



---

TESIS - SS142501

# **PENGEMBANGAN RAMALAN INTERVAL PADA MODEL GSTARX UNTUK PERAMALAN INDEKS HARGA KONSUMEN KELOMPOK BAHAN MAKANAN**

RISMA HAPSARI  
NRP. 1315 201 704

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

PROGRAM MAGISTER  
JURUSAN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2017





THESIS - SS142501

# INTERVAL PREDICTION GSTARX MODEL ON FORECASTING CONSUMER PRICE INDEX OF FOODS

RISMA HAPSARI  
NRP. 1315 201 704

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

MAGISTER PROGRAM  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS AND NATURAL SCIENCE  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2017



**PENGEMBANGAN RAMALAN INTERVAL PADA MODEL  
GSTARX UNTUK PERAMALAN INDEKS HARGA  
KONSUMEN KELOMPOK BAHAN MAKANAN**

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar

Magister Sains (M.Si)

di

Institut Teknologi Sepuluh Nopember

Oleh :

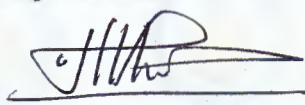
**RISMA HAPSARI**

**NRP. 1315 201 704**

Tanggal Ujian : 4 Januari 2017

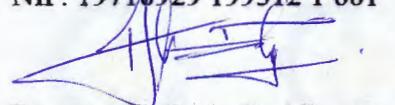
Periode Wisuda : Maret 2017

Disetujui Oleh :



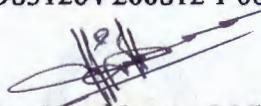
1. Dr. Suhartono, M.Sc.  
NIP. 19710929 199512 1 001

(Pembimbing I)



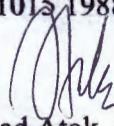
2. Dr. rer. pol. Dedy Dwi Prastyo, M.Si.  
NIP. 19831204 200812 1 002

(Pembimbing II)



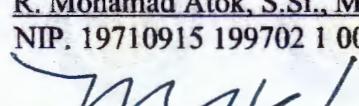
3. Prof. Drs. Nur Iriawan, M.Ikom., Ph.D.  
NIP. 19621015 198803 1 002

(Pengaji)



4. R. Mohamad Atok, S.Si., M.Si., Ph.D.  
NIP. 19710915 199702 1 001

(Pengaji)



5. Dr. Heru Margono, M.Sc.  
NIP. 19610214 198312 1 001

(Pengaji)

an. Direktur Program Pascasarjana  
Asisten Direktur

Direktur Program Pascasarjana,



Prof. Dr. Ir. Tri Widjaja, M.Eng.  
NIP 19610214 198603 1 001

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



# **PENGEMBANGAN RAMALAN INTERVAL PADA MODEL GSTARX UNTUK PERAMALAN INDEKS HARGA KONSUMEN KELOMPOK BAHAN MAKANAN**

Nama : Risma Hapsari  
NRP : 1315201704  
Pembimbing : Dr. Suhartono, M.Sc.  
Co Pembimbing : Dr. rer. pol. Dedy Dwi Prastyo, M.Si.

## **ABSTRAK**

Indeks Harga Konsumen (IHK) adalah indeks yang digunakan untuk mengukur perubahan harga pada sekelompok barang dan jasa yang dikonsumsi oleh rumah tangga pada periode tertentu. IHK bahan makanan termasuk komponen yang mudah bergejolak, artinya dominan dipengaruhi oleh *shocks* seperti gangguan alam dan perkembangan harga komoditas internasional. Pemodelan untuk peramalan IHK yang melibatkan aspek waktu dan lokasi (*spatio temporal*) dapat menggunakan *Generalized Space Time Autoregressive* (GSTAR). Untuk menambah akurasi dalam peramalan, model GSTAR dikembangkan menjadi model GSTARX dengan melibatkan variabel eksogen. Variabel eksogen yang digunakan dalam pemodelan GSTARX untuk peramalan IHK ini adalah kejadian Idul Fitri yang merupakan efek variasi kalender, kejadian bencana alam, dan kenaikan harga BBM. Studi kasus dalam pemodelan GSTARX ini diterapkan untuk peramalan IHK lima kota di Sumatera, yaitu Padang, Pekanbaru, Jambi, Palembang, dan Bengkulu. Tujuan penelitian ini adalah untuk mendapatkan model GSTARX yang sesuai untuk peramalan IHK kelompok bahan makanan lima kota di Sumatera, dan melakukan pengembangan peramalan interval, sehingga hasil ramalannya bisa dijadikan informasi awal bagi pemerintah dalam menentukan kebijakan. Analisis data *time series* menunjukkan model ARIMA dan GSTAR dengan penambahan variabel eksogen (variasi kalender dan intervensi kenaikan BBM dan bencana) akan memperkecil nilai RMSE yang berarti, permodelan semakin baik dibandingkan model tanpa variabel eksogen. Model terbaik pada GSTARX yaitu dengan bobot normalisasi inferensi parsial korelasi silang tidak menunjukkan adanya keterkaitan dengan wilayah lain. Hal tersebut berarti, pada fenomena harga bahan makanan di Pulau Sumatera tidak terbukti terdapat keterkaitan suatu lokasi dengan lokasi yang lain.

**Kata kunci :** GSTARX, IHK, *spatio temporal*, *time series*, ramalan interval



# **INTERVAL PREDICTION IN GSTARX MODEL FOR CONSUMER PRICES INDICES OF FOODS**

Name : Risma Hapsari  
NRP : 1315201704  
Supervisor : Dr. Suhartono, M.Sc.  
Co Supervisor : Dr. rer. pol. Dedy Dwi Prastyo, M.Si.

## **ABSTRACT**

Consumer Price Index (CPI) is an index used to measure the average change in prices in the group of goods and services consumed by households in a certain period. CPI is a monthly time series data are also influenced by aspects between locations. This is possible because there is a correlation between regions in meeting the needs of the goods / services of particular goods / services which cannot be produced. CPI according to the Foodstuffs group is one of the seven CPI according to commodity. CPI food ingredients including volatile components, it is meaning predominantly influenced by shocks such as natural disturbances and the development of international commodity prices. Modeling for forecasting CPI involving aspects of time and location (spatio temporal) can use the Generalized Space Time Autoregressive (GSTAR). To increase accuracy in forecasting, GSTAR developed into a model GSTARX involving exogenous variables. Exogenous variables used in modeling for forecasting CPI GSTARX are calendar variations, natural disasters, and rising fuel prices. The case studies in this GSTARX modeling applied to forecast the CPI five cities in Sumatra, i.e. Padang, Pekanbaru, Jambi, Palembang, and Bengkulu. The purpose of this study is to obtain appropriate GSTARX models for forecasting CPI foods five cities in Sumatra, and developing forecasting interval, so that the results can be used as preliminary information of his predictions for the government in determining policies. Analysis time series data shows that ARIMA and GSTAR models with exogenous variables (calendar variation and the increase of fuel and disaster interventions) will minimize RMSE values which means, modeling better than the model without exogenous variables. Analysis GSTARX GLS models with a normalization inference partial of cross correlation does not show any linkage with other regions. That means, the phenomenon of high food prices on the island of Sumatra did not prove there is a link one location to another.

**Key Words :** *GSTARX, IHK, spatio temporal, time series, interval prediction*



## KATA PENGANTAR

Alhamdulillah, segala puji bagi Allah SWT, Tuhan Yang Maha Pengasih lagi Maha Penyayang, yang telah melimpahkan ilmu, kesehatan, bimbingan, rahmat dan hidayah-Nya sehingga dengan izin-Nya penyusunan tesis dengan judul “Pengembangan Ramalan Interval pada Model GSTARX untuk Peramalan Indeks Harga Konsumen Kelompok Bahan Makanan” dapat diselesaikan.

Selesainya tesis ini tidak terlepas dari bimbingan, arahan, bantuan baik moral maupun material serta do'a tulus dan ikhlas dari berbagai pihak. Pada kesempatan ini penulis ingin menyampaikan ucapan terima kasih dan penghargaan yang setinggi-tingginya kepada:

1. Badan Pusat Statistik yang telah memberi kesempatan serta beasiswa kepada penulis untuk melanjutkan studi program S2 Statistika di ITS.
2. Bapak Dr. Suhartono selaku pembimbing dan Ketua Jurusan Statistika, FMIPA ITS yang telah meluangkan banyak waktu untuk memberikan bimbingan, arahan dan petunjuk dalam menyelesaikan tesis ini dengan berbagai keterbatasan penulis.
3. Bapak Dr. rer. pol. Dedy Dwi Prastyo, M.Si selaku pembimbing yang telah meluangkan banyak waktu untuk memberikan bimbingan, arahan dan petunjuk dalam menyelesaikan tesis ini.
4. Bapak Prof. Drs. Nur Iriawan, M.Ikom., Ph.D., Bapak R. Mohamad Atok, S.Si., M.Si., Ph.D., dan Bapak Dr. Heru Margono, M.Sc. selaku penguji yang telah banyak memberikan saran dan koreksi atas penulisan tesis ini serta Bapak Dr. Ir. Setiawan, M.S. selaku validator tesis.
5. Bapak Dr.rer.pol. Heri Kuswanto, M.Si selaku Kaprodi Pascasarjana Statistika ITS atas segala arahan dan bimbingan yang telah diberikan selama proses studi. Bapak Dr. Wahyu Wibowo, S.Si., M.Si. selaku dosen wali penulis selama menuntut ilmu di ITS. Serta Bapak dan Ibu dosen Statistika ITS yang telah mencerahkan ilmu dan pengalamannya selama proses studi dan seluruh staff jurusan Statistika, FMIPA ITS yang telah memberikan fasilitas selama proses studi.

6. Bapak, Ibu, adik (Lisa Indraswari), serta seluruh keluarga besar atas segala do'a dan dukungan sehingga penulis berhasil menyelesaikan studi dengan baik.
7. Teristimewa, suami tercinta, Budi Hartono, terima kasih atas segala do'a, dukungan, dan cintanya. Anak-anakku tersayang, Sunshine Mumtazia Jasmine dan Arawinda Neil Isy Karima atas pengertian dan dukungannya. Do'a dan harapan terbaik selalu untuk kalian.
8. Teman seperjuangan *Time Series*, Mas Agung dan Dik Harniaty, terima kasih yang sebesar-besarnya atas segala bantuan dan pertemanan yang menyenangkan ini. Serta Bapak Muhammad Sjahid Akbar, S.Si., M.Si. atas segala bantuan dan *sharing* ilmunya.
9. Temen-temen seperjuangan Batch 9 BPS, Mbak Mety, Mbak Nunik, Ervin, Irva, dan Mbak Efrilla (ARH48) atas segala bantuan, semangat, dan pengertiannya. Mas Arif, Bang Node, Suko, Bayu, Leman, Mas Benk, Mas Dinu, Mbak Kiki, Mbak Ayu, Mbak Ika, Tiara, Mbak Dewi yang telah bersama-sama dan saling memotivasi selama menempuh pendidikan. Semoga kita dapat berjumpa lagi di lain kesempatan dan senantiasa sukses.
10. Semua pihak yang telah membantu penyelesaian tesis ini.

Aakhirnya, do'a dan harapan selalu dipanjatkan kepada Allah SWT agar ilmu yang telah diperoleh menjadi barokah dan bermanfaat bagi sesama serta dapat menjadi sarana meraih ridho Allah. Aamiin Ya Robbal 'Alamin.

Surabaya, Januari 2017

**Penulis**

## DAFTAR ISI

<b>ABSTRAK .....</b>	<b>iii</b>
<b>ABSTRACT .....</b>	<b>v</b>
<b>KATA PENGANTAR.....</b>	<b>vii</b>
<b>DAFTAR ISI.....</b>	<b>ix</b>
<b>DAFTAR TABEL .....</b>	<b>xiii</b>
<b>DAFTAR GAMBAR.....</b>	<b>xvii</b>
<b>DAFTAR LAMPIRAN .....</b>	<b>xix</b>
<b>BAB 1 PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah.....	7
1.3 Tujuan Penelitian .....	7
1.4 Manfaat Penelitian .....	7
1.5 Batasan Masalah .....	8
<b>BAB 2 TINJAUAN PUSTAKA .....</b>	<b>9</b>
2.1 Model ARIMA.....	9
2.1.1 Identifikasi Model ARIMA.....	11
2.1.2 Estimasi dan Uji Signifikansi Parameter.....	13
2.1.3 Cek Diagnosa Model.....	15
2.1.4 Peramalan ARIMA.....	17
2.2 Model Intervensi .....	19
2.3 Variasi Kalender .....	22
2.4 Multivariat <i>Time Series</i> .....	24
2.4.1 <i>Vector Autoregressive Integrated Moving Average</i> (VARIMA).....	25
2.4.2 <i>Vector Autoregressive Moving Average with Exogenous Variable</i> (VARMAX) .....	25
2.4.3 <i>Matrix Cross Correlation Function</i> (MCCF) .....	26
2.4.4 <i>Matrix Partial Cross Correlation Function</i> (MPCCF).....	27
2.4.5 Estimasi Parameter Model VARIMA .....	29

2.4.6	Akaike's Information Criterion (AIC).....	30
2.4.7	Cek Diagnosa Model .....	31
2.4.8	Pemilihan Model Terbaik .....	31
2.5	Model <i>Generalized Space Time Autoregressive</i> (GSTAR).....	32
2.5.1	Penentuan Bobot Lokasi pada Model GSTAR.....	34
2.5.2	Estimasi Parameter Model GSTAR.....	39
2.5.3	Cek Diagnosa Model .....	45
2.5.4	Kriteria Pemilihan Model Terbaik.....	45
2.5.5	Peramalan Model GSTAR.....	46
2.6	Indeks Harga Konsumen (IHK) .....	48
2.6.1	Pengertian IHK .....	48
2.6.2	Penghitungan IHK .....	50
2.7	Bencana Alam .....	51
<b>BAB 3</b>	<b>METODOLOGI PENELITIAN.....</b>	<b>53</b>
3.1	Sumber Data .....	53
3.2	Variabel Penelitian .....	53
3.3	Metode Analisis.....	56
3.3.1	Pemodelan ARIMA .....	56
3.3.2	Pemodelan Variasi Kalender .....	56
3.3.3	Analisis Intervensi .....	57
3.3.4	Pemodelan GSTAR .....	58
3.3.5	Pemodelan GSTARX .....	59
<b>BAB 4</b>	<b>HASIL DAN PEMBAHASAN.....</b>	<b>63</b>
4.1	Karakteristik Data IHK di Sumatera .....	63
4.2	Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan di Sumatera.....	67
4.2.1	Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan Kota Padang.....	72
4.2.2	Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan Kota Pekanbaru .....	77
4.2.3	Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan Jambi.....	82

4.2.4 Pemodelan ARIMA pada IHK Kelompok Bahan Makanan Palembang.....	86
4.2.5 Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan Bengkulu .....	90
4.3 Pemodelan Data IHK Kelompok Bahan Makanan Sumatera menggunakan GSTAR-GLS .....	93
4.4 Pemodelan Data IHK Kelompok Bahan Makanan Sumatera Menggunakan GSTARX-GLS .....	102
4.4.1 Pemodelan Tahap Pertama.....	102
4.4.2 Pemodelan Tahap Kedua dengan Model GSTARX.....	103
4.4.3 Pemodelan GSTARX .....	112
4.4.4 Cek Diagnosa Model GSTARX.....	113
4.5 Pemilihan Model Terbaik pada Model .....	114
4.6 Peramalan pada Model GSTARX.....	119
<b>BAB 5 KESIMPULAN DAN SARAN .....</b>	<b>123</b>
5.1 Kesimpulan .....	123
5.2 Saran .....	123
<b>DAFTAR PUSTAKA .....</b>	<b>125</b>
<b>LAMPIRAN.....</b>	<b>131</b>
<b>BIOGRAFI PENULIS .....</b>	<b>177</b>



## DAFTAR TABEL

Tabel 2.1	Nilai Transformasi Box Cox .....	12
Tabel 2.2	Karakteristik teoritis ACF dan PACF .....	13
Tabel 2.3	Contoh Jarak dari Tiga Lokasi .....	36
Tabel 3.1	Struktur Data Deret Output .....	53
Tabel 3.2	Variabel <i>Dummy</i> Hari Raya Idul Fitri .....	55
Tabel 4.1	Statistik Deskriptif Data IHK Kelompok Bahan Makanan Lima Kota di Sumatera Tahun 2000-2014 .....	63
Tabel 4.2	Nilai Korelasi Data IHK Kelompok Bahan Makanan di Sumatera.....	65
Tabel 4.3	Jarak Tempuh Kendaraan dengan Jalur Darat Antar Lokasi Kota-kota di Sumatera.....	66
Tabel 4.4	Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Padang .....	72
Tabel 4.5	Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Padang .....	73
Tabel 4.6	Hasil Pengujian Residual <i>White Noise</i> Model ARIMA data IHK Kelompok Bahan Makanan Kota Padang .....	73
Tabel 4.7	Hasil Estimasi Parameter Model Variasi Kalender Kota Padang .....	74
Tabel 4.8	Hasil Estimasi Parameter Model Intervensi Kota Padang .....	75
Tabel 4.9	Hasil Estimasi Parameter Model ARIMAX Kota Padang .....	76
Tabel 4.10	Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Pekanbaru .....	78
Tabel 4.11	Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Pekanbaru .....	79
Tabel 4.12	Hasil Pengujian Residual <i>White Noise</i> Model ARIMA Data IHK Kelompok Bahan Makanan Kota Pekanbaru .....	79
Tabel 4.13	Hasil Estimasi Parameter Model Variasi Kalender Kota Pekanbaru .....	80
Tabel 4.14	Hasil Estimasi Parameter Model Intervensi Kota Pekanbaru .....	81
Tabel 4.15	Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Jambi .....	83

Tabel 4.16 Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Jambi.....	84
Tabel 4.17 Hasil Pengujian Residual <i>White Noise</i> Model ARIMA data IHK Kelompok Bahan Makanan Kota Jambi .....	84
Tabel 4.18 Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Palembang.....	87
Tabel 4.19 Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Palembang.....	87
Tabel 4.20 Hasil Pengujian Residual <i>White Noise</i> Model ARIMA data IHK Kelompok Bahan Makanan Kota Palembang.....	88
Tabel 4.21 Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Bengkulu.....	90
Tabel 4.22 Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Bengkulu .....	91
Tabel 4.23 Hasil Pengujian Residual <i>White Noise</i> Model ARIMA data IHK Kelompok Bahan Makanan Kota Bengkulu .....	91
Tabel 4.24 Model VARIMA dan AICC .....	94
Tabel 4.25 Hasil Estimasi Parameter Model GSTAR-GLS $(1,12_1)$ menggunakan Bobot Seragam .....	95
Tabel 4.26 Hasil Estimasi Parameter Model GSTAR-GLS $(1,12_1)$ Menggunakan Bobot Invers Jarak .....	98
Tabel 4.27 Hasil Estimasi Parameter Model GSTAR-GLS $(1,12_1)$ Menggunakan Bobot Normalisasi Inferensi Parsial Korelasi Silang .....	101
Tabel 4.28 Model VARIMA dan AICC .....	104
Tabel 4.29 Hasil Estimasi Parameter Model GSTARX-GLS $(1,12_1)$ menggunakan Bobot Seragam .....	106
Tabel 4.30 Hasil Estimasi Parameter Model GSTARX-GLS $(1,12_1)$ menggunakan Bobot Invers Jarak.....	108
Tabel 4.31 Hasil Estimasi Parameter Model GSTARX-GLS $(1,12_1)$ Menggunakan Normalisasi Inferensi Parsial Korelasi Silang .....	111
Tabel 4.32 Nilai AIC Residual Model GSTARX Berdasarkan Jenis Bobot Lokasi pada Data IHK Kelompok Bahan Makanan di Sumatera....	113

Tabel 4.33 Nilai <i>P-Value</i> Uji Kolmogorov Smirnov Residual GSTARX .....	114
Tabel 4.34 Nilai RMSE <i>In-Sample</i> Hasil Pemodelan ARIMA dan ARIMAX pada Data IHK Kelompok Bahan Makanan Lima Kota di Sumatera.....	114
Tabel 4.35 Nilai RMSE <i>In-Sample</i> Hasil Pemodelan GSTAR dan GSTARX pada Data IHK Kelompok Bahan Makanan Lima Kota di Sumatera.....	115
Tabel 4.36 Nilai RMSE <i>Out-Sample</i> Model ARIMA, ARIMAX, GSTAR, dan GSTARX pada Data IHK Kelompok Bahan Makanan Lima Kota di Sumatera .....	116



## DAFTAR GAMBAR

Gambar 2.1	Prosedur <i>Box-Jenkins</i> untuk Pembentukan Model ARIMA.....	10
Gambar 2.2	Respon terhadap <i>Step</i> dan <i>Pulse Input</i> .....	21
Gambar 2.3	Contoh Peta Tiga Lokasi .....	35
Gambar 2.4	Terjadinya <i>Supply Shock</i> pada Kurva Penawaran dan Permintaan.....	52
Gambar 3.1	Diagram Alir Analisis GSTARX.....	61
Gambar 4.1	Plot <i>Time Series</i> Data IHK Kelompok Bahan Kakanan Lima Kota di Sumatera .....	64
Gambar 4.2	Peta Lokasi Penelitian di Lima Kota IHK di Sumatera.....	66
Gambar 4.3	Plot Box-Cox Data IHK Kelompok Bahan Makanan .....	67
Gambar 4.4	Plot <i>Time Series</i> dan Plot ACF Data IHK Transformasi .....	69
Gambar 4.5	Boxplot dan Plot ACF Data IHK <i>Differencing 1</i> .....	70
Gambar 4.6	Boxplot Data IHK <i>Differencing 12</i> .....	71
Gambar 4.7	Plot ACF dan PACF data IHK Kota Padang.....	72
Gambar 4.8	RMSE <i>In-Sample</i> dan <i>Out-Sample</i> IHK di Kota Padang .....	76
Gambar 4.9	Hasil Ramalan Model Univariat IHK Kota Padang .....	77
Gambar 4.10	Plot ACF dan PACF Data IHK Kota Pekanbaru.....	78
Gambar 4.11	RMSE <i>In-Sample</i> dan <i>Out-Sample</i> IHK di Kota Pekanbaru .....	82
Gambar 4.12	Hasil Ramalan Model Univariat IHK Kota Pekanbaru .....	82
Gambar 4.13	Plot ACF dan PACF Data IHK Kota Jambi .....	83
Gambar 4.14	RMSE <i>In-Sample</i> dan <i>Out-Sample</i> IHK di Kota Jambi .....	85
Gambar 4.15	Hasil Ramalan Model Univariat IHK Kota Jambi .....	86
Gambar 4.16	Plot ACF dan PACF Data IHK Kota Palembang .....	86
Gambar 4.17	RMSE <i>In-Sample</i> dan <i>Out-Sample</i> IHK di Kota Palembang .....	89
Gambar 4.18	Hasil Ramalan Model Univariat IHK Kota Palembang .....	89
Gambar 4.19	Plot ACF dan PACF Data IHK Kota Bengkulu .....	90
Gambar 4.20	RMSE <i>In-Sample</i> dan <i>Out-Sample</i> IHK di Kota Bengkulu .....	92
Gambar 4.21	Hasil Ramalan Model Univariat IHK Kota Bengkulu .....	93
Gambar 4.22	Plot MCCF Residual di Lima Lokasi .....	93

Gambar 4.23	Plot MCCF data IHK Kelompok Bahan Makanan di Lima Lokasi.....	100
Gambar 4.24	Plot MCCF Residual di Lima Lokasi.....	103
Gambar 4.25	Plot MPCCF Residual di Lima Lokasi .....	104
Gambar 4.26	Plot MCCF Residual dari Pemodelan GSTAR Tahap 1 .....	110
Gambar 4.27	Nilai RMSE <i>Out-Sample</i> untuk <i>k-Step</i> pada Lima Kota di Sumatera .....	119
Gambar 4.28	Peramalan <i>Out-Sample</i> IHK Kelompok Bahan Makanan Model GSTARX dengan Bobot NIPKS .....	120

## DAFTAR LAMPIRAN

Lampiran 1.	Syntax ARIMA .....	131
Lampiran 2.	Estimasi Parameter Model ARIMA .....	135
Lampiran 3.	Syntax Variasi Kalender .....	138
Lampiran 4.	Hasil Estimasi Parameter Model Variasi Kalender .....	143
Lampiran 5.	Syntax Model Intervensi .....	147
Lampiran 6.	Output Estimasi Parameter Intervensi .....	150
Lampiran 7.	Syntax ARIMAX .....	152
Lampiran 8.	Output Estimasi Parameter ARIMAX.....	155
Lampiran 9.	Output GSTAR Bobot Seragam .....	158
Lampiran 10.	Output GSTAR Bobot Invers Jarak.....	159
Lampiran 11.	Output GSTAR Bobot Normalisasi Inferensi Parsial Korelasi Silang.....	160
Lampiran 12.	Output SAS Hasil Estimasi Parameter Model GSTARX-GLS Tahap 1 .....	161
Lampiran 13.	Output SAS Hasil Estimasi Parameter Model GSTARX-GLS Bobot Seragam .....	163
Lampiran 14.	Output SAS Hasil Estimasi Parameter Model GSTARX-GLS Bobot Invers Jarak .....	164
Lampiran 15.	Program SAS Model GSTARX SUR (1,12 <sub>1</sub> ) dengan Bobot Normalisasi Inferensi Korelasi Parsial Silang Variabel yang Signifikan .....	165
Lampiran 16.	Output SAS Hasil Estimasi Parameter Model GSTARX-GLS Bobot Normalisasi Inferensi Parsial Korelasi Silang .....	166
Lampiran 17.	Uji Normalitas Residual GSTARX Bobot Normalisasi Inferensi Parsial Korelasi Silang .....	167
Lampiran 18.	Penghitungan Matematis Varians pada Peramalan interval GSTAR .....	168
Lampiran 19.	Penghitungan Matematis Varians pada Peramalan Interval GSTAR Musiman.....	171
Lampiran 20.	Peramalan <i>Out-Sample</i> IHK Kelompok Bahan Makanan Model GSTARX Bobot Normalisasi Inferensi Parsial Korelasi Silang Lima Kota di Sumatera.....	175



## **BAB 1**

### **PENDAHULUAN**

#### **1.1 Latar Belakang**

Secara umum inflasi dapat diartikan kenaikan harga. Sedangkan menurut Badan Pusat Statistik (BPS), inflasi adalah kecenderungan naiknya harga barang dan jasa pada umumnya yang berlangsung secara terus menerus. Inflasi yang tinggi akan menjadi beban bagi banyak pihak. Jika inflasi meningkat, berarti harga barang dan jasa di dalam negeri mengalami kenaikan. Naiknya harga barang dan jasa tersebut menyebabkan turunnya nilai mata uang. Menurunnya daya beli mata uang menyebabkan kemampuan masyarakat berpenghasilan tetap dalam membeli barang dan jasa kebutuhan sehari-hari akan menjadi semakin rendah. Laju kenaikan harga yang tidak stabil juga menyulitkan perencanaan bagi dunia usaha dan menyebabkan dampak negatif lainnya yang tidak kondusif bagi perekonomian secara keseluruhan. Oleh karena berbagai dampak negatif tersebut maka setiap negara akan berusaha untuk mengendalikan laju inflasi pada tingkat yang rendah dan stabil (Suseno dan Astiyah, 2009).

Inflasi merupakan kenaikan harga barang dan jasa secara umum, maka untuk mengukur perubahan inflasi dari waktu ke waktu pada umumnya digunakan suatu angka indeks (Suseno dan Astiyah, 2009), yaitu Indeks Harga Konsumen (IHK). IHK adalah indeks yang menghitung rata-rata perubahan harga dari suatu paket barang dan jasa yang dikonsumsi oleh rumah tangga dalam kurun waktu tertentu. Dalam penghitungannya, IHK dapat dibedakan menjadi IHK menurut kelompok (1) Bahan Makanan, (2) Makanan Jadi, Minuman, Rokok, dan Tembakau, (3) Perumahan, (4) Sandang, (5) Kesehatan, (6) Pendidikan, Rekreasi, dan Olahraga, (7) Transportasi, Komunikasi, dan Jasa Keuangan. IHK kelompok bahan makanan merupakan komponen yang bergejolak yaitu dominan dipengaruhi oleh *shocks* (kejutan), seperti panen, gangguan alam atau faktor perkembangan harga komoditas pangan domestik maupun perkembangan harga komoditas pangan internasional (Ridhwan, 2013). Pada tahun 2015 nilai indeks

kelompok ini pun tertinggi jika dibandingkan kelompok lain, yaitu 128,01 dengan tahun dasar 2012 (BPS, 2016).

Faktor yang mempengaruhi inflasi di Indonesia bisa berasal dari sisi permintaan maupun penawaran (Suseno dan Astiyah, 2009). Dari sisi permintaan, kenaikan harga dapat berasal dari permintaan musiman, misalnya menjelang hari besar keagamaan seperti Idul Fitri. Berdasarkan survei mekanisme pembentukan harga yang dilakukan oleh Bank Indonesia pada tahun 2001, kenaikan harga-harga pada periode Idul Fitri disebabkan oleh tingginya permintaan dan kecenderungan perilaku permintaan yang kurang elastis terhadap harga pada periode tersebut.

Inflasi di Indonesia juga dapat disebabkan dari sisi penawaran. Dilihat dari sisi penawaran, kenaikan harga-harga dikarenakan meningkatnya biaya input (*cost push inflation*), kebijakan pemerintah terhadap harga (*administered prices*), dan *supply shocks*. Kebijakan pemerintah terhadap harga misalnya kenaikan Bahan Bakar Minyak (BBM) tahun 2005. Penelitian tentang harga minyak berpengaruh pada *Consumer Price Index (CPI)* telah dilakukan oleh Chou dan Tseng (2011). Di dalam penelitian lain yang dilakukan oleh Ridhwan (2013), faktor ekspektasi adaptif (persepsi pelaku ekonomi mengenai inflasi), serta nilai tukar, kesenjangan keluaran (*output gap*), dan harga minyak internasional berpengaruh dalam pembentukan inflasi regional.

*Supply shocks* adalah kenaikan harga yang disebabkan gangguan dari sisi penawaran, misal terjadinya bencana alam, terjadinya musim kering, dan gangguan distribusi sehingga proses penyaluran barang tidak lancar sehingga mempengaruhi barang yang ditawarkan, selanjutnya mengakibatkan kenaikan tingkat harga barang-barang dan pada akhirnya akan meningkatkan laju inflasi. Indonesia merupakan daerah rawan gempa bumi sebab dilalui oleh jalur pertemuan tiga lempeng tektonik, yaitu lempeng Indo-Australia, lempeng Eurasia, dan lempeng Pasifik (BMKG, 2016). Lokasi Pulau Sumatera berdekatan dengan pertemuan dua lempeng, yaitu Lempeng Eurasia dan Lempeng Indo-Australia yang selalu bergerak dan bisa menimbulkan gempa bumi kapan saja. Bencana alam seperti bencana alam dapat menyebabkan kenaikan harga yang bersifat lokal kedaerahan. Kota Padang, Pekanbaru, Jambi, Palembang, dan Bengkulu secara

geografis terletak pada lokasi yang berdekatan yaitu bawa bagian tengah dan selatan Pulau Sumatera. Menurut Hasbullah (2012), kenaikan harga pada wilayah yang berdekatan dimungkinkan mempunyai keterkaitan. Keterkaitan antar wilayah disebabkan adanya hubungan saling ketergantungan dalam memenuhi kebutuhan barang dan jasa. Demikian juga menurut penelitian Ridhwan (2012) dalam *working paper*nya, dari hasil analisis statistik *Moran's I* diketahui adanya indikasi klaster harga spasial antar kabupaten/kota di daerah yang secara geografis berdekatan. Informasi tersebut mendukung penelitian sebelumnya yaitu dengan fenomena harga ikut-ikutan (*copy-cat*). Analisis lanjutan yang dilakukan penelitian ini adalah mengaplikasikan model gravitasi sederhana pada data hasil survei, didapatkan hasil bahwa intensitas perdagangan secara signifikan dipengaruhi oleh jarak geografis, khususnya antar daerah yang berbasaran langsung secara geografis.

Data IHK merupakan data runtun waktu (*time series*), sehingga dapat dimodelkan dengan menggunakan metode analisis *time series*. *Time series* merupakan serangkaian pengamatan yang disusun secara berurutan menurut waktu dalam periode tertentu. Pada data *time series*, pengamatan pada saat ini berkaitan dengan pengamatan pada waktu sebelumnya. Data *time series* banyak ditemui pada bidang ekonomi dan bisnis (indeks harga saham, tingkat suku bunga, indeks harga, dan lain-lain), teknik, geofisika, ilmu kesehatan, meteorologi, serta *quality control* dan lain-lain (Wei, 2006). Berdasarkan banyaknya variabel yang diamati, data *time series* dapat dibedakan menjadi 2 (dua), yaitu univariat *time series* dan multivariat *time series*.

Pada analisis univariat *time series*, telah banyak dilakukan modifikasi dari model *Autoregressive* (AR) maupun *Moving Average* (MA), dan ARIMA. Moser, Rumler, & Scharler (2004) melakukan peramalan *Austrian Harmonized Consumer Price Index* (HICP) dan sub-indikatornya dengan menggunakan ARIMA. Penelitian lain tentang pemodelan inflasi dengan ARIMA dilakukan oleh Baciu (2015) dan Kelikume (2014). Sedangkan ARIMAX merupakan model peramalan yang melibatkan variabel eksogen. Variabel eksogen dilibatkan ke dalam model untuk mendapatkan tambahan informasi dan meningkatkan akurasi pemodelan atau peramalan suatu variabel. Model ARIMAX dengan variabel

eksogen metrik (interval atau rasio) dikenal dengan model Fungsi Transfer, sedangkan variabel eksogen non-metrik (nominal atau ordinal) terdiri dari Model Intervensi dan Model Variasi Kalender.

Penelitian tentang pemodelan inflasi maupun IHK dengan memasukkan variabel eksogen dilakukan oleh Novianti & Suhartono (2009), yaitu dengan memodelkan IHK dengan menggunakan model intervensi multi input. Model intervensi menggambarkan dengan tepat IHK di Indonesia tahun 1989 sampai dengan November 2008 adalah kenaikan harga BBM, perubahan tahun dasar pada Januari 2002, krisis moneter, kemerdekaan Timor Timur, dan tsunami Aceh. Penelitian lainnya oleh Stephani (2015), melakukan peramalan inflasi nasional dengan menggunakan pendekatan Time Series Klasik (ARIMA, fungsi transfer, variasi kalender, intervensi, ARIMAX) dan metode peramalan modern (ANFIS). Variabel eksogen yang digunakan adalah jumlah uang beredar, Tingkat Suku Bunga (SBI), waktu kenaikan harga Bahan Bakar Minyak (BBM), waktu kenaikan Tarif Dasar Listrik (TDL), dan waktu kenaikan gaji Pegawai Negeri Sipil (PNS). Berdasarkan hasil penelitian pada inflasi umum dan inflasi tujuh kelompok pengeluaran menunjukkan bahwa model ARIMAX dan ANFIS tidak selalu menjadi model terbaik. Muryanto (2016) melakukan pemodelan IHK di Kalimantan dengan menggunakan GSTARX dengan data jumlah uang beredar sebagai variabel eksogen. Hasil kajian menunjukkan bahwa orde model GSTAR pada pemodelan IHK dan pemodelan tahap GSTARX adalah GSTAR (1,1). Model GSTARX tersebut memberikan hasil ramalan yang akurat untuk IHK Kota Pontianak, Banjarmasin, Samarinda, dan Balikpapan dilihat dari nilai RMSE yang lebih kecil dari standar deviasi. Penelitian lainnya tentang perbandingan antara ARIMA dan ARIMAX dilakukan oleh Anggraeni, Vinarti, dan Kurniawati (2015) menyimpulkan bahwa metode ARIMAX lebih baik daripada ARIMA dalam hal akurasi level, testing dan hasil peramalan.

Model variasi kalender merupakan model *time series* yang digunakan untuk meramalkan data berdasarkan pola musiman dengan periode bervariasi. Pemodelan *time series* menggunakan variasi kalender telah dilakukan oleh Claveland dan Grupe (1983), serta Liu (1986). Selain itu, Urquhart dan McGroarty (2014) menggunakan efek kalender dalam memodelkan kondisi pasar

di *United State* (US). Penelitian variasi kalender lainnya yaitu dengan efek ramadhan dilakukan oleh Suhartono, Lee dan Hamzah (2010) untuk memodelkan penjualan pakaian muslim anak laki-laki. Penelitian ini berfokus pada pengembangan prosedur pembentukan model terbaik variasi kalender, yaitu menggunakan *dummy* regresi atau pendekatan *autoregressive* seperti yang telah dilakukan oleh Suhartono, Lee, dan Prastyo (2015). Kemudian prosedur pembentukan model terbaik tersebut diterapkan untuk peramalan data *time series*.

Jenis data time series yang lain adalah multivariat *time series*. Salah satu penggunaan multivariat *time series* adalah dengan model *Vector Autoregression Integrated Moving Average* (VARIMA). VARIMA merupakan generalisasi multivariat pada model univariat ARIMA. Model VARIMA menjelaskan keterkaitan antar pengamatan pada variabel tertentu pada suatu waktu dengan pengamatan pada variabel itu sendiri pada waktu-waktu sebelumnya dan juga keterkaitannya dengan pengamatan pada variabel lain pada waktu-waktu sebelumnya. Model tersebut terus mengalami perkembangan sejak pertama kali ditemukan oleh Quenouille (1957) dalam Gooijer dan Hyndman (2006). Memasukkan variabel eksogen juga dapat dilakukan pada pemodelan VAR, sehingga disebut VAR-X. Untuk data yang tidak stasioner atau mengikuti pola tren perlu dilakukan *differencing*. Pada data univariat menjadi *Autoregressive Integrated* (ARI), sedangkan untuk multivariat menjadi *Vector Autoregressive Integrated* (VARI). Apabila melibatkan variabel eksogen maka modelnya menjadi VARI-X seperti yang diaplikasikan oleh Apriliadara, Suhartono, dan Prastyo (2016) untuk memodelkan *inflow* dan *outflow* uang kartal.

Perkembangan berikutnya dari multivariat *time series* adalah dengan melibatkan unsur waktu dan lokasi yaitu model *Space Time Autoregressive* (STAR). Model STAR mengasumsikan fenomena *space time* dengan karakteristik lokasi seragam (homogen), sehingga parameter autoregresi maupun parameter *space time* konstan untuk semua lokasi. Perluasan model STAR menjadi *Generalized Space Time Autoregressive* (GSTAR) dilakukan untuk meningkatkan fleksibilitas parameter STAR. Sehingga GSTAR dapat didefinisikan sebagai metode yang dapat digunakan untuk memodelkan dan meramalkan variabel yang mempunyai keterkaitan waktu sebelumnya dan keterkaitan dengan kota lainnya

yang berdekatan. Kelemahan dari metode STAR tersebut telah diperbaiki dan dikembangkan oleh Borovkova et al. (2008) melalui suatu model yang dikenal dengan model GSTAR yang mengasumsikan bahwa lokasi-lokasi penelitian bersifat heterogen, sehingga perbedaan antar lokasi ini ditunjukkan dalam bentuk matriks pembobot. GSTARX merupakan model GSTAR dengan penambahan variabel eksogen. Kajian tentang perbandingan antara model GSTAR dan VARIMA telah dilakukan oleh Suhartono dan Atok (2006) dengan menggunakan data produksi minyak bumi. Hasil perbandingan ketepatan *out-sample* dari data menunjukkan bahwa model GSTAR memberikan ketepatan ramalan yang lebih baik dibanding VARIMA.

Pada kebanyakan penelitian tentang peramalan ekonomi, biasa menggunakan dan melakukan evaluasi dengan peramalan titik. Tetapi ketika ramalan titik dirasa kurang tepat karena sifatnya yang terbatas hanya meramalkan satu hasil, sehingga memberikan peluang besar terjadi kesalahan (*error*). Peramalan interval merupakan alternatif lain dari peramalan titik yang sama pentingnya. Peramalan interval merupakan nilai yang lebih besar untuk para pengambil keputusan dari peramalan titik, serta dapat digunakan secara lebih luas, karena dengan peramalan tersebut memungkinkan untuk evaluasi menyeluruh dari ketidakpastian di masa depan (Kim & et.al, 2009).

Hasil dari *M3 Competition* (Hibon & Makridakis, 1999) dapat dijadikan dasar atas pembandingan antara metode sederhana dan metode *hybrid*. Dari kompetisi tersebut dapat disimpulkan bahwa metode yang lebih kompleks tidak selalu menghasilkan perkiraan yang lebih akurat daripada metode sederhana (kesimpulan 1), dan metode *hybrid* dapat menghasilkan ramalan yang lebih baik dibandingkan metode sederhana (kesimpulan 3). Atas dasar tersebut, maka dalam penelitian ini akan dibandingkan antara ramalan interval ARIMA (mewakili metode sederhana) dan GSTARX (mewakili metode *hybrid*).

Berdasarkan yang telah diuraikan sebelumnya, penelitian ini akan melakukan pemodelan dan peramalan IHK berdasarkan kelompok bahan makanan di Sumatera menggunakan metode *time series* ARIMAX dengan variasi kalender dan model intervensi berupa kenaikan harga BBM dan kejadian bencana alam di Sumatera, serta GSTARX. Sampai saat ini belum ada penelitian peramalan

interval untuk model GSTARX. Maka dari itu, penelitian ini akan melakukan pengembangan metode peramalan interval untuk model GSTARX.

## **1.2 Rumusan Masalah**

Berdasarkan latar belakang yang telah diuraikan di atas maka ada beberapa rumusan masalah dalam penelitian ini bagaimana model ARIMA, ARIMAX, GSTAR, dan GSTARX yang sesuai untuk peramalan IHK kelompok bahan makanan lima kota di Sumatera. Variabel eksogen yang digunakan yaitu variasi kalender, bencana alam, dan kenaikan harga BBM. Selanjutnya, dari pemodelan terbaik yang sudah dihasilkan pada rumusan pertama maka akan dilakukan peramalan. Peramalan yang dilakukan adalah peramalan titik serta akan dikembangkan pada peramalan interval.

## **1.3 Tujuan Penelitian**

Berdasarkan rumusan masalah di atas, maka tujuan dari penelitian ini adalah :

1. Mendapatkan model ARIMA, ARIMAX, GSTAR, dan GSTARX pada data IHK kelompok bahan makanan lima kota di Sumatera.
2. Mendapatkan ramalan pada model ARIMA, ARIMAX, GSTAR dan GSTARX.
3. Mendapatkan model terbaik antara model ARIMA, ARIMAX, GSTAR dan GSTARX.
4. Mendapatkan ramalan interval pada model GSTAR terbaik.

## **1.4 Manfaat Penelitian**

Penelitian ini diharapkan memberikan manfaat yaitu

1. Mengetahui efek dari faktor-faktor yang berpengaruh terhadap IHK kelompok bahan makanan sebagai dasar antisipasi suatu kebijakan di masa datang.
2. Menghasilkan model GSTARX yang dapat menjelaskan keterkaitan IHK kelompok bahan makanan antara lima kota di Sumatera.

3. Hasil peramalan interval dapat dijadikan salah satu alternatif untuk mengatur kebijakan yang dapat menjaga kenaikan harga bahan makanan khususnya di Sumatera.

## 1.5 Batasan Masalah

Beberapa batasan masalah pada penelitian ini antara lain :

1. Pada penelitian ini wilayah yang diteliti hanya lima kota di Sumatera, yaitu Kota Padang, Pekanbaru, Jambi, Bengkulu, dan Palembang. IHK pada wilayah-wilayah tersebut menggunakan *series* tahun 2000-2015. Pemilihan lima kota tersebut didasarkan pada faktor kedekatan wilayah, kemiripan kultur dan budaya, serta ketersedian data.
2. Estimasi parameter yang digunakan dalam pemodelan GSTAR pada penelitian ini adalah metode *Generalized Least Square* (GLS). Penggunaan metode GLS karena metode tersebut bisa digunakan untuk mengestimasi model *Seemingly Unrelated Regression* (SUR) (Greene, 2007), dimana model SUR bisa mengatasi adanya korelasi *residual* antar persamaan (Zellner, 1962).

## BAB 2

### TINJAUAN PUSTAKA

Bagian ini akan menjelaskan teori yang berkaitan dengan analisis pada penelitian yang meliputi model *time series*, konsep dasar ARIMA, model intervensi, variasi kalender, dan penjelasan mengenai GSTAR.

#### 2.1 Model ARIMA

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan suatu model yang digunakan pada data *time series*. ARIMA adalah gabungan antara model *Autoregressive* (AR) dan model *Moving Average* (MA) dengan *differencing* orde  $d$ . Model ARIMA  $(p, d, q)$  secara umum dapat ditulis sebagai berikut (Wei, 2006:72).

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

dengan,  $\theta_0$  = konstanta,

$$\phi_p(B) = (1 - \phi_1B - \dots - \phi_pB^p),$$

$$\theta_q(B) = (1 - \theta_1B - \dots - \theta_qB^q).$$

Untuk data yang mengandung pola musiman, model ARIMA yang digunakan dapat dinotasikan sebagai ARIMA  $(P, D, Q)^s$ . Untuk pola datanya dapat dirumuskan sebagai berikut (Wei, 2006:166),

$$\Phi_P(B^s)(1 - B^s)^D Z_t = \theta_0 + \Theta_Q(B^s)a_t. \quad (2.2)$$

Model gabungan musiman dan non musiman ARIMA  $(p, d, q)(P, D, Q)^s$  merupakan model multiplikatif musiman Box-Jenkins (Wei, 2006:166), secara umum dapat ditulis :

$$\phi_p(B) \Phi_P(B^s) (1 - B)^d (1 - B^s)^D Z_t = \theta_0 + \theta_q(B) \Theta_Q(B^s) a_t, \quad (2.3)$$

dengan,

$\phi_p(B)$  = koefisien komponen AR tanpa periode musiman dengan orde  $p$

$\Phi_P(B^s)$  = koefisien komponen AR periode musiman  $S$  dengan orde  $P$

$\theta_q(B)$  = koefisien komponen MA tanpa periode musiman dengan orde  $q$

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

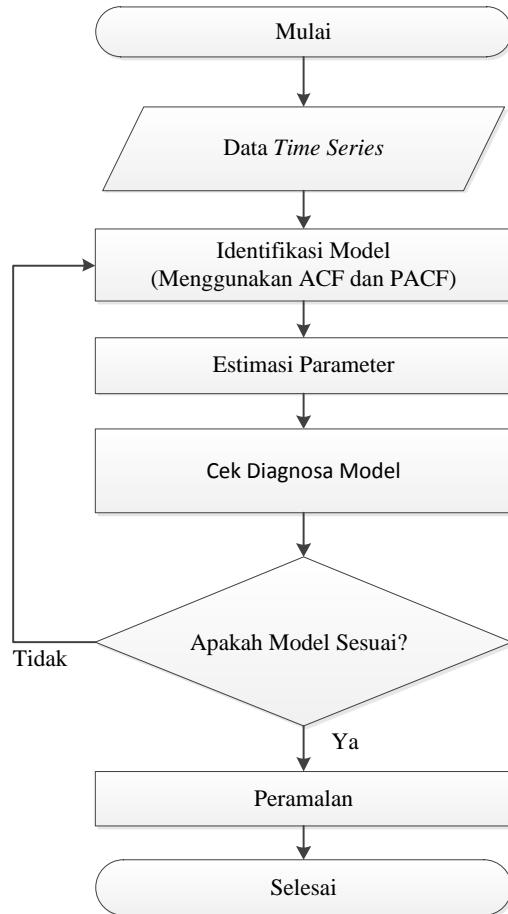
$(1 - B)^d$  = *differencing* tanpa musiman dengan orde  $d$

$(1 - B^S)^D$  = *differencing* musiman  $S$  dengan orde  $D$

$\mu$  = rata-rata dari data stasioner (dengan atau tanpa *differencing*)

$a_t$  = residual *white noise* dengan mean 0 dan varians  $\sigma_a^2$  atau  $a_t \sim WN(0, \sigma_a^2)$ .

Peramalan ARIMA dengan prosedur Box-Jenkins dimulai dari tahap identifikasi model, estimasi parameter, cek diagnosa dan peramalan dapat digambarkan pada Gambar 2.1.



Gambar 2.1 Prosedur Box-Jenkins untuk Pembentukan Model ARIMA

### 2.1.1 Identifikasi Model ARIMA

Menurut Wei (2006 : 108), identifikasi model ARIMA dilakukan melalui empat tahapan, yaitu :

**Tahap 1.** Melakukan *plotting* data *time series* dan menentukan transformasi yang sesuai.

Data yang dianalisis dengan model ARIMA harus memenuhi syarat memiliki sifat stasioner baik pada *mean* maupun varians. Stasioner dalam *mean* berarti memiliki rata-rata yang tetap (tidak dipengaruhi jalannya waktu) dan variansnya tetap (homoskedastisitas). Apabila ternyata data belum stasioner dalam *mean*, maka harus dilakukan proses *differencing*. Sedangkan apabila belum stasioner dalam varians, maka dapat diatasi dengan transformasi Box-Cox.

Proses *differencing* merupakan proses pembedaan atau pengurangan suatu data dengan data sebelumnya sampai data tersebut menjadi stasioner. Apabila suatu data *time series* tidak stasioner, maka data tersebut dapat dijadikan lebih mendekati stasioner dengan melakukan proses pembedaan pertama (*first difference*) sebagai berikut :

$$Z'_t = Z_t - Z_{t-1}. \quad (2.4)$$

Menggunakan *backshift* operator ( $B$ ), persamaan (2.3) dapat dituliskan menjadi sebagai berikut :

$$\begin{aligned} Z'_t &= Z_t - BZ_t \\ &= (1 - B) Z_t. \end{aligned} \quad (2.5)$$

*Differencing* pertama dinyatakan oleh  $(1 - B)$ .

Jika data belum stasioner setelah proses *differencing* pertama, maka dilakukan proses *differencing* orde kedua (*second difference*), yaitu *differencing* satu dari hasil *differencing* pertama sebelumnya  $(t - 1)$  sebagai berikut :

$$\begin{aligned} Z''_t &= Z'_t - Z'_{t-1} \\ Z''_t &= (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) \\ Z''_t &= Z_t - 2Z_{t-1} + Z_{t-2} \\ Z''_t &= Z_t - 2BZ_t + B^2Z_t \\ Z''_t &= (1 - 2B + B^2)Z_t \end{aligned}$$

$$Z_t'' = (1 - B)^2 Z_t. \quad (2.6)$$

Proses *differencing* kedua diberi notasi  $(1 - B)^2$ . Secara umum apabila terdapat *differencing* orde  $d$  untuk mencapai stasioneritas, maka dapat ditulis sebagai berikut :

$$\Delta^d Z_t = (1 - B)^d Z_t. \quad (2.7)$$

Data yang tidak stasioner dalam varians dapat diatasi dengan transformasi, salah satunya dengan transformasi Box-Cox. Untuk suatu nilai parameter  $\lambda$  (*lambda*), transformasi dapat didefinisikan dengan persamaan sebagai berikut (Wei, 2006:85),

$$T(Z_t) = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \lim_{\lambda \rightarrow 0} \frac{Z_t^\lambda - 1}{\lambda} = \ln(Z_t), & \lambda = 0. \end{cases} \quad (2.8)$$

Bentuk transformasi Box-Cox untuk beberapa nilai estimasi  $\lambda$  yang sering digunakan ditunjukkan pada Tabel 2.1.

Tabel 2.1 Nilai Transformasi Box Cox

Nilai $\lambda$	Transformasi
-1,0	$\frac{1}{Z_t}$
-0,5	$\frac{1}{\sqrt{Z_t}}$
0,0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1,0	$Z_t$ tidak ditransformasi

Uji stasioneritas varians tersebut ditampilkan dalam bentuk plot *Box-Cox*. Jika nilai batas bawah dan batas atas *lambda* dari data *time series* mengandung nilai satu, maka varians data tersebut sudah stasioner.

**Tahap 2.** Menghitung dan memeriksa *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data awal, untuk menentukan perlu

tidaknya dilakukan *differencing*. Berikut ini beberapa aturan umum yang dapat diikuti :

1. Bila ACF turun secara lambat dan PACF *cuts off after lag 1*, ini mengindikasikan perlu dilakukan *differencing* (Dickey *et al.* (1986) dalam (Wei, 2006)). Dapat dilakukan *first differencing*  $(1 - B)Z_t$ . Selain itu dapat pula menggunakan *unit root test* yang diusulkan oleh Dickey dan Fuller (1979) dalam Wei (2006 : 109).
2. Untuk mengatasi data yang tidak stasioner dapat dipertimbangkan untuk menggunakan order *differencing* yang lebih tinggi.  $(1 - B)^d Z_t$  untuk  $d > 1$ .

**Tahap 3.** Menghitung dan memeriksa ACF dan PACF dari data yang telah stasioner, untuk menentukan order dari  $p$  dan  $q$ . Pemeriksaan plot ACF dan PACF secara teoritis dapat dilihat dalam Tabel 2.2 berikut.

Tabel 2.2 Karakteristik teoritis ACF dan PACF

Model	Pola ACF	Pola PACF
AR( $p$ )	Menurun secara eksponensial ( <i>dies down</i> )	Terpotong setelah lag $p$ ( <i>cuts off after lag p</i> )
MA( $q$ )	Terpotong setelah lag $q$ ( <i>cuts off after lag q</i> )	Menurun secara eksponensial ( <i>dies down</i> )
ARMA( $p,q$ )	Menurun secara eksponensial setelah lag $(q-p)$	Menurun secara eksponensial setelah lag $(p-q)$

Sumber : Wei (2006 : 109).

### 2.1.2 Estimasi dan Uji Signifikansi Parameter

Setelah melakukan identifikasi dan diperoleh model selanjutnya adalah melakukan uji kelayakan model ARIMA sementara yang diperoleh. Model dianggap layak jika mempunyai parameter yang signifikan. Uji signifikansi parameter dilakukan setelah mendapatkan hasil estimasi parameter model ARIMA sementara.

Dalam Wei (2006:136), ada beberapa cara estimasi parameter untuk model ARIMA, yaitu estimasi dengan metode momen, estimasi dengan metode *least squares*, dan estimasi dengan metode *maximum likelihood*. Penelitian ini menggunakan metode *Least Square*, karena metode ini bekerja dengan membuat *error* yang tidak diketahui sama dengan nol dan meminimumkan jumlah kuadrat *error* (SSE). Pada bagian ini hanya akan diberikan ilustrasi penerapan metode *least squares* untuk estimasi parameter model AR(1), yaitu sebagai berikut,

$$Z_t - \mu = \phi_1(Z_{t-1} - \mu) + a_t. \quad (2.9)$$

Model pada persamaan (2.9) dapat dilihat sebagai suatu model regresi dengan variabel prediktor  $Z_{t-1}$  dan variabel respon  $Z_t$ . Estimasi *least squares* dilakukan dengan cara mencari nilai parameter yang meminimumkan jumlah kuadrat *error*, seperti dituliskan pada persamaan (2.10).

$$S_*(\phi_1, \mu) = \sum_{t=2}^n [(Z_t - \mu) - \phi_1(Z_{t-1} - \mu)]^2 \quad (2.10)$$

Melalui penerapan diferensial terhadap  $\mu$  dan kemudian disamakan dengan 0, akan diperoleh estimasi parameter model AR(1) ini seperti persamaan (2.11) berikut,

$$\hat{\mu} = \frac{\sum_{t=2}^n Z_t - \phi_1 \sum_{t=2}^n Z_{t-1}}{(n-1)(1-\phi_1)}. \quad (2.11)$$

Sedangkan untuk  $n$  yang besar,

$$\frac{\sum_{t=2}^n Z_t}{(n-1)} \approx \frac{\sum_{t=2}^n Z_{t-1}}{(n-1)} \approx \bar{Z},$$

sehingga persamaan (2.11) dapat direduksi menjadi persamaan berikut,

$$\hat{\mu} \approx \frac{\bar{Z} - \phi_1 \bar{Z}}{(1-\phi_1)} = \bar{Z}. \quad (2.12)$$

Dengan cara yang sama, persamaan (2.12) didiferensial terhadap  $\phi_1$  dan diperoleh,

$$\hat{\phi}_1 = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_t - \bar{Z})^2} \quad (2.13)$$

Dari hasil persamaan (2.13) dapat dijelaskan bahwa metode *least squares* akan menghasilkan nilai estimasi parameter yang hampir identik, terutama untuk data yang besar ( $n$  besar).

