

Pemodelan Data Curah Hujan Di Kabupaten Banyuwangi dengan Metode ARIMA dan *Radial Basis Function Neural Network*

Novelina Purba dan Brodjol Sutidjo S.U

Jurusan Statistika, Fakultas MIPA, Institut Teknologi Sepuluh Nopember (ITS)

Jl. Arief Rahman Hakim, Surabaya 60111 Indonesia

e-mail: novelinagirsang@gmail.com, brodjol.su@gmail.com

Abstrak—Curah hujan merupakan salah satu komponen lingkungan pemegang peranan penting dalam budidaya tanaman. Bagi Kabupaten Banyuwangi jumlah curah hujan sangat penting dalam menentukan ke-berhasilannya sebagai salah satu lumbung padi Jawa Timur. Perencanaan waktu tanam tidak lepas dari kondisi curah hujan. Penelitian ini menggunakan metode ARIMA dan RBFNN untuk memodelkan curah hujan di Kabupaten Banyuwangi dengan pendekatan linier dan non linier. Model ARIMA merupakan pendekatan linier pada data curah hujan, sedangkan model RBFNN merupakan pendekatan non linier pada data. Penelitian ini membandingkan kedua model tersebut berdasarkan nilai *Mean Square Error* (MSE). Data yang digunakan dalam penelitian ini berasal dari Stasiun Meteorologi Banyuwangi. Model ARIMA menghasilkan nilai MSE sebesar 344,658 dan model RBFNN menghasilkan nilai MSE sebesar 300,185. Berdasarkan perbandingan MSE dari kedua model disimpulkan bahwa model RBFNN lebih baik dari pada ARIMA dalam meramalkan curah hujan di Kabupaten Banyuwangi.

Kata Kunci— ARIMA, RBFNN, Curah Hujan, Banyuwangi.

I. PENDAHULUAN

Kabupaten Banyuwangi merupakan salah satu daerah penyumbang produksi padi terbesar di Provinsi Jawa Timur. Produktivitas lahan padi Kabupaten Banyuwangi sebesar 5,6 kw/ha hingga 6,7 kw/ha. Angka tersebut bahkan melampaui produktivitas padi nasional, yakni 5,9 kw/ha hingga 6,0 kw/ha.

Salah satu komponen lingkungan penentu keberhasilan usaha budidaya tanaman adalah iklim. Salah satu indikator iklim adalah curah hujan. Curah hujan didefinisikan sebagai jumlah air yang jatuh di permukaan tanah datar selama periode tertentu yang diukur dengan satuan tinggi (mm) di atas permukaan horizontal bila tidak terjadi evaporasi, limpasan, dan infiltrasi. Curah hujan satu millimeter (1 mm), artinya dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi satu millimeter. Jumlah curah hujan sangat penting dalam menentukan hasil budidaya tanaman [1]. Peningkatan curah hujan di suatu daerah menimbulkan potensi banjir. Sebaliknya, bila terjadi penurunan curah hujan di suatu daerah, akan mengakibatkan kekeringan.

Mengingat pentingnya peranan curah hujan dalam penentuan musim tanam untuk mencapai hasil yang maksimal, perlu dilakukan prediksi curah hujan di masa yang akan datang. Puslitbang Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) menjelaskan bahwa BMKG melakukan peramalan curah hujan dengan

menggunakan metode *Ensemble Mean* dan *Ensemble Bayesian Model Averaging* (BMA). Hasil peramalan dengan metode tersebut divalidasi dengan diagram Taylor untuk melihat kebaikan hasil peramalan. Hasil diagram Taylor menunjukkan bahwa teknik *ensemble mean* dan *ensemble BMA* tidak selalu memberikan akurasi terbaik.

Metode ARIMA (*Autoregressive Integrated Moving Average*) merupakan salah satu metode pemodelan data deret berkala secara linier untuk peramalan. Metode ARIMA mengasumsikan nilai residual *white noise* dan berdistribusi normal. Pada kenyataannya, terjadi kondisi cuaca ekstrim di Banyuwangi. Pemodelan data yang mengandung nilai ekstrim dengan menggunakan model ARIMA menyebabkan nilai residual tidak berdistribusi normal dan tidak *white noise*.

