

Penerapan Model *Generalized Space Time Autoregressive (GSTAR)* pada Data Inflasi Beberapa Kota

Ulfa Putri Rahmani^{1*}, Khoirin Nisa², Nurmaita Hamsyiah³

^{1,2}Jurusan Matematika, Universitas Lampung, Indonesia

³Program Studi Matematika, Fakultas Sains, UIN Sultan Maulana Hasanuddin, Banten, Indonesia

*corresponding author: ulfaput16@gmail.com

Received November 26, 2024; Received in revised form January 01, 2025; Accepted January 05, 2025

Abstrak. Model yang umum digunakan untuk data space time adalah model Vector autoregressive (VAR), Space Time Autoregressive (STAR), dan Generalized Space Time Autoregressive (GSTAR). Untuk lokasi yang memiliki karakteristik yang berbeda (heterogen), model GSTAR lebih baik digunakan dibandingkan model STAR. Tujuan dari penelitian ini adalah menerapkan model GSTAR pada data time series dari tiga lokasi berbeda. Data yang digunakan pada penelitian ini adalah data inflasi Palembang, Bandar Lampung, dan DKI Jakarta bulan Januari 2012 hingga Juni 2019. Bobot Lokasi yang digunakan adalah bobot lokasi invers jarak dan bobot lokasi normalisasi korelasi silang. Pada penelitian ini pendugaan parameter dilakukan dengan metode Generalized Least Square (GLS). Dari hasil analisis diperoleh model yang terbaik adalah model GSTAR(11) dengan bobot lokasi invers jarak karena memiliki rata-rata RMSE terkecil yaitu 0.467767.

Kata kunci: GSTAR; inflasi; *space time*; STAR; VAR

Abstract The models commonly used for space time data are the Vector autoregressive (VAR), Space Time Autoregressive (STAR), and Generalized Space Time Autoregressive (GSTAR) models. For locations that have different (heterogeneous) characteristics, the GSTAR model is better to use than the STAR model. The aim of this research is to apply the GSTAR model to time series data from three different locations. The data used in this research is inflation data from Palembang, Bandar Lampung, and DKI Jakarta from January 2012 to June 2019. The location weights used are distance inverse location weights and cross-correlation normalized location weights. In this research, parameter estimation was carried out using the Generalized Least Square (GLS) method. From the analysis results, it was found that the best model was the GSTAR(11) model with inverse distance location weights because it had the smallest average RMSE, namely 0.467767.

Keywords: GSTAR; inflation; *spacetime*; STAR; VAR



This is an open access article under the [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/)

PENDAHULUAN

Pada dasarnya setiap data yang diperoleh dari pengamatan berkaitan dengan waktu pengamatannya. Saat pengaruh variabel waktu dengan pengamatan di perhatikan, dimana data dianggap sebagai fungsi dari waktu, maka inilah yang disebut data *time series* atau deret waktu. Secara garis besar, deret waktu dapat dibagi menjadi deret waktu univariat dan deret waktu multivariat. Pada deret waktu univariat, hanya terdapat satu variabel pengamatan sedangkan pada deret waktu multivariat terdapat dua atau lebih variabel pengamatan. Dalam beberapa kasus, kebanyakan data *time series* multivariat juga dipengaruhi oleh faktor lokasi. Menurut Ruiz et al. (2021), data deret waktu dari beberapa lokasi yang berdekatan seringkali mempunyai hubungan yang saling bergantung. Data yang demikian, kemudian disebut dengan data *space time*.

Metode klasik yang umum digunakan untuk data *space time* adalah metode *Vector Autoregressive* (VAR). Meskipun VAR bersifat fleksibel, namun banyak parameter yang tidak diketahui yang harus diestimasi dengan data terbatas. Oleh sebab itu, Ord (2010) memperkenalkan metode yang disebut *Space Time Autoregressive* (STAR). Borovkova et al. (2002) yang pertama kali memperkenalkan model *Generalized Space Time Autoregressive* (GSTAR). GSTAR merupakan pengembangan dari model STAR dengan parameter autoregresif yang berbeda untuk setiap lokasi (Al Amri, 2020; Imro'ah, 2023). Parameter model yang berbeda pada setiap lokasi menyebabkan model GSTAR lebih fleksibel dibandingkan model STAR saat digunakan pada lokasi yang heterogen (Fransiska et al., 2020).

Model GSTAR dapat di representasikan sebagai suatu model linier dan parameter autoregresifnya dapat diduga dengan metode kuadrat terkecil (*Ordinary Least Square*) (Hestuningtias & Kurniawan, 2023; Mukhaiyar & Ramadhani, 2022). Mengingat pada metode kuadrat terkecil terdapat asumsi yang ketat untuk dipenuhi sebagai syaratnya, sementara dalam data deret waktu multivariat kemungkinan terdapat asumsi yang tidak terpenuhi, maka metode kuadrat terkecil tidak efisien digunakan untuk menduga parameter GSTAR. Menurut Iriany et al. (2021), metode OLS untuk estimasi parameter model kurang sesuai apabila digunakan pada model dengan respon multivariat dan residual yang saling berkorelasi seperti pada model GSTAR. Hasil kajian yang dilakukan oleh Arum et al. (2024) diperoleh estimator parameter GSTAR dengan metode GLS yang lebih efisien dari pada OLS dan ditunjukkan ketidakbiasan estimatornya. Oleh sebab itu, pada penelitian ini digunakan metode GLS untuk menduga parameter autoregresif model GSTAR.

Model *generalized STAR* (GSTAR) adalah pengembangan model STAR (*Space Time Autoregressive*), memungkinkan parameter autoregresif bervariasi pada setiap lokasi: $\phi_{kl}^{(i)}$, $i = 1, 2, \dots, N$. Jika diketahui sebuah deret $\{Z(t) : t = 0, \pm 1, \pm 2, \dots, \pm T\}$ merupakan sebuah deret waktu multivariate dari N variabel, maka model GSTAR dari orde autoregresif (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 berikut:

$$z_t = \sum_{k=1}^p \left[\Phi_{k0} z(t - k) + \sum_{l=1}^{\lambda_p} \Phi_{kl} W^{(l)} z(t - k) \right] + e(t) \tag{1}$$

dengan

- z_t = vektor pengamatan pada waktu ke- t lokasi ke- n ($N \times 1$)
- Φ_{k0} = matriks diagonal parameter autoregresif orde waktu ke- k dan orde ruang ke-0
- Φ_{kl} = matriks diagonal parameter autoregresif orde waktu ke- k dan orde ruang ke- l
- $W^{(l)}$ = matriks pembobot ($N \times N$) untuk lag spasial/ruang $l = 0, 1, \dots, \lambda_p$

$e(t)$ = vektor *noise* ukuran $(N \times 1)$ yang independen, identik, berdistribusi normal multivariat dengan mean nol dan matriks varians-kovarians $\sigma^2 I_N$

Nilai pembobot dipilih sedemikian sehingga memenuhi syarat $w_{ii}^{(k)} = 0$ dan $\sum_{j \neq i} w_{ij}^{(k)} = 1$. Dalam mengidentifikasi orde model GSTAR, orde spasial pada umumnya dibatasi pada orde satu karena orde yang lebih tinggi akan sulit untuk diinterpretasikan (Hestuningtias & Kurniawan, 2023). Sedangkan untuk orde waktu (*autoregressive*) dapat ditentukan dengan menggunakan AIC (Zhao et al., 2022).

