

**Model Generalized Space Time Autoregressive Integrated Moving Average
(Studi Kasus: Inflasi Kota Surabaya, Malang dan Kediri)**

**Model of Generalized Space Time Autoregressive Integrated Moving Average
(Case Study: Inflation in Surabaya, Malang and Kediri)**

Rafiqah Novi Eka Pratiwi¹, Sri Wahyuningsih², dan Meiliyani Siringoringo³

¹Laboratorium Statistika Ekonomi dan Bisnis FMIPA Universitas Mulawarman

²Laboratorium Statistika Terapan FMIPA Universitas Mulawarman

³Laboratorium Statistika Komputasi FMIPA Universitas Mulawarman

E-mail: novirafiqah@gmail.com

Abstract

Generalized Space Time Autoregressive Integrated Moving Average (GSTARIMA) is the models used to model the time series data containing spatial dependence between its locations (space time). GSTARIMA models can be used in economics data including export-import, exchange rate, production and inflation. Inflation is goods prices raising process in general. The inflation development in East Java is monitored through economic development in some big cities, such as Surabaya, Malang, and Kediri. Inflation is not only influenced by the previous times, but also has a correlation between one cities to other cities. The purpose of this research are to get the best GSTARIMA model and the forecasting results of inflation data in Surabaya, Malang and Kediri. Parameter estimation is performed using the ordinary least squares estimator (OLS) with the inverse distance weighting and cross correlation. The GSTARIMA(2,0,0)1 is the best inflation model of Surabaya, Malang, and Kediri with inverse distance weighting. In prediction, the result of those three cities inflation in 2017 is generally decreased trended. This can be seen from the inflation value which is around the value of 0,3 to almost close to the zero value.

Keywords: Inverse distance weighted, Cross correlation weighted, GSTARIMA, Inflation.

Pendahuluan

Analisis runtun waktu merupakan suatu metode analisis data yang ditujukan untuk melakukan suatu estimasi maupun peramalan pada masa yang akan datang. Pemodelan dan peramalan menggunakan metode runtun waktu dapat dilakukan baik terhadap data univariat maupun multivariat. Data runtun waktu multivariat dapat dimodelkan dengan model *Vector Autoregressive Moving Average* (VARMA) yang merupakan perluasan dari model *Autoregressive Moving Average* (ARMA). Suatu bentuk khusus dari model VARMA adalah model yang menggabungkan interdependensi waktu dan lokasi yang dikenal dengan model *Space Time Autoregressive Moving Average* (STARMA) yang pertama kali dikenalkan oleh Pfeifer dan Deutsch (1980). Model STARMA terkadang dianggap tidak realistis karena parameter diasumsikan sama untuk semua lokasi. Borovkova dkk, (2002) mengusulkan model yang juga dapat menggabungkan interdependensi waktu dan lokasi yaitu model *Generalized Space Time Autoregressive Moving Average* (GSTARMA), model ini dianggap lebih realistis karena menghasilkan parameter yang berbeda untuk setiap lokasi. Salah satu pertimbangan penting pada model GSTARIMA adalah matriks pembobot spasial. Secara umum, penelitian terkait GSTARIMA hanya berfokus pada pembobot spasial berorde 1. Model GSTARIMA bisa

digunakan pada sektor ekonomi diantaranya data ekspor, data nilai tukar (kurs), data produksi dan data inflasi.

Inflasi adalah suatu proses atau peristiwa kenaikan tingkat harga umum. Dikatakan tingkat harga umum oleh karena barang dan jasa itu banyak jumlah dan jenisnya. Inflasi merupakan salah satu masalah utama makro ekonomi yang banyak mendapatkan perhatian para pemikir ekonomi, karena peranannya yang sangat penting dalam kemajuan perekonomian suatu negara. Karena inflasi mempunyai pengaruh yang cukup besar dalam perekonomian suatu negara, maka pengendalian inflasi sangat penting untuk dilakukan.

Pencatatan lengkap inflasi dari tahun ke tahun hanya ada di Kota Surabaya, Malang dan Kediri yang menggambarkan besarnya laju pertumbuhan ekonomi di daerah tersebut. Berdasarkan data BPS Jawa Timur, sepanjang tahun 2014 tercatat bahwa kota Surabaya, Malang dan Kediri menempati urutan empat teratas penyumbang inflasi terbesar di Jawa Timur. Hal ini menarik untuk diteliti sebab ketiga kota tersebut memiliki lokasi yang berdekatan sehingga memiliki dependensi spasial satu sama lain.

Berdasarkan uraian tersebut ingin dianalisis mengenai fenomena inflasi di Kota Surabaya, Malang dan Kediri dengan model GSTARIMA. Judul penelitian yang diusulkan yaitu "Model

Generalized Space Time Autoregressive Integrated Moving Average”.

