TESIS - SS14 2501

MODEL GSTAR DENGAN VARIABEL EKSOGEN METRIK DAN NON METRIK UNTUK PERAMALAN INFLASI DI KALIMANTAN

AGUNG SETIAWAN PRASETYA
NRP : 131 520 1708

DOSEN PEMBIMBING :
Dr. Suhartono, M.Sc.
Dr. Drs. Agus Suharsono, M.S.

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

THESIS - SS14 2501

GSTAR MODEL WITH METRIC AND NON METRIC EXOGENEOUS VARIABLES FOR FORECASTING INFLATION IN KALIMANTAN

AGUNG SETIAWAN PRASETYA
NRP : 131 520 1708

SUPERVISOR
Dr. Suhartono, M.Sc.
Dr. Drs. Agus Suharsono, M.S.

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

MODEL GSTAR DENGAN VARIABEL EKSOGEN METRIK DAN NON METRIK UNTUK PERAMALAN INFLASI DI KALIMANTAN

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar Magister Sains (M.Si)
di
Institut Teknologi Sepuluh Nopember
Oleh :

AGUNG SETIAWAN PRASETYA
NRP. 1315 201 708

Tanggal Ujian : 10 Januari 2017
Periode Wisuda : Maret 2017

Disetujui Oleh :

1. Dr. Suhartono, M.Sc. (Pembimbing I)
   NIP. 19710929 199512 1 001

2. Dr. Drs. Agus Suharsono, M.S. (Pembimbing II)
   NIP. 19580823 198403 1 003

3. Dr. Ir. Setiawan, M.S. (Penguji)
   NIP. 19601030 198701 1 001

4. Dr. Wahyu Wibowo, M.Si. (Penguji)
   NIP. 19740328 199802 1 001

5. Dr. Vera Lisna, S.Si., M.Phil. (Penguji)
   NIP. 19681107 199403 2 002

an. Direktur Program Pascasarjana
Asisten Direktur

Prof. Dr. Ir. Tri Widjaja, M.Eng.
NIP. 19611021 198603 1 001

Direktur Program Pascasarjana,

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

MODEL GSTAR DENGAN VARIABEL EKSOGEN METRIK DAN NON METRIK UNTUK PERAMALAN INFLASI DI KALIMANTAN

Nama	: Agung Setiawan Prasetya
NRP	: 1315201708
Pembimbing	: Dr. Suhartono, M.Sc.
Co Pembimbing	: Dr. Drs. Agus Suharsono, M.S.

ABSTRAK

Salah satu indikator ekonomi makro yang digunakan dalam penyusunan kebijakan pemerintah di bidang ekonomi adalah *inflasi*. Inflasi merupakan data *time series* bulanan yang diduga dipengaruhi oleh aspek antar lokasi. Salah satu metode *time series* multivariat yang menggabungkan unsur dependensi waktu dan lokasi (*space time*) adalah model *Generalized* S*pace Time Autoregressive* (GSTAR). Dalam perkembangan model *space time*, tidak hanya dipengaruhi oleh dependensi waktu dan lokasi, tetapi juga terdapat faktor lain yang bisa digunakan untuk menambah akurasi dalam peramalan yaitu berupa variabel eksogen. Model GSTAR dengan melibatkan variabel eksogen dikenal dengan model GSTARX. Variabel eksogen yang digunakan adalah skala *metrik* (curah hujan) dan skala *non metrik* yaitu variasi kalender dan intevensi berupa kenaikan harga bahan bakar minyak (BBM). Studi kasus dalam penelitian ini diterapkan untuk peramalan inflasi enam kota di Kalimantan yaitu Pontianak, Sampit, Palangkaraya, Banjarmasin, Balikpapan dan Samarinda. Tujuan penelitian ini adalah ingin mendapatkan model GSTARX yang sesuai untuk peramalan inflasi enam kota di Kalimantan, sehingga hasil ramalannya bisa dijadikan informasi awal bagi pemerintah dalam menentukan kebijakan. Hasil pemodelan GSTARX untuk inflasi enam kota di Kalimantan adalah GSTARX-GLS ($[1,12]_1$). Pemodelan univariat dengan menambahkan variabel eksogen memberikan nilai RMSE yang lebih kecil dibandingkan tanpa melibatkan variabel eksogen. Demikian juga tingkat akurasi peramalan menunjukkan bahwa model univariat lebih baik dibandingkan dengan GSTARX-GLS. Hal ini berdasarkan dari nilai RMSE *out-sample* yang minimum.

Kata kunci : GSTARX, Inflasi, Kalimantan, s*pace-time*, *time series*

(Halaman ini sengaja dikosongkan)

GSTAR MODEL WITH METRIC AND NON METRIC EXOGENOUS VARIABLES FOR FORECASTING INFLATION IN KALIMANTAN

Name	: Agung Setiawan Prasetya
NRP	: 1315201708
Supervisor	: Dr. Suhartono, M.Sc.
Co Supervisor	: Dr. Drs. Agus Suharsono, M.S.

ABSTRACT

One of the macroeconomic indicators that used in the formulation of government's economic policy is inflation. Inflation is a monthly time series that also is influenced by location effects. Generalized Space-Time Autoregressive (GSTAR) is a multivariate time series model that combines time and location effects. The space-time data is not only influenced by time and inter-dependencies of location, but also there are other factors to increase the accuracy of forecasting time series, that can be expressed in exogenous variables. GSTAR model involving exogenous variable is known GSTARX model. The exogenous variable consists of the metric and non-metric scales. In this research, exogenous variables were taken into consideration as metric scale i.e. rainfall and non-metric scales that are the calendar variation and intervention in the form of the increase of fuel price. The case study is applied of GSTARX for forecasting inflation in six cities in Kalimantan i.e. Pontianak, Sampit, Palangkaraya, Banjarmasin, Balikpapan and Samarinda. The objection of this research is to obtain appropriate GSTARX model for inflation prediction so that the results of prediction can be used early information for government decision of policy. GSTAR modeling results for the inflation in six cities in Kalimantan is GSTAR($[1,12]_1$). By using the inverse distance weighting, showed that inflation in a region influenced by other regions in the previous twelve month period. The empirical result of GSTARX model for the inflation in six cities in Kalimantan is GSTARX-GLS ($[1,12]_1$). Modelling by univariate gives better results than model GSTARX-GLS. It is shown by the smallest of RMSE at in-sample dataset. Similarly, the accuracy of forecasting using out-sample RMSE shows that the univariate model is better than GSTARX-GLS.

Keywords : *GSTARX, Inflation, Kalimantan, space-time, time series*

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji dan syukur penulis panjatkan kehadirat Allah SWT atas segala rahmat dan hidayah-Nya, sehingga penulis bisa menyelesaikan tesis yang berjudul "Model GSTAR dengan Variabel Eksogen Metrik dan Non Metrik Untuk Peramalan Inflasi di Kalimantan" dengan baik dan tepat waktu.

Keberhasilan penyusunan tesis ini tidak terlepas dari bantuan, bimbingan, dan dukungan dari berbagai pihak. Untuk itu, pada kesempatan ini teriring rasa syukur dan doa, penulis menyampaikan ucapan terima kasih kepada :

1. Badan Pusat Statistik (BPS) yang telah memberi kesempatan serta beasiswa kepada penulis untuk melanjutkan studi program S2 di ITS.
2. Bapak Dr. Suhartono, M.Sc, dan Bapak Dr. Drs. Agus Suharsono, M.S. selaku dosen pembimbing yang telah meluangkan waktu untuk memberikan bimbingan, saran, masukan, serta motivasi selama penyusunan tesis ini.
3. Bapak Dr. Ir. Setiawan, M.S., Bapak Dr. Wahyu Wibowo dan Ibu Dr. Vera Lisna, S.Si., M.Phil. selaku penguji yang telah banyak memberikan saran dan masukan untuk menjadikan tesis ini menjadi lebih baik.
4. Bapak Dr. Suhartono, M.Sc., selaku Ketua Jurusan Statistika dan Bapak Dr. rer.pol. Heri Kuswanto, M.Si., selaku Ketua Program Studi Pascasarjana Jurusan Statistika FMIPA ITS atas arahan dan bantuannya selama penulis menempuh pendidikan di Program Magister Jurusan Statistika ITS.
5. Ibu Santi Puteri Rahayu, M.Si, Ph.D., selaku dosen wali, seluruh Bapak/Ibu dosen pengajar yang telah memberikan ilmu dan pengalaman yang bermanfaat kepada penulis, serta segenap karyawan dan keluarga besar Jurusan Statistika FMIPA ITS atas segala dukungan dan bantuannya.
6. Teristimewa untuk Istriku tercinta, Thina Anggraini yang selalu sabar dalam mendidik anak-anak, senantiasa mendoakan, mendukung serta memberi semangat pada penulis. Untuk Anak-anakku tersayang Aisyah Agna 'Aqila Nareswari dan Nafisha Almahyra Azkadina yang telah memberikan warna kehidupan, penyejuk hati dan penyemangat jiwa bagi penulis.
7. Abah Saefudin dan Ibu Cholilah Istiaty (orang tuaku tercinta) yang telah membesarkan, mendidik dan senantiasa mendoakan untuk kebaikan anak-

anaknya. Mama Hj. Siti Fahziah (mertua penulis) yang turut mendukung dan mendoakan untuk kebaikan penulis.

8. Mas Yudi (kakak), serta adik-adikku (Iin, Ardi, Bowo, Adi, Ayu dan Yanti) yang juga turut memberikan doanya bagi penulis.
9. Teman-teman BPS Batch-9 : Mas Dinu, Mas Suko, Kang Leman, Mas Benk, Mas Bayu, Bang Node, Mas Arif (fotographer dan pengarah gaya), Mba Ervin (selaku bendahara), Mba Risma dan Mba Aty (temen seperjuangan tesis), Mba Ika, Mba Ayu, Mba Kiki, Mba Tiara (thanks for catatannya), Mba Mety (yang sering tersentak dan terhenyak), Mba Irva, Mba Nunik, Mba Lila, dan Mba Dewi. Terima kasih atas segala bantuan, kebersamaan dan kekompakannya selama menjalani pendidikan di ITS.
10. Teman-teman reguler angkatan 2015, Pak Irul dan Mba Mia (admin pasca), Mba Linda (perpustakaan/RBS) serta semua pihak yang tidak bisa disebutkan satu per satu, Penulis menyampaikan rasa terima kasih atas bantuan dan dukungannya selama menjalani pendidikan di ITS.

Penulis menyadari bahwa tesis ini masih jauh dari sempurna, oleh karena itu, kritik maupun saran yang bersifat membangun sangat penulis harapkan demi perbaikan dalam penulisan di masa yang akan datang. Akhirnya, penulis berharap mudah-mudahan tesis ini bermanfaat untuk semua pihak yang memerlukan.

Surabaya, Januari 2017

Penulis

DAFTAR ISI

Halaman

DAFTAR TABEL

DAFTAR GAMBAR

DAFTAR LAMPIRAN

(Halaman ini sengaja dikosongkan)

BAB 1
PENDAHULUAN

1.1. Latar Belakang

Inflasi merupakan salah satu indikator ekonomi makro yang penting dan dapat memberikan gambaran stabilitas perekonomian suatu negara. Inflasi didefinisikan sebagai kenaikan harga barang dan jasa yang berlangsung secara terus-menerus (BPS, 2016). Makna inflasi adalah persentase tingkat kenaikan harga sejumlah barang dan jasa yang secara umum dikonsumsi rumah tangga. Inflasi disusun untuk mendapatkan indikator yang menggambarkan kecenderungan umum tentang perkembangan harga. Secara spesifik angka inflasi digunakan sebagai penentuan indeksasi upah dan gaji, penentuan target inflasi, dan indeksasi Anggaran Pendapatan dan Belanja Negara (BPS, 2013). Angka inflasi juga digunakan pemerintah sebagai salah satu asumsi dasar ekonomi makro dalam penyusunan nota keuangan yang menjadi acuan pada pembahasan rancangan APBN (Kemenkeu, 2016).

Menurut Kahalwaty (2000:5) dalam Dwijayanthy (2009) definisi lain inflasi merupakan keadaan dimana terjadi kenaikan harga-harga secara tajam (*absolute*), berlangsung secara terus-menerus dalam jangka waktu yang cukup lama, diikuti menurunnya nilai mata uang suatu negara. Menurut teori Keynes, inflasi terjadi karena pola konsumsi masyakarat yang berlebihan sehingga permintaan masyarakat terhadap barang dan jasa melebihi jumlah barang dan jasa yang tersedia, akibatnya akan terjadi *inflationary gap* (Atmadja, 1999).

Inflasi pada dasarnya merupakan potret keadaan harga barang dan jasa di pasar. Inflasi menjadi indikator yang penting karena berkaitan erat dan berhubungan langsung dengan masyarakat dan dunia usaha. Inflasi yang tingi akan berdampak pada tingkat daya beli masyarakat yang menurun. Dalam dunia usaha, inflasi yang tinggi akan berpengaruh pada produktivitas usaha karena sebagian harga bahan baku tentunya akan semakin melonjak tinggi.

Inflasi dihitung berdasarkan pada perubahan Indeks Harga Konsumen yang dikelompokkan dalam tujuh kelompok pengeluaran (BPS, 2013) yaitu: (1) Bahan makanan, (2) Makanan jadi, minuman, rokok dan tembakau, (3) Perumahan, air, listrik, gas dan bahan bakar, (4) Sandang, (5) Kesehatan, (6) Pendidikan, rekreasi dan olahraga dan (7) Transportasi, komunikasi dan jasa keuangan. Dalam penyajiannya, selain inflasi umum juga terdapat inflasi menurut kelompok pengeluaran. Besaran perubahan harga yang didasarkan pada mekanisme harga pasar untuk kelompok pengeluaran dipengaruhi oleh beberapa faktor diantaranya tingginya harga bahan baku, ketidakseimbangan antara permintaan dan ketersediaan barang dan jasa serta tingkat kesulitan dalam arus distribusi barang sehingga berakibat meningkatnya biaya/ongkos transportasi.

Berdasarkan penyebabnya, inflasi terjadi karena adanya *demand pull inflation* dan *cost push inflation*. *Demand pull inflation* terjadi karena adanya peningkatan permintaan masyarakat terhadap komoditi-komoditi hasil produksi di pasar barang dan jasa, sedangkan *cost push inflation* terjadi karena meningkatnya harga faktor-faktor produksi (baik yang berasal dari dalam negeri maupun luar negeri) di pasar faktor produksi. Tingkat inflasi dari waktu ke waktu terkadang tidak menentu, bahkan meningkatnya laju inflasi acapkali karena faktor kejadian diluar dugaan atau bersifat kejutan (*shock*) seperti terjadinya bencana alam (banjir, kekeringan, kebakaran hutan, gempa bumi) serta adanya faktor kebijakan pemerintah seperti kenaikan bahan bakar minyak (BBM) atau kenaikan tarif dasar listrik (TDL). Di Indonesia angka inflasi juga mengikuti pola atau siklus musiman, salah satunya ketika memasuki bulan puasa dan menjelang perayaan lebaran Idul Fitri. Kenaikan inflasi terjadi karena adanya kenaikan permintaan masyarakat terhadap barang dan jasa khususnya pada saat memasuki Ramadhan dan menjelang Hari Raya Idul Fitri (Bank Indonesia, 2015).

Perkembangan laju inflasi merupakan indikator penting untuk melihat pertumbuhan ekonomi yang berkelanjutan. Mengacu pada pertumbuhan ekonomi, secara garis besar selama tahun 2015 perekonomian nasional mengalami perlambatan dan hanya mampu tumbuh sebesar 4,79 persen. Angka ini lebih rendah dibandingkan dengan target yang ditetapkan oleh pemerintah dalam Anggaran Pendapatan daan Belanja Negara Perubahan (APBN-P) 2015 sebesar 5,7 persen. Menurut BPS (2016), pertumbuhan ekonomi Indonesia pada 2015 merupakan pertumbuhan terendah selama 6 tahun terakhir dan merupakan kali pertama ekonomi Indonesia berada di bawah 5 persen sejak tahun 2009 ketika terjadi krisis keuangan global. Perlambatan pertumbuhan ekonomi Indonesia juga berdampak di sebagian wilayah Indonesia, seperti pulau Sumatera, Jawa, dan Kalimantan. Perlambatan yang paling signifikan terjadi di Pulau Kalimantan yaitu dari 3,29 persen pada tahun 2014 menjadi 1,31 persen pada tahun 2015.

Pulau Kalimantan sebagai salah satu pulau terbesar di Indonesia, memiliki 9 kota penghitung inflasi yang bisa memberikan gambaran adanya dinamika perubahan harga di pulau Kalimantan. Pada tahun 2015 dari 9 kota inflasi di Kalimantan, kota Tarakan di provinsi Kalimantan Timur merupakan kota dengan inflasi terendah yaitu sebesar 3,42 persen. Adapun kota Tanjung di provinsi Kalimantan Selatan pada tahun 2015 merupakan kota dengan tingkat inflasi tertinggi yang mencapai 6,69 persen. Dilihat menurut provinsi di regional Kalimantan, inflasi Kalimantan Timur (4,89 persen) menempati posisi terendah kedua setelah Kalimantan Tengah (4,74 persen). Sementara inflasi di Kalimantan Selatan dan Kalimantan Barat berada di atas inflasi Kalimantan Timur masing-masing 5,14 persen dan 5,79 persen. Dengan demikian, bisa disimpulkan bahwa selama tahun 2015 Inflasi seluruh provinsi di Kalimantan, masih berada di atas realisasi inflasi nasional yang sebesar 3,35 persen.

Salah satu faktor yang mempengaruhi inflasi di Kalimantan adalah adanya cuaca yang kurang kondusif yaitu curah hujan tinggi (Bank Indonesia dalam *Kajian Ekonomi dan Keuangan Daerah di wilayah Kalimantan Selatan* pada triwulan I-2015). Curah hujan yang tinggi tentunya akan bisa merubah waktu atau masa tanam untuk beberapa komoditas di sektor pertanian yang berimplikasi akan berubah pula waktu panen, akibatnya ketersediaan barang di pasar akan terganggu pada waktu tertentu. Intensitas hujan yang tinggi bisa mengakibatkan terjadinya banjir sehingga kerapkali menjadi pemicu gagal panen suaut komoditas tertentu dan berimplikasi pada kurangnya ketersediaan barang. Dengan kata lain curah hujan bisa mempengaruhi dari sisi produksi barang. Inflasi di Kalimantan juga tidak lepas dari faktor musiman salah satunya pada saat memasuki bulan puasa dan menjelang perayaan hari raya Idul Fitri. Hal ini didukung berdasarkan laporan kajian dari Bappenas (2010) yang menyatakan bahwa terjadi peningkatan konsumsi barang dan jasa pada bulan Ramadhan dan perayaan hari raya Idul Fitri.

Menurut Hasbullah (2012) inflasi juga bisa terjadi karena adanya *output gap* yang berupa ketidakseimbangan antara permintaan dan pasokan. Di daerah (tidak terkecuali Kalimantan), faktor ketidakseimbangan antara permintaan dan pasokan merupakan komponen yang paling berpengaruh pada inflasi. Hal tersebut berkaitan dengan karakteristik sosial dan geografis setiap wilayah di indonesia yang berbeda-beda dan sangat kompleks. Ditinjau dari *supply* barang dan jasa, tidak semua barang dan jasa bisa diproduksi di regional Kalimantan. selain produksi lokal, sebagian kebutuhan barang dan jasa masyarakat di Kalimantan di datangkan dari luar Kalimantan.

Arus distribusi barang dari luar Kalimantan lebih banyak melalui jalur perairan, sehingga adanya cuaca yang buruk bisa berpengaruh pada ketersediaan barang akibat arus distribusi yang tidak lancar. Arus distribusi barang dan jasa juga terjadi antar provinsi di Kalimantan. Bappenas (2010) menjelaskan adanya pola pergerakan barang pada wilayah antar provinsi di Kalimantan. Kajian tersebut lebih rinci menyebutkan bahwa pergerakan barang dari provinsi Kalimantan Barat sebagian besar bertujuan ke provinsi Sumatera Selatan, Lampung, dan Kalimantan Selatan. Pergerakan barang dari daerah asal provinsi Kalimantan Selatan sebagian besar bertujuan ke provinsi Jawa Timur, Jawa Barat, Kalimantan Timur dan Sulawesi Selatan. Pergerakan barang dari provinsi Kalimantan Tengah bertujuan menuju provinsi Jawa Timur, Jawa tengah, Jawa Barat, dan Bali. Sementara pergerakan barang dari provinsi Kalimantan Timur sebagian besar bertujuan ke provinsi Kalimantan Selatan, Kalimantan Barat, Bali dan Jawa Timur. Kelancaran arus atau pergerakan distribusi barang baik melalui jalur perairan maupun darat tidak lepas dari faktor cuaca yang pada implikasinya bisa berdampak pada kurangnya *supply* barang di pasar sehingga bisa memicu adanya inflasi.

Permasalahan inflasi di Indonesia cukup dilematis, di satu sisi inflasi yang tinggi bisa berdampak buruk bagi pertumbuhan ekonomi dan menurunnya kemampuan daya beli masyarakat terutama untuk kalangan menengah ke bawah. Namun di sisi lain inflasi yang rendah justru berdampak pada terganggunya iklim investasi (Widaryoko, 2013). Sehingga dalam menghadapi inflasi perlu adanya program pemerintah guna menjaga kestabilan inflasi yang bertujuan untuk menjaga daya beli masyarakat. Pemerintah melalui Bank Indonesia menggunakan kebijakan moneter yaitu mengatur keseimbangan persediaan uang dengan persediaan barang untuk menjaga kestabilan inflasi. Namun demikian, selain faktor kebijakan tersebut juga terdapat faktor-faktor lain yang berpengaruh terhadap tinggi rendahnya laju inflasi. Untuk itu perlu adanya suatu pemodelan yang bisa meramalkan inflasi yang akan datang dengan melibatkan faktor-faktor yang berpengaruh terhadap inflasi. Dengan demikian kebijakan pemerintah dalam bidang moneter yang bertujuan untuk menjaga tingkat inflasi akan terarah.

Penelitian mengenai pemodelan dan peramalan inflasi telah banyak dilakukan dengan berbagai metode yang berbeda. Tercatat dalam situs pencarian *sciencedirect* pada tanggal 8 September 2016 terdapat sekitar 23.111 jurnal/artikel yang mengkaji masalah peramalan inflasi. Di beberapa negara, pemodelan dan peramalan inflasi antara lain dilakukan oleh Chan dan Pham (1990) yang melakukan perbandingan kekuatan peramalan dari tiga model inflasi (*interest rate*, *time series* dan *survey forecasts*) di Australia dengan suatu kesimpulan bahwa model inflasi dengan *survey forecasts* memiliki tingkat kekuatan peramalan yang paling tinggi dibandingkan kedua model inflasi lainnya. Stock dan Watson (1999) di Amerika Serikat serta Kapur (2013) di India meramalkan inflasi dengan menggunakan model *Phillips Curve*. Kajian dan peramalan inflasi periode 1974-1996 di Kenya dilakukan oleh Durevall dan Ndung'u (2001) dengan menggunakan model dinamis (*A Dynamic Model*). Kichian dan Rumler (2014) dengan pendekatan *Semi-Structural New Keynessian Phillips Curve* melakukan peramalan inflasi di Kanada. Sementara Kapetanios *et al.* (2015) melakukan peramalan inflasi dan pertumbuhan PDB di wilayah Uni Eropa (EA) dengan menggunakan metode *Heuristic Optimisation of Information Criteria and Variable Reduction*. Adapun Pierdzioch *et al.* (2016) melakukan penelitian dengan menggunakan pendekatan *Asymmetric Loss Function and Forecast Rationality* untuk meramalkan tingkat inflasi di Afrika Selatan.

Inflasi merupakan data yang bersifat *time series,* sehingga banyak kajian dan penelitian tentang inflasi menggunakan pendekatan atau analisis *time series.* Metode *time series* yang cukup populer digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA). ARIMA digunakan pada data runtun waktu yang univariat. Beberapa penelitian mengenai inflasi berbagai negara dengan pendekatan ARIMA antara lain di Indonesia (Tripena, 2011), Bangladesh (Faisal, 2012) dan Rumania (Baciu, 2015).

Model ARIMA hanya memperhitungkan kejadian pada waktu sebelumnya terhadap data yang diobservasi, pada kenyataannya kejadian data *time series* juga dipengaruhi oleh faktor lain atau variabel prediktor. Hal ini mendorong para peneliti dalam membangun suatu pemodelan dan peramalan (*forecasting*) memasukkan faktor lain atau variabel prediktor (variabel eksogen) untuk meningkatkan akurasi model dan peramalannya. Pemodelan ARIMA dengan menambahkan variabel prediktor atau variabel eksogen dikenal sebagai model ARIMAX. Variabel eksogen dalam analisis *time series* bisa berupa data berskala metrik (interval atau rasio) atau non-metrik (nominal atau ordinal).

Pada model *time series* khususnya model ARIMA, penambahan variabel eksogen yang digunakan berupa skala metrik dikenal sebagai Fungsi Transfer (Box, Jenkins, dan Reinsel, 2008). Adapun model *time series* dengan jenis variabel eksogen berupa skala non-metrik dikenal sebagai Intervensi (Bowerman dan O’Connell, 1993) atau Variasi Kalender (Liu, 1980). Wu dan Tsay (2003) pernah melakukan penelitian melalui simulasi dan menunjukkan bahwa koefisien model mengalami peningkatan akurasi peramalan dengan cara menambahkan data metrik sebagai variabel eksogen. Beberapa penelitian telah dilakukan terhadap data *time series* dengan melibatkan variabel eksogen pada berbagai kasus antara lain model fungsi transfer (Listyowati dan Ulama, 2013; Reganata dan Suhartono, 2015), model intervensi (Suhartono, 2007; Nuvitasari, 2009; Lee *et al*., 2010; Budiarti *et al.*, 2013; Eksiandayani, 2016) dan model variasi kalender (Lee *et al.*, 2010; Arini dan Bendesa, 2012; Suhartono *et al.*, 2015; Setiawan *et al.*, 2015; Ahmad *et al.*, 2015; Wulandari, *et al.*, 2016).

Adakalanya data runtun waktu mempunyai hubungan yang saling mempengaruhi antar variabel. Hal ini yang mendorong beberapa peneliti melakukan kajian dan analisis *time series* multivariat dengan melibatkan beberapa variabel yang berhubungan (Wei, 2006). Analisis time series multivariat yang biasa digunakan adalah *Vector Autoregressive* (VAR), *Vector Autoregressive Moving Average* (VARMA) atau *Vector Autoregressive Integrated Moving Average* (VARIMA). Beberapa penelitian inflasi dengan pendekatan multivariat pernah dilakukan oleh peneliti diantaranya Lack (2006), Clements dan Galvao (2013) menggunakan model *Vector Autoregressive* (VAR) untuk meramalkan tingkat inflasi. Moser *et al.* (2007) yang melakukan perbandingan terhadap models VAR dan ARIMA dalam meramalkan inflasi di Austria. Higgins *et al.* (2016) menerapkan model *Bayesian* VAR dalam melakukan peramalan pertumbuhan ekonomi dan inflasi di Cina.

Ditinjau dari model persamaan dalam metode statistik terdapat dua jenis yaitu *linear* dan *non-linear*. Model *time series* nonlinier berarti hubungan antara kejadian masa lalu dengan sekarang bersifat nonlinier. Metode runtun bersifat nonlinier adalah diantaranya *Artificial Neural Network* (ANN) atau biasa dikenal dengan *Neural Network* (NN), *Adaptive Network-based Fuzzy Inference System* (ANFIS) dan *Self-Exciting Threshold Autoregressive* (SETAR). Penggunaan metode nonlinier juga pernah diaplikasikan dalam penelitian tentang inflasi diantaranya Nakamura (2005) yang mengaplikasikan metode NN dalam peramalan inflasi di Amerika Serikat. Moshiri dan Cameron (2000) dalam penelitiannya menggunakan model *Hybrid BPN* (*Back-Propagation Artificial Neural Network*) dan membandingkan-nya dengan model *ekonometrik* untuk melakukan peramalan inflasi di Kanada. Silfiani dan Suhartono (2012) menggunakan metode *Ensembel* (gabungan) ARIMA dan ANN untuk meramalkan inflasi di Indonesia. Adapun Nuhad (2013) menerapkan model SETAR untuk meramalkan inflasi di Indonesia. Enke dan Mehdiyev (2014) melakukan peramalan inflasi di Amerika dengan menggunakan model *Hybrid Neuro-Fuzzy*. Stephani, Suharsono dan Suhartono (2015) membuat pemodelan dan peramalan inflasi berdasarkan faktor ekonomi makro dengan menggunakan pendekatan *time series* klasik dan ANFIS.

Perkembangan metode statistik khususnya pada data *time series* tidak hanya didasarkan pada keterkaitan waktu namun saat ini sudah melibatkan faktor keterkaitan antar lokasi. Dalam hukum pertama tentang geografi yang dikemukakan oleh Tobler (1979) dalam Anselin (1988:8) menyatakan bahwa:*"Everything is related to everything else, but near thing are more related than distant things".* Segala sesuatu saling berhubungan satu dengan yang lainnya, tetapi sesuatu yang dekat lebih mempunyai pengaruh daripada sesuatu yang jauh. Hukum itulah yang menjadi pilar tentang kajian sains regional. Adanya efek spasial merupakan hal yang lazim terjadi antara satu region dengan region yang lain. Seperti diketahui Inflasi dihitung berdasarkan pada IHK, sedangkan di sisi lain IHK antar kota yang berdekatan dimungkinkan memiliki keterkaitan antar lokasi (Hasbullah, 2012). Keterkaitan tersebut dicerminkan adanya hubungan saling ketergantungan dalam memenuhi kebutuhan barang dan jasa. Keterbatasn infrastruktur dan kondisi geografis pada suatu wilayah akan mempengaruhi ketersediaan barang dan jasa pada wilayah lain yang tidak dapat memproduksi barang dan jasa sendiri sehingga berdampak pada biaya dan harga antar wilayah.

Penggunaan metode multivariat seperti VAR dan lainnya masih belum bisa menjelaskan keterkaitan antar lokasi, demikian juga untuk penggunaan non-linier yang cenderung sulit untuk diinterpretasikan hasilnya apalagi yang bisa menjelaskan keterkaitan antar wilayah/lokasi. Dalam analisis *time series* terdapat suatu model yang bisa menggabungkan keterkaitan antar waktu dan lokasi yang dinamakan model *space-time.* Model *space-time* pertama kali diperkenalkan oleh

Cliff dan Ord (1975), yang kemudian dikaji lebih lanjut oleh oleh Pfeifer dan Deutsh (1980a, 1980b) dalam bentuk model *Space Time Autoregressive* (STAR). Nilai parameter yang dihasilkan model STAR berlaku hanya pada lokasi yang homogen dan kurang sesuai jika diterapkan pada lokasi yang heterogen. Ruchjana (2002) melakukan pengembangan model STAR untuk mengatasi kelemahan pada nilai parameter untuk lokasi yang bersifat heterogen yaitu dengan menggunakan *Generalized Space Time Autoregressive* (GSTAR) yang memungkinkan nilai parameter *autoregressive* (AR) bervariasi pada setiap lokasi. Dengan demikian parameter pada model GSTAR lebih fleksibel dan memungkinkan untuk bisa diterapkan pada lokasi yang heterogen. Adapun perbedaan antar lokasi ditunjukkan dalam bentuk matriks pembobot.

Banyak para peneliti menggunakan model GSTAR untuk menganalisis suatu kasus diantaranya Ruchjana (2002), Wutsqa dan Suhartono (2010), Nurhayati, Pasaribu dan Neswan (2012), Wutsqa, Suhartono dan Sutijo (2012), Diani, Setiawan dan Suhartono (2013), Setiawan, Suhartono dan Prastuti (2016). Adapun untuk aplikasi model GSTAR dalam pemodelan inflasi diantaranya dilakukan oleh Faizah dan Setiawan (2013), Ardianto (2014), Mulyaningsih (2015), Irawati, Tarno dan Yasin (2015).

Seperti halnya dalam model univariat, pada model *time series* multivariat juga diperlukan variabel prediktor (eksogen) yang diharapkan bisa meningkatkan atau menambah akurasi dalam pemodelan dan hasil ramalannya. Model STARX dan GSTARX merupakan pengembangan model *time series* multivariat untuk data *space time* yang melibatkan variabel eksogen. Kedua metode tersebut masing-masing memiliki kelebihan tergantung dalam tujuan penelitiannya. Namun demikian, metode GSTARX dinilai mampu menjelaskan adanya pengaruh suatu wilayah terhadap wilayah lain dalam variabel *time series* seperti inflasi, IHK, kunjungan turis dan lain-lain.

Penelitian dengan model GSTARX dalam berbagai kasus pernah dilakukan antara lain oleh Oktanidya (2015), Kurnia (2015), Ditago (2015), Mubarak (2015), Astuti (2016). Adapun penerapan model GSTARX pada kasus inflasi antara lain dilakukan oleh Muryanto (2016) yang melakukan pemodelan dan peramalan IHK di empat kota di Kalimantan dengan GSTARX dimana variabel eksogen yang digunakan sebagai prediktor berupa jumlah uang beredar yang masuk (*inflow*) dan keluar (*outflow*). Suhartono *et al.* (2016) menerapkan model GSTARX-GLS untuk meramalkan inflasi di empat kota besar di Indonesia yaitu Surabaya, Malang, Jember dan Kediri dengan menggunakan variabel eksogen berupa kenaikan harga bahan bakar minyak dan libur Idul Fitri.

Mengacu pada penelitian sebelumnya tentang inflasi dan variabel eksogen yang digunakan, sejauh ini belum terdapat penelitian yang melibatkan variabel eksogen berupa skala metrik (fungsi transfer) dan non metrik (intervensi dan variasi kalender) secara simultan. Maka dalam penelitian ini penulis akan melakukan pemodelan dan peramalan inflasi pada wilayah Kalimantan dengan menggunakan metode GSTAR dengan melibatkan variabel eksogen dengan skala metrik (curah hujan) dan skala non-metrik (variasi kalender dan intervensi). Variasi kalender yang dimaksud adalah kejadian perayaan hari raya Idul Fitri, sedangkan intervensi yang dicakup berupa kebijakan kenaikan harga bahan bakar minyak (BBM). Penyertaan variabel curah hujan didasarkan pada penjelasan sebelumnya yang didukung adanya suatu penelitian oleh Diouf (2007) tentang pemodelan inflasi di Mali dan laporan Bank Indonesia (2015). Penelitian Diouf menyatakan bahwa rata-rata curah hujan merupakan salah satu faktor yang mempengaruhi terjadinya inflasi.

1.2. Rumusan Masalah

Berdasarkan pada latar belakang di atas, maka rumusan masalah dalam penelitian ini bagaimana implementasi suatu pemodelan inflasi dengan GSTAR yang melibatkan variabel eksogen secara simultan. Variabel eksogen dimaksud meliputi skala metrik (fungsi transfer) dan skala non metrik (intervensi dan variasi kalender).

1.3. Tujuan Penelitian

Berdasarkan rumusan masalah, maka tujuan penelitian ini adalah :

1. Mendapatkan orde *autoregressive* (AR) untuk keterkaitan waktu dan lokasi (*spatio temporal*) serta pengaruh variabel eksogen berupa skala metrik dan non metrik pada pemodelan GSTARX.
2. Mendapatkan model GSTARX yang sesuai untuk peramalan data inflasi pada enam kota di Kalimantan.
3. Memperoleh angka ramalan yang dihasilkan dari model GSTARX.
4. Memperoleh perbandingan akurasi hasil peramalan model ARIMAX dan GSTARX untuk data inflasi pada enam kota di Kalimantan.

1.4. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut :

1. Menghasilkan model GSTARX yang bisa menjelaskan keterkaitan inflasi pada beberapa kota di Kalimantan dan dapat digunakan untuk meramalkan inflasi pada kota yang bersangkutan pada beberapa periode mendatang.
2. Mengetahui efek dari faktor-faktor yang berpengaruh terhadap inflasi sebagai dasar antisipasi suatu kebijakan bagi pemerintah atau *stakeholders* di masa yang akan datang.
3. Hasil ramalan yang diperoleh dapat dijadikan bahan masukan bagi pemerintah daerah atau *stakeholders* maupun peneliti lainnya yang berkepentingan dengan data inflasi untuk pengambilan suatu keputusan.
4. Tambahan referensi dan acuan empiris tentang model *space time* bagi para peneliti dalam melakukan penelitian selanjutnya untuk menganalisis variabel data time series dengan melihat keterkaitan waktu dan lokasi serta variabel eksogen metrik dan non metrik.

1.5. Batasan Penelitian

Penelitian ini dibatasi pada hal-hal sebagai berikut :

1. Metode estimasi parameter dalam model *time series* bisa menggunakan metode *Ordinary Least Square* (OLS), *Generalized Least Square* (GLS), *Maximum Likelihood*, *Moment dan Bayesian.* Dalam penelitian ini, untuk estimasi parameter yang digunakan dalam GSTAR 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).
2. Daerah/kota yang menjadi obyek penelitian adalah beberapa kota penghitung inflasi di pulau Kalimantan yang memiliki hubungan langsung antar kota sehingga ordo spasial yang digunakan dibatasi hanya pada ordo satu.
3. Wilayah yang menjadi obyek penelitian sebanyak enam kota dari sembilan kota penghitung inflasi yaitu Pontianak (Kalimantan Barat), Sampit dan Palangkaraya (Kalimantan Tengah), Banjarmasin (Kalimantan Selatan), Balikpapan dan Samarinda (Kalimantan Timur). Pemilihan ini didasaarkan karena faktor ketersediaan *series* data.

BAB 2
TINJAUAN PUSTAKA

Pada bab ini dijelaskan analisis yang digunakan dalam penelitian yang meliputi konsep dasar time series, model ARIMA, model fungsi transfer, model analisis intervensi, variasi kalender, dan model GSTARX. Selain itu juga akan diuraikan pembahasan tentang inflasi.

2.1. Model *Time Series* Univariat

Data *time series* adalah rangkaian data yang berupa nilai pengamatan yang diukur selama kurun waktu tertentu, berdasarkan waktu dengan interval yang sama. Analisis *time series*, merupakan metode yang mempelajari data deret waktu, baik dari segi teori yang menaunginya maupun untuk membuat peramalan *(prediksi)*. Analisis data *time series* univariat mengacu kepada data deret waktu yang terdiri dari satu observasi yang diukur dalam kurun waktu tertentu pada interval yang sama, sedangkan multivariat untuk data lebih dari satu observasi.

Model time series, baik model univariat maupun multivariat, banyak digunakan untuk analisis data ekonomi dan bisnis, karena dengan model *time series* bisa melihat pola gerakan nilai-nilai variabel pada satu interval waktu yang teratur. Pemodelan *time series* bisa digunakan untuk membuat keputusan pada saat ini, untuk peramalan, dan perencanaan masa depan.

Model deret waktu univariat yang sering digunakan adalah *Autoregressive Moving Average* (ARMA). Model ARMA merupakan gabungan dari model *Autoregressive* (AR) dengan ordo *p* dan *Moving Average* (MA) dengan ordo *q*. Model ARMA (*p*,*q*) dari *Box-Jenkins* dengan rataan $E[Y_t] = 0$ dinyatakan sebagai berikut :

$$Y_t = \sum_{j=1}^{p} \phi_j Y_{t-j} - \sum_{k=1}^{q} \theta_k a_{t-k} + a_t \qquad (2.1)$$

dengan $a_t \sim iid\ N(0, \sigma^2),\ t \in \boldsymbol{N}$, dan $\boldsymbol{N}$ merupakan bilangan asli {1,2,..,T}.

Jika data deret waktu tidak stasioner dalam rata-rata maka dilakukan *differencing* sehingga memunculkan ordo pembeda *d* sehingga menghasilkan model yang dikenal dengan *Autoregressive Integrated Moving Average* ARIMA. Model ARIMA (*p*,*d*,*q*) secara umum dapat ditulis sebagai berikut (Wei, 2006:72):

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta_q(B)\, a_t \tag{2.2}$$

dengan $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \cdots - \phi_p B^p$ merupakan operator AR yang stasioner, $\theta_p(B) = 1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_q B^q$ adalaha operator MA yang *invertible,* θ_0 merupakan suatu konstanta dan a_t adalah *residual* yang *white noise* dengan *mean* nol dan *varians* σ_a^2 atau $a_t \sim WN(0, \sigma_a^2)$.

Adapun untuk data *time series* yang memiliki pola musiman periode *S* dengan *differencing D,* dapat dinotasikan sebagai ARIMA $(P,D,Q)^S$. Secara umum model ARIMA $(p,d,q)(P,D,Q)^S$ dapat dituliskan sebagai berikut (Wei, 2006:166) :

$$\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^S)^D Y_t = \theta_0 + \theta_q(B)\Theta_Q(B^s)\, a_t \tag{2.3}$$

dengan $\Phi_P(B^s)$ = $1 - \Phi_1 B^s - \Phi_2 B^{2s} - \cdots - \phi_P B^{Ps}$

$\Theta_Q(B^s)$ = $1 - \Theta_1 B^s - \Theta_2 B^{2s} - \cdots - \Theta_Q B^{Qs}$

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

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

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

2.2. Model ARIMA *Box-Jenkins*

Model *Box-Jenkins* adalah salah satu teknik peramalan model *time series* didasarkan pada perilaku data variabel yang diamati. Model *Box-Jenkins* secara teknis dikenal sebagai model *Autoregressive Integrated Moving Average* atau ARIMA (Makridakis *et al*., 1999). Prosedur *Box* dan *Jenkins* digunakan untuk memilih model ARIMA yang sesuai pada data deret waktu.

Dalam menyusun model ARIMA dengan prosedur *Box-Jenkins* memerlukan beberapa tahapan yaitu dimulai dari tahap identifikasi model, estimasi parameter, cek diagnosa dan peramalan, seperti diperlihatkan pada Gambar 2.1. berikut (Box *et al.*, 2008) :

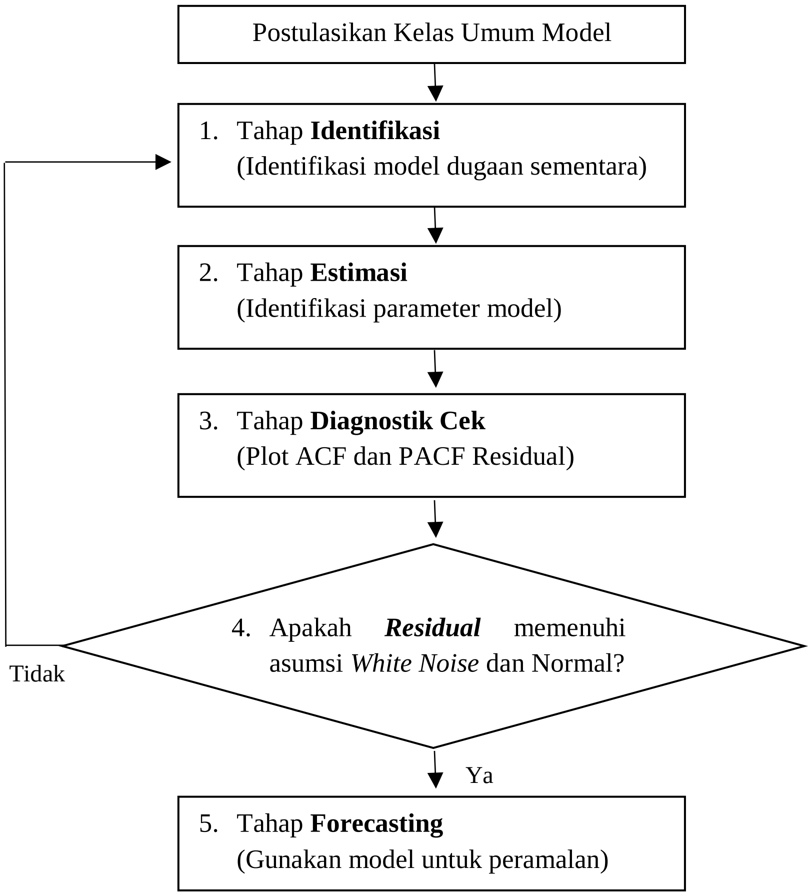

Gambar 2.1.
Tahapan Pembentukan Model ARIMA dengan Prosedur Box-Jenkins

2.2.1. Identifikasi Model

Dalam identifikasi model seperti pada persamaan (2.2) menurut Wei (2006 : 108-109) dilakukan dalam tahapan sebagai berikut :

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

Dalam pembentukan model ARIMA, syarat pertama yang harus dipenuhi adalah kestasioneran data *time series* dalam *mean* ataupun *varians*. Data dikatakan *stasioner* dalam *mean* apabila memiliki rata-rata yang konstan (tidak dipengaruhi waktu) dengan *varians* tetap (*homoskedastic*) dan tidak mengandung *autokorelasi*. Apabila data belum stasioner dalam *mean* maka bisa atasi dengan melakukan proses *differencing.*

Proses *differencing* merupakan proses dengan melakukan pengurangan atau pembedaan suatu data dengan data sebelumnya sampai data tersebut menjadi stasioner. Proses pembedaan pertama (*first difference*) sebagai berikut :

$$Y_t' = Y_t - Y_{t-1}. \tag{2.4}$$

Menggunakan *backshift* operator (B), persamaan (2.4) dapat dituliskan menjadi sebagai berikut :

$$Y_t' = Y_t - BY_t$$
$$Y_t' = (1 - B)Y_t. \tag{2.5}$$

Pembedaan pertama dinyatakan oleh $(1 - B)$.

Jika setelah proses *first difference* data masih belum stasioner, maka dilakukan proses *differencing* kedua (*second difference*), yaitu *differencing* satu dari hasil *differencing* pertama sebelumnya sebagai berikut :

$$Y_t'' = Y_t' - Y_{t-1}'$$
$$Y_t'' = Y_t - 2Y_{t-1} + Y_{t-2}$$
$$Y_t'' = (1 - B)^2 Y_t. \tag{2.6}$$

Sehingga proses *second difference* diberi notasi $(1 - B)^2$, sedangkan *first difference* $(1 - B)$. Maka secara umum apabila terdapat pembedaan orde *d* untuk mencapai stasioneritas, dapat dituliskan sebagai berikut :

$$\Delta^d Y_t = (1 - B)^d Y_t. \tag{2.7}$$

Adapun untuk data yang tidak stasioner dalam *varians* maka bisa diatasi dengan melakukan transformasi, salah satunya adalah transformasi Box-Cox. Untuk suatu nilai parameter λ (*lambda*), transformasi didefinisikan dengan persamaan sebagai berikut :

$$T(Y_t) = \begin{cases} \dfrac{Y_t^\lambda - 1}{\lambda} & , \lambda \neq 0 \\ \lim\limits_{\lambda \to 0} \dfrac{Y_t^\lambda - 1}{\lambda} = \ln(Y_t) & , \lambda = 0. \end{cases} \tag{2.8}$$

Bentuk transformasi *Box-Cox* untuk beberapa nilai estimasi λ yang sering digunakan bisa dilihat pada Tabel 2.1 (Wei, 2006:85).

Tabel 2.1. Nilai Transformasi *Box-Cox*

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

Uji stasioneritas *varians* tersebut ditampilkan dalam bentuk plot *Box-Cox*. *Varians* data dikatakan sudah stasioner atau stabil jika nilai batas bawah dan batas atas λ dari data *time series* mengandung nilai satu.

Tahap 2. Menghitung dan memeriksa sampel *Autocorrelation Function* (ACF) dan sampel *Partial Autocorrelation Function* (PACF) dari data awal, untuk menentukan perlu tidaknya dilakukan *differencing*. Beberapa langkah atau aturan umum yang dapat diikuti :

1. Bila ACF turun secara lambat dan PACF *cuts off* setelah *lag* 1, ini mengindikasikan perlu dilakukan *differencing* yaitu $(1 - B)Y_t$. 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 atau untuk $d > 1$ seperti pada persamaan (2.7).

Tahap 3. Menghitung dan memeriksa ACF dan PACF dari data yang telah stasioner, untuk menentukan order dari *p* dan *q*.

Untuk penentuan orde dari model AR(*p*), MA(*q*), ARMA(*p*,*q*), dan ARIMA (*p*,*d*,*q*) bisa diketahui dari plot ACF dan PACF. Karakteristik dari model AR, MA, ARMA dan ARIMA yang didasarkan pada plot ACF dan PACF untuk data yang telah stasioner bisa dilihat pada Tabel 2.2 berikut (Wei, 2006:109) :

Tabel 2.2. Pola Plot ACF dan PACF dari Model ARMA (*p*,*q*)

Proses	**ACF**	**PACF**
AR(*p*)	Menurun secara eksponensial (*dies down*)	Terpotong setelah lag *p* (*cut off*)
MA(*q*)	Terpotong setelah lag *q* (*cut off*)	Menurun secara eksponensial (*dies down*)
ARMA (*p*,*q*)	Menurun secara eksponensial (*dies down*) setelah lag (*q*-*p*)	Menurun secara eksponensial (*dies down*) setelah lag (*p*-*q*)

2.2.2. Tahap Estimasi dan Uji Signifikansi Parameter

Salah satu metode estimasi yang digunakan adalah *least square* (LS). Metode ini bekerja dengan membuat error yang tidak diketahui sama dengan nol dan meminimumkan jumlah kuadrat error (SSE). Misalkan diterapkan pada model AR(1) dan dinyatakan sebagai berikut (Cryer dan Chan, 2008:154-155) :

$$Y_t - \mu = \phi(Y_{t-1} - \mu) + a_t \tag{2.9}$$

dengan nilai SSE sebagai berikut :

$$S(\phi, \mu) = \sum_{t=2}^{n} a_t^2 = \sum_{t=2}^{n} [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2. \tag{2.10}$$

Kemudian persamaan (2.10) diturunkan terhadap μ menjadi

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

Sehingga diperoleh nilai taksiran parameter terhadap μ sebagai berikut :

$$\hat{\mu} = \frac{1}{(n-1)(1-\phi)}\left[\sum_{t=2}^{n} Y_t - \phi \sum_{t=2}^{n} Y_{t-1}\right]. \quad (2.11)$$

Untuk nilai n besar, maka

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

sehingga

$$\hat{\mu} = \frac{1}{(1-\phi)}(\bar{Y} - \phi\bar{Y}) = \bar{Y}. \quad (2.12)$$

Adapun persamaan (2.10) diturunkan terhadap ϕ menjadi

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

Untuk $\mu = \bar{Y}$ maka diperoleh nilai taksiran parameter terhadap ϕ sebagai berikut :

$$\hat{\phi} = \frac{\sum_{t=2}^{n}(Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^{n}(Y_{t-1} - \bar{Y})^2}. \quad (2.13)$$

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*, yaitu :

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

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 $\hat{\phi}$ dan n_p adalah jumlah parameter dalam model.

2.2.3. Tahap *Diagnostic Check* Model

Proses *diagnostic checking* dimaksudkan untuk mendapatkan model yang sesuai setelah mendapatkan parameter yang siginfikan. *Diagnostic checking* dilakukan dengan memeriksa *residual* hasil pemodelan. Model dikatakan sesuai jika memenuhi asumsi *residual* yang *white noise*. Residual yang *white noise* (Wei, 2006: 15) mengandung makna bahwa residual tersebut bersifat independen yang berasal dari distribusi tertentu dengan *mean* konstan $E(a_t) = \mu_a$, biasanya diasumsikan dengan 0 (nol) atau berdistribusi normal, variansi konstan $Var(a_t) = \sigma_a^2$ dan $\gamma_k = Cov(a_t, a_{t+k}) = 0$ untuk $k \neq 0$.

2.2.3.1. Independensi

Suatu *residual* dalam *time series* dikatakan independen jika tidak terdapat korelasi antar *residual* dengan *mean* nol dan varians konstan (σ_a^2). Hipotesis untuk uji *residual* (α_t) yang *white noise* adalah sebagai berikut (Wei, 2006: 153).:

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

H_1: minimal ada satu $\rho_k \neq 0; k = 1,2, \ldots, K$.

Adapun statistik uji yang digunakan adalah :

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

dimana $\hat{\rho}_k$ adalah estimasi ACF *residual* pala *lag-k* dan *n* adalah banyaknya *residual*. Daerah penolakan H_0 adalah $Q > \chi^2_{\alpha;K-p-q}$.

2.2.3.2. Uji Normalitas

Untuk menguji kenormalan *residual* model dengan menggunakan uji Kolmogorov-Smirnov. Hipotesis yang digunakan untuk uji kenormalan Kolmogorov-Smirnov adalah sebagai berikut :

$H_0: F(a_t) = F_0(a_t)$ (residual berdistribusi normal)

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

Sedangkan statistik uji yang digunakan adalah

$$D = Sup_x|S(a_t) - F_0(a_t)|. \tag{2.16}$$

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

$S(a_t)$ = fungsi distribusi kumulatif dari data asal (sampel)

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

Sup = nilai supremum (maksimum) semua *x* dari $|S(a_t) - F_0(a_t)|$.

2.2.4. Peramalan (*Forecasting*)

Tahapan terakhir yang dilakukan dalam analisis *time series* adalah tahap peramalan (Wei, 2006 :89-90). Suatu model ARIMA dengan d = 0 atau ARMA (p,q) yang stasioner secara umum didefinisikan dalam bentuk :

$$\phi(B)Y_t = \theta(B)a_t, \tag{2.17}$$

atau dapat ditulis dalam representasi MA, yaitu

$$Y_t = \psi(B)a_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \cdots \tag{2.18}$$

dimana

$$\psi(B) = \sum_{j=0}^{\infty} \psi_j B^j = \frac{\theta(B)}{\phi(B)}$$

dan $\psi_0 = 1$. Untuk $t = n + l$, kita mempunyai

$$Y_{n+l} = \sum_{j=0}^{\infty} \psi_j a_{n+l-j} \tag{2.19}$$

dengan menggunakan ramalan *Minimum Mean Square Error* akan diperoleh

$$\hat{Y}_n(l) = \psi_l a_n + \psi_{l+1} a_{n-1} + \psi_{l+2} a_{n-2} + \cdots. \tag{2.20}$$

$\hat{Y}_n(l)$ biasa dibaca sebagai ramalan pada langkah ke-*l* dari Y_n, sehingga untuk kesalahan ramalan pada l langkah ke depan diperoleh

$$e_n(l) = Y_n(l) - \hat{Y}_n(l) = \sum_{j=0}^{l-1} \psi_j a_{n+l-j}. \tag{2.21}$$

Sehingga variansi kesalahan ramalan pada l langkah ke depan ditulis

$$Var\big(e_n(l)\big) = \sigma_a^2 \sum_{j=0}^{l-1} \psi_j^2. \tag{2.22}$$

Error ramalan $e_n(l)$ seperti ditunjukkan pada persamaan (2.21) adalah saling independen dan kombinasi linier setelah waktu *n*. Untuk error ramalan pertama bisa ditulis

$$e_n(1) = Y_{n+1} - \hat{Y}_n(1) = a_{n+1} \tag{2.23}$$

dimana $\hat{Y}_n(1)$ adalah ramalan terbaik untuk Y_{n+1}.

2.3. Model Fungsi Transfer

Model fungsi transfer merupakan suatu model yang menggambarkan bahwa ramalan masa depan dari suatu deret waktu (*output series* atau y_t) adalah berdasarkan pada nilai-nilai masa lalu dari deret waktu itu sendiri serta didasarkan pada satu atau lebih deret waktu yang lain (*input series* atau x_t) yang berhubungan dengan *output series* tersebut.

Model fungsi transfer terbentuk melalui *Auto Correlation Function* (ACF) dan *Cross Correlation Function* (CCF) sehingga dapat digunakan untuk meramal suatu variabel berdasarkan informasi dari variabel lainnya. Bentuk umum model fungsi transfer untuk input tunggal, x_t, dan output tunggal, y_t, adalah sebagai berikut (Wei, 2006: 322) :

$$y_t = v(B)x_t + n_t, \tag{2.24}$$

dengan y_t = deret *output* yang stasioner

x_t = deret *input* yang stasioner

n_t = komponen *error* yang mengikuti model ARIMA tertentu

$v(B)$ = $v_0 + v_1 B + v_2 B^2 + \cdots$ yaitu koefisien model fungsi transfer atau bobot respon impuls.

Bentuk lain dari $v(B)$ dan n_t bisa ditulis sebagai berikut :

$$v(B) = \frac{\omega_s(B)B^b}{\delta_r(B)} \quad \text{dan} \quad n_t = \frac{\theta(B)}{\phi(B)} a_t.$$

Sehingga persamaan (2.24) dapat ditulis dalam bentuk

$$y_t = \frac{\omega_s(B)B^b}{\delta_r(B)} x_t + \frac{\theta(B)}{\phi(B)} \tag{2.25}$$

dengan

b = banyaknya periode sebelum deret input mulai berpengaruh terhadap deret output

$\omega_s(B) = \omega_0 - \omega_1 B - \omega_2 B^2 - \cdots - \omega_s B^s$ merupakan operator dengan orde *s*, yang mempresentasikan jumlah pengamatan masa lalu x_t yang berpengaruh terhadap y_t

$\delta_r(B) = 1 - \delta_1 B - \delta_2 B^2 - \cdots - \delta_r B^r$ merupakan operator dengan orde *r*, yang mempresentasikan jumlah pengamatan masa lalu dari deret ouput itu sendiri yang berpengaruh terhadap y_t

$\theta_q(B)$ = merupakan operator *moving average* orde ke-*q*, dari n_t

$\phi_p(B)$ = merupakan operator *autoregressive* orde ke-*p*, dari n_t

a_t = merupakan *residual* yang *white noise* dari deret n_t.

2.3.1. *Cross Correlation Function* (CCF)

CCF digunakan untuk mengukur kekuatan dan arah hubungan antara dua variabel *random* dimana bentuk fungsi kovarian silang antara x_t dan y_{t+k} (Wei, 2006: 325-326) dinyatakan sebagai berikut :

$$\gamma_{xy}(k) = E\left[(x_t - \mu_x)\left(y_{t+k} - \mu_y\right)\right] \tag{2.26}$$

dengan $k = 0, \pm1, \pm2, \dots, \mu_x = E(x_t)$ dan $\mu_y = E(y_t)$. Bentuk fungsi korelasi silang antara x_t dan y_t adalah :

$$\rho_{xy}(k) = \frac{\gamma_{xy}(k)}{\sigma_x \sigma_y} \tag{2.27}$$

dengan σ_x dan σ_y adalah standar deviasi dari x_t dan y_t.

2.3.2. Tahapan Pembentukan Fungsi Transfer

Dalam membangun model fungsi transfer, terdapat empat tahapan yaitu :

2.3.2.1. Identifikasi Model Fungsi Transfer

✓ *Prewhitening* deret *input*

$$\alpha_t = \frac{\phi_x(B)}{\theta_x(B)} x_t \tag{2.28}$$

dengan α_t merupakan deret *input* yang mengalami *prewhitening* dan *error* model ARIMA yang *white noise* dan $N(0, \sigma_a^2)$, dan x_t merupakan deret *input* yang stasioner.

✓ *Prewhitening* deret *output*

$$\beta_t = \frac{\phi_x(B)}{\theta_x(B)} y_t \tag{2.29}$$

dengan β_t merupakan deret *output* yang mengalami *prewhitening* berdasarkan parameter deret *input* dan y_t merupakan deret *output* yang stasioner.

✓ Menghitung sampel CCF antara α_t dan β_t

$$\hat{\rho}_{\alpha_t \beta_{t+k}} = r_k(\alpha_t, \beta_{t+k}) = \frac{1}{n} \sum_{t=1}^{n-k} (\alpha_t - \bar{\alpha})(\beta_{t+k} - \bar{\beta}) \Big/ S_x S_y \tag{2.30}$$

dengan

$$S_x = \sqrt{\frac{1}{n} \sum_{t=1}^{n} (\alpha_t - \bar{\alpha})^2} \text{ dan } S_y = \sqrt{\frac{1}{n} \sum_{t=1-k}^{n} \left(\beta_{t+k} - \bar{\beta}\right)^2}$$

✓ Penetapan orde *b*, *s*, *r* yang menghubungkan deret *input* dan deret *output* (Makridakis *et al.*, 1999).

1. Nilai *b* menyatakan bahwa y_t tidak dipengaruhi oleh x_t sampai pada periode *t*+b.
2. Nilai *s* menyatakan bahwa berapa lama deret *output* (y_t) secara terus menerus dipengaruhi oleh nilai-nilai baru dari deret *input* (x_t) atau y_t dipengaruhi oleh $x_{t-b}, x_{t-b-1}, \dots, x_{t-b-s}$.
3. Nilai *r* menunjukkan bahwa y_t berkaitan dengan nilai-nilai masa lalu dari *y*, yaitu $y_{t-1}, y_{t-2}, \dots, y_{t-r}$.

Setelah menetapkan orde *b*, *s*, *r*, selanjutnya dilakukan penaksiran model fungsi transfer sementara.

$$\hat{v}(B) = \frac{\hat{\omega}(B)}{\hat{\delta}(B)} B^b. \tag{2.31}$$

✓ Penaksiran awal deret noise ($\hat{n}_t$)

$$\hat{n}_t = y_t - \frac{\hat{\omega}(B)}{\hat{\delta}(B)} B^b x_t. \tag{2.32}$$

✓ Penetapan model fungsi transfer dan ARMA (*p*,*q*) dari deret *noise* seperti pada persamaan (2.25).

2.3.2.2. Estimasi Parameter Model Fungsi Transfer

Metode estimasi parameter model ARIMA dapat pula digunakan untuk estimasi parameter model fungsi transfer. Estimasi parameter model fungsi transfer menggunakan metode *conditional least square*, dengan parameter $\omega, \delta, \phi, \theta$. Setelah melakukan identifikasi model fungsi transfer sementara pada persamaan (2.32) selanjutnya parameter $\omega = (\omega_0, \omega_1, \dots, \omega_s)$, $\delta = (\delta_1, \delta_2, \dots, \delta_s)$, $\phi = (\phi_1, \dots, \phi_p)$, $\theta = (\theta_1, \dots, \theta_q)$, dan σ_a^2 akan diestimasi. Persamaan (2.25) dapat ditulis dalam bentuk berikut (Wei, 2006: 332-333) :

$$\delta_r(B)\phi(B)y_t = \phi(B)\omega_s(B)x_{t-b} + \delta_r(B)\theta(B)a_t \tag{2.33}$$

atau dapat juga ditulis :

$$c(B)y_t = d(B)x_{t-b} + e(B)a_t \tag{2.34}$$

dimana

$$
\begin{aligned}
c(B) = \delta_r(B)\phi(B) &= (1-\delta_1 B - \cdots \delta_r B^r)(1-\phi_1 B - \cdots - \phi_p B^p) \\
&= (1 - c_1 B^1 - c_2 B^2 - \cdots - c_{p+r} B^{p+r}) \\
d(B) = \phi(B)\omega_s(B) &= (1-\phi_1 B - \cdots - \phi_p B^p)(\omega_0 - \omega_1 B - \cdots - \omega_s B^s) \\
&= (d_0 - d_1 B^1 - d_2 B^2 - \cdots - d_{p+s} B^{p+s}) \\
e(B) = \delta_r(B)\theta(B) &= (1-\delta_1 B - \cdots \delta_r B^r)(1-\theta_1 B - \cdots - \theta_q B^q) \\
&= (1 - e_1 B^1 - e_2 B^2 - \cdots - e_{r+q} B^{r+q})
\end{aligned}
$$

maka,

$$
\begin{aligned}
a_t = \ & y_1 - c_1 y_{t-1} - \cdots - c_{p+r} y_{t-p-r} - d_0 x_{t-b} + d_1 x_{t-b-1} \\
& + \cdots + d_{p+s} x_{t-b-p-s} + e_{r+q} a_{t-r-q}
\end{aligned} \tag{2.35}
$$

dengan c_i, d_j, dan e_k adalah fungsi dari δ_i, ω_j, ϕ_k, dan θ_l. Dengan asumsi bahwa a_t adalah deret *white noise* $N(0, \sigma_a^2)$, sehingga fungsi *conditional likelihood :*

$$
L(\delta, \omega, \phi, \theta, \sigma_a^2 | b, x, y, x_0, y_0, a_0) = (2\pi\sigma_a^2)^{-n/2} exp\left[-\frac{1}{2\pi\sigma_a^2}\sum_{t=1}^{n} a_t^2\right] \tag{2.36}
$$

dengan x_0, y_0, a_0 adalah beberapa nilai awal yang sesuai untuk menghitung a_t dari persamaan (2.35) sama dengan nilai awal yang diperlukan dalam pendugaan model ARIMA univariat.

Metode estimasi *maximum likelihood* bisa digunakan untuk menduga paramater $\delta, \omega, \phi, \theta, \sigma_a^2$. Dengan mengatur nilai a sama dengan 0 sebagai nilai ekspektasi bersyarat, estimasi kuadrat terkecil nonlinier dari parameter tersebut diperoleh dengan nilai SSE, yaitu :

$$
S(\delta, \omega, \phi, \theta | b) = \sum_{t=t_0}^{n} a_t^2 \tag{2.37}
$$

dengan t_0 = max $\{p + r + 1, b + p + s + 1\}$.

Sejauh ini dengan asumsi *b* diketahui. Adapun nilai-nilai yang diberikan untuk *s*, *r*, *p*, dan *q*, jika penduga dari *b* juga dibutuhkan, maka persamaan (2.37) dapat dioptimisasi untuk nilai-nilai dari *b*. maka nilai *b* dipilih untuk nilai yang memberikan nilai jumlah kuadrat error minimum.

2.3.2.3. Uji Kesesuaian Model

Langkah dalam uji kesesuaian model fungsi transfer adalah sebagai berikut (Wei, 2006: 334-335) :

- ✓ Melakukan uji korelasi silang antara residual model deret *noise* (a_t) dengan deret input yang telah melalui *prewhitening* (α_t) untuk memastikan bahwa kedua deret tersebut bersifat independen dengan memperhatikan korelasi silang $(\hat{\rho}_{\alpha\hat{a}}(k))$ yang terletak diantara dua standar error $2(n-k)^{-1/2}$. Pengujian ini dinamakan uji *portmanteau* yang ditulis sebagai berikut :

$$Q_0 = m(m+2)\sum_{j=0}^{K}(m-j)^{-1}\hat{\rho}_{\alpha\hat{a}}^2(j) \tag{2.38}$$

yang mengikuti distribusi χ^2 dengan derajat bebas adalah $(K+1)-M$, $m = n - t_0 + 1$ dan m menyatakan banyaknya parameter δ_i dan ω_j yang diduga. Daerah penolakan adalah jika $Q_0 > \chi^2_{\alpha;(K+1)-M}$

- ✓ Pengujian autokorelasi residual model deret *noise* $(\hat{a}_t)$ atau disebut uji *white noise* dengan menggunakan statistik uji *Ljung-Box* seperti pada persamaan (2.39), selain itu dilakukan uji residual model deret *noise* berdistribusi normal.

$$Q_1 = m(m+2)\sum_{j=1}^{K}(m-j)^{-1}\hat{\rho}_{\hat{a}}^2(j) \tag{2.39}$$

dengan daerah penolakan adalah jika $Q_1 > \chi^2_{\alpha;(K-p-q)}$.

2.3.2.4. Peramalan Menggunakan Model Fungsi Transfer

Setelah model fungsi transfer yang sesuai diperoleh, pada tahap selanjutnya dilakukan peramlan terhadap nilai dari deret *output* (y_t) berdasarkan nilai masa lalu dari deret *ouput* dan deret *input* (x_t) yang mempengaruhinya. Misalkan bahwa y_t dan x_t adalah stasioner dan berhubungan dalam model fungsi transfer seperti pada persamaan (2.25) dan (2.28)

$$y_t = \frac{\omega_s(B)B^b}{\delta_r(B)}x_t + \frac{\theta(B)}{\phi(B)}a_t \quad \text{dan} \quad \phi_x(B)x_t = \theta_x(B)\alpha_t$$

dimana $\omega(B)$, $\delta(B)$, $\theta(B)$, $\phi(B)$, $\phi_x(B)$ dan $\theta_x(B)$ orde terbatas polinomial dalam B, untuk a_t dan α_t adalah independen dan merupakan deret yang *white noise* dengan varians masing-masing σ_a^2 dan σ_α^2, maka

$$u(B) = \frac{\omega_s(B)B^b\theta_x(B)}{\delta_r(B)\phi_x(B)} = u_0 + u_1B + u_2B^2 + \cdots \tag{2.40}$$

dan

$$\psi(B) = \frac{\theta(B)}{\phi(B)} = 1 + \psi_1B + \psi_2B^2 + \cdots \tag{2.41}$$

maka dapat ditulis

$$y_t = u(B)\alpha_t + \psi(B)a_t = \sum_{j=0}^{\infty} u_j\alpha_{t-j} + \sum_{j=0}^{\infty} \psi_j a_{t-j} \tag{2.42}$$

dimana $\psi = 1$, demikian juga $y_{t+l} = \sum_{j=0}^{\infty} u_j\alpha_{t+l-j} + \sum_{j=0}^{\infty} \psi_j a_{t+l-j}$, dan $\hat{y}_t(l) = \sum_{j=0}^{\infty} u_{l+j}^*\alpha_{t-j} + \sum_{j=0}^{\infty} \psi_{l+j}^* a_{t-j}$ merupakan ramalan ke-*l* dari y_{t+l}, maka error ramalan bisa ditulis sebagai berikut :

$$y_{t+l} - \hat{y}_t(l) = \sum_{j=0}^{l-1}(u_j\alpha_{t+l-j} + \psi_j a_{t+l-j}) - \sum_{j=0}^{\infty}(u_{l+j}^* - u_{l+j})\,\alpha_{t-j} - \sum_{j=0}^{\infty}(\psi_{l+j}^* - \psi_{l+j})\,a_{t-j} \tag{2.43}$$

2.4. Model ARIMAX Untuk Variasi Kalender

Menurut Lee *et al.* (2010), regresi dalam *time series* mempunyai konteks yang sama dengan regresi linier pada umumnya. Dengan mengasumsikan deret *output* atau dependen, $y_t, t = 1,2,\dots,n$ yang dipengaruhi oleh beberapa kemungkinan *input* (variabel independen), dengan input tersebut *fixed* dan diketahui. Hubungan ini dapat dinyatakan sebagai model regresi linier (Shumway and Stoffer (2006) dalam Lee *et al.* (2010)). Jika di terdapat trend dalam data, maka model dapat diformulasikan sebagai berikut :

$$y_t = \beta_0 + \beta_1 t + w_t \tag{2.44}$$

dimana w_t merupakan komponen *error* yang memenuhi asumsi identik, independen dan berdistribusi normal dengan rata-rata 0 dan varians σ_w^2. Model variasi kalender dapat dimodelkan dengan menggunakan regresi. Model regresi linier untuk data yang menggunakan efek variasi kalender yaitu (Lee *et al*., 2010):

$$y_t = \beta_0 + \beta_1 V_{1,t} + \beta_2 V_{2,t} + \cdots + \beta_p V_{p,t} + w_t \tag{2.45}$$

dimana $V_{p,t}$ adalah variabel *dummy* untuk efek variasi kalender ke-*p*. Banyaknya efek variasi kalender didasarkan pada plot deret waktu dari data atau statistika deskriptif (Lee *et al*., 2010).

Menurut Cyer dan Chan (2008) dalam Lee *et al*. (2010) bahwa model ARIMAX merupakan model ARIMA dengan tambahan variabel. Lee *et al*. (2010) menyatakan penambahan variabel eksogen pada model ARIMA berupa variasi kalender dapat dilakukan dengan variabel *dummy* hanya sebagai efek kalender variasi (ARIMAX dengan tren stokastik dengan *differencing* non musiman dan/atau musiman) dan variabel *dummy* untuk efek variasi kalender dan tren determinstik (ARIMAX tanpa order *differencing*).

Model ARIMA musiman secara umum dapat dituliskan sebagai berikut :

$$y_t = \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D}\varepsilon_t \tag{2.46}$$

dimana ε_t merupakan residual yang sudah *white noise* dengan *means* 0 dan varians konstan. Sehingga model ARIMAX dengan tren stokastik dapat dituliskan sebagai berikut :

$$y_t = \beta_1 V_{1,t} + \beta_2 V_{2,t} + \cdots + \beta_p V_{p,t} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D}\varepsilon_t. \tag{2.47}$$

Adapun model ARIMAX dengan tren deterministik bisa ditulis sebagai berikut :

$$y_t = \gamma t + \beta_1 V_{1,t} + \beta_2 V_{2,t} + \cdots + \beta_p V_{p,t} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)}\varepsilon_t. \tag{2.48}$$

Untuk membangun model ARIMAX dengan adanya efek variasi kalender dapat dijabarkan sebagai berikut (Lee *et al*., 2010) :

1. Menentukan variabel *dummy* pada periode variasi kalender.
2. Menghilangkan efek variasi kalender dari respon dengan *fitting* persamaan (2.45) pada model dengan tren stokastik, atau *fitting* persamaan (2.44) dan (2.45) secara bersamaan pada model dengan tren deterministik, untuk mendapatkan *error* 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 (2.47) dan (2.48) untuk masing-masing model dengan tren stokastik dan deterministik.
5. Uji signifikansi dari parameter dan melakukan *diagnostic checks* sampai proses stasioner dan ε_t mencapai proses *white noise.*

2.5. Analisis Intervensi

Pola data *time series* terkadang dipengaruhi oleh suatu kejadian tertentu misalnya adanya suatu intervensi baik yang bersifat eksternal maupun internal. Asumsi yang digunakan adalah kejadian intervensi terjadi pada waktu T yang diketahui dari suatu *time series* (Box *et al*., 1994). Dalam analisis intervensi bisa diketahui besar dan lamanya efek intervensi pada suatu *time series* (Wei, 1990).

2.5.1. Model Intervensi

Model intervensi merupakan suatu model yang bisa digunakan pada saat kejadian eksternal di luar perkiraan maupun kejadian internal yang bisa diperkirakan mempengaruhi variabel yang diramalkan. Bentuk umum dari model intervensi adalah sebagai berikut (Wei, 1990) :

$$Y_t = \frac{\omega_s(B)B^b}{\delta_r(B)} I_t + n_t \tag{2.49}$$

dimana :

Y_t = variabel respon pada waktu ke-*t*

I_t = variabel intervensi pada waktu *t*, bernilai 1 atau 0 yang menunjukkan ada tidaknya pengaruh intervensi pada waktu *t*, dapat berupa fungsi *step* (S_t) atau fungsi *pulse* (P_t).

n_t = komponen *error* (deret *noise*), yang mengikuti model ARIMA tanpa pengaruh intervensi

b = *delay* waktu mulai terjadinya efek intervensi

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

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

Jenis variabel intervensi dibagi menjadi dua yaitu fungsi *Step* dan *Pulse* (Box *et al.*, 1994). Fungsi *step* merupakan kejadian intervensi yang terjadi sejak waktu T dan seterusnya dalam waktu yang panjang. Misalnya pemberlakuan kebijakan baru berupa ketetapan tarif baru pada perusahaan *Cincinnati Bell Telephon* terhadap jumlah panggilan bantuan telepon lokal (McSweeny, 1978).

Bentuk intervensi fungsi *step* ini secara matematis dinotasikan sebagai berikut:

$$I_t = S_t = \begin{cases} 0 & ,t < T \\ 1 & ,t \geq T. \end{cases} \tag{2.50}$$

Adapun variabel intervensi pada fungsi *pulse*, kejadian intervensi terjadi hanya pada waktu T saja dan tidak berlanjut pada waktu selanjutnya, misalnya promosi gelegar 2 milyar yang dilakukan PT. Telkom Divre V (Suhartono dan Wahyuni, 2002). Secara matematis, bentuk intervensi fungsi *pulse* ini dinotasikan sebagai berikut :

$$I_t = P_t = \begin{cases} 0 & ,t \neq T \\ 1 & ,t = T. \end{cases} \tag{2.51}$$

2.5.2. Identifikasi Orde Model Intervensi

Untuk mengetahui orde pada model intervensi (*b*, *s*, dan *r*) dapat dilihat pada plot *residual* data waktu intervensi dengan model ARIMA atau intervensi sebelumnya. Nilai *b* menunjukkan kapan efek intervensi mulai terjadi, nilai *s* menunjukkan kapan gerak bobot respon mulai mengalami penurunan atau kenaikan, dan *r* menunjukkan pola dari *residual*.

2.5.3. Estimasi Parameter

Estimasi parameter model intervensi dihitung berdasarkan bentuk umum dari model fungsi transfer yaitu :

$$Y_t = \frac{\omega_s(B)}{\delta_r(B)} I_{t-b} + \frac{\theta(B)}{\phi(B)} a_t \tag{2.52}$$

Persamaan (2.52) dapat ditulis dalam bentuk lain yaitu :

$$\delta_r(B)\phi(B)Y_t = \phi(B)\omega_s(B)I_{t-b} + \delta_r(B)\theta(B)a_t \tag{2.53}$$

atau sama dengan

$$c(B)Y_t = d(B)I_{t-b} + e(B)a_t \tag{2.54}$$

dimana

$$\begin{aligned} c(B) &= \delta_r(B)\phi(B) = 1 - c_1B^1 - c_2B^2 - \cdots - c_{p+r}B^{p+r} \\ d(B) &= \phi(B)\omega_s(B) = d_0 - d_1B^1 - d_2B^2 - \cdots - d_{p+s}B^{p+s} \\ e(B) &= \delta_r(B)\theta(B) = 1 - e_1B^1 - e_2B^2 - \cdots - e_{r+q}B^{r+q} \end{aligned}$$

sehingga

$$a_t = \frac{c(B)Y_t - d(B)I_{t-b}}{e(B)} \tag{2.55}$$

dengan asumsi a_t adalah $N(0, \sigma_a^2)$ *white noise*. maka diperoleh fungsi *conditional likelihood* sebagai berikut :

$$L(\delta, \omega, \phi, \theta, \sigma_a^2 | b, I, y, I_0, y_0, a_0) = (2\pi\sigma_a^2)^{-n/2} exp\left[-\frac{1}{2\pi\sigma_a^2}\sum_{t=1}^{n} a_t^2\right] \tag{2.56}$$

untuk mendapatkan estimasi parameter dapat dilakukan dengan meminimumkan

$$S(\delta, \omega, \phi, \theta | b) = \sum_{t=t_0}^{n} a_t^2 \tag{2.57}$$

dengan t_0 = max $\{p + r + 1, b + p + s + 1\}$, dan a_t merupakan persamaan residual seperti pada (2.55).

Mengacu pada bentuk model intervensi *single input*, maka untuk model intervensi *multi input* dapat ditulis sebagai berikut (Wei, 2006) :

$$Y_t = \sum_{i=1}^{k} \frac{\omega_{s_i}(B)B^{b_i}}{\delta_{r_i}(B)} X_{i,t} + \frac{\theta(B)}{\phi(B)} a_t \tag{2.58}$$

dimana $X_{i,t}$ adalah variabel intervensi dengan $i = 1,2,\dots,k$ merupakan banyaknya intervensi.

2.6. Deteksi *Outlier*

Outlier dalam suatu data deret waktu merupakan suatu data pengamatan yang tidak konsisten sebagai akibat dari adanya kejadian luar biasa yang tidak terduga dan tanpa disadari seperti pemogokan, wabah perang, krisis politik atau ekonomi yang bergejolak. Pengamatan tersebut biasa dikenal dalam *time series* berupa *outlier* (Wei, 2006). *Outlier* dapat menyebabkan hasil analisis data menjadi tidak *reliable* dan tidak *valid*, sehingga deteksi *outlier* perlu dilakukan untuk menghilangkan efek *outlier* tersebut.

Deteksi *outlier* pertama kali diperkenalkan oleh Fox (1972) dalam Wei (2006). *Outlier* terdiri dari beberapa tipe, yaitu *additive outlier* (AO), *innovational outlier* (IO), *level shift* (LS) dan *temporary change* (TC). Cara mengatasi *outlier* dengan memasukkan *outlier* dalam model sampai mendapatkan model yang memenuhi asumsi *white noise* dan berdistribusi normal.