Bobot yang paling umum digunakan adalah pembobotan berdasarkan invers dari jarak *Euclidean* atau garis lurus antar lokasi. Menurut Rompon et al. (2023), jika diberikan dua lokasi dengan koordinat (x_i, y_i) dan (x_j, y_j) , maka jarak *Euclidean* antar lokasi tersebut adalah:

$$d_{i,j} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \tag{2}$$

Menurut Bi et al. (2024), invers dari jarak *euclidean* antar lokasi adalah $c(1 + d_{i,j})^{-a}$, dimana $d_{i,j}$ merupakan jarak lokasi i ke j , dan c, a sembarang konstanta positif. Selanjutnya penentuan bobot invers jarak dapat dilakukan dengan normalisasi nilai-nilai invers dari jarak *euclidean* antar lokasi, sehingga diperoleh persamaan untuk bobot invers jarak sebagai berikut:

$$w_{ij} = \frac{c(1+d_{i,j})^{-a}}{\sum_{j \neq i} c(1+d_{i,j})^{-a}} \tag{3}$$

dimana $i \neq j$, dan memenuhi $\sum_{j \neq i} w_{ij} = 1$.

Taksiran dari korelasi silang ini pada data sampel adalah sebagai berikut:

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [Z_i(t) - \bar{Z}_i][Z_j(t-k) - \bar{Z}_j]}{\sqrt{(\sum_{t=1}^n [Z_i(t) - \bar{Z}_i]^2 \sum_{t=1}^n [Z_j(t) - \bar{Z}_j]^2)}} \tag{5}$$

Selanjutnya, bobot lokasi ditentukan dengan normalisasi besaran-besaran korelasi silang antar lokasi bersesuaian tersebut.

Bobot berdasarkan pada normalisasi korelasi silang antar lokasi pada lag waktu yang bersesuaian untuk model GSTAR dirumuskan sebagai berikut:

$$w_{ij} = \frac{r_{ij}(1)}{\sum_{j \neq i} |r_{ij}(1)|} \tag{6}$$

dimana $i \neq j$, dan memenuhi $\sum_{j \neq i} |w_{ij}| = 1$.

Pendugaan Parameter GSTAR menggunakan Metode *Generalized Least Square* (GLS). Estimator GLS untuk parameter model GSTAR adalah sebagai berikut:

$$\hat{\Phi} = (Z^{*T} \Omega^{-1} Z^*)^{-1} Z^{*T} \Omega^{-1} Z \tag{7}$$

dengan $z = z_i(t)$, $Z^* = [z_i(t-k) \mathbf{V}_i(t-k)]$, $\Phi = \begin{pmatrix} \phi_{k0}^{(i)} \\ \phi_{kl}^{(i)} \end{pmatrix}$, dan Ω adalah matriks kovarian residual yang diperoleh dari estimasi dengan metode OLS. Cara yang sama juga digunakan pada pendugaan parameter STAR.

Pada pengujian residual, akan diperiksa asumsi *white noise* residual. Suatu proses $\{\varepsilon_t\}$ dikatakan sebagai proses *white noise* jika $\{\varepsilon_t\}$ adalah barisan peubah acak yang tidak berkorelasi dengan *mean* $E(\varepsilon_t) = \mu_\alpha = 0$, varians konstan $Var(\varepsilon_t) = \sigma_\varepsilon^2$ dan $\gamma_k =$

$Cov(\varepsilon_t, \varepsilon_{t+k}) = 0$ untuk semua $k \neq 0$. Oleh karena itu, suatu proses *white noise* $\{\varepsilon_t\}$ adalah stasioner dengan fungsi autokovariansi (Woodward et al., 2020).

$$\gamma_k = \begin{cases} \sigma_\varepsilon^2, & \text{jika } k = 0 \\ 0, & \text{jika } k \neq 0 \end{cases}$$

fungsi autokorelasi

$$\rho_k = \begin{cases} 1, & \text{jika } k = 0 \\ 0, & \text{jika } k \neq 0 \end{cases}$$

fungsi autokorelasi parsial

$$\phi_{kk} = \begin{cases} 1, & \text{jika } k = 0 \\ 0, & \text{jika } k \neq 0 \end{cases}$$

White noise digunakan untuk menjelaskan bahwa suatu data memiliki residual dengan perilaku acak dan stasioner. *White noise* dinotasikan dengan $\{\varepsilon_t\} \sim WN(0, \sigma_\varepsilon^2)$. Residual dikatakan *white noise* apabila memenuhi asumsi normalitas residual, homoskedastisitas, dan tidak ada autokorelasi residual.

METODE PENELITIAN

Data yang digunakan pada penelitian ini adalah data sekunder, yaitu data inflasi bulanan di Kota Bandar Lampung, Palembang, dan DKI Jakarta dari Januari 2012 hingga Juni 2019 yang diperoleh dari website Badan Pusat Statistika (BPS) Indonesia (<https://bps.go.id/site/resultTab>).

Analisis pada penelitian ini dilakukan dengan bantuan *software* SAS 9.4. Berikut adalah tahapan analisis dari penelitian ini.

1. Eksplorasi data
Melakukan eksplorasi data dengan melihat plot data untuk melihat gambaran secara umum tentang statistik deskriptif data inflasi Kota Bandar Lampung, Palembang, dan DKI Jakarta.
2. Menghitung koefisien korelasi antar lokasi
Besaran dari koefisien korelasi menjadi identifikasi keeratan dan arah hubungan inflasi satu lokasi dengan lokasi lainnya.
3. Pembagian data
Data dibagi mejadi dua bagian yaitu, data *in-sample* dan data *out-sample*. Data *in-sample* digunakan untuk pendugaan model dan data *out-sample* untuk validasi model.
4. Memeriksa kestasioneran data inflasi *in-sample* Kota Bandar Lampung, Palembang, dan DKI Jakarta. Apabila data tidak stasioner maka akan dilakukan *differencing*. Kestasioneran data akan dilihat melalui plot MACF dan MPACF serta uji ADF.
5. Membentuk model STAR dan GSTAR dengan langkah-langkah sebagai berikut ini:
 - a. Menentukan orde waktu dari model STAR dan GSTAR yang sesuai berdasarkan hasil identifikasi pada model VAR. Identifikasi Model VAR dilakukan dengan melihat nilai AIC yang paling kecil.
 - b. Menetapkan nilai bobot invers jarak dan normalisasi korelasi silang.
 - c. Melakukan penaksiran parameter dari model STAR dan GSTAR dengan metode GLS.
 - d. Menguji residual model STAR dan GSTAR. Pengujian residual model STAR dan GSTAR yang harus dipenuhi adalah asumsi *white noise*.
6. Menghitung RMSE untuk memilih model terbaik.

