



## Aplikasi Model Wavelet Neuro Fuzzy untuk Memprediksi Banjir Sungai Bengawan Solo

Nurmalitasari<sup>1</sup>, Sri Sumarlinda<sup>2</sup><sup>1,2</sup> STMIK Duta Bangsa Surakarta, IndonesiaCorrespondence: ✉ [nurmalitasari@stmikdb.ac.id](mailto:nurmalitasari@stmikdb.ac.id)

### Article Info

#### Article History

Received : 19-02-2018

Revised : 27-05-2018

Accepted : 04-06-2018

#### Keywords:

forecasting;

bengawan solo river;

wavelet neuro fuzzy;

MSE

### Abstract

The objectives of this article is to implementation wavelet neuro fuzzy method to predict water level of Bengawan Solo river. The wavelet neuro fuzzy method is a model combination between discrete wavelet transformation, Artificial Neural Network (ANN) and fuzzy logic. Wavelet Neuro fuzzy modeling aims to reduce the weaknesses of each system, and combine existing advantages of each system, so the predicted result has a very small error value. Wavelet neuro fuzzy modeling in this study used a wavelet model with Mother Haar level 1 with a fuzzy inference system of the Sugeno model order zero with a binary sigmoid activation function between the input layer and the hidden layer and the hidden layer with the output layer. Predicted when the flood is important because the predicted result can provide early warning information to the community around the river when the arrival of floods so as to reduce the risk of disaster and prepare for emergency response action. The data used in this study are high level of water level data obtained from AWLR Serenan post. The results of the wavelet neuro fuzzy method show the Mean Square error (MSE) forecast of 0.0613.

## PENDAHULUAN

Sejak tahun 1863 Bengawan Solo telah menimbulkan banjir di daerah hulu, bahkan saat ini banjir sudah masuk kawasan hilir. Banjir akibat luapan sungai Bengawan Solo terakhir terjadi bulan april 2015 dan ribuan rumah kebanjiran tersebar di sejumlah daerah. Kejadian banjir menyebabkan kerugian bagi masyarakat di sekitar sungai baik kerugian harta benda maupun nyawa [1]. Banjir merupakan fenomena alam yang tidak dapat dicegah, tetapi dapat dikurangi [2]. Salah satu upaya penanggulangan banjir adalah memberikan informasi peringatan dini kepada masyarakat disekitar sungai kapan waktu datangnya banjir. Peringatan dini merupakan pengambilan tindakan cepat dan tepat dalam rangka mengurangi risiko terkena bencana serta mempersiapkan tindakan tanggap darurat [3]. Dengan adanya peringatan dini penduduk sekitar sungai Bengawan Solo memiliki kesempatan untuk menyelamatkan diri dan harta bendanya. Mengingat begitu pentingnya informasi tentang kapan terjadinya banjir, maka dalam penelitian ini akan memprediksi tinggi muka air (TMA) sungai Bengawan Solo.

Penggunaan metode yang sesuai untuk melakukan prediksi mempunyai beberapa faktor yang berpengaruh yaitu waktu, pola data, hubungan antara dengan data sebelumnya dan tingkat keakuratan ramalan yang diinginkan. Dewasa ini berkembang metode baru dalam peramalan yang menghasilkan *error* sangat kecil yaitu metode *wavelet neuro fuzzy* [4][6]. Metode *wavelet neuro fuzzy* merupakan penggabungan model antara transformasi *wavelet* diskrit dan *neuro fuzzy*. Tranformasi *wavelet* diskrit merupakan metode yang mendekomposisikan sebuah data diskrit ke dalam beberapa data baru yang memiliki korelasi terhadap data sebelumnya [4][6]. Metode selanjutnya, *neuro fuzzy* adalah penggabungan

dua sistem, yaitu *Artificial Neural Network (ANN)* atau jaringan syaraf tiruan dengan logika *fuzzy* [7] [8]. Sedangkan, logika *fuzzy* merupakan representasi pengetahuan yang dikonstruksikan dengan IF-THEN rules [9]. Pemodelan *wavelet neuro fuzzy* bertujuan untuk mengurangi kelemahan dari masing-masing sistem, serta menggabungkan kelebihan yang ada dari masing-masing system [4][6].