2.6.1. *Additive Outlier* (AO)

Additive outlier (AO) merupakan kejadian yang mempengaruhi suatu deret runtun waktu pada satu waktu saja. Wei (2006) mendefinisikan model additive *outlier* sebagai berikut :

$$Y_t = \begin{cases} u_t & , t \neq T \\ u_t + \omega & , t = T \end{cases} \tag{2.59}$$

atau

$$Y_t = u_t + \omega I_t^{(T)}$$
$$= \frac{\theta(B)}{\phi(B)} a_t + \omega I_t^{(T)}, \tag{2.60}$$

dengan

$$I_t^{(T)} = \begin{cases} 1 & , t \neq T \\ 0 & , t = T \end{cases}$$

u_t adalah model ARIMA sebelum deteksi *outlier*

$I_t^{(T)}$ adalah variabel *outlier* pada waktu ke-*T*.

2.6.2. *Innovational Outlier* (IO)

Data *time series* yang mengandung *innovational outlier* memberikan efek yang lebih rumit jika dibandingkan ketiga tipe *outlier* lainnya. Wei (2006) mendefinisikan model IO sebagai berikut :

$$Y_t = u_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)}$$
$$= \frac{\theta(B)}{\phi(B)} \left(a_t + \omega I_t^{(T)} \right). \tag{2.61}$$

Efek AO hanya terjadi pada T observasi saja, sedangkan pada IO mempengaruhi seluruh observasi $Y_t, Y_{t+1}, \ldots$ melewati waktu T sepanjang memori dari sistem yang diberikan oleh $\frac{\theta(B)}{\phi(B)}$. Secara umum dalam data *time series* dapat mengandung beberapa *outlier* dengan tipe yang berbeda-beda. Wei (2006) menuliskan model *outlier*nya secara umum sebagai berikut :

$$Y_t = \sum_{h=1}^{H} \omega_h v_h(B) I_t^{(T_h)} + u_t, \tag{2.62}$$

dengan

$u_t = \frac{\theta(B)}{\phi(B)} a_t$, $I_t^{(T)}$ adalah variabel *outlier* pada waktu ke-T

$$v_h(B) = \begin{cases} 1 & \text{, untuk AO} \\ \frac{\theta(B)}{\phi(B)} & \text{, untuk IO.} \end{cases}$$

2.6.3. *Level Shift* (LS)

Level Shift merupakan kejadian yang mempengaruhi deret pada satu waktu tertentu dan memberikan efek suatu perubahan yang tiba-tiba dan permanen. Model *Level Shift* pada data runtun waktu dapat dinyatakan dengan (Wei, 2006) :

$$Y_t = u_t + \frac{1}{(1-B)}\omega_L I_t^{(T)}. \tag{2.63}$$

2.6.4. *Temporary Change* (TC)

Temporary Change adalah suatu kejadian dimana *outlier* menghasilkan efek awal pada waktu ke-*t* sebesar ω_c dan kemudian efek tersebut berkurang secara perlahan sesuai dengan besarnya δ. Model TC dinyatakan dengan:

$$Y_t = u_t + \frac{1}{(1-\delta B)}\omega_c I_t^{(T)} \tag{2.64}$$

dengan $|\delta| < 1$. Pada saat δ = 0 maka TC akan menjadi kasus AO sedangkan pada saat δ = 1 maka TC akan menjadi LS.

2.7. Model *Time Series* Multivariat

Dalam model *time series* univariat, analisis yang dilakukan hanya melibatkan satu variabel, sedangkan seringkali dalam kenyataannya ditemukan data *time series* yang saling berhubungan antara variabel yang satu dengan variabel lainnya. Analisis *time series* yang melibatkan keterkaitan beberapa variabel dikenal dengan model *time series* multivariat. Secara umum model *time series* multivariat digunakan untuk melakukan pemodelan dan menjelaskan adanya interaksi serta pergerakan dari sejumlah variabel *time series* yang memiliki keterkaitan pada waktu sebelumnya untuk mendapatkan keakuratan pemodelan atau peramalan.

Pada dasarnya proses dalam pemodelan *time series* multivariat sama dengan pemodelan *time series* univariat, salah satunya adalah memperhatikan stasioneritas data dalam rata-rata *(mean)* dan varians. Data multivariat data tidak stasioner dalam *mean*, maka akan dilakukan *differencing* sedangkan data yang tidak stasioner dalam varians akan dilakukan transformasi. Stationeritas data bisa ditunjukkan melalui plot *Matrix Cross Correlation Function* (MCCF) dan *Matrix Partial Cross Correlation Function* (MPCCF) serta Box-Cox (Wei, 2006).

2.7.1. *Matrix Cross Correlation Function* (MCCF)

Jika terdapat sebuah vektor time series dengan pengamatan sebanyak *n*, yaitu $\boldsymbol{Y}_1, \boldsymbol{Y}_2, \ldots, \boldsymbol{Y}_n$, maka persamaan MCCF dinyatakan dalam bentuk sebagai berikut (Wei, 2006) :

$$\hat{\boldsymbol{\rho}}(k) = [\hat{\rho}_{ij}(k)] \tag{2.65}$$

dengan $\hat{\rho}_{ij}(k)$ merupakan korelasi silang untuk komponen *series* ke-*i* dan ke-*j* yang dinyatakan dalam bentuk :

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k}(Y_{i,t} - \bar{Y}_i)(Y_{j,t+k} - \bar{Y}_j)}{\left[\sum_{t=1}^{n}(Y_{i,t} - \bar{Y}_i)^2 \sum_{t=1}^{n}(Y_{j,t} - \bar{Y}_j)^2\right]^{1/2}} \tag{2.66}$$

dengan $\bar{Y}_i$ dan $\bar{Y}_j$ merupakan rata-rata sampel komponen series yang bersesuaian.

Persamaan matriks korelasi sampel berfungsi untuk menentukan orde dalam model *Moving Average* (MA). Namun demikian bentuk matriks dan grafik akan semakin kompleks seiring dengan meningkatnya dimensi vektor. Tiao dan Box (1981) dalam Wei (2006) merumuskan sebuah metode yang sesuai untuk bisa meringkas penjelasan korelasi sampel, yaitu dengan menggunakan simbol (+), (-), dan (·) pada posisi baris ke-*i* dan kolom ke-*j* dari matriks korelasi sampel, yaitu :

1. Simbol (+) menotasikan nilai $\hat{\rho}_{ij}(k)$ yang lebih besar dari 2 kali estimasi standar *error* ($\hat{\boldsymbol{\rho}}(k)$) dan menunjukkan adanya hubungan korelasi positif.
2. Simbol (-) menotasikan nilai $\hat{\rho}_{ij}(k)$ yang kurang dari -2 kali estimasi standar *error* ($\hat{\boldsymbol{\rho}}(k)$) dan menunjukkan adanya hubungan korelasi negatif.

3. Simbol (.) menotasikan nilai $\hat{\rho}_{ij}(k)$ yang berada di antara ± 2 kali estimasi standar *error* $(\hat{\boldsymbol{\rho}}(k))$ yang artinya tidak terdapat hubungan korelasi.

2.7.2. *Matrix Partial Cross Correlation Function* (MPCCF)

Pada analisis *time series* univariat, fungsi autokorelasi parsial (PACF) digunakan untuk menentukan orde *p* dalam model *autoregressive* (AR*(p)*). Generalisasi dari konsep PACF ke dalam bentuk vector *time series* dilakukan oleh Tiao dan Box (1981) dalam Wei (2006), yang didefinisikan sebagai sebuah matriks autoregresi parsial pada *lag s* dengan notasi $\boldsymbol{\mathcal{P}}(s)$, sebagai koefisien matriks terakhir ketika data diterapkan ke dalam suatu proses *vector autoregressive* (VAR) dari orde s. $\boldsymbol{\mathcal{P}}(s)$ sama dengan $\Phi_{s,s}$ dalam regresi linier multivariat, sehingga persamaan untuk matriks autoregresi parsial dinyatakan dalam bentuk (Wei, 2006) :

$$\boldsymbol{\mathcal{P}}(s) = \begin{cases} \Gamma'(1)[\Gamma(1)]^{-1}, & s = 1 \\ \{\Gamma'(s) - \boldsymbol{c}'(s)[\boldsymbol{A}(s)]^{-1}\boldsymbol{b}(s)\}\{\Gamma'(0) - \boldsymbol{b}'(s)[A(s)]^{-1}\boldsymbol{b}(s)\}, & s > 1 \end{cases} \tag{2.67}$$

Untuk s ≥ 2, maka nilai *A(s), b(s),* dan *c(s)*

$$\boldsymbol{A}(s) = \begin{bmatrix} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \cdots & \Gamma'(s-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \cdots & \Gamma(0) \end{bmatrix}$$

$$\boldsymbol{b}(s) = \begin{bmatrix} \Gamma'(s-1) \\ \Gamma'(s-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix}, \quad \boldsymbol{c}(s) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix}. \tag{2.68}$$

Jika model dari data merupakan vector AR*(p)*, maka

$$\boldsymbol{\mathcal{P}}(s) = \begin{cases} \Phi_p, & s = p \\ 0, & s > p \end{cases} \tag{2.69}$$

sama halnya dengan persamaan autokorelasi parsial pada kasus data univariat, persamaan matriks parsial autoregresi, $\boldsymbol{\mathcal{P}}(s)$ juga memiliki sifat *cut-off* untuk proses *vector* AR.

Sebagaimana dalam MCCF, Tiao dan Box (1981) dalam Wei (2006) juga mengidentifikasi data berdasarkan nilai MPCCF dengan menotasikan nilai-nilai MPCCF dalam bentuk simbol (+), (-), dan (·). Tanda (+) untuk nilai lebih besar dari 2 kali estimasi standar *error* $(\widehat{\Phi}_p(k))$, tanda (-) untuk nilai kurang dari -2 kali estimasi standar *error* $(\widehat{\Phi}_p(k))$ dan tanda (.) untuk nilai antara ± 2 kali estimasi standar *error* $(\widehat{\Phi}_p(k))$.

2.7.3. *Akaike's Information Criterion* (AIC)

Dalam analisis *time series*, salah satu kriteria yang digunakan untuk menentukan model terbaik adalah menggunakan *Akaike's Information Criterion* (AIC) yang diperkenalkan oleh Akaike (1973) dalam Wei (2006) dengan mempertimbangkan banyaknya parameter. Kriteria AIC dalam pemilihan model terbaik adalah yang mempunyai nilai terkecil (minimum) diantara model yang ada. Rumus AIC yang digunakan adalah sebagai berikut :

$$AIC(p) = \ln(|\boldsymbol{S}(p)|) + \frac{2pm^2}{n}, \tag{2.70}$$

dengan p adalah orde dari proses VAR $(p = 1,2,\dots,p_0)$ dimana p_0 merupakan bilaangan bulat positif, n adalah banyaknya observasi, m adalah banyaknya variabel, dan $|\boldsymbol{S}(p)|$ merupakan determinan dari *residual sum of square* dan perkalian silangnya, yaitu :

$$\boldsymbol{S}_p = \sum_{t=p+1}^{n} (\boldsymbol{Y}_t - \hat{\boldsymbol{\tau}} - \widehat{\boldsymbol{\Phi}}_1\boldsymbol{Y}_{t-1} - \cdots - \widehat{\boldsymbol{\Phi}}_p\boldsymbol{Y}_{t-p}) \\ (\boldsymbol{Y}_t - \hat{\boldsymbol{\tau}} - \widehat{\boldsymbol{\Phi}}_1\boldsymbol{Y}_{t-1} - \cdots - \widehat{\boldsymbol{\Phi}}_p\boldsymbol{Y}_{t-p})' \tag{2.71}$$

dengan $\hat{\boldsymbol{\tau}}$ adalah vector konstan (Wei, 2006).

2.8. Model *Generalized Space Time Autoregressive* (GSTAR)

Model GSTAR sebagai *generalisasi* model STAR merupakan suatu model yang cenderung lebih fleksibel. Model STAR merupakan model yang dikategorikan berdasar *lag* yang berpengaruh secara linier baik dalam lokasi dan waktu (Pfeifer dan Deutsch, 1980a), Model *Generalized* STAR atau biasa disebut GSTAR merupakan spesifikasi dari model VAR.

Jika diberikan $Y_i(t)$ dengan $t = \{1,2,\dots,T\}$ dan $i = \{1,2,\dots,N\}$ merupakan indeks parameter waktu dan lokasi yang terhitung dan terbatas, maka model *Space Time Autoregressive Moving Average* (STARMA) dari Pfeifer dan Deustch (1980a) adalah :

$$\boldsymbol{Y}(t) = \sum_{k=1}^{p}\sum_{l=0}^{\lambda_k} \boldsymbol{\phi}_{kl}\boldsymbol{W}^{(l)}\boldsymbol{Y}(t-k) + \boldsymbol{\varepsilon}(t) - \sum_{k=1}^{q}\sum_{l=0}^{m_k} \boldsymbol{\theta}_{kl}\boldsymbol{W}^{(l)}\boldsymbol{\varepsilon}(t-k) \tag{2.72}$$

dengan

$\boldsymbol{\phi}_{kl}$ = parameter *autoregressive* pada lag waktu *k* dan lag spasial *l*

$\boldsymbol{\theta}_{kl}$ = parameter *moving average* pada lag waktu *k* dan lag spasial *l*

$\boldsymbol{W}^{(l)}$ = matriks bobot yang dipengaruhi oleh lokasi

$\boldsymbol{\varepsilon}(t)$ = *vector noise*/komponen *error*.

Dalam hal ini Pfeifer dan Deutsch memodelkan observasi dilokasi *i* pada saat *t* dengan kombinasi linear dari lokasi tersebut pada saat sebelumnya dan *residual* pada saat sebelumnya. Apabila orde *p* = 0, maka model (2.72) menjadi *Space Time Moving Average* (STMA) dan jika orde *q* = 0 menjadi model *Space Time Autoregressive* (STAR).

Model STAR orde (p_1), yang berarti orde spasial adalah 1 dan orde waktu adalah *p*, atau ditulis STAR (p_1) dari Pfeifer dan Deutsch (1980a) dirumuskan sebagai berikut :

$$\boldsymbol{Y}(t) = \sum_{k=1}^{p}[\boldsymbol{\Phi}_{k0}\boldsymbol{W}^{(0)}\boldsymbol{Y}(t-k) + \boldsymbol{\Phi}_{k1}\boldsymbol{W}^{(1)}\boldsymbol{Y}(t-k)] + \boldsymbol{\varepsilon}(t) \tag{2.73}$$

dengan

$\boldsymbol{\Phi}_{k1}$ = parameter STAR pada *lag* waktu (time) *k* dan *lag* spasial 1

$\boldsymbol{W}^{(l)}$ = matriks bobot ukuran ($N \times N$) pada *lag* spasial (dengan l = 0,1), dengan $\boldsymbol{W}^{(0)}$ adalah matriks identitas ukuran ($N \times N$)

$\boldsymbol{\varepsilon}(t)$ = *vector noise*/ukuran ($N \times 1$) berdistribusi normal multivariat dengan *mean* nol dan matriks varians-kovarians $\sigma^2 I_N$

$\boldsymbol{Y}(t)$ = *vector* acak ukuran ($N \times 1$) pada waktu *t*, yaitu $\boldsymbol{Y}(t) = [\boldsymbol{Y}_{\mathbf{1}}(t), \dots, \boldsymbol{Y}_N(t)]'$.

Model STAR (1_1) dengan lokasi sebanyak N dapat dinyatakan sebagai berikut :

$$\boldsymbol{Y}(t) = \phi_{10}\boldsymbol{I}_N\boldsymbol{Y}(t-1) + \phi_{11}\boldsymbol{I}_N\boldsymbol{W}^{(1)}\boldsymbol{Y}(t-1) + \boldsymbol{\varepsilon}(t) \tag{2.74}$$

Dari model (2.74), untuk sebanyak 3 (tiga) lokasi dapat dinyatakan sebagai berikut :

$$Y_1(t) = \phi_{10}Y_1(t-1) + \phi_{11}w_{12}Y_2(t-1) + \phi_{11}w_{13}Y_3(t-1) + \varepsilon_1(t)$$
$$Y_2(t) = \phi_{10}Y_2(t-1) + \phi_{11}w_{21}Y_1(t-1) + \phi_{11}w_{23}Y_3(t-1) + \varepsilon_2(t)$$
$$Y_3(t) = \phi_{10}Y_3(t-1) + \phi_{11}w_{31}Y_1(t-1) + \phi_{11}w_{32}Y_2(t-1) + \varepsilon_3(t)$$

Dengan menggunakan notasi matriks untuk tiga lokasi yang berbeda dapat dinyatakan sebagai berikut :

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} = \begin{bmatrix} \phi_{10} & 0 & 0 \\ 0 & \phi_{10} & 0 \\ 0 & 0 & \phi_{10} \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \begin{bmatrix} \phi_{11} & 0 & 0 \\ 0 & \phi_{11} & 0 \\ 0 & 0 & \phi_{11} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \begin{bmatrix} \varepsilon_1(t) \\ \varepsilon_2(t) \\ \varepsilon_3(t) \end{bmatrix} \tag{2.75}$$

Kelemahan model STAR adalah pada asumsi parameter autoregresi yaitu bahwa semua lokasi mempunyai parameter autoregresi yang sama, sehingga hanya sesuai digunakan pada lokasi yang homogen, cenderung tidak fleksibel atau kurang sesuai diterapkan pada lokasi yang heterogen. Untuk mengatasi kelemahan tersebut Ruchjana (2002) mengembangkan model GSTAR. Model GSTAR mengasumsikan bahwa parameter setiap lokasi diperbolehkan berbeda, sehingga model GSTAR sesuai digunakan pada lokasi-lokasi penelitian yang bersifat heterogen.

Jika diketahui data *time series* $\{Y(t): t = 0,1,2,\dots; i = 1,2,\dots,N\}$ merupakan sebuah *time series* multivariat dari *N* pengamatan, maka model

GSTAR dengan orde waktu AR(p) dan spasial $(\lambda_1, \lambda_2, \dots, \lambda_p)$ ditulis GSTAR $(p, \lambda_1, \lambda_2, \dots, \lambda_p)$ dapat dinyatakan sebagai berikut (Ruchjana, 2002).

$$\boldsymbol{Y}(t) = \sum_{k=1}^{p} [\boldsymbol{\Phi}_{k0}\boldsymbol{Y}(t-k) + \sum_{l=1}^{\lambda_p} \boldsymbol{\Phi}_{kl}\boldsymbol{W}^{(l)}\boldsymbol{Y}(t-k)] + \boldsymbol{\varepsilon}(t) \quad (2.76)$$

dengan

$\boldsymbol{Y}(t)$ = vektor acak ukuran (*Nx1*) pada waktu *t*, yaitu $\boldsymbol{Y}(t) = [\boldsymbol{Y_1}(t), \dots, \boldsymbol{Y}_N(t)]'$

$\boldsymbol{\Phi}_{k0}$ = $diag(\phi_{k0}^{(1)}, \dots, \phi_{kN}^{(N)})$ merupakan matriks koefisien parameter waktu

$\boldsymbol{\Phi}_{kl}$ = $diag(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(N)})$ merupakan matriks koefisien parameter spasial

$\boldsymbol{W}^{(l)}$ = nilai matriks pembobot ukuran $(N \times N)$ pada *lag* spasial ke-*l*, nilai pembobot yang dipilih harus memenuhi syarat $w_{ii}^{(l)} = 0$ dan $\sum_{i \neq j}^{(l)} w_{ij}^{(l)} = 1$

$\boldsymbol{\varepsilon}(t)$ = vektor *error* yang memenuhi asumsi identic, independen, dan berdistribusi normal multivariat dengan *mean* nol dan matriks varians-kovarians $\sigma^2 I_N$.

Sebagai contoh secara umum model GSTAR pada persamaan (2.76) dengan orde waktu 1 dan orde spasial 1 pada lokasi yang berbeda atau GSTAR (1_1) dapat ditulis sebagai berikut :

$$\boldsymbol{Y}(t) = \boldsymbol{\Phi}_{10}\boldsymbol{Y}(t-1) + \boldsymbol{\Phi}_{11}\boldsymbol{W}\boldsymbol{Y}(t-1) + \boldsymbol{\varepsilon}(t). \quad (2.77)$$

Dari persamaan (2.77), model untuk tiga lokasi yang berbeda dapat dinyatakan sebagai berikut :

$$Y_1(t) = \phi_{10}Y_1(t-1) + \phi_{11}w_{12}Y_2(t-1) + \phi_{11}w_{13}Y_3(t-1) + \varepsilon_1(t)$$
$$Y_2(t) = \phi_{20}Y_2(t-1) + \phi_{21}w_{21}Y_1(t-1) + \phi_{21}w_{23}Y_3(t-1) + \varepsilon_2(t)$$
$$Y_3(t) = \phi_{30}Y_3(t-1) + \phi_{31}w_{31}Y_1(t-1) + \phi_{31}w_{32}Y_2(t-1) + \varepsilon_3(t)$$

Persamaan (2.77) dapat ditulis menggunakan notasi matriks untuk tiga lokasi yang berbeda seperti pada persamaan (2.78) di bawah ini.

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} = \begin{bmatrix} \phi_{10} & 0 & 0 \\ 0 & \phi_{20} & 0 \\ 0 & 0 & \phi_{30} \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \begin{bmatrix} \phi_{11} & 0 & 0 \\ 0 & \phi_{21} & 0 \\ 0 & 0 & \phi_{31} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-1) \\ Y_2(t-1) \\ Y_3(t-1) \end{bmatrix} + \begin{bmatrix} \varepsilon_1(t) \\ \varepsilon_2(t) \\ \varepsilon_3(t) \end{bmatrix} \quad (2.78)$$

2.8.1. Identifikasi Model pada Model (GSTAR)

2.8.1.1. Orde Spasial

Karakter model spasial ditandai oleh adanya ketergantungan linier pada lokasi. Tingkat perubahan ketergantungan lokasi dinamakan orde spasial dilambangkan dengan l, dengan l = 1,2, …, λ. Orde spasial merupakan urutan berdasarkan jarak dari suatu lokasi tertentu ke semua lokasi yang ada disekitarnya.

Orde pertama adalah lokasi yang paling dekat dengan lokasi yang sedang diteliti, orde kedua adalah lokasi yang lebih jauh dari orde yang pertama dan lebih dekat dibanding dengan orde ketiga (Pfeifer and Deutsch, 1980a). Orde spasial pada sistem yang teratur digambarkan sebagai perubahan posisi suatu lokasi tertentu digeser ke lokasi terdekat disekitarnya dengan jarak yang sama. Pada sistem yang teratur, orde spasial adalah sistem *lattice* berupa grid bujur sangkar atau lingkaran dengan diameter tertentu.

Pada sistem dua dimensi pergeseran lokasi dapat ke arah kanan atau kiri (barat-timur) dan ke arah atas atau bawah (utara-selatan). Suatu kriteria yang biasa dipakai dalam sistem grid adalah pergeseran lokasi dilakukan hanya satu kali ke lokasi terdekat dengan jarak yang sama untuk setiap orde spasial. Selain itu dapat dipilih jarak minimum yang dicapai dari suatu lokasi tertentu ke lokasi terdekat disekitarnya (Ruchjana, 2002). Sebagai gambaran diberikan contoh orde spasial pada sistem satu dimensi dan dua dimensi seperti ditunjukkan pada Gambar 2.2 (Pfeifer dan Deutsch, 1980a).

Pada saat orde spasial l = 0 menyatakan bahwa suatu lokasi tidak mempunyai tetangga, melainkan lokasinya sendiri. Pada saat orde spasial l = 1 paling sedikit terdapat 4 tetangga yaitu 2 tetangga kanan-kiri dan 2 tetangga atas-bawah. Semua perbedaan posisi atau jarak suatu lokasi dengan lokasi yang lainnya pada saat orde spasial 1 dijadikan satu dan diberikan suatu bobot tertentu dan begitu pula untuk orde spasial yang lebih tinggi.

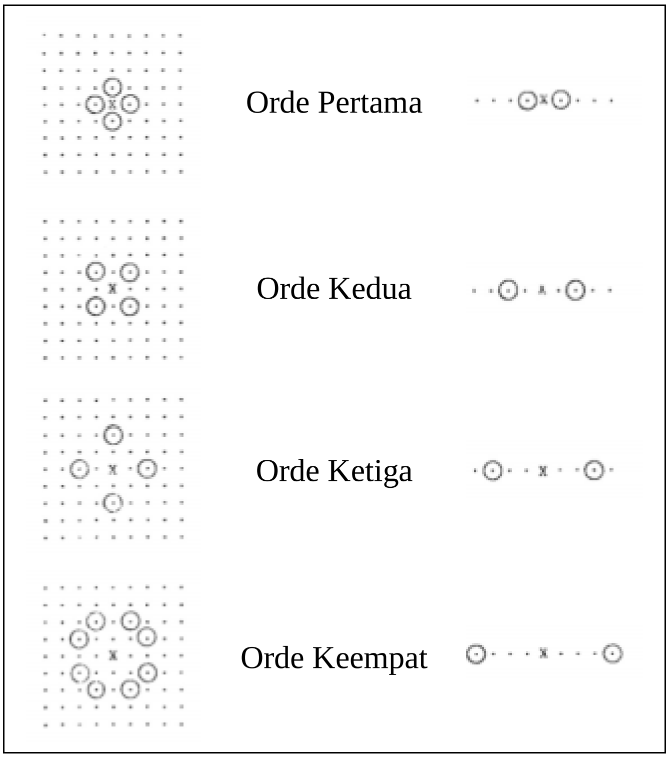

Gambar 2.2. Orde Spasial Pada Satu dan Dua Dimensi

Secara umum jika $y_i(t)$ adalah suatu pengamatan pada lokasi ke-i dengan $i = 1,2,\dots,N$ dan tetangga terdekatnya pada lokasi ke-j dengan $j = 1,2,\dots,N$ serta misalnya $L^{(1)}$ menyatakan operator orde spasial l, maka orde spasial l dapat didefinisikan dengan (Ruchjana, 2002) :

$$L^{(0)}y_i(t) = y_i(t) \; untuk \; l = 0$$

$$L^{(1)}y_i(t) = \sum_{j=1}^{N} w_{ij}^{(l)} \, y_i(t) untuk \; l \neq 0 \tag{2.79}$$

dimana $w_{ij}^{(l)}$ adalah suatu bobot tertentu yang menyatakan perbedaan posisi lokasi yang terdekat dari lokasi asal pada orde spasial l. Identifikasi orde spasial model GSTAR pada umumnya dibatasi pada orde satu karena orde yang lebih tinggi akan sulit untuk dilakukan interpretasi (Wutsqa *et al.*, 2010). Oleh karena itu, operator orde spasial 1 dalam penelitian ini dinyatakan dengan formula (Ruchjana, 2002) :

$$Ly_i(t) = \sum_{j=1}^{N} w_{ij} \, y_i(t). \tag{2.80}$$

Sifat-sifat bobot adalah $w_{ij} > 0$, jika lokasi ke-i dan lokasi ke-j berada dalam orde spasial 1 maka $w_{ij} \neq 0$, jika lokasi ke-i dan lokasi ke-j tidak berada dalam orde spasial 1 maka $w_{ij} = 0$, jumlah bobot untuk setiap lokasi i adalah $\sum_{j=1}^{N} w_{ij}^{(l)} = 1$ dan jumlah bobot untuk semua lokasi adalah $\sum_{i=1}^{N} \sum_{j=1}^{N} w_{ij}^{(l)} = N$.

Jika $y(t)$ menyatakan vektor kolom ukuran $(N \times 1)$ dari pengamatan $y_i(t)$ dengan $1 = 1,2,\dots,N$, maka operator orde spasial dinyatakan :

$$L^{(0)} y_i(t) = \boldsymbol{W}^{(0)} y(t) = \boldsymbol{I}_N y(t), \text{ untuk } l = 0$$
$$L^{(1)} y_i(t) = \boldsymbol{W}^{(1)} y(t), \text{ untuk } l \neq 0. \tag{2.81}$$

Untuk menyederhanakan penulisan, operator orde spasial 1 dalam bentuk vektor cukup dinyatakan dengan :

$$Ly(t) = \boldsymbol{W} y(t). \tag{2.82}$$

Selanjutnya dalam bentuk matriks, bobot w_{ij} pada orde spasial 1 dinyatakan oleh $\boldsymbol{W}$ berupa matriks bujursangkar $(N \times N)$ sebagai berikut :

$$\boldsymbol{W} = \begin{bmatrix} 0 & w_{12} & \cdots & w_{1N} \\ w_{21} & 0 & \cdots & w_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w_{N1} & w_{N2} & \cdots & 0 \end{bmatrix}.$$

2.8.1.2. Orde Waktu

Identifikasi orde waktu pada model GSTAR tidak berbeda dengan model VARMA. Penentuan orde waktu dapat dilakukan dengan menggunakan nilai AIC yang minimum (Wei, 2006). Akan tetapi penentuan orde model berdasarkan nilai AIC tidak dapat menangkap pola seasonal, oleh karena itu penentuan orde waktu dapat dilakukan berdasarkan plot MCCF dan MPCCF yang terbentuk (Wutsqa dan Suhartono, 2010).

2.8.2. Pemilihan Bobot Lokasi pada Model GSTAR

Dalam memilih atau menentukan bobot lokasi merupakan salah satu permasalahan dalam pemodelan GSTAR karena harus dipilih bobot lokasi yang sesuai untuk diterapkan pada data *time series* yang dianalisis. Suhartono dan Atok (2006) memberikan beberapa alternatif cara pembobotan dalam model GSTAR. Metode yang dapat digunakan untuk menentukan bobot antara lain bobot seragam, biner, invers jarak, normalisasi korelasi silang, dan normalisasi inferensia parsial korelasi silang.

2.8.2.1. Bobot Seragam

Bobot lokasi seragam memberikan nilai bobot yang sama untuk masing-masing lokasi. Oleh karena itu, bobot lokasi ini seringkali digunakan pada data yang lokasinya homogen atau mempunyai jarak antar lokasi yang sama. Nilai dari bobot lokasi seragam dihitung dengan formulasi $w_{ij} = \frac{1}{n_i}$ dengan n_i adalah jumlah lokasi yang berdekatan dengan lokasi ke-*i*. Contoh matriks bobot untuk tiga lokasi yang berbeda dapat ditulis dengan :

$$\boldsymbol{W} = \begin{bmatrix} 0 & 1/2 & 1/2 \\ 1/2 & 0 & 1/2 \\ 1/2 & 1/2 & 0 \end{bmatrix}.$$

2.8.2.2. Bobot Biner *(Binary)*

Nilai bobot lokasi biner didefinisikan berdasarkan hubungan letak suatu lokasi dengan lokasi lainnya. Hubungan antara dua kota yang secara geografis berdekatan didefinisikan $w_{ij} = 1$. Sedangkan jika secara geografis berjauhan, maka didefinisikan $w_{ij} = 0$. Nilai dari bobot biner adalah 0 dan 1. Nilai tersebut dipakai tergantung pada suatu batasan tertentu.

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

2.8.2.3. Bobot *Invers* Jarak

Penentuan bobot *invers* jarak dilakukan berdasarkan jarak sebenarnya antar lokasi di lapangan. Penghitungan bobot dengan metode *invers* jarak diperoleh dari normalisasi hasil invers jarak sebenarnya. Pada contoh dengan tiga lokasi dimisalkan diketahui jarak antar lokasi seperti terlihat pada Tabel 2.3.

Tabel 2.3. Contoh Jarak dari Tiga Lokasi

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

Bentuk matrik jarak yang terbentuk adalah :

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

Kemudian matriks $\boldsymbol{D}$ tersebut distandarkan dalam bentuk $\boldsymbol{W}$ 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 :

$$w_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_{j=1}^{N} \frac{1}{d_{ij}}}, j \neq i. \tag{2.83}$$

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 w_{ij} adalah nol, karena untuk suatu lokasi dianggap tidak ada jarak dengan dirinya sendiri. Sehingga bentuk matriks invers jarak yang terbentuk adalah :

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

Contoh penghitungan bobot invers jarak berdasarkan ilustrasi jarak lokasi tiga kota adalah sebagai berikut:

$$w_{AB} = \frac{\frac{1}{d_{AB}}}{\frac{1}{d_{AB}}+\frac{1}{d_{AC}}} = \frac{1}{1+\frac{1}{2}} = \frac{2}{3} \qquad w_{AC} = \frac{\frac{1}{d_{AC}}}{\frac{1}{d_{AB}}+\frac{1}{d_{AC}}} = \frac{\frac{1}{2}}{1+\frac{1}{2}} = \frac{1}{3}.$$

Dengan cara yang sama akan diperoleh

$$w_{BA} = \frac{3}{4}, w_{BC} = \frac{1}{4}, w_{CA} = \frac{3}{5}, w_{CB} = \frac{2}{5},$$

sehingga matriks pembobot yang diperoleh dengan metode invers jarak menjadi :

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

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

2.8.2.4. Bobot Normalisasi Korelasi Silang

Penentuan nilai bobot normalisasi korelasi silang dilakukan dengan menggunakan hasil normalisasi korelasi silang antar lokasi pada lag yang bersesuaian. Suhartono dan Atok (2006) memperkenalkan penggunaan bobot ini, kemudian dikembangkan oleh Suhartono dan Subanar (2006) dengan menggunakan inferensia statistik terhadap korelasi silang untuk penentuan bobot lokasinya. Secara umum korelasi silang antara lokasi ke-*i* dan ke-*j* pada lag waktu ke-k, corr $[Y_i(t), Y_j(t-k)]$, dapat dinyatakan sebagai berikut (Box, Jenkins, dan Reinsel, 2008) :

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j}, k = 0, +1, +2, \ldots \tag{2.84}$$

dengan $\gamma_{ij}(k)$ merupakan kovarians antara pengamatan di lokasi ke-i dank ke-j, σ_i dan σ_j merupakan standar deviasi antara pengamatan di lokasi ke-i dank ke-j. Taksiran dari korelasi silang pada sampel dapat dinyatakan dalam bentuk

$$r_{ij}(k) = \frac{\sum_{t=k+1}^{n}[Y_i(t) - \bar{Y}_i][Y_j(t-k) - \bar{Y}_j]}{\sqrt{(\sum_{t=k+1}^{n}[Y_i(t) - \bar{Y}_i]^2)(\sum_{t=k+1}^{n}\left[Y_j(t) - \bar{Y}_j\right]^2)}} \tag{2.85}$$

Proses ini secara umum menghasilkan bobot lokasi untuk model GSTAR (1_1) seperti pada persamaan (2.86)

$$w_{ij} = \frac{r_{ij}(1)}{\sum_{k\neq 1}|r_{ij}(1)|}, \text{dengan } j \neq i \text{ dan} \sum_{k\neq 1}\left|w_{ij}\right| = 1 \tag{2.86}$$

2.8.2.5. 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 dank ke-j pada lag waktu ke-k, corr $[Y_i(t), Y_j(t-k)]$, didefinisikan seperti persamaan (2.84). Estimasi dari persamaan korelasi silang data sampel dapat dilihat pada persamaan (2.85). 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

$$Varians\left[r_{ij}(k)\right] \cong \frac{1}{n-k}\left[1 + 2\sum_{s=1}^{\infty}\rho_{ii}(s)\rho_{jj}(s)\right]. \tag{2.87}$$

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

$$Varians\left[r_{ij}(k)\right] \cong \frac{1}{n-k}. \tag{2.88}$$

Untuk ukuran sampel yang besar, (n – k) dalam persamaan (2.88) 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

$$r_{ij}(k) \pm \left[t_{(\frac{\alpha}{2};(n-k-2)}\frac{1}{\sqrt{n}}\right]. \tag{2.89}$$

Dalam proses ini dihasilkan bobot lokasi dengan menggunakan normalisasi dari hasil inferensia 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).

2.8.3. Estimasi Parameter pada Model GSTAR

Estimasi parameter yang digunakan dalam model GSTAR terdiri dari metode estimasi *Ordinary Least Square* (OLS) dan metode estimasi *Generalized Least Square* (GLS).

2.8.3.1. Metode Estimasi *Ordinary Least Square* (OLS)

Pendugaan parameter model GSTAR dengan metode OLS dilakukan dengan meminimumkan jumlah kuadrat *errornya* (Ruchjana, *et al*., 2012). Dengan mengambil orde autoregresi, $p = 1$ dan orde spasial $\lambda_p = 1$ maka persamaan model GSTAR(1_1) juga dapat dinyatakan sebagai berikut :

$$\boldsymbol{Y}(t) = \boldsymbol{\Phi}_{10}\boldsymbol{Y}(t-1) + \boldsymbol{\Phi}_{11}\boldsymbol{W}^{(1)}\boldsymbol{Y}(t-1) + \boldsymbol{\varepsilon}(t), \tag{2.90}$$

dengan $\boldsymbol{\Phi}_{10}$ merupakan parameter autoregresi untuk keterkaitan waktu, dan $\boldsymbol{\Phi}_{11}$ merupakan parameter regresi spasial, dan $\boldsymbol{W}$ merupakan matriks pembobot.

Metode *least square* sering digunakan untuk melakukan pendugaan parameter pada model linier, sehingga metode ini dapat diterapkan pada model GSTAR(1_1) yang dapat ditulis dalam bentuk linier sebagai berikut :

$$\boldsymbol{Y} = \boldsymbol{X\beta} + \boldsymbol{e}. \tag{2.91}$$

Persamaan tersebut jika dijabarkan dalam bentuk matriks akan menjadi

$$\boldsymbol{Y} = \begin{bmatrix} \boldsymbol{Y}_1 \\ \boldsymbol{Y}_2 \\ \vdots \\ \boldsymbol{Y}_N \end{bmatrix}, \boldsymbol{X} = \begin{bmatrix} \boldsymbol{X}_1 & \boldsymbol{0} & \dots & \boldsymbol{0} \\ \boldsymbol{0} & \boldsymbol{X}_1 & \dots & \boldsymbol{0} \\ \vdots & \vdots & \ddots & \vdots \\ \boldsymbol{0} & \boldsymbol{0} & \dots & \boldsymbol{X}_N \end{bmatrix}, \boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1 \\ \boldsymbol{\beta}_2 \\ \vdots \\ \boldsymbol{\beta}_N \end{bmatrix}, \boldsymbol{e} = \begin{bmatrix} \boldsymbol{e}_1 \\ \boldsymbol{e}_2 \\ \vdots \\ \boldsymbol{e}_N \end{bmatrix} \tag{2.92}$$

Persamaan (2.91) dapat dimodifikasi jika terdapat beberapa lokasi seperti pada model GSTAR, sehingga model pada persamaan (2.91) untuk lokasi ke-i dapat ditulis sebagai berikut:

$$\boldsymbol{Y}_i = \boldsymbol{X}_i\boldsymbol{\beta}_i + \boldsymbol{e}_i, \tag{2.93}$$

dengan $\boldsymbol{Y}_i(t)$ merupakan banyaknya pengamatan ke-t ($t = 0,1,\dots,T$) untuk lokasi ke-i ($i = 1,2,\dots,N$), dan $\boldsymbol{\beta}_i = (\phi_{i0}^1, \phi_{i1}^1)'$. Jika diketahu $\boldsymbol{V}_i(t) = \sum_{j\neq i} w_{ij} Y_j(t)$ maka persamaan (2.93) dapat dijabarkan dalam bentuk matriks sebagai berikut :

$$\boldsymbol{Y} = \begin{bmatrix} \boldsymbol{Y}_i(1) \\ \boldsymbol{Y}_i(2) \\ \vdots \\ \boldsymbol{Y}_i(T) \end{bmatrix}, \boldsymbol{X} = \begin{bmatrix} \boldsymbol{Y}_i(0) & \boldsymbol{V}_i(0) \\ \boldsymbol{Y}_i(1) & \boldsymbol{V}_i(1) \\ \vdots & \vdots \\ \boldsymbol{Y}_i(T-1) & \boldsymbol{V}_i(T-1) \end{bmatrix}, \boldsymbol{\beta} = \begin{bmatrix} \phi_{i0}^1 \\ \phi_{i1}^1 \end{bmatrix}, \boldsymbol{e} = \begin{bmatrix} \boldsymbol{e}_i(1) \\ \boldsymbol{e}_i(2) \\ \vdots \\ \boldsymbol{e}_i(T) \end{bmatrix}. \tag{2.94}$$

Persamaan (2.93) jika dituliskan dalam bentuk matriks adalah sebagai berikut :

$$\begin{bmatrix} \boldsymbol{Y}_i(1) \\ \boldsymbol{Y}_i(2) \\ \vdots \\ \boldsymbol{Y}_i(T) \end{bmatrix} = \begin{bmatrix} \boldsymbol{Y}_i(0) & \boldsymbol{V}_i(0) \\ \boldsymbol{Y}_i(1) & \boldsymbol{V}_i(1) \\ \vdots & \vdots \\ \boldsymbol{Y}_i(T-1) & \boldsymbol{V}_i(T-1) \end{bmatrix} \begin{bmatrix} \phi_{i0}^1 \\ \phi_{i1}^1 \end{bmatrix} + \begin{bmatrix} \boldsymbol{e}_i(1) \\ \boldsymbol{e}_i(2) \\ \vdots \\ \boldsymbol{e}_i(T) \end{bmatrix}. \tag{2.95}$$

Jika $\boldsymbol{\beta}_i = \phi_{10}^1, \phi_{11}^1, \phi_{20}^1, \phi_{21}^1, \dots, \phi_{N0}^1, \phi_{N1}^1$, penjabaran matriks yang lebih rinci seperti ditunjukkan pada persamaan (2.96) berikut :

$$\begin{bmatrix} Y_i(1) \\ Y_i(2) \\ \vdots \\ Y_i(T) \\ \vdots \\ Y_N(1) \\ Y_N(2) \\ \vdots \\ Y_N(T) \end{bmatrix} = \begin{bmatrix} Y_i(0) & V_i(0) & \cdots & 0 & 0 \\ Y_i(1) & V_i(1) & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ Y_i(T-1) & V_i(T-1) & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & Y_N(0) & V_N(0) \\ 0 & 0 & \cdots & Y_N(1) & V_N(1) \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & Y_N(T-1) & V_N(T-1) \end{bmatrix} \begin{bmatrix} \phi_{10} \\ \phi_{11} \\ \vdots \\ \phi_{N0} \\ \phi_{N1} \end{bmatrix} + \begin{bmatrix} e_1(1) \\ e_1(2) \\ \vdots \\ e_1(T) \\ \vdots \\ e_N(1) \\ e_N(2) \\ \vdots \\ e_N(T) \end{bmatrix}. \tag{2.96}$$

Estimator least square untuk $\boldsymbol{\beta}_i$ dapat dihitung secara terpisah pada masing-masing lokasi namun tetap bergantung pada nilai $\boldsymbol{Y}(t)$ di lokasi yang lain. Sebagai contoh struktur data untuk estimasi parameter model GSTAR(1_1) di tiga lokasi yang berbeda dapat dituliskan sebagai berikut:

$$Y_1(t) = \phi_{10}Y_1(t-1) + \phi_{11}w_{12}Y_2(t-1) + \phi_{11}w_{13}Y_3(t-1) + \varepsilon_1(t)$$
$$Y_2(t) = \phi_{10}Y_2(t-1) + \phi_{11}w_{21}Y_1(t-1) + \phi_{11}w_{23}Y_3(t-1) + \varepsilon_2(t)$$
$$Y_3(t) = \phi_{10}Y_3(t-1) + \phi_{11}w_{31}Y_1(t-1) + \phi_{11}w_{32}Y_2(t-1) + \varepsilon_3(t),$$

jika $\boldsymbol{V}_i(t) = \sum_{j\neq 1} w_{ij}\boldsymbol{Y}_i(t)$, maka model di atas dapat dibentuk dalam notasi matriks sebagai berikut :

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \end{bmatrix} = \begin{bmatrix} Y_1(t-1) & 0 & 0 & V_1(t-1) & 0 & 0 \\ 0 & Y_2(t-1) & 0 & 0 & V_2(t-1) & 0 \\ 0 & 0 & Y_3(t-1) & 0 & 0 & V_3(t-1) \end{bmatrix} \begin{bmatrix} \phi_{10} \\ \phi_{20} \\ \phi_{30} \\ \phi_{11} \\ \phi_{21} \\ \phi_{31} \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{bmatrix}. \tag{2.97}$$

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

$$\boldsymbol{e}'\boldsymbol{e} = (\boldsymbol{Y} - \boldsymbol{X\beta})'(\boldsymbol{Y} - \boldsymbol{X\beta}), \tag{2.98}$$

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

$$\hat{\boldsymbol{\beta}} = [\boldsymbol{X}'\boldsymbol{X}]^{-1}\boldsymbol{X}'\boldsymbol{Y}. \tag{2.99}$$

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

$$\begin{bmatrix} \phi_{i0} \\ \phi_{i1} \end{bmatrix} = [\boldsymbol{X}'\boldsymbol{X}]^{-1}\boldsymbol{X}'\boldsymbol{Y}_i. \tag{2.100}$$

2.8.3.2. Estimasi Parameter dengan *Generalisasi Least Square* (GLS)

Model *Seemingly Unrelated Regression* (SUR) merupakan suatu model sistem persamaan yang terdiri dari beberapa persamaan regresi dimana residualnya antar pengamatan dalam satu persamaan tidak berkorelasi, tetapi *residual* antara persamaan yang satu dengan yang lain saling berkorelasi. Informasi adanya *residual* yang berkorelasi antar persamaan dapat digunakan untuk memperbaiki estimasi parameter model. Jadi model SUR bisa digunakan untuk mengatasi adanya korelasi *residual* antar persamaan sehingga mendapatkan estimator. Model SUR diperkenalkan oleh Zellner (1962). Menurut Greene (2007), model SUR bisa diestimasi menggunakan metode *Generalized Least Squares* (GLS).

Model SUR dengan *N* persamaan dimana masing-masing persamaan terdiri dari *K* variabel prediktor dapat dinyatakan sebagai berikut :

$$\begin{aligned} Y_1 &= \beta_{10} + \beta_{11}X_{1,1} + \beta_{12}X_{1,2} + \cdots + \beta_{1K}X_{1,K} + e_1 \\ Y_2 &= \beta_{20} + \beta_{21}X_{2,1} + \beta_{22}X_{2,2} + \cdots + \beta_{2K}X_{2,K} + e_2 \\ &\vdots \qquad\qquad\qquad \vdots \qquad\qquad\qquad \vdots \\ Y_N &= \beta_{N0} + \beta_{N1}X_{N,1} + \beta_{N2}X_{N,2} + \cdots + \beta_{NK}X_{N,K} + e_N \end{aligned} \tag{2.101}$$

Dengan $i = 1,2 \ldots., N$, dimana *N* menyatakan banyaknya persamaan dalam sistem. Model SUR pada persamaan (2.101) dapat ditulis dalam bentuk matriks sebagai berikut :

$$\begin{bmatrix} \boldsymbol{Y}_1 \\ \boldsymbol{Y_2} \\ \vdots \\ \boldsymbol{Y}_N \end{bmatrix} = \begin{bmatrix} \boldsymbol{X}_1 & \mathbf{0} & \ldots & \mathbf{0} \\ \mathbf{0} & \boldsymbol{X}_1 & \ldots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \ldots & \boldsymbol{X}_N \end{bmatrix} \begin{bmatrix} \boldsymbol{\beta}_1 \\ \boldsymbol{\beta_2} \\ \vdots \\ \boldsymbol{\beta}_N \end{bmatrix} + \begin{bmatrix} \boldsymbol{e}_1 \\ \boldsymbol{e_2} \\ \vdots \\ \boldsymbol{e}_N \end{bmatrix}. \tag{2.102}$$

Secara umum persamaan matriks (2.102) dapat ditulis pada persamaan (2.103)

$$\boldsymbol{Y}_i = \boldsymbol{X}_i\boldsymbol{\beta}_i + \boldsymbol{e}_i, \tag{2.103}$$

jika $t = 0,1, \ldots, T$ dengan *T* merupakan banyaknya pengamatan pada data *time series*, maka $\boldsymbol{Y}_i(t)$ merupakan vektor respon berukuran $(T \times 1)$, $\boldsymbol{X}_i$ merupakan matriks variabel independen berukuran $(T \times K)$. $\boldsymbol{\beta}_i$ merupakan vektor parameter berukuran $(K \times 1)$, dan $\boldsymbol{e}_i$ merupakan vektor residual berukuran $(T \times 1)$. Sehingga persamaan (2.102) dapat diuraikan sebagai beikut :

$$\begin{bmatrix} Y_{11} \\ Y_{12} \\ \vdots \\ Y_{1T} \\ Y_{21} \\ Y_{22} \\ \vdots \\ Y_{2T} \\ \vdots \\ Y_{N1} \\ Y_{N2} \\ \vdots \\ Y_{NT} \end{bmatrix} = \begin{bmatrix} \begin{bmatrix} 1 & x_{11,1} & \cdots & x_{11,K} \\ 1 & x_{12,1} & \cdots & x_{12,K} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{1T,1} & \cdots & x_{1T,K} \end{bmatrix} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \begin{bmatrix} 1 & x_{21,1} & \cdots & x_{21,K} \\ 1 & x_{22,1} & \cdots & x_{22,K} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{2T,1} & \cdots & x_{2T,K} \end{bmatrix} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \begin{bmatrix} 1 & x_{N1,1} & \cdots & x_{N1,K} \\ 1 & x_{N2,1} & \cdots & x_{N2,K} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{NT,1} & \cdots & x_{NT,K} \end{bmatrix} \end{bmatrix} \begin{bmatrix} \beta_{10} \\ \beta_{11} \\ \vdots \\ \beta_{1K} \\ \beta_{20} \\ \beta_{21} \\ \vdots \\ \beta_{2K} \\ \beta_{N0} \\ \beta_{N1} \\ \beta_{N2} \\ \vdots \\ \beta_{NK} \end{bmatrix} + \begin{bmatrix} e_{11} \\ e_{12} \\ \vdots \\ e_{1T} \\ e_{21} \\ e_{22} \\ \vdots \\ e_{2T} \\ \vdots \\ e_{N1} \\ e_{N2} \\ \vdots \\ e_{NT} \end{bmatrix} \tag{2.104}$$

Asumsi yang harus dipenuhi dalam persamaan model SUR $E(\varepsilon) = 0$ dan $E(\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}) = \boldsymbol{\sigma}_{ij}\boldsymbol{I}_T$ (Srivasta dan Dwivedi, 1979). Zellner (1962) mengasumsikan bahwa struktur matriks varians-kovarians pada sistem persamaan model SUR dapat dinyatakan :

$$E(\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}) = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_N \end{bmatrix} [e_1 \quad e_2 \quad \cdots \quad e_N] \tag{2.105}$$

Persamaan (2.105) dapat diuraikan menjadi :

$$E(\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}) = \begin{bmatrix} E(e_1e_1) & E(e_1e_2) & \cdots & E(e_1e_N) \\ E(e_2e_1) & E(e_2e_2) & \cdots & E(e_2e_N) \\ \vdots & \vdots & \ddots & \vdots \\ E(e_Ne_1) & E(e_Ne_2) & \cdots & E(e_Ne_N) \end{bmatrix} \tag{2.106}$$

karena $E(\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}) = \boldsymbol{\sigma}_{ij}\boldsymbol{I}_T$ sehingga dapat dituliskan

$$E(\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}) = \begin{bmatrix} \sigma_{11}\boldsymbol{I}_T & \sigma_{12}\boldsymbol{I}_T & \cdots & \sigma_{1N}\boldsymbol{I}_T \\ \sigma_{21}\boldsymbol{I}_T & \sigma_{22}\boldsymbol{I}_T & \cdots & \sigma_{2N}\boldsymbol{I}_T \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1}\boldsymbol{I}_T & \sigma_{N2}\boldsymbol{I}_T & \cdots & \sigma_{NN}\boldsymbol{I}_T \end{bmatrix}. \tag{2.107}$$

Persamaan (2.107) apabila diuraikan dengan perkalian Kronecker (⊗) menjadi

$$E(\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}) = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N2} & \cdots & \sigma_{NN} \end{bmatrix} \otimes \boldsymbol{I}_T$$

$$E(\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon}) = \boldsymbol{\Sigma} \otimes \boldsymbol{I}_T \qquad (2.108)$$
$$= \boldsymbol{\Omega}$$

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

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

Estimasi parameter model SUR dengan Metode GLS memerlukan invers dari matriks varian kovarian residual, dari persamaan (2.108) diperoleh :

$$\boldsymbol{\Omega} = \boldsymbol{\Sigma} \otimes \boldsymbol{I} \qquad (2.109)$$

menjadi

$$\boldsymbol{\Omega}^{-1} = \boldsymbol{\Sigma}^{-1} \otimes \boldsymbol{I} \qquad (2.110)$$

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

$$\widehat{\boldsymbol{\beta}} = (\boldsymbol{X}'\boldsymbol{\Omega}^{-1}\boldsymbol{X})^{-1}\boldsymbol{X}'\boldsymbol{\Omega}^{-1}\boldsymbol{Y} \qquad (2.111)$$

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

$$\widehat{\boldsymbol{\beta}} = (\boldsymbol{X}'(\boldsymbol{\Sigma} \otimes \boldsymbol{I})^{-1}\boldsymbol{X})^{-1}\boldsymbol{X}'(\boldsymbol{\Sigma} \otimes \boldsymbol{I})^{-1}\boldsymbol{Y} \text{ atau}$$

$$\widehat{\boldsymbol{\beta}} = (\boldsymbol{X}'\boldsymbol{\Sigma}^{-1} \otimes \boldsymbol{I}\boldsymbol{X})^{-1}\boldsymbol{X}'\boldsymbol{\Sigma}^{-1} \otimes \boldsymbol{I}\boldsymbol{Y}. \qquad (2.112)$$

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

Tahap 1 :

$$\boldsymbol{Y}_t = \boldsymbol{\omega}_0 \boldsymbol{X}_t + \boldsymbol{n}_t,$$

Tahap 2 :

$\boldsymbol{n}_t$ dimodelkan dengan GSTAR, mengikuti model bentuk umum GSTAR (dengan orde spasial 1) yaitu :

$$\boldsymbol{n}(t) = \sum_{k=1}^{p} [\boldsymbol{\Phi}_{k0}\boldsymbol{n}(t-k) + \boldsymbol{\Phi}_{k1}\boldsymbol{W}^{(1)}\boldsymbol{n}(t-k)] + \boldsymbol{\varepsilon}(t)$$

2.8.3.3. Regresi dengan Residual Berkorelasi

Pendugaan parameter dengan metode OLS pada analisis regresi menghasilkan *estimator* yang bersifat *unbiased* dan konsisten. Namun apabila terjadi *autocorrelation* pada residual 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 (2.101).
   b. Melakukan estimasi parameter pada model persamaan regresi dengan model OLS dari persamaan (2.101).
   c. Menghitung nilai residual $\hat{\varepsilon}_i$.
2. Tahapan kedua adalah sebagai berikut :
   a. Mengestimasi ϕ_j dan σ^2 dalam model AR(p) dengan memodelkan residual $\hat{\varepsilon}_i$ hasil penghitungan OLS berdasarkan model berikut :

$$\hat{\varepsilon}_{i,t} = \phi_1 \hat{\varepsilon}_{i,t-1} + \cdots + \phi_p \hat{\varepsilon}_{i,t-p} + n_t \qquad (2.113)$$

   b. Menghitung Ω berdasarkan ϕ_j dan σ^2 dari tahap (a).
   c. Menghitung estimasi GLS, $\hat{\boldsymbol{\beta}} = (\boldsymbol{X}'\boldsymbol{\Omega}^{-1}\boldsymbol{X})^{-1}\boldsymbol{X}'\boldsymbol{\Omega}^{-1}\boldsymbol{Y}$.
   d. Menghitung residual hasil estimasi model dengan GLS.

2.8.4. *Diagnostic Checking* Model

Diagnostic Checking 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*. Residual bersifat *white noise* apabila residual dari masing-masing data saling independen. Uji *white noise* dilakukan dengan cara memodelkan ulang residual yang didapatkan dari pemodelan. Pendeteksian *white noise* residual dapat dilakukan dengan melihat plot MCCF atau menggunakan kriteria minimum AIC

(Wei, 2006). Jika nilai AIC terkecil terletak pada AR(0) dan MA(0) dikatakan bahwa tidak ada korelasi antar residual, artinya residual bersifat *white noise*.

2.8.5. Kriteria Pemilihan Model Terbaik

Kriteria pemilihan model terbaik pada data *out-sample* dipilih berdasarkan nilai *Root Mean Square 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 dapat dihitung dengan formula sebagai berikut (Wei, 2006):

$$RMSE = \sqrt{\frac{1}{M}\sum_{l=1}^{M}\left(Y_{n+l} - \hat{Y}_n(l)\right)^2} \tag{2.114}$$

dengan *M* adalah banyaknya ramalan yang dilakukan, Y_{n+l} adalah data sebenarnya dan $\hat{Y}_n(l)$ adalah data hasil ramalan pada *l*-langkah ke depan.

2.9. Inflasi

Inflasi sebagai indikator penting ekonomi makro yang dapat memberikan informasi tentang dinamika perkembangan harga barang dan jasa yang dikonsumsi masyarakat. Perkembangan harga barang dan jasa ini berdampak langsung terhadap tingkat daya beli dan biaya hidup masyarakat. Bisa dikatakan bahwa inflasi merupakan indikator pergerakan antara permintaan dan penawaran di pasar riil (BPS, 2007).

Berdasarkan keparahannya inflasi juga dapat dibedakan (a) *Inflasi ringan* jika inflasi kurang dari 10 persen per tahun (*single digit*); (b) *Inflasi sedang* yaitu dengan tingkat inflasi antara 10 – 30 persen per tahun; (c) *Inflasi tinggi*, tingkat inflasi antara 30 – 100 persen per tahun; dan (d) *Hiperinflasi* jika inflasi lebih dari 100 persen per tahun (Atmadja, 1999).

Penghitungan inflasi salah satunya berdasarkan perubahan Indeks Harga Konsumen (IHK) dari waktu ke waktu dari suatu barang dan jasa. Jika perubahan IHK menunjukkan peningkatan maka terjadi inflasi, sebaliknya jika perubahan IHK menurun berarti terjadi deflasi. IHK dihitung dengan menggunakan rumus *Laspeyres* yang termodifikasi sebagai berikut :

$$IHK_t = \frac{\sum_{i=1}^{g} \frac{P_{ti}}{P_{(t-1)i}} P_{(t-1)i} Q_{0i}}{\sum_{i=1}^{g} P_{0i} Q_{0i}} \tag{2.115}$$

dengan

IHK_t	= Indeks harga konsumen periode ke-*t*
P_{ti}	= Harga jenis barang ke-*i*, periode ke-*t*
$P_{(t-1)i}$	= Harga jenis barang ke-*i*, periode ke-($t-1$)
$P_{(t-1)i}Q_{0i}$	= Nilai konsumsi jenis barang ke-*i*, periode ke-($t-1$)
$P_{0i}Q_{0i}$	= Nilai konsumsi jenis barang ke-*i*, pada tahun dasar
i	= jenis barang paket komoditas.

Penghitungan inflasi menurut BPS dengan membandingkan antar bulan atau inflasi bulan ke bulan (*month to month*), inflasi tahun ke tahun (*year on year*) yaitu bulan yang sama pada tahun ke-*A* dengan tahun ke-($A-1$) dan inflasi tahun kalender dengan membandingkan IHK bulan tahun ke-*A* terhadap bulan desember tahun ke-($A-1$). Formula inflasi yang digunakan adalah sebagai sebagai berikut :

$$Inflasi_{bulan\ (t)} = \frac{IHK\ bulan_{(t)} - IHK\ bulan_{(t-1)}}{IHK\ bulan_{(t-1)}} \times 100\% \tag{2.116}$$

$$Inflasi_{y\ on\ y} = \frac{IHK_{(bulan\ t\ tahun\ A)} - IHK_{(bulan\ t\ tahun\ (A-1))}}{IHK_{(bulan\ t\ tahun\ (A-1)}} \times 100\% \tag{2.117}$$

$$Inflasi_{tahun\ kalender} = \frac{IHK_{(bulan\ t\ tahun\ A)} - IHK_{(Des\ tahun\ (A-1))}}{IHK_{(Des\ tahun\ (A-1)}} \times 100\% \tag{2.118}$$

(Halaman ini sengaja dikosongkan)

BAB 3
METODOLOGI PENELITIAN

3.1. Sumber Data

Penelitian ini menggunakan data sekunder dengan skala metrik yaitu inflasi dan curah hujan serta data dengan skala non metrik berupa variasi kalender (tanggal dan bulan perayaan hari raya Idul Fitri) dan kebijakan pemerintah berupa kenaikan harga bahan bakar minyak (BBM) pada periode Januari 2001 – Desember 2015. Sumber data inflasi diperoleh dari Badan Pusat Statistik, sedangkan curah hujan bersumber dari BMKG untuk tiap kota lokasi survei yaitu Pontianak, Sampit, Palangkaraya, Banjarmasin, Balikpapan dan Samarinda.

Data pada periode Januari 2001 – Desember 2014 akan digunakan sebagai data training *(in-sample)*, sedangkan data pada periode Januari – Desember 2015 akan digunakan sebagai data validasi/testing *(out-sample)*. Data training digunakan untuk pemodelan, sedangkan data testing digunakan untuk mengetahui tingkat akurasi peramalan.

Lokasi keenam kota yang menjadi penelitian dapat dilihat pada peta wilayah Kalimantan seperti pada Gambar 3.1 berikut :

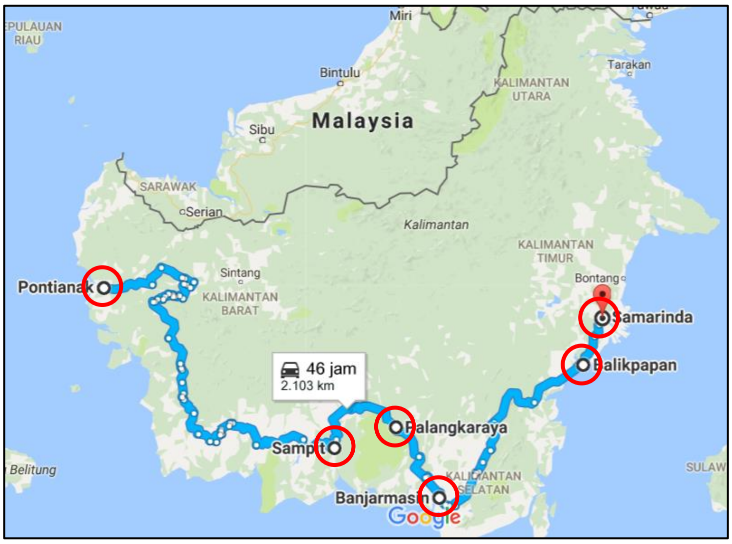

Gambar 3.1. Peta Lokasi Kota-kota di Kalimantan

Berdasarkan Gambar 3.1 diperoleh besaran jarak tempuh antar kota yang disajikan dalam bentuk matriks seperti pada Tabel 3.1 berikut :

Tabel 3.1. Jarak Antar Kota di Kalimantan (Km)

Lokasi	Jarak (Km)					
	Ponti-anak	Sampit	Palangka-raya	Banjar-masin	Balik-papan	Sama-rinda
Pontianak	0	1.074	1.296	1.490	1.988	2.104
Sampit	1.074	0	222	416	914	1.030
Palangkaraya	1.296	222	0	194	692	808
Banjarmasin	1.490	416	194	0	498	614
Balikpapan	1.988	914	692	498	0	116
Samarinda	2.104	1.030	808	614	116	0

Sumber : www.google.co.id/maps (data diolah)

3.2. Definisi Variabel Penelitian

Variabel yang digunakan dalam penelitian ini terdiri satu variabel respon dan dan tiga variabel prediktor. Adapun definisi operasional masing-masing variabel adalah sebagai berikut :

➢ Inflasi

Inflasi diartikan sebagai kecenderungan naiknya harga barang dan jasa pada umumnya yang berlangsung secara terus menerus. Jika terjadi inflasi, maka hal tersebut mengindikasikan harga barang dan jasa di dalam negeri mengalami kenaikan. Naiknya harga barang dan jasa tersebut menyebabkan turunnya nilai mata uang. Dengan demikian, inflasi dapat juga diartikan sebagai penurunan nilai mata uang terhadap nilai barang dan jasa secara umum. Indikator yang digunakan untuk mengukur tingkat inflasi adalah Indeks Harga Konsumen (IHK).

➢ Curah Hujan

Menurut BMKG, curah hujan merupakan ketinggian air hujan yang terkumpul dalam tempat yang datar, tidak menguap, tidak meresap, dan tidak mengalir. Satuan curah hujan dinyatakan dalam satuan millimeter satuan millimeter (mm).

Curah hujan 1 (satu) milimeter artinya dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi satu milimeter atau tertampung air sebanyak satu liter. Besarnya curah hujan (definisi BMKG) menurut jenisnya terdiri dari hujan kecil antara 0 – 21 mm per hari, hujan sedang antara 21 – 50 mm per hari dan hujan besar atau lebat di atas 50 mm per hari.

- *Dummy* variasi kalender

Indonesia dengan penduduk mayoritas beragama Islam, kejadian Hari Raya Idul Fitri (Lebaran) dianggap ikut memberikan pengaruh terhadap kenaikan harga barang. Sehingga setiap menjelang bulan Ramadhan dan Idul Fitri menjadi perhatian khusus bagi pemerintah untuk memantau ketersediaan dan distribusi barang khususnya bahan makanan. Variabel *dummy* terjadinya lebaran dapat dilihat seperti pada Tabel 3.2 sedangkan struktur variabel *dummy* dapat dilihat pada Tabel 3.6.

Tabel 3.2. Tanggal Hari Raya Idul Fitri 2001-2015

Data	Tahun	*t*	Tanggal, Bulan	*Dummy* untuk *t-1*, *t*
In-Sample	2001	1-12	17-18 Desember	D_{t-1} = 11, D_t = 12
	2002	13-24	06-07 Desember	D_{t-1} = 23, D_t = 24
	2003	25-36	25-26 November	D_{t-1} = 34, D_t = 35
	2004	37-48	14-15 November	D_{t-1} = 46, D_t = 47
	2005	49-60	03-04 November	D_{t-1} = 58, D_t = 59
	2006	61-72	23-24 Oktober	D_{t-1} = 69, D_t = 70
	2007	73-84	12-13 Oktober	D_{t-1} = 81, D_t = 82
	2008	85-96	01-02 Oktober	D_{t-1} = 93, D_t = 94
	2009	97-108	21-22 September	D_{t-1} = 104, D_t = 105
	2010	109-120	10-11 September	D_{t-1} = 116, D_t = 117
	2011	121-132	30-31 Agustus	D_{t-1} = 127, D_t = 128
	2012	133-144	19-20 Agustus	D_{t-1} = 139, D_t = 140
	2013	145-156	08-09 Agustus	D_{t-1} = 151, D_t = 152
	2014	157-168	28-29 Juli	D_{t-1} = 162, D_t = 163
Out-Sample	2015	169-180	17-18 Juli	D_{t-1} = 174, D_t = 175

Sumber : Diolah dari kalender (2001-2015)

Variasi kalender sebagai variabel *dummy* dalam penelitian ini dibuat dalam 2 model (skenario) yaitu *dummy* bulanan dan *dummy* mingguan dengan rincian sebagai berikut :

Model 1 (Skenario 1)

D_t = Variabel *dummy* bernilai 1 pada bulan dimana terjadinya hari raya Idul Fitri pada bulan ke-t dan bernilai 0 untuk bulan yang lain.

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

Model 2 (Skenario 2)

$D_{j,t}$ = Variabel *dummy* bernilai 1 pada bulan dimana terjadinya hari raya Idul Fitri pada mingu ke-j dan bernilai 0 untuk bulan yang lain, $j = 1,2,3,4$.

$D_{j,t-1}$ = Variabel *dummy* bernilai 1 pada satu bulan sebelum bulan terjadinya hari raya Idul Fitri pada bulan ke-j dan bernilai 0 untuk bulan yang lain, $j = 1,2,3,4$.

- Kebijakan Pemerintah (Harga BBM)

  Dalam kurun waktu 2001 – 2015, pemerintah menerapkan kebijakan dengan melakukan penyesuain harga BBM baik berupa kenaikan atau penurunan harga. BBM dimaksud mencakup jenis premium, solar dan minyak tanah. Kebijakan kenaikan harga BBM yang diduga memberikan dampak yang besar adalah kejadian pada bulan Oktober 2005. Kebijakan tersebut dianggap sebagai variabel intervensi dengan fungsi *pulse* karena hanya memberikan dampak pada saat terjadinya kebijakan tersebut. Secara rinci kebijakan pemerintah terhadap perubahan harga BBM seperti pada Tabel 3.3 berikut :

Tabel 3.3. Tanggal Kenaikan dan Penurunan Harga BBM 2001 - 2015

Tahun	Tanggal Berlaku	Keterangan	Tahun	Tanggal Berlaku	Keterangan
2001	16 Juni	↑ P, S dan MT	2008	24 Mei	↑ P, S dan MT
2002	1 Maret	↑ P, S dan MT		1 Desember	↓ P
	1 April	↑ P, S dan MT		15 Desember	↓ P dan S

Tahun	Tanggal Berlaku	Keterangan	Tahun	Tanggal Berlaku	Keterangan
	3 Mei	↑ P, S dan MT	2009	15 Januari	↓ P dan S
2003	1 Januari	↑ P, S dan MT	2013	22 Juni	↑ P dan S
	21 Januari	↓ S dan MT	2014	18 November	↑ P dan S
2005	1 Maret	↑ P, S dan MT	2015	1 Januari	↓ P dan S
	1 Oktober	↑ P, S dan ↓ MT		19 Januari	↓ P dan S

Sumber : https://id.wikipedia.org
Keterangan : ↑ = kenaikan harga
↓ = penurunan harga
P = Premium; S = Solar dan MT = Minyak Tanah

3.3. Struktur Data

Variabel yang menjadi respon dalam penelitian ini disimbolkan $\boldsymbol{Y}_{i,t}$ yang menyatakan tingkat inflasi pada lokasi ke-*i* dengan *i = 1,2,3,4,5,6* (Pontianak, Sampit, Palangkaraya, Banjarmasin, Balikpapan dan Samarinda) dan waktu ke-*t*. Dengan demikian secara rinci variabel respon dalam penelitian ini bisa dijabarkan seperti pada Tabel 3.4 berikut.

Tabel 3.4. Variabel *Output* (Respon) Dalam Penelitian

No	Variabel	Keterangan
1	$\boldsymbol{Y}_{1,t}$	Inflasi Kota Pontianak waktu ke-*t*
2	$\boldsymbol{Y}_{2,t}$	Inflasi Kota Sampit waktu ke-*t*
3	$\boldsymbol{Y}_{3,t}$	Inflasi Kota Palangkaraya waktu ke-*t*
4	$\boldsymbol{Y}_{4,t}$	Inflasi Kota Banjarmasin waktu ke-*t*
5	$\boldsymbol{Y}_{5,t}$	Inflasi Kota Balikpapan waktu ke-*t*
6	$\boldsymbol{Y}_{6,t}$	Inflasi Kota Samarinda waktu ke-*t*

Untuk variabel input *(eksogen)* dengan skala metrik yaitu curah hujan disimbolkan $x_{i,t}$ menyatakan banyaknya curah hujan pada lokasi ke-*i* dengan *i* = *1,2,3,4,5,6* (Pontianak, Sampit, Palangkaraya, Banjarmasin, Balikpapan dan Samarinda), pada waktu ke-*t*.

Struktur data untuk Inflasi dengan variabel prediktor adalah curah hujan yang terjadi pada enam kota di Kalimantan seperti pada Tabel 3.5 di bawah ini.

Tabel 3.5. Struktur Data Inflasi dengan Variabel Prediktor Curah Hujan

t	Tahun	Bulan	$Y_{1,t}$	$Y_{2,t}$	…	$Y_{6,t}$	$X_{1,t}$	$X_{2,t}$	…	$X_{6,t}$
1	2001	1	$Y_{1,1}$	$Y_{2,1}$	…	$Y_{6,1}$	$X_{1,1}$	$X_{2,1}$	…	$X_{6,1}$
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮	⋱	⋮
12	2001	12	$Y_{1,12}$	$Y_{2,12}$	…	$Y_{6,12}$	$X_{1,12}$	$X_{2,12}$	…	$X_{6,12}$
13	2002	1	$Y_{1,13}$	$Y_{2,13}$	…	$Y_{6,13}$	$X_{1,13}$	$X_{2,13}$	…	$X_{6,13}$
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮	⋱	⋮
24	2002	12	$Y_{1,24}$	$Y_{2,24}$	…	$Y_{6,24}$	$X_{1,24}$	$X_{2,24}$	…	$X_{6,24}$
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮	⋱	⋮
145	2013	1	$Y_{1,145}$	$Y_{2,145}$	…	$Y_{6,145}$	$X_{1,145}$	$X_{2,145}$	…	$X_{6,145}$
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮	⋱	⋮
156	2013	12	$Y_{1,156}$	$Y_{2,156}$	…	$Y_{6,156}$	$X_{1,156}$	$X_{2,156}$	…	$X_{6,156}$
157	2014	1	$Y_{1,157}$	$Y_{2,157}$	…	$Y_{6,157}$	$X_{1,157}$	$X_{2,157}$	…	$X_{6,157}$
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮	⋱	⋮
168	2014	12	$Y_{1,168}$	$Y_{2,168}$	…	$Y_{6,168}$	$X_{1,168}$	$X_{2,168}$	…	$X_{6,168}$

Tabel 3.6. Struktur Data Inflasi dengan Variabel *Dummy* Hari Raya Idul Fitri

t	Tahun	Bulan	$Y_{1,t}$	$Y_{2,t}$	…	$Y_{6,t}$	D_{t-1}	D_t
1	2001	1	$Y_{1,1}$	$Y_{2,1}$	…	$Y_{6,1}$	0	0
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮
11	2001	11	$Y_{1,11}$	$Y_{2,11}$	…	$Y_{6,11}$	1	0
12	2001	12	$Y_{1,12}$	$Y_{2,12}$	…	$Y_{6,12}$	0	1
13	2002	1	$Y_{1,13}$	$Y_{2,13}$	…	$Y_{6,13}$	0	0
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮
23	2002	11	$Y_{1,23}$	$Y_{2,23}$	…	$Y_{6,23}$	1	0
24	2002	12	$Y_{1,24}$	$Y_{2,24}$	…	$Y_{6,24}$	0	1
25	2003	1	$Y_{1,25}$	$Y_{2,25}$	…	$Y_{6,25}$	0	0
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮
145	2013	1	$Y_{1,145}$	$Y_{2,145}$	…	$Y_{6,145}$	0	0
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮

t	Tahun	Bulan	$Y_{1,t}$	$Y_{2,t}$	…	$Y_{6,t}$	D_{t-1}	D_t
151	2013	7	$Y_{1,151}$	$Y_{2,151}$	…	$Y_{6,151}$	1	0
152	2013	8	$Y_{1,152}$	$Y_{2,152}$	…	$Y_{6,152}$	0	1
153	2013	9	$Y_{1,153}$	$Y_{2,153}$	…	$Y_{6,153}$	0	0
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮
156	2013	12	$Y_{1,156}$	$Y_{2,156}$	…	$Y_{6,156}$	0	0
157	2014	1	$Y_{1,157}$	$Y_{2,157}$	…	$Y_{6,157}$	0	0
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮
162	2014	6	$Y_{1,162}$	$Y_{2,162}$	…	$Y_{6,162}$	1	0
163	2014	7	$Y_{1,163}$	$Y_{2,163}$	…	$Y_{6,163}$	0	1
164	2014	8	$Y_{1,164}$	$Y_{2,164}$	…	$Y_{6,164}$	0	0
⋮	⋮	⋮	⋮	⋮	⋱	⋮	⋮	⋮
168	2014	12	$Y_{1,168}$	$Y_{2,168}$	…	$Y_{6,168}$	0	0

3.4. Metode Analisis

Metode analisis yang digunakan dalam penelitian ini adalah menggunakan analisis deskriptif untuk memberikan gambaran inflasi yang berada di enam kota di Kalimantan. Selain itu dilakukan analisis inferensi berupa pengujian model yang dibentuk serta melakukan peramalan berdasarkan model yang terbaik. Dalam estimasi parameter, menggunakan menggunakan metode kuadrat terkecil/OLS dan *Generalized Least Square* (GLS)

3.5. Tahapan Penelitian

Secara umum dalam penelitian ini dilakukan beberapa tahapan seperti ditunjukkan pada diagram alur pada Gambar 3.2 Mengacu pada tujuan penelitian ini, maka tahapan analisis dalam penelitian adalah melakukan pemodelan data inflasi pada 6 (enam) lokasi dengan menggunakan model ARIMA, model fungsi transfer, variasi kalender dan intervensi serta model GSTARX. Pada tahap awal dilakukan eksplorasi data tentang inflasi di enam kota inflasi yang menjadi obyek penelitian untuk menghasilkan gambaran secara umum perkembangan dan karakteristik inflasi di masing-masing kota tersebut. Penyajian ekplorasi data dalam bentuk deskriptif dengan pembentukan plot time series untuk setiap kota inflasi tersebut.

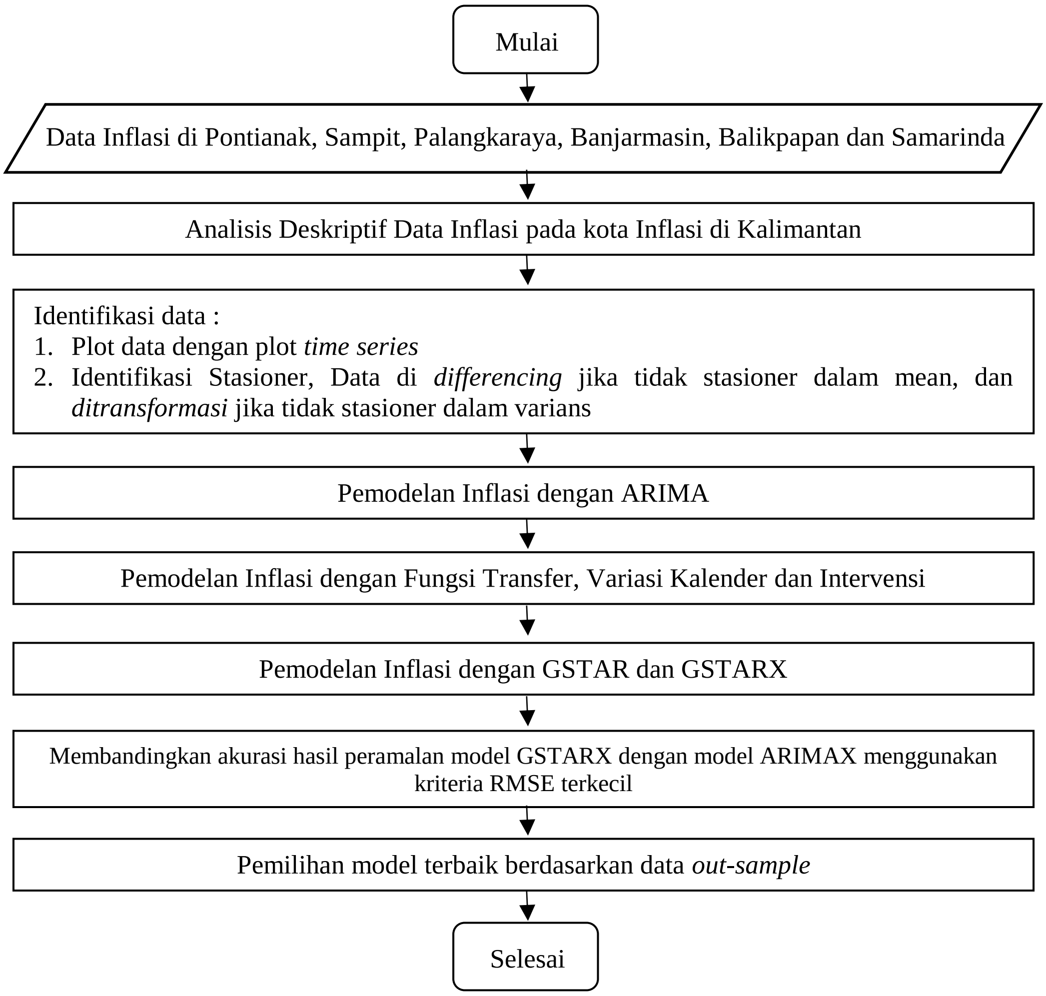

Gambar 3.2. Alur Tahapan Penelitian

Untuk tahapan melakukan pemodelan dengan GSTARX maka dilakukan dua tahap yaitu tahap petama melakukan pemodelan dengan ARIMA, ARIMAX dengan variabel eksogen non metrik berupa variasi kalender dan intervensi serta variabel eksogen metrik berupa fungsi transfer. Sedangkan tahap 2 melakukan model GSTAR yang berasal dari residual dari model pada tahap satu. Secara rinci dijabarkan sebagai berikut :

1. Memodelkan data inflasi dengan menggunakan ARIMA
   a. Membagi data series inflasi menjadi data *in-sample* dan data *out-sample*.

b. Identifikasi pola data dengan plot *time series*, membuat *plot Autocorrelation Function (ACF)* dan *plot Partial Autocorrelation Function (PACF)* dari data inflasi *(In-sample)*.
c. Memeriksa kestasioneran data inflasi di 6 (enam) kota baik dalam mean maupun varians.
d. Melakukan estimasi parameter model pada data inflasi di 6 kota
e. Melakukan dignosa terhadap model untuk mendapatkan model yang layak dan memenuhi asumsi residual *white noise* dan berdistribusi normal.
f. Melakukan peramalan berdasarkan model terbaik dan mengukur tingkat RMSE pada data *out-sample.*

2. Pembentukan model dengan variasi kalender
   a. Identifikasi dan menentukan variabel *dummy* berdasarkan periode kalender variasi terjadinya hari raya Idul Fitri dengan rincian sebagai berikut :

   Model 1 (*dummy* bulanan*)*

   D_{t-1} = Variabel *dummy* bulan sebelum Idul Fitri pada periode pengamaatan.

