0)	Ya	Tidak
Semarang	Rp100.000	ARIMA ([1,6,12],0,0)	Ya	Tidak
	Rp50.000	ARIMA ([10,12,13,14,22,23],0,0)	Ya	Ya
	Rp20.000	ARIMA ([1,3,4,6,11,12,13,23,24],0,0)	Ya	Ya
Yogyakarta	Rp100.000	ARIMA ([1,4,8,12,15,16,17,22,23],0,0)	Ya	Ya
	Rp50.000	ARIMA ([1,12,15,22,23],0,0)	Ya	Ya
	Rp20.000	ARIMA ([1,5,12,13],0,0)	Ya	Tidak
Bandung	Rp100.000	ARIMA ([1,2,4,6,10,12,15],0,0)	Ya	Tidak
	Rp50.000	ARIMA ([1,10,12,14,15,22,23],0,0)	Ya	Ya
	Rp20.000	ARIMA ([1,2,3,6,11,12,13,23,24],0,0)	Ya	Ya
Jakarta	Rp100.000	ARIMA ([5,6,10,12,22,23],0,0)	Ya	Ya
	Rp50.000	ARIMA ([2,3,5,12,23,25],0,0)	Ya	Ya
	Rp20.000	ARIMA ([12,23],0,0)	Ya	Tidak

Hasil estimasi parameter dan uji asumsi pemodelan ARIMAX dapat dilihat pada Lampiran 3. Sebagai contoh model ARIMAX yang dihasilkan untuk data *inflow* Rp100.000 di KPw Bank Sentral Jakarta adalah sebagai berikut.

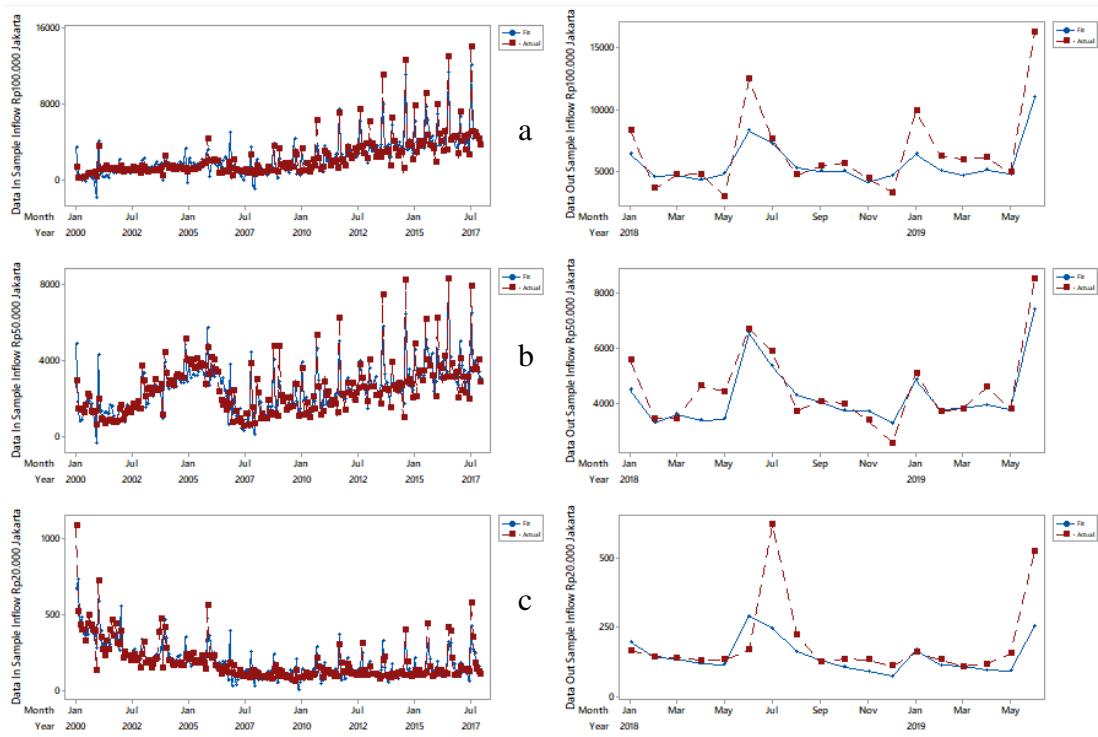
$$\hat{Z}_{5,t}^1 = 23,05t - 1550,73D_1 - 3805,62D_2 + 3,31tD_1 + 21,87tD_2 + 1170,89S_1 + 51,42S_2 - 88,37S_3 - 259,35S_4 - 130,77S_5 - 355,95S_6 + 560,02S_7 + 535,66S_8 - 98,58S_9 - 100,65S_{10} - 761,45S_{11} - 1347,92S_{12} + 3916,27CV_{1,t} + 2811,23CV_{2,t} + 2875,83CV_{3,t} - 895,31CV_{4,t} + 111,38CV_{1,t+1} + 290,52CV_{2,t+1} + 342,29CV_{3,t+1} + 4344,01CV_{4,t+1} + \varepsilon_{5,t}^1$$

dengan

$$\hat{\varepsilon}_{5,t}^1 = \frac{1}{(1 - \phi_1 B^1 - \phi_{12} B^{12} - \phi_{23} B^{23} - \phi_{35} B^{35})} a_t$$

Selanjutnya digambarkan plot perbandingan data prediksi dengan data aktual *inflow* dan *outflow* UPB KPw Bank Sentral provinsi di Jawa. Sebagai

contoh plot *inflow* UPB KPw Bank Sentral Jakarta dapat dilihat pada Gambar 4.10. Berdasarkan Gambar 4.10 diketahui bahwa hasil prediksi mampu mengikuti pola data *inflow* tetapi belum sepenuhnya mengikuti dengan nilai yang tepat. Hasil plot prediksi ARIMAX tidak jauh berbeda dengan dengan hasil model TSR yang belum cukup baik untuk melakukan prediksi *inflow* setiap UPB secara univariat.



**Gambar 4.10.** Perbandingan Data Aktual *Inflow* pecahan Rp100.000 (a), Rp50.000 (b), Rp20.000 (c) KPw Bank Sentral Jakarta dengan Prediksi Hasil Pemodelan ARIMAX *in sample* (kiri) dan *out sample* (kanan)

Kemudian dilakukan perhitungan nilai RMSE dan sMAPE untuk mengetahui kebaikan model ARIMAX memprediksi *inflow* dan *outflow* UPB KPw Bank Sentral Provinsi di Jawa. Nilai RMSE dan sMAPE diberikan pada Tabel 4.5.

**Tabel 4.5.** Nilai RMSE dan sMAPE Pemodelan ARIMAX *Inflow* dan *Outflow* setiap UPB

Lokasi	Data	Pecahan					
		Rp100.000		Rp50.000		Rp20.000	
		RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE
Surabaya	<i>In Sample</i>	361,78	42,067%	219,95	24,282%	19,27	25,962%
	<i>Out Sample</i>	834,46	23,534%	417,73	18,520%	36,71	32,866%
Semarang	<i>In Sample</i>	311,90	47,978%	176,80	28,468%	11,38	19,213%
	<i>Out Sample</i>	673,39	24,367%	265,54	12,933%	33,48	31,527%

**Tabel 4.5.** Nilai RMSE dan sMAPE Pemodelan ARIMAX *Inflow* dan *Outflow* setiap UPB (lanjutan)

Lokasi	Data	Pecahan					
		Rp100.000		Rp50.000		Rp20.000	
		RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE
Yogyakarta	<i>In Sample</i>	160,18	46,217%	85,01	30,591%	9,84	28,917%
	<i>Out Sample</i>	379,19	28,732%	174,16	19,446%	20,71	39,604%
Bandung	<i>In Sample</i>	366,98	43,188%	255,16	25,236%	22,45	23,985%
	<i>Out Sample</i>	798,13	23,852%	497,50	23,805%	35,36	22,871%
Jakarta	<i>In Sample</i>	834,83	39,302%	605,44	20,599%	64,98	22,947%
	<i>Out Sample</i>	2016,58	20,695%	607,52	10,382%	115,50	26,952%

. Hasil RMSE dan sMAPE pemodelan ARIMAX diketahui memiliki nilai yang masih cukup besar. Hal ini menunjukkan bahwa model ARIMAX memiliki performa kebaikan model yang tidak jauh berbeda dengan model TSR dalam melakukan prediksi *inflow* dan *outflow* UPB KPw Bank Sentral Provinsi di Jawa.

#### 4.5 Pemodelan GSTARX Data *Inflow* dan *Outflow* UPB KPw Bank Sentral Provinsi di Pulau Jawa

Model GSTARX merupakan pemodelan *hybrid* multivariat dengan memperhatikan faktor spasial dan pengaruh variabel eksogen. Faktor spasial ini ditunjukkan dengan adanya pembobotan pada masing-masing pecahan. Bobot yang digunakan dalam penelitian ini adalah bobot seragam, bobot invers jarak, dan bobot normalisasi korelasi silang.

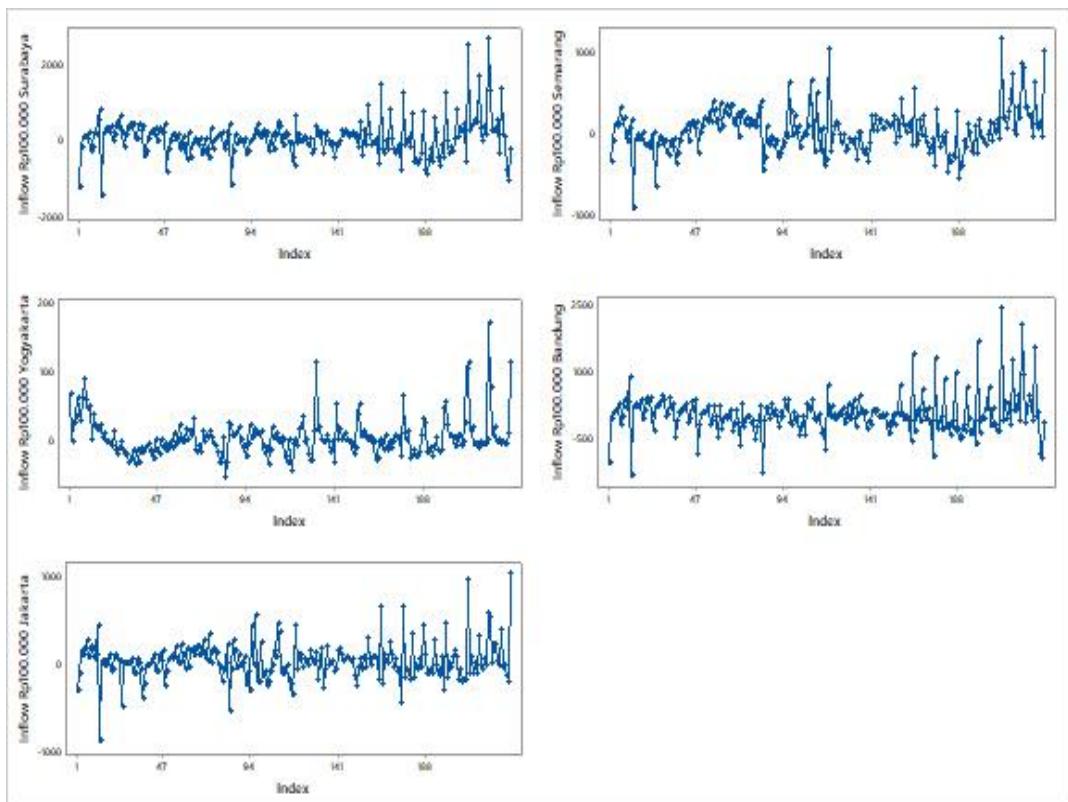
Sebelum melakukan pemodelan GSTARX terlebih dahulu dilihat korelasi antar wilayah Bank Sentral Provinsi di Pulau Jawa. Nilai korelasi dapat digunakan untuk mengetahui besar kecilnya kecenderungan keterkaitan antar KPw Bank Sentral. Pada Tabel 4.6 ditunjukkan bahwa korelasi antar wilayah Bank Sentral Propinsi di Jawa relatif tinggi untuk setiap pecahan. Sehingga mengindikasikan bahwa ada keterkaitan data *inflow* dan *outflow* UPB antar KPw Bank Sentral Provinsi di Pulau Jawa.

**Tabel 4.6.** Koefisien Korelasi data *Inflow* dan *Outflow* setiap UPB di Lima KPw Bank Sentral Provinsi di Jawa

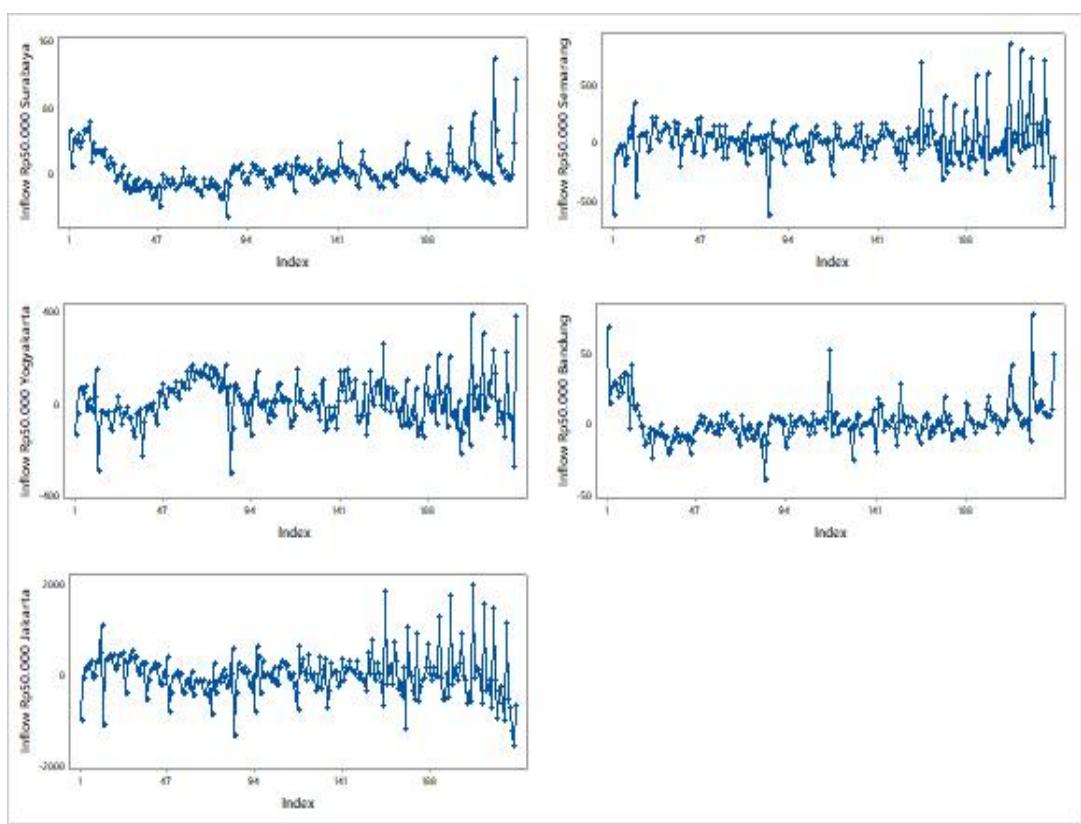
Pecahan	Wilayah	<i>Inflow</i>					
		Surabaya	Semarang	Yogyakarta	Bandung	Jakarta	
Rp100.000	Surabaya	1,000	0,967	0,939	0,907	0,911	
	Semarang	0,967	1,000	0,948	0,929	0,933	
	Yogyakarta	0,939	0,948	1,000	0,936	0,908	
	Bandung	0,907	0,929	0,936	1,000	0,936	
	Jakarta	0,911	0,933	0,908	0,936	1,000	
Rp50.000	Surabaya	1,000	0,894	0,880	0,802	0,869	
	Semarang	0,894	1,000	0,876	0,900	0,862	
	Yogyakarta	0,880	0,876	1,000	0,883	0,887	
	Bandung	0,802	0,900	0,883	1,000	0,819	
	Jakarta	0,869	0,862	0,887	0,819	1,000	
Rp20.000	Surabaya	1,000	0,897	0,863	0,848	0,858	
	Semarang	0,897	1,000	0,834	0,889	0,846	
	Yogyakarta	0,863	0,834	1,000	0,880	0,875	
	Bandung	0,848	0,889	0,880	1,000	0,917	
	Jakarta	0,858	0,846	0,875	0,917	1,000	
Pecahan		<i>Outflow</i>					
Rp100.000	Wilayah	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta	
		Surabaya	1,000	0,946	0,914	0,926	0,903
		Semarang	0,946	1,000	0,916	0,949	0,886
		Yogyakarta	0,914	0,916	1,000	0,920	0,894
		Bandung	0,926	0,949	0,920	1,000	0,917
Rp50.000	Wilayah	Jakarta	0,903	0,886	0,894	0,917	1,000
		Surabaya	1,000	0,918	0,916	0,899	0,881
		Semarang	0,918	1,000	0,933	0,947	0,892
		Yogyakarta	0,916	0,933	1,000	0,944	0,852
		Bandung	0,899	0,947	0,944	1,000	0,882
Rp20.000	Wilayah	Jakarta	0,881	0,892	0,852	0,882	1,000
		Surabaya	1,000	0,906	0,858	0,894	0,757
		Semarang	0,906	1,000	0,888	0,930	0,790
		Yogyakarta	0,858	0,888	1,000	0,893	0,705
		Bandung	0,894	0,930	0,893	1,000	0,743
		Jakarta	0,757	0,790	0,705	0,743	1,000

Pemodelan GSTARX memiliki dua tahap, pertama melakukan pemodelan TSR untuk menangkap pengaruh variabel eksogen yaitu komponen tren, musiman, dan variabel kalender pada data *inflow* dan *outflow*. Tahap kedua melakukan pemodelan residual dari model TSR dengan menggunakan model GSTAR pada setiap pecahan di lima KPw Bank Sentral Provinsi di Pulau Jawa.

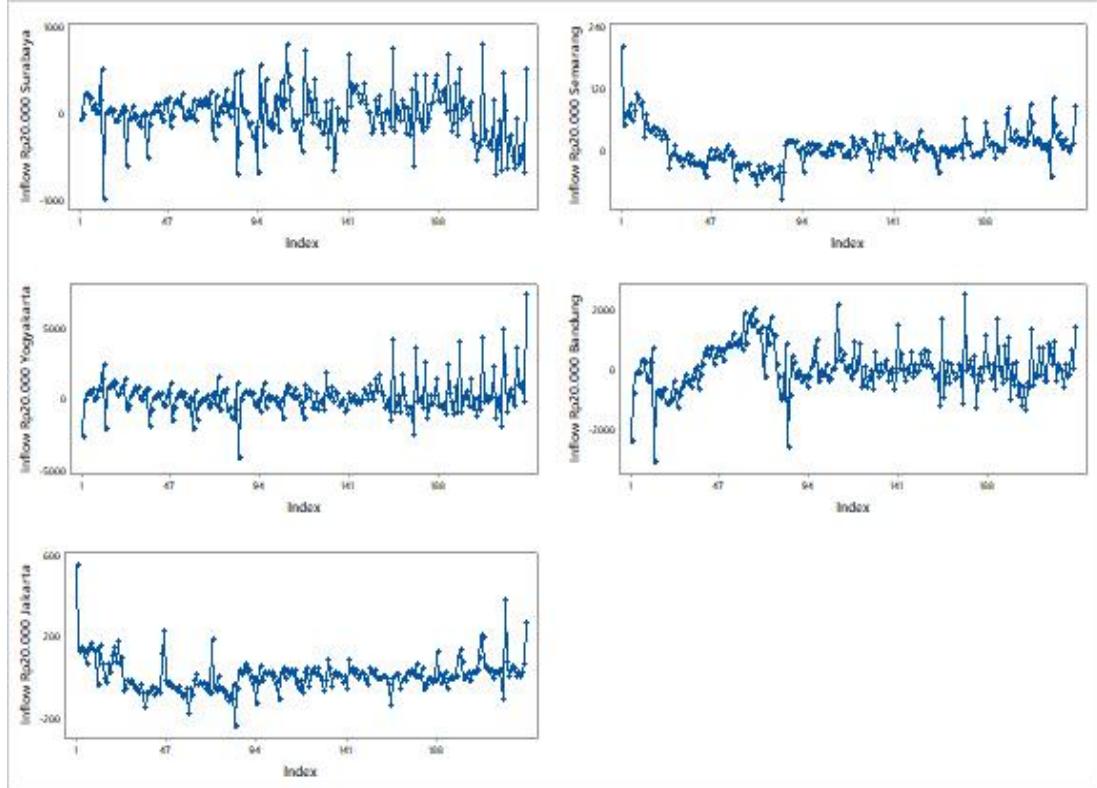
Tahap kedua diawali dengan melakukan pemeriksaan stasioneritas dan penentuan orde GSTAR. Identifikasi stasioneritas dilakukan dengan melihat *time series* plot data residual dari model TSR. *Time series* plot residual TSR *inflow* setiap UPB diberikan pada Gambar 4.11 hingga Gambar 4.13. Berdasarkan *time series* plot tersebut diketahui bahwa pola data residual telah stasioner mendekati nilai rata-rata 0. Selain itu untuk mengetahui stasioneritas residual TSR *inflow* Rp100.000 dapat dilihat pula melalui plot MCCF yang ditunjukkan pada Gambar 4.14. Pada Gambar menunjukkan nilai korelasi silang dengan pola *cut-off* pada *lag-lag* tertentu. Hal itu menunjukkan bahwa residual TSR *inflow* Rp100.000 telah stasioner.



**Gambar 4.11** *Time Series Plot Residual Model TSR Inflow Rp100.000 di Lima KPw*



**Gambar 4.12** Time Series Plot Residual Model TSR Inflow Rp50.000 di Lima KPw



**Gambar 4.13** Time Series Plot Residual Model TSR Inflow Rp20.000 di Lima KPw

Schematic Representation of Cross Correlations-inflow100													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Z11	++++	.....	.....	.....	....+	+++++	....	.....	....-	....-	....+	++++	
Z21	++++	.....	.....	.....	....-	.....	++++	.....	.....	.....	.....	.....	++++
Z31	++++	....-	.....	.....	....-	....+	++++	.....	.....	....-	....-	.....	++++
Z41	++++	....-	.....	.....	.....	.....	++++	.....	.....	.....	.....	.....	++++
Z51	++++	.....	.....	.....	....-	.....	++++	.....	.....	.....	.....	.....	++++

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

Schematic Representation of Cross Correlations-outflow100													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Z11	++..	...++	.+..	-.+..	.....	.....	++..	.+..+	-....	.....	....-	+..+	++..
Z21	++..	..+..	....	....	....	....	....	....	....	....	+..+	++..	++..
Z31	.++.	....	....	....	....	....	....	....	....	....	....	....	....
Z41	+..+	++..+	..+..	-....	....	....	++..	....	....	....	....	....-	....
Z51	..+..	....+	-....	....	....	....	....	....	....	....	....	....	....

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

**Gambar 4.14** Plot MCCF Residual Model TSR *Inflow* dan *Outflow* Rp100.000

Selanjutnya penentuan orde GSTAR dilakukan dengan melihat plot MPCCF untuk pecahan Rp100.000 ditunjukkan pada Gambar 4.15. Plot MCCFF dan MPCCF residual model TSR *Inflow* dan *Outflow* UPB dapat dilihat pada Lampiran 4.

Schematic Representation of Partial Cross Correlations-inflow100													
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12	
Z11	+...-	....	....-	....-	....	....	....+	....	....-	....	....	....+	
Z21	.....	....+	....-	.....	....-	.....	.....	.....	.....	....-	....	....+	
Z31	...+-	....+	....	....	....	....	....-	....	....	....	....	....-	
Z41	.-+-	....+	....+	....	....	....	....+	....	....	....	....	....	
Z51	....-	....-	....	....	....	....	....+	....	....	....	....	....	....+

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

Schematic Representation of Partial Cross Correlations-outflow100													
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12	
Y11	++..	+.+..	+-..	....-	....	....	....	....	....+	....	....	....	
Y21	....-	++..	....-	....	....	....	....+	....	....	....	....	....++	
Y31	....+	....	....	....	....	....	....-	....	....+	....	....	....	
Y41	....+-	....-	....-	....	....	....	....-	....	....-	....	....	....+	
Y51	....-	....	....	....	....	....	....	....	....+	....	....-	....++	

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

**Gambar 4.15** Plot MPCCF Residual Model TSR *Inflow* dan *Outflow* Rp100.000

Berdasarkan plot MPCCF dapat diketahui bahwa sebagian besar lokasi signifikan pada *lag* 1 dan *lag* 2 untuk pecahan Rp100.000. Sedangkan pada *lag-lag* lainnya tidak trdapat lokasi yang signifikan secara bersamaan. Sehingga orde yang ditentukan untuk *inflow* dan *outflow* Rp100.000 adalah GSTARX (2<sub>1</sub>). Selanjutnya pemodelan *inflow* dan *outflow* Rp100.000 untuk semua KPw Bank

sentral Provinsi di Jawa mengikuti model GSTARX ( $2_1$ ). Secara lengkap model GSTARX data *inflow* dan *outflow* untuk setiap uang pecahan besar (UPB) dapat dilihat pada Tabel 4.7.

**Tabel 4.7.** Model GSTARX *Inflow* dan *Outflow* UPB KPw Bank Sentral di Jawa

Data	Pecahan	Model
<i>Inflow</i>	Rp100.000	GSTARX ( $2_1$ )
	Rp50.000	GSTARX ( $2_1$ )
	Rp20.000	GSTARX ( $2_1$ )
<i>Outflow</i>	Rp100.000	GSTARX ( $2_1$ )
	Rp50.000	GSTARX ( $2_1$ )
	Rp20.000	GSTARX ( $2_1$ )

Estimasi parameter yang digunakan dalam pemodelan GSTARX adalah *Generalized least Square* (GLS). Setiap model GSTARX data *inflow* dan *outflow* setiap UPB dihitung dengan tiga bobot lokasi dan dilakukan pemilihan bobot lokasi terbaik berdasarkan nilai RMSE dan sMAPE terkecil dari masing-masing pemodelan. Hasil perhitungan RMSE dan sMAPE model GSTARX *inflow* setiap UPB KPw Bank Sentral di Pulau Jawa diberikan pada Tabel 4.8 dan Tabel 4.9.

**Tabel 4.8.** Nilai RMSE Pemodelan GSTARX *Inflow* setiap UPB lima KPw Bank Sentral di Jawa

Bobot	Lokasi	Pecahan					
		Rp100.000		Rp50.000		Rp20.000	
		<i>In</i> <i>Sample</i>	<i>Out</i> <i>Sample</i>	<i>In</i> <i>Sample</i>	<i>Out</i> <i>Sample</i>	<i>In</i> <i>Sample</i>	<i>Out</i> <i>Sample</i>
Seragam	Surabaya	406,359	842,152	231,452	384,269	21,277	50,874
	Semarang	441,594	417,847	199,786	334,203	12,506	44,091
	Yogyakarta	153,018	352,747	86,890	173,557	9,661	23,104
	Bandung	429,871	829,147	270,645	432,152	19,897	40,217
	Jakarta	964,152	2282,912	665,667	520,07	56,864	126,051
Invers Jarak	Surabaya	405,665	962,652	230,6	388,669	21,330	57,154
	Semarang	440,432	391,249	200,115	338,700	12,544	48,995
	Yogyakarta	153,192	367,594	87,0730	167,087	9,637	25,442
	Bandung	430,571	850,158	270,456	439,410	19,899	40,285
	Jakarta	962,847	2460,845	660,221	554,935	56,713	125,650
Korelasi Silang	Surabaya	405,342	1059,436	231,156	390,220	21,258	50,944
	Semarang	444,197	465,472	200,020	329,208	12,466	44,115
	Yogyakarta	152,273	378,269	87,091	174,582	9,645	23,135
	Bandung	428,696	988,675	270,904	434,934	19,884	40,317
	Jakarta	959,529	2779,181	665,654	532,275	56,782	126,155

**Tabel 4.9.** Nilai sMAPE Pemodelan GSTARX *Inflow* setiap UPB lima KPw Bank Sentral di Jawa

Bobot	Lokasi	Pecahan					
		Rp100.000		Rp50.000		Rp20.000	
		<i>In</i> Sample	<i>Out</i> Sample	<i>In</i> Sample	<i>Out</i> Sample	<i>In</i> Sample	<i>Out</i> Sample
Seragam	Surabaya	46,443%	21,970%	24,178%	15,895%	26,468%	24,680%
	Semarang	63,563%	23,949%	28,951%	15,516%	20,315%	31,542%
	Yogyakarta	45,687%	28,271%	30,632%	20,655%	28,923%	31,939%
	Bandung	48,356%	23,992%	26,015%	20,337%	22,515%	23,117%
	Jakarta	42,796%	21,889%	21,570%	9,476%	22,313%	29,336%
Invers Jarak	Surabaya	45,343%	32,266%	24,060%	15,741%	26,506%	30,076%
	Semarang	63,758%	22,800%	29,073%	16,132%	20,308%	40,907%
	Yogyakarta	44,378%	30,556%	30,712%	20,357%	28,866%	32,986%
	Bandung	47,547%	25,605%	25,895%	20,682%	22,490%	23,183%
	Jakarta	42,731%	25,524%	21,685%	11,440%	22,185%	28,826%
Korelasi Silang	Surabaya	45,997%	29,717%	24,102%	15,948%	26,467%	24,728%
	Semarang	63,852%	25,898%	28,796%	15,866%	20,283%	31,708%
	Yogyakarta	46,055%	28,182%	30,573%	20,502%	28,920%	32,081%
	Bandung	48,062%	30,953%	26,144%	20,404%	22,536%	23,179%
	Jakarta	43,657%	25,194%	21,459%	9,506%	22,295%	29,375%

#### 4.5.1 Pemodelan GSTARX Pecahan Rp100.000

Berdasarkan nilai RMSE dan sMAPE *out sample* pada Tabel 4.8 dan 4.9 diperoleh bobot terbaik untuk pecahan Rp100.000 adalah bobot seragam. Hasil estimasi parameter model GSTARX data *inflow* pecahan Rp100.000 dengan menggunakan bobot seragam ditunjukkan pada Tabel 4.10.

**Tabel 4.10.** Estimasi Parameter GSTARX *Inflow* Rp100.000 Bobot Seragam

Wilayah	Parameter	Koefisien	SE	t-value	p-value
Surabaya	$\phi_{10}^1$	0,205	0,063	3,245	0,001
	$\phi_{11}^1$	-0,272	0,072	-3,795	0,0002
	$\phi_{10}^2$	0,243	0,063	3,843	0,0002
	$\phi_{11}^2$	-0,231	0,070	-3,287	0,001
Semarang	$\phi_{20}^1$	0,001	0,064	0,021	0,984
	$\phi_{21}^1$	-0,175	0,069	-2,533	0,012
	$\phi_{20}^2$	0,087	0,064	1,354	0,177
	$\phi_{21}^2$	-0,059	0,069	-0,854	0,340
Yogyakarta	$\phi_{30}^1$	0,182	0,067	2,699	0,008
	$\phi_{31}^1$	-0,110	0,026	-4,227	$\approx 0,000$
	$\phi_{30}^2$	0,279	0,066	4,228	$\approx 0,000$
	$\phi_{31}^2$	-0,083	0,026	-3,233	0,001

**Tabel 4.10.** Estimasi Parameter GSTARX *Inflow* Rp100.000 Bobot Seragam (lanjutan)

Wilayah	Parameter	Koefisien	SE	t-value	p-value
Bandung	$\phi_{40}^1$	0,179	0,073	2,464	0,015
	$\phi_{41}^1$	-0,295	0,082	-3,578	0,004
	$\phi_{40}^2$	0,039	0,073	0,535	0,594
	$\phi_{41}^2$	-0,043	0,081	-0,531	0,596
Jakarta	$\phi_{50}^1$	0,027	0,075	0,355	0,723
	$\phi_{51}^1$	-0,667	0,235	-2,838	0,005
	$\phi_{50}^2$	0,141	0,074	1,898	0,059
	$\phi_{51}^2$	-0,443	0,235	-1,886	0,061

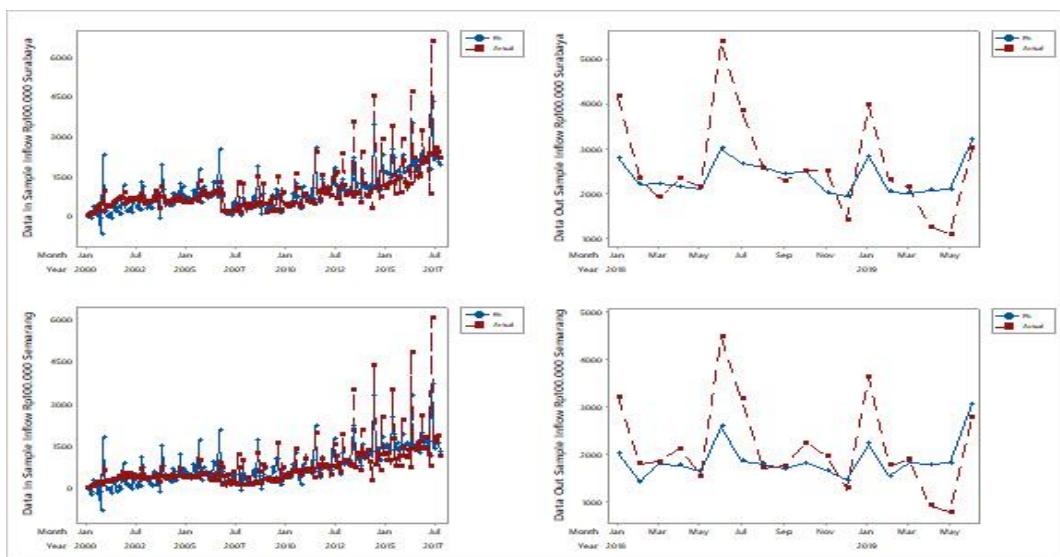
Berdasarkan Tabel 4.10 diketahui bahwa estimasi parameter untuk wilayah Surabaya dan Yogyakarta signifikan pada taraf signifikansi 5% baik parameter waktu maupun parameter lokasi. Sedangkan wilayah Semarang dan Jakarta ketiga estimasi parameter tidak signifikan hanya parameter lokasi untuk lag kedua yang signifikan. Untuk wilayah Bandung nilai estimasi parameter signifikan pada lag pertama saja baik parameter waktu dan parameter lokasi. Sehingga persamaan model GSTARX *inflow* pecahan Rp100.000 dengan bobot seragam sebagai berikut.

$$\begin{aligned}
 \begin{pmatrix} \hat{Z}_{1,t}^1 \\ \hat{Z}_{2,t}^1 \\ \hat{Z}_{3,t}^1 \\ \hat{Z}_{4,t}^1 \\ \hat{Z}_{5,t}^1 \end{pmatrix} &= \begin{pmatrix} 9,36 & 0 & 0 & 0 & 0 \\ 0 & 8,26 & 0 & 0 & 0 \\ 0 & 0 & 3,46 & 0 & 0 \\ 0 & 0 & 0 & 13,51 & 0 \\ 0 & 0 & 0 & 0 & 23,05 \end{pmatrix} \begin{pmatrix} t_{1,t}^1 \\ t_{2,t}^1 \\ t_{3,t}^1 \\ t_{4,t}^1 \\ t_{5,t}^1 \end{pmatrix} + \begin{pmatrix} -363,33 & 0 & 0 & 0 & 0 \\ 0 & -183,82 & 0 & 0 & 0 \\ 0 & 0 & -112,3 & 0 & 0 \\ 0 & 0 & 0 & -831,72 & 0 \\ 0 & 0 & 0 & 0 & -1550,73 \end{pmatrix} \begin{pmatrix} (D_1)_{1,t}^1 \\ (D_1)_{2,t}^1 \\ (D_1)_{3,t}^1 \\ (D_1)_{4,t}^1 \\ (D_1)_{5,t}^1 \end{pmatrix} + \dots + \\
 &\quad \begin{pmatrix} 484,37 & 0 & 0 & 0 & 0 \\ 0 & 199,26 & 0 & 0 & 0 \\ 0 & 0 & 245,70 & 0 & 0 \\ 0 & 0 & 0 & 314,35 & 0 \\ 0 & 0 & 0 & 0 & 1170,89 \end{pmatrix} \begin{pmatrix} (S_1)_{1,t}^1 \\ (S_1)_{2,t}^1 \\ (S_1)_{3,t}^1 \\ (S_1)_{4,t}^1 \\ (S_1)_{5,t}^1 \end{pmatrix} + \dots + \\
 &\quad \begin{pmatrix} 119,56 & 0 & 0 & 0 & 0 \\ 0 & 56,30 & 0 & 0 & 0 \\ 0 & 0 & 0,06 & 0 & 0 \\ 0 & 0 & 0 & 59,44 & 0 \\ 0 & 0 & 0 & 0 & 111,38 \end{pmatrix} \begin{pmatrix} (CV_{1,t+1})_{1,t}^1 \\ (CV_{1,t+1})_{2,t}^1 \\ (CV_{1,t+1})_{3,t}^1 \\ (CV_{1,t+1})_{4,t}^1 \\ (CV_{1,t+1})_{5,t}^1 \end{pmatrix} + \begin{pmatrix} \varepsilon_{1,t}^1 \\ \varepsilon_{2,t}^1 \\ \varepsilon_{3,t}^1 \\ \varepsilon_{4,t}^1 \\ \varepsilon_{5,t}^1 \end{pmatrix}
 \end{aligned}$$

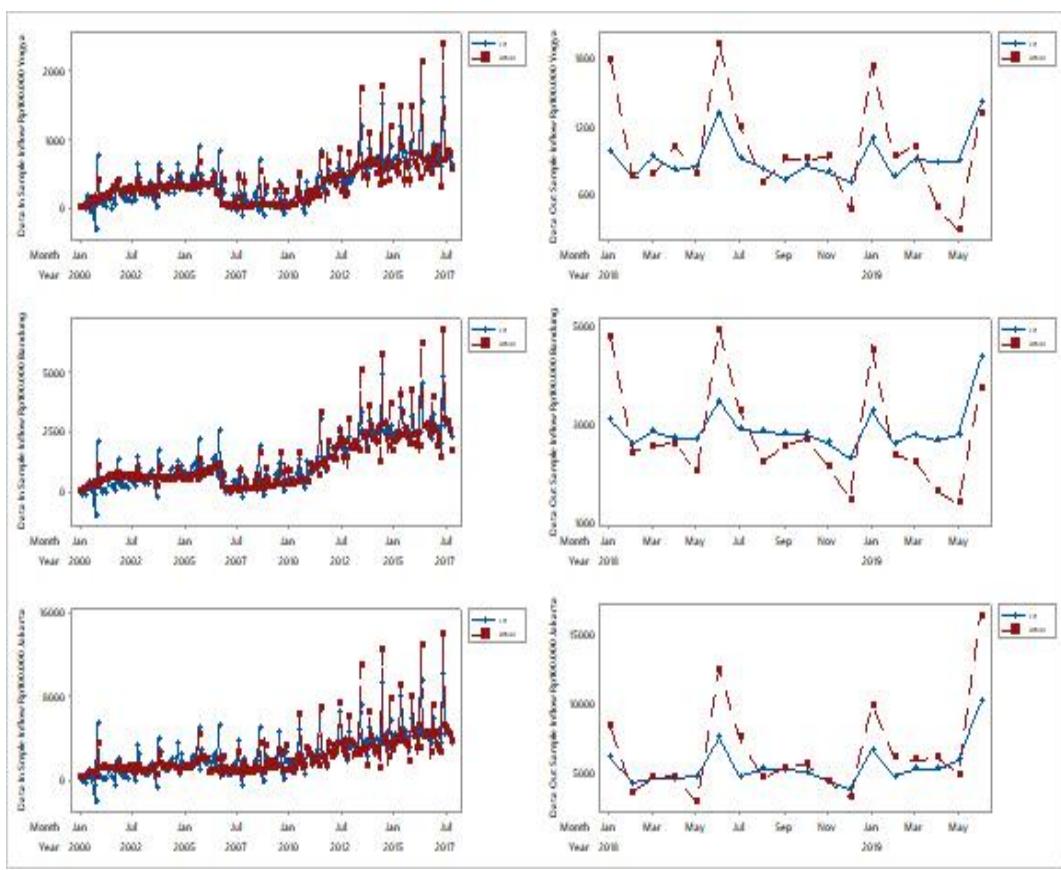
dengan

$$\begin{bmatrix} \hat{\varepsilon}_{1,t}^1 \\ \hat{\varepsilon}_{2,t}^1 \\ \hat{\varepsilon}_{3,t}^1 \\ \hat{\varepsilon}_{4,t}^1 \\ \hat{\varepsilon}_{5,t}^1 \end{bmatrix} = \begin{bmatrix} 0,205 & -0,068 & -0,068 & -0,068 & -0,068 \\ -0,04375 & 0,001 & -0,04375 & -0,04375 & -0,04375 \\ -0,0275 & -0,0275 & 0,182 & -0,0275 & -0,0275 \\ -0,07375 & -0,07375 & -0,07375 & 0,179 & -0,07375 \\ -0,16675 & -0,16675 & -0,16675 & -0,16675 & 0,027 \end{bmatrix} \begin{bmatrix} \varepsilon_{1,t-1}^1 \\ \varepsilon_{2,t-1}^1 \\ \varepsilon_{3,t-1}^1 \\ \varepsilon_{4,t-1}^1 \\ \varepsilon_{5,t-1}^1 \end{bmatrix} + \\ \begin{bmatrix} 0,243 & -0,05775 & -0,05775 & -0,05775 & -0,05775 \\ -0,01475 & 0,087 & -0,01475 & -0,01475 & -0,01475 \\ -0,02075 & -0,02075 & 0,279 & -0,02075 & -0,02075 \\ -0,01075 & -0,01075 & -0,01075 & 0,039 & -0,01075 \\ -0,11075 & -0,11075 & -0,11075 & -0,11075 & 0,141 \end{bmatrix} \begin{bmatrix} \varepsilon_{1,t-2}^1 \\ \varepsilon_{2,t-2}^1 \\ \varepsilon_{3,t-2}^1 \\ \varepsilon_{4,t-2}^1 \\ \varepsilon_{5,t-2}^1 \end{bmatrix} + \begin{bmatrix} a_{1,t}^1 \\ a_{2,t}^1 \\ a_{3,t}^1 \\ a_{4,t}^1 \\ a_{5,t}^1 \end{bmatrix}$$

Selanjutnya perbandingan data prediksi dengan data aktual *inflow* Rp100.000 KPw Bank Sentral di Jawa ditunjukkan pada Gambar 4.16. Pada plot data garis biru menunjukkan data prediksi dan garis merah menunjukkan data aktual. Berdasarkan Gambar 4.16 diketahui bahwa prediksi model GSTARX untuk *inflow* pecahan Rp100.000 dengan bobot seragam mampu mengikuti pola data aktual meskipun masih ada selisih besar antara data prediksi dan data aktual pada titik-titik puncak.



**Gambar 4.16** Perbandingan Data Aktual *Inflow* Rp100.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX Bobot Seragam *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.16** Perbandingan Data Aktual *Inflow* Rp100.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX Bobot Seragam *in sample* (kiri) dan *out sample* (kanan) (lanjutan)

#### 4.5.2 Pemodelan GSTARX Pecahan Rp50.000

Selanjutnya hasil estimasi parameter model GSTARX data *inflow* untuk pecahan Rp50.000 dengan bobot seragam diberikan pada Tabel 4.11. Berdasarkan Tabel 4.11 diketahui wilayah Jakarta memiliki tiga parameter signifikan pada taraf signifikansi 5% hanya parameter lokasi lag kedua yang tidak signifikan. Nilai estimasi parameter wilayah Surabaya dan Yogyakarta signifikan untuk dua parameter waktu sedangkan dua parameter lokasi tidak signifikan. Untuk wilayah Semarang hanya parameter waktu lag kedua yang signifikan. Sedangkan wilayah Bandung parameter waktu dan lokasi signifikan untuk lag pertama saja.

**Tabel 4.11.** Estimasi Parameter GSTARX *Inflow* Rp50.000 Bobot Seragam

Wilayah	Parameter	Koefisien	SE	t-value	p-value
Surabaya	$\phi_{10}^1$	0,245	0,068	3,590	0,0004
	$\phi_{11}^1$	-0,099	0,064	-1,539	0,125
	$\phi_{10}^2$	0,216	0,068	3,170	0,002
	$\phi_{11}^2$	-0,014	0,064	-0,214	0,831
Semarang	$\phi_{20}^1$	0,086	0,067	1,300	0,195
	$\phi_{21}^1$	-0,098	0,056	-1,749	0,082
	$\phi_{20}^2$	0,155	0,065	2,364	0,019
	$\phi_{21}^2$	0,0004	0,056	0,007	0,994
Yogyakarta	$\phi_{30}^1$	0,195	0,066	2,942	0,004
	$\phi_{31}^1$	-0,017	0,023	-0,719	0,473
	$\phi_{30}^2$	0,149	0,066	2,248	0,026
	$\phi_{31}^2$	0,033	0,023	1,424	0,156
Bandung	$\phi_{40}^1$	0,209	0,067	3,119	0,002
	$\phi_{41}^1$	-0,156	0,078	-2,012	0,045
	$\phi_{40}^2$	0,133	0,069	1,915	0,057
	$\phi_{41}^2$	-0,015	0,076	-0,204	0,839
Jakarta	$\phi_{50}^1$	0,271	0,071	3,792	$\approx 0,000$
	$\phi_{51}^1$	-0,608	0,288	-2,109	0,036
	$\phi_{50}^2$	0,356	0,070	5,200	$\approx 0,000$
	$\phi_{51}^2$	-0,399	0,289	-1,379	0,169

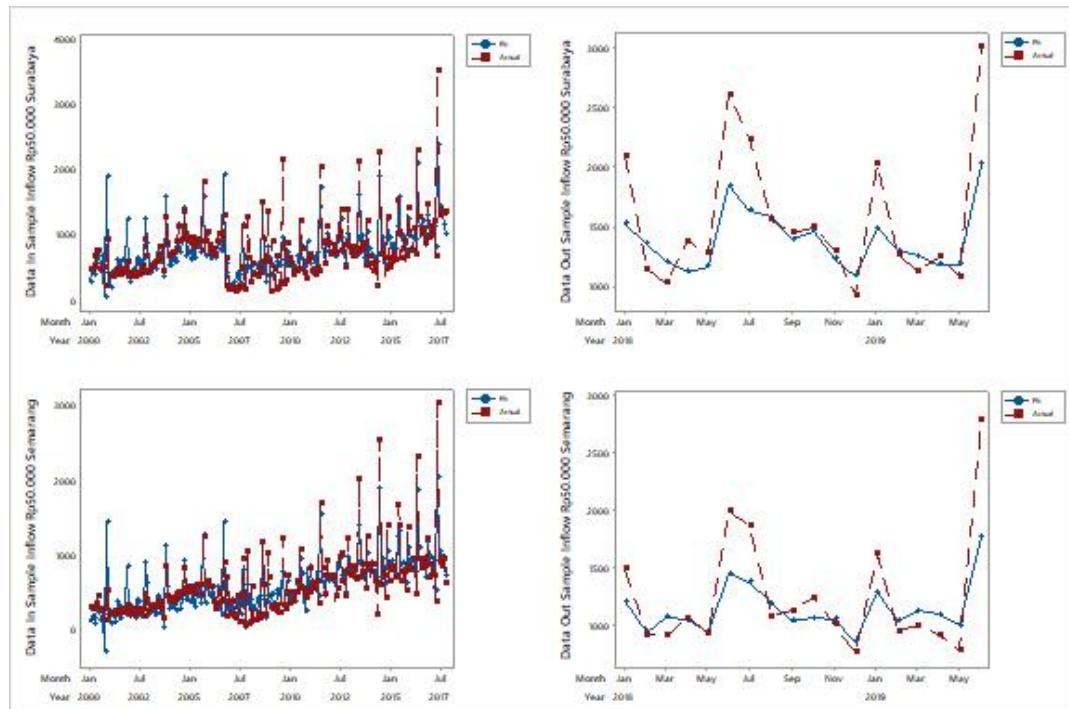
Persamaan model GSTARX *inflow* Rp50.000 dengan bobot normalisasi korelasi silang adalah sebagai berikut

$$\begin{aligned}
 \begin{pmatrix} \hat{Z}_{1,t}^2 \\ \hat{Z}_{2,t}^2 \\ \hat{Z}_{3,t}^2 \\ \hat{Z}_{4,t}^2 \\ \hat{Z}_{5,t}^2 \end{pmatrix} &= \begin{pmatrix} 3,13 & 0 & 0 & 0 & 0 \\ 0 & 3,81 & 0 & 0 & 0 \\ 0 & 0 & 1,79 & 0 & 0 \\ 0 & 0 & 0 & 7,85 & 0 \\ 0 & 0 & 0 & 0 & 10,67 \end{pmatrix} \begin{pmatrix} t_{1,t}^2 \\ t_{2,t}^2 \\ t_{3,t}^2 \\ t_{4,t}^2 \\ t_{5,t}^2 \end{pmatrix} + \begin{pmatrix} -611,79 & 0 & 0 & 0 & 0 \\ 0 & -388,90 & 0 & 0 & 0 \\ 0 & 0 & -182,57 & 0 & 0 \\ 0 & 0 & 0 & -1108,56 & 0 \\ 0 & 0 & 0 & 0 & -2106 \end{pmatrix} \begin{pmatrix} (D_1)_{1,t}^2 \\ (D_1)_{2,t}^2 \\ (D_1)_{3,t}^2 \\ (D_1)_{4,t}^2 \\ (D_1)_{5,t}^2 \end{pmatrix} + \dots + \\
 &\quad \begin{pmatrix} 690,85 & 0 & 0 & 0 & 0 \\ 0 & 365,40 & 0 & 0 & 0 \\ 0 & 0 & 269,15 & 0 & 0 \\ 0 & 0 & 0 & 540,61 & 0 \\ 0 & 0 & 0 & 0 & 2566,10 \end{pmatrix} \begin{pmatrix} (S_1)_{1,t}^2 \\ (S_1)_{2,t}^2 \\ (S_1)_{3,t}^2 \\ (S_1)_{4,t}^2 \\ (S_1)_{5,t}^2 \end{pmatrix} + \dots + \begin{pmatrix} 922,47 & 0 & 0 & 0 & 0 \\ 0 & 829,81 & 0 & 0 & 0 \\ 0 & 0 & 380,29 & 0 & 0 \\ 0 & 0 & 0 & 1180,42 & 0 \\ 0 & 0 & 0 & 0 & 3225,82 \end{pmatrix} \begin{pmatrix} (CV_{1,t})_{1,t}^2 \\ (CV_{1,t})_{2,t}^2 \\ (CV_{1,t})_{3,t}^2 \\ (CV_{1,t})_{4,t}^2 \\ (CV_{1,t})_{5,t}^2 \end{pmatrix} + \dots + \\
 &\quad \begin{pmatrix} 128,31 & 0 & 0 & 0 & 0 \\ 0 & 139,55 & 0 & 0 & 0 \\ 0 & 0 & 33,22 & 0 & 0 \\ 0 & 0 & 0 & 110,20 & 0 \\ 0 & 0 & 0 & 0 & 274,14 \end{pmatrix} \begin{pmatrix} (CV_{1,t+1})_{1,t}^2 \\ (CV_{1,t+1})_{2,t}^2 \\ (CV_{1,t+1})_{3,t}^2 \\ (CV_{1,t+1})_{4,t}^2 \\ (CV_{1,t+1})_{5,t}^2 \end{pmatrix} + \dots + \begin{pmatrix} \varepsilon_{1,t}^2 \\ \varepsilon_{2,t}^2 \\ \varepsilon_{3,t}^2 \\ \varepsilon_{4,t}^2 \\ \varepsilon_{5,t}^2 \end{pmatrix}
 \end{aligned}$$

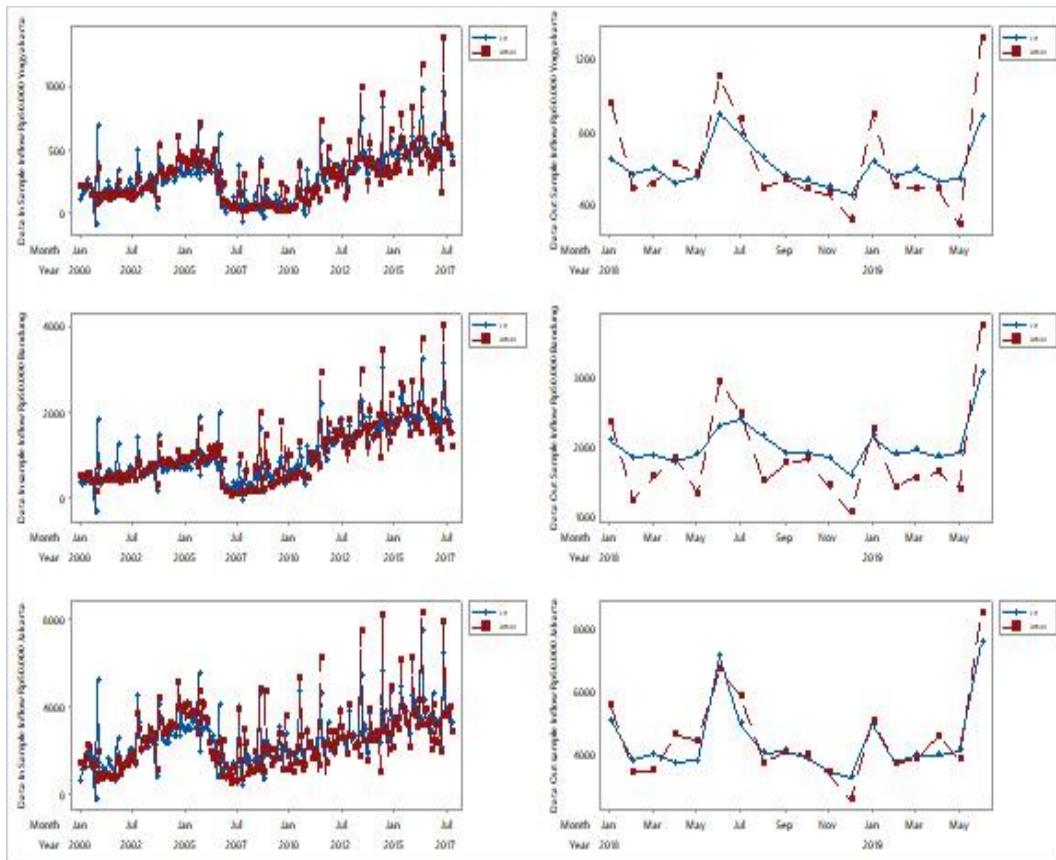
dengan

$$\begin{bmatrix} \hat{\varepsilon}_{1,t}^2 \\ \hat{\varepsilon}_{2,t}^2 \\ \hat{\varepsilon}_{3,t}^2 \\ \hat{\varepsilon}_{4,t}^2 \\ \hat{\varepsilon}_{5,t}^2 \end{bmatrix} = \begin{bmatrix} 0,245 & -0,02475 & -0,02475 & -0,02475 & -0,02475 \\ -0,0245 & 0,086 & -0,0245 & -0,0245 & -0,0245 \\ -0,00425 & -0,00425 & 0,195 & -0,00425 & -0,00425 \\ -0,039 & -0,039 & -0,039 & 0,209 & -0,039 \\ -0,152 & -0,152 & -0,152 & -0,152 & 0,271 \end{bmatrix} \begin{bmatrix} \varepsilon_{1,t-1}^2 \\ \varepsilon_{2,t-1}^2 \\ \varepsilon_{3,t-1}^2 \\ \varepsilon_{4,t-1}^2 \\ \varepsilon_{5,t-1}^2 \end{bmatrix} + \\ \begin{bmatrix} 0,216 & -0,0035 & -0,0035 & -0,0035 & -0,0035 \\ 0,0001 & 0,155 & 0,0001 & 0,0001 & 0,0001 \\ 0,00825 & 0,00825 & 0,149 & 0,00825 & 0,00825 \\ -0,00375 & -0,00375 & -0,00375 & 0,133 & -0,00375 \\ -0,09975 & -0,09975 & -0,09975 & -0,09975 & 0,356 \end{bmatrix} \begin{bmatrix} \varepsilon_{1,t-2}^2 \\ \varepsilon_{2,t-2}^2 \\ \varepsilon_{3,t-2}^2 \\ \varepsilon_{4,t-2}^2 \\ \varepsilon_{5,t-2}^2 \end{bmatrix} + \begin{bmatrix} a_{1,t}^2 \\ a_{2,t}^2 \\ a_{3,t}^2 \\ a_{4,t}^2 \\ a_{5,t}^2 \end{bmatrix}$$

Pada Gambar 4.17 ditunjukkan perbandingan data prediksi dengan data aktual *inflow* Rp50.000 KPw Bank Sentral di Jawa. Berdasarkan plot data diketahui data prediksi model GSTARX *inflow* Rp50.000 dengan bobot seragam mampu menangkap pola data aktual yang mencakup komponen tren, musiman, variasi kalender dan mengandung efek spasial. Tetapi seperti pada model-model sebelumnya, data prediksi belum sepenuhnya mengikuti pola dengan tepat.



**Gambar 4.17.** Perbandingan Data Aktual *Inflow* Rp50.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX dengan Bobot Seragam *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.17.** Perbandingan Data Aktual *Inflow* Rp50.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX dengan Bobot Seragam *in sample* (kiri) dan *out sample* (kanan) (lanjutan)

#### 4.5.3 Pemodelan GSTARX Pecahan Rp20.000

Estimasi parameter model GSTARX *inflow* Rp20.000 yang ditunjukkan pada Tabel 4.12 signifikan untuk parameter waktu lag pertama saja pada wilayah Yogyakarta dan Jakarta. Pada wilayah Surabaya hanya parameter lokasi untuk lag kedua tidak signifikan sedangkan wilayah Semarang hanya parameter lokasi lag kedua yang tidak signifikan untuk ketiga parameter lainnya signifikan pada taraf signifikansi 5%. Parameter waktu baik lag pertama maupun lag kedua pada wilayah Bandung signifikan sedangkan kedua parameter lokasinya tidak signifikan.

**Tabel 4.12.** Estimasi Parameter GSTARX *Inflow* Rp20.000 Bobot Seragam

Wilayah	Parameter	Koefisien	SE	t-value	p-value
Surabaya	$\phi_{10}^1$	0,331	0,060	5,497	$\approx 0,000$
	$\phi_{11}^1$	0,155	0,068	2,296	0,023
	$\phi_{10}^2$	0,173	0,058	2,965	0,003
	$\phi_{11}^2$	-0,068	0,060	-1,118	0,265
Semarang	$\phi_{20}^1$	0,364	0,064	5,695	$\approx 0,000$
	$\phi_{21}^1$	0,103	0,042	2,444	0,015
	$\phi_{20}^2$	0,122	0,059	2,057	0,041
	$\phi_{21}^2$	0,060	0,037	1,644	0,102
Yogyakarta	$\phi_{30}^1$	0,356	0,066	5,392	$\approx 0,000$
	$\phi_{31}^1$	0,037	0,031	1,198	0,232
	$\phi_{30}^2$	0,118	0,067	1,772	0,078
	$\phi_{31}^2$	0,040	0,030	1,363	0,174
Bandung	$\phi_{40}^1$	0,522	0,068	7,625	$\approx 0,000$
	$\phi_{41}^1$	0,017	0,075	0,230	0,818
	$\phi_{40}^2$	0,226	0,067	3,341	0,001
	$\phi_{41}^2$	0,006	0,073	0,078	0,938
Jakarta	$\phi_{50}^1$	0,438	0,072	6,045	$\approx 0,000$
	$\phi_{51}^1$	0,033	0,286	0,116	0,908
	$\phi_{50}^2$	0,084	0,067	1,267	0,207
	$\phi_{51}^2$	0,373	0,278	1,341	0,181

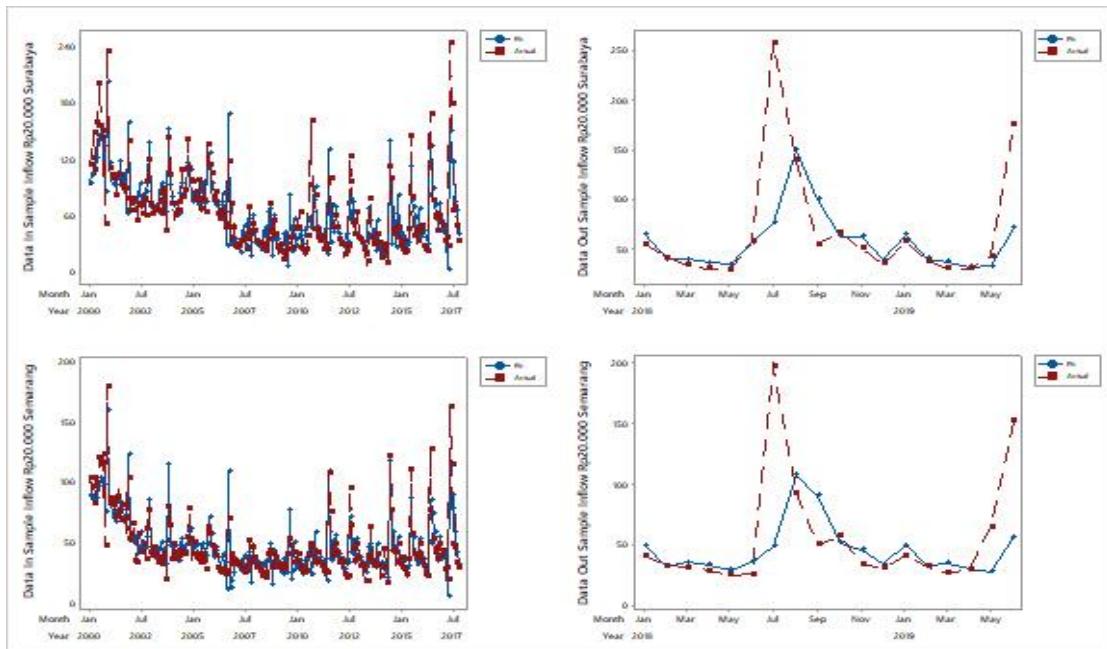
Persamaan model GSTARX *inflow* Rp20.000 dengan bobot lokasi seragam dapat ditulis sebagai berikut

$$\begin{aligned}
 \begin{pmatrix} \hat{Z}_{1,t}^3 \\ \hat{Z}_{2,t}^3 \\ \hat{Z}_{3,t}^3 \\ \hat{Z}_{4,t}^3 \\ \hat{Z}_{5,t}^3 \end{pmatrix} &= \begin{pmatrix} -0,23 & 0 & 0 & 0 & 0 \\ 0 & -0,12 & 0 & 0 & 0 \\ 0 & 0 & -0,18 & 0 & 0 \\ 0 & 0 & 0 & -0,25 & 0 \\ 0 & 0 & 0 & 0 & -0,82 \end{pmatrix} \begin{pmatrix} t_{1,t}^3 \\ t_{2,t}^3 \\ t_{3,t}^3 \\ t_{4,t}^3 \\ t_{5,t}^3 \end{pmatrix} + \begin{pmatrix} -89,40 & 0 & 0 & 0 & 0 \\ 0 & -36,63 & 0 & 0 & 0 \\ 0 & 0 & -42,82 & 0 & 0 \\ 0 & 0 & 0 & -124,79 & 0 \\ 0 & 0 & 0 & 0 & -213,83 \end{pmatrix} \begin{pmatrix} (D_1)_{1,t}^3 \\ (D_1)_{2,t}^3 \\ (D_1)_{3,t}^3 \\ (D_1)_{4,t}^3 \\ (D_1)_{5,t}^3 \end{pmatrix} + \dots + \\
 &\quad \begin{pmatrix} 115,85 & 0 & 0 & 0 & 0 \\ 0 & 73,36 & 0 & 0 & 0 \\ 0 & 0 & 62,77 & 0 & 0 \\ 0 & 0 & 0 & 137,74 & 0 \\ 0 & 0 & 0 & 0 & 352,38 \end{pmatrix} \begin{pmatrix} (S_1)_{1,t}^3 \\ (S_1)_{2,t}^3 \\ (S_1)_{3,t}^3 \\ (S_1)_{4,t}^3 \\ (S_1)_{5,t}^3 \end{pmatrix} + \dots + \begin{pmatrix} 34,68 & 0 & 0 & 0 & 0 \\ 0 & 16,61 & 0 & 0 & 0 \\ 0 & 0 & 12,74 & 0 & 0 \\ 0 & 0 & 0 & 33,20 & 0 \\ 0 & 0 & 0 & 0 & 170,35 \end{pmatrix} \begin{pmatrix} (CV_{1,t})_{1,t}^3 \\ (CV_{1,t})_{2,t}^3 \\ (CV_{1,t})_{3,t}^3 \\ (CV_{1,t})_{4,t}^3 \\ (CV_{1,t})_{5,t}^3 \end{pmatrix} + \dots + \\
 &\quad \begin{pmatrix} 45,50 & 0 & 0 & 0 & 0 \\ 0 & 28,16 & 0 & 0 & 0 \\ 0 & 0 & 13,03 & 0 & 0 \\ 0 & 0 & 0 & 23,05 & 0 \\ 0 & 0 & 0 & 0 & 91,86 \end{pmatrix} \begin{pmatrix} (CV_{1,t+1})_{1,t}^3 \\ (CV_{1,t+1})_{2,t}^3 \\ (CV_{1,t+1})_{3,t}^3 \\ (CV_{1,t+1})_{4,t}^3 \\ (CV_{1,t+1})_{5,t}^3 \end{pmatrix} + \dots + \begin{pmatrix} \varepsilon_{1,t}^3 \\ \varepsilon_{2,t}^3 \\ \varepsilon_{3,t}^3 \\ \varepsilon_{4,t}^3 \\ \varepsilon_{5,t}^3 \end{pmatrix}
 \end{aligned}$$

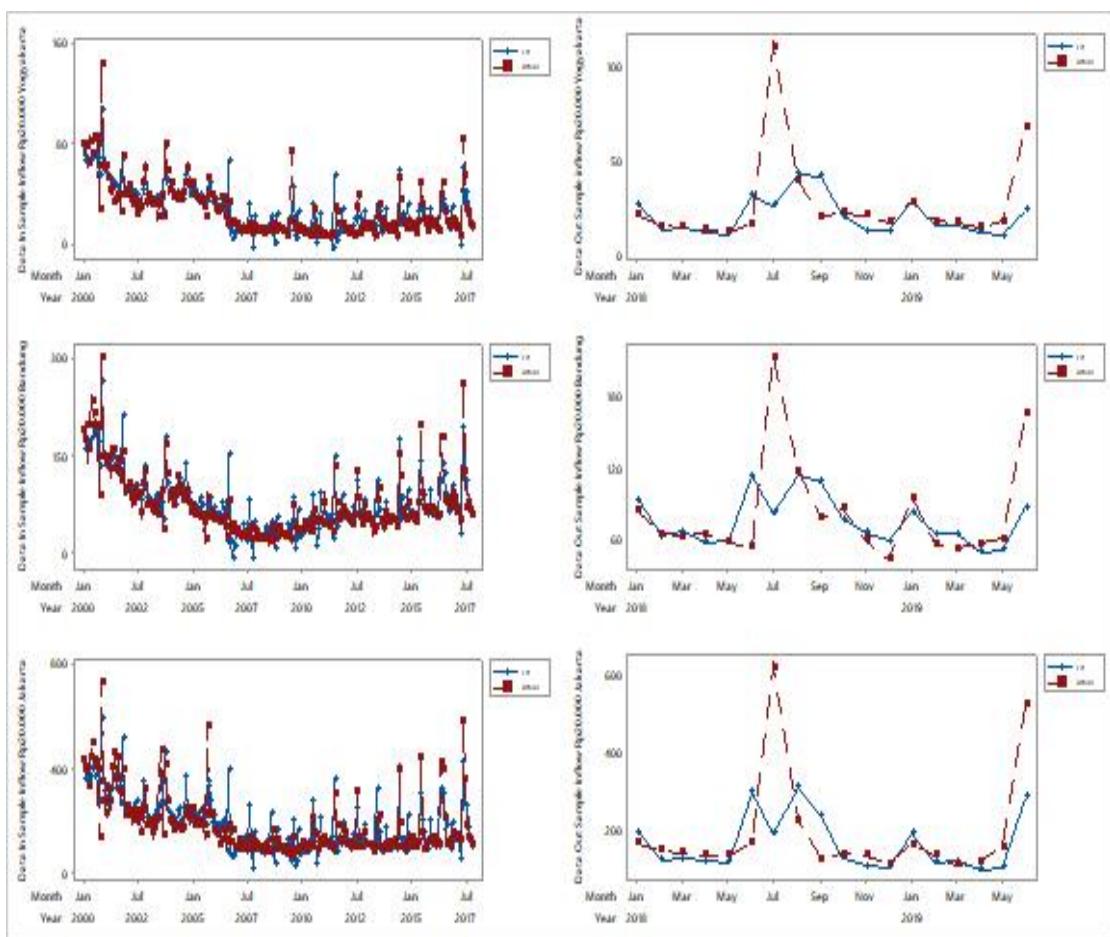
dengan

$$\begin{bmatrix} \hat{\varepsilon}_{1,t}^3 \\ \hat{\varepsilon}_{2,t}^3 \\ \hat{\varepsilon}_{3,t}^3 \\ \hat{\varepsilon}_{4,t}^3 \\ \hat{\varepsilon}_{5,t}^3 \end{bmatrix} = \begin{bmatrix} 0,331 & 0,03875 & 0,03875 & 0,03875 & 0,03875 \\ 0,02575 & 0,364 & 0,02575 & 0,02575 & 0,02575 \\ 0,00925 & 0,00925 & 0,356 & 0,00925 & 0,00925 \\ 0,00425 & 0,00425 & 0,00425 & 0,522 & 0,00435 \\ 0,00825 & 0,00825 & 0,00825 & 0,00825 & 0,438 \end{bmatrix} \begin{bmatrix} \varepsilon_{1,t-1}^3 \\ \varepsilon_{2,t-1}^3 \\ \varepsilon_{3,t-1}^3 \\ \varepsilon_{4,t-1}^3 \\ \varepsilon_{5,t-1}^3 \end{bmatrix} + \\ \begin{bmatrix} 0,173 & -0,017 & -0,017 & -0,017 & -0,017 \\ 0,015 & 0,122 & 0,015 & 0,015 & 0,015 \\ 0,01 & 0,01 & 0,118 & 0,01 & 0,01 \\ 0,0015 & 0,0015 & 0,0015 & 0,226 & 0,0015 \\ 0,09325 & 0,09325 & 0,09325 & 0,09325 & 0,084 \end{bmatrix} \begin{bmatrix} \varepsilon_{1,t-2}^3 \\ \varepsilon_{2,t-2}^3 \\ \varepsilon_{3,t-2}^3 \\ \varepsilon_{4,t-2}^3 \\ \varepsilon_{5,t-2}^3 \end{bmatrix} + \begin{bmatrix} a_{1,t}^3 \\ a_{2,t}^3 \\ a_{3,t}^3 \\ a_{4,t}^3 \\ a_{5,t}^3 \end{bmatrix}$$

Berdasarkan model GSTARX *inflow* Rp20.000 dengan yang diperoleh maka plot data perbandingan prediksi dengan data aktual ditunjukkan pada Gambar 4.18.



