

PERBANDINGAN ESTIMASI PARAMETER MODEL VAR-GSTAR DENGAN SUR_{FDS} DAN SUR_{MSSD} PADA CURAH HUJAN DI KOTA JAKARTA

Eka Purnama*, Erna Tri Herdiani*, Nurtiti Sunusi*

*Jurusan Matematika Universitas Hasanuddin, Jl. Perintis Kemerdekaan KM. 10 Tamalanrea Makassar
90245, Indonesia

Abstrak. Penelitian ini bertujuan untuk mengestimasi parameter model VAR-GSTAR curah hujan yang ada tiga lokasi di Jakarta yaitu Stasiun Meteorologi Budiarto Curug (Tangerang), Tanjung Priok (Jakarta) dan Observatorium (Jakarta Pusat). Penelitian ini membandingkan hasil estimasi parameter SUR menggunakan metode matriks variansi-kovariansi *Full Data Set* (FDS) dengan metode MSSD. Hasil perhitungan matriks variansi-kovariansi *error* dengan metode MSSD relatif lebih kecil dibandingkan dengan metode FDS. Sedangkan dalam mengukur pengaruh curah hujan antar lokasi metode FDS lebih baik daripada MSSD, hal ini dapat dilihat dari nilai R^2 FDS yang lebih besar dibandingkan MSSD. Namun MSSD dapat menaksir lebih banyak parameter daripada FDS. Nilai MSE (Mean Square Error) yang dihasilkan oleh MSSD juga lebih kecil dibandingkan FDS. Dengan demikian, MSSD dapat menjadi alternatif untuk mengestimasi matriks variansi-kovariansi *error* SUR.

Kata Kunci : VAR-GSTAR, *Seemingly Unrelated Regression*, Matriks Variansi-Kovariansi, *Mean Square Successive Difference*, *Full Data Set*.

I. PENDAHULUAN

Peramalan (forecasting) merupakan ilmu untuk memprediksi kejadian di masa depan dengan menggunakan data atau informasi pada masa lampau ataupun saat ini. Data yang biasa digunakan dalam peramalan adalah data runtun waktu (*time series*), sehingga dikenal model *Autoregressive Integrated Moving Average* (ARIMA). *Vector Autoregressive* (VAR) dan *Vector Autoregressive Moving Average* (VARMA) merupakan perluasan dari *time series* multivariat.

Model dari p -lag *vector autoregressive* (VAR(p)) adalah

$$\mathbf{Z}_t = \boldsymbol{\phi}_0 + \boldsymbol{\Phi}_1 \mathbf{Z}_{t-1} + \cdots + \boldsymbol{\Phi}_p \mathbf{Z}_{t-p} + \boldsymbol{\varepsilon}_t,$$

dimana $\boldsymbol{\phi}_0$ adalah vektor dimensi- k , $\boldsymbol{\Phi}_i$ adalah koefisien matriks berukuran $(n \times n)$ dan $\boldsymbol{\varepsilon}_t$ adalah vektor proses *white noise* berukuran $(n \times 1)$ dengan rata-rata nol (tidak berkorelasi serial) dengan kovariansi matriks $\boldsymbol{\Sigma}$. Model VAR (p) dapat dituliskan dengan operator *backshift*, sebagai berikut

$$(\mathbf{I} - \boldsymbol{\Phi}_1 \mathbf{B} - \cdots - \boldsymbol{\Phi}_p \mathbf{B}^p) \mathbf{Z}_t = \boldsymbol{\phi}_0 + \boldsymbol{\varepsilon}_t,$$

dimana $\mathbf{I}$ adalah matriks identitas.

Perluasan dari data *time series* yang memiliki dependensi terhadap lokasi dan waktu biasa juga dikenal dengan data *space time*, selanjutnya dikenal model *Space Time Autoregressive* (STAR) yang memiliki lebih sedikit parameter dibandingkan model VARMA serta *Space Time Autoregressive Moving Average* (STARMA). Pada model STAR, parameter *autoregressive* pada setiap lokasi diasumsikan sama. Sehingga diperkenalkan model yang lebih fleksibel dan membolehkan adanya perbedaan parameter *autoregressive* yang dikenal dengan *Generalized Space Time Autoregressive* (GSTAR) [2][13]. Model GSTAR ($p, \lambda_1, \dots, \lambda_p$) sebagai proses *space time* $\mathbf{Z}_t$ memenuhi