Tahap selanjutnya adalah melakukan uji kelayakan model ARIMA (sementara) yang diperoleh. Jika uji terhadap parameter adalah signifikan, maka model dianggap layak. Uji signifikansi parameter dilakukan setelah mendapatkan hasil estimasi parameter model ARIMA sementara. Hipotesis yang digunakan dalam uji signifikansi parameter adalah sebagai berikut:

$$H_0: \phi = 0$$

$$H_1: \phi \neq 0$$

Dengan  $\hat{\phi}$  adalah estimasi parameter model. Statistik uji yang digunakan adalah menggunakan uji t dituliskan pada persamaan (2.14).

$$t_{hit} = \frac{\hat{\phi}}{\widehat{se}(\hat{\phi})}. \quad (2.14)$$

Daerah penolakan  $H_0$  adalah  $|t_{hit}| > t_{(\frac{\alpha}{2}; n-n_p)}$ , dimana  $\widehat{se}(\hat{\phi})$  adalah nilai taksiran *standar error* dari  $\phi$ ,  $n_p$  adalah banyaknya parameter dalam model,  $n$  adalah banyaknya observasi, dan  $\alpha$  adalah tingkat kesalahan tipe-I.

### 2.1.3 Cek Diagnosa Model

Langkah selanjutnya setelah estimasi terbaik atau paling efisien untuk parameter-parameter dalam model diperoleh adalah melakukan cek diagnosa model (verifikasi), yakni memeriksa apakah model yang diestimasi sudah sesuai dengan data yang ada. Apabila model ARIMA yang diperoleh belum memenuhi asumsi residual *white noise*, maka harus dirumuskan kembali model yang baru, yang selanjutnya dilakukan estimasi dan verifikasi. Biasanya dalam verifikasi

akan diketahui bagaimana model yang kurang cocok itu dimodifikasi menjadi model baru.

Uji kesesuaian model meliputi uji kecukupan model (uji apakah residualnya *white noise*) dan uji asumsi distribusi normal :

#### 2.1.3.1 Uji Residual *White Noise*

Residual yang *white noise* artinya tidak terdapat korelasi antar residual, dengan *mean* nol dan varians konstan ( $\sigma_a^2$ ). Pengujian terhadap residual apakah merupakan proses yang *white noise* dapat dilakukan secara individu ataupun secara bersama-sama. Pengujian secara individu dapat dilakukan jika diketahui distribusi dari estimasi residual, yaitu secara umum mendekati normal dengan mean 0. Hipotesis yang digunakan untuk uji residual ( $\alpha_t$ ) yang *white noise* dapat dilakukan dengan menggunakan uji Ljung-Box, dengan tahapan sebagai berikut :

##### 1. Hipotesis

$$H_0: \rho_1 = \rho_2 = \dots = \rho_K = 0 \text{ (tidak ada korelasi antar residual)}$$

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

dengan  $k$  adalah lag waktu.

##### 2. Statistik Uji

Dengan statistik uji sebagai berikut (Wei, 2006:153),

$$Q = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{(n-k)}, \quad (2.15)$$

dimana  $\hat{\rho}_k^2$  adalah estimasi ACF residual dan  $n$  adalah banyaknya residual.

##### 3. Daerah Penolakan

Daerah penolakan  $H_0$  yang digunakan adalah  $Q > \chi^2_{\alpha;K-m}$ , dimana  $m = p + q$ .

#### 2.1.3.2 Uji Normalitas

Uji kenormalan terhadap residual model dilakukan dengan menggunakan uji *Kolmogorov-Smirnov*.

## 1. Hipotesis

$H_0: F(a_t) = F_0(a_t)$  untuk semua  $a_t$

$H_1: F(a_t) \neq F_0(a_t)$  untuk semua  $a_t$ .

## 2. Statistik Uji

Statistik uji yang digunakan :

$$D_{hitung} = \text{Sup}|S(a_t) - F_0(a_t)|, \quad (2.16)$$

dengan  $F(a_t)$  adalah fungsi distribusi yang belum diketahui,  $S(a_t)$  adalah fungsi distribusi kumulatif dari data asal dan  $a_t$  adalah residual.

## 3. Daerah Penolakan

Daerah penolakan  $H_0$  adalah  $D_{hitung} \geq D_{(n,1-\alpha)}$ .

### 2.1.4 Peramalan ARIMA

Proses stasioner yang mengikuti model ARMA  $(p,q)$  secara umum didefinisikan pada persamaan (2.17) sebagai berikut (Wei, 2006),

$$\phi(B)Z_t = \theta(B)a_t. \quad (2.17)$$

Karena model persamaan (2.17) stasioner, maka dapat ditulis dalam representasi MA, yaitu

$$Z_t = \psi(B)a_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots \quad (2.18)$$

Untuk  $t = n + l$ , akan diperoleh persamaan berikut,

$$Z_{n+l} = \sum_{j=0}^{\infty} \psi_j \cdot a_{n+l-j}. \quad (2.19)$$

$Z_t$  untuk  $t = n, n-1, n-2, \dots$  dapat dituliskan dalam persamaan (2.18), selanjutnya dapat memberikan ramalan *minimum mean square error*  $\hat{Z}_n(l)$  dari  $Z_{n+1}$  dengan bentuk persamaan sebagai berikut,

$$\hat{Z}_n(l) = \psi_l^* a_n + \psi_{l+1}^* a_{n-1} + \psi_{l+2}^* a_{n-2} + \dots, \quad (2.20)$$

dimana  $\psi_j^*$  ditentukan. Maka *mean square error* dari ramalan adalah sebagai berikut,

$$E(Z_{n+1} - \hat{Z}_n(l))^2 = \sigma_a^2 \sum_{j=0}^{l-1} \psi_j^2 + \sigma_a^2 \sum_{j=0}^{\infty} [\psi_{l+j} - \psi_{l+j}^*]^2, \quad (2.21)$$

akan terlihat mudah saat meminimalkan saat  $\psi_{l+j}^* = \psi_{l+j}$ . Oleh karena itu persamaan (2.20) akan menjadi,

$$\hat{Z}_n(l) = \psi_l a_n + \psi_{l+1} a_{n-1} + \psi_{l+2} a_{n-2} + \dots, \quad (2.22)$$

$\hat{Z}_n(l)$  merupakan ramalan  $l$  langkah ke depan dari  $Z_{n+l}$ . Error dari ramalannya berupa persamaan berikut,

$$e_n(l) = \sum_{j=0}^{l-1} \psi_j \cdot a_{n+l-j}. \quad (2.23)$$

Sehingga variansi kesalahan ramalan pada  $l$  langkah ke depan diperoleh pada persamaan (2.24).

$$\text{var}[e_n(l)] = \sigma_a^2 \sum_{j=0}^{l-1} \psi_j^2. \quad (2.24)$$

Dengan demikian, untuk proses yang berdistribusi normal, taksiran interval ramalan  $(1-\alpha)100\%$  adalah

$$\hat{Z}_n(l) \pm N_{\frac{\alpha}{2}} \sqrt{\text{var}[e_n(l)]}, \quad (2.25)$$

atau

$$\hat{Z}_n(l) \pm N_{\frac{\alpha}{2}} \cdot \sigma_a \left[ 1 + \sum_{j=0}^{l-1} \psi_j^2 \right]^{1/2}. \quad (2.26)$$

Selanjutnya, berdasarkan ARIMA  $(p,d,q)$ , dengan  $d \neq 0$

$$\phi(B)(1-B)^d Z_t = \theta(B) a_t. \quad (2.27)$$

maka ramalan *Minimum Mean Square Error* pada ARIMA adalah

$$\hat{Z}_n(l) = E(Z_{n+l} | Z_t, t \leq n), \quad (2.28)$$

Karena  $E(a_{n+j} | Z_t, t \leq n) = 0$ , untuk  $j > 0$ , maka kesalahan ramalan adalah

$$e_n(l) = Z_{n+l} - \hat{Z}_n(l), \quad (2.29)$$

$$= \sum_{j=0}^{l-1} \psi_j a_{n+1-j}.$$

## 2.2 Model Intervensi

Model intervensi adalah suatu model statistik *time series* yang banyak digunakan untuk menjelaskan efek dari suatu kejadian baik internal maupun eksternal yang diperkirakan akan mempengaruhi variabel yang akan diramalkan. Faktor internal merupakan suatu faktor yang dapat dikendalikan, berupa kebijakan pemerintah atau perusahaan. Contoh faktor internal adalah kenaikan harga BBM, kenaikan Tarif Dasar Listrik (TDL), kenaikan gaji Pegawai Negerii Sipil (PNS) dan lain-lain. Faktor eksternal merupakan sesuatu yang tidak dapat dikendalikan, yang berasal dari kejadian di alam atau perbuatan manusia. Contohnya berupa bom Bali, lumpur Lapindo, gunung meletus, kebakaran hutan, wabah flu burung, mogok kerja, dan lain-lain.

Kelebihan model intervensi ini adalah dapat menggambarkan seberapa lama dampak suatu intervensi pada data *time series*. Model intervensi merupakan gabungan model ARIMA dan fungsi dari variabel prediktor (X), sehingga bisa disebut model *Autoregressive Integrated Moving Average with Exogeneous Variable* (ARIMAX). Secara umum dapat dituliskan sebagai berikut (Cryer & Chan, 2008) :

$$Z_t = f(I_t) + n_t, \quad (2.30)$$

$f(I_t)$  merupakan fungsi yang menjelaskan besar dan lamanya pengaruh intervensi terhadap data respon (*time series*).

$I_t$  = variabel intervensi

$n_t$  = komponen *error* yang mengikuti model ARIMA sebelum terjadi intervensi.

Bentuk umumnya dapat dinyatakan sebagai berikut :

$$Z_t = \frac{\omega_s(B)}{\delta_r(B)} B^b I_t + n_t, \quad (2.31)$$

dengan,

$$\omega_s(B) = \omega_0 - \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s$$

$$\delta_r(B) = 1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r$$

$$n_t = \frac{\theta_q(B)\Theta_Q(B^s)}{\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D} a_t$$

dimana,

- $Z_t$  = variabel respon pada saat  $t$  yang menunjukkan data yang telah stasioner
- $b$  = menyatakan suatu waktu tunggu sampai muncul pengaruh intervensi  $I_t$  terhadap  $Z_t$ ,  $b = 1, 2, 3, \dots$
- $s$  = menyatakan waktu yang diperlukan agar efek intervensi menjadi stabil,  $s = 1, 2, 3, \dots$
- $r$  = menyatakan pola dari residual setelah terjadi intervensi,  $r = 1, 2, 3, \dots$
- $B$  = *Backshift operator* atau operator mundur, yaitu  $B^k Z_t = Z_{t-k}$  (Cryer & Chan, 2008:106).

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

Berikut ini persamaan dampak model intervensi pada data *time series* ( $Z_t^*$ ),

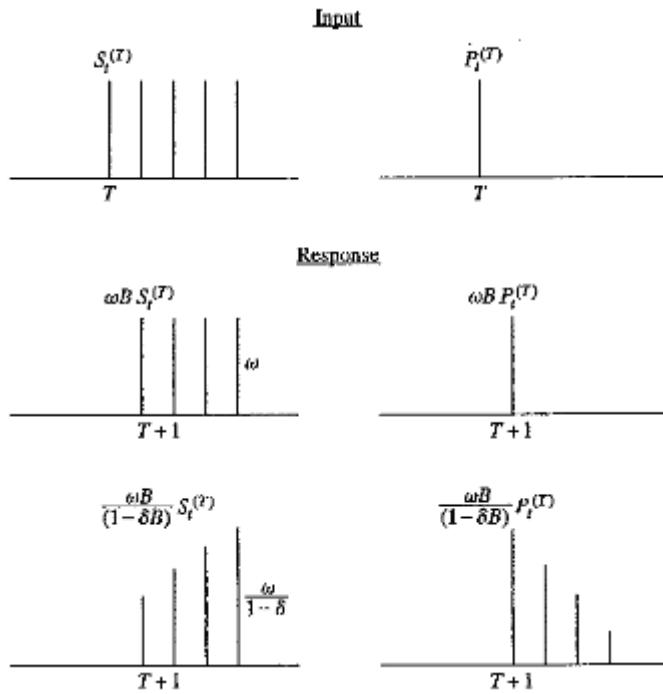
$$Z_t^* = \frac{\omega_s(B)}{\delta_r(B)} B^b I_t. \quad (2.32)$$

Variabel intervensi dapat dibedakan menjadi dua fungsi respon, yaitu *step function* dan *pulse function* (Wei, 2006). *Step function* dapat diartikan kejadian intervensi yang terjadi sejak waktu  $T$  dan seterusnya dan dalam waktu yang panjang, misalnya adalah krisis ekonomi global tahun 2008. *Step Function* secara matematis dapat dinotasikan sebagai berikut :

$$S_t^{(T)} = \begin{cases} 0, & t < T \\ 1, & t \geq T \end{cases}, \quad (2.33)$$

dengan  $T$  = waktu mulai terjadinya intervensi.

Pada gambar 2.2 merupakan respon model terhadap input berupa *step* dan *pulse*. Pada gambar tersebut terlihat perbedaan antara input *step* dan *pulse*, respon serta pemodelan yang dihasilkan.



Gambar 2.2 Respon terhadap *Step* dan *Pulse* Input

**Pulse function** merupakan kejadian intervensi yang terjadi pada waktu  $T$  saja, tidak berlanjut pada waktu setelahnya. Contoh dari fungsi ini adalah bencana tsunami Aceh bulan Desember tahun 2004, bom Bali bulan Oktober 2002 dan 2005. Secara matematis, bentuk intervensi *pulse function* dapat dinotasikan sebagai berikut :

$$P_t^{(T)} = \begin{cases} 0, & t \neq T \\ 1, & t = T. \end{cases} \quad (2.34)$$

Jika terjadi intervensi lebih dari satu jenis pada data *time series*, maka model fungsi intervensi yang digunakan adalah model intervensi multi input. Secara umum dapat dinotasikan sebagai berikut (Wei, 2006 : 215) :

$$Z_t = \theta_0 + \sum_{j=1}^k \frac{\omega_{sj}(B)B^{bj}}{\delta_{rj}(B)} I_{j,t} + \frac{\theta_q(B)}{\phi_p(B)(1-B)^d} a_t \quad (2.35)$$

$j$  = banyaknya variabel intervensi.

$\theta_0$  = konstanta

$b_j$  = banyaknya waktu tunggu mulai berpengaruhnya intervensi  $I_{j,t}$  pada  $Z_t$ , pada intervensi ke- $j$ . Variabel intervensinya dapat berupa fungsi *step* maupun *pulse*.

### 2.3 Variasi Kalender

Model variasi kalender merupakan model *time series* yang digunakan untuk meramalkan data berdasarkan pola musiman dengan periode bervariasi. Di sebagian besar negara-negara Islam, data series ekonomi atau bisnis dapat didekati dengan dua jenis efek kalender, yaitu hari perdagangan atau hari kerja dan efek liburan. Secara umum, tingkat ekonomi atau kegiatan usaha dapat berubah tergantung pada hari minggu. Karena komposisi hari dalam seminggu bervariasi dari bulan ke bulan dan tahun ke tahun. Efek tersebut, terutama karena komposisi hari perdagangan (atau hari kerja) di setiap bulan, yang disebut sebagai efek hari perdagangan (Liu, 1986). Selain dari itu, ada beberapa festival atau hari libur tradisional, seperti Ramadhan, Paskah, Tahun Baru Cina, dan Natal yang diatur sesuai dengan kalender lunas dan tanggal tersebut liburan dapat bervariasi antara dua bulan yang berdekatan dalam kalender Gregorian dari tahun ke tahun.

Karena kegiatan usaha dan pola perilaku konsumen dapat sangat dipengaruhi oleh liburan tersebut pengamatan *time series* dapat bervariasi tergantung pada apakah bulan tertentu mengandung seperti libur atau tidak. Efek tersebut disebut sebagai efek liburan (Liu, 1986). Secara umum, kalender Islam dengan menggunakan kalender lunas berdasarkan dua belas bulan lunas dalam tahun 354 (atau 355 hari di tahun kabisat), digunakan untuk penanggalan di negara Muslim (bersamaan dengan kalender Gregorian), dan digunakan oleh umat Islam untuk menentukan perayaan hari suci Islam Indonesia. Efek variasi dapat diketahui dari jumlah perdagangan sekitar liburan hari raya Idul Fitri, baik sebelum maupun sesudah hari raya tersebut.

Menurut (Liu, 1986) model variasi kalender merupakan kasus khusus dari model fungsi transfer. Metode transfer ini telah dimodifikasi sehingga dapat diaplikasikan pada ARIMA.

Menurut Suhartono dan Lee (2010), analisis regresi di data *time series* mempunyai konteks yang sama dengan regresi linier pada umumnya. Dengan mengasumsikan output (variabel dependen),  $y_t$ ,  $t = 1, 2, 3, \dots, n$  yang dipengaruhi oleh beberapa kemungkinan input (variabel independen), dengan input tersebut *fixed* dan diketahui. Hubungan ini dapat dinyatakan sebagai model regresi linier. Jika di dalam data terdapat trend, maka model dapat dituliskan sebagai berikut :

$$y_t = \beta_0 + \beta_1 t + w_t, \quad (2.36)$$

dengan  $w_t$  merupakan variabel *error* (residual), diasumsikan IIDN dengan *mean* 0 dan varians  $\sigma_e^2$ . Data dengan variasi kalender dapat dimodelkan dengan analisis regresi, dapat dirumuskan sebagai berikut,

$$y_t = \beta_0 + \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_p V_{p,t} + w_t, \quad (2.37)$$

dengan  $V_{P,t}$  adalah variabel *dummy* untuk efek variasi kalender ke- $p$ . Jumlah efek variasi kalender dapat diidentifikasi berdasarkan plot *time series* pada data.

Model ARIMAX merupakan model ARIMA dengan tambahan variabel. Pada penelitian yang dilakukan oleh Lee dan Suhartono (2010), tambahan variabel untuk ARIMA dengan variasi kalender dapat dilakukan dengan, variabel *dummy* hanya untuk efek variasi kalender (ARIMAX dengan tren stokastik dengan mengimplementasikan *differencing* non musiman dan/atau musiman), serta variabel *dummy* untuk efek variasi kalender dan tren deterministik (ARIMAX tanpa order *differencing*).

Model ARIMA musiman secara umum dapat dituliskan sebagai berikut,

$$y_t = \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} \varepsilon_t, \quad (2.38)$$

dimana  $\varepsilon_t$  merupakan residual yang sudah *white noise* dengan *means* 0 dan varians konstan.

Jadi, model ARIMAX dengan tren stokastik dapat dituliskan,

$$\begin{aligned} y_t &= \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_p V_{p,t} \\ &\quad + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} \varepsilon_t. \end{aligned} \quad (2.39)$$

Sedangkan, model ARIMAX dengan tren deterministik adalah sebagai berikut,

$$y_t = \gamma t + \beta_1 V_{1,t} + \beta_2 V_{2,t} + \cdots + \beta_p V_{p,t} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)} \varepsilon_t. \quad (2.40)$$

Prosedur pembentukan ARIMAX dengan adanya efek variasi kalender dapat dirinci sebagai berikut (Suhartono, Lee, & Hamzah, 2010) :

- 1) Menentukan variabel *dummy* pada periode variasi kalender.
- 2) Menghilangkan efek variasi kalender dari respon dengan *fitting* persamaan (2.38) pada model dengan tren stokastik, atau *fitting* persamaan (2.39) dan (2.40) secara bersamaan pada model dengan tren deterministik, untuk mendapatkan eror  $w_t$ .
- 3) Memodelkan  $w_t$  menggunakan model ARIMA (gunakan prosedur Box-Jenkins).
- 4) Order dari model ARIMA yang diperoleh dari langkah ke-3 digunakan untuk data asli dan variabel dummy dari efek variasi kalender sebagai variabel input secara bersamaan sebagai persamaan (2.39) dan (2.40) untuk masing-masing model dengan tren stokastik dan deterministik.
- 5) Uji signifikansi dari parameter dan melakukan *diagnostic checks* sampai proses stasioner dan  $\varepsilon_t$  mencapai proses *white noise*.

## 2.4 Multivariat Time Series

Multivariat *time series* merupakan analisis *time series* yang melibatkan banyak variabel. Dalam kenyataan, *data time series* memiliki keterkaitan antara satu dengan yang lain, misalkan variabel inflasi dipengaruhi jumlah uang beredar, tingkat suku bunga dan lain-lain. Sehingga, analisis hanya dengan menggunakan satu data *time series* (univariat *time series*) saja dianggap tidak cukup. Proses dalam multivariat *time series* sama dengan univariat *time series*, yaitu memperhatikan stasioneritas data yang dapat dilihat melalui plot *Matrix Cross Correlation Function* (MCCF) dan *Matrix Partial Cross Correlation Function* (MPCCF) serta plot *Box-Cox*.

#### **2.4.1 Vector Autoregressive Integrated Moving Average (VARIMA)**

Model VARIMA adalah suatu pendekatan peramalan kuantitatif yang biasa digunakan pada *multivariate time series*. Model ini menjelaskan keterkaitan antar pengamatan pada variabel tertentu pada suatu waktu dengan pengamatan pada variabel itu sendiri pada waktu-waktu sebelumnya, dan juga keterkaitannya dengan pengamatan pada variabel lain pada waktu-waktu sebelumnya (Box, Jenkins, & Reinsel, 2008). Pembentukan model VARIMA dilakukan melalui tahapan identifikasi (menggunakan plot *time series*, MCCF, MPCCF), estimasi parameter, penentuan orde model menggunakan nilai *Akaike's Information Criterion* (AIC), dan cek diagnosa melalui pengecekan apakah *residual* dari model telah memenuhi syarat *white noise* dan kenormalan (Suhartono & Atok, 2006).

Model VARMA untuk data yang tidak stasioner dapat dinotasikan sebagai berikut (Wei, 2006:401),

$$\Phi_p(B)\mathbf{D}(B)\mathbf{Z}_t = \Theta_q(B)a_t, \quad (2.41)$$

dengan operator *differencing*

$$\mathbf{D}(B) = \text{diag}((1 - B)^{d_1}, (1 - B)^{d_2}, \dots, (1 - B)^{d_m}),$$

Dalam perkembangannya, model *state-space* merupakan salah satu model yang dapat digunakan untuk merepresentasikan model VARIMA. Sebagai contoh, dalam studi tentang penjualan, variabel-variabel yang mungkin terlibat adalah volume penjualan, harga dan biaya iklan. Contoh lain adalah penjualan suatu produk pada beberapa daerah pemasaran yang saling berdekatan dan berkaitan.

#### **2.4.2 Vector Autoregressive Moving Average with Exogenous Variable (VARMAX)**

Model VARMAX adalah pengembangan dari model VARMA yang digunakan untuk memodelkan beberapa varibel secara simultan dengan melibatkan variabel prediktor (X). Model VARIMAX banyak digunakan untuk data *time series* di bidang ekonomi, dimana suatu variabel tidak hanya memiliki korelasi satu dengan yang lain, tetapi juga berkorelasi dengan masing-masing nilai

pada masa lalu. Model VARMAX memungkinkan untuk membentuk model hubungan dinamis antara variabel dependen tetapi juga antara variabel dependen dengan independen.

Model VARMAX  $(p,q,s)$  dapat ditulis dengan persamaan berikut :

$$\mathbf{Z}_t = \sum_{i=1}^p \Phi_i \mathbf{Z}_{t-i} + \sum_{i=0}^s \Theta_i^* \mathbf{X}_{t-i} + a_t - \sum_{i=1}^q \Theta_q a_{t-i}, \quad (2.42)$$

$\mathbf{Z}_t = (Z_{1t}, \dots, Z_{kt})'$  merupakan variabel endogen

$\mathbf{X}_t = (X_{1t}, \dots, X_{rt})'$  merupakan variabel eksogen

Model VARMAX  $(p,q,s)$  dapat juga ditulis dalam persamaan:

$$\Phi(B) \mathbf{Z}_t = \Theta^*(B) \mathbf{X}_t + \Theta(B) a_t, \quad (2.43)$$

dimana :

$$\Phi(B) = I_k - \Phi_1 B - \dots - \Phi_p B^p$$

$$\Theta^*(B) = \Theta_0^* + \Theta_1^* B + \dots + \Theta_s^* B^s$$

$$\Theta(B) = I_k + \Theta_1 B + \dots + \Theta_q B^q.$$

#### 2.4.3 Matrix Cross Correlation Function (MCCF)

Jika terdapat vektor *time series* dengan observasi sebanyak  $n$  berupa  $Z_1, Z_2, \dots, Z_n$  maka persamaan MCCF adalah sebagai berikut (Wei, 2006:401)

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)], \quad (2.44)$$

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

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,t+k} - \bar{Z}_j)}{\sqrt{(\sum_{t=1}^n (Z_{i,t} - \bar{Z}_i)^2)(\sum_{t=1}^n (Z_{j,t} - \bar{Z}_j)^2)}} \quad (2.45)$$

$\bar{Z}_i$  dan  $\bar{Z}_j$  merupakan rata-rata sampel dari komponen *series* yang bersesuaian.

MCCF digunakan untuk menentukan orde *Moving Average* (MA). Dalam hal ini, bentuk matriks akan semakin kompleks seiring dengan bertambahnya dimensi vektor. Sehingga Tiao dan Box (1981) memperkenalkan metode yang lebih mudah dalam menjelaskan hasil korelasi sampel dengan menggunakan

simbol (+), (-) dan (.) pada baris ke- $i$  dan kolom ke- $j$  pada matriks sampel korelasi:

- a. Simbol (+) menunjukkan bahwa nilai sampel korelasi ( $\hat{\rho}_{ij}(k)$ ) lebih besar dari 2 kali nilai estimasi *standar error* ( $\hat{\rho}(k)$ ) dan menunjukkan adanya hubungan korelasi positif.
- b. Simbol (-) menunjukkan bahwa nilai sampel korelasi ( $\hat{\rho}_{ij}(k)$ ) kurang dari -2 kali nilai estimasi *standar error* ( $\hat{\rho}(k)$ ) dan menunjukkan adanya hubungan negatif.
- c. Simbol (.) menunjukkan bahwa nilai sampel korelasi ( $\hat{\rho}_{ij}(k)$ ) berada diantara -2 sampai 2 dari nilai estimasi *standar error* ( $\hat{\rho}(k)$ ) yang artinya tidak terdapat hubungan korelasi.

Nilai-nilai MCCF selanjutnya dinotasikan ke dalam bentuk simbol dengan batas  $\pm 2$  kali estimasi *standar error*.

#### 2.4.4 Matrix Partial Cross Correlation Function (MPCCF)

*Partial Auto Correlation Function* (PACF) digunakan untuk menentukan orde dalam model *Autoregressive* (AR) pada *univariate time series*. Sedangkan Tiao dan Box (1981) dalam (Wei, 2006 : 403) mendefinisikan matriks autoregresi parsial pada lag  $s$  sebagai koefisien matriks terakhir ketika data diterapkan ke dalam proses vector autoregressive dari orde  $s$ . Notasi  $\Phi_{s,s}$  dalam regresi linier multivariat dituliskan sebagai berikut :

$$\mathbf{Z}_{t+s} = \Phi_{s,1} \mathbf{Z}_{t+s-1} + \Phi_{s,2} \mathbf{Z}_{t+s-2} + \cdots + \Phi_{s,s} \mathbf{Z}_t + \mathbf{e}_{s,t+s}, \quad (2.46)$$

dimana  $\mathbf{e}_{s,t+s}$  adalah komponen *error*.

Heyse dan Wei (1985a,b) memperluas definisi dari parsial autokorelasi univariat menjadi vektor *time series* dan memperoleh matriks korelasi antara  $\mathbf{Z}_t$  dan  $\mathbf{Z}_{t+s}$ . Matriks korelasi yang didefinisikan sebagai korelasi antar vektor *residual* memiliki persamaan sebagai berikut :

$$\begin{aligned} \mathbf{u}_{s-1,t+s} &= \mathbf{Z}_{t+s} - \alpha_{s-1,1} \mathbf{Z}_{t+s-1} - \cdots - \alpha_{s-1,s-1} \mathbf{Z}_{t+1} \\ &= \begin{cases} \mathbf{Z}_{t+s} - \sum_{k=1}^{s-1} \alpha_{s-1,k} \mathbf{Z}_{t+s-k}, & s \geq 2 \\ \mathbf{Z}_{t+1}, & s = 1 \end{cases}, \end{aligned} \quad (2.47)$$

dan

$$\mathbf{v}_{s-1,t} = \mathbf{Z}_t - \boldsymbol{\beta}_{s-1,1} \mathbf{Z}_{t+1} - \cdots - \boldsymbol{\beta}_{s-1,s-1} \mathbf{Z}_{t+s-1}$$

$$= \begin{cases} \mathbf{Z}_t - \sum_{k=1}^{s-1} \boldsymbol{\beta}_{s-1,k} \mathbf{Z}_{t+k}, & s \geq 2 \\ \mathbf{Z}_t & s = 1 \end{cases}, \quad (2.48)$$

Matriks koefisien regresi linier multivariat  $\boldsymbol{\alpha}_{s-1,k}$  dan  $\boldsymbol{\beta}_{s-1,k}$  diminimalisasi menjadi  $E[|\mathbf{u}_{s-1,t+s}|^2]$  dan  $E[|\mathbf{v}_{s-1,t}|^2]$ . Persamaan (2.47) merupakan *residual* dari regresi  $\mathbf{Z}_{t+s}$  dan persamaan (2.48) merupakan residual dari regresi  $\mathbf{Z}_t$ . Minimum dari persamaan di atas untuk generalisasi multivariat didapat persamaan

$$\begin{aligned} \mathbf{A}(s)\boldsymbol{\alpha}'(s) &= \mathbf{c}(s), \\ \mathbf{A}(s)\boldsymbol{\beta}'(s) &= \mathbf{b}(s), \end{aligned} \quad (2.49)$$

Yang disebut sebagai persamaan normal multivariat dari regresi  $\mathbf{Z}_{t+s}$  dan  $\mathbf{Z}_t$ .

$$\begin{bmatrix} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \cdots & \Gamma'(s-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \dots & \Gamma(0) \end{bmatrix} \begin{bmatrix} \boldsymbol{\alpha}'_{s-1,1} \\ \boldsymbol{\alpha}'_{s-1,2} \\ \vdots \\ \boldsymbol{\alpha}'_{s-1,s-1} \end{bmatrix} = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix} \quad (2.50)$$

Untuk  $s \geq 2$  diperoleh nilai  $\mathbf{A}(s)$ ,  $\mathbf{b}(s)$  dan  $\mathbf{c}(s)$  sebagai berikut :

$$\begin{aligned} \mathbf{A}(s) &= \begin{bmatrix} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \cdots & \Gamma'(s-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \dots & \Gamma(0) \end{bmatrix}, \mathbf{b}(s) = \begin{bmatrix} \Gamma'(s-1) \\ \Gamma'(s-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix} \\ \mathbf{c}(s) &= \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix}. \end{aligned}$$

Sehingga didapatkan nilai  $\boldsymbol{\alpha}'(s)$  dan  $\boldsymbol{\beta}'(s)$  sebagai berikut :

$$\boldsymbol{\alpha}'(s) = \begin{bmatrix} \boldsymbol{\alpha}'_{s-1,1} \\ \boldsymbol{\alpha}'_{s-1,2} \\ \vdots \\ \boldsymbol{\alpha}'_{s-1,s-1} \end{bmatrix} \text{ dan } \boldsymbol{\beta}'(s) = \begin{bmatrix} \boldsymbol{\beta}'_{s-1,s-1} \\ \boldsymbol{\beta}'_{s-1,s-2} \\ \vdots \\ \boldsymbol{\beta}'_{s-1,1} \end{bmatrix}$$

kemudian dapat dituliskan  $var(\mathbf{u}_{s-1,t+s})$  sebagai  $\mathbf{V}_u(s)$ ,  $var(\mathbf{v}_{s-1,t})$  sebagai  $\mathbf{V}_v(s)$ ,  $cov(\mathbf{v}_{s-1,t}, \mathbf{u}_{s-1,t+s})$  sebagai  $\mathbf{V}_{vu}(s)$  dan  $cov(\mathbf{u}_{s-1,t+s}, \mathbf{v}_{s-1,t})$  sama

dengan  $\mathbf{V}'_{vu}(s)$ . Sedangkan untuk  $s = 1$  akan diperoleh  $\mathbf{V}_u(1) = \mathbf{V}_v(1) = \Gamma(0)$  dan  $\mathbf{V}_{vu}(1) = \Gamma(1)$  karena tidak ada keterkaitan antara vektor  $\mathbf{Z}_t$  dan  $\mathbf{Z}_{t+1}$ .

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

$$\mathbf{P}(s) = [\mathbf{D}_v(s)]^{-1} \mathbf{V}_{vu}(s) [\mathbf{D}_u(s)]^{-1}, \quad (2.51)$$

dimana  $\mathbf{D}_v(s)$  adalah matriks diagonal dengan elemen ke- $i$  merupakan akar dari elemen diagonal ke- $i$  dari  $\mathbf{V}_v(s)$  dan  $\mathbf{D}_u(s)$  didefinisikan sama dengan  $\mathbf{V}_u(s)$ .

Tiao dan Box (1981) dalam Wei (2006) menotasikan elemen matriks  $\mathbf{P}_{ij}(s)$  dengan tanda (+), (-) dan (.). Tanda (+) untuk nilai lebih besar dari  $2/\sqrt{n}$ , tanda (-) untuk nilai kurang dari  $-2/\sqrt{n}$ , dan tanda (.) untuk nilai antara  $-2/\sqrt{n}$ , dan  $2/\sqrt{n}$ .

Identifikasi data dipermudah berdasarkan nilai MPCCF yang dinotasikan dalam simbol (+), (-) dan (.) seperti pada MCCF.

#### 2.4.5 Estimasi Parameter Model VARIMA

Setelah dugaan model VARIMA didapatkan, langkah selanjutnya adalah melakukan estimasi parameter dari dugaan model tersebut. Salah satu metode estimasi yang digunakan adalah *Maximum Likelihood Estimation* (MLE). Estimasi kasus *time series* univariat dapat digeneralisasi menjadi estimasi parameter matriks  $\Phi = (\Phi_1, \dots, \Phi_p)$ ,  $\Theta = (\Theta_1, \dots, \Theta_q)$  dan  $\Sigma$ . Misalkan diberikan contoh  $\mathbf{Z} = (\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_n)$  merupakan proses VARMA (p,q) dengan persamaan berikut ini (Wei, 2006):

Dengan metode *least square* yang meminimumkan jumlah kuadrat error diperoleh hasil persamaan untuk hasil estimasi parameter  $\hat{\Phi}$  yaitu (Wutsqa, 2008)

$$\hat{\Phi}' = \left[ \sum_{t=1}^n \mathbf{Z}_t \mathbf{Y}_t' \right] \left[ \sum_{t=1}^n \mathbf{Y}_t \mathbf{Y}_t' \right]^{-1} \quad (2.52)$$

Kemudian dilakukan pengujian signifikansi parameter yang diperoleh dengan metode *likelihood* terhadap model dengan menggunakan statistik uji  $t$ . Hipotesis yang digunakan dalam pengujian ini adalah sebagai berikut:

$$H_o: \Phi_{ijk} = 0$$

$$H_1: \Phi_{ijk} \neq 0$$

dengan statistik uji :

$$t_{hit} = \frac{\widehat{\Phi}_{ijk}}{\widehat{SE}(\widehat{\Phi}_{ijk})} \quad (2.53)$$

Hasil statistik uji yang diperoleh pada persamaan (2.53) kemudian dibandingkan dengan  $t_{\alpha/2}$  yang diperoleh dari tabel distribusi  $t$ . Keputusan akan menolak hipotesis nol jika  $|t_{hit}| > t_{\alpha/2, (n-p-1)}$  dengan tingkat signifikansi  $\alpha$ , sedangkan  $p$  adalah jumlah parameter yang diestimasi.

Setelah estimasi parameter dilakukan, selanjutnya kecukupan dari model yang sesuai harus diperiksa dengan analisis diagnosa dari *residual* dengan persamaan sebagai berikut :

$$\widehat{\mathbf{a}}_t = \dot{\mathbf{Z}}_t - \widehat{\Phi}_1 \dot{\mathbf{Z}}_{t-1} - \cdots - \widehat{\Phi}_p \dot{\mathbf{Z}}_{t-p} + \widehat{\Theta}_1 \widehat{\mathbf{a}}_{t-1} + \cdots + \widehat{\Theta}_p \widehat{\mathbf{a}}_{t-p}, \quad (2.54)$$

dimana  $\dot{\mathbf{Z}}_t$  digunakan untuk menotasikan  $\mathbf{Z}_t$  jika  $\boldsymbol{\mu} = 0$  dan menotasikan  $(\mathbf{Z}_t - \widehat{\boldsymbol{\mu}})$  jika  $\boldsymbol{\mu} \neq \mathbf{0}$  serta  $\widehat{\Phi}_i$  dan  $\widehat{\Theta}_j$  merupakan estimasi dari parameter  $\Phi_i$  dan  $\Theta_j$ . Suatu model dikatakan cukup jika residualnya bersifat *white noise*. Sehingga matriks korelasi dari  $\widehat{\mathbf{a}}_t$  harus sama dengan nol (Wei, 2006).

#### 2.4.6 Akaike's Information Criterion (AIC)

*Akaike Information Criterion* (AIC) merupakan kriteria pemilihan model terbaik yang diperkenalkan oleh Akaike (1973) dengan mempertimbangkan banyaknya parameter model. Kriteria pemilihan ini didasarkan pada nilai AIC yang terkecil (minimum) diantara model yang ada.

Dalam mengidentifikasi orde model VARIMA, dapat dilihat dari karakteristik orde spasial dan waktu. Orde spasial secara umum dibatasi hanya pada orde 1 saja, karena dengan orde yang lebih tinggi akan sulit untuk diinterpretasikan. Sedangkan untuk orde waktu ditentukan menggunakan nilai AIC (Wei, 2006 : 407),

$$AIC(p) = \ln(|S_p|) + \frac{2pm^2}{n}, \quad (2.55)$$

dimana  $n$  adalah banyaknya observasi,  $m$  adalah jumlah variabel,  $p$  adalah orde dari proses AR ( $p = 1, 2, \dots, p_o$ ) dimana  $p_o$  merupakan bilangan bulat positif dan  $|S_p|$  adalah determinan dari *residual sum of square* dan perkalian silangnya, yaitu

$$S_p = \sum_{t=p+1}^n (A \times B), \quad (2.56)$$

dengan,

$$\begin{aligned} A &= (\mathbf{Z}_t - \hat{\boldsymbol{\tau}} - \hat{\Phi}_1 \mathbf{Z}_{t-1} - \cdots - \hat{\Phi}_p \mathbf{Z}_{t-p}) \\ B &= (\mathbf{Z}_t - \hat{\boldsymbol{\tau}} - \hat{\Phi}_1 \mathbf{Z}_{t-1} - \cdots - \hat{\Phi}_p \mathbf{Z}_{t-p})', \end{aligned}$$

dimana  $\hat{\boldsymbol{\tau}}$  adalah vektor konstan.

#### 2.4.7 Cek Diagnosa Model

Tahap pemeriksaan (cek diagnosa model) dilakukan setelah tahap estimasi parameter. Pada tahap ini akan dilakukan pengujian apakah model layak (signifikan) sehingga dapat digunakan untuk peramalan. Suatu model dikatakan layak jika parameter model signifikan dan *residual* dari model memenuhi asumsi *white noise* dan kenormalan. Uji asumsi *white noise* dengan cara memodelkan ulang *residual* yang didapatkan dari model dan melakukan pengecekan letak nilai AIC terkecil.

#### 2.4.8 Pemilihan Model Terbaik

Kriteria pemilihan model terbaik pada data *in-sample* digunakan nilai AIC dimana model terbaik adalah model yang memiliki nilai AIC terendah. Model terbaik dipilih berdasarkan model terbaik pada data *out sample*. *Error* (RMSE). Model terbaik didapatkan jika nilai RMSE paling kecil diantara model yang ada, hal ini sesuai dengan tujuan dari peramalan, yaitu untuk memperoleh angka ramalan dengan kesalahan sekecil-kecilnya. Besarnya nilai RMSE pada data *out-sample* dapat dihitung dengan (Wei, 2006) :

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{M} \sum_{l=1}^M (z_{n+l} - \hat{z}_n(l))^2}, \quad (2.57)$$

dengan  $M$  adalah banyaknya ramalan yang dilakukan,  $Z_{n+l}$  adalah data sebenarnya  $\hat{Z}_n(l)$  adalah data hasil ramalan.

## 2.5 Model Generalized Space Time Autoregressive (GSTAR)

Model GSTAR adalah salah satu model yang banyak digunakan untuk memodelkan dan meramalkan data deret waktu dan lokasi. Model GSTAR merupakan generalisasi dari model *Space-Time Autoregressive* (STAR). Perbedaan yang mendasar antara model GSTAR dengan model STAR terletak pada pengasumsian parameternya. Model STAR mengasumsikan lokasi-lokasi yang digunakan dalam penelitian adalah sama, sehingga model ini hanya dapat diterapkan pada lokasi yang bersifat seragam. Sedangkan pada model GSTAR terdapat asumsi yang menyatakan lokasi-lokasi penelitian yang bersifat heterogen, sehingga perbedaan antar lokasi ini ditunjukkan dalam bentuk matriks pembobot.

Jika diberikan sebuah deret  $\{Z(t): t = 0, \pm 1, \pm 2, \dots, \pm T\}$  merupakan sebuah deret waktu multivariat dari  $N$  komponen, maka model *STAR autoregressive* order  $p$  dan spasial order  $\lambda_1, \dots, \lambda_p$  dapat dinotasikan  $\text{STAR}(p|\lambda_1, \dots, \lambda_p)$  didefinisikan sebagai berikut (Borovkova, Lopuhaa, & Ruchjana, 2008:483),

$$\mathbf{Z}(t) = \sum_{s=1}^p \sum_{k=0}^{\lambda_s} \Phi_{sk} \mathbf{W}^{(k)} \mathbf{Z}(t-s) + \mathbf{e}(t) \quad t = 0, \pm 1, \pm 2, \dots \quad (2.58)$$

dimana,

$\lambda_s$  : order spasial pada *autoregressive* ke- $s$

$\Phi_{sk}$  : parameter *autoregressive* pada lag waktu  $s$  dan lag spasial  $k$

$\mathbf{W}^{(k)}$  : matriks pembobot ukuran ( $N \times N$ ) pada lag spasial  $k$ ,  $k = 0, 1, \dots, \lambda_s$

$\mathbf{e}(t)$  : random *error* dengan mean 0.

Kelemahan model STAR ialah semua lokasi mempunyai parameter autoregresi yang sama, sehingga hanya sesuai digunakan pada lokasi yang bersifat homogen. Untuk mengatasi kelemahan model STAR tersebut, Ruchjana (2002) mengembangkan model model GSTAR untuk meningkatkan fleksibilitas parameter STAR. Pada model GSTAR yang dikembangkan tersebut, parameter model merupakan matriks dengan elemen diagonalnya menyatakan parameter

autoregresi dan parameter space time yang berubah untuk setiap lokasi. Model GSTAR dari orde *autoregressive*  $p$  dengan orde spasial  $\lambda_1, \lambda_2, \dots, \lambda_p$ , GSTAR  $(p; \lambda_1, \lambda_2, \dots, \lambda_p)$  dalam notasi matriks dapat ditulis sebagai berikut (Borovkova, Lopuhaa, & Ruchjana, 2008:485),

$$\mathbf{Z}(t) = \sum_{s=1}^p \left[ \Phi_{s0} + \sum_{k=1}^{\lambda_s} \Phi_{sk} \mathbf{W}^{(k)} \right] \mathbf{Z}(t-s) + \mathbf{e}(t), \quad (2.59)$$

dimana,

$$t = 0, \pm 1, \pm 2, \dots$$

$\mathbf{Z}(t)$  : vektor pengamatan pada  $t$  waktu ( $N \times 1$ )

$\lambda_s$  : order spasial pada *autoregressive* ke- $s$

$\Phi_{sk}$  : matriks diagonal dengan elemen diagonal sebagai *autoregressive* dan *space time* untuk setiap lokasi

$\mathbf{e}(t)$  : *white noise* dengan vektor mean  $\mathbf{0}$  dan matriks varian kovarian  $\sigma^2 \mathbf{I}$ .

Matriks  $\Phi_{s0}$  adalah diagonal  $(\phi_{s0}^{(1)}, \dots, \phi_{s0}^{(N)})$  yang merupakan matriks parameter waktu dan  $\Phi_{sk}$  adalah diagonal  $(\phi_{sk}^{(1)}, \dots, \phi_{sk}^{(N)})$  merupakan matriks parameter spasial. Nilai pembobot yang dipilih memenuhi syarat  $w_{ii}^{(k)} = 0$  dan  $\sum_{i \neq j} w_{ij}^{(k)} = 1$ .  $\mathbf{W}^{(k)}$  merupakan matriks pembobot ukuran ( $N \times N$ ) pada lag spasial  $j$ .  $\mathbf{Z}(t)$  adalah vektor acak ukuran ( $N \times 1$ ) pada waktu  $t$ , yaitu  $Z(t) = [Z_1(t) \ Z_2(t) \ \dots \ Z_N(t)]'$ .

Sehingga jika diketahui model GSTAR untuk orde waktu dan orde spasial satu dengan menggunakan tiga lokasi, maka akan diperoleh persamaan sebagai berikut:

$$\mathbf{Z}(t) = \Phi_{10} \mathbf{Z}(t-1) + \Phi_{11} \mathbf{W}^{(1)} \mathbf{Z}(t-1) + \mathbf{e}(t). \quad (2.60)$$

Dalam mengidentifikasi orde model GSTAR, orde waktu dapat ditentukan dengan menggunakan *Akaike's Information Criterion* (AIC) (Wei, 2006), sedangkan orde spasial pada umumnya dibatasi hanya orde satu saja karena orde yang lebih tinggi akan sulit untuk diinterpretasikan. Akan tetapi beberapa kajian yang telah dilakukan masih terbatas pada data deret waktu multivariat yang stasioner, tetapi belum melibatkan pola musiman atau *seasonal*. Sehingga penentuan orde model juga dapat dilakukan berdasarkan plot MCCF dan MPCCF

yang terbentuk (Wutsqa dan Suhartono, 2010). Apabila data yang digunakan mengandung pola musiman, maka model GSTAR yang digunakan adalah GSTAR musiman. Secara matematis, model GSTAR  $(p; \lambda_1, \lambda_2, \dots, \lambda_p)^s$  untuk pola data musiman dapat dituliskan ke dalam bentuk matriks sebagai berikut :

$$\mathbf{Z}(t) = \sum_{k=1}^p \left[ \Phi_{k0}^s \mathbf{Z}(t-s) + \sum_{l=1}^{\lambda_p} \Phi_{kl}^s \mathbf{W}^{(l)} \mathbf{Z}(t-s) \right] + \mathbf{e}(t), \quad (2.61)$$

dengan,

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

$\Phi_{kl}^s$  = diagonal  $(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(N)})$  merupakan parameter spasial periode musiman s

$\mathbf{e}(t)$  = vektor *error* yang identik, independen dan berdistribusi normal multivariat dengan mean 0 dan matriks varians-kovarians  $\sigma^2 I_N$

$\mathbf{Z}(t)$  = vektor acak berukuran  $(N \times 1)$  pada waktu  $t$ , yaitu

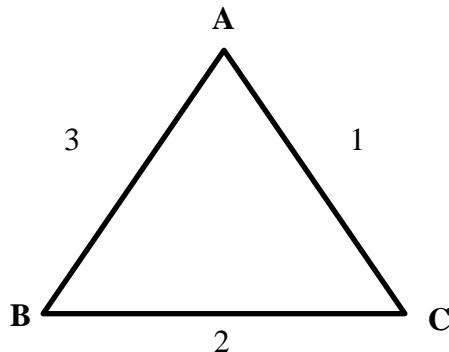
$\mathbf{Z}(t) = [Z_1(t) \ Z_2(t) \ \dots \ Z_N(t)]'$ .

Nilai pembobot yang dipilih memenuhi syarat  $w_{ii}^{(l)} = 0$  dan  $\sum_{i \neq j} w_{ij}^{(l)} = 1$ .

### 2.5.1 Penentuan Bobot Lokasi pada Model GSTAR

Pemilihan bobot lokasi merupakan salah satu permasalahan dalam pemodelan GSTAR karena harus dipilih bobot lokasi yang sesuai untuk diterapkan pada data runtun waktu tersebut. Menurut Suhartono dan Subanar (2006), ada beberapa metode yang digunakan untuk pembobotan dalam model GSTAR, yaitu bobot seragam (*uniform*), biner (*binary*), *versi* jarak, bobot berdasarkan pada *semi-variogram* atau *covariogram* dari variabel diantara lokasi dan bobot normalisasi hasil inferensi korelasi silang parsial. Pada bab ini tidak dibahas untuk bobot berdasarkan pada *semi-variogram* atau *covariogram* karena pembobot ini hanya dapat digunakan untuk lokasi yang banyak.

Beberapa pembobotan yang dapat digunakan untuk menentukan bobot dari ketiga lokasi adalah bobot seragam, *versi* jarak dan normalisasi hasil inferensi korelasi silang parsial.



Gambar 2.3 Contoh Peta Tiga Lokasi

### i. Bobot Seragam (*Uniform*)

Bobot lokasi seragam mengasumsikan bahwa lokasi-lokasi yang digunakan tersebut bersifat homogen atau mempunyai jarak antar lokasi yang sama, sehingga tiap lokasi mempunyai nilai yang sama. Penentuan nilai bobot dalam bobot lokasi seragam adalah :

$$w_{ij} = \frac{1}{n_i}, \quad (2.62)$$

dimana,  $n_i$  adalah jumlah tempat (*space*) yang berdekatan dengan lokasi  $i$ . Contoh matriks bobot seragam untuk tiga lokasi seperti Gambar 2.3 dapat ditulis sebagai berikut :

$$W_{ij} = \begin{bmatrix} 0 & 1/2 & 1/2 \\ 1/2 & 0 & 1/2 \\ 1/2 & 1/2 & 0 \end{bmatrix}.$$

### ii. Bobot Biner (*Binary*)

Metode dengan pembobot biner didefinisikan hubungan letak suatu lokasi dengan lokasi lainnya. Hubungan antara dua lokasi yang secara geografis berdekatan didefinisikan  $w_{ij} = 1$ . Sedangkan antar lokasi yang berjauhan didefinisikan  $w_{ij} = 0$ .

$$W_{ij} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix}.$$

### iii. Bobot Invers Jarak

Pembobotan dengan metode *invers jarak* dilakukan berdasarkan jarak sebenarnya antar lokasi di lapangan. Perhitungan bobot dengan metode *invers jarak* diperoleh dari hasil *invers jarak* sebenarnya kemudian dinormalisasi. Berdasarkan contoh pada Gambar 2.3 berikut adalah contoh perhitungan bobot:

Tabel 2.3 Contoh Jarak dari Tiga Lokasi

Lokasi	Lokasi		
	Kota A	Kota B	Kota C
Kota A	0	$d_{AB} = 3$	$d_{AC} = 1$
Kota B	$d_{BA} = 3$	0	$d_{BC} = 2$
Kota C	$d_{CA} = 1$	$d_{CB} = 2$	0

Bentuk matrik jarak yang terbentuk adalah:

$$\mathbf{D} = \begin{bmatrix} d_{AA} & d_{AB} & d_{AC} \\ d_{BA} & d_{BB} & d_{BC} \\ d_{CA} & d_{CB} & d_{CC} \end{bmatrix}.$$

Kemudian matriks  $\mathbf{D}$  tersebut distandardkan dalam bentuk  $\mathbf{W}$  untuk memenuhi sifat bobot  $\sum_{j=1}^N w_{ij}^{(l)} = 1$ ,  $j \neq i$ . Dengan asumsi jarak yang dekat memiliki hubungan antar lokasi yang kuat maka secara umum bobot invers jarak untuk masing-masing lokasi dapat dinyatakan dengan:

$$w_{ij} = \frac{1}{\sum_{j=1}^n \frac{1}{d_{ij}}}, \quad j \neq i, \quad (2.63)$$

dengan jumlah bobot untuk setiap lokasi adalah 1,  $\sum_{j=1}^N w_{ij} = 1$  dan  $\sum_{i=1}^N \sum_{j=1}^N w_{ij} = N$ . Diagonal matriks bobot invers jarak  $w_{ii}$  adalah nol, karena untuk suatu lokasi dianggap tidak ada jarak dengan dirinya sendiri. Sehingga bentuk matriks invers jarak yang terbentuk adalah:

$$\mathbf{W} = \begin{bmatrix} 0 & \frac{1}{d_{AB}} & \frac{1}{d_{AC}} \\ \frac{1}{d_{AB}} + \frac{1}{d_{AC}} & 0 & \frac{1}{d_{BC}} \\ \frac{1}{d_{BA}} + \frac{1}{d_{BC}} & \frac{1}{d_{BC}} + \frac{1}{d_{BA}} & 0 \\ \frac{1}{d_{CA}} + \frac{1}{d_{CB}} & \frac{1}{d_{CB}} + \frac{1}{d_{CA}} & 0 \end{bmatrix}.$$

Berikut ini contoh perhitungan bobot invers jarak berdasarkan contoh dengan Gambar 2.3,

$$w_{AB} = \frac{\frac{1}{d_{AB}}}{\frac{1}{d_{AB}} + \frac{1}{d_{AC}}} = \frac{\frac{1}{3}}{\frac{1}{3} + 1} = \frac{1}{4}$$

$$w_{AC} = \frac{\frac{1}{d_{AC}}}{\frac{1}{d_{AC}} + \frac{1}{d_{AC}}} = \frac{\frac{1}{3}}{1 + \frac{1}{3}} = \frac{3}{4}$$

Maka diperoleh matriks bobot invers jarak sebagai berikut :

$$\mathbf{W} = \begin{bmatrix} 0 & 1/4 & 3/4 \\ 2/5 & 0 & 3/5 \\ 2/3 & 1/3 & 0 \end{bmatrix}$$

Bentuk bobot invers jarak  $\mathbf{W}$  bukan merupakan matrik yang simetris, karena matrik jarak  $\mathbf{D}$  setelah distandardkan pada setiap lokasi harus memenuhi sifat bobot  $\sum_{j=1}^N w_{ij} = 1, j \neq i$ , kecuali untuk masing-masing lokasi mempunyai jarak yang sama.

#### iv. Bobot Normalisasi Korelasi Silang

Pembobotan dengan metode ini menggunakan hasil normalisasi korelasi silang antar lokasi pada *lag* yang bersesuaian. Pembobotan dengan metode ini pertama kali diperkenalkan oleh Suhartono dan Atok (2006). Wei (2006) mendefinisikan korelasi silang antara lokasi ke-*i* dan ke-*j* pada *lag* waktu ke-*k*,  $\text{corr}[Z_i, Z_j(t - k)]$  sebagai berikut :

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j},$$

dengan  $\gamma_{ij}(k)$  merupakan kovarians silang antara kejadian di lokasi ke- $i$  dan ke- $j$  pada lag waktu ke- $k$ , dimana  $k = 0, \pm 1, \pm 2, \dots$ .  $\sigma_i$  dan  $\sigma_j$  adalah standar deviasi dari kejadian di lokasi ke- $i$  dan ke- $j$ . Taksiran dari korelasi silang ini pada data sampel dapat dihitung dengan persamaan sebagai berikut :

$$\gamma_{ij}(k) = \frac{\sum_{t=k+1}^n [Z_i(t) - Z_i][Z_j(t-k) - Z_j]}{\sqrt{(\sum_{t=1}^n [Z_i(t) - \bar{Z}_i]^2)(\sum_{t=1}^n [Z_j(t) - \bar{Z}_j]^2)}} \quad (2.64)$$

#### v. Bobot Normalisasi Inferensia Parsial Korelasi Silang

Penghitungan bobot normalisasi inferensia parsial korelasi silang tidak jauh berbeda dengan pembobotan normalisasi korelasi silang. Secara umum korelasi silang antara kejadian di lokasi ke- $i$  dan ke- $j$  pada lag waktu ke- $k$ ,  $\text{corr}[Y_i(t), Y_j(t-k)]$ , didefinisikan seperti persamaan Estimasi dari persamaan korelasi silang data sampel dapat dilihat pada persamaan. Bartlett (1955) dalam Wei (2006) telah menurunkan varians dan kovarians dari besaran korelasi silang yang diperoleh dari sampel. Hipotesis awal menyatakan bahwa dua data *time series*  $Y_i$  dan  $Y_j$  adalah tidak berkorelasi, Bartlett menunjukkan bahwa

$$\text{Varians}[r_{ij}(k)] \cong \frac{1}{n-k} \left[ 1 + 2 \sum_{s=1}^{\infty} \rho_{ii}(s) \rho_{jj}(s) \right]$$

Oleh karena itu, ketika  $Y_i$  dan  $Y_j$  merupakan deret yang *white noise*, diperoleh

$$\text{Varians}[r_{ij}(k)] \cong \frac{1}{n-k}. \quad (2.65)$$

Untuk ukuran sampel yang besar,  $(n - k)$  dalam persamaan (2.64) seringkali diganti dengan  $n$ . Dibawah asumsi distribusi normal, maka nilai-nilai korelasi silang pada sampel ini dapat diuji apakah sama atau berbeda dengan nol. Uji hipotesis atau proses inferensia statistik dapat dilakukan menggunakan taksiran interval.

$$r_{ij}(k) \pm \left[ t_{(\frac{\alpha}{2};(n-k-2)} \frac{1}{\sqrt{n}}} \right].$$

Dalam proses ini dihasilkan bobot lokasi dengan menggunakan normalisasi dari hasil inferensi statistik parsial terhadap korelasi silang antar lokasi pada *lag* waktu yang bersesuaian. Bobot lokasi ini memungkinkan semua bentuk kemungkinan hubungan antar lokasi, sehingga tidak ada lagi batasan yang kaku tentang besarnya bobot, terutama yang bergantung dari jarak antar lokasi. Bobot ini juga memberikan fleksibilitas pada besar dan tanda hubungan antar lokasi yang berlainan, yaitu positif dan negatif. Bobot lokasi ini mencakup bobot lokasi seragam dan biner (Suhartono dan Subanar, 2006).

