

PEMODELAN *GENERALIZED SPACE TIME AUTOREGRESSIVE* (GSTAR) *SEASONAL* PADA DATA JUMLAH WISATAWAN MANCANEGERA EMPAT KABUPATEN/KOTA DI JAWA TENGAH

Ronny Gusnadi¹, Rita Rahmawati², Alan Prahutama³

¹Mahasiswa Jurusan Statistika FSM Universitas Diponegoro

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

ronnygusnadi@gmail.com, ritarahmawati@gmail.com, alan.prahutama@gmail.com

ABSTRACT

In many applications, several time series data are recorded simultaneously at a number of locations. Time series data from nearby locations often to be related by spatial and time. This data is called spatial time series data. *Generalized Space Time Autoregressive* (GSTAR) model is one of space time models used to modeling and forecasting spatial time series data. This study applied GTSAR model to modeling number of international tourist four locations in Magelang Regency, Surakarta City, Wonosobo Regency, and Karanganyar Regency. Based on the smallest RMSE mean of forecasting result, the best model chosen by this study is $GSTAR(1_1)-I(1)^{12}$ with the inverse distance weighted. Based on $GSTAR(1_1)-I(1)^{12}$ with the inverse distance weighted, the relationship between the location shown on International tourist arrivals Surakarta City influenced by the International tourist in other regencies.

Keywords: GSTAR, RMSE, *International Tourist*

1. PENDAHULUAN

Dalam fenomena yang terjadi dalam kehidupan sehari-hari, perkembangan analisis runtun waktu melibatkan interaksi yang cukup kompleks di dalamnya. Hal ini juga mempengaruhi perkembangan dalam kajian ilmiah, salah satunya perkembangan dalam kasus analisis runtun waktu multivariat. Beberapa data runtun waktu dicatat secara bersamaan di sejumlah lokasi yang menghasilkan runtun waktu spasial (*space time*), yaitu data yang disusun berdasarkan waktu dan lokasi^[1]. Data runtun waktu dari beberapa lokasi yang berdekatan seringkali memiliki keterkaitan antar lokasi satu dan lainnya^[1]. Dalam analisis runtun waktu spasial, salah satu model *space time* yang mampu menjelaskan data yang mempunyai keterkaitan waktu sebelumnya dan keterkaitan dengan lokasi yang berdekatan adalah *Generalized Space Time Autoregressive* (GSTAR). Salah satu data runtun waktu spasial terdapat dalam bidang pariwisata.

Pariwisata merupakan salah satu kekuatan dalam sosial dan ekonomi suatu negara^[4]. Pada tahun 2014 kontribusi sektor pariwisata Indonesia terhadap perekonomian diperkirakan bisa mencapai 8,1 persen^[8]. Jumlah wisatawan mancanegara yang berkunjung ke Daya Tarik Wisata di Jawa Tengah terus mengalami perkembangan. Empat Kabupaten/Kota di Jawa Tengah yang banyak dikunjungi wisatawan mancanegara, yaitu Kabupaten Magelang, Kota Surakarta, Kabupaten Wonosobo, dan Kabupaten Karanganyar. Perkembangan data kunjungan wisatawan mancanegara keempat lokasi tersebut memungkinkan selain dipengaruhi oleh waktu sebelumnya juga dipengaruhi keterkaitan satu sama lain. Dalam penelitian ini, data kunjungan wisatawan mancanegara keempat lokasi di atas akan dimodelkan dengan pendekatan model *Generalized Space Time Autoregressive* (GSTAR).

2. TINJAUAN PUSTAKA

2.1. *Multivariate Time Series*

runtun waktu multivariat merupakan suatu pengamatan secara simultan dari dua atau lebih variabel^[3]. Suatu runtun waktu multivariat biasanya disajikan dalam suatu *vector time series*. Gagasan dari suatu *vector time series* berawal dari konsep *vector stochastic* atau *random process* yang didefinisikan sebagai kumpulan dari *random vectors* yang disusun oleh waktu $Z(t_1), Z(t_2), \dots, Z(t_n)$.

Pada kasus multivariat, kestasioneritasan dari runtun waktu dapat dilihat dari *Matrix Autocorrelation Function* (MACF). Bentuk plot MACF yang *tails off* (turun secara perlahan) menandakan data tidak stasioner.

