

MODEL HIDROLOGI RUNTUN WAKTU UNTUK PERAMALAN DEBIT SUNGAI MENGUNAKAN METODE GABUNGAN TRANSFORMASI WAVELET – ARTIFICIAL NEURAL NETWORK

(Studi Kasus : Sub DAS Siak Hulu)

Edi Yusuf Adiman¹⁾, Imam Suprayogi²⁾, Yohana Lilis Handayani²⁾

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 : ediyusufadiman@gmail.com

Abstract

Softcomputing method has been widely used as hydrological analysis model, one of them for streamflow forecasting. Hybrid model of Wavelet Transformation - Artificial Neural Network (WANN) is one of the softcomputing method that can predict streamflow. WANN models need to be tested reliability of the Siak Hulu sub-watershed given the importance of streamflow information to generate management, planning, and using water resources and sustainable accurately. WANN models in this study used AWLR data converted into discharge data at Siak Hulu sub-watershed from January 2002 to December 2012. First, the data were decomposed and reconstructed using Wavelet Transformation. Then, ANN constructed forecasting model use backpropagation algorithm. WANN models were constructing use 12 forecasting scheme, and then it compared to obtain the best model of each forecasting scheme. The results of statistical analysis on coefficient of correlation (R) showed that the 12 schemes of WANN models developed by the process of calibration, testing, validation and simulation were categorized as very strong correlation. As for the process simulation models from 2011 to 2012, WANN models db5 level 2 for lead time one day scheme resulted the best correlation coefficient (R) is 0.9501752.

Keyword : forecasting streamflow, Siak Hulu sub-watershed, Wavelet Transformation, ANN.

A. PENDAHULUAN

Model hidrologi merupakan gambaran sederhana dari suatu sistem hidrologi yang aktual (Brook *et al*, 1991), untuk keperluan analisis tentang keberadaan air menurut aspek jumlah, waktu, tempat, probabilitas dan runtun waktu (*time series*). Model hidrologi memiliki banyak manfaat, salah satunya dapat digunakan untuk prediksi debit. Prediksi debit dari model hidrologi pada suatu DAS bisa menjadi Sistem Peringatan Dini (*Early Warning System*) terhadap terjadinya peristiwa banjir dan kekeringan.

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 secara keseluruhan dari hulu hingga hilirnya melewati beberapa kabupaten/kota, yaitu Kabupaten Rokan Hulu, Kabupaten Kampar, Kota Pekanbaru, Kabupaten Bengkalis dan Kabupaten Siak. Mengingat rawannya kawasan DAS Siak terhadap bencana banjir dan longsor disebabkan oleh pencemaran, erosi dan pendangkalan, maka perlu adanya model peramalan debit DAS Siak dalam suatu proses hidrologi agar dapat menghasilkan manajemen, perencanaan, dan penggunaan sumber daya air secara akurat dan berkelanjutan.

Telah banyak model hidrologi yang sudah di kembangkan untuk prediksi debit ini baik dengan model fisik maupun dengan model *softcomputing*. Oleh karena

membutuhkan tempat yang besar dan mahal biaya yang dibutuhkan dalam pembuatan model fisik ini, maka seiring berkembangnya teknik komputasi, penggunaan model *softcomputing* menjadi salah satu model yang patut untuk dicoba keandalannya.

Salah satu model *softcomputing* yang mendapat perhatian dalam pemodelan hidrologi akhir-akhir ini adalah model Jaringan Syaraf Tiruan (*Artificial Neural Network*). ANN adalah suatu teknik *softcomputing* untuk pengolahan informasi yang terinspirasi oleh sistem saraf secara biologis, seperti proses informasi pada otak manusia (Kusumadewi, 2003). Sistem kerja ANN ini layaknya sama seperti cara kerja otak manusia, yaitu belajar melalui contoh. Semakin banyak contoh yang dipelajari semakin bagus model yang akan dibangun. Contoh yang dimaksud dalam penelitian ini merupakan banyaknya data debit yang tersedia menurut urutan waktunya. Untuk mendapatkan data yang bagus dalam membangun model, ada baiknya data dianalisis terlebih dahulu. Data dianalisis dengan menggunakan metode Transformasi Wavelet. Transformasi Wavelet merupakan perubahan suatu fungsi matematika menjadi bentuk yang lebih sederhana. Transformasi Wavelet dapat membuat data menjadi lebih sederhana tanpa mengubah bentuk pola awal datanya dan diharapkan penggunaannya dapat membuat model menjadi lebih baik dari pada yang tidak menggunakannya.

