

MODEL HIDROLOGI RUNTUN WAKTU UNTUK PERAMALAN DEBIT SUNGAI MENGUNAKAN METODE *ARTIFICIAL NEURAL NETWORK* (ANN) (Studi Kasus : Sub DAS Siak Hulu)

Rendy Fadly¹⁾, Imam Suprayogi²⁾, Manyuk Fauzi²⁾

¹⁾Mahasiswa Jurusan Teknik Sipil, Fakultas Teknik, Universitas Riau

²⁾Dosen Jurusan Teknik Sipil, Fakultas Teknik, Universitas Riau

Kampus Bina Widya Jln. HR Soebrantas KM 12,5 Pekanbaru, Kode Pos 28293

Email : rendy.fadly@gmail.com

Abstract

ANN method is a soft computing method that can predict streamflow. predict streamflow is needed at the present time, one of which is for early warning flood. Judging from the success of the research is the application of ANN method, it is necessary to prove the performance of the ANN method to predict streamflow in Siak Hulu Sub-Watershed.

The data used for the development of ANN model predict streamflow in Siak Hulu Sub-Watershed is derived from the historical recording of data in Automatic Water Level Record (AWLR) station of Pantai Cermin from 2002 to 2012 (except 2007). ANN model development consists of 4 forecasting scheme is then compared to obtain the best model. In each of the schemes carried out the training process, testing, and validation. The algorithm used in the development of ANN model is backpropagation algorithm.

The results obtained in this study indicate that the performance of the ANN model that has been made to produce the value of the test statistic parameters of the correlation coefficient (R) categorized as a very strong correlation. The best forecasting scheme obtained that the forecasting scheme for one day to the next (Q_{t+1}) which resulted in a correlation coefficient (R) is 0.94903.

Keywords: forecasting streamflow, ANN, Siak Hulu sub-watershed.

A. PENDAHULUAN

Model hidrologi adalah gambaran sederhana dari suatu sistem hidrologi yang aktual (Harto, 1993). Adapun tujuan dari model hidrologi adalah untuk mempelajari siklus air yang ada di alam dan meramalkan outputnya. Model hidrologi dapat digunakan untuk peramalan banjir, perencanaan bendungan, pengaturan bendungan, pengelolaan, dan pengembangan DAS (Indarto, 2010).

Saat ini sudah banyak model hidrologi yang dibuat untuk berbagai macam kepentingan, salah satunya adalah untuk peramalan debit aliran sungai. Peramalan debit aliran sungai dirasa sangat penting untuk masa yang akan datang, terutama untuk sistem peringatan dini banjir. Menurut Indarto (2010) berbagai macam model hidrologi mulai dari yang sederhana sampai yang kompleks telah

banyak dikembangkan untuk menganalisis dan memprediksi fenomena hidrologi, namun sangat rumit jika fenomena hidrologi diprediksi dengan menggunakan model fisik atau model matematik, sehingga para ilmuwan akan selalu bergelut dengan pemodelan *soft computing*.

Pada dekade terakhir ini, model *soft computing* sebagai cabang dari ilmu kecerdasan buatan diperkenalkan sebagai alat peramalan seperti sistem berbasis pengetahuan, sistem pakar, logika *fuzzy*, *artificial neural network* (ANN) dan algoritma genetika (Suyanto, 2008). Deka dkk (2013) telah berhasil membangun sebuah pendekatan model hidrologi yaitu dengan menggunakan metode Wavelet-ANN untuk memprediksi debit aliran pada Sungai Brahmaputra, India. Pada penelitian ini Deka menggunakan 10 tahun data debit harian dari tahun 1990 hingga tahun 1999

untuk mendapatkan nilai debit prediksi 2 hari ke depan, 3 hari ke depan dan 4 hari ke depan. Dengan melihat dari nilai RMSE hasil penelitian Deka, disimpulkan bahwa unjuk kerja model Wavelet-ANN sangat baik. Selain itu Mahyudin (2013) juga telah menerapkan pemodelan hidrologi dengan membangun model prediksi liku kalibrasi dengan menggunakan pendekatan model ANN pada Sub DAS Siak Hulu. Hasil penelitian Mahyudin menunjukan bahwa model ANN dapat menghasilkan persamaan liku kalibrasi dengan nilai uji parameter statistik R sebesar 0,9975, dan masuk ke dalam kriteria sangat kuat.