Jaringan saraf tiruan merupakan pemrosesan suatu informasi yang dibuat menyerupai kinerja sel-sel saraf biologi. Jaringan saraf tiruan dibentuk untuk memecahkan masalah melalui proses pembelajaran, yaitu identifikasi pola dan pengelompokan. Model jaringan saraf tiruan efektif digunakan pada model nonlinier. Metode jaringan saraf tiruan pernah digunakan dalam memodelkan curah hujan di daerah sekitar aliran sungai Bengawan Solo oleh Fithriasari dkk (2013) [2]. *Radial Basis Function Neural Network* (RBFNN) merupakan salah satu metode jaringan saraf tiruan yang terdiri dari lapisan *input*, lapisan *hidden*, dan lapisan *ouput*. Jaringan RBFNN mengeluarkan nilai berupa persamaan linier pada lapisan *ouput*.

Perbandingan hasil analisis dengan metode ARIMA dan RBFNN telah dibahas dalam peramalan jumlah wisatawan di Indonesia [3]. Dikatakan bahwa hasil peramalan data wisatawan di Indonesia dengan RBFNN menghasilkan nilai *mean square error* (MSE) yang lebih kecil dibanding dengan metode ARIMA. Berdasarkan hasil tersebut, Haviluddin dan Jawahir merekomendasikan metode RBFNN sebagai salah satu metode alternatif untuk peramalan. Metode RBFNN juga pernah digunakan dalam peramalan curah hujan di Liuzhou, China [4]. Wu dkk menggunakan RBFNN karena dapat memperkirakan fungsi kontinu dengan ketepatan yang diinginkan. Dalam peramalan harga saham, metode RBFNN juga pernah digunakan dengan alasan pergerakan harga saham merupakan pola nonlinier dan dipengaruhi oleh banyak faktor [5].

Dalam penelitian ini digunakan metode ARIMA dan RBFNN untuk memodelkan curah hujan di Kabupaten Banyuwangi. Model ARIMA digunakan untuk pendekatan linier terhadap data curah hujan. Model RBFNN digunakan untuk pendekatan non linier untuk

menangkap pola yang tidak linier karena adanya data ekstrim akibat fenomena alam dan perubahan musim.

II. TINJAUAN PUSTAKA

A. Model Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA merupakan penggabungan antara model *Autoregressive* (AR) dan *Moving Average* (MA) serta proses *differencing* (orde d untuk data non musiman, orde D untuk data musiman) terhadap data *time series*. Secara umum, model ARIMA (p, d, q) dapat ditulis sebagai berikut [6]:

$$\Phi_p(B^s)\phi_p(B)(1-B)^d(1-B)^D Z_t = \theta_q(B)\Theta_Q(B)a_t, \quad (1)$$

dengan :

(p, d, q) : orde AR (p), orde *differencing* (d), orde MA (q) untuk data non musiman.

$\phi_p(B)$: komponen AR non musiman dengan orde (p)

$\Phi_p(B)$: komponen AR musiman dengan orde (P)

$\theta_q(B)$: komponen MA non musiman dengan orde (q)

$\Theta_Q(B)$: komponen MA musiman dengan orde (Q)

$(1-B)^d$: *differencing* non musiman dengan orde (d)

$(1-B)^D$: *differencing* musiman dengan orde (D)

Z_t : besarnya pengamatan (kejadian) pada waktu ke t

a_t : nilai residual pada saat t

B. Stasioner

Jika *time series plot* berfluktuasi di sekitar garis yang sejajar sumbu waktu t maka dapat dikatakan bahwa deret waktu sudah stasioner dalam *mean*, jika kondisi stasioner dalam *mean* tidak terpenuhi maka perlu dilakukan *differencing* terhadap data. Suatu data telah memenuhi syarat stasioner dalam *varians* jika nilai *rounded value* (λ) sudah bernilai 1, atau nilai batas *lower* dan *upper*-nya telah melewati 1. Jika syarat stasioner dalam *varians* belum terpenuhi maka perlu dilakukan transformasi. Transformasi yang diperkenalkan dalam buku Wei (2006) adalah transformasi *Box-Cox*, dengan rumus [6]:

