

BAB I PENDAHULUAN

1.1 Latar Belakang

Inflasi di negara-negara berkembang menjadi isu yang terus berulang dan mengancam stabilitas perekonomian, termasuk di Indonesia. Menurut Badan Pusat Statistik (BPS) (2023), Inflasi didefinisikan sebagai kondisi di mana harga barang dan jasa meningkat secara berkelanjutan dalam jangka waktu tertentu. Dalam perspektif ekonomi, inflasi yang terkendali memberi manfaat dengan menjaga stabilitas harga dan daya beli masyarakat. Namun, inflasi yang tinggi dapat menurunkan daya beli, menghambat investasi dan merusak kestabilan ekonomi secara keseluruhan (Meiditambua et al., 2023). Oleh karena itu, pengendalian inflasi menjadi prioritas utama dalam kebijakan ekonomi nasional untuk memastikan pertumbuhan ekonomi yang berkelanjutan.

Sebagai bagian dari upaya menjaga stabilitas harga, Bank Indonesia (BI) mulai menerapkan kerangka kerja *Inflation Targeting Framework* (ITF) pada 1 Juli 2005. Kerangka ini menggunakan suku bunga sebagai instrumen utama untuk mencapai target inflasi. Meskipun memberikan dampak positif dalam jangka panjang, pencapaian target inflasi seringkali menghadapi hambatan berupa kejutan sisi permintaan dan penawaran (Warjiyo & Juhro, 2019). Sebagai contoh, selama pandemi COVID-19 pada 2020, tingkat inflasi Indonesia menunjukkan pelemahan signifikan hingga mencapai deflasi sebesar 0,01% pada Juli 2020 (BPS, 2020). Situasi tersebut menunjukkan pentingnya pengawasan inflasi di setiap wilayah untuk menjaga kestabilan ekonomi nasional.

Dalam Konteks regional, Provinsi Sulawesi Selatan memiliki peran strategis sebagai salah satu lumbung pangan utama di Kawasan Timur Indonesia (KTI) (Diskominfo, 2021). Ketergantungan pada hasil produksi dan distribusi pangan dari wilayah ini menjadi komponen krusial dalam menjaga kestabilan harga. Gangguan pada sektor pangan wilayah ini dapat menyebabkan fluktuasi harga yang berdampak langsung pada tingkat inflasi, mengingat bahan pangan merupakan salah satu elemen utama dalam perhitungan inflasi. Berdasarkan data BPS (2023), perhitungan inflasi di Sulawesi Selatan mencakup lima Kota, yaitu Bulukumba, Watampone, Makassar, Parepare dan Palopo. Mulai tahun 2024, cakupan tersebut diperluas dengan penambahan beberapa Kota, yakni Wajo, Siddereng Rappang dan Luwu Timur (BPS, 2024). Peramalan inflasi menjadi langkah penting dalam mendukung pengambilan kebijakan yang lebih akurat untuk mengantisipasi ketidakstabilan ekonomi di masa depan.



flasi memerlukan pendekatan yang mampu menangkap dan spasial karena adanya interaksi ekonomi antara wilayah, perubahan harga suatu wilayah dapat dipengaruhi oleh wilayah spasial temporal pertama kali diperkenalkan Cliff dan Ord (1980) menyelidiki lebih lanjut mengenai model *Space Time Autoregressive* (STAR). Hasilnya menunjukkan bahwa model STAR berlaku hanya pada lokasi yang

homogen dan kurang sesuai jika diterapkan pada lokasi yang heterogen. Sehingga, Borovkova (2002) mengembangkan model STAR untuk menangani karakteristik lokasi yang heterogen dengan menggunakan model *Generalized Space Time Autoregressive* (GSTAR). Model GSTAR telah banyak digunakan dalam penelitian mengenai inflasi. Sebagai contoh, Mario *et al.* (2021) menerapkan model GSTAR (1,0,1) pada enam provinsi di Pulau Jawa, dan menunjukkan bahwa model tersebut efisien untuk meramalkan inflasi. Sementara Suciati *et al.* (2024) menerapkan model GSTAR untuk meramalkan inflasi lima kota di Pulau Sumatera, yang menunjukkan bahwa inflasi lima kota tersebut berkorelasi dengan data inflasi pada waktu sebelumnya dan dipengaruhi oleh data inflasi kota lain.

Meskipun model GSTAR efektif untuk menangani hubungan spasial temporal, model ini belum sepenuhnya mampu untuk menangani karakteristik data inflasi yang cenderung memiliki volatilitas tinggi. Menurut Bonar (2017), data inflasi sering menunjukkan volatilitas yang tinggi, yang mengakibatkan variansi error yang tidak konstan atau heteroskedastisitas. Untuk mengatasi masalah ini, Nainggolan (2010) mengintegrasikan komponen *Autoregressive Conditional Heteroscedasticity* (ARCH) ke dalam model GSTAR, yang kemudian dikenal sebagai model GSTAR-ARCH. Model ini diterapkan dalam berbagai penelitian, seperti pada data inflasi di Jawa Barat, di mana pengaruh ARCH terbukti signifikan pada tingkat kepercayaan 95%, serta model yang diperoleh mampu memprediksi inflasi dengan mempertimbangkan inflasi sebelumnya dari lokasi lainnya (Nainggolan, 2010). Selain itu, Model *Generalized Space Time Autoregressive Integrated-ARCH* (GSTARI-ARCH) diterapkan untuk peramalan Indeks Harga Konsumen (IHK) di Sumatera Utara, yang menunjukkan bahwa model ini lebih efektif dalam menangkap pola spasial temporal serta volatilitas inflasi, dibandingkan model GSTAR (Bonar, *et al.*, 2017). Baik pada model GSTAR-ARCH maupun GSTARI-ARCH, menggunakan bobot seragam.

Padahal, dalam model seperti GSTAR, pemilihan bobot memiliki peran penting karena menentukan kekuatan hubungan spasial antar wilayah dan secara langsung mempengaruhi performa model (Mukhaiyar, 2024). Huda & Imroah (2023) menunjukkan bahwa pemilihan matriks bobot yang tepat secara signifikan dalam meningkatkan akurasi peramalan. Salah satu pendekatan yang umum digunakan adalah bobot invers jarak, seperti yang diterapkan oleh Ashari *et al.* (2020). Pendekatan ini mempertimbangkan bahwa wilayah yang lebih dekat secara geografis memiliki keterkaitan ekonomi yang lebih kuat. Jarak antara wilayah secara ekonomi dapat memengaruhi inflasi melalui biaya distribusi dan logistik yang meningkat seiring bertambahnya jarak produsen dan konsumen (Goodwin *et al.*, 2019). Oleh karena itu, penggunaan bobot invers jarak dalam model spasial

representasikan hubungan spasial antara wilayah secara lebih erhadap karakteristik data inflasi.

raian tersebut, penelitian ini bertujuan memodelkan data inflasi di Selatan menggunakan model *Generalized Space Time* (AR) dan analisis residual dengan *Autoregressive Conditinal* (ARCH) dengan pendekatan bobot invers jarak, untuk



menghasilkan model permalan yang mampu menangkap pola spasial temporal serta karakteristik volatilitas pada data inflasi regional.