Sungai Siak merupakan salah satu sungai besar yang mendapatkan perhatian secara nasional, karena sungai tersebut memiliki fungsi dan peranan yang sangat besar dalam perkembangan wilayah dan ekonomi baik secara lokal, regional maupun nasional. Sungai Siak adalah salah satu sungai yang secara keseluruhan dari hulu hingga hilirnya berada di wilayah Provinsi Riau yang melewati beberapa Kabupaten/Kota, yaitu Kabupaten Rokan Hulu, Kabupaten Kampar, Kota Pekanbaru, Kabupaten Bengkalis dan Kabupaten Siak (Sudiana dkk, 2007)..

Dari latar belakang yang telah dipaparkan di atas, maka yang menjadi rumusan masalah pada penelitian ini adalah bagaimana konfigurasi model jaringan ANN untuk peramalan debit aliran sungai pada Sub DAS Siak Hulu, apa saja parameter-parameter yang berpengaruh pada ketepatan hasil dari model ANN untuk peramalan debit aliran sungai pada Sub DAS Siak Hulu, dan bagaimana tingkat kemampuan hasil dari model ANN dibandingkan dengan model Transformasi Wavelet-ANN pada peramalan debit aliran sungai pada Sub DAS Siak Hulu.

1. ANN (*Artificial Neural Network*)

Menurut Sutojo (2011) ANN adalah paradigma pengolahan informasi yang terinspirasi oleh sistem saraf secara biologis, seperti proses informasi pada otak manusia. Elemen kunci dari paradigma ini

adalah struktur dari sistem pengolahan informasi yang terdiri dari sejumlah besar elemen pemrosesan yang saling berhubungan (*neuron*), bekerja serentak untuk menyelesaikan masalah tertentu. Cara kerja ANN ini sama seperti cara kerja otak manusia, yaitu belajar melalui contoh. Sebuah ANN dikonfigurasi untuk aplikasi tertentu, seperti pengenalan pola atau klasifikasi data, melalui proses pembelajaran. Belajar dalam sistem biologis melibatkan penyesuaian terhadap koneksi *synaptic* yang ada antara *neuron*. Hal ini berlaku juga untuk ANN.

Menurut Siang (2005) ANN dibentuk sebagai generalisasi model matematika dari ANN biologi dengan asumsi sebagai berikut :

1. pemrosesan informasi terjadi pada banyak elemen sederhana (*neurons*),
2. sinyal dikirimkan diantara *neuron-neuron* melalui penghubung-penghubung,
3. penghubung antar *neuron* memiliki bobot yang akan memperkuat atau memperlemah sinyal,
4. untuk menentukan keluaran (*output*), setiap *neuron* menggunakan fungsi aktivasi yang dikenakan pada penjumlahan masukan (*input*) yang diterima. Besarnya keluaran (*output*) ini selanjutnya dibandingkan dengan suatu batas ambang,


Neuron adalah unit pemroses informasi yang menjadi dasar dalam pengoperasian ANN. *Neuron* terdiri dari 3 elemen pembentuk sebagai berikut :

1. himpunan unit-unit yang dihubungkan dengan jalur koneksi.
2. suatu unit penjumlah yang akan menjumlahkan masukan-masukan sinyal yang sudah dikalikan dengan bobotnya,
3. fungsi aktivasi yang akan menentukan apakah sinyal dari *input neuron* akan diteruskan ke *neuron* lain atautkah tidak.