HASIL DAN PEMBAHASAN

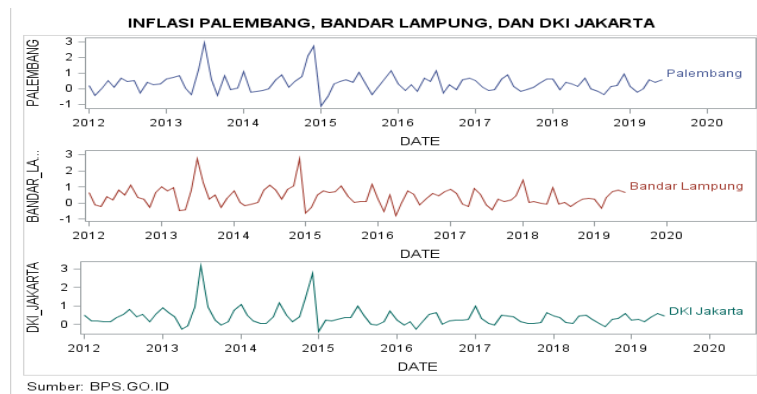
Eksplorasi Data

Sebelum melakukan analisis terhadap data inflasi Palembang, Bandar Lampung dan DKI Jakarta, dilakukan eksplorasi data terlebih dahulu. Eksplorasi data dilakukan untuk melihat gambaran secara umum tentang statistik deskriptif data inflasi ketiga kota tersebut dari Januari 2012 hingga Juni 2019. Gambaran umum dari data inflasi Palembang, Bandar Lampung dan DKI Jakarta dari Januari 2012 hingga Juni 2019 dapat dilihat pada Tabel 1.

Tabel 1. Statistika Deskriptif Data Inflasi Palembang, Bandar Lampung dan DKI Jakarta dari Januari 2012 hingga Juni 2019

Lokasi	N	Mean	Simpangan Baku	Min	Maks
Palembang	90	0.34778	0.60519	-1.15	2.92
Bandar Lampung	90	0.39233	0.58735	-0.76	2.75
DKI Jakarta	90	0.39400	0.50623	-0.41	3.16

Dari Tabel 1. dapat dilihat bahwa data yang digunakan pada penelitian ini adalah sebanyak 90 data untuk setiap lokasi. Data inflasi Palembang pada Januari 2012 hingga Juni 2019 memiliki nilai tengah atau rata-rata yang terkecil dibandingkan dua kota lainnya yaitu sebesar 0.34778 namun memiliki simpangan baku yang terbesar yaitu sebesar 0.60519. Sedangkan data inflasi DKI Jakarta memiliki mean terbesar dibandingkan dua kota lain yaitu 0.394, namun simpangan baku data inflasi DKI Jakarta merupakan yang terkecil yaitu sebesar 0.50623. Ditinjau dari nilai simpangan baku, data inflasi Palembang memiliki tingkat keragaman yang paling tinggi dibandingkan kota Bandar Lampung dan DKI Jakarta, sebaliknya DKI Jakarta memiliki tingkat keragaman yang terendah dibandingkan kota Palembang dan kota Bandar Lampung. Nilai inflasi terendah dari Palembang dan DKI Jakarta terjadi pada Januari 2015 yaitu masing-masing sebesar -1.15 dan -0.41. Nilai inflasi terendah kota Bandar Lampung adalah -0.76 yang terjadi pada bulan April 2016. Nilai inflasi tertinggi dari kota Palembang, Bandar Lampung, dan DKI Jakarta terjadi pada bulan Juli 2013 yang masing-masing bernilai 2.92, 2.75, dan 3.16. Berikut plot deret waktu inflasi di Palembang ditunjukkan pada Gambar 1.



Gambar 1. Plot deret waktu data inflasi Palembang, Bandar Lampung dan DKI Jakarta Januari 2009 hingga Juni 2019.

Pada Gambar 1. ditinjau pula plot deret waktu data inflasi Palembang, Bandar Lampung dan DKI Jakarta dari tahun 2012 hingga 2019 seperti yang terlihat pada Gambar 1. Dari plot deret waktu data inflasi Palembang, Bandar Lampung dan DKI Jakarta dari bulan Januari 2012 hingga Juni 2019 dapat dilihat bahwa ketiga data memiliki pola yang sama. Kesamaan pola mengindikasikan bahwa data inflasi Palembang, Bandar Lampung dan DKI Jakarta dari Januari 2009 hingga Juni 2019 kemungkinan memiliki keterkaitan satu sama lain.

Koefisien Korelasi Silang Data Inflasi Palembang, Bandar Lampung dan DKI Jakarta

Koefisien korelasi silang dari data inflasi ketiga kota digunakan untuk melihat keeratan hubungan linier antara inflasi Palembang, Bandar Lampung dan DKI Jakarta. Korelasi silang dari data inflasi Palembang, Bandar Lampung dan DKI Jakarta dapat dilihat pada Tabel 2.

Tabel 2. Nilai Korelasi Silang Data Inflasi antar Lokasi

Korelasi Silang			
Lokasi	Palembang	Bandar Lampung	DKI Jakarta
Palembang	1.00000	0.83235	0.83114
Bandar Lampung	0.83235	1.00000	0.84417
DKI Jakarta	0.83114	0.84417	1.00000

Tabel 2. menunjukkan bahwa nilai koefisien korelasi antar lokasi mendekati 1 dan bernilai positif. Nilai koefisien korelasi yang tinggi menunjukkan bahwa data inflasi ketiga kota tersebut memiliki keterkaitan yang besar satu sama lain. Hal inilah yang mendasari digunakannya pemodelan multivariat dengan model GSTAR.

Pembagian Data

Data inflasi kota Palembang, Bandar Lampung, dan DKI Jakarta yang digunakan pada penelitian ini ada sebanyak 90 data, yang kemudian dibagi menjadi 2 bagian yaitu :

- i) Data *in-sample* (pemodelan): data inflasi bulan Januari 2012 - Desember 2018 (84 data)
- ii) Data *out-sample* (validasi) : data inflasi bulan Januari 2019 - Juni 2019 (6 data).

Variabel-variabel yang digunakan pada penelitian ini adalah sebagai berikut:

- $Z_1(t)$: inflasi kota Palembang pada waktu t
- $Z_2(t)$: inflasi kota Bandar Lampung pada waktu t
- $Z_3(t)$: inflasi DKI Jakarta pada waktu t.

Stasioneritas Data Inflasi Kota Palembang, Bandar Lampung, dan DKI Jakarta

Stasioneritas data inflasi Kota Palembang, Bandar Lampung, dan DKI Jakarta dapat dilihat dari tabel MACF dan MPACF pada Tabel 3. dan Tabel 4.

