

Pemodelan VAR-NN dan GSTAR-NN untuk Peramalan Curah Hujan di Kabupaten Malang

Kadek Ardyo Novi Diani dan Setiawan dan Suhartono

Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh Nopember (ITS)

Jl. Arief Rahman Hakim, Surabaya 60111

E-mail: setiawan@statistika.its.ac.id

Abstrak—Model *Vector Autoregressive* (VAR) dan *Generalized Space Time Autoregressive* (GSTAR) merupakan metode pemodelan *time series* yang menggunakan lebih dari satu variabel. Kedua pemodelan tersebut merupakan kelompok pemodelan yang linier. Adapun *Neural Network* (NN), merupakan salah satu metode pemodelan yang mampu menangkap pola-pola nonlinier. Dalam penelitian ini, dilakukan penerapan metode pemodelan NN pada data curah hujan di Kabupaten Malang dengan menggunakan variabel input dalam model VAR dan GSTAR sebagai *input layer* dalam model NN. Perbandingan antara model VAR-NN dan GSTAR-NN juga dilakukan dalam penelitian ini untuk mengetahui model mana yang dapat memberikan nilai ramalan terbaik. Peramalan menggunakan kedua model tersebut dilakukan untuk 1 tahap, 3 tahap, 6 tahap, 9 tahap, 18 tahap, dan 36 tahap ke depan. Berdasarkan hasil perbandingan antara kedua model tersebut, diketahui bahwa model VAR-NN memberikan hasil peramalan yang lebih baik daripada model GSTAR-NN. Hasil ramalan terbaik dari kedua model tersebut akan diperoleh jika peramalan dilakukan pada 1 tahap ke depan dan dengan 1 *neuron* dalam *hidden layer*.

Kata kunci—curah hujan, GSTAR, model nonlinier, *neural network*, *time series*, VAR.

I. PENDAHULUAN

Kabupaten Malang merupakan salah satu kabupaten di Indonesia yang terletak di Provinsi Jawa Timur. Kabupaten ini tidak dapat terlepas dari sektor pertanian, bahkan merupakan sektor andalan dalam perekonomian.

Salah satu faktor penting yang mempengaruhi pertumbuhan output pertanian adalah iklim. Akan tetapi, adanya perubahan pola hujan pada tahun 1990-2000 dan intensitas hujan berubah makin tinggi mengakibatkan pergeseran awal musim dan pola tanam petani [1]. Oleh karena itu peramalan terhadap pola musim dianggap penting untuk memperoleh informasi yang tepat terhadap perubahan musim hujan dan kemarau yang terjadi di Indonesia.

Salah satu unsur iklim yang paling banyak digunakan dalam penelitian adalah curah hujan. Salah satu pemodelan *time series* yang banyak digunakan untuk data curah hujan adalah model ARIMA (*Autoregressive Integrated Moving Average*). Model ini bersifat *univariate* dan tidak memperhatikan faktor lokasi. Adapun model VAR (*Vector Autoregressive*) merupakan pemodelan *time series* yang

bersifat *multivariate*. Suhartono dan Wutsqa [2] menerapkan metode pemodelan ini pada data produksi kebun teh di Jawa Barat

Metode pemodelan lainnya yang dapat diterapkan pada data curah hujan adalah model GSTAR (*Generalized Space Time Autoregressive*). Model GSTAR ini dapat diterapkan pada data dengan variabel lokasi yang heterogen, dengan pemberian bobot untuk masing-masing lokasi. Penerapan model GSTAR ini telah dilakukan oleh Ningrum [3] pada data curah hujan bulanan di Kabupaten Ngawi, dan Maghfuro [4] yang memodelkan data curah hujan di Kabupaten Malang. Ada pula beberapa metode peramalan *time series* yang bersifat non linier, salah satunya adalah *neural network* (NN). Suhartono [5] mengembangkan metode *Feedforward Neural Network* (FFNN) untuk peramalan pada data *time series*.

Dalam data curah hujan, pemodelan yang bersifat non linier juga diperlukan untuk memperoleh model yang paling tepat pada akhirnya. Metode pemodelan non linier yang dapat digunakan dalam kasus ini antara lain VAR-NN dan GSTAR-NN yang merupakan metode pemodelan *neural network* dengan menggunakan variabel-variabel dalam model VAR dan GSTAR sebagai *input layer*.

Tujuan dari dilakukannya penelitian ini adalah untuk mendeskripsikan pola curah hujan di tiga lokasi di Malang, membentuk model VAR-NN dan GSTAR-NN, dan membandingkan ketepatan hasil ramalan antara kedua model tersebut untuk memperoleh model terbaik.