**Gambar 4.18.** Perbandingan Data Aktual *Inflow* Rp20.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX dengan Bobot Seragam *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.18.** Perbandingan Data Aktual *Inflow* Rp20.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX dengan Bobot Seragam *in sample* (kiri) dan *out sample* (lanjutan)

Pola komponen tren, musiman, dan varisai kalender pada data *inflow* Rp20.000 dapat ditangkap dengan model TSR dan efek spasial dapat diwakili dengan model GSTAR. Sehingga plot data prediksi model GSTARX *inflow* Rp20.000 dengan bobot seragam mampu mengikuti pola data aktual. Terlihat pada plot data *out sample* beberapa data prediksi memiliki selisih relatif kecil dengan data aktual meskipun belum sepenuhnya tepat terutama pada titik-titik tertinggi data.

#### 4.6 Pemodelan GSTARX-ERNN Data *Inflow* dan *Outflow* UPB di KPw Bank Sentral di Pulau Jawa

Pemodelan GSTARX-ERNN merupakan pemodelan *hybrid* antara model GSTARX dengan model *Elman Recurrent Neural Network* (ERNN). Model GSTARX-ERNN memiliki *context layer* yang berfungsi menyimpan kembali

memori jaringan dari *hidden layer* yang selanjutnya diproses kembali menuju *hidden layer* sebelum keluar sebagai output. Jumlah neuron pada *context layer* sama dengan jumlah neuron pada *hidden layer*.

Model GSTARX-ERNN dapat digunakan untuk data yang diduga memiliki komponen residual dengan pola linier dan nonlinier. Pemodelan ini dilakukan dengan dua tahap, pertama memodelkan data dengan model TSR. Tahap kedua memodelkan residual TSR menggunakan model ERNN dengan input residual model TSR dan residual model TSR yang telah diboboti dengan bobot GSTAR. Bobot GSTAR yang digunakan yaitu bobot seragam, invers jarak, dan normalisasi korelasi silang.

Pada model GSTARX-ERNN jumlah *neuron* yang digunakan pada *hidden layer* adalah 1, 2, 3, 4, 5, 10, dan 15 serta menggunakan fungsi aktivasi *tangent hyperbolic* untuk *hidden layer* dan fungsi aktivasi linier pada *output layer*. Jumlah input yang digunakan disesuaikan dengan model GSTARX yang telah ditentukan pada data *inflow* dan *outflow* setiap UPB. Sebelum melakukan pemodelan GSTARX-ERNN, akan dilakukan pengujian linieritas menggunakan uji Terasvirta terlebih dahulu. Hasil uji Terasvirta pada data *inflow* dan *outflow* UPB KPw Bank Sentral di Jawa diberikan pada Tabel 4.13 dan 4.14.

**Tabel 4.13.** Hasil Uji Terasvirta Data *Inflow* UPB KPw Bank Sentral di Pulau Jawa

Lokasi	Data	<i>Lag Input</i>	<i>F-value</i>	<i>df<sub>1</sub></i>	<i>df<sub>2</sub></i>	<i>p-value</i>	Keterangan
Surabaya	Rp100.000	1,2	1,066	7	223	0,387	Linier
	Rp50.000	1,2	3,001	7	223	0,005	Nonlinier
	Rp20.000	1,2	1,234	7	223	0,285	Linier
Semarang	Rp100.000	1,2	1,745	7	223	0,099	Linier
	Rp50.000	1,2	0,204	7	223	0,985	Linier
	Rp20.000	1,2	13,292	7	223	≈0,000	Nonlinier
Yogyakarta	Rp100.000	1,2	6,313	7	223	≈0,000	Nonlinier
	Rp50.000	1,2	1,173	7	223	0,319	Linier
	Rp20.000	1,2	5,963	7	223	≈0,000	Nonlinier
Bandung	Rp100.000	1,2	3,053	7	223	0,004	Nonlinier
	Rp50.000	1,2	2,481	7	223	0,018	Nonlinier
	Rp20.000	1,2	2,807	7	223	0,008	Nonlinier
Jakarta	Rp100.000	1,2	1,914	7	223	0,068	Linier
	Rp50.000	1,2	0,454	7	223	0,867	Linier
	Rp20.000	1,2	4,5783	7	223	≈0,000	Nonlinier

**Tabel 4.14.**Hasil Uji Terasvirta Data *Outflow* UPB KPw Bank Sentral di Pulau Jawa

Lokasi	Data	<i>Lag Input</i>	<i>F-value</i>	<i>df<sub>1</sub></i>	<i>df<sub>2</sub></i>	<i>p-value</i>	Keterangan
Surabaya	Rp100.000	1,2	3,348	7	223	0,002	Nonlinier
	Rp50.000	1,2	2,864	7	223	0,007	Nonlinier
	Rp20.000	1,2	3,418	7	223	0,002	Nonlinier
Semarang	Rp100.000	1,2	3,089	7	223	0,004	Nonlinier
	Rp50.000	1,2	3,536	7	223	0,001	Nonlinier
	Rp20.000	1,2	3,261	7	223	0,003	Nonlinier
Yogyakarta	Rp100.000	1,2	6,308	7	223	≈0,000	Nonlinier
	Rp50.000	1,2	4,336	7	223	0,0001	Nonlinier
	Rp20.000	1,2	3,127	7	223	0,004	Nonlinier
Bandung	Rp100.000	1,2	0,873	7	223	0,529	Linier
	Rp50.000	1,2	2,390	7	223	0,022	Nonlinier
	Rp20.000	1,2	4,592	7	223	≈0,000	Nonlinier
Jakarta	Rp100.000	1,2	1,709	7	223	0,108	Linier
	Rp50.000	1,2	4,584	7	223	≈0,000	Nonlinier
	Rp20.000	1,2	1,972	7	223	0,060	Nonlinier

Hasil pengujian linieritas menunjukkan bahwa *inflow* setiap pecahan KPw Bandung nonlinier terhadap lag 1 dan 2. Pada KPw Semarang dan Jakarta hanya pecahan Rp20.000 yang nonlinier sedangkan KPw Surabaya hanya pecahan Rp50.000 yang nonlinier. *Inflow* KPw Yogyakarta nonlinier pada pecahan Rp100.000 dan Rp20.000. Untuk data *outflow* setiap pecahan dari semua lokasi nonlinier kecuali pecahan Rp100.000 di KPw Bandung dan Jakarta.

#### 4.6.1 Pemodelan GSTARX-ERNN pecahan Rp100.000

Model GSTARX untuk *inflow* dan *outflow* pecahan Rp100.000 yaitu GSTARX (2<sub>1</sub>) sehingga input yang digunakan pada pemodelan GSTARX-ERNN *inflow* maupun *outflow* Rp100.000 adalah residual TSR *lag* 1 dan 2 serta residual TSR *lag* 1 dan 2 yang diboboti pada proses GSTAR dari kelima lokasi. Pemodelan GSTARX-ERNN dilakukan dengan mengkombinasikan jumlah neuron di *hidden layer* dengan jenis bobot GSTAR yang digunakan. Pemilihan bobot dan jumlah neuron terbaik dilakukan berdasarkan nilai rata-rata RMSE dan sMAPE terkecil. Hasil perhitungan rata-rata RMSE dan sMAPE untuk *inflow* pecahan Rp100.000 ditunjukkan pada Tabel 4.15 dan 4.16.

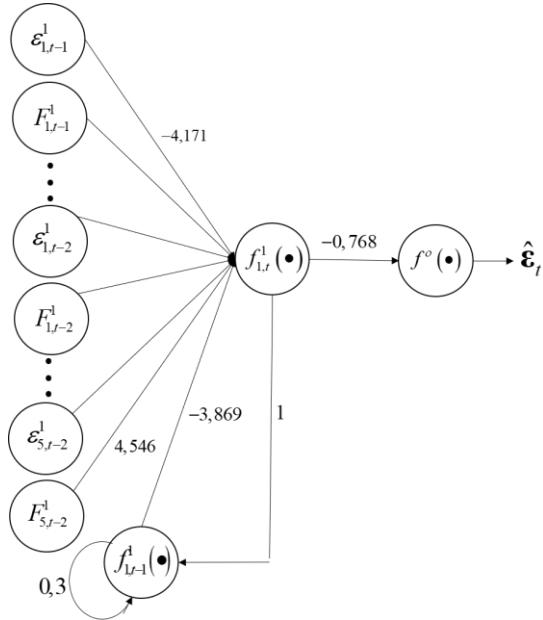
**Tabel 4.15.** Nilai rata-rata RMSE Model GSTARX-ERNN *Inflow* Rp100.000 KPw Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	RMSE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-ERNN(20,1,1)	470,593	1107,597
	GSTARX-ERNN(20,2,1)	434,125	1054,239
	GSTARX-ERNN(20,3,1)	417,261	1297,3
	GSTARX-ERNN(20,4,1)	398,562	1301,506
	GSTARX-ERNN(20,5,1)	384,574	1167,565
	GSTARX-ERNN(20,10,1)	345,195	1662,635
	GSTARX-ERNN(20,15,1)	325,371	1482,365
	GSTARX-ERNN(20,1,1)	466,441	1101,798
Invers Jarak	GSTARX-ERNN(20,2,1)	435,848	1041,735
	GSTARX-ERNN(20,3,1)	408,410	1255,233
	GSTARX-ERNN(20,4,1)	423,835	1325,811
	GSTARX-ERNN(20,5,1)	380,419	1251,913
	GSTARX-ERNN(20,10,1)	360,583	1744,352
	GSTARX-ERNN(20,15,1)	327,552	1916,397
	GSTARX-ERNN(20,1,1)	466,807	1095,677
	GSTARX-ERNN(20,2,1)	441,875	1224,498
Korelasi Silang	GSTARX-ERNN(20,3,1)	445,019	1156,232
	GSTARX-ERNN(20,4,1)	422,717	1384,132
	GSTARX-ERNN(20,5,1)	387,112	1504,592
	GSTARX-ERNN(20,10,1)	356,530	1805,14
	GSTARX-ERNN(20,15,1)	298,798	1685,068
	GSTARX-ERNN(20,1,1)	44,250%	27,387%
	GSTARX-ERNN(20,2,1)	46,042%	26,472%
	GSTARX-ERNN(20,3,1)	46,294%	31,867%

**Tabel 4.16.** Nilai Rata-Rata sMAPE Model GSTARX-ERNN *Inflow* Rp100.000 KPw Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	sMAPE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-ERNN(20,1,1)	44,250%	27,387%
	GSTARX-ERNN(20,2,1)	46,042%	26,472%
	GSTARX-ERNN(20,3,1)	46,294%	31,867%
	GSTARX-ERNN(20,4,1)	45,583%	32,253%
	GSTARX-ERNN(20,5,1)	43,823%	30,042%
	GSTARX-ERNN(20,10,1)	39,520%	59,635%
	GSTARX-ERNN(20,15,1)	40,717%	43,858%
	GSTARX-ERNN(20,1,1)	44,201%	27,858%
Invers Jarak	GSTARX-ERNN(20,2,1)	45,460%	27,330%
	GSTARX-ERNN(20,3,1)	44,505%	38,211%
	GSTARX-ERNN(20,4,1)	43,282%	42,485%
	GSTARX-ERNN(20,5,1)	43,609%	44,256%
	GSTARX-ERNN(20,10,1)	41,553%	58,257%
	GSTARX-ERNN(20,15,1)	38,387%	51,838%
	GSTARX-ERNN(20,1,1)	46,322%	26,557%
	GSTARX-ERNN(20,2,1)	43,864%	31,873%
Korelasi Silang	GSTARX-ERNN(20,3,1)	43,940%	29,366%
	GSTARX-ERNN(20,4,1)	48,974%	39,521%
	GSTARX-ERNN(20,5,1)	44,340%	47,864%
	GSTARX-ERNN(20,10,1)	38,817%	40,384%
	GSTARX-ERNN(20,15,1)	37,268%	50,109%

Berdasarkan Tabel diketahui bahwa model GSTARX-ERNN terbaik untuk memodelkan *inflow* Rp100.000 KPw Bank Sentral Provinsi di Pulau Jawa adalah model GSTARX-ERNN(20,1,1) dengan bobot korelasi silang. Arsitektur model GSTARX-ERNN(20,1,1) ditunjukkan pada Gambar 4.19.



**Gambar 4.19.** Arsitektur Model GSTARX-ERNN *Inflow* Rp100.000

Hasil estimasi parameter model GSTARX-ERNN(20,1,1) *inflow* Rp100.000 dengan bobot korelasi silang dapat dituliskan menjadi persamaan sebagai berikut.

$$\begin{aligned} \hat{Z}_{1,t}^1 &= \begin{pmatrix} 9,36 & 0 & 0 & 0 & 0 \\ 0 & 8,26 & 0 & 0 & 0 \\ 0 & 0 & 3,46 & 0 & 0 \\ 0 & 0 & 0 & 13,51 & 0 \\ 0 & 0 & 0 & 0 & 23,05 \end{pmatrix} \begin{pmatrix} t_{1,t}^1 \\ t_{2,t}^1 \\ t_{3,t}^1 \\ t_{4,t}^1 \\ t_{5,t}^1 \end{pmatrix} + \begin{pmatrix} -363,33 & 0 & 0 & 0 & 0 \\ 0 & -183,82 & 0 & 0 & 0 \\ 0 & 0 & -112,3 & 0 & 0 \\ 0 & 0 & 0 & -831,72 & 0 \\ 0 & 0 & 0 & 0 & -1550,73 \end{pmatrix} \begin{pmatrix} (D_1)_{1,t}^1 \\ (D_1)_{2,t}^1 \\ (D_1)_{3,t}^1 \\ (D_1)_{4,t}^1 \\ (D_1)_{5,t}^1 \end{pmatrix} + \dots + \\ &\quad \begin{pmatrix} 484,37 & 0 & 0 & 0 & 0 \\ 0 & 199,26 & 0 & 0 & 0 \\ 0 & 0 & 245,70 & 0 & 0 \\ 0 & 0 & 0 & 314,35 & 0 \\ 0 & 0 & 0 & 0 & 1170,89 \end{pmatrix} \begin{pmatrix} (S_1)_{1,t}^1 \\ (S_1)_{2,t}^1 \\ (S_1)_{3,t}^1 \\ (S_1)_{4,t}^1 \\ (S_1)_{5,t}^1 \end{pmatrix} + \dots + \begin{pmatrix} 1257,51 & 0 & 0 & 0 & 0 \\ 0 & 1289,27 & 0 & 0 & 0 \\ 0 & 0 & 612,1 & 0 & 0 \\ 0 & 0 & 0 & 1542,23 & 0 \\ 0 & 0 & 0 & 0 & 3916,27 \end{pmatrix} \begin{pmatrix} (CV_{1,t})_{1,t}^1 \\ (CV_{1,t})_{2,t}^1 \\ (CV_{1,t})_{3,t}^1 \\ (CV_{1,t})_{4,t}^1 \\ (CV_{1,t})_{5,t}^1 \end{pmatrix} + \dots + \\ &\quad \begin{pmatrix} 119,56 & 0 & 0 & 0 & 0 \\ 0 & 56,30 & 0 & 0 & 0 \\ 0 & 0 & 0,06 & 0 & 0 \\ 0 & 0 & 0 & 59,44 & 0 \\ 0 & 0 & 0 & 0 & 111,38 \end{pmatrix} \begin{pmatrix} (CV_{1,t+1})_{1,t}^1 \\ (CV_{1,t+1})_{2,t}^1 \\ (CV_{1,t+1})_{3,t}^1 \\ (CV_{1,t+1})_{4,t}^1 \\ (CV_{1,t+1})_{5,t}^1 \end{pmatrix} \end{aligned}$$

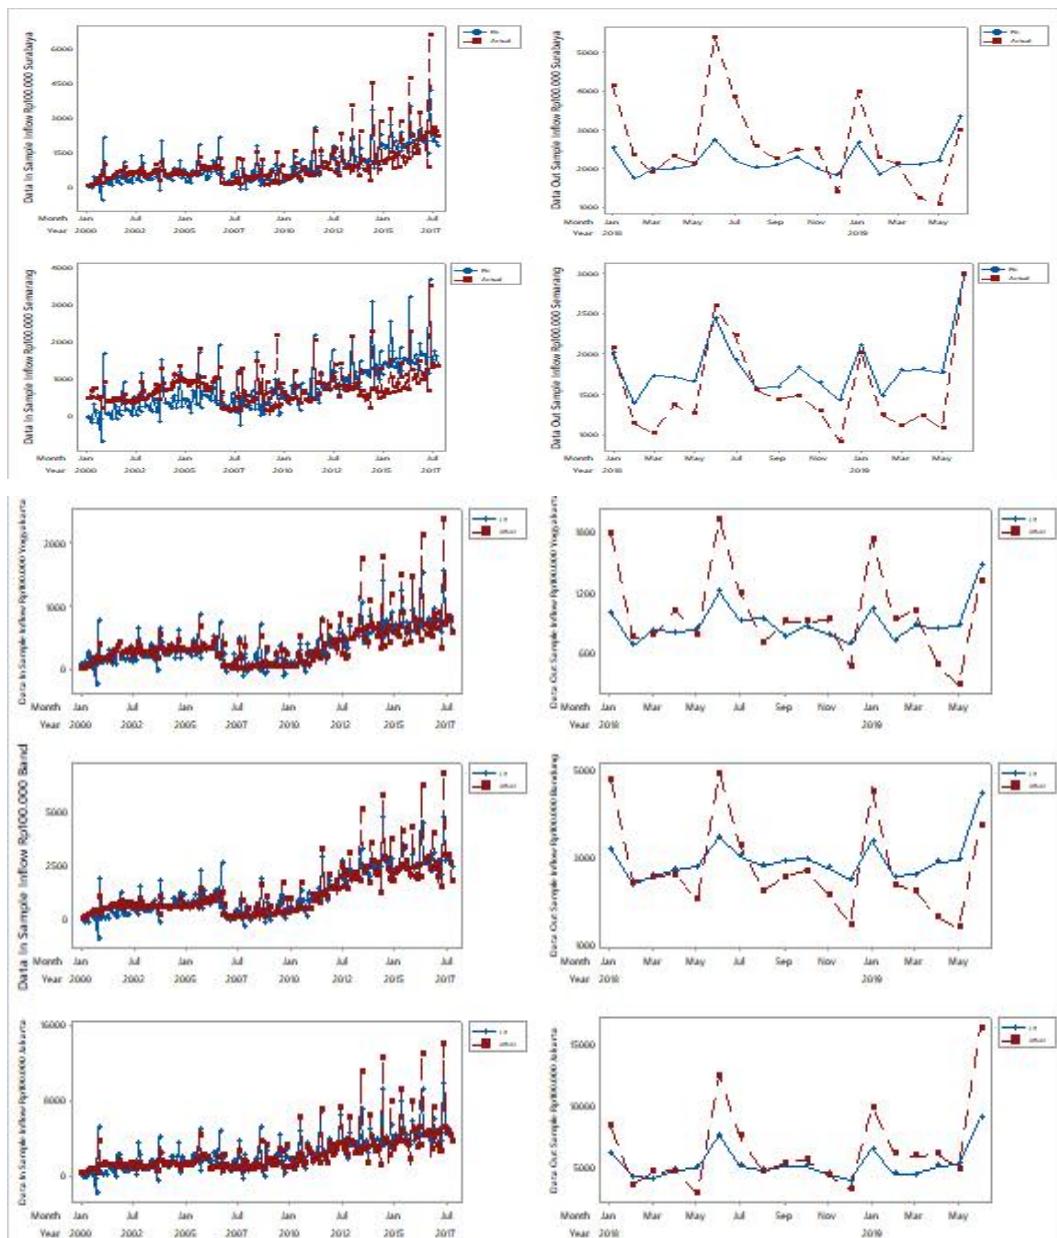
dengan

$$\hat{\epsilon}_t = -0,768 \times \tanh f_{1,t}^1(\bullet)$$

dan

$$\begin{aligned}
f_{1,t}^1(\bullet) = & -4,171\epsilon_{1,t-1}^1 + 3,297\epsilon_{2,t-1}^1 + 2,854\epsilon_{3,t-1}^1 + 3,986\epsilon_{4,t-1}^1 + 4,588\epsilon_{5,t-1}^1 + 13,368F_{1,t-1}^1 + \\
& 7,365F_{2,t-1}^1 + 6,341F_{3,t-1}^1 + 1,756F_{4,t-1}^1 + 1,771F_{5,t-1}^1 + 3,407\epsilon_{1,t-2}^1 + \\
& 0,286\epsilon_{2,t-2}^1 + 1,662\epsilon_{3,t-2}^1 - 1,265\epsilon_{4,t-2}^1 - 2,461\epsilon_{5,t-2}^1 - 1,577F_{1,t-2}^1 + \\
& 1,389F_{2,t-2}^1 - 3,908F_{3,t-2}^1 + 5,797F_{4,t-2}^1 + 4,546F_{5,t-2}^1 - 3,869f_{1,t-1}^1(\bullet)
\end{aligned}$$

Selanjutnya plot perbandingan pemodelan GSTARX-ERNN(20,1,1) dengan data aktual *inflow* Rp100.000 KPw Bank Sentral di Pulau Jawa ditampilkan pada Gambar 4.20.



**Gambar 4.20.** Perbandingan Data Aktual *Inflow* Rp100.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX-ERNN(20,1,1) Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan) (lanjutan)

#### 4.6.2 Pemodelan GSTARX-ERNN pecahan Rp50.000

Model GSTARX untuk *inflow* dan *outflow* adalah GSTARX (2<sub>1</sub>) sehingga jumlah input yang digunakan untuk pemodelan GSTARX-ERNN pecahan Rp50.000 sama dengan pemodelan pecahan Rp100.000 yaitu 20 input. Proses pemodelan dilakukan seperti pemodelan pecahan Rp100.000 serta memilih neuron dan bobot terbaik berdasar nilai RMSE dan sMAPE. Berikut ini hasil perhitungan RMSE dan sMAPE Model GSTARX-ERNN *Inflow* Rp50.000.

**Tabel 4.17.** Nilai Rata-Rata RMSE Model GSTARX-ERNN *Inflow* Rp50.000 KPw Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	RMSE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-ERNN(20,1,1)	301,450	402,045
	GSTARX-ERNN(20,2,1)	283,425	380,887
	GSTARX-ERNN(20,3,1)	270,162	412,153
	GSTARX-ERNN(20,4,1)	261,667	396,080
	GSTARX-ERNN(20,5,1)	250,414	427,501
	GSTARX-ERNN(20,10,1)	236,697	579,922
	GSTARX-ERNN(20,15,1)	196,589	775,490
Invers Jarak	GSTARX-ERNN(20,1,1)	300,271	423,332
	GSTARX-ERNN(20,2,1)	282,678	391,113
	GSTARX-ERNN(20,3,1)	263,566	415,247
	GSTARX-ERNN(20,4,1)	262,896	436,048
	GSTARX-ERNN(20,5,1)	253,297	475,470
	GSTARX-ERNN(20,10,1)	219,717	505,578
	GSTARX-ERNN(20,15,1)	189,689	763,627
Korelasi Silang	GSTARX-ERNN(20,1,1)	299,475	384,302
	GSTARX-ERNN(20,2,1)	284,992	369,244
	GSTARX-ERNN(20,3,1)	269,965	375,123
	GSTARX-ERNN(20,4,1)	266,258	380,306
	GSTARX-ERNN(20,5,1)	256,163	393,487
	GSTARX-ERNN(20,10,1)	227,381	474,137
	GSTARX-ERNN(20,15,1)	209,755	701,040

**Tabel 4.18.** Nilai Rata-Rata sMAPE Model GSTARX-ERNN *Inflow* Rp50.000 KPw

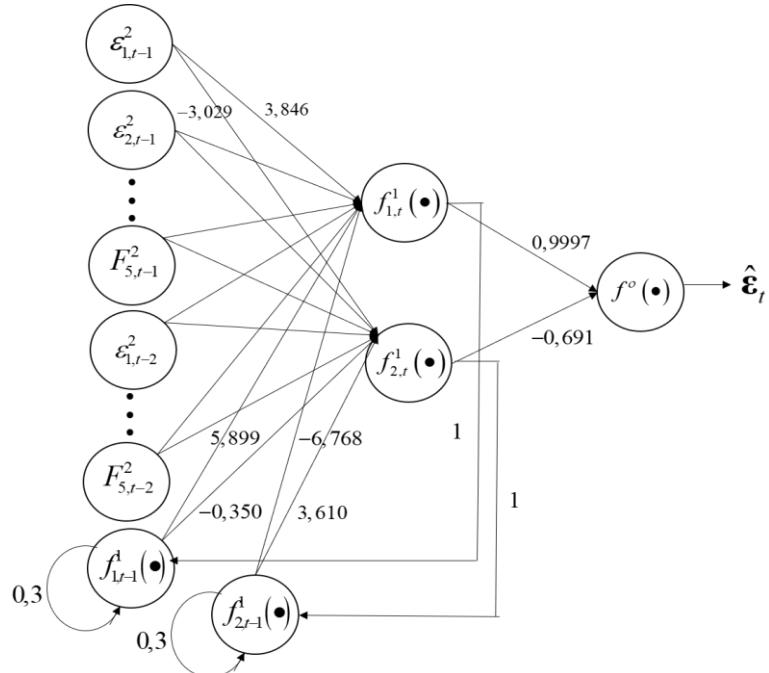
Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	sMAPE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-ERNN(20,1,1)	27,406%	18,004%
	GSTARX-ERNN(20,2,1)	26,920%	17,528%
	GSTARX-ERNN(20,3,1)	25,714%	17,885%
	GSTARX-ERNN(20,4,1)	25,998%	17,328%
	GSTARX-ERNN(20,5,1)	25,556%	19,823%
	GSTARX-ERNN(20,10,1)	24,110%	25,364%
	GSTARX-ERNN(20,15,1)	22,476%	31,285%

**Tabel 4.18.** Nilai Rata-Rata sMAPE Model GSTARX-ERNN *Inflow* Rp50.000 KPw  
Bank Sentral Provinsi di Pulau Jawa (lanjutan)

Bobot	Model	sMAPE	
		<i>In Sample</i>	<i>Out Sample</i>
Invers Jarak	GSTARX-ERNN(20,1,1)	27,268%	20,140%
	GSTARX-ERNN(20,2,1)	28,046%	17,206%
	GSTARX-ERNN(20,3,1)	25,934%	20,166%
	GSTARX-ERNN(20,4,1)	26,068%	20,858%
	GSTARX-ERNN(20,5,1)	25,216%	19,920%
	GSTARX-ERNN(20,10,1)	24,265%	24,011%
	GSTARX-ERNN(20,15,1)	21,807%	30,680%
Korelasi Silang	GSTARX-ERNN(20,1,1)	27,111%	16,946%
	GSTARX-ERNN(20,2,1)	27,072%	17,041%
	GSTARX-ERNN(20,3,1)	25,287%	16,950%
	GSTARX-ERNN(20,4,1)	24,892%	17,336%
	GSTARX-ERNN(20,5,1)	25,926%	19,099%
	GSTARX-ERNN(20,10,1)	23,087%	24,136%
	GSTARX-ERNN(20,15,1)	21,211%	34,224%

Berdasarkan nilai RMSE dan sMAPE yang diperoleh model terbaik untuk pemodelan *inflow* Rp50.000 yang dipilih adalah model GSTARX-ERNN(20,2,1) dengan bobot korelasi silang. Arsitektur jaringan model GSTARX-ERNN(20,2,1) diberikan pada Gambar 4.21.



**Gambar 4.21.** Arsitektur Model GSTARX-ERNN Data *Inflow* Rp50.000

Persamaan model model GSTARX-ERNN(20,2,1) untuk *inflow* Rp50.000 dapat dituliskan sebagai berikut.

$$\begin{aligned}
& \begin{pmatrix} \hat{Z}_{1,t}^2 \\ \hat{Z}_{2,t}^2 \\ \hat{Z}_{3,t}^2 \\ \hat{Z}_{4,t}^2 \\ \hat{Z}_{5,t}^2 \end{pmatrix} = \begin{pmatrix} 3,13 & 0 & 0 & 0 & 0 \\ 0 & 3,81 & 0 & 0 & 0 \\ 0 & 0 & 1,79 & 0 & 0 \\ 0 & 0 & 0 & 7,85 & 0 \\ 0 & 0 & 0 & 0 & 10,67 \end{pmatrix} \begin{pmatrix} t_{1,t}^2 \\ t_{2,t}^2 \\ t_{3,t}^2 \\ t_{4,t}^2 \\ t_{5,t}^2 \end{pmatrix} + \begin{pmatrix} -611,79 & 0 & 0 & 0 & 0 \\ 0 & -388,90 & 0 & 0 & 0 \\ 0 & 0 & -182,57 & 0 & 0 \\ 0 & 0 & 0 & -1108,56 & 0 \\ 0 & 0 & 0 & 0 & -2106 \end{pmatrix} \begin{pmatrix} (D_1)_{1,t}^2 \\ (D_1)_{2,t}^2 \\ (D_1)_{3,t}^2 \\ (D_1)_{4,t}^2 \\ (D_1)_{5,t}^2 \end{pmatrix} + \dots + \\
& \begin{pmatrix} 690,85 & 0 & 0 & 0 & 0 \\ 0 & 365,40 & 0 & 0 & 0 \\ 0 & 0 & 269,15 & 0 & 0 \\ 0 & 0 & 0 & 540,61 & 0 \\ 0 & 0 & 0 & 0 & 2566,10 \end{pmatrix} \begin{pmatrix} (S_1)_{1,t}^2 \\ (S_1)_{2,t}^2 \\ (S_1)_{3,t}^2 \\ (S_1)_{4,t}^2 \\ (S_1)_{5,t}^2 \end{pmatrix} + \dots + \begin{pmatrix} 922,47 & 0 & 0 & 0 & 0 \\ 0 & 829,81 & 0 & 0 & 0 \\ 0 & 0 & 380,29 & 0 & 0 \\ 0 & 0 & 0 & 1180,42 & 0 \\ 0 & 0 & 0 & 0 & 3225,82 \end{pmatrix} \begin{pmatrix} (CV_{1,t})_{1,t}^2 \\ (CV_{1,t})_{2,t}^2 \\ (CV_{1,t})_{3,t}^2 \\ (CV_{1,t})_{4,t}^2 \\ (CV_{1,t})_{5,t}^2 \end{pmatrix} + \dots + \\
& \begin{pmatrix} 128,31 & 0 & 0 & 0 & 0 \\ 0 & 139,55 & 0 & 0 & 0 \\ 0 & 0 & 33,22 & 0 & 0 \\ 0 & 0 & 0 & 110,20 & 0 \\ 0 & 0 & 0 & 0 & 274,14 \end{pmatrix} \begin{pmatrix} (CV_{1,t+1})_{1,t}^2 \\ (CV_{1,t+1})_{2,t}^2 \\ (CV_{1,t+1})_{3,t}^2 \\ (CV_{1,t+1})_{4,t}^2 \\ (CV_{1,t+1})_{5,t}^2 \end{pmatrix} + \dots + \begin{pmatrix} \varepsilon_{1,t}^2 \\ \varepsilon_{2,t}^2 \\ \varepsilon_{3,t}^2 \\ \varepsilon_{4,t}^2 \\ \varepsilon_{5,t}^2 \end{pmatrix}
\end{aligned}$$

dengan

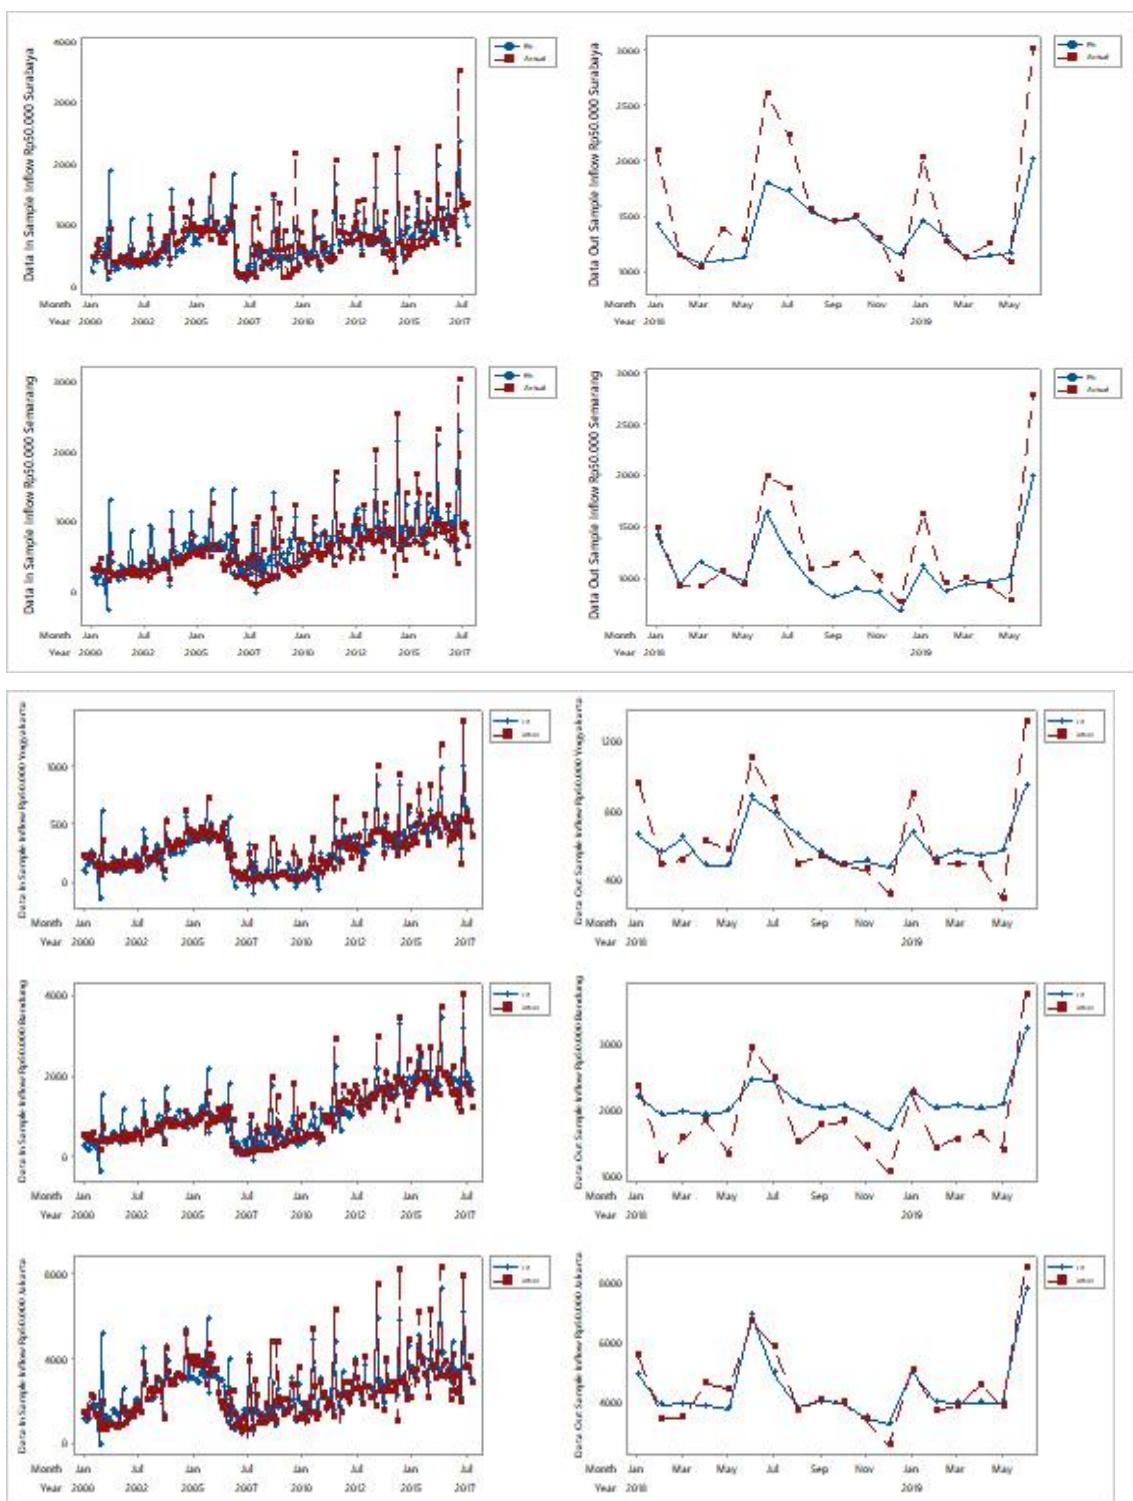
$$\hat{\varepsilon}_t = 0,9997 \times \tanh f_{1,t}^1(\bullet) - 0,691 \times \tanh f_{2,t}^1(\bullet)$$

dan

$$\begin{aligned}
f_{1,t}^1(\bullet) = & 3,846\varepsilon_{1,t-1}^2 + 0,786\varepsilon_{2,t-1}^2 + 7,229\varepsilon_{3,t-1}^2 + 5,688\varepsilon_{4,t-1}^2 + 3,619\varepsilon_{5,t-1}^2 - 1,981\mathbf{F}_{1,t-1}^2 - \\
& 6,319\mathbf{F}_{2,t-1}^2 - 5,984\mathbf{F}_{3,t-1}^2 - 6,146\mathbf{F}_{4,t-1}^2 - 2,924\mathbf{F}_{5,t-1}^2 - 2,514\varepsilon_{1,t-2}^2 - \\
& 5,041\varepsilon_{2,t-2}^2 + 2,767\varepsilon_{3,t-2}^2 + 6,401\varepsilon_{4,t-2}^2 + 2,580\varepsilon_{5,t-2}^2 + 3,682\mathbf{F}_{1,t-2}^2 + \\
& 9,252\mathbf{F}_{2,t-2}^2 + 2,118\mathbf{F}_{3,t-2}^2 + 2,642\mathbf{F}_{4,t-2}^2 - 1,091\mathbf{F}_{5,t-2}^2 + 5,899f_{1,t-1}^1(\bullet) - 6,768f_{2,t-1}^1(\bullet)
\end{aligned}$$

$$\begin{aligned}
f_{2,t}^1(\bullet) = & -3,029\varepsilon_{1,t-1}^2 + 6,771\varepsilon_{2,t-1}^2 + 6,788\varepsilon_{3,t-1}^2 + 4,570\varepsilon_{4,t-1}^2 + 0,652\varepsilon_{5,t-1}^2 - 3,935\mathbf{F}_{1,t-1}^2 - \\
& 3,826\mathbf{F}_{2,t-1}^2 - 2,566\mathbf{F}_{3,t-1}^2 - 0,478\mathbf{F}_{4,t-1}^2 - 0,066\mathbf{F}_{5,t-1}^2 - 11,402\varepsilon_{1,t-2}^2 - \\
& 0,715\varepsilon_{2,t-2}^2 - 6,364\varepsilon_{3,t-2}^2 + 2,782\varepsilon_{4,t-2}^2 - 6,411\varepsilon_{5,t-2}^2 + 4,873\mathbf{F}_{1,t-2}^2 + \\
& 0,604\mathbf{F}_{2,t-2}^2 - 9,511\mathbf{F}_{3,t-2}^2 + 0,439\mathbf{F}_{4,t-2}^2 + 2,622\mathbf{F}_{5,t-2}^2 - 0,350f_{1,t-1}^1(\bullet) + 3,610f_{2,t-1}^1(\bullet)
\end{aligned}$$

Plot perbandingan hasil pemodela GSTARX-ERNN dengan data actual *inflow* Rp50.000 divisualisaikan sebagai berikut.



**Gambar 4.22** Perbandingan Data Aktual *Inflow Rp50.000* di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX-ERNN(20,2,1) dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan)

#### 4.6.3 Pemodelan GSTARX-ERNN pecahan Rp20.000

Pemodelan GSTARX-ERNN pecahan Rp20.000 memiliki proses yang sama dengan pecahan Rp100.000 dan Rp50.000 dengan jumlah input yang sama pula. Karena model GSTARX untuk *inflow* dan *outflow* pecahan Rp20.000 berorde sama dengan UPB lainnya. Nilai RMSE dan sMAPE hasil pemodelan GSTARX-ERNN *inflow* Rp20.000 ditampilkan pada Tabel 4.19 dan 4.20.

**Tabel 4.19.** Nilai Rata-Rata RMSE Model GSTARX-ERNN *Inflow* Rp20.000 KPw Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	RMSE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-ERNN(20,1,1)	27,351	53,172
	GSTARX-ERNN(20,2,1)	23,893	54,976
	GSTARX-ERNN(20,3,1)	23,537	58,320
	GSTARX-ERNN(20,4,1)	31,778	57,210
	GSTARX-ERNN(20,5,1)	21,762	52,349
	GSTARX-ERNN(20,10,1)	18,007	60,365
	GSTARX-ERNN(20,15,1)	18,172	61,289
Invers Jarak	GSTARX-ERNN(20,1,1)	27,323	52,306
	GSTARX-ERNN(20,2,1)	24,216	52,517
	GSTARX-ERNN(20,3,1)	23,857	48,586
	GSTARX-ERNN(20,4,1)	22,319	52,620
	GSTARX-ERNN(20,5,1)	21,288	48,612
	GSTARX-ERNN(20,10,1)	20,257	65,919
	GSTARX-ERNN(20,15,1)	17,684	61,989
Korelasi Silang	GSTARX-ERNN(20,1,1)	27,326	53,144
	GSTARX-ERNN(20,2,1)	23,846	54,918
	GSTARX-ERNN(20,3,1)	23,353	58,201
	GSTARX-ERNN(20,4,1)	26,546	55,835
	GSTARX-ERNN(20,5,1)	21,450	52,129
	GSTARX-ERNN(20,10,1)	17,955	52,673
	GSTARX-ERNN(20,15,1)	15,819	59,142

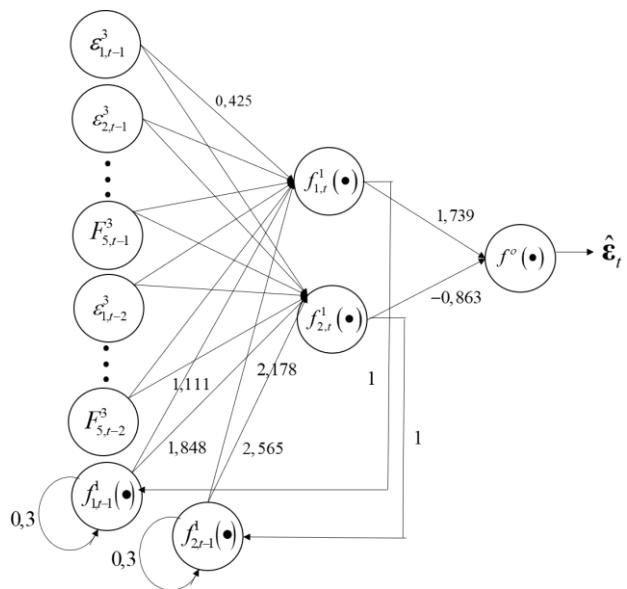
**Tabel 4.20.** Nilai Rata-Rata sMAPE Model GSTARX-ERNN *Inflow* Rp20.000 KPw Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	sMAPE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-ERNN(20,1,1)	26,231%	30,297%
	GSTARX-ERNN(20,2,1)	23,964%	26,446%
	GSTARX-ERNN(20,3,1)	26,783%	46,382%
	GSTARX-ERNN(20,4,1)	33,48%	40,652%
	GSTARX-ERNN(20,5,1)	21,961%	28,414%
	GSTARX-ERNN(20,10,1)	20,564%	38,723%
	GSTARX-ERNN(20,15,1)	19,974%	41,097%

**Tabel 4.20.** Nilai Rata-Rata sMAPE Model GSTARX-ERNN *Inflow* Rp20.000 KPw Bank Sentral Provinsi di Pulau Jawa (lanjutan)

Bobot	Model	sMAPE	
		In Sample	Out Sample
Invers Jarak	GSTARX-ERNN(20,1,1)	26,254%	29,814%
	GSTARX-ERNN(20,2,1)	23,699%	33,640%
	GSTARX-ERNN(20,3,1)	23,137%	28,004%
	GSTARX-ERNN(20,4,1)	26,291%	31,184%
	GSTARX-ERNN(20,5,1)	23,620%	39,036%
	GSTARX-ERNN(20,10,1)	21,493%	42,154%
	GSTARX-ERNN(20,15,1)	20,780%	52,756%
Korelasi Silang	GSTARX-ERNN(20,1,1)	26,210%	30,298%
	GSTARX-ERNN(20,2,1)	23,915%	26,300%
	GSTARX-ERNN(20,3,1)	25,692%	40,812%
	GSTARX-ERNN(20,4,1)	28,132%	31,200%
	GSTARX-ERNN(20,5,1)	21,823%	27,112%
	GSTARX-ERNN(20,10,1)	20,586%	39,094%
	GSTARX-ERNN(20,15,1)	17,890%	46,949%

Pada Tabel diketahui model GSTARX-ERNN *inflow* Rp20.000 yang terpilih adalah model GSTARX-ERNN dengan 20 input, 2 neuron *hidden layer*, dan 1 output serta bobot korelasi silang sebagai bobot lokasi terpilih. Arsitektur jaringan model GSTARX-ERNN(20,2,1) adalah sebagai berikut.



**Gambar 4.23.** Arsitektur Model GSTARX-ERNN Data *Inflow* Rp20.000  
Persamaan model GSTARX-ERNN(20,2,1) untuk *inflow* Rp20.000 dengan bobot korelasi silang dituliskan sebagai berikut.

$$\begin{aligned}
\begin{pmatrix} \hat{Z}_{1,t}^3 \\ \hat{Z}_{2,t}^3 \\ \hat{Z}_{3,t}^3 \\ \hat{Z}_{4,t}^3 \\ \hat{Z}_{5,t}^3 \end{pmatrix} &= \begin{pmatrix} -0,23 & 0 & 0 & 0 & 0 \\ 0 & -0,12 & 0 & 0 & 0 \\ 0 & 0 & -0,18 & 0 & 0 \\ 0 & 0 & 0 & -0,25 & 0 \\ 0 & 0 & 0 & 0 & -0,82 \end{pmatrix} \begin{pmatrix} t_{1,t}^3 \\ t_{2,t}^3 \\ t_{3,t}^3 \\ t_{4,t}^3 \\ t_{5,t}^3 \end{pmatrix} + \begin{pmatrix} -89,40 & 0 & 0 & 0 & 0 \\ 0 & -36,63 & 0 & 0 & 0 \\ 0 & 0 & -42,82 & 0 & 0 \\ 0 & 0 & 0 & -124,79 & 0 \\ 0 & 0 & 0 & 0 & -213,83 \end{pmatrix} \begin{pmatrix} (D_1)_{1,t}^3 \\ (D_1)_{2,t}^3 \\ (D_1)_{3,t}^3 \\ (D_1)_{4,t}^3 \\ (D_1)_{5,t}^3 \end{pmatrix} + \dots + \\
&\quad \begin{pmatrix} 115,85 & 0 & 0 & 0 & 0 \\ 0 & 73,36 & 0 & 0 & 0 \\ 0 & 0 & 62,77 & 0 & 0 \\ 0 & 0 & 0 & 137,74 & 0 \\ 0 & 0 & 0 & 0 & 352,38 \end{pmatrix} \begin{pmatrix} (S_1)_{1,t}^3 \\ (S_1)_{2,t}^3 \\ (S_1)_{3,t}^3 \\ (S_1)_{4,t}^3 \\ (S_1)_{5,t}^3 \end{pmatrix} + \dots + \\
&\quad \begin{pmatrix} 45,50 & 0 & 0 & 0 & 0 \\ 0 & 28,16 & 0 & 0 & 0 \\ 0 & 0 & 13,03 & 0 & 0 \\ 0 & 0 & 0 & 23,05 & 0 \\ 0 & 0 & 0 & 0 & 91,86 \end{pmatrix} \begin{pmatrix} (CV_{1,t+1})_{1,t}^3 \\ (CV_{1,t+1})_{2,t}^3 \\ (CV_{1,t+1})_{3,t}^3 \\ (CV_{1,t+1})_{4,t}^3 \\ (CV_{1,t+1})_{5,t}^3 \end{pmatrix} + \dots + \\
&\quad \begin{pmatrix} \epsilon_{1,t}^3 \\ \epsilon_{2,t}^3 \\ \epsilon_{3,t}^3 \\ \epsilon_{4,t}^3 \\ \epsilon_{5,t}^3 \end{pmatrix}
\end{aligned}$$

dengan

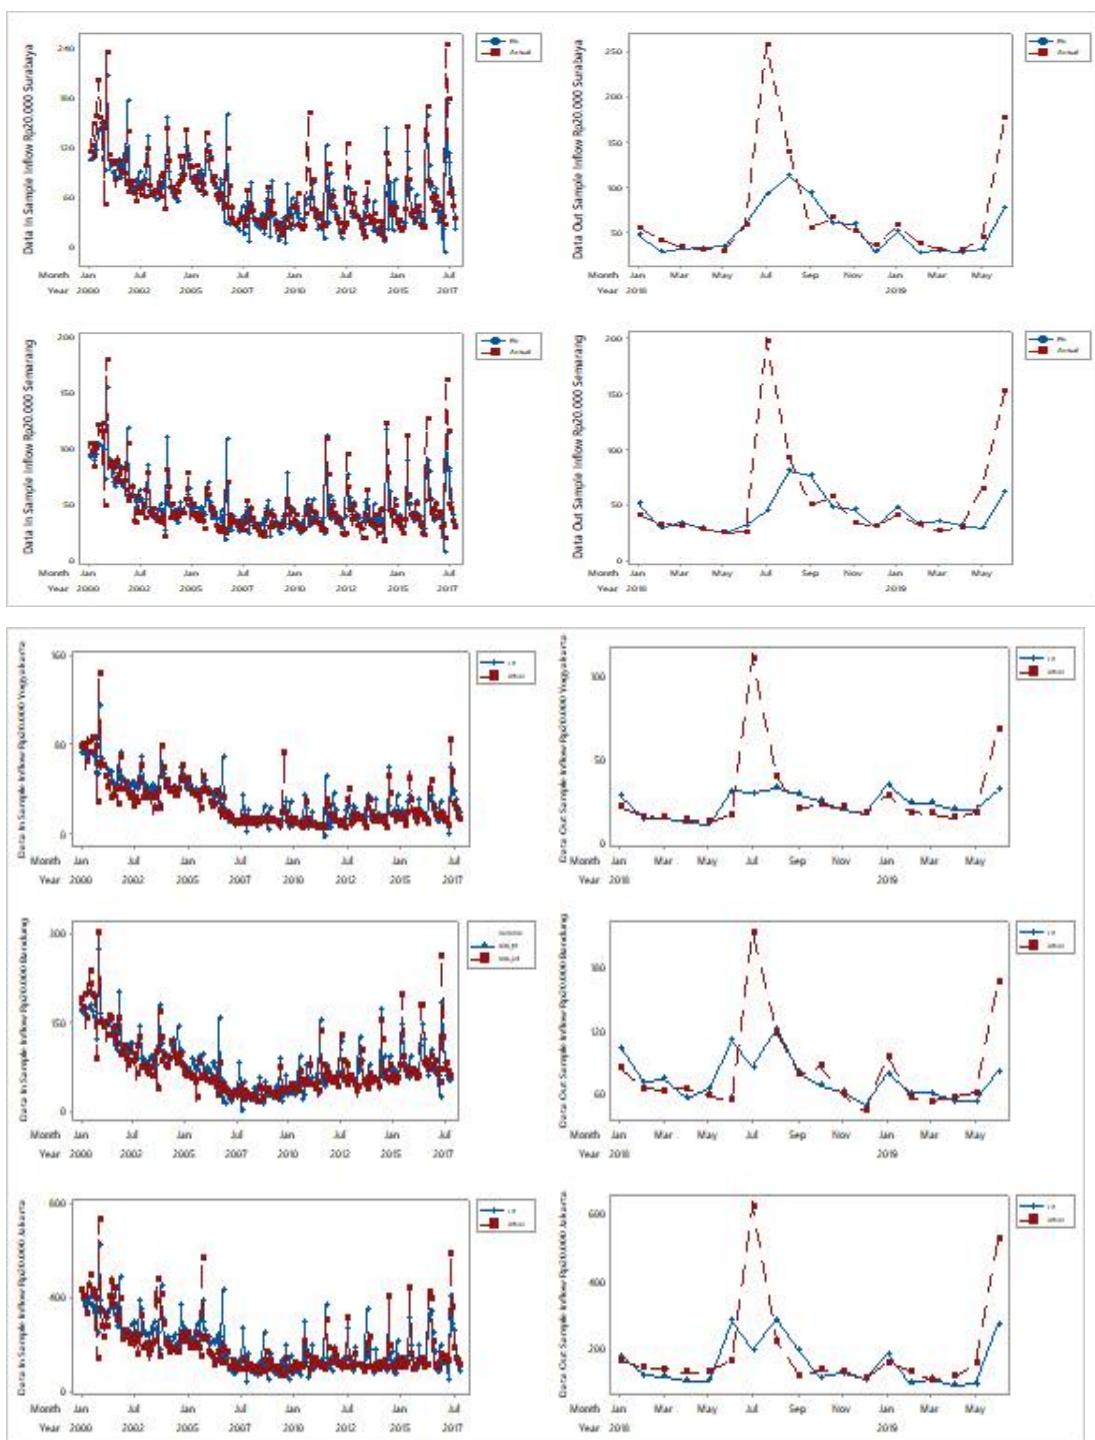
$$\hat{\epsilon}_t = 1,739 \times \tanh f_{1,t}^1(\bullet) - 0,863 \times \tanh f_{2,t}^1(\bullet)$$

dan

$$\begin{aligned}
f_{1,t}^1(\bullet) &= 0,425\epsilon_{1,t-1}^3 + 1,835\epsilon_{2,t-1}^3 - 1,205\epsilon_{3,t-1}^3 + 2,945\epsilon_{4,t-1}^3 - 0,624\epsilon_{5,t-1}^3 + 1,107F_{1,t-1}^3 + \\
&\quad 0,613F_{2,t-1}^3 + 2,614F_{3,t-1}^3 - 0,814F_{4,t-1}^3 + 2,937F_{5,t-1}^3 + 0,220\epsilon_{1,t-2}^3 - \\
&\quad 0,177\epsilon_{2,t-2}^3 + 5,891\epsilon_{3,t-2}^3 + 0,938\epsilon_{4,t-2}^3 + 1,783\epsilon_{5,t-2}^3 + 0,058F_{1,t-2}^3 + \\
&\quad 0,486F_{2,t-2}^3 - 3,135F_{3,t-2}^3 - 0,704F_{4,t-2}^3 - 1,237F_{5,t-2}^3 + 1,111f_{1,t-1}^1(\bullet) + 2,178f_{2,t-1}^1(\bullet)
\end{aligned}$$

$$\begin{aligned}
f_{2,t}^1(\bullet) &= -14,596\epsilon_{1,t-1}^3 - 1,511\epsilon_{2,t-1}^3 - 1,840\epsilon_{3,t-1}^3 - 2,137\epsilon_{4,t-1}^3 - 4,658\epsilon_{5,t-1}^3 + 4,576F_{1,t-1}^3 - \\
&\quad 0,365F_{2,t-1}^3 - 0,077F_{3,t-1}^3 + 0,524F_{4,t-1}^3 + 4,029F_{5,t-1}^3 - 2,931\epsilon_{1,t-2}^3 - \\
&\quad 1,059\epsilon_{2,t-2}^3 + 1,991\epsilon_{3,t-2}^3 + 0,540\epsilon_{4,t-2}^3 + 1,998\epsilon_{5,t-2}^3 - 0,618F_{1,t-2}^3 + \\
&\quad 0,537F_{2,t-2}^3 - 1,062F_{3,t-2}^3 - 0,876F_{4,t-2}^3 - 1,976F_{5,t-2}^3 + 1,848f_{1,t-1}^1(\bullet) + 2,565f_{2,t-1}^1(\bullet)
\end{aligned}$$

Kemudian plot perbandingan hasil pemodelan GSTARX-ERNN(20,2,1) dengan data aktual *inflow* Rp20.0000 ditunjukkan pada Gambar 4.24.



**Gambar 4.24.** Perbandingan Data Aktual *Inflow* Rp20.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX-ERNN(20,2,1) Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan)

## **4.7 Pemodelan GSTARX-JRNN Data *Inflow* dan *Outflow* UPB di KPw Bank Sentral di Pulau Jawa**

Pemodelan GSTARX-JRNN menggunakan struktur data, input, jumlah neuron dan jenis bobot lokasi yang sama dengan pemodelan GSTARX-ERNN. Tetapi arsitektur jaringan model GSTARX-JRNN sedikit berbeda dari model GSTARX-ERNN. *Context layer* pada jaringan GSTARX-JRNN menyimpan kembali memori jaringan dari *output layer* yang selanjutnya diproses kembali menuju *hidden layer* hingga menuju *output layer*. Sehingga jumlah neuron pada *context layer* hanya satu.

Seperti pada pemodelan GSTARX-ERNN, pemodelan GSTARX-JRNN juga terdiri dari dua tahap. Tahap pertama memodelkan data dengan model TSR dan tahap kedua memodelkan residual TSR menggunakan model *Jordan RNN* (JRNN) dengan input residual model TSR dan residual model TSR yang telah diboboti dengan bobot GSTAR.

### **4.7.1 Pemodelan GSTARX-JRNN pecahan Rp100.000**

Hasil perhitungan nilai rata-rata RMSE dan sMAPE dari kombinasi jumlah neuron dengan bobot lokasi untuk *inflow* Rp100.000 diberikan pada Tabel 4.21 dan Tabel 4.22. Berdasarkan nilai RMSE dan sMAPE diperoleh model GSTARX-JRNN(20,1,1) dengan bobot korelasi silang sebagai model terbaik. Selanjutnya arsitektur model GSTARX-JRNN(20,1,1) divisualisasikan pada Gambar 4.25.