$$\mathbf{Z}_t = \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \boldsymbol{\Phi}_{kl} \mathbf{W}^{(l)} \mathbf{Z}_{t-k} + \boldsymbol{\varepsilon}_t$$

dimana p adalah orde *autoregressive*, λ_k merupakan orde spasial pada orde *autoregressive* ke- k . $\mathbf{W}^{(l)} = w_{ij}^{(l)}$ berukuran $n \times n$ merupakan matriks bobot spasial untuk orde spasial l yang elemen diagonalnya bernilai nol dan jumlah dari elemen pada tiap baris sama dengan satu. Matriks $\mathbf{W}^{(0)}$ didefinisikan sebagai matriks identitas $\mathbf{I}$. Matriks $\boldsymbol{\Phi}_{kl}$ berukuran $n \times n$ merupakan matriks parameter dari lag temporal k dan lag spasial l dimana elemen-elemen diagonalnya adalah $(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(n)})$. $\boldsymbol{\varepsilon}_t$ adalah vektor error terhadap waktu t yang diasumsikan bebas, normal, memiliki rata-rata nol dan variansi konstan.

Pengkajian lebih mendalam dilakukan terhadap model GSTAR, dengan membahas prosedur membentuk model dengan penentuan bobot lokasi dan estimasi parameter *autoregressive* menggunakan metode *least square* serta sifat-sifatnya, khususnya konsistensi dan normalitas asimptotik [2] [14]. VAR-GSTAR yaitu model VAR dengan representasi model GSTAR, dan diaplikasikan pada runtun waktu multivariat *seasonal* [1]. Model dari VAR-GSTAR yaitu

$$Y = X\beta + \varepsilon,$$

atau dalam bentuk matriks

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_m \end{bmatrix} = \begin{bmatrix} X_1 & 0 & \dots & 0 \\ 0 & X_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & X_m \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_m \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_m \end{bmatrix},$$

dimana

$$1. \quad Y_i = \begin{bmatrix} Z_{i,p+1} \\ Z_{i,p+2} \\ \vdots \\ Z_{i,n} \end{bmatrix}, \quad Y_i \text{ berukuran } (n-p) \times 1$$

dan Y berukuran $m(n-p) \times 1$,

$$2. \quad X_i = \begin{bmatrix} Z_{1,p} & \dots & Z_{a_i,p} & \dots & Z_{1,1} & \dots & Z_{a_i,1} \\ \vdots & \ddots & \vdots & \ddots & \vdots & \ddots & \vdots \\ Z_{1,n-1} & \dots & Z_{a_i,n-1} & \dots & Z_{1,n-p} & \dots & Z_{a_i,n-p} \end{bmatrix},$$

X_i berukuran $(n-p) \times a_i p$ dan X

berukuran $m(n-p) \times \sum_{i=1}^m a_i p$,

$$3. \quad \beta_i = (\phi_{1,1}^{(i)}, \dots, \phi_{1,a_i}^{(i)}, \dots, \phi_{p,1}^{(i)}, \dots, \phi_{p,a_i}^{(i)})',$$

β_i berukuran $a_i p \times 1$ dan β berukuran

$$\sum_{i=1}^m a_i p \times 1,$$

$$4. \quad \varepsilon_i = \begin{bmatrix} \varepsilon_{i,p+1} \\ \varepsilon_{i,p+2} \\ \vdots \\ \varepsilon_{i,n} \end{bmatrix} \text{ berukuran } (n-p) \times 1 \text{ dan } \varepsilon$$

berukuran $m(n-p) \times 1$.

dengan $i = 1, 2, \dots, m$, m adalah banyaknya lokasi pengamatan, n menyatakan banyaknya pengamatan, p merupakan ordo *autoregressive* ($p > 0$), a_i menyatakan banyaknya pengamatan pada lokasi ke i dan distribusi error diasumsikan saling bebas dan berdistribusi identik $\varepsilon \sim N(0, \Omega)$.

