

## **ANALISIS SPASIAL DAN TEMPORAL DATA KEJADIAN BENCANA BANJIR DENGAN MODEL GENERALIZED SPACE TIME AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (GSTARIMA)**

Hanifa Mardiatun Nasution<sup>1</sup>, Hendra Cipta<sup>2</sup>

<sup>1,2</sup> Universitas Islam Negeri Sumatera Utara, Medan, Indonesia

[hanifa0703193098@uinsu.ac.id](mailto:hanifa0703193098@uinsu.ac.id)

**ABSTRACT** *The Generalized Space-Time Autoregressive Integrated Moving Average (GSTARIMA) is a model used to model time series data that exhibits spatial dependencies among its locations as well as temporal dependencies. GSTARIMA is applied in various economic contexts, including analyzing exports and imports, exchange rates, production, inflation, and rainfall. This research aims to develop the best GSTARIMA model and utilize it to forecast rainfall in the Medan Belawan District. The GSTARIMA model combines temporal and geographical aspects by adjusting parameters for each observed location. The data used in this study consists of monthly rainfall data for the Medan Belawan District, obtained from the Maritime Class II Meteorological Station in Belawan, spanning from January 2020 to December 2022. The identification of Autoregressive (AR) and Moving Average (MA) orders was performed through the analysis of the Autocorrelation Matrix (MACF) and Partial Autocorrelation Matrix (MPACF). This study employed a spatial order of 1, along with an inverse distance weighting matrix and cross-correlation normalization. Parameter estimation used the generalized least squares (GLS) method. The research results indicate that the GSTARIMA model (2,0,0) with the inverse distance weighting matrix achieved the lowest Mean Absolute Percentage Error (MAPE) rate, specifically at 1.0170. Thus, this model is considered the best for forecasting rainfall in the Medan Belawan District.*

**Keywords:** GSTARIMA model, rainfall forecasting, spatial dependencies, time series data

**ABSTRAK** *Generalized Space Time Autoregressive Integrated Moving Average (GSTARIMA) adalah model yang digunakan untuk memodelkan data deret waktu yang memiliki ketergantungan spasial antara lokasi-lokasinya (spasial) dan juga ketergantungan pada waktu. GSTARIMA digunakan dalam berbagai konteks ekonomi, termasuk analisis ekspor-impor, nilai tukar, produksi, inflasi, dan curah hujan. Tujuan dari penelitian ini adalah untuk mengembangkan model GSTARIMA terbaik dan menggunakan model tersebut untuk meramalkan curah hujan di Kecamatan Medan Belawan. Model GSTARIMA ini menggabungkan aspek waktu dan aspek geografis dengan penyesuaian parameter yang khusus untuk setiap lokasi yang diamati. Data yang digunakan dalam penelitian ini adalah data curah hujan bulanan di Kecamatan Medan Belawan, yang diperoleh dari Stasiun*

Meteorologi Kelas II Maritim Belawan, mulai dari Januari 2020 hingga Desember 2022. Identifikasi orde *Autoregressive* (AR) dan *Moving Average* (MA) dilakukan melalui analisis Matriks *Autocorrelation* (MACF) dan Matriks *Partial Autocorrelation* (MPACF). Dalam penelitian ini, digunakan orde spasial 1 dengan matriks pembobot invers jarak dan normalisasi korelasi silang. Estimasi parameter dilakukan dengan menggunakan metode *generalized least squares* (GLS). Hasil penelitian menunjukkan bahwa model GSTARIMA (2,0,0) dengan matriks pembobot invers jarak memiliki tingkat *Mean Absolute Percentage Error* (MAPE) terkecil, yaitu sebesar 1,0170. Dengan demikian, model ini dianggap sebagai model terbaik untuk meramalkan curah hujan di Kecamatan Medan Belawan.

**Kata-kata Kunci:** model GSTARIMA, peramalan curah hujan, ketergantungan spasial, data deret waktu

## PENDAHULUAN

Analisis deret waktu adalah metode yang mempelajari data dalam konteks waktu, baik secara teori maupun praktis. Menurut Cryer & Chan (2008), data deret waktu merupakan rangkaian data yang diamati dan diurutkan berdasarkan waktu. Salah satu aplikasi penting dari analisis deret waktu adalah peramalan atau prediksi nilai-nilai di masa depan berdasarkan data yang telah terjadi sebelumnya. Dalam analisis deret waktu, terdapat dua jenis utama, yaitu analisis deret waktu univariat dan multivariat.

Analisis deret waktu univariat fokus pada satu variabel deret waktu tanpa mempertimbangkan pengaruh variabel lain. Dalam pemodelan deret waktu univariat, pola-pola ditemukan melalui identifikasi fungsi *Autocorrelation* (ACF) dan *Partial Autocorrelation Function* (PACF) (Rachmadania, 2018). Sementara itu, analisis deret waktu multivariat melibatkan lebih dari satu variabel deret waktu atau mempertimbangkan pengaruh dari variabel lain, seperti pengaruh lokasi. Pemodelan deret waktu multivariat melibatkan identifikasi *Matrix Autocorrelation Function* (MACF) dan *Matrix Partial Autocorrelation Function* (MPACF).