### 2.5.2 Estimasi Parameter Model GSTAR

Estimasi parameter dalam model GSTAR terdiri dari dua metode, yaitu metode estimasi kuadrat terkecil atau *Ordinary Least Square* (OLS) dan metode *Generalized Least Square* (GLS). Metode estimasi kuadrat terkecil dengan meminimumkan jumlah kuadrat *error* sehingga diperoleh estimator dengan variansi terkecil. Metode tersebut digunakan untuk mengestimasi parameter masing-masing persamaan dalam sistem apabila persamaan yang satu dengan yang lain tidak saling berhubungan (*residual* tidak saling berkorelasi). Sedangkan metode GLS digunakan untuk mengestimasi parameter model *Seemingly Unrelated Regression* (SUR) dimana terdiri dari beberapa persamaan dan variabel-variabelnya tidak bersifat dua arah, akan tetapi antara persamaan-persamaan tersebut terjadi kaitan satu sama lainnya sehingga terjadi korelasi antara kesalahan-kesalahan persamaan tersebut (Zellner, 1962).

#### a. Metode Estimasi Kuadrat Terkecil / *Ordinary Least Square* (OLS)

Jika diketahui model GSTAR (1<sub>1</sub>) akan diestimasi dengan menggunakan metode estimasi kuadrat terkecil (OLS), sehingga dapat dituliskan persamaan dari model tersebut adalah :

$$\mathbf{Z}(t) = \boldsymbol{\Phi}_{10}\mathbf{Z}(t-1) + \boldsymbol{\Phi}_{11}\mathbf{W}\mathbf{Z}(t-1) + \mathbf{e}(t), \quad (2.66)$$

dengan  $\boldsymbol{\Phi}_{10}$  merupakan parameter regresi waktu,  $\boldsymbol{\Phi}_{11}$  merupakan parameter regresi spasial dan  $\mathbf{W}$  merupakan matriks pembobot. Metode estimasi kuadrat terkecil ini dapat digunakan untuk estimasi parameter pada model linier. Sehingga

metode ini dapat diterapkan pada model GSTAR (1<sub>1</sub>) dengan persamaan umumnya adalah sebagai berikut :

$$\mathbf{Z} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e}, \quad (2.67)$$

dengan  $\mathbf{Z} = (\mathbf{Z}'_1, \mathbf{Z}'_2, \dots, \mathbf{Z}'_N)', \mathbf{X} = \text{diag}(\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N), \boldsymbol{\beta} = (\boldsymbol{\beta}'_1, \boldsymbol{\beta}'_2, \dots, \boldsymbol{\beta}'_N)'$  dan  $\mathbf{e} = (\mathbf{e}'_1, \mathbf{e}'_2, \dots, \mathbf{e}'_N)'$ . Persamaan di atas dapat dimodifikasi jika terdapat beberapa lokasi seperti pada model GSTAR, sehingga model persamaan untuk lokasi ke-*i* dapat ditulis sebagai  $\mathbf{Z}_i = \mathbf{X}_i\boldsymbol{\beta}_i + \mathbf{e}_i$  dimana  $\boldsymbol{\beta}_i = (\phi_{0i}, \phi_{1i})'$ .

Persamaan (2.74) dapat dimodifikasi jika terdapat beberapa lokasi seperti pada model GSTAR, sehingga model pada persamaan (2.74) untuk lokasi ke-*i* dapat ditulis sebagai berikut:

$$\mathbf{Y}_i = \mathbf{X}_i\boldsymbol{\beta}_i + \mathbf{e}_i, \quad (2.68)$$

dengan  $\mathbf{Z}_i(t)$  merupakan banyaknya pengamatan ke-*t* (*t* = 0, 1, ..., *T*) untuk lokasi ke-*i* (*i* = 1, 2, ..., *N*), dan  $\boldsymbol{\beta}_i = (\phi_{i0}^1, \phi_{i1}^1)'$ . Jika diketahui  $\mathbf{V}_i(t) = \sum_{j \neq i} w_{ij} Y_j(t)$  maka persamaan (2.75) dapat dijabarkan dalam bentuk matriks sebagai berikut:

$$\mathbf{Z}_i = \begin{bmatrix} \mathbf{Z}_i(1) \\ \mathbf{Z}_i(2) \\ \vdots \\ \mathbf{Z}_i(T) \end{bmatrix} = \begin{bmatrix} \mathbf{Z}_i(0) & \mathbf{V}_i(0) \\ \mathbf{Z}_i(1) & \mathbf{V}_i(1) \\ \vdots & \vdots \\ \mathbf{Z}_i(T-1) & \mathbf{V}_i(T-1) \end{bmatrix} \quad \boldsymbol{\beta}_i = \begin{bmatrix} \phi_{i0}^1 \\ \phi_{i1}^1 \end{bmatrix} \quad \mathbf{e}_i = \begin{bmatrix} e_i(1) \\ e_i(2) \\ \vdots \\ e_i(T) \end{bmatrix} \quad (2.69)$$

Persamaan (2.66) jika dituliskan dalam bentuk matriks adalah sebagai berikut:

$$\begin{bmatrix} \mathbf{Z}_i(1) \\ \mathbf{Z}_i(2) \\ \vdots \\ \mathbf{Z}_i(T) \end{bmatrix} = \begin{bmatrix} \mathbf{Z}_i(0) & \mathbf{V}_i(0) \\ \mathbf{Z}_i(1) & \mathbf{V}_i(1) \\ \vdots & \vdots \\ \mathbf{Z}_i(T-1) & \mathbf{V}_i(T-1) \end{bmatrix} \begin{bmatrix} \phi_{i0}^1 \\ \phi_{i1}^1 \end{bmatrix} + \begin{bmatrix} e_i(1) \\ e_i(2) \\ \vdots \\ e_i(T) \end{bmatrix} \quad (2.70)$$

Jika  $\boldsymbol{\beta}_i = (\phi_{i0}^1, \phi_{i1}^1, \phi_{20}^1, \phi_{21}^1, \dots, \phi_{N0}^1, \phi_{N1}^1)$ .

Estimator *least square* untuk  $\boldsymbol{\beta}_i$  dapat dihitung secara terpisah pada masing-masing lokasi namun tetap bergantung pada nilai  $\mathbf{Z}(t)$  di lokasi yang lain. Sebagai contoh struktur data untuk estimasi parameter model GSTAR(1<sub>1</sub>) di tiga lokasi yang berbeda dapat dituliskan sebagai berikut:

$$Z_1(t) = \phi_{10} Z_1(t-1) + \phi_{11} w_{12} Z_2(t-1) + \phi_{11} w_{13} Z_3(t-1) + \varepsilon_1(t)$$

$$\begin{aligned} Z_2(t) &= \phi_{10}Z_2(t-1) + \phi_{11}w_{21}Z_1(t-1) + \phi_{11}w_{23}Z_3(t-1) + \varepsilon_2(t) \\ Z_3(t) &= \phi_{10}Z_3(t-1) + \phi_{11}w_{31}Z_1(t-1) + \phi_{11}w_{32}Z_2(t-1) + \varepsilon_3(t) \end{aligned}$$

Estimasi terhadap parameter  $\beta$  dilakukan menggunakan metode *least square* dengan cara meminimumkan fungsi

$$\mathbf{e}'\mathbf{e} = (\mathbf{Z} - \mathbf{X}\beta)'(\mathbf{Z} - \mathbf{X}\beta), \quad (2.71)$$

sehingga menghasilkan estimator  $\hat{\beta}$  sebagai berikut:

$$\hat{\beta} = [\mathbf{X}'\mathbf{X}]^{-1}\mathbf{X}'\mathbf{Z}. \quad (2.72)$$

Khususnya untuk vektor parameter  $\phi_{i0}$  dan  $\phi_{i1}$ , dengan  $i = 1, 2, \dots, N$

$$\phi_i = [\mathbf{X}'\mathbf{X}]^{-1}\mathbf{X}'\mathbf{Z}_i. \quad (2.73)$$

### b. Metode *Generalized Least Square* (GLS)

Model *Seemingly Unrelated Regression* (SUR) diperkenalkan oleh Arnold Zellner pada tahun 1962. Model ini digunakan untuk analisis regresi multivariat ketika variabel *residual* berkorelasi antar persamaan (Alaba, Olubusoye, & Ojo, 2010). Model SUR ini terdiri dari beberapa persamaan dimana *residual* antar pengamatan dalam satu persamaan tidak berkorelasi tetapi residual antara persamaan yang satu dengan persamaan yang lain saling berkorelasi (berautokorelasi). Jadi model SUR ini dapat mengatasi adanya korelasi *residual* antar persamaan sehingga mendapatkan suatu estimator. Menurut (Greene, 2002) model SUR dapat diestimasi menggunakan metode *Generalized Least Square* (GLS). Model SUR dengan  $M$  variabel dependen dinyatakan dengan (Greene, 2002):

$$\mathbf{Z}_i = \mathbf{X}_i\beta_i + \mathbf{e}_i, \quad (2.74)$$

$$\mathbf{Z}_i = \begin{bmatrix} z_{11} \\ \vdots \\ z_{1T} \\ z_{21} \\ \vdots \\ z_{2T} \\ \vdots \\ z_{N1} \\ \vdots \\ z_{NT} \end{bmatrix}, \boldsymbol{\beta}_i = \begin{bmatrix} \beta_{10} \\ \vdots \\ \beta_{1k} \\ \beta_{20} \\ \vdots \\ \beta_{2k} \\ \vdots \\ \beta_{N0} \\ \vdots \\ \beta_{Nk} \end{bmatrix}, \mathbf{e}_i = \begin{bmatrix} e_{11} \\ \vdots \\ e_{1T} \\ e_{21} \\ \vdots \\ e_{2T} \\ \vdots \\ e_{N1} \\ \vdots \\ e_{NT} \end{bmatrix} \quad (2.75)$$

$$\mathbf{X}_i = \left[ \begin{array}{cccc} 1 & x_{11,1} & \cdots & x_{1k,1} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{T1,1} & \cdots & x_{TK,1} \end{array} \right] \quad \left[ \begin{array}{cccc} 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{array} \right] \quad \left[ \begin{array}{cccc} 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{array} \right] \\ \left[ \begin{array}{cccc} 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{array} \right] \quad \left[ \begin{array}{cccc} 1 & x_{11,2} & \cdots & x_{1k,2} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{T1,2} & \cdots & x_{TK,2} \end{array} \right] \quad \left[ \begin{array}{cccc} 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{array} \right] \\ \left[ \begin{array}{cccc} 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{array} \right] \quad \left[ \begin{array}{cccc} 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{array} \right] \quad \left[ \begin{array}{cccc} 1 & x_{11,N} & \cdots & x_{1k,N} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{T1,N} & \cdots & x_{TK,N} \end{array} \right] \quad (2.76)$$

dengan  $i = 1, 2, \dots, M$ ,  $\mathbf{Z}_i$  adalah vektor pengamatan terurut berukuran  $(T \times 1)$  pada variabel dependen,  $\mathbf{X}_i$  adalah matriks pengamatan berukuran  $(T \times K)$  pada variabel independen,  $\boldsymbol{\beta}_i$  adalah vektor parameter berukuran  $(K \times 1)$ , dan  $\mathbf{e}_i$  adalah vektor *residual* berukuran  $(T \times 1)$ . Persamaan 2.74 dapat ditulis dalam bentuk matriks berikut :

$$\begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_T \end{bmatrix} = \begin{bmatrix} X_1 & 0 & \cdots & 0 \\ 0 & X_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & X_K \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_T \end{bmatrix} \quad (2.77)$$

$$\begin{aligned} Z_1 &= \beta_{10} + \beta_{11}X_{1,1} + \beta_{12}X_{1,2} + \cdots + \beta_{1K}X_{1,K} + e_1 \\ Z_2 &= \beta_{20} + \beta_{21}X_{2,1} + \beta_{22}X_{2,2} + \cdots + \beta_{2K}X_{2,K} + e_2 \\ &\vdots &&\vdots \\ Z_T &= \beta_{K0} + \beta_{K1}X_{K,1} + \beta_{K2}X_{K,2} + \cdots + \beta_{TK}X_{T,K} + e_T. \end{aligned}$$

Zellner (1962) mengasumsikan bahwa struktur matriks varians-kovarians pada sistem persamaan model SUR diberikan dengan,

$$E[\mathbf{e}_i \mathbf{e}_j'] = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_N \end{bmatrix} [e_1 \quad e_2 \quad \cdots \quad e_N], \quad (2.78)$$

persamaan (2.78) apabila diuraikan menjadi,

$$E[\mathbf{e}_i \mathbf{e}_j'] = \begin{bmatrix} E(e_1 e_1) & E(e_1 e_2) & \cdots & E(e_1 e_N) \\ E(e_2 e_1) & E(e_2 e_2) & \cdots & E(e_2 e_N) \\ \vdots & \vdots & \ddots & \vdots \\ E(e_N e_1) & E(e_N e_2) & \cdots & E(e_N e_N) \end{bmatrix} \quad (2.79)$$

karena  $E(\mathbf{e}_i \mathbf{e}_j') = \boldsymbol{\sigma}_{ij} \mathbf{I}_T$  sehingga dapat dituliskan

$$E(\mathbf{e}_i \mathbf{e}_j') = \begin{bmatrix} \sigma_{11} \mathbf{I}_T & \sigma_{12} \mathbf{I}_T & \cdots & \sigma_{1N} \mathbf{I}_T \\ \sigma_{21} \mathbf{I}_T & \sigma_{22} \mathbf{I}_T & \cdots & \sigma_{2N} \mathbf{I}_T \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} \mathbf{I}_T & \sigma_{N2} \mathbf{I}_T & \cdots & \sigma_{NN} \mathbf{I}_T \end{bmatrix} \quad (2.80)$$

persamaan (2.79) apabila diuraikan dengan perkalian Kronecker ( $\otimes$ ) menjadi

$$\begin{aligned} E(\mathbf{e}_i \mathbf{e}_j') &= \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N2} & \cdots & \sigma_{NN} \end{bmatrix} \otimes \mathbf{I}_T \\ &= \boldsymbol{\Sigma} \otimes \mathbf{I} \\ &= \boldsymbol{\Omega} \end{aligned} \quad (2.81)$$

$$\text{dengan } \boldsymbol{\Sigma} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N2} & \cdots & \sigma_{NN} \end{bmatrix} \text{ dan } \mathbf{I} = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{bmatrix}$$

Matriks  $\boldsymbol{\Sigma}$  merupakan matriks varians-kovarians residual berukuran  $(N \times N)$  dan  $\mathbf{I}$  merupakan matriks identitas berukuran  $(T \times T)$ .

Estimasi parameter model SUR dengan Metode GLS memerlukan invers dari matriks varian kovarian residual, dari persamaan (2.80) diperoleh :

$$\boldsymbol{\Omega} = \boldsymbol{\Sigma} \otimes \mathbf{I} \quad (2.82)$$

menjadi

$$\boldsymbol{\Omega}^{-1} = \boldsymbol{\Sigma}^{-1} \otimes \mathbf{I} \quad (2.83)$$

Estimasi parameter model SUR dilakukan dengan metode GLS yang merupakan pengembangan dari metode Ordinary Least Square (OLS), sehingga dari persamaan  $\mathbf{Z} = \mathbf{X}\beta + \mathbf{e}$  dapat dibentuk :

sehingga diperoleh penaksir tak bias  $\boldsymbol{\beta}$  dengan menggunakan GLS, yaitu:

$$\hat{\beta} = (\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}\mathbf{Z}, \quad (2.84)$$

karena  $\Omega = \Sigma \otimes \mathbf{I}$ , maka estimator  $\hat{\beta}$  adalah sebagai berikut:

$$\hat{\beta} = (\mathbf{X}'(\Sigma \otimes \mathbf{I})^{-1}\mathbf{X})^{-1}\mathbf{X}'(\Sigma \otimes \mathbf{I})^{-1}\mathbf{Z} \quad (2.85)$$

$$\hat{\beta} = (\mathbf{X}'\Sigma^{-1} \otimes \mathbf{I}\mathbf{X})^{-1}\mathbf{X}'\Sigma^{-1} \otimes \mathbf{I}\mathbf{Z}. \quad (2.86)$$

Metode GLS digunakan karena GSTAR dengan variabel eksogen tidak cukup dengan penyelesaian satu tahap.

### c. Regresi dengan Residual Berkorelasi

Penaksiran parameter dengan metode OLS pada analisis regresi menghasilkan penaksir yang bersifat *unbiased* dan konsisten. Namun apabila terjadi adanya residual yang berkorelasi antar persamaan dapat menyebabkan hasil estimasi  $\hat{\beta}$  dengan metode OLS menjadi tidak konsisten meskipun tetap *unbiased* (Wei, 2006). Wei (2006) mengembangkan metode estimasi parameter apabila terjadi korelasi residual antar persamaan dengan dua tahapan, yaitu:

1. Tahapan pertama adalah sebagai berikut:
  - a. Membentuk model persamaan regresi yang akan diestimasi, misal seperti pada persamaan (2.76).
  - b. Menghitung nilai residual  $e_i$  dari persamaan (2.76) dengan OLS.
2. Tahapan kedua adalah sebagai berikut:
  - a. Mengestimasi  $\phi_j$  dan  $\sigma^2$  dalam model AR( $p$ ) dengan memodelkan residual  $e_i$  hasil penghitungan OLS berdasarkan model berikut:
 
$$\hat{e}_{i,t} = \phi_1 \hat{e}_{i,t-1} + \cdots + \phi_p \hat{e}_{i,t-p} + n_t. \quad (2.87)$$
  - b. Menghitung  $\Omega$  berdasarkan  $\phi_j$  dan  $\sigma^2$  dari tahap (a)
  - c. Menghitung estimasi GLS,  $\hat{\beta} = (\mathbf{X}'\Omega^{-1}\mathbf{X})^{-1}\mathbf{X}'\Omega^{-1}\mathbf{Y}$ .
  - d. Menghitung residual hasil estimasi model dengan GLS.

### d. Kondisi Stasioner Parameter Model GSTAR

Borovkova, Lopuhaa, dan Ruchjana (2008) menyatakan bahwa model GSTAR khususnya GSTAR(1<sub>1</sub>) merupakan versi yang terbatas dari model VAR.

Oleh karena itu, kondisi stasioner model GSTAR dapat diperoleh dari kondisi stasioner model VAR. Model GSTAR(1<sub>1</sub>),  $\mathbf{Z}(t) = [\Phi_{10} + \Phi_{11}\mathbf{W}^{(1)}]\mathbf{Z}(t-1) + \mathbf{e}(t)$  dapat diwakili dengan model VAR(1),  $\mathbf{Z}(t) = \Phi_1\mathbf{Z}(t-1) + \mathbf{e}(t)$ , dengan

$$\Phi_1 = [\Phi_{10} + \Phi_{11}\mathbf{W}^{(1)}]$$

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

Suhartono dan Subanar (2007) menyatakan bahwa kondisi stasioner pada model GSTAR, khususnya untuk parameter pada model GSTAR(1<sub>1</sub>) dapat menggunakan syarat  $|\lambda| < 1$  yang disajikan dalam model VAR(1). Oleh karena itu, untuk mengecek kondisi stasioner parameter model GSTAR(1<sub>1</sub>) harus disajikan dalam bentuk VAR(1) terlebih dahulu.

### 2.5.3 Cek Diagnosa Model

Pemeriksaan diagnosa model dilakukan untuk mengetahui apakah model dugaan sudah memenuhi syarat kebaikan model atau belum. Suatu model dikatakan layak jika parameter model sudah signifikan dan residual dari model memenuhi asumsi *white noise* dan kenormalan. Residual bersifat *white noise* berarti residual dari masing-masing data saling independen. Uji *white noise* dilakukan dengan cara memodelkan ulang residual yang didapatkan dari pemodelan. Pendektsian *white noise* residual dapat dilakukan dengan melihat plot MCCF atau menggunakan kriteria minimum AIC. Jika nilai AIC terkecil terletak pada AR(0) dan MA(0) dikatakan bahwa tidak ada korelasi antar residual, artinya residual bersifat *white noise*.

### 2.5.4 Kriteria Pemilihan Model Terbaik

Kriteria pemilihan model terbaik dipilih berdasarkan nilai *Root Mean Square Error* (RMSE) data *out sample*. Model terbaik didapatkan jika nilai RMSE paling kecil diantara model yang ada, hal ini sesuai dengan tujuan dari peramalan, yaitu untuk memperoleh angka ramalan dengan kesalahan sekecil-kecilnya.

Besarnya nilai RMSE data *out-sample* dapat dihitung dengan formula sebagai berikut (Wei, 2006):

$$RMSE = \sqrt{\frac{1}{M} \sum_{l=1}^M (Z_{n+l} - \hat{Z}_n(l))^2}, \quad (2.88)$$

dengan  $M$  adalah banyaknya ramalan yang dilakukan,  $Z_{n+l}$  adalah data sebenarnya dan  $\hat{Z}_n(l)$  adalah data hasil ramalan.

### 2.5.5 Peramalan Model GSTAR

Setelah model terbaik terpilih berdasarkan kriteria RMSE *out-sample* terkecil, tahapan selanjutnya adalah peramalan model GSTAR. Secara umum peramalan titik model GSTAR dapat dituliskan pada persamaan berikut :

$$\hat{Z}_{i,T}(l) = \sum_{s=1}^p \left[ \hat{\Phi}_{k0} \mathbf{Z}(t-s) + \sum_{l=1}^{\lambda_p} \hat{\Phi}_{sl} \mathbf{W}^{(l)} \mathbf{Z}(t-s) \right]. \quad (2.89)$$

Sedangkan persamaan untuk peramalan interval adalah sebagai berikut :

$$\text{Batas bawah} = \hat{Z}_{i,n(k)} - N_{\frac{\alpha}{2}} \hat{\sigma}(k)$$

$$\text{Batas atas} = \hat{Z}_{i,n(k)} + N_{\frac{\alpha}{2}} \hat{\sigma}(k)$$

dimana,

$N_{\frac{\alpha}{2}}$  = nilai normal standar dari  $\alpha/2$

$\hat{\sigma}(k)$  = mean square error atau akar dari  $\text{var}(\varepsilon_{i,n}(k))$

Maka dari itu, diperlukan varians dari eror dalam perhitungan peramalan interval. Berdasarkan Lampiran 18 dan 19 varians tersebut dapat dirumuskan sebagai berikut.

#### Penghitungan Varians Error pada GSTAR ( $[1]_1$ )

- Untuk  $t = n + 1, i = 1, 2, \dots, I$

$$\text{var}(\varepsilon_{i,n}(1)) = \sigma_{a_i}^2,$$

- Untuk  $t = n + 2$

$$\text{var}(\varepsilon_{i,n}(2)) = \sigma_{a_i}^2 + \phi_{i0}^2 \text{var}(\varepsilon_{i,n}(1)) + \sum_{\substack{j=1 \\ (j \neq i)}}^I \tilde{\phi}_{ij}^2 \text{var}(\varepsilon_{j,n}(1))$$

- Untuk  $t = n + 3$

$$\text{var}(\varepsilon_{i,n}(3)) = \sigma_{a_i}^2 + \phi_{i0}^2 \text{var}(\varepsilon_{i,n}(2)) + \sum_{\substack{j=1 \\ (j \neq i)}}^I \tilde{\phi}_{ij}^2 \text{var}(\varepsilon_{j,n}(2))$$

⋮

Sehingga, bisa dirumuskan secara umum, untuk  $t = n + k$  adalah

$$\text{var}(\varepsilon_{i,n}(k)) = \sigma_{a_i}^2 + \phi_{i0}^2 \text{var}(\varepsilon_{i,n}(k-1)) + \sum_{\substack{j=1 \\ (j \neq i)}}^I \tilde{\phi}_{ij}^2 \text{var}(\varepsilon_{j,n}(k-1)) \quad (2.90)$$

#### A. Penghitungan Varians *Error* pada GSTAR ([12]<sub>1</sub>)

- Untuk  $t = n + 1, \quad i = 1, 2, \dots, I$

$$\text{var}(\varepsilon_{i,n}(1)) = \sigma_{a_i}^2,$$

⋮

- Untuk  $t = n + 12$

$$\text{var}(\varepsilon_{i,n}(12)) = \sigma_{a_i}^2$$

Maka varians *error* untuk  $t = n + k$ , dengan  $k = 1, 2, \dots, 12$  dapat dituliskan secara umum sebagai berikut,

$$\text{var}(\varepsilon_{i,n}(k)) = \sigma_{a_i}^2, \quad (2.91)$$

Sedangkan untuk  $t = n + k$ , dengan  $k = 13, 14, \dots$  dapat dituliskan sebagai berikut,

- Untuk  $t = n + 13$

$$\text{var}(\varepsilon_{i,n}(13)) = \sigma_{a_i}^2 + \phi_{i0}^2 \text{var}(\varepsilon_{i,n}(1)) + \sum_{\substack{j=1 \\ (j \neq i)}}^I \tilde{\phi}_{ij}^2 \text{var}(\varepsilon_{j,n}(1))$$

Maka untuk  $n + k$  dengan  $k \geq 13$  dirumuskan sebagai berikut,

$$\text{var}(\varepsilon_{i,n}(k)) = \sigma_{a_i}^2 + \phi_{i0}^2 \text{var}(\varepsilon_{i,n}(k-1)) + \sum_{\substack{j=1 \\ (j \neq i)}}^I \tilde{\phi}_{ij}^2 \text{var}(\varepsilon_{j,n}(k-1)) \quad (2.92)$$

dimana  $\sigma_{a_i}^2$  adalah *Mean Square Error* (MSE) pada masing-masing lokasi.

## **2.6 Indeks Harga Konsumen (IHK)**

### **2.6.1 Pengertian IHK**

IHK merupakan indeks yang menggambarkan perubahan harga pada sekelompok barang dan jasa yang dikonsumsi oleh rumah tangga pada periode tertentu. BPS menggunakan IHK sebagai salah satu dasar penghitungan inflasi nasional dan regional. Untuk menjamin bahwa IHK menunjukkan perubahan harga yang secara tidak langsung juga mengindikasikan perubahan daya beli masyarakat, maka penghitungan IHK menggunakan paket komoditas tetap pada tahun dasar. Besaran paket komoditas barang dan jasa yang dikonsumsi rumah tangga disusun dalam bentuk diagram timbang paket komoditas. Diagram timbang menunjukkan persentase nilai konsumsi tiap-tiap jenis barang/jasa terhadap total rata-rata pengeluaran rumah tangga di suatu kota.

Perkembangan kebutuhan barang dan jasa yang dikonsumsi masyarakat cukup pesat sejalan dengan perubahan yang dinamis kondisi sosial ekonomi masyarakat, sehingga paket komoditas dan diagram timbang IHK diperbarui secara periodik. Dalam perkembangannya, penyusunan paket komoditas dan diagram timbang IHK telah beberapa kali mengalami perubahan baik metode penghitungan, cakupan kota, dan jumlah paket komoditas yang dihitung. Paket komoditas dan diagram timbang disusun berdasarkan hasil SBH yang dilaksanakan 5-10 tahun sekali. Pada tahun 2012, SBH dilaksanakan di 82 kota besar, dengan cakupan sampel mencapai 136.080 rumah tangga.

Pemilihan paket komoditas yang dimasukkan dalam paket komoditas dan diagram timbang IHK adalah:

- a. Barang dan jasa yang pada umumnya dikonsumsi masyarakat di kota tersebut. Barang mewah yang dikonsumsi oleh sebagian kecil masyarakat tidak dimasukkan dalam paket komoditas.
- b. Secara terus menerus tersedia dipasar dalam waktu yang lama dan proporsi nilai konsumsi tidak kurang dari 0,02 persen.
- c. Barang dan jasa yang mempunyai persentase nilai konsumsi terhadap total konsumsi barang kurang dari 0,02 persen tetapi penting untuk keperluan hidup sehari-hari.

Berdasarkan hasil SBH 2012 diperoleh 7 kelompok barang dan jasa yang menjadi paket komoditas yaitu :

- a. Kelompok bahan makanan,
- b. Kelompok makanan jadi, minuman, rokok dan tembakau,
- c. Kelompok perumahan, air, listrik, gas dan bahan bakar,
- d. Kelompok sandang,
- e. Kelompok kesehatan,
- f. Kelompok pendidikan,
- g. Kelompok transport, komunikasi dan jasa keuangan.

Untuk menghitung nilai IHK pada bulan berjalan dilakukan Survei Harga Konsumen (SHK). Konsep harga yang digunakan dalam penghitungan IHK adalah sejumlah uang yang dibayarkan konsumen untuk membeli barang dan jasa yang mereka beli. Perubahan harga barang masing-masing komoditi tidak sama, biasanya tergantung pada tingkat konsumsi, musiman, dan ada juga komoditas barang dan jasa yang dikendalikan atau disubsidi oleh pemerintah seperti BBM, listrik, uang sekolah, tarif angkutan, tarif air, dan biaya jasa telepon. Kondisi ini menyebabkan cara pengumpulan data harga untuk setiap komoditas berbeda-beda. Harga yang frekuensi perubahannya tinggi dikumpulkan secara mingguan (bahkan untuk harga beras dikumpulkan harian). Harga komoditas lainnya dikumpulkan dua mingguan dan bulanan. Pengumpulan harga dapat dilakukan lebih cepat apabila ada fluktuasi perubahan harga yang tinggi, misalnya hari raya dan musim liburan.

Tempat pemantauan data harga konsumen adalah pasar tradisional, pasar swalayan, dan outlet. Pasar adalah tempat terjadinya transaksi jual beli antara pedagang dan pembeli. Pada pasar tradisional, masih ada proses tawar-menawar antara pedagang dengan pembeli. Sedangkan pada pasar modern, harganya sudah tetap misalnya menggunakan label harga sehingga tidak ada lagi proses tawar menawar. Berbeda dengan pasar, outlet adalah tempat yang menyediakan atau menjual barang-barang yang khusus atau berupa jasa. Contoh outlet adalah seperti toko bangunan, *fastfood*, rumah sakit, PLN, serta praktek dokter.

Pasar yang akan didata dipilih secara *purposive* dari pasar yang ada dengan kriteria sebagai berikut:

- a. Pasar tersebut merupakan pasar yang dijadikan acuan harga bagi pasar-pasar disekitarnya,
- b. Pasar yang relatif besar, terletak di daerah kota, dan berbagai komoditi dapat ditemui,
- c. Masyarakat banyak yang berbelanja disana, dan waktu keramaian berbelanja panjang.

### 2.6.2 Penghitungan IHK

Nilai IHK diperoleh melalui perbandingan nilai konsumsi pada suatu periode berjalan dengan nilai konsumsi pada tahun dasar hasil SBH terakhir. Nilai konsumsi adalah jumlah nilai yang dikeluarkan oleh rumah tangga untuk memperoleh suatu komoditas untuk dikonsumsi. Nilai konsumsi suatu komoditi merupakan perkalian harga komoditas dengan kuantitas (banyaknya) yang dikonsumsi. Formula yang digunakan untuk menghitung IHK masing-masing kota adalah berdasarkan *formula Laspeyres* dengan modifikasi sebagai berikut:

$$IHK_t = \frac{\sum_{i=1}^g \frac{P_{t,i}}{P_{(t-1),i}} P_{(t-1),i} Q_{o,i}}{\sum_{i=1}^g P_{o,i} Q_{o,i}} \quad (2.93)$$

dengan,

$IHK_t$	=	Indeks harga konsumen periode ke- $t$
$P_{t,i}$	=	Harga jenis barang/jasa ke- $i$ , periode ke- $t$
$P_{(t-1),i}$	=	Harga jenis barang/jasa ke- $i$ , periode ke- $(t-1)$
$\frac{P_{t,i}}{P_{(t-1),i}}$	=	Relatif Harga (RH) jenis barang/jasa $i$ pada bulan ke $t$
$P_{(t-1),i} Q_{o,i}$	=	Nilai konsumsi jenis barang/jasa ke- $i$ , periode ke- $(t-1)$
$P_{o,i} Q_{o,i}$	=	Nilai konsumsi jenis barang ke- $i$ pada tahun dasar
$g$	=	Jumlah jenis barang/jasa yang tercakup dalam paket komoditas IHK.

Badan Pusat Statistik (BPS) mendefinisikan inflasi sebagai kenaikan harga barang dan jasa secara umum dimana barang dan jasa tersebut merupakan kebutuhan pokok masyarakat atau inflasi merupakan turunnya daya jual mata

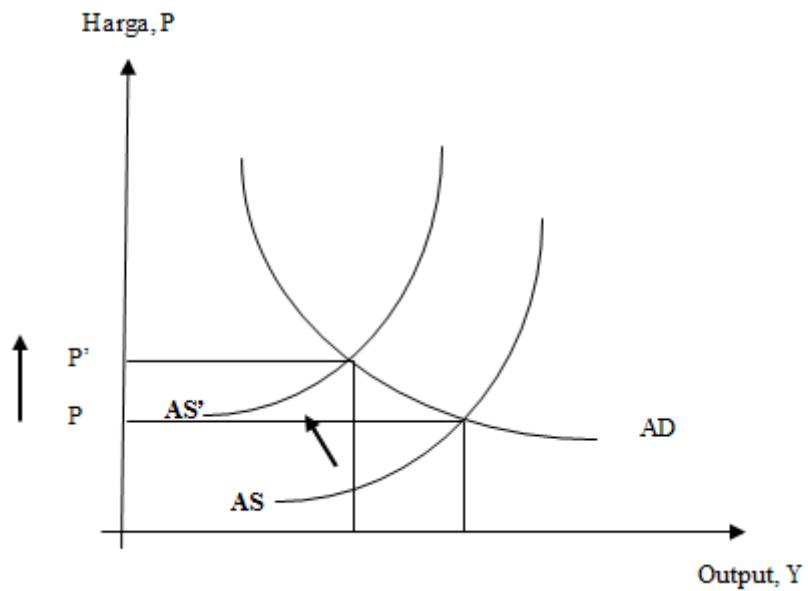
uang suatu negara. Tingkat inflasi berbeda antar periode. Penghitungan inflasi dapatkan dirumuskan sebagai berikut :

$$Inflasi_t = \frac{IHK_t - IHK_{t-1}}{IHK_{t-1}} 100\% \quad (2.94)$$

## 2.7 Bencana Alam

UU No.24 tahun 2007 tentang Penanggulangan Bencana mendefinisikan bencana sebagai peristiwa atau rangkaian peristiwa yang mengancam dan mengganggu kehidupan dan penghidupan masyarakat yang disebabkan, baik faktor alam maupun faktor non alam maupun faktor manusia sehingga mengakibatkan timbulnya korban jiwa manusia, kerusakan lingkungan, kerugian harta benda dan dampak psikologis (Supriyatna, 2011). Bencana alam menurut BPS (2011) merupakan peristiwa yang dapat membawa kerugian jiwa dan materil yang sangat besar sehingga berdampak luas pada kehidupan masyarakat di wilayah kejadian. Peristiwa alam dapat berupa banjir, letusan gunung berapi, gempa bumi, tsunami, tanah longsor, badai salju, kekeringan, hujan es, gelombang panas, hurikan, badai tropis, taifun, tornado, kebakaran liar dan wabah penyakit. Bencana alam ada yang tidak terjadi secara alami, artinya bencana tersebut terjadi karena kombinasi disebabkan oleh faktor manusia dan alam, contohnya adalah kebakaran hutan dan kelaparan.

Dari sisi analisis makroekonomi, bencana alam yang merusak fasilitas umum seperti jalan raya akan menyebabkan terhambatnya distribusi barang, sehingga terjadi *supply shock* yang menggeser kurva penawaran jangka pendek ke kiri. Itu berakibat kelangkaan pada barang maupun jasa. Kemudian terjadi kenaikan harga secara umum atau biasa disebut juga dengan inflasi (Supriyatna, 2011).



Gambar 2.4 Terjadinya *Supply Shock* pada Kurva Penawaran dan Permintaan

## BAB 3

### METODOLOGI PENELITIAN

Pada bab ini akan dijelaskan metodologi yang digunakan untuk mencapai tujuan penelitian, meliputi sumber data, variabel penelitian, dan metode analisis.

#### 3.1 Sumber Data

Sumber data yang digunakan merupakan data sekunder dari Badan Pusat Statistik (BPS). Data yang digunakan adalah data IHK kelompok bahan makanan bulanan periode Januari 2000 sampai dengan Desember 2015 di kota Padang, Pekanbaru, Jambi, Palembang, Bengkulu. Data IHK dibagi menjadi dua bagian, data *in-sample* mulai periode Januari 2000 sampai dengan Desember 2014, dan data *out-sample* periode Januari sampai dengan Desember 2015.

#### 3.2 Variabel Penelitian

Berdasarkan tujuan penelitian, maka variabel yang digunakan ada dua macam sebagai berikut :

1. Deret *Output*

Tabel 3.1 Struktur Data Deret Output

<b>t</b>	<b>Bulan</b>	<b>Tahun</b>	<b>Y<sub>1,t</sub></b>	<b>Y<sub>2,t</sub></b>	<b>Y<sub>3,t</sub></b>	<b>Y<sub>4,t</sub></b>	<b>Y<sub>5,t</sub></b>
1	1	2000	$Y_{1,1}$	$Y_{2,1}$	$Y_{3,1}$	$Y_{4,1}$	$Y_{5,1}$
2	2	2000	$Y_{1,2}$	$Y_{2,2}$	$Y_{3,2}$	$Y_{4,2}$	$Y_{5,2}$
:	:	:	:	:	:	:	:
6	6	2000	$Y_{1,6}$	$Y_{2,6}$	$Y_{3,6}$	$Y_{4,6}$	$Y_{5,6}$
:	:	:	:	:	:	:	:
12	12	2000	$Y_{1,12}$	$Y_{2,12}$	$Y_{3,12}$	$Y_{4,12}$	$Y_{5,12}$
:	:	:	:	:	:	:	:
192	12	2015	$Y_{1,192}$	$Y_{2,192}$	$Y_{3,192}$	$Y_{4,192}$	$Y_{5,192}$

- $Y_{1,t}$  = IHK kelompok Bahan Makanan Kota Padang  
 $Y_{2,t}$  = IHK kelompok Bahan Makanan Kota Pekanbaru  
 $Y_{3,t}$  = IHK kelompok Bahan Makanan Kota Jambi  
 $Y_{4,t}$  = IHK kelompok Bahan Makanan Kota Palembang  
 $Y_{5,t}$  = IHK kelompok Bahan Makanan Kota Bengkulu

## 2. Deret Input

### A. Variasi Kalender

Pada pemodelan variasi kalender akan dilakukan 2 (dua) skenario :

#### [1] Variasi kalender bulanan

$D_t$  = Variabel *dummy* bernilai 1 pada bulan hari raya Idul Fitri yang terjadi pada bulan ke- $t$  dan bernilai 0 pada bulan-bulan lainnya.

$D_{t-1}$  = Variabel *dummy* bernilai 1 pada satu bulan sebelum hari raya Idul Fitri yang terjadi pada bulan ke- $t$  dan bernilai 0 pada bulan-bulan lainnya.

#### [2] Variasi kalender mingguan

$D_{j,t}$  = Variabel *dummy* bernilai 1 pada bulan hari raya Idul Fitri yang terjadi pada minggu ke- $j$  dan bernilai 0 pada bulan-bulan lainnya.

$D_{j,t-1}$  = Variabel *dummy* bernilai 1 pada satu bulan sebelum hari raya Idul Fitri yang terjadi pada minggu ke- $j$  dan bernilai 0 pada bulan-bulan lainnya.

$$\text{dengan, } j = \begin{cases} 1, \text{ Minggu ke-1 (tanggal 1-7)} \\ 2, \text{ Minggu ke-2 (tanggal 8-15)} \\ 3, \text{ Minggu ke-3 (tanggal 16-23)} \\ 4, \text{ Minggu ke-4 (tanggal 24- terakhir)} \end{cases}$$

Penentuan pembagian minggu berdasarkan surat edaran Bank Indonesia. Dari rincian di atas, akan diperoleh variabel *dummy* hari raya Idul Fitri tahun 2000-2014 sebagai berikut :

Tabel 3.2 Variabel *Dummy* Hari Raya Idul Fitri

Tahun	Idul Fitri	Variabel Dummy	Tahun	Idul Fitri	Variabel Dummy
2000	8-9 Januari (M-2)	$D_{2,t} = \begin{cases} 1, & \text{bulan Januari} \\ 0, & \text{bulan lainnya} \end{cases}$	2008	1-2 Oktober (M-1)	
	26-27 Desember (M-4)	$D_{4,t} = \begin{cases} 1, & \text{bulan Desember} \\ 0, & \text{bulan lainnya} \end{cases}$			$D_{1,t} = \begin{cases} 1, & \text{bulan Oktober} \\ 0, & \text{bulan lainnya} \end{cases}$
		$D_{4,t-1} = \begin{cases} 1, & \text{bulan November} \\ 0, & \text{bulan lainnya} \end{cases}$			$D_{1,t-1} = \begin{cases} 1, & \text{bulan September} \\ 0, & \text{bulan lainnya} \end{cases}$
2001	16-17 Desember (M-3)	$D_{3,t} = \begin{cases} 1, & \text{bulan Desember} \\ 0, & \text{bulan lainnya} \end{cases}$	2009	20-21 September (M-3)	$D_{3,t} = \begin{cases} 1, & \text{bulan September} \\ 0, & \text{bulan lainnya} \end{cases}$
		$D_{3,t-1} = \begin{cases} 1, & \text{bulan November} \\ 0, & \text{bulan lainnya} \end{cases}$			$D_{3,t-1} = \begin{cases} 1, & \text{bulan Agustus} \\ 0, & \text{bulan lainnya} \end{cases}$
2002	5-6 Desember (M-1)	$D_{1,t} = \begin{cases} 1, & \text{bulan Desember} \\ 0, & \text{bulan lainnya} \end{cases}$	2010	10-11 September (M-2)	$D_{2,t} = \begin{cases} 1, & \text{bulan September} \\ 0, & \text{bulan lainnya} \end{cases}$
		$D_{1,t-1} = \begin{cases} 1, & \text{bulan November} \\ 0, & \text{bulan lainnya} \end{cases}$			$D_{2,t-1} = \begin{cases} 1, & \text{bulan Agustus} \\ 0, & \text{bulan lainnya} \end{cases}$
2003	25-26 November (M-4)	$D_{4,t} = \begin{cases} 1, & \text{bulan November} \\ 0, & \text{bulan lainnya} \end{cases}$	2011	30-31 Agustus (M-4)	$D_{4,t} = \begin{cases} 1, & \text{bulan Agustus} \\ 0, & \text{bulan lainnya} \end{cases}$
		$D_{4,t-1} = \begin{cases} 1, & \text{bulan Oktober} \\ 0, & \text{bulan lainnya} \end{cases}$			$D_{4,t-1} = \begin{cases} 1, & \text{bulan Juli} \\ 0, & \text{bulan lainnya} \end{cases}$
2004	13-14 November (M-2)	$D_{2,t} = \begin{cases} 1, & \text{bulan November} \\ 0, & \text{bulan lainnya} \end{cases}$	2012	19-20 Agustus (M-3)	$D_{3,t} = \begin{cases} 1, & \text{bulan Agustus} \\ 0, & \text{bulan lainnya} \end{cases}$
		$D_{2,t-1} = \begin{cases} 1, & \text{bulan Oktober} \\ 0, & \text{bulan lainnya} \end{cases}$			$D_{3,t-1} = \begin{cases} 1, & \text{bulan Juli} \\ 0, & \text{bulan lainnya} \end{cases}$
2005	3-4 November (M-1)	$D_{1,t} = \begin{cases} 1, & \text{bulan November} \\ 0, & \text{bulan lainnya} \end{cases}$	2013	8-9 Agustus (M-2)	$D_{2,t} = \begin{cases} 1, & \text{bulan Agustus} \\ 0, & \text{bulan lainnya} \end{cases}$
		$D_{1,t-1} = \begin{cases} 1, & \text{bulan Oktober} \\ 0, & \text{bulan lainnya} \end{cases}$			$D_{2,t-1} = \begin{cases} 1, & \text{bulan Juli} \\ 0, & \text{bulan lainnya} \end{cases}$
2006	24-25 Oktober (M-4)	$D_{1,t} = \begin{cases} 1, & \text{bulan Oktober} \\ 0, & \text{bulan lainnya} \end{cases}$	2014	28-29 Juli (M-4)	$D_{1,t} = \begin{cases} 1, & \text{bulan Juli} \\ 0, & \text{bulan lainnya} \end{cases}$
		$D_{1,t-1} = \begin{cases} 1, & \text{bulan September} \\ 0, & \text{bulan lainnya} \end{cases}$			$D_{1,t-1} = \begin{cases} 1, & \text{bulan Juni} \\ 0, & \text{bulan lainnya} \end{cases}$
2007	13-14 Oktober (M-2)	$D_{2,t} = \begin{cases} 1, & \text{bulan Oktober} \\ 0, & \text{bulan lainnya} \end{cases}$			
		$D_{2,t-1} = \begin{cases} 1, & \text{bulan September} \\ 0, & \text{bulan lainnya} \end{cases}$			

## B. Intervensi

Variabel intervensi yang digunakan ada tiga. Variabel intervensi I adalah kenaikan BBM Oktober 2005 ( $X_1$ ) yang merupakan fungsi *step*. Intervensi II dan III adalah gempa bumi Sumatera pada bulan September

2007 ( $X_2$ ) dan September 2009 ( $X_3$ ) yang merupakan fungsi *pulse*, dengan menetapkan  $b = 0$ ,  $s = 0$ ,  $r = 0$ .

### 3.3 Metode Analisis

Berdasarkan tujuan penelitian, maka tahapan dalam penelitian ini adalah melakukan permodelan pada data IHK di lima lokasi dengan menggunakan model ARIMA, ARIMAX (dengan variasi kalender dan intervensi), pemodelan GSTAR, dan GSTARX. Setelah pemodelan keempatnya, dilanjutkan dengan peramalan titik dan peramalan interval.

#### 3.3.1 Pemodelan ARIMA

Proses peramalan IHK dengan pemodelan ARIMA dilakukan sesuai dengan prosedur yang dilakukan oleh Box-Jenkins dimulai dari tahap identifikasi model, estimasi parameter, cek diagnosa dan peramalan. Tahapan yang dilakukan adalah sebagai berikut

1. Identifikasi stasioneritas varians dan rata-rata IHK pada masing-masing lokasi.
2. Identifikasi model dugaan sementara IHK masing-masing lokasi dengan melihat plot ACF dan PACF.
3. Estimasi parameter model IHK di masing-masing lokasi.
4. Melakukan pemeriksaan diagnosa apakah model telah sesuai yaitu memenuhi asumsi residual *white noise* dan berdistribusi normal.
5. Melakukan peramalan model ARIMA terbaik serta menghitung RMSE data *out-sample*.

#### 3.3.2 Pemodelan Variasi Kalender

Langkah pemodelan variasi kalender adalah sebagai berikut

1. Melakukan identifikasi variabel *dummy* berdasarkan periode variasi kalender dalam hal ini *dummy* hari raya Idul selama periode pengamatan.
2. Melakukan estimasi parameter dengan model regresi variasi kalender yang diberikan dengan bentuk

$$Z_{i,t} = f(D_{1,t}, D_{1,t-1}) + u_{i,t}. \quad (3.1)$$

3. Memodelkan residual hasil analisis regresi menggunakan ARIMA jika asumsi residual dari model regresi tidak memenuhi asumsi *white noise* (apabila residual dari model regresi sudah memenuhi asumsi *white noise* maka tidak perlu penambahan model ARIMA pada model regresi).

$$y_{i,t} = \delta_1 D_{t-1} + \delta_2 D_t + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} u_{i,t} \quad (3.2)$$

4. Melakukan pengecekan signifikansi parameter.
5. Melakukan pengecekan residual dari model yang terbentuk apakah sudah mencapai kondisi *white noise*.
6. Melakukan pengecekan residual dari model yang terbentuk apakah sudah berdistribusi normal
7. Melakukan peramalan model variasi kalender serta menghitung RMSE data *out-sample*.

### 3.3.3 Analisis Intervensi

Variabel intervensi dalam penelitian ini bersifat *pulse*, sehingga bisa didefinisikan bahwa nilai *impuls respons* menggunakan  $b=0$ ,  $s=0$  dan  $r=0$ .

- a. Melakukan pemodelan regresi dengan *dummy* (regresi *time series*)
- $$y_t = \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \varepsilon_t. \quad (3.3)$$
- b. Memodelkan residual hasil analisis regresi menggunakan ARIMA jika asumsi residual dari model regresi tidak memenuhi asumsi *white noise* (apabila residual dari model regresi sudah memenuhi asumsi *white noise* maka tidak perlu penambahan model ARIMA pada model regresi).
- c. Melakukan pengecekan signifikansi parameter.
- d. Melakukan pengecekan residual dari model yang terbentuk apakah sudah mencapai kondisi *white noise* dan berdistribusi normal.
- e. Melakukan peramalan model intervensi serta menghitung RMSE data *out-sample*.

### 3.3.4 Pemodelan GSTAR

Tahapan pemodelan GSTAR dilakukan menurut langkah-langkah berikut ini :

- a. Identifikasi stasioneritas dan pola data  $y_{i,t}$  yang diperoleh dengan menggunakan MCCF.
- b. Identifikasi orde waktu, AR( $p$ ) dari model  $y_{i,t}$  dengan menggunakan skematik MCCF dan AIC minimum.
- c. Menentukan bobot spasial yang digunakan, bobot spasial yang dipergunakan ditentukan dengan orde spasial satu ( $p_1$ ).
- d. Melakukan penghitungan nilai pembobot wilayah ( $\mathbf{W}^l$ ) menggunakan bobot seragam, invers jarak riil jarak tempuh transportasi darat, dan normalisasi inferensi parsial korelasi silang.
- e. Melakukan estimasi parameter dengan menggunakan orde  $p$  dari langkah (b) dengan model GSTAR-GLS.

$$\mathbf{y}(t) = \sum_{k=1}^p [\Phi_{k0}\mathbf{y}(t-k) + \Phi_{k1}\mathbf{W}^{(1)}\mathbf{y}(t-k)] + \mathbf{u}(t) \quad (3.4)$$

- f. Uji signifikansi parameter model GSTAR-GLS. Jika terdapat parameter-parameter yang tidak signifikan, dilakukan *restricted* dengan mengurangi variabel yang tidak signifikan.
- g. Mendapatkan model GSTAR-GLS.

Setelah diperoleh model GSTAR terbaik, maka selanjutnya dilakukan peramalan GSTAR dengan tahap sebagai berikut,

- a. Peramalan model GSTAR.
- b. *Diagnostic checking* hasil pemodelan GSTAR pada masing-masing lokasi dan bobot dengan pengujian residual yang *white noise* dengan menggunakan AIC yang terkecil.
- c. Menghitung nilai RMSE hasil pemodelan GSTAR masing-masing bobot pada data *out-sample*.
- d. Melakukan peramalan interval model GSTAR-GLS, dengan menggunakan perhitungan batas atas dan batas bawah sebagai berikut, pada GSTAR

$$\text{Batas bawah} = \widehat{\mathbf{Y}}_{i,n(k)} - N_{\frac{\alpha}{2}} \widehat{\sigma}(k)$$

$$\text{Batas atas} = \widehat{\mathbf{Y}}_{i,n(k)} + N_{\frac{\alpha}{2}} \widehat{\sigma}(k).$$

### 3.3.5 Pemodelan GSTARX

Tahapan pemodelan GSTARX dilakukan menurut langkah-langkah berikut ini :

1. Tahapan pertama adalah sebagai berikut:
  - a. Melakukan identifikasi model intervensi dan variasi kalender untuk masing-masing lokasi.
  - b. Melakukan estimasi parameter model intervensi dan variasi kalender untuk masing-masing lokasi.
  - c. Membentuk model persamaan regresi yang akan diestimasi, misal seperti pada persamaan (2.76).
  - d. Menghitung nilai residual  $u_{i,t}$  dari persamaan (2.76).
2. Tahapan kedua adalah sebagai berikut
  - h. Identifikasi stasioneritas dan pola data residual  $u_{i,t}$  yang diperoleh dengan menggunakan MCCF.
  - i. Identifikasi orde waktu, AR ( $p$ ) dari model  $u_{i,t}$  dengan menggunakan skematik MCCF dan AIC minimum
  - j. Menentukan bobot spasial yang digunakan, bobot spasial yang dipergunakan ditentukan dengan orde spasial satu ( $p_1$ ).
  - k. Melakukan penghitungan nilai pembobot wilayah ( $\mathbf{W}^l$ ) menggunakan bobot seragam, invers jarak riil jarak tempuh transportasi darat, dan normalisasi inferensia parsial korelasi silang.
  - l. Melakukan estimasi parameter dengan menggunakan orde  $p$  dari langkah (b) dengan model GSTARX-GLS.

$$\mathbf{u}(t) = \sum_{k=1}^p [\Phi_{k0} \mathbf{u}(t-k) + \Phi_{k1} \mathbf{W}^{(1)} \mathbf{u}(t-k)] + \mathbf{e}(t) \quad (3.5)$$

- m. Uji signifikansi parameter model GSTARX-GLS. Jika terdapat parameter-parameter yang tidak signifikan, dilakukan *restricted* dengan mengurangi variabel yang tidak signifikan.
- n. Mendapatkan model GSTARX-GLS.

