

Perbandingan Bobot Normalisasi Cross Correlation dengan Cross Covariance dalam Model Peramalan Curah Hujan

Agus Dwi Sulistyono¹, Aniek Iriany¹, Atiek Iriany², Ni Wayan Suryawardhani²

¹ Program Studi Agroteknologi Fakultas Pertanian Peternakan Universitas Muhammadiyah Malang

² Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Brawijaya

Email: agusdwisulistyono@umm.ac.id

Abstrak

Penggunaan bobot lokasi pada pembentukan model spatio temporal turut andil dalam tingkat keakuratan model yang dibentuk. Bobot lokasi yang sering digunakan antara lain bobot lokasi uniform, invers jarak, dan normalisasi korelasi silang. Bobot lokasi tersebut mempertimbangkan kedekatan antar lokasi. Untuk data yang memiliki tingkat variabilitas yang tinggi, penggunaan bobot lokasi yang telah disebutkan di atas menjadi kurang relevan. Penelitian ini dilakukan dengan tujuan untuk mendapatkan metode pembobotan yang lebih sesuai untuk data dengan variabilitas tinggi. Penelitian ini dilakukan dengan menggunakan data sekunder yang berasal dari data curah hujan 10 harian yang didapatkan dari BMKG Karangploso. Periode data yang digunakan adalah Januari 2005 sampai dengan Desember 2015. Titik pos hujan yang diteliti meliputi pos hujan wilayah Blimbing, Karangploso, Singosari, Dau, dan Wagir. Berdasarkan hasil penelitian model peramalan yang didapatkan adalah model GSTAR((1),1,2,3,12,36)-SUR. Model dengan bobot cross covariance menghasilkan tingkat akurasi yang lebih baik ditinjau dari nilai RMSE yang lebih rendah dan nilai R² lebih tinggi terutama untuk wilayah Karangploso, Dau, dan Wagir.

Kata Kunci

Spatio Temporal,
GSTAR, bobot lokasi,
curah hujan

PENDAHULUAN

Model *spatio-temporal* yang telah dikembangkan diantaranya adalah model *Space-Time Autoregressive* (STAR) yang diperkenalkan oleh Pfeifer & Deutsch (1980, 1981). Model STAR memiliki asumsi bahwa varian antara lokasi satu dengan lainnya adalah sama/homogen. Namun, pada kenyataannya, sering kali diperoleh keheterogenan antar lokasi pengamatan. Dengan demikian model STAR tidak sesuai untuk data yang mempunyai karakteristik lokasi yang heterogen. Inilah yang menjadi kelemahan model STAR dan kelemahan ini dapat ditangani dengan model *Generalized Space-Time Autoregressive* (GSTAR) dan GSTAR-OLS yang dikembangkan oleh Borovkova, Lopuha, & Ruchjana (2002) dan Ruchjana (2001a, 2001b). Model GSTAR yang dikembangkan tersebut ini digunakan untuk data yang memenuhi asumsi stasioneritas. Perkembangan terakhir dari model spatio-temporal ini adalah model GSTAR-SUR yang dikembangkan oleh Iriany, Suhariningsih, Ruchjana, & Setiawan (2013) untuk mengatasi data yang tidak stasioner dan berpola musiman. Lebih lanjut, penggunaan model hybrid GSTAR-SUR-NN juga dikembangkan untuk data yang memiliki pola non linier (Iriany, Firdaus, Nugroho, & Sulistyono, 2016; Sulistyono, Hadi Nugroho, & Iriany, 2015; Sulistyono, Nugroho, Fitriani, & Iriany, 2016).

Diterima:

17 September 2018

Dipresentasikan:

22 September 2018

Disetujui Terbit:

27 Desember 2018

Penggunaan bobot lokasi pada pembentukan model *spatio temporal* juga turut andil dalam tingkat keakuratan model yang dibentuk. Bobot lokasi yang sering digunakan antara lain bobot lokasi *uniform*, invers jarak, dan normalisasi korelasi silang (Suhartono & Atok, 2006; Suhartono & Subanar, 2006). Bobot lokasi tersebut mempertimbangkan kedekatan antar lokasi. Untuk data yang memiliki tingkat variabilitas yang tinggi, penggunaan bobot lokasi yang telah disebutkan di atas menjadi kurang relevan. Oleh karena itu, diperlukan bobot lokasi yang mempertimbangkan aspek variabilitas data pengamatan. Salah satu bobot lokasi yang telah dikembangkan adalah bobot rasio-variance yang terbukti memiliki tingkat akurasi yang lebih baik (Sulistiyono, Nugroho, & Iriany, 2016). Bobot lokasi lain yang dikembangkan yakni bobot *cross covariance*. Penggunaan bobot *cross covariance* telah diteliti dan diaplikasikan dalam penelitian Apanasovich & Genton (2010) untuk memprediksi polusi di California dan penelitian Efromovich & Smirnova (2013) untuk proses imaging fMRI dengan pendekatan wavelate. Penelitian ini dilakukan untuk mengetahui tingkat akurasi model GSTAR yang dibangun menggunakan bobot *cross covariance* dan membandingkan tingkat akurasinya dengan model GSTAR yang dibangun dengan bobot *cross correlation*.