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda} \quad (2)$$

C. Autocorrelation Function (ACF) dan Partial Autocorrelation (PACF)

ACF merupakan suatu koefisien yang menunjukkan hubungan linier pada data *time series* antara Z_t dengan Z_{t-k} . Korelasi antara $\{Z_t\}$ dengan $\{Z_{t-k}\}$ adalah sebagai berikut [6]:

$$\rho_k = \frac{\text{Cov}(Z_t, Z_{t-k})}{\sqrt{\text{Var}(Z_t)}\sqrt{\text{Var}(Z_{t-k})}} \quad (3)$$

PACF berfungsi untuk mengukur tingkat keeratan hubungan (korelasi) antara pasangan data Z_t dan Z_{t-k} setelah pengaruh variabel $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$ dihilangkan. Fungsi parsial autokorelasi antara Z_t dan Z_{t-k} bernilai sama dengan autokorelasi antara $Z_t - \hat{Z}_t$ dan $Z_{t-k} - \hat{Z}_{t-k}$, sehingga fungsi autokorelasi parsial dapat dihitung dengan rumus sebagai berikut [6]:

$$P_k = \frac{\text{Cov}[(Z_t - \hat{Z}_t), (Z_{t-k} - \hat{Z}_{t-k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)}\sqrt{\text{Var}(Z_{t-k} - \hat{Z}_{t-k})}} \quad (4)$$

dengan:

$$\hat{Z}_t = \beta_1 Z_{t-1} + \beta_2 Z_{t-2} + \dots + \beta_k Z_{t-k}$$

$$\hat{Z}_{t-k} = \alpha_1 Z_{t-k-1} + \alpha_2 Z_{t-k-2} + \dots + \alpha_k Z_1$$

D. Estimasi Parameter

Salah satu metode estimasi parameter adalah metode *Least Square Estimation*, yaitu dengan cara meminimumkan jumlah kuadrat residual. Untuk model AR(1) dinyatakan dalam rumus berikut [7]:

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2 \quad (5)$$

Taksiran parameter untuk μ dan $\hat{\phi}$ dari model AR(1) sebagai persamaan berikut :

$$\hat{\mu} = \frac{\bar{Z} - \phi\bar{Z}}{1 - \phi} = \frac{\bar{Z}(1 - \phi)}{1 - \phi} = \bar{Z} \quad (6)$$

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \quad (7)$$

E. Pengujian Signifikansi Parameter

Pengujian hipotesis dilakukan dengan menggunakan uji t . Misalkan yang diuji adalah parameter MA yaitu θ , maka hipotesis yang diuji adalah sebagai berikut :

$H_0: \theta_i = 0$ (parameter tidak signifikan terhadap model) untuk $i = 1, 2, \dots, q$

$H_1: \theta_i \neq 0$ (parameter sudah signifikan terhadap model)

Statistik uji [8]:

$$t_{hitung} = \frac{\hat{\theta}}{S_{\hat{\theta}}}, \quad (8)$$

dengan $\hat{\theta}$ merupakan nilai estimasi dari θ dan $S_{\hat{\theta}}$ adalah standar error dari nilai taksiran $\hat{\theta}$. Tolak H_0 jika $|t_{hitung}| > t_{\alpha/2, df=n-p}$ dengan p adalah banyaknya parameter, atau tolak H_0 jika $P_{value} < \alpha$, dengan α adalah taraf signifikansi.