Penggabungan model Transformasi Wavelet dan ANN diatas dinamakan model WANN. Dadu dan Deka (2013) mengatakan model WANN merupakan sebuah model gabungan (*hybrid model*) dari Transformasi Wavelet dan *Artificial Neural Network*. Penggunaan *hybrid model* pada proses pembangunan model peramalan diharapkan mampu menghasilkan model yang lebih baik dari pada yang hanya menggunakan satu jenis model saja.

Dari latar belakang yang telah dipaparkan di atas, maka yang menjadi rumusan masalah pada penelitian ini adalah

Bagaimana konfigurasi model peramalan debit aliran sungai menggunakan model WANN pada Sub DAS Siak Hulu Stasiun Pantai Cermin, parameter penting apakah yang berpengaruh terhadap ketepatan hasil peramalan debit aliran sungai menggunakan model WANN pada Sub DAS Siak Hulu Stasiun Pantai Cermin, dan bagaimana tingkat kemampuan model WANN terhadap ketepatan hasil peramalan debit aliran sungai pada Sub DAS Siak Hulu Stasiun Pantai Cermin.

1. Transformasi Wavelet

Menurut Irwandinata (2010), transformasi wavelet adalah pengubahan suatu fungsi matematika menjadi bentuk yang lebih sederhana yang membagi data menjadi beberapa komponen frekuensi yang berbeda-beda dan menganalisis setiap komponen tersebut dengan menggunakan resolusi yang sesuai dengan skalanya.

Transformasi wavelet dibagi menjadi dua bagian besar, yaitu transformasi wavelet kontinu (TWK) dan transformasi wavelet diskrit (TWD). Transformasi Wavelet Kontinu (TWK) mempunyai cara kerja dengan menghitung konvolusi sebuah sinyal dengan sebuah jendela modulasi pada setiap waktu dengan setiap skala yang diinginkan. Jendela modulasi yang mempunyai skala fleksibel inilah yang biasa disebut induk wavelet atau fungsi dasar wavelet. Menurut Reza (2013), dibandingkan dengan TWK, Transformasi Wavelet Diskrit (TWD) dianggap relatif lebih mudah dalam pengimplementasiannya. Prinsip dasar dari TWD adalah bagaimana cara mendapatkan representasi waktu dan skala dari sebuah sinyal menggunakan teknik pemfilteran digital dan operasi *sub-sampling*. Bentuk dari TWD dapat dilihat pada persamaan berikut :

$$TWD(m,n) = \sum (a_0^m)^{-0.5} f(k) \left[\frac{\psi(n - k a_0^m)}{a_0^m} \right]$$

- dengan :
- $\psi(k)$ = fungsi wavelet (wavelet induk),
 - $f(k)$ = sinyal asli,

a_0^m = konstanta skala,
 ka_0^m = konstanta translasi,
 k, m = variabel integer.

Sutarno (2010) dan Listyaningrum (2007) menjelaskan, pada proses *sub-sampling* sinyal pertama-tama dilewatkan pada rangkaian filter *high-pass* dan *low-pass*, kemudian setengah dari masing-masing keluaran diambil sebagai sample melalui operasi *sub-sampling*. Proses ini disebut sebagai proses dekomposisi satu tingkat. Keluaran dari filter *low-pass* digunakan sebagai masukan di proses dekomposisi tingkat berikutnya. Proses ini diulang sampai tingkat proses dekomposisi yang diinginkan. Gabungan dari keluaran-keluaran filter *high-pass* dan satu keluaran filter *low-pass* yang terakhir, disebut sebagai koefisien wavelet, yang berisi informasi sinyal hasil transformasi yang telah terkompresi. Pasangan filter *high-pass* dan *low-pass* yang digunakan harus memenuhi persamaan berikut:

$$h(L - 1 - n) = (-1)^n \cdot g(n)$$

Dengan :

$h[n]$ = filter *high-pass*,
 $g[n]$ = filter *low-pass*,
 L = panjang masing-masing filter.

Teknik pemfilteran TWD memiliki persamaan dengan pendekatan klasik untuk *denoising time series* yang berasal dari analisis Fourier yang mengasumsikan bahwa *noise* merupakan bentuk lain dari getaran pada frekuensi tinggi (Irwandinata, 2010). Dengan pemikiran ini, suatu *time series* pada dasarnya dapat didekomposisi kedalam bentuk gelombang sinus dari frekuensi berbeda dan apabila dilakukan proses penghilangan *noise*, maka hanya data frekuensi rendah yang akan ditinggalkan dalam pola *time series*. Transformasi Wavelet untuk penghilangan *noise (denoising)* mengasumsikan bahwa analisis *time series* pada resolusi yang berbeda mungkin dapat memisahkan antara bentuk sinyal asli (pola data sebenarnya) dengan *noise*-nya. Proses penghilangan

noise (denoised) pada Transformasi Wavelet dapat dilakukan dengan cara menggunakan nilai *threshold* tertentu untuk melakukan filter terhadap data koefisien detail kemudian direkonstruksi kembali menjadi bentuk awal (polanya).