Banjir adalah peristiwa di mana daratan yang biasanya kering menjadi tergenang oleh air, yang dapat disebabkan oleh curah hujan tinggi, topografi wilayah dataran rendah hingga cekung, serta rendahnya kemampuan tanah untuk menyerap air. Banjir juga dapat terjadi karena naiknya permukaan air akibat curah hujan abnormal, perubahan suhu, kerusakan tanggul atau bendungan, pencairan salju yang cepat, atau hambatan aliran air di tempat lain. Bencana banjir, terutama selama musim hujan, sering melanda Indonesia, terutama di daerah Medan Belawan. Terdapat beberapa faktor alam yang berkontribusi signifikan terhadap banjir di Medan, seperti curah hujan yang tinggi dan pasang naiknya air laut. Di samping itu, aktivitas manusia juga berperan penting dalam meningkatkan risiko banjir, seperti penggunaan lahan yang tidak tepat, pemukiman di daerah bantaran sungai, penggundulan hutan, pembuangan sampah ke dalam sungai, dan pembangunan di daerah dataran banjir (Soehatman, 2010).

Model GSTARIMA adalah suatu model statistik yang digunakan untuk menganalisis dan memodelkan data dalam konteks ruang dan waktu, termasuk data curah hujan. Keterkaitan antara model GSTARIMA dengan karakteristik curah hujan sangat relevan, karena model ini memungkinkan pemodelan curah hujan dalam aspek spasial dan temporal. Ini memiliki implikasi penting dalam berbagai bidang, seperti pemodelan banjir, manajemen sumber daya air, dan prediksi cuaca. Selain itu, model ini juga dapat digunakan untuk mengidentifikasi tren jangka panjang dalam data curah hujan, seperti peningkatan atau penurunan seiring berjalannya waktu.

Curah hujan merupakan salah satu fenomena alam yang menjadi komponen utama dalam siklus air. Dalam konteks perubahan iklim yang semakin diperhatikan, informasi yang akurat tentang variasi statistik dari karakteristik curah hujan menjadi sangat penting. Analisis dan pemodelan ini dapat diadaptasi untuk memprediksi curah hujan di wilayah lain yang memiliki topografi dan iklim serupa setelah melalui serangkaian uji statistik (Jimawan et al., 2018).

Tujuan utama dari penelitian ini adalah untuk mengembangkan model GSTARIMA terbaik dan menggunakannya untuk meramalkan bencana banjir di Medan Belawan. Pemilihan model terbaik didasarkan pada nilai rata-rata *Root Mean Square Error* (RMSE) yang terkecil. Analisis spasial adalah teknik analisis ruang yang dapat digunakan dalam pemrosesan data Sistem Informasi Geografis (SIG). Hasil analisis data spasial sangat bergantung pada lokasi atau tempat di mana objek sedang dianalisis.

Berdasarkan hasil estimasi dalam penelitian ini, terdapat indikasi adanya kointegrasi antara variabel yang digunakan, khususnya dalam konteks data bencana banjir. Sebagai respons terhadap temuan tersebut, penelitian ini akan memperluas model GSTARIMA menjadi model *Generalized Space Time Autoregressive Integrated Moving Average* (GSTARIMA) musiman. Dengan demikian, penelitian ini mengeksplorasi pemodelan dan peramalan data bencana banjir di Kecamatan Medan Belawan dengan menggunakan model peramalan GSTARIMA.

## **METODE PENELITIAN**

---

Data yang digunakan dalam penelitian ini adalah data curah hujan di Kec Medan Belawan periode januari 2020 sampai Desember 2022. Data diperoleh dari Stasiun Meteorologi Kelas II Maritim Belawan yang berada di Gabion, Jl. Raya Pelabuhan III, Bagan Deli, Medan Belawan, Kota Medan Sumatera Utara 20414. Penelitian ini menggunakan metode penelitian kuantitatif, yaitu sebuah penelitian dimana dalam praktiknya dilakukan dengan menggunakan data sekunder yang diperoleh dari publikasi oleh pihak lain pada suatu kurun waktu tertentu. Sedangkan model yang diterapkan dalam penelitian ini merupakan model *generalized space time autoregressive integrated moving average*.

### Stasioneritas dalam Variansi

Menurut (Makridakis et all., 1999), data dikatakan stasioner terhadap ragam apabila tidak terdapat fluktuasi pada data atau data bersifat konstan sepanjang waktu. Untuk mengetahui apakah data stasioner terhadap ragam atau tidak, dapat dideteksi menggunakan plot Box-Cox. Apabila nilai parameter transformasi ( $\lambda$ ) sama atau bernilai satu, maka dapat dikatakan bahwa data telah stasioner terhadap ragam dan sebaliknya.

Transformasi Box-Cox dilakukan agar data memenuhi stasioneritas terhadap ragam, secara umum perhitungan transformasi dengan rumus sebagai berikut:

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

Dimana  $\lambda$  disebut sebagai parameter Transformasi.

