

PEMODELAN INDEKS HARGA PROPERTI RESIDENSIAL DI INDONESIA MENGUNAKAN METODE *GENERALIZED SPACE TIME AUTOREGRESSIVE*

Syazwina Aufa¹, Rukun Santoso^{2*}, Suparti³

^{1,2,3} Departemen Statistika, Fakultas Sains dan Matematika, Universitas Diponegoro

*email: rukunsantoso25@gmail.com

ABSTRACT

Generalized Space Time Autoregressive (GSTAR) is a model used for space time data analysis. Space time data is data related to events at previous times and different locations. GSTAR is an expansion of the Space Time Autoregressive (STAR) method. The STAR method is only suitable for homogeneous locations while GSTAR can be used for heterogeneous locations. This research uses Residential Property Price Index (IHPR) data. IHPR data is in the form of a multivariate time series consisting of 18 cities/regions with a certain time span. In this study, the analysis of IHPR data is carried out by looking at the relationship between the previous time and other cities/regions. Therefore, the method that can be used is GSTAR method. Analysis of IHPR data in each city/region can help increase the supply of housing, thereby reducing the number of backlogs. The backlog of houses in Indonesia is still relatively high. Backlog is an indicator that is often used by the government to measure the number of housing needs in Indonesia. Based on the fulfillment of the assumptions and the smallest MSE value, the best model obtained is GSTAR(4;1,1,1,1) using cross-correlation normalized weight. The largest IHPR data on forecasting results is in the cities of Makassar, Manado, and Surabaya while the smallest IHPR data is in the city of Balikpapan. The GSTAR method produces forecasted data that is close to the actual data so it is good to use.

Keywords : GSTAR, OLS, IHPR

1. PENDAHULUAN

Backlog rumah adalah salah satu indikator yang sering digunakan oleh pemerintah untuk mengukur jumlah kebutuhan rumah di Indonesia. Istilah *backlog* sering diartikan sebagai perbandingan antara jumlah rumah yang terbangun dengan jumlah rumah yang dibutuhkan. Berdasarkan data jumlah penduduk tahun 2010, *backlog* kepemilikan rumah sebesar 13,5 juta unit. Selanjutnya berdasarkan buku proyeksi penduduk Indonesia tahun 2010-2035, *backlog* kepemilikan rumah pada tahun 2015 sebesar 11,4 juta unit (Buhaerah, 2019). Berdasarkan data Survey Sosial Ekonomi Nasional (SUSENAS) tahun 2020, Direktur Jenderal Perumahan Kementerian PUPR Iwan Suprijanto mengatakan bahwa angka *backlog* kepemilikan rumah masih sangat tinggi mencapai 12,75 juta unit belum termasuk dengan adanya pertumbuhan keluarga baru sebesar 700.000 sampai 800.000 per tahun (Laksono, 2022).

Kebutuhan akan perumahan akan terus menaik seiring dengan penambahan penduduk dan meningkatnya jumlah usia produktif. Permintaan masyarakat terhadap sektor properti diperkirakan akan terus berkembang setiap tahunnya. Ketika tingkat permintaan/*demand* meningkat, maka harga perumahan juga akan meningkat. Kondisi ini memungkinkan pengembang perumahan memiliki target pasar di seluruh Indonesia, tidak hanya di daerah tertentu saja.

Minimnya bahasan terkait harga properti residensial di Indonesia menjadi latar belakang penulis untuk melakukan penelitian. Hal ini perlu dilakukan untuk melihat peningkatan atau perlambatan pada penjualan rumah yang terjadi seiring peningkatan dan penurunan harga rumah. Bahasan mengenai harga properti residensial juga berguna agar pemerintah maupun pengembang di bidang properti bisa meningkatkan *supply* rumah sehingga menurunkan jumlah *backlog*. Pembangunan infrastruktur yang belum merata juga menjadi masalah penting di Indonesia. Oleh karena itu, peneliti ingin menganalisis keterkaitan IHPR di satu kota/wilayah dengan kota/wilayah lain di tengah pembangunan infrastruktur yang belum merata tersebut.

Indeks Harga Properti Residensial (IHPR) merupakan salah satu indikator ekonomi yang memberikan informasi mengenai perkembangan harga properti residensial di Indonesia. Data IHPR berbentuk *multivariate time series* terdiri dari 18 kota/wilayah dengan rentang waktu tertentu. Pada penelitian ini, analisis pergerakan data IHPR dilakukan dengan melihat keterkaitan dengan waktu sebelumnya dan kota/wilayah lainnya. Oleh karena itu, metode yang dapat digunakan untuk memodelkan dan meramalkan data IHPR yang memiliki keterkaitan dengan waktu dan kota/wilayah lainnya adalah metode *Generalized Space Time Autoregressive* (GSTAR).

2. TINJAUAN PUSTAKA

2.1 Multivariate Time Series

Multivariate time series memodelkan variabel-variabel yang berkorelasi dan tercatat dari waktu ke waktu (Halim dan Chandra, 2011). Berikut merupakan persamaan *multivariate time series*:

$$\mathbf{Z}(t) = [Z_1(t), Z_2(t), \dots, Z_N(t)]' \quad (1)$$

$\mathbf{Z}(t)$ merupakan matriks *time series* dengan variabel sebanyak $i=1,2,\dots, N$. t adalah periode *time series* berjalan dari $t=1,2,\dots,n$, dan diasumsikan $E(\mathbf{Z}(t))$ adalah vektor nol.

2.2 Stasioneritas Model Multivariate Time Series

a. Matrix Autocorrelation Function (MACF)

Matrix Autocorrelation Function (MACF) digunakan untuk melihat data *multivariate time series* sudah stasioner dalam mean atau belum. Ketika MACF menunjukkan penurunan lag yang melambat, maka data diindikasikan belum stasioner dan perlu dilakukan *differencing*. Stasioneritas data dalam varian tidak perlu dilakukan berdasarkan tulisan Shofiyah (2009).

Diberikan vektor *time series* dengan observasi sebanyak n yaitu $Z_i(1), Z_i(2), \dots, Z_i(n)$ maka matriks korelasi sampelnya dihitung sebagai berikut (Wei, 2006):

$$\hat{\boldsymbol{\rho}}(\mathbf{k}) = [\hat{\rho}_{ij}(\mathbf{k})] \quad (2)$$

dengan $\hat{\rho}_{ij}(\mathbf{k})$ adalah korelasi silang sampel untuk komponen lokasi ke- i dan ke- j pada lag ke- k .

$$\hat{\rho}_{ij}(\mathbf{k}) = \frac{\sum_{t=1}^{n-k} [(Z_i(t) - \bar{Z}_i)(Z_j(t+k) - \bar{Z}_j)]}{[\sum_{t=1}^n (Z_i(t) - \bar{Z}_i)^2 \sum_{t=1}^n (Z_j(t) - \bar{Z}_j)^2]^{\frac{1}{2}}} \quad (3)$$

\bar{Z}_i dan \bar{Z}_j merupakan mean sampel dari komponen lokasi yang bersesuaian.

b. Matrix Partial Autocorrelation Function (MPACF)

Matrix Partial Autocorrelation Function (MPACF) digunakan untuk mengidentifikasi orde model dugaan sementara. MPACF dicirikan dengan melihat *cut-off* pada lag waktu dan lag spasial tertentu. MPACF pada lag ke- k dinotasikan dengan $\mathcal{P}(k)$. Rumus $\mathcal{P}(k)$ adalah sebagai berikut (Wei, 2006):

$$\mathcal{P}(k) = \begin{cases} \boldsymbol{\Gamma}'(1)[\boldsymbol{\Gamma}(0)]^{-1} & k = 1 \\ \{\boldsymbol{\Gamma}'(k) - \mathbf{c}'(k)[\mathbf{A}(k)]^{-1}\mathbf{b}(k)\} \{\boldsymbol{\Gamma}(0) - \mathbf{b}'(k)[\mathbf{A}(k)]^{-1}\mathbf{b}(k)\}^{-1} & k > 1 \end{cases} \quad (4)$$

Untuk $k \geq 2$, maka nilai $\mathbf{A}(k)$, $\mathbf{b}(k)$, dan $\mathbf{c}(k)$ adalah sebagai berikut:

$$\mathbf{A}(k) = \begin{bmatrix} \boldsymbol{\Gamma}(0) & \boldsymbol{\Gamma}'(1) & \cdots & \boldsymbol{\Gamma}'(k-2) \\ \boldsymbol{\Gamma}(1) & \boldsymbol{\Gamma}(0) & \cdots & \boldsymbol{\Gamma}'(k-3) \\ \vdots & \vdots & \ddots & \vdots \\ \boldsymbol{\Gamma}(k-2) & \boldsymbol{\Gamma}(k-3) & \cdots & \boldsymbol{\Gamma}(0) \end{bmatrix} \quad \mathbf{b}(k) = \begin{bmatrix} \boldsymbol{\Gamma}'(k-1) \\ \boldsymbol{\Gamma}'(k-2) \\ \vdots \\ \boldsymbol{\Gamma}'(1) \end{bmatrix} \quad \mathbf{c}(k) = \begin{bmatrix} \boldsymbol{\Gamma}(1) \\ \boldsymbol{\Gamma}(2) \\ \vdots \\ \boldsymbol{\Gamma}(k-1) \end{bmatrix} \quad (5)$$

dengan $\boldsymbol{\Gamma}(k)$ adalah matriks kovarian lag- k .