1.2 Rumusan Masalah

Berdasarkan tinjauan latar belakang diatas, rumusan masalah dalam penelitian ini adalah:

1. Bagaimana model GSTAR-ARCH berbobot invers jarak untuk data inflasi lima kota di Sulawesi Selatan?
2. Bagaimana kinerja peramalan model GSTAR berbobot invers jarak dengan analisis residual ARCH pada inflasi lima kota di Sulawesi Selatan?

1.3 Batasan Masalah

Penelitian ini hanya menggunakan data inflasi lima Kota di Sulawesi Selatan yang terdiri dari Kota Bulukumba, Watampone, Makassar, Parepare dan Palopo. Lokasi tersebut hubungannya dekat satu sama lain, maka orde spasial yang digunakan dibatasi hanya pada orde satu. Adapun bobot lokasi yang digunakan adalah bobot invers jarak.

1.4 Tujuan Penelitian

Berdasarkan latar belakang yang telah diuraikan, maka tujuan dari penelitian ini adalah sebagai berikut:

1. Memperoleh model GSTAR-ARCH berbobot invers jarak untuk data inflasi lima kota di Sulawesi Selatan.
2. Memperoleh evaluasi kinerja peramalan model GSTAR berbobot invers jarak dengan analisis residual ARCH pada data inflasi lima kota di Sulawesi Selatan.

1.5 Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat sebagai berikut:

1. Mengembangkan pemahaman mengenai model GSTAR dan ARCH khususnya pada kasus inflasi lima Kota di Sulawesi Selatan.
2. Meningkatkan akurasi hasil permalan inflasi di Sulawesi Selatan menggunakan model GSTAR-ARCH.

1.6 Teori

Sub-bab teori ini membahas mengenai beberapa teori yang digunakan untuk membahas pokok pembahasan terkait Model GSTAR, ARCH dan inflasi.

1.6.1 Statistika Deskriptif

Statistika adalah cabang ilmu yang mempelajari metode pengumpulan, pengolahan, analisis, interpretasi, dan penarikan kesimpulan berdasarkan data. Menurut Nasution (2016), komponen utama dalam statistika, yaitu data, perlakuan meliputi pengolahan, analisis, interpretasi, dan penarikan metode kuantitatif yang digunakan untuk mengolah data tersebut. (2016), statistika deskriptif merupakan cabang statistika yang menghimpun, mengatur, dan mengolah data agar dapat disajikan. Tujuannya adalah memberikan gambaran yang jelas mengenai peristiwa tertentu berdasarkan data yang diperoleh. Dengan



demikian, statistika deskriptif membantu dalam memahami pola atau tren dalam data tanpa melakukan inferensi lebih lanjut.

1.6.2 Analisis Deret Waktu

Analisis deret waktu mempelajari data yang dikumpulkan secara berurutan dalam waktu, baik harian, bulanan, maupun tahunan. Tujuan utamanya adalah mengidentifikasi pola seperti tren, siklus, musiman, atau variasi acak, sehingga dapat digunakan untuk memahami dinamika data dan membuat prediksi berdasarkan pola historis (Hamilton, 2020).

Dalam analisis deret waktu, nilai suatu kejadian pada satu waktu tertentu seringkali dipengaruhi oleh nilai pada periode sebelumnya. Hal ini dapat direpresentasikan oleh variabel acak $Z(t)$ dengan $t = 1, 2, \dots$. Sekumpulan variabel acak $\{Z(t) | t = 1, 2, \dots\}$ disebut proses stokastik dengan parameter waktu diskrit. Artinya, perubahan data digambarkan terutama oleh dimensi waktu (Wikle, 2018). Secara umum, pemodelan deret waktu bertujuan untuk melakukan peramalan, yaitu memperkirakan nilai-nilai data di masa depan yang belum teramati (Huda dan Imroah, 2023).

Berdasarkan jumlah variabel yang diamati, deret waktu dibagi menjadi dua jenis. Pertama, deret waktu univariat, yaitu analisis terhadap satu variabel dalam kurun waktu tertentu dan multivariat. Model univariat, berfokus dinamika internal variabel tersebut dengan asumsi bahwa informasi prediksi dapat diperoleh sepenuhnya dari data historis variabel itu sendiri (Hamilton, 2020). Kedua, deret waktu multivariat, yaitu analisis terhadap lebih dari satu variabel. Dalam hal ini, hubungan antar variabel dianalisis diperhitungkan secara bersamaan dengan model yang dirancang untuk menangkap interaksi antar variabel sepanjang waktu.

Lebih lanjut, analisis deret waktu juga dapat diperluas dengan memperhitungkan dimensi spasial. Ketika dimensi lokasi (s) digabungkan dengan dimensi waktu (t), variabel acak $Z(s, t)$ dapat digunakan untuk merepresentasikan fenomena yang dipengaruhi oleh waktu dan lokasi sekaligus. Sekumpulan variabel acak $\{Z(s, t) | s, t = 1, 2, \dots\}$ disebut sebagai proses stokastik spasial temporal. Proses ini menunjukkan bahwa data tidak hanya dipengaruhi oleh faktor waktu tetapi juga dipengaruhi oleh perbedaan lokasi (Wikle, 2018).

1.6.3 Autokorelasi Spasial

Autokorelasi spasial adalah korelasi antara nilai suatu variabel di suatu lokasi dengan nilai variabel yang sama di lokasi lain berdasarkan dimensi ruang. Dalam konteks analisis spasial, autokorelasi spasial mengukur kedekatan nilai antara lokasi dalam dimensi ruang saja (Lembo, 2006).



Wong (2001), salah satu metode yang sering digunakan untuk autokorelasi spasial adalah Indeks Moran (Moran's Index). Autokorelasi secara global dan dihitung berdasarkan satu sampel sebanyak n , Indeks Moran dirumuskan sebagai berikut:

$$I = \frac{\sum_{j=1}^n \sum_{k=1}^n w_{jk} (x_j - \bar{x})(x_k - \bar{x})}{S^2 \sum_{j=1}^n \sum_{k=1}^n w_{jk}}, \quad (1)$$

dengan:

$$s^2 = \frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2, \quad (2)$$

di mana,

I : moran's I,

x_j : nilai pada lokasi j ,

x_k : nilai pada lokasi k ,

$\bar{x}$: rata rata dari nilai variabel x ,

W_{jk} : elemen pembobot terstandarisasi antara lokasi j dan k , di mana W_{jk} distandarisasi sehingga $\sum_{k=1}^n W_{jk} = 1$

s^2 : variansi sampel

Hipotesis dengan taraf signifikansi $\alpha = 5\%$ adalah sebagai berikut:

$H_0 : I = 0$ (Tidak ada korelasi spasial antara wilayah)

$H_1 : I \neq 0$ (Ada korelasi spasial antara wilayah)

Statistik uji:

$$Z(I) = \frac{I - E(I)}{\sqrt{\text{var}(I)}} \approx N(0,1) \quad (3)$$

dengan,

$$E(I) = -\frac{1}{n-1},$$

$$\text{var}(I) = \frac{n^2 S_1 - S_2 + 3S_0^2}{(n^2 - 1)S_0^2} - [E(I)]^2,$$

$$S_0 = \sum_{j=1}^n \sum_{k=1}^n w_{jk},$$

$$S_1 = \frac{1}{2} \sum_{j=1}^n \sum_{k=1}^n (w_{jk} + w_{kj})^2,$$

$$S_2 = \sum_{j=1}^n (\sum_{k=1}^n w_{jk} + \sum_{k=1}^n w_{kj})^2,$$

Kriteria uji:

Tolak H_0 jika $|Z(I)| > Z_{1-\alpha}$ atau $p_{value} \leq \alpha$ dengan taraf signifikansi $\alpha = 5\%$ artinya terdapat korelasi spasial antara wilayah.