Stasioneritas dalam Variansi

Suatu data dikatakan stasioner dalam variansi apabila struktur data dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah (Makridakis dkk, 1999). Bila kondisi stasioner dalam variansi tidak diperoleh, Box-Cox (1964) dalam Aswi dan Sukarna (2006) memperkenalkan transformasi pangkat (*power transformation*), yaitu :

$$Z_t^* = \frac{Z_t^{(\lambda)} - 1}{\lambda} \tag{1}$$

dimana λ disebut sebagai parameter transformasi.

Stasioneritas dalam Rata-rata

Suatu data runtun waktu dikatakan stasioner dalam rata-rata apabila fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan. Bila kondisi stasioner dalam rata-rata tidak diperoleh, maka perlu dilakukan proses pembedaan yang dirumuskan sebagai berikut (Makridakis dkk, 1999) :

$$\nabla^d = (1 - B)^d Z_t \tag{2}$$

Uji Augmented Dickey-Fuller (ADF)

Uji ADF merupakan pengujian stasioner dengan menentukan apakah data runtun waktu mengandung akar unit (*unit root*). Prosedur untuk menentukan apakah data stasioner atau tidak dengan cara membandingkan antara nilai statistik uji t yang disimbolkan dengan τ yaitu :

$$\tau = \left| \frac{\hat{\rho}}{SE(\hat{\rho})} \right| \tag{3}$$

dengan $\hat{\rho}$ adalah nilai taksiran dari parameter, $SE(\hat{\rho})$ merupakan standar error dari nilai taksiran $\hat{\rho}$, dengan daerah kritis pengujian ini adalah H_0 ditolak apabila nilai statistik ADF lebih besar daripada absolut nilai kritis distribusi statistik t (Widarjono, 2007).

Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

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

$$r_k = \frac{\sum_{t=1}^{T-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^{T-k} (Z_t - \bar{Z})^2} \tag{4}$$

PACF digunakan untuk mengukur tingkat keeratan (*association*) antara Z_t dan Z_{t+k} , apabila pengaruh dari lag waktu 1,2,3,... dan seterusnya sampai $k-1$ dianggap terpisah. Koefisien PACF dapat diduga dengan koefisien PACF sampel yang ditulis sebagai berikut :

$$\hat{\phi}_{kk} = \frac{r_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} r_j} \tag{5}$$

di mana $\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j}$, untuk $j = 1, 2, \dots, k-1$.

(Wei, 2006).

Model Generalized Space Time Autoregressive Integrated Moving Average (GSTARIMA)

Model GSTARMA merupakan perkembangan dari model STARMA. Pada model STARMA parameter diasumsikan sama untuk setiap lokasi. Asumsi ini menjadikan STARMA dianggap tidak fleksibel dan tidak realistis dalam menggambarkan karakteristik lokasi yang sangat mungkin tidak homogen. Borovkova dkk, (2002) mengusulkan model lebih lanjut dari STARMA yaitu GSTARMA. Perbedaan mendasar dari kedua model ini terletak pada parameternya, dimana pada model STARMA Φ_{kl} dan θ_{kl} merupakan konstanta, sedangkan pada model GSTARMA berupa matriks Φ_{kl} dan Θ_{kl} . Model GSTARMA yang mengalami pembedaan disebut model GSTARIMA. $GSTARIMA(p_{\lambda_k}, d, q_{\nu_k})$ didefinisikan sebagai berikut :

$$\nabla Z_t = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \Phi_{kl} \mathbf{W}^{(l)} \nabla Z_{t-k} - \sum_{k=1}^q \sum_{l=0}^{\nu_k} \Theta_{kl} \mathbf{W}^{(l)} e_{t-k} + e_t, \tag{6}$$

- dengan
- ∇Z_t = vektor pengamatan berukuran $n \times 1$ pada waktu ke- t
- Φ_{kl} = matriks diagonal parameter *autoregressive* pada lag waktu ke- k dan lag spasial ke- l berukuran $n \times n$
- $\mathbf{W}^{(l)}$ = matriks pembobot spasial lag ke- l berukuran $n \times n$
- Θ_{kl} = matriks diagonal parameter *moving average* pada lag waktu ke- k dan lag spasial ke- l berukuran $n \times n$
- e_t = vektor acak *white noise* berukuran $n \times 1$ yang diasumsikan berdistribusi normal dengan rata-rata nol dan variansi konstan (Pfeifer dan Deutsch, 1980).