**Tabel 4.21.** Nilai Rata-Rata RMSE Model GSTARX-JRNN *Inflow* Rp100.000 KPw

Bank Sentral Provinsi di Pulau Jawa

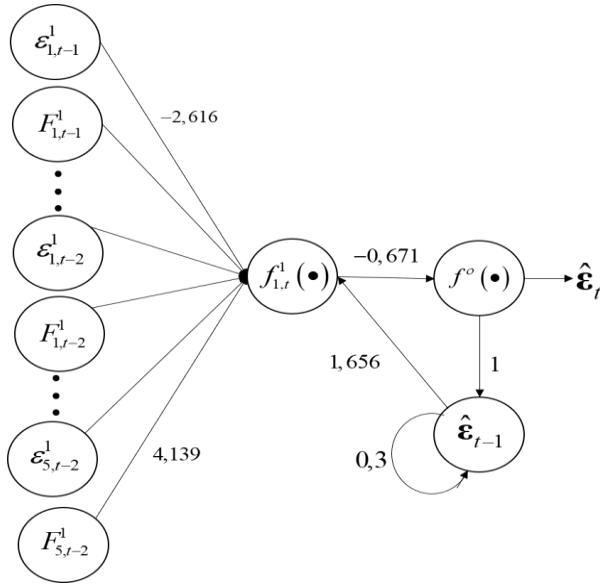
Bobot	Model	RMSE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-JRNN(20,1,1)	471,962	1094,249
	GSTARX-JRNN(20,2,1)	500,599	1072,315
	GSTARX-JRNN(20,3,1)	607,067	1216,513
	GSTARX-JRNN(20,4,1)	614,584	1268,871
	GSTARX-JRNN(20,5,1)	741,313	1261,493
	GSTARX-JRNN(20,10,1)	2104,96	2616,987
	GSTARX-JRNN(20,15,1)	1776,045	2375,404
Invers Jarak	GSTARX-JRNN(20,1,1)	466,608	1095,07
	GSTARX-JRNN(20,2,1)	489,876	1109,355
	GSTARX-JRNN(20,3,1)	579,164	1344,077
	GSTARX-JRNN(20,4,1)	583,404	1195,869
	GSTARX-JRNN(20,5,1)	854,207	1346,35

**Tabel 4.21.** Nilai Rata-Rata RMSE Model GSTARX-JRNN *Inflow* Rp100.000 KPw  
Bank Sentral Provinsi di Pulau Jawa (lanjutan)

Bobot	Model	RMSE	
		<i>In Sample</i>	<i>Out Sample</i>
Invers	GSTARX-JRNN(20,10,1)	1987,04	2760,344
Jarak	GSTARX-JRNN(20,15,1)	5973,228	5358,866
Korelasi Silang	GSTARX-JRNN(20,1,1)	470,152	1080,806
	GSTARX-JRNN(20,2,1)	478,606	1103,793
	GSTARX-JRNN(20,3,1)	1135,23	1852,014
	GSTARX-JRNN(20,4,1)	561,153	1215,777
	GSTARX-JRNN(20,5,1)	669,860	1317,559
	GSTARX-JRNN(20,10,1)	2346,683	2962,337
	GSTARX-JRNN(20,15,1)	2221,98	3090,148

**Tabel 4.22.** Nilai Rata-Rata sMAPE Model GSTARX-JRNN *Inflow* Rp100.000 KPw  
Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	sMAPE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-JRNN(20,1,1)	44,374%	26,399%
	GSTARX-JRNN(20,2,1)	48,358%	26,295%
	GSTARX-JRNN(20,3,1)	53,133%	32,686%
	GSTARX-JRNN(20,4,1)	53,652%	31,668%
	GSTARX-JRNN(20,5,1)	59,391%	30,873%
	GSTARX-JRNN(20,10,1)	109,379%	84,864%
	GSTARX-JRNN(20,15,1)	92,195%	77,509%
	GSTARX-JRNN(20,1,1)	44,202%	27,533%
Invers Jarak	GSTARX-JRNN(20,2,1)	50,393%	28,416%
	GSTARX-JRNN(20,3,1)	51,880%	34,158%
	GSTARX-JRNN(20,4,1)	53,876%	30,787%
	GSTARX-JRNN(20,5,1)	65,983%	42,975%
	GSTARX-JRNN(20,10,1)	92,367%	73,846%
	GSTARX-JRNN(20,15,1)	166,796%	136,723%
Korelasi Silang	GSTARX-JRNN(20,1,1)	45,885%	25,900%
	GSTARX-JRNN(20,2,1)	46,504%	26,797%
	GSTARX-JRNN(20,3,1)	68,092%	55,405%
	GSTARX-JRNN(20,4,1)	48,885%	32,524%
	GSTARX-JRNN(20,5,1)	60,383%	34,263%
	GSTARX-JRNN(20,10,1)	79,147%	80,579%
	GSTARX-JRNN(20,15,1)	91,407%	79,728%



**Gambar 4.25.** Arsitektur Model GSTARX-JRNN *Inflow* Rp100.000

Persamaan model GSTARX-JRNN(20,1,1) *inflow* Rp100.000 adalah sebagai berikut.

$$\begin{aligned}
 \begin{pmatrix} \hat{Z}_{1,t}^1 \\ \hat{Z}_{2,t}^1 \\ \hat{Z}_{3,t}^1 \\ \hat{Z}_{4,t}^1 \\ \hat{Z}_{5,t}^1 \end{pmatrix} &= \begin{pmatrix} 9,36 & 0 & 0 & 0 & 0 \\ 0 & 8,26 & 0 & 0 & 0 \\ 0 & 0 & 3,46 & 0 & 0 \\ 0 & 0 & 0 & 13,51 & 0 \\ 0 & 0 & 0 & 0 & 23,05 \end{pmatrix} \begin{pmatrix} t_{1,t}^1 \\ t_{2,t}^1 \\ t_{3,t}^1 \\ t_{4,t}^1 \\ t_{5,t}^1 \end{pmatrix} + \begin{pmatrix} -363,33 & 0 & 0 & 0 & 0 \\ 0 & -183,82 & 0 & 0 & 0 \\ 0 & 0 & -112,3 & 0 & 0 \\ 0 & 0 & 0 & -831,72 & 0 \\ 0 & 0 & 0 & 0 & -1550,73 \end{pmatrix} \begin{pmatrix} (D_1)_{1,t}^1 \\ (D_1)_{2,t}^1 \\ (D_1)_{3,t}^1 \\ (D_1)_{4,t}^1 \\ (D_1)_{5,t}^1 \end{pmatrix} + \dots + \\
 &\quad \begin{pmatrix} 484,37 & 0 & 0 & 0 & 0 \\ 0 & 199,26 & 0 & 0 & 0 \\ 0 & 0 & 245,70 & 0 & 0 \\ 0 & 0 & 0 & 314,35 & 0 \\ 0 & 0 & 0 & 0 & 1170,89 \end{pmatrix} \begin{pmatrix} (S_1)_{1,t}^1 \\ (S_1)_{2,t}^1 \\ (S_1)_{3,t}^1 \\ (S_1)_{4,t}^1 \\ (S_1)_{5,t}^1 \end{pmatrix} + \dots + \\
 &\quad \begin{pmatrix} 1257,51 & 0 & 0 & 0 & 0 \\ 0 & 1289,27 & 0 & 0 & 0 \\ 0 & 0 & 612,1 & 0 & 0 \\ 0 & 0 & 0 & 1542,23 & 0 \\ 0 & 0 & 0 & 0 & 3916,27 \end{pmatrix} \begin{pmatrix} (CV_{1,t})_{1,t}^1 \\ (CV_{1,t})_{2,t}^1 \\ (CV_{1,t})_{3,t}^1 \\ (CV_{1,t})_{4,t}^1 \\ (CV_{1,t})_{5,t}^1 \end{pmatrix} + \dots + \\
 &\quad \begin{pmatrix} 119,56 & 0 & 0 & 0 & 0 \\ 0 & 56,30 & 0 & 0 & 0 \\ 0 & 0 & 0,06 & 0 & 0 \\ 0 & 0 & 0 & 59,44 & 0 \\ 0 & 0 & 0 & 0 & 111,38 \end{pmatrix} \begin{pmatrix} (CV_{1,t+1})_{1,t}^1 \\ (CV_{1,t+1})_{2,t}^1 \\ (CV_{1,t+1})_{3,t}^1 \\ (CV_{1,t+1})_{4,t}^1 \\ (CV_{1,t+1})_{5,t}^1 \end{pmatrix} + \begin{pmatrix} \varepsilon_{1,t}^1 \\ \varepsilon_{2,t}^1 \\ \varepsilon_{3,t}^1 \\ \varepsilon_{4,t}^1 \\ \varepsilon_{5,t}^1 \end{pmatrix}
 \end{aligned}$$

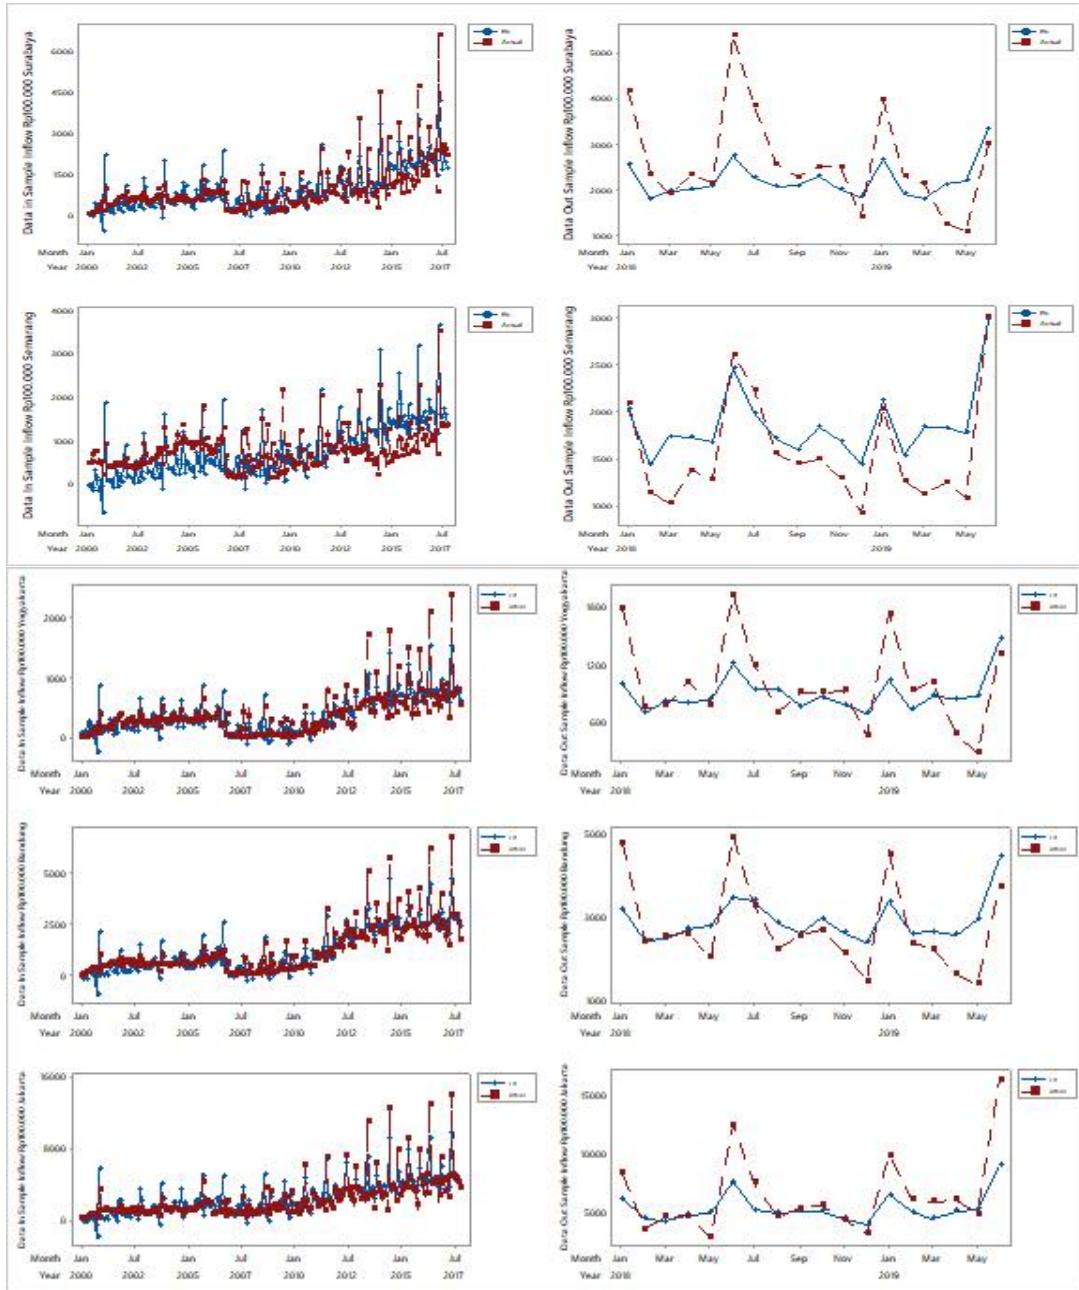
dengan

$$\hat{\varepsilon}_t = -0,671 \times \tanh f_{1,t}^1(\bullet)$$

dan

$$\begin{aligned}
 f_{1,t}^1(\bullet) = & -2,616\varepsilon_{1,t-1}^1 - 0,421\varepsilon_{2,t-1}^1 + 0,677\varepsilon_{3,t-1}^1 + 2,767\varepsilon_{4,t-1}^1 + 3,066\varepsilon_{5,t-1}^1 + 7,772F_{1,t-1}^1 + \\
 & 7,295F_{2,t-1}^1 + 6,099F_{3,t-1}^1 + 1,672F_{4,t-1}^1 + 1,639F_{5,t-1}^1 + 5,934\varepsilon_{1,t-2}^1 - \\
 & 1,008\varepsilon_{2,t-2}^1 + 1,9401\varepsilon_{3,t-2}^1 - 3,076\varepsilon_{4,t-2}^1 - 3,122\varepsilon_{5,t-2}^1 - 0,712F_{1,t-2}^1 + \\
 & 0,156F_{2,t-2}^1 - 4,033F_{3,t-2}^1 + 9,724F_{4,t-2}^1 + 4,139F_{5,t-2}^1 + 1,656\hat{\varepsilon}_{t-1}
 \end{aligned}$$

Selanjutnya plot perbandingan hasil pemodelan GSTARX-JRNN(20,1,1) dengan data aktual *inflow* Rp100.000 dapat dilihat pada Gambar 4.26.



**Gambar 4.26.** Perbandingan Data Aktual *Inflow* Rp100.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX-JRNN(20,1,1) dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan)

#### 4.7.2 Pemodelan GSTARX-JRNN pecahan Rp50.000

Model GSTARX-JRNN untuk *inflow* Rp50.000 yang dipilih adalah model GSTARX-JRNN(20,1,1) dengan bobot seragam berdasarkan nilai rata-rata RMSE

dan sMAPE pada Tabel 4.23 dan 4.24. Arsitektur model GSTARX-JRNN(20,1,1) diberikan pada Gambar 4.27.

**Tabel 4.23.** Nilai Rata-Rata RMSE Model GSTARX-JRNN *Inflow* Rp50.000

KPw Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	RMSE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-JRNN(20,1,1)	345,365	366,315
	GSTARX-JRNN(20,2,1)	385,086	396,207
	GSTARX-JRNN(20,3,1)	334,834	444,383
	GSTARX-JRNN(20,4,1)	362,555	492,590
	GSTARX-JRNN(20,5,1)	333,764	501,877
	GSTARX-JRNN(20,10,1)	359,777	505,122
	GSTARX-JRNN(20,15,1)	660,691	788,166
Invers Jarak	GSTARX-JRNN(20,1,1)	465,086	494,072
	GSTARX-JRNN(20,2,1)	475,087	512,617
	GSTARX-JRNN(20,3,1)	323,918	408,340
	GSTARX-JRNN(20,4,1)	362,544	446,086
	GSTARX-JRNN(20,5,1)	315,516	415,721
	GSTARX-JRNN(20,10,1)	336,318	739,087
	GSTARX-JRNN(20,15,1)	2765,599	2524,376
Korelasi Silang	GSTARX-JRNN(20,1,1)	403,772	420,656
	GSTARX-JRNN(20,2,1)	350,352	377,785
	GSTARX-JRNN(20,3,1)	347,079	409,698
	GSTARX-JRNN(20,4,1)	353,792	385,908
	GSTARX-JRNN(20,5,1)	478,099	414,373
	GSTARX-JRNN(20,10,1)	368,868	564,011
	GSTARX-JRNN(20,15,1)	520,173	764,221

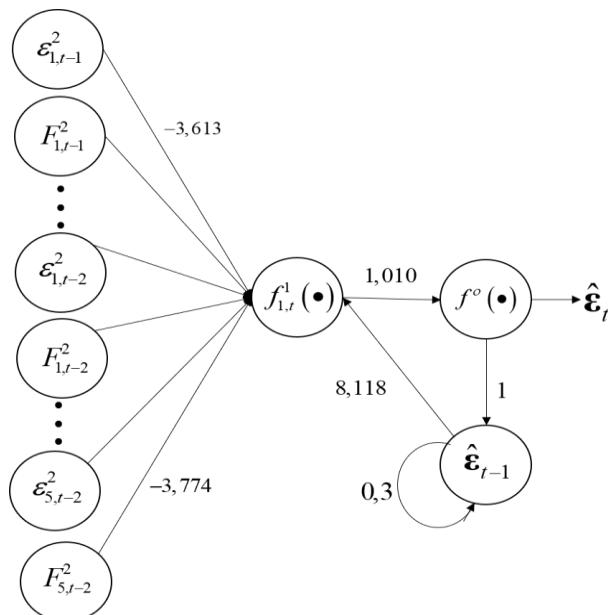
**Tabel 4.24.** Nilai Rata-Rata sMAPE Model GSTARX-JRNN *Inflow* Rp50.000

KPw Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	sMAPE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-JRNN(20,1,1)	31,268%	16,866%
	GSTARX-JRNN(20,2,1)	38,957%	19,673%
	GSTARX-JRNN(20,3,1)	32,830%	19,375%
	GSTARX-JRNN(20,4,1)	38,477%	21,092%
	GSTARX-JRNN(20,5,1)	32,694%	22,020%
	GSTARX-JRNN(20,10,1)	35,709%	25,403%
	GSTARX-JRNN(20,15,1)	44,917%	34,610%
Invers Jarak	GSTARX-JRNN(20,1,1)	42,818%	21,977%
	GSTARX-JRNN(20,2,1)	45,797%	23,747%
	GSTARX-JRNN(20,3,1)	32,407%	18,210%

**Tabel 4.24.** Nilai Rata-Rata sMAPE Model GSTARX-JRNN *Inflow* Rp50.000 KPW Bank Sentral Provinsi di Pulau Jawa (lanjutan)

Bobot	Model	sMAPE	
		<i>In Sample</i>	<i>Out Sample</i>
Invers	GSTARX-JRNN(20,4,1)	35,749%	19,877%
	GSTARX-JRNN(20,5,1)	31,581%	19,534%
	GSTARX-JRNN(20,10,1)	37,691%	35,291%
	GSTARX-JRNN(20,15,1)	198,487%	171,586%
Korelasi Silang	GSTARX-JRNN(20,1,1)	36,595%	19,178%
	GSTARX-JRNN(20,2,1)	32,489%	17,241%
	GSTARX-JRNN(20,3,1)	43,078%	20,416%
	GSTARX-JRNN(20,4,1)	34,407%	19,413%
	GSTARX-JRNN(20,5,1)	46,753%	20,920%
	GSTARX-JRNN(20,10,1)	36,806%	27,35%
	GSTARX-JRNN(20,15,1)	43,310%	33,319%



**Gambar 4.27.** Arsitektur Model GSTARX-JRNN Data *Inflow* Rp50.000

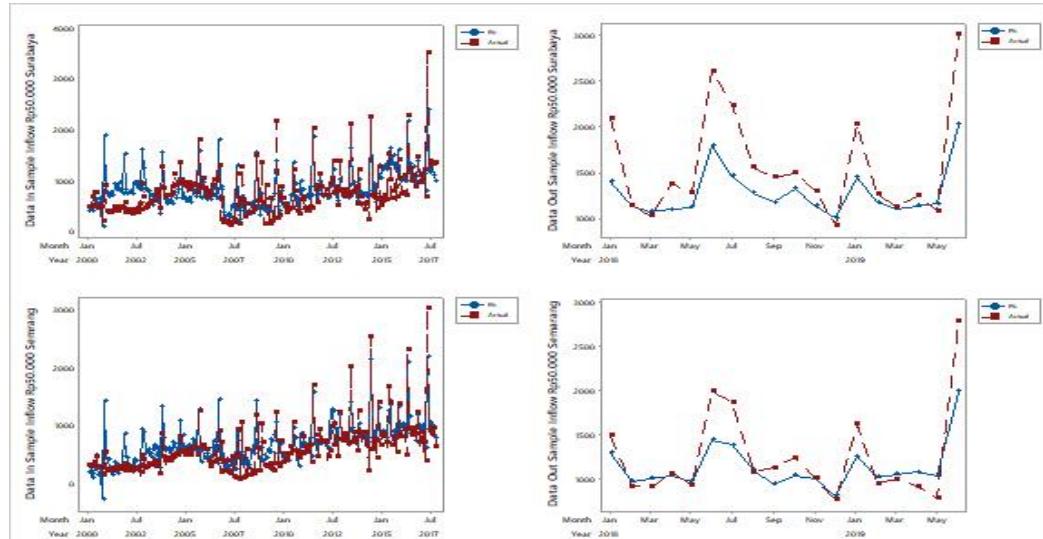
$$\begin{aligned}
& \hat{Z}_{1,t}^2 = \begin{pmatrix} 3,13 & 0 & 0 & 0 & 0 \\ 0 & 3,81 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} t_{1,t}^2 \\ t_{2,t}^2 \\ t_{3,t}^2 \\ t_{4,t}^2 \\ t_{5,t}^2 \end{pmatrix} + \begin{pmatrix} -611,79 & 0 & 0 & 0 & 0 \\ 0 & -388,90 & 0 & 0 & 0 \\ 0 & 0 & -182,57 & 0 & 0 \\ 0 & 0 & 0 & -1108,56 & 0 \\ 0 & 0 & 0 & 0 & -2106 \end{pmatrix} \begin{pmatrix} (D_1)_{1,t}^2 \\ (D_1)_{2,t}^2 \\ (D_1)_{3,t}^2 \\ (D_1)_{4,t}^2 \\ (D_1)_{5,t}^2 \end{pmatrix} + \dots \\
& \hat{Z}_{2,t}^2 = \begin{pmatrix} 690,85 & 0 & 0 & 0 & 0 \\ 0 & 365,40 & 0 & 0 & 0 \\ 0 & 0 & 269,15 & 0 & 0 \\ 0 & 0 & 0 & 540,61 & 0 \\ 0 & 0 & 0 & 0 & 2566,10 \end{pmatrix} \begin{pmatrix} (S_1)_{1,t}^2 \\ (S_1)_{2,t}^2 \\ (S_1)_{3,t}^2 \\ (S_1)_{4,t}^2 \\ (S_1)_{5,t}^2 \end{pmatrix} + \dots + \begin{pmatrix} 922,47 & 0 & 0 & 0 & 0 \\ 0 & 829,81 & 0 & 0 & 0 \\ 0 & 0 & 380,29 & 0 & 0 \\ 0 & 0 & 0 & 1180,42 & 0 \\ 0 & 0 & 0 & 0 & 3225,82 \end{pmatrix} \begin{pmatrix} (CV_{1,t})_{1,t}^2 \\ (CV_{1,t})_{2,t}^2 \\ (CV_{1,t})_{3,t}^2 \\ (CV_{1,t})_{4,t}^2 \\ (CV_{1,t})_{5,t}^2 \end{pmatrix} + \dots \\
& \hat{Z}_{3,t}^2 = \begin{pmatrix} 128,31 & 0 & 0 & 0 & 0 \\ 0 & 139,55 & 0 & 0 & 0 \\ 0 & 0 & 33,22 & 0 & 0 \\ 0 & 0 & 0 & 110,20 & 0 \\ 0 & 0 & 0 & 0 & 274,14 \end{pmatrix} \begin{pmatrix} (CV_{1,t+1})_{1,t}^2 \\ (CV_{1,t+1})_{2,t}^2 \\ (CV_{1,t+1})_{3,t}^2 \\ (CV_{1,t+1})_{4,t}^2 \\ (CV_{1,t+1})_{5,t}^2 \end{pmatrix} + \dots + \begin{pmatrix} \varepsilon_{1,t}^2 \\ \varepsilon_{2,t}^2 \\ \varepsilon_{3,t}^2 \\ \varepsilon_{4,t}^2 \\ \varepsilon_{5,t}^2 \end{pmatrix}
\end{aligned}$$

dengan

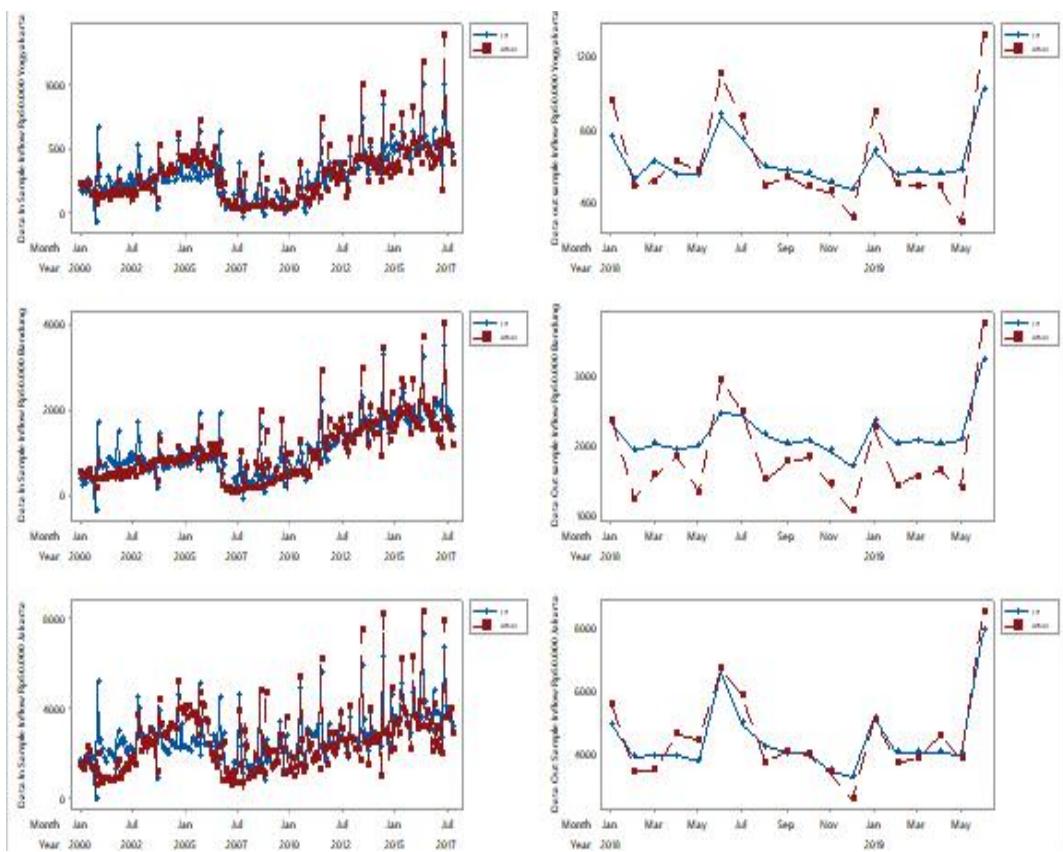
$$\hat{\epsilon}_t = 1,010 \times \tanh f_{1,t}^1(\bullet)$$

dan

$$\begin{aligned}
f_{1,t}^1(\bullet) = & -3,613\epsilon_{1,t-1}^2 - 9,491\epsilon_{2,t-1}^2 - 3,283\epsilon_{3,t-1}^2 - 2,113\epsilon_{4,t-1}^2 + 0,074\epsilon_{5,t-1}^2 - 2,962F_{1,t-1}^2 + \\
& 4,005F_{2,t-1}^2 - 1,024F_{3,t-1}^2 - 4,922F_{4,t-1}^2 - 4,556F_{5,t-1}^2 + 0,245\epsilon_{1,t-2}^2 - \\
& 5,517\epsilon_{2,t-2}^2 + 0,723\epsilon_{3,t-2}^2 + 0,790\epsilon_{4,t-2}^2 + 2,083\epsilon_{5,t-2}^2 - 0,159F_{1,t-2}^2 + \\
& 4,244F_{2,t-2}^2 + 1,895F_{3,t-2}^2 - 1,070F_{4,t-2}^2 - 3,774F_{5,t-2}^2 + 8,118\hat{\epsilon}_{t-1}
\end{aligned}$$



**Gambar 4.28.** Perbandingan Data Aktual *Inflow* Rp50.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX-JRNN(20,2,1) dengan Bobot Seragam *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.28.** Perbandingan Data Aktual *Inflow* Rp50.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX-JRNN(20,2,1) dengan Bobot Seragam *in sample* (kiri) dan *out sample* (kanan) (lanjutan)

#### 4.7.3 Pemodelan GSTARX-JRNN pecahan Rp20.000

Pemodelan GSTARX-JRNN *inflow* Rp20.000 dilakukan sama seperti pemodelan untuk pecahan-pecahan besar sebelumnya. Kemudian nilai rata-rata RMSE dan sMAPE hasil pemodelan GSTARX-JRNN *inflow* Rp20.000 ditampilkan pada Tabel 4.25 dan 4.26. Model GSTARX-JRNN terpilih berdasarkan nilai RMSE dan sMAPE yaitu model GSTARX-JRNN dengan 20 input, 3 neuron di *hidden layer*, dan 1 output serta bobot seragam sebagai bobot lokasi terpilih.

**Tabel 4.25.** Nilai Rata-Rata RMSE Model GSTARX-JRNN *Inflow* Rp20.000 KPw Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	RMSE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-JRNN(20,1,1)	27,750	54,023
	GSTARX-JRNN(20,2,1)	25,488	57,724
	GSTARX-JRNN(20,3,1)	26,236	49,749
	GSTARX-JRNN(20,4,1)	25,523	53,203
	GSTARX-JRNN(20,5,1)	32,004	53,486
	GSTARX-JRNN(20,10,1)	34,034	58,509
	GSTARX-JRNN(20,15,1)	231,421	205,332
Invers Jarak	GSTARX-JRNN(20,1,1)	27,574	53,058
	GSTARX-JRNN(20,2,1)	26,244	54,221
	GSTARX-JRNN(20,3,1)	25,848	51,467
	GSTARX-JRNN(20,4,1)	35,057	58,525
	GSTARX-JRNN(20,5,1)	31,111	55,311
	GSTARX-JRNN(20,10,1)	30,883	63,883
	GSTARX-JRNN(20,15,1)	68,671	73,597
Korelasi Silang	GSTARX-JRNN(20,1,1)	27,723	60,184
	GSTARX-JRNN(20,2,1)	26,606	55,326
	GSTARX-JRNN(20,3,1)	25,414	56,772
	GSTARX-JRNN(20,4,1)	26,423	55,826
	GSTARX-JRNN(20,5,1)	54,900	77,931
	GSTARX-JRNN(20,10,1)	42,100	79,268
	GSTARX-JRNN(20,15,1)	123,080	87,716

**Tabel 4.26.** Nilai Rata-Rata sMAPE Model GSTARX-JRNN *Inflow* Rp20.000 KPw Bank Sentral Provinsi di Pulau Jawa

Bobot	Model	sMAPE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	GSTARX-JRNN(20,1,1)	26,642%	32,037%
	GSTARX-JRNN(20,2,1)	24,941%	31,593%
	GSTARX-JRNN(20,3,1)	26,037%	26,305%
	GSTARX-JRNN(20,4,1)	25,147%	32,420%
	GSTARX-JRNN(20,5,1)	29,675%	39,083%
	GSTARX-JRNN(20,10,1)	31,893%	54,893%
	GSTARX-JRNN(20,15,1)	194,659%	180,127%
Invers Jarak	GSTARX-JRNN(20,1,1)	26,500%	31,035%
	GSTARX-JRNN(20,2,1)	25,280%	30,117%
	GSTARX-JRNN(20,3,1)	27,171%	30,211%
	GSTARX-JRNN(20,4,1)	41,285%	48,194%
	GSTARX-JRNN(20,5,1)	30,117%	40,596%
	GSTARX-JRNN(20,10,1)	31,548%	45,271%
	GSTARX-JRNN(20,15,1)	78,923%	67,073%
Korelasi Silang	GSTARX-JRNN(20,1,1)	26,617%	43,858%
	GSTARX-JRNN(20,2,1)	25,470%	41,647%
	GSTARX-JRNN(20,3,1)	25,615%	41,173%
	GSTARX-JRNN(20,4,1)	25,681%	45,256%
	GSTARX-JRNN(20,5,1)	34,916%	60,671%
	GSTARX-JRNN(20,10,1)	37,681%	62,494%
	GSTARX-JRNN(20,15,1)	147,681%	80,861%

Arsitektur model GSTARX-JRNN(20,3,1) dengan bobot seragam untuk *inflow* Rp20.000 diberikan pada Gambar 4.29. Selanjutnya dapat dituliskan persamaan model sebagai berikut.

$$\begin{aligned} \begin{pmatrix} \hat{Z}_{1,t}^3 \\ \hat{Z}_{2,t}^3 \\ \hat{Z}_{3,t}^3 \\ \hat{Z}_{4,t}^3 \\ \hat{Z}_{5,t}^3 \end{pmatrix} &= \begin{pmatrix} -0,23 & 0 & 0 & 0 & 0 \\ 0 & -0,12 & 0 & 0 & 0 \\ 0 & 0 & -0,18 & 0 & 0 \\ 0 & 0 & 0 & -0,25 & 0 \\ 0 & 0 & 0 & 0 & -0,82 \end{pmatrix} \begin{pmatrix} t_{1,t}^3 \\ t_{2,t}^3 \\ t_{3,t}^3 \\ t_{4,t}^3 \\ t_{5,t}^3 \end{pmatrix} + \begin{pmatrix} -89,40 & 0 & 0 & 0 & 0 \\ 0 & -36,63 & 0 & 0 & 0 \\ 0 & 0 & -42,82 & 0 & 0 \\ 0 & 0 & 0 & -124,79 & 0 \\ 0 & 0 & 0 & 0 & -213,83 \end{pmatrix} \begin{pmatrix} (D_1)_{1,t}^3 \\ (D_1)_{2,t}^3 \\ (D_1)_{3,t}^3 \\ (D_1)_{4,t}^3 \\ (D_1)_{5,t}^3 \end{pmatrix} + \dots + \\ &\quad \begin{pmatrix} 115,85 & 0 & 0 & 0 & 0 \\ 0 & 73,36 & 0 & 0 & 0 \\ 0 & 0 & 62,77 & 0 & 0 \\ 0 & 0 & 0 & 137,74 & 0 \\ 0 & 0 & 0 & 0 & 352,38 \end{pmatrix} \begin{pmatrix} (S_1)_{1,t}^3 \\ (S_1)_{2,t}^3 \\ (S_1)_{3,t}^3 \\ (S_1)_{4,t}^3 \\ (S_1)_{5,t}^3 \end{pmatrix} + \dots + \begin{pmatrix} 34,68 & 0 & 0 & 0 & 0 \\ 0 & 16,61 & 0 & 0 & 0 \\ 0 & 0 & 12,74 & 0 & 0 \\ 0 & 0 & 0 & 33,20 & 0 \\ 0 & 0 & 0 & 0 & 170,35 \end{pmatrix} \begin{pmatrix} (CV_{1,t})_{1,t}^3 \\ (CV_{1,t})_{2,t}^3 \\ (CV_{1,t})_{3,t}^3 \\ (CV_{1,t})_{4,t}^3 \\ (CV_{1,t})_{5,t}^3 \end{pmatrix} + \dots + \\ &\quad \begin{pmatrix} 45,50 & 0 & 0 & 0 & 0 \\ 0 & 28,16 & 0 & 0 & 0 \\ 0 & 0 & 13,03 & 0 & 0 \\ 0 & 0 & 0 & 23,05 & 0 \\ 0 & 0 & 0 & 0 & 91,86 \end{pmatrix} \begin{pmatrix} (CV_{1,t+1})_{1,t}^3 \\ (CV_{1,t+1})_{2,t}^3 \\ (CV_{1,t+1})_{3,t}^3 \\ (CV_{1,t+1})_{4,t}^3 \\ (CV_{1,t+1})_{5,t}^3 \end{pmatrix} + \begin{pmatrix} \varepsilon_{1,t}^3 \\ \varepsilon_{2,t}^3 \\ \varepsilon_{3,t}^3 \\ \varepsilon_{4,t}^3 \\ \varepsilon_{5,t}^3 \end{pmatrix} \end{aligned}$$

dengan

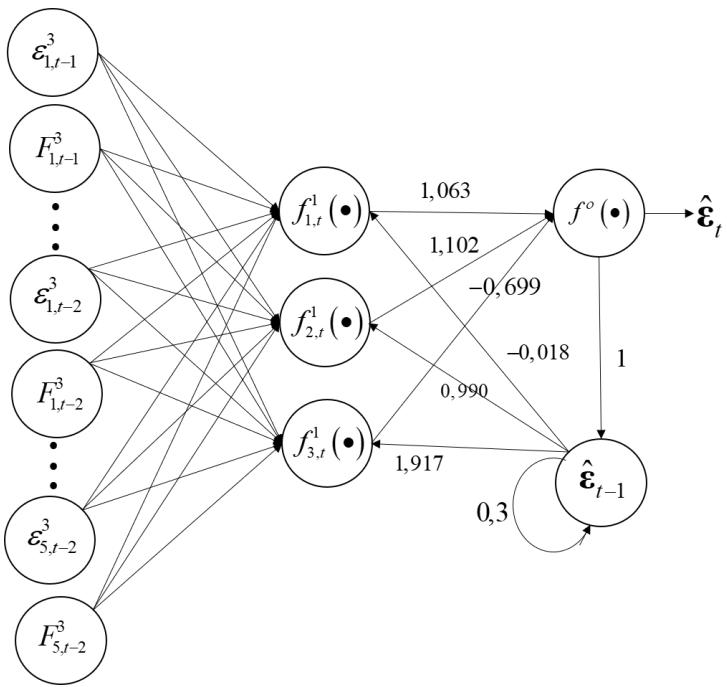
$$\hat{\varepsilon}_t = 1,063 \times \tanh f_{1,t}^1(\bullet) + 1,102 \times \tanh f_{2,t}^1(\bullet) - 0,699 \times \tanh f_{3,t}^1(\bullet)$$

dan

$$\begin{aligned} f_{1,t}^1(\bullet) &= 0,684\varepsilon_{1,t-1}^3 + 4,003\varepsilon_{2,t-1}^3 - 2,896\varepsilon_{3,t-1}^3 + 9,966\varepsilon_{4,t-1}^3 - 1,908\varepsilon_{5,t-1}^3 + 2,644F_{1,t-1}^3 + \\ &\quad 2,522F_{2,t-1}^3 - 5,028F_{3,t-1}^3 + 7,415F_{4,t-1}^3 - 8,074F_{5,t-1}^3 + 0,776\varepsilon_{1,t-2}^3 - \\ &\quad 3,710\varepsilon_{2,t-2}^3 + 3,732\varepsilon_{3,t-2}^3 - 1,957\varepsilon_{4,t-2}^3 - 0,040\varepsilon_{5,t-2}^3 + 4,120F_{1,t-2}^3 + \\ &\quad 4,416F_{2,t-2}^3 + 1,097F_{3,t-2}^3 - 10,329F_{4,t-2}^3 + 4,443F_{5,t-2}^3 - 0,018\hat{\varepsilon}_{t-1} \end{aligned}$$

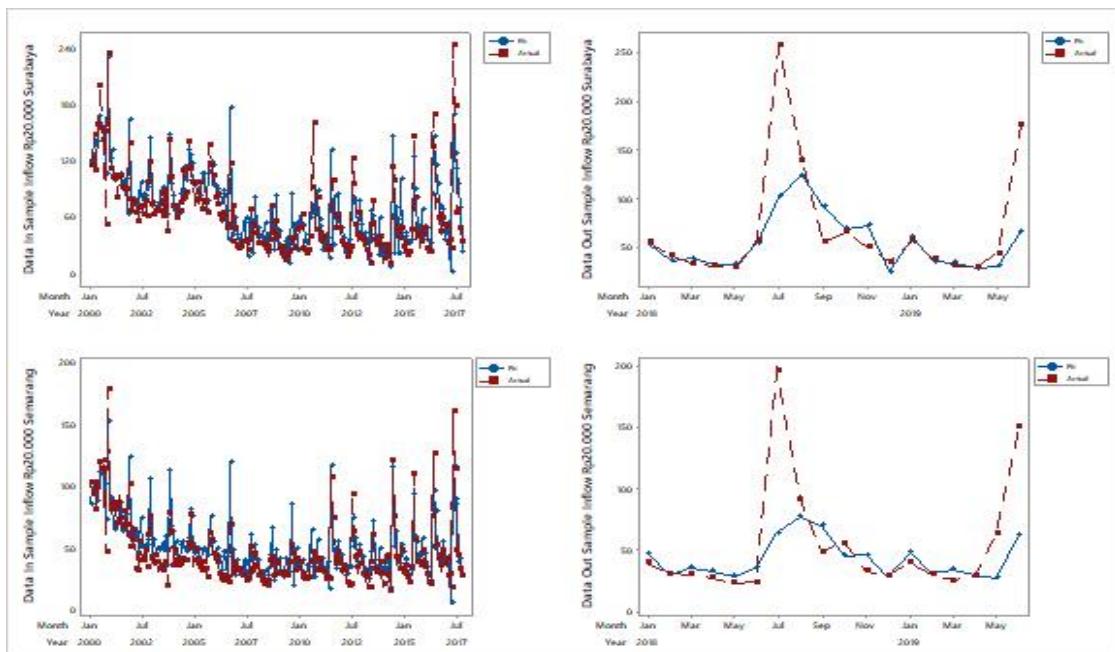
$$\begin{aligned} f_{2,t}^1(\bullet) &= 12,282\varepsilon_{1,t-1}^3 + 7,605\varepsilon_{2,t-1}^3 - 1,901\varepsilon_{3,t-1}^3 - 3,074\varepsilon_{4,t-1}^3 + 2,279\varepsilon_{5,t-1}^3 - 5,175F_{1,t-1}^3 - \\ &\quad 4,596F_{2,t-1}^3 + 1,328F_{3,t-1}^3 + 0,697F_{4,t-1}^3 - 1,145F_{5,t-1}^3 + 3,686\varepsilon_{1,t-2}^3 - \\ &\quad 2,355\varepsilon_{2,t-2}^3 + 1,600\varepsilon_{3,t-2}^3 + 1,903\varepsilon_{4,t-2}^3 - 0,927\varepsilon_{5,t-2}^3 + 0,023F_{1,t-2}^3 + \\ &\quad 0,703F_{2,t-2}^3 - 0,526F_{3,t-2}^3 - 0,134F_{4,t-2}^3 + 3,032F_{5,t-2}^3 + 0,990\hat{\varepsilon}_{t-1} \end{aligned}$$

$$\begin{aligned} f_{3,t}^1(\bullet) &= -1,696\varepsilon_{1,t-1}^3 + 4,127\varepsilon_{2,t-1}^3 - 4,406\varepsilon_{3,t-1}^3 - 6,672\varepsilon_{4,t-1}^3 - 3,391\varepsilon_{5,t-1}^3 - 1,450F_{1,t-1}^3 - \\ &\quad 5,165F_{2,t-1}^3 + 0,314F_{3,t-1}^3 + 2,444F_{4,t-1}^3 - 0,267F_{5,t-1}^3 + 0,869\varepsilon_{1,t-2}^3 - \\ &\quad 3,175\varepsilon_{2,t-2}^3 + 1,078\varepsilon_{3,t-2}^3 + 1,408\varepsilon_{4,t-2}^3 - 0,795\varepsilon_{5,t-2}^3 + 0,359F_{1,t-2}^3 + \\ &\quad 0,964F_{2,t-2}^3 - 0,242F_{3,t-2}^3 - 1,208F_{4,t-2}^3 + 1,615F_{5,t-2}^3 + 1,916\hat{\varepsilon}_{t-1} \end{aligned}$$

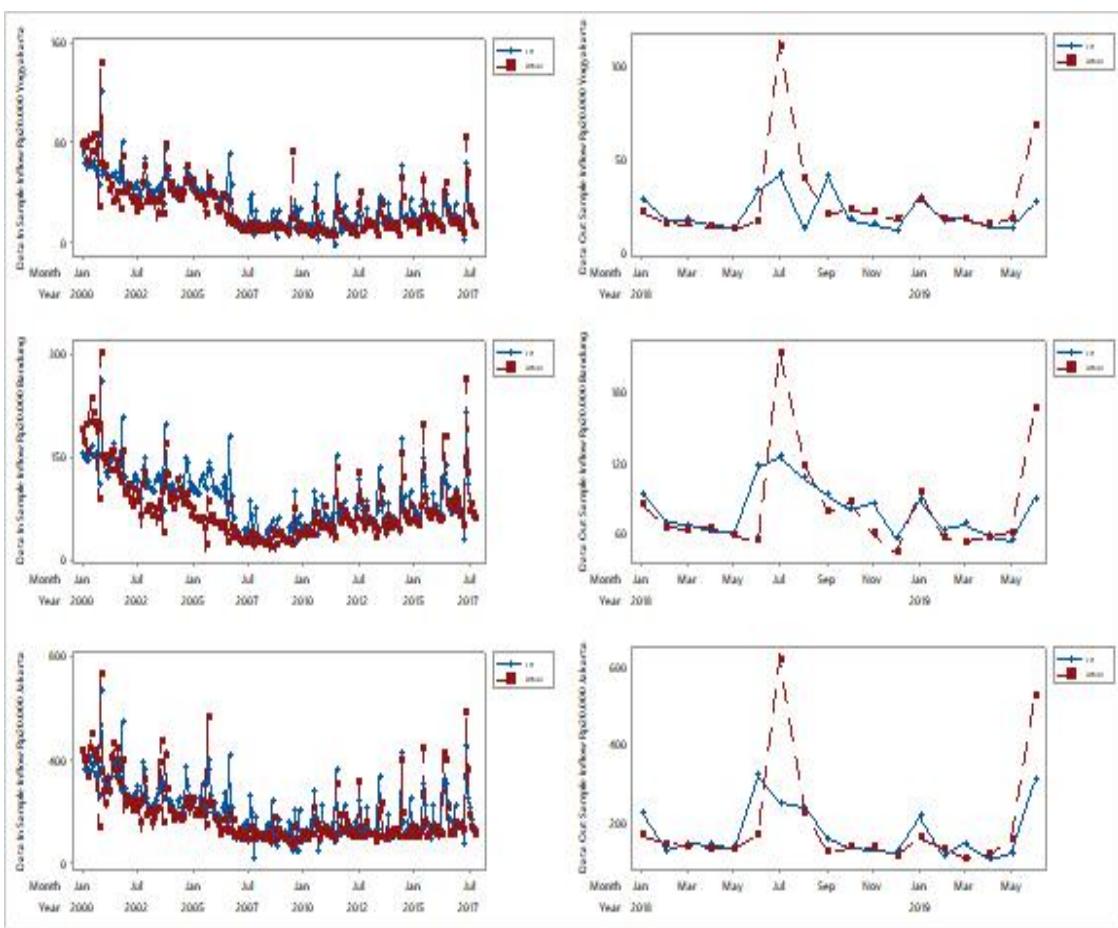


**Gambar 4.29.** Arsitektur Model GSTARX-JRNN Data *Inflow* Rp20.000

Plot perbandingan hasil pemodelan GSTARX-JRNN(20,3,1) bobot seragam dengan data aktual dari *inflow* pecahan Rp20.000 divisualisasikan pada Gambar 4.30.



**Gambar 4.30.** Perbandingan Data Aktual *Inflow* Rp20.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX-JRNN(20,3,1) dengan Seragam *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.30.** Perbandingan Data Aktual *Inflow* Rp20.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model GSTARX-JRNN(20,3,1) dengan Seragam *in sample* (kiri) dan *out sample* (kanan) (lanjutan)

#### 4.8 Pemodelan *Multivariate GSTARX (MGSTARX)* Data *Inflow* dan *Outflow* UPB di KPw Bank Sentral di Pulau Jawa

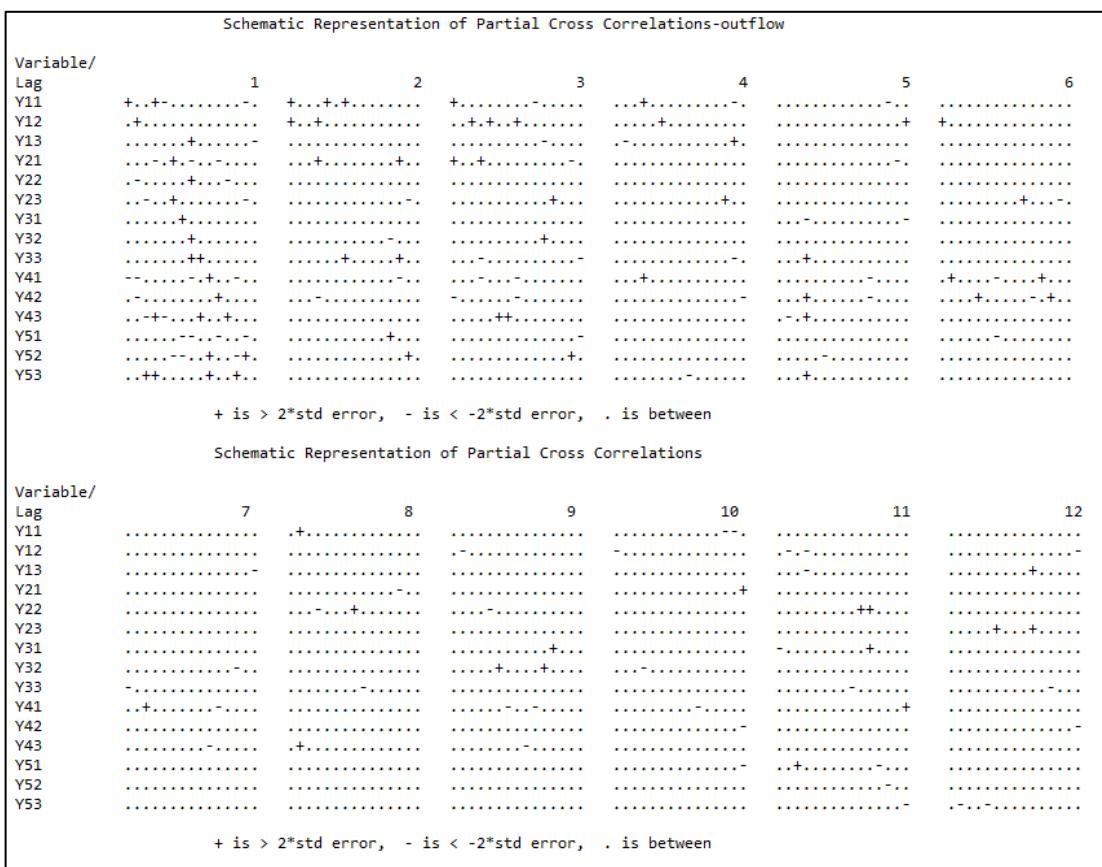
Pemodelan *Multivariate GSTARX (MGSTARX)* dilakukan dengan dua tahap pemodelan, yaitu pemodelan *time series regression* (TSR) sebagai pemodelan tahap pertama dan pemodelan residual TSR dengan model MGSTAR sebagai tahap kedua. Model MGSTAR menggunakan lebih dari satu variabel pengamatan di setiap lokasi. Pada penelitian ini, diduga variabel pecahan Rp100.000 tidak hanya memiliki keterkaitan dengan variabel pecahan Rp100.000 di lokasi lain tetapi juga berkaitan dengan variabel UPB lainnya, yaitu pecahan Rp50.000 dan Rp20.000. Nilai koefisien korelasi data *inflow* dan *outflow* antar uang pecahan besar (UPB) KPw Bank Sentral di Pulau Jawa diberikan pada Tabel 4.27.

**Tabel 4.27.** Koefisien Korelasi Data *Inflow* dan *Outflow* antar Uang Pecahan Besar (UPB) KPw Bank Sentral Provinsi di Pulau Jawa

Lokasi	Pecahan	<i>Inflow</i>			<i>Outflow</i>		
		Rp100.000	Rp50.000	Rp20.000	Rp100.000	Rp50.000	Rp20.000
Surabaya	Rp100.000	1,000	0,876	0,169	1,000	0,890	0,499
	Rp50.000	0,876	1,000	0,350	0,890	1,000	0,579
	Rp20.000	0,169	0,350	1,000	0,499	0,579	1,000
Semarang	Rp100.000	1,000	0,928	0,204	1,000	0,907	0,543
	Rp50.000	0,928	1,000	0,296	0,907	1,000	0,643
	Rp20.000	0,204	0,296	1,000	0,543	0,643	1,000
Yogyakarta	Rp100.000	1,000	0,915	0,003	1,000	0,933	0,452
	Rp50.000	0,915	1,000	0,193	0,933	1,000	0,481
	Rp20.000	0,003	0,193	1,000	0,452	0,481	1,000
Bandung	Rp100.000	1,000	0,947	0,139	1,000	0,947	0,652
	Rp50.000	0,947	1,000	0,173	0,947	1,000	0,661
	Rp20.000	0,139	0,173	1,000	0,652	0,661	1,000
Jakarta	Rp100.000	1,000	0,832	0,105	1,000	0,776	0,287
	Rp50.000	0,832	1,000	0,174	0,776	1,000	0,395
	Rp20.000	0,105	0,174	1,000	0,287	0,395	1,000

Berdasarkan Tabel 4.27 dapat diketahui bahwa pecahan Rp100.000 dan Rp50.000 memiliki nilai koefisien korelasi yang besar baik data *inflow* maupun *outflow*. Namun, pecahan Rp20.000 memiliki nilai koefisien korelasi yang relatif kecil terhadap pecahan Rp100.000 ataupun pecahan Rp50.000 pada data *inflow*. Sedangkan *outflow* Rp20.000 memiliki nilai koefisien yang cukup besar terhadap pecahan lainnya meskipun lebih kecil bila dibandingkan dengan korelasi pecahan Rp100.000 dengan Rp50.000. Sehingga dapat disimpulkan bahwa pecahan Rp100.000 dan Rp50.000 memiliki keterkaitan yang cukup tinggi dibandingkan dengan pecahan Rp20.000.

Selanjutnya dilakukan penentuan orde MGSTAR dengan menggunakan plot MPCCF yang dapat dilihat pada Gambar 4.31. Berdasarkan plot MPCCF diketahui bahwa semua lokasi dan setiap pecahan signifikan pada *lag* satu sedangkan pada *lag* yang lain tidak terdapat lokasi dan pecahan yang signifikan secara bersamaan. Sehingga orde untuk model MGSTARX data *outflow* adalah MGSTARX(1<sub>1</sub>). Selanjutnya pemodelan MGSTARX *outflow* setiap UPB di semua KPw Bank Sentral Provinsi di Jawa mengikuti model MGSTARX(1<sub>1</sub>).



**Gambar 4.31.** Plot MPCCF Residual Model TSR *Outflow* UPB KPw Bank Sentral di Jawa

Setelah menentukan orde model selanjutnya dilakukan proses pemodelan seperti pada pemodelan GSTARX tetapi dengan melibatkan variabel pecahan lain di setiap lokasi. Pemodelan MGSTARX menggunakan bobot-bobot lokasi yang sama dengan pemodelan GSTAR. Pemilihan bobot lokasi didasarkan pada nilai rata-rata RMSE dan sMAPE terkecil. Nilai RMSE dan sMAPE hasil pemodelan MGSTARX *outflow* ditunjukkan pada Tabel 4.28 dan Tabel 4.29.

**Tabel 4.28.** Nilai RMSE Model MGSTARX *Outflow* UPB KPw Bank Sentral di Jawa

Bobot	Lokasi	Pecahan					
		Rp100.000		Rp50.000		Rp20.000	
		<i>In</i>	<i>Out</i>	<i>In</i>	<i>Out</i>	<i>In</i>	<i>Out</i>
		Sample	Sample	Sample	Sample	Sample	Sample
Seragam	Surabaya	349,2303	1045,78	279,6961	377,4872	40,1500	105,1775
	Semarang	247,4088	913,5875	145,9251	439,4347	23,2035	73,9627
	Yogyakarta	157,1565	433,4616	99,6895	252,5891	14,8682	45,6421
	Bandung	398,098	1064,486	231,2139	523,3053	27,8201	108,921
	Jakarta	1489,873	3140,727	1142,479	1772,052	167,940	306,582
Invers	Surabaya	353,5517	1109,673	281,2225	388,8151	40,6536	107,9797
Jarak	Semarang	253,0259	963,5845	146,9867	453,7278	23,3305	75,9831

**Tabel 4.28.** Nilai RMSE Model MGSTARX *Outflow* UPB KPw Bank Sentral di Jawa (lanjutan)

Bobot	Lokasi	Pecahan					
		Rp100.000		Rp50.000		Rp20.000	
		<i>In Sample</i>	<i>Out Sample</i>	<i>In Sample</i>	<i>Out Sample</i>	<i>In Sample</i>	<i>Out Sample</i>
Invers Jarak	Yogyakarta	161,2547	457,3684	100,7897	264,9902	14,9969	46,2549
	Bandung	402,5718	1128,31	233,823	540,6308	27,8524	108,7944
	Jakarta	1495,907	3294,704	1147,201	1788,294	167,849	314,157
Korelasi Silang	Surabaya	341,9096	1060,785	275,5298	361,0884	39,3582	102,95
	Semarang	244,2333	916,8266	146,2801	430,6626	22,8035	72,71568
	Yogyakarta	156,5246	447,4567	99,3859	265,9205	14,7266	45,28976
	Bandung	394,5527	1055,989	230,713	518,4162	27,4534	106,2741
	Jakarta	1473,808	3104,949	1142,772	1694,867	167,2885	306,9672

**Tabel 4.29.** Nilai sMAPE Model MGSTARX *Outflow* UPB KPw Bank Sentral di Jawa

Bobot	Lokasi	Pecahan					
		Rp100.000		Rp50.000		Rp20.000	
		<i>In Sample</i>	<i>Out Sample</i>	<i>In Sample</i>	<i>Out Sample</i>	<i>In Sample</i>	<i>Out Sample</i>
Seragam	Surabaya	41,798%	32,770%	32,139%	19,656%	72,219%	87,538%
	Semarang	57,887%	46,361%	44,974%	41,895%	50,268%	93,470%
	Yogyakarta	49,120%	35,272%	46,311%	30,636%	48,126%	99,791%
	Bandung	52,038%	44,406%	45,261%	33,520%	57,451%	81,066%
	Jakarta	41,514%	25,182%	25,666%	20,648%	48,744%	73,262%
Invers Jarak	Surabaya	39,906%	34,057%	31,049%	19,877%	69,320%	74,459%
	Semarang	56,659%	47,410%	45,029%	41,483%	46,995%	92,133%
	Yogyakarta	48,824%	37,772%	46,702%	30,465%	46,775%	103,241%
	Bandung	52,147%	47,311%	44,763%	34,047%	56,595%	77,275%
	Jakarta	41,169%	25,535%	25,682%	21,112%	48,616%	72,188%
Korelasi Silang	Surabaya	41,901%	31,91%	32,532%	20,698%	71,232%	92,328%
	Semarang	58,998%	45,924%	45,437%	39,476%	49,987%	93,11%
	Yogyakarta	49,504%	34,612%	46,164%	31,042%	48,3%	89,407%
	Bandung	52,946%	44,021%	45,202%	32,946%	57,680%	82,511%
	Jakarta	41,704%	24,509%	25,459%	20,420%	49,243%	72,580%

Berdasarkan nilai rata-rata RMSE dan sMAPE terkecil dipilih model MGSTARX dengan bobot korelasi silang sebagai model MGSTARX terbaik untuk data *outflow*.

**Tabel 4.30.** Estimasi Parameter MGSTARX *Outflow* dengan bobot Korelasi Silang

Variabel	Lokasi	Parameter	Koefisien	SE	t-value	p-value
Rp100.000	Surabaya	$\phi_{10}^1$	0,10460	0,06839	1,5294	0,1277
		$\phi_{10}^{1*}$	0,10940	0,07668	1,4267	0,1552
		$\phi_{10}^{1**}$	-0,14191	0,39954	-0,3552	0,7228
		$\phi_{11}^1$	-0,15843	0,07460	-2,1237	0,0349
		$\phi_{11}^{1*}$	-0,39036	0,12531	-3,1153	0,0021
		$\phi_{11}^{1**}$	0,86785	0,19615	4,4244	$\approx 0,000$
Rp100.000	Semarang	$\phi_{20}^1$	0,13846	0,06313	2,1931	0,0294
		$\phi_{20}^{1*}$	-0,20191	0,10053	-2,0085	0,0458
		$\phi_{20}^{1**}$	-0,08629	0,46754	-0,1846	0,8538
		$\phi_{21}^1$	-0,14034	0,04626	-3,0336	0,0027
		$\phi_{21}^{1*}$	-0,10440	0,06825	-1,5297	0,1276
		$\phi_{21}^{1**}$	1,64055	0,22369	7,3341	$\approx 0,000$
Rp100.000	Yogyakarta	$\phi_{30}^1$	0,18484	0,06371	2,9015	0,0041
		$\phi_{30}^{1*}$	-0,07449	0,12021	-0,6197	0,5361
		$\phi_{30}^{1**}$	-0,62155	0,48149	-1,2909	0,1982
		$\phi_{31}^1$	-0,12804	0,02482	-5,1582	0,0000
		$\phi_{31}^{1*}$	-0,05706	0,03784	-1,5079	0,1331
		$\phi_{31}^{1**}$	0,94211	0,16009	5,8848	$\approx 0,000$
Rp50.000	Bandung	$\phi_{40}^1$	0,09778	0,07161	1,3654	0,1736
		$\phi_{40}^{1*}$	-0,06630	0,11876	-0,5583	0,5772
		$\phi_{40}^{1**}$	-0,84111	0,59224	-1,4202	0,1570
		$\phi_{41}^1$	-0,29384	0,06449	-4,5562	$\approx 0,000$
		$\phi_{41}^{1*}$	-0,08779	0,08994	-0,9761	0,3302
		$\phi_{41}^{1**}$	2,99651	0,38920	7,8258	$\approx 0,000$
Rp50.000	Jakarta	$\phi_{50}^1$	-0,00052	0,07663	-0,0068	0,9946
		$\phi_{50}^{1*}$	-0,45053	0,08938	-5,0406	$\approx 0,000$
		$\phi_{50}^{1**}$	3,23644	0,62161	5,2065	$\approx 0,000$
		$\phi_{51}^1$	-1,81431	0,52786	-3,4371	0,0007
		$\phi_{51}^{1*}$	2,19833	0,92090	2,3871	0,0178
		$\phi_{51}^{1**}$	1,90707	3,27942	0,5815	0,5615
Rp50.000	Surabaya	$\phi_{10}^2$	0,38747	0,06559	5,9075	$\approx 0,000$
		$\phi_{10}^{2*}$	-0,06511	0,34224	-0,1902	0,8493
		$\phi_{10}^{2**}$	0,02657	0,05861	0,4535	0,6506
		$\phi_{11}^2$	-0,23957	0,10293	-2,3274	0,0209
		$\phi_{11}^{2*}$	0,57483	0,15986	3,5958	0,0004
		$\phi_{11}^{2**}$	-0,27244	0,06114	-4,4562	$\approx 0,000$

**Tabel 4.30.** Estimasi Parameter MGSTARX *Outflow* dengan bobot Korelasi Silang  
(lanjutan)

Variabel	Lokasi	Parameter	Koefisien	SE	t-value	p-value
Rp50.000	Semarang	$\phi_{20}^2$	0,26297	0,06305	4,1710	$\approx 0,000$
		$\phi_{20}^{2*}$	0,58954	0,29628	1,9898	0,0479
		$\phi_{20}^{2**}$	-0,15199	0,03962	-3,8365	0,0002
		$\phi_{21}^2$	-0,03718	0,04155	-0,8948	0,3719
	Yogyakarta	$\phi_{21}^{2*}$	0,59941	0,13449	4,4571	$\approx 0,000$
		$\phi_{21}^{2**}$	-0,08508	0,02823	-3,0135	0,0029
		$\phi_{30}^2$	0,27269	0,06401	4,2599	$\approx 0,000$
		$\phi_{30}^{2*}$	0,20448	0,25931	0,7885	0,4313
	Bandung	$\phi_{30}^{2**}$	-0,02035	0,03385	-0,6012	0,5484
		$\phi_{31}^2$	-0,03281	0,02314	-1,4178	0,1577
		$\phi_{31}^{2*}$	0,43419	0,10054	4,3186	$\approx 0,000$
		$\phi_{31}^{2**}$	-0,10099	0,01508	-6,6957	$\approx 0,000$
		$\phi_{40}^2$	0,47080	0,07171	6,5654	$\approx 0,000$
		$\phi_{40}^{2*}$	-0,29802	0,35597	-0,8372	0,4034
		$\phi_{40}^{2**}$	-0,05274	0,04322	-1,2201	0,2238
		$\phi_{41}^2$	-0,16620	0,05336	-3,1146	0,0021
	Jakarta	$\phi_{41}^{2*}$	1,22423	0,22526	5,4348	$\approx 0,000$
		$\phi_{41}^{2**}$	-0,25406	0,03855	-6,5908	$\approx 0,000$
		$\phi_{50}^2$	0,22331	0,07193	3,1044	0,0021
		$\phi_{50}^{2*}$	0,50643	0,49167	1,0300	0,3042
		$\phi_{50}^{2**}$	-0,33461	0,06209	-5,3886	$\approx 0,000$
		$\phi_{51}^2$	-0,73136	0,75213	-0,9724	0,3319
		$\phi_{51}^{2*}$	1,67041	2,73113	0,6116	0,5415
		$\phi_{51}^{2**}$	0,54091	0,43077	1,2557	0,2106
	Rp20.000	$\phi_{10}^3$	0,10356	0,05407	1,9153	0,0568
		$\phi_{10}^{3*}$	0,00569	0,00936	0,6075	0,5442
		$\phi_{10}^{3**}$	0,00681	0,01050	0,6483	0,5175
		$\phi_{11}^3$	0,15317	0,02303	6,6506	$\approx 0,000$
		$\phi_{11}^{3*}$	-0,03244	0,00907	-3,5763	0,0004
		$\phi_{11}^{3**}$	0,00098	0,01519	0,0642	0,9489
		$\phi_{20}^3$	0,38989	0,05078	7,6778	$\approx 0,000$
		$\phi_{20}^{3*}$	-0,00002	0,00662	-0,0024	0,9981
	Semarang	$\phi_{20}^{3**}$	0,01101	0,01047	1,0515	0,2942
		$\phi_{21}^3$	0,07781	0,02138	3,6392	0,0003
		$\phi_{21}^{3*}$	-0,01026	0,00450	-2,2779	0,0237
		$\phi_{21}^{3**}$	-0,02323	0,00660	-3,5186	0,0005

**Tabel 4.30.** Estimasi Parameter MGSTARX *Outflow* dengan bobot Korelasi Silang (lanjutan)

Variabel	Lokasi	Parameter	Koefisien	SE	t-value	p-value
Yogyakarta	Rp20.000	$\phi_{30}^3$	0,38792	0,05056	7,6726	$\approx 0,000$
		$\phi_{30}^{3*}$	-0,00965	0,00668	-1,4441	0,1502
		$\phi_{30}^{3**}$	0,01236	0,01264	0,9776	0,3294
		$\phi_{31}^3$	0,06183	0,01535	4,0291	$\approx 0,000$
		$\phi_{31}^{3*}$	-0,00812	0,00243	-3,3462	0,0010
		$\phi_{31}^{3**}$	-0,00344	0,00367	-0,9365	0,3501
Bandung	Rp20.000	$\phi_{40}^3$	0,43414	0,04494	9,6597	$\approx 0,000$
		$\phi_{40}^{3*}$	-0,02073	0,00522	-3,9698	$\approx 0,000$
		$\phi_{40}^{3**}$	-0,01232	0,00867	-1,4221	0,1565
		$\phi_{41}^3$	0,15847	0,02689	5,8917	$\approx 0,000$
		$\phi_{41}^{3*}$	-0,00806	0,00460	-1,7537	0,0810
		$\phi_{41}^{3**}$	-0,00074	0,00645	-0,1147	0,9088
Jakarta		$\phi_{50}^3$	0,08817	0,07662	1,1508	0,2511
		$\phi_{50}^{2*}$	-0,00251	0,01067	-0,2350	0,8145
		$\phi_{50}^{3**}$	-0,02650	0,01235	-2,1468	0,0330
		$\phi_{51}^3$	0,31476	0,48787	0,6452	0,5195
		$\phi_{51}^{3*}$	-0,05962	0,07684	-0,7760	0,4386
		$\phi_{51}^{3**}$	0,14878	0,13442	1,1068	0,2696

Berdasarkan nilai estimasi parameter pada Tabel 4.30 dapat ditulis persamaan model MGSTARX dengan bobot korelasi silang untuk data *outflow* sebagai berikut.