2.2. *Seasonal Time Series*

Suatu runtun waktu terkadang mengandung fenomena *seasonal* atau musiman yang berulang pada periode waktu tertentu. Periode waktu terkecil untuk fenomena berulang ini disebut *seasonal period* atau periode musiman^[7]. Model ARIMA musiman multiplikatif dalam prosedur Box-Jenkins adalah sebagai berikut:

$$\phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\theta_Q(B^S) \quad (1)$$

Secara umum, komponen *autoregressive* musiman dan non musiman memiliki PACF *cutting off* atau terpotong pada lag musiman dan non musiman.

2.3. *Matrix Autocorrelation Function* (MACF)

Jika diberikan suatu *vector time series* sebanyak T observasi, yaitu Z_1, Z_2, \dots, Z_T , maka persamaan matriks korelasi sampel dapat dihitung sebagai berikut^[6]:

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

dimana $\hat{\rho}_{ij}(k)$ adalah korelasi silang sampel dari komponen deret ke- i dan ke- j pada lag waktu k yang diberikan sebagai berikut:

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{T-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,t+k} - \bar{Z}_j)}{[\sum_{t=1}^{T-k} (Z_{i,t} - \bar{Z}_i)^2 \sum_{t=1}^{T-k} (Z_{j,t} - \bar{Z}_j)^2]^{1/2}} \quad (3)$$

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

Dalam meringkas korelasi sampel terdapat metode sederhana menggunakan simbol yang dinotasikan dengan (+), (-) dan (.) pada matriks korelasi sampel ke (i,j) . Simbol-simbol tersebut dapat diartikan sebagai berikut:

- Simbol (+) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ lebih besar dari 2 kali standar error dari $\hat{\rho}_{ij}(k)$ dan menunjukkan hubungan korelasi positif antara komponen (i,j) .
- Simbol (-) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ lebih kecil dari -2 kali standar error dari $\hat{\rho}_{ij}(k)$ dan menunjukkan hubungan korelasi negatif antara komponen (i,j) .
- Simbol (.) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ berada di antara ± 2 kali standar error dari $\hat{\rho}_{ij}(k)$ dan menunjukkan tidak adanya korelasi antara komponen (i,j) .

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

$$S_{\hat{\rho}_{ij}(k)} = \sqrt{\frac{1}{T} (1 + 2\hat{\rho}_{ij}^2(1) + 2\hat{\rho}_{ij}^2(2) + \dots + 2\hat{\rho}_{ij}^2(k-1))} \quad (4)$$

dimana T adalah banyaknya pengamatan (observasi).

2.4. *Matrix Partial Autocorrelation Function* (MPACF)

Fungsi matriks autokorelasi parsial sangat berguna dalam mengidentifikasi orde dari sebuah model AR (p). *Matrix Partial Autocorrelation Function* (MPACF) pada lag ke- k yang dinotasikan dengan $\mathcal{P}(k)$ merupakan koefisien matriks terakhir ketika data yang

dimasukkan ke dalam suatu proses *vector time series* dari orde p . $\mathcal{P}(k)$ merupakan persamaan untuk $\Phi_{k,k}$ dalam regresi linier multivariat.

Persamaan untuk matriks autokorelasi parsial adalah sebagai berikut^[6]:

$$\mathcal{P}(k) = \begin{cases} \Gamma'(1)[\Gamma(0)]^{-1}, & k = 1 \\ \{\Gamma'(k) - \mathbf{c}'(k)[\mathbf{A}(k)]^{-1}\mathbf{b}(k)\} \{\Gamma'(0) - \mathbf{b}'(0)[\mathbf{A}(0)]^{-1}\mathbf{b}(0)\}^{-1}, & k > 1 \end{cases} \quad (5)$$

untuk $k \geq 2$, maka persamaan untuk nilai $\mathbf{A}(k)$, $\mathbf{b}(k)$ dan $\mathbf{c}(k)$ adalah sebagai berikut^[6]:

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

$$\mathbf{b}(k) = \begin{bmatrix} \Gamma'(k-1) \\ \Gamma'(k-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix}, \quad \mathbf{c}(k) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(k-1) \end{bmatrix}. \quad (6)$$

2.5. Model Generalized Space Time Autoregressive (GSTAR)

Model *Generalized Space Time Autoregressive* (GSTAR) merupakan suatu model yang lebih fleksibel sebagai generalisasi dari model *Space Time Autoregressive* (STAR) yang mampu mengungkapkan keterkaitan linier dari waktu dan lokasi. Model GSTAR memungkinkan nilai-nilai parameter *autoregressive* bervariasi untuk setiap lokasi. Pada model *Generalized Space Time Autoregressive* (GSTAR), keterikatan spasial dinyatakan oleh matriks pembobot^[9].

