

Pemodelan *Generalized Space Time Autoregressive (GSTAR)* Pada Data Inflasi di Kota Samarinda dan Kota Balikpapan

Modeling Generalized Space Time Autoregressive (GSTAR) On Inflation Data In Samarinda And Balikpapan

Riska Handayani¹, Sri Wahyuningsih², dan Desi Yuniarti³

^{1,2}Laboratorium Statistika Terapan Jurusan Matematika FMIPA Universitas Mulawarman

³Laboratorium Statistika Ekonomi dan Bisnis Jurusan Matematika FMIPA Universitas Mulawarman

E-mail: riskahandayani100595@gmail.com

Abstract

One of the macroeconomic indicators used in the preparation of government's economic policy is inflation. Inflation is a data time series monthly that also is influenced by location effects. Generalized Space Time Autoregressive (GSTAR) is a time series method that combines time and location effects. The case study is applied of GSTAR for forecasting inflation in two cities in East Kalimantan namely Samarinda and Balikpapan. This research aims to implement GSTAR model to gain forecasting model for inflation data in Samarinda city and Balikpapan city by using method of cross-correlation normalization. The resulting model is GSTAR model $GSTAR(2,1)$ and $GSTAR(3,1)$. The model obtained is not feasible to be used for forecasting, because it does not meet the white noise assumption.

Keywords: GSTAR, inflation, cross-correlation normalization, space time, time series

Pendahuluan

Menurut Sudarso (1991), salah satu indikator ekonomi makro yang digunakan untuk melihat/mengukur stabilitas (keseimbangan) perekonomian suatu negara adalah inflasi. Inflasi adalah suatu proses atau peristiwa kenaikan tingkat harga umum. Menurut Sukirno (2000), akibat buruk yang paling nyata dari inflasi adalah kemerosotan pendapatan riil yang diterima masyarakat. Selain itu dapat menimbulkan ketidakstabilan, pertumbuhan yang lambat, dan pengangguran yang semakin meningkat, serta mengurangi daya beli masyarakat.

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

mempengaruhi ketersediaan barang dan jasa pada wilayah lain yang tidak dapat memproduksi barang dan jasa sendiri sehingga berdampak pada biaya dan harga antar wilayah.

Perkembangan inflasi di Kalimantan Timur dipantau melalui perkembangan perekonomian di dua kota diantaranya, Kota Samarinda dan Kota Balikpapan. Pemodelan data yang melibatkan ruang dan waktu adalah *Space Time Autoregressive (STAR)* yang diperkenalkan oleh Pfeifer dan Deutsch (1980). Model STAR merupakan model yang menekankan efek waktu yang diamati pada beberapa lokasi. Namun, model STAR memiliki kelemahan yaitu model ini mengasumsikan parameter ruang waktu bernilai sama pada semua lokasi. Kelemahan dari model STAR telah direvisi dan dikembangkan oleh Ruchjana (2002) yang dikenal dengan model *Generalized Space Time Autoregressive (GSTAR)*. Model GSTAR mengasumsikan parameter ruang waktu bernilai berbeda untuk setiap lokasi.

Penelitian terdahulu yang menjadi acuan dalam penelitian ini, diantaranya yaitu penelitian Talungke, Nainggolan dan Hatidja (2015) yang menganalisis model GSTAR data inflasi di tiga lokasi dan didapatkan hasil bahwa model GSTAR yang diperoleh cukup baik untuk meramalkan data inflasi di tiga kota tersebut. Penelitian Gama (2017) yang membandingkan model STAR dan GSTAR untuk peramalan inflasi Dumai, Pekanbaru, dan Batam dan didapatkan model STAR (1,1) dan GSTAR (1,1) yang mana hasil perhitungan MAE dan RMSE menunjukkan bahwa peramalan inflasi Kota Dumai dan Pekanbaru lebih baik menggunakan GSTAR

bobot normalisasi korelasi silang sedangkan peramalan inflasi Kota Batam lebih baik menggunakan STAR bobot normalisasi korelasi silang dan penelitian Wutsqa, Suhartono dan Sutijo (2012) yang mengaplikasikan model GSTAR untuk mendapatkan model peramalan data pencemaran udara di Kota Surabaya dan model yang dihasilkan merupakan model GSTAR dengan orde autoregresif 3 dan orde spasial 1 dengan orde pembedaan 1. Model yang diperoleh menunjukkan adanya kecenderungan hubungan antar waktu dan hubungan spasial antara stasiun 1 dan stasiun 3.

Penelitian ini dibatasi pada data inflasi bulanan di dua lokasi yaitu Kota Samarinda dan Kota Balikpapan pada periode bulan Januari 2012 – Mei 2017. Pemodelan yang digunakan yaitu *Generalized Space Time Autoregressive* dengan pembobot normalisasi korelasi silang. Adapun tujuan dari penelitian ini yaitu untuk mengetahui model model GSTAR dengan bobot normalisasi korelasi silang pada data inflasi bulanan di Kota Samarinda dan Kota Balikpapan pada periode bulan Januari 2012 sampai dengan bulan Mei 2017 serta mengetahui apakah model GSTAR yang diperoleh memenuhi syarat kelayakan sebagai model peramalan

Model Generalized Space Time Autoregressive (GSTAR)

Model *generalized space time autoregressive* (GSTAR) merupakan pengembangan dari model STAR. Perbedaan mendasar antara keduanya adalah pengasumsian parameternya. Pada STAR parameternya tidak bergantung pada lokasi, sehingga model STAR hanya sesuai untuk lokasi-lokasi yang homogen. Sedangkan pada model GSTAR, parameter model berubah-ubah untuk setiap lokasi. Model GSTAR orde p dirumuskan sebagai berikut :

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

di mana :

k = lag waktu (1,2,...,p)

Φ_{k0} = diag $(\phi_{k0}^1, \dots, \phi_{k0}^n)$ yaitu, matriks diagonal parameter *autoregressive* pada lag waktu ke- k dan lag spasial ke-0