Tabel 3. MACF untuk Ketiga Series

Variabel/Lag	0	1	2	3	4	5	6	7	8	9	10
Palembang	+++	.++	-.	..--	..-
Bandar Lampung	+++-	..-+-	---	...
DKI Jakarta	+++	.++	..-	..-+	..+

+ is > 2*std error, - is < -2*std error, . is between

Tabel 4. MPACF untuk Ketiga Series

Variabel/Lag	1	2	3	4	5	6	7	8	9	10
Palembang
Bandar Lampung-
DKI Jakarta	..++	---+

+ is > 2*std error, - is < -2*std error, . is between

Dari Tabel 3. dan Tabel 4. terlihat bahwa beberapa nilai korelasi bernilai lebih dari 2 kali standar error (korelasi positif) atau kurang dari -2 kali standar error (korelasi negatif) dan terjadi hanya pada lag-lag tertentu. Selebihnya nilai korelasi menunjukkan tanda titik (.) yang berarti secara simultan ketiga variabel tidak memiliki korelasi, sehingga data inflasi ketiga kota dapat dikatakan telah stasioner terhadap mean.

Selain dengan melihat tabel MACF, uji stasioneritas selanjutnya dilakukan dengan uji *Augmented Dickey-Fuller* (ADF). Uji ini melihat apakah terdapat *unit root* di dalam model atau tidak. Hipotesis yang digunakan pada uji ADF adalah:

H_0 : $\delta = 0$, terdapat akar unit atau data tidak stasioner

H_1 : $\delta < 0$, tidak terdapat akar unit atau data stasioner.

Kriteria keputusannya adalah tolak H_0 jika nilai mutlak dari statistik tau lebih dari nilai kritis McKinnon atau $p\text{-value} < \alpha$, dengan taraf signifikansi yang digunakan adalah $\alpha = 0.05$. Tabel 5. menunjukkan output SAS 9.4 untuk uji stasioneritas dengan *Augmented Dickey-Fuller* (ADF).

Tabel 5. Uji *Augmented Dickey-Fuller* (ADF)

Variabel	Rho	Pr < Rho	Tau	Pr < Tau
Palembang	-64.99	<.0001	-5.56	<.0001
Bandar Lampung	-48.43	<.0001	-4.86	<.0001
DKI Jakarta	-43.61	<.0001	-4.58	<.0001

Berdasarkan Tabel 5. dapat dilihat bahwa nilai $p\text{-value}$ untuk ketiga variabel lebih kecil dari $\alpha = 0.05$ sehingga keputusan yang diambil adalah menolak H_0 , yang artinya tidak terdapat akar unit atau data stasioner.

Pembentukan Model STAR dan GSTAR

Penentuan Orde Model

Orde waktu pada model STAR dan GSTAR diperoleh dengan mengidentifikasi orde model VAR. Menurut Yilmaz (2023), nilai AIC terkecil merupakan pemilihan optimum yang digunakan untuk penentuan orde model VAR. AIC yang baik menghasilkan model yang memberikan tingkat galat yang kecil. Tabel 6. menunjukkan ringkasan nilai AIC dari model *autoregressive* (AR) dan *moving average* (MA) hingga lag ke-5.

Tabel 6. Ringkasan Nilai AIC

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	-5.511817	-5.456161	-5.386247	-5.21528	-5.093599	-4.941086
AR 1	-5.84948	-5.817512	-5.705429	-5.573926	-5.462826	-5.2834
AR 2	-5.749069	-5.640955	-5.543538	-5.395286	-5.258763	-5.088137
AR 3	-5.544377	-5.551624	-5.397488	-5.282272	-5.109899	-4.872254
AR 4	-5.505693	-5.537959	-5.29531	-5.150386	-4.756092	-4.520437
AR 5	-5.304145	-5.270115	-5.034081	-4.85184	-4.537308	-4.174303

Berdasarkan Tabel 6. nilai AIC yang terkecil adalah -5.84948 yang berada pada AR(1) dan MA(0), sehingga model yang terbaik adalah VAR(1). Berdasarkan orde waktu model VAR yang terpilih, maka orde waktu model GSTAR juga $p = 1$. Orde spasial model pada penelitian ini dibatasi pada orde satu karena orde yang lebih tinggi akan sulit untuk diinterpretasikan. Dengan demikian orde waktu dan orde spasial yang digunakan untuk model GSTAR pada penelitian ini adalah 1, sehingga model GSTAR yang terbentuk adalah GSTAR(1₁). Begitu pula dengan model STAR yang terpilih adalah model STAR(1₁).

Pembentukan Matriks Bobot Lokasi

Perhitungan Nilai Bobot Invers Jarak

Pembobotan yang pertama yaitu berdasarkan invers dari jarak *euclidean* atau garis lurus antar lokasi. Invers dari jarak *euclidean* antar lokasi adalah $c(1 + d_{i,j})^{-a}$, dimana $d_{i,j}$ merupakan jarak lokasi i ke j , dan c, a sembarang konstanta positif. Untuk mempermudah perhitungan, nilai c, a yang digunakan adalah 1, sehingga invers jarak antar lokasi menjadi $(1 + d_{i,j})^{-1}$.

Sehingga diperoleh persamaan untuk bobot invers jarak sebagai berikut:

$$w_{ij} = \frac{(1 + d_{i,j})^{-1}}{\sum_{j \neq i} (1 + d_{i,j})^{-1}}$$

dimana $i \neq j$, dan memenuhi $\sum_{j \neq i} w_{ij} = 1$. Jarak antar lokasi ditunjukkan oleh Tabel 7. (sumber: Google Map):

Tabel 7. Jarak Ketiga Kota

Lokasi	Jarak (km)
Palembang – Bandar Lampung ($d_{1,2} = d_{2,1}$)	278
Palembang – Jakarta ($d_{1,3} = d_{3,1}$)	422
Bandar Lampung – Jakarta ($d_{2,3} = d_{3,2}$)	191

Sehingga diperoleh matriks pembobot invers jarak yang terbentuk adalah sebagai berikut:

$$W = \begin{pmatrix} 0 & 0.6 & 0.4 \\ 0.41 & 0 & 0.59 \\ 0.32 & 0.68 & 0 \end{pmatrix}$$

Perhitungan Nilai Bobot Normalisasi Korelasi Silang

Pembobotan dengan metode ini didasarkan pada korelasi silang antar variabel pada waktu yang bersesuaian. Berikut ini contoh perhitungan nilai bobot normalisasi korelasi silang pada penelitian ini.

$$w_{12} = \frac{r_{12}(1)}{|r_{12}(1) + r_{13}(1)|}$$

dimana $i \neq j$, dan memenuhi $\sum_{j \neq i} |w_{ij}| = 1$.

