



TUGAS AKHIR - KS184822

**PENERAPAN MODEL HIBRIDA ARIMAX-DEEP
NEURAL NETWORK UNTUK PERAMALAN
INFLOW DAN OUTFLOW UANG KARTAL DI
JAWA TIMUR**

**JEMIMA ARISTA PUTRI
NRP 062116 4000 0022**

**Dosen Pembimbing
Dr. Suhartono, S.Si., M.Sc.**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS SAINS DAN ANALITIKA DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2020**

(Halaman ini sengaja dikosongkan)



TUGAS AKHIR - KS184822

PENERAPAN MODEL HIBRIDA ARIMAX-*DEEP NEURAL NETWORK* UNTUK PERAMALAN *INFLOW* DAN *OUTFLOW* UANG KARTAL DI JAWA TIMUR

**JEMIMA ARISTA PUTRI
NRP 062116 4000 0022**

**Dosen Pembimbing
Dr. Suhartono, S.Si., M.Sc.**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS SAINS DAN ANALITIKA DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2020**

(Halaman ini sengaja dikosongkan)



FINAL PROJECT - KS184822

**HYBRID ARIMAX-DEEP NEURAL NETWORK FOR
FORECASTING INFLOW AND OUTFLOW OF
CURRENCY IN EAST JAVA**

**JEMIMA ARISTA PUTRI
SN 062116 4000 0022**

**Supervisor
Dr. Suhartono, S.Si., M.Sc.**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF SCIENCE AND DATA ANALYTICS
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2020**

•

(Halaman ini sengaja dikosongkan)

LEMBAR PENGESAHAN

**PENERAPAN MODEL HIBRIDA ARIMAX-DEEP
NEURAL NETWORK UNTUK PERAMALAN INFLOW
DAN OUTFLOW UANG KARTAL DI JAWA TIMUR**

TUGAS AKHIR

Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Statistika
pada
Program Studi Sarjana Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember

Oleh:

Jemima Arista Putri
NRP. 062116 4000 0022

Disetujui oleh Pembimbing:
Dr. Suhartono, S.Si., M.Sc.
NIP. 19710929-199512 1 001

()



Mengetahui,
Kepala Departemen Statistika

Dr. Dra. Kartika Fithriasari, M.Si
NIP. 19691212 199303 2 002

SURABAYA, Juni 2020

(Halaman ini sengaja dikosongkan)

PENERAPAN MODEL HIBRIDA ARIMAX-DEEP NEURAL NETWORK UNTUK PERAMALAN INFLOW DAN OUTFLOW UANG KARTAL DI JAWA TIMUR

Nama Mahasiswa : Jemima Arista Putri
NRP : 062116 4000 0022
Departemen : Statistika-FSAD-ITS
Dosen Pembimbing : Dr. Suhartono, S.Si., M.Sc.

Abstrak

ARIMAX merupakan pengembangan model ARIMA dimana terdapat tambahan variabel eksogen sehingga dapat dilakukan regresi berganda, sedangkan Deep Neural Network (DNN) merupakan pengembangan dari NN dimana terdapat dua hidden layer yang diharapkan mampu mengenali proses lebih kompleks. Model ARIMAX memiliki kemampuan yang baik dalam menangkap pola linier dan DNN baik dalam menangkap pola non-linier dari data. Untuk meningkatkan akurasi peramalan, ARIMAX dikombinasikan secara series dengan DNN yakni dikenal dengan Hibrida ARIMAX-DNN. Penelitian ini bertujuan untuk mendapatkan model peramalan terbaik yang mengandung tren, musiman dan variasi kalender pada inflow dan outflow di KPw Jember, KPw Kediri, KPw Malang dan KPw Surabaya. Pemilihan metode terbaik yaitu berdasarkan nilai RMSE dan sMAPE terkecil diantara ARIMAX, DNN dan Hibrida ARIMAX-DNN. Terdapat 8 variabel untuk masing-masing inflow dan outflow yang terdiri dari total uang kertas, pecahan Rp100.000, Rp50.000, Rp20.000, Rp10.000, Rp5.000, Rp2.000 dan Rp1.000 dari Januari 2010 hingga Juni 2018. Hasil penelitian menunjukkan bahwa metode Hibrida ARIMAX-DNN merupakan metode terbaik yang terbanyak untuk meramalkan inflow dan outflow yaitu sebanyak 32 pecahan. Metode DNN baik untuk meramalkan 26 pecahan, sedangkan metode ARIMAX hanya baik digunakan untuk meramalkan 6 pecahan uang kertas. Sehingga dapat disimpulkan bahwa metode hibrida dan non-linier cenderung lebih baik untuk memodelkan inflow maupun outflow pecahan uang kertas yang ada di Jawa Timur.

Kata Kunci : ARIMAX, Deep Neural Network, Hibrida, Inflow, Jawa Timur, Outflow.

(Halaman ini sengaja dikosongkan)

HYBRID ARIMAX-DEEP NEURAL NETWORK MODEL FOR FORECASTING INFLOW AND OUTFLOW OF CURRENCY IN EAST JAVA

Name : Jemima Arista Putri
Student Number : 062116 4000 0022
Department : Statistics-FSAD-ITS
Supervisor : Dr. Suhartono, S.Si., M.Sc.

Abstract

ARIMA model is developed into ARIMAX model with additional exogenous variables and can performed multiple regression, while Deep Neural Network (DNN) is developed from NN with two hidden layer which is expected to be able to recognize more complex processes. ARIMAX model has a good capabilities to capture linear pattern and DNN is better to capture non-linear pattern of the data. To improve the accuracy of forecasting result, ARIMAX will combine with DNN namely Hybrid ARIMAX-DNN. The aim of this study is to find the best model that consist trend, seasonal and calendar variation pattern for forecasting inflow and outflow in KPw Jember, KPw Kediri, KPw Malang and KPw Surabaya. The best model of each banknotes denomination based on the smallest value of RMSE and sMAPE from ARIMAX, DNN and Hybrid ARIMAX-DNN. There are 8 variables for each inflow and outflow series denominations, i.e. total banknotes, Rp100.000, Rp50.000, Rp20.000, Rp10.000, Rp5.000, Rp2.000 and Rp1.000 from January 2010 until June 2019. The result showed that Hybrid ARIMAX-DNN method is the best method for predicting inflow and outflow on 32 banknotes denomination. The DNN good for predicting on 26 banknotes denomination, but the ARIMAX method is only good for predicting 6 banknotes. So it can be concluded that hybrid and non-linear methods provided more accurate for modeling the inflow and outflow of banknotes in East Java.

Keywords: *ARIMAX, Deep Neural Network, East Java, Hybrid, Inflow, Outflow.*

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji Syukur penulis panjatkan atas berkat, rahmat, dan karunia yang telah diberikan Allah SWT sehingga penulis dapat menyelesaikan Laporan Tugas Akhir ini yang berjudul **“Penerapan Model Hibrida ARIMAX-Deep Neural Network Untuk Peramalan *Inflow* Dan *Outflow* Uang Kartal Di Jawa Timur”** dengan tepat waktu.

Penulis menyadari dalam penyusunan Tugas Akhir ini tidak akan selesai tanpa bantuan maupun dukungan dari berbagai pihak. Pada kesempatan ini penulis menyampaikan terima kasih kepada:

1. Bunda Yuli Suwanti, Rama Dino Aristo, Adik Gabriella Tara Diva dan Adik Lady Khansa Haifa selaku keluarga penulis yang selalu memberikan doa dan dukungan selama penyusunan Tugas Akhir.
2. Dr. Suhartono, S.Si., M.Sc. selaku dosen pembimbing yang telah memberikan bimbingan, saran, serta motivasi selama penyusunan Tugas Akhir berlangsung.
3. Dr. Ir. Setiawan, M.S. dan Dr. rer. pol. Dedy Dwi Prastyo, S.Si., M.Si. selaku dosen penguji yang telah memberikan masukan dan bantuan dalam menyelesaikan Tugas Akhir.
4. Dr. Madu Ratna, M.Si selaku dosen wali yang telah banyak memberikan saran dan arahan dalam proses belajar selama ini di Departemen Statistika.
5. Dr. Dra. Kartika Fithriarsari M.Si selaku Kepala Departemen Statistika dan Vita Ratnasari, S.Si., M.Si dan Dr. Santi Wulan Purnami, S.Si., M.Si. selaku Sekretaris Departemen Statistika FSAD ITS.
6. Endah Setiyowati, M.Si yang telah banyak membantu berdiskusi bersama saat pengerjaan Tugas Akhir.

7. Sahabat penulis yaitu Khalim, Naila, Wawa, Vera, Kicky, Rivi dan Widya yang selalu memberikan support dan semangat dalam penyusunan Tugas Akhir.
8. Teman-teman seperjuangan TA khususnya Zevira dan Ajeng sebagai teman diskusi serta teman-teman TR16GER lainnya yang selalu memberikan semangat kepada penulis dalam penyusunan Tugas Akhir.
9. Seluruh pihak yang turut membantu dalam penyelesaian laporan Tugas Akhir ini baik secara langsung maupun tidak langsung.

Penulis menyadari masih banyak kekurangan dalam pembuatan laporan Tugas Akhir ini. Penulis berharap semoga laporan Tugas Akhir ini dapat bermanfaat dan menambah wawasan bagi pembaca. Kritik dan saran sangat diperlukan untuk perbaikan di masa yang akan datang.

Surabaya, Juni 2020

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGESAHAN	vii
ABSTRAK	ix
KATA PENGANTAR	xiii
DAFTAR ISI	xv
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xxi
DAFTAR LAMPIRAN	xxv
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	6
1.3 Tujuan Penelitian.....	7
1.4 Manfaat Penelitian.....	7
1.5 Batasan Masalah	7
BAB II TINJAUAN PUSTAKA	9
2.1 Analisis Deret Waktu.....	9
2.2 Regresi <i>Time Series</i>	9
2.3 ACF dan PACF.....	10
2.4 <i>Autoregressive Intergrated Moving Average</i> (ARIMA)	11
2.4.1 Identifikasi Model.....	14
2.4.2 Estimasi dan Pengujian Parameter.....	15
2.4.3 Cek Diagnosa.....	17
2.5 <i>Autoregressive Intergrated Moving Average with</i> <i>Exogeneous Variable (ARIMAX)</i>	19
2.6 Uji Linieritas.....	19
2.7 <i>Neural Network</i>	20
2.8 <i>Deep Neural Network</i>	23
2.9 Hibrida ARIMAX-DNN	29
2.10 Evaluasi Model	31
2.11 Uang Kartal.....	32

BAB III METODOLOGI PENELITIAN.....	33
3.1 Sumber Data	33
3.2 Variabel Penelitian.....	33
3.3 Langkah Analisis	35
3.4 Diagram Alir Penelitian.....	38
BAB IV ANALISIS DAN PEMBAHASAN.....	45
4.1 Karakteristik <i>Inflow</i> dan <i>Outflow</i> di Provinsi Jawa Timur	45
4.2 Pemodelan <i>Inflow</i> dan <i>Outflow</i> dengan ARIMAX di Provinsi Jawa Timur	62
4.3 Pemodelan <i>Inflow</i> dan <i>Outflow</i> dengan <i>Deep Neural Network</i> di Provinsi Jawa Timur	74
4.4 Pemodelan <i>Inflow</i> dan <i>Outflow</i> dengan Hibrida ARIMAX- <i>Deep Neural Network</i> di Provinsi Jawa Timur	85
4.5 Perbandingan Hasil Peramalan <i>Inflow</i> dan <i>Outflow</i> di Provinsi Jawa Timur	92
4.6 Peramalan <i>Inflow</i> dan <i>Outflow</i> di Provinsi Jawa Timur	118
BAB V KESIMPULAN DAN SARAN.....	127
5.1 Kesimpulan	127
5.2 Saran	127
DAFTAR PUSTAKA	129
LAMPIRAN	134
BIODATA PENULIS	239

DAFTAR GAMBAR

Gambar 2.1	Arsitektur <i>Neural Network</i>	22
Gambar 2.2	Arsitektur <i>Deep Neural Network</i>	23
Gambar 3.1	Diagram Alir Penelitian	38
Gambar 3.2	Diagram Alir ARIMAX.....	39
Gambar 3.3	Diagram Alir <i>Deep Neural Network</i>	40
Gambar 3.4	Proses ARIMAX.....	41
Gambar 3.5	Proses <i>Deep Neural Network</i>	42
Gambar 3.6	Proses Hibrida Series ARIMAX-DNN	43
Gambar 4.1	Plot <i>Time Series Inflow</i> dan <i>Outflow</i> Total Uang Kertas di (a)KPw Jember, (b)KPw Kediri, (c)KPw Malang dan (d)KPw Surabaya.....	46
Gambar 4.2	Rata-Rata <i>Inflow</i> dan <i>Outflow</i> Total Uang Kertas dalam Bulan di (a)KPw Jember, (b) KPw Kediri, (c)KPw Malang dan (d)KPw Surabaya	47
Gambar 4.3	Rata-Rata <i>Inflow</i> Total Uang Kertas Menurut Minggu Idul Fitri di (a)KPw Jember, (b)KPw Kediri, (c)KPw Malang dan (d)KPw Surabaya.....	49
Gambar 4.4	Rata-Rata <i>Outflow</i> Total Uang Kertas Menurut Minggu Idul Fitri di (a)KPw Jember, (b)KPw Kediri, (c)KPw Malang dan (d)KPw Surabaya.....	52
Gambar 4.5	Plot <i>Time Series</i> (a) <i>Inflow</i> dan (b) <i>Outflow</i> di KPw Jember.....	55
Gambar 4.6	Plot <i>Time Series</i> (a) <i>Inflow</i> dan (b) <i>Outflow</i> di KPw Kediri.....	57
Gambar 4.7	Plot <i>Time Series</i> (a) <i>Inflow</i> dan (b) <i>Outflow</i> di KPw Malang.....	59
Gambar 4.8	Plot <i>Time Series</i> (a) <i>Inflow</i> dan (b) <i>Outflow</i> di KPw Surabaya	61

Gambar 4.9	ACF dan PACF Residual Regresi <i>Time Series Inflow</i> Rp50.000 di KPw Jember	64
Gambar 4.10	Perbandingan Hasil Ramalan ARIMAX <i>Inflow</i> Rp50.000 di KPw Jember	67
Gambar 4.11	<i>Time Series Plot Inflow</i> (a)Data Asli dan (b)Data Stasioner	74
Gambar 4.12	Plot PACF <i>Inflow</i> Rp50.000 di KPw Jember.....	75
Gambar 4.13	RMSE dan sMAPE DNN <i>Inflow</i> Rp50.000 di KPw Jember.....	76
Gambar 4.14	Arsitektur DNN <i>Inflow</i> Rp50.000 di KPw Jember.....	76
Gambar 4.15	Perbandingan Hasil Ramalan DNN <i>Inflow</i> Rp50.000 di KPw Jember	79
Gambar 4.16	Lag PACF Residual ARIMAX <i>Inflow</i> Rp50.000 di KPw Jember	85
Gambar 4.17	Perbandingan RMSE dan sMAPE Data <i>Out-Sample</i> berdasarkan <i>Input</i> Hibrida ARIMAX-DNN <i>Inflow</i> Rp50.000 di KPw Jember.....	86
Gambar 4.18	Arsitektur Optimum Hibrida ARIMAX-DNN <i>Inflow</i> Rp50.000 di KPw Jember	87
Gambar 4.19	Perbandingan Hasil Ramalan Hibrida ARIMAX-DNN <i>Inflow</i> Rp50.000 di KPw Jember.....	88
Gambar 4.20	Perbandingan Hasil Ramalan <i>Inflow</i> Rp50.000 di KPw Jember	92
Gambar 4.21	Perbandingan Hasil Ramalan Ketiga Metode di KPw Jember.....	97
Gambar 4.22	Perbandingan Hasil Ramalan Ketiga Metode di KPw Kediri.....	103
Gambar 4.23	Perbandingan Hasil Ramalan Ketiga Metode di KPw Malang.....	109

Gambar 4.24	Perbandingan Hasil Ramalan Ketiga Metode di KPw Surabaya	115
Gambar 4.25	Jumlah Metode Terbaik di Provinsi Jawa Timur	117
Gambar 4.26	Peramalan <i>Inflow</i> di KPw Jember	119
Gambar 4.27	Peramalan <i>Outflow</i> di KPw Jember	120
Gambar 4.28	Peramalan <i>Inflow</i> di KPw Kediri	121
Gambar 4.29	Peramalan <i>Outflow</i> di KPw Kediri.....	122
Gambar 4.30	Peramalan <i>Inflow</i> di KPw Malang	123
Gambar 4.31	Peramalan <i>Outflow</i> di KPw Malang.....	124
Gambar 4.32	Peramalan <i>Inflow</i> di KPw Surabaya.....	125
Gambar 4.33	Peramalan <i>Outflow</i> di KPw Surabaya.....	126

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

Tabel 2.1	Bentuk Transformasi.....	14
Tabel 2.2	Identifikasi Model ARIMA	15
Tabel 3.1	Variabel Penelitian.....	33
Tabel 3.2	Variabel <i>Dummy</i>	34
Tabel 3.3	Daftar Idul Fitri Tahun 2010-2020.....	34
Tabel 4.1	Statistika Deskriptif Total Pecahan Uang Kertas	45
Tabel 4.2	Statistika Deskriptif Pecahan Uang Kertas di KPw Jember	54
Tabel 4.3	Statistika Deskriptif Pecahan Uang Kertas di KPw Kediri.....	56
Tabel 4.4	Statistika Deskriptif Pecahan Uang Kertas di KPw Malang.....	58
Tabel 4.5	Statistika Deskriptif Pecahan Uang Kertas di KPw Surabaya.....	60
Tabel 4.6	Estimasi Parameter Regresi <i>Time Series</i> <i>Inflow</i> Rp50.000 di KPw Jember	62
Tabel 4.7	Uji Asumsi Residual Regresi <i>Time Series</i> <i>Inflow</i> Rp50.000 di KPw Jember	64
Tabel 4.8	Estimasi Parameter ARIMAX <i>Inflow</i> Rp50.000 di KPw Jember.....	65
Tabel 4.9	Uji Asumsi Residual ARIMAX <i>Inflow</i> Rp50.000 di KPw Jember.....	67
Tabel 4.10	Model Residual untuk <i>Inflow</i> dan <i>Outflow</i> di KPw Jember	70
Tabel 4.11	Model Residual untuk <i>Inflow</i> dan <i>Outflow</i> di KPw Kediri.....	71
Tabel 4.12	Model Residual untuk <i>Inflow</i> dan <i>Outflow</i> di KPw Malang.....	72
Tabel 4.13	Model Residual untuk <i>Inflow</i> dan <i>Outflow</i> di KPw Surabaya.....	73

Tabel 4.14	Arsitektur DNN Optimum <i>Inflow</i> dan <i>Outflow</i> KPw Jember.....	80
Tabel 4.15	Arsitektur DNN Optimum untuk <i>Inflow</i> dan <i>Outflow</i> di KPw Kediri.....	81
Tabel 4.16	Arsitektur DNN Optimum untuk <i>Inflow</i> dan <i>Outflow</i> KPw Malang.....	82
Tabel 4.17	Arsitektur DNN Optimum untuk <i>Inflow</i> dan <i>Outflow</i> di KPw Surabaya.....	83
Tabel 4.18	Nilai RMSE dan sMAPE Terkecil Data <i>Out-Sample</i> untuk Setiap <i>Input</i> Hibrida ARIMAX-DNN <i>Inflow</i> Rp50.000 di KPw Jember	86
Tabel 4.19	Arsitektur Optimum Hibrida ARIMAX-DNN di KPw Jember	89
Tabel 4.20	Arsitektur Optimum Hibrida ARIMAX-DNN di KPw Kediri.....	90
Tabel 4.21	Arsitektur Optimum Hibrida ARIMAX-DNN di KPw Malang.....	91
Tabel 4.22	Arsitektur Optimum Hibrida ARIMAX-DNN di KPw Surabaya.....	91
Tabel 4.23	Nilai Kebaikan Model <i>Inflow</i> Rp50.000 di KPw Jember	93
Tabel 4.24	Nilai RMSE dan sMAPE <i>Inflow</i> dan <i>Outflow</i> di KPw Jember	98
Tabel 4.25	Metode Terbaik <i>Inflow</i> dan <i>Outflow</i> di KPw Jember	99
Tabel 4.26	Nilai RMSE dan sMAPE <i>Inflow</i> dan <i>Outflow</i> di KPw Kediri.....	104
Tabel 4.27	Metode Terbaik <i>Inflow</i> dan <i>Outflow</i> di KPw Kediri.....	105
Tabel 4.28	Nilai RMSE dan sMAPE <i>Inflow</i> dan <i>Outflow</i> di KPw Malang.....	110
Tabel 4.29	Metode Terbaik <i>Inflow</i> dan <i>Outflow</i> di KPw Malang.....	111

Tabel 4.30	Nilai RMSE dan sMAPE <i>Inflow</i> dan <i>Outflow</i> di KPw Surabaya.....	116
Tabel 4.31	Metode Terbaik <i>Inflow</i> dan <i>Outflow</i> di KPw Surabaya.....	117

(Halaman ini sengaja dikosongkan)

DAFTAR LAMPIRAN

Lampiran 1.	<i>Output</i> ARIMAX	134
Lampiran 2.	<i>Output</i> DNN	198
Lampiran 3.	<i>Output</i> Hibrida ARIMAX-DNN	214
Lampiran 4.	Hasil Uji Nonlinier	225
Lampiran 5.	<i>Syntax</i> Program SAS Metode ARIMAX.....	227
Lampiran 6.	<i>Syntax</i> Program R Metode DNN.....	228
Lampiran 7.	<i>Syntax</i> Program R Metode Hibrida ARIMAX- DNN	232
Lampiran 8.	Surat Keterangan Data Instansi	237

(Halaman ini sengaja dikosongkan)

BAB I


PENDAHULUAN

1.1 Latar Belakang

Uang adalah suatu benda yang dapat ditukarkan dengan benda lain dan dapat disimpan. Uang dalam bentuk fisik, yaitu uang tunai yang berupa uang kertas dan uang logam yang beredar di masyarakat. Uang tunai adalah uang yang ada di tangan masyarakat (di luar bank umum) dan siap dibelanjakan setiap saat, terutama untuk pembayaran-pembayaran dalam jumlah yang tidak terlalu besar. Uang tunai tersebut sering disebut sebagai uang kartal yang terdiri dari uang kertas dan uang logam. Saat ini, uang logam terdiri dari pecahan Rp100, Rp200 dan Rp500 dan Rp1.000. Sedangkan uang kertas terdiri dari pecahan Rp1.000, Rp2.000, Rp5.000, Rp10.000, Rp20.000, Rp50.000 dan Rp100.000. Dengan uang kartal masyarakat dapat melakukan pembayaran tunai secara langsung (Solikin & Suseno, 2002).

Uang kartal merupakan suatu kebutuhan wajib bagi masyarakat, walaupun metode pembayaran online kian berkembang di Indonesia. Pembayaran *online* tidak dapat dilakukan di berbagai kondisi, salah satunya adalah ketika terjadi bencana alam. Tsunami di Palu dan gempa di Lombok menyebabkan listrik padam dan kerusakan fasilitas umum sehingga metode pembayaran online tidak dapat dipakai, sehingga uang kartal sangat dibutuhkan untuk transaksi pembayaran. Uang kartal juga merupakan alat pembayaran tunai yang sah untuk transaksi perekonomian di Indonesia. Uang kartal yang disetorkan oleh bank umum ke bank sentral disebut dengan *inflow*, sedangkan uang kartal yang keluar dari bank sentral ke bank umum melalui penarikan uang layak edar disebut dengan *outflow*. Bank sentral mendistribusikan uang kartal ke setiap Kantor Perwakilan (KPw). Setiap KPw memiliki persebaran uang kartal yang berbeda-beda. Jawa Timur memiliki empat KPw, yaitu KPw Surabaya, KPw

Kediri, KPw Malang dan KPw Jember. Persebaran KPw di seluruh Indonesia dapat dilihat pada Gambar 1.1



Gambar 1.1 Persebaran KPw di Seluruh Indonesia

Pertumbuhan ekonomi Jawa Timur pada triwulan II 2018 mencapai 5,6% (yoy) dimana nilai ini lebih tinggi dibandingkan nasional yaitu sebesar 5,3% (yoy). Kinerja perekonomian Jawa Timur lebih baik dibandingkan DKI Jakarta, Jawa Barat dan Banten. Meningkatnya pertumbuhan ekonomi maka akan semakin banyak pula uang kartal yang beredar di masyarakat (Bank Indonesia, 2018: 2). Hal tersebut diperkuat dengan kondisi bahwa di Jawa Timur mengalami kondisi *net outflow*, kondisi ini terjadi ketika transaksi penarikan uang lebih besar daripada penyetoran uang. Jumlah *outflow* sebesar Rp36,56 triliun meningkat signifikan sebesar 99,39% dari triwulan I 2018 sejalan dengan momen Idul Fitri yang jatuh pada Juni 2018 (Bank Indonesia, 2018: 91). Besarnya kenaikan pertumbuhan ekonomi di Jawa Timur yang mengakibatkan *net outflow* perlu mendapatkan perhatian lebih agar jumlah uang yang dicetak memiliki tingkat kesalahan yang rendah sehingga kerugian dapat diminimalisir, oleh karena itu dibutuhkan

penelitian tentang pemodelan dan peramalan *inflow* dan *outflow* di Jawa Timur untuk mengatur aliran uang kartal yang masuk dan keluar.


Kebutuhan uang kartal setiap waktu berbeda secara signifikan. Hal ini disebabkan oleh beberapa faktor. Salah satu faktor yang mempengaruhi adalah variasi kalender hari besar atau hari libur seperti hari raya Idul Fitri. Suhartono, Lee dan Hamzah (2010) memperkenalkan suatu model regresi runtun waktu untuk pemodelan data yang mengandung pola variasi kalender, khususnya penjualan bulanan suatu produk pakaian muslim. Penelitian ini menggunakan *dummy* hari raya Idul Fitri dengan membandingkan metode ARIMA dan *Neural Network*. Nilai *Root Mean Square Error* (RMSE) terendah yaitu pemodelan menggunakan ARIMA dengan efek variasi kalender berupa variabel eksogen *dummy* Idul Fitri (ARIMAX). Metode ARIMAX merupakan model terbaik untuk meramalkan penjualan produk pakaian muslim yang dipengaruhi oleh hari raya Idul Fitri. Penelitian lain yang menunjukkan bahwa model variasi kalender perlu digunakan yaitu penelitian yang dilakukan oleh Suhartono, Lee dan Prastyo (2015). Penelitian ini menggunakan metode *two level* ARIMAX dan menunjukkan bahwa model variasi kalender memiliki nilai akurasi yang lebih baik untuk meramalkan penjualan pakaian ritel. Peramalan *inflow* dan *outflow* di Provinsi Jawa Barat oleh Juliyanto dan Suhartono (2017) juga membuktikan bahwa model dengan variasi kalender mampu menangkap pola dari variasi kalender yaitu efek hari raya Idul Fitri. Efek variasi kalender Idul Fitri diduga memberikan pengaruh yang berbeda terhadap data *inflow* dan *outflow*. Hal ini dikarenakan masyarakat cenderung menabung uang kembali setelah hari raya, sehingga nilai *inflow* juga akan dipengaruhi oleh bulan setelah Idul Fitri. Nilai *outflow* akan naik sebulan sebelum Idul Fitri dikarenakan masyarakat akan menarik uang sebelum Idul Fitri. Oleh karena itu

penelitian ini akan menggunakan variabel prediktor yaitu variabel *dummy* bulan Idul Fitri dan satu bulan setelah Idul Fitri untuk data *inflow*, sedangkan untuk data *outflow* akan menggunakan variabel *dummy* bulan Idul Fitri dan satu bulan sebelum Idul Fitri.

Data *time series* khususnya data keuangan umumnya membentuk pola data non-linier. Pemodelan non-linier untuk peramalan seringkali menggunakan metode *Artifisial Neural Network* atau biasa disebut dengan *Neural Network* (He, 2017). Salah satu pengembangan *Neural Network* yaitu *Deep Learning* dimana memiliki lebih banyak layer dan diharapkan mampu mengenali proses lebih kompleks (Schmidhuber, 2015). Penelitian mengenai *Deep Neural Network* (DNN) sudah pernah dilakukan, salah satunya adalah penelitian yang dilakukan oleh Suhartono dkk. (2019). Penelitian ini meramalkan nilai *inflow* dan *outflow* di Indonesia dengan tren, *seasonal*, variasi kalender. Metode yang digunakan adalah ARIMAX, DNN dan hibrida *Singular Spectrum Analysis-Deep Neural Network* (SSA-DNN) dengan ukuran kebaikan model menggunakan RMSE dan sMAPE. Nilai akurasi terbesar untuk meramalkan *inflow* dan *outflow* di Indonesia adalah dengan metode DNN. Wang, Chen & Chen (2019) melakukan penelitian *Applicability of Deep Neural Networks on Production Forecasting in Bakken Shale Reservoirs* mengenai pembentukan produksi minyak *Bakken Formation*. Hasil penelitian menggunakan metode DNN dengan 3 *layer* dan 200 *neuron* pada setiap *layer* mampu meramalkan produksi minyak *Bakken Formation* dengan baik.

Penelitian *The M4 Competition: Results, findings, conclusion and way forward* menyatakan bahwa metode gabungan atau hibrida mampu menangkap pola data baik tren maupun *seasonal* dan secara rata-rata mampu meningkatkan nilai akurasi dibandingkan metode individual (Makridakis, Spiliotis & Assimakopoulos, 2018b). Hasil penelitian Zhang (2003) serta

Zheng dan Zhong (2011) memberikan pernyataan yang sama, yaitu penggabungan model linier dan non-linier adalah salah satu cara efektif untuk meningkatkan nilai akurasi. Metode hibrida sudah banyak dikembangkan dan setiap tahunnya mengalami peningkatan yang signifikan dimana ditunjukkan pada Gambar 1.2. Hibrida dibedakan menjadi tiga jenis, hibrida *parallel*, *series* dan *parallel-series*. Pada tahun 2018, jumlah penelitian hibrida *series* menurun hingga tiga kali lipat (Hajirahimi & Khashei, 2019: 85).



Gambar 1.2 Jumlah Penelitian Metode Hibrida

Penelitian oleh Smyl (2020) menggabungkan metode *Exponential Smoothing* (ES) dan *Long Short Term Memory* (LSTM), dimana penelitian ini mengacu dari *M4 Forecasting Competition*. Metode ES memungkinkan untuk menangkap tren dan *seasonal* data, sedangkan LSTM mampu menangkap tren non-linier. Penelitian lainnya dilakukan oleh Suhartono, Prastyo, Puka, & Lee (2018) mengenai peramalan *inflow* dan *outflow* di provinsi Nusa Tenggara Timur menggunakan metode ARIMAX dan hybrid *Quantile Regression Neural Network* (QRNN). Hasil penelitian yaitu model hibrida QRNN lebih unggul untuk meramalkan *inflow* dan *outflow* dibanding metode lainnya. Suhartono dkk. (2017) juga melakukan penelitian *Hybrid model for forecasting time series with trend, seasonal and salendar variation patterns* mengenai *inflow* dan *outflow* di Indonesia. Penelitian ini menghasilkan bahwa model hibrida lebih akurat dibanding model individual.

Hibrida atau penggabungan metode diharapkan mampu menghasilkan pola yang sesuai sehingga dapat meningkatkan akurasi peramalan. Peramalan uang kartal di Jawa Timur menggunakan metode hibrida beberapa kali dilakukan. Salah satunya yaitu oleh Salehah dkk. (2017) mengenai peramalan *inflow* dan *outflow* untuk semua pecahan uang kertas. Penelitian ini menghasilkan bahwa akurasi model hibrida *ARIMAX-Quantile Regression* lebih unggul untuk meramalkan *inflow* dan *outflow* dibanding metode lainnya.

Berdasarkan beberapa penelitian yang dilakukan menunjukkan bahwa tidak terdapat suatu metode peramalan yang selalu terbaik untuk meramalkan berbagai jenis data. Setiap metode memiliki kelebihan dan kekurangan masing-masing, sehingga perlu untuk membandingkan beberapa metode dalam melakukan peramalan (Makridakis, Spiliotis & Assimakopoulos, 2018a). Secara umum terdapat tiga pendekatan yang digunakan untuk meramalkan *inflow* dan *outflow* yaitu model peramalan linier, model peramalan non-linier, dan model hibrida. Pada penelitian ini, model peramalan linier yang digunakan adalah model ARIMAX, untuk model non-linier yang digunakan adalah DNN serta model gabungan yang digunakan hibrida ARIMAX-DNN. Penelitian ini diharapkan mampu membantu perencanaan pemenuhan kebutuhan uang kartal di Jawa Timur pada masa yang akan datang.

1.2 Rumusan Masalah

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

1. Bagaimana karakteristik dari data *inflow* dan *outflow* uang kartal di Provinsi Jawa Timur?
2. Bagaimana model peramalan menggunakan metode ARIMAX, DNN dan hibrida ARIMAX-DNN?

3. Bagaimana hasil perbandingan peramalan menggunakan metode ARIMAX, DNN dan hibrida ARIMAX-DNN?
4. Bagaimana hasil peramalan nilai *inflow* dan *outflow* uang kartal di Provinsi Jawa Timur pada tahun 2019 dan 2020?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah diuraikan, tujuan yang ingin didapatkan dari penelitian ini adalah sebagai berikut:

1. Mengetahui karakteristik dari data *inflow* dan *outflow* uang kartal di Provinsi Jawa Timur.
2. Memperoleh model ARIMAX, DNN dan hibrida ARIMAX-DNN untuk peramalan *inflow* dan *outflow* uang kartal di Provinsi Jawa Timur.
3. Mendapatkan model terbaik *inflow* dan *outflow* dengan membandingkan metode ARIMAX, DNN dan hibrida ARIMAX-DNN.
4. Mendapatkan hasil peramalan nilai *inflow* dan *outflow* uang kartal di Provinsi Jawa Timur pada tahun 2019 dan 2020.

1.4 Manfaat Penelitian

Penelitian ini diharapkan dapat memberi manfaat untuk berbagai pihak, diantaranya adalah membantu perencanaan pemenuhan kebutuhan uang kartal di Jawa Timur pada masa yang akan datang. Pemenuhan kebutuhan uang kartal akan memudahkan dan membantu pelanggan Bank Sentral diantaranya bank umum maupun bank swasta, perusahaan maupun perseorangan. Sehingga permintaan pelanggan Bank Sentral menjadi terpenuhi. Selain itu juga diharapkan mampu memberikan wawasan keilmuan statistika mengenai metode ARIMAX, DNN dan hibrida ARIMAX-DNN.

1.5 Batasan Masalah

Batasan masalah pada penelitian ini yaitu data *inflow* dan *outflow* yang digunakan uang kertas semua pecahan serta nilai total *inflow* maupun *outflow* dengan periode bulanan mulai Januari 2010

hingga Juni 2019. Metode yang digunakan adalah ARIMAX, DNN dan hibrida ARIMAX-DNN. Fungsi aktivasi yang digunakan dalam metode DNN adalah sigmoid dan linier dengan jumlah neuron pada *hidden* layer yaitu satu hingga lima. Ukuran kebaikan model menggunakan nilai RMSE dan sMAPE.

BAB II TINJAUAN PUSTAKA

Tinjauan pustaka berisi landasan teori yang dipakai pada penelitian ini. Teori yang digunakan pada penelitian ini berasal dari buku, jurnal ilmiah, dan beberapa penelitian sebelumnya.

2.1 Analisis Deret Waktu

Deret waktu adalah data pengamatan yang diukur selama kurun waktu tertentu. Analisis deret waktu adalah metode yang digunakan untuk menganalisis deret waktu. Tujuan analisis deret waktu secara umum ada dua yaitu untuk memahami atau memodelkan pola deret data dan untuk memprediksi atau memperkirakan nilai masa depan berdasarkan deret masa lalu (Cryer & Chan, 2008: 1).

2.2 Regresi *Time Series*

Salah satu model *time series* adalah regresi *time series* dimana secara umum model ini sama dengan model regresi linier. Dengan mengasumsikan *output* atau dependen *time series* $Y_{i,t} = 1, 2, \dots, n$ yang dipengaruhi oleh beberapa variabel *input* atau prediktor, dengan *input* adalah *fixed variable* dan diketahui, maka dapat diformulasikan seperti model regresi linier (Shumway & Stoffer, 2006: 47). Variabel prediktor yang digunakan adalah variabel *dummy* berupa tren, musiman dan variasi kalender Idul Fitri seperti persamaan berikut (Suharto, Lee, & Hamzah, 2010: 35).

$$Y_t = \beta_1 t + \sum_{i=1}^S \alpha_i M_{i,t} + \sum_{j=1}^G \gamma_j V_{j,t} + \varepsilon_t, \quad (2.1)$$

dengan t merupakan *dummy* tren, $M_{s,t}$ adalah *dummy* musiman, $V_{G,t}$ adalah *dummy* variasi kalender Idul Fitri dan ε_t merupakan residual dari model regresi *time series* yang belum tentu memenuhi asumsi $IIDN_{(0, \sigma_a^2)}$.

2.3 ACF dan PACF

Autocorrelation Function (ACF) adalah suatu fungsi yang digunakan untuk menjelaskan hubungan atau korelasi antara Y_t dan Y_{t+k} dari proses yang sama dan hanya terpisah lag waktu ke- k . $\{Y_t\}$ merupakan proses yang stasioner jika $E(Y_t) = \mu$ dan $Var(Y_t) = E(Y_t - \mu) = \sigma^2$ (Wei, 2006: 10-11). Proses stasioner yaitu ketika fungsi distribusi secara keseluruhan adalah independen terhadap waktu. Berikut merupakan persamaan ACF.

$$\rho_k = \frac{Cov(Y_t, Y_{t+k})}{\sqrt{Var(Y_t)}\sqrt{Var(Y_{t+k})}} = \frac{\gamma_k}{\gamma_0}, \quad (2.2)$$

dengan

ρ_k : autokorelasi pada pada lag ke- k ,

$Cov(Y_t, Y_{t+k})$: $E(Y_t - \mu)(Y_{t+k} - \mu) = \gamma_k$,

$Var(Y_t)$: $Var(Y_{t+k}) = \gamma_0$.

Fungsi ACF pada sampel data deret waktu dituliskan sebagai berikut (Wei, 2006: 20).

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}, k = 0, 1, 2, \dots, \quad (2.3)$$

Partial Autocorrelation Function (PACF) digunakan untuk mengukur korelasi antara Y_t dan Y_{t+k} setelah pengaruh variabel $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ dihilangkan. Nilai PACF ditunjukkan sebagai berikut (Wei, 2006: 22).

$$P_k = \text{Corr}(Y_t, Y_{t+k} \mid Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}), \quad (2.4)$$

atau

$$P_k = \frac{\text{Cov}(Y_t - \hat{Y}_t, (Y_{t+k} - \hat{Y}_{t+k}))}{\sqrt{\text{Var}(Y_t - \hat{Y}_t)} \sqrt{\text{Var}(Y_{t+k} - \hat{Y}_{t+k})}}. \quad (2.5)$$

Sedangkan persamaan PACF pada sampel data deret waktu dinyatakan sebagai berikut:

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}, \quad (2.6)$$

dan

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{k,j} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}, \quad j=1,2,\dots,k. \quad (2.7)$$

2.4 Autoregressive Intergrated Moving Average (ARIMA)

ARIMA merupakan model peramalan yang dikenalkan oleh Box dan Jenkins yang memiliki orde operator p untuk *Autoregressive* (AR), d yang merupakan orde *differencing* dan q sebagai orde operator untuk *Moving Average* (MA) sehingga dikenal dengan $ARIMA(p,d,q)$. Model ARIMA adalah model untuk data *time series* yang tidak stasioner, sedangkan model ARMA untuk data *time series* yang stasioner sehingga tidak mengalami *differencing* (Wei, 2006: 33-74).

Model $AR(p)$ menjelaskan hubungan antara proses sekarang (Y_t) dan proses sebelumnya (Y_{t-k}) ditambah suatu nilai residual (a_t) yang sudah memenuhi asumsi *white noise* dan berdistribusi normal ($0, \sigma_a^2$). Bentuk umum model AR dinyatakan sebagai berikut (Wei, 2006: 33).

$$\dot{Y}_t = \phi_1 \dot{Y}_{t-1} + \dots + \phi_p \dot{Y}_{t-p} + a_t, \quad (2.8)$$

atau

$$\phi_p(B)\dot{Y}_t = a_t, \quad (2.9)$$

dengan $\dot{Y}_t = Y_t - \mu$ dan $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$.

MA(q) menjelaskan hubungan antara proses sekarang (Y_t) dengan suatu nilai residual pada waktu sebelumnya ($a_{t-k}; k=1,2,3,\dots$). Bentuk umum model MA dinyatakan sebagai berikut (Wei, 2006:47).

$$\dot{Y}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}, \quad (2.10)$$

atau

$$\dot{Y}_t = \theta_q(B)a_t, \quad (2.11)$$

dengan $\dot{Y}_t = Y_t - \mu$ dan $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$.

ARMA(p, q) adalah gabungan model AR dan MA dimana data *time series* sudah stasioner. Bentuk umum ARMA dinyatakan sebagai berikut (Wei, 2006: 57).

$$\dot{Y}_t = \phi_1 \dot{Y}_{t-1} + \dots + \phi_p \dot{Y}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}, \quad (2.12)$$

atau

$$\phi_p(B)\dot{Y}_t = \theta_q(B)a_t, \quad (2.13)$$

ARIMA(p, d, q) adalah gabungan model AR dan MA dimana data *time series* belum stasioner dan dilakukan *differencing*. Bentuk umum model ARIMA dinyatakan sebagai berikut (Wei, 2006: 72).

$$\phi_p(B)(1-B)^d \dot{Y}_t = \theta_q(B)a_t. \quad (2.14)$$

ARIMA(P, D, Q)^S adalah model ARIMA dengan pola musiman pada waktu ke S. Bentuk umum model SARIMA dinyatakan sebagai berikut (Wei, 2006: 164).

$$\Phi_p(B^S)(1-B^S)^D \dot{Y}_t = \Theta_Q(B^S)a_t. \quad (2.15)$$

Model ARIMA yang memiliki pola musiman dan pola non musiman disebut juga model multiplikatif ARIMA(p, d, q)(P, D, Q)^S. Bentuk umum model dinyatakan sebagai berikut (Wei, 2006: 166).

$$\phi_p(B)\Phi_p(B^S)(1-B)^d(1-B^S)^D \dot{Y}_t = \theta_q(B)\Theta_Q(B^S)a_t, \quad (2.16)$$

dengan

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p), \quad (2.17)$$

$$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q), \quad (2.18)$$

$$\Phi_p(B^S) = (1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_p B^{pS}), \quad (2.19)$$

$$\Theta_Q(B^S) = (1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS}), \quad (2.20)$$

dengan

- (p, d, q) : orde non musiman AR(p), orde *differencing* (d), orde MA(q) untuk pola non musiman,
- (P, D, Q) : orde musiman AR(P), orde *differencing* (D), orde MA(Q) untuk pola musiman,
- $\phi_p(B)$: koefisien komponen AR nonmusiman,
- $\Phi_p(B^S)$: koefisien komponen AR musiman S,
- $\theta_q(B)$: koefisien komponen MA nonmusiman,
- $\Theta_Q(B^S)$: koefisien komponen MA musiman S,
- $(1-B)^d$: operator *differencing* untuk orde d ,
- $(1-B^S)^D$: operator *differencing* untuk orde D musiman S,
- a_t : nilai residual waktu ke- t yang telah memenuhi asumsi *white noise*.

2.4.1 Identifikasi Model

Tahap pertama pada identifikasi model adalah melakukan cek kestasioneran data. Asumsi stasioner dalam data *time series* harus terpenuhi, baik stasioner dalam *mean* maupun stasioner dalam *varians*. Jika data belum stasioner dalam mean maka dapat diatasi dengan proses *differencing* sebanyak d (Wei, 2006: 71). Proses *differencing* dapat ditunjukkan sebagai berikut:

$$\Delta^d Y_t = (1 - B)^d Y_t. \quad (2.21)$$

Jika nilai λ yang tidak sama dengan 1 maka data belum stasioner dalam varians dan dapat dilakukan transformasi Box-Cox (Wei, 2006: 85). Bentuk dari transformasi Box-Cox dari nilai estimasi λ ditunjukkan pada Tabel 2.1.

Tabel 2.1 Bentuk Transformasi

Nilai Estimasi λ	Transformasi
-1,0	$\frac{1}{Y_t}$
-0,5	$\frac{1}{\sqrt{Y_t}}$
0,0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1,0	Y_t (tidak ada transformasi)

Sedangkan persamaan transformasi Box-Cox disajikan pada Persamaan (2.22).

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda}. \quad (2.22)$$

Identifikasi orde model ARIMA dapat dilakukan dari melihat plot ACF dan plot PACF, dengan syarat data telah stasioner.

Dugaan model ARIMA berdasarkan plot ACF dan plot PACF ditunjukkan pada Tabel 2.2 (Wei, 2006: 109).

Tabel 2.2 Identifikasi Model ARIMA

Model	Plot ACF	Plot PACF
AR(p)	Turun cepat secara eksponensial/ <i>dies down</i>	Terpotong setelah lag ke- p
MA(q)	Terpotong setelah lag ke- q	Turun cepat secara eksponensial/ <i>dies down</i>
ARMA(p, q)	Turun cepat setelah lag ($q-p$)	Turun cepat setelah lag ($p-q$)

2.4.2 Estimasi dan Pengujian Parameter

Estimasi parameter bertujuan untuk memperoleh nilai dari setiap parameter dalam model ARIMA. *Conditional Least Square* (CLS) adalah salah satu metode yang dapat digunakan untuk melakukan estimasi parameter (Cryer & Chan, 2008: 154-156). Persamaan CLS untuk estimasi model AR(1) dituliskan sebagai berikut:

$$\dot{Y}_t = \phi \dot{Y}_{t-1} + a_t \quad (2.23)$$

atau

$$Y_t - \mu = \phi(Y_{t-1} - \mu) + a_t, \quad (2.24)$$

sehingga

$$a_t = (Y_t - \mu) - \phi(Y_{t-1} - \mu). \quad (2.25)$$

Persamaan (2.25) merupakan estimasi *least square* dengan cara meminimumkan nilai error dimana Y_t sebagai variabel respon dan Y_{t-1} merupakan variabel prediktor. Nilai *Sum Square Error* (SSE) ditunjukkan sebagai berikut:

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2. \quad (2.26)$$

Meminimkan fungsi $S_c(\phi, \mu)$ dengan cara menurunkan $\frac{\partial S}{\partial \mu} = 0$ dilakukan untuk mengestimasi nilai ϕ dan μ terhadap masing-masing nilai ϕ dan μ , sehingga didapatkan

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi(Y_{t-1} - \mu)](-1 + \phi) = 0. \quad (2.27)$$

Berdasarkan Persamaan (2.27) didapatkan nilai μ ,

$$\mu = \frac{1}{(n-1)(1-\phi)} \left[\sum_{t=2}^n Y_t - \phi \sum_{t=2}^n Y_{t-1} \right], \quad (2.28)$$

untuk n besar,

$$\frac{1}{n-1} \sum_{t=2}^n Y_t \approx \frac{1}{n-1} \sum_{t=2}^n Y_{t-1} \approx \bar{Y}. \quad (2.29)$$

Persamaan (2.27) disederhanakan tanpa memperhatikan nilai ϕ menjadi

$$\hat{\mu} \approx \frac{1}{(1-\phi)} [\bar{Y} - \phi \bar{Y}] = \bar{Y}. \quad (2.30)$$

Estimasi nilai ϕ didapatkan dengan cara meminimumkan $\frac{\partial S_c(\phi, \bar{Y})}{\partial \phi} = 0$ dan didapatkan Persamaan (2.31).

$$\frac{\partial S_c}{\partial \phi} = \sum_{t=2}^n 2[(Y_t - \bar{Y}) - \phi(Y_{t-1} - \bar{Y})](Y_{t-1} - \bar{Y}) = 0, \quad (2.31)$$

sehingga didapatkan nilai ϕ sebagai berikut

$$\hat{\phi} = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2}. \quad (2.32)$$

Setelah dilakukan estimasi parameter maka langkah selanjutnya adalah melakukan uji signifikansi parameter. Pengujian signifikansi terhadap nilai estimasi parameter model AR(p) adalah dengan hipotesis sebagai berikut:

H_0 : $\phi_i = 0$ (Parameter tidak signifikan).

H_1 : $\phi_i \neq 0$ dimana $i = 1, 2, \dots, p$ (Parameter signifikan).

Statistik uji:

$$t_{hitung} = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)}, \quad (2.33)$$

Tolak H_0 , jika nilai statistik uji $|t_{hitung}|$ lebih besar dari nilai $t_{\alpha/2, (n-p)}$ dengan n adalah banyaknya pengamatan pada data *time series*.

2.4.3 Cek Diagnosa

Model ARIMA dengan parameter yang signifikan selanjutnya harus dilakukan cek diagnosa. Cek diagnosa merupakan suatu tahap untuk mengevaluasi apakah model telah memenuhi syarat kesesuaian model ARIMA. Asumsi yang harus terpenuhi yaitu *residual* yang didapatkan dari model harus bersifat *white noise* dan berdistribusi normal (Wei, 2006: 152-153).

a. Uji *White Noise*

Pengujian asumsi *white noise* dapat digunakan uji *portmanteau*. Residual disebut *white noise* jika mempunyai varians yang konstant atau identik dan bersifat independen yang berarti

antar residual homogen (Wei, 2006: 153). Uji *portmanteau* memiliki hipotesis sebagai berikut:

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

$$H_1 : \text{minimal ada satu } \rho_k \neq 0; k = 1, 2, \dots, K$$

Statistik uji yang digunakan adalah Ljung-Box,

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)}. \quad (2.34)$$

dengan

Q : statistik uji Ljung-Box,

n : jumlah pengamatan,

$\hat{\rho}_k$: ACF residual lag ke- k .

Daerah penolakannya adalah tolak H_0 jika $Q > \chi_{\alpha, K-p-q}^2$ atau nilai $p < \alpha$. Residual memenuhi asumsi *white noise* jika gagal tolak H_0 .

b. Uji Distribusi Normal

Asumsi residual berdistribusi normal dilakukan menggunakan metode *Kolmogorov-Smirnov* (Daniel, 1989: 343-345). Hipotesis yang digunakan adalah sebagai berikut:

$$H_0 : F_n(a_t) = F_0(a_t)$$

$$H_1 : F_n(a_t) \neq F_0(a_t)$$

Statistik uji yang digunakan adalah:

$$D = \text{Sup} |F_n(a_t) - F_0(a_t)|, \quad (2.35)$$

dengan

$F_n(a_t)$: fungsi peluang kumulatif dari data sampel,

$F_0(a_t)$: nilai peluang kumulatif dari distribusi normal,

Sup : nilai maksimum dari harga mutlak.

Apabila $D < D_{(1-\alpha),n}$ maka H_0 akan gagal ditolak atau nilai $p > \alpha$ artinya bahwa residual memenuhi asumsi distribusi normal.

2.5 Autoregressive Intergrated Moving Average with Exogeneous Variable (ARIMAX)

ARIMAX adalah pengembangan model ARIMA dimana terdapat tambahan variabel eksogen sehingga dapat dilakukan regresi berganda. ε_t merupakan residual regresi *time series* yang belum memenuhi asumsi *white noise*, dimana ε_t mengikuti persamaan ARIMA yakni $\varepsilon_t = \frac{\theta_q(B)}{\phi_p(B)} a_t$. Apabila residual dari

model regresi *time series* tidak memenuhi asumsi *white noise*, dilakukan pemodelan residual (ε_t) menggunakan model ARIMA. Model umum ARIMAX yang mengandung pola tren, musiman, dan kalender variasi dinyatakan pada Persamaan (2.38) (Suhartono, Lee, & Prastyo, 2015: 4).

$$Y_t = \beta_1 t + \sum_{i=1}^S \alpha_i M_{i,t} + \sum_{j=1}^G \gamma_j V_{j,t} + \frac{\theta_q(B)}{\phi_p(B)} a_t, \quad (2.38)$$

dengan

- $M_{i,t}$: variabel dummy untuk musiman bulan ke- i , dimana $i= 1, 2, \dots, S$,
- $V_{j,t}$: variabel dummy untuk kalender variasi Idul Fitri, dimana $j= 1, 2, \dots, G$,
- t : variabel *dummy* untuk tren.