Pembobot Kebalikan Jarak

Nilai dari bobot kebalikan jarak diperoleh berdasarkan perhitungan jarak sebenarnya antar lokasi yang dalam perhitungannya dapat menggunakan jarak koordinat lintang dan bujur antar titik pusat lokasi yang diamati. Lokasi yang berdekatan mendapatkan nilai bobot yang lebih besar dan demikian pula sebaliknya. dan pembobot kebalikan jarak dapat dihitung menggunakan rumus di bawah ini :

$$w_{ij} = \begin{cases} \frac{w_{ij}^*}{\sum_{h=1}^N w_{ih}^*}, & \text{untuk } i \neq h \\ 0, & \text{untuk } i=h \end{cases} \quad (7)$$

di mana

$$d_{ij} = d_{ji} = \left[(u_i - u_j)^2 + (v_i - v_j)^2 \right]^{1/2} \quad (8)$$

$$w_{ij}^* = w_{ji}^* = \frac{1}{d_{ij}} = \frac{1}{d_{ji}} \quad (9)$$

Pembobot Normalisasi Korelasi Silang

Suhartono dan Subanar (2006) mengenalkan pembobot normalisasi korelasi silang untuk model GSTAR dan Wutsqa dkk, (2010) menggunakan pembobot ini terhadap data simulasi. Pembobot ini tidak mensyaratkan aturan tertentu, seperti bergantung pada jarak antar lokasi. Penduga korelasi silang pada data sampel adalah sebagai berikut:

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [Z_i(t) - \bar{Z}_i][Z_j(t-k) - \bar{Z}_j]}{\left[\left(\sum_{t=1}^n [Z_i(t) - \bar{Z}_i]^2 \right) \left(\sum_{t=1}^n [Z_j(t) - \bar{Z}_j]^2 \right) \right]^{1/2}} \quad (10)$$

Selanjutnya diselesaikan dengan menormalisasikan korelasi silang antar lokasi pada lag yang sesuai yang kemudian menghasilkan pembobot lokasi sebagai berikut :

$$w_{ij} = \frac{|r_{ij}(k)|}{\sum_{h=1}^N |r_{ih}(k)|}; i \neq h, k=0,1,2,\dots,p \quad (11)$$

Pendugaan Parameter

Model GSTARIMA dapat direpresentasikan sebagai sebuah model linear dan parameter-parameter *autoregressive* model dapat diestimasi menggunakan metode kuadrat terkecil atau metode *least square* (Borovkova dkk, 2002). Bentuk linier metode kuadrat terkecil sebagai berikut :

$$\mathbf{Z} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e} \quad (12)$$

dengan penjabaran matriks sebagai berikut :

$$\mathbf{Z} = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{bmatrix} \quad \mathbf{X} = \begin{bmatrix} Z_1 & 0 & 0 & v_1 & 0 & 0 \\ 0 & \vdots & \vdots & 0 & \vdots & \vdots \\ \vdots & Z_2 & \vdots & \vdots & v_2 & \vdots \\ \vdots & 0 & \vdots & \vdots & 0 & \vdots \\ 0 & 0 & Z_n & 0 & 0 & v_n \end{bmatrix}$$

$$\boldsymbol{\beta} = \begin{bmatrix} \phi_{10}^{(i)} \\ \phi_{11}^{(i)} \\ \vdots \\ \phi_{kl}^{(N)} \end{bmatrix} \quad \text{dan } \mathbf{e} = \begin{bmatrix} e_1(1) \\ e_1(2) \\ \vdots \\ e_1(n) \end{bmatrix}$$

dengan $Z_i(t)$ merupakan banyak pengamatan pada periode ke- t , untuk lokasi $i = 1, 2, \dots, N$ dan

$$V_i(t) = \sum_{j=1}^N w_{ij}^{(1)} Z_j(t) \text{ untuk } i \neq j.$$

Nilai taksiran untuk parameter dapat dihitung menggunakan penaksir *least square* dengan formula sebagai berikut :

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \quad (13)$$

Uji Signifikansi Parameter

Uji signifikansi parameter dimana $\hat{\phi}$ adalah nilai taksiran dari parameter tersebut, dan $SE(\hat{\phi})$ adalah standar *error* dari nilai taksiran $\hat{\phi}$. Statistik ujinya sebagai berikut :

$$t_{hitung} = \frac{\hat{\phi}}{SE(\hat{\phi})} \quad (14)$$

Dengan kriteria penolakan menolak H_0 jika $|t_{hitung}| > t_{\left(\frac{\alpha}{2}, df=t-r\right)}$, dimana t adalah banyaknya pengamatan dan r adalah jumlah parameter atau dengan menggunakan *p-value*, yakni menolak H_0 jika *p-value* < α .

(Aswi dan Sukarna, 2006)

Uji White Noise

Suatu proses $\{a_t\}$ dikatakan proses *white noise* (proses yang bebas dan identik) jika bentuk variabel *random* yang berurutan tidak saling berkorelasi dan mengikuti distribusi tertentu. Uji asumsi *white noise* ini meliputi uji kenormalan residual dan uji independensi residual.

a. Uji Kenormalan Residual

Uji kenormalan residual diuji menggunakan uji Kolmogorov-Smirnov dengan statistik uji sebagai berikut :

$$D_{hit} = \sup |F_0(X) - S_n(X)| \quad (15)$$

dengan $F_0(X)$ adalah distribusi frekuensi kumulatif teoritis dan $S_n(X)$ adalah distribusi frekuensi kumulatif yang diobservasi. Daerah Penolakan

Menolak H_0 jika $D_{hit} > D_{(\alpha;t)}$ atau H_0 ditolak apabila $p\text{-value} < \alpha$. (Siegel, 1994).

b. Uji Independensi Residual

Uji independensi residual diuji dengan menggunakan uji Ljung-Box dengan statistik uji yang dirumuskan sebagai berikut:

$$Q_k^* = t(t+2) \sum_{k=1}^p \frac{\hat{\rho}_k^2}{(t-k)} \quad (16)$$

dengan $\hat{\rho}_k$ adalah autokorelasi residual.