Ada beberapa keluarga dari Transformasi Wavelet Diskrit diantaranya adalah Haar, Daubechies, Symlets, Coiflets. Wavelet Daubechies merupakan salah satu jenis Transformasi Wavelet Diskrit yang paling terkenal dan banyak dipergunakan dalam bidang citra digital, audio, kelistrikan dan hal-hal lain yang berhubungan dengan penggunaan sinyal. Wavelet Daubechies merupakan penyempurnaan dari Wavelet Haar yang memiliki panjang Wavelet dua kali dari ordenya (2N). Wavelet Daubechies disingkat dengan db diikuti dengan jumlah ordenya, misalnya db5 untuk wavelet daubechies yang mempunyai orde 5. Dalam setiap orde, wavelet daubechies memiliki level dalam tingkatan dekomposisinya. Angka level dari wavelet daubechies menunjukkan berapa kali sinyal akan melakukan proses dekomposisi.

2. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) adalah suatu teknik *softcomputing* untuk pengolahan informasi yang terinspirasi oleh sistem saraf secara biologis, seperti proses informasi pada otak manusia (Kusumadewi, 2003). Jaringan syaraf tiruan ini termasuk dalam bentuk kecerdasan buatan (*Artificial Intelligence*) yang membuat mesin komputer dapat melakukan pekerjaan sebaik yang dilakukan oleh manusia. Struktur dari sistem pengolahan informasi dari kecerdasan buatan ini terdiri dari sejumlah besar elemen pemrosesan yang saling berhubungan (*neuron*), bekerja serentak untuk menyelesaikan masalah tertentu.

Sistem kerja jaringan syaraf tiruan ini layaknya sama seperti cara kerja otak manusia, yaitu belajar melalui contoh. Fausett menjelaskan bahwa jaringan syaraf tiruan merupakan salah satu representasi buatan dari otak manusia yang selalu


mencoba mensimulasikan proses pembelajaran pada otak manusia tersebut (Suprayogi, 2009).

Kelebihan jaringan syaraf tiruan menurut Sutojo, dkk (2011) adalah memberikan kemampuan yang luar biasa untuk mendapatkan informasi dari data yang rumit atau tidak tepat, mampu menyelesaikan permasalahan yang tidak terstruktur dan sulit didefinisikan, dapat belajar dari pengalaman, mampu mengakuisisi pengetahuan walaupun tidak ada kepastian, mampu melakukan generalisasi dan ekstraksi dari suatu pola data tertentu, dapat menciptakan suatu pola pengetahuan melalui pengaturan diri atau kemampuan belajar (*self organizing*), mampu memilih suatu input data ke dalam kategori tertentu yang sudah ditetapkan (klasifikasi), mampu menggambarkan suatu secara keseluruhan walaupun hanya diberikan sebagian data dari objek tersebut (asosiasi), mempunyai kemampuan mengolah data-data input tanpa harus mempunyai target, dan mampu menemukan jawaban terbaik sehingga mampu meminimalisasi fungsi biaya (optimasi).

3. Backpropagation

Backpropagation merupakan salah satu model jaringan yang terdapat pada jaringan syaraf tiruan yang semakin diminati karena telah banyak aplikasi yang berhasil diselesaikannya. Seperti halnya model jaringan syaraf tiruan yang lain, *backpropagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan serta kemampuan jaringan untuk memberikan respon yang benar terhadap pola masukan yang serupa (tapi tidak sama) dengan pola yang dipakai selama pelatihan (Siang, 2009). *Backpropagation* itu sendiri merupakan sebuah metode sistematis pada jaringan syaraf tiruan dengan menggunakan algoritma pembelajaran yang terawasi dan biasanya digunakan untuk perceptron dengan banyak layer lapisan untuk mengubah bobot-bobot yang ada pada

lapisan tersembunyinya. Pembelajaran *backpropagation* menggunakan pola penyesuaian bobot untuk mencapai nilai kesalahan yang minimum antara keluaran hasil prediksi dengan keluaran data aslinya (Kusumadewi, 2004). 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 yang akan ditentukan pada tahap kalibrasi.