METODE

Penelitian ini menggunakan data sekunder yang berasal dari data curah hujan 10 harian yang didapatkan dari BMKG Karangploso. Periode data yang digunakan adalah Januari 2005 sampai dengan Desember 2015, dimana data untuk melakukan *training (in-sample)* adalah data bulan Januari 2005 sampai dengan Desember 2014. Sedangkan data bulan Januari 2015 sampai dengan Desember 2015 digunakan sebagai data *testing (out-of-sample)*. Langkah pertama yang dilakukan adalah pengujian stasioneritas data curah hujan. Uji stasioneritas terhadap rata-rata dilakukan dengan menggunakan uji Augmented Dickey Fuller. Sedangkan uji stasioneritas terhadap ragam dilakukan dengan uji Box-Cox. Langkah selanjutnya adalah mengidentifikasi lag MACF dan MPACF yang nyata untuk menentukan orde yang akan digunakan sebagai estimasi model GSTAR. Berikutnya, dilakukan penghitungan bobot

normalisasi cross correlation dengan persamaan $w_{ij} = \frac{r_{ij}(1)}{\sum_{k \neq i} |r_{ik}(1)|}$ (Suhartono & Subanar,

2006) dan bobot normalisasi *cross covariance*

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

(Apanasovich & Genton, 2010; Efromovich & Smirnova, 2013). Proses berikutnya yakni melakukan analisis GSTAR-OLS untuk mendapatkan nilai residual dengan persamaan

$\mathbf{Z}(t) = \boldsymbol{\mu}(t) + [\boldsymbol{\Phi}_{01} + \boldsymbol{\Phi}_{11}\mathbf{W}]\mathbf{Z}(t-1) + \boldsymbol{\varepsilon}(t)$. Selanjutnya Menghitung matriks var $(\boldsymbol{\varepsilon}) = \boldsymbol{\Omega}$ dengan persamaan

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1m} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{m1} & \sigma_{m2} & \dots & \sigma_{mm} \end{bmatrix}$$

Langkah berikutnya adalah estimasi parameter GSTAR(1,p)-SUR dengan menggunakan rumus $\beta = (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}y$. Model terbaik dipilih berdasarkan nilai RMSE dan R^2 prediction. Proses analisis data penelitian dilakukan dengan menggunakan software R dan SAS.

HASIL DAN PEMBAHASAN

Penelitian ini dilakukan dengan mengambil data curah hujan harian yang didapatkan dari titik pos hujan untuk wilayah Blimbing, Karangploso, Singosari, Dau, dan Wagir. Berikut deskripsi statistik data curah hujan pada kelima lokasi tersebut tersaji dalam Tabel 1:

Tabel 1. Deskripsi Statistik Data Curah Hujan di Lima Lokasi Penelitian

Lokasi	N	Rerata (mm)	Standar Deviasi (mm)	Minimum (mm)	Maksimum (mm)
Blimbing	360	5.682	6.909	0	33.5
Singosari	360	3.93	5.575	0	41.75
Karangploso	360	4.302	5.71	0	25.36
Dau	360	4.564	5.825	0	36.38
Wagir	360	7.08	8.187	0	43.63

Berdasarkan pada Tabel 1 di atas, secara deskriptif ditunjukkan bahwa rerata curah hujan di Kecamatan Wagir paling tinggi dan Kecamatan Singosari memiliki rerata curah hujan yang paling rendah. Di semua lokasi penelitian didapatkan nilai standar deviasi lebih besar dari rata-rata yang mengindikasikan tingkat keragaman curah hujan di semua lokasi penelitian sangat tinggi. Selain itu, heterogenitas lokasi pengamatan dapat diukur dengan menghitung Indeks Gini. Semakin tinggi nilai indeks gini, menunjukkan antar lokasi juga akan semakin heterogen. Perhitungan indeks gini untuk kelima lokasi pada penelitian ini adalah :

$$\begin{aligned}
 G_n &= 1 + \frac{1}{n} - \frac{2}{n^2 \bar{y}_i} \sum_{i=1}^N y_i \\
 &= 1 + \frac{1}{360} - \frac{2}{360^2 \cdot 5.111} 9200.68 \\
 &= 0.975
 \end{aligned}$$

Berdasarkan hasil perhitungan indeks gini didapatkan nilai indeks gini yang tinggi yaitu 0.975, mendekati 1. Dari penghitungan Indeks Gini tersebut ditunjukkan bahwa bahwa antarlokasi heterogen sehingga pemodelan menggunakan model GSTAR-SUR dapat dilakukan.