Matriks di bawah ini adalah matriks nilai korelasi silang antar variabel pada data inflasi kota Palembang, Bandar Lampung, dan DKI Jakarta pada lag waktu yang bersesuaian (lag 1):

$$\rho = \begin{pmatrix} 0.12880 & 0.05709 & 0.02982 \\ 0.26486 & 0.20601 & 0.26474 \\ 0.30617 & 0.24455 & 0.30942 \end{pmatrix}$$

Sehingga diperoleh matriks bobot lokasi sebagai berikut:

$$W = \begin{pmatrix} 0 & 0.66 & 0.34 \\ 0.5 & 0 & 0.5 \\ 0.56 & 0.44 & 0 \end{pmatrix}$$

Pendugaan Parameter Model STAR dan GSTAR

Pendugaan Parameter Model STAR dengan Bobot Invers Jarak

Hasil estimasi parameter model STAR(1₁) dengan bobot invers jarak menggunakan metode GLS ditunjukkan pada Tabel 8.

Tabel 8. Estimasi Parameter STAR(1₁) dengan Bobot Invers Jarak

Parameter	Nilai Estimasi	Standard Error	t hitung	Pr > t
ϕ_{10}	0.27582	0.0589	4.68	<.0001
ϕ_{11}	0.318323	0.0661	4.81	<.0001

Model STAR(1₁) dengan bobot invers jarak yang terbentuk dalam bentuk matriks yaitu:

$$\begin{pmatrix} \hat{z}_1(t) \\ \hat{z}_2(t) \\ \hat{z}_3(t) \end{pmatrix} = (0.27582) \begin{pmatrix} z_1(t-1) \\ z_2(t-1) \\ z_3(t-1) \end{pmatrix} + (0.318323) \begin{pmatrix} 0 & 0.6 & 0.4 \\ 0.41 & 0 & 0.59 \\ 0.32 & 0.68 & 0 \end{pmatrix} \begin{pmatrix} z_1(t-1) \\ z_2(t-1) \\ z_3(t-1) \end{pmatrix}$$

Berdasarkan matriks di atas, diperoleh model STAR(1₁) dengan bobot invers jarak menggunakan metode GLS untuk data inflasi masing-masing lokasi yaitu:

- a. Model STAR(1₁) dengan bobot invers jarak untuk inflasi kota Palembang
 $\hat{z}_1(t) = 0.27582 z_1(t-1) + 0.19 z_2(t-1) + 0.127 z_3(t-1)$
- b. Model STAR(1₁) dengan bobot invers jarak untuk inflasi kota Bandar Lampung
 $\hat{z}_2(t) = 0.27582 z_2(t-1) + 0.13 z_1(t-1) + 0.188 z_3(t-1)$
- c. Model STAR(1₁) dengan bobot invers jarak untuk inflasi DKI Jakarta
 $\hat{z}_3(t) = 0.27582 z_3(t-1) + 0.102 z_1(t-1) + 0.216 z_2(t-1)$.

Pendugaan Parameter Model STAR dengan Bobot Normalisasi Korelasi Silang

Hasil estimasi Parameter Model STAR(1₁) dengan bobot normalisasi korelasi silang menggunakan metode GLS dapat dilihat pada Tabel 9.

Tabel 9. Estimasi Parameter STAR(1₁) dengan Bobot Normalisasi Korelasi Silang

Parameter	Nilai Taksiran	Standard Error	t hitung	Pr > t
ϕ ₁₀	0.281831	0.0587	4.80	<.0001
ϕ ₁₁	0.327191	0.0675	4.85	<.0001

Berdasarkan Tabel 9. dapat dibentuk matriks untuk model STAR(1₁) dengan bobot normalisasi korelasi silang sebagai berikut:

$$\begin{pmatrix} \hat{z}_1(t) \\ \hat{z}_2(t) \\ \hat{z}_3(t) \end{pmatrix} = (0.281831) \begin{pmatrix} z_1(t-1) \\ z_2(t-1) \\ z_3(t-1) \end{pmatrix} + (0.327191) \begin{pmatrix} 0 & 0.66 & 0.34 \\ 0.5 & 0 & 0.5 \\ 0.56 & 0.44 & 0 \end{pmatrix} \begin{pmatrix} z_1(t-1) \\ z_2(t-1) \\ z_3(t-1) \end{pmatrix}$$

Berdasarkan matriks di atas, diperoleh model STAR(1₁) untuk data inflasi masing-masing lokasi yaitu:

- a. Model STAR(1₁) dengan bobot normalisasi korelasi silang untuk inflasi kota Palembang
 $\hat{z}_1(t) = 0.281831 z_1(t-1) + 0.216 z_2(t-1) + 0.111 z_3(t-1)$
- b. Model STAR(1₁) dengan bobot normalisasi korelasi silang untuk inflasi kota Bandar Lampung
 $\hat{z}_2(t) = 0.281831 z_2(t-1) + 0.164 z_1(t-1) + 0.164 z_3(t-1)$
- c. Model STAR(1₁) dengan bobot normalisasi korelasi silang untuk inflasi DKI Jakarta
 $\hat{z}_3(t) = 0.281831 z_3(t-1) + 0.183 z_1(t-1) + 0.144 z_2(t-1).$

Pendugaan Parameter Model GSTAR dengan Bobot Invers Jarak

Berikut output hasil pendugaan parameter autoregresif model GSTAR(1₁) dengan bobot lokasi normalisasi korelasi silang menggunakan metode GLS dapat dilihat pada Tabel 10.

Tabel 10. Estimasi Parameter GSTAR(1₁) dengan Bobot Invers Jarak

Parameter	Estimasi	Standard Error	t hitung	Pr > t	Parameter	Estimasi	Standard Error	t hitung	Pr > t
ϕ ₁₀ ⁽¹⁾	0.179282	0.1140	1.57	0.1196	ϕ ₁₁ ⁽¹⁾	0.248155	0.1354	1.83	0.0705
ϕ ₁₀ ⁽²⁾	0.068892	0.1282	0.54	0.5924	ϕ ₁₁ ⁽²⁾	0.58633	0.1570	3.73	0.0003
ϕ ₁₀ ⁽³⁾	0.467432	0.1058	4.42	<.0001	ϕ ₁₁ ⁽³⁾	0.156756	0.0986	1.59	0.1158

Dari Tabel 10. pendugaan parameter model GSTAR(1₁) dengan bobot invers jarak di atas, dapat dilihat bahwa ada beberapa parameter yang tidak signifikan pada taraf nyata α = 0.05 yaitu parameter ϕ₁₀⁽¹⁾, ϕ₁₀⁽²⁾, ϕ₁₁⁽¹⁾, dan ϕ₁₁⁽³⁾. Oleh sebab itu, dilakukan seleksi dengan metode *backward* yaitu mengeliminasi parameter yang tidak signifikan secara bertahap (satu per satu).