$$\hat{Y}_{1,t}^1 = 7,379t - 88,963D_1 - 1857,102D_2 - 5,304tD_1 + 9,119tD_2 - 178,295S_1 - 26,256S_2 + \\ 206,674S_3 + 214,400S_4 + 215,658S_5 + 400,905S_6 + 296,427S_7 + 286,346S_8 + 134,960S_9 + \\ 60,664S_{10} + 81,380S_{11} + 687,911S_{12} + 1150,684CV_{1,t-1} + 482,220CV_{2,t-1} - 56,158CV_{3,t-1} + \\ 113,736CV_{4,t-1} - 395,676CV_{1,t} + 304,389CV_{2,t} + 788,906CV_{3,t} + 1155,960CV_{4,t} + \varepsilon_{1,t}^1$$

$$\hat{Y}_{2,t}^1 = 5,659t + 136,1D_1 - 1333D_2 - 6,125tD_1 + 6,154tD_2 - 212S_1 - 93,66S_2 - 49,77S_3 + \\ 15,65S_4 + 3,528S_5 + 333,7S_6 + 125,7S_7 - 34,07S_8 + 46,53S_9 - 125,4S_{10} - \\ 112,5S_{11} + 216,3S_{12} + 1072CV_{1,t-1} + 435,4CV_{2,t-1} - 51,35CV_{3,t-1} + 33,28CV_{4,t-1} - \\ 342,6CV_{1,t} + 418,3CV_{2,t} + 790,6CV_{3,t} + 1040CV_{4,t} + \varepsilon_{2,t}^1 \\ \vdots$$

$$\hat{Y}_{5,t}^1 = 35,418t - 646,017D_1 - 6794,721D_2 - 12,389tD_1 + 43,486tD_2 - 1519,650S_1 - 851,966S_2 + \\ 118,270S_3 + 182,546S_4 + 307,357S_5 + 1043,489S_6 + 618,620S_7 - 266,733S_8 - 431,998S_9 + \\ 57,310S_{10} + 49,672S_{11} + 2483,553S_{12} + 5153,147CV_{1,t-1} + 1827,980CV_{2,t-1} + 471,784CV_{3,t-1} + \\ 155,270CV_{4,t-1} - 1911,349CV_{1,t} + 1039,972CV_{2,t} + 4320,350CV_{3,t} + 5219,043CV_{4,t} + \varepsilon_{5,t}^1 \\ \vdots$$

$$\hat{Y}_{5,t}^2 = 16,292t - 95,990D_1 - 6171,123D_2 - 17,289tD_1 + 33,626tD_2 + 1080,290S_1 + 1690,413S_2 + \\ 2690,392S_3 + 2323,036S_4 + 2653,626S_5 + 2774,913S_6 + 2524,222S_7 + 1938,630S_8 + 1841,550S_9 + \\ 1976,848S_{10} + 2252,383S_{11} + 4277,443S_{12} + 5215,284CV_{1,t-1} + 2966,334CV_{2,t-1} - 316,466CV_{3,t-1} + \\ 12,359CV_{4,t-1} - 1286,672CV_{1,t} + 2674,198CV_{2,t} + 3153,032CV_{3,t} + 3831,203CV_{4,t} + \varepsilon_{5,t}^2 \\ \vdots$$

$$\hat{Y}_{5,t}^3 = -0,738t - 198,322D_1 - 263,529D_2 + 0,574tD_1 + 1,275tD_2 + 365,758S_1 + 320,251S_2 + 350,332S_3 + \\ 356,889S_4 + 521,927S_5 + 418,455S_6 + 431,169S_7 + 341,719S_8 + 268,995S_9 + 262,729S_{10} + \\ 216,161S_{11} + 367,185S_{12} + 707,347CV_{1,t-1} + 527,959CV_{2,t-1} + 442,210CV_{3,t-1} + 440,654CV_{4,t-1} - \\ 121,073CV_{1,t} + 27,104CV_{2,t} + 238,870CV_{3,t} + 394,049CV_{4,t} + \varepsilon_{5,t}^3$$

dengan

$$\hat{\varepsilon}_{1,t}^1 = 0,1046\varepsilon_{1,t-1}^1 + 0,1094\varepsilon_{1,t-1}^2 - 0,1419\varepsilon_{1,t-1}^3 - 0,0381\varepsilon_{2,t-1}^1 - 0,0393\varepsilon_{3,t-1}^1 - 0,0540\varepsilon_{4,t-1}^1 - \\ 0,0269\varepsilon_{5,t-1}^1 - 0,0939\varepsilon_{2,t-1}^2 - 0,0970\varepsilon_{3,t-1}^2 - 0,1331\varepsilon_{4,t-1}^2 - \\ 0,0664\varepsilon_{5,t-1}^2 + 0,2088\varepsilon_{2,t-1}^3 + 0,2156\varepsilon_{3,t-1}^3 + 0,2960\varepsilon_{4,t-1}^3 + 0,1475\varepsilon_{5,t-1}^3$$

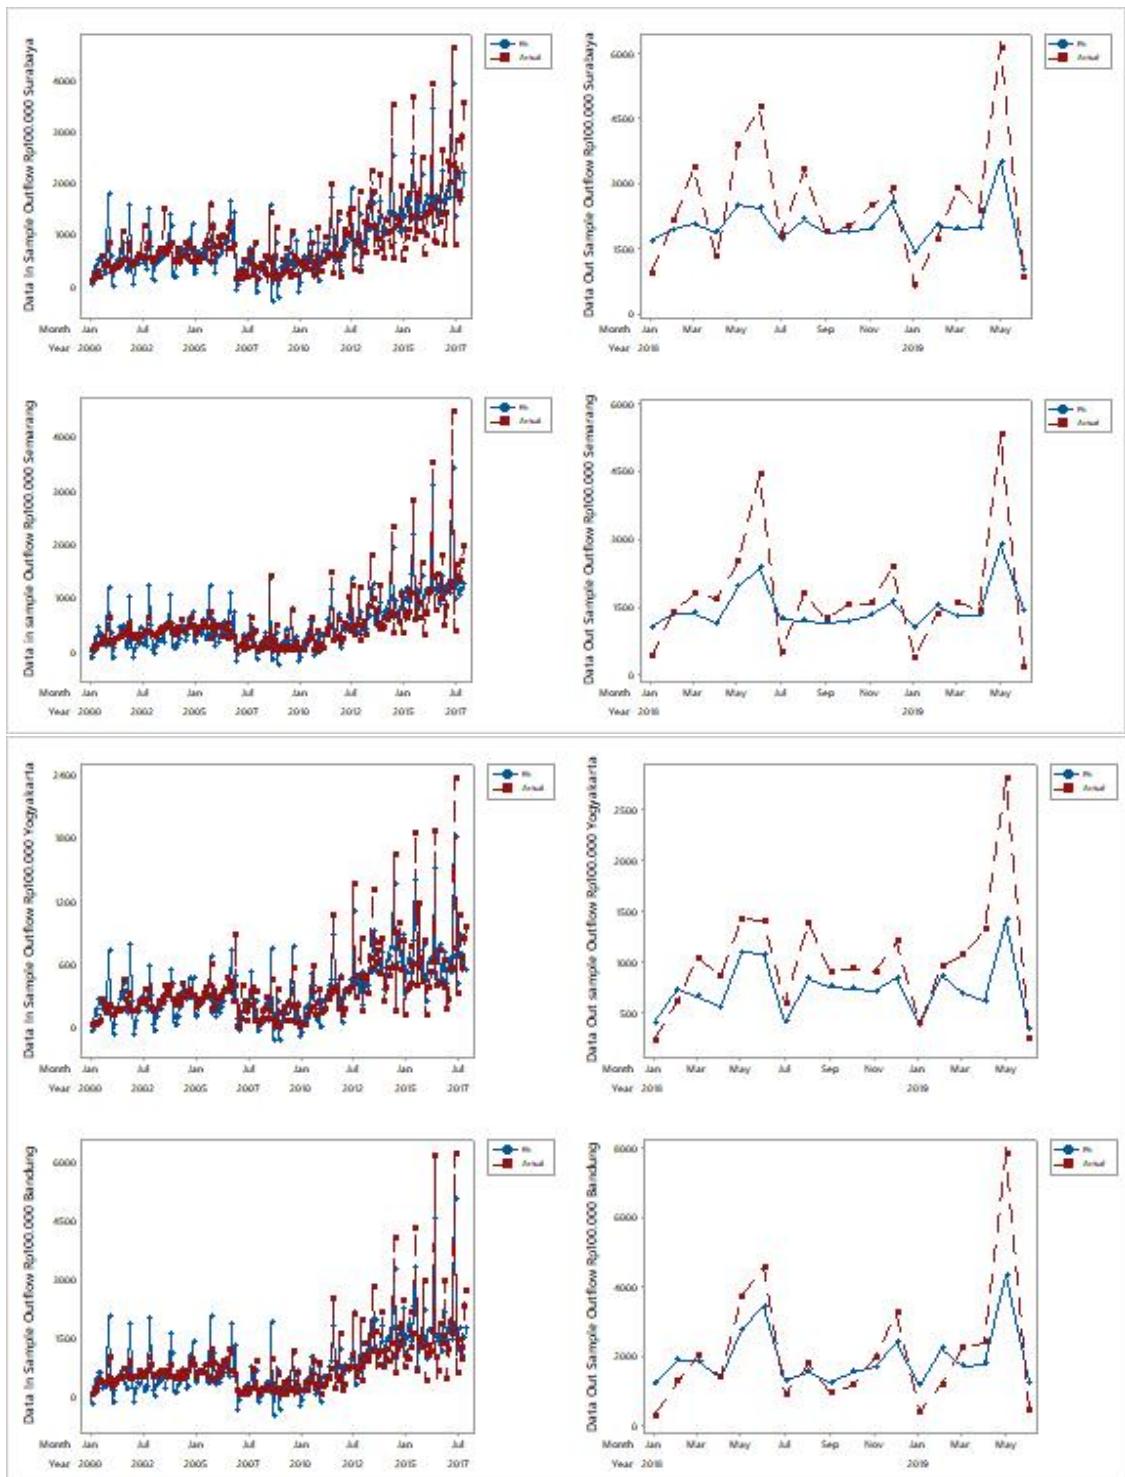
$$\hat{\varepsilon}_{2,t}^1 = 0,1385\varepsilon_{2,t-1}^1 - 0,2019\varepsilon_{2,t-1}^2 - 0,0863\varepsilon_{2,t-1}^3 - 0,0238\varepsilon_{3,t-1}^1 - 0,0384\varepsilon_{3,t-1}^2 - 0,0520\varepsilon_{4,t-1}^1 - \\ 0,0261\varepsilon_{5,t-1}^1 - 0,01770\varepsilon_{1,t-1}^2 - 0,0286\varepsilon_{3,t-1}^2 - 0,0387\varepsilon_{4,t-1}^2 - \\ 0,0194\varepsilon_{5,t-1}^2 + 0,2781\varepsilon_{1,t-1}^3 + 0,4492\varepsilon_{3,t-1}^3 + 0,6085\varepsilon_{4,t-1}^3 + 0,3050\varepsilon_{5,t-1}^3 \\ \vdots$$

$$\hat{\varepsilon}_{5,t}^1 = -0,0005\varepsilon_{5,t-1}^1 - 0,4505\varepsilon_{5,t-1}^2 + 3,2364\varepsilon_{5,t-1}^3 - 0,3688\varepsilon_{1,t-1}^1 - 0,3948\varepsilon_{2,t-1}^1 - 0,4347\varepsilon_{3,t-1}^1 - \\ 0,6160\varepsilon_{4,t-1}^1 + 0,4469\varepsilon_{1,t-1}^2 + 0,4784\varepsilon_{2,t-1}^2 + 0,5267\varepsilon_{3,t-1}^2 + \\ 0,7463\varepsilon_{4,t-1}^2 + 0,3877\varepsilon_{1,t-1}^3 + 0,4150\varepsilon_{2,t-1}^3 + 0,4569\varepsilon_{3,t-1}^3 + 0,6474\varepsilon_{4,t-1}^3 \\ \vdots$$

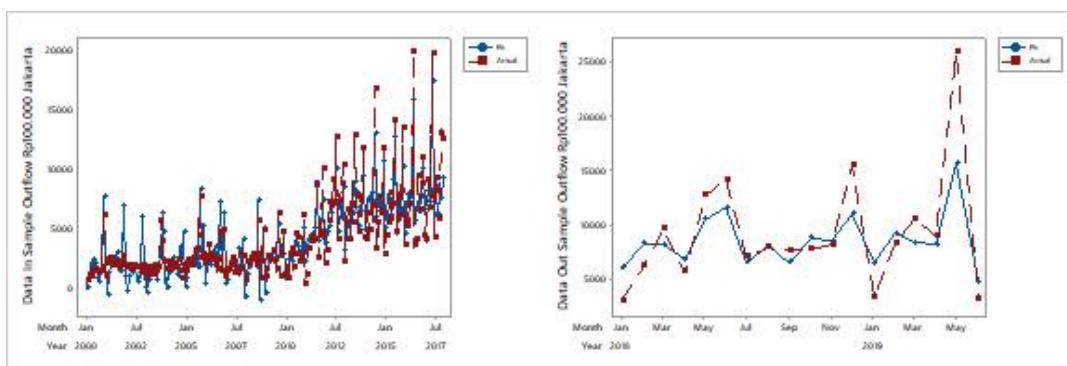
$$\hat{\varepsilon}_{5,t}^2 = 0,2233\varepsilon_{5,t-1}^2 + 0,5064\varepsilon_{5,t-1}^3 - 0,3346\varepsilon_{5,t-1}^1 - 0,1056\varepsilon_{1,t-1}^2 - 0,1603\varepsilon_{2,t-1}^2 - 0,2119\varepsilon_{3,t-1}^2 - \\ 0,2536\varepsilon_{4,t-1}^2 + 0,2412\varepsilon_{1,t-1}^3 + 0,3662\varepsilon_{2,t-1}^3 + 0,4839\varepsilon_{3,t-1}^3 + \\ 0,5791\varepsilon_{4,t-1}^3 + 0,0781\varepsilon_{1,t-1}^1 + 0,1186\varepsilon_{2,t-1}^1 + 0,1567\varepsilon_{3,t-1}^1 + 0,1875\varepsilon_{4,t-1}^1 \\ \vdots$$

$$\hat{\varepsilon}_{5,t}^3 = 0,0882\varepsilon_{5,t-1}^3 - 0,0025\varepsilon_{5,t-1}^1 - 0,0265\varepsilon_{5,t-1}^2 + 0,1012\varepsilon_{1,t-1}^3 + 0,1176\varepsilon_{2,t-1}^3 + 0,0335\varepsilon_{3,t-1}^3 + \\ 0,0625\varepsilon_{4,t-1}^3 - 0,0192\varepsilon_{1,t-1}^1 - 0,0223\varepsilon_{2,t-1}^1 - 0,0063\varepsilon_{3,t-1}^1 - \\ 0,0118\varepsilon_{4,t-1}^1 + 0,0478\varepsilon_{1,t-1}^2 + 0,0556\varepsilon_{2,t-1}^2 + 0,0158\varepsilon_{3,t-1}^2 + 0,0478\varepsilon_{4,t-1}^2$$

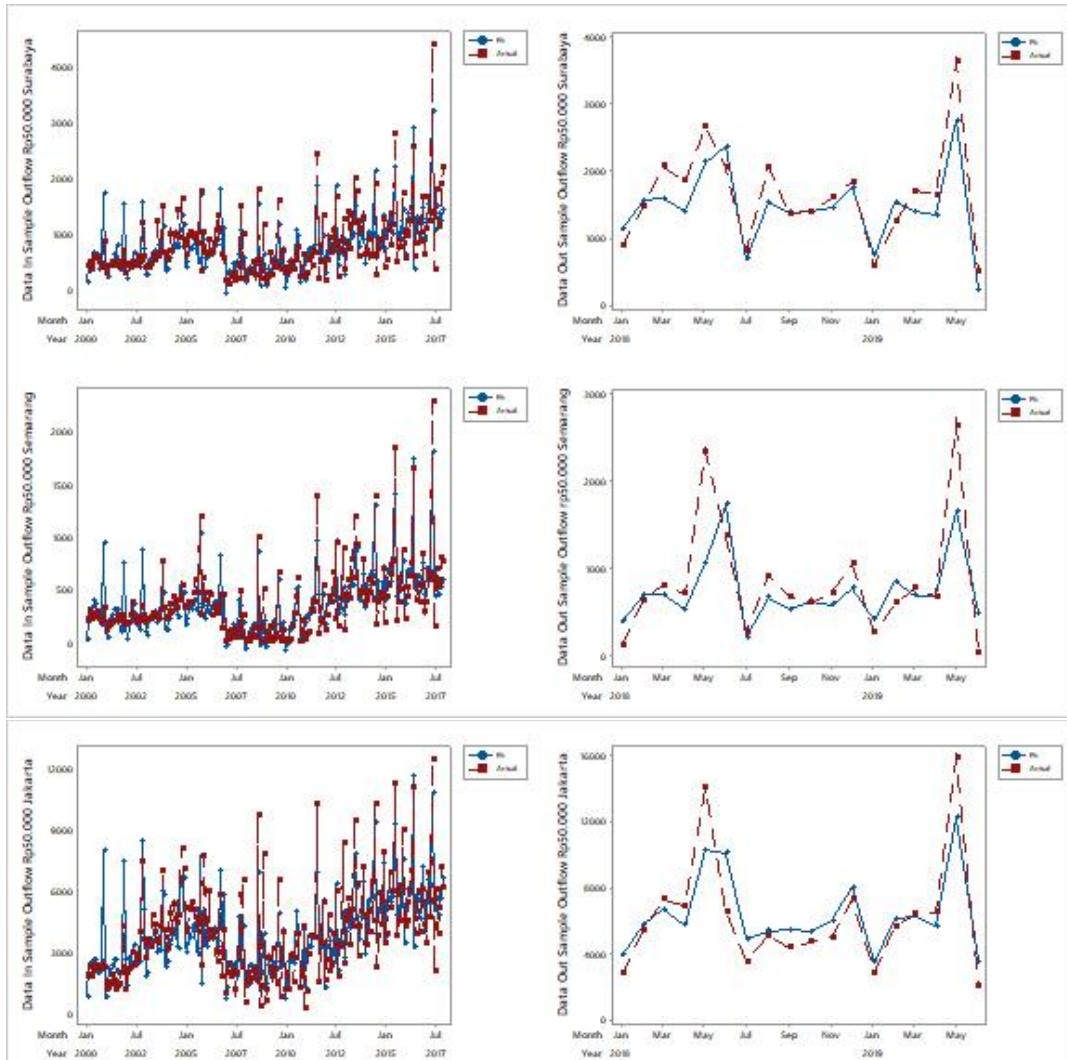
Selanjutnya plot perbandingan hasil pemodelan MGSTARX bobot korelasi silang dengan data aktual *outflow* ditunjukkan pada Gambar 4.32 hingga Gambar 4.34.



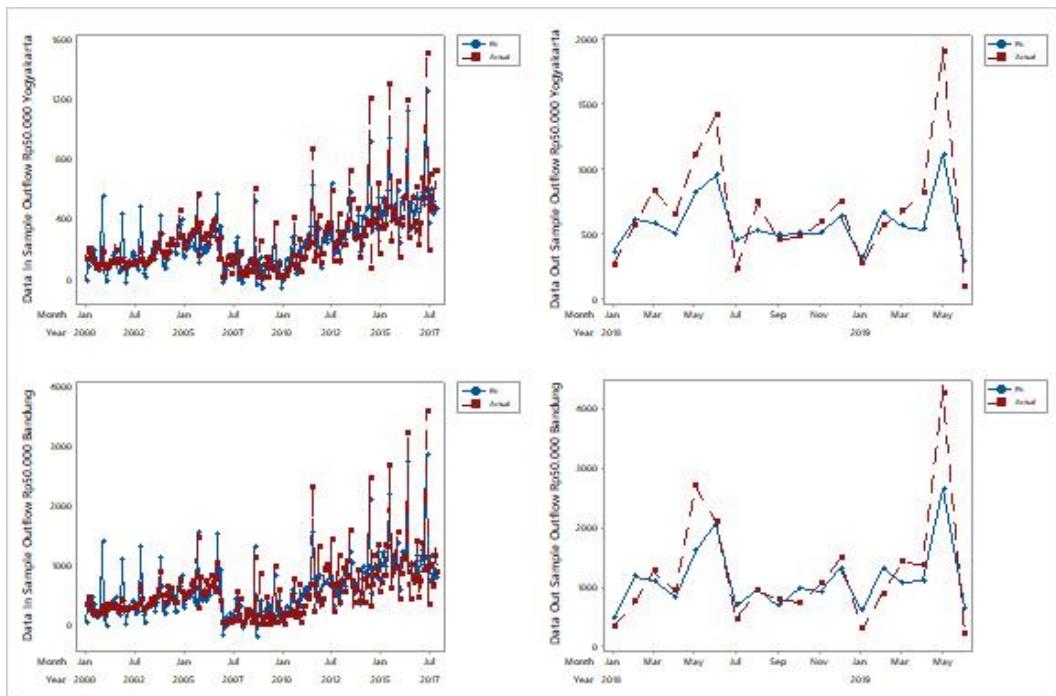
**Gambar 4.32.** Perbandingan Data Aktual *Outflow* Rp100.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan)



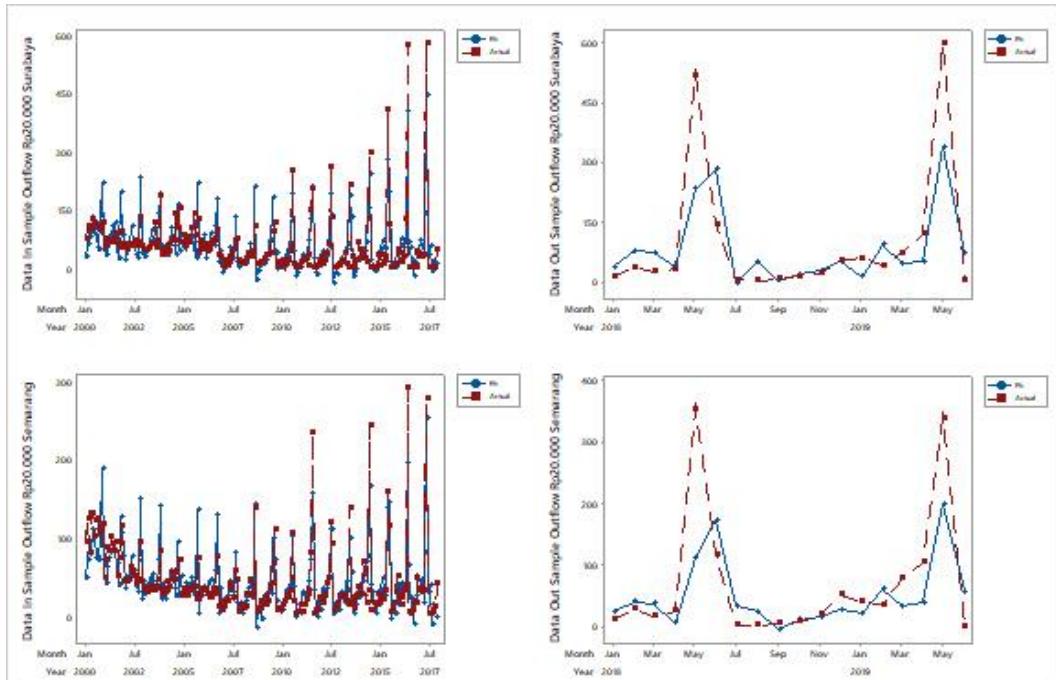
**Gambar 4.32.** Perbandingan Data Aktual *Outflow* Rp100.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan) (lanjutan)



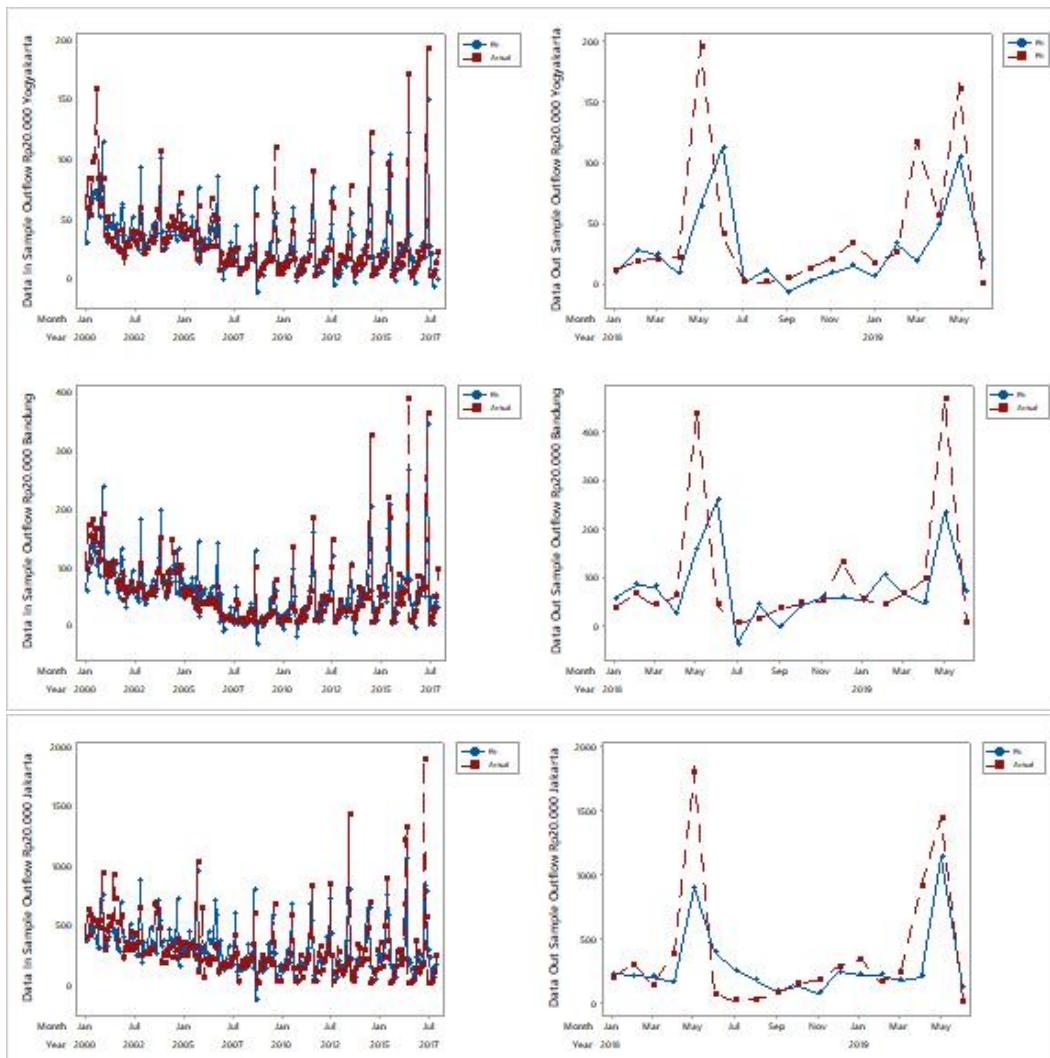
**Gambar 4.33** Perbandingan Data Aktual *Outflow* Rp50.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.33** Perbandingan Data Aktual *Outflow Rp50.000* di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan) (lanjutan)



**Gambar 4.34** Perbandingan Data Aktual *Outflow Rp20.000* di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.34** Perbandingan Data Aktual *Outflow* Rp20.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan) (lanjutan)

#### 4.9 Pemodelan MGSTARX-ERNN Data *Inflow* dan *Outflow* UPB di KPw Bank Sentral Provinsi di Pulau Jawa

Fungsi aktivasi, jumlah neuron dan jenis bobot lokasi yang digunakan dalam pemodelan ini sama dengan pemodelan GSTARX-ERNN. Hal yang membedakan adalah struktur data input pemodelan MGSTARX-ERNN. Penentuan *lag* input sesuai dengan orde MGSTARX pada pemodelan sebelumnya sehingga *lag* input yang digunakan adalah *lag* 1.

Pemodelan MGSTARX-ERNN melibatkan tiga variabel uang pecahan besar di setiap lokasi. Jadi, input yang digunakan meliputi  $\mathbf{\epsilon}_{1,t-1}^1, \mathbf{\epsilon}_{2,t-1}^1, \dots, \mathbf{\epsilon}_{1,t-1}^2, \dots, \mathbf{\epsilon}_{5,t-1}^3$  sebagai input yang menunjukkan hubungan *lag* variabel yang sama dan lokasi sama;  $\mathbf{F}_{1,t-1}^1, \mathbf{F}_{2,t-1}^1, \dots, \mathbf{F}_{1,t-1}^2, \dots, \mathbf{F}_{5,t-1}^3$  merupakan input yang menunjukkan hubungan *lag* variabel sama pada lokasi berbeda dengan struktur input sebagai berikut.

$$\mathbf{e}_{1,t-1}^1 = \begin{bmatrix} \mathbf{e}_{1,t-1}^1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \mathbf{e}_{2,t-1}^1 = \begin{bmatrix} 0 \\ \mathbf{e}_{2,t-1}^1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \dots, \mathbf{e}_{1,t-1}^2 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \dots, \mathbf{e}_{5,t-1}^3 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ \mathbf{e}_{5,t-1}^3 \end{bmatrix}$$

$$\mathbf{F}_{1,t-j}^1 = \begin{bmatrix} w_{12}\mathbf{e}_{2,t-1}^1 + w_{13}\mathbf{e}_{3,t-1}^1 + w_{14}\mathbf{e}_{4,t-1}^1 + w_{15}\mathbf{e}_{5,t-1}^1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \dots, \mathbf{F}_{5,t-1}^3 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ w_{51}\mathbf{e}_{1,t-1}^3 + w_{52}\mathbf{e}_{2,t-1}^3 + w_{53}\mathbf{e}_{3,t-1}^3 + w_{54}\mathbf{e}_{4,t-1}^3 \end{bmatrix}$$

Selanjutnya input  $\boldsymbol{\varepsilon}_{1,t-1}^{1\#}, \boldsymbol{\varepsilon}_{2,t-1}^{1\#}, \dots, \boldsymbol{\varepsilon}_{1,t-1}^{2\#}, \dots, \boldsymbol{\varepsilon}_{5,t-1}^{3\#}$  dan  $\boldsymbol{\varepsilon}_{1,t-1}^{1\#\#}, \boldsymbol{\varepsilon}_{2,t-1}^{1\#\#}, \dots, \boldsymbol{\varepsilon}_{1,t-1}^{2\#\#}, \dots, \boldsymbol{\varepsilon}_{5,t-1}^{3\#\#}$  menunjukkan hubungan *lag* variabel berbeda pada lokasi sama;

$\mathbf{F}_{1,t-1}^{1\#}, \mathbf{F}_{2,t-1}^{1\#}, \dots, \mathbf{F}_{5,t-1}^{1\#}$ ,  $\mathbf{F}_{1,t-1}^{2\#}, \dots, \mathbf{F}_{5,t-1}^{2\#}$  dan  $\mathbf{F}_{1,t-1}^{3\#}, \dots, \mathbf{F}_{5,t-1}^{3\#}$  merupakan input yang menunjukkan hubungan *lag* variabel berbeda pada lokasi yang berbeda. Struktur input yang digunakan dalam pemodelan MGSTARX-ERNN adalah sebagai berikut.

$$\boldsymbol{\varepsilon}_{1,t-1}^{1\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \dots, \boldsymbol{\varepsilon}_{1,t-1}^{2\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \dots, \boldsymbol{\varepsilon}_{1,t-1}^{3\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \dots, \boldsymbol{\varepsilon}_{5,t-1}^{3\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \end{bmatrix}$$

$$\boldsymbol{\varepsilon}_{1,t-1}^{1\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \dots, \boldsymbol{\varepsilon}_{1,t-1}^{2\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \dots, \boldsymbol{\varepsilon}_{1,t-1}^{3\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \dots, \boldsymbol{\varepsilon}_{5,t-1}^{3\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \end{bmatrix}$$

$$\mathbf{F}_{1,t-1}^{1\#} = \begin{bmatrix} \mathbf{0} \\ w_{12}\mathbf{\epsilon}_{2,t-1}^2 + w_{13}\mathbf{\epsilon}_{3,t-1}^2 + w_{14}\mathbf{\epsilon}_{4,t-1}^2 + w_{15}\mathbf{\epsilon}_{5,t-1}^2 \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \dots, \mathbf{F}_{1,t-1}^{2\#} = \begin{bmatrix} w_{12}\mathbf{\epsilon}_{2,t-1}^2 + w_{13}\mathbf{\epsilon}_{3,t-1}^2 + w_{14}\mathbf{\epsilon}_{4,t-1}^2 + w_{15}\mathbf{\epsilon}_{5,t-1}^2 \\ \mathbf{0} \end{bmatrix}, \dots$$

$$\mathbf{F}_{1,t-1}^{3\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{12}\mathbf{\epsilon}_{2,t-1}^3 + w_{13}\mathbf{\epsilon}_{3,t-1}^3 + w_{14}\mathbf{\epsilon}_{4,t-1}^3 + w_{15}\mathbf{\epsilon}_{5,t-1}^3 \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \dots, \mathbf{F}_{5,t-1}^{3\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{51}\mathbf{\epsilon}_{1,t-1}^3 + w_{52}\mathbf{\epsilon}_{2,t-1}^3 + w_{53}\mathbf{\epsilon}_{3,t-1}^3 + w_{54}\mathbf{\epsilon}_{4,t-1}^3 \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}$$

$$\mathbf{F}_{1,t-1}^{1\#\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{12}\boldsymbol{\epsilon}_{2,t-1}^1 + w_{13}\boldsymbol{\epsilon}_{3,t-1}^1 + w_{14}\boldsymbol{\epsilon}_{4,t-1}^1 + w_{15}\boldsymbol{\epsilon}_{5,t-1}^1 \\ \mathbf{0} \\ \mathbf{0} \\ \dots, \mathbf{F}_{1,t-1}^{2\#\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{12}\boldsymbol{\epsilon}_{2,t-1}^2 + w_{13}\boldsymbol{\epsilon}_{3,t-1}^2 + w_{14}\boldsymbol{\epsilon}_{4,t-1}^2 + w_{15}\boldsymbol{\epsilon}_{5,t-1}^2 \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix} \dots \end{bmatrix}$$

$$\mathbf{F}_{1,t-1}^{3\#\#} = \begin{bmatrix} w_{12}\boldsymbol{\epsilon}_{2,t-1}^3 + w_{13}\boldsymbol{\epsilon}_{3,t-1}^3 + w_{14}\boldsymbol{\epsilon}_{4,t-1}^3 + w_{15}\boldsymbol{\epsilon}_{5,t-1}^3 \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ \dots, \mathbf{F}_{5,t-1}^{3\#\#} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \mathbf{0} \\ w_{51}\boldsymbol{\epsilon}_{1,t-1}^3 + w_{52}\boldsymbol{\epsilon}_{2,t-1}^3 + w_{53}\boldsymbol{\epsilon}_{3,t-1}^3 + w_{54}\boldsymbol{\epsilon}_{4,t-1}^3 \\ \mathbf{0} \end{bmatrix} \end{bmatrix}$$

Selanjutnya dilakukan pemodelan MGSTARX-ERNN dengan mengkombinasikan jumlah neuron pada *hidden layer* dengan jenis bobot lokasi yang digunakan. Bobot lokasi dan neuron terbaik dipilih berdasarkan nilai rata-rata RMSE dan sMAPE *out sample* terkecil. Nilai rata-rata RMSE dan sMAPE pemodelan MGSTARX data *outflow* diberikan pada Tabel 4.31 dan Tabel 4.32. Berdasarkan nilai rata-rata terkecil dipilih model MGSTARX(90,2,1) dengan bobot seragam. Arsitektur model MGSTARX(90,2,1) data *outflow* ditunjukkan pada Gambar 4.35.

**Tabel 4.31.** Nilai Rata-Rata RMSE Model MGSTARX-ERNN *Outflow* Uang Pecahan Besar KPw Bank Sentral Provinsi di Jawa

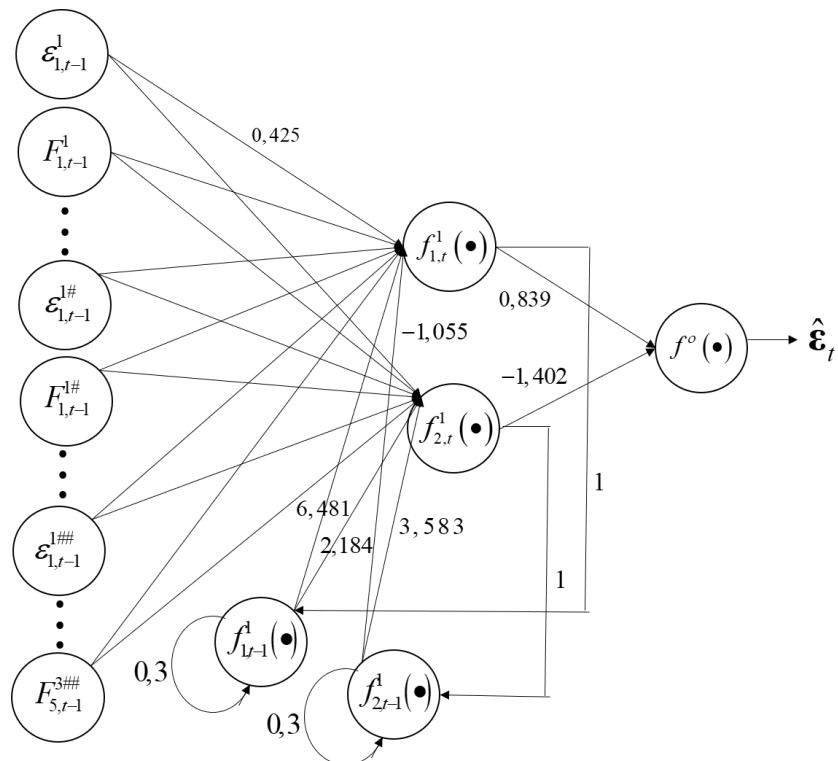
Bobot	Model	RMSE	
		In Sample	Out Sample
Seragam	MGSTARX-ERNN(90,1,1)	347,188	826,862
	MGSTARX-ERNN(90,2,1)*	375,645	826,570
	MGSTARX-ERNN(90,3,1)	593,518	888,515
	MGSTARX-ERNN(90,4,1)	476,999	925,743
	MGSTARX-ERNN(90,5,1)	542,878	849,422
	MGSTARX-ERNN(90,10,1)	592,509	1051,564
	MGSTARX-ERNN(90,15,1)	661,026	1069,117
Invers Jarak	MGSTARX-ERNN(90,1,1)	465,699	923,008
	MGSTARX-ERNN(90,2,1)	435,570	886,738
	MGSTARX-ERNN(90,3,1)	455,262	824,040
	MGSTARX-ERNN(90,4,1)	488,388	948,714
	MGSTARX-ERNN(90,5,1)	430,433	897,959
	MGSTARX-ERNN(90,10,1)	539,199	967,507
	MGSTARX-ERNN(90,15,1)	602,171	1022,257
Korelasi Silang	MGSTARX-ERNN(90,1,1)	352,681	829,856
	MGSTARX-ERNN(90,2,1)	455,476	880,959
	MGSTARX-ERNN(90,3,1)	469,836	885,864
	MGSTARX-ERNN(90,4,1)	446,557	862,365
	MGSTARX-ERNN(90,5,1)	451,188	920,615
	MGSTARX-ERNN(90,10,1)	486,858	1052,081
	MGSTARX-ERNN(90,15,1)	577,145	1028,294

**Tabel 4.32.** Nilai Rata-Rata sMAPE Model MGSTARX-ERNN *Outflow* Uang Pecahan Besar KPw Bank Sentral Provinsi di Jawa

Bobot	Model	sMAPE	
		In Sample	Out Sample
Seragam	MGSTARX-ERNN(90,1,1)	45,324%	51,804%
	MGSTARX-ERNN(90,2,1)*	54,843%	50,298%
	MGSTARX-ERNN(90,3,1)	62,009%	59,747%
	MGSTARX-ERNN(90,4,1)	55,828%	54,237%
	MGSTARX-ERNN(90,5,1)	56,544%	58,350%
	MGSTARX-ERNN(90,10,1)	58,306%	63,451%
	MGSTARX-ERNN(90,15,1)	59,765%	63,544%
Invers Jarak	MGSTARX-ERNN(90,1,1)	49,564%	52,425%
	MGSTARX-ERNN(90,2,1)	54,233%	53,781%
	MGSTARX-ERNN(90,3,1)	48,854%	51,368%

**Tabel 4.32.** Nilai Rata-Rata sMAPE Model MGSTARX-ERNN *Outflow* Uang Pecahan Besar KPw Bank Sentral Provinsi di Jawa (lanjutan)

Bobot	Model	sMAPE	
		In Sample	Out Sample
Invers	MGSTARX-ERNN(90,4,1)	56,541%	54,827%
	MGSTARX-ERNN(90,5,1)	48,721%	52,155%
	MGSTARX-ERNN(90,10,1)	51,814%	58,522%
	MGSTARX-ERNN(90,15,1)	58,946%	67,807%
Korelasi Silang	MGSTARX-ERNN(90,1,1)	45,725%	51,929%
	MGSTARX-ERNN(90,2,1)	57,509%	54,060%
	MGSTARX-ERNN(90,3,1)	67,036%	59,344%
	MGSTARX-ERNN(90,4,1)	49,982%	50,980%
	MGSTARX-ERNN(90,5,1)	49,582%	56,377%
	MGSTARX-ERNN(90,10,1)	56,703%	64,854%
	MGSTARX-ERNN(90,15,1)	56,374%	63,101%



**Gambar 4.35.** Arsitektur Model MGSTARX-ERNN(90,2,1) Data *Outflow*

$$\begin{aligned}
\hat{Y}_{1,t}^1 &= 7,379t - 88,963D_1 - 1857,102D_2 - 5,304tD_1 + 9,119tD_2 - 178,295S_1 - 26,256S_2 + \\
&\quad 206,674S_3 + 214,400S_4 + 215,658S_5 + 400,905S_6 + 296,427S_7 + 286,346S_8 + 134,960S_9 + \\
&\quad 60,664S_{10} + 81,380S_{11} + 687,911S_{12} + 1150,684CV_{1,t-1} + 482,220CV_{2,t-1} - 56,158CV_{3,t-1} + \\
&\quad 113,736CV_{4,t-1} - 395,676CV_{1,t} + 304,389CV_{2,t} + 788,906CV_{3,t} + 1155,960CV_{4,t} + \varepsilon_{1,t}^1 \\
\\
\hat{Y}_{2,t}^1 &= 5,659t + 136,1D_1 - 1333D_2 - 6,125tD_1 + 6,154tD_2 - 212S_1 - 93,66S_2 - 49,77S_3 + \\
&\quad 15,65S_4 + 3,528S_5 + 333,7S_6 + 125,7S_7 - 34,07S_8 + 46,53S_9 - 125,4S_{10} - \\
&\quad 112,5S_{11} + 216,3S_{12} + 1072CV_{1,t-1} + 435,4CV_{2,t-1} - 51,35CV_{3,t-1} + 33,28CV_{4,t-1} - \\
&\quad 342,6CV_{1,t} + 418,3CV_{2,t} + 790,6CV_{3,t} + 1040CV_{4,t} + \varepsilon_{2,t}^1 \\
&\quad \vdots \\
\hat{Y}_{5,t}^1 &= 35,418t - 646,017D_1 - 6794,721D_2 - 12,389tD_1 + 43,486tD_2 - 1519,650S_1 - 851,966S_2 + \\
&\quad 118,270S_3 + 182,546S_4 + 307,357S_5 + 1043,489S_6 + 618,620S_7 - 266,733S_8 - 431,998S_9 + \\
&\quad 57,310S_{10} + 49,672S_{11} + 2483,553S_{12} + 5153,147CV_{1,t-1} + 1827,980CV_{2,t-1} + 471,784CV_{3,t-1} + \\
&\quad 155,270CV_{4,t-1} - 1911,349CV_{1,t} + 1039,972CV_{2,t} + 4320,350CV_{3,t} + 5219,043CV_{4,t} + \varepsilon_{5,t}^1 \\
&\quad \vdots \\
\hat{Y}_{5,t}^2 &= 16,292t - 95,990D_1 - 6171,123D_2 - 17,289tD_1 + 33,626tD_2 + 1080,290S_1 + 1690,413S_2 + \\
&\quad 2690,392S_3 + 2323,036S_4 + 2653,626S_5 + 2774,913S_6 + 2524,222S_7 + 1938,630S_8 + 1841,550S_9 + \\
&\quad 1976,848S_{10} + 2252,383S_{11} + 4277,443S_{12} + 5215,284CV_{1,t-1} + 2966,334CV_{2,t-1} - 316,466CV_{3,t-1} + \\
&\quad 12,359CV_{4,t-1} - 1286,672CV_{1,t} + 2674,198CV_{2,t} + 3153,032CV_{3,t} + 3831,203CV_{4,t} + \varepsilon_{5,t}^2 \\
&\quad \vdots \\
\hat{Y}_{5,t}^3 &= -0,738t - 198,322D_1 - 263,529D_2 + 0,574tD_1 + 1,275tD_2 + 365,758S_1 + 320,251S_2 + 350,332S_3 + \\
&\quad 356,889S_4 + 521,927S_5 + 418,455S_6 + 431,169S_7 + 341,719S_8 + 268,995S_9 + 262,729S_{10} + \\
&\quad 216,161S_{11} + 367,185S_{12} + 707,347CV_{1,t-1} + 527,959CV_{2,t-1} + 442,210CV_{3,t-1} + 440,654CV_{4,t-1} - \\
&\quad 121,073CV_{1,t} + 27,104CV_{2,t} + 238,870CV_{3,t} + 394,049CV_{4,t} + \varepsilon_{5,t}^3
\end{aligned}$$

dengan

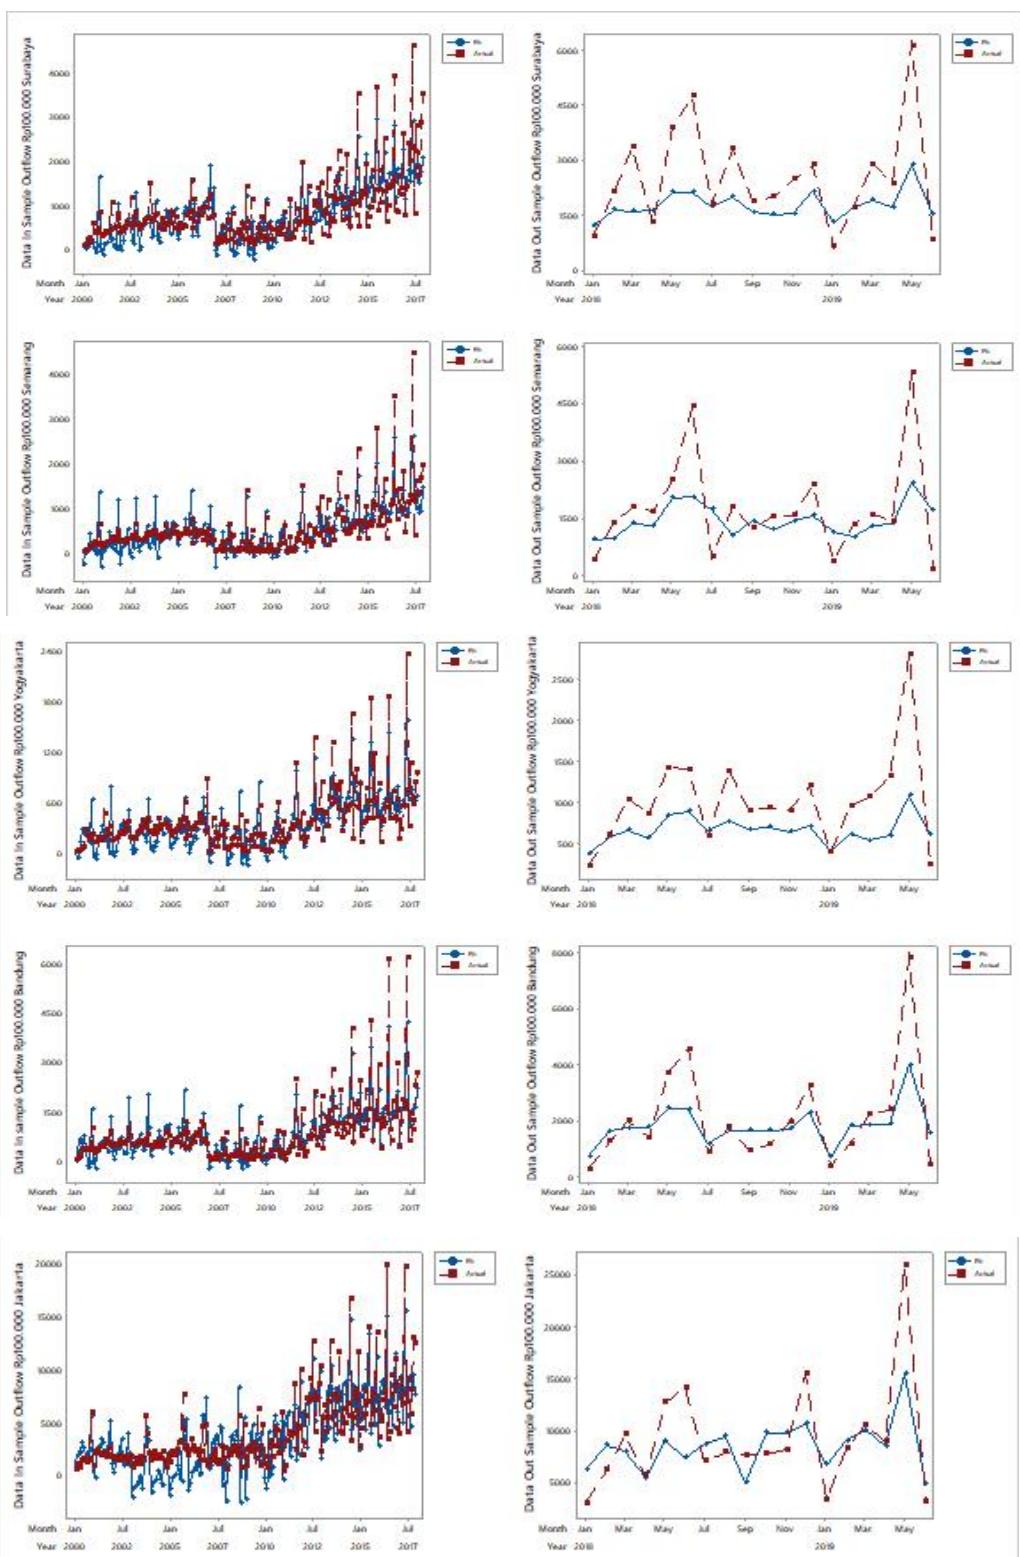
$$\hat{\varepsilon}_t = 0,839 \times \tanh f_{1,t}^1(\bullet) - 1,402 \times \tanh f_{2,t}^1(\bullet)$$

dan

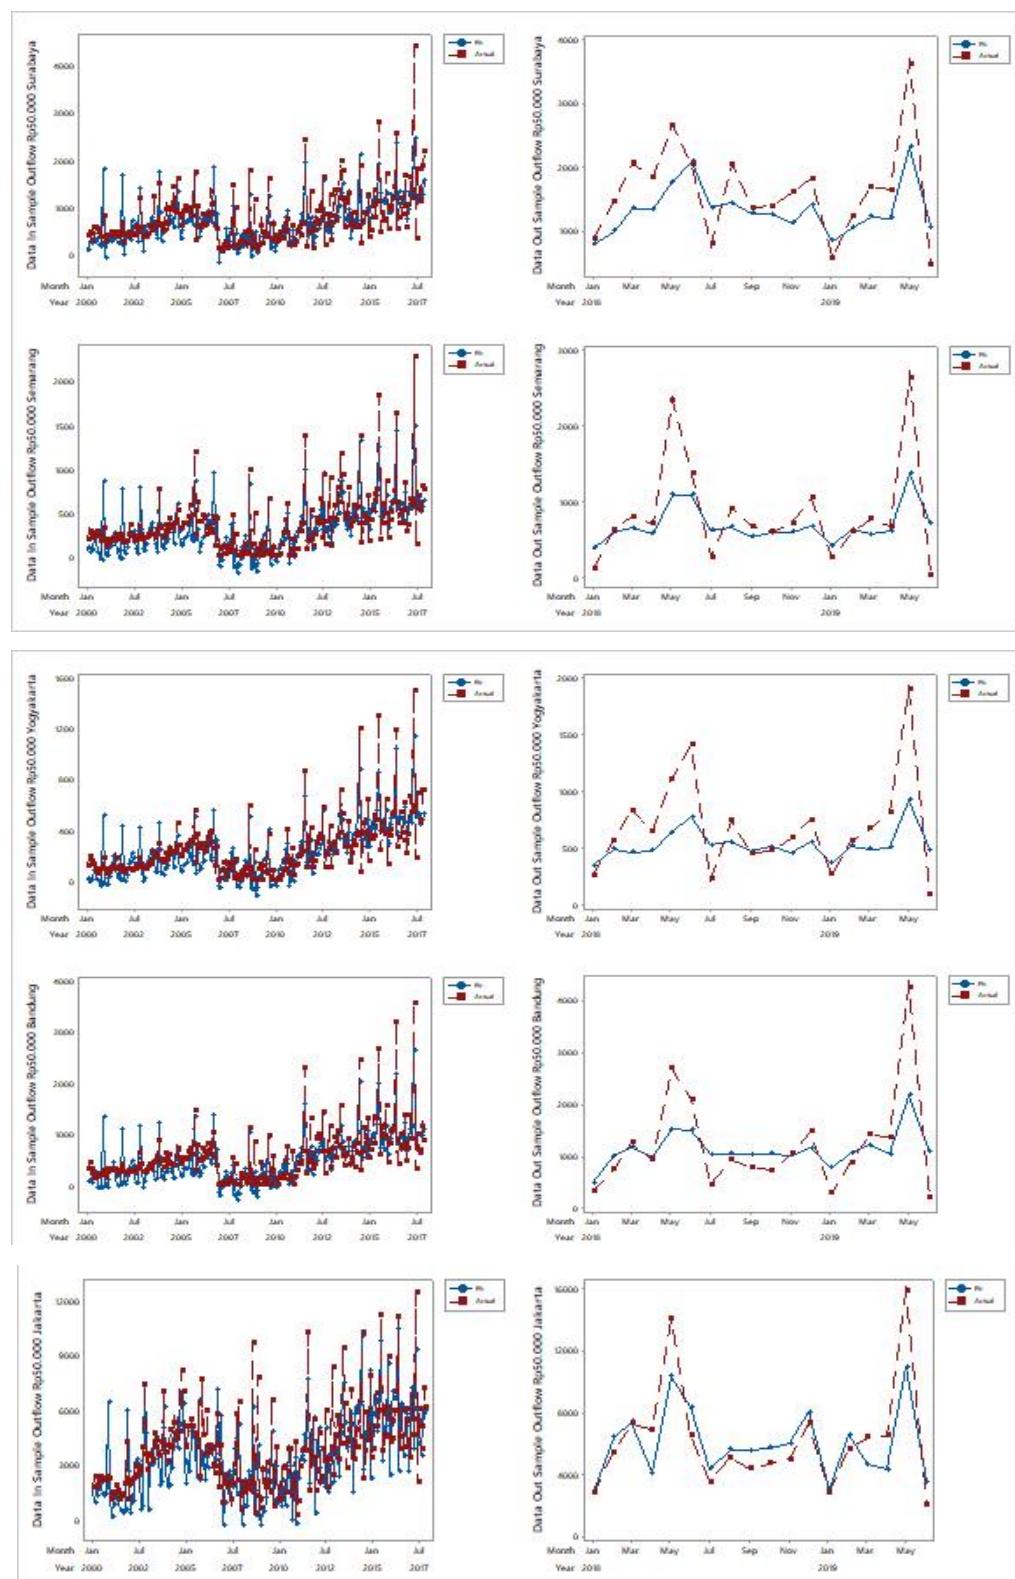
$$\begin{aligned}
f_{1,t}^1(\bullet) &= 5,154\varepsilon_{1,t-1}^1 + 1,523\varepsilon_{2,t-1}^1 + \dots + 0,164\varepsilon_{5,t-1}^3 + 0,534F_{1,t-1}^1 + \dots - 0,045F_{5,t-1}^3 - \\
&\quad 0,355\varepsilon_{1,t-1}^{1\#} + \dots + 9,709F_{5,t-1}^{3\#} - 3,017\varepsilon_{1,t-1}^{1\#\#} + \dots + 6,048F_{5,t-1}^{3\#\#} + 6,481f_{1,t-1}^1(\bullet) - 1,055f_{2,t-1}^1(\bullet)
\end{aligned}$$

$$\begin{aligned}
f_{2,t}^1(\bullet) &= 4,305\varepsilon_{1,t-1}^1 + 0,807\varepsilon_{2,t-1}^1 + \dots + 0,0465\varepsilon_{5,t-1}^3 + 0,847F_{1,t-1}^1 + \dots - 0,424F_{5,t-1}^3 - \\
&\quad 0,0467\varepsilon_{1,t-1}^{1\#} + \dots + 1,307F_{5,t-1}^{3\#} - 2,556\varepsilon_{1,t-1}^{1\#\#} + \dots - 5,209F_{5,t-1}^{3\#\#} + 2,184f_{1,t-1}^1(\bullet) + 3,583f_{2,t-1}^1(\bullet)
\end{aligned}$$

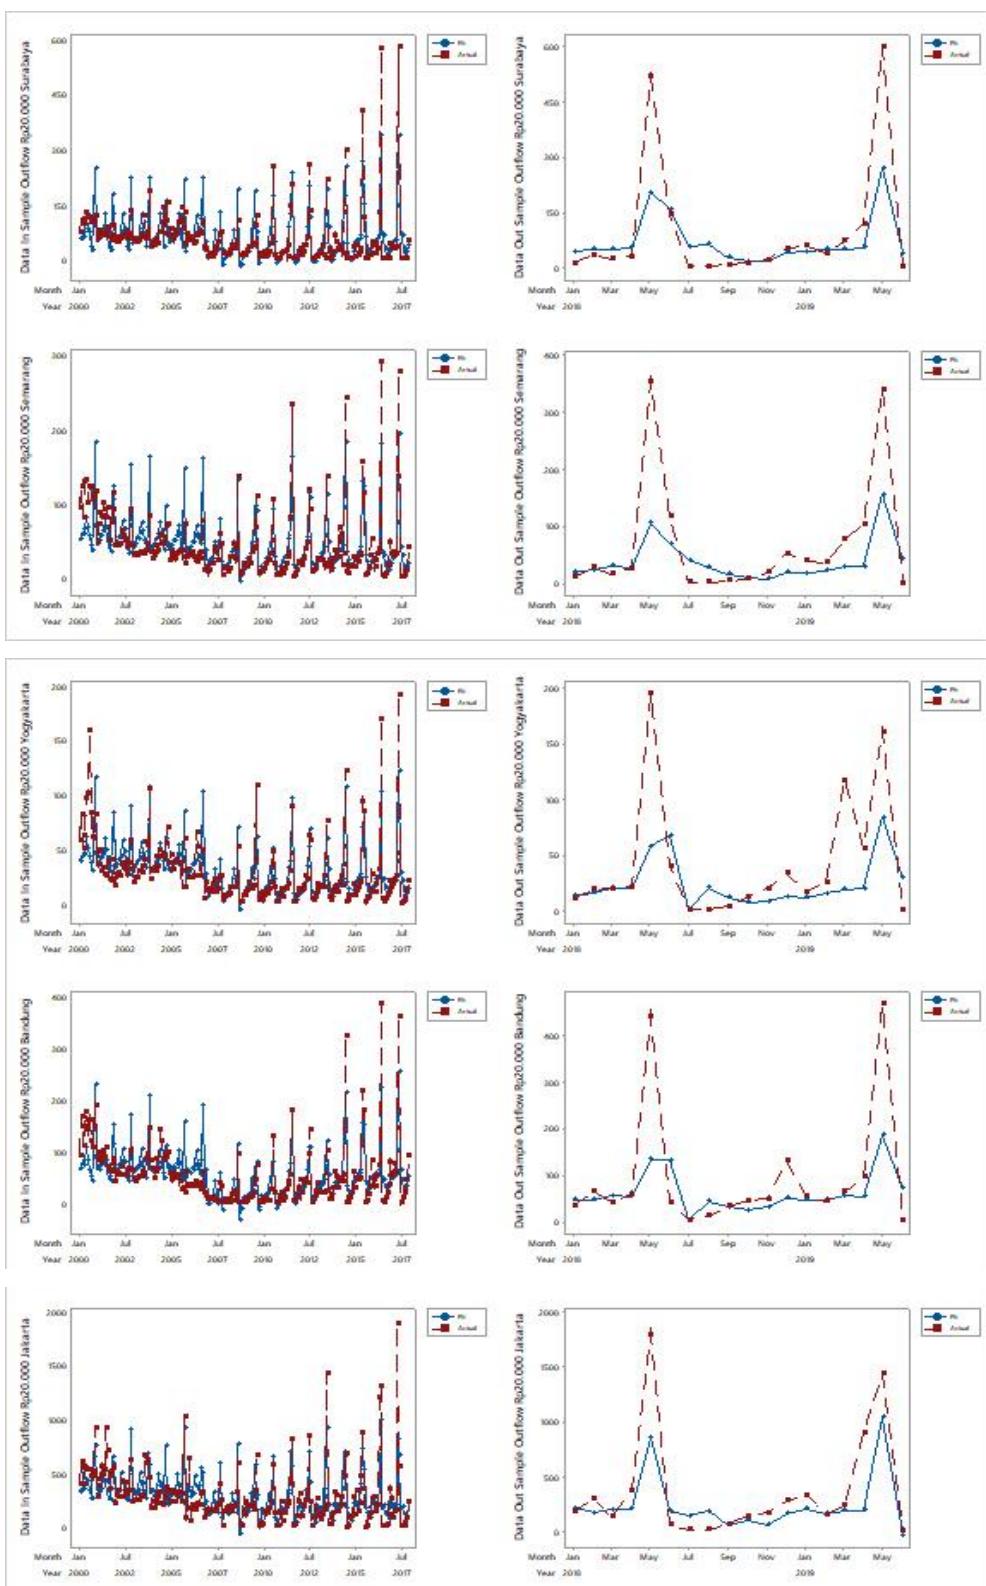
Selanjutnya plot perbandingan hasil pemodelan MGSTARX-ERNN(90,2,1) bobot seragam dengan data aktual *outflow* UPB KPw Bank Sentral Provinsi di Pulau Jawa divisualisasikan pada Gambar 4.36 hingga Gambar 4.38.



**Gambar 4.36** Perbandingan Data Aktual *Outflow* Rp100.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX-ERNN(90,2,1) dengan Bobot Seragam *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.37** Perbandingan Data Aktual *Outflow* Rp50.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX-ERNN(90,2,1) dengan Bobot Seragam *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.38** Perbandingan Data Aktual *Outflow* Rp20.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX-ERNN(90,2,1) dengan Bobot Seragam *in sample* (kiri) dan *out sample* (kanan)

#### **4.10 Pemodelan MGSTARX-JRNN Data *Inflow* dan *Outflow* UPB di KPw Bank Sentral Provinsi di Pulau Jawa**

Pemodelan MGSTARX-JRNN dilakukan dengan proses yang sama dengan MGSTARX-ERNN. Seperti yang telah dijelaskan sebelumnya hal yang membedakan adalah arsitektur jaringan dari MGSTARX-JRNN. Nilai rata-rata RMSE dan sMAPE pemodelan MGSTARX-JRNN data *outflow* ditampilkan pada Tabel 4.33 dan Tabel 4.34. Selanjutnya model terbaik yang dipilih berdasarkan nilai rata-rata RMSE dan sMAPE *out sample* terkecil yaitu MGSTARX-JRNN(90,2,1) dengan bobot korelasi silang.