### 3. Peramalan GSTARX

Pada tahap ini dilakukan langkah-langkah dalam pemodelan GSTARX yaitu sebagai berikut :

- Melakukan peramalan  $u_{i,t}$  dengan model GSTARX-GLS.

$$\hat{Y}_{i,t} = \hat{y}_{i,t} + \hat{u}_{i,t} \quad (3.6)$$

Level 1 :

$$\hat{y}_{i,t} = \delta_1 D_{t-1} + \delta_2 D_t + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3$$

Level 2 :

$$\hat{u}_{i,t} = \sum_{k=1}^p [\boldsymbol{\Phi}_{k0} \mathbf{u}(t-k) + \boldsymbol{\Phi}_{k1} \mathbf{W}^{(1)} \mathbf{u}(t-k)] + \boldsymbol{e}(t).$$

dimana,

$\hat{Y}_{i,t}$  : hasil ramalan ke- $t$  di lokasi ke- $i$  dari model GSTARX

$\hat{y}_{i,t}$  : hasil ramalan ke- $t$  di lokasi ke- $i$  di tahap I

$\hat{n}_{i,t}$  : hasil ramalan ke- $t$  di lokasi ke- $i$  di tahap II

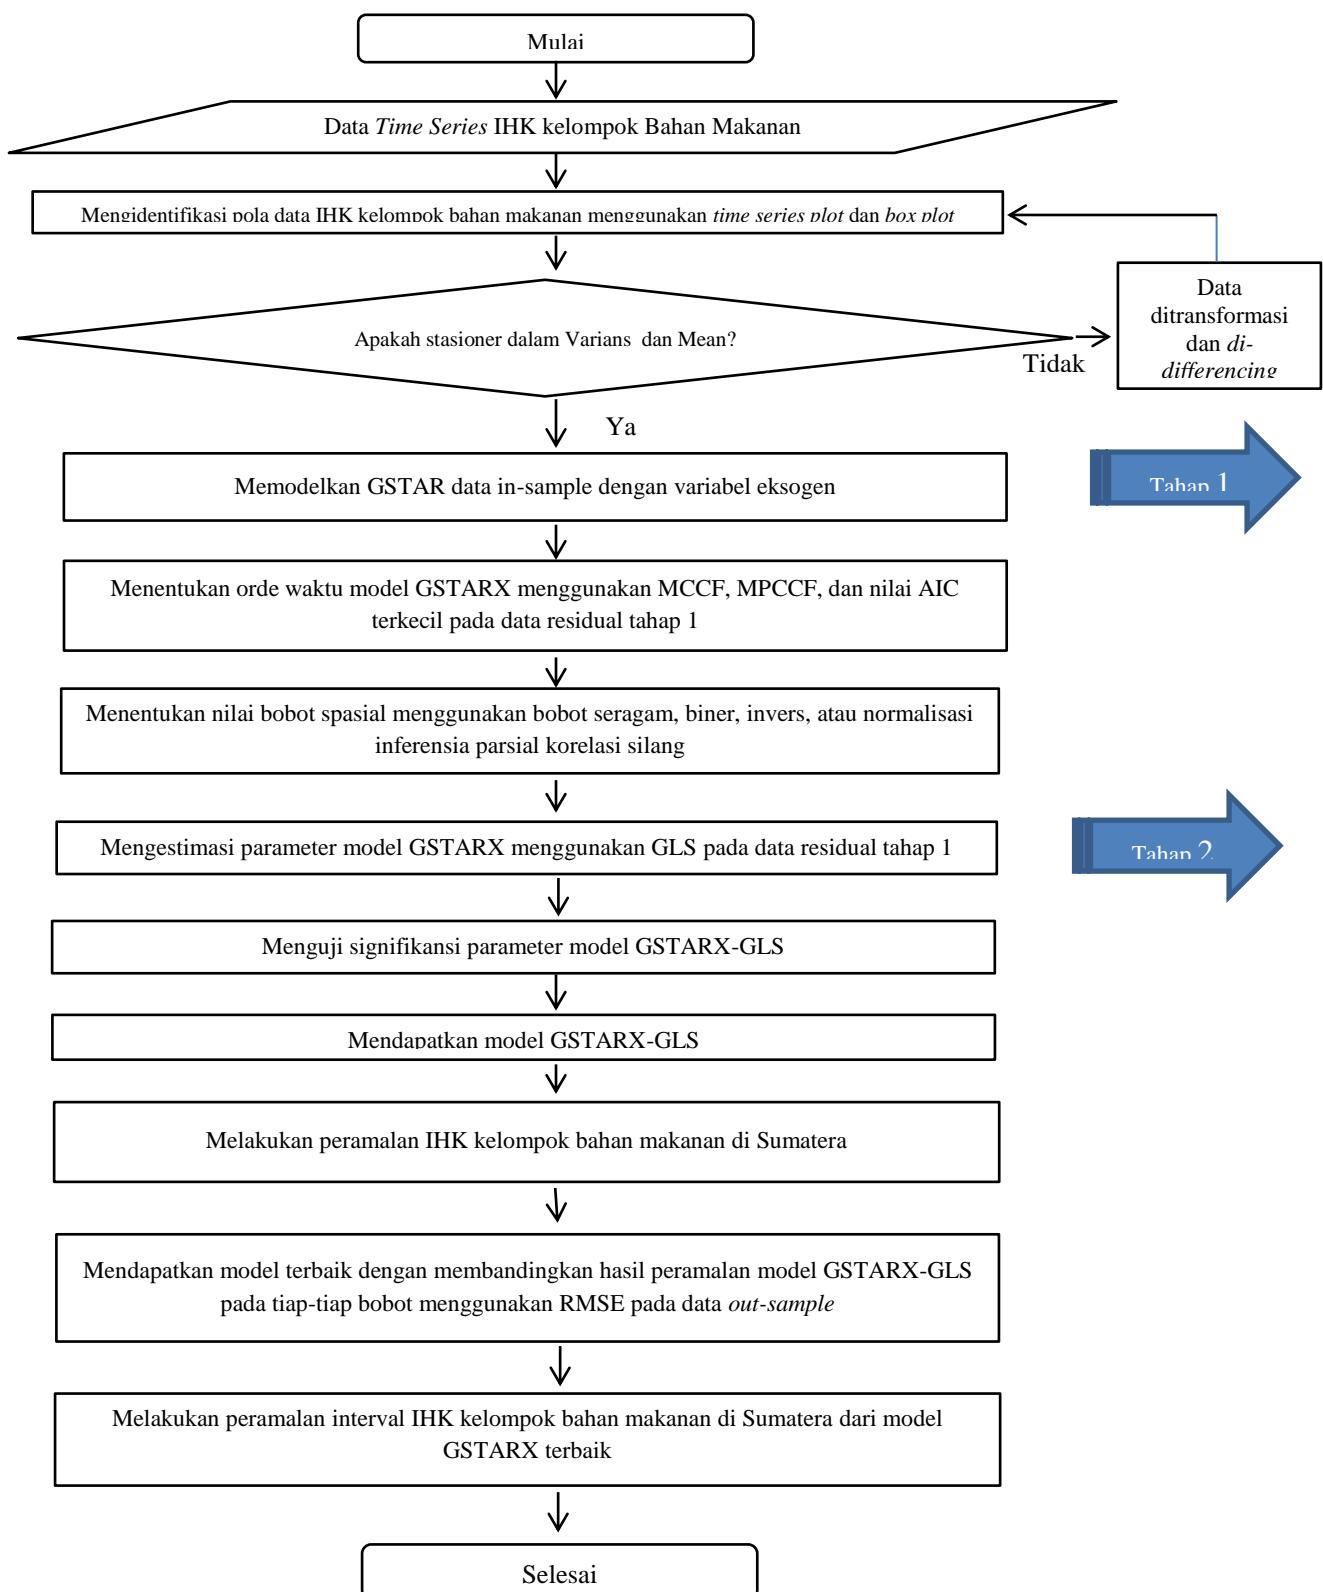
$i$  : banyaknya lokasi

$k$  : orde AR

- Diagnostic checking* hasil pemodelan GSTARX pada masing-masing lokasi dan bobot dengan pengujian residual yang *white noise* dengan menggunakan AIC yang terkecil.
- Menghitung nilai RMSE hasil pemodelan GSTARX masing-masing bobot pada data *out-sample*.
- Melakukan peramalan interval model GSTARX-GLS, dengan menggunakan perhitungan batas atas dan batas bawah sebagai berikut, pada GSTARX

$$\text{Batas bawah} = \hat{Y}_{i,n(k)} - N_{\frac{\alpha}{2}} \hat{\sigma}(k)$$

$$\text{Batas atas} = \hat{Y}_{i,n(k)} + N_{\frac{\alpha}{2}} \hat{\sigma}(k).$$



Gambar 3.1 Diagram Alir Analisis GSTARX



## **BAB 4**

### **HASIL DAN PEMBAHASAN**

Pada bagian ini akan diuraikan analisis pemodelan data IHK kelompok bahan makanan di kota Padang, Pekanbaru, Jambi, Palembang, dan Bengkulu. Pemodelan data tersebut dilakukan dengan analisis *time series* yaitu model ARIMA, model intervensi, dan model GSTARX dengan estimasi GLS. Pemodelan tersebut dilanjutkan dengan peramalan dengan interval.

#### **4.1 Karakteristik Data IHK di Sumatera**

Data yang digunakan dalam analisis ini adalah data IHK kelompok bahan makanan periode bulan Januari 2000 sampai dengan Desember 2015. Data bulan Januari 2000 sampai dengan Desember 2014 sebanyak 180 pengamatan digunakan sebagai data *in-sample*, dan data bulan Januari sampai Desember tahun 2015 sebagai data *out-sample*.

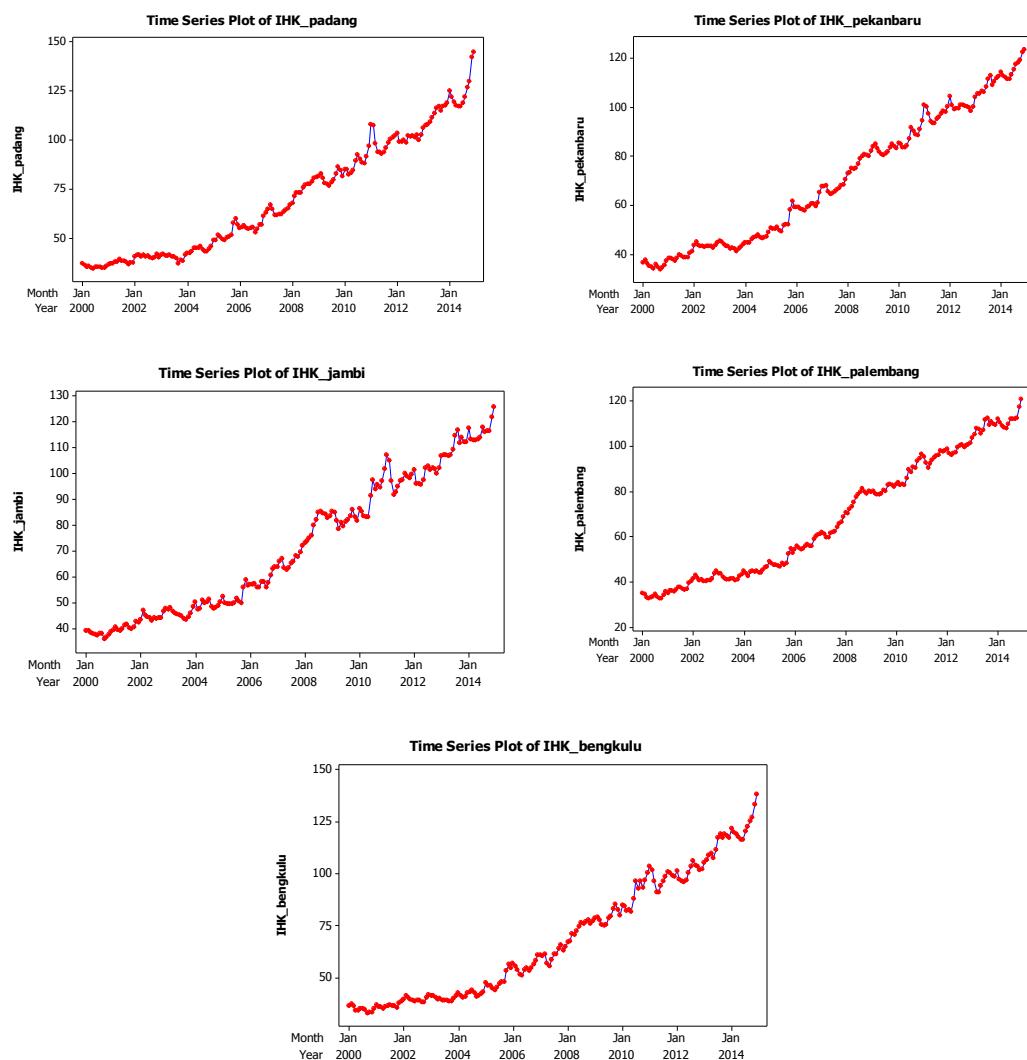
Data IHK kelompok bahan makanan pada lima kota di Pulau Sumatera bagian tengah dan selatan diantaranya adalah Kota Padang, Kota Pekanbaru, Kota Jambi, Kota Palembang, dan Kota Bengkulu. Masing-masing kota tersebut merupakan ibukota dari Provinsi Sumatera Barat, Riau, Jambi, Sumatera Selatan, dan Bengkulu.

Tabel 4.1 Statistik Deskriptif Data IHK Kelompok Bahan Makanan Lima Kota di Sumatera Tahun 2000-2014

Kota	Rata-rata	Standar Deviasi	Minimum	Maksimum
Padang	70,06	29,06	34,28	144,79
Pekanbaru	70,54	26,36	33,91	123,35
Jambi	71,57	26,31	35,87	125,70
Palembang	68,45	26,57	32,56	120,84
Bengkulu	69,06	29,35	32,97	138,40

Secara umum, statistik deskriptif untuk data IHK kelompok bahan makanan pada lima kota di Sumatera ditunjukkan pada Tabel 4.1. Berdasarkan tabel tersebut, diketahui selama Januari 2000 sampai dengan Desember 2014 nilai

rata-rata IHK kelompok bahan makanan di Padang sebesar 70,06, Pekanbaru sebesar 70,54, Jambi sebesar 71,57, Palembang sebesar 68,45, dan Bengkulu bernilai 69,06. Nilai variansi lima kota tersebut menunjukkan angka yang relatif tinggi, ini mengindikasikan fluktuasi kebutuhan konsumsi terutama bahan makanan masyarakat di masing-masing kota tersebut relatif tinggi. Hal lain juga disebabkan karena data IHK merupakan data indeks yang angkanya selalu naik di tiap periodenya (data tren).



Gambar 4.1 Plot *Time Series* Data IHK Kelompok Bahan Kakanan Lima Kota di Sumatera

Gambar 4.1 menunjukkan bahwa pergerakan IHK kelompok bahan makanan selama tahun 2000 sampai dengan tahun 2014 mengalami peningkatan

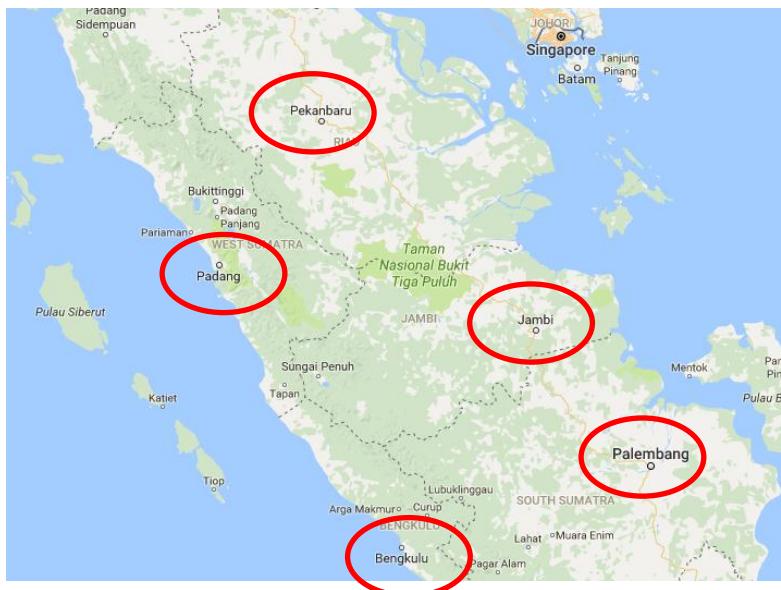
pada setiap periode. Pergerakan data pada masing-masing kota terjadi secara beriringan dan cenderung memiliki pola yang sama, dimana terdapat kecenderungan adanya peningkatan ataupun penurunan di suatu kota hampir pasti juga terjadi pada kota lainnya. Hal ini menunjukkan bahwa fenomena perubahan harga barang dan jasa pada lima kota IHK di Sumatera memiliki karakteristik yang hampir sama.

Nilai korelasi IHK antar kota dapat digunakan untuk mengetahui besar kecilnya kecenderungan hubungan IHK antar kota. Hasil penghitungan korelasi IHK antar kota seperti terlihat pada **Tabel 4.2**.

Tabel 4.2 Nilai Korelasi Data IHK Kelompok Bahan Makanan di Sumatera

Kota	Padang	Pekanbaru	Jambi	Palembang	Bengkulu
<b>Padang</b> <i>p-value</i>	1	0,995 (0,000)	0,993 (0,000)	0,992 (0,000)	0,997 (0,000)
<b>Pekanbaru</b> <i>p-value</i>	0,995 (0,000)	1	0,996 (0,000)	0,998 (0,000)	0,994 (0,000)
<b>Jambi</b> <i>p-value</i>	0,993 (0,000)	0,996 (0,000)	1	0,998 (0,000)	0,996 (0,000)
<b>Palembang</b> <i>p-value</i>	0,992 (0,000)	0,998 (0,000)	0,998 (0,000)	1	0,995 (0,000)
<b>Bengkulu</b> <i>p-value</i>	0,997 (0,000)	0,994 (0,000)	0,996 (0,000)	0,995 (0,000)	1

Pada Tabel 4.2 menunjukkan bahwa antar IHK lima kota di Sumatera mempunyai nilai korelasi yang tinggi. Hal ini mengindikasikan bahwa terjadi keterkaitan data IHK kelompok bahan makanan antar kota pada orde waktu yang sama. Nilai korelasi IHK antar wilayah ini mendukung pernyataan sebelumnya yang menyatakan bahwa IHK antar lokasi yang berdekatan saling memiliki keterkaitan yang tinggi. Lokasi kelima wilayah yang saling berdekatan ditunjukkan pada Gambar 4.2 Lima wilayah tersebut terdapat pada lokasi yang berdekatan yaitu pada bagian selatan dan tengah pulau Sumatera. Selain terletak di lokasi yang berdekatan, kelima wilayah tersebut memiliki juga memiliki karakteristik yang hampir sama. Kelimanya memiliki kebudayaan melayu yang cukup kuat, hal tersebut berpengaruh pada pola konsumsi di lima daerah tersebut.



Gambar 4.2 Peta Lokasi Penelitian di Lima Kota IHK di Sumatera

Jalan raya lintas Sumatera merupakan jalur perhubungan darat yang terpenting di Sumatera. Ini dikarenakan jalur kereta api hanya ada di Provinsi Sumatera Utara, Sumatera Barat, Sumatera Selatan, dan Lampung. Berikut ini jarak antar lima kota di Sumatera dalam penelitian ini dengan menggunakan jarak tempuh kendaraan dengan transportasi darat yang semuanya diukur dengan menggunakan aplikasi *Google Maps*.

Tabel 4. 3 Jarak Tempuh Kendaraan dengan Jalur Darat Antar Lokasi Kota-kota di Sumatera

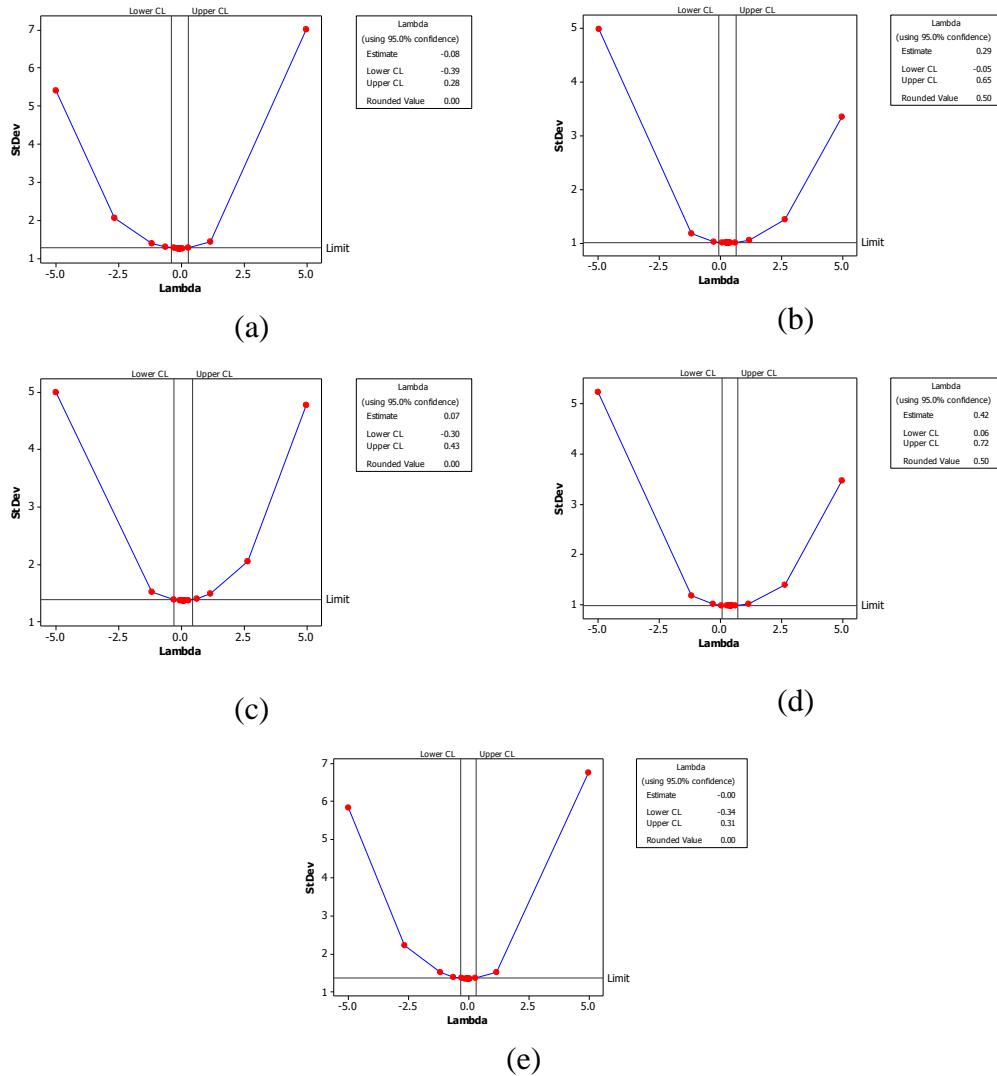
Lokasi	Jarak (km)				
	Padang	Pekanbaru	Jambi	Palembang	Bengkulu
Padang	0	310	617	884	709
Pekanbaru	310	0	454	736	752
Jambi	617	454	0	283	447
Palembang	884	736	283	0	433
Bengkulu	709	752	447	433	0

Sumber : [www.google.co.id/maps](http://www.google.co.id/maps) (diolah)

## 4.2 Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan di Sumatera

Prosedur dalam pemodelan ARIMA pada IHK kelompok bahan makanan lima kota di Sumatera menggunakan prosedur Box-Jenkins. Tahapannya berupa identifikasi data, estimasi parameter, cek diagnosa model, dan peramalan.

Tahap identifikasi pada pemodelan ARIMA dilakukan untuk mengetahui stasioneritas data baik pada varians maupun rata-rata. Identifikasi stasioneritas data dalam varians dapat dilihat dari plot Box-Cox. Identifikasi plot Box-Cox ada data IHK kelompok bahan makanan pada kelima lokasi menunjukkan semuanya belum stasioner pada varians ditunjukkan pada Gambar 4. 3.

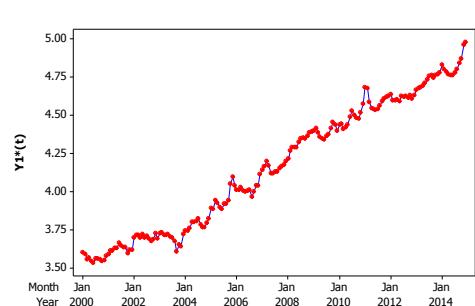


Gambar 4. 3 Plot Box-Cox Data IHK Kelompok Bahan Makanan

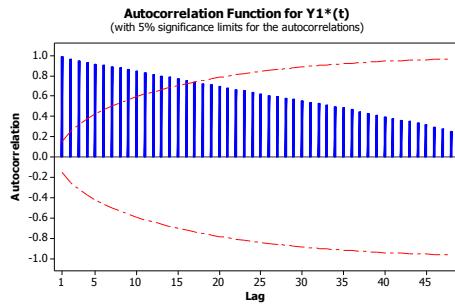
(a) Padang, (b) Pekanbaru, (c) Jambi, (d) Palembang, (e) Bengkulu

Maka dilakukan transformasi pada semua data IHK tersebut. Untuk keseragaman, transformasi yang dilakukan adalah transformasi *logaritma natural* (*ln*).

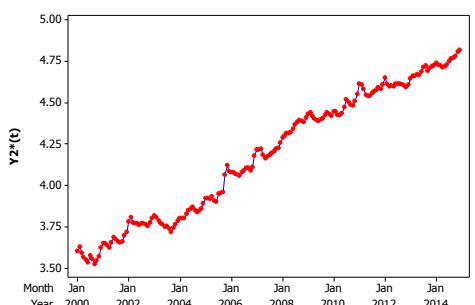
Setelah data ditransformasi, selanjutnya dilakukan identifikasi pada data untuk memeriksa stasioner dalam *mean* dengan melihat plot *time series* dan plot ACF. Data dikatakan sudah stasioner dalam *mean* jika pada plot *time series* menunjukkan pola rata-rata yang tetap dan tidak dipengaruhi oleh waktu. Plot ACF menunjukkan pola turun cepat dan segera *cut off* pada lag tertentu.



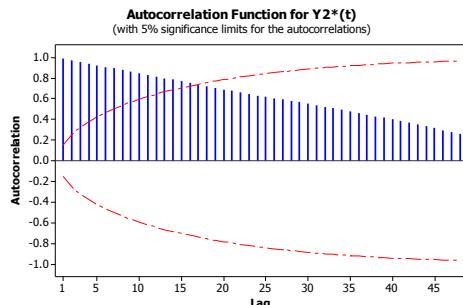
(a)



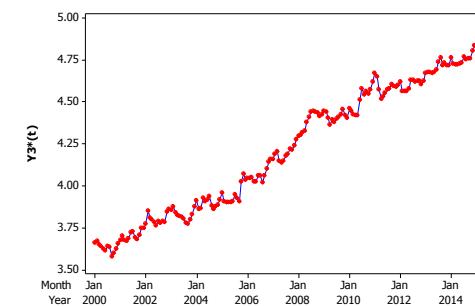
(a)



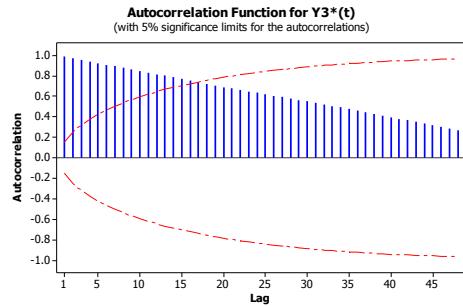
(b)



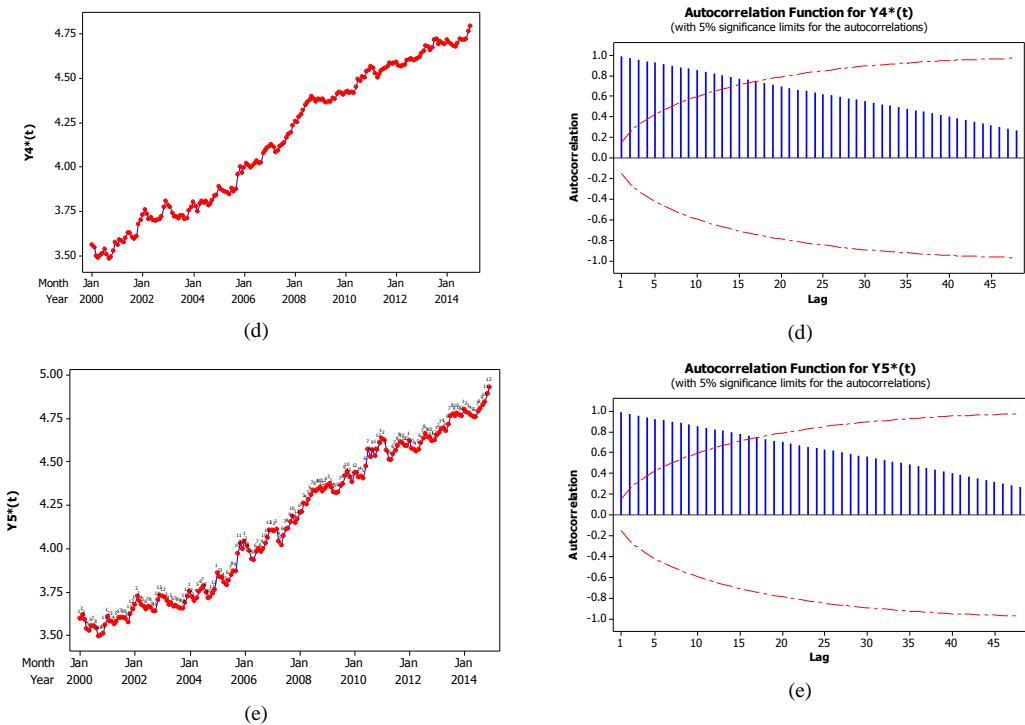
(b)



(c)

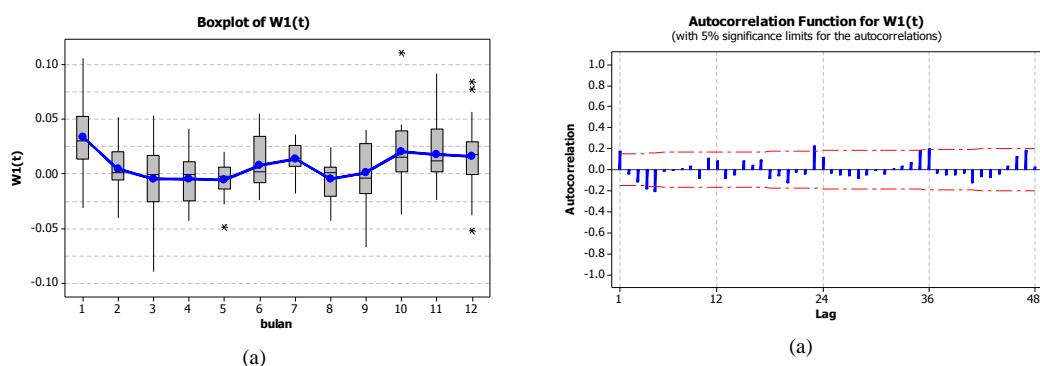


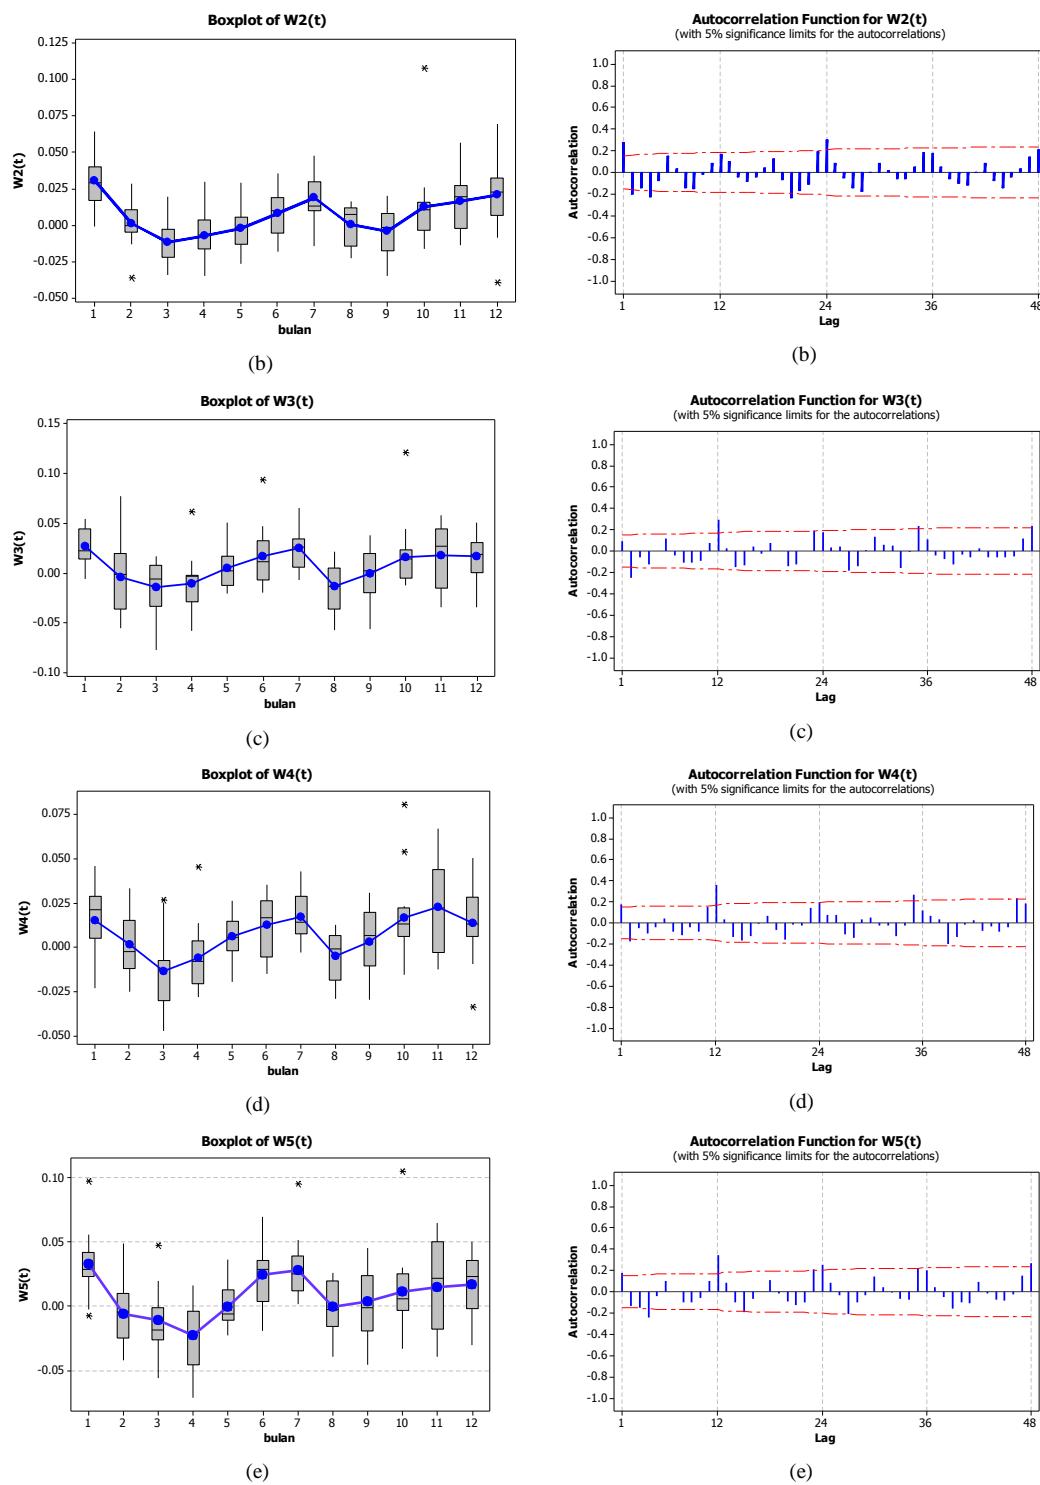
(c)



Gambar 4.4 Plot *Time Series* dan Plot ACF Data IHK Transformasi  
 (a) Padang, (b) Pekanbaru, (c) Jambi, (d) Palembang, (e) Bengkulu

Berdasarkan **Gambar 4.4**, data IHK belum stasioner dalam *mean* karena pada plot *time series* menunjukkan pola rata-rata yang meningkat (tren naik) seiring dengan berjalananya waktu. Pada plot ACF menunjukkan pola turun lamban dan tidak segera *cut off* pada lag tertentu. Maka, data IHK perlu dilakukan *differencing* 1. Setelah dilakukan differencing 1, maka diidentifikasi kembali menggunakan box-plot yang ditunjukkan pada Gambar 4.5.

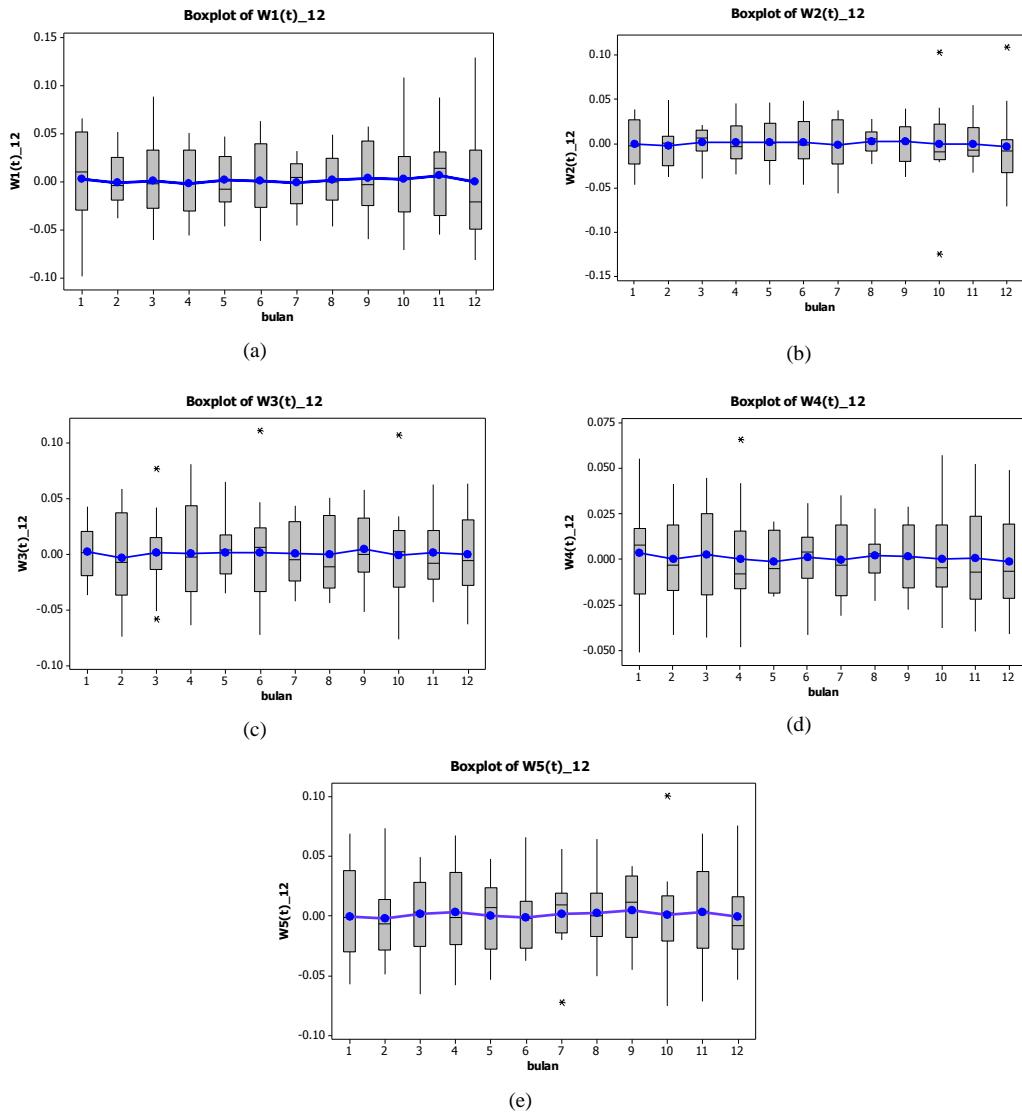




Gambar 4.5 Boxplot dan Plot ACF Data IHK Differencing 1  
 (a) Padang, (b) Pekanbaru, (c) Jambi, (d) Palembang, (e) Bengkulu

Dengan menggunakan boxplot dapat kita putuskan apakah data sudah stasioner dalam mean atau belum. Berdasarkan Gambar 4.5, boxplot pada ke lima

lokasi menunjukkan data belum stasioner pada *mean*. Sedangkan dari plot ACF, terlihat lag musiman (12) signifikan. Hal ini menunjukkan masih diperlukan *differencing* 12 untuk mendapatkan data yang stasioner pada *mean*.



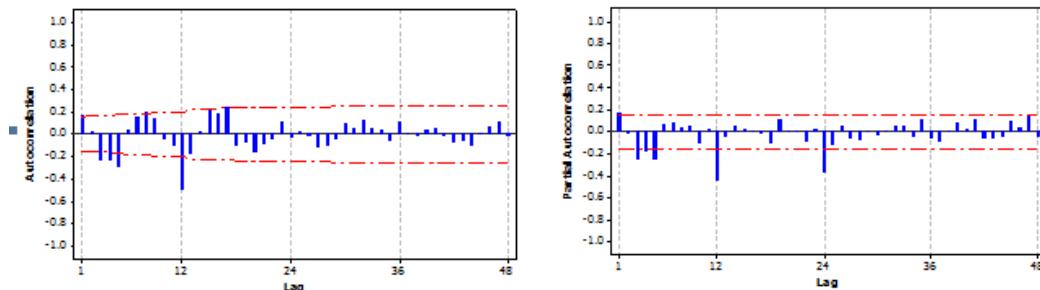
Gambar 4.6 Boxplot Data IHK *Differencing* 12  
 (a) Padang, (b) Pekanbaru, (c) Jambi, (d) Palembang, (e) Bengkulu

Dengan menggunakan boxplot seperti terlihat pada **Gambar 4.6**, data IHK pada kelima lokasi yang telah di-*differencing* 1 dan 12 sudah stasioner pada *mean*. Setelah data stasioner dalam varians dan *mean*, selanjutnya dapat dilakukan proses penentuan orde model ARIMA sementara.

#### 4.2.1 Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan Kota Padang

##### A. Pemodelan ARIMA Kota Padang

Setelah dilakukan *differencing* 1 dan 12, terlihat dari **Gambar 4.6** bahwa data telah stasioner dalam *mean*. Setelah data stasioner dalam varians dan *mean*, maka selanjutnya dilakukan proses penentuan orde model ARIMA sementara.



Gambar 4.7 Plot ACF dan PACF data IHK Kota Padang

Gambar 4.7 merupakan plot dari data IHK Kota Padang yang telah stasioner baik dalam varians maupun *mean*. Pada plot ACF memperlihatkan pola *dies down* dan *cut off* pada lag tertentu. Ini juga merupakan indikasi bahwa data tersebut sudah stasioner. Orde model ARIMA masing-masing kota dapat ditentukan berdasarkan lag-lag yang signifikan pada plot ACF dan PACF. Identifikasi lag yang signifikan pada plot ACF terjadi pada lag 1,3,4,5,8,12,17. Sedangkan pada plot PACF lag yang signifikan ada pada lag 1,3,4,5,12,24. Dari lag-lag yang signifikan tersebut selanjutnya dibuat beberapa alternatif model ARIMA, yang ditunjukkan pada **Tabel 4.4**.

Tabel 4.4 Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Padang

Model ARIMA	AIC
([4], 1, [4])(0,1,1) <sup>12</sup>	-692,015
([4], 1, [4, 5])(0, 1, 1) <sup>12</sup>	<b>-696,410</b>

Dari alternatif model diperoleh model ARIMA  $([4], 1, [4,5])(0,1,1)^{12}$  sebagai model terbaik dengan nilai AIC sebesar -696,410. Model terbaik yang terpilih selanjutnya digunakan untuk mengestimasi parameter pada pemodelan IHK Kelompok Bahan Makanan Kota Padang. Hasil pengujian signifikansi parameter ditunjukkan pada Tabel 4.5 berikut ini.

Tabel 4.5 Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Padang

Parameter	Estimasi	Standar Error	t-value	p-value	Lag
$\theta_4$	-0,6711	0,1620	-4,14	<0,0001	4
$\theta_5$	0,1749	0,0704	2,49	0,0139	5
$\Theta_1$	0,7946	0,0509	15,61	<0,0001	12
$\phi_4$	-0,7400	0,1549	-4,78	<0,0001	4

Berdasarkan Tabel 4.5 menunjukkan bahwa dengan taraf signifikansi  $\alpha=0,05$  seluruh parameter signifikan karena memiliki *p-value* kurang dari 0,05, sehingga seluruh parameter dapat digunakan dalam model. Secara matematis, model ARIMA  $([4], 1, [4,5])(0,1,1)^{12}$  IHK Kota Padang dapat dituliskan sebagai berikut:

$$y_{1,t} = \frac{(1 + 0,6711 B^4 - 0,1749B^5)(1 - 0,7946B^{12})}{(1 - B)(1 - B^{12})(1 + 0,74 B^4)} a_{1,t},$$

dengan  $y_{1,t} = \ln(Y_{1,t})$ .

Tabel 4.6 Hasil Pengujian Residual White Noise Model ARIMA data IHK Kelompok Bahan Makanan Kota Padang

Model ARIMA	Lag	Chi-Square	DF	p-value
$([4], 1, [4,5])(0,1,1)^{12}$	6	4,83	2	0,0892
	12	10,56	8	0,2278
	18	20,9	14	0,1043
	24	26,63	20	0,1459

Langkah selanjutnya adalah melakukan *diagnostic checking* untuk melihat kesesuaian model yaitu residual memenuhi asumsi *white noise* dan berdistribusi normal. Taraf signifikansi yang digunakan pada kedua uji ini sebesar  $\alpha=0,05$ . Hasil pengujian asumsi residual *white noise* dapat dilihat pada Tabel 4.6.

Hasil uji residual *white noise* pada Tabel 4.6 menunjukkan bahwa autokorelasi residual model ARIMA  $([4], 1, [4,5])(0,1,1)^{12}$  memiliki nilai *p-value* yang lebih besar dari 0,05 berarti bahwa autokorelasi tidak signifikan atau tidak terdapat korelasi antar lag sehingga asumsi residual *white noise* sudah terpenuhi.

Uji normalitas residual pada model ARIMA  $([4], 1, [4,5])(0,1,1)^{12}$  dilakukan dengan menggunakan uji Kolmogorov-Smirnov. Hasil uji Kolmogorov-Smirnov menghasilkan nilai uji sebesar 0,051161 dengan *p-value* sebesar  $>0,1500$ . Dengan taraf signifikansi  $\alpha=0,05$  memiliki nilai *p-value* yang lebih besar dari 0,05 yang berarti bahwa model ARIMA  $([4], 1, [4,5])(0,1,1)^{12}$  sudah memenuhi asumsi residual berdistribusi normal.

## B. Pemodelan Variasi Kalender Kota Padang

Pada pemodelan variasi kalender dilakukan 2 skenario pemodelan yaitu, skenario 1 dengan *dummy* bulanan dan skenario 2 *dummy* mingguan.

Tabel 4.7 Hasil Estimasi Parameter Model Variasi Kalender Kota Padang

Model	Parameter	Estimasi	Standar Error	<i>p-value</i>	variabel
Skenario 1 $([4], 1, [4,5])(0,1,1)^{12}$	$\theta_4$	-0,6711	0,1620	<0,0001	
	$\theta_5$	0,1749	0,0704	0,0139	
	$\Theta_1$	0,7946	0,0509	<0,0001	
	$\phi_4$	-0,7400	0,1549	<0,0001	
Skenario 2 $([4], 1, [4,5])(0,1,1)^{12}$	$\theta_4$	-0,6972	0,1562	<0,0001	
	$\theta_5$	0,1640	0,0693	0,0191	
	$\Theta_1$	0,7954	0,0512	<0,0001	
	$\phi_4$	-0,7661	0,1477	<0,0001	
	$\delta_{1,t-1}$	0,0240	0,0112	0,033	$d_{1,t-1}$

Hasil pengujian signifikansi parameter keduanya ditunjukkan pada data IHK kelompok bahan makanan Kota Padang dengan pemodelan variasi kalender bulanan (skenario 1) tidak ada yang signifikan pada variabel *dummy*-nya, sehingga model variasi kalender bulanan akan sama dengan model ARIMA. Ini berarti terjadinya hari raya Idul Fitri maupun bulan suci ramadhan tidak berpengaruh pada kenaikan IHK pada bulan terjadinya hari raya Idul Fitri.

Sedangkan pada variasi kalender mingguan (skenario 2), ketika bulan suci ramadhan jatuh pada minggu pertama, maka IHK kelompok bahan makanan akan mengalami kenaikan pada satu bulan setelah ramadhan. Model variasi kalender mingguan dapat dituliskan modelnya sebagai berikut,

$$y_{1,t} = 0,024 d_1 t_1 + \frac{(1 + 0,6972 B^4 - 0,164B^5)(1 - 0,7954 B^{12})}{(1 - B)(1 - B^{12})(1 + 0,7661 B^4)} a_{1,t}$$

### C. Pemodelan Intervensi Kota Padang

Berikutnya dilakukan pemodelan intervensi yaitu dengan penambahan variabel eksogen berupa kenaikan BBM bulan Oktober 2005 dan bencana gempa bumi pada tiap-tiap daerah.

Tabel 4.8 Hasil Estimasi Parameter Model Intervensi Kota Padang

Model	Parameter	Estimasi	Standar Error	p-value	variabel
$([4], 1, [4,5])(0,1,1)^{12}$	$\theta_4$	-0,6177	0,2060	0,0031	
	$\theta_5$	0,1515	0,0726	0,0384	
	$\Theta_1$	0,8066	0,0504	<0,0001	
	$\phi_4$	-0,7084	0,1910	0,0003	
	$\beta_1$	0,0920	0,0270	0,0008	$X_1$

Dari hasil pemodelan intervensi, hanya variabel  $X_1$  (kenaikan BBM) yang berpengaruh kepada kenaikan IHK bahan makanan di kota Padang, sedangkan bencana tidak berpengaruh secara signifikan. Hal ini menunjukkan bahwa kenaikan harga BBM berpengaruh terhadap kenaikan harga-harga bahan makanan. Sedangkan bencana alam berupa gempa bumi, meskipun menimbulkan kerusakan terutama jalan raya yang menghubungkan antar lokasi di Provinsi

Sumatera Barat dan dengan provinsi lain, namun tidak secara signifikan meningkatkan IHK kelompok bahan makanan. Pemodelan intervensi kota Padang dapat dituliskan sebagai berikut,

$$y_{1,t} = 0,092 X_1 + \frac{(1 + 0,6177 B^4 - 0,1515 B^5)(1 - 0,8066 B^{12})}{(1 - B)(1 - B^{12})(1 + 0,7084 B^4)} a_{1,t}$$

#### D. Pemodelan ARIMAX Kota Padang

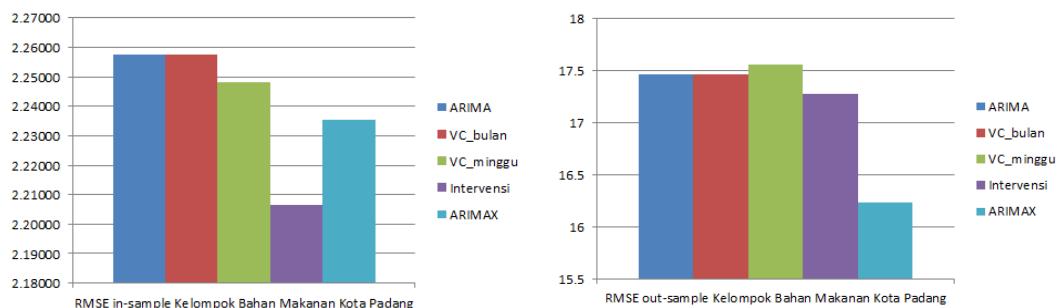
Pada pemodelan ARIMAX yang variabel eksogennya berupa gabungan antara *dummy* dari variasi kalender mingguan, intervensi kenaikan BBM, dan bencana gempa bumi, akan menghasilkan estimasi paramater seperti yang ditunjukkan pada Tabel 4.9 berikut,

Tabel 4.9 Hasil Estimasi Parameter Model ARIMAX Kota Padang

Model	Parameter	Estimasi	Standar Error	p-value	variabel
$(0,1,[5])(0,1,1)^{12}$	$\theta_5$	0,224	0,079	0,0051	
	$\Theta_1$	0,820	0,048	<0,0001	
	$\beta_1$	0,099	0,027	0,0003	$X_1$

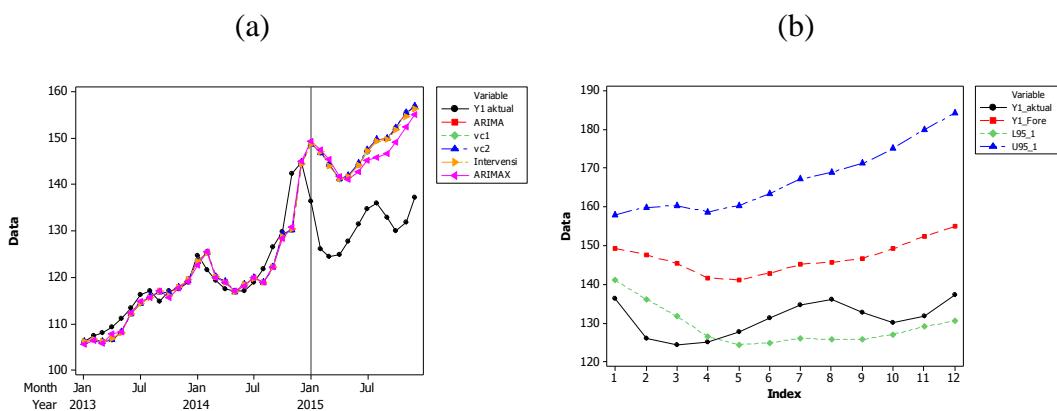
Model ARIMAX kota Padang dapat dituliskan sebagai berikut,

$$y_{1,t} = 0,099 X_1 + \frac{(1 - 0,224 B^5)(1 - 0,82 B^{12})}{(1 - B)(1 - B^{12})} a_{1,t}$$



Gambar 4. 8 RMSE *In-Sample* dan *Out-Sample* IHK di Kota Padang

Model ARIMA dengan penambahan variabel eksogen (kenaikan harga BBM) lebih efisien daripada model ARIMA tanpa variabel eksogen, hal ini terlihat dari menurunnya nilai RMSE *in-sample* setelah penambahan variabel eksogen. Sedangkan kriteria model terbaik berdasarkan nilai RMSE *out-sample* minimum, yaitu model ARIMAX dengan variabel eksogen kenaikan harga BBM. Variabel eksogen kenaikan harga BBM yang dimodelkan bersama dengan data IHK kelompok bahan makanan di Kota Padang ternyata mampu meningkatkan akurasi model. Sedangkan variabel bencana tidak signifikan berpengaruh terhadap IHK.



Gambar 4.9 Hasil Ramalan Model Univariat IHK Kota Padang

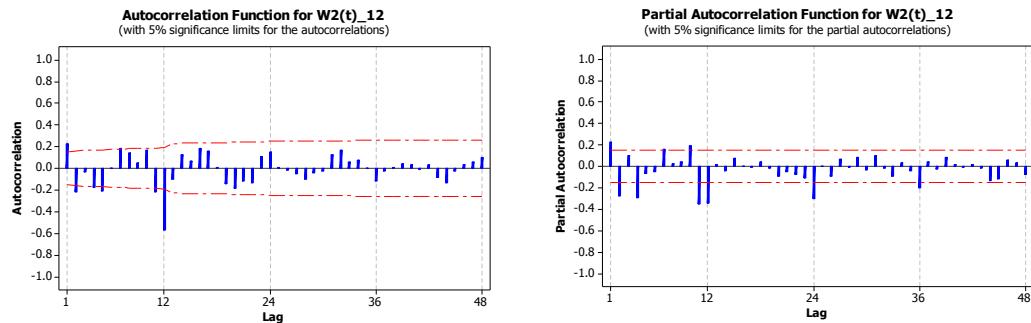
- (a) Ramalan Titik
- (b) Ramalan Interval Model Terbaik (ARIMAX)

Pada Gambar 4.9 merupakan ramalan model ARIMA, variasi kalender, intervensi, dan ARIMAX serta dibandingkan dengan data aktualnya. Ramalan dari model yang terbentuk berada cukup jauh di atas data aktual. Hal ini disebabkan kesalahan penentuan data *out-sample*, dimana data aktual dalam keadaan tidak stabil, sehingga hasil peramalannya menjadi jauh dari data aktual.

#### 4.2.2 Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan Kota Pekanbaru

## A. Pemodelan ARIMA Kota Pekanbaru

Setelah dilakukan *differencing* 1 dan 12, data telah stasioner dalam *mean*. Setelah data stasioner dalam varians dan *mean*, maka selanjutnya dilakukan proses penentuan orde model ARIMA sementara.



Gambar 4.10 Plot ACF dan PACF Data IHK Kota Pekanbaru

Gambar 4.10 merupakan plot ACF dan PACF dari data IHK Kota Pekanbaru yang telah stasioner baik dalam varians maupun *mean*. Pada plot ACF memperlihatkan pola *dies down* dan *cut off* pada lag tertentu. Ini juga merupakan indikasi bahwa data tersebut sudah stasioner. Orde model ARIMA masing-masing kota dapat ditentukan berdasarkan lag-lag yang signifikan pada plot ACF dan PACF. Identifikasi lag non-musiman yang signifikan pada plot ACF terjadi pada lag 1,2,4,5,7,11 dan pada plot PACF 1,2,4,7,11. Sedangkan pada musiman, lag yang signifikan pada plot ACF pada 12, pada plot PACF *dies down*.