Prediksi dengan menggunakan metode *wavelet neuro fuzzy* pernah dilakukan dalam memprediksi curah hujan harian [6], memprediksi dan *emulation* tugas [4], memprediksi nilai tukar Euro terhadap dollar Amerika [10], memprediksi banjir di sungai Fahlian dengan menggunakan data *Runoff* [5]. Hasil dari penelitian-penelitian tersebut menunjukkan nilai *error* yang sangat kecil. Melihat hal tersebut, dalam memprediksi banjir sungai Bengawan Solo, peneliti tertarik untuk menggunakan metode *wavelet neuro fuzzy*.

## METODE

Data yang digunakan dalam penelitian ini adalah data tinggi muka air yang diperoleh dari pos *AWLR* Serenan tanggal 1-30 Oktober 2016. Metode peramalan yang digunakan dalam penelitian ini adalah metode *wavelet neuro fuzzy*. Langkah-langkah peramalan menggunakan *wavelet neuro fuzzy* adalah sebagai berikut [11]

### 1) Mentransformasi Data

Transformasi data menggunakan *wavelet mother Haar* level 1 dengan menggunakan DWT pada data sebenarnya. Data nilai tukar sebenarnya didekomposisikan ke beberapa banyaknya DWs tertentu yang masing-masing mempunyai kontribusi berbeda terhadap data sebenarnya. DWs yang signifikan diperoleh berdasarkan besarnya nilai koefisien korelasi. Koefisien korelasi akan memberikan informasi terhadap DWs yang dipilih dengan data sebenarnya tentang pemilihan model *input*. Ditentukan  $r \geq 0.5$  sebagai korelasi yang signifikan antara data DWs dengan data sebenarnya. Hasil penjumlahan dari beberapa DWs yang signifikan tersebut berdasarkan nilai korelasi yang diperoleh akan digunakan sebagai *input* model prediksi.

### 2) Menentukan Banyaknya Input Model

Pada penelitian ini, *Autocorrelation Function (ACF)* atau fungsi *autokorelasi* digunakan untuk menentukan banyaknya *input* yang akan digunakan pada sebuah model. Banyaknya *input* ditentukan dengan banyaknya lag yang keluar melebihi batas garis signifikansi.

### 3) Memilih Variabel *Input-output* pada Data Pelatihan

Proses ini menggunakan metode eliminasi *backward* dengan fungsi biaya *Sum Square Error (SSE)*. Seleksi variabel dilakukan dengan cara mengeliminasi variabel-variabel yang tidak diperlukan dan mempertahankan variabel-variabel yang memberikan korelasi yang cukup signifikan terhadap variabel *output*  $y_i$ .

### 4) Mengelompokkan (*Clustering*) Data Pelatihan

Proses *clustering* membagi data TRD menjadi  $r$  kelas dengan menggunakan metode pengclustoran *Fuzzy C-Means (FCM)*. FCM adalah teknik pengclustoran data dimana tiap data dalam suatu *cluster* ditentukan oleh derajat keanggotaannya.

### 5) Pembelajaran jaringan syaraf yang berhubungan dengan bagian *anteseden* (bagian IF) pada aturan-aturan inferensi *fuzzy*

Setiap vektor *input* pada data TRD, ditentukan  $m_i = (m_i^1, m_i^2, \dots, m_i^r)$ ,  $i = 1, 2, \dots, N_s$  dengan aturan *fuzzy* sebagai berikut [11]:

$$m_i^k = \begin{cases} 1; & k = s \\ 0; & k \neq s \end{cases}$$

dengan

$m_i^k$  = derajat keanggotaan tiap data ( $x_i$ ) pada *cluster* ke- $k$  ( $k \leq r$ )

$s$  = banyaknya aturan inferensi *fuzzy*

Derajat keanggotaan tiap data dapat diperoleh sebagai *output* jaringan yang telah dilatih sebagai [11]:

$$\mu_{As}x_i = m_i^s$$

dengan  $i = 1, 2, \dots, N$ ,  $s = 1, 2, \dots, r$  dan  $\mu_{As}$  adalah nilai keanggotaan tiap data dalam himpunan *fuzzy*  $A$  pada aturan *fuzzy* ke- $s$  bagian *anteseden*.

