

Editor: Sri Rizqi Wahyuningrum, M.Si.



GSTARX PERAMALAN ARUS UANG DI PROVINSI JAWA TIMUR

Dr. R. Agoes Kamaroellah, M.Si.
Reza Mubarak, M.Si.

Editor: Sri Rizqi Wahyuningrum, M.Si.

GSTARX Peramalan Arus Uang di Provinsi Jawa Timur

**Dr. R. Agoes Kamaroellah, M.Si.
Reza Mubarak, M.Si.**



Penerbit:
IAIN Madura Press

GSTARX Peramalan Arus Uang di Provinsi Jawa Timur

Penyusun:

Dr. R. Agoes Kamaroellah, M.Si.

Reza Mubarak, M.Si.

Editor:

Sri Rizqi Wahyuningrum, M.Si.

Desain Sampul : Tim Desain IAIN Madura Press

Setting & Layout : Tim Redaksi IAIN Madura Press

Penerbit:

IAIN Madura Press

Jl. Panglegur Km. 04 Pamekasan

Email: iaimadurapress@gmail.com

Alamat Penerbit: Jl. Panglegur Km. 04

Gd. Perpustakaan Lt. 4 IAIN Madura

ISBN: 978-623-5614-26-7

Cetakan 1, Tahun 2023

v + 109 hlm, 18,2cm x 25,7cm

Hak Cipta ada pada penyusun

Dilarang memperbanyak karya ini dengan cara apa pun, tanpa izin tertulis dari penyusun,
dan atau penerbit

Kata Pengantar

Puji syukur penulis panjatkan kehadirat Allah SWT yang telah memberikan berkah dan Rahmat-Nya, sehingga penulis dapat menyelesaikan Buku GSTARX Peramalan Arus Uang di Provinsi Jawa Timur dengan Efek Idul Fitri dan Indeks Harga Konsumen (IHK) sebagai salah satu buku yang dapat membantu dalam perkuliahan Ekonomi Makro.

Secara umum, efek variasi kalender Lebaran data *inflow* Kota Surabaya, Malang, Jember dan Kediri pada bulan yang terdapat Hari Raya Idul Fitri akan mengalami efek yang berbeda dengan bulan-bulan lainnya. Model GSTARX-GLS pada level dua yang terbentuk pada kajian terapan berlaku untuk data *outflow* di empat kota/kabupaten di Jawa Timur tersebut.

Pemodelan data *inflow* terbaik adalah *full model* GSTARX dengan bobot invers jarak berdasarkan data *in sample* dengan RMSE total terkecil. Sedangkan model terbaik berdasarkan *out sample* dengan RMSE terkecil adalah model GSTARX dengan bobot normalisasi korelasi silang.

Pemodelan data *outflow* terbaik adalah *full model* GSTARX dengan bobot invers jarak berdasarkan data *in sample* dengan RMSE total terkecil. Sedangkan model terbaik berdasarkan *out sample* dengan RMSE total terkecil adalah model GSTARX dengan bobot seragam.

Dengan adanya buku ini, akan membantu permasalahan penugasan mahasiswa dan menjadi bahan buku ajar dosen di mata kuliah ekonomi makro, bahkan statistika. Karena aplikasi dari buku ini sudah dapat mewakili jawaban terbentuknya penggunaan metode statistika dan mata kuliah ekonomi makro. Sehingga pada dasarnya mata kuliah tersebut akan menjadi variatif.

Penulis menyadari bahwa selesainya buku ini adalah berkat bantuan semua pihak, baik secara langsung maupun tidak langsung. Semoga Buku ini bermanfaat bagi penulis, mahasiswa khususnya dan para pembaca lainnya pada umumnya.

Pamekasan, 11 Desember 2023

Penulis

Daftar Isi

Cover	i
Halaman Judul	ii
Kata Pengantar	iii
Daftar Isi	iv
Bagian 1:	
Peramalan <i>Inflow</i> Dan <i>Outflow</i>	1
Bagian 2:	
Efek Variasi Kalender	4
Bagian 3:	
Persamaan GSTAR.....	6
Bagian 4:	
Pemilihan Bobot	10
Bagian 5:	
Pemilihan Model dan IHK (Indeks Harga Konsumen)	15
Bagian 6:	
Struktur Data Pemodelan GSTARX	18
Bagian 7:	
Pemodelan Data <i>Inflow</i> dan <i>Outflow</i>	22
Bagian 8:	
Peramalan Data <i>Inflow</i> dan <i>Outflow</i> GSTARX	95
Daftar Pustaka	107

BAGIAN 1

PERAMALAN *INFLOW* DAN *OUTFLOW*

Peramalan telah menjadi bagian penting dalam kehidupan manusia di berbagai aspek. Oleh karena itu, penerapan dan pengembangan studi peramalan telah meningkat seiring berjalannya waktu untuk menjawab semua kebutuhan manusia¹. Peramalan dapat membantu manusia dalam merencanakan masa depan dan membuat keputusan yang rasional. Model peramalan yang paling populer digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA).

Pengembangan model ARIMA dengan melibatkan variabel eksogen disebut model ARIMAX. Dalam hal ini, X merupakan notasi dari variabel eksogen. X berupa metrik dikenal dengan model Fungsi Transfer², sedangkan untuk X non-metrik dikenal dengan Model Intervensi³ dan Model Variasi Kalender⁴.

Perkembangan pemodelan *time series*, terutama pemodelan untuk data multivariat, cukup pesat dan hasil akurasi ramalan lebih baik jika melibatkan suatu eksogen, salah satu contohnya adalah model *Generalized Space Time Autoregressive* (GSTAR). Namun, dalam penerapannya pada pengembangan model GSTAR yang melibatkan suatu variabel eksogen masih belum banyak dilakukan. Dan juga, estimasi parameter pemodelan *spatio temporal* masih terbatas dengan

1 Jon Scott Armstrong, *Principles of Forecasting: A Handbook for Researchers and Practitioners*, vol. 30 (Springer Science & Business Media, 2001).

2 George EP Box et al., *Time Series Analysis: Forecasting and Control* (John Wiley & Sons, 2015).

3 Bruce L. Bowerman and Richard T. O'Connell, "Forecasting and Time Series: An Applied Approach. 3rd," 1993.

4 Chung Chen and Lon-Mu Liu, "Forecasting Time Series with Outliers," *Journal of Forecasting* 12, no. 1 (1993): 13–35.

menggunakan *Ordinary Least Square* atau OLS⁵. Terzi berpendapat estimasi parameter dengan OLS pada model GSTAR kurang efisien dikarenakan residual saling berkorelasi. *Generalized Least Square* (GLS) adalah salah satu alternatif metode estimasi parameter untuk residual yang saling berkorelasi⁶. Penelitian ini akan menggunakan model GSTAR dengan variabel eksogen (GSTARX), khususnya dengan metode estimasi parameter GLS yang selanjutnya ditulis dengan GSTARX-GLS.

Studi kasus yang akan digunakan adalah data *inflow* (penyetoran uang) dan *outflow* (penarikan uang) di Provinsi Jawa Timur. Istilah *Inflow* diartikan untuk kegiatan bank umum melakukan penyetoran uang ke Bank Indonesia, sedangkan *outflow* adalah kegiatan bank umum melakukan penarikan Uang yang masih Layak Edar (ULE) dari Bank Indonesia⁷. Kegiatan *inflow* dan *outflow* dilakukan untuk memenuhi ketersediaan uang yang ada di masyarakat melalui semua bank yang ada di Indonesia. Jumlah *outflow* dan *inflow* akan meningkat cukup tinggi di Jawa Timur pada momen perayaan tertentu seperti Hari Raya Idul Fitri⁸. Dikarenakan momen Hari Raya Idul Fitri terjadi tiap tahun, maka data tersebut mengalami efek variasi kalender. Adanya kenaikan konsumsi pada momen Hari Raya Idul Fitri menjadikan alasan Indeks Harga Konsumen (IHK) mempengaruhi jumlah *inflow* dan *outflow* yang akan digunakan sebagai eksogen metrik.

5 Budi Nurani Ruchjana, "Pemodelan Kurva Produksi Minyak Bumi Menggunakan Model Generalisasi STAR," in *Forum Statistika Dan Komputasi*, 2002, 01–06.

6 Arnold Zellner, "An Efficient Method of Estimating Seemingly Unrelated Regressions and Tests for Aggregation Bias," *Journal of the American Statistical Association* 57, no. 298 (1962): 348–68.

7 Tim Informasi Hukum, *Surat Edaran Bank Indonesia Nomor 13/9/DPU Tanggal 5 April 2011 Perihal Penyetoran Dan Penarikan Uang Rupiah Oleh Bank Umum Di Bank Indonesia* (Direktorat Hukum, 2011).

8 Manager Divisi Asesmen Ekonomi dan Keuangan, "Kajian Ekonomi Regional Jawa Timur Triwulan I – 2014. Kantor Perwakilan Bank Indonesia Wilayah IV" (Kantor Perwakilan Bank Indonesia Wilayah IV, 2014).

Penulisan ini dapat memperkaya konsep atau teori yang menyokong perkembangan ilmu ekonometrika, khususnya yang terkait dengan peramalan. Selain itu penelitian ini menunjukkan bahwa adanya efek idul fitri dan IHK dapat memperlihatkan hasil ramalan yang lebih baik dibandingkan dengan mengabaikan kedua efek hal ini, sehingga hasil penelitian ini dapat memberikan informasi kepada para penulisan lain yang akan melakukan penelitian dibidang yang sama untuk pengembangan suatu teori lebih lanjut mengenai peramalan.

BAGIAN 2

EFEK VARIASI KALENDER

Secara umum, efek variasi kalender Lebaran data *inflow* Kota Surabaya dan Kediri pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2, atau terjadi 1 bulan setelahnya jika tanggal hari raya tersebut terdapat di minggu ke-3 dan ke-4. Sedangkan pada Kota Malang dan Kabupaten Jember, efek variasi kalender Lebaran terjadi pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2, atau terjadi 1 bulan setelahnya jika tanggal hari raya tersebut terdapat di minggu ke-4.

Selanjutnya, data *outflow* di Kota Surabaya, Malang dan Kediri mengalami efek variasi kalender Lebaran pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-2, 3 dan 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2. Sedangkan pada *outflow* di Kabupaten Jember mengalami efek variasi kalender Lebaran pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-3 dan 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan 3.

Model GSTARX-GLS pada level dua yang terbentuk pada kajian terapan adalah GSTARX (3₁) untuk data *inflow* dan GSTAR ([1,3]₁) untuk data *outflow* di empat kota/kabupaten di Jawa Timur.

Pemodelan data *inflow* terbaik adalah *full model* GSTARX dengan bobot invers jarak berdasarkan data *in sample* dengan RMSE total terkecil. Sedangkan model terbaik berdasarkan *out sample* dengan RMSE terkecil adalah model GSTRAX dengan bobot normalisasi korelasi silang.

Pemodelan data *outflow* terbaik adalah *full model* GSTARX dengan bobot invers jarak berdasarkan data *in sample* dengan

RMSE total terkecil. Sedangkan model terbaik berdasarkan *out sample* dengan RMSE total terkecil adalah model GSTARX dengan bobot seragam.

Peramalan data *inflow* dan *outflow keempat* Kota/Kabupaten di Jawa Timur sudah cukup baik dengan menggunakan model GSTARX-GLS. Hal ini bisa dilihat bahwa nilai ini lebih kecil dibandingkan dengan standart deviasi.

BAGIAN 3

PERSAMAAN GSTAR

A. Variasi Kalender

Model variasi kalender berdasarkan model analisis regresi dengan variabel *dummy* untuk efek variasi kalender dengan asumsi tambahan *trend* stokastik (*differencing* non musiman atau musiman) dan *trend* deterministik (tanpa *differencing*). Prosedur pembentukan model yang dimaksud adalah sebagai berikut:

- a. Menentukan variabel *dummy* untuk periode variasi kalender.
- b. Menentukan tipe *trend*, yaitu

$$\begin{aligned}
 & - \text{Trend stokastik} : \\
 & y_t = \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_P V_{P,t} + \\
 & \frac{\theta_q(B)\Theta_q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} w_t \quad (2.1)
 \end{aligned}$$

$$\begin{aligned}
 & - \text{Trend deterministik} : \\
 & y_t = \gamma t + \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_P V_{P,t} + \\
 & \frac{\theta_q(B)\Theta_q(B^S)}{\phi_p(B)\Phi_P(B^S)} w_t \quad (2.2)
 \end{aligned}$$

- c. Melakukan cek diagnosa pada residual w_t dengan prosedur Box-Jenkins.
- d. Jika w_t belum *white noise* maka lag yang signifikan berdasarkan plot ACF dan PACF ditambahkan sebagai variabel prediktor. Dan melakukan estimasi ulang model yang terdapat pada persamaan (2.1) atau (2.2) dan cek diagnosa kembali sampai w_t telah *white noise*⁹.

9 M. Lee and N. Hamzah, "Calendar Variation Model Based on ARIMAX for Forecasting Sales Data with Ramadhan Effect," in *Proceedings of the Regional Conference on Statistical Sciences*, 2010, 349–61.

B. Fungsi Transfer

Model ini adalah 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 dan berdasarkan pula pada satu atau lebih deret waktu yang lain (*input series* atau x_t) yang berhubungan dengan *output series* tersebut. Bentuk umum model fungsi transfer untuk input tunggal, x_t , dan output tunggal, y_t , adalah¹⁰:

$$y_t = v_0x_t + v_1x_{t-1} + v_2x_{t-2} + \dots + e_t \quad (2.3)$$

$$y_t = v(B)x_t + e_t \quad (2.4)$$

dengan:

y_t : representasi dari deret output yang stasioner

x_t : representasi dari input yang stasioner

e_t : representasi dari variabel *error* (deret *noise*) yang mengikuti suatu model ARIMA tertentu.

$v(B) = v_0 - v_1B - v_2B - \dots$ merupakan koefisien model fungsi transfer atau bobot respon impuls.

C. Model Vector Autoregressive Moving Average (VARMA)

VARMA adalah salah satu analisis *time series* multivariat yang menggunakan banyak variabel secara bersamaan. Seperti pada ARMA, analisis ini juga memperhatikan stasioneritas data dan hal ini dapat dilihat dari plot dari *Matrix Cross Correlation Function* (MCCF) dan *Matrix Partial Cross Correlation Function* (MPCCF) serta plot *Box-Cox*. Perlakuan terhadap data multivariat yang tidak stasioner sama dengan data univariat yang tidak stasioner. Data multivariat yang tidak stasioner dalam varians di transformasi agar data dapat stasioner, dan jika tidak stasioner dalam rata-rata dilakukan *differencing* untuk men-stasioner-kannya. Jika diberikan $y_i(t)$

¹⁰ William WS Wei, "Time Series Analysis," in *The Oxford Handbook of Quantitative Methods in Psychology*: Vol. 2, 2006.

dengan $t \in T$, $T = \{1, 2, \dots, T\}$ dan $i = \{1, 2, \dots, N\}$ yang merupakan indeks parameter waktu dan variabel yang dihitung dan terbatas, maka model VARMA secara umum dapat dinyatakan dalam persamaan sebagai berikut.¹¹

$$\Phi_p(B)Y(t) = \Theta_q(B)a(t) \quad (2.5)$$

dengan $Y(t)$ adalah vektor *time series* multivariat yang terkoreksi nilai rata-rata, $\Phi_p(B)$ dan $\Theta_q(B)$ berturut-turut adalah suatu matriks AR dan MA polinomial orde p dan q .

Dalam analisis deret waktu sering dijumpai data-data yang tidak stasioner. Model VARMA yang tidak stasioner dapat dinyatakan dalam bentuk persamaan.¹²

$$\Phi_p(B)D(B)Y(t) = \Theta_q(B)a(t) \quad (2.6)$$

dengan $D(B) = \text{diag}((1 - B)^{d_1}, (1 - B)^{d_2}, \dots, (1 - B)^{d_m})$. Pembentukan model VARIMA dilakukan melalui tahapan identifikasi (menggunakan plot *time series*, MCCF, MPCCF, dan nilai AICc) untuk penentuan orde model, estimasi parameter dilakukan menggunakan metode *Least Square* atau *Maximum Likelihood*, cek diagnosa (dilakukan pengecekan apakah residual dari model telah memenuhi syarat *white noise*, melalui MCCF, MPCCF, dan nilai AICc dari residual) dan akhirnya dilakukan peramalan.

D. Model Generalized Spatio Temporal Autoregressive (GSTAR)

Model GSTAR merupakan salah satu suatu model *multivariate time series* yang lebih fleksibel sebagai generalisasi dari model *Space-Time Autoregressive* (STAR) yang juga merupakan spesifikasi dari model *Vector Autoregressive* (VAR). Model GSTAR dari orde *autoregressive* (waktu) dan orde spasial $\lambda_1, \lambda_2, \dots, \lambda_p$, GSTAR ($p; \lambda_1, \lambda_2, \dots, \lambda_p$) dalam notasi matriks dapat ditulis sebagai berikut¹³:

¹¹ Wei.

¹² Wei.

¹³ Svetlana Borovkova, Hendrik P. Lopuhaä, and Budi Nurani Ruchjana, "Consistency and Asymptotic Normality of Least Squares Estimators in Generalized STAR Models," *Statistica Neerlandica* 62, no. 4 (2008): 482–508.

$$Y(t) = \sum_{k=1}^p \left[\Phi_{k0} Y(t-k) + \sum_{l=1}^{\lambda_p} \Phi_{kl} W^{(l)} Y(t-k) \right] + \varepsilon(t) \quad (2.7)$$

dengan :

$\Phi_{k0} = \text{diag}(\phi_{k0}^{(1)}, \dots, \phi_{k0}^{(N)})$ merupakan matrik parameter waktu,

$\Phi_{kl} = \text{diag}(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(N)})$ merupakan matrik parameter spasial,

$\varepsilon(t)$: vektor *noise* ukuran $(N \times 1)$ yang independen, identik, berdistribusi normal multivariat dengan mean nol dan matriks varians-kovarians $\sigma^2 \mathbf{I}_N$.

Nilai pembobot dipilih sedemikian hingga, sampai memenuhi syarat $w_{ii}^{(k)} = 0$ dan $\sum_{i \neq j} w_{ij}^{(k)} = 1$. Dalam mengidentifikasi orde model GSTAR, orde spasial pada umumnya dibatasi pada orde satu karena orde yang lebih tinggi akan sulit untuk diinterpretasikan¹⁴.

14 D. U. Wutsqa, Sutijo B. Suhartono, and B. Sutijo, "Generalized Space-Time Autoregressive Modeling," in *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and Its Applications (ICMSA2010)*, 2010.

BAGIAN 4

PEMILIHAN BOBOT

1. Pemilihan Bobot pada Model GSTAR

Salah satu permasalahan utama dalam pembentukan model GSTAR adalah dalam menentukan bobot lokasi yang sesuai untuk diterapkan pada data *time eries* yang kan dianalisis. Suhartono¹⁵ memberikan beberapa macam 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 korelasi silang.

a. Bobot Seragam (*Uniform*)

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

$$w_{ij} = \frac{1}{s_i} \quad (2.8)$$

dengan s_i adalah banyaknya lokasi yang berdekatan dengan lokasi ke- i . Sehingga untuk contoh kasus tiga lokasi, matriks pembobotnya adalah sebagai berikut:

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

15 Suhartono Suhartono, "A Comparative Study of Forecasting Models for Trend and Seasonal Time Series Does Complex Model Always Yield Better Forecast than Simple Models," *Jurnal Teknik Industri* 7, no. 1 (2005): 22–30.

b. Bobot Biner (*Binary*)

Metode dengan pembobot biner hanya bergantung pada keadaan yang terbatas. Pembobotan dengan metode biner memiliki pembobot dengan $w_{ij} = 0$ atau 1.

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

c. Bobot Invers Jarak

Pembobotan dengan metode *invers* jarak dilakukan berdasarkan jarak sebenarnya antar lokasi. Perhitungan bobot dengan metode *invers* jarak diperoleh dari normalisasi hasil *invers* jarak sebenarnya. Pada contoh dengan tiga lokasi dimisalkan diketahui jarak antar lokasi seperti yang disajikan pada Tabel 1

Tabel 1 Jarak Contoh Tiga Lokasi

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

Sedangkan secara umum perhitungan bobot *invers* jarak masing-masing lokasi adalah:

$$w_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_{j=1}^s \frac{1}{d_{ij}}}, j \neq i \quad (2.9)$$

d. Bobot Normalisasi Korelasi Silang

Pembobotan dengan metode normalisasi korelasi silang adalah menggunakan hasil normalisasi korelasi silang antar lokasi pada *lag* yang bersesuaian. Secara umum korelasi

silang antara lokasi ke- i dan ke- j pada lag waktu ke- k , $corr[Y_i(t), Y_j(t - k)]$, didefinisikan sebagai: ¹⁶

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j}, k=0, \pm 1, \pm 2, \dots \quad (2.10)$$

dengan $\gamma_{ij}(k)$ merupakan kovarians silang antara kejadian di lokasi ke- i dan ke- j . Taksiran dari korelasi silang ini pada sampel dapat hitung dengan persamaan berikut:

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [Y_i(t) - \bar{Y}_i][Y_j(t-k) - \bar{Y}_j]}{\sqrt{(\sum_{t=k+1}^n [Y_i(t) - \bar{Y}_i]^2)(\sum_{t=k+1}^n [Y_j(t) - \bar{Y}_j]^2)}} \quad (2.11)$$

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

$$w_{ij} = \frac{r_{ij}(1)}{\sum_{k \neq i} |r_{ij}(1)|}, \text{ dengan } i \neq j \text{ dan } \sum_{k \neq i} |w_{ij}| = 1 \quad (2.12)$$

e. Bobot Normalisasi Inferensia Korelasi Silang Parsial

Pembobotan normalisasi inferensia korelasi silang parsial tidak jauh berbeda dengan pembobotan normalisasi korelasi silang. Secara umum korelasi silang antara lokasi ke- i dan ke- j pada lag waktu ke- k , $corr[Y_i(t), Y_j(t - k)]$, Hipotesis yang menyatakan dua data deret waktu Z_i dan Z_j adalah tidak berkorelasi yang menunjukkan bahwa

$$Varians[r_{ij}(k)] \cong \frac{1}{n-k} [1 + 2 \sum_{s=1}^{\infty} \rho_{ii}(s) \rho_{jj}(s)] \quad (2.13)$$

Sehingga ketika Z_i dan Z_j merupakan deret yang *white noise* maka diperoleh :

$$Varians[r_{ij}(k)] \cong \frac{1}{n-k} \quad (2.14)$$

Untuk ukuran sampel yang besar, $(n - k)$ dalam persamaan (2.14) seringkali digantikan dengan n . Berdasarkan asumsi

¹⁶ Box et al., *Time Series Analysis*.

distribusi normal, korelasi silang diestimasi dari sampel yang dapat diuji signifikan berbeda dari nol. Proses inferensi statistik parsial dilakukan dengan taksiran interval seperti pada persamaan berikut.

$$r_{ij}(k) \pm \left[t_{(\frac{\alpha}{2}; (n-k-2))} \frac{1}{\sqrt{n}} \right] \quad (2.15)$$

Penentuan bobot lokasi dapat dilakukan melalui normalisasi dari hasil besar-besaran korelasi silang antar lokasi pada waktu yang bersesuaian. Proses ini secara umum menghasilkan bobot lokasi dengan menggunakan normalisasi dari hasil inferensi statistik parsial terhadap korelasi silang antar lokasi pada lag waktu yang bersesuaian ini memungkinkan semua bentuk kemungkinan hubungan antar lokasi. Dengan demikian, tidak ada lagi batasan yang kaku tentang besarnya bobot, terutama yang bergantung dari jarak antar lokasi. Bobot ini juga memberikan fleksibilitas pada besar dan tanda hubungan antar lokasi yang bisa berlainan (positif dan negatif).

2. Regresi dengan Residual Berkorelasi

Penggunaan analisis regresi pada persamaan (2.42) dengan metode OLS mengakibatkan estimasi $\hat{\beta}$ bias dan tidak konsisten dikarenakan adanya korelasi antar residual e_i .¹⁷ Wei menawarkan metode yang terdiri dari dua level tahapan, yaitu:

1. Tahapan Level 1 adalah sebagai berikut:
 - a. Membentuk model regresi yang akan diestimasi, misal seperti pada persamaan (2.43).
 - b. Menghitung residual e_i dari persamaan (2.43) dengan OLS.
2. Tahapan Level 2 adalah sebagai berikut:
 - a. Memodelkan residual e_i dengan persamaan (2.63) berikut.

¹⁷ Wei, "Time Series Analysis."

$$e_{i,t} = \varphi_1 \varepsilon_{t-1} + \dots + \varphi_p \varepsilon_{t-p} + n_t \quad (2.16)$$

- b. Mengestimasi φ_j dan σ^2 dalam model AR (p) dengan metode OLS.
- c. Menghitung Ω berdasarkan nilai φ_j dan σ^2 dari tahap (b).
- d. Menghitung penaksir GLS, $\hat{\beta} = (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}Y$.

3. Cek Diagnosa Model

Cek diagnosa model dilakukan untuk mengetahui apakah model dugaan sudah memenuhi syarat kebaikan model atau belum. Suatu model dikatakan layak jika parameter model signifikan dan residual dari model memenuhi asumsi *white noise* dan kenormalan. Uji asumsi *white noise* dengan cara memodelkan ulang residual yang didapatkan dari model dan melakukan pengecekan letak nilai AICc terkecil. Jika nilai AICc terkecil terletak pada AR(0) dan MA(0) maka dikatakan residual dari model telah memenuhi asumsi *white noise*.

Corrected Akaike's Information Criterion (AICc) adalah suatu kriteria pemilihan model terbaik AIC dengan tambahan koreksi untuk sampel kecil atau terbatas (*finite*). AICc dikembangkan oleh Hurvich dan Tsai¹⁸ untuk mengatasi bias pada AIC dimana bias yang dihasilkan Rumus AIC adalah sebagai berikut:

$$AIC(k) = n \ln \hat{\sigma}_a^2 + 2k \quad (2.17)$$

Dengan $\hat{\sigma}_a^2$ adalah nilai varians residual dengan estimasi *maximum likelihood*, k adalah banyaknya parameter dalam model, n adalah banyaknya observasi. Sedangkan rumus AICc adalah sebagai berikut:

$$AICc(k) = AIC(k) + \frac{2(k+1)(k+2)}{n-k-2} \quad (2.18)$$

18 Clifford M. Hurvich and Chih-Ling Tsai, "Regression and Time Series Model Selection in Small Samples," *Biometrika* 76, no. 2 (1989): 297–307.

