

PENGEMBANGAN MODEL GSTAR-SUR DENGAN PENDEKATAN NEURAL NETWORK PADA RESIDUAL

Agus Dwi Sulistyono¹, Atiek Iriany², Diana Rosyida²

¹ Program Studi Agribisnis Perikanan, Fakultas Perikanan dan Ilmu Kelautan, Universitas Brawijaya, Malang

² Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Brawijaya Malang

Email: agus.dwi.sulistyono@gmail.com

Abstrak

Model GSTAR merupakan suatu model space time yang stasioner. Salah satu data yang memiliki fenomena space time adalah curah hujan. Curah hujan pada saat sekarang sulit untuk diprediksi karena memiliki pola dan karakteristik yang sulit untuk diidentifikasi. Fenomena ini merupakan fenomena non linier. Adapun model yang mempertimbangkan unsur non linier adalah neural network. Pendugaan parameter model GSTAR yang akan digunakan adalah pendekatan model Seemingly Unrelated Regression (SUR). Metode ini mampu mengatasi adanya korelasi antar sisaan melalui matriks ragam peragam sisaan dalam model. Penelitian ini akan membandingkan hasil ramalan curah hujan menggunakan model GSTAR-SUR dan model GSTAR-SUR dengan pendekatan neural network pada residual. Data yang digunakan dalam penelitian ini adalah data curah hujan di empat daerah Jawa Barat, yaitu Cisondari, Chincona, Cibuni, dan Lembang, mulai tahun 2005 sampai 2018. Data curah hujan ini merupakan data 10 harian. Pada kasus ini model GSTAR-SUR-NN menghasilkan hasil ramal yang lebih mendekati nilai aktual dari pada model GSTAR-SUR.

Kata Kunci:

GSTAR-SUR
neural network
curah hujan

PENDAHULUAN

Model ruang waktu pertama kali diperkenalkan oleh Pfeifer dan Deutsch (Pfeifer & Deutsch, 1980). Model tersebut dikenal dengan istilah model space time autoregressive (STAR). Model STAR berkembang menjadi model GSTAR yang diperkenalkan oleh Ruchjana (Ruchjana, 2002). Model GSTAR merupakan suatu model space time yang stasioner.

Metode pendugaan parameter dalam model ruang waktu adalah Ordinary Least Square (OLS). Pada metode OLS didapat residual model space time yang saling berkorelasi sehingga menghasilkan nilai duga yang tidak efisien (Iriany, Suhariningsih, Ruchjana, & Setiawan, 2013). Metode lain yang dapat digunakan untuk menduga parameter model space time adalah pendekatan model Seemingly Unrelated Regression (SUR). SUR menggunakan metode Generalized Least Square (GLS) untuk menduga parameter model. Metode ini mampu mengatasi adanya korelasi antar sisaan melalui matriks ragam peragam sisaan dalam model (Setiawan, Suhartono, & Prastuti, 2016).

Salah satu data yang memiliki fenomena space time adalah curah hujan. Curah hujan pada saat sekarang sulit untuk diprediksi karena memiliki pola dan karakteristik yang sulit

Diterima:

XX Agustus 2019

Dipresentasikan:

21 September 2019

Disetujui Terbit:

5 Oktober 2019

untuk diidentifikasi. Fenomena ini merupakan fenomena non linier. Adapun model yang mempertimbangkan unsur non linier adalah neural network (Suhartono, Ulama, & Endharta, 2010). Beberapa penelitian yang menerapkan model deret waktu non linier khususnya neural network adalah Sulistyono, et al (Sulistyono, Nugroho, Fitriani, & Iriani, 2016), (Sulistyono, Hadi Nugroho, & Iriany, 2015), Vlahogianni dan Karlaftis (Vlahogianni & Karlaftis, 2013), Caudill (Caudill, 1990), Suhartono (Suhartono, 2007). Penelitian ini akan membandingkan hasil ramalan curah hujan menggunakan model GSTAR-SUR dan model GSTAR-SUR-NN dengan harapan dapat diperoleh hasil ramalan yang lebih akurat.

METODE

Data yang digunakan dalam penelitian ini adalah data curah hujan di empat daerah Jawa Barat, yaitu Cisondari, Chincona, Cibuni, dan Lembang. Periode data curah hujan mulai tahun 2005 sampai 2018. Data curah hujan ini merupakan data 10 harian.