Tabel 4.10 Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Pekanbaru

Model ARIMA	AIC
$([1,2,4], 1,0)(0,1,1)^{12}$	-821,88
$(0,1,2)(0,1,1)^{12}$	<b>-823,694</b>
$(2,1,0)(0,1,1)^{12}$	-818,479

Berdasarkan nilai AIC yang minimum pada Tabel 4.10 menunjukkan bahwa model ARIMA  $(0,1,2)(0,1,1)^{12}$  sebagai model terbaik dengan nilai AIC sebesar -823,694. Model terbaik yang terpilih selanjutnya digunakan untuk

mengestimasi parameter pada pemodelan IHK kelompok bahan makanan Kota Pekanbaru. Hasil pengujian signifikansi parameter ditunjukkan pada Tabel 4.11.

Berdasarkan Tabel 4.11 menunjukkan bahwa dengan taraf signifikansi  $\alpha = 0,05$  seluruh parameter signifikan karena memiliki *p-value* kurang dari 0,05, sehingga seluruh parameter dapat digunakan dalam model.

Tabel 4.11 Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Pekanbaru

Parameter	Estimasi	Standar Error	t-value	p-value	Lag
$\theta_1$	-0,2566	0,0753	-3,41	0,0008	1
$\theta_2$	0,2729	0,0755	3,61	0,0004	2
$\Theta_1$	0,7283	0,0546	13,34	<0,0001	12

Secara matematis, model ARIMA  $(0,1,2)(0,1,1)^{12}$  IHK Kota Pekanbaru dapat dituliskan sebagai berikut:

$$y_{2,t} = \frac{(1 + 0,2566 B - 0,2729 B^2)(1 - 0,7283 B^{12})}{(1 - B)(1 - B^{12})} a_{2,t},$$

dengan  $y_{2,t} = \ln(Y_{2,t})$ .

Langkah selanjutnya adalah melakukan cek diagnosa untuk melihat kesesuaian model yaitu residual memenuhi asumsi *white noise* dan berdistribusi normal. Taraf signifikansi yang digunakan pada kedua uji ini sebesar  $\alpha=0,05$ . Hasil pengujian asumsi residual *white noise* dapat dilihat pada

Tabel 4.12 Hasil Pengujian Residual *White Noise* Model ARIMA Data IHK Kelompok Bahan Makanan Kota Pekanbaru

Model ARIMA	Lag	Chi-Square	DF	p-value
$(0,1,2)(0,1,1)^{12}$	6	3,45	3	0,3269
	12	10,48	9	0,3131
	18	17,38	15	0,2967
	24	30,75	21	0,0779

Hasil uji residual *white noise* pada Tabel 4.12 menunjukkan bahwa autokorelasi residual model ARIMA (0,1,2)(0,1,1)<sup>12</sup> memiliki nilai *p-value* yang lebih besar dari 0,05 berarti bahwa autokorelasi tidak signifikan atau tidak terdapat korelasi antar lag sehingga asumsi residual *white noise* sudah terpenuhi.

Uji normalitas residual pada model ARIMA (0,1,2)(0,1,1)<sup>12</sup> dilakukan dengan menggunakan uji Kolmogorov-Smirnov. Hasil uji Kolmogorow-Smirnow menghasilkan nilai uji sebesar 0,05226 dengan *p-value* sebesar >0,1500. Dengan taraf signifikansi  $\alpha=0,05$  memiliki nilai *p-value* yang lebih besar dari 0,05 yang berarti bahwa model ARIMA (0,1,2)(0,1,1)<sup>12</sup> sudah memenuhi asumsi residual berdistribusi normal.

## B. Pemodelan Variasi Kalender Kota Pekanbaru

Tabel 4.13 Hasil Estimasi Parameter Model Variasi Kalender Kota Pekanbaru

Model	Parameter	Estimasi	Standar Error	<i>p-value</i>	variabel
Skenario 1 (0,1,2)(0,1,1) <sup>12</sup>	$\theta_1$	-0,2566	0,0753	0,0008	
	$\theta_2$	0,2729	0,0755	0,0004	
	$\Theta_1$	0,7283	0,0546	<0,0001	
Skenario 2 ([1,2,4],1,0)(0,1,1) <sup>12</sup>	$\Theta_1$	0,7210	0,0561	<0,0001	
	$\phi_1$	0,2235	0,0760	0,0038	
	$\phi_2$	-0,2584	0,0778	0,0011	
	$\phi_4$	-0,1541	0,0768	0,0464	
	$\delta_{1,t-1}$	0,0353	0,0086	<0,0001	$d_{1,t-1}$
	$\delta_{1t}$	0,0341	0,0086	0,0001	$d_{1,t}$

Data IHK kelompok bahan makanan Kota Pekanbaru dengan pemodelan variasi kalender bulanan (skenario 1) tidak ada yang signifikan pada variabel *dummy*-nya. Ini berarti terjadinya hari raya Idul Fitri maupun bulan suci ramadhan tidak berpengaruh pada kenaikan IHK pada bulan terjadinya hari raya Idul Fitri. Sedangkan pada variasi kalender mingguan (skenario 2), ketika bulan suci ramadhan dan Idul Fitri jatuh pada minggu pertama, maka IHK kelompok bahan makanan akan mengalami kenaikan pada bulan terjadinya Idul Fitri. Model variasi kalender skenario 2 dapat dituliskan modelnya sebagai berikut,

$$y_{2,t} = 0,0353 d_{1,t-1} + 0,0341 d_{1,t} + \frac{(1 - 0,7210 B^{12})}{(1 - B)(1 - B^{12})(1 - 0,2235 B + 0,2584 B^2 + 0,1541 B^4)} a_{2,t}$$

### C. Pemodelan Intervensi Kota Pekanbaru

Dari Tabel 4.14 menunjukkan hasil pemodelan intervensi, hanya variabel  $X_1$  (kenaikan BBM) yang berpengaruh kepada kenaikan IHK bahan makanan di kota Pekanbaru. Hal ini menunjukkan bahwa kenaikan harga BBM berpengaruh terhadap kenaikan harga-harga bahan makanan.

Tabel 4.14 Hasil Estimasi Parameter Model Intervensi Kota Pekanbaru

Model	Parameter	Estimasi	Standar Error	p-value	variabel
$(0,1, [1,2,11])(0,1,1)^{12}$	$\theta_1$	-0,1751	0,0780	0,026	
	$\theta_2$	0,2342	0,0765	0,0026	
	$\theta_{11}$	0,2028	0,0751	0,0077	
	$\Theta_1$	0,7122	0,0578	<0,0001	
	$\beta_1$	0,0736	0,0163	<0,0001	$X_1$

Pemodelan intervensi Kota Pekanbaru dapat dituliskan sebagai berikut,

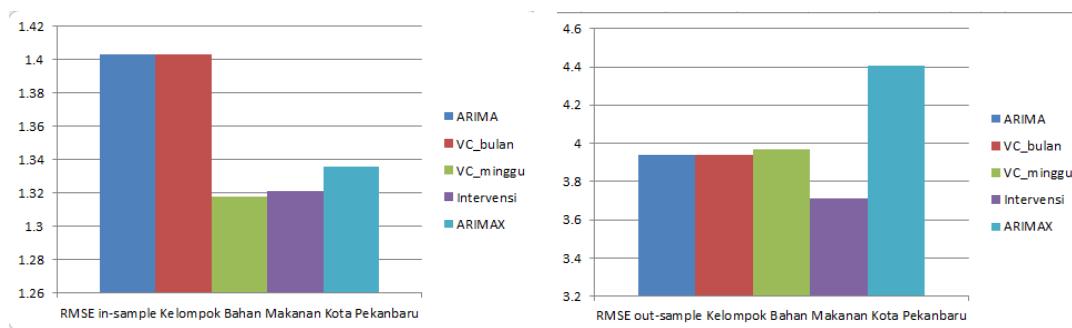
$$y_{2,t} = 0,0736 X_1 + \frac{(1 + 0,1751B^1 - 0,2342 B^5 - 0,2028 B^{11})(1 - 0,7122 B^{12})}{(1 - B)(1 - B^{12})} a_{2,t}$$

### D. Pemodelan ARIMAX Kota Pekanbaru

Pada pemodelan ARIMAX yang variabel eksogennya berupa gabungan antara *dummy* dari variasi kalender mingguan dan intervensi kenaikan BBM dapat dimodelkan sebagai berikut,

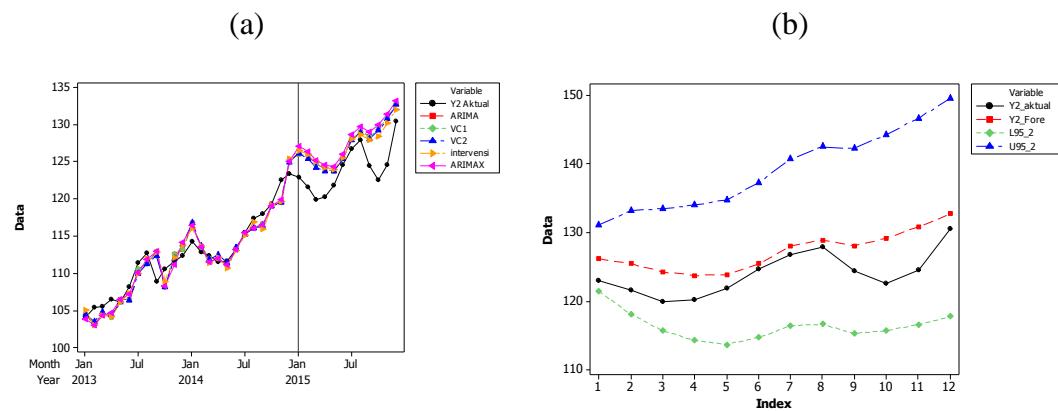
$$y_{2,t} = 0,0179 d_{1t} + 0,0981 X_1 + \frac{(1 + 0,1825 B^1)(1 - 0,7051 B^{12})}{(1 - B)(1 - B^{12})} a_{2,t}$$

Selain kenaikan BBM, ternyata terjadinya Idul Fitri pada minggu pertama pada bulan yang bersangkutan akan menaikkan IHK kelompok bahan makanan di Kota Pekanbaru.



Gambar 4.11 RMSE *In-Sample* dan *Out-Sample* IHK di Kota Pekanbaru

Model ARIMA dengan penambahan variabel eksogen (kenaikan harga BBM) lebih efisien daripada model ARIMA tanpa variabel eksogen, hal ini terlihat dari menurunnya nilai RMSE *in-sample* setelah penambahan variabel eksogen. Sedangkan kriteria model terbaik berdasarkan nilai RMSE *out-sample* minimum, yaitu model intervensi dengan variabel eksogen kenaikan harga BBM. Variabel eksogen kenaikan harga BBM yang dimodelkan bersama dengan data IHK kelompok bahan makanan di Kota Pekabaru ternyata mampu meningkatkan akurasi model. Sedangkan variabel bencana tidak signifikan berpengaruh terhadap IHK.



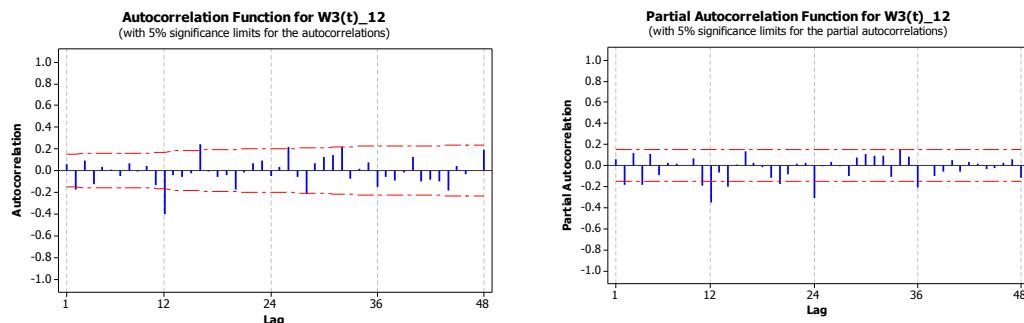
Gambar 4. 12 Hasil Ramalan Model Univariat IHK Kota Pekanbaru

- (a) Ramalan Titik
- (b) Ramalan Interval Model Terbaik (Intervensi)

#### 4.2.3 Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan Jambi

### A. Pemodelan ARIMA Kota Jambi

Setelah dilakukan *differencing* 1 dan 12, terlihat dari **Gambar 4.6** bahwa data telah stasioner dalam *mean*. Setelah data stasioner dalam varians dan *mean*, maka selanjutnya dilakukan proses penentuan orde model ARIMA sementara.



Gambar 4.13 Plot ACF dan PACF Data IHK Kota Jambi

Gambar 4.13 merupakan plot dari data IHK Kota Jambi yang telah stasioner baik dalam varians maupun *mean*. Pada plot ACF memperlihatkan pola *dies down* dan *cut off* pada lag tertentu. Ini juga merupakan indikasi bahwa data tersebut sudah stasioner. Orde model ARIMA masing-masing kota dapat ditentukan berdasarkan lag-lag yang signifikan pada plot ACF dan PACF. Identifikasi lag yang signifikan pada plot ACF terjadi pada lag 2,12. Sedangkan pada plot PACF lag yang signifikan ada pada lag 2,4,11,12.

Tabel 4.15 Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Jambi

Model ARIMA	AIC
(0, 1, [2])(0, 1, 1) <sup>12</sup>	-717,608
([2], 1, 0)(0,1,1) <sup>12</sup>	-715,246

Dari lag-lag yang signifikan tersebut diperoleh model ARIMA (0,1,[2])(0,1,1)<sup>12</sup> sebagai model terbaik dengan nilai AIC sebesar -717,608. Model terbaik yang terpilih selanjutnya digunakan untuk mengestimasi parameter

pada pemodelan IHK Kelompok Bahan Makanan Kota Jambi. Hasil pengujian signifikansi parameter ditunjukkan pada Tabel 4.16 berikut ini.

Tabel 4.16 Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Jambi

Parameter	Estimasi	Standar Error	t-value	p-value	Lag
$\theta_2$	0,29508	0,07528	3,92	0,0001	2
$\theta_1$	0,76632	0,05127	14,95	<0,0001	12

Berdasarkan Tabel 4.16 menunjukkan bahwa dengan taraf signifikansi  $\alpha = 0,05$  seluruh parameter signifikan karena memiliki *p-value* kurang dari 0,05, sehingga seluruh parameter dapat digunakan dalam model. Secara matematis, model ARIMA  $(0,1,[2])(0,1,1)^{12}$  IHK Kota Jambi dapat dituliskan sebagai berikut,

$$y_{3,t} = \frac{(1 - 0,29508 B^2)(1 - 0,76632 B^{12})}{(1 - B)(1 - B^{12})} a_{3,t},$$

dengan  $y_{3,t} = \ln(Y_{3,t})$

Langkah selanjutnya adalah melakukan *diagnostic checking* untuk melihat kesesuaian model yaitu residual memenuhi asumsi *white noise* dan berdistribusi normal. Taraf signifikansi yang digunakan pada kedua uji ini sebesar  $\alpha=0,05$ . Hasil pengujian asumsi residual *white noise* dapat dilihat pada Tabel 4.17.

Tabel 4.17 Hasil Pengujian Residual *White Noise* Model ARIMA data IHK Kelompok Bahan Makanan Kota Jambi

Model ARIMA	Lag	Chi-Square	DF	p-value
$(0,1,[2])(0,1,1)^{12}$	6	3,05	4	0,5492
	12	4,98	10	0,8924
	18	11,03	16	0,8075
	24	17,91	22	0,7110

Hasil uji residual *white noise* pada Tabel 4.17 menunjukkan bahwa autokorelasi residual model ARIMA  $(0,1,[2])(0,1,1)^{12}$  memiliki nilai *p-value*

yang lebih besar dari 0,05 berarti bahwa autokorelasi tidak signifikan atau tidak terdapat korelasi antar lag sehingga asumsi residual *white noise* sudah terpenuhi.

Uji normalitas residual pada model ARIMA (0,1,[2])(0,1,1)<sup>12</sup> dilakukan dengan menggunakan uji Kolmogorov-Smirnov. Hasil uji Kolmogorow-Smirnov menghasilkan nilai uji sebesar 0,05248 dengan *p-value* sebesar >0,1500. Dengan taraf signifikansi  $\alpha=0,05$  memiliki nilai *p-value* yang lebih besar dari 0,05 yang berarti bahwa model ARIMA (0,1,[2])(0,1,1)<sup>12</sup> sudah memenuhi asumsi residual berdistribusi normal.

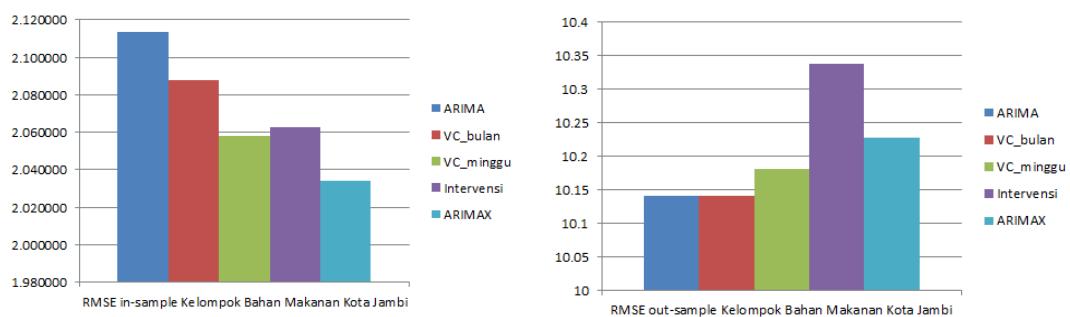
## B. Pemodelan Variasi Kalender Kota Jambi

Data IHK kelompok bahan makanan Kota Jambi dengan pemodelan variasi kalender bulanan (skenario 1) tidak ada yang signifikan pada variabel *dummy*-nya. Ini berarti terjadinya hari raya Idul Fitri maupun bulan suci ramadhan tidak berpengaruh pada kenaikan IHK pada bulan terjadinya hari raya Idul Fitri. Sedangkan pada variasi kalender mingguan (skenario 2), ketika bulan suci ramadhan dan Idul Fitri jatuh pada minggu pertama, maka IHK kelompok bahan makanan akan mengalami kenaikan pada bulan terjadinya Idul Fitri. Pemodelan variasi kalender di kota Jambi dapat dituliskan sebagai berikut,

$$y_{3,t} = \frac{(1 - 0,2968 B^2)(1 - 0,7737 B^{12})}{(1 - B)(1 - B^{12})} a_{3,t}$$

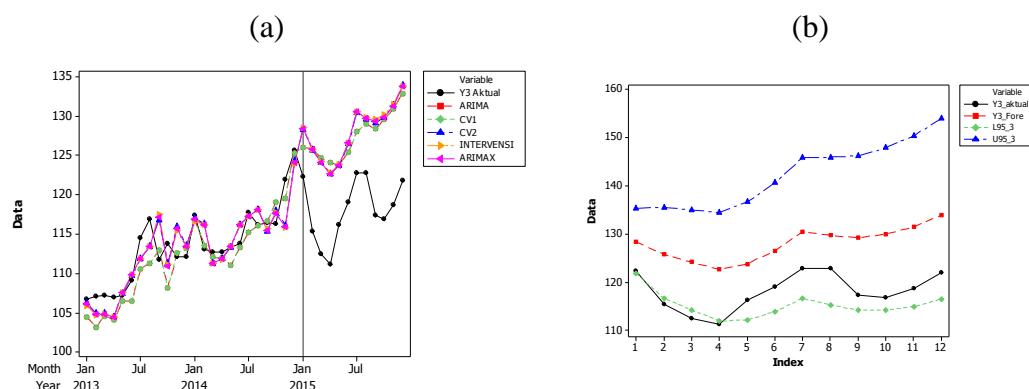
Pemodelan ARIMAX dapat dituliskan sebagai berikut.

$$y_{3,t} = \\ 0,029 d1t - 1 + 0,037 d1t + 0,072 X1 + \frac{(1-0,279 B^2)(1-0,765 B^{12})}{(1-B)(1-B^{12})} a_{3,t}.$$



Gambar 4. 14 RMSE *In-Sample* dan *Out-Sample* IHK di Kota Jambi

Model ARIMA dengan penambahan variabel eksogen (kenaikan harga BBM) lebih efisien daripada model ARIMA tanpa variabel eksogen, hal ini terlihat dari menurunnya nilai RMSE *in-sample* setelah penambahan variabel eksogen. Sedangkan kriteria model terbaik berdasarkan nilai RMSE *out-sample* minimum, yaitu model variasi kalender. Peristiwa Idul Fitri berpengaruh pada kenaikan harga bahan makanan di Kota Jambi.

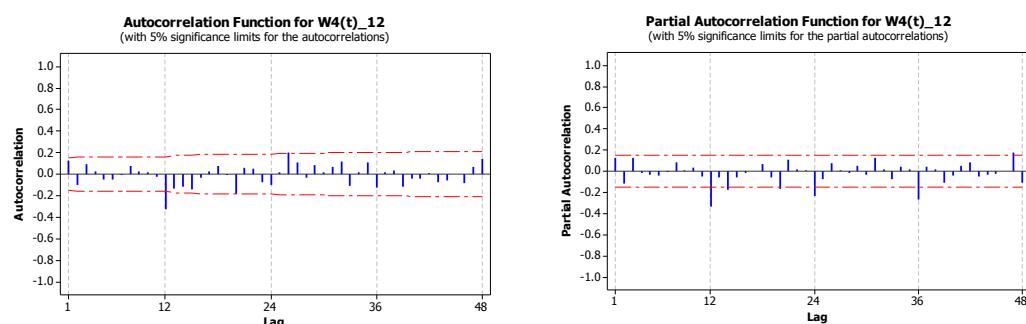


Gambar 4.15 Hasil Ramalan Model Univariat IHK Kota Jambi

- (a) Ramalan Titik
- (b) Ramalan Interval Model Terbaik (Variasi Kalender)

#### 4.2.4 Pemodelan ARIMA pada IHK Kelompok Bahan Makanan Palembang

Setelah dilakukan *differencing* 1 dan 12, terlihat dari **Gambar 4.6** bahwa data telah stasioner dalam *mean*. Setelah data stasioner dalam varians dan *mean*, maka selanjutnya dilakukan proses penentuan orde model ARIMA sementara.



Gambar 4.16 Plot ACF dan PACF Data IHK Kota Palembang

Gambar 4.16 merupakan plot dari data IHK Kota Palembang yang telah stasioner baik dalam varians maupun *mean*. Pada plot ACF memperlihatkan pola *dies down* dan *cut off* pada lag tertentu. Ini juga merupakan indikasi bahwa data tersebut sudah stasioner. Orde model ARIMA masing-masing kota dapat ditentukan berdasarkan lag-lag yang signifikan pada plot ACF dan PACF. Identifikasi lag yang signifikan pada plot ACF terjadi pada lag 1,12. Sedangkan pada plot PACF lag yang signifikan ada pada lag 1,12,24,36.

Tabel 4.18 Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Palembang

Model ARIMA	AIC	RMSE	
		In-sample	Out-sample
(1, 1, 1)(0, 1, 1) <sup>12</sup>	<b>-828,191</b>	<b>0,02009</b>	<b>0,05480</b>
(0,1,0)(0,1,1) <sup>12</sup>	-826,429	0,02032	0,05605

Dari lag-lag yang signifikan tersebut diperoleh model ARIMA (1,1,1)(0,1,1)<sup>12</sup> sebagai model terbaik dengan nilai AIC sebesar -828,191. Model terbaik yang terpilih selanjutnya digunakan untuk mengestimasi parameter pada pemodelan IHK Kelompok Bahan Makanan Kota Palembang. Hasil pengujian signifikansi parameter ditunjukkan pada Tabel 4.19 berikut ini.

**Tabel 4.19** Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Palembang

Parameter	Estimasi	Standar Error	t-value	p-value	Lag
$\theta_1$	-0,75081	0,19353	-3,88	0,0002	1
$\Theta_1$	0,62891	0,06226	10,1	<0,0001	12
$\phi_1$	-0,60081	0,23387	-2,57	0,0111	1

Berdasarkan Tabel 4.19 menunjukkan bahwa dengan taraf signifikansi  $\alpha=0,05$  seluruh parameter signifikan karena memiliki *p-value* kurang dari 0,05, sehingga seluruh parameter dapat digunakan dalam model. Secara matematis, model ARIMA (1,1,1)(0,1,1)<sup>12</sup> IHK Kota Palembang dapat dituliskan sebagai berikut:

$$y_{4,t} = \frac{(1 + 0,75081 B)(1 - 0,62891 B^{12})}{(1 - B)(1 - B^{12})(1 + 0,60081 B)} a_{4,t}$$

dengan  $y_{4,t} = \ln(Y_{4,t})$

Langkah berikutnya adalah melakukan *diagnostic checking* untuk melihat kesesuaian model yaitu residual memenuhi asumsi *white noise* dan berdistribusi normal. Taraf signifikansi yang digunakan pada kedua uji ini sebesar  $\alpha=0,05$ . Hasil pengujian asumsi residual *white noise* dapat dilihat pada Tabel 4.20.

Tabel 4.20 Hasil Pengujian Residual *White Noise* Model ARIMA data IHK Kelompok Bahan Makanan Kota Palembang

Model ARIMA	Lag	Chi-Square	DF	p-value
$(1,1,1)(0,1,1)^{12}$	6	1,87	3	0,5993
	12	4,44	9	0,8802
	18	11,55	15	0,7128
	24	18,27	21	0,6320

Hasil uji residual *white noise* pada Tabel 4.20 menunjukkan bahwa autokorelasi residual model ARIMA  $(1,1,1)(0,1,1)^{12}$  memiliki nilai *p-value* yang lebih besar dari 0,05 berarti bahwa autokorelasi tidak signifikan atau tidak terdapat korelasi antar lag sehingga asumsi residual *white noise* sudah terpenuhi.

Uji normalitas residual pada model ARIMA  $(1,1,1)(0,1,1)^{12}$  dilakukan dengan menggunakan uji Kolmogorov-Smirnov. Hasil uji Kolmogorow-Smirnow menghasilkan nilai uji sebesar 0,049861 dengan *p-value* sebesar  $>0,1500$ . Dengan taraf signifikansi  $\alpha=0,05$  memiliki nilai *p-value* yang lebih besar dari 0,05 yang berarti bahwa model ARIMA  $(1,1,1)(0,1,1)^{12}$  sudah memenuhi asumsi residual berdistribusi normal.

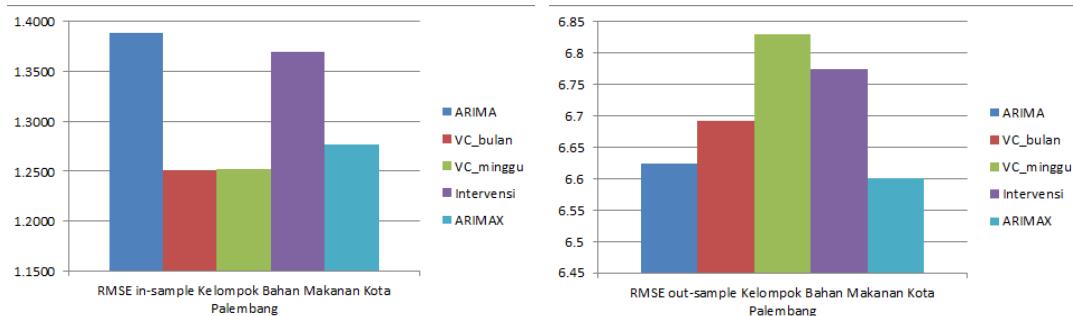
Data IHK kelompok bahan makanan Kota Palembang dengan pemodelan variasi kalender bulanan (skenario 1) signifikan pada variabel *dummy dt-1* dan *dt*. Ini berarti terjadinya hari raya Idul Fitri maupun bulan suci ramadhan berpengaruh pada kenaikan IHK pada bulan terjadinya hari raya Idul Fitri. Sedangkan pada variasi kalender mingguan (skenario 2), ketika bulan suci ramadhan jatuh pada minggu pertama dan Idul Fitri jatuh pada minggu pertama,

kedua dan keempat maka IHK kelompok bahan makanan akan mengalami kenaikan pada bulan terjadinya Idul Fitri. Pemodelan variasi kalender bulanan dan mingguan kota Jambi dapat dituliskan sebagai berikut,

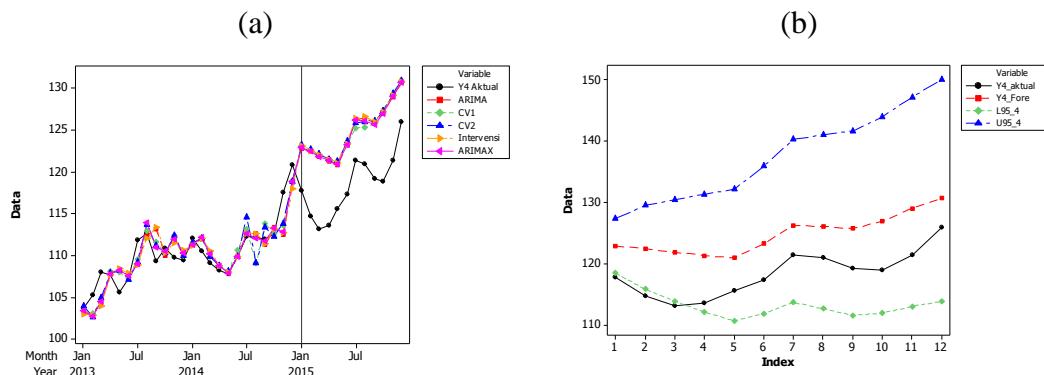
$$y_{4,t} = 0,0079Dt - 1 + 0,0204Dt + \frac{(1 + 0,7671B)(1 - 0,7117B^{12})}{(1 - B)(1 - B^{12})(1 + 0,5084B)} a_{4,t}$$

$$y_{4,t} = 0,0322D1t - 1 + 0,401D1t + 0,0155D2t + 0,0155D4t$$

$$+ \frac{(1 + 0,7937B)(1 - 0,7107B^{12})}{(1 - B)(1 - B^{12})(1 + 0,5356B)} a_{4,t}$$



Gambar 4.17 RMSE *In-Sample* dan *Out-Sample* IHK di Kota Palembang



Gambar 4.18 Hasil Ramalan Model Univariat IHK Kota Palembang

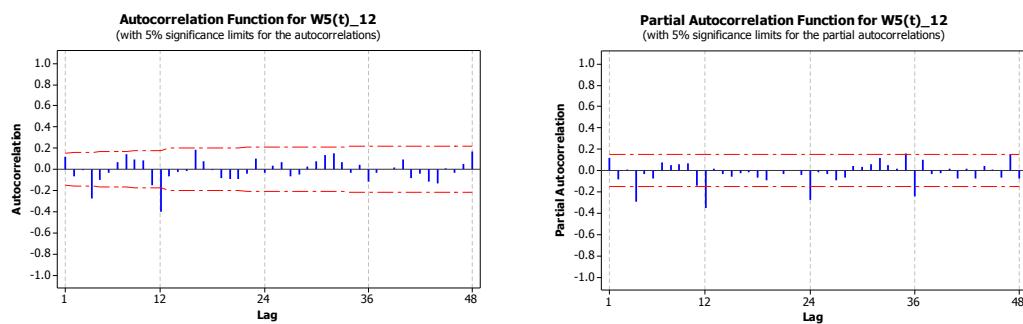
- (a) Ramalan Titik
- (b) Ramalan Interval Model Terbaik (ARIMAX)

Model ARIMA dengan penambahan variabel eksogen (variasi kalender) lebih efisien daripada model ARIMA tanpa variabel eksogen, hal ini terlihat dari menurunnya nilai RMSE *in-sample* setelah penambahan variabel eksogen. Sedangkan kriteria model terbaik berdasarkan nilai RMSE *out-sample* minimum, yaitu model ARIMAX. Dimana variabel eksogen yang signifikan pada model

tersebut adalah terjadinya Idul Fitri pada minggu pertama atau minggu kedua. Peristiwa Idul Fitri berpengaruh pada kenaikan harga bahan makanan di Kota Palembang.

#### 4.2.5 Pemodelan ARIMA dan ARIMAX pada IHK Kelompok Bahan Makanan Bengkulu

Setelah dilakukan *differencing* 1 dan 12, terlihat dari **Gambar 4.6** bahwa data telah stasioner dalam *mean*. Setelah data stasioner dalam varians dan *mean*, maka selanjutnya dilakukan proses penentuan orde model ARIMA sementara.



Gambar 4.19 Plot ACF dan PACF Data IHK Kota Bengkulu

Gambar 4.19 merupakan plot dari data IHK Kota Bengkulu yang telah stasioner baik dalam varians maupun *mean*. Pada plot ACF memperlihatkan pola *dies down* dan *cut off* pada lag tertentu. Ini juga merupakan indikasi bahwa data tersebut sudah stasioner. Orde model ARIMA masing-masing kota dapat ditentukan berdasarkan lag-lag yang signifikan pada plot ACF dan PACF. Identifikasi lag yang signifikan pada plot ACF terjadi pada lag 4,12. Sedangkan pada plot PACF lag yang signifikan ada pada lag 4,12,24,36.

Tabel 4.21 Nilai AIC Hasil Pemodelan ARIMA pada IHK Kota Bengkulu

Model ARIMA	AIC	RMSE	
		In-sample	Out-sample
(0,1, [4])(0,1,1) <sup>12</sup>	-726,277	0,0272	0,0643
([4], 1, 0)(0, 1, 1) <sup>12</sup>	<b>-726,445</b>	<b>0,0272</b>	<b>0,0645</b>

Dari lag-lag yang signifikan tersebut diperoleh model ARIMA  $([4], 1, 0)(0, 1, 1)^{12}$  sebagai model terbaik dengan nilai AIC sebesar -726,445. Model terbaik yang terpilih selanjutnya digunakan untuk mengestimasi parameter pada pemodelan IHK Kelompok Bahan Makanan Kota Palembang. Hasil pengujian signifikansi parameter ditunjukkan pada Tabel 4.22 berikut ini.

Tabel 4.22 Hasil Estimasi Parameter Model ARIMA Data IHK Kelompok Bahan Makanan Kota Bengkulu

Parameter	Estimasi	Standar Error	t-value	p-value	Lag
$\Theta_1$	0,72562	0,05487	13,22	<0,0001	12
$\Phi_1$	-0,22668	0,07722	-2,94	0,0038	4

Berdasarkan Tabel 4.22 menunjukkan bahwa dengan taraf signifikansi  $\alpha=0,05$  seluruh parameter signifikan karena memiliki *p-value* kurang dari 0,05, sehingga seluruh parameter dapat digunakan dalam model. Secara matematis, model ARIMA  $([4], 1, 0)(0, 1, 1)^{12}$  IHK Kota Palembang dapat dituliskan sebagai berikut:

$$y_{5,t} = \frac{(1 - 0,72562 B^{12})}{(1 - B)(1 - B^{12})(1 + 0,22668 B^4)} a_{5,t}$$

Langkah selanjutnya adalah melakukan cek diagnosa untuk melihat kesesuaian model yaitu residual memenuhi asumsi *white noise* dan berdistribusi normal. Taraf signifikansi yang digunakan pada kedua uji ini sebesar  $\alpha=0,05$ . Hasil pengujian asumsi residual *white noise* dapat dilihat pada Tabel 4.23.

Tabel 4.23 Hasil Pengujian Residual *White Noise* Model ARIMA data IHK Kelompok Bahan Makanan Kota Bengkulu

Model ARIMA	Lag	Chi-Square	DF	p-value
$([4], 1, 0)(0, 1, 1)^{12}$	6	3,46	4	0,4835
	12	5,5	10	0,8552
	18	9,33	16	0,8992
	24	15,04	22	0,8605

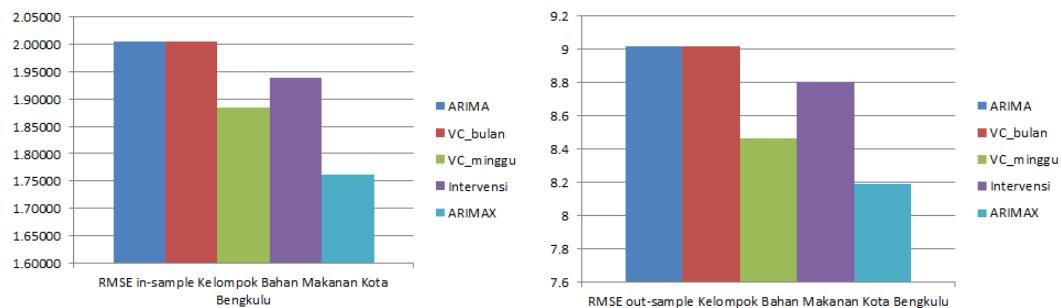
Hasil uji residual *white noise* pada Tabel 4.23 menunjukkan bahwa autokorelasi residual model ARIMA  $([4], 1, 0)(0, 1, 1)^{12}$  memiliki nilai *p-value* yang lebih besar dari 0,05 berarti bahwa autokorelasi tidak signifikan atau tidak terdapat korelasi antar lag sehingga asumsi residual *white noise* sudah terpenuhi.

Uji normalitas residual pada model ARIMA  $([4], 1, 0)(0, 1, 1)^{12}$  dilakukan dengan menggunakan uji Kolmogorov-Smirnov. Hasil uji Kolmogorov-Smirnov menghasilkan nilai uji sebesar 0,0359 dengan *p-value* sebesar  $>0,1500$ . Dengan taraf signifikansi  $\alpha=0,05$  memiliki nilai *p-value* yang lebih besar dari 0,05 yang berarti bahwa model ARIMA  $([4], 1, 0)(0, 1, 1)^{12}$  sudah memenuhi asumsi residual berdistribusi normal.

Data IHK kelompok bahan makanan Kota Bengkulu dengan pemodelan variasi kalender bulanan (skenario 1) terjadinya hari raya Idul Fitri berpengaruh pada kenaikan IHK pada bulan tersebut. Sedangkan pada variasi kalender mingguan (skenario 2), ketika bulan suci ramadhan jatuh pada minggu pertama dan keempat, serta Idul Fitri jatuh pada minggu pertama, maka IHK kelompok bahan makanan akan mengalami kenaikan pada bulan terjadinya Idul Fitri.

Pemodelan ARIMAX pada data IHK kelompok Bahan Makanan di Kota Bengkulu dapat dituliskan sebagai berikut,

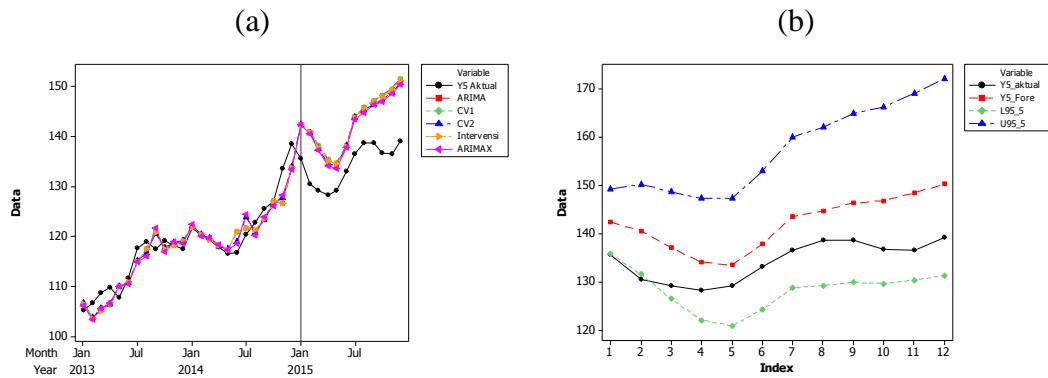
$$y_{5,t} = -0,018 D_{4,t-1} + 0,031 D_{1t} + 0,095 X_1 + \frac{(1-0,73 B)}{(1-B)(1-B^{12})(1+0,29B)} a_{4,t},$$



Gambar 4.20 RMSE *In-Sample* dan *Out-Sample* IHK di Kota Bengkulu

Model ARIMA dengan penambahan variabel eksogen (ARIMAX) lebih efisien daripada model ARIMA tanpa variabel eksogen, hal ini terlihat dari menurunnya nilai RMSE *in-sample* setelah penambahan variabel eksogen. Sedangkan kriteria model terbaik berdasarkan nilai RMSE *out-sample* minimum,

yaitu model ARIMAX. Dimana variabel eksogen yang signifikan pada model tersebut adalah terjadinya Idul Fitri pada minggu pertama dan kenaikan harga BBM.



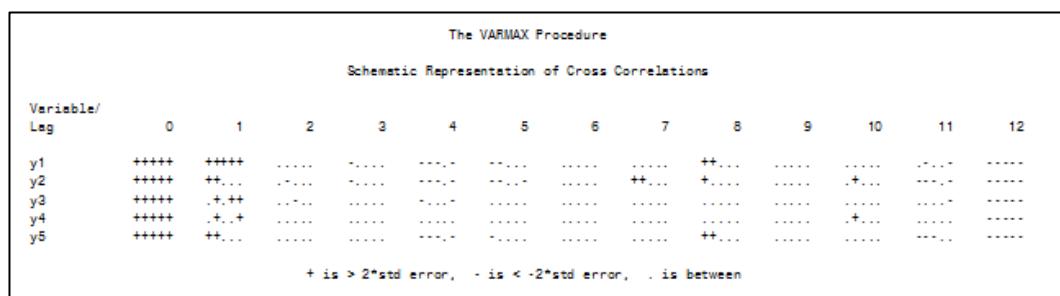
Gambar 4.21 Hasil Ramalan Model Univariat IHK Kota Bengkulu

- (a) Ramalan Titik
- (b) Ramalan Interval Model Terbaik (ARIMAX)

### 4.3 Pemodelan Data IHK Kelompok Bahan Makanan Sumatera menggunakan GSTAR-GLS

Pemodelan menggunakan metode GSTAR-GLS merupakan pemodelan untuk data *time series* dengan memperhatikan faktor spasial atau lokasi. Faktor lokasi ini ditunjukkan dengan adanya pembobotan yang diberikan pada masing-masing variabel. Pembobot yang digunakan dalam penelitian ini terdiri dari tiga jenis bobot, yaitu bobot seragam, invers jarak, dan normalisasi inferensi parsial korelasi silang.

Yang pertama dilakukan adalah dilakukan pemeriksaan stasioneritas dan penetuan orde AR. Tahap identifikasi stasioneritas dilakukan melalui plot MCCF yang ditunjukkan pada Gambar 4.22 berikut,



Gambar 4.22 Plot MCCF Residual di Lima Lokasi

Dari uji stasioneritas menunjukkan bahwa data IHK kelompok bahan makanan di lima lokasi Pulau Sumatera sudah stasioner. Hal ini terlihat dari banyaknya titik yang muncul dalam plot MCCF. Setelah asumsi stasioneritas terpenuhi, kemudian dilakukan identifikasi untuk menentukan orde model VARIMA. Penentuan orde model VARIMA dengan melihat plot MCCF dari nilai yang sudah stasioner (Gambar 4.22) dan AICC terkecil.

Tabel 4.24 Model VARIMA dan AICC

<b>Model</b>	<b>AICC</b>
(1,0,0)	-38,059
([12], 0,0)	-39,0817
([1, 12], 0, 0)	<b>-39,1208</b>

Berdasarkan Tabel 4.24 dapat diketahui bahwa AICC terkecil ada pada model ([1,12], 0,0). Berikutnya, orde dalam model VARIMA tersebut digunakan dalam pemodelan GSTAR-GLS. Dengan menggunakan nilai AIC terkecil dan lag yang signifikan maka model yang terbentuk adalah VAR(1,12). Orde model selanjutnya digunakan dalam model GSTAR, yaitu lag 1 dan 12, sedangkan orde spasial yang digunakan dibatasi pada orde spasial 1, sehingga model GSTAR yang digunakan dalam penelitian ini adalah model GSTAR ([1,12]<sub>1</sub>). Model GSTAR ([1,12]<sub>1</sub>) dapat ditulis dengan persamaan sebagai berikut,

$$\mathbf{y}_{i,t} = [\Phi_{10}^1 + \Phi_{11}^1 \mathbf{W}] \mathbf{y}_{i,(t-1)} + [\Phi_{10}^{12} + \Phi_{11}^{12} \mathbf{W}] \mathbf{y}_{i,(t-12)} + \mathbf{u}_{i,t}$$

Sedangkan dalam bentuk matriks dapat ditulis seperti berikut,

$$\begin{aligned}
\begin{bmatrix} y_{1,t} \\ y_{2,t} \\ y_{3,t} \\ y_{4,t} \\ y_{5,t} \end{bmatrix} &= \left[ \begin{bmatrix} \phi_{10}^1 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^1 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^1 & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^1 & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^1 \end{bmatrix} + \begin{bmatrix} \phi_{11}^1 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^1 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^1 & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^1 & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^1 \end{bmatrix} \right] \begin{bmatrix} 0 & w_{12} & w_{13} & w_{14} & w_{15} \\ w_{21} & 0 & w_{23} & w_{24} & w_{25} \\ w_{31} & w_{32} & 0 & w_{34} & w_{35} \\ w_{41} & w_{42} & w_{43} & 0 & w_{45} \\ w_{51} & w_{52} & w_{53} & w_{54} & 0 \end{bmatrix} \begin{bmatrix} y_{1,t-1} \\ y_{2,t-1} \\ y_{3,t-1} \\ y_{4,t-1} \\ y_{5,t-1} \end{bmatrix} \\
&+ \begin{bmatrix} \phi_{10}^{12} & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{12} & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{12} & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{12} & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{12} \end{bmatrix} \\
&+ \begin{bmatrix} \phi_{11}^{12} & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{12} & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{12} & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{12} & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{12} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} & w_{14} & w_{15} \\ w_{21} & 0 & w_{23} & w_{24} & w_{25} \\ w_{31} & w_{32} & 0 & w_{34} & w_{35} \\ w_{41} & w_{42} & w_{43} & 0 & w_{45} \\ w_{51} & w_{52} & w_{53} & w_{54} & 0 \end{bmatrix} \begin{bmatrix} y_{1,t-12} \\ y_{2,t-12} \\ y_{3,t-12} \\ y_{4,t-12} \\ y_{5,t-12} \end{bmatrix} + \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \\ u_{5,t} \end{bmatrix}
\end{aligned}$$

### A. Pemodelan GSTAR-GLS ( $[1,12]_1$ ) dengan Bobot Seragam

Bobot seragam dalam pemodelan GSTAR-GLS mengasumsikan bahwa data IHK kelompok bahan makanan pada suatu lokasi memiliki pengaruh yang sama terhadap IHK kelompok bahan makanan di lokasi-lokasi lainnya. Matriks bobot seragam yang digunakan dalam analisis ini adalah sebagai berikut,

$$W_{ij} = \begin{bmatrix} 0 & 0,25 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0,25 & 0 \end{bmatrix}$$

Tabel 4.25 Hasil Estimasi Parameter Model GSTAR-GLS ( $[1,12]_1$ ) menggunakan Bobot Seragam

Lokasi	Parameter	Estimasi	Standard Error	P-Value
Padang	$\phi_{11}^1$	0,259	0,099	0,0100
	$\phi_{10}^{12}$	-0,487	0,051	<0,0001
Pekanbaru	$\phi_{21}^1$	0,171	0,059	0,0043
	$\phi_{20}^{12}$	-0,484	0,044	<0,0001
Jambi	$\phi_{30}^1$	-0,169	0,072	0,0202
	$\phi_{31}^1$	0,315	0,108	0,0040
	$\phi_{30}^{12}$	-0,399	0,048	<0,0001
Palembang	$\phi_{41}^1$	0,128	0,053	0,0177
	$\phi_{40}^{12}$	-0,360	0,051	<0,0001
Bengkulu	$\phi_{51}^1$	0,175	0,085	0,0490
	$\phi_{50}^{12}$	-0,428	0,047	<0,0001

Hasil estimasi parameter model GSTAR-GLS menghasilkan 20 parameter. Tetapi tidak semua variabel yang diestimasi akan signifikan. Oleh karena itu dilakukan pemodelan ulang dengan hanya memasukkan variabel yang signifikan saja pada  $\alpha=5\%$  ditunjukkan pada Tabel 4.25

Hasil estimasi parameter pada Tabel 4.25 selanjutnya digunakan untuk membentuk persamaan matriks model GSTAR-GLS ( $[1,12]_1$ ) bobot seragam pada persamaan berikut,

$$\begin{bmatrix} y_{1,t} \\ y_{2,t} \\ y_{3,t} \\ y_{4,t} \\ y_{5,t} \end{bmatrix} = \left( \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0,169 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 0,259 & 0 & 0 & 0 & 0 \\ 0 & 0,171 & 0 & 0 & 0 \\ 0 & 0 & 0,315 & 0 & 0 \\ 0 & 0 & 0 & 0,128 & 0 \\ 0 & 0 & 0 & 0 & 0,175 \end{bmatrix} \begin{bmatrix} 0,25 & 0,25 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0,25 & 0 \end{bmatrix} \begin{bmatrix} y_{1(t-1)} \\ y_{2(t-1)} \\ y_{3(t-1)} \\ y_{4(t-1)} \\ y_{5(t-1)} \end{bmatrix} \right) + \left( \begin{bmatrix} -0,487 & 0 & 0 & 0 & 0 \\ 0 & -0,497 & 0 & 0 & 0 \\ 0 & 0 & -0,399 & 0 & 0 \\ 0 & 0 & 0 & -0,360 & 0 \\ 0 & 0 & 0 & 0 & -0,428 \end{bmatrix} \begin{bmatrix} 0 & 0,25 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0,25 & 0 \end{bmatrix} \begin{bmatrix} y_{1(t-12)} \\ y_{2(t-12)} \\ y_{3(t-12)} \\ y_{4(t-12)} \\ y_{5(t-12)} \end{bmatrix} \right) + \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \\ u_{5,t} \end{bmatrix}$$

atau

$$= \left( \begin{bmatrix} 0 & 0,065 & 0,065 & 0,065 & 0,065 \\ 0,043 & 0 & 0,043 & 0,043 & 0,043 \\ 0,079 & 0,079 & -0,169 & 0,079 & 0,079 \\ 0,032 & 0,032 & 0,032 & 0 & 0,032 \\ 0,044 & 0,044 & 0,044 & 0,044 & 0 \end{bmatrix} \begin{bmatrix} y_{1(t-1)} \\ y_{2(t-1)} \\ y_{3(t-1)} \\ y_{4(t-1)} \\ y_{5(t-1)} \end{bmatrix} \right) + \left( \begin{bmatrix} -0,487 & 0 & 0 & 0 & 0 \\ 0 & -0,497 & 0 & 0 & 0 \\ 0 & 0 & -0,399 & 0 & 0 \\ 0 & 0 & 0 & -0,360 & 0 \\ 0 & 0 & 0 & 0 & -0,428 \end{bmatrix} \begin{bmatrix} y_{1(t-12)} \\ y_{2(t-12)} \\ y_{3(t-12)} \\ y_{4(t-12)} \\ y_{5(t-12)} \end{bmatrix} \right) + \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \\ u_{5,t} \end{bmatrix}$$

Model dalam persamaan matriks tersebut kemudian dijabarkan untuk masing-masing lokasi (Padang, Pekanbaru, Jambi, Palembang, Bengkulu) sebagai berikut,

a) Model GSTAR-GLS ( $[1,12]_1$ ) di Padang

$$y_{1,t} = 0,065 y_{2,t-1} + 0,065 y_{3,t-1} + 0,065 y_{4,t-1} + 0,065 y_{5,t-1} - 0,487 y_{1,t-12} + u_{1,t},$$

b) Model GSTAR-GLS ( $[1,12]_1$ ) di Pekanbaru

$$y_{2,t} = 0,043 y_{1,t-1} + 0,043 y_{3,t-1} + 0,043 y_{4,t-1} + 0,043 y_{5,t-1} - 0,497 y_{2,t-12} + u_{2,t},$$

c) Model GSTAR-GLS ( $[1,12]_1$ ) di Jambi

$$y_{3,t} = 0,079 y_{1,t-1} + 0,079 y_{2,t-1} - 0,169 y_{3,t-1} + 0,079 y_{4,t-1} + 0,079 y_{5,t-1} - 0,399 y_{3,t-12} + u_{3,t},$$

d) Model GSTAR-GLS ( $[1,12]_1$ ) di Palembang

$$y_{4,t} = 0,032 y_{1,t-1} + 0,032 y_{2,t-1} + 0,032 y_{3,t-1} + 0,032 y_{5,t-1} - 0,360 y_{4,t-12} + u_{4,t}$$

e) Model GSTAR-GLS ( $[1,12]_1$ ) di Bengkulu

$$y_{5,t} = 0,044 y_{1,t-1} + 0,044 y_{2,t-1} + 0,044 y_{3,t-1} + 0,044 y_{4,t-1} - 0,428 y_{5,t-1} + u_{5,t},$$

Persamaan yang terbentuk dengan model GSTAR-GLS ( $[1,12]_1$ ) untuk data IHK bahan makanan di setiap lokasi dapat diketahui bahwa pola data IHK

bahan makanan di suatu lokasi mengikuti pola IHK bahan makanan di lokasi tersebut atau dari lokasi lain pada waktu yang berbeda. Dengan menggunakan bobot seragam diperoleh hasil bahwa pola IHK bahan makanan pada kota Padang mengikuti pola IHK kota Pekanbaru, Jambi, Palembang, dan Bengkulu satu bulan sebelumnya dan 12 bulan sebelumnya di kota itu sendiri. Pada satu bulan sebelumnya, untuk pola IHK Kota Jambi polanya selain mengikuti kota lain juga juga oleh IHK Kota Jambi itu sendiri.

### B. Pemodelan GSTAR-GLS ( $[1, 12]_1$ ) dengan Bobot Invers Jarak

Pemodelan GSTAR-GLS dengan menggunakan bobot invers jarak mengasumsikan bahwa IHK di suatu lokasi dipengaruhi oleh jauh atau dekatnya jarak yang dimiliki dengan lokasi lainnya. Jarak antara dua lokasi yang jauh akan memiliki bobot yang cenderung lebih rendah dibandingkan dengan jarak antara dua lokasi yang dekat.

Berdasarkan gambar Gambar 4.2, jarak antara kota Padang dan Palembang merupakan jarak terjauh dibandingkan lokasi lainnya, yaitu 884 km. Sedangkan jarak terdekat 283 km, yaitu jarak perjalanan darat antara kota Palembang dan kota Jambi. Jarak antar lima lokasi di Sumatera tersebut kemudian dinormalisasikan nilai invers jaraknya, yang kemudian digunakan sebagai matriks pembobot.

Matriks pembobot invers jarak berdasarkan peta jarak lima lokasi ditampilkan sebagai berikut,

$$W_{ij} = \begin{bmatrix} 0 & 0,44 & 0,22 & 0,15 & 0,19 \\ 0,40 & 0 & 0,27 & 0,17 & 0,16 \\ 0,17 & 0,23 & 0 & 0,37 & 0,23 \\ 0,14 & 0,16 & 0,42 & 0 & 0,28 \\ 0,19 & 0,18 & 0,31 & 0,32 & 0 \end{bmatrix}$$

Hasil estimasi parameter model GSTAR-GLS menghasilkan 20 parameter. Tetapi tidak semua variabel yang diestimasi akan signifikan. Oleh karena itu dilakukan pemodelan ulang dengan hanya memasukkan variabel yang signifikan saja pada  $\alpha = 5\%$  akan ditunjukkan pada Tabel 4.26.