### Stasioneritas dalam Rata-rata

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

#### Uji Augmented Dickey-fuller (ADF)

Stasioneritas pada rata-rata dapat diperiksa dengan Augmented Dickey- Fuller Test (ADF). Jika data tidak stasioner terhadap rata-rata, maka perlu dilakukan proses diferensi hingga data dinyatakan stasioner terhadap rata-rata. Berikut adalah bentuk diferensi pertama ( $d=1$ ):

$$\nabla Z_t = Z_t - Z_{t-1} \quad (2)$$

Keterangan:

$\nabla Z_t$  = Hasil differensi waktu ke-t

$Z_t$  = Hasil pengamatan waktu ke-t

$Z_{t-1}$  = Hasil pengamatan waktu ke- (t-1)

Hipotesis untuk uji stasioneritas data adalah:

$H_0: \varphi = 0$ , ( $Y_t$  tidak stasioner)

$H_1: \varphi < 0$ , ( $Y_t$  stasioner)

Statistik Uji :

$$\tau_{\hat{\varphi}} = \frac{\hat{\varphi}}{se(\hat{\varphi})} \quad (3)$$

Jika nilai statistik  $|\tau|$  lebih kecil dari nilai kritis, maka  $H_0$  ditolak atau dapat dikatakan data tersebut stasioner. Nilai kritis dalam Uji ADF dapat dilihat dalam tabel Mackinnon. Ketiga variabel sudah stasioner sehingga hasil ini mengindikasikan

bahwa model *Autoregressive Distributed Lag* (ADL) dapat dibentuk dari variabel-variabel tersebut.

### Pemodelan *Generalized Space Time Autoregressive Integrated Moving Average* (GSTARIMA)

Model GSTARIMA dapat digunakan untuk memodelkan data deret waktu multivariat yang mempertimbangkan perbedaan karakteristik antar lokasinya. Sehingga model GSTARIMA dinyatakan sebagai model yang fleksibel sebagai generalisasi dari model STARIMA. Perbedaan yang mendasar antara model STARIMA dengan GSTARIMA terletak pada parameter, pada model STARIMA  $\Phi_{kl}$  dan  $\Theta_{kl}$  merupakan konstanta sedangkan untuk model GSTARIMA berupa matriks  $\Phi_{kl}$  dan  $\Theta_{kl}$ . secara umum penulisan model GSTARIMA dapat dituliskan sebagai berikut (Shelly Rachmadania (2):

$$\nabla Z_{it} = \sum_{k=1}^p \sum_{l=0}^{\lambda_p} \Phi_{kl} W^{(l)} \nabla Z_{i(t-k)} + e_{it} - \sum_{k=1}^q \sum_{l=0}^{mq} \Theta_{kl} W^{(l)} e_{i(t-k)} \quad (4)$$

Keterangan:

- $\nabla Z_{it}$  = Vector acak yang mengalami diferensiasi dengan ukuran  $(n \times 1)$  pada waktu  $t$
- $\lambda_p$  = Orde space ke- $p$  pada autoregressive
- $p$  = Jumlah lokasi
- $\Phi_{kl}$  = Matriks diagonal parameter autoregressive pada lag waktu ke- $k$  dan lag spasial ke- $l$
- $\Theta_{kl}$  = Matriks diagonal parameter moving average pada lag waktu ke- $k$  dan lag spasial ke- $l$
- $W^{(l)}$  = Matriks bobot ukuran  $(n \times n)$  pada lag space  $l$  (dimana  $s = 0, 1, 2, \dots$ )
- $e_{it}$  = Vector noise ukuran  $(n \times 1)$  berdistribusi normal multivariate dengan mean 0 dan matriks varians-kovarians  $\sigma^2 n$

### *Matrix Autocorrelation Function* (MACF)

Fungsi matrix korelasi sangat dibutuhkan pada proses identifikasi model Vektor MA( $q$ ). Untuk menyatakan bahwa model yang identifikasi adalah model Vektor MA( $q$ ), dapat diperoleh melalui identifikasi matriks korelasi yang bernilai nol setelah lag ke- $q$ . Identifikasi bentuk matriks dan grafik dapat mengalami kesulitan apabila ukuran dimensi dan vektor yang semakin besar.

Adapun fungsi matriks korelasi sampel (MACF) dapat dinyatakan dengan rumus sebagai berikut:

$$\hat{\rho}_{ij}(k) = \frac{\sum_{i=1}^{n-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,i+k} - \bar{Z}_j)}{[\sum_{i=1}^n (Z_{i,t} - \bar{Z}_i)^2 \sum_{i=1}^n (Z_{j,i+k} - \bar{Z}_j)^2]^{\frac{1}{2}}}$$

Keterangan:

- $\hat{\rho}_{ij}$  = Korelasi silang sampel dari deret waktu lokasi ke-I dan ke-j pada log k
- $Z_{it}$  = Data pengamatan pada lokasi I dan waktu ke-t
- $Z_{j,t}$  = Data pengamatan pada lokasi j dan waktu ke-t
- $Z_i$  = Rata-rata data pengamatan dari lokasi i
- $Z_j$  = Rata-rata data pengamatan dari lokasi j