Adapun konsep dalam penelitian ini adalah membentuk model GSTAR-SUR dan model GSTAR-SUR-NN, kemudian membandingkan hasil ramalan dari kedua model tersebut berdasarkan nilai RMSE dan nilai MAD. Bobot lokasi yang digunakan dalam pemodelan GSTAR adalah bobot korelasi silang. Bobot lokasi ini pertama kali diperkenalkan oleh Suhartono dan Atok (Suhartono & Atok, 2006). Bobot lokasi korelasi silang menggunakan hasil normalisasi korelasi silang pada lag yang bersesuaian (Suhartono & Subanar, 2006). Perhitungan bobot normalisasi korelasi silang adalah $W_{ij} = \frac{r_{ij}(s)}{\sum_{k \neq s} |r_{ik}(s)|}$ dengan $i \neq j$ dan bobot ini memenuhi $\sum_{i \neq j} W_{ij} = 1$.

Pendugaan parameter yang digunakan adalah *Seemingly Unrelated Regression* (SUR). SUR merupakan suatu persamaan yang pendugaan parameternya menggunakan *Generalized Least Square* (GLS) (Setiawan, 1992). Model SUR dengan M persamaan dinyatakan dengan

$$\mathbf{Y}_i = \mathbf{X}_i \boldsymbol{\beta}_i + \boldsymbol{\varepsilon}_i, \quad i = 1, \dots, m \quad (1)$$

Menurut Greene (Apriliyah, Mahmudi, & Widodo, 2008), persamaan (1) merupakan model SUR dengan asumsi $E[\mathbf{e}|\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m] = 0$ dan $E[\boldsymbol{\varepsilon}' \boldsymbol{\varepsilon} | \mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_m] = \boldsymbol{\Omega}$ dengan $\boldsymbol{\Omega}$ adalah matriks ragam peragam. Matriks $\boldsymbol{\Omega}$ menggambarkan hubungan galat dengan

$$\boldsymbol{\Omega} = \begin{bmatrix} \sigma_{11} \mathbf{I}_{mT} & \sigma_{12} \mathbf{I}_{mT} & \dots & \sigma_{1m} \mathbf{I}_{mT} \\ \sigma_{21} \mathbf{I}_{mT} & \sigma_{22} \mathbf{I}_{mT} & \dots & \sigma_{2m} \mathbf{I}_{mT} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{m1} \mathbf{I}_{mT} & \sigma_{m2} \mathbf{I}_{mT} & \dots & \sigma_{mm} \mathbf{I}_{mT} \end{bmatrix} = \boldsymbol{\Sigma} \otimes \mathbf{I}_{mT} \quad (2)$$

dengan \mathbf{I}_{mT} merupakan matriks identitas berukuran $(mT \times mT)$ dan $\boldsymbol{\Sigma}$ merupakan matriks yang berukuran $(m \times m)$ dengan σ_{ij} adalah ragam galat dari masing-masing persamaan untuk $i = j$ dan kovarian galat antar persamaan $i \neq j$. Pendugaan parameter model diperoleh dengan menduga parameter $\boldsymbol{\beta}$ dalam persamaan (3)

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}' \boldsymbol{\Omega}^{-1} \mathbf{X})^{-1} \mathbf{X}' \boldsymbol{\Omega}^{-1} \mathbf{Y} \quad (3)$$