Metode lain yang dapat digunakan untuk estimasi yaitu *Seemingly Unrelated*

Regression (SUR). SUR merupakan perluasan dari persamaan regresi yang berbentuk sistem persamaan regresi dimana setiap persamaan nampak tidak berhubungan, namun terjadi korelasi *error* antar persamaan. SUR membolehkan adanya sifat heterokedastik dan korelasi serial antara individu [4] [5]. Misalkan terdapat sebanyak M persamaan

$$Y_{it} = X_{it}\beta_{it} + \varepsilon_{it} \quad i = 1, 2, \dots, M,$$

dimana i adalah banyaknya persamaan dan $t = 1, \dots, T$ adalah indeks pengamatan [15]. Estimasi β menggunakan SUR dapat diperoleh sebagai berikut

$$\hat{\beta}_{SUR} = (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}Y,$$

dimana Ω adalah

$$\Omega = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1M} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{M1} & \sigma_{M2} & \dots & \sigma_{MM} \end{bmatrix} \otimes I$$

$$= \Sigma \otimes I.$$

dimana Σ adalah matriks variansi-kovariansi. Estimator SUR telah digunakan untuk memprediksi curah hujan dengan model GSTAR(1, p) yang mengandung data musiman [8].

Beberapa penelitian menunjukkan bahwa estimasi menggunakan SUR lebih baik dibandingkan Ordinary Least Square (OLS) ketika terjadi korelasi *error* antar persamaan [12]. Estimator SUR juga lebih efisien baik untuk ukuran sampel besar maupun kecil [3], sedangkan untuk data yang berkorelasi residual lemah, estimasi menggunakan OLS masih lebih baik dari pada SUR [9].

Hingga saat ini, metode yang digunakan untuk mengestimasi matriks variansi-kovariansi SUR masih menggunakan matriks variansi-kovariansi *full data set* (FDS). Metode lain yang dapat digunakan untuk mengestimasi matriks variansi-kovariansi adalah *Mean Square Successive Difference* (MSSD) [10]. Pada MSSD, jika terdapat *smooth trend* pada data, variansi yang dihasilkan MSSD lebih kecil daripada *full data set* [7].

Estimator variansi MSSD yang merupakan estimator tak bias adalah

$$q^2 = \frac{1}{2(n-1)} \sum_{i=1}^{n-1} (X_{i+1} - X_i)^2,$$

dimana MSSD didefinisikan sebagai berikut

$$\text{MSSD} = \frac{1}{n-1} \sum_{i=1}^{n-1} (X_{i+1} - X_i)^2,$$

dan elemen-elemen matriks kovariansi MSSD adalah

$$\begin{aligned} \text{cov}(X_j, X_k) \\ = \frac{\sum_{i=2}^n (X_{j,i} - X_{j,i-1})(X_{k,i} - X_{k,i-1})}{2(n-1)}. \end{aligned} \quad [6]$$

II. METODE PENELITIAN

Lokasi dan Rancangan Penelitian



Penelitian ini merupakan penelitian terapan. Penelitian terapan dilakukan pada estimasi curah hujan di kota Jakarta. Data curah hujan diperoleh situs www.ogimet.com [11] pada tiga lokasi yaitu Stasiun Meteorologi Curug, Observatory dan Tanjung Priok. Data yang diperoleh berupa data curah hujan bulanan dari bulan Januari 2007 hingga Desember 2014.

III. ANALISIS DATA



Penelitian diawali dengan mengidentifikasi plot ACF dan PACF. Data dinormalkan dan distasionerkan terlebih dahulu dengan proses transformasi data dan *differencing*. Selanjutnya membuat model VAR-GSTAR dari tiga lokasi. Kemudian menghitung matriks variansi-kovariansi error model menggunakan FDS dan MSSD. Hasil matriks variansi-kovariansi digunakan pada SUR untuk mengestimasi model VAR-GSTAR.