### *Matrix Partial Autocorrelation Function (MPACF)*

Fungsi matrix parsial korelasi sampel (MPACF) dibutuhkan dalam proses pengidentifikasian model vector AR(p). korelasi antara  $Z_t$  antara  $Z_{t+k}$  dapat diketahui setelah dependensi linier pada variabel  $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k}$  diabaikan. Berdasarkan (Wei, 2006), persamaan *Matrix Partial Autocorrelation Function* (MPACF) dirumuskan sebagai berikut:

$$\phi_{kk} = \frac{\text{cov}[(Z_t - Z_t)(Z_{t+k} - Z_{t+k})]}{\sqrt{\text{var}(Z_t - Z_t)}\sqrt{\text{var}(Z_{t+k} - Z_{t+k})}}$$

Keterangan:

- $\phi_{kk}$  = Koefisien matriks partial korelasi pada lag k
- $Z_t$  = Data pengamatan pada waktu ke t
- $Z_t$  = Rata-rata data pengamatan pada waktu ke t
- $Z_{t+k}$  = Data pengamatan pada waktu ke-(t+k)

### *Akaike's Information Criteria Corrected (AICC)*

Indikator AICC digunakan untuk pemilihan model VARIMA jika dihasilkan lebih dari satu model. Indikator AICC dapat menghasilkan model dengan panjang lag yang lebih tepat dibandingkan dengan indikator yang lain. Model terbaik ditentukan dengan nilai AICC yang terkecil. Untuk mengjitung nilai AICC digunakan rumus sebagai berikut:

$$AIC = N \cdot \ln\left(\frac{Sse}{N}\right) + 2K$$

Keterangan:

- N = Jumlah Observasi
- Sse = Jumlah Kuadrat Kesalahan

K = Jumlah Parameter

## Bobot Lokasi Normalisasi Korelasi Silang

Perhitungan bobot lokasi normalisasi korelasi silang tidak mensyaratkan aturan tertentu, seperti bergantung pada jarak antar lokasi namun bersesuaian dengan jarak lokasi umum namun bersesuaian dengan lag waktu yang terbentuk. Secara umum korelasi silang antar lokasi ke- $i$  dan ke- $j$  pada lag waktu ke- $k$  didefinisikan sebagai berikut:

$$\rho_{ij}(k) = \frac{y_{ij}(k)}{\sigma_i \sigma_j}$$

dengan  $y_{ij}(k)$  merupakan kovarian silang antar amatan pada lokasi ke- $i$  dan lokasi ke- $j$  pada lag waktu ke- $k$ ,  $\sigma_i$  dan  $\sigma_j$  adalah simpangan baku dari amatan pada lokasi ke- $i$  dan lokasi ke- $j$ . Penduga korelasi silang pada data contoh adalah sebagai berikut:

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [z_i(t-k) - \bar{z}_i] [z_j(t) - \bar{z}_j]}{\left[ \sum_{t=1}^n [z_i(t) - \bar{z}_i]^2 \right] \left[ \sum_{t=1}^n [z_j(t-k) - \bar{z}_j]^2 \right]}$$

Perhitungan bobot normalisasi korelasi silang dapat diselesaikan dengan menormalisasikan korelasi silang antar lokasi pada lag yang sesuai. Secara umum, proses ini menghasilkan pembobot lokasi yang sesuai dengan persamaan di atas, dan harus memenuhi  $\sum_{i \neq j} |w_{ij}| = 1$

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

## Pendugaan Parameter Model GSTARIMA

Pendugaan model GSTARIMA dapat dilakukan dengan menggunakan metode *ordinary least square* atau OLS. Metode OLS pada model  $\mathbf{W}$  GSTARIMA digunakan dalam pendugaan parameter *vector autoregressive* dan *vector moving average*. Pendugaan parameter dengan menggunakan metode OLS dapat dilakukan dengan meminimumkan jumlah kuadrat sisaan.

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e}$$

Pendugaan parameter model diperoleh dengan menduga parameter  $\boldsymbol{\beta}$  dengan menghitung jumlah kuadrat sisaan. kemudian meminimumkan dengan cara menurunkan parameter  $\boldsymbol{\beta}$  secara parsial kemudian disamakan dengan nol demikian didapatkan nilai duga  $\boldsymbol{\beta}$  dengan rumus sebagai berikut:

$$\hat{\boldsymbol{\beta}}_{(N_p \times 1)} = (\mathbf{X}'_{(N_p \times NT)} \mathbf{X}_{(NT \times N_p)})^{-1} (\mathbf{X}'_{(N_p \times NT)} \mathbf{Y}_{(NT \times 1)})$$

### Uji White Noise

Pemeriksaan diagnostic model GSTARIMA sama seperti pada model ARIMA, untuk mengetahui model GSTARIMA layak digunakan atau tidak, digunakan uji *portmanteau multivariat* yaitu generalisasi dari uji L-jung Box Q untuk multivariate, dengan hipotesis sebagai berikut.