Tabel 11. Estimasi Parameter GSTAR(1₁) dengan Bobot Invers Jarak (*Backward Selection*)

Parameter	Estimasi	Standard Error	t hitung	Pr > t
$\phi_{10}^{(1)}$	0.279561	0.0834	3.35	0.0012
$\phi_{10}^{(3)}$	0.539482	0.0684	7.89	<.0001
$\phi_{11}^{(2)}$	0.533543	0.0919	5.80	<.0001

Dari parameter-parameter yang signifikan Tabel 11. matriks model GSTAR(1₁) dengan bobot invers jarak menggunakan metode GLS adalah:

$$\begin{pmatrix} \hat{z}_1(t) \\ \hat{z}_2(t) \\ \hat{z}_3(t) \end{pmatrix} = \begin{pmatrix} 0.279561 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0.539482 \end{pmatrix} \begin{pmatrix} z_1(t-1) \\ z_2(t-1) \\ z_3(t-1) \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0.533543 & 0 \\ 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} 0 & 0.6 & 0.4 \\ 0.41 & 0 & 0.59 \\ 0.32 & 0.68 & 0 \end{pmatrix} \begin{pmatrix} z_1(t-1) \\ z_2(t-1) \\ z_3(t-1) \end{pmatrix}$$

Matriks di atas jika dijabarkan maka akan diperoleh model GSTAR(1₁) untuk data inflasi masing-masing lokasi yaitu:

- Model GSTAR(1₁) dengan bobot invers jarak untuk inflasi kota Palembang
 $\hat{z}_1(t) = 0.279561 z_1(t-1)$
- Model GSTAR(1₁) dengan bobot invers jarak untuk inflasi kota Bandar Lampung
 $\hat{z}_2(t) = 0.21875 z_1(t-1) + 0.31479 z_3(t-1)$
- Model GSTAR(1₁) dengan bobot invers jarak untuk inflasi DKI Jakarta
 $\hat{z}_3(t) = 0.539482 z_3(t-1)$.

Pendugaan Parameter Model GSTAR dengan Bobot Normalisasi Korelasi Silang

Hasil pendugaan parameter autoregresif model GSTAR(1₁) dengan bobot lokasi normalisasi korelasi silang menggunakan metode GLS dapat dilihat pada Tabel 12.

Tabel 12. Pendugaan Parameter GSTAR(1₁) dengan Bobot Normalisasi Korelasi Silang

Parameter	Estimasi	Standard Error	t hitung	Pr > t	Parameter	Estimasi	Standard Error	t hitung	Pr > t
$\phi_{10}^{(1)}$	0.243917	0.1209	2.02	0.0470	$\phi_{11}^{(1)}$	0.193889	0.1309	1.48	0.1424
$\phi_{10}^{(2)}$	0.068164	0.1270	0.54	0.5929	$\phi_{11}^{(2)}$	0.590053	0.1594	3.70	0.0004
$\phi_{10}^{(3)}$	0.420637	0.1014	4.15	<.0001	$\phi_{11}^{(3)}$	0.211147	0.0986	2.14	0.0352

Dari Tabel 12. pendugaan parameter model GSTAR(1₁) dengan bobot normalisasi korelasi silang di atas, dapat dilihat bahwa pada taraf nyata $\alpha = 0.05$ terdapat parameter yang tidak signifikan, yaitu parameter $\phi_{10}^{(2)}$ dan $\phi_{11}^{(1)}$. Oleh sebab itu, dilakukan seleksi dengan metode *backward* yaitu mengeliminasi parameter yang tidak signifikan secara bertahap (satu per satu). Berikut pendugaan parameter GSTAR ditunjukkan pada Tabel 13.

Tabel 13. Pendugaan Parameter GSTAR(1₁) dengan Bobot Normalisasi Korelasi Silang (*Backward Selection*)

Parameter	Estimasi	Standard Error	t hitung	Pr > t
$\phi_{10}^{(1)}$	0.362271	0.0933	3.88	0.0002
$\phi_{10}^{(3)}$	0.383829	0.0996	3.85	0.0002
$\phi_{11}^{(2)}$	0.604033	0.1006	6.01	<.0001
$\phi_{11}^{(3)}$	0.200315	0.0977	2.05	0.0436

Berdasarkan parameter-parameter yang diperoleh pada Tabel 13. dapat dibentuk matriks untuk model GSTAR(1₁) dengan bobot normalisasi korelasi silang sebagai berikut:

$$\begin{pmatrix} \hat{z}_1(t) \\ \hat{z}_2(t) \\ \hat{z}_3(t) \end{pmatrix} = \begin{pmatrix} 0.362271 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0.383829 \end{pmatrix} \begin{pmatrix} z_1(t-1) \\ z_2(t-1) \\ z_3(t-1) \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0.604033 & 0 \\ 0 & 0 & 0.200315 \end{pmatrix} \begin{pmatrix} 0 & 0.66 & 0.34 \\ 0.5 & 0 & 0.5 \\ 0.56 & 0.44 & 0 \end{pmatrix} \begin{pmatrix} z_1(t-1) \\ z_2(t-1) \\ z_3(t-1) \end{pmatrix}$$

Berdasarkan matriks di atas, diperoleh model GSTAR(1₁) untuk data inflasi masing-masing lokasi yaitu:

- a. Model GSTAR(1₁) dengan bobot lokasi normalisasi korelasi silang untuk inflasi kota Palembang

$$\hat{z}_1(t) = 0.362271 z_1(t-1)$$

- b. Model GSTAR(1₁) dengan bobot lokasi normalisasi korelasi silang untuk inflasi kota Bandar Lampung

$$\hat{z}_2(t) = 0.302 z_1(t-1) + 0.302 z_3(t-1)$$

- c. Model GSTAR(1₁) dengan bobot lokasi normalisasi korelasi silang untuk inflasi DKI Jakarta

$$\hat{z}_3(t) = 0.383829 z_3(t-1) + 0.11218 z_1(t-1) + 0.08814 z_2(t-1).$$

Pengujian Residual Model GSTAR

Uji Normalitas Residual

Tabel 14. memperlihatkan hasil pengujian normal multivariat dengan uji statistik Mardia skewness, Mardia kurtosis dan Henze-Zirkler T model STAR(1₁) dan GSTAR(1₁). Hipotesis yang digunakan pada uji normal multivariat adalah sebagai berikut:

H₀ : residual berdistribusi normal multivariat

H₁ : residual tidak berdistribusi normal multivariat.

Kriteria keputusan untuk uji normal multivariat adalah tolak H₀ jika *p-value* < α, dengan α = 0.05.

