

PERAMALAN PASANG SURUT AIR LAUT DI PULAU JAWA MENGGUNAKAN MODEL *GENERALIZED SPACE TIME AUTOREGRESSIVE* (GSTAR)

(Studi Kasus : Ketinggian Pasang Surut Air Laut di Stasiun
Pasang Surut Jakarta, Cirebon, Semarang dan Surabaya)

Chyntia Arum Widyastuti¹, Abdul Hoyyi², Rita Rahmawati³

¹Mahasiswa Departemen Statistika FSM Universitas Diponegoro

^{2,3}Staff Pengajar Departemen Statistika FSM Universitas Diponegoro

ABSTRACT

In daily life is often found time series data contains not only connection among the events in previous times, but also has a relationship between one location to another. Data with time series and location linkage is called space-time data. Generalized Space Time Autoregressive (GSTAR) model is one of the commonest used to make model and forecast space-time data. The purposes of this research are to get the best GSTAR model and the forecasting results for the data ocean tide heights at four stations of Java island, those are Stations of Jakarta, Cirebon, Semarang and Surabaya. The best model obtained is GSTAR(1;1)-I(1) which is using cross correlation normalization weight because its residuals fulfill white noise assumption with the smallest value of MAPE and RMSE. The best GSTAR model explains that the elevation ocean tide data in Stations of Cirebon and Semarang is only influenced by the earlier times, and not influenced by other locations but can affect the height of the tide at other locations. As for the elevation ocean tide data stations of Jakarta and Surabaya are influence each other.

Keywords: GSTAR, *Space-Time*, *Ocean Tide*, MAPE and RMSE.

1 PENDAHULUAN

Pasang surut air laut merupakan fenomena naik turunnya permukaan air laut laut yang disebabkan oleh gaya tarik menarik antara bumi, bulan dan matahari. Salah satu dampak fenomena pemanasan global yang terjadi adalah naiknya permukaan air laut. Kenaikan permukaan air laut yang terus bertambah akan mengakibatkan masuknya air laut ke daratan atau banjir rob. Menurut Badan Nasional Penanggulangan Bencana dalam Ibnudin (2016), banjir rob menggenangi daerah-daerah yang permukaannya berada lebih rendah dari permukaan air laut. Daerah yang sering terjadi banjir rob antara lain Jakarta, Cirebon, Semarang dan Surabaya yang berada di kawasan pantai utara Jawa.

Time series merupakan suatu deretan observasi yang diambil secara berurutan berdasarkan waktu dengan interval yang sama (Box *et al.*, 1994). salah satu model yang menggabungkan unsur waktu dan lokasi adalah model *space time* (Wutsqa *et al.*, 2010). Model *Space Time Autoregressive* (STAR) merupakan awal dari model *space time* yang diperkenalkan oleh Pfeifer dan Deutsch (1980a, 1980b). Model *Space Time Autoregressive* (STAR) mempunyai kelemahan pada fleksibilitas parameter yang menjelaskan dependensi lokasi dan waktu yang berbeda pada suatu data deret waktu dan lokasi (Prisandy dan Suhartono, 2008). Kelemahan ini diperbaiki oleh Borovkova, Lopuhaa dan Ruchjana (2002) melalui suatu model yang dikenal sebagai *Generalized Space Time Autoregressive* (GSTAR). Berdasarkan uraian penulis tertarik untuk melakukan penelitian menggunakan model *Generalized Space Time Autoregressive* (GSTAR) untuk peramalan data ketinggian

pasang surut air laut di empat stasiun Pulau Jawa yaitu Stasiun Jakarta, Cirebon, Semarang dan Surabaya.

2 TINJAUAN PUSTAKA

2.1 Time Series Multivariat

Time series multivariat adalah serangkaian data yang terdiri dari beberapa variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan dengan interval waktu yang tetap (Wei, 2006). Identifikasi pada model *time series* multivariat hampir sama dengan *time series* univariat. Pengidentifikasian stasioneritas pada model *time series* multivariat dapat dilakukan dengan melihat dari plot *Matrix Autocorrelation Function* (MACF)

2.2 Matrix Autocorrelation Function (MACF)

Jika terdapat sebuah vektor *time series* dengan pengamatan sebanyak T , yaitu Z_1, Z_2, \dots, Z_T , maka persamaan matriks korelasi sampelnya sebagai berikut (Wei, 2006):

$$\hat{\boldsymbol{\rho}}(k) = [\hat{\rho}_{ij}(k)] \quad (1)$$

dengan $\hat{\rho}_{ij}(k)$ merupakan korelasi silang sampel untuk komponen deret ke- i dan ke- j yang dinyatakan dalam persamaan berikut:

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

\bar{Z}_i dan \bar{Z}_j merupakan rata-rata sampel dari komponen deret yang bersesuaian.