Φ_{k1} = diag $(\phi_{k1}^1, \dots, \phi_{k1}^n)$ yaitu, matriks diagonal parameter *autoregressive* pada lag waktu ke- k dan lag spasial ke-1

$\mathbf{e}(t)$ = vektor sisaan berukuran $(n \times 1)$ pada waktu ke- t

$\mathbf{Z}(t)$ = vektor data deret waktu ukuran $(n \times 1)$ pada waktu ke- t

\mathbf{W} = matriks bobot ukuran $(n \times n)$ pada lag spasial l

(Suhartono dan Subanar, 2006)

Autocorrelation Function

Fungsi autokorelasi adalah korelasi antara nilai-nilai suatu deret waktu yang sama dengan selesai waktu (*time lag*) 0,1,2 periode atau lebih ACF digunakan untuk mengidentifikasi model MA. Persamaan fungsi autokorelasi dapat dirumuskan sebagai berikut :

$$r(k) = \frac{\sum_{t=1}^n (Z(t) - \bar{Z})(Z(t-k) - \bar{Z})}{\sum_{t=1}^n (Z(t) - \bar{Z})^2} \quad (2)$$

dengan :

$r(k)$ = nilai dari fungsi autokorelasi (ACF) pada lag waktu ke- k

$Z(t)$ = nilai deret waktu ke- t

\bar{Z} = rata-rata data pengamatan

Partial Autocorrelation Function

Fungsi autokorelasi parsial digunakan untuk mengukur derajat asosiasi antara nilai deret waktu ke- t ($Z(t)$) dengan nilai deret waktu pada k waktu sebelum t ($Z(t)$), ketika efek dari rentang atau jangka waktu (*time lag*) dihilangkan. PACF digunakan untuk mengidentifikasi model AR. Persamaan fungsi parsial autokorelasi dapat dirumuskan sebagai berikut:

$$r(k) = \phi_1 r(k - 1) + \phi_2 r(k - 2) + \dots + \phi_p r(k - p) \quad (3)$$

dengan :

$r(k)$ = nilai dari fungsi autokorelasi (ACF) pada lag waktu ke- k

p = ordo *autoregressive*

ϕ_p = nilai dari fungsi autokorelasi parsial (PACF) pada Ar ordo ke- p

Kestasioneran Data

Dalam analisis deret waktu, pembentukan model analisis deret waktu ditentukan dengan asumsi bahwa data dalam keadaan stasioner. Stasioneritas berarti bahwa tidak terdapat perubahan yang drastis pada data. Fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan variansi dari fluktuasi tersebut. Makridakis menyatakan bentuk visual dari suatu plot data *time series* seringkali cukup untuk meyakinkan bahwa data tersebut adalah stasioner atau tidak stasioner. Akan tetapi, secara formal untuk mengidentifikasi kestasioneran data dilakukan dengan uji *Augmented Dickey Fuller* (ADF) jika data belum stasioner terhadap *mean* perlu dilakukan *differencing* atau pembedaan. Sebaliknya, jika data belum stasioner pada varian jika nilai atas dan bawah pada lambda kurang dari nol, sehingga perlu dilakukan transformasi *Box Cox* agar data stasioner (Makridakis, 1999).

Uji Augmented Dickey Fuller

Uji *Augmented Dickey Fuller* (ADF) merupakan pengujian stasioner dengan menentukan apakah data deret waktu (*time series*)

mengandung akar unit (*unit root*). Rumusan hipotesis untuk uji akar unit ADF adalah :

$$H_0 : \gamma = 0 \text{ (tidak stasioner)}$$

$$H_1 : \gamma \neq 0 \text{ (stasioner)}$$

Prosedur untuk menentukan apakah data stasioner atau tidak dengan cara membandingkan antara nilai statistik uji t yang disimbolkan dengan τ yaitu :

$$\tau = \left| \frac{\hat{\gamma}}{SE(\hat{\gamma})} \right| \tag{4}$$

di mana $\hat{\gamma}$ adalah nilai taksiran dari parameter, $SE(\hat{\gamma})$ merupakan standar *error* dari nilai taksiran $\hat{\gamma}$, dengan daerah kritis pengujian ini adalah menolak H_0 apabila nilai statistik ADF atau τ lebih besar dari pada absolut nilai kritis distribusi statistik t yaitu $\left| t_{\left(\frac{\alpha}{2}, df=n-n_p\right)} \right|$, di mana n adalah banyak pengamatan dan n_p adalah jumlah parameter (Gujarati, 2003).

Transformasi Box Cox

Transformasi *Box Cox* adalah transformasi pangkat pada respon. *Box Cox* mempertimbangkan kelas transformasi berparameter tunggal yaitu λ yang dipangkatkan pada variabel respon Z_t , sehingga transformasinya menjadi Z_t^λ . λ adalah parameter yang perlu diduga.

Cryer dan Kung-Sik (2008), mendefinisikan Transformasi *Box Cox* sebagai berikut:

$$T(Z_t) = \begin{cases} Z_t(\lambda) = \frac{Z_t^{\lambda-1}}{\lambda}; & \text{untuk } \lambda \neq 0 \\ \log(Z_t) & ; \text{untuk } \lambda = 0 \end{cases} \tag{5}$$

di mana λ merupakan parameter transformasi.

Pemilihan Orde Model GSTAR

Menurut Wutsqa, Suhartono dan Sutijo (2012), pemilihan orde spasial model GSTAR pada umumnya dibatasi pada orde 1, karena orde yang lebih tinggi akan sulit untuk diinterpretasikan. Sedangkan untuk orde waktu (*autoregressive*) dapat ditentukan dengan melihat plot PACF yang terputus setelah lag ke- p dan dapat kita tentukan ordenya dari nilai *akaike information criterion* (AIC) yang terkecil. Perhitungan AIC sebagaimana menurut Akaike (1974) dalam Lutkephol (2005) yaitu :

$$AIC(p) = \ln|\sum_u \tilde{u}(p)| + \frac{2K^2}{T} \tag{6}$$

di mana $\sum_u \tilde{u}(p) = T^{-1} \sum_{t=1}^T \hat{u}_t \hat{u}_t'$ adalah matriks taksiran kovarian residual dari model *vector autoregressive* (p), T merupakan jumlah residual dan K merupakan jumlah variabel.