Jika diberikan suatu vektor deret waktu $\mathbf{Z}_t = [Z_{1,t}, Z_{2,t}, \dots, Z_{n,t}]'$, $t = 0, \pm 1, \pm 2, \dots$, sebagai suatu vektor deret waktu berdimensi n , maka model GSTAR dari orde *autoregressive* p dan orde spasial $\lambda_1, \lambda_2, \dots, \lambda_p$, GSTAR $(p_{\lambda_1, \lambda_2, \dots, \lambda_p})$ dapat ditulis sebagai berikut^[9]:

$$\mathbf{Z}(t) = \sum_{k=1}^p \left[\Phi_{k0} + \sum_{l=1}^{\lambda_p} \Phi_{kl} \mathbf{W}^{(l)} \right] \mathbf{Z}(t-k) + \mathbf{a}(t) \quad (7)$$

dimana $\Phi_{k0} = \text{diag}(\phi_{k0}^1, \dots, \phi_{k0}^n)$ dan $\Phi_{kl} = \text{diag}(\phi_{sl}^1, \dots, \phi_{sl}^n)$, sedangkan bobot-bobot dipilih untuk memenuhi $w_{ii}^{(l)} = 0$ dan $\sum_{j=1}^n w_{ij}^{(l)} = 1$.

a. Bobot Invers Jarak

Bobot yang paling umum digunakan adalah pembobotan berdasarkan invers dari jarak *euclidean* atau garis lurus antar lokasi. Jika diberikan dua lokasi dengan koordinat (x_i, y_i) , dan (x_j, y_j) , maka jarak *euclidean* antar lokasi tersebut adalah^[2]:

$$d_{i,j} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (8)$$

Menurut Cliff dan Ord (1981), invers dari jarak *euclidean* antar lokasi adalah $c(1 + d_{i,j})^{-\alpha}$, dimana $d_{i,j}$ merupakan jarak lokasi i ke j , dan c, α sembarang konstanta positif^[11]. Selanjutnya, penentuan bobot invers jarak dapat dilakukan dengan normalisasi nilai-nilai invers dari jarak *euclidean* antar lokasi, sehingga diperoleh persamaan untuk bobot invers jarak sebagai berikut:

$$w_{ij} = \frac{c(1+d_{i,j})^{-\alpha}}{\sum_{j \neq i} c(1+d_{i,j})^{-\alpha}} \quad (9)$$

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

b. Bobot Normalisasi Korelasi Silang

Penentuan bobot spasial dengan menggunakan normalisasi dari hasil korelasi silang antar lokasi pada lag waktu yang bersesuaian pertama kali diusulkan oleh Suhartono dan Atok^[5]. Taksiran dari korelasi silang ini pada data sampel adalah:

$$r_{ij}(k) = \frac{\sum_{t=k+1}^T [(Z_i(t) - \bar{Z}_i)(Z_j(t-k) - \bar{Z}_j)]}{\left[\sum_{t=1}^T (Z_i(t) - \bar{Z}_i)^2 \sum_{t=1}^T (Z_j(t) - \bar{Z}_j)^2 \right]^{\frac{1}{2}}} \quad (10)$$

Selanjutnya, penentuan bobot spasial dapat dilakukan dengan normalisasi dari besaran-besaran korelasi silang antar lokasi pada lag waktu yang bersesuaian. Proses ini secara umum menghasilkan bobot lokasi untuk model GSTAR(1₁) sebagai berikut:

$$w_{ij} = \frac{r_{ij}(1)}{\sum_{j \neq i} |r_{ij}(1)|}, \quad (11)$$

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

2.6. Estimasi Parameter

Suatu model GSTAR dapat direpresentasikan sebagai sebuah model linear dan parameter-parameter *autoregressive* model dapat diestimasi menggunakan metode kuadrat terkecil atau metode *least square*^[11]. Dengan mempertimbangkan model GSTAR(1₁) yang didefinisikan dari persamaan (7) dapat dituliskan sebagai berikut:

$$Z_i(t) = \phi_{10}^i Z_i(t-1) + \phi_{11}^i \sum_{j=1}^n w_{ij} Z_j(t-1) + a_i(t). \quad (12)$$

Jika diberikan pengamatan $Z_i(t)$, $t = 1, 2, \dots, T$, untuk lokasi $i = 1, 2, \dots, n$, dan dengan

$$V_i(t) = \sum_{j=1}^n w_{ij} Z_j(t) \quad \text{untuk } i \neq j, \quad (13)$$

maka persamaan untuk lokasi ke- i dalam model linear dapat ditulis dalam bentuk $\mathbf{Y}_i = \mathbf{X}_i \boldsymbol{\beta}_i + \mathbf{a}_i$, dimana $\boldsymbol{\beta}_i = (\phi_{10}^i, \phi_{11}^i)'$ merupakan parameter *autoregressive* untuk waktu dan spasial. Estimasi dari vektor parameter dengan metode *Least Square* adalah sebagai berikut:

$$\hat{\boldsymbol{\beta}} = [\mathbf{X}'\mathbf{X}]^{-1} \mathbf{X}'\mathbf{Y} \quad (14)$$