Pengujian stasioneritas terhadap ragam dilakukan dengan menggunakan plot *Box-Cox*. Stasioneritas terhadap ragam dikatakan terpenuhi jika dari hasil plot *Box-Cox* didapatkan nilai $\lambda = 1$. Namun, jika nilai $\lambda \neq 1$, maka dilakukan proses transformasi data. Berikut hasil pengujian stasioneritas terhadap ragam pada data curah hujan tiap lokasi :

Tabel 2. Pengujian Stasioneritas Terhadap Ragam Curah Hujan Tiap Lokasi

Lokasi	λ	Transformasi I	
		Transformasi	λ
Blimbing	-0.27	$Z^{-0.27}$	1.0
Singosari	-0.68	$Z^{-0.68}$	1.0
Karangploso	-0.50	$Z^{-0.5}$	1.0
Dau	-0.50	$Z^{-0.5}$	1.0
Wagir	-0.19	$Z^{-0.19}$	1.0

Berdasarkan Tabel 4.3 nilai λ awal untuk semua lokasi penelitian belum bernilai 1. Hal ini menunjukkan bahwa data curah hujan di tiap lokasi belum stasioner terhadap ragam sehingga perlu dilakukan transformasi Box-Cox. Hasil transformasi Box-Cox I menunjukkan nilai $\lambda = 1$ yang berarti bahwa data telah stasioner terhadap ragam dan transformasi dihentikan.

Selain stasioner terhadap ragam, pengujian stasioneritas juga dilakukan terhadap rata-rata. Pengujian stasioneritas terhadap rata-rata dilakukan dengan menggunakan uji *Augmented Dickey Fuller* (ADF). Stasioneritas terhadap rata-rata dikatakan terpenuhi jika dari hasil pengujian ADF didapatkan p-value kurang dari 0.05. Jika dari hasil pengujian ADF didapatkan p-value lebih dari 0.05, maka perlu dilakukan proses differencing. Berikut hasil pengujian ADF:

Tabel 3. Pengujian Stasioneritas Terhadap Rata-Rata Curah Hujan Tiap Lokasi

Lokasi	t-Statistics	p-value
Blimbing	-5.974	0.000
Singosari	-5.556	0.000
Karangploso	-7.831	0.000
Dau	-7.215	0.000
Wagir	-7.425	0.000

Berdasarkan hasil pengujian stasioneritas terhadap rata-rata dengan menggunakan uji ADF pada Tabel 3, pada tiap lokasi didapatkan p-value kurang dari 0.05. Dari pengujian ini ditunjukkan bahwa stasioneritas data curah hujan terhadap rata-rata telah terpenuhi.

Proses identifikasi model GSTAR dilakukan dengan melihat skema *Matrix Partial Autocorrelation Function* (MPACF).

Tabel 4. Skema Matriks Partial Autokorelasi (MPACF)

Schematic Representation of Partial Cross Correlations												
Variable/Lag	1	2	3	4	5	6	7	8	9	10	11	12
BLIMBING	.+++.	.+...
SINGOSARI	+++..	.+...	.+...+...	-....	.+...	-....
KARANGPLOSO	+.+.+	+.+.+	+.+.++..+	...-.	.+...+..
DAU	..+++.	+.+.+	...-.-.	-...-
WAGIR	+.+.+	+.+.++.+

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

Berdasarkan skema matriks MPACF pada Tabel 4 terlihat bahwa terdapat lag MPACF yang nyata pada lag 1 sampai lag 3. Kemudian pada lag 4, tidak ada autokorelasi parsial yang signifikan. Kemudian pada lag 5 dan seterusnya terdapat beberapa autokorelasi parsial yang signifikan. Berdasarkan dari skema MPACF tersebut, ditunjukkan bahwa autokorelasi parsial yang signifikan terpotong pada lag 4. Sehingga, penentuan orde VAR (p) dilakukan dengan melihat nilai AIC terkecil untuk lag yang nyata. Berikut nilai AIC pada pada lag 1 hingga lag 3:

Tabel 5. Nilai AIC untuk Penentuan Orde GSTAR

Orde	Nilai AIC
1	14.67906
2	14.52868
3	14.52445

Berdasarkan nilai AIC pada Tabel 5 terlihat bahwa nilai AIC terendah didapatkan pada orde ke-3. Sehingga, model GSTAR yang digunakan memiliki orde 3. Selain menentukan orde dengan nilai AIC, identifikasi model GSTAR juga dilakukan dengan melakukan plot ACF dan PACF secara univariat pada tiap lokasi. Berdasarkan pada plot ACF ditunjukkan bahwa data curah hujan pada tiap lokasi terdapat indikasi pola musiman. Hal ini dapat dilihat pada plot ACF yang memiliki pola yang berulang pada time lag tertentu. Berdasarkan pada plot PACF pada Lampiran 8 ditunjukkan bahwa pada beberapa *time lag* terdapat PACF yang melewati garis batas 5%. Jika dipadukan pada 5 lokasi, ditemukan bahwa kelima lokasi tersebut memiliki PACF yang melewati time lag 12 dan 36. Oleh karena itu, hasil identifikasi pola musiman ditunjukkan bahwa model yang sesuai adalah GSTAR ((1),1,2,3,12,36).

Penelitian ini menggunakan lima lokasi dengan nilai $n_i^{(1)}$ atau banyaknya lokasi yang berdekatan dengan lokasi i adalah 4 lokasi sehingga matriks normalisasi *cross correlation* adalah sebagai berikut :

$$W_{ij} = \begin{bmatrix} 0 & 0.2353 & 0.2294 & 0.2688 & 0.2665 \\ 0.2664 & 0 & 0.2143 & 0.2675 & 0.2518 \\ 0.2734 & 0.2100 & 0 & 0.2765 & 0.2401 \\ 0.2950 & 0.2174 & 0.2327 & 0 & 0.2549 \\ 0.2694 & 0.2235 & 0.2420 & 0.2650 & 0 \end{bmatrix}$$

Sedangkan besarnya bobot normalisasi *cross covariance* berdasarkan penghitungan adalah sebagai berikut :

$$W_{ij} = \begin{bmatrix} 0 & 0.2060 & 0.2056 & 0.2458 & 0.3426 \\ 0.2754 & 0 & 0.1831 & 0.2331 & 0.3084 \\ 0.2847 & 0.1764 & 0 & 0.2427 & 0.2962 \\ 0.3058 & 0.1818 & 0.1993 & 0 & 0.3130 \\ 0.3085 & 0.2065 & 0.2290 & 0.2559 & 0 \end{bmatrix}$$

Hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi korelasi silang untuk Kecamatan Blimbing adalah sebagai berikut :

$$\hat{Z}_{1t} = 0.119 Z_{1(t-1)} + 0.009 Z_{2(t-1)} - 0.009 Z_{3(t-1)} + 0.022 Z_{4(t-1)} + 0.017 Z_{5(t-1)} + 0.205 Z_{1(t-2)} + 0.087 Z_{2(t-2)} + 0.084 Z_{3(t-2)} + 0.009 Z_{4(t-2)} + 0.075 Z_{5(t-2)} - 0.086 Z_{1(t-3)} - 0.074 Z_{2(t-3)} + 0.037 Z_{3(t-3)} + 0.023 Z_{4(t-3)} + 0.005 Z_{5(t-3)} + 0.059 Z_{1(t-12)} - 0.056 Z_{2(t-12)} - 0.01 Z_{3(t-12)} + 0.019 Z_{4(t-12)} - 0.025 Z_{5(t-12)} + 0.246 Z_{1(t-36)} + 0.052 Z_{2(t-36)} - 0.093 Z_{3(t-36)} + 0.034 Z_{4(t-36)} + 0.069 Z_{5(t-36)}$$

Sedangkan hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi *cross covariance* adalah sebagai berikut :

$$\hat{Z}_{1t} = 0.116 Z_{1(t-1)} + 0.003 Z_{2(t-1)} - 0.006 Z_{3(t-1)} + 0.022 Z_{4(t-1)} + 0.015 Z_{5(t-1)} + 0.212 Z_{1(t-2)} + 0.083 Z_{2(t-2)} + 0.081 Z_{3(t-2)} + 0.018 Z_{4(t-2)} + 0.072 Z_{5(t-2)} - 0.092 Z_{1(t-3)} - 0.066 Z_{2(t-3)} + 0.031 Z_{3(t-3)} + 0.025 Z_{4(t-3)} + 0 Z_{5(t-3)} + 0.06 Z_{1(t-12)} - 0.048 Z_{2(t-12)} - 0.016 Z_{3(t-12)} + 0.016 Z_{4(t-12)} - 0.023 Z_{5(t-12)} + 0.256 Z_{1(t-36)} + 0.045 Z_{2(t-36)} - 0.085 Z_{3(t-36)} + 0.025 Z_{4(t-36)} + 0.068 Z_{5(t-36)}$$

Hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi korelasi silang untuk Kecamatan Singosari adalah sebagai berikut :

$$\hat{Z}_{2t} = 0.024 Z_{1(t-1)} + 0.171 Z_{2(t-1)} - 0.009 Z_{3(t-1)} + 0.02 Z_{4(t-1)} + 0.012 Z_{5(t-1)} + 0.017 Z_{1(t-2)} - 0.255 Z_{2(t-2)} + 0.083 Z_{3(t-2)} + 0.009 Z_{4(t-2)} + 0.052 Z_{5(t-2)} + 0.055 Z_{1(t-3)} + 0.649 Z_{2(t-3)} + 0.036 Z_{3(t-3)} + 0.021 Z_{4(t-3)} + 0.004 Z_{5(t-3)} - 0.017 Z_{1(t-12)} + 0.335 Z_{2(t-12)} - 0.01 Z_{3(t-12)} + 0.018 Z_{4(t-12)} - 0.018 Z_{5(t-12)} + 0.031 Z_{1(t-36)} - 0.084 Z_{2(t-36)} - 0.092 Z_{3(t-36)} + 0.031 Z_{4(t-36)} + 0.048 Z_{5(t-36)}$$

Sedangkan hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi *cross covariance* adalah sebagai berikut :

$$\hat{Z}_{2t} = 0.024 Z_{1(t-1)} + 0.206 Z_{2(t-1)} - 0.006 Z_{3(t-1)} + 0.021 Z_{4(t-1)} + 0.01 Z_{5(t-1)} + 0.013 Z_{1(t-2)} - 0.281 Z_{2(t-2)} + 0.081 Z_{3(t-2)} + 0.016 Z_{4(t-2)} + 0.05 Z_{5(t-2)} + 0.055 Z_{1(t-3)} + 0.639 Z_{2(t-3)} + 0.03 Z_{3(t-3)} + 0.023 Z_{4(t-3)} + 0 Z_{5(t-3)} - 0.017 Z_{1(t-12)} + 0.301 Z_{2(t-12)} - 0.015 Z_{3(t-12)} + 0.015 Z_{4(t-12)} - 0.016 Z_{5(t-12)} + 0.025 Z_{1(t-36)} - 0.04 Z_{2(t-36)} - 0.084 Z_{3(t-36)} + 0.023 Z_{4(t-36)} + 0.047 Z_{5(t-36)}$$

Hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi korelasi silang untuk Kecamatan Karangploso adalah sebagai berikut :

$$\hat{Z}_{3t} = 0.033 Z_{1(t-1)} + 0.008 Z_{2(t-1)} + 0.411 Z_{3(t-1)} + 0.023 Z_{4(t-1)} + 0.016 Z_{5(t-1)} + 0.023 Z_{1(t-2)} + 0.081 Z_{2(t-2)} - 0.318 Z_{3(t-2)} + 0.01 Z_{4(t-2)} + 0.072 Z_{5(t-2)} + 0.076 Z_{1(t-3)} - 0.069 Z_{2(t-3)} - 0.056 Z_{3(t-3)} + 0.024 Z_{4(t-3)} + 0.005 Z_{5(t-3)} - 0.023 Z_{1(t-12)} - 0.052 Z_{2(t-12)} + 0.029 Z_{3(t-12)} + 0.02 Z_{4(t-12)} - 0.024 Z_{5(t-12)} + 0.042 Z_{1(t-36)} + 0.048 Z_{2(t-36)} + 0.752 Z_{3(t-36)} + 0.035 Z_{4(t-36)} + 0.066 Z_{5(t-36)}$$

Sedangkan hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi *cross covariance* adalah sebagai berikut :

$$\hat{Z}_{3t} = 0.033 Z_{1(t-1)} + 0.003 Z_{2(t-1)} + 0.407 Z_{3(t-1)} + 0.023 Z_{4(t-1)} + 0.014 Z_{5(t-1)} + 0.018 Z_{1(t-2)} + 0.078 Z_{2(t-2)} - 0.348 Z_{3(t-2)} + 0.019 Z_{4(t-2)} + 0.069 Z_{5(t-2)} + 0.076 Z_{1(t-3)} - 0.061 Z_{2(t-3)} - 0.028 Z_{3(t-3)} + 0.026 Z_{4(t-3)} + 0 Z_{5(t-3)} - 0.023 Z_{1(t-12)} - 0.045 Z_{2(t-12)} + 0.067 Z_{3(t-12)} + 0.017 Z_{4(t-12)} - 0.022 Z_{5(t-12)} + 0.035 Z_{1(t-36)} + 0.042 Z_{2(t-36)} + 0.744 Z_{3(t-36)} + 0.026 Z_{4(t-36)} + 0.065 Z_{5(t-36)}$$

Hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi korelasi silang untuk Kecamatan Dau adalah sebagai berikut :

$$\hat{Z}_{4t} = 0.033 Z_{1(t-1)} + 0.009 Z_{2(t-1)} - 0.009 Z_{3(t-1)} + 0.253 Z_{4(t-1)} + 0.016 Z_{5(t-1)} + 0.023 Z_{1(t-2)} + 0.089 Z_{2(t-2)} + 0.086 Z_{3(t-2)} + 0.13 Z_{4(t-2)} + 0.069 Z_{5(t-2)} + 0.076 Z_{1(t-3)} - 0.075 Z_{2(t-3)} + 0.038 Z_{3(t-3)} + 0 Z_{4(t-3)} + 0.005 Z_{5(t-3)} - 0.023 Z_{1(t-12)} - 0.057 Z_{2(t-12)} - 0.01 Z_{3(t-12)} - 0.119 Z_{4(t-12)} - 0.023 Z_{5(t-12)} + 0.042 Z_{1(t-36)} + 0.053 Z_{2(t-36)} - 0.096 Z_{3(t-36)} + 0.169 Z_{4(t-36)} + 0.064 Z_{5(t-36)}$$

Sedangkan hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi *cross covariance* adalah sebagai berikut :

$$\hat{Z}_{4t} = 0.034 Z_{1(t-1)} + 0.003 Z_{2(t-1)} - 0.006 Z_{3(t-1)} + 0.25 Z_{4(t-1)} + 0.014 Z_{5(t-1)} + 0.018 Z_{1(t-2)} + 0.085 Z_{2(t-2)} + 0.084 Z_{3(t-2)} + 0.083 Z_{4(t-2)} + 0.066 Z_{5(t-2)} + 0.077 Z_{1(t-3)} - 0.067 Z_{2(t-3)} + 0.032 Z_{3(t-3)} - 0.008 Z_{4(t-3)} + 0 Z_{5(t-3)} - 0.023 Z_{1(t-12)} - 0.049 Z_{2(t-12)} - 0.016 Z_{3(t-12)} - 0.113 Z_{4(t-12)} - 0.021 Z_{5(t-12)} + 0.035 Z_{1(t-36)} + 0.046 Z_{2(t-36)} - 0.087 Z_{3(t-36)} + 0.203 Z_{4(t-36)} + 0.063 Z_{5(t-36)}$$

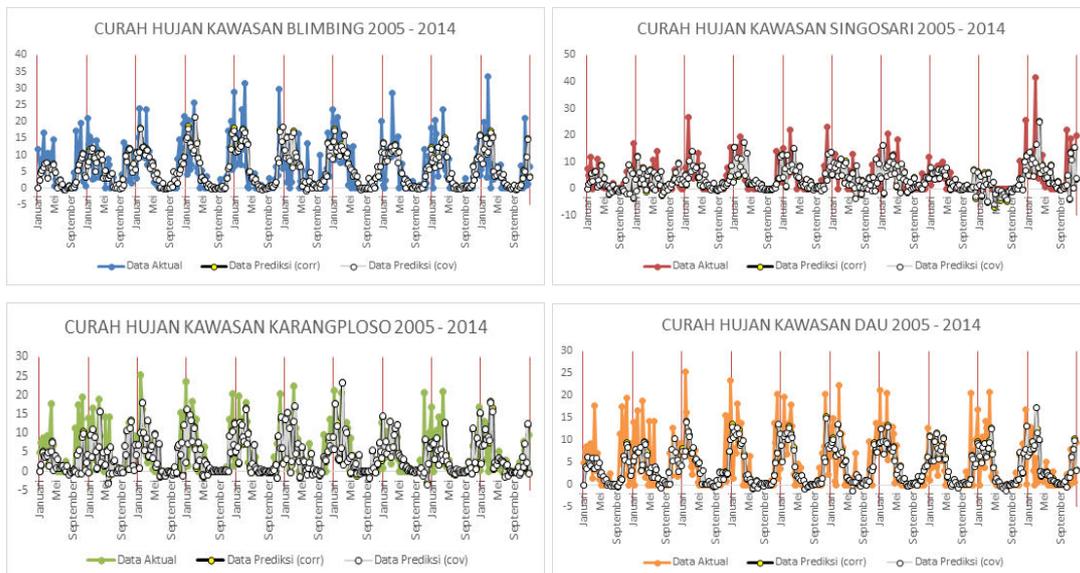
Hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi korelasi silang untuk Kecamatan Wagir adalah sebagai berikut :