Daerah Penolakan

Menolak H_0 jika $Q_k^* > \chi_{(\alpha;df=t-k-r)}^2$, k berarti pada lag k dan r adalah jumlah parameter yang ditaksir dalam model atau dengan menggunakan $p\text{-value}$, yakni menolak H_0 jika $p\text{-value} < \alpha$.

(Aswi dan Sukarna, 2006).

Kriteria Pemilihan Model Terbaik

Pemilihan model terbaik pada penelitian ini didasarkan pada dua kriteria, yakni pada nilai Akaike's Information Criterion (AIC) dan pada nilai Mean Absolute Percentage Error (MAPE).

1. Akaike's Information Criterion (AIC)

Kriteria AIC dirumuskan sebagai berikut :

$$AIC = t \times \ln \left(\frac{SSE}{t} \right) + 2r + t \times \ln(2\pi) \quad (17)$$

2. Mean Absolute Percentage Error (MAPE)

Kriteria MAPE dirumuskan sebagai berikut :

$$MAPE = \frac{\sum_{t=1}^m \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right|}{m} \times 100\% \quad (18)$$

Inflasi

Inflasi dapat didefinisikan sebagai suatu proses kenaikan harga-harga yang berlaku dalam suatu perekonomian. Tingkat inflasi (persentasi pertambahan kenaikan harga) berbeda dari satu periode ke periode lainnya, dan berbeda pula dari satu negara ke negara lainnya (Sukirno, 2004).

Metode Penelitian

Data yang digunakan dalam penelitian ini adalah data inflasi bulanan Kota Surabaya, Malang dan Kediri periode Januari 2010 sampai Desember 2016. Data diperoleh dari website resmi Badan Pusat Statistik (BPS) Provinsi Jawa Timur.

Hasil dan Pembahasan Statistika Deskriptif

Statistika deskriptif dari data runtun waktu dapat dilihat pada Tabel 1.

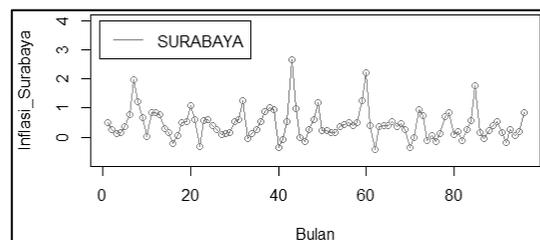
Tabel 1. Statistika Deskriptif Data Inflasi Surabaya, Malang dan Kediri *month to month* (mtm) periode Januari 2010 sampai Desember 2016

Lokasi	N	Rata-Rata	Deviasi Standar	Mini-mum	Maksi-mum
Surabaya	84	0,443	0,524	-0,420	2,670
Malang	84	0,418	0,579	-0,570	3,490
Kediri	84	0,369	0,607	-0,830	3,260

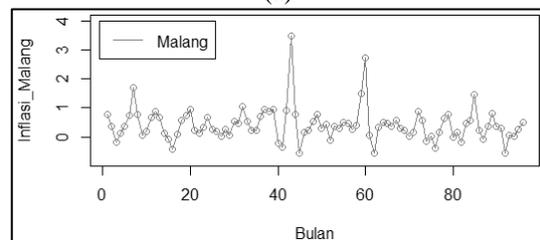
Tabel 1 menjelaskan bahwa jumlah data yang digunakan dalam penelitian ini sebanyak 84 data untuk tiap-tiap lokasi. Kediri mempunyai rata-rata inflasi yang paling rendah diantara tiga kota tersebut yaitu sebesar 0,381%. Surabaya mempunyai rata-rata inflasi paling tinggi yaitu 0,455%. Nilai inflasi tertinggi yaitu di Malang sebesar 3,490% dan terendah di Surabaya sebesar 2,670%.

Time Series Plot

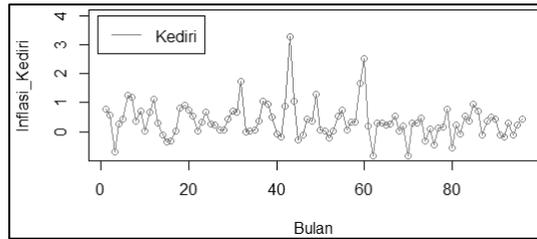
Time series plot digunakan untuk mengetahui lebih jelas kenaikan dan penurunan pada data dan dapat digunakan untuk memeriksa kestasioneran data dalam rata-rata dan varians yang dapat dilihat pada Gambar 2.



