

## Pemodelan *Generalized Space Time Autoregressive* untuk Meramalkan Data Inflasi Bulanan di Provinsi Jawa Barat

Hikma Abdia<sup>1</sup>, Tiara Annisa Akhsan<sup>2</sup>, Anisa Kalondeng<sup>3</sup>, Siswanto Siswanto<sup>4</sup>

<sup>1,2,3,4</sup> Program Studi Statistika, Universitas Hasanuddin

<sup>1,2,3,4</sup> Jl. Perintis Kemerdekaan KM.10, Kota Makassar, Sulawesi Selatan, 90245

Email: [abdiahikma03@gmail.com](mailto:abdiahikma03@gmail.com)<sup>1</sup>, [tiaraannisaakhsan@gmail.com](mailto:tiaraannisaakhsan@gmail.com)<sup>2</sup>, [nkalondeng@gmail.com](mailto:nkalondeng@gmail.com)<sup>3</sup>, [siswanto@unhas.ac.id](mailto:siswanto@unhas.ac.id)<sup>4</sup>

Korespondensi penulis : [siswanto@unhas.ac.id](mailto:siswanto@unhas.ac.id)

### Abstrak

Inflasi adalah penurunan nilai uang akibat kenaikan nilai barang dan jasa secara terus-menerus. Inflasi juga merupakan fenomena ekonomi yang sangat mempengaruhi kehidupan sehari-hari masyarakat dan stabilitas ekonomi sebuah negara. Untuk menjaga stabilitas harga dan pertumbuhan ekonomi, penting untuk memantau dan meramalkan tingkat inflasi. Metode *Generalized Space Time Autoregressive* (GSTAR) adalah metode yang mampu meramalkan tingkat inflasi dengan melibatkan keterkaitan antar lokasi dan waktu. Data yang digunakan pada penelitian ini adalah data inflasi 7 kota di Jawa Barat yaitu Kota Bandung, Bekasi, Bogor, Cirebon, Depok, Sukabumi dan Tasikmalaya pada bulan Januari 2018 hingga Desember 2022. Tujuan dari penelitian ini adalah memperoleh model dan hasil peramalan GSTAR terbaik berdasarkan data inflasi di tujuh kota di Jawa Barat. Berdasarkan hasil penelitian model GSTAR  $(1_1)I(1)$  nilai MSE dan nilai MAPE data komposit 80:20 pada data training yaitu 0.12% dan 12.20%, dan diperoleh hasil peramalan enam kota relatif naik dan satu kota mengalami penurunan. Sehingga model terbaik untuk data inflasi tujuh kota di Jawa Barat yaitu model GSTAR  $(1_1)I(1)$  dengan bobot lokasi seragam.

**Kata Kunci:** *Generalized Space Time Autoregressive*, Inflasi, MAPE, MSE

### Abstract

*Inflation is the decline in the value of money due to the continuous increase in the value of goods and services. Inflation is also an economic phenomenon that greatly affects people's daily lives and the economic stability of a country. To maintain price stability and economic growth, it is important to monitor and forecast the inflation rate. The Generalized Space Time Autoregressive (GSTAR) method is a method that is able to forecast inflation rates involving interrelationships between location and time. The data used in this study is inflation data for 7 cities in West Java, namely Bandung, Bekasi, Bogor, Cirebon, Depok, Sukabumi and Tasikmalaya in January 2018 to December 2022. This purpose of this study is to obtain the*

best GSTAR model and forecasting results based on inflation data in seven cities in West Java. Based on the research results, the GSTAR ( $\mathbf{1}_1$ ) $\mathbf{I}(1)$  model, the MSE value and MAPE value of the 80:20 which is 0.12% and 12.20%, and the forecast results obtained for six cities relatively increased and one city experienced a decline. So that the best model for inflation data of seven cities in West Java is the GSTAR ( $\mathbf{1}_1$ ) $\mathbf{I}(1)$  model with uniform location location weights.

**Keywords:** Generalized Space Time Autoregressive, Inflation, MAPE, MSE

## 1. Pendahuluan

Inflasi dapat diartikan sebagai penurunan nilai mata uang berdasarkan nilai total barang dan jasa. Hal tersebut disebabkan oleh fakta bahwa inflasi adalah suatu tren kenaikan harga barang dan jasa yang berlangsung secara konsisten [1]. Inflasi juga merupakan fenomena ekonomi yang sangat mempengaruhi kehidupan sehari-hari masyarakat dan stabilitas ekonomi sebuah negara [2]. Berdasarkan 82 kota yang digunakan untuk menghitung inflasi negara, Jawa Barat termasuk provinsi yang paling informatif, karena memiliki tujuh kota yaitu Bandung, Bekasi, Bogor, Cirebon, Depok, Sukabumi dan Tasikmalaya yang memberikan tunjangan inflasi daerah untuk membentuk inflasi negara. Oleh karena itu, Jawa Barat merupakan salah satu provinsi yang berpengaruh signifikan terhadap laju inflasi negara [3]. Guna menciptakan kebijakan moneter dan fiskal yang tepat untuk menjaga stabilitas harga dan pertumbuhan ekonomi, maka penting untuk memantau dan meramalkan tingkat inflasi di kota-kota tersebut [4].

Model yang paling umum digunakan dalam peramalan adalah model *time series*, model yang memperhatikan data sebelumnya secara berurutan pada interval waktu yang sama seperti harian, mingguan, bulanan, atau tahunan. Model *Space Time Autoregressive* (STAR) umumnya digunakan untuk menghubungkan deret waktu dengan lokasi [5]. Akan tetapi, model *Generalized Space Time Autoregressive* (GSTAR) adalah perkembangan dari model STAR karena parameter *autoregressive* diasumsikan memiliki nilai yang sama di semua lokasi [6]. Model GSTAR lebih fleksibel dibandingkan model STAR, karena parameter *autoregressive* yang dihipotesiskan mempunyai lokasi yang berbeda, sehingga cocok untuk lokasi dengan karakteristik heterogen [7].

Penelitian terdahulu yang dilakukan oleh Gama (2017) yang membandingkan efektivitas model STAR dan GSTAR dalam meramalkan tingkat inflasi di wilayah Dumai, Pekanbaru, dan Batam. Hasilnya menunjukkan bahwa model STAR memiliki nilai (1,1) dan GSTAR memiliki nilai (1,1) berdasarkan perhitungan MAE dan RMSE yang berarti ramalan inflasi Kota Batam lebih baik dengan bobot korelasi silang normalisasi STAR. Selain itu penelitian yang dilakukan oleh Talungke, Nainggolan dan Hatidja (2015) menganalisis data inflasi menggunakan model GSTAR pada tiga lokasi yang berbeda. Penelitian tersebut menemukan bahwa model GSTAR yang dihasilkan mampu memprediksi data inflasi di ketiga kota tersebut dengan cukup baik.