   D_t = Variabel *dummy* bulan Idul Fitri pada periode pengamatan.

   Model 2 (*dummy* mingguan*)*

   $D_{i,t-1}$ = Variabel *dummy* minggu ke-*i* sebelum bulan Idul Fitri pada periode pengamatan, dimana untuk $i = 1,2,3,4$.

   $D_{i,t}$ = Variabel *dummy* minggu ke-*i* saat terjadinya hari Raya Idul Fitri pada periode pengamatan, dimana untuk $i = 1,2,3,4$.

   b. Melakukan pemodelan dan estimasi parameter dengan model regresi variasi kalender sebagai berikut :

   $$y_{i,t} = f\left(D_{i,t}, D_{i,t-1}\right) + u_{i,t} \tag{3.1}$$

   c. Memodelkan residual dari model regresi *dummy* dengan menggunakan model ARIMA. Apabila residual dari model regresi sudah memenuhi asumsi *white noise* maka tidak perlu penambahan model ARIMA pada model regresi.

d. Melakukan pengecekan signifikansi parameter.

e. Melakukan cek diagnosa terhadap residual dari model ARIMA untuk mengetahui kelayakan model ARIMA yang terbentuk. Kelayakan model dimaksud adalah residual sudah memenuhi asumsi *white noise* dan mengikuti distribusi normal.

3. Pembentukan model dengan intervensi

Variabel intervensi dalam penelitian ini bersifat *pulse*, sehingga bisa didefinisikan bahwa nilai respons impuls menggunakan *b*=0, *s*=0 dan *r*=0. Dengan demikian perlakuan untuk penyertaan variabel intervensi sama halnya dengan perlakuan adanya *outlier* dengan tipe *Additive Outlier*, sehingga pemodelan secara khusus untuk variabel intervensi tidak akan dilakukan karena sudah tercakup dalam pemodelan yang melibatkan deteksi outlier dengan tipe *Additive Outlier* (AO). Sehingga bentuk persamaan model intervensi identik dengan model deteksi *outlier* tipe *additive* seperti pada persamaan (2.60) yaitu :

$$\begin{aligned} Y_t &= u_t + \omega P_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} a_t + \omega P_t^{(T)}, \end{aligned} \tag{3.2}$$

dengan

$$I_t^{(T)} = \begin{cases} 1 & , t \neq T \\ 0 & , t = T \end{cases}$$

u_t adalah model ARIMA sebelum deteksi *outlier*

$I_t^{(T)}$ adalah variabel *Intervensi* pada waktu ke-*T*.

4. Pemodelan fungsi transfer

a. Mengidentifikasi stasioneritas deret input yaitu variabel curah hujan

b. Melakukan *prewhitening* pada *input series* dan *ouput series*: membentuk model ARIMA untuk masing-masing *input series* dengan melalui tahap identifikasi model, estimasi parameter model, dan pengujian model sehingga mendapatkan nilai *prewhitening* input series. dan mendapatkan output series dengan menggunakan hasil pemutihan dari input series.

c. Menetapkan bobot respon impuls (*b*,*s*,*r*) yang menghubungkan setiap data deret input dan deret output serta penaksiran awal deret error n_t.

d. Melakukan pemodelan dengan model fungsi transfer sementara berdasarkan orde (*b*,*s*,*r*) dan pemodelan ARIMA untuk n_t.

e. Melakukan estimasi parameter model fungsi transfer, sehingga memperoleh model.

$$y_t = \frac{\omega_s(B)B^b}{\delta_r(B)} x_t + \frac{\theta_q(B)}{\phi_p(B)} a_t. \tag{3.3}$$

f. Melakukan diagnosa (*diagnostic checking)* model untuk mendapatkan model yang layak dengan memeriksa residual untuk mengetahui tercapainya asumsi *residual* yang *white noise* dan berdistribusi normal.

g. Melakukan peramalan dengan model terbaik dan menghitung nilai RMSE pada data out-sample.

5. Pembentukan model pada level satu

Berdasarkan persamaan (3.1), (3.2) dan (3.3) maka diperoleh model ARIMAX untuk tiap lokasi dengan 3 variabel eksogen sebagai berikut :

$$\dot{y}_{i,t} = \beta_{i,1} D_{i,t-1} + \beta_{i,2} D_{i,t} + \alpha_{Int} P_{i,t} + \frac{\omega_s(B)B^b}{\delta_r(B)} x_{i,t} + n_{i,t} \tag{3.4}$$

dengan $\dot{y}_{i,t} = y_{i,t} - \mu$, dan $y_{i,t} = Ln(\mathrm{Y}_{\mathrm{i,t}})$.

6. Pembentukan model dengan GSTARX

Pada tahapan level 2 dimana residual n_t dari 6 lokasi yang didapat pada persamaan (3.4) dibentuk model GSTAR dengan bobot lokasi menggunakan bobot invers jarak, normalisasi korelasi silang, dan normalisasi inferensia korelasi silang parsial. Pada tahap kedua dilakukan langkah-langkah sebagai berikut :

b.1. Mengidentifikasi stasioneritas dalam rata-rata residual $n_{i,t}$ dengan menggunakan skema MCCF.

b.2. Menentukan orde waktu (p) dari model $n_{i,t}$ yang telah stasioner dengan menggunakan skematik MCCF dan nilai AIC minimum.

b.3. Menentukan bobot spasial yang digunakan, bobot spasial yang dipergunakan ditentukan dengan orde spasial satu ($\lambda_p = 1$).

b.4. Melakukan penghitungan nilai pembobot wilayah ($\boldsymbol{W^1}$) menggunakan bobot seragam, invers jarak imajiner dengan menarik garis lurus (tipe I), invers jarak riil jarak tempuh transportasi darat (tipe II), normalisasi korelasi silang dan normalisasi inferensia parsial korelasi silang.

b.5. Melakukan estimasi parameter dengan menggunakan ordo p dari langkah (b.2.) dengan model GSTAR-GLS.

$$\boldsymbol{n}(t) = \sum_{k=1}^{p} \left[\boldsymbol{\Phi}_{k0}\boldsymbol{n}(t-k) + \boldsymbol{\Phi}_{k1}\boldsymbol{W}^{(1)}\boldsymbol{n}(t-k) \right] + \boldsymbol{e}(t) \tag{3.5}$$

b.6. Menguji signifikansi parameter model GSTAR-GLS. Jika terdapat parameter-parameter yang tidak signifikan, dilakukan *restricted* dengan mengurangi variabel yang tidak signifikan.

b.7. Mendapatkan model GSTAR-GLS dan melakukan peramalan $\hat{n}_{i,t}$ dengan model GSTAR-GLS.

7. Peramalan dengan GSTARX

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

a. Melakukan peramalan dengan model GSTARX untuk data inflasi pada 6 kota di Kalimantan berdasarkan persamaan (3.4) dan (3.2) sebagai berikut :

$\hat{Y}_{i,t} = \hat{y}_{i,t} + \hat{n}_{i,t}$

Level 1 : $\hat{y}_{i,t} = \beta_{i,1}D_{i,t-1} + \beta_{i,2}D_{i,t} + \alpha_{i,Int}P_t + + \frac{\omega_s(B)B^b}{\delta_r(B)}x_{it} + n_{i,t}$

Level 2 :

$$\boldsymbol{n}(t) = \sum_{k=1}^{p} \left[\boldsymbol{\Phi}_{k0}\boldsymbol{n}(t-k) + \boldsymbol{\Phi}_{k1}\boldsymbol{W}^{(1)}\boldsymbol{n}(t-k) \right] + \boldsymbol{e}(t) \tag{3.6}$$

dengan

$\hat{Y}_{i,t}$: 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 pada GSTAR

b. Melakukan *diagnostic checking* hasil pemodelan GSTARX masing-masing bobot dengan pengujian residual yang *white noise* dengan menggunakan AIC yang terkecil.

c. Menghitung nilai RMSE hasil pemodelan GSTARX masing-masing bobot pada data *out-sample.*

8. Pemilihan model terbaik

   a. Melakukan perbandingan hasil peramalan GSTARX dengan ARIMAX menggunakan empat macam bobot berdasarkan kriteria model RMSE untuk data *out-sample*.

   b. Mendapatkan model terbaik berdasarkan data *out-sample*.

(Halaman ini sengaja dikosongkan)

BAB 4
HASIL DAN PEMBAHASAN

Pada bab ini akan dijelaskan secara rinci analisis dan hasil pemodelan inflasi yang dilakukan pada 6 lokasi di wilayah Kalimantan yang meliputi Kota Pontianak, Sampit, Palangkaraya, Banjarmasin, Balikpapan dan Samarinda. Pemodelan inflasi dilakukan dengan menggunakan analisis *time series* univariat maupun multivariat yaitu model ARIMA, variasi kalender, analisis intervensi, dan model fungsi transfer. Untuk analisis intervensi akan diintegrasikan dengan adanya deteksi outlier pada setiap model univariat.

Estimasi parameter dari model ARIMA, variasi kalender dan fungsi transfer menggunakan *Conditional Least Square.* Untuk pemodelan multivariat dilakukan pada tahap kedua, dengan menggunakan model GSTAR dari *residual* hasil model simultan univariat. Estimasi parameter pada model GSTAR menggunakan *Generalized Least Square*. Pada setiap pemodelan dilakukan pemilihan model terbaik sehingga bisa digunakan untuk melakukan peramalan terhadap inflasi di enam kota di wilayah Kalimantan. Untuk memberikan gambaran umum digunakan analisis deskriptif mengenai inflasi di Kalimantan.

4.1. Karakteristik Data Inflasi Enam Lokasi di Kalimantan

Dalam penelitian ini menggunakan data inflasi pada periode bulan Januari 2001 – Desember 2015 pada 6 kota di wilayah Kalimantan yaitu Pontianak, Sampit, Palangkaraya, Banjarmasin, Balikapapan dan Samarinda. Pada periode Januari 2001 – Desember 2014 digunakan sebagai data *in-sample* sedangkan data pada peride Januari – Desember 2015 digunakan sebagai data *out-sample.* Inflasi yang dimaksud dalam penulisan ini adalah inflasi umum.

Summary dari data inflasi enam kota di Kalimantan bisa dilihat pada Tabel 4.1. Berdasarkan pada tabel tersebut memperlihatkan bahwa rata-rata inflasi selama periode Januari 2001 – Desember 2014 di enam lokasi tersebut relatif tidak jauh berbeda. Rata-rata inflasi tertinggi di Samarinda yang tercatat sebesar 0,683 persen diikuti Balikpapan dengan tingkat rata-rata sebesar 0,673 persen.

Tabel 4.1. Statistik Deskriptif Data Inflasi Pada Enam Kota di Kalimantan

Lokasi	*Mean*	Standar Deviasi	Minimum	Maksimum
Pontianak	0,668	0,946	-1,66	7,17
Sampit	0,598	1,050	-1,89	6,78
Palangkaraya	0,645	1,003	-1,30	6,83
Banjarmasin	0,647	0,980	-1,23	8,05
Balikpapan	0,673	0,917	-1,33	6,38
Samarinda	0,683	0,953	-1,27	7,38

Adapun rata-rata inflasi terkecil terjadi di Sampit sebesar 0,598 persen. Sementara rata-rata inflasi di lokasi lain yaitu Pontianak sebesar 0,668 persen, Palangkaraya sebesar 0,645 persen dan Banjarmasin sebesar 0,647 persen. Tingkat rata-rata inflasi yang tidak jauh berbeda pada enam wilayah tersebut mengindikasikan bahwa pengendalian inflasi oleh pihak terkait di masing-masing wilayah telah berjalan dengan baik.

Berdasarkan Gambar 4.1 menunjukkan tingkat persebaran data inflasi di masing-masing lokasi relatif tidak berbeda jauh. Namun demikian terdapat sebaran inflasi yang cenderung bersifat pencilan atau *outlier*. Pada boxplot di atas menunjukkan bahwa setiap lokasi memiliki data *outlier* yang beragam pada waktu terjadinya. Namun demikian, pada semua lokasi terdapat tingkat inflasi yang dianggap *outlier* dan terjadi pada bulan yang sama yaitu pada bulan Oktober 2005, dimana pada bulan ini untuk seluruh wilayah merupakan tingkat inflasi tertinggi selama kurun waktu tersebut. Tingginya tingkat inflasi pada bulan tersebut sebagai akibat dari adanya kebijakan pemerintah dalam menaikkan harga bahan bakar minyak (BBM) yang diberlakukan mulai tanggal 01 Oktober 2005.

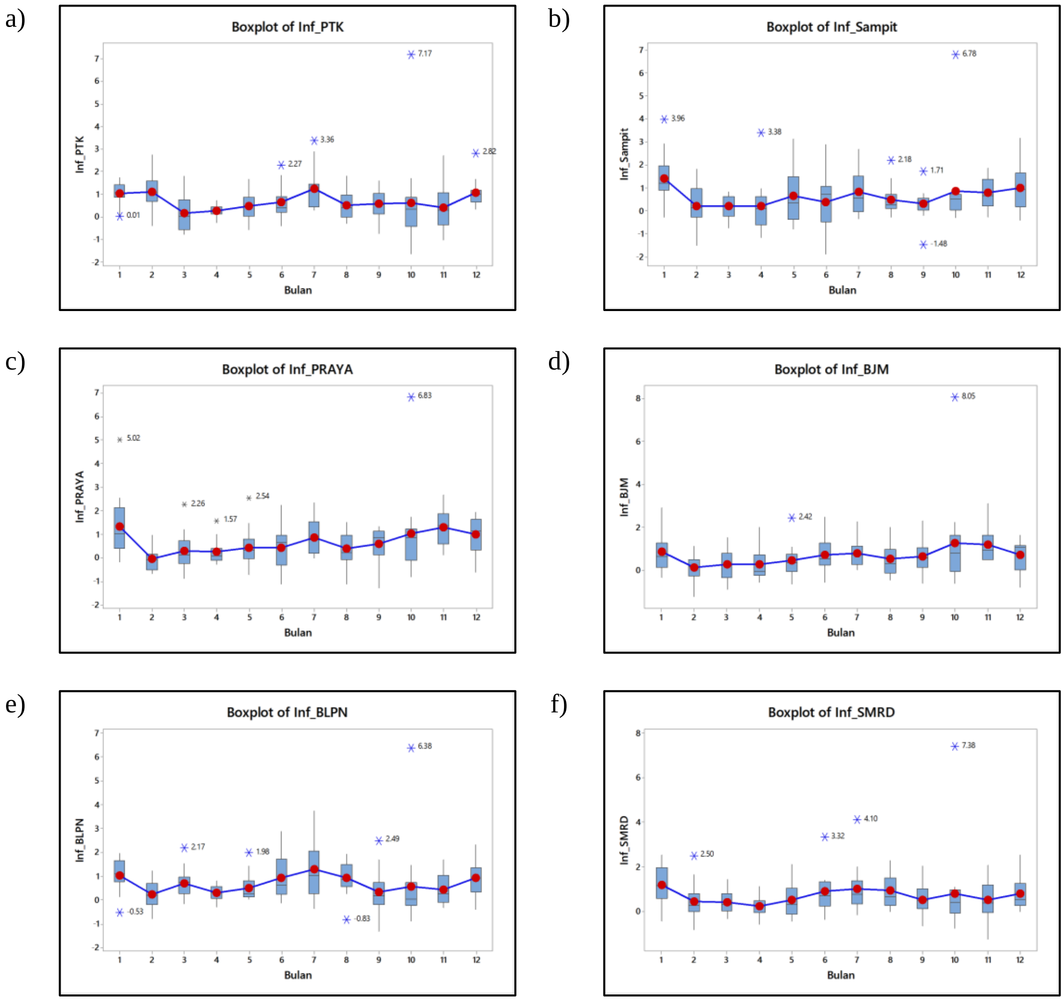

Gambar 4.1. Boxplot Inflasi Enam Wilayah di Kalimantan
(a) Pontianak (b) Sampit (c) Palangkaraya (d) Banjarmasin (e) Balikpapan (f) Samarinda

Pada Tabel 4.1 dan Gambar 4.1 juga memberikan gambaran bahwa inflasi terendah terjadi pada wilayah Sampit yang mengalami *deflasi* sebesar 1,89 pada bulan Juni 2005, sedangkan tingkat inflasi tertinggi terjadi di Banjarmasin sebesar 7,38 persen pada bulan Oktober 2005. Berdasarkan pola persebarannya, fluktuasi inflasi yang tertinggi ada di Sampit, dimana persebaran data terhadap rata-rata inflasi atau tingkat deviasinya sebesar 1,050 sedangkan fluktuasi yang terendah terjadi di Balikpapan dengan tingkat deviasi sebesar 0,917.

a)

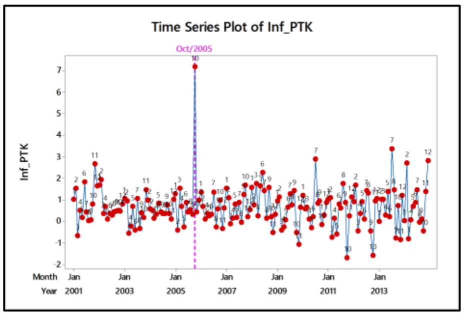

b)

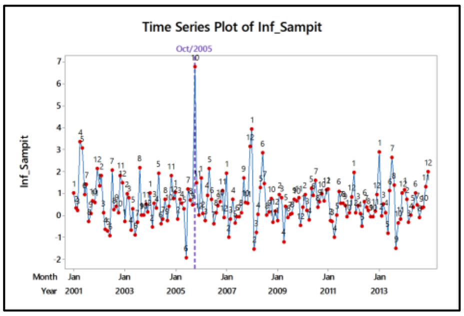

c)

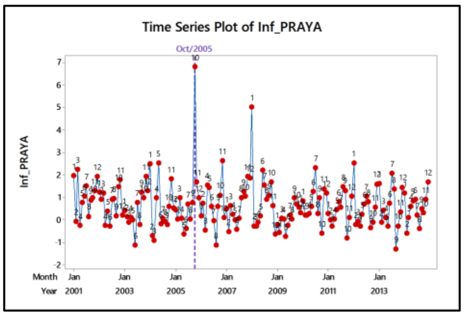

d)

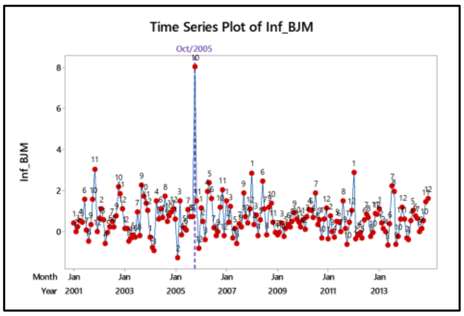

e)

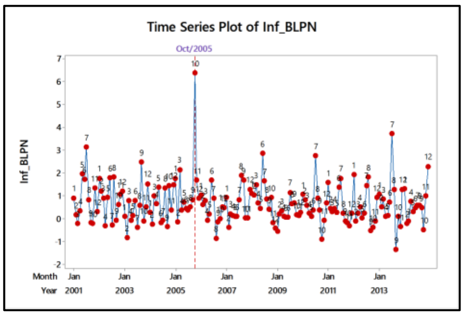

f)

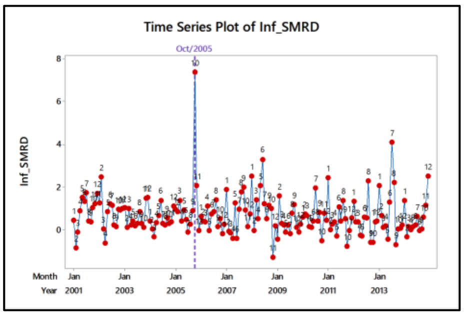

Gambar 4.2. Plot *Time Series* Inflasi Enam Wilayah di Kalimantan
(a) Pontianak (b) Sampit (c) Palangkaraya (d) Banjarmasin (e) Balikpapan (f) Samarinda

Berdasarkan pada Gambar 4.2 memperlihatkan pergerakan inflasi secara fluktuatif dan memiliki pola perubahan yang relatif sama pada enam lokasi tersebut. Kenaikan harga BBM pada bulan Oktober 2005 sebagai dampak dari pengurangan subsidi BBM oleh pemerintah, memberikan pengaruh yang sangat signifikan terhadap perubahan inflasi. Kenaikan BBM pada Oktober 2005 dirasa cukup besar dimana untuk jenis premium mengalami kenaikan lebih dari 85 persen dan jenis solar lebih dari 100 persen. Perubahan inflasi pada enam wilayah di Kalimantan juga memiliki kecenderungan pola musiman, dimana pada bulan-bulan tertentu besaran inflasi berada pada nilai tertinggi seperti pada bulan Juli khususnya di bidang pendidikan karena memasuki tahun ajaran baru sekolah serta pada bulan Desember yang disebabkan meningkatnya permintaan karena libur natal dan tahun baru.

Inflasi di wilayah Kalimantan juga tidak lepas karena faktor adanya kejadian atau *event* tertentu seperti perayaan hari besar agama. Dalam penelitian ini akan dibahas pengaruh dari perayaan hari besar agama yaitu hari raya Idul Fitri atau pada bulan menjelang perayaan Idul Fitri. Dalam analisis *time series* fenomena ini lebih dikenal dengan faktor variasi kalender. Hal yang lazim dan menjadi fenomena ekonomi secara nasional bahwa setiap menjelang perayaan Idul Fitri berbagai kebutuhan barang dan jasa meningkat. Hal ini memicu adanya kenaikan harga suatu barang dan jasa khususnya harga sembilan bahan pokok. Selain itu pada waktu-waktu menjelang perayaan Idul Fitri, permintaan terhadap layanan jasa transportasi juga mengalami peningkatan khususnya karena adanya suatu *tradisi* mudik lebaran. Adanya kenaikan harga di sektor layanan jasa transportasi khusunya darat dan laut pada setiap tahunnya menjelang perayaan lebaran berdampak pada kenaikan harga barang dan jasa pada sektor lain karena berhubungan dengan adanya arus distribusi barang atau jasa. Hal ini yang menyebabkan terjadinya inflasi pada bulan dimana terjadinya perayaan idul fitri atau satu bulan menjelang perayaan Idul Fitri.

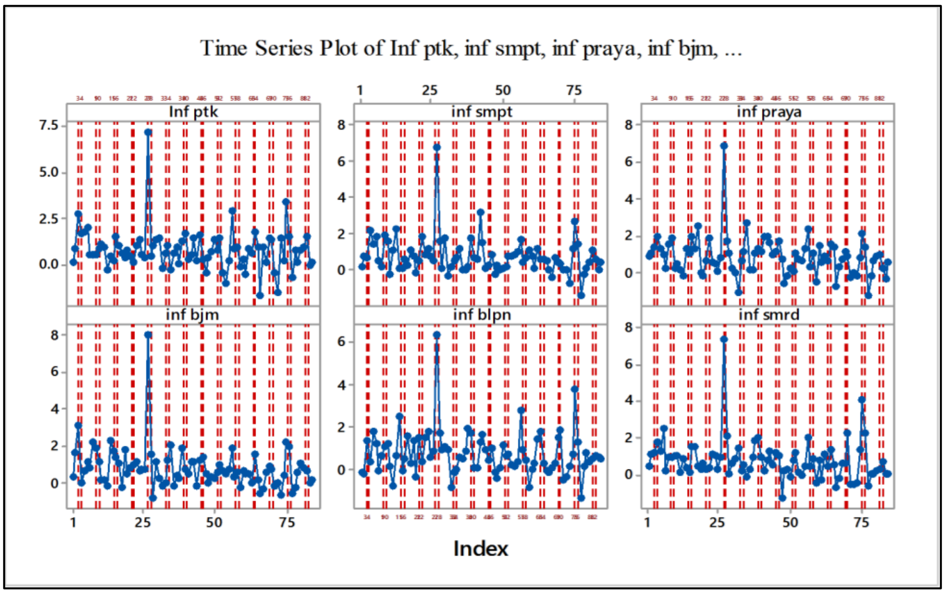

Gambar 4.3. Inflasi di Enam Lokasi Pada Bulan Hari Raya Idul Fitri

Berdasarkan plot data pada Gambar 4.3 di atas memperlihatkan bahwa setiap menjelang perayaan hari raya Idul Fitri atau pada saat bulan terjadinya Idul Fitri cenderung terjadi inflasi. Umumnya inflasi terjadi pada satu bulan sebelum bulan perayaan hari raya Idul Fitri atau juga bisa terjadi pada bulan dimana terjadi hari raya Idul Fitri.

Hal lain yang menyebabkan terjadinya inflasi diduga karena faktor cuaca dalam hal ini tingginya curah hujan. Curah hujan yang tinggi kerap kali menyebabkan terrjadinya banjir di sejumlah daerah, dan tidak sedikit lahan pertanian banyak yang rusak karena banjir. Hal ini berdampak pada produksi pertanian yang gagal panen seperti padi, sayur-sayuran dan komoditas lainnya yang rentan rusak banjir. Ketika produksi menurun, maka secara ekonomi persediann barang di pasar juga berkurang, sedangkan di sisi lain permintaan akan barang tetap bahkan cenderung meningkat. Kondisi ini bisa memberikan efek terhadap kenaikan harga barang meningkat.

Tabel 4.2. Statistik Deskriptif Curah Hujan (mm) Pada Enam Kota di Kalimantan

Lokasi	*Mean*	Standar Deviasi	Minimum	Maksimum
Pontianak	262.58	124.63	16	688
Sampit	214.40	215.3	0	1778
Palangkaraya	252.70	152.6	3	729.1
Banjarmasin	230.69	128.91	0	505
Balikpapan	234.55	113.94	10.8	705.1
Samarinda	199.41	97.07	0	501

Berdasarkan Tabel 4.2 memperlihatkan rata-rata curah hujan per bulan untuk enam lokasi di Kalimantan relatif tidak jauh berbeda. Rata—rata curah hujan tertinggi terjadi di Pontianak yang mencapai 262.58 mm per bulan. Sedangkan rata-rata curah hujan terendah berada pada wilayah Samarinda dengan rata-rata sebesar 199.41 mm per bulan. Data deskripsi di atas menunjukkan selama periode 2001-2014 tingkat curah hujan yang tinggi terjadi di Sampit yang mencapai 1.778

mm. Adapun untuk tingkat curah hujan terendah (nilai minimum) terjadi di Sampit, Banjarmasin dan Samarinda.

Curah hujan yang tinggi juga kerap kali mengganggu distribusi barang dan jasa antar wilayah, terlebih ketika kondisi jalan menjadi rusak akibat banyaknya genangan air sebagai dampak dari tingginya curah hujan di suatu wilayah. Adanya distribusi barang yang terganggu, menyebabkan pasokan atau ketersediaan barang dan jasa di pasar menjadi terbatas sehingga seringkali berdampak pada harga barang menjadi naik. Barang dan jasa yang tersedia di wilayah Kalimantan, tidak semuanya merupakan produksi lokal. Sebagian masih tergantung pada wilayah lain khususnya produksi dari pulau jawa atau antar wilayah lain di Kalimantan. Ketika suatu barang dan jasa didistribusikan melalui transportasi air, maka tingginya curah hujan sangat mengganggu dalam distribusi barang dan jasa, hal ini berakibat ketersediaan barang dan jasa menjadi langka karena keterlambatan pasokan yang berasal dari luar daerah atau pulau. Untuk itu dalam penelitian ini akan mencoba menyertakan variabel curah hujan sebagai prediktor dalam pemodelan Inflasi pada enam wilayah di Kalimantan.

4.2. Kestasioneran Data

Dalam pemodelan ARIMA inflasi pada enam kota di Kalimantan menggunakan prosedur Box-Jenkins. Dalam tahapan prosedur Box-Jenkins meliputi identifikasi data, estimasi parameter, cek diagnosa dan peramalan. Sebelum memasuki tahapan langkah awal yang dilakukan adalah dengan melakukan identifikasi data. Tahap identifikasi data dilakukan untuk mengetahui kestasioneran data yang meliputi stasioner dalam rata-rata dan varians.

Untuk melihat kestasioneran data inflasi dalam rata-rata bisa dilihat berdasarkan Box-Plot dari data inflasi seperti pada Gambar 4.4 Berdasarkan pada gambar tersebut menunjukkan bahwa data inflasi enam kota di Kalimantan sudah stasioner dalam rata-rata. Stasioner dalam rata-rata untuk data inflasi tersebut setelah dilakukan *differencing* musiman ($D = 1$), karena data inflasi pada enam kota menunjukkan adanya seasonal pada bulan tertentu.

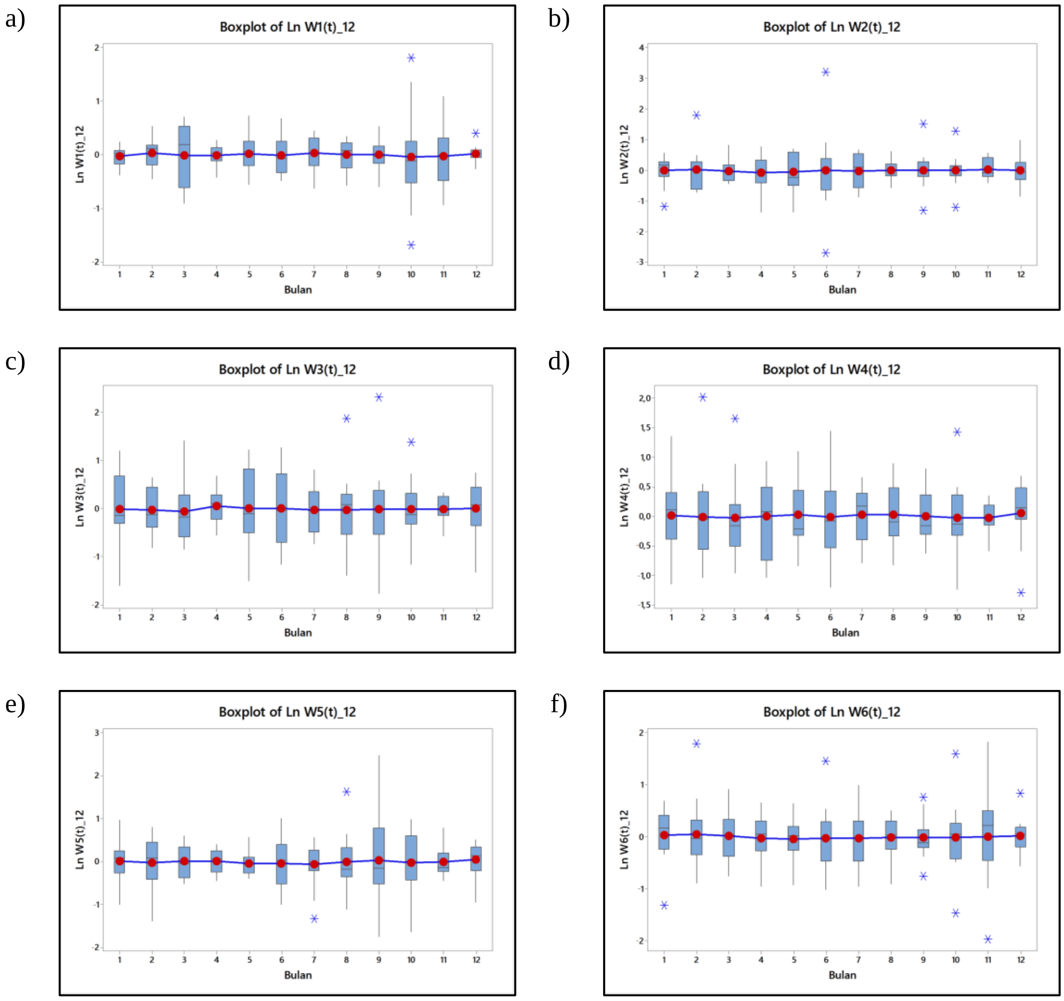

Gambar 4.4. Boxplot Inflasi dengan *Differencing* Musiman/Seasonal
(a) Pontianak (b) Sampit (c) Palangkaraya (d) Banjarmasin (e) Balikpapan (f) Samarinda

Kestasioneran dalam rata-rata ditunjukkan dengan tingkat rata-rata yang mendekati garis lurus untuk tiap wilayah. Selain stasioner dalam rata-rata, untuk bisa dilakukan pemodelan ARIMA maka perlu dilihat stasioner dalam varians.

Identifikasi kestasioneran data dalam varians dapat dilakukan dengan melihat plot Box-Cox pada Gambar 4.5 di bawah ini. Penggunaan Box-Cox untuk mengidentifikasi kestasioneran data dalam *varians* mensyaratkan data harus bernilai positif. Adapun dalam data inflasi terdapat data yang bernilai negatif. Untuk itu terlebih dahulu dilakukan transformasi data dengan menambahkan konstanta (suatu angka) terhadap *series* data inflasi di masing-masing wilayah agar diperoleh suatu deret data baru yang bernilai positif.

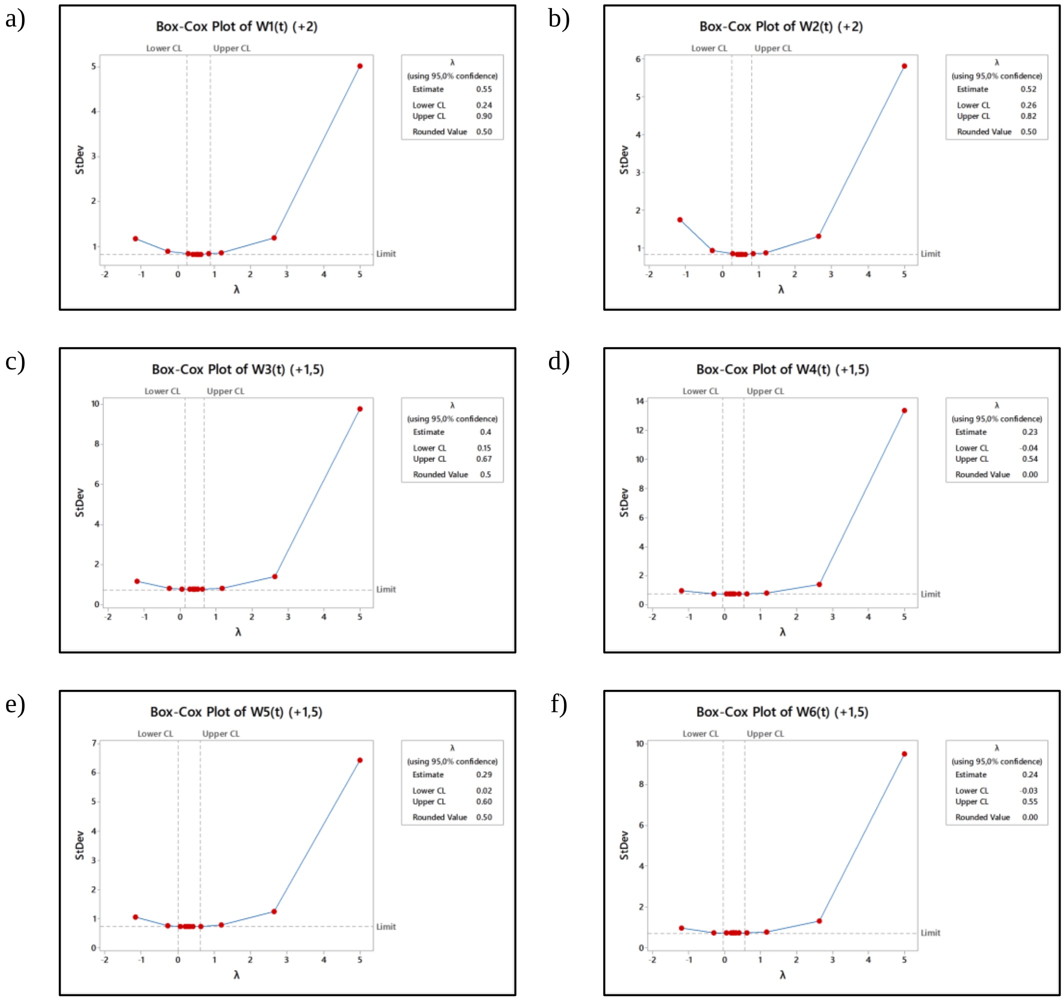

Gambar 4.5. Box-Cox Inflasi Setelah *Differencing* Musiman/Seasonal
(a) Pontianak (b) Sampit (c) Palangkaraya (d) Banjarmasin (e) Balikpapan (f) Samarinda

Berdasarkan Tabel 4.1 terlihat bahwa nilai minimum dari inflasi di tiap kota berbeda-beda, sehingga penambahan konstanta untuk mempositifkan data inflasi di tiap lokasi berbeda. Data inflasi di Pontianak dan Sampit dilakukan transformasi awal dengan menambahkan suatu konstanta bernilai 2, sedangkan untuk data inflasi pada Palangkaraya, Banjarmasin, Balikpapan dan Samarinda dilakukan transformasi awal dengan menambahkan suatu konstanta bernilai 1,5.

Hasil Box-Cox seperti pada Gambar 4.5 menunjukkan bahwa nilai *rounded value* Lambda pada masing-masing lokasi berbeda-beda dan belum memuat nilai satu. Hal ini menunjukkan bahwa data inflasi pada enam lokasi masih belum stasioner dalam varians. Dengan demikian data inflasi pada enam lokasi perlu dilakukan transformasi berdasarkan nilai Box-Cox. Untuk keseragaman dalam tahapan pemodelan *univariate* dan *multivariate* yang melibatkan antar wilayah (pengaruh *spatial*) maka dilakukan transformasi yang sama terhadap data inflasi pada enam kota yaitu dengan *logaritma natural* (*Ln*) terhadap data awal inflasi.

Adanya transformasi data dengan *logaritma natural* (*Ln*) akan menyebabkan struktur data dalam residual yang berkaitan dengan urutan deteksi *outlier* akan berubah. Untuk itu, pada penelitian ini terlebih dahulu akan dilakukan pemodelan dengan menggunakan data inflasi tanpa transformasi yang bertujuan uantuk mendeteksi adanya *outlier* dari residual sesuai deskripsi berdasarkan pada plot *time series* dari data inflasi enam kota. Adapun untuk pemodelan inflasi yang bertujuan untuk peramalan dalam penelitian ini akan digunakan data yang telah dilakukan transformasi untuk memenuhi kestasioneran data dalam rata-rata dan varians sesuai prosedur Box-Jenkins.

4.3. Pemodelan Inflasi Pontianak

4.3.1. Model ARIMA (Data Tanpa Transformasi)

Pada pemodelan ARIMA dengan menggunakan data tanpa transformasi dimaksudkan untuk mendeteksi adanya *outlier* yang sesuai dengan kondisi riil berdasarkan deskripsi dari plot *time series* data. Adanya *outlier* dalam pemodelan ARIMA inflasi bisa berdampak pada model yang tidak memenuhi asumsi residual yang mengikuti distribusi normal. Berdasarkan *outlier* yang terdeteksi juga bisa menjelaskan fenomena atau faktor yang menyebabkan terjadinya inflasi atau deflasi yang tinggi.

Pemodelan ARIMA dengan prosedur Box-Jenkins diawali dengan penentuan orde ARIMA berdasarkan plot ACF dan PACF dari data tersebut.

Berdasarkan plot ACF dan PACF (Gambar 4.6) dari data inflasi di Kota Pontianak, maka bisa ditentukan orde ARIMA. Penentuan orde ARIMA didasarkan lag-lag yang signifikan pada plot ACF dan PACF dari data inflasi.

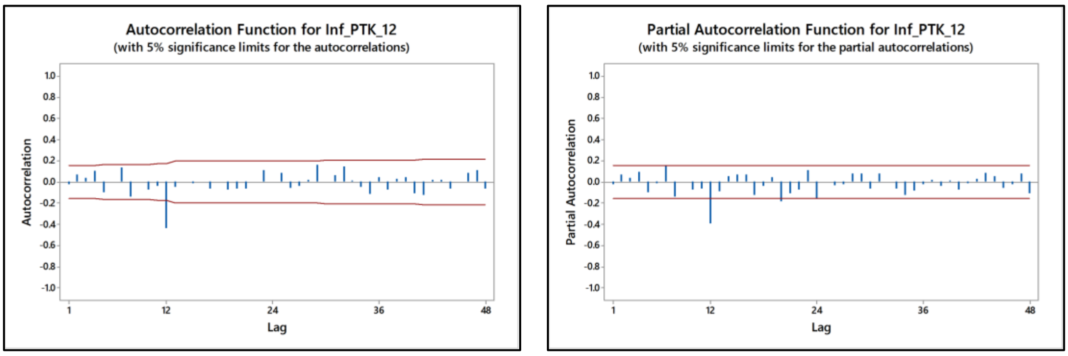

Gambar 4.6. Plot ACF dan PACF Inflasi Pontianak Setelah *Differencing* Musiman

Pada Gambar 4.6 memperlihatkan bahwa lag yang signifikan pada plot ACF maupun PACF terjadi pada lag 12 dan tidak adanya lag-lag non musiman yang signifikan. Hal ini bisa disimpulkan bahwa model ARIMA sementara untuk data inflasi Pontianak adalah ARIMA $(1,1,0)^{12}$ dan ARIMA $(0,1,1)^{12}$. Untuk menentukan model ARIMA yang akan digunakan, maka digunakan nilai AIC yang dihasilkan dari kedua model tersebut. Hasil nilai AIC seperti diperlihatkan pada Tabel 4.3 di bawah ini.

Tabel 4.3. Hasil Identifikasi dan Nilai AIC Model ARIMA Sementara Inflasi Pontianak

Model ARIMA Hasil Identifikasi	**AIC**	**Keterangan**
ARIMA $(1,1,0)^{12}$	450.352	-
ARIMA $(0,1,1)^{12}$	**438.318**	dipilih untuk pemodelan

Tabel 4.3 menunjukkan bahwa nilai AIC terkecil adalah model ARIMA $(0,1,1)^{12}$ dengan besaran 438.318. Hal ini menunjukkan bahwa berdasarkan kriteria nilai AIC terkecil maka model ARIMA $(0,1,1)^{12}$ merupakan model ARIMA terpilih untuk inflasi Pontianak. Hal yang sama (cara dan prosedur pemodelan) dilakukan terhadap penentuan model ARIMA pada wilayah lain seperti Sampit, Palangkaraya, Banjarmasin, Balikpapan dan Samarinda. Hasil

identifikasi model terbaik untuk model ARIMA pada enam wilayah seperti diperlihatkan pada Tabel 4.4 Adapun estimasi parameter dari model terpilih seperti bisa dilihat pada Tabel 4.5.

Tabel 4.4. Model ARIMA Inflasi Enam Kota di Kalimantan

Kota	Model ARIMA	RMSE	
		In-Sample	Out-Sample
Pontianak	$(0,1,1)^{12}$	0.983	0.769
Sampit	$(0,0,1)(0,1,1)^{12}$	1.161	0.505
Palangkaraya	$(0,0,1)(0,1,1)^{12}$	1.035	0.540
Banjarmasin	$(0,1,1)^{12}$	1.037	0.407
Balikpapan	$(0,1,1)^{12}$	1.011	0.723
Samarinda	$(0,0,[1,20])(0,1,1)^{12}$	0.998	0.600

Tabel 4.5. Hasil Estimasi Parameter Model ARIMA Inflasi Enam Kota di Kalimantan

Kota	**Model ARIMA**	**Parameter**	**Estimasi**	**Std. Error**	**P-*value***	**White Noise**	**KS (*p-value*)**
Ponti-anak	$(0,1,1)^{12}$	Θ_1	0.628	0.0657	<.0001	Ya	0.1096 (*0.0100*)
Sampit	$(0,0,1)(0,1,1)^{12}$	θ_1	-0.269	0.078	0.0007	Ya	0.0747 (*0.0325*)
		Θ_1	0.693	0.059	<.0001		
Palang-karaya	$(0,0,1)(0,1,1)^{12}$	θ_1	-0.168	0.080	0.0369	Ya	0.0909 (*<0.010*)
		Θ_1	0.758	0.055	<.0001		
Banjar-masin	$(0,1,1)^{12}$	Θ_1	0.758	0.055	<.0001	Ya	0.0626 (*0.1384*)
Balik-papan	$(0,1,1)^{12}$	Θ_1	0.680	0.060	<.0001	Ya	0.0626 (*0.1384*)
Sama-rinda	$(0,0,[1,20])(0,1,1)^{12}$	θ_1	-0.275	0.078	0.0005	Ya	0.1253 (*<0.010*)
		θ_{20}	0.226	0.081	0.0061		
		Θ_1	0.798	0.052	<.0001		

Estimasi parameter pada Tabel 4.5 bisa ditulis dalam bentuk persamaan model untuk masing-masing wilayah adalah sebagai berkut :

- ✓ Pontianak : $\dot{Y}_{1,t} = Y_{1,t-12} + a_{1,t} - 0.628\, a_{1,t-12}$
- ✓ Sampit : $\dot{Y}_{2,t} = Y_{2,t-12} + (1 + 0.269\, B)(1 - 0.693\, B^{12})\, a_{2,t}$
- ✓ Palangkaraya : $\dot{Y}_{3,t} = Y_{3,t-12} + (1 + 0.168\, B)(1 - 0.758\, B^{12})\, a_{3,t}$
- ✓ Banjarmasin : $\dot{Y}_{4,t} = Y_{4,t-12} + (1 - 0.758\, B^{12})\, a_{4,t}$
- ✓ Balikpapan : $\dot{Y}_{5,t} = Y_{5,t-12} + (1 - 0.680\, B^{12})\, a_{5,t}$
- ✓ Samarinda : $\dot{Y}_{6,t} = Y_{6,t-12} + (1 + 0.275\, B - 0.226\, B^{20})(1 - 0.798\, B^{12})\, a_{2,t}$

Hasil model ARIMA untuk data inflasi pada enam wilayah di Kalimantan pada Tabel 4.4 memberikan informasi bahwa semua parameter pada model signifikan pada taraf uji $\alpha = 0.05$. Meski demikian, model ARIMA yang terbentuk masih belum memenuhi asumsi residual yang mengikuti disribusi normal. Hal ini ditunjukkan pada nilai *p-value* dari uji Kolmogorov-Smirnov kurang dari tingkat taraf uji $\alpha = 0.05$. Adanya ketidaknormalan dari residual model disebabkan adanya *outlier*. Hasil deteksi *outlier* untuk masing-masing model per wilayah seperti pada Tabel 4.6 di bawah ini.

Tabel 4.6. Hasil Deteksi *Outlier* Model ARIMA Inflasi Enam Kota di Kalimantan (Observasi ke-*t*)

Pontianak (Data ke-*t*)	Sampit (Data ke-*t*)	Palangkaraya (Data ke-*t*)	Banjarmasin (Data ke-*t*)	Balikpapan (Data ke-*t*)	Samarinda (Data ke-*t*)
58	**58**	**58**	**58**	**58**	**58**
167	4	85	133	7	**151**
11	85	41	85	**151**	**90**
151	84	3	65	33	14
90	**90**	153	**90**	**90**	97
115	32	**90**	64	68	168
87	5	37	11	97	59
51	54	133	33	167	152
82	153	16	40	115	140
154	97	115	44	81	95

Pontianak (Data ke-*t*)	Sampit (Data ke-*t*)	Palangkaraya (Data ke-*t*)	Banjarmasin (Data ke-*t*)	Balikpapan (Data ke-*t*)	Samarinda (Data ke-*t*)
158	25	71	152	51	115
6	14	96	60	153	
147	19	68	**151**	46	
50	145	64	50	14	
89	12	94	51	59	
35	**151**	**151**	81	96	
143	41	65	115	5	
130	100	30	66	66	
164	86	141	6	94	
142	65	62	128	25	

Hasil deteksi *outlier* di atas menunjukkan bahwa pada data ke-58 merupakan data *outlier* yang sangat signifikan dan muncul pertama kali pada semua model ARIMA untuk data inflasi di masing-masing wilayah. *Series* data inflasi ke-58 merupakan kejadian inflasi pada bulan Oktober 2005. Pada pembahasan deskriptif inflasi telah disebutkan bahwa pada kurun waktu 2001-2014 inflasi tertinggi untuk enam kota di Kalimantan terjadi pada bulan Oktober 2005. Tingginya inflasi pada bulan tersebut sebagai dampak dari kebijakan pemerintah dalam menaikkan harga bahan bakar minyak (BBM) per 1 Oktober 2005. Kenaikan harga BBM dimaksud adalah pada jenis premium yang mengalami kenaikan harga lebih dari 85 persen dan jenis solar yang mencapai lebih dari 100 persen.

Deteksi *outlier* lain yang menunjukkan adanya inflasi yang cukup tinggi dan terjadi pada enam kota di Kalimantan adalah series inflasi ke-90 dan 151. Series data inflasi ke-90 merupakan kejadian inflasi pada Juni 2008, sedangkan series data inflasi ke-151 merupakan kejadian inflasi pada Juli 2013. Kejadian inflasi bulan Juni 2008 pada enam kota di Kalimantan karena bersumber dari dampak kenaikan harga BBM yang diberlakukan pada 24 Mei 2008. Kenaikan harga BBM yang mencapai rata-rata 28,7 persen dinilai memberikan kontribusi besar dalam peningkatan inflasi. Selain itu inflasi juga disebabkan adanya kenaikan indeks barang dan jasa di sektor makanan, minuman, perumahan, air listrik dan gas, sandang, kelompok kesehatan, pendidikan, rekreasi dan olahraga, transportasi, komunikasi dan jasa keuangan. Kenaikan indeks harga pada sektor pendidikan, rekreasi dan olahraga karena meningkatnya pengeluaran keluarga untuk pendidikan dan libur panjang anak sekolah.

Pada *series* inflasi ke-151 menunjukkan kejadian inflasi pada bulan Juli 2013 yang terjadi pada enam kota di Kalimantan. Terjadinya inflasi yang relatif tinggi pada bulan tersebut dipicu sebagai dampak lanjutan atas kenaikan BBM per 22 Juni 2013 khususnya untuk jenis premium dan solar. Hal lain yang mendorong adanya kenaikan inflasi bulan Juli 2013 karena pada bulan tersebut bertepatan dengan bulan puasa. Kenaikan harga selama puasa lebih disebabkan karena faktor permintaan yang meningkat khususnya untuk jenis bahan makanan. Penjelasan deteksi *outlier* yang lain untuk setiap lokasi bisa dilihat pada Tabel 4.7 berikut.

Tabel 4.7. Hasil Deteksi *Outlier* Model ARIMA Inflasi Enam Kota di Kalimantan dan Penjelasannya (Observasi ke-*i*)

Lokasi (Data ke-*t*)	**Bulan/Tahun Kejadian**	**Penjelasan**
Pontianak		
58	Oktober 2005	Sudah dijelaskan di atas.
167	November 2014	Kenaikan BBM (premium dan solar) pada 18 November 2014 yang memicu kenaikan indeks harga di sektor trasnportasi.
11	November 2001	Memasuki bulan puasa, berdampak pada kenaikan indeks harga khusunya pada kelompok bahan makanan.
151	Juli 2013	Sudah dijelaskan sebelumnya.
90	Juni 2008	Sudah dijelaskan sebelumnya.
115	Juli 2010	Kenaikan Tarif Dasar Listrik (TDL) rata-rata 10% mulai tanggal 1 Juli 2010 yang memicu kenaikan inflasi pada kelompok perumahan dan listrik.
87	Maret 2008	Kenaikan harga minyak goreng sebesar 19,83% di Pontianak dan merupakan kenaikan tertinggi secara nasional.
51	Maret 2005	Kebijakan kenaikan harga BBM per 01 Maret 2005 untuk premium (33%), solar (27%) dan minyak tanah (22%).
82	Oktober 2007	Kenaikan harga sebagai akibat meningkatnya permintaan menjelang perayaan hari raya Idul Fitri (12-13 Oktober 2007).

Lokasi (Data ke-*t*)	**Bulan/Tahun Kejadian**	**Penjelasan**
154	Oktober 2013	Kenaikan harga daging sapi sebagai dampak meningkatnya permintaan menjelang perayaan hari raya Idul Adha. Harga daging sapi mencapai Rp. 125.000 per Kg. Adanya kelangkaan pasokan gula pasir sehingga memicu kenaikan harga pada komoditas tersebut.
158	Februari 2014	Pontianak tercatat dengan Inflasi tertinggi se-Indonesia. Adanya faktor musiman yaitu menjelang perayaan Cap Go Meh yang memicu kenaikan permintaan masyarakat terhadap barang dan jasa. Disamping itu adanya cuaca ekstrem seperti curah hujan yang tinggi di sejumlah daerah sentra produksi komodiatas yang berpengaruh terhadap kondisi produksi dan juga menghambat distribusi barang akibat banjir.
Sampit		
58	Oktober 2005	Sudah dijelaskan di atas.
4	April 2001	Sampit tercatat mengalami Inflasi tertinggi se-Indonesia. Adanya kenaikan harga barang karena meningkatnya permintaan karena pasokan yang kurang lancar.
85	Januari 2008	Kenaikan harga pada sejumlah komoditas sebagai dampak dari gangguan pasokan barang dan jasa yang didatangkan dari luar Sampit dan Palangkaraya.
84	Desember 2008	Faktor musiman yaitu kenaikan harga barang menjelang perayaan natal dan tahun baru.
90	Juni 2008	Sudah dijelaskan sebelumnya.
153	September 2013	Penurunan indeks harga pada 2 kelompok pengeluaran yaitu kelompok bahan makan dan kelompok makanan jadi. Penurunan karena mulai normalnya harga barang pasca perayaan hari Raya Idul Fitri.
97	Januari 2009	Terjadi deflasi karena faktor musiman pasca perayaan natal dan tahun baru, harga sejumlah barang mengalami penurunan.
14	Februari 2002	Kenaikan harga pada sejumlah komoditas seperti beras, cabe merah, cabe rawit. Hal ini karena faktor *supply* yang kurang dalam memenuhi permintaan pasar.
19	Juli 2002	Adanya kenaikan dari sejumlah kmoditas barang seperti biaya pendidikan/uang sekolah SLTA, SLTP dan SD.
145	Januari 2013	Kenaikan harga sejumlah komoditas yang cukup signifikan seperti udang basah dan cabe rawit.
12	Desember 2001	Kenaikan harga karena meningkatnya permintaan barang dan jasa menjelang perayaan hari raya Idul Fitri.
151	Juli 2013	Sudah dijelaskan sebelumnya.
Palangka-raya		
58	Juli 2013	Sudah dijelaskan sebelumnya.

Lokasi (Data ke-*t*)	**Bulan/Tahun Kejadian**	**Penjelasan**
85	Januari 2008	Kenaikan harga pada sejumlah komoditas sebagai dampak dari gangguan pasokan barang dan jasa yang didatangkan dari luar Sampit dan Palangkaraya.
41	Mei 2004	Adanya pengaruh kenaikan harga minyak dunia dan melemahnya nilai tukar rupiah. Meskipun secara nasional kecil pengaruhnya, namun untuk tingkat distribusi barang sampai ke Kalimantan memberikan pengaruh terhadap kenaikan harga pada beberapa komoditas barang dan jasa terutama pada kelompok bahan makanan.
3	Maret 2001	Terjadi inflasi karena kenaikan
153	September 2013	Penurunan indeks harga pada 2 kelompok pengeluaran yaitu kelompok bahan makan dan kelompok makanan jadi. Penurunan karena mulai normalnya harga barang pasca perayaan hari Raya Idul Fitri.
90	Juni 2008	Sudah dijelaskan sebelumnya.
37	Januari 2004	Inflasi karena meningkatnya harga dari sejumlah kommoditas karena faktor distribusi atau supply barang yang terhambat.
133	Januari 2012	Kenaikan harga pada komoditi daging ayam ras dan jenis ikan khususnya ikan gabus karena pasokan atau *supply* barang di pasar terganggu karena tingkat curah hujan yang tinggi dibandingkan pada bulan sebelumnya.
16	April 2002	Terjadinya deflasi karena adanya penurunan harga pada sejumlah komoditas pokok seperti beras, daging ayam ras cabe rawit, telor dan ikan segar.
115	Juli 2010	Kenaikan Tarif Dasar Listrik (TDL) rata-rata 10% mulai tanggal 1 Juli 2010 yang memicu kenaikan inflasi pada kelompok perumahan dan listrik.
71	November 2006	Adanya kenaikan harga pada kelompok komoditas sayur-sayuran.yang mencapai 8,01 persen, terutama komoditas kentang dan bawang putih.
96	Desember 2008	Faktor musiman yaitu kenaikan harga barang menjelang perayaan natal dan tahun baru.
68	Agustus 2006	Terjadinya deflasi yang lebih tinggi pada kelompok bahan makanan dibandingkan adanya kenaiakan harga (inflasi) pada kelompok pendidikan memberikan pengaruh pada terjadinya deflasi di Palangkaraya. Secara nasional, inflasi pada Agustus 2006 tercatat yang terendah.
64	April 2006	Inflasi karena adanya kenaikan harga pada kelompok makanan jadi. Inflasi Palangkaraya pada bulan ini merupakan tertinggi kedua di wilayah Kalimantan setelah Banjarmasin..

Lokasi (Data ke-*t*)	**Bulan/Tahun Kejadian**	**Penjelasan**
94	Oktober 2008	Palangkaraya merupakan kota inflsi tertinggi se-Indonesia pada bulan Oktober 2008. Terjadinya kenaikan permintaan terhadap barang dan jasa pada bulan perayaan hari Raya Idul Fitri pada berdampak pada meningkatnya harga pada sejumlah komoditas bahan makanan seperti ikan patin, daging ayam ras, beras, kacang panjang dan ikan mas.
151	Juli 2013	Sudah dijelaskan sebelumnya.
Banjar-masin		
58	Oktober 2005	Sudah dijelaskan sebelumnya.
133	Januari 2012	Inflasi tertinggi se-Indonesia karena pengaruh kenaikan harga bahan makanan seperti beras, daging ayam ras dan ikan segar.
85	Januari 2008	Secara nasional, inflasi Januari 2008 merupakan inflasi tertinggi selama 4 tahun terakhir. Khusus Januari, inflasi selalu di atas satu, karena selain faktor internal seperti distribusi, juga karena faktor global seperti kenaikan kedelai dan beras. Di samping itu harga minyak tanah yang meningkat secara nasional (14,69 persen).
65	Mei 2006	Terjadinya kenaikan harga pada kelompok bahan makanan seperti beras, bawang putih, daging ayam ras.
90	Juni 2008	Sudah dijelaskan sebelumnya.
64	April 2006	Inflasi karena adanya kenaikan harga pada kelompok makanan jadi. Inflasi Banjarmasin pada bulan ini merupakan tertinggi se-Indonesia.
11	November 2001	Memasuki bulan puasa, berdampak pada kenaikan indeks harga khusunya pada kelompok bahan makanan.
33	September 2003	Banjarmasin pada bulan ini tercatat mengalami inflasi tertinggi kedua setelah Balikapapan. Hal ini karena faktor kenaikan harga pada kelompok makanan jadi, perumahan, dan sandang.
40	April 2004	Kenaikan harga sejumlah komoditas berupa bahan makan dan makanan jadi. Selain itu tidak bisa dijelaskan apakah ada kaitannya dengan pemilu, karena kondisinya sama dengan April 1999 yang bertepatan dengan pemilu, dimana pada saat itu juga mengalami inflasi yang tidak kecil.
44	Agustus 2004	Inflasi karena kenaikan harga pada kelompok bahan makanan.
152	Agustus 2013	Inflasi karena faktor musiman, karena adanya perayaan hari raya Idul Fitri. kenaikan pada sejumlah barang dan jasa akibat meningkatnya permintaan seperti transportasi, rekreasi

Lokasi (Data ke-*t*)	**Bulan/Tahun Kejadian**	**Penjelasan**
60	Desember 2005	Faktor musiman yaitu kenaikan harga barang menjelang perayaan natal dan tahun baru.
151	Juli 2013	Sudah dijelaskan sebelumnya.
50	Februari 2005	Terjadi deflasi karena adanya penuruanan harga pada sejumlah kelompok pengeluaran seperti bahan makanan. Umumnya inflasi akan landai sampai masuk pada bulan Juni yang mulai meningkat karena libur anak sekolah.
51	Maret 2005	Kebijakan kenaikan harga BBM per 01 Maret 2005 untuk premium (33%), solar (27%) dan minyak tanah (22%).
81	September 2007	Kenaikan harga karena meningkatnya permintaan selama bulan puasa, terutama pada kelompok pengeluaran bahan makanan dan makanan jadi.
115	Juli 2010	Kenaikan Tarif Dasar Listrik (TDL) rata-rata 10% mulai tanggal 1 Juli 2010 yang memicu kenaikan inflasi pada kelompok perumahan dan listrik.
66	Juni 2006	Inflasi karena faktor musiman memasuki masa libur anak sekolah dan menjelang tahun ajaran baru.
6	Juni 2001	Kebijakan kenaikan harga BBM seperti premium (26%), solar (50%) dan minyak tanah yang diberlakukan mulai 16 Juni 2001.
128	Agustus 2011	Kenaikan harga karena meningkatnya harga sejumlah akibat meningkatnya permintaan selama bulan puasa dan menjelang perayaan hari raya Idul Fitri (30-31 Agustus 2011).
Balik-papan		
58	Juli 2013	Sudah dijelaskan sebelumnya.
7	Juli 2001	Inflasi musiman di sektor pendidikan, selain itu dampak dari kenaikan harga BBM pada pertengahan bulan Juni.
151	Juli 2013	Sudah dijelaskan sebelumnya.
33	September 2003	Balikpapan pada bulan ini tercatat mengalami inflasi tertinggi se-Indonesia. Hal ini karena faktor kenaikan harga pada kelompok makanan jadi, perumahan, dan sandang.
90	Juni 2008	Sudah dijelaskan sebelumnya.
68	Agustus 2006	Terjadinya deflasi pada kelompok bahan makanan dibandingkan adanya kenaiakan harga (inflasi) pada kelompok pendidikan memberikan pengaruh pada terjadinya deflasi di Balikpapan. Secara nasional, inflasi pada Agustus 2006 tercatat yang terendah.
97	Januari 2009	Inflasi karena kenaikan sejumlah barang dan jasa yang dipengaruhi faktor musiman seperti sayuran, ayam,

Lokasi (Data ke-*t*)	Bulan/Tahun Kejadian	Penjelasan
		cabai dan bawang karena faktor minimnya pasokan.
167	November 2014	Kenaikan BBM (premium dan solar) pada 18 November 2014 yang memicu kenaikan indeks harga di sektor trasnportasi.
115	Juli 2010	Kenaikan Tarif Dasar Listrik (TDL) rata-rata 10% mulai tanggal 1 Juli 2010 yang memicu kenaikan inflasi pada kelompok perumahan dan listrik.
81	September 2007	Kenaikan harga karena meningkatnya permintaan selama bulan puasa, terutama pada kelompok pengeluaran bahan makanan dan makanan jadi.
51	Maret 2005	Kebijakan kenaikan harga BBM per 01 Maret 2005 untuk premium (33%), solar (27%) dan minyak tanah (22%).
153	September 2013	Penurunan indeks harga pada 2 kelompok pengeluaran yaitu kelompok bahan makan dan kelompok makanan jadi. Penurunan karena mulai normalnya harga barang pasca perayaan hari Raya Idul Fitri.
46	Oktober 2004	Kenaikan harga karena meningkatnya permintaan barang dan jasa menjelang atau memasuki bulan puasa.
59	November 2005	Inflasi karena faktor musiman, karena adanya perayaan hari raya Idul Fitri. Kenaikan pada sejumlah barang dan jasa akibat meningkatnya permintaan seperti kelompok pengeluaran bahan makanan, transportasi khususnya angkutan dalam kota.
96	Desember 2008	Faktor musiman yaitu kenaikan harga barang menjelang perayaan natal dan tahun baru.
66	Juni 2006	Inflasi karena faktor musiman memasuki masa libur anak sekolah dan menjelang tahun ajaran baru.
94	Oktober 2008	Terjadinya kenaikan permintaan terhadap barang dan jasa pada bulan perayaan hari Raya Idul Fitri pada berdampak pada meningkatnya harga pada sejumlah komoditas bahan makanan seperti ikan patin, daging ayam ras, beras, kacang panjang dan ikan mas.
25	Januari 2003	Kenaikan harga pada beberapa komoditas seperti minyak tanah, beras sayur mayur, harga rokok dan tembakau.
Sama-rinda		
58	Oktober 2005	Sudah dijelaskan sebelumnya.
151	Juli 2013	Sudah dijelaskan sebelumnya.
90	Juni 2008	Sudah dijelaskan sebelumnya.
14	Februari 2002	Kenaikan harga pada sejumlah komoditas seperti beras, cabe merah, cabe rawit. Hal ini karena faktor *supply* yang kurang dalam memenuhi permintaan pasar.

Lokasi (Data ke-*t*)	Bulan/Tahun Kejadian	Penjelasan
97	Januari 2009	Inflasi karena kenaikan sejumlah barang dan jasa yang dipengaruhi faktor musiman seperti sayuran, ayam, cabai dan bawang karena faktor minimnya pasokan.
168	Desember 2014	Kenaikan harga karena faktor musiman yaitu perayaan Natal dan libur akhir tahun.
59	November 2005	Inflasi karena faktor musiman, karena adanya perayaan hari raya Idul Fitri. Kenaikan pada sejumlah barang dan jasa akibat meningkatnya permintaan seperti kelompok pengeluaran bahan makanan, transportasi khususnya angkutan dalam kota.
152	Agustus 2013	Inflasi karena faktor musiman, karena adanya perayaan hari raya Idul Fitri. kenaikan pada sejumlah barang dan jasa akibat meningkatnya permintaan seperti transportasi, rekreasi
140	Agustus 2012	Kenaikan harga pada saat bulan puasa dan menjelang hari raya Idul Fitri
95	November 2008	Terjadinya deflasi karena penyediaan bahan pokok terutama pangan cukup memadai sehingga dalam bidang pangan.
115	Juli 2010	Kenaikan Tarif Dasar Listrik (TDL) rata-rata 10% mulai tanggal 1 Juli 2010 yang memicu kenaikan inflasi pada kelompok perumahan dan listrik.

Dengan banyaknya *outlier* yang terdeteksi pada model untuk setiap wilayah, hal ini akan memberikan dampak pada residual dari setiap model tidak mengikuti distribusi normal. Pada pemodelan selanjutnya yang bertujuan untuk peramalan, maka penggunaan deteksi *outlier* hanya dibatasi untuk mengatasi asumsi kelayakan model yaitu agar residual model sudah mengikuti distribusi normal, sehingga model yang diperoleh layak digunakan untuk peramalan.

Pada pembentukan model univariat dan multivariat selanjutnya digunakan data yang telah stasioner dalam rata-rata dan varians. Hal ini untuk memenuhi syarat prosedur Box-Jenkins seperti telah dijelaskan sebelumnya.

4.3.2. Model ARIMA

Langkah awal dalam pemodelan ARIMA setelah terpenuhinya kestasioneran data dalam rata-rata atau varians, maka dilakukan identifikasi untuk menentukan orde model ARIMA yang sesuai. Penentuan orde ARIMA didasarkan lag-lag yang signifikan pada plot ACF dan PACF dari data inflasi hasil transformasi dan *differencing* musiman.

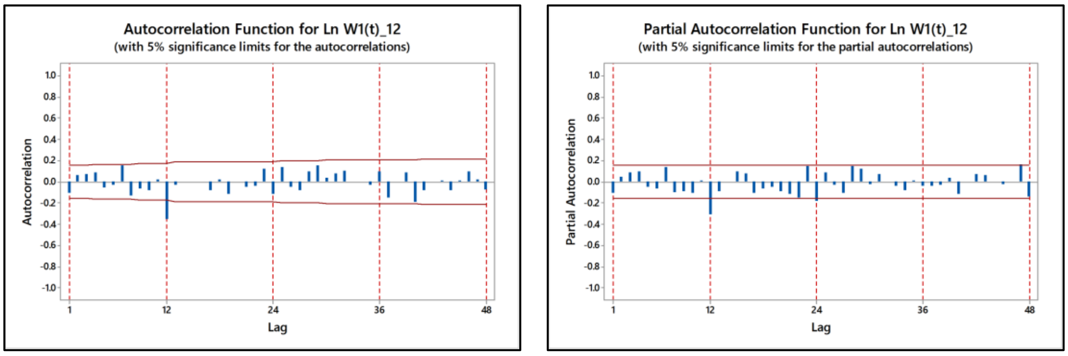

Gambar 4.7. Plot ACF dan PACF Inflasi Pontianak Hasil Transformasi dan *Differencing* Musiman

Pada Gambar 4.7 bisa diidentifikasi bahwa lag yang signifikan pada plot ACF terjadi pada lag 12, sedangkan pada plot PACF terjadi pada lag 12 dan 24. Berdasarkan identifikasi lag yang signifikan tersebut, menunnjukkan tidak adanya lag-lag non musiman yang signifikan, sedangkan lag yang signifikan terdapat pada lag musiman 12 dan 24 dimana untuk pola ACF bersifat *cut off* pada lag 12 (lag 1 pada musiman 12), sedangkan PACF bersifat *dies down*, sehingga bisa disimpulkan bahwa model ARIMA inflasi untuk Pontianak adalah ARIMA $(0,0,0)(0,1,1)^{12}$ atau $(0,1,1)^{12}$. Selanjutnya dilihat estimasi parameter untuk pemodelan inflasi pontianak. Hasil pengujian parameter untuk model tersebut dapat dilihat pada Tabel 4.8.

Tabel 4.8. Hasil Estimasi Parameter Model ARIMA Inflasi Pontianak

Model ARIMA	**Parameter**	**Estimasi**	**Standar Error**	**P-value**
$(0,1,1)^{12}$	Θ_1	0.60002	0.06693	<.0001

Berdasarkan hasil estimasi di atas menunjukkan bahwa dengan taraf signifikansi $\alpha = 0.05$ parameter model ARIMA memiliki nilai *p-value* kurang dari 0.05 sehingga parameter tersebut bisa digunakan dalam model. Secara matematis, model ARIMA $(0,1,1)^{12}$ bisa ditulis sebagai berikut :

$$\dot{y}_{1,t} = y_{1,t-12} + a_{1,t} - 0.60002\, a_{1,t-12}$$

dengan $\dot{y}_{1,t} = y_{1,t} - \mu$, dan $y_{1,t} = \mathrm{Ln}(\mathrm{Y}_{1,t} + 2)$

Langkah selanjutnya adalah melakukan *diagnostic checking* untuk melihat kelayakan model yaitu residual memenuhi asumsi *white noise* dan berdistribusi normal. Taraf signifikansi yang digunakan sebesar $\alpha = 0.05$. hasil pengujian asumsi residual *white noise* dapat dilihat pada Tabel 4.9.

Tabel 4.9. Hasil Uji Asumsi *White Noise* dan Normalitas ARIMA $(0,1,1)^{12}$ Inflasi Pontianak

Uji *White Noise*				**Uji Kenormalan**	
Lag	**Chi-Square**	**DF**	**Pr >ChiSq**	KS	*P-Value*
6	2.13	5	0.8305	0.089445	< 0.0100.
12	10.59	11	0.4781		
18	12.15	17	0.7911		
24	19.95	23	0.6449		
30	26.51	29	0.5981		

Hasil uji di atas menunjukkan bahwa nilai autokorelasi residual model ARIMA $(0,1,1)^{12}$ memiliki *p-value* yang lebih besar dari 0.05 yang berarti bahwa tidak terdapat korelasi antar lag sehingga asumsi residual *white noise* sudah terpenuhi. Adapun untuk uji normalitas *residual* pada model ARIMA $(0,1,1)^{12}$ menunjukkan bahwa uji asumsi dengan Kolmogorov-Smirnov menghasilkan nilai uji sebesar 0.089445 dengan nilai *p-value* kurang dari 0.0100. Ini berarti pada pada taraf uji $\alpha = 0.05$ menunjukkan bahwa model ARIMA $(0,1,1)^{12}$ belum memenuhi asumsi residual mengikuti distribusi normal.

Tabel 4.10. Hasil Deteksi *Outlier* Model ARIMA $(0,1,1)^{12}$ Inflasi Pontianak

Observasi	**Tipe**	**Estimasi Efek Outlier**	**Chi-Square**	***p-value***
130	Additive	-1.49068	39.81	<.0001
142	Additive	-1.47654	38.58	<.0001
58	Additive	1.2845	29.87	<.0001
155	Additive	-0.82606	11.64	0.0006
107	Additive	-0.81694	12.45	0.0004

Ketidaknormalan residual salah satunya disebabkan adanya data *outlier*, sehingga deteksi *outlier* pada model dapat dilakukan untuk menyelesaikan permasalahan tersebut. Hasil deteksi *outlier* pada model ARIMA $(0,1,1)^{12}$ seperti terlihat pada Tabel 4.10. Hasil deteksi *outlier* pada model ARIMA $(0,1,1)^{12}$ menunjukkan adanya data *outlier* pada data observasi ke-130, 142, 58, 155 dan 107 dengan tipe AO (*Additive Outlier*).

Terdapat 3 observasi yang memilki nilai *Chi-Square* tinggi yaitu pada pengamatan data ke 130, 142 dan 58. Pada pengamatan 130 dan 142 bernilai negatif, ini menunjukkan adanya deflasi yang terjadi pada bulan Oktober 2011 dan Oktober 2012. Adanya deflasi pada kedua bulan tersebut karena adanya penurunan indeks harga pada beberapa komoditi khususnya makanan dan transportasi pasca perayaan Idul Fitri. Adapun pada observasi ke-58 bernilai positif yang berarti terjadinya inflasi yang terjadi pada bulan Oktober 2005. Inflasi pada bulan Oktober 2005 disebabkan adanya kebijakan pemerintah dalam meningkatkan harga BBM per 01 Oktober 2005 sebagai akibat pengurangan subsidi Bahan Bakar Minyak (BBM).

Oleh karena itu, estimasi parameter model ARIMA $(0,1,1)^{12}$ dilanjutkan dengan menambahkan deteksi *outlier* secara iteratif satu persatu. Hasil estimasi parameter model dengan melibatkan deteksi *outlier* secara iteratif dapat dilihat pada Tabel 4.11.

Tabel 4.11. Hasil Estimasi Parameter Model ARIMA dengan Deteksi *Outlier* Inflasi Pontianak

Parameter	**Tipe Outlier**	**Estimasi**	**Standar Error**	**P-value**
Θ_1	-	0.60534	0.06941	<.0001
ω_{AO130}	AO	-1.80492	0.27799	<.0001
ω_{AO142}	AO	-1.53323	0.27988	<.0001
ω_{AO58}	AO	1.27422	0.26903	<.0001

Hasil estimasi parameter model ARIMA $(0,1,1)^{12}$ dengan melibatkan deteksi outlier pada ketiga pengamatan menunjukkan bahwa dengan taraf signifikansi $\alpha = 0.05$ parameter model ARIMA memiliki nilai *p-value* kurang dari 0.05 sehingga parameter tersebut bisa digunakan dalam model. Tahap berikutnya adalah menguji kelayakan model dengan menggunakan uji *white noise* dan uji normalitas pada residual dengan menggunakan uji Kolmogorov-Smirnov.

Tabel 4.12. Hasil Uji *Residual White Noise* Model ARIMA $(0,1,1)^{12}$ Inflasi Pontianak dengan Deteksi *Outlier*

Lag	**Chi-Square**	**DF**	**Pr >ChiSq**
6	1.51	5	0.9114
12	8.39	11	0.6778
18	12.26	17	0.7841
24	14.06	23	0.9251
30	19.77	29	0.9001

Hasil uji menunjukkan bahwa nilai autokorelasi residual model ARIMA $(0,1,1)^{12}$ memiliki *p-value* yang lebih besar dari 0.05 yang berarti bahwa tidak terdapat korelasi antar lag sehingga asumsi residual *white noise* sudah terpenuhi. Adapun untuk hasil uji Kolmogorov-Smirnov menghasilkan nilai uji sebesar 0.063013 dengan *p-value* sebesar 0,1322. Ini berarti pada taraf uji $\alpha = 0.05$ maka model ARIMA $(0,1,1)^{12}$ dengan deteksi outlier tersebut sudah memenuhi asumsi bahwa residual pada model mengikuti distribusi normal.

Dengan melihat nilai AIC ARIMA $(0,1,1)^{12}$ dengan deteksi *outlier* dan RMSE *in-sample*, maka model ARIMA dengan menyertakan deteksi *outlier* merupakan model terbaik karena memiliki nilai AIC atau RMSE yang terkecil seperti pada Tabel 4.13.

Tabel 4.13. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan ARIMA Inflasi Pontianak

Model ARIMA	**AIC**	**RMSE *in-sample***
ARIMA $(0,1,1)^{12}$	133.6268	0.3702
ARIMA $(0,1,1)^{12}$ dengan deteksi *outlier*	70.90275	0.29989

Secara matematis, model ARIMA $(0,1,1)^{12}$ dengan deteksi outlier bisa ditulis sebagai berikut :

$$\dot{y}_{1,t} = y_{1,t-12} - 1.805\, I_t^{T=130} - 1.533\; I_t^{T=142} + 1.274\; I_t^{T=58}\, a_{1,t} - 0.605\, a_{1,t-12}$$

dengan $\dot{y}_{1,t} = y_{1,t} - \mu$, dan $y_{1,t} = \mathrm{Ln}(\mathrm{Y}_{1,\mathrm{t}} + 2)$

4.3.3. Model Variasi Kalender

Pemodelan ARIMAX dalam hal ini melibatkan variabel eksogen non metrik berupa variasi kalender dan variabel eksogen metrik dalm bentuk fungsi transfer. Dalam pola data berdasarkan plot *time series* dari inflasi, terdapat data yang berupa pencilan (*outlier*) yang diduga adanya suatu kejadian berupa kejutan atau sering dinamakan suatu intervensi, sehingga untuk pembahasan intervensi akan diintegrasikan dengan pemodelan yang melibatkan adanya deteksi *outlier* pada variasi kalender ataupun fungsi transfer.

Pembentukan model variasi kalender inflasi menggunakan variabel *dummy*. variabel *dummy* yang digunakan dalam variasi kalender adalah dummy *bulanan* dan *mingguan*. *Dummy* bulanan yang dibentuk adalah D_t yang menyatakan efek variasi kalender yang terjadi pada bulan yang terdapat Hari Raya Idul Fitri dan D_{t-1} menyatakan satu bulan sebelum Hari Raya Idul Fitri. Adapun *dummy* mingguan yang ditulis $D_{1,t}$, $D_{2,t}$, $D_{3,t}$ dan $D_{4,t}$ menyatakan efek variasi kalender yang terjadi pada bulan terdapat Hari Raya Idul Fitri jika hari raya terjadi pada minggu ke-1, 2, 3, dan 4. Sedangkan *dummy* yang ditulis $D_{1,t-1}$, $D_{2,t-1}$, $D_{3,t-1}$, $D_{4,t-1}$. menyatakan efek variasi kalender yang terjadi pada 1 bulan sebelum bulan terdapat Hari Raya Idul Fitri jika hari raya terjadi pada minggu ke-1, 2, 3, dan 4.

