

KOMPARASI MODEL PERAMALAN DEBIT SUNGAI MENGGUNAKAN ANN, WAVELET- ANN UNTUK Mendukung SISTEM DETEKSI DINI BANJIR DI SUNGAI SIAK

Imam Suprayogi¹, Joleha², Manyuk Fauzi³, Alfian⁴, Suprasman⁵

^{1,2,3,4,5} Jurusan Teknik Sipil, Fakultas Teknik,
Universitas Riau, Pekanbaru.

Email: drisuprayogi@yahoo.com

ABSTRACT

River flow forecasting in a hydrological process has a strategic role to be able to produce the management, planning, and use of water resources accurately and sustainably. The effort to realize an analysis of the hydrological process above, is needed a model that is a simplification of the real natural phenomenon. The main purpose of the research is to develop a time series hydrology model for the needs of river discharge forecasting so that accurate information can be used to be observed in some time ahead on a cross-section of the river. The method of approach used in this research is to use a softcomputing component that is Artificial Neural Network (ANN) and a combined model between Wavelet Transform – Artificial Neural Network (W-ANN). Research supporting Data was obtained from the AWLR recording of the Mirror Beach Station from 2002 – 2012, which is a stage hydrograph to be transformed into a discharge hydrograph using the rating curve equation that was created by BWS III Sumatera. The main research results proved that the W – ANN model for the needs of river discharge forecasting one day ahead ($t + 1$) in the Siak River using the MATLAB 7.0 software resulted in a higher value coefficient of correlation 0.951 when compared to ANN by 0.948, although both ANN and Wavelet-ANN models have a very strong degree of relationship $0.75 < R < 0.99$.

Keywords: model, forecasting, river discharge, softcomputing, ANN, Wavelet-ANN

ABSTRAK

Peramalan aliran sungai dalam suatu proses hidrologis memiliki peran yang strategis untuk dapat menghasilkan manajemen, perencanaan, dan penggunaan sumber daya air secara akurat dan berkelanjutan. Upaya merealisasikan suatu analisis proses hidrologi yang dideskripsikan di atas, dibutuhkan model yang merupakan penyederhanaan fenomena alam yang sesungguhnya. Tujuan utama penelitian adalah mengembangkan model hidrologi runtun waktu untuk kebutuhan peramalan debit sungai sehingga diperoleh informasi yang akurat untuk dapat dijadikan sebagai pengamatan dalam beberapa waktu ke depan di suatu penampang sungai. Metode pendekatan yang digunakan dalam penelitian ini adalah menggunakan komponen softcomputing yaitu Artificial Neural Network (ANN) dan gabungan model antara Transformasi Wavelet – Artificial Neural Network (W-ANN). Data pendukung penelitian diperoleh dari pencatatan AWLR Stasiun Pantai Cermin dari tahun 2002–2012 yang berupa *stage hydrograph* untuk ditransformasikan menjadi *discharge hydrograph* menggunakan persamaan *rating curve* yang telah dibuat oleh BWS III Sumatera. Hasil utama penelitian membuktikan bahwa model W – ANN untuk kebutuhan peramalan debit sungai satu hari ke depan ($t + 1$) di Sungai Siak menggunakan software MATLAB 7.0 menghasilkan nilai koefisien korelasi 0.951 yang lebih tinggi bila dibandingkan ANN sebesar 0.948,

meskipun kedua model ANN dan Wavelet - ANN memiliki derajat hubungan sangat kuat $0.75 < R < 0.99$.

Kata kunci : model, peramalan, debit sungai, Softcomputing, ANN, Wavelet - ANN

1. PENDAHULUAN

Sungai Siak merupakan salah satu sungai besar yang mendapatkan perhatian secara Nasional, karena sungai tersebut memiliki fungsi dan peranan yang sangat vital 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 dan Soewandhita, 2007). Masih dikatakan oleh Sudiana dan Soewandhita (2007) berdasarkan kondisi fisik tersebut Sungai Siak memiliki manfaat yang sangat besar bagi semua pihak yaitu sumber air domestik bagi masyarakat di sepanjang Sungai Siak, sumber air baku (*intake*) bagi PDAM Kota Pekanbaru, sumber air baku untuk industri, sumber mata pencaharian bagi nelayan di sepanjang Sungai Siak dan sarana transportasi.

Bersumber dari Paparan Menteri Pekerjaan Umum pada acara Seminar Penyelamatan dan Pelestarian Daerah Aliran Sungai (DAS) Siak di Pekanbaru 6 Agustus 2005 bahwa DAS Siak termasuk DAS kritis, kawasan rawan bencana banjir dan longsor, terjadi berbagai pencemaran, erosi dan sedimentasi. Kejadian banjir di Provinsi Riau akibat meluapnya Sungai Siak dan anak-anak sungainya merupakan indikator adanya perubahan ekosistem pada DAS tersebut. Perubahan ekosistem tersebut disebabkan oleh wilayah dalam DAS Siak merupakan daerah yang potensial berkembang bagi kegiatan sosial ekonomi masyarakat.