Untuk meringkas penjelasan korelasi sampel menggunakan simbol (+), (-), and (.) pada posisi (i, j) dari matriks korelasi sampel, dimana simbol (+) menotasikan nilai yang lebih besar dari 2 kali estimasi standar *error* menunjukkan adanya hubungan korelasi positif, (-) menotasikan nilai yang kurang dari -2 kali estimasi standar *error* atau adanya hubungan korelasi negatif, sedangkan (.) menotasikan nilai yang berada di antara ± 2 kali estimasi standar *error* yang artinya tidak terdapat hubungan korelasi.

Standar error nilai $\hat{\rho}_{ij}(k)$ dapat dihitung dengan persamaan sebagai berikut:

$$\text{Std.error}[\hat{\rho}_{ij}(k)] \cong \sqrt{\frac{1}{T-k}} \quad (3)$$

2.2 Matrix Partial Autocorrelation Function (MPACF)

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

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

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

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

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

Identifikasi data berdasarkan nilai MPACF juga dinotasikan dalam bentuk (+) dan (-) dan (.) seperti pada *Matrix Autocorrelation Function* (MACF).

2.3 Model *Generalized Space Time Autoregressive (GSTAR)*

Model GSTAR merupakan generalisasi dari model *Space Time Autoregressive (STAR)*. Perbedaan antara model GSTAR dan model STAR terletak pada asumsi parameternya. Model STAR mengasumsikan bahwa nilai-nilai parameter *autoregressive* untuk lokasi-lokasi yang digunakan adalah sama. Sedangkan pada model GSTAR terdapat asumsi yang menyatakan nilai-nilai parameter *autoregressive* bersifat heterogen untuk setiap lokasi, sehingga perbedaan antar lokasi ini ditunjukkan dalam bentuk matriks pembobot (Wutsqa *et al.*, 2010).

Jika diketahui sebuah deret $\mathbf{Z}_t = [Z_{1,t}, Z_{2,t}, \dots, Z_{n,t}]'$ merupakan suatu vektor deret waktu berdimensi n , maka model GSTAR dari orde *autoregressive* p dengan orde spasial $\lambda_1, \lambda_2, \dots, \lambda_p$, yaitu $\text{GSTAR}(p; \lambda_1, \lambda_2, \dots, \lambda_p)$. Untuk data yang tidak stasioner dalam mean maka dilakukan differensi, sehingga model GSTAR yang terbentuk adalah $\text{GSTAR}(p; \lambda_1, \lambda_2, \dots, \lambda_p) - I(d)$. Sehingga dalam notasi matriks dapat dituliskan sebagai berikut (Wutsqa *et al.*, 2010):

$$\mathbf{Z}(t) = \sum_{k=1}^p \left(\Phi_{k0} + \sum_{l=1}^{\lambda_p} \Phi_{kl} \mathbf{W}^{(l)} \right) \mathbf{Z}(t-k) + \mathbf{e}(t) \quad (5)$$

dimana $\Phi_{k0} = \text{diag}(\phi_{k0}^1, \dots, \phi_{k0}^n)$ dan $\Phi_{kl} = \text{diag}(\phi_{kl}^1, \dots, \phi_{kl}^n)$, sedangkan $\mathbf{e}(t)$ adalah vektor galat berukuran $(n \times 1)$, $\mathbf{Z}(t)$ merupakan vektor acak berukuran $(n \times 1)$ pada waktu t , $\mathbf{W}^{(l)}$ adalah matriks bobot berukuran $(n \times n)$ dengan nilai pembobot yang dipilih memenuhi syarat $w_{ii}^{(l)} = 0$ dan $\sum_{j=1}^n w_{ij}^{(l)} = 1$. Pemilihan bobot lokasi pada model GSTAR sebagai berikut:

a. Bobot Seragam (*Uniform*)

Bobot seragam mengasumsikan bahwa lokasi-lokasi yang digunakan bersifat homogen dengan memberikan nilai bobot yang sama untuk setiap lokasi. Penentuan nilai bobot dalam bobot lokasi seragam adalah sebagai berikut (Suhartono dan Atok, 2006):

$$w_{ij} = \begin{cases} \frac{1}{n_i}, & i \neq j \\ 0, & \text{lainnya} \end{cases} \quad (6)$$

dengan n_i adalah jumlah lokasi yang berdekatan dengan lokasi ke- i .