$H_0$  :  $\rho_1 = \dots = \rho_m = 0$  (sisaan bersifat white noise) vs

$H_1$  : minimal ada satu  $\rho_k \neq 0, k = 1, 2, \dots, k$  (sisaan tidak bersifat white noise)

Di mana  $\rho$  adalah matrix korelasi dari vector error. Statistic yang digunakan adalah:

$$Q_N(m) = T^2 \sum_{t=1}^m \frac{1}{T-t} \text{tr}(\hat{\Gamma}'_t \hat{\Gamma}_0^{-1} \hat{\Gamma}_t \hat{\Gamma}_0^{-1})$$

Keterangan:

$T$  = Jumlah pengamatan

$m$  = Banyaknya parameter yang diduga

$N$  = Banyaknya variabel (lokasi)

$\hat{\Gamma}'_t$  = Matrik kovariansi silang pada lag waktu ke-  $t$

Kriteria keputusan terima  $H_0$  apabila nilai statistic uji  $Q < X^2_{N^2 m}$  pada taraf nyata  $\alpha$  atau  $p$ -value dari statistic uji  $Q$  lebih besar dari nilai  $\alpha$ , sehingga dapat disimpulkan bahwa sisaan bersifat white noise.

### Peramalan Model GSTARIMA

Peramalan dilakukan setelah model terbaik didapatkan, model tersebut diharapkan mampu menghasilkan peramalan yang sesuai. Peramalan adalah aktivitas menghitung atau memprediksi beberapa kejadian atau kondisi yang akan datang. Peramalan pada model GSTARIMA dilakukan secara bertahap per periode peramalan satu periode mendatang (Nurchayani, 2016).

Untuk mengetahui tingkat akurasi hasil peramalan digunakan indicator mean absolute percentage error (MAPE). MAPE merupakan persentase kesalahan hasil peramalan terhadap data aktual selama periode tertentu. Rumus MAPE dapat dituliskan sebagai berikut:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{\hat{y}_t} \times 100\%$$

Keterangan:

$y_t$  = Data actual pada waktu ke- $t$

$\hat{y}_t$  = Nilai hasil prediksi waktu ke- $t$



## HASIL PENELITIAN DAN PEMBAHASAN

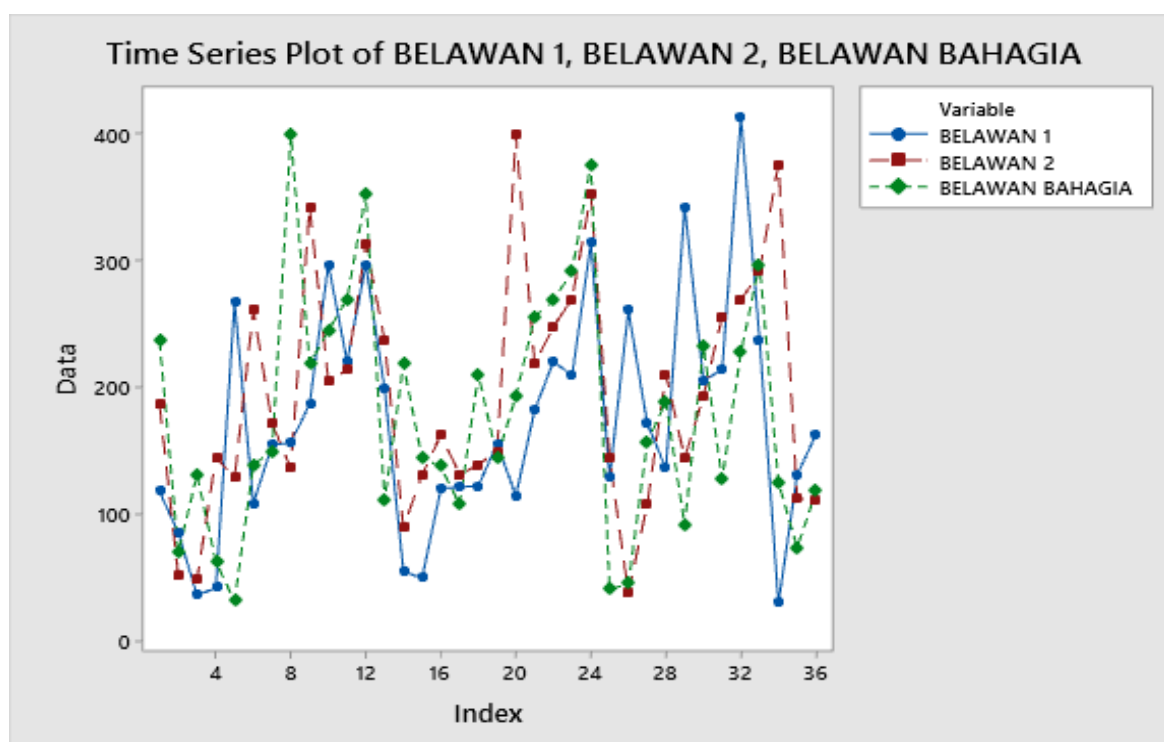
Statistika deskriptif merupakan metode statistika yang digunakan untuk merinci dan menggambarkan data yang telah dikumpulkan, sehingga dapat diubah menjadi informasi yang lebih bermakna. Dalam konteks ini, ditampilkan hasil analisis deskriptif data curah hujan dari tahun 2019 hingga 2021.