Model ARIMA untuk variasi kalender menggunakan model ARIMA yang terbaik yang telah dijelaskan sebelumnya untuk masing-masing wilayah. Namun demikian ada kemungkinan menggunakan model ARIMA lain karena faktor ketidaknormalan dalam residual akibat adanya data *outlier*, sehingga memungkinkan model ARIMA bisa berubah. Dalam penyajiannya model ARIMA dengan variasi kalender bulanan dan mingguan menggunakan model *restricted* dimana estimasi parameter yang ada pada model sudah signifikan pada taraf signifikansi $\alpha = 0.05$ sampai $\alpha = 0.10$.

Model variasi kalender bulanan untuk inflasi Pontianak yang terbentuk seperti ditunjukkan pada Tabel 4.14 di bawah ini.

Tabel 4.14. Hasil Estimasi Parameter Variasi Kalender Bulanan Inflasi Pontianak

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
$(0,1,1)^{12}$	Θ_1	0.72477	0.06031	<.0001	Ya	0.081941 (*0.0113*)
	D_{t-1}	0.38058	0.10833	0.0006		
	D_t	0.3432	0.10887	0.0019		
$(0,1,1)^{12}$ Dengan Deteksi Outlier	Θ_1	0.67829	0.06645	<.0001	Ya	0.05911 (*>0.1500*)
	D_{t-1}	0.23641	0.09334	0.0123		
	D_t	0.28709	0.09102	0.0019		
	ω_{AO130}	-1.75437	0.27533	<.0001		
	ω_{AO142}	-1.48762	0.27738	<.0001		
	ω_{AO58}	1.2161	0.27546	<.0001		

Hasil estimasi di atas memperlihatkan bahwa dengan menggunakan taraf uji $\alpha = 0.05$, maka parameter model ARIMA $(0,1,1)^{12}$ dengan variasi kalender bulanan memiliki nilai *p-value* kurang dari 0.05 sehingga parameter tersebut dikatakan signifikan dan bisa digunakan dalam model. Berdasarkan uji asumsi untuk menentukan kelayakan suatu model, terlihat bahwa model variasi kalender dengan deteksi outlier telah memenuhi asumsi residual *white noise* dan mengikuti distribusi normal. Berdasarkan pada Tabel 4.14 di atas, menunjukkan pada model deteksi *outlier* terdapat 3 buah *outlier* yang sebelumnya telah dijelaskan pada pemodelan ARIMA.

Dengan menggunakan kriteria nilai AIC dan RMSE *in-sample* terkecil, maka model variasi kalender bulanan dengan deteksi *outlier* merupakan model terbaik seperti ditunjukkan pada Tabel 4.15.

Tabel 4.15. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan Variasi Kalender (Bulanan) Inflasi Pontianak

Model ARIMA Variasi Kalender	**AIC**	**RMSE *in-sample***
$(0,1,1)^{12}$	124.1627	0.3568
$(0,1,1)^{12}$ dengan deteksi *outlier*	63.5630	0.2911

Dengan demikian model ARIMA dengan variasi kalender bulanan yang melibatkan deteksi *outlier* bisa digunakan untuk melakukan peramalan inflasi di Pontianak. Secara matematis, model tersebut bisa ditulis sebagai berikut :

$$\dot{y}_{1,t} = 0.2364\ D_{t-1} + 0.2871\ D_t + -1.7544\ I_t^{T=130} - 1.4876\ I_t^{T=142} + 1.2161\ \ I_t^{T=58} + y_{1,t-12} + (1 - 0.6783\ B^{12})a_{1,t}$$

dengan $\dot{y}_{1,t} = y_{1,t} - \mu$, dan $y_{1,t} = \mathrm{Ln}(\mathrm{Y}_{1,\mathrm{t}} + 2)$

Berdasarkan model persamaan tersebut menunjukkan bahwa kejadian pada bulan dimana terdapat perayaan Hari Raya Idul Fitri serta satu bulan sebelum perayaan Idul Fitri memberikan pengaruh terhadap inflasi di Pontianak. Faktor lain seperti adanya intervensi juga berpengaruh pada besar kecilnya inflasi di Pontianak. Ini ditunjukkan dengan adanya data deteksi *outlier* pada waktu *T*=58 dalam model yang merupakan terjadinya kebijakan keniakan harga BBM pada bulan Oktober 2005. Adapun model variasi kalender dengan *dummy* mingguan seperti ditunjukkan pada Tabel 4.16.

Tabel 4.16. Hasil Estimasi Parameter Variasi Kalender Mingguan Inflasi Pontianak

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
CV-ARIMA $(0,1,1)^{12}$	Θ_1	0.7411	0.05991	<.0001	Ya	0.08809 (*<0.0100*)
	$D_{1,t-1}$	0.70872	0.19602	0.0004		
	$D_{2,t-1}$	0.34834	0.16998	0.0422		
	$D_{3,t-1}$	0.59409	0.17693	0.001		
	$D_{2,t}$	0.38765	0.17072	0.0246		
	$D_{3,t}$	0.36247	0.16787	0.0324		
	$D_{4,t}$	0.42942	0.17474	0.0151		

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	White Noise	KS (*p-value*)
CV-ARIMA $(0,1,1)^{12}$ Dengan Deteksi Outlier	Θ_1	0.71637	0.06421	<.0001	Ya	0.062128 (*0.1448*)
	$D_{2,t-1}$	0.29993	0.13835	0.0318		
	$D_{3,t-1}$	0.45694	0.14393	0.0018		
	$D_{2,t}$	0.29822	0.13859	0.0331		
	$D_{3,t}$	0.32231	0.13972	0.0225		
	$D_{4,t}$	0.35655	0.14216	0.0132		
	ω_{AO130}	-1.78887	0.27474	<.0001		
	ω_{AO142}	-1.51387	0.2769	<.0001		
	ω_{AO58}	1.41923	0.26955	<.0001		

Hasil estimasi di atas memperlihatkan dengan model ARIMA $(0,1,1)^{12}$ deteksi *outlier* merupakan model yang telah memenuhi asumsi kelayakan model yaitu residual yang *white noise* dan mengikuti distribusi normal. Selain itu dengan menggunakan kriteria nilai AIC dan RMSE *in-sample* terkecil, maka model variasi kalender mingguan dengan deteksi *outlier* merupakan model terbaik yang bisa digunakan untuk melakukan peramalan inflasi di Pontianak dengan variabel eksogen *dummy* variasi kalender. Adapun nilai AIC atau RMSE seperti ditunjukkan pada Tabel 4.17.

Tabel 4.17. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan Variasi Kalender Mingguan Inflasi Pontianak

Model ARIMA Variasi Kalender	AIC	RMSE *in-sample*
ARIMA $(0,1,1)^{12}$	122.7357	0.3508
ARIMA $(0,1,1)^{12}$ dengan deteksi *outlier*	62.65915	0.287628

Secara matematis, model ARIMA variasi kalender mingguan dengan deteksi *outlier* di atas bisa ditulis sebagai berikut :

$$\dot{y}_{1,t} = 0.299\, D_{2,t-1} + 0.457 D_{3,t-1} + 0.298\, D_{2,t} + 0.322 D_{3,t} + 0.356 D_{4,t} - 1.788\, I_t^{T=130}$$
$$-1.513\, I_t^{T=142} + 1.419\; I_t^{T=58} + y_{1,t-12} + (1 - 0.716\, B^{12}) a_{1,t}$$

dengan $\dot{y}_{1,t} = y_{1,t} - \mu$, dan $y_{1,t} = \mathrm{Ln}(\mathrm{Y}_{1,t} + 2)$.

4.3.4. Model Fungsi Transfer

Model ARIMA yang melibatkan variabel eksogen (*input*) dengan berskala metrik dikenal sebagai model fungsi transfer. Variabel eksogen yang digunakan dalam penelitian ini adalah curah hujan. Beberapa tahapan dalam pemodelan fungsi transfer yaitu tahap identifikasi yang meliputi pemodelan ARIMA data input *series*, proses *prewhitening* data input *series* dengan output *series*, penghitungan CCF, dan penentuan orde model fungsi ARIMA residual, tahapan estimasi parameter, tahapan checking diagnosa model, dan tahapan peramalan.

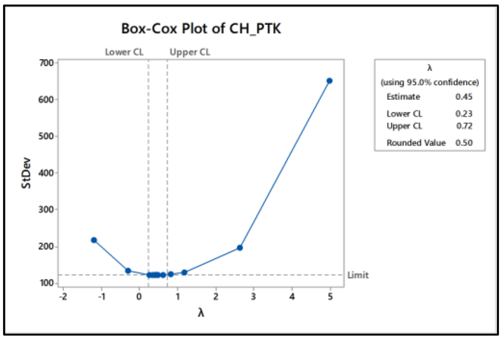

Gambar 4.8. Plot BoxCox dari Data Input Curah Hujan Pontianak

Pada tahap pembentukan model ARIMA untuk variabel input, terlebih dahulu dilakukan identifikasi stasioneritas data dalam varians maupun rata-rata. Hasil plot Box-Cox di atas menunjukkan bahwa data curah hujan belum menunjukkan stasioner dalam varian. Nilai *lambda* masih belum mencapai angka satu dan hanya menunjukkan angka 0.05. Hal ini berarti data curah hujan perlu dilakukan transformasi dengan melakukan akar kuadrat dari data asli.

Setelah data stasioner dalam varians, maka dilakukan identifikasi stasioner dalam rata-rata. Berdasarkan Gambar 4.9 di atas pada bagian (a) memperlihatkan bahwa rata-rata curah hujan masih belum stasioner dalam rata-rata. Boxplot tersebut juga menunjukkan bahwa adanya pola musiman dari rata-rata pada bulan yang sama. Sehingga untuk menstasionerkan dilakukan *differencing* musiman ($D = 1$).

a) b)

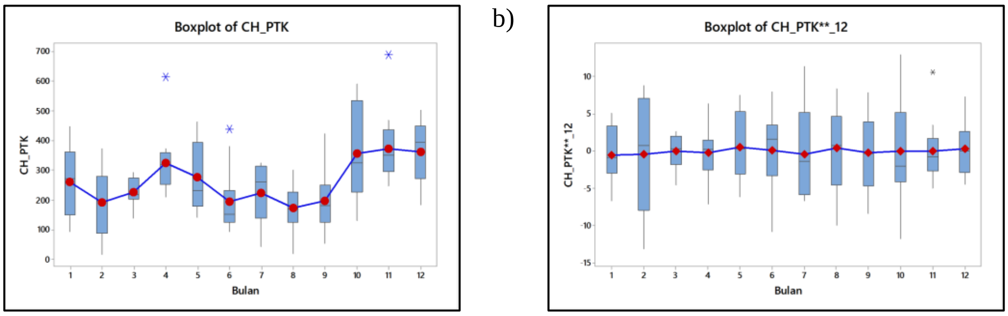

Gambar 4.9. Boxplot Curah Hujan di Pontianak
(a) Sebelum dilakukan Differencing (b) Setelah dilakukan Differencing

Pada Gambar 4.9 bagian (b) merupakan boxplot curah hujan yang sudah dilakukan *differencing* musiman dan sudah menunjukkan stasioner dalam rata-rata. Penentuan model ARIMA untuk data input didasarkan pada ACF dan PACF data yang sudah stasioner.

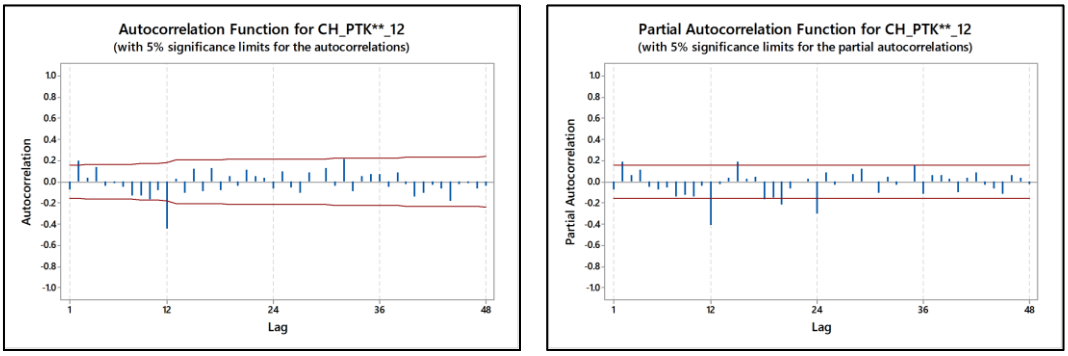

Gambar 4.10. Plot ACF dan PACF Curah Hujan Pontianak Hasil Transformasi dan *Differencing* Musiman

Berdasarkan ACF dan PACF di atas, model ARIMA yang terbentuk untuk variabel input adalah ARIMA $(0,1,1)^{12}$ dengan persamaan ditulis :

$$\dot{x}_{1,t} = \frac{(1 - 0.8084\,B^{12})}{(1 - B^{12})} a_{1,t}$$

Dari model ARIMA terssebut maka didapatkan deret input curah hujan yang telah dilakukan *prewhitening* sebagai berikut :

$$\alpha_{1,t} = \frac{(1 - B^{12})}{(1 - 0.8084\,B^{12})} \dot{x}_{1,t}$$

Adapun *prewhitening* deret output inflasi Pontianak mengikuti *prewhitening* dari deret input curah hujan sehingga dihasil output Inflasi Pontianak yang sudah dilakukan *prewhitening* yaitu sebagai berikut :

$$\beta_{1,t} = \frac{(1 - B^{12})}{(1 - 0.8084\, B^{12})} \dot{y}_{1,t}$$

Plot CCF hasil *prewhitening* antara data inflasi dengan deret input curah hujan Kota Pontianak adalah seperti pada Gambar 4.11 berikut.

Crosscorrelations

Lag	Covariance	Correlation
-10	-0.0030597	-.00214
-9	-0.195975	-.13716
-8	0.043763	0.03063
-7	-0.193906	-.13572
-6	-0.021151	-.01480
-5	-0.041505	-.02905
-4	-0.013262	-.00928
-3	-0.057461	-.04022
-2	0.189949	0.13295
-1	-0.085395	-.05977
0	0.024689	0.01728
1	0.175265	0.12267
2	-0.126711	-.08869
3	0.038737	0.02711
4	0.101472	0.07102
5	0.249225	0.17443
6	-0.174571	-.12218
7	0.030791	0.02155
8	-0.019263	-.01348
9	0.074407	0.05208
10	0.099953	0.06996
11	-0.025524	-.01786
12	0.131453	0.09201
13	-0.181744	-.12720
14	-0.183068	-.12813
15	0.117464	0.08221
16	-0.102363	-.07164
17	0.036210	0.02534
18	-0.100793	-.07055
19	-0.014612	-.01023
20	-0.184047	-.12882
21	0.036444	0.02551
22	0.054354	0.03804
23	-0.225274	-.15767
24	0.130575	0.09139

Gambar 4.11. Plot CCF Inflasi Pontianak dengan Variabel Input (Curah Hujan)

Bobot respons impuls berdasarkan plot CCF di atas adalah *b*=5, *s*=0 dan *r*=0. Berdasarkan bobot respons impuls tersebut kemudian dilakukan pemodelan ARIMA terhadap deret atau komponen *error* (n_t) sehingga mendapatkan residual yang *white noise*.

Autocorrelation Plot of Residuals

Lag	Covariance	Correlation	Std Error
0	0.174860	1.00000	0
1	-0.017102	-.09781	0.080064
2	0.010829	0.06193	0.080826
3	0.012996	0.07432	0.081130
4	0.015866	0.09073	0.081565
5	-0.0091353	-.05224	0.082210
6	-0.0050880	-.02910	0.082422
7	0.026330	0.15058	0.082488
8	-0.023117	-.13221	0.084232
9	-0.011545	-.06603	0.085551
10	-0.012906	-.07381	0.085877
11	0.0044887	0.02567	0.086283
12	-0.061585	-.35220	0.086332
13	-0.0060265	-.03446	0.095097
14	-0.0004144	-.00237	0.095177
15	0.0021629	0.01237	0.095178
16	-0.0018813	-.01076	0.095188
17	-0.013527	-.07736	0.095196
18	0.0034121	0.01951	0.095598
19	-0.020133	-.11514	0.095624
20	-0.0018082	-.01034	0.096508
21	-0.0076749	-.04389	0.096515
22	-0.0073205	-.04186	0.096643
23	0.020393	0.11662	0.096759
24	-0.019373	-.11079	0.097656

Partial Autocorrelations

Lag	Correlation
1	-0.09781
2	0.05287
3	0.08629
4	0.10469
5	-0.04372
6	-0.05947
7	0.13584
8	-0.10414
9	-0.09614
10	-0.09766
11	0.01200
12	-0.31423
13	-0.09012
14	0.00042
15	0.10147
16	0.07544
17	-0.09957
18	-0.06440
19	-0.05112
20	-0.08986
21	-0.11937
22	-0.14935
23	0.14643
24	-0.17435

Gambar 4.12. Plot ACF dan PACF Komponen *Error* (n_t)

Orde ARIMA untuk komponen *error* (n_t) ditentukan berdasarkan ACF dan PACF dari komponen *error* hasil respons impuls seperti ditunjukkan pada Gambar 4.12 di atas. Berdasarkan plot ACF dan PACF tersebut, maka model ARIMA untuk komponen *error* (n_t) adalah ARIMA $(0,1,1)^{12}$. Hasil estimasi model fungsi transfer berdasarkan model ARIMA $(0,1,1)^{12}$ seperti ditunjukkan pada Tabel 4.18 berikut.

Tabel 4.18. Hasil Estimasi Parameter Model Fungsi Transfer Inflasi Pontianak

Model ARIMA	**Parameter**	**Estimasi**	**Standar Error**	**P-value**
FT-ARIMA $(0,1,1)^{12}$ *b*=5, *s*=0, *r*=0	Θ_1	0.5817	0.0698	<.0001
	ω_5	0.0213	0.0077	0.0062

Pada tabel di atas memperlihatkan seluruh parameter signifikan pada taraf uji 0.05. Selanjutnya dilakukan pengecekan kelayakan model dengan menguji asumsi *white noise* dan normalitas dari residual model yang dihasilkan. Hasil uji asumsi seperti pada Tabel 4.19 di bawah ini

Tabel 4.19. Hasil Uji Residual *White Noise* dan Normalitas Model Fungsi Transfer Inflasi Pontianak

Uji *White Noise*				**Uji Kenormalan**	
Lag	**Chi-Square**	**DF**	**Pr >ChiSq**	KS	*P-Value*
6	2.74	5	0.7403	0.073715	0.0437
12	8.69	11	0.6507		
18	11.25	17	0.8435		
24	20.5	23	0.6119		
30	26.66	29	0.5902		

Berdasarkan pada tabel uji asumsi di atas menunjukkan bahwa model fungsi transfer sudah memenuhi asumsi *white noise* namun belum memenuhi kenormalan dari residualnya. Untuk mengatasi hal tersebut maka dilakukan pemodelan dengan melibatkan deteksi outlier. Hasil deteksi outlier dari model fungsi transfer seperti pada Tabel 4.20 berikut.

Tabel 4.20. Hasil Deteksi *Outlier* Model Fungsi Transfer Inflasi Pontianak

Observasi	Tipe	Estimasi Efek Outlier	Chi-Square	*p-value*
130	Additive	-1.41473	27.03	<.0001
142	Additive	-1.39836	30.28	<.0001
58	Additive	1.1934	22.53	<.0001
155	Additive	-0.78485	9.66	0.0019
107	Additive	-0.74444	9.58	0.002

Nilai estimasi parameter model fungsi transfer dengan penyertaan deteksi *outlier* seperti ditunjukkan pada Tabel 4.21.

Tabel 4.21. Hasil Estimasi Parameter Model Fungsi Transfer Data Inflasi Pontianak dengan Deteksi *Outlier*

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	*White Noise*	KS (*p-value*)
FT-ARIMA $(0,1,1)^{12}$ *b*=5, *s*=0, *r*=0 Dengan Deteksi *Outlier*	Θ_1	0.5296	0.0764	<.0001	Ya	0.071841 (*0.0552*)
	ω_0	0.0131	0.0061	0.0328		
	ω_{AO130}	-1.7434	0.2656	<.0001		
	ω_{AO142}	-1.4830	0.2668	<.0001		
	ω_{AO58}	1.2096	0.2558	<.0001		
	ω_{AO155}	-0.8350	0.2647	0.002		

Hasil estimasi pada Tabel 4.21 menunjukkan bahwa seluruh parameter signifikan pada taraf uji $\alpha = 0.05$ sehingga bisa digunakan dalam model. Pada tabel tersebut juga memperlihatkan bahwa model tersebut telah memenuhi asumsi residual yang *white noise* dan mengikuti distribusi normal.

Berdasarkan nilai AIC model fungsi transfer dengan deteksi *outlier* dan RMSE *in-sample*, maka model tersebut merupakan model terbaik karena memiliki nilai AIC atau RMSE yang terkecil dibandingkan dengan model tanpa deteksi *outlier*, seperti ditunjukkan pada Tabel 4.22 di bawah ini.

Tabel 4.22. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan Fungsi Transfer Inflasi Pontianak

Model ARIMA Fungsi Transfer	**AIC**	**RMSE *in-sample***
FT-ARIMA $(0,1,1)^{12}$ *b*=5, *s*=0, *r*=0	127.3614	0.3665
FT-ARIMA $(0,1,1)^{12}$ *b*=5, *s*=0, *r*=0 Dengan deteksi *outlier*	61.47621	0.2909

Model fungsi transfer dengan deteksi *outlier* pada inflasi Pontianak telah memenuhi syarat asumsi residual yang *white noise* dan mengikuti distribusi normal, sehingga model tersebut layak digunakan untuk melakukan permalan. Secara matematis model fungsi transfer dengan deteksi *outlier* bisa ditulis sebagai berikut :

$$\dot{y}_{1,t} = 0.0131\, x_{1,t-5} - 1.743\, I_t^{T=130} - 1.483\, I_t^{T=142} + 1.2096\ I_t^{T=58} - 0.835\, I_t^{T=155} + (1 - 0.5296\, B^{12}) a_{1,t}$$

Dimana $\dot{y}_{1,t} = y_{1,t} - \mu$, dan $y_{1,t} = \mathrm{Ln}(\mathrm{Y}_{1,\mathrm{t}} + 2)$.

Secara simultan pemodelan ARIMAX dilakukan dengan cara menggabungkan seluruh variabel eksogen diantaranya curah hujan (fungsi transfer), variasi kalender (bulanan) dan intervensi. Dalam penentuan respons impuls *b*, *s*, *r* mengikuti *b*, *s*, *r* dari model fungsi transfer inflasi Pontianak. Adapun penentuan orde ARIMA ditentukan berdasarkan residualnya. Model ARIMAX gabungan yang ditampilkan adalah model dengan parameter yang sudah signifikan seperti terlihat pada Tabel 4.23 di bawah ini.

Tabel 4.23. Hasil Estimasi Parameter Model ARIMAX Simultan Inflasi Pontianak

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
ARIMA $(0,1,1)^{12}$ *b*=5, *s*=0, *r*=0	Θ_1	0.6653	0.0671	<.0001	Ya	0.06828 (*0.0842*)
	ω_0	0.0177	0.0073	0.0172		
	D_{t-1}	0.2411	0.1100	0.03		
	D_t	0.3547	0.1063	0.0011		
	P_t	1.2244	0.3196	0.0002		

Berdasarkan pada Tabel 4.23 menunjukkan bahwa parameter dari model gabungan sudah signifikan pada taraf uji $\alpha = 0.05$. Model tersebut juga seudah memenuhi asumsi residual yang *white noise* dan mengikuti distribusi normal. Secara matematis, model tersebut dapat ditulis sebagai berikut :

$$\dot{y}_{1,t} = 0.018 x_{1,t-5} + 0.2411\, D_{,t-1} + 0.355\, D_{,t} + 1.224\, P_t + (1 - 0.665\, B^{12}) a_{1,t}$$

dengan $\dot{y}_{1,t} = y_{1,t} - \mu$, dan $y_{1,t} = \mathrm{Ln}(\mathrm{Y}_{1,\mathrm{t}} + 2)$.

Berdasarkan pemodelan inflasi Pontianak yang telah dilakukan dengan beberapa metode univariat, maka bisa dilakukan perbandingan model terbaik berdasarkan nilai RMSE *in-sample*. Hasil akurasi peramalan bisa diketahui berdasarkan nilai dari RMSE *out-sample* untuk menentukan model yang akan digunakan untuk meramalkan inflasi di Pontianak. Perbandingan nilai RMSE bisa dilihat pada Gambar 4.13 di bawah ini.

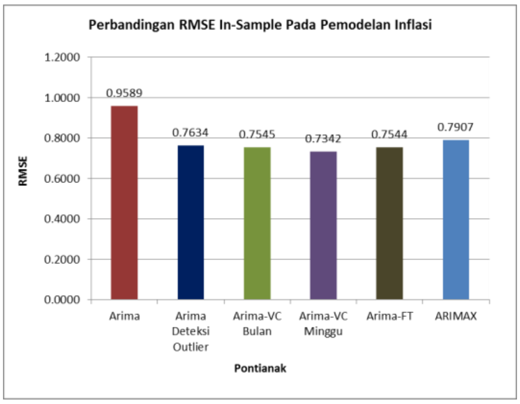

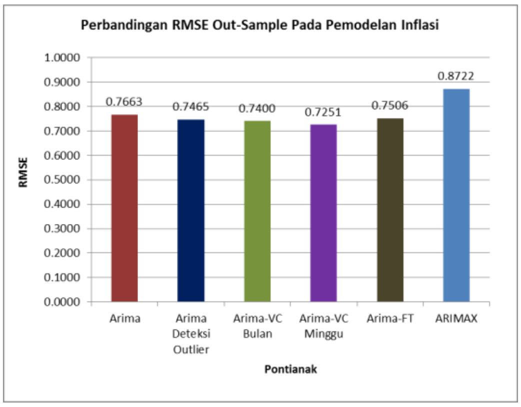

Gambar 4.13. Perbandingan RMSE *In-Sampel* Berdasarkan Model Inflasi Pontianak

Pada Gambar 4.13 di atas menunjukkan bahwa pemodelan univariat dengan penambahan variabel prediktor bisa menurunkan nilai tingkat kesalahan terhadap standar errornya. Hal ini terlihat dari nilai RMSE *in-sample* yang mengalami penurunan antara model ARIMA dengan model ARIMAX (variasi kalender, fungsi transfer maupun gabungan). Adapun untuk menentukan model yang akan digunakan dalam permalan didasarkan pada tingkat akurasi model dilihat dari nilai RMSE *out-sampel* yang terkecil. Berdasarkan Gambar 4.13 menunjukkan bahwa model ARIMA-Variasi Kalender mingguan memberikan akurasi yang lebih tinggi dibandingkan dengan model yang lain. Hal ini terlihat pada nilai RMSE *out-sample* yang terkecil yaitu sebesar 0.7251. Adapun hasil ramalan inflasi berdasarkan beberapa metode pemodelan dibandingkan dengan data aktual (*data out-sample*) seperti ditunjukkan pada Gambar 4.14.

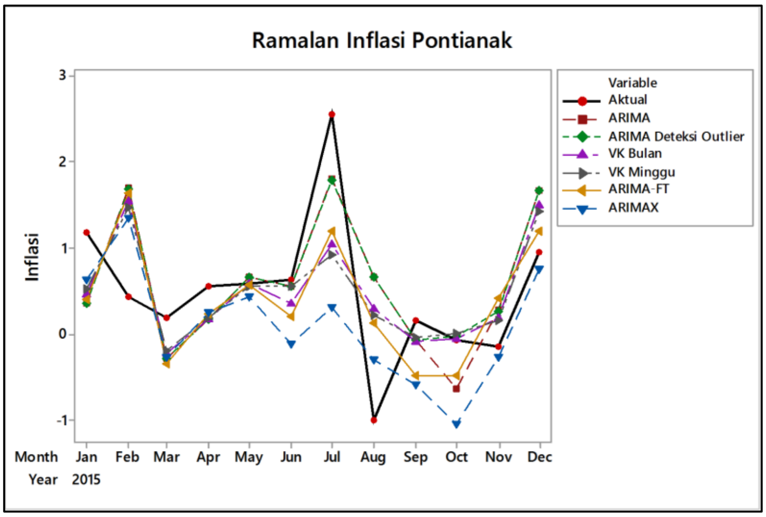

Gambar 4.14. Hasil Peramalan Inflasi Pontianak

4.4. Pemodelan Inflasi Sampit

4.4.1. Model ARIMA

Berdasarkan cara dan langkah yang sama dengan sebelumnya maka diperoleh plot ACF dan PACF (Lampiran 9.a) dan hasil identifikasi model ARIMA seperti pada Tabel 4.24. Berdasarkan kriteria nilai AIC terkecil, maka diperoleh hasil estimasi parameter model seperti ditunjukkan pada Tabel 4.25.

Hasil deteksi *outlier* pada model ARIMA $([4],0,0)(0,1,1)^{12}$ mendapatkan data *outlier* pada observasi ke-54, 153, 86, dan 58 dengan tipe AO (*Additive Outlier*) seperti ditunjukkan pada lampiran 12. Data ke-54 merupakan kejadian deflasi pada bulan bulan Juni 2005, data ke-153 merupakan data deflasi pada bulan September 2013 dan observasi ke-86 adalah deflasi pada bulan Februari 2008. Terjadinya deflasi pada tahun-tahun tersebut dikarenakan adanya penurunan indeks harga pada pada kelompok pengeluaran yang lebih didominasi oleh kelompok bahan makanan.

Tabel 4.24. Hasil Identifikasi dan Nilai AIC Model ARIMA Sementara Inflasi Sampit

Model ARIMA Hasil Identifikasi	AIC	Keterangan
ARIMA $(0,0,[4])(0,1,1)^{12}$	228.6301	-
ARIMA $([4],0,0)(0,1,1)^{12}$	**228.3831**	dipilih untuk pemodelan

Tabel 4.25. Hasil Estimasi Parameter Model ARIMA Inflasi Sampit

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	White Noise	KS (*p-value*)
ARIMA $([4],0,0)(0,1,1)^{12}$	Θ_1	0.70998	0.05895	<.0001	Ya	0.099688 (*0.0100*)
	ϕ_4	-0.16918	0.08076	0.0378		
ARIMA $([4],0,0)(0,1,1)^{12}$ dengan deteksi *outlier*	Θ_1	0.68731	0.06117	<.0001	Ya	0.065923 (*0,0946*)
	ϕ_4	-0.14671	0.08211	0.0760		
	ω_{AO54}	-2.80497	0.38007	<.0001		
	ω_{AO153}	-1.61957	0.39451	<.0001		

Adapun pada observasi ke-58 bernilai positif yang menunjukkan terjadinya inflasi yang terjadi pada bulan Oktober 2005. Inflasi pada bulan Oktober 2005 terjadi secara global di enam wilayah di Kalimantan, sebagai akibat dari kebijakan kebijakan pemerintah yang bersifat nasional yaitu adanya kenaikan harga BBM pada bulan Oktober 2005 sebagai dampak pengurangan subsidi BBM. Berdasarkan nilai AIC dan RMSE *in-sample* terkecil, maka model ARIMA $([4],0,0)(0,1,1)^{12}$ dengan deteksi *outlier* merupakan model terbaik seperti diperlihatkan pada Tabel 4.26.

Tabel 4.26. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan ARIMA Inflasi Sampit

Model ARIMA	AIC	RMSE *in-sample*
$([4],0,0)(0,1,1)^{12}$	228.3831	0.499918
$([4],0,0)(0,1,1)^{12}$ dengan deteksi *outlier*	171.6624	0.414206

Secara matematis, model ARIMA ([4],0,0)(0,1,1)^{12} dengan deteksi *outlier* bisa ditulis sebagai berikut :

$$\dot{y}_{2,t} = y_{2,t-12} - 0.147\, y_{2,t-4} + 0.147\, y_{2,t-16} - 2.805\, I_t^{T=54} - 1.620\, I_t^{T=153}$$
$$+(1 - 0.68731\, B^{12})\, a_{2,t}$$

dengan $\dot{y}_{2,t} = y_{2,t} - \mu$, dan $y_{2,t} = \mathrm{Ln}(\mathrm{Y}_{2,\mathrm{t}} + 2)$.

4.4.2. Model Variasi Kalender

Dengan cara yang sama diperoleh model ARIMA-variasi kalender bulanan dengan estimasi parameter seperti pada Tabel 4.27. Adapun model terbaik berdasarkan kriteria AIC terkecil seperti ditunjukkan pada Tabel 4.28.

Tabel 4.27. Hasil Estimasi Parameter Variasi Kalender Bulanan Inflasi Sampit

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
CV_ARIMA (1,0,1)(0,1,1)^{12}	θ_1	-0.76951	0.17636	<.0001	Ya	0.100787 (*<0.0100*)
	Θ_1	0.73393	0.0585	<.0001		
	ϕ_1	-0.60858	0.21824	0.006		
	D_t	0.21984	0.13154	0.0967		
CV-ARIMA (1,0,1)(0,1,1)^{12} Dengan Deteksi *Outlier*	θ_1	-0.90605	0.06897	<.0001	Ya	0.068023 (*0.0773*)
	Θ_1	0.74001	0.06242	<.0001		
	ϕ_1	-0.6225	0.11149	<.0001		
	D_t	0.19584	0.07863	0.0139		
	ω_{AO54}	-3.0563	0.29708	<.0001		
	ω_{AO153}	-1.82294	0.30146	<.0001		
	ω_{AO86}	-1.22102	0.28542	<.0001		
	ω_{AO58}	1.1892	0.29561	<.0001		
	ω_{AO4}	0.83912	0.17706	<.0001		

Tabel 4.28. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan Variasi Kalender (Bulanan) Inflasi Sampit

Model ARIMA Variasi Kalender	**AIC**	**RMSE *in-sample***
CV-ARIMA (1,0,1)(0,1,1)^{12}	229.195	0.4981
CV-ARIMA (1,0,1)(0,1,1)^{12} dengan deteksi *outlier*	118.859	0.3444

Secara matematis, model variasi kalender bulanan dengan deteksi *outlier* bisa ditulis sebagai berikut :

$$\dot{y}_{2,t} = 0.196\, D_t - 3.056\, I_t^{T=54} - 1.823\, I_t^{T=153} - 1.2221\ \ I_t^{T=86} + 1.189\ \ I_t^{T=58}$$
$$- 0.622\, y_{1,t-1} + (1 - 0.906\, B)(1 + 0.740\, B^{12})\, a_{2,t}$$

dengan $\dot{y}_{2,t} = y_{2,t} - \mu$, dan $y_{2,t} = \mathrm{Ln}(\mathrm{Y}_{2,\mathrm{t}} + 2)$

Berdasarkan persamaan model variasi kalender bulanan tersebut menunjukkan bahwa kejadian hari raya Idul Fitri di Sampit memberikan pengaruh terhadap terjadinya inflasi. Adapun model inflasi Sampit dengan variasi kalender mingguan bisa dilihat hasil estimasinya pada Tabel 4.29 di bawah ini.

Tabel 4.29. Hasil Estimasi Parameter Variasi Kalender Mingguan Inflasi Sampit

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
CV-ARIMA $(2,1,0)^{12}$	Φ_1	-0.60441	0.08042	<.0001	Ya	0.099935 (*<0.0100*)
	Φ_2	-0.25494	0.0824	0.0023		
	$D_{1,t-1}$	0.45115	0.25951	0.0841		
CV-ARIMA $(2,1,0)^{12}$ Dengan Deteksi Outlier	Φ_1	-0.53768	0.08081	<.0001	Ya	0.07029 (*0.0586*)
	Φ_2	-0.30892	0.08387	0.0003		
	$D_{1,t-1}$	0.44553	0.22051	0.0451		
	ω_{AO54}	-2.95516	0.38193	<.0001		

Tabel 4.30. Nilai AIC dan RMSE In-Sample Hasil Pemodelan Variasi Kalender Mingguan pada Inflasi Sampit

Model ARIMA Variasi Kalender	**AIC**	**RMSE *in-sample***
CV-ARIMA $(2,1,0)^{12}$	242.0118	0.520596
CV-ARIMA $(2,1,0)^{12}$ dengan deteksi *outlier*	194.1298	0.445134

Berdasarkan hasil estimasi parameter dan uji kelayakan model serta dengan kriteria nilai AIC dan RMSE *in-sample* terkecil, maka model variasi kalender mingguan dengan deteksi *outlier* merupakan model terbaik seperti ditunjukkan pada Tabel 4.30.

Secara matematis, model variasi kalender mingguan dengan deteksi *outlier* di atas bisa ditulis sebagai berikut :

$$\dot{y}_{2,t} = 0.446\, D_{1,t-1} - 2.955\, I_t^{T=54} - 0.538\, y_{2,t-12} - 0.309 y_{2,t-24} + a_{2,t}$$

dengan $\dot{y}_{2,t} = y_{2,t} - \mu$, dan $y_{2,t} = \mathrm{Ln}(\mathrm{Y}_{2,\mathrm{t}} + 2)$.

4.4.3. Model Fungsi Transfer

Berdasarkan plot ACF dan PACF deret input curah hujan (Lampiran 10.a) diperoleh model ARIMA yang untuk variabel input yaitu ARIMA $(0,0,2)(0,1,1)^{12}$ dengan persamaan ditulis :

$$\dot{x}_{2,t} = \frac{(1 + 0.261B + 0.208B^2)(1 - 0.554\, B^{12})}{(1 - B^{12})} a_{2,t}$$

Berdasarkan model ARIMA tersebut maka didapatkan deret input curah hujan yang telah dilakukan *prewhitening* sebagai berikut :

$$\alpha_{2,t} = \frac{(1 - B^{12})}{(1 + 0.261B + 0.208B^2)(1 - 0.554\, B^{12})} \dot{x}_{2,t}$$

Adapun *prewhitening* deret output inflasi Sampit mengikuti *prewhitening* dari deret input curah hujan sehingga diperoleh output Inflasi Sampit yang sudah dilakukan *prewhitening* yaitu sebagai berikut :

$$\beta_{2,t} = \frac{(1 - B^{12})}{(1 + 0.261B + 0.208B^2)(1 - 0.554\, B^{12})} \dot{y}_{2,t}$$

Hasil CCF hasil *prewhitening* antara data inflasi dengan deret input curah hujan seperti pada Lampiran 11 (a). Berdasarkan hasil CCF, maka bisa ditentukan bobot respons impuls yang digunakan untuk menduga kapan mulai terjadinya pengaruh dari deret input (variabel eksogen), serta berapa lama pengaruh dari deret input tersebut.

Bobot respons impuls berdasarkan plot CCF adalah *b*=14, *s*=0 dan *r*=0. Selanjutnya dengan bobot tersebut, dilakukan pemodelan ARIMA terhadap deret atau komponen *error* (n_t) sehingga mendapatkan residual yang *white noise*. Orde ARIMA ditentukan berdasarkan ACF dan PACF dari komponen *error* (n_t) hasil respons impuls seperti pada Lampiran 12 (a). Model ARIMA komponen *error*

(n_t) yang terbentuk adalah ARIMA ([2,4],0,0)(0,1,1)^{12}. Hasil estimasi model fungsi transfer seperti dicantumkan pada Tabel 4.31 di bawah ini.

Tabel 4.31. Hasil Estimasi Parameter Model Fungsi Transfer Inflasi Sampit

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
FT-ARIMA ([2,4],0,0)(0,1,1)^{12} *b*=14, *s*=0 dan *r*=0	Θ_1	0.7130	0.0641	<.0001	Ya	0.071889 (*0.0723*)
	ϕ_2	-0.2261	0.0841	0.008		
	ϕ_4	-0.2154	0.0847	0.0121		
	ω_0	0.0157	0.0070	0.0261		

Hasil pada Tabel 4.31 menunjukkan bahwa seluruh parameter signifikan pada taraf uji 0.05. Tabel 4.31 juga menunjukkan bahwa model Fungsi Transfer sudah memenuhi asumsi *white noise* dan kenormalan, sehingga model tersebut layak digunakan untuk melakukan permalan. Secara matematis model fungsi transfer di atas bisa ditulis sebagai berikut :

$$\dot{y}_{2,t} = 0.0157\, x_{2,t-14} + \frac{(1-0.713B^{12})}{(1+0.226\,B^2+0.215\,B^4)}a_{2,t}$$

dimana $\dot{y}_{2,t} = y_{2,t} - \mu$, dan $y_{2,t} = \mathrm{Ln}(\mathrm{Y}_{2,t})$.

Secara simultan pemodelan ARIMAX untuk inflasi Sampit dengan cara menggabungkan semua variabel eksogen dan hanya melibatkan variabel atau parameter yang signifikan seperti terlihat pada Tabel 4.32 berikut.

Tabel 4.32. Hasil Estimasi Parameter Model ARIMAX Simultan Inflasi Sampit

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
ARIMA ([2],0,0)(0,1,1)^{12} *b*=14, *s*=0, *r*=0	Θ_1	0.7132	0.0638	<.0001	Ya	0.069924 0.0878
	ϕ_2	-0.2037	0.0844	0.0171		
	ω_0	0.0182	0.0073	0.0132		
	P_t	1.4120	0.4287	0.0013		

Berdasarkan pada Tabel 4.32 memperlihatkan bahwa parameter dalam model univariat simultan tersebut sudah signifikan serta residual dari model tersebut sudah memenuhi untuk uji *white noise* dan kenormalan pada taraf uji $\alpha = 0.05$. Secara matematis, model tersebut dapat ditulis sebagai berikut :

$$\dot{y}_{2,t} = y_{2,t-12} - 0.204 y_{2,t-2} + 0.204 y_{2,t-14} + 0.018 x_{2,t-14} + 1.412\, P_t$$
$$+ (1 - 0.713\, B^{12}) a_{2,t}$$

dengan $\dot{y}_{2,t} = y_{2,t} - \mu$, dan $y_{2,t} = \text{Ln}(\text{Y}_{2,t} + 2)$.

Berdasarkan pemodelan inflasi Sampit yang telah dilakukan dengan beberapa metode, maka bisa dilakukan perbandingan model terbaik berdasarkan nilai RMSE *in-sample*. Hasil akurasi peramalan bisa diketahui berdasarkan nilai dari RMSE *out-sample*. Perbandingan nilai RMSE bisa dilihat pada gambar di bawah ini.

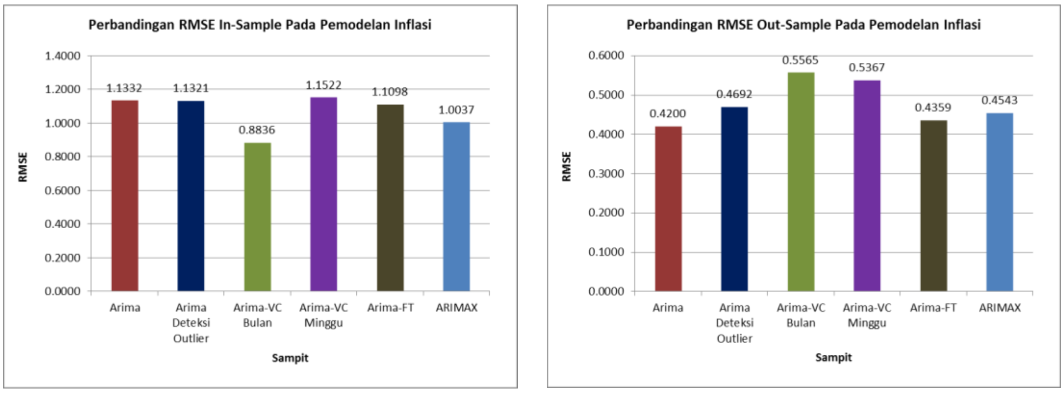

Gambar 4.15. Perbandingan RMSE Berdasarkan Model Inflasi Sampit

Gambar 4.15 di atas menunjukkan bahwa dalam pemodelan, dengan penambahan variabel prediktor, bisa menurunkan nilai tingkat kesalahan terhadap standar errornya. Model ARIMA-Variasi Kalender dengan menggunakan *dummy* bulanan merupakan model terbaik dibandingkan dengan model univariat lainnya untuk pemodelan inflasi di Sampit. Hal ini didasarkan pada nilai RMSE *in-sample* terkecil yaitu sebesar 0.8836.

Namun demikian berdasarkan tingkat akurasi ramalannya menunjukkan bahwa model ARIMA tanpa melibatkan varaibel eksogen merupakan model dengan akurasi ramalan lebih baik dibandingkan dengan model yang lain. Hal ini terlihat pada nilai RMSE *out-sample* yang terkecil yaitu sebesar 0.4200. Hasil ramalan inflasi berdasarkan beberapa metode pemodelan dibandingkan dengan data aktual (*data out-sample*) dapat dilihat pada Gambar 4.16 di bawah ini.

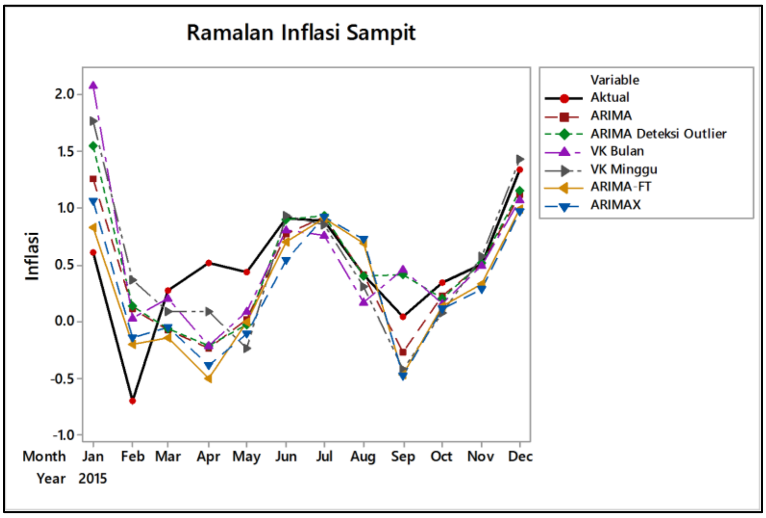

Gambar 4.16. Hasil Peramalan Inflasi Sampit

4.5. Pemodelan Inflasi Palangkaraya

4.5.1. Model ARIMA

Hasil identifikasi model ARIMA berdasarkan plot ACF dan PACF pada Lampiran 9.b menghasilkan model ARIMA sementara untuk inflasi Palangkaraya seperti pada Tabel 4.33 dan model ARIMA terbaik seperti pada Tabel 4.34.

Tabel 4.33. Hasil Identifikasi dan Nilai AIC Model ARIMA Sementara Inflasi Palangkaraya

Model ARIMA Hasil Identifikasi	AIC	Keterangan
ARIMA $(1,0,0)(0,1,1)^{12}$	227.6438	-
ARIMA $(0,0,1)(0,1,1)^{12}$	**226.8309**	dipilih untuk pemodelan

Tabel 4.34. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan ARIMA pada Inflasi Pontianak

Model ARIMA	AIC	RMSE *in-sample*
ARIMA $(0,0,1)(0,1,1)^{12}$	226.8309	0.4974
ARIMA $(0,0,1)(0,1,1)^{12}$ dengan deteksi *outlier*	**165.8842**	**0.4041**

Berdasarkan nilai AIC dan RMSE *in-sample*, maka model ARIMA $(0,0,1)(0,1,1)^{12}$ dengan deteksi *outlier* merupakan model terbaik seperti diperlihatkan pada Tabel 4.34 Secara matematis, berdasarkan Lampiran 14, maka model ARIMA $(0,0,1)(0,1,1)^{12}$ dengan deteksi *outlier* bisa ditulis sebagai berikut :

$$\dot{y}_{3,t} = y_{3,t-12} - 2.367\, I_t^{T=153} - 1.429\, I_t^{T=68} - 1.493\, I_t^{T=30} + 1.275\, I_t^{T=58} + (1 + 0.258\, B)(1 - 0.716\, B^{12}) a_{3,t}$$

dengan $\dot{y}_{3,t} = y_{3t} - \mu$, dan $y_{3,t} = \mathrm{Ln}(\mathrm{Y}_{3,t} + 1.5)$

Hasil deteksi *outlier* pada model ARIMA $(0,0,1)(0,1,1)^{12}$ menunjukkan adanya data outlier pada observasi ke-153, 68, 30, 58 dengan tipe AO (*Additive Outlier*). Data ke-153 merupakan kejadian deflasi pada bulan September 2013, data ke-68 merupakan data deflasi pada bulan Agustus 2006, data ke-30 adalah deflasi pada bulan Juni 2003. Terjadinya deflasi pada tahun-tahun tersebut dikarenakan adanya penurunan indeks harga pada pada kelompok pengeluaran yang lebih didominasi oleh kelompok bahan makanan.

4.5.2. Model Variasi Kalender

Langkah yang sama dilakukan dalam pemodelan ARIMA dengan efek variasi kalender bulanan untuk inflasi Palangkaraya. Hasil estimasi parameter untuk model variasi kalender bulanan seperti ditunjukkan pada Tabel 4.35, sedangkan model terbaik berdasarkan AIC dan RMSE *in-sample* terkecil seperti pada Tabel 4.36 berikut.

Tabel 4.35. Hasil Estimasi Parameter ARIMA dengan Variasi Kalender Bulanan untuk Inflasi Palangkaraya

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
$(0,0,1)(0,1,1)^{12}$	θ_1	-0.16721	0.08032	0.039	Ya	0.080948 (*0.0136*)
	Θ_1	0.77518	0.05429	<.0001		
	D_{t-1}	0.25435	0.14117	0.0736		
	D_t	0.35465	0.14113	0.013		

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	White Noise	KS (*p-value*)
$(0,0,1)(0,1,1)^{12}$ Dengan Deteksi Outlier	θ_1	-0.25638	0.08016	0.0017	Ya	0.067475 (*0.0818*)
	Θ_1	0.7315	0.05772	<.0001		
	D_t	0.22072	0.10342	0.0345		
	ω_{A153}	-2.29586	0.37471	<.0001		
	ω_{AO30}	-1.50425	0.36097	<.0001		
	ω_{AO68}	-1.42489	0.36176	0.0001		
	ω_{AO58}	1.39013	0.36389	0.0002		

Tabel 4.36. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan Variasi Kalender pada Inflasi Palangkaraya

Model ARIMA Variasi Kalender	AIC	RMSE *in-sample*
$(0,0,1)(0,1,1)^{12}$	224.0211	0.4899
$(0,0,1)(0,1,1)^{12}$ dengan deteksi *outlier*	163.2339	0.3994

Secara matematis, model variasi kalender bulanan dengan deteksi *outlier* bisa ditulis sebagai berikut :

$$\dot{y}_{3,t} = 0.221\, D_t - 2.296\, I_t^{T=153} - 1.504\, I_t^{T=30} - 1.425\, I_t^{T=68} + 1.390\, I_t^{T=58}$$
$$+(1 + 0.256\, B)(1 - 0.731\, B^{12})a_{3,t}$$

dengan $\dot{y}_{3,t} = y_{3,t} - \mu$, dan $y_{3,t} = \mathrm{Ln}(\mathrm{Y}_{3,\mathrm{t}})$

Persamaan model variasi kalender bulanan tersebut menunjukkan bahwa kejadian hari raya Idul Fitri di Palangkaraya memberikan pengaruh terhadap terjadinya inflasi. Adapun untuk model inflasi Palangkaraya dengan variasi kalender mingguan bisa dilihat hasil estimasinya pada Tabel 4.37.

Tabel 4.37. Hasil Estimasi Parameter Variasi Kalender Mingguan Inflasi Palangkaraya

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	White Noise	KS (*p-value*)
$(0,0,1)(0,1,1)^{12}$	θ_1	-0.20432	0.08015	0.0118	Ya	0.064261 (*0.1144*)
	Θ_1	0.75563	0.05589	<.0001		
	$D_{1,t-1}$	0.53647	0.25861	0.0397		
	$D_{2,t}$	0.42008	0.2254	0.0643		

Berdasarkan hasil estimasi parameter di atas, memperlihatkan bahwa parameter pada model variasi kalender mingguan di atas telah memenuhi signifikansi dengan taraf uji $\alpha = 0.05$. Pada uji asumsi residual, model tersebut sudah memenuhi uji kelayakan model. Secara matematis, model variasi kalender mingguan di atas bisa ditulis sebagai berikut :

$$\dot{y}_{3,t} = 0.536\, D_{1,t-1} + 0.420\, D_t + (1 + 0.204\, B)(1 - 0.756\, B^{12})a_{3,t}$$

dengan $\dot{y}_{3,t} = y_{3,t} - \mu$, dan $y_{3,t} = \mathrm{Ln}(\mathrm{Y}_{3,t})$.

4.5.3. Model Fungsi Transfer

Hasil identifikasi model ARIMA dari deret input berdasarkan ACF dan PACF deret input (Lampiran 10.b) diperoleh model ARIMA variabel input adalah ARIMA $(0,0,2)(0,1,1)^{12}$ dengan persamaan ditulis :

$$\dot{x}_{3,t} = \frac{(1 + 0.193B + 0.239B^2)(1 - 0.713\, B^{12})}{(1 - B^{12})} a_{3,t}$$

Dari model ARIMA tersebut maka didapatkan deret input curah hujan yang telah dilakukan *prewhitening* sebagai berikut :

$$\alpha_{3,t} = \frac{(1 - B^{12})}{(1 + 0.193B + 0.239B^2)(1 - 0.713\, B^{12})} \dot{x}_{3,t}$$

Adapun untuk *prewhitening* deret output inflasi Palangkaraya mengikuti *prewhitening* dari deret input curah hujan sehingga dihasilkan output Inflasi Palangkaraya yang sudah dilakukan *prewhitening* yaitu sebagai berikut :

$$\beta_{3,t} = \frac{(1 - B^{12})}{(1 + 0.193B + 0.239B^2)(1 - 0.713\, B^{12})} \dot{y}_{3,t}$$

Mengacu hasil CCF pada Lampiran 11 (b) maka bisa ditentukan bobot respons impuls yang digunakan untuk menduga kapan mulai terjadinya pengaruh dari deret input (variabel eksogen), serta berapa lama pengaruh dari deret input tersebut. Bobot respons impuls berdasarkan plot CCF tersebut adalah *b*=8, *s*=0 dan *r*=0. Selanjutnya dengan bobot tersebut, dilakukan pemodelan ARIMA terhadap komponen *error* (n_t) sehingga mendapatkan residual yang *white noise*. Orde ARIMA untuk komponen *error* (n_t) ditentukan berdasarkan ACF dan PACF dari komponen *error* (n_t) hasil respons impuls seperti pada Lampiran 12 (b). Model ARIMA komponen *error* (n_t) yang terbentuk adalah adalah ARIMA $(0,0,1)(0,1,1)^{12}$. Hasil estimasi model fungsi transfer seperti dicantumkan pada Tabel 4.38 di bawah ini.

Tabel 4.38. Hasil Estimasi Parameter Model Fungsi Transfer Inflasi Palangkaraya

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
FT-ARIMA $(0,0,1)(0,1,1)^{12}$ *b*=8, *s*=0 dan *r*=0	θ_1	-0.2117	0.0827	0.0115	Ya	0.082943 (*0.0139*)
	Θ_1	0.7640	0.0580	<.0001		
	ω_0	0.0161	0.0093	0.0864		
$(0,0,1)(0,1,1)^{12}$ Dengan Deteksi Outlier	θ_1	-0.2529	0.0814	0.0023	Ya	0.059414 (>*0.1500*)
	Θ_1	0.7489	0.0578	<.0001		
	ω_0	0.0133	0.0085	0.1205		
	ω_{AO153}	-2.3308	0.4214	<.0001		

Hasil pada tabel di atas menunjukkan bahwa pada model tanpa menggunakan deteksi *outlier* parameter variabel input masih signifikan pada taraf uji $\alpha = 0.10$ namun masih belum memenuhi asumsi kenormalan. Adapun dengan menggunakan model deteksi *outlier* seperti pada Tabel 4.38 di atas, model fungsi transfer justru menunjukkan bahwa variabel input (curah hujan) tidaklah signifikan pada taraf uji uji $\alpha = 0.05$ atau $\alpha = 0.10$. ini berarti variabel curah hujan tidak memberikan pengaruh yang signifikan pada terjadinya inflasi di Palangkaraya. Secara matematis model fungsi transfer dengan deteksi *outlier* bisa ditulis sebagai berikut :

$$\dot{y}_{3,t} = 0.0133\, x_{3,t-8} - 2.331\, I_t^{T=153} + (1 + 0.253B)(1 - 0.749B^{12})a_{3,t}$$

dimana $\dot{y}_{3,t} = y_{3,t} - \mu$, dan $y_{3,t} = \mathrm{Ln}(\mathrm{Y}_{3,\mathrm{t}} + 1.5)$.

Secara simultan pemodelan ARIMAX untuk inflasi Palangkaraya dengan cara menggabungkan semua variabel eksogen dan hanya melibatkan variabel atau parameter yang signifikan seperti terlihat pada Tabel 4.39 di bawah ini.

Tabel 4.39. Hasil Estimasi Parameter Model ARIMAX Simultan Inflasi Palangkaraya

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
$(2,0,0)(0,1,1)^{12}$ Dengan Deteksi Outlier	Θ_1	0.7174	0.0592	<.0001	Ya	0.051369 (>*0.1500*)
	ϕ_1	0.2348	0.0818	0.0047		
	ϕ_2	-0.1720	0.0824	0.0386		
	D_t	0.2205	0.1043	0.0362		
	P_t	1.3805	0.3590	0.0002		
	ω_{AO153}	-2.2560	0.3723	<.0001		
	ω_{AO68}	-1.3906	0.3570	0.0001		
	ω_{AO30}	-1.5252	0.3551	<.0001		

Berdasarkan pada tabel di atas memperlihatkan bahwa parameter variabel dalam model telah signifikan. Dalam model tersebut tidak terdapat variabel input curah hujan, ini berarti variabel curah hujan tidak memberikan pengaruh yang signifikan terhadap inflasi yang terjadi di Palangkaraya. Secara matematis, model tersebut dapat ditulis sebagai berikut :

$$\dot{y}_{3,t} = y_{3,t-12} + 0.235y_{3,t-1} - 0.172y_{3,t-2} - 0.235y_{3,t-13} + 0.172y_{3,t-14} + 0.221\, D_t + 1.3805\, P_t - 2.256\, I_t^{T=153} - 1.391\, I_t^{T=68} - 1.525\, I_t^{T=30} + (1 - 0.714\, B^{12})a_{3,t}$$

dengan $\dot{y}_{3,t} = y_{3,t} - \mu$, dan $y_{3,t} = \mathrm{Ln}(\mathrm{Y}_{3,\mathrm{t}} + 1.5)$.

Berdasarkan pemodelan inflasi Palangkaraya yang telah dilakukan dengan beberapa metode, maka bisa dilakukan perbandingan model terbaik berdasarkan nilai RMSE *in-sample*. Hasil akurasi peramalan bisa diketahui berdasarkan nilai dari RMSE *out-sample*. Perbandingan nilai RMSE bisa dilihat pada Gambar 4.17.

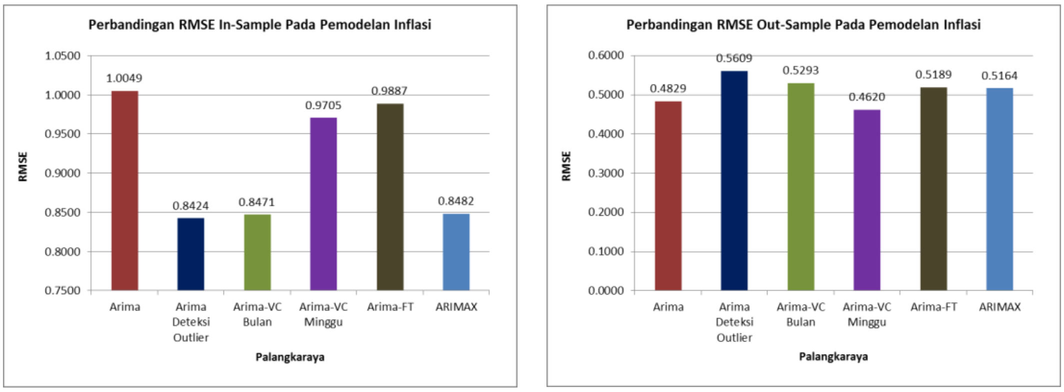

Gambar 4.17. Perbandingan RMSE Berdasarkan Model Inflasi Palangkaraya

Pada Gambar 4.17 memperlihatkan bahwa dalam pemodelan univariat untuk inflasi di Palangkaraya dengan penambahan variabel prediktor bisa menurunkan nilai tingkat kesalahan terhadap standar errornya. Model ARIMA dengan deteksi *outlier* merupakan model terbaik untuk inflasi Palangkaraya yang didasarkan pada nilai RMSE *in-sample* terkecil yaitu sebesar 0.8424.

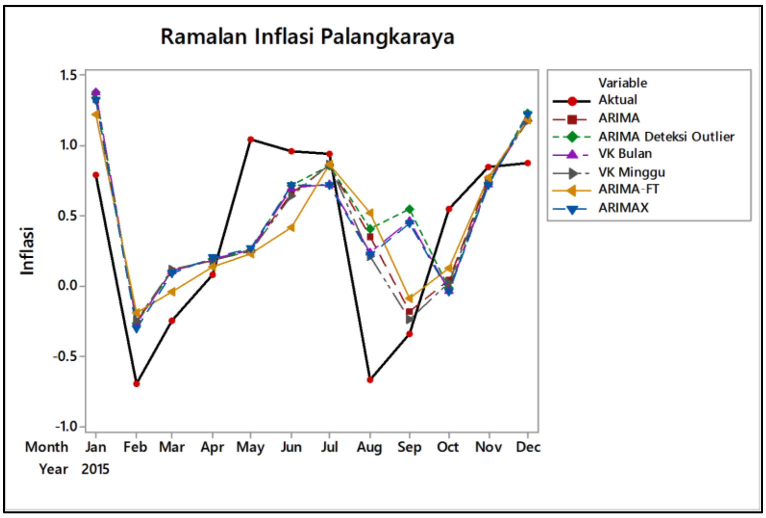

Gambar 4.18. Hasil Peramalan Inflasi Palangkaraya

Namun demikian berdasarkan tingkat akurasi ramalannya menunjukkan bahwa model ARIMA-Kalender Variasi dengan *dummy* mingguan merupakan model dengan akurasi ramalan lebih baik dibandingkan dengan model yang lain.

Hal ini dilihat pada nilai RMSE *out-sample* yang terkecil yaitu sebesar 0.4620. Hasil ramalan inflasi berdasarkan beberapa metode pemodelan dibandingkan dengan data aktual (*data out-sample*) dapat dilihat pada Gambar 4.18.

4.6. Pemodelan Inflasi Banjarmasin

4.6.1. Model ARIMA

Berdasarkan cara dan langkah yang sama dengan sebelumnya maka diperoleh plot ACF dan PACF (Lampiran 9.c) dan hasil identifikasi model ARIMA seperti pada Tabel 4.40. Hasil estimasi parameter untuk model terpilih dapat dilihat pada Tabel 4.41.

Tabel 4.40 Hasil Identifikasi dan Nilai AIC Model ARIMA Sementara Inflasi Banjarmasin

Model ARIMA Hasil Identifikasi	AIC	Keterangan
$(1,1,0)^{12}$	218.4706	-
$(0,1,1)^{12}$	**194.3731**	dipilih untuk pemodelan

Tabel 4.41. Hasil Estimasi Parameter Model ARIMA Inflasi Banjarmasin

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	White Noise	KS (*p-value*)
$(0,1,1)^{12}$	Θ_1	0.76749	0.05487	<.0001	Ya	0.051219 (>*0.1500*)

Hasil estimasi di atas memperlihatkan bahwa dengan menggunakan taraf uji $\alpha = 0.05$, maka parameter model ARIMA $(0,1,1)^{12}$ memiliki nilai *p-value* kurang dari 0.05 sehingga parameter tersebut bisa digunakan dalam model. Hasil uji asumsi juga menunjukkan model ARIMA $(0,1,1)^{12}$ telah memenuhi asumsi residual *white noise* dan berdistribusi normal. Secara matematis, model ARIMA $(0,1,1)^{12}$ bisa ditulis sebagai berikut :

$$\dot{y}_{4,t} = y_{4,t-12} + a_{4,t} - 0.76749\, a_{4,t-12}$$

dengan $\dot{y}_{4,t} = y_{4,t} - \mu$, dan $y_{4,t} = \mathrm{Ln}(\mathrm{Y}_{4,t} + 1.5)$

4.6.2. Model Variasi Kalender

Pemodelan ARIMA dengan efek variasi kalender bulanan untuk inflasi Banjarmasin tidak berbeda dengan cara dan langkah seperti di atas. Hasil estimasi parameter untuk model ARIMA dengan variasi kalender bulanan untuk inflasi Banjarmasin seperti ditunjukkan pada Tabel 4.42.

Tabel 4.42. Hasil Estimasi Parameter ARIMA dengan Variasi Kalender Bulanan untuk Inflasi Banjarmasin

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
CV-ARIMA $(0,1,1)^{12}$	Θ_1	0.80978	0.05304	<.0001	Ya	0.051384 (>*0.1500*)
	D_{t-1}	0.28119	0.12189	0.0224		

Hasil estimasi pada tabel di atas menunjukkan bahwa model tersebut sudah memenuhi syarat signifikan dan kelayakan model dimana residual dari model telah *white noise* dan mengikuti distribusi normal. Secara matematis, model variasi kalender bulanan dengan deteksi *outlier* bisa ditulis sebagai berikut :

$$\dot{y}_{4,t} = 0.282\, D_{t-1} + (1 - 0.810\, B^{12})a_{4,t}$$

dengan $\dot{y}_{4,t} = y_{4,t} - \mu$, dan $y_{4,t} = \mathrm{Ln}(\mathrm{Y}_{4,\mathrm{t}} + 1.5)$

Berdasarkan persamaan model variasi kalender bulanan tersebut menunjukkan bahwa inflasi di Banjarmasin dipengaruhi oleh satu bulan sebelum bulan perayaan Hari Raya Idul Fitri. Kondisi ini berkaitan dengan tradisi di Banjarmasin ketika memasuki bulan ramadhan terdapat pasar kaget yang sering disebut pasar kue. Permintaan terhadap barang konsumsi pada waktu itu cukup besar sehingga berakibat adanya kenaikan harga terhadap barang dan jasa yang dibutuhkan oleh masyarakat.

Adapun hasil estimasi model inflasi Banjarmasin dengan variasi kalender mingguan bisa dilihat pada Tabel 4.43 berikut. Pada tabel tersebut menunjukkan bahwa model variasi kalender mingguan untuk peramalan inflasi di Banjarmasin memiliki parameter yang signifikan pada taraf uji $\alpha = 0.05$. Disamping itu, hasil uji kelayakan terhadap model tersebut memperlihatkan bahwa residual dari model telah *white noise* dan mengikuti distribusi normal.

Tabel 4.43. Hasil Estimasi Parameter Variasi Kalender Mingguan Inflasi Banjarmasin

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	White Noise	KS (*p-value*)
CV-ARIMA $(0,1,1)^{12}$	Θ_1	0.80595	0.05366	<.0001	Ya	0.044911 (>*0.1500*)
	$D_{1,t-1}$	0.62307	0.24528	0.0121		
	$D_{3,t-1}$	0.40213	0.20016	0.0463		

Secara matematis, model variasi kalender mingguan di atas bisa ditulis sebagai berikut :

$$\dot{y}_{4,t} = 0.623\, D_{1,t-1} + 0.402\, D_{3,t-1} + (1 - 0.806\, B^{12})a_{4,t}$$

dengan $\dot{y}_{4,t} = y_{4,t} - \mu$, dan $y_{4,t} = \mathrm{Ln}(\mathrm{Y}_{4,t} + 1.5)$.

4.6.3. Model Fungsi Transfer

Berdasarkan plot ACF dan PACF deret input curah hujan (Lampiran 10.c) diperoleh model ARIMA yang untuk variabel input yaitu ARIMA $(2,0,0)(0,1,1)^{12}$ dengan persamaan ditulis :

$$\dot{x}_{4,t} = \frac{(1 - 0.7038\, B^{12})}{(1 - 0.251B - 0.157B^2)(1 - B^{12})} a_{4,t}$$

Berdasarkan model ARIMA terssebut maka didapatkan deret input curah hujan yang telah dilakukan *prewhitening* sebagai berikut :

$$\alpha_{4,t} = \frac{(1 - 0.251B - 0.157B^2)(1 - B^{12})}{(1 - 0.7038\, B^{12})} \dot{x}_{4,t}$$

Adapun *prewhitening* deret output inflasi Banjarmasin mengikuti *prewhitening* dari deret input curah hujan sehingga diperoleh output Inflasi Banjarmasin yang sudah dilakukan *prewhitening* yaitu sebagai berikut :

$$\beta_{3,t} = \frac{(1 - 0.251B - 0.157B^2)(1 - B^{12})}{(1 - 0.7038\, B^{12})} \dot{y}_{3,t}$$

Hasil CCF hasil *prewhitening* antara data inflasi dengan deret input curah hujan seperti pada Lampiran 11 (c). Berdasarkan hasil CCF bobot respons impuls yang terbentuk adalah *b*=0, *s*=0 dan *r*=0. Selanjutnya dengan bobot tersebut, dilakukan pemodelan ARIMA terhadap komponen *error* (n_t) sehingga mendapatkan residual yang *white noise*. Orde ARIMA ditentukan berdasarkan ACF dan PACF dari komponen *error* (n_t) hasil respons impuls seperti pada Lampiran 12 (c). Model ARIMA komponen *error* (n_t) yang terbentuk adalah ARIMA $(0,1,1)^{12}$. Hasil estimasi model fungsi transfer seperti dicantumkan pada Tabel 4.44 berikut ini.

Tabel 4.44. Hasil Estimasi Parameter Model Fungsi Transfer Inflasi Banjarmasin

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
FT-ARIMA $(0,1,1)^{12}$ *b*=0, *s*=0, *r*=0	Θ_1	0.7559	0.0578	<.0001	Ya	0.046313 >0.1500
	ω_0	-0.0126	0.0116	0.2809		
ARIMA $(0,1,1)^{12}$ *b*=0, *s*=0, *r*=0	Θ_1	0.76749	0.0549	<.0001	Ya	0.051219 >0.1500

Hasil pada tabel di atas menunjukkan bahwa parameter fungsi transfer (curah hujan) tidak signifikan pada taraf uji $\alpha = 0.05$, sehingga model fungsi transfer untuk inflasi Banjarmasin tidak bisa terbentuk. Dengan demikian, model terbaik untuk fungsi transfer inflasi Banjarmasin mengikuti model ARIMA. Secara matematis model bisa ditulis sebagai berikut :

$$\dot{y}_{4,t} = y_{4,t-12} + (1 - 0.76749B^{12})a_{4,t}$$

dimana $\dot{y}_{4,t} = y_{4,t} - \mu$, dan $y_{4,t} = \text{Ln}(\text{Y}_{4,\text{t}} + 1.5)$.

Secara simultan pemodelan ARIMAX untuk inflasi Banjarmasin dengan cara menggabungkan semua variabel eksogen dan hanya melibatkan variabel atau parameter yang signifikan seperti terlihat pada Tabel 4.45 di bawah ini.

Tabel 4.45. Hasil Estimasi Parameter Model ARIMAX Simultan Inflasi Banjarmasin

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
$([6],0,0)(0,1,1)^{12}$	Θ_1	0.7908	0.0550	<.0001	Ya	0.045988 (*>0.1500*)
	ϕ_6	-0.1696	0.0807	0.0373		
	D_{t-1}	0.2396	0.1216	0.0507		
	P_t	1.2492	0.4144	0.003		

Berdasarkan Tabel 4.45 di atas memperlihatkan bahwa parameter variabel input curah hujan tidak signifikan dalam model univariat simultan. Ini berarti curah hujan tidak mempunyai pengaruh yang signifikan pada inflasi di Banjarmasin. Hasil uji asumsi residual dari model tersebut sudah memenuhi untuk uji *white noise* dan kenormalan pada taraf uji $\alpha = 0.05$. Secara matematis, model tersebut dapat ditulis sebagai berikut :

$$\dot{y}_{4,t} = y_{4,t-12} - 0.170\, y_{4,t-6} + 0.170 y_{4,t-18} + 0.240\, D_{t-1} + 1.249\, P_t + (1 - 0.791\, B^{12}) a_{4,t}$$

dengan $\dot{y}_{4,t} = y_{4,t} - \mu$, dan $y_{4,t} = \mathrm{Ln}(\mathrm{Y}_{4,\mathrm{t}} + 1.5)$.

Persamaan model di atas menyimpulkan bahwa inflasi pada waktu ke-*t* mempunyai keterkaitan dengan inflasi yang terjadi pada bulan-bulan sebelumnya. Selain itu inflasi juga dipengaruhi adanya variasi kalender yang terjadi pada satu bulan sebelum bulan hari raya Idul Fitri.

Berdasarkan pemodelan inflasi Banjarmasin yang telah dilakukan dengan beberapa metode, maka bisa dilakukan perbandingan model terbaik berdasarkan nilai RMSE *in-sample*. Hasil akurasi peramalan bisa diketahui berdasarkan nilai dari RMSE *out-sample*. Perbandingan nilai RMSE bisa dilihat pada Gambar 4.19.

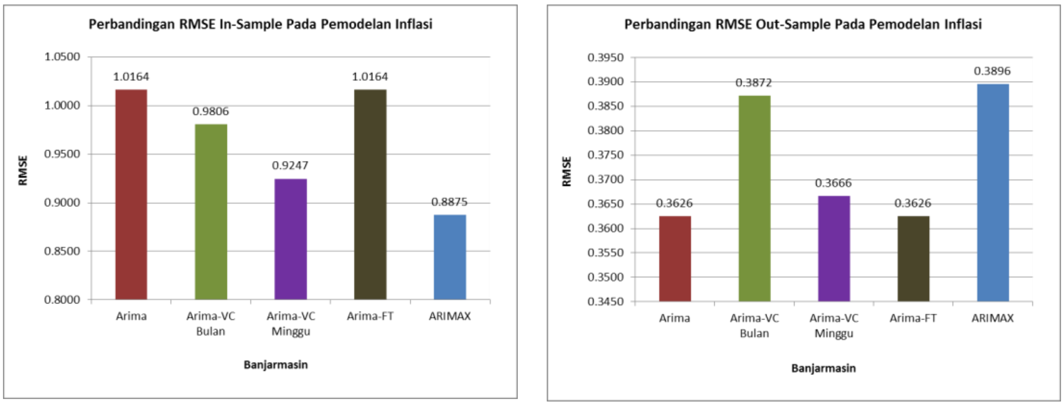

Gambar 4.19. Perbandingan RMSE Berdasarkan Model Inflasi Banjarmasin

Gambar 4.19 di atas menunjukkan bahwa model ARIMAX simultan merupakan model terbaik dibandingkan dengan model univariat lainnya untuk pemodelan inflasi di Banjarmasin. Hal ini didasarkan pada nilai RMSE *in-sample* terkecil yaitu sebesar 0.8875.

Namun demikian berdasarkan tingkat akurasi ramalan menunjukkan bahwa model ARIMA memberikan akurasi yang lebih tinggi dibandingkan dengan model yang lain. Hal ini terlihat pada nilai RMSE *out-sample* yang terkecil yaitu sebesar 0.3626. Adapun hasil ramalan inflasi berdasarkan beberapa metode pemodelan dibandingkan dengan data aktual (*data out-sample*) seperti ditunjukkan pada Gambar 4.20 di bawah ini.

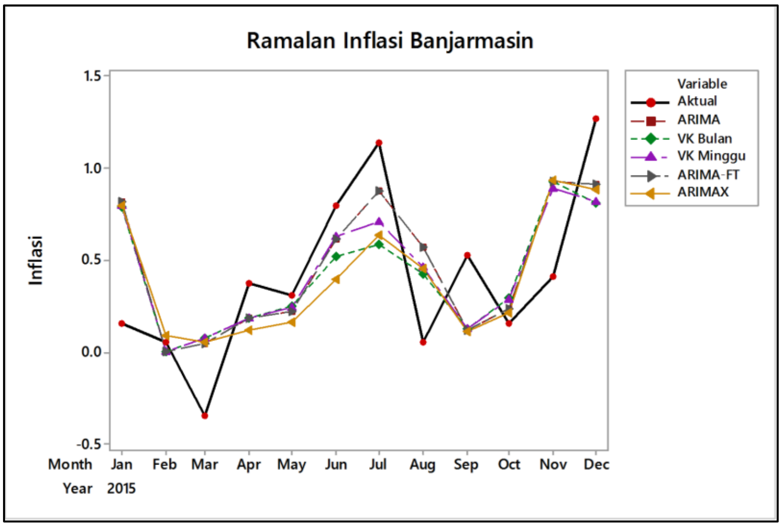

Gambar 4.20. Hasil Peramalan Inflasi Banjarmasin

4.7. Pemodelan Inflasi Balikpapan

4.7.1. Model ARIMA

Hasil identifikasi model ARIMA berdasarkan plot ACF dan PACF inflasi Balikpapan pada Lampira 9.d menghasilkan model ARIMA sementara untuk inflasi Balikpapan seperti pada Tabel 4.46 Adapun model ARIMA terbaik yang diperoleh dapat dilihat pada Tabel 4.47.

Tabel 4.46. Hasil Identifikasi dan Nilai AIC Model ARIMA Sementara Inflasi Balikpapan

Model ARIMA Hasil Identifikasi	AIC	Keterangan
ARIMA $(2,1,0)^{12}$	204.5324	-
ARIMA $(0,1,1)^{12}$	**199.2837**	dipilih untuk pemodelan

Tabel 4.47. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan ARIMA Inflasi Balikpapan

Model ARIMA	AIC	RMSE *in-sample*
ARIMA $(0,1,1)^{12}$	199.2837	0.4568
ARIMA $(0,1,1)^{12}$ dengan deteksi *outlier*	**156.1447**	**0.3953**

Mengacu pada nilai AIC dan RMSE *in-sample* menyimpulkan bahwa ARIMA $(0,0,0)(0,1,1)^{12}$ dengan deteksi *outlier* merupakan model terbaik yang bisa digunakan sebagai peramalan. Secara matematis, model ARIMA $(0,1,1)^{12}$ dengan deteksi *outlier* (Lampiran 14) untuk model inflasi Balikpapan bisa ditulis sebagai berikut :

$$\dot{y}_{5,t} = y_{5,t-12} - 2.263\, I_t^{T=153} - 1.555\, I_t^{T=58} + (1 - 0.697\, B^{12})a_{5,t}$$

dengan $\dot{y}_{5,t} = y_{5,t} - \mu$, dan $y_{5,t} = \mathrm{Ln}(\mathrm{Y}_{5,\mathrm{t}} + 1.5)$

4.7.2. Model Variasi Kalender

Dengan cara dan langkah yang sama, hasil estimasi parameter untuk model ARIMA dengan variasi kalender bulanan untuk inflasi Balikpapan seperti pada Tabel 4.48 di bawah ini.

Tabel 4.48. Hasil Estimasi Parameter ARIMA dengan Variasi Kalender Bulanan Inflasi Balikpapan

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	White Noise	KS (*p-value*)
CV_ARIMA $(0,1,1)^{12}$	Θ_1	0.7589	0.05544	<.0001	Ya	0.091056 (*<0.0100*)
	D_{t-1}	0.34177	0.12534	0.0071		
CV-ARIMA $(0,1,1)^{12}$ Deteksi *Outlier*	Θ_1	0.73417	0.05699	<.0001	Ya	0.066501 (*0.0898*)
	D_{t-1}	0.30586	0.11575	0.0091		
	ω_{A153}	-2.23436	0.39687	<.0001		

Hasil estimasi pada Tabel 4.48 di atas menunjukkan bahwa variasi kalender bulanan dengan deteksi *outlier* lebih layak untuk digunakan dalam pemodelan dan peramalan inflasi di Balikpapan. Model tersebut didukung dengan kriteria nilai AIC dan RMSE *in-sample* terkecil pada kedua model variasi kalender bulanan tersebut seperti disajikan pada Tabel 4.49 di bawah ini.