(a)



(b)



(c)

Gambar 2. Time Series Plot Data Inflasi (a) Kota Surabaya (b) Kota Malang dan (c) Kota Kediri periode Januari 2010 sampai Desember 2016

Untuk melihat kecenderungan inflasi yang saling berkaitan dapat dilihat dari nilai korelasi antar lokasi. Nilai korelasi yang semakin kuat, artinya kecenderungan inflasi antar lokasi saling kuat berkaitan.

Tabel 2. Nilai Korelasi Data Inflasi Surabaya, Malang dan Kediri periode Januari 2010 sampai Desember 2016

Lokasi	Surabaya	Malang	Kediri
Surabaya	1		
<i>p-value</i>	0,000		
Malang	0,917	1	
<i>p-value</i>	0,000	0,000	
Kediri	0,873	0,895	1
<i>p-value</i>	0,000	0,000	0,000

Tabel 2 menjelaskan bahwa inflasi Surabaya, Malang dan Kediri untuk waktu yang bersesuaian memiliki korelasi yang signifikan, terlihat dari *p-value* yang lebih kecil dari $\alpha < 0,05$. Nilai korelasi yang lebih dari 0,80 artinya memiliki korelasi yang sangat kuat.

Berdasarkan *Box-Cox Transformation*, Secara umum, ketiga kota mempunyai batas bawah, batas atas, *rounded value* dan nilai lambda berbeda di masing-masing lokasi. Jika akan dilakukan transformasi, maka transformasi yang dipakai berbeda-beda sesuai dengan nilai lambda masing-masing lokasi. Oleh karena itu transformasi tidak perlu dilakukan dan data dianggap stasioner dalam varian.

Langkah selanjutnya melihat kestasioneran data dalam rata-rata menggunakan uji ADF. Hasil pengujian ADF dapat dilihat pada Tabel 3.

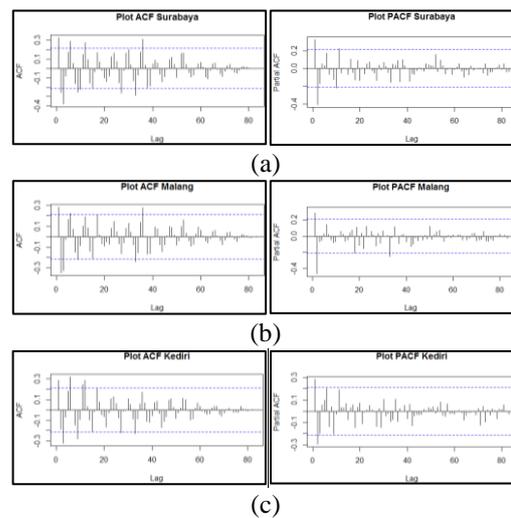
Tabel 3. Uji *Augmented Dickey-Fuller* (ADF) Data Inflasi Surabaya, Malang dan Kediri periode Januari 2010 sampai Desember 2016

Lokasi	(τ)	Keputusan	Kesimpulan
Surabaya	4,657	Menolak H_0	Data stasioner
Malang	4,549	Menolak H_0	Data stasioner
Kediri	4,227	Menolak H_0	Data stasioner

Tabel 3 menunjukkan bahwa keputusan untuk semua lokasi adalah menolak H_0 , sehingga kesimpulannya semua lokasi sudah stasioner dalam rata-rata. Oleh karena itu, pada analisis ini tidak dilakukan *differencing* karena data sudah stasioner dalam rata-rata.

Pemilihan Orde Model GSTARIMA

Pada model GSTARIMA orde spasial pada umumnya terbatas pada orde 1, karena untuk orde yang lebih tinggi akan sulit untuk diinterpretasikan. Pemilihan orde waktu dapat dilakukan dengan melihat plot ACF dan PACF untuk setiap lokasi seperti Gambar 3 berikut :



Gambar 3. Plot ACF dan PACF Data Inflasi (a) Kota Surabaya (b) Kota Malang dan (c) Kota Kediri periode Januari 2010 sampai Desember 2016

Gambar 3(a), 3(b) dan 3(c) mempunyai kesamaan pada plot ACF dan PACF yaitu menunjukkan pola *dies down* pada ACF dan pola *PACF cut off after lag 2*, sehingga model sementara yang mungkin adalah AR(1) dan AR(2). Kemudian mencari nilai AIC terkecil masing-masing lokasi berdasarkan model sementara :

Tabel 4. Nilai AIC Masing-masing Lokasi

Lokasi	Model	AIC
Surabaya	ARIMA(1,0,0)	124,430
	ARIMA(2,0,0)	108,480
Malang	ARIMA(1,0,0)	146,130
	ARIMA(2,0,0)	127,690
Kediri	ARIMA(1,0,0)	158,200
	ARIMA(2,0,0)	152,720