F. Uji Linieritas

Uji linieritas dapat dilakukan Uji Terasvirta. Prosedur pengujian Uji Terasvirta adalah dengan meregresikan Z_t pada 1, Z_{t-1}, \dots, Z_{t-p} , sehingga diperoleh model linear [9]:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \hat{\epsilon}_t, \quad (9)$$

kemudian menghitung jumlah kuadrat nilai residual yaitu $SSR_0 = \sum \hat{\epsilon}_t^2$. Selanjutnya, meregresikan $\hat{\epsilon}_t$ pada 1, $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$, dan m prediktor tambahan yang merupakan hasil pendekatan ekspansi Taylor, dan kemudian menghitung jumlah kuadrat nilai residual $SSR_1 = \sum \hat{v}_t^2$. Langkah terakhir adalah menghitung nilai statistik uji sebagai berikut:

$$F_{hit} = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(n-p-1-m)} \quad (10)$$

dengan n adalah jumlah pengamatan. Test dilakukan dengan menguji hipotesis :

H_0 : Model linier

H_0 : Model nonlinier

H_0 ditolak jika $F_{hit} > F_{(k-1, n-k)}$.

G. Radial Basis Function Neural Network (RBFNN)

Jaringan saraf tiruan atau *Neural Network* (NN) adalah sistem pemrosesan informasi yang memiliki karakteristik mirip jaringan saraf biologi. [10]. Jaringan saraf tiruan RBF memiliki 3 *layer*, yaitu *input layer*, *hidden layer*, dan *ouput layer*. *Ouput* dirumuskan sebagai berikut:

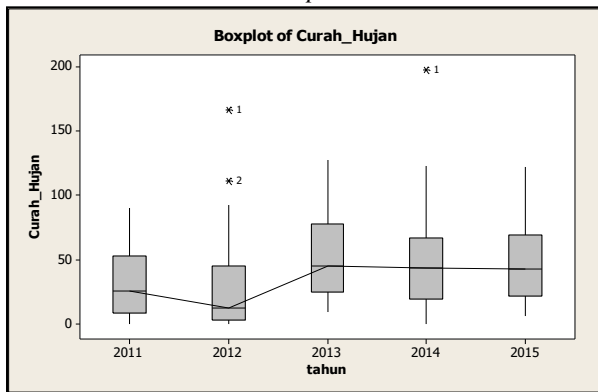
$$\hat{y} = \sum_{j=1}^m w_j h_j(x) \quad (11)$$

Dimana fungsi aktivasi dengan RBF (Gaussian) dinyatakan sebagai berikut:

$$h_j(x) = \exp\left(-\frac{\|x - c_j\|^2}{\sigma_j^2}\right) \quad (12)$$

Dimana:

- \mathbf{c}_j = vektor *Center* pada node ke- j
- σ_j = standar deviasi pada node ke- j .
- \mathbf{x} = vektor *input*



Gambar 1. Sebaran Data Curah Hujan Kab. Banyuwangi

H. Pemilihan Model Terbaik

Kriteria pemilihan model terbaik adalah nilai *Mean Square Error* (MSE) dan nilai *Mean Absolute Error* (MAE), dengan rumus sebagai berikut [6]:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2 \tag{13}$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |Z_t - \hat{Z}_t| \tag{14}$$

Model yang paling baik adalah model yang menghasilkan nilai MSE dan MAE terkecil.

III. METODE PENELITIAN

I. Sumber Data

Data yang digunakan dalam penelitian ini merupakan data curah hujan harian di Kabupaten Banyuwangi yang diambil dari Stasiun Meteorologi Kelas III Banyuwangi yang diambil dari <http://dataonline.bmkg.go.id/>, yang kemudian dijadikan data dasarian dengan melakukan penjumlahan dari curah hujan harian. Struktur organisasi data yang digunakan seperti pada Tabel 1.