II. TINJAUAN PUSTAKA

A. Model VAR (*Vector Autoregressive*)

Sebuah *multivariate* runtuk waktu dikatakan sebuah VAR proses dari orde 1 jika mengikuti persamaan [6]:

$$\mathbf{Z}_t = \phi_0 + \Phi \mathbf{Z}_{t-1} + \mathbf{a}_t \quad (1)$$

Sehingga dalam bentuk matriks, persamaan model VAR(1) untuk data *time series* dengan 2 variabel dapat ditulis sebagai berikut,

$$\begin{bmatrix} Z_{1t} \\ Z_{2t} \end{bmatrix} = \begin{bmatrix} \phi_{10} \\ \phi_{20} \end{bmatrix} + \begin{bmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{bmatrix} \begin{bmatrix} Z_{1t-1} \\ Z_{2t-1} \end{bmatrix} + \begin{bmatrix} a_{1t} \\ a_{2t} \end{bmatrix} \quad (2)$$

Untuk persamaan model VAR dengan orde p atau VAR(p) dapat ditulis sebagai berikut [6].

$$\mathbf{Z}_t = \phi_0 + \Phi \mathbf{Z}_{t-1} + \dots + \Phi_p \mathbf{Z}_{t-p} + \mathbf{a}_t, \quad p > 0. \quad (3)$$

Dengan operator *back-shift* B , persamaan (3) dapat ditulis menjadi

$$(\mathbf{I} - \Phi_1 B - \dots - \Phi_p B^p) \mathbf{Z}_t = \phi_0 + \mathbf{a}_t \quad (4)$$

dimana \mathbf{I} adalah matriks identitas berukuran $k \times k$.

B. Model GSTAR (Generalized Space Time Autoregressive)

Jika diketahui sebuah deret $\{Z(t): t = 0, \pm 1, \pm 2, \dots\}$ merupakan sebuah deret waktu multivariat dari N komponen, maka persamaan model GSTAR untuk orde waktu dan orde spasial 1 dengan menggunakan 3 lokasi yang berbeda adalah sebagai berikut,

$$Z(t) = \Phi_{10}Z(t-1) + \Phi_{11}W^{(1)}Z(t-1) + e(t) \quad (5)$$

dan dalam bentuk matriks, persamaan (6) dapat ditulis sebagai berikut

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \\ Z_3(t) \end{bmatrix} = \begin{bmatrix} \phi_{10} & 0 & 0 \\ 0 & \phi_{20} & 0 \\ 0 & 0 & \phi_{30} \end{bmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{bmatrix} + \begin{bmatrix} \phi_{11} & 0 & 0 \\ 0 & \phi_{21} & 0 \\ 0 & 0 & \phi_{31} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{bmatrix} \begin{bmatrix} Z_1(t-1) \\ Z_2(t-1) \\ Z_3(t-1) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ e_3(t) \end{bmatrix} \quad (6)$$

Dalam mengidentifikasi orde model GSTAR, orde spasial pada umumnya dibatasi pada orde 1 karena orde yang lebih tinggi akan sulit untuk diinterpretasikan [7].

Pemilihan pembobot lokasi adalah salah satu permasalahan utama dalam permodelan GSTAR. Metode yang digunakan sebagai pembobot lokasi dalam GSTAR adalah sebagai berikut:

1. Bobot lokasi seragam

Bobot lokasi ini mengasumsikan bahwa lokasi-lokasi yang digunakan dalam penelitian bersifat homogen. Penentuan nilai bobot dalam bobot lokasi seragam adalah

$$w_{ij} = \frac{1}{n_i} \quad (7)$$

dengan n_i merupakan banyaknya lokasi yang berdekatan.

2. Bobot lokasi invers jarak

Pembobotan dengan metode invers jarak dilakukan berdasarkan jarak sebenarnya antar lokasi di lapangan. Perhitungan bobot dengan metode invers jarak diperoleh dari hasil invers jarak sebenarnya yang kemudian dinormalisasi.

3. Bobot lokasi korelasi silang

Pembobotan dengan metode ini menggunakan hasil normalisasi korelasi silang antar lokasi pada lag yang bersesuaian [8]. Taksiran dari korelasi silang ini pada sampel dapat dihitung dengan persamaan berikut

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [Z_i(t) - \bar{Z}_i][Z_j(t-k) - \bar{Z}_j]}{\sqrt{(\sum_{t=1}^n [Z_i(t) - \bar{Z}_i]^2) (\sum_{t=1}^n [Z_j(t) - \bar{Z}_j]^2)}} \quad (8)$$

C. Vector Autoregressive Neural Network (VAR-NN)

Model VAR-NN merupakan pemodelan *Neural Network* yang berdasarkan pada orde input dalam model VAR. Arsitektur dari pemodelan ini memiliki jumlah *neuron* pada *output layer* sebanyak *series multivariate* yang digunakan.