2.3 Uji Keheterogenan Lokasi dengan Indeks Gini

Indeks Gini diperkenalkan oleh seorang statistikawan Italia, Corrado Gini (1884-1965) untuk mengkaji heterogenan lokasi. Indeks Gini adalah suatu koefisien yang menunjukkan ketidakmerataan suatu distribusi. Indeks Gini digunakan dengan membandingkan suatu perubahan antar periode dan antar lokasi.

Hipotesis:

H_0 : Lokasi Homogen (kemerataan sempurna)

H_1 : Lokasi Heterogen (kemerataan tidak sempurna)

Statistik Uji:

$$G = 1 + \frac{1}{T} - \frac{2}{T^2 \bar{Z}_i} \sum_{t=1}^n Z_i(t) \quad (6)$$

Z_i adalah nilai pengamatan pada lokasi ke- i , $\bar{Z}_i(t)$ adalah rata-rata nilai pengamatan, dan T adalah jumlah keseluruhan pengamatan. H_0 ditolak jika indeks Gini mempunyai nilai 1.

2.4 Pembobot Spasial

Pembobot spasial memberikan informasi intensitas efek spasial dari suatu unit lokasi di dalam sistem geografi.

a. Pembobot *Invers Jarak*

Pembobot *invers jarak* adalah pembobot yang berdasarkan jarak sebenarnya yaitu menggunakan nilai *latitude* dan *longitude* lokasi. Perhitungan bobot diperoleh dari hasil *invers jarak* yang sebenarnya kemudian dinormalisasi. Pembobot *invers jarak* dirumuskan sebagai berikut (Faizah dan Setiawan, 2013):

$$w_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_{j=1}^N \frac{1}{d_{ij}}}, j \neq i \quad (7)$$

dengan $d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$ adalah jarak lokasi ke- i dengan lokasi ke- j .

b. Pembobot Normalisasi Korelasi Silang

Pembobot normalisasi korelasi silang menggunakan normalisasi hasil korelasi antar lokasi pada lag yang bersesuaian. Taksiran dari korelasi silang pada data sampel adalah (Suhartono dan Atok, 2006):

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [(Z_i(t) - \bar{Z}_i)(Z_j(t-k) - \bar{Z}_j)]}{[\sum_{t=1}^n (Z_i(t) - \bar{Z}_i)^2 \sum_{t=1}^n (Z_j(t) - \bar{Z}_j)^2]^{\frac{1}{2}}} \quad (8)$$

Penentuan bobot dilakukan dengan menormalisasi hasil korelasi silang pada lag waktu yang bersesuaian. Proses ini umumnya menghasilkan bobot spasial untuk model GSTAR(1;1). Perhitungan bobot normalisasi korelasi silang adalah sebagai berikut:

$$w_{ij} = \frac{r_{ij}(1)}{\sum_{k \neq i} |r_{ik}(1)|}, \text{ dengan } i \neq j \quad (9)$$

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

2.5 Model *Generalized Space-Time Autoregressive (GSTAR)*

Generalized Space Time Autoregressive (GSTAR) diperkenalkan oleh Ruchjana *et al.* (2002). GSTAR merupakan suatu model yang dapat digunakan untuk analisis data *space-time*. Data *space time* adalah data yang berhubungan dengan kejadian pada waktu sebelumnya dan lokasi yang berbeda. Sebuah deret $\mathbf{Z}(t) = [Z_1(t), Z_2(t), \dots, Z_N(t)]'$ adalah vektor *time series* pada waktu ke t dengan pengamatan sebanyak $i=1, 2, \dots, N$ dan $E(\mathbf{Z}(t))$ adalah vektor nol. Model GSTAR($p; \lambda_1, \lambda_2, \dots, \lambda_p$) dengan p adalah orde *autoregressive* dan $(\lambda_1, \lambda_2, \dots, \lambda_p)$ adalah orde spasial sebagai berikut :

$$\mathbf{Z}(t) = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \Phi_{kl} \mathbf{WZ}(t-k) + \mathbf{e}(t) \quad (10)$$

$\mathbf{Z}(t)$: Vektor acak berukuran $N \times 1$ pada periode $t=1,2,\dots,n$ ($\mathbf{Z}(t) = [Z_1(t), Z_2(t), \dots, Z_N(t)]'$)

Φ_{kl} : Matriks diagonal yang mengandung elemen diagonal orde *autoregressive* dan *space-time* pada setiap lokasi ($\Phi_{kl} = \text{diag}(\Phi_{kl}^1, \dots, \Phi_{kl}^N)$)

\mathbf{W} : Matriks bobot berukuran $N \times N$ dengan nilai pembobot yang dipilih memenuhi syarat $w_{ii}=0$ dan $\sum_{j=1}^N w_{ij} = 1$

$\mathbf{e}(t)$: Vektor galat berukuran $N \times 1$ yang diasumsikan berdistribusi normal dengan mean nol dan varian konstan ($\mathbf{e}(t) = [e_1(t), e_2(t), \dots, e_N(t)]'$)

Model parameter ($\Phi_{kl}^1, \dots, \Phi_{kl}^N$) untuk orde *autoregressive* $k=1,2,\dots$ dst dan $l=1,2,\dots$ dst dapat diestimasi menggunakan estimasi *Ordinary Least Square* (OLS). Untuk penelitian ini digunakan model GSTAR dengan pembatasan orde *autoregressive* $k=5$ dan orde spasial $l=1$ karena mempertimbangkan banyaknya parameter yang diestimasi. Estimasi OLS untuk matriks parameter Φ adalah:

$$\Phi = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Z} \quad (11)$$

2.6 Uji Asumsi Model

Asumsi-asumsi dalam model GSTAR adalah *white noise multivariate* residual dan normal *multivariate* residual (Pfeifer dan Deutsch, 1980)..

a. Asumsi White Noise Multivariate Residual

Asumsi *white noise multivariate* pada residual adalah asumsi dasar bahwa antar residual tidak memiliki korelasi dengan *mean* sama dengan nol dan varian konstan. Asumsi residual *white noise multivariate* dilakukan dengan menggunakan portmanteau *multivariate test* yang merupakan bentuk umum dari *Ljung-Box statistic* pada kasus *multivariate* sebagai berikut (Tsay, 2005):

Hipotesis:

$H_0 : \rho_1 = \rho_2 = \dots = \rho_l = \mathbf{0}$ (residual telah *white noise*)

$H_1 : \text{minimal ada satu } \rho_i \neq \mathbf{0}$, dimana $i=1,2,\dots,l$ (residual tidak *white noise*)

dengan ρ adalah matriks korelasi dari vektor error.

Statistik uji:

$$Q_N(l) = T^2 \sum_{l=1}^l \frac{1}{T-l} \text{tr}(\hat{\Gamma}'_l \hat{\Gamma}_0^{-1} \hat{\Gamma}_l \hat{\Gamma}_0^{-1}) \quad (12)$$

l : banyak lag

T : Jumlah keseluruhan pengamatan

$\text{tr}(\mathbf{A})$: *trace* dari matriks \mathbf{A} dengan $\mathbf{A} = (\hat{\Gamma}'_l \hat{\Gamma}_0^{-1} \hat{\Gamma}_l \hat{\Gamma}_0^{-1})$

Kriteria pengujian:

H_0 ditolak jika $Q \geq \chi_{\alpha, N^2 l}^2$ atau *p-value* $< \alpha$ sehingga residual *white noise*.

b. Asumsi Normal Multivariate Residual

Pengujian kenormalan residual dapat dilakukan menggunakan uji Kolmogorov Smirnov. Residual model GSTAR mengikuti distribusi normal N -variat jika jarak d_i^2 mengikuti distribusi *chi square* dengan derajat bebas N (Bohling, 2006).

Hipotesis yang diuji:

$H_0 : d_i^2 \sim \chi_N^2$ (jarak mahalanobis mengikuti distribusi *chi square* dengan derajat bebas N , residual berdistribusi normal *multivariate*)

$H_1 : d_i^2$ tidak mengikuti χ_N^2 (jarak mahalanobis tidak mengikuti distribusi *chi square* dengan derajat bebas N , residual tidak berdistribusi normal *multivariate*)

Statistika uji :

$$D = \text{Sup}|S(d_i^2) - F_0(d_i^2)| \quad (13)$$

$S(d_i^2)$: proporsi jarak mahalanobis yang $\leq d_i^2$

Sup : Nilai supremum untuk semua d_i^2 dari selisih mutlak $S(d_i^2)$ dan $F_0(d_i^2)$

$F_0(d_i^2)$: fungsi peluang kumulatif dari distribusi hipotesis (*chi square*)

Kriteria pengujian yaitu H_0 ditolak jika $D \geq D_{(1-\alpha),n}$ atau $p\text{-value} < \alpha$ dengan $D_{(1-\alpha)}$ adalah nilai table Kolmogorov-Smirnov dengan kuantil $(1 - \alpha)$.