b. Bobot Biner (*Binary*)

Menurut Suhartono dan Atok (2006), metode dengan pembobot biner hanya bergantung pada keadaan yang terbatas. Pembobotan dengan metode biner memiliki pembobot dengan $w_{ij} = 0$ atau 1. Jarak lokasi terdekat akan bernilai 1, sedangkan jarak lokasi yang lebih jauh bernilai 0.

c. Bobot *Invers Jarak*

Pembobotan dengan metode *invers jarak* dilakukan berdasarkan jarak sebenarnya antar lokasi. Lokasi yang berdekatan mendapat nilai bobot yang lebih besar. Perhitungan bobot dengan metode *invers jarak* diperoleh dari hasil *invers jarak* yang sebenarnya kemudian dinormalisasi (Faizah dan Setiawan, 2013).

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

dengan d_{ij} adalah jarak lokasi ke- i dengan lokasi ke- j .

d. Bobot Normalisasi Korelasi Silang

Pembobotan dengan metode normalisasi korelasi silang adalah menggunakan normalisasi hasil korelasi silang antar lokasi pada lag yang bersesuaian. Penggunaan bobot ini pertama kali diperkenalkan oleh Suhartono dan Atok (2006). Secara umum korelasi silang antara lokasi ke-*i* dan ke-*j* pada lag waktu ke-*k*, $corr[Z_i(t), Z_j(t-k)]$, didefinisikan sebagai berikut:

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j}, k = 1, 2, 3, \dots \tag{8}$$

dimana $\gamma_{ij}(k)$ merupakan kovarians silang antara kejadian di lokasi ke-*i* dan ke-*j*.

Taksiran dari korelasi silang pada sampel dapat dihitung dengan persamaan berikut:

$$r_{ij}(k) = \frac{\sum_{t=k+1}^T [Z_i(t) - \bar{Z}_i][Z_j(t-k) - \bar{Z}_j]}{\sqrt{\left(\sum_{t=1}^T [Z_i(t) - \bar{Z}_i]^2\right)\left(\sum_{t=1}^T [Z_j(t) - \bar{Z}_j]^2\right)}} \tag{9}$$

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

$$w_{ij} = \frac{r_{ij}(k)}{\sum_{j \neq i} |r_{ij}(k)|}, \text{ dengan } i \neq j \text{ dan } \sum_{j \neq i} |w_{ij}| = 1 \tag{10}$$

2.4 Estimasi Parameter dengan Ordinary Least Square (OLS)

Metode *Ordinary Least Square* (OLS) merupakan metode estimasi dengan meminimalkan jumlah kuadrat errornya. Model persamaan GSTAR(1;1) dapat ditulis dalam bentuk linier sebagai berikut:

$$Y_i = X_i \beta_i + e_i$$

dimana, $Y_i = \begin{bmatrix} Z_i(2) \\ Z_i(3) \\ \vdots \\ Z_i(T) \end{bmatrix}$, $X_i = \begin{bmatrix} Z_i(1) & V_i(1) \\ Z_i(2) & V_i(2) \\ \vdots & \vdots \\ Z_i(T-1) & V_i(T-1) \end{bmatrix}$, $\beta_i = \begin{bmatrix} \phi_{i0}^1 \\ \phi_{i1}^1 \end{bmatrix}$, $e_i = \begin{bmatrix} e_i(2) \\ e_i(3) \\ \vdots \\ e_i(T) \end{bmatrix}$ (11)

dengan $Z_i(t)$ merupakan banyaknya pengamatan dimana $t=1,2,\dots,T$ untuk lokasi $i=1,2,\dots,n$ dan $V_i(t) = \sum_{j \neq i} w_{ij} Z_j(t)$ untuk $i \neq j$.

Sehingga nilai taksiran untuk parameter dapat dihitung menggunakan metode *least square* dengan rumus sebagai berikut:

$$\hat{\beta} = (X'X)^{-1} X'Y \tag{12}$$

2.5 Kriteria Pemilihan Model Terbaik

Pemilihan model terbaik dapat dilakukan berdasarkan kriteria *in sample* dan *out sample*. Kriteria *in sample* yang digunakan dalam penelitian ini yaitu *Akaike Information Criterion* (AIC). Sedangkan kriteria *out sample* yaitu menggunakan *Mean Absolute Percentage Error* (MAPE) dan nilai *Root Mean Square Error* (RMSE).