2. *Backpropagation*

Menurut Kusumadewi (2004), *backpropagation* adalah algoritma pembelajaran yang terawasi dan biasanya

digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyinya. Algoritma *backpropagation* menggunakan *error output* untuk mengubah nilai-nilai bobot-bobotnya dalam arah mundur (*backward*). Untuk mendapatkan *error* ini, tahap perambatan maju (*forward propagation*) harus dikerjakan terlebih dahulu. Pada saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi. Arsitektur jaringan *backpropagation* dapat dilihat seperti Gambar berikut :



Gambar 1. Arsitektur Jaringan
Backpropagation

(Sumber : Kusumadewi, 2004)

2. Kriteria Tingkat Kesalahan

Menurut Arun Goel (2011), ada 2 kriteria tingkat kesalahan yaitu nilai *Root Mean Square Error* (RMSE) dan *Correlation Coefficient* (R). *Root Mean Square Error* (RMSE) merupakan besarnya tingkat kesalahan hasil prediksi, dimana semakin kecil (mendekati 0) nilai RMSE maka hasil prediksi akan semakin akurat. Sedangkan *Correlation Coefficient* (R) merupakan perbandingan antara nilai prediksi dengan nilai sebenarnya. Nilai R dapat dihitung dengan persamaan berikut :

$$R = \frac{\sum xy}{\sqrt{\sum x^2 \sum y^2}}$$

dengan:

$x = X - X'$, $y = Y - Y'$
 X = Nilai pengamatan
 X' = Rata-rata nilai X
 Y = Nilai Prediksi
 Y' = Rata-rata nilai Y

Untuk memudahkan melakukan interpretasi mengenai kekuatan hubungan antara dua variabel dibuat kriteria sebagai berikut :

- $R = 0$, dimana Tidak ada korelasi antara dua variabel,
- $0 < R \leq 0,25$, dimana korelasi sangat lemah,
- $0,25 < R \leq 0,50$, dimana korelasi cukup,
- $0,50 < R \leq 0,75$, dimana korelasi kuat,
- $0,75 < R \leq 0,99$, dimana korelasi sangat kuat, dan
- $R = 1,00$, dimana korelasi sempurna.

Sedangkan nilai RMSE dapat dihitung dengan persamaan sebagai berikut :

$$RMSE = \left[\frac{\sum (X - Y)^2}{n} \right]^{0.5}$$

dengan:

n = Jumlah data,
 X = nilai pengamatan,
 Y = nilai prediksi.

B. METODOLOGI PENELITIAN

Lokasi pada penelitian ini adalah Sungai Siak Sub DAS Siak Hulu Stasiun Pantai Cermin Kecamatan Tapung Kabupaten Kampar Provinsi Riau, yang mewakili Sungai Tapung Kiri.

1. Pengumpulan dan Pengelompokan Data

Pengumpulan data pada penelitian ini didapat dari Balai Wilayah Sungai Sumatera III Provinsi Riau Jl. Cut Nyak Dien 01, Pekanbaru. Data yang didapat antara lain :

1. *Discharge hydrograph* pada Stasiun *Automatic Water Level Record* (AWLR) Pantai Cermin yang mewakili Sungai Tapung Kiri tahun 2002 sampai 2008 (kecuali 2007).
2. *Stage hydrograph* pada Stasiun *Automatic Water Level Record* (AWLR) Pantai Cermin untuk tahun 2009 sampai 2012 yang diubah menjadi *discharge hydrograph* menggunakan persamaan liku kalibrasi yang dikembangkan oleh Mahyudin (2013) menggunakan pendekatan Model ANN.

Sedangkan untuk pengelompokan data-datanya adalah sebagai berikut :

1. Untuk data pelatihan (*training*) digunakan data sebanyak 70% dari total data tahun 2002 sampai 2010 (kecuali tahun 2007).
2. Untuk data pengujian (*testing*) digunakan data sebanyak 30% dari total data tahun 2002 sampai 2010 (kecuali tahun 2007).