Tabel 14. Uji Normalitas Residual Model

Persamaan	Uji Normalitas				Keputusan
	Uji Statistik	Nilai	p-value		
STAR(1 ₁) Invers Jarak	Mardia Skewness	14.75	0.1413		H ₀ diterima
	Mardia Kurtosis	1.11	0.2656		
	Henze-Zirkler T	0.91	0.0929		
STAR(1 ₁) Normalisasi Korelasi Silang	Mardia Skewness	16.51	0.0859		H ₀ diterima
	Mardia Kurtosis	1.16	0.2457		
	Henze-Zirkler T	0.94	0.0652		
GSTAR(1 ₁) Invers Jarak	Mardia Skewness	10.27	0.4172		H ₀ diterima
	Mardia Kurtosis	0.48	0.6293		
	Henze-Zirkler T	0.94	0.0645		
GSTAR(1 ₁) Normalisasi Korelasi Silang	Mardia Skewness	11.66	0.3082		H ₀ diterima
	Mardia Kurtosis	0.92	0.3565		
	Henze-Zirkler T	0.92	0.0788		

Pada Tabel 14. terlihat bahwa untuk semua model yang terbentuk, ketiga uji statistik memiliki nilai p-value > α, sehingga keputusan yang diambil adalah tidak tolak H₀, yang artinya residual model STAR(1₁) dan GSTAR(1₁) dengan dua bobot lokasi berdistribusi normal multivariat.

Uji Heteroskedastisitas

Tabel 15. menunjukkan output SAS untuk uji White setiap model STAR(1₁) dan GSTAR(1₁) yang terbentuk.

Tabel 15. Uji heteroskedastisitas dengan Metode White

Model	Lokasi	Statistik	p-value	Model	Lokasi	Statistik	p-value
STAR(1 ₁) Invers Jarak	Palembang	11.69	0.0394*	GSTAR(1 ₁) Invers Jarak	Palembang	4.75	0.0928
	Bandar	6.34	0.2743		Bandar	5.17	0.0755
	Lampung	6.39	0.2704		Lampung	1.58	0.4533
STAR(1 ₁) Normalisasi Korelasi Silang	DKI Jakarta	11.89	0.0364*	GSTAR(1 ₁) Normalisasi Korelasi Silang	DKI Jakarta	4.88	0.0870
	Palembang	6.95	0.2247		Palembang	5.24	0.0728
	Bandar	8.03	0.1546		Bandar	6.43	0.2662

*heteroskedastis

Hipotesis yang digunakan pada uji White yaitu:

H₀ : $\sigma_i^2 = \sigma^2$ untuk setiap i (tidak terdapat heteroskedastisitas)

H₁ : $\exists \sigma_i^2 \neq \sigma^2$ (terdapat heteroskedastisitas).

Kriteria keputusan untuk uji White sama dengan uji normalitas, yaitu tolak H₀ jika p-value < α, dengan α = 0.05.

Berdasarkan Tabel 15. terlihat bahwa untuk model STAR(1₁) dengan kedua bobot lokasi, terdapat heteroskedastisitas pada model di lokasi Palembang. Sedangkan untuk model GSTAR(1₁) dengan kedua bobot lokasi, asumsi homoskedastisitas terpenuhi di setiap lokasi.

Uji Autokorelasi Residual

Asumsi terakhir yang diuji pada pengujian residual model adalah autokorelasi residual. Pada penelitian ini, pengujian autokorelasi residual dilakukan dengan uji Breusch-Godfrey atau disebut juga dengan uji *Lagrange Multiplier* (LM). Hipotesis yang digunakan pada uji Breusch-Godfrey adalah sebagai berikut.

$H_0 : \rho_1 = \rho_2 = \dots = \rho_p = 0$ (Residual tidak berkorelasi)

$H_1 : \text{setidaknya ada satu } \rho_s \text{ tidak nol. (Residual berkorelasi)}$

Dengan signifikansi $\alpha = 0.05$, kriteria keputusan untuk uji ini adalah tolak H_0 jika statistik $LM > \chi_p^2$ atau $p\text{-value} < \alpha$.

Tabel 16. Tabel Uji Autokorelasi Residual Breusch-Godfrey

Model	Lokasi	LM	p-value	Keputusan
STAR(1 ₁) Invers Jarak	Palembang	3.06	0.0803	Terdapat autokorelasi residual
	Bandar Lampung	5.33	0.0210	
	DKI Jakarta	5.52	0.0188	
STAR(1 ₁) Normalisasi Korelasi Silang	Palembang	3.55	0.0595	Terdapat autokorelasi residual
	Bandar Lampung	4.21	0.0402	
GSTAR(1 ₁) Invers Jarak	DKI Jakarta	4.56	0.1022	Tidak terdapat autokorelasi residual
	Palembang	1.35	0.2447	
	Bandar Lampung	1.99	0.1579	
GSTAR(1 ₁) Normalisasi Korelasi Silang	DKI Jakarta	3.48	0.0622	Tidak terdapat autokorelasi residual
	Palembang	0.25	0.6174	
	Bandar Lampung	0.45	0.5000	
	DKI Jakarta	2.75	0.0971	

Ringkasan hasil pengujian residual model disajikan dalam Tabel 17.

Tabel 17. Ringkasan Hasil Uji Residual Model

	Normalitas	Heteroskedastisitas	Autokorelasi	Kesimpulan
STAR(1 ₁) Invers Jarak	Residual	Terdapat	Terdapat	Residual tidak <i>white noise</i>
	Normal	Heteroskedastisitas	autokorelasi	
STAR(1 ₁) Normalisasi Korelasi Silang	Residual	Terdapat	Terdapat	Residual tidak <i>white noise</i>
	Normal	Heteroskedastisitas	autokorelasi	
GSTAR(1 ₁) Invers Jarak	Residual	Tidak terdapat	Tidak terdapat	Residual <i>white noise</i>
	Normal	Heteroskedastisitas	autokorelasi	
GSTAR(1 ₁) Normalisasi Korelasi Silang	Residual	Tidak terdapat	Tidak terdapat	Residual <i>white noise</i>
	Normal	Heteroskedastisitas	autokorelasi	

Berdasarkan Tabel 17, model GSTAR(1₁) dengan bobot invers jarak dan normalisasi korelasi silang memenuhi asumsi residual *white noise*.

Pemilihan Model Terbaik

Setelah melakukan pengujian terhadap residual model dan diperoleh kesimpulan bahwa model GSTAR(1₁) memenuhi asumsi *white noise*, selanjutnya adalah perhitungan nilai RMSE dengan menggunakan data *out-sample*. Nilai RMSE digunakan untuk melihat

perbandingan ketepatan peramalan antara model STAR(1₁) dengan dua bobot lokasi dan model GSTAR(1₁) dengan dua bobot lokasi. Model yang memiliki nilai RMSE yang terkecil akan dipilih sebagai model terbaik.

Tabel 18. Perbandingan Nilai RMSE dari Model yang Terbentuk

RMSE	Lokasi			Rata-Rata RMSE
	Palembang	Bandar Lampung	DKI Jakarta	
STAR(1 ₁) Invers Jarak	0.53385	0.52695	0.34385	0.468217
STAR(1 ₁) Normalisasi Korelasi Silang	0.53330	0.52400	0.34153	0.466277
GSTAR(1 ₁) Invers Jarak	0.52752	0.53059	0.34519	0.467767
GSTAR(1 ₁) Normalisasi Korelasi Silang	0.53693	0.52640	0.34025	0.46786

Berdasarkan Tabel 18. model yang memiliki nilai RMSE terkecil adalah model STAR(1₁) dengan bobot normalisasi korelasi silang namun model tersebut tidak memenuhi asumsi *white noise*. Sehingga model yang dipilih sebagai model terbaik adalah model GSTAR(1₁) dengan bobot invers jarak karena model tersebut memenuhi asumsi *white noise* dan memiliki nilai RMSE yang lebih kecil yaitu sebesar 0.467767.