1. Akaike Information Criterion (AIC)

Akaike's Information Criterion (AIC) adalah suatu kriteria dalam pemilihan model terbaik yang diperkenalkan oleh Akaike (1973). Suatu model dikatakan baik apabila nilai AIC-nya paling kecil.

Perhitungan nilai AIC sebagai berikut (Wutsqa *et al.*, 2010):

$$AIC(p) = \ln|\hat{\Sigma}_p| + \frac{2}{T}pK^2 \quad (13)$$

dimana K adalah banyaknya variabel, T adalah banyak pengamatan, dan $\hat{\Sigma}_p$ merupakan matriks dugaan varian-kovarian residual. Orde *autoregressive* p dari model GSTAR ditentukan oleh nilai $AIC(p)$ terkecil dari semua kemungkinan orde model.

2. Mean Absolute Percentage Error (MAPE)

MAPE digunakan untuk mengukur kesalahan nilai dugaan model yang dinyatakan dalam bentuk rata-rata persentase absolut residual. Semakin kecil nilai MAPE menunjukkan bahwa presentase kesalahan yang dihasilkan oleh model juga semakin kecil. Perhitungan MAPE dapat ditulis sebagai berikut:

$$MAPE = \frac{\sum_{t=1}^m \left| \left(\frac{Z_t - \hat{Z}_t}{Z_t} \right) \times 100\% \right|}{m} \quad (14)$$

dengan m = banyaknya ramalan yang dilakukan

Z_t = data sebenarnya

\hat{Z}_t = data hasil ramalan.

3. Root Mean Square Error (RMSE)

Salah satu metode yang digunakan untuk mengetahui error dari sebuah peramalan adalah Root Mean Square Error (RMSE). Model peramalan terbaik dipilih jika memiliki nilai RMSE terkecil. Berikut adalah persamaan dari RMSE (Wei, 2006):

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{M} \sum_{t=1}^m (Z_t - \hat{Z}_t)^2} \quad (15)$$

dengan m = banyaknya ramalan yang dilakukan

Z_t = data sebenarnya

\hat{Z}_t = data hasil ramalan.

2.6 Pasang Surut Air Laut

Pasang surut air laut adalah fenomena naik dan turunnya permukaan air laut secara periodik yang disebabkan oleh pengaruh gravitasi benda-benda langit terutama bulan dan matahari (Rahardjo dan Sanusi, 1983). Besar naik turunnya permukaan air laut tergantung pada kedudukan bumi terhadap bulan dan matahari. Pada saat bumi berada segaris dengan bulan dan matahari akan menyebabkan besar gaya tarik bulan dan matahari terhadap bumi akan maksimum yang mengakibatkan permukaan laut akan menjadi pasang. Sebaliknya saat kedudukan bumi, matahari dan bulan persis membentuk sudut siku-siku sehingga besar gaya tarik bulan dan matahari terhadap bumi akan saling melemahkan dan permukaan laut akan turun mencapai titik terendah Widyantoro (2014).

3 METODOLOGI PENELITIAN

3.1 Data

Data yang digunakan dalam penelitian ini adalah data sekunder yaitu data ketinggian pasang surut air laut di stasiun Jakarta, Cirebon, Semarang dan Surabaya dari tanggal 13 Maret sampai 22 Juli 2015 yang diperoleh dari Badan Informasi Geospasial (BIG).

3.2 Variabel Penelitian

Variabel pada penelitian ini ada empat, yaitu:

1. Z_1 = Ketinggian Pasang surut air laut di Stasiun Jakarta dalam cm
2. Z_2 = Ketinggian Pasang surut air laut di Stasiun Cirebon dalam cm
3. Z_3 = Ketinggian Pasang surut air laut di Stasiun Semarang dalam cm
4. Z_4 = Ketinggian Pasang surut air laut di Stasiun Surabaya dalam cm

3.3 Langkah Analisis Data

Tahapan analisis sebagai berikut:

1. Menentukan data deret waktu dan lokasi yang akan digunakan dalam penelitian.
2. Mengidentifikasi orde model GSTAR menggunakan MACF, MPACF dan nilai AIC minimum.
3. Mengecek kestasioneritas data menggunakan MACF.
4. Menentukan bobot lokasi yang digunakan pada model GSTAR.
5. Melakukan estimasi parameter model GSTAR untuk masing-masing bobot lokasi.
6. Melakukan pengecekan asumsi *white noise*.
7. Menghitung nilai RMSE untuk masing-masing bobot lokasi.
8. Menentukan model GSTAR terbaik berdasarkan nilai RMSE terkecil.
9. Melakukan peramalan data deret waktu dan lokasi dari model terbaik untuk beberapa periode ke depan.