TABEL 1. STRUKTUR DATA

Tahun	Curah Hujan
2011	Z_1
2011	Z_2
⋮	⋮
2015	Z_{180}

J. Langkah Analisis

1. Membagi data menjadi dua, yaitu data *training* (periode Januari 2011-Februari 2015) dan data *testing* (Maret 2015-Februari 2016).
2. Membuat model ARIMA dengan melihat plot ACF dan PACF.
3. Mengambil nilai residual (a_t) sebagai input RBFNN.
4. Menentukan variabel input dengan melihat plot fungsi autokorelasi (ACF) dari nilai residual. Variabel input ditentukan oleh *lag-lag* yang nilai ACF-nya signifikan.
5. Menentukan nilai pusat dan varians dengan menggunakan metode klaster dari hasil pengelompokan.
6. Menentukan jaringan yang optimum. Jaringan yang optimum adalah jaringan dengan nilai MAPE dan MSE terkecil dari data *testing*.
7. Membandingkan kedua model berdasarkan nilai MSE nya.

IV. ANALISIS DAN PEMBAHASAN

Sebelum dilakukan analisis, terlebih dahulu dilakukan *pre-processing* data. *Pre-processing* data pada penelitian ini meliputi imputasi terhadap data kosong, penjumlahan data harian menjadi data dasarian dan transformasi data untuk mengatasi data yang bernilai nol. Imputasi data dilakukan dengan mengisi data yang kosong dengan nilai rata-rata curah hujan pada tahun 2000-2010.

A. Deskriptif Data Curah Hujan Kabupaten Banyuwangi

Deskriptif data penelitian (dalam satuan millimeter) dijelaskan dalam Tabel 2. Dari Tabel 2 diketahui bahwa jumlah curah hujan dasarian tertinggi selama tahun 2011-2015 terjadi tahun 2014. Sebaran data curah hujan Kabupaten Banyuwangi digambarkan dalam *boxplot* pada Gambar 1.

Berdasarkan *boxplot* pada Gambar 4.1 terdapat data *outlier* di tahun 2012 dan 2014. Data *outlier* pada tahun 2012 terdapat pada data ke-37 (Januari) dan 40 (Februari). Curah hujan di Kabupaten Banyuwangi pada dasarian pertama bulan Januari 2012 sebesar 166 mm dan curah hujan di Kabupaten Banyuwangi pada dasarian pertama Februari 2012 sebesar 111 mm. Data *outlier* pada tahun 2014 terdapat pada data ke-111. Data ke-111 merupakan curah hujan pada dasarian ke-3 bulan Januari 2014, dengan jumlah curah hujan sebesar 197. Angka ini juga merupakan curah hujan tertinggi selama lima tahun pengamatan mulai 2011 sampai 2015.


TABEL 2. DESKRIPTIF DATA CURAH HUJAN KABUPATEN BANYUWANGI

Tahun	Mean	St.Dev	Minimum	Maximum	Median
2011	31,39	28,41	0,00	90,00	25,14
2012	28,64	36,84	0,00	166,00	12,50
2013	53,11	35,11	9,20	127,07	45,12
2014	49,92	41,10	0,00	197,16	43,40
2015	49,32	33,83	6,30	122,11	42,51


B. Pemodelan Curah Hujan Banyuwangi dengan ARIMA

Pada tahap awal dilakukan pembagian data sebanyak 162 sebagai *in sample* dan 18 sebagai *out sample*. Data curah hujan terlebih dahulu ditambahkan nilai 1, agar dapat diperiksa stasioneritasnya terhadap varians dengan *box-cox plot*. Berikut *Time series plot* data curah hujan Kabupaten Banyuwangi.


Dari *time series plot* nya tampak bahwa data curah hujan Kabupaten Banyuwangi tidak stasioner terhadap varians. Untuk lebih jelasnya akan dijelaskan oleh *box-cox plot*. Nilai *rounded value* (λ) tidak melewati nilai 1, menandakan bahwa data yang digunakan belum stasioner terhadap varians. Pengecekan data stasioner terhadap mean dilakukan dengan melihat plot ACF dan PACF nya. Data curah hujan Kab. Banyuwangi belum stasioner terhadap mean, karena plot PACF nya turun lambat menuju 0, maka dilakukan *differencing* orde 1.