Berdasarkan Tabel 4, terlihat bahwa Surabaya yang memiliki nilai AIC terkecil yaitu 108,480. Hal ini menjadikan ARIMA (2,0,0) sebagai orde maksimum baik dari sisi *autoregressive*, *differencing*, maupun *moving average*. Model

ARIMA(2,0,0) untuk Surabaya inilah yang selanjutnya akan diterapkan pada model GSTARIMA. Berdasarkan hal tersebut, dipilih model GSTARIMA(2,0,0)1 yang digunakan pada data inflasi Kota Surabaya, Kota Malang dan Kota Kediri.

Berikut adalah persamaan untuk model GSTARIMA(2,0,0)1 :

$$Z(t) = \Phi_{10}^{(i)} Z(t-1) + \Phi_{20}^{(i)} Z(t-2) + \Phi_{11}^{(i)} W_{ij}^{(k)} Z(t-1) + \Phi_{21}^{(i)} W_{ij}^{(k)} Z(t-2) + e(t)$$

Pembentukan Matriks Pembobot Kebalikan Jarak

Nilai dari bobot kebalikan jarak diperoleh dari perhitungan berdasarkan jarak sebenarnya antar lokasi. Lokasi yang berdekatan mendapatkan nilai bobot yang lebih besar.

Tabel 5. Jarak Kota Surabaya, Malang dan Kediri

Lokasi	Jarak (km)
Surabaya-Malang	90 km
Surabaya-Kediri	120 km
Malang-Kediri	100 km

Setelah perhitungan pembobot kebalikan jarak, diperoleh matriks bobot kebalikan jarak sebagai berikut :

$$W = \begin{bmatrix} 0 & 0,571 & 0,429 \\ 0,526 & 0 & 0,474 \\ 0,455 & 0,545 & 0 \end{bmatrix}$$

Pembentukan Matriks Pembobot Normalisasi Korelasi Silang

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. Dalam GSTARIMA(2,0,0)1 korelasi silang yang digunakan adalah korelasi silang antar lokasi pada lag 2.

Setelah perhitungan pembobot normalisasi korelasi silang, diperoleh matriks bobot normalisasi korelasi silang sebagai berikut :

$$W = \begin{bmatrix} 0 & 0,531 & 0,469 \\ 0,521 & 0 & 0,478 \\ 0,487 & 0,513 & 0 \end{bmatrix}$$

Estimasi Parameter Model

Estimasi parameter model GSTAR dilakukan pada bobot lokasi dengan menggunakan metode kuadrat terkecil dengan cara meminimumkan

jumlah kuadrat simpangannya. Pada tahap identifikasi terbentuk model GSTARIMA(2,0,0)1 dengan bobot lokasi yang digunakan yaitu pembobot kebalikan jarak dan pembobot normalisasi korelasi silang.

Nilai semua parameter model GSTARIMA(2,0,0)1 dengan pembobot kebalikan jarak dan pembobot normalisasi korelasi silang yang diestimasi menghasilkan 12 parameter yang disajikan pada Tabel 6.

Tabel 6. Hasil Estimasi Parameter Model GSTARIMA(2,0,0)1 dengan Bobot Kebalikan Jarak dan Bobot Normalisasi Korelasi Silang

Statistik	Pembobot	
	Kebalikan Jarak	Normalisasi Korelasi Silang
$\hat{\phi}_{10}^{(1)}$	0,312	0,077
$\hat{\phi}_{10}^{(2)}$	0,409	0,134
$\hat{\phi}_{10}^{(3)}$	0,324	0,316
$\hat{\phi}_{20}^{(1)}$	-0,457	-0,450
$\hat{\phi}_{20}^{(2)}$	0,053	0,057
$\hat{\phi}_{20}^{(3)}$	0,674	0,668
$\hat{\phi}_{11}^{(1)}$	-0,766	-0,762
$\hat{\phi}_{11}^{(2)}$	0,524	0,519
$\hat{\phi}_{11}^{(3)}$	0,011	0,024
$\hat{\phi}_{21}^{(1)}$	0,673	0,657
$\hat{\phi}_{21}^{(2)}$	0,044	0,037
$\hat{\phi}_{21}^{(3)}$	-0,333	-0,322

Pengujian Signifikansi Parameter Model

Pengujian signifikansi parameter untuk model GSTARIMA pada Kota Surabaya, Malang dan Kediri untuk pembobot kebalikan jarak dan pembobot normalisasi korelasi silang adalah sebagai berikut :

Pembobot Kebalikan Jarak

Pengujian signifikansi parameter model GSTARIMA(2,0,0)1 dengan pembobot kebalikan jarak dapat dilihat pada Tabel 7. Dengan daerah kritis menolak H_0 jika $|t_{hitung}| > 1,98932$. Berdasarkan Tabel 7 dapat dilihat bahwa semua $|t_{hitung}| > 1,98932$ maka diputuskan menolak H_0 . Kesimpulannya, parameter model untuk pembobot kebalikan jarak signifikan.