Jika didapatkan *lag* dalam model yang besar maka dipertimbangkan dengan menggunakan *principle of parsimony*. *Principle of parsimony* sendiri merupakan suatu prinsip yang menyatakan bahwa semakin sederhana sebuah model statistik dengan jumlah variabel dependen (yang dipengaruhi) cukup informatif untuk menjelaskan model, semakin baik pula model statistik tersebut.

Pemilihan Bobot Lokasi Model GSTAR

Pada pemodelan GSTAR permasalahan yang sering terjadi yaitu terletak pada pemilihan atau penentuan bobot lokasi. Pada penelitian ini, bobot lokasi yang digunakan yaitu bobot lokasi normalisasi korelasi silang. Metode ini menggunakan nilai korelasi antar lokasi yang telah dinormalisasi sebagai pembobot. Sehingga besar bobot di setiap lokasi berbeda sesuai dengan tingkat keeratan hubungan antar lokasi tersebut.

Taksiran dari korelasi silang ini pada data sampel adalah :

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [Z_i(t)-Z_i] [Z_j(t-k)-Z_j]}{\sqrt{(\sum_{t=1}^n [Z_i(t)-Z_i]^2)(\sum_{t=1}^n [Z_j(t)-Z_j]^2)}} \tag{7}$$

di mana, koefisien $r_{ij}(k)$ merupakan korelasi silang kejadian di lokasi ke- i dan ke- j (Suhartono dan Subanar, 2006).

Selanjutnya, penentuan bobot lokasi dapat dilakukan dengan normalisasi silang dari besaran korelasi silang antar lokasi pada waktu yang bersesuaian. Proses ini secara umum menghasilkan bobot lokasi sebagai berikut :

$$W_{ij}^{(k)} = \frac{r_{ij}(k)}{\sum_{K \neq i|r_{iK}(k)}}, i \neq j, k = 1, \dots, p \tag{8}$$

Bobot-bobot lokasi dengan menggunakan normalisasi dari korelasi silang antar lokasi pada lag waktu yang bersesuaian ini memungkinkan adanya kemungkinan hubungan antar lokasi. Bobot ini juga memberikan fleksibilitas pada besar dan tanda hubungan antar lokasi yang bisa berlainan yaitu positif dan negatif (Wutsqa, Suhartono dan Sutijo, 2012).

Pendugaan Parameter Model GSTAR

Pendugaan parameter model GSTAR dilakukan pada bobot lokasi dengan menggunakan Metode Kuadrat Terkecil dilakukan dengan meminimumkan jumlah kuadrat *error* nya (Borovkova, Lopuhaa dan Ruchjana, 2008).

$$Y_i = X_i \beta_i + e_i \tag{9}$$

dengan $Y_i(t)$ merupakan banyaknya pengamatan ke- t ($t = 0, 1, \dots, T$) untuk lokasi ke- i ($i = 1, 2, \dots, N$), dan $\beta_i = (\phi_{10}^{(1)}, \phi_{11}^{(1)})$. Jika diketahui $V_i(t) = \sum_{j \neq i}^N W_{ij} Z_j(t)$ maka persamaan (9) dapat dijabarkan dalam bentuk matriks sebagai berikut :

$$Y_i = \begin{bmatrix} Z_i(1) \\ Z_i(2) \\ \vdots \\ Z_i(T) \end{bmatrix}, X_i = \begin{bmatrix} Z_i(0) & V_i(0) \\ Z_i(1) & V_i(1) \\ \vdots & \vdots \\ Z_i(T-1) & V_i(T-1) \end{bmatrix}, \beta = \begin{bmatrix} \phi_{10}^{(1)} \\ \phi_{11}^{(1)} \end{bmatrix}, e_i = \begin{bmatrix} e_i(1) \\ e_i(2) \\ \vdots \\ e_i(T) \end{bmatrix}$$

Estimasi dengan metode *least square* sebagai berikut :

$$\hat{\beta} = [X'X]^{-1}X'Y \tag{10}$$

Pemeriksaan Diagnostik Model GSTAR

Pemeriksaan diagnostik dilakukan untuk melihat kelayakan model. Yang termasuk di dalam tahapan pemeriksaan diagnostik ini antara lain adalah pengujian signifikansi parameter model dan pengujian kesesuaian model, di mana untuk pengujian kesesuaian model ada suatu

asumsi dasar yang harus dipenuhi yaitu residual bersifat *white noise* dan berdistribusi normal (Wei, 1990).

Uji Signifikansi Parameter

Uji signifikansi parameter dimana $\hat{\theta}$ adalah nilai taksiran dari parameter tersebut, serta $SE(\hat{\theta})$ adalah standar error dari nilai taksiran $\hat{\theta}$, maka dapat dilakukan dengan tahapan sebagai berikut :

Hipotesis

$$H_0: \theta = 0$$

(parameter model tidak signifikan)

$$H_1: \theta \neq 0$$

(parameter model signifikan)

Statistik Uji

$$t_{hitung} = \frac{\hat{\theta}}{SE(\hat{\theta})} \tag{11}$$

Daerah Penolakan

Tolak H_0 jika $|t_{hitung}| > t_{(\frac{\alpha}{2}, df=n-n_p)}$, dimana n adalah banyaknya pengamatan dan n_p adalah jumlah parameter atau dengan menggunakan *p-value*, yakni tolak H_0 jika *p-value* < α .

(Aswi dan Sukarna, 2006)

Uji Kesesuaian Model

Menurut Wei (1990) ada dua asumsi dasar yang harus dipenuhi dalam uji kesesuaian model yaitu residual model bersifat *white noise* dan berdistribusi normal. Asumsi residual yang pertama yaitu bersifat *white noise* model dapat ditulis sebagai berikut.