2.6 Uji Linieritas

Sebelum melakukan pemodelan menggunakan *neural network*, akan dilakukan pengujian linieritas menggunakan uji Terasvirta. Pengujian linieritas dengan uji LM yaitu apabila penambahan variabel independen pada suatu model linier akan meningkatkan nilai R^2 secara signifikan, maka model linier

tersebut kurang tepat dalam menggambarkan hubungan antara variabel independen dan variabel dependen. Dengan kata lain, bentuk fungsional dari data bukan merupakan bentuk yang linier (Gujarati, 2004: 523-524). Berikut adalah tahapan yang dilakukan dalam melakukan pengujian linieritas dengan uji LM.

1. Meregresikan Y_t pada X_t sehingga diperoleh model linier:

$$Y_t = \beta_0 + \beta_1 X_t + u_t, \quad (2.39)$$

dan akan diperoleh nilai residual $\hat{u}_t = Y_t - \hat{Y}_t$.

2. Menambahkan variabel independen misal \hat{X}_t^2 dan \hat{X}_t^3 sehingga diperoleh model nonlinier:

$$\hat{u}_t = \beta_0 + \beta_1 X_t + \beta_2 \hat{X}_t^2 + \beta_3 \hat{X}_t^3 + v_t, \quad (2.40)$$

dan v merupakan nilai residual dari model baru.

3. Untuk ukuran sampel besar, perhitungan statistik uji secara asimtotis akan mengikuti distribusi *chi-square* (χ^2). Dengan demikian, perhitungan statistik uji dapat dilakukan menggunakan Persamaan (2.41).

$$\chi^2 = nR^2, \quad (2.41)$$

dengan n merupakan ukuran sampel, dan R^2 merupakan koefisien determinasi dari model regresi Persamaan (2.40).

Apabila χ_{hitung}^2 yang diperoleh pada langkah 3 lebih besar daripada $\chi_{\alpha,df}^2$ maka dapat disimpulkan bahwa model linier pada Persamaan (2.39) bukan merupakan model yang tepat atau terdapat permasalahan non-linieritas antara variabel independen dan variabel dependen yang digunakan.

2.7 Neural Network

Neural Network adalah sistem pemroses informasi yang terdiri atas neuron-neuron yang saling berhubungan. Arsitektur


Neural Network yang sering digunakan adalah *Feed Forward Neural Network* (FFNN). Pada FFNN neuron neuron saling berhubungan dalam satu *layer* sehingga data berjalan hanya pada satu jalur. Setiap neuron akan menerima informasi hanya dari neuron pada *layer* sebelumnya dimana *input* dari neuron berasal dari bobot *output* neuron pada *layer* sebelumnya. Layer diantara *input* dan *output* disebut *hidden layer* (Chong & Zak, 2001: 220). Model umum dari FFNN adalah sebagai berikut (Zhang & Qi, 2005: 506).

$$\hat{Y}_{(t)} = f^o \left[b^o + \sum_{i=1}^p w_i^o f_i^{h_1} \left(b_i^{h_1} + \sum_{j=1}^q w_{ji}^{h_1} X_{j(t)} \right) \right], \quad (2.43)$$

dengan

- $\hat{Y}_{(t)}$: nilai dugaan dari variabel *output*,
- $X_{j(t)}$: variabel *input* sebanyak q , dengan $(j = 1, 2, \dots, q)$,
- t : indeks pasangan data *input*-target $(x_{j(t)}, y_{(t)})$, dengan $t = 1, 2, \dots, n$,
- $w_{ji}^{h_1}$: bobot dari *input* ke- j yang menuju *neuron* ke- i pada *hidden layer 1*, dengan $i = 1, 2, \dots, p$,
- $b_i^{h_1}$: bias pada *neuron* ke- i pada *hidden layer 1*, dengan $i = 1, 2, \dots, p$,
- $f_i^{h_1}$: fungsi aktivasi di *neuron* ke- i pada *hidden layer*,
- w_i^o : bobot dari *neuron* ke- i di *hidden layer* yang menuju *neuron* pada *output layer*,
- b^o : bias pada *neuron* di *output layer*,
- f^o : fungsi aktivasi pada *neuron* di *output layer*.

Nilai respon $Y_{(t)}$ dapat digambarkan pada arsitektur dengan 1 *hidden layer* dan q variabel *input* seperti Gambar 2.1.



Gambar 2.1 Arsitektur *Neural Network*

Notasi $v_{i(t)}$ digunakan untuk menyatakan suatu vektor nilai-nilai setelah proses penjumlahan *input* dan bobot-bobot (bias termasuk di dalamnya) pada *hidden layer* di *neuron* ke- i untuk data ke- t (Suhartono, 2007: 45-47).

$$v_{i(t)} = b_i^{h_1} + \sum_{j=1}^q w_{ji}^{h_1} X_{j(t)}, \quad (2.44)$$

sedangkan $a_{i(t)}$ digunakan untuk output pada *hidden layer* di *neuron* ke- i ,

$$a_{i(t)}^h = f_i^{h_1} \left(b_i^{h_1} + \sum_{j=1}^q w_{ji}^{h_1} X_{j(t)} \right). \quad (2.45)$$

Menggunakan cara yang sama, notasi penjumlahan dari *input* dan bobot-bobot pada *output layer* ditunjukkan sebagai berikut:

$$v_{0(t)} = b^o + \sum_{i=1}^p w_i^o a_{i(t)}, \quad (2.46)$$

output pada output layer adalah


$$\hat{Y}_{(t)} = a_{(t)}^o = f^o(v_{0(t)}). \quad (2.47)$$

Dengan demikian, hubungan antara input $X_{j(t)}$, $j= 1, 2, \dots, q$ dengan output \hat{Y} adalah

$$\begin{aligned} \hat{Y}_{(t)} &= f^o \left(b^o + \sum_{i=1}^p w_i^o f_i^{h_1} (v_{i(t)}) \right) \\ &= f^o \left[b^o + \sum_{i=1}^p w_i^o f_i^{h_1} \left(b_i^{h_1} + \sum_{j=1}^q w_{ji}^{h_1} X_{q(t)} \right) \right] \\ &= F(X_{1(t)}, X_{2(t)}, \dots, X_{q(t)}). \end{aligned} \quad (2.48)$$

2.8 Deep Neural Network

Deep Neural Network (DNN) merupakan pengembangan dari Neural Network yang memiliki lebih banyak layer dan diharapkan mampu mengenali proses lebih kompleks. Arsitektur DNN dapat ditunjukkan pada Gambar 2.2.



Gambar 2.2 Arsitektur Deep Neural Network

Input yang akan digunakan pada penelitian ini adalah variabel *dummy* dan lag. Pemilihan lag *input* yaitu berdasarkan lag PACF yang signifikan pada data (Faraway & Chatfield, 1998: 234; Zang & Qi, 2005: 506; Crone & Kourentzes, 2009: 620). Pada *input* dan *hidden layer* memiliki bias yang bernilai satu (Zang & Qi, 2005: 506). Semakin banyak jumlah neuron yang digunakan pada *hidden layer* terdapat kemungkinan akan meningkatkan akurasi model, namun juga memungkinkan nilai prediksi *out-sample* menurun (Faraway & Chatfield, 1998: 248). Oleh karena itu jumlah neuron yang digunakan pada *hidden layer* dicobakan dari satu hingga lima. Model umum yang digunakan pada DNN dapat digenerelisasi dari FFNN satu *layer* dan dapat ditunjukkan sebagai berikut (Suhartono dkk., 2019: 1789).

$$\hat{Y}_{(t)} = f^o \left[b^o + \sum_{i=1}^p w_i^o f_i^{h_2} \left(b_i^{h_2} + \sum_{j=1}^q w_{ji}^{h_2} f_j^{h_1} \left(b_j^{h_1} + \sum_{k=1}^r w_{kj}^{h_1} X_{k(t)} \right) \right) \right], \quad (2.49)$$

dengan

$\hat{Y}_{(t)}$: nilai dugaan variabel *output*,

f^o : fungsi aktivasi pada neuron di lapisan *output*,

b^o : bias pada neuron di lapisan *output*,

w_i^o : bobot neuron ke-*i* pada *hidden layer* menuju neuron pada *output layer*,

$f_i^{h_2}$: fungsi aktivasi di *neuron* ke-*i* pada *hidden layer*,

$b_i^{h_2}$: bias pada neuron ke-*i* pada *hidden layer*,

$w_{ji}^{h_2}$: bobot dari *input* ke-*j* menuju *neuro* ke-*i* pada *hidden layer*,

$f_j^{h_1}$: fungsi aktivasi di *neuron* ke-*j* pada *hidden layer*,

$b_j^{h_1}$: bias pada neuron ke- j pada hidden layer,

$w_{kj}^{h_1}$: bobot dari *input* ke- k menuju neuro ke- j pada hidden layer,

$X_{k(t)}$: variabel *input* sebanyak r .

Notasi $v_{j(t)}$ digunakan untuk menyatakan suatu vektor nilai-nilai setelah proses penjumlahan *input* dan bobot-bobot (bias termasuk di dalamnya) pada *hidden layer 1* di *neuron* ke- j untuk data ke- t yang ditunjukkan pada Peramaan (2.50).

$$v_{j(t)} = b_j^{h_1} + \sum_{k=1}^r w_{kj}^{h_1} X_{k(t)}, \quad (2.50)$$

sedangkan $a_{j(t)}$ digunakan untuk output pada *hidden layer* di neuron ke- j ,

$$a_{j(t)} = f_j^{h_1} \left(b_j^{h_1} + \sum_{k=1}^r w_{kj}^{h_1} X_{k(t)} \right). \quad (2.51)$$

Notasi $v_{i(t)}$ digunakan untuk menyatakan suatu vektor nilai-nilai setelah proses penjumlahan *input* dan bobot-bobot (bias termasuk di dalamnya) pada *hidden layer 2* di *neuron* ke- i untuk data ke- t ,

$$v_{i(t)} = b_i^{h_2} + \sum_{j=1}^q w_{ji}^{h_2} a_{j(t)}, \quad (2.52)$$

sedangkan $a_{i(t)}$ digunakan untuk output pada *hidden layer* di neuron ke- i ,

$$a_{i(t)} = f_i^{h_2}(v_{i(t)}). \quad (2.53)$$

Menggunakan cara yang sama, notasi penjumlahan dari *input* dan bobot pada *output layer* sebagai berikut:

$$v_{0(t)} = b^o + \sum_{i=1}^p w_i^o a_{i(t)}, \quad (2.54)$$

$$\hat{Y}_{(t)} = f^o(v_{0(t)}). \quad (2.55)$$

Dengan demikian, hubungan antara *input* $X_{k(t)}$, $k= 1, 2, \dots, r$ dengan *output* \hat{Y} ditunjukkan sebagai Persamaan (2.56).

$$\begin{aligned} \hat{Y}_{(t)} &= f^o \left(b^o + \sum_{i=1}^p w_i^o f_i^{h_2} \left(v_{i(t)} \right) \right) \\ &= f^o \left[b^o + \sum_{i=1}^p w_i^o f_i^{h_2} \left(b_i^{h_2} + \sum_{j=1}^q w_{ji}^{h_2} f_j^{h_1} \left(b_j^{h_1} + \sum_{k=1}^r w_{kj}^{h_1} X_{k(t)} \right) \right) \right] \quad (2.56) \\ &= F(X_{1(t)}, X_{2(t)}, \dots, X_{r(t)}). \end{aligned}$$

Pemetaan keseluruhan pada *Deep Neural Network* disajikan pada Persamaan (2.57).

$$\begin{bmatrix} \hat{Y}_{(1)} \\ \hat{Y}_{(2)} \\ \vdots \\ \hat{Y}_{(n)} \end{bmatrix} = \begin{bmatrix} F(X_{1(1)}, X_{2(1)}, \dots, X_{r(1)}) \\ F(X_{1(2)}, X_{2(2)}, \dots, X_{r(2)}) \\ \vdots \\ F(X_{1(n)}, X_{2(n)}, \dots, X_{r(n)}) \end{bmatrix}. \quad (2.57)$$

2.8.1 Fungsi Aktivasi

Fungsi aktifasi yang sering digunakan adalah *sigmoid*. Fungsi *sigmoid* dianggap cukup sederhana sehingga banyak digunakan pada berbagai jenis penelitian dan fungsi ini baik digunakan dalam *neural network* dengan algoritma *backpropagation*. Fungsi *sigmoid* memiliki nilai fungsi yang terletak pada 0 sampai 1 yang ditunjukkan pada sebagai berikut (Karlik & Olgac, 2011: 112).

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (2.58)$$

Fungsi aktivasi yang paling banyak digunakan untuk *output layer* adalah fungsi linier karena fungsi aktivasi non-linier dapat menyebabkan distorsi pada *output* yang ditentukan (Khashei & Bijari, 2010: 481). Persamaan fungsi aktivasi linier dimana nilai *output* sama dengan nilai *input* adalah sebagai berikut:

$$f(x) = x. \quad (2.59)$$

2.8.2 Algoritma Backpropagation

Algoritma yang paling sering digunakan analisis *time series* yaitu dengan melakukan *fitting* terhadap parameter-parameter fungsi khususnya untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron pada *hidden layer* adalah algoritma *backpropagation* dengan metode *gradient descent* (Zhang, Pawuto, & Hu, 1998: 48). Dalam melakukan *training* DNN dengan penentuan bobot misal diberikan $X_d = [X_{d_1}, X_{d_2}, \dots, X_{d_r}]^T$. Untuk memperoleh bobot digunakan formula dengan meminimumkan (Chong & Zak, 2001: 224-227).

$$\frac{1}{2} \sum_{t=1}^n (X_{d(t)} - \hat{Y}_{(t)})^2, \quad (2.60)$$

dimana $\hat{Y}_{(t)}$ merupakan *output* dari DNN pada respon dengan *input* X_{d_1}, \dots, X_{d_r} sebagai berikut:

$$\hat{Y}_{(t)} = f^o \left(b^o + \sum_{i=1}^p w_i^o f_i^{h_2} \left(b_i^{h_2} + \sum_{j=1}^q w_{ji}^{h_2} f_j^{h_1} \left(b_j^{h_1} + \sum_{k=1}^r w_{kj}^{h_1} X_{k(t)} \right) \right) \right). \quad (2.61)$$

Persamaan (2.59) digunakan untuk mendapatkan nilai $w_i^0, w_j^{h_2}$ dan $w_{kj}^{h_1}$. Simbol E digunakan sebagai fungsi objektif untuk meminimumkan yang ditunjukkan sebagai berikut:

$$E = \frac{1}{2} \sum_{t=1}^n (X_{d(t)} - \hat{Y}_{(t)})^2 \quad (2.62)$$

$$= \frac{1}{2} \sum_{t=1}^n \left(X_{d(t)} - \left(b^o + \sum_{i=1}^p w_i^o f_i^{h_2} \left(b_i^{h_2} + \sum_{j=1}^q w_{ji}^{h_2} f_j^{h_1} \left(b_j^{h_1} + \sum_{k=1}^r w_{kj}^{h_1} X_{k(t)} \right) \right) \right) \right)^2$$

Untuk menyelesaikan masalah optimasi Persamaan (2.62) digunakan algoritma *gradient* dengan ukuran langkah yang tetap. Sehingga didapatkan tiga persamaan pembaruan bobot $b^o, w_i^o, b_i^{h_2}, w_j^{h_2}, b_j^{h_1}$ dan $w_{kj}^{h_1}$ pada DNN untuk pembaruan bobot maupun bias pada *output layer*, *hidden layer 1* dan *hidden layer 2*.

a. Pembaruan bobot dan bias pada *output layer*

$$w_i^{o(s+1)} = w_i^{o(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{(s)} a_{i(t)}^{(s)}, \quad (2.63)$$

$$b^{o(s+1)} = b^{o(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{(s)}, \quad (2.64)$$

dengan

$$\delta_{(t)} = (X_{d(t)} - Y_{(t)}) f^o \left(b^o + \sum_{i=1}^p w_i^o a_{i(t)} \right). \quad (2.65)$$

b. Pembaruan bobot dan bias pada *hidden layer 2*

$$w_{ji}^{h_2(s+1)} = w_{ji}^{h_2(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[h_2](s)} a_{j(t)}^{(s)}, \quad (2.66)$$

$$b_i^{h_2(s+1)} = b_i^{h_2(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[h_2](s)}, \quad (2.67)$$

dengan

$$\delta_{(t)}^{[h_2]} = \delta_{(t)} w_i^o f_i^{h_2} \left(b_i^{h_2} + \sum_{j=1}^q w_{ij}^{h_2} a_{j(t)} \right). \quad (2.68)$$

c. Pembaruan bobot dan bias pada *hidden layer 1*

$$w_{kj}^{h_1(s+1)} = w_{kj}^{h_1(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[h_1](s)} X_{k(t)}, \quad (2.69)$$

$$b_j^{h_1(s+1)} = b_j^{h_1(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[h_1](s)}, \quad (2.70)$$

dengan

$$\delta_{(t)}^{[h_1]} = \delta_{(t)} \delta_{(t)}^{[h_2]} w_{ji}^{h_2} f_i^{h_1} \left(b_j^{h_1} + \sum_{k=1}^r w_{kj}^{h_1} X_{k(t)} \right). \quad (2.71)$$

2.9 Hibrida ARIMAX-DNN

Penggabungan model *time series* memiliki nilai akurasi peramalan yang lebih baik dibandingkan model individual. Berdasarkan penelitian *M4-Competition* oleh Makridakis, Spiliotis dan Assimakopoulus (2018b) menunjukkan bahwa metode gabungan secara rata-rata mampu meningkatkan akurasi peramalan dibanding model individual. Model hibrida terbagi menjadi tiga, yaitu *parallel*, *series* dan *parallel-series* (Hajirahimi & Khashei, 2019: 85). Model ARIMAX mampu menangkap pola linier, namun tidak mampu menangkap pola non-linier. Oleh karena itu penelitian ini menggabungkan metode ARIMAX dan *Deep Neural Network* secara *series* dengan harapan mampu menangkap pola linier dan non-linier.

Hibrida *series* terdiri dari komponen linier dan non-linier dimana komponen ini diproses secara berurutan oleh model ARIMA dan DNN. Dengan demikian, untuk menemukan pola yang tersisa yang tidak ditangkap oleh model pertama, output yang diperoleh pada tahap pertama digunakan sebagai *input* untuk model kedua. Konsep dasarnya adalah bahwa satu model tidak cukup untuk menangkap semua hubungan dalam data. Model umum dari hibrida *time series* adalah sebagai berikut (Zhang, 2003: 165).

$$Y_t = Y_t^{(l)} + Y_t^{(n)} + e_t \quad (2.72)$$

dengan

$Y_t^{(l)}$: komponen linier,

$Y_t^{(n)}$: komponen non-linier.

Model ARIMAX pada model hibrida bertujuan untuk menyelesaikan kasus model linier, dimana nilai residual model terdapat hubungan non-linier. Persamaan residual model ditunjukkan sebagai berikut:

$$a_t = Y_t - \hat{Y}_t^{(l)}, \quad (2.73)$$

dengan $\hat{Y}_t^{(l)}$ adalah nilai ramalan model linier pada waktu ke- t , DNN akan memodelkan residual seperti persamaan berikut:

$$a_t = f(a_{t-1}, a_{t-2}, \dots, a_{t-p}) + e_t = \hat{Y}_t^{(n)} + e_t, \quad (2.74)$$

dengan $f(\cdot)$ adalah fungsi non-linier dari model DNN dan e_t adalah residual dari model DNN. Sehingga nilai ramalan model hibrida ARIMAX-DNN ditunjukkan pada Persamaan (2.75).

$$\hat{Y}_t = \hat{Y}_t^{(l)} + \hat{Y}_t^{(n)}. \quad (2.75)$$

2.10 Evaluasi Model

Penelitian ini menggunakan 3 model yaitu ARIMAX, *Deep Neural Network* dan hibrida ARIMAX *Deep Neural Network*. Model yang tepat untuk *in-sample* belum tentu menghasilkan nilai kebaikan model yang tinggi pada data *out-sample* (Makridakis dkk., 2018a: 19). Oleh karena itu pada penelitian ini memilih model terbaik berdasarkan data *out-sample*. Seringkali RMSE lebih dipilih dibandingkan MSE jika data yang digunakan memiliki skala yang sama. Umumnya RMSE sangat sering digunakan karena relevan dengan pemodelan statistik (Hyndman & Koehler, 2006: 682). Persamaan RMSE ditunjukkan pada Persamaan (2.76).

$$RMSE = \sqrt{\frac{1}{L} \sum_{l=1}^L (Y_{n+l} - \hat{Y}_n(l))^2}. \quad (2.76)$$

Akan tetapi, RMSE sangat sensitif jika terdapat data *outlier*. Sehingga digunakan ukuran kebaikan model lainnya yaitu sMAPE dikarenakan sMAPE lebih stabil jika terdapat data *outlier* (Makridakis, 1993: 529). Penggunaan ukuran kebaikan model sMAPE jika menghindari nilai *error* yang besar ketika terdapat data aktual yang mendekati 0 (Makridakis & Hibon, 2000: 461). Persamaan sMAPE ditunjukkan sebagai berikut:

$$sMAPE = \left(\frac{1}{L} \sum_{l=1}^L \frac{2|Y_{n+l} - \hat{Y}_n(l)|}{(Y_{n+l} + \hat{Y}_n(l))} \right) \times 100\%, \quad (2.77)$$

dengan

Y_{n+l} : data *out of sample* yang ke- l ,

$\hat{Y}_n(l)$: ramalan untuk data *out of sample* yang ke- l ,

L : panjang data *out of sample*.

2.11 Uang Kartal

Uang adalah suatu benda yang dapat ditukarkan dengan benda lain dan dapat disimpan. Uang dalam bentuk fisik, yaitu uang tunai yang berupa uang kertas dan uang logam yang beredar di masyarakat. Uang tunai adalah uang yang ada di tangan masyarakat (di luar bank umum) dan siap dibelanjakan setiap saat, terutama untuk pembayaran-pembayaran dalam jumlah yang tidak terlalu besar. Uang tunai tersebut sering disebut sebagai uang kartal yang terdiri dari uang kertas dan uang logam. Uang kartal beredar di masyarakat berfungsi sebagai otoritas moneter. Dengan uang kartal masyarakat dapat melakukan pembayaran tunai secara langsung (Solikin & Suseno, 2002).

Transaksi penarikan uang rupiah (*outflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang keluar dari bank sentral kepada perbankan dan masyarakat, terdiri dari penarikan bank umum, penarikan non-bank, kas keliling dalam rangka penukaran, penarikan dalam rangka kas titipan di bank umum, dan penarikan lainnya. Sedangkan transaksi penyetoran uang rupiah (*inflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang masuk dari perbankan dan masyarakat ke bank sentral, terdiri dari setoran bank umum, setoran bank umum, setoran non-ban, kas keliling dalam rangka hasil penukaran, penyetoran dalam rangka kas titipan di bank umum, dan penyetoran lainnya. Selisih transaksi penarikan/penyetoran uang rupiah merupakan selisih antara transaksi penyetoran uang rupiah (*inflow*) dan transaksi penarikan uang rupiah (*outflow*) (Bank Indonesia, 2016: 1-2).

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang merupakan data *inflow* dan *outflow* uang kartal Bank “X” di Jawa Timur dengan periode bulanan mulai bulan Januari 2010 hingga Juni 2019. Data akan dibagi menjadi data *in-sample* dan *out-sample*. Data *in-sample* yang digunakan yaitu data Januari 2010 hingga Desember 2017, sedangkan data *out-sample* yaitu data Januari 2018 hingga Juni 2019.

3.2 Variabel Penelitian

Variabel yang digunakan dalam penelitian ini adalah uang kertas pecahan dan total *inflow* maupun *outflow* di empat KPw Jawa Timur yang ditunjukkan pada Tabel 3.1.

Tabel 3.1 Variabel Penelitian

Variabel	<i>Inflow</i>	Variabel	<i>Outflow</i>
$Y_{1,t}^{(i)}$	Total	$Y_{9,t}^{(i)}$	Total
$Y_{2,t}^{(i)}$	Rp100.000,00	$Y_{10,t}^{(i)}$	Rp100.000,00
$Y_{3,t}^{(i)}$	Rp50.000,00	$Y_{11,t}^{(i)}$	Rp50.000,00
$Y_{4,t}^{(i)}$	Rp20.000,00	$Y_{12,t}^{(i)}$	Rp20.000,00
$Y_{5,t}^{(i)}$	Rp10.000,00	$Y_{13,t}^{(i)}$	Rp10.000,00
$Y_{6,t}^{(i)}$	Rp5.000,00	$Y_{14,t}^{(i)}$	Rp5.000,00
$Y_{7,t}^{(i)}$	Rp2.000,00	$Y_{15,t}^{(i)}$	Rp2.000,00
$Y_{8,t}^{(i)}$	Rp1.000,00	$Y_{16,t}^{(i)}$	Rp1.000,00

Tabel 3.1 menunjukkan variabel *inflow* dan *outflow* untuk KPw_{*i*} dengan *i*=1,2,3,4 dimana KPw₁ adalah Jember, KPw₂ adalah Kediri, KPw₃ adalah Malang dan KPw₄ adalah Surabaya. Sedangkan untuk variabel *dummy* dapat ditunjukkan pada Tabel 3.2.

Tabel 3.2 Variabel *Dummy*

<i>Dummy</i>	Keterangan
Tren	$t = 1, 2, 3, \dots, n$
Musiman	$M_{i,t} = \begin{cases} 1 & \text{untuk bulan ke } i, i=1, 2, \dots, 12 \\ 0 & \text{lainnya} \end{cases}$
Variasi Kalender (Idul Fitri)	$V_{j,t-1} = \begin{cases} 1 & \text{untuk minggu ke } j \text{ satu bulan sebelum Idul Fitri} \\ 0 & \text{lainnya} \end{cases}$
	$V_{j,t} = \begin{cases} 1 & \text{untuk minggu ke } j \text{ ketika bulan Idul Fitri} \\ 0 & \text{lainnya} \end{cases}$
	$V_{j,t+1} = \begin{cases} 1 & \text{untuk minggu ke } j \text{ satu bulan setelah Idul Fitri} \\ 0 & \text{lainnya} \end{cases}$

Pola variasi kalender pada data mengikuti terjadinya Idul Fitri dengan ketentuan minggu ke-1 adalah tanggal 1 sampai 7, minggu ke-2 adalah tanggal 8 sampai 15, minggu ke-3 adalah tanggal 16 sampai 23 dan minggu ke-4 adalah tanggal 24 sampai akhir. Data terjadinya Idul Fitri dari tahun 2010 hingga 2020 disajikan pada Tabel 3.3.

Tabel 3.3 Daftar Idul Fitri Tahun 2010-2020

Tahun	Tanggal Idul Fitri	Minggu ke- j	Variabel <i>Dummy</i>		
			$V_{j,t-1}$	$V_{j,t}$	$V_{j,t+1}$
2010	10-11 Sept	2	Agustus	September	Oktober
2011	30-31 Agust	4	Juli	Agustus	September
2012	19-20 Agust	3	Juli	Agustus	September
2013	08-09 Agust	2	Juli	Agustus	September
2014	28-29 Juli	4	Juni	Juli	Agustus
2015	17-18 Juli	3	Juni	Juli	Agustus
2016	06-07 Juli	1	Juni	Juli	Agustus
2017	26-27 Juni	4	Mei	Juni	Juli
2018	15-16 Juni	3	Mei	Juni	Juli
2019	3-4 Juni	1	Mei	Juni	Juli
2020	23-24 Mei	4	April	Mei	Juni

3.3 Langkah Analisis

Penelitian ini dilakukan beberapa tahapan untuk meramalkan *inflow* dan *outflow* di Jawa Timur yaitu sebagai berikut:

1. Mendeskripsikan karakteristik data pada *inflow* maupun *outflow* untuk setiap KPw di Provinsi Jawa Timur melalui statistika deskriptif maupun secara visual dengan diagram.
2. Membagi data menjadi dua, yaitu data *in-sample* dan data *out-sample*. Data *in-sample* yaitu mulai Januari 2010 hingga Desember 2017, sedangkan data *out-sample* yaitu mulai Januari 2018 hingga Juni 2019.
3. Melakukan pemodelan dan peramalan untuk semua pecahan uang kertas dan total *inflow* maupun *outflow* di setiap KPw menggunakan metode ARIMAX dengan langkah sebagai berikut:
 - a. Meregresikan variabel respon dengan semua variabel *dummy* yang digunakan. Pemodelan menggunakan regresi *time series* tidak menggunakan konstanta dikarenakan agar memudahkan interpretasi model dengan variabel *dummy* bulan sejumlah 12.
 - i. Meregresikan *inflow* dengan variabel *dummy* tren, musiman, variasi kalender bulan Idul Fitri dan satu bulan setelah Idul Fitri. Hasil dari pemodelan regresi *time series* ini membentuk persamaan untuk data *inflow* yang ditunjukkan pada Persamaan (3.1).

$$Y_t = \beta_1 t + \sum_{i=1}^{12} \alpha_i M_{i,t} + \sum_{j=1}^4 \gamma_j V_{j,t} + \sum_{j=1}^4 \omega_j V_{j,t+1} + \varepsilon_t. \quad (3.1)$$
 - ii. Meregresikan *outflow* dengan variabel *dummy* tren, musiman, variasi kalender bulan Idul Fitri dan satu bulan sebelum Idul Fitri. Hasil dari pemodelan regresi *time series* ini membentuk persamaan untuk data *outflow* yang ditunjukkan pada Persamaan (3.2).

$$Y_t = \beta_1 t + \sum_{i=1}^{12} \alpha_i M_{i,t} + \sum_{j=1}^4 \gamma_j V_{j,t} + \sum_{j=1}^4 \omega_j V_{j,t-1} + \varepsilon_t. \quad (3.2)$$

- c. Melakukan cek diagnosa pada residual regresi *time series*, jika memenuhi asumsi *white noise* maka dilanjutkan dengan peramalan menggunakan model regresi *time series*. Namun jika belum memenuhi asumsi maka dilanjutkan ke langkah selanjutnya.
 - d. Melakukan pemodelan ARIMA dengan identifikasi melalui orde ACF dan PACF pada residual regresi *time series*.
 - e. Melakukan cek diagnosa kembali pada residual model ARIMAX.
 - f. Melakukan peramalan dengan model ARIMAX dan mendapatkan nilai RMSE maupun sMAPE.
4. Melakukan pemodelan dan peramalan data *inflow* dan *outflow* untuk setiap pecahan menggunakan metode *Deep Neural Network* dengan langkah sebagai berikut:
- a. Menentukan variabel *input* berdasarkan variabel komponen tren, musiman dan kalender variasi pada ARIMAX serta lag variabel respon berdasarkan plot PACF yang signifikan.
 - b. Melakukan *preprocessing* data menggunakan normalisasi. Terdapat tiga jenis *preprocessing* yaitu normalisasi, standarisasi dan adj normalisasi. Jika *input* neuron sebanyak 1-5, maka *preprocessing* menggunakan ketiga jenis tersebut tidak memiliki perbedaan yang cukup signifikan (Suhartono dkk., 2018: 7). Persamaan normalisasi ditunjukkan sebagai berikut:

$$Y_t^* = \frac{Y_t - \min(Y_t)}{\max(Y_t) - \min(Y_t)}. \quad (3.3)$$

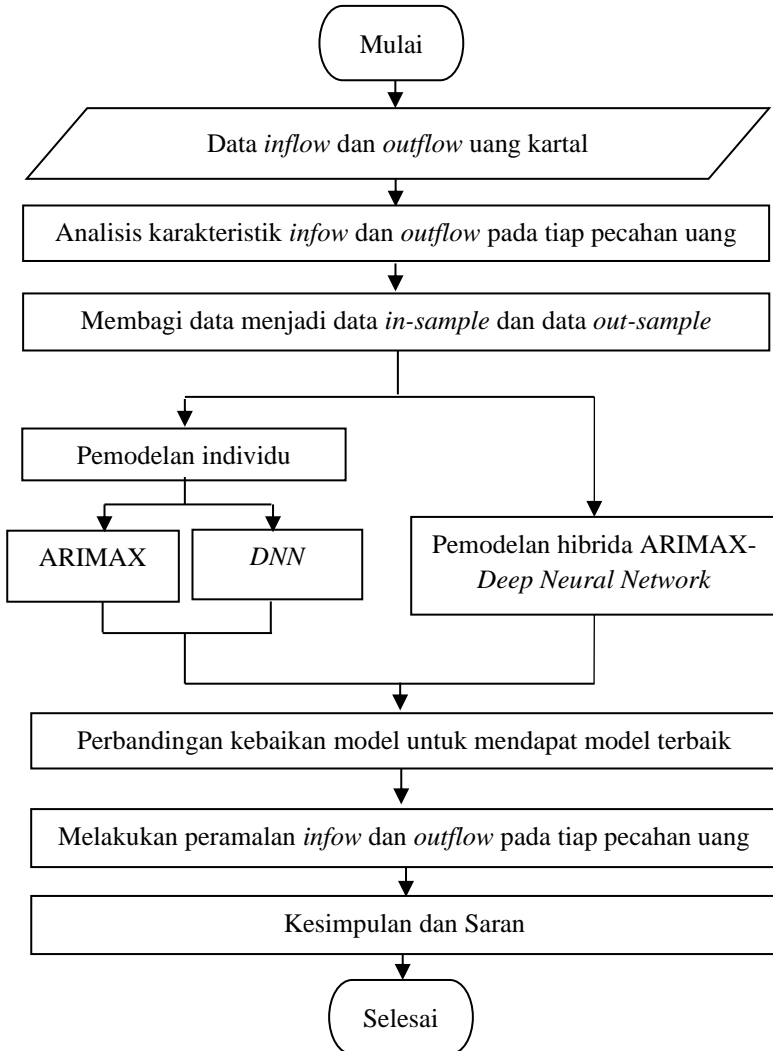
- c. Menentukan banyak *input*, jumlah neuron dalam *hidden layer*, bobot awal dan fungsi aktivasi.
- d. Melakukan peramalan dengan arsitektur *Deep Neural Network* dan mendapatkan nilai RMSE maupun sMAPE.
- e. Melakukan *postprocessing* data yang ditunjukkan pada Persamaan (3.4).

$$Y_t = Y_t^* (\max(Y_t) - \min(Y_t)) + \min(Y_t). \quad (3.4)$$

5. Melakukan pemodelan dan peramalan data *inflow* dan *outflow* untuk setiap pecahan menggunakan metode hibrida *series* dengan langkah sebagai berikut:
 - a. Melakukan pemodelan ARIMAX pada data *inflow* maupun *outflow*.
 - b. Melakukan normalisasi pada lag pada residual yang akan digunakan sebagai *input* pemodelan DNN.
 - c. Menggunakan dua jenis input lag, input lag yang pertama adalah menggunakan orde AR pada model ARIMAX. Sedangkan input lag yang kedua adalah lag 1,12,35 sebagai justifikasi tren, musiman dan variasi kalender.
 - d. Menggabungkan model ARIMAX dan DNN menjadi model hibrida ARIMAX-DNN.
 - e. Melakukan *postprocessing* data.
6. Membandingkan model ARIMAX, *Deep Neural Network* dan hibrida *series* ARIMAX-DNN dan memilih model terbaik berdasarkan nilai RMSE dan sMAPE pada data *out-sample*.
7. Mendapatkan hasil peramalan untuk semua pecahan dan total *inflow* maupun *outflow* di setiap KPw Provinsi Jawa Timur.

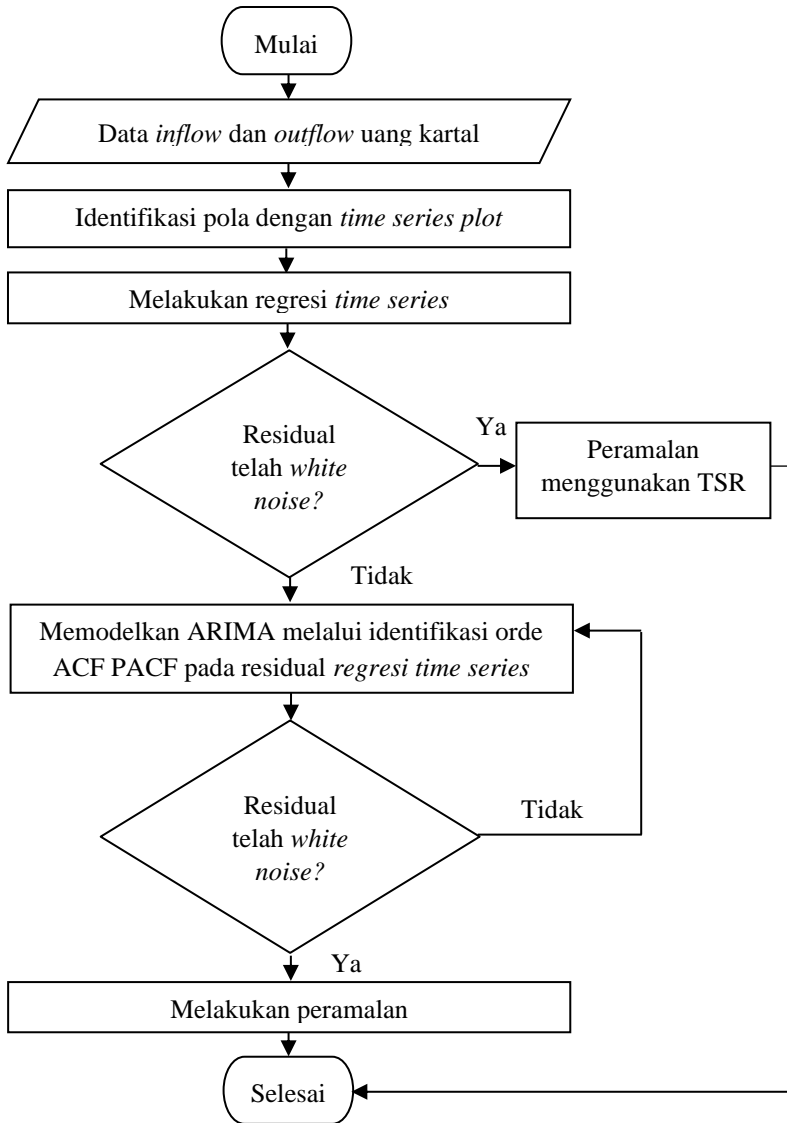
3.4 Diagram Alir Penelitian

Berdasarkan langkah analisis yang telah diuraikan, diagram alir pada penelitian ini adalah sebagai berikut:



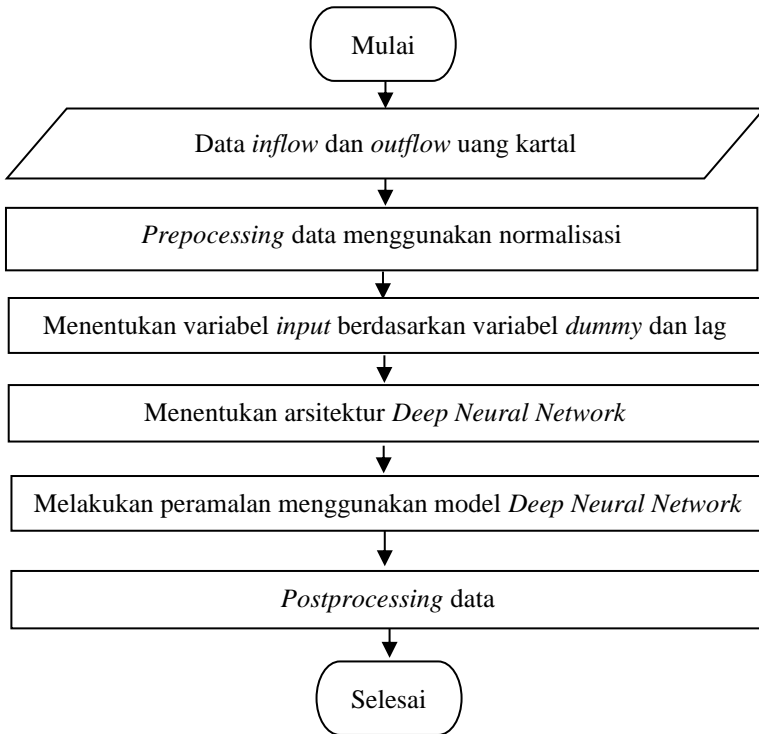
Gambar 3.1 Diagram Alir Penelitian

Langkah analisis pemodelan ARIMAX yaitu sebagai berikut:




Gambar 3.2 Diagram Alir ARIMAX

Langkah analisis pemodelan *Deep Neural Network* dapat digambarkan dengan diagram alir pada Gambar 3.3.




Gambar 3. 3 Diagram Alir *Deep Neural Network*

Proses pemodelan ARIMAX dapat digambarkan pada Gambar 3.4.



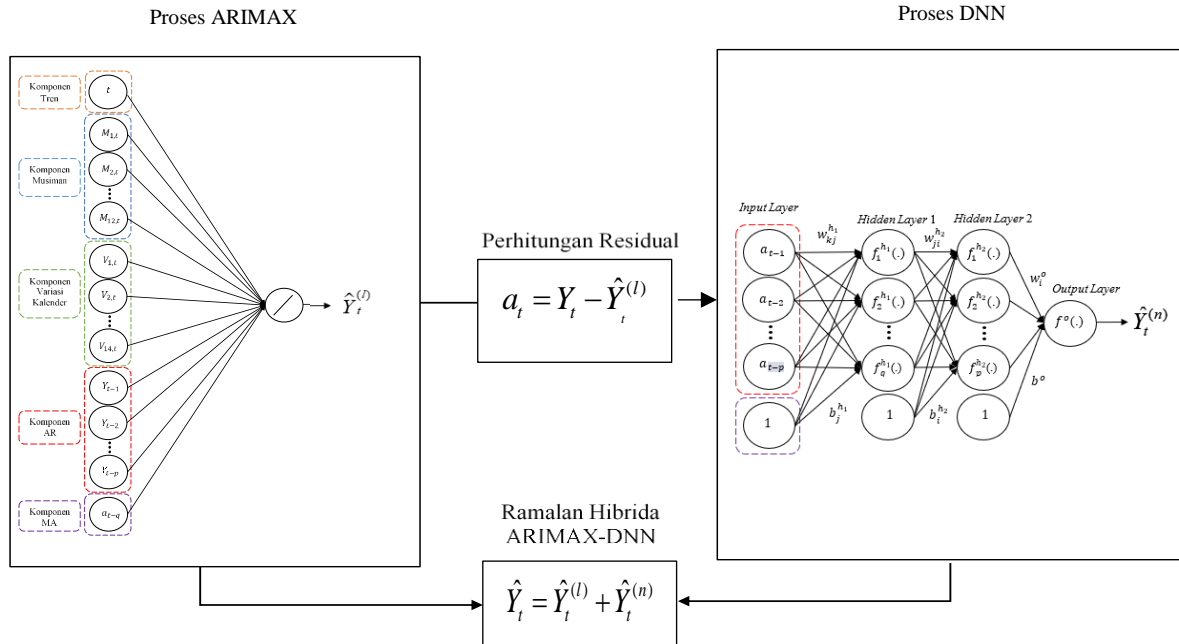
Gambar 3.4 Proses ARIMAX

Proses pemodelan *Deep Neural Network* dapat digambarkan pada Gambar 3.5.



Gambar 3.5 Proses *Deep Neural Network*

Proses pemodelan Hibrida *Series* ARIMAX-DNN dapat digambarkan pada Gambar 3.6.



Gambar 3.6 Proses Hibrida *Series* ARIMAX-DNN

(Halaman ini sengaja dikosongkan)

BAB IV ANALISIS DAN PEMBAHASAN

4.1 Karakteristik *Inflow* dan *Outflow* di Provinsi Jawa Timur


Analisis deskriptif dilakukan untuk mengetahui gambaran umum data *inflow* dan *outflow* pada bulan Januari 2010 hingga Juni 2019 di 4 KPw yang tersebar di Provinsi Jawa Timur yaitu KPw Jember, KPw Kediri, KPw Malang dan KPw Surabaya.

Tabel 4.1 Statistika Deskriptif Total Pecahan Uang Kertas

KPw	Data	Mean	StDev	Min	Max
Jember	<i>Inflow</i>	855	530	172	3.059
	<i>Outflow</i>	665	572	5.2	3.352
Kediri	<i>Inflow</i>	999	700	159	3.622
	<i>Outflow</i>	1.153	935	38	5.745
Malang	<i>Inflow</i>	1.143	564	267	3.327
	<i>Outflow</i>	701	661	5.9	3.753
Surabaya	<i>Inflow</i>	2.740	1.806	463	10.609
	<i>Outflow</i>	2.658	2.032	322	11.756

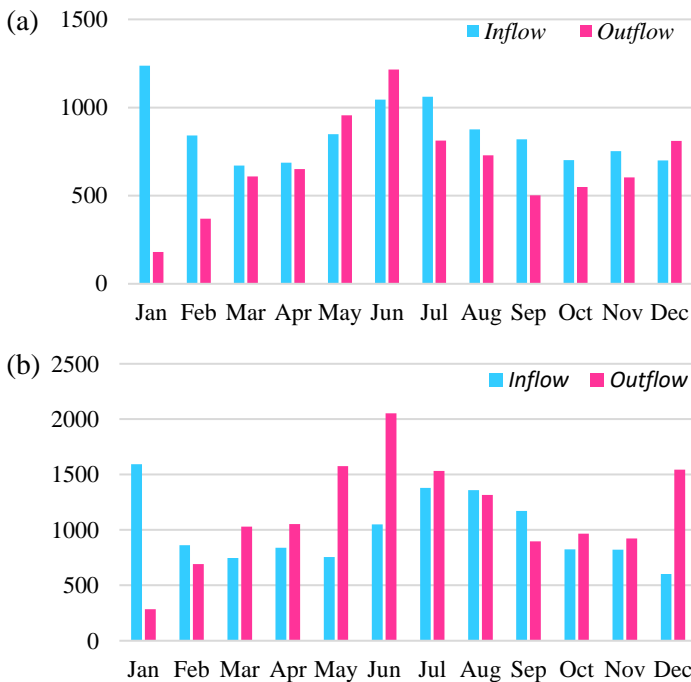
Berdasarkan Tabel 4.1 diketahui jika rata-rata *inflow* tertinggi adalah di KPw Surabaya sebesar 2.740 miliar rupiah dengan nilai standar deviasi 1.806, lalu diikuti oleh KPw Malang sebesar 1.143 miliar rupiah dengan standar deviasi 564, KPw Kediri 999 miliar rupiah dengan standar deviasi 700 dan rata-rata *inflow* terendah yaitu di KPw Jember sebesar 855 miliar rupiah dengan standar deviasi 530. Sama halnya dengan rata-rata *inflow*, rata-rata *outflow* yang tertinggi adalah KPw Surabaya sebesar 2.658 miliar rupiah dan yang terendah juga KPw Jember yaitu sebesar 665 miliar rupiah. Sedangkan untuk KPw Kediri memiliki rata-rata sebesar 1.153 miliar rupiah dimana nilai ini lebih unggul dibandingkan KPw Malang yaitu sebesar 701 miliar rupiah dengan standar deviasi sebesar 661. Karakteristik *inflow* dan *outflow* pada tiap

KPw dijelaskan lebih lanjut sebagai berikut: Plot *time series* digunakan untuk mengetahui pola yang terbentuk dari data *inflow* maupun *outflow* yang ditunjukkan pada Gambar 4.1.

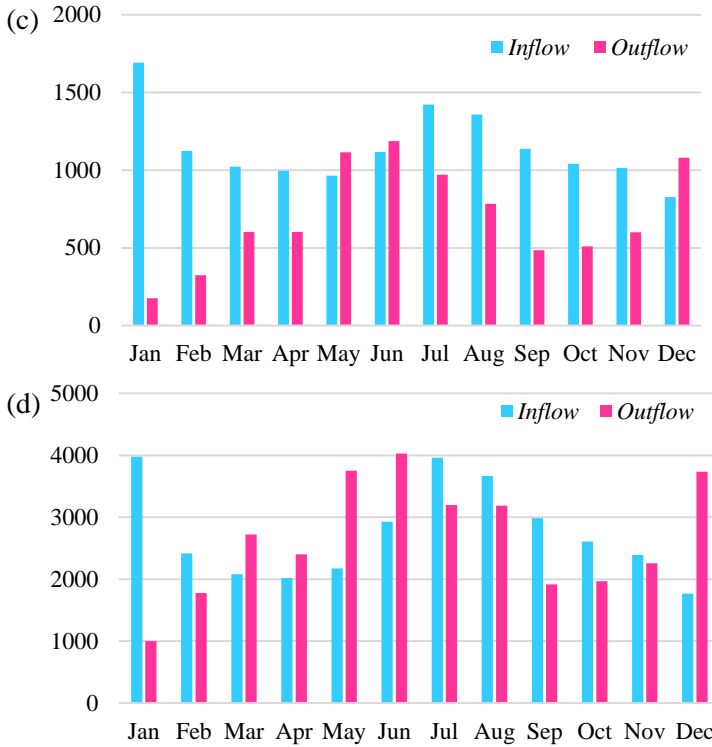


Gambar 4.1 Plot *Time Series Inflow* dan *Outflow* Total Uang Kertas di (a) KPw Jember, (b) KPw Kediri, (c) KPw Malang dan (d) KPw Surabaya

Gambar 4.1 menunjukkan pola data *inflow* maupun *outflow* memiliki tren yang selalu meningkat. Garis hijau pada plot menunjukkan hari terjadinya Idul Fitri, sedangkan titik warna biru menunjukkan Idul Fitri yang terjadi di minggu pertama, warna kuning menunjukkan Idul Fitri di minggu kedua, warna ungu menunjukkan Idul Fitri di minggu ketiga dan hijau menunjukkan Idul Fitri di minggu keempat. Ketika Idul Fitri terjadi pada minggu keempat, total *inflow* uang kertas memiliki jumlah yang sedikit, namun total *outflow* uang kertas memiliki jumlah yang banyak. Selanjutnya untuk mengetahui pergerakan rata-rata peredaran total uang kertas setiap bulannya di keempat KPw yang tersebar di Provinsi Jawa Timur ditunjukkan pada Gambar 4.2.



Gambar 4.2 Rata-Rata *Inflow* dan *Outflow* Total Uang Kertas dalam Bulan di (a) KPw Jember, (b) KPw Kediri, (c) KPw Malang dan (d) KPw Surabaya

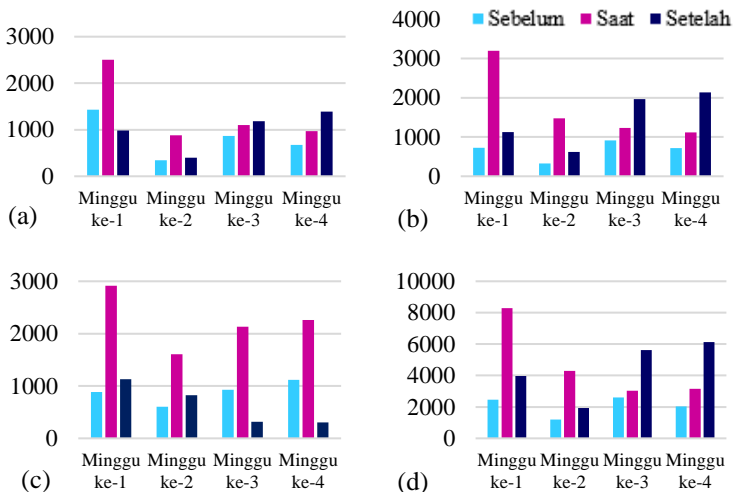


Gambar 4.2 Rata-Rata *Inflow* dan *Outflow* Total Uang Kertas dalam Bulan di (a) KPw Jember, (b) KPw Kediri, (c) KPw Malang dan (d) KPw Surabaya (Lanjutan)

Berdasarkan Gambar 4.2 dapat diketahui jika *inflow* total uang kertas tertinggi di keempat KPw yang ada di Provinsi Jawa Timur terjadi pada bulan Januari, Juni, Juli dan Agustus. Hal ini diduga karena pada bulan Desember masyarakat merayakan tahun baru dan natal, sehingga pada bulan Januari cenderung menyetorkan uangnya ke Bank. Sedangkan pada bulan Juni, Juli dan Agustus merupakan bulan yang berkaitan dengan terjadinya Idul Fitri. Rata-rata *outflow* total uang kertas tertinggi baik di KPw Jember, KPw Kediri, KPw Malang dan KPw Surabaya yaitu pada bulan Mei, Juni, Juli dan Desember. Sama halnya dengan rata-rata *inflow*,

bulan Mei, Juni dan Juli merupakan bulan yang berkaitan dengan Idul Fitri. Pada bulan Desember, masyarakat cenderung mengambil uangnya di Bank sebelum merayakan natal atau tahun baru.