Model GSTAR terbaik yang diperoleh untuk data inflasi kota Palembang, Bandar Lampung, dan DKI Jakarta adalah sebagai berikut.

- a. Model GSTAR(1₁) dengan bobot invers jarak untuk inflasi kota Palembang
 $\hat{z}_1(t) = 0.279561 z_1(t-1)$
- b. Model GSTAR(1₁) dengan bobot invers jarak untuk inflasi kota Bandar Lampung
 $\hat{z}_2(t) = 0.21875 z_1(t-1) + 0.31479 z_3(t-1)$
- c. Model GSTAR(1₁) dengan bobot invers jarak untuk inflasi DKI Jakarta
 $\hat{z}_3(t) = 0.539482 z_3(t-1)$.

KESIMPULAN DAN SARAN

Berdasarkan hasil analisis dan pembahasan diperoleh kesimpulan bahwa model GSTAR lebih sesuai digunakan untuk data inflasi Palembang, Bandar Lampung, dan DKI Jakarta dibandingkan model STAR. Meskipun model STAR memiliki nilai RMSE yang lebih kecil tetapi model STAR tidak memenuhi asumsi *white noise*. Model GSTAR yang terbaik untuk data inflasi kota Palembang, Bandar Lampung, dan DKI Jakarta adalah model GSTAR(1₁) dengan bobot lokasi yang digunakan yaitu bobot lokasi invers jarak. Model GSTAR(1₁) dengan bobot lokasi invers jarak memenuhi asumsi *white noise* dan memiliki nilai rata-rata RMSE yaitu 0.467767. Model GSTAR menjelaskan keterkaitan ruang dan waktu pada data inflasi, dimana inflasi Bandar Lampung pada waktu t dipengaruhi oleh inflasi Palembang dan DKI Jakarta pada satu periode sebelumnya (t - 1), tetapi inflasi Bandar Lampung pada satu periode sebelumnya tidak mempengaruhi inflasi ketiga kota pada waktu t.

DAFTAR PUSTAKA

- Al Amri, M. Z. (2020). Perbandingan Model STAR dan GSTAR untuk Peramalan Indeks Harga Konsumen di Kota Padang, Pekanbaru, Jambi, dan Palembang. *Media Edukasi Data Ilmiah Dan Analisis (MEDIAN)*, 3(01), 29–38.
- Arum, P. R., Fathoni Amri, I., & Amri, S. (2024). GLS estimation in python to forecast gross regional domestic product using generalized space–time autoregressive seemingly unrelated regression model. *Frontiers in Applied Mathematics and Statistics*, 10, 1365723. <https://doi.org/10.3389/fams.2024.1365723>
- Bi, J., Wang, J., Cao, H., Yao, G., Wang, Y., Li, Z., Sun, M., Yang, H., Zhen, J., & Zheng, G. (2024). Inverse distance weight-assisted particle swarm optimized indoor localization. *Applied Soft Computing*, 164, 112032. <https://doi.org/10.1016/j.asoc.2024.112032>
- Borovkova, S. A., Lopuhaä, H. P., & Nurani, B. (2002). Generalized STAR model with experimental weights. *Proceedings of the 17th International Workshop on Statistical Modelling*, 139–147.
- Fransiska, H., Sunandi, E., & Agustina, D. (2020). Peramalan Curah Hujan Provinsi Bengkulu dengan Generalized Space-Time Autoregressive. *MUST: Journal of Mathematics Education, Science and Technology*, 5(2), 130–142. <https://doi.org/10.30651/must.v5i2.5326>
- Hestuningtias, F., & Kurniawan, M. H. S. (2023). The Implementation of the Generalized Space-Time Autoregressive (GSTAR) Model for Inflation Prediction. *Enthusiastic: International Journal of Applied Statistics and Data Science*, 176–188. <https://doi.org/10.20885/enthusiastic.vol3.iss2.art5>
- Imro'ah, N. (2023). Determination of the best weight matrix for the Generalized Space Time Autoregressive (GSTAR) model in the Covid-19 case on Java Island, Indonesia. *Spatial Statistics*, 54, 100734. <https://doi.org/10.1016/j.spasta.2023.100734>
- Iriany, A., Aini, N. N., & Sulistyono, A. D. (2021). Spatio Temporal Modelling for Government Policy the COVID-19 Pandemic in East Java. *CAUCHY: Jurnal Matematika Murni Dan Aplikasi*, 6(4), 218–226. <https://doi.org/10.18860/ca.v6i4.10639>
- Mukhaiyar, U., & Ramadhani, S. (2022). The Generalized STAR Modeling with Heteroscedastic Effects. *CAUCHY: Jurnal Matematika Murni Dan Aplikasi*, 7(2), 158–172. <https://doi.org/10.18860/ca.v7i2.13097>
- Ord, J. K. (2010). Spatial autocorrelation: A statistician's reflections. *Perspectives on Spatial Data Analysis*, 165–180. https://doi.org/10.1007/978-3-642-01976-0_12
- Rompon, M., Soblia, H. T., Monika, P., Abdullah, A. S., & Ruchjana, B. N. (2023). Identifikasi Autokorelasi Spasial Warisan Budaya Tak Benda di Indonesia Menggunakan Indeks Moran. *Statistika*, 23(2), 156–163. <https://doi.org/10.29313/statistika.v23i2.2675>
- Ruiz, A. P., Flynn, M., Large, J., Middlehurst, M., & Bagnall, A. (2021). The great multivariate time series classification bake off: a review and experimental evaluation of recent algorithmic advances. *Data Mining and Knowledge Discovery*, 35(2), 401–449. <https://doi.org/10.1007/s10618-020-00727-3>
- Woodward, W. A., Gray, H. L., & Elliott, A. (2020). Nonstationary Time Series Models. In *Applied Time Series Analysis* (pp. 203–220). <https://doi.org/10.1201/b11459-9>
- Yilmaz, V. (2023). Decomposition of effects for the structural model consisting of

two mediating latent variables: an example of entrepreneurial intention.
Journal of Modelling in Management, 18(3), 973–992. <https://doi.org/10.1108/JM2-01-2022-0008>

Zhao, L., Li, Z., & Qu, L. (2022). Forecasting of Beijing PM2. 5 with a hybrid ARIMA model based on integrated AIC and improved GS fixed-order methods and seasonal decomposition. *Heliyon*, 8(12). <https://doi.org/10.1016/j.heliyon.2022.e12239>