Hipotesis

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_p = 0, k = 1, 2, \dots, p$$

Tidak terdapat autokorelasi antar residual (residual memenuhi syarat *white noise*)

$$H_1 : \text{Minimal ada satu } \rho_k \neq 0$$

Terdapat autokorelasi antar residual (residual tidak memenuhi syarat *white noise*)

Statistik uji, yaitu statistik uji Ljung-Box :

$$Q^* = n(n + 2) \sum_{k=1}^p \frac{\hat{\rho}_k^2}{(n-k)} \tag{12}$$

di mana, $k = \text{lag } 1, 2, \dots, p$

$n = \text{jumlah residual}$

$\hat{\rho}_k = \text{autokorelasi residual}$

Daerah Penolakan

Menolak H_0 jika $Q^* > \chi^2_{(\alpha, df=k-m)}$, s berarti pada lag s dan m adalah jumlah parameter yang ditaksir dalam model atau dengan menggunakan *p-value*, yakni menolak H_0 jika *p-value* < α .

(Aswi dan Sukarna, 2006)

Asumsi yang kedua yaitu, uji asumsi residual berdistribusi normal ini bertujuan untuk mengetahui apakah data telah memenuhi asumsi kenormalan atau belum. Salah satu cara yang dapat ditempuh untuk melakukan uji asumsi

kenormalan ini adalah uji Kolmogorov-Smirnov. Uji Kolmogorov-Smirnov adalah suatu tes *goodness of fit*, artinya yang diperhatikan adalah tingkat kesesuaian antara distribusi serangkaian data observasi dengan suatu distribusi teoritis tertentu.

Tahapan dalam pengujian kenormalan residual adalah sebagai berikut :

Hipotesis

$$H_0 : \varepsilon_i \sim N(0, \sigma^2), i = 1, 2, \dots, n$$

(Residual berdistribusi normal)

$$H_1 : \varepsilon_i \not\sim N(0, \sigma^2), i = 1, 2, \dots, n$$

(Residual tidak berdistribusi normal)

Statistik uji

$$D = \text{maksimum} |F_0(X) - S_n(X)| \tag{13}$$

di mana :

$F_0(X)$ = distribusi frekuensi kumulatif teoritis

$S_n(X)$ = distribusi frekuensi kumulatif yang diobservasi

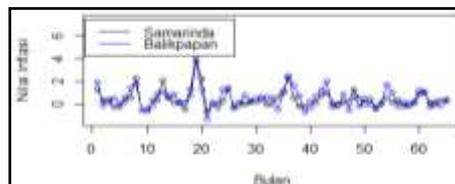
Daerah Penolakan

Menolak H_0 jika $D > D_{(\alpha; n)}$ atau H_0 ditolak apabila *p-value* < α .

(Siegel, 1988)

Hasil dan Pembahasan

Data yang akan digunakan dalam penelitian ini adalah data inflasi bulanan di Kota Samarinda dan Kota Balikpapan pada bulan Januari 2012 sampai dengan bulan Mei 2017.



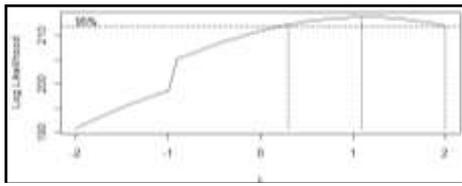
Gambar 1. Inflasi Kota Samarinda dan Kota Balikpapan bulan Januari 2012 – Mei 2017

Pada Gambar 1. data inflasi Kota Samarinda dan Kota Balikpapan bulan Januari 2012 – Mei 2017 mengalami kenaikan dan penurunan harga yang tidak jauh berbeda, terlihat dari letak titik data masing-masing kota di tiap bulannya yang cukup berdekatan. Inflasi Kota Samarinda tertinggi pada bulan ke-19 yaitu bulan Juli tahun 2013 sebesar 4,1 % dan terendah pada bulan ke-21 yaitu bulan September tahun 2013 sebesar -0,67 %. Sedangkan inflasi Kota Balikpapan tertinggi pada bulan ke-19 yaitu bulan Juli tahun 2013 sebesar 3,75 % dan terendah pada bulan ke-21 yaitu bulan September tahun 2013 sebesar -1,33 %.

Kestasioneran Data

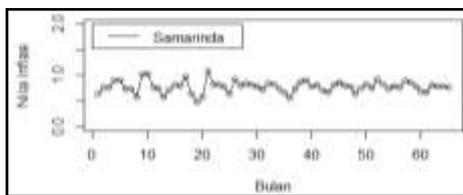
Untuk melihat stasioner dalam variansi menggunakan *Box-Cox plot*, sedangkan untuk stasioner dalam rata-rata menggunakan uji *Augmented Dickey Fuller* (ADF).

Kota Samarinda



Gambar 2. Box Cox data transformasi inflasi Kota Samarinda bulan Januari 2012 – Mei 2017

Pada Gambar 2, setelah data awal ditransformasi dengan $Z_1^{-0,42}$ dan diperoleh nilai λ berada di sekitaran nilai 1. Hal ini menunjukkan bahwa data sudah stasioner dalam variansi. Selanjutnya membuat *time series plot* data yang telah ditransformasi sebagai berikut :

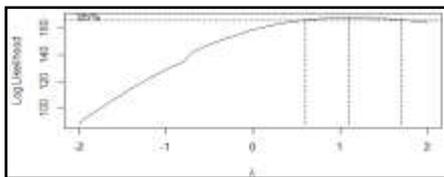


Gambar 3. *Time Series Plot* data transformasi inflasi Kota Samarinda bulan Januari 2012 – Mei 2017

Pada Gambar 3. terlihat bahwa data yang telah ditransformasi menunjukkan fluktuasi data yang berada di sekitar nilai rata-rata yang konstan. Sehingga dapat dikatakan data inflasi Kota Samarinda bulan Januari 2012 - Mei 2017 yang telah ditransformasi sudah stasioner dalam rata-rata. Stasioneritas data dalam rata-rata pada penelitian ini dapat juga dilihat dengan menggunakan uji *Augmented Dickey Fuller* (ADF).