Gambar 1. Arsitektur Jaringan *Backpropagation* (Kusumadewi, 2004)

Arsitektur jaringan *backpropagation* seperti terlihat pada Gambar 1 diatas terdiri dari tiga unit (neurons) pada lapisan masukan, yaitu X1, X2, X3 ; 1 lapisan tersembunyi dengan 2 neurons, yaitu Z1, Z2 ; serta 1 unit pada lapisan keluaran yaitu Y1. Bobot yang menghubungkan X1, X2, dan X3 dengan neurons pertama dan lapisan tersembunyi adalah V1, V2, dan V3. Untuk b11 dan b12 adalah bobot bias yang menuju ke neurons pertama dan kedua pada lapisan tersembunyi. Bobot yang menghubungkan Z1 dan Z2 dengan neuron pada lapisan keluaran adalah W1 dan W2. Bobot bias menghubungkan lapisan tersembunyi dengan lapisan keluaran. Fungsi aktivasi yang digunakan antara lapisan tersembunyi dengan lapisan keluaran adalah fungsi aktivasi yang akan ditentukan pada tahap kalibrasi.

4. Tingkat Kinerja Model

Goel (2011) menggunakan 2 tingkat kinerja model untuk membangun model peramalan yaitu dengan *Root Mean Square Error (RMSE)* dan *Correlation Coefficient (R)*.

Nilai RMSE dapat dihitung dengan persamaan berikut :

$$RMSE = \sqrt{\frac{\sum(X-Y)^2}{n}}$$

dengan:

X = nilai pengamatan,

Y = nilai prediksi,

n = jumlah data.

Menurut Suwarno (2008), koefisien korelasi adalah pengukuran statistik kovarian atau asosiasi antara dua variabel. Koefisien korelasi menunjukkan kekuatan (*strenght*) hubungan linear dan arah hubungan dua variabel acak. Untuk memudahkan melakukan interpretasi mengenai kekuatan hubungan antara dua variabel dibuat kriteria sebagai berikut.

- a. $R = 0$: tidak ada korelasi antara dua variabel,
- b. $0 < R \leq 0,25$: korelasi sangat lemah,
- c. $0,25 < R \leq 0,50$: korelasi cukup,
- d. $0,50 < R \leq 0,75$: korelasi kuat,
- e. $0,75 < R \leq 0,99$: korelasi sangat kuat,
- f. $R = 1,00$: korelasi sempurna.

Nilai dari 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.

B. METODOLOGI PENELITIAN

Metode penelitian yang digunakan adalah metode yang dikembangkan oleh Dadu dan Deka (2013) dari India yaitu

menggunakan model gabungan (*hybrid model*) dari Transformasi Wavelet dan *Artificial Neural Network* (Jaringan Syaraf Tiruan) yang menghasilkan Model WANN.

1. Pengumpulan dan Pengelompokan Data


Data yang digunakan dalam penelitian ini berupa data AWLR yang dikonversi menjadi data debit dari tahun 2002 – 2012 (kecuali tahun 2007) yang dapat dilihat pada Lampiran A. Adapun untuk tahun 2009 – 2012, konversi dari data AWLR menjadi data debit diperoleh persamaan liku kalibrasi dari hasil penelitian Mahyudin (2013). Sumber data diambil dari Balai Wilayah Sungai Sumatera III Provinsi Riau Jl. Cut Nyak Dien 01, Pekanbaru. Adapun distribusi data yaitu sebagai berikut ini.

1. 70% dari data tahun 2002 – 2010 digunakan sebagai data kalibrasi (*training*),
2. Sisa 30% dari data tahun 2002 – 2010 digunakan sebagai data pengujian (*testing*),
3. Seluruh data tahun 2002 – 2010 digunakan sebagai data validasi (*validation*),
4. Data tahun 2011 – 2012 digunakan sebagai data pengujian hasil peramalan (simulasi).

2. Pembangunan Model WANN

Model yang dibangun adalah model gabungan (*hybrid model*) dari Transformasi Wavelet dan *Artificial Neural Network*. Model Transformasi Wavelet dikerjakan terlebih dahulu karena hasil data yang dikeluarkannya digunakan untuk model *Artificial Neural Network*. Model dari Transformasi Wavelet ini berfungsi untuk menghilangkan *noise (denoise)* pada data yang akan menghasilkan pola data yang lebih sederhana agar dapat memudahkan ANN dalam mengenali data yang pada akhirnya dapat bertujuan untuk menghasilkan model yang lebih bagus dari pada yang tidak menggunakannya. Secara

sederhana, skema WANN dapat dilihat pada Gambar 2.



Gambar 2. Model WANN Sederhana

Setelah data dimodifikasi oleh Transformasi Wavelet, data yang dihasilkannya digunakan sebagai input dan target pada model ANN. Selanjutnya ANN akan membuat model peramalan debit menggunakan model jaringan *backpropagation*.