2.7. Kriteria Pemilihan Model

Kriteria pemilihan orde *autoregressive* p dari semua kemungkinan model ditentukan menggunakan metode *Akaike's Information Criterion* (AIC). Sedangkan untuk kriteria pemilihan model peramalan terbaik ditentukan dengan memperhatikan nilai *Root Mean Square Error* (RMSE).

1. Akaike's Information Criterion

Perhitungan nilai $AIC(p)$ diperoleh melalui persamaan berikut^[9]:

$$AIC(p) = \ln(|\hat{\Sigma}_p|) + \frac{2K^2 p}{T} \quad (15)$$

dimana K adalah banyaknya parameter dalam model, T merupakan 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. Root Mean Square Error (RMSE)

Tujuan dari model peramalan adalah untuk meramalkan nilai yang akan datang dengan *error* sekecil mungkin, salah satu alternatif untuk pemilihan model berdasarkan nilai *error* adalah *Root Mean Square Error* (RMSE)^[6]. Persamaan RMSE dirumuskan sebagai berikut:

$$RMSE = \sqrt{\left(\frac{1}{T} \sum_{t=1}^T (Z_t - \hat{Z}_t)^2\right)} \quad (16)$$

dengan T merupakan banyaknya pengamatan, Z_t adalah nilai pengamatan pada waktu ke- t , dan \hat{Z}_t adalah nilai ramalan pada waktu ke- t .

2.8. Pengujian Asumsi Residual

Asumsi dasar yang harus dipenuhi adalah *error vector* bersifat *white noise*. Residual bersifat *white noise* mengartikan bahwa residual dari masing-masing data adalah saling independen^[9]. Berdasarkan model estimasi, penduga untuk residual dapat ditulis sebagai berikut:

$$\hat{a}(t) = Z(t) - \hat{Z}(t) \quad (17)$$

Pengecekan asumsi *white noise* residual dapat dilihat menggunakan ACF atau PACF dari residual. Jika setiap plot ACF tidak signifikan secara statistik terhadap 2 standar error dari ACF residual, maka residual bersifat *white noise*^[6]. Cara lain yang dapat digunakan adalah dengan kriteria minimum AIC dari residual. Jika nilai AIC residual terkecil berada pada lag ke-0 maka dapat dikatakan bahwa tidak ada korelasi antar masing-masing residual, yang berarti residual bersifat *white noise*.

2.9. Pariwisata

Kata wisatawan (*tourist*) mengarah kepada orang yang melakukan wisata. *International tourist* (wisatawan mancanegara) adalah pengunjung atau pelancong sementara (*temporary visitors*) yang tinggal paling tidak 24 jam di negara yang dikunjungi dengan tujuan perjalanan seperti rekreasi, liburan, dan bisnis^[4].

3. METODE PENELITIAN

3.1. Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder jumlah wisatawan mancanegara pada empat Kabupaten/Kota di Jawa Tengah yang diperoleh dari Dinas Kebudayaan dan Pariwisata Propinsi Jawa Tengah dengan periode waktu dari bulan Januari 2008 hingga bulan Desember 2014. Data yang didapat sebanyak 84 data dibagi menjadi 2 bagian yaitu:

- (i) data *in-sample* : Januari 2008 – Desember 2013 (72 data)
- (ii) data *out-sample* : Januari 2014 – Desember 2014 (12 data).

Data *in-sample* digunakan untuk memodelkan data dan data *out-sample* digunakan untuk mengecek validasi model.