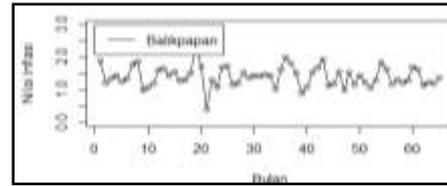
Didapatkan nilai $\tau = 7,35 < t_{(0,025;64)} = 1,99$, maka diputuskan menolak H_0 dan disimpulkan bahwa data inflasi Kota Samarinda bulan Januari 2012 - Mei 2017 sudah stasioner dalam rata-rata.

Kota Balikpapan



Gambar 4. Box Cox data transformasi inflasi Kota Balikpapan bulan Januari 2012 – Mei 2017

Pada Gambar 4. setelah data awal ditransformasi dengan $Z_2^{0,52}$ dan diperoleh nilai λ berada di sekitaran nilai 1. Hal ini menunjukkan bahwa data sudah stasioner dalam variansi. Selanjutnya membuat *time series plot* data yang telah ditransformasi sebagai berikut :



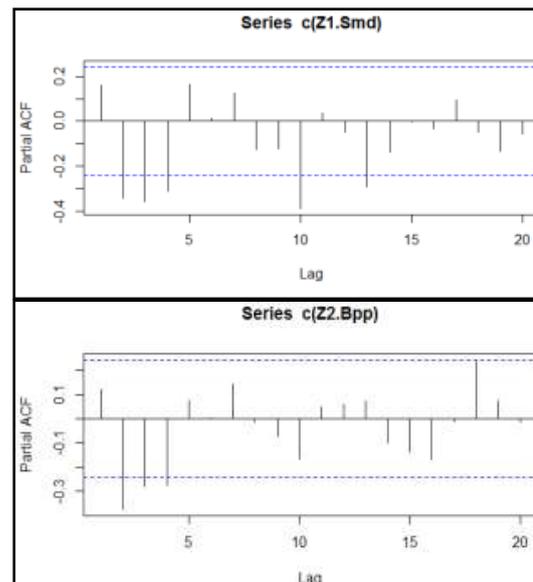
Gambar 5. *Time Series Plot* data transformasi inflasi Kota Balikpapan bulan Januari 2012 – Mei 2017

Pada Gambar 5. terlihat bahwa data yang telah ditransformasi menunjukkan fluktuasi data yang berada di sekitar nilai rata-rata yang konstan. Sehingga dapat dikatakan data inflasi Kota Balikpapan bulan Januari 2012 - Mei 2017 yang telah ditransformasi sudah stasioner dalam rata-rata. Stasioneritas data dalam rata-rata pada penelitian ini dapat juga dilihat dengan menggunakan uji *Augmented Dickey Fuller* (ADF).

Didapatkan nilai $\tau = 7,12 < t_{(0,025;64)} = 1,99$, maka diputuskan menolak H_0 dan disimpulkan bahwa data inflasi Kota Balikpapan bulan Januari 2012 - Mei 2017 sudah stasioner dalam rata-rata.

Pemilihan Orde Model GSTAR

Orde yang akan ditentukan dalam pemodelan ini adalah orde spasial dan orde waktu. Orde spasial pada umumnya terbatas pada orde 1, karena untuk orde yang lebih tinggi akan sulit untuk diinterpretasikan. Sedangkan untuk orde waktu (*autoregressive*) dapat ditentukan dengan melihat nilai AIC terkecil pada *lag* PACF yang *cut off*, sebagai berikut :



Gambar 6. Grafik PACF data transformasi inflasi Kota Samarinda dan Kota Balikpapan bulan Januari 2012 - Mei 2017

Berdasarkan prinsip *parsimony* grafik PACF pada Gambar 6. yang terlihat bahwa nilai PACF *cut off* pada lag 2,3, dan 4. Hal ini merujuk pada model AR(2), AR(3), dan AR(4), sehingga kombinasi model GSTAR yang memungkinkan pada peramalan inflasi Kota Samarinda dan Kota Balikpapan adalah GSTAR (2,1), GSTAR (3,1), dan GSTAR (4,1).

Tabel 1. Nilai AIC

Orde	Nilai AIC
AR (2)	56,88
AR (3)	52,31
AR (4)	46,27

Pada Tabel 1. diketahui bahwa nilai AIC terkecil berada pada orde keempat yaitu sebesar 46,27. Namun karena pertimbangan *lag* yang cukup besar maka akan tetap dilakukan pengujian untuk GSTAR (3,1) dan GSTAR (2,1).

Perhitungan Bobot Lokasi Model GSTAR

Pemodelan dengan menggunakan bobot normalisasi korelasi silang mempunyai asumsi bahwa keterikatan inflasi antara lokasi dipengaruhi oleh tinggi rendahnya korelasi antara inflasi di lokasi satu dengan inflasi di lokasi lainnya. Perhitungan bobot normalisasi korelasi silang diperoleh melalui normalisasi dari nilai-nilai korelasi antara lokasi pada *lag* yang bersesuaian.

Tabel 2. Nilai Korelasi Silang antar Lokasi

Notasi Korelasi Silang	Nilai Korelasi Silang	Notasi Korelasi Silang	Nilai Korelasi Silang
$r_{12}(1)$	-0,1758	$r_{21}(1)$	-0,1977
$r_{12}(2)$	0,4017	$r_{21}(2)$	0,2553
$r_{12}(3)$	0,2747	$r_{21}(3)$	0,4549
$r_{12}(4)$	0,1944	$r_{21}(4)$	0,1711

Dari nilai korelasi silang tersebut didapatkan bobot korelasi silang sebagai berikut :

$$W_{ij}^{(1)} = \begin{pmatrix} 0 & -1 \\ -1 & 0 \end{pmatrix} \quad W_{ij}^{(2)} = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$$

$$W_{ij}^{(3)} = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix} \quad W_{ij}^{(4)} = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$$

Estimasi Parameter Model GSTAR

Estimasi parameter model GSTAR dilakukan pada bobot lokasi dengan menggunakan metode kuadrat terkecil dengan cara meminimumkan jumlah kuadrat simpangannya. Dengan rumus untuk mencari estimasi parameter kuadrat terkecil dengan menggunakan persamaan $\hat{\beta} = (X'X)^{-1}$. Hasil estimasi parameter terdapat pada Tabel 3.