Backpropagation merupakan merupakan sebuah metode sistematis pada jaringan syaraf tiruan dengan menggunakan algoritma pembelajaran yang terawasi, maksudnya dalam membuat model jaringan output yang diharapkan telah diketahui sebelumnya (output target). Output target ini berfungsi sebagai bahan pencocokan dengan output yang dihasilkan nantinya (output pembelajaran). Apabila terjadi perbedaan antara output pembelajaran dengan output target, maka akan muncul error. Jika nilai error ini masih cukup besar akan mengindikasikan bahwa masih perlu dilakukan banyak pembelajaran lagi. Dengan menggunakan model jaringan *backpropagation* pada ANN yang terdapat pada software MATLAB, maka dibuatlah model untuk mensimulasikan sistem di atas sehingga dihasilkan suatu model peramalan ANN dengan data yang sudah mengalami Transformasi Wavelet.

C. HASIL DAN PEMBAHASAN

1. Membangun Model WANN

Model yang dibangun adalah model gabungan (*hybrid model*) dari Transformasi Wavelet dan *Artificial Neural Network*. Model Transformasi Wavelet dikerjakan terlebih dahulu karena hasil data yang dikeluarkannya digunakan untuk model *Artificial Neural Network*. Dalam pemilihan model WANN ini, menggunakan kriteria

nilai regresi (R). Model yang dibangun terdiri dari beberapa jenis model sesuai dengan tingkatan berapa hari model tersebut dapat meramalkan (*forecasting*) debit. Ini berfungsi untuk melihat keandalan model yang sudah dibangun terhadap kriteria nilai regresinya (R). Input dan Output target yang digunakan berbeda pula terhadap model yang akan dibangun, yang diambil dari pra-proses pembangunan model (Transformasi Wavelet) yang terdiri dari beberapa level dalam proses modifikasi dan dekomposisinya. Pada penelitian ini menggunakan model peramalan dari satu hari (Q_{t+1}) sampai empat hari (Q_{t+4}) kedepan dan untuk pra-proses pembangunan model dengan menggunakan Transformasi Wavelet Daubechies 5 dari level 1 sampai level 3. Adapun skemanya adalah :

1. Wavelet db5 level 1 untuk peramalan satu hari kedepan (Q_{t+1})
2. Wavelet db5 level 1 untuk peramalan dua hari kedepan (Q_{t+2})
3. Wavelet db5 level 1 untuk peramalan tiga hari kedepan (Q_{t+3})
4. Wavelet db5 level 1 untuk peramalan empat hari kedepan (Q_{t+4})
5. Wavelet db5 level 2 untuk peramalan satu hari kedepan (Q_{t+1})
6. Wavelet db5 level 2 untuk peramalan dua hari kedepan (Q_{t+2})
7. Wavelet db5 level 2 untuk peramalan tiga hari kedepan (Q_{t+3})
8. Wavelet db5 level 2 untuk peramalan empat hari kedepan (Q_{t+4})
9. Wavelet db5 level 3 untuk peramalan satu hari kedepan (Q_{t+1})
10. Wavelet db5 level 3 untuk peramalan dua hari kedepan (Q_{t+2})
11. Wavelet db5 level 3 untuk peramalan tiga hari kedepan (Q_{t+3})
12. Wavelet db5 level 3 untuk peramalan empat hari kedepan (Q_{t+4})

Dari skema di atas, nanti dapat dilihat dan dibandingkan bahwa model yang mana yang menghasilkan nilai regresi (R) yang bagus untuk proses pengujian hasil peramalan.


2. Pra-proses Pembangunan Model (Transformasi Wavelet)

Sebelum membangun model peramalan, data debit yang digunakan untuk proses pembangunan model peramalan (data debit tahun 2002 - 2010, kecuali 2007) dilakukan proses dekomposisi dan rekonstruksi. Adapun penggunaan proses dekomposisi dan rekonstruksi tersebut diharapkan dapat membangun model yang lebih baik daripada dengan yang tidak menggunakannya. Proses dekomposisi dan rekonstruksi ini menggunakan Metode Transformasi Wavelet. Transformasi Wavelet dapat memodifikasi data menjadi bentuk yang lebih sederhana, dengan cara menghilangkan *noise (denoise)* pada data

kemudian membangun kembali menjadi bentuk semula (pola data sebenarnya).

Metode Transformasi Wavelet yang digunakan yaitu Transformasi Wavelet Daubechies 5 (db5). Transformasi Wavelet Db5 ini terdiri dari beberapa level dimana pada setiap level menggunakan tahapan penyederhanaan sesuai dengan angka levelnya. Misalnya Transformasi Wavelet Db5 level 1 menggunakan 1 kali proses penyederhanaan, untuk level 2 menggunakan 2 kali proses penyederhanaan, begitu seterusnya.

Hasil dari proses Transformasi Wavelet menggunakan software Matlab dengan menggunakan data debit tahun 2002 - 2010 (kecuali 2007) dapat dilihat pada gambar di bawah ini.