Permasalahan utama dengan model GSTAR adalah penentuan dan pemilihan bobot lokasi. Pada model inflasi GSTAR pembobot lokasi invers jarak dapat digunakan. Hal tersebut diperoleh dengan normalisasi nilai-nilai jarak invers antar lokasi. Oleh

karena itu, dengan menggunakan bobot lokasi *invers* jarak 7 lokasi di Jawa Barat yaitu Bandung, Bekasi, Bogor, Cirebon, Depok, Sukabumi dan Tasikmalaya, diharapkan model ini menghasilkan model GSTAR terbaik yang menggambarkan keterkaitan waktu dan lokasi dengan memperhatikan nilai kesalahan peramalan terkecil [8].

## 2. Metode Penelitian

Penelitian ini menggunakan data sekunder yang diperoleh dari publikasi Badan Pusat Statistik. Penelitian ini menggunakan data Inflasi tujuh kota di Jawa Barat yaitu Kota Bandung, Bekasi, Bogor, Cirebon, Depok, Sukabumi dan Tasikmalaya. Data yang diambil merupakan data pada periode Januari 2018 hingga Desember 2022. Penelitian ini menerapkan model GSTAR dengan pembobot lokasi seragam. Langkah-langkah berikut diambil untuk menganalisis data dalam penelitian ini:

### 1) Statistik Deskriptif

Analisis ini bertujuan untuk menyajikan gambaran umum tentang perubahan harga-harga di berbagai sektor ekonomi pada kota-kota di Jawa Barat serta memberikan wawasan yang lebih mendalam mengenai faktor-faktor yang memengaruhi inflasi di tingkat lokal. Analisis ini juga mendukung perumusan kebijakan ekonomi yang lebih efektif dan berkelanjutan. Dengan demikian, analisis ini tidak hanya merinci data inflasi secara terperinci namun juga memberikan kontribusi pada pemahaman yang lebih luas terkait dinamika ekonomi di wilayah tersebut.

### 2) Menghitung Koefisien Korelasi Antar Lokasi

Hubungan inflasi antar lokasi diukur dengan koefisien korelasi. Dua variabel dianggap saling berkorelasi apabila terjadi perubahan pada salah satu variabel yang diikuti oleh perubahan yang teratur menuju arah positif atau negatif. Koefisien korelasinya berkisar dari -1 hingga 1. Jika  $\rho = 0$ , maka tidak ada korelasi antara dua lokasi. Jika  $\rho < 0$ , maka terdapat korelasi negatif antara dua lokasi, sedangkan jika  $\rho > 0$ , maka terdapat korelasi positif antara dua lokasi. Adanya korelasi yang sempurna ditunjukkan oleh nilai koefisien korelasi mendekati satu [9].

### 3) Memeriksa Heterogenitas Spasial

Indeks gini pertama kali diperkenalkan oleh seorang statistikawan Italia, yaitu Corrado Gini (1884-1965) dengan tujuan untuk mempelajari keragaman diberbagai lokasi. Indeks Gini merupakan suatu koefisien yang menunjukkan sejauh mana distribusi homogen. Penggunaan Indeks Gini dilakukan untuk membandingkan perubahan baik antar periode waktu maupun antar lokasi. Statistik uji indeks gini terdapat pada persamaan (1).

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

Jika  $Z_i$  adalah nilai pengamatan pada lokasi ke-  $i$ ,  $\bar{Z}_i(t)$  adalah nilai rata-rata, dan  $T$  merupakan total jumlah pengamatan. Jika nilai indeks gini adalah 1 maka  $H_0$  ditolak [10].

#### 4) Memeriksa Kestasioneran Data Tiap Lokasi

Tujuan dari memeriksa kestasioneran data tiap lokasi adalah untuk menentukan apakah koefisien tertentu dalam model *Vector Autoregressive* (VAR) yang diramalkan memiliki nilai yang sama dengan satu atau tidak. Salah satu metode yang digunakan adalah uji *augmented Dickey-Fuller* (ADF), yang dapat memberikan informasi tentang stasioneran data dengan kriteria keputusan pada taraf signifikansi  $(1 - \alpha)100\%$  [11]. Dengan mengimplementasikan uji ini, penelitian ini berusaha untuk memvalidasi kecocokan model VAR dengan data empiris di berbagai lokasi, sehingga dapat memberikan dasar yang kuat untuk analisis dan interpretasi hasil ramalan.

#### 5) Mengidentifikasi Orde Model GSTAR

Ordo *autoregressive* dan ordo spasial digunakan dalam model GSTAR. Penentuan orde spasial hanya terbatas pada orde spasial satu, karena penginterpretasian orde spasial lebih dari satu sulit dilakukan. Namun, modFel VAR(p) dengan nilai AIC terkecil dapat digunakan untuk menentukan orde *autoregressive* [12].

#### 6) Menghitung Bobot Lokasi Model GSTAR

Bobot lokasi yang baik adalah ketika model dengan memiliki kesalahan prediksi yang kecil. Nilai pembobot harus memenuhi syarat  $w_{ij}^k = 0$  dan  $\sum_{i \neq j} w_{ij}^k = 1; i = 1, 2, \dots, N$ . Pembobot lokasi yang digunakan pada penelitian ini yaitu bobot lokasi seragam. Matriks pembobotnya dapat didefinisikan pada persamaan (2) [13].

$$W = [w_{ij}] = \begin{bmatrix} 0 & w_{12} & \dots & w_{1n} \\ w_{21} & 0 & \dots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{N2} & w_{N2} & \dots & 0 \end{bmatrix} \quad \#(2)$$