Misalkan bobot dari input layer ke hidden layer pada dinotasikan sebagai w , dan bobot dari hidden layer ke output layer adalah λ , serta $\alpha = (\alpha_1, \alpha_2, \alpha_3, \alpha_4)$ dan $\beta = (\beta_1, \beta_2, \beta_3)$ merupakan vektor bias pada input dan hidden layer, maka output dari model VAR(1)-NN dapat ditulis sebagai berikut [9]

$$Y_t = \lambda F(Yw + \alpha) + \beta + \varepsilon_t \quad (9)$$

dan

$$F(Yw + \alpha) = \frac{1}{1 + \exp(-(Yw + \alpha))} \quad (10)$$

D. Generalized Autoregressive Neural Network (GSTAR-NN)

Model GSTAR-NN merupakan pemodelan dalam *neural network* yang berdasarkan pada model GSTAR. Model GSTAR-NN ini hanya memiliki satu unit *neuron* pada *output layer*.

Neuron output pada arsitektur GSTAR-NN dinotasikan dengan \hat{Y}_t , sedangkan *neuron-neuron inputnya* dinotasikan dengan Y_{t-1}^* dan F_{t-1}^* untuk model GSTAR(1)₁-NN. Lebih jelasnya, berikut adalah struktur data dari masing-masing notasi tersebut [5].

$$\begin{aligned} \hat{Y}_t &= \begin{bmatrix} \hat{Y}_{1t} \\ \hat{Y}_{2t} \\ \hat{Y}_{3t} \end{bmatrix}, Y_{t-1}^* = \begin{bmatrix} Y_{1,t-1} \\ 0 \\ 0 \end{bmatrix}, Y_{2,t-1}^* = \begin{bmatrix} 0 \\ Y_{2,t-1} \\ 0 \end{bmatrix}, Y_{3,t-1}^* = \begin{bmatrix} 0 \\ 0 \\ Y_{3,t-1} \end{bmatrix}, \\ F_{1,t-1}^* &= \begin{bmatrix} w_{12}Y_{2,t-1} + w_{13}Y_{3,t-1} \\ 0 \\ 0 \end{bmatrix}, F_{2,t-1}^* = \begin{bmatrix} 0 \\ w_{21}Y_{1,t-1} + w_{23}Y_{3,t-1} \\ 0 \end{bmatrix}, \\ F_{3,t-1}^* &= \begin{bmatrix} 0 \\ 0 \\ w_{31}Y_{1,t-1} + w_{32}Y_{2,t-1} \end{bmatrix} \end{aligned} \quad (11)$$

E. Pemilihan Model Terbaik

Pemilihan model terbaik menggunakan kriteria out-sampel dengan membenadingkan nilai *Root Mean Square Error* (RMSE) terkecil. RMSE dari suatu model dapat diperoleh melalui perhitungan sebagai berikut [10]

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{M} \sum_{i=1}^M (Z_i - \hat{Z}_i)^2} \quad (12)$$

dengan M merupakan banyaknya ramalan yang dilakukan.

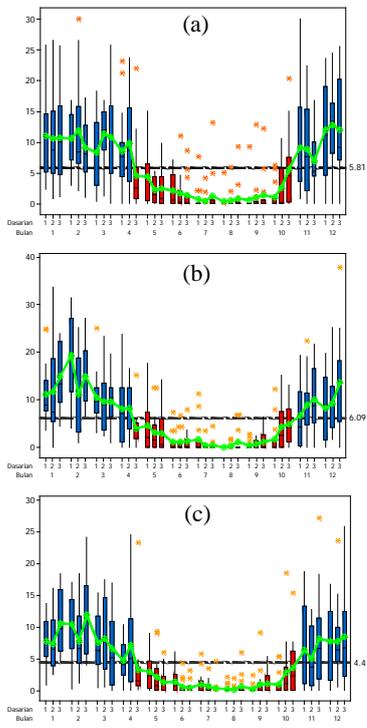
F. Curah Hujan

Curah hujan merupakan jumlah air hujan yang turun pada suatu daerah dalam kurun waktu tertentu. Satuan yang digunakan dalam mengukur curah hujan adalah millimeter (mm). Curah hujan satu millimeter artinya dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi satu millimeter atau sebanyak satu liter.

III. METODOLOGI PENELITIAN

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa data curah hujan di Kabupaten Malang dari tahun 1996 sampai Pebruari 2012 yang diperoleh dari Badan Meteorologi dan Geofisika (BMG) Malang. Data curah hujan ini kemudian dibagi menjadi data in-sampel dan out-sampel. Data in-sampe dimulai dari tahun 1996 hingga Februari 2011. Dan data out-sampel dimulai dari Maret 2011 hingga Februari 2012.

Terdapat tiga variabel yang digunakan dalam penelitian ini yang merupakan data ketinggian curah hujan di tiga lokasi di Malang, yaitu Tumpang, Pujon, dan Batu. Tahapan analisis yang dilakukan dimulai dari mendeskripsikan pola curah hujan di ketiga lokasi tersebut. Kemudian membentuk model VAR dan GSTAR, yang kemudian dilanjutkan dengan membentuk model VAR-NN dan GSTAR-NN menggunakan variabel-variabel dari model VAR dan GSTAR.



Gambar 1. Box Plot Data Curah Hujan Dasarian di (a)Tumpang; (b)Pujon; dan (c)Batu.