BAGIAN 5

PEMILIHAN MODEL DAN IHK (INDEKS HARGA KONSUMEN)

1. Kriteria Pemilihan Model Terbaik

Model terbaik dipilih pada data *out-sample* jika memiliki nilai RMSE terkecil. Tujuan utama dari peramalan adalah untuk menghasilkan hasil peramalan yang optimum dimana hanya terdapat error yang sangat kecil. Oleh karena itu, digunakan RMSE (Root Mean Square Error) untuk mengetahui error dari sebuah peramalan. Berikut ini adalah persamaan dari RMSE¹⁹:

$$RMSE = \sqrt{\frac{1}{M} \sum_{l=1}^M (Y_{n+l} - \hat{Y}_n(l))^2} \quad (2.17)$$

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

2. Penyetoran (*Inflow*) dan Penarikan Uang (*Outflow*) oleh Bank Umum di Bank Indonesia

Bank Indonesia mempunyai otonomi penuh dalam merumuskan dan melaksanakan setiap tugas dan wewenangnya sebagaimana ditentukan dalam undang-undang. Salah satu fungsi dan peran dari status dan kedudukan Bank Indonesia yaitu mengatur dan mengawasi bank umum di Indonesia.

Tahun 2011, Bank Indonesia mengeluarkan surat edaran kepada semua bank umum di Indonesia mengenai beberapa aturan dalam kegiatan penyetoran dan penarikan uang dalam meningkatkan efektifitas dan efisiensi manajemen kas perbankan serta mengoptimalkan pengolahan uang oleh perbankan²⁰. Kegiatan *inflow* dan *outflow* dilakukan untuk

¹⁹ Wei, "Time Series Analysis."

²⁰ Tim Informasi Hukum, *Surat Edaran Bank Indonesia Nomor 13/9/DPU Tanggal 5 April 2011 Perihal Penyetoran Dan Penarikan Uang Rupiah Oleh Bank Umum Di Bank Indonesia*.

memenuhi ketersediaan uang yang ada di masyarakat melalui semua bank yang ada di Indonesia.

3. Indeks Harga Konsumen (IHK)

Indikator yang sering digunakan untuk mengukur kenaikan harga adalah Indeks Harga Konsumen (IHK). Perubahan IHK dari waktu ke waktu menunjukkan pergerakan harga dari paket barang dan jasa yang dikonsumsi masyarakat. Sejak Juli 2008, paket barang dan jasa dalam keranjang IHK telah dilakukan dengan berpedoman pada Survei Biaya Hidup (SBH) Tahun 2007 yang dilaksanakan oleh Badan Pusat Statistik (BPS). Kemudian, BPS akan memonitor perkembangan harga dari barang dan jasa tersebut secara bulanan di beberapa kota, di pasar tradisional dan modern terhadap beberapa jenis barang/jasa di setiap kota. Laju inflasi sendiri dihitung berdasarkan besarnya IHK, dengan persamaan sebagai berikut²¹.

$$\text{Inflasi} = \text{IHK}_t - \text{IHK}_{t-1} \quad (2.5)$$

dengan IHK dapat dihitung dengan persamaan (2.51).

$$\text{IHK} = \frac{P_{ti}}{P_{oi}} \times 100\% \quad (2.6)$$

Salah satu modifikasi penghitungan indeks harga berdasarkan pendekatan Laspeyres adalah,

$$I_t = \frac{\sum_{i=1}^k \frac{P_{ti}}{P_{(t-1)i}} \times (P_{(t-1)i} \times Q_{oi})}{\sum_{i=1}^k P_{oi} \times Q_{oi}} \times 100 \quad (2.7)$$

dengan

I_t = indeks bulan ke- t

P_{ti} = harga jenis barang i , bulan ke- t

$P_{(t-1)i}$ = harga jenis barang i , bulan ke- $(t - 1)$

$P_{(t-1)i} \times Q_{oi}$ = nilai konsumsi jenis barang i , bulan ke- $(t - 1)$

21 Pusat Riset dan Edukasi Bank Sentral (PRES), "Kodifikasi Peraturan Bank Indonesia Sistem Pembayaran Tunai Pengelolaan Uang Rupiah" (Bank Indonesia, 2013).

$P_{0i} \times Q_{0i}$ = nilai konsumsi jenis barang i , pada tahun dasar

k = banyaknya jenis barang paket komoditas dalam sub kelompok, kelompok kota bersangkutan.

BAGIAN 6

STRUKTUR DATA PEMODELAN GSTARX

Struktur data yang digunakan terbagi menjadi dua, yaitu untuk data *inflow* dan *outflow* dan berdasarkan penentuan *dummy* juga dibedakan menjadi dua, yaitu struktur data untuk prediktor berupa variabel *dummy* dan berupa variabel metrik, yaitu data Indek Harga Konsumen (IHK). Variabel *dummy* digunakan untuk menyatakan efek variasi kalender. Variabel *dummy* yang digunakan adalah *dummy* dengan periode mingguan pada periode satu bulan terjadinya Idul Fitri, dan periode satu bulan setelah terjadinya Idul Fitri. Pusat Riset dan Edukasi Bank Sentral (PRES) Bank Indonesia (2013) memiliki definisi sendiri dalam penentuan periode mingguan pada Tabel 3 sebagai berikut.

Tabel 2 Jarak Antar Lokasi di Empat Lokasi di Jawa Timur

Lokasi	Jarak ke (km)			
	Kota Surabaya	Kota Malang	Kota Kediri	Kabupaten Jember
Kota Surabaya	0	80,05	101,67	141,89
Kota Malang	80,05	0	63,98	113,74
Kota Kediri	101,67	63,98	0	182,10
Kabupaten Jember	141,89	113,74	182,10	0

Sumber : www.maps.google.com (diolah)

Tabel 3 Ketentuan Periode Mingguan

Minggu	Tanggal
1	01, 02, 03, 04, 05, 06, dan 07
2	08, 09, 10, 11, 12, 13, 14 dan 15
3	16, 17, 18, 19, 20, 21, 22 dan 23
4	Untuk bulan Februari bukan Tahun Kabisat, yaitu; 24, 25, 26, 27, dan 28

Untuk bulan Februari Tahun Kabisat, yaitu;

24, 25, 26, 27, 28 dan 29

Untuk bulan April, Juni, September dan November, yaitu;

24, 25, 26, 27, 28, 29, dan 30

Dan bulan Januari, Maret, Mei, Juli, Agustus, Oktober, dan Desember, yaitu;

24, 25, 26, 27, 28, 29, 30, dan 31

Berdasarkan ketentuan tersebut, untuk pemodelan data *inflow* didapatkan persamaan sebagai berikut.

$$M_{i,t} = \begin{cases} 1 & , \text{bulan ke-}t \text{ dengan momen Idul Fitri di minggu ke-}i \\ 0 & , \text{untuk bulan yang lain} \end{cases}$$

(3.1)

$$M_{i,t+1} = \begin{cases} 1 & , \text{bulan ke-}(t + 1) \text{ dengan momen Idul Fitri di minggu ke-}i \\ 0 & , \text{untuk bulan yang lain} \end{cases}$$

Berdasarkan ketentuan tersebut, untuk pemodelan data *outflow* didapatkan persamaan sebagai berikut.

$$M_{i,t} = \begin{cases} 1 & , \text{bulan ke-}t \text{ dengan momen Idul Fitri di minggu ke-}i \\ 0 & , \text{untuk bulan yang lain} \end{cases}$$

(3.2)

$$M_{i,t-1} = \begin{cases} 1 & , \text{bulan ke-}(t - 1) \text{ dengan momen Idul Fitri di minggu ke-}i \\ 0 & , \text{untuk bulan yang lain} \end{cases}$$

Sedangkan tanggal Hari Raya Idul Fitri dari Tahun 2003 sampai dengan 2014 dapat dilihat pada Tabel 4 sebagai berikut.

Tabel 4 Tanggal Hari Raya Idul Fitri pada Tahun 2003-2011

Tahun	Tanggal Hari Raya Idul Fitri
2003	25-26 November
2004	14-15 November
2005	03-04 November
2006	23-24 Oktober
2007	12-13 Oktober
2008	01-02 Oktober
2009	21-22 September
2010	10-11 September
2011	30-31 Agustus
2012	19-20 Agustus
2013	08-09 Agustus
2014	28-29 Juli

Tahapan yang dijelaskan adalah tahapan pembentukan model GSTARX. Tahapan-tahapannya adalah sebagai berikut:

- a. Melakukan pemodelan GSTARX pada kedua data tersebut adalah dengan langkah-langkah sebagai berikut:
 - 1) Melakukan analisis deskriptif terhadap data *inflow* dan *outflow* empat kota di Jawa Timur
 - 2) Tahap identifikasi, dengan langkah-langkah sebagai berikut:
 - I. Pada tahapan ini ada dua langkah yang dilakukan, yaitu:
 - i. Identifikasi model variasi kalender
 - ii. Identifikasi model fungsi transfer pada masing-masing data *inflow* dan *outflow* yaitu sebagai berikut:
 - 3) Tahap estimasi, dengan langkah-langkah sebagai berikut:
 - I. Melakukan Tahapan Level 1, dimana dari tahap identifikasi untuk estimasi parameter model variasi

- kalender dan model fungsi transfer digabung menjadi satu persamaan dengan estimasi OLS.
- II. Melakukan Tahapan Level 2, dimana residual u_t dari keempat lokasi yang didapatkan dibentuk model GSTAR dengan bobot lokasi menggunakan bobot seragam, invers jarak, normalisasi korelasi silang dan normalisasi inferensia korelasi silang parsial.
 - III. Menguji signifikansi parameter model GSTARX-OLS dan GSTARX-GLS. Jika terdapat parameter-parameter yang tidak signifikan, dilakukan *restricted* dengan metode *backward*.
 - IV. Mendapatkan model GSTARX-OLS dan GSTARX-GLS.
- 4) Melakukan peramalan dari model GSTARX-OLS dan GSTARX-GLS pada *in-sample* dan *out-sample* di masing-masing data *inflow* dan *outflow* di Surabaya, Malang, Kediri, dan Jember
 - 5) Melakukan cek diagnosa terhadap model yang didapatkan dengan melakukan pengujian *white noise* menggunakan nilai AIC terkecil dari residual.
- b. Membandingkan hasil peramalan GSTARX-OLS dan GSTARX-GLS menggunakan kriteria model RMSE untuk data *in-sample* dan *out-sample*.
 - c. Mendapatkan model terbaik berdasarkan data *in-sample* dan *out-sample*.

BAGIAN 7

PEMODELAN DATA *INFLOW* DAN *OUTFLOW*

A. Pemodelan Data *Inflow* dan *Outflow* Di Provinsi Jawa Timur

Sebelum dilakukan pemodelan dengan GSTARX, data *inflow* dan *outflow* dilakukan tahap deskripsi dan eksplorasi. Berikut hasil dari pembahasan dan hasil dari tahapan eksplorasi tersebut.

1. Karakteristik Data *Inflow* dan *Outflow* Jawa Timur

Secara umum, nilai-nilai deskripsi untuk tiap Kota/Kabupaten *Inflow* dan *Outflow* lebih jelasnya dapat dilihat pada Tabel 5

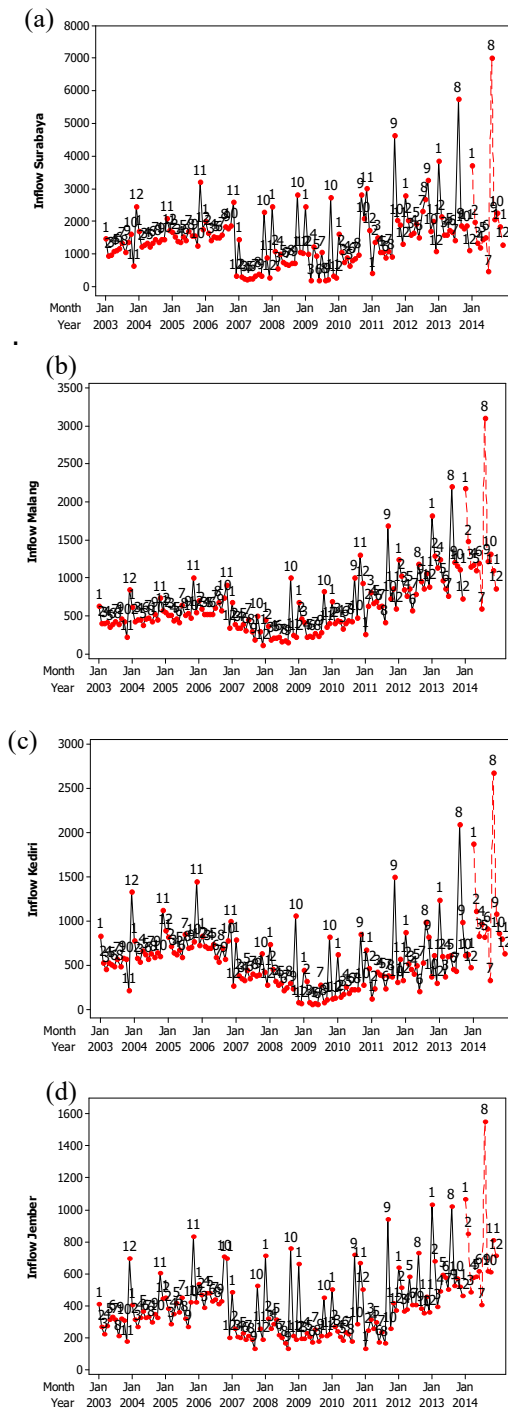
Tabel 5 Statistika Deskriptif Data *Inflow* dan *Outflow* di Jawa Timur

Jenis Data	Kota/Kabupaten	Mean	Standart Deviasi	Minimum	Maksimum
<i>Inflow</i>	Surabaya	1501.4	974.0	179.3	7006.3
	Malang	660.6	433.9	110.7	3107.4
	Kediri	575.0	377.7	58.7	2673.3
	Jember	405.1	221.6	129.2	1552.0
<i>Outflow</i>	Surabaya	1387.8	1072.8	43.1	6489.1
	Malang	398.2	340.9	5.0	2932.6
	Kediri	592.1	475.0	5.5	3286.4
	Jember	303.3	232.9	5.3	1733.1

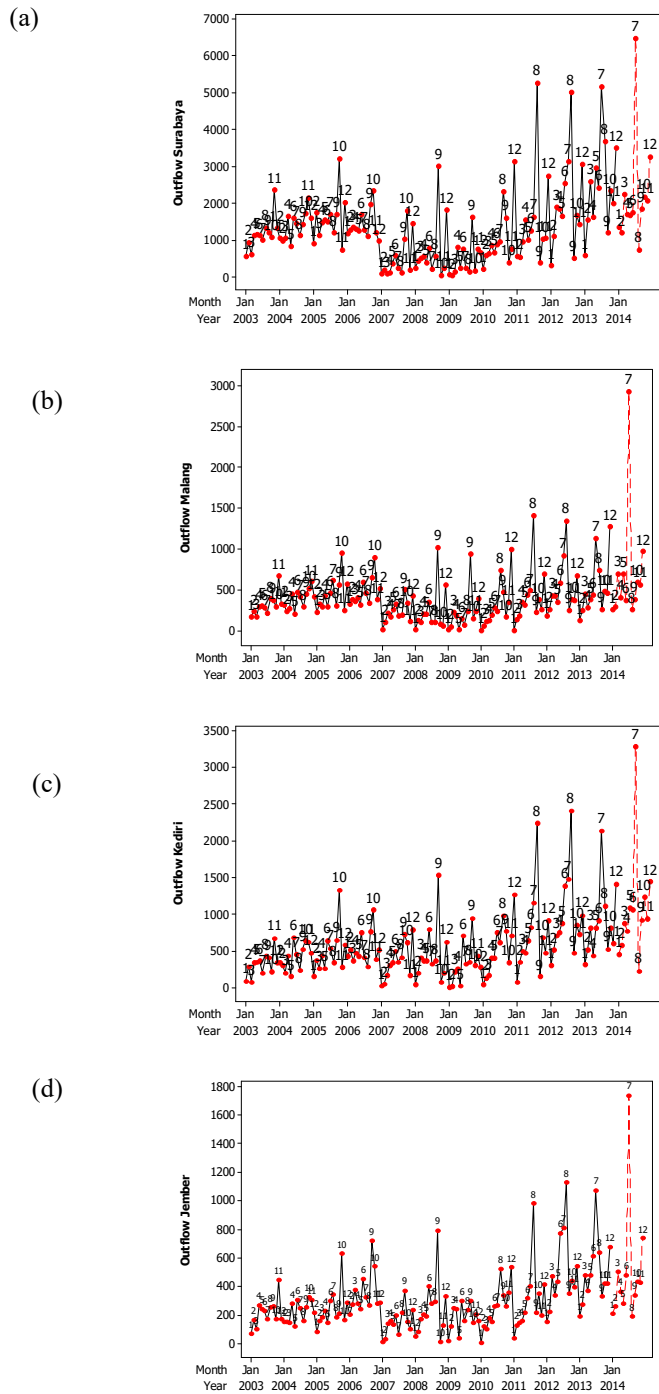
Tabel 5 menjelaskan bahwa *mean* (rata-rata) data *inflow* di Surabaya, Malang, Kediri dan Jember berturut-turut adalah 1501.4; 660.6; 575.0 dan 405.1, sedangkan rata-rata data *outflow* masing-masing kota berturut-turut 1387.8; 398.2; 592.1; dan 303.3. Dari keempat rata-rata dari kedua jenis data tersebut, Kota Surabaya memiliki rata-rata yang jauh

lebih besar dibandingkan dengan yang dimiliki oleh Kota/Kabupaten lainnya. Hal ini bisa dilihat pada nilai minimum dan maksimum kota Surabaya yang memang memiliki nilai yang jauh lebih besar daripada kota/kabupaten lainnya, yaitu untuk data *inflow* berturut-turut sebesar 179,3 dan 7006.3 dan untuk data *outflow* berturut-turut sebesar 43,1 dan 6489.1. Dengan adanya perbedaan data *inflow* dan *outflow* yang cukup besar antara Kota Surabaya dengan kota/kabupaten lainnya mengakibatkan nilai standart deviasinya juga cukup besar, yaitu sebesar 974.0 untuk *inflow* dan 1072.8 untuk *outflow*. Sedangkan nilai standart deviasi dari ketiga kota/kabupaten lainnya untuk data *inflow* dan *outflow* hanya berada dikisaran 220–475 saja.

Analisis selanjutnya adalah melakukan plot *time series* untuk data *inflow* dan *outflow* di empat kota / kabupaten tersebut di Jawa Timur dari tahun 2003 sampai dengan tahun 2014 seperti yang disajikan dalam Gambar 1. Plotting data berasal dari data *in-sample* dan *out-sample* yang dimasukkan dalam satu gambar agar mendapatkan gambaran umum pola data dari tahun ke tahun.



Gambar 1 Plot Time Series Data *Inflow* (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember



Gambar 2 Plot Time Series Data *Outflow* (a) Surabaya, (b) Malang, (c) Kediri, (d) Jember

Pada Gambar 1 dan 2 dapat dilihat bahwa Kota Surabaya, Malang, Kediri dan Jember memiliki pola yang sama tiap bulannya baik data *inflow* maupun *outflow*. Setiap tahun pada data *in-sample* selalu mengalami kenaikan di satu bulan tertentu. Kondisi ini juga terjadi pada data *out-sample* dimana mengalami kenaikan yang cukup besar pada bulan Agustus untuk data *inflow* dan bulan Juli untuk data *outflow*. Hal ini dikarenakan penentuan 1 Syawal berdasarkan kalender Hijriyah akan selalu berubah-ubah tiap tahunnya jika didasarkan pada kalender Masehi.

Selain memiliki pola yang sama pada tiap kota/kabupaten di masing-masing data *inflow* dan *outflow*, keterkaitan data juga bisa dilihat pada nilai korelasi antar kota tiap data *inflow* dan *outflow*. Pada Tabel 6 dan Tabel 7 menunjukkan korelasi tinggi antar kota yang mengindikasikan bahwa terjadi keterkaitan data *inflow* dan *outflow* antar kota.

Tabel 6 Nilai Korelasi Data *Inflow* di Empat Kota Jawa Timur

Kota	Surabaya	Malang	Kediri	Jember
Surabaya	1			
Malang	0.838	1		
Kediri	0.825	0.697	1	
Jember	0.878	0.832	0.826	1

Tabel 7 Nilai Korelasi Data *Outflow* di Empat Kota Jawa Timur

Kota	Surabaya	Malang	Kediri	Jember
Surabaya	1			
Malang	0.904	1		
Kediri	0.890	0.894	1	
Jember	0.879	0.863	0.934	1

Pada Tabel 6 dan 7 dapat dilihat bahwa korelasi yang terjadi antar kota cukup tinggi, yaitu berkisar antara 0.6-0.9. Hal ini mendukung pernyataan sebelumnya bahwa antar data

inflow ataupun *outflow* di tiap kota/kabupaten saling memiliki keterkaitan yang cukup tinggi.

Selain itu, informasi yang bisa didapatkan dari Gambar 1 dan 2 bahwa terdapat *trend* kenaikan sebanyak tiga *trend* yaitu :

1. *Trend* 1 terjadi pada bulan Januari 2003 sampai dengan bulan Desember 2006.
2. *Trend* 2 terjadi pada bulan Januari 2007 sampai dengan bulan Desember 2010.
3. *Trend* 3 terjadi pada bulan Januari 2011 sampai dengan bulan Desember 2013.


Terjadinya tiga *trend* pada data *inflow* dan *outflow* diakibatkan karena adanya peraturan dari Bank Indonesia yang mempengaruhinya. Diantara *trend* 1 dan 2 yang terjadi diakibatkan adanya penerapan kebijakan uji coba setoran bayaran bank yang diberlakukan dari 28 Oktober 2005 dan kemudian diatur dalam ketentuan sesuai dengan Surat Edaran No.9/37/DPU tanggal 27 Desember 2007 perihal Penyetoran dan Penarikan Uang Rupiah oleh Bank Umum di Bank Indonesia. Kebijakan ini berlaku secara nasional sejak Desember 2006 di seluruh wilayah Kantor BI, sehingga berdampak pada penurunan aliran uang kartal secara signifikan pada tahun 2007. Sedangkan diantara *trend* 2 dan 3 terjadi dikarenakan BI membuat perubahan terhadap mekanisme penyetoran dan penarikan uang rupiah oleh bank umum di Bank Indonesia sebagaimana yang tertuang dalam Surat Edaran No.13/9/DPU pada tahun 2011.

2. Pemodelan ARIMA pada *Inflow* dan *Outflow* di Empat Kabupaten/Kota Jawa Timur

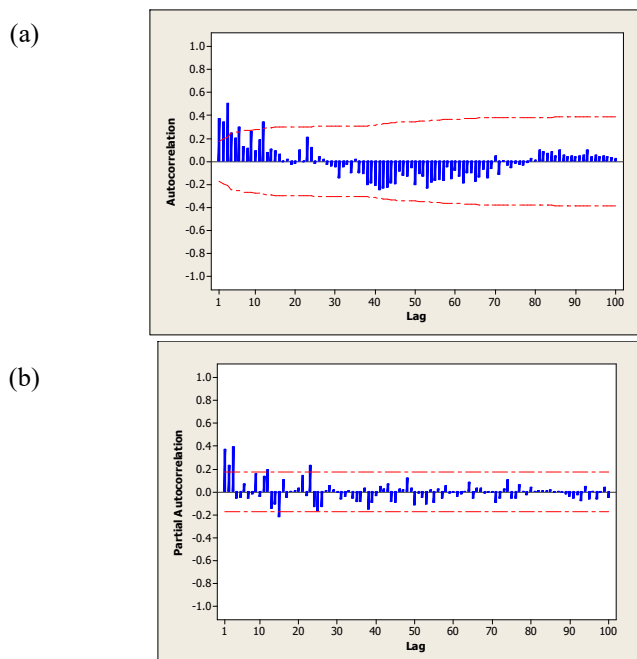
Pada tahapan pemodelan ARIMA menggunakan prosedur Box-Jenkins. Tahap awal yang dilakukan adalah melakukan identifikasi data untuk mengetahui kestasioneran dalam mean dengan melihat plot *time series* dan plot ACF serta kestasioneran dalam varians dengan melihat *time series plot*

dan *Box Cox plot*. Jika tidak stasioner dalam mean, maka data di-*differencing*, serta jika tidak stasioner dalam varians, maka data ditransformasi Box-Cox.

Sebagai contoh prosedur Box Jenkins dalam pemodelan ARIMA digunakan data *inflow* Surabaya. *Box-Cox plot* dan *ACF plot* yang menunjukkan belum stasioner dalam varians dan rata-rata disajikan dalam gambar berikut.




Gambar 3 *Box-Cox Plot Inflow* Surabaya



Gambar 4 (a) Plot ACF dan (b) Plot PACF *Inflow* Surabaya

Berdasarkan *time series plot* tersebut dapat dilihat bahwa data belum stasioner dalam varians karena varians data tersebut berubah-ubah berdasarkan waktu. Hal ini juga diperkuat dengan *Box-Cox plot* pada Gambar tersebut dimana selang interval antara LCL dan UCL pada data tersebut tidak memuat nilai *rounded value* lambda sebesar 1, sehingga perlu dilakukan transformasi. Nilai lambda yang dipilih 0.25 sehingga transformasi yang dilakukan adalah $Y_{1,t}^{0.25}$.

Setelah ditransformasi dan data telah stasioner dalam varians, dilakukan pengecekan stasioneritas dalam *mean* dengan melihat plot *time series* dan plot ACF. Plot *time series* menunjukkan adanya *trend* naik dan pola ACF yang turun lambat menunjukkan data belum stasioner dalam *mean* sehingga perlu dilakukan *differencing* pada data. Hasil *differencing* di lag 12 ditampilkan pada Gambar tersebut. Plot ACF setelah dilakukan *differencing* di lag 12 menunjukkan data telah stasioner dalam *mean* dan varians.



Gambar 5 (a) Plot ACF dan (b) Plot PACF *Inflow* Surabaya setelah *differencing* di lag 12

Setelah asumsi stasioneritas terpenuhi, maka dilakukan penentuan orde model ARIMA dengan melihat pola ACF dan PACF pada Gambar tersebut. Berdasarkan lag-lag yang signifikan pada plot ACF dan PACF, maka diperoleh model ARIMA $[[2][6,23],0,[1][3]](0,1,0)^{12}$. Hasil pengujian signifikansi parameter dapat dilihat pada Tabel berikut.