#### 7) Mengestimasi Parameter Model GSTAR

Metode kuadrat terkecil atau yang dikenal sebagai *Least Square Method* (LSM), merupakan pendekatan yang efektif untuk mengestimasi parameter dalam model *autoregressive* GSTAR. Model ini dapat dijelaskan sebagai suatu model linier yang mencerminkan hubungan antara variabel-variabel yang terlibat. Dengan menggunakan LSM, vektor parameter dapat diestimasi dengan meminimalkan jumlah kuadrat dari selisih antara nilai observasi aktual dan nilai yang diprediksi oleh model. Proses estimasi parameter ini dapat didefinisikan secara matematis pada persamaan (3), yang memberikan dasar bagi penentuan nilai-nilai parameter yang optimal untuk mencapai kesesuaian terbaik antara model dan data observasional [14]

$$\bar{\beta} = [X'X]^{-1}X'Y \quad \#(3)$$

### 8) Menguji kelayakan model

Uji kelayakan model dilakukan setelah melakukan estimasi parameter untuk model GSTAR. Uji dilakukan dengan menggunakan uji asumsi *white noise*, di mana uji *Ljung-Box* dipilih sebagai metode evaluasi. Proses pengujian menggunakan statistik uji *Ljung-Box Pearce* yang dapat ditemukan pada persamaan (4) [15]. Hasil dari uji ini menjadi kunci dalam menilai sejauh mana model GSTAR mampu menggambarkan keadaan *white noise* yang diinginkan, memberikan pemahaman yang lebih mendalam terkait validitas dan kehandalan model yang telah diestimasi.

$$Q = n(n + 2) \sum_{k=1}^K \frac{\rho_k^2}{n - k} \quad \#(4)$$

dengan,

$Q$  : Statistik uji *Ljung Box Pearce*

$n$  : Banyak data

$K$  : Banyak lag yang diuji

### 9) Menentukan Model GSTAR Terbaik

Pentingnya nilai akurasi dalam peramalan menjadi kriteria utama dalam menilai dan memilih metode yang paling optimal. Dalam menentukan model terbaik untuk *Generalized Space-Time Autoregressive* (GSTAR), digunakanlah dua parameter utama, yaitu *Mean Square Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE). Kedua ukuran kesalahan peramalan ini menjadi penentu utama dalam memilih model GSTAR yang memberikan hasil yang paling akurat dan dapat diandalkan. Dengan memperhatikan nilai-nilai tersebut, dapat dipastikan bahwa penilaian terhadap akurasi peramalan menjadi langkah kritis dalam mengevaluasi dan meningkatkan metode peramalan yang digunakan.

#### a) *Mean Square Error* (MSE)

Keakuratan nilai estimasi model dapat diukur melalui bentuk kesalahan kuadrat rata-rata yang dihitung menggunakan *Mean Squared Error* (MSE). Proses penghitungan kesalahan ini melibatkan langkah-langkah seperti pengkuadratan setiap nilai kesalahan, penjumlahan hasil pengkuadratan, dan pembagian total kesalahan dengan jumlah pengamatan. Persamaan matematis yang merepresentasikan proses ini dapat ditemukan pada persamaan (5). Dengan menggunakan MSE, kita dapat menggambarkan sejauh mana model memberikan estimasi yang akurat dengan mempertimbangkan seluruh data pengamatan [15].

$$MSE = \frac{\sum e_i^2}{n} = \frac{\sum (Z_i - F_i)^2}{n}; i = 1, 2, \dots, n \quad \#(5)$$

dengan

$n$  : Jumlah periode waktu data

$e_i$  : Kesalahan pada periode waktu ke- $i$

$Z_i$  : Data pada periode waktu ke-  $i$   
 $F_i$  : Ramalan untuk periode waktu ke-  $i$

b) *Mean Absolute Percentage Error (MAPE)*

Tingkat akurasi estimasi model, yang diukur sebagai bentuk rata-rata persentase absolut kesalahan, dapat dihitung dengan menggunakan MAPE. Untuk membandingkan data dalam konteks interval waktu yang berbeda digunakan MAPE. Ekspresi matematis dari perhitungan ini dapat dijabarkan secara detail dalam persamaan (6). Metode ini memberikan pemahaman yang lebih mendalam tentang seberapa baik model mampu memberikan estimasi yang akurat dalam mengatasi variasi data pada berbagai interval waktu [15].

$$MAPE = \frac{\sum \frac{|e_i|}{Z_i} \times 100\%}{n} = \frac{\sum \frac{|Z_i - F_i|}{Z_i} \times 100\%}{n}; i = 1, 2, \dots, n \quad \#(6)$$

dengan

$n$  : Jumlah periode waktu data

$e_i$  : Kesalahan pada periode waktu ke- $i$

$Z_i$  : Data pada periode waktu ke-  $i$

$F_i$  : Ramalan untuk periode waktu ke-  $i$

10) Melakukan Peramalan Berdasarkan Model GSTAR Terbaik

11) Menarik Kesimpulan

### 3. Hasil dan Pembahasan

#### 3.1 Statistik Deskriptif

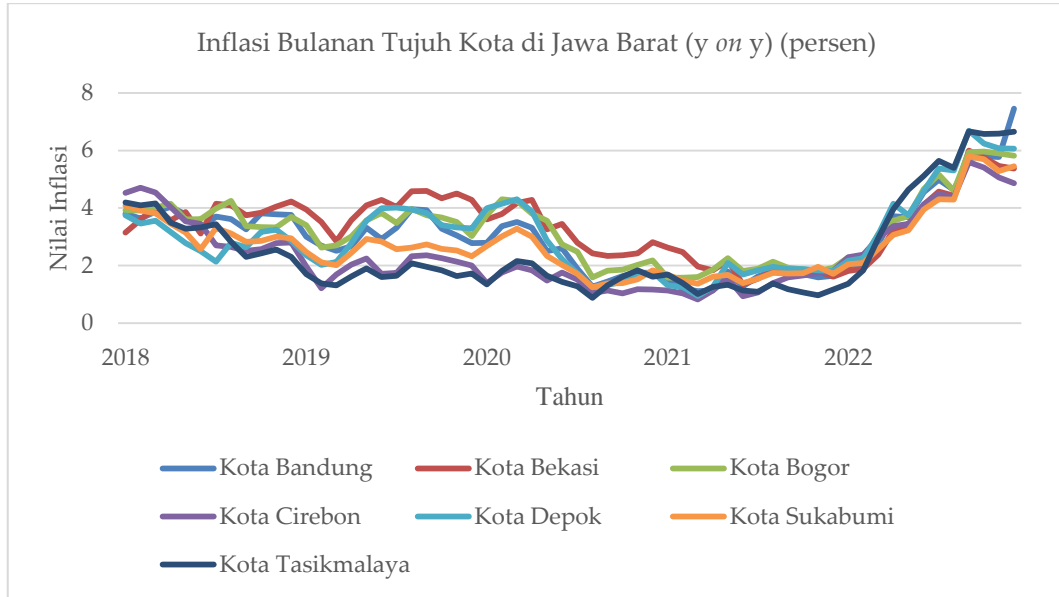
Analisis deskriptif data inflasi bulanan dilakukan dengan tujuan memberikan pemahaman menyeluruh mengenai tingkat inflasi yang terjadi di beberapa kota di Jawa Barat, yaitu Bandung, Bekasi, Bogor, Cirebon, Depok, Sukabumi, dan Tasikmalaya.