**Tabel 4.33.** Nilai Rata-Rata RMSE Model MGSTARX-JRNN *Outflow* UPB KPw Bank Sentral Provinsi di Jawa

Bobot	Model	RMSE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	MGSTARX-JRNN(90,1,1)	348,582	824,108
	MGSTARX-JRNN(90,2,1)	371,528	798,237
	MGSTARX-JRNN(90,3,1)	484,612	801,115
	MGSTARX-JRNN(90,4,1)	446,541	811,920
	MGSTARX-JRNN(90,5,1)	566,752	932,598
	MGSTARX-JRNN(90,10,1)	648,191	942,520
	MGSTARX-JRNN(90,15,1)	804,167	1348,362
Invers Jarak	MGSTARX-JRNN(90,1,1)	464,997	918,399
	MGSTARX-JRNN(90,2,1)	410,221	820,419
	MGSTARX-JRNN(90,3,1)	598,931	924,686
	MGSTARX-JRNN(90,4,1)	563,889	985,410
	MGSTARX-JRNN(90,5,1)	478,925	876,857
	MGSTARX-JRNN(90,10,1)	645,753	909,340
	MGSTARX-JRNN(90,15,1)	977,027	1023,963
Korelasi Silang	MGSTARX-JRNN(90,1,1)	352,558	831,795
	MGSTARX-JRNN(90,2,1)*	355,197	788,135
	MGSTARX-JRNN(90,3,1)	484,612	801,115
	MGSTARX-JRNN(90,4,1)	544,448	879,802
	MGSTARX-JRNN(90,5,1)	687,692	925,757
	MGSTARX-JRNN(90,10,1)	677,503	916,747
	MGSTARX-JRNN(90,15,1)	905,693	1142,077

**Tabel 4.34 .** Nilai Rata-Rata sMAPE Model MGSTARX-JRNN *Outflow* KPw Bank Sentral Provinsi di Jawa

Bobot	Model	sMAPE	
		<i>In Sample</i>	<i>Out Sample</i>
Seragam	MGSTARX-JRNN(90,1,1)	45,483%	51,783%
	MGSTARX-JRNN(90,2,1)	48,489%	51,278%
	MGSTARX-JRNN(90,3,1)	51,351%	52,784%
	MGSTARX-JRNN(90,4,1)	49,683%	52,924%
	MGSTARX-JRNN(90,5,1)	60,940%	56,980%
	MGSTARX-JRNN(90,10,1)	56,940%	55,894%
	MGSTARX-JRNN(90,15,1)	73,941%	77,229%
Invers Jarak	MGSTARX-JRNN(90,1,1)	49,392%	51,839%
	MGSTARX-JRNN(90,2,1)	49,42%	51,280%
	MGSTARX-JRNN(90,3,1)	60,517%	60,286%
	MGSTARX-JRNN(90,4,1)	65,420%	87,125%
	MGSTARX-JRNN(90,5,1)	54,615%	53,702%
	MGSTARX-JRNN(90,10,1)	64,906%	62,311%
	MGSTARX-JRNN(90,15,1)	91,628%	75,240%
Korelasi Silang	MGSTARX-JRNN(90,1,1)	45,717%	51,927%
	MGSTARX-JRNN(90,2,1)*	47,650%	51,182%
	MGSTARX-JRNN(90,3,1)	51,351%	52,784%
	MGSTARX-JRNN(90,4,1)	55,203%	55,392%
	MGSTARX-JRNN(90,5,1)	72,148%	67,365%
	MGSTARX-JRNN(90,10,1)	68,476%	64,838%
	MGSTARX-JRNN(90,15,1)	79,456%	74,901%

Arsitektur model MGSTARX-JRNN(90,2,1) *outflow* dapat dilihat pada Gambar 4.39. Berdasarkan arsitektur jaringan persamaan model MGSTARX-JRNN dapat ditulis sebagai berikut.

$$\hat{Y}_{1,t}^1 = 7,379t - 88,963D_1 - 1857,102D_2 - 5,304tD_1 + 9,119tD_2 - 178,295S_1 - 26,256S_2 + 206,674S_3 + 214,400S_4 + 215,658S_5 + 400,905S_6 + 296,427S_7 + 286,346S_8 + 134,960S_9 + 60,664S_{10} + 81,380S_{11} + 687,911S_{12} + 1150,684CV_{1,t-1} + 482,220CV_{2,t-1} - 56,158CV_{3,t-1} + 113,736CV_{4,t-1} - 395,676CV_{1,t} + 304,389CV_{2,t} + 788,906CV_{3,t} + 1155,960CV_{4,t} + \varepsilon_{1,t}^1$$

$$\begin{aligned}\hat{Y}_{2,t}^1 &= 5,659t + 136,1D_1 - 1333D_2 - 6,125tD_1 + 6,154tD_2 - 212S_1 - 93,66S_2 - 49,77S_3 + 15,65S_4 + 3,528S_5 + 333,7S_6 + 125,7S_7 - 34,07S_8 + 46,53S_9 - 125,4S_{10} - 112,5S_{11} + 216,3S_{12} + 1072CV_{1,t-1} + 435,4CV_{2,t-1} - 51,35CV_{3,t-1} + 33,28CV_{4,t-1} - 342,6CV_{1,t} + 418,3CV_{2,t} + 790,6CV_{3,t} + 1040CV_{4,t} + \varepsilon_{2,t}^1 \\ &\vdots \\ \hat{Y}_{5,t}^1 &= 35,418t - 646,017D_1 - 6794,721D_2 - 12,389tD_1 + 43,486tD_2 - 1519,650S_1 - 851,966S_2 + 118,270S_3 + 182,546S_4 + 307,357S_5 + 1043,489S_6 + 618,620S_7 - 266,733S_8 - 431,998S_9 + 57,310S_{10} + 49,672S_{11} + 2483,553S_{12} + 5153,147CV_{1,t-1} + 1827,980CV_{2,t-1} + 471,784CV_{3,t-1} + 155,270CV_{4,t-1} - 1911,349CV_{1,t} + 1039,972CV_{2,t} + 4320,350CV_{3,t} + 5219,043CV_{4,t} + \varepsilon_{5,t}^1 \\ &\vdots \\ \hat{Y}_{5,t}^2 &= 16,292t - 95,990D_1 - 6171,123D_2 - 17,289tD_1 + 33,626tD_2 + 1080,290S_1 + 1690,413S_2 + 2690,392S_3 + 2323,036S_4 + 2653,626S_5 + 2774,913S_6 + 2524,222S_7 + 1938,630S_8 + 1841,550S_9 + 1976,848S_{10} + 2252,383S_{11} + 4277,443S_{12} + 5215,284CV_{1,t-1} + 2966,334CV_{2,t-1} - 316,466CV_{3,t-1} + 12,359CV_{4,t-1} - 1286,672CV_{1,t} + 2674,198CV_{2,t} + 3153,032CV_{3,t} + 3831,203CV_{4,t} + \varepsilon_{5,t}^2 \\ &\vdots \\ \hat{Y}_{5,t}^3 &= -0,738t - 198,322D_1 - 263,529D_2 + 0,574tD_1 + 1,275tD_2 + 365,758S_1 + 320,251S_2 + 350,332S_3 + 356,889S_4 + 521,927S_5 + 418,455S_6 + 431,169S_7 + 341,719S_8 + 268,995S_9 + 262,729S_{10} + 216,161S_{11} + 367,185S_{12} + 707,347CV_{1,t-1} + 527,959CV_{2,t-1} + 442,210CV_{3,t-1} + 440,654CV_{4,t-1} - 121,073CV_{1,t} + 27,104CV_{2,t} + 238,870CV_{3,t} + 394,049CV_{4,t} + \varepsilon_{5,t}^3\end{aligned}$$

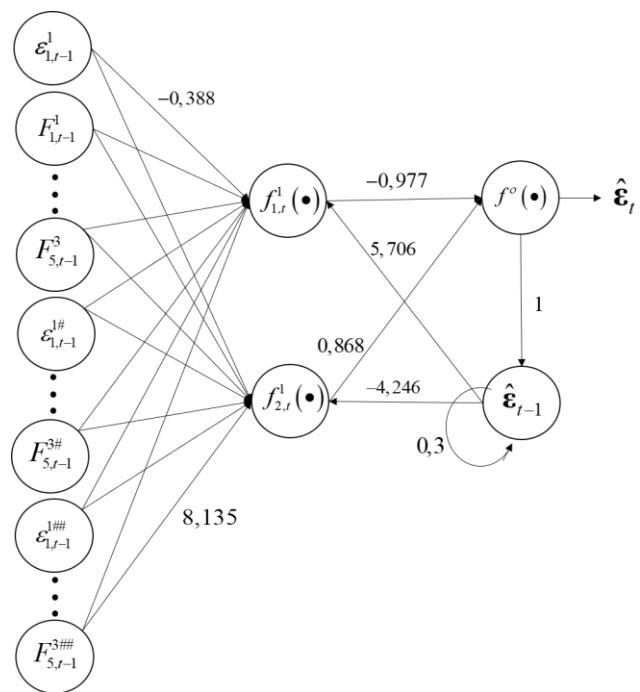
dengan

$$\hat{\boldsymbol{\varepsilon}}_t = -0,977 \times \tanh f_{1,t}^1(\bullet) + 0,868 \times \tanh f_{2,t}^1(\bullet)$$

dan

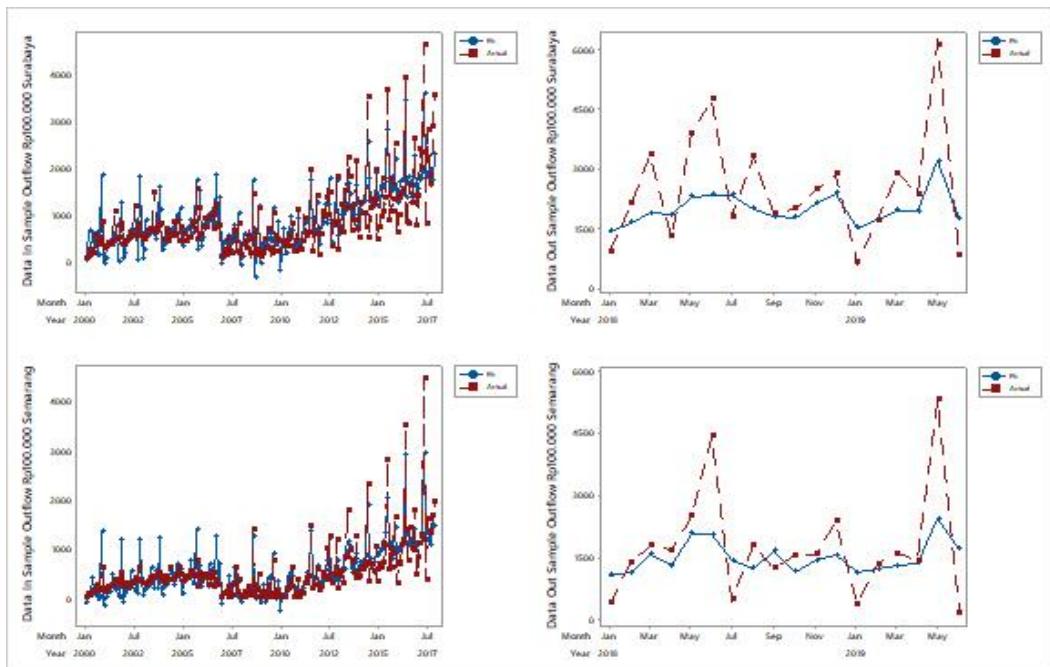
$$f_{1,t}^1(\bullet) = -0,388\boldsymbol{\varepsilon}_{1,t-1}^1 - 1,778\boldsymbol{\varepsilon}_{2,t-1}^1 + \dots - 0,995\boldsymbol{\varepsilon}_{5,t-1}^3 + 1,283\mathbf{F}_{1,t-1}^1 + \dots + 3,579\mathbf{F}_{5,t-1}^3 + 0,477\boldsymbol{\varepsilon}_{1,t-1}^{1\#} + \dots - 3,485\mathbf{F}_{5,t-1}^{3\#} + 1,390\boldsymbol{\varepsilon}_{1,t-1}^{1\#\#} + \dots - 4,251\mathbf{F}_{5,t-1}^{3\#\#} + 5,706\hat{\boldsymbol{\varepsilon}}_{t-1}$$

$$f_{2,t}^1(\bullet) = 2,244\boldsymbol{\varepsilon}_{1,t-1}^1 + 1,372\boldsymbol{\varepsilon}_{2,t-1}^1 + \dots - 0,229\boldsymbol{\varepsilon}_{5,t-1}^3 + 1,095\mathbf{F}_{1,t-1}^1 + \dots + 3,122\mathbf{F}_{5,t-1}^3 + 0,591\boldsymbol{\varepsilon}_{1,t-1}^{1\#} + \dots - 0,834\mathbf{F}_{5,t-1}^{3\#} + 1,464\boldsymbol{\varepsilon}_{1,t-1}^{1\#\#} + \dots + 8,135\mathbf{F}_{5,t-1}^{3\#\#} - 4,246\hat{\boldsymbol{\varepsilon}}_{t-1}$$

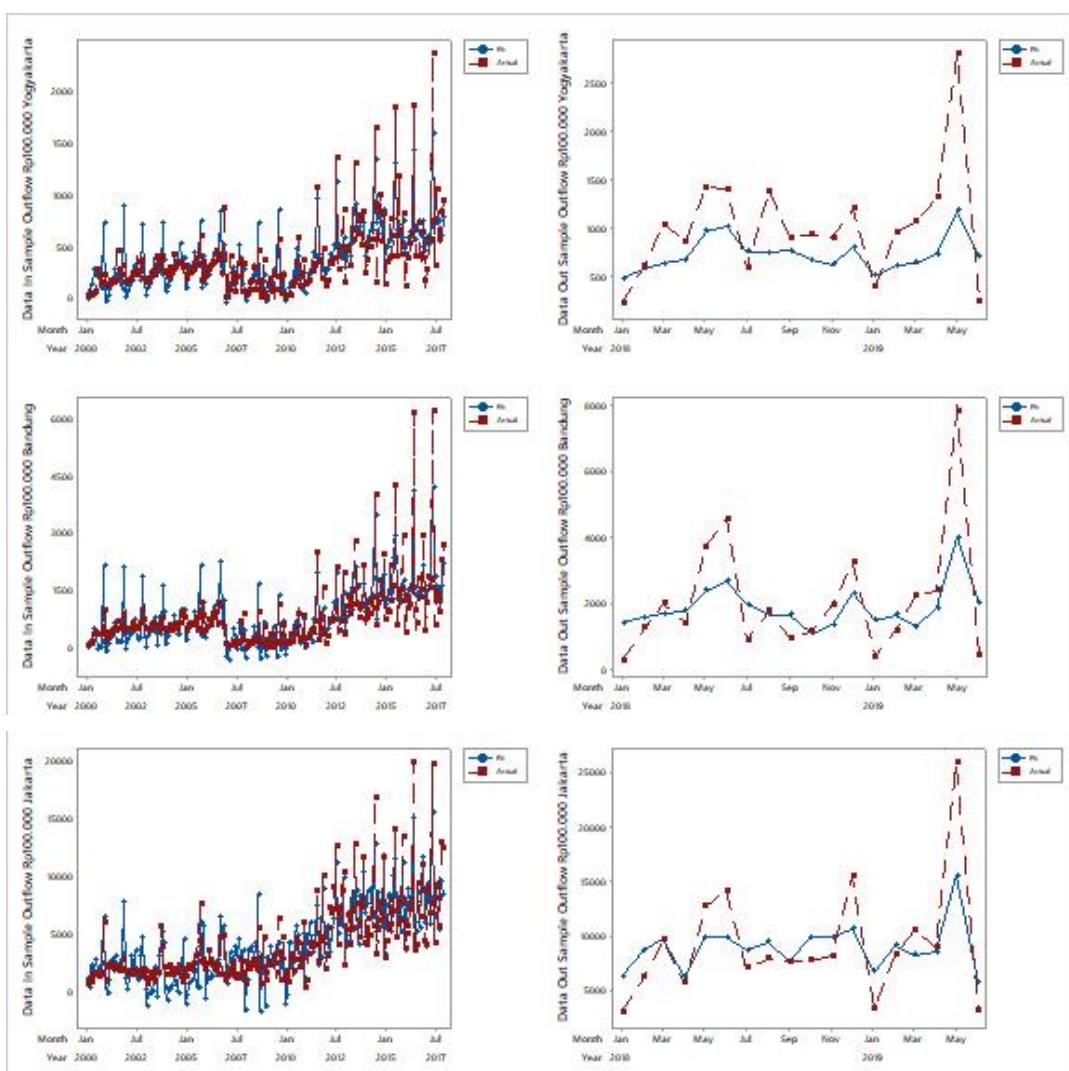


**Gambar 4.39.** Arsitektur Model MGSTARX-JRNN(90,2,1) Data *Outflow*

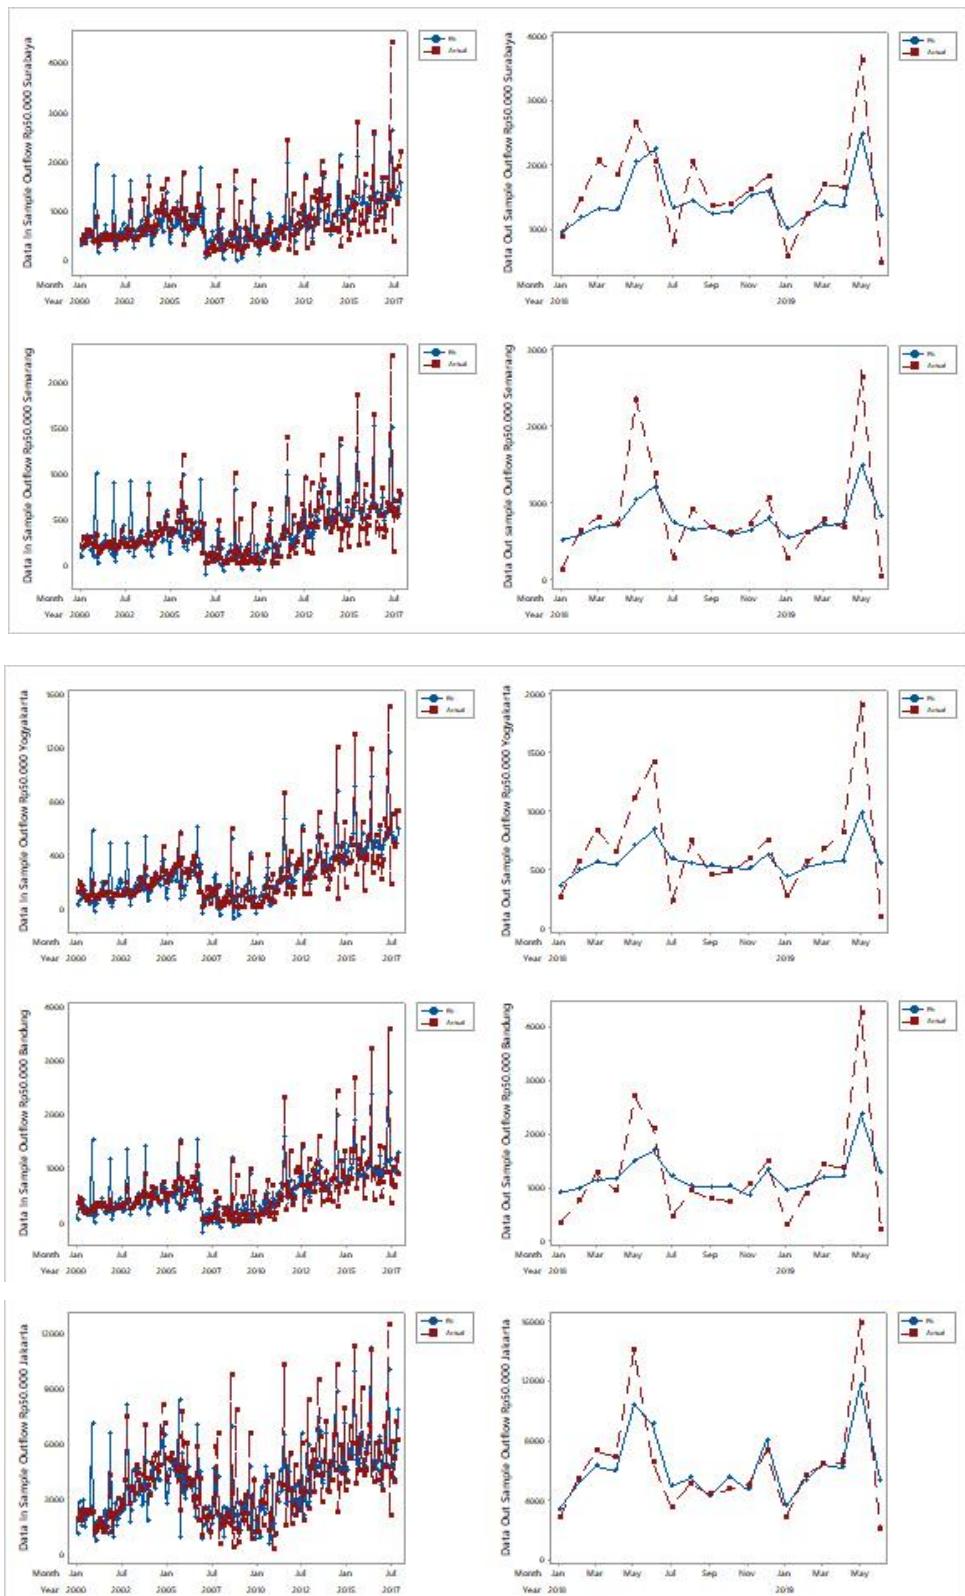
Plot perbandingan hasil pemodelan MGSTARX-JRNN(90,2,1) bobot korelasi silang dengan data aktual *outflow* UPB KPw Bank Sentral di Jawa ditunjukkan pada Gambar 4.40 hingga Gambar 4.42.



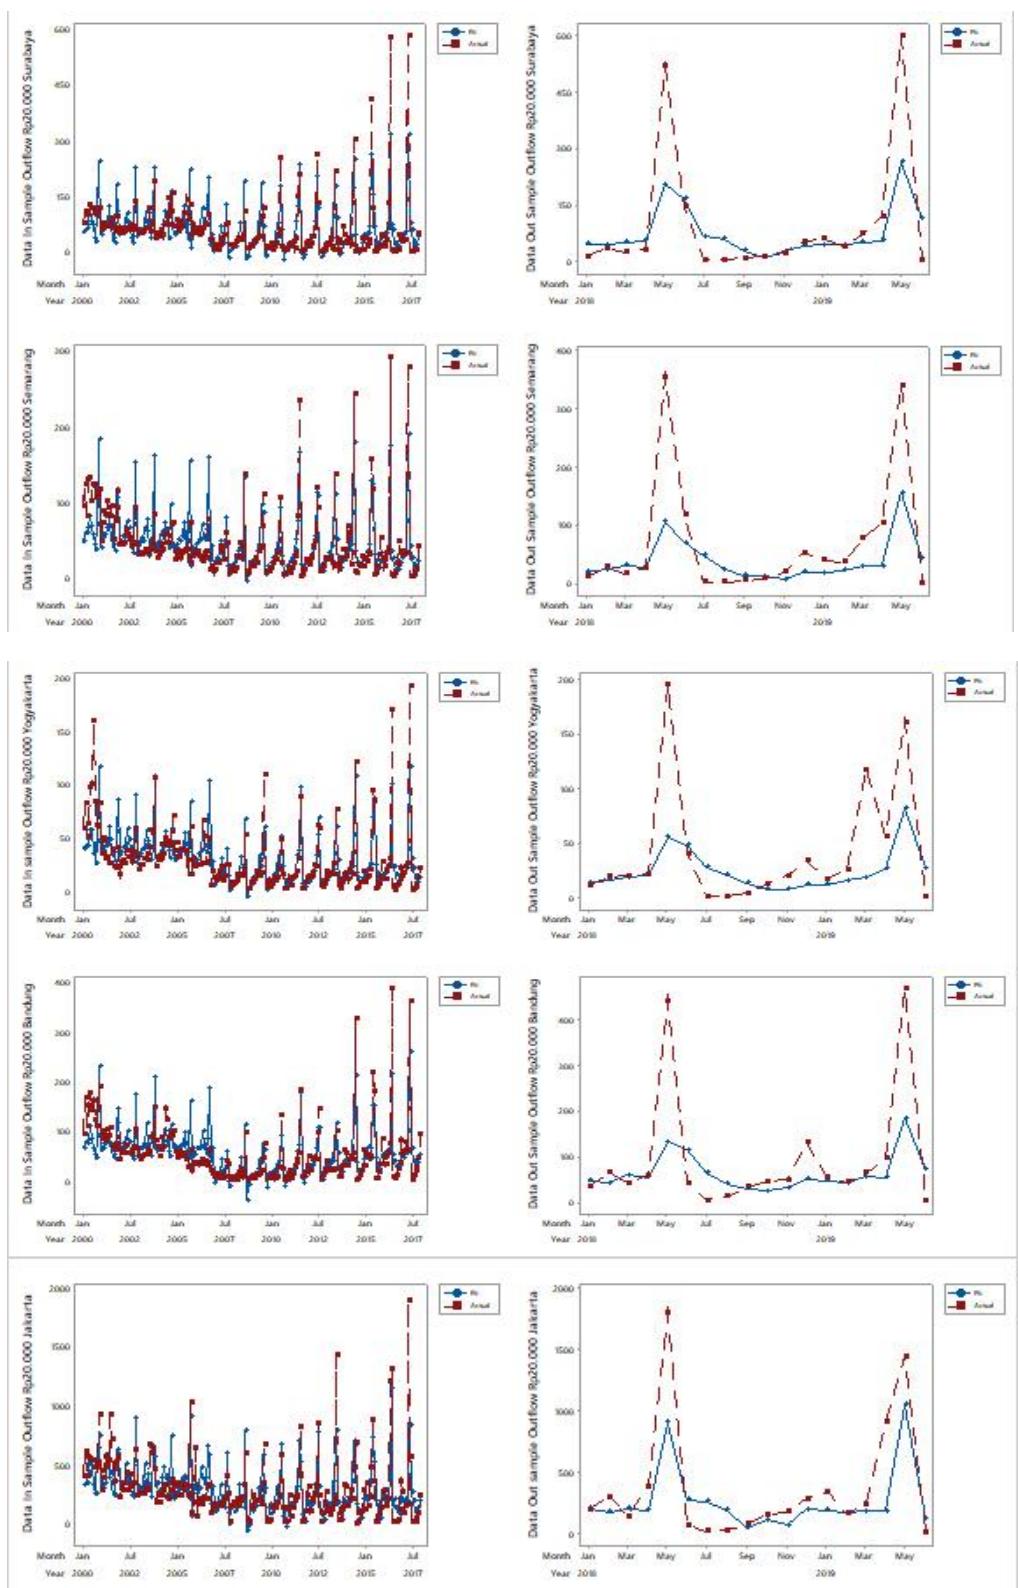
**Gambar 4.40** Perbandingan Data Aktual *Outflow* Rp100.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX-JRNN(90,2,1) dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.40** Perbandingan Data Aktual *Outflow* Rp100.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX-JRNN(90,2,1) dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan) (lanjutan)



**Gambar 4.41** Perbandingan Data Aktual *Outflow* Rp50.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX-JRNN(90,2,1) dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan)



**Gambar 4.42** Perbandingan Data Aktual *Outflow* Rp20.000 di Lima KPw Bank Sentral dengan Prediksi Hasil Model MGSTARX-ERNN(90,2,1) dengan Bobot Korelasi Silang *in sample* (kiri) dan *out sample* (kanan)

## 4.11 Perbandingan Hasil Pemodelan *Inflow* dan *Outflow* UPB KPw Bank Sentral Provinsi di Jawa

Perbandingan kriteria kebaikan model data *inflow* dan *outflow* dilakukan menggunakan nilai sMAPE yaitu dengan cara menghitung rata-rata kelima KPw BANK SENTRAL provinsi pada masing-masing model dan dipilih model dengan nilai rata-rata sMAPE terkecil. Nilai rata-rata sMAPE masing-masing model untuk setiap data *inflow* dan *outflow* dapat dilihat pada Tabel 4.35.

**Tabel 4.35.** Rata-Rata Nilai sMAPE Pemodelan *Inflow* dan *Outflow* UPB KPw Bank Sentral Provinsi di Jawa

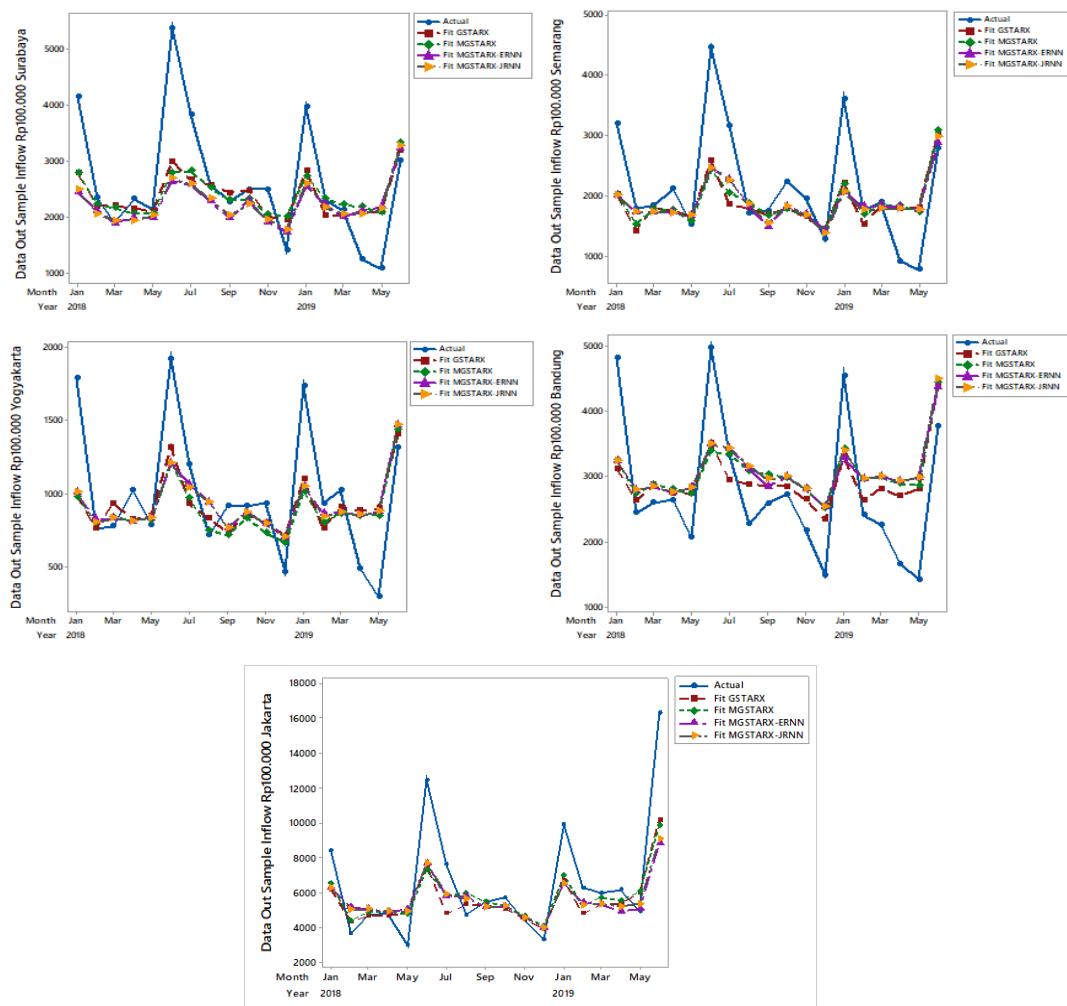
Data	Pecahan	Model TSR	Model ARIMAX	Model GSTARX	Model MGSTARX
<i>Inflow</i>	Rp100.000	25,527%	24,236%	24,014%	24,593%
	Rp50.000	17,563%	17,017%	16,376%	17,690%
	Rp20.000	34,022%	30,764%	28,123%	32,001%
<i>Outflow</i>	Rp100.000	42,984%	34,943%	37,166%	36,195%
	Rp50.000	36,058%	30,560%	35,764%	28,916%
	Rp20.000	79,246%	71,089%	75,079%	83,859%
Data	Pecahan	GSTARX-ERNN	GSTARX-JRNN	MGSTARX-ERNN	MGSTARX-JRNN
<i>Inflow</i>	Rp100.000	26,557%	25,900%	25,107%	25,382%
	Rp50.000	17,041%	16,865%	16,628%	17,189%
	Rp20.000	26,299%	26,304%	33,205%	32,822%
<i>Outflow</i>	Rp100.000	36,861%	39,480%	38,986%	40,860%
	Rp50.000	32,272%	33,041%	34,201%	33,988%
	Rp20.000	75,197%	77,281%	72,666%	75,610%

Berdasarkan Tabel 4.35 diperoleh model dengan rata-rata sMAPE terkecil untuk setiap pecahan yang ditampilkan sebagai berikut.

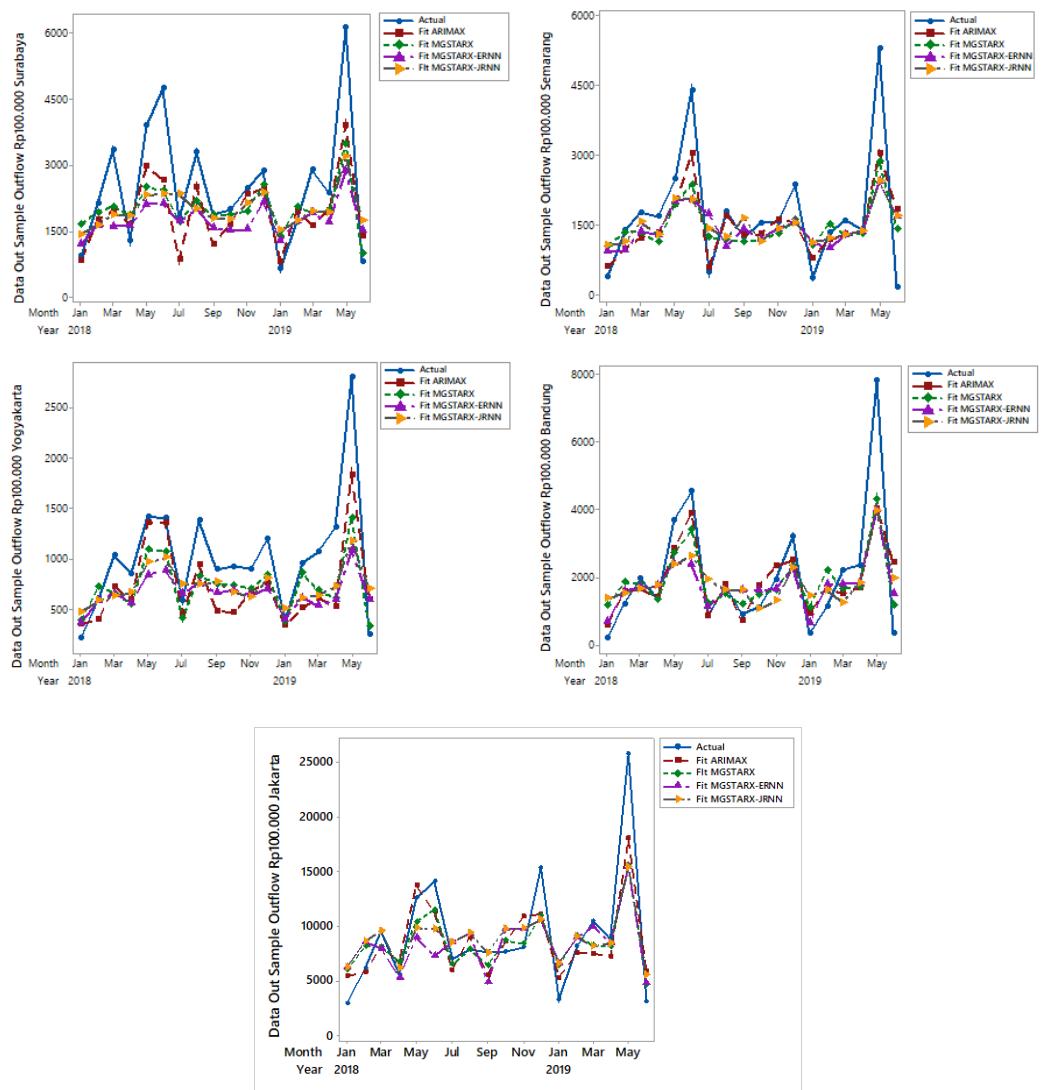
**Tabel 4.36.** Model Terpilih Pemodelan *Inflow* dan *Outflow* UPB KPw Bank Sentral Provinsi di Jawa

Data	Pecahan	Model	Bobot Lokasi
<i>Inflow</i>	Rp100.000	GSTARX	Seragam
	Rp50.000	GSTARX	Seragam
	Rp20.000	GSTARX-ERNN(20,2,1)	Korelasi Silang
<i>Outflow</i>	Rp100.000	ARIMAX	-
	Rp50.000	MGSTARX	Korelasi Silang
	Rp20.000	ARIMAX	-

Model MGSTARX, baik MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN bukan merupakan model terbaik dalam memodelkan data *inflow* dan *outflow* UPB KPw Bank Sentral provinsi di Jawa secara multivariat. Hal ini dikarenakan terdapat korelasi antar pecahan yang relatif kecil seperti korelasi pecahan Rp100.000 dengan pecahan Rp20.000. Semakin banyak variabel yang terlibat dalam pemodelan, khususnya model multivariat, maka semakin banyak pula kesalahan prediksi variabel yang juga terlibat dan berimplikasi pada akurasi kebaikan model. Sebagai contoh ditampilkan perbandingan model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN dengan model terbaik dari *inflow* dan *outflow* pecahan Rp100.000 pada Gambar 4.43 dan Gambar 4.44.



**Gambar 4.43.** Perbandingan Aktual dan Fit Model MGSTARX, MGSTARX-ERNN, MGSTARX-JRNN dengan Model Terbaik *Inflow* Rp100.000 pada Lima KPw Bank Sentral di Jawa



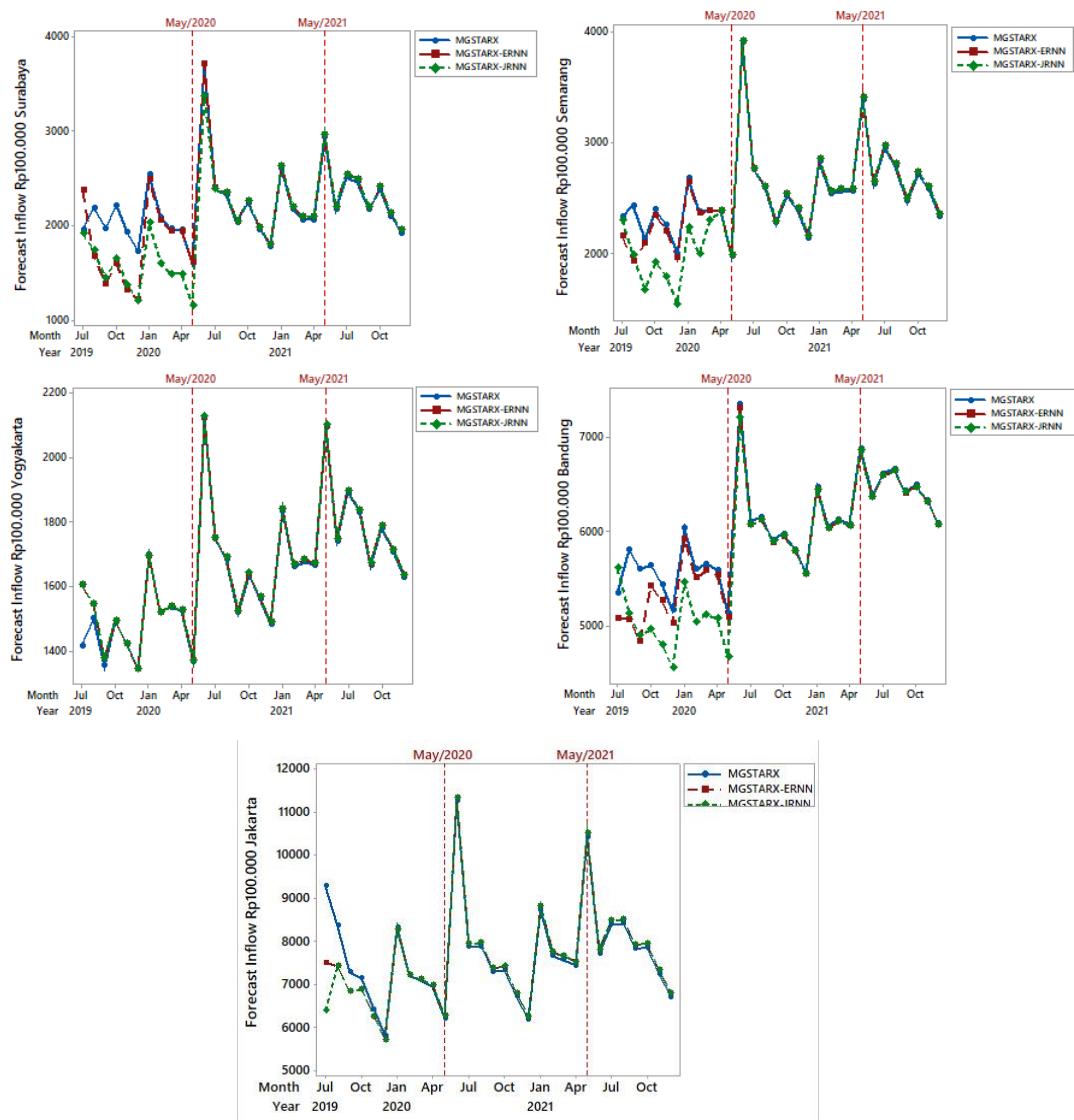
**Gambar 4.44.** Perbandingan Aktual dan Fit Model MGSTARX, MGSTARX-ERNN, MGSTARX-JRNN dengan Model Terbaik *Outflow* Rp100.000 pada Lima KPw Bank Sentral di Jawa

Berdasarkan Gambar 4.39 diketahui bahwa model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN memiliki pola yang mirip dengan model terbaik *inflow* Rp100.000 yaitu model GSTARX. Apabila dibandingkan dengan data aktual diketahui empat model tersebut memiliki selisih nilai yang cukup besar pada titik-titik data tinggi. Sehingga baik model GSTARX maupun MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada data *inflow* Rp100.000 belum mampu mengikuti pola data aktual khususnya pada data-data puncak.

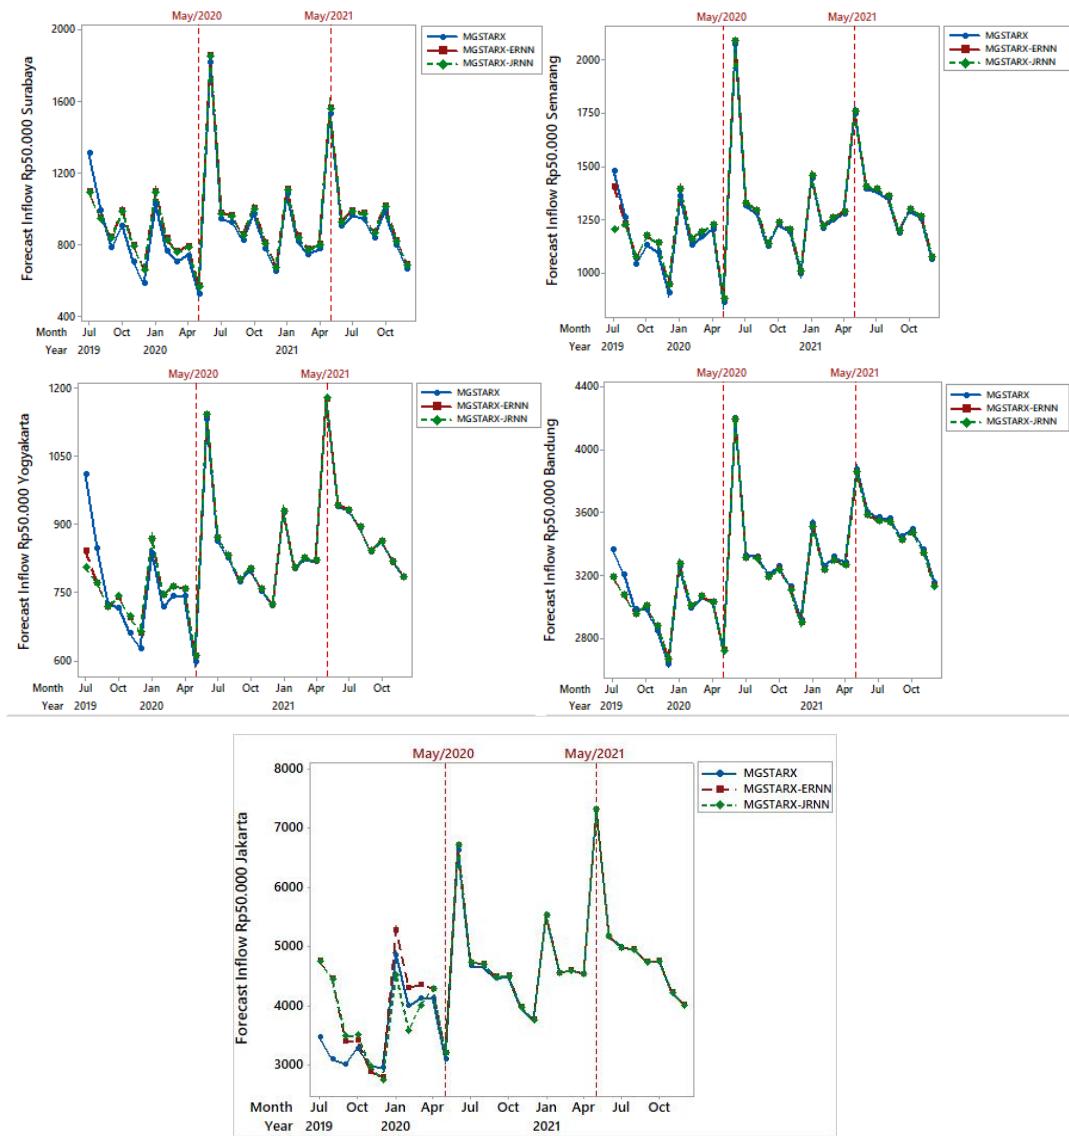
Sedangkan untuk data *outflow* Rp100.000 terlihat pada Gambar 4.40 model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN memiliki selisih nilai yang tidak terlalu besar dibandingkan dengan model terbaik *outflow* Rp100.000 yaitu model ARIMAX. Baik model ARIMAX maupun MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN mampu mengikuti pola data aktual dengan cukup baik. Pada titik-titik data tinggi model ARIMAX dan MGSTARX mengikuti pola data aktual lebih tepat dibandingkan model lainnya khususnya pada KPw Bank Sentral Yogyakarta dan KPw Bank Sentral Bandung.

#### **4.12 Peramalan Data *Inflow* dan *Outflow* UPB KPw Bank Sentral Provinsi di Jawa**

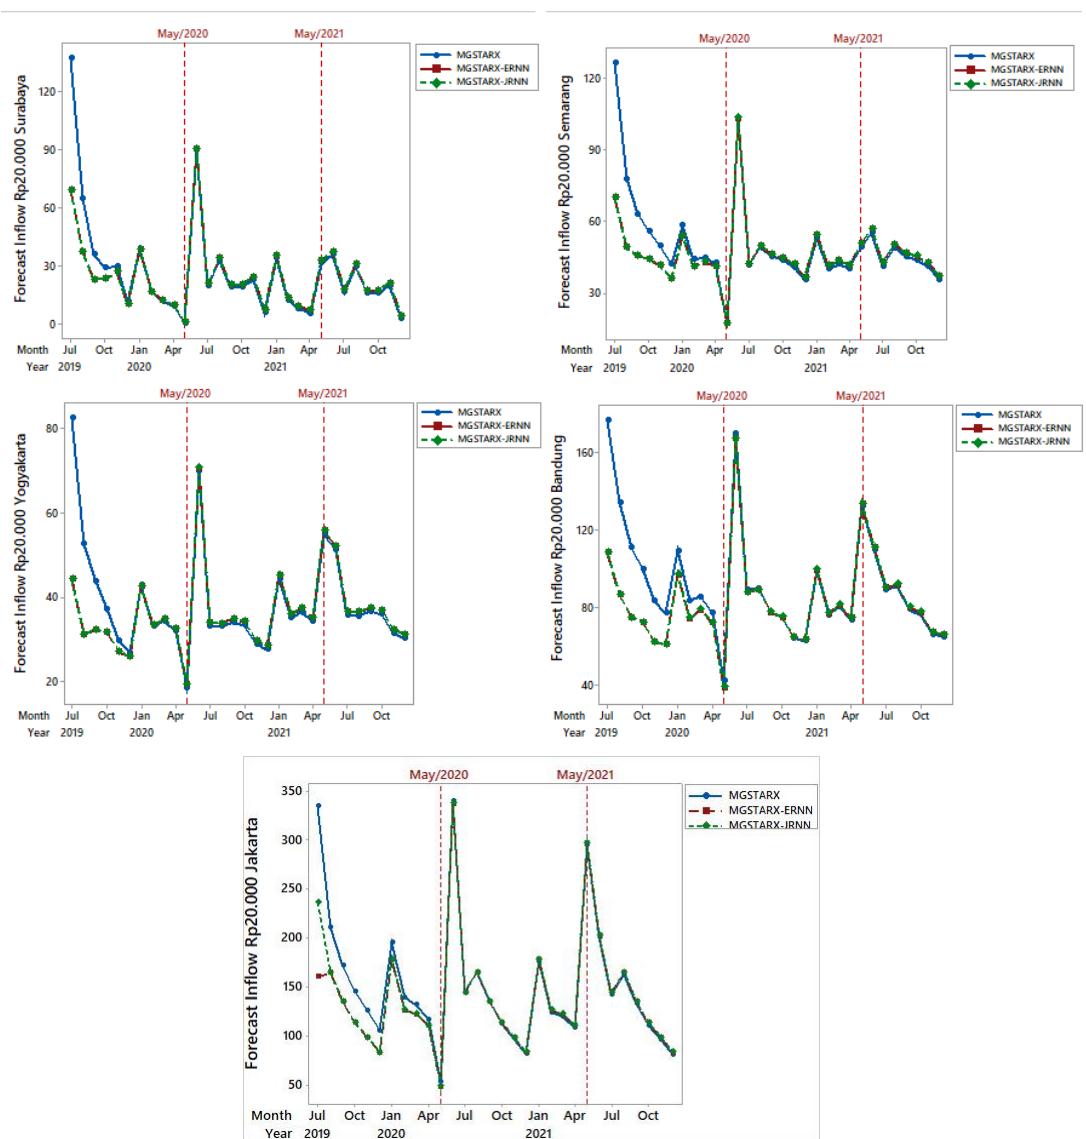
Pada penelitian ini menggunakan model MGSTARX, model MGSTARX-ERNN, dan model MGSTARX-JRNN untuk melakukan peramalan data *inflow* dan *outflow* UPB KPw Bank Sentral provinsi di Pulau Jawa. Berdasarkan nilai rata-rata RMSE dan sMAPE *out sample* terkecil dipilih model MGSTARX dengan bobot invers jarak untuk *inflow* dan bobot korelasi silang untuk *outflow*. Model MGSTARX-ERNN yang digunakan adalah model MGSTARX-ERNN(90,1,1) dengan bobot seragam untuk data *inflow* sedangkan untuk data *outflow* menggunakan model MGSTARX-ERNN(90,2,1) dengan bobot yang sama. Selanjutnya digunakan model MGSTARX-JRNN(90,1,1) dengan bobot invers jarak pada data *inflow* dan MGSTARX-JRNN(90,2,1) dengan bobot korelasi silang pada data *outflow*. Berikut ini *time series* plot hasil peramalan *inflow* setiap pecahan besar menggunakan ketiga model diberikan pada Gambar 4.45 hingga Gambar 4.47. Hasil peramalan *inflow* dan *outflow* masing-masing pecahan dengan ketiga model dapat dilihat pada Lampiran 7.



**Gambar 4.45.** Peramalan Inflow Rp100.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada Lima KPw Bank Sentral Provinsi di Jawa



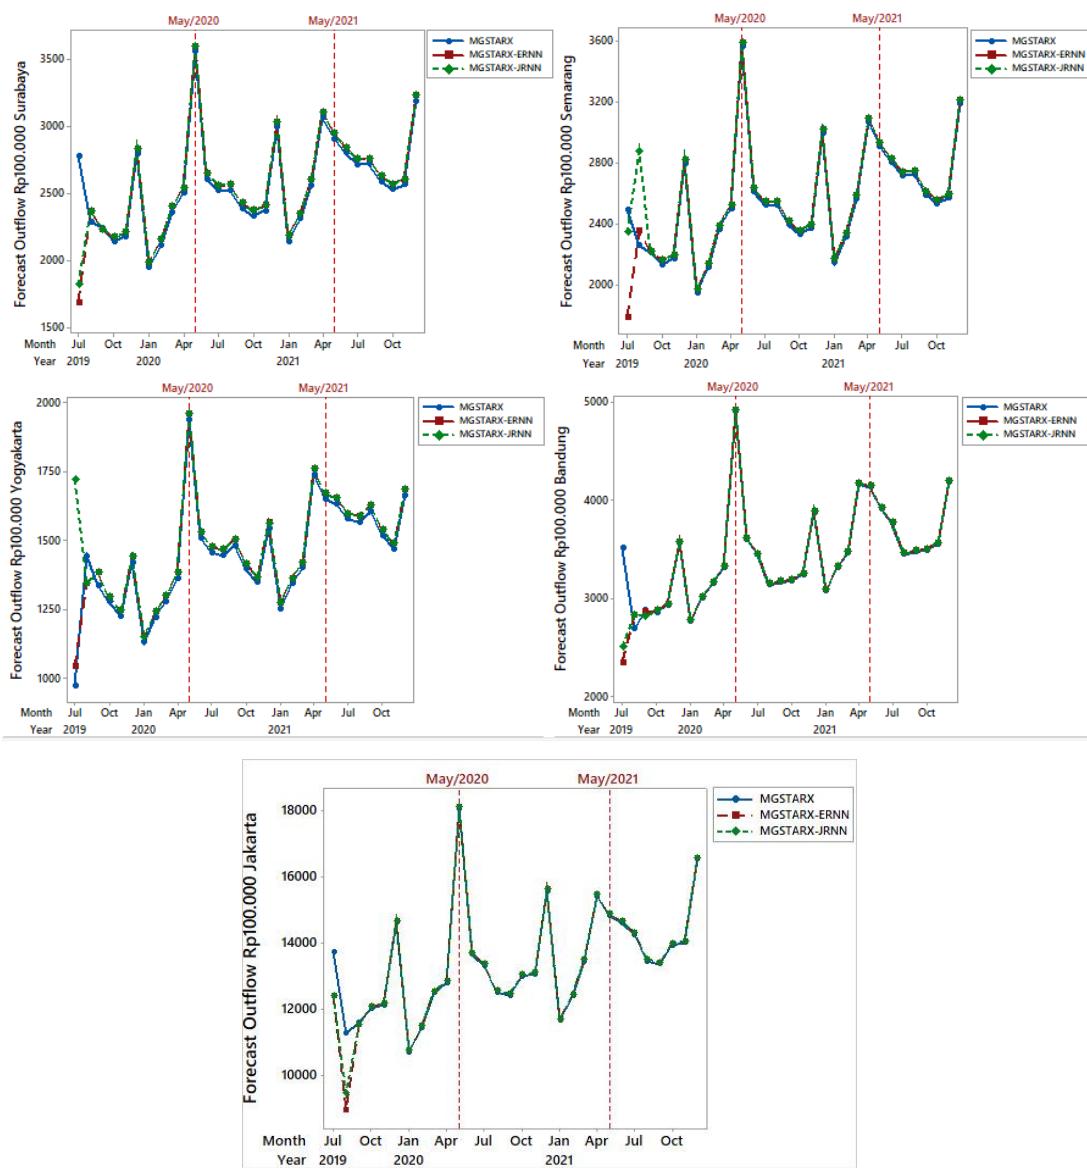
**Gambar 4.46.** Peramalan *Inflow* Rp50.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada Lima KPw Bank Sentral Provinsi di Jawa



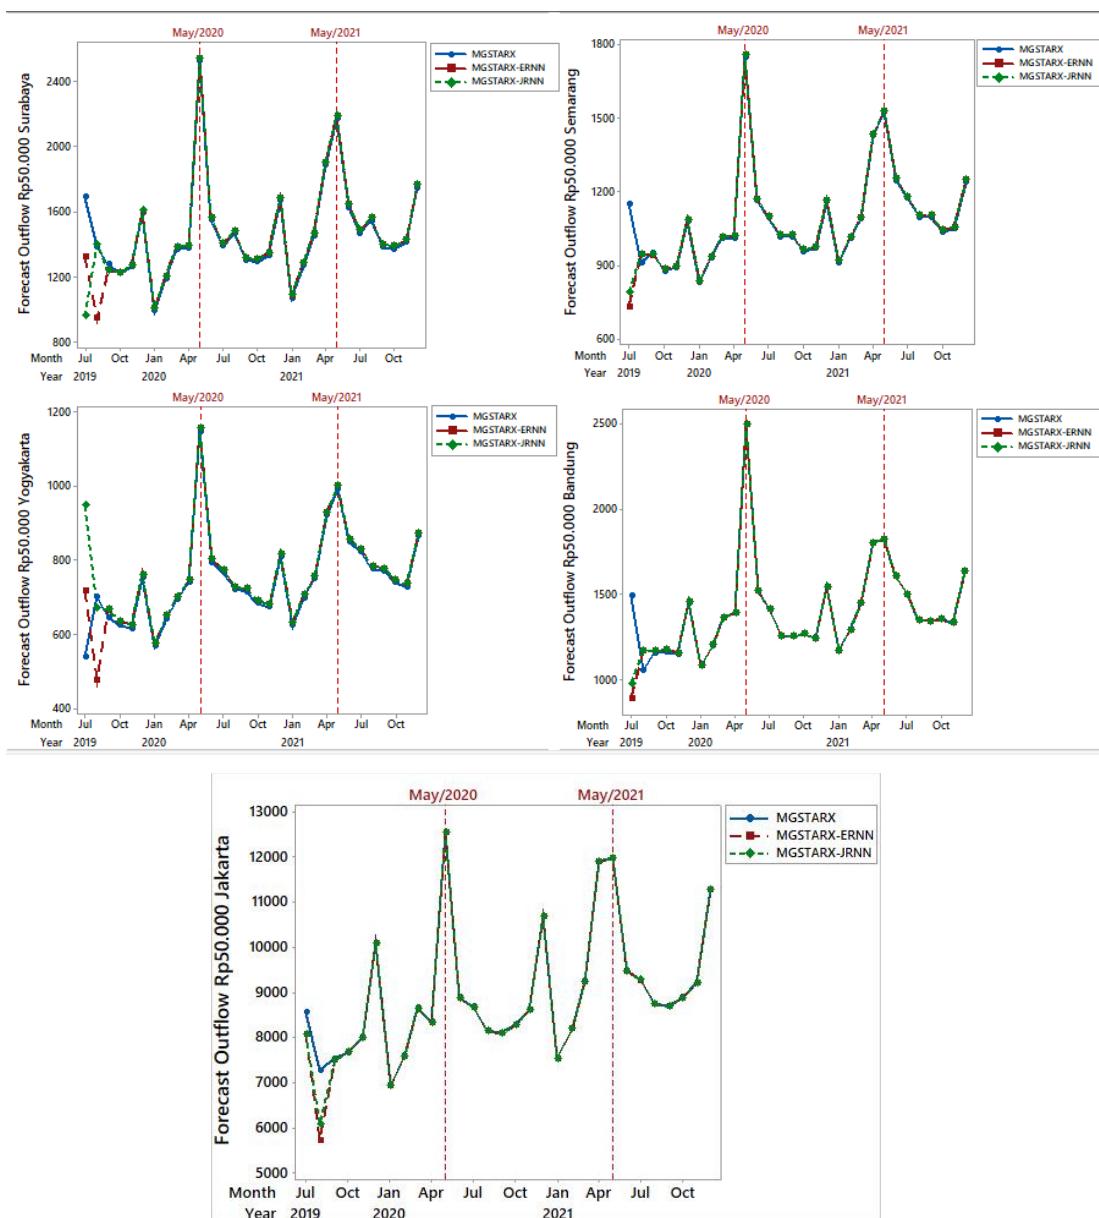
**Gambar 4.47.** Peramalan *Inflow* Rp20.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN Pada Lima KPw Bank Sentral Provinsi di Jawa

Pada peramalan data *inflow* setiap UPB dengan ketiga model yang digunakan memberikan hasil yang relatif sama yaitu mengalami peningkatan tertinggi pada Bulan Juni 2020 dan Bulan Mei 2021. Hal ini menunjukkan bahwa ketiga model mampu meramalkan sesuai dengan efek variasi kalender Hari Raya Idul Fitri. Pada tahun 2020 Hari Raya Idul Fitri terjadi pada Bulan Mei sehingga pola data *inflow* yang dipengaruhi bulan terjadinya hari raya dan bulan setelah terjadinya hari raya menyebabkan nilai yang tinggi pada Bulan Juni 2020. Begitu juga pada tahun 2021 diperkirakan Hari Raya Idul Fitri terjadi pada Bulan Mei sehingga peningkatan data *inflow* tertinggi pada Bulan Mei 2021.

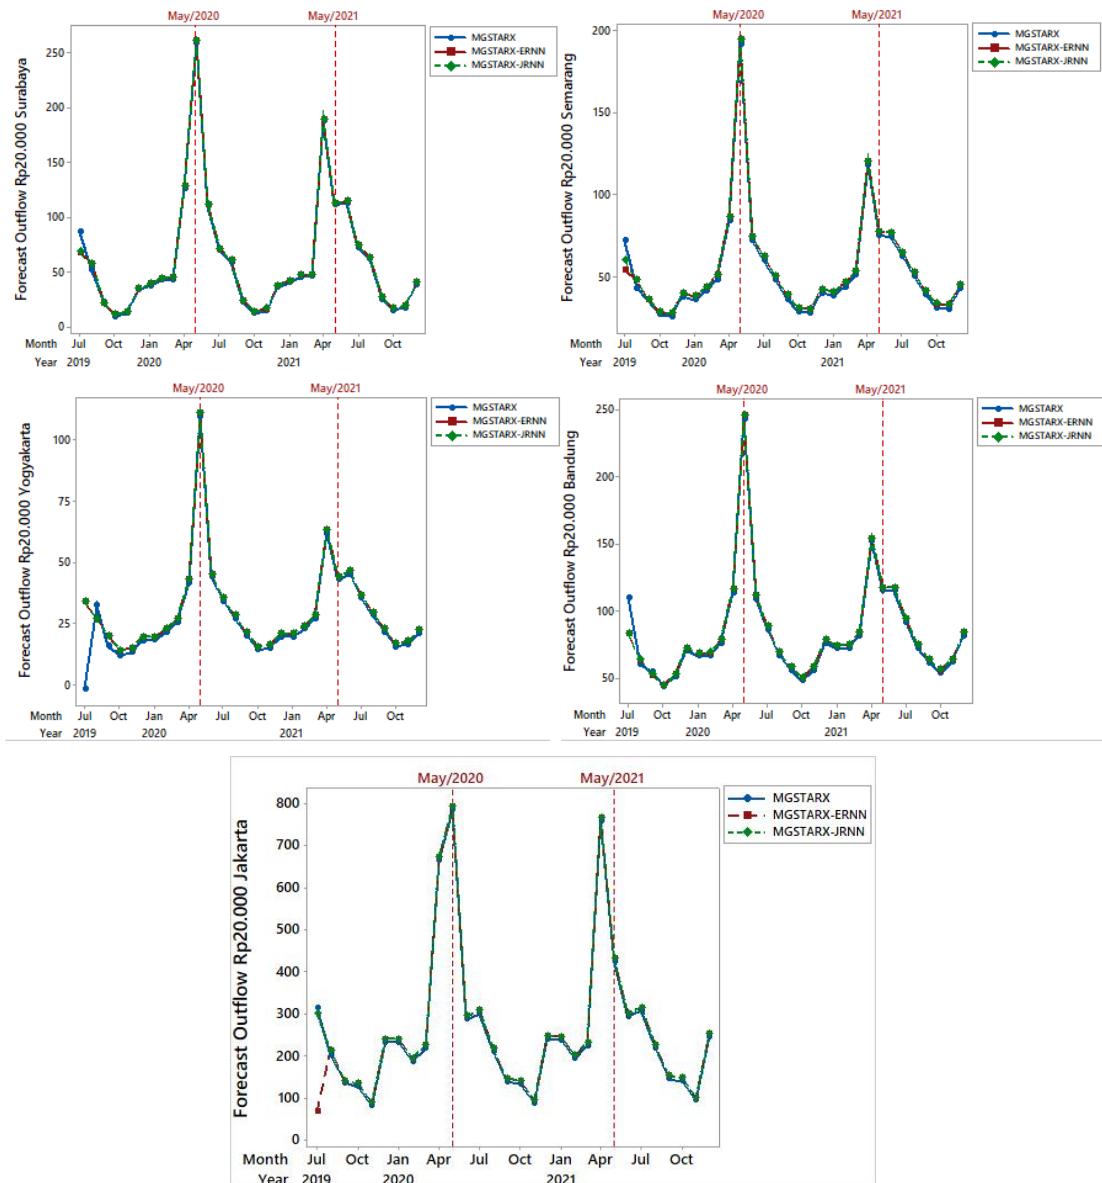
Selanjutnya peramalan *outflow* UPB KPw Bank Sentral provinsi di Jawa menggunakan model MGSTARX, model MGSTARX-ERNN, dan model MGSTARX-JRNN ditampilkan pada Gambar 4.48 hingga Gambar 4.50.



**Gambar 4.48.** Peramalan *Outflow* Rp100.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada KPw Bank Sentral Provinsi di Jawa



**Gambar 4.49.** Peramalan *Outflow Rp50.000* dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada KPw Bank Sentral Provinsi di Jawa

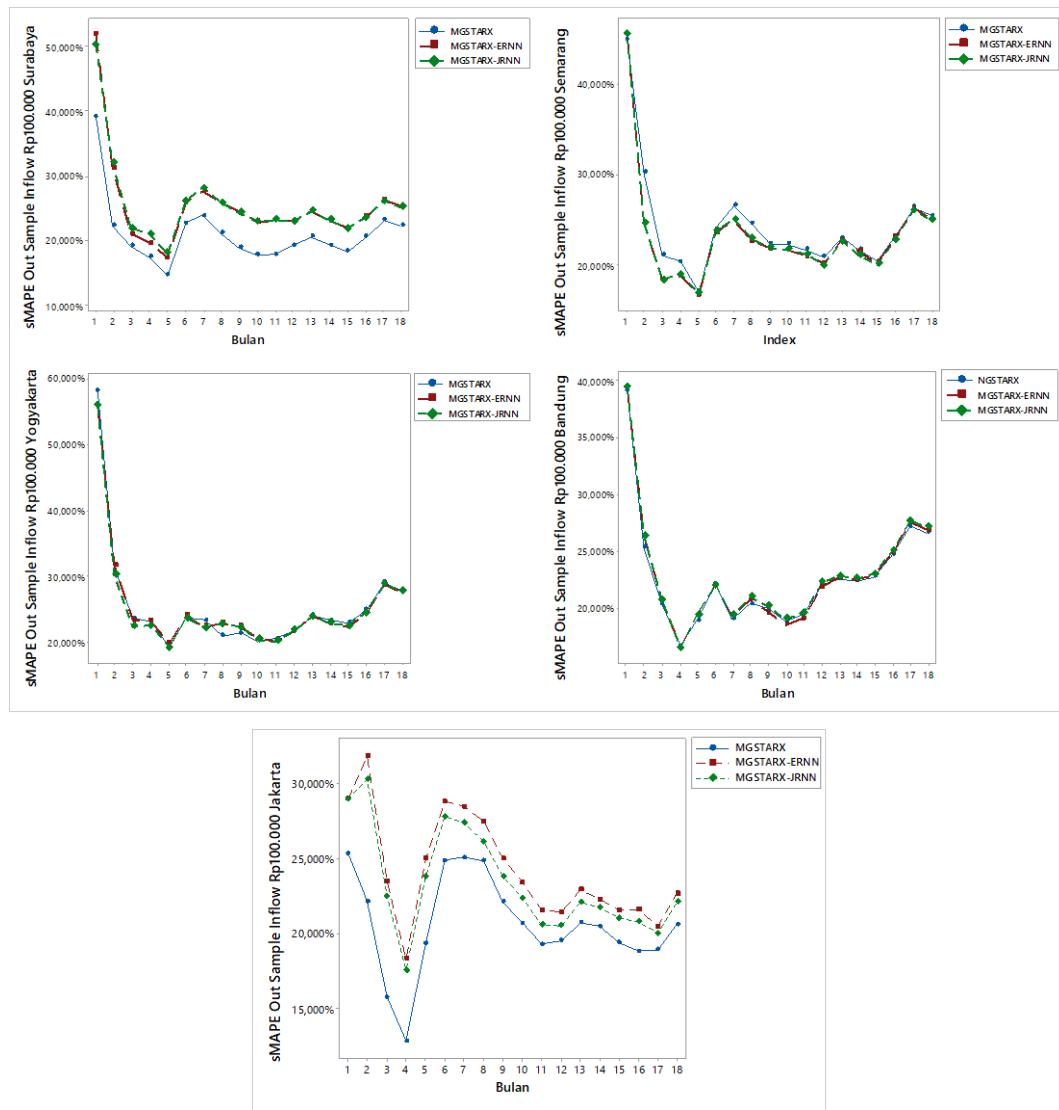


**Gambar 4.50** Peramalan *Outflow* Rp20.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN pada KPw Bank Sentral Provinsi di Jawa

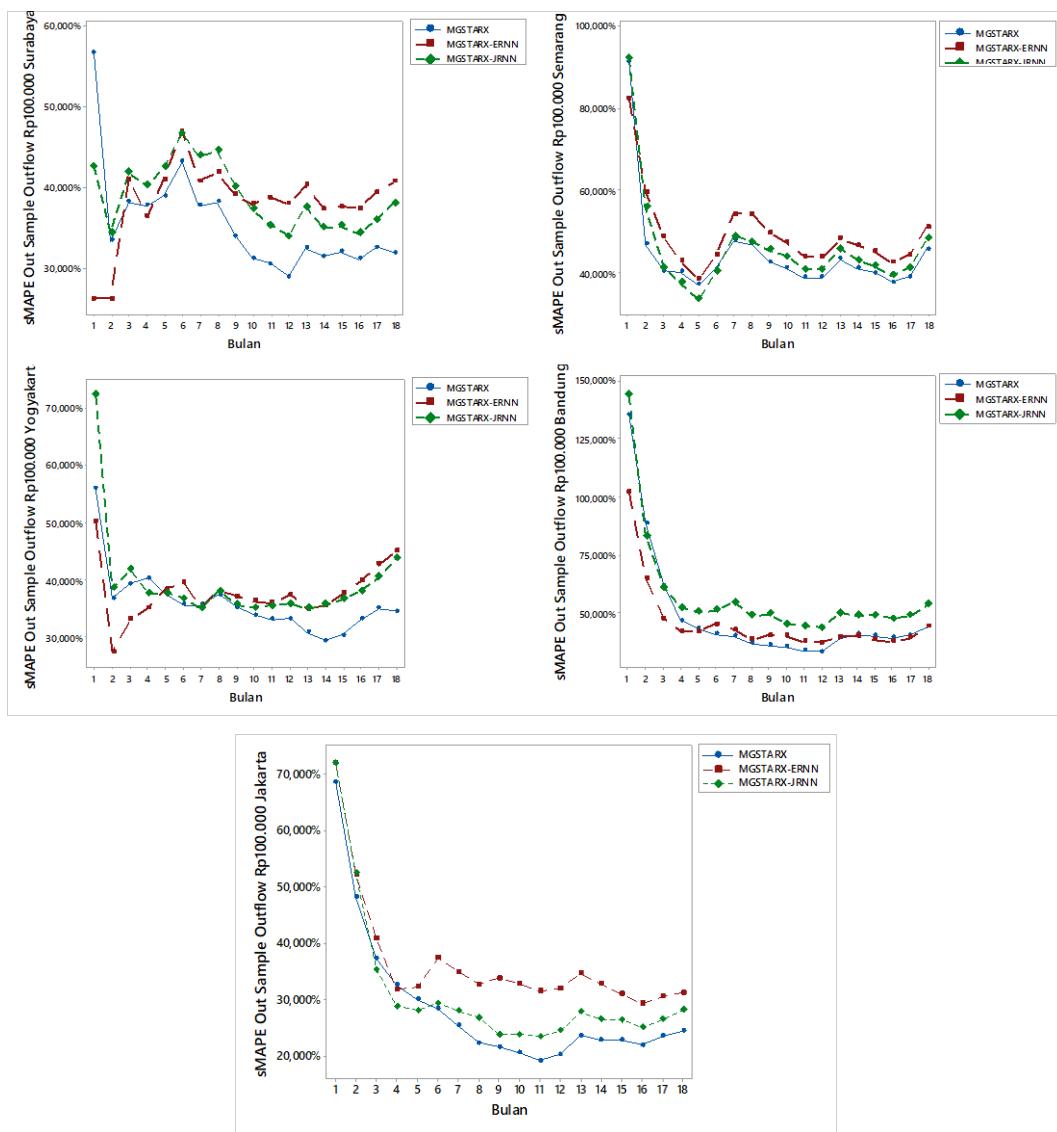
Pada peramalan *outflow* UPB KPw Bank Sentral provinsi di Jawa dengan ketiga model mengalami peningkatan tertinggi yang sama terjadi pada Bulan Mei 2020. Selain Bulan Mei 2020 data *outflow* mengalami peningkatan pada Bulan April 2021. Hal ini dikaitkan dengan efek variasi kalender Hari Raya Idul Fitri yang diperkirakan terjadi pada Bulan Mei 2020 dan Mei 2021. Pola data *outflow* yang dipengaruhi bulan sebelum terjadinya hari raya dan bulan terjadinya hari raya menyebabkan data *outflow* mengalami peningkatan yang signifikan. Jadi,

model MGSTARX, model MGSTARX-ERNN, dan model MGSTARX-JRNN mampu meramalkan sesuai dengan efek variasi kalender Hari Raya Idul Fitri.