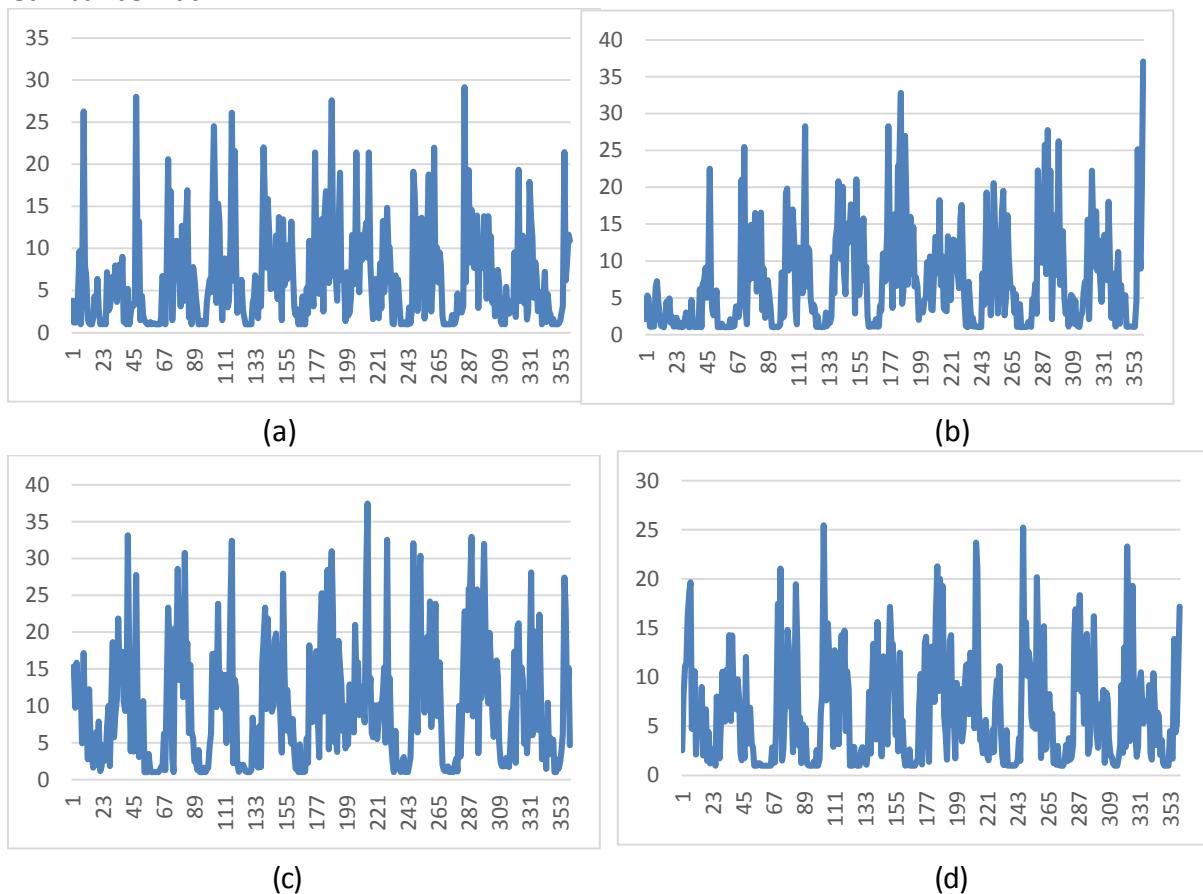
Pada penelitian ini, model neural network akan diterapkan pada sisaan model GSTAR-SUR. Terdapat 3 komponen dalam model neural network, yaitu input layer, hidden layer, dan output layer. Input layer yang digunakan adalah sisaan model GSTAR-SUR. Hidden layer yang digunakan sebanyak 1 layer tetapi jumlah neuron yang digunakan dalam hidden layer berdasarkan nilai RMSE terkecil. Output layer yang digunakan sebanyak 4 variabel. Algoritma yang digunakan adalah algoritma resilient backpropagation. Algoritma ini pernah diterapkan

oleh Apriliyah, et al (Apriliyah et al., 2008) dan Fadil, et al (Fadil, Penangsang, & Soeprijanto, 2009) dalam memperkirakan penjualan beban listrik.

HASIL DAN PEMBAHASAN

Identifikasi Data

Gambaran secara umum dari data yang akan dianalisis lebih lanjut dapat dilihat dari Gambar berikut



Gambar 1. Plot Data Tiap Lokasi

Gambar 1.a merupakan plot data curah hujan daerah Cisondari, Gambar 1.b merupakan plot data curah hujan daerah Chincona, Gambar 1.c merupakan plot data curah hujan daerah Cibuni, dan Gambar 1.d merupakan plot data curah hujan daerah Lembang. Pada Gambar 1 terlihat bahwa pola data curah hujan di daerah Cisondari, Chincona, Cibuni, dan Lembang memiliki pola data acak horizontal. Besar kecilnya curah hujan di empat daerah tersebut dari waktu ke waktu sulit untuk diprediksi karena kenaikan curah hujan tidak terjadi pada selang waktu yang sama untuk setiap daerah. Selain itu, kuantitas curah hujan di empat daerah tersebut juga sama. Namun pada keempat daerah tersebut pernah terjadi kenaikan curah hujan secara bersama, yakni pada pengamatan ke 47, 72, 188, dan 214.

Berdasarkan plot data pada Gambar 1 terlihat jelas bahwa data tidak stasioner terhadap ragam sehingga perlu dilakukan transformasi Box-Cox. Data dikatakan stasioneritas terhadap ragam apabila nilai lambda (λ) sama dengan 1.

Hasil transformasi berdasarkan Tabel 1 menghasilkan data yang sudah stasioner terhadap ragam. Data yang telah stasioner terhadap ragam akan dilakukan uji *Dickey-Fuller* untuk mengetahui apakah data tersebut sudah stasioner terhadap rata-rata. Hasil uji Dickey Fuller menunjukkan bahwa data yang sudah stasioner terhadap ragam juga sudah stasioner terhadap rata-rata, sehingga tidak perlu dilakukan differencing.

Tabel 1. Transformasi Box-Cox

Lokasi	Transformasi
Cisondari	$(Z_{1t} + 1)^{-0.16}$
Chincona	$(Z_{2t} + 1)^{-0.14}$
Cibuni	$\ln(Z_{3t} + 1) + 1$
Lembang	$[\ln(Z_{4t} + 1) + 1]^{0.25}$

Model GSTAR-SUR

Ordo spasial yang digunakan dalam penelitian ini adalah ordo 1, sedangkan ordo autoregressive dan ordo moving average ditentukan berdasarkan skema MPACF dan MACF.