**Tabel 3.1 Statistik Deskriptif Data Inflasi Bogor, Sukabumi, Bandung, Cirebon, Bekasi, Depok, dan Tasikmalaya**

Kota	Min.	Max.	Mean	Std. Deviation
Bandung	1.11	7.45	3.01	1.32
Bekasi	1.35	6.00	3.37	1.13
Bogor	1.58	5.96	3.25	1.17
Cirebon	0.82	5.60	2.43	1.28
Depok	0.95	6.68	3.01	1.36
Sukabumi	1.25	5.79	2.70	1.10
Tasikmalaya	0.88	6.66	2.49	1.60

Tabel 3.1 menunjukkan bahwa sepanjang bulan Januari 2018-Desember 2022, Kota Bandung merupakan kota dengan inflasi tertinggi diantara enam kota lainnya yaitu sebesar 7.45%. Kota Depok, Tasikmalaya, Bekasi, Bogor, dan Sukabumi berturut-turut mempunyai tingkat inflasinya sebesar 6.68%, 6.66%, 6.00%, 5.96%, dan 5.79%. Sedangkan

Kota Cirebon merupakan kota dengan *fluktuasi* inflasi paling rendah dibandingkan tujuh kota lainnya sebesar 5.60%. Kota yang rata-rata inflasinya tertinggi adalah Kota Bekasi sebesar 3.37%, dan terendah adalah Kota Cirebon sebesar 2.43%.



**Gambar 3.1 Grafik Inflasi Tahunan 7 Kota di Jawa Barat**

Kesamaan pola inflasi yang tergambar pada gambar 3.1 mencerminkan tren serupa di Kota Bandung, Bekasi, Bogor, Cirebon, Depok, Sukabumi, dan Tasikmalaya. Analisis terhadap grafik tersebut menunjukkan adanya konsistensi dalam pola inflasi tahunan di ketujuh kota tersebut. Hal ini tidak hanya mencerminkan kesamaan karakteristik ekonomi setiap kota, tetapi juga memberikan bukti yang kuat tentang keterkaitan erat di antara mereka. Keseluruhan pola inflasi yang seragam ini memperkuat pandangan bahwa faktor-faktor yang memengaruhi inflasi di ketujuh kota tersebut saling terkait dan memperlihatkan integrasi ekonomi yang signifikan di wilayah tersebut.

### 3.2 Uji Korelasi

Nilai korelasi antar lokasi, yang mencerminkan seberapa besar hubungan antara satu lokasi dengan lokasi lainnya, dapat dilihat dalam Tabel 3.2. Tabel ini memberikan gambaran yang jelas tentang sejauh mana keterkaitan antar lokasi tersebut. Korelasi ini menjadi indikator penting dalam memahami pola hubungan spasial antar lokasi yang terdapat dalam data. Dengan melihat nilai korelasi antar lokasi, kita dapat mengidentifikasi sejauh mana pengaruh atau interaksi yang mungkin terjadi di antara berbagai lokasi, memberikan wawasan yang berharga dalam konteks analisis spasial.

**Tabel 3.2 Korelasi Antar Lokasi**

	Bandung	Bekasi	Bogor	Cirebon	Depok	Sukabumi	Tasikmalaya
Bandung	1	0.89	0.96	0.87	0.92	0.95	0.89
Bekasi	0.88	1	0.90	0.67	0.84	0.82	0.67
Bogor	0.95	0.90	1	0.83	0.94	0.95	0.84

Cirebon	0.87	0.67	0.83	1	0.79	0.93	0.94
Depok	0.91	0.84	0.94	0.79	1	0.92	0.81
Sukabumi	0.95	0.82	0.95	0.93	0.92	1	0.93
Tasikmalaya	0.88	0.68	0.83	0.94	0.81	0.93	1

Tabel 3.2 menggambarkan tingkat korelasi yang tinggi antara lokasi-lokasi yang terjangkau, dengan nilai korelasi antar ketujuh kota tetap berada di atas 0.6. Terdapat korelasi yang mencolok antara Sukabumi-Bogor dan Bandung-Sukabumi, mencapai 0.95, yang menandakan adanya hubungan antar lokasi. Fenomena ini memberikan gambaran bahwa hubungan antara Sukabumi-Bogor dan Bandung-Sukabumi memiliki perbedaan yang substansial, memperkuat observasi mengenai tingginya tingkat korelasi antar lokasi terjangkau dalam analisis ini.

### 3.3 Heterogenitas Lokasi

Uji heterogenitas lokasi adalah salah satu asumsi yang mendasari pemodelan GSTAR. Seperti yang telah dibahas sebelumnya, salah satu syarat analisis model GSTAR adalah memiliki karakteristik lokasi yang bersifat heterogen. Dengan demikian, dalam memeriksa heterogenitas suatu lokasi dapat dilakukan dengan menggunakan indeks gini. Nilai indeks gini berkisar dari 0 hingga 1, semakin tinggi nilainya maka lokasi penelitian semakin beragam. Nilai Indeks gini disajikan pada Tabel 3.3.

**Tabel 3.3 Nilai Indeks Gini**

Kota	Indeks Gini
Bandung	1
Bekasi	1
Bogor	1
Cirebon	1
Depok	1
Sukabumi	1
Tasikmalaya	1

Berdasarkan informasi yang terdapat pada Tabel 3.3, dapat disimpulkan bahwa nilai indeks Gini sebesar 1. Hal ini mengindikasikan bahwa data secara keseluruhan memenuhi asumsi model GSTAR, yang menunjukkan karakteristik lokasi yang heterogen di setiap lokasi pengamatan. Hasil ini memberikan gambaran bahwa distribusi nilai pada variabel yang diamati memiliki tingkat ketidaksetaraan yang tinggi, yang sesuai dengan karakteristik yang diharapkan oleh model GSTAR.