3. Untuk data validasi (*validation*) digunakan data sebanyak 100% dari total data tahun 2002 sampai 2010 (kecuali tahun 2007).
4. Dan data debit 2011 dan 2012 digunakan untuk prediksi debit.

C. HASIL DAN PEMBAHASAN

1. Proses *training* Model ANN

Dalam melakukan proses *training* ada parameter-parameter yang harus diperhatikan, seperti fungsi pelatihan, fungsi pembelajaran, jumlah neuron, fungsi aktivasi, epoch, kinerja tujuan, maksimum kegagalan, laju pembelajaran dan momentum. Proses *training* akan selesai jika didapatkan nilai regresi (R) yang bagus. Setelah model didapat langkah selanjutnya adalah melakukan *testing* model dan *validation* model.

Data yang digunakan untuk proses *training* pada skema Q_{t+1} yaitu berjumlah 70% dari data debit tahun 2002-2010. Adapun pemilihan properti dan parameter yang telah dicoba pada *training* skema Q_{t+1} terdapat pada tabel-tabel berikut :

Tabel 1 Nilai R pada Proses *Training* Model ANN Skema Q_{t+1} Berdasarkan Variasi Penggunaan Jumlah *Neuron*

Train	Neuron	Transfer Function		Parameter Jaringan				R
	layer 1	Layer 1	Layer 2	Epoch	Max Fail	Learning Rate	Momentum	
1	5	tansig	tansig	1000	6	0.01	0.9	0.83085
2	10	tansig	tansig	1000	6	0.01	0.9	0.72721
3	15	tansig	tansig	1000	6	0.01	0.9	0.96748
4	20	tansig	tansig	1000	6	0.01	0.9	0.71089
5	25	tansig	tansig	1000	6	0.01	0.9	0.69844
6	30	tansig	tansig	1000	6	0.01	0.9	0.65815
7	35	tansig	tansig	1000	6	0.01	0.9	0.77243
8	40	tansig	tansig	1000	6	0.01	0.9	0.96071
9	45	tansig	tansig	1000	6	0.01	0.9	0.75463
10	50	tansig	tansig	1000	6	0.01	0.9	0.68086
11	55	tansig	tansig	1000	6	0.01	0.9	0.73229
12	60	tansig	tansig	1000	6	0.01	0.9	0.76245
13	65	tansig	tansig	1000	6	0.01	0.9	0.62021
14	70	tansig	tansig	1000	6	0.01	0.9	0.78876
15	75	tansig	tansig	1000	6	0.01	0.9	0.87367
16	80	tansig	tansig	1000	6	0.01	0.9	0.71679
17	85	tansig	tansig	1000	6	0.01	0.9	0.7948
18	90	tansig	tansig	1000	6	0.01	0.9	0.76474
19	95	tansig	tansig	1000	6	0.01	0.9	0.95577
20	100	tansig	tansig	1000	6	0.01	0.9	0.74174

Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 2 Nilai R pada Proses *Training* Model ANN Skema Q_{t+1} Berdasarkan Variasi Penggunaan *Transfer Function*.

Train	Neuron	Transfer Function		Parameter Jaringan				R
	layer 1	Layer 1	Layer 2	Epoch	Max Fail	Learning Rate	Momentum	
1	15	tansig	pureline	1000	6	0.01	0.9	0.96926
2	15	tansig	tansig	1000	6	0.01	0.9	0.96748
3	15	tansig	logsig	1000	6	0.01	0.9	0.3699
4	15	pureline	pureline	1000	6	0.01	0.9	0.96919
5	15	pureline	tansig	1000	6	0.01	0.9	0.84032
6	15	logsig	tansig	1000	6	0.01	0.9	0.95401
7	15	logsig	pureline	1000	6	0.01	0.9	0.96713

Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 3 Nilai R pada Proses *Training* Model ANN Skema Q_{t+1} Berdasarkan Variasi Penggunaan Jumlah *Epoch* dan *Max Fail*

Train	Neuron	Transfer Function		Parameter Jaringan				R
	layer 1	Layer 1	Layer 2	Epoch	Max Fail	Learning Rate	Momentum	
1	15	tansig	pureline	50	6	0.01	0.9	0.81050
2	15	tansig	pureline	100	6	0.01	0.9	0.96297
3	15	tansig	pureline	500	6	0.01	0.9	0.96926
4	15	tansig	pureline	800	6	0.01	0.9	0.96926
5	15	tansig	pureline	1000	6	0.01	0.9	0.96926
6	15	tansig	pureline	1500	6	0.01	0.9	0.96926
7	15	tansig	pureline	1500	500	0.01	0.9	0.97163
8	15	tansig	pureline	1500	700	0.01	0.9	0.97163
9	15	tansig	pureline	1500	1500	0.01	0.9	0.97163
10	15	tansig	pureline	3000	1500	0.01	0.9	0.97174
11	15	tansig	pureline	3000	2000	0.01	0.9	0.97174
12	15	tansig	pureline	5000	3000	0.01	0.9	0.97180
13	15	tansig	pureline	5000	5000	0.01	0.9	0.97180
14	15	tansig	pureline	7000	5000	0.01	0.9	0.97183
15	15	tansig	pureline	10000	10000	0.01	0.9	0.97187

Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 4 Nilai R pada Proses *Training* Model ANN Skema Q_{t+1} Berdasarkan Variasi Penggunaan *Learning Rate*

Train	Neuron	Transfer Function		Parameter Jaringan				R
	layer 1	Layer 1	Layer 2	Epoch	Max Fail	Learning Rate	Momentum	
1	15	tansig	pureline	10000	10000	0.01	0.9	0.97187
2	15	tansig	pureline	10000	10000	0.05	0.9	0.97187
3	15	tansig	pureline	10000	10000	0.1	0.9	0.97187
4	15	tansig	pureline	10000	10000	0.2	0.9	0.97187
5	15	tansig	pureline	10000	10000	0.3	0.9	0.97187
6	15	tansig	pureline	10000	10000	0.4	0.9	0.97187
7	15	tansig	pureline	10000	10000	0.5	0.9	0.97187
8	15	tansig	pureline	10000	10000	0.6	0.9	0.97187
9	15	tansig	pureline	10000	10000	0.7	0.9	0.97185
10	15	tansig	pureline	10000	10000	0.8	0.9	0.97187
11	15	tansig	pureline	10000	10000	0.9	0.9	0.97187
12	15	tansig	pureline	10000	10000	1	0.9	0.97185


Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 5 Nilai R pada Proses *Training* Model ANN Skema Q_{t+1} Berdasarkan Variasi Penggunaan *Momentum*

Train	Neuron	Transfer Function		Parameter Jaringan				R
	layer 1	Layer 1	Layer 2	Epoch	Max Fail	Learning Rate	Momentum	
1	15	tansig	pureline	10000	10000	0.01	0.01	0.96499
2	15	tansig	pureline	10000	10000	0.01	0.05	0.96588
3	15	tansig	pureline	10000	10000	0.01	0.1	0.97100
4	15	tansig	pureline	10000	10000	0.01	0.2	0.97178
5	15	tansig	pureline	10000	10000	0.01	0.3	0.97180
6	15	tansig	pureline	10000	10000	0.01	0.4	0.97181
7	15	tansig	pureline	10000	10000	0.01	0.5	0.97182
8	15	tansig	pureline	10000	10000	0.01	0.6	0.97183
9	15	tansig	pureline	10000	10000	0.01	0.7	0.97184
10	15	tansig	pureline	10000	10000	0.01	0.8	0.97183
11	15	tansig	pureline	10000	10000	0.01	0.9	0.97187
12	15	tansig	pureline	10000	10000	0.01	1	0.89955