2.7 Uji Signifikansi Model

Pengujian signifikansi dilakukan setelah diperoleh nilai estimasi dari tiap parameter untuk mengetahui model yang diperoleh layak atau tidak digunakan. Pengujian sebagai berikut (Zahro, 2017):

Hipotesis:

H_0 : semua nilai $\Phi_{kl}^i = 0$ (estimasi parameter tidak signifikan)

H_i : ada nilai $\Phi_{kl}^i \neq 0$ (estimasi parameter signifikan)

untuk semua lag waktu k dan lag spasial l dengan $k= 1,2,\dots,5$, $l = 0,1$, dan $i= 1,2,\dots,N$

2.8 Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah metode yang digunakan untuk mengevaluasi metode peramalan. MSE digunakan untuk mengukur rata-rata kuadrat kesalahan yaitu rata-rata selisih kuadrat antara nilai taksiran dan nilai sebenarnya. Semakin kecil nilai MSE, maka semakin baik model yang dipilih (Wei, 2006).

Rumus untuk mengetahui besarnya MSE per kota/wilayah adalah :

$$MSE = \frac{1}{Nn} \sum_{i=1}^N \sum_{t=1}^n (Z_i(t) - \hat{Z}_i(t))^2 \quad (14)$$

dengan Nn sama dengan T adalah banyaknya keseluruhan observasi

2.9 Indeks Harga Properti Residensial (IHPR)

Indeks Harga Properti Residensial (IHPR) adalah salah satu indikator yang memberikan informasi mengenai perkembangan properti residensial. Data IHPR diperoleh dari Survey Harga Properti Residensial (SHPR) pasar primer yang dilakukan oleh Bank Indonesia secara triwulan. Survey dilakukan terhadap sekitar 600 pengembang/*developer* yang mempunyai skala kegiatan cukup besar serta aktif memproduksi membangun rumah secara kontinyu di 18 kota dan wilayah.

Hasil SHPR diolah dan disajikan dalam bentuk IHPR perkota/wilayah dengan menggunakan metode *chain index* yang menggunakan tahun dasar 2002=100 (Bank Indonesia, 2020). IHPR perkota/wilayah dihitung dengan rumus (Bank Indonesia, 2020):

$$IHPR_t = IHPR_{t-1} + (IHPR_{t-1} \times \frac{\Delta P_t}{100}) \quad (15)$$

$IHPR_t$ adalah data IHPR pada periode t , $IHPR_{t-1}$ adalah data IHPR pada periode $t-1$, dan ΔP_t adalah selisih rata-rata harga t dengan rata-rata harga $t-1$.

3. METODE PENELITIAN

3.1. Jenis dan Sumber Data

Data yang digunakan pada penelitian ini adalah data sekunder. Data yang digunakan yaitu data Indeks Harga Properti Residensial yang berasal dari website resmi www.bi.go.id pada tahun 2012 kuartal pertama tahun 2022 triwulan pertama. Data dibagi menjadi data *training* dan *testing*. Data *training* yaitu Data IHPR tahun 2012 triwulan pertama hingga tahun 2021 triwulan ketiga dan data *testing* yaitu data IHPR tahun 2021 triwulan keempat hingga tahun 2022 triwulan pertama. Data *testing* dijadikan sebagai data perbandingan dengan data hasil peramalan. Variabel yang digunakan pada penelitian ini adalah sebagai berikut:

- Z₁ : Indeks Harga Properti Residensial (IHPR) di Bandung
- Z₂ : Indeks Harga Properti Residensial (IHPR) di Bandar Lampung
- Z₃ : Indeks Harga Properti Residensial (IHPR) di Banjarmasin
- Z₄ : Indeks Harga Properti Residensial (IHPR) di Denpasar
- Z₅ : Indeks Harga Properti Residensial (IHPR) di Palembang
- Z₆ : Indeks Harga Properti Residensial (IHPR) di Semarang
- Z₇ : Indeks Harga Properti Residensial (IHPR) di Yogyakarta
- Z₈ : Indeks Harga Properti Residensial (IHPR) di Padang
- Z₉ : Indeks Harga Properti Residensial (IHPR) di Medan
- Z₁₀ : Indeks Harga Properti Residensial (IHPR) di Makassar
- Z₁₁ : Indeks Harga Properti Residensial (IHPR) di Manado
- Z₁₂ : Indeks Harga Properti Residensial (IHPR) di Surabaya
- Z₁₃ : Indeks Harga Properti Residensial (IHPR) di Pontianak
- Z₁₄ : Indeks Harga Properti Residensial (IHPR) di Batam
- Z₁₅ : Indeks Harga Properti Residensial (IHPR) di Balikpapan
- Z₁₆ : Indeks Harga Properti Residensial (IHPR) di Jabodebek-Banten

3.2 Prosedur Analisis Data

Prosedur analisis data adalah sebagai berikut:

1. Menentukan banyaknya data dan lokasi yang digunakan
2. Melakukan analisis deskriptif pada data
3. Melakukan analisis korelasi antar lokasi
4. Menghitung nilai indeks Gini untuk melihat keheterogenan lokasi
5. Menentukan bobot lokasi yang digunakan pada model GSTAR
6. Mengecek stasioneritas data dalam *mean* menggunakan MACF
7. Mengidentifikasi orde model GSTAR menggunakan MACF dan MPACF
8. Melakukan estimasi parameter model GSTAR
9. Mengitung nilai MSE pada masing-masing model GSTAR
10. Melakukan pengecekan asumsi *white noise* dan normal *multivariate*
11. Melakukan uji kesesuaian model GSTAR
12. Mencari model terbaik berdasarkan pemenuhan asumsi, nilai MSE terkecil, dan bobot yang digunakan
13. Melakukan peramalan untuk beberapa periode ke depan

4. HASIL DAN PEMBAHASAN

4.1 Deskripsi Data IHPR

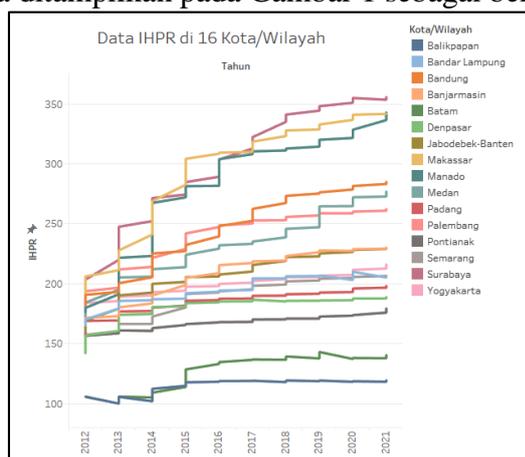
Deskripsi data IHPR ditampilkan pada Tabel 1 berikut ini.

Tabel 1. Statistika Deskriptif Data IHPR

Kota/Wilayah	N	Minimum	Maksimum	Mean	Standar Deviasi
Surabaya	39	189,840	355,840	295,760	52,650
Makassar	39	186,730	341,900	291,490	50,050
Manado	39	176,320	342,960	280,520	51,363
Bandung	39	181,670	285,120	242,930	34,343
Palembang	39	181,280	262,420	237,270	25,087
Medan	39	171,830	277,060	230,290	29,810
Jabodebek Banten	39	160,040	229,800	206,580	20,163
Banjarmasin	39	166,050	230,350	206,350	21,742
Yogyakarta	39	178,450	216,300	198,650	9,756
Bandar lampung	39	164,890	209,960	194,030	12,886
Semarang	39	154,470	206,790	187,800	17,990

Padang	39	156,380	198,230	184,410	10,983
Denpasar	39	141,890	188,910	178,990	12,611
Pontianak	39	148,090	179,430	166,720	7,363
Batam	39	100,000	143,060	126,270	14,791
Balikpapan	39	100,000	119,440	114,420	6,222

Berdasarkan Tabel 1 diketahui bahwa setiap lokasi memiliki 39 data. Surabaya dan Makassar memiliki nilai *mean* terbesar yaitu 295,670 dan 291,490. Balikpapan memiliki nilai *mean* terkecil yaitu 114,420. Data memiliki standar deviasi 6,222 -52,650 secara keseluruhan. Visualisasi data ditampilkan pada Gambar 1 sebagai berikut.



Gambar 1. Visualisasi Data IHPR

Berdasarkan Gambar 1 terlihat bahwa data untuk setiap lokasi memiliki kecenderungan naik berdasarkan satuan waktu. Hal ini mengindikasikan bahwa data belum stasioner sehingga perlu dilakukan penanganan. Grafik tersebut menunjukkan kecenderungan naik antar lokasi yang relatif sama sehingga memiliki hubungan korelasi antar lokasi.

4.2 Uji Keheterogenan Lokasi dengan Indeks Gini

Indeks Gini digunakan dengan membandingkan suatu perubahan antar periode dan antar lokasi. Diperoleh nilai indeks Gini di 16 kota/wilayah yaitu sebesar 1,001402. Dengan kriteria pengujian H_0 ditolak jika indeks Gini sama dengan 1, maka H_0 ditolak sehingga 16 kota/wilayah heterogen.

4.3 Penentuan Matriks Bobot Lokasi

a. Bobot *Invers* Jarak

Perhitungan bobot *invers* jarak dilakukan dengan menghitung jarak sebenarnya menggunakan nilai *latitude* dan *longitude* lokasi. Hasil perhitungan bobot *invers* jarak diperoleh dari hasil *invers* jarak yang sebenarnya ($\frac{1}{d}$) kemudian dinormalisasi yaitu pada Tabel 2.