### 3.4 Kestasioneran Data

Pemodelan *time-series* dapat diterima jika data yang digunakan memenuhi persyaratan stasioner. Uji *Augmented Dickey Fuller* (ADF) dapat digunakan untuk menguji stasioneritas data dalam rata-rata. Kriteria uji ADF adalah bahwa data dikatakan stasioner jika *p-value* kurang dari  $\alpha$ . Hasil uji ADF dengan  $\alpha = 0.05$  menunjukkan bahwa data tidak stasioner, sehingga disarankan untuk melakukan proses *differencing* 1. Setelah proses *differencing* 1 selesai, data diuji kembali dengan uji ADF yang dapat dilihat pada Tabel 3.4

**Tabel 3.4 Uji ADF**



Kota	Dickey-Fuller	p-value
Bandung	-4.21	0.01
Bekasi	-3.96	0.02
Bogor	-3.9	0.02
Kota	Dickey-Fuller	p-value
Cirebon	-4.11	0.01
Depok	-5.32	0.01
Sukabumi	-3.87	0.02
Tasikmalaya	-3.66	0.04

Dari hasil analisis pada Tabel 3.4, dapat disimpulkan bahwa uji stasioneritas data inflasi di setiap lokasi penelitian menghasilkan hasil yang menunjukkan sifat stasioner. Artinya, data inflasi pada setiap lokasi penelitian cenderung stabil dan tidak mengalami tren signifikan seiring waktu. Hasil ini memberikan dasar yang kuat untuk interpretasi lebih lanjut terkait perilaku dan karakteristik inflasi di wilayah-wilayah tersebut, memperkuat keandalan data yang digunakan dalam penelitian ini.

### 3.5 Pemilihan Orde Model GSTAR

Identifikasi orde model VAR ditentukan oleh panjang lag yang optimal. Nilai *Akaike's Information Criterion* (AIC) digunakan untuk menentukan kriteria panjang lag terbaik. Nilai AIC terkecil pada berbagai lag digunakan untuk menentukan orde model terbaik untuk GSTAR. Nilai AIC disajikan pada tabel 3.5.

Tabel 3.5 Nilai AIC Pada Model VAR

Lag	AIC
1	-18.30
2	-18.13
3	-18.29

Dari hasil analisis pada Tabel 3.5, dapat disimpulkan bahwa nilai AIC terendah terdapat pada lag pertama, mengindikasikan bahwa orde model *autoregressive* GSTAR adalah 1. Hal ini menggambarkan bahwa model GSTAR yang diperoleh adalah GSTAR  $(1_1)I(1)$  sesuai dengan hasil penilaian AIC. Dengan demikian, keputusan untuk mengadopsi orde *autoregressive* 1 pada model GSTAR didukung oleh nilai AIC yang paling rendah, memvalidasi kecocokan dan ketepatan model GSTAR  $(1_1)I(1)$  dalam menggambarkan data yang ada.

### 3.6 Bobot Lokasi Pada Model GSTAR

Bobot lokasi seragam diberikan pada setiap lokasi yang berdekatan dengan  $i$ . Bobot lokasi seragam umumnya cocok untuk data yang memiliki jarak antar lokasi yang seragam atau homogen. Dengan menggunakan persamaan  $W_{ij} = \frac{1}{n_i}$ , maka hasil perhitungan bobot lokasi seragam dapat dilihat pada persamaan (3.1).

$$W = \begin{bmatrix} 0 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 \\ 1/6 & 0 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 \\ 1/6 & 1/6 & 0 & 1/6 & 1/6 & 1/6 & 1/6 \\ 1/6 & 1/6 & 1/6 & 0 & 1/6 & 1/6 & 1/6 \\ 1/6 & 1/6 & 1/6 & 1/6 & 0 & 1/6 & 1/6 \\ 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 0 & 1/6 \\ 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 1/6 & 0 \end{bmatrix}$$

$$= \begin{bmatrix} 0 & 0.17 & 0.17 & 0.17 & 0.17 & 0.17 & 0.17 \\ 0.17 & 0 & 0.17 & 0.17 & 0.17 & 0.17 & 0.17 \\ 0.17 & 0.17 & 0 & 0.17 & 0.17 & 0.17 & 0.17 \\ 0.17 & 0.17 & 0.17 & 0 & 0.17 & 0.17 & 0.17 \\ 0.17 & 0.17 & 0.17 & 0.17 & 0 & 0.17 & 0.17 \\ 0.17 & 0.17 & 0.17 & 0.17 & 0.17 & 0 & 0.17 \\ 0.17 & 0.17 & 0.17 & 0.17 & 0.17 & 0.17 & 0 \end{bmatrix} \quad \#(3.1)$$

### 3.7 Estimasi Model GSTAR

Metode kuadrat terkecil dapat digunakan untuk menghitung estimasi setiap parameter dalam model *autoregressive* GSTAR, yang dilakukan dengan meminimalkan jumlah residual kuadrat digambarkan sebagai model linier. Estimasi dari vektor parameter dengan metode *Least Square* dapat didefinisikan pada persamaan (2.3) [14]. Hasil estimasi tersebut dapat dilihat pada tabel 3.6.

**Tabel 3.6 Estimasi Parameter GSTAR (1<sub>1</sub>)I(1) Dengan Bobot Lokasi Seragam**

Parameter	Estimasi
$\phi_{10}^1$	0.62
$\phi_{10}^2$	0.76
$\phi_{10}^3$	0.60
$\phi_{10}^4$	0.83
$\phi_{10}^5$	0.76
$\phi_{10}^6$	0.97
$\phi_{10}^7$	0.86
$\phi_{11}^1$	0.43
$\phi_{11}^2$	0.19
$\phi_{11}^3$	0.41
$\phi_{11}^4$	0.10
$\phi_{11}^5$	0.31
$\phi_{11}^6$	0.01
$\phi_{11}^7$	0.07

Pada Tabel 3.6, terdapat penjelasan mengenai hasil estimasi parameter model GSTAR yang menggunakan bobot lokasi yang seragam. Model GSTAR dengan persamaan (1<sub>1</sub>)I(1) diterapkan pada data inflasi bulanan di berbagai kota, termasuk Kota Bandung, Bekasi, Bogor, Cirebon, Depok, Sukabumi, dan Tasikmalaya. Untuk membentuk model ini, digunakan matriks pembobot seragam yang dijelaskan pada persamaan (3.2). Penelitian ini mencerminkan upaya untuk menggambarkan dan menganalisis pola inflasi di kawasan tersebut dengan mempertimbangkan faktor-faktor

yang terkait, yang tercermin dalam hasil estimasi parameter yang terdokumentasi dalam tabel tersebut.