Tabel 8 Hasil Estimasi Parameter Model ARIMA Pada Data *Inflow* Surabaya

Model ARIMA	Parameter	Estimasi	<i>P-Value</i>
ARIMA $[[2][6,23],0,[1][3]](0,1,0)^{12}$	ϕ_2	0.24	0.01
	ϕ_6	0.22	0.03
	ϕ_{23}	0.31	0.002
	θ_1	-0.19	0.04
	θ_3	-0.51	<0.001

Hasil uji signifikansi parameter pada model menunjukkan bahwa model tersebut memiliki parameter-parameter yang signifikan. Hal ini dilihat berdasarkan *p-value* yang semuanya kurang dari 5%. Untuk hasil signifikansi parameter untuk lokasi lainnya pada data *inflow* dan *outflow* dapat dilihat pada Lampiran.

Setelah estimasi dan uji signifikansi parameter dilakukan, selanjutnya dilakukan pengujian asumsi residual model meliputi uji *white noise* dan distribusi normal. Taraf signifikansi yang digunakan pada kedua uji ini sebesar 0.05. Hasil pengujian asumsi residual *white noise* dan distribusi normal dapat dilihat pada Tabel berikut.

Tabel 9 Hasil Uji White Noise dan Kenormalan Residual
Model ARIMA
Pada Data *Inflow* Surabaya

Model ARIMA	White Noise Residual		Kenormalan Residual
	Hingga Lag	<i>P-Value</i>	<i>P-Value</i>
ARIMA ([2][6,23],0,[1][3])(0,1,0) ¹²	6	0.06	0.13
	12	0.06	
	18	0.09	
	24	0.11	
	30	0.12	
	36	0.06	

Berdasarkan Tabel tersebut menunjukkan asumsi residual *white noise* dan distribusi normal sudah terpenuhi. Maka model ARIMA tersebut layak untuk peramalan *inflow* Surabaya. Namun, tidak semua model ARIMA pada tiap lokasi untuk data *inflow* dan *outflow* layak digunakan dalam peramalan. Hal ini disebabkan beberapa diantara model yang terbentuk tidak memenuhi asumsi residual berdistribusi normal. Tabel berikut menyajikan asumsi residual *white noise*

dan berdistribusi normal untuk data *inflow* dan *outflow* di tiap lokasi pada pemodelan ARIMA.

Tabel 10 Hasil Uji White Noise dan Kenormalan Residual
Model ARIMA
Pada Data *Inflow* dan *Outflow* di Tiap Lokasi

Data	Lokasi	Model ARIMA $(p,d,q)(P,D,Q)^s$	Asumsi Residual	
			White Noise	Distribusi Normal
<i>Inflow</i>	Surabaya	$([2][6,23],0,[1][3])(0,1,0)^{12}$	Terpenuhi	Terpenuhi
	Malang	$([(1)(20)],1,2)(0,1,0)^{12}$	Terpenuhi	Tidak Terpenuhi
	Kediri	$([(1)(20)],1,2)(0,1,0)^{12}$	Terpenuhi	Tidak Terpenuhi
	Jember	$(3,0,3)(0,1,0)^{12}$	Terpenuhi	Tidak Terpenuhi
<i>Outflow</i>	Surabaya	$([13,23,35],1,[1,3]) (0,1,1)^{12}$	Terpenuhi	Terpenuhi
	Malang	$(1,0,[3,23])(0,1,0)^{12}$	Terpenuhi	Terpenuhi
	Kediri	$([(2,7),35],0,[3,23])(0,1,[12])^{12}$	Terpenuhi	Terpenuhi
	Jember	$(0,0,3)(0,1,[12])^{12}$	Terpenuhi	Terpenuhi

Hasil lengkap output pengujian asumsi untuk tiap lokasi data *inflow* dan *outflow* dapat dilihat di Lampiran. Pada Tabel tersebut menunjukkan untuk data *inflow* di Kota Malang, Kediri dan Jember masih belum memenuhi asumsi residual berdistribusi normal. Ketiga model ini perlu menyertakan *outlier* dalam analisis pembentukan model untuk mengatasi asumsi tersebut. Namun, analisis yang dilakukan dalam penelitian ini dibatasi untuk pemodelan ARIMA tanpa penambahan analisis *outlier*, maka ketiga model tersebut tetap digunakan dalam peramalan.

Secara matematis, model ARIMA *inflow* dan *outflow* untuk keempat kabupaten/kota tersebut dapat ditulis sebagai berikut.

i. Data *inflow*

- a. Kota Surabaya dengan model ARIMA $([2][6,23],0,[1][3])(0,1,0)^{12}$:

$$y_{t,1}^{0.25} = \frac{(1+0.19B)(1+0.51B^3)}{(1-B^{12})(1-0.24B^2)(0.22B^6-0.31B^{23})} + \varepsilon_{t,1}$$

- b. Kota Malang dengan model ARIMA $([(1)(20)],1,2)(0,1,0)^{12}$:

$$\ln y_{t,2} = \frac{(1-1.54B+0.67B^2)}{(1-B^{12})(1-B)(1-0.60B)(1-0.19B^{20})} + \varepsilon_{t,2}$$

- c. Kota Kediri dengan model ARIMA $([(1)(20)],1,2)(0,1,0)^{12}$:

$$\ln y_{t,3} = \frac{(1-1.64B+0.85B^2)}{(1-B^{12})(1-B)(1-0.57B)(1-0.17B^{20})} + \varepsilon_{t,3}$$

- d. Kota Jember dengan model ARIMA $(3,0,3)(0,1,0)^{12}$:

$$y_{t,4}^{-0.5} = \frac{(1-0.76B-0.74B^2+0.92B^3)}{(1-B^{12})(1-0.87B-0.67B^2+0.76B^3)} + \varepsilon_{t,4}$$

ii. Data *outflow*

- a. Kota Surabaya dengan model ARIMA $([13,23,35],1,[1,3])(0,1,1)^{12}$:

$$y_{t,1}^{0.29} = \frac{(1-0.73B+0.18B^3)(1-0.52B^{12})}{(1-B^{12})(1-B)(1+0.23B^{13}+0.26B^{23}-0.41B^{35})} + \varepsilon_{t,1}$$

- b. Kota Malang dengan model ARIMA $(1,0,[3,23])(0,1,0)^{12}$:

$$y_{t,2}^{0.5} = \frac{(1+0.30B^3+0.40B^{23})}{(1-B^{12})(1-0.22B)} + \varepsilon_{t,2}$$

- c. Kota Kediri dengan model ARIMA $([(2,7),35],0,[3,23])(0,1,[12])^{12}$:

$$y_{t,3}^{0.5} = \frac{(1+0.30B^3+0.37B^{23})}{(1-B^{12})(1-B)(1-0.19B^2-0.30B^7)(1+0.34B^{12})(1-0.40B^{35})} + \varepsilon_{t,3}$$

- d. Kota Jember dengan model ARIMA $(0,0,3)(0,1,[12])^{12}$:

$$y_{t,4}^{0.5} = \frac{(1+0.20B+0.25B^2+0.35B^3)(1+0.34B^{12})}{(1-B^{12})} + \varepsilon_{t,4}$$

Model ARIMA *outflow* dan *inflow* di kabupaten/kota Jawa Timur secara keseluruhan mengandung unsur musiman 12. Hal ini sesuai dengan hasil identifikasi pada plot *time series* yang menunjukkan pola data yang berulang setiap tahunnya.

3. Pemodelan Variasi Kalender pada *Inflow* dan *Outflow* Empat Kabupaten/Kota Jawa Timur

Pembentukan model variasi kalender *inflow* dan *outflow* menggunakan variabel-variabel *dummy*. Variabel *dummy* untuk variasi kalender yang digunakan adalah *dummy* mingguan. Variabel *dummy* mingguan yang ditulis $M_{1,t}$, $M_{2,t}$, $M_{3,t}$ dan $M_{4,t}$ menyatakan efek variasi kalender terjadi pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut di minggu ke-1, 2, 3 atau 4. Sedangkan variabel *dummy* mingguan yang ditulis $M_{1,t+1}$, $M_{2,t+1}$, $M_{3,t+1}$ dan $M_{4,t+1}$ menyatakan efek variasi kalender terjadi pada 1 bulan setelah bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut di minggu ke-1, 2, 3 atau 4. Untuk variabel *dummy* mingguan yang ditulis $M_{1,t-1}$, $M_{2,t-1}$, $M_{3,t-1}$ dan $M_{4,t-1}$ menyatakan efek variasi kalender terjadi pada 1 bulan sebelum bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut di minggu ke-1, 2, 3 atau 4.

Variabel *dummy trend* yang digunakan ada tiga yaitu *trend* 1 yang ditulis D_1 (untuk *intercept trend* 1) dan $D_1 t_1$ (untuk *trend* 1) terjadi pada bulan Januari 2003 sampai dengan bulan Desember 2006, *trend* 2 yang ditulis D_2 (untuk *intercept trend* 2) dan $D_2 t_2$ (untuk *trend* 2) terjadi pada bulan Januari 2007 sampai dengan bulan Desember 2010 serta *tren* 3 yang ditulis D_3 (untuk *intercept trend* 3) dan $D_3 t_3$ (untuk *trend* 3) terjadi pada bulan Januari 2011 sampai dengan bulan Desember 2013. Adanya variabel *dummy* untuk *additive outlier* ditulis A_i dengan $i=1,2,\dots$ atau 132 untuk memenuhi asumsi normalitas residual.

Sebagai contoh prosedur dalam pemodelan variasi kalender digunakan data *inflow* Surabaya. Berikut adalah model *restricted* variasi kalender yang hanya melibatkan variabel *dummy* saja dimana estimasi parameter yang ada pada model sudah signifikan semua dengan taraf signifikansi 0.05.

$$y_{t,1} = 1901.1 M_{1,t} + 1936.7 M_{2,t} + 1416.8 M_{3,t+1} + 2223.2 M_{4,t+1} + 1350.2 D_1 + 1982.2 D_3 + 12.42 D_2 t_2 + \varepsilon_{t,1}$$

Setelah estimasi dan uji signifikansi parameter dilakukan, selanjutnya dilakukan pengujian asumsi residual model meliputi uji *white noise* dan distribusi normal. Taraf signifikansi yang digunakan pada kedua uji ini sebesar 0.05. Hasil pengujian asumsi residual *white noise* dan distribusi normal dapat dilihat pada Tabel berikut.

Tabel 11 Hasil Uji White Noise dan Kenormalan Residual Model Variasi Kalender Pada Data *Inflow* Surabaya

White Noise Residual		Kenormalan Residual
Hingga Lag	P-Value	P-Value
6	0.69	<0.01
12	0.16	
18	0.16	
24	0.25	
30	0.38	
36	0.13	

Berdasarkan Tabel tersebut menunjukkan asumsi residual *white noise* sudah terpenuhi. Namun asumsi residual distribusi normal belum terpenuhi sehingga perlu menyertakan *outlier* dalam analisis pembentukan model untuk mengatasi asumsi tersebut.

Tabel 4.8 Hasil Deteksi Outlier Residual

t	Type	Estimasi	χ^2	P-Value
121	<i>Additive</i>	1884.3	19.46	<0.0001
95	<i>Additive</i>	1830.5	19.06	<0.0001
128	<i>Additive</i>	1846.7	18.90	<0.0001
61	<i>Additive</i>	1705.8	16.77	<0.0001

Hasil dari deteksi *outlier* dengan taraf signifikansi 0.05 diperoleh sebagaimana yang ada pada Tabel tersebut. Empat pengamatan yang dianggap sebagai *outlier* adalah pengamatan ke-121, 95, 128 dan 61. Pengurutan *outlier* didasarkan nilai *chi-square* tertinggi. Hasil estimasi parameter dari pemodelan variasi kalender dengan penambahan *outlier* dimana estimasi parameter yang ada pada model sudah signifikan semua dengan taraf signifikansi 0.05 adalah sebagai berikut.

$$y_{t,1} = 1914.5 M_{1,t} + 1344.3 M_{2,t} + 1485.3 M_{3,t+1} + 2245.8 M_{4,t+1} + 1360.4 D_1 + 1809.5 D_3 + 11.89 D_2 t_2 + 2057.0 A_{121} + 2611.9 A_{128} + 1880.5 A_{95} + 1737.9 A_{61} + \varepsilon_{t,1}$$

Selanjutnya dilakukan pengujian asumsi residual model meliputi uji *white noise* dan distribusi normal. Hasil pengujian dapat dilihat pada Tabel berikut.

Tabel 12 Hasil Uji White Noise dan Kenormalan Residual Model Variasi Kalender dengan Penambahan *Outlier* Pada Data *Inflow* Surabaya

White Noise Residual		Kenormalan Residual
Hingga Lag	P-Value	P-Value
6	0.05	0.07
12	0.06	
18	0.04	
24	0.07	
30	0.02	
36	0.006	

Berdasarkan Tabel tersebut menunjukkan asumsi residual *white noise* menjadi tidak terpenuhi walaupun residual sudah berdistribusi normal. Agar residual *white noise* maka dilakukan pemodelan ARIMA pada residual. Hasil pengujian signifikansi estimasi parameter dari pemodelan

variasi kalender dengan penambahan *outlier* dan pemodelan ARIMA residual dapat dilihat pada Tabel berikut.

Tabel 13 Hasil Estimasi Parameter Model Variasi Kalender dengan Penambahan *Outlier* dan Pemodelan ARIMA Residual Pada Data *Inflow* Surabaya

Parameter	Estimasi	Nilai T	P-Value
$M_{1,t}$	1692.4	5.67	<0.0001
$M_{2,t}$	1318.6	5.33	<0.0001
$M_{3,t+1}$	1499.9	6.13	<0.0001
$M_{4,t+1}$	228.0	7.65	<0.0001
D_1	1349.9	16.58	<0.0001
D_3	1790.4	15.54	<0.0001
D_2t_2	12.0	13.08	<0.0001
A_{121}	2144.2	5.05	<0.0001
A_{128}	2655.4	5.41	<0.0001
A_{95}	1852.4	4.38	<0.0001
A_{61}	1611.9	3.78	0.0002
ϕ_3	0.2	2.67	0.0086

Hasil uji signifikansi parameter pada Tabel tersebut menunjukkan bahwa model tersebut memiliki parameter-parameter yang signifikan. Hal ini dilihat berdasarkan *p-value* yang semuanya kurang dari 5%. Secara matematis, model yang terbentuk sebagai berikut.

$$y_{t,1} = 1692.4 M_{1,t} + 1318.6 M_{2,t} + 1499.9 M_{3,t+1} + 2289.0 M_{4,t+1} + 1349.9 D_1 + 1790.4 D_3 + 12.05 D_2t_2 + 2144.2 A_{121} + 2655.4 A_{128} + 1852.4 A_{95} + 1611.9 A_{61} + \frac{1}{(1-0.24^{-3})} \varepsilon_{t,1}$$

Selanjutnya dilakukan pengujian asumsi residual model meliputi uji *white noise* dan distribusi normal. Hasil pengujian dapat dilihat pada Tabel berikut.

Tabel 14 Hasil Uji White Noise dan Kenormalan Residual Model Variasi Kalender dengan Penambahan *Outlier* dan Model ARIMA Residual Pada Data *Inflow* Surabaya

White Noise Residual		Kenormalan Residual
Hingga Lag	<i>P-Value</i>	<i>P-Value</i>
6	0.46	0.051
12	0.52	
18	0.34	
24	0.46	
30	0.20	
36	0.08	

Berdasarkan Tabel tersebut menunjukkan asumsi residual white noise dan distribusi normal sudah terpenuhi. Maka model variasi kalender tersebut layak untuk peramalan *inflow* Surabaya.

Hasil pemodelan dari lokasi lainnya dengan data *inflow* dan *outflow* dengan semua estimasi parameter telah signifikan dengan taraf signifikansi 0.05 sebagai berikut:

i. Data *inflow*

a. Kota Malang

$$y_{t,2} = 540.05 M_{1,t} + 311.13 M_{2,t} + 764.06 M_{4,t+1} + 363.30 D_1 + 5.09 D_1 t_1 + 5.44 D_2 t_2 + 8.10 D_3 t_3 + 840.30 A_{121} + 789.32 A_{95} + 850.75 A_{128} + 406.65 A_{49} + \varepsilon_{t,2}$$

b. Kota Kediri

$$y_{t,3} = 806.45 M_{1,t} + 430.80 M_{2,t} + 420.30 M_{3,t+1} + 904.47 M_{4,t+1} + 574.75 D_1 + 346.91 D_2 + 3.97 D_3 t_3 + 963.11 A_{128} + 778.91 A_{121} + 522.35 A_{129} + 484.04 A_{109} + \frac{1}{(1-0.22^3 - 0.29^{12})(1-0.24B^6)} \varepsilon_{t,3}$$

c. Kota Jember

$$y_{t,4} = 391.19 M_{1,t} + 328.04 M_{2,t} + 156.75 M_{3,t} + 481.93 M_{4,t+1} + 246.35 D_1 + 263.27 D_2 + 5.11 D_1 t_1 + 4.01 D_3 t_3 + 454.23 A_{121} + 416.63 A_{95} + \frac{1}{(1-0.49^{12})(1-0.35B^{23})} \varepsilon_{t,4}$$

ii. Data *outflow*

a. Kota Surabaya

$$y_{t,1} = 277.73 M_{2,t} + 676.41 M_{3,t} + 607.51 M_{4,t} + 715.98 M_{1,t-1} + 208.42 M_{2,t-1} + 311.38 D_1 + 2.55 D_2 t_2 + 3.29 D_3 t_3 - 382.28 A_{84} + \frac{1}{(1-0.85 B^{12})} \varepsilon_{t,1}$$

b. Kota Malang

$$y_{t,2} = 282.06 M_{2,t} + 634.02 M_{3,t} + 631.95 M_{4,t} + 807.50 M_{1,t-1} + 279.89 M_{2,t-1} + 204.41 M_{3,t-1} + 225.20 D_1 + \frac{1}{(1-0.31 B^{10})(1-0.98 B^{12})(1-0.27 B^{15})} \varepsilon_{t,2}$$

c. Kota Kediri

$$y_{t,3} = 581.75 M_{2,t} + 785.67 M_{3,t} + 878.58 M_{4,t} + 1158.0 M_{1,t-1} + 356.62 M_{2,t-1} + 219.23 D_1 + 865.41 D_3 + 6.22 D_1 t_1 + 5.92 D_2 t_2 + 686.10 A_{96} - 990.21 A_{128} + \frac{1}{(1-0.22 B^{12})} \varepsilon_{t,3}$$

d. Kota Jember

$$y_{t,4} = 230.53 M_{3,t} + 304.89 M_{4,t} + 493.52 M_{1,t-1} + 252.55 M_{3,t-1} + 154.13 D_1 + 3.25 D_1 t_1 + 2.44 D_2 t_2 + 3.75 D_3 t_3 + 579.70 A_{127} + \frac{1}{(1-0.29 B)(1-0.68 B^{12})} \varepsilon_{t,4}$$

Model variasi kalender yang terbentuk masing-masing dilakukan pengujian asumsi residual model meliputi uji *white noise* dan distribusi normal dimana semua asumsi terpenuhi. Taraf signifikansi yang digunakan pada uji *white noise* dan distribusi normal sebesar 0.05.

B. Pemodelan GSTARX pada Data *Inflow* dan *Outflow*

Tahapan proses yang dilakukan di dalam simulasi, diterapkan di dalam pada kasus sebenarnya untuk mengestimasi parameter model GSTARX yang dilakukan dengan dua level. Namun, sebelum melakukan estimasi parameter model GSTARX tahap awal yang dilakukan adalah menentukan estimasi parameter model variasi kalender dan *trend* linier tersendiri serta menentukan bobot respon impuls pada model fungsi transfer tersendiri juga. Secara lengkap, berikut hasil analisis dan pembahasan serta tahapan yang dilakukan.

1. Identifikasi Model untuk Level 1

Pada tahapan ini terdapat dua model yang berbeda yang dibentuk, yaitu model variasi kalender dan *trend* linier (non metrik) serta model fungsi transfer (metrik). Dari kedua model yang terbentuk digabung menjadi satu model gabungan. Berikut tahapan-tahapan yang dilakukan pemodelan terpisah masing-masing yang non metrik dan yang metrik.

1. Identifikasi Model Variasi Kalender dan *Trend* Linier (Non Metrik)

Pada dasarnya, pembentukan model variasi kalender dan *trend* linier di tahapan ini sama halnya dengan pembentukan model variasi kalender di pembahasan sebelumnya, hanya saja tanpa melibatkan *outlier* dan model AR(*p*) residual. Hasil estimasi parameter pada model variasi kalender dan *trend* linier adalah sebagai berikut:

i. Untuk data *inflow* di:

- Kota Surabaya :

$$y_{t,1} = \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_7 M_{3,t+1} + \beta_8 M_{4,t+1} + \gamma_1 D_1 + \gamma_3 D_3 + \pi_2 D_2 t_2 + \varepsilon_{t,1}$$

- Kota Malang:

$$y_{t,2} = \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_8 M_{4,t+1} + \gamma_1 D_1 + \pi_1 D_1 t_1 + \pi_2 D_2 t_2 + \pi_3 D_3 t_3 + \varepsilon_{t,2}$$

- Kota Kediri:

$$y_{t,3} = \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_7 M_{3,t+1} + \beta_8 M_{4,t+1} + \gamma_1 D_1 + \gamma_2 D_2 + \pi_3 D_3 t_3 + \varepsilon_{t,3}$$

- Kabupaten Jember:

$$y_{t,4} = \beta_1 M_{1,t} + \beta_2 M_{2,t} + \beta_8 M_{4,t+1} + \gamma_1 D_1 + \pi_1 D_1 t_1 + \pi_3 D_3 t_3 + \varepsilon_{t,4}$$

ii. Untuk data *outflow* di:

- Kota Surabaya :

$$y_{t,1} = \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{1,t-1} + \beta_6 M_{2,t-1} + \beta_7 M_{3,t-1} + \gamma_1 D_1 - + \gamma_2 D_2 + \pi_2 D_2 t_2 + \pi_3 D_3 t_3 + \varepsilon_{t,1}$$

- Kota Malang :

$$y_{t,2} = \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{1,t-1} + \beta_6 M_{2,t-1} + \beta_7 M_{3,t-1} + \gamma_1 D_1 + \pi_1 D_1 t_1 + \varepsilon_{t,2}$$

- Kota Kediri:

$$y_{t,3} = \beta_2 M_{2,t} + \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{1,t-1} + \beta_6 M_{2,t-1} + \beta_7 M_{3,t-1} + \gamma_1 D_1 + \pi_2 D_2 t_2 + \pi_3 D_3 t_3 + \varepsilon_{t,3}$$

- Kota Jember :

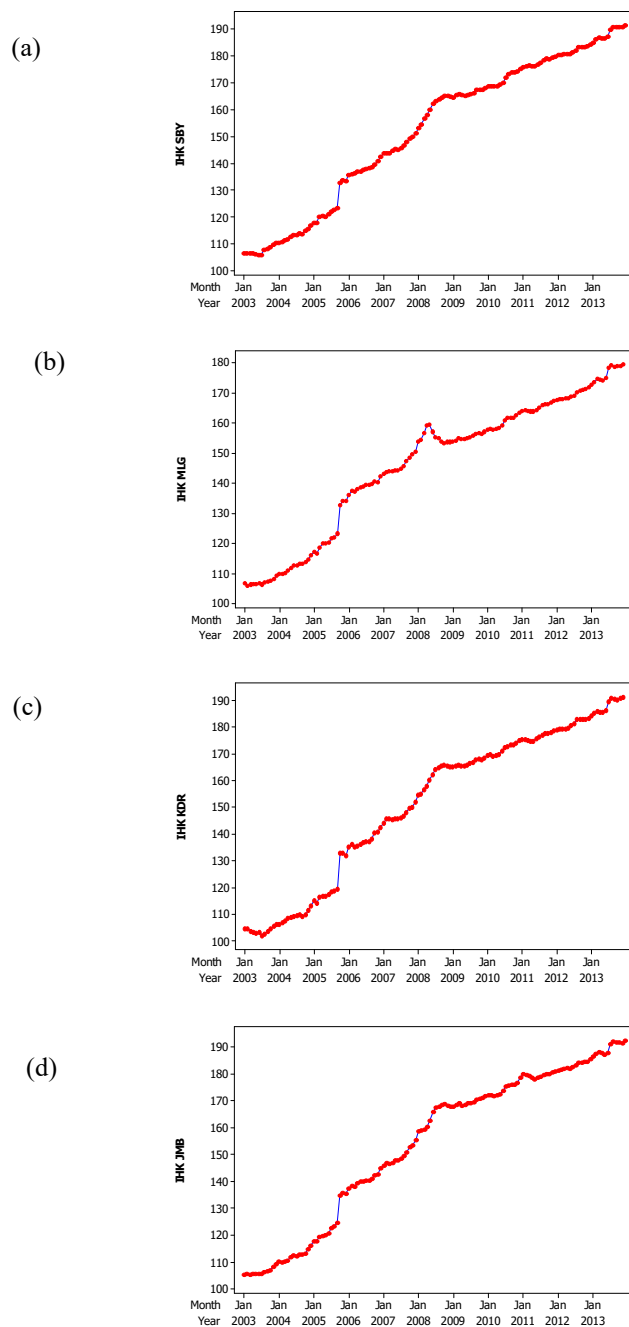
$$y_{t,4} = \beta_3 M_{3,t} + \beta_4 M_{4,t} + \beta_5 M_{1,t-1} + \beta_7 M_{3,t-1} + \gamma_1 D_1 + \pi_1 D_1 t_1 + \pi_2 D_2 t_2 + \pi_3 D_3 t_3 + \varepsilon_{t,4}$$

Semua estimasi parameter yang ada pada model di tiap lokasi data *inflow* dan *outflow* telah signifikan dengan taraf signifikansi 0.05. Sedangkan pengujian asumsi residual dan distribusi normal diabaikan dikarenakan pengujian asumsi residual *white noise* akan dipenuhi di level 2. Selanjutnya dilakukan pemodelan fungsi transfer untuk tiap lokasi data *inflow* dan *outflow*.

2. Identifikasi Model Fungsi Transfer (Metrik)

Tahapan pertama dalam pemodelan ARIMA deret input IHK tiap kota/kabupaten. Gambar berikut menunjukkan *time series plot* IHK kota Surabaya ($x_{t,1}$), Malang ($x_{t,2}$), Kediri ($x_{t,3}$) dan Jember ($x_{t,4}$). IHK di keempat kota/kabupaten tampak stasioner dalam varians, namun belum stasioner dalam mean.

Untuk mengatasi stasioner dalam *mean*, IHK di empat kota tersebut dilakukan *differencing* pada lag 1.