Diagram batang pada Gambar 4.2 menunjukkan adanya pengaruh yang signifikan Idul Fitri terhadap pergerakan *inflow* maupun *outflow* total uang kertas di tiap KPw yang ada di Provinsi Jawa Timur. Pada penelitian sebelumnya juga menunjukkan adanya pengaruh Idul Fitri berkaitan dengan minggu terjadinya Idul Fitri. Rata-rata *inflow* pada saat dan satu bulan setelah Idul Fitri ditunjukkan pada Gambar 4.3.



Gambar 4.3 Rata-Rata *Inflow* Total Uang Kertas Menurut Minggu Idul Fitri di (a)KPw Jember, (b)KPw Kediri, (c)KPw Malang dan (d)KPw Surabaya


Gambar 4.3 menunjukkan rata-rata kenaikan *inflow* total pecahan kertas di keempat KPw yang ada di Provinsi Jawa Timur pada periode Januari 2010 hingga Juni 2019. Kenaikan *inflow* berdasarkan minggu Idul Fitri memiliki pola sebagai berikut:

1. Apabila Idul Fitri terjadi pada minggu pertama, maka rata-rata *inflow* memiliki nilai yang sangat tinggi pada bulan terjadinya Idul Fitri dan menurun pada satu bulan setelah Idul Fitri. Rata-rata *inflow* total uang kertas pada minggu pertama di KPw Jember yaitu sebesar 2.501 miliar rupiah dan menurun pada bulan selanjutnya yaitu dengan rata-rata sebesar 982,04 miliar rupiah dimana nilai ini menurun lebih dari dua kali lipat. Tercatat di KPw Kediri rata-rata *inflow* total uang kertas pada bulan Idul Fitri yaitu 3.196 miliar rupiah, di KPw Malang sebesar 2.915 miliar rupiah dan di KPw Surabaya sebesar 2.915 miliar rupiah. Sedangkan pada satu bulan setelah Idul Fitri di KPw Kediri sebesar 1.122,8 miliar rupiah, di KPw Malang sebesar 1.130,5 miliar rupiah dan KPw Surabaya sebesar 3.961,7 miliar rupiah.
2. Apabila Idul Fitri terjadi pada minggu kedua, maka rata-rata *inflow* memiliki nilai yang lebih tinggi dibandingkan satu bulan setelah Idul Fitri. Rata-rata *inflow* total uang kertas pada minggu kedua di KPw Jember yaitu sebesar 880 miliar rupiah, sedangkan satu bulan setelahnya memiliki rata-rata sebesar 396 miliar rupiah. Pada bulan Idul Fitri di KPw Kediri memiliki rata-rata sebesar 1.476 miliar rupiah dan bulan setelahnya sebesar 618 miliar rupiah, sedangkan di KPw Malang memiliki rata-rata sebesar 1.609 miliar rupiah dan bulan setelahnya sebesar 823 miliar rupiah. Untuk KPw Surabaya memiliki rata-rata *inflow* pada saat Idul Fitri sebesar 4.290 miliar rupiah dan bulan setelah Idul Fitri sebesar 1.929,1 miliar rupiah.
3. Apabila Idul Fitri terjadi pada minggu ketiga, maka rata-rata *inflow* memiliki nilai yang hampir sama dengan satu bulan setelah Idul Fitri. Rata-rata *inflow* total uang kertas pada minggu ketiga sebesar 1.101 miliar rupiah dan pada bulan selanjutnya memiliki rata-rata yang tidak jauh berbeda yaitu

sebesar 1.186 miliar rupiah. KPw Kediri memiliki rata-rata *inflow* pada bulan Idul Fitri sebesar 1.229 miliar rupiah dan bulan selanjutnya sebesar 1.965 miliar rupiah, KPw Malang memiliki rata-rata *inflow* pada bulan Idul Fitri sebesar 2.133 miliar rupiah dan bulan selanjutnya sebesar 315,9 miliar rupiah. Sedangkan pada KPw Surabaya memiliki rata-rata sebesar 3.035 miliar rupiah dan bulan selanjutnya sebesar 5.611 miliar rupiah.

4. Apabila Idul Fitri terjadi pada minggu keempat, maka rata-rata *inflow* akan tinggi pada satu bulan setelah terjadinya Idul Fitri. Tercatat rata-rata *inflow* pada saat terjadinya Idul Fitri di minggu keempat sebesar 970 miliar rupiah dan satu bulan setelah Idul Fitri memiliki rata-rata sebesar 1.393 miliar rupiah. Sedangkan di KPw Kediri memiliki rata-rata *inflow* uang kertas pada bulan Idul Fitri sebesar 1.113 miliar rupiah dan bulan selanjutnya sebesar 2.134 miliar rupiah. Untuk KPw Malang memiliki rata-rata sebesar 2.263 miliar rupiah dan bulan selanjutnya sebesar 302,2 miliar rupiah. KPw Surabaya memiliki rata-rata sebesar 3.163 miliar rupiah dan bulan selanjutnya meningkat tajam menjadi 6.129 miliar rupiah.

Pola kenaikan *outflow* memiliki perbedaan dengan pola kenaikan *inflow*. *Outflow* dipengaruhi oleh bulan terjadinya Idul Fitri dan satu bulan sebelum terjadinya Idul Fitri karena masyarakat cenderung menarik uang sebelum merayakan Idul Fitri. Untuk lebih jelasnya ditunjukkan pada Gambar 4.4.



Gambar 4.4 Rata-Rata *Outflow* Total Uang Kertas Menurut Minggu Idul Fitri di (a)KPw Jember, (b)KPw Kediri, (c)KPw Malang dan (d)KPw Surabaya

Berdasarkan Gambar 4.4 diketahui rata-rata kenaikan *outflow* total pecahan kertas di keempat KPw yang ada di Provinsi Jawa Timur pada periode Januari 2010 hingga Juni 2019. Kenaikan *outflow* berdasarkan minggu Idul Fitri memiliki pola sebagai berikut:

1. Apabila Idul Fitri terjadi pada minggu pertama, maka rata-rata *outflow* memiliki nilai yang sangat rendah pada bulan terjadinya Idul Fitri dan pada satu bulan sebelum terjadinya Idul Fitri memiliki nilai yang sangat tinggi. Rata-rata *inflow* total uang kertas di KPw Jember pada satu bulan sebelum Idul Fitri yaitu sebesar 2968 miliar rupiah dan menurun hingga 6 kali lipat pada bulan terjadinya Idul Fitri yaitu dengan rata-rata sebesar 480 miliar rupiah. Tercatat di KPw Kediri rata-rata *inflow* total uang kertas pada bulan Idul Fitri yaitu 668 miliar rupiah, di KPw Malang sebesar 434,6 miliar rupiah dan di KPw Surabaya sebesar 1.344,3 miliar rupiah. Sedangkan

pada satu bulan sebelum Idul Fitri di KPw Kediri sebesar 4.819 miliar rupiah, di KPw Malang sebesar 1.130,5 miliar rupiah dan KPw Surabaya sebesar 3.961,7 miliar rupiah.

2. Apabila Idul Fitri terjadi pada minggu kedua, maka rata-rata *outflow* memiliki nilai yang hampir sama dengan satu bulan sebelum Idul Fitri. Rata-rata *outflow* total uang kertas di KPw Jember pada minggu kedua sebesar 488 miliar rupiah dan pada bulan sebelumnya memiliki rata-rata yang tidak jauh berbeda yaitu sebesar 797 miliar rupiah. Pada bulan Idul Fitri di KPw Kediri memiliki rata-rata sebesar 668 miliar rupiah dan bulan sebelumnya sebesar 4.819 miliar rupiah, sedangkan di KPw Malang memiliki rata-rata sebesar 434,6 miliar rupiah dan bulan setelahnya sebesar 648,49 miliar rupiah. Untuk KPw Surabaya memiliki rata-rata *inflow* pada saat Idul Fitri sebesar 1.3443,3 miliar rupiah dan bulan setelah Idul Fitri sebesar 1.602,6 miliar rupiah.
3. Apabila Idul Fitri terjadi pada minggu ketiga, maka rata-rata *outflow* memiliki nilai yang lebih tinggi dibandingkan satu bulan sebelum Idul Fitri. Rata-rata *outflow* total uang kertas pada minggu ketiga yaitu sebesar 1.761 miliar rupiah, sedangkan satu bulan sebelumnya memiliki rata-rata yang lebih kecil yaitu sebesar 1.032 miliar rupiah. KPw Kediri memiliki rata-rata *outflow* pada bulan Idul Fitri sebesar 3.563 miliar rupiah dan bulan sebelumnya sebesar 1.519 miliar rupiah, KPw Malang memiliki rata-rata *outflow* pada bulan Idul Fitri sebesar 2.133 miliar rupiah dan bulan sebelumnya sebesar 927 miliar rupiah. Sedangkan pada KPw Surabaya memiliki rata-rata sebesar 7.074 miliar rupiah dan bulan sebelumnya sebesar 3.641 miliar rupiah.
4. Apabila Idul Fitri terjadi pada minggu keempat, maka rata-rata *outflow* akan tinggi pada saat terjadinya Idul Fitri. Tercatat rata-rata *outflow* pada saat terjadinya Idul Fitri di

minggu keempat sebesar 1813 miliar rupiah dan satu bulan sebelum Idul Fitri memiliki rata-rata yang rendah yaitu sebesar 904 miliar rupiah. Sedangkan di KPw Kediri memiliki rata-rata *outflow* uang kertas pada bulan Idul Fitri sebesar 3.023 miliar rupiah dan bulan sebelumnya sebesar 1.438 miliar rupiah. Untuk KPw Malang memiliki rata-rata sebesar 2263 miliar rupiah dan bulan sebelumnya sebesar 1.120 miliar rupiah. KPw Surabaya memiliki rata-rata sebesar 6336 miliar rupiah dan bulan sebelumnya sebesar 3.815 miliar rupiah.

Uang kartal terdiri dari uang logam dan uang kertas dimana pada penelitian ini menggunakan pecahan uang kertas dan total jumlah uang kertas. Berikut adalah statistika deskriptif mengenai *inflow* maupun *outflow* tiap pecahan di empat KPw yang tersebar di Provinsi Jawa Timur.


4.1.1 Karakteristik *Inflow* dan *Outflow* di Kantor Perwakilan Jember

Kantor Perwakilan Jember memiliki wilayah kerja di Banyuwangi, Bondowoso, Jember dan Situbondo. Berikut adalah statistika deskriptif *inflow* dan *outflow* pecahan uang kertas di KPw Jember.

Tabel 4.2 Statistika Deskriptif Pecahan Uang Kertas di KPw Jember

Pecahan	<i>Inflow</i>		<i>Outflow</i>	
	Mean	StDev	Mean	StDev
100.000	477	321,1	394,2	343,1
50.000	326,7	175,1	236,7	193,4
20.000	13,443	8,889	11,5	18,02
10.000	11,568	8,471	10,42	19,57
5.000	8,382	6,687	8,48	19,23
2.000	3,186	2,844	3,78	8,271
1.000	0,613	0,661	0,23	0,463

Tabel 4.2 menunjukkan bahwa semakin besar pecahan maka nilai rata-rata *inflow* dan *outflow* juga semakin besar. Begitu pula dengan nilai standar deviasi, hanya saja *outflow* uang kertas pecahan Rp20.000 memiliki nilai standar deviasi yang lebih kecil dibandingkan *outflow* uang kertas pecahan Rp10.000. Pola dari data tiap pecahan ditunjukkan pada plot *time series* berikut:



Gambar 4.5 Plot *Time Series* (a)*Inflow* dan (b)*Outflow* di KPw Jember

Berdasarkan Gambar 4.5 menunjukkan plot *time series* periode Januari 2010 hingga Juni 2019. Pada plot *time series* untuk tiap pecahan memiliki tren naik, akan tetapi pada uang kertas pecahan Rp1.000 setiap tahunnya mengalami penurunan. Hal ini diduga karena pada tahun 2009 terdapat percetakan uang logam Rp1.000, akan tetapi uang kertas Rp1.000 tidak ditarik dari peredaran masyarakat. Oleh karena itu semakin bertambahnya tahun, penggunaan uang kertas Rp1.000 semakin berkurang. Pada semua plot *time series* juga memiliki puncak tinggi pada waktu-waktu tertentu yaitu pada periode lebaran.

4.1.2 Karakteristik *Inflow* dan *Outflow* di Kantor Perwakilan Kediri


Kantor Perwakilan Kediri memiliki wilayah kerja di Blitar, Kediri, Madiun, Magetan, Nganjuk, Ngawi, Pacitan, Ponorogo, Trenggalek dan Tulungagung. Statistika deskriptif dari *inflow* dan *outflow* pecahan uang kertas di KPw Kediri ditunjukkan Tabel 4.3.

Tabel 4.3 Statistika Deskriptif Pecahan Uang Kertas di KPw Kediri

Pecahan	<i>Inflow</i>		<i>Outflow</i>	
	Mean	StDev	Mean	StDev
100.000	561,6	439,2	765	624,6
50.000	356,5	218	341,8	278,3
20.000	21,71	17,66	19,09	32,06
10.000	19,98	18,56	13,67	24,76
5.000	16,11	15,83	9,94	20,04
2.000	6,275	5,913	3,585	7,659
1.000	0,967	1,171	0,3879	1,0329

Tabel 4.3 menunjukkan statistika deskriptif KPw Kediri pada periode Januari 2010 hingga Juni 2019. Semakin besar pecahan maka nilai rata-rata *inflow* dan *outflow* di KPw Kediri juga semakin besar. Begitu pula dengan nilai standar deviasi, hanya saja *inflow* uang kertas pecahan Rp20.000 memiliki nilai standar deviasi yang

lebih kecil dibandingkan *inflow* uang kertas pecahan Rp10.000. Pola dari data tiap pecahan ditunjukkan pada plot *time series* berikut:



Gambar 4.6 Plot *Time Series* (a)*Inflow* dan (b)*Outflow* di KPw Kediri

Gambar 4.6 menunjukkan plot *time series* periode Januari 2010 hingga Juni 2019 di KPw Kediri. Beberapa pecahan baik *inflow* maupun *outflow* memiliki tren naik, akan tetapi pada uang

kertas pecahan Rp2.000 memiliki nilai yang konstan dan Rp1.000 setiap tahunnya mengalami penurunan. Pada semua pecahan juga memiliki puncak tinggi pada waktu-waktu tertentu yaitu pada periode Idul Fitri.


4.1.3 Karakteristik *Inflow* dan *Outflow* di Kantor Perwakilan Malang

Kantor Perwakilan Malang memiliki wilayah kerja di Lumajang, Malang, Pasuruan, Probolinggo dan Batu. Statistika deskriptif dari *inflow* dan *outflow* pecahan uang kertas di KPw Malang ditunjukkan pada Tabel 4.4.

Tabel 4.4 Statistika Deskriptif Pecahan Uang Kertas di KPw Malang

Pecahan	<i>Inflow</i>		<i>Outflow</i>	
	Mean	StDev	Mean	StDev
100.000	610,3	337,8	401,1	379,4
50.000	474,6	200,5	262,4	246
20.000	16,658	10,618	13,33	25,98
10.000	14,498	9,843	11,06	21,18
5.000	11,384	8,659	8,98	17,31
2.000	4,566	3,034	3,862	7,607
1.000	0,6662	0,72	0,276	0,8562

Tabel 4.4 menunjukkan statistika deskriptif dari semua pecahan uang kertas *inflow* dan *outflow* di KPw Malang pada periode Januari 2010 hingga Juni 2019. Semakin besar pecahan, maka rata-rata dan standar deviasinya juga semakin besar. *Inflow* pecahan Rp100.000 memiliki rata-rata sebesar 610,3 miliar rupiah, sedangkan *outflow* pecahan Rp100.000 memiliki rata-rata sebesar 401,1 miliar rupiah. Hal ini menunjukkan jika rata-rata *inflow* untuk semua pecahan memiliki nilai yang lebih besar dibandingkan rata-rata *outflow* di KPw Malang. Berikut adalah plot *time series* untuk semua pecahan di KPw Malang.



Gambar 4.7 Plot Time Series (a) *Inflow* dan (b) *Outflow* di KPw Malang

Gambar 4.7 menunjukkan bahwa semua pecahan pada *inflow* dan *outflow* meningkat pada saat-saat tertentu yaitu pada periode Idul Fitri. Pada *outflow* pecahan Rp 5.000 dan pecahan Rp2.000 memiliki nilai yang cenderung konstan, sedangkan pada *inflow* dan *outflow* pecahan Rp1.000 memiliki tren yang cenderung turun. Pada tahun 2010 telah dilakukan percetakan uang baru berbentuk

logam sehingga penggunaan uang kertas Rp1.000 sedikit demi sedikit berkurang.


4.1.4 Karakteristik *Inflow* dan *Outflow* di Kantor Perwakilan Surabaya

Kantor Perwakilan Surabaya memiliki wilayah kerja di Bangkalan, Bojonegoro, Gresik, Jombang, Lamongan, Mojokerto, Pamekasan, Sampang, Sidoarjo, Sumenep, Tuban dan Surabaya. Statistika deskriptif dari *inflow* dan *outflow* pecahan uang kertas di KPw Surabaya ditunjukkan pada Tabel 4.5.

Tabel 4.5 Statistika Deskriptif Pecahan Uang Kertas di KPw Surabaya

Pecahan	<i>Inflow</i>		<i>Outflow</i>	
	Mean	StDev	Mean	StDev
100.000	1551	1138	1413	1087
50.000	988,5	560,2	1049	715,8
20.000	53,43	43,7	60,6	118,3
10.000	46,86	38,23	60,6	122,4
5.000	38,55	29,35	48,33	104,31
2.000	19,16	13,53	25,71	60,02
1.000	2,829	2,872	0,94	2,474

Tabel 4.5 menunjukkan statistika deskriptif dari semua pecahan uang kertas *inflow* dan *outflow* di KPw Surabaya pada periode Januari 2010 hingga Juni 2019. Semakin besar pecahan, maka rata-rata dan standar deviasinya juga semakin besar. Pada *outflow* pecahan Rp10.000 dan Rp20.000 memiliki rata-rata yang sama yaitu sebesar 60,6 miliar rupiah. Pecahan lainnya juga menunjukkan jika rata-rata *inflow* memiliki nilai yang lebih kecil dibandingkan rata-rata *outflow* di KPw Surabaya. Plot *time series* untuk semua pecahan di KPw Surabaya ditunjukkan pada Gambar 4.8.



Gambar 4.8 Plot *Time Series* (a)*Inflow* dan (b)*Outflow* di KPw Surabaya

Berdasarkan Gambar 4.8 semua pecahan pada *inflow* dan *outflow* meningkat pada saat-saat tertentu yaitu pada periode Idul Fitri. *Outflow* Rp1.000 memiliki perbedaan yang sangat terlihat yaitu pada tahun 2015 hingga 2019 sudah tidak ada lonjakan yang terjadi ketika periode Idul Fitri.

4.2 Pemodelan *Inflow* dan *Outflow* dengan ARIMAX di Provinsi Jawa Timur

Langkah yang dilakukan sebelum melakukan pemodelan data *inflow* dan *outflow* dengan ARIMAX adalah memodelkan dengan regresi *time series*. Dilakukan regresi *time series* pada data *inflow* Rp50.000 di KPw Jember dengan 27 variabel prediktor Setelah dilakukan regresi *time series*, didapatkan hasil pada Tabel 4.6.

Tabel 4.6 Estimasi Parameter Regresi *Time Series Inflow* Rp50.000 di KPw Jember

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	nilai <i>p</i>
t	β	4,1388	0,1873	22,09	<,0001
M_1	α_1	204,73	19,003	10,77	<,0001
M_2	α_2	95,899	19,084	5,030	<,0001
M_3	α_3	49,577	19,165	2,590	0,0116
M_4	α_4	35,590	19,248	1,850	0,0684
M_5	α_5	92,129	19,333	4,770	<,0001
M_6	α_6	71,457	19,698	3,630	0,0005
M_7	α_7	76,496	22,231	3,440	0,0010
M_8	α_8	48,971	25,111	1,950	0,0549
M_9	α_9	32,518	23,023	1,410	0,1620
M_{10}	α_{10}	41,395	20,647	2,000	0,0486
M_{11}	α_{11}	59,544	19,870	3,000	0,0037
M_{12}	α_{12}	30,468	19,964	1,530	0,1312
$V_{1,t}$	$\gamma_{1,t}$	278,52	53,428	5,210	<,0001
$V_{1,t+1}$	$\omega_{1,t+1}$	30,095	54,473	0,550	0,5823
$V_{2,t}$	$\gamma_{2,t}$	197,03	38,907	5,060	<,0001
$V_{2,t+1}$	$\omega_{2,t+1}$	18,922	37,569	0,500	0,6160
$V_{3,t}$	$\gamma_{3,t}$	163,30	38,654	4,220	<,0001
$V_{3,t+1}$	$\omega_{3,t+1}$	5,2078	38,628	0,130	0,8931
$V_{4,t}$	$\gamma_{4,t}$	-93,773	31,259	-3,000	0,0037
$V_{4,t+1}$	$\omega_{4,t+1}$	277,72	31,856	8,720	<,0001

Pada Tabel 4.6 terdapat estimasi tiap parameter dan nilai standar estimasi yang menunjukkan nilai standar deviasi di sekitar garis estimasi yang mengukur variabilitas nilai aktual dari nilai prediksi. Berdasarkan nilai p diketahui bahwa terdapat 15 variabel memiliki nilai p kurang dari α (0,05) yang artinya variabel tersebut berpengaruh signifikan terhadap *inflow* pecahan kertas Rp50.000 di KPw Jember. Adanya variabel yang tidak signifikan disebabkan karena ada beberapa efek variasi kalender yang tidak terlalu berpengaruh pada *inflow* pecahan kertas Rp50.000 di KPw Jember. Model yang didapatkan untuk *inflow* uang kertas pecahan Rp50.000 di KPw Jember adalah sebagai berikut:


$$\begin{aligned}
 Y_t = & 4,1388t + 204,738M_{1,t} + 95,899M_{2,t} + 49,577M_{3,t} \\
 & + 35,5905M_{4,t} + 92,129M_{5,t} + 71,4574M_{6,t} + 76,496M_{7,t} \\
 & + 48,9713M_{8,t} + 32,5186M_{9,t} + 41,395M_{10,t} + 59,544M_{11,t} \\
 & + 30,095M_{12,t} + 197,037V_{1,t} + 30,095V_{1,t+1} + 197,037V_{2,t} \\
 & + 18,922V_{2,t+1} + 163,303V_{3,t} + 5,2078V_{3,t+1} - 93,7738V_{4,t} \\
 & + 277,722V_{4,t+1} + \varepsilon_t.
 \end{aligned}$$

Dilakukan pengecekan residual dari model regresi *time series* apakah telah memenuhi asumsi atau belum. Jika residual belum memenuhi asumsi *white noise* maka dilakukan pemodelan ARIMA pada residual dari regresi *time series*. Setelah didapatkan estimasi parameter *inflow* Rp50.000, dilakukan uji Ljung Box untuk cek *white noise* dan dilakukan uji Kolmogorv Smirnov untuk cek normalitas data. Hasil uji *white noise* dari residual model regresi *time series inflow* Rp50.000 di KPw Jember ditunjukkan pada Tabel 4.7.

Tabel 4.7 Uji Asumsi Residual Regresi *Time Series Inflow* Rp50.000 di KPw Jember

Hingga Lag ke-	Chi-Square	DF	nilai p
6	13,23	6	0,0395
12	17,13	12	0,1447
18	21,73	18	0,2440
24	27,33	24	0,2893
30	37,54	30	0,1620
36	43,32	36	0,1873

Berdasarkan Tabel 4.7 dapat diketahui jika terdapat nilai p dari uji Ljung Box yang kurang dari 0,05. Hal ini menunjukkan jika residual *inflow* uang kertas pecahan Rp50.000 di KPw Jember belum memenuhi asumsi *white noise* yang berarti residual independen atau mengandung autokorelasi dan residual telah berdistribusi normal. Selanjutnya dilakukan pemodelan menggunakan ARIMA berdasarkan plot ACF dan PACF pada residual hasil pemodelan menggunakan regresi *time series* guna memenuhi asumsi independen. Plot ACF dan PACF dari residual *inflow* uang kertas pecahan Rp50.000 di KPw Jember ditunjukkan pada Gambar 4.5.



Gambar 4.9 ACF dan PACF Residual Regresi *Time Series Inflow* Rp50.000 di KPw Jember

Berdasarkan plot ACF dan PACF pada Gambar 4.9 maka didapatkan dugaan model ARIMA dari residual *inflow* uang kertas pecahan Rp50.000 di KPw Jember. Hasil dugaan model

selanjutnya dilakukan estimasi parameter dan uji asumsi residual. Estimasi parameter dari model ARIMAX ditunjukkan pada Tabel 4.8.

Tabel 4.8 Estimasi Parameter ARIMAX *Inflow* Rp50.000 di KPw Jember

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	nilai <i>p</i>
AR(1)	ϕ_1	0,37929	0,11324	3,35	0,0013
<i>t</i>	β	4,11011	0,27313	15,05	<,0001
M_1	α_1	204,502	21,0496	9,72	<,0001
M_2	α_2	96,6047	21,3122	4,53	<,0001
M_3	α_3	50,6580	21,4567	2,36	0,0209
M_4	α_4	36,8312	21,6032	1,7	0,0924
M_5	α_5	93,4497	21,7578	4,29	<,0001
M_6	α_6	70,6233	22,1056	3,19	0,0021
M_7	α_7	80,4717	24,0511	3,35	0,0013
M_8	α_8	53,5539	26,2224	2,04	0,0447
M_9	α_9	33,5816	25,0165	1,34	0,1836
M_{10}	α_{10}	44,0327	23,2403	1,89	0,062
M_{11}	α_{11}	61,8094	22,5869	2,74	0,0078
M_{12}	α_{12}	33,9793	22,3992	1,52	0,1335
$V_{1,t}$	$\gamma_{1,t}$	248,450	49,9744	4,97	<,0001
$V_{1,t+1}$	$\omega_{1,t+1}$	-2,44008	50,1684	-0,05	0,9613
$V_{2,t}$	$\gamma_{2,t}$	201,814	35,2802	5,72	<,0001
$V_{2,t+1}$	$\omega_{2,t+1}$	12,0212	34,8079	0,35	0,7308
$V_{3,t}$	$\gamma_{3,t}$	142,363	35,7878	3,98	0,0002
$V_{3,t+1}$	$\omega_{3,t+1}$	-1,51067	35,4028	-0,04	0,9661
$V_{4,t}$	$\gamma_{4,t}$	-76,1263	28,7039	-2,65	0,0098
$V_{4,t+1}$	$\omega_{4,t+1}$	290,622	28,6692	10,14	<,0001

Tabel 4.8 menunjukkan bahwa estimasi parameter ARIMA telah signifikan karena memiliki nilai *p* kurang dari α dan terdapat 6 variabel *dummy* yang tidak berpengaruh signifikan pada *inflow* pecahan kertas Rp50.000 di KPw Jember. Persamaan model

ARIMAX yang didapatkan untuk *inflow* uang kertas pecahan Rp50.000 di KPw Jember adalah sebagai berikut:

$$\begin{aligned}
 Y_t = & 4,1101t + 204,502M_{1,t} + 96,6047M_{2,t} + 50,658M_{3,t} \\
 & + 36,8312M_{4,t} + 93,4497M_{5,t} + 70,6233M_{6,t} + 80,4717M_{7,t} \\
 & + 53,5539M_{8,t} + 33,5816M_{9,t} + 44,0327M_{10,t} + 61,8094M_{11,t} \\
 & + 33,9793M_{12,t} + 248,450V_{1,t} - 2,44008V_{1,t+1} + 201,814V_{2,t} \\
 & + 12,0212V_{2,t+1} + 142,363V_{3,t} - 1,51067V_{3,t+1} - 76,1263V_{4,t} \\
 & + 290,622V_{4,t+1} + \frac{1}{(1-0,37929B)} a_t.
 \end{aligned}$$

dan persamaan model untuk ramalan *inflow* uang kertas pecahan Rp50.000 di KPw Jember adalah

$$\begin{aligned}
 \hat{Y}_t = & 4,1101t + 204,502M_{1,t} + 96,6047M_{2,t} + 50,658M_{3,t} \\
 & + 36,8312M_{4,t} + 93,4497M_{5,t} + 70,6233M_{6,t} + 80,4717M_{7,t} \\
 & + 53,5539M_{8,t} + 33,5816M_{9,t} + 44,0327M_{10,t} + 61,8094M_{11,t} \\
 & + 33,9793M_{12,t} + 248,450V_{1,t} - 2,44008V_{1,t+1} + 201,814V_{2,t} \\
 & + 12,0212V_{2,t+1} + 142,363V_{3,t} - 1,51067V_{3,t+1} - 76,1263V_{4,t} \\
 & + 290,622V_{4,t+1} + 0,37929\varepsilon_{t-1}
 \end{aligned}$$

dimana


$$\begin{aligned}
 \varepsilon_{t-1} = & Y_{t-1} - (4,1101(t-1) + 204,502M_{1,t-1} + 96,6047M_{2,t-1} \\
 & + 50,658M_{3,t-1} + 36,8312M_{4,t-1} + 93,4497M_{5,t-1} \\
 & + 70,6233M_{6,t-1} + 80,4717M_{7,t-1} + 53,5539M_{8,t-1} \\
 & + 33,5816M_{9,t-1} + 44,0327M_{10,t-1} + 61,8094M_{11,t-1} \\
 & + 33,9793M_{12,t-1} + 248,450V_{1,t-1} - 2,44008V_{1,(t+1)-1} \\
 & + 201,814V_{2,t-1} + 12,0212V_{2,(t+1)-1} + 142,363V_{3,t-1} \\
 & - 1,51067V_{3,(t+1)-1} - 76,1263V_{4,t-1} + 290,622V_{4,(t+1)-1}).
 \end{aligned}$$

Setelah dilakukan estimasi parameter dan didapatkan model *inflow* uang kertas pecahan Rp50.000 di KPw Jember yaitu ARIMA(1,0,0), selanjutnya adalah melakukan uji asumsi residual untuk mengetahui asumsi memenuhi *white noise* dan berdistribusi normal. Hasil pengujian residual model ARIMAX ditunjukkan pada Tabel 4.9.

Tabel 4.9 Uji Asumsi Residual ARIMAX *Inflow* Rp50.000 di KPw Jember

Hingga Lag ke-	Chi-Square	DF	nilai p
6	1,890	5	0,8644
12	8,750	11	0,6448
18	13,73	17	0,6866
24	20,40	23	0,6176
30	26,73	29	0,5860
36	31,29	35	0,6480

Residual model ARIMAX sudah memenuhi asumsi *white noise* karena nilai p seluruh lag lebih dari α dan telah memenuhi asumsi berdistribusi normal. Perbandingan data aktual dengan hasil ramalan pada data *in-sample* ditunjukkan pada Gambar 4.10.

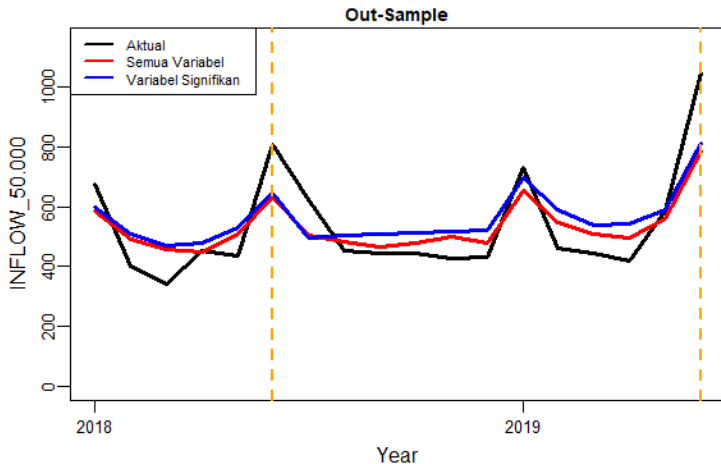


Gambar 4.10 Perbandingan Hasil Ramalan ARIMAX *Inflow* Rp50.000 di KPw Jember

Gambar 4.10 menunjukkan perbandingan hasil ramalan dan data asli pada *in-sample* maupun *out-sample*. Hasil ramalan model ARIMAX pada data *inflow* Rp50.000 telah mengikuti pola data aktual dan mampu menangkap efek variasi kalender Idul Fitri.

Namun hasil ramalan *inflow* pada *out-sample* data ke 6 dan data ke 18 yaitu bulan Juni 2018 dan Juni 2019 ketika Idul Fitri yang ditunjukkan pada garis hijau belum mampu mendekati nilai aktual dari data sehingga memiliki selisih yang cukup besar.

Setelah mendapatkan hasil ramalan dari model ARIMAX menggunakan semua variabel *dummy*, dicobakan model ARIMAX dengan variabel *dummy* yang signifikan pada *inflow* pecahan Rp50.000 di KPw Jember. Hasil perbandingan ramalan menggunakan semua variabel dibanding variabel signifikan pada data *out-sample* ditunjukkan pada Gambar 4.11.



Gambar 4.11 Perbandingan Hasil Ramalan menggunakan Semua Variabel dan Variabel Signifikan pada *Inflow* Rp50.000 di KPw Jember

Gambar 4.11 menunjukkan jika hasil ramalan menggunakan semua variabel dengan variabel yang signifikan tidak memberikan perbedaan yang cukup signifikan, hal ini ditandai dengan garis merah dan garis biru membentuk pola yang sama. Pada saat terjadi lonjakan nilai *inflow*, hasil ramalan menggunakan kedua model memiliki perbedaan ketika bulan Januari 2019 dimana hasil ramalan yang mendekati data aktual adalah model ARIMAX(1,0,0) yang menggunakan variabel signifikan.

Sedangkan pada lonjakan lainnya tidak memiliki perbedaan antara model dengan semua variabel dengan variabel signifikan. Pada saat tidak terjadi lonjakan, hasil ramalan yang mendekati data aktual adalah model dengan semua variabel. Untuk mengetahui perbedaan hasil ramalan ketika terjadi lonjakan dan tidak terjadi lonjakan nilai *inflow*, berikut diberikan nilai RMSE dan sMAPE untuk data *out-sample* berdasarkan terjadinya lonjakan *inflow* yang ditunjukkan pada Tabel 4.10.

Tabel 4.10 Nilai RMSE dan sMAPE Hasil Ramalan menggunakan Semua Variabel dan Variabel Signifikan pada *Inflow* Rp50.000 di KPw Jember Berdasarkan Lonjakan *Inflow*

Model	RMSE			sMAPE		
	Terjadi Lonjakan	Tidak Terjadi Lonjakan	Keseluruhan	Terjadi Lonjakan	Tidak Terjadi Lonjakan	Keseluruhan
Semua Variabel	168.0653	74.48131	100.7231	0.196175	0.129187	0.145909
Variabel Signifikan	149.3312	92.59593	107.8155	0.18812	0.176745	0.173581

Tabel 4.10 menunjukkan nilai RMSE dan sMAPE pada data *out-sample inflow* pecahan Rp50.000 di KPw Jember. Ketika terjadi lonjakan nilai *inflow*, nilai RMSE dan sMAPE terkecil yaitu model menggunakan variabel signifikan. Akan tetapi ketika tidak terjadi lonjakan *inflow* maka model terbaik adalah model dengan semua variabel. Dikarenakan pada satu tahun hanya terjadi dua kali lonjakan nilai *inflow* yaitu bulan Januari dan bulan Idul Fitri, sehingga secara keseluruhan untuk ramalan periode Januari 2018 hingga Juni 2019 menunjukkan jika nilai RMSE dan sMAPE terkecil yaitu model ARIMAX(1,0,0) dengan semua variabel.

Signifikansi parameter dalam peramalan tidak terlalu diperhatikan dan yang lebih diperhatikan adalah akurasi peramalan (Hyndman & Kostenko, 2008). Oleh karena itu semua variabel akan digunakan dalam pemodelan pada penelitian ini dan diharapkan mampu menangkap semua pola data.

Dilakukan hal yang sama untuk pecahan uang kertas lainnya untuk KPw Jember dan KPw lainnya. Berikut adalah hasil model ARIMAX untuk setiap KPw.

4.2.1 Pemodelan *Inflow* dan *Outflow* dengan ARIMAX di Kantor Perwakilan Jember

Model ARIMAX terbaik untuk total dan semua pecahan uang kertas *inflow* maupun *outflow* di KPw Jember ditunjukkan pada Tabel 4.11.

Tabel 4.11 Pemodelan *Inflow* dan *Outflow* di KPw Jember

Variabel	Pecahan	Model	Residual	
			White Noise	Berdistribusi Normal
<i>Inflow</i>	Total	Regresi <i>Time Series</i>	Ya	Ya
	100.000	Regresi <i>Time Series</i>	Ya	Ya
	50.000	ARIMAX(1,0,0)	Ya	Ya
	20.000	ARIMAX([1,11],0,0)	Ya	Tidak
	10.000	Regresi <i>Time Series</i>	Ya	Tidak
	5.000	ARIMAX([1,11,12],0,0)	Ya	Tidak
	2.000	ARIMAX([1,10],0,0)	Ya	Tidak
	1.000	ARIMAX(0,0,[1,2,8,9])	Ya	Ya
<i>Outflow</i>	Total	ARIMAX([3],0,0)	Ya	Ya
	100.000	ARIMAX([3],0,0)	Tidak	Ya
	50.000	ARIMAX([3,10,12],0,0)	Tidak	Ya
	20.000	ARIMAX(0,0,1)	Ya	Tidak
	10.000	ARIMAX(0,0,1)	Ya	Tidak
	5.000	ARIMAX(0,0,1)	Ya	Tidak
	2.000	ARIMAX(0,0,1)	Ya	Tidak
	1.000	Regresi <i>Time Series</i>	Ya	Tidak

Tabel 4.11 menunjukkan jika pada *inflow* di KPw Jember terdapat empat pecahan yang ketika pemodelan regresi *time series* memiliki residual yang telah *white noise*, sehingga tidak dilakukan pemodelan ARIMA pada residualnya. Residual regresi *time series* yang belum memenuhi asumsi *white noise* pada semua pecahan telah stasioner dalam *mean* sehingga tidak perlu dilakukan

differencing dan dilanjutkan dengan pemodelan ARIMA berdasarkan ACF dan PACF residual. Sedangkan untuk *outflow* di KPw Jember hanya pecahan Rp1.000 yang residual regresi *time series* belum memenuhi asumsi *white noise*.

4.2.2 Pemodelan *Inflow* dan *Outflow* dengan ARIMAX di Kantor Perwakilan Kediri

Model ARIMAX terbaik untuk total dan semua pecahan uang kertas *inflow* maupun *outflow* di KPw Kediri ditunjukkan pada Tabel 4.12

Tabel 4.12 Model Residual untuk *Inflow* dan *Outflow* di KPw Kediri

Variabel	Pecahan	Model	Residual	
			White Noise	Berdistribusi Normal
<i>Inflow</i>	Total	Regresi <i>Time Series</i>	Ya	Ya
	100.000	Regresi <i>Time Series</i>	Ya	Ya
	50.000	Regresi <i>Time Series</i>	Ya	Tidak
	20.000	Regresi <i>Time Series</i>	Ya	Tidak
	10.000	Regresi <i>Time Series</i>	Ya	Tidak
	5.000	ARIMAX([1,11],0,0)	Ya	Tidak
	2.000	ARIMAX([1,2,12],0,0)	Ya	Ya
	1.000	ARIMAX(1,0,0)	Ya	Ya
<i>Outflow</i>	Total	Regresi <i>Time Series</i>	Ya	Tidak
	100.000	Regresi <i>Time Series</i>	Ya	Ya
	50.000	ARIMAX([17,22],0,0)	Tidak	Ya
	20.000	Regresi <i>Time Series</i>	Ya	Tidak
	10.000	ARIMAX([1,11],0,0)	Ya	Tidak
	5.000	Regresi <i>Time Series</i>	Ya	Tidak
	2.000	Regresi <i>Time Series</i>	Ya	Tidak
	1.000	ARIMAX(0,0,[12])	Ya	Tidak

Tabel 4.12 menunjukkan residual regresi *time series* yang memenuhi asumsi *white noise* pada *inflow* dan *outflow* di KPw Kediri yaitu sebanyak sepuluh pecahan. Hanya terdapat tiga pecahan pada masing-masing *inflow* dan *outflow* yang residualnya di modelkan dengan ARIMA. Untuk *inflow* yaitu pecahan

Rp5.000, Rp2.000 dan Rp1.000, sedangkan untuk *outflow* yaitu pecahan Rp50.000, Rp10.000 dan pecahan Rp1.000. Model terbaik untuk semua pecahan baik *inflow* maupun *outflow* di KPw Kediri telah memenuhi asumsi *white noise*, kecuali pada pecahan Rp50.000.

4.2.3 Pemodelan *Inflow* dan *Outflow* dengan ARIMAX di Kantor Perwakilan Malang

Model ARIMAX terbaik untuk total dan semua pecahan uang kertas *inflow* maupun *outflow* di KPw Malang ditunjukkan pada Tabel 4.13.

Tabel 4.13 Model Residual untuk *Inflow* dan *Outflow* di KPw Malang

Variabel	Pecahan	Model	Residual	
			White Noise	Berdistribusi Normal
<i>Inflow</i>	Total	ARIMAX(2,0,0)	Ya	Ya
	100.000	ARIMAX([1,2,4],0,0)	Ya	Ya
	50.000	ARIMAX([1,2,12],1,0)	Ya	Ya
	20.000	Regresi <i>Time Series</i>	Ya	Tidak
	10.000	Regresi <i>Time Series</i>	Ya	Tidak
	5.000	Regresi <i>Time Series</i>	Ya	Tidak
	2.000	ARIMAX(1,0,0)	Ya	Ya
	1.000	ARIMAX(1,0,0)	Ya	Tidak
<i>Outflow</i>	Total	ARIMAX(2,0,0)	Ya	Ya
	100.000	ARIMAX(2,0,0)	Ya	Ya
	50.000	Regresi <i>Time Series</i>	Ya	Tidak
	20.000	ARIMAX([1,11,12],0,0)	Ya	Tidak
	10.000	ARIMAX([1,11],0,0)	Ya	Tidak
	5.000	Regresi <i>Time Series</i>	Ya	Tidak
	2.000	Regresi <i>Time Series</i>	Ya	Tidak
	1.000	Regresi <i>Time Series</i>	Ya	Tidak

Tabel 4.13 menunjukkan jika terdapat sembilan pecahan di KPw Malang yang residual hasil regresi *time series* belum memenuhi asumsi *white noise*. Untuk residual regresi *time series* yang belum memenuhi asumsi *white noise* dilanjutkan dengan

pemodelan ARIMA berdasarkan identifikasi plot ACF dan PACF yaitu pada residual *inflow* total pecahan, Rp100.000, Rp50.000, Rp2.000, Rp1.000 dan pada residual *outflow* total pecahan, Rp100.000, Rp20.000 dan Rp10.000. Model terbaik untuk semua pecahan baik *inflow* maupun *outflow* di KPw Malang telah memenuhi asumsi *white noise*.

4.2.4 Pemodelan *Inflow* dan *Outflow* dengan ARIMAX di Kantor Perwakilan Surabaya

Model ARIMAX terbaik untuk total dan semua pecahan uang kertas *inflow* maupun *outflow* di KPw Surabaya ditunjukkan pada Tabel 4.14.

Tabel 4.14 Model Residual untuk *Inflow* dan *Outflow* di KPw Surabaya


Variabel	Pecahan	Model	Residual	
			White Noise	Berdistribusi Normal
<i>Inflow</i>	Total	ARIMAX([2,4],0,0)	Ya	Ya
	100.000	ARIMAX([4],0,0)	Ya	Tidak
	50.000	ARIMAX(3,1,0)	Ya	Ya
	20.000	ARIMAX(1,0,0)	Ya	Tidak
	10.000	ARIMAX([1,11],0,0)	Ya	Tidak
	5.000	ARIMAX([1,2,11],0,0)	Ya	Tidak
	2.000	ARIMAX([1,4],0,0)	Ya	Ya
	1.000	ARIMAX(0,0,[1,2,10])	Tidak	Ya
<i>Outflow</i>	Total	ARIMAX([3],0,0)	Ya	Ya
	100.000	ARIMAX([3],0,0)	Ya	Ya
	50.000	ARIMAX([3],0,0)	Ya	Ya
	20.000	Regresi <i>Time Series</i>	Ya	Tidak
	10.000	Regresi <i>Time Series</i>	Ya	Tidak
	5.000	ARIMAX(0,0,1)	Ya	Tidak
	2.000	ARIMAX([1,23],0,0)	Ya	Tidak
	1.000	Regresi <i>Time Series</i>	Ya	Tidak

Tabel 4.14 menunjukkan residual regresi *time series* yang memenuhi asumsi *white noise* pada *outflow* di KPw Surabaya yaitu

sebanyak tiga pecahan, sehingga lainnya akan dimodelkan dengan ARIMA dan didapatkan model terbaik pada Tabel 4.14.


4.3 Pemodelan *Inflow* dan *Outflow* dengan *Deep Neural Network* di Provinsi Jawa Timur

Langkah yang dilakukan untuk memodelkan *inflow* dan *outflow* dengan *Deep Neural Network* (DNN). *Input* pada DNN adalah lag PACF yang signifikan, *dummy* tren, *dummy* bulan dan *dummy* variasi kalender. Arsitektur yang digunakan adalah dua *hidden layer* dengan jumlah masing-masing *layer* adalah satu hingga lima neuron. Fungsi aktivasi yang digunakan pada *hidden layer* adalah sigmoid dan fungsi aktivasi yang digunakan pada *output layer* adalah linier. Sedangkan untuk nilai pembobot didapatkan menggunakan algoritma *backpropagation* dengan melakukan replikasi sebanyak 10 kali guna mendapatkan nilai pembobot terbaik. *Input* yang digunakan adalah lag signifikan dari PACF data yang telah stasioner. Berikut adalah *time series* plot dari *inflow* uang kertas pecahan Rp50.000 di KPw Jember adalah sebagai berikut:



Gambar 4.12 *Time Series* Plot *Inflow* (a) Data Asli dan (b) Data Stasioner

Gambar 4.12(a) menunjukkan *time series* plot yang tidak stasioner. Pola data pada pecahan Rp50.000 terdapat tren dan musiman, sehingga dilakukan *differencing seasonal* dan *non-seasonal*. Setelah dilakukan *differencing*, dapat dilihat pola *time series* telah stasioner dan plot PACF data yang telah stasioner ditunjukkan pada Gambar 4.13.



Gambar 4.13 Plot PACF *Inflow* Rp50.000 di KPw Jember

Plot PACF pada Gambar 4.13 menunjukkan jika terdapat 1 lag yang signifikan yaitu lag 1. Karena data telah dilakukan *differencing*, maka penjabaran model yaitu sebagai berikut:

$$a_t = (1 - B)(1 - B^{12})(1 - \phi_1 B)\dot{Y}_t$$


$$a_t = (1 - B - B^{12} + B^{13})(1 - \phi_1 B)\dot{Y}_t$$

$$a_t = (1 - (1 + \phi_1)B + \phi_1 B^2 - B^{12} + (1 + \phi_1)B^{13} - \phi_1 B^{14})\dot{Y}_t$$

$$a_t = \dot{Y}_t - (1 + \phi_1)\dot{Y}_{t-1} + \phi_1 \dot{Y}_{t-2} - \dot{Y}_{t-12} + (1 + \phi_1)\dot{Y}_{t-13} - \phi_1 \dot{Y}_{t-14}$$


$$\dot{Y}_t = (1 + \phi_1)\dot{Y}_{t-1} - \phi_1 \dot{Y}_{t-2} + \dot{Y}_{t-12} - (1 + \phi_1)\dot{Y}_{t-13} + \phi_1 \dot{Y}_{t-14} + a_t$$

Setelah dilakukan penjabaran model, didapatkan *input* yang digunakan adalah lag 1, 2, 12, 13, 14 dan variabel *dummy*. Selanjutnya dilakukan uji Terasvirta terhadap lag *input* dengan data dan didapatkan hasil bahwa model non-linier adalah model yang sesuai untuk menjelaskan hubungan Y_t dengan *input*nya. Pemilihan arsitektur terbaik adalah berdasarkan nilai RMSE dan sMAPE terkecil pada data *out-sample* yang ditunjukkan pada Gambar 4.14.



Gambar 4.14 RMSE dan sMAPE DNN *Inflow* Rp50.000 di KPw Jember

Neuron yang digunakan adalah 1 sampai 5 pada *hidden layer* 1 dan *hidden layer* 2 sehingga terdapat 25 kombinasi. Tabel 4.14 menunjukkan jika dari 25 kombinasi dapat diketahui jika nilai RMSE dan sMAPE terkecil data *out-sample* yaitu pada kombinasi ke-23 dimana terdapat 3 neuron pada *hidden layer* 1 dan 5 neuron pada *hidden layer* 2. Berikut adalah hasil arsitektur optimum pada kombinasi ke-23 data *inflow* Rp50.000 di KPw Jember.