Untuk mengetahui hingga bulan ke berapa model dapat meramalkan data *inflow* dan *outflow* KPw Bank Sentral provinsi di Jawa dengan baik dapat diketahui melalui perkembangan nilai sMAPE data *out sample*. Sebagai contoh, Gambar 4.51 menunjukkan perkembangan nilai sMAPE data *out sample* dari data *inflow* pecahan Rp100.000.



**Gambar 4.51** Nilai sMAPE setiap Langkah peramalan Data *Out Sample Inflow* Pecahan Rp100.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN



**Gambar 4.52** Nilai sMAPE setiap Langkah peramalan Data *Out Sample Outflow* Pecahan Rp100.000 dengan Model MGSTARX, MGSTARX-ERNN, dan MGSTARX-JRNN

Pada data *inflow* Rp100.000 KPw Bank Sentral Surabaya berdasarkan Gambar 4.51 diketahui bahwa pada peramalan hingga 18 bulan menunjukkan nilai sMAPE di sekitar nilai 25% untuk peramalan dengan model MGSTARX-ERNN dan MGSTARX-JRNN. Sedangkan untuk model MGSTARX nilai sMAPE peramalan hingga 18 bulan berada di bawah 25% dan peramalan hingga bulan kelima memiliki nilai sMAPE terkecil yaitu 14%. Pada KPw Bank Sentral Semarang, KPw Bank Sentral Yogyakarta dan KPw Bank Sentral Bandung ketiga model memiliki perubahan nilai sMAPE yang hampir sama untuk peramalan hingga 18 bulan yaitu sekitar 25% dengan nilai sMAPE terkecil pada peramalan

hingga bulan ke-5. Untuk data *inflow* Rp100.000 KPw Bank Sentral Jakarta memiliki nilai sMAPE pemodelan MGSTARX dibawah 15% untuk ramalan hingga bulan ke-4, untuk ramalan bulan ke-5 dan selanjutnya bernilai 20-25%. Sedangkan model MGSTARX-ERNN dan MGSTARX-JRNN menghasilkan nilai sMAPE dibawah 20% untuk ramalan hingga bulan ke-4 dan ramalan bulan ke-5 dan selanjutnya berada disekitar 25-30%.

Pada data *outflow* Rp100.000 nilai sMAPE untuk peramalan hingga 18 bulan bernilai diatas 40% untuk KPw Bank Sentral Surabaya, KPw Bank Sentral Semarang, KPw Bank Sentral Yogyakarta dan KPw Bank Sentral Bandung sedangkan KPw Bank Sentral Jakarta memiliki nilai sMAPE sekitar 30%. *Outflow* Rp100.000 di KPw Bank Sentral Surabaya dan KPw Bank Sentral Yogyakarta menghasilkan nilai sMAPE terkecil pada peramalan hingga bulan ke-2 yaitu dibawah 30% untuk model MGSTARX-ERNN dan dibawah 40% untuk Model MGSTARX dan MGSTARX-JRNN. Untuk KPw Bank Sentral Semarang nilai sMAPE terkecil pada peramalan hingga bulan ke-5 dengan nilai dibawah 40%. Sedangkan KPw Bank Sentral Bandung dan Jakarta nilai sMAPE terkecil pada peramalan hingga bulan ke-12.

## **BAB 5**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan maka diperoleh kesimpulan sebagai berikut.

1. Kajian simulasi dilakukan untuk mengetahui performa model *hybrid* MGSTAR-RNN yaitu model MGSTAR-ERNN dan model MGSTAR-JRNN dibandingkan dengan model MGSTAR tanpa melibatkan variabel eksogen. Hasil dari kajian simulasi yaitu model MGSTAR-ERNN merupakan model yang memiliki performa *in sample* lebih baik dibandingkan model MGSTAR dan MGSTAR-JRNN untuk data yang memiliki hubungan residual ketika variabel sama lokasi berbeda maupun data dengan hubungan residual variabel berbeda lokasi sama.
2. Karakteristik data *inflow* dan *outflow* Uang Pecahan Besar (UPB) di KPw Bank Sentral Surabaya, Semarang, Yogyakarta, Bandung, dan Jakarta mengandung pola tren, musiman, dan variasi kalender sehingga dilakukan pemodelan *Time Series Regression* (TSR) sebagai tahap pertama untuk menangkap pola data tersebut. Pemodelan data *inflow* dan *outflow* setiap pecahan UPB dilakukan menggunakan Model ARIMAX, GSTARX, GSTARX-ERNN, GSTARX-JRNN, MGSTARX, MGSTARX-ERNN dan MGSTARX-JRNN. Hasil perbandingan akurasi kebaikan model menunjukkan bahwa model terbaik untuk masing-masing pecahan adalah ARIMAX untuk data *outflow* Rp20.000 dan Rp100.000, GSTARX untuk data *inflow* Rp50.000 dan Rp100.000, MGSTARX untuk data *outflow* Rp50.000 dan GSTARX-ERNN untuk data *inflow* Rp20.000. Hasil ini menunjukkan bahwa model MGSTARX dan *hybrid* MGSTARX-RNN yang lebih kompleks tidak selalu memberikan prediksi yang lebih akurat dibanding model yang lebih sederhana. Secara umum, kesimpulan ini juga sesuai dengan hasil M3-*competition*, yang menunjukkan bahwa model yang lebih kompleks tidak selalu memberikan ramalan yang lebih akurat dibandingkan dengan model yang lebih sederhana

3. Performa model *hybrid* MGSTARX-RNN pada hasil pemodelan data terapan tidak lebih baik daripada model MGSTARX tidak seperti pada kajian simulasi yang menunjukkan bahwa performa *hybrid* MGSTAR-RNN lebih baik dibanding MGSTAR. Hal ini dimungkinkan adanya hubungan residual ketika variabel berbeda dan lokasi berbeda pada data terapan selain hubungan residual yang terdapat pada data kajian simulasi. Adanya korelasi yang kecil antar variabel dependen diduga menjadi salah satu penyebab hasil prediksi model MGSTARX dan *hybrid* MGSTARX-RNN tidak lebih akurat dibanding model yang lebih sederhana. Semakin banyak variabel yang terlibat dalam peramalan, khususnya model multivariat, maka semakin banyak pula kesalahan prediksi variabel yang juga terlibat dan berimplikasi pada ramalan yang tidak lebih akurat.
4. Peramalan data *inflow* dan *outflow* pecahan Rp100.000, Rp50.000, dan Rp20.000 pada kelima KPw Bank Sentral Provinsi di Jawa menggunakan model MGSTARX, model MGSTARX-ERNN, dan model MGSTARX-JRNN memberikan hasil ramalan dengan pola yang hampir sama. Hari Raya Idul Fitri tahun 2020 dan tahun 2021 diperkirakan terjadi pada Bulan Mei sehingga pada peramalan data *inflow* ketiga UPB menyebabkan nilai yang tinggi pada Bulan Juni 2020 dan Mei 2021. Hal ini sesuai dengan efek variasi kalender Hari Raya Idul Fitri yang mempengaruhi data *inflow* pada bulan terjadinya hari raya dan bulan setelah hari raya. Sedangkan data *outflow* dipengaruhi pada bulan sebelum hari raya dan bulan terjadinya hari raya sehingga peramalan data *outflow* memiliki nilai yang tinggi pada Bulan Mei 2020 dan Bulan April 2021.

## **5.2 Saran**

Berdasarkan kesimpulan yang diperoleh dapat diberikan saran untuk penelitian berikutnya bahwa perlu dikembangkan pemilihan orde yang digunakan dalam pemodelan GSTARX maupun MGSTARX. Selain itu data yang digunakan untuk memodelkan *Multivariate* GSTARX dapat dicek dependensi antar pecahan dan antar lokasinya terlebih dahulu. Disarankan pula untuk penelitian selanjutnya dapat memodelkan pada data empiris dua pecahan dengan korelasi yang signifikan dan tinggi (di atas 0,5) untuk memperkuat dugaan jika korelasi yang kecil (di bawah 0,5) menjadi salah satu penyebab hasil prediksi model MGSTARX dan *hybrid* MGSTARX-RNN tidak lebih baik dibanding model yang lebih sederhana. Serta menambahkan skenario pada data simulasi yang mengindikasikan adanya hubungan residual variabel berbeda lokasi berbeda dan dilakukan pembagian *in sample* dan *out sample* data pada kajian simulasi.

*Halaman ini sengaja dikosongkan*

## DAFTAR PUSTAKA

- Bank Indonesia. (2012). *Peraturan Bank Indonesia Nomor 14/7/PBI/2012 Tentang Pengelolaan Uang Rupiah*. Jakarta: Bank Indonesia
- Bank Indonesia. (2017). *Metadata : Uang Kartal yang Diedarkan*. Jakarta: Bank Indonesia
- Bank Indonesia. (2017). *Metadata : Indikator Pengedaran Uang*. Jakarta: Bank Indonesia.
- Borovkova, S., Lopuhä, H. P., dan Ruchjana, B. N. (2008). Consistency and Asymptotic Normality of Least Squares Estimators in Generalized STAR Models. *Statistica Neerlandica*, 62, 482-508.
- Borovkova, S., Lopuhaa, R., dan Nurani, B. (2002). Generalized STAR Model with Experimental Weights. *Proceedings of the 17th International Workshop on Statistical Modelling*, 143-151.
- Bowerman, B., dan O'Connell, R. (1993). *Forecasting and Time Series* (3rd ed.). California: Duxbury Press.
- Cliff, A. D., dan Ord, J. K. (1975). Space-Time Modeling with An Application to Regional Forecasting. *Transactions of the Institute of British Geographers*, 64, 119-128.
- Dana, I. M., Suhartono, dan Rahayu, S. P. (2018). *Model Hybrid GSTARX-ANN Untuk Peramalan Data Space-Time Dengan Efek Variasi Kalender (Studi Kasus: Data Inflow dan Outflow Uang Kartal di Bank Indonesia Wilayah Jawa Timur)*. Tesis Magister, Surabaya: Statistika ITS.
- De Gooijer, J.G. dan Hyndman, R. (2006). 25 Years of time series forecasting. *International Journal of Forecasting*. 22. 443-473
- Elman, J. (1990). Finding Structure in Time. *Cognitive Science*. 14. 179-211.
- Fausett, L. (1994). *Fundamental Of Neural Network : Architectures, Algorithms and Applications*. New Jersey: Prentice-Hall Inc.
- Hannan, E. J. (1970). *Multiple Time Series*. New York: John Wiley and Sons, Inc.

- Haykin, S. (1999). Neural Networks a Comprehensive Foundation. New Jersey : Prentice Hall.
- Hyndman, R. J., Koehler, A. B., Ord, J. K., dan Snyder, R. D. (2008). *Forecasting with Exponential Smoothing, the State Space Approach*. Berlin: Springer-Verlag.
- Jordan, M., I. (1997). "Serial Order: A parallel distributed processing," Advances in Psychology, vol. 121, pp. 471-495.
- Kusumadewi, S. (2003). *Artificial Intelligence (Teknik dan Aplikasinya)*. Yogyakarta: Graha Ilmu.
- Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan menggunakan MATLAB & Excel Link*. Yogyakarta : Graha Ilmu.
- Lewis, N. D. (2016). *Deep Learning Made Easy with R*. South Carolina: Createspace Independent Publishing Platform.
- Ma , X., Chen, S., dan Chen, F. (2017). Multivariate Space-Time Modeling of Crash Frequencies by Injury Severity Levels. *Analytic Methods in Accident Research*, 15, 29-40.
- Makridakis, S., dan Hibon, M. (2000). The M3-Competition: Result, Conclusion and Implication. *International Journal of Forecasting*, 16, 451-476
- Nahdliyah, N., Suhartono, dan Akbar, M. S. (2019). *Model Multivariate Generalized Space Time Untoregressive untuk Monitoring Kualitas Udara di Surabaya*. Tugas Akhir, Surabaya: Statistika ITS.
- 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.

- Putri, T.E, Firdaus, dan Sabilla. (2018). Short-term Forecasting of Electricity Consumption Revenue on Java-Bali Electricity System using Jordan Recurrent Neural Network. *Journal of Information Systems Engineering and Business Intelligence*, 4 (2), 96–105
- Ruchjana, B. N. (2002). Pemodelan Kurva Produksi Minyak Bumi Menggunakan Model Generalisasi S-TAR. *Forum Statistika dan Komputasi*, 21, 1-6.
- Siang, J. J. (2005). *Jaringan Syaraf Tiruan & Programnya Menggunakan MATLAB*. Yogyakarta.
- Sigalingging, H., Setiawan, E., dan Sihaloho, H. D. (2004). *Kebijakan Pengedaran Uang di Indonesia*. Jakarta: Bank Indonesia.
- Suhartono dan Endharta, A.J. (2009). Peramalan Konsumsi Listrik Jangka Pendek Dengan ARIMA Musiman Ganda dan Elman-Recurrent Neural Network. *JUTI: Jurnal Ilmiah Teknologi Informasi*. 7. 183-190.
- Suhartono, Gazali, M., dan Prastyo, D. (2018). VARX and GSTARX Models for Forecasting Currency Inflow and Outflow with Multiple Calender Variations Effect. *Matematika*, 57-72.
- Suhartono, Lee, M. H., dan Hamzah, N. (2010). Calendar Variation Model based on Time Series Regression for Sales Forecasts: The Ramadhan Effects. *Proceedings of the Regional Conference on Statistical Sciences 2010 (RCSS'10)*, 30-41.
- Suhartono, dan Atok, R. M. (2006). Pemilihan Bobot Lokasi yang Optimal pada Model GSTAR. *Prosiding Konferensi Nasional Matematika XIII*. Universitas Negeri Semarang.
- Suhartono, dan Subanar. (2006). The Optimal Determination of Space Weight in GSTAR Model by Using Cross-Correlation Inference. *Journal of Quantitative Method*, 2, 45-53.
- Suhartono, Prastyo, D., Kuswanto, H., dan Lee, M. (2018). Comparison between VAR, GSTAR, FFNN-VAR, and FFNN-GSTAR Models for Forecasting Oil Production. *MATEMATIKA*, Vol. 34. No. 1, 103-111.

- Suhartono, Saputri, P. D., Prastyo, D. D., dan Rahayu, S. P. (2018). Hybrid Quantile Regression Neural Network Model for Forecasting Currency Inflow and Outflow in Indonesia. *Journal of Physics: Conference Series*. 1028.
- Terasvirta, T., Lin, C.-F., dan Granger, C. W. (1993). Power of the Neural Networks Linearity Test. *Journal of Time Series Analysis*, 14, 209-220.
- Tsay, R. (2014). *Multivariate Time Series Analysis*. Chicago: John Wiley Inc.
- Wei, W. W. (2006). *Time Series Analysis Univariate and Multivariate Methods* (2nd ed.). New Jersey: Pearson Education Inc.
- 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.
- Zellner, A. (1962). An Efficient Methof of Estimating Seemingly Unrelated regression and Test for Aggregation Bias. *Journal of the American Statistical Association*, 5, 348-368.
- Zhang, G. P. (2003). Time Series Forecasting Using A Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159-175.

## LAMPIRAN

### Lampiran 1. Data yang Digunakan

Tahun	Bulan	<i>Inflow</i> (miliar Rp)			<i>Outflow</i> (miliar Rp)		
		Rp100.000	Rp50.000	Rp20.000	Rp100.000	Rp50.000	Rp20.000
2000	Januari	1,939	1066,621	210,709	0,942	576,797	137,042
2000	Februari	1,512	498,356	126,793	0,065	246,482	90,943
2000	Maret	5,890	459,725	113,450	0,842	287,803	103,072
2000	April	21,416	471,535	120,950	5,038	275,339	95,453
:	:	:	:	:	:	:	:
2019	Maret	2122,191	1121,552	29,891	1887,846	995,671	25,827
2019	April	1241,243	1241,243	29,570	917,165	917,165	29,342
2019	Mei	1078,396	1078,396	42,747	778,878	778,878	64,005
2019	Juni	3004,200	3004,200	175,259	2778,946	2778,946	151,780

### *Outflow* (miliar Rp)

**Lampiran 1.** Data yang Digunakan (lanjutan)

Tahun	Bulan	<i>Inflow</i> (miliar Rp)					
		Yogyakarta			Bandung		
		Rp100.000	Rp50.000	Rp20.000	Rp100.000	Rp50.000	Rp20.000
2000	Januari	4,476	464,513	152,091	6,491	975,846	399,423
2000	Februari	7,173	207,766	86,389	9,692	499,152	201,444
2000	Maret	10,510	222,804	79,350	29,186	530,036	189,447
2000	April	16,889	212,545	80,155	55,230	492,800	174,000
:	:	:	:	:	:	:	:
2019	Maret	1023,287	497,122	17,786	2251,093	1562,487	53,017
2019	April	489,921	489,921	15,626	1655,428	1655,428	57,622
2019	Mei	295,769	295,769	18,584	1412,466	1412,466	61,073
2019	Juni	1316,435	1316,435	67,584	3762,908	3762,908	166,734
<i>Outflow</i> (miliar Rp)							
2000	Januari	4,0964	82,6556	30,65176	12,6912	171,5073	81,3172
2000	Februari	7,3068	120,483	58,54136	23,1	323,364	93,4131
2000	Maret	10,6696	190,8823	82,6613	63,15	434,6378	167,9169
2000	April	15,9427	130,8038	51,45794	91,7988	243,1075	110,8472
:	:	:	:	:	:	:	:
2019	Maret	1063,609	667,2145	116,4116	2217,819	1400,051	63,54606
2019	April	1306,231	810,109	55,278	2356,646	1356,76	94,92404
2019	Mei	2788,997	1896,583	160,418	7798,991	4241,468	466,5198
2019	Juni	245,8782	94,1271	0,156	371,1619	184,2146	2,71954

**Lampiran 1.** Data yang Digunakan (lanjutan)

		<i>Inflow</i> (miliar Rp)		
Tahun	Bulan	Jakarta		
		Rp100.000	Rp50.000	Rp20.000
2000	Januari	1301,057	2926,503	1088,198
2000	Februari	222,876	1463,852	524,556
2000	Maret	227,447	1446,469	436,171
2000	April	250,494	1411,799	405,695
:	:	:	:	:
2019	Maret	5959,952	3844,752	108,715
2019	April	6136,122	4621,263	118,151
2019	Mei	4908,128	3838,365	156,090
2019	Juni	16277,904	8517,362	524,255
<i>Outflow</i> (miliar Rp)				
2000	Januari	317,5475	950,76615	218,9204
2000	Februari	534,3511	1710,3317	392,4011
2000	Maret	915,9751	2278,105	612,5522
2000	April	720,4558	1742,374	400,4129
:	:	:	:	:
2019	Maret	10467,12	6351,6234	233,0855
2019	April	8856,079	6476,6969	901,8337
2019	Mei	25819,78	15792,907	1433,526
2019	Juni	3111,648	1991,842	5,7744

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series*

a. *Inflow Rp100.000 KPw BI Surabaya*

	Estimate	Std.	Error	t value	Pr(> t )
t	9,3583	0,5558	16,837	< 2e-16	***
D1	-363,3281	522,5972	-0,695	0,487753	
D2	-964,7783	747,5306	-1,291	0,198395	
tD1	-2,7999	4,7784	-0,586	0,558602	
tD2	2,8248	4,7740	0,592	0,554754	
S1	484,3676	123,0725	3,936	0,000116	***
S2	38,1348	120,8480	0,316	0,752681	
S3	-82,6399	120,1043	-0,688	0,492245	
S4	-94,8720	120,1752	-0,789	0,430830	
S5	-20,1169	120,2656	-0,167	0,867334	
S6	-149,8326	120,9839	-1,238	0,217069	
S7	321,6174	123,3849	2,607	0,009866	**
S8	257,2881	125,2410	2,054	0,041304	*
S9	-51,9596	124,5511	-0,417	0,677019	
S10	148,2928	124,9083	1,187	0,236618	
S11	-142,8878	126,1547	-1,133	0,258785	
S12	-330,9167	126,2208	-2,622	0,009454	**
CV1t	1257,5097	233,9702	5,375	2,22e-07	***
CV2t	784,1328	209,8884	3,736	0,000247	***
CV3t	566,0950	233,4619	2,425	0,016248	*
CV4t	-423,1841	191,3621	-2,211	0,028192	*
CV1t+1	119,5597	233,9954	0,511	0,609977	
CV2t+1	139,1842	209,5716	0,664	0,507404	
CV3t+1	310,7640	233,4750	1,331	0,184763	
CV4t+1	1799,7647	191,6221	9,392	< 2e-16	***

b. *Inflow Rp100.000 KPw BI Semarang*

	Estimate	Std.	Error	t value	Pr(> t )
t	8,2581	0,5206	15,862	< 2e-16	***
D1	-183,8147	489,4936	-0,376	0,707690	
D2	-1559,1184	700,1786	-2,227	0,027133	*
tD1	-2,4362	4,4757	-0,544	0,586859	
tD2	8,2903	4,4716	1,854	0,065283	,
S1	199,2628	115,2765	1,729	0,085503	,
S2	-103,8627	113,1929	-0,918	0,360000	
S3	-101,8361	112,4964	-0,905	0,366479	
S4	-119,7798	112,5628	-1,064	0,288620	
S5	-180,8918	112,6474	-1,606	0,109965	
S6	-274,2043	113,3203	-2,420	0,016469	*
S7	218,2831	115,5691	1,889	0,060439	,
S8	39,4022	117,3077	0,336	0,737324	
S9	-290,3534	116,6614	-2,489	0,013671	*
S10	-61,5305	116,9961	-0,526	0,599554	
S11	-211,4132	118,1635	-1,789	0,075174	,
S12	-473,5555	118,2254	-4,006	8,86e-05	***
CV1t	1289,2710	219,1495	5,883	1,77e-08	***
CV2t	872,3949	196,5932	4,438	1,54e-05	***
CV3t	743,1867	218,6734	3,399	0,000824	***
CV4t	-352,8688	179,2404	-1,969	0,050435	,
CV1t+1	56,2997	219,1730	0,257	0,797553	
CV2t+1	184,7051	196,2964	0,941	0,347919	
CV3t+1	450,0682	218,6856	2,058	0,040942	*
CV4t+1	1652,2871	179,4839	9,206	< 2e-16	***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

c. *Inflow Rp100.000 KPw BI Yogyakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	3,461e+00	2,128e-01	16,264	< 2e-16 ***
D1	-1,123e+02	2,001e+02	-0,561	0,57538
D2	-1,488e+03	2,862e+02	-5,201	5,08e-07 ***
tD1	-2,400e+00	1,829e+00	-1,312	0,19119
tD2	8,699e+00	1,828e+00	4,760	3,82e-06 ***
S1	2,457e+02	4,711e+01	5,216	4,74e-07 ***
S2	5,990e+01	4,626e+01	1,295	0,19697
S3	6,366e+01	4,598e+01	1,385	0,16782
S4	4,214e+01	4,601e+01	0,916	0,36084
S5	6,228e+01	4,604e+01	1,353	0,17772
S6	3,618e+01	4,632e+01	0,781	0,43571
S7	2,282e+02	4,723e+01	4,831	2,78e-06 ***
S8	1,563e+02	4,795e+01	3,260	0,00132 **
S9	-2,205e+01	4,768e+01	-0,462	0,64431
S10	8,219e+01	4,782e+01	1,719	0,08728 ,
S11	-2,933e+00	4,829e+01	-0,061	0,95164
S12	-9,342e+01	4,832e+01	-1,933	0,05468 ,
CV1t	6,121e+02	8,957e+01	6,834	1,08e-10 ***
CV2t	3,920e+02	8,035e+01	4,879	2,24e-06 ***
CV3t	3,457e+02	8,937e+01	3,868	0,00015 ***
CV4t	-1,903e+02	7,326e+01	-2,597	0,01013 *
CV1t+1	5,559e-02	8,958e+01	0,001	0,99951
CV2t+1	5,583e+01	8,023e+01	0,696	0,48734
CV3t+1	6,642e+01	8,938e+01	0,743	0,45832
CV4t+1	5,781e+02	7,336e+01	7,881	2,41e-13 ***

d. *Inflow Rp100.000 KPw BI Bandung*

	Estimate	Std. Error	t value	Pr(> t )
t	13,5092	0,5755	23,472	< 2e-16 ***
D1	-831,7184	541,1351	-1,537	0,12595
D2	-4846,9052	774,0474	-6,262	2,46e-09 ***
tD1	-2,2121	4,9479	-0,447	0,65533
tD2	29,9596	4,9434	6,061	7,10e-09 ***
S1	314,3461	127,4382	2,467	0,01452 *
S2	-143,6904	125,1348	-1,148	0,25229
S3	-109,6599	124,3647	-0,882	0,37901
S4	-202,7605	124,4382	-1,629	0,10487
S5	-157,3491	124,5317	-1,264	0,20794
S6	-212,2629	125,2755	-1,694	0,09183 ,
S7	200,0758	127,7617	1,566	0,11900
S8	207,9619	129,6837	1,604	0,11045
S9	-69,8515	128,9692	-0,542	0,58872
S10	-51,2059	129,3391	-0,396	0,69262
S11	-255,0580	130,6297	-1,953	0,05234 ,
S12	-540,6196	130,6982	-4,136	5,28e-05 ***
CV1t	1542,2288	242,2697	6,366	1,41e-09 ***
CV2t	714,4040	217,3337	3,287	0,00120 **
CV3t	681,8159	241,7434	2,820	0,00530 **
CV4t	-538,7026	198,1502	-2,719	0,00716 **
CV1t+1	59,4396	242,2958	0,245	0,80647
CV2t+1	226,8523	217,0057	1,045	0,29717
CV3t+1	583,8836	241,7569	2,415	0,01667 *
CV4t+1	1693,9618	198,4195	8,537	4,25e-15 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

e. *Inflow Rp100.000 KPw BI Jakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	23,052	1,319	17,482	< 2e-16 ***
D1	-1550,728	1239,740	-1,251	0,2125
D2	-3805,621	1773,341	-2,146	0,0331 *
tD1	3,312	11,336	0,292	0,7705
tD2	21,873	11,325	1,931	0,0549 ,
S1	1170,890	291,961	4,010	8,69e-05 ***
S2	51,424	286,684	0,179	0,8578
S3	-88,367	284,919	-0,310	0,7568
S4	-259,352	285,088	-0,910	0,3641
S5	-130,773	285,302	-0,458	0,6472
S6	-355,954	287,006	-1,240	0,2164
S7	560,022	292,702	1,913	0,0572 ,
S8	535,663	297,105	1,803	0,0730 ,
S9	-98,575	295,468	-0,334	0,7390
S10	-100,652	296,316	-0,340	0,7345
S11	-761,450	299,273	-2,544	0,0117 *
S12	-1347,923	299,429	-4,502	1,17e-05 ***
CV1t	3916,272	555,039	7,056	3,08e-11 ***
CV2t	2811,233	497,911	5,646	5,87e-08 ***
CV3t	2875,834	553,834	5,193	5,29e-07 ***
CV4t	-895,305	453,962	-1,972	0,0500 ,
CV1t+1	111,367	555,099	0,201	0,8412
CV2t+1	290,523	497,160	0,584	0,5597
CV3t+1	342,289	553,865	0,618	0,5373
CV4t+1	4344,013	454,579	9,556	< 2e-16 ***

f. *Inflow Rp50.000 KPw BI Surabaya*

	Estimate	Std. Error	t value	Pr(> t )
t	3,1256	0,3204	9,756	< 2e-16 ***
D1	-611,7905	301,2248	-2,031	0,043640 *
D2	110,1598	430,8763	0,256	0,798485
tD1	2,5491	2,7543	0,926	0,355861
tD2	-2,0106	2,7517	-0,731	0,465884
S1	690,8547	70,9389	9,739	< 2e-16 ***
S2	425,5089	69,6567	6,109	5,52e-09 ***
S3	353,6908	69,2281	5,109	7,81e-07 ***
S4	381,0262	69,2690	5,501	1,20e-07 ***
S5	401,6532	69,3210	5,794	2,79e-08 ***
S6	333,2283	69,7351	4,778	3,51e-06 ***
S7	564,7688	71,1190	7,941	1,67e-13 ***
S8	546,7841	72,1889	7,574	1,51e-12 ***
S9	439,1184	71,7912	6,117	5,29e-09 ***
S10	587,8609	71,9971	8,165	4,27e-14 ***
S11	394,0959	72,7155	5,420	1,79e-07 ***
S12	261,1562	72,7536	3,590	0,000421 ***
CV1t	922,4645	134,8603	6,840	1,04e-10 ***
CV2t	733,2709	120,9796	6,061	7,08e-09 ***
CV3t	105,1884	134,5673	0,782	0,435372
CV4t	-239,7277	110,3010	-2,173	0,030981 *
CV1t+1	128,3108	134,8748	0,951	0,342638
CV2t+1	172,1550	120,7970	1,425	0,155743
CV3t+1	460,2812	134,5749	3,420	0,000765 ***
CV4t+1	1108,7803	110,4509	10,039	< 2e-16 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

g. *Inflow Rp50.000 KPw BI Semarang*

	Estimate	Std. Error	t value	Pr(> t )
t	3,814	0,260	14,668	< 2e-16 ***
D1	-388,899	244,470	-1,591	0,113311
D2	-239,810	349,693	-0,686	0,493687
tD1	1,761	2,235	0,788	0,431715
tD2	1,402	2,233	0,628	0,530766
S1	365,395	57,573	6,347	1,56e-09 ***
S2	126,012	56,532	2,229	0,026978 *
S3	156,146	56,184	2,779	0,005994 **
S4	181,158	56,218	3,222	0,001495 **
S5	110,818	56,260	1,970	0,050312 ,
S6	38,615	56,596	0,682	0,495882
S7	269,288	57,719	4,665	5,78e-06 ***
S8	230,523	58,587	3,935	0,000117 ***
S9	67,289	58,265	1,155	0,249583
S10	161,004	58,432	2,755	0,006429 **
S11	123,938	59,015	2,100	0,037031 *
S11	-75,699	59,046	-1,282	0,201382
CV1t	829,811	109,451	7,582	1,44e-12 ***
CV2t	535,892	98,185	5,458	1,48e-07 ***
CV3t	250,907	109,213	2,297	0,022679 *
CV4t	-278,416	89,519	-3,110	0,002156 **
CV1t+1	139,554	109,462	1,275	0,203891
CV2t+1	246,922	98,037	2,519	0,012601 *
CV3t+1	375,489	109,219	3,438	0,000719 ***
CV4t+1	993,736	89,640	11,086	< 2e-16 ***

h. *Inflow Rp50.000 KPw BI Yogyakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	1,7897	0,1210	14,786	< 2e-16 ***
D1	-182,5723	113,8002	-1,604	0,110295
D2	-638,8620	162,7814	-3,925	0,000121 ***
tD1	-0,9836	1,0405	-0,945	0,345704
tD2	3,3366	1,0396	3,210	0,001559 **
S1	269,1502	26,8001	10,043	< 2e-16 ***
S2	140,7160	26,3157	5,347	2,53e-07 ***
S3	154,4909	26,1538	5,907	1,57e-08 ***
S4	144,6827	26,1692	5,529	1,05e-07 ***
S5	159,6100	26,1889	6,095	5,94e-09 ***
S6	144,4663	26,3453	5,484	1,31e-07 ***
S7	240,8561	26,8682	8,964	2,85e-16 ***
S8	197,2882	27,2724	7,234	1,11e-11 ***
S9	140,1676	27,1221	5,168	5,93e-07 ***
S10	157,3927	27,1999	5,787	2,90e-08 ***
S11	107,5539	27,4713	3,915	0,000126 ***
S12	68,3849	27,4857	2,488	0,013702 *
CV1t	380,2890	50,9491	7,464	2,89e-12 ***
CV2t	335,6402	45,7051	7,344	5,85e-12 ***
Cv3t	46,7477	50,8384	0,920	0,358976
Cv4t	-166,9157	41,6708	-4,006	8,86e-05 ***
CV1t+1	33,2186	50,9546	0,652	0,515233
CV2t+1	111,6636	45,6361	2,447	0,015317 *
CV3t+1	31,2195	50,8413	0,614	0,539908
CV4t+1	371,7356	41,7274	8,909	4,07e-16 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

i. *Inflow Rp50.000 KPw BI Bandung*

	Estimate	Std. Error	t value	Pr(> t )
t	7,8542	0,3509	22,384	< 2e-16 ***
D1	-1108,5578	329,9107	-3,360	0,000941 ***
D2	-1916,2649	471,9091	-4,061	7,14e-05 ***
tD1	3,6327	3,0166	1,204	0,229976
tD2	11,5341	3,0138	3,827	0,000176 ***
S1	540,6122	77,6945	6,958	5,36e-11 ***
S2	250,5969	76,2902	3,285	0,001214 **
S3	291,7104	75,8207	3,847	0,000163 ***
S4	237,6849	75,8655	3,133	0,002003 **
S5	291,8531	75,9226	3,844	0,000165 ***
S6	242,3551	76,3760	3,173	0,001757 **
S7	460,3800	77,8917	5,911	1,54e-08 ***
S8	435,3106	79,0635	5,506	1,17e-07 ***
S9	300,4191	78,6279	3,821	0,000180 ***
S10	328,9787	78,8535	4,172	4,58e-05 ***
S11	181,8008	79,6403	2,283	0,023545 *
S12	-47,8208	79,6820	-0,600	0,549121
CV1t	1180,4159	147,7032	7,992	1,23e-13 ***
CV2t	515,2636	132,5006	3,889	0,000139 ***
CV3t	316,3727	147,3823	2,147	0,033085 *
CV4t	-379,7251	120,8051	-3,143	0,001937 **
CV1t+1	110,1970	147,7191	0,746	0,456590
CV2t+1	274,5406	132,3006	2,075	0,039315 *
CV3t+1	478,4402	147,3906	3,246	0,001382 **
CV4t+1	1111,3895	120,9693	9,187	< 2e-16 ***

j. *Inflow Rp50.000 KPw BI Jakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	10,666	1,042	10,235	< 2e-16 ***
D1	-2105,995	979,820	-2,149	0,032863 *
D2	-2268,333	1401,549	-1,618	0,107216
tD1	8,526	8,959	0,952	0,342483
tD2	10,031	8,951	1,121	0,263817
S1	2566,101	230,749	11,121	< 2e-16 ***
S2	1573,695	226,579	6,945	5,76e-11 ***
S3	1592,642	225,184	7,073	2,80e-11 ***
S4	1516,880	225,317	6,732	1,90e-10 ***
S5	1414,884	225,487	6,275	2,29e-09 ***
S6	1400,154	226,833	6,173	3,94e-09 ***
S7	1895,807	231,335	8,195	3,55e-14 ***
S8	1844,037	234,815	7,853	2,85e-13 ***
S9	1611,688	233,521	6,902	7,37e-11 ***
S10	1609,812	234,191	6,874	8,62e-11 ***
S11	1057,216	236,528	4,470	1,34e-05 ***
S12	823,165	236,652	3,478	0,000625 ***
CV1t	3225,815	438,672	7,354	5,52e-12 ***
CV2t	2856,306	393,521	7,258	9,60e-12 ***
CV3t	1185,499	437,719	2,708	0,007376 **
CV4t	-996,650	358,786	-2,778	0,006018 **
CV1t+1	274,140	438,719	0,625	0,532806
CV2t+1	707,551	392,927	1,801	0,073325 ,
CV3t+1	145,981	437,743	0,333	0,739133
CV4t+1	2492,160	359,273	6,937	6,05e-11 ***

## Lampiran 2. Estimasi Parameter Model Regresi *Time Series* (lanjutan)

### k. Inflow Rp20.000 KPw BI Surabaya

	Estimate	Std. Error	t value	Pr(> t )
t	-0,22610	0,03300	-6,851	9,81e-11 ***
D1	-89,40396	31,03007	-2,881	0,00441 **
D2	-18,79459	44,38586	-0,423	0,67245
tD1	0,46599	0,28373	1,642	0,10215
tD2	-0,02323	0,28346	-0,082	0,93478
S1	115,84696	7,30763	15,853	< 2e-16 ***
S2	94,64058	7,17555	13,189	< 2e-16 ***
S3	90,54591	7,13139	12,697	< 2e-16 ***
S4	88,34867	7,13560	12,381	< 2e-16 ***
S5	87,10922	7,14097	12,199	< 2e-16 ***
S6	82,67006	7,18362	11,508	< 2e-16 ***
S7	99,91616	7,32618	13,638	< 2e-16 ***
S8	113,35843	7,43639	15,244	< 2e-16 ***
S9	99,75240	7,39542	13,488	< 2e-16 ***
S10	100,28144	7,41664	13,521	< 2e-16 ***
S11	104,31656	7,49064	13,926	< 2e-16 ***
S12	87,63909	7,49457	11,694	< 2e-16 ***
CV1t	34,68316	13,89236	2,497	0,01339 *
CV2t	27,45298	12,46247	2,203	0,02880 *
CV3t	-16,01571	13,86218	-1,155	0,24939
CV4t	-31,95233	11,36244	-2,812	0,00544 **
CV1t+1	45,50007	13,89386	3,275	0,00126 **
CV2t+1	36,57108	12,44366	2,939	0,00370 **
CV3t+1	44,21491	13,86296	3,189	0,00167 **
CV4t+1	86,65354	11,37788	7,616	1,18e-12 ***

### l. Inflow Rp20.000 KPw BI Semarang

	Estimate	Std. Error	t value	Pr(> t )
t	-0,12120	0,02385	-5,081	8,90e-07 ***
D1	-36,62572	22,42647	-1,633	0,10409
D2	-31,91952	32,07915	-0,995	0,32098
tD1	0,16639	0,20506	0,811	0,41613
tD2	0,16666	0,20487	0,813	0,41695
S1	73,36093	5,28147	13,890	< 2e-16 ***
S2	60,37508	5,18601	11,642	< 2e-16 ***
S3	62,24646	5,15410	12,077	< 2e-16 ***
S4	60,58587	5,15714	11,748	< 2e-16 ***
S5	56,92255	5,16102	11,029	< 2e-16 ***
S6	51,95836	5,19184	10,008	< 2e-16 ***
S7	61,39011	5,29488	11,594	< 2e-16 ***
S8	68,84440	5,37453	12,809	< 2e-16 ***
S9	65,25398	5,34492	12,209	< 2e-16 ***
S10	63,87982	5,36025	11,917	< 2e-16 ***
S11	61,03017	5,41374	11,273	< 2e-16 ***
S12	55,57241	5,41658	10,260	< 2e-16 ***
CV1t	16,61164	10,04048	1,654	0,09968 ,
CV2t	12,38296	9,00705	1,375	0,17080
CV3t	-2,91991	10,01867	-0,291	0,77103
CV4t	-20,35826	8,21202	-2,479	0,01404 *
CV1t+1	28,16189	10,04156	2,805	0,00556 **
CV2t+1	23,51343	8,99345	2,615	0,00965 **
CV3t+1	42,55996	10,01923	4,248	3,37e-05 ***
CV4t+1	70,38709	8,22318	8,560	3,69e-15 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)  
 m. *Inflow Rp20.000 KPw BI Yogyakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	-0,17823	0,01659	-10,746	< 2e-16 ***
D1	-42,82237	15,59390	-2,746	0,00661 **
D2	-73,88963	22,30574	-3,313	0,00111 **
tD1	0,19035	0,14258	1,335	0,18347
tD2	0,39743	0,14245	2,790	0,00581 **
S1	62,76630	3,67239	17,091	< 2e-16 ***
S2	53,25803	3,60601	14,769	< 2e-16 ***
S3	54,43216	3,58382	15,188	< 2e-16 ***
S4	52,00310	3,58594	14,502	< 2e-16 ***
S5	50,50810	3,58863	14,074	< 2e-16 ***
S6	48,25826	3,61007	13,368	< 2e-16 ***
S7	52,65633	3,68171	14,302	< 2e-16 ***
S8	52,38818	3,73710	14,018	< 2e-16 ***
S9	53,23408	3,71651	14,324	< 2e-16 ***
S10	52,39050	3,72717	14,056	< 2e-16 ***
S11	47,61914	3,76436	12,650	< 2e-16 ***
S12	46,20292	3,76633	12,267	< 2e-16 ***
CV1t	12,73747	6,98149	1,824	0,06964 ,
CV2t	21,91619	6,26291	3,499	0,00058 ***
CV3t	10,04218	6,96632	1,442	0,15107
CV4t	-12,00872	5,71010	-2,103	0,03677 *
CV1t+1	13,03020	6,98224	1,866	0,06355 ,
CV2t+1	20,16830	6,25346	3,225	0,00148 **
CV3t+1	16,67983	6,96672	2,394	0,01762 *
CV4t+1	41,36409	5,71786	7,234	1,1e-11 ***

n. *Inflow Rp20.000 KPw BI Bandung*

	Estimate	Std. Error	t value	Pr(> t )
t	-0,24942	0,04544	-5,488	1,28e-07 ***
D1	-124,78518	42,72709	-2,921	0,00392 **
D2	-94,13043	61,11744	-1,540	0,12518
tD1	0,58923	0,39068	1,508	0,13315
tD2	0,46439	0,39032	1,190	0,23561
S1	137,74297	10,06230	13,689	< 2e-16 ***
S2	115,06009	9,88043	11,645	< 2e-16 ***
S3	119,18072	9,81963	12,137	< 2e-16 ***
S4	112,35895	9,82542	11,436	< 2e-16 ***
S5	111,10495	9,83281	11,299	< 2e-16 ***
S6	107,40840	9,89154	10,859	< 2e-16 ***
S7	127,42290	10,08784	12,631	< 2e-16 ***
S8	128,62800	10,23960	12,562	< 2e-16 ***
S9	116,63643	10,18319	11,454	< 2e-16 ***
S10	113,93023	10,21240	11,156	< 2e-16 ***
S11	103,49043	10,31430	10,034	< 2e-16 ***
S12	101,86710	10,31970	9,871	< 2e-16 ***
CV1t	33,20233	19,12920	1,736	0,08423 ,
CV2t	59,80973	17,16030	3,485	0,00061 ***
Cv3t	-0,98429	19,08764	-0,052	0,95893
CV4t	-32,38208	15,64560	-2,070	0,03982 *
CV1t+1	23,04523	19,13126	1,205	0,22985
CV2t+1	40,92133	17,13439	2,388	0,01790 *
CV3t+1	64,38968	19,08871	3,373	0,00090 ***
CV4t+1	99,58392	15,66686	6,356	1,48e-09 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

o. *Inflow Rp20.000 KPw BI Jakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	-0,8181	0,1037	-7,893	2,24e-13 ***
D1	-213,8274	97,4564	-2,194	0,029436 *
D2	-177,1688	139,4031	-1,271	0,205306
tD1	0,8848	0,8911	0,993	0,322025
tD2	0,8192	0,8903	0,920	0,358653
S1	352,3756	22,9511	15,353	< 2e-16 ***
S2	300,5018	22,5363	13,334	< 2e-16 ***
S3	296,3989	22,3976	13,233	< 2e-16 ***
S4	284,6037	22,4108	12,699	< 2e-16 ***
S5	284,1072	22,4277	12,668	< 2e-16 ***
S6	275,0511	22,5617	12,191	< 2e-16 ***
S7	318,6469	23,0094	13,849	< 2e-16 ***
S8	338,9287	23,3555	14,512	< 2e-16 ***
S9	309,3316	23,2269	13,318	< 2e-16 ***
S10	287,6056	23,2935	12,347	< 2e-16 ***
S11	272,4962	23,5259	11,583	< 2e-16 ***
S12	257,3637	23,5383	10,934	< 2e-16 ***
CV1t	170,3493	43,6319	3,904	0,000131 ***
CV2t	187,0172	39,1410	4,778	3,52e-06 ***
CV3t	-17,9443	43,5371	-0,412	0,680684
CV4t	-61,5182	35,6861	-1,724	0,086350 ,
CV1t+1	91,8608	43,6366	2,105	0,036587 *
CV2t+1	102,0725	39,0819	2,612	0,009724 **
CV3t+1	139,5642	43,5395	3,205	0,001581 **
CV4t+1	236,4557	35,7346	6,617	3,60e-10 ***

p. *Outflow Rp100.000 KPw BI Surabaya*

	Estimate	Std. Error	t value	Pr(> t )
t	7,3792	0,4885	15,105	< 2e-16 ***
D1	-88,9633	460,1286	-0,193	0,846895
D2	-1857,1015	658,7778	-2,819	0,005325 **
tD1	-5,3035	4,2064	-1,261	0,208914
tD2	9,1188	4,2070	2,168	0,031433 *
S1	-178,2947	106,4038	-1,676	0,095445 .
S2	-26,2561	105,7472	-0,248	0,804176
S3	206,6735	105,7934	1,954	0,052214 .
S4	214,4003	105,8568	2,025	0,044220 *
S4	215,6581	106,4661	2,026	0,044197 *
S5	400,9050	108,5536	3,693	0,000289 ***
S6	296,4272	110,0398	2,694	0,007693 **
S7	286,3462	109,4169	2,617	0,009580 **
S8	134,9601	109,7136	1,230	0,220168
S10	60,6639	110,8055	0,547	0,584688
S11	81,3804	111,0004	0,733	0,464363
S12	687,9108	108,8386	6,320	1,80e-09 ***
CV1t-1	1150,6842	206,1320	5,582	8,06e-08 ***
CV2t-1	482,2204	206,6424	2,334	0,020657 *
CV3t-1	-56,1584	205,7016	-0,273	0,785141
CV4t-1	113,7362	168,5908	0,675	0,500728
CV1t	-395,6762	206,1323	-1,920	0,056408 .
CV2t	304,3889	184,6203	1,649	0,100847
CV3t	788,9058	205,5369	3,838	0,000168 ***
CV4t	1155,9598	168,7658	6,849	9,89e-11 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

q. *Outflow Rp100.000 KPw BI Semarang*

	Estimate	Std. Error	t value	Pr(> t )
t	5,659e+00	3,693e-01	15,323	< 2e-16 ***
D1	1,361e+02	3,478e+02	0,391	0,69593
D2	-1,333e+03	4,980e+02	-2,677	0,00807 **
tD1	-6,125e+00	3,180e+00	-1,926	0,05557 .
tD2	6,154e+00	3,180e+00	1,935	0,05445 .
S1	-2,120e+02	8,044e+01	-2,635	0,00910 **
S2	-9,366e+01	7,994e+01	-1,172	0,24279
S3	-4,977e+01	7,997e+01	-0,622	0,53443
S4	1,565e+01	8,002e+01	0,196	0,84515
S5	3,528e+00	8,048e+01	0,044	0,96509
S6	3,337e+02	8,206e+01	4,066	6,98e-05 ***
S7	1,257e+02	8,318e+01	1,511	0,13254
S8	-3,407e+01	8,271e+01	-0,412	0,68087
S9	4,653e+01	8,294e+01	0,561	0,57542
S10	-1,254e+02	8,376e+01	-1,497	0,13597
S11	-1,125e+02	8,391e+01	-1,341	0,18157
S12	2,163e+02	8,228e+01	2,629	0,00926 **
CV1t-1	1,072e+03	1,558e+02	6,882	8,24e-11 ***
CV2t-1	4,354e+02	1,562e+02	2,787	0,00585 **
CV3t-1	-5,135e+01	1,555e+02	-0,330	0,74157
CV4t-1	3,328e+01	1,274e+02	0,261	0,79430
CV1t	-3,426e-02	1,558e+02	0,000	0,99982
CV2t	4,183e+02	1,396e+02	2,997	0,00309 **
CV3t	7,906e+02	1,554e+02	5,088	8,60e-07 ***
CV4t	1,040e+03	1,276e+02	8,152	4,62e-14 ***

r. *Outflow Rp100.000 KPw BI Yogyakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	2,6503	0,2338	11,337	< 2e-16 ***
D1	82,5030	220,1718	0,375	0,708284
D2	-1213,3799	315,2256	-3,849	0,000162 ***
tD1	-3,0759	2,0128	-1,528	0,128114
tD2	7,4939	2,0131	3,723	0,000259 ***
S1	-101,0997	50,9143	-1,986	0,048499 *
S2	-21,1072	50,6001	-0,417	0,677046
S3	26,0535	50,6222	0,515	0,607381
S4	82,5238	50,6525	1,629	0,104916
S5	83,7817	50,9441	1,645	0,101701
S6	226,2780	51,9430	4,356	2,16e-05 ***
S7	161,9231	52,6541	3,075	0,002412 **
S8	141,9960	52,3561	2,712	0,007296 **
S9	169,5130	52,4980	3,229	0,001463 **
S10	71,8851	53,0205	1,356	0,176764
S11	13,7050	53,1137	0,258	0,796661
S12	198,2173	52,0794	3,806	0,000190 ***
CV1t-1	476,4722	98,6343	4,831	2,78e-06 ***
Cv2t-1	271,4317	98,8785	2,745	0,006627 **
CV3t-1	3,1426	98,4283	0,032	0,974563
CV4t-1	15,8269	80,6708	0,196	0,844669
CV1t	-142,1135	98,6344	-1,441	0,151276
CV2t	171,9717	88,3409	1,947	0,053040 .
CV3t	608,5914	98,3495	6,188	3,63e-09 ***
CV4t	578,9377	80,7545	7,169	1,61e-11 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

s. *Outflow Rp100.000 KPw BI Bandung*

	Estimate	Std. Error	t value	Pr(> t )
t	7,376	0,591	12,481	< 2e-16 ***
D1	-349,542	556,632	-0,628	0,530781
D2	-3235,242	796,944	-4,060	7,17e-05 ***
tD1	-3,796	5,089	-0,746	0,456646
tD2	18,515	5,089	3,638	0,000353 ***
S1	-241,121	128,720	-1,873	0,062565 .
S2	-28,759	127,926	-0,225	0,822365
S3	91,958	127,982	0,719	0,473313
S4	111,904	128,058	0,874	0,383294
S5	129,719	128,795	1,007	0,315126
S6	468,236	131,321	3,566	0,000459 ***
S7	283,149	133,119	2,127	0,034700 *
S8	-52,165	132,365	-0,394	0,693948
S9	-49,644	132,724	-0,374	0,708792
S10	-60,618	134,045	-0,452	0,651622
S11	-20,779	134,281	-0,155	0,877187
S12	584,860	131,666	4,442	1,51e-05 ***
CV1t-1	1638,481	249,364	6,571	4,64e-10 ***
CV2t-1	656,050	249,982	2,624	0,009383 **
CV3t-1	143,344	248,844	0,576	0,565266
CV4t-1	115,357	203,950	0,566	0,572320
CV1t	-234,658	249,365	-0,941	0,347881
CV2t	578,309	223,341	2,589	0,010356 *
CV3t	1288,455	248,644	5,182	5,56e-07 ***
CV4t	1657,671	204,161	8,119	5,65e-14 ***

t. *Outflow Rp100.000 KPw BI Jakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	35,418	2,197	16,123	< 2e-16 ***
D1	-646,017	2068,945	-0,312	0,75520
D2	-6794,721	2962,161	-2,294	0,02289 *
tD1	-12,389	18,914	-0,655	0,51322
tD2	43,486	18,917	2,299	0,02260 *
S1	-1519,650	478,439	-3,176	0,00174 **
S2	-851,966	475,487	-1,792	0,07475 .
S3	118,270	475,695	0,249	0,80392
S4	182,546	475,980	0,384	0,70176
S5	307,357	478,719	0,642	0,52162
S6	1043,489	488,106	2,138	0,03380 *
S7	618,620	494,789	1,250	0,21273
S8	-266,733	491,988	-0,542	0,58834
S9	-431,998	493,322	-0,876	0,38230
S10	57,310	498,232	0,115	0,90854
S11	49,672	499,108	0,100	0,92083
S12	2483,553	489,387	5,075	9,16e-07 ***
CV1t-1	5153,147	926,862	5,560	9,01e-08 ***
CV2t-1	1827,980	929,157	1,967	0,05059 .
CV3t-1	471,784	924,927	0,510	0,61059
CV4t-1	155,270	758,060	0,205	0,83793
CV1t	-1911,349	926,863	-2,062	0,04055 *
CV2t	1039,972	830,136	1,253	0,21182
CV3t	4320,350	924,186	4,675	5,55e-06 ***
CV4t	5219,043	758,847	6,878	8,44e-11 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

u. *Outflow Rp50.000 KPw BI Surabaya*

	Estimate	Std. Error	t value	Pr(> t )
t	4,1596	0,4032	10,316	< 2e-16 ***
D1	-191,4663	379,7836	-0,504	0,614740
D2	-668,8666	543,7457	-1,230	0,220169
tD1	-2,6367	3,4719	-0,759	0,448516
tD2	2,4951	3,4724	0,719	0,473296
S1	54,7821	87,8242	0,624	0,533523
S2	247,5483	87,2823	2,836	0,005058 **
S3	420,5745	87,3204	4,816	2,97e-06 ***
S4	396,5227	87,3727	4,538	1,00e-05 ***
S5	380,3016	87,8756	4,328	2,43e-05 ***
S6	578,8550	89,5986	6,461	8,45e-10 ***
S7	413,8685	90,8253	4,557	9,25e-06 ***
S8	481,6990	90,3112	5,334	2,70e-07 ***
S9	313,7016	90,5560	3,464	0,000657 ***
S10	295,6325	91,4573	3,232	0,001446 **
S11	328,6858	91,6181	3,588	0,000424 ***
S12	659,0713	89,8339	7,337	6,10e-12 ***
CV1t-1	1130,7085	170,1384	6,646	3,07e-10 ***
CV2t-1	453,5185	170,5597	2,659	0,008502 **
CV3t-1	-55,2021	169,7832	-0,325	0,745436
CV4t-1	22,6836	139,1524	0,163	0,870681
CV1t	-334,8420	170,1386	-1,968	0,050509 .
CV2t	748,2201	152,3830	4,910	1,95e-06 ***
CV3t	895,4988	169,6472	5,279	3,52e-07 ***
CV4t	1181,5965	139,2969	8,483	5,98e-15 ***

v. *Outflow Rp50.000 KPw BI Semarang*

	Estimate	Std. Error	t value	Pr(> t )
t	2,3210	0,2139	10,851	< 2e-16 ***
D1	-206,9264	201,4684	-1,027	0,305676
D2	-772,7164	288,4473	-2,679	0,008031 **
tD1	-0,9441	1,8418	-0,513	0,608816
tD2	4,3629	1,8421	2,368	0,018859 *
S1	-10,0470	46,5891	-0,216	0,829490
S2	82,8434	46,3017	1,789	0,075166 .
S3	155,8155	46,3219	3,364	0,000929 ***
S4	171,5381	46,3496	3,701	0,000281 ***
S5	186,0336	46,6164	3,991	9,38e-05 ***
S6	290,4614	47,5304	6,111	5,45e-09 ***
S7	212,4361	48,1812	4,409	1,73e-05 ***
S8	129,9035	47,9084	2,711	0,007309 **
S9	122,4595	48,0383	2,549	0,011583 *
S10	56,6066	48,5165	1,167	0,244765
S11	62,3070	48,6018	1,282	0,201400
S12	245,4933	47,6552	5,151	6,41e-07 ***
CV1t-1	744,9683	90,2554	8,254	2,47e-14 ***
CV2t-1	315,9598	90,4788	3,492	0,000595 ***
CV3t-1	-38,5111	90,0669	-0,428	0,669436
CV4t-1	-19,5431	73,8179	-0,265	0,791490
CV1t	-27,5675	90,2555	-0,305	0,760365
CV2t	389,5384	80,8364	4,819	2,94e-06 ***
CV3t	573,0617	89,9948	6,368	1,40e-09 ***
CV4t	696,6261	73,8945	9,427	< 2e-16 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

w. *Outflow* Rp50.000 KPw BI Yogyakarta

	Estimate	Std. Error	t value	Pr(> t )
t	2,1821	0,1469	14,855	< 2e-16 ***
D1	-19,6165	138,3527	-0,142	0,887398
D2	-489,1241	198,0831	-2,469	0,014416 *
tD1	-1,8807	1,2648	-1,487	0,138671
tD2	2,4642	1,2650	1,948	0,052880 .
S1	-62,0910	31,9938	-1,941	0,053764 .
S2	7,6437	31,7964	0,240	0,810281
S3	53,6099	31,8102	1,685	0,093563 .
S4	65,2402	31,8293	2,050	0,041761 *
S5	68,1521	32,0125	2,129	0,034542 *
S6	140,4744	32,6402	4,304	2,68e-05 ***
S7	108,3965	33,0871	3,276	0,001250 **
S8	57,4611	32,8998	1,747	0,082323 .
S9	47,2055	32,9890	1,431	0,154079
S10	10,8101	33,3173	0,324	0,745946
S11	-4,3198	33,3759	-0,129	0,897155
S12	127,1856	32,7259	3,886	0,000140 ***
CV1t-1	413,1007	61,9803	6,665	2,76e-10 ***
CV2t-1	156,2224	62,1338	2,514	0,012753 *
CV3t-1	-5,5209	61,8509	-0,089	0,928968
CV4t-1	29,2231	50,6923	0,576	0,564969
CV1t	-97,0296	61,9804	-1,565	0,119124
CV2t	220,3929	55,5121	3,970	0,000102 ***
CV3t	329,1608	61,8014	5,326	2,80e-07 ***
CV4t	431,0352	50,7450	8,494	5,56e-15 ***

x. *Outflow* Rp50.000 KPw BI Bandung

	Estimate	Std. Error	t value	Pr(> t )
t	4,25570	0,34054	12,497	< 2e-16 ***
D1	-477,64365	320,74244	-1,489	0,13809
D2	-650,38176	459,21504	-1,416	0,15832
tD1	-0,01348	2,93214	-0,005	0,99634
tD2	3,10113	2,93260	1,057	0,29163
S1	-40,29621	74,17103	-0,543	0,58757
S2	72,10306	73,71336	0,978	0,32924
S3	222,03705	73,74555	3,011	0,00296 **
S4	208,07664	73,78973	2,820	0,00531 **
S5	210,11890	74,21443	2,831	0,00513 **
S6	360,60181	75,66958	4,765	3,72e-06 ***
S7	245,41914	76,70560	3,199	0,00161 **
S8	83,88465	76,27139	1,100	0,27280
S9	72,81958	76,47820	0,952	0,34222
S10	77,68748	77,23936	1,006	0,31578
S11	47,64925	77,37516	0,616	0,53875
S12	340,87169	75,86828	4,493	1,21e-05 ***
CV1t-1	1138,89788	143,68871	7,926	1,83e-13 ***
CV2t-1	361,00667	144,04448	2,506	0,01304 *
CV3t-1	40,79764	143,38868	0,285	0,77632
CV4t-1	41,02695	117,51981	0,349	0,72739
CV1t	-111,82558	143,68887	-0,778	0,43739
CV2t	372,09021	128,69352	2,891	0,00428 **
CV3t	830,90545	143,27386	5,799	2,72e-08 ***
CV4t	1129,66656	117,64180	9,603	< 2e-16 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

y. *Outflow Rp50.000 KPw BI Jakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	16,292	1,612	10,108	< 2e-16 ***
D1	-95,990	1518,133	-0,063	0,94965
D2	-6171,123	2173,549	-2,839	0,00501 **
tD1	-17,289	13,878	-1,246	0,21437
tD2	33,626	13,881	2,423	0,01635 *
S1	1080,290	351,065	3,077	0,00240 **
S2	1690,413	348,899	4,845	2,61e-06 ***
S3	2690,392	349,051	7,708	6,82e-13 ***
S4	2323,036	349,260	6,651	2,98e-10 ***
S5	2653,626	351,270	7,554	1,70e-12 ***
S6	2774,913	358,158	7,748	5,37e-13 ***
S7	2524,222	363,062	6,953	5,53e-11 ***
S8	1938,630	361,006	5,370	2,27e-07 ***
S9	1841,550	361,985	5,087	8,64e-07 ***
S10	1976,848	365,588	5,407	1,90e-07 ***
S11	2252,383	366,231	6,150	4,44e-09 ***
S12	4277,443	359,098	11,912	< 2e-16 ***
CV1t-1	5215,284	680,105	7,668	8,63e-13 ***
CV2t-1	2966,334	681,789	4,351	2,21e-05 ***
CV3t-1	-316,466	678,685	-0,466	0,64154
CV4t-1	12,359	556,243	0,022	0,98230
CV1t	-1286,672	680,106	-1,892	0,06002 .
CV2t	2674,198	609,130	4,390	1,87e-05 ***
CV3t	3153,032	678,141	4,650	6,20e-06 ***
Cv4t	3831,203	556,820	6,881	8,30e-11 ***

z. *Outflow Rp20.000 KPw BI Surabaya*

	Estimate	Std. Error	t value	Pr(> t )
t	-0,03775	0,05816	-0,649	0,517041
D1	-73,73629	54,78023	-1,346	0,179886
D2	-68,97299	78,43024	-0,879	0,380280
tD1	0,33784	0,50079	0,675	0,500738
tD2	0,26928	0,50086	0,538	0,591454
S1	50,55953	12,66782	3,991	9,37e-05 ***
S2	55,30153	12,58965	4,393	1,85e-05 ***
S3	55,70244	12,59515	4,423	1,64e-05 ***
S4	59,78056	12,60269	4,743	4,10e-06 ***
S5	71,23092	12,67523	5,620	6,70e-08 ***
S6	122,01726	12,92376	9,441	< 2e-16 ***
S7	80,96892	13,10070	6,181	3,78e-09 ***
S8	70,32549	13,02654	5,399	1,98e-07 ***
S9	33,49587	13,06186	2,564	0,011104 *
S10	22,99158	13,19186	1,743	0,082967 .
S11	25,44770	13,21506	1,926	0,055632 .
S12	46,45535	12,95769	3,585	0,000428 ***
CV1t-1	197,35433	24,54088	8,042	9,08e-14 ***
CV2t-1	137,37475	24,60164	5,584	7,99e-08 ***
CV3t-1	151,20364	24,48963	6,174	3,91e-09 ***
CV4t-1	78,75595	20,07144	3,924	0,000122 ***
CV1t	-2,57320	24,54090	-0,105	0,916602
CV2t	49,02513	21,97982	2,230	0,026881 *
CV3t	76,09024	24,47002	3,110	0,002161 **
CV4t	199,64727	20,09227	9,937	< 2e-16 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

aa. *Outflow Rp20.000 KPw BI Semarang*

	Estimate	Std. Error	t value	Pr(> t )
t	-0,12996	0,03441	-3,777	0,000212 ***
D1	-32,55894	32,40771	-1,005	0,316329
D2	-58,50692	46,39894	-1,261	0,208864
tD1	0,12484	0,29626	0,421	0,673961
tD2	0,33789	0,29631	1,140	0,255574
S1	44,20710	7,49422	5,899	1,64e-08 ***
S2	49,48923	7,44797	6,645	3,09e-10 ***
S3	56,24203	7,45123	7,548	1,76e-12 ***
S4	55,95177	7,45569	7,505	2,28e-12 ***
S5	64,10901	7,49860	8,549	3,94e-15 ***
S6	78,98902	7,64563	10,331	< 2e-16 ***
S7	67,05442	7,75031	8,652	2,07e-15 ***
S8	54,72963	7,70644	7,102	2,37e-11 ***
S9	43,01279	7,72733	5,566	8,72e-08 ***
S10	34,99870	7,80424	4,485	1,26e-05 ***
S11	34,06158	7,81796	4,357	2,15e-05 ***
S12	46,04280	7,66571	6,006	9,41e-09 ***
CV1t-1	118,85141	14,51826	8,186	3,75e-14 ***
CV2t-1	67,20531	14,55421	4,618	7,12e-06 ***
CV3t-1	71,96073	14,48795	4,967	1,50e-06 ***
CV4t-1	35,66356	11,87416	3,003	0,003027 **
CV1t	-9,33082	14,51828	-0,643	0,521193
CV2t	16,03113	13,00315	1,233	0,219141
CV3t	77,20961	14,47635	5,334	2,71e-07 ***
CV4t	134,99638	11,88649	11,357	< 2e-16 ***

bb. *Outflow Rp20.000 KPw BI Yogyakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	-0,10862	0,02266	-4,794	3,28e-06 ***
D1	-37,45676	21,33959	-1,755	0,080816 .
D2	-44,59388	30,55243	-1,460	0,146047
tD1	0,18561	0,19508	0,951	0,342576
tD2	0,22372	0,19511	1,147	0,252975
S1	35,06669	4,93474	7,106	2,31e-11 ***
S2	38,13622	4,90429	7,776	4,53e-13 ***
S3	42,17244	4,90643	8,595	2,95e-15 ***
S4	42,85194	4,90937	8,729	1,27e-15 ***
S5	45,36174	4,93762	9,187	< 2e-16 ***
S6	60,08599	5,03444	11,935	< 2e-16 ***
S7	50,15211	5,10337	9,827	< 2e-16 ***
S8	43,02645	5,07448	8,479	6,11e-15 ***
S9	35,96310	5,08824	7,068	2,87e-11 ***
S10	29,91951	5,13888	5,822	2,42e-08 ***
S11	30,73567	5,14791	5,971	1,13e-08 ***
S12	35,09163	5,04766	6,952	5,55e-11 ***
CV1t-1	61,76870	9,55988	6,461	8,42e-10 ***
CV2t-1	33,94926	9,58355	3,542	0,000498 ***
CV3t-1	28,69254	9,53992	3,008	0,002987 **
CV4t-1	15,26483	7,81881	1,952	0,052362 .
CV1t	-7,24606	9,55989	-0,758	0,449406
CV2t	12,58435	8,56222	1,470	0,143274
CV3t	51,76029	9,53228	5,430	1,70e-07 ***
CV4t	80,52961	7,82693	10,289	< 2e-16 ***