Tabel 4.26 Hasil Estimasi Parameter Model GSTAR-GLS ( $[1,12]_1$ ) Menggunakan Bobot Invers Jarak

Lokasi	Parameter	Estimasi	Standard Error	P-Value
Padang	$\phi_{11}^1$	0,317	0,094	0,0010
	$\phi_{10}^{12}$	-0,478	0,050	<0,0001
Pekanbaru	$\phi_{21}^1$	0,191	0,052	0,0003
	$\phi_{20}^{12}$	-0,494	0,044	<0,0001
Jambi	$\phi_{31}^1$	0,194	0,093	0,0382
	$\phi_{30}^{12}$	-0,394	0,048	<0,0001
Palembang	$\phi_{41}^1$	0,163	0,050	0,0013
	$\phi_{40}^{12}$	-0,357	0,051	<0,0001
Bengkulu	$\phi_{51}^1$	0,241	0,082	0,0037
	$\phi_{50}^{12}$	-0,423	0,047	<0,0001

Hasil estimasi parameter pada selanjutnya digunakan untuk membentuk persamaan matriks model GSTAR-GLS ( $[1,12]_1$ ) bobot lokasi pada persamaan berikut,

$$\begin{aligned}
 \begin{bmatrix} y_{1,t} \\ y_{2,t} \\ y_{3,t} \\ y_{4,t} \\ y_{5,t} \end{bmatrix} &= \left( \begin{bmatrix} 0,317 & 0 & 0 & 0 & 0 \\ 0 & 0,191 & 0 & 0 & 0 \\ 0 & 0 & 0,194 & 0 & 0 \\ 0 & 0 & 0 & 0,163 & 0 \\ 0 & 0 & 0 & 0 & 0,241 \end{bmatrix} \begin{bmatrix} 0 & 0,44 & 0,22 & 0,15 & 0,19 \\ 0,40 & 0 & 0,27 & 0,17 & 0,16 \\ 0,17 & 0,23 & 0 & 0,37 & 0,23 \\ 0,14 & 0,16 & 0,42 & 0 & 0,28 \\ 0,19 & 0,18 & 0,31 & 0,32 & 0 \end{bmatrix} \begin{bmatrix} y_{1(t-1)} \\ y_{2(t-1)} \\ y_{3(t-1)} \\ y_{4(t-1)} \\ y_{5(t-1)} \end{bmatrix} \right) \\
 &\quad + \left( \begin{bmatrix} -0,478 & 0 & 0 & 0 & 0 \\ 0 & -0,494 & 0 & 0 & 0 \\ 0 & 0 & -0,394 & 0 & 0 \\ 0 & 0 & 0 & -0,357 & 0 \\ 0 & 0 & 0 & 0 & -0,423 \end{bmatrix} \begin{bmatrix} y_{1(t-12)} \\ y_{2(t-12)} \\ y_{3(t-12)} \\ y_{4(t-12)} \\ y_{5(t-12)} \end{bmatrix} \right) + \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \\ u_{5,t} \end{bmatrix} \\
 &= \left( \begin{bmatrix} 0 & 0,138 & 0,070 & 0,049 & 0,060 \\ 0,076 & 0 & 0,052 & 0,032 & 0,031 \\ 0,033 & 0,045 & 0 & 0,072 & 0,045 \\ 0,022 & 0,027 & 0,069 & 0 & 0,045 \\ -0,047 & 0,044 & 0,074 & 0,076 & 0 \end{bmatrix} \begin{bmatrix} y_{1(t-1)} \\ y_{2(t-1)} \\ y_{3(t-1)} \\ y_{4(t-1)} \\ y_{5(t-1)} \end{bmatrix} \right) + \left( \begin{bmatrix} -0,478 & 0 & 0 & 0 & 0 \\ 0 & -0,494 & 0 & 0 & 0 \\ 0 & 0 & -0,394 & 0 & 0 \\ 0 & 0 & 0 & -0,357 & 0 \\ 0 & 0 & 0 & 0 & -0,423 \end{bmatrix} \begin{bmatrix} y_{1(t-12)} \\ y_{2(t-12)} \\ y_{3(t-12)} \\ y_{4(t-12)} \\ y_{5(t-12)} \end{bmatrix} \right) + \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \\ u_{5,t} \end{bmatrix}.
 \end{aligned}$$

Model dalam persamaan matriks tersbut kemudian dijabarkan untuk masing-masing lokasi (Padang, Pekanbaru, Jambi, Palembang, Bengkulu) sebagai berikut,

a) Model GSTAR-GLS ( $[1,12]_1$ ) di Padang

$$y_{1,t} = 0,138y_{2,t-1} + 0,07y_{3,t-1} + 0,049y_{4,t-1} + 0,06y_{5,t-1} - 0,478y_{1,t-12} + u_{1,t},$$

b) Model GSTAR-GLS ( $[1,12]_1$ ) di Pekanbaru

$$y_{2,t} = 0,076y_{1,t-1} + 0,052y_{3,t-1} + 0,032y_{4,t-1} + 0,031y_{5,t-1} - 0,494y_{2,t-12} + u_{2,t},$$

c) Model GSTAR-GLS ( $[1,12]_1$ ) di Jambi

$$y_{3,t} = 0,033y_{1,t-1} + 0,045y_{2,t-1} + 0,072y_{4,t-1} + 0,045y_{5,t-1} - 0,394y_{3,t-12} + u_{3,t},$$

d) Model GSTAR-GLS ( $[1,12]_1$ ) di Palembang

$$y_{4,t} = 0,022 y_{1,t-1} + 0,027 y_{2,t-1} + 0,069 y_{3,t-1} + 0,045 y_{5,t-1} - 0,357 y_{4,t-12} + u_{4,t}$$

e) Model GSTAR-GLS ( $[1,12]_1$ ) di Bengkulu

$$y_{5,t} = 0,047 y_{1,t-1} + 0,044 y_{2,t-1} + 0,074 y_{3,t-1} + 0,076 y_{4,t-1} - 0,423 y_{5,t-12} + u_{5,t},$$

Persamaan yang terbentuk dengan model GSTAR-GLS ( $[1,12]_1$ ) untuk data IHK bahan makanan di setiap lokasi dapat diketahui bahwa pola data IHK di suatu lokasi mengikuti pola data IHK di lokasi tersebut atau dari lokasi lain pada waktu yang berbeda. Misalnya, diketahui IHK kelompok bahan makanan Kota Padang polanya mengikuti IHK bahan makanan kota tersebut 12 bulan sebelumnya, serta IHK Kota Pekanbaru, Jambi, Palembang, dan Bengkulu sebulan sebelumnya.

### C. Pemodelan GSTAR-GLS ( $[1, 12]_1$ ) dengan Bobot Normalisasi Inferensi Parsial Korelasi Silang

Pemodelan GSTAR-GLS pada pemodelan data IHK kelompok bahan makanan lima kota di Sumatera dengan menerapkan bobot normalisasi inferensi parsial korelasi silang mengasumsikan bahwa keterkaitan IHK antar lokasi lebih dipengaruhi oleh nilai tinggi rendahnya parsial silang yang dimiliki oleh data IHK pada suatu lokasi dengan IHK pada lokasi lainnya. Penghitungan bobot normalisasi inferensi parsial korelasi silang diperoleh melalui normalisasi dari nilai korelasi silang dari data antar lokasi pada lag yang bersesuaian. Tanda (+), (-), dan (.) dalam matriks MCCF digunakan sebagai pedoman, nilai korelasi mana saja yang dimasukkan dalam bobot. Berikut ini akan digambarkan penghitungan nilai bobot normalisasi inferensi parsial korelasi silang dari hasil output SAS. Ditunjukkan pada gambar 4.23.

Nilai korelasi disesuaikan dengan tanda yang ada pada *schematic of cross correlation*, dan di-nolkan pada diagonal utama. Pertahankan angka korelasi pada dengan tanda (+) dan (-), dan nol pada (.). Ini semua dilakukan pada semua lag yang sudah ditentukan sebelumnya, dalam penelitian ini menggunakan lag 1 dan 12.

The VARMAX Procedure													
Schematic Representation of Cross Correlations													
Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
y1	+++++	+++++	.....	-....-	-....-	.....	.....	.....	++...	.....	.....	-....	----
y2	+++++	+...+	....	-....-	-....-	.....	++...	+....	.....	.+..	-....	----	----
y3	+++++	.+..+	....	....	-....-	....	....	....	....	....	....	-....	----
y4	+++++	.+..+	....	....	....	....	....	....	....	....	.+..	....	----
y5	+++++	+...+	....	-....-	-....-	....	....	....	++...	....	....	-....	----

Cross-Correlation Matrices of Endogenous (Dependent) Series												
Lag	Variable	y1	y2	y3	y4	y5						
1	y1	0.17088	0.27832	0.18915	0.21075	0.25174						
	y2	0.20772	0.22322	0.15356	0.08799	0.13391						
	y3	0.12621	0.15951	0.06227	0.18810	0.16459						
	y4	0.10060	0.17678	0.09391	0.12916	0.20050						
	y5	0.21285	0.24033	0.08217	0.08242	0.11480						
12	y1	-0.48929	-0.35142	-0.30611	-0.17084	-0.26648						
	y2	-0.43769	-0.56720	-0.34213	-0.28035	-0.39321						
	y3	-0.33495	-0.34801	-0.39759	-0.26522	-0.32072						
	y4	-0.24703	-0.31368	-0.22669	-0.32311	-0.22272						
	y5	-0.34287	-0.33218	-0.25398	-0.19414	-0.40317						

Gambar 4.23 Plot MCCF data IHK Kelompok Bahan Makanan di Lima Lokasi

Matriks bobot normalisasi inferensi parsial korelasi silang yang digunakan untuk mengestimasi atau menaksir parameter model GSTARX-GLS ( $[1,12]_1$ ) untuk lag 1 dituliskan pada matriks sebagai berikut,

Matriks pembobot normalisasi inferensi parsial korelasi silang pada lag 1 dan lag 12 berdasarkan peta jarak lima lokasi ditampilkan sebagai berikut :

$$W_{ij} = \begin{bmatrix} 0 & 0,30 & 0,20 & 0,23 & 0,27 \\ 0,36 & 0 & 0,26 & 0,15 & 0,23 \\ 0,20 & 0,25 & 0 & 0,29 & 0,26 \\ 0,18 & 0,31 & 0,16 & 0 & 0,35 \\ 0,34 & 0,39 & 0,13 & 0,13 & 0 \end{bmatrix}$$

$$W_{ij} = \begin{bmatrix} 0 & -0,32 & -0,28 & -0,16 & -0,24 \\ -0,30 & 0 & -0,24 & -0,19 & -0,27 \\ -0,26 & -0,27 & 0 & -0,21 & -0,25 \\ -0,24 & -0,31 & -0,22 & 0 & -0,22 \\ -0,31 & -0,30 & -0,23 & -0,17 & 0 \end{bmatrix}$$

Hasil estimasi parameter model GSTAR-GLS menghasilkan 20 parameter. Tetapi tidak semua variabel yang diestimasi akan signifikan. Oleh karena itu

dilakukan pemodelan ulang dengan hanya memasukkan variabel yang signifikan saja pada  $\alpha=5\%$  akan ditunjukkan pada Tabel 4.27.

Tabel 4.27 Hasil Estimasi Parameter Model GSTAR-GLS ( $[1,12]_1$ )  
Menggunakan Bobot Normalisasi Inferensi Parsial Korelasi Silang

Lokasi	Parameter	Estimasi	Standard Error	P-Value
Padang	$\phi_{10}^{12}$	-0,500	0,051	<0,0001
Pekanbaru	$\phi_{20}^{12}$	-0,511	0,043	<0,0001
Jambi	$\phi_{30}^1$	-0,112	0,043	0,0105
	$\phi_{30}^{12}$	-0,409	0,049	<0,0001
Palembang	$\phi_{40}^{12}$	-0,371	0,051	<0,0001
Bengkulu	$\phi_{50}^{12}$	-0,431	0,046	<0,0001

Hasil estimasi parameter pada selanjutnya digunakan untuk membentuk persamaan matriks model GSTAR-GLS ( $[1,12]_1$ ) bobot Normalisasi Inferensi Parsial Korelasi Silang lokasi pada persamaan berikut :

$$\begin{bmatrix} y_{1,t} \\ y_{2,t} \\ y_{3,t} \\ y_{4,t} \\ y_{5,t} \end{bmatrix} = \left( \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.112 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} y_{1(t-1)} \\ y_{2(t-1)} \\ y_{3(t-1)} \\ y_{4(t-1)} \\ y_{5(t-1)} \end{bmatrix} \right) + \left( \begin{bmatrix} -0.500 & 0 & 0 & 0 & 0 \\ 0 & -0.511 & 0 & 0 & 0 \\ 0 & 0 & -0.409 & 0 & 0 \\ 0 & 0 & 0 & -0.371 & 0 \\ 0 & 0 & 0 & 0 & -0.431 \end{bmatrix} \begin{bmatrix} y_{1(t-12)} \\ y_{2(t-12)} \\ y_{3(t-12)} \\ y_{4(t-12)} \\ y_{5(t-12)} \end{bmatrix} \right) + \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \\ u_{5,t} \end{bmatrix}$$

Model dalam persamaan matriks tersebut kemudian dijabarkan untuk masing-masing lokasi (Padang, Pekanbaru, Jambi, Palembang, Bengkulu) sebagai berikut :

- a) Model GSTAR-GLS ( $[1,12]_1$ ) di Padang

$$y_{1,t} = -0,500 y_{1,t-12} + u_{1,t},$$

- b) Model GSTAR-GLS ( $[1,12]_1$ ) di Pekanbaru

$$y_{2,t} = -0,511 y_{2,t-12} + u_{2,t},$$

- c) Model GSTAR-GLS ( $[1,12]_1$ ) di Jambi

$$y_{3,t} = -0,112 y_{3,t-1} - 0,409 y_{3,t-12} + u_{3,t},$$

- d) Model GSTAR-GLS ( $[1,12]_1$ ) di Palembang

$$y_{4,t} = -0,371 y_{4,t-12} + u_{4,t},$$

- e) Model GSTAR-GLS ( $[1,12]_1$ ) di Bengkulu

$$y_{5,t} = -0,431 y_{5,t-12} + u_{5,t},$$

Persamaan yang terbentuk dengan model GSTAR-GLS ([1,12]<sub>1</sub>) untuk data IHK bahan makanan di setiap lokasi dapat diketahui bahwa pola data IHK di suatu lokasi mengikuti pola data IHK di lokasi tersebut pada waktu yang berbeda, tapi tidak mengikuti pola daerah lain. Misalnya, diketahui IHK kelompok bahan makanan Kota Pekanbaru polanya hanya mengikuti IHK bahan makanan kota tersebut 12 bulan sebelumnya.

#### **4.4 Pemodelan Data IHK Kelompok Bahan Makanan Sumatera Menggunakan GSTARX-GLS**

Pemodelan menggunakan metode GSTARX-GLS merupakan pemodelan untuk data *time series* dengan memperhatikan faktor spasial atau lokasi. Faktor lokasi ini ditunjukkan dengan adanya pembobotan yang diberikan pada masing-masing variabel. Pembobot yang digunakan dalam penelitian ini terdiri dari tiga jenis bobot, yaitu bobot seragam, invers jarak, dan normalisasi inferensia parsial korelasi silang. Estimasi parameter model menggunakan metode GLS (*Generalized Least Square*) atau SUR (*Seemingly Unrelated Regression*) melalui dua tahap.

##### **4.4.1 Pemodelan Tahap Pertama**

Pada estimasi tahap pertama dengan cara melakukan regresi antara data IHK yang telah stasioner dengan variabel eksogen (variasi kalender mingguan, kenaikan BBM dan terjadinya bencana alam secara *restrict*). Diregresikan tanpa lag di lokasi yang sama dan berlainan, sehingga diperoleh  $u_{i,t}$  (residual), dengan  $i = 1, 2, \dots, 5$ . Hasil estimasi parameter tahap satu dapat dituliskan sebagai berikut,

- a) Model regresi IHK Kota Padang :

$$y_{1,t}^* = -0,01475 d_{2,t-1} + u_{1,t} .$$

- b) Model regresi IHK Kota Pekanbaru :

$$y_{2,t}^* = -0,01632 d_{4,t} + u_{2,t} .$$

- c) Model regresi IHK Kota Jambi :

$$y_{3,t}^* = 0,019876 d_{1,t} + u_{3,t} .$$

- d) Model regresi IHK Kota Palembang :

$$y_{4,t}^* = 0,019058 d_{2,t-1} - 0,01423 d_{4,t-1} + u_{4,t} .$$

e) Model regresi IHK Kota Bengkulu :

$$y_{5,t}^* = 0,022535 d_{3,t-1} - 0,02384 d_{4,t-1} + u_{5,t}$$

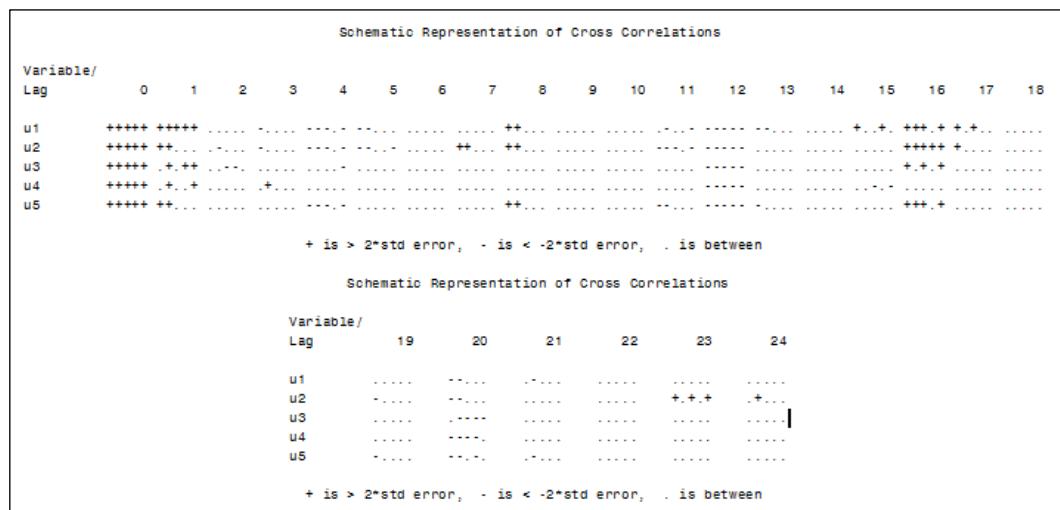
\* : merupakan y yang ditransformasi (ln)

Model yang diperoleh digunakan untuk mendapatkan hasil peramalan tahap pertama ( $\hat{y}_{i,t}$ ) dan residual ( $u_{i,t}$ ). Pada tahapan selanjutnya, residual ( $u_{i,t}$ ) dengan  $i = 1,2,3,4,5$  untuk masing-masing lokasi menjadi variabel respon pada tahap 2 (dua).

#### 4.4.2 Pemodelan Tahap Kedua dengan Model GSTARX

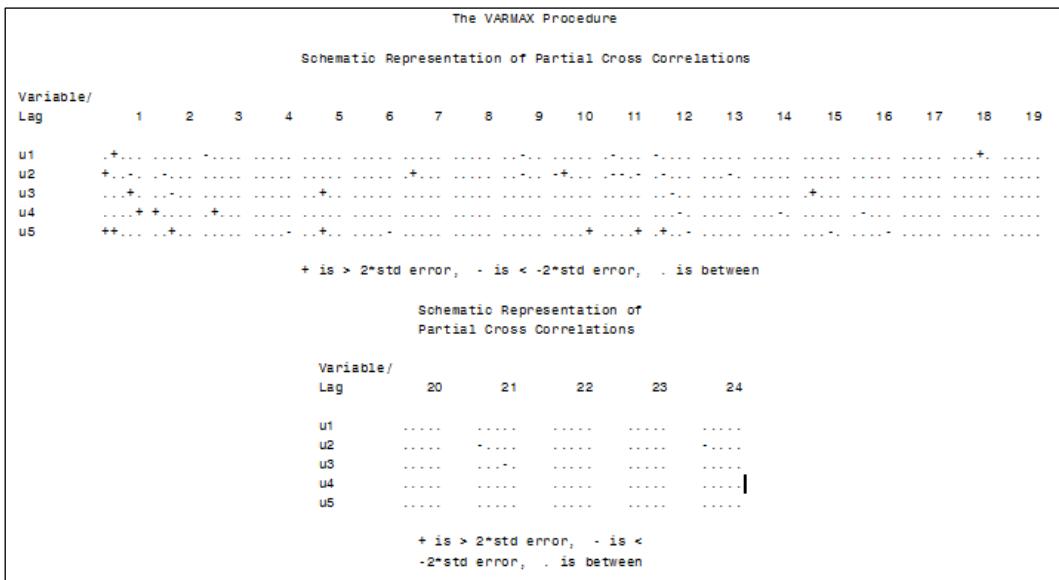
##### 4.4.2.1 Identifikasi Model GSTARX

Dari model  $u_{i,t}$  yang telah didapatkan, selanjutnya dilakukan pemeriksaan stasioneritas dan penetuan orde AR. Tahap identifikasi stasioneritas dilakukan melalui plot MCCF yang ditunjukkan pada Gambar 4.24 berikut :



Gambar 4.24 Plot MCCF Residual di Lima Lokasi

Gambar 4.24 menunjukkan bahwa data residual di lima lokasi Pulau Sumatera sudah stasioner. Hal ini terlihat dari banyaknya tanda titik yang muncul dalam plot MCCF. Setelah asumsi stasioneritas terpenuhi, kemudian dilakukan identifikasi untuk menetukan orde model VARIMA. Penentuan orde model VARIMA dengan melihat plot MPCCF dari nilai yang sudah stasioner (Gambar 4.25) dan AICC terkecil (Tabel 4.28).



Gambar 4.25 Plot MPCCF Residual di Lima Lokasi

Gambar 4.25 menunjukkan bahwa plot MPCCF *cut off* atau signifikan pada lag 1 dan 12. Hal ini dapat dilihat dari tanda positif (+) dan negatif (-) yang muncul pada ketiga lag tersebut. Selain plot MPCCF, orde model VARIMA juga dapat dilihat dari nilai AICC terkecil.

Tabel 4.28 Model VARIMA dan AICC

Model	AICC
(1,0,0)	-38,2244
([1,2,12], 0,0)	-39,1272
([1, 12], 0, 0)	<b>-39,2464</b>

Berdasarkan Tabel 4.28 dapat diketahui bahwa AICC terkecil ada pada model ([1,12], 0,0). Berikutnya, orde dalam model VARIMA tersebut digunakan dalam pemodelan GSTARX-GLS. Dengan menggunakan nilai AIC terkecil dan lag yang signifikan maka model yang terbentuk adalah VAR(1,12). Orde model selanjutnya digunakan dalam model GSTAR, yaitu lag 1 dan 12, sedangkan orde spasial yang digunakan dibatasi pada orde spasial 1, sehingga model GSTAR yang digunakan dalam penelitian ini adalah model GSTAR ([1,12]<sub>1</sub>). Model GSTAR ([1,12]<sub>1</sub>) dapat ditulis dengan persamaan sebagai berikut:

$$\mathbf{u}_{i,t} = [\Phi_{10}^1 + \Phi_{11}^1 \mathbf{W}] \mathbf{u}_{i,(t-1)} + [\Phi_{10}^{12} + \Phi_{11}^{12} \mathbf{W}] \mathbf{u}_{i,(t-12)} + \mathbf{e}_{i,t}.$$

Sedangkan dalam bentuk matriks dapat ditulis seperti berikut:

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

#### 4.4.2.2 Estimasi Parameter Model GSTARX

Dalam pemodelan GSTAR pada data residual ( $u_{i,t}$ ) IHK, metode estimasi parameter yang digunakan adalah estimasi GLS dikarenakan data residual ( $u_{i,t}$ ) IHK antar lokasi saling berkorelasi sehingga lebih akurat jika data yang berkorelasi diestimasi dengan GLS. Oleh karena itu untuk pemodelan GSTAR (1<sub>1</sub>) pada data residual ( $u_{i,t}$ ) IHK lima kota di Sumatera selanjutnya disebut dengan pemodelan GSTARX-GLS ([1,12]<sub>1</sub>).

Bobot lokasi yang digunakan dalam pemodelan GSTARX-GLS ([1,12]<sub>1</sub>) untuk peramalan IHK lima kota di Sumatera adalah bobot seragam, invers jarak, normalisasi inferensi parsial korelasi silang.

#### A. Pemodelan GSTARX-GLS ([1,12]<sub>1</sub>) dengan Bobot Seragam

Bobot seragam dalam pemodelan GSTARX-GLS mengasumsikan bahwa data IHK kelompok bahan makanan pada suatu lokasi memiliki pengaruh yang sama terhadap IHK kelompok bahan makanan di lokasi-lokasi lainnya. Matriks bobot seragam yang digunakan dalam analisis ini adalah sebagai berikut,

$$W_{ij} = \begin{bmatrix} 0 & 0,25 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0,25 & 0 \end{bmatrix}$$

Tabel 4.29 Hasil Estimasi Parameter Model GSTARX-GLS ( $[1,12]_1$ ) menggunakan Bobot Seragam

Lokasi	Parameter	Estimasi	Standard Error	P-Value
Padang	$\phi_{11}^1$	0,276	0,100	0,0062
	$\phi_{10}^{12}$	-0,484	0,050	<0,0001
Pekanbaru	$\phi_{21}^1$	0,177	0,058	0,0028
	$\phi_{20}^{12}$	-0,484	0,044	<0,0001
Jambi	$\phi_{30}^1$	-0,181	0,072	0,0128
	$\phi_{31}^1$	0,333	0,108	0,0024
	$\phi_{30}^{12}$	-0,385	0,048	<0,0001
Palembang	$\phi_{41}^1$	0,117	0,053	0,0279
	$\phi_{40}^{12}$	-0,349	0,051	<0,0001
Bengkulu	$\phi_{51}^1$	0,170	0,085	0,049
	$\phi_{50}^{12}$	-0,401	0,048	<0,0001

Hasil estimasi parameter model GSTARX-GLS menghasilkan 20 parameter. Tetapi tidak semua variabel yang diestimasi akan signifikan. Oleh karena itu dilakukan pemodelan ulang dengan hanya memasukkan variabel yang signifikan saja pada  $\alpha=5\%$  ditunjukkan pada Tabel 4.29. Hasil estimasi parameter selanjutnya digunakan untuk membentuk persamaan matriks model GSTARX-GLS ( $[1,12]_1$ ) bobot lokasi pada persamaan berikut :

$$\begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \\ u_{5,t} \end{bmatrix} = \left( \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0,181 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 0,276 & 0 & 0 & 0 & 0 \\ 0 & 0,177 & 0 & 0 & 0 \\ 0 & 0 & 0,333 & 0 & 0 \\ 0 & 0 & 0 & 0,117 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0,25 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0,25 & 0 \end{bmatrix} \begin{bmatrix} u_{1(t-1)} \\ u_{2(t-1)} \\ u_{3(t-1)} \\ u_{4(t-1)} \\ u_{5(n-1)} \end{bmatrix} \right) + \begin{pmatrix} -0,484 & 0 & 0 & 0 & 0 \\ 0 & -0,484 & 0 & 0 & 0 \\ 0 & 0 & -0,385 & 0 & 0 \\ 0 & 0 & 0 & -0,349 & 0 \\ 0 & 0 & 0 & 0 & -0,401 \end{pmatrix} \begin{bmatrix} 0 & 0,25 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0,25 & 0 \end{bmatrix} \begin{bmatrix} u_{1(t-12)} \\ u_{2(t-12)} \\ u_{3(t-12)} \\ u_{4(t-12)} \\ u_{5(t-12)} \end{bmatrix} + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \\ e_{5,t} \end{bmatrix}$$

atau

$$= \left( \begin{bmatrix} 0 & 0,069 & 0,069 & 0,069 & 0,0690 \\ 0,044 & 0 & 0,044 & 0,044 & 0,044 \\ 0,083 & 0,083 & -0,181 & 0,083 & 0,083 \\ 0,029 & 0,029 & 0,029 & 0 & 0,029 \\ 0,042 & 0,042 & 0,042 & 0,042 & 0 \end{bmatrix} \begin{bmatrix} u_{1(t-1)} \\ u_{2(t-1)} \\ u_{3(t-1)} \\ u_{4(t-1)} \\ u_{5(t-1)} \end{bmatrix} \right) + \left( \begin{bmatrix} -0,484 & 0 & 0 & 0 & 0 \\ 0 & -0,484 & 0 & 0 & 0 \\ 0 & 0 & -0,385 & 0 & 0 \\ 0 & 0 & 0 & -0,349 & 0 \\ 0 & 0 & 0 & 0 & -0,401 \end{bmatrix} \begin{bmatrix} u_{1(t-12)} \\ u_{2(t-12)} \\ u_{3(t-12)} \\ u_{4(t-12)} \\ u_{5(t-12)} \end{bmatrix} \right) + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \\ e_{5,t} \end{bmatrix}$$

Model dalam persamaan matriks tersebut kemudian dijabarkan untuk masing-masing lokasi (Padang, Pekanbaru, Jambi, Palembang, Bengkulu) sebagai berikut :

a) Model GSTARX-GLS ( $[1,12]_1$ ) di Padang

$$u_{1,t} = 0,069 u_{2,t-1} + 0,069 u_{3,t-1} + 0,069 u_{4,t-1} + 0,069 u_{5,t-1} - 0,484 u_{1,t-12} + e_{1,t},$$

b) Model GSTARX-GLS ( $[1,12]_1$ ) di Pekanbaru

$$u_{2,t} = 0,044 u_{1,t-1} + 0,044 u_{3,t-1} + 0,044 u_{4,t-1} + 0,044 u_{5,t-1} - 0,484 u_{2,t-12} + e_{2,t},$$

c) Model GSTARX-GLS ( $[1,12]_1$ ) di Jambi

$$u_{3,t} = 0,083 u_{1,t-1} + 0,083 u_{2,t-1} - 0,181 u_{3,t-1} + 0,083 u_{4,t-1} + 0,083 u_{5,t-1} - 0,385 u_{3,t-12} + e_{3,t},$$

d) Model GSTARX-GLS ( $[1,12]_1$ ) di Palembang

$$u_{4,t} = 0,029 u_{1,t-1} + 0,029 u_{2,t-1} + 0,029 u_{3,t-1} + 0,029 u_{5,t-1} - 0,349 u_{4,t-12} + e_{4,t}$$

e) Model GSTARX-GLS ( $[1,12]_1$ ) di Bengkulu

$$u_{5,t} = 0,042 u_{1,t-1} + 0,042 u_{2,t-1} + 0,042 u_{3,t-1} + 0,042 u_{4,t-1} - 0,401 u_{5,t-1} + e_{5,t},$$

Persamaan yang terbentuk dengan model GSTARX-GLS ( $[1,12]_1$ ) untuk data IHK bahan makanan di setiap lokasi dapat diketahui bahwa data IHK bahan makanan di suatu lokasi polanya akan mengikuti IHK bahan makanan di lokasi tersebut atau dari lokasi lain pada waktu yang berbeda. Dengan menggunakan bobot seragam diperoleh hasil bahwa pola data IHK kelompok bahan makanan pada suatu kota akan mengikuti pola data IHK kota lain satu bulan sebelumnya dan 12 bulan sebelumnya di kota itu sendiri. Pada satu bulan sebelumnya, untuk Kota Jambi selain mengikuti pola data IHK bahan makanan kota lain juga mengikuti pola IHK Kota Jambi itu sendiri.

## B. Pemodelan GSTARX-GLS ( $[1, 12]_1$ ) dengan Bobot Invers Jarak

Pemodelan GSTARX-GLS dengan menggunakan bobot invers jarak mengasumsikan bahwa IHK di suatu lokasi dipengaruhi oleh jauh atau dekatnya jarak yang dimiliki dengan lokasi lainnya. Jarak antara dua lokasi yang jauh akan memiliki bobot yang cenderung lebih rendah dibandingkan dengan jarak antara dua lokasi yang dekat.

Berdasarkan Gambar

**Gambar 4.2**, jarak antara kota Padang dan Palembang merupakan jarak terjauh dibandingkan lokasi lainnya, yaitu 884 km. Sedangkan jarak terdekat 283 km, yaitu jarak perjalanan darat antara kota Palembang dan kota Jambi. Jarak antar lima lokasi di Sumatera tersebut kemudian dinormalisasikan nilai invers jaraknya, yang kemudian digunakan sebagai matriks pembobot.

Matriks pembobot invers jarak berdasarkan peta jarak lima lokasi ditampilkan sebagai berikut :

$$W_{ij} = \begin{bmatrix} 0 & 0,44 & 0,22 & 0,15 & 0,19 \\ 0,40 & 0 & 0,27 & 0,17 & 0,16 \\ 0,17 & 0,23 & 0 & 0,37 & 0,23 \\ 0,14 & 0,16 & 0,42 & 0 & 0,28 \\ 0,19 & 0,18 & 0,31 & 0,32 & 0 \end{bmatrix}$$

Hasil estimasi parameter model GSTAR-GLS menghasilkan 20 parameter. Tetapi tidak semua variabel yang diestimasi akan signifikan. Oleh karena itu dilakukan pemodelan ulang dengan hanya memasukkan variabel yang signifikan saja pada  $\alpha=5\%$  akan ditunjukkan pada Tabel 4.30.

Tabel 4.30 Hasil Estimasi Parameter Model GSTARX-GLS ( $[1,12]_1$ ) menggunakan Bobot Invers Jarak

Lokasi	Parameter	Estimasi	Standard Error	P-Value
Padang	$\phi_{11}^1$	0,316	0,097	0,0014
	$\phi_{10}^{12}$	-0,476	0,050	<0,0001
Pekanbaru	$\phi_{21}^1$	0,186	0,053	0,0006
	$\phi_{20}^{12}$	-0,481	0,044	<0,0001
Jambi	$\phi_{30}^1$	-0,152	0,075	0,0443
	$\phi_{31}^1$	0,350	0,112	0,0022
	$\phi_{30}^{12}$	-0,384	0,048	<0,0001
Palembang	$\phi_{41}^1$	0,137	0,051	0,0077
	$\phi_{40}^{12}$	-0,345	0,051	<0,0001
Bengkulu	$\phi_{51}^1$	0,208	0,085	0,0155
	$\phi_{50}^{12}$	-0,398	0,047	<0,0001

Hasil estimasi parameter pada selanjutnya digunakan untuk membentuk persamaan matriks model GSTARX-GLS ( $[1,12]_1$ ) bobot lokasi pada persamaan berikut :

$$\begin{aligned}
& \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \\ u_{5,t} \end{bmatrix} = \\
& \left( \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.152 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} u_{1(t-1)} \\ u_{2(t-1)} \\ u_{3(t-1)} \\ u_{4(t-1)} \\ u_{5(n-1)} \end{bmatrix} \right) + \left( \begin{bmatrix} 0.316 & 0 & 0 & 0 & 0 \\ 0 & 0.186 & 0 & 0 & 0 \\ 0 & 0 & 0.35 & 0 & 0 \\ 0 & 0 & 0 & 0.137 & 0 \\ 0 & 0 & 0 & 0 & 0.208 \end{bmatrix} \begin{bmatrix} 0 & 0.44 & 0.22 & 0.15 & 0.19 \\ 0.40 & 0 & 0.27 & 0.17 & 0.16 \\ 0.17 & 0.23 & 0 & 0.37 & 0.23 \\ 0.14 & 0.16 & 0.42 & 0 & 0.28 \\ 0.19 & 0.18 & 0.31 & 0.32 & 0 \end{bmatrix} \begin{bmatrix} u_{1(t-1)} \\ u_{2(t-1)} \\ u_{3(t-1)} \\ u_{4(t-1)} \\ u_{5(n-1)} \end{bmatrix} \right) + \\
& \left( \begin{bmatrix} -0.476 & 0 & 0 & 0 & 0 \\ 0 & -0.481 & 0 & 0 & 0 \\ 0 & 0 & -0.384 & 0 & 0 \\ 0 & 0 & 0 & -0.345 & 0 \\ 0 & 0 & 0 & 0 & -0.398 \end{bmatrix} \begin{bmatrix} u_{1(t-12)} \\ u_{2(t-12)} \\ u_{3(t-12)} \\ u_{4(t-12)} \\ u_{5(n-12)} \end{bmatrix} \right) + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \\ e_{5,t} \end{bmatrix} \\
& = \left( \begin{bmatrix} 0 & 0.138 & 0.069 & 0.048 & 0.060 \\ 0.074 & 0 & 0.050 & 0.031 & 0.030 \\ 0.059 & 0.080 & -0.152 & 0.129 & 0.082 \\ 0.019 & 0.022 & 0.058 & 0 & 0.038 \\ -0.040 & 0.038 & 0.064 & 0.066 & 0 \end{bmatrix} \begin{bmatrix} u_{1(t-1)} \\ u_{2(t-1)} \\ u_{3(t-1)} \\ u_{4(t-1)} \\ u_{5(n-1)} \end{bmatrix} \right) + \left( \begin{bmatrix} -0.476 & 0 & 0 & 0 & 0 \\ 0 & -0.481 & 0 & 0 & 0 \\ 0 & 0 & -0.384 & 0 & 0 \\ 0 & 0 & 0 & -0.345 & 0 \\ 0 & 0 & 0 & 0 & -0.398 \end{bmatrix} \begin{bmatrix} u_{1(t-12)} \\ u_{2(t-12)} \\ u_{3(t-12)} \\ u_{4(t-12)} \\ u_{5(n-12)} \end{bmatrix} \right) + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \\ e_{5,t} \end{bmatrix}
\end{aligned}$$

Model dalam persamaan matriks tersbut kemudian dijabarkan untuk masing-masing lokasi (Padang, Pekanbaru, Jambi, Palembang, Bengkulu) sebagai berikut :

a) Model GSTARX-GLS ( $[1,12]_1$ ) di Padang

$$u_{1,t} = 0.138u_{2,t-1} + 0.069u_{3,t-1} + 0.048u_{4,t-1} + 0.06u_{5,t-1} - 0.476u_{1,t-12} + e_{1,t},$$

b) Model GSTARX-GLS ( $[1,12]_1$ ) di Pekanbaru

$$u_{2,t} = 0.074u_{1,t-1} + 0.05u_{3,t-1} + 0.031u_{4,t-1} + 0.03u_{5,t-1} - 0.481u_{2,t-1} + e_{2,t},$$

c) Model GSTARX-GLS ( $[1,12]_1$ ) di Jambi

$$u_{3,t} = 0.059u_{1,t-1} + 0.08u_{2,t-1} - 0.152u_{3,t-1} + 0.129u_{4,t-1} + 0.082u_{5,t-1} - 0.384u_{3,t-12} + e_{3,t},$$

d) Model GSTARX-GLS ( $[1,12]_1$ ) di Palembang

$$u_{4,t} = 0.019u_{1,t-1} + 0.022u_{2,t-1} + 0.058u_{3,t-1} + 0.038u_{5,t-1} - 0.345u_{4,t-12} + e_{4,t}$$

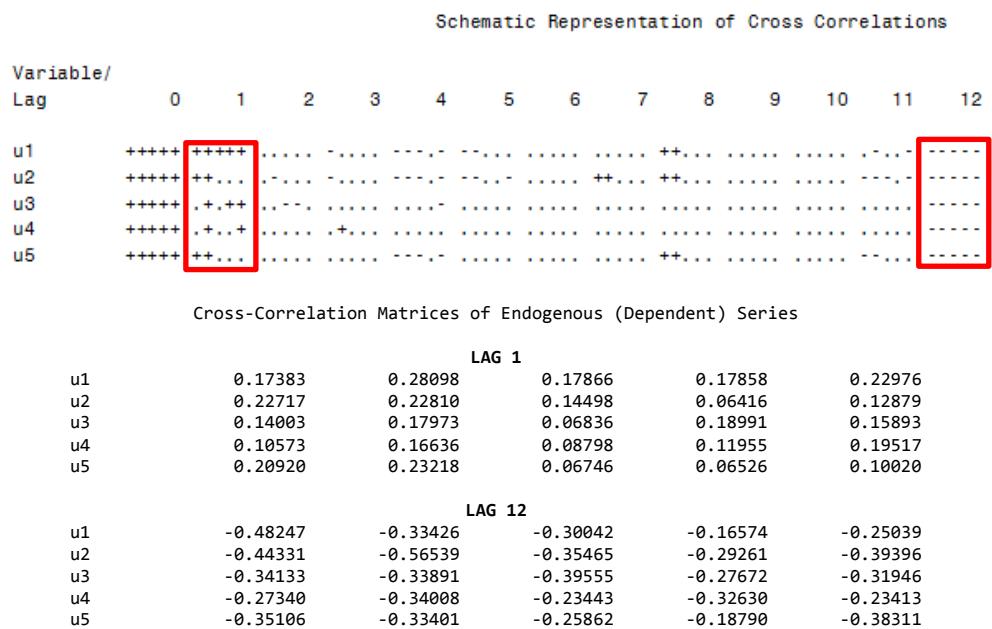
e) Model GSTARX-GLS ( $[1,12]_1$ ) di Bengkulu

$$u_{5,t} = 0.04u_{1,t-1} + 0.038u_{2,t-1} + 0.064u_{3,t-1} + 0.066u_{4,t-1} - 0.398u_{5,t-12} + e_{5,t},$$

Persamaan yang terbentuk dengan model GSTARX-GLS ( $[1,12]_1$ ) untuk data IHK bahan makanan di setiap lokasi dapat diketahui bahwa data IHK di suatu lokasi polanya akan mengikuti IHK di lokasi tersebut atau dari lokasi lain pada waktu yang berbeda. Misalnya, diketahui data IHK kelompok bahan makanan Kota Jambi poalnya mengikuti IHK kota tersebut satu bulan sebelumnya dan 12 bulan sebelumnya, serta IHK kota Padang, Pekanbaru, Palembang, dan Bengkulu 12 bulan sebelumnya.

### C. Bobot Normalisasi Inferensi Parsial Korelasi Silang

Pemodelan GSTARX-GLS pada pemodelan data IHK kelompok bahan makanan lima kota di Sumatera dengan menerapkan bobot normalisasi inferensi parsial korelasi silang mengasumsikan bahwa keterkaitan IHK antar lokasi lebih dipengaruhi oleh nilai tinggi rendahnya parsial silang yang dimiliki oleh data IHK pada suatu lokasi dengan IHK pada lokasi lainnya. Penghitungan bobot normalisasi inferensi parsial korelasi silang diperoleh melalui normalisasi dari nilai korelasi silang dari *error* yang telah diperoleh di level 1 antar lokasi pada lag yang bersesuaian. Tanda (+), (-), dan (.) dalam matriks MCCF digunakan sebagai pedoman, nilai korelasi mana saja yang dimasukkan dalam bobot. Berikut ini akan digambarkan penghitungan nilai bobot normalisasi inferensi parsial korelasi silang dari hasil output SAS.



Gambar 4.26 Plot MCCF Residual dari Pemodelan GSTAR Tahap 1

Nilai korelasi disesuaikan dengan tanda yang ada pada *schematic of cross correlation*, dan di-nolkan pada diagonal utama. Pertahankan angka korelasi pada dengan tanda (+) dan (-), dan nol pada (.). Ini semua dilakukan pada semua lag

yang sudah ditentukan sebelumnya, dalam penelitian ini menggunakan lag 1 dan 12.

Matriks bobot normalisasi inferensi parsial korelasi silang yang digunakan untuk mengestimasi atau menaksir parameter model GSTARX-GLS ([1,12]<sub>1</sub>) untuk lag 1 dituliskan pada matriks sebagai berikut,

$$W_{ij} = \begin{bmatrix} 0 & 0,32 & 0,21 & 0,21 & 0,26 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 0,34 & 0 & 0,36 & 0,30 \\ 0 & 0,46 & 0 & 0 & 0,54 \\ 0,47 & 0,53 & 0 & 0 & 0 \end{bmatrix}$$

Sedangkan bobot normalisasi korelasi silang untuk lag 12, adalah sebagai berikut,

$$W_{ij} = \begin{bmatrix} 0 & -0,32 & -0,29 & -0,16 & -0,24 \\ -0,30 & 0 & -0,24 & -0,20 & -0,27 \\ -0,27 & -0,27 & 0 & -0,22 & -0,25 \\ -0,25 & -0,31 & -0,22 & 0 & -0,22 \\ -0,31 & -0,30 & -0,23 & -0,17 & 0 \end{bmatrix}$$

Hasil estimasi parameter model GSTAR-GLS menghasilkan 20 parameter. Tetapi tidak semua variabel yang diestimasi akan signifikan. Oleh karena itu dilakukan pemodelan ulang dengan hanya memasukkan variabel yang signifikan saja pada  $\alpha=10\%$  akan ditunjukkan pada Tabel 4.31.

Tabel 4.31 Hasil Estimasi Parameter Model GSTARX-GLS ([1,12]<sub>1</sub>) Menggunakan Normalisasi Inferensi Parsial Korelasi Silang

Lokasi	Parameter	Estimasi	Standard Error	P-Value
Padang	$\phi_{10}^{12}$	-0,498	0,051	<0,0001
Pekanbaru	$\phi_{20}^{12}$	-0,507	0,043	<0,0001
Jambi	$\phi_{30}^{12}$	-0,387	0,048	<0,0001
Palembang	$\phi_{40}^{12}$	-0,383	0,051	<0,0001
Bengkulu	$\phi_{50}^{12}$	-0,418	0,046	<0,0001

Hasil estimasi parameter pada Tabel 4.31 selanjutnya digunakan untuk membentuk persamaan matriks model GSTARX-GLS ([1,12]<sub>1</sub>) bobot lokasi pada persamaan berikut :

$$\begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \\ u_{5,t} \end{bmatrix} = \left( \begin{bmatrix} -0.498 & 0 & 0 & 0 & 0 \\ 0 & -0.507 & 0 & 0 & 0 \\ 0 & 0 & -0.387 & 0 & 0 \\ 0 & 0 & 0 & -0.383 & 0 \\ 0 & 0 & 0 & 0 & -0.418 \end{bmatrix} \begin{bmatrix} u_{1(t-12)} \\ u_{2(t-12)} \\ u_{3(t-12)} \\ u_{4(t-12)} \\ u_{5(n-12)} \end{bmatrix} \right) + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \\ e_{5,t} \end{bmatrix}$$

Model dalam persamaan matriks tersebut kemudian dijabarkan untuk masing-masing lokasi (Padang, Pekanbaru, Jambi, Palembang, Bengkulu) sebagai berikut :

- a) Model GSTARX-GLS  $([1,12]_1)$  di Padang

$$u_{1,t} = -0,498 u_{1,t-12},$$

- b) Model GSTARX-GLS  $([1,12]_1)$  di Pekanbaru

$$u_{2,t} = -0,507 u_{2,t-12},$$

- c) Model GSTARX-GLS  $([1,12]_1)$  di Jambi

$$u_{3,t} = -0,387 u_{3,t-12},$$

- d) Model GSTARX-GLS  $([1,12]_1)$  di Palembang

$$u_{4,t} = -0,383 u_{4,t-12}$$

- e) Model GSTARX-GLS  $([1,12]_1)$  di Bengkulu

$$u_{5,t} = -0,418 u_{5,t-12},$$

Dengan menggunakan bobot normalisasi inferensi parsial korelasi silang, parameter yang signifikan akan berbeda dari bobot seragam dan invers jarak. Persamaan yang terbentuk dengan model GSTAR-GLS  $([1,12]_1)$  dapat diketahui bahwa data IHK kelompok bahan makanan di suatu lokasi polanya akan mengikuti IHK kelompok bahan makanan di lokasi tersebut pada 12 bulan sebelumnya. Indeks harga bahan makanan polanya tidak mengikuti lokasi lain.

#### 4.4.3 Pemodelan GSTARX

Pemodelan GSTARX merupakan kombinasi dari hasil peramalan tahap pertama dengan menggunakan model intervensi multiinput dan peramalan tahap kedua dengan menggunakan model GSTARX-GLS  $([1,12]_1)$ . Formula penghitungan pemodelan GSTARX adalah sebagai berikut:

$$\hat{Y}_{i,t} = \hat{y}_{i,t} + \hat{u}_{i,t}$$

dengan,

-  $\hat{Y}_{i,t}$  adalah hasil ramalan ke- $t$  di lokasi ke- $i$  dari model GSTARX

- $\hat{y}_{i,t}$  adalah hasil ramalan ke- $t$  di lokasi ke- $i$  pada tahap pertama,
- $\hat{u}_{i,t}$  adalah hasil ramalan ke- $t$  di lokasi ke- $i$  pada tahap kedua.

#### 4.4.4 Cek Diagnosa Model GSTARX

Pada tahap ini pengujian asumsi residual *white noise* dilakukan untuk memenuhi asumsi model GSTARX sehingga model dianggap layak. Pengujian tersebut dilakukan dengan cara memodelkan ulang *residual* dari model GSTARX dan melakukan pengecekan letak nilai AIC terkecil. Hasil penghitungan nilai AIC residual pada pemodelan GSTARX ( $[1,12]_1$ ) pada data IHK kelompok bahan makanan di Sumatera dapat dilihat pada Tabel 4.32.

Tabel 4.32 Nilai AIC Residual Model GSTARX Berdasarkan Jenis Bobot Lokasi pada Data IHK Kelompok Bahan Makanan di Sumatera

Bobot	Lag	MA (0)	MA (1)	MA (2)
Seragam	AR (0)	<b>-39,6525</b>	-39,4412	-39,4995
	AR (1)	-39,5295	-39,2161	-39,2201
Invers Jarak	AR (0)	<b>-39,6685</b>	-39,4186	-39,4923
	AR (1)	-39,5213	-39,1927	-39,2151
Normalisasi Inferensi Parsial Korelasi Silang (NIPKS)	AR (0)	<b>-39,5319</b>	-39,3813	-39,3818
	AR (1)	-39,4931	-39,2181	-39,1210

Hasil penghitungan menunjukkan bahwa nilai AIC terkecil pada ketiga model terletak pada lag AR(0) dan MA(0). Hal ini berarti asumsi residual *white noise* telah terpenuhi untuk semua model sehingga layak digunakan untuk peramalan.

Selain pengujian residual *white noise*, yang dilakukan adalah pengujian normalitas residual model GSTARX. Dengan menggunakan uji Kolmogorov Smirnov pada residual masing-masing lokasi, hasilnya ditunjukkan sebagai berikut.

Tabel 4.33 Nilai *P-Value* Uji Kolmogorov Smirnov Residual GSTARX

Bobot	Nilai p-value uji Kologorov Smirnov				
	Padang	Pekanbaru	Jambi	Palembang	Bengkulu
Seragam	>0,150	>0,150	>0,150	>0,150	>0,150
Invers Jarak	>0,150	>0,113	>0,150	>0,150	>0,150
NIPKS	>0,150	>0,150	>0,150	>0,150	>0,150

Berdasarkan Tabel 4.33 terlihat bahwa residual model GSTARX untuk semua bobot sudah memenuhi asumsi berdistribusi normal. Karena asumsi white noise dan residual berdistribusi normal sudah terpenuhi, maka langkah selanjutnya yaitu pemilihan model terbaik dapat dilakukan.

#### 4.5 Pemilihan Model Terbaik pada Model

Setelah memperoleh hasil pemodelan dan pengujian kelayakan model, selanjutnya dilakukan penghitungan efisiensi dan akurasi pemodelan dengan melihat RMSE *in-sample* serta RMSE *out-sample*. Jumlah data *in-sample* yang digunakan sebanyak 155 observasi sedangkan data *out-sample* sebanyak 12 observasi. Efisiensi dan akurasi hasil peramalan data *in-sample* dan *out-sample* pada pemodelan didasarkan pada nilai RMSE terkecil. Hasil penghitungan RMSE *in-sample* pada pemodelan ARIMA dan ARIMAX dapat dilihat pada Tabel 4.34 berikut ini,

Tabel 4.34 Nilai RMSE *In-Sample* Hasil Pemodelan ARIMA dan ARIMAX pada Data IHK Kelompok Bahan Makanan Lima Kota di Sumatera

Metode	Kota					RMSE Rata-rata	Efisiensi (%)
	Padang	Pekanbaru	Jambi	Palembang	Bengkulu		
ARIMA	2,257	1,403	2,114	1,389	2,006	<b>1,834</b>	
Variasi Kalender 1	2,257	1,403	2,088	1,251	2,006	<b>1,801</b>	1,80
Variasi Kalender 2	2,248	1,318	2,058	1,253	1,885	<b>1,752</b>	4,47
Intervensi	2,207	1,321	2,063	1,369	1,939	<b>1,778</b>	3,05
ARIMAX	2,235	1,335	2,034	1,277	1,762	<b>1,729</b>	5,73

Berdasarkan Tabel 4.34 model ARIMA dengan penambahan variabel eksogen berupa terjadinya hari raya Idul Fitri, kenaikan BBM, kejadian bencana alam di Sumatera, dan gabungan seluruh variabel eksogen mampu meningkatkan tingkat akurasi pemodelan. Secara umum, model variasi kalender skenario 1 (bulanan) dan skenario 2 (mingguan) mampu meningkatkan ketepatan pemodelan ARIMA masing-masing sebesar 1,8 % dan 4,47 %. Variasi kalender skenario 2 lebih baik dalam meningkatkan akurasi model ARIMA dibandingkan dengan variasi kalender skenario 1, karena pada variasi kalender 2 lebih bisa menangkap terjadinya Idul Fitri yang diasumsikan meningkatkan harga bahan makanan. Terjadinya Idul Fitri pada minggu pertama, kedua, ketiga, atau keempat akan memberikan pengaruh yang berbeda pada kenaikan harga bahan makanan di bulan tersebut. Model intervensi yaitu dengan variabel eksogen kenaikan BBM dan terjadinya bencana alam gempa bumi di Padang, Jambi, dan Bengkulu mampu meningkatkan akurasi model ARIMA sebesar 3,05 %. Pemodelan ARIMAX yang menggunakan seluruh variabel eksogen mampu meningkatkan akurasi sebesar 5,73 %. Pemodelan ARIMAX ini paling baik dalam meningkatkan akurasi model ARIMA.

Tabel 4.35 Nilai RMSE *In-Sample* Hasil Pemodelan GSTAR dan GSTARX pada Data IHK Kelompok Bahan Makanan Lima Kota di Sumatera

Metode	Kota					RMSE Rata-rata	Efisiensi (%)
	Padang	Pekanbaru	Jambi	Palembang	Bengkulu		
<b>GSTAR</b>							
Seragam	2,717	1,619	2,498	1,543	2,358	<b>2,147</b>	
Invers Jarak	2,714	1,612	2,515	1,550	2,359	<b>2,150</b>	
NIPKS	2,729	1,642	2,555	1,547	2,371	<b>2,169</b>	
<b>GSTARX</b>							
Seragam	2,723	1,625	2,508	1,528	2,346	<b>2,146</b>	0,04
Invers Jarak	2,717	1,618	2,512	1,531	2,346	<b>2,145</b>	0,24
NIPKS	2,733	1,651	2,514	1,521	2,342	<b>2,152</b>	0,77

Berdasarkan Tabel 4.35 secara rata-rata model GSTARX mampu meningkatkan akurasi daripada tanpa penambahan variabel eksogen. Pada

pemodelan GSTARX dengan bobot seragam mampu meningkatkan akurasi sebesar 0,04 %, pada bobot invers jarak mampu meningkatkan 0,24 %, dan pada bobot normalisasi inferensi korelasi parsial korelasi silang penambahan variabel eksogen dapat meningkatkan akurasi sebesar 0,77 %.