1.6.4 Stasioneritas

Data dikatakan stasioner jika data tidak memuat perubahan yang drastis. Fluktuasi data berada pada sekitar nilai rata-rata dan variansi yang konstan dan tidak bergantung pada waktu (Makridakis *et al.*, 1999). Dalam analisis deret waktu multivariat, konsep ini penting untuk memastikan model tidak bekerja dengan struktur data yang bias atau tidak stabil. Menurut Wei (2006) stasioner data dibagi menjadi dua, yaitu:



agam

riat $Z(t)$ dikatakan stasioner dalam ragam jika matriks berubah sepanjang waktu. Untuk menguji stasioner ragam, rmasi Box-Cox, selama data bernilai positif (Drapper & Smith, ggap stasioner dalam ragam apabila parameter transformasi tidak, transformasi diperlukan (Wei, 2006).

Berikut rumus yang digunakan dalam transformasi (Wei, 2006):

$$T(Z(t)) = [Z(t)]^\lambda = \begin{cases} \frac{[Z(t)]^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln(Z(t)), & \lambda = 0 \end{cases} \quad (4)$$

Berdasarkan persamaan (4) diperoleh tabel transformasi lambda sebagai berikut:

Tabel 1. Nilai lambda dan bentuk transformasinya

Nilai lambda	-1	-0,5	0	0,5	1
Bentuk transformasi	$\frac{1}{Z(t)}$	$\frac{1}{\sqrt{Z(t)}}$	$\ln(Z(t))$	$\sqrt{Z(t)}$	$Z(t)$

Sumber: Wei, 2006.

b. Stasioner dalam rata-rata

Deret multivariat $Z(t)$ dikatakan stasioner dalam rata-rata jika nilai ekspektasinya konstan, yaitu $E(Z(t)) = \mu(t) = \mu$ di mana μ merupakan vektor tetap (independen terhadap waktu). Uji *Augmented Dickey-Fuller* (ADF) diperkenalkan pertama kali oleh Dickey dan Fuller pada tahun 1979 dan merupakan pengujian stasioner yang paling umum digunakan adalah data deret waktu yang memiliki akar unit di dalam model atau tidak. Hipotesis yang diuji (Wei, 2006):

$H_0 : \phi = 0$ (Data tidak stasioner)

$H_1 : \phi < 0$ (Data stasioner)

dengan, statistik uji sebagai berikut:

$$t_{hitung} = \frac{\hat{\phi}}{SE(\hat{\phi})} \quad (5)$$

dengan $SE(\hat{\phi}) = \left[\frac{\hat{\sigma}_e^2}{(\sum_{t=1}^n Z_{t-1}^2)} \right]^{1/2}$, dan $\hat{\sigma}_e^2 = \sum_{t=1}^n \frac{(Z_t - Z_{t-1})^2}{(n-1)}$. Kriteria keputusan yaitu tolak H_0 jika $|t_{hitung}| > |t_{tabel}|$ atau $p_{value} < \alpha$ dengan taraf signifikansi $\alpha = 5\%$.

Penanganan data yang tidak stasioner dalam rata-rata dilakukan melalui proses *differencing* untuk menghasilkan data yang stasioner. Operator langkah mundur (*backward shift*) sangat tepat untuk menggambarkan proses *differencing* (Makridakis *et al.*, 1999). Operator *backward shift* sebagai berikut:

$$BZ(t) = Z(t-1) \quad (6)$$

di mana,

$Z(t)$: variabel Z pada waktu ke- t , $t = 2, 3, 4, \dots$,


$Z(t-1)$: variabel Z pada waktu ke- $t-1$,

d shift,

g ada pada $Z(t)$ mempunyai pengaruh untuk menggeser data
melakang.

deret waktu tidak stasioner maka data tersebut dapat dibuat
melakukan *differencing* pertama dari data, sebagai berikut:

$$Z(t)' = Z(t) - Z(t-1) \quad (7)$$



Dengan menggunakan operator *backward shift*, maka persamaan (7) dapat dinyatakan sebagai bentuk:

$$\begin{aligned} Z(t)' &= Z(t) - BZ(t) \\ Z(t)' &= (1 - B)Z(t) \end{aligned} \quad (8)$$

Persamaan (8) merupakan *differencing* pertama, maka secara umum, jika terdapat *differencing* ke- d untuk mencapai stasioneritas dinotasikan sebagai $(1 - B)^d$ dengan $d \geq 1$. Dengan menerapkan *differencing* menggunakan operator *backward shift*, data deret waktu yang tidak stasioner dalam rata-rata dapat diubah menjadi stasioner, sehingga lebih sesuai untuk analisis lanjutan.

1.6.5 Model Space Time Autoregressive (STAR)

Model STAR merupakan model dengan parameter *autoregressive* dan parameter spatio-temporal yang bersifat homogen untuk semua lokasi (Pfeifer & Deutch, 1980). Menurut Borovkova (2008), secara umum model STAR dengan orde *autoregressive* p dan orde spasial $\lambda_1, \dots, \lambda_p$ maka dapat ditulis dengan model STAR $(p, \lambda_1, \dots, \lambda_p)$ yang dinyatakan sebagai berikut:

$$Z(t) = \sum_{s=1}^p \sum_{k=0}^{\lambda_s} \Phi_{sk} W^{(k)} Z(t-s) + e(t) \quad (9)$$

di mana,

p : orde waktu *autoregressive*,

λ_s : orde spasial dari *autoregressive* ke- s , di mana $s = 1, 2, \dots, p$,

Φ_{sk} : Parameter *spatial autoregressive* pada lag s dan lag spasial k ,
 $k = 1, 2, \dots, \lambda_s$,

$e(t)$: Kesalahan acak dengan rata-rata nol.

1.6.6 Model Generalized Space Time Autoregressive (GSTAR)

Model STAR yang mengasumsikan semua lokasi mempunyai parameter *autoregressive* yang sama, hanya sesuai diterapkan pada lokasi yang homogen, sehingga cenderung tidak fleksibel atau kurang sesuai diterapkan pada lokasi Heterogen. Untuk itu, Borovkova (2002) mengembangkan model GSTAR yang mengasumsikan bahwa parameter setiap lokasi diperbolehkan berbeda.

Jika diketahui deret waktu $\{Z_i(t) : t = 0, 1, 2, \dots; i = 1, 2, \dots, N\}$ merupakan sebuah deret waktu multivariat dari N pengamatan, maka model GSTAR dengan orde waktu $AR(p)$ dan spasial $(\lambda_1, \lambda_2, \dots, \lambda_p)$ dapat ditulis $GSTAR(p, \lambda_1, \lambda_2, \dots, \lambda_p)$.