Variable/Lag	Schematic Representation of Partial Cross Correlations														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
cisondari	++...	+....	...-	-.+.	...-.
cinchona	++...	.+..+.+.
cibuni	.-++	...+	++..
lembang	...++

+ is $> 2^{\text{std error}}$, - is $< -2^{\text{std error}}$, . is between

(a)

Variable/Lag	Schematic Representation of Cross Correlations															
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
cisondari	++++	++++	+++	+++	+++	+++	+++	-..+	-..+	-..+	-..+
cinchona	++++	+++	+++	+++	+++	+++	+++	++..
cibuni	---++	---++	---++	---++	---++	---++	---++	---++
lembang	---++	---++	---++	---++	---++	---++	---++	...+.

+ is $> 2^{\text{std error}}$, - is $< -2^{\text{std error}}$, . is between

(b)

Gambar 2. Skema MPACF dan MACF

Gambar 2.a merupakan skema MPACF yang menunjukkan ordo autoregressive dan Gambar 2.b merupakan skema MACF yang menunjukkan ordo moving average. Skema MPACF menunjukkan bahwa semua lokasi signifikan pada lag pertama sehingga ordo autoregressive yaitu satu, sedangkan skema MACF memiliki pola gelombang sinus sehingga ordo moving average adalah 0 (Wei, 2006). Ordo model GSTAR yang akan digunakan adalah adalah GSTAR (1₁). Adapun persamaan matematis model GSTAR (1₁) adalah

$$Z_t = \Phi_{10} Z_{t-1} + \Phi_{11} W^{(1)} Z_{t-1} + \varepsilon_t \quad (4)$$

Estimasi parameter model GSTAR (1₁) menggunakan pendekatan model SUR. Pada penelitian ini, parameter yang tidak signifikan tidak dihilangkan dengan tujuan agar pengaruh pembootan dari masing-masing lokasi tetap ada dan adanya perbedaan signifikansi parameter terjadi karena pemodelan dilakukan secara multivariat. Konstenko dan Hyndman (Kostenko & Hyndman, 2008) menyatakan bahwa variabel yang tidak signifikan tetap dapat digunakan untuk melakukan peramalan. Adapun model GSTAR-SUR (1₁) yang terbentuk masing-masing lokasi adalah:

1. Cisondari

$$\hat{Z}_{1t} = 0.8589 Z_{1,t-1} + 0.0234 Z_{2,t-1} + 0.0223 Z_{3,t-1} + 0.0218 Z_{4,t-1} \quad (5)$$

2. Chincona

$$\hat{Z}_{2t} = 0.8860 Z_{2,t-1} + 0.0193 Z_{1,t-1} + 0.0184 Z_{3,t-1} + 0.0172 Z_{4,t-1} \quad (6)$$

3. Cibuni

$$\hat{Z}_{3t} = 0.6879 Z_{3,t-1} + 0.2877 Z_{1,t-1} + 0.2962 Z_{2,t-1} + 0.3353 Z_{4,t-1} \quad (7)$$

4. Lembang

$$\hat{Z}_{4t} = 0.9458 Z_{4,t-1} + 0.0122 Z_{1,t-1} + 0.0125 Z_{2,t-1} + 0.0146 Z_{3,t-1} \quad (8)$$

Model GSTAR-SUR-NN

Sisaan model GSTAR-SUR (1₁) akan dilakukan pemodelan neural network sehingga persamaan matematis model hybrid GSTAR-SUR-NN adalah