IV. HASIL PENELITIAN


Model curah hujan dari tiga lokasi di Jakarta diawali dengan mengidentifikasi model *time series* univariat melalui plot ACF dan PACF masing masing lokasi sebagai berikut :



(a)



(b)



(c)

Gambar 1 Plot ACF dan PACF (a) Stasiun Meteorologi Curug (b) Observatory (c) Tanjung Priok

Dari diagram PACF diperoleh adanya *cut off* pada lag 1 dan terdapat pola musiman (*seasonal*) sehingga dilakukan *differencing* 1 non-seasonal dan *differencing* 1 *seasonal* 12. Sehingga variabel prediktornya adalah *lag* 1 dan *lag* 12. Dengan demikian dapat dibuat model VAR-GSTAR dari tiga lokasi sebagai berikut :

$$\begin{aligned} Z_{1t} = & \phi_{11}^{(1)} Z_{1(t-1)} + \phi_{12}^{(1)} Z_{1(t-12)} \\ & + \phi_{21}^{(1)} Z_{2(t-1)} \\ & + \phi_{22}^{(1)} Z_{2(t-12)} \\ & + \phi_{31}^{(1)} Z_{3(t-1)} \\ & + \phi_{32}^{(1)} Z_{3(t-12)} \\ & + \phi_{41}^{(1)} Z_{4(t-1)} \\ & + \phi_{42}^{(1)} Z_{4(t-12)} + \varepsilon_{1t} \end{aligned}$$

$$\begin{aligned} Z_{2t} = & \phi_{11}^{(2)} Z_{1(t-1)} + \phi_{12}^{(2)} Z_{1(t-12)} \\ & + \phi_{21}^{(2)} Z_{2(t-1)} \\ & + \phi_{22}^{(2)} Z_{2(t-12)} \\ & + \phi_{31}^{(2)} Z_{3(t-1)} \\ & + \phi_{32}^{(2)} Z_{3(t-12)} \\ & + \phi_{41}^{(2)} Z_{4(t-1)} \\ & + \phi_{42}^{(2)} Z_{4(t-12)} + \varepsilon_{2t} \end{aligned}$$

$$\begin{aligned} Z_{3t} = & \phi_{11}^{(3)} Z_{1(t-1)} + \phi_{12}^{(3)} Z_{1(t-12)} \\ & + \phi_{21}^{(3)} Z_{2(t-1)} \\ & + \phi_{22}^{(3)} Z_{2(t-12)} \\ & + \phi_{31}^{(3)} Z_{3(t-1)} \\ & + \phi_{32}^{(3)} Z_{3(t-12)} + \varepsilon_{3t} \end{aligned}$$

Matriks korelasi *error* dan signifikansi korelasi diberikan dalam Tabel 1 dan Tabel 2 sebagai berikut:

Tabel 1: Korelasi error antar model

Korelasi	Model 1	Model 2	Model 3
Model 1	1	0,335	0,353
Model 2	0,335	1	0,655
Model 3	0,553	0,655	1

Tabel 2

<i>p</i> -value	Model 1	Model 2	Model 3
Model 1		0,004	0,003
Model 2	0,004		0,000
Model 3	0,003	0,000	

Tabel 1 dan 2 menunjukkan adanya korelasi *error* yang kuat antar persamaan dilihat dari nilai *p*-value yang signifikan baik pada taraf signifikansi *p*-value 0,01 maupun *p*-value 0,05. Adanya korelasi *error* ini sesuai dengan asumsi bahwa estimasi SUR digunakan untuk data yang tampak tidak saling berhubungan tapi terdapat korelasi *error* antar persamaan. Dari hasil perhitungan estimasi matriks variansi-kovariansi *error* FDS dan MSSD diperoleh hasil sebagai berikut:

$$\hat{\Sigma}_{FDS} = \begin{bmatrix} 24,382 & 2,308 & 1,538 \\ 2,308 & 1,948 & 0,807 \\ 1,538 & 0,807 & 0,78 \end{bmatrix}$$

$$\hat{\Sigma}_{MSSD} = \begin{bmatrix} 27,892 & 1,338 & 0,958 \\ 1,338 & 1,75 & 0,612 \\ 0,958 & 0,612 & 0,77 \end{bmatrix}$$

Dari hasil perhitungan matriks variansi-kovariansi *error* dengan metode FDS dan MSSD diperoleh bahwa *variansi* *error* model pertama lebih besar jika diestimasi

dengan MSSD. Tapi secara keseluruhan, estimasi dengan MSSD memberikan hasil taksiran variansi-kovariansi yang lebih kecil dibandingkan FDS.

Perbandingan antara parameter SUR_{FDS} dan SUR_{MSSD} ditunjukkan pada Tabel 3 berikut:

Tabel 3. Hasil Perbandingan Estimasi Parameter SUR_{FDS} dan SUR_{MSSD} .