Model GSTAR dinyatakan sebagai berikut (Ruchjana, 2002):

$$Z(t) = \sum_{s=1}^p [\Phi_{s0} Z(t-s) + \sum_{k=1}^{\lambda_s} \Phi_{sk} W^{(k)} Z(t-s) + e(t)] \quad (10)$$



observasi multivariat pada waktu t , berukuran $(N \times 1)$,
autoregressive ke- s , di mana $s = 1, 2, \dots, p$,
spasial regresi, di mana $k = 1, 2, \dots, \lambda_s$,
membobot matriks $N \times N$ pada lag spasial ke- k ,
yang *white noise* dengan distribusi $N(0, \Sigma)$.

Dengan $\Phi_{s_0} = \text{diag}(\phi_{s_0}^1, \dots, \phi_{s_0}^N)$, $\Phi_{s_k} = \text{diag}(\phi_{s_k}^1, \dots, \phi_{s_k}^N)$, adalah matriks diagonal $N \times N$ dan $W^{(k)}$ adalah matriks $N \times N$ dengan elemen $w_{ij}^{(k)}$ sebagai pembobot yang harus memenuhi syarat $w_{ii}^{(k)} = 0$ dan $\sum_{i \neq j} w_{ij}^{(l)} = 1, i = 1, 2, \dots, N$.

Persamaan (11) dapat dinyatakan dalam bentuk matriks, sebagai berikut (Suryani & Sari, 2018):

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \\ \vdots \\ Z_n(t) \end{bmatrix} = \begin{bmatrix} \phi_{s_0}^{(1)} & 0 & \dots & 0 \\ 0 & \phi_{s_0}^{(2)} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \phi_{s_0}^{(n)} \end{bmatrix} \begin{bmatrix} Z_1(t-s) \\ Z_2(t-s) \\ \vdots \\ Z_n(t-s) \end{bmatrix} + \begin{bmatrix} \phi_{s_k}^{(1)} & 0 & \dots & 0 \\ 0 & \phi_{s_k}^{(2)} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \phi_{s_k}^{(n)} \end{bmatrix} \begin{bmatrix} Z_1(t-s) \\ Z_2(t-s) \\ \vdots \\ Z_n(t-s) \end{bmatrix} + \begin{bmatrix} 0 & w_{12} & \dots & w_{1n} \\ w_{21} & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & \dots & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-s) \\ Z_2(t-s) \\ \vdots \\ Z_n(t-s) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ \vdots \\ e_n(t) \end{bmatrix}$$

1.6.7 Matriks Bobot Lokasi

Menurut Mansoer *et al.* (2016), hubungan spasial model GSTAR dapat dinyatakan dalam matriks pembobot. Pemilihan bobot menjadi salah satu komponen penting karena menentukan bagaimana hubungan spasial antar lokasi dimodelkan. Pembobot spasial yang digunakan pada penelitian ini dalam bobot invers jarak.

Dalam konteks spasial, matriks bobot invers jarak dibuat berdasarkan jarak antar lokasi sebenarnya. Jarak ini kemudian digunakan sebagai dasar untuk perhitungan bobot jarak invers. Hasil perhitungan bobot invers jarak, kemudian dinormalisasi. Normalisasi dilakukan untuk memastikan total bobot dari lokasi i ke setiap lokasi lain bernilai 1 (Anselin, 1988). Menurut Anselin (1988), normalisasi baris memastikan pengaruh lokal dapat ditafsirkan secara relatif terhadap semua lokasi lain di sekitar lokasi i . Dengan kata lain, normalisasi menghasilkan skala pengaruh lokal yang konsisten. Selain itu, LeSage & Pace (2009) menjelaskan bahwa normalisasi bobot (terutama *row normalization*) membuat model lebih stabil dan memudahkan interpretasi koefisien spasial sebagai bentuk rata-rata pengaruh tetangga. Secara umum bobot invers jarak dituliskan sebagai berikut (Huda *et al.*, 2021):

$$w_{ij} = \frac{\frac{1}{d_{ij}}}{\sum_{j=1}^N \frac{1}{d_{ij}}} \quad (11)$$

dengan $\sum_{i \neq j} w_{ij} = 1$, w_{ij} adalah nilai bobot antara lokasi ke- i dan lokasi ke- j . d_{ij} adalah jarak sebenarnya antara lokasi ke- i dan lokasi ke- j .



in ini, lokasi j didefinisikan sebagai kota-kota lain yang an spasial dengan kota i . Karena penelitian ini menggunakan a, Watampone, Makassar, Parepare dan Palopo) maka j ta kecuali kota i . Misalnya jika $i = \text{Bulukumba}$ maka $j = \text{sar, Parepare, Palopo}$. Hal ini mencerminkan bahwa setiap keterkaitan dengan kota-kota lain dalam sistem.

1.6.8 Identifikasi Orde Model GSTAR

Space Time Autocorrelation Function (STACF) dan *Space Time Partial Autocorrelation Function* (STPACF) digunakan untuk mengidentifikasi model GSTAR. Teknik ini mengadaptasi pendekatan dari Pfeifer dan Deutsch (1980). Batas signifikansi pada plot STACF dan STPACF ditentukan berdasarkan nilai kritis distribusi normal standar $z_{\alpha/2} = 1,96$ dibagi total observasi spasial-temporal, yaitu perkalian antara jumlah lokasi dan jumlah waktu pengamatan. Hal ini berbeda dengan plot ACF dan PACF yang hanya menggunakan jumlah observasi waktu saja (Pfeifer & Deutsch, 1980).

a. STACF (*Space Time Autocorrelation Function*)

Dalam kerangka multivariat, STACF menyatakan kovarians antara variabel acak yang tertunda baik dalam waktu maupun ruang. Karakteristik STACF GSTAR yaitu menurun secara signifikan (*tail off*) yang menunjukkan data tidak stasioner dalam spatio-temporal. Sebaliknya, untuk data stasioner, STACF biasanya menunjukkan nilai yang stabil atau mendekati nol setelah beberapa *lag*.

Dengan spasial lag $l = 0, 1, \dots, \lambda, k = 0$, dan lag waktu $s = 1, 2, \dots$, STACF didefinisikan sebagai berikut (Pfeifer, Deutsch, 1980):

$$\hat{\rho}_{l0}(s) = \frac{\sum_{i=1}^N \sum_{t=1}^T L^{(l)} Z_i(t) L^{(0)} Z_i(t+s)}{\sqrt{(\sum_{i=1}^N \sum_{t=1}^T (L^{(l)} Z_i(t))^2) \cdot (\sum_{i=1}^N \sum_{t=1}^T (L^{(0)} Z_i(t+s))^2)}} \quad (12)$$

di mana,

$\hat{\rho}_{l0}(s)$: nilai autokorelasi spatio-temporal pada lag spasial l dan lag waktu s antara variabel acak $Z_i(t)$ dan $Z_i(t+s)$.