**Tabel 1.** Statistika Deskriptif Data Curah Hujan Tahun 2019-2021

Lokasi	Rata-Rata Curah Hujan	Simpangan Baku Curah Hujan	Minimum Curah Hujan	Maksimum Curah Hujan
Belawan 1	183,34	88,63	29,8	413,6
Belawan 2	194,03	91,17	37,8	399,4
Belawan Bahagia	180,22	93,55	31,4	399,4

Tabel 1 menunjukkan bahwa rata-rata curah hujan, nilai minimum, dan nilai maksimum tertinggi pada 3 tahun terakhir terjadi Belawan II yaitu 194,03 mm, 37,8 mm, dan 399,4 mm. Sedangkan untuk nilai simpangan baku tertinggi terjadi di Belawan Bahagia senilai 93,55 mm.

*Time series plot* digunakan untuk mengetahui lebih jelas kenaikan dan penurunan pada data dan dapat digunakan untuk memeriksa kestasioneran data.



**Gambar 1** Time Series Plot curah hujan di Belawan

Gambar 1 di atas menunjukkan bahwa curah hujan pada ketiga lokasi cenderung memiliki pola yang sama. Curah hujan di atas juga menunjukkan bahwa curah hujan memiliki pola musiman.

Pada stasioneritas ragam dilakukan dengan menduga parameter transformasi lambda ( $\lambda$ ) yang dihasilkan dari plot Box-Cox. Jika nilai  $\lambda$  mendekati 1 menunjukkan bahwa data telah stasioner terhadap ragam dan sebaliknya. Hal ini berarti membutuhkan data yang bernilai positif. Berikut hasil pengujian kestasioneran terhadap ragam untuk masing-masing lokasi.

**Tabel 2** Uji Stasioneritas Rata-Rata Curah Hujan Terhadap Ragam

Lokasi	$\lambda$	Transformasi I	
		Bentuk Transformasi	$\lambda$
Belawan I	2,0	$(y_t)^2$	1
Belawan II	0,5	$\sqrt{y_t}$	1
Belawan Bahagia	0,5	$\sqrt{y_t}$	1

Tabel 2 menunjukkan bahwa nilai awal  $\lambda$  yang tidak sama dengan 1 dilakukan transformasi Box-Cox sehingga ketiga lokasi menunjukkan keadaan yang stasioner terhadap ragam setelah mengalami satu kali transformasi.


Pengujian stasioneritas terhadap rata-rata dilakukan dengan menguji *Augmented Dickey Fuller* (ADF). Data dikatakan stasioner jika p-value <  $\alpha$ . Berikut hasil pengujian ADF.

**Tabel 3** Hasil Unit *Root Test* pada *first difference*


Variabel	First difference	
	Statistik ( $\tau$ ) uji ADF	Nilai Critic 5%
$X_1$	2.694	- 3,85
$X_2$	-0,011	-3,85
$X_3$	-0,247	-3,85

Berdasarkan Tabel 3 hasil pemeriksaan stasioneritas di kondisi first difference. Jika statistik  $\tau$  lebih besar dari nilai kritis ADF maka terima  $H_1$  yang berarti tidak terdapat akar unit. Akar unit mengindikasikan bahwa data tersebut tidak stasioner dalam arti rata-ratanya tidak konstan sepanjang waktu.


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



Gambar 2 Plot ACF di Belawan 1



Gambar 3 Plot ACF di Belawan 2



Gambar 4 Plot ACF di Belawan Bahagia

Berdasarkan gambar-gambar yang disajikan di atas, menunjukkan bahwa pada plot ACF dan PACF mempunyai kesamaan pola, yaitu menunjukkan pola dies down pada ACF dan pola PACF *cut off after lag 2*, sehingga model yang mungkin adalah AR (1) Dan AR (2).

Selanjutnya mencari nilai AIC terkecil masing-masing lokasi berdasarkan model Akaike's Information Criteria Corrected (AICC).

Tabel 4 Nilai AIC Masing-masing Lokasi

Lokasi	Model	AIC
Belawan 1	ARIMA (1,0,0)	376,32
	ARIMA(2,0,0)	372,07
Belawan 2	ARIMA (1,0,0)	379,05

Lokasi	Model	AIC
Belawan Bahagia	ARIMA(2,0,0)	364,782
	ARIMA (1,0,0)	377,73
	ARIMA(2,0,0)	364,25

Berdasarkan tabel 4 ,terlihat bahwa Belawan Bahagia yang memiliki nilai AIC terkecil yaitu 364,25. Hal ini menjadikan ARIMA ( 2,0,0) sebagai orde maksimum baik dari sisi autoregressive differencing, maupun moving average. Model ARIMA (2,0,0) untuk Belawan Bahagia inilah yang selanjutnya akan diterapkan pada model GSTARIMA. Berdasarkan hal tersebut, dipilih model GSTARIMA (2,0,0) yang digunakan pada data curah hujan di belawan 1,dan belawan 2.