Terdapat empat variabel yang digunakan dalam penelitian ini yang merupakan data jumlah kunjungan wisatawan mancanegara di Daya Tarik Wisata (DTW) Kabupaten/Kota Jawa Tengah, yaitu:

1. $Z_1(t)$: Jumlah kunjungan wisatawan mancanegara Kabupaten Magelang
2. $Z_2(t)$: Jumlah kunjungan wisatawan mancanegara Kota Surakarta
3. $Z_3(t)$: Jumlah kunjungan wisatawan mancanegara Kabupaten Wonosobo
4. $Z_4(t)$: Jumlah kunjungan wisatawan mancanegara Kabupaten Karanganyar

3.2. Metode Analisis

Metode analisis yang digunakan dalam penelitian tugas akhir ini akan diuraikan sebagai berikut:

1. Melakukan identifikasi orde model dugaan sementara dengan melihat MACF, MPACF, dan nilai AIC minimum.

2. Memeriksa kestasioneritasan proses dengan melihat MACF. Jika proses tidak stasioner dan mengandung pola *seasonal* pada MACF, maka dapat dilakukan *differencing* dan memasukkan lag *seasonal* kedalam model jika data telah stasioner dan MPACF yang nyata pada lag *seasonal*. Pola *seasonal* dapat diidentifikasi dengan melihat MACF yang nyata pada lag *seasonal*.
3. Menghitung matriks pembobot pada model GSTAR.
4. Menghitung estimasi parameter *autoregressive* untuk model GSTAR dengan metode *least square*.
5. Melakukan pengecekan asumsi *white noise* residual.
6. Menghitung nilai RMSE masing-masing model.
7. Memilih model terbaik berdasarkan nilai RMSE.

4. HASIL DAN PEMBAHASAN

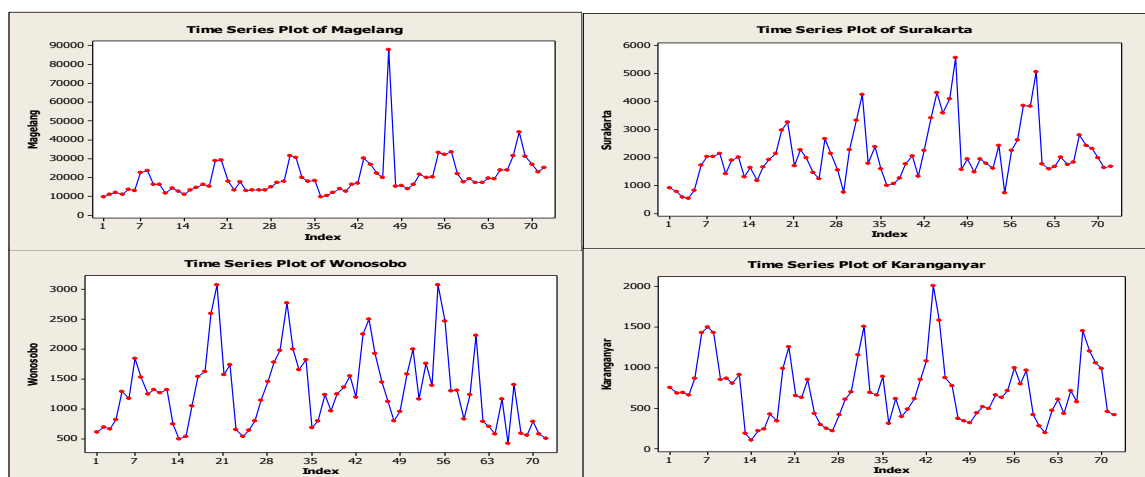
4.1. Statistika Deskriptif

Hasil analisis statistika deskriptif dari data empat lokasi tersebut ditampilkan dalam Tabel 1.

Tabel 1 Statistika Deskriptif Data Wisatawan Mancanegara di Jawa Tengah

Lokasi	Total	Rata-rata	Min.	Maks.	Standar Deviasi
Kab. Magelang (Z1)	1450366	20144	9536	87732	10665,82
Kota Surakarta (Z2)	150670	2093	526	5576	1009,05
Kab. Wonosobo (Z3)	94603	1314	427	3074	633,9341
Kab. Karanganyar (Z4)	51301	713	103	2007	384,4297

Berdasarkan analisis deskriptif pada Tabel 1 terlihat bahwa rata-rata tertinggi dari banyaknya kunjungan wisatawan mancanegara pada empat lokasi di atas antara tahun 2008 sampai 2013, terdapat pada Kabupaten Magelang yaitu sebesar 20144 wisatawan mancanegara.



Gambar 1 Plot *time series* data kunjungan wisatawan mancanegara di empat Kabupaten/Kota

Gambar 1 memperlihatkan bahwa secara umum pola kunjungan wisatawan mancanegara pada empat Kabupaten/Kota di atas relatif sama. Hal itu memungkinkan kecenderungan efek saling keterkaitan antar lokasi satu dengan lokasi yang lain.