Parameter	SUR	
	FDS	MSSD
Konstanta 1	-0.03198	-0.03404
$\phi_{11}^{(1)}$	-0.43278	-0.43247
$\phi_{12}^{(1)}$	-0.39938	-0.40881
$\phi_{21}^{(1)}$	-0.08572	-0.11928
$\phi_{22}^{(1)}$	-0.24129	-0.27687
$\phi_{31}^{(1)}$	-0.19428	-0.23085
$\phi_{32}^{(1)}$	-0.0194	-0.0086
$\phi_{41}^{(1)}$	0.169591	0.22515
$\phi_{42}^{(1)}$	1.211013	1.334476
Konstanta 2	-0.03779	-0.03847
$\phi_{11}^{(2)}$	0.024977	0.025078
$\phi_{12}^{(2)}$	0.063348	0.060249
$\phi_{21}^{(2)}$	-0.11167	-0.1227
$\phi_{22}^{(2)}$	-0.39045	-0.40215
$\phi_{31}^{(2)}$	-0.08385	-0.09587
$\phi_{32}^{(2)}$	0.182797	0.186344
$\phi_{41}^{(2)}$	-0.20477	-0.18651
$\phi_{42}^{(2)}$	-0.3413	-0.30073
Konstanta 3	-0.01463	-0.01463
$\phi_{11}^{(3)}$	0.043541	0.043541
$\phi_{12}^{(3)}$	0.012306	0.012306
$\phi_{21}^{(3)}$	-0.06206	-0.06206
$\phi_{22}^{(3)}$	0.024033	0.024033
$\phi_{31}^{(3)}$	-0.36819	-0.36819
$\phi_{32}^{(3)}$	-0.28859	-0.28859

Hasil uji signifikansi parameter secara parsial disajikan pada Tabel 4 sebagai berikut :

Tabel 4. Perbandingan uji signifikansi estimator SUR_{FDS} dan SUR_{MSSD} .

Parameter	t-hitung	p-value	t-hitung	p-value
-----------	----------	---------	----------	---------

	SUR FDS		SUR MSSD	
$\phi_{11}^{(1)}$	-5.2424	0.000 1	5.2020 5	0.000 1
$\phi_{12}^{(1)}$	- 4.30412	0.000 1	- 4.3749 9	0.000 1
$\phi_{21}^{(1)}$	- 0.20401	0.839	- 0.2818 8	0.779
$\phi_{22}^{(1)}$	- 0.56336	0.575 2	- 0.6419 3	0.523 3
$\phi_{31}^{(1)}$	- 0.31826	0.751 4	- 0.3755 4	0.708 5
$\phi_{32}^{(1)}$	- 0.03075	0.975 6	- 0.0135 5	0.989 2
$\phi_{41}^{(1)}$	0.28174 4	0.779 1	0.3714 31	0.711 6
$\phi_{42}^{(1)}$	1.96870 3	0.053 5	2.1542 56	0.035 1
$\phi_{11}^{(2)}$	1.40423 3	0.165 2	1.4315 98	0.157 3
$\phi_{12}^{(2)}$	3.16868	0.002 4	3.0599 33	0.003 3
$\phi_{21}^{(2)}$	- 1.23348	0.222 1	- 1.3760 8	0.173 7
$\phi_{22}^{(2)}$	- 4.23118	< 0.000 1	- 4.4248	< 0.000 1
$\phi_{31}^{(2)}$	- 0.63758	0.526 1	- 0.7401 5	0.462
$\phi_{32}^{(2)}$	1.34507 6	0.183 5	1.3922 27	0.168 8
$\phi_{41}^{(2)}$	- 1.57892	0.119 4	- 1.4602 3	0.149 3
$\phi_{42}^{(2)}$	- 2.57516	0.012 4	- 2.3039	0.024 6
$\phi_{11}^{(3)}$	3.47633 4	0.000 9	3.4763 34	0.000 9
$\phi_{12}^{(3)}$	0.97738 6	0.332 1	0.9773 86	0.332 1
$\phi_{21}^{(3)}$	- 1.06168	0.292 4	- 1.0616 8	0.292 4
$\phi_{22}^{(3)}$	0.39610 5	0.693 3	0.3961 05	0.693 3
$\phi_{31}^{(3)}$	- 4.11462	0.000 1	- 4.1146 2	0.000 1
$\phi_{32}^{(3)}$	-3.0969	0.002	-	0.002