**6) Pembelajaran jaringan syaraf yang berhubungan dengan bagian konsekuen (bagian THEN) pada aturan-aturan inferensi fuzzy.**

Pada bagian ini, akan dilakukan pembelajaran jaringan syaraf pada bagian THEN dari  $R^s$  dengan *input*  $x = (x_{i1}^s, x_{i2}^s, \dots, x_{im}^s)$ ,  $i = 1, 2, \dots, Nc$  dan target *output*  $y_i^s$ ,  $i = 1, 2, \dots, Ns$ . Selanjutnya hasil pelatihan akan diujikan pada data CHD dengan *input*  $x = (x_{i1}^s, x_{i2}^s, \dots, x_{im}^s)$ ,  $i = 1, 2, \dots, Nc$  untuk mendapatkan SSE CHD sebagai berikut (Lin, 1996):

$$E_m^s = \sum_{i=1}^{Nc} [y_i - f_s(x_i)\mu_{As}(x_i)]^2$$

untuk  $s=1,2,\dots,r$  dengan

$r$  = banyaknya kelas

$y_i$  = target *output* ke- $i$

$Nc$  = banyak pasangan data CHD

$\mu_{As}(xi)$  = derajat keanggotaan tiap  $xi$  dalam himpunan *fuzzy*  $A$  pada aturan *fuzzy* ke- $s$  bagian *anteseden*

$f_s(xi)$  = *Output* jaringan hasil pembelajaran tiap  $xi$  pada setiap aturan inferensi *fuzzy*  $R^s$  pada bagian konsekuen

Selanjutnya, *error* dengan pembobotan dapat dihitung sebagai berikut:

$$E_m^s = \sum_{i=1}^{Nc} \mu_{As}(x_i)[y_i - f_s(x_i)\mu_{As}(x_i)]^2$$

**7) Menyederhanakan bagian konsekuen (bagian THEN) menggunakan metode backward**

Dari semua variabel *input* yang terpilih tidak semua variabel berpartisipasi pada *neural network* memiliki kontribusi yang cukup baik. Oleh karena itu, salah satu variabel dapat dieliminasi untuk mendapatkan hasil *output* yang lebih baik dan kemudian melatih jaringan kembali untuk mendapatkan SSE ( $E_m^{sp}$ ) sebagai berikut (Lin, 1995):

$$E_m^{sp} = \sum_{i=1}^{Nc} [y_i - f_s(x_i)\mu_{As}(x_i)]^2$$

untuk  $p=1,2,\dots,m$  dengan,

$r$  = banyaknya kelas

$y_i$  = target *output* ke- $i$

$Nc$  = banyak pasangan data CHD

$\mu_{As}(x_i)$  = derajat keanggotaan tiap  $x_i$  dalam himpunan *fuzzy*  $A$  pada aturan *fuzzy* ke- $s$  bagian anteseden dengan eliminasi variable *input*  $x_p$

$f_s(x_i)$  = *Output* jaringan hasil pembelajaran tiap  $x_i$  pada setiap aturan inferensi *fuzzy*  $R^s$  pada bagian konsekuen dengan eliminasi variable *input*  $x_p$ .

Jika  $E_m^{Ss} > E_m^{Sp}$  terpenuhi akan ditentukan parameter konsekuen untuk tiap  $R^s$  dengan menggunakan metode *Least Square Estimator* (LSE) untuk mengidentifikasi parameter-parameter linearnya. LSE merupakan pembelajaran *off-line* dengan menggunakan metode *invers*.