IV. ANALISIS DAN PEMBAHASAN

A. Statistika Deskriptif

Hasil analisis deskriptif dari data curah hujan di ketiga lokasi ini menunjukkan bahwa pola musim di ketiga lokasi tersebut memiliki periode yang sama. Pola musim tersebut ditampilkan dalam box plot pada Gambar 1.

Ketinggian curah hujan cenderung menurun mulai bulan April dasarian ketiga dan meningkat kembali pada bulan November. Berdasarkan analisis secara tahunan diketahui bahwa rata-rata curah hujan tertinggi di lokasi Tumpang dan Batu tercatat pada tahun 2010, dan di Lokasi Batu pada tahun 1999.

B. Pemodelan Vector Autoregressive (VAR)

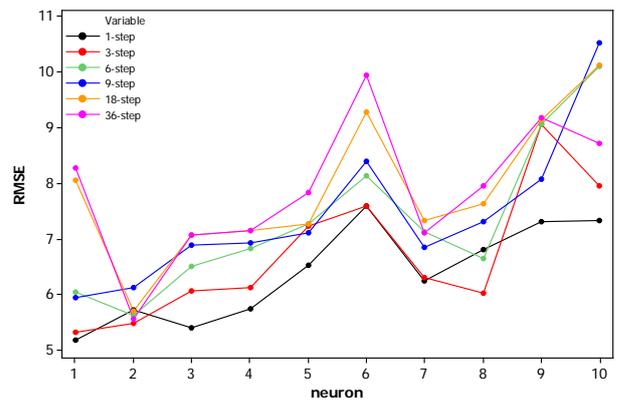
Hasil identifikasi pada data curah hujan di ketiga lokasi melalui plot MACF dan MPACF menunjukkan bahwa data tersebut tidak stasioner dan terdapat pola musiman dengan periode 36. Sehingga untuk mengatasinya data curah hujan didifferencing 1 dan 36.

Berdasarkan plot MACF dan MPACF yang telah stasioner, diperoleh dua kemungkinan model VAR, yaitu model VARIMA (6,1,0)(1,1,0)³⁶ dan VARIMA (6,1,0)(2,1,0)³⁶. Selanjutnya dilakukan peramalan 1 tahun ke depan menggunakan kedua model ini. Hasil pengujian asumsi residual dari kedua model ini menunjukkan bahwa asumsi white noise tidak dapat dipenuhi oleh residual kedua model. Sedangkan asumsi distribusi multivariat normal sudah terpenuhi.

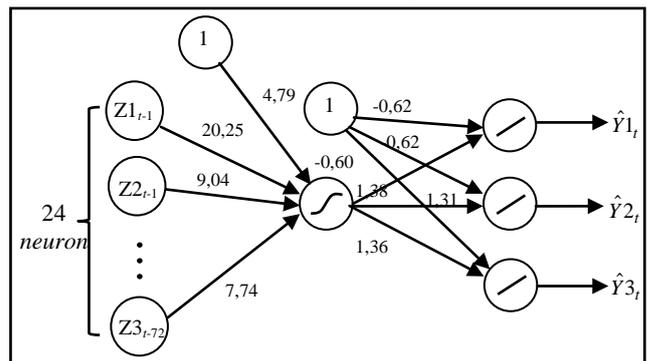
Hasil perhitungan nilai RMSE berdasarkan peramalan out-sampel menunjukkan bahwa model VARIMA (6,1,0)(2,1,0)³⁶ memberikan hasil peramalan yang lebih daripada model VARIMA (6,1,0)(1,1,0)³⁶.

C. Pemodelan Vector Autoregressive Neural Network (VAR-NN)

Berdasarkan hasil pemodelan VAR, arsitektur dari model VAR-NN yang akan dibentuk menggunakan 24 neuron



Gambar 2. Grafik Nilai RMSE Out-sampel Model VAR-NN



Gambar 3. Arsitektur Model VAR-NN dengan 1 Neuron pada Hidden Layer

input, 1 hidden layer, dan 3 neuron output. Jumlah neuron dalam hidden layer yang digunakan mulai dari 1 hingga 10. Peramalan dengan model VAR-NN dilakukan untuk 1 tahap, 3 tahap, 6 tahap, 9 tahap, 18 tahap, dan 36 tahap ke depan. Hasil perhitungan nilai RMSE out-sampel untuk masing-masing cara peramalan dengan jumlah neuron di hidden layer dari 1 hingga 10 ditampilkan dalam Gambar 2.

Gambar 2 menunjukkan bahwa semakin banyak jumlah neuron pada hidden layer maka nilai RMSE-nya cenderung semakin meningkat. Nilai RMSE terkecil diperoleh dari hasil peramalan dengan 1 neuron di hidden layer dan dilakukan untuk 1 tahap ke depan. Sehingga diperoleh arsitektur model VAR-NN seperti pada Gambar 3.