Sumber: Hasil *Running* Program Bantu MATLAB


Maka dari itu disimpulkan bahwa model yang terbaik pada proses *training* model ANN untuk Skema Q_{t+1} yaitu menggunakan 15 neuron, *transfer function* berupa *tansig* di layer 1 dan *pureline* di layer 2. Jumlah *epoch* dan *max fail* sebesar 10000, *learning rate* bernilai 0.01 dan *momentum* bernilai 0.9, dengan menggunakan model tersebut didapatkan hasil R sebesar 0.97187. Proses *training* pada Matlab dapat dilihat pada Gambar berikut :



Gambar 3 Hasil Proses *Training* Model

Skema Q_{t+1}

(Sumber: Hasil *Running* Program Bantu MATLAB)



Gambar 2 Proses *Training* Skema Q_{t+1}

(Sumber: Hasil *Running* Program Bantu MATLAB)

Dengan cara yang sama dilakukan juga proses *training* untuk skema Q_{t+2} , Q_{t+3} , dan Q_{t+4} . Berikut disajikan pada Tabel 4.6 untuk model ANN dan hasil R yang dihasilkan pada skema Q_{t+2} , Q_{t+3} , dan Q_{t+4} :


Tabel 6 Nilai R pada Proses *Training* Model ANN Skema Q_{t+2} , Q_{t+3} , dan Q_{t+4} .

Skema	Neuron	Transfer Function		Parameter Jaringan				R
	layer 1	Layer 1	Layer 2	Epoch	Max Fail	Learning Rate	Momentum	
Q_{t+2}	15	tansig	tansig	10000	10000	0.01	0.9	0.91164
Q_{t+3}	15	tansig	pureline	10000	10000	0.05	0.9	0.84809
Q_{t+4}	40	pureline	pureline	10000	10000	0.01	0.9	0.76874

Sumber: Hasil *Running* Program Bantu MATLAB


2. Testing Model ANN

Setelah mendapat model jaringan ANN pada proses *training*, maka selanjutnya model tersebut akan diujikan lagi di dalam proses *testing*. Hal ini bertujuan untuk membuktikan apakah model yang dibangun pada proses *training* tersebut dapat bekerja dengan baik atau tidak pada proses *testing*. Namun data yang digunakan berbeda dengan proses *training*, yaitu menggunakan data sebanyak 30% dari total data tahun 2002-2010. Berikut proses *testing* dan hasilnya untuk skema Q_{t+1} :



Gambar 4 Proses *Testing* Skema Q_{t+1}

(Sumber : Hasil *Running* Program Bantu MATLAB)



Gambar 5 Hasil Proses *Testing* Model

Skema Q_{t+1}

(Sumber : Hasil *Running* Program Bantu MATLAB)

Dari gambar di atas didapatkan hasil nilai R sebesar 0.97792, nilai ini termasuk juga ke dalam kriteria sangat kuat, hal ini berarti model yang telah dibuat pada proses *training* sudah cocok untuk proses *testing*, selanjutnya untuk lebih memastikan lagi akan dilakukan proses *validation*. Sedangkan untuk hasil R proses *testing* pada skema Q_{t+2} , Q_{t+3} , dan Q_{t+4} disajikan pada Tabel berikut :


Tabel 7 Nilai R Proses *Testing* Model ANN Skema Q_{t+2} , Q_{t+3} , dan Q_{t+4} .