Uji Signifikansi Parameter

Untuk mengetahui model terbaik, maka perlu dilakukan pengujian signifikansi parameter. Pengujian signifikansi parameter untuk model

GSTAR pada Kota Samarinda dan Kota Balikpapan terdapat pada Tabel 4, Tabel 5 dan Tabel 6.

Tabel 3. Hasil Estimasi Parameter Model GSTAR

	Notasi Parameter	Nilai Taksiran	Notasi Parameter	Nilai Taksiran
GSTAR (2,1)	$\phi_{10}^{(1)}$	0,5871	$\phi_{10}^{(2)}$	0,4189
	$\phi_{11}^{(1)}$	-0,1133	$\phi_{11}^{(2)}$	-0,3757
	$\phi_{20}^{(1)}$	-0,0546	$\phi_{20}^{(2)}$	-0,1112
	$\phi_{21}^{(1)}$	0,1483	$\phi_{21}^{(2)}$	0,8597
GSTAR (3,1)	$\phi_{10}^{(1)}$	0,5371	$\phi_{10}^{(2)}$	0,3302
	$\phi_{11}^{(1)}$	-0,1350	$\phi_{11}^{(2)}$	-0,5833
	$\phi_{20}^{(1)}$	0,0257	$\phi_{20}^{(2)}$	-0,1077
	$\phi_{21}^{(1)}$	0,1477	$\phi_{21}^{(2)}$	0,5344
	$\phi_{30}^{(1)}$	-0,1374	$\phi_{30}^{(2)}$	-0,1578
	$\phi_{31}^{(1)}$	0,0377	$\phi_{31}^{(2)}$	0,5591
	$\phi_{10}^{(1)}$	0,4722	$\phi_{10}^{(2)}$	0,2973
GSTAR (4,1)	$\phi_{11}^{(1)}$	-0,1652	$\phi_{11}^{(2)}$	-0,6536
	$\phi_{20}^{(1)}$	-0,0557	$\phi_{20}^{(2)}$	-0,1338
	$\phi_{21}^{(1)}$	0,1806	$\phi_{21}^{(2)}$	0,7349
	$\phi_{30}^{(1)}$	-0,0509	$\phi_{30}^{(2)}$	-0,1135
	$\phi_{31}^{(1)}$	0,0425	$\phi_{31}^{(2)}$	0,6551
	$\phi_{40}^{(1)}$	-0,2200	$\phi_{40}^{(2)}$	-0,2194
	$\phi_{41}^{(1)}$	0,0871	$\phi_{41}^{(2)}$	0,0477

Tabel 4. Nilai Uji Signifikansi Parameter Model GSTAR (2,1)

Variabel	Parameter	Nilai Taksiran	Standar Error	t_{hitung}
Z_1^*	$\phi_{10}^{(1)}$	0,5871	0,0938	6,2577
	$\phi_{11}^{(1)}$	-0,1133	0,1298	-0,8734
	$\phi_{20}^{(1)}$	-0,0546	0,0945	-0,5775
	$\phi_{21}^{(1)}$	0,1483	0,1307	1,1342
Z_2^*	$\phi_{10}^{(2)}$	0,4189	0,1690	2,4786
	$\phi_{11}^{(2)}$	-0,3757	0,6041	-0,6218
	$\phi_{20}^{(2)}$	-0,1112	0,1713	-0,6491
	$\phi_{21}^{(2)}$	0,8597	0,6065	1,1342

dengan daerah penolakan menolak H_0 jika $|t| > (t_{0,025;63}) = 1,99$.

Tabel 5. Nilai Uji Signifikansi Parameter Model GSTAR (3,1)

Variabel	Parameter	Nilai Taksiran	Standar Error	t_{hitung}
Z_1^*	$\phi_{10}^{(1)}$	0,5371	0,0915	5,8674
	$\phi_{11}^{(1)}$	-0,1350	0,1282	-1,0532
	$\phi_{10}^{(1)}$	0,5371	0,0915	5,8674
	$\phi_{20}^{(1)}$	0,0257	0,0923	0,2791

Tabel 5. Nilai Uji Signifikansi Parameter Model GSTAR (3,1) (Lanjutan)

Variabel	Parameter	Nilai Taksiran	Standar Error	t_{hitung}
Z_1^*	$\phi_{21}^{(1)}$	0,1477	0,1291	1,1440
	$\phi_{30}^{(1)}$	-0,1374	0,0930	-1,4763
	$\phi_{31}^{(1)}$	0,0377	0,1300	0,2899
Z_2^*	$\phi_{10}^{(2)}$	0,3302	0,1600	2,0640
	$\phi_{11}^{(2)}$	-0,5833	0,5878	-0,9924
	$\phi_{20}^{(2)}$	-0,1077	0,1622	-0,6644
	$\phi_{21}^{(2)}$	0,5344	0,5901	0,9056
	$\phi_{30}^{(2)}$	-0,1578	0,1643	-0,9606
	$\phi_{31}^{(2)}$	0,5591	0,5925	0,9435

dengan daerah penolakan menolak H_0 jika $|t| > (t_{0,025;62}) = 1,99$.