$$Z_t = Z_{t,GSTAR} + Z_{t,NN} + e_t \quad (9)$$

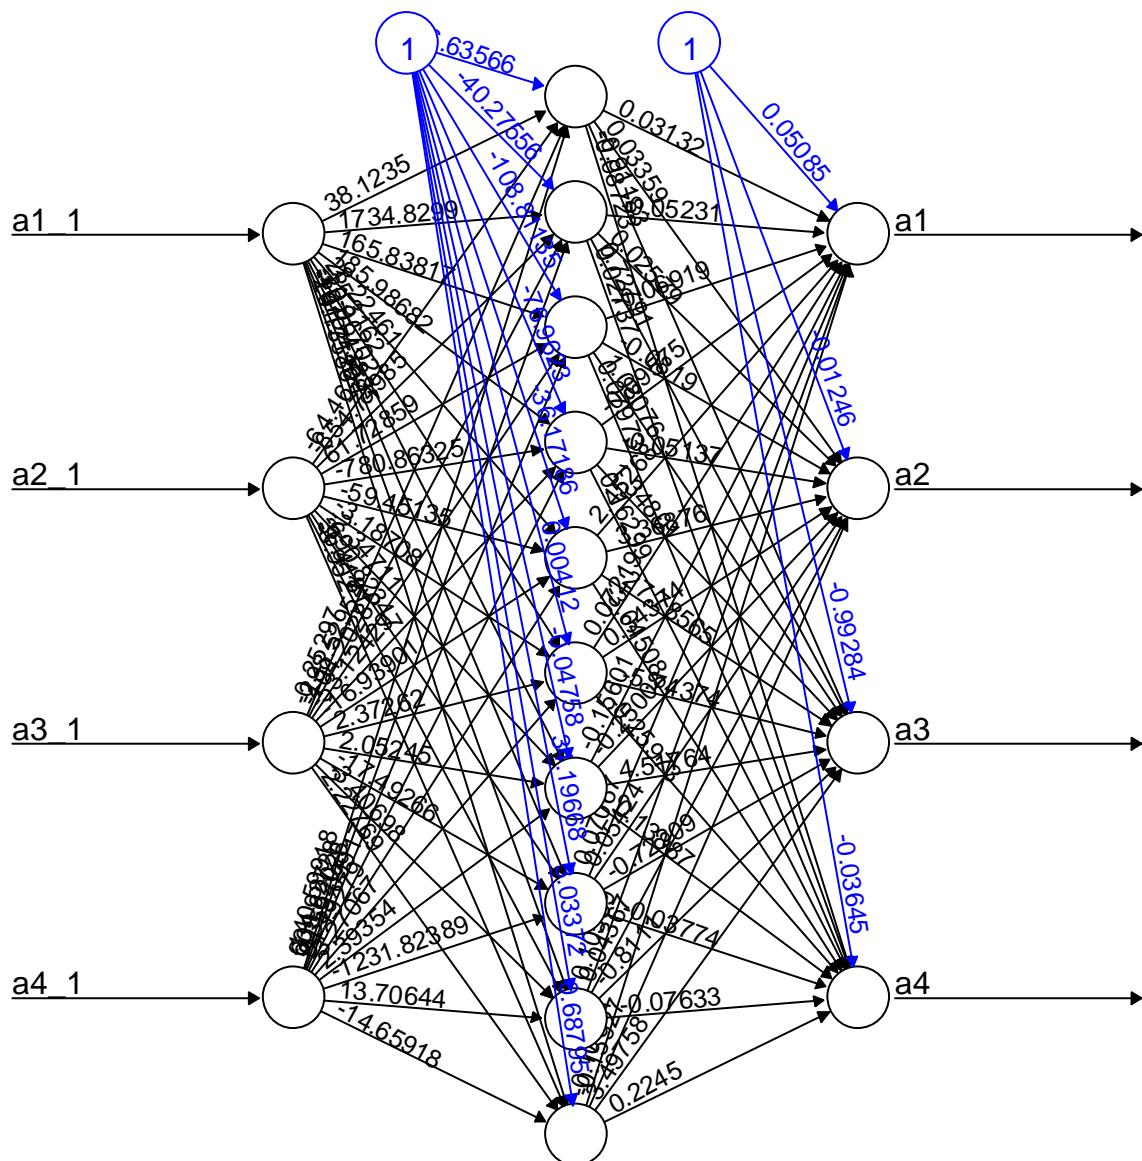
Pemodelan neural network untuk analisis data curah hujan di daerah Cisondari, Chincona, Cibuni, dan Lembang menggunakan 4 input berdasarkan residual yang didapat dari model GSTAR-SUR (1₁). Variable-variabel input tersebut adalah $a_{1,t-1}$, $a_{2,t-1}$, $a_{3,t-1}$, dan $a_{4,t-1}$. Suhartono dan Endharta (Suhartono & Endharta, 2011) pernah menggunakan sisaan model deret waktu sebagai input layer pada pemodelan neural network. Adapun variabel pada output layer sejumlah variabel yang digunakan dalam pemodelan GSTAR-SUR (1₁) yakni sebanyak 4 variabel. Adapun hidden layer yang digunakan sebanyak 1 dengan jumlah neuron didalamnya dibatasi 1 sampai 10 neuron. Pemilihan arsitektur terbaik dilakukan dengan melihat nilai RMSE terkecil dari hasil peramalan.