Tabel 4.49. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan Variasi Kalender Bulanan Inflasi Balikpapan

Model ARIMA Variasi Kalender	**AIC**	**RMSE *in-sample***
CV-ARIMA $(0,1,1)^{12}$	194.5332	0.4485
CV-ARIMA $(0,1,1)^{12}$ dengan deteksi *outlier*	167.2104	0.4096

Secara matematis, model variasi kalender bulanan dengan deteksi *outlier* bisa ditulis sebagai berikut :

$$\dot{y}_{5,t} = 0.306\, D_{t-1} - 2.234\, I_t^{T=153} + (1 - 0.734\, B^{12})a_{5,t}$$

dengan $\dot{y}_{5,t} = y_{5,t} - \mu$, dan $y_{5,t} = \mathrm{Ln}(\mathrm{Y}_{5,\mathrm{t}} + 1.5)$

Berdasarkan persamaan model variasi kalender bulanan tersebut menunjukkan bahwa kejadian satu bulan sebelum bulan hari raya Idul Fitri di Balikpapan berkaitan dengan terjadinya inflasi. Disamping adanya faktor deflasi yang terjadi pada *T*=153 (September 2013) yang memberikan pengaruh terhadap besaran inflasi di Balikpapan. Untuk model inflasi Balikpapan dengan variasi kalender mingguan bisa dilihat hasil estimasinya pada Tabel 4.50.

Tabel 4.50. Hasil Estimasi Parameter Variasi Kalender Mingguan Inflasi Balikpapam

<table>
<tr><th>Model ARIMA</th><th>Para-meter</th><th>Estimasi</th><th>Standar Error</th><th>P-value</th><th>White Noise</th><th>KS (p-value)</th></tr>
<tr><td rowspan="4">$(0,1,1)^{12}$
Dengan Deteksi Outlier</td><td>Θ_1</td><td>0.70844</td><td>0.05918</td><td><.0001</td><td rowspan="4">Ya</td><td rowspan="4">0.057368
(>0.1500)</td></tr>
<tr><td>$D_{1,t-1}$</td><td>0.60605</td><td>0.21609</td><td>0.0057</td></tr>
<tr><td>$D_{2,t-1}$</td><td>0.48793</td><td>0.18866</td><td>0.0106</td></tr>
<tr><td>ω_{A153}</td><td>-2.21564</td><td>0.38718</td><td><.0001</td></tr>
</table>

Berdasarkan hasil estimasi parameter di atas, memperlihatkan bahwa model variasi kalender mingguan denga deteksi *outlier* untuk peramalan inflasi

Balikpapan telah signifikan pada taraf uji $\alpha = 0.05$. Pada uji asumsi residual, model tersebut juga sudah memenuhi uji kelayakan model.

Secara matematis, model variasi kalender mingguan di atas bisa ditulis sebagai berikut :

$$\dot{y}_{5,t} = 0.0.606\, D_{1,t-1} + 0.488\, D_{2,t-1} - 2.216\, I_t^{T=153} + (1 - 0.708\, B^{12})a_{5,t}$$

dengan $\dot{y}_{5,t} = y_{5,t} - \mu$, dan $y_{5,t} = \mathrm{Ln}(\mathrm{Y}_{5,\mathrm{t}} + 1.5)$

Model variasi kalender mingguan tersebut mendukung model variasi kalender bulanan dimana terjadinya inflasi lebih sering terjadi pada satu bulan sebelum bulan perayaan hari raya Idul Fitri.

4.7.3. Model Fungsi Transfer

Berdasarkan plot ACF dan PACF deret input curah hujan (Lampiran 10.d.) diperoleh model ARIMA yang untuk variabel input yaitu ARIMA $(0,0,[3])(0,1,1)^{12}$ dengan persamaan ditulis :

$$\dot{x}_{5,t} = \frac{(1 + 0.186B^3)(1 - 0.753\, B^{12})}{(1 - B^{12})} a_{5,t}$$

Berdasarkan model ARIMA tersebut maka didapatkan deret input curah hujan yang telah dilakukan *prewhitening* sebagai berikut :

$$\alpha_{5,t} = \frac{(1 - B^{12})}{(1 + 0.186B^3)(1 - 0.753\, B^{12})} \dot{x}_{5,t}$$

Adapun *prewhitening* deret output inflasi Balikpapan mengikuti *prewhitening* dari deret input curah hujan sehingga dihasilkan output Inflasi Balikpapan yang sudah dilakukan *prewhitening* yaitu sebagai berikut :

$$\beta_{5,t} = \frac{(1 - B^{12})}{(1 + 0.186B^3)(1 - 0.753\, B^{12})} \dot{y}_{5,t}$$

Plot CCF hasil *prewhitening* antara data inflasi dengan deret input curah hujan seperti ditunjukkan pada Lampiran 11 (d). Berdasarkan pada hasil plot CCF maka bobot respons impuls yang terbentuk adalah *b*=4, *s*=0 dan *r*=0. Selanjutnya dengan bobot tersebut, dilakukan pemodelan ARIMA terhadap komponen *error*

(n_t) sehingga mendapatkan residual yang *white noise*. Orde ARIMA ditentukan berdasarkan ACF dan PACF dari komponen *error* (n_t) hasil respons impuls seperti pada Lampiran 12 (d). Model ARIMA komponen *error* (n_t) yang terbentuk adalah ARIMA $(0,1,1)^{12}$. Hasil estimasi model fungsi transfer seperti dicantumkan pada Tabel 4.51 berikut ini.

Tabel 4.51. Hasil Estimasi Parameter Model Fungsi Transfer Inflasi Balikpapan

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
FT-ARIMA $(0,1,1)^{12}$ *b*=4, *s*=0 dan *r*=0	Θ_1	0.6701	0.0627	<.0001	Ya	0.08995 (*<0.0100*)
	ω_0	-0.0154	0.0089	0.0856		
FT-ARIMA $(0,1,1)^{12}$ *b*=4, *s*=0 dan *r*=0. Dengan Deteksi Outlier	Θ_1	0.7221	0.0601	<.0001	Ya	0.051772 (*>0.1500*)
	ω_0	-0.0102	0.0071	0.1578		
	ω_{AO153}	-2.2653	0.3523	<.0001		
	ω_{AO58}	1.5097	0.3426	<.0001		
	ω_{AO68}	-1.2759	0.3397	0.0002		
	ω_{LS8}	-0.6421	0.1461	<.0001		

Berdasarkan pada tabel di atas menyimpulkan bahwa model fungsi transfer tanpa deteksi *outlier* masih belum memenuhi asumsi kenormalan, namun di sisi lain, model dengan deteksi *outlier* justru memperlihatkan bahwa parameter dari variabel input curah hujan menjadi tidak signifikan. Berdasarkan nilai AIC dari kedua model tersebut, menyimpulkan bahwa model dengan deteksi outlier merupakan model yang terbaik seperti pada Tabel 4.52.

Tabel 4.52. Nilai AIC dan RMSE *In-Sample* Hasil Pemodelan Fungsi Transfer Inflasi Balikpapan

Model ARIMA Variasi Kalender	**AIC**	**RMSE *in-sample***
FT-ARIMA $(0,1,1)^{12}$	197.8611	0.4609
FT-ARIMA $(0,1,1)^{12}$ dengan deteksi *outlier*	**130.3929**	**0.3645**

Secara matematis model fungsi transfer dengan deteksi outlier bisa ditulis sebagai berikut :

$$\dot{y}_{5,t} = -0.010\, x_{5,t-4} - 2.265\, I_t^{T=153} + 1.509\, I_t^{T=58} - 1.276\, I_t^{T=68} - \frac{1}{(1-B)} 0.642 I_t^{T=8} + (1 - 0.722B^{12}) a_{5,t}$$

dimana $\dot{y}_{5,t} = y_{5,t} - \mu$, dan $y_{5,t} = \text{Ln}(\text{Y}_{5,\text{t}} + 1.5)$.

Secara simultan pemodelan ARIMAX untuk inflasi Balikpapan dengan cara menggabungkan semua variabel eksogen dan hanya melibatkan variabel atau parameter yang signifikan seperti ditunjukkan pada Tabel 4.53 di bawah ini.

Tabel 4.53. Hasil Estimasi Parameter Model ARIMAX Simultan Inflasi Balikpapan

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	***P-value***	**White Noise**	**KS (*p-value*)**
$(0,1,1)^{12}$	Φ_1	0.6970	0.0599	<.0001	Ya	0.06988 (*0.0619*)
	P_t	1.5552	0.3660	<.0001		
	ω_{AO153}	-2.2628	0.3799	<.0001		

Berdasarkan pada Tabel 4.53 memperlihatkan bahwa model simultan trsebut telah memenuhi uji kelayakan model. Namun demikian, parameter untuk variabel input (curah hujan) dinilai tidak signifikan dan ini berarti bahwa curah hujan tidak berpengaruh signifikan terhadap inflasi yang trjadi di Balikpapan. Secara matematis, model tersebut bisa ditulis sebagai berikut :

$$\dot{y}_{5,t} = y_{5,t-12} + 1.555\, P_t - 2.263\, I_t^{T=153} + (1 - 0.697) a_{5,t}$$

dengan $\dot{y}_{5,t} = y_{5,t} - \mu$, dan $y_{5,t} = \text{Ln}(\text{Y}_{5,\text{t}} + 1.5)$.

Berdasarkan pemodelan inflasi Balikpapan yang telah dilakukan dengan beberapa metode, maka bisa dilakukan perbandingan model terbaik berdasarkan nilai RMSE *in-sample*. Hasil akurasi peramalan bisa diketahui berdasarkan nilai dari RMSE *out-sample*. Perbandingan nilai RMSE bisa dilihat pada Gambar 4.21 di bawah ini.

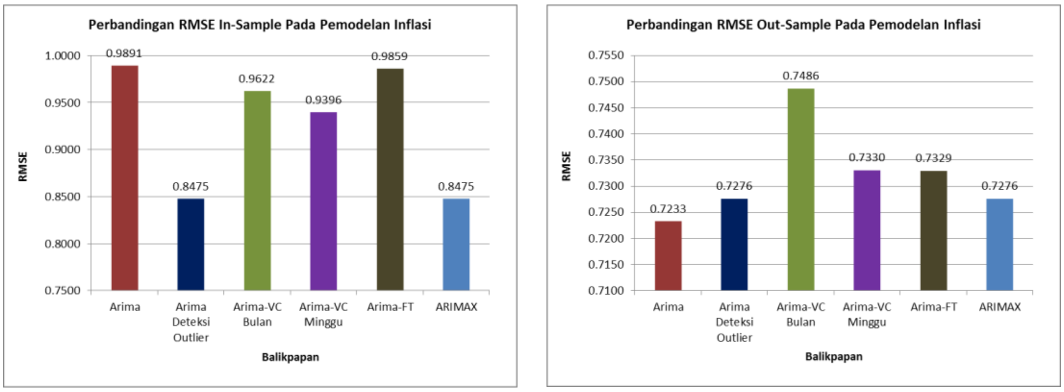

Gambar 4.21. Perbandingan RMSE Berdasarkan Model Inflasi Balikpapan

Gambar 4.21 menunjukkan bahwa model ARIMA dengan deteksi *outlier* merupakan model terbaik dibandingkan dengan model univariat lainnya untuk pemodelan inflasi di Balikpapan. Hal ini didasarkan pada nilai RMSE *in-sample* terkecil yaitu sebesar 0.8475.

Namun demikian berdasarkan tingkat akurasi ramalan menunjukkan bahwa model ARIMA memberikan akurasi yang lebih tinggi dibandingkan dengan model yang lain. Hal ini terlihat pada nilai RMSE *out-sample* yang terkecil yaitu sebesar 0.7233. Adapun hasil ramalan inflasi berdasarkan beberapa metode pemodelan dibandingkan dengan data aktual (*data out-sample*) seperti ditunjukkan pada Gambar 4.22 berikut.

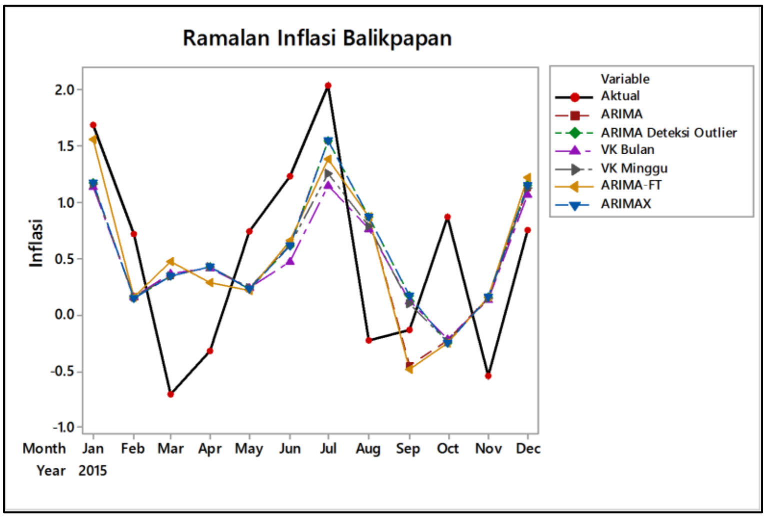

Gambar 4.22. Hasil Peramalan Inflasi Balikpapan

4.8. Pemodelan Inflasi Samarinda

4.8.1. Model ARIMA

Berdasarkan cara dan langkah yang sama dengan sebelumnya maka diperoleh plot ACF dan PACF (Lampiran 9.e) dan hasil identifikasi model ARIMA seperti pada Tabel 4.54.

Tabel 4.54. Hasil Identifikasi dan Nilai AIC Model ARIMA Sementara Inflasi Samarinda

Model ARIMA Hasil Identifikasi	AIC	Keterangan
ARIMA $(0,1,1)^{12}$	196.6802	-
ARIMA $([3],0,0)(0,1,1)^{12}$	**193.0569**	dipilih untuk pemodelan

Berdasarkan pada tabel di atas serta mengacu pada penggunaan kriteria AIC terkecil maka model ARIMA $([3],0,0)(0,1,1)^{12}$ selanjutnya akan digunakan untuk memodelkan inflasi di Samarinda. Hasil estimasi parameter untuk model ARIMA $([3],0,0)(0,1,1)^{12}$ seperti pada Tabel 4.55.

Tabel 4.55. Hasil Estimasi Parameter Model ARIMA Inflasi Samarinda

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	White Noise	KS (*p-value*)
$([3],0,0)(0,1,1)^{12}$	Θ_1	0.72075	0.0581	<.0001	Ya	0.068031 (*0.0772*)
	ϕ_3	-0.19537	0.08059	0.0165		

Hasil estimasi di atas memperlihatkan bahwa model ARIMA $([3],0,0)(0,1,1)^{12}$ baik dari sisi parameter maupun asumsi telah memenuhi kelayakan model untuk peramalan. Secara matematis, model ARIMA $([3],0,0)(0,1,1)^{12}$ bisa ditulis sebagai berikut :

$$\dot{y}_{6,t} = -0.195\, y_{6,t-3} + y_{6,t-12} + 0.195\, y_{6,t-15} + a_{6,t} - 0.721\, a_{6,t-12}$$

dengan $\dot{y}_{6,t} = y_{6,t} - \mu$, dan $y_{6,t} = \text{Ln}(\text{Y}_{6,t} + 1.5)$.

4.8.2. Model Variasi Kalender

Dengan cara dan langkah yang sama, hasil estimasi parameter untuk model ARIMA dengan variasi kalender bulanan untuk inflasi Samarinda seperti pada Tabel 4.56 di bawah ini.

Tabel 4.56. Hasil Estimasi Parameter ARIMA dengan Variasi Kalender Bulanan untuk Inflasi Samarinda

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
CV-ARIMA $(0,1,1)^{12}$	Θ_1	0.73672	0.05774	<.0001	Ya	0.063069 (>*0.1314*)
	D_{t-1}	0.28773	0.132	0.0308		
	D_t	0.39851	0.13269	0.0031		

Hasil estimasi pada Tabel 4.56 di atas menunjukkan bahwa model ARIMA dengan variasi kalender bulanan untuk inflasi Samarinda telah memenuhi syarat signifikan dalam parameternya. Demikian juga dengan Hasil uji asumsi yang memperlihatkan bahwa residual sudah *white noise* dan mengikuti distribusi normal. Secara matematis, model ARIMA $(0,1,1)^{12}$ dengan variasi kalender bulanan untuk model inflasi Samarinda bisa ditulis sebagai berikut :

$$\dot{y}_{6,t} = 0.288\, D_{t-1} + 0.398\, D_t + (1 - 0.737\, B^{12})a_{6,t}$$

dengan $\dot{y}_{6,t} = y_{6,t} - \mu$, dan $y_{6,t} = \text{Ln}(\text{Y}_{6,\text{t}} + 1.5)$

Berdasarkan persamaan model variasi kalender bulanan tersebut menunjukkan bahwa pada bulan dimana terdapat bulan perayaan hari raya Idul Fitri serta satu bulan sebelum bulan perayaan Idul Fitri mempengaruhi terhadap besar kecilnya inflasi.

Tabel 4.57. Hasil Estimasi Parameter Variasi Kalender Mingguan Inflasi Samarinda

Model ARIMA	**Para-meter**	**Estimasi**	**Standar Error**	**P-value**	**White Noise**	**KS (*p-value*)**
CV-ARIMA $(0,0,[23])(0,1,1)^{12}$	θ_{23}	-0.25961	0.08406	0.0024	Ya	0.05162 (>*0.1500*)
	Θ_1	0.73928	0.05659	<.0001		
	$D_{1,t-1}$	0.55965	0.22157	0.0126		

Adapun model variasi kalender mingguan untuk inflasi Samarinda dapat dilihat pada Tabel 4.57. di atas. Pada Tabel 4.57 memperlihatkan bahwa model ARIMA $(0,0,[23])(0,1,1)^{12}$ dengan variasi kalender mingguan untuk inflasi Samarinda telah memenuhi syarat signifikan dalam parameternya. Demikian juga dengan Hasil uji asumsi yang memperlihatkan bahwa residual sudah *white noise* dan mengikuti distribusi normal. Secara matematis, model ARIMA $(0,0,[23])(0,1,1)^{12}$ dengan variasi kalender mingguan untuk model inflasi Samarinda bisa ditulis sebagai berikut :

$$\dot{y}_{6,t} = 0.560\, D_{1,t-1} + (1 + 0.260\, B^{23})(1 - 0.739\, B^{12})\, a_{6,t}$$

dengan $\dot{y}_{6,t} = y_{6,t} - \mu$, dan $y_{6,t} = \mathrm{Ln}(\mathrm{Y}_{6,\mathrm{t}} + 1.5)$

4.8.3. Model Fungsi Transfer

Berdasarkan plot ACF dan PACF deret input curah hujan (Lampiran 10.e) diperoleh model ARIMA yang untuk variabel input yaitu ARIMA $(0,0,1)(0,1,1)^{12}$ dengan persamaan ditulis :

$$\dot{x}_{6,t} = \frac{(1 + 0.175)(1 - 0.799B^{12})}{(1 - B^{12})}\, a_{6,t}$$

Berdasarkan model ARIMA tersebut maka didapatkan deret input curah hujan yang telah dilakukan *prewhitening* sebagai berikut :

$$\alpha_{6,t} = \frac{(1 - B^{12})}{(1 + 0.175)(1 - 0.799B^{12})}\, \dot{x}_{6,t}$$

Adapun *prewhitening* deret output inflasi Samarinda mengikuti *prewhitening* dari deret input curah hujan sehingga diperoleh output Inflasi Samarinda yang sudah melalui *prewhitening* yaitu sebagai berikut :

$$\beta_{6,t} = \frac{(1 - B^{12})}{(1 + 0.175)(1 - 0.799B^{12})}\, \dot{y}_{6,t}$$

Plot CCF hasil *prewhitening* antara data inflasi dengan deret input curah hujan seperti ditunjukkan pada Lampiran 11 (e). Berdasarkan pada hasil plot CCF maka bobot respons impuls yang terbentuk adalah *b*=5, *s*=0 dan *r*=0. Selanjutnya dengan bobot tersebut, dilakukan pemodelan ARIMA terhadap komponen *error*

(n_t) sehingga mendapatkan residual yang *white noise*. Orde ARIMA ditentukan berdasarkan ACF dan PACF dari komponen *error* (n_t) hasil respons impuls seperti pada Lampiran 12 (e). Model ARIMA komponen *error* (n_t) yang terbentuk adalah ARIMA ([3],0,0)(0,1,1)^{12}. Hasil estimasi model fungsi transfer seperti dicantumkan pada di bawah ini.

Tabel 4.58. Hasil Estimasi Parameter Model Fungsi Transfer Inflasi Samarinda

Model ARIMA	Para-meter	Estimasi	Standar Error	P-value	White Noise	KS (*p-value*)
FT-ARIMA ([3],0,0)(0,1,1)^{12} *b*=5, *s*=0 dan *r*=0.	Θ_1	0.6949	0.0616	<.0001	Ya	0.053177 (>*0.1500*)
	ϕ_3	-0.2004	0.0824	0.0162		
	ω_0	-0.0009	0.0004	0.0182		

Pada Tabel 4.58 memberikan penjelasan bahwa parameter dalam model fungsi transfer telah signifikan pada taraf uji α = 0.05 serta model tersebut sudah memenuhi asumsi uji *white noise* dan normalitas. Secara matematis model fungsi transfer di atas bisa ditulis sebagai berikut :

$$\dot{y}_{6,t} = y_{6,t-12} - 0.200y_{6,t-3} + 0.200y_{6,t-15} - 0.0009x_{6,t-5} + (1 - 695B^{12})a_{6,t}$$

dimana $\dot{y}_{6,t} = y_{6,t} - \mu$, dan $y_{6,t} = \text{Ln}(\text{Y}_{6,\text{t}} + 1.5)$.

Secara simultan pemodelan ARIMAX untuk inflasi Samarinda seperti terlihat pada Tabel 4.59 di bawah ini.

Tabel 4.59. Hasil Estimasi Parameter Model ARIMAX Simultan Inflasi Samarinda

Model ARIMA	Para-meter	Estimasi	Standar Error	*P-value*	White Noise	KS (*p-value*)
ARIMA (0,1,1)^{12} dengan deteksi *outlier*	Θ_1	0.6838	0.0620	<.0001	Ya	0.0702 (>*0.0593*)
	D_t	0.3168	0.1125	0.0055		
	P_t	1.6204	0.3567	<.0001		
	ω_{AO95}	-2.0441	0.3556	<.0001		

Hasil estimasi pada Tabel 4.59 di atas memperlihatkan bahwa model simultan tersebut telah memenuhi uji kelayakan model. Namun demikian, parameter untuk variabel input (curah hujan) dinilai tidak signifikan dan ini berarti bahwa curah hujan tidak berpengaruh signifikan terhadap inflasi yang di Samarinda. Secara matematis, model tersebut bisa ditulis sebagai berikut :

$$\dot{y}_{6,t} = y_{6,t-12} + 0.317\, D_t + 1.620\, P_t - 2.044\, I_t^{T=95} + (1 - 0.684\, B^{12})a_{6,t}$$

dengan $\dot{y}_{6,t} = y_{6,t} - \mu$, dan $y_{6,t} = \mathrm{Ln}(\mathrm{Y}_{6,\mathrm{t}} + 1.5)$.

Pemodelan inflasi Samarinda yang telah dilakukan dengan beberapa metode memberikan gambaran dan perbandingan model terbaik berdasarkan nilai RMSE *in-sample*. Hasil akurasi peramalan bisa diketahui berdasarkan nilai dari RMSE *out-sample*.

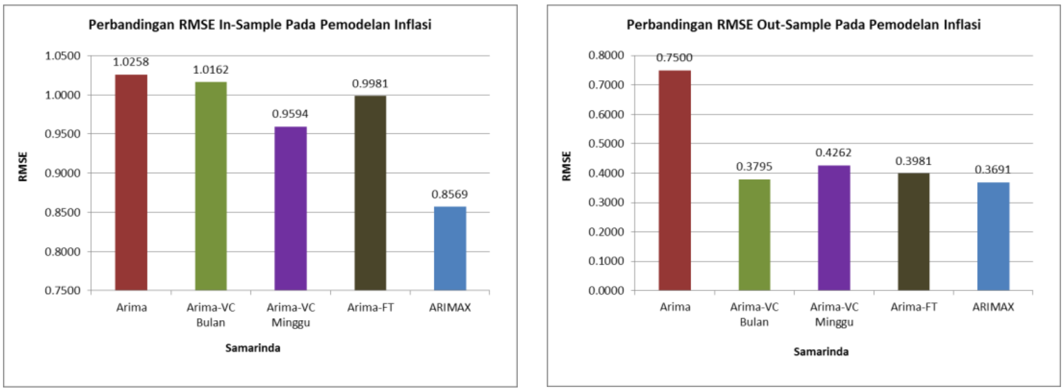

Gambar 4.23. Perbandingan RMSE Berdasarkan Model Inflasi Samarinda

Gambar 4.23 di atas menunjukkan bahwa model ARIMAX secara simultan memiliki nilai RMSE *in-sample* terkecil yaitu sebesar 0.8569. Hal ini bisa dikatakan bahwa model ARIMAX simultan merupakan model terbaik dibandingkan dengan model univariat lainnya untuk pemodelan inflasi di Samarinda. Demikian juga berdasarkan tingkat akurasi ramalan menunjukkan bahwa model ARIMAX simultan memberikan akurasi yang lebih tinggi dibandingkan dengan model yang lain. Hal ini terlihat pada nilai RMSE *out-sample* yang terkecil yaitu sebesar 0.3691. Adapun hasil ramalan inflasi berdasarkan beberapa metode pemodelan dibandingkan dengan data aktual (*data out-sample*) seperti ditunjukkan pada Gambar 4.24 di bawah ini.

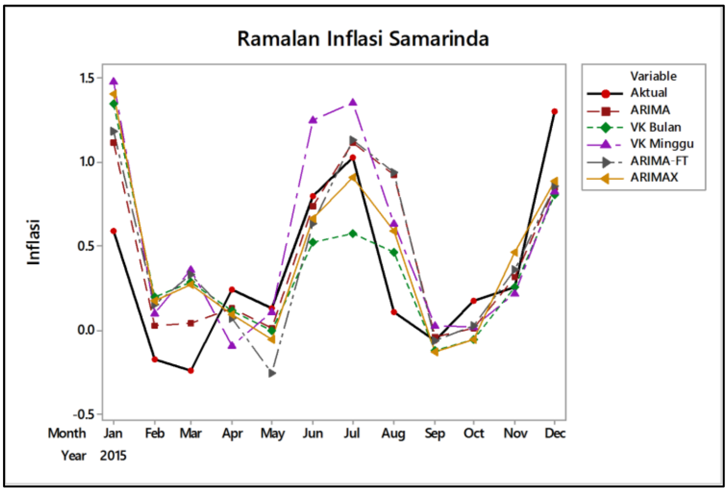

Gambar 4.24. Hasil Peramalan Inflasi Samarinda

4.9. Pemodelan GSTAR

Pemodelan GSTAR secara umum mengikuti prosedur Box-Jenkins yaitu identifikasi stasioneritas, penentuan orde waktu dan spasial, estimasi parameter dengan menggunakan beberapa bobot lokasi, tahapan pengecekan kelayakan model dan tahap peramalan

4.9.1. Identifikasi Model GSTAR

Identifikasi stasioneritas secara multivariat terhadap data inflasi $(Y_{i,t})$ enam kota di Kalimantan bisa dilihat secara visual dari skema plot MCCF seperti ditunjukkan pada gambar di bawah ini.

```
                 Schematic Representation of Cross Correlations

Variable/
Lag             0      1      2      3      4      5      6      7      8      9

u1           ++++++ ...... ...... ...... ...+.. ...... ...... .+.+.. .+.... ......
u2           ++++++ ..+..+ ...... ...... --...- .....- ...... ...... ...... ..+..+
u3           ++++++ .++++. +..... .--... ...... ...... ...... ...... ...... ......
u4           ++++++ ...... ...... ...... .+.... ...... ...... ...... ...... ......
u5           ++++++ .....+ +..... +..... .++... ...... ...... +..... ...... .+....
u6           ++++++ ..+.+. ...... .-.... ...... ...... ...... .+.+.. .+.... ......

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

Gambar 4.25 Skema MCCF Data Inflasi

Berdasarkan pada skema MCCF terlihat bahwa data sudah stasioner yang ditunjukkan adanya banyak tanda titik (.) yang muncul pada plot MCCF. Pada plot MCCF juga memperlihatkan adanya korelasi antar wilayah yang diperlihatkan adanya tanda (+) pada lag 0 untuk semua wilayah meskipun dengan tingkat korelasi yang kecil.

Penentuan orde waktu (AR) untuk model GSTAR diidentifikasi dengan melihat skema plot MPCCF. Berbagai kemungkinan orde yang terbentuk dari hasil identifikasi pada skema MPCCF, maka untuk memilih orde GSTAR yang akan digunakan ditentukan berdasarkan nilai AICC yang terkecil.

Berdasarkan skema plot MPCCF pada Gambar 4.25 terlihat bahwa pada lag ke 4, 9 dan 12 memiliki tanda positif (+) atau negatif (-) yang lebih banyak dibandingkan lainnya atau dengan kata lain bersifat signifikan. Sehingga orde AR untuk GSTAR terdapat berbagai kemungkinan berdasarkan pada lag-lag tersebut seperti ditampilkan pada Tabel 4.60.

```
        Schematic Representation of Partial Cross Correlations

Variable/
Lag         1      2      3      4      5      6      7      8      9      10

u1       ...... ...... ...... ...+.. ...... ...... ...... ...... ...... ..-.-.
u2       ...... ...... ...... --.... ...... ..-+.. ...... ...-.. .....+ ......
u3       .+.... +.-.+. ...... ...... ...... .+.... ...... .....+ ..+... ......
u4       ...... ...... ...... .+.... ...-.. ...-.. ...... ...... .+.... ......
u5       ...... +..... ...... ..+..+ ...... ...... ...... ...... .....- ..-...
u6       ...... ...... .-...- .-.... ...... ...... ...... ...... ...... ...-..

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

Gambar 4.26 Skema MPCCF Inflasi ($Y_{i,t}$) Enam Wilayah di Kalimantan.

```
Variable/
Lag           11       12       13       14

u1          ....+.   ......   ......   ......
u2          ......   ......   ......   ....+.
u3          ......   ..-...   -.....   ......
u4          ...+..   ...-..   ......   ......
u5          ......   .+..-.   ...+..   ......
u6          ......   .....-   ......   ......
```

Lanjutan Gambar 4.26

Tabel 4.60. Identifikasi Orde AR untuk GSTAR dan Nilai AIC

Orde AR untuk GSTAR	Nilai AIC	Orde AR untuk GSTAR	Nilai AIC
[4]	-9.3908	[4,12]	-10.3823
[9]	-9.05363	[9,12]	-10.0343
[12]	**-10.3923**	[4,9,12]	-10.0371
[4,9]	-9.1881		

Hasil identifikasi orde waktu (AR) untuk model GSTAR berdasarkan pada Tabel 4.60 menunjukkan bahwa orde AR yang bisa digunakan adalah orde *p*=[12] karena memiliki nilai AIC yang terkecil (-10.3923) dibandingkan dengan kemungkinana orde AR yang lain. Adapun untuk orde spasial yang digunakan dalam penelitian ini dibatasi pada orde 1. Dengan demikian, model GSTAR yang digunakan dalam penelitian ini adalah model GSTAR ($[12]_1$). Model GSTAR ($[12]_1$) dapat ditulis sebagai berikut :

$$\boldsymbol{Y}(t) = \boldsymbol{\Phi}_{120}\boldsymbol{Y}(t-12) + \boldsymbol{\Phi}_{121}\boldsymbol{W}^{(1)}\boldsymbol{Y}(t-12) + \boldsymbol{e}(t)$$

Model tersebut jika ditulis dalam bentuk matriks adalah sebagai berikut :

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \\ Y_4(t) \\ Y_5(t) \\ Y_6(t) \end{bmatrix} = \begin{bmatrix} \phi_{10}^{12} & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{12} & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{12} & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{12} & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{12} & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{60}^{12} \end{bmatrix} \begin{bmatrix} Y_1(t-12) \\ Y_2(t-12) \\ Y_3(t-12) \\ Y_4(t-12) \\ Y_5(t-12) \\ Y_6(t-12) \end{bmatrix} +$$

$$\begin{bmatrix} \phi_{11}^{12} & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{12} & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{12} & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{12} & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{12} & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{61}^{12} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} & w_{14} & w_{15} & w_{16} \\ w_{21} & 0 & w_{23} & w_{24} & w_{25} & w_{26} \\ w_{31} & w_{32} & 0 & w_{34} & w_{35} & w_{36} \\ w_{41} & w_{42} & w_{43} & 0 & w_{45} & w_{46} \\ w_{51} & w_{52} & w_{53} & w_{54} & 0 & w_{56} \\ w_{61} & w_{62} & w_{63} & w_{64} & w65 & 0 \end{bmatrix} \begin{bmatrix} Y_1(t-12) \\ Y_2(t-12) \\ Y_3(t-12) \\ Y_4(t-12) \\ Y_5(t-12) \\ Y_6(t-12) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \\ e_4(t) \\ e_5(t) \\ e_6(t) \end{bmatrix}.$$

4.9.2. Estimasi Parameter

Pemodelan GSTAR untuk inflasi enam wilayah di Kalimantan menggunakan metode estimasi GLS. Oleh karena itu dalam pemodelan GSTAR ($[12]_1$) pada data inflasi pada enam kota di Kalimantan selanjutnya dinamakan sebagai pemodelan GSTAR-GLS ($[12]_1$). Bobot lokasi yang digunakan adalah menggunakan bobot lokasi seragam, invers jarak, normalisasi korelasi silang dan normalisasi inferensia parsial korelasi silang.

4.9.2.1. Pemodelan GSTAR-GLS ($[12]_1$) dengan Bobot Seragam

Bobot lokasi seragam mengasumsikan bahwa data inflasi memiliki keterkaitan yang sama antar lokasi (spasial). Oleh karena itu, pemberian bobot lokasi ke-*i* dan ke-*j* adalah sama. Pada penelitian ini, jumlah lokasi dalam penelitian sebanyak enam lokasi. Nilai $w_{ij} = \frac{1}{n_i}$, dengan $n_i = 5$, maka $w_{ij} = 0.2$ pada setiap wilayah pada lag waktu ke-1 dengan lokasi yang berbeda pada waktu yang sama. Bobot seragam untuk enam wilayah dalam bentuk matriks adalah sebagai berikut :

$$\boldsymbol{W} = \begin{bmatrix} 0 & 0.2 & 0.2 & 0.2 & 0.2 & 0.2 \\ 0.2 & 0 & 0.2 & 0.2 & 0.2 & 0.2 \\ 0.2 & 0.2 & 0 & 0.2 & 0.2 & 0.2 \\ 0.2 & 0.2 & 0.2 & 0 & 0.2 & 0.2 \\ 0.2 & 0.2 & 02 & 0.2 & 0 & 0.2 \\ 0.2 & 0.2 & 0.2 & 0.2 & 0.2 & 0 \end{bmatrix}$$

Hasil estimasi parameter untuk model GSTAR-GLS($[12]_1$) yang *full model* dapat dilihat pada Tabel 4.61.

Tabel 4.61. Estimasi Parameter *Full Model* dari Model GSTAR-GLS ($[12]_1$) Inflasi dengan Bobot Seragam

Lokasi	**Parameter**	**Estimasi**	**Standar Error**	**t-value**	**p-value**
Pontianak	ϕ_{10}^{12}	-0.44355	0.076501	-5.8	<.0001
	ϕ_{11}^{12}	0.038557	0.08073	0.48	0.6337
Sampit	ϕ_{20}^{12}	-0.43709	0.072409	-6.04	<.0001
	ϕ_{21}^{12}	-0.10247	0.120819	-0.85	0.3978
Palangkaraya	ϕ_{30}^{12}	-0.48469	0.070689	-6.86	<.0001
	ϕ_{31}^{12}	-0.15164	0.133996	-1.13	0.2597
Banjarmasin	ϕ_{40}^{12}	-0.43212	0.075938	-5.69	<.0001
	ϕ_{41}^{12}	-0.12792	0.12351	-1.04	0.3021
Balikpapan	ϕ_{50}^{12}	-0.51152	0.070902	-7.21	<.0001
	ϕ_{51}^{12}	-0.17452	0.107082	-1.63	0.1054
Samarinda	ϕ_{60}^{12}	-0.50202	0.07024	-7.15	<.0001
	ϕ_{61}^{12}	-0.03201	0.108056	-0.3	0.7675

Tabel di atas menunjukkan masih terdapat parameter yang tidak signifikan pada tingkat taraf uji $\alpha = 0.05$ sehingga perlu dilakukan seleksi parameter untuk menghasilkan model terbaik dan signifikan yang memenuhi taraf uji $\alpha = 0.05$. Estimasi parameter untuk model yang bersifat *restricted model* seperti pada tabel berikut :

Tabel 4.62. Estimasi Parameter *Restricted* Model dari Model GSTAR-GLS ([12]$_1$) Inflasi dengan Bobot Seragam

Lokasi	Parameter	Estimasi	Standar Error	t-value	p-value
Pontianak	ϕ_{10}^{12}	-0.40444	0.070512	-5.74	<.0001
Sampit	ϕ_{20}^{12}	-0.43311	0.062798	-6.9	<.0001
Palangkaraya	ϕ_{30}^{12}	-0.49471	0.054312	-9.11	<.0001
Banjarmasin	ϕ_{40}^{12}	-0.45555	0.058965	-7.73	<.0001
Balikpapam	ϕ_{50}^{12}	-0.55792	0.059726	-9.34	<.0001
Samarinda	ϕ_{60}^{12}	-0.48227	0.05827	-8.28	<.0001

Berdasarkan pada Tabel 4.62 menunjukkan bahwa parameter pada model GSTAR-GLS ([12]$_1$) dengan bobot seragam dapat digunakan pada tingkat taraf uji $\alpha = 0.05$. Bentuk persamaan matriks model GSTAR-GLS ([12]$_1$) dengan bobot lokasi seragam adalah sebagai berikut :

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \\ Y_4(t) \\ Y_5(t) \\ Y_6(t) \end{bmatrix} = \begin{bmatrix} -0.404 & 0 & 0 & 0 & 0 & 0 \\ 0 & -0.433 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.495 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.456 & 0 & 0 \\ 0 & 0 & 0 & 0 & -0.558 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0.482 \end{bmatrix} \begin{bmatrix} Y_1(t-12) \\ Y_2(t-12) \\ Y_3(t-12) \\ Y_4(t-12) \\ Y_5(t-12) \\ Y_6(t-12) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \\ e_4(t) \\ e_5(t) \\ e_6(t) \end{bmatrix}$$

Persamaan matriks di atas dapat diuraikan menjadi bentuk persamaan untuk tiap lokasi sebagai berikut :

- ✓ Model GSTAR-GLS ([12]$_1$) di Pontianak

  $Y_{1,t} = -0.404\, Y_{1,t-12} + e_{1,t}$

- ✓ Model GSTAR-GLS ([12]$_1$) di Sampit

  $Y_{2,t} = -0.433\, Y_{2,t-12} + e_{2,t}$

- ✓ Model GSTAR-GLS ([12]$_1$) di Palangkaraya

  $Y_{3,t} = -0.495\, Y_{3,t-12} + e_{3,t}$

- ✓ Model GSTAR-GLS ([12]$_1$) di Banjarmasin

  $Y_{4,t} = -0.456\, Y_{4,t-12} + e_{4,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Balikpapan

  $Y_{5,t} = -0.558\ Y_{5,t-12} + e_{5,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Samarinda

  $Y_{6,t} = -0.482\ Y_{6,t-12} + e_{6,t}$

Berdasarkan pemodelan GSTAR-GLS ($[12]_1$) data inflasi enam kota di Kalimantan dengan menggunakan bobot lokasi seragam memperlihatkan bahwa tidak ada keterkaitan inflasi antar lokasi di Kalimantan. Hal ini terlihat pada model yang tidak menunjukkan adanya parameter efek spasial. Inflasi di suatu lokasi hanya dipengaruhi oleh wilayah yang bersangkutan pada waktu yang berbeda yaitu dua belas bulan sebelumnya.

4.9.2.2. Pemodelan GSTAR ($[12]_1$) dengan Bobot Invers Jarak

Pada pemodelan GSTAR($[12]_1$) dengan bobot invers jarak dilakukan dengan menggunakan jarak tempuh transportasi darat antar lokasi ($\boldsymbol{D}$). Matriks jarak untuk enam lokasi di Kalimantan adalah sebagai berikut :

$$\boldsymbol{D} = \begin{bmatrix} 0 & 1.074 & 1.296 & 1.490 & 1..988 & 2144 \\ 1.074 & 0 & 222 & 416 & 914 & 1030 \\ 1.296 & 222 & 0 & 194 & 692 & 808 \\ 1.490 & 416 & 194 & 0 & 498 & 614 \\ 1.988 & 914 & 692 & 498 & 0 & 116 \\ 2.144 & 1.030 & 808 & 614 & 116 & 0 \end{bmatrix}$$

Pemodelan dengan menggunakan bobot invers jarak mengasumsikan bahwa data inflasi suatu wilayah dipengaruhi oleh jarak antara lokasi tersebut dengan lokasi lainnya. Jarak antara dua lokasi yang berjauhan cenderung memiliki bobot yang lebih kecil dibandingkan dengan jarak antara dua lokasi yang lebih berdekatan. Matriks bobot invers jarak ($\boldsymbol{W}$) untuk enam lokasi di wilayah Kalimantan adalah sebagai berikut :

$$\boldsymbol{W} = \begin{bmatrix} 0 & 0.28 & 0.23 & 0.20 & 0.15 & 0.14 \\ 0.09 & 0 & 0.45 & 0.24 & 0.11 & 0.10 \\ 0.06 & 0.34 & 0 & 0.39 & 0.11 & 0.09 \\ 0.06 & 0.20 & 0.43 & 0 & 0.17 & 0.14 \\ 0.04 & 0.08 & 0.11 & 0.15 & 0 & 0.63 \\ 0.04 & 0.08 & 0.10 & 0.13 & 0.67 & 0 \end{bmatrix}$$

Hasil estimasi parameter untuk model GSTAR-GLS($[12]_1$) yang *full model* dapat dilihat pada Tabel 4.63 di bawah ini.

Tabel 4.63. Estimasi Parameter *Full Model* dari Model GSTAR-GLS ($[12]_1$) Inflasi dengan Bobot Invers Jarak

Lokasi	**Parameter**	**Estimasi**	**Standar Error**	**t-value**	**p-value**
Pontianak	ϕ_{10}^{12}	-0.43941	0.075388	-5.83	<.0001
	ϕ_{11}^{12}	0.057448	0.075561	0.76	0.4483
Sampit	ϕ_{20}^{12}	-0.41318	0.072957	-5.66	<.0001
	ϕ_{21}^{12}	-0.13214	0.102811	-1.29	0.2008
Palangkaraya	ϕ_{30}^{12}	-0.49107	0.073444	-6.69	<.0001
	ϕ_{31}^{12}	-0.10621	0.110791	-0.96	0.3394
Banjarmasin	ϕ_{40}^{12}	-0.41977	0.078595	-5.34	<.0001
	ϕ_{41}^{12}	-0.12166	0.105375	-1.15	0.2502
Balikpapan	ϕ_{50}^{12}	-0.50655	0.0725	-6.99	<.0001
	ϕ_{51}^{12}	-0.14257	0.087936	-1.62	0.1072
Samarinda	ϕ_{60}^{12}	-0.52819	0.070551	-7.49	<.0001
	ϕ_{61}^{12}	0.028843	0.088006	0.33	0.7436

Tabel di atas menunjukkan masih terdapat parameter yang tidak signifikan pada tingkat taraf uji $\alpha = 0.05$ sehingga perlu dilakukan seleksi parameter untuk menghasilkan model terbaik dan signifikan yang memenuhi taraf uji $\alpha = 0.05$. Estimasi parameter untuk model yang bersifat *restricted model* seperti pada tabel di bawah ini.

Tabel 4.64. Estimasi Parameter *Restricted* Model dari Model GSTAR-GLS ($[12]_1$) Inflasi dengan Bobot Invers Jarak

Lokasi	**Parameter**	**Estimasi**	**Standar Error**	**t-value**	**p-value**
Pontianak	ϕ_{10}^{12}	-0.40444	0.070512	-5.74	<.0001
Sampit	ϕ_{20}^{12}	-0.43311	0.062798	-6.9	<.0001
Palangkaraya	ϕ_{30}^{12}	-0.49471	0.054312	-9.11	<.0001
Banjarmasin	ϕ_{40}^{12}	-0.45555	0.058965	-7.73	<.0001
Balikpapam	ϕ_{50}^{12}	-0.55792	0.059726	-9.34	<.0001
Samarinda	ϕ_{60}^{12}	-0.48227	0.05827	-8.28	<.0001

Berdasarkan pada Tabel 4.64 menunjukkan bahwa parameter pada model GSTAR-GLS ($[12]_1$) dengan bobot invers jarak dapat digunakan pada tingkat taraf uji $\alpha = 0.05$. Bentuk persamaan matriks model GSTAR-GLS ($[12]_1$) dengan bobot lokasi invers jarak adalah sebagai berikut :

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \\ Y_4(t) \\ Y_5(t) \\ Y_6(t) \end{bmatrix} = \begin{bmatrix} -0.404 & 0 & 0 & 0 & 0 & 0 \\ 0 & -0.433 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.495 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.456 & 0 & 0 \\ 0 & 0 & 0 & 0 & -0.558 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0.482 \end{bmatrix} \begin{bmatrix} Y_1(t-12) \\ Y_2(t-12) \\ Y_3(t-12) \\ Y_4(t-12) \\ Y_5(t-12) \\ Y_6(t-12) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \\ e_4(t) \\ e_5(t) \\ e_6(t) \end{bmatrix}$$

Persamaan matriks di atas dapat diuraikan menjadi bentuk persamaan untuk tiap lokasi sebagai berikut :

✓ Model GSTAR-GLS ($[12]_1$) di Pontianak

$Y_{1,t} = -0.404\ Y_{1,t-12} + e_{1,t}$

✓ Model GSTAR-GLS ($[12]_1$) di Sampit

$Y_{2,t} = -0.433\ Y_{2,t-12} + e_{2,t}$

✓ Model GSTAR-GLS ($[12]_1$) di Palangkaraya

$Y_{3,t} = -0.495\ Y_{3,t-12} + e_{3,t}$

✓ Model GSTAR-GLS ($[12]_1$) di Banjarmasin

$Y_{4,t} = -0.456\ Y_{4,t-12} + e_{4,t}$

✓ Model GSTAR-GLS ($[12]_1$) di Balikpapan

$Y_{5,t} = -0.558\ Y_{5,t-12} + e_{5,t}$

✓ Model GSTAR-GLS ($[12]_1$) di Samarinda

$Y_{6,t} = -0.482\ Y_{6,t-12} + e_{6,t}$

Berdasarkan pemodelan GSTAR-GLS ($[12]_1$) data inflasi enam kota di Kalimantan dengan menggunakan bobot lokasi invers jarak tidak berbeda dengan bobot seragam yang menunjukkan tidak ada keterkaitan inflasi antar lokasi di

Kalimantan. Hal ini terlihat pada model yang tidak menunjukkan adanya parameter efek spasial. Inflasi di suatu lokasi hanya dipengaruhi oleh wilayah yang bersangkutan pada waktu yang berbeda yaitu dua belas bulan sebelumnya.

4.9.2.3. Pemodelan GSTAR ($[12]_1$) dengan Bobot Normalisasi Korelasi Silang

Pemodelan GSTAR-GLS ($[12]_1$) dengan menggunakan bobot normalisasi korelasi silang mempunyai asumsi bahwa keterikaitan inflasi antara lokasi dipengaruhi oleh tinggi rendahnya korelasi antara inflasi di lokasi satu dengan inflasi di lokasi lainnya. Perhitungan bobot normalisasi korelasi silang diperoleh melalui normalisasi dari nilai-nilai korelasi antara lokasi pada lag yang bersesuaian. Dalam GSTAR-GLS ($[12]_1$) maka korelasi silang yang digunakan adalah korelasi silang pada lag 12. Korelasi silang pada lag 12 yang terbentuk adalah sebagai beirkut :

The VARMAX Procedure

Cross-Correlation Matrices of Endogenous (Dependent) Series

Lag	Variable	u1	u2	u3	u4	u5	u6
12	u1	-0.34991	-0.10729	-0.17633	-0.17248	-0.15528	-0.15395
	u2	-0.04328	-0.45439	-0.29216	-0.25795	-0.25061	-0.23464
	u3	-0.07054	-0.30678	-0.51410	-0.36769	-0.33923	-0.23750
	u4	-0.11813	-0.31195	-0.38719	-0.48579	-0.33240	-0.23030
	u5	-0.10870	-0.00927	-0.26196	-0.16880	-0.44919	-0.15343
	u6	-0.13648	-0.14616	-0.14327	-0.16688	-0.25700	-0.44350

Gambar 4.27. Nilai Korelasi Silang Pada Lag 12

Berdasarkan nilai korelasi silang pada 12, maka matriks bobot normalisasi korelasi silang yang digunakan pada lag 12 ($\boldsymbol{W}^{\mathbf{12}}$) dapat ditulis :

$$\boldsymbol{W}^{\mathbf{12}} = \begin{bmatrix} 0 & -0.14 & -0.23 & -0.23 & -0.20 & -0.20 \\ -0.04 & 0 & -0.27 & -0.24 & -0.23 & -0.22 \\ -0.05 & -0.23 & 0 & -0.28 & -0.26 & -0.18 \\ -0.08 & -0.23 & -0.28 & 0 & -0.24 & -0.17 \\ -0.016 & -0.01 & -0.37 & -0.24 & 0 & -0.22 \\ -0.16 & -0.17 & -0.17 & -0.20 & -0.30 & 0 \end{bmatrix}$$

Hasil estimasi parameter untuk model GSTAR-GLS($[12]_1$) yang *full model* dapat dilihat pada Tabel 4.65 di bawah ini.

Tabel 4.65. Estimasi Parameter *Full Model* dari Model GSTAR-GLS ($[12]_1$) Inflasi dengan Bobot Normalisasi Korelasi Silang

Lokasi	Parameter	Estimasi	Standar Error	t-value	p-value
Pontianak	ϕ_{10}^{12}	-0.43995	0.076706	-5.74	<.0001
	ϕ_{11}^{12}	-0.04739	0.080626	-0.59	0.5576
Sampit	ϕ_{20}^{12}	-0.43211	0.073315	-5.89	<.0001
	ϕ_{21}^{12}	0.082149	0.111603	0.74	0.4629
Palangkaraya	ϕ_{30}^{12}	-0.48655	0.074275	-6.55	<.0001
	ϕ_{31}^{12}	0.11814	0.121517	0.97	0.3326
Banjarmasin	ϕ_{40}^{12}	-0.42775	0.07666	-5.58	<.0001
	ϕ_{41}^{12}	0.11253	0.112938	1	0.3208
Balikpapan	ϕ_{50}^{12}	-0.51275	0.07386	-6.94	<.0001
	ϕ_{51}^{12}	0.132659	0.099552	1.33	0.1848
Samarinda	ϕ_{60}^{12}	-0.50153	0.07024	-7.14	<.0001
	ϕ_{61}^{12}	0.00921	0.107538	0.09	0.9319

Tabel di atas menunjukkan masih terdapat parameter yang tidak signifikan pada tingkat taraf uji $\alpha = 0.05$ sehingga perlu dilakukan seleksi parameter untuk menghasilkan model terbaik dan signifikan yang memenuhi taraf uji $\alpha = 0.05$. Estimasi parameter untuk model yang bersifat *restricted model* seperti pada Tabel 4.66 di bawah ini.

Tabel 4.66. Estimasi Parameter *Restricted* Model dari Model GSTAR-GLS ($[12]_1$) Inflasi dengan Bobot Normalisasi Korelasi Silang

Lokasi	Parameter	Estimasi	Standar Error	t-value	p-value
Pontianak	ϕ_{10}^{12}	-0.40444	0.070512	-5.74	<.0001
Sampit	ϕ_{20}^{12}	-0.43311	0.062798	-6.9	<.0001
Palangkaraya	ϕ_{30}^{12}	-0.49471	0.054312	-9.11	<.0001
Banjarmasin	ϕ_{40}^{12}	-0.45555	0.058965	-7.73	<.0001
Balikpapam	ϕ_{50}^{12}	-0.55792	0.059726	-9.34	<.0001
Samarinda	ϕ_{60}^{12}	-0.48227	0.05827	-8.28	<.0001

Berdasarkan pada Tabel 4.66 menunjukkan bahwa parameter pada model GSTAR-GLS ($[12]_1$) dengan bobot normalisasi korelasi silang tidak berbeda dengan kedua bobot sebelumnya. Hal ini karena pada taraf uji $\alpha = 0.05$ tidak terdapat parameter spasial yang signifikan. Bentuk persamaan matriks model GSTAR-GLS ($[12]_1$) dengan bobot lokasi normalisasi korelasi silang sama tidak berbeda dengan kedua bobot sebelumnya yaitu sebagai berikut :

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \\ Y_4(t) \\ Y_5(t) \\ Y_6(t) \end{bmatrix} = \begin{bmatrix} -0.404 & 0 & 0 & 0 & 0 & 0 \\ 0 & -0.433 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.495 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.456 & 0 & 0 \\ 0 & 0 & 0 & 0 & -0.558 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0.482 \end{bmatrix} \begin{bmatrix} Y_1(t-12) \\ Y_2(t-12) \\ Y_3(t-12) \\ Y_4(t-12) \\ Y_5(t-12) \\ Y_6(t-12) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \\ e_4(t) \\ e_5(t) \\ e_6(t) \end{bmatrix}$$

Persamaan matriks di atas dapat diuraikan menjadi bentuk persamaan untuk tiap lokasi sebagai berikut :

- ✓ Model GSTAR-GLS ($[12]_1$) di Pontianak

  $Y_{1,t} = -0.404\, Y_{1,t-12} + e_{1,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Sampit

  $Y_{2,t} = -0.433\, Y_{2,t-12} + e_{2,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Palangkaraya

  $Y_{3,t} = -0.495\, Y_{3,t-12} + e_{3,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Banjarmasin

  $Y_{4,t} = -0.456\, Y_{4,t-12} + e_{4,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Balikpapan

  $Y_{5,t} = -0.558\, Y_{5,t-12} + e_{5,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Samarinda

  $Y_{6,t} = -0.482\, Y_{6,t-12} + e_{6,t}$

Model GSTAR-GLS ($[12]_1$) data inflasi enam kota di Kalimantan dengan menggunakan bobot lokasi normalisasi korelasi silang menunjukkan tidak ada keterkaitan inflasi antar lokasi di Kalimantan. Inflasi di suatu lokasi hanya dipengaruhi oleh wilayah yang bersangkutan pada waktu yang berbeda yaitu dua belas bulan sebelumnya.

4.9.2.4. Pemodelan GSTAR ($[12]_1$) dengan Bobot Normalisasi Inferensia Parsial Korelasi Silang

Perhitungan bobot normalisasi inferensia parsial korelasi silang diperoleh melalui normalisasi dari nilai-nilai korelasi silang berdasarkan skema plot MCCF pada lag yang bersesuain. Pada model GSTAR-GLS ($[12]_1$) maka skema plot MCCF yang dilihat adalah pada 12, dimana yang bertanda titik diberi nilai nol, sedangkan untuk skema plot yang bertanda + atau – maka nilai yang digunakanadalah nilai korelasi silang yang bersesuaian. Langkah berikutnya melakukan normalisasi setelah mendapatkan korelasi dengan inferensia parsial korelasi silang. Skema plot MCCF pada 12 serta matriks bobot normalisasi inferensia parsial korelasi silang yang digunakan untuk mengestimasi parameter GSTAR-GLS ($[12]_1$) dapat ditunjukkan pada Gambar 4.28 di bawah ini.

```
      Schematic Representation of Cross Correlations

Variable/
Lag          10       11       12       13       14

u1         ..-.-.   ......   -.--..   ......   ......
u2         ......   ......   .-----   ....--   ..+...
u3         ......   ..-..-   .-----   -----.   ......
u4         ......   ......   .-----   -.....   ......
u5         ......   ......   ..---.   --....   ......
u6         ..---.   ..-...   ...---   ......   ......

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

Gambar 4.28. Skema Tanda Plot MCCF Pada Lag 12

Berdasarkan skema tanda plot MCCF pada lag 12 maka matriks bobot normalisasi inferensia parsial korelasi silang yang digunakan lag 12 ($\boldsymbol{W}^{12}$) dapat ditulis :

$$\boldsymbol{W}^{12} = \begin{bmatrix} 0 & 0 & -0.51 & -0.49 & 0 & 0 \\ 0 & 0 & -0.28 & -0.25 & -0.24 & -0.23 \\ 0 & -0.25 & 0 & -0.29 & -0.27 & -0.19 \\ 0 & -0.25 & -0.31 & 0 & -0.26 & -0.18 \\ 0 & 0 & -0.36 & -0.39 & 0 & 0 \\ 0 & 0 & 0 & -0.39 & -0.61 & 0 \end{bmatrix}$$

Hasil estimasi parameter untuk model GSTAR-GLS($[12]_1$) yang *full model* dapat dilihat pada Tabel 4.67 di bawah ini.

Tabel 4.67. Estimasi Parameter *Full Model* dari Model GSTAR-GLS ($[12]_1$) Inflasi dengan Bobot Normalisasi Inferensia Parsial Korelasi Silang

Lokasi	**Parameter**	**Estimasi**	**Standar Error**	**t-value**	**p-value**
Pontianak	ϕ_{10}^{12}	-0.44743	0.075365	-5.94	<.0001
	ϕ_{11}^{12}	-0.0822	0.061964	-1.33	0.1868
Sampit	ϕ_{20}^{12}	-0.43137	0.073423	-5.88	<.0001
	ϕ_{21}^{12}	0.054128	0.108819	0.5	0.6197
Palangkaraya	ϕ_{30}^{12}	-0.47913	0.075578	-6.34	<.0001
	ϕ_{31}^{12}	0.080263	0.11478	0.7	0.4855
Banjarmasin	ϕ_{40}^{12}	-0.41493	0.076323	-5.44	<.0001
	ϕ_{41}^{12}	0.088903	0.103858	0.86	0.3934
Balikpapan	ϕ_{50}^{12}	-0.51809	0.072753	-7.12	<.0001
	ϕ_{51}^{12}	0.06685	0.074531	0.9	0.3713
Samarinda	ϕ_{60}^{12}	-0.50769	0.067338	-7.54	<.0001
	ϕ_{61}^{12}	-0.0443	0.087916	-0.5	0.6151

Pada tingkat taraf uji $\alpha = 0.05$ menunjukkan masih terdapat parameter yang tidak signifikan, sehingga perlu dilakukan seleksi parameter untuk menghasilkan model terbaik. Estimasi parameter untuk model yang bersifat *restricted model* seperti pada tabel berikut :

Tabel 4.68. Estimasi Parameter *Restricted* Model dari Model GSTAR-GLS ($[12]_1$) Inflasi dengan Bobot Normalisasi Inferensia Parsial Korelasi Silang

Lokasi	**Parameter**	**Estimasi**	**Standar Error**	**t-value**	**p-value**
Pontianak	ϕ_{10}^{12}	-0.40444	0.070512	-5.74	<.0001
Sampit	ϕ_{20}^{12}	-0.43311	0.062798	-6.9	<.0001
Palangkaraya	ϕ_{30}^{12}	-0.49471	0.054312	-9.11	<.0001
Banjarmasin	ϕ_{40}^{12}	-0.45555	0.058965	-7.73	<.0001
Balikpapam	ϕ_{50}^{12}	-0.55792	0.059726	-9.34	<.0001
Samarinda	ϕ_{60}^{12}	-0.48227	0.05827	-8.28	<.0001

Berdasarkan pada Tabel 4.68 menunjukkan bahwa parameter pada model GSTAR-GLS ($[12]_1$) dengan bobot normalisasi inferensia parsial korelasi silang tidak berbeda dengan penggunaan ketiga bobot sebelumnya. Hal ini karena pada taraf uji $\alpha = 0.05$ tidak terdapat parameter spasial yang signifikan. Bentuk persamaan matriks model GSTAR-GLS ($[12]_1$) dengan bobot lokasi normalisasi inferensia parsial korelasi silang sama tidak berbeda dengan kedua bobot sebelumnya yaitu sebagai berikut :

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \\ Y_3(t) \\ Y_4(t) \\ Y_5(t) \\ Y_6(t) \end{bmatrix} = \begin{bmatrix} -0.404 & 0 & 0 & 0 & 0 & 0 \\ 0 & -0.433 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.495 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.456 & 0 & 0 \\ 0 & 0 & 0 & 0 & -0.558 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0.482 \end{bmatrix} \begin{bmatrix} Y_1(t-12) \\ Y_2(t-12) \\ Y_3(t-12) \\ Y_4(t-12) \\ Y_5(t-12) \\ Y_6(t-12) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \\ e_4(t) \\ e_5(t) \\ e_6(t) \end{bmatrix}$$

Persamaan matriks di atas dapat diuraikan menjadi bentuk persamaan untuk tiap lokasi sebagai berikut :

- ✓ Model GSTAR-GLS ($[12]_1$) di Pontianak

  $Y_{1,t} = -0.404\, Y_{1,t-12} + e_{1,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Sampit

  $Y_{2,t} = -0.433\, Y_{2,t-12} + e_{2,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Palangkaraya

  $Y_{3,t} = -0.495\, Y_{3,t-12} + e_{3,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Banjarmasin

  $Y_{4,t} = -0.456\, Y_{4,t-12} + e_{4,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Balikpapan

  $Y_{5,t} = -0.558\, Y_{5,t-12} + e_{5,t}$

- ✓ Model GSTAR-GLS ($[12]_1$) di Samarinda

  $Y_{6,t} = -0.482\, Y_{6,t-12} + e_{6,t}$

Berdasarkan pemodelan GSTAR-GLS ($[12]_1$) data inflasi enam kota di Kalimantan dengan menggunakan empat bobot lokasi yaitu bobot seragam, invers jarak, normalisasi korelasi silang dan normalisasi inferensia parsial korelasi silang menunjukkan bahwa pada *full* model, masih terdapat parameter yang tidak signifikan (pada $\alpha = 0.05$). Adapun dalam bentuk *restricted* model memperlihatkan seluruh parameter yang memiliki keterkaitan efek spasial tidak signifikan. Dengan demikian, model GSTAR untuk semua bobot lokasi adalah sama yaitu model yang hanya menjelaskan keterkaitan antara waktu pada lokasi yang bersangkutan. Hal ini berarti dengan model GSTAR-GLS ($[12]_1$) menyatakan bahwa inflasi di suatu lokasi hanya dipengaruhi oleh wilayah yang bersangkutan pada waktu yang berbeda yaitu dua belas bulan sebelumnya.

4.9.3. *Diagnostic Checking* Model GSTAR

Tahapan *diagnostic checking* dilakukan untuk menguji asumsi apakah residual sudah *white noise* atau tidak, sehingga model GSTAR bisa dianggap sebagai model yang layak. Pengujian ini dilakukan dengan cara memodelkan kembali *residual* dari model GSTAR dan melakukan pengecekan letak nilai AIC terkecil. Hasil penghitungan nilai AIC residual pada pemodelan GSTAR ($[1,12]_1$) dapat dilihat pada pada Tabel 4.69 di bawah ini.

Tabel 4.69. Nilai AIC Residual Model GSTARX Berdasarkan Jenis Bobot Lokasi

Jenis Bobot	Lag	MA (0)	MA (1)	MA (2)
Seragam	AR (0)	**-10.899**	-10.5945	-10.2594
	AR (1)	-10.8186	-10.3699	-10.1003
Invers Jarak	AR (0)	**-10.899**	-10.5945	-10.2594
	AR (1)	-10.8186	-10.3699	-10.1003
Normalisasi Korelasi Silang	AR (0)	**-10.899**	-10.5945	-10.2594
	AR (1)	-10.8186	-10.3699	-10.1003
Normalisasi Inferensi Parsial Korelasi Silang	AR (0)	**-10.899**	-10.5945	-10.2594
	AR (1)	-10.8186	-10.3699	-10.1003

Hasil penghitungan memperlihatkan bahwa nilai AIC terkecil dari model GSTAR pada keempat bobot terletak pada lag AR(0) dan MA(0). Hal ini menunjukkan bahwa asumsi residual dari model GSTAR sudah memenuhi asumsi yang *white noise* sehingga model yang terbentuk layak digunakan untuk peramalan.

4.10. Pemodelan Tahap Pertama ARIMAX Secara Simultan

Untuk pemodelan ARIMAX secara simultan pada tahapan ini dilakukan tanpa melakukan pemodelan ARIMA pada residualnya. Sehingga akan didapatkan suatu deret residual yang belum *white noise*. Hal ini akan dilakukan pada tahapan kedua dimana residual dari model simultan dijadikan sebagai respons untuk membentuk model GSTAR. Hasil persamaan simultan untuk inflasi pada enam wilayah di Kalimantan yang melibatkan variabel eksogen berupa variasi kalender dan fungsi transfer adalah sebagai berikut :

a. Pontianak

$\dot{y}_{1,t} = 0.022x_{1,t-5} + 0.0343\ D_{,t-1} + 0.226\ D_{,t} + 1.266\ P_t + u_{1,t}$

b. Sampit

$\dot{y}_{2,t} = 0.0094\ x_{2,t-14} + 1.295\ P_t + u_{2,t}$

c. Palangkaraya

$\dot{y}_{3,t} = 0.033\ D_t + 1.284\ P_t - 2.037\ I_t^{T=153} - 1.624\ I_t^{T=68} - 1.209\ I_t^{T=30} + u_{3,t}$

d. Banjarmasin

$\dot{y}_{4,t} = -0.057\ D_{t-1} + 1.364\ P_t + u_{4,t}$

e. Balikpapan

$\dot{y}_{5,t} = 1.312\ P_t - 2.116\ I_t^{T=153} + u_{5,t}$

f. Samarinda

$\dot{y}_{6,t} = 0.213\ D_t + 1.642\ P_t - 1.895\ I_t^{T=95} + u_{6,t}$

4.11. Pemodelan Tahap Kedua dengan Model GSTAR

Tahapan dalam pemodelan GSTAR secara umum mengikuti prosedur Box-Jenkins yang meliputi uji stasioneritas, penentuan orde waktu dan spasial, estimasi parameter dengan berbagai bobot, diagnosa cek dan pengujian residual yang *white noise* serta tahap peramalan.

4.11.1. Identifikasi Model GSTAR

Hasil residual pada tahap pertama digunakan untuk membentuk suatu model GSTAR langkah awal dalam pemodelan GSTAR adalah melakukan identifikasi terhadap residual $(u_{i,t})$ untuk mengetahui kestasioneran dan penentuan orde. Untuk mengetahui data residual sudah stasioner bisa menggunakan *time series* plot dan plot MCCF.

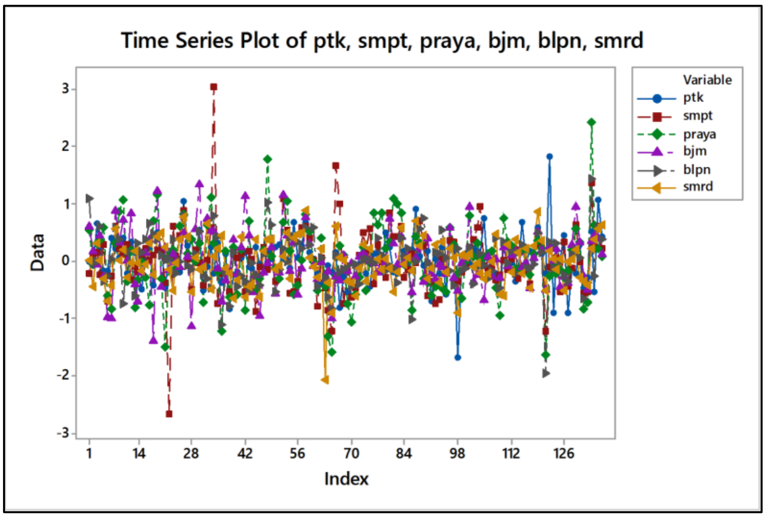

Gambar 4.29. Plot *Time Series* dari Deret Residual

Gambar 4.29 memperlihatkan bahwa residual sudah stasioner karena bergerak dengan pola yang tetap di sekitar rata-rata. Pada gambar tersebut juga terlihat adanya *outlier* yang terdeteksi, dimana salah satunya merupakan adanya intrvensi kenaikan harga BBM.

```
                Schematic Representation of Cross Correlations

Variable/
Lag           0      1      2      3      4      5      6      7      8      9

u1        +.++++ -+.... ...... ...... ...... ...... ...... ...... ...... ......
u2        .+++++ ..+..+ ...... ...... ...... ...... ...... ...... ...-.. ..+...
u3        ++++++ .++... .--... .-.... ...... ..+... ...... ...... ...... ......
u4        ++++++ ...... ...... ....-. .+.... ...... ...... ...... ...... ......
u5        ++++++ ...... ...... +..... .++... ...... ...... ...... ...... ....-.
u6        ++++++ ..+... ...... +..... ...... ...... ...... ...... ...... ......
```

Gambar 4.30. Skema MCCF dari Residual

Berdasarkan pada skema MCCF terlihat bahwa data sudah stasioner yang ditunjukkan adanya banyak tanda titik (.) yang muncul pada plot MCCF. Pada plot MCCF juga memperlihatkan adanya korelasi antar wilayah yang diperlihatkan adanya tanda (+) pada lag 0 untuk semua wilayah meskipun dengan tingkat korelasi yang kecil.

Tabel 4.70. Korelasi Residual ($u_{i,t}$) Inflasi antar Lokasi di Kalimantan.

Lokasi	ponti-anak	sampit	palangka-raya	banjar-masin	balik-papan	sama-rinda
pontianak	0	0.121	0.224	0.32	0.243	0.394
sampit	0.121	0	0.443	0.416	0.27	0.344
palangkaraya	0.224	0.443	0	0.655	0.375	0.423
banjarmasin	0.32	0.416	0.655	0	0.383	0.389
balikapapn	0.243	0.27	0.375	0.383	0	0.43
samarinda	0.394	0.344	0.423	0.389	0.43	0

Penentuan orde waktu (AR) untuk model GSTAR diidentifikasi dengan melihat skema plot MPCCF. Berbagai kemungkinan orde yang terbentuk dari hasil identifikasi pada skema MPCCF, maka untuk memilih orde GSTAR yang akan digunakan ditentukan berdasarkan nilai AICC yang terkecil.

Berdasarkan pada skema MPCCF maka terlihat bahwa pada lag ke,1,3,6 dan 12 memiliki tanda positif (+) dan negatif (-) yang lebih banyak dibandingkan lainnya atau dengan kata lain bersifat signifikan. Sehingga orde AR untuk GSTAR terdapat berbagai kemungkinan berdasarkan pada lag-lag tersebut seperti ditampilkan pada Tabel 4.71.

```
                Schematic Representation of Partial Cross Correlations

Variable/
Lag           1      2      3      4      5      6      7      8      9     10

u1         -+.... ...... .....+ ...... ...... ...... ...... ...... ...... ......
u2         ...... ...... ...... ...... .....- ..-+.+ ...... ...-.. ..+... ......
u3         .+.... .--... ...... ...... +..... .+..-. ...... ...... ...... ......
u4         ...... ...... ....-. .+.... ...-.. ...... ...... .+-... .+.... ......
u5         ...... ...... ...... ..+... ...... ...... ...... ...... ....-. ......
u6         ..+... ...... +..... ...... ...... ...... ...... ...... .-.... .-.-..

              Variable/
              Lag            11        12        13        14

              u1          ....+.    .....+    ......    ......
              u2          .....+    .-....    ......    ......
              u3          ......    ......    -.....    ......
              u4          ...+..    ...-..    ......    ...-..
              u5          ......    ......    ......    ......
              u6          ......    .....-    ......    ......

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

Gambar 4.31 Skema MPCCF $u_{i,t}$ Inflasi Enam Wilayah di Kalimantan.

Tabel 4.71. Identifikasi Orde AR Untuk GSTAR dan Nilai AIC

Orde AR untuk GSTAR	Nilai AIC	Orde AR untuk GSTAR	Nilai AIC
[1,3]	-10.4033	[6,12]	-11.4844
[1,6]	-10.4631	[1,3,6]	-10.2863
[1,12]	**-11.5198**	[1,3,12]	-11.2269
[3,6]	-1.4392	[1,6,12]	-11.3707
[3,12]	-11.4183	[3,6,12]	-11.1823

Hasil identifikasi orde waktu (AR) untuk model GSTAR berdasarkan pada Tabel 4.71 menunjukkan bahwa orde AR yang bisa digunakan adalah orde *p*=[1,12] karena memiliki nilai AIC yang terkecil (-11.5198) dibandingkan dengan kemungkinana orde AR yang lain. Adapun untuk orde spasial yang digunakan dalam penelitian ini dibatasi pada orde 1. Dengan demikian, model GSTAR yang digunakan dalam penelitian ini adalah model GSTAR ($[1,12]_1$). Model GSTAR ($[1,12]_1$) dapat ditulis sebagai berikut :

$$\boldsymbol{u}_i(t) = \boldsymbol{\Phi}_{10}\boldsymbol{u}(t-1) + \boldsymbol{\Phi}_{11}\boldsymbol{W}^{(1)}\boldsymbol{u}(t-1) + \boldsymbol{\Phi}_{120}\boldsymbol{u}(t-12) + \boldsymbol{\Phi}_{121}\boldsymbol{W}^{(1)}\boldsymbol{u}(t-12) + \boldsymbol{e}(t)$$

Model tersebut jika ditulis dalam bentuk matriks adalah sebagai berikut :

$$\begin{bmatrix} u_1(t) \\ u_2(t) \\ u_3(t) \\ u_4(t) \\ u_5(t) \\ u_6(t) \end{bmatrix} = \begin{bmatrix} \phi_{10}^{1} & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{1} & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{1} & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{1} & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{1} & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{60}^{1} \end{bmatrix} \begin{bmatrix} u_1(t-1) \\ u_2(t-1) \\ u_3(t-1) \\ u_4(t-1) \\ u_5(t-1) \\ u_6(t-1) \end{bmatrix} + \begin{bmatrix} \phi_{10}^{12} & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{20}^{12} & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{30}^{12} & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{40}^{12} & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{50}^{12} & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{60}^{12} \end{bmatrix} \begin{bmatrix} u_1(t-12) \\ u_2(t-12) \\ u_3(t-12) \\ u_4(t-12) \\ u_5(t-12) \\ u_6(t-12) \end{bmatrix} +$$

$$\begin{bmatrix} \phi_{11}^{1} & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{1} & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{1} & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{1} & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{1} & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{61}^{1} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} & w_{14} & w_{15} & w_{16} \\ w_{21} & 0 & w_{23} & w_{24} & w_{25} & w_{26} \\ w_{31} & w_{32} & 0 & w_{34} & w_{35} & w_{36} \\ w_{41} & w_{42} & w_{43} & 0 & w_{45} & w_{46} \\ w_{51} & w_{52} & w_{53} & w_{54} & 0 & w_{56} \\ w_{61} & w_{62} & w_{63} & w_{64} & w65 & 0 \end{bmatrix} \begin{bmatrix} u_1(t-1) \\ u_2(t-1) \\ u_3(t-1) \\ u_4(t-1) \\ u_5(t-1) \\ u_6(t-1) \end{bmatrix} +$$

$$\begin{bmatrix} \phi_{11}^{12} & 0 & 0 & 0 & 0 & 0 \\ 0 & \phi_{21}^{12} & 0 & 0 & 0 & 0 \\ 0 & 0 & \phi_{31}^{12} & 0 & 0 & 0 \\ 0 & 0 & 0 & \phi_{41}^{12} & 0 & 0 \\ 0 & 0 & 0 & 0 & \phi_{51}^{12} & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_{61}^{12} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} & w_{14} & w_{15} & w_{16} \\ w_{21} & 0 & w_{23} & w_{24} & w_{25} & w_{26} \\ w_{31} & w_{32} & 0 & w_{34} & w_{35} & w_{36} \\ w_{41} & w_{42} & w_{43} & 0 & w_{45} & w_{46} \\ w_{51} & w_{52} & w_{53} & w_{54} & 0 & w_{56} \\ w_{61} & w_{62} & w_{63} & w_{64} & w65 & 0 \end{bmatrix} \begin{bmatrix} u_1(t-12) \\ u_2(t-12) \\ u_3(t-12) \\ u_4(t-12) \\ u_5(t-12) \\ u_6(t-12) \end{bmatrix}.$$

4.11.2. Estimasi Parameter

Pada pemodelan tahap pembentukan model GSTAR pada residual $(u_{i,t})$, metode estimasi parameter yang digunakan adalah menggunakan metode GLS. Hal ini akan lebih akurat dibandingkan dengan metode OLS, karena data antara residual $(u_{i,t})$ memiliki korelasi meskipun kecil. Sehingga dalam pemodelan GSTAR ($[1,12]_1$) pada residual data inflasi pada enam kota di Kalimantan selanjutnya dinamakan sebagai pemodelan GSTAR-GLS ($[1,12]_1$). Bobot lokasi yang digunakan adalah menggunakan bobot lokasi invers jarak, normalisasi korelasi silang dan normalisasi inferensia parsial korelasi silang.

4.11.2.1. Pemodelan GSTAR ($[1,12]_1$) dengan Bobot Seragam

Bobot lokasi seragam menghasilkan suatu koefisien dalam model yang menyatakan bahwa hubungan antara data residual inflasi pada setiap wilayah pada lag waktu ke-1 dengan lokasi yang berbeda pada waktu yang sama. Bobot seragam untuk enam wilayah dalam bentuk matriks adalah sebagai berikut :

$$\boldsymbol{W} = \begin{bmatrix} 0 & 0.20 & 0.20 & 0.20 & 0.20 & 0.20 \\ 0.20 & 0 & 0.20 & 0.20 & 0.20 & 0.20 \\ 0.20 & 0.20 & 0 & 0.20 & 0.20 & 0.20 \\ 0.20 & 0.20 & 0.20 & 0 & 0.20 & 0.20 \\ 0.20 & 0.20 & 020 & 0.20 & 0 & 0.20 \\ 0.20 & 0.20 & 0.20 & 0.20 & 0.20 & 0 \end{bmatrix}$$

Hasil estimasi parameter untuk model GSTAR-GLS([1,12]$_1$) yang *full model* dapat dilihat pada Tabel 4.72.

Tabel 4.72. Estimasi Parameter *Full Model* dari Model GSTAR-GLS ([1,12]$_1$) dengan Bobot Seragam Pada $u_{i,t}$ Inflasi

Lokasi	Parameter	DF	Estimasi	Standar Error	t-value	p-value
Pontianak	ϕ_{10}^{1}	1	-0.19496	0.077943	-2.5	0.0137
	ϕ_{11}^{1}	1	0.137494	0.089915	1.53	0.1287
	ϕ_{10}^{12}	1	-0.40618	0.081901	-4.96	<.0001
	ϕ_{11}^{12}	1	0.01527	0.093161	0.16	0.8701
Sampit	ϕ_{20}^{1}	1	-0.08172	0.077877	-1.05	0.296
	ϕ_{21}^{1}	1	0.319423	0.144176	2.22	0.0285
	ϕ_{20}^{12}	1	-0.51288	0.077295	-6.64	<.0001
	ϕ_{21}^{12}	1	-0.05943	0.14597	-0.41	0.6846
Palangkaraya	ϕ_{30}^{1}	1	0.054582	0.069665	0.78	0.4348
	ϕ_{31}^{1}	1	0.224281	0.125502	1.79	0.0763
	ϕ_{30}^{12}	1	-0.50262	0.067896	-7.4	<.0001
	ϕ_{31}^{12}	1	-0.28314	0.129552	-2.19	0.0307
Banjarmasin	ϕ_{40}^{1}	1	-0.05745	0.08113	-0.71	0.4802
	ϕ_{41}^{1}	1	0.18911	0.151337	1.25	0.2138
	ϕ_{40}^{12}	1	-0.42008	0.080881	-5.19	<.0001
	ϕ_{41}^{12}	1	-0.25595	0.156618	-1.63	0.1047
Balikpapan	ϕ_{50}^{1}	1	0.113711	0.088092	1.29	0.1991
	ϕ_{51}^{1}	1	0.089825	0.090703	0.99	0.3239
	ϕ_{50}^{12}	1	-0.06328	0.079883	-0.79	0.4298
	ϕ_{51}^{12}	1	-0.16785	0.093842	-1.79	0.0761
Samarinda	ϕ_{60}^{1}	1	-0.02523	0.075024	-0.34	0.7372
	ϕ_{61}^{1}	1	0.190841	0.108262	1.76	0.0804
	ϕ_{60}^{12}	1	-0.48397	0.075367	-6.42	<.0001
	ϕ_{61}^{12}	1	-0.10701	0.11034	-0.97	0.334

Tabel 4.72 di atas menunjukkan masih terdapat parameter yang tidak signifikan pada tingkat taraf uji $\alpha = 0.05$ sehingga perlu dilakukan seleksi parameter untuk menghasilkan model terbaik dan signifikan yang memenuhi taraf uji $\alpha = 0.05$. Estimasi parameter untuk model yang bersifat *restricted model* seperti pada Tabel 4.73.