Gambar 4.15 Arsitektur DNN *Inflow* Rp50.000 di KPw Jember

Pada Gambar 4.15 menunjukkan jika arsitektur optimum pada *inflow* pecahan Rp50.000 di KPw Jember memiliki jumlah neuron pada *hidden layer* 1 sebanyak 3 neuron dan jumlah neuron pada *hidden layer* 2 sebanyak 4 neuron. Didapatkan persamaan model sebagai berikut:

$$\hat{Y}_{3,t}^{(1)*} = -0,124 - 1,239 f_1^{h_2}(\cdot) + 1,788 f_2^{h_2}(\cdot) + 0,358 f_3^{h_2}(\cdot) + 0,146 f_4^{h_2}(\cdot) + 0,673 f_5^{h_2}(\cdot)$$

dimana

$$f_1^{h_2}(\cdot) = (1 + \exp(-(-0,657 - 1,500 f_1^{h_1}(\cdot) + 1,073 f_2^{h_1}(\cdot) + 2,477 f_3^{h_1}(\cdot))))^{-1}$$

$$f_2^{h_2}(\cdot) = (1 + \exp(-(-0,232 + 1,272 f_1^{h_1}(\cdot) + 0,794 f_2^{h_1}(\cdot) - 1,722 f_3^{h_1}(\cdot))))^{-1}$$

$$f_3^{h_2}(\cdot) = (1 + \exp(-(-4,866 + 7,594 f_1^{h_1}(\cdot) - 5,512 f_2^{h_1}(\cdot) + 27,847 f_3^{h_1}(\cdot))))^{-1}$$

$$f_4^{h_2}(\cdot) = (1 + \exp(-(-1,587 - 1,966 f_1^{h_1}(\cdot) - 0,124 f_2^{h_1}(\cdot) - 10,189 f_3^{h_1}(\cdot))))^{-1}$$

$$f_5^{h_2}(\cdot) = (1 + \exp(-(-0,186 + 0,792 f_1^{h_1}(\cdot) - 0,339 f_2^{h_1}(\cdot) - 1,104 f_3^{h_1}(\cdot))))^{-1}$$

dimana

$$f_1^{h_1}(\cdot) = (1 + \exp(-(-1,256 + 2,318 Y_{t-1}^* + 0,790 Y_{t-2}^* - 0,1645 Y_{t-12}^* - 0,049 Y_{t-13}^* - 1,166 Y_{t-14}^* + 0,011 t + 1,522 M_1 - 1,948 M_2 - 1,136 M_3 - 1,632 M_4 - 0,378 M_5 - 0,365 M_6 - 1,962 M_7 - 1,648 M_8 - 0,477 M_9 - 0,662 M_{10} - 1,245 M_{11} - 1,066 M_{12} + 2,461 V_{1,t} + 0,231 V_{1,t+1} + 2,646 V_{2,t} + 0,541 V_{2,t+1} - 1,614 V_{3,t} + 0,086 V_{3,t+1} - 0,086 V_{4,t} - 1,416 V_{4,t+1})))^{-1}$$

$$f_2^{h_1}(\cdot) = (1 + \exp(-(-0,152 + 1,374 Y_{t-1}^* + 0,767 Y_{t-2}^* + 0,014 Y_{t-12}^* + 1,171 Y_{t-13}^* + 0,109 Y_{t-14}^* + 2,414 t + 0,744 M_1 - 1,034 M_2 + 0,319 M_3 - 0,909 M_4 + 0,205 M_5 - 0,044 M_6 + 0,419 M_7 + 0,692 M_8 + 0,124 M_9 - 0,294 M_{10} - 1,478 M_{11} + 0,508 M_{12} - 1,991 V_{1,t} + 0,253 V_{1,t+1} - 0,477 V_{2,t} + 0,179 V_{2,t+1} + 0,394 V_{3,t} + 0,910 V_{3,t+1} - 0,106 V_{4,t} + 1,033 V_{4,t+1})))^{-1}$$

$$\begin{aligned}
f_3^h(.) = & (1 + \exp(-(0,405 + 0,617Y_{t-1}^* - 0,274Y_{t-2}^* + 1,912Y_{t-12}^* + 0,159Y_{t-13}^* \\
& - 3,23Y_{t-14}^* - 0,021t + 0,908M_1 - 2,852M_2 - 0,013M_3 - 1,465M_4 \\
& + 0,303M_5 + 0,637M_6 - 1,535M_7 + 0,196M_8 + 1,232M_9 - 0,486M_{10} \\
& - 1,454M_{11} - 0,727M_{12} - 1,912V_{1,t} + 0,547V_{1,t+1} + 0,232V_{2,t} + 0,122V_{2,t+1} \\
& - 0,101V_{3,t} - 1,004V_{3,t+1} - 1,576V_{4,t} + 0,248V_{4,t+1})))^{-1}
\end{aligned}$$

Perhitungan hasil peramalan untuk satu tahap kedepan dapat dilakukan dengan menghitung pada *hidden layer* 1 terlebih dahulu. Data yang digunakan adalah mulai periode Januari 2010, sehingga untuk peramalan pada satu tahap kedepan yaitu data *out-sample* bulan Januari 2018 memiliki nilai tren sebesar 97 dan *dummy* M_1 bernilai 1 sedangkan bulan lainnya bernilai 0. Bulan Januari 2018 tidak terjadi Idul Fitri, oleh karena itu nilai *dummy* variasi kalender semuanya bernilai 0. Lag yang digunakan pada *input* yaitu lag 1 adalah Desember 2017, lag 2 adalah November 2017, lag 12 adalah Januari 2017, lag 13 adalah Desember 2016 dan lag 14 adalah November 2016. Dengan nilai minimum sebesar 67,3085 miliar rupiah dan nilai maksimum sebesar 776,3746 miliar rupiah didapatkan perhitungan manual untuk satu tahap kedepan pada *hidden layer* 1 adalah sebagai berikut:

$$\begin{aligned}
f_1^h(.) = & (1 + \exp(-(-1,256 + 2,318(0,444) + 0,790(0,464) - 0,1645(0,720) \\
& - 0,049(0,518) - 1,166(0,532) + 0,011(97) + 1,522(1))))^{-1} \\
= & 0,876
\end{aligned}$$

$$\begin{aligned}
f_2^h(.) = & (1 + \exp(-(0,152 + 1,374(0,444) + 0,767(0,464) + 0,014(0,720) \\
& + 1,171(0,518) + 0,109(0,532) + 2,414(97) + 0,744(1))))^{-1} \\
= & 1,000
\end{aligned}$$

$$\begin{aligned}
f_3^h(.) = & (1 + \exp(-(0,405 + 0,617(0,444) - 0,274(0,464) + 1,912(0,720) \\
& + 0,159(0,518) - 3,23(0,532) - 0,021(97) + 0,908(1))))^{-1} \\
= & 0,297
\end{aligned}$$


pada *hidden layer 2* yaitu

$$f_1^{h_2}(\cdot) = 0,875, \quad f_2^{h_2}(\cdot) = 1,000, \quad f_3^{h_2}(\cdot) = 0,989, \quad f_4^{h_2}(\cdot) = 0,002 \quad \text{dan} \\ f_5^{h_2}(\cdot) = 0,460.$$

sedangkan pada *output layer* yaitu

$$\hat{Y}_{3,t}^{(1)*} = -0,124 - 1,239(0,759) + 1,788(0,762) + 0,358(0,989) + \\ 0,146(0,002) + 0,673(0,460) \\ = 0,962$$

Hasil dari *output layer* selanjutnya dilakukan *postprocessing* dengan normalisasi agar hasil ramalan memiliki skala yang sama dengan data aktual. Sehingga didapatkan nilai ramalan *inflow* pada Januari 2018 sebesar 748,698 miliar rupiah. Perbandingan hasil data aktual dan ramalan menggunakan model terbaik DNN ditunjukkan pada Gambar 4.16.



Gambar 4.16 Perbandingan Hasil Ramalan DNN *Inflow* Rp50.000 di KPw Jember

Hasil ramalan pada data *in-sample* telah mengikuti pola data aktual dan mampu menangkap variasi kalender Idul Fitri. Untuk data *out-sample* terdapat 3 lonjakan yaitu pada bulan terjadinya Idul Fitri yang ditandai dengan garis hijau pada Juni 2018 dan Juni 2019, serta satu bulan setelah Natal yaitu Januari 2019. Model

DNN dapat menangkap 2 lonjakan *inflow* pecahan Rp50.000 di KPw Jember, akan tetapi pada Idul Fitri 2019 hasil ramalan memiliki sedikit selisih dengan data aktual.

Dilakukan cara yang sama untuk pecahan uang kertas *inflow* maupun *outflow* di KPw Jember dan KPw lainnya. Pemilihan arsitektur optimum berdasarkan nilai RMSE dan sMAPE yang terkecil diantara 25 arsitektur lainnya.

4.3.1 Pemodelan *Inflow* dan *Outflow* dengan *Deep Neural Network* di Kantor Perwakilan Jember

Hasil arsitektur DNN yang optimum pada *inflow* maupun *outflow* di KPw Jember ditunjukkan pada Tabel 4.15.

Tabel 4.15 Arsitektur DNN Optimum *Inflow* dan *Outflow* KPw Jember

	Pecahan	Lag Input	Jumlah Neuron di Hidden Layer	
			1	2
<i>Inflow</i>	Total	1,2,3,12,13,14,15	2	4
	100.000	1,2,3,12,13,14,15	4	3
	50.000	1,2,12,13,14	3	5
	20.000	12,24	3	5
	10.000	2,10,12,14,22	3	2
	5.000	11,12,23	3	5
	2.000	1,2,3,11,12,13,14,15,23,24	3	2
	1.000	1,3,4,6,7,12,13,15,16,18,19	4	1
<i>Outflow</i>	Total	1,2,3,12,13,14,15	5	2
	100.000	1,2,3,12,13,14,15	5	2
	50.000	1,2,3,12,13,14,15	1	1
	20.000	12,24	3	2
	10.000	10,11,12,22,23	4	5
	5.000	12,24	2	4
	2.000	12	4	4
	1.000	12,24	2	2

Tabel 4.15 menunjukkan lag PACF yang signifikan sebagai *input* dari pemodelan DNN dan variabel *dummy*. Lag *input* yang digunakan adalah lag PACF dari data yang stasioner. Pada *inflow*

outflow pecahan Rp20.000, Rp10.000, Rp5.000 dan *outflow* pecahan Rp2.000, Rp1.000 tidak terdapat tren pada pola data, sehingga hanya dilakukan *differencing seasonal*. Sedangkan pada pecahan yang tidak disebutkan, terdapat tren pada *time series* plot, oleh karena itu dilakukan *differencing seasonal* maupun *non-seasonal*.

4.3.2 Pemodelan *Inflow* dan *Outflow* dengan *Deep Neural Network* di Kantor Perwakilan Kediri

Hasil arsitektur DNN yang optimum pada *inflow* maupun *outflow* di KPw Kediri ditunjukkan pada Tabel 4.16.

Tabel 4.16 Arsitektur DNN Optimum *Inflow* dan *Outflow* di KPw Kediri

	Pecahan	Lag Input	Jumlah Neuron di Hidden Layer	
			1	2
<i>Inflow</i>	Total	1,2,3,12,13,14,15	1	4
	100.000	1,2,3,12,13,14,15	2	4
	50.000	1,2,3,12,13,14,15	1	4
	20.000	11,12,23,24	5	1
	10.000	2,10,12,14,22,24	5	2
	5.000	2,12,14,23,24,35	4	3
	2.000	1,2,3,11,12,13,14,15,23,24	3	4
	1.000	1,12,13,14	1	5
<i>Outflow</i>	Total	1,2,3,4,5,12,13,14,15,16,17	5	5
	100.000	1,2,3,4,5,12,13,14,15,16,17	5	5
	50.000	1,2,3,4,5,12,13,14,15,16,17	3	2
	20.000	12,24	3	1
	10.000	10,11,12,22,23,35	1	3
	5.000	12,34	2	2
	2.000	11,12,23,24	3	4
	1.000	12,24,35,36	5	4

Semua data *inflow* dan *outflow* di KPw Kediri belum stasioner. Pada *inflow outflow* pecahan Rp20.000, Rp10.000 dan Rp5.000 serta *outflow* Rp2.000 dan Rp1.000 tidak terdapat tren namun terdapat pola musiman. Oleh karena itu dilakukan

differencing seasonal. Sedangkan pada pecahan yang tidak disebutkan terdapat tren dan pola musiman. Lag PACF yang signifikan pada data yang telah stasioner dalam tiap pecahan yang ditunjukkan pada Tabel 4.16 digunakan dalam *input* pemodelan DNN. Selain lag signifikan, *input* yang digunakan adalah variabel *dummy*. Hasil uji linier menunjukkan bahwa model non-linier adalah model yang sesuai untuk menjelaskan hubungan Y_t dengan *inputnya* pada semua pecahan di KPw Kediri.

4.3.3 Pemodelan *Inflow* dan *Outflow* dengan *Deep Neural Network* di Kantor Perwakilan Malang

Hasil arsitektur DNN yang optimum pada *inflow* maupun *outflow* di KPw Malang ditunjukkan pada Tabel 4.17.

Tabel 4.17 Arsitektur DNN Optimum *Inflow* dan *Outflow* KPw Malang

	Pecahan	Lag <i>Input</i>	Jumlah Neuron di <i>Hidden Layer</i>	
			1	2
<i>Inflow</i>	Total	1,2,3,12,13,14,15,34,35	1	3
	100.000	1,2,3,12,13,14,15,34,35	1	2
	50.000	1,2,3,6,7,12,13,14,15,18,19	4	2
	20.000	12,21,33,35	1	1
	10.000	2,10,11,12,14,22,23,24	1	1
	5.000	1,11,12,13,22,23,34	1	2
	2.000	1,2,11,12,13,14,23,24	5	3
	1.000	1,2,3,4,12,13,14,15,16	4	3
<i>Outflow</i>	Total	1,2,3,4,12,13,14,15,16	1	1
	100.000	1,2,3,4,12,13,14,15,16	5	4
	50.000	1,2,3,4,12,13,14,15,16	3	5
	20.000	12,24,34	4	4
	10.000	10,11,12,22,23	5	2
	5.000	12,13,25,34,35	2	4
	2.000	12,22,23,34,35	2	1
	1.000	12,24	1	5

Pada *inflow outflow* pecahan Rp20.000, Rp10.000 dan Rp5.000 serta *outflow* Rp2.000 dan Rp1.000 tidak terdapat tren

namun terdapat pola musiman. Oleh karena itu hanya dilakukan *differencing seasonal*. Sedangkan pecahan lainnya dilakukan *differencing seasonal* dan *non-seasonal*. Tabel 4.16 menunjukkan bahwa lag PACF untuk semua *inflow* dan *outflow* yang signifikan pada data yang telah stasioner.

4.3.4 Pemodelan *Inflow* dan *Outflow* dengan *Deep Neural Network* di Kantor Perwakilan Surabaya

Hasil arsitektur DNN yang optimum pada *inflow* maupun *outflow* di KPw Surabaya ditunjukkan pada Tabel 4.18.


Tabel 4.18 Arsitektur DNN Optimum untuk *Inflow* dan *Outflow* di KPw Surabaya

	Pecahan	Lag Input	Jumlah Neuron di Hidden Layer	
			1	2
<i>Inflow</i>	Total	1,2,3,4,12,13,14,15,16	2	5
	100.000	1,2,3,4,12,13,14,15,16	4	3
	50.000	1,2,3,4,12,13,14,15,16	5	4
	20.000	1,10,11,12,13,22,23,24,35,36	3	2
	10.000	2,10,11,12,14,22,23,24	1	2
	5.000	2,12,14,23,35	2	1
	2.000	1,2,12,13,14	1	5
	1.000	1,2,3,12,13,14,15	3	4
<i>Outflow</i>	Total	1,2,3,4,12,13,14,15,16	2	5
	100.000	1,2,3,4,12,13,14,15,16	2	5
	50.000	1,2,3,4,12,13,14,15,16	3	1
	20.000	12,13,24,25	2	2
	10.000	10,11,12,22,23	2	1
	5.000	1,12,13,22,24,34	3	5
	2.000	1,12,13,22,23,34,35	2	4
	1.000	12,24,36	1	2

Lag PACF yang signifikan pada data yang telah stasioner digunakan sebagai *input* beserta variabel *dummy*. Hasil uji linier menunjukkan bahwa model non-linier adalah model yang sesuai untuk menjelaskan hubungan Y_t dengan *inputnya* pada semua pecahan di KPw Surabaya.

4.4 Pemodelan *Inflow* dan *Outflow* dengan Hibrida ARIMAX-*Deep Neural Network* di Provinsi Jawa Timur


Setelah *inflow* pecahan Rp50.000 dimodelkan dengan ARIMAX dan didapatkan nilai residualnya, selanjutnya akan dilakukan pemodelan Hibrida ARIMAX-DNN. Residual ARIMAX akan dimodelkan dengan DNN dan hasil ramalan DNN akan dijumlahkan dengan ramalan ARIMAX. Pemodelan residual ARIMAX menggunakan DNN bertujuan agar meningkatkan akurasi, dikarenakan data *time series* cenderung tidak cukup hanya dimodelkan oleh satu model (Khashei & Bijari, 2010). Pemodelan residual ARIMAX menggunakan arsitektur DNN dua *hidden layer* dengan jumlah masing-masing *layer* adalah satu hingga lima neuron. Fungsi aktivasi yang digunakan pada *hidden layer* adalah sigmoid dan fungsi aktivasi yang digunakan pada *output layer* adalah linier. Terdapat dua jenis *input* yang digunakan dalam pemodelan residual ARIMAX menggunakan metode DNN, *input* yang pertama adalah model AR pada model ARIMAX dan *input* yang kedua adalah lag 1,12 dan 35 untuk menghilangkan efek *trend*, *seasonal* dan kalender variasi (Faraway & Chatfield, 1998).



Gambar 4.17 Lag PACF Residual ARIMAX *Inflow* Rp50.000 di KPw Jember

Penggunaan *input* lag 1,12 dan 35 juga dikarenakan lag PACF pada residual ARIMAX tidak ada yang signifikan yang ditunjukkan pada Gambar 4.16. Pemilihan arsitektur optimum adalah berdasarkan nilai RMSE dan sMAPE terkecil pada data *out-sample* dan dicobakan untuk *input* pertama adalah berdasarkan

model ARIMAX(1,0,0) yang berarti *input* hanya lag 1. Sedangkan pada *input* kedua adalah lag 1,12 dan 35. Berikut adalah hasil perbandingan nilai RMSE dan sMAPE.




Gambar 4.18 Perbandingan RMSE dan sMAPE Data *Out-Sample* berdasarkan *Input* Hibrida ARIMAX-DNN *Inflow* Rp50.000 di KPw Jember

Gambar 4.18 menunjukkan jika pada model DNN dengan *input* lag 1 cenderung menghasilkan nilai RMSE dan sMAPE yang konstan dan lebih kecil dibanding *input* lag 1,12,35.

Tabel 4.19 Nilai RMSE dan sMAPE Terkecil Data *Out-Sample* untuk Setiap *Input* Hibrida ARIMAX-DNN *Inflow* Rp50.000 di KPw Jember

Lag Input	Kombinasi ke-	RMSE	sMAPE
1	17	100,615	14,448
1,12,35	11	100,708	14.644

Berdasarkan Tabel 4.19 dimana merupakan kombinasi terbaik dari setiap *input* menunjukkan jika *input* dengan lag 1 memiliki nilai RMSE dan sMAPE terkecil. Sehingga *input* yang digunakan untuk memodelkan residual ARIMAX menggunakan metode DNN adalah lag 1. Diantara 25 kombinasi neuron, kombinasi ke-17 adalah kombinasi dimana terdapat 2 *neuron* pada *hidden layer* 1 dan 4 *neuron* pada *hidden layer* 2. Arsitektur kombinasi ke-17 metode DNN pada residual ARIMAX ditunjukkan pada Gambar 4.19.



Gambar 4.19 Arsitektur Optimum Hibrida ARIMAX-DNN *Inflow* Rp50.000 di KPw Jember

Persamaan model dari arsitektur optimum Hibrida ARIMAX-DNN pada *inflow* pecahan Rp50.000 di KPw Jember dengan jumlah neuron pada *hidden layer* 1 sebanyak 2 neuron dan jumlah neuron pada *hidden layer* 2 sebanyak 3 neuron terdiri dari model linier dan non-linier. Didapatkan persamaan model non-linier sebagai berikut:

$$\hat{Y}_{3,t}^{(n)*} = 0,545 + 1,751f_1^{h_2}(\cdot) - 0,413f_2^{h_2}(\cdot) - 1,221f_3^{h_2}(\cdot) + 0,039f_4^{h_2}(\cdot)$$

dimana

$$f_1^{h_2}(\cdot) = (1 + \exp(-(1,317 - 0,590f_1^h(\cdot) + 0,068f_2^h(\cdot))))^{-1}$$

$$f_2^{h_2}(\cdot) = (1 + \exp(-(-0,854 - 3,966f_1^h(\cdot) + 10,944f_2^h(\cdot))))^{-1}$$

$$f_3^{h_2}(\cdot) = (1 + \exp(-(-0,989 + 0,401f_1^h(\cdot) - 0,353f_2^h(\cdot))))^{-1}$$

$$f_1^{h_2}(\cdot) = (1 + \exp(-(0,955 - 1,672f_1^{h_1}(\cdot) - 0,585f_2^{h_1}(\cdot))))^{-1}$$

dimana


$$f_1^{h_1}(\cdot) = (1 + \exp(-(0,114 + 1,355a_{t-1}^*)))^{-1}$$

$$f_2^{h_1}(\cdot) = (1 + \exp(-(7,075 - 8,619a_{t-1}^*)))^{-1}$$

Untuk model linier yang telah didapat dari model ARIMAX sebelumnya yaitu $\hat{Y}_t^{(l)}$, sehingga didapatkan model Hibrida ARIMAX-DNN

$$\hat{Y}_t = \hat{Y}_t^{(l)} + \hat{Y}_t^{(n)}.$$

Perbandingan hasil data aktual dan ramalan menggunakan arsitektur terbaik Hibrida ARIMAX-DNN ditunjukkan pada Gambar 4.20.



Gambar 4.20 Perbandingan Hasil Ramalan Hibrida ARIMAX-DNN *Inflow* Rp50.000 di KPw Jember

Gambar 4.20 menunjukkan hasil ramalan Hibrida ARIMAX-DNN pada data *in-sample* dan *out-sample* telah mengikuti pola data aktual dan mampu menangkap variasi kalender Idul Fitri, akan tetapi pada Idul Fitri 2019 hasil ramalan memiliki selisih yang cukup besar dengan data aktual. Dilakukan cara yang sama untuk total uang kertas dan pecahan uang kertas *inflow* maupun *outflow* di KPw Jember dan KPw lainnya.

4.4.1 Pemodelan *Inflow* dan *Outflow* dengan Hibrida ARIMAX-DNN di Kantor Perwakilan Jember

Hasil arsitektur optimum model Hibrida ARIMAX-DNN untuk *inflow* dan *outflow* di KPw Jember ditunjukkan pada Tabel 4.20.

Tabel 4.20 Arsitektur Optimum Hibrida ARIMAX-DNN di KPw Jember

Pecahan	<i>Inflow</i>			<i>Outflow</i>		
	Lag Input	Neuron di		Lag Input	Neuron di	
		Hidden Layer			Hidden Layer	
		1	2		1	2
Total	1,12,35	4	1	1,12,35	2	4
100.000	1,12,35	5	1	3	2	4
50.000	1	2	4	1,12,35	5	4
20.000	1,12,35	4	3	1,12,35	2	1
10.000	1,12,35	4	1	1,12,35	2	5
5.000	1,12,35	2	4	1,12,35	5	2
2.000	1,12,35	2	1	1,12,35	4	3
1.000	1,12,35	4	3	1,12,35	4	1

Pemodelan Hibrida ARIMAX-DNN di KPw Jember dilakukan dan didapatkan lag PACF yang signifikan tertera pada Tabel 4.20. Pada data *inflow* dan *outflow* semua pecahan di KPw Jember cenderung memiliki nilai RMSE dan sMAPE terkecil pada lag 1,12,35, kecuali pada *inflow* pecahan Rp50.000 dan *outflow* pecahan Rp100.000 lag *input* terbaik pada lag model ARIMAX.

4.4.2 Pemodelan *Inflow* dan *Outflow* dengan Hibrida ARIMAX-DNN di Kantor Perwakilan Kediri

Hasil arsitektur optimum model Hibrida ARIMAX-DNN untuk *inflow* dan *outflow* di KPw Kediri ditunjukkan pada Tabel 4.21

Tabel 4.21 Arsitektur Optimum Hibrida ARIMAX-DNN di KPw Kediri

Pecahan	<i>Inflow</i>			<i>Outflow</i>		
	Lag Input	Neuron di		Lag Input	Neuron di	
		<i>Hidden Layer</i>			<i>Hidden Layer</i>	
		1	2		1	2
Total	1,12,35	5	3	1,12,35	4	1
100.000	1,12,35	4	3	1,12,35	4	2
50.000	1,12,35	5	4	1,12,35	5	3
20.000	1,12,35	1	5	1,12,35	1	2
10.000	1,12,35	2	2	1,12,35	4	3
5.000	1,11	4	2	1,12,35	4	5
2.000	1,12,35	5	2	1,12,35	3	2
1.000	1,12,35	2	2	1,12,35	5	3

Tabel 4.21 menyajikan lag PACF yang signifikan dan jumlah neuron optimum pada data *inflow* maupun *outflow* di KPw Kediri. Pemilihan lag optimum adalah berdasarkan nilai RMSE dan SMAPE terkecil diantara lag AR model ARIMAX dan lag 1,12,35 sebagai justifikasi tren, *seasonal* dan variasi kalender. Pada *inflow* pecahan Rp5.000 memiliki lag optimum pada lag AR model ARIMAX, sedangkan *inflow* pecahan lainnya memiliki lag optimum 1,12,35. Untuk semua pecahan pada data *outflow* memiliki lag optimum 1,12,35 dibandingkan lag AR model ARIMAX.

4.4.3 Pemodelan *Inflow* dan *Outflow* dengan Hibrida ARIMAX-DNN di Kantor Perwakilan Malang

Hasil arsitektur optimum model Hibrida ARIMAX-DNN untuk di KPw Malang ditunjukkan pada Tabel 4.22.

Tabel 4.22 Arsitektur Optimum Hibrida ARIMAX-DNN di KPw Malang

Pecahan	<i>Inflow</i>			<i>Outflow</i>		
	Lag Input	Neuron di		Lag Input	Neuron di	
		<i>Hidden Layer</i>			<i>Hidden Layer</i>	
		1	2		1	2
Total	1,12,35	2	2	1,12,35	5	5
100.000	1,12,35	4	2	1,12,35	4	5
50.000	1,12,35	1	3	1,12,35	2	4
20.000	1,12,35	4	5	1,12,35	4	5
10.000	1,12,35	5	5	1,12,35	2	4
5.000	1,12,35	2	5	1,12,35	4	2
2.000	1,12,35	5	4	1,12,35	4	3
1.000	1,12,35	4	4	1,12,35	4	1

Tabel 4.22 menunjukkan lag *input* pada *inflow* maupun *outflow* untuk semua pecahan di KPw Malang memiliki lag optimum pada lag 1,12,35. Arsitektur pada semua pecahan cenderung kompleks dimana jumlah neuron didominasi 4 dan 5.

4.4.4 Pemodelan *Inflow* dan *Outflow* dengan Hibrida ARIMAX-DNN di Kantor Perwakilan Surabaya

Hasil arsitektur optimum model Hibrida ARIMAX-DNN untuk *inflow* dan *outflow* di KPw Surabaya ditunjukkan Tabel 4.23.


Tabel 4.23 Arsitektur Optimum Hibrida ARIMAX-DNN di KPw Surabaya

Pecahan	<i>Inflow</i>			<i>Outflow</i>		
	Lag Input	Neuron di		Lag Input	Neuron di	
		<i>Hidden Layer</i>			<i>Hidden Layer</i>	
		1	2		1	2
Total	1,12,35	4	5	2,4	2	4
100.000	4	1	5	4	2	4
50.000	1,12,35	2	5	1,12,35	4	2
20.000	1,12,35	1	4	1,12,35	4	2
10.000	1,12,35	2	5	1,12,35	4	1
5.000	1,12,35	1	2	1,12,35	5	1
2.000	1,12,35	5	5	1,12,35	5	3
1.000	1,12,35	1	1	1,12,35	2	3

Tabel 4.23 menunjukkan pemodelan Hibrida ARIMAX-DNN pada data *outflow* di KPw Surabaya cenderung memiliki lag *input* yaitu lag 1,12,35, kecuali pada *inflow* pecahan Rp100.000 dan *outflow* total uang kertas serta pecahan Rp100.000. Arsitektur optimum pada *inflow* didominasi jumlah neuron sebanyak 1 dan 5, sedangkan pada *outflow* didominasi jumlah neuron sebanyak 2 dan 4.

4.5 Perbandingan Hasil Peramalan *Inflow* dan *Outflow* di Provinsi Jawa Timur

Setelah dilakukan analisis model ARIMAX, DNN dan Hibrida ARIMAX-DNN dilakukan perbandingan hasil peramalan *inflow* dan *outflow* untuk setiap KPw. Perbandingan hasil peramalan dilakukan guna mendapatkan metode terbaik berdasarkan nilai RMSE dan sMAPE terkecil pada data *out-sample*. Perbandingan peramalan pada *inflow* pecahan Rp50.000 di KPw Jember ditunjukkan Tabel 4.21.



Gambar 4.21 Perbandingan Hasil Ramalan *Inflow* Rp50.000 di KPw Jember

Hasil peramalan menggunakan metode ARIMAX, DNN dan Hibrida ARIMAX-DNN ditunjukkan pada Gambar 4.16 dimana terdapat data *in-sample* dan *out-sample*. Periode data *in-sample* adalah bulan Januari 2010 hingga Desember 2017, sedangkan data *out-sample* memiliki periode Januari 2018 hingga Juni 2019. Pada plot *in-sample* maupun *out-sample* menunjukkan bahwa ketiga metode mampu menangkap pola data aktual. Terdapat 3 lonjakan

nilai *inflow* pada data *out-sample* yaitu pada Januari 2018, Juni 2018, Januari 2019 dan Juni 2019. Metode ARIMAX dan Hibrida mampu mencapai data aktual saat terjadi lonjakan, kecuali pada Juni 2018 hasil ramalan lebih rendah dibanding data aktual. Namun hasil ramalan metode DNN cenderung lebih tepat mengikuti pola data aktual *out-sample* dibanding metode lainnya. Nilai RMSE dan sMAPE untuk tiap metode ditunjukkan Tabel 4.24.


Tabel 4.24 Nilai Keباikan Model *Inflow* Rp50.000 di KPw Jember









Model	In-Sample		Out-Sample	
	RMSE	sMAPE	RMSE	sMAPE
ARIMAX	40,357	0,135	100,723	0,146
DNN	19,250	0,052	81,327	0,121
Hibrida ARIMAX-DNN	39,658	0,135	100,615	0,144


Tabel 4.24 menyajikan nilai RMSE dan sMAPE untuk setiap metode. Setelah dilakukan perbandingan, metode DNN memiliki nilai RMSE dan sMAPE terkecil dibandingkan ketiga model lainnya. Sehingga dapat disimpulkan jika *inflow* pecahan Rp50.000 baik dimodelkan menggunakan metode DNN.


4.5.1 Perbandingan Hasil Peramalan *Inflow* dan *Outflow* di Kantor Perwakilan Jember


Hasil perbandingan ramalan untuk *inflow* dan *outflow* di KPw Jember ditunjukkan pada Gambar 4.22.











Gambar 4.22 Perbandingan Hasil Ramalan Ketiga Metode di KPw Jember

Gambar 4.22 menyajikan perbandingan hasil ramalan *inflow* maupun *outflow* pada data *in-sample* maupun data *out-sample*. Dapat diketahui jika data *out-sample* total uang kertas, pecahan Rp100.000 dan pecahan Rp50.000 pada variasi kalender Idul Fitri tidak mengalami lonjakan yang sangat tinggi. Berdasarkan metode ARIMAX, DNN dan Hibrida ARIMAX-DNN selanjutnya dilakukan perbandingan nilai kesalahan ramalan antar model yang digunakan. Nilai kesalahan ramalan yang digunakan adalah RMSE dan sMAPE ditunjukkan pada Tabel 4.25.

Tabel 4.25 Nilai RMSE dan sMAPE *Inflow* dan *Outflow* di KPw Jember

Pecahan	Metode	<i>Inflow</i>				<i>Outflow</i>			
		<i>Data In-Sample</i>		<i>Data Out-Sample</i>		<i>Data In-Sample</i>		<i>Data Out-Sample</i>	
		RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE
Total	ARIMAX	112,020	0,193	268,102	0,134	140,605	0,321	359,444	0,282
	DNN	52,412	0,056	285,723	0,133	31,443	0,052	654,118	0,450
	HIBRIDA	73,961	0,071	264,849	0,125	130,226	0,178	342,558	0,267
100.000	ARIMAX	73,823	0,264	199,677	0,184	102,672	0,411	173,155	0,251
	DNN	20,841	0,041	197,160	0,190	9,598	0,040	408,318	0,381
	HIBRIDA	52,400	0,088	180,942	0,161	101,146	0,375	174,288	0,244
50.000	ARIMAX	40,357	0,135	100,723	0,146	43,932	0,245	177,609	0,300
	DNN	19,250	0,052	81,327	0,121	44,195	0,196	248,823	0,300
	HIBRIDA	39,658	0,135	100,615	0,144	29,662	0,127	168,248	0,292
20.000	ARIMAX	3,850	0,219	4,292	0,173	3,949	0,481	23,060	0,698
	DNN	0,999	0,055	3,653	0,253	1,228	0,238	12,990	0,721
	HIBRIDA	1,938	0,174	3,653	0,157	3,585	0,481	23,579	0,699
10.000	ARIMAX	4,688	0,349	7,291	0,389	3,412	0,458	27,501	0,667
	DNN	0,820	0,067	7,037	0,315	0,810	0,223	15,261	0,560
	HIBRIDA	3,692	0,280	7,138	0,331	2,759	0,526	25,852	0,605
5.000	ARIMAX	2,899	0,370	8,064	0,447	2,906	0,586	24,546	0,713
	DNN	0,798	0,083	3,144	0,282	0,625	0,206	25,167	0,756
	HIBRIDA	2,959	0,252	8,229	0,466	2,054	0,532	24,392	0,678
2.000	ARIMAX	1,465	0,519	3,309	0,567	1,665	0,571	8,064	0,624
	DNN	0,328	0,115	2,843	0,432	0,242	0,155	10,087	0,747
	HIBRIDA	1,105	0,346	2,936	0,527	1,064	0,475	8,111	0,585
1.000	ARIMAX	0,237	0,485	0,208	1,849	0,271	0,933	0,182	1,845
	DNN	0,040	0,092	0,099	0,353	0,057	0,570	0,112	1,002
	HIBRIDA	0,143	0,394	0,246	1,747	0,189	1,193	0,192	1,682


Tabel 4.26 Metode Terbaik *Inflow* dan *Outflow* di KPw Jember









Pecahan	Metode Terbaik	
	<i>Inflow</i>	<i>Outflow</i>
Total	Hibrida ARIMAX-DNN	Hibrida ARIMAX-DNN
100.000	Hibrida ARIMAX-DNN	ARIMAX
50.000	DNN	Hibrida ARIMAX-DNN
20.000	Hibrida ARIMAX-DNN	DNN
10.000	DNN	DNN
5.000	DNN	Hibrida ARIMAX-DNN
2.000	DNN	ARIMAX
1.000	DNN	DNN


Pemilihan metode terbaik untuk setiap pecahan adalah berdasarkan nilai RMSE dan sMAPE terkecil pada data *out-sample*. Tabel 4.26 menyajikan metode terbaik untuk *inflow* dan *outflow* di KPw Jember berdasarkan nilai RMSE dan sMAPE yang terkecil. Dapat diketahui jika pada KPw Jember, terdapat 8 pecahan dengan metode terbaik menggunakan DNN. Sedangkan untuk metode Hibrida ARIMAX-DNN baik untuk memodelkan 6 pecahan dan terdapat 2 pecahan yang baik dimodelkan menggunakan metode ARIMAX.


4.5.2 Perbandingan Hasil Peramalan *Inflow* dan *Outflow* di Kantor Perwakilan Kediri


Hasil perbandingan ramalan untuk *inflow* dan *outflow* di KPw Kediri ditunjukkan pada Gambar 4.23.











Gambar 4.23 Perbandingan Hasil Ramalan Ketiga Metode di KPw Kediri

Berdasarkan Gambar 4.23 dapat diketahui jika hasil ramalan pada pecahan Rp5.000, Rp2.000 dan Rp1.000 cenderung tidak mengikuti pola dikarenakan diduga ada faktor lain yang menyebabkan data tidak memiliki pola tertentu seperti pecahan lainnya. Hasil ramalan *outflow* cenderung lebih stabil dibandingkan data *inflow*, hal ini dikarenakan pola data *inflow* terdapat lonjakan lain selain Idul Fitri terutama untuk pecahan besar seperti total uang kertas, Rp100.000 dan Rp50.000.

Tabel 4.27 Nilai RMSE dan sMAPE Inflow dan Outflow di KPw Kediri

Pecahan	Metode	Inflow				Outflow			
		Data In-Sample		Data Out-Sample		Data In-Sample		Data Out-Sample	
		RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE
Total	ARIMAX	180,538	0,255	474,396	0,268	269,964	0,278	602,404	0,398
	DNN	126,689	0,119	552,149	0,296	48,124	0,042	635,851	0,326
	HIBRIDA	167,185	0,122	466,008	0,261	212,164	0,164	556,699	0,332
100.000	ARIMAX	122,174	0,364	405,463	0,353	206,223	0,327	489,943	0,443
	DNN	57,244	0,112	436,517	0,393	32,291	0,036	455,730	0,371
	HIBRIDA	102,906	0,136	396,205	0,343	126,337	0,163	460,288	0,409
50.000	ARIMAX	63,732	0,197	155,084	0,261	83,624	0,257	200,234	0,407
	DNN	50,637	0,124	150,687	0,254	13,823	0,046	145,842	0,307
	HIBRIDA	55,677	0,117	150,664	0,255	51,959	0,157	158,329	0,338
20.000	ARIMAX	7,756	0,327	20,106	0,468	9,164	0,541	22,643	0,702
	DNN	1,459	0,070	12,704	0,391	2,921	0,316	20,635	0,731
	HIBRIDA	6,682	0,260	12,344	0,364	8,654	0,637	22,285	0,686
10.000	ARIMAX	9,915	0,466	18,623	0,569	4,247	0,496	20,602	0,653
	DNN	1,023	0,068	29,356	0,568	2,280	0,323	11,861	0,503
	HIBRIDA	8,139	0,390	15,341	0,489	2,494	0,437	20,156	0,696
5.000	ARIMAX	5,719	0,358	15,751	0,530	2,821	0,430	9,243	0,673
	DNN	0,789	0,073	19,710	0,749	0,674	0,200	6,332	0,550
	HIBRIDA	4,940	0,315	14,630	0,475	1,111	0,330	8,424	0,574
2.000	ARIMAX	2,868	0,595	7,414	0,762	1,383	0,387	3,240	0,599
	DNN	0,341	0,062	6,837	0,563	0,287	0,295	2,209	0,554
	HIBRIDA	1,610	0,342	5,557	0,564	1,055	0,411	3,247	0,630
1.000	ARIMAX	0,553	0,604	0,215	1,801	0,491	1,164	0,210	1,828
	DNN	0,322	0,336	0,212	0,662	0,524	0,689	0,253	0,740
	HIBRIDA	0,392	0,706	0,216	1,739	0,254	1,076	0,298	1,227

Pemilihan metode terbaik yaitu berdasarkan nilai RMSE dan sMAPE yang terkecil pada data *out-sample* yang disajikan Tabel 4.27. Metode terbaik di KPw Kediri ditunjukkan Tabel 4.28.


Tabel 4.28 Metode Terbaik *Inflow* dan *Outflow* di KPw Kediri


Pecahan	Metode Terbaik	
	<i>Inflow</i>	<i>Outflow</i>
Total	Hibrida ARIMAX-DNN	Hibrida ARIMAX-DNN
100.000	Hibrida ARIMAX-DNN	Hibrida ARIMAX-DNN
50.000	Hibrida ARIMAX-DNN	DNN
20.000	Hibrida ARIMAX-DNN	DNN
10.000	Hibrida ARIMAX-DNN	DNN
5.000	Hibrida ARIMAX-DNN	DNN
2.000	Hibrida ARIMAX-DNN	DNN
1.000	DNN	ARIMAX


Berdasarkan Tabel 4.28, metode terbaik data *inflow* didominasi oleh Hibrida ARIMAX-DNN dan metode terbaik pada data *outflow* didominasi oleh DNN. Terdapat 7 pecahan dengan metode terbaik Hibrida ARIMAX-DNN untuk data *inflow*, sedangkan pada data *outflow* hanya 2 pecahan dengan metode terbaik Hibrida ARIMAX-DNN.


4.5.3 Perbandingan Hasil Peramalan *Inflow* dan *Outflow* di Kantor Perwakilan Malang


Hasil perbandingan ramalan untuk *inflow* dan *outflow* di KPw Malang ditunjukkan pada Gambar 4.24.











Gambar 4.24 Perbandingan Hasil Ramalan Ketiga Metode di KPw Malang

Gambar 4.24 menunjukkan hasil ramalan data *out-sample inflow* pecahan Rp2.000 memiliki hasil ramalan yang tidak mengikuti pola, sedangkan pecahan Rp1.000 memiliki hasil ramalan Hibrida yang bernilai hampir sama setiap bulannya. Untuk data *out-sample outflow*, pecahan yang hasil ramalan tidak mengikuti pola data aktual adalah pecahan Rp1.000. Pada pecahan Rp1.000 data *inflow* dan *outflow* memiliki nilai data aktual yang cenderung konstan dan tidak terjadi lonjakan ketika Idul Fitri.

Tabel 4.29 Nilai RMSE dan sMAPE *Inflow* dan *Outflow* di KPw Malang

Pecahan	Metode	<i>Inflow</i>				<i>Outflow</i>			
		<i>Data In-Sample</i>		<i>Data Out-Sample</i>		<i>Data In-Sample</i>		<i>Data Out-Sample</i>	
		RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE
Total	ARIMAX	176,317	0,159	300,159	0,172	167,250	0,322	440,601	0,358
	DNN	104,845	0,072	281,906	0,154	111,231	0,159	777,308	0,461
	HIBRIDA	144,311	0,085	278,103	0,154	101,374	0,139	394,888	0,496
100.000	ARIMAX	108,133	0,203	247,270	0,242	112,098	0,397	225,716	0,357
	DNN	64,792	0,084	175,854	0,145	19,972	0,056	526,302	0,614
	HIBRIDA	75,807	0,096	217,228	0,203	91,112	0,239	215,751	0,350
50.000	ARIMAX	70,410	0,147	160,683	0,184	73,472	0,314	254,423	0,354
	DNN	10,430	0,013	177,046	0,256	15,315	0,069	328,354	0,634
	HIBRIDA	64,411	0,107	163,613	0,196	76,837	0,226	253,245	0,355
20.000	ARIMAX	6,228	0,296	5,968	0,297	5,006	0,667	27,898	0,943
	DNN	3,649	0,180	6,842	0,277	0,987	0,159	18,407	0,605
	HIBRIDA	4,777	0,246	4,492	0,252	2,958	0,537	26,000	0,888
10.000	ARIMAX	5,941	0,307	5,993	0,357	3,684	0,482	17,577	0,873
	DNN	2,405	0,171	4,799	0,232	0,736	0,180	17,551	0,676
	HIBRIDA	4,350	0,278	4,730	0,253	1,527	0,351	13,619	0,856
5.000	ARIMAX	5,482	0,376	5,376	0,526	3,981	0,680	21,883	0,946
	DNN	2,408	0,222	2,393	0,210	1,346	0,258	13,847	0,476
	HIBRIDA	4,299	0,356	4,575	0,462	2,462	0,508	19,027	0,858
2.000	ARIMAX	1,778	0,424	3,293	0,558	2,042	0,723	7,076	0,994
	DNN	0,057	0,009	3,014	0,531	0,558	0,286	2,419	0,454
	HIBRIDA	1,474	0,253	2,952	0,505	1,056	0,741	5,779	0,711
1.000	ARIMAX	0,357	0,472	0,226	1,940	0,578	1,269	0,255	1,879
	DNN	0,045	0,110	0,094	0,365	0,237	0,738	0,208	0,948
	HIBRIDA	0,155	0,475	0,225	1,916	0,417	1,490	0,193	1,694

Pemilihan metode terbaik yaitu berdasarkan nilai RMSE dan sMAPE yang terkecil pada data *out-sample* pada Tabel 4.29. Metode terbaik yang terpilih untuk *inflow* dan *outflow* di KPw Malang ditunjukkan Tabel 4.30.


Tabel 4.30 Metode Terbaik *Inflow* dan *Outflow* di KPw Malang









Pecahan	Metode Terbaik	
	<i>Inflow</i>	<i>Outflow</i>
Total	Hibrida ARIMAX-DNN	Hibrida ARIMAX-DNN
100.000	DNN	Hibrida ARIMAX-DNN
50.000	ARIMAX	Hibrida ARIMAX-DNN
20.000	Hibrida ARIMAX-DNN	DNN
10.000	Hibrida ARIMAX-DNN	Hibrida ARIMAX-DNN
5.000	DNN	DNN
2.000	Hibrida ARIMAX-DNN	DNN
1.000	DNN	Hibrida ARIMAX-DNN


Tabel 4.30 menunjukkan metode terbaik di KPw Malang terbanyak adalah Hibrida ARIMAX-DNN yaitu sebanyak 10 pecahan. Pada *inflow* dan *outflow* uang kertas cenderung memiliki metode terbaik Hibrida ARIMAX-DNN. Metode DNN baik untuk memetodekan 1 pecahan yaitu *inflow* Rp50.000.


4.5.4 Perbandingan Hasil Peramalan *Inflow* dan *Outflow* di Kantor Perwakilan Surabaya


Hasil perbandingan ramalan untuk *inflow* dan *outflow* di KPw Surabaya ditunjukkan pada Gambar 4.25.











Gambar 4.25 Perbandingan Hasil Ramalan Ketiga Metode di KPw Surabaya

Gambar 4.25 menyajikan hasil ramalan *inflow* dan *outflow* pada data *in-sample* dan *out-sample*. Pada *inflow* pecahan Rp2.000 memiliki hasil ramalan yang tidak mengikuti pola data aktual. Untuk *outflow* pecahan Rp1.000 pada Idul Fitri bulan Juni 2018 memiliki hasil ramalan ARIMAX dan Hibrida ARIMAX-DNN yang terlalu tinggi dibanding data aktual, sedangkan metode DNN cenderung tidak mengikuti pola aktual.

Tabel 4.31 Nilai RMSE dan sMAPE *Inflow* dan *Outflow* di KPw Surabaya


Pecahan	Metode	<i>Inflow</i>				<i>Outflow</i>			
		<i>Data In-Sample</i>		<i>Data Out-Sample</i>		<i>Data In-Sample</i>		<i>Data Out-Sample</i>	
		RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE
Total	ARIMAX	454,652	0,197	1003,055	0,161	524,945	0,263	1355,887	0,250
	DNN	207,222	0,078	1166,525	0,219	231,205	0,109	2432,857	0,380
	HIBRIDA	396,510	0,132	980,910	0,154	500,765	0,231	1335,189	0,237
100.000	ARIMAX	315,000	0,299	901,303	0,239	306,534	0,281	824,972	0,293
	DNN	65,969	0,041	889,628	0,295	145,580	0,105	1497,322	0,386
	HIBRIDA	293,755	0,178	898,907	0,239	287,333	0,245	822,500	0,285
50.000	ARIMAX	141,089	0,157	322,215	0,167	256,738	0,292	593,105	0,273
	DNN	27,969	0,022	409,122	0,221	48,769	0,050	787,040	0,393
	HIBRIDA	118,917	0,112	312,121	0,166	196,243	0,176	592,144	0,292
20.000	ARIMAX	22,703	0,292	41,025	0,340	27,363	0,767	51,160	0,619
	DNN	3,341	0,060	18,053	0,173	9,131	0,595	28,491	0,612
	HIBRIDA	19,673	0,276	38,563	0,345	14,176	0,724	51,116	0,661
10.000	ARIMAX	16,806	0,259	24,769	0,343	27,462	0,727	75,742	0,698
	DNN	18,098	0,398	29,150	0,308	9,439	0,631	88,570	0,761
	HIBRIDA	13,112	0,231	20,362	0,275	19,143	0,648	76,498	0,673
5.000	ARIMAX	13,565	0,273	26,350	0,545	24,852	0,813	33,668	0,602
	DNN	4,782	0,129	19,999	0,409	34,548	0,721	100,491	1,201
	HIBRIDA	13,130	0,248	26,474	0,549	18,372	0,775	31,998	0,683
2.000	ARIMAX	6,512	0,393	13,630	0,558	9,701	0,896	17,634	0,615
	DNN	4,976	0,192	10,005	0,326	17,164	0,772	40,419	0,806
	HIBRIDA	4,436	0,234	13,696	0,542	3,404	0,656	15,775	0,584
1.000	ARIMAX	1,100	0,415	0,666	1,892	1,132	1,130	0,464	1,627
	DNN	0,219	0,096	0,411	0,509	1,061	0,594	0,645	0,840
	HIBRIDA	0,462	0,279	0,515	1,349	0,831	0,856	0,512	0,687

Tabel 4.32 Metode Terbaik *Inflow* dan *Outflow* di KPw Surabaya

Pecahan	Metode Terbaik	
	<i>Inflow</i>	<i>Outflow</i>
Total	Hibrida ARIMAX-DNN	Hibrida ARIMAX-DNN
100.000	DNN	Hibrida ARIMAX-DNN
50.000	Hibrida ARIMAX-DNN	Hibrida ARIMAX-DNN
20.000	DNN	DNN
10.000	Hibrida ARIMAX-DNN	ARIMAX
5.000	DNN	Hibrida ARIMAX-DNN
2.000	DNN	Hibrida ARIMAX-DNN
1.000	DNN	ARIMAX

Berdasarkan Tabel 4.32 menunjukkan bahwa terdapat 8 pecahan yang memiliki metode terbaik Hibrida ARIMAX-DNN diantara kedua metode lainnya. Pada data *inflow*, metode terbaik untuk tiap pecahan didominasi oleh DNN, sedangkan metode terbaik untuk tiap pecahan data *outflow* didominasi oleh Hibrida ARIMAX-DNN.

Setelah dilakukan pemilihan metode terbaik *inflow* dan *outflow* di setiap KPw, jumlah metode terbaik untuk semua KPw ditunjukkan pada Gambar 4.26.



Gambar 4.26 Jumlah Metode Terbaik di Provinsi Jawa Timur


Gambar 4.26 menyajikan metode Hibrida ARIMAX-DNN merupakan metode terbaik yang terbanyak untuk meramalkan *inflow* dan *outflow* di semua KPw yang ada di Provinsi Jawa Timur yaitu sebanyak 32 pecahan. Selanjutnya adalah metode DNN pada data *inflow* sebanyak 14 pecahan dan pada data *outflow* sebanyak 12 pecahan. Metode ARIMAX hanya baik digunakan untuk meramalkan 6 pecahan uang kertas. Sehingga dapat disimpulkan bahwa model hibrida dan non-linier cenderung lebih baik untuk memodelkan *inflow* maupun *outflow* pecahan uang kertas yang ada di Jawa Timur. Hal ini menunjukkan jika data *time series* cenderung tidak cukup hanya dimodelkan oleh satu model (Khashei & Bijari, 2010), dan hasil penelitian ini juga sesuai dengan hasil penelitian *M4-Competition* oleh Makridakis, Spiliotis dan Assimakopoulus (2018b) yang menunjukkan bahwa metode hibrida secara rata-rata mampu meningkatkan akurasi peramalan dibanding model individual.

4.6 Peramalan *Inflow* dan *Outflow* di Provinsi Jawa Timur

Langkah selanjutnya adalah melakukan peramalan *inflow* dan *outflow* di Provinsi Jawa Timur berdasarkan model terbaik yang telah dipilih untuk masing-masing pecahan pada setiap KPw. Peramalan yang dilakukan yaitu sebanyak 18 periode kedepan yakni periode bulan Juli 2019 hingga Desember 2020. Peramalan ini dapat digunakan jika kondisi tahun 2020 diasumsikan sama dengan keadaan tahun-tahun sebelumnya. Dengan adanya pandemi COVID-19, hasil peramalan dapat digunakan beberapa persen dari jumlah *inflow* dan *outflow* untuk menyesuaikan kondisi yang ada. Berikut adalah hasil peramalan *inflow* dan *outflow* untuk setiap KPw yang ada di Provinsi Jawa Timur.

4.6.1 Peramalan *Inflow* dan *Outflow* di Kantor Perwakilan Jember


Hasil ramalan 18 periode kedepan menggunakan metode terbaik untuk setiap pecahan data *inflow* maupun *outflow* di KPw Jember ditunjukkan sebagai berikut



Gambar 4.27 Peramalan *Inflow* di KPw Jember

Gambar 4.27 menyajikan hasil ramalan 18 periode kedepan yaitu bulan Juli 2019 hingga bulan Desember 2020 untuk *inflow* di KPw Jember. Garis merah pada plot merupakan bulan terjadinya Idul Fitri yaitu pada Mei 2020. Pada tahun 2020, Idul Fitri terjadi pada minggu ke-4 sehingga *inflow* akan tinggi pada satu bulan setelah terjadinya Idul Fitri. Total uang kertas, pecahan Rp100.000, Rp50.000, dan Rp20.000 memiliki nilai *inflow* yang melonjak

sangat tinggi pada satu bulan setelah Idul Fitri yaitu bulan Juni 2020.




Gambar 4.28 Peramalan *Outflow* di KPw Jember

Garis merah pada Gambar 4.28 merupakan bulan saat Idul Fitri yaitu bulan Mei 2020. Idul Fitri tahun 2020 terjadi pada minggu ke-4 sehingga rata-rata *outflow* akan tinggi pada saat terjadinya Idul Fitri. Enam dari delapan pecahan *outflow* di KPw Jember memiliki nilai *outflow* yang melonjak tinggi pada saat terjadinya Idul Fitri, namun untuk pecahan Rp10.000 dan Rp1.000 memiliki nilai *outflow* yang tinggi pada satu bulan sebelum Idul Fitri.


4.6.2 Peramalan *Inflow* dan *Outflow* di Kantor Perwakilan Kediri

Hasil peramalan menggunakan model terbaik untuk setiap pecahan data *inflow* ditunjukkan pada Gambar 4.28, sedangkan data *outflow* ditunjukkan pada Gambar 4.29.



Gambar 4.29 Peramalan *Inflow* di KPw Kediri

Dikarenakan pada tahun 2020 Idul Fitri terjadi pada minggu ke-4, maka nilai *inflow* akan tinggi pada satu bulan setelah Idul Fitri yaitu pada bulan Juni 2020. Total uang kertas, pecahan Rp100.000, Rp 50.000, Rp20.000 dan Rp10.000 memiliki nilai *inflow* yang melonjak tinggi pada satu bulan setelah Idul Fitri. Sedangkan pecahan lainnya tidak mengalami lonjakan yang tinggi pada bulan Juni 2020.