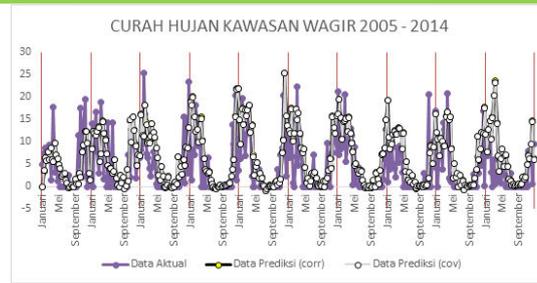
$$\hat{Z}_{5t} = 0.031 Z_{1(t-1)} + 0.009 Z_{2(t-1)} - 0.01 Z_{3(t-1)} + 0.023 Z_{4(t-1)} + 0.243 Z_{5(t-1)} + 0.022 Z_{1(t-2)} + 0.092 Z_{2(t-2)} + 0.092 Z_{3(t-2)} + 0.01 Z_{4(t-2)} + 0.07 Z_{5(t-2)} + 0.072 Z_{1(t-3)} - 0.078 Z_{2(t-3)} + 0.04 Z_{3(t-3)} + 0.024 Z_{4(t-3)} + 0.048 Z_{5(t-3)} - 0.022 Z_{1(t-12)} - 0.059 Z_{2(t-12)} - 0.011 Z_{3(t-12)} + 0.02 Z_{4(t-12)} + 0.047 Z_{5(t-12)} + 0.04 Z_{1(t-36)} + 0.055 Z_{2(t-36)} - 0.102 Z_{3(t-36)} + 0.035 Z_{4(t-36)} + 0.206 Z_{5(t-36)}$$

Sedangkan hasil pendugaan parameter model GSTAR((1),1,2,3,12,36)-SUR dengan bobot lokasi normalisasi *cross covariance* adalah sebagai berikut :

$$\hat{Z}_{5t} = 0.032 Z_{1(t-1)} + 0.003 Z_{2(t-1)} - 0.007 Z_{3(t-1)} + 0.023 Z_{4(t-1)} + 0.252 Z_{5(t-1)} + 0.017 Z_{1(t-2)} + 0.088 Z_{2(t-2)} + 0.089 Z_{3(t-2)} + 0.018 Z_{4(t-2)} + 0.071 Z_{5(t-2)} + 0.072 Z_{1(t-3)} - 0.07 Z_{2(t-3)} + 0.034 Z_{3(t-3)} + 0.026 Z_{4(t-3)} + 0.061 Z_{5(t-3)} - 0.022 Z_{1(t-12)} - 0.051 Z_{2(t-12)} - 0.017 Z_{3(t-12)} + 0.017 Z_{4(t-12)} + 0.042 Z_{5(t-12)} + 0.033 Z_{1(t-36)} + 0.047 Z_{2(t-36)} - 0.093 Z_{3(t-36)} + 0.026 Z_{4(t-36)} + 0.204 Z_{5(t-36)}$$

Berikut plot prediksi data curah hujan di tiap lokasi :





Gambar 1. Curah Hujan Aktual dan Prediksi Model GSTAR((1),1,2,3,12,36)-SUR dengan bobot Cross Correlation dan Cross Covariance

Pemeriksaan ketepatan model GSTAR((1),1,2,3,12,36)-SUR dilakukan dengan menghitung nilai RMSE dan R^2 *prediction* pada model dengan bobot lokasi normalisasi korelasi silang dan *cross covariance*. Semakin rendah nilai RMSE dan semakin tinggi nilai R^2 *prediction*, maka semakin baik pula ketepatan model GSTAR((1),1,2,3,12,36)-SUR dalam menghasilkan nilai ramalan. Berikut pemeriksaan ketepatan model GSTAR((1),1,2,3,12,36)-SUR tersaji dalam Tabel 6:

Tabel 6. Pemeriksaan Ketepatan Model GSTAR((1),1,2,3,12,36)-SUR

Lokasi	Model Bobot Korelasi Silang			Model Bobot <i>Cross Covariance</i>		
	RMSE Data Training	RMSE Data Testing	R^2 <i>prediction</i>	RMSE Data Training	RMSE Data Testing	R^2 <i>prediction</i>
Blimbing			0.579			0.558
Singosari			0.609			0.599
Karangploso	5.796	10.471	0.707	5.779	10.433	0.720
Dau			0.565			0.595
Wagir			0.328			0.336

Berdasarkan hasil pemeriksaan ketepatan model GSTAR((1),1,2,3,12,36)-SUR pada Tabel 6, model GSTAR((1),1,2,3,12,36)-SUR yang menggunakan bobot korelasi silang memiliki nilai RMSE data training sebesar 5.796 dan RMSE pada data testing sebesar 10.471. Sedangkan pada model GSTAR((1),1,2,3,12,36)-SUR yang menggunakan bobot *cross covariance*, model, didapatkan nilai RMSE data training sebesar 5.779 dan RMSE data testing sebesar 10.433. Jika nilai RMSE pada kedua model tersebut dibandingkan, maka nilai RMSE kedua model relatif sama.