$Z_i(t)$: deret waktu multivariat untuk lokasi i pada waktu t ,

$L^{(l)} Z_i(t)$: lag spasial untuk lokasi i pada waktu t dengan bobot spasial pada lag l dengan $L^{(l)} Z_i(t) = \sum_{j=1}^N w_{ij}^{(l)} Z_j(t)$

$L^{(0)} Z_i(t+s)$: lag temporal untuk lokasi i pada waktu $t+s$, yang dipengaruhi oleh bobot spasial pada lag 0.

b. STPACF (*Space Time Partial Autocorrelation Function*)

STPACF digunakan untuk mengidentifikasi orde terbaik dari model GSTAR dengan mempertimbangkan lag waktu dan lag spasial, serta melihat hubungan parsial antar komponen waktu dan ruang dalam model tersebut.

Karakteristik STPACF pada model GSTAR(1,1) menunjukkan adanya (*cut off*) pada lag waktu $s = 1$ dan lag spasial $l = 1$, yang menandakan bahwa model tersebut hanya melibatkan hubungan yang relevan pada waktu dan ruang dengan lag pertama. STPACF dapat dihitung menggunakan rumus (Pfeifer, Deutsch, 1980):

$$\hat{\gamma}_{h0}(s) = \sum_{j=1}^k \sum_{l=0}^{\lambda} \hat{\phi}_{jl} \hat{\gamma}_{hl}(s-j) \quad (13)$$



isi STPACF pada lag waktu s dan lag spasial $l = 0$,
eter autoregressive pada lag waktu j dan lag spasial,
en autokovarian pada lag waktu $s - j$,

- k : jumlah lag waktu yang dipertimbangkan,
 λ : jumlah lag spasial yang dipertimbangkan.

Persamaan (15) merupakan bentuk rekursif dari STPACF yang diperoleh melalui persamaan Yule-Walker spasial. Dengan demikian, perhitungan STACF dilakukan secara bertahap dengan memanfaatkan nilai-nilai autokovarian dan parameter *autoregressive* dari lag sebelumnya.

Setelah mengidentifikasi kandidat orde model GSTAR berdasarkan STACF dan STPACF, pemilihan orde terbaik dapat dilakukan dengan menggunakan *Akaike Information Criterion* (AIC). AIC digunakan untuk membandingkan berbagai model dengan kompleksitas berbeda dan memilih model dengan keseimbangan terbaik antara *goodness-of-fit* dan parsimoni. AIC didefinisikan sebagai berikut (Akaike, 1973 dalam Cavanaugh & Neath, 2019).

$$AIC = -2 \log L(\hat{\theta}) + 2k \quad (14)$$

di mana,

$L(\hat{\theta})$: likelihood maksimum dari model,

k : jumlah parameter dalam model.

Dalam konteks GSTAR, likelihood diperoleh dari model regresi spasial temporal yang mengestimasi parameter berdasarkan data deret waktu multivariat. Model dengan nilai AIC terkecil dipilih sebagai model terbaik karena memberikan keseimbangan antara akurasi dan kompleksitas model (Cavanaugh & Neath, 2019).

1.6.9 Estimasi Parameter Model GSTAR

Model GSTAR merupakan model linear sehingga parameternya dapat diduga dengan metode kuadrat terkecil. Model GSTAR dengan orde p dapat dituliskan dalam bentuk matriks sebagai berikut (Hapsari, 2017):

$$\begin{aligned} \begin{bmatrix} Z_1(t) \\ Z_2(t) \\ \vdots \\ Z_N(t) \end{bmatrix} &= \begin{bmatrix} \phi_{s0}^{(1)} & 0 & \cdots & 0 \\ 0 & \phi_{s0}^{(2)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \phi_{s0}^{(N)} \end{bmatrix} \begin{bmatrix} Z_1(t-s) \\ Z_2(t-s) \\ \vdots \\ Z_N(t-s) \end{bmatrix} + \begin{bmatrix} \phi_{sk}^{(1)} & 0 & \cdots & 0 \\ 0 & \phi_{sk}^{(2)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \phi_{sk}^{(N)} \end{bmatrix} \\ &\quad \begin{bmatrix} Z_1(t-s) \\ Z_2(t-s) \\ \vdots \\ Z_N(t-s) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ \vdots \\ e_N(t) \end{bmatrix} \\ &= \begin{bmatrix} \phi_{s0}^{(1)} Z_1(t-s) \\ \phi_{s0}^{(2)} Z_2(t-s) \\ \vdots \\ \phi_{s0}^{(N)} Z_N(t-s) \end{bmatrix} + \begin{bmatrix} \phi_{sk}^{(1)} [w_{12} Z_2(t-s) + w_{13} Z_3(t-s) + \cdots + w_{1N} Z_N(t-s)] \\ \phi_{sk}^{(2)} [w_{21} Z_1(t-s) + w_{23} Z_3(t-s) + \cdots + w_{2N} Z_N(t-s)] \\ \vdots \\ \phi_{sk}^{(N)} [w_{N1} Z_1(t-s) + w_{N2} Z_2(t-s) + w_{N3} Z_3(t-s) + \cdots] \end{bmatrix} \\ &\quad + \begin{bmatrix} e_1(t) \\ e_2(t) \\ \vdots \\ e_N(t) \end{bmatrix} \end{aligned}$$

$w_{ij} Z_j(t)$ maka model GSTAR yang ditulis dalam bentuk linear:

$$Z = X\beta + e \quad (15)$$



Jika dijabarkan dalam bentuk matriks, persamaan (15) dapat ditulis sebagai berikut:

$$Z = \begin{bmatrix} Z_1(t) \\ Z_2(t) \\ \vdots \\ Z_n(t) \end{bmatrix};$$

$$X = \begin{bmatrix} Z_1(t-s) & 0 & \cdots & 0 & V_1(t-s) & 0 & \cdots & 0 \\ 0 & Z_2(t-s) & \cdots & 0 & 0 & V_2(t-s) & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & Z_N(t-s) & 0 & 0 & \cdots & V_N(t-s) \end{bmatrix};$$

$$\beta = \begin{bmatrix} \phi_{s0}^1 \\ \phi_{s0}^2 \\ \vdots \\ \phi_{s0}^N \\ \phi_{sk}^1 \\ \phi_{sk}^2 \\ \vdots \\ \phi_{sk}^N \end{bmatrix}; e = \begin{bmatrix} e_1(t) \\ e_2(t) \\ \vdots \\ e_N(t) \end{bmatrix},$$

Estimasi parameter β dilakukan dengan meminimalkan jumlah kuadrat error yaitu $Q(B) = e'e$, dengan:

$$Q(B) = (Z - X\beta)'(Z - X\beta) \quad (16)$$

$$Z'Z - 2\beta'X'Z + \beta'X'X\beta$$

Untuk meminimalkan $Q(B)$, turunkan fungsi tersebut terhadap β

$$\frac{\partial Q(B)}{\partial \beta} = \frac{\partial}{\partial \beta} (Z'Z - 2\beta'X'Z + \beta'X'X\beta) = -2X'Z + 2X'X\beta$$

Untuk mencapai minimum, turunan fungsi objektif disetarakan dengan nol:

$$\begin{aligned} \frac{\partial Q(B)}{\partial \beta} &= 0 \\ -2X'Z + 2X'X\beta &= 0 \\ 2(X'X\beta - X'Z) &= 0 \\ X'X\beta &= X'Z \\ \hat{\beta} &= [X'X]^{-1}X'Z \end{aligned} \quad (17)$$

Estimator $\hat{\beta}$ ada dan uni jika matriks $X'X$ bersifat *invertible* (nonsingular) (Hapsari, 2017).