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \\ Z_4(t) \\ Z_5(t) \\ Z_6(t) \\ Z_7(t) \end{bmatrix} = \begin{bmatrix} 0.62 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0.76 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.60 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.83 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.76 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.97 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.86 \end{bmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \\ Z_4(t-1) \\ Z_5(t-1) \\ Z_6(t-1) \\ Z_7(t-1) \end{bmatrix} + \begin{bmatrix} 0.43 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0.19 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.41 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.10 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.31 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.01 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.07 \end{bmatrix} \begin{bmatrix} 0 & 0.17 & 0.17 & 0.17 & 0.17 & 0.17 & 0.17 \\ 0.17 & 0 & 0.17 & 0.17 & 0.17 & 0.17 & 0.17 \\ 0.17 & 0.17 & 0 & 0.17 & 0.17 & 0.17 & 0.17 \\ 0.17 & 0.17 & 0.17 & 0 & 0.17 & 0.17 & 0.17 \\ 0.17 & 0.17 & 0.17 & 0.17 & 0 & 0.17 & 0.17 \\ 0.17 & 0.17 & 0.17 & 0.17 & 0.17 & 0 & 0.17 \\ 0.17 & 0.17 & 0.17 & 0.17 & 0.17 & 0.17 & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \\ Z_4(t-1) \\ Z_5(t-1) \\ Z_6(t-1) \\ Z_7(t-1) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \\ e_4(t) \\ e_5(t) \\ e_6(t) \\ e_7(t) \end{bmatrix} \tag{3.2}$$

Contoh model persamaan GSTAR  $(1_1)I(1)$  dengan bobot lokasi seragam di Kota Bogor

$$\begin{aligned} Z_1(t) = & 0.62Z_1(t-1) + 1.04Z_2(t-1) + 1.04Z_3(t-1) + 1.04Z_4(t-1) \\ & + 1.04Z_5(t-1) + 1.04Z_6(t-1) + 1.04Z_7(t-1) + e_1(t) \end{aligned}$$

Berdasarkan model diatas diperoleh pengaruh inflasi dari satu kota ke kota lain mempunyai bobot yang seragam. Artinya naik atau turunnya inflasi di suatu kota mempunyai pengaruh yang sama terhadap perubahan tingkat inflasi di kota-kota lain. Dengan differensiasi sekali, model ini membantu dalam mengeksplorasi perubahan jangka pendek dalam inflasi, sehingga memberikan informasi tentang bagaimana perubahan inflasi dari bulanan di setiap lokasi dapat mempengaruhi perubahan inflasi di lokasi lain, dengan bobot yang sama pada setiap lokasi.

### 3.8 Uji Kelayakan Model

Model GSTAR  $(1_1)I(1)$  dianggap cocok untuk penggunaan apabila nilai residualnya memperlihatkan sifat *white noise*. Keberlanjutan penggunaan model ini sangat tergantung pada ketepatan asumsi bahwa residu tersebut bersifat *white noise*. Untuk memastikan bahwa asumsi tersebut terpenuhi, uji *Ljung Box Pearce* digunakan sebagai metode pengecekan. Uji ini bertujuan untuk mengidentifikasi apakah residu dari model GSTAR  $(1_1)I(1)$  dapat dianggap sebagai *white noise* atau tidak, sehingga hasilnya dapat memberikan kepercayaan dalam interpretasi dan penggunaan model tersebut. Dengan demikian, penerapan uji *Ljung Box Pearce* menjadi suatu langkah penting dalam mengevaluasi kesesuaian dan kualitas model GSTAR  $(1_1)I(1)$  dalam konteks analisis data yang dilakukan.

**Tabel 3.7 Uji White Noise**

Bobot Lokasi	P-value	Tanda	Alpha	Keputusan	Kesimpulan
Seragam	0.057	>	0.05	Gagal Tolak H0	Residual memenuhi asumsi white noise

Analisis dari tabel 3.7 menunjukkan bahwa residual model GSTAR  $(1_1)I(1)$  memiliki sifat *white noise*, yang mengindikasikan bahwa tidak terdapat korelasi yang signifikan antara residual tersebut dan model. Temuan ini memberikan implikasi positif, menandakan bahwa model ini dapat dianggap layak digunakan dalam konteks analisis yang dilakukan. Keberadaan *white noise* pada residual menegaskan bahwa tidak ada pola atau informasi yang belum diakomodasi oleh model, memvalidasi kehandalan model GSTAR  $(1_1)I(1)$  dalam menjelaskan fenomena yang diamati.

### 3.9 Ukuran Kesalahan Model

Pemeriksaan ketepatan model dapat dilakukan melalui perbandingan ukuran kesalahan pada model, yang dapat diamati dari nilai *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE) pada data *training* dan *testing* yang telah diperoleh. Pengujian ini menggunakan komposisi uji 80:20, di mana model dievaluasi dengan menggunakan 80% data untuk pelatihan dan 20% sisanya untuk pengujian. Dengan demikian, proses ini memberikan pemahaman terkait kinerja model dan memungkinkan penilaian yang lebih terhadap keakuratan dan ketepatan prediksi.

**Tabel 3.8 Perbandingan Nilai MSE dan MAPE Data Training dan Testing pada Model GSTAR  $(1_1)I(1)$  dengan komposisi 80:20**

	MSE	MAPE
<i>Training</i>	0.12	12.20
<i>Testing</i>	11.15	60.69

Dari hasil analisis kelayakan model dengan menggunakan komposisi 80:20, terlihat bahwa nilai *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE) untuk data *training* lebih kecil dibandingkan dengan data *testing*. Secara spesifik, nilai MSE dan MAPE untuk data *training* masing-masing adalah sebesar 0.12% dan 12.20%. Hal ini mengindikasikan bahwa model memiliki performa yang baik dalam menangani data *training*, namun demikian, perlu dilakukan evaluasi lebih lanjut untuk memastikan kemampuan generalisasi model terhadap data *testing*.