Tabel 2. Bobot Invers Jarak

	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8	Z9	Z10	Z11	Z12	Z13	Z14	Z15	Z16
Z1	0	0,085	0,030	0,030	0,048	0,084	0,081	0,025	0,017	0,244	0,012	0,045	0,033	0,027	0,022	0,217
Z2	0,111	0	0,032	0,029	0,122	0,057	0,055	0,046	0,027	0,169	0,015	0,040	0,045	0,047	0,025	0,179
Z3	0,060	0,049	0	0,088	0,048	0,085	0,077	0,033	0,027	0,057	0,042	0,109	0,076	0,041	0,152	0,057
Z4	0,066	0,049	0,095	0	0,043	0,101	0,104	0,031	0,025	0,059	0,037	0,182	0,049	0,035	0,067	0,059
Z5	0,080	0,155	0,039	0,033	0	0,056	0,053	0,080	0,043	0,099	0,019	0,043	0,071	0,095	0,032	0,102
Z6	0,094	0,049	0,047	0,052	0,038	0	0,316	0,022	0,017	0,073	0,016	0,111	0,037	0,026	0,030	0,071
Z7	0,094	0,048	0,044	0,055	0,037	0,327	0	0,022	0,017	0,072	0,016	0,110	0,035	0,025	0,029	0,070
Z8	0,062	0,087	0,040	0,035	0,119	0,049	0,048	0	0,119	0,069	0,024	0,042	0,064	0,138	0,035	0,070
Z9	0,057	0,070	0,045	0,038	0,088	0,050	0,048	0,162	0	0,061	0,030	0,044	0,070	0,133	0,042	0,062
Z10	0,090	0,047	0,010	0,010	0,022	0,024	0,023	0,010	0,007	0	0,004	0,014	0,013	0,011	0,008	0,706
Z11	0,058	0,053	0,098	0,079	0,054	0,066	0,064	0,045	0,042	0,056	0	0,074	0,071	0,053	0,131	0,056
Z12	0,071	0,048	0,085	0,130	0,041	0,155	0,149	0,026	0,021	0,062	0,025	0	0,046	0,031	0,050	0,061
Z13	0,070	0,074	0,081	0,048	0,092	0,071	0,064	0,055	0,044	0,074	0,032	0,062	0	0,093	0,065	0,075
Z14	0,060	0,079	0,046	0,035	0,128	0,051	0,048	0,125	0,088	0,067	0,025	0,043	0,097	0	0,040	0,068
Z15	0,054	0,048	0,191	0,078	0,048	0,069	0,064	0,036	0,031	0,053	0,070	0,081	0,077	0,045	0	0,053
Z16	0,080	0,051	0,011	0,010	0,023	0,024	0,022	0,010	0,007	0,712	0,004	0,014	0,013	0,011	0,008	0

b. Bobot Normalisasi Korelasi Silang

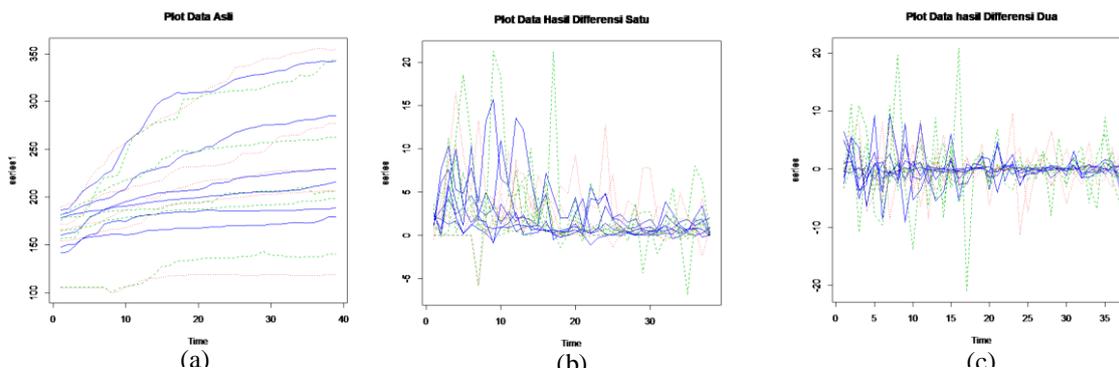
Perhitungan bobot normalisasi korelasi silang menggunakan normalisasi hasil korelasi silang antar lokasi pada lag yang bersesuaian. Tabel 3 merupakan hasil perhitungan bobot normalisasi korelasi silang.

Tabel 3. Bobot Normalisasi Korelasi Silang

	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8	Z9	Z10	Z11	Z12	Z13	Z14	Z15	Z16
Z1	0	0,067	0,069	0,060	0,068	0,068	0,069	0,066	0,067	0,068	0,068	0,069	0,067	0,066	0,062	0,068
Z2	0,068	0	0,068	0,063	0,068	0,067	0,068	0,069	0,067	0,067	0,067	0,069	0,068	0,063	0,058	0,069
Z3	0,068	0,066	0	0,062	0,068	0,069	0,068	0,066	0,066	0,068	0,068	0,068	0,066	0,066	0,064	0,067
Z4	0,064	0,068	0,066	0	0,070	0,066	0,066	0,072	0,064	0,070	0,070	0,067	0,070	0,058	0,059	0,070
Z5	0,067	0,066	0,068	0,065	0	0,068	0,067	0,067	0,065	0,069	0,068	0,067	0,067	0,065	0,063	0,068
Z6	0,068	0,065	0,069	0,062	0,068	0	0,067	0,066	0,065	0,069	0,068	0,068	0,067	0,066	0,065	0,067
Z7	0,069	0,066	0,068	0,060	0,067	0,068	0	0,067	0,069	0,068	0,068	0,069	0,068	0,063	0,060	0,068
Z8	0,067	0,067	0,067	0,066	0,068	0,067	0,068	0	0,067	0,068	0,068	0,068	0,069	0,061	0,059	0,069
Z9	0,069	0,068	0,068	0,060	0,067	0,068	0,070	0,068	0	0,067	0,067	0,069	0,069	0,063	0,058	0,069
Z10	0,067	0,066	0,068	0,065	0,069	0,068	0,067	0,068	0,065	0	0,069	0,068	0,067	0,064	0,063	0,068
Z11	0,067	0,066	0,068	0,065	0,069	0,067	0,067	0,068	0,066	0,069	0	0,068	0,067	0,063	0,062	0,068
Z12	0,069	0,068	0,068	0,062	0,068	0,068	0,068	0,067	0,067	0,068	0,068	0	0,067	0,064	0,060	0,069
Z13	0,068	0,066	0,067	0,063	0,068	0,067	0,070	0,069	0,069	0,068	0,068	0,068	0	0,062	0,060	0,069
Z14	0,069	0,063	0,070	0,059	0,069	0,071	0,067	0,064	0,063	0,069	0,068	0,067	0,065	0	0,070	0,065
Z15	0,068	0,061	0,070	0,062	0,070	0,071	0,065	0,064	0,061	0,071	0,070	0,066	0,064	0,071	0	0,065
Z16	0,068	0,068	0,067	0,065	0,068	0,067	0,068	0,069	0,068	0,068	0,068	0,069	0,069	0,061	0,058	0

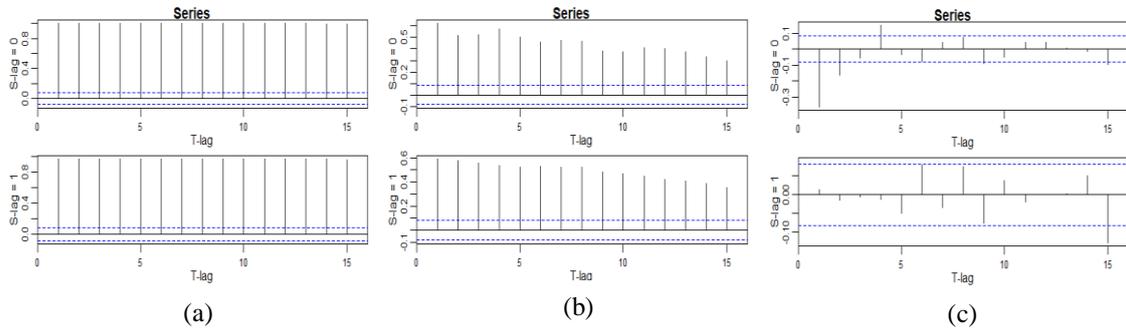
4.4 Identifikasi Model GSTAR

Identifikasi model GSTAR dilakukan dengan melihat plot MACF dan MPACF. Gambar 2 menunjukkan plot data asli, data setelah differencing pertama, dan data setelah differencing kedua.