Gambar 4.30 Peramalan *Outflow* di KPw Kediri

Gambar 4.30 menyajikan hasil ramalan *outflow* di KPw Kediri periode Juli 2019 hingga Desember 2020. Nilai *outflow* pada tiap pecahan melonjak tinggi pada saat Idul Fitri yaitu bulan Mei 2020. Pada pecahan Rp50.000 terjadi lonjakan yang sangat tinggi pada bulan Desember 2019 yaitu pada saat terjadinya Natal. Total *outflow* pecahan uang kertas pada saat Idul Fitri mengalami sedikit penurunan dari bulan sebelumnya.


4.6.3 Peramalan *Inflow* dan *Outflow* di Kantor Perwakilan Malang

Hasil peramalan menggunakan model terbaik di KPw Malang untuk data *inflow* ditunjukkan pada Gambar 4.31, sedangkan data *outflow* ditunjukkan pada Gambar 4.32.



Gambar 4.31 Peramalan *Inflow* di KPw Malang

Hasil ramalan *inflow* di KPw Malang pada saat satu bulan setelah Idul Fitri 2020 yaitu bulan Juni menunjukkan bahwa terjadi lonjakan. Pada total uang kertas *inflow* memiliki hasil ramalan cenderung konstan. Plot hasil ramalan Rp1.000 menunjukkan adanya peningkatan pada satu bulan setelah Idul Fitri namun hanya sedikit pertambahan nilai *inflow*.




Gambar 4.32 Peramalan *Outflow* di KPw Malang

Gambar 4.27 menyajikan hasil ramalan *outflow* di KPw Malang selama 18 periode dari bulan Juli 2019 hingga Desember 2020. Garis merah menandakan terjadinya Idul Fitri yaitu Mei 2020. Semua pecahan memiliki nilai *outflow* yang tinggi yaitu pada saat Idul Fitri. Pada total pecahan uang kertas, nilai *inflow* untuk setiap bulan cenderung fluktuatif dan tidak konstan, berbeda dengan pecahan lainnya yang hanya tinggi pada saat bulan terjadinya Idul Fitri.

4.6.4 Peramalan *Inflow* dan *Outflow* di Kantor Perwakilan Surabaya


Hasil ramalan 18 periode kedepan yaitu bulan Juli 2019 hingga Desember 2020 untuk *inflow* dan *outflow* di KPw Surabaya ditunjukkan sebagai berikut:



Gambar 4.33 Peramalan *Inflow* di KPw Surabaya

Garis warna merah pada Gambar 4.33 menandakan bulan terjadinya Idul Fitri yaitu bulan Mei 2020. Terdapat 5 pecahan yang memiliki nilai *inflow* melonjak tinggi ketika satu bulan setelah Idul Fitri Juni 2020 yaitu total uang kertas, pecahan Rp100.000, Rp50.000, Rp20.000 dan Rp10.000. Untuk pecahan Rp5.000 hanya terjadi sedikit lonjakan. Pada pecahan Rp2.000 dan

Rp1.000 menunjukkan bahwa pada saat Idul Fitri dan setelah Idul Fitri cenderung konstan.



Gambar 4.34 Peramalan *Outflow* di KPw Surabaya

Hasil ramalan *outflow* di KPw Surabaya untuk semua pecahan menunjukkan nilai yang tinggi pada saat Idul Fitri bulan Mei 2020. Hal ini juga telah sesuai dengan pola variasi kalender yakni hari raya Idul Fitri yang terjadi pada minggu ke 4 bulan Mei akan mengakibatkan *outflow* yang tinggi pada bulan Mei.

Dalam memenuhi kebutuhan uang di masyarakat, salah satu rencana Bank yaitu dengan menyusun Rencana Cetak Uang (RKU). Nilai ramalan *inflow* dan *outflow* per pecahan uang kertas yang dihasilkan tiap KPw dapat menjadi usulan jumlah pengadaan uang untuk Jawa Timur.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis yang telah dilakukan, maka didapatkan kesimpulan sebagai berikut:

1. Karakteristik total *inflow* dan *outflow* di KPw Surabaya memiliki nilai yang tinggi untuk semua pecahan dibandingkan KPw lainnya. Semakin besar nilai pecahan maka rata-rata dan standar deviasi akan semakin besar.
2. Nilai *inflow* mengalami kenaikan pada waktu-waktu tertentu, yakni pada saat Idul Fitri dan satu bulan setelah Idul Fitri. Sedangkan nilai *outflow* mengalami kenaikan pada saat Idul Fitri dan satu bulan sebelum Idul Fitri. Hari raya Idul Fitri yang terjadi pada minggu berbeda akan mengakibatkan perbedaan peningkatan *inflow* dan *outflow* di semua KPw yang ada di Provinsi Jawa Timur.
3. Perbandingan metode ARIMAX, DNN dan Hibrida ARIMAX-DNN menunjukkan bahwa Hibrida ARIMAX-DNN merupakan metode terbaik dalam meramalkan 32 pecahan, selanjutnya metode DNN merupakan metode terbaik dalam meramalkan 26 pecahan dan 6 pecahan lainnya baik diramalkan dengan metode ARIMAX.
4. Hasil peramalan untuk periode Juli 2019 hingga Desember 2020 menunjukkan bahwa *inflow* tertinggi pada satu bulan setelah Idul Fitri. Sedangkan hasil peramalan *outflow* tertinggi pada saat Idul Fitri. Tingginya *inflow* pada satu bulan setelah Idul Fitri dan tingginya *outflow* pada saat Idul Fitri telah sesuai dengan pola variasi kalender yakni hari raya Idul Fitri yang terjadi pada minggu ke 4 bulan Mei 2020.

5.2 Saran

Saran untuk penelitian selanjutnya adalah mempertimbangkan penggunaan deteksi *outlier* untuk mengatasi asumsi distribusi

normal yang tidak terpenuhi. Untuk metode DNN sebaiknya mencoba menggunakan fungsi aktivasi lainnya pada *hidden layer* dan dapat dijadikan perbandingan supaya mengetahui fungsi aktivasi yang sesuai pada data penelitian.

DAFTAR PUSTAKA

- Bank Indonesia. (2016). *Metadata Uang Kartal yang Diedarkan*. Retrieved January 13, 2020, from <https://www.bi.go.id/id/statistik/metadata/items/Documents/Tabel-1-Uang-Primer-21102016.pdf>
- Bank Indonesia. (2018). *Kajian Ekonomi dan Keuangan Regional Provinsi Jawa Timur*. Surabaya: Kantor Perwakilan Bank Indonesia Provinsi Jawa Timur.
- Chong, E. K., & Zak, S. H. (2001). *An Introduction to Optimization (2nd Edition)*. Canada: John Wiley & Sons, Inc.
- Crone, S. F., & Kourentzes, N. (2009). Input-variable specification for neural network - An analysis of forecasting low and high time series frequency. *International Joint Conference on Neural Network*.
- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis*. USA: Springer.
- Daniel, W. W. (1989). *Statistik Non Parametrik Terapan. Alih Bahasa: Alex Tri Kantjono W.* Jakarta: PT. Gramedia.
- Faraway, J., & Chatfield, C. (1998). Time series forecasting with neural networks: *Applied Statistic* 47(2), 231-250.
- Gujarati, D. (2004). *Basic Econometrics (4th ed.)*. New York: The McGraw-Hill.
- Hajirahimi, Z., & Khashei, M. (2019). Hybrid Structures in Time Series Modeling and Forecasting. *Engineering Applications of Artificial Intelligence* 86, 83-106.
- He, W. (2017). Load Forecasting via Deep Neural Network. *Procedia Computer Science* 122, 308-314.

- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting* 22, 679-688.
- Hyndman, R. J., & Kostenko, A. V. (2008). *Forecasting without significance tests?* Diambil kembali dari <https://www.semanticscholar.org/paper/Forecasting-without-significance-tests-Kostenko-Hyndman/f9e981ce476390a452f699e4f36f4acdf1450c16>
- Juliyanto, & Suhartono. (2017). *Peramalan Inflow dan Outflow Uang Kartal di Provinsi Jawa Barat menggunakan Hybrid ARIMAX-Neural Network dan GARCH*. Surabaya: Tugas Akhir, Institut Teknologi Sepuluh Nopember.
- Karlik, B., & Olgac, A. V. (2011). Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks. *International Journal of Artificial Intelligence And Expert Systems (IJAE), Volume (1): Issue (4)*, 111-122.
- Khashei, M., & Bijari, M. (2010). An artificial neural network (p, d,q) model for timeseries forecasting. *Expert Systems with Applications* 37, 479-489.
- Khashei, M., & Hajirahimi, Z. (2017). Performance evaluation of series and parallel strategies for financial time series forecasting. *Financial Innovation* 3, 1-24.
- Kim, J., Kim, H., Huh, S., Lee, J., & Choi, K. (2018). Deep Neural Network with Weighted Spikes. *Neurocomputing Vol. 311*, 373-386.

- Makridakis, S. (1993). Accuracy measures: theoretical and practical concerns. *International Journal of Forecasting* 9, 527-529.
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International Journal of Forecasting* 16, 451-476.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018a). Statistical and Machine Learning Forecasting Methods: Concerns and Ways Forward. *PLoS ONE* 13.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018b). The M4 Competition: Results, findings, conclusion and way. *International Journal of Forecasting* 34, 802-808.
- Salehah, N. A., Suhartono, & Prastyo, D. D. (2017). *Penerapan Model Hybrid ARIMAX-Quantile Regression untuk Peramalan Inflow dan Outflow Pecahan Uang Kartal di Jawa Timur*. Surabaya: Tugas Akhir, Institut Teknologi Sepuluh Nopember.
- Schmidhuber, J. (2015). Deep Learning in Neural Network: An overview. *Neural Neural*, 61, 85-117.
- Shumway, R. H., & Stoffer, D. S. (2006). *Time Series Analysis and Its Applications with R Examples*. Pittsburg: Springer.
- Smyl, S. (2020). A Hybrid Method of Exponential Smoothing and Recurrent Neural Network for Time Series Forecasting. *International Journal of Forecasting* 36, 75-85.
- Solikin, & Suseno. (2002). *Uang: Pengertian, Penciptaan, dan Peranannya dalam Perekonomian*. Jakarta: Pusat Pendidikan Studi Kebanksentralan (PPSK) Bank Indonesia.

- Suhartono. (2007). *Feedforward neural network for time series forecasting*. Yogyakarta: Disertasi, Universitas Gadjah Mada.
- Suhartono, Amalia, F. F., Saputri, P. D., Rahayu, S. P., & Ulama, B. S. (2018). Simulation Study for Determining the Best Architecture of Multilayer Perceptron for Forecasting Nonlinear Seasonal Time Series. *2nd International Conference on Statistics, Mathematics, Teaching, and Research*.
- Suhartono, Ashari, D. E., Prastyo, D. D., Kuswanto, H., & Lee, M. H. (2019). Deep Neural Network for Forecasting Inflow and Outflow in Indonesia. *Sains Malaysiana* 48(8), 1787-1798.
- Suhartono, Lee, M. H., & Hamzah, N. A. (2010). Calendar Variation Model Based on ARIMAX for Forecasting Sales Data with Ramadhan Effect. *Proceedings of the Regional Conference on Statistical Sciences 2010*, (hal. 349-361).
- Suhartono, Lee, M. H., & Prastyo, D. D. (2015). Two Levels ARIMAX and Regression Models for Forecasting Time Series Data with Calendar Variation Effects. *AIP Conference Proceedings*, (hal. 150-164).
- Suhartono, Prastyo, D. D., Puka, A. O., & Lee, M. H. (2018). Comparison between Hybrid Quantile Regression Neural Network and Autoregressive Intergrated Moving Average with Exogenous Variable fo Forecasting of Currency Inflow and Outflow in Bank Indonesia. *Jurnal Teknologi (Sciences & Engineering)* 80:6, 61-68.
- Suhartono, Rahayu, S. P., Prastyo, D. D., Wijayanti, D. G., & Julianto. (2017). Hybrid Model for Forecasting Time

- Series with Trend, Seasonal and Salendar Variation Patterns. *IOP Conf. Series: Journal of Physics: Conf. Series* 890, 012160.
- Wang, S., Chen, Z., & Chen, S. (2019). Applicability of Deep Neural Networks on Production Forecasting in Bakken. *Journal of Petroleum Science and Engineering* 179, 112-125.
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate Methods, Second Edition*. United States: Pearson Education, Inc.
- Zhang, G. P. (2003). Time Series Forecasting using a Hybrid ARIMA and Neural Network Model. *Neurocomputing* 50, 159-175.
- Zhang, G. P., & Qi, M. (2005). Neural Network Forecasting for Seasonal and Trend Time Series. *European Journal of Operational Research* 160, 501-514.
- Zhang, G., Pawuto, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of art. *International Journal of Forecasting* 14, 35-62.
- Zheng, F., & Zhong, S. (2011). Time Series Forecasting using A Hybrid RBF Neural Network and AR Model based on Binomial Smoothing. *International Journal of Mathematical, Computational, Physical, Electrical and Computer Engineering Vol:5 No:3*.

LAMPIRAN

Lampiran 1. Output ARIMAX

- Inflow* KPw Jember

Total Uang Kertas

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	12.14489	0.48774	24.90	<.0001	0	t	0
NUM2	504.43935	49.47337	10.20	<.0001	0	M_1	0
NUM3	192.63304	49.68210	3.88	0.0002	0	M_2	0
NUM4	24.08921	49.89472	0.48	0.6306	0	M_3	0
NUM5	-7.35875	50.11118	-0.15	0.8836	0	M_4	0
NUM6	141.52657	50.33145	2.81	0.0063	0	M_5	0
NUM7	87.90287	51.29052	1.71	0.0906	0	M_6	0
NUM8	131.21812	57.87692	2.27	0.0263	0	M_7	0
NUM9	-4.38382	65.37294	-0.07	0.9467	0	M_8	0
NUM10	-41.85305	59.93738	-0.70	0.4872	0	M_9	0
NUM11	-1.96692	53.75136	-0.04	0.9709	0	M_10	0
NUM12	43.26726	51.72995	0.84	0.4056	0	M_11	0
NUM13	-1.78072	51.97540	-0.03	0.9728	0	M_12	0
NUM14	851.32587	139.09136	6.12	<.0001	0	V1_t	0
NUM15	14.83481	141.81194	0.10	0.9170	0	V1_t1	0
NUM16	581.36668	101.28903	5.74	<.0001	0	V2_t	0
NUM17	83.58987	97.80513	0.85	0.3955	0	V2_t1	0
NUM18	622.12461	100.62959	6.18	<.0001	0	V3_t	0
NUM19	48.66847	100.56179	0.48	0.6298	0	V3_t1	0
NUM20	-301.69114	81.37800	-3.71	0.0004	0	V4_t	0
NUM21	884.76055	82.93224	10.67	<.0001	0	V4_t1	0
Variance Estimate				16062.06			
Std Error Estimate				126.7362			
AIC				1220.422			
SBC				1274.274			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	12.13	6	0.0591	0.265	0.078	0.026	0.157	0.050	0.129
12	18.46	12	0.1024	0.089	0.172	0.039	-0.099	0.078	0.061
18	22.58	18	0.2071	0.039	0.010	-0.056	-0.043	0.133	0.103
24	29.14	24	0.2150	0.055	-0.081	-0.064	-0.125	-0.102	-0.109
30	38.93	30	0.1274	-0.066	0.031	-0.120	-0.109	-0.194	-0.035
36	46.47	36	0.1136	-0.125	0.015	-0.108	-0.097	-0.091	-0.071
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		----p Value-----		
Shapiro-Wilk	W	0.990015	Pr < W	0.6924	
Kolmogorov-Smirnov	D	0.054407	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.033829	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq	0.279012	Pr > A-Sq	>0.2500	

Rp100.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	7.73137	0.33922	22.79	<.0001	0	t	0
NUM2	275.28679	34.40833	8.00	<.0001	0	M_1	0
NUM3	74.96490	34.55350	2.17	0.0332	0	M_2	0
NUM4	-40.58343	34.70137	-1.17	0.2459	0	M_3	0
NUM5	-51.61245	34.85192	-1.48	0.1428	0	M_4	0
NUM6	42.19732	35.00511	1.21	0.2318	0	M_5	0
NUM7	9.58345	35.66519	0.27	0.7889	0	M_6	0
NUM8	38.05089	40.25293	0.95	0.3475	0	M_7	0
NUM9	-107.24549	45.46635	-2.36	0.0209	0	M_8	0
NUM10	-127.11742	41.69596	-3.05	0.0032	0	M_9	0
NUM11	-76.12597	37.38964	-2.04	0.0452	0	M_10	0
NUM12	-35.97516	35.97776	-1.00	0.3206	0	M_11	0
NUM13	-47.60351	36.14847	-1.32	0.1919	0	M_12	0
NUM14	554.17751	96.73692	5.73	<.0001	0	V1_t	0
NUM15	-14.85019	98.62906	-0.15	0.8807	0	V2_t	0
NUM16	411.26257	70.44570	5.84	<.0001	0	V3_t	0
NUM17	59.80414	68.02268	0.88	0.3815	0	V4_t	0
NUM18	492.56659	69.98707	7.04	<.0001	0	V3_t	0
NUM19	35.05747	69.93991	0.50	0.6177	0	V3_t	0
NUM20	-179.23142	56.59774	-3.17	0.0022	0	V4_t	0
NUM21	593.04830	57.67870	10.28	<.0001	0	V4_t	0
Variance Estimate				7769.363			
Std Error Estimate				88.14399			
AIC				1150.7			
SBC				1204.552			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.68	6	0.1926	0.191	0.078	0.016	-0.170	0.029	0.116
12	16.36	12	0.1752	0.103	0.186	0.020	-0.094	0.103	0.089
18	20.13	18	0.3253	0.054	-0.050	-0.034	0.014	0.115	0.108
24	26.64	24	0.3214	0.042	-0.116	-0.063	-0.118	-0.101	-0.090
30	33.16	30	0.3158	-0.075	-0.009	-0.148	-0.056	-0.128	0.013
36	41.96	36	0.2284	-0.125	-0.004	-0.093	-0.065	-0.137	-0.105
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.977576	Pr < W	0.0989
Kolmogorov-Smirnov	D	0.059201	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.07403	Pr > W-Sq	0.2476
Anderson-Darling	A-Sq	0.557129	Pr > A-Sq	0.1496

Rp50.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.37929	0.11924	3.35	0.0013	1	y	0
NUM1	4.11011	0.27313	15.05	<.0001	0	t	0
NUM2	204.50229	21.04966	9.72	<.0001	0	M_1	0
NUM3	96.60478	21.31226	4.53	<.0001	0	M_2	0
NUM4	50.65807	21.45675	2.36	0.0209	0	M_3	0
NUM5	36.83128	21.60320	1.70	0.0924	0	M_4	0
NUM6	93.44974	21.75787	4.29	<.0001	0	M_5	0
NUM7	70.62937	22.10565	3.19	0.0021	0	M_6	0
NUM8	80.47172	24.05116	3.35	0.0013	0	M_7	0
NUM9	53.55397	26.22246	2.04	0.0447	0	M_8	0
NUM10	33.58162	25.01657	1.34	0.1836	0	M_9	0
NUM11	44.03277	23.24031	1.89	0.0620	0	M_10	0
NUM12	61.80944	22.58693	2.74	0.0078	0	M_11	0
NUM13	33.97935	22.39920	1.52	0.1335	0	M_12	0
NUM14	248.45038	49.97447	4.97	<.0001	0	V1_t	0
NUM15	-2.44008	50.16844	-0.05	0.9613	0	V1_t1	0
NUM16	201.81444	35.28020	5.72	<.0001	0	V2_t	0
NUM17	12.02124	34.80799	0.35	0.7308	0	V2_t1	0
NUM18	142.36344	35.78784	3.98	0.0002	0	V3_t	0
NUM19	-1.51067	35.49289	-0.04	0.9651	0	V3_t1	0
NUM20	-76.12628	28.70997	-2.65	0.0098	0	V4_t	0
NUM21	290.62198	28.66925	10.14	<.0001	0	V4_t1	0
Variance Estimate				2112.916			
Std Error Estimate				45.96647			
AIC				1026.408			
SBC				1082.824			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.89	5	0.8644	-0.011	0.013	-0.002	0.111	0.021	0.073
12	8.75	11	0.6448	-0.147	0.093	0.116	-0.138	-0.011	0.028
18	13.72	17	0.6866	-0.063	0.082	-0.095	-0.120	0.085	0.036
24	20.40	23	0.6176	0.029	-0.041	0.029	-0.103	0.086	-0.174
30	26.73	29	0.5860	-0.086	0.088	-0.030	-0.001	-0.165	-0.049
36	31.29	35	0.6480	-0.080	0.090	-0.102	-0.054	0.034	-0.041
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.984981	Pr < W	0.3443	
Kolmogorov-Smirnov	D	0.077786	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.068248	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq	0.402954	Pr > A-Sq	>0.2500	

Rp20.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.30703	0.09195	3.34	0.0013	1	y	0
AR1_2	0.69296	0.12189	5.68	<.0001	11	y	0
NUM1	0.10976	0.09836	1.12	0.2681	0	t	0
NUM2	14.43184	2.33228	4.92	<.0001	0	M_1	0
NUM3	13.58805	2.90512	4.67	<.0001	0	M_2	0
NUM4	11.41440	2.91532	3.92	0.0002	0	M_3	0
NUM5	9.07073	2.93199	3.09	0.0028	0	M_4	0
NUM6	9.14806	2.95889	3.09	0.0028	0	M_5	0
NUM7	8.55282	3.02878	2.82	0.0061	0	M_6	0
NUM8	10.97907	3.17991	3.45	0.0009	0	M_7	0
NUM9	17.47318	3.49926	4.99	<.0001	0	M_8	0
NUM10	11.58684	3.49786	3.31	0.0014	0	M_9	0
NUM11	8.13085	3.28810	2.47	0.0157	0	M_10	0
NUM12	8.03147	3.11018	2.58	0.0118	0	M_11	0
NUM13	9.34064	3.09081	3.02	0.0035	0	M_12	0
NUM14	3.51596	4.51214	0.78	0.4384	0	V1_t	0
NUM15	-11.81622	4.12409	-2.87	0.0054	0	V1_t1	0
NUM16	2.27240	3.37619	0.67	0.5023	0	V2_t	0
NUM17	4.97595	3.19071	1.60	0.1129	0	V2_t1	0
NUM18	-6.16244	3.09223	-1.99	0.0500	0	V3_t	0
NUM19	10.13054	3.11637	3.25	0.0017	0	V3_t1	0
NUM20	-7.36657	2.76303	-2.67	0.0094	0	V4_t	0
NUM21	8.78194	3.06556	2.86	0.0054	0	V4_t1	0
Variance Estimate				19.48954			
Std Error Estimate				4.414583			
AIC				577.2462			
SBC				636.2262			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.50	4	0.6442	-0.019	0.036	0.080	0.071	0.072	0.078
12	10.14	10	0.4283	-0.022	0.107	0.026	-0.084	0.165	0.150
18	12.29	16	0.7235	0.049	-0.112	0.026	0.009	-0.046	0.029
24	17.71	22	0.7228	0.032	0.018	0.029	-0.138	0.060	0.131
30	19.93	28	0.8672	0.036	0.038	0.041	-0.019	0.087	-0.059
36	23.28	34	0.9172	0.056	0.038	0.047	0.011	0.121	-0.022
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.854975	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.132437	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.380362	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.27421	Pr > A-Sq	<0.0050

Rp10.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.09584	0.02046	4.68	<.0001	0	t	0
NUM2	6.94923	2.07576	3.35	0.0013	0	M_1	0
NUM3	6.50171	2.08451	3.12	0.0026	0	M_2	0
NUM4	4.29548	2.05344	2.05	0.0437	0	M_3	0
NUM5	2.12335	2.10252	1.01	0.3144	0	M_4	0
NUM6	1.68929	2.11176	0.80	0.4263	0	M_5	0
NUM7	1.48365	2.15158	0.69	0.4926	0	M_6	0
NUM8	4.90766	2.42835	2.02	0.0469	0	M_7	0
NUM9	19.01615	2.74286	6.93	<.0001	0	M_8	0
NUM10	17.38272	2.51480	6.91	<.0001	0	M_9	0
NUM11	7.79305	2.25525	3.46	0.0009	0	M_10	0
NUM12	4.61943	2.17044	2.13	0.0366	0	M_11	0
NUM13	4.17295	2.18073	1.91	0.0595	0	M_12	0
NUM14	8.73687	5.83586	1.50	0.1386	0	V1_t	0
NUM15	-3.08046	5.95001	-0.52	0.6062	0	V1_t1	0
NUM16	-10.14645	4.24979	-2.39	0.0195	0	V2_t	0
NUM17	4.62791	4.10362	1.13	0.2630	0	V2_t1	0
NUM18	-12.56409	4.22212	-2.98	0.0039	0	V3_t	0
NUM19	4.16861	4.21928	0.99	0.3263	0	V3_t1	0
NUM20	-10.09387	3.41438	-2.96	0.0042	0	V4_t	0
NUM21	3.23291	3.47959	0.93	0.3558	0	V4_t1	0
Variance Estimate				28.27557			
Std Error Estimate				5.317478			
AIC				611.5694			
SBC				665.4208			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.74	6	0.1361	0.269	0.083	-0.105	-0.078	-0.004	-0.032
12	15.01	12	0.2407	-0.089	-0.054	-0.057	-0.040	0.094	0.153
18	18.75	18	0.4072	0.089	-0.079	-0.094	-0.071	-0.054	-0.038
24	27.52	24	0.2810	-0.022	-0.091	-0.063	-0.050	0.153	0.172
30	29.90	30	0.4707	0.115	-0.034	-0.026	0.029	0.031	-0.032
36	33.16	36	0.6046	-0.050	-0.017	-0.016	-0.042	-0.068	-0.108

Model for variable y
No mean term in this model.

Tests for Normality			
Test	--Statistic--	----p Value-----	
Shapiro-Wilk	W	0.737847	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.152915	Pr > D <0.0100
Cramer-von Mises	W-Sq	0.447077	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	3.420378	Pr > A-Sq <0.0050

Rp5.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.32679	0.12681	2.58	0.0120	1	y	0
AR1_2	0.85478	0.14537	5.88	<.0001	11	y	0
AR1_3	-0.47435	0.20288	-2.34	0.0222	12	y	0
NUM1	0.07829	0.02651	2.95	0.0042	0	t	0
NUM2	2.77721	1.77527	1.56	0.1221	0	M_1	0
NUM3	2.75546	1.76926	1.56	0.1238	0	M_2	0
NUM4	0.59997	1.78626	0.34	0.7379	0	M_3	0
NUM5	-0.18903	1.80580	-0.10	0.9169	0	M_4	0
NUM6	0.11532	1.83087	0.06	0.9500	0	M_5	0
NUM7	0.09224	1.86122	0.05	0.9606	0	M_6	0
NUM8	2.11925	1.97058	1.08	0.2858	0	M_7	0
NUM9	7.70945	2.12994	3.62	0.0005	0	M_8	0
NUM10	12.04020	2.04222	5.90	<.0001	0	M_9	0
NUM11	7.38984	1.94110	3.81	0.0003	0	M_10	0
NUM12	2.04747	1.89574	1.08	0.2837	0	M_11	0
NUM13	0.86457	1.89084	0.46	0.6489	0	M_12	0
NUM14	0.03612	3.31879	0.01	0.9913	0	V1_t	0
NUM15	6.48896	3.07294	2.11	0.0382	0	V1_t	0
NUM16	-3.49356	2.44319	-1.43	0.1571	0	V2_t	0
NUM17	0.27000	2.18139	0.12	0.9018	0	V2_t	0
NUM18	-4.24917	2.20884	-1.92	0.0583	0	V3_t	0
NUM19	0.33601	2.19699	0.15	0.8789	0	V3_t	0
NUM20	-6.02988	2.06853	-2.92	0.0047	0	V4_t	0
NUM21	1.09621	2.32858	0.47	0.6392	0	V4_t	0
Variance Estimate				11.20574			
Std Error Estimate				3.347497			
AIC				524.79556			
SBC				586.34			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.69	3	0.2966	0.108	0.140	-0.034	-0.049	0.043	-0.016
12	8.90	9	0.4467	-0.042	-0.010	0.037	-0.070	0.186	0.056
18	10.35	15	0.7970	0.045	0.053	-0.068	0.021	0.045	0.026
24	14.94	21	0.8261	-0.018	-0.083	-0.035	0.086	0.089	0.109
30	16.59	27	0.9407	0.040	-0.023	0.066	-0.011	-0.018	-0.071
36	21.85	33	0.9309	-0.079	0.003	-0.063	-0.115	0.008	-0.106

Model for variable y
No mean term in this model.

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.901032	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.094285	Pr > D	0.0350
Cramer-von Mises	W-Sq	0.19029	Pr > W-Sq	0.0071
Anderson-Darling	A-Sq	1.415582	Pr > A-Sq	<0.0050

Rp2.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.33942	0.09902	3.37	0.0012	1	y	0
AR1_2	0.47226	0.10974	4.30	<.0001	10	y	0
NUM1	0.06061	0.01573	3.85	0.0002	0	t	0
NUM2	0.08800	0.99631	0.09	0.9299	0	M_1	0
NUM3	-0.41122	0.99936	-0.41	0.6819	0	M_2	0
NUM4	-0.47312	0.98329	-0.48	0.6318	0	M_3	0
NUM5	-0.85555	0.98886	-0.87	0.3898	0	M_4	0
NUM6	-1.14339	0.98949	-1.16	0.2514	0	M_5	0
NUM7	-0.97812	0.99932	-0.98	0.3309	0	M_6	0
NUM8	-0.64806	1.04507	-0.62	0.5371	0	M_7	0
NUM9	0.65340	1.11527	0.59	0.5598	0	M_8	0
NUM10	2.48521	1.10637	2.25	0.0277	0	M_9	0
NUM11	3.14444	1.07365	2.93	0.0045	0	M_10	0
NUM12	1.39476	1.06555	1.31	0.1947	0	M_11	0
NUM13	-0.20459	1.06237	-0.19	0.8478	0	M_12	0
NUM14	0.80289	1.69262	0.47	0.6367	0	V1_t	0
NUM15	3.13687	1.76284	1.78	0.0793	0	V1_t1	0
NUM16	-1.41123	1.18625	-1.19	0.2380	0	V2_t	0
NUM17	-0.34595	1.22842	-0.28	0.7780	0	V2_t1	0
NUM18	-0.53077	1.16011	-0.46	0.6487	0	V3_t	0
NUM19	0.18606	1.16304	0.16	0.8733	0	V3_t1	0
NUM20	-1.97994	1.04459	-1.90	0.0620	0	V4_t	0
NUM21	-0.56057	0.97263	-0.58	0.5662	0	V4_t1	0
Variance Estimate				2.850707			
Std Error Estimate				1.688404			
AIC				392.7093			
SBC				451.6893			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.22	4	0.6962	0.023	-0.116	0.023	0.079	0.030	-0.018
12	9.82	10	0.4567	0.015	0.099	0.024	0.048	0.140	-0.190
18	11.95	16	0.7477	0.065	0.020	0.071	0.051	-0.073	-0.027
24	16.77	22	0.7761	-0.056	-0.117	0.061	-0.025	0.110	-0.071
30	18.55	28	0.9116	-0.005	0.062	-0.002	-0.061	0.026	-0.068
36	25.82	34	0.8420	-0.025	0.038	-0.122	0.002	-0.175	0.003

Model for variable y
No mean term in this model.

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.906692	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.135492	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.443816	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	2.733661	Pr > A-Sq	<0.0050	

Rp1.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	-0.96917	0.08805	-11.01	<.0001	1	y	0
MA1_2	-0.34863	0.08551	-4.08	0.0001	2	y	0
MA1_3	-0.25308	0.12247	-2.12	0.0379	3	y	0
MA1_4	-0.58065	0.11317	-5.13	<.0001	3	y	0
NUM1	-0.01914	0.0027201	-7.03	<.0001	0	t	0
NUM2	1.82666	0.16867	10.83	<.0001	0	M_1	0
NUM3	1.65352	0.18951	8.73	<.0001	0	M_2	0
NUM4	1.70955	0.19536	8.75	<.0001	0	M_3	0
NUM5	1.61010	0.18695	8.65	<.0001	0	M_4	0
NUM6	1.93677	0.18914	7.38	<.0001	0	M_5	0
NUM7	1.44435	0.19604	7.37	<.0001	0	M_6	0
NUM8	1.27196	0.20484	6.21	<.0001	0	M_7	0
NUM9	1.14383	0.20798	5.50	<.0001	0	M_8	0
NUM10	1.54025	0.19867	7.75	<.0001	0	M_9	0
NUM11	2.17164	0.20435	10.63	<.0001	0	M_10	0
NUM12	1.93214	0.20064	9.63	<.0001	0	M_11	0
NUM13	1.80112	0.17910	10.06	<.0001	0	M_12	0
NUM14	0.47775	0.27783	1.72	0.0899	0	V1_t	0
NUM15	0.79422	0.27307	2.91	0.0048	0	V1_t1	0
NUM16	0.46208	0.17016	2.72	0.0083	0	V2_t	0
NUM17	0.66606	0.19115	3.48	0.0008	0	V2_t1	0
NUM18	0.01486	0.18379	0.08	0.9358	0	V3_t	0
NUM19	0.28369	0.18895	1.51	0.1365	0	V3_t1	0
NUM20	-0.12830	0.16511	-0.78	0.4397	0	V4_t	0
NUM21	0.30328	0.17940	1.69	0.0953	0	V4_t1	0
Variance Estimate				0.075878			
Std Error Estimate				0.275459			
AIC				45.92738			
SBC				110.0361			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.21	2	0.0271	0.053	0.190	0.138	0.071	0.036	0.085
12	27.24	8	0.0006	0.118	0.020	0.117	0.258	0.152	0.253
18	28.77	14	0.0112	0.029	-0.058	0.077	0.041	0.012	0.034
24	30.65	20	0.0600	0.064	0.048	0.068	0.026	0.044	-0.037
30	34.34	26	0.1267	-0.083	0.032	-0.091	0.040	-0.095	-0.018
36	41.85	32	0.1141	-0.053	-0.113	0.036	-0.129	-0.106	-0.070

Model for variable y

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.972845	Pr < W	0.0435
Kolmogorov-Smirnov	D	0.069853	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.071363	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.528797	Pr > A-Sq	0.1807

- *Outflow KPw Jember*

Total Uang Kertas

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.32472	0.11532	2.82	0.0062	3	y	0
NUM1	8.45405	0.86386	9.79	<.0001	0	t	0
NUM2	-221.46838	71.83805	-3.08	0.0029	0	M_1	0
NUM3	-89.32356	72.39751	-1.24	0.2181	0	M_2	0
NUM4	74.32164	72.77497	1.02	0.3105	0	M_3	0
NUM5	101.34767	73.40002	1.38	0.1715	0	M_4	0
NUM6	147.99300	74.62741	1.98	0.0511	0	M_5	0
NUM7	306.11580	81.88888	3.74	0.0004	0	M_6	0
NUM8	4.08826	89.42657	0.05	0.9637	0	M_7	0
NUM9	-171.40424	83.69221	-2.05	0.0441	0	M_8	0
NUM10	-15.07392	77.73318	-0.19	0.8468	0	M_9	0
NUM11	61.37853	75.02817	0.82	0.4153	0	M_10	0
NUM12	109.22260	75.59022	1.45	0.1524	0	M_11	0
NUM13	294.81673	76.03743	3.88	0.0002	0	M_12	0
NUM14	1587.4	171.03164	9.28	<.0001	0	V1_t1	0
NUM15	-138.10824	173.32489	-0.80	0.4281	0	V1_t	0
NUM16	701.47081	123.51035	5.68	<.0001	0	V2_t1	0
NUM17	407.09037	119.13810	3.42	0.0010	0	V2_t	0
NUM18	436.04629	123.82209	3.52	0.0007	0	V3_t1	0
NUM19	856.69922	123.67906	6.93	<.0001	0	V3_t	0
NUM20	42.07118	99.52148	0.42	0.6737	0	V4_t1	0
NUM21	1449.4	101.32490	14.30	<.0001	0	V4_t	0
Variance Estimate				26731.28			
Std Error Estimate				163.437			
AIC				1270.034			
SBC				1326.449			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.81	5	0.8742	0.049	0.048	-0.039	0.030	0.044	0.093
12	13.40	11	0.2681	0.032	0.135	0.012	-0.168	0.033	0.237
18	16.63	17	0.4799	0.125	-0.082	-0.053	-0.012	-0.052	0.017
24	22.19	23	0.5086	-0.085	0.067	-0.056	-0.147	-0.027	-0.082
30	31.28	29	0.3524	-0.044	-0.002	-0.204	-0.069	-0.133	0.010
36	35.81	35	0.4302	-0.035	0.067	-0.003	-0.005	-0.092	-0.123
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.992146	Pr < W	0.8494
Kolmogorov-Smirnov	D	0.065189	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.04092	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.245996	Pr > A-Sq	>0.2500

Rp100.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.41482	0.11084	3.74	0.0004	3	y	0
NUM1	5.71988	0.70750	8.08	<.0001	0	t	0
NUM2	-177.44616	56.21823	-3.16	0.0023	0	M_1	0
NUM3	-94.01119	56.69254	-1.66	0.1015	0	M_2	0
NUM4	1.12600	57.03491	0.02	0.9843	0	M_3	0
NUM5	48.24284	57.71577	0.84	0.4059	0	M_4	0
NUM6	40.36463	58.62597	0.69	0.4933	0	M_5	0
NUM7	154.02261	63.38459	2.43	0.0175	0	M_6	0
NUM8	-15.35492	68.33143	-0.22	0.8228	0	M_7	0
NUM9	-141.21037	64.59980	-2.19	0.0320	0	M_8	0
NUM10	-17.34557	60.82860	-0.29	0.7763	0	M_9	0
NUM11	18.95574	58.77495	0.32	0.7480	0	M_10	0
NUM12	51.48670	53.19376	0.87	0.3873	0	M_11	0
NUM13	153.20961	59.62544	2.57	0.0122	0	M_12	0
NUM14	988.87972	121.28763	8.15	<.0001	0	V1_t1	0
NUM15	-234.31649	123.65761	-1.89	0.0620	0	V1_t	0
NUM16	363.49766	87.78655	4.14	<.0001	0	V2_t1	0
NUM17	230.10783	84.82775	2.71	0.0083	0	V2_t	0
NUM18	233.39606	88.51345	2.64	0.0102	0	V3_t1	0
NUM19	477.15639	87.89708	5.43	<.0001	0	V3_t	0
NUM20	-9.87937	70.86177	-0.14	0.8995	0	V4_t1	0
NUM21	814.06995	72.03728	11.30	<.0001	0	V4_t	0
Variance Estimate				14413.2			
Std Error Estimate				120.955			
AIC				1210.735			
SBC				1267.151			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.17	5	0.5251	0.113	0.090	-0.061	0.046	0.070	0.097
12	19.83	11	0.0477	0.095	0.237	0.017	-0.022	0.101	0.259
18	24.22	17	0.1135	0.146	-0.107	-0.007	0.042	-0.057	0.019
24	28.01	23	0.2154	-0.058	0.128	-0.010	-0.091	-0.000	-0.045
30	35.77	29	0.1805	-0.053	-0.003	-0.173	-0.032	-0.149	-0.015
36	47.11	35	0.0829	-0.044	0.041	-0.043	-0.062	-0.179	-0.179
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.992167	Pr < W	0.8508
Kolmogorov-Smirnov	D	0.050924	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.033085	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.231612	Pr > A-Sq	>0.2500

Rp50.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.32971	0.10944	3.01	0.0036	3	y	0
AR1_2	-0.37200	0.11800	-3.15	0.0024	10	y	0
AR1_3	0.27544	0.11956	2.30	0.0241	12	y	0
NUM1	2.52937	0.24508	10.30	<.0001	0	t	0
NUM2	-37.24262	28.29216	-1.32	0.1922	0	M_1	0
NUM3	17.91875	27.98336	0.64	0.5240	0	M_2	0
NUM4	55.45282	27.84472	1.99	0.0502	0	M_3	0
NUM5	49.97071	28.86563	1.73	0.0877	0	M_4	0
NUM6	92.58815	28.99510	3.19	0.0021	0	M_5	0
NUM7	112.00311	30.63281	3.65	0.0005	0	M_6	0
NUM8	47.92409	32.44376	1.48	0.1440	0	M_7	0
NUM9	-6.16059	32.42856	-0.19	0.8499	0	M_8	0
NUM10	-18.45971	30.05407	-0.61	0.5410	0	M_9	0
NUM11	64.85396	29.69327	2.18	0.0322	0	M_10	0
NUM12	75.20524	29.68147	2.53	0.0135	0	M_11	0
NUM13	115.65008	29.25142	3.95	0.0002	0	M_12	0
NUM14	407.95420	51.43559	7.93	<.0001	0	V1_t	0
NUM15	86.84002	48.96397	1.77	0.0804	0	V1_t	0
NUM16	216.20356	38.72414	5.58	<.0001	0	V2_t	0
NUM17	167.96405	35.72718	4.70	<.0001	0	V2_t	0
NUM18	116.01856	37.83981	3.07	0.0031	0	V3_t	0
NUM19	281.30072	38.60483	7.29	<.0001	0	V3_t	0
NUM20	0.01037	31.56565	0.00	0.9937	0	V4_t	0
NUM21	481.62229	34.60502	13.92	<.0001	0	V4_t	0
Variance Estimate				2590.58			
Std Error Estimate				50.89774			
AIC				1047.344			
SBC				1108.888			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	21.69	3	<.0001	0.154	0.208	-0.040	0.307	0.204	0.092
12	25.35	9	0.0026	-0.061	0.027	0.119	-0.034	-0.116	0.017
18	27.36	15	0.0260	0.034	0.060	-0.103	0.003	0.027	0.035
24	44.86	21	0.0018	-0.176	-0.167	-0.126	-0.087	-0.055	-0.230
30	58.50	27	0.0004	-0.157	-0.162	-0.173	-0.086	-0.109	-0.025
36	60.67	33	0.0023	-0.055	-0.001	0.036	-0.015	0.084	-0.051
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.982474	Pr < W	0.2289
Kolmogorov-Smirnov	D	0.049964	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.032067	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.27479	Pr > A-Sq	>0.2500

Rp20.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	-0.57271	0.10840	-5.28	<.0001	1	y	0
NUM1	0.05661	0.02731	2.07	0.0416	0	t	0
NUM2	1.81150	2.18316	0.83	0.4093	0	M_1	0
NUM3	2.02234	2.24622	0.90	0.3709	0	M_2	0
NUM4	3.42506	2.26095	1.51	0.1341	0	M_3	0
NUM5	4.52684	2.27530	1.99	0.0504	0	M_4	0
NUM6	9.67939	2.31018	4.19	<.0001	0	M_5	0
NUM7	9.83538	2.52965	3.89	0.0002	0	M_6	0
NUM8	-2.73706	2.75309	-0.99	0.3234	0	M_7	0
NUM9	-3.13979	2.62946	-1.19	0.2363	0	M_8	0
NUM10	-1.57539	2.43044	-0.65	0.5189	0	M_9	0
NUM11	-0.15282	2.37026	-0.06	0.9488	0	M_10	0
NUM12	1.68986	2.38672	0.71	0.4827	0	M_11	0
NUM13	3.51380	2.32644	1.51	0.1352	0	M_12	0
NUM14	35.29646	5.53050	6.38	<.0001	0	V1_t1	0
NUM15	-0.55067	5.11373	-0.11	0.9145	0	V1_t	0
NUM16	25.20481	3.61562	6.97	<.0001	0	V2_t1	0
NUM17	4.47318	3.57921	1.25	0.2153	0	V2_t	0
NUM18	27.06389	3.62881	7.46	<.0001	0	V3_t1	0
NUM19	26.39349	3.61692	7.46	<.0001	0	V3_t	0
NUM20	20.09680	2.94346	6.83	<.0001	0	V4_t1	0
NUM21	47.18808	2.95548	15.97	<.0001	0	V4_t	0
Variance Estimate				21.69895			
Std Error Estimate				4.658213			
AIC				586.8663			
SBC				643.282			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.11	5	0.9533	0.003	-0.012	-0.051	-0.073	-0.073	-0.014
12	9.86	11	0.5430	0.034	-0.066	0.032	-0.201	0.150	0.102
18	13.65	17	0.6916	0.049	-0.059	0.035	-0.153	0.001	-0.042
24	17.62	23	0.7777	0.054	0.050	0.033	0.110	0.006	-0.111
30	19.68	29	0.9025	0.027	0.052	-0.096	0.027	-0.027	0.031
36	36.83	35	0.3844	-0.033	0.003	-0.064	0.051	-0.267	-0.177

Model for variable y
No mean term in this model.

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.892487	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.136038	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.612994	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	3.432342	Pr > A-Sq	<0.0050

Rp10.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	-0.56847	0.11003	-5.17	<.0001	1	y	0
NUM1	0.05085	0.02385	2.13	0.0363	0	t	0
NUM2	1.07540	1.90888	0.56	0.5749	0	M_1	0
NUM3	1.09070	1.96321	0.56	0.5802	0	M_2	0
NUM4	1.98410	1.97605	1.00	0.3186	0	M_3	0
NUM5	3.89337	1.98911	1.96	0.0541	0	M_4	0
NUM6	9.52827	2.01980	4.72	<.0001	0	M_5	0
NUM7	10.78263	2.20463	4.89	<.0001	0	M_6	0
NUM8	-1.24002	2.49762	-0.52	0.6081	0	M_7	0
NUM9	-3.64735	2.30003	-1.59	0.1171	0	M_8	0
NUM10	-1.43061	2.12429	-0.67	0.5028	0	M_9	0
NUM11	-0.76954	2.07146	-0.37	0.7113	0	M_10	0
NUM12	0.95874	2.08582	0.46	0.6471	0	M_11	0
NUM13	2.01111	2.03399	0.99	0.3260	0	M_12	0
NUM14	33.40582	4.75773	7.02	<.0001	0	V1_t1	0
NUM15	-2.47034	4.47907	-0.55	0.5829	0	V1_t	0
NUM16	34.00157	3.21058	10.59	<.0001	0	V2_t1	0
NUM17	5.08331	3.13540	1.62	0.1092	0	V2_t	0
NUM18	21.27160	3.17536	6.70	<.0001	0	V3_t1	0
NUM19	32.68105	3.16822	10.32	<.0001	0	V3_t	0
NUM20	15.57650	2.59221	6.01	<.0001	0	V4_t1	0
NUM21	49.61910	2.58775	19.17	<.0001	0	V4_t	0
Variance Estimate				16.64773			
Std Error Estimate				4.080163			
AIC				561.4273			
SBC				617.843			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.65	5	0.7543	-0.037	-0.067	-0.035	-0.106	-0.081	-0.033
12	5.45	11	0.9076	-0.049	0.020	-0.060	0.002	0.090	0.104
18	8.85	17	0.9449	0.010	-0.097	0.067	-0.112	-0.023	-0.047
24	13.74	23	0.9342	0.042	-0.051	0.053	-0.051	0.068	-0.153
30	16.58	29	0.9683	-0.035	0.110	-0.076	-0.013	0.000	-0.042
36	24.62	35	0.9046	0.036	-0.044	0.056	0.075	-0.195	-0.050
Model for variable y									
No mean term in this model.									

Tests for Normality			
Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W	0.88276	Pr < W < 0.0001
Kolmogorov-Smirnov	D	0.144962	Pr > D < 0.0100
Cramer-von Mises	W-Sq	0.578806	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq	3.399552	Pr > A-Sq < 0.0050

Rp5.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	-0.55086	0.11469	-4.80	<.0001	1	y	0
NUM1	0.05099	0.02037	2.50	0.0145	0	t	0
NUM2	-0.28519	1.63672	-0.17	0.8621	0	M_1	0
NUM3	-0.43203	1.67906	-0.26	0.7978	0	M_2	0
NUM4	0.23561	1.69082	0.14	0.8896	0	M_3	0
NUM5	1.15421	1.70194	0.68	0.4998	0	M_4	0
NUM6	5.92689	1.72830	3.43	0.0010	0	M_5	0
NUM7	7.06193	1.89159	3.73	0.0004	0	M_6	0
NUM8	-2.55513	2.06508	-1.24	0.2199	0	M_7	0
NUM9	-4.34153	1.37084	-2.20	0.0307	0	M_8	0
NUM10	-1.35711	1.01816	-1.08	0.2852	0	M_9	0
NUM11	-1.55894	1.77215	-0.88	0.3819	0	M_10	0
NUM12	-0.82226	1.78439	-0.46	0.6463	0	M_11	0
NUM13	-0.10280	1.74300	-0.06	0.9531	0	M_12	0
NUM14	50.14054	4.20309	11.93	<.0001	0	V1_t1	0
NUM15	-0.95207	3.86608	-0.25	0.8062	0	V1_t	0
NUM16	29.62125	2.77317	10.68	<.0001	0	V2_t1	0
NUM17	4.94914	2.70547	1.83	0.0714	0	V2_t	0
NUM18	16.87362	2.74279	6.15	<.0001	0	V3_t1	0
NUM19	30.35246	2.73475	11.10	<.0001	0	V3_t	0
NUM20	12.75152	2.23393	5.71	<.0001	0	V4_t1	0
NUM21	48.10293	2.23432	21.53	<.0001	0	V4_t	0
Variance Estimate				12.39143			
Std Error Estimate				3.520146			
AIC				533.0815			
SBC				589.4972			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.89	5	0.6866	-0.024	-0.047	-0.053	-0.116	-0.073	-0.075
12	6.00	11	0.8735	-0.042	-0.012	-0.040	0.084	0.071	0.104
18	10.00	17	0.9037	0.079	-0.102	0.034	-0.107	-0.037	-0.060
24	12.51	23	0.9619	0.001	-0.053	0.088	-0.039	0.074	-0.046
30	14.50	29	0.9886	-0.074	0.055	-0.074	-0.023	-0.003	-0.011
36	23.48	35	0.9310	0.032	0.009	0.077	0.093	-0.200	-0.055
Model for variable y									
No mean term in this model.									