Gambar 6 Plot Times Series IHK (a) Kota Surabaya, (b) Kota Malang, (c) Kota Kediri dan (d) Kabupaten Jember

Berdasarkan ACF dan PACF dari IHK yang telah stasioner dalam *mean* dan varians, model ARIMA yang didapat ditunjukkan pada Tabel berikut. Model ARIMA yang terbentuk untuk IHK digunakan untuk tahap selanjutnya, yaitu *prewhitening* deret input. Selanjutnya, tahapan dalam *prewhitening* deret output mengikuti *prewhitening* deret input. Penjelasan mengenai pemodelan fungsi transfer dengan deret *input* IHK secara lengkap hanya dilakukan untuk deret output *inflow* di Kota Surabaya.

Tabel 15 Model ARIMA IHK di Kota Surabaya, Malang, Kediri dan Jember

IHK Kota	ARIMA (p,d,q)	Persamaan Matematis
Surabaya	(1,1,1)	$x_{t,1} = \frac{1-0.99B}{(1-B)(1-0.90B)} a_{t,1}$
Malang	([3,4],1,1)	$x_{t,2} = \frac{1+0.34B}{(1-B)(1-0.24B^3-0.17B^4)} a_{t,2}$
Kediri	(1,1,1)	$x_{t,3} = \frac{1+0.71B}{(1-B)(1+0.51B)} a_{t,3}$
Jember	(1,1,1)	$x_{t,4} = \frac{1-0.90B}{(1-B)(1-0.99B)} a_{t,4}$

Berdasarkan model ARIMA IHK Kota Surabaya pada Tabel tersebut, maka didapatkan deret *input* IHK yang telah di-*prewhitening*, yaitu

$$a_{t,1} = \frac{(1-B)(1-0.90B)}{1-0.99B} x_{t,1}$$


Prewhitening deret output *Inflow* Surabaya mengikuti *prewhitening* deret input. Sehingga deret output *Inflow* Surabaya adalah

$$\beta_{t,1} = \frac{(1-B)(1-0.90B)}{1-0.99B} y_{t,1}$$

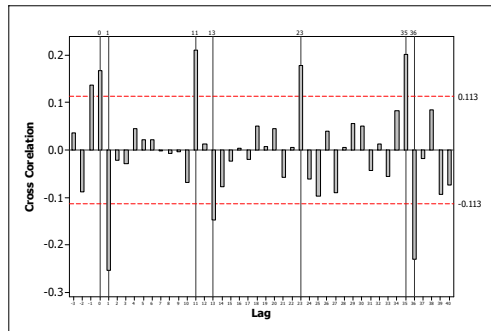
Kemudian pada tahap selanjutnya adalah identifikasi bobot respon impuls untuk pemodelan fungsi transfer. Identifikasi ini berdasarkan plot *Cross Correlation* (CCF) antara IHK yang telah stasioner dalam mean dan varians dengan

masing-masing data *inflow* dan *outflow*. Plot CCF tiap lokasi dan data dapat dilihat pada Gambar berikut.


(a)




(b)

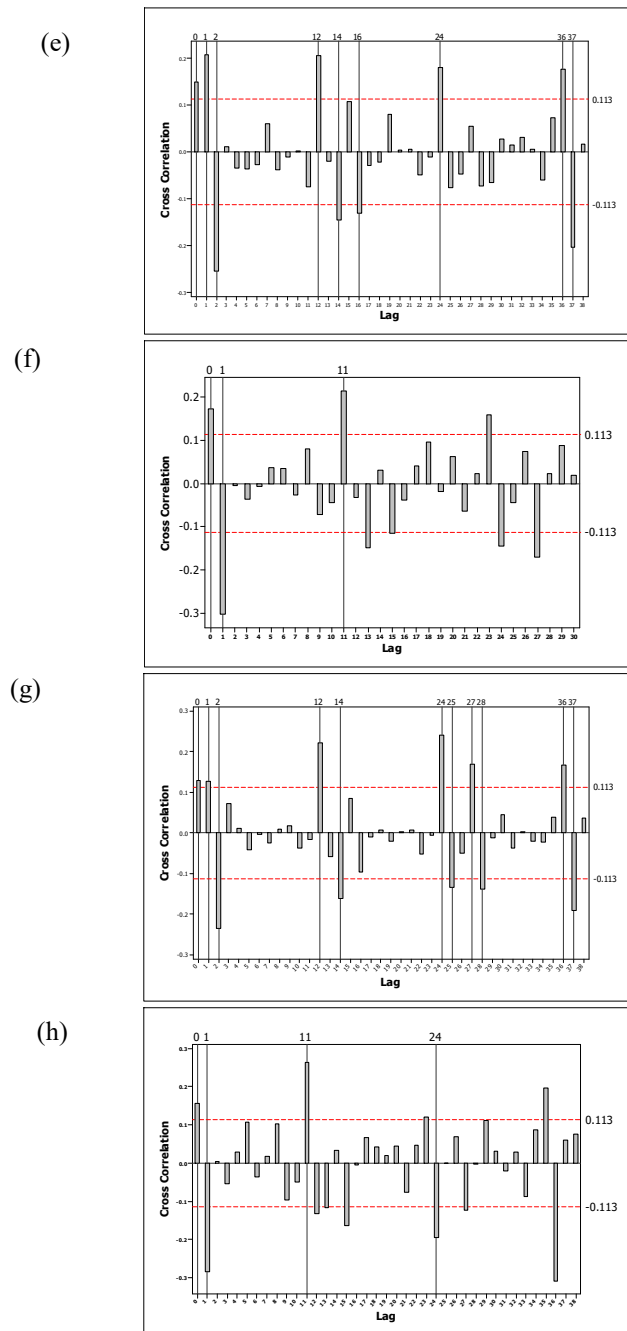


(c)



(d)





Gambar 7 Plot CCF antar IHK yang telah stasioner dengan (a) *Inflow* Surabaya, (b) *Outflow* Surabaya, (c) *Inflow* Malang, (d) *Outflow* Malang, (e) *Inflow* Kediri, (f) *Outflow* Kediri, (g) *Inflow* Jember, (h) *Outflow* Jember

Dari Gambar tersebut didapatkan CCF antar *inflow* dan *outflow* dengan IHK di masing-masing keempat kota/kabupaten tersebut sehingga dapat dibentuk bobot respon impuls untuk masing-masing *inflow* dan *outflow* di tiap kota/kabupaten. Hasil dari penentuan bobot respon impuls untuk pemodelan fungsi transfer tiap lokasi dan data adalah sebagai berikut.

i. Untuk data *inflow* di:

- Kota Surabaya memiliki pola $b = 1; s = 1; r = 0$

$$y_{t,1} = (\omega_0 - \omega_1 B)x_{(t-1),1} + n_{t,1}$$

- Kota Malang memiliki pola $b = 1; s = 1; r = 0$

$$y_{t,2} = (\omega_0 - \omega_1 B)x_{(t-1),2} + n_{t,2}$$

- Kota Kediri memiliki pola $b = 1; s = 1, 11; r = 0$

$$y_{t,3} = (\omega_0 - \omega_1 B + \omega_{11} B^{11})x_{(t-1),3} + n_{t,3}$$

- Data *Inflow* Jember berpola $b = 1; s = 1; r = 0$

$$y_{t,4} = (\omega_0 - \omega_1 B)x_{(t-1),4} + n_{t,4}$$

ii. Untuk data *outflow* di:

- Kota Surabaya memiliki pola $b = 0; s = 1; r = 0$

$$y_{t,1} = (\omega_0 - \omega_1 B)x_{t,1} + n_{t,1}$$

- Kota Malang memiliki pola $b = 0; s = 1; r = 0$

$$y_{t,2} = (\omega_0 - \omega_1 B)x_{t,2} + n_{t,2}$$

- Kota Kediri memiliki pola $b = 0; s = 1, ; r = 0$

$$y_{t,3} = (\omega_0 - \omega_1 B)x_{t,3} + n$$

- Kabupaten Jember memiliki pola $b = 0; s = 1, ; r = 0$

$$y_{t,4} = (\omega_0 - \omega_1 B)x_{t,4} + n_{t,4}$$

Setelah estimasi parameter dari model fungsi transfer untuk tiap lokasi dan data telah signifikan, selanjutnya melakukan estimasi parameter model gabungan dari model variasi kalender dan fungsi transfer dari dua model yang terbentuk masing-masing data *inflow* dan *outflow* di tiap kota/kabupaten tersebut. Asumsi residual *white noise* diabaikan dikarenakan pengujian asumsi ini dilakukan di level 2.

2. Estimasi Parameter Model di Level 1

Penggabungan model dari model variasi kalender dan *trend* linier serta model fungsi transfer mengabaikan signifikansi estimasi parameter dan asumsi residual. Hal ini disebabkan model gabungan yang dibentuk tidak memasukkan parameter *outlier* dan model $AR(p)$ residual di model variasi kalender serta model $ARMA(p,q)$ deret *noise* di model fungsi transfer. Penggabungan model ini hanya memasukkan parameter *dummy* mingguan dan *trend* yang signifikan di model variasi kalender serta parameter bobot respon impuls yang signifikan di model fungsi transfer. Model gabungan yang terbentuk adalah sebagai berikut:

i. Untuk Data *Inflow* di:

- Kota Surabaya:

$$y_{t,1} = 1758.1M_{1,t} + 1886.4M_{2,t} + 1671.2M_{3,t+1} + 2227.0M_{4,t+1} - 1611.4D_1 + 373.7D_3 - 10.23D_2t_2 + (20.50 - 7.70B)x_{(t-1),1} + u_{t,1}$$

Inflow mengalami efek variasi kalender Lebaran di Kota Surabaya pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2, atau terjadi 1 bulan setelahnya jika tanggal hari raya tersebut terdapat di minggu ke-3 dan ke-4.

- Kota Malang:

$$y_{t,2} = 604.09M_{1,t} + 553.85M_{2,t} + 763.46M_{4,t+1} - 591.44D_1 - 5.10D_1t_1 - 10.82D_2t_2 - 4.87D_3t_3 + (13.84 - 9.01B)x_{(t-1),2} + u_{t,2}$$

Efek variasi kalender Lebaran di Kota Malang terjadi pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2, atau terjadi 1 bulan setelahnya jika tanggal hari raya tersebut terdapat di minggu ke-4.

- Kota Kediri:

$$y_{t,3} = 772.57M_{1,t} + 630.58M_{2,t} + 423.67M_{3,t+1} + 1152.1M_{4,t+1} + -2517.4D_1 - 2040.2D_2 - 13.72D_3t_3 + (-8.24 - 13.06B + 18.57B^{11})x_{(t-1),3} + u_{t,3}$$

Inflow mengalami efek variasi kalender Lebaran di Kota Kediri pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2, atau terjadi 1 bulan setelahnya jika tanggal hari raya tersebut terdapat di minggu ke-3 dan ke-4.

- Kabupaten Jember:

$$y_{t,4} = 506.18 M_{1,t} + 384.86M_{2,t} + 568.11M_{4,t+1} - 1215.1D_1 - 380.93D_2 + 11.11D_1t_1 - 1.00D_3t_3(-7.94 - 5.97 B)x_{(t-1),4} + u_{t,4}$$

Efek variasi kalender Lebaran di Kota Jember terjadi pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2, atau terjadi 1 bulan setelahnya jika tanggal hari raya tersebut terdapat di minggu ke-4.

- ii. Untuk Data *Outflow* di:

- Kota Surabaya:

$$y_{t,1} = 1381.5 M_{2,t} + 1817.9M_{3,t} + 2716.9M_{4,t} + 2483.6M_{1,t-1} + 1503.6M_{2,t-1} + 7376.8D_1 + 135.41D_2t_2 + 112.47D_3t_3 + (-82.13 - 18.14B)x_{t,1} + u_{t,1}$$

Outflow mengalami efek variasi kalender Lebaran di Kota Surabaya pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-2, 3 dan 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2.

- Kota Malang:

$$y_{t,2} = 1381.5M_{2,t} + 1817.9M_{3,t} + 2716.9M_{4,t} + 2483.6M_{1,t-1} + 1503.6M_{2,t-1} + 7376.8D_1 +$$

$$135.41D_2t_2 + 112.47D_3t_3 + (-82.13 - 18.14B)x_{t,2} + u_{t,2}$$

Efek variasi kalender Lebaran di Kota Malang terjadi pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-2, 3 dan 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan 2.

- Kota Kediri:

$$y_{t,3} = 337.93M_{2,t} + 863.48M_{3,t} + 994.86M_{4,t} + 1125.2M_{1,t-1} + 586.58M_{2,t-1} + 510.41D_1 + 3650.3D_3 + 37.86D_1t_1 + 39.22D_2t_2 + (-26.16 + 14.77 B)x_{t,3} + u_{t,3}$$

Outflow mengalami efek variasi kalender Lebaran di Kota Kediri pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-2, 3 dan 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1.

- Kabupaten Jember:

$$y_{t,4} = 309.28 M_{3,t} + 469.31 M_{4,t} + 531.54M_{1,t-1} + 237.23M_{3,t-1} + 505.42D_1 + 16.40D_1t_1 + 21.30D_2t_2 + 18.84D_3t_3 + (-5.87 - 10.74 B)x_{t,4} + u_{t,4}$$

Efek variasi kalender Lebaran di Kabupaten Jember pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-3 dan 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan 3.

Pada tahapan selanjutnya, residual $u_{i,t}$ dengan $i = 1,2,3,4$ untuk masing-masing data *inflow* dan *outflow* menjadi variabel respon di level 2.

3. Identifikasi Orde Model pada Level 2

Selanjutnya dilakukan pemeriksaan stasioneritas dan juga penentuan orde AR pada data $u_{i,t}$ dengan $i = 1,2,3,4$ untuk masing-masing data *inflow* dan *outflow*. Skema MCCF pada

Gambar berikut menunjukkan bahwa data telah stasioner untuk $u_{i,t} inflow$. Hal ini terlihat dari banyaknya tanda (.) yang muncul.

Variabel/ Lag	0	1	2	3	4	5	6	7
u1	++++	----	+.+
u2	++++	----
u3	++++	----	-.
u4	++++	----	+.+	-.-

Gambar 8 Representasi skema MCCF untuk $u_{i,t} inflow$ di empat lokasi

Pengecekan orde waktu dari model VAR dapat pula dilakukan dengan melihat skema MPCCF seperti pada Gambar berikut

Variabel/ Lag	1	2	3	4	5	6	7	8
u1	-+. .	-+. .	.+.
u2	--. .	-. .	-.
u3	..-+	..-.	.+-.
u4	..--	..-.-	..+.

Gambar 9 Representasi skema MPCCF untuk $u_{i,t} inflow$ di empat lokasi

Skema MPCCF pada Gambar tersebut menunjukkan bahwa tanda positif (+) yang muncul pada keempat lokasi di lag ke-1, 2 dan 3 sehingga model yang terbentuk VAR(3). Hal yang sama juga dilakukan untuk pemeriksaan stasioneritas dan juga penentuan orde AR $u_{i,t} outflow$. Skema MCCF pada Gambar berikut menunjukkan bahwa data telah stasioner untuk $u_{i,t} outflow$. Hal ini terlihat dari banyaknya tanda (.) yang muncul.

Variabel/ Lag	0	1	2	3	4	5	6	7
u1	++++	----
u2	++++	----
u3	++++	----
u4	++++	----	-.-

Gambar 10 Representasi skema MCCF untuk $u_{i,t} outflow$ di empat lokasi

Pengecekan orde waktu dari model VAR dapat pula dilakukan dengan melihat skema MPCCF seperti pada Gambar berikut.

Variabel/ Lag	1	2	3	4	5	6	7	8
u1	-.	--..	+...+.
u2	.-..
u3	..-.	..-.	+. .	-.. .	-.. .	..+.
u4	...-	...--

Gambar 11 Representasi skema MPCCF untuk $u_{i,t}$ *outflow* di empat lokasi

Skema MPCCF pada Gambar tersebut menunjukkan bahwa tanda positif (+) dan (-) yang dominan muncul pada keempat lokasi pada lag ke-1 dan 3 sehingga model yang terbentuk VAR([1,3]).

4. Estimasi Parameter Model GSTAR di Level 2

Tahap identifikasi dalam pemodelan GSTAR memiliki proses yang sama dengan pemodelan VARIMA dalam menentukan orde model. Sehingga, orde model GSTAR yang digunakan dalam analisis ini sama dengan orde dalam model VARIMA, dimana model VAR(3) untuk $u_{i,t}$ *inflow* dan model VAR([1,3]) untuk $u_{i,t}$ *outflow*. Sehingga, untuk $u_{i,t}$ *inflow* menggunakan model GSTAR(3₁) dan untuk $u_{i,t}$ *outflow* menggunakan model GSTAR([1,3]₁). Model GSTAR(3₁) dapat ditulis dengan persamaan sebagai berikut:

$$u_{i,t} = [\Phi_{10}^1 + \Phi_{11} W^1]u_{i,(t-1)} + [\Phi_{10}^2 + \Phi_{21} W^1]u_{i,(t-2)} + [\Phi_{10}^3 + \Phi_{31} W^1]u_{i,(t-3)} + e_{i,t}$$

dalam bentuk matriks dapat ditulis seperti berikut.

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} \phi_{10}^1 & 0 & 0 & 0 \\ 0 & \phi_{20}^1 & 0 & 0 \\ 0 & 0 & \phi_{30}^1 & 0 \\ 0 & 0 & 0 & \phi_{40}^1 \end{pmatrix} + \begin{pmatrix} \phi_{11}^1 & 0 & 0 & 0 \\ 0 & \phi_{21}^1 & 0 & 0 \\ 0 & 0 & \phi_{31}^1 & 0 \\ 0 & 0 & 0 & \phi_{41}^1 \end{pmatrix} \begin{pmatrix} 0 & \omega_{12} & \omega \\ \omega_{21} & 0 & \omega \\ \omega_{31} & \omega_{32} & \omega \\ \omega_{41} & \omega_{42} & \omega \end{pmatrix} \\ \begin{pmatrix} \phi_{10}^2 & 0 & 0 & 0 \\ 0 & \phi_{20}^2 & 0 & 0 \\ 0 & 0 & \phi_{30}^2 & 0 \\ 0 & 0 & 0 & \phi_{40}^2 \end{pmatrix} + \begin{pmatrix} \phi_{11}^2 & 0 & 0 & 0 \\ 0 & \phi_{21}^2 & 0 & 0 \\ 0 & 0 & \phi_{31}^2 & 0 \\ 0 & 0 & 0 & \phi_{41}^2 \end{pmatrix} \begin{pmatrix} 0 & \omega_{12} & \omega \\ \omega_{21} & 0 & \omega \\ \omega_{31} & \omega_{32} & \omega \\ \omega_{41} & \omega_{42} & \omega \end{pmatrix} \\ \begin{pmatrix} \phi_{10}^3 & 0 & 0 & 0 \\ 0 & \phi_{20}^3 & 0 & 0 \\ 0 & 0 & \phi_{30}^3 & 0 \\ 0 & 0 & 0 & \phi_{40}^3 \end{pmatrix} + \begin{pmatrix} \phi_{11}^3 & 0 & 0 & 0 \\ 0 & \phi_{21}^3 & 0 & 0 \\ 0 & 0 & \phi_{31}^3 & 0 \\ 0 & 0 & 0 & \phi_{41}^3 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} \epsilon_{1,t} \\ \epsilon_{2,t} \\ \epsilon_{3,t} \\ \epsilon_{4,t} \end{pmatrix} \\ \begin{pmatrix} 0 & \omega_{12} & \omega_{13} & \omega_{14} \\ \omega_{21} & 0 & \omega_{23} & \omega_{24} \\ \omega_{31} & \omega_{32} & 0 & \omega_{34} \\ \omega_{41} & \omega_{42} & \omega_{43} & 0 \end{pmatrix} \end{bmatrix}$$

Sedangkan model GSTAR([1,3]₁) dapat ditulis dengan persamaan sebagai berikut:

$$u_{i,t} = [\Phi_{10}^1 + \Phi_{11} W^1]u_{i,(t-1)} + [\Phi_{10}^3 + \Phi_{11} W^1]u_{i,(t-3)} + e_{i,t}$$

dalam bentuk matriks dapat ditulis seperti berikut.

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

Estimasi parameter yang digunakan adalah estimasi GLS dikarenakan data *inflow* dan *outflow* antar lokasi saling berkorelasi sehingga lebih efisien jika data yang berkorelasi diestimasi dengan GLS. Penggunaan bobot dalam pemodelan GSTAR untuk masing-masing data *inflow* dan *outflow* terdapat empat macam bobot, yaitu bobot seragam, invers jarak, normalisasi korelasi silang dan normalisasi inferensia korelasi silang parsial. Model yang digunakan adalah *full model* dengan semua estimasi parameter digunakan dan *restricted model* dengan estimasi parameter yang signifikan saja yang digunakan. Alasan penggunaan *full model* adalah apakah model ini lebih baik dibandingkan *restricted model*. Menurut Armstrong (2001), model ramalan yang baik adalah model yang dapat meramal lebih baik jika secara tradisional (*restricted model*) tidak lebih baik daripada didasarkan keputusan dari peneliti (*full model*).

a. Bobot Seragam

a) Full Model pada Data Inflow

Penerapan bobot seragam pada pemodelan GSTAR mengasumsikan bahwa data *inflow* suatu lokasi memiliki keterkaitan yang sama terhadap data *inflow* lainnya sehingga

pemberian bobot untuk lokasi ke- i dan j adalah sama. Matriks bobot seragam yang digunakan pada model GSTAR(3₁) dituliskan pada persamaan sebagai berikut.

$$W = \begin{bmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{bmatrix}$$

Hasil penghitungan dengan estimasi parameter model GSTAR (3₁) adalah sebagai berikut:

Tabel 16 Estimasi Parameter *Full Model* dari metode GLS dengan Bobot Seragam pada $u_{i,t}$ Inflow

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.42	0.11	-3.89	0.0002
	ϕ_{11}^1	1	-0.51	0.37	-1.37	0.17
	ϕ_{10}^2	1	-0.29	0.11	-2.62	0.01
	ϕ_{11}^2	1	-0.33	0.39	-0.84	0.40
	ϕ_{10}^3	1	0.12	0.11	1.12	0.27
	ϕ_{11}^3	1	-0.58	0.37	-1.57	0.12
Malang	ϕ_{20}^1	1	-0.54	0.10	-5.54	<0.0001
	ϕ_{21}^1	1	0.09	0.08	1.18	0.24
	ϕ_{20}^2	1	-0.38	0.10	-3.80	0.0002
	ϕ_{21}^2	1	0.12	0.08	1.41	0.16
	ϕ_{20}^3	1	-0.14	0.10	-1.45	0.15
	ϕ_{21}^3	1	0.14	0.08	1.83	0.07
Kediri	ϕ_{30}^1	1	-0.49	0.10	-5.01	<0.0001
	ϕ_{31}^1	1	-0.01	0.08	-0.09	0.93
	ϕ_{30}^2	1	-0.50	0.10	-5.19	<0.0001
	ϕ_{31}^2	1	0.09	0.08	1.08	0.28
	ϕ_{30}^3	1	-0.24	0.10	-2.33	0.02
	ϕ_{31}^3	1	0.13	0.08	1.67	0.10
Jember	ϕ_{40}^1	1	-0.01	0.05	-0.23	0.82
	ϕ_{41}^1	1	-0.35	0.10	-3.69	0.0003

	ϕ_{40}^2	1	0.01	0.05	0.20	0.84
	ϕ_{41}^2	1	-0.16	0.09	-1.77	0.08
	ϕ_{40}^3	1	0.05	0.05	1.00	0.32
	ϕ_{41}^3	1	-0.01	0.05	-0.23	0.82

Berdasarkan parameter-parameter pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model GSTAR(3₁) dengan menggunakan bobot seragam pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} -0.42 & 0 & 0 & 0 \\ 0 & -0.54 & 0 & 0 \\ 0 & 0 & -0.49 & 0 \\ 0 & 0 & 0 & -0.43 \end{pmatrix} + \begin{pmatrix} -0.51 & 0 & 0 & 0 \\ 0 & 0.09 & 0 & 0 \\ 0 & 0 & -0.01 & 0 \\ 0 & 0 & 0 & -0.01 \end{pmatrix} \\ \begin{pmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{pmatrix} \end{bmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \\ \begin{bmatrix} \begin{pmatrix} -0.29 & 0 & 0 & 0 \\ 0 & -0.38 & 0 & 0 \\ 0 & 0 & -0.50 & 0 \\ 0 & 0 & 0 & -0.35 \end{pmatrix} + \begin{pmatrix} -0.33 & 0 & 0 & 0 \\ 0 & 0.12 & 0 & 0 \\ 0 & 0 & 0.09 & 0 \\ 0 & 0 & 0 & 0.01 \end{pmatrix} \\ \begin{pmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{pmatrix} \end{bmatrix} \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \\ \begin{bmatrix} \begin{pmatrix} 0.12 & 0 & 0 & 0 \\ 0 & -0.14 & 0 & 0 \\ 0 & 0 & -0.24 & 0 \\ 0 & 0 & 0 & -0.16 \end{pmatrix} + \begin{pmatrix} -0.58 & 0 & 0 & 0 \\ 0 & 0.14 & 0 & 0 \\ 0 & 0 & 0.13 & 0 \\ 0 & 0 & 0 & 0.05 \end{pmatrix} \\ \begin{pmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{pmatrix} \end{bmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix} .$$

Model GSTAR(3₁) untuk $u_{i,t}$ inflow pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR (3₁) di Kota Surabaya

$$u_{1,t} = -0.42 u_{1,(t-1)} - 0.17 u_{2,(t-1)} - 0.17 u_{3,(t-1)} - 0.17 u_{4,(t-1)} + -0.29 u_{1,(t-2)} - 0.11 u_{2,(t-2)} - 0.11 u_{3,(t-2)} - 0.11 u_{4,(t-2)} + 0.12 u_{1,(t-3)} - 0.19 u_{2,(t-3)} - 0.19 u_{3,(t-3)} - 0.19 u_{4,(t-3)} + e_{1,t}$$
- Model GSTAR (3₁) di Kota Malang

$$u_{2,t} = 0.03 u_{1,(t-1)} - 0.54 u_{2,(t-1)} + 0.03 u_{3,(t-1)} - 0.03 u_{4,(t-1)} + 0.04 u_{1,(t-2)} - 0.04 u_{2,(t-2)} + 0.04 u_{3,(t-2)} + 0.04 u_{4,(t-2)} + 0.05 u_{1,(t-3)} - 0.14 u_{2,(t-3)} + 0.05 u_{3,(t-3)} + 0.05 u_{4,(t-3)} + e_{2,t}$$
- Model GSTAR (3₁) di Kota Kediri

$$u_{3,t} = -0.002 u_{1,(t-1)} - 0.002 u_{2,(t-1)} - 0.49 u_{3,(t-1)} - 0.002 u_{4,(t-1)} + 0.03 u_{1,(t-2)} + 0.03 u_{2,(t-2)} - 0.50 u_{3,(t-2)} + 0.03 u_{4,(t-2)} + 0.04 u_{1,(t-3)} + 0.04 u_{2,(t-3)} - 0.24 u_{3,(t-3)} + 0.04 u_{4,(t-3)} + e_{3,t}$$
- Model GSTAR (3₁) di Kabupaten Jember

$$u_{4,t} = -0.004 u_{1,(t-1)} - 0.004 u_{2,(t-1)} - 0.004 u_{3,(t-1)} - 0.43 u_{4,(t-1)} + 0.004 u_{1,(t-2)} + 0.004 u_{2,(t-2)} + 0.004 u_{3,(t-2)} - 0.35 u_{4,(t-2)} + 0.02 u_{1,(t-3)} + 0.02 u_{2,(t-3)} + 0.02 u_{3,(t-3)} - 0.16 u_{4,(t-3)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *inflow* di setiap lokasi dapat diketahui bahwa pengaruh *inflow* di suatu lokasi dipengaruhi oleh *inflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Misal, *inflow* di Kota Surabaya dipengaruhi oleh *inflow* Surabaya, Malang, Kediri dan Jember 1, 2 dan 3 bulan sebelumnya. Begitu juga *inflow* di Kota Malang, Kediri dan Jember memiliki interpretasi model yang sama dengan yang di Kota Surabaya.