**Lampiran 2.** Estimasi Parameter Model Regresi *Time Series* (lanjutan)

cc. *Outflow Rp20.000 KPw BI Bandung*

	Estimate	Std. Error	t value	Pr(> t )
t	-0,09610	0,04425	-2,172	0,031099 *
D1	-90,54119	41,67601	-2,173	0,031049 *
D2	-113,02454	59,66859	-1,894	0,059709 .
tD1	0,36502	0,38099	0,958	0,339235
tD2	0,56717	0,38105	1,488	0,138285
xV21	65,21475	9,63749	6,767	1,57e-10 ***
xV22	65,24363	9,57802	6,812	1,22e-10 ***
xV23	74,15104	9,58221	7,738	5,68e-13 ***
xV24	72,66020	9,58795	7,578	1,47e-12 ***
xV25	80,27017	9,64313	8,324	1,60e-14 ***
xV26	106,15262	9,83221	10,796	< 2e-16 ***
xV27	82,39288	9,96682	8,267	2,28e-14 ***
xV28	62,57489	9,91040	6,314	1,86e-09 ***
xV29	51,02157	9,93728	5,134	6,94e-07 ***
xV30	42,94128	10,03618	4,279	2,97e-05 ***
xV31	50,40019	10,05382	5,013	1,22e-06 ***
xV32	69,78717	9,85803	7,079	2,69e-11 ***
xV33	122,16707	18,67034	6,543	5,39e-10 ***
xV34	71,52833	18,71657	3,822	0,000179 ***
xV35	64,20612	18,63136	3,446	0,000699 ***
xV36	39,00540	15,27006	2,554	0,011418 *
xV37	-15,24131	18,67036	-0,816	0,415324
xV38	26,67859	16,72193	1,595	0,112270
xV39	84,75646	18,61644	4,553	9,41e-06 ***
xV40	160,66185	15,28591	10,510	< 2e-16 ***

dd. *Outflow Rp20.000 KPw BI Jakarta*

	Estimate	Std. Error	t value	Pr(> t )
t	-0,7384	0,2223	-3,322	0,00107 **
D1	-198,3224	209,3311	-0,947	0,34463
D2	-263,5294	299,7046	-0,879	0,38035
tD1	0,5737	1,9136	0,300	0,76465
tD2	1,2752	1,9139	0,666	0,50605
S1	365,7583	48,4074	7,556	1,68e-12 ***
S2	320,2508	48,1087	6,657	2,89e-10 ***
S3	350,3324	48,1297	7,279	8,52e-12 ***
S4	356,8886	48,1585	7,411	3,95e-12 ***
S5	521,9265	48,4357	10,776	< 2e-16 ***
S6	418,4550	49,3854	8,473	6,34e-15 ***
S7	431,1692	50,0616	8,613	2,64e-15 ***
S8	341,7190	49,7782	6,865	9,07e-11 ***
S9	268,9949	49,9132	5,389	2,07e-07 ***
S10	262,7290	50,4099	5,212	4,83e-07 ***
S11	216,1605	50,4986	4,281	2,95e-05 ***
S12	367,1849	49,5151	7,416	3,84e-12 ***
CV1t-1	707,3466	93,7778	7,543	1,82e-12 ***
CV2t-1	527,9585	94,0100	5,616	6,82e-08 ***
CV3t-1	442,2101	93,5820	4,725	4,44e-06 ***
CV4t-1	440,6536	76,6988	5,745	3,57e-08 ***
CV1t	-121,0733	93,7779	-1,291	0,19824
CV2t	27,1035	83,9913	0,323	0,74728
CV3t	238,8703	93,5070	2,555	0,01141 *
CV4t	394,0491	76,7784	5,132	7,01e-07 ***

### Lampiran 3. Estimasi Parameter dan Uji Asumsi Model ARIMAX

- *Inflow* Pecahan Rp100.000

#### a. Estimasi parameter

```
coeftest(modelARIMA11)-KPw BI Surabaya
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar6  0,178705  0,062021 2,8813 0,0039598 **
ar12 0,379481  0,069133 5,4892 4,038e-08 ***
ar35 0,260004  0,075055 3,4642 0,0005319 ***

coeftest(modelARIMA21)-KPw BI Semarang
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar1 -0,159545  0,052023 -3,0668 0,002164 **
ar6  0,136970  0,055222 2,4803 0,013126 *
ar12 0,454650  0,063081 7,2074 5,703e-13 ***
ar35 0,291509  0,066783 4,3650 1,271e-05 ***

coeftest(modelARIMA31)-KPw BI Yogyakarta
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar11 -0,175623  0,074556 -2,3556 0,01849 *
| 

coeftest(modelARIMA41)-KPW BI Bandung
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar6  0,120369  0,057612 2,0893 0,0366790 *
ar12 0,457595  0,060267 7,5928 3,131e-14 ***
ar23 0,227568  0,062963 3,6143 0,0003012 ***
ar31 -0,143707  0,064537 -2,2268 0,0259637 *

coeftest(modelARIMA51)-KPw BI Jakarta
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar1 -0,123750  0,055732 -2,2204 0,026389 *
ar12 0,390207  0,061790 6,3150 2,701e-10 ***
ar23 0,195744  0,067268 2,9099 0,003615 **
ar35 0,212949  0,071754 2,9678 0,003000 **
```

#### c. Uji Asumsi Normalitas

```
One-sample Kolmogorov-Smirnov test
data: resiARIMAX11
D = 0,087856, p-value = 0,07126
alternative hypothesis: two-sided

One-sample Kolmogorov-Smirnov test
data: resiARIMAX21
D = 0,10115, p-value = 0,02408
alternative hypothesis: two-sided

One-sample Kolmogorov-Smirnov test
data: resiARIMAX31
D = 0,098037, p-value = 0,03146
alternative hypothesis: two-sided
```

#### b. Uji Asumsi *White Noise*

LB.ARIMAX11	statistics	p.value
6	18,46285	0,005173852
12	26,51330	0,009074026
18	28,14596	0,059868463
24	32,58148	0,113216706
30	41,86779	0,073459519

LB.ARIMAX21	statistics	p.value
6	2,507748	0,8675996
12	5,129894	0,9534990
18	6,738712	0,9921509
24	10,295585	0,9932163
30	16,734613	0,9756229

LB.ARIMAX31	statistics	p.value
6	13,66197	3,364866e-02
12	60,35458	1,945044e-08
18	76,96980	2,889193e-09
24	89,63783	1,654793e-09
30	98,52349	3,171806e-09

LB.ARIMAX41	statistics	p.value
6	4,508643	0,6081866
12	10,431074	0,5781982
18	15,195371	0,6485114
24	17,712916	0,8167087
30	19,701998	0,9240705

LB.ARIMAX51	statistics	p.value
6	8,545651	0,2007884
12	15,644677	0,2080578
18	19,401784	0,3674841
24	22,706022	0,5372032
30	24,998632	0,7250984

One-sample Kolmogorov-Smirnov test
data: resiARIMAX41
D = 0,088549, p-value = 0,0676
alternative hypothesis: two-sided

One-sample Kolmogorov-Smirnov test
data: resiARIMAX51
D = 0,061765, p-value = 0,3821
alternative hypothesis: two-sided

### Lampiran 3. Estimasi Parameter dan Uji Asumsi Model ARIMAX (lanjutan)

- *Inflow* Pecahan Rp50.000

a. Estimasi Parameter

b. Uji Asumsi *White Noise*

<pre> coeftest(modelARIMA12)-KPw BI Surabaya z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar2  0,150227  0,063719 2,3576 0,018392 * ar3  0,262426  0,065515 4,0056 6,186e-05 *** ar12 0,280426  0,068630 4,0861 4,387e-05 *** ar15 -0,193615  0,072614 -2,6663 0,007668 **  coeftest(modelARIMA22)-KPw BI Semarang z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1  -0,124516  0,060742 -2,0499 0,0403717 * ar12  0,371803  0,064649 5,7511 8,864e-09 *** ar23  0,242349  0,068494 3,5383 0,0004028 ***  coeftest(modelARIMA32)-KPw BI Yogyakarta z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1  0,148618  0,064283 2,3119 0,0207814 * ar2  0,231740  0,064632 3,5855 0,0003364 *** ar12 0,218655  0,067566 3,2361 0,0012116 **  coeftest(modelARIMA42)-KPw BI Bandung z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar15 -0,213305  0,069938 -3,0499 0,002289 ** ar23  0,178404  0,069899 2,5523 0,010701 * ar24 -0,152211  0,070957 -2,1451 0,031942 *  coeftest(modelARIMA52)-KPw BI Jakarta z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1  0,148746  0,060281 2,4676 0,0136038 * ar2  0,214490  0,059087 3,6301 0,0002833 *** ar3  0,245056  0,064807 3,7813 0,0001560 *** ar12 0,418996  0,064959 6,4501 1,118e-10 *** ar15 -0,283718  0,066335 -4,2771 1,894e-05 *** ar23  0,155446  0,061453 2,5295 0,0114223 * ar24 -0,184596  0,067576 -2,7317 0,0063015 ** </pre>	<table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX12</th> </tr> <tr> <th></th> <th>statistics</th> <th>p.value</th> </tr> </thead> <tbody> <tr> <td>6</td> <td>7,65639</td> <td>0,2643731</td> </tr> <tr> <td>12</td> <td>10,91974</td> <td>0,5358090</td> </tr> <tr> <td>18</td> <td>13,70608</td> <td>0,7480406</td> </tr> <tr> <td>24</td> <td>18,05374</td> <td>0,8003937</td> </tr> <tr> <td>30</td> <td>29,44150</td> <td>0,4945033</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX22</th> </tr> <tr> <th></th> <th>statistics</th> <th>p.value</th> </tr> </thead> <tbody> <tr> <td>6</td> <td>1,723083</td> <td>0,9433254</td> </tr> <tr> <td>12</td> <td>3,623583</td> <td>0,9893118</td> </tr> <tr> <td>18</td> <td>5,519043</td> <td>0,9977893</td> </tr> <tr> <td>24</td> <td>8,390812</td> <td>0,9986385</td> </tr> <tr> <td>30</td> <td>16,082241</td> <td>0,9820363</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX32</th> </tr> <tr> <th></th> <th>statistics</th> <th>p.value</th> </tr> </thead> <tbody> <tr> <td>6</td> <td>5,302375</td> <td>0,5056565</td> </tr> <tr> <td>12</td> <td>9,653464</td> <td>0,6463326</td> </tr> <tr> <td>18</td> <td>13,308900</td> <td>0,7729051</td> </tr> <tr> <td>24</td> <td>19,224260</td> <td>0,7399262</td> </tr> <tr> <td>30</td> <td>23,012312</td> <td>0,8147534</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX42</th> </tr> <tr> <th></th> <th>statistics</th> <th>p.value</th> </tr> </thead> <tbody> <tr> <td>6</td> <td>6,068073</td> <td>0,4156079</td> </tr> <tr> <td>12</td> <td>10,177555</td> <td>0,6003871</td> </tr> <tr> <td>18</td> <td>16,234096</td> <td>0,5762137</td> </tr> <tr> <td>24</td> <td>19,889709</td> <td>0,7030306</td> </tr> <tr> <td>30</td> <td>26,752365</td> <td>0,6362426</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX52</th> </tr> <tr> <th></th> <th>statistics</th> <th>p.value</th> </tr> </thead> <tbody> <tr> <td>6</td> <td>2,864047</td> <td>0,8257068</td> </tr> <tr> <td>12</td> <td>7,571375</td> <td>0,8176656</td> </tr> <tr> <td>18</td> <td>11,226401</td> <td>0,8845033</td> </tr> <tr> <td>24</td> <td>13,807300</td> <td>0,9508835</td> </tr> <tr> <td>30</td> <td>21,030460</td> <td>0,8869330</td> </tr> </tbody> </table>	LB.ARIMAX12				statistics	p.value	6	7,65639	0,2643731	12	10,91974	0,5358090	18	13,70608	0,7480406	24	18,05374	0,8003937	30	29,44150	0,4945033	LB.ARIMAX22				statistics	p.value	6	1,723083	0,9433254	12	3,623583	0,9893118	18	5,519043	0,9977893	24	8,390812	0,9986385	30	16,082241	0,9820363	LB.ARIMAX32				statistics	p.value	6	5,302375	0,5056565	12	9,653464	0,6463326	18	13,308900	0,7729051	24	19,224260	0,7399262	30	23,012312	0,8147534	LB.ARIMAX42				statistics	p.value	6	6,068073	0,4156079	12	10,177555	0,6003871	18	16,234096	0,5762137	24	19,889709	0,7030306	30	26,752365	0,6362426	LB.ARIMAX52				statistics	p.value	6	2,864047	0,8257068	12	7,571375	0,8176656	18	11,226401	0,8845033	24	13,807300	0,9508835	30	21,030460	0,8869330
LB.ARIMAX12																																																																																																										
	statistics	p.value																																																																																																								
6	7,65639	0,2643731																																																																																																								
12	10,91974	0,5358090																																																																																																								
18	13,70608	0,7480406																																																																																																								
24	18,05374	0,8003937																																																																																																								
30	29,44150	0,4945033																																																																																																								
LB.ARIMAX22																																																																																																										
	statistics	p.value																																																																																																								
6	1,723083	0,9433254																																																																																																								
12	3,623583	0,9893118																																																																																																								
18	5,519043	0,9977893																																																																																																								
24	8,390812	0,9986385																																																																																																								
30	16,082241	0,9820363																																																																																																								
LB.ARIMAX32																																																																																																										
	statistics	p.value																																																																																																								
6	5,302375	0,5056565																																																																																																								
12	9,653464	0,6463326																																																																																																								
18	13,308900	0,7729051																																																																																																								
24	19,224260	0,7399262																																																																																																								
30	23,012312	0,8147534																																																																																																								
LB.ARIMAX42																																																																																																										
	statistics	p.value																																																																																																								
6	6,068073	0,4156079																																																																																																								
12	10,177555	0,6003871																																																																																																								
18	16,234096	0,5762137																																																																																																								
24	19,889709	0,7030306																																																																																																								
30	26,752365	0,6362426																																																																																																								
LB.ARIMAX52																																																																																																										
	statistics	p.value																																																																																																								
6	2,864047	0,8257068																																																																																																								
12	7,571375	0,8176656																																																																																																								
18	11,226401	0,8845033																																																																																																								
24	13,807300	0,9508835																																																																																																								
30	21,030460	0,8869330																																																																																																								
<p>c. Uji Asumsi Normalitas</p> <pre> One-sample Kolmogorov-Smirnov test data: resiARIMAX12 D = 0,083169, p-value = 0,1007 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX22 D = 0,077472, p-value = 0,1496 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX32 D = 0,069111, p-value = 0,2535 alternative hypothesis: two-sided </pre>	<pre> One-sample Kolmogorov-Smirnov test data: resiARIMAX42 D = 0,076258, p-value = 0,1621 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX52 D = 0,086632, p-value = 0,07815 alternative hypothesis: two-sided </pre>																																																																																																									

### Lampiran 3. Estimasi Parameter dan Uji Asumsi Model ARIMAX (lanjutan)

- *Inflow* Pecahan Rp20.000

a. Estimasi Parameter

b. Uji Asumsi *White Noise*

<pre> coefstest(modelARIMA13)-KPw BI Surabaya z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1  0,516933  0,053880  9,5941 &lt; 2,2e-16 *** ar11 0,251934  0,065098  3,8701 0,0001088 *** ar23 0,257198  0,071260  3,6093 0,0003070 *** ar24 -0,212532 0,073646 -2,8859 0,0039035 ** ar36 -0,181061 0,064339 -2,8142 0,0048902 **  coefstest(modelARIMA23)-KPw BI Semarang z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1  0,459016  0,059321  7,7378 1,011e-14 *** ar2  0,148014  0,059602  2,4834 0,01301 * ar11 0,400381  0,059107  6,7739 1,254e-11 *** ar36 -0,194533 0,043086 -4,5150 6,331e-06 ***  coefstest(modelARIMA33)-KPw BI Yogyakarta z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1  0,320637  0,068805  4,6601 3,161e-06 *** ar2  0,259230  0,070229  3,6912 0,0002232 *** ar3  0,144685  0,068051  2,1261 0,0334937 * ar12 0,332219  0,072058  4,6104 4,018e-06 *** ar13 -0,236057 0,075945 -3,1083 0,0018820 **  coefstest(modelARIMA43)-KPw BI Bandung z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1 0,613246  0,064363  9,5279 &lt; 2,2e-16 *** ar3 0,275194  0,065323  4,2128 2,522e-05 ***  coefstest(modelARIMA53)-KPw BI Jakarta z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1 0,505301  0,068987  7,3245 2,397e-13 *** ar3 0,241333  0,069957  3,4497 0,0005612 *** </pre>	<table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX13</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr> <td>6</td> <td>5,904325</td> <td>0,4339927</td> </tr> <tr> <td>12</td> <td>11,496567</td> <td>0,4869088</td> </tr> <tr> <td>18</td> <td>14,948479</td> <td>0,6655016</td> </tr> <tr> <td>24</td> <td>21,202730</td> <td>0,6267386</td> </tr> <tr> <td>30</td> <td>26,326906</td> <td>0,6583459</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX23</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr> <td>6</td> <td>8,172489</td> <td>0,22573676</td> </tr> <tr> <td>12</td> <td>13,445656</td> <td>0,33749715</td> </tr> <tr> <td>18</td> <td>20,745177</td> <td>0,29246356</td> </tr> <tr> <td>24</td> <td>33,978909</td> <td>0,08504461</td> </tr> <tr> <td>30</td> <td>42,346579</td> <td>0,06682366</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX33</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr> <td>6</td> <td>4,738410</td> <td>0,5777748</td> </tr> <tr> <td>12</td> <td>5,306052</td> <td>0,9469677</td> </tr> <tr> <td>18</td> <td>8,249661</td> <td>0,9746836</td> </tr> <tr> <td>24</td> <td>12,826738</td> <td>0,9688909</td> </tr> <tr> <td>30</td> <td>13,783463</td> <td>0,9950104</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX43</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr> <td>6</td> <td>19,81167</td> <td>0,0029914028</td> </tr> <tr> <td>12</td> <td>35,39225</td> <td>0,0004054625</td> </tr> <tr> <td>18</td> <td>38,11648</td> <td>0,0037381927</td> </tr> <tr> <td>24</td> <td>49,16111</td> <td>0,0018079521</td> </tr> <tr> <td>30</td> <td>51,16319</td> <td>0,0093603396</td> </tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX53</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr> <td>6</td> <td>10,03565</td> <td>0,1231585</td> </tr> <tr> <td>12</td> <td>16,40396</td> <td>0,1734264</td> </tr> <tr> <td>18</td> <td>18,37261</td> <td>0,4313720</td> </tr> <tr> <td>24</td> <td>23,68363</td> <td>0,4798028</td> </tr> <tr> <td>30</td> <td>25,82056</td> <td>0,6842583</td> </tr> </tbody> </table>	LB.ARIMAX13			statistics	p.value		6	5,904325	0,4339927	12	11,496567	0,4869088	18	14,948479	0,6655016	24	21,202730	0,6267386	30	26,326906	0,6583459	LB.ARIMAX23			statistics	p.value		6	8,172489	0,22573676	12	13,445656	0,33749715	18	20,745177	0,29246356	24	33,978909	0,08504461	30	42,346579	0,06682366	LB.ARIMAX33			statistics	p.value		6	4,738410	0,5777748	12	5,306052	0,9469677	18	8,249661	0,9746836	24	12,826738	0,9688909	30	13,783463	0,9950104	LB.ARIMAX43			statistics	p.value		6	19,81167	0,0029914028	12	35,39225	0,0004054625	18	38,11648	0,0037381927	24	49,16111	0,0018079521	30	51,16319	0,0093603396	LB.ARIMAX53			statistics	p.value		6	10,03565	0,1231585	12	16,40396	0,1734264	18	18,37261	0,4313720	24	23,68363	0,4798028	30	25,82056	0,6842583
LB.ARIMAX13																																																																																																										
statistics	p.value																																																																																																									
6	5,904325	0,4339927																																																																																																								
12	11,496567	0,4869088																																																																																																								
18	14,948479	0,6655016																																																																																																								
24	21,202730	0,6267386																																																																																																								
30	26,326906	0,6583459																																																																																																								
LB.ARIMAX23																																																																																																										
statistics	p.value																																																																																																									
6	8,172489	0,22573676																																																																																																								
12	13,445656	0,33749715																																																																																																								
18	20,745177	0,29246356																																																																																																								
24	33,978909	0,08504461																																																																																																								
30	42,346579	0,06682366																																																																																																								
LB.ARIMAX33																																																																																																										
statistics	p.value																																																																																																									
6	4,738410	0,5777748																																																																																																								
12	5,306052	0,9469677																																																																																																								
18	8,249661	0,9746836																																																																																																								
24	12,826738	0,9688909																																																																																																								
30	13,783463	0,9950104																																																																																																								
LB.ARIMAX43																																																																																																										
statistics	p.value																																																																																																									
6	19,81167	0,0029914028																																																																																																								
12	35,39225	0,0004054625																																																																																																								
18	38,11648	0,0037381927																																																																																																								
24	49,16111	0,0018079521																																																																																																								
30	51,16319	0,0093603396																																																																																																								
LB.ARIMAX53																																																																																																										
statistics	p.value																																																																																																									
6	10,03565	0,1231585																																																																																																								
12	16,40396	0,1734264																																																																																																								
18	18,37261	0,4313720																																																																																																								
24	23,68363	0,4798028																																																																																																								
30	25,82056	0,6842583																																																																																																								
<p>c. Uji Asumsi Normalitas</p> <pre> One-sample Kolmogorov-Smirnov test data: resiARIMAX13 D = 0,092581, p-value = 0,04931 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX23 D = 0,07247, p-value = 0,2066 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX33 D = 0,14005, p-value = 0,000418 alternative hypothesis: two-sided </pre>	<pre> One-sample Kolmogorov-Smirnov test data: resiARIMAX43 D = 0,10351, p-value = 0,01954 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX53 D = 0,11438, p-value = 0,007026 alternative hypothesis: two-sided </pre>																																																																																																									

### Lampiran 3. Estimasi Parameter dan Uji Asumsi Model ARIMAX (lanjutan)

- *Outflow Pecahan Rp100.000*

a. Estimasi Parameter

b. Uji Asumsi *White Noise*

<pre> coefest(modelARIMA11)-KPw BI Surabaya z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar6   0,137311  0,055666 2,4667 0,0136367 * ar10  -0,123097  0,062064 -1,9834 0,0473223 * ar12   0,388904  0,062266 6,2458 4,216e-10 *** ar13  -0,232159  0,061834 -3,7545 0,0001737 *** ar15  -0,157535  0,059907 -2,6296 0,0085473 ** ar23   0,227764  0,065592 3,4724 0,0005158 *** ... Signif. codes:  0 '***' 0,001 '**' 0,01 '*' 0,05 '.'  coefest(modelARIMA21)-KPw Bi Semarang z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1  -0,177323  0,056466 -3,1403 0,001688 ** ar5   0,034902  0,055501  0,6289 0,529447 ar12   0,548003  0,066455  8,2463 &lt; 2,2e-16 *** ar23   0,277369  0,069390 3,9972 6,409e-05 *** ... Signif. codes:  0 '***' 0,001 '**' 0,01 '*' 0,05 '.'  coefest(modelARIMA31)-KPw BI Yogyakarta z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1  -0,1863492  0,0526059 -3,5424 0,0003966 *** ar4  -0,0085626  0,0588525 -0,1455 0,8843216 ar8  -0,1075181  0,0571052 -1,8828 0,0597264 . ar12   0,3705534  0,0573488  6,4614 1,037e-10 *** ar15  -0,1582757  0,0561047 -2,8211 0,0047862 ** ar16  -0,2518942  0,0650386 -3,8730 0,0001075 *** ar17  -0,0994209  0,0580775 -1,7119 0,0869213 . ar22  -0,1127901  0,0560478 -2,0124 0,0441788 * ar23   0,3488952  0,0604563  5,7710 7,879e-09 *** ... Signif. codes:  0 '***' 0,001 '**' 0,01 '*' 0,05 '.'  coefest(modelARIMA41)-KPw BI Bandung z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar1  -0,303874  0,052129 -5,8293 5,566e-09 *** ar2  -0,117733  0,056615 -2,0795 0,0375682 * ar4  -0,076934  0,052392 -1,4684 0,1419855 ar6   0,096725  0,051170  1,8903 0,0587207 . ar10  -0,145437  0,056543 -2,5722 0,0101069 * ar12   0,524148  0,057479  9,1189 &lt; 2,2e-16 *** ar15  -0,193748  0,057681 -3,3590 0,0007823 *** ... Signif. codes:  0 '***' 0,001 '**' 0,01 '*' 0,05 '.'  coefest(modelARIMA51)-KPw BI Jakarta z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar5   0,194986  0,057859  3,3700 0,0007516 *** ar6   0,101606  0,055486  1,8312 0,0670686 . ar10  -0,151757  0,062651 -2,4223 0,0154238 * ar12   0,282413  0,060454  4,6716 2,989e-06 *** ar22  -0,198676  0,066758 -2,9761 0,0029198 ** ar23   0,280577  0,061831  4,5378 5,684e-06 *** ... Signif. codes:  0 '***' 0,001 '**' 0,01 '*' 0,05 '.'  One-sample Kolmogorov-Smirnov test data: resiARIMAX41 D = 0,10005, p-value = 0,02649 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX51 D = 0,052293, p-value = 0,596 alternative hypothesis: two-sided </pre>	<pre> LB.ARIMAX11 statistics p.value 6   10,42906 0,10770787 12  16,34329 0,17601387 18  22,02099 0,23105471 24  31,70233 0,13454755 30  40,39616 0,09741661  LB.ARIMAX21 statistics p.value 6   11,40726 0,07657617 12  15,49060 0,21569632 18  17,92219 0,46078931 24  29,60656 0,19813551 30  45,06551 0,03806336  LB.ARIMAX31 statistics p.value 6   3,159733 0,7885482 12  4,837310 0,9631932 18  16,441755 0,5617467 24  17,368719 0,8325160 30  23,388199 0,7989705  LB.ARIMAX41 statistics p.value 6   1,119169 0,9806889 12  6,612309 0,8821353 18  9,050225 0,9585679 24  27,853008 0,2662887 30  31,890878 0,3726197  LB.ARIMAX51 statistics p.value 6   6,924987 0,3278401 12  9,505557 0,6592495 18  13,837202 0,7396405 24  15,883658 0,8922295 30  24,426272 0,7524059 </pre>
<pre> One-sample Kolmogorov-Smirnov test data: resiARIMAX41 D = 0,10005, p-value = 0,02649 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX51 D = 0,052293, p-value = 0,596 alternative hypothesis: two-sided </pre>	<pre> c. Uji Asumsi Normalitas  One-sample Kolmogorov-Smirnov test data: resiARIMAX11 D = 0,078202, p-value = 0,1424 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX21 D = 0,12139, p-value = 0,003438 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX31 D = 0,086085, p-value = 0,08141 alternative hypothesis: two-sided </pre>

### Lampiran 3. Estimasi Parameter dan Uji Asumsi Model ARIMAX (lanjutan)

- *Outflow* Pecahan Rp50.000

a. Estimasi Parameter

b. Uji Asumsi *White Noise*

<pre> coefest(modelARIMA12)-KPw BI Surabaya z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar2   0,141234  0,060549 2,3326 0,019671 * ar3   0,175315  0,059571 2,9430 0,003251 ** ar12  0,189380  0,068984 2,7453 0,006046 *** ar22 -0,320702  0,066045 -4,8558 1,199e-06 *** ar23  0,265173  0,066675 3,9771 6,977e-05 *** ... Signif, codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'  coefest(modelARIMA22)-KPw BI Semarang z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ari0 -0,029937  0,065820 -0,4548 0,6492383 ari2  0,215568  0,064882 3,3225 0,0008923 *** ari3 -0,178111  0,064359 -2,7675 0,0056491 ** ari4 -0,099836  0,062892 -1,5874 0,1124168 ar22 -0,212349  0,066098 -3,2126 0,0013153 *** ar23  0,351027  0,065849 5,3308 9,78e-08 *** ... Signif, codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'  coefest(modelARIMA32)-KPw BI Yogyakarta z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ari1 -0,142079  0,057384 -2,4760 0,0132878 * ari2  0,399316  0,063327 6,3056 2,87e-10 *** ari5 -0,089578  0,062453 -1,4343 0,1514816 ar22 -0,185433  0,064319 -2,8830 0,0039386 ** ar23  0,254599  0,066415 3,8334 0,0001264 *** ... Signif, codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'  coefest(modelARIMA42)-KPw BI Bandung z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ari1 -0,149457  0,058539 -2,5531 0,0106770 * ari0 -0,035136  0,063561 -0,5528 0,5804035 ari2  0,408803  0,061170 6,6831 2,340e-11 *** ari4 -0,086750  0,059348 -1,4617 0,1438204 ari5 -0,159897  0,056672 -2,8214 0,0047811 ** ar22 -0,224554  0,065980 -3,4034 0,0006656 *** ar23  0,271478  0,066669 4,0720 4,661e-05 *** ... Signif, codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'  coefest(modelARIMA52)-KPw BI Jakarta z test of coefficients:        Estimate Std. Error z value Pr(&gt; z ) ar2   0,240917  0,061842 3,8957 9,792e-05 *** ar3   0,158815  0,061104 2,5991 0,009347 ** ar5   0,109707  0,062874 1,7449 0,081007 . ari2  0,190985  0,066331 2,8793 0,003986 ** ar23  0,259239  0,066320 3,9089 9,270e-05 *** ar25 -0,277788  0,068859 -4,0342 5,480e-05 *** ... Signif, codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'  </pre>	<table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX12</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr><td>6</td><td>3,089308</td><td>0,7975571</td></tr> <tr><td>12</td><td>5,036352</td><td>0,9567538</td></tr> <tr><td>18</td><td>9,730440</td><td>0,9403501</td></tr> <tr><td>24</td><td>13,169796</td><td>0,9632393</td></tr> <tr><td>30</td><td>19,702119</td><td>0,9240675</td></tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX22</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr><td>6</td><td>12,02538</td><td>0,06140499</td></tr> <tr><td>12</td><td>15,66207</td><td>0,20720874</td></tr> <tr><td>18</td><td>19,35935</td><td>0,37001603</td></tr> <tr><td>24</td><td>20,36293</td><td>0,67596091</td></tr> <tr><td>30</td><td>31,68409</td><td>0,38236246</td></tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX32</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr><td>6</td><td>4,623890</td><td>0,5928737</td></tr> <tr><td>12</td><td>7,427131</td><td>0,8281456</td></tr> <tr><td>18</td><td>12,111143</td><td>0,8414465</td></tr> <tr><td>24</td><td>17,417036</td><td>0,8303390</td></tr> <tr><td>30</td><td>22,866936</td><td>0,8206903</td></tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX42</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr><td>6</td><td>8,391626</td><td>0,2107924</td></tr> <tr><td>12</td><td>10,149789</td><td>0,6028215</td></tr> <tr><td>18</td><td>19,066607</td><td>0,3877326</td></tr> <tr><td>24</td><td>29,790861</td><td>0,1917804</td></tr> <tr><td>30</td><td>38,277137</td><td>0,1427630</td></tr> </tbody> </table> <table border="1"> <thead> <tr> <th colspan="3">LB.ARIMAX52</th> </tr> <tr> <th>statistics</th> <th>p.value</th> <th></th> </tr> </thead> <tbody> <tr><td>6</td><td>1,818065</td><td>0,9356476</td></tr> <tr><td>12</td><td>4,433250</td><td>0,9742907</td></tr> <tr><td>18</td><td>6,258713</td><td>0,9950305</td></tr> <tr><td>24</td><td>10,101545</td><td>0,9941155</td></tr> <tr><td>30</td><td>13,551037</td><td>0,9957059</td></tr> </tbody> </table>	LB.ARIMAX12			statistics	p.value		6	3,089308	0,7975571	12	5,036352	0,9567538	18	9,730440	0,9403501	24	13,169796	0,9632393	30	19,702119	0,9240675	LB.ARIMAX22			statistics	p.value		6	12,02538	0,06140499	12	15,66207	0,20720874	18	19,35935	0,37001603	24	20,36293	0,67596091	30	31,68409	0,38236246	LB.ARIMAX32			statistics	p.value		6	4,623890	0,5928737	12	7,427131	0,8281456	18	12,111143	0,8414465	24	17,417036	0,8303390	30	22,866936	0,8206903	LB.ARIMAX42			statistics	p.value		6	8,391626	0,2107924	12	10,149789	0,6028215	18	19,066607	0,3877326	24	29,790861	0,1917804	30	38,277137	0,1427630	LB.ARIMAX52			statistics	p.value		6	1,818065	0,9356476	12	4,433250	0,9742907	18	6,258713	0,9950305	24	10,101545	0,9941155	30	13,551037	0,9957059
LB.ARIMAX12																																																																																																										
statistics	p.value																																																																																																									
6	3,089308	0,7975571																																																																																																								
12	5,036352	0,9567538																																																																																																								
18	9,730440	0,9403501																																																																																																								
24	13,169796	0,9632393																																																																																																								
30	19,702119	0,9240675																																																																																																								
LB.ARIMAX22																																																																																																										
statistics	p.value																																																																																																									
6	12,02538	0,06140499																																																																																																								
12	15,66207	0,20720874																																																																																																								
18	19,35935	0,37001603																																																																																																								
24	20,36293	0,67596091																																																																																																								
30	31,68409	0,38236246																																																																																																								
LB.ARIMAX32																																																																																																										
statistics	p.value																																																																																																									
6	4,623890	0,5928737																																																																																																								
12	7,427131	0,8281456																																																																																																								
18	12,111143	0,8414465																																																																																																								
24	17,417036	0,8303390																																																																																																								
30	22,866936	0,8206903																																																																																																								
LB.ARIMAX42																																																																																																										
statistics	p.value																																																																																																									
6	8,391626	0,2107924																																																																																																								
12	10,149789	0,6028215																																																																																																								
18	19,066607	0,3877326																																																																																																								
24	29,790861	0,1917804																																																																																																								
30	38,277137	0,1427630																																																																																																								
LB.ARIMAX52																																																																																																										
statistics	p.value																																																																																																									
6	1,818065	0,9356476																																																																																																								
12	4,433250	0,9742907																																																																																																								
18	6,258713	0,9950305																																																																																																								
24	10,101545	0,9941155																																																																																																								
30	13,551037	0,9957059																																																																																																								
<pre> One-sample Kolmogorov-Smirnov test data: resiARIMAX42 D = 0,050037, p-value = 0,6518 alternative hypothesis: two-sided  One-sample Kolmogorov-Smirnov test data: resiARIMAX52 D = 0,082885, p-value = 0,1028 alternative hypothesis: two-sided </pre>	<p>c. Uji Asumsi Normalitas</p> <p>One-sample Kolmogorov-Smirnov test</p> <p>data: resiARIMAX12</p> <p>D = 0,064264, p-value = 0,3343</p> <p>alternative hypothesis: two-sided</p> <p>One-sample Kolmogorov-Smirnov test</p> <p>data: resiARIMAX22</p> <p>D = 0,061476, p-value = 0,3879</p> <p>alternative hypothesis: two-sided</p> <p>One-sample Kolmogorov-Smirnov test</p> <p>data: resiARIMAX32</p> <p>D = 0,051701, p-value = 0,6106</p> <p>alternative hypothesis: two-sided</p>																																																																																																									

### Lampiran 3. Estimasi Parameter dan Uji Asumsi Model ARIMAX (lanjutan)

- *Outflow* Pecahan Rp20.000

a. Estimasi Parameter

```
coeftest(modelARIMA13)-KPw BI Surabaya
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar2 -0,051530  0,055112 -0,9350  0,349786
ar10 -0,160804  0,059619 -2,6972  0,006993 **
ar12  0,571402  0,061981  9,2190 < 2,2e-16 ***
ar13 -0,156117  0,060487 -2,5810  0,009852 **
---
Signif. codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'

coeftest(modelARIMA23)-KPw BI Semarang
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar1  0,346111  0,059795  5,7882 7,112e-09 ***
ar3  0,047812  0,045142  1,0591  0,289539
ar4  0,066381  0,048971  1,3555  0,175251
ar6  0,083095  0,049558  1,6767  0,093594 .
ar11 0,051345  0,058390  0,8793  0,379215
ar12 0,538089  0,065243  8,2474 < 2,2e-16 ***
ar13 -0,161870  0,057698 -2,8055  0,005024 **
ar23 0,354140  0,065894  5,3744  7,683e-08 ***
ar24 -0,482089  0,065230 -7,3906 1,461e-13 ***
---
Signif. codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'

coeftest(modelARIMA33)-KPw BI Yogyakarta
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar1  0,436646  0,059312  7,3618 1,814e-13 ***
ar5  0,098859  0,057750  1,7119  0,08692 .
ar12 0,411428  0,077438  5,3130 1,079e-07 ***
ar13 -0,383166  0,079899 -4,7956 1,621e-06 ***
---
Signif. codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'

coeftest(modelARIMA43)-KPw BI Bandung
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar1  0,378176  0,060224  6,2795 3,397e-10 ***
ar2  0,159783  0,054786  2,9165  0,00354 **
ar3  0,028984  0,051935  0,5581  0,57679
ar6  0,103986  0,052901  1,9657  0,04934 *
ar11 0,064568  0,063072  1,0237  0,30597
ar12 0,402302  0,064144  6,2718 3,568e-10 ***
ar13 -0,366121  0,062389 -5,8684 4,400e-09 ***
ar23 0,329874  0,068652  4,8050 1,547e-06 ***
ar24 -0,305765  0,072609 -4,2111 2,541e-05 ***
---
Signif. codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'

coeftest(modelARIMA53)-KPw BI Jakarta
z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar12 0,405265  0,067351  6,0172 1,774e-09 ***
ar23 0,232919  0,076519  3,0439  0,002335 **
---
Signif. codes:  0 '****' 0,001 '**' 0,01 '*' 0,05 '.'
```

b. Uji Asumsi *White Noise*

LB.ARIMAX13	statistics	p.value
6	1,981979	0,9213485
12	7,144115	0,8479446
18	17,453048	0,4921916
24	22,532258	0,5475305
30	24,070633	0,7688194

LB.ARIMAX23	statistics	p.value
6	2,02034	0,9178185
12	10,03050	0,6132850
18	11,38282	0,8774114
24	20,88851	0,6452934
30	21,16092	0,8827885

LB.ARIMAX33	statistics	p.value
6	7,555277	0,2725276
12	11,758522	0,4652628
18	15,033641	0,6596559
24	23,264964	0,5042048
30	26,026905	0,6737575

LB.ARIMAX43	statistics	p.value
6	2,390348	0,8805319
12	4,429825	0,9743739
18	8,701476	0,9662621
24	15,611599	0,9015826
30	18,860282	0,9428849

LB.ARIMAX53	statistics	p.value
6	4,408518	0,6215720
12	6,689316	0,8774436
18	7,155304	0,9887500
24	14,534328	0,9336477
30	18,628977	0,9474377

c. Uji Asumsi Normalitas

One-sample Kolmogorov-Smirnov test  
 data: resiARIMAX13  
 D = 0,13774, p-value = 0,0005512  
 alternative hypothesis: two-sided

One-sample Kolmogorov-Smirnov test  
 data: resiARIMAX23  
 D = 0,086557, p-value = 0,07859  
 alternative hypothesis: two-sided

One-sample Kolmogorov-Smirnov test  
 data: resiARIMAX33  
 D = 0,16102, p-value = 2,733e-05  
 alternative hypothesis: two-sided

One-sample Kolmogorov-Smirnov test  
 data: resiARIMAX43  
 D = 0,071066, p-value = 0,2254  
 alternative hypothesis: two-sided

One-sample Kolmogorov-Smirnov test  
 data: resiARIMAX53  
 D = 0,10419, p-value = 0,01838  
 alternative hypothesis: two-sided

#### Lampiran 4. Plot MCCF dan MPCCF Residual Model TSR

##### a. Pecahan Rp100.000

Schematic Representation of Cross Correlations-inflow100													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Z11	+++++	.....	.....	....	+...+	+++++	+	.....	....	....	....+	.....	+++++
Z21	+++++	.....	.....	....	.....	+++++	.....	.....	.....	.....	.....	.....	+++++
Z31	+++++	....-	.....	....	+...+	+++++	.....	.....	....-	....	....	....	+++++
Z41	+++++	....-	.....	....	.....	+++++	.....	.....	.....	.....	.....	.....	+++++
Z51	+++++	....-	.....	....-	.....	+++++	.....	.....	.....	.....	.....	.....	+++++

Schematic Representation of Cross Correlations-outflow100													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Y11	+++++	....-	...+..	+...+	....	+...+	+++++	.....	.....	+++++	....-	++..	+++++
Y21	+++++	-----	...+..	.....	....-	+...+	+++++	.....	.....	+...+	.....	+++++	+++++
Y31	+++++	.....	.....	+....	....-	.....	+....	.....	.....	+++++	....-	...+..	+++++
Y41	+++++	-----	.....	....-	.....	++..+	.....	.....	.....	....-	+...+	+++++	+++++
Y51	+++++	-----	.....	....-	.....	+...+	++..+	.....	.....	+....	....-	...+..	+++++

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

Schematic Representation of Partial Cross Correlations-inflow100												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
Z11	....-	+....	....-	+...-	.....	.....	....+	.....	....-	....	....	....+
Z21	.....	.+....	....-	....-	.....	.....	.....	.....	.....	....-	....	....+
Z31	...+-	...+..	.....	+....	.....	....-	.....	.....	.....	....-	....	....-
Z41	.-+-	...+-	...+.	.....	+...+	.....	.....	.....	.....	.....	.....	.....
Z51	....-	-....	.....	....-	.....	+...+	.....	.....	.....	.....	....	....+

Schematic Representation of Partial Cross Correlations-outflow100												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
Y11	++...	+...+	+...-	....-	.....	.....	.....	....+	.....	.....	.....	.....
Y21	....-	+...+	.....	....-	.....	....+	.....	.....	....	....	....	....
Y31	...+	.....	.....	....-	.....	....-	....	....+	...+..	....	....	....
Y41	-...+	....-	....-	....	....-	....-	....-	....-	....	....	....	....
Y51	....-	.....	....-	....-	.....	....-	....	....+	.....	....-	....	....++

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

#### Lampiran 4. Plot MCCF dan MPCCF Residual Model TSR (lanjutan)

##### b. Pecahan Rp50.000

Schematic Representation of Cross Correlations-Inflow50													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Z12	+++++	+...-	+.++	++..+	+...-	+.++	+++..	+.+-.	+...-	+.++	+.++	++...	+++..
Z22	+++++	.....	.....	.....	.....	.....	.....	.....	.....	.....	.....	.....	.....
Z32	+++++	.....	+.++	+.++	+.++	+.++	.....	.....	.....	.....	.....	.....	+++..
Z42	+++++	-...-	...+	...+	.....	...+	.....	-...-	.....	.....	.....	.....	.....
Z52	+++++	...+.	+++..	+.++	+.++	+.++	...+.	+.++	+.++	...+.	+.++	+.++	+++++

Schematic Representation of Cross Correlations-outflow50													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Y12	+++++	.....	.....	+	....	.....	++...	+++..	.....	+++..	-...-	++..+	+++++
Y22	+++++	-...-	.....	.....	-...-	.....	++...	.....	.....	-...-	.....	+++++	+++++
Y32	+++++	.....	.....	.....	-...-	.....	++...	.....	.....	-...-	.....	++++.	++++.
Y42	+++++	.....	.....	.....	-...-	.....	++...	.....	.....	-...-	.....	+++++	+++++
Y52	+++++	.....	...+	...+	.....	...+	...+	....+	.....	...+	-...-	....+	+++++

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

Schematic Representation of Partial Cross Correlations-inflow50													
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12	
Z12	+...-	+-..	+.++	...-	....	....	....	....	....	....	....	....	....
Z22	....-	-...-	....-	....	....	....	-..+	-...-	....	....	....	....	....
Z32	-+..	...+..	....	....	-...-	....	....	-...-	....	....	....	....	....
Z42	-.-+	...+.	-.-+	....	-.-+	....	..+..	....	..+..	....	-.-+	....	....
Z52	-...+	...+.	....	....	....	....	....	....	....	-...+	...+..	....	....

Schematic Representation of Partial Cross Correlations-outflow50													
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12	
Y12	+...-	....	+	....	....	....	..+..	-...-	....	-+..	....	....	....
Y22	.+-.	.+..	....	....	....	....	....	-...-	....	...+.	....	...+.	....
Y32	....	...+..	....	....	....	....	....	....	-...-	-+..	....	....	....
Y42	-.-+	....	-...-	....	..+..	....	....	....	....	....	....	...+.	....
Y52	-...+	...+.	-...-	....	....	....	....	....	....	....	....	....	+++..

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

##### c. Pecahan 20.000-MCCF

Schematic Representation of Cross Correlations-Inflow20													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Z13	+++++	+++++	+++++	+++++	+++++	++++	..++.	....	....	.+..+	+..++	+++++	+++++
Z23	+++++	+++++	+++++	+++++	+++++	++++	++++	++++	++++	++..+	++..+	+++++	+++++
Z33	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++
Z43	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++	+++++
Z53	+++++	+++++	+++++	+++++	+++++	+++++	..++.	++++	....	.+..+	+..++	+++++	+++++

Schematic Representation of Cross Correlations-Outflow20													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Y13	+++++	.....	-...-	....	....	....	....	....	-...-	-...-	+++++	+++++	+++++
Y23	+++++	.+..	....	....	...+..	....	..++.	....	....	....	....	+++++	+++++
Y33	+++++	+++.	...++.	....	...+..	....	....	....	....	....	....	+++++	+++++
Y43	+++++	++..	....	...+..	....	..++.	....	....	....	....	....	+++++	+++++
Y53	+++++	++..	-...-	....	....	....	....	....	-...-	-...-	....	....	+++..

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

#### Lampiran 4. Plot MCCF dan MPCCF Residual Model TSR (lanjutan)

##### Pecahan Rp20.000 - MPCCF

Schematic Representation of Partial Cross Correlations-inflow20												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
Z13	.....	.....	.....	-.....	.....	.....	.....	.....	.....	.+-..	.+...	.....
Z23	.+.	.....	.....	.....	.....	.....	-.-	.....	.....	.....	.+..+	....-
Z33	..+.-	++..	.....	.....	.....	.....	.....	.....	.....	.+...+	....	.....
Z43	.+..	.+..	.....	.....	.....	.....	.....	.....	.....	....-	..+..	.....
Z53	....+	.....	.....	.....	.....	.....	.....	....+	.....	.....	+....	....+

Schematic Representation of Partial Cross Correlations-outflow20												
Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
Y13	....-	....-	....-	.....	.....	.....	.....	.....	.....	.....	....+	++..-
Y23	-+..	.....	...+..	.....	.....	.....	-.-	.....	...+..	.....	....+	....+
Y33	..+..	..+..	....-	.....	.....	.....	.....	.....	.....	.....	....+	.....
Y43	-++.	...+..	...+..	.....	.....	.....	.....	.....	.....	.....	....+	.....
Y53	++..	.....	.....	.....	.....	.....	.....	.....	.....	.....	....++	.....

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

##### MCCF Semua Pecahan -Inflow

Schematic Representation of Cross Correlations-Inflow all						
Variable/ Lag	0	1	2	3	4	5
Z11	++..++..++..++..	..+..+..+..+..	.....	.....	.....	.....
Z12	++++++..++..++..	..++..+..+..+..	..++..+..+..+..	..+..+..+..+..	..+..+..+..+..	..+..+..+..+..
Z13	..++..++..++..++..	..+..+..+..+..+..	..+..+..+..+..+..	..+..+..+..+..+..	..+..+..+..+..+..	..+..+..+..+..+..
Z21	..+..+..+..+..+..+..	..+..+..+..+..+..+..	..+..+..+..+..+..+..	..+..+..+..+..+..+..	..+..+..+..+..+..+..	..+..+..+..+..+..+..
Z22	++++++..++..++..++..	..++..+..+..+..+..	.....	.....	.....	.....
Z23	.....	.....	.....	.....	.....	.....
Z31	++..++..++..++..++..	..+..+..+..+..+..+..	.....	.....	.....	.....
Z32	++++++..++..++..++..	..+..+..+..+..+..+..	..+..+..+..+..+..+..	..+..+..+..+..+..+..	..+..+..+..+..+..+..	..+..+..+..+..+..+..
Z33	..+..+..+..+..+..+..+..	..+..+..+..+..+..+..+..	..+..+..+..+..+..+..+..	..+..+..+..+..+..+..+..	..+..+..+..+..+..+..+..	..+..+..+..+..+..+..+..
Z41	++..++..++..++..++..	..+..+..+..+..+..+..+..	.....	.....	.....	.....
Z42	++..++..++..++..++..	..+..+..+..+..+..+..+..	.....	.....	.....	.....
Z43	.....	.....	.....	.....	.....	.....
Z51	++++++..++..++..++..++..	..+..+..+..+..+..+..+..	.....	.....	.....	.....
Z52	++..++..++..++..++..++..	..+..+..+..+..+..+..+..+..	..+..+..+..+..+..+..+..+..	..+..+..+..+..+..+..+..+..	..+..+..+..+..+..+..+..+..	..+..+..+..+..+..+..+..+..
Z53	.....	.....	.....	.....	.....	.....

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

Schematic Representation of Cross Correlations						
Variable/ Lag	7	8	9	10	11	12
Z11	.....	.....	.....	.....	.....	.....
Z12	.+....+..+..	.....	.....	.....	.....	.....
Z13	.....	.....	.....	.....	.....	.....
Z21	.....	.....	.....	.....	.....	.....
Z22	.....	.....	.....	.....	.....	.....
Z23	.....	.....	.....	.....	.....	.....
Z31	.....	.....	.....	.....	.....	.....
Z32	.....	.....	.....	.....	.....	.....
Z33	..+..+..+..+..+..	..+..+..+..+..+..	..+..+..+..+..+..	..+..+..+..+..+..	..+..+..+..+..+..	..+..+..+..+..+..
Z41	.....	.....	.....	.....	.....	.....
Z42	.....	.....	.....	.....	.....	.....
Z43	.....	.....	.....	.....	.....	.....
Z51	.....	.....	.....	.....	.....	.....
Z52	.....	.....	.....	.....	.....	.....
Z53	.....	.....	.....	.....	.....	.....

## Lampiran 4. Plot MCCF dan MPCCF Residual Model TSR (lanjutan)

### MPCCF Semua Pecahan -Inflow

Schematic Representation of Partial Cross Correlations-Inflow						
Variable/ Lag	1	2	3	4	5	6
Z11	+.+	.	.	.	.	.
Z12	.+	..	..	.	.	.
Z13	..+	.	.	.	.	.
Z21	....+.	..+.-	..+.-	....-	....-	....-
Z22	.....	.....	.....	....+.-	..+.-	..+.-
Z23	....+.	.....+	.....	....+	.....	.....
Z31	....+.	.....+	....-	....-	+	....
Z32	....+.-	.....	....+	....	....	....
Z33	....+.-	....-	.....	....-	....	....
Z41	....+.-	....-	....-	....+.	....-	....+
Z42	....+.-	.....+	.....	....-	....-	....+
Z43	....+.-	.....+.-	.....	.....	.....	.....
Z51	....+.-	....-	.....	.....	.....	.....
Z52	....+.-	....-+.	....-+.	....+.	....+	....
Z53	....+.-	.....	.....	....+.	.....	.....

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

Schematic Representation of Partial Cross Correlations						
Variable/ Lag	7	8	9	10	11	12
Z11	.....+..	-.-.+..	.....	.....-	.....	.....
Z12	....+..	.....	-.-.+..	...+..	.....-..	.....
Z13	.....	.....	.....	.....	....+..+..	....+..+..
Z21	.....	.....	.....	....-..	....+..	....+..
Z22	....+.-	.....	....-	....+..	.....	.....
Z23	.....	.....	.....	.....	....+..	.....
Z31	.....-	.....	....-	....-	....+..	.....+..
Z32	....+..	.....	....-	....+..	....-	....+..
Z33	.....	....+..	.....	....+	.....	.....
Z41	....+..	.....	.....	.....	....-..	....+..
Z42	.....	.....	.....	.....	....-..	....+..
Z43	....+..	.....	.....	.....	....+..	....+..
Z51	.....	.....	.....	.....	.....	.....
Z52	....-..	.....	....-	.....	.....	.....
Z53	.....	....+..	.....	.....	....+..	.....

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

### MCCF Semua Pecahan -Outflow

Schematic Representation of Cross Correlations-Outflow All						
Variable/ Lag	0	1	2	3	4	5
Y11	++++++	....-..-.	....+..	++..+..-.	....-..-.	++..+..+..
Y12	++++++	.....	..+	.....	..+..	++++..+..+..
Y13	++++++	.....	.....	.....	....+..+..	....+..+..
Y21	++++++	....-..-.	....+..	....-..	++..+..+..	++++++
Y22	++++++	....-..-.	.....	.....	.....	++
Y23	++++++	....+..	....-..-.	....+..	....+..+..+..	....+..+..+..
Y31	++++++	....-..-.	.....	.....	.....	++
Y32	++++++	....-..-.	.....	.....	.....	++
Y33	++++++	....+..+..+..	....+..+..	.....	....+..+..	....+..+..
Y41	++++++	....-..-.	.....	.....	.....	++
Y42	++++++	.....	.....	.....	.....	++
Y43	++++++	....+..+..-.	....+..	.....	....+..+..+..	....+..+..+..
Y51	++++++	....-..-.	.....	.....	....+..+..+..	....+..+..+..
Y52	++++++	.....	....+..	....-..	....-..	....+..
Y53	++++++	++++++	....-..-.	.....	.....	....+..+..+..

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

Schematic Representation of Cross Correlations						
Variable/ Lag	7	8	9	10	11	12
Y11	.....	.....	++..+..+..	....-..-.	++++++	++..+..+..
Y12	.....	.....	++..+..	....-..-.	++..+..+..	++..+..+..
Y13	.....	....-..	.....	....+..+..+..	.....	.....
Y21	.....	....+..+..	....-..	++++++	++..+..+..	++..+..+..
Y22	.....	....-..-.	.....	....+..+..+..	.....	.....
Y23	.....	....-..-.	.....	....+..+..+..	.....	.....
Y31	.....	....+..+..+..	....-..-.	....+..+..+..	....+..+..+..	....+..+..+..
Y32	.....	....+..+..	....-..-.	....+..+..+..	....+..+..+..	....+..+..+..
Y33	.....	....-..	.....	....+..+..+..	....+..+..+..	....+..+..+..
Y41	.....	....-..-.	.....	....-..-.	....+..+..+..	....+..+..+..
Y42	.....	....-..-.	.....	....-..-.	....+..+..+..	....+..+..+..
Y43	.....	....-..-.	.....	....-..-.	....+..+..+..	....+..+..+..
Y51	.....	....+..	....-..-.	....+..+..+..	....+..+..+..	....+..+..+..
Y52	....+..	....-..-.	....+..	....-..-.	....+..+..+..	....+..+..+..
Y53	....+..	....-..-.	....-..	.....	....+..+..+..	....+..+..+..

#### Lampiran 4. Plot MCCF dan MPCCF Residual Model TSR (lanjutan)

##### MPCCF Semua Pecahan -Outflow

Schematic Representation of Partial Cross Correlations-outflow						
Variable/ Lag	1	2	3	4	5	6
Y11	+.+.....-.	+.+.+.....	+.....-.-.	...+.....-.	.....-.....-	.....
Y12	.+.....	+.+.....	..+..+.....	....+.....	.....+.....	+
Y13	.....+.....-	.....	.....-.....	-.....+.....	.....	.....
Y21	....+.-.-.	...+.....+..	+.+.....-.	.....	.....-.....	.....
Y22	.....+.....	.....	.....	.....	.....	.....
Y23	....+.....-.	.....-.....	.....+.....	.....+..	.....	.....+.....
Y31	.....+.....	.....	.....	.....	.....-.....	.....
Y32	.....+.....	.....-.....	.....+.....	.....	.....	.....
Y33	.....++..	.....+.....+	.....-.....	.....-.	...+.....	.....
Y41	....-+.....-.	.....-.....	.....-.....	...+.....	.....	.....+.....+
Y42	.....+.....	.....-.....	.....-.....	.....-.	...+.....-.	.....+.....+
Y43	...+-.....+..	.....	.....+.....	.....	..+.....	.....
Y51	.....-.....-.	.....+.....	.....-.....	.....	.....	.....-.....
Y52	.....-.....+.....	.....+..	.....+.....	.....-.....	.....	.....
Y53	...++.....+..	.....	.....-.....	...+.....	.....	.....

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

Schematic Representation of Partial Cross Correlations						
Variable/ Lag	7	8	9	10	11	12
Y11	.....	..+.....	.....	.....-+..	.....	.....
Y12	.....	.....	.....-.	.....-.	.....	.....
Y13	.....-.	.....	.....	.....+.....	.....	.....+.....
Y21	.....	.....-.	.....	.....+.....	.....	.....
Y22	.....	....+.....	.....	.....	.....+.....	.....
Y23	.....	.....	.....	.....	.....	.....+.....+
Y31	.....	.....	...+.....	.....	.....-+.....	.....
Y32	.....-.	.....	.....+.....+	.....	.....	.....
Y33	.....-.	.....	.....	.....	.....-.	.....-.
Y41	..+.....-.	.....	.....-.....	.....-.	.....+.....	.....
Y42	.....	.....	.....-.....	.....	.....	.....
Y43	.....-.	..+.....	.....-.....	.....	.....	.....
Y51	.....	.....	.....	.....-.	...+.....-.	.....
Y52	.....	.....	.....	.....-.	.....	.....
Y53	.....	.....	.....	.....-.	.....	.....-.