Gambar 3. Hasil Transformasi Wavelet Db5 Level 1

Pada Gambar 3 di atas menunjukkan data yang mengalami proses penyederhanaan dengan model Transformasi Wavelet db5 level 1 menggunakan software Matlab. Data asli dibuat dalam bentuk grafik yang ditunjukkan pada grafik berwarna merah. Karena level yang digunakan adalah level satu, maka proses penyederhanaan (dekomposisi) dilakukan satu kali yang

nilainya ditunjukkan pada grafik d1 (kiri). Setelah nilai dekomposisi ditentukan, data akan dibangun kembali (rekonstruksi) seperti pola awalnya yang ditunjukkan pada grafik a1 (kiri). Untuk proses *denoise* pada data, digunakan suatu nilai *threshold* tertentu. Disini menggunakan nilai *threshold default* dari Matlab untuk level satu yaitu 3.817. Setelah nilai *threshold* ditentukan, selanjutnya data kembali melakukan

rekonstruksi yang ditunjukkan pada grafik a1 (kanan). Data pada grafik a1 (kanan) inilah yang akan digunakan pada input dan output target model ANN.

3. Proses Membangun Model Peramalan (ANN)

Setelah data disiapkan, langkah selanjutnya adalah membangun model dengan ANN menggunakan software Matlab. Model ANN yang dibangun berfungsi untuk peramalan (*forecasting*) debit. Untuk itu model ANN membutuhkan input dan output target yang berupa debit pula, yang diambil dari hasil pra-proses pembangunan model. Misalnya untuk membangun model yang dapat meramal

satu hari kedepan diperlukan input berupa debit hari ini (Q_t) dan output target berupa hari esoknya (Q_{t+1}) seperti yang terlihat pada Gambar 2.

Ada tiga tahap dalam membangun model peramalan yaitu tahap kalibrasi (pembelajaran), tahap pengujian, dan tahap validasi.

Pada tahap kalibrasi model, menggunakan 6 parameter yang perlu dimodifikasi agar mendapatkan nilai regresi (R) yang maksimal (tertinggi). Parameter-nya yaitu neurons, transfer function, epoch, max fail, learning rate, dan momentum. Berikut adalah contoh hasil tahapan kalibrasi model pada 12 skema peramalan.

Tabel 1. Hasil dari Kalibrasi Maksimum dari Setiap Parameter Pelatihan

No	Model	Parameter						
		neurons	transfer function		epoch	max fail	learning rate	momentum
			layer 1	layer 2				
1	WANN db5 lvl 1 untuk Q_{t+1}	15	tansig	purelin	5000	5000	0.1	0.9
2	WANN db5 lvl 1 untuk Q_{t+2}	40	purelin	purelin	1000	1000	0.01	0.9
3	WANN db5 lvl 1 untuk Q_{t+3}	1	tansig	tansig	5000	5000	0.01	0.9
4	WANN db5 lvl 1 untuk Q_{t+4}	15	purelin	purelin	1000	1000	0.01	0.9
5	WANN db5 lvl 2 untuk Q_{t+1}	15	purelin	purelin	1000	1000	0.01	0.9
6	WANN db5 lvl 2 untuk Q_{t+2}	15	tansig	tansig	5000	5000	0.01	0.9
7	WANN db5 lvl 2 untuk Q_{t+3}	40	purelin	purelin	1000	1000	0.01	0.9
8	WANN db5 lvl 2 untuk Q_{t+4}	15	purelin	purelin	1000	1000	0.01	0.9
9	WANN db5 lvl 3 untuk Q_{t+1}	15	purelin	purelin	1000	1000	0.01	0.9
10	WANN db5 lvl 3 untuk Q_{t+2}	15	tansig	tansig	5000	5000	0.01	0.9
11	WANN db5 lvl 3 untuk Q_{t+3}	15	tansig	tansig	5000	5000	0.1	0.9
12	WANN db5 lvl 3 untuk Q_{t+4}	15	purelin	purelin	1000	1000	0.01	0.9

Sumber: Hasil *Running* Program Bantu MATLAB

Adapun untuk nilai R dari kalibrasi, pengujian dan validasi pada setiap skema dapat dilihat pada tabel di bawah ini.