b) Restricted Model pada Data Inflow

Tidak semua parameter pada pemodelan GSTAR dengan bobot seragam signifikan. Pada bagian ini pemodelan GSTAR(3₁) hanya dengan parameter yang signifikan saja sehingga didapatkan model yang *restricted*. Hasil penghitungan dengan estimasi parameter model GSTAR (3₁) adalah sebagai berikut:

Tabel 17 Estimasi Parameter *Restricted Model* dari metode GLS dengan Bobot Seragam pada $u_{i,t}$ Inflow

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.48	0.05	-9.19	<0.0001
	ϕ_{10}^2	1	-0.37	0.05	-7.15	<0.0001
Malang	ϕ_{20}^1	1	-0.36	0.05	-6.86	<0.0001
	ϕ_{20}^2	1	-0.27	0.05	-5.03	<0.0001
Kediri	ϕ_{30}^1	1	-0.43	0.05	-8.43	<0.0001
	ϕ_{30}^2	1	-0.37	0.05	-7.27	<0.0001
Jember	ϕ_{40}^1	1	-0.39	0.05	-7.02	<0.0001
	ϕ_{40}^2	1	-0.32	0.05	-5.74	<0.0001

Berdasarkan parameter-parameter yang signifikan pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model *restricted* GSTAR(3₁) dengan menggunakan bobot seragam pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} -0.48 & 0 & 0 & 0 \\ 0 & -0.36 & 0 & 0 \\ 0 & 0 & -0.43 & 0 \\ 0 & 0 & 0 & -0.39 \end{bmatrix} + \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{bmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{bmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \\
 \begin{bmatrix} -0.37 & 0 & 0 & 0 \\ 0 & -0.27 & 0 & 0 \\ 0 & 0 & -0.37 & 0 \\ 0 & 0 & 0 & -0.32 \end{bmatrix} + \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{bmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{bmatrix} \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \\
 \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix}.$$

Model GSTAR(3₁) untuk $u_{i,t}$ inflow pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR (3₁) di Kota Surabaya
 $u_{1,t} = -0.48 u_{1,(t-1)} - 0.37 u_{1,(t-2)} + e_{1,t}$
- Model GSTAR (3₁) di Kota Malang
 $u_{2,t} = -0.36 u_{2,(t-1)} - 0.26 u_{2,(t-2)} + e_{2,t}$
- Model GSTAR (3₁) di Kota Kediri
 $u_{3,t} = -0.43 u_{3,(t-1)} - 0.37 u_{3,(t-2)} + e_{3,t}$
- Model GSTAR (3₁) di Kabupaten Jember
 $u_{4,t} = -0.38 u_{4,(t-1)} - 0.32 u_{4,(t-2)} + e_{4,t}$

Berdasarkan model yang terbentuk untuk inflow di setiap lokasi dapat diketahui bahwa pengaruh inflow di suatu lokasi dipengaruhi oleh inflow di lokasi tersebut dengan waktu yang berbeda. Misal, inflow di Kota Surabaya dipengaruhi oleh inflow Surabaya sendiri di 1 dan 2 bulan sebelumnya. Begitu juga inflow di Kota Malang, Kediri dan Jember memiliki interpretasi model yang sama dengan yang di Kota Surabaya.

c) Full Model pada Data Outflow

Tahapan penerapan bobot seragam pada data *outflow* dengan pemodelan $GSTAR([1,3]_1)$ sama dengan yang dilakukan pada data *inflow*. Matriks bobot seragam yang digunakan untuk melakukan estimasi parameter model $GSTAR([1,3]_1)$ sama dengan matriks bobot seragam untuk data *inflow*. Hasil penghitungan dengan estimasi parameter model $GSTAR([1,3]_1)$ adalah sebagai berikut:

Tabel 18 Estimasi Parameter *Full Model* dari metode GLS dengan Bobot Seragam pada $u_{i,t}$ *Outflow*

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.47	0.25	-1.89	0.06
	ϕ_{11}^1	1	0.04	0.48	0.07	0.94
	ϕ_{10}^3	1	0.09	0.10	0.86	0.39
	ϕ_{11}^3	1	-0.78	0.37	-2.13	0.04
Malang	ϕ_{20}^1	1	-0.34	0.10	-3.29	0.001
	ϕ_{21}^1	1	-0.05	0.06	-0.89	0.37
	ϕ_{20}^3	1	0.04	0.10	0.36	0.72
	ϕ_{21}^3	1	-0.08	0.06	-1.34	0.18
Kediri	ϕ_{30}^1	1	-0.31	0.09	-3.26	0.001
	ϕ_{31}^1	1	-0.19	0.10	-2.04	0.04
	ϕ_{30}^3	1	0.02	0.09	0.25	0.80
	ϕ_{31}^3	1	-0.05	0.10	-0.47	0.64
Jember	ϕ_{40}^1	1	-0.26	0.09	-3.08	0.002
	ϕ_{41}^1	1	-0.06	0.04	-1.72	0.09
	ϕ_{40}^3	1	-0.06	0.09	-0.73	0.47
	ϕ_{41}^3	1	0.01	0.04	0.31	0.76

Berdasarkan parameter-parameter pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model $GSTAR([1,3]_1)$ dengan menggunakan bobot seragam pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} -0.46 & 0 & 0 & 0 \\ 0 & -0.34 & 0 & 0 \\ 0 & 0 & -0.31 & 0 \\ 0 & 0 & 0 & -0.26 \end{pmatrix} + \\ \begin{pmatrix} 0.04 & 0 & 0 & 0 \\ 0 & -0.05 & 0 & 0 \\ 0 & 0 & -0.20 & 0 \\ 0 & 0 & 0 & -0.06 \end{pmatrix} \begin{pmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{pmatrix} \\ \begin{pmatrix} 0.09 & 0 & 0 & 0 \\ 0 & 0.04 & 0 & 0 \\ 0 & 0 & 0.02 & 0 \\ 0 & 0 & 0 & -0.06 \end{pmatrix} + \\ \begin{pmatrix} -0.78 & 0 & 0 & 0 \\ 0 & -0.08 & 0 & 0 \\ 0 & 0 & -0.05 & 0 \\ 0 & 0 & 0 & 0.01 \end{pmatrix} \begin{pmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{pmatrix} \end{bmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix}$$

Model GSTAR([1,3]₁) untuk $u_{i,t}$ *outflow* pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR ([1,3]₁) di Kota Surabaya

$$u_{1,t} = -0.46 u_{1,(t-1)} + 0.01 u_{2,(t-1)} + 0.01 u_{3,(t-1)} + 0.01 u_{4,(t-1)} + 0.09 u_{1,(t-3)} - 0.26 u_{2,(t-3)} - 0.26 u_{3,(t-3)} - 0.26 u_{4,(t-3)} + e_{1,t}$$
- Model GSTAR ([1,3]₁) di Kota Malang

$$u_{2,t} = -0.02 u_{1,(t-1)} - 0.34 u_{2,(t-1)} - 0.02 u_{3,(t-1)} - 0.02 u_{4,(t-1)} + -0.03 u_{1,(t-3)} + 0.04 u_{2,(t-3)} - 0.03 u_{3,(t-3)} - 0.03 u_{4,(t-3)} + e_{2,t}$$
- Model GSTAR ([1,3]₁) di Kota Kediri

$$u_{3,t} = -0.06 u_{1,(t-1)} - 0.06 u_{2,(t-1)} - 0.31 u_{3,(t-1)} - 0.06 u_{4,(t-1)} + -0.02 u_{1,(t-3)} - 0.02 u_{2,(t-3)} + 0.02 u_{3,(t-3)} - 0.02 u_{4,(t-3)} + e_{3,t}$$
- Model GSTAR ([1,3]₁) di Kabupaten Jember

$$u_{4,t} = -0.02 u_{1,(t-1)} - 0.02 u_{2,(t-1)} - 0.02 u_{3,(t-1)} - 0.26 u_{4,(t-1)} + 0.004 u_{1,(t-3)} + 0.004 u_{2,(t-3)} + 0.004 u_{3,(t-3)} - 0.06 u_{4,(t-3)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *outflow* di setiap lokasi dapat diketahui bahwa pengaruh *outflow* di suatu lokasi dipengaruhi oleh *outflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Misal, *outflow* di Kota Surabaya dipengaruhi oleh *outflow* Surabaya, Malang, Kediri dan Jember 1, 2 dan 3 bulan sebelumnya. Begitu juga *outflow* di Kota Malang, Kediri dan Jember memiliki interpretasi model yang sama dengan Kota Surabaya.

d) Restricted Model pada Data Outflow

Tidak semua parameter pada pemodelan GSTAR dengan bobot seragam signifikan. Pada bagian ini pemodelan GSTAR([1,3]₁) hanya dengan parameter yang signifikan saja sehingga didapatkan model yang *restricted*. Hasil penghitungan dengan estimasi parameter model GSTAR ([1,3]₁) adalah sebagai berikut:

Tabel 19 Estimasi Parameter *Restricted Model* dari metode GLS dengan Bobot Seragam pada $u_{i,t}$ Outflow

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.34	0.05	-6.67	<0.0001
	ϕ_{11}^3	1	-0.44	0.15	-3.03	0.003
Malang	ϕ_{20}^1	1	-0.34	0.05	-6.21	<0.0001
	ϕ_{21}^3	1	-0.06	0.02	-2.54	0.01
Kediri	ϕ_{30}^1	1	-0.41	0.05	-8.28	<0.0001
Jember	ϕ_{40}^1	1	-0.26	-0.32	0.06	-5.55

Berdasarkan parameter-parameter yang signifikan pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model *restricted* GSTAR([1,3]₁) dengan menggunakan bobot seragam pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} -0.34 & 0 & 0 & 0 \\ 0 & -0.34 & 0 & 0 \\ 0 & 0 & -0.41 & 0 \\ 0 & 0 & 0 & -0.32 \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \\ \begin{bmatrix} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} + \begin{pmatrix} -0.44 & 0 & 0 & 0 \\ 0 & -0.06 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix} \\ \begin{pmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{pmatrix} \end{bmatrix}$$

Model GSTAR([1,3]₁) untuk $u_{i,t}$ inflow pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR ([1,3]₁) di Kota Surabaya

$$u_{1,t} = -0.34 u_{1,(t-1)} - 0.14 u_{2,(t-3)} - 0.14 u_{3,(t-3)} - 0.14 u_{4,(t-3)} + e_{1,t}$$
- Model GSTAR ([1,3]₁) di Kota Malang

$$u_{2,t} = -0.34 u_{2,(t-1)} - 0.02 u_{1,(t-3)} - 0.02 u_{3,(t-3)} - 0.02 u_{4,(t-3)} + e_{2,t}$$
- Model GSTAR ([1,3]₁) di Kota Kediri

$$u_{3,t} = -0.41 u_{3,(t-1)} + e_{3,t}$$
- Model GSTAR ([1,3]₁) di Kabupaten Jember

$$u_{4,t} = -0.32 u_{4,(t-1)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *outflow* di setiap lokasi dapat diketahui bahwa pengaruh *outflow* di suatu lokasi dipengaruhi oleh *outflow* di lokasi tersebut dengan waktu yang berbeda. Ada juga suatu lokasi yang dipengaruhi di lokasi yang berbeda dan di waktu yang berbeda. Misal, *outflow* di Kota Surabaya dipengaruhi oleh *outflow* Surabaya sendiri di 1 dan 3 bulan sebelumnya serta pada tiga lokasi lainnya di 3 bulan sebelumnya. Begitu juga *outflow* di Kota Malang, Kediri dan Jember memiliki konsep interpretasi model yang sama dengan Kota Surabaya.

b. Bobot Invers Jarak

a) Full Model pada Data Inflow

Pemodelan GSTAR(3₁) dengan menggunakan bobot invers jarak mengasumsikan bahwa data *inflow* suatu lokasi dipengaruhi oleh jarak antara lokasi tersebut dengan lokasi lainnya. Jarak antara dua lokasi yang lebih jauh cenderung memiliki bobot yang lebih rendah dibandingkan dengan jarak antara dua lokasi yang lebih dekat. Matriks bobot invers jarak yang digunakan untuk mengestimasi atau menaksir parameter model GSTAR(3₁) dituliskan pada persamaan sebagai berikut.

$$W = \begin{bmatrix} 0 & 0,425 & 0,335 & 0,240 \\ 0,338 & 0 & 0,423 & 0,238 \\ 0,318 & 0,505 & 0 & 0,177 \\ 0,330 & 0,412 & 0,257 & 0 \end{bmatrix}$$

Hasil penghitungan dengan estimasi parameter model GSTAR (3₁) adalah sebagai berikut:

Tabel 20 Estimasi Parameter *Full Model* dari metode GLS dengan Bobot Invers Jarak pada $u_{i,t}$ *Inflow*

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.40	0.11	-3.80	0.0002
	ϕ_{11}^1	1	-0.58	0.35	-1.64	0.10
	ϕ_{10}^2	1	-0.30	0.11	-2.74	0.01
	ϕ_{11}^2	1	-0.31	0.37	-0.85	0.40
	ϕ_{10}^3	1	0.12	0.10	1.17	0.24
	ϕ_{11}^3	1	-0.61	0.35	-1.74	0.08
Malang	ϕ_{20}^1	1	-0.55	0.10	-5.64	<0.0001
	ϕ_{21}^1	1	0.09	0.07	1.26	0.21
	ϕ_{20}^2	1	-0.38	0.10	-3.75	0.0003
	ϕ_{21}^2	1	0.11	0.08	1.36	0.17

	ϕ_{20}^3	1	-0.15	0.10	-1.53	0.13
	ϕ_{21}^3	1	0.13	0.07	1.83	0.07
Kediri	ϕ_{30}^1	1	-0.50	0.10	-4.91	<0.0001
	ϕ_{31}^1	1	-0.01	0.08	-0.12	0.91
	ϕ_{30}^2	1	-0.49	0.10	-4.96	<0.0001
	ϕ_{31}^2	1	0.07	0.08	0.93	0.35
	ϕ_{30}^3	1	-0.21	0.11	-1.99	0.05
	ϕ_{31}^3	1	0.10	0.08	1.27	0.21
	Jember	ϕ_{40}^1	1	-0.42	0.09	-4.59
ϕ_{41}^1		1	-0.02	0.05	-0.35	0.72
ϕ_{40}^2		1	-0.35	0.10	-3.69	0.0003
ϕ_{41}^2		1	0.01	0.05	0.12	0.91
ϕ_{40}^3		1	-0.18	0.09	-1.94	0.05
ϕ_{41}^3		1	0.05	0.05	1.01	0.32

Berdasarkan parameter-parameter pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model GSTAR(3₁) dengan menggunakan bobot invers jarak pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{pmatrix} -0.40 & 0 & 0 & 0 \\ 0 & -0.55 & 0 & 0 \\ 0 & 0 & -0.50 & 0 \\ 0 & 0 & 0 & -0.42 \end{pmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{pmatrix} -0.58 & 0 & 0 & 0 \\ 0 & 0.09 & 0 & 0 \\ 0 & 0 & -0.009 & 0 \\ 0 & 0 & 0 & -0.02 \end{pmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{pmatrix} 0 & 0.425 & 0.335 & 0.240 \\ 0.338 & 0 & 0.423 & 0.238 \\ 0.318 & 0.505 & 0 & 0.177 \\ 0.330 & 0.412 & 0.257 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \begin{pmatrix} -0.30 & 0 & 0 & 0 \\ 0 & -0.38 & 0 & 0 \\ 0 & 0 & -0.49 & 0 \\ 0 & 0 & 0 & -0.35 \end{pmatrix} \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \begin{pmatrix} -0.31 & 0 & 0 & 0 \\ 0 & 0.11 & 0 & 0 \\ 0 & 0 & 0.07 & 0 \\ 0 & 0 & 0 & 0.006 \end{pmatrix} \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \begin{pmatrix} 0 & 0.425 & 0.335 & 0.240 \\ 0.338 & 0 & 0.423 & 0.238 \\ 0.318 & 0.505 & 0 & 0.177 \\ 0.330 & 0.412 & 0.257 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} 0.12 & 0 & 0 & 0 \\ 0 & -0.15 & 0 & 0 \\ 0 & 0 & -0.21 & 0 \\ 0 & 0 & 0 & -0.18 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} -0.61 & 0 & 0 & 0 \\ 0 & 0.13 & 0 & 0 \\ 0 & 0 & 0.10 & 0 \\ 0 & 0 & 0 & 0.05 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix}$$

Model GSTAR(3₁) untuk $u_{i,t}$ inflow pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR (3₁) di Kota Surabaya

$$\begin{aligned}
 u_{1,t} = & -0.40 u_{1,(t-1)} - 0.24 u_{2,(t-1)} - 0.19 u_{3,(t-1)} - \\
 & 0.14 u_{4,(t-1)} + -0.30 u_{1,(t-2)} - 0.13 u_{2,(t-2)} - \\
 & 0.10 u_{3,(t-2)} - 0.07 u_{4,(t-2)} + 0.12 u_{1,(t-3)} - \\
 & 0.26 u_{2,(t-3)} - 0.20 u_{3,(t-3)} - 0.15 u_{4,(t-3)} + e_{1,t}
 \end{aligned}$$

- Model GSTAR (3₁) di Kota Malang

$$\begin{aligned}
 u_{2,t} = & 0.03 u_{1,(t-1)} - 0.55 u_{2,(t-1)} + 0.04 u_{3,(t-1)} - \\
 & 0.02 u_{4,(t-1)} + 0.04 u_{1,(t-2)} - 0.38 u_{2,(t-2)} +
 \end{aligned}$$

$$0.04 u_{3,(t-2)} + 0.02 u_{4,(t-2)} + 0.05 u_{1,(t-3)} - \\ 0.15 u_{2,(t-3)} + 0.06 u_{3,(t-3)} + 0.03 u_{4,(t-3)} + e_{2,t}$$

- Model GSTAR (3₁) di Kota Kediri

$$u_{3,t} = -0.003 u_{1,(t-1)} - 0.005 u_{2,(t-1)} - 0.5 u_{3,(t-1)} - \\ 0.002 u_{4,(t-1)} + 0.02 u_{1,(t-2)} + 0.04 u_{2,(t-2)} - \\ 0.49 u_{3,(t-2)} + 0.01 u_{4,(t-2)} + 0.03 u_{1,(t-3)} + \\ 0.05 u_{2,(t-3)} - 0.21 u_{3,(t-3)} + 0.02 u_{4,(t-3)} + e_{3,t}$$

- Model GSTAR (3₁) di Kabupaten Jember

$$u_{4,t} = -0.006 u_{1,(t-1)} - 0.007 u_{2,(t-1)} - \\ 0.005 u_{3,(t-1)} - 0.42 u_{4,(t-1)} + 0.002 u_{1,(t-2)} + \\ 0.003 u_{2,(t-2)} + 0.002 u_{3,(t-2)} - 0.35 u_{4,(t-2)} + \\ 0.02 u_{1,(t-3)} + 0.02 u_{2,(t-3)} + 0.01 u_{3,(t-3)} - \\ 0.18 u_{4,(t-3)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *inflow* di setiap lokasi dapat diketahui bahwa pengaruh *inflow* di suatu lokasi dipengaruhi oleh *inflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Misal, *inflow* di Kota Surabaya dipengaruhi oleh *inflow* Surabaya, Malang, Kediri dan Jember 1, 2 dan 3 bulan sebelumnya. Begitu juga *inflow* di Kota Malang, Kediri dan Jember memiliki interpretasi model yang sama dengan yang di Kota Surabaya.

b) Restricted Model pada Data Inflow

Tidak semua parameter pada pemodelan GSTAR dengan bobot invers jarak signifikan. Pada bagian ini pemodelan GSTAR(3₁) hanya dengan parameter yang signifikan saja sehingga didapatkan model yang *restricted*. Hasil penghitungan dengan estimasi parameter model GSTAR (3₁) adalah sebagai berikut:

Tabel 21 Estimasi Parameter *Restricted Model* dari metode GLS dengan Bobot Invers Jarak pada $u_{i,t}$ *Inflow*

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.52	0.05	-9.57	<0.0001
	ϕ_{10}^2	1	-0.42	0.06	-7.40	<0.0001
	ϕ_{11}^3	1	-0.39	0.17	-2.35	0.02
Malang	ϕ_{20}^1	1	-0.37	0.05	-7.07	<0.0001
	ϕ_{20}^2	1	-0.26	0.05	-4.95	<0.0001
Kediri	ϕ_{30}^1	1	-0.47	0.05	-8.88	<0.0001
	ϕ_{30}^2	1	-0.42	0.05	-7.69	<0.0001
	ϕ_{30}^3	1	-0.12	0.04	-2.77	0.007
Jember	ϕ_{40}^1	1	-0.42	0.06	-7.39	<0.0001
	ϕ_{40}^2	1	-0.36	0.06	-6.11	<0.0001
	ϕ_{40}^3	1	-0.11	0.05	-2.17	0.03

Berdasarkan parameter-parameter yang signifikan pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model *restricted* GSTAR(3₁) dengan menggunakan bobot invers jarak pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} -0.52 & 0 & 0 & 0 \\ 0 & -0.37 & 0 & 0 \\ 0 & 0 & -0.47 & 0 \\ 0 & 0 & 0 & -0.42 \end{pmatrix} & \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \\ \begin{pmatrix} -0.42 & 0 & 0 & 0 \\ 0 & -0.26 & 0 & 0 \\ 0 & 0 & -0.42 & 0 \\ 0 & 0 & 0 & -0.36 \end{pmatrix} & \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \\ \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & -0.12 & 0 \\ 0 & 0 & 0 & -0.11 \end{pmatrix} & \begin{pmatrix} -0.39 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \end{bmatrix} + \begin{pmatrix} 0 & 0,425 & 0,335 & 0,240 \\ 0,338 & 0 & 0,423 & 0,238 \\ 0,318 & 0,505 & 0 & 0,177 \\ 0,330 & 0,412 & 0,257 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{pmatrix} 0 & 0,425 & 0,335 & 0,240 \\ 0,338 & 0 & 0,423 & 0,238 \\ 0,318 & 0,505 & 0 & 0,177 \\ 0,330 & 0,412 & 0,257 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \begin{pmatrix} 0 & 0,425 & 0,335 & 0,240 \\ 0,338 & 0 & 0,423 & 0,238 \\ 0,318 & 0,505 & 0 & 0,177 \\ 0,330 & 0,412 & 0,257 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix}$$

Model GSTAR(3₁) untuk $u_{i,t}$ *inflow* pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR (3₁) di Kota Surabaya

$$u_{1,t} = -0.52 u_{1,(t-1)} - 0.42 u_{1,(t-2)} - 0.17 u_{2,(t-3)} - 0.13 u_{3,(t-3)} + -0.09 u_{4,(t-3)} + e_{1,t}$$
- Model GSTAR (3₁) di Kota Malang

$$u_{2,t} = -0.37 u_{2,(t-1)} - 0.26 u_{3,(t-2)} + e_{2,t}$$
- Model GSTAR (3₁) di Kota Kediri

$$u_{3,t} = -0.47 u_{3,(t-1)} - 0.42 u_{3,(t-2)} - 0.12 u_{3,(t-3)} + e_{3,t}$$
- Model GSTAR (3₁) di Kabupaten Jember

$$u_{4,t} = 0.42 u_{4,(t-1)} - 0.36 u_{4,(t-2)} - 0.11 u_{4,(t-3)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *inflow* di setiap lokasi bahwa pengaruh *inflow* di suatu lokasi dipengaruhi oleh *inflow* di lokasi tersebut dengan waktu yang berbeda. Misal, *inflow* di Kota Surabaya dipengaruhi oleh *inflow* Surabaya sendiri di 1 dan 2 bulan sebelumnya serta dipengaruhi oleh Kota Malang, Kediri dan Jember di 3 bulan sebelumnya. Begitu juga *inflow* di Kota Malang, Kediri dan Jember memiliki konsep interpretasi model yang sama dengan Kota Surabaya.

c) Full Model pada Data Outflow

Penerapan bobot invers jarak pada data *outflow* dengan pemodelan GSTAR([1,3]₁) sama dengan yang diterapkan pada data *inflow*. Matriks bobot invers jarak yang digunakan untuk mengestimasi atau menaksir parameter model GSTAR([1,3]₁) sama dengan matriks bobot invers jarak untuk data *inflow* yang tertulis dalam persamaan sebelumnya. Hasil penghitungan dengan estimasi parameter model GSTAR ([1,3]₁) adalah sebagai berikut:

Tabel 22 Estimasi Parameter *Full Model* dari metode GLS dengan Bobot Invers Jarak pada $u_{i,t} Outflow$

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.45	0.33	-1.37	0.17
	ϕ_{11}^1	1	0.00	0.58	0.01	0.99
	ϕ_{10}^3	1	0.09	0.10	0.82	0.41
	ϕ_{11}^3	1	-0.72	0.37	-1.97	0.05
Malang	ϕ_{20}^1	1	-0.34	0.10	-3.34	0.001
	ϕ_{21}^1	1	-0.05	0.06	-0.88	0.38
	ϕ_{20}^3	1	0.02	0.10	0.21	0.84
	ϕ_{21}^3	1	-0.07	0.06	-1.18	0.24
Kediri	ϕ_{30}^1	1	-0.32	0.09	-3.50	0.0006
	ϕ_{31}^1	1	-0.18	0.09	-1.98	0.05
	ϕ_{30}^3	1	0.04	0.09	0.41	0.68
	ϕ_{31}^3	1	-0.05	0.09	-0.57	0.57
Jember	ϕ_{40}^1	1	-0.25	0.09	-2.97	0.004
	ϕ_{41}^1	1	-0.07	0.04	-1.83	0.07
	ϕ_{40}^3	1	-0.06	0.09	-0.70	0.49
	ϕ_{41}^3	1	0.01	0.04	0.34	0.73