Tabel 4.73. Estimasi Parameter *Restricted* Model dari Model GSTAR-GLS ($[1,12]_1$) dengan Bobot Seragam Pada $u_{i,t}$ Inflasi

Lokasi	Parameter	DF	Estimasi	Standar Error	t-value	p-value
Pontianak	ϕ_{10}^{1}	1	-0.185	0.073305	-2.52	0.0128
	ϕ_{10}^{12}	1	-0.36725	0.078008	-4.71	<.0001
Sampit	ϕ_{20}^{12}	1	-0.48052	0.069262	-6.94	<.0001
Palangkaraya	ϕ_{30}^{12}	1	-0.57603	0.054622	-10.55	<.0001
Banjarmasin	ϕ_{40}^{12}	1	-0.4758	0.063641	-7.48	<.0001
Samarinda	ϕ_{60}^{12}	1	-0.48133	0.066373	-7.25	<.0001

Berdasarkan pada Tabel 4.73 menunjukkan bahwa parameter pada model GSTAR-GLS ($[1,12]_1$) dengan bobot seragam dapat digunakan pada tingkat taraf uji $\alpha = 0.05$. Bentuk persamaan matriks model GSTAR-GLS ($[1,12]_1$) dengan bobot lokasi seragam adalah sebagai berikut :

$$\begin{bmatrix} u_1(t) \\ u_2(t) \\ u_3(t) \\ u_4(t) \\ u_5(t) \\ u_6(t) \end{bmatrix} = \begin{bmatrix} -0.185 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} u_1(t-1) \\ u_2(t-1) \\ u_3(t-1) \\ u_4(t-1) \\ u_5(t-1) \\ u_6(t-1) \end{bmatrix} + \begin{bmatrix} -0.367 & 0 & 0 & 0 & 0 & 0 \\ 0 & -0.481 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.576 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.476 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0.481 \end{bmatrix} \begin{bmatrix} u_1(t-12) \\ u_2(t-12) \\ u_3(t-12) \\ u_4(t-12) \\ u_5(t-12) \\ u_6(t-12) \end{bmatrix} + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \\ e_{5,t} \\ e_{6,t} \end{bmatrix}.$$

Persamaan matriks di atas dapat diuraikan menjadi bentuk persamaan untuk tiap lokasi sebagai berikut :

✓ Model GSTAR-GLS ($[1,12]_1$) di Pontianak

$$u_{1,t} = -0.185\, u_{1,t-1} - 0.367\, u_{1,t-12} + e_{1,t}$$

✓ Model GSTAR-GLS ($[1,12]_1$) di Sampit

$$u_{2,t} = -0.481\, u_{2t-12} + e_{2,t}$$

✓ Model GSTAR-GLS ($[1,12]_1$) di Palangkaraya

$$u_{3,t} = -0.576\, u_{3,t-12} + e_{3,t}$$

- ✓ Model GSTAR-GLS ([1,12]$_1$) di Banjarmasin

  $u_{4,t} = -0.476\, u_{4t-12} + e_{4,t}$

- ✓ Model GSTAR-GLS ([1,12]$_1$) di Samarinda

  $u_{6,t} = -0.481\, u_{6,t-12} + e_{6,t}$

Berdasarkan pemodelan GSTAR-GLS ([1,12]$_1$) data inflasi enam kota di Kalimantan dengan menggunakan bobot lokasi seragam memperlihatkan bahwa tidak ada keterkaitan inflasi antar lokasi di Kalimantan. Hal ini terlihat pada model yang tidak menunjukkan adanya parameter efek spasial. Inflasi di suatu lokasi hanya dipengaruhi oleh wilayah yang bersangkutan pada waktu yang berbeda.

4.11.2.2. Pemodelan GSTAR ([1,12]$_1$) dengan Bobot Invers Jarak

Pada pemodelan GSTAR([1,12]$_1$) dengan bobot invers jarak dilakukan dengan menggunakan jarak tempuh transportasi darat antar lokasi ($\boldsymbol{D}$). Matriks jarak untuk enam lokasi di Kalimantan adalah sebagai berikut :

$$\boldsymbol{D} = \begin{bmatrix} 0 & 1.074 & 1.296 & 1.490 & 1..988 & 2144 \\ 1.074 & 0 & 222 & 416 & 914 & 1030 \\ 1.296 & 222 & 0 & 194 & 692 & 808 \\ 1.490 & 416 & 194 & 0 & 498 & 614 \\ 1.988 & 914 & 692 & 498 & 0 & 116 \\ 2.144 & 1.030 & 808 & 614 & 116 & 0 \end{bmatrix}$$

Pemodelan dengan menggunakan bobot invers jarak mengaasumsikan bahwa data inflasi suatu wilayah dipengaruhi oleh jarak antara lokasi tersebut dengan lokasi lainnya. Jarak antara dua lokasi yang berjauhan cenderung memiliki bobot yang lebih kecil dibandingkan dengan jarak antara dua lokasi yang lebih berdekatan. Matriks bobot invers jarak ($\boldsymbol{W}$) untuk enam lokasi di wilayah Kalimantan adalah sebagai berikut :

$$\boldsymbol{W} = \begin{bmatrix} 0 & 0.28 & 0.23 & 0.20 & 0.15 & 0.14 \\ 0.09 & 0 & 0.45 & 0.24 & 0.11 & 0.10 \\ 0.06 & 0.34 & 0 & 0.39 & 0.11 & 0.09 \\ 0.06 & 0.20 & 0.43 & 0 & 0.17 & 0.14 \\ 0.04 & 0.08 & 0.11 & 0.15 & 0 & 0.63 \\ 0.04 & 0.08 & 0.10 & 0.13 & 0.67 & 0 \end{bmatrix}$$

Hasil estimasi parameter untuk model GSTAR-GLS($[1,12]_1$) yang *full model* dapat dilihat pada Tabel 4.74 di bawah ini.

Tabel 4.74. Estimasi Parameter *Full Model* dari Model GSTAR-GLS ($[1,12]_1$) dengan Bobot Invers Jarak Pada $u_{i,t}$ Inflasi

Lokasi	Parameter	DF	Estimasi	Standar Error	t-value	p-value
Pontianak	ϕ_{10}^{1}	1	-0.19324	0.077182	-2.5	0.0136
	ϕ_{11}^{1}	1	0.120186	0.082434	1.46	0.1473
	ϕ_{10}^{12}	1	-0.39068	0.081146	-4.81	<.0001
	ϕ_{11}^{12}	1	0.027154	0.085178	0.32	0.7504
Sampit	ϕ_{20}^{1}	1	-0.09315	0.078556	-1.19	0.2379
	ϕ_{21}^{1}	1	0.279063	0.119369	2.34	0.021
	ϕ_{20}^{12}	1	-0.48375	0.078186	-6.19	<.0001
	ϕ_{21}^{12}	1	-0.06854	0.118581	-0.58	0.5643
Palangkaraya	ϕ_{30}^{1}	1	0.07444	0.074474	1	0.3194
	ϕ_{31}^{1}	1	0.161416	0.099219	1.63	0.1063
	ϕ_{30}^{12}	1	-0.53062	0.072142	-7.36	<.0001
	ϕ_{31}^{12}	1	-0.15104	0.10099	-1.5	0.1373
Banjarmasin	ϕ_{40}^{1}	1	-0.08218	0.084278	-0.98	0.3314
	ϕ_{41}^{1}	1	0.208885	0.131259	1.59	0.114
	ϕ_{40}^{12}	1	-0.40249	0.083813	-4.8	<.0001
	ϕ_{41}^{12}	1	-0.20162	0.132284	-1.52	0.13
Balikpapan	ϕ_{50}^{1}	1	0.136805	0.090742	1.51	0.1342
	ϕ_{51}^{1}	1	0.070058	0.083463	0.84	0.4028
	ϕ_{50}^{12}	1	-0.09668	0.083958	-1.15	0.2517
	ϕ_{51}^{12}	1	-0.08832	0.085946	-1.03	0.3061
Samarinda	ϕ_{60}^{1}	1	-0.05793	0.074113	-0.78	0.4359
	ϕ_{61}^{1}	1	0.270861	0.106812	2.54	0.0124
	ϕ_{60}^{12}	1	-0.46056	0.074177	-6.21	<.0001
	ϕ_{61}^{12}	1	-0.15813	0.103445	-1.53	0.1289

Berdasarkan pada Tabel 4.74 masih terdapat adanya parameter yang tidak signifikan pada tingkat taraf uji $\alpha = 0.05$. Untuk itu dilakukan seleksi parameter untuk menghasilkan model terbaik dan signifikan yang memenuhi taraf uji $\alpha = 0.05$. Estimasi parameter untuk model yang bersifat *restricted model* seperti pada Tabel 4.75.

Tabel 4.75. Estimasi Parameter Restricted Model dari Model GSTAR-GLS ($[1,12]_1$) dengan Bobot Invers Jarak Pada $u_{i,t}$ Inflasi

Lokasi	**Parameter**	**DF**	**Estimasi**	**Standar Error**	**t-value**	**p-value**
Pontianak	ϕ_{10}^{1}	1	-0.18594	0.073298	-2.54	0.0124
	ϕ_{10}^{12}	1	-0.36788	0.078019	-4.72	<.0001
Sampit	ϕ_{20}^{12}	1	-0.48204	0.069327	-6.95	<.0001
Palangkaraya	ϕ_{31}^{1}	1	0.144783	0.067582	2.14	0.0341
	ϕ_{30}^{12}	1	-0.56115	0.054578	-10.28	<.0001
Banjarmasin	ϕ_{40}^{12}	1	-0.46885	0.063607	-7.37	<.0001
Samarinda	ϕ_{60}^{12}	1	-0.4809	0.066777	-7.2	<.0001

Berdasarkan Tabel 4.75 menunjukkan bahwa parameter pada model GSTAR-GLS ($[1,12]_1$) dapat digunakan pada tingkat taraf uji $\alpha = 0.05$. Bentuk persamaan matriks model GSTAR-GLS ($[1,12]_1$) dengan bobot invers jarak adalah sebagai berikut :

$$\begin{bmatrix} u_1(t) \\ u_2(t) \\ u_3(t) \\ u_4(t) \\ u_5(t) \\ u_6(t) \end{bmatrix} = \begin{bmatrix} -0.186 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} u_1(t-1) \\ u_2(t-1) \\ u_3(t-1) \\ u_4(t-1) \\ u_5(t-1) \\ u_6(t-1) \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.145 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0.278 & 0.230 & 0.200 & 0.150 & 0.142 \\ 0.094 & 0 & 0.455 & 0.243 & 0.110 & 0.098 \\ 0.059 & 0.344 & 0 & 0.393 & 0.110 & 0.094 \\ 0.057 & 0.203 & 0.434 & 0 & 0.169 & 0.137 \\ 0.037 & 0.080 & 0.106 & 0.147 & 0 & 0.631 \\ 0.037 & 0.075 & 0.096 & 0.126 & 0.667 & 0 \end{bmatrix} \begin{bmatrix} u_1(t-1) \\ u_2(t-1) \\ u_3(t-1) \\ u_4(t-1) \\ u_5(t-1) \\ u_6(t-1) \end{bmatrix}$$

$$+ \begin{bmatrix} -0.368 & 0 & 0 & 0 & 0 & 0 \\ 0 & -0.482 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.561 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.469 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0.481 \end{bmatrix} \begin{bmatrix} u_1(t-12) \\ u_2(t-12) \\ u_3(t-12) \\ u_4(t-12) \\ u_5(t-12) \\ u_6(t-12) \end{bmatrix} + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \\ e_{5,t} \\ e_{6,t} \end{bmatrix}.$$

Persamaan matriks di atas dapat ditulis untuk tiap lokasi sebagai berikut :

✓ Model GSTAR-GLS ($[1,12]_1$) di Pontianak

$u_{1,t} = -0.186\, u_{1,t-1} - 0.368\, u_{1,t-12} + e_{1,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Sampit

  $u_{2,t} = -0.482\, u_{2,t-12} + e_{2,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Palangkaraya

  $u_{3,t} = 0.009\, u_{1,t-1} + 0.050\, u_{2t-1} + 0.057\, u_{4t-1} + 0.016\, u_{5,t-1} + 0.014\, u_{6,t-1} - 0.561\, u_{3,t-12} + e_{3,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Banjarmasin

  $u_{4,t} = -0.469\, u_{4t-12} + e_{4,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Samarinda

  $u_{6,t} = -0.481\, u_{6,t-12} + e_{6,t}$

Parameter pada model GSTAR-GLS ($[1,12]_1$) dengan bobot invers jarak, memperlihatkan bahwa hanya terdapat 1 lokasi yang memiliki efek spasial yaitu Palangkaraya. Inflasi Palangkaraya dipengaruhi oleh inflasi Pontianak, Sampit, Banjarmasin, Balikpapan dan Samarinda pada waktu satu bulan sebelumnya. Adapun untuk 5 lokasi lainnya, terjadinya inflasi hanya dipengaruhi oleh wilayah yang bersangkutan pada lag 12 bulan sebelumnya.

4.11.2.3. Pemodelan GSTAR ($[1,12]_1$) dengan Bobot Normalisasi Korelasi Silang

Pemodelan GSTAR-GLS ($[1,12]_1$) dengan menggunakan bobot normalisasi korelasi silang mempunyai asumsi bahwa keterikaitan inflasi antara lokasi dipengaruhi oleh tinggi rendahnya korelasi antara inflasi di lokasi satu dengan inflasi di lokasi lainnya. Perhitungan bobot normalisasi korelasi silang diperoleh melalui normalisasi dari nilai-nilai korelasi antara lokasi pada lag yang bersesuaian. Dalam GSTAR-GLS ($[1,12]_1$) maka korelasi silang yang digunakan adalah korelasi silang pada lag 1 dan lag 12. Korelasi silang pada lag 1 dan 12 yang terbentuk adalah sebagai beirkut :

The VARMAX Procedure
Cross-Correlation Matrices of Endogenous (Dependent) Series

Lag	Variable	u1	u2	u3	u4	u5	u6
1	u1	-0.18866	0.20868	0.06966	-0.04058	0.04936	0.10425
	u2	-0.03727	0.08559	0.24048	0.13348	0.14932	0.16899
	u3	0.09010	0.22444	0.26065	0.11858	0.15818	0.13633
	u4	0.04169	0.12923	0.13071	-0.03695	0.05457	0.01945
	u5	-0.00909	-0.01768	0.08077	0.02772	0.15134	0.12143
	u6	-0.02069	0.06792	0.23252	0.05979	0.13458	0.08412
12	u1	-0.32103	-0.07957	-0.19054	-0.16891	-0.07523	-0.11322
	u2	-0.05617	-0.50128	-0.33709	-0.28481	-0.14048	-0.26320
	u3	-0.01840	-0.23435	-0.58574	-0.36671	-0.13152	-0.18270
	u4	-0.10943	-0.28949	-0.44841	-0.50666	-0.17722	-0.24415
	u5	-0.02401	0.01155	-0.24319	-0.17100	-0.10518	-0.23020
	u6	-0.21493	-0.12862	-0.23828	-0.17600	-0.06801	-0.45593

Gambar 4.32. Nilai Korelasi Silang Pada Lag 1 dan 12

Berdasarkan nilai korelasi silang pada lag 1 dan 12, maka matriks bobot normalisasi korelasi silang yang digunakan pada lag 1 ($\boldsymbol{W}^{1}$) dapat ditulis :

$$\boldsymbol{W}^{1}=\begin{bmatrix} 0 & 0.442 & 0.147 & -0.086 & 0.104 & 0.221 \\ -0.051 & 0 & 0.330 & 0.183 & 0.205 & 0.232 \\ 0.124 & 0.308 & 0 & 0.163 & 0.217 & 0.187 \\ 0.111 & 0.344 & 0.348 & 0 & 0.145 & 0.052 \\ -0.035 & -0.069 & 0315 & 0.108 & 0 & 0.473 \\ -0.040 & 0.132 & 0.451 & 0.116 & 0.261 & 0 \end{bmatrix}$$

Adapun matriks bobot normalisasi korelasi silang yang digunakan pada lag 12 ($\boldsymbol{W}^{12}$) dapat ditulis :

$$\boldsymbol{W}^{12}=\begin{bmatrix} 0 & -0.127 & -0.304 & -0.269 & -0.120 & -0.180 \\ -0.052 & 0 & -0.312 & -0.263 & -0.130 & -0.243 \\ -0.020 & -0.251 & 0 & -0.393 & -0.141 & -0.196 \\ -0.086 & -0.228 & -0.353 & 0 & -0.140 & -0.192 \\ -0.035 & -0.017 & -0.358 & -0.251 & 0 & -0.339 \\ -0.260 & -0.156 & -0.289 & -0.213 & -0.082 & 0 \end{bmatrix}$$

Hasil estimasi parameter untuk model GSTAR-GLS($[1,12]_1$) yang *full model* dapat dilihat pada Tabel 4.76.

Tabel 4.76. Estimasi Parameter *Full Model* dari Model GSTAR-GLS ($[1,12]_1$) dengan Bobot Normalisasi Korelasi Silang Pada $u_{i,t}$ Inflasi

Lokasi	**Parameter**	**DF**	**Estimasi**	**Standar Error**	**t-value**	**p-value**
Pontianak	ϕ_{10}^{1}	1	-0.17269	0.076381	-2.26	0.0255
	ϕ_{11}^{1}	1	0.02056	0.09169	0.22	0.8229
	ϕ_{10}^{12}	1	-0.38887	0.083456	-4.66	<.0001
	ϕ_{11}^{12}	1	-0.02443	0.087604	-0.28	0.7808

Lokasi	Parameter	DF	Estimasi	Standar Error	t-value	p-value
Sampit	ϕ_{20}^{1}	1	-0.06726	0.080507	-0.84	0.4051
	ϕ_{21}^{1}	1	0.205949	0.140092	1.47	0.144
	ϕ_{20}^{12}	1	-0.49486	0.079257	-6.24	<.0001
	ϕ_{21}^{12}	1	0.05668	0.130212	0.44	0.6641
Palangkaraya	ϕ_{30}^{1}	1	0.061286	0.071226	0.86	0.3912
	ϕ_{31}^{1}	1	0.159894	0.11298	1.42	0.1595
	ϕ_{30}^{12}	1	-0.51863	0.072596	-7.14	<.0001
	ϕ_{31}^{12}	1	0.168873	0.10839	1.56	0.1217
Banjarmasin	ϕ_{40}^{1}	1	-0.10917	0.07987	-1.37	0.1741
	ϕ_{41}^{1}	1	0.19049	0.127375	1.5	0.1373
	ϕ_{40}^{12}	1	-0.41284	0.082884	-4.98	<.0001
	ϕ_{41}^{12}	1	0.197397	0.135859	1.45	0.1487
Balikpapan	ϕ_{50}^{1}	1	0.085185	0.087793	0.97	0.3338
	ϕ_{51}^{1}	1	0.088563	0.095543	0.93	0.3557
	ϕ_{50}^{12}	1	-0.05204	0.080941	-0.64	0.5215
	ϕ_{51}^{12}	1	0.118431	0.083851	1.41	0.1603
Samarinda	ϕ_{60}^{1}	1	0.006762	0.074699	0.09	0.928
	ϕ_{61}^{1}	1	0.064075	0.093311	0.69	0.4935
	ϕ_{60}^{12}	1	-0.49763	0.076001	-6.55	<.0001
	ϕ_{61}^{12}	1	0.036914	0.104926	0.35	0.7256

Estimasi parameter model GSTAR-GLS ($[1,12]_1$) yang bersifat *restricted model* untuk menghasilkan model terbaik dan signifikan pada taraf uji $\alpha = 0.05$ seperti pada Tabel 4.77.

Tabel 4.77. Estimasi Parameter *Restricted* Model dari Model GSTAR-GLS ($[1,12]_1$) dengan Bobot Normalisasi Korelasi Silang pada $u_{i,t}$ Inflasi

Lokasi	Parameter	DF	Estimasi	Standar Error	t-value	p-value
Pontianak	ϕ_{10}^{1}	1	-0.185	0.073305	-2.52	0.0128
	ϕ_{10}^{12}	1	-0.36725	0.078008	-4.71	<.0001
Sampit	ϕ_{20}^{12}	1	-0.48052	0.069262	-6.94	<.0001
Palangkaraya	ϕ_{30}^{12}	1	-0.57603	0.054622	-10.55	<.0001
Banjarmasin	ϕ_{40}^{12}	1	-0.4758	0.063641	-7.48	<.0001
Samarinda	ϕ_{60}^{12}	1	-0.48133	0.066373	-7.25	<.0001

Berdasarkan pada Tabel 4.77 di atas memperlihatkan parameter pada model GSTAR-GLS ($[1,12]_1$) dengan bobot normalisasi korelasi silang dapat digunakan pada tingkat taraf uji $\alpha = 0.05$. Bentuk persamaan matriks model GSTAR-GLS ($[1,12]_1$) dengan bobot normalisasi korelasi silang adalah sebagai berikut :

$$\begin{bmatrix} u_1(t) \\ u_2(t) \\ u_3(t) \\ u_4(t) \\ u_5(t) \\ u_6(t) \end{bmatrix} = \begin{bmatrix} -0.185 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} u_1(t-1) \\ u_2(t-1) \\ u_3(t-1) \\ u_4(t-1) \\ u_5(t-1) \\ u_6(t-1) \end{bmatrix} + \begin{bmatrix} -0.367 & 0 & 0 & 0 & 0 & 0 \\ 0 & -0.480 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.576 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.476 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0.481 \end{bmatrix} \begin{bmatrix} u_1(t-12) \\ u_2(t-12) \\ u_3(t-12) \\ u_4(t-12) \\ u_5(t-12) \\ u_6(t-12) \end{bmatrix} + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \\ e_{5,t} \\ e_{6,t} \end{bmatrix}$$

Bentuk persamaan matriks dari model GSTAR ($[1,12]_1$) di atas dapat ditulis untuk tiap lokasi sebagai berikut :

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Pontianak

  $u_{1,t} = -0.185\, u_{1,t-1} - 0.367\, u_{1,t-12} + e_{1,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Sampit

  $u_{2,t} = -0.480\, u_{2t-12} + e_{2,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Palangkaraya

  $u_{3,t} = -0.576\, u_{3,t-12} + e_{3,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Banjarmasin

  $u_{4,t} = -0.476\, u_{4t-12} + e_{4,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Samarinda

  $u_{6,t} = -0.481\, u_{6,t-12} + e_{6,t}$

Berdasarkan model GSTAR-GLS ($[1,12]_1$) dengan bobot normalisasi korelasi silang, menunjukkan bahwa tidak adanya lokasi inflasi yang memiliki efek spasial. Inflasi di satu lokasi tidak mempengaruhi lokasi lain, begitu sebaliknya, sehingga inflasi yang terjadi di satu lokasi hanya dipengaruhi oleh lokasi yang itu sendiri pada lag dua belas bulan sebelumnya.

4.11.2.4. Pemodelan GSTAR ($[1,12]_1$) dengan Bobot Normalisasi Inferensia Parsial Korelasi Silang

Perhitungan bobot normalisasi inferensia parsial korelasi silang diperoleh melalui normalisasi dari nilai-nilai korelasi silang berdasarkan skema plot MCCF pada lag yang bersesuain. Dalam model GSTAR-GLS ($[1,12]_1$) maka skema plot MCCF yang dilihat adalah pada lag 1 dan 12, dimana yang bertanda titik maka diberi nilai nol. Sedangkan untuk skema plot yang bertanda + atau – maka nilai yang digunakan nilai korelasi silang yang bersesuaian. Langkah berikutnya melakukan normalisasi setelah mendapatkan korelasi dengan inferensia parsial korelasi silang. Skema plot MCCF pada lag 1 dan 12 serta matriks bobot normalisasi inferensia parsial korelasi silang yang digunakan untuk mengestimasi parameter GSTAR-GLS ($[1,12]_1$) dapat ditunjukkan sebagai berikut :

Schematic Representation of Cross Correlations

Variable/ Lag	0	1	2	3	4	5	6	7
u1	+.++++	-+....	......	......	......	......	......	......
u2	.+++++	..+..+	......	......	......	......	......	......
u3	++++++	.++...	.--...	.-....	......	..+...	......	......
u4	++++++	......	......	....-.	.+....	......	......	......
u5	++++++	......	......	+.....	.++...	......	......	......
u6	++++++	..+...	......	+.....	......	......	......	......

Schematic Representation of Cross Correlations

Variable/ Lag	10	11	12	13	14
u1	......	......	-.--..	.-....	......
u2	......	......	.---.-	..-.--	......
u3	......	..-..-	.---.-	---...	......
u4	......	......	.-----	-.....	.....-
u5	......	......	..--.-	......	......
u6	...-..	..-...	-.--.-	......	......

Gambar 4.33. Skema Tanda Plot MCCF Pada Lag 1 dan 12

Berdasarkan skema tanda plot MCCF pada lag 1 dan 12 maka matriks bobot normalisasi inferensia parsial korelasi silang yang digunakan pada lag 1 ($\boldsymbol{W}^{1}$) dan lag 12 ($\boldsymbol{W}^{12}$) dapat ditulis :

$$\boldsymbol{W}^{1} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.59 & 0 & 0 & 0.41 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \end{bmatrix} \quad \boldsymbol{W}^{12} = \begin{bmatrix} 0 & 0 & -0.530 & -0.470 & 0 & 0 \\ 0 & 0 & -0.381 & -0.322 & 0 & -0.297 \\ 0 & -0.299 & 0 & -0.468 & 0 & -0.233 \\ 0 & -0.250 & -0.387 & 0 & -0.153 & -0.211 \\ 0 & 0 & -0.377 & -0.265 & 0 & -0.357 \\ -0.342 & 0 & -0.379 & -0.280 & 0 & 0 \end{bmatrix}$$

Hasil estimasi parameter untuk model GSTAR-GLS($[1,12]_1$) yang *full model* dapat dilihat pada Tabel 4.78. di bawah ini.

Tabel 4.78. Estimasi Parameter *Full Model* dari Model GSTAR-GLS ($[1,12]_1$) dengan Bobot Normalisasi Inferensia Parsial Korelasi Silang pada $u_{i,t}$ Inflasi

Lokasi	Parameter	DF	Estimasi	Standar Error	t-value	p-value
Pontianak	ϕ_{10}^{1}	1	-0.16616	0.07516	-2.21	0.0289
	ϕ_{11}^{1}	1	-0.04763	0.049612	-0.96	0.3389
	ϕ_{10}^{12}	1	-0.38844	0.082504	-4.71	<.0001
	ϕ_{11}^{12}	1	-0.05141	0.066621	-0.77	0.4418
Sampit	ϕ_{20}^{1}	1	-0.0978	0.078957	-1.24	0.2178
	ϕ_{21}^{1}	1	0.183475	0.111069	1.65	0.101
	ϕ_{20}^{12}	1	-0.48513	0.078673	-6.17	<.0001
	ϕ_{21}^{12}	1	0.058191	0.116994	0.5	0.6198
Palangkaraya	ϕ_{30}^{1}	1	0.060316	0.063798	0.95	0.3462
	ϕ_{31}^{1}	1	0.040958	0.05391	0.76	0.4488
	ϕ_{30}^{12}	1	-0.52511	0.073543	-7.14	<.0001
	ϕ_{31}^{12}	1	0.122972	0.097677	1.26	0.2104
Banjarmasin	ϕ_{40}^{1}	1	-0.06444	0.063887	-1.01	0.3151
	ϕ_{41}^{1}	0	0	.	.	.
	ϕ_{40}^{12}	1	-0.39779	0.083333	-4.77	<.0001
	ϕ_{41}^{12}	1	0.199114	0.125889	1.58	0.1162
Balikpapan	ϕ_{50}^{1}	1	0.094792	0.076859	1.23	0.2197
	ϕ_{51}^{1}	0	0	.	.	.
	ϕ_{50}^{12}	1	-0.06405	0.080427	-0.8	0.4273
	ϕ_{51}^{12}	1	0.099062	0.080653	1.23	0.2216
Samarinda	ϕ_{60}^{1}	1	0.026555	0.071537	0.37	0.7111
	ϕ_{61}^{1}	1	-0.04931	0.062142	-0.79	0.4289
	ϕ_{60}^{12}	1	-0.53791	0.076155	-7.06	<.0001
	ϕ_{61}^{12}	1	-0.04126	0.096184	-0.43	0.6687

Adapun estimasi parameter model yang bersifat *restricted* seperti ditunjukkan pada Tabel 4.79 di bawah ini.

Tabel 4.79. Estimasi Parameter *Restricted* Model dari Model GSTAR-GLS ($[1,12]_1$) dengan Bobot Normalisasi Inferensia Parsial Korelasi Silang pada $u_{i,t}$ Inflasi

Lokasi	Parameter	DF	Estimasi	Standar Error	t-value	p-value
Pontianak	ϕ_{10}^{1}	1	-0.185	0.073305	-2.52	0.0128
	ϕ_{10}^{12}	1	-0.36725	0.078008	-4.71	<.0001

Lokasi	Parameter	DF	Estimasi	Standar Error	t-value	p-value
Sampit	ϕ_{20}^{12}	1	-0.48052	0.069262	-6.94	<.0001
Palangkaraya	ϕ_{30}^{12}	1	-0.57603	0.054622	-10.55	<.0001
Banjarmasin	ϕ_{40}^{12}	1	-0.4758	0.063641	-7.48	<.0001
Samarinda	ϕ_{60}^{12}	1	-0.48133	0.066373	-7.25	<.0001

Bentuk persamaan matriks model GSTAR-GLS ($[1,12]_1$) dengan bobot normalisasi inferensia parsial korelasi silang adalah sebagai berikut :

$$\begin{bmatrix} u_1(t) \\ u_2(t) \\ u_3(t) \\ u_4(t) \\ u_5(t) \\ u_6(t) \end{bmatrix} = \begin{bmatrix} -0.185 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} u_1(t-1) \\ u_2(t-1) \\ u_3(t-1) \\ u_4(t-1) \\ u_5(t-1) \\ u_6(t-1) \end{bmatrix} + \begin{bmatrix} -0.367 & 0 & 0 & 0 & 0 & 0 \\ 0 & -0.480 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.576 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.476 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0.481 \end{bmatrix} \begin{bmatrix} u_1(t-12) \\ u_2(t-12) \\ u_3(t-12) \\ u_4(t-12) \\ u_5(t-12) \\ u_6(t-12) \end{bmatrix} + \begin{bmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \\ e_{5,t} \\ e_{6,t} \end{bmatrix}$$

Bentuk persamaan matriks dari model GSTAR ($[1,12]_1$) di atas dapat ditulis untuk tiap lokasi sebagai berikut :

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Pontianak
  $u_{1,t} = -0.185\, u_{1,t-1} - 0.367\, u_{1,t-12} + e_{1,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Sampit
  $u_{2,t} = -0.480\, u_{2t-12} + e_{2,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Palangkaraya
  $u_{3,t} = -0.576\, u_{3,t-12} + e_{3,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Banjarmasin
  $u_{4,t} = -0.476\, u_{4t-12} + e_{4,t}$

- ✓ Model GSTAR-GLS ($[1,12]_1$) di Samarinda
  $u_{6,t} = -0.481\, u_{6,t-12} + e_{6,t}$

Berdasarkan model GSTAR-GLS ($[1,12]_1$) dengan bobot normalisasi inferensia parsial korelasi silang memperlihatkan bahwa estimasi parameter dengan bobot ini sama dengan bobot normalisasi korelasi silang. Hal ini karena pada kedua model tersebut bobot lokasi yang digunakan tidak memberikan pengaruh yang signifikan pada taraf uji $\alpha = 0.05$.

4.11.3. Pemodelan GSTARX

Pemodelan GSATRX merupakan gabungan dari model ARIMAX simultan dengan model GSTAR ($[1,12]_1$). Formulasi dari pemodelan GSTARX adalah

$$\hat{Y}_{i,t} = \hat{y}_{i,t} + \hat{u}_{i,t}$$

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* pada tahap pertama
$\hat{u}_{i,t}$ = hasil ramalan ke-*t* di lokasi ke-*i* pada tahap kedua

Model GSTARX untuk setiap lokasi berdasarkan bobot lokasi adalah:

Pontianak

- Bobot Seragam

  $$\hat{Y}_{1,t} = 0.022\, x_{1,t-5} + 0.0343\, D_{,t-1} + 0.226\, D_{,t} + 1.266\, P_t - 0.185\, u_{1,t-1} - 0.367\, u_{1,t-12} + e_{1,t}$$

- Bobot Invers Jarak

  $$\hat{Y}_{1,t} = 0.022 x_{1,t-5} + 0.0343\, D_{,t-1} + 0.226\, D_{,t} + 1.266\, P_t - 0.186\, u_{1,t-1} - 0.368\, u_{1,t-12} + e_{1,t}$$

- Normalisasi Korelasi Silang

  $$\hat{Y}_{1,t} = 0.022\, x_{1,t-5} + 0.0343\, D_{,t-1} + 0.226\, D_{,t} + 1.266\, P_t - 0.185\, u_{1,t-1} - 0.367\, u_{1,t-12} + e_{1,t}$$

- Normalisasi Inferensia Parsial Korelasi Silang

  $$\hat{Y}_{1,t} = 0.022 x_{1,t-5} + 0.0343\, D_{,t-1} + 0.226\, D_{,t} + 1.266\, P_t - 0.185\, u_{1,t-1} - 0.367\, u_{1,t-12} + e_{1,t}$$

Sampit

- Bobot Seragam

  $$\hat{Y}_{2,t} = 0.0094\, x_{2,t-14} + 1.295\, P_t - 0.481\, u_{2t-12} + e_{2,t}$$

- Bobot Invers Jarak

$\hat{Y}_{2,t} = 0.0094\, x_{2,t-14} + 1.295\, P_t - 0.482\, u_{2,t-12} + e_{2,t}$

- Normalisasi Korelasi Silang

$\hat{Y}_{2,t} = 0.0094\, x_{2,t-14} + 1.295\, P_t - 0.480\, u_{2t-12} + e_{2,t}$

- Normalisasi Inferensia Parsial Korelasi Silang

$\hat{Y}_{2,t} = 0.0094\, x_{2,t-14} + 1.295\, P_t - 0.480\, u_{2t-12} + e_{2,t}$

Palangkaraya

- Bobot Seragam

$\hat{Y}_{3,t} = 0.033\, D_t + 1.284\, P_t - 2.037\, I_t^{T=153} - 1.624\, I_t^{T=68} - 1.209\, I_t^{T=30}$
$-0.576\, u_{3,t-12} + e_{3,t}$

- Bobot Invers Jarak

$\hat{Y}_{3,t} = 0.033\, D_t + 1.284\, P_t - 2.037\, I_t^{T=153} - 1.624\, I_t^{T=68} - 1.209\, I_t^{T=30} +$
$0.009\, u_{1,t-1} + 0.050\, u_{2t-1} + 0.057\, u_{4t-1} + 0.016\, u_{5,t-1} +$
$0.014\, u_{6,t-1} - 0.561\, u_{3,t-12} + e_{3,t}$

- Normalisasi Korelasi Silang

$\hat{Y}_{3,t} = 0.033\, D_t + 1.284\, P_t - 2.037\, I_t^{T=153} - 1.624\, I_t^{T=68} - 1.209\, I_t^{T=30}$
$-0.576\, u_{3,t-12} + e_{3,t}$

- Normalisasi Inferensia Parsial Korelasi Silang

$\hat{Y}_{3,t} = 0.033\, D_t + 1.284\, P_t - 2.037\, I_t^{T=153} - 1.624\, I_t^{T=68} - 1.209\, I_t^{T=30}$
$-0.576\, u_{3,t-12} + e_{3,t}$

Banjarmasin

- Bobot Seragam

$\hat{Y}_{4,t} = -0.057\, D_{t-1} + 1.364\, P_t - 0.476\, u_{4t-12} + e_{4,t}$

- Bobot Invers Jarak

$\hat{Y}_{4,t} = -0.057\, D_{t-1} + 1.364\, P_t - 0.469\, u_{4t-12} + e_{4,t}$

- Normalisasi Korelasi Silang

$\hat{Y}_{4,t} = -0.057\, D_{t-1} + 1.364\, P_t - 0.467\, u_{4t-12} + e_{4,t}$

- Normalisasi Inferensia Parsial Korelasi Silang

  $\hat{Y}_{4,t} = -0.057\ D_{t-1} + 1.364\ P_t - 0.467\ u_{4t-12} + e_{4,t}$

Balikpapan

Tidak ada model GSTAR yang terbentuk, sehingga persamaan gabungan GSTARX adalah sama dengan model ARIMAX yaitu

$$\hat{Y}_{5,t} = 1.312\ P_t - 2.116\ I_t^{T=153} + e_{5,t}$$

Samarinda

- Bobot Seragam

  $\hat{Y}_{6,t} = 0.213\ D_t + 1.642\ P_t \pm 1.895\ I_t^{T=95} - 0.481\ u_{6,t-12} + e_{6,t}$
- Bobot Invers Jarak

  $\hat{Y}_{6,t} = 0.213\ D_t + 1.642\ P_t \pm 1.895\ I_t^{T=95} - 0.481\ u_{6,t-12} + e_{6,t}$
- Normalisasi Korelasi Silang

  $\hat{Y}_{6,t} = 0.213\ D_t + 1.642\ P_t + -1.895\ I_t^{T=95} - 0.481\ u_{6,t-12} + e_{6,t}$
- Normalisasi Inferensia Parsial Korelasi Silang

  $\hat{Y}_{6,t} = 0.213\ D_t + 1.642\ P_t + -1.895\ I_t^{T=95} - 0.481\ u_{6,t-12} + e_{6,t}$

4.11.4. *Diagnostic Checking* Model GSTARX

Tahapan *diagnostic checking* dilakukan untuk menguji asumsi apakah residual sudah *white noise* atau tidak, sehingga model GSTARX bisa dianggap sebagai model yang layak. Pengujian ini dilakukan dengan cara memodelkan kembali *residual* dari model GSTARX dan melakukan pengecekan letak nilai AIC terkecil. Hasil penghitungan nilai AIC residual pada pemodelan GSTARX $([1,12]_1)$ dapat dilihat pada Tabel 4.80.

Hasil penghitungan menunjukkan bahwa nilai AIC terkecil pada keempat bobot yang digunakan terletak pada lag AR(0) dan MA(0). Hal ini berarti bahwa asumsi residual dari model GSTARX sudah memenuhi asumsi yang *white noise* sehingga model yang terbentuk layak digunakan untuk peramalan.

Tabel 4.80. Nilai AIC Residual Model GSTARX Berdasarkan Jenis Bobot Lokasi

Jenis Bobot	Lag	MA (0)	MA (1)	MA (2)
Seragam	AR (0)	**-9.84504**	-9.50869	-9.23246
	AR (1)	-9.69139	-9.30765	-8.98615
Invers Jarak	AR (0)	**-9.87122**	-9.48439	-9.20303
	AR (1)	-9.69252	-9.25736	-8.95903
Normalisasi Korelasi Silang	AR (0)	**-9.84504**	-9.50869	-9.23246
	AR (1)	-9.69139	-9.30765	-8.98615
Normalisasi Inferensi Parsial Korelasi Silang	AR (0)	**-9.84504**	-9.50869	-9.23246
	AR (1)	-9.69139	-9.30765	-8.98615

4.11.5. Pemilihan Model Terbaik

Pemilihan model terbaik untuk model inflasi enam lokasi di Kalimantan didasarkan pada penghitungan akurasi peramalan data *in sample* dan *out-sample.* Jumlah data *in-sample* yang digunakan sebanyak 168 observasi sedangkan data *out-sample* sebanyak 12 observasi. Akurasi hasil peramalan data *in-sample* dan *out-sample* pada model univariat dan GSTARX didasarkan pada nilai RMSE terkecil. Hasil penghitungan RMSE *in-sample* ditunjukkan pada Tabel 4.81.

Pada Tabel 4.81 memberikan informasi bahwa pada pemodelan univariat dengan menambahkan satu atau lebih variabel eksogen (prediktor) mampu menurunkan tingkat kesalahan model terhadap standar errornya. Nilai RMSE *in-sampel* untuk model ARIMAX (variasi kalender, fungsi transfer dan gabungan) lebih kecil dibandingkan dengan model ARIMA saja tanpa menambahkan variabel prediktor. Hal ini berarti model ARIMAX lebih baik model ARIMA.

Hal yang sama juga terjadi pada model multivariat yaitu GSTAR dan GSTARX. Nilai RMSE *in-sampel* pada model GSTARX menunjukkan nilai yang lebih kecil dibandingkan dengan model GSTAR untuk semua penggunaan bobot lokasi. Ini berarti adanya penambahan variabel eksogen pada model GSTAR mampu menurunkan tingkat kesalahan dalam pemodelan.

Tabel 4.81. Nilai RMSE *In-Sample* Hasil Pemodelan Univariat dan GSTARX

Model	**Ponti-anak**	**Sampit**	**Plk.Raya**	**Banjar-masin**	**Balik-papan**	**Sama-rinda**
Univariat						
ARIMA	0.9589	1.1332	1.0049	1.0164	0.9891	1.0258
ARIMA Deteksi Outlier	0.7634	1.1321	**0.8424**	**-**	**0.8475**	**-**
Variasi Kalender Bulanan	0.7545	**0.8836**	0.8471	0.9806	0.9622	1.0162
Variasi Kalender Mingguan	**0.7342**	1.1522	0.9705	0.9247	0.9396	0.9594
Fungsi Transfer	0.7544	1.1098	0.9887	1.0164	0.9859	0.9981
ARIMAX	0.7907	1.0037	0.8482	**0.8875**	0.8475	**0.8569**
GSTAR*)	1.8643	1.8057	1.4313	1.4437	1.4163	1.4837
GSTARX						
Seragam	0.8071	0.9976	0.8863	0.9071	1.0120	0.9022
Invers Jarak	0.8071	0.9974	**0.8824**	0.9080	1.0120	0.9023
Normalisasi Korelasi Silang	0.8071	0.9976	0.8863	0.9071	1.0120	0.9022
Normalisasi Inferensia Parsial Korelasi Silang	0.8071	0.9976	0.8863	0.9071	1.0120	0.9022

***)** **RMSE** untuk semua bobot sama, karena tidak ada parameter yang mengandung efek spasial

Berdasarkan pembahasan tentang model GSTARX sebelumnya, diperoleh bahwa model GSTARX dengan menggunakan bobot invers jarak memiliki efek spasial dan terjadi di satu lokasi yaitu di Palangkaraya. Model GSTARX dengan bobot lokasi invers jarak juga memberikan kebaikan model dibandingkan dengan bobot lainnya. Hal ini terlihat pada nilai RMSE *in-sample* yang lebih kecil dibandingkan dengan bobot yang lainnya.

4.12. Perbandingan Hasil Model ARIMA, Variasi Kalender, Fungsi Transfer dan GSTARX

Perbandingan hasil pemodelan ARIMA, Variasi Kalender, Fungsi Transfer dan GSTARX dilakukan untuk melihat tingkat akurasi peramalan.

Perbandingan akurasi model pada pemodelan ARIMA, variasi kalender, fungsi transfer, dan GSTARX dengan beberapa bobot menggunakan nilai RMSE terkecil pada data *out-sample*. Nilai RMSE *out-sample* untuk beberapa metode bisa dilihat pada Tabel 4.82 di bawah ini.

Tabel 4.82. Nilai RMSE *Out-Sample* Hasil Pemodelan Univariat dan GSTARX

Model	**Ponti-anak**	**Sampit**	**Plk.Raya**	**Banjar-masin**	**Balik-papan**	**Sama-rinda**
Univariat						
ARIMA	0.7663	**0.4200**	0.4829	**0.3626**	**0.7233**	0.7500
ARIMA Deteksi Outlier	0.7465	0.4692	0.5609	-	0.7276	-
Variasi Kalender Bulanan	0.7400	0.5565	0.5293	0.3872	0.7486	0.3795
Variasi Kalender Mingguan	**0.7251**	0.5367	**0.4620**	0.3666	0.7330	0.4262
Fungsi Transfer	0.7506	0.4359	0.5189	0.3626	0.7329	0.3981
ARIMAX	0.8722	0.4543	0.5164	0.3896	0.7276	**0.3691**
GSTAR*)	1.711	1.565	1.142	1.059	1.253	0.949
GSTARX						
Seragam	0.893	0.658	0.588	0.431	1.044	0.436
Invers Jarak	0.893	0.658	0.622	0.427	1.044	0.436
Normalisasi Korelasi Silang	0.893	0.657	0.588	0.431	1.044	0.436
Normalisasi Inferensia Parsial Korelasi Silang	0.893	0.657	0.588	0.431	1.044	0.436

***) RMSE** untuk semua bobot sama, karena tidak ada parameter yang mengandung efek spasial

Pada pemodelan inflasi dengan metode univariat menunjukkan bahwa model terbaik untuk masing-masing lokasi berbeda-beda. Pemilihan model terbaik didasarkan pada nilai RMSE *out-sampel* terkecil. Pemodelan inflasi di Pontianak yang memberikan akurasi terbaik adalah ARIMA-Variasi Kalender dengan *dummy* mingguan. Pada wilayah Sampit, model inflasi terbaik adalah model

ARIMA sedangkan untuk Palangkaraya adalah model ARIMA-Variasi Kalender dengan *dummy* mingguan. Adapun untuk Banjarmasin dan Balikpapan adalah model ARIMA sedangkan untuk Samarinda adalah model ARIMAX gabungan.

Pemodelan inflasi dengan metode multivariat yaitu GSTAR dan GSTARX menunjukkan bahwa model GSTARX lebih baik dibandingkan dengan model GSTAR. Model GSTARX dengan bobot invers jarak menghasilkan sebuah model yang memiliki keterkaitan antar lokasi, sehingga dalam hal ini model GSTARX terbaik yang digunakan adalah menggunakan bobot invers jarak.

Pada perbandingan model univariat dengan GSTARX maka bisa dinyatakan bahwa pemodelan univariat untuk inflasi pada enam kota di pulau Kalimantan lebih baik daripada penggunaan model GSTAR maupun GSTARX. Hal ini disebabkan karena pada model GSTAR ataupun GSTARX tidak menunjukkan adanya efek lokasi dan hanya bisa menjelaskan parameter *autoregressive* (AR) tanpa bisa mengakomodir faktor *moving average* (MA). Adapun model univariat lebih fleksibel karena selain bisa menjelaskan parameter *autoregressive* (AR) juga bisa menjelaskan faktor *moving average* (MA).

Hal lain yang dapat diperoleh dari hasil di atas bahwa pada setiap model baik univariat atau multivariat menunjukkan bahwa nilai RMSE *out-sampel* lebih besar dari nilai RMSE *in-sampel*. Hal bisa dijelaskan bahwa pada data *in-sampel* yang digunakan untuk membentuk model memiliki fluktuasi data yang tinggi. Disamping itu pada data *in-sampel* mengindikasikan adanya suatu data yang bersifat *outlier*, dan tidak semua *outlier* dilibatkan dalam pemodelan. Pemodelan inflasi dengan deteksi *outlier* hanya bertujuan untuk memenuhi asumsi kelayakan model agar residual dari model mengikuti distribusi normal. Adapun untuk data *out-sampel* tidak berfluktuasi dan relatif stabil.

Hasil peramalan inflasi dengan beberapa model pada data *out-sampel* menurut wilayah dapat dilihat pada Gambar 4.34 di bawah ini.

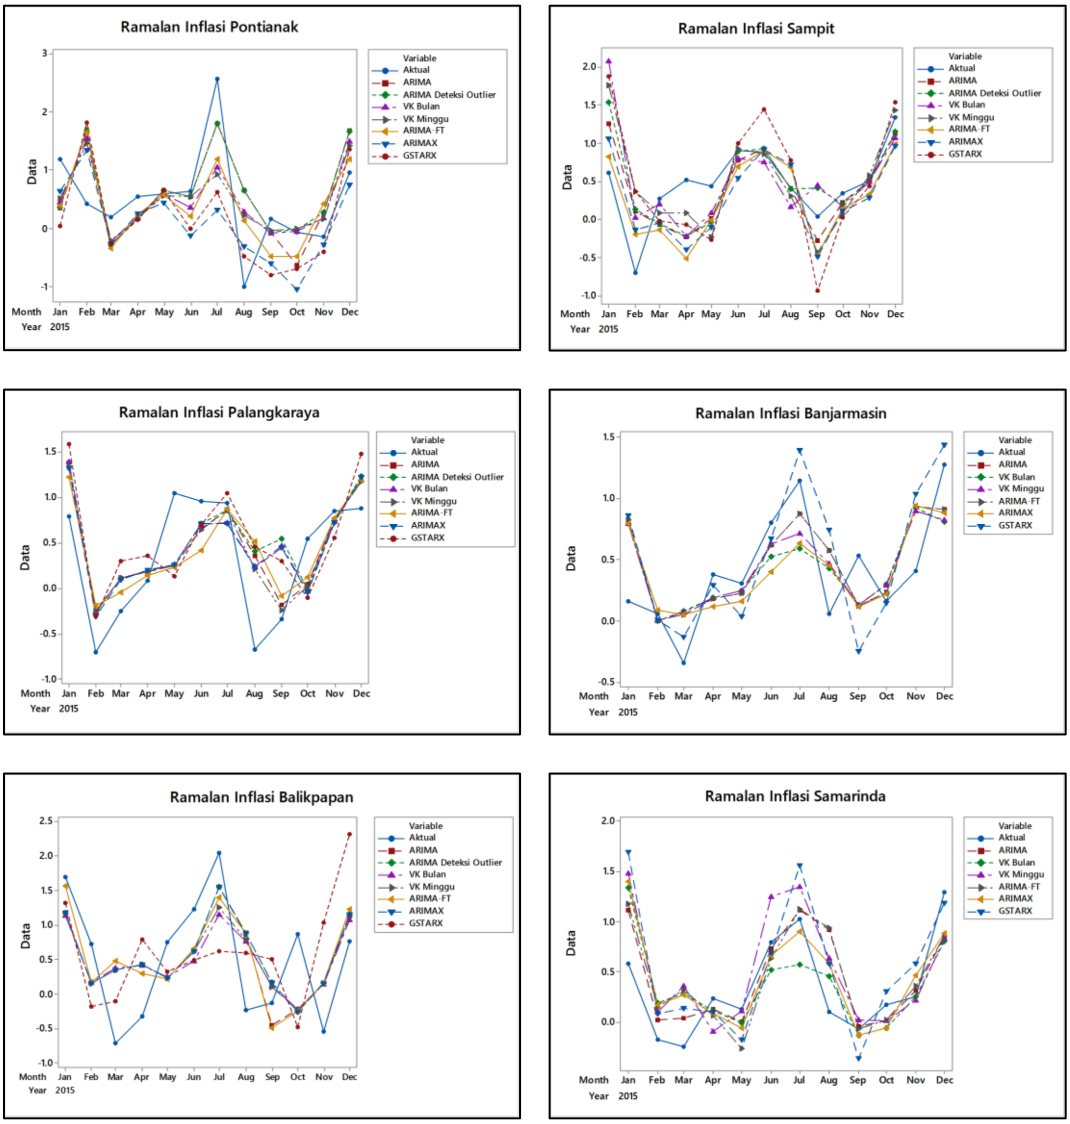

Gambar 4.34. Perbandingan Pemodelan Berdasarkan RMSE Setiap Metode

Adapun hasil ramalan inflasi untuk masing-masing wilayah dengan model univariat terpilih dan model GSATRX bisa dilihat pada Lampiran 20. Untuk mengukur sejauh mana kekuatan peramalan pada model GSTARX, maka digunakan perbandingan nilai RMSE *out-sampel* untuk masing-masing data ramalan. Nilai RMSE *out-sampel* untuk model univariat terpilih dengan model GSTARX pada masing-masing wilayah dapat dilihat pada Gambar 4.35.

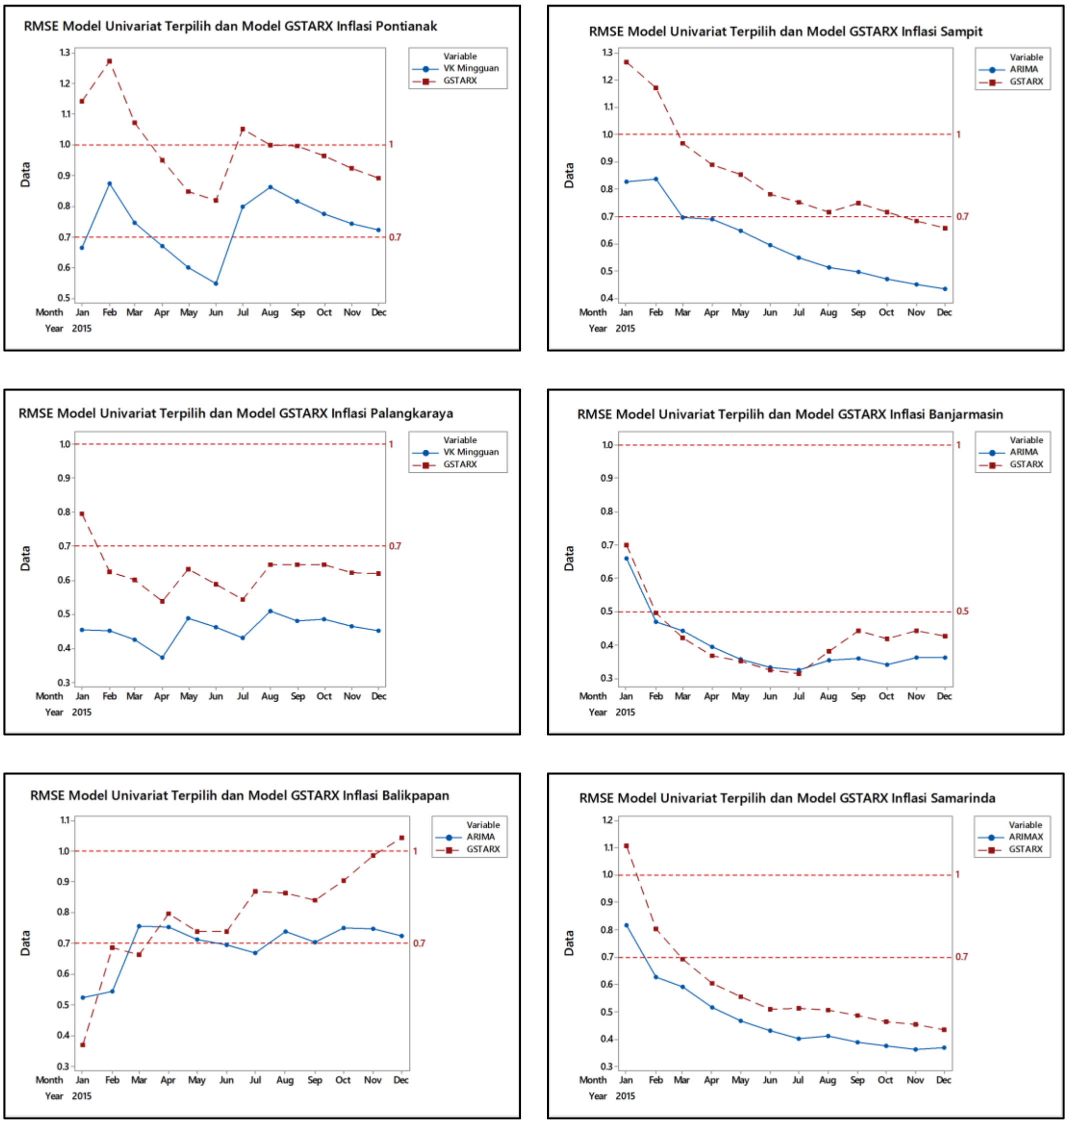

Gambar 4.35. Perbandingan Kekuatan Peramalan Berdasarkan RMSE

Berdasarkan pada Gambar 4.35 memperlihatkan keefektifan model univariat dan GSTARX dalam meramalkan inflasi enam kota di Pulau Kalimantan dengan menggunakan perbandingan RMSE *out-sampel*. Secara umum keefektifan peramalan model GSTARX untuk kasus inflasi enam kota di Pulau Kalimantan dengan menggunakan data sampel (Januari 2001- Desember 2014) bisa meramalkan hanya sampai pada bulan pertama dan kedua.

BAB 5
KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan analisis dan pembahasan, maka bisa diambil keseimpulan sebagai berikut :

a. Pemodelan inflasi hanya dengan ARIMA secara umum pada semua wilayah observasi, memberikan nilai RMSE *in-sample* yang lebih tinggi dibandingkan dengan pemodelan ARIMA yang melibatkan variabel eksogen. Keterlibatan variabel eksogen berupa intervensi (terintegrasi dengan deteksi outlier), variasi kalender dan fungsi transfer bisa menurunkan nilai RMSE *in-sample* tingkat penurunan yang berbeda-beda pada setiap wilayah (Tabel 4.81).

b. Pemodelan GSTAR untuk data inflasi enam kota di Kalimantan menghasilkan suatu model GSTAR-GLS ($[12]_1$). Parameter model GSTAR-GLS ($[12]_1$) dengan semua jenis bobot lokasi tidak menunjukkan adanya efek spasial, sehingga model yang terbentuk sama untuk semua jenis bobot.

c. Penambahan variabel eksogen pada model GSTAR bisa menurunkan nilai RMSE dan memberikan akurasi peramalan yang lebih baik. Model GSTARX yang terbentuk adalah model GSTARX-GLS (($[1,12]_1$). Model GSTARX-GLS (($[1,12]_1$) menunjukkan bahwa tidak semua inflasi di suatu wilayah mempunyai keterkaitan. Hal ini diduga karena penanganan inflasi di suatu wilayah berbeda-beda. Masing-masing pemerintah daerah mempunyai kebijakan sesuai karakteristik perekonomian wilayah yang bersangkutan. Disamping itu, ketersediaan barang dan jasa di enam kota tersebut lebih banyak berasal dari luar wilayah Kalimanatan seperti pulau Jawa, meskipun ada *supplly* barang dan jasa yang bersifat lokal namun tidaklah besar. Berdasarkan jenis bobot lokasi memperlihatkan bahwa hanya bobot invers jarak yang memiliki efek spasial pada model dan hanya terjadi pada satu wilayah yaitu Palangkaraya.

d. Pemodelan inflasi enam kota di pulau Kalimantan menunjukkan bahwa model univariat memberikan tingkat akurasi yang lebih baik dibandingkan dengan model GSTARX. Hal ini berarti, tidak semua model yang lebih komplek lebih baik dibandingkan dengan model yang lebih sederhana.

5.2. Saran

Dalam kajian inflasi enam wilayah di Kalimantan dengan menggunakan model GSTARX masih belum bisa menjelaskan adanya efek spasial secara menyeluruh dengan semua jenis bobot. Ini diduga karena faktor variabel eksogen metrik yang tidak signifikan dalam model. Untuk itu dalam penelitian selanjutnya perlu dipertimbangkan variabel eksogen metrik lainnya.

DAFTAR PUSTAKA

Ahmad, I. S., Setiawan, Suhartono, & Masun, N. H. (2015). Forecasting of Monthly Inflow and Outflow Currency Using Time Series Regression and ARIMAX : The Idul Fitri Effect. *AIP Conference Proceedings, 1691, 050002*.

Anselin, L. (1988). *Spatial Econometrics : Methods and Models.* The Netherlands: Kluwer Academic Publishers.

Ardianto, M. P. (2014). Pemodelan Generalized Space Time Autoregressive (GSTAR) Pada Tiga Periode Waktu (Studi Kasus Inflasi di Lima Kota Besar di Pulau Jawa). *Jurnal Mahasiswa Statistik, Vol.2, No.4*, hal.265-268.

Arini, P. S., & Bendesa, I. G. (2012). Pengaruh Hari Raya Galungan pada Seasonal Adjustment IHK dan Penentuan Komoditas Utama Yang Mempengaruhi Inflasi di Provinsi Bali : Analisis ARIMA. *Jurnal Ekonomi Kuatitatif Terapan, Vol.5 No.2*, hal. 79-86.

Astuti, D. (2016). *Penerapan Model Generalized Space Time Autoregressive with Exogenous Variabel (GSTARX) Untuk Peramalan Volume Ekspor CPO.* Tesis S2, Universitas Padjadjaran, Bandung.

Atmadja, A. S. (1999). Inflasi di Indonesia : Sumber-Sumber Penyebab dan Pengendaliannya. *Jurnal Akuntansi dan Keuangan, Vol.1, No.1*, hal. 54-67.

Baciu, I. C. (2015). Stochastic Models for Forecasting Inflation Rate. Empirical Evidence from Romania. *Procedia Economics and Finance, 20,* hal.44-52.

Bank Indonesia. (2015). *Kajian Ekonomi dan Keuangan Regional Kalimantan Selatan : Triwulan I-2015.* Perwakilan Bank Indonesia Provinsi Kalimantan Selatan.

Bappenas. (2010). *Kajian Strategis Aktivitas Ruang Antara Kawasan Strategis Nasional Dengan Daerah Tertinggal di Pulau Kalimantan.* Jakarta: Bappenas.

Bowerman, B. L., & O'Connell, R. T. (1993). *Forecasting and Time Series : An Applied Approach.* California: Duxburry Press.

Box, G. E., Jenkins, G. M., & Reinsel, G. C. (2008). *Time Series Analysis : Forecasting and Control* ((Fourth Edition) ed.). John Wiley and Sons Inc.

BPS. (2007). *Memahami Data Strategis Yang Dihasilkan BPS.* Jakarta: Badan Pusat Statistik.

BPS. (2013). *Data Strategis BPS.* Jakarta: CV. Dharmaputra.

BPS. (2016). *Laporan Pereknonomian Indonesia 2016.* CV. Nario Sari.

Budiarti, L., Tarno, & Warsito, B. (2013). Analisis Intervensi dan Deteksi Outlier Pada Data Wisatawan Domestik (Studi Kasus di DIY). *Jurnal Gaussian, Vol.2, No.1*, hal.39-48.

Chan, K. K., & Pham, T. M. (1990). Models of Inflation Forecasts : Some Australian Evidence. *Australian Journal of Management, Vol.15 No.1*, hal. 89-105.

Clements, M. P., & Galvao, A. B. (2013). Forecasting with Vector Autoregressive Models of Data Vintages : US Output Growth and Inflation. *International Journal of Forecasting, No.29*, hal. 698-714.

Cliff, A. D., & Ord, J. K. (1975). Space-Time Modelling with an Application to Regional Forecasting. *Transactions of the Institute of British Geographers, No.64*, hal.119-128.

Diani, K. A., Setiawan, & Suhartono. (2013). Pemodelan VAR-NN dan GSTAR-NNuntuk Peramalan Curah Hujan di Kabupaten Malang. *Jurnal Sains dan Seni POMITS, Vol.2, No.1 (2337-3520)*, D.31-D.36.

Diouf, M. A. (2007). Modelling Inflation for Mali. *IMF Working Paper*, WP/07/295.

Ditago, A. P. (2015). *Model GSTARX Dua Level Berdasarkan Variasi Kalender dengan Efek Ramadhan Untuk Peramalan Pejualan Pakaian di Perusahaan Ritel.* Tesis S2, Institut Teknologi Sepuluh Nopember, Surabaya.

Durevall, D., & Ndung'u, N. (2001). A Dynamic Model of Inflation in Kenya, 1974-1996. *Journal of African Economies, vol.10, Issue 1*, hal. 92-125.

Dwijayanthy, F., & Naomi, P. (2009). Analisis Pengaruh Inflasi, BI Rate, dan Nilai Tukar MAta Uang terhadap Profitabilitas Bank Periode 2003-2007. *Karisma, Vol. 3(2),* hal. 87-98.

Eksiandayani, S. (2016). *Pemodelan Peramalan Inflasi Umum dan Inflasi Menurut Kelompok Pengeluaran di Indonesia dengan Metode Hibrida ARIMAX-NN.* Tesis S2, Institut Teknologi Sepuluh Nopember, Surabaya.

Enke, D., & Mehdiyev, N. (2014). A Hybrid Neuro-Fuzzy Model to Forecast Inflation. *Procedia Computer Science, 36*, hal. 254-260.

Faisal, F. (2012). Forecasting Bangladesh's Inflation Using Time Series ARIMA Models. *World Review of Business Research, vol. 2. no. 3.*, hal. 100-117.

Faizah, L. A., & Setiawan. (2013). Pemodelan Inflasi di Kota Semarang, Yogyakarta, dan Surakarta dengan Pendekatan GSTAR. *Jurnal Sains dan Seni POMITS, Vol.2, No.2 (2337-3520),* hal. D.317-D.322.

Greene, W. H. (2007). *Economic Analysis, Sixth Edition.* New Jersey: Prentice Hall, Upper Saddle River.

Hasbullah, J. (2012). *Tangguh Dengan Statistik.* Jakarta: Nuansa Cendikia.

Higgins, P., Zha, T., & Zhong, W. (2016). Forecasting China's Economic Growth and Inflation. *China Economic Review.*

Irawati, L., Tarno, & Yasin, H. (2015). Peramalan Indeks Harga Konsumen 4 Kota di Jawa Tengah Menggunakan Model Generalized Space Time Autoregressive (GSTAR). *Jurnal Gaussian, Vol.4, No.3,* hal.553-562.

Kapetanios, G., Marcellino, M., & Papailias, F. (2015). Forecasting Inflation and GDP Growth Using Heuristic Optimation of Information Criteria and Variable Reduction Methods. *Computational Statistics and Data Analysis*.

Kapur, M. (2013). Revisiting the Phillips Curve for India and Inflation Forecasting. *Journal of Asian Economics, 25,* hal. 17-27.

Kemenkeu. (2016). *Informasi APBN 2016.*

Kichian, M., & Rumler, F. (2014). Forecasting Canadian Inflation : A Semi-Structural NKPC Approach. *Economic Modelling, 43,* hal. 183-191.

Kurnia, J. D. (2015). *Model Generalized Space Time Autoregressive-X (GSTARX) untuk Meramalkan Permintaan Uang di Provinsi Jawa Tengah.* Tesis S2, Institut Teknologi Sepuluh Nopember, Surabaya.

Lack, C. (2006). *Forecasting Swiss Inflation Using VAR Models.* Zurich, Switzerland: Swiss National Bank Economics Studies.

Lee, M. H., Suhartono, & Hamzah, N. A. (2010). Calender Variation Model Based on ARIMAX for Forecasting Sales Data with Ramadhan Effect. *Proceedings of The Regional Conference on Statistical Sciences 2010 (RCSS'10), Malaysia Institute of Statistics, Faculty of Computer and Mathematical Sciences, Universiti Teknologi MARA (UiTM), Malaysia*, hal. 349-361.

Lee, M. H., Suhartono, & Sanugi, B. (2010). Multi Input Intervention Model for Evaluating the Impact of the Asian and Terrorist Attacks on Tourist Arrivals. *Matematika, Vol.26, No.1*, hal.83-106.

Listyowati, & Sutijo, B. (2013). Pemodelan Indeks Harga Konsumen (IHK) Umum Berdasarkan IHK Sektor Bahan Makanan dan IHK Sektor Makanan Jadi, Minuman/Rokok. *Jurnal Sains dan Seni POMITS, Vol.2, No.2 (2337-3520),* hal. D.323-D.328.

Liu, L. M. (1980). Analysis of Time Series with Calender Effects. *Management Science, Vol.26, No.1*.

Makridakis, S., Wheelwright, S. C., & Mc.Gee, V. E. (1999). *Metode dan Aplikasi Peramalan Edisi Kedua [Terjemahan]*. Jakarta: Erlangga.

McSweeny, A. J. (1978). The Effects of Response Cost on the Behavior of a Million Persons : Charging for Directory Assistance in Cincinnati. *Journal of Applied Behavioral Analysis, Vol.11*, hal. 47-51.

Moser, G., Rumler, F., & Scharler, J. (2007). Forecasting Austrian Inflation. *Economic Modelling, Vol. 24(3)*, hal. 470-480.

Moshiri, S., & Cameron, N. (2000). Neural Network Versus Econometric Models in Forecasting Inflation. *Journal of Forecasting*, 19, 201-207.

Mubarak, R. (2015). *Model Generalized Space Time Autoregressive with Exogenous Variables Untuk Peramalan Arus Uang di Bank Indonesia Wilayah Jawa Timur*. Tesis S2, Institut Teknologi Sepuluh Nopember, Surabaya.

Mulyaningsih, T. (2015). *Model Generalized Space Time Autoregressive Integrated Untuk Peramalan Indks Harga Konsumen Beberapa Kota di Jawa Tengah.* Tesis S2, Universitas Padjadjaran, Bandung.

Muryanto. (2016). *Pemodelan GSTARX untuk Peramalan Indeks Harga Konsumen di Kalimantan.* Tesis S2, Institut Teknologi Sepuluh Nopember, Surabaya.

Nakamura, E. (2005). Inflation forecasting using a neural network. *Economic Letters, 86(3)*, hal.373-378.

Nuhad, F. (2014). Penerapan Model Nonlinear Self-Exciting Threshold Autoregressive (SETAR) untuk Pemodelan Data Inflasi di Indonesia. *Jurnal Mahasiswa Statistik, Vol. 2(4)*, hal. 289.

Nurhayati, N., Pasaribu, U. S., & Neswan, O. (2012). Application of Generalized Space-Time Autoregressive Model on GDP Daa in West European Countries. *Journal of Probability and Statistics, Article ID 867056*, 16 pages.

Nuvitasari, E. (2009). *Analisis Intervensi Multi Input Fungsi Step and Pulse untuk Peramalan Kunjungan Wisatawan ke Indonesia.* Tesis, Institut Teknologi Sepuluh Nopember, Surabaya.

Oktanidya, K. S. (2015). *Pemodelan GSTARX dengan Intervensi Pulse dan Step untuk Peramalan Wisatawan Mancanegara.* Tesis S2, Institut Teknologi Sepuluh Nopember, Surabaya.

Pfeifer, P. E., & Deutch, S. J. (1980a). A Three Stage Iterative Procedure for Space-Time Modelling. *Technometrics, Vol. 22, No.1*, hal. 35-47.

Pfeifer, P. E., & Deutsch, S. J. (1980b). Identification and Interpretation of First Order Space-Time ARMA Models. *Technometrics*, *Vol. 22 No.1*, hal. 397-408.

Pierdzioch, C., Reid, M. B., & Gupta, R. (2016). Asymmetric Loss Function and Forecast Rationality. *Economic System*, *40*, hal. 82-92.

Reganata, G. P. (2015). *Peramalan Inflow dan Outflow Uang Kartal dengan Fungsi Transfer Multi Input dan Hybrid ARIMA-Artificial Neural Network di Provinsi Bali.* Tesis S2, Institut Teknologi Sepuluh Nopember, Surabaya.

Ruchjana, B. N. (2002). Pemodelan Kurva Produksi Minyak Bumi Menggunakan Model Generalisasi S-TAR1. *Forum Statistika dan Komputasi*, Seminar Nasional, IPB, Bogor.

Ruchjana, B. N. (2002). *Suatu Model Generalisasi Space Time Autoregressive dan Penerapannya pada Produksi Minyak Bumi.* Disertasi. Program Doktor Institut Teknologi Bandung.

Ruchjana, B. N., Borovkova, S. A., & Lopuhaa, H. P. (2012). Least Squares Estimation of Generalized Space Time Autoregressive (GSTAR) Model and Its Properties. *The 5th International Conference on Research and Education in Mathematics*, American Institute of Physics. hal.61-64.

Setiawan, Suhartono, & Prastuti, M. (2016). S-GSTAR-SURModel for Seasonal Spatio Temporal Data Forecasting. *Malaysian Journal of Mathematical Sciences, 10(S)*, 53-65.

Setiawan, Suhartono, Ahmad, I. S., & Rahmawati, N. I. (2015). Configuring Calender Variation Based on Time Series Regression Method for Forecasting of Monthly Currency Inflow and outflow in Central Java. *AIP Conference Proceedings, 1691, 050024*.

Silfiani, M., & Suhartono. (2012). Aplikasi Metode Ensembel untuk Peramalan Inflasi di Indonesia. *Jurnal Sains dan Seni ITS, Vol.1, No.1, ISSN : 2301-928X*, hal. D.171-176.

Srivastava, V. K., & Dwivedi, T. D. (1979). Estimation of Seemingly Unrelated Regression Equation : A Brief Survey. *Journal of Econometrics, Vol.10*, hal. 15-32.

Stephani, C. A., Suharsono, A., & Suhartono. (2015). Peramalan Inflasi Nasional Berdasarkan Faktor Ekonomi Makro Menggunakan Pendekatan Time Series Klasik dan ANFIS. *Jurnal Sains dan Seni ITS, Vol 4(1),* D67-D72.

Stock, J. H., & Watson, M. W. (1999). Forecasting Inflation. *Journal of Monetary, Vol. 44*, hal. 293-335.

Suhartono. (2007). Teori dan Aplikasi Model Intervensi Fungsi Pulse. *Jurnal Ilmiah MatStat, Vol. 7, No.2,* hal. 191-214.

Suhartono, & Atok, R. M. (2006). Pemilihan Bobot Lokasi yang Optimal pada Model GSTAR. *Prosiding Konferensi Nasional Matematika XIII* (hal. hal. 571-580). Universitas Negeri Semarang, Semarang.

Suhartono, & Lee, M. d. (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, & Subanar. (2006). The Optimal Determination of Space Weight in GSTAR Model by Using Cross-Correlation Inference. *Jurnal of Quantitative Methods, Vol. 2,* hal. 45-53.

Suhartono, Lee, M. H., & Prastyo, D. D. (2015). Two Levels ARIMAX and Regression Models for Forcerasting Time Series Data with Calender Variation Effects. *AIP Conference Proceedings 1691, 050026*.

Suhartono, Wahyuningrum, S. R., Setiawan, & Akbar, M. S. (2016). GSTARX-GLS Model for Spatio-Temporal Data Forecasting. *Malaysian Journal of Mathematical Sciences, 10(S),* 91-103.

Tripena, A. (2011). Peramalan Indeks Harga Konsumen dan Inflasi Indonesi dengan Metode ARIMA Box-Jenkins. *Magistra, No.75, Th.XXIII*, ISSN 0215-9511.

Wei, W. W. (2006). *Time Series Analysis : Univariate and Multivariate (Second Edition).* USA: Pearson Education, Inc.

Widaryoko, N. (2013). *Inflasi dan Pertumbuhan Ekonomi : Pendugaan Ambang Batas Inflasi di Indonesia.* Tesis S2, Institut Pertanian Bogor, Bogor.

Wu, C. S., & Tsay, R. S. (2003). Forecasting with Leading Indicators Revisited. *Journal of Forecasting, Vol. 22, issue 8*, hal. 603-617.

Wulandari, N., Setiawan, & Ahmad, I. S. (2016). Peramalan Inflasi Kota Surabaya dengan Pendekatan ARIMA, Variasi Kalender, dan Intervensi. *Jurnal Sains dan Seni ITS , Vol.5 N0.1, 2337-3520*, hal. D.90-D.95.

Wutsqa, D. U., & Suhartono. (2010). Peramalan Deret Waktu Multivariat Seasonal pada Data Pariwisata dengan Model VAR-GSTAR. *Jurnal Ilmu Dasar, Vol.11 No.1*, hal. 101-109.

Wutsqa, D. U., Suhartono, & Sutijo, B. (2012). Aplikasi Model Generalized Space Time Autoregressive Pada Data Pencemaran Udara di Kota Surabaya. *Pythagoras, Vol.7, No.2*.

Zellner, A. (1962). An Efficient Method of Estimating Seemingly Unrelated Regressions and Tests for Aggregation Bias. *Journal of The American Statistical Association, Vol.57, No.298*, hal. 346-368.