Skema	Neuron	Transfer Function		Parameter Jaringan				R
	layer 1	Layer 1	Layer 2	Epoch	Max Fail	Learning Rate	Momentum	
Q_{t+2}	15	tansig	tansig	10000	10000	0.01	0.9	0.92567
Q_{t+3}	15	tansig	pureline	10000	10000	0.05	0.9	0.84798
Q_{t+4}	40	pureline	pureline	10000	10000	0.01	0.9	0.76033


Sumber: Hasil *Running* Program Bantu MATLAB

3. *Validation* model ANN

Setelah proses *testing*, selanjutnya dilakukan proses *validation*. Adapun data yang digunakan pada proses *validation* adalah dengan menggunakan data sebanyak 100% dari tahun 2002-2010, sedangkan property dan parameter model jaringan yang digunakan sama dengan model pada proses *training* dan *testing*. Langkah yang dilakukan juga sama dengan proses *testing*. Berikut proses dan hasil dari *validation* pada skema Q_{t+1} :



Gambar 6 Proses *Validation* Skema Q_{t+1}
(Sumber : Hasil *Runing* Program Bantu MATLAB)



Gambar 7 Hasil Proses *Validation* Model Skema Q_{t+1}
(Sumber : Hasil *Runing* Program Bantu MATLAB)

Dari gambar di atas juga bisa dilihat bahwa nilai R yang dihasilkan juga termasuk ke dalam kriteria yang sangat kuat, maka dari itu disimpulkan bahwa model yang telah dibuat pada skema Q_{t+1} dapat digunakan untuk proses peramalan debit selanjutnya. Sedangkan untuk hasil R proses *validation* pada skema Q_{t+2} , Q_{t+3} , dan Q_{t+4} disajikan pada Tabel berikut :

Tabel 8 Nilai R Proses *Validation* Model ANN Skema Q_{t+2} , Q_{t+3} , dan Q_{t+4} .

Skema	Neuron	Transfer Function		Parameter Jaringan				R
	layer 1	Layer 1	Layer 2	Epoch	Max Fail	Learning Rate	Momentum	
Q_{t+2}	15	tansig	tansig	10000	10000	0.01	0.9	0.90607
Q_{t+3}	15	tansig	pureline	10000	10000	0.05	0.9	0.8448
Q_{t+4}	40	pureline	pureline	10000	10000	0.01	0.9	0.77451

Sumber: Hasil *Running* Program Bantu MATLAB


4. Prediksi Debit Tahun 2011-2012

Setelah *validaton* data hasilnya sangat bagus, maka langkah selanjutnya yaitu melakukan prediksi debit untuk tahun 2011-2012. Adapun proses prediksinya yaitu :

a (target) = data debit tahun 2011-2012
network1 = model prediksi
b (Output) = sim(network1,a)


Setelah dilakukan simulasi untuk prediksi debit tahun 2011-2012, maka hasil prediksi (output) akan dibandingkan dengan data targetnya dan lalu menghitung persentase kesalahan, nilai R dan nilai RMSE.

Berikut disajikan grafik perbandingan antara debit prediksi dan debit eksisting untuk keempat jenis skema :




Gambar 8 Grafik Perbandingan Antara Debit Eksisting dan Debit Prediksi Tahun 2011-2012 Untuk Skema Q_{t+1}

(Sumber : Program Bantu *Microsoft Excel*)




Gambar 9 Grafik Perbandingan Antara Debit Eksisting dan Debit Prediksi Tahun 2011-2012 Untuk Skema Q_{t+2}

(Sumber : Program Bantu *Microsoft Excel*)



Gambar 10 Grafik Perbandingan Antara Debit Eksisting dan Debit Prediksi Tahun 2011-2012 Untuk Skema Q_{t+3}

(Sumber : Program Bantu *Microsoft Excel*)



Gambar 11 Grafik Perbandingan Antara Debit Eksisting dan Debit Prediksi Tahun 2011-2012 Untuk Skema Q_{t+4}

(Sumber : Program Bantu *Microsoft Exce*)

D. Kesimpulan

Dari penelitian yang telah dilakukan maka dapat diambil beberapa kesimpulan, antara lain adalah :