Berdasarkan arsitektur pada Gambar 3 selanjutnya dibentuk persamaan model VAR-NN, yaitu

- Untuk lokasi Tumpang $\hat{Y}_1 = -0,62 + 1,38f^{(h)}$
- Untuk lokasi Pujon $\hat{Y}_2 = -0,62 + 1,31f^{(h)}$
- Untuk lokasi Batu $\hat{Y}_3 = -0,6 + 1,36f^{(h)}$

dengan $f^{(h)}$ merupakan persamaan untuk fungsi aktivasi sigmoid sebagai berikut

$$f^{(h)} = \frac{1}{1 + e^{-(h)}}$$

dimana,

$$\begin{aligned}
 h = & 4,79 + 20,25Y_{1(t-1)} + 0,94Y_{2(t-1)} + 12,20Y_{3(t-1)} + 8,15Y_{1(t-2)} + \\
 & - 7,68Y_{2(t-2)} + 9,46Y_{3(t-2)} - 7,05Y_{1(t-3)} - 2,79Y_{2(t-3)} + \\
 & 7,11Y_{3(t-3)} + 4,99Y_{1(t-4)} + 11,09Y_{2(t-4)} - 14Y_{3(t-4)} + \\
 & 0,67Y_{1(t-5)} - 11,04Y_{2(t-5)} + 1,11Y_{3(t-5)} + 3,98Y_{1(t-6)} + 0,14Y_{2(t-6)} + \\
 & - 0,74Y_{3(t-6)} + 6,86Y_{1(t-36)} + 9,72Y_{2(t-36)} - 0,6Y_{3(t-36)} + \\
 & - 4,87Y_{1(t-72)} + 9,83Y_{2(t-72)} + 7,74Y_{3(t-72)}
 \end{aligned}$$

D. Pemodelan Generalized Space Time Autoregressive (GSTAR)

Tahap identifikasi dalam pemodelan GSTAR memiliki proses yang sama pemodelan VAR dalam menentukan orde model. Sehingga model GSTAR yang dibentuk dalam penelitian ini adalah GSTAR $([1,2,3,4,5,6,36,72]_1)-I(1)(1)^{36}$, dengan total 48 variabel. Terdapat dua jenis model GSTAR $([1,2,3,4,5,6,36,72]_1)-I(1)(1)^{36}$ yang dibentuk, yaitu model GSTAR dengan semua variabel, dan model GSTAR dengan variabel-variabel yang signifikan saja.

Bobot lokasi yang digunakan dalam pemodelan ini adalah bobot lokasi seragam, invers jarak, dan korelasi silang. Hasil penaksiran parameter dengan ketiga bobot tersebut menunjukkan terdapat 23 variabel yang signifikan.

Hasil pengujian asumsi *white noise* residual dari kedua model GSTAR tersebut menunjukkan bahwa error dari kedua model tersebut tidak identik dan independen, atau tidak memenuhi asumsi *white noise*. Sedangkan asumsi distribusi multivariat normal sudah terpenuhi.

Hasil peramalan dengan kedua jenis model GSTAR $([1,2,3,4,5,6,36,72]_1)-I(1)(1)^{36}$ ini menggunakan masing-masing bobot lokasi menunjukkan bahwa bobot lokasi invers jarak memberikan hasil peramalan yang terbaik untuk kedua model GSTAR tersebut. Hasil perbandingan nilai RMSE tersebut dapat dilihat pada tabel 1.

Dari kedua jenis model GSTAR $([1,2,3,4,5,6,36,72]_1)-I(1)(1)^{36}$, hasil peramalan terbaik dihasilkan oleh model GSTAR $([1,2,3,4,5,6,36,72]_1)-I(1)(1)^{36}$ dengan semua variabel menggunakan bobot invers jarak.

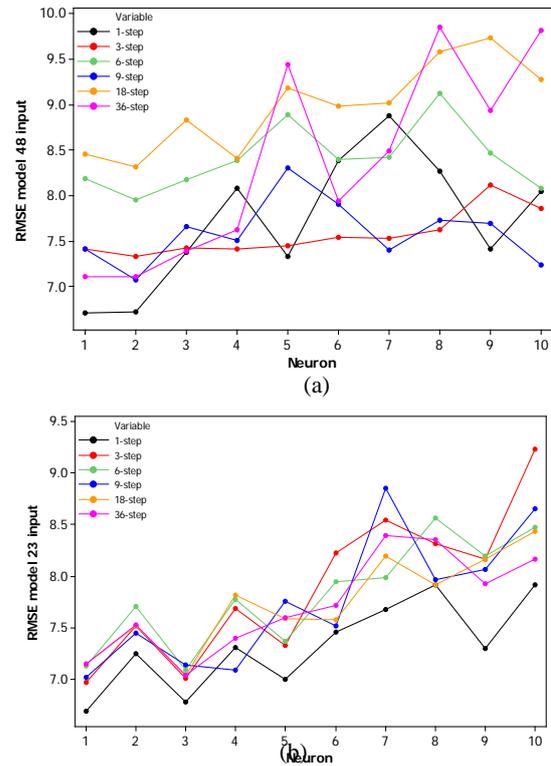
Tabel 1. Perbandingan Nilai RMSE Out-sampel dari Model GSTAR $([1,2,3,4,5,6,36,72]_1)-I(1)(1)^{36}$