## Lampiran 5. Estimasi Parameter Model GSTARX Bobot Terbaik

Inflow Pecahan Rp100.000 GSTARX(2 <sub>1</sub> ) Bobot Seragam				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0,204573658	0,063046662	3,24479984	1,367617e-03
loc1_wlag1loc1	-0,271899850	0,07163871	-3,79543214	1,928221e-04
loc1_lag2loc1	0,242842945	0,06319349	3,84284744	1,611170e-04
loc1_wlag2loc1	-0,230513198	0,07013643	-3,28664002	1,188322e-03
loc2_lag1loc2	0,001327189	0,06478822	0,02048504	9,836759e-01
loc2_wlag1loc2	-0,174698087	0,06896706	-2,53306551	1,203738e-02
loc2_lag2loc2	0,087083778	0,06431949	1,35392518	1,772155e-01
loc2_wlag2loc2	-0,058578739	0,06857903	-0,85417856	3,939794e-01
loc3_lag1loc3	0,181719423	0,06732225	2,69924776	7,515606e-03
loc3_wlag1loc3	-0,109829226	0,02598013	-4,22743098	3,526121e-05
loc3_lag2loc3	0,279339672	0,06607348	4,22771238	3,522062e-05
loc3_wlag2loc3	-0,083007392	0,02567346	-3,23319910	1,421606e-03
loc4_lag1loc4	0,178801050	0,07256066	2,46415971	1,453683e-02
loc4_wlag1loc4	-0,294570679	0,08233126	-3,57787151	4,300799e-04
loc4_lag2loc4	0,038923659	0,07282756	0,53446330	5,935864e-01
loc4_wlag2loc4	-0,042865400	0,08066331	-0,53141135	5,956954e-01
loc5_lag1loc5	0,026588892	0,07481013	0,35541833	7,226330e-01
loc5_wlag1loc5	-0,666967274	0,23502730	-2,83782891	4,987518e-03
loc5_lag2loc5	0,141117763	0,07435513	1,89788877	5,908236e-02
loc5_wlag2loc5	-0,443074939	0,23495282	-1,88580388	6,070179e-02
Inflow Pecahan Rp50.000 GSTARX(2 <sub>1</sub> ) Bobot Seragam				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0,2446581815	0,06815263	3,589856974	4,118777e-04
loc1_wlag1loc1	-0,0991345313	0,06441386	-1,539024796	1,253037e-01
loc1_lag2loc1	0,2163247618	0,06823889	3,170109640	1,751503e-03
loc1_wlag2loc1	-0,0136481697	0,06391894	-0,213523084	8,311261e-01
loc2_lag1loc2	0,0863933758	0,06647199	1,299695950	1,951301e-01
loc2_wlag1loc2	-0,0982895774	0,05620096	-1,748895014	8,177023e-02
loc2_lag2loc2	0,1546877836	0,06543454	2,364007954	1,899063e-02
loc2_wlag2loc2	0,0003933207	0,05549713	0,007087226	9,943520e-01
loc3_lag1loc3	0,1945942770	0,06614363	2,941995581	3,627184e-03
loc3_wlag1loc3	-0,0166951940	0,02320750	-0,719387900	4,727017e-01
loc3_lag2loc3	0,1485728208	0,06610313	2,247591406	2,564174e-02
loc3_wlag2loc3	0,0326649628	0,02293928	1,423974820	1,559379e-01
loc4_lag1loc4	0,2093417436	0,06711186	3,119295881	2,067310e-03
loc4_wlag1loc4	-0,1559684714	0,07753436	-2,011604487	4,553962e-02
loc4_lag2loc4	0,1326960100	0,06928138	1,915319908	5,681025e-02
loc4_wlag2loc4	-0,0154830289	0,07590244	-0,203985927	8,385620e-01
loc5_lag1loc5	0,2708222250	0,07142662	3,791614914	1,956164e-04
loc5_wlag1loc5	-0,6077082921	0,28809935	-2,109370607	3,609713e-02
loc5_lag2loc5	0,3653450268	0,07025449	5,200308906	4,711520e-07
loc5_wlag2loc5	-0,3990302290	0,28941074	-1,378767854	1,694332e-01

**Lampiran 5.** Estimasi Parameter Model GSTARX Bobot Terbaik (lanjutan)

Inflow Pecahan Rp20.000 GSTARX(2 <sub>1</sub> ) Bobot Seragam				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0,331431804	0,06029442	5,49689033	1,114612e-07
loc1_wlag1loc1	0,155446899	0,06769692	2,29621833	2,264992e-02
loc1_lag2loc1	0,173443874	0,05849708	2,96500072	3,376829e-03
loc1_wlag2loc1	-0,067581315	0,06046688	-1,11765844	2,649899e-01
loc2_lag1loc2	0,363852490	0,06388873	5,69509663	4,124828e-08
loc2_wlag1loc2	0,103124199	0,04219843	2,44379218	1,535907e-02
loc2_lag2loc2	0,122090163	0,05934946	2,05714027	4,090842e-02
loc2_wlag2loc2	0,060388742	0,03673796	1,64376942	1,017201e-01
loc3_lag1loc3	0,355918906	0,06600779	5,39207406	1,867014e-07
loc3_wlag1loc3	0,036716346	0,03064546	1,19810054	2,322283e-01
loc3_lag2loc3	0,117919543	0,06652938	1,77244325	7,777084e-02
loc3_wlag2loc3	0,040482448	0,02969474	1,36328701	1,742519e-01
loc4_lag1loc4	0,521883298	0,06844343	7,62503109	8,317791e-13
loc4_wlag1loc4	0,017294171	0,07514570	0,23014186	8,182056e-01
loc4_lag2loc4	0,225933301	0,06762304	3,34107002	9,877313e-04
loc4_wlag2loc4	0,005725295	0,07320275	0,07821147	9,377343e-01
loc5_lag1loc5	0,438126697	0,07248355	6,04449827	6,751766e-09
loc5_wlag1loc5	0,033214114	0,28564994	0,11627559	9,075453e-01
loc5_lag2loc5	0,084260118	0,06650729	1,26693057	2,065834e-01
loc5_wlag2loc5	0,373167693	0,27826160	1,34106787	1,813471e-01
Outflow Pecahan Rp100.000 GSTARX(2 <sub>1</sub> ) Bobot Korelasi Silang				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0,10839508	0,07024425	1,5431169	1,243080e-01
loc1_wlag1loc1	-0,22196682	0,06260365	-3,5455891	4,829412e-04
loc1_lag2loc1	0,11670051	0,06810093	1,7136403	8,807044e-02
loc1_wlag2loc1	-0,07224999	0,03914453	-1,8457238	6,634004e-02
loc2_lag1loc2	0,07652971	0,06292647	1,2161768	2,252828e-01
loc2_wlag1loc2	-0,11988828	0,04340618	-2,7620096	6,253959e-03
loc2_lag2loc2	0,19131054	0,06840854	2,7965884	5,644022e-03
loc2_wlag2loc2	-0,11541980	0,05540049	-2,0833712	3,842771e-02
loc3_lag1loc3	0,20203944	0,06192079	3,2628693	1,287305e-03
loc3_wlag1loc3	-0,13105619	0,02149603	-6,0967612	5,119147e-09
loc3_lag2loc3	-0,07912769	0,06358865	-1,2443683	2,147511e-01
loc3_wlag2loc3	0,04073443	0,03623255	1,1242494	2,621907e-01
loc4_lag1loc4	0,03979081	0,06735640	0,5907503	5,553230e-01
loc4_wlag1loc4	-0,21891146	0,06390066	-3,4258088	7,372483e-04
loc4_lag2loc4	-0,01353538	0,06637314	-0,2039285	8,386068e-01
loc4_wlag2loc4	-0,04064502	0,03158636	-1,2867902	1,995841e-01
loc5_lag1loc5	0,05712906	0,07819327	0,7306134	4,658296e-01
loc5_wlag1loc5	-1,41753333	0,41515992	-3,4144272	7,670390e-04
loc5_lag2loc5	0,12184700	0,07741576	1,5739302	1,170089e-01
loc5_wlag2loc5	-0,94113905	0,36808947	-2,5568214	1,126914e-02

**Lampiran 5.** Estimasi Parameter Model GSTARX Bobot Terbaik (lanjutan)

Outflow Pecahan Rp50.000 GSTARX(2 <sub>1</sub> ) Bobot Korelasi Silang				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0,308629956	0,06672176	4,62562661	6,526787e-06
loc1_wlag1loc1	-0,428427614	0,09256448	-4,62842351	6,447345e-06
loc1_lag2loc1	0,149376571	0,06034284	2,47546486	1,409752e-02
loc1_wlag2loc1	0,001291866	0,03350139	0,03856156	9,692766e-01
loc2_lag1loc2	0,239337357	0,06241089	3,83486514	1,660837e-04
loc2_wlag1loc2	-0,151928126	0,04044962	-3,75598438	2,236128e-04
loc2_lag2loc2	0,113510637	0,05745130	1,97577130	4,949016e-02
loc2_wlag2loc2	0,006750404	0,02143056	0,31498964	7,530823e-01
loc3_lag1loc3	0,128473186	0,05969270	2,15224270	3,251902e-02
loc3_wlag1loc3	-0,085856740	0,02286593	-3,75478866	2,246150e-04
loc3_lag2loc3	0,102419557	0,05298310	1,93306101	5,457338e-02
loc3_wlag2loc3	0,006592890	0,01317583	0,50037740	6,173333e-01
loc4_lag1loc4	0,210872739	0,06085542	3,46514295	6,424206e-04
loc4_wlag1loc4	-0,261692295	0,05632688	-4,64595762	5,970136e-06
loc4_lag2loc4	0,033430205	0,05600789	0,59688384	5,512279e-01
loc4_wlag2loc4	0,029596002	0,02902717	1,01959640	3,090931e-01
loc5_lag1loc5	0,100930448	0,07134344	1,41471232	1,586339e-01
loc5_wlag1loc5	-0,920087595	0,46872436	-1,96296091	5,097103e-02
loc5_lag2loc5	0,280878611	0,07962610	3,52746911	5,152270e-04
loc5_wlag2loc5	-0,509506473	0,41774681	-1,21965377	2,239642e-01
Outflow Pecahan Rp20.000 GSTARX(2 <sub>1</sub> ) Bobot Seragam				
	estimate	std.error	t-value	p-value
loc1_lag1loc1	0,07931380	0,06020103	1,3174824	1,891125e-01
loc1_wlag1loc1	0,25411971	0,05801760	4,3800452	1,872179e-05
loc1_lag2loc1	-0,01621224	0,05922734	-0,2737290	7,845619e-01
loc1_wlag2loc1	-0,15615847	0,06053759	-2,5795289	1,057610e-02
loc2_lag1loc2	0,31563919	0,05866064	5,3807664	1,973040e-07
loc2_wlag1loc2	0,06875323	0,03387037	2,0298932	4,362867e-02
loc2_lag2loc2	0,13107429	0,05777205	2,2688183	2,429581e-02
loc2_wlag2loc2	-0,09035057	0,03399928	-2,6574261	8,479496e-03
loc3_lag1loc3	0,36345102	0,05639509	6,4447278	7,796130e-10
loc3_wlag1loc3	0,04264551	0,02029022	2,1017764	3,676499e-02
loc3_lag2loc3	0,13112016	0,05534025	2,3693454	1,872596e-02
loc3_wlag2loc3	-0,07019034	0,02017112	-3,4797434	6,102260e-04
loc4_lag1loc4	0,27009245	0,05023363	5,3767258	2,012330e-07
loc4_wlag1loc4	0,15771301	0,03912064	4,0314526	7,753915e-05
loc4_lag2loc4	0,15598716	0,04788004	3,2578749	1,309053e-03
loc4_wlag2loc4	-0,14730209	0,03952742	-3,7265797	2,495286e-04
loc5_lag1loc5	0,01431093	0,07373803	0,1940780	8,463024e-01
loc5_wlag1loc5	0,60349447	0,48534515	1,2434336	2,150944e-01
loc5_lag2loc5	-0,01345715	0,07900087	-0,1703418	8,649053e-01
loc5_wlag2loc5	-0,09323382	0,44041112	-0,2116972	8,325486e-01

**Lampiran 6.** Estimasi Parameter Model MGSTARX Bobot Terbaik

Inflow MGSTARX(1 <sub>1</sub> ) Bobot Invers Jarak				
	estimate	std.error	t-value	p-value
Z11_lag1Z11	0,1985535382	0,092478084	2,1470334224	3,294229e-02
Z11_lag1Z12	0,1352891177	0,104407470	1,2957800550	1,964805e-01
Z11_lag1Z13	-0,4192844301	0,775276223	-0,5408194107	5,892080e-01
Z11_wlag1Z11	-0,0702634839	0,124884571	-0,5626274174	5,742916e-01
Z11_wlag1Z12	-0,5793811626	0,165037814	-3,5105964476	5,476119e-04
Z11_wlag1Z13	0,8376372794	1,116596390	0,7501701485	4,539959e-01
Z21_lag1Z21	0,0406592606	0,086047872	0,4725190728	6,370494e-01
Z21_lag1Z22	-0,1568839015	0,126649712	-1,2387229215	2,168375e-01
Z21_lag1Z23	0,6562902092	1,136242781	0,5775968129	5,641581e-01
Z21_wlag1Z21	-0,0317879060	0,104131366	-0,3052673473	7,604663e-01
Z21_wlag1Z22	-0,2977675410	0,135648461	-2,1951413095	2,925450e-02
Z21_wlag1Z23	0,4592119064	1,049713558	0,4374640139	6,622266e-01
Z31_lag1Z31	0,0990218065	0,093896325	1,0545866064	2,928320e-01
Z31_lag1Z32	0,1549886629	0,127480101	1,2157871025	2,254375e-01
Z31_lag1Z33	-2,4877354017	0,730467556	-3,4056754227	7,913684e-04
Z31_wlag1Z31	-0,0504198488	0,041406239	-1,2176872488	2,247158e-01
Z31_wlag1Z32	-0,1535571823	0,063020297	-2,4366305681	1,566186e-02
Z31_wlag1Z33	0,6509423733	0,448203094	1,4523379730	1,479073e-01
Z41_lag1Z41	0,0408940408	0,105434064	0,3878636499	6,985117e-01
Z41_lag1Z42	0,0413332468	0,114640670	0,3605461031	7,188029e-01
Z41_lag1Z43	1,9019898565	0,953625975	1,9944820160	4,739884e-02
Z41_wlag1Z41	-0,0189736132	0,063720299	-0,2977640306	7,661790e-01
Z41_wlag1Z42	-0,2071385262	0,067045412	-3,0895257222	2,277324e-03
Z41_wlag1Z43	-0,6690044490	0,655614916	-1,0204228621	3,087077e-01
Z51_lag1Z51	0,2170412097	0,084683400	2,5629723120	1,108090e-02
Z51_lag1Z52	-0,2399683049	0,083134937	-2,8864916817	4,304724e-03
Z51_lag1Z53	0,5295223406	0,802915842	0,6594991818	5,103013e-01
Z51_wlag1Z51	-0,7203928172	0,277404580	-2,5969031119	1,007510e-02
Z51_wlag1Z52	0,0578061634	0,353492264	0,1635287933	8,702601e-01
Z51_wlag1Z53	0,8908139380	2,660996774	0,3347670116	7,381366e-01
Z12_lag1Z12	0,3389425292	0,096188957	3,5237156243	5,226562e-04
Z12_lag1Z13	0,0706156752	0,711408216	0,0992618213	9,210255e-01
Z12_lag1Z11	0,0217714711	0,085249179	0,2553862834	7,986759e-01
Z12_wlag1Z12	0,1286683145	0,119794444	1,0740758080	2,840272e-01
Z12_wlag1Z13	0,4601743475	0,804239761	0,5721855220	5,678112e-01
Z12_wlag1Z11	-0,2842871184	0,100458785	-2,8298880789	5,110457e-03
Z22_lag1Z22	0,0640090556	0,090212924	0,7095330969	4,787845e-01
Z22_lag1Z23	0,3982974115	0,822256459	0,4843956010	6,286124e-01
Z22_lag1Z21	-0,0369701560	0,061910199	-0,5971577661	5,510484e-01
Z22_wlag1Z22	0,1163930508	0,080244862	1,4504735590	1,484256e-01
Z22_wlag1Z23	0,2153458455	0,657555235	0,3274946866	7,436216e-01
Z22_wlag1Z21	-0,1544374789	0,067445326	-2,2898173593	2,303021e-02
Z32_lag1Z32	0,4057406176	0,092970442	4,3641893918	2,005104e-05
Z32_lag1Z33	-0,1922879925	0,528326758	-0,3639565656	7,162584e-01
Z32_lag1Z31	-0,0840585001	0,068586775	-1,2255788483	2,217365e-01
Z32_wlag1Z32	0,0684227210	0,039499258	1,7322533057	8,470378e-02
Z32_wlag1Z33	0,0275585970	0,287434274	0,0958779084	9,237094e-01
Z32_wlag1Z31	-0,0846047114	0,027022686	-3,1308772080	1,992252e-03
Z42_lag1Z42	0,3941971817	0,093615804	4,2107973745	3,780913e-05
Z42_lag1Z43	0,9589380468	0,780315028	1,2289114174	2,204869e-01
Z42_lag1Z41	-0,2160579293	0,087535660	-2,4682275630	1,438124e-02
Z42_wlag1Z42	-0,0004979832	0,049323164	-0,0100963350	9,919541e-01
Z42_wlag1Z43	-0,4149501184	0,529749182	-0,7832954390	4,343403e-01
Z42_wlag1Z41	-0,0522524972	0,050898215	-1,0266076638	3,057919e-01

**Lampiran 6.** Estimasi Parameter Model MGSTARX Bobot Terbaik (lanjutan)

Inflow MGSTARX(1 <sub>1</sub> ) Bobot Invers Jarak				
	estimate	std.error	t-value	p-value
Z52_lag1Z52	0,6334379427	0,071141420	8,9039260965	2,220446e-16
Z52_lag1Z53	0,7956890275	0,758421516	1,0491382576	2,953262e-01
Z52_lag1Z51	-0,3104482881	0,080470855	-3,8578972126	1,523320e-04
Z52_wlag1Z52	-0,2095805327	0,324626284	-0,6456055572	5,192430e-01
Z52_wlag1Z53	-1,2209878598	2,407780535	-0,5071009763	6,126186e-01
Z52_wlag1Z51	-0,2458653815	0,257755224	-0,9538715745	3,412506e-01
Z13_lag1Z13	0,2677285358	0,056336532	4,7523077286	3,737955e-06
Z13_lag1Z11	0,0069080657	0,006733685	1,0258967997	3,061261e-01
Z13_lag1Z12	0,0061945526	0,007590553	0,8160871453	4,153794e-01
Z13_wlag1Z13	0,2144425082	0,069122562	3,1023518578	2,185110e-03
Z13_wlag1Z11	0,0028104252	0,008299706	0,3386174325	7,352379e-01
Z13_wlag1Z12	0,0127220852	0,010315760	1,2331473563	2,189059e-01
Z23_lag1Z23	0,3774615432	0,056425498	6,6895562530	2,012994e-10
Z23_lag1Z21	0,0069983915	0,004252459	1,6457280437	1,013228e-01
Z23_lag1Z22	0,0020646061	0,006234840	0,3311401746	7,408704e-01
Z23_wlag1Z23	0,1585165388	0,045184673	3,5081926682	5,523039e-04
Z23_wlag1Z21	0,0058930474	0,004620177	1,2755024999	2,035473e-01
Z23_wlag1Z22	-0,0085962899	0,005534134	-1,5533214905	1,218593e-01
Z33_lag1Z33	0,3435534041	0,062525010	5,4946557644	1,132249e-07
Z33_lag1Z31	-0,0066288926	0,008082331	-0,8201708580	4,130531e-01
Z33_lag1Z32	0,0129076791	0,010968144	1,1768334773	2,406005e-01
Z33_wlag1Z33	0,0867932590	0,034394109	2,5234919864	1,236355e-02
Z33_wlag1Z31	0,0039649934	0,003221655	1,2307318164	2,198065e-01
Z33_wlag1Z32	0,0030343213	0,004755445	0,6380731108	5,241246e-01
Z43_lag1Z43	0,6191532668	0,056095749	11,0374365430	0,000000e+00
Z43_lag1Z41	0,0046631500	0,006210074	0,7509008180	4,535570e-01
Z43_lag1Z42	-0,0051946040	0,006778288	-0,7663592532	4,443273e-01
Z43_wlag1Z43	-0,0245251848	0,038804168	-0,6320244959	5,280616e-01
Z43_wlag1Z41	0,0082811096	0,003717995	2,2273049671	2,699339e-02
Z43_wlag1Z42	-0,0040971348	0,003801123	-1,0778748960	2,823321e-01
Z53_lag1Z53	0,4548373599	0,070620435	6,4405913032	8,040302e-10
Z53_lag1Z51	0,0008004726	0,007436296	0,1076439915	9,143814e-01
Z53_lag1Z52	-0,0080914012	0,006709166	-1,2060218938	2,291725e-01
Z53_wlag1Z53	0,0271211498	0,218755928	0,1239790394	9,014510e-01
Z53_wlag1Z51	0,0395011017	0,023244676	1,6993612279	9,073899e-02
Z53_wlag1Z52	-0,0000140700	0,029701805	-0,0004737087	9,996225e-01

**Lampiran 6.** Estimasi Parameter Model MGSTARX Bobot Terbaik (lanjutan)

Outflow MGSTARX(1 <sub>1</sub> ) Bobot Korelasi Silang				
	estimate	std.error	t-value	p-value
Y11_lag1Y11	1,046002e-01	0,068393812	1,529381498	1,276820e-01
Y11_lag1Y12	1,094031e-01	0,076682580	1,426701316	1,551582e-01
Y11_lag1Y13	-1,419071e-01	0,399541356	-0,355174982	7,228167e-01
Y11_wlag1Y11	-1,584349e-01	0,074603090	-2,123704389	3,487054e-02
Y11_wlag1Y12	-3,903628e-01	0,125306001	-3,115276298	2,095687e-03
Y11_wlag1Y13	8,678468e-01	0,196151356	4,424373435	1,556129e-05
Y21_lag1Y21	1,384550e-01	0,063133544	2,193049886	2,940705e-02
Y21_lag1Y22	-2,019050e-01	0,100525616	-2,008493347	4,587781e-02
Y21_lag1Y23	-8,628646e-02	0,467538179	-0,184554899	8,537571e-01
Y21_wlag1Y21	-1,403447e-01	0,046263009	-3,033625840	2,722664e-03
Y21_wlag1Y22	-1,043989e-01	0,068247632	-1,529707349	1,276013e-01
Y21_wlag1Y23	1,640552e+00	0,223688997	7,334076622	4,836576e-12
Y31_lag1Y31	1,848396e-01	0,063704960	2,901494184	4,111561e-03
Y31_lag1Y32	-7,449083e-02	0,120207810	-0,619683742	5,361410e-01
Y31_lag1Y33	-6,215512e-01	0,481485856	-1,290902327	1,981636e-01
Y31_wlag1Y31	-1,280408e-01	0,024822939	-5,158165867	5,777426e-07
Y31_wlag1Y32	-5,705964e-02	0,037840375	-1,507903719	1,330893e-01
Y31_wlag1Y33	9,421121e-01	0,160092528	5,884797147	1,567121e-08
Y41_lag1Y41	9,777676e-02	0,071608946	1,365426654	1,735868e-01
Y41_lag1Y42	-6,630343e-02	0,118755189	-0,558320305	5,772233e-01
Y41_lag1Y43	-8,411147e-01	0,592239011	-1,420228492	1,570312e-01
Y41_wlag1Y41	-2,938382e-01	0,064491484	-4,556233171	8,849638e-06
Y41_wlag1Y42	-8,779270e-02	0,089943809	-0,976083822	3,301513e-01
Y41_wlag1Y43	2,996513e+00	0,382904302	7,825750154	2,478018e-13
Y51_lag1Y51	-5,183732e-04	0,076627448	-0,006764850	9,946089e-01
Y51_lag1Y52	-4,505389e-01	0,089382946	-5,040546690	1,003808e-06
Y51_lag1Y53	3,236442e+00	0,621613956	5,206514665	4,591700e-07
Y51_wlag1Y51	-1,814307e+00	0,527864302	-3,437071194	7,094497e-04
Y51_wlag1Y52	2,198329e+00	0,920903087	2,387144809	1,787096e-02
Y51_wlag1Y53	1,907066e+00	3,279415643	0,581526168	5,615125e-01
Y12_lag1Y12	3,874728e-01	0,065590041	5,907493791	1,392911e-08
Y12_lag1Y13	-6,510868e-02	0,342239831	-0,190242858	8,493035e-01
Y12_lag1Y11	2,657916e-02	0,058610563	0,453487503	6,506682e-01
Y12_wlag1Y12	-2,395726e-01	0,102934127	-2,327435884	2,089898e-02
Y12_wlag1Y13	5,748250e-01	0,159861824	3,595761491	4,035885e-04
Y12_wlag1Y11	-2,724408e-01	0,061137145	-4,456224046	1,359340e-05
Y22_lag1Y22	2,629651e-01	0,063045701	4,171024222	4,444334e-05
Y22_lag1Y23	5,895384e-01	0,296283545	1,989777641	4,791902e-02
Y22_lag1Y21	-1,519947e-01	0,039617980	-3,836508276	1,652610e-04
Y22_wlag1Y22	-3,718416e-02	0,041554916	-0,894819735	3,719128e-01
Y22_wlag1Y23	5,994119e-01	0,134485208	4,457084396	1,354371e-05
Y22_wlag1Y21	-8,508009e-02	0,028232749	-3,013524977	2,901487e-03
Y32_lag1Y32	2,726987e-01	0,064014544	4,259948757	3,091281e-05
Y32_lag1Y33	2,044821e-01	0,259319203	0,788534417	4,312777e-01
Y32_lag1Y31	-2,035416e-02	0,033857980	-0,601162814	5,483830e-01
Y32_wlag1Y32	-3,281135e-02	0,023142660	-1,417786401	1,577423e-01
Y32_wlag1Y33	4,341943e-01	0,100540391	4,318605195	2,425321e-05
Y32_wlag1Y31	-1,009883e-01	0,015082570	-6,695694907	1,944631e-10

**Lampiran 6.** Estimasi Parameter Model MGSTARX Bobot Terbaik (lanjutan)

Outflow MGSTARX(1 <sub>1</sub> ) Bobot Korelasi Silang				
	estimate	std.error	t-value	p-value
Y42_lag1Y42	4,708046e-01	0,071710323	6,565366792	4,032810e-10
Y42_lag1Y43	-2,980246e-01	0,355969351	-0,837219954	4,034253e-01
Y42_lag1Y41	-5,273656e-02	0,043222824	-1,220109049	2,237985e-01
Y42_wlag1Y42	-1,662004e-01	0,053362049	-3,114580577	2,100413e-03
Y42_wlag1Y43	1,224228e+00	0,225256155	5,434827012	1,520786e-07
Y42_wlag1Y41	-2,540624e-01	0,038547841	-6,590834398	3,499512e-10
Y52_lag1Y52	2,233105e-01	0,071934748	3,104348081	2,171072e-03
Y52_lag1Y53	5,064296e-01	0,491668426	1,030022597	3,041899e-01
Y52_lag1Y51	-3,346067e-01	0,062095575	-5,388575096	1,907440e-07
Y52_wlag1Y52	-7,313563e-01	0,752129817	-0,972380375	3,319854e-01
Y52_wlag1Y53	1,670407e+00	2,731130890	0,611617352	5,414557e-01
Y52_wlag1Y51	5,409136e-01	0,430771609	1,255685267	2,106321e-01
Y13_lag1Y13	1,035639e-01	0,054073367	1,915248694	5,682589e-02
Y13_lag1Y11	5,685434e-03	0,009359218	0,607468889	5,441992e-01
Y13_lag1Y12	6,807291e-03	0,010500569	0,648278264	5,175166e-01
Y13_wlag1Y13	1,531744e-01	0,023031793	6,650564576	2,505878e-10
Y13_wlag1Y11	-3,244240e-02	0,009071530	-3,576288135	4,329708e-04
Y13_wlag1Y12	9,755764e-04	0,015192607	0,064213892	9,488613e-01
Y23_lag1Y23	3,898857e-01	0,050780799	7,677818138	6,123990e-13
Y23_lag1Y21	-1,574965e-05	0,006618940	-0,002379482	9,981037e-01
Y23_lag1Y22	1,101363e-02	0,010474311	1,051489340	2,942481e-01
Y23_wlag1Y23	7,781274e-02	0,021381616	3,639235837	3,446227e-04
Y23_wlag1Y21	-1,025953e-02	0,004503875	-2,277933861	2,374186e-02
Y23_wlag1Y22	-2,323279e-02	0,006602936	-3,518554933	5,323428e-04
Y33_lag1Y33	3,879228e-01	0,050559436	7,672609381	6,319389e-13
Y33_lag1Y31	-9,647761e-03	0,006680782	-1,444106682	1,502064e-01
Y33_lag1Y32	1,236146e-02	0,012644459	0,977618887	3,293931e-01
Y33_wlag1Y33	6,183410e-02	0,015346861	4,029103848	7,838094e-05
Y33_wlag1Y31	-8,123461e-03	0,002427680	-3,346182615	9,713706e-04
Y33_wlag1Y32	-3,437569e-03	0,003670595	-0,936515650	3,500886e-01
Y43_lag1Y43	4,341439e-01	0,044944032	9,659656929	0,000000e+00
Y43_lag1Y41	-2,073413e-02	0,005222926	-3,969830497	9,890079e-05
Y43_lag1Y42	-1,232381e-02	0,008666199	-1,422054433	1,565011e-01
Y43_wlag1Y43	1,584704e-01	0,026897103	5,891726210	1,511791e-08
Y43_wlag1Y41	-8,062776e-03	0,004597631	-1,753680681	8,095109e-02
Y43_wlag1Y42	-7,396271e-04	0,006447720	-0,114711403	9,087840e-01
Y53_lag1Y53	8,817383e-02	0,076619549	1,150800739	2,511291e-01
Y53_lag1Y51	-2,506176e-03	0,010665737	-0,234974513	8,144586e-01
Y53_lag1Y52	-2,650295e-02	0,012345305	-2,146803709	3,296082e-02
Y53_wlag1Y53	3,147558e-01	0,487867191	0,645167024	5,195265e-01
Y53_wlag1Y51	-5,962452e-02	0,076836378	-0,775993410	4,386301e-01
Y53_wlag1Y52	1,487845e-01	0,134424211	1,106827796	2,696407e-01

**Lampiran 7.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX (Miliar Rp)

Periode	<i>Inflow</i> Rp100.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	1958,949	2330,915	1417,318	5346,484	9285,218
Agt 2019	2187,384	2434,837	1500,976	5808,097	8363,434
Sep 2019	1971,932	2136,885	1355,896	5601,346	7279,581
Okt 2019	2212,708	2396,631	1490,25	5642,819	7143,109
Nov 2019	1924,804	2256,186	1423,275	5442,738	6419,261
Des 2019	1730,03	1999,712	1346,433	5165,222	5809,201
Jan 2020	2536,941	2677,281	1696,919	6034,749	8324,294
Feb 2020	2084,569	2380,072	1521,69	5597,7	7214,497
Mar 2020	1960,902	2389,738	1535,994	5657,999	7093,801
Apr 2020	1948,978	2381,209	1525,227	5595,333	6948,8
Mei 2020	1603,609	1978,218	1366,141	5135,69	6213,114
Juni 2020	3702,124	3902,359	2119,675	7349,542	11262
Juli 2020	2380,822	2755,896	1745,092	6105,879	7871,434
Agt 2020	2324,826	2591,158	1684,871	6153,125	7886,536
Sep 2020	2024,906	2276,158	1518,303	5915,723	7293,216
Okt 2020	2235,23	2520,198	1634,43	5975,566	7333,125
Nov 2020	1954,673	2385,879	1561,273	5813,498	6715,093
Des 2020	1777,677	2139,557	1482,804	5570,156	6171,959
Jan 2021	2604,296	2828,386	1834,008	6467,666	8734,531
Feb 2021	2169,62	2541,412	1660,255	6052,414	7659,131
Mar 2021	2060,568	2559,695	1676,116	6129,408	7563,634
Apr 2021	2060,179	2558,084	1666,716	6079,402	7437,109
Mei 2021	2931	3385,756	2091,004	6882,411	10421,5
Juni 2021	2168,334	2621,185	1740,85	6383,21	7720,285
Juli 2021	2512,646	2945,429	1889,186	6612,015	8390,476
Agt 2021	2460,4	2783,033	1829,447	6663,258	8410,905
Sep 2021	2163,261	2469,778	1663,234	6428,832	7821,49
Okt 2021	2375,642	2715,115	1779,623	6490,886	7864,264
Nov 2021	2096,604	2581,755	1706,657	6330,458	7248,336
Des 2021	1920,729	2336,142	1628,329	6088,332	6706,747

**Lampiran 7.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX (Miliar Rp)  
(lanjutan)

Periode	<i>Inflow</i> Rp50.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	1308,861	1478,561	1009,904	3364,468	3470,626
Agt 2019	993,2888	1257,99	846,5403	3203,373	3101,292
Sep 2019	783,905	1042,009	724,2236	2982,759	3013,418
Okt 2019	905,6145	1130,265	717,0888	2989,733	3282,674
Nov 2019	708,2953	1097,108	661,7377	2848,896	2977,811
Des 2019	582,6872	906,8959	627,0835	2640,801	2951,762
Jan 2020	1022,96	1358,649	836,6064	3256,011	4860,773
Feb 2020	768,3339	1129,722	718,2916	2993,726	3999,248
Mar 2020	706,0729	1169,524	742,1409	3061,732	4121,251
Apr 2020	741,441	1203,313	741,7863	3033,247	4127,3
Mei 2020	528,8979	862,5277	598,4705	2731,887	3094,509
Juni 2020	1814,273	2069,779	1129,902	4196,551	6622,579
Juli 2020	941,3022	1313,493	861,8365	3325,316	4671,282
Agt 2020	926,7907	1281,104	825,0283	3321,67	4658,251
Sep 2020	821,9916	1123,943	774,2599	3207,669	4459,875
Okt 2020	973,1448	1223,506	797,5251	3256,723	4488,465
Nov 2020	781,4509	1192,122	753,4907	3129,746	3963,757
Des 2020	650,3307	998,043	719,9499	2920,11	3755,697
Jan 2021	1081,663	1444,606	926,2121	3528,369	5523,23
Feb 2021	817,814	1210,624	803,1778	3258,064	4554,394
Mar 2021	747,392	1246,111	822,2807	3318,803	4596,154
Apr 2021	776,0494	1276,438	817,7475	3284,339	4542,649
Mei 2021	1531,215	1747,281	1173,551	3873,288	7318,807
Juni 2021	902,9012	1391,378	939,6376	3602,549	5176,867
Juli 2021	963,4844	1380,386	929,5498	3565,491	4986,291
Agt 2021	946,6757	1346,866	891,1521	3559,861	4955,679
Sep 2021	840,1699	1188,87	839,1902	3444,395	4744,368
Okt 2021	990,0605	1287,818	861,5655	3492,371	4763,44
Nov 2021	797,4349	1255,981	816,8706	3364,602	4231,726
Des 2021	665,6282	1061,568	782,841	3154,384	4018,508

**Lampiran 7.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX (Miliar Rp)  
(lanjutan)

Periode	<i>Inflow</i> Rp20.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	137,4201	126,2487	82,37701	176,2306	334,2605
Agt 2019	65,08139	77,78438	52,5995	134,1103	210,5885
Sep 2019	36,03654	63,0267	43,59716	110,6965	171,721
Okt 2019	29,20991	55,88634	37,15384	99,68598	145,2556
Nov 2019	29,97929	49,7855	29,55531	83,1789	125,5082
Des 2019	11,61716	42,1382	26,78621	76,86551	105,2929
Jan 2020	38,81671	58,29509	42,76348	109,0664	195,4038
Feb 2020	16,8933	44,03264	33,05423	83,50243	139,204
Mar 2020	12,22451	44,89699	34,21999	85,38803	131,5016
Apr 2020	9,534957	42,44925	31,87953	76,85944	116,8238
Mei 2020	0,629382	17,82207	18,51459	41,94507	52,55847
Juni 2020	89,67624	103,1456	69,80363	169,2794	339,7488
Juli 2020	19,90479	41,85101	33,01963	89,046	145,5791
Agt 2020	33,00878	49,05906	32,94358	89,79879	164,8757
Sep 2020	19,08494	45,29442	33,98845	77,5184	134,542
Okt 2020	19,31233	43,80112	33,34879	74,64852	112,2676
Nov 2020	23,05838	40,87411	28,78504	64,14015	96,75122
Des 2020	6,101572	35,37041	27,57923	62,52011	81,31741
Jan 2021	34,03757	53,13656	44,35515	98,45331	176,1065
Feb 2021	12,56498	40,1459	35,06105	75,86823	124,0683
Mar 2021	8,208378	42,02552	36,4506	80,11688	119,8441
Apr 2021	5,752433	40,38287	34,23792	73,44562	107,9597
Mei 2021	31,70966	49,12763	54,87619	132,1686	294,4148
Juni 2021	36,13409	55,32436	51,09608	109,7633	200,3659
Juli 2021	16,55595	41,27705	35,54388	89,04535	141,8539
Agt 2021	29,74606	48,76861	35,49405	90,44612	162,11
Sep 2021	15,8886	45,21761	36,55851	78,65527	132,4942
Okt 2021	16,16677	43,88445	35,93365	76,15352	110,7546
Nov 2021	19,9514	41,07697	31,38114	65,92092	95,6355
Des 2021	3,023754	35,66224	30,18386	64,50682	80,49618

**Lampiran 7.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX (Miliar Rp)  
(lanjutan)

Periode	<i>Outflow</i> Rp100.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	2774,588	2486,439	973,7084	3510,721	13739,24
Agt 2019	2283,333	2249,566	1442,362	2688,01	11260,52
Sep 2019	2236,873	2206,065	1336,573	2877,514	11605,52
Okt 2019	2137,473	2127,041	1275,706	2855,316	12021,64
Nov 2019	2174,863	2168,429	1225,124	2931,739	12115,21
Des 2019	2793,19	2790,318	1420,047	3562,432	14618,94
Jan 2020	1942,151	1940,669	1130,269	2763,182	10696,54
Feb 2020	2109,849	2109,125	1220,264	3001,595	11444,13
Mar 2020	2358,911	2358,547	1277,536	3148,316	12494,56
Apr 2020	2496,696	2496,513	1360,009	3309,554	12793,96
Mei 2020	3556,596	3556,504	1934,564	4895,596	18062,11
Juni 2020	2602,347	2602,3	1508,303	3602,342	13658,53
Juli 2020	2514,353	2514,33	1454,119	3443,15	13312,82
Agt 2020	2520,765	2520,753	1444,354	3133,731	12506,52
Sep 2020	2385,875	2385,869	1482,026	3162,145	12420,25
Okt 2020	2328,077	2328,074	1394,549	3177,062	12988,51
Nov 2020	2365,291	2365,29	1346,517	3242,793	13059,8
Des 2020	2988,32	2988,319	1541,175	3874,324	15572,6
Jan 2021	2138,613	2138,612	1252,003	3074,235	11648,31
Feb 2021	2307,15	2307,149	1342,141	3312,489	12394,9
Mar 2021	2556,577	2556,577	1399,446	3459,097	13444,04
Apr 2021	3063,023	3063,023	1737,492	4160,985	15415,2
Mei 2021	2902,947	2902,947	1649,434	4126,952	14830,91
Juni 2021	2800,303	2800,303	1630,103	3913,05	14605,97
Juli 2021	2712,323	2712,323	1575,893	3753,855	14260,01
Agt 2021	2718,74	2718,74	1566,11	3444,433	13453,56
Sep 2021	2583,852	2583,852	1603,771	3472,846	13367,2
Okt 2021	2526,054	2526,054	1516,287	3487,763	13935,41
Nov 2021	2563,269	2563,269	1468,251	3553,494	14006,68
Des 2021	3186,297	3186,297	1662,908	4185,024	16519,46

**Lampiran 7.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX (Miliar Rp)  
(lanjutan)

Periode	<i>Outflow</i> Rp50.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	1688,616	1148,4	537,0926	1489,1	8554,849
Agt 2019	1383,779	910,6874	701,5739	1057,16	7280,01
Sep 2019	1275,21	949,8736	646,0629	1156,891	7532,693
Okt 2019	1225,258	875,3482	623,3701	1158,507	7660,834
Nov 2019	1260,61	888,8814	615,5839	1147,387	8016,298
Des 2019	1592,015	1077,574	752,6448	1450,823	10089,67
Jan 2020	992,2754	828,4878	568,2814	1079,546	6943,591
Feb 2020	1190,474	927,8626	642,7605	1200,577	7602,612
Mar 2020	1369,541	1007,42	693,4207	1358,597	8651,586
Apr 2020	1374,494	1010,225	738,9527	1393,404	8345,704
Mei 2020	2523,661	1747,541	1148,347	2491,641	12544,49
Juni 2020	1547,174	1162,009	794,2981	1519,913	8884,114
Juli 2020	1388,789	1090,658	766,879	1412,135	8683,107
Agt 2020	1463,245	1014,804	720,5983	1257,98	8147,294
Sep 2020	1301,887	1014,042	714,9944	1254,282	8100,052
Okt 2020	1290,464	954,8716	683,2486	1266,511	8285,224
Nov 2020	1330,168	967,2554	672,767	1243,831	8610,652
Des 2020	1667,206	1157,125	808,9198	1544,411	10685,62
Jan 2021	1069,57	908,2689	624,2902	1170,6	7538,375
Feb 2021	1268,991	1007,843	698,6715	1290,356	8198,412
Mar 2021	1448,671	1087,499	749,2842	1447,647	9248,307
Apr 2021	1884,792	1425,866	921,7833	1802,05	11897,2
Mei 2021	2169,928	1520,624	993,512	1822,532	11985,57
Juni 2021	1626,916	1242,197	850,0877	1608,282	9482,581
Juli 2021	1468,584	1170,855	822,6561	1500,456	9281,807
Agt 2021	1543,069	1095,007	776,3669	1346,278	8746,133
Sep 2021	1381,727	1094,247	770,7576	1342,57	8698,971
Okt 2021	1370,312	1035,078	739,0085	1354,795	8884,187
Nov 2021	1410,02	1047,462	728,5249	1332,113	9209,639
Des 2021	1747,061	1237,332	864,6765	1632,693	11284,62

**Lampiran 7.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX (Miliar Rp)  
(lanjutan)

Periode	<i>Outflow</i> Rp20.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	86,09605	71,59466	-1,58342	109,5865	315,1885
Agt 2019	51,22827	42,97746	32,3773	59,66118	203,2219
Sep 2019	22,30826	35,86434	15,70261	54,394	136,0445
Okt 2019	9,446765	26,60655	11,95649	43,37822	126,4374
Nov 2019	12,14969	25,78075	13,20678	51,02858	81,05017
Des 2019	33,19121	37,68513	17,93952	70,35565	232,2205
Jan 2020	37,46506	35,94013	18,11065	66,02075	231,3956
Feb 2020	42,40185	41,3598	21,33876	66,37452	186,46
Mar 2020	43,01512	48,28687	25,5113	75,67543	217,1335
Apr 2020	126,0701	83,85203	41,58351	113,6197	664,9223
Mei 2020	258,6373	191,5431	109,4813	243,3363	783,9227
Juni 2020	110,0045	71,63211	43,79648	109,0179	286,9587
Juli 2020	69,18584	59,90475	33,98128	85,72463	300,2221
Agt 2020	58,77291	47,78793	26,97304	66,3758	211,316
Sep 2020	22,17426	36,27928	20,02627	55,29286	139,133
Okt 2020	11,9012	28,47339	14,09868	47,68346	133,4063
Nov 2020	14,58869	27,7444	15,03049	55,61347	87,37597
Des 2020	35,8278	39,9337	19,50188	75,47159	238,9379
Jan 2021	40,16347	38,30603	19,59222	71,37031	238,0485
Feb 2021	45,13698	43,79614	22,77696	71,87031	193,0781
Mar 2021	45,76941	50,7569	26,92834	81,24883	223,6966
Apr 2021	187,4538	117,8799	61,67222	151,7574	758,7482
Mei 2021	110,7861	75,07091	42,93222	114,9887	423,4679
Juni 2021	112,7788	74,12772	45,18723	114,6637	293,4297
Juli 2021	71,962	62,40106	35,36846	91,37499	306,6809
Agt 2021	61,5501	50,28419	28,35789	72,02808	217,7674
Sep 2021	24,95201	38,77529	21,40965	60,94583	145,5802
Okt 2021	14,67924	30,96913	15,48115	53,3366	139,8511
Nov 2021	17,36689	30,23993	16,41241	61,26658	93,81945
Des 2021	38,60608	42,42908	20,88347	81,12463	245,3807

**Lampiran 8.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-ERNN  
(Miliar Rp)

Periode	<i>Inflow</i> Rp100.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	2370,274	2155,797	1604,469	5080,325	7508,652
Agt 2019	1679,249	1937,164	1544,686	5072,24	7423,762
Sep 2019	1382,185	2090,409	1378,482	4838,076	6834,449
Okt 2019	1594,62	2340,508	1494,878	5430,256	6877,297
Nov 2019	1315,638	2207,756	1421,917	5270,661	6261,425
Des 2019	1219,37	1962,165	1343,592	5028,572	5719,876
Jan 2020	2483,903	2651,532	1694,903	5927,006	8283,614
Feb 2020	2052,597	2364,955	1521,227	5512,438	7209,073
Mar 2020	1944,028	2383,529	1537,146	5589,938	7114,207
Apr 2020	1943,98	2382,134	1527,787	5540,306	6988,147
Mei 2020	1607,734	1984,702	1369,836	5090,483	6266,346
Juni 2020	3713,15	3913,093	2124,248	7311,703	11325,41
Juli 2020	2397,018	2769,842	1750,328	6073,549	7942,296
Agt 2020	2344,872	2607,51	1690,6	6124,903	7962,861
Sep 2020	2047,808	2294,302	1524,396	5890,559	7373,548
Okt 2020	2260,243	2539,674	1640,792	5952,673	7416,396
Nov 2020	1981,246	2406,339	1567,831	5792,29	6800,524
Des 2020	1805,4	2160,745	1489,506	5550,197	6258,975
Jan 2021	2632,867	2850,112	1840,817	6448,632	8822,713
Feb 2021	2198,817	2563,535	1667,141	6034,064	7748,172
Mar 2021	2090,226	2582,11	1683,06	6111,563	7653,306
Apr 2021	2090,177	2580,714	1673,701	6061,931	7527,246
Mei 2021	2961,248	3408,546	2098,02	6865,216	10511,98
Juni 2021	2198,767	2644,092	1747,889	6366,219	7811,017
Juli 2021	2543,216	2968,422	1896,242	6595,174	8481,395
Agt 2021	2491,069	2806,09	1836,514	6646,529	8501,96
Sep 2021	2194,005	2492,882	1670,31	6412,184	7912,647
Okt 2021	2406,44	2738,254	1786,706	6474,299	7955,495
Nov 2021	2127,443	2604,919	1713,745	6313,916	7339,623
Des 2021	1951,597	2359,325	1635,42	6071,823	6798,074

**Lampiran 8.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-ERNN  
(Miliar Rp) (lanjutan)

Periode	<i>Inflow</i> Rp50.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	1094,865	1405,557	841,9068	3190,982	4761,065
Agt 2019	949,6843	1232,464	770,34	3075,104	4455,852
Sep 2019	843,1336	1074,446	718,3457	2959,601	3396,841
Okt 2019	992,9911	1173,378	740,6972	3007,549	3415,662
Nov 2019	800,3411	1141,529	695,9847	2879,759	2883,769
Des 2019	668,5164	947,1075	661,942	2669,526	2803,563
Jan 2020	1099,33	1393,418	867,8336	3277,347	5279,739
Feb 2020	835,0991	1159,251	744,5258	3006,72	4309,686
Mar 2020	764,396	1194,602	763,4271	3067,222	4349,337
Apr 2020	792,8464	1224,829	758,7452	3032,585	4294,272
Mei 2020	574,8607	881,2902	611,8831	2726,416	3216,324
Juni 2020	1856,059	2086,455	1140,517	4187,421	6711,102
Juli 2020	979,9341	1328,609	870,2976	3313,445	4735,291
Agt 2020	963,0644	1295,06	831,8561	3307,764	4704,218
Sep 2020	856,5137	1137,042	779,8619	3192,26	4492,567
Okt 2020	1006,371	1235,973	802,2133	3240,208	4511,388
Nov 2020	813,7212	1204,124	757,5008	3112,419	3979,489
Des 2020	681,8965	1009,703	723,4582	2902,186	3766,135
Jan 2021	1112,71	1456,014	929,3498	3510,007	5529,768
Feb 2021	848,4792	1221,847	806,0419	3239,38	4558,06
Mar 2021	777,7761	1257,197	824,9432	3299,882	4597,704
Apr 2021	806,2265	1287,425	820,2613	3265,244	4542,639
Mei 2021	1561,239	1758,194	1175,955	3854,064	7317,646
Juni 2021	932,8137	1402,237	941,9611	3583,232	5174,859
Juli 2021	993,3142	1391,204	931,8137	3546,104	4983,657
Agt 2021	976,4446	1357,655	893,3722	3540,423	4952,585
Sep 2021	869,8938	1199,637	841,378	3424,92	4740,934
Okt 2021	1019,751	1298,569	863,7294	3472,868	4759,755
Nov 2021	827,1014	1266,72	819,0169	3345,078	4227,856
Des 2021	695,2766	1072,299	784,9743	3134,845	4014,501

**Lampiran 8.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-ERNN  
(Miliar Rp) (lanjutan)

Periode	<i>Inflow Rp20.000</i>				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	69,46167	69,84943	44,18969	107,9746	160,2243
Agt 2019	37,15455	49,19345	31,11054	86,34943	164,3564
Sep 2019	23,29919	45,6485	32,17565	74,57285	134,7604
Okt 2019	23,5789	44,31981	31,55127	72,08162	113,0354
Nov 2019	27,36469	41,51562	26,99912	61,8568	97,92705
Des 2019	10,43788	36,10332	25,8021	60,44844	82,79567
Jan 2020	38,39642	53,9373	42,58468	96,53929	177,8086
Feb 2020	16,94072	40,99692	33,29561	74,07139	125,9359
Mar 2020	12,59671	42,91376	34,68895	78,407	121,834
Apr 2020	10,15015	41,29863	32,4791	71,8002	110,0399
Mei 2020	1,432594	17,32252	19,19458	38,3791	48,02629
Juni 2020	90,62641	103,1492	70,53675	166,8635	336,945
Juli 2020	20,96964	42,23927	33,78993	87,50909	144,0863
Agt 2020	34,16259	49,73902	33,74099	88,92916	164,3691
Sep 2020	20,30723	46,19407	34,80609	77,15257	134,7731
Okt 2020	20,58694	44,86538	34,18172	74,66135	113,0481
Nov 2020	24,37273	42,06119	29,62956	64,43652	97,93973
Des 2020	7,445921	36,64889	28,43255	63,02817	82,80835
Jan 2021	35,40446	54,48287	45,21513	99,11902	177,8213
Feb 2021	13,94876	41,54249	35,92606	76,65112	125,9486
Mar 2021	9,604751	43,45933	37,31939	80,98673	121,8467
Apr 2021	7,158187	41,8442	35,10954	74,37993	110,0525
Mei 2021	33,12238	50,60931	55,74993	133,1506	296,5743
Juni 2021	37,55199	56,82106	51,9714	110,7807	202,5746
Juli 2021	17,97768	42,78484	36,42038	90,08881	144,099
Agt 2021	31,17063	50,28459	36,37143	91,50889	164,3818
Sep 2021	17,31527	46,73964	37,43654	79,7323	134,7858
Okt 2021	17,59498	45,41094	36,81216	77,24108	113,0608
Nov 2021	21,38076	42,60676	32,26001	67,01625	97,95241
Des 2021	4,453961	37,19446	31,06299	65,6079	82,82103

**Lampiran 8.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-ERNN  
(Miliar Rp) (lanjutan)

Periode	<i>Outflow</i> Rp100.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	1680,969	1783,22	1042,589	2350,94	12418,39
Agt 2019	2363,578	2346,911	1343,686	2835,212	8953,648
Sep 2019	2228,706	2212,021	1381,347	2863,398	11525,58
Okt 2019	2170,892	2154,225	1293,863	2878,542	12093,81
Nov 2019	2208,107	2191,439	1245,827	2944,273	12165,06
Des 2019	2831,135	2814,468	1440,484	3575,803	14677,84
Jan 2020	1981,428	1964,76	1151,311	2775,714	10753,54
Feb 2020	2149,964	2133,297	1241,447	3013,968	11500,13
Mar 2020	2399,392	2382,725	1298,752	3160,576	12549,27
Apr 2020	2537,353	2520,686	1381,194	3321,772	12847,72
Mei 2020	3597,332	3580,665	1955,707	4907,793	18115,21
Juni 2020	2643,118	2626,451	1529,41	3614,529	13711,2
Juli 2020	2555,138	2538,471	1475,199	3455,334	13365,23
Agt 2020	2561,555	2544,888	1465,416	3145,912	12558,78
Sep 2020	2426,667	2410	1503,077	3174,325	12472,42
Okt 2020	2368,869	2352,202	1415,593	3189,243	13040,64
Nov 2020	2406,083	2389,416	1367,558	3254,973	13111,9
Des 2020	3029,112	3012,445	1562,214	3886,504	15624,69
Jan 2021	2179,404	2162,737	1273,041	3086,415	11700,39
Feb 2021	2347,941	2331,274	1363,178	3324,668	12446,98
Mar 2021	2597,369	2580,702	1420,483	3471,277	13496,12
Apr 2021	3103,814	3087,147	1758,529	4173,165	15467,28
Mei 2021	2943,738	2927,071	1670,471	4139,131	14882,98
Juni 2021	2841,094	2824,427	1651,14	3925,23	14658,05
Juli 2021	2753,115	2736,447	1596,929	3766,034	14312,08
Agt 2021	2759,532	2742,865	1587,146	3456,613	13505,63
Sep 2021	2624,644	2607,976	1624,808	3485,026	13419,27
Okt 2021	2566,845	2550,178	1537,324	3499,943	13987,48
Nov 2021	2604,06	2587,393	1489,288	3565,674	14058,75
Des 2021	3227,088	3210,421	1683,945	4197,204	16571,53

**Lampiran 8.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-ERNN  
(Miliar Rp) (lanjutan)

Periode	<i>Outflow</i> Rp50.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	1325,913	730,7344	718,8151	891,7109	8073,368
Agt 2019	946,2733	942,2488	476,89	1169,048	5726,731
Sep 2019	1239,056	939,5533	666,9166	1165,361	7490,532
Okt 2019	1227,641	882,3198	635,1675	1177,564	7675,612
Nov 2019	1267,35	894,7041	624,6839	1154,883	8001,201
Des 2019	1604,39	1084,574	760,8355	1455,462	10076,18
Jan 2020	1006,755	835,7179	576,2052	1081,651	6928,944
Feb 2020	1206,176	935,2922	650,5862	1201,407	7588,984
Mar 2020	1385,857	1014,948	701,1987	1358,698	8638,881
Apr 2020	1391,144	1017,812	746,6984	1393,121	8333,801
Mei 2020	2540,49	1755,16	1156,069	2491,16	12533,15
Juni 2020	1564,102	1169,646	802,0019	1519,333	8873,156
Juli 2020	1405,77	1098,304	774,5703	1411,508	8672,382
Agt 2020	1480,256	1022,456	728,2812	1257,33	8136,708
Sep 2020	1318,913	1021,696	722,6718	1253,622	8089,546
Okt 2020	1307,499	962,5268	690,9227	1265,846	8274,762
Nov 2020	1347,207	974,9111	680,4391	1243,165	8600,214
Des 2020	1684,247	1164,781	816,5907	1543,744	10675,19
Jan 2021	1086,612	915,925	631,9604	1169,933	7527,957
Feb 2021	1286,033	1015,499	706,3414	1289,689	8187,997
Mar 2021	1465,714	1095,155	756,9539	1446,98	9237,894
Apr 2021	1901,836	1433,522	929,4529	1801,383	11886,79
Mei 2021	2186,971	1528,28	1001,181	1821,866	11975,16
Juni 2021	1643,959	1249,853	857,7571	1607,615	9472,169
Juli 2021	1485,627	1178,512	830,3255	1499,789	9271,395
Agt 2021	1560,113	1102,663	784,0364	1345,612	8735,722
Sep 2021	1398,77	1101,903	778,4271	1341,904	8688,559
Okt 2021	1387,356	1042,734	746,6779	1354,128	8873,776
Nov 2021	1427,064	1055,118	736,1943	1331,447	9199,228
Des 2021	1764,104	1244,988	872,346	1632,026	11274,21

**Lampiran 8.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-ERNN  
(Miliar Rp) (lanjutan)

Periode	<i>Outflow</i> Rp20.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	67,57101	54,0842	33,93409	82,35759	68,23879
Agt 2019	57,70525	47,6423	26,92352	63,01068	212,7972
Sep 2019	21,10715	36,13339	19,97527	51,92843	140,61
Okt 2019	10,83439	28,32723	14,04678	44,3192	134,8809
Nov 2019	13,52204	27,59804	14,97804	52,24918	88,84925
Des 2019	34,76122	39,78719	19,44909	72,10723	240,4105
Jan 2020	39,09693	38,15942	19,53925	68,00588	239,5207
Feb 2020	44,07046	43,64947	22,72388	68,50582	194,5501
Mar 2020	44,7029	50,6102	26,8752	77,88431	225,1685
Apr 2020	127,7685	86,19143	42,93462	115,8699	672,9152
Mei 2020	260,3417	193,8894	110,8243	245,6074	791,8854
Juni 2020	111,7123	73,98098	45,13403	111,2991	294,9016
Juli 2020	70,8955	62,25431	35,31526	88,01041	308,1527
Agt 2020	60,4836	50,13745	28,30469	68,66349	219,2393
Sep 2020	23,8855	38,62854	21,35644	57,58124	147,052
Okt 2020	13,61274	30,82238	15,42794	49,97202	141,3229
Nov 2020	16,30039	30,09318	16,3592	57,902	95,29131
Des 2020	37,53957	42,28233	20,83026	77,76004	246,8525
Jan 2021	41,87528	40,65456	20,92042	73,65869	245,9628
Feb 2021	46,84881	46,14462	24,10505	74,15864	200,9922
Mar 2021	47,48125	53,10535	28,25637	83,53712	231,6106
Apr 2021	189,1656	120,2283	63,00022	154,0457	766,6622
Mei 2021	112,4979	77,41932	44,26021	117,277	431,3818
Juni 2021	114,4907	76,47613	46,5152	116,9519	301,3436
Juli 2021	73,67385	64,74946	36,69643	93,66323	314,5948
Agt 2021	63,26195	52,63259	29,68586	74,31631	225,6813
Sep 2021	26,66385	41,12369	22,73761	63,23406	153,4941
Okt 2021	16,39109	33,31752	16,80911	55,62483	147,765
Nov 2021	19,07874	32,58833	17,74037	63,55482	101,7334
Des 2021	40,31793	44,77748	22,21143	83,41286	253,2946

**Lampiran 9.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-JRNN  
(Miliar Rp)

Periode	<i>Inflow</i> Rp100.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	1909,272	2302,048	1604,898	5613,372	6385,06
Agt 2019	1737,566	1990,693	1545,115	5134,092	7426,498
Sep 2019	1440,501	1677,486	1378,911	4899,747	6837,185
Okt 2019	1652,937	1922,857	1495,307	4961,861	6880,033
Nov 2019	1373,939	1789,525	1422,346	4801,478	6264,16
Des 2019	1198,093	1544,058	1344,021	4559,385	5722,612
Jan 2020	2025,561	2237,076	1695,332	5457,82	8286,35
Feb 2020	1591,511	1994,076	1521,656	5043,253	7211,809
Mar 2020	1482,929	2295,673	1537,575	5120,858	7116,943
Apr 2020	1483,34	2382,266	1528,216	5074,742	6990,883
Mei 2020	1156,529	1984,835	1370,265	4672,694	6269,082
Juni 2020	3359,772	3913,227	2124,677	7215,059	11328,14
Juli 2020	2384,593	2769,975	1750,757	6075,557	7945,031
Agt 2020	2344,331	2607,643	1691,029	6126,913	7965,597
Sep 2020	2047,267	2294,435	1524,825	5892,568	7376,284
Okt 2020	2259,702	2539,807	1641,221	5954,683	7419,132
Nov 2020	1980,705	2406,472	1568,26	5794,3	6803,259
Des 2020	1804,859	2160,878	1489,935	5552,207	6261,711
Jan 2021	2632,326	2850,245	1841,246	6450,641	8825,449
Feb 2021	2198,277	2563,668	1667,57	6036,074	7750,908
Mar 2021	2089,685	2582,243	1683,489	6113,573	7656,042
Apr 2021	2089,636	2580,847	1674,13	6063,941	7529,982
Mei 2021	2960,707	3408,679	2098,449	6867,225	10514,72
Juni 2021	2198,226	2644,225	1748,318	6368,229	7813,753
Juli 2021	2542,675	2968,555	1896,671	6597,184	8484,13
Agt 2021	2490,529	2806,223	1836,943	6648,539	8504,695
Sep 2021	2193,464	2493,016	1670,739	6414,194	7915,382
Okt 2021	2405,9	2738,387	1787,135	6476,309	7958,231
Nov 2021	2126,902	2605,052	1714,174	6315,925	7342,358
Des 2021	1951,056	2359,459	1635,849	6073,832	6800,81

**Lampiran 9.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-JRNN  
(Miliar Rp) (lanjutan)

Periode	<i>Inflow Rp50.000</i>				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	1087,857	1201,892	804,9377	3189,527	4755,688
Agt 2019	942,6762	1227,325	770,6215	3073,649	4450,476
Sep 2019	836,1255	1074,32	718,6316	2958,146	3482,195
Okt 2019	985,983	1173,251	740,983	3006,094	3500,969
Nov 2019	793,333	1141,402	696,2705	2878,304	2969,07
Des 2019	661,5083	946,9809	662,2279	2668,071	2755,737
Jan 2020	1092,322	1393,292	868,1195	3275,892	4520,929
Feb 2020	828,091	1159,125	744,8117	3005,265	3587,911
Mar 2020	757,3879	1194,475	763,713	3065,767	4002,324
Apr 2020	785,8383	1224,703	759,031	3031,13	4288,801
Mei 2020	567,8526	881,1635	612,169	2724,961	3210,948
Juni 2020	1849,051	2086,328	1140,803	4185,966	6705,726
Juli 2020	972,926	1328,482	870,5835	3311,99	4729,915
Agt 2020	956,0563	1294,933	832,1419	3306,309	4698,842
Sep 2020	849,5056	1136,915	780,1477	3190,805	4487,191
Okt 2020	999,3632	1235,847	802,4991	3238,753	4506,012
Nov 2020	806,7131	1203,998	757,7866	3110,964	3974,113
Des 2020	674,8884	1009,576	723,744	2900,73	3760,759
Jan 2021	1105,702	1455,887	929,6356	3508,552	5524,392
Feb 2021	841,4711	1221,72	806,3278	3237,925	4552,684
Mar 2021	770,768	1257,071	825,2291	3298,427	4592,328
Apr 2021	799,2184	1287,298	820,5472	3263,789	4537,263
Mei 2021	1554,231	1758,067	1176,241	3852,609	7312,27
Juni 2021	925,8056	1402,11	942,247	3581,777	5169,483
Juli 2021	986,3061	1391,078	932,0996	3544,649	4978,281
Agt 2021	969,4365	1357,529	893,6581	3538,968	4947,209
Sep 2021	862,8857	1199,511	841,6638	3423,465	4735,557
Okt 2021	1012,743	1298,442	864,0152	3471,413	4754,379
Nov 2021	820,0933	1266,593	819,3027	3343,623	4222,48
Des 2021	688,2685	1072,172	785,2601	3133,39	4009,125

**Lampiran 9.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-JRNN  
(Miliar Rp) (lanjutan)

Periode	<i>Inflow Rp20.000</i>				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	69,45744	69,92065	44,22661	108,1734	236,4062
Agt 2019	37,15032	49,25852	31,14749	86,54822	164,8286
Sep 2019	23,29496	45,71356	32,21259	74,77163	135,2326
Okt 2019	23,57467	44,38487	31,58821	72,28041	113,5076
Nov 2019	27,36046	41,58068	27,03606	62,05558	98,39921
Des 2019	10,43365	36,16838	25,83904	60,64723	83,26783
Jan 2020	38,39219	54,00237	42,62163	96,73808	178,2808
Feb 2020	16,93649	41,06199	33,33256	74,27018	126,4081
Mar 2020	12,59248	42,97883	34,72589	78,60579	122,3061
Apr 2020	10,14592	41,3637	32,51604	71,99899	110,512
Mei 2020	1,428364	17,38758	19,23152	38,57789	48,49846
Juni 2020	90,62218	103,2142	70,5737	167,0623	337,4172
Juli 2020	20,96541	42,30433	33,82688	87,70787	144,5584
Agt 2020	34,15836	49,80408	33,77793	89,12794	164,8413
Sep 2020	20,303	46,25913	34,84304	77,35136	135,2453
Okt 2020	20,58271	44,93044	34,21866	74,86013	113,5203
Nov 2020	24,3685	42,12625	29,66651	64,63531	98,41189
Des 2020	7,441692	36,71395	28,46949	63,22696	83,28051
Jan 2021	35,40023	54,54794	45,25208	99,3178	178,2935
Feb 2021	13,94453	41,60755	35,963	76,8499	126,4208
Mar 2021	9,600522	43,52439	37,35634	81,18551	122,3188
Apr 2021	7,153958	41,90927	35,14649	74,57871	110,5247
Mei 2021	33,11815	50,67437	55,78688	133,3494	297,0465
Juni 2021	37,54776	56,88612	52,00835	110,9795	203,0467
Juli 2021	17,97345	42,8499	36,45733	90,2876	144,5711
Agt 2021	31,1664	50,34965	36,40838	91,70767	164,8539
Sep 2021	17,31104	46,8047	37,47348	79,93108	135,2579
Okt 2021	17,59075	45,47601	36,84911	77,43986	113,5329
Nov 2021	21,37654	42,67182	32,29695	67,21504	98,42457
Des 2021	4,449731	37,25952	31,09994	65,80668	83,29319

**Lampiran 9.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-JRNN  
(Miliar Rp) (lanjutan)

Periode	<i>Outflow</i> Rp100.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	1812,705	2340,592	1719,197	2505,478	12417,87
Agt 2019	2363,961	2873,243	1343,602	2835,419	9470,413
Sep 2019	2229,074	2212,121	1381,263	2818,297	11525,06
Okt 2019	2171,275	2154,323	1293,779	2878,75	12093,93
Nov 2019	2208,49	2191,537	1245,743	2944,48	12164,54
Des 2019	2831,518	2814,566	1440,4	3576,011	14677,32
Jan 2020	1981,811	1964,858	1151,227	2775,922	10753,02
Feb 2020	2150,347	2133,395	1241,364	3014,175	11499,61
Mar 2020	2399,775	2382,823	1298,669	3160,784	12548,75
Apr 2020	2537,736	2520,784	1381,11	3321,979	12847,2
Mei 2020	3597,716	3580,763	1955,623	4908	18114,69
Juni 2020	2643,501	2626,549	1529,326	3614,737	13710,68
Juli 2020	2555,521	2538,569	1475,115	3455,541	13364,72
Agt 2020	2561,938	2544,986	1465,332	3146,12	12558,27
Sep 2020	2427,05	2410,098	1502,993	3174,533	12471,91
Okt 2020	2369,252	2352,3	1415,51	3189,45	13040,12
Nov 2020	2406,467	2389,514	1367,474	3255,181	13111,38
Des 2020	3029,495	3012,543	1562,13	3886,711	15624,17
Jan 2021	2179,788	2162,835	1272,958	3086,622	11699,87
Feb 2021	2348,324	2331,372	1363,094	3324,875	12446,46
Mar 2021	2597,752	2580,8	1420,399	3471,484	13495,6
Apr 2021	3104,197	3087,245	1758,445	4173,372	15466,76
Mei 2021	2944,121	2927,169	1670,387	4139,338	14882,46
Juni 2021	2841,478	2824,525	1651,056	3925,437	14657,53
Juli 2021	2753,498	2736,546	1596,846	3766,242	14311,56
Agt 2021	2759,915	2742,963	1587,063	3456,82	13505,11
Sep 2021	2625,027	2608,074	1624,724	3485,233	13418,75
Okt 2021	2567,229	2550,276	1537,24	3500,15	13986,96
Nov 2021	2604,443	2587,491	1489,204	3565,881	14058,23
Des 2021	3227,472	3210,519	1683,861	4197,411	16571,01

**Lampiran 9.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-JRNN  
(Miliar Rp) (lanjutan)

Periode	<i>Outflow</i> Rp50.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	960,3128	786,7127	947,9724	975,7685	8074,299
Agt 2019	1400,827	942,3333	672,4979	1169,185	6080,103
Sep 2019	1239,493	941,5836	666,8886	1165,442	7491,463
Okt 2019	1228,07	882,4042	635,1395	1177,701	7676,691
Nov 2019	1267,779	894,7885	624,6559	1155,02	8002,131
Des 2019	1604,819	1084,659	760,8075	1455,599	10077,11
Jan 2020	1007,184	835,8024	576,1772	1081,788	6929,874
Feb 2020	1206,605	935,3766	650,5582	1201,544	7589,914
Mar 2020	1386,286	1015,033	701,1707	1358,835	8639,811
Apr 2020	1391,573	1017,896	746,6704	1393,258	8334,732
Mei 2020	2540,919	1755,245	1156,041	2491,297	12534,08
Juni 2020	1564,531	1169,73	801,9739	1519,47	8874,086
Juli 2020	1406,199	1098,389	774,5423	1411,644	8673,312
Agt 2020	1480,685	1022,54	728,2532	1257,467	8137,639
Sep 2020	1319,342	1021,78	722,6438	1253,758	8090,476
Okt 2020	1307,928	962,6113	690,8947	1265,983	8275,693
Nov 2020	1347,636	974,9956	680,4111	1243,302	8601,145
Des 2020	1684,676	1164,866	816,5627	1543,881	10676,12
Jan 2021	1087,041	916,0094	631,9324	1170,07	7528,888
Feb 2021	1286,462	1015,584	706,3134	1289,826	8188,928
Mar 2021	1466,143	1095,24	756,9259	1447,117	9238,825
Apr 2021	1902,265	1433,606	929,4249	1801,52	11887,72
Mei 2021	2187,4	1528,364	1001,153	1822,003	11976,09
Juni 2021	1644,388	1249,937	857,7291	1607,752	9473,1
Juli 2021	1486,056	1178,596	830,2975	1499,926	9272,326
Agt 2021	1560,542	1102,747	784,0084	1345,749	8736,652
Sep 2021	1399,199	1101,987	778,3991	1342,04	8689,49
Okt 2021	1387,785	1042,818	746,6499	1354,265	8874,706
Nov 2021	1427,493	1055,203	736,1663	1331,584	9200,158
Des 2021	1764,533	1245,073	872,318	1632,163	11275,14

**Lampiran 9.** Hasil Ramalan *Inflow* dan *Outflow* Model MGSTARX-JRNN  
(Miliar Rp) (lanjutan)

Periode	<i>Outflow</i> Rp20.000				
	Surabaya	Semarang	Yogyakarta	Bandung	Jakarta
Juli 2019	68,13527	59,77299	33,92924	82,41299	301,691
Agt 2019	57,72337	47,65612	26,91867	63,06608	212,7775
Sep 2019	21,12527	36,14722	19,97042	51,98383	140,5903
Okt 2019	10,85251	28,34106	14,04193	44,3746	134,8612
Nov 2019	13,54016	27,61186	14,97318	52,30458	88,82955
Des 2019	34,77934	39,80101	19,44424	72,16263	240,3908
Jan 2020	39,11505	38,17324	19,5344	68,06128	239,501
Feb 2020	44,08858	43,6633	22,71903	68,56123	194,5304
Mar 2020	44,72102	50,62402	26,87035	77,93971	225,1488
Apr 2020	127,7866	86,20526	42,92977	115,9253	672,8955
Mei 2020	260,3598	193,9032	110,8194	245,6628	791,8657
Juni 2020	111,7304	73,99481	45,12918	111,3545	294,8819
Juli 2020	70,91362	62,26814	35,31041	88,06581	308,133
Agt 2020	60,50172	50,15127	28,29984	68,7189	219,2196
Sep 2020	23,90362	38,64236	21,35159	57,63664	147,0323
Okt 2020	13,63086	30,8362	15,42309	50,02742	141,3032
Nov 2020	16,31851	30,10701	16,35435	57,9574	95,27161
Des 2020	37,55769	42,29615	20,82541	77,81545	246,8328
Jan 2021	41,8934	40,66839	20,91557	73,7141	245,9431
Feb 2021	46,86693	46,15844	24,1002	74,21404	200,9725
Mar 2021	47,49937	53,11917	28,25152	83,59253	231,5909
Apr 2021	189,1838	120,2421	62,99537	154,1011	766,6425
Mei 2021	112,516	77,43315	44,25536	117,3324	431,3621
Juni 2021	114,5088	76,48995	46,51035	117,0073	301,3239
Juli 2021	73,69197	64,76328	36,69158	93,71863	314,5751
Agt 2021	63,28007	52,64641	29,68101	74,37171	225,6616
Sep 2021	26,68197	41,13751	22,73276	63,28946	153,4744
Okt 2021	16,40921	33,33135	16,80426	55,68024	147,7453
Nov 2021	19,09686	32,60215	17,73552	63,61022	101,7137
Des 2021	40,33605	44,7913	22,20658	83,46826	253,2749

*Halaman ini sengaja dikosongkan*

## **SURAT PERNYATAAN**

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FMKSD ITS:

Nama : Vania Orva Nur Laily

NRP : 06211850010005

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 Sentral

Keterangan : Data *Inflow* dan *Outflow* di Kantor Bank Sentral wilayah Surabaya, Semarang, Yogyakarta, Bandung, dan Jakarta

Surat pernyataan ini dibuat dengan sebenarnya. Apabila terdapat permalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Surabaya, 18 Agustus 2020

Mengetahui,

Pembimbing Tesis



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

Mahasiswa



Vania Orva Nurlaily  
NRP. 06211850010005

*Halaman ini sengaja dikosongkan*

## **BIODATA PENULIS**



Penulis memiliki nama lengkap Vania Orva Nur Laily dilahirkan di Kediri pada 10 Agustus 1995. Penulis menempuh pendidikan formal di SDI Al-Huda pada tahun 2002-2008, kemudian melanjutkan pendidikan di MTsN Kediri 2 pada tahun 2008-2011, dan melanjutkan pendidikan di MAN 3 Kota Kediri pada tahun 2011-2013. Pada tahun 2013 penulis melanjutkan studi Sarjana di Departemen Statistika Universitas Diponegoro (UNDIP) Semarang dan lulus pada tahun 2017. Penulis berkesempatan untuk melanjutkan studi program Magister Statistika di Institut Teknologi Statistika pada Tahun 2018. Apabila pembaca ingin memberi kritik dan saran serta diskusi lebih lanjut mengenai Tesis ini, dapat menghubungi penulis melalui email [vaniaorva@gmail.com](mailto:vaniaorva@gmail.com).

*Halaman ini sengaja dikosongkan*