### 3.10 Peramalan

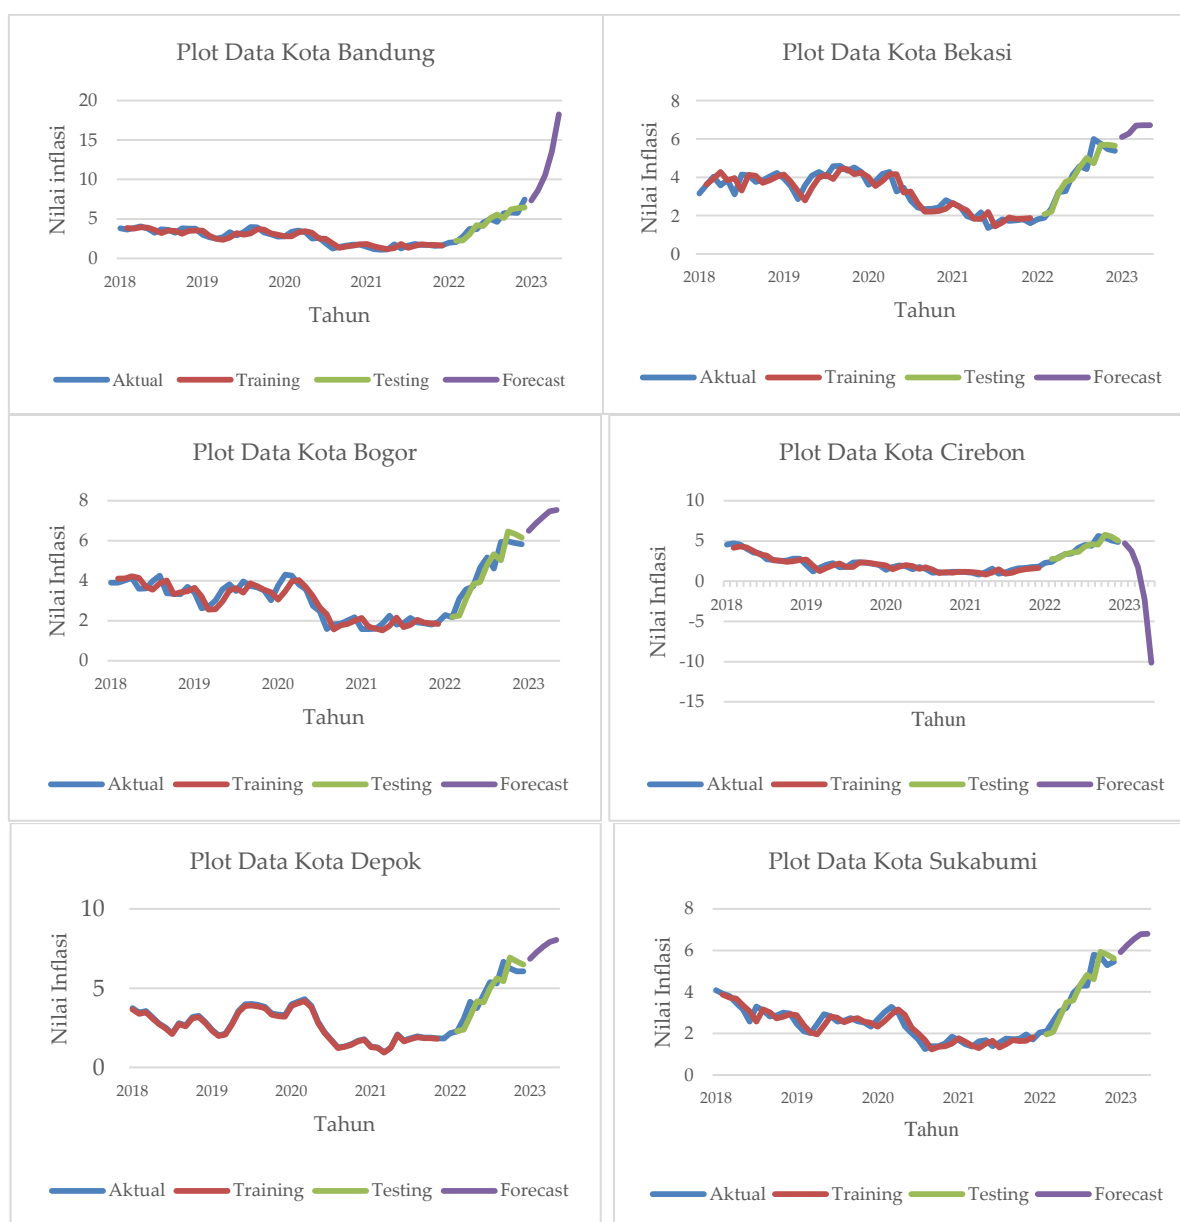
Model terbaik yang telah diperoleh sebelumnya digunakan untuk melakukan peramalan 5 bulan kedepan. Proses perhitungan ini melibatkan metode dan parameter yang telah terbukti efektif dalam prediksi sebelumnya. Hasil peramalan untuk 5 bulan mendatang akan ditampilkan secara rinci pada tabel 3.9, memberikan gambaran yang jelas dan terstruktur untuk mendukung keputusan dan perencanaan ke depan.


**Tabel 3.9 Nilai Peramalan Inflasi**

Tanggal	Bandung	Bekasi	Bogor	Cirebon	Depok	Sukabumi	Tasikmalaya
01/01/2023	7.34	6.09	6.49	4.69	6.86	5.91	7.34

01/02/2023	8.63	6.29	6.86	3.76	7.26	6.25	7.76
01/03/2023	10.55	6.69	7.19	1.75	7.62	6.54	8.15
01/04/2023	13.51	6.71	7.46	-2.32	7.93	6.78	8.5
01/05/2023	18.26	6.71	7.53	-10.12	8.04	6.8	8.67

Berdasarkan hasil prediksi yang tercantum dalam tabel 3.9, dapat diamati bahwa terjadi peningkatan relatif dalam data inflasi di hampir setiap lokasi, kecuali di Cirebon yang mengalami penurunan. Hal ini lebih terperinci dan terilustrasikan melalui *plot* time series pada gambar 3.2, yang menampilkan hasil ramalan data inflasi untuk tiap lokasi. *Plot* tersebut memberikan gambaran visual yang lebih jelas mengenai tren perubahan inflasi di setiap daerah, memperkuat pemahaman terhadap dinamika ekonomi yang sedang berlangsung.