Lokasi	Pemodelan dengan Semua Variabel			Pemodelan dengan Variabel yang Signifikan		
	Sera-gam	Inv. Jarak	Kor Silang	Sera-gam	Inv. Jarak	Kor Silang
Tumpang	10,026	10,007*	10,008	10,196	10,196	10,196
Pujon	8,882	8,808	8,879	8,852	8,827	8,556*
Batu	5,322	5,34	5,32*	5,537	5,537	5,537
Total	8,321	8,291*	8,313	8,426	8,316*	8,323

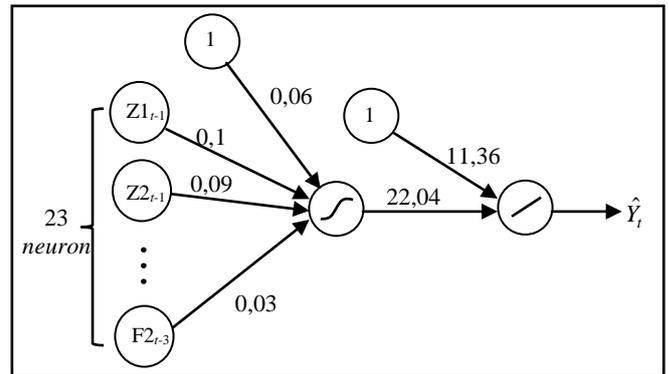
E. Pemodelan Generalized Space Time Autoregressive Neural Network (GSTAR-NN)

Dalam pemodelan GSTAR-NN juga menggunakan 2 arsitektur, yaitu arsitektur dengan semua variabel dari model GSTAR $([1,2,3,4,5,6,36,72]_1)-I(1)(1)^{36}$ dimasukkan menjadi *input* sehingga terdapat 48 *neuron input*, dan arsitektur dengan variabel-variabel yang signifikan saja dari model GSTAR $([1,2,3,4,5,6,36,72]_1)-I(1)(1)^{36}$ yang dijadikan *input*, yaitu sebanyak 23 *neuron input*.

Arsitektur model GSTAR-NN hanya memiliki 1 *neuron* pada *output layer*. Sedangkan jumlah *hidden layer*nya diabatasi hanya 1 *hidden layer* dengan jumlah *neuron* dalam *hidden layer* mulai dari 1 sampai 10 *neuron*. Dengan melakukan peramalan untuk 1 tahun ke depan dengan cara peramalan 1 tahap, 3 tahap, 6 tahap, 9 tahap, 18 tahap, dan



Gambar 4. Grafik Nilai RMSE Out-sampel Model GSTAR-NN dengan (a) 48 Neuron Input, (b) 23 Neuron Input



Gambar 5. Arsitektur Model GSTAR-NN dengan 23 Neuron Input dan 1 Neuron pada Hidden Layer

36 tahap ke depan, diperoleh nilai RMSE untuk masing-masing cara peramalan dengan jumlah *neuron* dalam *hidden layer* dari 1 sampai 10. Hasil perhitungan nilai RMSE dari kedua arsitektur model GSTAR-NN ditampilkan dalam bentuk grafik pada Gambar 4.

Nilai RMSE terendah dari kedua model tersebut diperoleh dari hasil peramalan dengan metode 1 tahap ke depan. Sedangkan hasil perbandingan nilai RMSE untuk kedua model GSTAR-NN tersebut, diketahui bahwa model GSTAR-NN dengan 23 *neuron input* memberikan hasil peramalan yang lebih baik daripada model GSTAR-NN dengan 48 *neuron input*. Bentuk arsitektur model GSTAR-NN dengan 23 *neuron input* ditampilkan dalam Gambar 5.

Selanjutnya dibentuk persamaan untuk model GSTAR-NN dengan 23 *neuron input* berdasarkan arsitektur model pada Gambar 5, yaitu sebagai berikut

$$\hat{Y}_t = 11,36 - 22,04f^{(h)}$$

Tabel 2. Perbandingan Nilai RMSE Model VAR-NN dan GSTAR-NN

Model	RMSE			
	Tumpang	Pujon	Batu	Total
VAR-NN	6,299	4,430	4,590	5,180
GSTAR-NN	6,513	8,287	4,821	6,692
VARIMA	6,404	7,813	4,719	6,438
GSTAR	6,432	7,819	4,840	6,479

dengan $f^{(h)}$ merupakan fungsi aktivasi sigmoid dengan persamaan

$$f^{(h)} = \frac{1}{1 + e^{(h)}}$$

dimana

$$h = 0,06 + 0,1Z1_{t-1} + 0,09Z2_{t-1} + 0,09Z3_{t-1} + 0,07Z1_{t-2} + 0,07Z2_{t-2} + 0,06Z3_{t-2} + 0,06Z1_{t-3} + 0,05Z2_{t-3} + 0,06Z3_{t-3} + 0,04Z1_{t-4} + 0,06Z2_{t-4} + 0,03Z3_{t-4} + 0,03Z1_{t-5} + 0,03Z2_{t-5} + 0,02Z1_{t-6} + 0,02Z2_{t-6} + 0,1Z1_{t-36} + 0,09Z2_{t-36} + 0,09Z3_{t-36} + 0,04Z1_{t-72} + 0,05Z2_{t-72} + 0,05Z3_{t-72} + 0,03F2_{t-3}$$