1.6.10 Model Autoregressive Conditional Heteroscedasticity (ARCH)

Model *Autoregressive Conditional Heteroskedasticity* (ARCH) pertama kali diperkenalkan oleh Engle (1982) untuk mengatasi masalah heteroskedastisitas deret waktu.



a, dalam analisis deret waktu, residual e_t sering diasumsikan stan (homoskedastisitas). Namun, pada banyak data terutama an, terdapat kondisi di mana variansi residual tidak konstan, ubah dari waktu ke waktu. Fenomena inilah yang disebut bersyarat. Model ARCH digunakan memodelkan perilaku

variansi residual secara dinamis. Secara matematis, model ARCH (p) dirumuskan sebagai berikut (Engle, 1982):

$$\begin{aligned} e_t &= \varepsilon_t \sqrt{h_t} \\ h_t &= \sigma_t^2 = a_0 + \sum_{i=1}^p a_i e_{t-i}^2 \end{aligned} \quad (18)$$

di mana,

- h_t : variansi bersyarat pada waktu t ,
- $a_0 > 0$: konstanta positif,
- $\varepsilon_t \sim N(0,1)$: residual standar,
- e_{t-i}^2 : residual kuadrat dari periode sebelumnya,
- $a_1, a_2, \dots, a_p$: parameter model ARCH,
- $a_0 > 0$ dan $a_i \geq 0$.

Sebagai contoh, persamaan model ARCH(1):

$$h_t = \sigma_t^2 = a_0 + a_1 e_{t-1}^2 \quad (19)$$

Untuk mendeteksi ada tidaknya efek ARCH dalam residual digunakan uji lagrange Multiplier atau biasa disebut uji ARCH-LM. Hipotesis yang diuji sebagai berikut:

$H_0: a_1 = a_2 = \dots = a_p = 0$ (tidak terdapat efek ARCH)

H_0 : setidaknya terdapat satu $a_i \neq 0, i = 1, 2, \dots, p$ (terdapat efek ARCH)

Pengujian dilakukan dengan meregresi residual kuadrat terhadap lagnya:

$$e_t^2 = a_0 + a_1 e_{t-1}^2 + a_2 e_{t-2}^2 + \dots + a_p e_{t-p}^2 + \varepsilon_t \quad (20)$$

Statistik uji yang digunakan dalam uji ARCH-LM adalah:

$$LM = T \cdot R^2 \quad (21)$$

di mana,

- T : jumlah observasi,
- R^2 : koefisien determinasi dari regresi residual kuadrat,

Jika nilai p_{value} dari statistik uji lebih kecil dari tingkat signifikansi $\alpha = 0,05$ maka H_0 ditolak yang berarti terdapat efek ARCH. Sebaliknya, jika nilai p_{value} lebih besar dari $\alpha = 0,05$ maka tidak ada bukti yang cukup untuk menolak H_0 yang berarti tidak ada pengaruh efek ARCH.

Dalam penelitian ini, uji ARCH-LM diterapkan pada residual model GSTAR. Jika hasil pengujian menunjukkan adanya efek ARCH, maka residual tersebut akan dimodelkan lebih lanjut menggunakan model ARCH. Dengan demikian, terbentuklah model GSTAR-ARCH, yaitu model yang menggabungkan struktur spasial-temporal dari GSTAR dengan dinamika volatilitas residual yang ditangkap oleh ARCH

Model GSTAR-ARCH dengan orde waktu (p), spasial de ARCH q dapat dinyatakan sebagai berikut (Monika, 2022):

$$\sum_{s=1}^p [\Phi_{s0} Z(t-s) + \sum_{k=1}^{qs} \Phi_{sk} W^{(k)} Z(t-s) + e(t)] \quad (22)$$

residual $e(t)$ dimodelkan menggunakan model ARCH, yaitu:

$$e(t) = D_t \varepsilon_t \quad (23)$$



di mana:

$$D_t = \text{diag}(\sqrt{h_{1,t}}, \dots, \sqrt{h_{N,t}})$$

dan

$$\varepsilon_t \sim N(0,1)$$

Setiap elemen $h_{i,t}$ pada D_t merepresentasikan ragam bersyarat dari lokasi i yang dimodelkan melalui proses ARCH pada persamaan (19), ε_t adalah residual standar. Dengan demikian, ragam bersyarat dari $e(t)$ dapat ditulis sebagai berikut:

$$\Sigma_t = \text{Var}[e_t|F_{t-1}] = D_t^2 = \text{diag}(h_{1,t}, \dots, h_{N,t})$$

Model GSTAR-ARCH menggabungkan struktur spasial temporal dari model GSTAR dengan perubahan volatilitas residual dari model ARCH. Setelah estimasi parameter kedua model diperoleh, interval prediksi dikonstruksi dengan menggabungkan ramalan model GSTAR dengan variansi bersyarat dari model ARCH. Berikut ini rumus batas atas dan bawah (Pellegrini et al., 2011):

$$\begin{aligned} \text{Batas atas (Upper bound)} &= \hat{Z}(t) + z_{\alpha/2} \times \sqrt{h_t} \\ \text{Batas bawah (Lower bound)} &= \hat{Z}(t) - z_{\alpha/2} \times \sqrt{h_t} \end{aligned} \quad (24)$$

di mana,

$z_{\alpha/2}$: nilai kritis dari distribusi normal standar ($z_{0,025} = 1,96$ untuk interval kepercayaan 95%).

$\sqrt{h_t}$: simpangan baku dari residual yang dimodelkan oleh ARCH,

$\hat{Z}(t)$: hasil prediksi dari model GSTAR.

Batas atas dan bawah merupakan interval prediksi yang memperhitungkan volatilitas residual melalui variansi bersyarat h_t dari model ARCH. Dengan demikian, prediksi $\hat{Z}(t)$ dari model GSTAR dilengkapi dengan rentang ketidakpastian yang berasal dari heteroskedastisitas bersyarat (Pellegrini et al., 2011).

1.6.11 Estimasi Parameter Model ARCH

Estimasi parameter pada model ARCH dilakukan dengan menggunakan metode Maximum Likelihood Estimation (MLE), karena model ini bersifat nonlinear. Tujuan utama MLE adalah mencari nilai parameter yang memaksimalkan kemungkinan munculnya data residual sesuai dengan model ARCH yang dibentuk. Dalam penelitian ini, residual dari model GSTAR yang menunjukkan gejala heteroskedastisitas dianalisis lebih lanjut menggunakan ARCH agar pola variansi yang tidak konstan dapat ditangkap secara memadai.

Proses estimasi parameter model ARCH dilakukan dengan memaksimalkan fungsi likelihood, yang memberikan parameter optimal untuk model ARCH



residual model GSTAR dihitung menggunakan rumus $e(t) = Z(t) - \hat{Z}(t)$ adalah data observasi, dan $\hat{Z}(t)$ adalah prediksi dari model tersebut menjadi input untuk model ARCH. Pada model ARCH variansi bersyarat h_t didefinisikan pada persamaan (18).