Tabel 2 Nilai Korelasi Data Wisatawan Mancanegara Z1, Z2, Z3, dan Z4

Lokasi	Z1	Z2	Z3
Z2	0,602		
<i>p-value</i>	0,000		
Z3	0,336	0,366	
<i>p-value</i>	0,004	0,002	
Z4	0,497	0,349	0,406
<i>p-value</i>	0,000	0,003	0,000

*Menggunakan korelasi rho spearman

Tabel 2 menjelaskan bahwa pada waktu yang bersesuaian meskipun nilai-nilai korelasi relatif kecil, terdapat korelasi yang signifikan antar data wisatawan empat lokasi tersebut pada taraf signifikansi 5%. Hal tersebut mengindikasikan kecenderungan adanya keterkaitan antar lokasi satu dan lainnya.

4.2. Identifikasi Model GSTAR

Tahap identifikasi meliputi identifikasi MACF (*Matrix Autocorrelation Function*), MPACF (*Matrix Partial Autocorrelation Function*), dan nilai AIC (*Akaike's Information Criterion*) pada beberapa orde model.

Tabel 3 Skema Matriks Korelasi Silang (MACF) Z1, Z2, Z3, dan Z4

Variabel/Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Z1	++++	+..-	..-	..-	..-	..-+	+++.
Z2	++++	++..	..+	..-	..-	..-	..-+	..++	+++.
Z3	++++	++++	..+	..+-	..-	..-	..-+	..++	++++
Z4	++++	+++.	..+-	..-	..-	..-	..-+	..++	+++.

+ is > 2*std error, - is < -2*std error, . is between

Skema matriks korelasi silang (MACF) pada Tabel 3 menunjukkan bahwa data belum stasioner dalam mean. Hal ini ditunjukkan oleh banyaknya simbol (+) dan (-) pada setiap lag. MACF menunjukkan bahwa data perlu dilakukan *differencing* 12, karena terdapat kecenderungan data bersifat musiman yang ditandai dengan terdapat simbol (+) pada lag ke-1 kemudian lag ke-12.

Tabel 4 Skema Matriks Korelasi Silang (MACF) Z1, Z2, Z3, dan Z4 Setelah *Differencing* 12

Variabel/Lag	0	1	2	3	4	5	6	7	8	9	10	11	12
Z1	++..++-
Z2	++..	..+--
Z3	++..	..+
Z4	..+	..+	..+	..+	..+-

+ is > 2*std error, - is < -2*std error, . is between

Tabel 4 menunjukkan bahwa data sudah stasioner. Hal ini ditunjukkan banyaknya notasi (.) yang mengindikasikan bahwa tidak adanya korelasi. Sementara notasi (+) dan (-) pada skema hanya keluar pada lag tertentu.

Tabel 5 Skema Matriks Korelasi Silang Parsial (MPACF) Z1, Z2, Z3, dan Z4 Setelah *Differencing* 12

Variabel/Lag	1	2	3	4	5	6	7	8	9	10	11	12
Z1	..-+-
Z2	..+
Z3	..+
Z4	..++

+ is > 2*std error, - is < -2*std error, . is between

Pada Tabel 5 lag-lag yang berada di luar nilai standar error dipilih sebagai orde *autoregressive* model sementara yang sesuai. Orde yang mempunyai nilai AIC terkecil dianggap orde model sementara yang sesuai.

Tabel 6 Ringkasan Nilai-nilai AIC dari Semua Orde Model

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	0,0115824	0,0654625	0,2313884	0,5886884	0,6818562	1,0370349
AR 1	-0,69842	0,1065773	0,6282258	1,0189042	1,1332784	1,9304401
AR 2	-0,339491	0,4707984	1,0951738	1,5848689	2,0267453	3,2471558
AR 3	-0,165896	0,5275179	1,5493946	2,2580111	2,8147789	4,3233151
AR 4	-0,027601	1,160597	2,312924	3,1037323	4,6077418	7,5551306
AR 5	0,8620043	1,6307187	3,409154	4,6588258	7,3906434	12,118951

Berdasarkan Tabel 6 terlihat bahwa nilai AIC terkecil terdapat pada AR (1) yakni sebesar -0,69842. Dengan demikian dapat disimpulkan bahwa untuk memodelkan GSTAR musiman pada kasus ini merupakan hasil *differencing* 12 dengan model yang digunakan adalah GSTAR (1)₁-I(1)¹².