Masih bersumber dari Paparan Menteri Pekerjaan Umum yang mengacu hasil penelitian yang dilakukan oleh Tim Fakultas Teknik, Universitas Gadjah Mada (UGM) Yogyakarta bahwa Sungai Siak memiliki kedalaman 20-29 meter merupakan sungai terdalam di Indonesia, namun saat ini terjadi penumpukan sedimen di dasar sungai yang telah mencapai ketinggian 8 meter atau sepertiga dari kedalaman sungai. Hal ini mengindikasikan adanya erosi yang cukup besar di bagian hulu sungai. Adanya sedimen dapat mengganggu pelayaran terutama saat muka air surut di musim kemarau. Di lain pihak, dalam musim hujan dapat terjadi bahaya banjir karena berkurangnya kapasitas sungai dalam menampung aliran air.

Peramalan aliran sungai dalam suatu proses hidrologis memiliki peran yang penting agar dapat menghasilkan manajemen, perencanaan, dan penggunaan sumber daya air secara akurat dan berkelanjutan. Untuk keperluan analisa hidrologi diperlukan data hidrologi yang panjang, tetapi sering dijumpai data yang tersedia tidak lengkap atau bahkan tidak ada sama sekali. Sesuai dengan karakteristik fenomena hidrologi suatu daerah pengaliran sungai, aliran sungai berubah-ubah tidak beraturan, oleh karena itu sukar untuk meramalkan besarnya debit yang melintasi penampang sungai secara pasti

pada suatu saat tertentu. Untuk mendekati fenomena tersebut maka perlu dikembangkan suatu analisa sistem hidrologi dengan menggunakan model yang merupakan penyederhanaan kenyataan alam yang sebenarnya (Hadihardaja dan Sutikno, 2005).

Banyak fenomena keteknikan dan alam yang sulit dan rumit, yang perlu didekati (diprediksi) dengan model fisik dan/atau model matematik, sehingga dalam kesehariannya para ilmuwan akan selalu bergelut dengan pemodelan. Dalam pemodelan, tentu mengandung ketidaksemaan atau kesalahan. Kesalahan tersebut mungkin dikarenakan skemanya, asumsi-asumsi, ataupun karena faktor manusianya (Pratikto, 1999). Kesalahan merupakan bentuk ketidakberdayaan ilmuwan atas ketidakmampuannya dalam menerangkan seluruh fakta yang diperoleh merangkai dalam sebuah model. Tugas utama ilmuwan adalah bagaimana menerangkan suatu fakta/fenomena suatu model sedemikian hingga akan mempunyai kesalahan sekecil-kecilnya (Iriawan, 2005).

Pada dekade terakhir ini, model *softcomputing* 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. Dasar pemilihan model *softcomputing* sebagai *tool* dalam pemodelan sistem, pemodelan *softcomputing* sangat menguntungkan bekerja pada sistem tak linier yang cukup sulit model matematikanya, serta fleksibilitas parameter yang dipakai yang biasa merupakan kendala pada *tool* yang lain (Purnomo, 2005).

Sebelum dilakukan proses peramalan menggunakan ANN, diduga bahwa data mentah runtun waktu (*time series*) mempunyai pola-pola tersembunyi yang dipengaruhi oleh variabel waktu, misalnya pola *trend*, musiman, siklus atau random. Pola-pola ini dapat menjadi masukan tambahan bagi ANN, sehingga diharapkan kemampuan ANN untuk melakukan proses peramalan dapat meningkat (Yustanti, 2004).

Metode gabungan Transformasi Wavelet dan komponen *softcomputing* ANN telah diaplikasikan untuk memprediksi debit aliran di Sungai Lou, Kota Shanwey, Provinsi Guangdong, China. Hasil penelitian membuktikan bahwa metode pendekatan Transformasi Wavelet - ANN terbukti menghasilkan tingkat akurasi yang lebih baik dalam memprediksi debit aliran bila dibandingkan metode ANN yang diukur menggunakan kriteria uji parameter statistik koefisien korelasi (R) dan koefisien efisiensi (CE) (Ju dkk, 2008). Penelitian sejenis juga telah dilakukan dengan mengaplikasikan metode gabungan antara Wavelet - ANN untuk memprediksi debit aliran di Sungai Brahmaputra, India. Hasil penelitian membuktikan bahwa metode pendekatan Transformasi Wavelet - ANN menghasilkan tingkat akurasi yang akurat guna memprediksi debit aliran untuk empat hari ke depan (Q_{t+4}) menggunakan kriteria uji parameter statistik koefisien korelasi (R) dan koefisien efisiensi (CE) (Dadu dan Dekha, 2013).