4 HASIL DAN PEMBAHASAN

4.1 Statistika Deskriptif

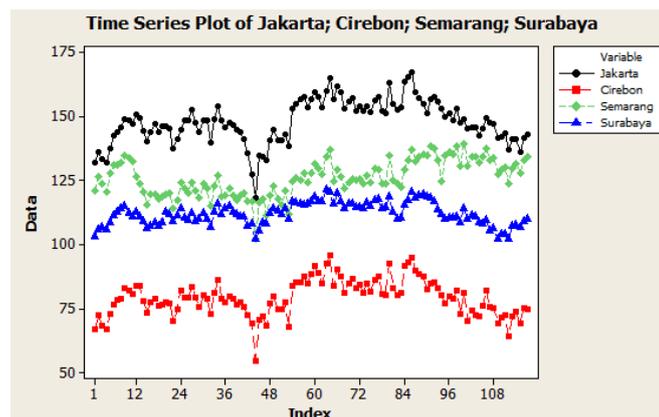
Hasil analisis statistika deskriptif data ketinggian pasang surut air laut di empat stasiun ditampilkan dalam Tabel 1.

Tabel 1. Statistika Deskriptif Data Ketinggian Pasang Surut Air Laut (dalam cm)

Lokasi	n	Mean	Min	Max	Ragam
Stasiun Jakarta	117	147,910	118,250	167,080	70,400
Stasiun Cirebon	117	79,334	54,708	95,792	49,243
Stasiun Semarang	117	125,930	102,210	139,330	48,840
Stasiun Surabaya	117	112,030	102,080	121,290	18,950

Berdasarkan Tabel 1 dapat dilihat bahwa panjang data yang digunakan untuk setiap lokasi sebanyak 117 data. Stasiun Jakarta mempunyai rata-rata tertinggi sebesar 147,910 cm dan merupakan lokasi yang mempunyai keragaman tertinggi yaitu sebesar 70,400 cm².

Pola data ketinggian pasang surut air laut ditunjukkan pada *time series plot* berikut ini:



Gambar 1. Plot *Time Series* Data Ketinggian Pasang Surut Air Laut Secara Bersama-Sama

Terlihat pada Gambar 1 secara umum pola data ketinggian pasang surut air laut di empat stasiun relatif sama. Hal itu diduga ada efek saling berkaitan antar keempat lokasi tersebut. Efek saling keterkaitan data ketinggian pasang surut air laut juga dapat dilihat dari nilai korelasi antar lokasi pada Tabel 2.

Tabel 2. Nilai Korelasi Data Ketinggian Pasang Surut Air Laut di Empat Stasiun

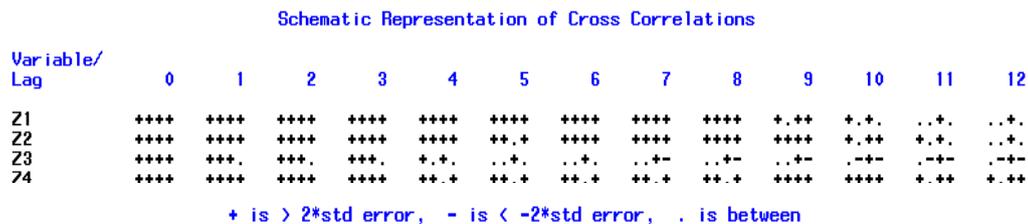
Lokasi	Z ₁	Z ₂	Z ₃	Z ₄
Z ₁	1			
<i>p-value</i>	0,000*			
Z ₂	0,946	1		
<i>p-value</i>	0,000*	0,000*		
Z ₃	0,561	0,501	1	
<i>p-value</i>	0,000*	0,000*	0,000*	
Z ₄	0,820	0,884	0,390	1
<i>p-value</i>	0,000*	0,000*	0,000*	0,000*

* Signifikan pada $\alpha = 5\%$

Berdasarkan Tabel 2 terdapat hubungan linier positif dan signifikan pada α sebesar 5% antara ketinggian pasang surut air laut di Stasiun Jakarta (Z₁), Stasiun Cirebon (Z₂), Stasiun Semarang (Z₃) dan Stasiun Surabaya (Z₄).