Tests for Normality			
Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W	0.879106	Pr < W <0.0001
Kolmogorov-Smirnov	D	0.180654	Pr > D <0.0100
Cramer-von Mises	W-Sq	0.648979	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq	3.604496	Pr > A-Sq <0.0050

Rp2.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	-0.50107	0.12064	-4.15	<.0001	1	y	0
NUM1	0.01612	0.01120	1.44	0.1543	0	t	0
NUM2	0.07501	0.31043	0.26	0.3946	0	M_1	0
NUM3	0.09306	0.33003	0.10	0.9206	0	M_2	0
NUM4	0.23963	0.33601	0.26	0.7987	0	M_3	0
NUM5	0.65823	0.94209	0.70	0.4869	0	M_4	0
NUM6	3.58696	0.95677	3.75	0.0003	0	M_5	0
NUM7	2.55219	1.05829	2.41	0.0184	0	M_6	0
NUM8	-2.20151	1.15340	-1.91	0.0602	0	M_7	0
NUM9	-0.05120	1.03620	-0.05	0.3629	0	M_8	0
NUM10	-0.41973	1.00722	-0.42	0.6781	0	M_9	0
NUM11	-0.44041	0.98046	-0.45	0.6546	0	M_10	0
NUM12	-0.19842	0.98716	-0.20	0.8412	0	M_11	0
NUM13	0.13458	0.96873	0.14	0.8899	0	M_12	0
NUM14	24.12001	2.44821	9.85	<.0001	0	V1_t1	0
NUM15	1.85043	2.19423	0.84	0.4018	0	V1_t	0
NUM16	20.35374	1.59366	12.77	<.0001	0	V2_t1	0
NUM17	2.06468	1.53381	1.35	0.1824	0	V2_t	0
NUM18	8.59093	1.55452	5.53	<.0001	0	V3_t1	0
NUM19	11.37820	1.55286	7.33	<.0001	0	V3_t	0
NUM20	7.30311	1.26336	5.78	<.0001	0	V4_t1	0
NUM21	23.40268	1.27018	18.42	<.0001	0	V4_t	0
Variance Estimate				3.978489			
Std Error Estimate				1.994615			
AIC				424.0156			
SBC				480.4313			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.12	5	0.9522	0.023	-0.000	-0.089	-0.019	-0.047	0.008
12	3.42	11	0.3899	-0.013	0.014	-0.089	0.027	0.100	-0.043
18	8.30	17	0.9598	0.202	-0.033	-0.017	-0.014	-0.019	-0.008
24	14.58	23	0.9091	-0.003	-0.038	0.051	-0.207	-0.019	-0.046
30	15.29	29	0.9826	-0.014	0.065	0.008	-0.022	0.015	0.005
36	29.77	35	0.7185	0.015	0.015	0.002	-0.093	-0.291	0.020
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.787761	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.225341	Pr > D	<0.0100
Cramer-von Mises	W-Sq	1.37583	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	7.126755	Pr > A-Sq	<0.0050

Rp1.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	-0.0043660	0.0012007	-3.64	0.0005	0	t	0
NUM2	0.37533	0.12180	3.09	0.0026	0	M_1	0
NUM3	0.38633	0.12231	3.16	0.0023	0	M_2	0
NUM4	0.39136	0.12283	3.19	0.0021	0	M_3	0
NUM5	0.40888	0.12337	3.31	0.0014	0	M_4	0
NUM6	0.38686	0.12572	3.08	0.0029	0	M_5	0
NUM7	0.14564	0.14207	1.03	0.3086	0	M_6	0
NUM8	0.07575	0.16053	0.47	0.6384	0	M_7	0
NUM9	0.67376	0.14700	4.58	<.0001	0	M_8	0
NUM10	0.34249	0.13173	2.60	0.0112	0	M_9	0
NUM11	0.29282	0.12675	2.31	0.0236	0	M_10	0
NUM12	0.29842	0.12735	2.34	0.0218	0	M_11	0
NUM13	0.44246	0.12795	3.46	0.0009	0	M_12	0
NUM14	0.29489	0.34242	0.86	0.3919	0	V1_t	0
NUM15	0.28513	0.34912	0.82	0.4167	0	V1_t	0
NUM16	0.20880	0.24936	0.84	0.4051	0	V2_t	0
NUM17	0.02026	0.24078	0.08	0.9332	0	V2_t	0
NUM18	0.80124	0.24773	3.23	0.0018	0	V3_t	0
NUM19	0.33044	0.24757	1.33	0.1860	0	V3_t	0
NUM20	0.53999	0.20034	2.99	0.0037	0	V4_t	0
NUM21	2.17455	0.20417	10.65	<.0001	0	V4_t	0
Variance Estimate				0.097346			
Std Error Estimate				0.312003			
AIC				67.10705			
SBC				120.3584			
Number of Residuals				36			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.17	6	0.6536	0.129	0.130	-0.025	-0.059	0.006	-0.069
12	7.94	12	0.7897	-0.024	-0.013	0.021	0.031	0.147	-0.056
18	16.43	18	0.5828	-0.096	-0.142	-0.171	-0.055	-0.099	-0.038
24	27.37	24	0.2875	-0.120	-0.009	0.079	0.200	0.127	0.095
30	32.62	30	0.3393	-0.062	-0.124	-0.110	-0.078	0.023	-0.028
36	48.86	36	0.0747	-0.002	0.037	0.099	0.170	-0.152	-0.206
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	----p Value----		
Shapiro-Wilk	W	0.875579	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.158529	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.534513	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.997245	Pr > A-Sq	<0.0050

- Inflow KPw Kediri**

Total Uang Kertas

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	14.80116	0.79164	18.70	<.0001	0	t	0
NUM2	714.77146	80.29944	8.90	<.0001	0	M_1	0
NUM3	118.55276	80.63822	1.47	0.1457	0	M_2	0
NUM4	-8.78362	80.98332	-0.11	0.9139	0	M_3	0
NUM5	39.03813	81.33466	0.48	0.6326	0	M_4	0
NUM6	43.35130	81.69217	0.53	0.5972	0	M_5	0
NUM7	-130.81771	83.23260	-1.57	0.1202	0	M_6	0
NUM8	149.62714	93.93910	1.59	0.1154	0	M_7	0
NUM9	257.30270	106.10577	2.42	0.0177	0	M_8	0
NUM10	-10.02208	97.28340	-0.10	0.9182	0	M_9	0
NUM11	-54.35116	87.24298	-0.62	0.5352	0	M_10	0
NUM12	-8.25010	83.96206	-0.10	0.9220	0	M_11	0
NUM13	-224.73047	84.36044	-2.66	0.0094	0	M_12	0
NUM14	1450.2	225.75936	6.42	<.0001	0	V1_t	0
NUM15	-318.54701	230.17270	-1.38	0.1705	0	V1_t1	0
NUM16	959.83918	164.40060	5.84	<.0001	0	V2_t	0
NUM17	242.95667	158.74595	1.53	0.1301	0	V2_t1	0
NUM18	510.50340	163.33028	3.13	0.0025	0	V3_t	0
NUM19	271.23817	163.22023	1.66	0.1007	0	V3_t1	0
NUM20	-407.94462	132.06333	-3.09	0.0028	0	V4_t	0
NUM21	1631.3	134.60539	12.12	<.0001	0	V4_t1	0
Variance Estimate				42313.92			
Std Error Estimate				205.7035			
AIC				1313.413			
SBC				1367.265			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.35	6	0.8853	0.096	-0.036	-0.013	0.095	-0.051	0.029
12	6.05	12	0.9135	-0.038	0.108	-0.006	-0.099	-0.064	0.084
18	15.44	18	0.6314	-0.066	-0.185	-0.183	-0.093	-0.020	0.016
24	20.16	24	0.6874	-0.127	-0.125	-0.034	-0.047	-0.050	0.026
30	25.98	30	0.6761	-0.002	-0.061	-0.083	-0.091	-0.057	0.149
36	38.50	36	0.3572	0.009	0.125	0.094	0.208	0.048	-0.111

Model for variable y
No mean term in this model.

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.98415	Pr < W	0.3015	
Kolmogorov-Smirnov	D	0.076837	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.0789	Pr > W-Sq	0.2188	
Anderson-Darling	A-Sq	0.490714	Pr > A-Sq	0.2229	

Rp100.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	9.78730	0.54330	18.01	<.0001	0	t	0
NUM2	363.39242	55.10900	6.59	<.0001	0	M_1	0
NUM3	-4.35828	55.34150	-0.08	0.9374	0	M_2	0
NUM4	-80.12224	55.57835	-1.44	0.1536	0	M_3	0
NUM5	-39.80193	55.81947	-0.71	0.4780	0	M_4	0
NUM6	-26.38165	56.06482	-0.47	0.6393	0	M_5	0
NUM7	-135.26960	57.12201	-2.37	0.0205	0	M_6	0
NUM8	60.46500	64.46981	0.94	0.3513	0	M_7	0
NUM9	52.09156	72.81973	0.72	0.4766	0	M_8	0
NUM10	-140.48136	66.76499	-2.10	0.0387	0	M_9	0
NUM11	-147.33061	59.87431	-2.46	0.0162	0	M_10	0
NUM12	-112.37490	57.62264	-1.95	0.0549	0	M_11	0
NUM13	-228.75493	57.89604	-3.95	0.0002	0	M_12	0
NUM14	1008.8	154.93559	6.51	<.0001	0	V1_t	0
NUM15	-379.13719	157.96608	-2.40	0.0189	0	V1_t1	0
NUM16	666.49704	112.82710	5.91	<.0001	0	V2_t	0
NUM17	133.01837	108.94635	1.22	0.2259	0	V2_t1	0
NUM18	400.11046	112.09255	3.57	0.0006	0	V3_t	0
NUM19	106.42504	112.01702	0.95	0.3451	0	V3_t1	0
NUM20	-223.53038	30.64796	-2.47	0.0160	0	V4_t	0
NUM21	1082.1	92.37925	11.71	<.0001	0	V4_t1	0

Variance Estimate	19929.82
Std Error Estimate	141.173
AIC	1241.135
SBC	1294.986
Number of Residuals	96

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.00	6	0.6764	0.023	0.038	-0.032	0.162	-0.024	0.096
12	7.22	12	0.8431	0.005	0.123	-0.001	-0.098	-0.038	0.058
18	15.38	18	0.6358	-0.074	-0.178	-0.148	-0.080	-0.066	0.024
24	21.38	24	0.6161	-0.153	-0.133	-0.052	-0.051	-0.037	0.030
30	24.65	30	0.7418	0.006	-0.022	-0.014	-0.081	-0.066	0.108
36	34.40	36	0.5446	0.034	0.132	0.050	0.130	-0.018	-0.078

Model for variable y
No mean term in this model.

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.985992	Pr < W	0.4026
Kolmogorov-Smirnov	D	0.077656	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.087122	Pr > W-Sq	0.1701
Anderson-Darling	A-Sq	0.48116	Pr > A-Sq	0.2335

Rp50.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	4.48877	0.27749	16.18	<.0001	0	t	0
NUM2	312.41816	28.14713	11.10	<.0001	0	M_1	0
NUM3	91.47374	28.26589	3.24	0.0018	0	M_2	0
NUM4	53.39757	28.38685	1.88	0.0638	0	M_3	0
NUM5	68.07628	28.51001	2.39	0.0195	0	M_4	0
NUM6	65.54643	28.63532	2.29	0.0249	0	M_5	0
NUM7	4.98400	29.17529	0.17	0.8648	0	M_6	0
NUM8	60.61719	32.92821	1.84	0.0696	0	M_7	0
NUM9	129.50161	37.19296	3.48	0.0008	0	M_8	0
NUM10	41.64269	34.10047	1.22	0.2258	0	M_9	0
NUM11	27.16959	30.58103	0.89	0.3771	0	M_10	0
NUM12	62.78960	29.43098	2.13	0.0362	0	M_11	0
NUM13	-27.68806	29.57063	-0.94	0.3521	0	M_12	0
NUM14	419.37694	79.13395	5.30	<.0001	0	V1_t	0
NUM15	-80.66255	80.68178	-1.00	0.3206	0	V1_t1	0
NUM16	349.02480	57.62688	6.06	<.0001	0	V2_t	0
NUM17	89.86314	55.64477	1.61	0.1105	0	V2_t1	0
NUM18	171.76780	57.25170	3.00	0.0037	0	V3_t	0
NUM19	150.77806	57.21313	2.64	0.0102	0	V3_t1	0
NUM20	-131.30862	46.29880	-2.84	0.0059	0	V4_t	0
NUM21	513.71206	47.18306	10.89	<.0001	0	V4_t1	0
Variance Estimate				5199.081			
Std Error Estimate				72.10465			
AIC				1112.136			
SBC				1165.988			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.00	6	0.0884	0.204	0.041	0.181	0.155	0.055	-0.078
12	15.86	12	0.1978	-0.052	0.054	0.018	-0.163	-0.109	0.007
18	21.24	18	0.2677	-0.097	-0.094	-0.157	0.003	0.055	-0.025
24	23.85	24	0.4703	-0.074	-0.074	0.064	-0.077	0.001	-0.005
30	28.41	30	0.5487	0.030	0.018	-0.064	-0.020	0.053	0.154
36	38.58	36	0.3539	-0.034	0.078	0.104	0.100	0.022	-0.194
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--		----p Value-----	
Shapiro-Wilk	W	0.965737	Pr < W	0.0130
Kolmogorov-Smirnov	D	0.102429	Pr > D	0.0144
Cramer-von Mises	W-Sq	0.144911	Pr > W-Sq	0.0277
Anderson-Darling	A-Sq	0.884177	Pr > A-Sq	0.0233

Rp20.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.15229	0.03377	4.51	<.0001	0	t	0
NUM2	15.37649	3.42521	4.49	<.0001	0	M_1	0
NUM3	10.86163	3.43966	3.16	0.0023	0	M_2	0
NUM4	6.99858	3.45438	2.03	0.0463	0	M_3	0
NUM5	5.69574	3.46937	1.64	0.1048	0	M_4	0
NUM6	3.87383	3.48461	1.11	0.2698	0	M_5	0
NUM7	1.70239	3.55032	0.48	0.6330	0	M_6	0
NUM8	11.87365	4.00701	2.96	0.0041	0	M_7	0
NUM9	22.10751	4.52539	4.89	<.0001	0	M_8	0
NUM10	19.29105	4.14967	4.65	<.0001	0	M_9	0
NUM11	15.28725	3.72139	4.11	0.0001	0	M_10	0
NUM12	11.15016	3.58144	3.11	0.0026	0	M_11	0
NUM13	10.17328	3.59843	2.83	0.0060	0	M_12	0
NUM14	23.21117	3.62976	2.41	0.0184	0	V1_t	0
NUM15	37.57398	9.81812	3.83	0.0003	0	V1_t1	0
NUM16	-5.56486	7.01258	-0.79	0.4300	0	V2_t	0
NUM17	11.97030	6.77138	1.77	0.0812	0	V2_t1	0
NUM18	-14.93306	6.96692	-2.14	0.0353	0	V3_t	0
NUM19	19.06569	6.96223	2.74	0.0077	0	V3_t1	0
NUM20	-15.21544	5.63407	-2.70	0.0086	0	V4_t	0
NUM21	30.48731	5.74168	5.31	<.0001	0	V4_t1	0
				Variance Estimate	76.98957		
				Std Error Estimate	8.77437		
				AIC	707.73		
				SBC	761.5813		
				Number of Residuals	96		
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.62	6	0.0710	0.305	0.135	-0.072	-0.005	-0.024	-0.003
12	16.14	12	0.1851	-0.041	0.017	-0.045	0.068	0.098	0.150
18	20.32	18	0.3150	0.031	-0.077	-0.103	-0.081	-0.106	-0.022
24	27.07	24	0.3011	-0.003	-0.040	-0.064	0.022	0.295	0.065
30	30.57	30	0.4370	-0.010	-0.104	-0.072	-0.069	-0.063	-0.025
36	36.80	36	0.4316	0.002	-0.036	0.055	-0.008	0.098	-0.161
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--		----p Value-----	
Shapiro-Wilk	W	0.859628	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.105263	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.356037	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.409682	Pr > A-Sq	<0.0050

Rp10.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.17847	0.04327	4.12	<.0001	0	t	0
NUM2	11.43550	4.38924	2.61	0.0111	0	M_1	0
NUM3	7.81106	4.40776	1.77	0.0804	0	M_2	0
NUM4	4.41708	4.42663	1.00	0.3216	0	M_3	0
NUM5	2.06919	4.44583	0.47	0.6430	0	M_4	0
NUM6	0.22161	4.46537	0.05	0.9606	0	M_5	0
NUM7	-1.43290	4.54957	-0.31	0.7538	0	M_6	0
NUM8	9.74722	5.13480	1.90	0.0615	0	M_7	0
NUM9	25.38069	5.79984	4.38	<.0001	0	M_8	0
NUM10	24.11394	5.31760	4.53	<.0001	0	M_9	0
NUM11	17.08163	4.76879	3.58	0.0006	0	M_10	0
NUM12	8.74719	4.58945	1.91	0.0605	0	M_11	0
NUM13	8.33611	4.61122	1.81	0.0746	0	M_12	0
NUM14	9.35982	12.34009	0.76	0.4505	0	V1_t	0
NUM15	45.27336	12.58146	3.60	0.0006	0	V1_t1	0
NUM16	-18.51522	8.98630	-2.06	0.0428	0	V2_t	0
NUM17	9.14331	8.67721	1.05	0.2954	0	V2_t1	0
NUM18	-22.97370	8.92779	-2.57	0.0120	0	V3_t	0
NUM19	16.42015	8.92178	1.84	0.0697	0	V3_t1	0
NUM20	-17.99192	7.21980	-2.49	0.0149	0	V4_t	0
NUM21	13.63976	7.35769	1.85	0.0677	0	V4_t1	0
Variance Estimate				126.4264			
Std Error Estimate				11.24395			
AIC				755.345			
SBC				809.1964			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.87	6	0.6947	0.083	0.090	-0.086	-0.063	-0.104	-0.032
12	7.20	12	0.8441	-0.047	-0.083	0.002	-0.031	0.091	0.109
18	12.29	18	0.9321	0.001	-0.084	-0.120	-0.081	-0.116	-0.045
24	19.53	24	0.7232	0.008	-0.020	-0.047	-0.049	0.225	0.026
30	22.05	30	0.8524	0.010	-0.042	-0.068	-0.087	-0.052	-0.039
36	34.81	36	0.5251	0.064	-0.034	0.062	0.026	0.169	-0.211

Model for variable y
No mean term in this model.

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.848518	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.159167	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.484004	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	3.199793	Pr > A-Sq	<0.0050	

Rp5.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.36219	0.09513	3.81	0.0003	1	y	0
AR1_2	0.63781	0.11406	5.59	<.0001	11	y	0
NUM1	0.14639	0.10265	1.43	0.1581	0	t	0
NUM2	10.64408	4.67857	2.28	0.0258	0	M_1	0
NUM3	10.41809	4.67054	2.23	0.0288	0	M_2	0
NUM4	6.98676	4.70044	1.49	0.1415	0	M_3	0
NUM5	5.31998	4.72731	1.13	0.2642	0	M_4	0
NUM6	3.92700	4.74459	0.81	0.4225	0	M_5	0
NUM7	2.98990	4.77424	0.63	0.5331	0	M_6	0
NUM8	7.26100	4.93687	1.47	0.1457	0	M_7	0
NUM9	18.96168	5.28764	3.59	0.0006	0	M_8	0
NUM10	30.83716	5.33261	5.78	<.0001	0	M_9	0
NUM11	17.73019	5.10849	3.47	0.0009	0	M_10	0
NUM12	11.15298	4.91080	2.27	0.0261	0	M_11	0
NUM13	9.62442	4.90405	1.96	0.0535	0	M_12	0
NUM14	-10.22549	6.68803	-1.53	0.1306	0	V1_t1	0
NUM15	50.71039	6.23629	8.13	<.0001	0	V1_t	0
NUM16	-18.59748	5.14066	-3.62	0.0005	0	V2_t1	0
NUM17	2.02319	4.56398	0.44	0.6589	0	V2_t	0
NUM18	-11.12313	4.58027	-2.43	0.0176	0	V3_t1	0
NUM19	-22.00053	4.78129	-4.60	<.0001	0	V3_t	0
NUM20	-12.46016	4.07281	-3.06	0.0031	0	V4_t1	0
NUM21	-7.66268	4.42642	-1.73	0.0877	0	V4_t	0
Variance Estimate				43.01729			
Std Error Estimate				6.558757			
AIC				653.2567			
SBC				712.2367			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.87	4	0.0964	0.122	-0.170	-0.150	-0.088	-0.042	0.047
12	17.53	10	0.0635	0.035	0.039	0.048	-0.151	-0.090	-0.226
18	19.85	16	0.2763	0.088	0.024	0.030	-0.013	-0.043	-0.016
24	27.13	22	0.2061	-0.006	-0.008	0.021	0.201	0.143	0.057
30	36.62	28	0.1276	-0.221	-0.044	-0.072	-0.027	0.117	0.011
36	43.50	34	0.1275	-0.080	-0.033	-0.025	-0.088	0.115	-0.126
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.925649	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.137462	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.355393	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	2.208807	Pr > A-Sq	<0.0050	

Rp2.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.57874	0.10813	5.35	<.0001	1	y	0
AR1_2	-0.27651	0.11311	-2.44	0.0170	2	y	0
AR1_3	-0.31084	0.12175	-2.55	0.0128	12	y	0
NUM1	0.08729	0.01418	6.15	<.0001	0	t	0
NUM2	1.76601	1.17317	1.51	0.1366	0	M_1	0
NUM3	2.05734	1.18241	1.74	0.0861	0	M_2	0
NUM4	0.12108	1.19204	0.10	0.9194	0	M_3	0
NUM5	-0.34373	1.20495	-0.78	0.4361	0	M_4	0
NUM6	-1.02433	1.21453	-0.84	0.4018	0	M_5	0
NUM7	-1.71012	1.23519	-1.38	0.1705	0	M_6	0
NUM8	-0.80638	1.38495	-0.58	0.5622	0	M_7	0
NUM9	3.84645	1.59349	2.41	0.0183	0	M_8	0
NUM10	6.38498	1.48124	4.31	<.0001	0	M_9	0
NUM11	8.49282	1.31455	6.46	<.0001	0	M_10	0
NUM12	6.80756	1.26454	5.38	<.0001	0	M_11	0
NUM13	3.77907	1.25035	3.02	0.0035	0	M_12	0
NUM14	-0.08385	3.62911	-0.02	0.9816	0	V1_t	0
NUM15	-0.87100	3.67722	-0.24	0.8134	0	V1_t1	0
NUM16	-5.05178	2.54329	-1.99	0.0508	0	V2_t	0
NUM17	-1.56816	2.50145	-0.63	0.5327	0	V2_t1	0
NUM18	-3.62052	2.54452	-1.42	0.1531	0	V3_t	0
NUM19	0.24089	2.55134	0.09	0.9250	0	V3_t1	0
NUM20	-5.92822	2.13524	-2.77	0.0070	0	V4_t	0
NUM21	-6.68383	2.12780	-3.14	0.0024	0	V4_t1	0
Variance Estimate				11.07413			
Std Error Estimate				3.327781			
AIC				523.6614			
SBC				585.2058			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.44	3	0.4862	-0.043	0.040	-0.077	-0.030	-0.107	-0.047
12	15.05	9	0.0895	-0.151	-0.042	-0.063	0.201	0.216	0.006
18	18.27	15	0.2486	-0.048	-0.032	0.049	-0.033	-0.135	-0.047
24	23.03	21	0.3422	-0.126	0.002	0.147	-0.006	0.006	-0.027
30	26.31	27	0.5015	-0.102	0.086	0.020	-0.067	0.035	-0.018
36	33.62	33	0.4373	-0.022	0.162	-0.122	0.008	-0.086	0.020
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.95765	Pr < W	0.0035	
Kolmogorov-Smirnov	D	0.082019	Pr > D	0.1103	
Cramer-von Mises	W-Sq	0.124071	Pr > W-Sq	0.0529	
Anderson-Darling	A-Sq	0.823867	Pr > A-Sq	0.0338	

Rp1.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
ARI_1	0.70522	0.08511	8.29	<.0001	1	y	0
NUM1	-0.03183	0.0071163	-4.47	<.0001	0	t	0
NUM2	3.26397	0.42618	7.66	<.0001	0	M_1	0
NUM3	3.45822	0.44200	7.82	<.0001	0	M_2	0
NUM4	2.61677	0.45173	5.79	<.0001	0	M_3	0
NUM5	2.65356	0.45839	5.79	<.0001	0	M_4	0
NUM6	2.28215	0.46341	4.92	<.0001	0	M_5	0
NUM7	2.51617	0.46877	5.37	<.0001	0	M_6	0
NUM8	2.20770	0.48577	4.54	<.0001	0	M_7	0
NUM9	2.00978	0.50229	4.00	<.0001	0	M_8	0
NUM10	2.35931	0.49200	4.80	<.0001	0	M_9	0
NUM11	2.39037	0.47617	6.15	<.0001	0	M_10	0
NUM12	3.33737	0.46620	7.16	<.0001	0	M_11	0
NUM13	3.01029	0.45488	6.62	<.0001	0	M_12	0
NUM14	0.24469	0.64328	0.38	0.7048	0	V1_t	0
NUM15	0.46112	0.64650	0.71	0.4779	0	V1_t1	0
NUM16	-0.20036	0.45507	-0.44	0.6610	0	V2_t	0
NUM17	1.64418	0.45234	3.63	0.0005	0	V2_t1	0
NUM18	-0.31867	0.45357	-0.70	0.4845	0	V3_t	0
NUM19	0.38109	0.45238	0.84	0.4023	0	V3_t1	0
NUM20	-0.42346	0.36168	-1.17	0.2454	0	V4_t	0
NUM21	-0.11599	0.36229	-0.32	0.7498	0	V4_t1	0
Variance Estimate				0.413444			
Std Error Estimate				0.642996			
AIC				206.6587			
SBC				263.0744			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.05	5	0.4092	-0.032	0.112	0.001	-0.136	-0.119	-0.056
12	18.41	11	0.0724	0.042	0.151	0.030	0.284	0.044	0.086
18	21.19	17	0.2178	0.073	-0.059	-0.055	-0.074	0.075	0.030
24	26.26	23	0.2888	0.003	0.075	0.021	-0.013	0.138	-0.118
30	28.65	29	0.4831	-0.076	0.040	0.037	-0.060	-0.025	0.066
36	33.71	35	0.5301	-0.087	-0.023	0.042	-0.096	-0.052	-0.107
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.987992	Pr < W	0.5376	
Kolmogorov-Smirnov	D	0.088715	Pr > D	0.0625	
Cramer-von Mises	W-Sq	0.098397	Pr > W-Sq	0.1196	
Anderson-Darling	A-Sq	0.505024	Pr > A-Sq	0.2070	

- **Outflow KPw Kediri**

Total Uang Kertas

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	13.61792	1.18709	11.47	<.0001	0	t	0
NUM2	-300.69421	120.41161	-2.50	0.0147	0	M_1	0
NUM3	3.14424	120.91962	0.03	0.9793	0	M_2	0
NUM4	218.12086	121.43711	1.80	0.0765	0	M_3	0
NUM5	274.58601	121.96396	2.25	0.0273	0	M_4	0
NUM6	385.39318	124.28723	3.10	0.0027	0	M_5	0
NUM7	683.90752	140.45658	4.87	<.0001	0	M_6	0
NUM8	185.53005	158.70633	1.17	0.2461	0	M_7	0
NUM9	-274.89985	145.39475	-1.89	0.0626	0	M_8	0
NUM10	91.50538	130.22895	0.70	0.4844	0	M_9	0
NUM11	219.65838	125.31484	1.75	0.0837	0	M_10	0
NUM12	146.29399	125.90383	1.16	0.2489	0	M_11	0
NUM13	736.27860	126.50121	5.82	<.0001	0	M_12	0
NUM14	2635.9	338.52988	7.79	<.0001	0	V1_t1	0
NUM15	-323.60244	345.15143	-0.94	0.3515	0	V1_t	0
NUM16	1264.6	246.52403	5.13	<.0001	0	V2_t1	0
NUM17	678.12416	238.04470	2.85	0.0057	0	V2_t	0
NUM18	239.08575	244.91905	0.98	0.3321	0	V3_t1	0
NUM19	1842.3	244.75403	7.53	<.0001	0	V3_t	0
NUM20	219.51582	198.06323	1.11	0.2713	0	V4_t1	0
NUM21	2812.8	201.84604	13.94	<.0001	0	V4_t	0
Variance Estimate				95146.97			
Std Error Estimate				308.459			
AIC				1391.203			
SBC				1445.054			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.13	6	0.5273	-0.148	0.127	0.038	-0.001	0.009	0.107
12	12.13	12	0.4357	-0.070	0.063	0.177	-0.036	0.053	0.140
18	18.54	18	0.4205	0.016	-0.055	0.030	-0.035	-0.139	0.034
24	24.39	24	0.4395	-0.007	0.141	0.051	-0.147	-0.049	-0.010
30	30.85	30	0.4230	-0.077	-0.032	-0.186	0.001	-0.073	0.021
36	36.87	36	0.4285	-0.022	-0.030	-0.007	-0.020	-0.098	-0.165
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.963107	Pr < W	0.0084
Kolmogorov-Smirnov	D	0.093801	Pr > D	0.0370
Cramer-von Mises	W-Sq	0.158863	Pr > W-Sq	0.0192
Anderson-Darling	A-Sq	0.937555	Pr > A-Sq	0.0183

Rp100.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	11.44975	0.91601	12.50	<.0001	0	t	0
NUM2	-309.26624	92.91449	-3.33	0.0014	0	M_1	0
NUM3	-109.76136	93.30649	-1.18	0.2432	0	M_2	0
NUM4	44.20286	93.70581	0.47	0.6385	0	M_3	0
NUM5	96.48940	94.11234	1.03	0.3085	0	M_4	0
NUM6	143.42503	95.90507	1.50	0.1390	0	M_5	0
NUM7	332.30490	108.38200	3.07	0.0030	0	M_6	0
NUM8	11.77683	122.46425	0.10	0.9236	0	M_7	0
NUM9	-286.34467	112.14619	-2.55	0.0127	0	M_8	0
NUM10	-1.01755	100.48995	-0.01	0.9919	0	M_9	0
NUM11	37.46349	96.69802	0.39	0.6995	0	M_10	0
NUM12	-7.93030	97.15251	-0.08	0.9352	0	M_11	0
NUM13	354.13436	97.61347	3.63	0.0005	0	M_12	0
NUM14	1615.3	261.22340	6.18	<.0001	0	V1_t1	0
NUM15	-183.93345	266.33285	-0.69	0.4919	0	V1_t	0
NUM16	709.74289	190.22795	3.73	0.0004	0	V2_t1	0
NUM17	439.60198	183.68495	2.39	0.0192	0	V2_t	0
NUM18	83.23609	188.98948	0.44	0.6609	0	V3_t1	0
NUM19	979.51618	188.86215	5.19	<.0001	0	V3_t	0
NUM20	126.98017	152.83363	0.83	0.4087	0	V4_t1	0
NUM21	1673.8	155.75260	10.75	<.0001	0	V4_t	0
				Variance Estimate	56653.28		
				Std Error Estimate	238.0195		
				AIC	1341.429		
				SBC	1395.281		
				Number of Residuals	96		
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.53	6	0.3669	-0.111	0.186	0.087	0.027	0.053	0.084
12	14.48	12	0.2708	-0.069	0.081	0.166	-0.037	0.108	0.144
18	19.00	18	0.4557	0.045	-0.033	0.096	-0.037	-0.142	0.070
24	22.43	24	0.5534	-0.058	0.154	0.076	-0.052	0.000	0.005
30	27.96	30	0.5726	-0.024	-0.010	-0.188	-0.011	-0.065	0.004
36	34.81	36	0.5250	-0.019	-0.021	0.014	-0.013	-0.091	-0.186
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	----p Value-----		
Shapiro-Wilk	W	0.953114	Pr < W	0.0017
Kolmogorov-Smirnov	D	0.085576	Pr > D	0.0829
Cramer-von Mises	W-Sq	0.187955	Pr > W-Sq	0.0076
Anderson-Darling	A-Sq	1.178455	Pr > A-Sq	<0.0050

Rp50.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
ARI_1	-0.30704	0.13212	-2.32	0.0229	17	y	0
ARI_2	-0.39200	0.13838	-2.76	0.0073	22	y	0
NUM1	1.76046	0.28090	6.27	<.0001	0	t	0
NUM2	14.10815	37.19918	0.38	0.7056	0	M_1	0
NUM3	122.06213	37.07775	3.29	0.0015	0	M_2	0
NUM4	176.62308	37.49739	4.71	<.0001	0	M_3	0
NUM5	159.33304	38.00436	4.19	<.0001	0	M_4	0
NUM6	228.35138	38.94321	5.86	<.0001	0	M_5	0
NUM7	309.53795	43.33515	7.14	<.0001	0	M_6	0
NUM8	187.34133	48.21187	3.89	0.0002	0	M_7	0
NUM9	46.96609	46.51601	1.01	0.3160	0	M_8	0
NUM10	87.77780	40.56452	2.16	0.0337	0	M_9	0
NUM11	189.26229	39.19561	4.83	<.0001	0	M_10	0
NUM12	170.70061	39.11604	4.36	<.0001	0	M_11	0
NUM13	391.94208	35.07845	10.03	<.0001	0	M_12	0
NUM14	686.47736	104.82653	6.55	<.0001	0	U1_t1	0
NUM15	-61.33928	104.32430	-0.59	0.5584	0	V1_t	0
NUM16	341.77709	73.60419	4.64	<.0001	0	U2_t1	0
NUM17	218.89765	71.46431	3.06	0.0031	0	U2_t	0
NUM18	74.47049	73.63256	1.01	0.3156	0	U3_t1	0
NUM19	708.30100	70.36458	9.38	<.0001	0	U3_t	0
NUM20	53.59627	60.68100	0.88	0.3800	0	U4_t1	0
NUM21	862.12204	63.79497	13.51	<.0001	0	U4_t	0
Variance Estimate				9196.314			
Std Error Estimate				95.89742			
AIC				1168.232			
SBC				1227.272			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	16.27	4	0.0027	0.177	0.202	0.189	0.124	-0.075	0.177
12	26.01	10	0.0037	0.138	0.104	0.198	0.106	0.074	0.067
18	28.52	16	0.0273	-0.043	-0.028	0.003	-0.088	-0.104	-0.011
24	31.52	22	0.0859	-0.002	0.029	0.004	-0.035	-0.065	-0.130
30	44.42	28	0.0252	-0.131	-0.127	-0.201	-0.103	-0.082	-0.060
36	74.05	34	<.0001	-0.155	-0.073	-0.170	-0.190	-0.262	-0.179
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.975592	Pr < W	0.0700	
Kolmogorov-Smirnov	D	0.064612	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.086275	Pr > W-Sq	0.1752	
Anderson-Darling	A-Sq	0.576861	Pr > A-Sq	0.1354	

Rp20.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.07263	0.03990	1.82	0.0727	0	t	0
NUM2	2.98597	4.04745	0.74	0.4630	0	M_1	0
NUM3	4.56636	4.06453	1.12	0.2648	0	M_2	0
NUM4	7.67057	4.08192	1.88	0.0641	0	M_3	0
NUM5	9.94765	4.09963	2.43	0.0176	0	M_4	0
NUM6	10.74980	4.17773	2.57	0.0121	0	M_5	0
NUM7	21.61873	4.72123	4.58	<.0001	0	M_6	0
NUM8	1.19532	5.33467	0.22	0.8233	0	M_7	0
NUM9	-7.58622	4.89521	-1.55	0.1247	0	M_8	0
NUM10	-2.18166	4.37745	-0.50	0.6197	0	M_9	0
NUM11	2.66232	4.21227	0.63	0.5293	0	M_10	0
NUM12	2.39915	4.23207	0.57	0.5725	0	M_11	0
NUM13	5.23784	4.25215	1.23	0.2219	0	M_12	0
NUM14	115.94766	11.37317	10.19	<.0001	0	V1_t1	0
NUM15	-6.13428	11.60174	-0.53	0.5985	0	V1_t	0
NUM16	52.21535	8.28653	6.30	<.0001	0	V2_t1	0
NUM17	13.03255	8.00151	1.63	0.1076	0	V2_t	0
NUM18	45.52649	8.23258	5.53	<.0001	0	V3_t1	0
NUM19	44.10010	8.22703	5.36	<.0001	0	V3_t	0
NUM20	14.28617	6.65759	2.15	0.0351	0	V4_t1	0
NUM21	105.11303	6.78475	15.49	<.0001	0	V4_t	0
Variance Estimate				107.5033			
Std Error Estimate				10.36838			
AIC				739.7797			
SBC				793.631			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.06	6	0.0865	0.143	0.047	-0.193	-0.206	-0.082	0.014
12	12.73	12	0.3892	0.006	-0.022	-0.063	-0.046	0.033	0.086
18	16.49	18	0.5582	0.057	0.010	-0.077	-0.082	-0.115	0.053
24	21.52	24	0.6080	0.069	0.108	0.120	0.082	-0.045	-0.027
30	22.44	30	0.8374	-0.004	-0.022	-0.051	-0.000	-0.043	-0.041
36	47.16	36	0.1009	-0.003	0.100	0.043	-0.025	-0.282	-0.260
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.810609	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.199616	Pr > D	<0.0100
Cramer-von Mises	W-Sq	1.057944	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	5.717314	Pr > A-Sq	<0.0050

Rp10.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.41586	0.09575	4.34	<.0001	1	y	0
AR1_2	0.46029	0.09999	4.60	<.0001	11	y	0
NUM1	-0.0068799	0.05173	-0.13	0.8946	0	t	0
NUM2	2.57816	3.44497	0.75	0.4566	0	M_1	0
NUM3	3.16217	3.49513	0.90	0.3686	0	M_2	0
NUM4	5.85635	3.55232	1.65	0.1035	0	M_3	0
NUM5	9.85693	3.53993	2.46	0.0162	0	M_4	0
NUM6	12.47813	3.65617	3.41	0.0011	0	M_5	0
NUM7	18.54482	3.77113	4.92	<.0001	0	M_6	0
NUM8	5.53896	3.94452	1.40	0.1645	0	M_7	0
NUM9	5.70085	3.96973	1.44	0.1553	0	M_8	0
NUM10	5.94656	3.84860	1.55	0.1266	0	M_9	0
NUM11	4.50549	3.72662	1.21	0.2306	0	M_10	0
NUM12	3.46327	3.64653	0.95	0.3454	0	M_11	0
NUM13	3.57918	3.61437	0.99	0.3253	0	M_12	0
NUM14	67.64319	5.01604	13.49	<.0001	0	V1_t1	0
NUM15	-7.60978	4.83865	-1.57	0.1201	0	V1_t	0
NUM16	47.84749	3.70650	12.91	<.0001	0	V2_t1	0
NUM17	8.12994	3.45230	2.35	0.0212	0	V2_t	0
NUM18	39.10607	3.49068	11.20	<.0001	0	V3_t1	0
NUM19	40.60259	3.47497	11.68	<.0001	0	V3_t	0
NUM20	17.71637	2.93013	6.05	<.0001	0	V4_t1	0
NUM21	79.09298	3.14699	25.13	<.0001	0	V4_t	0
Variance Estimate				23.72455			
Std Error Estimate				4.870785			
AIC				596.1279			
SBC				655.1079			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.05	4	0.0897	0.121	-0.058	-0.162	-0.151	-0.112	0.013
12	10.54	10	0.3948	-0.033	-0.045	-0.013	-0.032	0.101	0.089
18	11.63	16	0.7689	-0.075	0.034	-0.021	0.034	-0.011	0.034
24	16.60	22	0.7851	0.010	-0.025	0.011	-0.002	0.002	-0.193
30	18.52	28	0.9124	0.073	0.089	0.015	0.025	0.000	-0.012
36	27.81	34	0.7640	0.012	0.063	0.025	-0.071	-0.107	-0.197
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.926411	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.136562	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.43678	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	2.466623	Pr > A-Sq	<0.0050	

Rp5.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	-0.0012630	0.01228	-0.10	0.9184	0	t	0
NUM2	1.63926	1.24585	1.36	0.1767	0	M_1	0
NUM3	1.75688	1.25110	1.40	0.1644	0	M_2	0
NUM4	3.07031	1.25646	2.44	0.0169	0	M_3	0
NUM5	4.99572	1.26131	3.96	0.0002	0	M_4	0
NUM6	7.60659	1.28595	5.92	<.0001	0	M_5	0
NUM7	9.18627	1.45324	6.32	<.0001	0	M_6	0
NUM8	3.36433	1.64206	2.05	0.0440	0	M_7	0
NUM9	2.21467	1.50371	1.47	0.1450	0	M_8	0
NUM10	1.22154	1.34742	0.91	0.3675	0	M_9	0
NUM11	0.86713	1.29658	0.67	0.5057	0	M_10	0
NUM12	1.41244	1.30267	1.08	0.2817	0	M_11	0
NUM13	2.02864	1.30885	1.55	0.1254	0	M_12	0
NUM14	89.70330	3.50262	25.61	<.0001	0	V1_t	0
NUM15	-2.43459	3.57113	-0.70	0.4870	0	V1_t	0
NUM16	54.89754	2.55068	21.52	<.0001	0	V2_t	0
NUM17	4.92065	2.46294	2.00	0.0494	0	V2_t	0
NUM18	24.96273	2.53407	9.85	<.0001	0	V3_t	0
NUM19	37.22846	2.53236	14.70	<.0001	0	V3_t	0
NUM20	14.95645	2.04927	7.30	<.0001	0	V4_t	0
NUM21	56.91339	2.08841	27.25	<.0001	0	V4_t	0
				Variance Estimate	10.1856		
				Std Error Estimate	3.191489		
				AIC	513.5513		
				SBC	567.4026		
				Number of Residuals	96		
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.12	6	0.3100	0.156	-0.043	-0.162	-0.120	-0.056	-0.026
12	9.78	12	0.6349	-0.040	-0.055	-0.012	0.092	0.048	-0.093
18	12.42	18	0.8248	-0.102	-0.103	-0.035	-0.017	0.007	0.023
24	17.00	24	0.8487	0.034	-0.014	-0.004	-0.073	-0.058	-0.159
30	20.11	30	0.9137	0.092	0.108	0.050	0.002	-0.020	-0.005
36	26.61	36	0.8730	0.074	0.118	-0.106	-0.055	0.063	0.077
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.790267	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.230651	Pr > D	<0.0100
Cramer-von Mises	W-Sq	1.066085	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	5.85468	Pr > A-Sq	<0.0050

Rp2.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.0030074	0.0060231	0.50	0.6190	0	t	0
NUM2	0.41938	0.61095	0.69	0.4946	0	M_1	0
NUM3	0.45159	0.61353	0.74	0.4640	0	M_2	0
NUM4	0.64257	0.61616	1.04	0.3004	0	M_3	0
NUM5	1.18072	0.61883	1.91	0.0602	0	M_4	0
NUM6	2.32041	0.63062	3.68	0.0004	0	M_5	0
NUM7	2.77354	0.71266	3.89	0.0002	0	M_6	0
NUM8	0.76304	0.80525	0.95	0.3464	0	M_7	0
NUM9	0.51647	0.73741	0.70	0.4859	0	M_8	0
NUM10	0.35521	0.66076	0.54	0.5925	0	M_9	0
NUM11	0.10685	0.63583	0.17	0.8670	0	M_10	0
NUM12	0.17647	0.63882	0.28	0.7831	0	M_11	0
NUM13	0.44909	0.64185	0.70	0.4863	0	M_12	0
NUM14	26.32442	1.71765	15.33	<.0001	0	V1_t	0
NUM15	-0.74246	1.75125	-0.42	0.6728	0	V1_t	0
NUM16	27.30742	1.25083	21.83	<.0001	0	V2_t	0
NUM17	2.25554	1.20781	1.87	0.0657	0	V2_t	0
NUM18	9.02496	1.24269	7.26	<.0001	0	V3_t	0
NUM19	12.26595	1.24185	9.88	<.0001	0	V3_t	0
NUM20	5.02196	1.00495	5.00	<.0001	0	V4_t	0
NUM21	27.20128	1.02414	26.56	<.0001	0	V4_t	0
Variance Estimate				2.449473			
Std Error Estimate				1.565079			
AIC				376.7414			
SBC				430.5928			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.81	6	0.9918	-0.045	0.022	-0.063	-0.032	-0.023	-0.000
12	8.17	12	0.7715	0.004	-0.014	-0.028	0.001	0.017	-0.254
18	9.31	18	0.9520	0.081	-0.019	-0.036	-0.029	0.023	-0.020
24	18.73	24	0.7662	0.029	-0.027	0.000	-0.163	0.200	-0.071
30	19.18	30	0.9361	-0.030	0.007	0.003	-0.006	-0.048	0.005
36	28.44	36	0.8111	-0.010	-0.027	-0.102	0.098	-0.170	0.104
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.653277	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.287106	Pr > D	<0.0100
Cramer-von Mises	W-Sq	2.401923	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	12.04223	Pr > A-Sq	<0.0050

Rp1.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	-0.79348	0.10071	-7.88	<.0001	12	y	0
NUM1	-0.0089939	0.0028882	-3.11	0.0026	0	t	0
NUM2	0.57271	0.34341	1.67	0.0996	0	M_1	0
NUM3	0.50823	0.34450	1.47	0.1459	0	M_2	0
NUM4	0.52636	0.34556	1.52	0.1320	0	M_3	0
NUM5	0.67631	0.34569	1.96	0.0542	0	M_4	0
NUM6	0.67664	0.34823	1.94	0.0558	0	M_5	0
NUM7	0.20485	0.38051	0.54	0.5919	0	M_6	0
NUM8	0.20607	0.39432	0.52	0.6028	0	M_7	0
NUM9	1.79353	0.40394	4.17	<.0001	0	M_8	0
NUM10	0.90134	0.38521	2.34	0.0220	0	M_9	0
NUM11	0.47769	0.35237	1.36	0.1793	0	M_10	0
NUM12	0.51035	0.35385	1.44	0.1534	0	M_11	0
NUM13	0.55877	0.35528	1.57	0.1200	0	M_12	0
NUM14	1.99254	0.65510	3.04	0.0033	0	V1_t1	0
NUM15	0.35338	0.56629	0.62	0.5345	0	V1_t	0
NUM16	0.19839	0.48757	0.40	0.6883	0	V2_t1	0
NUM17	0.34099	0.33938	1.00	0.3183	0	V2_t	0
NUM18	-0.0028708	0.50686	-0.01	0.9955	0	V3_t1	0
NUM19	1.54876	0.51627	3.00	0.0037	0	V3_t	0
NUM20	0.83690	0.36039	2.32	0.0230	0	V4_t1	0
NUM21	4.05276	0.50365	8.05	<.0001	0	V4_t	0
Variance Estimate				0.346373			
Std Error Estimate				0.588534			
AIC				189.666			
SBC				246.0817			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.17	5	0.2899	-0.052	-0.003	-0.089	-0.132	-0.132	-0.120
12	10.34	11	0.4999	-0.040	-0.034	-0.011	0.066	0.117	0.129
18	11.68	17	0.8193	-0.059	0.070	0.007	-0.002	0.002	-0.056
24	21.75	23	0.5356	-0.091	-0.102	-0.053	0.048	0.233	-0.032
30	23.69	29	0.7442	0.025	-0.043	-0.056	-0.067	-0.058	-0.026
36	41.72	35	0.2019	0.018	0.070	0.107	0.236	-0.127	-0.172
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.872832	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.134505	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.389156	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.512919	Pr > A-Sq	<0.0050

- Inflow KPw Malang**

Total Uang Kertas

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.33184	0.11217	2.96	0.0042	1	y	0
AR1_2	0.38051	0.11372	3.35	0.0013	2	y	0
NUM1	10.00686	2.16442	4.62	<.0001	0	t	0
NUM2	1044.0	129.90450	8.04	<.0001	0	M_1	0
NUM3	585.64867	131.86539	4.44	<.0001	0	M_2	0
NUM4	480.19777	134.89357	3.56	0.0007	0	M_3	0
NUM5	417.53171	136.47187	3.06	0.0031	0	M_4	0
NUM6	446.84995	137.92356	3.24	0.0018	0	M_5	0
NUM7	277.49718	139.57575	1.99	0.0505	0	M_6	0
NUM8	467.30212	145.10184	3.22	0.0019	0	M_7	0
NUM9	500.38667	150.77649	3.32	0.0014	0	M_8	0
NUM10	189.87876	146.40097	1.30	0.1987	0	M_9	0
NUM11	383.79516	141.72428	2.71	0.0084	0	M_10	0
NUM12	393.51990	138.32273	2.84	0.0058	0	M_11	0
NUM13	202.47413	138.02158	1.47	0.1467	0	M_12	0
NUM14	1412.0	201.11887	7.02	<.0001	0	V1_t	0
NUM15	57.94011	201.54307	0.29	0.7746	0	V1_t-1	0
NUM16	955.61838	141.90582	6.73	<.0001	0	V2_t	0
NUM17	212.37673	139.47982	1.52	0.1322	0	V2_t-1	0
NUM18	472.12681	141.27257	3.34	0.0013	0	V3_t	0
NUM19	304.96830	140.99079	2.16	0.0338	0	V3_t-1	0
NUM20	-590.62371	112.41173	-5.25	<.0001	0	V4_t	0
NUM21	1613.3	112.79320	14.30	<.0001	0	V4_t-1	0
Variance Estimate				40882.38			
Std Error Estimate				202.1939			
AIC				1311.514			
SBC				1370.495			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.12	4	0.5379	-0.049	-0.102	0.016	0.070	0.028	-0.109
12	17.42	10	0.0656	0.077	0.191	0.121	-0.025	0.124	0.239
18	23.68	16	0.0987	-0.143	-0.081	-0.029	0.100	0.123	0.032
24	25.43	22	0.2770	0.003	0.109	-0.017	0.011	0.035	-0.025
30	32.49	28	0.2551	-0.055	-0.038	0.026	-0.107	-0.073	0.168
36	46.48	34	0.0751	-0.072	-0.053	-0.033	0.096	0.020	-0.267
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--	----p Value----			
Shapiro-Wilk	W	0.989683	Pr < W	0.6665	
Kolmogorov-Smirnov	D	0.057768	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.064535	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq	0.375695	Pr > A-Sq	>0.2500	

Rp100.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
ARI_1	0.24230	0.11189	2.17	0.0332	1	y	0
ARI_2	0.20473	0.12028	2.37	0.0206	2	y	0
ARI_3	0.25316	0.11618	2.18	0.0326	4	y	0
NUM1	6.97780	1.45514	4.80	<.0001	0	t	0
NUM2	540.00294	84.83657	6.37	<.0001	0	M_1	0
NUM3	249.89104	85.91228	2.91	0.0048	0	M_2	0
NUM4	153.70147	87.21155	1.76	0.0822	0	M_3	0
NUM5	111.27091	87.73171	1.27	0.2088	0	M_4	0
NUM6	143.14488	88.88397	1.61	0.1117	0	M_5	0
NUM7	30.70532	89.94680	0.34	0.7338	0	M_6	0
NUM8	132.14567	93.75278	1.41	0.1630	0	M_7	0
NUM9	128.91156	97.39600	1.32	0.1895	0	M_8	0
NUM10	-85.32548	93.78317	-0.91	0.3659	0	M_9	0
NUM11	85.85947	91.30110	0.94	0.3502	0	M_10	0
NUM12	97.22136	90.08160	1.08	0.2841	0	M_11	0
NUM13	-3.20230	90.04592	-0.04	0.9717	0	M_12	0
NUM14	975.00027	126.21678	7.72	<.0001	0	V1_t	0
NUM15	-69.14362	127.45378	-0.54	0.5891	0	V1_t-1	0
NUM16	687.40022	90.04303	7.63	<.0001	0	V2_t	0
NUM17	95.05729	88.08268	1.08	0.2841	0	V2_t-1	0
NUM18	401.05276	89.53168	4.48	<.0001	0	V3_t	0
NUM19	165.37966	89.44347	1.85	0.0686	0	V3_t-1	0
NUM20	-236.39167	71.70510	-4.13	<.0001	0	V4_t	0
NUM21	1048.3	72.33427	14.49	<.0001	0	V4_t-1	0
Variance Estimate				15590.44			
Std Error Estimate				124.8617			
AIC				1219.642			
SBC				1281.187			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.68	3	0.2987	-0.053	-0.014	0.011	-0.066	-0.001	-0.167
12	13.94	9	0.1246	0.087	0.074	0.159	-0.005	0.075	0.221
18	19.73	15	0.2262	-0.105	-0.080	-0.087	0.094	0.084	0.021
24	22.42	21	0.3759	0.088	-0.112	0.052	0.033	0.001	-0.073
30	32.18	27	0.2254	-0.034	-0.129	0.009	-0.049	-0.064	0.213
36	41.39	33	0.1498	-0.028	0.043	-0.000	0.004	-0.013	-0.237

Model for variable y
No mean term in this model.

Tests for Normality				
Test	--Statistic--	----p Value----		
Shapiro-Wilk	W	0.993783	Pr < W	0.9396
Kolmogorov-Smirnov	D	0.046049	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.028486	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.207382	Pr > A-Sq	>0.2500

Rp50.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	2.76194	0.39492	6.99	<.0001	0	t	0
NUM2	482.05327	40.05810	12.03	<.0001	0	M_1	0
NUM3	313.28376	40.22710	7.79	<.0001	0	M_2	0
NUM4	297.25389	40.39926	7.36	<.0001	0	M_3	0
NUM5	293.89894	40.57459	7.00	<.0001	0	M_4	0
NUM6	281.69618	40.75287	6.91	<.0001	0	M_5	0
NUM7	225.04663	41.52133	5.42	<.0001	0	M_6	0
NUM8	290.70270	46.86236	6.20	<.0001	0	M_7	0
NUM9	295.61777	52.93182	5.58	<.0001	0	M_8	0
NUM10	191.61090	48.53070	3.95	0.0002	0	M_9	0
NUM11	254.82951	49.52195	5.06	<.0001	0	M_10	0
NUM12	263.88907	41.88523	6.30	<.0001	0	M_11	0
NUM13	189.34021	42.08397	4.50	<.0001	0	M_12	0
NUM14	340.05791	112.62089	3.02	0.0035	0	V1_t	0
NUM15	-77.30571	114.82373	-0.67	0.5029	0	V1_t1	0
NUM16	334.53350	82.01272	4.08	0.0001	0	V2_t	0
NUM17	76.56871	79.19185	0.97	0.3367	0	V2_t1	0
NUM18	160.41621	81.47178	1.97	0.0527	0	V3_t	0
NUM19	158.64017	81.42388	1.95	0.0551	0	V3_t1	0
NUM20	-225.16273	65.89096	-3.42	0.0010	0	V4_t	0
NUM21	615.61374	67.14941	9.17	<.0001	0	V4_t1	0
				Variance Estimate	10530.25		
				Std. Error Estimate	102.617		
				AIC	1179.89		
				SBC	1233.742		
				Number of Residuals	96		
* AIC and SBC do not include log determinant.							