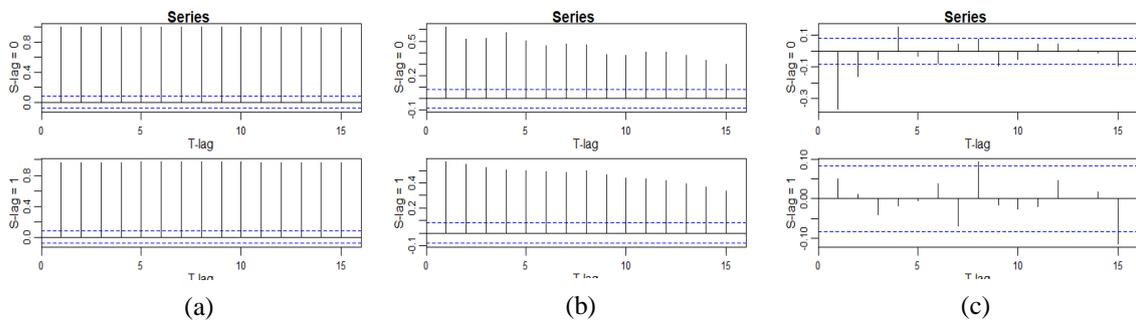


Gambar 2. Plot Data Asli (a), Data Hasil Differencing Pertama (b), dan Data Hasil Differencing Kedua (c)

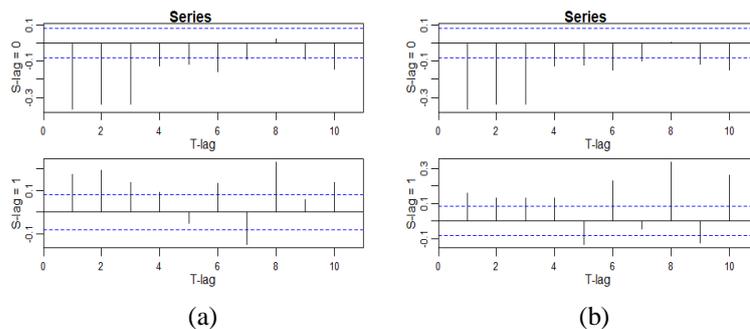
Gambar 3 menunjukkan grafik MACF pada bobot invers jarak, Gambar 4 menunjukkan grafik MACF pada bobot normalisasi korelasi silang, dan Gambar 5 menunjukkan grafik MPACF pada data hasil *differencing* kedua di masing-masing bobot.



Gambar 3. Grafik MACF Bobot Invers Jarak (a) Data Asli, (b) Data Hasil *Differencing* Pertama, (c) Data Hasil *Differencing* Kedua



Gambar 4. Grafik MACF Bobot Normalisasi Korelasi Silang (a) Data Asli, (b) Data Hasil *Differencing* Pertama, (c) Data Hasil *Differencing* Kedua



Gambar 5. Grafik MPACF setelah *Differencing* Kedua (a) Bobot Invers Jarak (b) Bobot Normalisasi Korelasi Silang

Pada Gambar 3(a) dan 4(a), grafik MACF menurun secara eksponensial. Hal ini menunjukkan data belum stasioner dan perlu dilakukan *differencing*. Data setelah dilakukan *differencing* pertama masih menurun secara eksponensial dan data setelah *differencing* kedua mengalami penurunan lag yang signifikan. Seluruh data IHPR dari 16 kota/wilayah sudah stasioner dalam *mean* setelah dilakukan *differencing* kedua.

Gambar 5 menunjukkan MPACF setelah *differencing* kedua di masing-masing bobot. Pada bobot invers jarak, MPACF *cut-off* di lag 1,2,3,4, dst pada spasial lag nol dan *cut-off* di lag 1,2,3,4, dst pada spasial lag satu. Pada bobot normalisasi korelasi silang, MPACF *cut-off* di lag 1,2,3,4, dst pada spasial lag nol dan *cut-off* di lag 1,2,3,4, dst pada

spasial lag satu. *Cut-off* yang beragam ini dapat dijadikan sebagai pembentuk orde model GSTAR. Karena banyaknya pilihan orde, maka ditentukan batas maksimal orde yaitu lima. Hal ini dikarenakan banyaknya parameter yang diestimasi bisa mencapai 160 dengan orde time lima dan spasial satu. Setelah ditentukan batas maksimum orde, maka dilakukan estimasi parameter model GSTAR pada lag 1,2,3, dan 4 (lag lima tidak *cut-off* di MPACF Bobot Invers Jarak). Selanjutnya dilakukan estimasi parameter model GSTAR(1;1), GSTAR(2;1,1), GSTAR(3;1,1,1) dan GSTAR(4;1,1,1,1). Pemilihan model terbaik didasarkan pada nilai MSE terkecil, pemenuhan asumsi model, dan bobot yang digunakan.

4.5 Estimasi Parameter Model

Estimasi parameter model GSTAR menggunakan *Ordinary Least Square* (OLS). Estimasi parameter dilakukan dengan membandingkan dua jenis bobot yaitu bobot invers jarak dan bobot normalisasi korelasi silang. Berikut ditampilkan nilai MSE hasil estimasi parameter pada masing-masing model:

Tabel 4. Nilai MSE pada Model GSTAR

Model	Matriks	Matriks Normalisasi
	Invers Jarak	Korelasi silang
GSTAR (1;1)	8,261	8,181
GSTAR (2;1,1)	7,204	7,167
GSTAR (3;1,1,1)	6,369	6,209
GSTAR (4;1,1,1,1)	5,806	5,689

4.6 Asumsi Model GSTAR

Hasil perhitungan *white noise* menggunakan portmanteau *multivariate test* untuk model GSTAR(1;1) ditampilkan pada Tabel 5.

Tabel 5. Hasil Portmanteau *Multivariate Test* Model GSTAR(1;1)

Lag	Bobot Invers Jarak		Bobot Normalisasi Korelasi Silang	
	Statistic(Q)	P-value	Statistic(Q)	P-value
1	12,500	0,003	11,438	0,003
2	78,233	0,001	82,468	0,001
3	112,230	0,001	116,402	0,001
4	131,318	0,001	135,671	0,001
5	144,776	0,001	148,503	0,001
6	158,449	0,001	163,276	0,001
7	168,660	0,001	174,109	0,001

Berdasarkan Tabel 5, dapat dilihat bahwa nilai *p-value* pada setiap lag memiliki nilai kurang dari $\alpha = 5\%$, sehingga H_0 ditolak dan residual di kedua bobot pada model GSTAR(1;1) tidak memenuhi asumsi *white noise*.

Asumsi residual normal multivariat menggunakan uji *multivariate* Kolmogorov Smirnov. Hasil pengujian menunjukkan bahwa H_0 diterima karena nilai *p-value* lebih besar dari $\alpha = 5\%$, sehingga jarak mahalnobis (d_i^2) mengikuti distribusi *chi square* pada derajat bebas $N=16$ dan residual data IHPR pada model GSTAR(1;1) berdistribusi normal *multivariate*.

Tabel 6. Hasil *Multivariate* Kolmogorov Smirnov Model GSTAR(1;1)

	Bobot Invers Jarak	Bobot Normalisasi Korelasi Silang
<i>P-value</i>	0,885	0,885

Dengan perhitungan yang sama diperoleh, untuk model GSTAR(2;1,1) tidak memenuhi asumsi *white noise* dan memenuhi asumsi normal *multivariate*. Model

GSTAR(3;1,1,1) memenuhi asumsi *white noise* dan memenuhi asumsi normal *multivariate* dan model GSTAR(4;1,1,1,1) memenuhi asumsi *white noise* dan memenuhi asumsi normal *multivariate*.

4.7 Uji Signifikansi Model

Pengujian signifikansi dilakukan setelah diperoleh nilai estimasi dari tiap parameter. H_0 ditolak jika terdapat $\Phi_{kl}^i \neq 0$ yaitu nilai estimasi parameter berbeda dengan nilai nol sehingga estimasi parameter secara keseluruhan signifikan. Karena nilai estimasi parameter yang didapat dari model GSTAR(1;1), GSTAR(2;1,1), GSTAR(3;1,1,1), dan GSTAR(4;1,1,1,1) secara keseluruhan ada yang berbeda dengan 0, maka secara keseluruhan parameternya signifikan.

4.8 Pemilihan Model Terbaik

Berdasarkan hasil estimasi parameter yang diperoleh dari keempat model GSTAR menggunakan bobot invers jarak dan normalisasi korelasi silang, maka dipilih model terbaik berdasarkan indikator pada Tabel 7.

Tabel 7. Pemilihan Model Terbaik

Bobot	Model	Asumsi <i>White Noise</i>	Asumsi Normal <i>Multivariate</i>	MSE
Invers Jarak	GSTAR(1;1)	Tidak terpenuhi	Terpenuhi	8,261
	GSTAR(2;1,1)	Tidak terpenuhi	Terpenuhi	7,204
	GSTAR(3;1,1,1)	Terpenuhi	Terpenuhi	6,369
	GSTAR(4;1,1,1,1)	Terpenuhi	Terpenuhi	5,806
Normalisasi Korelasi Silang	GSTAR(1;1)	Tidak terpenuhi	Terpenuhi	8,181
	GSTAR(2;1,1)	Tidak terpenuhi	Terpenuhi	7,167
	GSTAR(3;1,1,1)	Terpenuhi	Terpenuhi	6,209
	GSTAR(4;1,1,1,1)	Terpenuhi	Terpenuhi	5,689

Berdasarkan pemenuhan asumsi model dan nilai MSE gabungan terkecil, Model terbaik untuk data IHPR adalah model GSTAR(4;1,1,1,1) menggunakan bobot normalisasi korelasi silang.