**Gambar 3.2 Grafik Peramalan Inflasi masing-masing Kota**

Gambar 3.2 menjelaskan grafik perbandingan dari hasil analisis data inflasi kota Bandung, Bekasi, Bogor, Cirebon, Depok, Sukabumi dan Tasikmalaya periode Januari 2018 hingga Desember 2022. Pada grafik, garis biru menggambarkan data aktual, garis merah menggambarkan data *train*, garis hijau menggambarkan hasil peramalan pada data *testing* dan garis ungu menggambarkan hasil peramalan inflasi. Berdasarkan grafik nilai inflasi kota Bandung, Bekasi, Bogor, Depok, Sukabumi dan Tasikmalaya berturut-turut naik sebesar 1.45%, 0.25%, 0.29%, 0.33%, 0.25%, dan 0.3%. Sehingga garis peramalan pada grafik relatif naik. Sedangkan pada grafik kota Cirebon nilai inflasi turun sebesar 3.08% dan dapat dilihat pada grafik garis peramalan menurun secara signifikan selama 5 bulan kedepan.

#### 4. Kesimpulan

Hasil penelitian menunjukkan bahwa secara keseluruhan grafik data inflasi bulanan mengalami tren turun pada periode akhir tahun 2018 hingga awal tahun 2021, dan setelah itu mengalami fluktuasi yang cukup signifikan pada periode akhir tahun 2021 hingga awal tahun 2022. Dari ketujuh grafik *forecasting* dapat dilihat bahwa inflasi bulanan, enam kota relatif naik dan satu kota mengalami penurunan. Dan diperoleh model terbaik untuk data inflasi 7 kota di Jawa Barat yaitu model GSTAR (1<sub>1</sub>)I(1) dengan bobot lokasi seragam.

Diharapkan bahwa penelitian yang akan datang dapat menggunakan pembobot lain karena berdasarkan MAPE model kurang baik digunakan, diharapkan meningkatkan keakuratan peramalan dengan memasukkan data inflasi bulanan dari tempat lain, melihat jenis pengembangan metode GSTAR seperti GSTAR-X, dan mempertimbangkan perbandingan antara model GSTAR dan metode lain. Selain itu, diharapkan bahwa penelitian ini akan memberikan panduan penting bagi pemerintah untuk mengantisipasi fluktuasi inflasi yang mungkin terjadi, yang akan membantu mereka membuat kebijakan moneter dan fiskal yang lebih tepat dan efisien.

#### Daftar Pustaka

- [1] B. P. Statistik, "Indeks Harga Konsumen (IHK)." [Online]. Available: <https://www.bps.go.id/subject/3/inflasi.html>
- [2] M. Ingriela Toja Mario, R. Dwi Bekti, and J. Statistka, "Pemodelan Generalized Space Time Autoregressive (Gstar) Untuk Peramalan Tingkat Inflasi Di Pulau Jawa," *J. Stat. Ind. dan Komputasi*, vol. 06, no. 02, pp. 171–184, 2021.

- [3] D. M. Putri, "Analisis Regresi Data Panel untuk Pemodelan Laju Inflasi Tujuh Kota di Provinsi Jawa Barat Tahun 2013-2020," *J. Biotropika*, vol. 2(3), pp. 164–168, 2022.
- [4] A. Hartadi *et al.*, "Musim inflasi di jawa barat dan penyebabnya," vol. 15, no. 43, pp. 115–119, 2019.
- [5] A. Rahim, D. Retno Dwi Hastuti, D. Pradipta, N. Bustanul, and N. Azizah, "The Influence of Respondent Characteristics and Different Areas on Small-Scale Fisherman Household Income of Urban Coastal Areas in," *J. Socioecon. Dev.*, vol. 1, no. 2, pp. 63–71, 2018.
- [6] R. Handayani, S. Wahyuningsih, and D. Yuniarti, "Pemodelan Generalized Space Time Autoregressive (GSTAR) Pada Data Inflasi di Kota Samarinda dan Kota Balikpapan," *J. Eksponensial*, vol. 9, no. 2, pp. 153–162, 2018.
- [7] Agnesya Risnandar and Anneke Iswani Achmad, "Pemodelan Generalized Space Time Autoregressive untuk Meramalkan Indeks Harga Konsumen," *J. Ris. Stat.*, pp. 43–50, 2023.
- [8] M. A. Masdin and D. Lusiyanti, "Peramalan Menggunakan Model Generalized Space Time Autoregressive ( GSTAR ) untuk Indeks Harga Konsumen di Empat Kota Provinsi Sulawesi Selatan," vol. 14, no. 1, pp. 39–49, 2018.
- [9] M. Andini, "Peramalan curah hujan di DKI Jakarta dengan menggunakan metode generalized space time autoregressive integrated (gstar-i) jurnal ilmiah," *Peramalan curah hujan di DKI Jakarta dengan menggunakan Metod. Gen. Sp. time autoregressive Integr. J. Ilm.*, 2021.
- [10] S. Aufa, R. Santoso, and S. Suparti, "Pemodelan Indeks Harga Properti Residensial Di Indonesia Menggunakan Metode Generalized Space Time Autoregressive," *J. Gaussian*, vol. 11, no. 1, pp. 31–44, 2022.
- [11] D. A. Kusumaningrum and S. P. Palupi, "Analisis Keterkaitan Data Inflasi Antara Provinsi DKI Jakarta dan Jawa Barat Tahun 2014-2021 Menggunakan Metode Vector Autoregressive (VAR)," *Gov. Stat.*, vol. 1, no. 1, pp. 1–12, 2022.
- [12] V. P. Balqis, E. Kurniati, and O. Rohaeni, "Model Peramalan Data Inflasi dengan Metode Generalized Space Time Autoregressive (GSTAR) pada Tiga Kota di Jawa Barat," *Pros. Mat. Semin. Penelit. Sivitas Akad. Unisba*, pp. 43–50, 2020.
- [13] N. F. Arini, N. M. Huda, and W. Andani, "Perbandingan Matriks Bobot Invers Jarak dan Bobot Seragam pada Model Gstar (1;1) untuk Data Indeks Harga Konsumen (Studi Kasus: Indeks Harga Konsumen di Kalimantan Barat)," *Tensor Pure Appl. Math. J.*, vol. 4, no. 1, pp. 27–36, 2023.
- [14] E. Siswanto, H. Yasin, and S. Sudarno, "Pemodelan Generalized Space Time Autoregressive (Gstar) Seasonal Pada Data Curah Hujan Empat Kabupaten Di Provinsi Jawa Tengah," *J. Gaussian*, vol. 8, no. 4, pp. 418–427, 2019.
- [15] S. S. R. Kharisma, "Implementasi Model Generalized Space Time Autoregressive (Gstar) Dalam Peramalan Data Harga Beras" 2022.