1. peramalan debit sungai pada sub DAS Siak Hulu yang terbaik menggunakan pendekatan model ANN adalah model peramalan satu hari kedepan (Q_{t+1}) yang menghasilkan nilai korelasi (R) sebesar

0.94903 dan nilai *root mean square error* (RMSE) sebesar 14.69120,

2. dari keempat konfigurasi model ANN yang telah dibuat, didapatkan skema yang terbaik yaitu skema model untuk Q_{t+1} dengan menggunakan *neuron* sebanyak 15 buah, *layer* 1 memakai *transfer function tansig*, *layer* 2 memakai *transfer function pureline*, *epoch* dan *max fail* sebesar 10000,

- learning rate* sebesar 0.01, dan *momentum* sebesar 0.9,
3. jangkauan peramalan debit pada sub DAS Siak Hulu beberapa hari kedepan (Q_{t+1} , Q_{t+2} , Q_{t+3} , Q_{t+4}) dengan melihat uji parameter statistik R sudah dikategorikan kuat,

E. Saran

Adapun saran yang didapat dari penelitian ini adalah :

1. Penelitian berikutnya bisa dilakukan juga dengan meramalkan 5 hari kedepan, 6 hari ke depan, dst.
2. Penelitian berikutnya juga bisa dilakukan dengan menggunakan program bantu lain, seperti ANFIS, WAVELET-ANFIS, dll.

F. DAFTAR PUSTAKA

- Deka, dkk. 2013. *Multistep Lead Time Forecasting of Hydrologic Time Series Using Daubechies Wavelet-Neural Network Hybrid Model*. International Journal of Scientific and Engineering Research. 4: 115-124.
- Goel, A. 2011. *ANN-Based Approach for Predicting Rating Curve of an Indian River*. International Scholarly Research Network ISRN Civil Engineering, Volume 2011, Article ID 291370, 4 pages doi:10.5402/2011/291370.
- Harto, Sri. 1993. *Analisis Hidrologi*. Jakarta: Gramedia.
- Indarto. 2010. *Hidrologi*. Jakarta: Bumi Aksara.
- Kusumadewi, Sri. 2004. *Membangun Jaringan Saraf Tiruan Menggunakan MATLAB dan EXCEL LINK*. Yogyakarta: Graha Ilmu.
- Mahyudin. 2013. *Model Prediksi Liku Kalibrasi Menggunakan Pendekatan Jaringan Saraf Tiruan (Studi Kasus: Sub Das Siak Hulu)*. Skripsi. Pekanbaru: Fakultas Teknik Universitas Riau.
- Prahesti, I. 2013. *Implementasi Jaringan Saraf Tiruan Algoritma Backpropagation Untuk Memprediksi Curah Hujan Di Yogyakarta*. Tugas Akhir Jurusan Teknik Informatika. Yogyakarta: Sekolah Tinggi Manajemen Infromatika Dan Komputer Amikom.
- Siang, J.J. 2009. *Jaringan Syaraf Tiruan dan Pemrograman Menggunakan MATLAB*. Yogyakarta: ANDI.
- Sudiana, dkk. 2007. *Pola Konservasi Sumberdaya Air DAS Siak*. Alami. 12: 1.
- Sutojo, dkk. 2011. *Kecerdasan Buatan*. Yogyakarta: Andi Offset.
- Suyanto. 2008. *Softcomputing Membangun Mesin Ber-IQ Tinggi*. Bandung : Informatika.
- Suprayogi, I. 2009. *Model Peramalan Intrusi Air Laut Di Estuari Menggunakan Pendekatan Softcomputing*. Disertasi Doktor. Jurusan Teknik Sipil, Fakultas Teknik Sipil dan Perencanaan (FTSP) Bidang Keahlian Manajemen dan Rekayasa Sumber Air. Institut Teknologi Sepuluh Nopember (ITS). Surabaya.
- Triadmodjo, Bambang. 2009. *Hidrologi Terapan*. Yogyakarta: Beta Offset.