4.9 Model Data IHPR menggunakan GSTAR(4;1,1,1,1)

Model GSTAR(4;1,1,1,1) menggunakan bobot normalisasi korelasi silang merupakan model terbaik untuk data IHPR di 16 kota/wilayah di Indonesia. Dengan menggunakan nilai estimasi parameter, maka diperoleh pemodelan menggunakan bobot normalisasi korelasi silang sebagai berikut:

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \\ Z_4(t) \\ Z_5(t) \\ Z_6(t) \\ Z_7(t) \\ Z_8(t) \\ Z_9(t) \\ Z_{10}(t) \\ Z_{11}(t) \\ Z_{12}(t) \\ Z_{13}(t) \\ Z_{14}(t) \\ Z_{15}(t) \\ Z_{16}(t) \end{bmatrix} = \begin{bmatrix} -0,415 \\ -0,582 \\ -1,095 \\ -0,940 \\ -0,874 \\ 0,088 \\ -0,211 \\ -0,635 \\ -0,477 \\ 0,033 \\ -0,553 \\ -0,804 \\ -0,578 \\ -0,785 \\ -0,497 \\ -0,392 \end{bmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \\ Z_4(t-1) \\ Z_5(t-1) \\ Z_6(t-1) \\ Z_7(t-1) \\ Z_8(t-1) \\ Z_9(t-1) \\ Z_{10}(t-1) \\ Z_{11}(t-1) \\ Z_{12}(t-1) \\ Z_{13}(t-1) \\ Z_{14}(t-1) \\ Z_{15}(t-1) \\ Z_{16}(t-1) \end{bmatrix} + \begin{bmatrix} 0 & -0,039 & -0,040 & -0,035 & -0,039 & -0,040 & -0,038 & -0,039 & -0,039 & -0,039 & -0,040 & -0,039 & -0,038 & -0,036 & -0,039 \\ -0,010 & 0 & -0,010 & -0,009 & -0,010 & -0,010 & -0,010 & -0,010 & -0,010 & -0,010 & -0,010 & -0,010 & -0,010 & -0,009 & -0,009 & -0,010 \\ -0,033 & -0,032 & 0 & -0,030 & -0,033 & -0,033 & -0,033 & -0,032 & -0,033 & -0,033 & -0,033 & -0,032 & -0,032 & -0,031 & -0,032 \\ 0,040 & 0,042 & 0,041 & 0 & 0,044 & 0,041 & 0,041 & 0,045 & 0,040 & 0,043 & 0,044 & 0,042 & 0,044 & 0,036 & 0,037 & 0,044 \\ -0,003 & -0,003 & -0,003 & -0,003 & 0 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 \\ -0,015 & -0,015 & -0,016 & -0,014 & -0,016 & 0 & -0,015 & -0,015 & -0,015 & -0,016 & -0,015 & -0,015 & -0,015 & -0,015 & -0,015 & -0,015 \\ 0,005 & 0,005 & 0,005 & 0,005 & 0,005 & 0,005 & 0 & 0,005 & 0,005 & 0,005 & 0,005 & 0,005 & 0,005 & 0,005 & 0,005 & 0,005 \\ 0,006 & 0,007 & 0,007 & 0,006 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,006 & 0,006 & 0,007 \\ 0,083 & 0,081 & 0,082 & 0,071 & 0,080 & 0,081 & 0,084 & 0,081 & 0 & 0,080 & 0,083 & 0,083 & 0,075 & 0,069 & 0,082 \\ -0,116 & -0,114 & -0,118 & -0,112 & -0,119 & -0,118 & -0,116 & -0,117 & -0,113 & 0 & -0,119 & -0,117 & -0,116 & -0,110 & -0,109 & -0,118 \\ 0,033 & 0,033 & 0,034 & 0,033 & 0,034 & 0,034 & 0,034 & 0,034 & 0,033 & 0,034 & 0 & 0,034 & 0,034 & 0,032 & 0,031 & 0,034 \\ 0,046 & 0,046 & 0,046 & 0,042 & 0,046 & 0,045 & 0,045 & 0,045 & 0,045 & 0,045 & 0 & 0,045 & 0,043 & 0,040 & 0,046 \\ 0,018 & 0,017 & 0,018 & 0,017 & 0,018 & 0,018 & 0,018 & 0,018 & 0,018 & 0,018 & 0,018 & 0 & 0,016 & 0,016 & 0,018 \\ -0,038 & -0,035 & -0,039 & -0,033 & -0,038 & -0,039 & -0,037 & -0,036 & -0,035 & -0,038 & -0,038 & -0,037 & -0,036 & 0 & -0,039 & -0,036 \\ -0,039 & -0,035 & -0,041 & -0,036 & -0,041 & -0,041 & -0,038 & -0,037 & -0,036 & -0,041 & -0,041 & -0,038 & -0,037 & -0,041 & 0 & -0,038 \\ 0,030 & 0,030 & 0,030 & 0,029 & 0,030 & 0,030 & 0,030 & 0,031 & 0,030 & 0,030 & 0,030 & 0,031 & 0,031 & 0,027 & 0,026 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \\ Z_4(t-1) \\ Z_5(t-1) \\ Z_6(t-1) \\ Z_7(t-1) \\ Z_8(t-1) \\ Z_9(t-1) \\ Z_{10}(t-1) \\ Z_{11}(t-1) \\ Z_{12}(t-1) \\ Z_{13}(t-1) \\ Z_{14}(t-1) \\ Z_{15}(t-1) \\ Z_{16}(t-1) \end{bmatrix} + \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \\ Z_4(t-1) \\ Z_5(t-1) \\ Z_6(t-1) \\ Z_7(t-1) \\ Z_8(t-1) \\ Z_9(t-1) \\ Z_{10}(t-1) \\ Z_{11}(t-1) \\ Z_{12}(t-1) \\ Z_{13}(t-1) \\ Z_{14}(t-1) \\ Z_{15}(t-1) \\ Z_{16}(t-1) \end{bmatrix}$$