4.3. Penentuan Bobot Lokasi pada Model GSTAR

a. Bobot Invers Jarak

Hasil perhitungan matriks pembobot dengan metode invers jarak adalah sebagai berikut:

$$W_{ij} = \begin{bmatrix} 0 & 0,307348 & 0,409149 & 0,283503 \\ 0,29984 & 0 & 0,259672 & 0,440487 \\ 0,443068 & 0,28824 & 0 & 0,268692 \\ 0,288365 & 0,459258 & 0,252377 & 0 \end{bmatrix}$$

b. Bobot Normalisasi Korelasi Silang

Dalam analisis ini *lag* yang digunakan adalah *lag* 1, karena orde *p* pada model GSTAR (1)₁-I(1)¹² di sini bernilai satu. Hasil perhitungan dari normalisasi nilai-nilai korelasi silang antar lokasi adalah sebagai berikut:

$$W_{ij} = \begin{bmatrix} 0 & 0,57467 & -0,0359 & -0,38943 \\ -0,87196 & 0 & -0,01519 & 0,11285 \\ -0,12025 & 0,31344 & 0 & -0,56631 \\ -0,08163 & -0,30055 & -0,61782 & 0 \end{bmatrix}$$

4.4. Estimasi Parameter Model GSTAR

a. Model GSTAR (1)₁-I(1)¹² dengan Bobot Invers Jarak

Hasil dari estimasi parameter model GSTAR (1)₁-I(1)¹² dengan bobot lokasi invers jarak ditampilkan dalam Tabel 7 berikut ini.

Tabel 7 Estimasi Parameter Model GSTAR (1)₁-I(1)¹² dengan bobot invers jarak semua parameter

Parameter	Nilai Taksiran	<i>t</i> _{hitung}	<i>p</i> -value
Φ_{10}	0,0298	0,28	0,783
Φ_{20}	0,5512	4,36	0,000*
Φ_{30}	0,5338	4,04	0,000*
Φ_{40}	0,5567	3,93	0,000*
Φ_{11}	0,0658	0,27	0,785
Φ_{21}	-0,8958	-3,10	0,002*
Φ_{31}	-0,0683	-0,40	0,692
Φ_{41}	-0,1093	-0,67	0,507

*Signifikan pada taraf signifikansi 5%

b. Model GSTAR (1₁)-I(1)¹² dengan Bobot Normalisasi Korelasi Silang

Hasil dari estimasi parameter model GSTAR (1₁)-I(1)¹² dengan bobot normalisasi korelasi silang ditampilkan dalam Tabel 8 berikut ini.

Tabel 8 Estimasi Parameter Model GSTAR (1₁)-I(1)¹² dengan bobot normalisasi korelasi silang semua parameter

Parameter	Nilai Taksiran	<i>t</i> _{hitung}	<i>p</i> -value
Φ_{10}	-0,0890	-0,75	0,454
Φ_{20}	0,5968	4,80	0,000*
Φ_{30}	0,4687	3,39	0,001*
Φ_{40}	0,5409	3,80	0,000*
Φ_{11}	0,4326	2,13	0,034*
Φ_{21}	0,4979	3,92	0,000*
Φ_{31}	0,3193	1,35	0,179
Φ_{41}	0,1340	0,76	0,450

*Signifikan pada taraf signifikansi 5%

Berdasarkan hasil estimasi parameter model GSTAR dengan semua bobot lokasi di atas didapat bahwa beberapa lokasi dipengaruhi oleh lokasi lainnya secara signifikan yang dapat menjelaskan keterkaitan antar lokasi yang ada.

4.5. Cek Diagnosa

Pengecekan asumsi residual yang dilakukan pada model GSTAR (1₁)-I(1)¹² untuk melihat bahwa residual dari masing-masing data adalah saling independen.

Tabel 9 AIC Residual dari Model GSTAR (1₁)-I(1)¹² dengan Bobot Invers Jarak

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	-0,811609	-0,155251	-0,078502	0,2459554	0,505142	1,1139137
AR 1	-0,518482	0,3174073	0,4813453	1,0944151	1,2212428	2,1916144
AR 2	-0,496891	0,4090206	0,9432657	1,7131525	2,3726867	3,7764149
AR 3	-0,293239	0,5702797	1,380919	2,236733	3,2816808	5,0955852
AR 4	0,1211236	0,9477967	2,2384232	3,3961378	5,0677655	8,2336461
AR 5	0,9853914	1,8979712	3,557018	5,122807	8,1856843	13,619501

Tabel 10 AIC Residual dari Model GSTAR (1₁)-I(1)¹² dengan Bobot Normalisasi Korelasi Silang

Lag	MA 0	MA 1	MA 2	MA 3	MA 4	MA 5
AR 0	-1,097807	-0,365504	-0,18686	0,2417026	0,5106515	1,2376216
AR 1	-0,668497	0,1234929	0,4333382	1,0273743	1,3586617	2,3867212
AR 2	-0,549723	0,3091924	1,0122205	1,7334389	2,0759583	3,2993505
AR 3	-0,144961	0,8069128	1,7175376	2,5584221	3,7018773	5,4197331
AR 4	0,2390675	1,0421258	2,4050967	3,787353	5,3632553	8,3860439
AR 5	0,9727654	1,8903841	3,4521391	4,7578901	8,0826101	13,033193