LAMPIRAN

Lampiran 1. Data Inflasi Pada Enam Lokasi di Kalimantan

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2001	1	1	1.02	1.05	1.98	0.46	0.93	0.46
2001	2	2	1.53	0.36	-0.06	0.03	0.19	-0.83
2001	3	3	-0.65	0.24	2.26	0.26	-0.18	-0.11
2001	4	4	0.53	3.38	-0.23	0.56	0.36	0.89
2001	5	5	0.18	3.1	0.78	0.49	1.98	1.52
2001	6	6	1.83	0.97	1.08	1.59	1.73	1.34
2001	7	7	0.43	1.45	1.51	0.1	3.15	1.75
2001	8	8	0.06	-0.27	0.17	-0.45	0.86	0.41
2001	9	9	0.08	0.11	0.88	0.36	-0.14	0.4
2001	10	10	0.82	0.68	1.01	1.6	-0.19	1.06
2001	11	11	2.69	0.62	1.32	3.08	1.36	1.22
2001	12	12	1.66	2.15	1.93	0.02	0.32	1.72
2002	1	13	1.71	1.36	1.23	0.66	1.79	1.26
2002	2	14	1.95	1.82	0.94	1.12	1.24	2.5
2002	3	15	0.38	0.14	1.2	0.6	0.93	0.07
2002	4	16	0.71	-0.62	-0.22	-0.56	-0.3	-0.59
2002	5	17	0.11	-0.7	0.4	-0.03	0.96	0.86
2002	6	18	0.37	-0.9	-0.28	0.25	1.81	1.24
2002	7	19	0.3	2.09	0.93	0.54	-0.26	1.17
2002	8	20	0.46	0.28	0.95	0.24	1.85	0.24
2002	9	21	0.5	0.43	0.2	0.81	-0.06	0.18
2002	10	22	0.51	0.15	1.49	2.23	0.63	0.96
2002	11	23	0.48	1.85	1.8	1.86	1.07	0.93
2002	12	24	0.82	1.51	0.22	1.13	1.22	1.02
2003	1	25	1.07	-0.27	0.42	0.18	0.13	1.05
2003	2	26	0.96	1.01	0.14	0.19	-0.81	0.12
2003	3	27	-0.54	0.81	-0.08	-0.43	0.82	1.01
2003	4	28	-0.23	-0.63	0.11	-0.3	-0.04	0.23
2003	5	29	0.69	0.31	0.01	-0.14	0.15	0.42
2003	6	30	-0.4	-0.85	-1.12	-0.23	0.8	0.22
2003	7	31	1.06	-0.29	0.8	1	-0.35	0.33
2003	8	32	-0.31	2.18	-0.19	-0.16	0.61	0.88
2003	9	33	0.42	0.04	1.25	2.29	2.49	0.33
2003	10	34	0.2	0.03	0.98	1.74	-0.07	0.12

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2003	11	35	1.49	0.53	1.95	1.42	0.52	1.48
2003	12	36	0.98	0.18	1.3	1.06	1.55	1.54
2004	1	37	0.6	1.04	2.51	-0.23	0.3	0.43
2004	2	38	0.51	-0.52	-0.68	-0.73	-0.23	0.06
2004	3	39	0.15	0.58	-0.89	-0.92	1.02	-0.33
2004	4	40	0.32	0.36	0.98	1.52	0.66	0.35
2004	5	41	0.84	1.95	2.54	0.63	1.41	0.68
2004	6	42	0.44	-0.37	-0.17	1.15	-0.14	1.4
2004	7	43	0.38	-0.13	0.09	0.7	-0.05	0.3
2004	8	44	0.36	0.74	-0.07	1.77	1.37	0.24
2004	9	45	0.78	-0.21	-0.2	0.51	-0.34	0.57
2004	10	46	0.39	0.42	0.6	0.81	1.46	0.31
2004	11	47	0.1	1.84	1.85	0.98	0.38	0.38
2004	12	48	1.03	0.79	0.54	1.15	1.51	1.13
2005	1	49	1.29	1.09	0.46	0.62	1.79	0.99
2005	2	50	-0.41	-0.15	0.05	-1.23	-0.11	0.85
2005	3	51	1.55	0.76	1	1.51	2.17	1.4
2005	4	52	0.71	0.58	0.08	-0.12	0.39	0.44
2005	5	53	-0.24	0.32	-0.61	0.2	0.73	0.95
2005	6	54	0.9	-1.89	-0.38	0.11	0.48	0.5
2005	7	55	0.44	1.23	0.72	1.11	0.38	-0.08
2005	8	56	0.55	0.72	0.06	0.76	0.54	0.28
2005	9	57	0.33	0.5	0.8	0.75	0.86	0.92
2005	10	58	7.17	6.78	6.83	8.05	6.38	7.38
2005	11	59	0.46	1.52	1.7	1.53	1.7	2.07
2005	12	60	1.01	0.05	0.99	-0.78	0.9	-0.01
2006	1	61	1.37	1.71	0.18	1.16	1.06	0.64
2006	2	62	0.69	0.1	0.74	0.52	0.64	0.41
2006	3	63	0.13	-0.22	-0.43	-0.36	0.81	0.37
2006	4	64	0.38	0.95	1.57	1.99	-0.05	1.11
2006	5	65	0.26	2.17	1.46	2.42	0.23	-0.02
2006	6	66	0.34	0.76	0.61	1.62	1.72	0.77
2006	7	67	1.38	-0.35	-0.03	0.23	0.91	0.85
2006	8	68	-0.26	0.16	-1.11	-0.17	-0.83	1.41
2006	9	69	0.6	0.48	0.62	0.03	-0.13	0.16
2006	10	70	0.98	0.64	1.12	1.23	0.02	0.52
2006	11	71	-0.31	1.15	2.65	2.05	0.54	-0.17
2006	12	72	0.62	-0.06	0.13	-0.16	0.49	0.26

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2007	1	73	1.56	1.94	0.49	1.53	0.94	1.91
2007	2	74	1.11	-0.98	-0.51	0.49	-0.36	-0.05
2007	3	75	-0.12	-0.13	0.64	1.24	0.24	-0.14
2007	4	76	0.16	0.76	0.27	-0.28	0.16	-0.37
2007	5	77	0.8	-0.34	0.01	0.18	0.12	1.28
2007	6	78	0.18	-0.04	-0.42	-0.56	0.11	-0.38
2007	7	79	0.88	-0.03	0.08	0.4	0.86	0.96
2007	8	80	-0.02	0.16	1.01	0.27	1.91	1.8
2007	9	81	1.24	1.71	1.28	1.91	1.7	2.01
2007	10	82	1.69	0.61	1.06	0.76	0.05	0.93
2007	11	83	0.24	0.57	1.93	0.46	0.04	0.16
2007	12	84	0.55	3.15	1.88	1.15	1.31	0.75
2008	1	85	1.6	3.96	5.02	2.89	1.13	2.51
2008	2	86	0.77	-1.51	-0.25	0.37	1.06	0
2008	3	87	1.78	-0.77	-0.27	0.82	1.51	1.43
2008	4	88	0.26	0.08	-0.09	-0.18	0.72	0.55
2008	5	89	1.65	1.29	0.19	0.59	0.45	2.08
2008	6	90	2.27	2.87	2.22	2.48	2.88	3.32
2008	7	91	1.44	1.47	1.56	1.12	1.67	1.23
2008	8	92	0.15	0.05	0.93	-0.13	0.89	0.52
2008	9	93	1.59	0.19	1.09	1.22	0.43	1.18
2008	10	94	0.24	0.78	1.71	1.39	0.96	1.03
2008	11	95	-0.5	-0.29	0.66	0.49	-0.15	-1.27
2008	12	96	0.33	0.2	-0.61	-0.03	-0.41	0.2
2009	1	97	0.97	-0.2	-0.19	-0.12	-0.53	-0.44
2009	2	98	1.15	0.98	-0.55	-0.03	0.21	1.62
2009	3	99	-0.38	0.83	0.09	0.45	0.35	0.31
2009	4	100	-0.26	-1.17	0.06	-0.19	0.13	0.25
2009	5	101	0.09	0.42	-0.71	0.17	0.07	-0.08
2009	6	102	0.68	-0.07	-0.24	0.36	0.1	0.24
2009	7	103	1.29	0.08	0.21	0.26	1.17	-0.18
2009	8	104	0.76	0.12	0.06	0.54	0.66	0.78
2009	9	105	1.43	0.75	1.01	0.96	0.7	1.2
2009	10	106	-0.49	0.7	0.72	0.65	0.2	0.12
2009	11	107	-1.04	0.82	0.58	0.49	0.17	-0.09
2009	12	108	0.66	-0.43	0.34	0.26	0.31	0.26
2010	1	109	1.23	0.41	0.86	0.59	1.07	0.6
2010	2	110	0.6	0.96	0.24	0.13	0.83	0.76

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2010	3	111	0.66	0.24	0.23	0.76	0.62	0.7
2010	4	112	0.11	-0.19	0.3	1.09	0.26	0.18
2010	5	113	-0.28	1.26	0.62	1.05	0.12	0.13
2010	6	114	0.21	0.94	1.28	0.7	0.38	0.43
2010	7	115	2.89	1.6	2.33	1.89	2.78	1.98
2010	8	116	0.85	0.39	0.29	0.35	0.92	0.42
2010	9	117	0.95	0.65	0.99	0.6	0.39	0.84
2010	10	118	-0.15	1.01	-0.59	-0.27	-0.89	-0.5
2010	11	119	0.29	0.68	1.4	0.65	-0.04	0.79
2010	12	120	0.9	1.2	1.2	1.17	0.72	0.46
2011	1	121	1.04	1.21	0.29	-0.34	1.59	2.45
2011	2	122	1.1	-0.22	0.02	0.8	0.45	0.02
2011	3	123	-0.71	-0.27	-0.26	0.01	0.32	0.29
2011	4	124	0.17	-0.96	0.05	-0.23	0.45	0.38
2011	5	125	-0.58	0.03	0.48	0.51	0.3	-0.28
2011	6	126	0.8	1.13	0.82	0.49	1.39	1.09
2011	7	127	0.62	0.57	0.56	0.03	1.79	0.44
2011	8	128	1.78	0.58	1.48	1.53	0.26	1.38
2011	9	129	0.88	0.48	1.33	0.17	-0.07	0.52
2011	10	130	-1.66	-0.03	-0.81	-0.6	-0.15	-0.75
2011	11	131	0.26	0.16	0.13	0.47	-0.3	-0.03
2011	12	132	1.15	0.87	1.07	1.07	0.26	0.57
2012	1	133	0.94	1.96	2.53	2.92	1.94	1.33
2012	2	134	1.7	0.16	-0.21	-0.31	-0.09	0.4
2012	3	135	-0.44	0.46	-0.06	-0.14	0.25	0.38
2012	4	136	0.39	0.1	-0.28	-0.01	0.53	-0.25
2012	5	137	0.93	-0.48	0.25	-0.29	0.04	-0.26
2012	6	138	0.13	0.65	0.72	0.59	0.25	0.62
2012	7	139	1.43	0.41	1.06	0.87	1.48	0.58
2012	8	140	1.33	0.25	0.81	0.7	1.84	2.29
2012	9	141	-0.43	-0.05	-0.33	-0.2	-0.51	-0.56
2012	10	142	-1.55	-0.05	-0.08	-0.03	-0.36	-0.58
2012	11	143	0.96	0.23	0.57	0.91	-0.08	0.37
2012	12	144	1.08	0.98	1.61	0.85	0.96	0.42
2013	1	145	0.01	2.91	1.63	1.14	1.09	2.09
2013	2	146	1.04	-0.01	-0.1	0.43	0.54	0.68
2013	3	147	1.02	0.54	0.44	0.19	0.87	0.12
2013	4	148	0.29	0.16	0.12	0.04	0.11	0.21

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2013	5	149	1.4	-0.8	-0.26	-0.64	0.16	-0.44
2013	6	150	0.22	1.15	0.74	0.41	0.74	1.31
2013	7	151	3.36	2.66	2.09	2.24	3.75	4.1
2013	8	152	1.47	1.41	1.37	1.99	1.3	2.22
2013	9	153	-0.75	-1.48	-1.3	-0.6	-1.33	-0.67
2013	10	154	0.73	-0.33	-0.25	-0.22	0.12	0.04
2013	11	155	-0.85	-0.13	0.38	0.62	-0.34	0.11
2013	12	156	1.23	1.03	1.47	1.23	1.31	0.24
2014	1	157	0.04	1.19	1.21	0.64	1.32	1.37
2014	2	158	2.73	0.75	-0.57	-0.28	-0.18	-0.32
2014	3	159	-0.78	-0.3	0.12	-0.36	-0.1	0.17
2014	4	160	0.08	0.04	0.62	0.55	0.79	0.01
2014	5	161	0.72	0.38	0.86	1.07	0.32	0.15
2014	6	162	0.9	1.03	0.91	0.79	0.49	0.24
2014	7	163	1.49	0.51	0.22	0.69	0.62	0.66
2014	8	164	-0.03	-0.06	-0.36	0.02	0.59	-0.01
2014	9	165	0.13	0.37	0.51	0.18	0.51	0.04
2014	10	166	-0.42	0.41	0.33	0.56	-0.48	0.6
2014	11	167	1.41	1.33	0.92	1.47	1.03	1.15
2014	12	168	2.82	2.01	1.69	1.63	2.31	2.52
2015	1	169	1.19	0.61	0.79	0.16	1.69	0.59
2015	2	170	0.43	-0.7	-0.7	0.06	0.72	-0.17
2015	3	171	0.19	0.27	-0.25	-0.34	-0.71	-0.24
2015	4	172	0.55	0.52	0.08	0.38	-0.32	0.24
2015	5	173	0.59	0.44	1.05	0.31	0.75	0.13
2015	6	174	0.64	0.91	0.96	0.8	1.23	0.8
2015	7	175	2.56	0.89	0.94	1.14	2.04	1.03
2015	8	176	-1	0.42	-0.67	0.06	-0.23	0.11
2015	9	177	0.16	0.04	-0.34	0.53	-0.13	-0.06
2015	10	178	-0.07	0.34	0.55	0.16	0.87	0.18
2015	11	179	-0.14	0.51	0.85	0.41	-0.54	0.26
2015	12	180	0.96	1.34	0.88	1.27	0.76	1.3

Lampiran 2. Data Curah Hujan Pada Enam Lokasi di Kalimantan

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2001	1	1	306	416	354	364	443.7	156.4
2001	2	2	253	285	384	267	300.9	307.3
2001	3	3	269	285	278	375	204.1	235.7
2001	4	4	357	776	270	148	571.6	157.6
2001	5	5	161	577	45	124	138.7	187.1
2001	6	6	223	317	298	93	96.3	109.7
2001	7	7	302	133	18	80	219.2	98.4
2001	8	8	155	0	57	10	89.7	26.4
2001	9	9	155	308	163	90	171.7	167.7
2001	10	10	345	552	251	218	66.1	134.1
2001	11	11	469	106	336	208	242.8	220.8
2001	12	12	184	295	207	364	314.1	112.1
2002	1	13	446.9	337	344	147	299.4	156.9
2002	2	14	76.5	384	134	269	133.7	128.2
2002	3	15	285.9	431	309	325	293.5	284.4
2002	4	16	339.4	491	247	361	148	190.9
2002	5	17	141.5	126	64	204	145	130
2002	6	18	136	311	197	285	238.6	180.6
2002	7	19	153.7	2	11	9	132.8	76.4
2002	8	20	164	26	10	0	281.6	32.7
2002	9	21	107.6	0	3	95	99.2	73.5
2002	10	22	210.7	161	64	236	42.1	140.1
2002	11	23	362.3	379	360	331	320	101.7
2002	12	24	297.4	445	322	365	278.3	181.5
2003	1	25	394	439	266	380	325.4	253.3
2003	2	26	297	423	172	257	132.2	257.9
2003	3	27	202	314	538	274	401.8	471.3
2003	4	28	614	442	407	230	250	135.7
2003	5	29	147	1778	229	122	441.2	244.9
2003	6	30	134	142	113	140	360.7	79.8
2003	7	31	281	65	9	66	229	44.5
2003	8	32	207	75	90	62	404.7	95.6
2003	9	33	132	81	65	79	224.4	273.8
2003	10	34	302	188	265	185	117.7	220.9
2003	11	35	334	476	333	276	180.1	203.7
2003	12	36	257	600	176	334	140.6	217.9

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2004	1	37	384	671	365	365	236.5	339.7
2004	2	38	16	1086	266	294	320	224.3
2004	3	39	216	511	283	271	424	401.6
2004	4	40	312	151	351	240	167.4	384.8
2004	5	41	386	120	317	115	197.7	367.6
2004	6	42	113	17	72	127	107.6	55.4
2004	7	43	249	78	228	91	215.1	100.1
2004	8	44	19	0	8	67	10.8	0
2004	9	45	309	79	69	86	130.9	171.7
2004	10	46	182	21	26	165	115.6	2.1
2004	11	47	351	328	581	219	251	280.9
2004	12	48	422	606	522	346	281.7	175.5
2005	1	49	290.5	13	314.5	371	171.9	200.7
2005	2	50	163	19	455.5	286	232.2	38.9
2005	3	51	221.6	19	310.7	255	270.7	225.4
2005	4	52	256	14	119.6	235	152.5	336.3
2005	5	53	409.8	17	147.2	121	258.7	199.4
2005	6	54	167.8	11	123.2	119	102.4	98.6
2005	7	55	151.7	11	87.1	83	211.6	271
2005	8	56	161.7	7	29.8	72	151.3	145.4
2005	9	57	309	6	164.9	93	35.9	94.1
2005	10	58	538.3	16	371.2	147	279.5	339.6
2005	11	59	351	19	222.7	291	270.7	304.5
2005	12	60	422	17	273.4	385	247	296.5
2006	1	61	184	14	177.5	371	229.1	227.8
2006	2	62	345	16	252.8	286	375	206.8
2006	3	63	137	17	312	255	165.8	214.6
2006	4	64	260	20	337.2	235	385.3	206.6
2006	5	65	228	14	131.9	121	244.5	306.5
2006	6	66	220	14	188.7	119	610.2	184.6
2006	7	67	41	5	90.9	83	80.9	24.4
2006	8	68	57	2	6.4	72	93.9	97.5
2006	9	69	171	3	27.2	93	253.6	107.7
2006	10	70	130	1	12.6	147	12	69.6
2006	11	71	297	11	94.3	291	122.1	190.6
2006	12	72	477	18	417	385	314.7	110
2007	1	73	281	311	323.6	459.6	275.7	306.8
2007	2	74	92	409	214.3	433.1	258	220.4

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2007	3	75	203	287	512.4	424.3	144.2	260.3
2007	4	76	314	508	440.9	324.1	198.8	339.7
2007	5	77	462	313	324.2	367.6	250.3	112.3
2007	6	78	438	168	286	275.8	377.9	213.4
2007	7	79	312	251	122.3	230.4	392.8	278.5
2007	8	80	142	146	154.1	141.9	198.8	132.9
2007	9	81	215	137	93.4	26	335.8	182.6
2007	10	82	591	263	512.4	338.5	97.7	181.4
2007	11	83	250	198	253	252	88	84.6
2007	12	84	366	250	376.8	434.5	205.1	141.2
2008	1	85	124.5	130	323.6	345	340.4	142.6
2008	2	86	106.4	167	214.3	275.7	223.6	194.4
2008	3	87	209.8	392	512.4	242.5	323.8	211.4
2008	4	88	321.4	361	440.9	258.6	256.3	259.4
2008	5	89	233.8	291	324.2	155.4	259.4	50.9
2008	6	90	101.8	166	286	163.9	454.3	205.2
2008	7	91	317.1	183	122.3	256.1	705.1	333.3
2008	8	92	279	212	154.1	172.3	308.8	148.7
2008	9	93	200.5	296	93.4	142.3	291.7	153.4
2008	10	94	565.2	271	512.4	310.1	238.1	207.6
2008	11	95	246.2	293	253	406.5	346.1	501
2008	12	96	426.1	279	376.8	434.1	324.7	349.7
2009	1	97	262	238	251	402.2	240.3	164
2009	2	98	66.9	174	380.9	322.9	210.7	196.2
2009	3	99	291	421	512	264.7	290.5	278.9
2009	4	100	372.2	319	272.1	208.2	161.3	309.1
2009	5	101	182.5	258	276.6	201.4	103	186.4
2009	6	102	135.4	71	41	121	157	41.2
2009	7	103	121.9	78	27.1	256.1	259.6	157.3
2009	8	104	299.5	21	11.8	56	93.1	122.7
2009	9	105	189.5	46	30.9	50	64.6	98.5
2009	10	106	381.9	209	203.1	190.9	144.7	232.3
2009	11	107	688	412	217.6	384.3	178.6	165.3
2009	12	108	309.2	416	555.6	356.4	338	211.3
2010	1	109	233.5	250	313.2	407.2	218.8	148.2
2010	2	110	274.1	248	353.4	233.1	248	161.5
2010	3	111	286.1	436	368.4	357.5	210.2	157.2
2010	4	112	210.4	302	405	396.2	342.9	163.7

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2010	5	113	320.8	312	346.1	197.4	262.2	222.6
2010	6	114	381.2	295	291.4	301.8	337.5	320.1
2010	7	115	320	385	318.8	95.5	275	258.7
2010	8	116	173.9	277	302.9	132.4	76.7	144.1
2010	9	117	423.7	261	429.3	243.4	182	202
2010	10	118	242.1	258	729.1	371.4	369.7	235.1
2010	11	119	449.9	258	328.6	418.1	241.5	207.1
2010	12	120	202.6	231	322.3	414.4	222.9	224.2
2011	1	121	355.3	232	317.3	494.9	175.6	332.2
2011	2	122	229.1	259	280.3	427.9	224.4	320.3
2011	3	123	151.7	159	511.1	378.7	253.6	368.4
2011	4	124	241	303	356.2	366	255	331.6
2011	5	125	204	280	376.6	278.4	232.1	388.6
2011	6	126	173.5	42.7	36.1	177.5	424.4	95.2
2011	7	127	144.1	104.5	122.9	55	122.6	238.1
2011	8	128	193.1	54	26.6	42	128.3	124.2
2011	9	129	147.9	73	176.5	218.9	355	131.9
2011	10	130	533.2	169.2	414.9	171.5	198.8	218.4
2011	11	131	292.8	290.1	427.2	371.5	247.8	196.7
2011	12	132	463.5	380.8	388.9	351.9	330.8	244.3
2012	1	133	147.8	384	434.6	458	252.8	329.6
2012	2	134	256.9	344.1	255.9	361.8	290	205.6
2012	3	135	209.3	125	339.5	308.3	244.2	257.4
2012	4	136	358.5	369	269.1	246.5	178.6	370.6
2012	5	137	221.5	139.1	229.3	129.9	476.1	127.7
2012	6	138	93.6	44	272.8	9.2	196.6	171.6
2012	7	139	322.8	52.5	244.3	133.2	337.7	146.7
2012	8	140	73	8.5	75	35.8	161.6	140
2012	9	141	54	25	72.3	50	72.2	110.4
2012	10	142	441	76	250.7	29	203	116.2
2012	11	143	401	99	243.5	31	227.5	228.4
2012	12	144	502	0	475.5	479.5	176	220.3
2013	1	145	150	154	257.2	490	190	175.7
2013	2	146	373	150.5	503.4	358	515.9	209.1
2013	3	147	262	156.5	253.4	249	36.8	284.3
2013	4	148	343	246	561.1	307	205	337.2
2013	5	149	437	235.5	248.5	415	259.4	233.5
2013	6	150	128	38	135.8	75	191.2	161

Tahun	Bulan	t	Pontianak	Sampit	Palangka raya	Banjarmasin	Balikpapan	Samarinda
2013	7	151	274	250.5	242.9	186	205.3	145.2
2013	8	152	208	38	146	144	328.7	90.2
2013	9	153	231	123	159	98	165.1	256
2013	10	154	232	2	121.2	94	146.6	223.1
2013	11	155	299	143	319.1	285	442.2	363.1
2013	12	156	445	131	396.1	505	220.4	275.7
2014	1	157	93.8	135.5	138.3	320	199.6	272.6
2014	2	158	109.4	43	149.4	229	98	216.2
2014	3	159	230.3	172	294.8	256	256.1	317.7
2014	4	160	224.6	201.5	575.9	109	271.5	147.6
2014	5	161	336.1	248.5	223.3	280	146.8	297.7
2014	6	162	254.1	269	207.7	118	246.3	197
2014	7	163	113.5	20	41	37	242.2	49.5
2014	8	164	290.4	30	62.3	85	187.3	81.3
2014	9	165	92	16	121	9	21.2	83
2014	10	166	305	46	123	15	164.3	11.3
2014	11	167	430.3	348.5	312.3	196	145.8	300.6
2014	12	168	275.6	215	604.7	361	421.9	447.8
2015	1	169	278.4	249.1	286	457	267.3	344.8
2015	2	170	228	332.2	466.6	393	329.1	193
2015	3	171	205	233.6	434.9	189	180.8	197.8
2015	4	172	204	529	297.7	285	217.6	343.7
2015	5	173	207	227.2	326.1	175	198.7	213.5
2015	6	174	326.7	97.8	135	106	511.4	259.2
2015	7	175	187.1	8.9	31.9	44	114.5	162.7
2015	8	176	77.2	30.1	23	19	69.1	57.6
2015	9	177	52.3	0	0	0	0	0
2015	10	178	217.7	43.7	60	29	37.5	73.2
2015	11	179	412.6	301.9	430.8	108	111.1	60.9
2015	12	180	279.9	267.6	262.7	503	112.7	191.4

Lampiran 3. Macro SAS Untuk Pengolahan ARIMA

```
data work.arimainf;
   infile"D:\SYNTAX\arima_kal.txt" dlm='09'x;
   input y1 y2 y3 y4 y5 y6;

/*------------------------------ PONTIANAK ------------------------------*/

/*------------- Tanpa Deteksi Outlier -------------------*/

 proc arima data=work.arimainf;
   identify var=y1(12) noprint;
   run;

   estimate q=(12) noconstant;
   run;

   forecast lead=12 out=ramalan;
   run;

   outlier maxnum=5 alpha=0.05;
   run;

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

 proc export data=work.ramalan
   outfile='D:\OUTPUT\ARIMA dan OUTLIER.xls'
   dbms=excel
   replace;
   sheet="y1q12_TOL";
   run;



/*------------- Dengan Deteksi Outlier -------------------*/

 data work.arimainf;
   set work.arimainf;
     if _n_=130 then a130=1;
     else a130=0;
     if _n_=142 then a142=1;
     else a142=0;
     if _n_=58 then a58=1;
     else a58=0;
     if _n_=155 then a155=1;
     else a155=0;
     if _n_=107 then a107=1;
     else a107=0;
```

```
proc arima data=work.arimainf;
     identify var=y1(12) crosscorr=(a130(12) a142(12) a58(12) a155(12) a107(12)) nlag=12
    noprint;
     run;


  estimate q=(12) noconstant input=(a130 a142 a58 a155 a107) plot;
  run;

  forecast lead=12 out=ramalan;
  run;

  outlier maxnum=5 alpha=0.05;
  run;

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

proc export data=work.ramalan
  outfile='D:\OUTPUT\ARIMA dan OUTLIER.xls'
  dbms=excel
  replace;
  sheet="y1q12_OL";
  run;
```

Lampiran 4. Macro SAS Untuk Pengolahan ARIMA dengan Variasi Kalender Bulanan

```
 data work.arima_cv;
   infile"D:\SYNTAX\cvbulanan_kal.txt" dlm='09'x;
   input y1 y2 y3 y4 y5 y6 dt_1 dt;


/*----------------- Variasi Kalender Bulanan Pontianak ----------------*/

/*------------------------- Tanpa Deteksi Outlier -------------------------*/

 proc arima data=work.arima_cv;
   identify var=y1(12) crosscorr=(dt_1(12) dt(12)) noprint;
   run;

   estimate 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;
   var residual;
   run;

 proc export data=work.ramalan
   outfile='D:\OUTPUT\VKbulanan_KAL.xls'
   dbms=excel
   replace;
   sheet="TDO_y1q12";
   run;


/*------------------------- Dengan Deteksi Outlier -------------------------*/

 data work.arima_cv;
   set work.arima_cv;
     if _n_=142 then a142=1;
     else a142=0;
     if _n_=154 then a130=1;
     else a154=0;
     if _n_=58 then a58=1;
     else a58=0;
     if _n_=107 then a107=1;
     else a107=0;
```

```
proc arima data=work.arima_cv;
  identify var=y1(12) crosscorr=(dt_1(12) dt(12) a130(12) a142(12) a58(12) a107(12)) nlag=12
  noprint;
  run;


  estimate q=(12) noconstant input=(dt_1 dt a130 a142 a58 a107) plot;
  run;

  forecast lead=12 out=ramalan;
  run;

  outlier maxnum=5 alpha=0.05;
  run;

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

proc export data=work.ramalan
  outfile='D:\OUTPUT\VKbulanan_KAL.xls'
  dbms=excel
  replace;
  sheet="DO_y1q12";
  run;
```

Lampiran 5. Macro SAS untuk Pengolahan ARIMA dengan Variasi Kalender Mingguan

```
data work.arima_cv;
   infile"D:\SYNTAX\cvmingguan_kal.txt" dlm='09'x;
   input y1 y2 y3 y4 y5 y6 d1t_1 d2t_1 d3t_1 d4t_1 d1t d2t d3t d4t;

/*----------------- Variasi Kalender Mingguan Pontianak ----------------*/

/*---------------------------Tanpa Deteksi Outlier --------------------------*/

 proc arima data=work.arima_cv;
   identify var=y1(12) crosscorr=(d1t_1(12) d2t_1(12) d3t_1(12) d4t_1(12) d1t(12) d2t(12)
     d3t(12) d4t(12)) noprint;
   run;

   estimate 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;
   var residual;
   run;

 proc export data=work.ramalan
   outfile='D:\OUTPUT\VKmingguan_KAL.xls'
   dbms=excel
   replace;
   sheet="TDO_y1q12";
   run;

/*------------- Tanpa Deteksi Outlier (Hanya Parameter Signifikan  -------------*/

 proc arima data=work.arima_cv;
   identify var=y1(12) crosscorr=(d1t_1(12) d2t_1(12) d3t_1(12) d4t_1(12) d1t(12) d2t(12)
     d3t(12) d4t(12)) noprint;
   run;

   estimate q=(12) noconstant input=(d1t_1 d2t_1 d3t_1 d2t d3t d4t) plot;
   run;

   forecast lead=12 out=ramalan;
   run;

   outlier maxnum=5 alpha=0.05;
   run;
```

```
 proc univariate data=ramalan normal;
   var residual;
   run;

 proc export data=work.ramalan
   outfile='D:\OUTPUT\VKmingguan_KAL.xls'
   dbms=excel
   replace;
   sheet="TDO_y1q12_SIGN";
   run;

/*------------- Dengan Deteksi Outlier dan Parameter yang Signifikan -------------*/

 data work.arima_cv;
   set work.arima_cv;
     if _n_=130 then a130=1;
     else a130=0;
     if _n_=142 then a142=1;
     else a142=0;
     if _n_=58 then a58=1;
     else a58=0;
     if _n_=167 then a167=1;
     else a167=0;
     if _n_=107 then a107=1;
     else a107=0;

 proc arima data=work.arima_cv;
  identify var=y1(12) crosscorr=(d1t_1(12) d2t_1(12) d3t_1(12) d2t(12) d3t(12) d4t(12) a130(12)
  a142(12) a58(12)) nlag=12 noprint;
  run;

  estimate q=(12) noconstant input=(d1t_1 d2t_1 d3t_1 d2t d3t d4t a130 a142 a58) plot;
  run;

  forecast lead=12 out=ramalan;
  run;

  outlier maxnum=5 alpha=0.05;
  run;

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

 proc export data=work.ramalan
  outfile='D:\OUTPUT\VKmingguan_KAL.xls'
  dbms=excel
  replace;
  sheet="DO_y1q12";
  run;
```

Lampiran 6. Macro SAS untuk Pengolahan ARIMA dengan Fungsi Transfer

```
data ft_ptk;
   input y1 ch1;
datalines;

1.105256831       17.493
1.261297871       15.906
.
.
.
1.226712291       20.744
1.572773928       16.601
;


/*--------------------------- Pontianak ---------------------------*/

/*------------------ Tanpa Deteksi Outlier ---------------------*/

 proc arima data=ft_ptk;
 /*--------- Look at the input process --------------------------*/
    identify var=ch1(12) nlag=24 noprint;
   run;

 /*--------- Model Untuk Variabel Input (Curah Hujan) ---------*/
   estimate q=(12) noconstant plot;
   run;

 /*------------- Crosscorrelation of prewhitened series ------------*/
   identify var=y1(12) crosscorr=(ch1(12)) nlag=24;
   run;

 /*------------- Estimate full model (Model Fungsi Transfer) ------------*/
   estimate q=(12) input=( 5 $ (0) / (0) ch1 ) noconstant plot;
   run;

   forecast lead=12 out=ramalan;
   run;

   outlier maxnum=5 alpha=0.05;
   run;

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

 proc export data=ramalan
   outfile='D:\OUTPUT\FT_KAL.xls'
   dbms=excel replace;
   sheet="y1q12ft_TOL";
   run;
```

```
/*------------------ Dengan Deteksi Outlier ---------------------*/

 data ft_ptk;
    set ft_ptk;
      if _n_=130 then a130=1;
      else a130=0;
      if _n_=142 then a142=1;
      else a142=0;
      if _n_=58 then a58=1;
      else a58=0;
      if _n_=155 then a155=1;
      else a155=0;

 proc arima data=ft_ptk;
   /*------look at the  input prosess-------------*/
   identify var=y1(12) crosscorr=(ch1(12) a130(12) a142(12) a58(12) a155(12)) nlag=12 noprint;
   run;

   estimate q=(12) input=( 5 $ (0) / (0) ch1 a130 a142 a58 a155) noconstant plot;
   run;

   forecast lead=12 out=ramalan;
   run;

   outlier maxnum=5 alpha=0.05;
   run;

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

 proc export data=ramalan
   outfile='D:\OUTPUT\FT_KAL.xls'
   dbms=excel replace;
   sheet="y1q12ft_OL";
```

Lampiran 7. Macro SAS Untuk Pengolahan GSTAR

```
data work.gstarlevel2;
  infile"D:\GSTAR\gstar_nipks.txt" dlm='09'x;
  input u1 u2 u3 u4 u5 u6 u11 u21 u31 u41 u51 u61 wu11 wu21 wu31 wu41 wu51 wu61 u112
u212 u312 u412 u512 u612 wu112 wu212 wu312 wu412 wu512 wu612;



/*-------------- Penentuan Orde GSTAR -----------------*/
proc varmax data=res_arimax;
   model u1 u2 u3 u4 u5 u6 /p=1 lagmax=14 minic=(type=aicc p=14 q=2) dftest noint printall;
   output lead=12 out=hasil;
   run;



/*------------ GSTAR dengan SysLin -----------------------*/

proc syslin data=gstarlevel2 sur out=hasil;
  u1t: model u1=u11 wu11 u112 wu112 / noint;
       output p=uhat1 r=uresid1;
  u2t: model u2=u21 wu21 u212 wu212 / noint;
       output p=uhat2 r=uresid2;
  u3t: model u3=u31 wu31 u312 wu312 / noint;
       output p=uhat3 r=uresid3;
  u4t: model u4=u41 wu41 u412 wu412 / noint;
       output p=uhat4 r=uresid4;
  u5t: model u5=u51 wu51 u512 wu512 / noint;
       output p=uhat5 r=uresid5;
  u6t: model u6=u61 wu61 u612 wu612 / noint;
       output p=uhat6 r=uresid6;
  run;


/*------------ Hanya untuk parameter Signifikan -----------------------*/

proc syslin data=gstarlevel2 sur out=hasil;
  u1t: model u1=u11 u112 / noint;
       output p=uhat1 r=uresid1;
  u2t: model u2=wu21 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;
  u6t: model u6=u612 / noint;
       output p=uhat6 r=uresid6;
  run;
```

Lampiran 8. Plot ACF dan PACF Data Inflasi (Tanpa Transformasi)

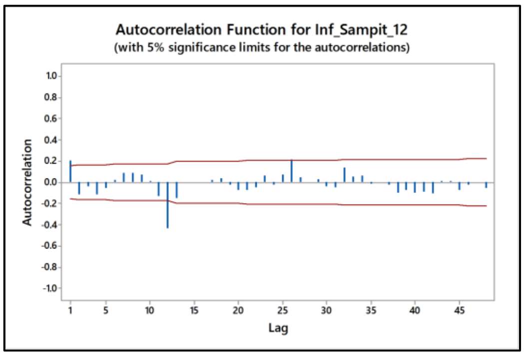

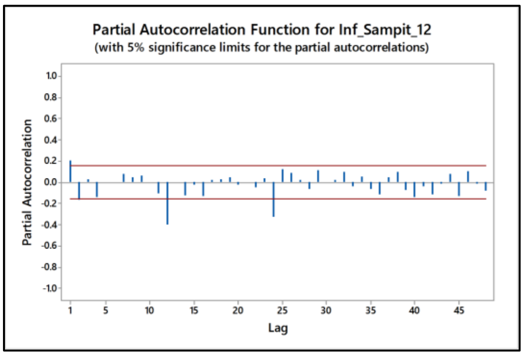

a. Plot ACF dan PACF Inflasi Sampit (Tanpa Transformasi)

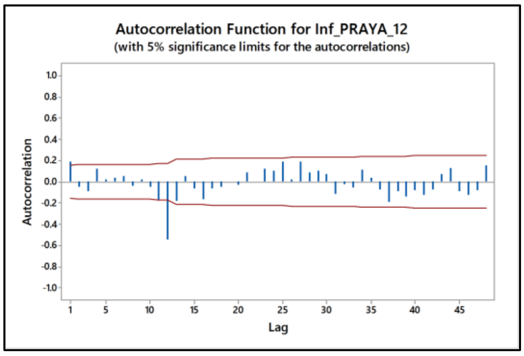

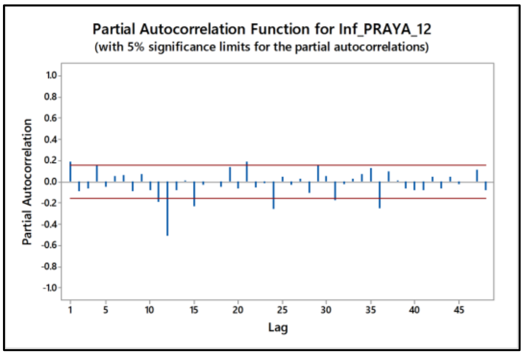

b. Plot ACF dan PACF Inflasi Palangkaraya (Tanpa Transformasi)

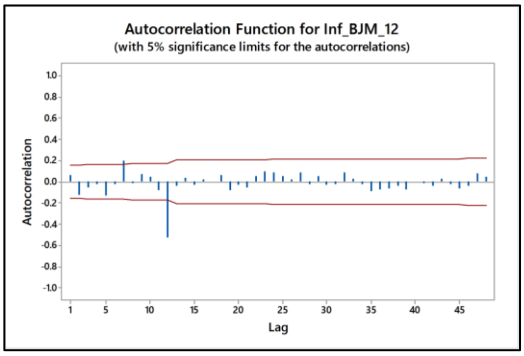

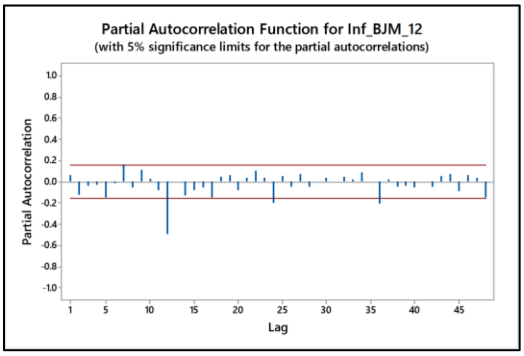

c. Plot ACF dan PACF Inflasi Banjarmasin (Tanpa Transformasi)

Lanjutan Lampiran 8

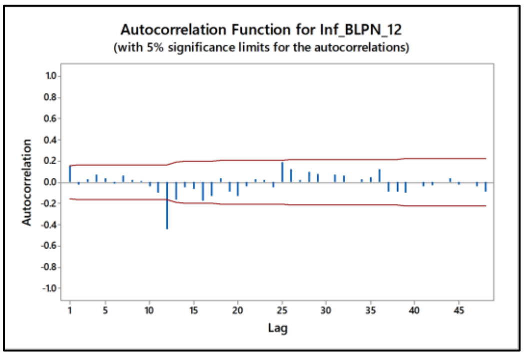

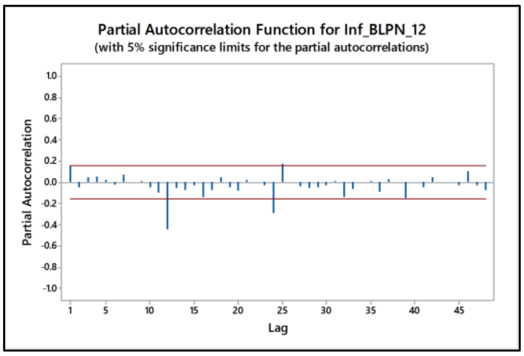

d. Plot ACF dan PACF Inflasi Balikpapan (Tanpa Transformasi)

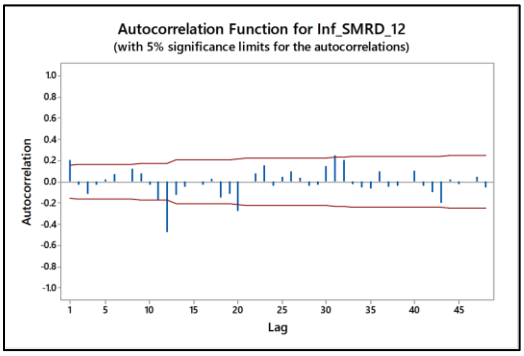

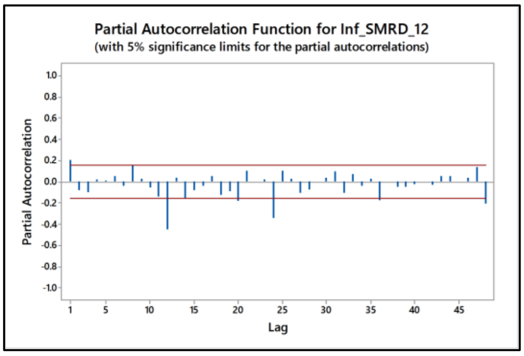

e. Plot ACF dan PACF Inflasi Samarinda (Tanpa Transformasi)

Lampiran 9. Plot ACF dan PACF Data Inflasi (Setelah Transformasi)

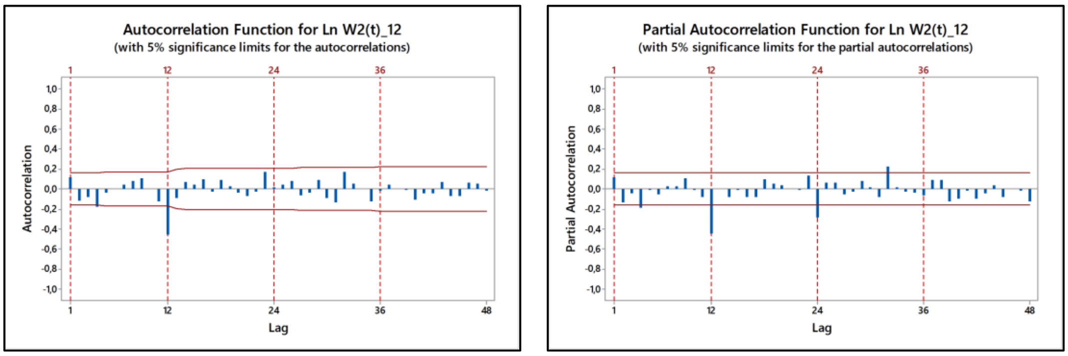

a. Plot ACF dan PACF Inflasi Sampit

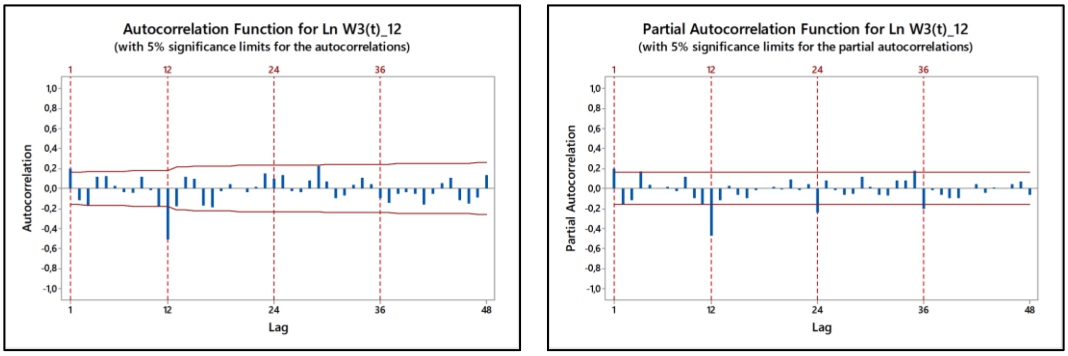

b. Plot ACF dan PACF Inflasi Palangkaraya

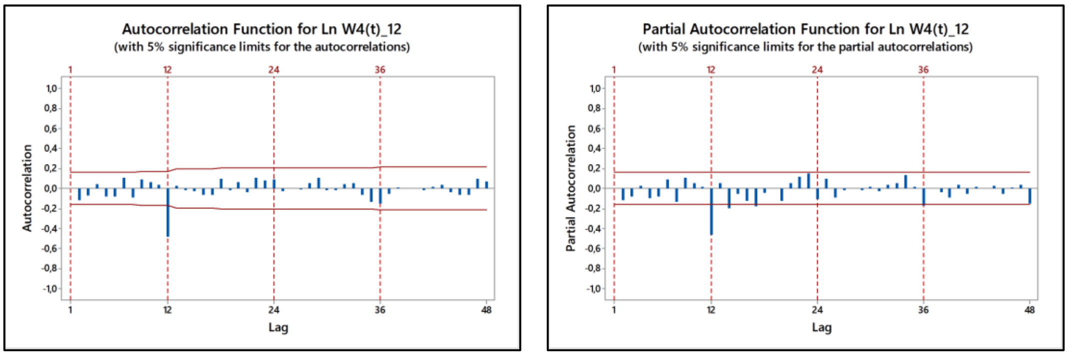

c. Plot ACF dan PACF Inflasi Banjarmasin

Lanjutan Lampiran 9

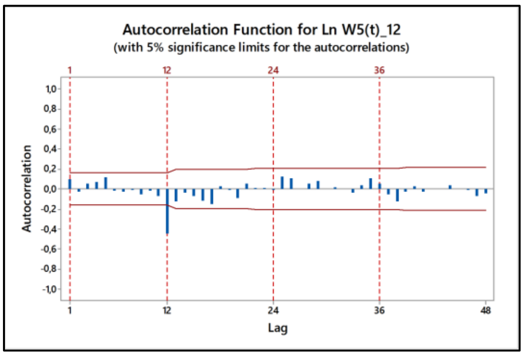

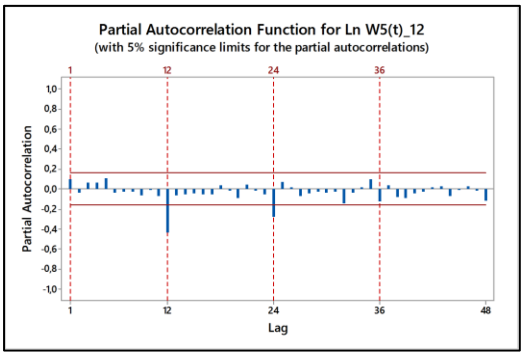

d. Plot ACF dan PACF Inflasi Balikpapan

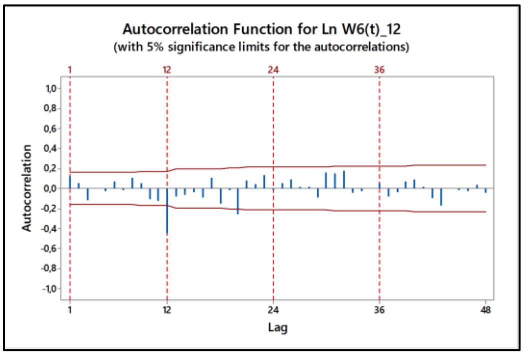

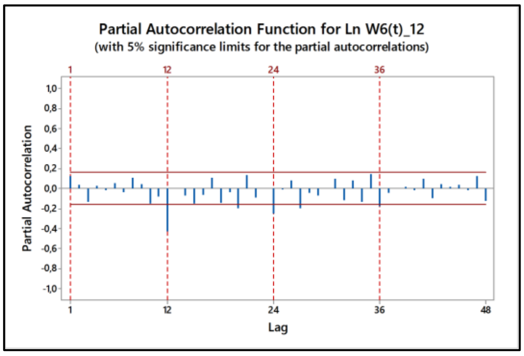

e. Plot ACF dan PACF Inflasi Samarinda

Lampiran 10. Plot ACF dan PACF Deret Input (Curah Hujan yang Sudah Stasioner)

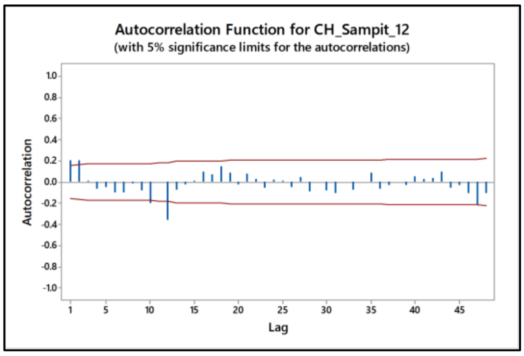

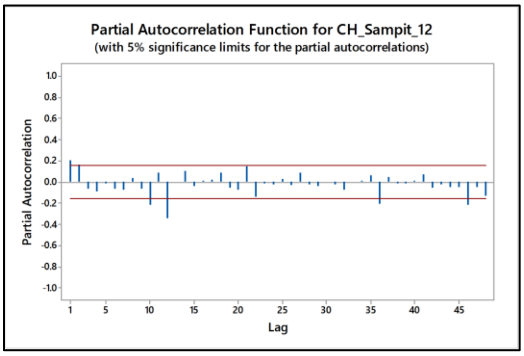

a. Plot ACF dan PACF Deret Input (Curah Hujan) Sampit

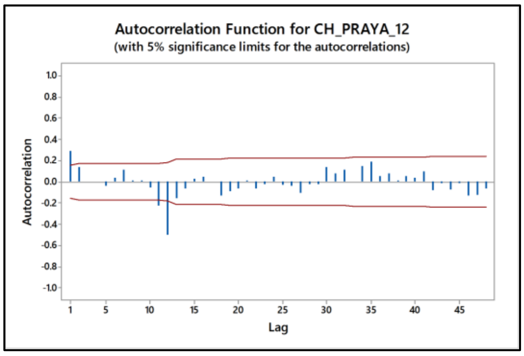

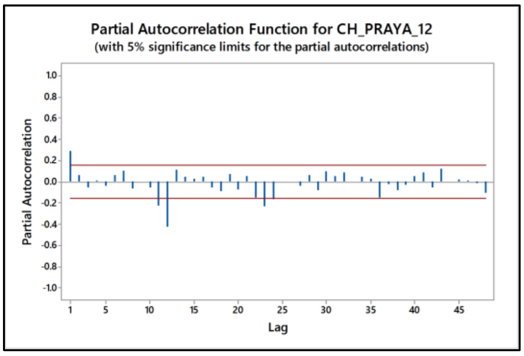

b. Plot ACF dan PACF Deret Input (Curah Hujan) Palangkaraya

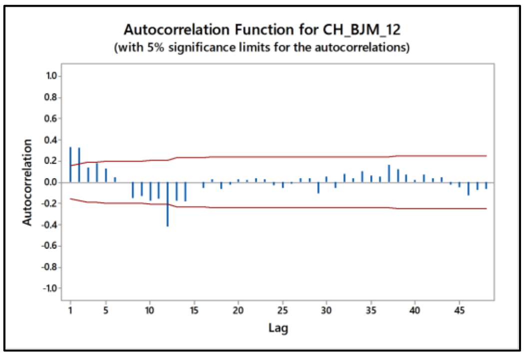

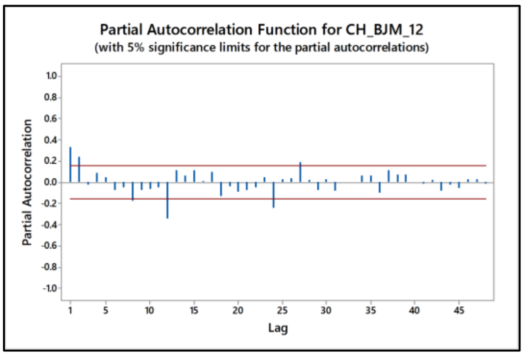

c. Plot ACF dan PACF Deret Input (Curah Hujan) Banjarmasin

Lanjutan Lampiran 10.

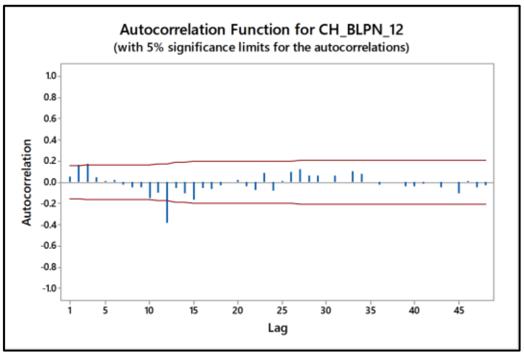

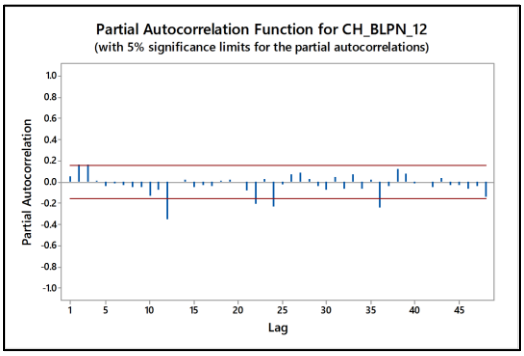

d. Plot ACF dan PACF Deret Input (Curah Hujan) Balikpapan

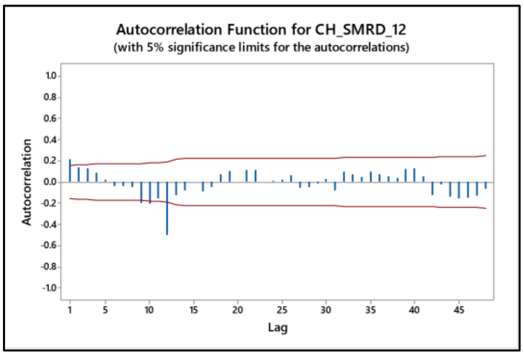

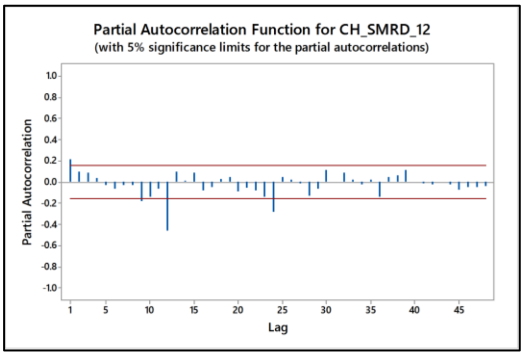

e. Plot ACF dan PACF Deret Input (Curah Hujan) Samarinda

Lampiran 11. Plot CCF antara Variabel Inflasi dan Deret Input (Curah Hujan)

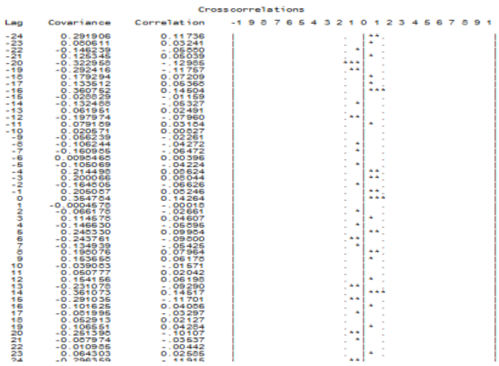

a. Sampit

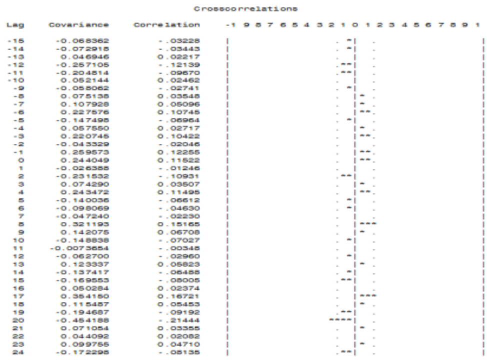

b. Palangkaraya

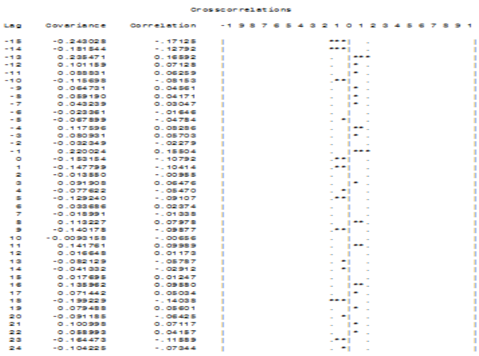

c. Banjarmasin

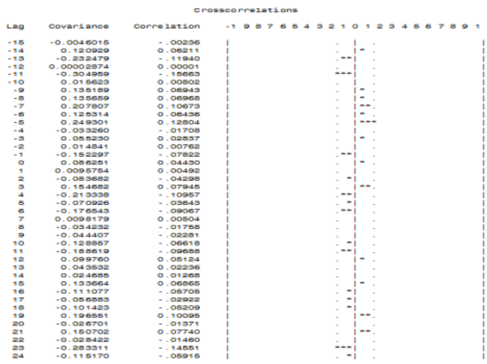

d. Balikpapan

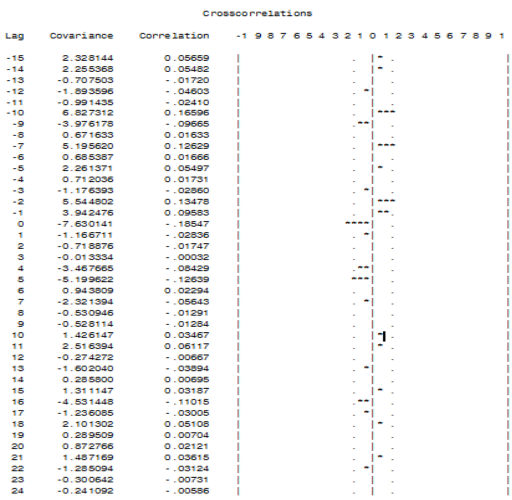

e. Samarinda

Lampiran 12. Plot ACF dan PACF dari Komponen *Error* (n_t) Hasil Respons Impuls Pada Pembentukan Fungsi Transfer

Autocorrelation Plot of Residuals

Lag	Covariance	Correlation	Std Error
0	0.368135	1.00000	0
1	0.030373	0.08251	0.083918
2	-0.050204	-.13637	0.084487
3	-0.019030	-.05169	0.086024
4	-0.066549	-.18077	0.086242
5	-0.013941	-.03787	0.088871
6	-0.0044163	-.01200	0.088984
7	0.022482	0.06107	0.088995
8	0.029424	0.07993	0.089290
9	0.031079	0.08442	0.089793
10	0.0030502	0.00829	0.090350
11	-0.047851	-.12998	0.090355
12	-0.181019	-.49172	0.091663
13	-0.044189	-.12003	0.108662
14	0.021255	0.05774	0.109592
15	0.022144	0.06015	0.109806
16	0.048024	0.13045	0.110038
17	-0.012260	-.03330	0.111122
18	0.027893	0.07577	0.111192
19	0.0034816	0.00946	0.111555
20	-0.021126	-.05739	0.111561
21	-0.032881	-.08932	0.111768
22	-0.011994	-.03258	0.112270
23	0.076087	0.20668	0.112336
24	0.026198	0.07116	0.114983

Partial Autocorrelations

Lag	Correlation
1	0.08251
2	-0.14416
3	-0.02768
4	-0.19872
5	-0.01738
6	-0.07044
7	0.04958
8	0.02206
9	0.08830
10	-0.00041
11	-0.08805
12	-0.49301
13	-0.09296
14	-0.14267
15	-0.01969
16	-0.09435
17	-0.11939
18	0.03950
19	0.03535
20	0.01114
21	-0.06230
22	-0.05973
23	0.12070
24	-0.29753

a. Sampit

Autocorrelation Plot of Residuals

Lag	Covariance	Correlation	Std Error
0	0.394089	1.00000	0
1	0.084584	0.21463	0.082199
2	-0.032235	-.08180	0.085903
3	-0.050587	-.12837	0.086427
4	0.056013	0.14213	0.087706
5	0.048682	0.12353	0.089249
6	0.0095235	0.02417	0.090397
7	-0.0082886	-.02103	0.090440
8	-0.033591	-.08524	0.090473
9	0.013169	0.03342	0.091014
10	-0.016267	-.04128	0.091097
11	-0.077932	-.19775	0.091224
12	-0.200087	-.50772	0.094076
13	-0.072154	-.18309	0.111057
14	0.035979	0.09130	0.113078
15	0.030167	0.07655	0.113575
16	-0.071309	-.18095	0.113923
17	-0.081702	-.20732	0.115849
18	-0.010275	-.02607	0.118329
19	0.016458	0.04176	0.118368
20	0.0066784	0.01695	0.118468
21	0.00056374	0.00143	0.118484
22	0.014670	0.03722	0.118484
23	0.072883	0.18494	0.118563
24	0.035038	0.08891	0.120496

Partial Autocorrelations

Lag	Correlation
1	0.21463
2	-0.13404
3	-0.08506
4	0.19451
5	0.02692
6	-0.00025
7	0.03182
8	-0.10343
9	0.05879
10	-0.08949
11	-0.21589
12	-0.45535
13	-0.07936
14	0.02476
15	-0.02974
16	-0.07812
17	-0.05168
18	0.02255
19	0.00170
20	-0.06149
21	0.03230
22	-0.03395
23	0.06108
24	-0.26915

b. Palangkaraya

Autocorrelation Plot of Residuals

Lag	Covariance	Correlation	Std Error
0	0.308638	1.00000	0
1	-0.0060660	-.01965	0.080064
2	-0.034677	-.11235	0.080095
3	-0.014801	-.04796	0.081099
4	0.010024	0.03248	0.081281
5	-0.030666	-.09936	0.081364
6	-0.023532	-.07624	0.082138
7	0.034693	0.11241	0.082590
8	-0.024711	-.08007	0.083565
9	0.023702	0.07679	0.084055
10	0.018245	0.05912	0.084504
11	0.021831	0.07073	0.084769
12	-0.146297	-.47401	0.085146
13	0.014512	0.04702	0.100650
14	-0.013915	-.04508	0.100791
15	-0.014914	-.04832	0.100920
16	-0.013091	-.04241	0.101068
17	-0.013435	-.04353	0.101182
18	0.029180	0.09454	0.101302
19	-0.0062195	-.02015	0.101866
20	0.017232	0.05583	0.101892
21	-0.015388	-.04986	0.102088
22	0.034382	0.11140	0.102244
23	0.012962	0.04200	0.103019
24	0.023507	0.07616	0.103128

Partial Autocorrelations

Lag	Correlation
1	-0.01965
2	-0.11278
3	-0.05333
4	0.01757
5	-0.11125
6	-0.08088
7	0.08956
8	-0.10916
9	0.09537
10	0.04887
11	0.06239
12	-0.45955
13	0.08483
14	-0.20959
15	-0.03319
16	-0.10041
17	-0.14931
18	-0.02765
19	0.03693
20	-0.11348
21	0.04955
22	0.12296
23	0.13337
24	-0.13609

c. Banjarmasin

Lanjutan Lampiran 12.

```
                     Autocorrelation Plot of Residuals

Lag  Covariance   Correlation  -1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1    Std Error

  0    0.304922      1.00000   |                    |********************|           0
  1    0.026954      0.08840   |                  . |**.                 |    0.081111
  2   -0.011858      -.03889   |                  . *|  .                |    0.081742
  3    0.013619      0.04466   |                  . |*  .                |    0.081864
  4    0.033656      0.11038   |                  . |**.                 |    0.082024
  5    0.036850      0.12085   |                  . |**.                 |    0.082995
  6  -0.0005184      -.00170   |                  . |  .                 |    0.084145
  7   -0.011610      -.03808   |                  . *|  .                |    0.084145
  8  -0.0009122      -.00299   |                  . |  .                 |    0.084258
  9   -0.015266      -.05007   |                  . *|  .                |    0.084259
 10  -0.0060444      -.01982   |                  . |  .                 |    0.084455
 11  -0.0089003      -.02919   |                  . *|  .                |    0.084485
 12   -0.138546      -.45437   |          *********|  .                 |    0.084552
 13   -0.034859      -.11432   |                 . **|   .              |    0.099325
 14  -0.0089820      -.02946   |                 .  *|   .              |    0.100187
 15   -0.024983      -.08193   |                 . **|   .              |    0.100244
 16   -0.039155      -.12841   |                 .***|   .              |    0.100683
 17   -0.042660      -.13991   |                 .***|   .              |    0.101755
 18   0.0017334      0.00568   |                 .   |   .              |    0.103013
 19  -0.0039244      -.01287   |                 .   |   .              |    0.103015
 20   -0.032398      -.10625   |                 . **|   .              |    0.103025
 21    0.013801      0.04526   |                 .   |*  .              |    0.103744
 22    0.013639      0.04473   |                 .   |*  .              |    0.103874
 23  -0.0056171      -.01842   |                 .   |   .              |    0.104000
 24   0.0045805      0.01502   |                 .   |   .              |    0.104022
```

```
                  Partial Autocorrelations

Lag   Correlation   -1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1

  1      0.08840    |                  .  |**.                    |
  2     -0.04707    |                  . *|  .                    |
  3      0.05295    |                  .  |* .                    |
  4      0.10072    |                  .  |**.                    |
  5      0.10829    |                  .  |**.                    |
  6     -0.01423    |                  .  |  .                    |
  7     -0.03710    |                  . *|  .                    |
  8     -0.01919    |                  .  |  .                    |
  9     -0.07674    |                  .**|  .                    |
 10     -0.01979    |                  .  |  .                    |
 11     -0.02248    |                  .  |  .                    |
 12     -0.45472    |            *********|  .                    |
 13     -0.04839    |                  . *|  .                    |
 14     -0.06122    |                  . *|  .                    |
 15     -0.06643    |                  . *|  .                    |
 16     -0.04247    |                  . *|  .                    |
 17     -0.03370    |                  . *|  .                    |
 18      0.03024    |                  .  |* .                    |
 19     -0.02092    |                  .  |  .                    |
 20     -0.07926    |                  .**|  .                    |
 21      0.05274    |                  .  |* .                    |
 22      0.01483    |                  .  |  .                    |
 23     -0.03485    |                  . *|  .                    |
 24     -0.22496    |                 ****|  .                    |
```

d. Balikpapan

```
                     Autocorrelation Plot of Residuals

Lag  Covariance   Correlation  -1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1    Std Error

  0    0.268639      1.00000   |                    |********************|           0
  1    0.027094      0.10086   |                  . |**.                 |    0.081379
  2    0.025454      0.09475   |                  . |**.                 |    0.082202
  3   -0.039339      -.14644   |                 ***|  .                 |    0.082923
  4  -0.0007505      -.00279   |                  . |  .                 |    0.084618
  5   -0.013106      -.04879   |                  . *|  .                |    0.084618
  6    0.026014      0.09684   |                  . |**.                 |    0.084805
  7  0.00012103      0.00045   |                  . |  .                 |    0.085534
  8    0.019932      0.07420   |                  . |*  .                |    0.085534
  9    0.010761      0.04006   |                  . |*  .                |    0.085959
 10   -0.031272      -.11641   |                  .**|  .                |    0.086082
 11   -0.031870      -.11864   |                  .**|  .                |    0.087119
 12   -0.113885      -.42393   |           ********|   .               |    0.088182
 13   -0.020671      -.07695   |                 . **|   .              |    0.100779
 14   -0.030098      -.11204   |                 . **|   .              |    0.101168
 15  -0.0039328      -.01464   |                 .   |   .              |    0.101986
 16   -0.019896      -.07406   |                 .  *|   .              |    0.102000
 17    0.038550      0.14350   |                 .   |***.              |    0.102355
 18   -0.051174      -.19049   |                 ****|   .              |    0.103679
 19   0.0030900      0.01150   |                 .   |   .              |    0.105972
 20   -0.050770      -.18899   |                 ****|   .              |    0.105980
 21    0.030440      0.11331   |                 .   |** .              |    0.108189
 22    0.010724      0.03992   |                 .   |*  .              |    0.108972
 23    0.039608      0.14744   |                 .   |***.              |    0.109069
 24  -0.0091936      -.03422   |                 .  *|   .              |    0.110381
```

```
                  Partial Autocorrelations

Lag   Correlation   -1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1

  1      0.10086    |                  .  |**.                    |
  2      0.08545    |                  .  |**.                    |
  3     -0.16669    |                  ***|  .                    |
  4      0.02100    |                  .  |  .                    |
  5     -0.02109    |                  .  |  .                    |
  6      0.08170    |                  .  |**.                    |
  7     -0.00991    |                  .  |  .                    |
  8      0.04915    |                  .  |* .                    |
  9      0.05799    |                  .  |* .                    |
 10     -0.15129    |                  ***|  .                    |
 11     -0.07998    |                  .**|  .                    |
 12     -0.40621    |             ********|  .                    |
 13     -0.02088    |                  .  |  .                    |
 14     -0.09795    |                  .**|  .                    |
 15     -0.15354    |                  ***|  .                    |
 16     -0.05633    |                  . *|  .                    |
 17      0.13613    |                  .  |***                    |
 18     -0.17318    |                  ***|  .                    |
 19      0.01214    |                  .  |  .                    |
 20     -0.11398    |                  .**|  .                    |
 21      0.14098    |                  .  |***                    |
 22     -0.04998    |                  . *|  .                    |
 23      0.00165    |                  .  |  .                    |
 24     -0.22749    |                *****|  .                    |
```

e. Samarinda

Lampiran 13. Output ARIMA (Data Tanpa Transformasi)

PONTIANAK
ARIMA $(1,1,0)^{12}$

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
AR1,1	-0.48876	0.07554	-6.47	<.0001	12

Variance Estimate	1.043527
Std Error Estimate	1.021532
AIC	450.3523
SBC	453.4021
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.05	5	0.4100	-0.078	0.064	0.056	0.092	-0.094	0.024
12	15.32	11	0.1685	0.123	-0.172	-0.007	-0.067	-0.002	-0.109
18	16.45	17	0.4919	-0.017	0.005	-0.003	0.071	-0.034	-0.004
24	27.34	23	0.2417	0.006	-0.074	-0.098	-0.061	0.059	-0.191
30	33.90	29	0.2428	0.068	-0.073	-0.021	-0.035	0.149	-0.018

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
58	Additive	6.31559	125.38	<.0001
151	Additive	2.21954	13.14	0.0003
90	Additive	1.94099	12.56	0.0004
167	Shift	1.51933	11.54	0.0007
51	Additive	1.71624	11.43	0.0007
154	Additive	1.86463	12.36	0.0004
115	Additive	1.62225	11.04	0.0009
87	Additive	1.60974	10.87	0.0010
17	Shift	-0.53644	10.43	0.0012
147	Additive	1.70242	10.31	0.0013
89	Additive	1.50146	10.15	0.0014
82	Additive	1.35874	8.57	0.0034
50	Additive	-1.29343	7.76	0.0053
30	Additive	-1.25574	7.90	0.0049
125	Additive	-1.17866	7.07	0.0078
164	Additive	-1.43157	6.96	0.0084
107	Additive	-1.16631	7.08	0.0078
158	Additive	1.36742	6.77	0.0093
10	Shift	0.44246	6.38	0.0115
155	Additive	-1.10535	6.55	0.0105

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.87648	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.097021	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.365808	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.247256	Pr > A-Sq	<0.0050

ARIMA $(0,1,1)^{12}$

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.62837	0.06570	9.56	<.0001	12

Variance Estimate	0.966051
Std Error Estimate	0.982879
AIC	438.3175
SBC	441.3674
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	1.28	5	0.9368	-0.049	0.021	0.015	0.043	-0.047	0.028
12	9.12	11	0.6104	0.129	-0.152	-0.019	-0.084	-0.009	-0.006
18	10.00	17	0.9035	-0.062	-0.027	0.001	-0.002	-0.005	0.022
24	14.77	23	0.9028	0.003	-0.075	-0.095	-0.045	0.091	0.033
30	20.62	29	0.8726	0.021	-0.083	-0.025	-0.043	0.143	0.005

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
58	Additive	6.63061	129.46	<.0001
167	Shift	1.62896	12.81	0.0003
11	Additive	2.13722	11.31	0.0008
151	Additive	1.93986	10.64	0.0011
90	Additive	1.82333	10.22	0.0014
115	Additive	1.75495	10.04	0.0015
87	Additive	1.74029	9.91	0.0016
51	Additive	1.60524	8.76	0.0031
82	Additive	1.50418	9.45	0.0021
154	Additive	1.52016	9.37	0.0022
158	Additive	1.58763	8.98	0.0027
6	Additive	1.58217	9.04	0.0026
147	Additive	1.45657	8.72	0.0031
50	Additive	-1.38172	8.51	0.0035
89	Additive	1.36095	8.92	0.0028
35	Additive	1.22926	7.17	0.0074
143	Additive	1.21182	7.24	0.0071
130	Additive	-1.16496	7.62	0.0058
164	Additive	-1.27917	7.57	0.0059
142	Additive	-1.16969	7.64	0.0057

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.871484	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.109609	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.350386	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.120401	Pr > A-Sq	<0.0050

SAMPIT
ARIMA (0,0,1)(0,1,1)^{12}

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	-0.26862	0.07786	-3.45	0.0007	1
MA2,1	0.69288	0.05920	11.70	<.0001	12

Variance Estimate	1.347835
Std Error Estimate	1.160963
AIC	491.2618
SBC	497.3615
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	5.94	4	0.2037	-0.033	-0.104	0.039	-0.148	0.023	0.033
12	7.92	10	0.6362	0.065	0.012	0.044	-0.060	0.011	0.042
18	12.01	16	0.7432	-0.044	0.061	0.002	-0.119	0.058	0.011
24	15.78	22	0.8264	-0.031	0.058	-0.053	-0.047	0.101	-0.033
30	28.56	28	0.4350	0.030	0.214	-0.020	-0.100	0.054	-0.084

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
58	Additive	6.04995	55.58	<.0001
4	Additive	2.89388	13.49	0.0002
85	Additive	2.50280	11.92	0.0006
84	Additive	2.50193	11.44	0.0007
90	Additive	2.23293	10.01	0.0016
32	Additive	2.22761	9.14	0.0025
5	Additive	2.19196	7.84	0.0051
54	Additive	-2.00616	7.74	0.0054
153	Additive	-1.92793	7.45	0.0064
97	Additive	-1.76282	7.10	0.0077
25	Additive	-1.79370	7.12	0.0076
14	Additive	1.76836	6.82	0.0090
19	Additive	1.72586	6.76	0.0093
145	Additive	1.57606	6.16	0.0131
12	Additive	1.64085	6.96	0.0084
151	Additive	1.56628	6.88	0.0087
41	Additive	1.49624	7.49	0.0062
100	Additive	-1.39906	6.93	0.0085

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
86	Additive	-1.40895	7.06	0.0079
65	Additive	1.38851	6.83	0.0089

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.931713	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.074682	Pr > D	0.0325
Cramer-von Mises	W-Sq	0.205484	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.445232	Pr > A-Sq	<0.0050

PALANGKARAYA
ARIMA (0,0,1)(0,1,1)^{12}

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	-0.16798	0.07978	-2.11	0.0369	1
MA2,1	0.75805	0.05466	13.87	<.0001	12

Variance Estimate	1.071226
Std Error Estimate	1.035001
AIC	455.4293
SBC	461.529
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	5.11	4	0.2762	-0.005	-0.048	-0.114	0.046	0.020	0.117
12	7.54	10	0.6733	0.051	-0.062	0.039	-0.063	-0.019	-0.048
18	13.86	16	0.6090	-0.082	0.047	-0.042	-0.149	0.001	0.057
24	21.18	22	0.5098	-0.025	-0.058	0.102	-0.019	0.147	0.057
30	29.72	28	0.3769	0.092	-0.047	0.143	-0.040	0.062	0.090

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
58	Additive	5.96281	70.88	<.0001
85	Additive	3.99925	33.88	<.0001
41	Additive	2.14414	9.86	0.0017
3	Additive	2.15556	9.20	0.0024
153	Additive	-2.00869	8.68	0.0032
90	Additive	1.84678	7.86	0.0051
37	Additive	1.72008	6.68	0.0097

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
133	Additive	1.66973	6.32	0.0120
16	Shift	-0.52484	6.18	0.0129
115	Additive	1.49188	6.52	0.0107
71	Additive	1.40595	6.02	0.0142
96	Additive	-1.38516	5.85	0.0156
68	Additive	-1.36170	6.44	0.0112
64	Additive	1.36159	6.58	0.0103
94	Additive	1.28896	5.97	0.0146
151	Additive	1.28498	5.85	0.0156
65	Additive	1.23957	5.95	0.0147
30	Additive	-1.25754	6.47	0.0109
141	Additive	-1.19382	5.75	0.0165
62	Additive	1.13512	5.36	0.0206

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.903323	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.090942	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.249756	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.697946	Pr > A-Sq	<0.0050

BANJARMASIN
ARIMA $(0,1,1)^{12}$

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.75851	0.05538	13.70	<.0001	12

Variance Estimate	1.074793
Std Error Estimate	1.036722
AIC	454.9575
SBC	458.0074
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	---Autocorrelations---					
6	5.48	5	0.3606	0.064	-0.143	-0.079	-0.039	-0.042	-0.008
12	10.76	11	0.4634	0.166	-0.031	0.006	0.016	-0.009	-0.055
18	12.29	17	0.7825	-0.010	-0.052	-0.042	-0.008	0.036	0.052
24	17.10	23	0.8041	-0.025	-0.009	-0.081	0.059	0.106	0.065
30	20.45	29	0.8783	0.029	-0.051	0.034	-0.034	0.107	-0.014

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
58	Additive	6.99161	78.32	<.0001
133	Additive	2.22943	8.28	0.0040
85	Additive	2.32079	9.29	0.0023
65	Additive	2.12169	7.74	0.0054
90	Additive	1.98013	7.12	0.0076
64	Additive	1.86866	6.58	0.0103
11	Additive	1.75573	5.71	0.0168
33	Additive	1.65943	5.68	0.0172
40	Additive	1.57295	5.35	0.0208
44	Additive	1.56516	5.65	0.0174
152	Additive	1.53601	5.27	0.0217
60	Additive	-1.49147	5.82	0.0158
151	Additive	1.51328	5.99	0.0144
50	Additive	-1.44469	5.84	0.0156
51	Additive	1.40592	6.13	0.0133
81	Additive	1.39914	6.39	0.0115
115	Additive	1.32160	5.66	0.0174
66	Additive	1.23530	4.97	0.0258
6	Additive	1.30480	5.00	0.0253
128	Additive	1.22353	4.95	0.0261

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.89827	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.062579	Pr > D	0.1384
Cramer-von Mises	W-Sq	0.213275	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.411648	Pr > A-Sq	<0.0050

BALIKPAPAN
ARIMA $(0,1,1)^{12}$

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.68048	0.06041	11.26	<.0001	12

Variance Estimate	1.021762
Std Error Estimate	1.010822
AIC	447.064
SBC	450.1139
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	4.02	5	0.5468	0.139	-0.057	-0.030	-0.032	0.009	0.027
12	5.36	11	0.9124	0.045	-0.062	-0.027	-0.034	-0.017	0.002
18	14.85	17	0.6065	-0.029	-0.048	-0.118	-0.152	-0.104	0.056

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	---------	---------	Autocorrelations	---------	---------	---------
24	20.53	23	0.6096	-0.043	-0.150	-0.053	0.045	0.043	0.013
30	27.33	29	0.5540	0.157	0.041	-0.076	0.052	0.026	0.017

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
58	Additive	6.04598	69.28	<.0001
7	Additive	2.99782	15.19	<.0001
151	Additive	2.44912	11.50	0.0007
33	Additive	2.36072	11.80	0.0006
90	Additive	2.27034	11.60	0.0007
68	Additive	-1.91234	8.35	0.0039
97	Additive	-1.74167	6.93	0.0085
167	Shift	1.30256	8.13	0.0044
115	Additive	1.60305	8.06	0.0045
81	Additive	1.52568	7.34	0.0067
51	Additive	1.47114	6.79	0.0092
153	Additive	-1.47598	6.61	0.0101
46	Additive	1.31475	5.91	0.0151
14	Additive	1.32759	6.01	0.0143
59	Additive	1.27591	6.02	0.0142
96	Additive	-1.24306	6.53	0.0106
5	Additive	1.31307	5.90	0.0151
66	Additive	1.17114	5.97	0.0146
94	Additive	1.01846	4.64	0.0313
25	Additive	-1.03252	4.62	0.0317

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.914452	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.090193	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.351641	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.025919	Pr > A-Sq	<0.0050

SAMARINDA
ARIMA (0,0,[1,20])(0,1,1)^{12}

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	-0.27483	0.07784	-3.53	0.0005	1
MA1,2	0.22589	0.08125	2.78	0.0061	20
MA2,1	0.79777	0.05246	15.21	<.0001	12

Variance Estimate	0.996399
Std Error Estimate	0.998198
AIC	445.1169
SBC	454.2664
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	--------Autocorrelations--------					
6	4.82	3	0.1854	-0.019	-0.097	-0.105	-0.040	0.042	0.076
12	6.51	9	0.6877	-0.008	0.016	-0.009	-0.081	0.054	0.009
18	12.09	15	0.6721	-0.040	-0.082	-0.067	-0.035	0.084	-0.103
24	18.68	21	0.6058	0.047	-0.027	-0.041	-0.009	0.175	-0.019
30	19.80	27	0.8392	-0.005	0.009	-0.029	-0.000	-0.025	0.064

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
58	Additive	6.03912	91.18	<.0001
151	Additive	2.68796	15.76	<.0001
90	Additive	2.28134	12.83	0.0003
14	Additive	2.22843	12.50	0.0004
97	Additive	-1.74009	8.17	0.0043
168	Additive	1.95076	8.64	0.0033
59	Additive	1.46477	6.18	0.0129
152	Additive	1.48731	5.40	0.0201
140	Additive	1.63203	7.05	0.0079
95	Additive	-1.35742	5.15	0.0233
115	Additive	1.43495	5.95	0.0148

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.841904	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.125326	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.529856	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	3.358465	Pr > A-Sq	<0.0050

Lampiran 14. Output ARIMA (Data Transformasi)

PONTIANAK
ARIMA (2,1,0)^{12}

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
AR1,1	-0.49719	0.08061	-6.17	<.0001	12
AR1,2	-0.34449	0.09093	-3.79	0.0002	24

Variance Estimate	0.138437
Std Error Estimate	0.372072
AIC	136.2314
SBC	142.3311
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.09	4	0.7191	-0.066	0.000	0.038	0.083	-0.013	-0.013
12	9.30	10	0.5035	0.115	-0.109	-0.066	-0.114	0.018	-0.018
18	11.32	16	0.7892	-0.081	-0.029	0.045	-0.004	-0.007	0.045
24	18.43	22	0.6804	-0.021	-0.031	-0.087	-0.028	0.164	-0.045
30	24.80	28	0.6384	0.050	-0.070	-0.043	0.032	0.140	0.056

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
130	Additive	-1.32107	34.04	<.0001
142	Additive	-1.36077	34.00	<.0001
58	Additive	1.29465	32.69	<.0001
155	Additive	-0.93607	15.35	<.0001
107	Additive	-0.74497	11.14	0.0008

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.942835	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.086462	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.313954	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.794189	Pr > A-Sq	<0.0050

ARIMA (0,1,1)^{12}

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.60002	0.06693	8.96	<.0001	12

Variance Estimate	0.137012
Std Error Estimate	0.370152
AIC	133.6268
SBC	136.6766
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.13	5	0.8305	-0.097	-0.005	0.039	0.049	-0.011	0.001
12	10.59	11	0.4781	0.121	-0.121	-0.073	-0.105	0.054	0.046
18	12.15	17	0.7911	-0.063	-0.038	0.024	0.004	-0.003	0.054
24	19.95	23	0.6449	-0.040	-0.032	-0.094	-0.043	0.159	-0.059
30	26.51	29	0.5981	0.026	-0.088	-0.053	0.016	0.141	0.051