Variabel $Z1_t$, $Z2_t$, $Z3_t$, dan $F2_t$ merupakan vektor sebagai berikut

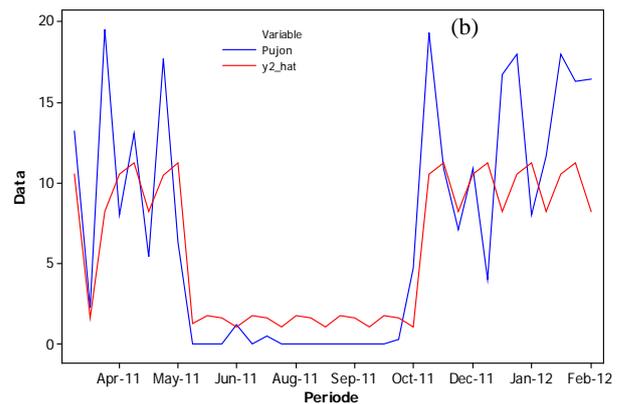
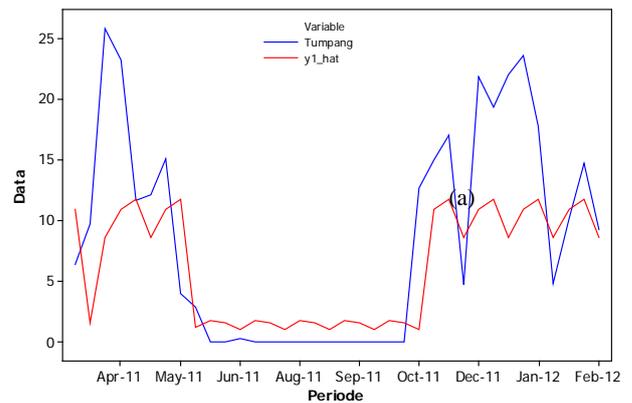
$$Z1_t = \begin{bmatrix} Y1_t \\ 0 \\ 0 \end{bmatrix}, \quad Z2_t = \begin{bmatrix} 0 \\ Y2_t \\ 0 \end{bmatrix}, \quad Z3_t = \begin{bmatrix} 0 \\ 0 \\ Y3_t \end{bmatrix}, \quad F2_t = \begin{bmatrix} 0 \\ 0,216Y1_t + 0,784Y3_t \\ 0 \end{bmatrix}$$

F. Perbandingan Hasil Peramalan Model VAR-NN dan GSTAR-NN

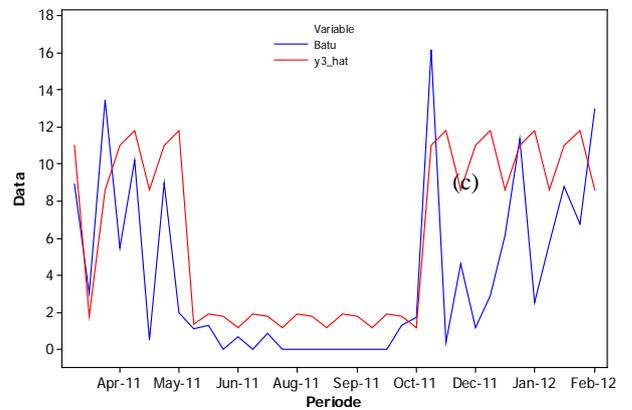
Nilai RMSE hasil peramalan out-sampel dari model VAR-NN dan GSTAR-NN tersebut selanjutnya dibandingkan untuk mengetahui model yang dapat memberikan hasil peramalan terbaik. Perbandingan tersebut juga dilakukan terhadap model VARIMA (6,1,0)(2,1,0)³⁶ dan GSTAR ([1,2,3,4,5,6,36,72]₁)-I(1)(1)³⁶ dengan bobot invers jarak dan menggunakan semua variabel untuk peramalan pada 1 periode ke depan. Hasil perbandingan keempat model tersebut ditampilkan dalam Tabel 2.

Tabel 2 menunjukkan bahwa nilai RMSE terkecil baik di masing-masing lokasi maupun secara keseluruhan diperoleh dari hasil peramalan dengan model VAR-NN. Maka hal ini menunjukkan bahwa model yang dapat memberikan hasil peramalan untuk ketinggian curah hujan terbaik untuk lokasi Tumpang, Pujon, dan Batu adalah model VAR-NN dengan 1 neuron di hidden layer, dengan peramalan yang dilakukan untuk setiap 10 hari sekali.