Borja (1982), dalam model ARCH residual $e(t)$ tidak saling near, namun tidak bersifat independen, karena variansi h_t

bergantung pada residual sebelumnya. Residual e_t diasumsikan mengikuti distribusi normal bersyarat dengan rata-rata nol dan variansi h_t , yaitu:

$$e_t | F_{t-1} \sim N(0, h_t)$$

Fungsi kepadatan peluang residual bersyarat $f(e_t | h_t)$ di rumuskan sebagai berikut:

$$f(e_t | h_t) = \frac{1}{\sqrt{2\pi h_t}} \exp\left(-\frac{e_t^2}{2h_t}\right) \quad (25)$$

Untuk n data residual, fungsi likelihood total dinyatakan sebagai berikut:

$$L(a_0, a_1, \dots, a_p) = \prod_{t=1}^n f(e_t | h_t) = \prod_{t=1}^n \frac{1}{\sqrt{2\pi h_t}} \exp\left(-\frac{e_t^2}{2h_t}\right) \quad (26)$$

Untuk memudahkan proses estimasi, digunakan log-likelihood yang dinyatakan sebagai berikut:

$$\ln L(a_0, a_1, \dots, a_p) = -\frac{1}{2} \sum_{t=p+1}^n \left[\ln(2\pi) + \ln(h_t) + \frac{e_t^2}{h_t} \right] \quad (27)$$

Parameter optimal diperoleh dengan memaksimalkan fungsi log-likelihood, yaitu dengan menghitung turunan parsial log-likelihood terhadap parameter $a_0, a_1, \dots, a_p$ dan menyamakannya dengan nol. Proses ini dilakukan secara iteratif menggunakan metode Newton-Raphson dengan pembaruan parameter menggunakan rumus $\theta^{(k+1)} = \theta^{(k)} - H(\theta^{(k)})^{-1} \nabla l(\theta^{(k)})$, di mana $\nabla l(\theta^{(k)})$ adalah gradient log-likelihood dan $H(\theta^{(k)})$ adalah matriks hessian. Proses iterasi dihentikan ketika perubahan nilai log-likelihood sangat kecil atau mencapai maksimum.

Setelah diperoleh estimasi variansi bersyarat h_t dari model ARCH, dilakukan pembentukan residual standar untuk keperluan diagnostik. Residual standar didefinisikan sebagai berikut (Engle, 1982):

$$\varepsilon_t = \frac{e_t}{\sqrt{\hat{h}_t}} \quad (28)$$

Di mana, e_t adalah residual model GSTAR, $\hat{h}_t$ merupakan estimasi variansi kondisional pada waktu ke- t dari model ARCH dan ε_t adalah residual standar. Residual standar digunakan untuk mengevaluasi apakah model ARCH telah berhasil mengondisikan variansi residual model GSTAR menjadi konstan, sehingga residual tidak lagi menunjukkan kondisi heteroskedastisitas (Engle, 1982).

1.6.12 Diagnostik Residual Model GSTAR-ARCH

Langkah selanjutnya setelah estimasi parameter model yang signifikan adalah pengujian asumsi residual. Residual yang digunakan adalah residual standar.



Residual yang harus dipenuhi antara lain, residual standar bersifat *white noise* dan berdistribusi normal (Setyowati *et. al.*, 2021). Untuk menguji asumsi ini, dilakukan dengan uji ARCH-LM sesuai persamaan (21).

Residual (e_t) disebut sebagai proses *white noise* apabila variabel acak tersebut memiliki rata-rata nol, variansi konstan yaitu tidak ada korelasi antara residual yang bersifat *white noise* adalah residual yang tidak

memiliki pola sistematis dan hanya mengandung noise acak. Jika residual independen dan berdistribusi normal, maka disebut Gaussian *white noise* (Wei, 2006).

Untuk mengetahui asumsi *white noise* digunakan uji *Ljung Box* dengan hipotesis yaitu (Wei, 2006):

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

H_1 : minimal terdapat $\rho_f \neq 0, f = 0, 1, 2, \dots, K$ (Residual memiliki autokorelasi)

Statistik uji *Ljung Box* dihitung sebagai

$$Q = T(T+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{T-k} \quad (29)$$

Di mana, $\hat{\rho}_k$ adalah autokorelasi dari residual, k adalah lag $1, 2, \dots, p$ dan T adalah jumlah residual. Q mengikuti distribusi χ^2 dengan derajat kebebasan K . Jika $p_{value} < 0,05$, maka H_0 ditolak yang menunjukkan bahwa residual memiliki autokorelasi atau tidak *white noise*.

b. Distribusi Normal

Selain asumsi *white noise*, mengecek asumsi residual standar berdistribusi normal juga penting dilakukan untuk memastikan keabsahan inferensi statistik yang dilakukan. Pengujian ini dilakukan untuk mengetahui residual standar dari model GSTAR-ARCH yang mengikuti distribusi normal atau tidak. Uji Kolmogorov-Smirnov digunakan untuk memastikan bahwa model tidak melanggar asumsi normalitas. Hipotesis dalam uji Kolmogorov-Smirnov adalah (Aryani, 2013):

H_0 : Residual berdistribusi normal

H_1 : Residual tidak berdistribusi normal

Dengan statistik uji:

$$D = \sup |F_n(x) - F(x)| \quad (30)$$

di mana,

$F_n(x)$: fungsi distribusi kumulatif empiris residual,

$F(x)$: fungsi distribusi kumulatif normal teoritis berdasarkan rata-rata dan varians residual

Jika nilai p_{value} dari uji lebih kecil dari tingkat signifikansi ($p_{value} < 0,05$), maka H_0 ditolak, yang berarti data tidak mengikuti distribusi normal. Sebaliknya, jika $p_{value} \geq 0,05$ maka tidak ada bukti cukup untuk menolak H_0 , yang menunjukkan bahwa residual mengikuti distribusi normal.

1.6.13 Pemilihan Model Terbaik

Ada beberapa metode yang dapat digunakan untuk memilih model terbaik, ukuran



yang digunakan dalam penelitian ini adalah *Root Mean Square* (RMSE) adalah salah satu metode yang digunakan untuk mengukur dalam prediksi model. RMSE mengukur seberapa besar deviasi yang diprediksi oleh model dan nilai yang sebenarnya. Nilai kecil menunjukkan bahwa model memiliki kesalahan yang lebih kecil dalam melakukan prediksi (Irawati & Tarno, 2015).

Berikut rumus untuk menghitung RMSE (Wei, 2006):

$$RMSE = \sqrt{\frac{1}{m} \sum_{t=1}^m (Z(t) - \hat{Z}(t))^2}, \quad (31)$$

di mana,

Z_t : Data sebenarnya,

$\hat{Z}_t$: data hasil ramalan

m : banyaknya ramalan yang dilakukan.

Semakin kecil nilai RMSE, semakin baik model dalam memprediksi nilai yang mendekati nilai yang sebenarnya. Nilai RMSE yang lebih tinggi menunjukkan kesalahan prediksi yang lebih besar. Namun, RMSE juga sensitif terhadap outliers, karena kesalahan dikuadratkan, yang dapat memberikan bobot lebih besar pada kesalahan prediksi yang ekstrem.