		9	3.0969	9
--	--	---	--------	---

Berdasarkan Tabel 4, dapat dibuat persamaan regresi untuk parameter yang signifikan. Estimasi SUR menggunakan matriks variansi-kovariansi FDS diperoleh persamaan berikut:

$$Z_{1t} = -0.43278 Z_{1(t-1)} + -0.39938 Z_{1(t-12)} + \varepsilon_{1t},$$

$$Z_{2t} = 0.063348 Z_{1(t-12)} + 0.182797 Z_{2(t-12)} + -0.3413 Z_{4(t-12)} + \varepsilon_{2t},$$

$$Z_{3t} = 0.043541 Z_{1(t-1)} + -0.36819 Z_{3(t-1)} + -0.28859 Z_{3(t-12)} + \varepsilon_{3t}.$$

Estimasi SUR menggunakan matriks variansi-kovariansi MSSD diperoleh persamaan sebagai berikut :

$$Z_{1t} = -0.43247 Z_{1(t-1)} + -0.40881 Z_{1(t-12)} + 1.334476 Z_{4(t-12)} + \varepsilon_{1t}.$$

$$Z_{2t} = 0.060249 Z_{1(t-12)} + -0.40215 Z_{2(t-12)} + -0.30073 Z_{4(t-12)} + \varepsilon_{2t}.$$

$$Z_{3t} = 0.043541 Z_{1(t-1)} + -0.36819 Z_{3(t-1)} + -0.28859 Z_{3(t-12)} + \varepsilon_{3t}.$$

Perbandingan hasil uji kebaikan model hasil taksiran β^{SUR} FDS dan β^{SUR} MSSD ditunjukkan pada Tabel 4 sebagai berikut:

Tabel 4. Perbandingan uji kebaikan Model estimasi SUR_{FDS} dan SUR_{MSSD} .

	Model SUR	1	2	3
SS_{res}	FDS	1844.376	150.0061	56.11763
	MSSD	1731.005	150.2324	56.11763
SS_{reg}	FDS	1202.181	46.96794	22.93709
	MSSD	1082.315	45.68393	22.93709
SS_{tot}	FDS	2823.042	180.637	80.69668
	MSSD	2823.042	180.637	80.69668
R^2	FDS	0.425846	0.260013	0.284238
	MSSD	0.383386	0.252905	0.284238
$Adj R^2$	FDS	0.400516	0.215835	0.241506
	MSSD	0.346573	0.208302	0.241506

MSE	FDS	17.17401	0.680695	0.332422
	MSSE	15.68572	0.662086	0.332422
RMSE	FDS	4.144154	0.825042	0.57656
	MSSD	3.96052	0.813687	0.57656

Dari studi kasus yang dilakukan pada curah hujan di Jakarta menunjukkan bahwa hasil uji kebaikan model taksiran SUR dengan matriks variansi-kovariansi FDS dan MSSD diperoleh R^2 yang cukup kecil. R^2 yang diperoleh dengan metode FDS lebih besar dibandingkan R^2 yang diperoleh dengan metode MSSD. Dengan demikian, metode FDS lebih baik digunakan dibandingkan MSSD dalam mengukur pengaruh parameter dalam model.

Nilai MSE yang diperoleh pada tabel Tabel 4 menunjukkan bahwa metode SUR yang menggunakan matriks variansi-kovariansi MSSE lebih baik dibandingkan FDS. Nilai MSE dengan metode MSSD lebih kecil daripada menggunakan metode FDS pada model pertama dan kedua. Sedangkan pada model ketiga menghasilkan nilai MSE yang sama, karena hasil taksiran parameter pada model ketiga juga menghasilkan parameter yang sama. Hasil uji kebaikan model dengan metode MSSD menghasilkan nilai yang tidak jauh berbeda dengan FDS. Dengan demikian MSSD dapat dijadikan alternatif dalam mengestimasi parameter SUR.