Pembentukan Matriks Pembobot Invers Jarak melibatkan perhitungan bobot kebalikan jarak berdasarkan jarak fisik antara lokasi-lokasi yang diamati. Dalam proses ini, lokasi yang berdekatan akan mendapatkan bobot yang lebih besar, sesuai dengan jarak yang lebih dekat di antara mereka.

**Tabel 5** Jarak Wilayah Belawan1, Belawan 2 dan Belawan Bahagia

Lokasi	Jarak (km)
Belawan 1- Belawan 2	1,089 km
Belawan 1- Belawan Bahagia	11,03 km
Belawan 2- Belawan Bahagia	10,15 km

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

$$W = \frac{1}{d_{ij}}$$

$$W = \begin{bmatrix} 0 & \frac{1}{1,089} & \frac{1}{11,03} \\ \frac{1}{1,089} & 0 & \frac{1}{10,15} \\ \frac{1}{11,03} & \frac{1}{10,15} & 0 \end{bmatrix}$$

$$W = \begin{bmatrix} 0 & 0,91 & 0,09 \\ 0,91 & 0 & 0,09 \\ 0,09 & 0,09 & 0 \end{bmatrix}$$

## Matrik Pembobot Korelasi Silang

Pemodelan dengan menggunakan bobot normalisasi korelasi silang mempunyai asumsi bahwa keterikatan inflasi antara lokasi.

Matrix Korelasi Silang

$$W = \begin{bmatrix} 0 & 0,10 & 0,16 \\ 0,12 & 0 & 0,22 \\ 0,14 & 0,21 & 0 \end{bmatrix}$$

## Estimasi Parameter Model

Estimasi parameter model GSTARIMA dilakukan pada bobot lokasi dengan menggunakan kuadrat terkecil dengan cara meminimumkan jumlah kuadrat simpanganya. Pada tahap identifikasi terbentuk model GSTARIMA(2,0,0) dengan bobot lokasi yang digunakan yaitu pembobot kebalikan jarak dan pembobot normalisasi korelasi silang.

Nilai semua parameter model GSTARIMA(2,0,0) dengan pembobot kebalikan jarak dan pembobot normalisasi korelasi silang yang diestimasi menghasilkan 36 parameter yang disajikan pada Tabel 6.

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

Pembobot		
Statistik	Kebalikan Jarak	Normalisasi Korelasi Silang
$\hat{\phi}_{10}^1$	0	0
$\hat{\phi}_{10}^2$	0	0
$\hat{\phi}_{10}^3$	0	0
$\hat{\phi}_{20}^1$	517.737	79.4977
$\hat{\phi}_{20}^2$	247.6211	19.1613
$\hat{\phi}_{20}^3$	-59.9655	25.3419
$\hat{\phi}_{30}^1$	-324.48	-34.0097
$\hat{\phi}_{30}^2$	-105.1273	29.2902
$\hat{\phi}_{30}^3$	495.3684	8.1811
$\hat{\phi}_{11}^1$	-142.6844	-60.4507
$\hat{\phi}_{11}^2$	-437.3488	-5.005
$\hat{\phi}_{11}^3$	435.8744	57.3767
$\hat{\phi}_{21}^1$	-266.8694	-90.18
$\hat{\phi}_{21}^2$	-709.3886	-80.8953
$\hat{\phi}_{21}^3$	378.0434	82.9483
$\hat{\phi}_{31}^1$	546.1851	43.0958
$\hat{\phi}_{31}^2$	-119.3694	-2.2939
$\hat{\phi}_{31}^3$	-90.9916	11.5663
$\hat{\phi}_{12}^1$	106.0371	4.8293

Pembobot		
Statistik	Kebalikan Jarak	Normalisasi Korelasi Silang
$\hat{\varphi}_{12}^2$	403.7338	28.4423
$\hat{\varphi}_{12}^3$	-294.2667	-0.3183
$\hat{\varphi}_{22}^1$	-346.8897	-40.9567
$\hat{\varphi}_{22}^2$	293.2977	18.1944
$\hat{\varphi}_{22}^3$	196.0818	40.55
$\hat{\varphi}_{32}^1$	529.9029	-16.4934
$\hat{\varphi}_{32}^2$	-356.5702	-54.715
$\hat{\varphi}_{32}^3$	772.9165	188.816
$\hat{\varphi}_{13}^1$	226.5311	21.98
$\hat{\varphi}_{13}^2$	2.0896	-32.3388
$\hat{\varphi}_{13}^3$	-184.4532	-0.1548
$\hat{\varphi}_{23}^1$	28.3088	-8.6085
$\hat{\varphi}_{23}^2$	289.2869	38.6026
$\hat{\varphi}_{23}^3$	-228.5448	5.9125
$\hat{\varphi}_{33}^1$	-388.7149	-124.0822
$\hat{\varphi}_{33}^2$	-282.6255	-43.3533
$\hat{\varphi}_{33}^3$	160.4522	78.4782

## Uji Asumsi White Noise

Hasil pengujian asumsi white noise meliputi uji kenormalan residual dan uji independensi residual. Asumsi white noise diperlukan untuk menguji validasi dari model. Uji asumsi white noise untuk pembobot kebalikan jarak dan pembobot normalisasi korelasi silang untuk masing-masing lokasi disajikan pada Tabel 7.