### 8) Menentukan *Output Akhir*

Nilai  $y_i$  \*akhir dapat diperoleh sebagai berikut [11]:

$$y_i^* = \frac{\sum_{s=1}^r f_s(x_i) \mu_{As}(x_i)}{\sum_{s=1}^r \mu_{As}(x_i)}$$

dengan.  $i=1,2,\dots,N$

$y_i^*$  = *output* akhir

$\mu_{As}(x_i)$  = derajat keanggotaan tiap  $x_i$  dalam himpunan *fuzzy*  $A$  pada aturan *fuzzy* ke- $s$  bagian anteseden

$f_s(x_i)$  = *Output* jaringan hasil pembelajaran tiap  $x_i$  pada setiap aturan inferensi *fuzzy*  $R^s$  pada bagian konsekuen

### 9) Mengukur Kesalahan Peramalan

Untuk mengecek besar kesalahan peramalan, dapat diketahui dengan menghitung selisih antara nilai asli dengan nilai peramalannya, yang dikenal dengan nama *error* atau galat. Dalam penelitian ini cara pengukuran yang digunakan untuk mengetahui besarnya kesalahan yang dihasilkan oleh model peramalan menggunakan *Mean Square Error* (MSE).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y - \hat{Y})^2$$

## HASIL DAN PEMBAHASAN

Pada penelitian ini, model *wavelet neuro fuzzy* adalah model wavelet dengan *Mother Haar level 1* dengan sistem inferensi *fuzzy* model Sugeno. Data yang digunakan dalam penelitian ini adalah data Tinggi Muka Air (TMA) dari pos *AWRL Serenan* pada tanggal 1-30 Oktober 2016. Model *Wavelet Neuro Fuzzy* yang digunakan dalam penelitian ini adalah model *wavelet neuro fuzzy* sugeno orde nol dengan fungsi aktivasi *sigmoid biner* antara lapisan *input* dengan lapisan tersembunyi dan lapisan tersembunyi dengan lapisan *output*. Langkah-langkah peramalan banjir menggunakan *wavelet neuro fuzzy* sugeno orde nol dengan fungsi aktivasi *sigmoid biner* antara lapisan *input* dengan lapisan tersembunyi dan lapisan tersembunyi dengan lapisan *output* adalah sebagai berikut.

#### a. Proses Transformasi Data

Proses transformasi *wavelet* mendekomposisikan data sebenarnya menjadi data DW1 ( $d$ ) dan data *approximation* ( $a$ ). langkah selanjutnya menghitung korelasi antara *approximation* dengan data sebenarnya (tma) dan antara DW1 dengan tma. Korelasi antara data *approximation* dengan data tma

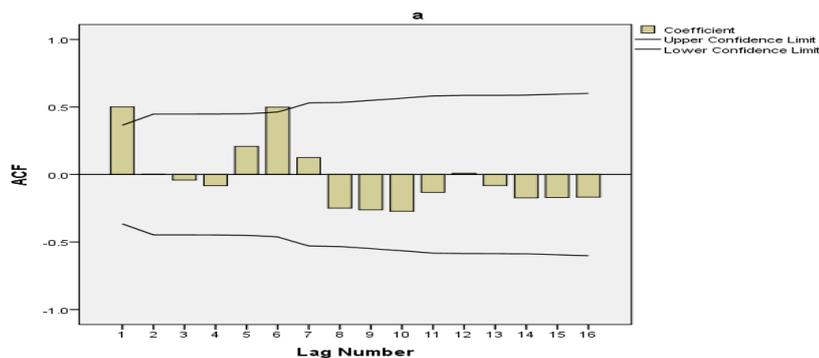
sebesar 0.914. Sedangkan korelasi antara data DW1 dengan data tma sebesar 0.406. Dari hasil perhitungan korelasi *approximation* dan DW1 dengan data sebenarnya diperoleh korelasi yang paling besar adalah korelasi antara data *approximation* dengan tma. Sehingga nilai *approximation* digunakan sebagai *input* dari model *neuro fuzzy*.

Tabel 1. DWs yang digunakan sebagai input *neuro fuzzy*.

t	DWs	t	DWs
1	1.425	16	2.475
2	1.425	17	1.775
3	2.375	18	1.775
4	2.375	19	1.335
5	1.825	20	1.335
6	1.825	21	1.305
7	1.45	22	1.305
8	1.45	23	1.45
9	2.775	24	1.45
10	2.775	25	1.515
11	1.925	26	1.515
12	1.925	27	1.65
13	1.655	28	1.65
14	1.655	29	1.77
15	2.475	30	1.77

**b. Penentuan banyaknya *input* model**

Data *input* ditentukan dengan menggunakan *plot* fungsi autokorelasi (ACF) dari hasil DWT. Banyaknya lag yang keluar atau melebihi batas garis signifikansi menunjukkan banyaknya variabel yang akan digunakan dalam membangun model.