Tabel 2. Hasil dari kalibrasi, pengujian dan validasi model maksimum untuk Q_{t+1}

Model	Nilai R Kalibrasi	Nilai R Pengujian	Nilai R Validasi	Tingkat Korelasi
Db5L1	0.97486	0.96292	0.9718	Sangat Kuat
Db5L2	0.97595	0.96713	0.97594	Sangat Kuat
Db5L3	0.97737	0.96799	0.97709	Sangat Kuat

Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 3. Hasil dari kalibrasi, pengujian dan validasi model maksimum untuk Q_{t+2}

Model	Nilai R Kalibrasi	Nilai R Pengujian	Nilai R Validasi	Tingkat Korelasi
Db5L1	0.91079	0.89509	0.91336	Sangat Kuat
Db5L2	0.92503	0.90091	0.92077	Sangat Kuat
Db5L3	0.93008	0.9089	0.92528	Sangat Kuat

Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 4. Hasil dari kalibrasi, pengujian dan validasi model maksimum untuk Q_{t+3}

Model	Nilai R Kalibrasi	Nilai R Pengujian	Nilai R Validasi	Tingkat Korelasi
Db5L1	0.83037	0.80372	0.84557	Sangat Kuat
Db5L2	0.84736	0.81234	0.85988	Sangat Kuat
Db5L3	0.86903	0.82963	0.86747	Sangat Kuat

Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 5. Hasil dari kalibrasi, pengujian dan validasi model maksimum untuk Q_{t+4}

Model	Nilai R Kalibrasi	Nilai R Pengujian	Nilai R Validasi	Tingkat Korelasi
Db5L1	0.78565	0.74387	0.7775	Sangat Kuat
Db5L2	0.79595	0.75677	0.78947	Sangat Kuat
Db5L3	0.80933	0.7695	0.80217	Sangat Kuat

Sumber: Hasil *Running* Program Bantu MATLAB

4. Pengujian Hasil Peramalan (Simulasi)

Setelah mendapatkan model – model yang maksimum pada setiap skema, maka model tersebut siap untuk melakukan peramalan (*forecasting*). Model yang sudah disiapkan pada proses peramalan akan diuji kembali untuk melihat unjuk kerjanya terhadap data peramalan (simulasi). Data simulasi merupakan data di luar dari data yang digunakan pada proses pembangunan model. Data yang digunakan adalah data tahun 2011 – 2012 pada stasiun Pantai

Cermin. Data tersebut digunakan sebagai input dari model mana yang akan kita ramalkan, dan akan menghasilkan output sesuai dengan model yang digunakan. Data output yang dihasilkan model inilah yang akan kita bandingkan dengan nilai sebenarnya dari data peramalan tersebut. Untuk nilai Koefisien Korelasi (R) dan RMSE dari hasil peramalan debit tahun 2011 – 2012 pada setiap skema model dapat dilihat pada tabel di bawah ini.

Tabel 6. Hasil peramalan model WANN db5 untuk Q_{t+1}

Model	Nilai Root Mean Square Error (RMSE)	Nilai Koefisien Korelasi (R)	Tingkat Korelasi
Db5L1	14.659449	0.9493257	Sangat Kuat
Db5L2	14.525965	0.9501752	Sangat Kuat
Db5L3	14.533197	0.9501752	Sangat Kuat

Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 7. Hasil peramalan model WANN db5 untuk Q_{t+2}

Model	Nilai Root Mean Square Error (RMSE)	Nilai Koefisien Korelasi (R)	Tingkat Korelasi
Db5L1	21.42562	0.889856	Sangat Kuat
Db5L2	21.49402	0.887729	Sangat Kuat
Db5L3	21.44875	0.888301	Sangat Kuat

Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 8. Hasil peramalan model WANN db5 untuk Q_{t+3}

Model	Nilai Root Mean Square Error (RMSE)	Nilai Koefisien Korelasi (R)	Tingkat Korelasi
Db5L1	25.95679	0.830359	Sangat Kuat
Db5L2	26.40756	0.826454	Sangat Kuat
Db5L3	26.42413	0.824245	Sangat Kuat


Sumber: Hasil *Running* Program Bantu MATLAB

Tabel 9. Hasil peramalan model WANN db5 untuk Q_{t+4}


Model	Nilai Root Mean Square Error (RMSE)	Nilai Koefisien Korelasi (R)	Tingkat Korelasi
Db5L1	30.2719	0.763164	Sangat Kuat
Db5L2	30.20935	0.763164	Sangat Kuat
Db5L3	30.21361	0.763164	Sangat Kuat

Sumber: Hasil *Running* Program Bantu MATLAB


Untuk hasil perbandingan antara hasil peramalan model terbaik pada setiap skema peramalan dengan hasil pengamatan dapat dilihat pada gambar di bawah ini.




