

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

Nurmalitasari¹, Sri Sumarlinda²

^{1,2}STMIK Duta Bangsa

¹nurmalitasari@stmikdb.ac.id, ²srisumarlinda78@gmail.com

Submitted :19-02-2018, Revised: 27-05-2018, Accepted: 04-06-2018

Abstract

The objectives of this research 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 research 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 research 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.

Keywords: *Forecasting, Bengawan Solo River, Wavelet neuro fuzzy, MSE*

Abstrak

Penelitian ini bertujuan mengimplementasikan metode *wavelet neuro fuzzy* untuk memprediksi tinggi muka air (tma) sungai Bengawan Solo. Metode *wavelet neuro fuzzy* merupakan penggabungan model antara transformasi *wavelet* diskrit, *Artificial Neural Network* (ANN) dan logika *fuzzy*. Pemodelan *wavelet neuro fuzzy* ini bertujuan untuk mengurangi kelemahan dari masing-masing sistem, serta menggabungkan kelebihan yang ada dari masing-masing sistem, sehingga hasil prediksi memiliki nilai *error* yang sangat kecil. Model *wavelet neuro fuzzy* yang digunakan dalam penelitian ini adalah model *wavelet* dengan *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. Prediksi kapan terjadinya banjir penting dilakukan karena dengan hasil prediksi mampu memberikan informasi peringatan dini kepada masyarakat disekitar sungai kapan waktu datangnya banjir sehingga mengurangi risiko terkena bencana serta mempersiapkan tindakan tanggap darurat. Data yang digunakan dalam penelitian ini adalah data tinggi muka air yang diperoleh dari pos *Automatic Water Level Recorder (AWLR)* Serenan. Hasil implemmentasi dari metode *wavelet neuro fuzzy* menunjukkan *Mean Square error* (MSE) peramalan sebesar 0,0613.

Kata Kunci: Peramalan, Sungai Bengawan Solo, *Wavelet neuro fuzzy*, MSE

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 (RI, 2015). Banjir merupakan fenomena alam yang tidak dapat dicegah, tetapi dapat dikurangi (Toth, Brath, & Montanari, 2000). 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 (Undang-undang No. 24 Tahun 2007). 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* (Bodyanskiy, Pliss, & Vynokurova, 2008; Fereydooni, M. & Pezhman, S, 2015; Kişi, 2007). 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 (Bodyanskiy dkk., 2008; Fereydooni, M. & Pezhman, S, 2015; Kişi, 2007). Metode selanjutnya, *neuro fuzzy* adalah penggabungan dua sistem, yaitu *Artificial Neural Network (ANN)* atau jaringan syaraf tiruan dengan logika *fuzzy* (Karl *et.al*, 2010; Fausset, 1994; Nabizadeh M, Mosaedi A, & Dehghani A, 2011). Sedangkan, logika *fuzzy* merupakan representasi pengetahuan yang dikonstruksikan dengan IF-THEN *rules* (Sielvy, 2013). Pemodelan *wavelet neuro fuzzy* bertujuan untuk mengurangi kelemahan dari masing-masing sistem, serta menggabungkan kelebihan yang ada dari masing-masing system (Bodyanskiy dkk., 2008; Fereydooni, M. & Pezhman, S, 2015; Kişi, 2007).

Prediksi dengan menggunakan metode *wavelet neuro fuzzy* pernah dilakukan dalam memprediksi curah hujan harian (Kişi, 2007), memprediksi dan *emulation* tugas (Bodyanskiy dkk., 2008), memprediksi nilai tukar euro terhadap dollar Amerika (Setiaji, 2014), memprediksi banjir di sungai Fahlian dengan menggunakan data *Runoff* (Fereydooni, M. & Pezhman, S, 2015). 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 PENELITIAN

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 (Lin & Lee, 1996)

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 pengelusteran *Fuzzy C-Means*

(FCM). FCM adalah teknik pengclusteran 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 (Lin & Lee, 1996):

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

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 (Lin & Lee, 1996):

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

dengan $i = 1, 2, \dots, N$, $s = 1, 2, \dots, r$ dan μ_{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

$\mu_{As}(x_i)$ = 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*

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

$\mu_{A_s}(x_i)$ = 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 $E_m^s > E_m^{sp}$ 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 (Lin, 1996):

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

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

y_i * = *output* akhir

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

Tabel 6. Kecenderungan data CHD pada *cluster* tertentu

Data ke-	Matriks partisi		Maks μ_{ik}	Cluster ke-
	μ_{i1}	μ_{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 eror = 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 (μ_{As}) TRD & CHD

Data	Nilai Keanggotaan		Data	Nilai Keanggotaan	
Ke-	μ_{A1}	μ_{A2}	Ke-	μ_{A1}	μ_{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 konsekuen (bagian *THEN*) pada aturan-aturan inferensi *fuzzy*.

Pada bagian ini akan dilakukan pembelajaran jaringan syaraf pada bagian THEN dari R^s dengan input $x = (x_{i1}^s, x_{i2}^s, x_{i3}^s, \dots, x_{im}^s)$ 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 *Bacpropagation lavenbergh 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 dari bab sebelumnya 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

- Bodyanskiy, Y., Pliss, I., & Vynokurova, O. (2008). Adaptive wavelet-neuro-fuzzy network in the forecasting and emulation tasks. *Int. journal on information theory and applications*, 15(1), 47–55.
- Fausset, L. (1994). Fundamentals of neural networks. *Architecture, Algorithm and Application*. Prentice Hall.
- Fereydooni, M., & Pezhman, S. (2015). Use Of Hybrid Wavelet-Neural And Wavelet Neuro-Fuzzy Model In Simulation Of Rate Of Flow Of River (Study Case: Fahlian River). *Indian Journal of Fundamental and Applied Life Sciences*, 5(3), 692–701.

- Karl, A., Lohani, A., Goel, N., and Roy, G. (2010), Development of Flood Forecasting System Using Statistical and ANN Techniques in the Downstream Catchment of Mahanadi Basin India, *Journal of Water Resource and Protection*, 10(2), 880-886.
- Kişi, Ö. (2007). Streamflow forecasting using different artificial neural network algorithms. *Journal of Hydrologic Engineering*, 12(5), 532–539.
- Lin, C.-T., & Lee, C. G. (1996). Neural fuzzy systems. PTR Prentice Hall.
- Nabizadeh M, Mosaedi A, & Dehghani A. (2011). Intelligent estimation of rate of flow by utilizing ANFIS (Adaptive-Network-Based Fuzzy Inference System). *Water and Irrigation Management*, 2(1), 69–80.
- RI, B. N. P. B. (2015). Data Bencana Indonesia. Jakarta: BNPB.
- Setiaji, A. (2014). *Aplikasi model wavelet-neuro-fuzzy untuk memprediksi nilai tukar euro terhadap dollar amerika* (PhD Thesis). UNY.
- Sielvy E. (2013). *Aplikasi Model Neuro Fuzzy untuk Memprediksi Harga Emas* (Skripsi). UNY, Yogyakarta.
- Toth, E., Brath, A., and Montanari, A. (2000). Comparison of short-term rainfall prediktion models for real-time flood forecasting. *Journal of Hydrology*, 239(1), 132-147).