Gambar 1. Diagram ACF

Berdasarkan Gambar 1, lag yang keluar ada pada lag ke-1 dan 6, sehingga model yang akan dibangun menggunakan 2 variabel *input* dengan 28 pasang data. *Input* yang digunakan adalah lag ke-1 sebagai *input* pertama ( $x_1$ ) dan lag ke-6 sebagai *input* kedua ( $x_2$ ).

**c. Pemilihan variabel *input-output* pada data pelatihan**

Pemilihan variabel *input* dan *output* ditetapkan dengan pemilihan variabel *input*  $x_1$  dan  $x_2$  yang berhubungan dengan  $y, j = 1, 2, 3, \dots, 30$  menggunakan jaringan *backpropagation* dengan metode

eliminasi *backward* dan fungsi biaya *SEE*. Pasangan *input-input* sebanyak 28 data yang telah dipilih. Selanjutnya 28 pasang data tersebut dibagi menjadi 2 yaitu *Training data* (TRD) dan *Checking data* (CHD) dengan komposisi pembagian yang digunakan adalah 75% untuk TRD dan 25% untuk CHD. Data TRD terdapat 21 pasang seperti pada tabel 2. dan data CHD terdapat 7 pasang seperti pada tabel 3.

Tabel 2. Tabel pasangan TRD *Input* dan *Output* data tma.

Data Ke-	Variabel Input		Target Output ( $y$ )	Data Ke-	Variabel Input		Target Output ( $y$ )
	$x_2$	$x_1$			$x_2$	$x_1$	
1	1.425	1.425	2.9	12	1.925	1.655	1.69
2	1.425	2.375	1.85	13	1.655	1.655	2.4
3	2.375	2.375	2	14	1.655	2.475	2.55
4	2.375	1.825	1.65	15	2.475	2.475	1.9
5	1.825	1.825	1.5	16	2.475	1.775	1.65
6	1.825	1.45	1.4	17	1.775	1.775	1.52
7	1.45	1.45	2.5	18	1.775	1.335	1.15
8	1.45	2.775	3.05	19	1.335	1.335	1.4
9	2.775	2.775	2	20	1.335	1.305	1.21
10	2.775	1.925	1.85	21	1.305	1.305	1.42
11	1.925	1.925	1.62				

Tabel 3. Tabel pasangan CHD *Input* dan *Output* data tma.

Data Ke-	Variabel Input		Target Output ( $y$ )
	$x_2$	$x_1$	
1	1.45	1.45	1.48
2	1.45	1.515	1.41
3	1.515	1.515	1.62
4	1.515	1.65	1.75
5	1.65	1.65	1.55
6	1.65	1.77	2
7	1.77	1.77	1.54

Seleksi variabel dilakukan dengan cara mengeliminasi variabel-variabel yang tidak diperlukan dan mempertahankan variabel-variabel yang memberikan korelasi yang cukup signifikan terhadap variabel *output*  $y_i$ . Proses tersebut dilakukan dengan menentukan nilai SSE terkecil pada setiap variabel yang dieliminasi. Sebelum menghitung nilai SSE TRD, terlebih dahulu perlu dilakukan perhitungan untuk mengetahui jumlah neuron pada lapisan tersembunyi. Pemilihan jumlah *neuron* pada lapisan tersembunyi dilakukan dengan perhitungan terhadap nilai *Mean Square Error* (MSE) pada TRD. Nilai MSE terkecil akan menetapkan jumlah *neuron* yang akan digunakan pada model jaringan. Tabel 4 berikut adalah hasil perhitungan SSE data TRD dan CHD.

Tabel 4. Perbandingan SSE data TRD dan CHD

Variabel yang dieliminasi	SSE
Tidak ada yang dieliminasi	5.526
$x_1$	5.500
$x_2$	6.773

SSE yang diperoleh pada saat variabel  $x_1$  dieliminasi cukup kecil sehingga penghapusan  $x_1$  akan memberikan model yang lebih baik, sehingga variabel input yang berpartisipasi pada bagian anteseden (bagian If) adalah variabel  $x_2$  dengan target *output*  $y_i$ .