Tabel 4.36 Nilai RMSE *Out-Sample* Model ARIMA, ARIMAX, GSTAR, dan GSTARX pada Data IHK Kelompok Bahan Makanan Lima Kota di Sumatera

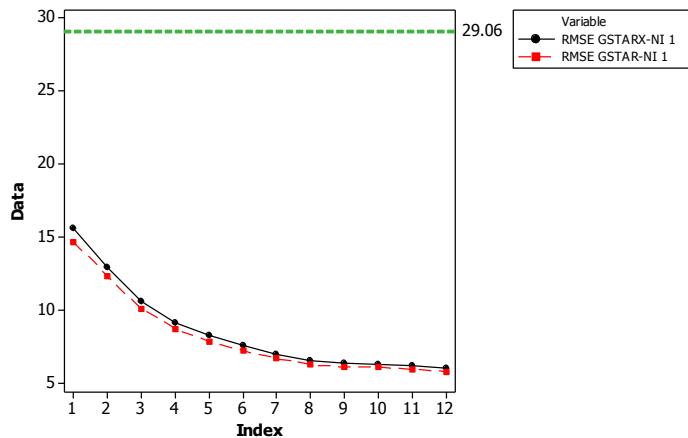
Metode	Kota					RMSE Rata-rata
	Padang	Pekanbaru	Jambi	Palembang	Bengkulu	
ARIMA	17,467	3,938	10,14	6,623	9,021	<b>9,438</b>
Variasi Kalender 1	17,467	3,938	10,14	6,692	9,021	<b>9,452</b>
Variasi Kalender 2	17,561	3,712	10,181	6,831	8,463	<b>9,35</b>
Intervensi	17,275	3,712	10,339	6,774	8,808	<b>9,382</b>
ARIMAX	16,232	4,407	10,228	6,601	8,189	<b>9,131</b>
<b>GSTAR</b>						
Seragam	6,016	2,516	3,552	2,283	3,362	<b>3,546</b>
Invers Jarak	6,045	2,539	3,707	2,447	3,395	<b>3,627</b>
NIPKS	5,778	2,365	3,439	2,312	3,255	<b>3,430</b>
<b>GSTARX</b>						
Seragam	6,053	2,501	3,565	2,373	3,282	<b>3,555</b>
Invers Jarak	6,040	2,499	3,640	2,408	3,326	<b>3,583</b>
NIPKS	6,015	2,503	3,544	2,402	3,239	<b>3,541</b>

Nilai RMSE *out-sample* pada Tabel 4.36 menunjukkan bahwa model terbaik pada data univariat adalah model ARIMAX. Dimana pada model tersebut telah dimasukkan semua variabel eksogen yang dianggap berpengaruh meningkatkan harga bahan makanan di Sumatera. Peristiwa Idul Fitri dan kenaikan BBM secara signifikan berpengaruh terhadap kenaikan harga kelompok makanan di lima kota, sedangkan terjadinya bencana gempa bumi hanya berpengaruh di Kota Bengkulu. Seperti kita ketahui bahwa Kota Bengkulu terletak di pantai barat Pulau Sumatera, dimana lokasi tersebut dekat dengan pertemuan dua lempeng sehingga sering terjadi gempa bumi. Selain Kota Bengkulu, Kota Padang juga terletak di pantai barat dan sering tertimpa bencana

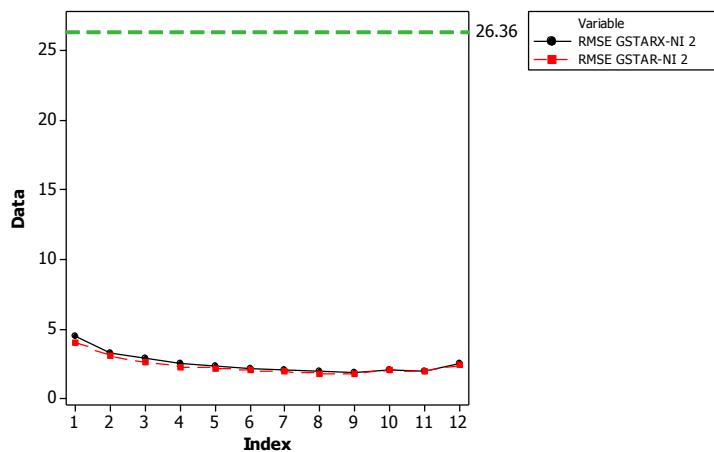
gempa bumi. Tetapi, bencana gempa bumi tidak berpengaruh pada kenaikan harga makanan di Padang.

Pada pemodelan GSTARX, model terbaik secara umum adalah dengan bobot normalisasi inferensi parsial korelasi silang. Jika dianalisis pada masing-masing kota, Kota Padang, Jambi, dan Bengkulu menunjukkan model terbaik adalah dengan bobot normalisasi inferensi parsial korelasi silang. Pada Kota Pekanbaru dengan invers jarak, sedangkan Palembang, model terbaik adalah GSTARX dengan bobot seragam. Dari pemodelan GSTARX dengan bobot normalisasi inferensi parsial korelasi silang diperoleh model bahwa data IHK kelompok bahan makanan pada suatu lokasi polanya akan mengikuti data lokasi tersebut 12 bulan yang lalu. Pemodelan GSTARX terbaik tidak menunjukkan adanya keterkaitan dengan wilayah lain. Hal tersebut berarti, pada fenomena harga bahan makanan di Pulau Sumatera tidak terbukti terdapat keterkaitan suatu lokasi dengan lokasi yang lain.

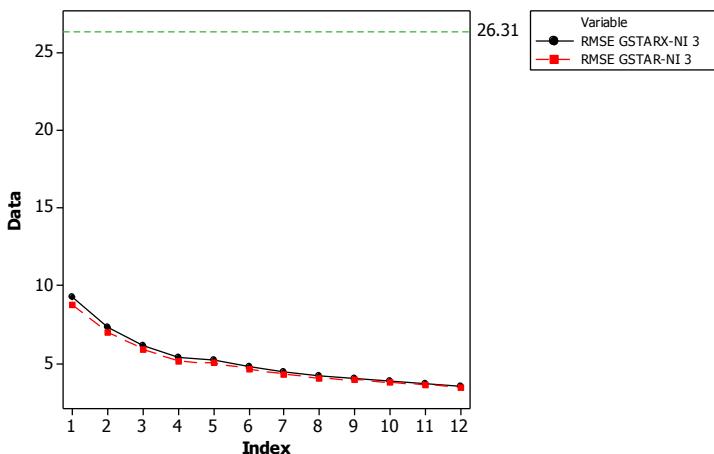
Perbandingan RMSE *out-sample k-step* GSTAR dan GSTARX dengan bobot normalisasi inferensi parsial korelasi silang juga dapat disajikan dalam bentuk plot deret waktu seperti Gambar 4.27 berikut,



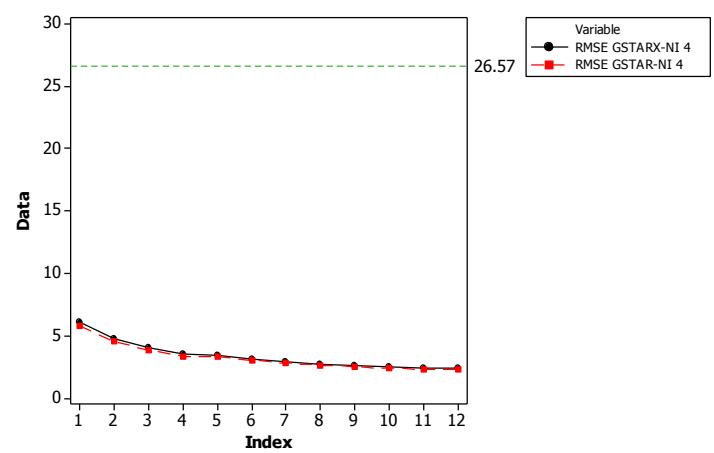
(1)



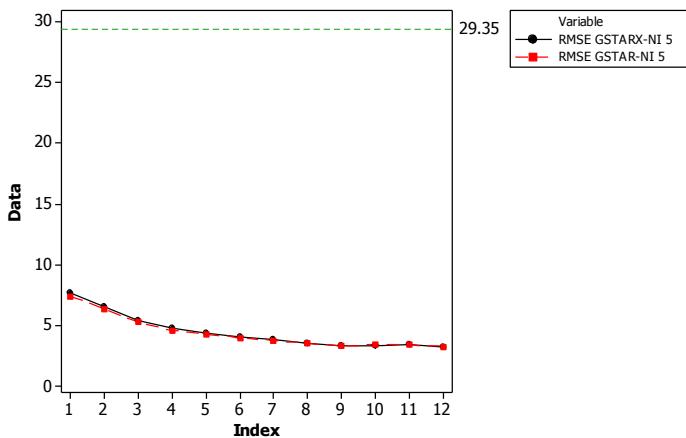
(2)



(3)



(4)



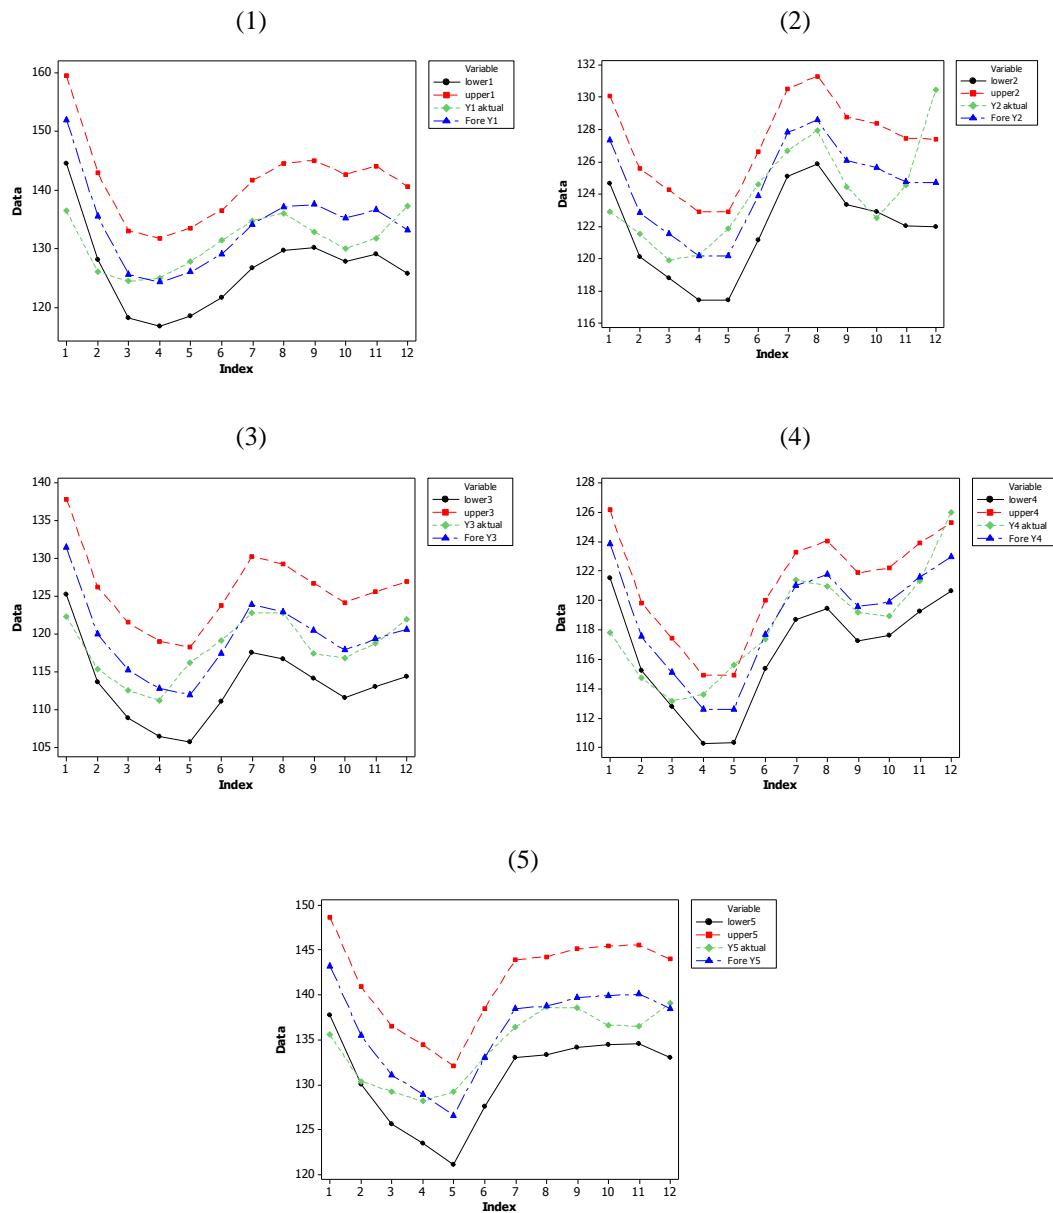
(5)

Gambar 4.27 Nilai RMSE *Out-Sample* untuk  $k$ -*Step* pada Lima Kota di Sumatera  
 (1)Padang, (2)Pekanbaru, (3)Jambi, (4)Palembang, (5)Bengkulu

Berdasarkan Gambar 4.27, nilai RMSE *out-sample* GSTAR dan GSTARX dengan bobot normalisasi inferensi parsial korelasi silang keduanya berada di bawah standar deviasi data (garis hijau putus-putus). Ini berarti sampai  $k=12$  pada kedua model tersebut masih cukup baik dalam melakukan peramalan. Nilai RMSE *out-sample* pada awal peramalan bernilai tinggi, hal tersebut dikarenakan ketidaktepatan dalam menentukan data *out-sample*. Penentuan data *out-sample* harus melihat kondisi data yang relatif stabil atau pola data yang tidak berubah. Karena jika terjadi perubahan pola maka model data *in-sample* menjadi tidak relevan.

#### 4.6 Peramalan pada Model GSTARX

Berikut ini merupakan hasil peramalan interval dari model terbaik yang sudah diperoleh dari langkah-langkah sebelumnya.



Gambar 4.28 Peramalan *Out-Sample* IHK Kelompok Bahan Makanan Model GSTARX dengan Bobot NIPKS  
 (1)Padang, (2)Pekanbaru, (3)Jambi, (4)Palembang, (5)Bengkulu

Perbandingan hasil peramalan interval dan data aktual pada Gambar 4.28 menunjukkan bahwa data aktual pada ramalan *step 1* (Bulan Januari 2015) berada di luar interval ramalan. Hal tersebut dikarenakan terjadi perubahan pola data aktual di waktu tersebut. Karena jika terjadi perubahan atau penyimpangan pola data maka model data *in-sample* menjadi tidak relevan. Sehingga, penentuan data *out-sample* harus melihat kondisi data yang relatif stabil.

Dari uraian di atas, dapat disimpulkan bahwa model terbaik pada Kota Padang adalah model GSTARX dengan menggunakan bobot normalisasi inferensi parsial korelasi silang. Dari model tersebut dapat dijelaskan bahwa data IHK kelompok bahan makanan Kota Padang akan mengikuti pola data tersebut setahun sebelumnya, atau berulang secara musiman (12 bulan). Pada Kota Pekanbaru model GSTARX terbaik adalah dengan bobot invers jarak dimana harga bahan makanan pola datanya mengikuti pola data harga makanan di lokasi lain sebulan sebelumnya dan lokasi tersebut 12 bulan sebelumnya. Model terbaik IHK kelompok bahan makanan Kota Jambi dan Bengkulu sama dengan Kota Padang. Lokasi berikutnya, yaitu Kota Palembang terpilih model terbaik adalah GSTAR dengan bobot seragam. Pada model ini, data harga bahan makanan mengikuti pola harga bahan makanan kota lain (Padang, Pekanbaru, Jambi, dan Bengkulu) satu bulan sebelumnya dan pola harga bahan makanan Kota Palembang itu sendiri 12 bulan sebelumnya. Pemodelan terbaik pada GSTARX tidak seluruhnya menunjukkan ada keterkaitan dengan wilayah lain. Hal tersebut berarti, pada fenomena harga bahan makanan di Pulau Sumatera tidak terbukti terdapat keterkaitan suatu lokasi dengan lokasi yang lain. Keterkaitan dengan wilayah lain hanya berlaku di Kota Pekanbaru dan Palembang.



## **BAB 5**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan hasil analisis dan pembahasan, maka kesimpulan yang diperoleh dari penelitian ini sebagai berikut:

- a. Penambahan variabel eksogen (variasi kalender, intervensi kenaikan BBM dan bencana alam) pada pemodelan ARIMA dapat memperkecil nilai RMSE dibandingkan ARIMA tanpa penambahan variabel eksogen pada data IHK kelompok bahan makanan lima kota di Sumatera. Penurunan RMSE sebesar 5,73 %.
- b. Penambahan variabel eksogen (variasi kalender, intervensi kenaikan BBM dan bencana alam) pada pemodelan GSTARX dapat memperkecil nilai RMSE *in-sample* dibandingkan GSTAR tanpa penambahan variabel eksogen pada data IHK kelompok bahan makanan lima kota di Sumatera. Penurunan RMSE *in-sample* sebesar 0,04 sampai 0,77 %.
- c. Pemodelan terbaik adalah GSTARX dengan bobot normalisasi inferensi parsial korelasi silang. Pemodelan terbaik tidak semuanya menunjukkan adanya keterkaitan dengan wilayah lain. Hal tersebut berarti, pada fenomena harga bahan makanan di Pulau Sumatera tidak terbukti terdapat keterkaitan suatu lokasi dengan lokasi yang lain pada kelima wilayah.

#### **5.2 Saran**

Saran yang dapat diberikan untuk penelitian selanjutnya :

1. Penentukan data *out-sample* harus melihat kondisi data yang relatif stabil atau pola *outsample* yang tidak berubah. Karena jika terjadi perubahan pola maka model data *in-sample* menjadi tidak relevan. Serta perlu ada studi lanjutan yang bisa menangkap pola data tertentu, sehingga tidak akan terjadi lagi kesalahan dalam penentuan data *out-sample*.
2. Perlu ditambahkan variabel eksogen lainnya yang mendukung pemodelan ARIMA dan GSTAR.

3. Bagi pemerintah khususnya Tim Pengendali Inflasi Daerah (TPID), peramalan data IHK dapat digunakan untuk menentukan skenario dalam mengatasi permasalahan kenaikan harga (inflasi) daerah.

## DAFTAR PUSTAKA

- Alaba, O. O., Olubusoye, E. O., & Ojo, S. O. (2010). Efficiency of Seemingly. *European Journal of Scientific Research, Vol.39, No.1*, 153-160.
- Anggraeni, W., Vinarti, R. A., & Kurniawati, Y. D. (2015). Performance Comparison Between ARIMA and ARIMAX method in Moslem Kids Clothes Demand Forecasting : Case Study. *Procedia Computer Science* 72, 630-637.
- Apriliadara, M., Suhartono, & Prastyo, D. D. (2016). VARI-X Model for Currency Inflow and Outflow Forecasting with Eid Fitri Effect in Indonesia. *AIP Conference Proceedings*, 1746, 020041.
- Baciu, I. C. (2015). Stochastic Models for Forecasting Inflation Rate. Empirical Evidence from Romania. *Procedia Economics and Finance* 20, 44-52.
- Badan Pusat Statistik (BPS). (2013). *Diagram Timbang Indeks Harga Konsumen (Buku 1)*. Jakarta: Badan Pusat Statistik.
- Badan Pusat Statistik (BPS). (2016). *Indeks Harga Konsumen 82 Kota di Indonesia*. Jakarta: Badan Pusat Statistik.
- Badan Pusat Statistik. (2011). *Ringkasan Eksekutif Statistik Potensi Daerah Indonesia 2011*. Jakarta: BPS.
- Badan Pusat Statistik. (2016). *Statistik Indonesia 2016*. Jakarta: Badan Pusat Statistik.
- Bank Indonesia. (n.d.). Retrieved 08 15, 2016, from www.bi.go.id: <http://www.bi.go.id/id/moneter/inflasi/pengenalan/Contents/Disagregasi.aspx>
- Bank Indonesia (BI). (2013). *Bank Indonesia dan Inflasi*. Retrieved 08 29, 2016, from <http://www.bi.go.id/id/moneter/inflasi/bi-dan-inflasi/Contents/Default.aspx>
- Bank Indonesia (BI). (2013). *Tujuan Kebijakan Moneter Bank Indonesia*. Retrieved September 28, 2016, from <http://www.bi.go.id/id/moneter/tujuan-kebijakan/Contents/Default.aspx>
- Borovkova, S., Lopuhaa, H. P., & Ruchjana, B. N. (2008). Consistency and Asymtotic Normality of Least Squares Estimators in Generalized STAR Models. *Statistica Neerlandica* Vol.62, 482-508.

- Box, G. P., Jenkins, G. M., & Reinsel, G. C. (2008). *Time Series Analysis : Forecasting and Control (4th edition)*. New Jersey: John Wiley & Sons.
- Central Bank of The Republic of Turkey. (2013). Short-Term Inflation Forecasting Model for Turkey and a Forecast Combination Analysis. *Economic Modelling*.
- Chou, K. W., & Tseng, Y. H. (2011). Pass Through of Oil Prices to CPI Inflation in Taiwan. *International Research Journal of Finance and Economics*, 73-83.
- Christoffersen, P. (1998). Evaluating Interval Forecast. *International Economic Review Vo. 39*, 841-862.
- Cleveland, W. P., & Grupe, M. R. (1983). *Modeling Time Series When Calender Effects are Present*. Retrieved from <https://www.census.gov/ts/.../ClevelandGrupe1983.pdf>.
- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis with Application in R*. Iowa: Springer.
- Deutsch, S. J., & Pfeifer, P. E. (1981). Space Time ARMA Modeling with Contemporaneously Correlated Innovations. *Technometrics Vol.23 No.4*, 401-409.
- Ditago, A. P., & Suhartono. (2015). Simulation Study of Parameter Estimation Two-Level GSTARX-GLS Model. *International Seminar on Science and Technology* (pp. 167-168). Surabaya: ITS.
- Eksiyandayani, S. (2016). *Pemodelan Peramalan Inflasi Umum dan Inflasi menurut Kelompok Pengeluaran di Indonesia dengan Metode Hibrida ARIMAX-NN [Tesis]*. Surabaya: ITS.
- Faizah, L. A., & Setiawan. (2013). Permodelan Inflasi di Kota Semarang, Yogyakarta, dan Surabaya dengan Pendekatan GSTAR. *Jurnal Sains dan Seni Pomits Vol.2 No.2*.
- Ghalayini, L. (2011). The Interaction between Oil Price and Economic Growth. *Middle Eastern Finance and Economics*, 127-141.
- Gooijer, J. D., & Hyndman, R. J. (2006). 25 Years of Time Series Forecasting. *International Journal of Forecasting 22*, 443-473.
- Greene, W. (2002). *Econometric Analysis. Fifth Edition*. New Jersey: Prentice Hall.

- Hasbullah, S. (2012). *Tangguh dengan Statistik, Akurat dalam Membaca Realita Dunia*. Bandung: Nuansa Cendekia.
- Hibon, M., & Makridakis, S. (1999). <https://flora.insead.edu>. Retrieved from [https://flora.insead.edu/fichierst\\_wp/inseadwp1999/99-70.pdf](https://flora.insead.edu/fichierst_wp/inseadwp1999/99-70.pdf)
- Kelikume, I., & Salami, A. (2014). Time Series Modeling and Forecasting Inflation : Evidence from Nigeria. *The International Journal of Business and Finance Research*, 41-52.
- Kementrian Dagang Indonesia (KADIN). (2011, Juli 26). Distribusi dan Penyediaan Pangan. Jakarta.
- Kim, J., & et.al. (2009). *Beyond point forecasting:Evaluation of Alternative Prediction Intervals for Tourist Arrivals*. Department of Econometrics and Business Statsitics Monash University.
- Kusumaningtyas, S. A., & Aldrian, E. (2016, 08 14). Impact of the June 2013 Riau Province Smoke Haze Event on Regional Air Pollution. *Environ Res. Lett.11*.
- Lee, M. H., Suhartono, & Sanugi, B. (2010). Multi Input Intervention Model for Evaluating the Impact of the Asian Crisis and Terrorist Attacks on Tourist Arrivals. *MATEMATIKA*, 83-106.
- Lim, C., Mc Aleer, M., & Min, J. C. (2008). ARMAX Modelling of International Tourist Demand. *Mathematic and Computers in Simulation*.
- Lipsey, R. G., Purvis, D. D., Steiner, P. O., & Courant, P. N. (1992). *Makroekonomi*. Jakarta: Binarupa Aksara.
- Liu, L. M. (1986). Identification of Time Series Model in The Presence of Calendar Variation. *International Journal of Forecasting* 2, 357-372.
- Lutkepohl, H. (2005). *New Introduction to Multiple Time Series Analysis*. Berlin: Springer.
- Moser, G., Rumler, F., & Scharler, J. (2004). *Forecasting Australian Inflation (Working Paper 91)*. Oesterreichische National Bank.
- Mulyaningsih, T., Ruchjana, B. N., & Soemartini. (2013, 01). *Pendekatan Model Time Series untuk Pemodelan Inflasi Beberapa Kota di Jawa Tengah*. Retrieved 08 11, 2016, from pustaka.unpad.ac.id: [http://pustaka.unpad.ac.id/wp-content/uploads/2015/01/Makalah-Semnas\\_Tri-Mulyaningsih\\_140720131.pdf](http://pustaka.unpad.ac.id/wp-content/uploads/2015/01/Makalah-Semnas_Tri-Mulyaningsih_140720131.pdf)

- Muryanto. (2016). *Pemodelan GSTAR-X untuk peramalan Indeks Harga Konsumen di Kalimantan*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Nizar, M. (2012). Dampak Fluktuasi Harga Minyak Dunia terhadapa Perekonomian Indonesia. *Buletin Ilmiah Litbang Perdagangan Vol.6 No.2*, 189-210.
- Novianti, P. W., & Suhartono. (2009). Modeling of Indonesia Consumer Price Index Using Multi Input Intervention Model. *Bulletin of Monetary Economic and Banking*, 75-95.
- Oktanindya, K. (2015). *Pemodelan GSTARX dengan Intervensi Pulse dan Step untuk Permalan Wisatawan Mancanegara [Tesis]*. Surabaya: ITS.
- Pfeifer, P., & Deutsch, S. (1980a). A Three Stage Iterative Procedure For Space Time Modeling. *Technometrics*, Vol 22, 35-47.
- Pfeifer, P., & Deutsch, S. (1980b). Identification and Interpretation of First Order Space Time ARMA Model. *Technometrics*, 397-408.
- Ramadhan, G. (2009). Analisis Keterkaitan harga antar Komoditas Kelompok Pembentuk Inflasi di Sumatera Barat. *Focus Group Discussion Pengendalian Inflasi di Sumatera Barat*. Padang: Bank Indonesia.
- Ridhwan, M. A., Karlina, I., & Yanfitri. (2012). *Kajian Komoditas Pangan Strategis: Faktor Determinasi Variasi Harga Antardaerah*. Jakarta: Bank Indonesia.
- Ridhwan, M. M., Ibrahim, I. F., & Karlina, I. (2012). *Perdagangan Antardaerah, Distribusi, Transportasi, dan Pengelolaan Stok Komoditas Pangan Strategis di Indonesia (Working Paper)*. Jakarta: Bank Indonesia.
- Ridhwan, M. M., Werdaningtyas, H., & Grace, M. V. (2013). *Dinamika dan Heterogenitas Inflasi Regional di Indonesia*. Jakarta: Bank Indonesia.
- Ruchjana, B. (2002). *The Generalized Space Time Autoregressive Order One Model and Its Application to Oil Production Data.[Disertasi, tidak dipublikasikan]*. Bandung: Department Mathematics, Institut Teknologi Bandung.
- Ruchjana, B. N. (2002). Suatu Model Generalized Space Time Autoregresive dan Penerapanya pada Produksi Minyak Bumi. Bandung: Program Doktor Institut Teknologi Bandung.

- Ruchjana, B. N., Borovkova, S. A., & Lopuhaa, H. P. (2012). Least Square Estimation of Generalized Space Time Autoregressive (GSTAR) Model and Its Properties. *The 5th International Conference on Research and Education in Mathematics* (pp. 61-64). American Institute of Physics.
- Srivastava, V., & Dwivedi, T. (1979). Estimation of Seemingly Unrelated Regression Equation; A Brief Syuvey. *Jurnal of Econometrics*, 15-32.
- Stephani, C. A. (2015). Peramalan Inflasi Nasional Berdasarkan Faktor Ekonomi Makro Menggunakan Pendekatan Time Series Klasik dan ANFIS. *Jurnal Sains dan Seni ITS Vo.1*, 67-72.
- Suhartono, & Atok, R. M. (2006). Perbandingan antara Model GSTAR dan VARIMA untuk Peramalan Data Deret Waktu dan Lokasi.
- Suhartono, & Subanar. (2006). The Optimal Determination of Space Weight in GSTAR Model by Using Cross-Correlation Inference. *Jurnal Of Quantitative Methods*, (pp. 45-53).
- Suhartono, Lee, M. H., & Hamzah, N. A. (2010). Calendar Variation Model based on Time Series Regression for Sales Forecast: The Ramadhan Effects. *Proceedings of the Regional Conference on Statistical Science 2010 (RCSS'10)*.
- Suhartono, Lee, M. H., & Prastyo, D. D. (2015). Two Level ARIMAX and Regression Models for Forecasting Time Series Data with Calendar Variation Effect. *AIP Conference Proceedings*, 1691, 050026.
- Sukirno, S. (2008). *Makro Ekonomi (Teori Pengantar)*. Jakarta: PT. Raja Grafindo.
- Supriyatna, Y. (2011). *Analisis Dampak Bencana terhadap Perekonomian Indonesia dengan Pendekatan SNSE (Tesis)*. Depok: Universitas Indonesia.
- Suseno, & Astiyah, S. (2009). *Inflasi* (Vol. 22). Jakarta: Pusat Pendidikan dan Studi Kebanksentralan (PPSK) Bank Indonesia.
- Syahtria, M. F., Suhandak, & Firdausi, N. (2016). Dampak Inflasi, Fluktuasi Harga Minyak dan Emas Domestik terhadapa Nilai Tukar Rupiah dan Pertumbuhan Ekonomi. *Jurnal Administrasi Bisnis Vol.32*, 59-68.
- Terzi, s. (1995). Maximum Likelihood Estimation of a GSTAR (1:1) Model. *Statistical Method and Application* , 377-393.

- Tiao, G. C., & Box, G. P. (1981). Modeling Multiple Time Series with Applications. *Journal of American Statistical Association* Vol.76, 802-816.
- Urquhart, A., & McGroarty, F. (2014). Calendar Effects, market condition and the Adaptive Market Hypothesis:Evidence from Long Run U.S. Data. *International Review of Financial Analysis*, 13-25.
- Wahyuningrum, S. (2014). *Model G-STAR-GLS untuk Peramalan Spatio Temporal*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Wei, W. (2006). *Time Series Analysis Univariate and Multivariate Methods*. Pearson International.
- Wulandari, D. A., Gusriani, N., & Ruchjana, B. N. (2014). Penaksiran Parameter Model Vector Autoregressive Integrated (VARI) dengan Metode MLE dan Penerapannya pada Data Indeks Harga Konsumen. *IndoMS Journal Statistics* Vol.2 No.1, 27-37.
- Wutsqa, D. U., & Suhartono. (2010). Peramalan Deret Waktu Multivariat Seasonal pada Data Pariwisata dengan Model VAR-GSTAR. *Jurnal Ilmu Dasar* Vol.11, 101-109.
- Wutsqa, D. U., Suhartono, & Sutijo, B. (2010). Generalized Space Time Autoregressive Modelling. *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and Its Applications (ICMSA2010)* (pp. 752-761). Malaysia: Universiti Tunku Abdul Rahman.
- Wutsqa, D., & Suhartono. (2010). Peramalan Deret Waktu Multivariate Seasonal pada Data Pariwisata dengan Model VAR-GSTAR. *Jurnal Ilmu Dasar*, 101-109.
- Xiumei, S., Min, Z., & Ming, Z. (2011). Empirical Study on The Relationship Between Economics Growth and Carbon Emmision in Resource-Dependent Cities Based on Vector Autoregressive Model. *Energy Procedia*.
- Zellner, A. (1962). An Efficient Method of Estimating Seemingly Unrelated Regression and test for Aggregation Bias. *Journal of The American Statistical Association*, 346-368.
- Zivot, E. (2013, May 29). *Multivariate Time Series and Vector Autoregressions*.

## LAMPIRAN

### Lampiran 1. *Syntax ARIMA*

```
data work.arimainf;
  infile "C:\data\data_ln.txt" dlm='09'x;
  input y1 y2 y3 y4 y5;

/*-----ARIMA Y1([4],1,[4,5])(0,1,1)12-----*/

proc arima data=work.arimainf;
  /*--- Pemodelan ARIMA Y1 -----*/
  identify var=y1(1,12) noprint;
  run;

  /*--- fit of model -----*/
  estimate p=(4) q=(4,5)(12) noconstant plot;
  forecast lead=12 out=ramalan;
  run;

  outlier maxnum=5 alpha=0.05;
  run;

  /*--- test of normality -----*/
  proc univariate data=ramalan normal;
    var residual;
    run;

proc export data=work.ramalan
  /*--- save output -----*/
  outfile='c:\OUTPUT\arima1_ln_p4.q4.12.xls'
  dbms=excel replace;
  sheet="p4.q4.5.12_ln";
  run;

/*-----ARIMA Y2-----*/

proc arima data=work.arimainf;
  /*--- Pemodelan ARIMA Y2_2 -----*/
  identify var=y2(1,12) noprint;
  run;

  /*--- fit of model -----*/
  estimate q=(1 2)(12) noconstant plot;
  forecast lead=12 out=ramalan;
  run;
```

```

outlier maxnum=5 alpha=0.05;
run;

/*--- test of normality -----*/
proc univariate data=ramalan normal;
var residual;
run;

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\OUTPUT\arima2_ln1.xls'
dbms=excel replace;
sheet="q1.2.12";
run;

/*-----ARIMA Y3-----*/

proc arima data=work.arimainf;
/*--- Pemodelan ARIMA Y3 -----*/
identify var=y3(1,12) noprint;
run;

/*--- fit of model -----*/
estimate q=(2)(12) noconstant plot;
forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

/*--- test of normality -----*/
proc univariate data=ramalan normal;
var residual;
run;

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\OUTPUT\arima3_ln1.xls'
dbms=excel replace;
sheet="q2.12";
run;

/*-----ARIMA Y4-----*/

proc arima data=work.arimainf;
/*--- Pemodelan ARIMA Y4_1 -----*/

```

```

identify var=y4(1,12) noprint;
run;

/*--- fit of model -----*/
estimate p=(1) q=(1)(12) noconstant plot;
forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

/*--- test of normality -----*/
proc univariate data=ramalan normal;
var residual;
run;

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\OUTPUT\arima4_ln1_p1.q1.12.xls'
dbms=excel replace;
sheet="p1.q1.12";
run;

/*-----ARIMA Y5-----*/

proc arima data=work.arimainf;
/*--- Pemodelan ARIMA Y5_2 -----*/
identify var=y5(1,12) noprint;
run;

/*--- fit of model -----*/
estimate p=(4) q=(12) noconstant plot;
forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

/*--- test of normality -----*/
proc univariate data=ramalan normal;
var residual;
run;

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\OUTPUT\arima5_ln2_p4.q12.xls'

```

```
dbms=excel replace;  
sheet="p4.q12";  
run;
```

## Lampiran 2. Estimasi Parameter Model ARIMA

KOTA PADANG

### The ARIMA Procedure

#### Conditional Least Squares Estimation

Parameter	Standard Estimate	Error	t Value	Approx Pr >  t	Lag
MA1,1	-0.67108	0.16204	-4.14	<.0001	4
MA1,2	0.17489	0.07035	2.49	0.0139	5
MA2,1	0.79463	0.05090	15.61	<.0001	12
AR1,1	-0.74002	0.15491	-4.78	<.0001	4

#### Autocorrelation Check of Residuals

Lag	Square	DF	To	Chi-	Pr > Autocorrelations-----				
			ChiSq	-----					
6	4.83	2	0.0892	0.104	-0.051	-0.122	-0.002	-0.005	-0.004
12	10.56	8	0.2278	0.028	-0.023	-0.089	-0.089	0.110	0.051
18	20.90	14	0.1043	-0.064	-0.049	0.091	0.112	0.139	-0.094
24	26.63	20	0.1459	0.027	-0.040	0.033	-0.045	0.149	-0.040
30	33.00	26	0.1622	-0.137	-0.049	-0.047	0.043	0.081	0.003

#### Tests for Normality

Test	--Statistic---		----p Value-----	
Shapiro-Wilk	W	0.987041	Pr < W	0.1258
Kolmogorov-Smirnov	D	0.051161	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.082994	Pr > W-Sq	0.1956
Anderson-Darling	A-Sq	0.555185	Pr > A-Sq	0.1536

KOTA PEKANBARU

### The ARIMA Procedure

#### Conditional Least Squares Estimation

Parameter	Standard Estimate	Error	t Value	Approx Pr >  t	Lag
MA1,1	-0.25655	0.07527	-3.41	0.0008	1
MA1,2	0.27286	0.07551	3.61	0.0004	2
MA2,1	0.72828	0.05461	13.34	<.0001	12

#### Autocorrelation Check of Residuals

Lag	Square	DF	To	Chi-	Pr > Autocorrelations-----				
			ChiSq	-----					
6	3.45	3	0.3269	0.005	0.023	-0.030	-0.113	-0.069	-0.029
12	10.48	9	0.3131	0.087	0.021	-0.064	0.071	-0.135	-0.062
18	17.38	15	0.2967	-0.061	0.054	0.036	0.102	0.131	-0.038
24	30.75	21	0.0779	-0.018	-0.194	-0.078	-0.117	0.099	0.043
30	34.10	27	0.1632	-0.023	-0.000	-0.026	-0.071	0.076	-0.066

#### Tests for Normality

Test	--Statistic---		----p Value-----	
Shapiro-Wilk	W	0.967955	Pr < W	0.0007
Kolmogorov-Smirnov	D	0.052262	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.079255	Pr > W-Sq	0.2177
Anderson-Darling	A-Sq	0.584018	Pr > A-Sq	0.1317

KOTA JAMBI

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Standard Estimate	Error	t Value	Pr >  t	Lag
MA1,1	0.29508	0.07528	3.92	0.0001	2
MA2,1	0.76632	0.05127	14.95	<.0001	12

Autocorrelation Check of Residuals

Lag	Square	DF	To ChiSq	Pr > Autocorrelations-----					
6	3.05	4	0.5492	0.055	0.022	0.097	-0.062	0.021	-0.026
12	4.98	10	0.8924	-0.039	-0.043	-0.021	-0.036	-0.068	0.032
18	11.03	16	0.8075	-0.069	-0.048	-0.054	0.147	-0.027	-0.012
24	17.91	22	0.7110	-0.014	-0.120	-0.017	0.041	0.135	-0.027
30	26.36	28	0.5533	-0.018	0.137	-0.087	-0.009	0.006	0.122

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.986898	Pr < W 0.1207
Kolmogorov-Smirnov	D 0.05248	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.05904	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.411853	Pr > A-Sq >0.2500

KOTA PALEMBANG

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Standard Estimate	Error	t Value	Pr >  t	Lag
MA1,1	-0.75081	0.19353	-3.88	0.0002	1
MA2,1	0.62891	0.06226	10.10	<.0001	12
AR1,1	-0.60081	0.23387	-2.57	0.0111	1

Autocorrelation Check of Residuals

Lag	Square	DF	To ChiSq	Pr > Autocorrelations-----					
6	1.87	3	0.5993	-0.041	-0.073	0.032	0.033	-0.043	0.006
12	4.44	9	0.8802	-0.024	0.016	0.065	-0.031	0.005	0.090
18	11.55	15	0.7128	-0.114	-0.084	-0.093	-0.054	0.064	0.053
24	18.27	21	0.6320	0.030	-0.139	0.061	0.001	0.041	-0.096
30	27.91	27	0.4157	-0.029	0.156	-0.010	-0.084	0.117	0.038

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.989988	Pr < W 0.2883
Kolmogorov-Smirnov	D 0.049861	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.063872	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.442311	Pr > A-Sq >0.2500

KOTA BENGKULU

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Standard Estimate	Error	t Value	Pr >  t	Lag
MA1,1	0.72562	0.05487	13.22	<.0001	12
AR1,1	-0.22668	0.07722	-2.94	0.0038	4

Autocorrelation Check of Residuals									
Lag	Square	DF	ChiSq	To	Chi-	Pr >	Autocorrelations-----		
6	3.46	4	0.4835	0.064	-0.104	-0.001	-0.007	-0.050	-0.052
12	5.50	10	0.8552	0.006	-0.018	0.041	0.011	-0.055	0.078
18	9.33	16	0.8992	-0.020	-0.028	-0.104	0.088	0.028	-0.004
24	15.04	22	0.8605	-0.020	-0.028	-0.040	-0.033	0.146	-0.063
30	19.04	28	0.8969	-0.035	0.077	-0.059	0.027	-0.004	0.092

Tests for Normality									
Test	--Statistic---			----p Value-----					
Shapiro-Wilk	W	0.988796	Pr < W	0.2076					
Kolmogorov-Smirnov	D	0.035855	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.041121	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.29122	Pr > A-Sq	>0.2500					

### Lampiran 3. Syntax Variasi Kalender

```
data work.arima_cv;
  infile "c:\data\data_vc2_ln.txt" dlm='09'x;
  input y1 y2 y3 y4 y5 d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t;

/*----- VARIASI KALENDER BULANAN -----*/
/*----- VARIASI KALENDER Y1_PADANG -----*/
proc arima data=work.arima_cv;
  /*----look at the input prosess-----*/
  identify var=y1(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12)) noprint;
run;

/*----fit of model -----*/
estimate p=(4) q=(4)(12) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
  /*--- test of normality -----*/
  var residual;
run;

/*----- VARIASI KALENDER Y2_PEKANBARU -----*/
proc arima data=work.arima_cv;
  /*----look at the input prosess-----*/
  identify var=y2(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12)) noprint;
run;

/*----fit of model -----*/
estimate P=(1 2 4) q=(12) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
  /*--- test of normality -----*/
  var residual;
run;

/*----- VARIASI KALENDER Y3_JAMBI -----*/
proc arima data=work.arima_cv;
  /*----look at the input prosess-----*/
```

```

identify var=y3(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate q=(2)(12) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

/*----- VARIASI KALENDER Y4_PALEMBANG -----*/
proc arima data=work.arima_cv;
/*-----look at the input prosess-----*/
identify var=y4(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate p=(1) q=(1)(12) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

*----- VARIASI KALENDER Y5_BENGKULU-----*/
proc arima data=work.arima_cv;
/*-----look at the input prosess-----*/
identify var=y5(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate p=(4) q=(12) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;

```

```

run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

/*----- VARIASI KALENDER MINGGUAN -----*/
data work.arima_cv;
infile "c:\data\data_vc1_ln.txt" dlm='09'x;
input y1 y2 y3 y4 y5 dt_1 dt;

/*----- VARIASI KALENDER Y1_PADANG -----*/
proc arima data=work.arima_cv;
/*-----look at the input prosess-----*/
identify var=y1(1,12) crosscorr=(dt_1(1,12) dt(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate p=(4) q=(4)(12) noconstant input=(dt_1 dt) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\output\vcbulan_1.xls'
dbms=excel
replace;
sheet="p4.q4.12";
run;

/*----- VARIASI KALENDER Y2_PEKANBARU-----*/
proc arima data=work.arima_cv;
/*-----look at the input prosess-----*/
identify var=y2(1,12) crosscorr=(dt_1(1,12) dt(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate q=(1 2)(12) noconstant input=(dt_1 dt) plot;
run;

forecast lead=12 out=ramalan;
run;

```

```

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

/*----- VARIASI KALENDER Y3_JAMBI-----*/
proc arima data=work.arima_cv;
/*-----look at the input prosess-----*/
identify var=y3(1,12) crosscorr=(dt_1(1,12) dt(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate q=(2)(12) noconstant input=(dt_1 dt) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\output\vcbulan_3.xls'
dbms=excel
replace;
sheet="q2.12";
run;

/*----- VARIASI KALENDER Y4_PALEMBANG -----*/
proc arima data=work.arima_cv;
/*-----look at the input prosess-----*/
identify var=y4(1,12) crosscorr=(dt_1(1,12) dt(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate p=(1) q=(1)(12) noconstant input=(dt_1 dt) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

```

```

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\output\vcbulan_4.xls'
dbms=excel
replace;
sheet="p1.q1.12";
run;

/*----- VARIASI KALENDER Y5_BENGKULU -----*/
proc arima data=work.arima_cv;
/*----look at the input prosess-----*/
identify var=y5(1,12) crosscorr=(dt_1(1,12) dt(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate p=(4) q=(12) noconstant input=(dt_1 dt) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\output\vcbulan_5.xls'
dbms=excel
replace;
sheet="p4.q12";
run;

```

#### Lampiran 4. Hasil Estimasi Parameter Model Variasi Kalender

KOTA PADANG

The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift	
MA1,1	-0.69720	0.15621	-4.46	<.0001	4	y1	0	
MA1,2	0.16400	0.06929	2.37	0.0191	5	y1	0	
MA2,1	0.79539	0.05118	15.54	<.0001	12	y1	0	
AR1,1	-0.76613	0.14768	-5.19	<.0001	4	y1	0	
NUM1	0.02398	0.01115	2.15	0.0330	0	d1t_1	0	

Autocorrelation Check of Residuals									
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations				
6	4.61	2	0.0997	0.098	-0.049	-0.116	0.015	-0.021	-0.027
12	10.42	8	0.2368	0.020	0.000	-0.110	-0.058	0.117	0.054
18	21.72	14	0.0846	-0.068	-0.064	0.121	0.123	0.098	-0.111
24	28.52	20	0.0976	0.040	-0.014	0.023	-0.055	0.160	-0.061
30	31.83	26	0.1987	-0.086	-0.070	-0.013	0.007	0.062	0.007

Tests for Normality								
Test			--Statistic--	p Value-----				
Shapiro-Wilk		W	0.988147	Pr < W	0.1728			
Kolmogorov-Smirnov		D	0.052007	Pr > D	>0.1500			
Cramer-von Mises		W-Sq	0.07895	Pr > W-Sq	0.2195			
Anderson-Darling		A-Sq	0.535732	Pr > A-Sq	0.1751			

KOTA PEKANBARU

The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift	
MA1,1	0.72100	0.05609	12.85	<.0001	12	y2	0	
AR1,1	0.22352	0.07600	2.94	0.0038	1	y2	0	
AR1,2	-0.25838	0.07778	-3.32	0.0011	2	y2	0	
AR1,3	-0.15405	0.07675	-2.01	0.0464	4	y2	0	
NUM1	0.03525	0.0086412	4.08	<.0001	0	d1t_1	0	
NUM2	0.03410	0.0085984	3.97	0.0001	0	d1t	0	

Autocorrelation Check of Residuals									
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations				
6	3.25	2	0.1972	0.013	-0.033	0.085	-0.008	-0.017	-0.100
12	6.89	8	0.5485	0.061	0.018	-0.067	0.045	-0.085	-0.049
18	13.70	14	0.4722	-0.066	0.071	0.056	0.097	0.065	-0.102
24	25.44	20	0.1849	-0.000	-0.113	-0.118	-0.143	0.106	0.044
30	29.52	26	0.2878	-0.073	0.042	0.021	-0.103	0.047	0.001

Tests for Normality								
Test			--Statistic--	p Value-----				
Shapiro-Wilk		W	0.994301	Pr < W	0.7662			
Kolmogorov-Smirnov		D	0.053182	Pr > D	>0.1500			
Cramer-von Mises		W-Sq	0.042722	Pr > W-Sq	>0.2500			
Anderson-Darling		A-Sq	0.259729	Pr > A-Sq	>0.2500			

KOTA JAMBI

The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift	
MA1,1	0.77234	0.05201	14.85	<.0001	12	y3	0	
AR1,1	-0.25529	0.07694	-3.32	0.0011	2	y3	0	
NUM1	0.0090191	0.0063154	1.43	0.1552	0	dt_1	0	
NUM2	0.01209	0.0061415	1.97	0.0507	0	dt	0	

Autocorrelation Check of Residuals									
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations				
6	4.96	4	0.2910	0.054	-0.030	0.103	-0.118	-0.021	-0.012
12	7.45	10	0.6825	-0.064	-0.029	0.006	-0.051	-0.075	0.024
18	11.81	16	0.7568	-0.066	-0.035	-0.022	0.130	-0.018	-0.014
24	19.36	22	0.6230	-0.033	-0.113	-0.040	0.048	0.141	-0.035
30	28.37	28	0.4451	-0.024	0.154	-0.088	-0.057	-0.002	0.097

Tests for Normality								
Test	--Statistic---			-----p Value-----				
Shapiro-Wilk	W	0.98902	Pr < W	0.2210				
Kolmogorov-Smirnov	D	0.043325	Pr > D	>0.1500				
Cramer-von Mises	W-Sq	0.042129	Pr > W-Sq	>0.2500				
Anderson-Darling	A-Sq	0.313511	Pr > A-Sq	>0.2500				

The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift	
MA1,1	0.29679	0.07598	3.91	0.0001	2	y3	0	
MA2,1	0.77372	0.05116	15.12	<.0001	12	y3	0	
NUM1	0.04713	0.01297	3.63	0.0004	0	d1t_1	0	
NUM2	0.04455	0.01294	3.44	0.0007	0	d1t	0	

Autocorrelation Check of Residuals									
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations				
6	2.78	4	0.5961	0.060	0.019	0.086	-0.068	0.001	0.013
12	3.83	10	0.9546	-0.060	-0.006	0.004	-0.047	-0.006	0.005
18	11.54	16	0.7752	-0.150	0.003	0.027	0.109	-0.064	-0.048
24	16.47	22	0.7921	-0.048	-0.029	-0.030	-0.012	0.145	0.007
30	28.47	28	0.4396	0.001	0.179	-0.069	-0.050	0.007	0.142

Tests for Normality								
Test	--Statistic---			-----p Value-----				
Shapiro-Wilk	W	0.995272	Pr < W	0.8753				
Kolmogorov-Smirnov	D	0.044889	Pr > D	>0.1500				
Cramer-von Mises	W-Sq	0.037854	Pr > W-Sq	>0.2500				
Anderson-Darling	A-Sq	0.267367	Pr > A-Sq	>0.2500				

KOTA PALEMBANG

The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift	
MA1,1	-0.76705	0.12015	-6.38	<.0001	1	y4	0	

MA2,1	0.71172	0.05764	12.35	<.0001	12	y4	0		
AR1,1	-0.50844	0.16131	-3.15	0.0019	1	y4	0		
NUM1	0.0078880	0.0038639	2.04	0.0428	0	dt_1	0		
NUM2	0.02043	0.0038175	5.35	<.0001	0	dt	0		
Autocorrelation Check of Residuals									
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations-----				
6	3.99	3	0.2622	-0.055	-0.105	0.052	0.057	-0.057	0.000
12	6.84	9	0.6538	-0.039	0.020	0.066	0.030	-0.075	0.054
18	12.62	15	0.6318	-0.033	-0.089	-0.069	-0.082	0.100	0.024
24	23.89	21	0.2985	0.046	-0.151	0.018	0.117	-0.004	-0.138
30	35.85	27	0.1186	-0.011	0.202	-0.030	-0.082	0.087	0.057
Tests for Normality									
Test			--Statistic--		p Value-----				
Shapiro-Wilk			W	0.98822	Pr < W	0.1764			
Kolmogorov-Smirnov			D	0.052096	Pr > D	>0.1500			
Cramer-von Mises			W-Sq	0.070896	Pr > W-Sq	>0.2500			
Anderson-Darling			A-Sq	0.474143	Pr > A-Sq	0.2431			
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Pr >  t	Lag	Variable	Shift	
MA1,1	-0.79371		0.11127	-7.13	<.0001	1	y4	0	
MA2,1	0.71071		0.05831	12.19	<.0001	12	y4	0	
AR1,1	-0.53561		0.15359	-3.49	0.0006	1	y4	0	
NUM1	0.03215		0.0078107	4.12	<.0001	0	dt_1	0	
NUM2	0.04009		0.0077595	5.17	<.0001	0	dt	0	
NUM3	0.01552		0.0042347	3.66	0.0003	0	d2t	0	
NUM4	0.01845		0.0037813	4.88	<.0001	0	d4t	0	
Autocorrelation Check of Residuals									
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations-----				
6	3.18	3	0.3641	-0.047	-0.082	0.058	0.045	-0.059	0.027
12	4.44	9	0.8802	-0.043	-0.002	0.051	0.020	0.034	0.030
18	11.07	15	0.7476	-0.111	-0.076	0.017	-0.106	0.078	0.006
24	13.39	21	0.8943	0.011	-0.068	0.022	0.057	-0.041	-0.043
30	23.01	27	0.6846	0.053	0.128	-0.053	-0.087	0.114	0.071
Tests for Normality									
Test			--Statistic--		p Value-----				
Shapiro-Wilk			W	0.991074	Pr < W	0.3834			
Kolmogorov-Smirnov			D	0.045735	Pr > D	>0.1500			
Cramer-von Mises			W-Sq	0.045144	Pr > W-Sq	>0.2500			
Anderson-Darling			A-Sq	0.310188	Pr > A-Sq	>0.2500			
KOTA BENGKULU									
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Pr >  t	Lag	Variable	Shift	
MA1,1	0.73837		0.05426	13.61	<.0001	12	y5	0	
AR1,1	-0.22855		0.07740	-2.95	0.0036	4	y5	0	
NUM1	0.01147		0.0044060	2.60	0.0101	0	dt	0	
Autocorrelation Check of Residuals									
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations-----				

6	7.32	4	0.1201	0.106	-0.152	0.027	-0.006	-0.073	-0.046
12	9.07	10	0.5254	-0.020	-0.021	0.051	0.027	-0.068	0.030
18	12.64	16	0.6988	0.042	-0.032	-0.103	0.058	0.050	-0.003
24	16.60	22	0.7853	-0.051	-0.011	-0.069	0.027	0.092	-0.060
30	19.32	28	0.8881	-0.009	0.078	-0.057	0.001	0.022	0.059

#### Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.987409	Pr < W 0.1398
Kolmogorov-Smirnov	D 0.029622	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.018864	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.161178	Pr > A-Sq >0.2500

#### The ARIMA Procedure

##### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.27396	0.07701	3.56	0.0005	4	y5	0
MA2,1	0.74680	0.05389	13.86	<.0001	12	y5	0
NUM1	0.03800	0.01067	3.56	0.0005	0	d1t_1	0
NUM2	-0.01655	0.0064130	-2.58	0.0108	0	d4t_1	0
NUM3	0.04943	0.01064	4.64	<.0001	0	d1t	0

##### Autocorrelation Check of Residuals

Lag	Square	DF	ChiSq	Autocorrelations-----						
				To	Chi-	Pr >				
6	3.00	4	0.5580	0.084	-0.074	0.010	-0.015	-0.064	-0.023	
12	4.58	10	0.9173	-0.005	0.049	0.040	0.065	0.022	-0.005	
18	6.29	16	0.9846	-0.056	-0.007	-0.017	0.063	0.022	-0.037	
24	11.44	22	0.9679	-0.070	0.099	-0.027	-0.074	0.071	0.027	
30	13.87	28	0.9881	0.049	0.035	-0.027	0.002	0.028	0.082	

#### Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.995399	Pr < W 0.8876
Kolmogorov-Smirnov	D 0.040869	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.031935	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.20959	Pr > A-Sq >0.2500

## Lampiran 5. Syntax Model Intervensi

```
data work.arimainf;
  infile"C:\data\data_intervensi.txt" dlm='09'x;
  input y1 y2 y3 y4 y5;

/*----- Y1_Intervensi -----*/
data work.arimainf;
  set work.arimainf;
  if _n_>=70 then s70=1;
  else s70=0;
  if _n_=87 then a87=1;
  else a87=0;
  if _n_=118 then a118=1;
  else a118=0;

proc arima data=work.arimainf;
  /*-----look at the input prosess-----*/
  identify var=y1(1,12) crosscorr=(s70(1,12) a87(1,12) a118(1,12)) nlag=12 noprint;
  run;

  /*-----fit of model -----*/
  estimate p=(4) q=(4,5)(12) noconstant input=(s70 a87 a118 ) plot;
  run;

  forecast lead=12 out=ramalan;
  run;

  outlier maxnum=5 alpha=0.05;
  run;

  proc univariate data=ramalan normal;
  /*--- test of normality -----*/
  var residual;
  run;

/*----- Y2_Intervensi -----*/
data work.arimainf;
  set work.arimainf;
  if _n_>=70 then s70=1;
  else s70=0;
  if _n_=87 then a87=1;
  else a87=0;
  if _n_=118 then a118=1;
  else a118=0;

proc arima data=work.arimainf;
  /*-----look at the input prosess-----*/
  identify var=y2(1,12) crosscorr=(s70(1,12) a87(1,12) a118(1,12)) nlag=12 noprint;
  run;

  /*-----fit of model -----*/
  estimate q=(1,2)(12) noconstant input=(s70 a87 a118) plot;
  run;

  forecast lead=12 out=ramalan;
  run;
```

```

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

/*----- Y3_Intervensi -----*/
data work.arimainf;
set work.arimainf;
if _n_>=70 then s70=1;
else s70=0;
if _n_=87 then a87=1;
else a87=0;
if _n_=118 then a118=1;
else a118=0;

proc arima data=work.arimainf;
/*-----look at the input prosess-----*/
identify var=y3(1,12) crosscorr=(s70(1,12) a87(1,12) a118(1,12)) nlag=12 noprint;
run;

/*-----fit of model -----*/
estimate q=(2)(12) noconstant input=(s70 a87 a118) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

/*----- Y4_Intervensi -----*/
data work.arimainf;
set work.arimainf;
if _n_>=70 then s70=1;
else s70=0;
if _n_=87 then a87=1;
else a87=0;
if _n_=118 then a118=1;
else a118=0;

proc arima data=work.arimainf;
/*-----look at the input prosess-----*/
identify var=y4(1,12) crosscorr=(s70(1,12) a87(1,12) a118(1,12)) nlag=12 noprint;
run;