Berdasarkan parameter-parameter pada Tabel tersebut, makadapat dibentuk persamaan matriks untuk model GSTAR([1,3]₁) dengan menggunakan bobot invers jarak pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{pmatrix} -0.45 & 0 & 0 & 0 \\ 0 & -0.34 & 0 & 0 \\ 0 & 0 & -0.32 & 0 \\ 0 & 0 & 0 & -0.25 \end{pmatrix} + \begin{pmatrix} 0.004 & 0 & 0 & 0 \\ 0 & -0.05 & 0 & 0 \\ 0 & 0 & -0.18 & 0 \\ 0 & 0 & 0 & -0.07 \end{pmatrix} \begin{pmatrix} 0 & 0,425 & 0,335 & 0,240 \\ 0,338 & 0 & 0,423 & 0,238 \\ 0,318 & 0,505 & 0 & 0,177 \\ 0,330 & 0,412 & 0,257 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{pmatrix} 0.85 & 0 & 0 & 0 \\ 0 & 0.02 & 0 & 0 \\ 0 & 0 & 0.04 & 0 \\ 0 & 0 & 0 & -0.06 \end{pmatrix} + \begin{pmatrix} -0.72 & 0 & 0 & 0 \\ 0 & -0.07 & 0 & 0 \\ 0 & 0 & -0.05 & 0 \\ 0 & 0 & 0 & 0.01 \end{pmatrix} \begin{pmatrix} 0 & 0,425 & 0,335 & 0,240 \\ 0,338 & 0 & 0,423 & 0,238 \\ 0,318 & 0,505 & 0 & 0,177 \\ 0,330 & 0,412 & 0,257 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix}$$

Model GSTAR([1,3]₁) untuk $u_{i,t}$ outflow pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR([1,3]₁) di Kota Surabaya

$$u_{1,t} = -0.45 u_{1,(t-1)} + 0.002 u_{2,(t-1)} + 0.002 u_{3,(t-1)} + 0.001 u_{4,(t-1)} + 0.08 u_{1,(t-3)} - 0.31 u_{2,(t-3)} - 0.24 u_{3,(t-3)} - 0.17 u_{4,(t-3)} + e_{1,t}$$
- Model GSTAR([1,3]₁) di Kota Malang

$$u_{2,t} = -0.02 u_{1,(t-1)} - 0.34 u_{2,(t-1)} - 0.02 u_{3,(t-1)} - 0.01 u_{4,(t-1)} + -0.02 u_{1,(t-3)} + 0.02 u_{2,(t-3)} - 0.03 u_{3,(t-3)} - 0.02 u_{4,(t-3)} + e_{2,t}$$
- Model GSTAR([1,3]₁) di Kota Kediri

$$u_{3,t} = -0.058 u_{1,(t-1)} - 0.09 u_{2,(t-1)} - 0.32 u_{3,(t-1)} - 0.03 u_{4,(t-1)} + 0.02 u_{1,(t-3)} - 0.03 u_{2,(t-3)} + 0.04 u_{3,(t-3)} - 0.01 u_{4,(t-3)} + e_{3,t}$$

- Model GSTAR([1,3]₁) di Kabupaten Jember

$$u_{4,t} = -0.02 u_{1,(t-1)} - 0.03 u_{2,(t-1)} - 0.02 u_{3,(t-1)} - 0.25 u_{4,(t-1)} + 0.004 u_{1,(t-3)} + 0.005 u_{2,(t-3)} + 0.003 u_{3,(t-3)} - 0.06 u_{4,(t-3)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *outflow* di setiap lokasi dapat diketahui bahwa pengaruh *outflow* di suatu lokasi dipengaruhi oleh *outflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Misal, *outflow* di Kota Surabaya dipengaruhi oleh *outflow* Surabaya, Malang, Kediri dan Jember 1 dan 3 bulan sebelumnya. Begitu juga *inflow* di Kota Malang, Kediri dan Jember memiliki konsep interpretasi model yang sama dengan Kota Surabaya.

d) Restricted Model pada Data Outflow

Tidak semua parameter pada pemodelan GSTAR dengan bobot invers jarak signifikan. Pada bagian ini pemodelan GSTAR([1,3]₁) hanya dengan parameter yang signifikan saja sehingga didapatkan model yang *restricted*. Hasil penghitungan dengan estimasi parameter model GSTAR ([1,3]₁) adalah sebagai berikut:

Tabel 23 Estimasi Parameter *Restricted Model* dari metode GLS dengan Bobot Invers Jarak pada $u_{i,t}$ Outflow

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.33	0.05	-6.65	<0.0001
	ϕ_{11}^3	1	-0.41	0.14	-2.91	0.004
Malang	ϕ_{20}^1	1	-0.34	0.05	-6.21	<0.0001
	ϕ_{21}^3	1	-0.05	0.02	-2.45	0.02
Kediri	ϕ_{30}^1	1	-0.41	0.05	-8.27	<0.0001
Jember	ϕ_{40}^1	1	-0.32	0.06	-5.55	<0.0001

Berdasarkan parameter-parameter yang signifikan pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model *restricted* GSTAR([1,3]₁) dengan menggunakan bobot invers jarak pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} -0.34 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & -0.41 & 0 \\ 0 & 0 & 0 & -0.32 \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} 0 & 0,425 & 0,335 & 0,240 \\ 0,338 & 0 & 0,423 & 0,238 \\ 0,318 & 0,505 & 0 & 0,177 \\ 0,330 & 0,412 & 0,257 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{bmatrix} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} + \begin{pmatrix} -0.41 & 0 & 0 & 0 \\ 0 & -0.05 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix} \\ \begin{pmatrix} 0 & 0,425 & 0,335 & 0,240 \\ 0,338 & 0 & 0,423 & 0,238 \\ 0,318 & 0,505 & 0 & 0,177 \\ 0,330 & 0,412 & 0,257 & 0 \end{pmatrix} \end{bmatrix}$$

Model GSTAR([1,3]₁) untuk $u_{i,t}$ *outflow* pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR ([1,3]₁) di Kota Surabaya

$$u_{1,t} = -0.33 u_{1,(t-1)} - 0.17 u_{2,(t-3)} - 0.14 u_{3,(t-3)} - 0.10 u_{4,(t-3)} + e_{1,t}$$
- Model GSTAR ([1,3]₁) di Kota Malang

$$u_{2,t} = -0.02 u_{1,(t-3)} - 0.02 u_{3,(t-3)} - 0.01 u_{4,(t-3)} + e_{2,t}$$
- Model GSTAR ([1,3]₁) di Kota Kediri

$$u_{3,t} = -0.41 u_{3,(t-1)} + e_{3,t}$$
- Model GSTAR ([1,3]₁) di Kabupaten Jember

$$u_{4,t} = -0.32 u_{4,(t-1)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *outflow* di setiap lokasi dapat diketahui bahwa pengaruh *outflow* di suatu lokasi dipengaruhi oleh *outflow* di lokasi tersebut dengan waktu yang berbeda. Ada juga suatu lokasi yang dipengaruhi di lokasi yang berbeda dan di waktu yang berbeda. Misal, *outflow* di Kota Surabaya dipengaruhi oleh *outflow* Surabaya sendiri di 1 bulan sebelumnya serta pada tiga lokasi lainnya di 3 bulan sebelumnya. Begitu juga *outflow* di Kota Malang, Kediri dan Jember memiliki konsep interpretasi model yang sama dengan Kota Surabaya.

c. Bobot Normalisasi Korelasi Silang

a) Full Model pada Data Inflow

Penerapan bobot normalisasi korelasi silang pada pemodelan GSTAR mengasumsikan bahwa keterkaitan *inflow* antar lokasi lebih dipengaruhi oleh tinggi rendahnya korelasi yang dimiliki dari *inflow* pada suatu lokasi. Perhitungan bobot normalisasi korelasi silang diperoleh melalui normalisasi dari nilai-nilai korelasi antar lokasi pada lag yang bersesuaian. Dikarenakan model yang digunakan adalah GSTAR(3₁) maka korelasi silang yang digunakan yang terdapat di lag 1, 2 dan 3. Matriks bobot normalisasi korelasi silang yang digunakan untuk mengestimasi atau menaksir parameter model GSTAR(3₁) untuk lag 1 dituliskan pada persamaan sebagai berikut.

$$W_1 = \begin{bmatrix} 0 & 0.37 & 0.34 & 0.29 \\ 0.24 & 0 & 0.37 & 0.38 \\ 0.27 & 0.37 & 0 & 0.36 \\ 0.29 & 0.41 & 0.30 & 0 \end{bmatrix}$$

Matriks bobot normalisasi korelasi silang untuk lag 2 dituliskan pada persamaan sebagai berikut.

$$W_2 = \begin{bmatrix} 0 & 0.32 & 0.22 & 0.47 \\ 0.43 & 0 & 0.31 & 0.26 \\ 0.37 & 0.35 & 0 & 0.28 \\ 0.35 & 0.36 & 0.29 & 0 \end{bmatrix}$$

Matriks bobot normalisasi korelasi silang untuk lag 3 dituliskan pada persamaan sebagai berikut.

$$W_3 = \begin{bmatrix} 0 & 0.34 & 0.45 & 0.70 \\ 0.62 & 0 & 0.61 & 0.63 \\ 0.46 & 0.19 & 0 & 0.52 \\ 0.35 & 0.26 & 0.18 & 0 \end{bmatrix}$$

Hasil penghitungan dengan estimasi parameter model GSTAR (3₁) adalah sebagai berikut:

Tabel 24 Estimasi Parameter *Full Model* dari metode GLS dengan Bobot Normalisasi Korelasi Silang pada $u_{i,t}$ *Inflow*

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	0.002	0.24	0.01	0.99
	ϕ_{11}^1	1	1.06	0.47	2.26	0.03
	ϕ_{10}^2	1	-0.23	0.11	-2.10	0.04
	ϕ_{11}^2	1	-0.61	0.39	-1.56	0.12
	ϕ_{10}^3	1	0.15	0.11	1.45	0.15
	ϕ_{11}^3	1	-0.45	0.25	-1.82	0.07
Malang	ϕ_{20}^1	1	-0.55	0.10	-5.43	<0.0001
	ϕ_{21}^1	1	-0.09	0.09	-0.95	0.34
	ϕ_{20}^2	1	-0.38	0.10	-3.93	0.0001
	ϕ_{21}^2	1	0.09	0.07	1.31	0.19
	ϕ_{20}^3	1	-0.14	0.09	-1.50	0.14
	ϕ_{21}^3	1	0.08	0.04	1.88	0.06
Kediri	ϕ_{30}^1	1	-0.52	0.10	-5.32	<0.0001
	ϕ_{31}^1	1	0.01	0.08	0.16	0.87
	ϕ_{30}^2	1	-0.51	0.09	-5.55	<0.0001
	ϕ_{31}^2	1	0.07	0.07	1.03	0.31
	ϕ_{30}^3	1	-0.26	0.10	-2.70	0.01
	ϕ_{31}^3	1	0.12	0.06	2.03	0.04
Jember	ϕ_{40}^1	1	-0.42	0.09	-4.55	<0.0001
	ϕ_{41}^1	1	0.03	0.05	0.58	0.56
	ϕ_{40}^2	1	-0.37	0.10	-3.85	0.0002
	ϕ_{41}^2	1	0.01	0.05	0.18	0.86
	ϕ_{40}^3	1	-0.17	0.09	-1.84	0.07
	ϕ_{41}^3	1	0.06	0.05	1.15	0.25

Berdasarkan parameter-parameter pada Tabel tersebut, makadapat dibentuk persamaan matriks untuk model GSTAR(3₁) dengan menggunakan bobot normalisasi korelasi silang pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} 0.002 & 0 & 0 & 0 \\ 0 & -0.55 & 0 & 0 \\ 0 & 0 & -0.52 & 0 \\ 0 & 0 & 0 & -0.42 \end{pmatrix} + \begin{pmatrix} 1.06 & 0 & 0 & 0 \\ 0 & -0.09 & 0 & 0 \\ 0 & 0 & 0.01 & 0 \\ 0 & 0 & 0 & 0.03 \end{pmatrix} \\ \begin{pmatrix} 0 & 0.37 & 0.34 & 0.29 \\ 0.24 & 0 & 0.37 & 0.38 \\ 0.27 & 0.37 & 0 & 0.36 \\ 0.29 & 0.41 & 0.30 & 0 \end{pmatrix} \end{bmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \\ \begin{bmatrix} \begin{pmatrix} -0.23 & 0 & 0 & 0 \\ 0 & -0.38 & 0 & 0 \\ 0 & 0 & -0.51 & 0 \\ 0 & 0 & 0 & -0.37 \end{pmatrix} + \begin{pmatrix} -0.61 & 0 & 0 & 0 \\ 0 & 0.09 & 0 & 0 \\ 0 & 0 & 0.07 & 0 \\ 0 & 0 & 0 & 0.009 \end{pmatrix} \\ \begin{pmatrix} 0 & 0.32 & 0.22 & 0.47 \\ 0.43 & 0 & 0.31 & 0.26 \\ 0.37 & 0.35 & 0 & 0.28 \\ 0.35 & 0.36 & 0.29 & 0 \end{pmatrix} \end{bmatrix} \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \\ \begin{bmatrix} \begin{pmatrix} 0.16 & 0 & 0 & 0 \\ 0 & -0.14 & 0 & 0 \\ 0 & 0 & -0.26 & 0 \\ 0 & 0 & 0 & -0.17 \end{pmatrix} + \begin{pmatrix} -0.45 & 0 & 0 & 0 \\ 0 & 0.08 & 0 & 0 \\ 0 & 0 & 0.12 & 0 \\ 0 & 0 & 0 & 0.06 \end{pmatrix} \\ \begin{pmatrix} 0 & 0.34 & 0.45 & 0.70 \\ 0.62 & 0 & 0.61 & 0.63 \\ 0.46 & 0.19 & 0 & 0.52 \\ 0.35 & 0.26 & 0.18 & 0 \end{pmatrix} \end{bmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix}.$$

Model GSTAR(3₁) untuk $u_{i,t}$ inflow pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR (3₁) di Kota Surabaya

$$\begin{aligned}
 u_{1,t} = & 0.002 u_{1,(t-1)} + 0.39 u_{2,(t-1)} + 0.36 u_{3,(t-1)} + \\
 & 0.31 u_{4,(t-1)} \pm 0.23 u_{1,(t-2)} - 0.19 u_{2,(t-2)} - \\
 & 0.13 u_{3,(t-2)} - 0.28 u_{4,(t-2)} + 0.15 u_{1,(t-3)} - \\
 & 0.16 u_{2,(t-3)} - 0.20 u_{3,(t-3)} - 0.32 u_{4,(t-3)} + e_{1,t}
 \end{aligned}$$

- Model GSTAR (3₁) di Kota Malang

$$u_{2,t} = -0.02 u_{1,(t-1)} - 0.54 u_{2,(t-1)} - 0.03 u_{3,(t-1)} - 0.03 u_{4,(t-1)} + 0.04 u_{1,(t-2)} - 0.38 u_{2,(t-2)} + 0.03 u_{3,(t-2)} + 0.02 u_{4,(t-2)} + 0.05 u_{1,(t-3)} - 0.14 u_{2,(t-3)} + 0.05 u_{3,(t-3)} + 0.05 u_{4,(t-3)} + e_{2,t}$$
- Model GSTAR (3₁) di Kota Kediri

$$u_{3,t} = 0.004 u_{1,(t-1)} + 0.005 u_{2,(t-1)} - 0.5 u_{3,(t-1)} + 0.005 u_{4,(t-1)} + 0.03 u_{1,(t-2)} + 0.03 u_{2,(t-2)} - 0.51 u_{3,(t-2)} + 0.02 u_{4,(t-2)} + 0.06 u_{1,(t-3)} + 0.02 u_{2,(t-3)} - 0.26 u_{3,(t-3)} + 0.06 u_{4,(t-3)} + e_{3,t}$$
- Model GSTAR (3₁) di Kabupaten Jember

$$u_{4,t} = 0.009 u_{1,(t-1)} + 0.01 u_{2,(t-1)} + 0.01 u_{3,(t-1)} - 0.42 u_{4,(t-1)} + 0.003 u_{1,(t-2)} + 0.003 u_{2,(t-2)} + 0.003 u_{3,(t-2)} - 0.37 u_{4,(t-2)} + 0.02 u_{1,(t-3)} + 0.02 u_{2,(t-3)} + 0.01 u_{3,(t-3)} - 0.17 u_{4,(t-3)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *inflow* di setiap lokasi dapat diketahui bahwa pengaruh *inflow* di suatu lokasi dipengaruhi oleh *inflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Misal, *inflow* di Kota Surabaya dipengaruhi oleh *inflow* Surabaya, Malang, Kediri dan Jember 1, 2 dan 3 bulan sebelumnya. Begitu juga *inflow* di Kota Malang, Kediri dan Jember memiliki interpretasi model yang sama dengan yang di Kota Surabaya.

b) Restricted Model pada Data Inflow

Tidak semua parameter pada pemodelan GSTAR dengan bobot normalisasi korelasi silang signifikan. Pada bagian ini pemodelan GSTAR(3₁) hanya dengan parameter yang signifikan saja sehingga didapatkan model yang *restricted*. Hasil penghitungan dengan estimasi parameter model GSTAR (3₁) adalah sebagai berikut:

Tabel 25 Estimasi Parameter *Restricted Model* dari metode GLS dengan Bobot Normalisasi Korelasi Silang pada $u_{i,t}$ *Inflow*

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{11}^1	1	1.00	0.10	9.89	<0.0001
	ϕ_{10}^2	1	-0.40	0.06	-7.22	<0.0001
	ϕ_{11}^3	1	-0.25	0.12	-2.05	0.04
Malang	ϕ_{20}^1	1	-0.42	0.05	-7.81	<0.0001
	ϕ_{20}^2	1	-0.26	0.05	-5.02	<0.0001
Kediri	ϕ_{30}^1	1	-0.53	0.06	-9.57	<0.0001
	ϕ_{30}^2	1	-0.43	0.05	-7.9	<0.0001
	ϕ_{30}^3	1	-0.27	0.08	-3.44	0.0008
	ϕ_{31}^3	1	0.09	0.04	2.2	0.03
Jember	ϕ_{40}^1	1	-0.47	0.06	-7.93	<0.0001
	ϕ_{40}^2	1	-0.36	0.06	-6.05	<0.0001
	ϕ_{40}^3	1	-0.11	0.05	-2.09	0.04

Berdasarkan parameter-parameter yang signifikan pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model *restricted* GSTAR(3₁) dengan menggunakan bobot normalisasi korelasi silang pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & -0.42 & 0 & 0 \\ 0 & 0 & -0.53 & 0 \\ 0 & 0 & 0 & -0.47 \end{pmatrix} + \begin{pmatrix} 1.04 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} 0 & 0.37 & 0.34 & 0.29 \\ 0.24 & 0 & 0.37 & 0.38 \\ 0.27 & 0.37 & 0 & 0.36 \\ 0.29 & 0.41 & 0.30 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \\
 \begin{pmatrix} -0.40 & 0 & 0 & 0 \\ 0 & -0.26 & 0 & 0 \\ 0 & 0 & -0.43 & 0 \\ 0 & 0 & 0 & -0.36 \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} 0 & 0.32 & 0.22 & 0.47 \\ 0.43 & 0 & 0.31 & 0.26 \\ 0.37 & 0.35 & 0 & 0.28 \\ 0.35 & 0.36 & 0.29 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \\
 \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & -0.27 & 0 \\ 0 & 0 & 0 & -0.11 \end{pmatrix} + \begin{pmatrix} -0.25 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0.1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix} \\
 \begin{pmatrix} 0 & 0.34 & 0.45 & 0.70 \\ 0.62 & 0 & 0.61 & 0.63 \\ 0.46 & 0.19 & 0 & 0.52 \\ 0.35 & 0.26 & 0.18 & 0 \end{pmatrix}$$

Model GSTAR(3₁) untuk $u_{i,t}$ inflow pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR (3₁) di Kota Surabaya

$$\begin{aligned}
 u_{1,t} &= 0.37 u_{2,(t-1)} + 0.34 u_{3,(t-1)} + 0.30 u_{4,(t-1)} - \\
 &\quad 0.40 u_{1,(t-2)} + -0.87 u_{2,(t-3)} - 0.11 u_{3,(t-3)} - \\
 &\quad 0.18 u_{4,(t-3)} + e_{1,t}
 \end{aligned}$$
- Model GSTAR (3₁) di Kota Malang

$$u_{2,t} = -0.42 u_{2,(t-1)} - 0.26 u_{2,(t-2)} + e_{2,t}$$
- Model GSTAR (3₁) di Kota Kediri

$$\begin{aligned}
 u_{3,t} &= -0.53 u_{3,(t-1)} - 0.43 u_{3,(t-2)} + 0.04 u_{1,(t-3)} + \\
 &\quad 0.02 u_{2,(t-3)} - +0.27 u_{3,(t-3)} + 0.04 u_{4,(t-3)} + \\
 &\quad e_{3,t}
 \end{aligned}$$
- Model GSTAR (3₁) di Kabupaten Jember

$$\begin{aligned}
 u_{4,t} &= -0.47 u_{4,(t-1)} - 0.36 u_{4,(t-2)} - 0.11 u_{4,(t-3)} + \\
 &\quad e_{4,t}
 \end{aligned}$$

Berdasarkan model yang terbentuk untuk inflow di setiap lokasi dapat diketahui bahwa pengaruh inflow di suatu lokasi dipengaruhi oleh inflow di lokasi tersebut dengan waktu yang berbeda. Ada juga suatu lokasi yang dipengaruhi di lokasi

yang berbeda dan di waktu yang berbeda. Misal, *inflow* di Kota Surabaya dipengaruhi oleh *inflow* Surabaya sendiri di 2 bulan sebelumnya serta pada tiga lokasi lainnya di 1 dan 3 bulan sebelumnya. Begitu juga *inflow* di Kota Malang, Kediri dan Jember memiliki konsep interpretasi model yang sama dengan Kota Surabaya.

c) Full Model pada Data Outflow

Tahapan penerapan bobot normalisasi korelasi silang pada data *outflow* dengan pemodelan $GSTAR([1,3]_1)$ sama dengan yang dilakukan pada data *inflow*. Perhitungan bobot normalisasi korelasi silang diperoleh melalui normalisasi dari nilai-nilai korelasi antar lokasi pada lag yang bersesuaian. Dikarenakan model yang digunakan adalah $GSTAR([1,3]_1)$ maka korelasi silang yang digunakan yang terdapat di lag 1 dan 3. Matriks bobot normalisasi korelasi silang yang digunakan untuk mengestimasi atau menaksir parameter model $GSTAR([1,3]_1)$ untuk lag 1 dituliskan pada persamaan sebagai berikut.

$$W_1 = \begin{bmatrix} 0 & 0.37 & 0.31 & 0.32 \\ 0.42 & 0 & 0.30 & 0.28 \\ 0.37 & 0.33 & 0 & 0.30 \\ 0.36 & 0.36 & 0.28 & 0 \end{bmatrix}.$$

Sedangkan matriks bobot normalisasi korelasi silang untuk lag 6 dituliskan pada persamaan sebagai berikut.

$$W_3 = \begin{bmatrix} 0 & 0.14 & 0.44 & 0.42 \\ 0.52 & 0 & 0.26 & 0.22 \\ 0.66 & 0.22 & 0 & 0.11 \\ 0.34 & 0.36 & 0.31 & 0 \end{bmatrix}.$$

Hasil penghitungan dengan estimasi parameter model $GSTAR([1,3]_1)$ adalah sebagai berikut:

Tabel 26 Estimasi Parameter *Full Model* dari metode GLS dengan Bobot Normalisasi Korelasi Silang pada $u_{i,t}$ *Outflow*

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.45	0.33	-1.37	0.17
	ϕ_{11}^1	1	0.00	0.58	0.01	0.99
	ϕ_{10}^3	1	0.09	0.10	0.82	0.41
	ϕ_{11}^3	1	-0.72	0.37	-1.97	0.05
Malang	ϕ_{20}^1	1	-0.34	0.10	-3.34	0.001
	ϕ_{21}^1	1	-0.05	0.06	-0.88	0.38
	ϕ_{20}^3	1	0.02	0.10	0.21	0.84
	ϕ_{21}^3	1	-0.07	0.06	-1.18	0.24
Kediri	ϕ_{30}^1	1	-0.32	0.09	-3.50	0.0006
	ϕ_{31}^1	1	-0.18	0.09	-1.98	0.05
	ϕ_{30}^3	1	0.04	0.09	0.41	0.68
	ϕ_{31}^3	1	-0.05	0.09	-0.57	0.57
Jember	ϕ_{40}^1	1	-0.25	0.09	-2.97	0.004
	ϕ_{41}^1	1	-0.07	0.04	-1.83	0.07
	ϕ_{40}^3	1	-0.06	0.09	-0.70	0.49
	ϕ_{41}^3	1	0.01	0.04	0.34	0.73

Berdasarkan parameter-parameter pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model GSTAR([1,3]₁) dengan menggunakan bobot normalisasi korelasi silang pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{pmatrix} -0.48 & 0 & 0 & 0 \\ 0 & -0.32 & 0 & 0 \\ 0 & 0 & -0.30 & 0 \\ 0 & 0 & 0 & -0.26 \end{pmatrix} + \begin{pmatrix} 0 & 0.37 & 0.31 & 0.32 \\ 0.42 & 0 & 0.30 & 0.28 \\ 0.37 & 0.33 & 0 & 0.30 \\ 0.36 & 0.36 & 0.28 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{pmatrix} 0.04 & 0 & 0 & 0 \\ 0 & 0.07 & 0 & 0 \\ 0 & 0 & 0.01 & 0 \\ 0 & 0 & 0 & -0.02 \end{pmatrix} + \begin{pmatrix} 2.76 & 0 & 0 & 0 \\ 0 & 0.31 & 0 & 0 \\ 0 & 0 & 0.65 & 0 \\ 0 & 0 & 0 & 0.17 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix}$$