**d. Pengelompokan (*Clustering*) data pelatihan**

Pada bagian ini, data TRD dan CHD akan dibagi menjadi  $r$  kelas ( $r \geq 2$ ) dengan menggunakan metode pengclusteran FCM, sehingga akan memiliki  $r$  buah aturan  $R^s$ ,  $s = 1, 2, \dots, r$ . Dalam penelitian ini data TRD dan CHD akan dibagi menjadi 2 kelas, sehingga diperoleh 2 buah aturan  $R^s$ ,  $s = 1, 2$ . Pasangan input dan output pada aturan ke- $s$  direpresentasikan sebagai  $(x_i^s, y_i^s)$ ,  $i = 1, 2, \dots, N_s$  dengan  $N_s$  adalah jumlah data yang masuk pada kelas ke- $s$ . Berdasarkan hasil *clustering*, diperoleh nilai keanggotaan setiap data pada setiap *cluster* dan kecenderungan suatu data masuk ke suatu *cluster* seperti tabel 5 dan 6 berikut.

Tabel 5. Nilai keanggotaan data TRD pada *cluster* tertentu

Data Ke-	Matriks Partisi			Maks $\mu_{ik}$	Cluster Ke-	Data Ke-	Matriks Partisi			Maks $\mu_{ik}$	Cluster Ke-
	$\mu_{i1}$	$\mu_{i2}$	$\mu_{ik}$				$\mu_{i1}$	$\mu_{i2}$	$\mu_{ik}$		
1	0.073	0.927	0.927	0.927	2	12	0.985	0.015	0.985	0.985	1
2	0.577	0.423	0.577	0.577	1	13	0.029	0.971	0.971	0.971	2
3	0.729	0.271	0.729	0.729	1	14	0.004	0.996	0.996	0.996	2
4	0.893	0.107	0.893	0.893	1	15	0.77	0.23	0.77	0.77	1
5	0.975	0.025	0.975	0.975	1	16	0.858	0.142	0.858	0.858	1
6	0.961	0.039	0.961	0.961	1	17	0.962	0.038	0.962	0.962	1
7	0.019	0.981	0.981	0.981	2	18	0.896	0.104	0.896	0.896	1
8	0.105	0.895	0.895	0.895	2	19	0.756	0.244	0.756	0.756	1
9	0.673	0.327	0.673	0.673	1	20	0.771	0.229	0.771	0.771	1
10	0.723	0.277	0.723	0.723	1	21	0.739	0.261	0.739	0.739	1
11	0.997	0.003	0.997	0.997	1						

Tabel 6. Kecenderungan data CHD pada *cluster* tertentu

Data ke-	Matriks partisi		Maks $\mu_{ik}$	Cluster ke-
	$\mu_{i1}$	$\mu_{i2}$		
1	0.944	0.056	0.944	1
2	0.920	0.080	0.920	1
3	0.905	0.095	0.905	1
4	0.414	0.586	0.586	2
5	0.928	0.072	0.928	1

6	0.038	0.962	0.962	2
7	0.770	0.230	0.770	1

**e. Pembelajaran jaringan syaraf yang berhubungan dengan bagian *anteseden* (bagian *IF*) pada aturan-aturan inferensi *fuzzy*.**

Setiap vector pada data TRD dan CHD, ditentukan  $m_i = (m_i^1, m_i^2, \dots, m_i^r), i = 1, 2, \dots, 21, r =$  banyaknya kelas, untuk data TRD dan  $i = 1, 2, \dots, 7$  untuk data CHD. Selanjutnya akan dilatih jaringan syaraf tiruan dengan variabel *input*  $x_2$  dengan target *output*  $m_1$  dan  $m_2$  menggunakan metode *backpropagation*, fungsi aktivasi *sigmoid bipolar* dengan satu lapisan tersembunyi, parameter yang digunakan adalah maksimum epoch = 50, laju pembelajaran = 1 dan toleransi error =  $10^{-6}$ , dengan banyaknya *neuron* pada lapisan tersembunyi pada penelitian ini menggunakan 1 *input*. Hasil pembelajaran berupa suatu nilai keanggotaan setiap data pada himpunan fuzzy A pada aturan fuzzy ke- $s$  bagian anteseden.  $\mu_{As}(x_i) = \hat{m}_i^s; i = 1, 2, \dots, N; s = 1, 2, \dots, r$ . Hasil pembelajarannya dapat dilihat dalam tabel 5.81 berikut.