Tabel 7. Pengujian Signifikansi Parameter Model GSTARIMA(2,0,0)1 dengan Pembobot Kebalikan Jarak

Statistik	Taksiran	SE Taksiran	t hitung
$\hat{\phi}_{10}^{(1)}$	0,312	0,077	4,068
$\hat{\phi}_{20}^{(1)}$	-0,457	0,135	3,394
$\hat{\phi}_{20}^{(2)}$	0,053	0,079	0,662
$\hat{\phi}_{11}^{(1)}$	-0,766	0,080	9,525
$\hat{\phi}_{11}^{(2)}$	0,524	0,149	3,492
$\hat{\phi}_{11}^{(3)}$	0,011	0,079	0,144
$\hat{\phi}_{21}^{(1)}$	0,673	0,157	4,279
$\hat{\phi}_{21}^{(2)}$	0,044	0,080	0,549
$\hat{\phi}_{21}^{(3)}$	-0,333	0,158	2,108

Pembobot Normalisasi Korelasi Silang

Pengujian signifikansi parameter model GSTARIMA(2,0,0)1 dengan pembobot normalisasi korelasi silang dapat dilihat pada Tabel 8.

Tabel 8. Pengujian Signifikansi Parameter Model GSTARIMA(2,0,0)1 dengan Pembobot Normalisasi Korelasi Silang

Statistik	Taksiran	SE Taksiran	t hitung
$\hat{\phi}_{10}^{(1)}$	0,323	0,077	4,209
$\hat{\phi}_{20}^{(1)}$	-0,450	0,134	3,348
$\hat{\phi}_{20}^{(2)}$	0,057	0,079	0,719
$\hat{\phi}_{11}^{(1)}$	-0,762	0,080	9,470
$\hat{\phi}_{11}^{(2)}$	0,519	0,150	3,453
$\hat{\phi}_{11}^{(3)}$	0,024	0,079	0,301
$\hat{\phi}_{21}^{(1)}$	0,657	0,158	4,157
$\hat{\phi}_{21}^{(2)}$	0,037	0,080	0,466
$\hat{\phi}_{21}^{(3)}$	-0,322	0,158	2,031

Dengan daerah kritis menolak H_0 jika $|t_{hitung}| > 1,98932$. Berdasarkan Tabel 8 dapat dilihat bahwa semua $|t_{hitung}| > 1,98932$ maka diputuskan menolak H_0 . Kesimpulannya, parameter model untuk pembobot normalisasi korelasi silang signifikan.

Uji Asumsi White Noise

Hasil pengujian asumsi *white noise* meliputi uji kenormalan residual dan uji independensi

residual. Asumsi *white noise* diperlukan untuk menguji validitas dari model. Uji asumsi *white noise* untuk pembobot kebalikan jarak dan pembobot normalisasi korelasi silang untuk masing-masing lokasi disajikan pada Tabel 9.

Tabel 9. Hasil Pengujian Asumsi White Noise Model GSTARIMA(2,0,0)1

Pembobot	Variabel	White Noise	
		Kenormalan Residual	Independensi Residual
Kebalikan Jarak	Z_1	Memenuhi	Memenuhi
	Z_2	Memenuhi	Memenuhi
	Z_3	Memenuhi	Memenuhi
Normalisasi Korelasi Silang	Z_1	Memenuhi	Memenuhi
	Z_2	Memenuhi	Memenuhi
	Z_3	Memenuhi	Memenuhi

Berdasarkan Tabel 9 diperoleh bahwa model GSTARIMA(2,0,0)1 untuk pembobot kebalikan jarak dan normalisasi korelasi silang memenuhi asumsi *white noise*.

Pemilihan Model Terbaik

Perbandingan ketepatan ramalan untuk masing-masing model GSTARIMA(2,0,0)1 digunakan untuk menentukan bobot lokasi terbaik yang dapat dilihat dari nilai AIC terkecil yang dapat dilihat pada Tabel 10.