$$\begin{bmatrix} -0,294 \\ -0,529 \\ -0,385 \\ -0,516 \\ -0,145 \\ -0,458 \\ -0,520 \\ -0,099 \\ -0,385 \\ -0,479 \\ -0,747 \\ -0,663 \\ -0,471 \\ -0,384 \\ -0,294 \\ -0,183 \end{bmatrix} \begin{bmatrix} Z_1(t-2) \\ Z_2(t-2) \\ Z_3(t-2) \\ Z_4(t-2) \\ Z_5(t-2) \\ Z_6(t-2) \\ Z_7(t-2) \\ Z_8(t-2) \\ Z_9(t-2) \\ Z_{10}(t-2) \\ Z_{11}(t-2) \\ Z_{12}(t-2) \\ Z_{13}(t-2) \\ Z_{14}(t-2) \\ Z_{15}(t-2) \\ Z_{16}(t-2) \end{bmatrix} + \begin{bmatrix} 0 & -0,003 & -0,003 & -0,002 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 \\ 0,026 & 0 & 0,025 & 0,024 & 0,026 & 0,025 & 0,025 & 0,025 & 0,025 & 0,025 & 0,025 & 0,025 & 0,025 & 0,025 & 0,025 & 0,025 & 0,025 \\ -0,001 & -0,001 & 0 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 & -0,001 \\ 0,072 & 0,076 & 0,074 & 0 & 0,079 & 0,074 & 0,074 & 0,081 & 0,072 & 0,078 & 0,079 & 0,075 & 0,079 & 0,065 & 0,066 & 0,079 & 0,079 \\ -0,007 & -0,007 & -0,007 & -0,007 & 0 & -0,007 & -0,007 & -0,007 & -0,007 & -0,007 & -0,007 & -0,007 & -0,007 & -0,007 & -0,006 & -0,007 & -0,007 \\ 0,012 & 0,011 & 0,012 & 0,011 & 0,012 & 0 & 0,011 & 0,011 & 0,012 & 0,012 & 0,011 & 0,011 & 0,011 & 0,011 & 0,011 & 0,011 & 0,011 \\ 0,008 & 0,008 & 0,008 & 0,007 & 0,008 & 0,008 & 0 & 0,008 & 0,008 & 0,008 & 0,008 & 0,008 & 0,008 & 0,008 & 0,008 & 0,007 & 0,008 \\ 0,006 & 0,006 & 0,006 & 0,006 & 0,006 & 0,006 & 0,006 & 0 & 0,006 & 0,006 & 0,006 & 0,006 & 0,006 & 0,006 & 0,005 & 0,005 & 0,006 \\ 0,040 & 0,039 & 0,039 & 0,034 & 0,038 & 0,039 & 0,040 & 0,039 & 0 & 0,038 & 0,038 & 0,040 & 0,039 & 0,036 & 0,033 & 0,039 & 0,039 \\ 0,021 & 0,020 & 0,021 & 0,020 & 0,021 & 0,021 & 0,021 & 0,021 & 0,020 & 0 & 0,021 & 0,021 & 0,020 & 0,020 & 0,020 & 0,021 & 0,021 \\ -0,160 & -0,157 & -0,162 & -0,156 & -0,164 & -0,161 & -0,161 & -0,161 & -0,157 & -0,164 & 0 & -0,162 & -0,161 & -0,151 & -0,149 & -0,163 & -0,163 \\ 0,056 & 0,055 & 0,056 & 0,051 & 0,055 & 0,055 & 0,055 & 0,055 & 0,055 & 0,055 & 0 & 0,055 & 0,052 & 0,049 & 0,056 & 0,056 & 0,056 \\ 0,033 & 0,032 & 0,033 & 0,031 & 0,033 & 0,032 & 0,034 & 0,033 & 0,033 & 0,033 & 0,033 & 0 & 0,030 & 0,029 & 0,033 & 0,033 & 0,033 \\ -0,024 & -0,023 & -0,025 & -0,021 & -0,025 & -0,025 & -0,024 & -0,023 & -0,023 & -0,025 & -0,024 & -0,024 & -0,023 & 0 & -0,025 & -0,023 & -0,023 \\ -0,037 & -0,034 & -0,038 & -0,034 & -0,039 & -0,039 & -0,036 & -0,034 & -0,039 & -0,039 & -0,036 & -0,035 & -0,039 & 0 & -0,036 & -0,036 & -0,036 \\ -0,005 & -0,005 & -0,005 & -0,004 & -0,005 & -0,005 & -0,005 & -0,005 & -0,005 & -0,005 & -0,005 & -0,005 & -0,005 & -0,004 & -0,004 & 0 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-2) \\ Z_2(t-2) \\ Z_3(t-2) \\ Z_4(t-2) \\ Z_5(t-2) \\ Z_6(t-2) \\ Z_7(t-2) \\ Z_8(t-2) \\ Z_9(t-2) \\ Z_{10}(t-2) \\ Z_{11}(t-2) \\ Z_{12}(t-2) \\ Z_{13}(t-2) \\ Z_{14}(t-2) \\ Z_{15}(t-2) \\ Z_{16}(t-2) \end{bmatrix} + \begin{bmatrix} -0,182 \\ -0,366 \\ 0,043 \\ -0,229 \\ -0,124 \\ -0,069 \\ -0,011 \\ 0,169 \\ -0,469 \\ 0,209 \\ -0,415 \\ -0,457 \\ -0,583 \\ -0,172 \\ 0,059 \\ -0,073 \end{bmatrix} \begin{bmatrix} Z_1(t-3) \\ Z_2(t-3) \\ Z_3(t-3) \\ Z_4(t-3) \\ Z_5(t-3) \\ Z_6(t-3) \\ Z_7(t-3) \\ Z_8(t-3) \\ Z_9(t-3) \\ Z_{10}(t-3) \\ Z_{11}(t-3) \\ Z_{12}(t-3) \\ Z_{13}(t-3) \\ Z_{14}(t-3) \\ Z_{15}(t-3) \\ Z_{16}(t-3) \end{bmatrix} + \begin{bmatrix} 0 & -0,075 & -0,077 & -0,066 & -0,075 & -0,076 & -0,077 & -0,074 & -0,075 & -0,076 & -0,075 & -0,077 & -0,074 & -0,073 & -0,069 & -0,076 & -0,076 \\ 0,039 & 0 & 0,038 & 0,036 & 0,039 & 0,038 & 0,038 & 0,038 & 0,038 & 0,038 & 0,038 & 0,038 & 0,038 & 0,038 & 0,038 & 0,038 & 0,038 \\ 0,018 & 0,017 & 0 & 0,016 & 0,018 & 0,018 & 0,018 & 0,018 & 0,017 & 0,018 & 0,018 & 0,018 & 0,018 & 0,018 & 0,017 & 0,017 & 0,018 \\ 0,067 & 0,071 & 0,069 & 0 & 0,074 & 0,069 & 0,069 & 0,067 & 0,067 & 0,073 & 0,073 & 0,073 & 0,073 & 0,073 & 0,061 & 0,062 & 0,074 \\ 0,028 & 0,028 & 0,029 & 0,027 & 0 & 0,029 & 0,028 & 0,029 & 0,027 & 0,029 & 0,029 & 0,028 & 0,028 & 0,027 & 0,027 & 0,029 & 0,029 \\ 0,025 & 0,024 & 0,025 & 0,022 & 0,025 & 0 & 0,024 & 0,024 & 0,024 & 0,025 & 0,025 & 0,025 & 0,024 & 0,024 & 0,024 & 0,024 & 0,024 \\ 0,012 & 0,011 & 0,012 & 0,010 & 0,012 & 0,012 & 0 & 0,012 & 0,012 & 0,012 & 0,012 & 0,012 & 0,012 & 0,011 & 0,010 & 0,010 & 0,012 \\ 0,003 & 0,003 & 0,003 & 0,002 & 0,003 & 0,003 & 0,003 & 0 & 0,003 & 0,003 & 0,003 & 0,003 & 0,003 & 0,002 & 0,002 & 0,003 & 0,003 \\ 0,041 & 0,040 & 0,040 & 0,035 & 0,040 & 0,040 & 0,041 & 0,040 & 0 & 0,040 & 0,039 & 0,041 & 0,041 & 0,037 & 0,034 & 0,041 & 0,041 \\ -0,067 & -0,065 & -0,068 & -0,065 & -0,068 & -0,068 & -0,067 & -0,067 & -0,065 & 0 & -0,068 & -0,067 & -0,067 & -0,063 & -0,063 & -0,068 & -0,068 \\ 0,021 & 0,021 & 0,022 & 0,021 & 0,022 & 0,022 & 0,022 & 0,022 & 0,021 & 0,022 & 0 & 0,022 & 0,022 & 0,020 & 0,020 & 0,022 & 0,022 \\ 0,018 & 0,018 & 0,018 & 0,016 & 0,018 & 0,017 & 0,018 & 0,017 & 0,017 & 0,017 & 0,017 & 0 & 0,017 & 0,016 & 0,015 & 0,018 & 0,018 \\ 0,028 & 0,027 & 0,027 & 0,026 & 0,027 & 0,027 & 0,028 & 0,028 & 0,028 & 0,027 & 0,027 & 0,028 & 0 & 0,025 & 0,024 & 0,028 & 0,028 \\ -0,041 & -0,038 & -0,042 & -0,035 & -0,042 & -0,042 & -0,040 & -0,038 & -0,038 & -0,042 & -0,041 & -0,040 & -0,039 & 0 & -0,042 & -0,039 & -0,039 \\ -0,044 & -0,040 & -0,046 & -0,041 & -0,046 & -0,046 & -0,043 & -0,042 & -0,040 & -0,047 & -0,046 & -0,040 & -0,042 & -0,046 & 0 & -0,043 & -0,043 \\ -0,009 & -0,010 & -0,009 & -0,009 & -0,009 & -0,009 & -0,010 & -0,010 & -0,009 & -0,009 & -0,009 & -0,010 & -0,010 & -0,009 & -0,008 & 0 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-3) \\ Z_2(t-3) \\ Z_3(t-3) \\ Z_4(t-3) \\ Z_5(t-3) \\ Z_6(t-3) \\ Z_7(t-3) \\ Z_8(t-3) \\ Z_9(t-3) \\ Z_{10}(t-3) \\ Z_{11}(t-3) \\ Z_{12}(t-3) \\ Z_{13}(t-3) \\ Z_{14}(t-3) \\ Z_{15}(t-3) \\ Z_{16}(t-3) \end{bmatrix} + \begin{bmatrix} -0,239 \\ -0,286 \\ -0,006 \\ 0,095 \\ -0,238 \\ -0,238 \\ -0,197 \\ 0,127 \\ -0,306 \\ -0,172 \\ -0,044 \\ -0,286 \\ 0,112 \\ -0,280 \\ -0,040 \\ -0,106 \\ -0,105 \end{bmatrix} \begin{bmatrix} Z_1(t-4) \\ Z_2(t-4) \\ Z_3(t-4) \\ Z_4(t-4) \\ Z_5(t-4) \\ Z_6(t-4) \\ Z_7(t-4) \\ Z_8(t-4) \\ Z_9(t-4) \\ Z_{10}(t-4) \\ Z_{11}(t-4) \\ Z_{12}(t-4) \\ Z_{13}(t-4) \\ Z_{14}(t-4) \\ Z_{15}(t-4) \\ Z_{16}(t-4) \end{bmatrix} + \begin{bmatrix} 0 & 0,027 & 0,028 & 0,024 & 0,028 & 0,028 & 0,028 & 0,027 & 0,027 & 0,028 & 0,028 & 0,028 & 0,027 & 0,027 & 0,025 & 0,028 & 0,028 \\ -0,022 & 0 & -0,022 & -0,021 & -0,022 & -0,022 & -0,022 & -0,022 & -0,022 & -0,022 & -0,022 & -0,022 & -0,022 & -0,022 & -0,020 & -0,019 & -0,023 \\ 0,071 & 0,069 & 0 & 0,065 & 0,072 & 0,072 & 0,071 & 0,069 & 0,069 & 0,072 & 0,071 & 0,071 & 0,071 & 0,069 & 0,069 & 0,067 & 0,071 \\ 0,026 & 0,027 & 0,026 & 0 & 0,028 & 0,027 & 0,026 & 0,029 & 0,026 & 0,028 & 0,028 & 0,027 & 0,028 & 0,023 & 0,024 & 0,028 & 0,028 \\ 0,034 & 0,034 & 0,035 & 0,033 & 0 & 0,035 & 0,034 & 0,034 & 0,033 & 0,035 & 0,035 & 0,034 & 0,034 & 0,033 & 0,033 & 0,032 & 0,034 \\ 0,024 & 0,023 & 0,024 & 0,022 & 0,024 & 0 & 0,023 & 0,023 & 0,023 & 0,024 & 0,024 & 0,024 & 0,023 & 0,023 & 0,023 & 0,023 & 0,023 \\ 0,009 & 0,009 & 0,009 & 0,008 & 0,009 & 0,009 & 0 & 0,009 & 0,009 & 0,009 & 0,009 & 0,009 & 0,009 & 0,009 & 0,008 & 0,008 & 0,009 \\ -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & 0 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 & -0,003 \\ 0,005 & 0,005 & 0,005 & 0,004 & 0,005 & 0,005 & 0,005 & 0,005 & 0 & 0,005 & 0,005 & 0,005 & 0,005 & 0,004 & 0,004 & 0,005 & 0,005 \\ 0,041 & 0,040 & 0,042 & 0,040 & 0,042 & 0,042 & 0,041 & 0,041 & 0,040 & 0 & 0,042 & 0,041 & 0,041 & 0,039 & 0,039 & 0,042 & 0,042 \\ -0,087 & -0,086 & -0,088 & -0,085 & -0,089 & -0,088 & -0,088 & -0,089 & -0,086 & -0,090 & 0 & -0,088 & -0,088 & -0,082 & -0,081 & -0,089 & -0,089 \\ 0,068 & 0,068 & 0,068 & 0,067 & 0,067 & 0,067 & 0,067 & 0,067 & 0,067 & 0,067 & 0,067 & 0 & 0,067 & 0,067 & 0,063 & 0,060 & 0,068 \\ 0,011 & 0,011 & 0,011 & 0,010 & 0,011 & 0,011 & 0,011 & 0,011 & 0,011 & 0,011 & 0,011 & 0,011 & 0,011 & 0 & 0,010 & 0,010 & 0,011 \\ 0,010 & 0,010 & 0,011 & 0,009 & 0,010 & 0,011 & 0,010 & 0,010 & 0,010 & 0,010 & 0,010 & 0,010 & 0,010 & 0 & 0,011 & 0,010 & 0,010 \\ -0,060 & -0,054 & -0,062 & -0,055 & -0,062 & -0,062 & -0,058 & -0,057 & -0,054 & -0,063 & -0,062 & -0,058 & -0,057 & -0,062 & 0 & -0,057 & -0,057 \\ 0,007 & 0,007 & 0,007 & 0,006 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,007 & 0,006 & 0,006 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-4) \\ Z_2(t-4) \\ Z_3(t-4) \\ Z_4(t-4) \\ Z_5(t-4) \\ Z_6(t-4) \\ Z_7(t-4) \\ Z_8(t-4) \\ Z_9(t-4) \\ Z_{10}(t-4) \\ Z_{11}(t-4) \\ Z_{12}(t-4) \\ Z_{13}(t-4) \\ Z_{14}(t-4) \\ Z_{15}(t-4) \\ Z_{16}(t-4) \end{bmatrix}$$