Tabel 5.81 Nilai Keanggotaan pada bagian IF ( $\mu_{As}$ ) TRD & CHD

Data	Nilai Keanggotaan		Data	Nilai Keanggotaan	
Ke-	$\mu_{A1}$	$\mu_{A2}$	Ke-	$\mu_{A1}$	$\mu_{A2}$
1	0.73427	0.534998	15	0.728239	0.368341
2	0.525417	0.690436	16	0.805642	0.150389
3	0.899928	0.259985	17	0.456985	0.576987
4	0.901738	0.145845	18	0.805995	0.111831
5	0.878942	0.160917	19	0.4996	0.533178
6	0.883612	0.088155	20	0.770107	0.164245
7	0.790417	0.294874	21	0.796418	0.082579
8	0.583958	0.618724	22	0.87374	-0.152765
9	0.85803	0.269222	23	0.872358	-0.083023
10	0.863105	0.153083	24	0.887911	-0.10089
11	0.741868	0.361793	25	0.888174	-0.055453
12	0.811706	0.158686	26	0.863888	0.357202
13	0.725732	0.296987	27	0.876676	0.225351
14	0.328436	0.709307	28	0.855406	0.47831

**f. Pembelajaran jaringan syaraf yang berhubungan dengan bagian konsekuensi (bagian *THEN*) pada aturan-aturan inferensi *fuzzy*.**

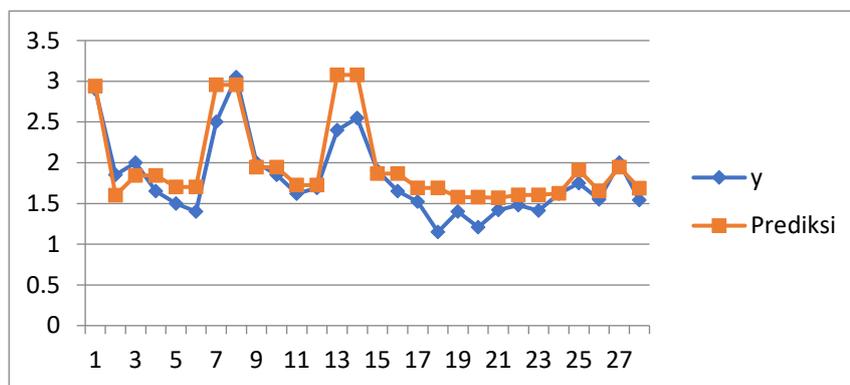
Pada bagian ini akan dilakukan pembelajaran jaringan syaraf pada bagian THEN dari  $R^s$  dengan input  $x = (x_{i1}^s, x_{i2}^s, x_{i3}^s, \dots, x_{im}^s)$  dan target output  $y_i^s, i = 1, 2, \dots, 21; s = 1, 2$ . Proses pembelajaran dibagi menjadi 2 proses pembelajaran sesuai dengan jumlah *cluster* yang ditentukan, yaitu  $R^1(NN_1)$ , dan  $R^2(NN_2)$ . Proses selanjutnya adalah pembelajaran tiap  $NNs$  menggunakan jaringan *Backpropagation levenbergh marquardt* dengan 1 lapisan tersembunyi, dengan parameter: maksimum epoch 5,  $\mu = 0.75$  dan  $\beta = 2$ , dan toleransi error =  $10^{-6}$ . Fungsi aktivasi yang digunakan antara lapisan *input* dengan lapisan tersembunyi adalah fungsi *sigmoid biner* yang juga untuk lapisan antara lapisan tersembunyi dan lapisan *output*.