Gambar 2. Time Series Plot Data Curah Hujan Kab. Banyuwangi



Gambar 3. Box-Cox Plot Data Curah Hujan Kabupaten Banyuwangi



Gambar 4. ACF Curah Hujan Kab. Banyuwangi Setelah Dilakukan Differencing



Gambar 5. PACF Curah Hujan Kab. Banyuwangi Setelah Dilakukan Differencing

Hasil estimasi parameter dan uji signifikansi parameter dari model-model tersebut dirangkum dalam **Error! Reference source not found.3**.

Dari ketiga model yang dicobakan, ketiga-tiganya memiliki parameter yang signifikan. Untuk menentukan model mana yang lebih baik, selanjutnya akan dilakukan pemeriksaan apakah nilai residual sudah *white noise*. Hasil dari pengujian nilai residual *white noise* dijelaskan pada Tabel 4.

TABEL 4. STATISTIK LJUNG-BOX NILAI RESIDUAL MODEL ARIMA

Model	Lag	²	Df	P-value	Kesimpulan
(1,1,0)(0,0,1) ¹⁵	12	15,7	10	0,109	<i>White noise</i>
	24	31,4	22	0,088	
	36	44,7	34	0,104	
	48	53,7	46	0,202	
	(0,1,1)(0,0,1) ¹⁵	12	9,2	10	0,511

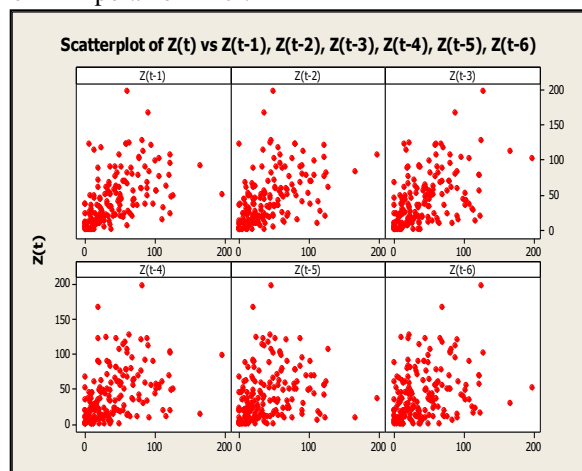
	24	20,4	22	0,588	
	36	33,9	34	0,474	
	48	52,9	46	0,225	
(2,1,0)(0,0,1) ¹⁵	12	9,6	9	0,382	<i>White noise</i>
	24	20,6	21	0,485	
	36	33,0	33	0,469	
	48	45,7	45	0,445	

Berdasarkan Tabel 4 diketahui bahwa ketiga model ARIMA memenuhi asumsi residual independen. Pengujian dengan uji *Kolmogorov-Smirnov* memberikan nilai *P-value* > 0,05, sehingga dapat disimpulkan bahwa ketiga model memenuhi asumsi residual berdistribusi normal.

Dari ketiga model tersebut model ARIMA(2,1,0)(0,0,1)¹⁵ merupakan model yang terbaik karena memiliki nilai MSE terkecil, yaitu sebesar 344,658 dan MAE terkecil, yaitu 12,654.

C. Uji Linieritas

Uji linieritas dilakukan dengan Uji Terasvirta. Dari pengujian ini diketahui bahwa data yang digunakan memiliki pola nonlinier.



Gambar 6. Scatter Plot Data Curah Hujan Terhadap Lag-Lag Signifikan

Perhitungan nilai statistik uji F_{hit} menghasilkan nilai sebesar 9,0078. Nilai F_{tabel} dengan nilai signifikansi (α) 5% adalah sebesar 3,0470. Nilai F_{hit} lebih besar dari nilai F_{tabel} sehingga dapat disimpulkan bahwa terdapat pola nonlinier pada data curah hujan Kabupaten Banyuwangi.