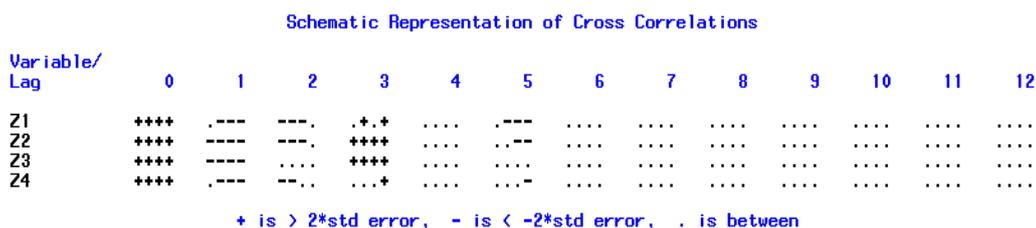
4.2 Identifikasi Model GSTAR

Pengidentifikasi stasioneritas pada model *multivariate time series* dapat dilakukan dengan melihat dari plot MACF, yakni sebagai berikut:



Gambar 2. MACF Data Ketinggian Pasang Surut Air Laut di Empat Stasiun

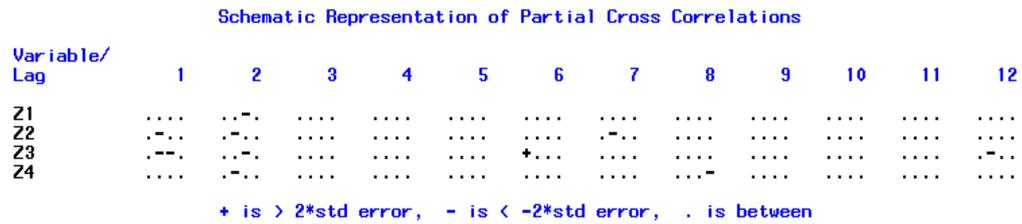
Berdasarkan Gambar 2 terlihat bahwa data belum stasioner dalam mean. Hal ini ditunjukkan oleh banyaknya simbol (+) dan (-) yang keluar dari ± 2 kali batas *standard error* pada setiap lag. Oleh karena itu data perlu dilakukan *differencing*.



Gambar 3. MACF Data Ketinggian Pasang Surut Air Laut di Empat Stasiun Setelah *Differencing* 1

Setelah dilakukan *differencing* 1, diperoleh plot MACF yang ditampilkan pada Gambar 3. Dari gambar tersebut dapat dilihat hampir semua tanda bersimbol (.) yang mengindikasikan bahwa tidak adanya korelasi. Sedangkan untuk tanda (+) dan (-) tidak ada lag yang keluar dari ± 2 kali batas *standard error* secara bersama-sama, hanya keluar pada lag-lag tertentu saja. Hal ini menunjukkan bahwa data sudah stasioner dalam mean yang dilihat secara subjektif peneliti.

Tahapan selanjutnya menentukan orde model dugaan sementara dengan melihat lag-lag pada MPACF yang keluar dari batas *standard error*.



Gambar 4. MPACF Data Ketinggian Pasang Surut Air Laut di Empat Stasiun

Gambar 4 menunjukkan bahwa ada beberapa lag yang keluar dari batas *standard error*. Karena jumlah lag yang keluar dari batas *standard error* lebih dari satu maka model yang akan terbentuk juga akan lebih dari satu model. Oleh karena itu perlu dilakukan identifikasi terhadap nilai-nilai AIC pada beberapa orde. Orde dengan nilai AIC terkecil dapat membentuk model GSTAR yang sesuai. Hasil identifikasi terhadap nilai AIC untuk semua model dugaan sementara sebagai berikut:

Minimum Information Criterion

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	6.1848299	6.2619441	6.3806534	6.6169412	6.6981043	6.8668093
AR 1	6.108908	6.364068	6.3839669	6.6796447	6.7112786	6.9426994
AR 2	6.1161083	6.4038052	6.5931639	6.8452183	6.9187202	7.1426523
AR 3	6.354561	6.6979957	6.9099498	7.1707651	7.0774509	7.4292139
AR 4	6.5690476	6.7513312	6.9501541	7.0570617	7.2947607	7.7812911
AR 5	6.8254428	7.027519	7.2095346	7.418397	7.7419684	8.2661661

Gambar 5. Nilai AIC dari Beberapa Orde Model

Gambar 5 menunjukkan bahwa nilai AIC terkecil terdapat pada ARMA(1,0) atau AR(1) yakni sebesar 6,108908, sehingga pada tahap identifikasi didapat model yang paling sesuai mempunyai orde *autoregressive* sama dengan satu ($p=1$). Pada penelitian ini orde spasial yang digunakan adalah orde spasial satu ($\lambda_p=1$). Dengan demikian dapat disimpulkan bahwa model yang paling sesuai untuk data ketinggian pasang surut air laut di empat stasiun Pulau Jawa yang sudah dilakukan *differencing* orde 1 adalah model GSTAR(1;1)-I(1).