Tabel 6. Nilai Uji Signifikansi Parameter Model GSTAR (4,1)

Variabel	Parameter	Nilai Taksiran	Standar Error	t_{hitung}	
Z_1^*	$\phi_{10}^{(1)}$	0,4722	0,0843	5,5963	
	$\phi_{11}^{(1)}$	-0,1652	0,1231	1,3422	
	$\phi_{20}^{(1)}$	-0,0557	0,0857	0,6497	
	$\phi_{21}^{(1)}$	0,1806	0,1240	1,4571	
	$\phi_{30}^{(1)}$	-0,0509	0,0857	0,5941	
	$\phi_{31}^{(1)}$	0,0425	0,1245	0,3416	
	$\phi_{40}^{(1)}$	-0,2200	0,0865	2,5438	
	$\phi_{41}^{(1)}$	0,0871	0,1262	0,6905	
	Z_2^*	$\phi_{10}^{(2)}$	0,2973	0,1555	1,9121
		$\phi_{11}^{(2)}$	-0,6536	0,5772	1,1322
$\phi_{20}^{(2)}$		-0,1338	0,15762	0,8489	
$\phi_{21}^{(2)}$		0,7349	0,5796	1,2680	
$\phi_{30}^{(2)}$		-0,1135	0,1597	0,7107	
$\phi_{31}^{(2)}$		0,6551	0,5819	1,1256	
$\phi_{40}^{(2)}$		-0,2194	0,1627	1,3482	
$\phi_{41}^{(2)}$		0,0477	0,5847	0,0816	

dengan daerah penolakan menolak H_0 jika $|t| > (t_{0,025;61}) = 1,99$.

Hasil seleksi parameter untuk menghasilkan model terbaik dan memenuhi uji signifikansi parameter terdapat pada Tabel 7. Berdasarkan Tabel 7. didapatkan model pada masing masing lokasi, hanya saja untuk model GSTAR (4,1) pada lokasi Kota Balikpapan tidak terdapat parameter yang signifikan sehingga GSTAR (4,1) ditiadakan.

Tabel 7. Hasil Seleksi Uji Signifikansi Parameter Model GSTAR

Variabel	Parameter	Nilai Taksiran	Standar Error	t_{hitung}
Z_1^*	GSTAR (2,1) $\phi_{10}^{(1)}$	0,9852	0,1275	7,7261
	GSTAR (3,1) $\phi_{10}^{(1)}$	0,9852	0,1275	7,7261
Z_1^*	GSTAR (4,1) $\phi_{10}^{(1)}$	0,8909	0,1285	6,9301
	$\phi_{40}^{(1)}$	0,0551	0,0865	0,6374
Z_2^*	GSTAR (2,1) $\phi_{10}^{(2)}$	0,9522	0,1703	5,5901
	GSTAR (3,1) $\phi_{10}^{(2)}$	0,9522	0,1612	5,5901

Dengan demikian model GSTAR untuk data inflasi Kota Samarinda dan Kota Balikpapan adalah sebagai berikut :

GSTAR (2,1)

untuk $i = 1$ yaitu Kota Samarinda

$$Z_1^*(t) = \phi_{10}^{(1)} Z_1^*(t-1) + e_1(t) = 0,9852 Z_1^*(t-1) + e_1(t)$$

untuk $i = 2$ yaitu Kota Balikpapan

$$Z_2^*(t) = \phi_{10}^{(2)} Z_2^*(t-1) + e_2(t) = 0,9522 Z_2^*(t-1) + e_2(t)$$

GSTAR (3,1)

untuk $i = 1$ yaitu Kota Samarinda

$$Z_1^*(t) = \phi_{10}^{(1)} Z_1^*(t-1) + e_1(t) = 0,9852 Z_1^*(t-1) + e_1(t)$$

untuk $i = 2$ yaitu Kota Balikpapan

$$Z_2^*(t) = \phi_{10}^{(2)} Z_2^*(t-1) + e_2(t) = 0,9522 Z_2^*(t-1) + e_2(t)$$

Model tersebut menunjukkan bahwa pada inflasi Kota Samarinda data inflasi dipengaruhi oleh data satu lag sebelumnya, sedangkan tidak ada data lag sebelumnya yang mempengaruhi hubungannya dengan inflasi Kota Balikpapan. Begitu pula pada inflasi Kota Balikpapan data inflasi dipengaruhi oleh data satu lag sebelumnya, sedangkan tidak ada data lag sebelumnya yang mempengaruhi hubungannya dengan inflasi Kota Samarinda.

Uji Kesesuaian Model

Setelah model yang signifikan didapat maka dilanjutkan uji kesesuaian model pada data residual model GSTAR (2,1) dan model GSTAR (3,1) masing-masing terdapat pada Tabel 8 dan Tabel 9.

Berdasarkan Tabel 8. dan 9. model GSTAR (2,1) dan GSTAR (3,1) terlihat bahwa untuk variabel Z_1^* dan Z_2^* pada model GSTAR (2,1) dan GSTAR (3,1) terdapat nilai $p\text{-value} < \alpha$ (0,05) maka diputuskan menolak H_0 . Dengan taraf kepercayaan 95% maka disimpulkan bahwa residual variabel Z_1^* dan Z_2^* pada model GSTAR

(2,1) dan GSTAR (3,1) tidak memenuhi syarat *white noise*.

Tabel 8. Statistik Uji *White Noise* GSTAR (2,1)

Varia bel	Ljung-Box				
	Lag	12	24	36	48
Z_1^*	Q	37,293	48,751	56,272	62,356
	P-value	0,0002	0,0020	0,0168	0,0797
	Lag	12	24	36	48
Z_2^*	Q	19,41	37,717	46,008	49,94
	P-value	0,0791	0,0370	0,1226	0,3962

Tabel 9. Statistik Uji *White Noise* GSTAR (3,1)

Varia bel	Ljung-Box				
	Lag	12	24	36	48
Z_1^*	Q	37,293	48,751	56,272	62,356
	P-value	0,0002	0,0020	0,0168	0,0797
	Lag	12	24	36	48
Z_2^*	Q	19,41	37,717	46,008	49,94
	P-value	0,0791	0,0370	0,1226	0,3962

Pengujian kenormalan residual model model GSTAR (2,1) dan GSTAR (3,1) masing-masing terdapat pada Tabel 10 dan Tabel 11.