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1_1	-0.63135	0.09788	-6.45	<.0001	1
AR1_2	-0.25206	0.09776	-2.58	0.0115	2
AR1_3	0.22390	0.09285	2.41	0.0179	12

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.22	3	0.0417	-0.018	-0.130	-0.193	-0.059	-0.018	-0.152
12	15.26	9	0.0841	-0.063	0.134	0.122	0.087	0.132	-0.059
18	20.04	15	0.1796	-0.151	-0.030	-0.068	0.086	0.072	-0.031
24	21.36	21	0.4379	-0.004	0.052	0.046	0.044	-0.005	-0.050
30	30.30	27	0.3007	0.009	-0.007	0.045	-0.146	-0.072	0.188
36	39.26	33	0.2095	0.001	-0.032	-0.084	0.147	0.108	-0.132
Model for variable y									
Period(s) of Differencing 1									

Tests for Normality				
Test	--Statistic--		----p Value-----	
Shapiro-Wilk	W	0.98749	Pr < W	0.5092
Kolmogorov-Smirnov	D	0.051973	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.038727	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.308276	Pr > A-Sq	>0.2500

Rp20.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.03709	0.02712	1.37	0.1754	0	t	0
NUM2	14.59655	2.75041	5.31	<.0001	0	M_1	0
NUM3	12.63044	2.76201	4.57	<.0001	0	M_2	0
NUM4	12.51945	2.77383	4.51	<.0001	0	M_3	0
NUM5	9.03377	2.78587	3.24	0.0018	0	M_4	0
NUM6	9.29794	2.79811	3.32	0.0014	0	M_5	0
NUM7	7.31079	2.85087	2.56	0.0123	0	M_6	0
NUM8	12.12737	3.21759	3.77	0.0003	0	M_7	0
NUM9	22.25425	3.63432	6.12	<.0001	0	M_8	0
NUM10	19.35986	3.33214	5.81	<.0001	0	M_9	0
NUM11	16.30444	2.98824	5.46	<.0001	0	M_10	0
NUM12	16.55442	2.87586	5.76	<.0001	0	M_11	0
NUM13	10.90022	2.88950	3.77	0.0003	0	M_12	0
NUM14	24.70546	7.73260	3.19	0.0020	0	V1_t	0
NUM15	22.17319	7.88385	2.81	0.0063	0	V1_t1	0
NUM16	-6.16948	5.63103	-1.10	0.2768	0	V2_t	0
NUM17	2.32615	5.43735	0.43	0.6700	0	V2_t1	0
NUM18	-11.47419	5.59437	-2.05	0.0438	0	V3_t	0
NUM19	17.33377	5.59060	3.10	0.0027	0	V3_t1	0
NUM20	-11.93710	4.52410	-2.64	0.0101	0	V4_t	0
NUM21	23.04958	4.61051	5.00	<.0001	0	V4_t1	0
Variance Estimate				49.64235			
Std Error Estimate				7.045732			
AIC				665.6027			
SBC				719.454			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.49	6	0.1479	0.278	0.125	0.001	-0.010	-0.047	0.013
12	14.98	12	0.2426	-0.043	0.074	0.031	-0.099	0.095	0.150
18	16.32	18	0.5703	-0.025	0.008	0.015	-0.058	-0.040	-0.073
24	27.74	24	0.2711	-0.045	-0.025	-0.072	-0.051	0.277	0.044
30	29.48	30	0.4924	0.032	-0.011	-0.048	-0.041	-0.018	-0.083
36	37.63	36	0.3947	0.028	-0.068	-0.053	0.001	0.121	-0.173
Model for variable y									
No mean term in this model.									

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.49	6	0.1479	0.278	0.125	0.001	-0.010	-0.047	0.013
12	14.98	12	0.2426	-0.043	0.074	0.031	-0.099	0.095	0.150
18	16.32	18	0.5703	-0.025	0.008	0.015	-0.058	-0.040	-0.073
24	27.74	24	0.2711	-0.045	-0.025	-0.072	-0.051	0.277	0.044
30	29.48	30	0.4924	0.032	-0.011	-0.048	-0.041	-0.018	-0.083
36	37.63	36	0.3947	0.028	-0.068	-0.053	0.001	0.121	-0.173
Model for variable y									
No mean term in this model.									

Rp10.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.05242	0.02590	2.02	0.0465	0	t	0
NUM2	10.84958	2.52716	4.13	<.0001	0	M_1	0
NUM3	10.58363	2.63824	4.01	0.0001	0	M_2	0
NUM4	10.27035	2.64954	3.88	0.0002	0	M_3	0
NUM5	6.83013	2.66103	2.57	0.0123	0	M_4	0
NUM6	6.18322	2.67273	2.31	0.0234	0	M_5	0
NUM7	4.78123	2.72313	1.76	0.0832	0	M_6	0
NUM8	9.04355	3.07341	2.94	0.0043	0	M_7	0
NUM9	19.83352	3.47147	5.71	<.0001	0	M_8	0
NUM10	19.02426	3.18283	5.98	<.0001	0	M_9	0
NUM11	15.99746	2.85433	5.60	<.0001	0	M_10	0
NUM12	15.39087	2.74699	5.60	<.0001	0	M_11	0
NUM13	9.05168	2.76002	3.28	0.0016	0	M_12	0
NUM14	9.37278	7.38610	1.27	0.2084	0	V1_t	0
NUM15	27.55985	7.53057	3.66	0.0005	0	V1_t1	0
NUM16	-11.68205	5.37870	-2.17	0.0330	0	V2_t	0
NUM17	-0.70837	5.19370	-0.14	0.8919	0	V2_t1	0
NUM18	-11.46838	5.34368	-2.15	0.0351	0	V3_t	0
NUM19	14.09688	5.34008	2.64	0.0101	0	V3_t1	0
NUM20	-11.03321	4.32138	-2.55	0.0127	0	V4_t	0
NUM21	12.61899	4.40391	2.87	0.0054	0	V4_t1	0
Variance Estimate				45.29304			
Std Error Estimate				6.730011			
AIC				656.8004			
SBC				710.6517			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.63	6	0.5916	0.146	0.013	-0.079	-0.099	-0.091	-0.007
12	9.24	12	0.6827	-0.058	-0.041	-0.102	-0.047	0.096	0.123
18	12.53	18	0.8189	-0.065	-0.100	-0.007	-0.072	-0.050	-0.079
24	22.47	24	0.5511	-0.063	-0.074	-0.059	-0.058	0.245	-0.034
30	24.79	30	0.7353	0.064	-0.053	-0.072	-0.041	0.044	-0.036
36	32.86	36	0.6186	-0.011	0.001	-0.002	-0.010	0.198	-0.113

Model for variable y
No mean term in this model.

Tests for Normality					
Test	--Statistic--		----p Value-----		
Shapiro-Wilk	W	0.867375	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.133493	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.515275	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	3.073058	Pr > A-Sq	<0.0050	

Rp5.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.03738	0.02387	1.57	0.1215	0	t	0
NUM2	9.63780	2.42118	3.98	0.0002	0	M_1	0
NUM3	8.73315	2.43140	3.59	0.0006	0	M_2	0
NUM4	8.02119	2.44180	3.28	0.0016	0	M_3	0
NUM5	5.97067	2.45240	2.43	0.0173	0	M_4	0
NUM6	4.79994	2.46318	1.95	0.0551	0	M_5	0
NUM7	4.39372	2.50962	1.75	0.0841	0	M_6	0
NUM8	7.49504	2.83245	2.65	0.0099	0	M_7	0
NUM9	16.27757	3.19329	5.09	<.0001	0	M_8	0
NUM10	26.36226	2.93328	8.99	<.0001	0	M_9	0
NUM11	17.31333	2.63054	6.58	<.0001	0	M_10	0
NUM12	10.62749	2.53162	4.20	<.0001	0	M_11	0
NUM13	9.06558	2.54363	3.56	0.0006	0	M_12	0
NUM14	-1.33652	6.80701	-0.20	0.8449	0	V1_t	0
NUM15	27.75921	6.94015	4.00	0.0001	0	V1_t1	0
NUM16	-16.61956	4.95700	-3.35	0.0013	0	V2_t	0
NUM17	-6.37068	4.78650	-1.46	0.1495	0	V2_t1	0
NUM18	-11.06332	4.92472	-2.25	0.0276	0	V3_t	0
NUM19	-5.29425	4.92141	-1.08	0.2855	0	V3_t1	0
NUM20	-9.44287	3.98257	-2.37	0.0203	0	V4_t	0
NUM21	-2.44499	4.05863	-0.60	0.5487	0	V4_t1	0
Variance Estimate				38.46923			
Std Error Estimate				6.202357			
AIC				641.1241			
SBC				694.9754			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.95	6	0.6290	0.072	0.041	-0.119	-0.105	-0.103	0.021
12	8.13	12	0.7746	-0.007	-0.036	-0.040	-0.085	0.111	0.107
18	9.88	18	0.9356	-0.072	-0.085	0.015	-0.033	-0.013	-0.038
24	24.37	24	0.4407	-0.085	-0.089	-0.035	0.014	0.296	-0.096
30	29.48	30	0.4926	0.023	-0.114	-0.094	-0.071	0.018	-0.097
36	36.72	36	0.4352	-0.037	-0.037	0.077	0.017	0.153	-0.121
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.877295	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.14831	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.532748	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	3.296361	Pr > A-Sq	<0.0050	

Rp2.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.25696	0.11691	2.20	0.0311	1	y	0
NUM1	0.05195	0.01023	5.08	<.0001	0	t	0
NUM2	3.80089	0.86290	4.40	<.0001	0	M_1	0
NUM3	2.49223	0.86811	2.87	0.0053	0	M_2	0
NUM4	1.94226	0.87257	2.23	0.0291	0	M_3	0
NUM5	0.99456	0.87777	1.13	0.2608	0	M_4	0
NUM6	0.25427	0.88325	0.29	0.7742	0	M_5	0
NUM7	-0.31198	0.89843	-0.35	0.7294	0	M_6	0
NUM8	0.51564	0.99449	0.52	0.6057	0	M_7	0
NUM9	1.68371	1.10350	1.53	0.1313	0	M_8	0
NUM10	4.05100	1.03622	3.91	0.0002	0	M_9	0
NUM11	4.67649	0.94601	4.94	<.0001	0	M_10	0
NUM12	3.47685	0.91567	3.80	0.0003	0	M_11	0
NUM13	2.44433	0.91291	2.68	0.0091	0	M_12	0
NUM14	-0.52954	2.23123	-0.24	0.8131	0	V1_t	0
NUM15	5.92176	2.24183	2.64	0.0101	0	V1_t1	0
NUM16	-2.73949	1.60274	-1.75	0.0848	0	V2_t	0
NUM17	-2.03292	1.55592	-1.35	0.1827	0	V2_t1	0
NUM18	-2.70272	1.58490	-1.71	0.0923	0	V3_t	0
NUM19	-0.18379	1.58053	-0.12	0.9077	0	V3_t1	0
NUM20	-2.67095	1.27604	-2.09	0.0398	0	V4_t	0
NUM21	-0.12945	1.28776	-0.10	0.9202	0	V4_t1	0
Variance Estimate				4.099725			
Std Error Estimate				2.024778			
AIC				426.8973			
SBC				483.313			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.47	5	0.6273	0.022	-0.081	-0.004	-0.013	-0.105	0.124
12	12.64	11	0.3178	0.149	0.091	0.068	-0.109	-0.080	-0.175
18	16.23	17	0.5079	0.054	-0.005	-0.039	-0.039	-0.068	-0.106
24	20.02	23	0.6408	-0.140	-0.073	0.025	0.027	-0.007	-0.065
30	22.77	29	0.7871	-0.114	-0.008	-0.057	0.016	0.050	-0.009
36	35.38	35	0.4503	0.139	0.067	-0.052	0.076	0.213	-0.073
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.967764	Pr < W	0.0182
Kolmogorov-Smirnov	D	0.085376	Pr > D	0.0842
Cramer-von Mises	W-Sq	0.120798	Pr > W-Sq	0.0604
Anderson-Darling	A-Sq	0.750625	Pr > A-Sq	0.0490

Rp1.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
aR1_1	0.63961	0.09126	7.01	<.0001	1	y	0
NUM1	-0.02060	0.0038530	-5.35	<.0001	0	t	0
NUM2	2.07572	0.24336	8.53	<.0001	0	M_1	0
NUM3	1.84867	0.25082	7.37	<.0001	0	M_2	0
NUM4	1.81153	0.25509	7.10	<.0001	0	M_3	0
NUM5	1.73447	0.25812	6.72	<.0001	0	M_4	0
NUM6	1.54970	0.26063	5.95	<.0001	0	M_5	0
NUM7	1.51432	0.26400	5.74	<.0001	0	M_6	0
NUM8	1.47013	0.27693	5.33	<.0001	0	M_7	0
NUM9	1.34393	0.28863	4.66	<.0001	0	M_8	0
NUM10	1.70791	0.28215	6.05	<.0001	0	M_9	0
NUM11	2.05451	0.27144	7.57	<.0001	0	M_10	0
NUM12	2.01229	0.26571	7.57	<.0001	0	M_11	0
NUM13	2.11339	0.26017	8.12	<.0001	0	M_12	0
NUM14	0.11211	0.41569	0.27	0.7881	0	VT_t	0
NUM15	0.31091	0.41794	0.74	0.4593	0	V1_t	0
NUM16	-0.06220	0.29440	-0.21	0.8332	0	V2_t	0
NUM17	0.76729	0.29211	2.63	0.0105	0	V2_t	0
NUM18	-0.07873	0.23939	-0.27	0.7894	0	V3_t	0
NUM19	0.01255	0.23310	0.04	0.9660	0	V3_t	0
NUM20	-0.25373	0.23427	-1.08	0.2823	0	V4_t	0
NUM21	0.15377	0.23477	0.66	0.5145	0	V4_t	0
				Variance Estimate	0.165449		
				Std Error Estimate	0.406754		
				AIC	118.7359		
				SBC	175.1516		
				Number of Residuals	96		
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.68	5	0.3386	0.086	-0.120	-0.136	0.122	-0.020	0.027
12	17.41	11	0.0963	0.055	0.145	0.121	-0.062	0.097	0.234
18	19.17	17	0.3190	0.025	-0.085	-0.056	0.044	0.028	0.037
24	22.89	23	0.4672	0.035	0.029	0.108	-0.095	-0.040	-0.071
30	27.54	29	0.5427	0.098	-0.000	-0.003	-0.142	0.039	-0.050
36	39.19	35	0.2874	-0.038	-0.074	0.058	-0.103	-0.087	-0.217
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.930536	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.109552	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.31739	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	1.886112	Pr > A-Sq	<0.0050	

- **Outflow KPw Malang**

Total Uang Kertas

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	-0.38822	0.11622	-2.91	0.0048	1	y	0
AR1_2	-0.26651	0.11881	-2.24	0.0279	2	y	0
NUM1	8.08352	0.48605	16.63	<.0001	0	t	0
NUM2	-190.46619	75.12398	-2.54	0.0134	0	M_1	0
NUM3	-94.83987	76.69734	-1.24	0.2202	0	M_2	0
NUM4	130.34010	77.23474	1.69	0.0958	0	M_3	0
NUM5	193.40628	77.22566	1.34	0.1847	0	M_4	0
NUM6	221.44393	76.62893	2.82	0.0062	0	M_5	0
NUM7	200.39077	89.27636	2.24	0.0278	0	M_6	0
NUM8	135.70024	101.71775	1.33	0.1863	0	M_7	0
NUM9	-153.29533	90.83544	-1.69	0.0958	0	M_8	0
NUM10	-1.38669	81.11045	-0.02	0.9864	0	M_9	0
NUM11	44.30695	77.95546	0.57	0.5715	0	M_10	0
NUM12	141.63222	76.25371	1.81	0.0744	0	M_11	0
NUM13	564.73013	78.46954	7.20	<.0001	0	M_12	0
NUM14	2058.7	215.33986	9.56	<.0001	0	V1_t1	0
NUM15	-101.15007	223.94039	-0.45	0.6528	0	V1_t	0
NUM16	709.93728	160.97264	4.41	<.0001	0	V2_t1	0
NUM17	466.33400	148.51043	3.14	0.0024	0	V2_t	0
NUM18	200.19866	156.27988	1.28	0.2042	0	V3_t1	0
NUM19	1161.8	155.79203	7.46	<.0001	0	V3_t	0
NUM20	67.77480	127.29443	0.53	0.5960	0	V4_t1	0
NUM21	2031.8	132.79719	15.30	<.0001	0	V4_t	0
Variance Estimate				37805.73			
Std Error Estimate				194.4369			
AIC				1304.004			
SBC				1362.984			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.19	4	0.2688	0.041	0.005	0.101	-0.178	-0.023	-0.081
12	9.55	10	0.4810	-0.090	-0.005	0.142	-0.087	0.033	0.058
18	14.50	16	0.5616	-0.030	-0.176	-0.048	-0.033	-0.079	-0.038
24	23.07	22	0.3980	-0.079	0.132	0.137	0.109	0.118	-0.004
30	28.56	28	0.4349	0.050	-0.029	-0.190	-0.028	0.006	-0.013
36	38.54	34	0.2715	0.018	0.085	0.022	0.090	-0.137	-0.173

Model for variable y
No mean term in this model.

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.985376	Pr < W	0.3662	
Kolmogorov-Smirnov	D	0.067002	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.070903	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq	0.446975	Pr > A-Sq	>0.2500	

Rp100.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	-0.28988	0.11458	-2.53	0.0136	1	y	0
AR1_2	-0.32144	0.11855	-2.71	0.0083	2	y	0
NUM1	5.12397	0.32694	15.67	<.0001	0	t	0
NUM2	-137.62051	50.68698	-2.72	0.0083	0	M_1	0
NUM3	-79.83450	51.52718	-1.55	0.1256	0	M_2	0
NUM4	26.42553	52.21250	0.51	0.6143	0	M_3	0
NUM5	17.88577	52.16543	0.34	0.7327	0	M_4	0
NUM6	102.82659	53.05818	1.94	0.0565	0	M_5	0
NUM7	98.84627	60.31173	1.64	0.1055	0	M_6	0
NUM8	134.48502	68.81081	1.95	0.0545	0	M_7	0
NUM9	-106.06718	61.47327	-1.73	0.0887	0	M_8	0
NUM10	2.53663	54.73858	0.05	0.9532	0	M_9	0
NUM11	15.97697	52.60522	0.30	0.7622	0	M_10	0
NUM12	76.66432	52.79376	1.45	0.1507	0	M_11	0
NUM13	314.29528	52.96986	5.93	<.0001	0	M_12	0
NUM14	1197.8	142.92866	8.38	<.0001	0	V1_t1	0
NUM15	-30.89527	148.32682	-0.21	0.8362	0	V1_t	0
NUM16	297.07788	107.08146	2.77	0.0079	0	V2_t1	0
NUM17	241.50533	98.90420	2.44	0.0170	0	V2_t	0
NUM18	49.52731	103.82532	0.48	0.6348	0	V3_t1	0
NUM19	651.24872	103.60650	6.29	<.0001	0	V3_t	0
NUM20	-12.80012	84.96447	-0.15	0.8807	0	V4_t1	0
NUM21	1003.1	88.49314	11.34	<.0001	0	V4_t	0
Variance Estimate				17108.2			
Std Error Estimate				130.7983			
AIC				1227.885			
SBC				1286.865			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.32	4	0.2563	0.057	-0.010	0.148	-0.156	0.098	-0.095
12	15.95	10	0.1012	-0.165	-0.053	0.005	-0.009	0.171	0.175
18	18.03	16	0.3221	0.036	-0.068	0.064	-0.041	-0.055	-0.055
24	25.30	22	0.2828	-0.148	0.079	0.054	-0.103	0.098	-0.081
30	29.41	28	0.3921	0.054	-0.015	-0.091	0.098	0.023	-0.090
36	41.18	34	0.1853	-0.028	0.014	-0.024	0.058	-0.208	-0.167
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		----p Value-----		
Shapiro-Wilk	W	0.985376	Pr < W	0.3662	
Kolmogorov-Smirnov	D	0.067002	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.070903	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq	0.446975	Pr > A-Sq	>0.2500	

Rp50.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	2.76719	0.32107	8.62	<.0001	0	t	0
NUM2	-53.40887	32.56771	-1.64	0.1052	0	M_1	0
NUM3	-16.64939	32.70511	-0.51	0.6122	0	M_2	0
NUM4	99.53318	32.84500	3.03	0.0033	0	M_3	0
NUM5	71.29606	32.98757	2.16	0.0339	0	M_4	0
NUM6	80.18286	33.61595	2.39	0.0196	0	M_5	0
NUM7	98.35362	37.98927	2.59	0.0116	0	M_6	0
NUM8	20.25097	42.92527	0.47	0.6385	0	M_7	0
NUM9	-32.20819	39.30866	-0.82	0.4152	0	M_8	0
NUM10	4.49467	35.22300	0.13	0.3001	0	M_9	0
NUM11	32.94293	33.89388	0.97	0.3342	0	M_10	0
NUM12	68.85903	34.05319	2.02	0.0467	0	M_11	0
NUM13	255.67484	34.21476	7.47	<.0001	0	M_12	0
NUM14	491.50108	91.56212	5.37	<.0001	0	V1_t	0
NUM15	-128.31960	93.35305	-1.37	0.1734	0	V1_t	0
NUM16	232.62342	66.67731	3.49	0.0008	0	V2_t	0
NUM17	189.76808	64.38391	2.95	0.0043	0	V2_t	0
NUM18	12.33933	66.24321	0.19	0.8527	0	V3_t	0
NUM19	377.09619	66.19858	5.70	<.0001	0	V3_t	0
NUM20	8.56339	53.57013	0.16	0.8734	0	V4_t	0
NUM21	806.24028	54.59327	14.77	<.0001	0	V4_t	0
Variance Estimate				6960.374			
Std Error Estimate				83.42886			
AIC				1140.145			
SBC				1193.936			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	12.39	6	0.0538	-0.203	-0.031	0.194	-0.177	-0.005	-0.106
12	17.67	12	0.1261	-0.009	-0.047	0.160	-0.100	-0.102	-0.011
18	21.26	18	0.2665	-0.038	-0.053	-0.036	0.118	0.045	-0.037
24	22.07	24	0.5749	-0.040	0.057	0.002	-0.021	0.028	-0.022
30	27.26	30	0.6097	0.073	0.036	-0.103	-0.078	0.045	0.111
36	35.54	36	0.4904	-0.048	0.127	-0.004	0.029	-0.060	-0.177
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		----p Value-----		
Shapiro-Wilk	W	0.922299	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.103777	Pr > D	0.0119	
Cramer-von Mises	W-Sq	0.28218	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	1.799998	Pr > A-Sq	<0.0050	

Rp20.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
ARI_1	0.48112	0.11116	4.33	<.0001	1	y	0
ARI_2	0.94159	0.11621	8.10	<.0001	11	y	0
ARI_3	-0.48040	0.15830	-3.06	0.0031	12	y	0
NUM1	0.13744	0.10546	1.30	0.1966	0	t	0
NUM2	2.51265	3.86402	0.65	0.5176	0	M_1	0
NUM3	3.30670	3.93965	0.84	0.4041	0	M_2	0
NUM4	5.64119	4.07428	1.38	0.1705	0	M_3	0
NUM5	6.93048	4.23905	1.63	0.1064	0	M_4	0
NUM6	12.64699	4.40620	2.87	0.0054	0	M_5	0
NUM7	6.85899	4.62129	1.48	0.1422	0	M_6	0
NUM8	0.63995	4.72892	0.14	0.8928	0	M_7	0
NUM9	-6.57857	4.54952	-1.45	0.1525	0	M_8	0
NUM10	-2.87003	4.38845	-0.65	0.5152	0	M_9	0
NUM11	-1.37073	4.24769	-0.32	0.7479	0	M_10	0
NUM12	-0.37116	4.12624	-0.09	0.9286	0	M_11	0
NUM13	2.34910	4.08400	0.58	0.5676	0	M_12	0
NUM14	75.05095	5.67853	13.22	<.0001	0	V1_t	0
NUM15	-27.14689	5.31796	-5.10	<.0001	0	V1_t	0
NUM16	49.37409	3.98909	12.38	<.0001	0	V2_t	0
NUM17	5.76647	3.73080	1.55	0.1266	0	V2_t	0
NUM18	36.29919	3.73906	9.71	<.0001	0	V3_t	0
NUM19	33.44097	3.73224	8.96	<.0001	0	V3_t	0
NUM20	9.87275	3.53539	2.79	0.0067	0	V4_t	0
NUM21	66.36153	3.97061	16.71	<.0001	0	V4_t	0
Variance Estimate				36.58189			
Std Error Estimate				6.048296			
AIC				638.3758			
SBC				699.3202			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.56	3	0.4645	-0.032	0.065	0.048	-0.132	-0.015	-0.010
12	7.42	9	0.5933	-0.085	0.053	-0.023	0.015	0.093	-0.157
18	12.76	15	0.6207	0.113	-0.180	-0.003	0.015	-0.033	-0.011
24	25.59	21	0.2227	0.027	-0.123	0.183	-0.008	0.073	0.214
30	27.12	27	0.4571	-0.069	0.020	0.059	-0.033	0.010	-0.038
36	39.99	33	0.1876	0.032	0.052	-0.172	0.065	-0.087	-0.197
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.951439	Pr < W	0.0014	
Kolmogorov-Smirnov	D	0.124682	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.381284	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	1.981333	Pr > A-Sq	<0.0050	

Rp10.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
ARI_1	0.42226	0.09328	4.53	<.0001	1	y	0
ARI_2	0.57774	0.10923	5.29	<.0001	11	y	0
NUM1	0.07804	0.09496	0.82	0.4139	0	t	0
NUM2	0.06577	3.28294	0.02	0.9841	0	M_1	0
NUM3	1.18710	3.31106	0.36	0.7210	0	M_2	0
NUM4	4.05259	3.38049	1.20	0.2345	0	M_3	0
NUM5	5.93392	3.41448	1.74	0.0865	0	M_4	0
NUM6	11.75885	3.44511	3.41	0.0011	0	M_5	0
NUM7	7.88525	3.51037	2.25	0.0277	0	M_6	0
NUM8	-1.89098	3.64630	-0.50	0.6171	0	M_7	0
NUM9	1.87624	3.73583	0.50	0.6170	0	M_8	0
NUM10	2.34808	3.70094	0.63	0.5278	0	M_9	0
NUM11	0.72798	3.62176	0.20	0.8413	0	M_10	0
NUM12	-0.34033	3.54107	-0.10	0.9237	0	M_11	0
NUM13	0.93551	3.48615	0.27	0.7892	0	M_12	0
NUM14	59.36531	4.31636	13.75	<.0001	0	V1_t1	0
NUM15	-0.25260	4.10965	-0.06	0.9492	0	V1_t	0
NUM16	49.02732	3.24502	15.11	<.0001	0	V2_t1	0
NUM17	5.95476	3.01501	1.98	0.0520	0	V2_t	0
NUM18	46.44640	3.01228	15.42	<.0001	0	V3_t1	0
NUM19	35.32446	3.00827	11.74	<.0001	0	V3_t	0
NUM20	13.99123	2.74373	5.10	<.0001	0	V4_t1	0
NUM21	71.90781	2.92618	24.57	<.0001	0	V4_t	0
Variance Estimate				18.75116			
Std Error Estimate				4.330261			
AIC				573.5434			
SBC				632.5234			
Number of Residuals				36			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.52	4	0.2378	0.134	-0.005	-0.098	-0.153	-0.032	-0.049
12	17.95	10	0.0558	-0.053	-0.061	-0.013	0.015	0.324	0.023
18	18.56	16	0.2922	0.020	0.049	0.000	0.049	-0.002	-0.003
24	21.31	22	0.5014	-0.049	-0.074	0.069	-0.014	0.083	-0.044
30	22.07	28	0.7781	-0.035	0.029	0.029	-0.002	0.005	-0.050
36	27.72	34	0.7677	0.048	0.110	-0.074	0.013	-0.102	-0.084
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.910634	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.186497	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.690369	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	3.620363	Pr > A-Sq	<0.0050	

Rp5.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.04110	0.01737	2.37	0.0205	0	t	0
NUM2	-0.24916	1.76175	-0.14	0.8879	0	M_1	0
NUM3	-0.13696	1.76918	-0.08	0.9385	0	M_2	0
NUM4	1.54135	1.77675	0.87	0.3884	0	M_3	0
NUM5	2.74844	1.78446	1.54	0.1277	0	M_4	0
NUM6	10.56758	1.81845	5.81	<.0001	0	M_5	0
NUM7	2.52738	2.05503	1.23	0.2226	0	M_6	0
NUM8	3.39937	2.32204	1.46	0.1474	0	M_7	0
NUM9	-3.14003	2.12640	-1.48	0.1439	0	M_8	0
NUM10	-1.23406	1.90539	-0.65	0.5192	0	M_9	0
NUM11	-1.08585	1.83349	-0.59	0.5555	0	M_10	0
NUM12	-1.12802	1.84211	-0.61	0.5422	0	M_11	0
NUM13	-0.72332	1.85085	-0.39	0.6970	0	M_12	0
NUM14	99.73935	4.95905	20.14	<.0001	0	V1_t1	0
NUM15	-3.59784	5.04993	-0.71	0.4784	0	V1_t	0
NUM16	46.17015	3.60691	12.80	<.0001	0	V2_t1	0
NUM17	7.05477	3.48285	2.03	0.0464	0	V2_t	0
NUM18	21.85591	3.58342	6.10	<.0001	0	V3_t1	0
NUM19	40.58047	3.58101	11.33	<.0001	0	V3_t	0
NUM20	9.67251	2.89787	3.34	0.0013	0	V4_t1	0
NUM21	50.91159	2.95322	17.24	<.0001	0	V4_t	0
Variance Estimate				20.3679			
Std Error Estimate				4.513081			
AIC				580.0778			
SBC				633.9291			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.33	6	0.7664	0.022	-0.146	-0.015	-0.058	-0.039	-0.077
12	12.37	12	0.4161	-0.110	-0.081	0.002	0.105	0.206	0.101
18	19.37	18	0.3695	-0.183	-0.148	-0.004	-0.036	-0.047	-0.048
24	25.62	24	0.3725	-0.028	0.003	0.095	0.071	-0.185	-0.006
30	25.93	30	0.6787	0.003	-0.043	0.013	0.010	0.011	0.007
36	28.98	36	0.7904	0.012	0.058	0.014	-0.039	0.121	-0.015

Model for variable y
No mean term in this model.

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.733691	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.238053	Pr > D	<0.0100
Cramer-von Mises	W-Sq	1.146737	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	6.012075	Pr > A-Sq	<0.0050

Rp2.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.01969	0.0089917	2.19	0.0317	0	t	0
NUM2	-0.17651	0.31207	-0.19	0.8471	0	M_1	0
NUM3	-0.18591	0.31532	-0.20	0.8397	0	M_2	0
NUM4	0.14337	0.91984	0.16	0.8766	0	M_3	0
NUM5	0.48352	0.92383	0.52	0.6022	0	M_4	0
NUM6	4.94286	0.94143	5.25	<.0001	0	M_5	0
NUM7	1.26966	1.06390	1.19	0.2365	0	M_6	0
NUM8	-1.08398	1.20214	-0.90	0.3701	0	M_7	0
NUM9	-1.41272	1.10085	-1.28	0.2033	0	M_8	0
NUM10	-0.54941	0.90643	-0.56	0.5732	0	M_9	0
NUM11	-0.63699	0.94921	-0.67	0.5042	0	M_10	0
NUM12	-0.59397	0.95367	-0.62	0.5353	0	M_11	0
NUM13	-0.48374	0.95820	-0.50	0.6151	0	M_12	0
NUM14	33.73013	2.56423	13.15	<.0001	0	V1_t1	0
NUM15	0.76689	2.61438	0.29	0.7701	0	V1_t	0
NUM16	25.48293	1.86732	13.65	<.0001	0	V2_t1	0
NUM17	3.96380	1.80309	2.20	0.0310	0	V2_t	0
NUM18	14.53476	1.85516	7.83	<.0001	0	V3_t1	0
NUM19	13.32086	1.85391	7.19	<.0001	0	V3_t	0
NUM20	5.93602	1.50025	3.96	0.0002	0	V4_t1	0
NUM21	24.58296	1.52890	16.08	<.0001	0	V4_t	0
Variance Estimate				5.45902			
Std Error Estimate				2.336455			
AIC				453.6755			
SBC				507.5268			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.12	6	0.9084	-0.068	-0.044	0.007	-0.074	-0.044	-0.081
12	8.33	12	0.7591	-0.071	-0.080	-0.007	0.018	0.194	0.084
18	9.74	18	0.9400	-0.014	-0.014	-0.061	-0.058	-0.058	-0.035
24	11.19	24	0.9876	-0.029	-0.007	0.077	-0.062	0.012	-0.024
30	11.55	30	0.9990	-0.006	-0.014	-0.031	-0.034	-0.011	-0.012
36	12.42	36	0.9999	0.006	0.035	-0.013	0.056	-0.016	0.030
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.712518	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.200913	Pr > D	<0.0100
Cramer-von Mises	W-Sq	1.35305	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	7.000443	Pr > A-Sq	<0.0050

Rp1.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	-0.0061479	0.0026487	-2.32	0.0230	0	t	0
NUM2	0.34166	0.26867	1.27	0.2074	0	M_1	0
NUM3	0.34766	0.26300	1.29	0.2015	0	M_2	0
NUM4	0.44913	0.27096	1.66	0.1016	0	M_3	0
NUM5	0.61008	0.27213	2.24	0.0279	0	M_4	0
NUM6	0.36778	0.27732	1.33	0.1888	0	M_5	0
NUM7	-0.28254	0.31340	-0.90	0.3702	0	M_6	0
NUM8	-0.33880	0.35412	-0.96	0.3418	0	M_7	0
NUM9	1.29346	0.32428	4.01	0.0001	0	M_8	0
NUM10	0.51406	0.29058	1.77	0.0809	0	M_9	0
NUM11	0.40056	0.27961	1.43	0.1561	0	M_10	0
NUM12	0.39448	0.28093	1.40	0.1644	0	M_11	0
NUM13	0.41834	0.28226	1.48	0.1425	0	M_12	0
NUM14	0.91834	0.75535	1.22	0.2279	0	V1_t1	0
NUM15	0.94338	0.77013	1.22	0.2244	0	V1_t	0
NUM16	1.89360	0.55006	3.45	0.0009	0	V2_t1	0
NUM17	0.04015	0.53114	0.08	0.9399	0	V2_t	0
NUM18	0.76649	0.54648	1.40	0.1649	0	V3_t1	0
NUM19	0.71196	0.54611	1.30	0.1963	0	V3_t	0
NUM20	1.05236	0.44193	2.38	0.0198	0	V4_t1	0
NUM21	3.08852	0.45037	6.86	<.0001	0	V4_t	0
Variance Estimate				0.473695			
Std Error Estimate				0.688255			
AIC				219.0071			
SBC				272.8585			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.32	6	0.7681	0.120	0.008	-0.015	-0.085	-0.073	-0.074
12	14.51	12	0.2636	-0.067	-0.087	-0.007	-0.124	0.134	0.130
18	16.15	18	0.5818	0.046	-0.006	-0.058	-0.048	-0.056	-0.056
24	21.45	24	0.6122	-0.044	-0.043	0.064	0.177	-0.047	-0.013
30	22.26	30	0.8444	-0.028	-0.058	-0.031	-0.010	-0.020	-0.018
36	27.71	36	0.8374	-0.035	-0.075	-0.038	0.007	-0.098	-0.132
Model for variable y									
No mean term in this model.									

Tests for Normality			
Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W	0.756382	Pr < W < 0.0001
Kolmogorov-Smirnov	D	0.178027	Pr > D < 0.0100
Cramer-von Mises	W-Sq	1.094055	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq	5.891337	Pr > A-Sq < 0.0050

- Inflow KPw Surabaya*

Total Uang Kertas

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
ARI_1	0.26649	0.11328	2.35	0.0213	2	y	0
ARI_2	0.36260	0.11616	3.12	0.0026	4	y	0
NUM1	29.79679	4.24973	7.01	<.0001	0	t	0
NUM2	2190.8	293.35670	7.47	<.0001	0	M_1	0
NUM3	889.15812	295.84502	3.01	0.0036	0	M_2	0
NUM4	505.51898	298.29257	1.69	0.0944	0	M_3	0
NUM5	344.39343	300.48999	1.15	0.2555	0	M_4	0
NUM6	538.71207	304.23612	1.77	0.0808	0	M_5	0
NUM7	277.48394	308.58822	0.90	0.3715	0	M_6	0
NUM8	967.92393	326.29798	2.97	0.0041	0	M_7	0
NUM9	724.89942	345.57769	2.10	0.0394	0	M_8	0
NUM10	47.13415	327.82247	0.14	0.8861	0	M_9	0
NUM11	847.53349	314.63646	2.69	0.0088	0	M_10	0
NUM12	636.97625	309.89564	2.06	0.0434	0	M_11	0
NUM13	144.80288	311.92507	0.46	0.6439	0	M_12	0
NUM14	4204.3	518.79629	8.11	<.0001	0	V1_t	0
NUM15	1208.7	529.84559	2.28	0.0255	0	V1_t	0
NUM16	3358.4	374.89194	8.96	<.0001	0	V2_t	0
NUM17	599.57696	368.92951	1.63	0.1084	0	V2_t	0
NUM18	1593.0	373.97164	4.26	<.0001	0	V3_t	0
NUM19	1260.3	374.20962	3.37	0.0012	0	V3_t	0
NUM20	-1342.0	301.71083	-4.45	<.0001	0	V4_t	0
NUM21	5205.2	306.67013	16.97	<.0001	0	V4_t	0
Variance Estimate				271836			
Std Error Estimate				521.379			
AIC				1493.386			
SBC				1552.367			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.54	4	0.6372	-0.023	-0.009	0.143	-0.046	0.043	-0.007
12	6.07	10	0.8090	0.111	0.099	-0.010	0.022	0.086	0.053
18	8.17	16	0.9436	0.073	-0.008	-0.094	-0.055	0.030	-0.012
24	10.02	22	0.9861	0.015	0.026	-0.056	-0.003	-0.087	0.054
30	20.91	28	0.8291	0.049	-0.129	0.068	-0.147	-0.156	0.097
36	26.13	34	0.8307	-0.084	-0.017	-0.012	0.091	-0.055	-0.124
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.980791	Pr < W	0.1722
Kolmogorov-Smirnov	D	0.081989	Pr > D	0.1107
Cramer-von Mises	W-Sq	0.141967	Pr > W-Sq	0.0310
Anderson-Darling	A-Sq	0.743807	Pr > A-Sq	0.0509

Rp100.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.42206	0.11496	3.67	0.0005	4	y	0
NUM1	21.45716	2.10544	10.19	<.0001	0	t	0
NUM2	1192.1	171.81844	6.94	<.0001	0	M_1	0
NUM3	297.17701	173.03068	1.72	0.0901	0	M_2	0
NUM4	57.50726	174.21701	0.33	0.7423	0	M_3	0
NUM5	-40.97072	175.34039	-0.23	0.8159	0	M_4	0
NUM6	87.66027	176.95035	0.50	0.6218	0	M_5	0
NUM7	-101.06139	179.04950	-0.56	0.5759	0	M_6	0
NUM8	361.09789	194.74398	1.85	0.0677	0	M_7	0
NUM9	117.39458	211.38048	0.56	0.5803	0	M_8	0
NUM10	-463.99109	196.33388	-2.36	0.0207	0	M_9	0
NUM11	134.59859	184.14595	0.73	0.4671	0	M_10	0
NUM12	61.16855	181.07756	0.34	0.7365	0	M_11	0
NUM13	-243.49222	182.27663	-1.34	0.1857	0	M_12	0
NUM14	2905.4	361.67618	8.03	<.0001	0	V1_t1	0
NUM15	526.82054	371.26268	1.42	0.1601	0	V1_t	0
NUM16	2314.4	263.29828	8.79	<.0001	0	V2_t1	0
NUM17	403.44071	253.80328	1.59	0.1162	0	V2_t	0
NUM18	1181.5	262.42275	4.50	<.0001	0	V3_t1	0
NUM19	663.68214	262.78447	2.53	0.0137	0	V3_t	0
NUM20	-827.54474	212.35790	-3.90	0.0002	0	V4_t1	0
NUM21	3298.7	216.39509	15.24	<.0001	0	V4_t	0
Variance Estimate				128724.6			
Std Error Estimate				358.7821			
AIC				1420.93			
SBC				1477.946			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.43	5	0.1908	-0.074	0.184	0.123	-0.045	0.095	0.088
12	11.08	11	0.4370	0.119	0.090	0.024	0.005	0.079	0.068
18	13.30	17	0.7157	0.077	0.011	-0.088	-0.060	-0.041	-0.013
24	14.10	23	0.9239	-0.013	0.011	-0.012	-0.006	-0.075	-0.006
30	21.31	29	0.8475	0.050	-0.119	0.055	-0.081	-0.133	0.091
36	25.46	35	0.8815	-0.092	0.016	-0.032	0.046	-0.099	-0.075
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.987965	Pr < W	0.5356	
Kolmogorov-Smirnov	D	0.091074	Pr > D	0.0482	
Cramer-von Mises	W-Sq	0.112342	Pr > W-Sq	0.0797	
Anderson-Darling	A-Sq	0.555554	Pr > A-Sq	0.1511	

Rp50.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	7.15629	0.80150	8.93	<.0001	0	t	0
NUM2	848.69452	81.29988	10.44	<.0001	0	M_1	0
NUM3	453.08430	81.64289	5.55	<.0001	0	M_2	0
NUM4	375.18075	81.99229	4.58	<.0001	0	M_3	0
NUM5	299.65270	82.34801	3.64	0.0005	0	M_4	0
NUM6	401.89323	82.70996	4.86	<.0001	0	M_5	0
NUM7	302.03069	84.26359	3.59	0.0005	0	M_6	0
NUM8	529.98535	95.10948	5.57	<.0001	0	M_7	0
NUM9	431.48023	107.42774	4.02	0.0001	0	M_8	0
NUM10	322.87795	98.49545	3.28	0.0016	0	M_9	0
NUM11	494.94972	88.32994	5.60	<.0001	0	M_10	0
NUM12	449.20948	85.00814	5.28	<.0001	0	M_11	0
NUM13	265.37705	85.41148	3.11	0.0027	0	M_12	0
NUM14	1171.2	228.56966	5.12	<.0001	0	V1_t	0
NUM15	238.13630	233.04041	1.02	0.3101	0	V1_t1	0
NUM16	1091.9	166.44886	6.56	<.0001	0	V2_t	0
NUM17	156.39078	160.72376	0.97	0.3337	0	V2_t1	0
NUM18	429.24716	165.36521	2.60	0.0113	0	V3_t	0
NUM19	457.43440	165.25379	2.77	0.0071	0	V3_t1	0
NUM20	-382.88459	133.72895	-2.86	0.0054	0	V4_t	0
NUM21	1763.9	136.28304	12.94	<.0001	0	V4_t1	0
Variance Estimate				43374.86			
Std Error Estimate				208.2663			
AIC				1315.791			
SBC				1369.642			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1_1	-0.90357	0.10096	-8.95	<.0001	1
AR1_2	-0.51910	0.12770	-4.07	0.0001	2
AR1_3	-0.28482	0.10138	-2.81	0.0061	3

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.37	3	0.9469	0.001	0.002	-0.013	-0.035	-0.025	-0.040
12	2.39	9	0.9837	0.066	0.083	-0.067	0.050	-0.016	-0.020
18	3.31	15	0.9993	0.059	0.037	-0.046	-0.022	0.024	-0.031
24	5.89	21	0.9995	0.074	0.028	-0.081	-0.057	-0.033	0.059
30	12.39	27	0.9926	-0.012	-0.070	0.085	-0.124	-0.125	0.064
36	16.50	33	0.9926	-0.090	0.028	-0.019	0.073	-0.002	-0.112

Model for variable y

Period(s) of Differencing 1

No mean term in this model.

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.98201	Pr < W	0.2175	
Kolmogorov-Smirnov	D	0.064691	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.046844	Pr > W-Sq	>0.2500	
Anderson-Darling	A-Sq	0.367587	Pr > A-Sq	>0.2500	

Rp20.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AF1_1	0.41173	0.11367	3.62	0.0005	1	y	0
NUM1	0.13294	0.16110	0.82	0.4140	0	t	0
NUM2	48.31456	12.12932	3.98	0.0002	0	M_1	0
NUM3	33.85231	12.30223	2.75	0.0075	0	M_2	0
NUM4	30.18466	12.39264	2.44	0.0173	0	M_3	0
NUM5	25.69462	12.48001	2.06	0.0430	0	M_4	0
NUM6	20.82796	12.57188	1.66	0.1018	0	M_5	0
NUM7	19.49323	12.77434	1.53	0.1313	0	M_6	0
NUM8	46.46897	13.87040	3.35	0.0013	0	M_7	0
NUM9	66.17422	15.19869	4.35	<.0001	0	M_8	0
NUM10	58.89405	14.51043	4.06	0.0001	0	M_9	0
NUM11	57.33712	13.42444	4.27	<.0001	0	M_10	0
NUM12	52.33938	13.04518	4.01	0.0001	0	M_11	0
NUM13	30.75384	12.91543	2.38	0.0198	0	M_12	0
NUM14	79.08466	27.81813	2.84	0.0058	0	V1_t	0
NUM15	90.02707	28.07845	3.21	0.0020	0	V1_t1	0
NUM16	-9.81024	20.62942	-0.48	0.6358	0	V2_t	0
NUM17	12.33837	19.88177	0.62	0.5368	0	V2_t1	0
NUM18	-22.92629	20.03541	-1.14	0.2562	0	V3_t	0
NUM19	57.65053	19.92905	2.89	0.0050	0	V3_t1	0
NUM20	-36.96320	16.01419	-2.31	0.0238	0	V4_t	0
NUM21	64.66277	16.06952	4.02	0.0001	0	V4_t1	0
				Variance Estimate	668.639		
				Std Error Estimate	25.85805		
				AIC	915.9525		
				SBC	972.3681		
				Number of Residuals	96		
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.60	5	0.7616	0.030	-0.003	-0.145	-0.061	0.004	-0.011
12	9.94	11	0.5357	0.106	-0.012	0.008	-0.123	0.170	0.106
18	10.63	17	0.8753	-0.013	-0.051	0.015	0.031	-0.037	0.024
24	20.63	23	0.6034	-0.022	-0.013	-0.136	-0.035	0.234	0.056
30	21.53	29	0.8368	-0.042	-0.041	-0.017	-0.004	-0.057	-0.001
36	31.40	35	0.6428	0.042	-0.114	-0.044	0.028	0.104	-0.189
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.836835	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.195606	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.712384	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	3.881914	Pr > A-Sq	<0.0050	

Rp10.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.38129	0.09371	4.07	0.0001	1	y	0
AR1_2	0.61871	0.11321	5.47	<.0001	11	y	0
NUM1	0.29880	0.29187	1.02	0.3093	0	t	0
NUM2	38.66540	13.90627	2.78	0.0069	0	M_1	0
NUM3	23.82325	13.96851	1.71	0.0924	0	M_2	0
NUM4	18.05805	14.15868	1.28	0.2052	0	M_3	0
NUM5	9.60440	14.29644	0.67	0.5039	0	M_4	0
NUM6	11.60114	14.40339	0.81	0.4232	0	M_5	0
NUM7	13.13229	14.46124	0.91	0.3668	0	M_6	0
NUM8	33.20326	14.69483	2.26	0.0268	0	M_7	0
NUM9	52.55827	15.36813	3.42	0.0010	0	M_8	0
NUM10	48.26737	15.60665	3.09	0.0028	0	M_9	0
NUM11	37.49204	15.19752	2.47	0.0160	0	M_10	0
NUM12	37.41389	14.71500	2.54	0.0131	0	M_11	0
NUM13	26.78872	14.62965	1.83	0.0712	0	M_12	0
NUM14	-12.86848	20.23045	-0.64	0.5267	0	V1_t	0
NUM15	70.06959	18.23842	3.84	0.0003	0	V1_t1	0
NUM16	-17.91048	14.74309	-1.21	0.2283	0	V2_t	0
NUM17	2.90238	13.65625	0.21	0.8323	0	V2_t1	0
NUM18	-15.58623	13.51080	-1.15	0.2524	0	V3_t	0
NUM19	22.68553	14.25376	1.59	0.1160	0	V3_t1	0
NUM20	-32.00481	11.91564	-2.69	0.0089	0	V4_t	0
NUM21	35.83392	13.20664	2.71	0.0083	0	V4_t1	0
Variance Estimate				371.4135			
Std Error Estimate				19.27209			
AIC				860.2052			
SBC				919.1852			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.60	4	0.8083	-0.021	0.052	-0.072	-0.061	-0.046	-0.039
12	5.87	10	0.8261	0.029	0.066	-0.019	-0.179	0.039	0.002
18	6.93	16	0.9746	-0.079	-0.010	0.036	0.034	0.014	0.013
24	25.65	22	0.2672	-0.021	-0.031	-0.050	-0.188	0.326	-0.010
30	26.53	28	0.5442	-0.028	-0.032	-0.012	-0.040	-0.015	-0.050
36	38.87	34	0.2537	0.047	-0.042	-0.136	0.105	0.108	-0.187
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.815843	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.182743	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.753374	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	4.564287	Pr > A-Sq	<0.0050

Rp5.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.43665	0.09987	4.37	<.0001	1	y	0
AR1_2	-0.28050	0.08663	-2.84	0.0058	2	y	0
AR1_3	0.56198	0.11046	5.09	<.0001	11	y	0
NUM1	0.27478	0.10885	2.52	0.0138	0	t	0
NUM2	26.67303	9.34096	2.86	0.0056	0	M_1	0
NUM3	20.18243	9.34149	2.16	0.0341	0	M_2	0
NUM4	16.19508	9.42351	1.72	0.0900	0	M_3	0
NUM5	10.23223	9.45733	1.08	0.2829	0	M_4	0
NUM6	12.24516	9.44273	1.30	0.1988	0	M_5	0
NUM7	11.45775	9.45706	1.21	0.2296	0	M_6	0
NUM8	23.30338	9.93518	2.35	0.0218	0	M_7	0
NUM9	38.93669	10.62024	3.67	0.0005	0	M_8	0
NUM10	44.42577	10.79371	4.12	0.0001	0	M_9	0
NUM11	42.38081	10.41738	4.07	0.0001	0	M_10	0
NUM12	29.78947	9.93767	3.00	0.0037	0	M_11	0
NUM13	22.32268	9.81348	2.27	0.0259	0	M_12	0
NUM14	-39.81979	16.66665	-2.03	0.0462	0	V1_t	0
NUM15	28.79235	15.38615	1.87	0.0654	0	V1_t1	0
NUM16	-16.38824	12.17215	-1.35	0.1824	0	V2_t	0
NUM17	0.03344	11.57399	0.00	0.9977	0	V2_t1	0
NUM18	-14.19029	11.41656	-1.24	0.2179	0	V3_t	0
NUM19	7.42069	11.55399	0.64	0.5227	0	V3_t1	0
NUM20	-29.87273	9.92344	-2.41	0.0187	0	V4_t	0
NUM21	-0.60323	11.42603	-0.05	0.9580	0	V4_t1	0
Variance Estimate				245.3545			
Std Error Estimate				15.6638			
AIC				821.0783			
SBC				882.6227			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.28	3	0.1526	-0.026	-0.106	0.109	-0.100	-0.130	-0.031
12	7.40	9	0.5958	-0.035	0.079	0.005	0.016	-0.095	-0.051
18	10.00	15	0.8196	-0.014	0.104	0.037	0.040	-0.062	0.065
24	17.45	21	0.6833	-0.091	-0.061	-0.068	-0.054	0.144	0.135
30	23.47	27	0.6594	-0.175	0.007	0.050	-0.088	-0.027	-0.057
36	28.76	33	0.6781	0.013	0.037	-0.050	0.017	-0.036	-0.168
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W	0.92842	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.122603	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.360084	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	2.08602	Pr > A-Sq	<0.0050	

Rp2.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.41543	0.11091	3.75	0.0004	1	y	0
AR1_2	-0.26977	0.10976	-2.46	0.0164	4	y	0
NUM1	0.18871	0.03436	5.49	<.0001	0	t	0
NUM2	9.08659	3.31616	2.74	0.0077	0	M_1	0
NUM3	9.25276	3.34235	2.77	0.0071	0	M_2	0
NUM4	7.20487	3.34622	2.15	0.0346	0	M_3	0
NUM5	2.98549	3.36952	0.89	0.3785	0	M_4	0
NUM6	0.81237	3.41588	0.24	0.8127	0	M_5	0
NUM7	0.69996	3.48752	0.20	0.8415	0	M_6	0
NUM8	5.89583	3.78610	1.56	0.1237	0	M_7	0
NUM9	17.14795	4.15747	4.12	<.0001	0	M_8	0
NUM10	29.43083	4.00329	7.35	<.0001	0	M_9	0
NUM11	31.22538	3.69497	8.45	<.0001	0	M_10	0
NUM12	17.19992	3.56131	4.81	<.0001	0	M_11	0
NUM13	12.51138	3.50471	3.57	0.0006	0	M_12	0
NUM14	-9.89168	7.77650	-1.27	0.2074	0	V1_t	0
NUM15	11.60198	7.85238	1.48	0.1438	0	V1_t1	0
NUM16	-17.46345	5.61450	-3.11	0.0027	0	V2_t	0
NUM17	-11.03885	5.49138	-2.01	0.0481	0	V2_t1	0
NUM18	-11.83955	5.58677	-2.12	0.0375	0	V3_t	0
NUM19	-13.29112	5.55479	-2.39	0.0193	0	V3_t1	0
NUM20	-13.46670	4.43519	-3.04	0.0033	0	V4_t	0
NUM21	-12.70207	4.46542	-2.84	0.0058	0	V4_t1	0
Variance Estimate				55.76229			
Std Error Estimate				7.467415			
AIC				678.1683			
SBC				737.1483			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.74	4	0.7835	0.024	-0.008	-0.040	-0.038	0.011	0.114
12	3.78	10	0.9587	0.005	-0.078	0.001	0.015	-0.000	0.110
18	6.57	16	0.9806	0.920	-0.129	-0.066	-0.040	-0.034	-0.003
24	16.12	22	0.8101	0.012	-0.110	-0.098	0.100	0.183	-0.096
30	18.58	28	0.9106	0.025	-0.092	-0.080	0.029	-0.003	0.042
36	23.71	34	0.9063	-0.096	0.060	-0.014	0.118	0.035	-0.078

Model for variable y
No mean term in this model.