Tabel 10. Perbandingan Ketepatan Ramalan Model GSTARIMA(2,0,0)1 Antar Bobot Lokasi Berdasarkan Nilai AIC

Lokasi	AIC	
	Bobot Kebalikan Jarak	Bobot Normalisasi Korelasi Silang
Surabaya	133,094	133,458
Malang	150,731	150,868
Kediri	160,852	161,005
Rata-rata	148,226	148,443

Berdasarkan Tabel 10 dapat diketahui bahwa ketepatan ramalan model GSTARIMA(2,0,0)1 menggunakan dua bobot lokasi menghasilkan rata-rata nilai AIC sebesar 148,226 untuk pembobot kebalikan jarak dan 148,443 untuk pembobot normalisasi korelasi silang. Model GSTARIMA(2,0,0)1 dengan pembobot kebalikan jarak dipilih sebagai model terbaik dengan nilai AIC terkecil sebesar 148,226

Peramalan

Model yang digunakan untuk meramalkan inflasi Kota Surabaya, Malang dan Kediri periode Januari sampai Desember tahun 2017 adalah model GSTARIMA(2,0,0)1 dengan pembobot

kebalikan jarak, dengan persamaan model sebagai berikut :

1. Persamaan model untuk nilai inflasi Kota Surabaya

$$Z_1(t) = 0,312Z_1(t-1) + 0,233Z_2(t-1) + 0,175Z_3(t-1) + 0,324Z_1(t-2) - 0,261Z_2(t-2) - 0,196Z_3(t-2) + e_1(t) \quad (19)$$

2. Persamaan model untuk nilai inflasi Kota Malang

$$Z_2(t) = 0,354Z_1(t-1) + 0,319Z_3(t-1) + 0,276Z_1(t-2) - 0,766Z_2(t-2) + 0,248Z_3(t-2) + e_2(t) \quad (20)$$

3. Persamaan model untuk nilai inflasi Kota Kediri

$$Z_3(t) = 0,306Z_1(t-1) + 0,367Z_2(t-1) - 0,151Z_1(t-2) - 0,181Z_2(t-2) + e_3(t) \quad (21)$$

Hasil peramalan inflasi Kota Surabaya, Malang dan Kediri periode Januari sampai Desember tahun 2017 model GSTARIMA(2,0,0)1 dengan pembobot kebalikan jarak dapat dilihat pada Tabel 11.

Tabel 11. Peramalan Nilai Inflasi di Kota Surabaya, Malang dan Kediri periode Januari 2017 sampai Desember 2017

t	Bulan	Nilai Inflasi (%)		
		Surabaya	Malang	Kediri
85	Januari	0,236	0,171	0,263
86	Februari	0,119	-0,033	-0,054
87	Maret	-0,00006	0,024	-0,042
88	April	0,056	0,031	-0,003
89	Mei	0,026	-0,009	0,024
90	Juni	0,021	0,008	-0,009
91	Juli	0,013	0,025	0,007
92	Agustus	0,018	0,004	0,009
93	September	0,004	-0,005	0,0004
94	Oktober	0,003	0,005	-0,004
95	November	0,004	0,005	0,003
96	Desember	0,003	-0,002	0,002

Tabel 11 menunjukkan bahwa hasil peramalan nilai inflasi Kota Surabaya, Malang dan Kediri periode Januari-Desember 2017 mengalami penurunan. Berdasarkan hasil peramalan pada Tabel 11 didapat nilai akurasi menggunakan Mean Absolute Percentage Error (MAPE) sebesar 39,515%.

Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan, disimpulkan bahwa model terbaik untuk inflasi di Kota Surabaya, Malang dan Kediri adalah model GSTARIMA(2,0,0)1 dengan pembobot kebalikan jarak. Hasil peramalan ketiga kota mengikuti pola data aktual pada periode waktu yang sama. Hasil peramalan menunjukkan nilai-nilai yang fluktuatif setiap bulannya dengan nilai inflasi berada pada interval -0,00006% sampai 0,263%.

Daftar Pustaka

Aswi and Sukarna. (2006). *Analisis Deret Waktu dan Aplikasi*. Makassar: Andira Publisher.

Borovkova, SA., Lopuhaa, H.P., dan Ruchjana, B.N. (2002). Generalized STAR Model With Experimental Weights. Editor. *Proceedings of the 17th International Workshop on Statistical Modeling*.

Makridakis, S., Wheelwright, S.C., dan McGee, V.E. (1999). *Metode dan Aplikasi Peramalan*. Edisi Kedua Jilid I. Jakarta: Penerbit Erlangga.

Pfeifer P.E. and Deutsch S.J. (1980). A Three Stage Iterative Procedure For Space-Time Modeling. *Technometrics*. Vol. 22, No. 1.

Siegel, S. (1994). *Statistika Non Parametrik*. Jakarta: PT Gramedia Pustaka.

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. (2004). *Makroekonomi Teori Pengantar*. Edisi Ketiga. Jakarta : Rajawali Pers.

Wei, W.S.S. (2006). *Time series Analysis: Univariate and Multivariate Methods*. New York (US), Boston: Addison-Wesley Publishing Co.

Widarjono, A. (2007). *Ekonometrika: Teori dan Aplikasi untuk Ekonomi dan Bisnis*. Edisi Kedua. Yogyakarta: Ekonisia Fakultas Ekonomi UII.

Wutsqa, D.U., Suhartono, Sutijo, B. (2010). Generalized Space-Time Autoregressive Modeling. *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and its Applications (ICMSA 2010)*; Kuala Lumpur, Malaysia.