V. KESIMPULAN DAN SARAN

Hasil penelitian menunjukkan MSSD mampu menaksir lebih banyak parameter dibandingkan dengan metode FDS, dan nilai MSE yang dihasilkan MSSD relatif lebih kecil dibandingkan FDS. Namun dalam mengukur pengaruh parameter terhadap model, metode FDS menghasilkan koefisien determinasi yang lebih besar dibandingkan MSSD. Hasil uji kebaikan model antara FDS dan MSSD tidak jauh berbeda, sehingga MSSD dapat dijadikan sebagai alternatif untuk mengestimasi matriks variansi-kovariansi *error* pada SUR.

Penelitian ini dilakukan dengan mengambil studi kasus pada data yang memiliki *trend* musiman (*seasonal*). Penelitian selanjutnya dapat dilakukan pada penelitian non-musiman untuk melihat bagaimana pengaruh *trend* terhadap estimasi matriks variansi-kovariansi MSSD pada SUR.

UCAPAN TERIMA KASIH

Penulis menyampaikan terimakasih kepada Komisi Penasehat Dr. Erna Tri Herdiani, M. Si dan Dr. Nurtiti Sunusi, M. Si yang telah memberikan pengarahan dan bimbingan dalam menyelesaikan jurnal ilmiah ini, serta kepada semua pihak yang telah memberikan bantuan dan fasilitas dalam penulisan jurnal ilmiah ini.

DAFTAR PUSTAKA

1. Dhoriva U. W., dan Suhartono. 2010. Peramalan Deret Waktu Multivariate Seasonal pada Data Pariwisata Dengan Model VAR-GSTAR. *Jurnal Ilmu Dasar*. 11:933-949.
2. Dhoriva U. W., Suhartono, dan Brodjol S. 2010. Generalized Space-Time Autoregressive Modeling. *Proceeding of the 6th IMT-GT Conference on Mathematics, Statistics and its Applications (ICMSA2010)*. 752-761.
3. Ebukuyo, O. B., Adepoju, A. A., dan Olamide, E. I. 2013 Bootstrap Approach for Estimating Seemingly Unrelated Regression with Varying Degrees of Autocorelated Disturbances. *Applied Mathematics*. 5: 55-63.
4. Greene, William H. 2002. *Econometric Analysis: Fifth Edition*. New Jersey: Pearson Education, Inc.
5. Gujarati. 2004. *Basic Econometrics, Forth Edition*. The McGraw-Hill Companies.
6. Holmes, Donald, and Mergen, A. Erhan. 1998. A Multivariate Test for Randomness. *Quality Engineering*. 10: 505-508.
7. _____. 2005. Integrating Several Variance Estimators. *RIT Scholar Works*.
8. Iriany, Atiek dkk. Prediction of Precipitation Data at Batu Town Using the GSTAR (1, p)- SUR Model. 2013. *Journal of Basic and Applied Scientific Research*. 3(6): 860-865.
9. Nawawi, Fachrul. 2014. Estimasi Parameter Model Vector Autoregressive – Generalized Space Time Autoregressive dengan Metode Seemingly Unreated Regression. Tesis Program Pasca Sarjana Universitas Hasanuddin. *Tidak dipublikasikan*.
10. Neumann, J. Von., dkk. 1941. The Mean Square Successive Difference. *The Annals of Mathematical Statistics*. Volume 12 : 153-162.
11. Ogimet. 2015. <http://ogimet.com/gsynres.phtml.en>. Data diakses pada 14 April 2015.
12. Olamide, E. I., dan Adepoju, A. A. 2013. Estimating Seemingly Unrelated Regressions with First Order Autoregressive Disturbances. *Studies in Mathematical Science*. 6: 40-57.
13. Ruchjana, B. N. 2002. Pemodelan Kurva Produksi Minyak Bumi menggunakan Model Generalisasi S-TAR. *Forum Statistika dan Komputasi*. 01-06.
14. Ruchjana, B. N., Borokova, S. A. dan Lopusha, H. P. 2012. Least Square Estimation of Generalized Space Time Autoregressive (GSTAR) Model and Its Properties. *AIP Conference Proceedings*. 1450:61-64.
15. Zellner, A. 1962. An Efficient Method of Estimating Seemingly Unrelatad Regression and Test for Aggregation Bias. *Journal of the American Statistical Association*. 57: 348-368.