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.990592	Pr < W	0.7371
Kolmogorov-Smirnov	D	0.064596	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.045576	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.279907	Pr > A-Sq	>0.2500

Rp1.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	-0.86670	0.10824	-8.01	<.0001	1	y	0
MA1_2	-0.30212	0.12260	-2.46	0.0161	2	y	0
MA1_3	-0.23009	0.08677	-2.65	0.0098	10	y	0
NUM1	-0.07591	0.01077	-7.05	<.0001	0	t	0
NUM2	6.95236	0.73173	9.50	<.0001	0	M_1	0
NUM3	7.55946	0.78279	9.66	<.0001	0	M_2	0
NUM4	6.83935	0.78528	8.71	<.0001	0	M_3	0
NUM5	6.91762	0.79550	8.70	<.0001	0	M_4	0
NUM6	6.53456	0.80518	8.12	<.0001	0	M_5	0
NUM7	6.22329	0.81479	7.64	<.0001	0	M_6	0
NUM8	6.13966	0.85259	7.20	<.0001	0	M_7	0
NUM9	6.33926	0.89491	7.08	<.0001	0	M_8	0
NUM10	6.33679	0.89757	7.06	<.0001	0	M_9	0
NUM11	8.63952	0.85552	10.10	<.0001	0	M_10	0
NUM12	7.92024	0.83126	9.53	<.0001	0	M_11	0
NUM13	7.79596	0.78389	9.95	<.0001	0	M_12	0
NUM14	-0.45335	1.34052	-0.34	0.7351	0	V1_t	0
NUM15	-0.13305	1.30303	-0.10	0.9190	0	V1_t1	0
NUM16	-0.17824	0.95708	-0.19	0.8528	0	V2_t	0
NUM17	1.40394	0.95627	1.47	0.1464	0	V2_t1	0
NUM18	-1.31181	0.94989	-1.38	0.1715	0	V3_t	0
NUM19	-0.46816	0.93236	-0.50	0.6171	0	V3_t1	0
NUM20	-1.41313	0.78023	-1.82	0.0731	0	V4_t	0
NUM21	-1.35573	0.76343	-1.76	0.0823	0	V4_t1	0
Variance Estimate				1.674792			
Std Error Estimate				1.294137			
AIC				342.3248			
SBC				403.8692			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	11.56	3	0.0091	0.096	0.160	0.044	-0.058	0.148	0.225
12	32.05	9	0.0002	-0.001	0.206	-0.030	0.235	0.258	0.148
18	33.60	15	0.0039	0.018	0.082	-0.077	0.014	0.011	-0.012
24	35.82	21	0.0229	-0.038	0.062	-0.071	0.074	-0.042	0.004
30	41.71	27	0.0352	-0.082	-0.077	-0.081	-0.076	-0.036	-0.033
36	50.12	33	0.0285	-0.077	-0.066	-0.114	-0.010	-0.111	-0.139
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.947826	Pr < W	0.0008
Kolmogorov-Smirnov	D	0.080214	Pr > D	0.1306
Cramer-von Mises	W-Sq	0.113585	Pr > W-Sq	0.0769
Anderson-Darling	A-Sq	0.968942	Pr > A-Sq	0.0154

- *Outflow KPw Surabaya*

Total Uang Kertas

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.47258	0.11241	4.20	<.0001	3	y	0
NUM1	30.36681	3.85861	7.87	<.0001	0	t	0
NUM2	-436.73218	238.41312	-1.86	0.1475	0	M_1	0
NUM3	161.89153	301.14201	0.54	0.5925	0	M_2	0
NUM4	819.29537	302.76348	2.71	0.0084	0	M_3	0
NUM5	693.88070	307.37810	2.26	0.0269	0	M_4	0
NUM6	858.95025	312.00858	2.75	0.0074	0	M_5	0
NUM7	1126.1	334.60926	3.37	0.0012	0	M_6	0
NUM8	252.40959	357.75320	0.71	0.4827	0	M_7	0
NUM9	-377.13117	339.62854	-1.11	0.2704	0	M_8	0
NUM10	-51.18169	322.78751	-0.16	0.8744	0	M_9	0
NUM11	279.55664	312.17221	0.90	0.3734	0	M_10	0
NUM12	476.78717	314.40827	1.52	0.1337	0	M_11	0
NUM13	1953.4	316.92290	6.16	<.0001	0	M_12	0
NUM14	4940.3	601.15710	8.22	<.0001	0	V1_t1	0
NUM15	-859.88921	608.75382	-1.41	0.1620	0	V1_t1	0
NUM16	3148.9	434.91663	7.24	<.0001	0	V2_t1	0
NUM17	2077.0	419.59158	4.95	<.0001	0	V2_t1	0
NUM18	969.53433	435.54403	2.23	0.0291	0	V3_t1	0
NUM19	3942.9	432.83617	9.11	<.0001	0	V3_t1	0
NUM20	-88.83984	349.05427	-0.25	0.7998	0	V4_t1	0
NUM21	5432.3	355.92150	15.26	<.0001	0	V4_t1	0
Variance Estimate				366910.8			
Std Error Estimate				605.7316			
AIC				1521.485			
SBC				1577.901			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.00	5	0.5497	-0.049	0.132	0.007	-0.122	0.052	-0.044
12	4.60	11	0.9490	-0.009	0.034	0.045	-0.011	0.033	0.033
18	7.89	17	0.9688	-0.056	-0.109	-0.001	-0.075	-0.076	0.043
24	17.95	23	0.7602	-0.082	0.108	0.083	-0.069	0.179	-0.130
30	27.91	29	0.5225	-0.015	-0.052	-0.169	0.168	-0.008	0.112
36	36.44	35	0.4018	-0.052	-0.029	-0.052	-0.139	-0.118	-0.128
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.978689	Pr < W	0.1199
Kolmogorov-Smirnov	D	0.060133	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.062801	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.472623	Pr > A-Sq	0.2429

Rp100.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
AR1_1	0.45599	0.11602	3.93	0.0002	3	y	0
NUM1	18.21221	2.20759	8.25	<.0001	0	t	0
NUM2	-347.59991	171.70441	-2.02	0.0465	0	M_1	0
NUM3	-43.29563	173.31773	-0.25	0.8034	0	M_2	0
NUM4	336.37661	174.17737	1.93	0.0573	0	M_3	0
NUM5	311.56670	176.71073	1.76	0.0820	0	M_4	0
NUM6	304.09391	179.41020	2.14	0.0356	0	M_5	0
NUM7	417.16334	192.73564	2.16	0.0337	0	M_6	0
NUM8	256.60630	206.87790	1.24	0.2188	0	M_7	0
NUM9	-272.17612	195.92514	-1.39	0.1689	0	M_8	0
NUM10	-6.41709	185.71792	-0.03	0.9725	0	M_9	0
NUM11	86.62297	179.62410	0.48	0.6311	0	M_10	0
NUM12	220.48008	180.86354	1.22	0.2267	0	M_11	0
NUM13	1136.0	182.30746	6.23	<.0001	0	M_12	0
NUM14	2134.1	352.76456	6.05	<.0001	0	V1_t	0
NUM15	-611.77964	358.46639	-1.71	0.0921	0	V1_t	0
NUM16	1053.5	256.10408	4.11	<.0001	0	V2_t	0
NUM17	992.13258	246.95618	4.02	0.0001	0	V2_t	0
NUM18	-120.33612	256.31043	-0.47	0.6384	0	V3_t	0
NUM19	1675.3	254.62706	6.58	<.0001	0	V3_t	0
NUM20	-339.76879	205.03885	-1.66	0.1017	0	V4_t	0
NUM21	2165.6	209.05547	10.36	<.0001	0	V4_t	0
				Variance Estimate	125227.5		
				Std Error Estimate	353.075		
				AIC	1418.286		
				SBC	1474.702		
				Number of Residuals	96		
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.45	5	0.4863	-0.016	0.103	0.030	-0.141	0.013	-0.107
12	5.88	11	0.8811	0.008	0.004	0.064	-0.022	0.056	0.072
18	7.98	17	0.9670	-0.024	0.017	-0.039	-0.047	-0.114	0.015
24	13.99	23	0.6423	-0.129	0.078	0.081	-0.168	0.133	-0.139
30	30.61	29	0.3842	0.3842	-0.075	-0.018	-0.115	0.217	0.018
36	38.16	35	0.3279	-0.083	-0.055	-0.040	-0.123	-0.073	-0.132
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.968755	Pr < W	0.0216	
Kolmogorov-Smirnov	D	0.066934	Pr > D	>0.1500	
Cramer-von Mises	W-Sq	0.074571	Pr > W-Sq	0.2444	
Anderson-Darling	A-Sq	0.577578	Pr > A-Sq	0.1348	

Rp50.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	11.30305	1.23650	9.14	<.0001	0	t	0
NUM2	-110.48993	125.42374	-0.88	0.3812	0	M_1	0
NUM3	143.51817	125.95289	1.14	0.2581	0	M_2	0
NUM4	449.66573	126.49193	3.55	0.0007	0	M_3	0
NUM5	329.84195	127.04071	2.60	0.0113	0	M_4	0
NUM6	337.78204	129.46068	2.61	0.0110	0	M_5	0
NUM7	532.55419	146.30307	3.64	0.0005	0	M_6	0
NUM8	83.12363	165.31247	0.50	0.6166	0	M_7	0
NUM9	-63.96204	151.38430	-0.42	0.6739	0	M_8	0
NUM10	2.04121	135.64972	0.02	0.9880	0	M_9	0
NUM11	197.21714	130.53107	1.51	0.1350	0	M_10	0
NUM12	263.56624	131.14457	2.01	0.0481	0	M_11	0
NUM13	793.55153	131.76682	6.02	<.0001	0	M_12	0
NUM14	1148.9	352.62117	3.26	0.0017	0	V1_t1	0
NUM15	-419.47213	359.51834	-1.17	0.2470	0	V1_t	0
NUM16	999.54502	256.78558	3.89	0.0002	0	V2_t1	0
NUM17	976.61041	247.95330	3.94	0.0002	0	V2_t	0
NUM18	93.09023	255.11380	0.36	0.7162	0	V3_t1	0
NUM19	1637.6	254.94190	6.42	<.0001	0	V3_t	0
NUM20	-75.94579	206.30761	-0.37	0.7138	0	V4_t1	0
NUM21	2084.5	210.24788	9.91	<.0001	0	V4_t	0
Variance Estimate				103232.8			
Std Error Estimate				321.2986			
AIC				1399.033			
SBC				1452.884			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
ARI_1	-0.88316	0.08802	-10.03	<.0001	1
ARI_2	-0.54048	0.08952	-6.04	<.0001	2

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.10	4	0.8938	-0.007	-0.054	-0.061	-0.051	0.040	-0.010
12	2.25	10	0.9941	0.002	-0.049	-0.048	-0.062	0.008	-0.045
18	4.67	16	0.9972	-0.068	-0.091	0.034	-0.039	-0.056	0.048
24	11.76	22	0.9622	0.041	0.121	0.000	-0.026	0.173	-0.095
30	16.06	28	0.9650	-0.080	-0.046	-0.082	0.084	0.057	0.076
36	23.06	34	0.9222	-0.013	-0.019	0.044	-0.018	-0.169	-0.118
Model for variable y									
Period(s) of Differencing 1									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.979204	Pr < W	0.1354
Kolmogorov-Smirnov	D	0.079853	Pr > D	0.1392
Cramer-von Mises	W-Sq	0.082222	Pr > W-Sq	0.1991
Anderson-Darling	A-Sq	0.596811	Pr > A-Sq	0.1209

Rp20.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.38491	0.12340	3.12	0.0026	0	t	0
NUM2	7.07659	12.51685	0.57	0.5735	0	M_1	0
NUM3	5.52054	12.56966	0.44	0.6618	0	M_2	0
NUM4	3.08443	12.62345	0.24	0.8076	0	M_3	0
NUM5	10.28362	12.67822	0.81	0.4199	0	M_4	0
NUM6	25.73895	12.91972	1.99	0.0500	0	M_5	0
NUM7	51.61588	14.60053	3.54	0.0007	0	M_6	0
NUM8	-29.58695	16.49760	-1.73	0.0872	0	M_7	0
NUM9	-39.38393	15.10762	-2.61	0.0110	0	M_8	0
NUM10	-22.15850	13.53737	-1.64	0.1059	0	M_9	0
NUM11	-16.30922	13.02654	-1.25	0.2145	0	M_10	0
NUM12	-13.73915	13.08777	-1.05	0.2972	0	M_11	0
NUM13	13.74980	13.14986	1.05	0.2991	0	M_12	0
NUM14	491.52457	35.19035	13.97	<.0001	0	V1_t	0
NUM15	0.44682	35.87866	0.01	0.9901	0	V1_t	0
NUM16	258.18537	25.62630	10.08	<.0001	0	V2_t1	0
NUM17	40.61123	24.74487	1.64	0.1049	0	V2_t	0
NUM18	303.18749	25.45946	11.91	<.0001	0	V3_t1	0
NUM19	137.96898	25.44230	5.42	<.0001	0	V3_t	0
NUM20	131.46233	20.58877	6.39	<.0001	0	V4_t1	0
NUM21	345.64279	20.98200	16.47	<.0001	0	V4_t	0
Variance Estimate				1028.13			
Std Error Estimate				32.06447			
AIC				956.5454			
SBC				1010.397			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.49	6	0.7458	0.111	-0.037	-0.042	-0.066	-0.107	-0.056
12	7.93	12	0.7907	-0.075	-0.025	-0.039	-0.065	0.143	0.089
18	9.33	18	0.9515	0.051	-0.050	-0.067	-0.040	0.031	0.008
24	12.19	24	0.9777	0.027	0.007	0.103	0.092	-0.047	0.025
30	13.61	30	0.9955	-0.009	-0.041	-0.075	-0.013	-0.053	0.002
36	32.73	36	0.6251	-0.060	0.015	0.096	0.061	-0.239	-0.223
Model for variable y									
No mean term in this model.									

Tests for Normality					
Test	--Statistic--		-----p Value-----		
Shapiro-Wilk	W	0.820163	Pr < W	<0.0001	
Kolmogorov-Smirnov	D	0.162027	Pr > D	<0.0100	
Cramer-von Mises	W-Sq	0.728817	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq	4.372007	Pr > A-Sq	<0.0050	

Rp10.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	0.31380	0.12760	2.46	0.0162	0	t	0
NUM2	3.58563	12.94338	0.28	0.7837	0	M_1	0
NUM3	5.53253	12.93799	0.43	0.6682	0	M_2	0
NUM4	6.85243	13.05361	0.52	0.6012	0	M_3	0
NUM5	17.02571	13.11024	1.30	0.1980	0	M_4	0
NUM6	26.39449	13.35998	1.98	0.0519	0	M_5	0
NUM7	55.85375	15.09807	3.70	0.0004	0	M_6	0
NUM8	-51.34809	17.05378	-3.01	0.0036	0	M_7	0
NUM9	-21.14228	15.62244	-1.35	0.1800	0	M_8	0
NUM10	-17.97991	13.99867	-1.28	0.2030	0	M_9	0
NUM11	-13.28790	13.47044	-0.99	0.3271	0	M_10	0
NUM12	-11.49261	13.53375	-0.85	0.3985	0	M_11	0
NUM13	9.46364	13.59797	0.70	0.4886	0	M_12	0
NUM14	404.22603	36.38952	11.11	<.0001	0	V1_t1	0
NUM15	30.30366	37.10129	0.82	0.4166	0	V1_t	0
NUM16	289.47284	26.49955	10.92	<.0001	0	V2_t1	0
NUM17	53.65091	25.58809	2.10	0.0394	0	V2_t	0
NUM18	294.65382	26.32703	11.19	<.0001	0	V3_t1	0
NUM19	180.64757	26.30929	6.87	<.0001	0	V3_t	0
NUM20	150.75042	21.29037	7.08	<.0001	0	V4_t1	0
NUM21	387.48259	21.69699	17.86	<.0001	0	V4_t	0
Variance Estimate				1099.394			
Std Error Estimate				33.15712			
AIC				962.979			
SBC				1016.83			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.63	6	0.5926	0.161	-0.091	-0.030	-0.054	-0.002	0.089
12	8.62	12	0.7352	-0.012	-0.043	-0.065	-0.086	0.135	-0.066
18	10.91	18	0.8981	-0.126	0.027	-0.044	-0.023	0.028	0.020
24	11.99	24	0.9084	0.013	0.004	-0.023	-0.005	0.016	0.020
30	13.42	30	0.9961	0.087	-0.015	-0.050	0.005	-0.077	-0.028
36	29.71	36	0.7609	-0.050	-0.052	0.053	0.117	-0.204	-0.205
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.778019	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.192319	Pr > D	<0.0100
Cramer-von Mises	W-Sq	1.104257	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	6.357679	Pr > A-Sq	<0.0050

Rp5.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1_1	0.35625	0.11639	3.06	0.0031	1	y	0
NUM1	0.14598	0.07440	1.95	0.0550	0	t	0
NUM2	-1.75793	11.10245	-0.16	0.8747	0	M_1	0
NUM3	3.58515	11.34793	0.32	0.7529	0	M_2	0
NUM4	4.04725	11.36962	0.36	0.7229	0	M_3	0
NUM5	11.06675	11.39175	0.97	0.3345	0	M_4	0
NUM6	27.12607	11.60344	2.34	0.0221	0	M_5	0
NUM7	21.93996	13.17260	1.67	0.1000	0	M_6	0
NUM8	-27.74498	14.96331	-1.85	0.0677	0	M_7	0
NUM9	-2.31915	13.44054	-0.17	0.8835	0	M_8	0
NUM10	-7.48441	11.97940	-0.62	0.5340	0	M_9	0
NUM11	-6.01968	11.53372	-0.52	0.6033	0	M_10	0
NUM12	-5.40247	11.55889	-0.47	0.6416	0	M_11	0
NUM13	7.85535	11.59645	0.68	0.5003	0	M_12	0
NUM14	536.10345	32.92051	16.28	<.0001	0	V1_t1	0
NUM15	15.80458	33.05396	0.48	0.6340	0	V1_t	0
NUM16	336.12830	24.73053	13.58	<.0001	0	V2_t1	0
NUM17	26.60541	22.41950	1.19	0.2390	0	V2_t	0
NUM18	313.20561	23.40380	13.38	<.0001	0	V3_t1	0
NUM19	203.76366	23.46067	8.69	<.0001	0	V3_t	0
NUM20	122.13479	18.84032	6.48	<.0001	0	V4_t1	0
NUM21	234.02929	19.74788	11.85	<.0001	0	V4_t	0
				Variance Estimate	898.1052		
				Std Error Estimate	28.95005		
				AIC	937.6388		
				SBC	994.0545		
				Number of Residuals	96		
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.41	5	0.9951	0.011	-0.030	-0.024	0.046	0.011	-0.011
12	3.12	11	0.9891	0.029	-0.009	0.010	-0.011	0.135	-0.072
18	5.03	17	0.9977	-0.099	0.057	-0.016	-0.051	-0.004	-0.028
24	29.73	23	0.1573	0.031	-0.037	-0.018	0.125	0.125	-0.395
30	30.52	29	0.3884	-0.020	-0.001	-0.003	-0.043	-0.058	0.007
36	44.59	35	0.1285	-0.017	0.021	0.008	0.027	-0.299	0.019
Model for variable y									
No mean term in this model.									

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.698469	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.197957	Pr > D	<0.0100
Cramer-von Mises	W-Sq	1.580819	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	8.60292	Pr > A-Sq	<0.0050

Rp2.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
ARI_1	-0.26106	0.10789	-2.42	0.0180	1	y	0
ARI_2	0.52537	0.11049	4.76	<.0001	23	y	0
NUM1	0.13934	0.00352	3.53	0.0007	0	t	0
NUM2	-2.65632	4.08678	-0.65	0.5177	0	M_1	0
NUM3	-1.73338	4.09750	-0.42	0.6735	0	M_2	0
NUM4	-0.35078	4.10252	-0.09	0.9321	0	M_3	0
NUM5	2.93348	4.12460	0.71	0.4792	0	M_4	0
NUM6	10.16273	4.18545	2.43	0.0176	0	M_5	0
NUM7	13.52863	4.75350	2.84	0.0058	0	M_6	0
NUM8	-13.40121	5.62424	-2.38	0.0198	0	M_7	0
NUM9	-10.51063	5.22481	-2.01	0.0479	0	M_8	0
NUM10	-9.17273	4.42929	-2.07	0.0419	0	M_9	0
NUM11	-7.21586	4.25239	-1.70	0.0940	0	M_10	0
NUM12	-5.83385	4.24294	-1.37	0.1734	0	M_11	0
NUM13	-1.82513	4.23523	-0.42	0.6721	0	M_12	0
NUM14	238.36499	14.29856	16.67	<.0001	0	V1_t1	0
NUM15	1.60448	12.97562	0.12	0.9019	0	V1_t	0
NUM16	250.85743	9.90496	25.33	<.0001	0	V2_t1	0
NUM17	15.98369	8.97659	1.78	0.0791	0	V2_t	0
NUM18	149.70668	10.13225	14.78	<.0001	0	V3_t1	0
NUM19	92.39465	10.11012	9.14	<.0001	0	V3_t	0
NUM20	42.42519	7.39270	5.74	<.0001	0	V4_t1	0
NUM21	183.52384	8.37922	21.90	<.0001	0	V4_t	0
Variance Estimate				136.9693			
Std Error Estimate				11.70339			
AIC				764.4396			
SBC				823.4196			
Number of Residuals				96			

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.54	4	0.8199	-0.001	-0.070	-0.033	-0.042	-0.073	-0.044
12	7.64	10	0.6642	-0.091	-0.029	-0.004	0.019	0.214	0.015
18	10.57	16	0.8955	0.033	-0.046	-0.079	-0.093	-0.055	-0.061
24	17.75	22	0.7204	0.001	-0.010	0.075	0.145	0.123	-0.118
30	22.96	28	0.7348	-0.018	-0.069	-0.122	-0.073	-0.112	0.006
36	43.50	34	0.1274	0.043	0.046	0.131	0.241	-0.237	-0.001

Model for variable y
No mean term in this model.

Tests for Normality			
Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W	0.79723	Pr < W < 0.0001
Kolmogorov-Smirnov	D	0.191664	Pr > D < 0.0100
Cramer-von Mises	W-Sq	1.239095	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq	6.795589	Pr > A-Sq < 0.0050

Rp1.000

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
NUM1	-0.01238	0.0050268	-2.46	0.0161	0	t	0
NUM2	0.91370	0.50988	1.79	0.0772	0	M_1	0
NUM3	1.23033	0.51204	2.42	0.0180	0	M_2	0
NUM4	1.14497	0.51423	2.23	0.0290	0	M_3	0
NUM5	1.11465	0.51646	2.16	0.0341	0	M_4	0
NUM6	0.94741	0.52630	1.80	0.0759	0	M_5	0
NUM7	-0.26464	0.59476	-0.44	0.6576	0	M_6	0
NUM8	0.77268	0.67204	1.15	0.2539	0	M_7	0
NUM9	2.10250	0.61542	3.42	0.0010	0	M_8	0
NUM10	0.96007	0.55146	1.74	0.0858	0	M_9	0
NUM11	0.82498	0.53065	1.55	0.1242	0	M_10	0
NUM12	0.82378	0.53314	1.55	0.1265	0	M_11	0
NUM13	1.13219	0.53567	2.11	0.0379	0	M_12	0
NUM14	1.56995	1.43351	1.10	0.2769	0	V1_t	0
NUM15	0.22029	1.46155	0.15	0.8806	0	V1_t	0
NUM16	11.86371	1.04391	11.36	<.0001	0	V2_t	0
NUM17	1.66737	1.00800	1.65	0.1023	0	V2_t	0
NUM18	0.56239	1.03711	0.54	0.5832	0	V3_t	0
NUM19	3.94082	1.03641	3.80	0.0003	0	V3_t	0
NUM20	0.97913	0.83870	1.17	0.2467	0	V4_t	0
NUM21	8.34726	0.85472	9.77	<.0001	0	V4_t	0
Variance Estimate				1.706088			
Std Error Estimate				1.306173			
AIC				342.0211			
SBC				395.8724			
Number of Residuals				96			
* AIC and SBC do not include log determinant.							

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.83	6	0.8304	0.045	0.073	-0.078	-0.062	-0.066	-0.078
12	3.89	12	0.9854	-0.000	-0.066	-0.019	0.050	0.049	-0.008
18	6.22	18	0.9952	-0.114	-0.003	-0.057	0.009	-0.041	-0.049
24	22.98	24	0.5211	-0.104	-0.097	-0.064	0.098	0.303	-0.072
30	24.21	30	0.7626	-0.047	-0.021	-0.004	0.033	0.010	0.071
36	44.72	36	0.1511	-0.015	-0.000	0.022	0.058	-0.338	-0.120
Model for variable y									
No mean term in this model.									


Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.770433	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.190832	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.833701	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	5.136886	Pr > A-Sq	<0.0050

Lampiran 2. Output DNN

- Inflow KPw Jember**


Total Uang Kertas

Rp100.000




Rp50.000


Rp20.000




Rp10.000




Rp5.000



Rp2.000




Rp1.000




- **Outflow KPw Jember**


Total Uang Kertas




Rp100.000




Rp50.000




Rp20.000




Rp10.000




Rp5.000



Rp2.000




Rp1.000




• **Inflow KPw Kediri**
Total Uang Kertas

Rp100.000




Rp50.000


Rp20.000




Rp10.000




Rp5.000



Rp2.000




Rp1.000




- **Outflow KPw Kediri**


Total Uang Kertas




Rp100.000



Rp50.000




Rp20.000




● **Outflow KPw Malang**



Total Uang Kertas



Rp100.000




Rp50.000




• *Inflow KPw Surabaya*


Total Uang Kertas




Rp100.000




Rp50.000




Rp20.000




Rp10.000




Rp5.000



Rp2.000




Rp1.000




• **Outflow KPw Surabaya**


Total Uang Kertas




Rp100.000



Rp50.000



Rp20.000





Lampiran 3. Output Hibrida ARIMAX-DNN

- Inflow KPw Jember**



Total Uang Kertas

Rp100.000





Rp50.000

Rp20.000




Rp10.000


Rp5.000




Rp2.000




Rp1.000




• **Outflow KPw Jember**
Total Uang Kertas




Rp100.000




Rp50.000




Rp20.000




Rp10.000




Rp5.000



Rp2.000




Rp1.000




• **Inflow KPw Kediri**


Total Uang Kertas




Rp100.000




Rp50.000




Rp20.000




Rp10.000




Rp5.000



Rp2.000




Rp1.000




• **Outflow KPw Kediri**

Total Uang Kertas




Error: 0.396318 Steps: 4197

Rp100.000




Error: 0.254385 Steps: 1162

Rp50.000




Error: 0.291787 Steps: 1982

Rp20.000




Error: 0.441384 Steps: 136

Rp10.000




Error: 0.233881 Steps: 1150

Rp5.000




Error: 0.089974 Steps: 1314

Rp2.000




Rp1.000




- Inflow KPw Malang**


Total Uang Kertas




Rp100.000




Rp50.000




Rp20.000




Rp10.000




Rp5.000




Rp2.000




Rp1.000




• **Outflow KPw Malang**
Total Uang Kertas




Rp100.000




Rp50.000




Rp20.000




Rp10.000




Rp5.000



Rp2.000




Rp1.000




• **Inflow KPw Surabaya**


Total Uang Kertas




Rp100.000




Rp50.000




Rp20.000




Rp10.000




Rp10.000



Rp2.000




Rp1.000




- Outflow di KPw Surabaya**


Total Uang Kertas




Rp100.000




Rp50.000




Rp20.000




Rp10.000




Rp5.000



Rp2.000



Rp1.000



Lampiran 4. Hasil Uji Nonlinier

• KPw Jember

	Pecahan	Lag	Chi-Sq	DF	P-Value	Kesimpulan
<i>Inflow</i>	Total	1,12	21,786	7	0,0027	Nonlinier
	100.000	1,12	21,601	7	0,0029	Nonlinier
	50.000	1,12	20,762	7	0,0041	Nonlinier
	20.000	12,24	83,961	7	0,0000	Nonlinier
	10.000	2,12	22,705	7	0,0019	Nonlinier
	5.000	12,23	59,02	7	0,0000	Nonlinier
	2.000	1,12	20,321	7	0,0049	Nonlinier
	1.000	1,12	35,879	7	0,0000	Nonlinier
<i>Outflow</i>	Total	1,12	19,149	7	0,0077	Nonlinier
	100.000	1,12	20,222	7	0,0051	Nonlinier
	50.000	1,12	21,176	7	0,0035	Nonlinier
	20.000	12,24	42,309	7	0,0000	Nonlinier
	10.000	10,12	57,723	7	0,0000	Nonlinier
	5.000	12,24	57,328	7	0,0000	Nonlinier
	2.000	12	10,515	2	0,0053	Nonlinier
	1.000	12,24	11,001	7	0,1386	Linier

• KPw Kediri

	Pecahan	Lag	Chi-Sq	DF	P-Value	Kesimpulan
<i>Inflow</i>	Total	1,12	29,792	7	0,0001	Nonlinier
	100.000	1,12	35,06	7	0,0000	Nonlinier
	50.000	1,12	22,841	7	0,0018	Nonlinier
	20.000	12,24	29,829	7	0,0001	Nonlinier
	10.000	2,12	19,525	7	0,0067	Nonlinier
	5.000	2,12	20,426	7	0,0047	Nonlinier
	2.000	1,12	23,236	7	0,0016	Nonlinier
	1.000	1,12	42,69	7	0,0000	Nonlinier
<i>Outflow</i>	Total	1,12	23,906	7	0,0012	Nonlinier
	100.000	1,12	21,104	7	0,0036	Nonlinier
	50.000	1,12	29,844	7	0,0001	Nonlinier
	20.000	12,24	44,061	7	0,0001	Nonlinier
	10.000	10,12	15,285	7	0,0325	Nonlinier
	5.000	12,34	56,561	7	0,0000	Nonlinier
	2.000	12,24	78,726	7	0,0000	Nonlinier
	1.000	12,24	23,981	7	0,0011	Nonlinier

- **KPw Malang**

	Pecahan	Lag	Chi-Sq	DF	P-Value	Kesimpulan
<i>Inflow</i>	Total	1,12	44,697	7	0,0000	Nonlinier
	100.000	1,12	38,364	7	0,0000	Nonlinier
	50.000	1,12	48,851	7	0,0000	Nonlinier
	20.000	12,21	21,264	7	0,0034	Nonlinier
	10.000	2,12	20,929	7	0,0039	Nonlinier
	5.000	1,12	20,71	7	0,0042	Nonlinier
	2.000	1,12	51,586	7	0,6406	Linier
	1.000	1,12	14,472	7	0,9841	Linier
<i>Outflow</i>	Total	1,12	19,13	7	0,0078	Nonlinier
	100.000	1,12	18,638	7	0,0094	Nonlinier
	50.000	1,12	23,018	7	0,0017	Nonlinier
	20.000	12,24	24,776	7	0,0008	Nonlinier
	10.000	10,12	16,051	7	0,0246	Nonlinier
	5.000	12,24	49,264	7	0,0000	Nonlinier
	2.000	12,34	93,104	7	0,0000	Nonlinier
	1.000	12,24	2,106	7	0,9537	Linier

- **KPw Surabaya**

	Pecahan	Lag	Chi-Sq	DF	P-Value	Kesimpulan
<i>Inflow</i>	Total	1,12	37,33	7	0,0000	Nonlinier
	100.000	1,12	40,14	7	0,0000	Nonlinier
	50.000	1,12	40,126	7	0,0000	Nonlinier
	20.000	1,12	55,141	7	0,0000	Nonlinier
	10.000	2,12	33,639	7	0,0000	Nonlinier
	5.000	2,12	28,142	7	0,0002	Nonlinier
	2.000	1,12	17,011	7	0,0173	Nonlinier
	1.000	1,12	39,336	7	0,0000	Nonlinier
<i>Outflow</i>	Total	1,12	40,997	7	0,0000	Nonlinier
	100.000	1,12	27,132	7	0,0003	Nonlinier
	50.000	1,12	39,871	7	0,0000	Nonlinier
	20.000	12,24	98,511	7	0,0000	Nonlinier
	10.000	12,23	43,696	7	0,0000	Nonlinier
	5.000	1,12	113,25	7	0,0000	Nonlinier
	2.000	1,12	94,986	7	0,0000	Nonlinier
	1.000	12,24	35,014	7	0,0000	Nonlinier

Lampiran 5. Syntax Program SAS Metode ARIMAX

```

data train;
input y t M_1 M_2 M_3 M_4 M_5 M_6 M_7 M_8 M_9 M_10 M_11
M_12 V1_t V1_t1 V2_t V2_t1 V3_t V3_t1 V4_t V4_t1;
datalines;
244.02965 1 1 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0
148.6623 2 0 1 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0
147.31215 3 0 0 1 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0
110.87285 4 0 0 0 1 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0
.
.
.
. 113 0 0 0 0 1 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0
. 114 0 0 0 0 0 1 0 0 0 0 0 0
1 0 0 0 0 0 0 0
;
proc arima data=train;
identify var=y(0) crosscorr=(t M_1 M_2 M_3 M_4 M_5 M_6 M_7
M_8 M_9 M_10 M_11 M_12 V1_t V1_t1 V2_t V2_t1 V3_t V3_t1
V4_t V4_t1) nlags=36;
run;
estimate p=(0) q=(0) input=(t M_1 M_2 M_3 M_4 M_5 M_6 M_7
M_8 M_9 M_10 M_11 M_12 V1_t V1_t1 V2_t V2_t1 V3_t V3_t1
V4_t V4_t1) noconstant method=cls;
forecast out=train lead=18 PRINTALL;
run;
proc univariate data=train normal;
var Residual;
run ;
proc export data=work.train
outfile='D:/A.TugasAkhir/BAB 4/JEMBER/ TOTAL_IJ.xls'
dbms=excel
replace;
run ;

```

Lampiran 6. Syntax Program R Metode DNN

```

library(neuralnet)
library(tseries)
library(forecast)
library(readxl)
data<-read_excel("D:/A.Tugas Akhir/BAB 4/JEMBER/DNN/DATA
DNN IJ.xlsx", sheet = "50K")
datat<-as.ts(data)
training<-as.ts(datat[1:96,])
testing<-as.ts(datat[97:114,])

ystd<-(training[,1]-min(training[,1]))/(max(training[,1])-
min(training[,1]))

#lag yang signifikan
lagyt<-c(1,2,5,6,12,35)
maxlag<-max(lagyt)
laginput<-matrix(NA,(length(ystd)-maxlag),length(lagyt))

for (j in 1:length(lagyt))
{
  laginput[,j]<-ystd[(maxlag-lagyt[j]+1):(length(ystd)-lagyt[j])]
}
head(laginput)

colnames(laginput)<-
c("Yt_1","Yt_2","Yt_5","Yt_6","Yt_12","Yt_35")
Yt<-ystd[(maxlag+1):length(ystd)]

TOTAL<-
data.frame(cbind(Yt,laginput,datat[(maxlag+1):length(ystd),-1]))
head(TOTAL)

#jumlah neuron
h1<-c(1,2,3,4,5)
h2<-c(1,2,3,4,5)
neuron<-cbind(rep(h1,times=length(h2)), rep(h2,each=length(h1)))
n_fore<-18
dummy1<-rbind((datat[(maxlag+1):length(ystd),-1]),testing[,-1])

```

```

koefisien=list()
bestmodel=list()
fitsmodel=list()
foremodel=list()
akurasi=list()

for (k in seq_along(neuron[,1]))
{
  set.seed(k)
  best.model<-
neuralnet(Yt~Yt_1+Yt_2+Yt_5+Yt_6+Yt_12+Yt_35+t+M_1+M_2
+M_3+M_4+M_5+M_6+M_7+M_8+M_9+M_10+M_11+M_12+V
1t+V1t1+V2t+V2t1+V3t+V3t1+V4t+V4t1,data=TOTAL,hidden=ne
uron[k,],stepmax = 1e+08,rep=10, act.fct = "logistic", linear.output
= TRUE, likelihood = TRUE)
  plot(best.model, rep="best")
  mypath<-file.path("D:/A.Tugas Akhir/BAB 4/JEMBER/DNN/
PLOT/50K IJ", paste("50K IJ",(k),".jpg",sep=""))
  png(file=mypath)
  plot(best.model,rep="best")
  dev.off()

  koefisien[[k]]<-
best.model$weight[which.min(best.model$result.matrix[1,])]

  ytesting<-c(TOTAL[,1],rep(0,n_fore))
for (l in ((length(TOTAL[,1])+1):(length(TOTAL[,1])+n_fore)))
{
  dummytesting<-t(as.matrix(dummy1[l,]))
  lagtesting<-matrix(0,1,length(lagyt))
  for (m in 1:length(lagyt))
  {
    lagtesting[[m]]<-ytesting[(l-lagyt[m])]
  }
  inputtesting<-cbind(lagtesting,dummytesting)
  ytesting[l]<-compute(best.model,covariate = inputtesting,
                      rep =
which.min(best.model$result.matrix[1,]))$net.result
}

```

```

fits.model<-
unlist(best.model$net.result[which.min(best.model$result.matrix[1,
]))*
  (max(training[,1])-min(training[,1]))+min(training[,1])
  NtTrain<-(TOTAL[,1]*(max(training[,1])-
min(training[,1]))+min(training[,1]))-

(unlist(best.model$net.result[which.min(best.model$result.matrix[1,
])))*
  (max(training[,1])-min(training[,1]))+min(training[,1]))
  AvgNtTrain<-(abs(TOTAL[,1]*(max(training[,1])-
min(training[,1]))+min(training[,1]))+
  abs(unlist(best.model$net.result)*(max(training[,1])-
min(training[,1]))+
  min(training[,1])))/2
  RMSETraining<-((sum(NtTrain^2))/length(NtTrain))^(1/2)

sMAPE1<-c()
for (p1 in 1:length(NtTrain))
{
  sMAPE1[p1]<-
(1/length(NtTrain))*abs(NtTrain[p1])/AvgNtTrain[p1]
}
sMAPETraining<-sum(sMAPE1)*100

fore.model<-
ytesting[(length(TOTAL[,1])+1):(length(TOTAL[,1])+n_fore)]*(ma
x(training[,1])-min(training[,1]))+min(training[,1])
  NtTest<-(testing[,1])-
(ytesting[(length(TOTAL[,1])+1):(length(TOTAL[,1])+n_fore)]*(m
ax(training[,1])-min(training[,1]))+min(training[,1]))
  AvgNtTest<-
(abs(testing[,1])+abs(ytesting[(length(TOTAL[,1])+1):(length(TOT
AL[,1])+n_fore)]*(max(training[,1])-
min(training[,1]))+min(training[,1])))/2)
  RMSETesting<-((sum(NtTest^2))/length(NtTest))^(1/2)

```



```
sMAPE2<-c()
for (p2 in 1:length(NtTest))
{
  sMAPE2[p2]<-
(1/length(NtTest))*abs(NtTest[p2])/AvgNtTest[p2]
}
sMAPETesting<-sum(sMAPE2)*100

fitsmodel[[k]]<-fits.model
foremodel[[k]]<-fore.model
akurasi[[k]]<-
rbind(RMSETraining,RMSETesting,sMAPETraining,sMAPETesting)
}

write.csv(akurasi,"D:/A.Tugas Akhir/BAB4/JEMBER/DNN/
OUTPUT/50K_IJ_Akurasi.csv")
write.csv(fitsmodel,"D:/A.Tugas Akhir/BAB4/JEMBER/DNN/
OUTPUT/50K_IJ_Fits.csv")
write.csv(foremodel,"D:/A.Tugas Akhir/BAB 4/JEMBER/DNN/
OUTPUT/50K_IJ_Fore.csv")
saveRDS(koefisien,file = "D:/A.Tugas Akhir/BAB4/JEMBER/DNN
/KOEF/50K_IJ_Koef.rds")
```

Lampiran 7. Syntax Program R Metode Hibrida ARIMAX-DNN

```

library(neuralnet)
library(tseries)
library(forecast)
library(readxl)
data <- read_excel("D:/A.Tugas Akhir/BAB
4/JEMBER/HIBRID/DATA HIBRID I.xlsx",
sheet = "50K")
datat<-as.ts(data)
training<-as.matrix(as.ts(datat[1:96,]))
testing<-as.matrix(as.ts(datat[97:114,]))
resitrain<-as.matrix(as.ts(training[,1]-training[,2]))
resinorm<-((resitrain-min(resitrain))/(max(resitrain)-min(resitrain)))

tick=c(1,12,24,36)
par(mfrow=c(2,1),mar=c(2.8,3,1.2,0.4)) #the number of picture and
its margin
par(mgp=c(1.7,0.5,0)) #the distance between labels and
axis
#ACF
acf(resitrain,lag.max=36,axes=F,ylim=c(-1,1))
box()
axis(side=1,at=tick,label=tick,lwd=0.5,las=0,cex.axis=0.8)
abline(v=tick,lty="dotted", lwd=2, col="grey")
axis(side=2,lwd=0.5,las=2,cex=0.5,cex.axis=0.8)
#PACF
pacf(resitrain,lag.max=36,axes=F,ylim=c(-1,1))
box()
axis(side=1,at=tick,label=tick,lwd=0.5,las=0,cex.axis=0.8)
abline(v=tick,lty="dotted", lwd=2, col="grey")
axis(side=2,lwd=0.5,las=2,cex=0.5,cex.axis=0.8)

#lag yang signifikan
lagresi<-c(1)
maxlag<-max(lagresi)
laginput<-matrix(NA,(length(resinorm)-maxlag),length(lagresi))

```

```

for (j in 1:length(lagresi))
{
  laginput[,j]<-resinorm[(maxlag-lagresi[j]+1):(length(resinorm)-
lagresi[j])]
}
head(laginput)

colnames(laginput)<-c("at_1")
Et<-resinorm[(maxlag+1):length(resinorm)]

TOTAL<-data.frame(cbind(Et,laginput))
head(TOTAL)

#jumlah neuron
h1<-c(1,2,3,4,5)
h2<-c(1,2,3,4,5)
neuron<-cbind(rep(h1,times=length(h2)), rep(h2,each=length(h1)))
n_fore<-18

koefisien=list()
bestmodel=list()
fitsmodel=list()
fitsresi=list()
foreresi=list()
foremodel=list()
akurasi=list()

for (k in seq_along(neuron[,1]))
{
  set.seed(k)
  best.model<-neuralnet(at~at_1,
data=TOTAL,hidden=neuron[k,],stepmax = 1e+08,rep=10,
act.fct = "logistic", linear.output = TRUE, likelihood
= TRUE)
  plot(best.model, rep="best")
  mypath<-file.path("D:/A.Tugas Akhir/BAB 4/JEMBER/
HIBRID/PLOT/50K I", paste("50K I",(k)," .jpg",sep=""))

```

```

png(file=mypath)
plot(best.model,rep="best")
dev.off()

koefisien[[k]]<-
best.model$weight[which.min(best.model$result.matrix[1,])]

ytesting<-c(TOTAL[,1],rep(0,n_fore))

for (l in ((length(TOTAL[,1])+1):(length(TOTAL[,1])+n_fore)))
{
  lagtesting<-matrix(0,1,length(lagresi))
  for (m in 1:length(lagresi))
  {
    lagtesting[[m]]<-ytesting[(l-lagresi[m])]
  }
  inputtesting<-lagtesting
  ytesting[l]<-compute(best.model,covariate = inputtesting,
                     rep
                     =
                     which.min(best.model$result.matrix[1,]))$net.result
}
fits.model<-
unlist(best.model$net.result[which.min(best.model$result.matrix[1,]
)])*
(max(resitrain)-min(resitrain))+min(resitrain)
fits.hibrid<-
training[(maxlag+1):length(training[,1]),2]+unlist(best.model$net.re
sult[which.min(best.model$result.matrix[1,])])*
(max(resitrain)-min(resitrain))+min(resitrain)

NtTrain<--(training[(maxlag+1):length(training[,1]),1])-
(training[(maxlag+1):length(training[,1]),2]+

(unlist(best.model$net.result)*(max(resitrain)-
min(resitrain))+(min(resitrain))))
AvgNtTrain<--(abs((training[(maxlag+1):length(training[,1]),1]))+
abs((training[(maxlag+1):length(training[,1]),2]+(unlist(best.model$
net.result)*

```

```

RMSETraining<-((sum(NtTrain^2))/length(NtTrain))^(1/2)

sMAPE1<-c()
for (p1 in 1:length(NtTrain))
{
  sMAPE1[p1]<-
(1/length(NtTrain))*abs(NtTrain[p1])/AvgNtTrain[p1]
}
sMAPETraining<-sum(sMAPE1)*100

fore.model<-
ytesting[(length(TOTAL[,1])+1):(length(TOTAL[,1])+n_fore)]*(max(
resitrain)-min(resitrain))
+min(resitrain)
fore.hibrid<-
testing[,2]+(ytesting[(length(TOTAL[,1])+1):(length(TOTAL[,1])+
n_fore)]*(max(resitrain)-min(resitrain))+min(resitrain))
NtTest<-testing[,1]-
(testing[,2]+ytesting[(length(TOTAL[,1])+1):(length(TOTAL[,1])+
n_fore)]*(max(resitrain)-min(resitrain))+min(resitrain))
AvgNtTest<-
(abs(testing[,1])+abs((testing[,2]+ytesting[(length(TOTAL[,1])+1):
length(TOTAL[,1])+n_fore)]*(max(resitrain)-
min(resitrain))+min(resitrain))))/2
RMSETesting<-((sum(NtTest^2))/length(NtTest))^(1/2)

sMAPE2<-c()
for (p2 in 1:length(NtTest))
{
  sMAPE2[p2]<-
(1/length(NtTest))*abs(NtTest[p2])/AvgNtTest[p2]
}
sMAPETesting<-sum(sMAPE2)*100
fitsmodel[[k]]<-fits.hibrid
foreresi[[k]]<-fore.model
foremodel[[k]]<-fore.hibrid
akurasi[[k]]<-
rbind(sMAPETraining,RMSETraining,sMAPETesting,RMSETestin
g)

```

```
write.csv(akurasi,"D:/A.Tugas Akhir/BAB 4/JEMBER/HIBRID/  
OUTPUT/50K I AKURASI.csv")  
write.csv(fitsmodel,"D:/A.Tugas Akhir/BAB 4/JEMBER/HIBRID/  
OUTPUT/50K I FITS.csv")  
write.csv(foremodel,"D:/A.Tugas Akhir/BAB 4/JEMBER/HIBRID/  
OUTPUT/50K I FORE.csv")  
saveRDS(koefisien,file = "D:/A.Tugas Akhir/BAB4/JEMBER/  
HIBRID/KOEF/50K I KOEF.rds")
```

Lampiran 8 Surat Keterangan Data Instansi**SURAT PERNYATAAN**

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FSAD ITS:

Nama : Jemima Arista Putri

NRP : 06211640000022

menyatakan bahwa data yang digunakan dalam Tugas Akhir ini merupakan data sekunder yang diambil dari:

Sumber : Bank “X”

Keterangan : Data *Inflow* dan *Outflow* di Jawa Timur

Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Mengetahui

Pembimbing Tugas Akhir



Dr. Suhartono, S.Si., M.Sc.

NIP. 19710929 199512 1 001

Surabaya, 14 Juni 2020



Jemima Arista Putri

NRP. 06211640000022

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Penulis dengan nama lengkap Jemima Arista Putri memiliki nama panggilan Jemima merupakan anak pertama dari tiga bersaudara yang dilahirkan di Banyuwangi pada tanggal 22 Mei 1998. Pendidikan yang telah ditempuh oleh penulis adalah SDN 1 Lateng, SMPN 1 Banyuwangi dan SMAN 1 Glagah. Kemudian penulis diterima sebagai Mahasiswa Departemen Statistika Institut Teknologi Sepuluh

Nopember melalui jalur SNMPTN pada tahun 2016 dengan NRP 06211640000022. Selama masa perkuliahan, penulis aktif di beberapa organisasi yakni sebagai staff departemen kewirausahaan HIMASTA-ITS 17/18, staff hubungan luar KSE ITS 17/18 dan sekertaris departemen kewirausahaan 18/19. Selain itu penulis juga aktif dalam mengikuti kepanitiaan, beberapa kepanitiaan yang diikuti penulis yaitu LO kegiatan GERIGI ITS 2017 dan Tim Soal Pekan Raya Statistika (PRS) 2017 maupun 2018. Pada bidang akademik penulis diberi kesempatan untuk menjadi finalis pada beberapa lomba analisis data yang diadakan oleh UB, IPB, UNMUL, UNS, UNDIP, BINUS, UGM dan lomba infografis yang diadakan oleh UNAIR. Penulis berkesempatan menjadi asisten dosen pada mata kuliah Pengenalan Ilmu Komputer, Program Komputer, Komputasi Statistika dan Komputasi Aktuaria. Ketika masa perkuliahan, penulis mendapat beasiswa dari beberapa pihak, yaitu oleh Alumni Statistika, Karya Salemba Empat dan READI. Pada masa perkuliahan, penulis berkesempatan menjalani program *internship* di Badan Meteorologi, Klimatologi dan Geofisika (BMKG) Pusat Jakarta dan di SDG's Research Center ITS serta beberapa kali mengikuti kegiatan survey. Apabila pembaca ingin memberi kritik dan saran mengenai Tugas Akhir, dapat menghubungi penulis melalui email jemima.arista@gmail.com.

(Halaman ini sengaja dikosongkan)