Berdasarkan Tabel 9 dan Tabel 10 dapat diketahui bahwa nilai AIC minimum dari residual model GSTAR (1₁)-I(1)¹² bobot invers jarak dan normalisasi korelasi silang terdapat pada orde AR (0) dan MA (0). Hal ini mengindikasikan bahwa tidak terdapat korelasi antar masing-masing residual, yang berarti residual model GSTAR (1₁)-I(1)¹² bersifat *white noise*.

4.6. Pemilihan Model Terbaik

Nilai RMSE yang dihasilkan masing-masing model pada setiap lokasi dirangkum pada Tabel 11.

Tabel 11 Ringkasan RMSE model GSTAR (1₁)-I(1)¹² pada Setiap Bobot Lokasi

Jenis Bobot	Lokasi				Rata-rata
	Magelang	Surakarta	Wonosobo	Karanganyar	
Invers Jarak	2780,9112	1433,493	491,5337	552,0358334	1329,182
Korelasi Silang	3065,5143	1977,301	424,4045	519,2406303	1474,698

Berdasarkan ringkasan RMSE pada Tabel 11 dapat disimpulkan bahwa model GSTAR (1₁)-I(1)¹² dengan bobot invers jarak merupakan model yang lebih baik dalam menggambarkan model ini. Hal itu dijelaskan oleh nilai RMSE dari hasil peramalan pada model GSTAR (1₁)-I(1)¹² dengan bobot invers jarak lebih kecil dari model GSTAR (1₁)-I(1)¹² dengan bobot normalisasi korelasi yaitu sebesar 1329,182.

5. KESIMPULAN

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan didapatkan kesimpulan bahwa model yang sesuai untuk data kunjungan wisatawan mancanegara empat Kabupaten/Kota di Jawa Tengah pada penelitian ini adalah model GSTAR(1₁)-I(1)¹². Model yang didapat berdasarkan bobot invers jarak dan normalisasi korelasi silang menggambarkan adanya keterikatan waktu dan lokasi yang ada, hal ini ditunjukkan dengan adanya parameter yang signifikan mempengaruhi lokasi satu dan lokasi lainnya. Model terbaik yang dihasilkan adalah model GSTAR (1₁)-I(1)¹² dengan bobot invers jarak, karena memiliki nilai rata-rata RMSE yang lebih kecil yaitu 1329,182.

DAFTAR PUSTAKA

1. Borovkova, S.A., Lopuhaa, H.P., and Ruchjana, B.N., Consistency and Asymptotic Normality of Least Square Estimators in Generalized STAR Models, *Journal compilation Statistica Neerlandica*, 2008: 482-500.
2. Fotheringham, A. S., Brunson, C., Charlton, M., *Quantitative Geography*, Sage Publications Ltd, London, 2000.
3. Gilgen, H., *Univariate Statistics in Geosciences*, Springer, Netherland, 2006.
4. Pitana, I. G., Diarta, I. K. S., *Pengantar Ilmu Pariwisata*, ANDI Yogyakarta, 2009.
5. Suhartono dan Subanar, The Optimal Determination of Space Weight in GSTAR Model by Using Cross-Correlation Inference, *JOURNAL OF QUANTITAVE METHODS: Journal Devoted to The Mathematical and Statistical Application in Various Field*, Vol. 2, No. 2, 2006, 45:53.
6. Wei, W.W.S., *Time Series Analysis Univariate and Multivariate Methods*, Addison Wesley Publishing Company, Inc., Canada, 1994.
7. Wei, W.W.S., *Time Series Analysis Univariate and Multivariate Methods*, Addison Wesley Publishing Company, Inc., Canada, 2006.
8. Widadio, N. A., *Menparekraf: Perkembangan Pariwisata Indonesia Paling Bagus*, Kompas, 2014.
<http://travel.kompas.com/read/2014/04/02/0949478/Menparekraf.Perkembangan.Pariwisata.Indonesia.Paling.Bagus> (diakses pada 25 Desember 2014 ; pukul 11.40 WIB).
9. Wutsqa, D. U., Suhartono, Sutijo, B., Generalized Space-Time Autoregressive Modeling, *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and its Applications (ICMSA2010)*, Universiti Tunku Abdul Rahman, Kuala Lumpur, Malaysia, 2010, 752:761.