```

```

/*-----fit of model -----*/
estimate p=(1) q=(1)(12) noconstant input=(s70 a87 a118) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

/*----- Y5_Intervensi -----*/
data work.arimainf;
set work.arimainf;
if _n_>=70 then s70=1;
else s70=0;
if _n_=87 then a87=1;
else a87=0;
if _n_=118 then a118=1;
else a118=0;

proc arima data=work.arimainf;
/*-----look at the input prosess-----*/
identify var=y5(1,12) crosscorr=(s70(1,12) a87(1,12) a118(1,12)) nlag=12 noprint;
run;

/*-----fit of model -----*/
estimate p=(4) q=(12) noconstant input=(s70 a118) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

```

## Lampiran 6. Output Estimasi Parameter Intervensi

KOTA PADANG

### The ARIMA Procedure

#### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
MA1,1	-0.61769	0.20598	-3.00	0.0031	4	y1	0
MA1,2	0.15151	0.07258	2.09	0.0384	5	y1	0
MA2,1	0.80660	0.05035	16.02	<.0001	12	y1	0
AR1,1	-0.70838	0.19096	-3.71	0.0003	4	y1	0
NUM1	0.09199	0.02704	3.40	0.0008	0	s70	0

#### Autocorrelation Check of Residuals

Lag	Square	DF	To	Chi-	Pr > Autocorrelations-----				
			ChiSq	-----	-----	-----	-----	-----	
6	2.29	2	0.3179	0.071	0.005	-0.083	0.013	-0.034	-0.001
12	6.17	8	0.6278	-0.016	0.005	-0.098	-0.073	0.073	0.034
18	17.14	14	0.2490	-0.061	-0.078	0.112	0.097	0.109	-0.122
24	27.56	20	0.1202	0.043	-0.021	0.038	-0.121	0.177	-0.061
30	29.74	26	0.2785	-0.080	-0.042	-0.034	0.013	0.037	0.002

#### Tests for Normality

Test	--Statistic---		----p Value-----	
Shapiro-Wilk	W		Pr < W	
Kolmogorov-Smirnov	D		Pr > D	
Cramer-von Mises	W-Sq		Pr > W-Sq	
Anderson-Darling	A-Sq		Pr > A-Sq	

KOTA JAMBI

### The ARIMA Procedure

#### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
MA1,1	0.25627	0.07645	3.35	0.0010	2	y3	0
MA2,1	0.75997	0.05185	14.66	<.0001	12	y3	0
NUM1	0.09216	0.02452	3.76	0.0002	0	s70	0

#### Autocorrelation Check of Residuals

Lag	Square	DF	To	Chi-	Pr > Autocorrelations-----				
			ChiSq	-----	-----	-----	-----	-----	
6	2.63	4	0.6218	0.042	0.017	0.095	-0.064	-0.000	-0.004
12	5.22	10	0.8757	-0.055	-0.007	-0.027	-0.019	-0.098	0.025
18	10.48	16	0.8403	-0.083	-0.032	-0.036	0.130	-0.027	-0.037
24	15.17	22	0.8549	-0.023	-0.092	-0.053	0.010	0.105	-0.035
30	22.76	28	0.7447	-0.044	0.136	-0.075	-0.031	-0.018	0.101

#### Tests for Normality

Test	--Statistic---		----p Value-----	
Shapiro-Wilk	W		Pr < W	
Kolmogorov-Smirnov	D		Pr > D	
Cramer-von Mises	W-Sq		Pr > W-Sq	
Anderson-Darling	A-Sq		Pr > A-Sq	

KOTA PALEMBANG

### The ARIMA Procedure

Conditional Least Squares Estimation												
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift					
MA1,1	0.63855	0.06106	10.46	<.0001	12	y4	0					
NUM1	0.06137	0.01782	3.44	0.0007	0	s70	0					
Autocorrelation Check of Residuals												
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations							
6	2.06	5	0.8412	0.043	-0.090	0.044	-0.008	-0.011				
12	3.63	11	0.9796	-0.027	0.023	0.045	-0.024	0.042				
18	11.55	17	0.8265	-0.121	-0.106	-0.087	-0.058	0.063				
24	15.85	23	0.8617	0.026	-0.116	0.025	0.016	-0.005				
30	23.03	29	0.7752	-0.003	0.134	-0.032	-0.070	0.093				
Tests for Normality												
Test			--Statistic--		p Value-----							
Shapiro-Wilk		W	0.988764	Pr < W	0.2057							
Kolmogorov-Smirnov		D	0.067414	Pr > D	0.0632							
Cramer-von Mises		W-Sq	0.116223	Pr > W-Sq	0.0714							
Anderson-Darling		A-Sq	0.680867	Pr > A-Sq	0.0781							
KOTA BENGKULU												
The ARIMA Procedure												
Conditional Least Squares Estimation												
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift					
MA1,1	0.71776	0.05639	12.73	<.0001	12	y5	0					
AR1,1	-0.23313	0.07791	-2.99	0.0032	4	y5	0					
NUM1	0.09445	0.02359	4.00	<.0001	0	s70	0					
NUM2	0.02852	0.01686	1.69	0.0925	0	a118	0					
Autocorrelation Check of Residuals												
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations							
6	0.93	4	0.9197	0.013	-0.043	-0.034	-0.007	-0.038				
12	3.92	10	0.9509	0.007	-0.017	-0.029	0.045	-0.079				
18	7.09	16	0.9714	-0.050	-0.032	-0.068	0.088	-0.036				
24	13.72	22	0.9112	0.003	-0.030	-0.035	-0.055	0.133				
30	18.18	28	0.9214	-0.002	0.077	-0.083	0.060	-0.031				
Tests for Normality												
Test			--Statistic--		p Value-----							
Shapiro-Wilk		W	0.993694	Pr < W	0.6898							
Kolmogorov-Smirnov		D	0.043168	Pr > D	>0.1500							
Cramer-von Mises		W-Sq	0.043759	Pr > W-Sq	>0.2500							
Anderson-Darling		A-Sq	0.335013	Pr > A-Sq	>0.2500							

## Lampiran 7. Syntax ARIMAX

```

data work.arimax;
  infile "c:\data\data_vc2_ln.txt" dlm='09'x;
  input y1 y2 y3 y4 y5 d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t;

/*-----ARIMAX_Y1-----*/
data work.arimax;
  set work.arimax;
  if _n_>=70 then s70=1;
  else s70=0;
  if _n_=87 then a87=1;
  else a87=0;
  if _n_=118 then a118=1;
  else a118=0;

proc arima data=work.arimax;
  /*-----look at the input prosess-----*/
  identify var=y1(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12) s70(1,12) a87(1,12) a118(1,12)) noprint;
  run;

  /*-----fit of model -----*/
  estimate p=(0) q=(0) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t s70 a87 a118)
plot;
  run;

  forecast lead=12 out=ramalan;
  run;

  outlier maxnum=5 alpha=0.05;
  run;

proc univariate data=ramalan normal;
  /*--- test of normality -----*/
  var residual;
  run;

/*-----ARIMAX_Y2-----*/
data work.arimax;
  set work.arimax;
  if _n_>=70 then s70=1;
  else s70=0;

proc arima data=work.arimax;
  /*-----look at the input prosess-----*/
  identify var=y2(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12) s70(1,12)) noprint;
  run;

  /*-----fit of model -----*/
  estimate p=(0) q=(0) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t s70) plot;
  run;

  forecast lead=12 out=ramalan;
  run;

```

```

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\OUTPUT\GSTARX\GSTARX_Y2(lokal).xls'
dbms=excel replace;
sheet="1";
run;

/*-----ARIMAX_Y3-----*/
data work.arimax;
set work.arimax;
if _n_>=70 then s70=1;
else s70=0;
if _n_=118 then a118=1;
else a118=0;

proc arima data=work.arimax;
/*-----look at the input prosess-----*/
identify var=y3(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12) s70(1,12) a118(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate p=(0) q=(0) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t s70 a118) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

/*-----ARIMAX_Y4-----*/
data work.arimax;
set work.arimax;
if _n_>=70 then s70=1;
else s70=0;

proc arima data=work.arimax;
/*-----look at the input prosess-----*/
identify var=y4(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12) s70(1,12)) noprint;
run;

```

```

/*-----fit of model -----*/
estimate p=(0) q=(0) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t s70) plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

proc export data=work.ramalan
/*--- save output -----*/
outfile='c:\OUTPUT\GSTARX\GSTARX_Y4(lokal).xls'
dbms=excel replace;
sheet="1";
run;

/*-----ARIMAX_Y5-----*/
data work.arimax;
set work.arimax;
if _n_>=70 then s70=1;
else s70=0;
if _n_=87 then a87=1;
else a87=0;
if _n_=118 then a118=1;
else a118=0;

proc arima data=work.arimax;
/*-----look at the input prosess-----*/
identify var=y5(1,12) crosscorr=(d1t_1(1,12) d2t_1(1,12) d3t_1(1,12) d4t_1(1,12) d1t(1,12)
d2t(1,12) d3t(1,12) d4t(1,12) s70(1,12) a87(1,12) a118(1,12)) noprint;
run;

/*-----fit of model -----*/
estimate p=(0) q=(0) noconstant input=(d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t s70 a87 a118)
plot;
run;

forecast lead=12 out=ramalan;
run;

outlier maxnum=5 alpha=0.05;
run;

proc univariate data=ramalan normal;
/*--- test of normality -----*/
var residual;
run;

```

## Lampiran 8. Output Estimasi Parameter ARIMAX

KOTA PADANG								
The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift	
MA1,1	0.22384	0.07889	2.84	0.0051	5	y1	0	
MA2,1	0.82012	0.04841	16.94	<.0001	12	y1	0	
NUM1	0.09869	0.02699	3.66	0.0003	0	s70	0	
Autocorrelation Check of Residuals								
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations			
6	4.30	4	0.3673	0.086	0.002	-0.091	-0.096	0.005
12	6.20	10	0.7978	0.010	0.075	0.007	-0.045	0.052
18	22.16	16	0.1382	-0.138	-0.046	0.116	0.133	0.139
24	30.45	22	0.1079	0.005	-0.033	0.010	-0.108	0.171
30	31.56	28	0.2929	-0.033	-0.007	-0.062	0.007	0.023
Tests for Normality								
Test	--Statistic---			-----p Value-----				
Shapiro-Wilk	W	0.990383		Pr < W	0.3204			
Kolmogorov-Smirnov	D	0.044458		Pr > D	>0.1500			
Cramer-von Mises	W-Sq	0.062811		Pr > W-Sq	>0.2500			
Anderson-Darling	A-Sq	0.441262		Pr > A-Sq	>0.2500			
KOTA PEKANBARU								
The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift	
MA1,1	-0.18249	0.07769	-2.35	0.0200	1	y2	0	
MA2,1	0.70511	0.05662	12.45	<.0001	12	y2	0	
NUM1	0.01791	0.0064461	2.78	0.0061	0	dit	0	
NUM2	0.09810	0.01756	5.59	<.0001	0	s70	0	
Autocorrelation Check of Residuals								
Lag	Square	DF	To Chi-Sq	Pr >	Autocorrelations			
6	5.73	4	0.2206	-0.020	-0.106	0.003	-0.135	-0.041
12	9.81	10	0.4570	0.090	0.021	-0.016	0.007	-0.103
18	16.41	16	0.4246	-0.085	0.013	0.074	0.089	0.109
24	29.75	22	0.1248	-0.063	-0.135	-0.112	-0.107	0.142
30	31.17	28	0.3097	-0.030	0.015	-0.015	-0.073	0.003
Tests for Normality								
Test	--Statistic---			-----p Value-----				
Shapiro-Wilk	W	0.989166		Pr < W	0.2302			
Kolmogorov-Smirnov	D	0.059001		Pr > D	>0.1500			
Cramer-von Mises	W-Sq	0.10259		Pr > W-Sq	0.1042			
Anderson-Darling	A-Sq	0.601402		Pr > A-Sq	0.1192			

KOTA JAMBI

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
MA1,1	0.27879	0.07703	3.62	0.0004	2	y3	0
MA2,1	0.76520	0.05187	14.75	<.0001	12	y3	0
NUM1	0.02954	0.01426	2.07	0.0399	0	d1t_1	0
NUM2	0.03717	0.01293	2.88	0.0046	0	d1t	0
NUM3	0.07222	0.02723	2.65	0.0088	0	s70	0

Autocorrelation Check of Residuals

Lag	Square	DF	ChiSq	Pr > Autocorrelations						
				To	Chi-	Pr >	Autocorrelations			
6	2.87	4	0.5803	0.052	0.018	0.089	-0.070	-0.011	0.025	
12	4.63	10	0.9147	-0.073	0.013	0.008	-0.048	-0.044	0.004	
18	11.94	16	0.7484	-0.153	0.019	0.016	0.098	-0.048	-0.061	
24	15.74	22	0.8287	-0.049	-0.035	-0.046	-0.031	0.113	-0.004	
30	27.05	28	0.5154	-0.036	0.176	-0.065	-0.059	-0.011	0.126	

Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.994049	Pr < W 0.7349
Kolmogorov-Smirnov	D 0.04479	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.046489	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.324761	Pr > A-Sq >0.2500

KOTA PALEMBANG

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
MA1,1	-0.78610	0.16487	-4.77	<.0001	1	y4	0
MA2,1	0.65111	0.06203	10.50	<.0001	12	y4	0
AR1,1	-0.63156	0.20690	-3.05	0.0027	1	y4	0
NUM1	0.03156	0.0080890	3.90	0.0001	0	d1t_1	0
NUM2	0.03649	0.0080416	4.54	<.0001	0	d1t	0
NUM3	0.01402	0.0050282	2.79	0.0059	0	d2t	0

Autocorrelation Check of Residuals

Lag	Square	DF	ChiSq	Pr > Autocorrelations						
				To	Chi-	Pr >	Autocorrelations			
6	1.40	3	0.7061	-0.045	-0.063	0.040	0.019	-0.016	0.001	
12	2.46	9	0.9819	-0.032	0.026	0.014	0.011	0.054	0.032	
18	11.07	15	0.7473	-0.173	-0.042	-0.006	-0.105	0.059	0.025	
24	12.36	21	0.9294	-0.009	-0.046	0.015	0.043	-0.033	-0.034	
30	23.12	27	0.6786	0.011	0.144	-0.039	-0.090	0.122	0.088	

Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.991065	Pr < W 0.3825
Kolmogorov-Smirnov	D 0.045232	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.049156	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.33618	Pr > A-Sq >0.2500

KOTA BENGKULU

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Pr >  t	Approx Lag	Variable	Shift
MA1,1	0.72467	0.05637	12.86	<.0001	12	y5	0
AR1,1	-0.32048	0.07742	-4.14	<.0001	4	y5	0
NUM1	-0.02000	0.0060795	-3.29	0.0012	0	d4t_1	0
NUM2	0.03287	0.0084875	3.87	0.0002	0	d1t	0
NUM3	0.02377	0.0089823	2.65	0.0089	0	d3t	0
NUM4	0.09604	0.02122	4.53	<.0001	0	s70	0
NUM5	0.03510	0.01498	2.34	0.0203	0	a87	0
NUM6	0.04393	0.01580	2.78	0.0061	0	a118	0

Autocorrelation Check of Residuals									
Lag	Square	DF	ChiSq	To	Chi-	Pr >			
				-----	-----	Autocorrelations-----			
6	1.09	4	0.8952	0.052	0.006	-0.023	-0.005	-0.021	0.052
12	2.55	10	0.9901	-0.063	-0.013	-0.014	0.052	-0.033	0.003
18	3.53	16	0.9995	-0.032	-0.050	-0.016	0.005	-0.038	0.000
24	6.84	22	0.9992	-0.073	0.062	-0.055	0.007	0.031	-0.063
30	8.79	28	0.9998	-0.000	0.054	0.005	0.017	0.080	-0.000

Tests for Normality									
Test				--Statistic--	p Value-----				
Shapiro-Wilk		W	0.995654	Pr < W	0.9105				
Kolmogorov-Smirnov		D	0.032062	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.019552	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.155685	Pr > A-Sq	>0.2500				

## Lampiran 9. Output GSTAR Bobot Seragam

The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v11	1	0.259314	0.099375	2.61	0.0100
y112	1	-0.48719	0.050580	-9.63	<.0001
 Model Y2T Dependent Variable y2					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v21	1	0.170656	0.058893	2.90	0.0043
y212	1	-0.49699	0.043948	-11.31	<.0001
 Model Y3T Dependent Variable y3					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
y31	1	-0.16870	0.071857	-2.35	0.0202
v31	1	0.315335	0.108015	2.92	0.0040
y312	1	-0.39922	0.047671	-8.37	<.0001
 Model Y4T Dependent Variable y4					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v41	1	0.127601	0.053223	2.40	0.0177
y412	1	-0.36047	0.050994	-7.07	<.0001
 Model Y5T Dependent Variable y5					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v51	1	0.174774	0.084741	2.06	0.0409
y512	1	-0.42776	0.047162	-9.07	<.0001

## Lampiran 10. Output GSTAR Bobot Invers Jarak

The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v11	1	0.316861	0.094383	3.36	0.0010
y112	1	-0.47823	0.050317	-9.50	<.0001
		Model Dependent Variable		Y2T	
				y2	
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v21	1	0.191045	0.052025	3.67	0.0003
y212	1	-0.49402	0.043703	-11.30	<.0001
		Model Dependent Variable		Y3T	
				y3	
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v31	1	0.194189	0.092866	2.09	0.0382
y312	1	-0.39395	0.048071	-8.20	<.0001
		Model Dependent Variable		Y4T	
				y4	
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v41	1	0.163023	0.049587	3.29	0.0013
y412	1	-0.35652	0.051350	-6.94	<.0001
		Model Dependent Variable		Y5T	
				y5	
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v51	1	0.240583	0.081615	2.95	0.0037
y512	1	-0.42257	0.047056	-8.98	<.0001

**Lampiran 11. Output GSTAR Bobot Normalisasi Inferensi Parsial Korelasi Silang**

The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
y112	1	-0.50013	0.050644	-9.88	<.0001
Model Dependent Variable Y2T y2					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
y212	1	-0.51111	0.043087	-11.86	<.0001
Model Dependent Variable Y3T y3					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
y31	1	-0.11165	0.043104	-2.59	0.0105
y312	1	-0.40927	0.048673	-8.41	<.0001
Model Dependent Variable Y4T y4					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
y412	1	-0.37093	0.051303	-7.23	<.0001
Model Dependent Variable Y5T y5					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
y512	1	-0.43085	0.046425	-9.28	<.0001

Lampiran 12. Output SAS Hasil Estimasi Parameter Model GSTARX-GLS  
Tahap 1

The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Model		Y1T			
	Dependent Variable	y1			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
x1	1	-0.00031	0.003193	-0.10	0.9216

Model		Y2T			
	Dependent Variable	y2			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
d1t	1	0.013919	0.011319	1.23	0.2206
x1	1	-0.00087	0.002094	-0.42	0.6770

Model		Y3T			
	Dependent Variable	y3			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
d1t_1	1	-0.00076	0.012859	-0.06	0.9531
d1t	1	0.023785	0.015357	1.55	0.1234
x1	1	-0.00035	0.002439	-0.14	0.8860

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
d1t_1	1	-0.00551	0.009602	-0.57	0.5668
d1t	1	-0.00094	0.011193	-0.08	0.9333
d2t	1	-0.01143	0.007739	-1.48	0.1415

Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
d4t_1	1	-0.02094	0.010369	-2.02	0.0450
d1t	1	0.010325	0.015190	0.68	0.4977
d3t	1	0.011123	0.011921	0.93	0.3522
x1	1	-0.00041	0.002528	-0.16	0.8708
x2	1	0.031318	0.020615	1.52	0.1307
x3	1	-0.01191	0.020615	-0.58	0.5642

Dengan X direstrict

The SYSLIN Procedure					
Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
Y1 d2t_1	1	-0.01475	0.012744	-1.16	0.2489
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
Y2 d4t	1	-0.01632	0.008308	-1.96	0.0512
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
Y3 d1t	1	0.019876	0.011606	1.71	0.0887
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
Y4 d2t_1	1	0.019058	0.007509	2.54	0.0121
d4t_1	1	-0.01423	0.007594	-1.87	0.0628
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
Y5 d3t_1	1	0.022535	0.011559	1.95	0.0529
d4t_1	1	-0.02384	0.010124	-2.36	0.0197

Lampiran 13. Output SAS Hasil Estimasi Parameter Model GSTARX-GLS  
Bobot Seragam

The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v11	1	0.276496	0.099666	2.77	0.0062
u112	1	-0.48352	0.050390	-9.60	<.0001
Model Dependent Variable U2T u2					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v21	1	0.176786	0.058236	3.04	0.0028
u212	1	-0.48408	0.044003	-11.00	<.0001
Model Dependent Variable U3T u3					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
u31	1	-0.18052	0.071692	-2.52	0.0128
v31	1	0.333467	0.108225	3.08	0.0024
u312	1	-0.38539	0.047506	-8.11	<.0001
Model Dependent Variable U4T u4					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v41	1	0.117085	0.052757	2.22	0.0279
u412	1	-0.34934	0.050840	-6.87	<.0001
Model Dependent Variable U5T u5					
The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v51	1	0.169591	0.085459	1.98	0.0490
u512	1	-0.40125	0.047617	-8.43	<.0001

**Lampiran 14. Output SAS Hasil Estimasi Parameter Model GSTARX-GLS  
Bobot Invers Jarak**

The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v11	1	0.315607	0.096718	3.26	0.0014
u112	1	-0.47593	0.050155	-9.49	<.0001
Model Dependent Variable		U2T u2			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v21	1	0.186023	0.052722	3.53	0.0006
u212	1	-0.48072	0.043921	-10.95	<.0001
Model Dependent Variable		U3T u3			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
u31	1	-0.15161	0.074737	-2.03	0.0443
v31	1	0.349605	0.112230	3.12	0.0022
u312	1	-0.38448	0.047605	-8.08	<.0001
Model Dependent Variable		U4T u4			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v41	1	0.137253	0.050791	2.70	0.0077
u412	1	-0.34504	0.050788	-6.79	<.0001
Model Dependent Variable		U5T u5			
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
v51	1	0.208362	0.085102	2.45	0.0155
u512	1	-0.39845	0.047439	-8.40	<.0001

Lampiran 15. Program SAS Model GSTARX SUR ( $[1, 12]_1$ ) dengan Bobot Normalisasi Inferensi Korelasi Parsial Silang Variabel yang Signifikan

```
data work.gstarNI;
infile "C:\data\data_NI.txt" dlm='09'x;

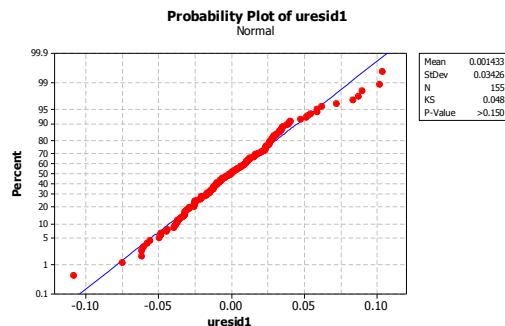
input u1 u2 u3 u4 u5 u11 u21 u31 u41 u51 v11 v21 v31 v41 v51 u112 u212 u312 u412 u512
v112 v212 v312 v412 v512;
/*----- GSTAR bobot NI dengan SysLin (sign) -----*/
proc syslin data=gstarNI sur out=a;
u1t: model u1= u112 / noint;
output p=uhat1 r=uresid1;
u2t: model u2= u212 / noint;
output p=uhat2 r=uresid2;
u3t: model u3= u312 / noint;
output p=uhat3 r=uresid3;
u4t: model u4= u412 / noint;
output p=uhat4 r=uresid4;
u5t: model u5= u512 / noint;
output p=uhat5 r=uresid5;
run;
proc print data=a;
run;
proc export data=work.a
outfile='c:\output\GSTARX\level2_restrict\NI.xls'
dbms=excel
replace;
sheet='NI';
run;
```

**Lampiran 16. Output SAS Hasil Estimasi Parameter Model GSTARX-GLS  
Bobot Normalisasi Inferensi Parsial Korelasi Silang**

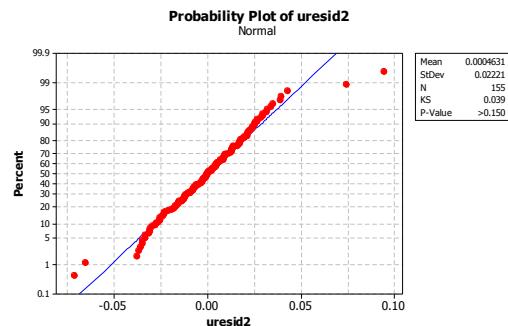
The SYSLIN Procedure Seemingly Unrelated Regression Estimation					
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
u112	1	-0.49782	0.050604	-9.84	<.0001
Model Dependent Variable					U2T u2
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
u212	1	-0.50711	0.043106	-11.76	<.0001
Model Dependent Variable					U3T u3
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
u312	1	-0.38662	0.047857	-8.08	<.0001
Model Dependent Variable					U4T u4
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
u412	1	-0.38284	0.050647	-7.56	<.0001
Model Dependent Variable					U5T u5
Parameter Estimates					
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr >  t
u512	1	-0.41847	0.046150	-9.07	<.0001

Lampiran 17. Uji Normalitas Residual GSTARX Bobot Normalisasi Inferensi Parsial Korelasi Silang

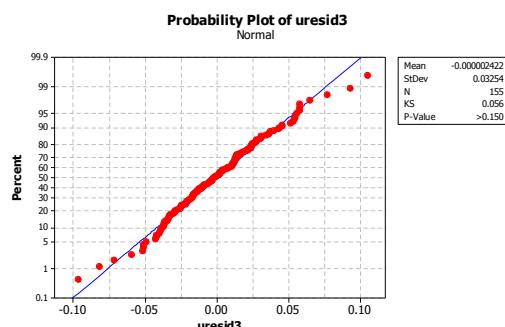
(a)



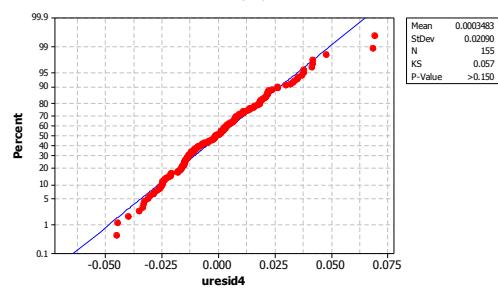
(b)



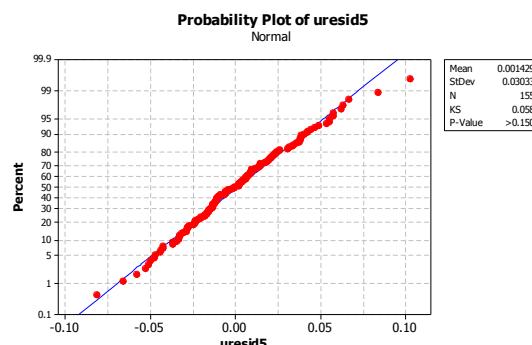
(c)



(d)



(e)



Lampiran 18. Penghitungan Matematis Varians pada Peramalan interval GSTAR

Secara matematis, peramalan pada model GSTAR dijelaskan pada persamaan berikut ini. Peramalan model GSTAR akan dijelaskan dengan menggunakan ilustrasi model GSTAR ( $1_1$ ) di tiga lokasi,

$$Y_{1,t} = \phi_{10}Y_{1,t-1} + \tilde{\phi}_{12}Y_{2,t-1} + \tilde{\phi}_{13}Y_{3,t-1} + a_{1,t},$$

$$Y_{2,t} = \tilde{\phi}_{21}Y_{1,t-1} + \phi_{20}Y_{2,t-1} + \tilde{\phi}_{23}Y_{3,t-1} + a_{2,t},$$

$$Y_{3,t} = \tilde{\phi}_{31}Y_{1,t-1} + \tilde{\phi}_{32}Y_{2,t-1} + \phi_{30}Y_{3,t-1} + a_{3,t},$$

dimana,

$$\tilde{\phi}_{12} = \phi_{11}W_{12} \quad \tilde{\phi}_{13} = \phi_{11}W_{13}$$

$$\tilde{\phi}_{21} = \phi_{21}W_{21} \quad \tilde{\phi}_{23} = \phi_{21}W_{23}$$

$$\tilde{\phi}_{31} = \phi_{31}W_{31} \quad \tilde{\phi}_{32} = \phi_{31}W_{32}$$

Ramalan titik untuk  $k$  ke depan dari periode ke- $n$  adalah :

**Untuk  $t = n + 1$ :**

$$[1] \quad Y_{1,n+1} = \phi_{10}Y_{1,n} + \tilde{\phi}_{12}Y_{2,n} + \tilde{\phi}_{13}Y_{3,n} + a_{1,n+1}$$

$$\begin{array}{r} \hat{Y}_{1,n}(1) = \phi_{10}Y_{1,n} + \tilde{\phi}_{12}Y_{2,n} + \tilde{\phi}_{13}Y_{3,n} + 0 \\ \hline \end{array} \quad -$$

$$\varepsilon_{1,n}(1) = a_{1,n+1}$$

$$\text{var}(\varepsilon_{1,n}(1)) = \sigma_{a_1}^2$$

$$[2] \quad Y_{2,n+1} = \tilde{\phi}_{21}Y_{1,n} + \phi_{20}Y_{2,n} + \tilde{\phi}_{23}Y_{3,n} + a_{2,n+1}$$

$$\begin{array}{r} \hat{Y}_{2,n}(1) = \tilde{\phi}_{21}Y_{1,n} + \phi_{20}Y_{2,n} + \tilde{\phi}_{23}Y_{3,n} + 0 \\ \hline \end{array} \quad -$$

$$\varepsilon_{2,n}(1) = a_{2,n+1}$$

$$\text{var}(\varepsilon_{2,n}(1)) = \sigma_{a_2}^2$$

$$[3] \quad Y_{3,n+1} = \tilde{\phi}_{31}Y_{1,n} + \tilde{\phi}_{32}Y_{2,n} + \phi_{30}Y_{3,n} + a_{3,n+1}$$

$$\begin{array}{r} \hat{Y}_{3,n}(1) = \tilde{\phi}_{31}Y_{1,n} + \tilde{\phi}_{32}Y_{2,n} + \phi_{30}Y_{3,n} + 0 \\ \hline \end{array} \quad -$$

$$\varepsilon_{3,n}(1) = a_{3,n+1}$$

$$\text{var}(\varepsilon_{3,n}(1)) = \sigma_{a_3}^2$$

Secara umum untuk  $t = n + 1, i = 1, 2, 3, \dots, I$

$$\text{var}(\varepsilon_{i,n}(1)) = \sigma_{a_i}^2$$

**Untuk  $t = n + 2$ :**

$$\begin{aligned}
 [1] \quad & Y_{1,n+2} = \phi_{10}Y_{1,n+1} + \tilde{\phi}_{12}Y_{2,n+1} + \tilde{\phi}_{13}Y_{3,n+1} + a_{1,n+2} \\
 & \hat{Y}_{1,n}(2) = \phi_{10}\hat{Y}_{1,n}(1) + \tilde{\phi}_{12}\hat{Y}_{2,n}(1) + \tilde{\phi}_{13}\hat{Y}_{3,n}(1) + 0 \\
 & \underline{\varepsilon_{1,n}(2)} = \phi_{10}\varepsilon_{1,n}(1) + \tilde{\phi}_{12}\varepsilon_{2,n}(1) + \tilde{\phi}_{13}\varepsilon_{3,n}(1) + a_{1,n+2} \\
 & \text{var}(\varepsilon_{1,n}(2)) = \text{var}(\phi_{10}\varepsilon_{1,n}(1) + \tilde{\phi}_{12}\varepsilon_{2,n}(1) + \tilde{\phi}_{13}\varepsilon_{3,n}(1) + a_{1,n+2}) \\
 \\
 [2] \quad & Y_{2,n+2} = \tilde{\phi}_{21}Y_{1,n+1} + \phi_{20}Y_{2,n+1} + \tilde{\phi}_{23}Y_{3,n+1} + a_{2,n+2} \\
 & \hat{Y}_{2,n}(2) = \tilde{\phi}_{21}\hat{Y}_{1,n}(1) + \phi_{20}\hat{Y}_{2,n}(1) + \tilde{\phi}_{23}\hat{Y}_{3,n}(1) + 0 \\
 & \underline{\varepsilon_{2,n}(2)} = \tilde{\phi}_{21}\varepsilon_{1,n}(1) + \phi_{20}\varepsilon_{2,n}(1) + \tilde{\phi}_{23}\varepsilon_{3,n}(1) + a_{2,n+2} \\
 & \text{var}(\varepsilon_{2,n}(2)) = \text{var}(\tilde{\phi}_{21}\varepsilon_{1,n}(1) + \phi_{20}\varepsilon_{2,n}(1) + \tilde{\phi}_{23}\varepsilon_{3,n}(1) + a_{2,n+2}) \\
 \\
 [3] \quad & Y_{3,n+2} = \tilde{\phi}_{31}Y_{1,n+1} + \tilde{\phi}_{32}Y_{2,n+1} + \phi_{30}Y_{3,n+1} + a_{3,n+2} \\
 & \hat{Y}_{3,n}(2) = \tilde{\phi}_{31}\hat{Y}_{1,n}(1) + \tilde{\phi}_{32}\hat{Y}_{2,n}(1) + \phi_{30}\hat{Y}_{3,n}(1) + 0 \\
 & \underline{\varepsilon_{3,n}(2)} = \tilde{\phi}_{31}\varepsilon_{1,n}(1) + \tilde{\phi}_{32}\varepsilon_{2,n}(1) + \phi_{30}\varepsilon_{3,n}(1) + a_{3,n+2} \\
 & \text{var}(\varepsilon_{3,n}(2)) = \text{var}(\tilde{\phi}_{31}\varepsilon_{1,n}(1) + \tilde{\phi}_{32}\varepsilon_{2,n}(1) + \phi_{30}\varepsilon_{3,n}(1) + a_{3,n+2})
 \end{aligned}$$

Secara umum untuk  $t = n + 2, i = 1, 2, 3, \dots, I$

Karena  $\varepsilon_{i,n}(k)$  saling independen atau asumsi *white noise* sudah terpenuhi maka  $\text{cov}(\varepsilon_{ij,n}(k)) = 0$ , dengan  $j \neq i$ . Maka persamaan umum untuk varians dari *error* adalah,

$$\text{var}(\varepsilon_{i,n}(2)) = \sigma_{a_i}^2 + \phi_{i0}^2 \text{var}(\varepsilon_{i,n}(1)) + \sum_{\substack{j=1 \\ (j \neq i)}}^I \tilde{\phi}_{ij}^2 \text{var}(\varepsilon_{j,n}(1))$$

**Untuk  $t = n + 3$ :**

$$\begin{aligned}
 [1] \quad & Y_{1,n+3} = \phi_{10}Y_{1,n+2} + \tilde{\phi}_{12}Y_{2,n+2} + \tilde{\phi}_{13}Y_{3,n+2} + a_{1,n+3} \\
 & \hat{Y}_{1,n}(3) = \phi_{10}\hat{Y}_{1,n}(2) + \tilde{\phi}_{12}\hat{Y}_{2,n}(2) + \tilde{\phi}_{13}\hat{Y}_{3,n}(2) + 0 \\
 & \underline{\varepsilon_{1,n}(3) = \phi_{10}\varepsilon_{1,n}(2) + \tilde{\phi}_{12}\varepsilon_{2,n}(2) + \tilde{\phi}_{13}\varepsilon_{3,n}(2) + a_{1,n+3}} \quad - \\
 & \text{var}(\varepsilon_{1,n}(3)) = \text{var}(\phi_{10}\varepsilon_{1,n}(2) + \tilde{\phi}_{12}\varepsilon_{2,n}(2) + \tilde{\phi}_{13}\varepsilon_{3,n}(2) + a_{1,n+3}) \\
 \\
 [2] \quad & Y_{2,n+3} = \tilde{\phi}_{21}Y_{1,n+2} + \phi_{20}Y_{2,n+2} + \tilde{\phi}_{23}Y_{3,n+2} + a_{2,n+3} \\
 & \hat{Y}_{2,n}(3) = \tilde{\phi}_{21}\hat{Y}_{1,n}(2) + \phi_{20}\hat{Y}_{2,n}(2) + \tilde{\phi}_{23}\hat{Y}_{3,n}(2) + 0 \\
 & \underline{\varepsilon_{2,n}(3) = \tilde{\phi}_{21}\varepsilon_{1,n}(2) + \phi_{20}\varepsilon_{2,n}(2) + \tilde{\phi}_{23}\varepsilon_{3,n}(2) + a_{2,n+3}} \quad - \\
 & \text{var}(\varepsilon_{2,n}(3)) = \text{var}(\tilde{\phi}_{21}\varepsilon_{1,n}(2) + \phi_{20}\varepsilon_{2,n}(2) + \tilde{\phi}_{23}\varepsilon_{3,n}(2) + a_{2,n+3}) \\
 \\
 [3] \quad & Y_{3,n+3} = \tilde{\phi}_{31}Y_{1,n+2} + \tilde{\phi}_{32}Y_{2,n+2} + \phi_{30}Y_{3,n+2} + a_{3,n+3} \\
 & \hat{Y}_{3,n}(3) = \tilde{\phi}_{31}\hat{Y}_{1,n}(2) + \tilde{\phi}_{32}\hat{Y}_{2,n}(2) + \phi_{30}\hat{Y}_{3,n}(2) + 0 \\
 & \underline{\varepsilon_{3,n}(3) = \tilde{\phi}_{31}\varepsilon_{1,n}(2) + \tilde{\phi}_{32}\varepsilon_{2,n}(2) + \phi_{30}\varepsilon_{3,n}(2) + a_{3,n+3}} \quad - \\
 & \text{var}(\varepsilon_{3,n}(3)) = \text{var}(\tilde{\phi}_{31}\varepsilon_{1,n}(2) + \tilde{\phi}_{32}\varepsilon_{2,n}(2) + \phi_{30}\varepsilon_{3,n}(2) + a_{3,n+3})
 \end{aligned}$$

Secara umum untuk  $t = n + 3$ ,  $i = 1, 2, 3, \dots, I$

$$\text{var}(\varepsilon_{i,n}(3)) = \sigma_{a_i}^2 + \phi_{i0}^2 \text{var}(\varepsilon_{i,n}(2)) + \sum_{\substack{j=1 \\ (j \neq i)}}^I \tilde{\phi}_{ij}^2 \text{var}(\varepsilon_{j,n}(2))$$

Lampiran 19. Penghitungan Matematis Varians pada Peramalan Interval GSTAR Musiman

Secara matematis, peramalan pada model GSTAR musiman dijelaskan pada persamaan berikut ini. Peramalan model GSTAR akan dijelaskan dengan menggunakan ilustrasi model GSTAR (12<sub>1</sub>) di tiga lokasi,

$$Y_{1,t} = \phi_{10}Y_{1,t-12} + \tilde{\phi}_{12}Y_{2,t-12} + \tilde{\phi}_{13}Y_{3,t-12} + a_{1,t},$$

$$Y_{2,t} = \tilde{\phi}_{21}Y_{1,t-12} + \phi_{20}Y_{2,t-12} + \tilde{\phi}_{23}Y_{3,t-12} + a_{2,t},$$

$$Y_{3,t} = \tilde{\phi}_{31}Y_{1,t-12} + \tilde{\phi}_{32}Y_{2,t-12} + \phi_{30}Y_{3,t-12} + a_{3,t},$$

dimana,

$$\tilde{\phi}_{12} = \phi_{11}W_{12}$$

$$\tilde{\phi}_{13} = \phi_{11}W_{13}$$

$$\tilde{\phi}_{21} = \phi_{21}W_{21}$$

$$\tilde{\phi}_{23} = \phi_{21}W_{23}$$

$$\tilde{\phi}_{31} = \phi_{31}W_{31}$$

$$\tilde{\phi}_{32} = \phi_{31}W_{32}$$

Ramalan titik untuk  $k$  ke depan dari periode ke- $n$  adalah :

**Untuk  $t = n + 1$ :**

Keterangan untuk  $Y_{t-12} = Y_{n+1-12} = Y_{n-11}$

$$[1] \quad Y_{1,n+1} = \phi_{10}Y_{1,n-11} + \tilde{\phi}_{12}Y_{2,n-11} + \tilde{\phi}_{13}Y_{3,n-11} + a_{1,n+1}$$

$$\underline{\hat{Y}_{1,n}(1) = \phi_{10}Y_{1,n-11} + \tilde{\phi}_{12}Y_{2,n-11} + \tilde{\phi}_{13}Y_{3,n-11} + 0} \quad -$$

$$\varepsilon_{1,n}(1) = a_{1,n+1}$$

$$\text{var}(\varepsilon_{1,n}(1)) = \sigma_{a_1}^2$$

$$[2] \quad Y_{2,n+1} = \tilde{\phi}_{21}Y_{1,n-11} + \phi_{20}Y_{2,n-11} + \tilde{\phi}_{23}Y_{3,n-11} + a_{2,n+1}$$

$$\underline{\hat{Y}_{2,n}(1) = \tilde{\phi}_{21}Y_{1,n-11} + \phi_{20}Y_{2,n-11} + \tilde{\phi}_{23}Y_{3,n-11} + 0} \quad -$$

$$\varepsilon_{2,n}(1) = a_{2,n+1}$$

$$\text{var}(\varepsilon_{2,n}(1)) = \sigma_{a_2}^2$$

$$[3] \quad Y_{3,n+1} = \tilde{\phi}_{31}Y_{1,n-11} + \tilde{\phi}_{32}Y_{2,n-11} + \phi_{30}Y_{3,n-11} + a_{3,n+1}$$

$$\underline{\hat{Y}_{3,n}(1) = \tilde{\phi}_{31}Y_{1,n-11} + \tilde{\phi}_{32}Y_{2,n-11} + \phi_{30}Y_{3,n-11} + 0} \quad -$$

$$\varepsilon_{3,n}(1) = a_{3,n+1}$$

$$\text{var}(\varepsilon_{3,n}(1)) = \sigma_{a_3}^2$$

Secara umum untuk  $t = n + 1, i = 1, 2, 3, \dots, I$

$$\text{var}(\varepsilon_{i,n}(1)) = \sigma_{a_i}^2$$

**Untuk  $t = n + 2$ :**

Keterangan untuk  $Y_{t-12} = Y_{n+2-12} = Y_{n-10}$

$$[1] Y_{1,n+2} = \phi_{10}Y_{1,n-10} + \tilde{\phi}_{12}Y_{2,n-10} + \tilde{\phi}_{13}Y_{3,n-10} + a_{1,n+2}$$

$$\begin{array}{r} \hat{Y}_{1,n}(2) = \phi_{10}Y_{1,n-10} + \tilde{\phi}_{12}Y_{2,n-10} + \tilde{\phi}_{13}Y_{3,n-10} + 0 \\ \hline \varepsilon_{1,n}(2) = a_{1,n+2} \end{array} -$$

$$\text{var}(\varepsilon_{1,n}(2)) = \sigma_{a_1}^2$$

$$[2] Y_{2,n+2} = \tilde{\phi}_{21}Y_{1,n-10} + \phi_{20}Y_{2,n-10} + \tilde{\phi}_{23}Y_{3,n-10} + a_{2,n+2}$$

$$\begin{array}{r} \hat{Y}_{2,n}(2) = \tilde{\phi}_{21}Y_{1,n-10} + \phi_{20}Y_{2,n-10} + \tilde{\phi}_{23}Y_{3,n-10} + 0 \\ \hline \varepsilon_{2,n}(2) = a_{2,n+2} \end{array} -$$

$$\text{var}(\varepsilon_{2,n}(2)) = \sigma_{a_2}^2$$

$$[3] Y_{3,n+2} = \tilde{\phi}_{31}Y_{1,n-10} + \tilde{\phi}_{32}Y_{2,n-10} + \phi_{30}Y_{3,n-10} + a_{3,n+2}$$

$$\begin{array}{r} \hat{Y}_{3,n}(2) = \tilde{\phi}_{31}Y_{1,n-10} + \tilde{\phi}_{32}Y_{2,n-10} + \phi_{30}Y_{3,n-10} + 0 \\ \hline \varepsilon_{3,n}(2) = a_{3,n+2} \end{array} -$$

$$\text{var}(\varepsilon_{3,n}(2)) = \sigma_{a_3}^2$$

Secara umum untuk  $t = n + 2, i = 1, 2, 3, \dots, I$

$$\text{var}(\varepsilon_{i,n}(2)) = \sigma_{a_i}^2$$

**Untuk  $t = n + 3$ :**

Keterangan untuk  $Y_{t-12} = Y_{n+3-12} = Y_{n-9}$

$$[1] Y_{1,n+3} = \phi_{10}Y_{1,n-9} + \tilde{\phi}_{12}Y_{2,n-9} + \tilde{\phi}_{13}Y_{3,n-9} + a_{1,n+3}$$

$$\begin{array}{r} \hat{Y}_{1,n}(3) = \phi_{10}Y_{1,n-9} + \tilde{\phi}_{12}Y_{2,n-9} + \tilde{\phi}_{13}Y_{3,n-9} + 0 \\ \hline \varepsilon_{1,n}(3) = a_{1,n+3} \end{array} -$$

$$\text{var}(\varepsilon_{1,n}(3)) = \sigma_{a_1}^2$$

$$[2] Y_{2,n+3} = \tilde{\phi}_{21}Y_{1,n-9} + \phi_{20}Y_{2,n-9} + \tilde{\phi}_{23}Y_{3,n-9} + a_{2,n+3}$$

$$\begin{array}{r} \hat{Y}_{2,n}(3) = \tilde{\phi}_{21}Y_{1,n-9} + \phi_{20}Y_{2,n-9} + \tilde{\phi}_{23}Y_{3,n-9} + 0 \\ \hline \varepsilon_{2,n}(3) = a_{2,n+3} \end{array} -$$

$$\text{var} (\varepsilon_{2,n}(3)) = \sigma_{a_2}^2$$

$$[3] \quad Y_{3,n+3} = \tilde{\phi}_{31}Y_{1,n-9} + \tilde{\phi}_{32}Y_{2,n-9} + \phi_{30}Y_{3,n-9} + a_{3,n+3}$$

$$\begin{array}{c} \hat{Y}_{3,n}(3) = \tilde{\phi}_{31}Y_{1,n-9} + \tilde{\phi}_{32}Y_{2,n-9} + \phi_{30}Y_{3,n-9} + 0 \\ \hline \varepsilon_{3n}(3) = a_{3,n+3} \end{array} -$$

$$\text{var} (\varepsilon_{2,n}(3)) = \sigma_{a_3}^2$$

Secara umum untuk  $t = n + 3, i = 1, 2, 3, \dots, I$

$$\text{var} (\varepsilon_{i,n}(3)) = \sigma_{a_i}^2$$

:

**Untuk  $t = n + 12$ :**

Keterangan untuk  $Y_{t-12} = Y_{n+12-12} = Y_n$

$$[1] \quad Y_{1,n+12} = \phi_{10}Y_{1,n} + \tilde{\phi}_{12}Y_{2,n} + \tilde{\phi}_{13}Y_{3,n} + a_{1,n+12}$$

$$\begin{array}{c} \hat{Y}_{1,n}(12) = \phi_{10}Y_{1,n} + \tilde{\phi}_{12}Y_{2,n} + \tilde{\phi}_{13}Y_{3,n} + 0 \\ \hline \varepsilon_{1,n}(12) = a_{1,n+12} \end{array} -$$

$$\text{var} (\varepsilon_{1,n}(12)) = \sigma_{a_1}^2$$

$$[2] \quad Y_{2,n+12} = \tilde{\phi}_{21}Y_{1,n} + \phi_{20}Y_{2,n} + \tilde{\phi}_{23}Y_{3,n} + a_{2,n+12}$$

$$\begin{array}{c} \hat{Y}_{2,n}(12) = \tilde{\phi}_{21}Y_{1,n} + \phi_{20}Y_{2,n} + \tilde{\phi}_{23}Y_{3,n} + 0 \\ \hline \varepsilon_{2,n}(12) = a_{2,n+12} \end{array} -$$

$$\text{var} (\varepsilon_{2,n}(2)) = \sigma_{a_2}^2$$

$$[3] \quad Y_{3,n+12} = \tilde{\phi}_{31}Y_{1,n} + \tilde{\phi}_{32}Y_{2,n} + \phi_{30}Y_{3,n} + a_{3,n+12}$$

$$\begin{array}{c} \hat{Y}_{3,n}(12) = \tilde{\phi}_{31}Y_{1,n} + \tilde{\phi}_{32}Y_{2,n} + \phi_{30}Y_{3,n} + 0 \\ \hline \varepsilon_{3,n}(12) = a_{3,n+12} \end{array} -$$

$$\text{var} (\varepsilon_{3,n}(12)) = \sigma_{a_3}^2$$

Secara umum untuk  $t = n + 12, i = 1, 2, 3, \dots, I$

$$\text{var} (\varepsilon_{i,n}(12)) = \sigma_{a_i}^2$$

**Untuk  $t = n + 13$ :**

Keterangan untuk  $Y_{t-12} = Y_{n+13-12} = Y_{n+1}$

$$\begin{aligned}[1] Y_{1,n+13} &= \phi_{10}Y_{1,n+1} + \tilde{\phi}_{12}Y_{2,n+1} + \tilde{\phi}_{13}Y_{3,n+1} + a_{1,n+13} \\ \hat{Y}_{1,n}(13) &= \phi_{10}\hat{Y}_{1,n}(1) + \tilde{\phi}_{12}\hat{Y}_{2,n}(1) + \tilde{\phi}_{13}\hat{Y}_{3,n}(1) + 0 \\ \varepsilon_{1,n}(13) &= \phi_{10}\varepsilon_{1,n}(1) + \tilde{\phi}_{12}\varepsilon_{2,n}(1) + \tilde{\phi}_{13}\varepsilon_{3,n}(1) + a_{1,n+13} \\ \text{var}(\varepsilon_{1,n}(13)) &= \text{var}(\phi_{10}\varepsilon_{1,n}(1) + \tilde{\phi}_{12}\varepsilon_{2,n}(1) + \tilde{\phi}_{13}\varepsilon_{3,n}(1) + a_{1,n+13}) \end{aligned}$$

$$\begin{aligned}[2] Y_{2,n+13} &= \tilde{\phi}_{21}Y_{1,n+1} + \phi_{20}Y_{2,n+1} + \tilde{\phi}_{23}Y_{3,n+1} + a_{2,n+13} \\ \hat{Y}_{2,n}(13) &= \tilde{\phi}_{21}\hat{Y}_{1,n}(1) + \phi_{20}\hat{Y}_{2,n}(1) + \tilde{\phi}_{23}\hat{Y}_{3,n}(1) + 0 \\ \varepsilon_{2,n}(13) &= \tilde{\phi}_{21}\varepsilon_{1,n}(1) + \phi_{20}\varepsilon_{2,n}(1) + \tilde{\phi}_{23}\varepsilon_{3,n}(1) + a_{2,n+13} \\ \text{var}(\varepsilon_{2,n}(13)) &= \text{var}(\tilde{\phi}_{21}\varepsilon_{1,n}(1) + \phi_{20}\varepsilon_{2,n}(1) + \tilde{\phi}_{23}\varepsilon_{3,n}(1) + a_{2,n+13}) \end{aligned}$$

$$\begin{aligned}[3] Y_{3,n+13} &= \tilde{\phi}_{31}Y_{1,n+1} + \tilde{\phi}_{32}Y_{2,n+1} + \phi_{30}Y_{3,n+1} + a_{3,n+13} \\ \hat{Y}_{3,n}(13) &= \tilde{\phi}_{31}\hat{Y}_{1,n}(1) + \tilde{\phi}_{32}\hat{Y}_{2,n}(1) + \phi_{30}\hat{Y}_{3,n}(1) + 0 \\ \varepsilon_{3,n}(13) &= \tilde{\phi}_{31}\varepsilon_{1,n}(1) + \tilde{\phi}_{32}\varepsilon_{2,n}(1) + \phi_{30}\varepsilon_{3,n}(1) + a_{3,n+13} \\ \text{var}(\varepsilon_{3,n}(13)) &= \text{var}(\tilde{\phi}_{31}\varepsilon_{1,n}(1) + \tilde{\phi}_{32}\varepsilon_{2,n}(1) + \phi_{30}\varepsilon_{3,n}(1) + a_{3,n+13}) \end{aligned}$$

Secara umum untuk  $t = n + s + 1$ ,  $i = 1, 2, 3, \dots, I$  dan  $s = \text{musiman}$

$$\text{var}(\varepsilon_{i,n}(13)) = \sigma_{a_i}^2 + \phi_{i0}^2 \text{var}(\varepsilon_{i,n}(1)) + \sum_{\substack{j=1 \\ (j \neq i)}}^I \tilde{\phi}_{ij}^2 \text{var}(\varepsilon_{j,n}(1))$$

Lampiran 20. Peramalan *Out-Sample* IHK Kelompok Bahan Makanan Model GSTARX Bobot Normalisasi Inferensi Parsial Korelasi Silang Lima Kota di Sumatera

Kota	Bulan	$\hat{Y}_{i,t}$	Batas Bawah	Batas Atas
Padang	1	152,0	144,5	159,5
	2	135,5	128,0	143,0
	3	125,6	118,1	133,0
	4	124,2	116,8	131,7
	5	126,0	118,5	133,5
	6	129,0	121,6	136,5
	7	134,1	126,7	141,6
	8	137,1	129,6	144,5
	9	137,6	130,1	145,0
	10	135,2	127,7	142,7
	11	136,6	129,1	144,0
	12	133,1	125,7	140,6
Pekanbaru	1	127,4	124,6	130,1
	2	122,8	120,1	125,6
	3	121,5	118,8	124,3
	4	120,2	117,4	122,9
	5	120,2	117,4	122,9
	6	123,9	121,2	126,6
	7	127,8	125,1	130,5
	8	128,6	125,9	131,3
	9	126,1	123,3	128,8
	10	125,6	122,9	128,4
	11	124,7	122,0	127,5
	12	124,7	122,0	127,4
Jambi	1	131,5	125,2	137,8
	2	119,9	113,6	126,2
	3	115,2	108,9	121,5
	4	112,7	106,4	119,0
	5	111,9	105,6	118,3
	6	117,4	111,1	123,7
	7	123,9	117,6	130,2
	8	122,9	116,6	129,3
	9	120,4	114,1	126,7
	10	117,8	111,5	124,2
	11	119,3	113,0	125,6
	12	120,6	114,3	126,9

Lanjutan Lampiran 19

Kota	Bulan	$\hat{Y}_{i,t}$	Batas Bawah	Batas Atas
Palembang	1	123,8	121,5	126,2
	2	117,5	115,2	119,8
	3	115,1	112,8	117,4
	4	112,6	110,3	114,9
	5	112,6	110,3	114,9
	6	117,7	115,4	120,0
	7	121,0	118,7	123,3
	8	121,7	119,4	124,1
	9	119,6	117,3	121,9
	10	119,9	117,6	122,2
	11	121,6	119,3	123,9
	12	123,0	120,7	125,3
Bengkulu	1	143,3	137,8	148,7
	2	135,5	130,0	141,0
	3	131,1	125,6	136,6
	4	129,0	123,5	134,5
	5	126,6	121,1	132,1
	6	133,0	127,6	138,5
	7	138,5	133,0	144,0
	8	138,8	133,3	144,3
	9	139,7	134,2	145,2
	10	140,0	134,5	145,5
	11	140,1	134,6	145,6
	12	138,5	133,1	144,0

## BIOGRAFI PENULIS



Penulis dilahirkan di Magelang, Jawa Tengah pada tanggal 6 Mei 1985. Putri pertama dari dua bersaudara buah cinta dari pasangan Bapak Urip Budi Rahardjo dan Ibu Sri Hastuti. Saat ini penulis sudah berkeluarga dengan suami bernama Budi Hartono serta dikaruniai dua orang anak bernama Sunshine Mumtazia Jasmine dan Arawinda Neil Isy Karima. Riwayat pendidikan penulis adalah SDN Kalinegoro III (1991-1997), SMP Negeri 1 Kota Magelang (1997-2000), SMU Negeri 1 Kota Magelang (2000-2003), Sekolah Tinggi Ilmu Statistik (STIS) Jakarta (2003-2007). Setelah menamatkan pendidikan D-IV di STIS, penulis ditugaskan bekerja di BPS Provinsi Jambi (2008-Sekarang) sebagai staf di Bidang Neraca Wilayah dan Analisis Stastistik. Pada tahun 2015 penulis memperoleh kesempatan untuk melanjutkan studi S2 di Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Institut Teknologi Sepuluh Nopember (ITS) Surabaya dengan beasiswa dari BPS. Alamat email yang bisa dihubungi [hapsari@bps.go.id](mailto:hapsari@bps.go.id).

Surabaya, Januari 2017

Risma Hapsari