4.3 Penentuan Bobot Lokasi Model GSTAR

Bobot lokasi yang paling baik adalah bobot lokasi yang membentuk dugaan kesalahan ramalan terkecil. Ada empat pembobot yang dilakukan dalam penelitian ini, yaitu:

1. Bobot Seragam

Hasil perhitungan bobot seragam sabagai berikut:

$$W = \begin{bmatrix} 0 & 0,33 & 0,33 & 0,33 \\ 0,33 & 0 & 0,33 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0,33 & 0 \end{bmatrix}$$

2. Bobot Biner

Hasil perhitungan bobot biner sabagai berikut:

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

3. Bobot Invers Jarak

Hasil perhitungan bobot invers jarak sabagai berikut:

$$W = \begin{bmatrix} 0 & 0,562 & 0,272 & 0,166 \\ 0,426 & 0 & 0,396 & 0,177 \\ 0,223 & 0,428 & 0 & 0,349 \\ 0,201 & 0,283 & 0,515 & 0 \end{bmatrix}$$

4. Bobot Normalisasi Korelasi Silang

Hasil perhitungan bobot normalisasi korelasi silang sabagai berikut:

$$W = \begin{bmatrix} 0 & -0,38063 & -0,42449 & -0,19488 \\ -0,28244 & 0 & -0,44714 & -0,27042 \\ -0,31361 & -0,41183 & 0 & -0,27456 \\ -0,27125 & -0,35311 & -0,37564 & 0 \end{bmatrix}$$

Setelah terbentuk model GSTAR(1;1)-I(1) untuk masing-masing pembobot, langkah selanjutnya mengecek diagnosa *white noise* residual. Diperoleh hasil bahwa residual dari model GSTAR menggunakan bobot seragam, bobot biner dan bobot normalisasi korelasi silang memenuhi asumsi *white noise*. Sedangkan untuk bobot invers jarak tidak memenuhi asumsi *white noise* residual.

Sehingga dari hasil analisis dapat diperoleh bahwa model GSTAR terbaik adalah menggunakan bobot normalisasi korelasi silang karena menghasilkan residual yang memenuhi asumsi *white noise* dengan rata-rata nilai MAPE dan RMSE terkecil, yaitu sebesar 11,261% dan 13,260. Sehingga persamaan model GSTAR terbaik untuk data ketinggian pasang surut air laut di Pulau Jawa masing-masing lokasi adalah sebagai berikut:

i. Jakarta

$$Z_1(t) = Z_1(t-1) - 0,060(Z_2(t-1) - Z_2(t-2)) - 0,067(Z_3(t-1) - Z_3(t-2)) - 0,031(Z_4(t-1) - Z_4(t-2)) + e_1(t)$$

ii. Cirebon

$$Z_2(t) = 0,675Z_2(t-1) + 0,325Z_2(t-2) + e_2(t)$$

iii. Semarang

$$Z_3(t) = 0,639Z_3(t-1) + 0,361Z_3(t-2) + e_3(t)$$

iv. Surabaya

$$Z_4(t) = Z_4(t-1) - 0,060(Z_1(t-1) - Z_1(t-2)) - 0,078(Z_2(t-1) - Z_2(t-2)) - 0,083(Z_3(t-1) - Z_3(t-2)) + e_4(t)$$

Berdasarkan model GSTAR terbaik dapat dianalisis bagaimana keterkaitan antar waktu dan lokasi pada data ketinggian pasang surut air laut di Pulau Jawa. Model GSTAR terbaik menjelaskan bahwa data ketinggian pasang surut air laut Stasiun Cirebon dan Stasiun Semarang hanya dipengaruhi oleh waktu-waktu sebelumnya, tidak dipengaruhi oleh kota lain namun dapat mempengaruhi ketinggian pasang surut air laut di kota lain. Sedangkan untuk data ketinggian pasang surut air laut Stasiun Jakarta dan Stasiun Surabaya saling mempengaruhi satu sama lain.