**g. Penyederhanaan bagian konsekuen (bagian THEN) menggunakan metode eliminasi backward**

Dalam penelitian ini bagian penyederhanaan bagian konsekuen tidak dilakukan, karena hanya mengandung satu variabel input saja yaitu  $x_2$ , jadi tidak ada variabel lain yang dieliminasi.

**h. Penentuan Output akhir**

Hasil prediksi banjir sungai Bengawan Solo dapat dilihat pada gambar 2 berikut.



Gambar 2. prediksi banjir sungai Bengawan Solo

**i. Penentuan MSE**

Nilai MSE hasil prediksi banjir sungai Bengawan Solo adalah sebagai berikut.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_i^*)^2 = 0.0613$$

**SIMPULAN DAN SARAN**

Berdasarkan uraian hasil penelitian dan pembahasan maka penulis dapat memberikan kesimpulan bahwa model *wavelet neuro fuzzy* dapat diterapkan untuk memprediksi banjir sungai Bengawan Solo. Dalam penerapannya model wavelet yang digunakan adalah *Mother Haar level 1* dengan sistem inferensi *fuzzy* model Sugeno orde nol dengan fungsi aktivasi *sigmoid biner* antara lapisan *input* dengan lapisan tersembunyi dan lapisan tersembunyi dengan lapisan *output*. Hasil prediksi dengan menggunakan metode *wavelet Neuro Fuzzy* diperoleh nilai *Mean Square Error* (MSE) adalah 0.0613. Saran yang diajukan dari hasil penelitian ini adalah memperbanyak data *training wavelet Neuro Fuzzy* untuk meningkatkan performa dari struktur *wavelet Neuro Fuzzy* yang disusun.

**DAFTAR PUSTAKA**

[1] B. N. P. B. RI, “Data Bencana Indonesia,” *Jkt. BNPB*, 2015.  
 [2] A. Findayani, “Kesiapsiagaan Masyarakat Dalam Penanggulangan Banjir Di Kota Semarang,” *J. Geogr. Media Informasi Pengemb. Ilmu Dan Profesi Kegeografian*, Jan. 2015.  
 [3] Dewan Perwakilan Rakyat Republik Indonesia and Presiden Republik Indonesia, *Undang-Undang Republik Indonesia Nomor 24 Tahun 2007 Tentang Penanggulangan Bencana Dengan Rahmat Tuhan Yang Maha Esa Presiden Republik Indonesia*. .

- [4] Y. Bodyanskiy, I. Pliss, and O. Vynokurova, "Adaptive wavelet-neuro-fuzzy network in the forecasting and emulation tasks," *Int J. Inf. Theory Appl.*, vol. 15, no. 1, pp. 47–55, 2008.
- [5] Fereydooni, M. and Pezhman, S, "Use Of Hybrid Wavelet-Neural And Wavelet Neuro-Fuzzy Model In Simulation Of Rate Of Flow Of River (Study Case: Fahlian River)," *Indian J. Fundam. Appl. Life Sci.*, vol. 5, no. 3, pp. 692–701, 2015.
- [6] Ö. Kişi, "Streamflow forecasting using different artificial neural network algorithms," *J. Hydrol. Eng.*, vol. 12, no. 5, pp. 532–539, 2007.
- [7] L. Fausset, "Fundamentals of neural networks," *Archit. Algorithm Appl. Prentice Hall*, 1994.
- [8] Nabizadeh M, Mosaedi A, and Dehghani A, "Intelligent estimation of rate of flow by utilizing ANFIS (Adaptive-Network-Based Fuzzy Inference System)," *Water Irrig. Manag.*, vol. 2, no. 1, pp. 69–80, 2011.
- [9] Sielvy E., "Aplikasi Model Neuro Fuzzy untuk Memprediksi Harga Emas," Skripsi, UNY, Yogyakarta, 2013.
- [10] A. Setiaji, "Aplikasi model wavelet-neuro-fuzzy untuk memprediksi nilai tukar euro terhadap dollar amerika," PhD Thesis, UNY, 2014.
- [11] C.-T. Lin and C. G. Lee, "Neural fuzzy systems," *PTR Prentice Hall*, 1996.