D. Pemodelan dengan RBFNN

Penentuan variabel input dilakukan berdasarkan plot ACF. Nilai ACF data curah hujan signifikan pada lag 1, 2, 3, 4, 5 dan 6. Oleh karena itu, variabel input adalah Z_{t-1} , Z_{t-2} , Z_{t-3} , Z_{t-4} , Z_{t-5} dan Z_{t-6} . Variabel input tersebut kemudian dikelompokkan dengan K-Means Cluster, dan mendapatkan jaringan optimum dengan 3 kelompok. Artinya, jaringan RBFNN yang terbentuk memiliki 3 neuron pada lapisan hidden layer.

TABEL 5. NILAI MSE MODEL BERDASARKAN BANYAKNYA KELOMPOK YANG TERBENTUK

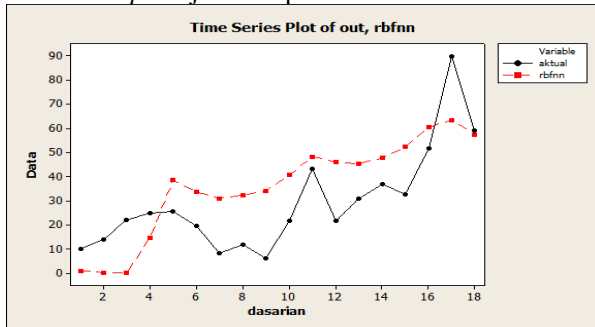
Banyak kelompok	MSE (training)	MSE (testing)
2 kelompok	1.518,5	357,97
3 kelompok	1.447,5	300,18
4 kelompok	1.329,3	762,80
5 kelompok	1.333,9	527,95
6 kelompok	3.276,4	2.399,31

Berdasarkan Tabel 5 diketahui bahwa jaringan yang terbentuk dari 3 kelompok memiliki nilai MSE terkecil, sehingga dianggap sebagai model terbaik. Pembobot yang didapat dengan 3 kelompok pada jaringan RBFNN curah hujan Kabupaten Banyuwangi adalah sebagai berikut:

$$C = \begin{pmatrix} 77,7934 & 53,6311 & 17,6167 \\ 84,8241 & 49,4043 & 17,4761 \\ 88,1518 & 47,4875 & 17,1844 \\ 89,2987 & 45,7832 & 16,7162 \\ 89,2659 & 46,6566 & 16,7456 \\ 83,5049 & 52,3610 & 15,4184 \end{pmatrix} \Sigma = \begin{pmatrix} 50,9877 & 39,1760 & 46,1366 \\ 55,9218 & 38,3156 & 46,2239 \\ 58,4472 & 38,0684 & 46,3453 \\ 51,0193 & 37,5187 & 45,9396 \\ 50,8262 & 37,5976 & 46,1268 \\ 50,7949 & 38,5581 & 47,0919 \end{pmatrix}$$

$w_1 = 128,4790, w_2 = 56,0659, w_3 = 60,8272.$

Grafik perbandingan nilai peramalan curah hujan dan data aktual curah hujan di Kabupaten Banyuwangi untuk data *out sample* dijelaskan pada Gambar 7.



Gambar 7. Data Aktual dan Peramalan dengan RBFNN

E. Peramalan dengan RBFNN

Dari kedua metode yang digunakan, diketahui bahwa nilai MSE dan MAE model RBFNN lebih kecil dibandingkan model ARIMA, maka model yang digunakan untuk melakukan peramalan adalah RBFNN. Nilai ramalan curah hujan di Kabupaten Banyuwangi dengan model RBFNN ditampilkan dalam Tabel 6.