1.6.14 Inflasi

Inflasi merupakan tingkat kenaikan harga secara umum dari barang/komoditas dan jasa selama suatu periode tertentu. Inflasi diukur dengan tingkat inflasi yaitu tingkat perubahan dari tingkat harga secara umum (Hartono, 2022). Pengelolaan inflasi merupakan salah satu fokus utama kebijakan ekonomi nasional karena inflasi yang terkendali berkontribusi pada stabilitas ekonomi stabil, mendorong pertumbuhan ekonomi jangka panjang, meningkatkan investasi, serta menciptakan lapangan kerja. Bank Indonesia, sebagai bank sentral, memainkan peran utama dalam mengendalikan inflasi melalui berbagai instrumen kebijakan moneter, seperti penyesuaian suku bunga, intervensi di pasar uang, dan pengaturan likuiditas. Selain itu, faktor-faktor lain yang mempengaruhi inflasi termasuk pertumbuhan ekonomi, produksi barang dan jasa, serta kebijakan fiskal pemerintah, yang saling berinteraksi dalam menentukan tingkat inflasi (BPS, 2023).

Dalam ilmu ekonomi, inflasi diklasifikasikan berdasarkan penyebab utamanya, yaitu:

- a. *Demand Pull Inflation*. Inflasi ini terjadi akibat peningkatan permintaan total (aggregate demand) yang tidak diimbangi oleh kapasitas produksi. Ketika tingkat pendapatan masyarakat meningkat, konsumsi pun naik, sementara produksi barang dan jasa tidak mampu memenuhi lonjakan permintaan. Kondisi ini mendorong kenaikan harga secara terus-menerus. Dalam jangka pendek, peningkatan harga ini mungkin direspons dengan penambahan kapasitas produksi, tetapi jika kenaikan produksi tidak sebanding dengan permintaan, inflasi akan terus berlanjut (Indriyani, 2016).

- b. *Cost Push Inflation*. Jenis inflasi ini dipicu oleh kenaikan biaya produksi, seperti kenaikan harga bahan baku, yang mengurangi kemampuan produsen untuk menjual barang dan jasa. Penurunan penawaran total (aggregate supply) menyebabkan harga naik. Cost-push kali terjadi bersamaan dengan resesi, sehingga berdampak ekonomian secara keseluruhan (Indriyani, 2016).



- c. Ekspektasi. Inflasi ekspektasi muncul sebagai respons terhadap prediksi para pelaku ekonomi tentang kondisi ekonomi masa depan. Ketika pelaku ekonomi memperkirakan adanya kenaikan harga atau perubahan kebijakan, mereka cenderung menyesuaikan harga barang dan jasa lebih awal, sehingga menciptakan inflasi. Faktor-faktor seperti perubahan kebijakan fiskal atau moneter, inflasi di masa lalu, dan kondisi ekonomi terkini mempengaruhi ekspektasi ini. Oleh karena itu, inflasi ekspektasi berperan penting dalam pembentukan harga dan upah di pasar (Suseno & Astiyah, 2009).

Menurut Badan Pusat Statistik (BPS, 2023), inflasi diukur berdasarkan perubahan Indeks Harga Konsumen (IHK) pada periode waktu tertentu dibandingkan dengan periode sebelumnya. IHK mencerminkan rata-rata perubahan harga barang dan jasa yang dikonsumsi rumah tangga, sehingga inflasi sering digunakan untuk mengevaluasi dampak kenaikan harga terhadap daya beli masyarakat. Adapun rumus untuk menghitung laju inflasi adalah sebagai berikut:

$$LI_n = \frac{I_n - I_{(n-1)}}{I_{(n-1)}} \times 100 \quad (32)$$

di mana,


LI_n : laju inflasi periode ke- n

I_n : indeks harga konsumen periode ke- n

I_{n-1} : indeks harga konsumen periode ke- $n - 1$



1.6.15 Kerangka Konseptual



Gambar 1. kerangka konseptual



BAB II METODE PENELITIAN

2.1 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder, yaitu data inflasi 5 Kota di Sulawesi Selatan pada periode Januari 2014 hingga Desember 2023. Data ini diperoleh dari Badan Pusat Statistik (BPS) yang merupakan hasil pengukuran inflasi Kota Bulukumba, Watampone, Makassar, Parepare dan Palopo.

2.2 Variabel Penelitian

Variabel dalam penelitian ini disimbolkan $Z_i(t)$ yang menyatakan inflasi pada Kota ke- i dengan $i = 1,2,3,4,5$, (Bulukumba, Watampone, Makassar, Parepare, Palopo) dan waktu ke- t . Data inflasi disajikan dalam bentuk persen. Secara rinci dapat dilihat pada tabel 2.

Tabel 2. Variabel penelitian

No.	Variabel Penelitian	Nama Variabel
1.	$Z_1(t)$	Inflasi Kota Bulukumba waktu ke- t
2.	$Z_2(t)$	Inflasi Kota Watampone waktu ke- t
3.	$Z_3(t)$	Inflasi Kota Makassar waktu ke- t
4.	$Z_4(t)$	Inflasi Kota Parepare waktu ke- t
5.	$Z_5(t)$	Inflasi Kota Palopo waktu ke- t

Sumber: Data olah, 2025

2.3 Metode Analisis Data

Adapun langkah-langkah yang dilakukan berdasarkan tujuan penelitian adalah sebagai berikut:

1. Analisis deskriptif data dan mengidentifikasi pola data.
2. Memeriksa korelasi spasial antar lokasi dengan menggunakan Indeks Moran.
3. Melakukan pengujian asumsi terhadap data deret waktu, yaitu pemeriksaan stasioneritas data terhadap ragam dan rata-rata.
4. Melakukan penanganan apabila data tidak memenuhi asumsi. Jika data tidak stasioner terhadap ragam maka perlu dilakukan transformasi. Sementara jika data tidak stasioner terhadap rata-rata maka perlu dilakukan *differencing* hingga data stasioner.
5. Membagi data dengan proporsi 80% data *training* dan 20% data *testing*.
6. Membentuk matriks bobot invers jarak.



Optimized using
trial version
www.balesio.com

Se model GSTAR yakni orde waktu dan spasial. Menentukan menggunakan STPACF, sementara orde spasial yang digunakan tu.

stimasi parameter model GSTAR bobot invers jarak *Ordinary Least Square* (OLS).

nya pelanggaran asumsi homoskedastisitas dengan mengecek GSTAR menggunakan uji *Lagrange Multiplier*.

10. Menangani apabila terdapat heteroskedastisitas pada residual model GSTAR dengan memodelkan residual menggunakan model ARCH.
11. Estimasi parameter model ARCH menggunakan *Maximum Likelihood Estimation* (MLE).
12. Diagnostik residual standar model GSTAR-ARCH menggunakan uji asumsi homoskedastisitas dengan uji ARCH-LM, asumsi *white noise* dengan *Ljung-Box test* dan asumsi normalitas dengan uji Kolmogorov-Smirnov.
13. Melakukan permalan inflasi lima kota di Sulawesi Selatan menggunakan model GSTAR-ARCH berbasis bobot invers jarak.
14. Evaluasi hasil permalan model GSTAR-ARCH menggunakan *Root Mean Square Error* (RMSE).