Gambar 4. Hasil Perbandingan Antara Debit Pengamatan dengan Debit Peramalan Model WANN db5 level 2 untuk Q_{t+1}



Gambar 5. Hasil Perbandingan Antara Debit Pengamatan dengan Debit Peramalan Model WANN db5 level 1 untuk Q_{t+2}



Gambar 6. Hasil Perbandingan Antara Debit Pengamatan dengan Debit Peramalan Model WANN db5 level 1 untuk Q_{t+3}



Gambar 7. Hasil Perbandingan Antara Debit Pengamatan dengan Debit Peramalan Model WANN db5 level 2 untuk Q_{t+4}

Dari tabel dan gambar di atas dapat dilihat bahwa semakin lama waktu model dalam meramalkan debit, maka semakin menurun tingkat kinerja model berdasarkan uji parameter statistik koefisien korelasi (R) dan semakin bertambah besarnya tingkat kesalahan berdasarkan uji RMSE.

D. KESIMPULAN

1. Model peramalan debit aliran sungai pada Sub DAS Siak Hulu Stasiun Pantai Cermin menggunakan WANN db5 level 2 memberikan hasil terbaik berdasarkan uji

parameter statistik Koefisien Korelasi (R) untuk satu hari kedepan sebesar 0.9501752.

2. Model peramalan terbaik adalah model WANN db5 level 2 untuk peramalan satu hari kedepan dengan menggunakan parameter: jumlah neurons 15, transfer function pada layer 1 "purelin" dan layer 2 "purelin", jumlah epoch 1000, jumlah max fail 1000, angka learning rate 0.01, dan angka momentum 0.9.

3. Tingkat kemampuan model WANN db5 level 1, level 2 dan level 3 berdasarkan uji parameter statistik Koefisien Korelasi (R) untuk peramalan satu (Q_{t+1}), dua (Q_{t+2}), tiga (Q_{t+3}), bahkan empat (Q_{t+4}) hari kedepan, dikategorikan sebagai korelasi sangat kuat.

E. SARAN

1. Penelitian berikutnya bisa memprediksikan debit seminggu kedepan menggunakan model WANN, mengingat model dapat diproyeksikan sebagai sistem peringatan dini banjir.
2. Mengingat tingkat kesensitifan model peramalan WANN yang tinggi, perlunya kehati-hatian dan pemahaman mendalam tentang model agar mendapatkan model peramalan yang bagus.

F. DAFTAR PUSTAKA

- Brooks, K.N., Folliot, P.F., Gregesen, H.M. and Thames, J.L. 1991. *Hydrology and The Management of Watershed*. USA: Iowa State University Press.
- Dadu, K.S. and Deka, P.C. 2013. Multistep Lead Time Forecasting of Hydrologic Time Series Using Daubechies Wavelet – Artificial Neural Network Hybrid Model. *IJSER 2013*. Vol. 4: 115-124.
- Goel, A. 2011. ANN-Based Approach for Prediting Rating Curve of an Indian River. *ISRN Civil Engineering*. Article ID 291370.
- Irwindinata. 2010. *Teory Wavelet*. Available at: <URL: <http://irwindinata.wordpress.com/2010/07/08/teori-wavelet.html>> [Accessed 28 Juli 2014].
- Kusumadewi, S. 2003. *Artificial Intelligence Teknik dan Aplikasinya*. Yogyakarta: Graha Ilmu.
- Kusumadewi, S. 2004. *Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB & EXEL LINK*. Yogyakarta: Graha Ilmu.
- Listyaningrum, R. 2007. Analisis Tekstur Menggunakan Metode Transformasi Paket Wavelet. *Makalah Seminar Tugas Akhir*. Semarang, Januari 2007.
- Mahyudin. 2013. *Model Prediksi Liku Kalibrasi Menggunakan Pendekatan Jaringan Saraf Tiruan (Studi Kasus: Sub Das Siak Hulu)*. Skripsi. Pekanbaru: Fakultas Teknik Universitas Riau.
- Reza, C. 2013. Teknik Potensi Diferensial pada Transformator Daya Tiga Fasa dengan Menggunakan Transformasi Wavelet. Skripsi. Bandung: Universitas Pendidikan Indonesia.
- Siang, J.J. 2009. *Jaringan Syaraf Tiruan dan Pemrograman Menggunakan MATLAB*. Yogyakarta: ANDI.
- Suprayogi, I. 2009. *Model Peramalan Intrusi Air Laut di Estuari Menggunakan Pendekatan Softcomputing*. Disertasi. Surabaya: Fakultas Teknik Institut Teknologi Sepuluh November.
- Sutarno. 2010. Analisis Perbandingan Transformasi Wavelet pada Pengenalan Citra Wajah. *Jurnal Generic*. Vol. 5:15-21.
- Sutojo, T., Mulyanto, E. dan Suhartono, V. 2011. *Kecerdasan Buatan*. Yogyakarta: Andy Offset.
- Suwarno. 2008. *Analisis Korelasi*. Sukoharjo: Universitas Veteran Bangun Nusantara.