Tabel 2. Nilai RMSE pada Sejumlah Neuron dalam Hidden Layer

Jumlah Neuron dalam Hidden Layer	Nilai RMSE	Jumlah Neuron dalam Hidden Layer	Nilai RMSE
1	0.3866	6	0.3410
2	0.3788	7	0.3411
3	0.3706	8	0.3391
4	0.3715	9	0.3413
5	0.3679	10	0.3070

Nilai RMSE terkecil terjadi ketika jumlah neuron dalam hidden layer sebanyak 10. Sehingga dapat disimpulkan bahwa arsitektur terbaik pada pemodelan neural network adalah

NN (4,10,4). Adapun arsitektur terbaik neural network residual model GSTAR-SUR (1₁). ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur Terbaik Neural Network Residual Model GSTAR-SUR (1₁)

Adapun persamaan matematis dari model GSTAR-SUR-NN pada masing-masing lokasi adalah

1. Cisondari

$$\hat{Z}_{1t} = Z_{1t,GSTAR} + Z_{1t,NN}$$

$Z_{1t,GSTAR}$ sesuai dengan persamaan (5)

$$\begin{aligned} Z_{1t,NN} = & 0.0508 + 0.0313 f(h_1) - 0.0523 f(h_2) - 0.0692 f(h_3) - 0.0958 f(h_4) \\ & + 2.4523 f(h_5) + 0.0722 f(h_6) - 0.1560 f(h_7) + 0.0707 f(h_8) \\ & + 0.0159 f(h_9) - 0.1036 f(h_{10}) \end{aligned} \quad (10)$$

2. Chincona

$$\hat{Z}_{2t} = Z_{2t,GSTAR} + Z_{2t,NN}$$

$Z_{2t,GSTARIMA}$ sesuai dengan persamaan (6)

$$\begin{aligned} Z_{2t,NN} = & -0.0125 + 0.0336 f(h_1) + 0.0258 f(h_2) - 0.0819 f(h_3) \\ & - 0.0514 f(h_4) + 3.3688 f(h_5) + 0.3437 f(h_6) - 0.2501 f(h_7) \\ & + 0.0542 f(h_8) + 0.04379 f(h_9) - 0.159 f(h_{10}) \end{aligned} \quad (11)$$

3. Cibuni

$$\hat{Z}_{3t} = Z_{3t,GSTAR} + Z_{3t,NN}$$

$Z_{3t,GSTAR}$ sesuai dengan persamaan (7)

$$\begin{aligned} Z_{3t,NN} = & -0.9928 - 0.91183 f(h_1) + 0.7279 f(h_2) + 1.0808 f(h_3) \\ & + 1.3480 f(h_4) - 27.7856 f(h_5) - 5.7437 f(h_6) + 4.5176 f(h_7) \\ & - 0.7221 f(h_8) - 0.8111 f(h_9) + 3.4976 f(h_{10}) \end{aligned} \quad (12)$$

4. Lembang

$$\hat{Z}_{4t} = Z_{4t,GSTAR} + Z_{4t,NN}$$

$Z_{4t,GSTAR}$ sesuai dengan persamaan (8)

$$\begin{aligned} Z_{4t,NN} = & -0.0364 - 0.0872 f(h_1) + 0.0274 f(h_2) + 0.0797 f(h_3) \\ & + 0.1630 f(h_4) - 3.0451 f(h_5) - 0.2597 f(h_6) + 0.1389 f(h_7) \\ & - 0.0377 f(h_8) - 0.0763 f(h_9) + 0.2245 f(h_{10}) \end{aligned} \quad (13)$$

Adapun $f(h_i)$ adalah fungsi aktivasi logistic sigmoid pada hidden unit yang didefinisikan sebagai berikut