Maka diperoleh hasil peramalan ketinggian curah hujan untuk periode bulan Maret 2011 hingga Februari 2012 di lokasi Tumpang, Pujon, dan Batu dengan model VAR-NN seperti pada Gambar 6.



Gambar 6. Time Series Plot Hasil Peramalan Out-sampel Model VAR-NN di Lokasi (a)Tumpang (b)Pujon (c)Batu



Gambar 6. (lanjutan) Time Series Plot Hasil Peramalan Out-sampel Model VAR-NN di Lokasi (a)Tumpang (b)Pujon (c)Batu

V. KESIMPULAN DAN SARAN

Kesimpulan yang dapat diambil dari hasil analisis dan pembahasan adalah sebagai berikut :

1. Data curah hujan di ketiga lokasi memiliki pola yang sama, yaitu cenderung rendah pada bulan April dasarian ketiga sampai bulan Oktober dasarian ketiga.
2. Hasil pemodelan data curah hujan di lokasi Tumpang, Pujon, dan Batu dengan metode VAR-NN menunjukkan bahwa model VAR-NN terbaik adalah model yang menggunakan variabel-variabel yang signifikan dari model VARIMA(6,1,0)(2,1,0)³⁶ sebagai input layer, dan dengan 1 neuron dalam hidden layer. Sedangkan model GSTAR-NN terbaik adalah model

GSTAR-NN yang menggunakan variabel-variabel yang signifikan dari model GSTAR $([1,2,3,4,5,6,36,72])_1-I(1)(1)^{36}$ dengan bobot invers jarak sebagai *input layer*, dan 1 *neuron* dalam *hidden layer*. Hasil peramalan terbaik dari kedua model ini diperoleh dari hasil peramalan untuk 1 tahap ke depan, atau setiap 10 hari ke depan.

3. Hasil perbandingan model VAR, GSTAR, VAR-NN dan GSTAR-NN menunjukkan bahwa model yang dapat memberikan hasil peramalan terbaik adalah model VAR-NN dengan 1 *neuron* dalam *hidden layer*.

Dalam penelitian tugas akhir ini asumsi *white noise* dari residual belum terpenuhi oleh model VAR dan GSTAR, sehingga model yang diperoleh belum optimal. Untuk penelitian selanjutnya disarankan agar peneliti menggunakan metode *recurrent neural network*. Selain itu, dalam melakukan peramalan curah hujan sebaiknya dilakukan untuk satu tahap ke depan, karena hasil peramalannya akan lebih baik. Untuk penelitian selanjutnya disarankan agar menggunakan data curah hujan tahunan karena hasil peramalan yang diperoleh akan lebih baik.

DAFTAR PUSTAKA

- [1] M. Ratag, *Perubahan iklim: Perubahan variasi curah hujan, cuaca dan iklim ekstrim*. Badan Meteorologi dan Geofisika, Jakarta, (2007).
- [2] Suhartono dan D.U. Wutsqa, "Perbandingan Model VAR dan STAR pada Peramalan Produksi Teh di Jawa Barat", (2007).
- [3] S.P. "Ningrum, Pemodelan Spatio-Temporal dengan Metode GSTAR pada Data Curah Hujan Bulanan di Kabupaten Ngawi". *Tugas Akhir Statistika ITS, Surabaya*, (2010).
- [4] L. Maghfuro, "Peramalan Model Curah Hujan di Kabupaten Malang dengan Pendekatan Model Univariate Time Series dan Multivariate Time Series". *Tugas Akhir Mahasiswa Statistika ITS, Surabaya*, (2012)..=
- [5] Suhartono, "Feedforward neural Network untuk Pemodelan Runtun Waktu". *Seminar Disertasi Universitas Gajah Mada Yogyakarta*, (2007).
- [6] R.S. Tsay, *Analysis of Financial Time Series: Financial Econometrics*. University of Chicago: John Wiley & Sons, Inc, (2002).
- [7] D.U. Wutsqa, Suhartono, dan B. Sutijo, "Generalized Space-Time Autoregressive Modeling". *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and its Application (ICMSA 2010)*, Universiti Tunku Abdul Rahman, Kuala Lumpur, Malaysia, (2010).
- [8] Suhartono dan R.M. Atok, "Perbandingan antara Model GSTAR dan VARIMA untuk Peramalan Data Deret Waktu dan Lokasi". *Seminar Nasional Statistika, ITS Surabaya*, (2006).
- [9] D.U., Wutsqa, Subanar, S. Guritno, dan Z. Sujuti, "Forecasting Performance of VAR-NN and VARMA Models". *Proceeding of the 2nd IMT-GT Regional Conference on Mathematics, Statistics and Applications, Universiti Sains Malaysia*, (2006a)..

- [10] W.W.S. Wei, *Time Series Analysis: Univariate and Multivariate Methods*. United State of America: Addison-Wesley Publishing Company, Inc., (1994).