4.4 Peramalan Model GSTAR

Berdasarkan model terbaik yaitu model GSTAR(1;1)-I(1) dengan bobot normalisasi korelasi silang, maka dapat digunakan untuk mendapatkan nilai-nilai ramalan untuk masing-masing lokasi. Data yang akan diramalkan sebanyak 10 periode kedepan yaitu dari tanggal 23 Juli 2015 sampai 1 Agustus 2015. Hasil ramalan dari model GSTAR terbaik untuk data ketinggian pasang surut air laut di empat stasiun Pulau Jawa ditampilkan pada Tabel 3.

Tabel 3. Hasil Ramalan Data Ketinggian Pasang Surut Air Laut di Pulau Jawa menggunakan model GSTAR terbaik

Tanggal	Jakarta	Cirebon	Semarang	Surabaya
23 Juli 2015	147,422	78,473	133,916	108,104
24 Juli 2015	148,726	79,455	133,888	107,694
25 Juli 2015	147,297	78,461	134,726	108,244
26 Juli 2015	149,666	78,028	131,287	106,787
27 Juli 2015	146,319	79,490	133,483	105,887
28 Juli 2015	145,877	78,323	132,023	102,753
29 Juli 2015	150,004	77,421	130,698	103,386
30 Juli 2015	148,286	78,669	132,883	102,193
31 Juli 2015	149,386	76,076	132,592	104,692
1 Agustus 2015	150,828	77,898	131,453	102,335

5 KESIMPULAN

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan, disimpulkan bahwa model GSTAR terbaik untuk data ketinggian pasang surut air laut di Stasiun Jakarta, Cirebon, Semarang dan Surabaya adalah model GSTAR(1;1)-(1) menggunakan bobot normalisasi korelasi silang. Hal ini dikarenakan lokasi tersebut menghasilkan residual yang memenuhi asumsi *white noise* dengan rata-rata nilai MAPE sebesar 11,261% dan RMSE sebesar 13,260. Model GSTAR terbaik menjelaskan bahwa data ketinggian pasang surut air laut Stasiun Cirebon dan Stasiun Semarang hanya dipengaruhi oleh waktu-waktu sebelumnya, tidak dipengaruhi oleh kota lain namun dapat mempengaruhi ketinggian pasang surut air laut di kota lain. Sedangkan untuk data ketinggian pasang surut air laut Stasiun Jakarta dan Stasiun Surabaya saling mempengaruhi satu sama lain.

DAFTAR PUSTAKA

- Box, G.E.P., Jenkins, G.M. dan Reinsel G.C. 1994. *Time Series Analysis: Forecasting and Control*. Third Edition. Englewood Cliffs: Prentice Hall.
- Faizah, L.A. dan Setiawan. 2013. Pemodelan Inflasi di Kota Semarang, Yogyakarta dan Surakarta dengan Pendekatan GSTAR. *Jurnal Sains dan Seni Pomits*. Vol.2. No.2.
- Ibnudin, A. 2016. Ini Wilayah Pesisir yang Dilanda Banjir Rob, Pikiran Rakyat. <http://www.pikiran-rakyat.com/nasional/2016/06/07/ini-wilayah-pesisir-yang-dilanda-banjir-rob-371094> (diakses pada 10 Juni 2016; pukul 11.20 WIB).
- Prisandy, D.E. dan Suhartono. 2008. Penerapan Metode GSTAR(p1) untuk Meramalkan Data Penjualan Rokok di Tiga Lokasi. *Widya Teknik*. Vol.7. No.2. 199:210.
- Rahardjo, S. dan Sanusi, H.S. 1983. *Oseanografi Perikanan*. Edisi Pertama. Departemen Pendidikan dan Kebudayaan. Jakarta.
- Suhartono dan Atok, R.M. 2006. Pemilihan Bobot Lokasi yang Optimal pada model GSTAR. *Presented at National Mathematics Conference XIII*. Semarang: Universitas Negeri Semarang.
- Wei, W.W.S. 2006. *Time Series Analysis and Multivariate Methods*. Addison Wesley Publishing Company. Inc. Canada.
- Widyantoro, B.T. 2014. Karakteristik Pasang Surut Laut di Indonesia. *Jurnal Ilmiah Geomatika*. Vol.20. No.1. 65-72.
- Wutsqa, D.U., Suhartono dan Sujito, B. 2010. *Generalized Space-Time Autoregressive Modeling. Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and its Application*. Universiti Tunku Abdul Rahman. Kuala Lumpur. Malaysia. 752:761.