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
130	Additive	-1.49068	39.81	<.0001
142	Additive	-1.47654	38.58	<.0001
58	Additive	1.28450	29.87	<.0001
155	Additive	-0.82606	11.64	0.0006
107	Additive	-0.81694	12.45	0.0004

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.938608	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.089445	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.306947	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.787858	Pr > A-Sq	<0.0050

ARIMA (0,1,1)^{12}
(Dengan Deteksi Outlier a130 a142 a58)

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.60534	0.06941	8.72	<.0001	12	y1	0
NUM1	-1.80492	0.27799	-6.49	<.0001	0	a130	0
NUM2	-1.53323	0.27988	-5.48	<.0001	0	a142	0
NUM3	1.27422	0.26903	4.74	<.0001	0	a58	0

Variance Estimate	0.089934
Std Error Estimate	0.29989
AIC	70.90275
SBC	83.10217
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	1.51	5	0.9114	-0.070	0.034	-0.018	0.048	0.023	0.013
12	8.39	11	0.6778	0.105	-0.140	-0.062	-0.059	0.058	0.005
18	12.26	17	0.7841	-0.053	-0.047	-0.018	0.004	-0.098	0.084
24	14.06	23	0.9251	-0.049	-0.034	-0.035	-0.063	0.025	-0.020
30	19.77	29	0.9001	0.016	-0.041	-0.092	0.125	-0.006	0.060

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
155	Additive	-0.82291	11.51	0.0007
107	Additive	-0.81909	13.38	0.0003
87	Additive	0.65889	9.83	0.0017
147	Additive	0.69715	10.98	0.0009
51	Additive	0.62526	9.94	0.0016

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.982836	Pr < W	0.0497
Kolmogorov-Smirnov	D	0.063013	Pr > D	0.1322
Cramer-von Mises	W-Sq	0.124804	Pr > W-Sq	0.0518
Anderson-Darling	A-Sq	0.800169	Pr > A-Sq	0.0392

SAMPIT
ARIMA (0,0,[4])(0,1,1)^{12}

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.15959	0.08084	1.97	0.0501	4
MA2,1	0.70811	0.05917	11.97	<.0001	12

Variance Estimate	0.250314
Std Error Estimate	0.500314
AIC	228.6301
SBC	234.7298
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	--Autocorrelations--					
6	4.69	4	0.3201	0.110	-0.121	-0.033	-0.007	-0.001	0.038
12	6.47	10	0.7744	0.019	0.042	0.077	-0.044	-0.006	0.025
18	9.51	16	0.8909	0.023	0.089	-0.026	-0.009	0.013	0.089
24	13.82	22	0.9077	-0.003	0.098	0.000	-0.016	0.113	0.027
30	26.44	28	0.5489	0.111	0.138	-0.109	-0.070	0.120	-0.059

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
54	Additive	-2.73934	65.68	<.0001
153	Additive	-1.61861	26.31	<.0001
86	Additive	-1.33947	19.97	<.0001
58	Additive	1.26447	18.43	<.0001
7	Shift	-0.43003	12.39	0.0004

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.909631	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.097384	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.441205	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.711191	Pr > A-Sq	<0.0050

ARIMA ([4],0,0)(0,1,1)^{12}

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.70998	0.05895	12.04	<.0001	12
AR1,1	-0.16918	0.08076	-2.09	0.0378	4

Variance Estimate	0.249918
Std Error Estimate	0.499918
AIC	228.3831
SBC	234.4828
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	--Autocorrelations--					
6	4.61	4	0.3300	0.107	-0.122	-0.032	0.002	0.002	0.038
12	6.01	10	0.8143	0.016	0.016	0.074	-0.042	-0.005	0.025
18	9.06	16	0.9111	0.025	0.089	-0.030	-0.010	0.008	0.088
24	13.53	22	0.9173	0.001	0.099	-0.002	-0.015	0.118	0.024
30	25.83	28	0.5823	0.110	0.134	-0.108	-0.070	0.120	-0.058

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
54	Additive	-2.73431	67.00	<.0001
153	Additive	-1.63827	25.10	<.0001
86	Additive	-1.33014	21.54	<.0001
58	Additive	1.25845	19.88	<.0001
7	Shift	-0.42573	12.86	0.0003

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.908301	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.099688	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.437594	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.714097	Pr > A-Sq	<0.0050

ARIMA ([4],0,0)(0,1,1)^{12}
Dengan Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.68731	0.06117	11.24	<.0001	12	y2	0
AR1,1	-0.14671	0.08211	-1.79	0.0760	4	y2	0
NUM1	-2.80497	0.38007	-7.38	<.0001	0	a54	0
NUM2	-1.61957	0.39451	-4.11	<.0001	0	a153	0

Variance Estimate	0.171567
Std Error Estimate	0.414206
AIC	171.6624
SBC	183.8618
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations--------------					
6	8.86	4	0.0648	0.186	-0.132	0.014	0.013	0.049	0.024
12	13.69	10	0.1875	0.095	0.098	0.067	-0.037	-0.014	0.066
18	18.86	16	0.2758	0.004	0.112	-0.000	-0.114	0.037	0.050
24	20.73	22	0.5374	-0.011	0.009	-0.037	0.054	0.033	-0.067
30	28.21	28	0.4531	0.064	0.124	-0.052	-0.127	0.026	-0.015

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
86	Additive	-1.34023	21.66	<.0001
58	Additive	1.27238	19.06	<.0001
7	Shift	-0.43084	12.70	0.0004
100	Additive	-0.92815	9.26	0.0023
85	Additive	0.82018	8.37	0.0038

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.967792	Pr < W	0.0010
Kolmogorov-Smirnov	D	0.065923	Pr > D	0.0946
Cramer-von Mises	W-Sq	0.19755	Pr > W-Sq	0.0056
Anderson-Darling	A-Sq	1.30623	Pr > A-Sq	<0.0050

PALANGKARAYA
ARIMA ([1],0,0)(0,1,1)^{12}

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.74787	0.05671	13.19	<.0001	12
AR1,1	0.15329	0.08045	1.91	0.0586	1

Variance Estimate	0.248737
Std Error Estimate	0.498735
AIC	227.6438
SBC	233.7435
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----	-----	-----Autocorrelations-----	-----	-----	-----
6	6.72	4	0.1514	0.019	-0.106	-0.112	0.024	0.103	0.078
12	9.32	10	0.5022	0.008	-0.067	0.097	-0.036	0.008	-0.012
18	18.53	16	0.2938	-0.115	0.086	0.043	-0.153	-0.054	0.062
24	26.23	22	0.2418	0.020	-0.039	0.019	0.019	0.186	0.068
30	32.58	28	0.2517	0.022	-0.024	-0.047	0.002	0.156	0.070

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
153	Additive	-2.36197	35.47	<.0001
68	Additive	-1.50460	16.16	<.0001
30	Additive	-1.43938	17.09	<.0001
58	Additive	1.30241	14.21	0.0002
39	Additive	-1.11657	11.93	0.0006

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.943196	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.08189	Pr > D	0.0114
Cramer-von Mises	W-Sq	0.326124	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.943629	Pr > A-Sq	<0.0050

ARIMA (0,0,[1])(0,1,1)^{12}

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	-0.18182	0.07996	-2.27	0.0244	1
MA2,1	0.74535	0.05680	13.12	<.0001	12

Variance Estimate	0.247444
Std Error Estimate	0.497438
AIC	226.8309
SBC	232.9306
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	5.39	4	0.2496	-0.010	-0.075	-0.109	0.025	0.098	0.073
12	8.27	10	0.6027	0.013	-0.069	0.101	-0.042	0.009	-0.011
18	17.10	16	0.3792	-0.116	0.084	0.041	-0.150	-0.050	0.057
24	24.63	22	0.3153	0.018	-0.038	0.025	0.013	0.185	0.060
30	30.55	28	0.3374	0.026	-0.022	-0.042	0.000	0.152	0.068

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
153	Additive	-2.36199	37.67	<.0001
68	Additive	-1.48212	17.37	<.0001
30	Additive	-1.44436	16.81	<.0001
58	Additive	1.29758	13.85	0.0002
39	Additive	-1.06268	10.92	0.0010

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.945109	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.085307	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.314618	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.874723	Pr > A-Sq	<0.0050

ARIMA (0,0,[1])(0,1,1)^{12}
(Dengan Deteksi Outlier

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	-0.25791	0.07992	-3.23	0.0015	1	y3	0
MA2,1	0.71563	0.05838	12.26	<.0001	12	y3	0
NUM1	-2.36667	0.37641	-6.29	<.0001	0	a153	0
NUM2	-1.42855	0.36411	-3.92	0.0001	0	a68	0
NUM3	-1.49301	0.36330	-4.11	<.0001	0	a30	0
NUM4	1.27457	0.36195	3.52	0.0006	0	a58	0

Variance Estimate	0.163291
Std Error Estimate	0.404093
AIC	165.8842
SBC	184.1834
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.74	4	0.2197	-0.022	-0.100	-0.063	0.000	0.123	0.075
12	10.82	10	0.3715	0.033	-0.099	0.116	0.016	-0.029	-0.070
18	23.15	16	0.1097	-0.151	0.134	0.048	-0.130	-0.089	0.054
24	28.60	22	0.1565	0.016	0.036	0.066	-0.013	0.091	0.122
30	35.75	28	0.1492	0.053	-0.065	-0.044	0.079	0.142	0.041

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
39	Additive	-1.00052	10.76	0.0010
85	Additive	0.97883	10.88	0.0010
63	Additive	-0.86153	8.96	0.0028
130	Additive	-0.84986	8.93	0.0028
118	Additive	-0.87466	10.36	0.0013

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.983479	Pr < W	0.0593
Kolmogorov-Smirnov	D	0.063719	Pr > D	0.1221
Cramer-von Mises	W-Sq	0.126726	Pr > W-Sq	0.0487
Anderson-Darling	A-Sq	0.810565	Pr > A-Sq	0.0371

BANJARMASIN
ARIMA $(1,1,0)^{12}$

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
AR1,1	-0.52247	0.07196	-7.26	<.0001	12

Variance Estimate	0.236026
Std Error Estimate	0.485825
AIC	218.4706
SBC	221.5205
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	10.34	5	0.0663	0.021	-0.163	-0.065	-0.030	-0.113	-0.138
12	20.32	11	0.0412	0.098	-0.080	0.098	0.115	0.101	-0.101
18	27.60	17	0.0499	0.004	-0.105	-0.088	-0.043	-0.106	0.097
24	48.56	23	0.0014	0.022	0.087	0.028	0.175	0.071	-0.262
30	54.15	29	0.0031	-0.054	-0.020	-0.056	0.042	0.134	0.052

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
50	Additive	-1.79861	25.11	<.0001
58	Additive	1.28377	12.87	0.0003
60	Additive	-1.18744	12.78	0.0004
39	Additive	-1.02628	9.54	0.0020
38	Additive	-0.99541	8.98	0.0027

Tests for Normality

Test	Statistic		p Value	
Shapiro-Wilk	W	0.98875	Pr < W	0.2457
Kolmogorov-Smirnov	D	0.048064	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.075055	Pr > W-Sq	0.2424
Anderson-Darling	A-Sq	0.524478	Pr > A-Sq	0.1873

ARIMA $(0,1,1)^{12}$

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.76749	0.05487	13.99	<.0001	12

Variance Estimate	0.202243
Std Error Estimate	0.449714
AIC	194.3731
SBC	197.4229
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	9.15	5	0.1031	0.063	-0.163	-0.114	-0.017	-0.057	-0.100
12	13.93	11	0.2372	0.061	-0.078	0.036	0.052	0.120	0.004
18	20.85	17	0.2329	0.016	-0.137	-0.112	-0.053	-0.036	0.062
24	27.16	23	0.2493	-0.005	0.051	-0.023	0.114	0.124	0.050
30	34.39	29	0.2252	-0.046	-0.089	-0.090	0.029	0.133	0.033

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
50	Additive	-1.79392	22.78	<.0001
58	Additive	1.37467	14.69	0.0001
39	Additive	-1.13300	10.57	0.0011
60	Additive	-1.08571	9.95	0.0016
78	Additive	-0.88963	6.87	0.0088

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.99156	Pr < W	0.4859
Kolmogorov-Smirnov	D	0.051219	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.029286	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.239875	Pr > A-Sq	>0.2500

BALIKPAPAN
ARIMA $(2,1,0)^{12}$

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
AR1,1	-0.67698	0.08189	-8.27	<.0001	12
AR1,2	-0.32176	0.08651	-3.72	0.0003	24

Variance Estimate	0.214486
Std Error Estimate	0.463127
AIC	204.5324
SBC	210.6321
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	1.61	4	0.8071	0.055	-0.057	-0.006	-0.008	0.056	0.022
12	3.83	10	0.9548	0.009	-0.089	-0.044	-0.049	-0.015	-0.027
18	10.96	16	0.8121	-0.024	-0.030	-0.116	-0.092	-0.125	0.038
24	16.29	22	0.8014	0.044	-0.145	0.017	0.023	0.046	-0.057
30	19.93	28	0.8670	0.108	0.054	-0.041	0.041	0.032	-0.010

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
153	Additive	-2.24112	41.15	<.0001
58	Additive	1.40897	19.95	<.0001
68	Additive	-1.26567	16.10	<.0001
7	Additive	1.29818	12.85	0.0003
97	Additive	-1.07030	13.08	0.0003

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.958034	Pr < W	0.0001
Kolmogorov-Smirnov	D	0.098855	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.224707	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.436238	Pr > A-Sq	<0.0050

ARIMA $(0,1,1)^{12}$

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.70744	0.05889	12.01	<.0001	12

Variance Estimate	0.208711
Std Error Estimate	0.456848
AIC	199.2837
SBC	202.3336
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	3.51	5	0.6223	0.092	-0.067	-0.024	-0.025	0.074	0.045
12	6.10	11	0.8669	-0.001	-0.105	-0.061	-0.023	0.010	-0.006
18	13.86	17	0.6769	-0.024	-0.067	-0.128	-0.099	-0.099	0.055
24	20.55	23	0.6084	0.004	-0.171	0.015	0.027	0.065	0.047
30	23.66	29	0.7454	0.093	0.010	-0.055	0.043	0.045	0.028

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
153	Additive	-2.26915	40.10	<.0001
58	Additive	1.53166	20.04	<.0001
68	Additive	-1.32599	15.99	<.0001
97	Additive	-1.01451	9.36	0.0022
7	Additive	1.06978	9.59	0.0020

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.949321	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.092224	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.20862	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.489509	Pr > A-Sq	<0.0050

ARIMA $(0,1,1)^{12}$
Dengan Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.69699	0.05989	11.64	<.0001	12	y5	0
NUM1	-2.26283	0.37989	-5.96	<.0001	0	a153	0
NUM2	1.55524	0.36599	4.25	<.0001	0	a58	0

Variance Estimate	0.156298
Std Error Estimate	0.395345
AIC	156.1447
SBC	165.2943
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	3.80	5	0.5790	0.112	-0.066	0.001	-0.040	0.042	0.059
12	9.78	11	0.5507	0.016	-0.155	-0.105	-0.002	0.010	-0.019
18	16.52	17	0.4875	0.012	-0.063	-0.117	-0.064	-0.123	0.037
24	22.61	23	0.4837	-0.025	-0.143	0.035	-0.063	0.051	0.068
30	24.10	29	0.7241	0.031	0.012	0.011	0.034	0.070	0.017

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
68	Additive	-1.32659	15.57	<.0001
97	Additive	-1.01509	9.12	0.0025
7	Additive	1.08305	10.05	0.0015
26	Additive	-0.94201	8.64	0.0033
118	Additive	-0.92632	8.59	0.0034

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.973721	Pr < W	0.0045
Kolmogorov-Smirnov	D	0.06988	Pr > D	0.0619
Cramer-von Mises	W-Sq	0.102343	Pr > W-Sq	0.1051
Anderson-Darling	A-Sq	0.863216	Pr > A-Sq	0.0261

SAMARINDA
ARIMA $(0,1,1)^{12}$

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.69093	0.06009	11.50	<.0001	12

Variance Estimate	0.205256
Std Error Estimate	0.453052
AIC	196.6802
SBC	199.7301
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	9.17	5	0.1024	0.124	-0.040	-0.181	-0.037	0.028	0.070
12	12.86	11	0.3028	0.004	-0.009	-0.005	-0.145	0.024	-0.003
18	20.40	17	0.2542	-0.039	-0.076	-0.129	-0.065	0.107	-0.060
24	37.97	23	0.0256	0.030	-0.210	0.045	-0.023	0.219	0.005
30	42.60	29	0.0495	0.003	0.018	-0.053	0.037	-0.042	0.133

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
95	Additive	-2.09428	45.42	<.0001
58	Additive	1.53397	24.98	<.0001
2	Additive	-1.22010	14.75	0.0001
97	Additive	-1.01120	11.55	0.0007
151	Additive	0.95137	9.83	0.0017

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.946951	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.075879	Pr > D	0.0262
Cramer-von Mises	W-Sq	0.235405	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.413768	Pr > A-Sq	<0.0050

ARIMA ([3]),0,0)(0,1,1)^{12}

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.72075	0.05810	12.40	<.0001	12
AR1,1	-0.19537	0.08059	-2.42	0.0165	3

Variance Estimate	0.199275
Std Error Estimate	0.446402
AIC	193.0569
SBC	199.1566
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	---	---	---Autocorrelations---	---	---	---
6	2.81	4	0.5893	0.119	-0.023	0.008	-0.019	0.024	0.043
12	7.58	10	0.6699	-0.024	-0.000	0.004	-0.165	0.023	-0.000
18	15.72	16	0.4727	-0.075	-0.060	-0.153	-0.069	0.059	-0.075
24	28.63	22	0.1557	0.011	-0.163	0.030	-0.020	0.204	0.021
30	32.94	28	0.2381	0.006	0.047	-0.032	0.063	-0.017	0.121

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
95	Additive	-2.03754	43.92	<.0001
58	Additive	1.41738	23.27	<.0001
14	Additive	1.09994	13.49	0.0002
90	Additive	1.04358	12.82	0.0003
151	Additive	0.98400	10.86	0.0010

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.939832	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.068031	Pr > D	0.0772
Cramer-von Mises	W-Sq	0.19891	Pr > W-Sq	0.0053
Anderson-Darling	A-Sq	1.387235	Pr > A-Sq	<0.0050

Lampiran 15. Output SAS ARIMA-Variasi Kalender

➢ Pontianak

VC Bulanan-Tanpa Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.72477	0.06031	12.02	<.0001	12	y1	0
NUM1	0.38058	0.10833	3.51	0.0006	0	dt_1	0
NUM2	0.34320	0.10887	3.15	0.0019	0	dt	0

Variance Estimate	0.127326
Std Error Estimate	0.356828
AIC	124.1627
SBC	133.3123
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	6.16	5	0.2908	-0.141	0.029	0.117	0.051	-0.038	0.008
12	13.19	11	0.2808	0.115	-0.150	-0.020	-0.048	-0.036	0.049
18	13.92	17	0.6729	-0.039	-0.012	0.021	0.027	0.000	0.036
24	18.61	23	0.7238	-0.027	0.005	-0.066	-0.024	0.098	-0.100

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
130	Additive	-1.52539	37.55	<.0001
142	Additive	-1.46171	34.03	<.0001
58	Additive	1.16067	22.06	<.0001
107	Additive	-0.74844	10.47	0.0012
155	Additive	-0.78511	11.14	0.0008

Tests for Normality

Test	--Statistic---		-----p Value------	
Kolmogorov-Smirnov	D	0.081941	Pr > D	0.0113

VC Bulanan-Dengan Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.67829	0.06645	10.21	<.0001	12	y1	0
NUM1	0.23641	0.09334	2.53	0.0123	0	dt_1	0
NUM2	0.28709	0.09102	3.15	0.0019	0	dt	0
NUM3	-1.75437	0.27533	-6.37	<.0001	0	a130	0
NUM4	-1.48762	0.27738	-5.36	<.0001	0	a142	0
NUM5	1.21610	0.27546	4.41	<.0001	0	a58	0

Variance Estimate	0.084744
Std Error Estimate	0.291108
AIC	63.56304
SBC	81.86217
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.68	5	0.7487	-0.085	0.057	0.034	0.066	-0.018	0.020
12	8.85	11	0.6356	0.101	-0.156	-0.046	-0.020	-0.008	-0.005
18	12.08	17	0.7950	-0.031	-0.039	-0.024	0.033	-0.098	0.066
24	13.28	23	0.9456	-0.038	-0.021	-0.027	-0.042	-0.032	-0.034
30	18.10	29	0.9423	0.043	-0.026	-0.089	0.119	0.017	0.013

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
107	Additive	-0.75570	10.93	0.0009
155	Additive	-0.82047	12.64	0.0004
87	Additive	0.66127	9.50	0.0021
147	Additive	0.66142	9.35	0.0022
51	Additive	0.64203	9.48	0.0021

Tests for Normality

Test	Statistic		p Value	
Shapiro-Wilk	W	0.98607	Pr < W	0.1203
Kolmogorov-Smirnov	D	0.05911	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.133145	Pr > W-Sq	0.0414
Anderson-Darling	A-Sq	0.780177	Pr > A-Sq	0.0434

VC Mingguan-Tanpa Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.74110	0.05991	12.37	<.0001	12	y1	0
NUM1	0.70872	0.19602	3.62	0.0004	0	d1t_1	0
NUM2	0.34834	0.16998	2.05	0.0422	0	d2t_1	0
NUM3	0.59409	0.17693	3.36	0.0010	0	d3t_1	0
NUM4	0.38765	0.17072	2.27	0.0246	0	d2t	0
NUM5	0.36247	0.16787	2.16	0.0324	0	d3t	0
NUM6	0.42942	0.17474	2.46	0.0151	0	d4t	0

Variance Estimate	0.123077
Std Error Estimate	0.350824
AIC	122.7357
SBC	144.0847
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.37	5	0.3727	-0.145	0.020	0.091	0.057	-0.012	-0.023
12	10.01	11	0.5298	0.114	-0.096	-0.031	-0.058	-0.006	0.037
18	12.10	17	0.7937	-0.061	0.008	-0.007	0.018	-0.001	0.088
24	15.98	23	0.8561	-0.079	0.038	-0.043	-0.039	0.084	-0.055
30	20.35	29	0.8818	0.070	-0.059	-0.058	0.019	0.090	0.049

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
130	Additive	-1.55869	41.77	<.0001
142	Additive	-1.48732	38.14	<.0001
58	Additive	0.77000	10.51	0.0012
167	Shift	0.56652	10.51	0.0012
107	Additive	-0.70951	9.52	0.0020

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.942916	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.08809	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.304454	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.666266	Pr > A-Sq	<0.0050

VC Mingguan-Dengan Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.71637	0.06421	11.16	<.0001	12	y1	0
NUM1	0.29993	0.13835	2.17	0.0318	0	d2t_1	0
NUM2	0.45694	0.14393	3.17	0.0018	0	d3t_1	0
NUM3	0.29822	0.13859	2.15	0.0331	0	d2t	0
NUM4	0.32231	0.13972	2.31	0.0225	0	d3t	0
NUM5	0.35655	0.14216	2.51	0.0132	0	d4t	0
NUM6	-1.78887	0.27474	-6.51	<.0001	0	a130	0
NUM7	-1.51387	0.27690	-5.47	<.0001	0	a142	0
NUM8	1.41923	0.26955	5.27	<.0001	0	a58	0

Variance Estimate	0.08273
Std Error Estimate	0.287628
AIC	62.65915
SBC	90.10785
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	3.35	5	0.6460	-0.101	0.054	0.040	0.073	-0.028	0.011
12	7.04	11	0.7958	0.071	-0.107	-0.070	-0.004	-0.028	-0.001
18	15.13	17	0.5862	-0.069	-0.061	-0.049	0.056	-0.111	0.139

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
24	17.54	23	0.7821	-0.082	0.004	-0.014	-0.031	-0.070	-0.021
30	25.28	29	0.6637	0.050	-0.041	-0.110	0.153	-0.026	0.001

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
107	Additive	-0.77683	12.64	0.0004
155	Additive	-0.80418	13.89	0.0002
87	Additive	0.66389	10.31	0.0013
50	Additive	-0.64014	9.92	0.0016
51	Additive	0.63869	10.91	0.0010

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.989287	Pr < W	0.2820
Kolmogorov-Smirnov	D	0.062128	Pr > D	0.1448
Cramer-von Mises	W-Sq	0.119376	Pr > W-Sq	0.0642
Anderson-Darling	A-Sq	0.659686	Pr > A-Sq	0.0868

- **Sampit**

VC Bulanan-Tanpa Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	-0.76951	0.17636	-4.36	<.0001	1	y2	0
MA2,1	0.73393	0.05850	12.55	<.0001	12	y2	0
AR1,1	-0.60858	0.21824	-2.79	0.0060	1	y2	0
NUM1	0.21984	0.13154	1.67	0.0967	0	dt	0

Variance Estimate	0.248085
Std Error Estimate	0.498081
AIC	229.195
SBC	241.3945
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	4.00	3	0.2616	-0.006	-0.027	-0.080	-0.117	-0.031	0.053
12	5.64	9	0.7752	0.028	0.033	0.069	-0.046	-0.016	0.027
18	8.85	15	0.8855	0.013	0.092	-0.053	0.011	-0.013	0.080
24	13.29	21	0.8980	-0.021	0.092	-0.029	-0.035	0.115	0.008
30	22.46	27	0.7135	0.099	0.138	-0.099	-0.067	0.057	-0.040

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
54	Additive	-2.86495	80.78	<.0001
153	Additive	-1.53306	26.71	<.0001
86	Additive	-1.37669	24.56	<.0001
58	Additive	1.28240	22.48	<.0001
4	Additive	0.98821	11.70	0.0006

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.913771	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.100787	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.397115	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.474933	Pr > A-Sq	<0.0050

VC Bulanan-Dengan Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	-0.90605	0.06897	-13.14	<.0001	1	y2	0
MA2,1	0.74001	0.06242	11.86	<.0001	12	y2	0
AR1,1	-0.62250	0.11149	-5.58	<.0001	1	y2	0
NUM1	0.19584	0.07863	2.49	0.0139	0	dt	0
NUM2	-3.05630	0.29708	-10.29	<.0001	0	a54	0
NUM3	-1.82294	0.30146	-6.05	<.0001	0	a153	0
NUM4	-1.22102	0.28542	-4.28	<.0001	0	a86	0
NUM5	1.18920	0.29561	4.02	<.0001	0	a58	0
NUM6	0.83912	0.17706	4.74	<.0001	0	a4	0

Variance Estimate	0.118609
Std Error Estimate	0.344397
AIC	118.8591
SBC	146.3078
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	4.30	3	0.2311	-0.009	-0.013	-0.092	-0.079	0.106	-0.019
12	12.34	9	0.1949	0.060	0.104	0.006	-0.080	-0.155	0.052
18	15.79	15	0.3962	0.025	0.053	-0.012	-0.112	0.060	-0.008
24	18.79	21	0.5987	-0.032	0.091	-0.026	0.032	-0.071	-0.019
30	22.76	27	0.6979	0.110	0.042	-0.037	-0.004	0.064	0.040

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
74	Additive	-0.70685	8.51	0.0035
100	Additive	-0.64588	7.26	0.0070
90	Additive	0.70881	9.26	0.0023
5	Additive	0.62594	5.33	0.0210
97	Additive	-0.54009	4.41	0.0358

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.974706	Pr < W	0.0057
Kolmogorov-Smirnov	D	0.068023	Pr > D	0.0773
Cramer-von Mises	W-Sq	0.162891	Pr > W-Sq	0.0173
Anderson-Darling	A-Sq	1.046638	Pr > A-Sq	0.0093

VC Mingguan-Tanpa Deteksi Outlier

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
AR1,1	-0.60441	0.08042	-7.52	<.0001	12	y2	0
AR1,2	-0.25494	0.08240	-3.09	0.0023	24	y2	0
NUM1	0.45115	0.25951	1.74	0.0841	0	d1t_1	0

Variance Estimate	0.27102
Std Error Estimate	0.520596
AIC	242.0118
SBC	251.1614
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	----------Autocorrelations----------					
6	9.33	4	0.0533	0.081	-0.124	-0.060	-0.150	-0.017	0.097
12	13.84	10	0.1807	0.062	0.021	0.083	-0.116	-0.027	-0.038
18	16.83	16	0.3969	-0.035	0.108	-0.001	-0.029	-0.032	0.049
24	25.66	22	0.2665	-0.019	0.119	-0.020	-0.088	0.123	-0.101
30	39.37	28	0.0751	0.075	0.162	-0.116	-0.084	0.096	-0.100

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
54	Additive	-2.86443	80.90	<.0001
86	Additive	-1.41678	20.72	<.0001
153	Additive	-1.50778	19.29	<.0001
4	Additive	1.22635	11.89	0.0006
100	Additive	-0.89349	8.63	0.0033

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.939533	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.099935	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.37012	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.260766	Pr > A-Sq	<0.0050

VC Mingguan-Dengan Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
AR1,1	-0.53768	0.08081	-6.65	<.0001	12	y2	0
AR1,2	-0.30892	0.08387	-3.68	0.0003	24	y2	0
NUM1	0.44553	0.22051	2.02	0.0451	0	d1t_1	0
NUM2	-2.95516	0.38193	-7.74	<.0001	0	a54	0

Variance Estimate	0.198144
Std Error Estimate	0.445134
AIC	194.1298
SBC	206.3292
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations--------------					
6	8.46	4	0.0762	0.158	-0.119	-0.034	-0.082	0.003	0.076
12	14.47	10	0.1526	0.156	0.056	0.049	-0.054	-0.038	-0.045
18	18.27	16	0.3084	-0.046	0.104	0.039	-0.082	-0.023	-0.006
24	21.94	22	0.4637	-0.022	0.028	-0.074	0.003	0.044	-0.106
30	26.22	28	0.5609	0.034	0.087	-0.059	-0.091	0.042	-0.007

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
153	Additive	-1.49115	21.21	<.0001
86	Additive	-1.33254	19.75	<.0001
4	Additive	1.19651	11.51	0.0007
100	Additive	-0.94506	9.93	0.0016
17	Additive	-0.91564	8.31	0.0039

Tests for Normality

Test	--Statistic---		-----p Value------	
Kolmogorov-Smirnov	D	0.07029	Pr > D	0.0586

- **Palangkaraya**

VC Bulanan-Tanpa Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	-0.16721	0.08032	-2.08	0.0390	1	y3	0
MA2,1	0.77518	0.05429	14.28	<.0001	12	y3	0
NUM1	0.25435	0.14117	1.80	0.0736	0	dt_1	0
NUM2	0.35465	0.14113	2.51	0.0130	0	dt	0

Variance Estimate	0.239992
Std Error Estimate	0.489889
AIC	224.0211
SBC	236.2205
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.38	4	0.2502	-0.006	-0.054	-0.115	0.063	0.106	0.042
12	10.11	10	0.4310	0.041	-0.048	0.131	-0.020	-0.064	-0.051
18	18.76	16	0.2812	-0.099	0.135	0.040	-0.122	-0.064	0.032
24	23.61	22	0.3681	0.056	-0.028	0.040	0.034	0.136	0.035
30	29.00	28	0.4126	0.040	0.025	-0.031	0.013	0.140	0.071

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
153	Additive	-2.24019	29.79	<.0001
30	Additive	-1.45839	13.73	0.0002
68	Additive	-1.40079	12.92	0.0003
58	Additive	1.25336	10.29	0.0013
39	Additive	-1.06765	7.81	0.0052

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.95164	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.080948	Pr > D	0.0136
Cramer-von Mises	W-Sq	0.219155	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.418919	Pr > A-Sq	<0.0050

VC Bulanan-Dengan Deteksi Outlier
(Hanya Parameter yang Signifikan)

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	-0.25638	0.08016	-3.20	0.0017	1	y3	0
MA2,1	0.73150	0.05772	12.67	<.0001	12	y3	0
NUM1	0.22072	0.10342	2.13	0.0345	0	dt	0
NUM2	-2.29586	0.37471	-6.13	<.0001	0	a153	0
NUM3	-1.50425	0.36097	-4.17	<.0001	0	a30	0
NUM4	-1.42489	0.36176	-3.94	0.0001	0	a68	0
NUM5	1.39013	0.36389	3.82	0.0002	0	a58	0

Variance Estimate	0.159559
Std Error Estimate	0.399449
AIC	163.2339
SBC	184.5829
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.36	4	0.2520	-0.020	-0.097	-0.070	0.044	0.108	0.069
12	10.33	10	0.4119	0.027	-0.069	0.109	0.033	-0.048	-0.093
18	22.44	16	0.1295	-0.141	0.162	0.029	-0.101	-0.100	0.044
24	27.33	22	0.1988	0.031	0.054	0.057	0.016	0.059	0.125
30	34.11	28	0.1972	0.045	-0.050	-0.040	0.086	0.146	0.020

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
39	Additive	-1.00280	10.87	0.0010
85	Additive	0.97359	10.95	0.0009
63	Additive	-0.86035	8.68	0.0032
130	Additive	-0.84632	9.16	0.0025
41	Additive	0.83319	9.04	0.0026

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.984855	Pr < W	0.0864
Kolmogorov-Smirnov	D	0.067475	Pr > D	0.0818
Cramer-von Mises	W-Sq	0.102453	Pr > W-Sq	0.1047
Anderson-Darling	A-Sq	0.699756	Pr > A-Sq	0.0702

VC Mingguan-Tanpa Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	-0.20432	0.08015	-2.55	0.0118	1	y3	0
MA2,1	0.75563	0.05589	13.52	<.0001	12	y3	0
NUM1	0.53647	0.25861	2.07	0.0397	0	d1t_1	0
NUM2	0.42008	0.22540	1.86	0.0643	0	d2t	0

Variance Estimate	0.239214
Std Error Estimate	0.489095
AIC	223.5147
SBC	235.7141
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	7.64	4	0.1057	-0.010	-0.075	-0.122	0.045	0.136	0.077
12	11.60	10	0.3125	0.024	-0.089	0.118	-0.022	-0.013	-0.027
18	21.90	16	0.1465	-0.129	0.134	0.074	-0.111	-0.080	0.020
24	29.77	22	0.1242	0.074	-0.024	0.074	0.004	0.172	0.039
30	38.79	28	0.0843	0.060	-0.010	-0.090	0.019	0.157	0.098

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
153	Additive	-2.20978	31.24	<.0001
68	Additive	-1.46864	16.22	<.0001
30	Additive	-1.44918	15.69	<.0001
39	Additive	-1.04316	8.12	0.0044
85	Additive	0.99575	8.47	0.0036

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.955738	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.064261	Pr > D	0.1144
Cramer-von Mises	W-Sq	0.186243	Pr > W-Sq	0.0081
Anderson-Darling	A-Sq	1.243303	Pr > A-Sq	<0.0050

- **Banjarmasin**

VC Bulanan

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.80978	0.05304	15.27	<.0001	12	y4	0
NUM1	0.28119	0.12189	2.31	0.0224	0	dt_1	0

Variance Estimate	0.197531
Std Error Estimate	0.444444
AIC	191.6854
SBC	197.7851
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----------	------	Autocorrelations	------	------	-----------
6	9.34	5	0.0963	0.043	-0.147	-0.106	0.005	-0.056	-0.141
12	13.85	11	0.2415	0.064	-0.060	0.065	0.016	0.120	0.009
18	19.67	17	0.2914	0.007	-0.118	-0.114	-0.025	-0.061	0.044
24	25.28	23	0.3359	0.001	0.058	0.003	0.088	0.133	0.041
30	30.30	29	0.3993	-0.061	-0.060	-0.086	0.044	0.081	0.055

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
50	Additive	-1.79808	24.37	<.0001
58	Additive	1.18711	10.98	0.0009
39	Additive	-1.12912	10.79	0.0010
60	Additive	-1.09566	10.57	0.0012
78	Additive	-0.86092	6.73	0.0095

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.988604	Pr < W	0.2365
Kolmogorov-Smirnov	D	0.051384	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.03533	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.266898	Pr > A-Sq	>0.2500

VC Mingguan

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.80595	0.05366	15.02	<.0001	12	y4	0
NUM1	0.62307	0.24528	2.54	0.0121	0	d1t_1	0
NUM2	0.40213	0.20016	2.01	0.0463	0	d3t_1	0

Variance Estimate	0.193769
Std Error Estimate	0.440192
AIC	189.6695
SBC	198.819
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	9.83	5	0.0801	0.059	-0.141	-0.143	0.009	-0.031	-0.126
12	14.87	11	0.1887	0.036	-0.073	0.035	0.049	0.140	0.006
18	20.31	17	0.2586	-0.007	-0.132	-0.086	-0.021	-0.067	0.038
24	25.93	23	0.3040	-0.024	0.073	-0.009	0.075	0.129	0.049
30	31.25	29	0.3536	-0.044	-0.067	-0.095	0.041	0.078	0.067

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
50	Additive	-1.79778	22.00	<.0001
39	Additive	-1.12955	9.20	0.0024
60	Additive	-1.09471	8.96	0.0028
78	Additive	-0.87684	6.07	0.0137
38	Additive	-0.84704	5.58	0.0182

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.98492	Pr < W	0.0879
Kolmogorov-Smirnov	D	0.044911	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.035676	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.339773	Pr > A-Sq	>0.2500

➢ **Balikpapan**

VC Bulanan-Tanpa Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.75890	0.05544	13.69	<.0001	12	y5	0
NUM1	0.34177	0.12534	2.73	0.0071	0	dt_1	0

Variance Estimate	0.20117
Std Error Estimate	0.448519
AIC	194.5332
SBC	200.6329
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	1.66	5	0.8943	0.084	-0.029	-0.020	0.004	0.046	0.002
12	3.35	11	0.9853	-0.010	-0.076	-0.028	-0.056	0.016	-0.003
18	10.10	17	0.8993	-0.024	-0.036	-0.096	-0.095	-0.133	0.025
24	15.97	23	0.8566	0.013	-0.155	0.026	0.005	0.072	0.046
30	18.57	29	0.9319	0.106	0.028	-0.015	0.027	0.009	0.024

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
153	Additive	-2.23863	35.77	<.0001
58	Additive	1.30394	12.95	0.0003
68	Additive	-1.27621	13.26	0.0003
97	Additive	-1.01082	8.41	0.0037
33	Additive	0.98419	8.59	0.0034

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.946109	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.091056	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.218364	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.602373	Pr > A-Sq	<0.0050

VC Bulanan-Dengan Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.73417	0.05699	12.88	<.0001	12	y5	0
NUM1	0.30586	0.11575	2.64	0.0091	0	dt_1	0
NUM2	-2.23436	0.39687	-5.63	<.0001	0	a153	0

Variance Estimate	0.167787
Std Error Estimate	0.409618
AIC	167.2104
SBC	176.36
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	3.78	5	0.5821	0.149	-0.032	0.003	0.008	0.017	-0.004
12	7.34	11	0.7712	0.033	-0.088	-0.059	-0.092	-0.019	-0.000
18	15.92	17	0.5296	-0.017	-0.024	-0.100	-0.129	-0.145	0.014
24	21.63	23	0.5426	-0.012	-0.152	0.016	-0.019	0.080	0.034
30	24.30	29	0.7141	0.105	0.025	0.007	0.038	0.024	0.017

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
58	Additive	1.32174	14.20	0.0002
68	Additive	-1.28316	14.03	0.0002
97	Additive	-1.01277	8.88	0.0029
7	Additive	1.04724	8.68	0.0032
33	Additive	0.98197	8.46	0.0036

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.972672	Pr < W	0.0034
Kolmogorov-Smirnov	D	0.066501	Pr > D	0.0898
Cramer-von Mises	W-Sq	0.112519	Pr > W-Sq	0.0798
Anderson-Darling	A-Sq	0.967232	Pr > A-Sq	0.0158

VC Mingguan-Dengan Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.70844	0.05918	11.97	<.0001	12	y5	0
NUM1	0.60605	0.21609	2.80	0.0057	0	d1t_1	0
NUM2	0.48793	0.18866	2.59	0.0106	0	d2t_1	0
NUM3	-2.21564	0.38718	-5.72	<.0001	0	a153	0

Variance Estimate	0.16185
Std Error Estimate	0.402306
AIC	162.5676
SBC	174.767
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.02	5	0.8460	0.095	-0.025	0.015	0.034	-0.007	0.039
12	7.71	11	0.7393	0.040	-0.112	-0.104	-0.093	-0.018	0.003
18	14.24	17	0.6499	-0.034	-0.027	-0.073	-0.105	-0.127	0.049
24	18.30	23	0.7412	0.032	-0.111	0.038	-0.010	0.079	0.032
30	21.85	29	0.8264	0.126	-0.004	-0.002	0.018	0.050	-0.007

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
68	Additive	-1.29877	14.88	0.0001
97	Additive	-1.01446	9.10	0.0026
58	Additive	1.00445	10.49	0.0012
7	Additive	1.07284	10.90	0.0010
33	Additive	0.98542	10.37	0.0013

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.974948	Pr < W	0.0061
Kolmogorov-Smirnov	D	0.057368	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.097922	Pr > W-Sq	0.1222
Anderson-Darling	A-Sq	0.853486	Pr > A-Sq	0.0282

- **Samarinda**

VC Bulanan

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.73672	0.05774	12.76	<.0001	12	y6	0
NUM1	0.28773	0.13200	2.18	0.0308	0	dt_1	0
NUM2	0.39851	0.13269	3.00	0.0031	0	dt	0

Variance Estimate	0.195001
Std Error Estimate	0.441589
AIC	190.6586
SBC	199.8082
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	7.80	5	0.1675	0.151	0.003	-0.152	-0.041	-0.017	0.031
12	10.22	11	0.5105	-0.033	-0.015	0.048	-0.081	-0.043	-0.048
18	15.88	17	0.5323	0.033	-0.026	-0.117	-0.079	0.056	-0.085
24	33.79	23	0.0682	0.021	-0.236	0.075	0.062	0.177	-0.033
30	39.76	29	0.0880	0.064	0.062	-0.051	0.008	-0.080	0.117

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
95	Additive	-2.01727	37.67	<.0001
58	Additive	1.46974	23.88	<.0001
2	Additive	-1.18854	15.33	<.0001
97	Additive	-1.00137	11.21	0.0008

Tests for Normality

Test	--Statistic---		-----p Value------	
Kolmogorov-Smirnov	D	0.063069	Pr > D	0.1314

VC Mingguan

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	-0.25961	0.08406	-3.09	0.0024	23	y6	0
MA2,1	0.73928	0.05659	13.06	<.0001	12	y6	0
NUM1	0.55965	0.22157	2.53	0.0126	0	d1t_1	0

Variance Estimate	0.188052
Std Error Estimate	0.43365
AIC	184.9979
SBC	194.1475
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations---------------					
6	9.06	4	0.0597	0.134	-0.020	-0.175	-0.050	0.016	0.068
12	14.42	10	0.1546	0.035	-0.011	-0.062	-0.151	0.060	-0.016
18	21.16	16	0.1726	-0.010	-0.063	-0.120	-0.083	0.102	-0.051
24	26.09	22	0.2477	0.039	-0.135	0.068	-0.052	0.010	-0.008
30	30.97	28	0.3184	0.007	0.024	-0.052	0.057	-0.068	0.118

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
107	Additive	-1.94679	38.43	<.0001
14	Additive	-1.17184	11.20	0.0008
109	Additive	-0.87324	7.65	0.0057
163	Additive	0.93262	8.23	0.0041
102	Additive	0.83951	8.08	0.0045

Tests for Normality

Test	--Statistic---		-----p Value------	
Kolmogorov-Smirnov	D	0.05162	Pr > D	>0.1500

Lampiran 16. Output SAS ARIMA-Fungsi Transfer

➢ Pontianak

FT-Tanpa Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.58168	0.06975	8.34	<.0001	12	y1	0
NUM1	0.02125	0.0076557	2.78	0.0062	0	ch1	5

Variance Estimate	0.134313
Std Error Estimate	0.366488
AIC	127.3614
SBC	133.3959
Number of Residuals	151

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.74	5	0.7403	-0.088	0.004	0.091	0.022	-0.020	-0.024
12	8.69	11	0.6507	0.085	-0.063	-0.029	-0.109	0.094	0.059
18	11.25	17	0.8435	-0.039	0.009	0.087	0.020	0.011	0.072
24	20.50	23	0.6119	-0.067	-0.013	-0.063	-0.060	0.180	-0.081
30	26.66	29	0.5902	-0.000	-0.084	-0.090	0.008	0.121	0.055

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
130	Additive	-1.41473	27.03	<.0001
142	Additive	-1.39836	30.28	<.0001
58	Additive	1.19340	22.53	<.0001
155	Additive	-0.78485	9.66	0.0019
107	Additive	-0.74444	9.58	0.0020

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.948889	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.073715	Pr > D	0.0437
Cramer-von Mises	W-Sq	0.210519	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.31158	Pr > A-Sq	<0.0050

FT-Dengan Deteksi Outlier

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.52959	0.07639	6.93	<.0001	12	y1	0
NUM1	0.01306	0.0060587	2.16	0.0328	0	ch1	5
NUM2	-1.74335	0.26557	-6.56	<.0001	0	a130	0
NUM3	-1.48297	0.26676	-5.56	<.0001	0	a142	0
NUM4	1.20957	0.25584	4.73	<.0001	0	a58	0
NUM5	-0.83498	0.26473	-3.15	0.0020	0	a155	0

Variance Estimate	0.084612
Std Error Estimate	0.290882
AIC	61.47621
SBC	79.57989
Number of Residuals	151

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.66	5	0.7515	-0.041	-0.004	0.113	0.045	0.023	0.002
12	6.56	11	0.8332	0.102	-0.033	-0.062	-0.056	0.059	0.045
18	10.77	17	0.8680	0.032	-0.054	0.039	0.009	-0.100	0.094
24	14.18	23	0.9216	-0.047	-0.047	0.018	-0.074	0.061	-0.071
30	18.33	29	0.9373	0.016	-0.029	-0.105	0.099	-0.011	0.011

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
107	Additive	-0.74851	10.42	0.0012
147	Additive	0.67855	8.47	0.0036
50	Additive	-0.64457	8.21	0.0042
90	Additive	0.63409	8.06	0.0045
51	Additive	0.60864	8.02	0.0046

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.984712	Pr < W	0.0936
Kolmogorov-Smirnov	D	0.071841	Pr > D	0.0552
Cramer-von Mises	W-Sq	0.142906	Pr > W-Sq	0.0303
Anderson-Darling	A-Sq	0.818102	Pr > A-Sq	0.0355

- **Sampit**

FT-Dengan Deteksi Outlier

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.71295	0.06409	11.13	<.0001	12	y2	0
AR1,1	-0.22607	0.08405	-2.69	0.0080	2	y2	0
AR1,2	-0.21539	0.08466	-2.54	0.0121	4	y2	0
NUM1	0.01568	0.0069723	2.25	0.0261	0	ch2	14

Variance Estimate	0.225219
Std Error Estimate	0.474572
AIC	195.2441
SBC	207.0675
Number of Residuals	142

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	0.95	3	0.8126	0.031	-0.011	-0.029	-0.007	-0.006	-0.066
12	5.24	9	0.8126	0.039	-0.014	0.007	-0.111	-0.097	-0.063
18	8.68	15	0.8937	-0.112	0.002	-0.070	0.041	-0.005	0.048
24	13.90	21	0.8740	-0.022	0.079	-0.002	-0.030	0.127	0.082

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob>ChiSq
54	Additive	-2.33919	48.04	<.0001
153	Additive	-1.42554	19.37	<.0001
58	Additive	1.34672	20.96	<.0001
86	Additive	-0.99666	11.62	0.0007
84	Additive	0.84176	9.08	0.0026

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.944867	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.071889	Pr > D	0.0723
Cramer-von Mises	W-Sq	0.212474	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.43754	Pr > A-Sq	<0.0050

- **Palangkaraya**

FT-Tanpa Deteksi Outlier

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	-0.21169	0.08265	-2.56	0.0115	1	y3	0
MA2,1	0.76397	0.05802	13.17	<.0001	12	y3	0
NUM1	0.01613	0.0093412	1.73	0.0864	0	ch3	8

Variance Estimate	0.240466
Std Error Estimate	0.490373
AIC	212.0489
SBC	221.0405
Number of Residuals	148

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	7.25	4	0.1233	-0.009	-0.074	-0.156	0.026	0.112	0.062
12	9.96	10	0.4437	0.042	-0.110	0.015	-0.044	0.028	-0.016
18	16.91	16	0.3914	-0.095	0.048	0.006	-0.155	-0.045	0.065
24	27.19	22	0.2042	0.026	-0.053	0.008	-0.003	0.228	0.050

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
153	Additive	-2.32507	40.12	<.0001
68	Additive	-1.46519	16.94	<.0001
30	Additive	-1.29912	13.55	0.0002
58	Additive	1.21395	13.57	0.0002
85	Additive	0.97472	8.93	0.0028

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.952484	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.082943	Pr > D	0.0139
Cramer-von Mises	W-Sq	0.243538	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.399502	Pr > A-Sq	<0.0050

FT-Dengan Deteksi Outlier

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	-0.25290	0.08136	-3.11	0.0023	1	y3	0
MA2,1	0.74889	0.05778	12.96	<.0001	12	y3	0
NUM1	0.01326	0.0084882	1.56	0.1205	0	ch3	8
NUM2	-2.33075	0.42138	-5.53	<.0001	0	a153	0

Variance Estimate	0.200048
Std Error Estimate	0.447267
AIC	185.7893
SBC	197.7782
Number of Residuals	148

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	7.69	4	0.1037	-0.005	-0.063	-0.172	0.012	0.101	0.078
12	13.17	10	0.2145	0.062	-0.102	0.086	-0.099	-0.007	-0.052
18	22.35	16	0.1321	-0.084	0.055	0.037	-0.178	-0.077	0.074
24	29.94	22	0.1200	0.021	-0.026	0.015	-0.035	0.185	0.077

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
68	Additive	-1.45130	17.12	<.0001
30	Additive	-1.31043	14.27	0.0002
58	Additive	1.21855	13.61	0.0002
85	Additive	0.96989	9.09	0.0026
130	Additive	-0.85177	7.03	0.0080

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.984531	Pr < W	0.0959
Kolmogorov-Smirnov	D	0.059414	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.125236	Pr > W-Sq	0.0508
Anderson-Darling	A-Sq	0.774707	Pr > A-Sq	0.0445

- **Banjarmasin**

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.75587	0.05784	13.07	<.0001	12	y4	0
NUM1	-0.01257	0.01162	-1.08	0.2809	0	ch4	0

Variance Estimate	0.201995
Std Error Estimate	0.449439
AIC	195.172
SBC	201.2717
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----	-------	Autocorrelations	-------	-------	-----
6	9.14	5	0.1037	0.067	-0.164	-0.102	-0.012	-0.068	-0.100
12	14.47	11	0.2078	0.064	-0.069	0.041	0.053	0.135	0.004
18	21.72	17	0.1958	0.025	-0.146	-0.118	-0.038	-0.030	0.058
24	27.41	23	0.2388	-0.001	0.052	-0.017	0.116	0.112	0.043
30	34.65	29	0.2163	-0.059	-0.082	-0.096	0.025	0.129	0.034

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
50	Additive	-1.79750	21.29	<.0001
58	Additive	1.34379	13.38	0.0003
39	Additive	-1.14528	10.56	0.0012
60	Additive	-1.08203	9.62	0.0019
38	Additive	-0.85531	6.08	0.0137

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.991887	Pr < W	0.5217
Kolmogorov-Smirnov	D	0.046313	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.02975	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.222654	Pr > A-Sq	>0.2500

Menghilangkan FT, Karena Tidak Signifikan

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.76749	0.05487	13.99	<.0001	12

Variance Estimate	0.202243
Std Error Estimate	0.449714
AIC	194.3731
SBC	197.4229
Number of Residuals	156

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	------------------Autocorrelations--------------					
6	9.15	5	0.1031	0.063	-0.163	-0.114	-0.017	-0.057	-0.100
12	13.93	11	0.2372	0.061	-0.078	0.036	0.052	0.120	0.004
18	20.85	17	0.2329	0.016	-0.137	-0.112	-0.053	-0.036	0.062
24	27.16	23	0.2493	-0.005	0.051	-0.023	0.114	0.124	0.050
30	34.39	29	0.2252	-0.046	-0.089	-0.090	0.029	0.133	0.033

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
50	Additive	-1.79392	22.78	<.0001
58	Additive	1.37467	14.69	0.0001
39	Additive	-1.13300	10.57	0.0011
60	Additive	-1.08571	9.95	0.0016
78	Additive	-0.88963	6.87	0.0088

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.99156	Pr < W	0.4859
Kolmogorov-Smirnov	D	0.051219	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.029286	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.239875	Pr > A-Sq	>0.2500

➢ Balikpapan

FT-Tanpa Deteksi Outlier

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.67009	0.06273	10.68	<.0001	12	y5	0
NUM1	-0.01538	0.0088863	-1.73	0.0856	0	ch5	4

Variance Estimate	0.212412
Std Error Estimate	0.460881
AIC	197.8611
SBC	203.9089
Number of Residuals	152

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	---------------	--	Autocorrelations	--	--	---------------
6	4.97	5	0.4192	0.095	-0.086	-0.037	0.043	0.083	0.071
12	6.68	11	0.8246	-0.014	-0.058	-0.062	-0.023	0.045	-0.021
18	13.87	17	0.6766	-0.025	-0.074	-0.131	-0.084	-0.083	0.069
24	20.26	23	0.6262	-0.010	-0.163	0.005	0.061	0.040	0.062
30	23.52	29	0.7523	0.077	-0.002	-0.036	0.047	0.056	0.070

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
153	Additive	-2.24865	46.38	<.0001
58	Additive	1.40770	20.67	<.0001
68	Additive	-1.25178	18.43	<.0001
8	Shift	-0.65923	12.85	0.0003

Tests for Normality

Test	--Statistic---		-----p Value------	
Kolmogorov-Smirnov	D	0.08995	Pr > D	<0.0100

FT-Dengan Deteksi Outlier

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.72212	0.06007	12.02	<.0001	12	y5	0
NUM1	-0.01015	0.0071475	-1.42	0.1578	0	ch5	4
NUM2	-2.26531	0.35234	-6.43	<.0001	0	a153	0
NUM3	1.50971	0.34263	4.41	<.0001	0	a58	0
NUM4	-1.27587	0.33973	-3.76	0.0002	0	a68	0
NUM5	-0.64214	0.14607	-4.40	<.0001	0	s8	0

Variance Estimate	0.132828
Std Error Estimate	0.364455
AIC	130.3929
SBC	148.5362
Number of Residuals	152

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	3.87	5	0.5688	0.063	-0.105	0.011	-0.006	0.066	0.071
12	12.52	11	0.3256	-0.049	-0.183	-0.112	-0.041	0.038	-0.036
18	19.30	17	0.3113	0.008	-0.102	-0.144	-0.005	-0.064	0.066
24	24.69	23	0.3665	0.022	-0.104	0.065	0.064	0.003	0.101
30	25.59	29	0.6471	-0.039	-0.032	0.028	-0.002	0.006	0.037

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
33	Additive	0.99375	10.82	0.0010
97	Additive	-0.97169	10.94	0.0009
26	Additive	-1.00317	11.66	0.0006
118	Additive	-0.91114	9.74	0.0018
90	Additive	0.77073	6.90	0.0086

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.980482	Pr < W	0.0296
Kolmogorov-Smirnov	D	0.051772	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.051091	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.467015	Pr > A-Sq	>0.2500

➢ Samarinda

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag	Variable	Shift
MA1,1	0.69487	0.06160	11.28	<.0001	12	y6	0
AR1,1	-0.20039	0.08241	-2.43	0.0162	3	y6	0
NUM1	-0.0008573	0.0003589	-2.39	0.0182	0	ch6	5

Variance Estimate	0.184507
Std Error Estimate	0.429542
AIC	176.2886
SBC	185.3404
Number of Residuals	151

* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	1.41	4	0.8419	0.068	-0.011	0.008	-0.005	0.044	0.047
12	5.61	10	0.8468	0.017	0.002	0.029	-0.155	-0.018	0.006
18	17.86	16	0.3322	-0.111	-0.107	-0.138	-0.034	0.115	-0.121
24	27.89	22	0.1794	0.031	-0.097	0.083	-0.014	0.196	0.003
30	30.94	28	0.3196	-0.017	0.023	-0.037	0.079	0.000	0.087

Outlier Details

Obs	Type	Estimate	Chi-Square	Approx Prob> ChiSq
95	Additive	-1.98957	28.83	<.0001
58	Additive	1.36419	13.48	0.0002
90	Additive	0.97197	7.30	0.0069
151	Additive	0.97610	7.85	0.0051
97	Additive	-0.86476	6.92	0.0085

Tests for Normality

Test	Statistic		p Value	
Shapiro-Wilk	W	0.958327	Pr < W	0.0002
Kolmogorov-Smirnov	D	0.053177	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.08719	Pr > W-Sq	0.1707
Anderson-Darling	A-Sq	0.668544	Pr > A-Sq	0.0831

Lampiran 17. Output MCCF dan MPCCF Penentuan Orde AR

- Skema Representasi MCCF

```
                 Schematic Representation of Cross Correlations

Variable/
Lag          0      1      2      3      4      5      6      7      8      9

u1         +.++++ -+.... ...... ...... ...... ...... ...... ...... ...... ......
u2         .+++++ ..+..+ ...... ...... ...... ...... ...... ...... ...-.. ..+...
u3         ++++++ .++... .--... .-.... ...... ..+... ...... ...... ...... ......
u4         ++++++ ...... ...... ....-. .+.... ...... ...... ...... ...... ......
u5         ++++++ ...... ...... +..... .++... ...... ...... ...... ...... ....-.
u6         ++++++ ..+... ...... +..... ...... ...... ...... ...... ...... ......


           Variable/
           Lag           10        11        12        13        14

           u1          ......    ......    -.--..    .-....    ......
           u2          ......    ......    .---.-    ..-.--    ......
           u3          ......    ..-..-    .---.-    ----..    ......
           u4          ......    ......    .-----    -.....    .....-
           u5          ......    ......    ..--.-    ......    ......
           u6          ...-..    ..-...    -.--.-    ......    ......

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

- Skema Representasi MPCCF

```
             Schematic Representation of Partial Cross Correlations

Variable/
Lag          1      2      3      4      5      6      7      8      9     10

u1         -+.... ...... .....+ ...... ...... ...... ...... ...... ...... ......
u2         ...... ...... ...... ...... .....- ..-+.+ ...... ...-.. ..+... ......
u3         .+.... .--... ...... ...... +..... .+..-. ...... ...... ...... ......
u4         ...... ...... ....-. .+.... ...-.. ...... ...... .+-... .+.... ......
u5         ...... ...... ...... ..+... ...... ...... ...... ...... ....-. ......
u6         ..+... ...... +..... ...... ...... ...... ...... ...... .-.... .-.-..

               Variable/
               Lag           11        12        13        14

               u1          ....+.    .....+    ......    ......
               u2          .....+    .-....    ......    ......
               u3          ......    ......    -.....    ......
               u4          ...+..    ...-..    ......    ...-..
               u5          ......    ......    ......    ......
               u6          ......    .....-    ......    ......

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

Lampiran 18. Output GSTAR dengan SUR

Bobot Seragam : *Full* Model

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y112	1	-0.44355	0.076501	-5.80	<.0001
wy112	1	0.038557	0.080730	0.48	0.6337

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y212	1	-0.43709	0.072409	-6.04	<.0001
wy212	1	-0.10247	0.120819	-0.85	0.3978

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y312	1	-0.48469	0.070689	-6.86	<.0001
wy312	1	-0.15164	0.133996	-1.13	0.2597

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y412	1	-0.43212	0.075938	-5.69	<.0001
wy412	1	-0.12792	0.123510	-1.04	0.3021

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y512	1	-0.51152	0.070902	-7.21	<.0001
wy512	1	-0.17452	0.107082	-1.63	0.1054

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y612	1	-0.50202	0.070240	-7.15	<.0001
wy612	1	-0.03201	0.108056	-0.30	0.7675

Bobot Seragam : *Restricted* Model

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y112	1	-0.40444	0.070512	-5.74	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y212	1	-0.43311	0.062798	-6.90	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y312	1	-0.49471	0.054312	-9.11	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y412	1	-0.45555	0.058965	-7.73	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y512	1	-0.55792	0.059726	-9.34	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y612	1	-0.48227	0.058270	-8.28	<.0001

Bobot Invers Jarak : *Full* Model

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y112	1	-0.43941	0.075388	-5.83	<.0001
wy112	1	0.057448	0.075561	0.76	0.4483

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y212	1	-0.41318	0.072957	-5.66	<.0001
wy212	1	-0.13214	0.102811	-1.29	0.2008

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y312	1	-0.49107	0.073444	-6.69	<.0001
wy312	1	-0.10621	0.110791	-0.96	0.3394

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y412	1	-0.41977	0.078595	-5.34	<.0001
wy412	1	-0.12166	0.105375	-1.15	0.2502

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y512	1	-0.50655	0.072500	-6.99	<.0001
wy512	1	-0.14257	0.087936	-1.62	0.1072

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y612	1	-0.52819	0.070551	-7.49	<.0001
wy612	1	0.028843	0.088006	0.33	0.7436

Bobot Invers Jarak : *Restricted* Model

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y112	1	-0.40444	0.070512	-5.74	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y212	1	-0.43311	0.062798	-6.90	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y312	1	-0.49471	0.054312	-9.11	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y412	1	-0.45555	0.058965	-7.73	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y512	1	-0.55792	0.059726	-9.34	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y612	1	-0.48227	0.058270	-8.28	<.0001

Bobot Normalisasi Korelasi Silang : *Full* Model

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y112	1	-0.43995	0.076706	-5.74	<.0001
wy112	1	-0.04739	0.080626	-0.59	0.5576

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y212	1	-0.43211	0.073315	-5.89	<.0001
wy212	1	0.082149	0.111603	0.74	0.4629

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y312	1	-0.48655	0.074275	-6.55	<.0001
wy312	1	0.118140	0.121517	0.97	0.3326

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y412	1	-0.42775	0.076660	-5.58	<.0001
wy412	1	0.112530	0.112938	1.00	0.3208

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y512	1	-0.51275	0.073860	-6.94	<.0001
wy512	1	0.132659	0.099552	1.33	0.1848

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y612	1	-0.50153	0.070240	-7.14	<.0001
wy612	1	0.009210	0.107538	0.09	0.9319

Bobot Normalisasi Korelasi Silang : *Restricted* Model

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y112	1	-0.40444	0.070512	-5.74	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y212	1	-0.43311	0.062798	-6.90	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y312	1	-0.49471	0.054312	-9.11	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y412	1	-0.45555	0.058965	-7.73	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y512	1	-0.55792	0.059726	-9.34	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y612	1	-0.48227	0.058270	-8.28	<.0001

Bobot Normalisasi Inferensia Parsial Korelasi Silang *Full* Model

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y112	1	-0.44743	0.075365	-5.94	<.0001
wy112	1	-0.08220	0.061964	-1.33	0.1868

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y212	1	-0.43137	0.073423	-5.88	<.0001
wy212	1	0.054128	0.108819	0.50	0.6197

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y312	1	-0.47913	0.075578	-6.34	<.0001
wy312	1	0.080263	0.114780	0.70	0.4855

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y412	1	-0.41493	0.076323	-5.44	<.0001
wy412	1	0.088903	0.103858	0.86	0.3934

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y512	1	-0.51809	0.072753	-7.12	<.0001
wy512	1	0.066850	0.074531	0.90	0.3713

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y612	1	-0.50769	0.067338	-7.54	<.0001
wy612	1	-0.04430	0.087916	-0.50	0.6151

Bobot Normalisasi Inferensia Parsial Korelasi Silang *Restricted* Model

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y112	1	-0.40444	0.070512	-5.74	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y212	1	-0.43311	0.062798	-6.90	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y312	1	-0.49471	0.054312	-9.11	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y412	1	-0.45555	0.058965	-7.73	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y512	1	-0.55792	0.059726	-9.34	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
y612	1	-0.48227	0.058270	-8.28	<.0001

Minimum Information Criterion

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	-10.89899	-10.59452	-10.25937	-9.96326	-9.921589	-9.503856
AR 1	-10.81862	-10.36985	-10.10031	-9.685225	-9.504807	-9.021496
AR 2	-10.52772	-10.16147	-9.766763	-9.284507	-8.99042	-8.416057
AR 3	-10.17927	-9.741727	-9.272354	-8.935455	-8.467976	-7.76973
AR 4	-10.04079	-9.587451	-8.9303	-8.386332	-7.804192	-6.936575
AR 5	-9.469711	-9.053923	-8.33966	-7.603355	-6.901463	-6.271993

Lampiran 19. Output GSTARX dengan SUR

➢ **Bobot Seragam *Full Model***

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u11	1	-0.19496	0.077943	-2.50	0.0137
wu11	1	0.137494	0.089915	1.53	0.1287
u112	1	-0.40618	0.081901	-4.96	<.0001
wu112	1	0.015270	0.093161	0.16	0.8701

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u21	1	-0.08172	0.077877	-1.05	0.2960
wu21	1	0.319423	0.144176	2.22	0.0285
u212	1	-0.51288	0.077295	-6.64	<.0001
wu212	1	-0.05943	0.145970	-0.41	0.6846

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u31	1	0.054582	0.069665	0.78	0.4348
wu31	1	0.224281	0.125502	1.79	0.0763
u312	1	-0.50262	0.067896	-7.40	<.0001
wu312	1	-0.28314	0.129552	-2.19	0.0307

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u41	1	-0.05745	0.081130	-0.71	0.4802
wu41	1	0.189110	0.151337	1.25	0.2138
u412	1	-0.42008	0.080881	-5.19	<.0001
wu412	1	-0.25595	0.156618	-1.63	0.1047

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u51	1	0.113711	0.088092	1.29	0.1991
wu51	1	0.089825	0.090703	0.99	0.3239
u512	1	-0.06328	0.079883	-0.79	0.4298
wu512	1	-0.16785	0.093842	-1.79	0.0761

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u61	1	-0.02523	0.075024	-0.34	0.7372
wu61	1	0.190841	0.108262	1.76	0.0804
u612	1	-0.48397	0.075367	-6.42	<.0001
wu612	1	-0.10701	0.110340	-0.97	0.3340

➢ **Bobot Seragam *Restricted Model***

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u11	1	-0.18500	0.073305	-2.52	0.0128
u112	1	-0.36725	0.078008	-4.71	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u212	1	-0.48052	0.069262	-6.94	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u312	1	-0.57603	0.054622	-10.55	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u412	1	-0.47580	0.063641	-7.48	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u612	1	-0.48133	0.066373	-7.25	<.0001

Minimum Information Criterion

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	-9.845043	-9.508692	-9.232462	-9.043288	-8.964499	-8.687244
AR 1	-9.691387	-9.30765	-8.986153	-8.746828	-8.632314	-8.4011
AR 2	-9.422041	-9.012396	-8.873234	-8.642783	-8.395869	-8.064504
AR 3	-9.16021	-8.782881	-8.674412	-8.32806	-7.994426	-7.572001
AR 4	-9.04401	-8.664749	-8.445446	-7.915364	-7.552776	-7.104714
AR 5	-8.596893	-8.404247	-8.028068	-7.52247	-7.09718	-6.675696

- **Bobot Invers Jarak *Full Model***

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u11	1	-0.19324	0.077182	-2.50	0.0136
wu11	1	0.120186	0.082434	1.46	0.1473
u112	1	-0.39068	0.081146	-4.81	<.0001
wu112	1	0.027154	0.085178	0.32	0.7504

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u21	1	-0.09315	0.078556	-1.19	0.2379
wu21	1	0.279063	0.119369	2.34	0.0210
u212	1	-0.48375	0.078186	-6.19	<.0001
wu212	1	-0.06854	0.118581	-0.58	0.5643

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u31	1	0.074440	0.074474	1.00	0.3194
wu31	1	0.161416	0.099219	1.63	0.1063
u312	1	-0.53062	0.072142	-7.36	<.0001
wu312	1	-0.15104	0.100990	-1.50	0.1373

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u41	1	-0.08218	0.084278	-0.98	0.3314
wu41	1	0.208885	0.131259	1.59	0.1140
u412	1	-0.40249	0.083813	-4.80	<.0001
wu412	1	-0.20162	0.132284	-1.52	0.1300

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u51	1	0.136805	0.090742	1.51	0.1342
wu51	1	0.070058	0.083463	0.84	0.4028
u512	1	-0.09668	0.083958	-1.15	0.2517
wu512	1	-0.08832	0.085946	-1.03	0.3061

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u61	1	-0.05793	0.074113	-0.78	0.4359
wu61	1	0.270861	0.106812	2.54	0.0124
u612	1	-0.46056	0.074177	-6.21	<.0001
wu612	1	-0.15813	0.103445	-1.53	0.1289

- **Bobot Invers Jarak *Restricted Model***

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u11	1	-0.18594	0.073298	-2.54	0.0124
u112	1	-0.36788	0.078019	-4.72	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u212	1	-0.48204	0.069327	-6.95	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
wu31	1	0.144783	0.067582	2.14	0.0341
u312	1	-0.56115	0.054578	-10.28	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u412	1	-0.46885	0.063607	-7.37	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u612	1	-0.48090	0.066777	-7.20	<.0001

The VARMAX Procedure

Minimum Information Criterion

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	-9.871223	-9.484387	-9.203026	-9.019933	-8.937745	-8.66863
AR 1	-9.692516	-9.257362	-8.959034	-8.734677	-8.606119	-8.375403
AR 2	-9.409811	-8.993424	-8.851794	-8.620039	-8.403817	-8.052875
AR 3	-9.157824	-8.771249	-8.652052	-8.274077	-7.967592	-7.554023
AR 4	-9.025893	-8.645142	-8.424831	-7.891713	-7.521061	-7.077683
AR 5	-8.586	-8.388165	-8.007813	-7.484185	-7.073656	-6.674955

- **Bobot Normalisasi Korelasi Silang *Full Model***

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u11	1	-0.17269	0.076381	-2.26	0.0255
wu11	1	0.020560	0.091690	0.22	0.8229
u112	1	-0.38887	0.083456	-4.66	<.0001
wu112	1	-0.02443	0.087604	-0.28	0.7808

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u21	1	-0.06726	0.080507	-0.84	0.4051
wu21	1	0.205949	0.140092	1.47	0.1440
u212	1	-0.49486	0.079257	-6.24	<.0001
wu212	1	0.056680	0.130212	0.44	0.6641

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u31	1	0.061286	0.071226	0.86	0.3912
wu31	1	0.159894	0.112980	1.42	0.1595
u312	1	-0.51863	0.072596	-7.14	<.0001
wu312	1	0.168873	0.108390	1.56	0.1217

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u41	1	-0.10917	0.079870	-1.37	0.1741
wu41	1	0.190490	0.127375	1.50	0.1373
u412	1	-0.41284	0.082884	-4.98	<.0001
wu412	1	0.197397	0.135859	1.45	0.1487

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u51	1	0.085185	0.087793	0.97	0.3338
wu51	1	0.088563	0.095543	0.93	0.3557
u512	1	-0.05204	0.080941	-0.64	0.5215
wu512	1	0.118431	0.083851	1.41	0.1603

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u61	1	0.006762	0.074699	0.09	0.9280
wu61	1	0.064075	0.093311	0.69	0.4935
u612	1	-0.49763	0.076001	-6.55	<.0001
wu612	1	0.036914	0.104926	0.35	0.7256

Bobot Normalisasi Korelasi Silang *Restricted Model*

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u11	1	-0.18500	0.073305	-2.52	0.0128
u112	1	-0.36725	0.078008	-4.71	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u212	1	-0.48052	0.069262	-6.94	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u312	1	-0.57603	0.054622	-10.55	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u412	1	-0.47580	0.063641	-7.48	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u612	1	-0.48133	0.066373	-7.25	<.0001

The VARMAX Procedure

Minimum Information Criterion

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	-9.845043	-9.508692	-9.232462	-9.043288	-8.964499	-8.687244
AR 1	-9.691387	-9.30765	-8.986153	-8.746828	-8.632314	-8.4011
AR 2	-9.422041	-9.012396	-8.873234	-8.642783	-8.395869	-8.064504
AR 3	-9.16021	-8.782881	-8.674412	-8.32806	-7.994426	-7.572001
AR 4	-9.04401	-8.664749	-8.445446	-7.915364	-7.552776	-7.104714
AR 5	-8.596893	-8.404247	-8.028068	-7.52247	-7.09718	-6.675696

➢ Bobot Normalisasi Inferensia Parsial Korelasi Silang *Full Model*

The SYSLIN Procedure
Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u11	1	-0.16616	0.075160	-2.21	0.0289
wu11	1	-0.04763	0.049612	-0.96	0.3389
u112	1	-0.38844	0.082504	-4.71	<.0001
wu112	1	-0.05141	0.066621	-0.77	0.4418

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u21	1	-0.09780	0.078957	-1.24	0.2178
wu21	1	0.183475	0.111069	1.65	0.1010
u212	1	-0.48513	0.078673	-6.17	<.0001
wu212	1	0.058191	0.116994	0.50	0.6198

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u31	1	0.060316	0.063798	0.95	0.3462
wu31	1	0.040958	0.053910	0.76	0.4488
u312	1	-0.52511	0.073543	-7.14	<.0001
wu312	1	0.122972	0.097677	1.26	0.2104

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u41	1	-0.06444	0.063887	-1.01	0.3151
wu41	0	0	.	.	.
u412	1	-0.39779	0.083333	-4.77	<.0001
wu412	1	0.199114	0.125889	1.58	0.1162

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u51	1	0.094792	0.076859	1.23	0.2197
wu51	0	0	.	.	.
u512	1	-0.06405	0.080427	-0.80	0.4273
wu512	1	0.099062	0.080653	1.23	0.2216

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u61	1	0.026555	0.071537	0.37	0.7111
wu61	1	-0.04931	0.062142	-0.79	0.4289
u612	1	-0.53791	0.076155	-7.06	<.0001
wu612	1	-0.04126	0.096184	-0.43	0.6687

➢ Bobot Normalisasi Inferensia Parsial Korelasi Silang *Restricted Model*

The SYSLIN Procedure Seemingly Unrelated Regression Estimation

Parameter Estimates

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u11	1	-0.18500	0.073305	-2.52	0.0128
u112	1	-0.36725	0.078008	-4.71	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u212	1	-0.48052	0.069262	-6.94	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u312	1	-0.57603	0.054622	-10.55	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u412	1	-0.47580	0.063641	-7.48	<.0001

Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > |t|
u612	1	-0.48133	0.066373	-7.25	<.0001

The VARMAX Procedure

Minimum Information Criterion

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	-9.845043	-9.508692	-9.232462	-9.043288	-8.964499	-8.687244
AR 1	-9.691387	-9.30765	-8.986153	-8.746828	-8.632314	-8.4011
AR 2	-9.422041	-9.012396	-8.873234	-8.642783	-8.395869	-8.064504
AR 3	-9.16021	-8.782881	-8.674412	-8.32806	-7.994426	-7.572001
AR 4	-9.04401	-8.664749	-8.445446	-7.915364	-7.552776	-7.104714
AR 5	-8.596893	-8.404247	-8.028068	-7.52247	-7.09718	-6.675696

Lampiran 20. Ramalan Inflasi Enam Kota di Kalimantan dengan Metode Univariat Terpilih dan GSATRX

Lokasi	Tahun	Bulan	Data Aktual	Ramalan Inflasi	
				Univariat Terpilih	GSTARX
(1)	(2)	(3)	(4)	(5)	(6)
Pontianak	2016	Januari	0.36	0.53	-0.46
		Februari	0.33	1.47	1.45
		Maret	-0.08	-0.19	-1.23
		April	-0.51	0.19	-0.53
		Mei	1.67	0.56	-0.37
		Juni	1.21	0.55	0.37
		Juli	0.87	0.93	0.04
		Agustus	0.41	0.22	-0.62
		September	-1.06	-0.03	-0.33
		Oktober	-0.36	0.00	-1.05
		November	0.07	0.16	0.82
		Desember	0.93	1.42	1.85
Sampit	2016	Januari	0.7	1.44	1.17
		Februari	-0.44	0.14	1.43
		Maret	-0.34	0.03	-0.61
		April	-0.46	-0.15	-0.19
		Mei	0.42	0.00	0.47
		Juni	0.65	0.77	0.61
		Juli	0.49	0.90	-0.14
		Agustus	0.56	0.39	-0.40
		September	-0.46	-0.27	0.85
		Oktober	-0.63	0.23	0.45
		November	0.67	0.51	1.38
		Desember	1.3	1.13	2.20
Palangkaraya	2016	Januari	0.17	1.25	0.97
		Februari	-0.41	-0.25	-0.70
		Maret	-0.04	0.12	0.02
		April	-0.29	0.18	0.76
		Mei	0.02	0.25	1.41
		Juni	0.91	0.65	1.09
		Juli	0.2	0.86	-0.19
		Agustus	0.12	0.22	-0.67
		September	0.11	-0.24	0.60
		Oktober	-0.34	0.02	0.69
		November	0.18	0.75	1.18
		Desember	1.28	1.18	1.86

Lokasi	Tahun	Bulan	Data Aktual	Ramalan Inflasi	
				Univariat Terpilih	GSTARX
(1)	(2)	(3)	(4)	(5)	(6)
Banjarmasin	2016	Januari	0.49	0.82	0.54
		Februari	0.18	0.01	-0.40
		Maret	0.14	0.05	-0.45
		April	0.04	0.19	0.68
		Mei	0.3	0.22	1.77
		Juni	1.06	0.62	1.06
		Juli	0.56	0.88	0.42
		Agustus	0.07	0.58	-0.23
		September	0.11	0.12	0.43
		Oktober	-0.26	0.24	0.79
		November	0.11	0.93	1.70
		Desember	0.82	0.91	1.73
Balikpapan	2016	Januari	-0.21	1.17	1.32
		Februari	0.5	0.16	-0.18
		Maret	-0.04	0.35	-0.10
		April	-0.4	0.43	0.79
		Mei	0.13	0.24	0.32
		Juni	1.74	0.63	0.49
		Juli	1.03	1.55	0.62
		Agustus	-0.18	0.87	0.59
		September	0.21	-0.45	0.51
		Oktober	-0.07	-0.22	-0.48
		November	0.12	0.15	1.03
		Desember	1.26	1.13	2.31
Samarinda	2016	Januari	0.5	1.41	1.23
		Februari	0.05	0.17	-0.48
		Maret	0.44	0.27	0.18
		April	-0.3	0.09	-0.03
		Mei	0.05	-0.05	0.33
		Juni	0.61	0.66	0.06
		Juli	0.2	0.91	-0.17
		Agustus	0.39	0.59	-0.23
		September	-0.2	-0.13	0.28
		Oktober	-0.1	-0.05	0.76
		November	0.28	0.47	1.47
		Desember	0.87	0.89	3.38

BIOGRAFI PENULIS

Penulis dilahirkan di Tegal, Jawa Tengah pada tanggal 26 Desember 1978, merupakan putra kedua dari empat bersaudara, buah cinta dari pasangan Bapak Saefudin dan Ibu Cholilah Istiaty. Penulis memulai pendidikan formalnya dari SDN 1 Dermasandi (1985-1991), SMP Muhammadiyah Dermasandi (1991-1994), SMU Negeri 1 Slawi (1994-1997). Penulis kemudian melanjutkan pendidikan ke jenjang sarjana di Sekolah Tinggi Ilmu Statistik (STIS) Jakarta (1997-2001) jurusan Statistik Ekonomi. Setelah menyelesaikan pendidikan DIV di STIS, penulis ditugaskan bekerja di BPS Kota Palangkaraya Provinsi Kalimantan Tengah (2001-2009), BPS Provinsi Kalimantan Selatan (2009-2010), BPS Kabupaten Banjar Provinsi Kalimantan Selatan (2010-Sekarang). Pada tahun 2015 penulis memperoleh kesempatan beasiswa dari BPS untuk melanjutkan pendidikan ke jenjang S2 di Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Institut Teknologi Sepuluh Nopember (ITS) Surabaya. Pembaca yang ingin memberikan kritik, saran dan pertanyaan mengenai penelitian ini bisa menghubungi penulis melalui email uavpall.prast2009@gmail.com.