$$f(h_i) = \frac{1}{1 + e^{-(h_i)}} , \quad i = 1, 2, \dots, 10 \quad (14)$$

di mana,

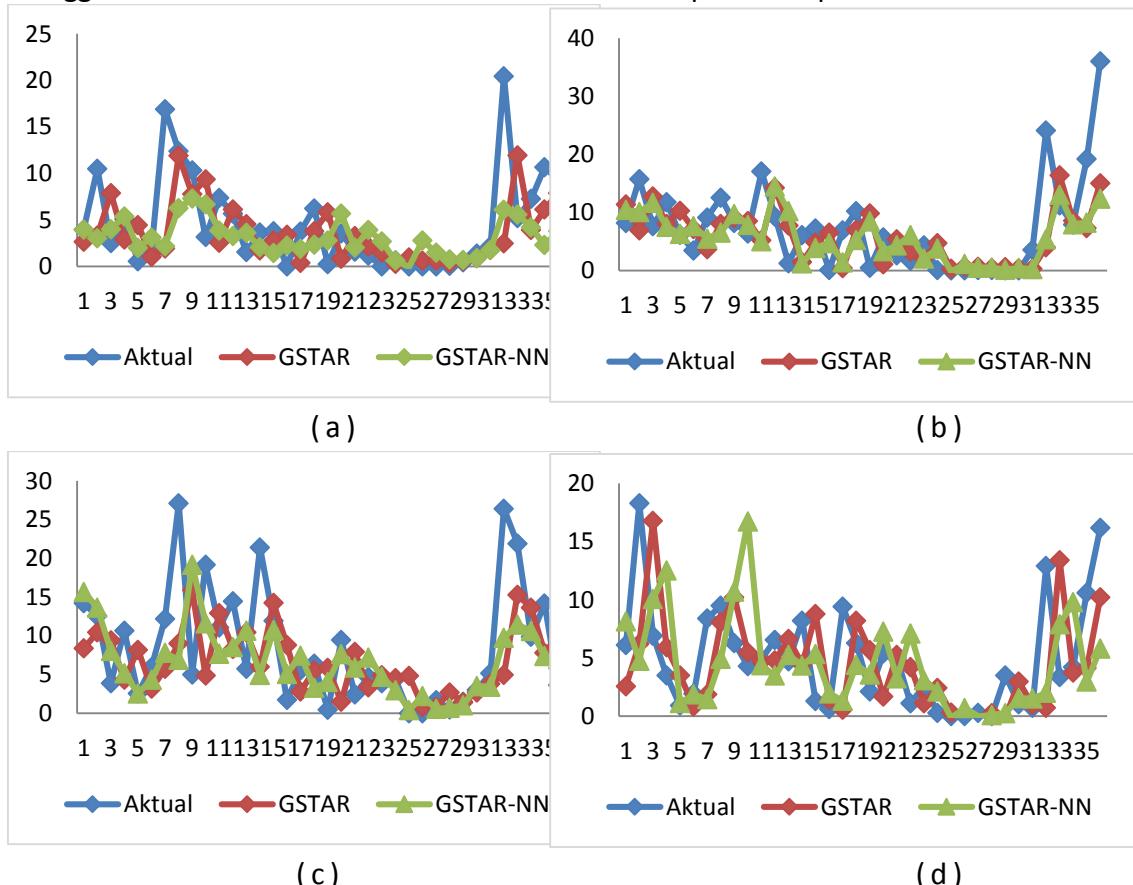
$$\begin{aligned} h_1 &= -6.6357 + 38.1235 a_{1,t-1} - 64.4647 a_{2,t-1} - 0.2530 a_{3,t-1} - 140.5992 a_{4,t-1} \\ h_2 &= -40.2756 + 1734.8299 a_{1,t-1} - 654.7498 a_{2,t-1} - 298.5295 a_{3,t-1} \\ &\quad + 634.9273 a_{4,t-1} \\ h_3 &= -108.8113 + 165.8382 a_{1,t-1} + 61.7286 - 104.2028 a_{3,t-1} \\ &\quad + 3303.6202 a_{4,t-1} \\ h_4 &= -76.9623 + 185.9868 a_{1,t-1} - 780.8632 a_{2,t-1} - 53.1243 a_{3,t-1} \\ &\quad - 1359.0992 a_{4,t-1} \\ h_5 &= -36.1719 + 28.2246 a_{1,t-1} - 59.4513 a_{2,t-1} - 16.9390 a_{3,t-1} \\ &\quad + 84.1928 a_{4,t-1} \\ h_6 &= 0.0041 - 15.3162 a_{1,t-1} - 3.1871 a_{2,t-1} + 2.3726 a_{3,t-1} - 3.2707 a_{4,t-1} \\ h_7 &= -0.0476 - 20.9670 a_{1,t-1} - 2.3471 a_{2,t-1} + 2.0524 a_{3,t-1} + 2.3935 a_{4,t-1} \\ h_8 &= 34.1967 - 1075.4388 a_{1,t-1} - 690.8235 a_{2,t-1} - 17.4927 a_{3,t-1} \\ &\quad - 1231.8239 a_{4,t-1} \end{aligned}$$

$$h_9 = 3.0337 - 141.7110 a_{1,t-1} + 36.4181 a_{2,t-1} - 1231.8239 a_{3,t-1} \\ + 13.7064 a_{4,t-1}$$

$$h_{10} = 0.6880 - 20.13583 a_{1,t-1} - 3.9520 a_{2,t-1} + 2.2277 a_{3,t-1} - 14.6592 a_{4,t-1}$$

Perbandingan Model GSTARIMA-SUR dan GSTAR-SUR-NN

Perbandingan model GSTAR-SUR dan GSTAR-SUR-NN dapat dilihat dari plot hasil ramalan. Perbandingan berdasarkan grafik masih bersifat subjektif sehingga kriteria lain yang digunakan adalah dengan menghitung nilai RMSE dan nilai MAD. Adapun plot hasil ramalan menggunakan model GSTAR-SUR dan GSTAR-SUR-NN dapat dilihat pada Gambar 4.



Gambar 4. Plot Hasil Ramalan Curah Hujan 2018

Gambar 4.a merupakan plot hasil ramalan curah hujan daerah Cisondari, sedangkan Gambar 4.b, 4.c, dan 4.d secara berturut-turut adalah plot hasil ramalan curah hujan daerah Cinchoni, Cibuni, dan Lembang. Berdasarkan Gambar 4 dapat dilihat bahwa hasil ramalan menggunakan GSTAR-SUR (1_1) dan GSTAR-SUR (1_1)-NN (4,10,4) memiliki pola yang hampir sama dengan data actual. Gambar tersebut masih belum dapat ditentukan model yang lebih baik. Oleh karena itu, pada Tabel 3 akan ditampilkan nilai RMSE dan MAD pada masing-masing model.