4.10 Peramalan Menggunakan Model GSTAR terbaik

Model terbaik yaitu model GSTAR(4;1,1,1,1) menggunakan bobot normalisasi korelasi silang. Model digunakan untuk meramalkan data IHPR pada tahun 2021 triwulan keempat dan tahun 2022 triwulan pertama. Peramalan yang dilakukan di masing-masing lokasi ditampilkan pada Tabel 8.

Tabel 8. Hasil Peramalan dan Perbandingan dengan Data Aktual

Kota/ Wilayah	Kuartil IV Tahun 2021		Kuartil I Tahun 2022	
	Aktual	Peramalan	Aktual*	Peramalan
	Bandung	287,720	287,073	287,720
Bandar Lampung	206,650	206,780	206,650	206,398
Banjarmasin	230,234	231,401	231,172	232,117
Denpasar	189,510	189,766	189,789	190,062
Palembang	263,436	265,381	263,436	266,470
Semarang	207,300	207,302	207,334	207,686
Yogyakarta	217,577	218,797	219,563	221,052
Padang	198,585	198,263	198,810	198,254
Medan	278,852	279,003	279,193	280,277
Makassar	343,810	346,592	343,882	349,323
Manado	352,631	353,938	355,072	363,246
Surabaya	353,680	351,492	358,913	349,032
Pontianak	180,502	182,169	180,180	184,696
Batam	139,679	141,983	138,105	143,335
Balikpapan	119,788	120,529	119,899	121,115
Jabodebek-Banten	231,472	230,368	231,472	230,929
MSE		1,960		16,136

Berdasarkan Tabel 8, pada triwulan keempat tahun 2021 selisih data aktual dan peramalan terbesar berada di kota Makassar, Surabaya, dan Batam. Nilai MSE pada data IHPR kuartil I tahun 2022 memiliki MSE yang lebih besar dari data IHPR kuartil IV tahun 2021 dikarenakan data tersebut masih data perkiraan dari Bank Indonesia. . Data IHPR terbesar pada hasil peramalan terdapat di kota Makassar, Manado dan Surabaya sementara data IHPR terkecil terdapat di kota Balikpapan. Secara keseluruhan, data hasil peramalan dan data aktual memiliki nilai MSE yang kecil. Karena data aktual dan data peramalan memiliki nilai MSE yang kecil, dapat diambil kesimpulan bahwa metode GSTAR adalah metode yang efektif dalam meramalkan data IHPR di 16 kota/wilayah di Indonesia.

5. KESIMPULAN

Pemodelan terbaik untuk data Indeks Harga Properti Residensial (IHPR) yaitu menggunakan model GSTAR(4;1,1,1,1) bobot normalisasi korelasi silang. MSE yang diperoleh sebesar 5,689. Asumsi model GSTAR terpenuhi yaitu residual *white noise multivariate* dan residual normal *multivariate*. Karena data aktual dan data peramalan memiliki nilai MSE yang kecil, dapat diambil kesimpulan bahwa metode GSTAR adalah metode yang efektif dalam meramalkan data IHPR di 16 kota/wilayah di Indonesia.

DAFTAR PUSTAKA

- Bekti, R.D. dan Pratiwi, N. 2016. *Metode Spatio-Temporal Untuk Peramalan*. Institut Sains & Teknologi Akprind Yogyakarta. Yogyakarta: 42/SPP/LPPM/PL/IV/2016.
- Bohling, G. 2006. Classical Normal-Based Discriminant Analysis, *Scientist*, (March), pp. 1–24.
- Buhaerah, P. 2019. Pengaruh Kredit Pemilikan Rumah terhadap Keterjangkauan Harga Properti Residensial, *Kajian Ekonomi Keuangan*, 3(3), pp. 182–197.
- Departemen Statistik. 2021. *Survey Harga Properti Residensial di Pasar Primer- Triwulan III 2021*. <https://www.bi.go.id/id/publikasi/laporan/Pages/SHPR-Triwulan-III-2021.aspx>. Diakses pada 1 September 2021.
- Faizah, L.A. dan Setiawan. 2013. Pemodelan Inflasi di Kota Semarang, Yogyakarta dan Surakarta dengan Pendekatan GSTAR. *Jurnal Sains dan Seni Pomits*. Vol.2. No.2.
- Halim, S. dan Chandra, A. (2011). Pemodelan Time Series Multivariat secara Otomatis, *Jurnal Teknik Industri*, 13(1). doi: 10.9744/jti.13.1.19-26.
- Laksono, M.Y. 2022. *Backlog Rumah Membengkak Jadi 12,75 Juta, Apa Langkah Pemerintah?*. Kompas.com. <https://www.kompas.com/properti/read/2022/02/06/151343121/backlog-rumah-membengkak-jadi-1275-juta-apa-langkah-pemerintah?page=all>. Diakses: 20 Maret 2022.
- Pfeifer, P. E. dan Deutsch, S. J. 1980. *A Three Stage Iterative Procedure for Space- Time Modeling*, *Technometrics* 22, 35-47.
- Ruchjana, B. N., Borovkova, S. A., dan Lopuhaa, H. P. 2012. *Least Squares Estimation of Generalized Space Time AutoRegressive (GSTAR) Model and its Properties*, *AIP Conference Proceedings*, 1450(October 2014), pp. 61–64. doi: 10.1063/1.4724118.
- Shofiyah, M.A. 2009. *Peramalan Data Produksi Gas di Joint Operating Body Pertamina Petrochina East Java (JOB P-PEJ) dengan Model GSTAR dan ARIMA*.
- Suhartono dan Atok, R.M. 2006. *Pemilihan Bobot Lokasi yang Optimal pada model GSTAR*. Presented at National Mathematics Conference XIII. Semarang: Universitas Negeri Semarang.
- Suhartono dan Subanar. 2007. Some Comments on the Theorem Providing Stasionerity

- Condition for GSTAR Models in The Paper by Borovkova et al. *Journal of The Indonesian Mathematical Society (MIHMI)*, No.13, Vo.1: 44-52.
- Talungke, Y., Nainggolan, N., dan Hatidja, D. 2015. *Model Generalized Space Time Autoregressive (GSTAR) dengan Analisis Data Menggunakan Software R*, d'CARTESIAN, 4(2), p. 122. doi: 10.35799/dc.4.2.2015.8649.
- Tsay, R.S. 2005. *Analysis of Financial Time series*. John Wiley & Sons. New Jersey.
- Wei, W. W. S. 2006. *Time Series Analysis : Univariate and Multivariate Methods*, (January 1989). doi: 10.2307/2289741.
- Wutsqa, D. U., Suhartono, dan Sutijo, B. 2010. *Generalized Space-Time Autoregressive Modeling*, Procee-dings of the 6th IMT-GT Conference on Mathematics, Statistics and its Application (ICMSA 2010, University Tunku Abdul Rahman, Malaysia).
- Zahro, J. 2017. Price Estimation of Red Chili Pepper by Using Generalized Space ime Autoregressive (G-STAR)', (July). <https://www.researchgate.net/publication/318110071>.