Tabel 10. Nilai D_{hitung} Pengujian Kenormalan Residual GSTAR (2,1)

Variabel	D_{hitung}
Z_1^*	0,3853
Z_2^*	0,2262

Tabel 11. Nilai D_{hitung} Pengujian Kenormalan Residual GSTAR (3,1)

Variabel	D_{hitung}
Z_1^*	0,3853
Z_2^*	0,2262

Pada Tabel 10. dan 11. model GSTAR (2,1) dan GSTAR (3,1) terlihat bahwa untuk variabel Z_1^* dan Z_2^* memiliki nilai $D_{hitung} > D_{(0,05;62)}$ (0,17) maka diputuskan H_0 gagal ditolak, maka disimpulkan bahwa residual variabel Z_1^* dan Z_2^* pada model GSTAR (2,1) dan GSTAR (3,1) berdistribusi normal.

Berdasarkan uji kelayakan model tersebut, syarat *white noise* tidak terpenuhi untuk model GSTAR (2,1) dan GSTAR (3,1). Dengan demikian model GSTAR (2,1) dan GSTAR (3,1) tersebut tidak dapat digunakan untuk peramalan data periode selanjutnya. Pada Gambar 6. terdapat *cut off* pada grafik PACF dan grafik ACF, sehingga dimungkinkan model yang tepat untuk data ini adalah model yang menggabungkan AR dan MA atau GSTARMA (*Generalized Space Time Autoregressive Moving Average*).

Kesimpulan

Berdasarkan analisis yang telah dilakukan, maka dapat diperoleh kesimpulan bahwa model yang diperoleh yaitu model GSTAR (2,1) dan GSTAR (3,1) untuk data inflasi Kota Samarinda dan Kota Balikpapan diperoleh secara berturut-turut sebagai berikut :

GSTAR (2,1)

$$Z_1^*(t) = 0,9852 Z_1^*(t - 1)$$

$$Z_2^*(t) = 0,9522 Z_2^*(t - 1)$$

GSTAR (3,1)

$$Z_1^*(t) = 0,9852 Z_1^*(t - 1)$$

$$Z_2^*(t) = 0,9522 Z_2^*(t - 1)$$

dimana $Z_1(t) = (Z_1^*(t)^{(1/-0,42)}) - 1,5$ dan $Z_2(t) = (Z_2^*(t)^{(1/0,52)}) - 1,5$.

Model GSTAR (2,1) dan GSTAR (3,1) tidak layak digunakan untuk peramalan karena tidak memenuhi asumsi *white noise*.

Daftar Pustaka

- Anselin, L. (1998). *Spatial Econometrics : Methods and Models*. The Netherlands: Kluwer Academic Publishers.
- Aswi and Sukarna. (2006). *Analisis Deret Waktu dan Aplikasi*. Makasar : Andira Publisher.
- Borovkova, S., Lopuhaa, H.P., dan Ruchjana, B.N. (2008). Consistency and Asymptotic Normality of Least Square Estimators in Generalized STAR Models. *Journal Compilation Statistica Nederlandica*.
- Cryer, J.D., and Kung-Sik, C. (2008). *Time Series Analysis with Application in R Second Edition*. University of Iowa : Departemen of Statistics and Actuarial Science.
- Gama, P.D.S. (2017). Perbandingan Model STAR dan GSTAR Untuk Peramalan Inflasi Dumai, Pekanbaru, Dan Batam. *Statistika*, Vol. 5, No. 1, Mei 2017.
- Gujarati, D. N. (2003). *Basic Econometrics*. Now York : McGraw-Hill.
- Hasbullah, J. (2012). *Tanggung Dengan Statistik*. Jakarta: Nuansa Cendikia.
- Lutkepohl, Helmut. (2005). *New Indroduction to Multiple Time Series Analysis*. New York : Springer.
- Makridakis, S. (1999). *Metode dan Aplikasi Peramalan*. Edisi Kedua Jilid I. Untung Sus Andriyanto dan Abdul Basith, Penerjemah. Jakarta : Penerbit Erlangga. Terjemahan dari : Forecasting, 2nd Edition.
- Pfeifer P.E. and Deutsch S.J. (1980). A three stage iterative procedure for space-time modeling. *Technometrics*. Vol. 22, No. 1.
- Ruchjana, B.N. (2002). Pemodelan Kurva Produksi Minyak Bumi menggunakan Model Generalisasi STAR. *Forum Statistika Komputasi*. Bogor : IPB.
- Siegel, S. (1988). *Statistik Non Parametrik*. Jakarta : PT Gramedia.

- Sudarso. (1991). *Pengantar Ekonomi Makro*. Jakarta : Rineke Cipta.
- Suhartono and Subanar. (2006). The Optimal Determination of Space Weight in GSTAR Model by using Cross-correlation Inference. *Journal Of Quantitative Methods : Journal Devoted to The Mathematical and Statistical Application in Various Fields*. Vol. 2, No. 2.
- Sukirno S. (2000). *Makroekonomi Modern Perkembangan Pemikiran dari Klasik hingga Keynesian Baru*. Jakarta : PT Raja Grafindo Persada.
- Talungke, Y., Nainggolan, and N., Hatidja, D. (2015). *Model Generalized Space Time Autoregressive (GSTAR) dengan Analisis Data Menggunakan Software R*. *JdC*. Vol. 4, No. 2.
- Wutsqa, U.D., Suhartono, and Sutijo, B. (2012). Aplikasi Model Generalized Space Time Autoregressive Pada Data Pencemaran Udara Di Kota Surabaya. *Phytagoras*. Vol. 7, No. 2.
- Wei, W.S.S. (1990). *Time Series Analysis Univariate and Multivariate Methods*. California : Addison- Wesley Publishing Company, Inc.