Selain dilakukan dengan menghitung nilai RMSE, pemeriksaan ketepatan model juga dilakukan dengan menghitung nilai R^2 *prediction* pada tiap lokasi. Sebagaimana terlihat pada Tabel 6, nilai R^2 *prediction* pada model GSTAR((1),1,2,3,12,36)-SUR yang menggunakan bobot *cross covariance*, lebih tinggi daripada R^2 *prediction* pada model dengan bobot korelasi silang, kecuali di lokasi Kecamatan Blimbing dan Singosari.

SIMPULAN

Model dengan bobot cross covariance menghasilkan tingkat akurasi yang lebih baik ditinjau dari nilai RMSE yang lebih rendah dan nilai R^2 lebih tinggi terutama untuk wilayah Karangploso, Dau, dan Wagir.

DAFTAR RUJUKAN

- Apanasovich, T. V., & Genton, M. G. (2010). Cross-covariance functions for multivariate random fields based on latent dimensions. *Biometrika*, 97(1), 15–30. <https://doi.org/10.1093/biomet/asp078>
- Borovkova, Lopuha, & Ruchjana, B. N. (2002). Generalized S-TAR with Random Weights. In *Proceeding of the 17th International Workshop on Statistical Modeling*. Chania-Greece.
- Efromovich, S., & Smirnova, E. (2013). Statistical Analysis of Large Cross-Covariance and Cross-Correlation Matrices Produced by fMRI Images. *Journal of Biometrics & Biostatistics*, 05(02). <https://doi.org/10.4172/2155-6180.1000193>
- Iriany, A., Firdaus, W. M., Nugroho, W. H., & Sulistyono, A. D. (2016). Rainfall Forecasting Using Gstar-Sur-Nn Approach in West Java Province. In *International Conference on Science, Engineering, Bulit Environment, and Social Science* (p. 1). Bandung.
- Iriany, A., Suhariningsih, Ruchjana, B. N., & Setiawan. (2013). Prediction of Precipitation Data at Batu Town Using the GSTAR (1 , p) -SUR Model. *Journal of Basic and Applied Scientific Research*, 3(6), 860–865.
- Pfeifer, P. E., & Deutsch, S. J. (1980). Identification and interpretation of first order space-time arma models. *Technometrics*. <https://doi.org/10.1080/00401706.1980.10486172>
- Pfeifer, P. E., & Deutsch, S. J. (1981). Seasonal Space-Time ARIMA Modeling. *Geographical Analysis*. <https://doi.org/10.1111/j.1538-4632.1981.tb00720.x>
- Ruchjana, B. N. (2001a). *Pemodelan Kurva Produksi Minyak Bumi Menggunakan Model Generalisasi STAR*. Bogor.
- Ruchjana, B. N. (2001b). Study on the Weight Matrix in the Space-Time Autoregressive Model. In *Proceeding of the Tenth International Symposium on Applied Stochastic Models and Data Analysis (ASMDA)* (pp. 789–794). Compiègne, France.
- Suhartono, & Atok, R. M. (2006). Pemilihan Bobot Lokasi yang Optimal pada Model GSTAR. In *Prosiding Konferensi Nasional Matematika XIII*. Semarang.
- Suhartono, & Subanar. (2006). The Optimal Determination of Space Weight in GSTAR Model by using Cross-correlation Inference. *Journal of Quantitative Methods*, 2(2), 45–53. Retrieved from http://personal.its.ac.id/files/pub/1042-suhartono-statistics-Suhartono_and_Subanar.pdf
- Sulistyono, A. D., Hadi Nugroho, W., & Iriany, A. (2015). Development of Hybrid Model GSTAR-SUR-NN and Aplication for Rainfall Forecasting. In *1st International Conference Pure Applied Resources Univ. Muhammadiyah Malang* (p. 104). Malang.
- Sulistyono, A. D., Nugroho, W. H., Fitriani, R., & Iriany, A. (2016). Hybrid Model GSTAR-SUR-NN For Precipitation Data. *Cauchy*, 4(2), 74. <https://doi.org/10.18860/ca.v4i2.3490>
- Sulistyono, A. D., Nugroho, W. H., & Iriany, A. (2016). Location Weight of GSTAR Model for Heterogeneity Variance of Precipitation Data. In *International Conference on Science, Engineering, Bulit Environment, and Social Science* (p. 6). Bandung.