Model GSTAR([1,3]₁) untuk $u_{i,t}$ *outflow* pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR([1,3]₁) di Kota Surabaya

$$u_{1,t} = -0.48 u_{1,(t-1)} - 0.02 u_{2,(t-1)} - 0.01 u_{3,(t-1)} - 0.01 u_{4,(t-1)} + 0.04 u_{1,(t-3)} + 0.38 u_{2,(t-3)} + 1.21 u_{3,(t-3)} + 1.17 u_{4,(t-3)} + e_{1,t}$$
- Model GSTAR([1,3]₁) di Kota Malang

$$u_{2,t} = 0.02 u_{1,(t-1)} - 0.32 u_{2,(t-1)} + 0.02 u_{3,(t-1)} + 0.02 u_{4,(t-1)} + 0.16 u_{1,(t-3)} + 0.07 u_{2,(t-3)} + 0.08 u_{3,(t-3)} + 0.07 u_{4,(t-3)} + e_{2,t}$$
- Model GSTAR([1,3]₁) di Kota Kediri

$$u_{3,t} = 0.07 u_{1,(t-1)} + 0.06 u_{2,(t-1)} - 0.30 u_{3,(t-1)} + 0.06 u_{4,(t-1)} + 0.43 u_{1,(t-3)} + 0.14 u_{2,(t-3)} + 0.02 u_{3,(t-3)} + 0.07 u_{4,(t-3)} + e_{3,t}$$
- Model GSTAR([1,3]₁) di Kabupaten Jember

$$u_{4,t} = 0.02 u_{1,(t-1)} + 0.02 u_{2,(t-1)} + 0.02 u_{3,(t-1)} - 0.26 u_{4,(t-1)} + 0.06 u_{1,(t-3)} + 0.06 u_{2,(t-3)} + 0.05 u_{3,(t-3)} - 0.02 u_{4,(t-3)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *outflow* di setiap lokasi dapat diketahui bahwa pengaruh *outflow* di suatu lokasi dipengaruhi oleh *outflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Misal, *outflow* di Kota Surabaya dipengaruhi oleh *outflow* Surabaya, Malang, Kediri dan Jember 1 dan 3 bulan sebelumnya. Begitu juga *inflow* di Kota Malang, Kediri dan Jember memiliki konsep interpretasi model yang sama dengan Kota Surabaya.

d) Restricted Model pada Data Outflow

Tidak semua parameter pada pemodelan GSTAR dengan bobot normalisasi korelasi silang signifikan. Pada bagian ini pemodelan GSTAR([1,3]₁) hanya dengan parameter yang signifikan saja sehingga didapatkan model yang *restricted*. Hasil penghitungan dengan estimasi parameter model GSTAR ([1,3]₁) adalah sebagai berikut:

Tabel 27 Estimasi Parameter *Restricted Model* dari metode GLS dengan Bobot Normalisasi Korelasi Silang pada $u_{i,t}$

Outflow

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.34	0.05	-6.7	<.0001
	ϕ_{11}^3	1	1.75	0.54	3.23	0.002
Malang	ϕ_{20}^1	1	-0.33	0.05	-6.19	<.0001
	ϕ_{21}^3	1	0.17	0.06	2.72	0.007
Kediri	ϕ_{31}^1	1	-0.41	0.05	-8.29	<.0001
Jember	ϕ_{40}^1	1	-0.32	0.06	-5.57	<.0001

Berdasarkan parameter-parameter yang signifikan pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model *restricted* GSTAR([1,3]₁) dengan menggunakan bobot normalisasi korelasi silang pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} -0.36 & 0 & 0 & 0 \\ 0 & -0.35 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -0.32 \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & -0.34 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} 0 & 0.37 & 0.31 & 0.32 \\ 0.42 & 0 & 0.30 & 0.28 \\ 0.37 & 0.33 & 0 & 0.30 \\ 0.36 & 0.36 & 0.28 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{bmatrix} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} + \begin{pmatrix} -0.41 & 0 & 0 & 0 \\ 0 & -0.04 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix} \\ \begin{pmatrix} 0 & 0.14 & 0.44 & 0.42 \\ 0.52 & 0 & 0.26 & 0.22 \\ 0.66 & 0.22 & 0 & 0.11 \\ 0.34 & 0.36 & 0.31 & 0 \end{pmatrix} \end{bmatrix}$$

Model GSTAR([1,3]₁) untuk $u_{i,t}$ *outflow* pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR ([1,3]₁) di Kota Surabaya

$$u_{1,t} = -0.36 u_{1,(t-1)} - 0.55 u_{2,(t-3)} - 0.18 u_{3,(t-3)} - 0.17 u_{4,(t-3)} + e_{1,t}$$
- Model GSTAR ([1,3]₁) di Kota Malang

$$u_{2,t} = -0.35 u_{2,(t-1)} - 0.02 u_{1,(t-3)} - 0.01 u_{3,(t-3)} - 0.01 u_{4,(t-3)} + e_{2,t}$$
- Model GSTAR ([1,3]₁) di Kota Kediri

$$u_{3,t} = -0.12 u_{1,(t-1)} - 0.11 u_{2,(t-1)} - 0.10 u_{4,(t-1)} + e_{3,t}$$
- Model GSTAR ([1,3]₁) di Kabupaten Jember

$$u_{4,t} = -0.32 u_{4,(t-1)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *outflow* di setiap lokasi dapat diketahui bahwa pengaruh *outflow* di suatu lokasi dipengaruhi oleh *outflow* di lokasi tersebut dengan waktu yang berbeda. Ada juga suatu lokasi yang dipengaruhi di lokasi yang berbeda dan di waktu yang berbeda. Misal, *outflow* di Kota Surabaya dipengaruhi oleh *outflow* Surabaya sendiri di 1 bulan sebelumnya serta pada tiga lokasi lainnya di 3 bulan sebelumnya. Begitu juga *outflow* di Kota Malang, Kediri

dan Jember memiliki konsep interpretasi model yang sama dengan Kota Surabaya.

e. Bobot Normalisasi Inferensia Korelasi Silang Parsial

a) Full Model pada Data Inflow

Penerapan bobot normalisasi inferensia korelasi silang parsial pada pemodelan GSTAR(3₁) mengasumsikan bahwa keterkaitan *inflow* di suatu lokasi lebih dipengaruhi oleh tinggi rendahnya parsial korelasi yang dimiliki pada lokasi tersebut. Penghitungan bobot normalisasi inferensia korelasi silang parsial diperoleh melalui proses inferensia statistik yang dilakukan dengan menggunakan selang kepercayaan 95%, yaitu $t_{(0.05/2, (n-k-2))} / \sqrt{n}$ dengan $n = 132$ dengan lag ke- k . Korelasi silang yang digunakan yang terdapat di lag 1, 2 dan 3. Hasil perhitungan inferensia parsial korelasi silang antar lokasi pada lag 1, $r_{ij}(1)$, dapat dilihat pada Tabel sebagai berikut.

Tabel 28 Taksiran Normalisasi Korelasi Silang antar Lokasi $u_{i,t}$ Inflow dengan Selang Kepercayaan 95% untuk Lag 1

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$P_1(12)$	-0.422	-0.594	-0.250	tidak valid
$P_1(13)$	-0.414	-0.586	-0.242	tidak valid
$P_1(14)$	-0.339	-0.512	-0.167	tidak valid
$P_1(21)$	-0.187	-0.359	-0.015	tidak valid
$P_1(23)$	-0.298	-0.471	-0.126	tidak valid
$P_1(24)$	-0.293	-0.466	-0.121	tidak valid

Tabel 29 Taksiran Normalisasi Korelasi Silang antar Lokasi $u_{i,t}$ Inflow dengan Selang Kepercayaan 95% untuk Lag 1 (Lanjutan)

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$P_1(31)$	-0.183	-0.355	-0.011	tidak valid
$P_1(32)$	-0.342	-0.514	-0.169	tidak valid
$P_1(34)$	-0.324	-0.496	-0.152	tidak valid
$P_1(41)$	-0.228	-0.400	-0.056	tidak valid
$P_1(42)$	-0.320	-0.492	-0.148	tidak valid
$P_1(43)$	-0.257	-0.429	-0.085	tidak valid

Berdasarkan Tabel tersebut dapat diketahui bahwa nilai parsial korelasi silang antar lokasi tidak ada yang valid, sehingga bobot yang digunakan adalah bobot seragam untuk di lag 1. Sedangkan hasil perhitungan inferensia parsial korelasi silang antar lokasi pada lag 2, $r_{ij}(2)$, dapat dilihat pada Tabel berikut.

Tabel 30 Taksiran Normalisasi Korelasi Silang antar Lokasi $u_{i,t}$ Inflow dengan Selang Kepercayaan 95% untuk Lag 2

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$P_4(12)$	-0.085	-0.257	0.088	tidak valid
$P_4(13)$	-0.091	-0.263	0.081	tidak valid
$P_4(14)$	-0.125	-0.297	0.047	tidak valid
$P_4(21)$	-0.104	-0.276	0.068	tidak valid
$P_4(23)$	-0.142	-0.314	0.030	tidak valid
$P_4(24)$	-0.064	-0.237	0.108	tidak valid
$P_4(31)$	-0.089	-0.261	0.083	tidak valid
$P_4(32)$	-0.107	-0.279	0.065	tidak valid
$P_4(34)$	-0.023	-0.195	0.150	tidak valid
$P_4(41)$	-0.127	-0.299	0.045	tidak valid
$P_4(42)$	-0.132	-0.304	0.041	tidak valid
$P_4(43)$	-0.127	-0.299	0.045	tidak valid

Berdasarkan Tabel tersebut dapat diketahui bahwa nilai parsial korelasi silang antar lokasi tidak ada yang valid, sehingga bobot yang digunakan adalah bobot seragam untuk di lag 2. Sedangkan hasil perhitungan inferensia parsial korelasi silang antar lokasi pada lag 3, $r_{ij}(3)$, dapat dilihat pada Tabel berikut.

Tabel 31 Taksiran Normalisasi Korelasi Silang antar Lokasi $u_{i,t}$ Inflow dengan Selang Kepercayaan 95% untuk Lag 3

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$P_4(12)$	0.151	-0.021	0.151	tidak valid
$P_4(13)$	0.182	0.010	0.182	valid
$P_4(14)$	0.128	-0.044	0.128	tidak valid
$P_4(21)$	0.093	-0.079	0.093	tidak valid
$P_4(23)$	0.076	-0.096	0.076	tidak valid
$P_4(24)$	0.097	-0.076	0.097	tidak valid
$P_4(31)$	0.120	-0.052	0.120	tidak valid
$P_4(32)$	0.148	-0.025	0.148	tidak valid
$P_4(34)$	0.066	-0.106	0.066	tidak valid
$P_4(41)$	0.188	0.016	0.188	valid
$P_4(42)$	0.153	-0.019	0.153	tidak valid
$P_4(43)$	0.208	0.035	0.208	valid

Berdasarkan Tabel tersebut dapat diketahui bahwa nilai parsial korelasi silang antar lokasi ada yang valid dan tidak, sehingga bobot yang digunakan adalah bobot seperti berikut:

$$W_3 = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0.33 & 0 & 0.33 & 0.33 \\ 0.33 & 0.33 & 0 & 0.33 \\ 0.5 & 0 & 0.5 & 0 \end{bmatrix}$$

Hasil penghitungan dengan estimasi parameter model GSTAR (31) adalah sebagai berikut:

Tabel 32 Estimasi Parameter *Full Model* dari metode GLS dengan Bobot Normalisasi Inferensia Korelasi Silang Parsial pada $u_{i,t}$ *Inflow*

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{10}^1	1	-0.02	0.23	-0.07	0.94
	ϕ_{11}^1	1	-1.05	0.46	-2.31	0.02
	ϕ_{10}^2	1	-0.27	0.11	-2.49	0.01
	ϕ_{11}^2	1	-0.41	0.37	-1.12	0.26
	ϕ_{10}^3	1	0.10	0.10	1.01	0.32
	ϕ_{11}^3	1	-0.49	0.27	-1.81	0.07
Malang	ϕ_{20}^1	1	-0.56	0.10	-5.71	<0.0001
	ϕ_{21}^1	1	0.09	0.08	1.12	0.27
	ϕ_{20}^2	1	-0.39	0.10	-3.92	0.0001
	ϕ_{21}^2	1	0.11	0.08	1.39	0.17
	ϕ_{20}^3	1	-0.14	0.09	-1.46	0.15
	ϕ_{21}^3	1	0.13	0.08	1.63	0.11
Kediri	ϕ_{30}^1	1	-0.52	0.10	-5.32	<0.0001
	ϕ_{31}^1	1	-0.01	0.08	-0.13	0.90
	ϕ_{30}^2	1	-0.51	0.09	-5.45	<0.0001
	ϕ_{31}^2	1	0.08	0.08	1.02	0.31
	ϕ_{30}^3	1	-0.27	0.11	-2.54	0.01
	ϕ_{31}^3	1	0.14	0.08	1.70	0.09
Jember	ϕ_{40}^1	1	-0.41	0.09	-4.50	<0.0001
	ϕ_{41}^1	1	-0.03	0.05	-0.61	0.54
	ϕ_{40}^2	1	-0.34	0.10	-3.53	0.0006
	ϕ_{41}^2	1	-0.004	0.05	-0.08	0.94
	ϕ_{40}^3	1	-0.12	0.09	-1.32	0.19
	ϕ_{41}^3	1	0.01	0.04	0.39	0.70

Berdasarkan parameter-parameter pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model GSTAR(3₁) dengan menggunakan bobot normalisasi inferensia korelasi silang parsial pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} -0.02 & 0 & 0 & 0 \\ 0 & -0.56 & 0 & 0 \\ 0 & 0 & -0.52 & 0 \\ 0 & 0 & 0 & -0.41 \end{pmatrix} + \begin{pmatrix} -1.05 & 0 & 0 & 0 \\ 0 & 0.09 & 0 & 0 \\ 0 & 0 & -0.01 & 0 \\ 0 & 0 & 0 & -0.03 \end{pmatrix} \\ \begin{pmatrix} 0 & 0.33 & 0.33 & 0.33 \\ 0.33 & 0 & 0.33 & 0.33 \\ 0.33 & 0.33 & 0 & 0.33 \\ 0.33 & 0.33 & 0.33 & 0 \end{pmatrix} \\ \begin{pmatrix} -0.27 & 0 & 0 & 0 \\ 0 & -0.40 & 0 & 0 \\ 0 & 0 & -0.51 & 0 \\ 0 & 0 & 0 & -0.34 \end{pmatrix} + \begin{pmatrix} -0.41 & 0 & 0 & 0 \\ 0 & 0.11 & 0 & 0 \\ 0 & 0 & 0.08 & 0 \\ 0 & 0 & 0 & -0.004 \end{pmatrix} \\ \begin{pmatrix} 0 & 0.33 & 0.33 & 0.33 \\ 0.33 & 0 & 0.33 & 0.33 \\ 0.33 & 0.33 & 0 & 0.33 \\ 0.33 & 0.33 & 0.33 & 0 \end{pmatrix} \\ \begin{pmatrix} 0.10 & 0 & 0 & 0 \\ 0 & -0.14 & 0 & 0 \\ 0 & 0 & -0.27 & 0 \\ 0 & 0 & 0 & -0.12 \end{pmatrix} + \begin{pmatrix} -0.49 & 0 & 0 & 0 \\ 0 & 0.13 & 0 & 0 \\ 0 & 0 & 0.14 & 0 \\ 0 & 0 & 0 & 0.01 \end{pmatrix} \\ \begin{pmatrix} 0 & 0 & 1 & 0 \\ 0.33 & 0 & 0.33 & 0.33 \\ 0.33 & 0.33 & 0 & 0.33 \\ 0.5 & 0 & 0.5 & 0 \end{pmatrix} \end{bmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix} .$$

Model GSTAR(3₁) untuk $u_{i,t}$ inflow pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR (3₁) di Kota Surabaya

$$\begin{aligned}
 u_{1,t} = & -0.02 u_{1,(t-1)} - 0.35 u_{2,(t-1)} - 0.35 u_{3,(t-1)} - \\
 & 0.35 u_{4,(t-1)} + -0.27 u_{1,(t-2)} - 0.14 u_{2,(t-2)} - \\
 & 0.14 u_{3,(t-2)} - 0.14 u_{4,(t-2)} + 0.10 u_{1,(t-3)} - \\
 & 0.49 u_{3,(t-3)} + e_{1,t}
 \end{aligned}$$

- Model GSTAR (3₁) di Kota Malang

$$u_{2,t} = 0.03 u_{1,(t-1)} - 0.56 u_{2,(t-1)} + 0.03 u_{3,(t-1)} + 0.03 u_{4,(t-1)} + 0.04 u_{1,(t-2)} - 0.39 u_{2,(t-2)} + 0.04 u_{3,(t-2)} + 0.04 u_{4,(t-2)} + 0.04 u_{1,(t-3)} - 0.14 u_{2,(t-3)} + 0.04 u_{3,(t-3)} + 0.04 u_{4,(t-3)} + e_{2,t}$$

- Model GSTAR (3₁) di Kota Kediri

$$u_{3,t} = -0.003 u_{1,(t-1)} - 0.003 u_{2,(t-1)} - 0.52 u_{3,(t-1)} - 0.003 u_{4,(t-1)} + 0.03 u_{1,(t-2)} + 0.03 u_{2,(t-2)} - 0.51 u_{3,(t-2)} + 0.03 u_{4,(t-2)} + 0.04 u_{1,(t-3)} + 0.04 u_{2,(t-3)} - 0.27 u_{3,(t-3)} + 0.04 u_{4,(t-3)} + e_{3,t}$$

- Model GSTAR (3₁) di Kabupaten Jember

$$u_{4,t} = -0.01 u_{1,(t-1)} - 0.01 u_{2,(t-1)} - 0.01 u_{3,(t-1)} - 0.41 u_{4,(t-1)} + -0.001 u_{1,(t-2)} - 0.001 u_{2,(t-2)} - 0.001 u_{3,(t-2)} - 0.34 u_{4,(t-2)} + 0.007 u_{1,(t-3)} + 0.007 u_{3,(t-3)} - 0.12 u_{4,(t-3)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *inflow* di setiap lokasi dapat diketahui bahwa pengaruh *inflow* di suatu lokasi dipengaruhi oleh *inflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Misal, *inflow* di Kota Surabaya dipengaruhi oleh *inflow* Surabaya, Malang, Kediri dan Jember 1 dan 2 serta 3 bulan sebelumnya di Kota Surabaya dan Malang. Begitu juga *inflow* di Kota Malang, Kediri dan Jember memiliki konsep interpretasi model yang sama dengan Kota Surabaya.

b) Restricted Model pada Data Inflow

Tidak semua parameter pada pemodelan GSTAR dengan bobot normalisasi inferensia korelasi silang parsial signifikan. Pada bagian ini pemodelan GSTAR(3₁) hanya dengan parameter yang signifikan saja sehingga didapatkan model yang *restricted*. Hasil penghitungan dengan estimasi parameter model GSTAR (3₁) adalah sebagai berikut:

Tabel 34 Estimasi Parameter *Restricted Model* dari metode GLS dengan Bobot Normalisasi Inferensia Korelasi Silang Parsial pada $u_{i,t}$ *Inflow*

Lokasi	Variable	DF	Estimasi	SE	Nilai t	P-Value
Surabaya	ϕ_{11}^1	1	1.06	0.47	2.26	0.03
	ϕ_{10}^2	1	-0.23	0.11	-2.10	0.04
Malang	ϕ_{20}^1	1	-0.55	0.10	-5.43	<0.0001
	ϕ_{21}^3	1	0.08	0.04	1.88	0.06
Kediri	ϕ_{30}^1	1	-0.52	0.10	-5.32	<0.0001
	ϕ_{30}^2	1	-0.51	0.09	-5.55	<0.0001
	ϕ_{31}^2	1	0.07	0.07	1.03	0.31
Jember	ϕ_{40}^1	1	-0.42	0.09	-4.55	<0.0001
	ϕ_{40}^2	1	-0.37	0.10	-3.85	0.0002

Berdasarkan parameter-parameter yang signifikan pada Tabel tersebut, maka dapat dibentuk persamaan matriks untuk model *restricted* GSTAR(3₁) dengan menggunakan bobot normalisasi inferensia korelasi silang parsial pada persamaan sebagai berikut:

$$\begin{pmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \\ u_{4,t} \end{pmatrix} = \begin{bmatrix} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & -0.32 & 0 & 0 \\ 0 & 0 & -0.46 & 0 \\ 0 & 0 & 0 & -0.40 \end{pmatrix} + \begin{pmatrix} -0.96 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \\ \begin{pmatrix} 0 & 0.33 & 0.33 & 0.33 \\ 0.33 & 0 & 0.33 & 0.33 \\ 0.33 & 0.33 & 0 & 0.33 \\ 0.33 & 0.33 & 0.33 & 0 \end{pmatrix} \\ \begin{pmatrix} -0.23 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & -0.40 & 0 \\ 0 & 0 & 0 & -0.19 \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0.12 & 0 \\ 0 & 0 & 0 & -0.004 \end{pmatrix} \\ \begin{pmatrix} 0 & 0.33 & 0.33 & 0.33 \\ 0.33 & 0 & 0.33 & 0.33 \\ 0.33 & 0.33 & 0 & 0.33 \\ 0.33 & 0.33 & 0.33 & 0 \end{pmatrix} \\ \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0.06 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \end{bmatrix} \begin{pmatrix} u_{1,(t-1)} \\ u_{2,(t-1)} \\ u_{3,(t-1)} \\ u_{4,(t-1)} \end{pmatrix} + \begin{pmatrix} u_{1,(t-2)} \\ u_{2,(t-2)} \\ u_{3,(t-2)} \\ u_{4,(t-2)} \end{pmatrix} + \begin{pmatrix} u_{1,(t-3)} \\ u_{2,(t-3)} \\ u_{3,(t-3)} \\ u_{4,(t-3)} \end{pmatrix} + \begin{pmatrix} e_{1,t} \\ e_{2,t} \\ e_{3,t} \\ e_{4,t} \end{pmatrix}$$

Model GSTAR(3₁) untuk $u_{i,t}$ inflow pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut.

- Model GSTAR (3₁) di Kota Surabaya

$$u_{1,t} = -0.32 u_{2,(t-1)} - 0.32 u_{3,(t-1)} - 0.32 u_{4,(t-1)} - 0.23 u_{1,(t-2)} + e_{1,t}$$

- Model GSTAR (3₁) di Kota Malang

$$u_{2,t} = -0.32 u_{2,(t-1)} + 0.02 u_{1,(t-3)} + 0.02 u_{3,(t-3)} + 0.02 u_{4,(t-3)} + e_{2,t}$$

- Model GSTAR (3₁) di Kota Kediri

$$u_{3,t} = -0.46 u_{3,(t-1)} + 0.04 u_{1,(t-2)} + 0.04 u_{2,(t-2)} - 0.04 u_{3,(t-2)} + 0.04 u_{4,(t-2)} + e_{3,t}$$

- Model GSTAR (3₁) di Kabupaten Jember

$$u_{4,t} = -0.40 u_{4,(t-1)} - 0.19 u_{4,(t-2)} + e_{4,t}$$

Berdasarkan model yang terbentuk untuk *inflow* di setiap lokasi dapat diketahui bahwa pengaruh *inflow* di suatu lokasi dipengaruhi oleh *inflow* di lokasi tersebut dengan waktu yang berbeda. Ada juga suatu lokasi yang dipengaruhi di lokasi yang berbeda dan di waktu yang berbeda. Misal, *inflow* di Kota Surabaya dipengaruhi oleh *inflow* Surabaya sendiri di 2 bulan sebelumnya serta pada tiga lokasi lainnya di 1 bulan sebelumnya. Begitu juga *inflow* di Kota Malang, Kediri dan Jember memiliki konsep interpretasi model yang sama dengan Kota Surabaya.

c) Data *Outflow*

Tahapan penerapan bobot normalisasi inferensia korelasi silang parsial pada data *outflow* dengan pemodelan GSTAR([1,3]₁) sama dengan yang dilakukan pada data *inflow*. Korelasi silang yang digunakan yang terdapat di lag 1 dan 3. Hasil perhitungan inferensia parsial korelasi silang antar lokasi pada lag 1, $r_{ij}(1)$, dapat dilihat pada Tabel berikut.

Tabel 35 Taksiran Normalisasi Korelasi Silang antar Lokasi $u_{i,t}$ Outflow dengan Selang Kepercayaan 95% untuk Lag 1

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$P_1(12)$	-0.371	-0.543	-0.199	tidak valid
$P_1(13)$	-0.314	-0.486	-0.141	tidak valid
$P_1(14)$	-0.317	-0.490	-0.145	tidak valid
$P_1(21)$	-0.417	-0.589	-0.245	tidak valid
$P_1(23)$	-0.301	-0.473	-0.129	tidak valid
$P_1(24)$	-0.273	-0.445	-0.101	tidak valid

Tabel 36 Taksiran Normalisasi Korelasi Silang antar Lokasi $u_{i,t}$ Outflow dengan Selang Kepercayaan 95% untuk Lag 1 (Lanjutan)

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$P_1(31)$	-0.502	-0.674	-0.329	tidak valid
$P_1(32)$	-0.443	-0.615	-0.270	tidak valid
$P_1(34)$	-0.407	-0.579	-0.235	tidak valid
$P_1(41)$	-0.387	-0.559	-0.215	tidak valid
$P_1(42)$	-0.387	-0.559	-0.215	tidak valid
$P_1(43)$	-0.305	-0.477	-0.133	tidak valid

Berdasarkan Tabel tersebut dapat diketahui bahwa nilai parsial korelasi silang antar lokasi tidak ada yang valid, sehingga bobot yang digunakan adalah bobot seragam untuk di lag 1. Sedangkan hasil perhitungan inferensia parsial korelasi silang antar lokasi pada lag 3, $r_{ij}(3)$, dapat dilihat pada Tabel berikut.

Tabel 37 Taksiran Normalisasi Korelasi Silang antar Lokasi $u_{i,t}$ Outflow dengan Selang Kepercayaan 95% untuk Lag 3

Parameter	Nilai Taksiran	Batas Bawah	Batas Atas	Keterangan
$P_6(12)$	-0.035	-0.207	0.138	tidak valid
$P_6(13)$	-0.111	-0.283	0.061	tidak valid
$P_6(14)$	-0.107	-0.279	0.065	tidak valid
$P_6(21)$	-0.148	-0.320	0.024	tidak valid
$P_6(23)$	-0.074	-0.246	0.098	tidak valid
$P_6(24)$	-0.064	-0.236	0.108	tidak valid
$P_6(31)$	-0.081	-0.253	0.092	tidak valid
$P_6(32)$	0.027	-0.145	0.199	tidak valid
$P_6(34)$	0.014	-0.158	0.186	tidak valid
$P_6(41)$	-0.053	-0.225	0.119	tidak valid
$P_6(42)$	0.056	-0.116	0.229	tidak valid
$P_6(43)$	-0.048	-0.221	0.124	tidak valid

Berdasarkan Tabel tersebut dapat diketahui bahwa nilai parsial korelasi silang antar lokasi tidak ada yang valid, sehingga bobot yang digunakan adalah bobot seragam untuk di lag 3.