Tabel 3. Nilai RMSE dan MAD Setiap Model

Model	Nilai RMSE	Nilai MAD
GSTAR-SUR (1_1)	6.2215	4.3295

GSTAR-SUR (1 ₁)-NN (4,10,4)	5.8684	3.8917
Model yang menghasilkan nilai RMSE dan MAD terkecil yaitu model GSTAR-SUR (1 ₁)-NN (4,10,4). Rata-rata kesalahan peramalan model GSTAR-SUR (1 ₁)-NN (4,10,4) hanya memiliki selisih 3.8917 mm, sedangkan pada model GSTAR-SUR (1 ₁) memiliki selisih 4.3295 mm. sehingga kesimpulan bahwa model GSTAR-SUR (1 ₁)-NN (4,10,4) lebih baik dari model GSTAR-SUR (1 ₁) dalam meramalkan curah hujan di daerah Cisondari, Cinchoni, Cibuni, dan Lembang.		

SIMPULAN

Hasil peramalan curah hujan 10 harian di daerah Cisondari, Chincona, Cibuni, dan Lembang dengan menggunakan model GSTAR-SUR (1₁)-NN (4,10,4) menghasilkan hasil ramal yang lebih mendekati nilai aktual dari pada model GSTAR-SUR (1₁), dengan rata-rata kesalahan peramalan sebesar 3.8917 mm.

DAFTAR RUJUKAN

- Apriliyah, Mahmudi, W. F., & Widodo, A. W. (2008). Perkiraan Penjualan Beban Listrik Menggunakan Jaringan Saraf Tiruan Resilient Backpropagation. *Kursor*, 4, no.2, 41–47.
- Caudill, M. (1990). Using Neural Nets in Modelling Vector Time Series. *AI Expert*, (April), 59–64. <https://doi.org/10.1108/03684929410074986>
- Fadil, J., Penangsang, O., & Soeprijanto, A. (2009). Load Forecasting for the Dstribution Network of South and Middle Kalimantan Using Artificial Neural Networks Resilient Propagation. In *Proceedings of National Seminar on Applied Technology, Science, and Arts (1st APTECS)*. Surabaya.
- 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.
- Kostenko, A. V., & Hyndman, R. J. (2008). Forecasting WithoutSignificance Test?
- Pfeifer, P. E., & Deutsch, S. J. (1980). Stationarity and Invertibility Regions for Low Order STARMA Models. *Communications in Statistics-Simulation and Computation*, 9 no. 5, 551–562.
- Ruchjana, B. N. (2002). *A Generalized Space Time Autoregressive Model and its Application to Oil Production Data*. ITB.
- Setiawan. (1992). *Study on Seemingly Unrelated Regression (SUR) and its application to Almost Ideal Demand System (AIDS)*. Institut Pertanian Bogor.
- Setiawan, Suhartono, & Prastuti, M. (2016). S-GSTAR-SUR model for seasonal spatio temporal data forecasting. *Malaysian Journal of Mathematical Sciences*, 10, 53–65.
- Suhartono. (2007). *Feedforward Neural Networks Untuk Pemodelan Runtun Waktu*. Universitas Gadjah Mada.
- Suhartono, & Atok, R. M. (2006). Pemilihan Bobot Lokasi yang Optimal pada Model GSTAR. In *Prosiding Konferensi Nasional Matematika XIII*. Semarang.
- Suhartono, & Endharta, A. J. (2011). Double Seasonal Recurrent Neural Networks for Forecasting Short Term Electricity Load Demand in Indonesia. *Recurrent Neural Networks*

- for Temporal Data Processing. <https://doi.org/10.5772/15062>
- 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
- Suhartono, Ulama, B. S. S., & Endharta, A. J. (2010). Seasonal Time Series Data Forecasting by Using Neural Networks Multiscale Autoregressive Model, 7(10), 1372–1378.
- Sulistyono, A. D., Hadi Nugroho, W., & Iriany, A. (2015). Development of Hybrid Model GSTAR-SUR-NN and Application 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*. <https://doi.org/10.18860/ca.v4i2.3490>
- Vlahogianni, E. I., & Karlaftis, M. G. (2013). Testing and Comparing Neural Network and Statistical Approaches for Predicting Transportation Time Series. *Transportation Research Record: Journal of the Transportation Research Board*, 2399(1), 9–22. <https://doi.org/10.3141/2399-02>
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate* (2nd ed.). USA: Pearson Education Inc.