TABEL 6. NILAI RAMALAN CURAH HUJAN KAB. BANYUWANGI JANUARI-JUNI 2016

t	Bulan	Z _t
181	Januari	54.7067
182	Januari	56.0664
183	Januari	59.8967
184	Februari	63.6484
185	Februari	63.8621
186	Februari	61.9997
187	Maret	60.7236
188	Maret	62.4815
189	Maret	65.3660
190	April	66.7021
191	April	66.2479
192	April	65.9434
193	Mei	67.2170
194	Mei	70.3320
195	Mei	73.0041
196	Juni	74.4410
197	Juni	76.5792
198	Juni	81.3512

V. KESIMPULAN DAN SARAN

Model yang ARIMA yang dapat mewakili data curah hujan Kabupaten Banyuwangi adalah ARIMA(2,1,0)(0,0,1)¹⁵. Model matematisnya adalah:

$$Z_t = 0,4207 Z_{t-1} + 0,3716 Z_{t-2} + 0,2077 Z_{t-3} - 0,3088 a_{t-15} + a_t$$

Model ini menjelaskan bahwa jumlah curah hujan di Kabupaten Banyuwangi pada periode sekarang dipengaruhi oleh jumlah curah hujan pada empat periode sebelumnya berturut-turut, dan kesalahan peramalan pada 15 periode sebelumnya. Model *Radial Basis Function* (RBFNN) yang optimum adalah dengan 6 *neuron* pada input, 3 *neuron* pada lapisan tersembunyi, dan 1 *neuron* pada lapisan *output*.

Berdasarkan perbandingan MSE dan RMSE dari model ARIMA dan RBFNN, dapat dikatakan bahwa pada kasus pemodelan curah hujan di Kabupaten Banyuwangi pada tahun 2011-2015, metode RBFNN lebih baik dari pada ARIMA. Akan tetapi, berdasarkan nilai *Mean Absolute Error* (MAE), metode ARIMA lebih baik dibandingkan RBFNN

Penelitian selanjutnya sebaiknya menggunakan metode imputasi lain seperti fungsi transfer atau regresi. Agar lebih sensitif menangkap perubahan musim dan fenomena alam yang berpengaruh atau memberi intervensi pada data curah hujan.

DAFTAR PUSTAKA

- [1]. Anwar, M., Liu, D., Macadam, I., Kelly, G. (2015). *Climate Change Impacts on Phenology and Yields of Five Broadacre Crops at Four Climatologically Distinct Locations in Australia*. *Agricultural System*, 133-144.
- [2]. Fithriyari, K., Iriawan, N., Ulama, B.S.S., & Sutikno. (2013). *On Multivariate Time Series Rainfall Modeling Using Time Delay Neural Network*. *International Journal of Applied Mathematics and Statistics*.
- [3]. Haviluddin & Jawahir, A. (2015). *Comparing of ARIMA and RBFNN for Short-Term Forecasting*. *International Journal of Advance in Intelligent Informatics Vol 1, No.1*, 15-22.
- [4]. Wu, J., Long, J., & Liu, M. (2012). *Evolution of RBF Neural Networks for Rainfall Prediction using hybrid Particle Swarm Optimization and Genetic Algorithm*. *Neurocomputing* 148, 136-142.
- [5]. Shen, W., Guo, Xiaopen., Wu, C., & Wu, D. (2010). *Forecasting Stock Indices Using Radial Basis Function Neural Networks Optimized by Artificial Fish Swarm Algorithm*. *Knowledge-Based System* 24, 378-385.
- [6]. Wei, W. (2006). *Time Series Analysis Univariate and Multivariate Methods*. Amerika: Addison Wesley Publishing Company, Inc.
- [7]. Cryer, J., & Chan, K. (2008). *Time Series Analysis with Application in R, 2nd ed.* USA: PWS-Kent Publishing (Duxbury Press).
- [8]. Bowerman, B., & O'Connell. (1993). *Forecasting and Time Series: An Applied Approach, 3rd ed.* California: Duxbury Press.
- [9]. Subanar & Suhartono. (2000). *Uji Linieritas Tipe Lagrange Multiplier dengan Ekspansi Taylor untuk Deteksi Hubungan Nonlinier Pada Data Time Series*. Yogyakarta: Universitas Gadjah Mada
- [10]. Fausett, L. (1994). *Fundamentals of Neural Networks (Architectures, Algorithms, dan Applications)*. Upper Saddle River, New Jersey: Prentice.