BAGIAN 8
PERAMALAN DATA *INFLOW* DAN *OUTFLOW*
GSTARX

A. Peramalan Data *Inflow* dan *Outflow*

Hasil ramalan data in-sample dan out-sample didapatkan dari persamaan berikut.

$$\hat{z}_{i,t} = \hat{y}_{i,t} + \hat{u}_{i,t}$$

dengan:

$\hat{z}_{i,t}$ adalah hasil ramalan ke- t di lokasi ke- i dari model GSTARX dengan dua level,

$\hat{y}_{i,t}$ adalah hasil ramalan ke- t di lokasi ke- i di level 1,

$\hat{u}_{i,t}$ adalah ramalan ke- t di lokasi ke- i di level 2.

Setelah melakukan perhitungan hasil ramalan dilakukan perhitungan kebaikan peramalan data *in sample*. Kebaikan peramalan data *in-sample* didasarkan pada nilai RMSE terkecil untuk pemodelan dengan ARIMA, Variasi Kalender dan GSTARX-GLS dua level pada data *inflow* sebagai berikut.

Tabel 38 Nilai RMSE Data *In-Sample* Model ARIMA, Variasi Kalender dan GSTARX-GLS pada Data *Inflow*

Model	Bobot	Kota/Kabupaten				RMSE
		Surabaya	Malang	Kediri	Jember	Total
ARIMA	-	779.76	282.22	300.20	209.41	392.90
Variasi Kalender	-	*432.45	*157.36	*144.05	*93.42	*206.82
GSTARX-GLS dengan Dua Level (Full)	Seragam	607.33	205.00	208.89	147.20	292.11
	Invers Jarak	*602.22	*204.91	210.02	147.24	*291.10
	Normalisasi Korelasi Silang	606.97	205.85	207.79	147.20	291.95
	Normalisasi Inferensia	607.41	205.00	208.89	147.13	292.11

	Korelasi Silang Parsial					
GSTARX-GLS dengan Dua Level (Restricted)	Seragam	623.00	216.91	208.49	145.11	298.38
	Invers Jarak	623.20	216.91	208.54	145.56	298.55
	Normalisasi Korelasi Silang	615.94	216.91	*206.51	145.56	296.23
	Normalisasi Inferensia Korelasi Silang Parsial	614.33	224.44	209.30	*145.11	298.29

Tabel 39 Nilai RMSE Data *In-Sample* Model ARIMA, Variasi Kalender dan GSTARX-GLS pada Data *Outflow*

Model	Bobot	Kota/Kabupaten				RMSE Total
		Surabaya	Malang	Kediri	Jember	
ARIMA	-	651.57	172.18	240.41	143.84	302.00
Variasi Kalender	-	*466.69	*137.12	*190.40	*97.61	*222.96
GSTARX-GLS dengan Dua Level (Full)	Seragam	711.20	196.69	295.15	145.72	403.99
	Invers Jarak	713.37	196.92	295.58	145.48	405.03
	Normalisasi Korelasi Silang	*710.65	*196.31	*294.12	*145.25	*336.58
GSTARX-GLS dengan Dua Level (Restricted)	Seragam	717.05	198.19	306.96	145.82	408.94
	Invers Jarak	717.67	198.25	306.96	145.82	409.22
	Normalisasi Korelasi Silang	715.56	198.05	306.96	145.82	341.59

RMSE terkecil dari model univariat data *inflow* untuk tiap lokasi berdasarkan Tabel tersebut adalah Variasi Kalender, begitu juga nilai terkecil pada RMSE total terdapat di model ini. Nilai RMSE total terkecil pada pemodelan GSTARX-GLS dengan dua level terdapat pada *full model* dengan bobot

invers jarak dengan rincian model ini terbaik dalam memodelkan data *inflow* Kota Surabaya dan Kota Malang. Pada Kota Kediri dan Kabupaten Jember masing-masing dimodelkan dengan baik oleh GSTARX-GLS *restricted model* dengan bobot normalisasi korelasi silang dan normalisasi inferensia korelasi silang parsial. Berikut nilai RMSE data *in-sample* pada tiap model untuk data *outflow*.

RMSE terkecil dari model univariat data *outflow* untuk tiap lokasi berdasarkan Tabel tersebut adalah Variasi Kalender, begitu juga nilai terkecil pada RMSE total terdapat di model ini. Nilai RMSE total terkecil pada pemodelan GSTARX-GLS dengan dua level terdapat pada *full model* dengan bobot normalisasi korelasi silang dengan rincian model ini terbaik dalam memodelkan data *outflow* untuk empat kota di Jawa Timur. Hasil perbandingan data *out-sample* didasarkan pada nilai RMSE terkecil dengan pemodelan ARIMA, Variasi Kalender dan GSTARX-GLS dua level pada data *inflow* sebagai berikut.

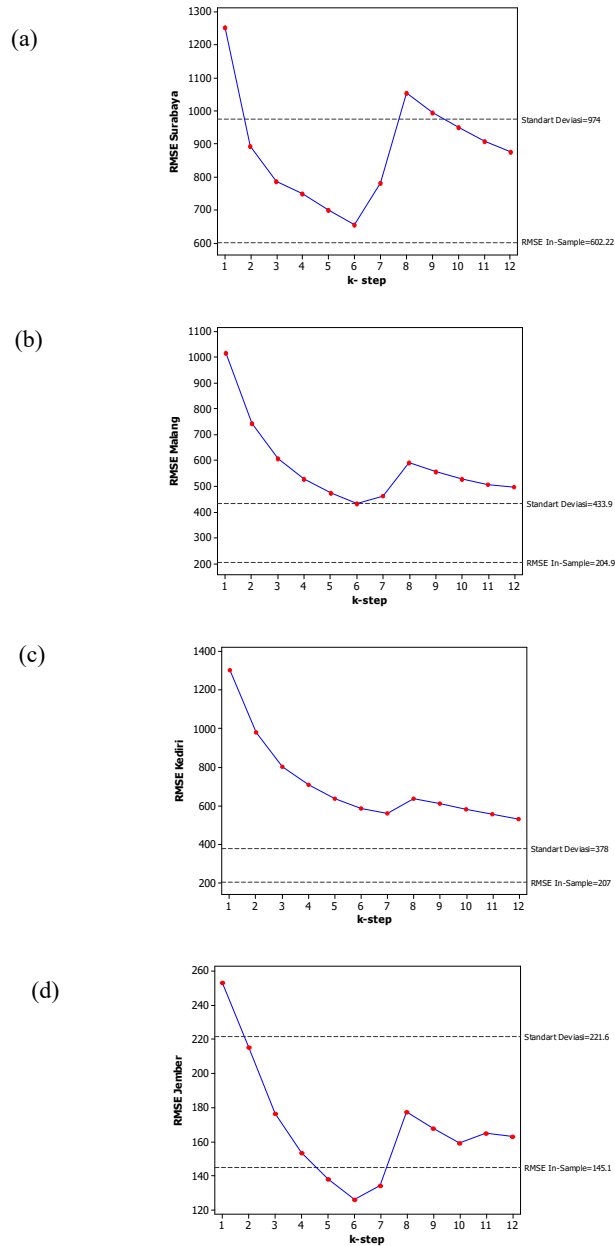
Tabel 40 Nilai RMSE Data *Out-Sample* Model ARIMA, Variasi Kalender dan GSTARX-GLS pada Data *Inflow*

Model	Bobot	Kota/Kabupaten				RMSE Total
		Surabaya	Malang	Kediri	Jember	
ARIMA	-	1400.67	*289.97	*226.85	370.07	*571.89
Variasi Kalender	-	*1126.07	520.38	600.12	*238.74	621.33
GSTARX-GLS dengan Dua Level (<i>Full</i>)	Seragam	*875.34	497.47	533.89	163.20	517.48
	Invers Jarak	877.87	497.48	538.44	163.62	519.35
	Normalisasi Korelasi Silang	875.52	*497.19	*532.66	*163.10	*517.12
	Normalisasi Inferensia Korelasi Silang Parsial	868.06	499.52	536.82	165.42	517.46

GSTARX- GLS dengan Dua Level (Restricted)	Seragam	889.31	507.90	543.40	165.24	526.46
	Invers Jarak	937.13	526.94	553.36	175.03	548.12
	Normalisasi Korelasi Silang	879.42	508.08	535.48	165.29	522.07
	Normalisasi Inferensia Korelasi Silang Parsial	876.54	497.69	536.37	165.29	518.97

Dari Tabel tersebut dapat dilihat bahwa RMSE total terkecil pada model univariat data *inflow* untuk Kota Malang dan Kediri adalah ARIMA, begitu juga nilai terkecil pada RMSE total terdapat di model ini. Pemodelan *inflow* di Kota Surabaya dan Jember pada pemodelan univariat terdapat pada model variasi kalender. Nilai RMSE total terkecil pada pemodelan GSTARX-GLS dengan dua level terdapat pada *full model* dengan bobot normalisasi korelasi silang dimana Kota Malang, Kediri dan Kabupaten Jember termasuk di dalamnya. Sedangkan Kota Surabaya dimodelkan dengan baik pada *full model* dengan bobot seragam.

Untuk melihat sampai ke *k*-step ke berapa model ini bisa memprediksi dengan baik data *inflow* di tiap lokasi dapat dilihat pada Gambar berikut.



Gambar 12 Nilai RMSE *Out-Sample k-Step Inflow* di Jawa Timur

Jika RMSE *k-step* berada di bawah standart deviasi maka ramalan *out-sample* untuk *k-step* cukup baik. Namun jika

ini berada di atas standart deviasi, berarti model tidak begitu baik dalam meramalkan data *out-sample* untuk *k-step*. Secara umum, pada Gambar tersebut dapat dilihat bahwa ramalan *out-sample* untuk pemodelan GSTARX-GLS terbaik pada data *inflow* Kota Surabaya dan Kabupaten Jember sudah cukup baik. Sedangkan ramalan *out-sample inflow* Kota Malang dan Kediri tidak begitu bagus menggunakan model ini. Grafik pada Gambar (a), (b), (c) dan (d) memiliki pola yang sama dan pada step ke-1 dan 8 masih belum bisa diramal dengan baik oleh model ini. Pada step ke-1 terjadi seperti demikian mengindikasikan adanya pola musiman yang terjadi pada bulan Januari yang masih belum dimodelkan dengan baik di level 1 maupun di level 2. Sedangkan pada step ke-8 terjadi demikian dikarenakan adanya efek lebaran yang terjadi di bulan Agustus yang diluar prediksi didasarkan pada pemodelan data *in-sample*. Sehingga untuk *k-step* selanjutnya mengalami kenaikan RMSE yang berdampak pada kurang baiknya ramalan dengan model GSTARX-GLS terbaik ini.

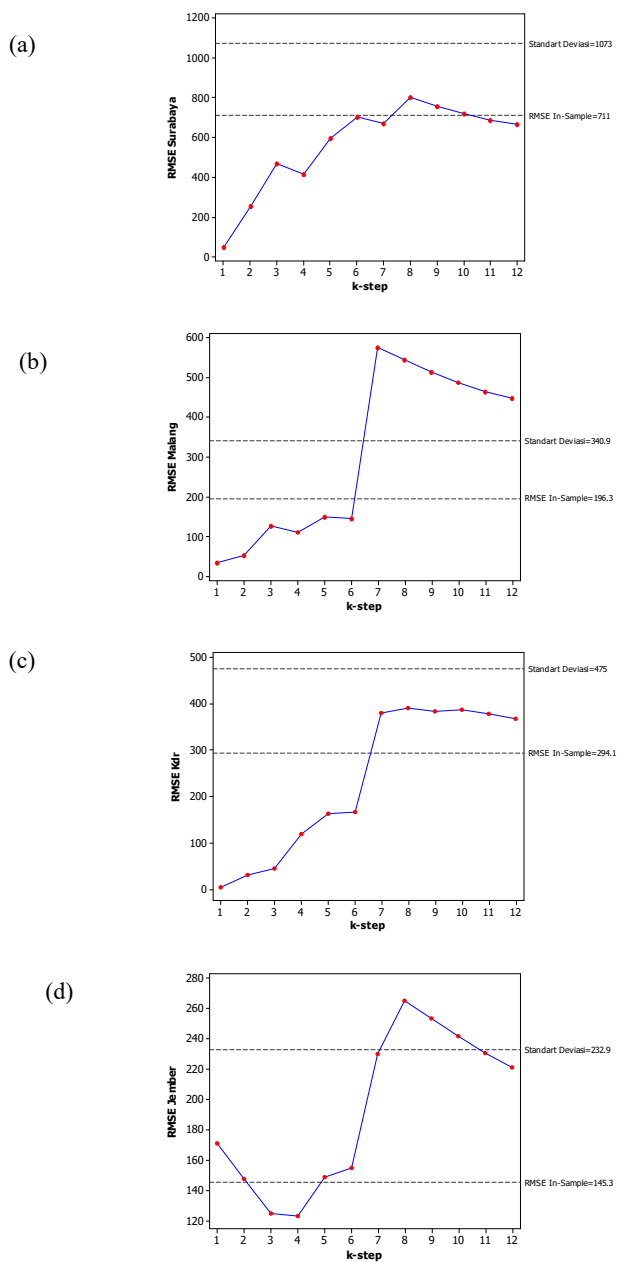
RMSE *in-sample* pada Gambar 4.53 merupakan RMSE total *in-sample* dari model terbaik GSTARX-GLS. Nilai ini menjelaskan bahwa peramalan data *inflow keempat* Kota/Kabupaten di Jawa Timur sudah cukup baik dengan menggunakan model GSTARX-GLS. Hal ini bisa dilihat bahwa nilai ini lebih kecil dibandingkan dengan standart deviasi. Sedangkan untuk nilai RMSE data *out-sample* pada tiap model untuk data *outflow* ditampilkan pada tabel berikut.

Tabel 41 Nilai RMSE Data *Out-Sample* Model ARIMA, Variasi Kalender dan GSTARX-GLS pada Data *Outflow*

Model	Bobot	Kota/Kabupaten				RMSE Total
		Surabaya	Malang	Kediri	Jember	
ARIMA	-	988.83	543.81	*314.51	*296.81	535.99
Variasi Kalender	-	*688.53	*469.08	463.39	308.51	*482.38
GSTARX-GLS dengan Dua Level (Full)	Seragam	674.42	*448.09	*367.61	224.57	*428.67
	Invers Jarak	689.37	450.75	369.44	224.23	433.45
	Normalisasi Korelasi Silang	*663.85	459.07	373.68	*220.92	429.38
GSTARX-GLS dengan Dua Level (Restricted)	Seragam	682.07	448.88	367.62	224.39	430.74
	Invers Jarak	681.39	448.15	367.62	224.39	430.39
	Normalisasi Korelasi Silang	683.17	449.02	368.00	224.39	431.15

Dari Tabel tersebut dapat dilihat bahwa RMSE terkecil pada model univariat data *outflow* untuk Kota Surabaya dan Malang adalah Variasi Kalender, begitu juga nilai terkecil pada RMSE total terdapat di model ini. Pemodelan *outflow* di Kota Kediri dan Jember pada pemodelan univariat terdapat pada model ARIMA. Nilai RMSE total terkecil pada pemodelan GSTARX-GLS dengan dua level terdapat pada *full model* dengan bobot seragam dimana Kota Malang dan Kediri termasuk di dalamnya. Sedangkan Kota Surabaya dan Kabupaten Jember dimodelkan dengan baik pada *full model* dengan bobot normalisasi korelasi silang.

Untuk melihat sampai ke *k*-step ke berapa model ini bisa memprediksi dengan baik data *outflow* di tiap lokasi dapat dilihat pada Gambar berikut.



Gambar 13 Nilai RMSE *Out-Sample k-Step Outflow* di Jawa Timur

Secara umum sama halnya dengan pada kasus data *inflow*, Gambar tersebut dapat menampilkan bahwa ramalan *out-sample* untuk pemodelan GSTARX-GLS terbaik pada data *outflow* Kota Surabaya sudah cukup baik. Hal ini bisa dilihat pada Gambar (a) dimana nilai *k-step* sudah dibawah standart deviasi. Sedangkan ramalan *out-sample outflow* Kota Malang, Kediri dan Kabupaten Jember tidak begitu bagus menggunakan model ini. Grafik pada Gambar (b), (c) dan (d) memiliki pola yang hampir sama dimana mulai pada step ke-7 nilai RMSE mengalami kenaikan. Hal ini dikarenakan adanya efek lebaran yang terjadi di bulan Agustus yang diluar prediksi didasarkan pada pemodelan data *in-sample*. Sehingga untuk *k-step* selanjutnya mengalami kenaikan RMSE yang berdampak pada kurang baiknya ramalan dengan model GSTARX-GLS terbaik ini.

RMSE *in-sample* pada Gambar tersebut menjelaskan bahwa peramalan data *outflow keempat* Kota/Kabupaten di Jawa Timur sudah cukup baik dengan menggunakan model GSTARX-GLS. Hal ini bisa dilihat bahwa nilai ini lebih kecil dibandingkan dengan standart deviasi.

B. Pengujian Asumsi Residual White Noise Model GSTARX Dua Level

Pengujian asumsi *residual white noise* dilakukan untuk memenuhi asumsi model GSTARX-GLS dengan dua level. Pengujian tersebut dilakukan dengan cara memodelkan ulang *residual* dari model GSTAR pada level dua dan melakukan pengecekan letak nilai AIC terkecil. Asumsi *residual white noise* terpenuhi jika nilai AIC terkecil terletak pada lag AR(0) dan MA(0). Tabel berikut menunjukkan nilai AIC *residual* model GSTARX-GLS untuk data *inflow*.

Tabel 42 Nilai AIC Residual Model GSTARX-GLS di Level Dua pada Data *Inflow*

Model	Bobot	Lag	MA (0)	MA (1)	MA (2)	MA (3)	MA (4)	
GSTAR X-GLS (<i>full</i>)	Seragam	AR (0)	*40. 18	40.4 5	40.6 1	40.7 5	40.8 9	
		AR (1)	40.3 3	40.6 0	40.7 6	40.8 7	41.0 1	
	Invers Jarak	AR (0)	*40. 18	40.4 6	40.6 2	40.7 6	40.8 9	
		AR (1)	40.3 4	40.6 2	40.7 7	40.8 8	41.0 1	
	Normali sasi Korelasi Silang	AR (0)	*40. 14	40.4 3	40.6 0	40.7 4	40.8 7	
		AR (1)	40.3 0	40.5 8	40.7 4	40.8 7	41.0 1	
	Normali sasi Inferens ia Korelasi Silang Parsial	AR (0)	*40. 16	40.4 5	40.6 2	40.7 5	40.8 9	
		AR (1)	40.3 2	40.6 1	40.7 9	40.8 7	41.0 0	
	GSTAR X-GLS (<i>restric ted</i>)	Seragam	AR (0)	*40. 34	40.5 8	40.7 7	40.8 7	40.9 9
			AR (1)	40.4 5	40.7 1	40.8 9	41.0 0	41.1 3
Invers Jarak		AR (0)	*40. 25	40.5 0	40.6 9	40.8 2	40.9 4	
		AR (1)	40.3 9	40.6 7	40.8 5	40.9 5	41.0 9	
Normali sasi		AR (0)	*40. 21	40.5 0	40.6 8	40.8 1	40.9 2	

	Korelasi Silang	AR (1)	40.3 8	40.6 4	40.8 4	40.9 7	41.0 5
	Normalisasi	AR (0)	*40.42	40.7 0	40.8 0	40.8 8	41.0 2
		Inferensia	AR (1)	40.5 9	40.8 0	40.9 1	40.9 7
	Korelasi Silang Parsial						

Berdasarkan Tabel tersebut dapat diketahui bahwa nilai AIC terkecil pada *full* dan *restricted* model GSTARX-GLS untuk keempat macam bobot terletak pada lag AR(0) dan MA(0). Hal ini berarti asumsi residual *white noise* telah terpenuhi. Tabel berikut menunjukkan nilai AIC *residual* model GSTARX-GLS untuk data *outflow*.

Tabel 43 Nilai AIC Residual Model GSTARX-GLS di Level Dua pada Data *Outflow*

Model	Bobot	Lag	MA (0)	MA (1)	MA (2)	MA (3)	MA (4)
GSTARX-GLS (<i>full</i>)	Seragam	AR (0)	*39.16	39.71	39.88	40.10	40.18
		AR (1)	39.23	39.75	39.92	40.14	40.19
	Invers Jarak	AR (0)	*41.15	41.38	41.35	41.51	41.57
		AR (1)	41.26	41.46	41.46	41.56	41.52
	Normalisasi Korelasi Silang	AR (0)	*41.13	41.35	41.33	41.48	41.55
		AR (1)	41.24	41.44	41.45	41.55	41.52
GSTARX-GLS (<i>restricted</i>)	Seragam	AR (0)	*41.20	41.43	41.40	41.55	41.60
		AR (1)	41.31	41.49	41.46	41.60	41.52
	Invers Jarak	AR (0)	*41.21	41.44	41.40	41.56	41.61
		AR (1)	41.32	41.50	41.46	41.60	41.52
	Normalisasi Korelasi Silang	AR (0)	*41.19	41.42	41.38	41.55	41.60
		AR (1)	41.30	41.49	41.47	41.60	41.51

Berdasarkan Tabel tersebut dapat diketahui bahwa nilai AIC terkecil pada *full* dan *restricted* model GSTARX-GLS untuk keempat macam bobot terletak pada lag AR(0) dan MA(0). Hal ini berarti asumsi residual *white noise* telah terpenuhi.

DAFTAR PUSTAKA

- Amalia, Farah Fajrina, Suhartono, Santi Puteri Rahayu, and Novri Suhermi. "Quantile Regression Neural Network for Forecasting Inflow and Outflow in Yogyakarta." *Journal of Physics: Conference Series* 1028 (June 2018): 012232. <https://doi.org/10.1088/1742-6596/1028/1/012232>.
- Apriliadara, Meriska, Suhartono, and Dedy Dwi Prastyo. "VARI-X Model for Currency Inflow and Outflow Forecasting with Eid Fitr Effect in Indonesia." *AIP Conference Proceedings* 1746, no. 1 (June 17, 2016): 020041. <https://doi.org/10.1063/1.4953966>.
- Armstrong, Jon Scott. *Principles of Forecasting: A Handbook for Researchers and Practitioners*. Vol. 30. Springer Science & Business Media, 2001.
- Astuti, Dewi, and Budi Nurani Ruchjana. "Generalized Space Time Autoregressive with Exogenous Variable Model and Its Application." In *Journal of Physics: Conference Series*, 893:012038. IOP Publishing, 2017.
- Borovkova, Svetlana, Hendrik P. Lopuhaä, and Budi Nurani Ruchjana. "Consistency and Asymptotic Normality of Least Squares Estimators in Generalized STAR Models." *Statistica Neerlandica* 62, no. 4 (2008): 482–508.
- Bowerman, Bruce L., and Richard T. O'Connell. "Forecasting and Time Series: An Applied Approach. 3rd," 1993.
- Box, George EP, Gwilym M. Jenkins, Gregory C. Reinsel, and Greta M. Ljung. *Time Series Analysis: Forecasting and Control*. John Wiley & Sons, 2015.
- Chen, Chung, and Lon-Mu Liu. "Forecasting Time Series with Outliers." *Journal of Forecasting* 12, no. 1 (1993): 13–35.
- Hurvich, Clifford M., and Chih-Ling Tsai. "Regression and Time Series Model Selection in Small Samples." *Biometrika* 76, no. 2 (1989): 297–307.

- Lee, M., and N. Hamzah. "Calendar Variation Model Based on ARIMAX for Forecasting Sales Data with Ramadhan Effect." In *Proceedings of the Regional Conference on Statistical Sciences*, 349–61, 2010.
- Manager Divisi Assesmen Ekonomi dan Keuangan. "Kajian Ekonomi Regional Jawa Timur Triwulan I – 2014. Kantor Perwakilan Bank Indonesia Wilayah IV." Kantor Perwakilan Bank Indonesia Wilayah IV, 2014.
- Pusat Riset dan Edukasi Bank Sentral (PRES). "Kodifikasi Peraturan Bank Indonesia Sistem Pembayaran Tunai Pengelolaan Uang Rupiah." Bank Indonesia, 2013.
- Ruchjana, Budi Nurani. "Pemodelan Kurva Produksi Minyak Bumi Menggunakan Model Generalisasi STAR." In *Forum Statistika Dan Komputasi*, 01–06, 2002.
- Suhartono, Novi Ajeng Salehah, Dedy Dwi Prastyo, and Santi Puteri Rahayu. "Hybrid ARIMAX Quantile Regression Model for Forecasting Inflow and Outflow of East Java Province." *Journal of Physics: Conference Series* 1028, no. 1 (June 2018): 012228. <https://doi.org/10.1088/1742-6596/1028/1/012228>.
- Suhartono, Suhartono. "A Comparative Study of Forecasting Models for Trend and Seasonal Time Series Does Complex Model Always Yield Better Forecast than Simple Models." *Jurnal Teknik Industri* 7, no. 1 (2005): 22–30.
- Suhartono, Suhartono, Muhammad Munawir Gazali, and Dedy Dwi Prastyo. "VARX and GSTARX Models for Forecasting Currency Inflow and Outflow with Multiple Calendar Variations Effect." *MATEMATIKA: Malaysian Journal of Industrial and Applied Mathematics* 34, no. 3 (2018): 57–72.
- Susanti, Ana, Hario Jati Setyadi, Medi Taruk, and Putut Pamilih Widagdo. "Forecasting Inflow and Outflow of Money

Currency in East Java Using a Hybrid Exponential Smoothing and Calendar Variation Model.” In *Journal of Physics: Conference Series*, 979:012096. IOP Publishing, 2018.

Tim Informasi Hukum. *Surat Edaran Bank Indonesia Nomor 13/9/DPU Tanggal 5 April 2011 Perihal Penyetoran Dan Penarikan Uang Rupiah Oleh Bank Umum Di Bank Indonesia*. Direktorat Hukum, 2011.

Wei, William WS. “Time Series Analysis.” In *The Oxford Handbook of Quantitative Methods in Psychology: Vol. 2*, 2006.

Wutsqa, D. U., Sutijo B. Suhartono, and B. Sutijo. “Generalized Space-Time Autoregressive Modeling.” In *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and Its Applications (ICMSA2010)*, 2010.

Zellner, Arnold. “An Efficient Method of Estimating Seemingly Unrelated Regressions and Tests for Aggregation Bias.” *Journal of the American Statistical Association* 57, no. 298 (1962): 348–68.