**Tabel 7** Hasil pengujian Asumsi White Noise Model GSTARIMA(2,0,0)1

White Noise			
Pembobot	Variabel	Kenormalan Residual	Independensi Residual
Kebalikan Jarak	X <sub>1</sub>	0,989	0,514
	X <sub>2</sub>	0,989	0,514
	X <sub>3</sub>	0,989	0,514
Normalisasi Korelasi Silang	X <sub>1</sub>	0,547	0,861
	X <sub>2</sub>	0,547	0,861
	X <sub>3</sub>	0,547	0,861

Berdasarkan Tabel 7 diperoleh bahwa model GSTARIMA (2,0,0) untuk pembobot kebalikan jarak dan normalisasi korelasi silang memenuhi asumsi white noise. Dari hasil pengujian White Noise dilihat bahwa kedua bobot lokasi diatas lebih dari 0,05 maka dapat disimpulkan bahwa model tersebut memenuhi asumsi White Noise . Maka langkah selanjutnya untuk menentukan model terbaik yang dipilih dengan melihat nilai MAPE dari dua bobot lokasi model tersebut.

### Pemilihan Model GSTARIMA Terbaik

Model terbaik yang terpilih adalah model dengan nilai MAPE terkecil dari hasil ramalan. Ramalan yang dihasilkan berasal dari model GSTARIMA (2,0,0) dengan semua parameter yang diduga dimasukkan kedalam model untuk masing-masing pembobot. Tabel 8 menunjukkan hasil perbandingan nilai MAPE untuk setiap pembobot yang digunakan.

**Tabel 8** Hasil Perbandingan Nilai MAPE Untuk Masing-masing Pembobot

Lokasi	MAPE Kebalikan Jarak(%)	MAPE Korelasi Silang(%)
Belawan 1	2,7523	1,1046
Belawan 2	2,0399	1,0227
Belawan Bahagia	2,5214	1,0170
Rata-rata	2,4379	1,0481

Hasil menunjukkan bahwa rata-rata nilai MAPE terkecil adalah model GSTARI dengan menggunakan pembobot kebalikan jarak dan korelasi silang.oleh karena itu, dapat disimpulkan bahwa model terbaik yang terpilih adalah model GSTARI dengan pembobot kebalikan jarak plot data ramalan pada masing-masing model mendekati data aktualnya. Hal tersebut menandakan bahwa model yang terpilih sudah cukup baik.

### KESIMPULAN DAN SARAN

Berdasarkan analisis dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa model GSTARIMA(2,0,0) dengan pembobot kebalikan jarak dan korelasi silang merupakan model terbaik untuk meramalkan curah hujan di wilayah Belawan 1, Belawan 2, dan Belawan Bahagia. Hasil peramalan untuk ketiga wilayah tersebut berhasil mencerminkan pola aktual curah hujan pada periode waktu yang sama. Hasil peramalan juga menunjukkan bahwa nilai curah hujan aktual berkisar antara 1,0170% hingga 2,7523% untuk Belawan Bahagia hingga Belawan 1.

Untuk penelitian selanjutnya, disarankan untuk mengkaji bencana banjir dalam skala harian dengan menggunakan model lain serta pendekatan parameter yang berbeda. Hal ini dapat memberikan wawasan tambahan yang berguna untuk pemahaman

lebih mendalam tentang fenomena cuaca di wilayah ini dan meningkatkan akurasi peramalan bencana banjir.

### DAFTAR PUSTAKA

---

- Cryer, J. D., & Chan, K. S. (2008). Time series regression models. *Time series analysis: with applications in R*, 249-276. [https://doi.org/10.1007/978-0-387-75959-3\\_11](https://doi.org/10.1007/978-0-387-75959-3_11)
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1999). *Metode dan aplikasi peramalan*. Jakarta: Erlangga.
- Nurchayani, F. (2016). Pengelompokan Stasiun Hujan untuk Model Generalized Space Time Autoregressive (GSTAR) pada Peramalan Curah Hujan Kabupaten Jember dengan Tiga Pembobotan. *Skripsi*. Universitas Jember
- Rachmadania, S. (2018). Pemodelan Generalized Space Time Autoregressive Integrated Moving Average (GSTARIMA) dengan differencing musiman pada Data Kelembaban Udara (Studi Kasus Pada Lima Stasiun BMKG di Jawa Timur) (*Doctoral dissertation, Universitas Brawijaya*).
- Soehatman, R. (2010). *Manajemen Bencana*. Jakarta: Dian Rakyat.
- Stephanie, S., Jimawan, O. N., & Jayadi, D. (2018). Analisis Statistika Pengaruh Curah Hujan Terhadap Banjir Di Jakarta Melalui Pemodelan Matematika. *Jurnal Meteorologi Klimatologi dan Geofisika*, 5(2), 22-28. Retrieved from <https://jurnal.stmkg.ac.id/index.php/jmkg/article/view/55>
- William, W., & Wei, S. (2006). Time series analysis: univariate and multivariate methods. USA, *Pearson Addison Wesley, Segunda edicion*. Cap, 10, 212-235.