Merujuk keberhasilan penelitian terdahulu terkait penerapan cabang Artificial Intelligence dalam rekayasa sumberdaya air dengan upaya menggabungkan metode transformasi wavelet untuk proses filtering data dan model *softcomputing* yang

komponennya seperti ANN yang memiliki keunggulan spesifik (generik) pengenalan pola data, maka tujuan utama penelitian adalah mengembangkan varian model hidrologi runtun waktu untuk peramalan debit sungai beberapa waktu ke depan di suatu penampang sungai sebagai salah satu input data penting untuk membangun Sistem Deteksi Dini Banjir di Sungai Siak.


2. LANDASAN TEORI

Metode Transformasi Wavelet

Algoritma pembelajaran dengan ANN tidak dilakukan modifikasi sehingga prosedur yang digunakan untuk pelatihan dan peramalan menggunakan algoritma yang telah digunakan dalam penelitian sebelumnya. Sedangkan untuk pra-proses dengan menggunakan metode transformasi wavelet, dilakukan modifikasi yaitu proses dekomposisi dan rekonstruksi dilakukan sebelum proses peramalan, asumsi yang digunakan adalah bahwa data yang akan dipelajari dalam arsitektur ANN yang telah ditentukan merupakan data yang sudah dihilangkan *noise* nya, bukan koefisien waveletnya. Algoritma dekomposisi dapat dilihat sebagai berikut :

1. Pilih fungsi wavelet.
2. Masukkan level dekomposisi (j)
3. IF $\text{mod}(N/2^j) = 0$ THEN langkah 4 ELSE ulangi langkah 2
4. Menghitung nilai koefisien wavelet yaitu koefisien Aproksimasi (A) dan koefisien Detail (D)
5. Plot nilai koefisien wavelet (cA dan cD) yang diperoleh untuk mengetahui kesesuaian pola datanya terhadap data asli.

Proses penghilangan noise (*denoised*) dapat dilakukan dengan cara menggunakan nilai treshold tertentu untuk melakukan filter terhadap data koefisien detail (*high-pass component*) kemudian direkonstruksi kembali menjadi bentuk awal, atau rekonstruksi dilakukan hanya dari koefisien aproksimasi saja, komponen detail tidak diikuti dalam proses rekonstruksi. Sebelum dilakukan proses peramalan data runtun waktu debit aliran sungai sebagai input model ANN terlebih dahulu dilakukan proses penyaringan data menggunakan Metode Transformasi Wavelet. Transformasi Wavelet Diskrit memiliki keluarga 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.



Sumber : Rajae, dkk (2010)

Gambar 1. Fungsi Wavelet Daubechies Berdasarkan Orde-nya


Model ANN

Seperti halnya otak manusia, jaringan syaraf juga terdiri dari beberapa *neuron*, ada hubungan *neuron-neuron* tersebut. *Neuron-neuron* akan mentransformasikan informasi yang diterima melalui sambungan keluarnya menuju ke *neuron-neuron* yang lain. Pada jaringan syaraf hubungan ini dikenal dengan nama bobot. Informasi tersebut disimpan pada suatu nilai tertentu pada bobot tersebut (Camelio dkk. 2013).

Selanjutnya pada jaringan syaraf, *neuron-neuron* akan dikumpulkan dalam lapisan-lapisan (*layer*) yang disebut dengan lapisan *neuron* (*neuron layers*). Biasanya *neuron-neuron* pada suatu lapisan akan dihubungkan dengan lapisan-lapisan sebelum dan sesudahnya (kecuali lapisan *input* dan lapisan *output*). Informasi yang diberikan pada jaringan syaraf akan dirambatkan lapisan ke lapisan, mulai dari lapisan input sampai ke lapisan output melalui lapisan yang lainnya, yang sering dikenal dengan dengan nama lapisan tersembunyi (*hidden layer*). Tergantung pada algoritma pembelajarannya, bisa jadi informasi tersebut akan dirambatkan secara mundur pada jaringan.

Algoritma Pembelajaran Backpropagation

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 propagation*). Untuk mendapatkan *error* ini, tahap perambatan maju (*upward propagation*) harus dikerjakan terlebih dahulu. Pada saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi (Fausset. 1996). Selanjutnya arsitektur jaringan backpropagation dapat dilihat seperti pada Gambar 2 di bawah ini.



Sumber : Fausset (1996)

Gambar 2. Arsitektur Jaringan Backpropagation

Ada tiga fase Pelatihan backpropagation, untuk fase pertama, yaitu propagasi maju. Dalam propagasi maju, setiap sinyal masukan dipropagasi (dihitung maju) ke layar tersembunyi hingga layar keluaran dengan menggunakan fungsi aktivasi yang ditentukan. Fase kedua, yaitu propagasi mundur. Kesalahan (selisih antara keluaran jaringan dengan target yang diinginkan) yang terjadi dipropagasi mundur mulai dari garis yang berhubungan langsung dengan unit-unit di layar keluaran. Fase ketiga, yaitu perubahan bobot. Pada fase ini dilakukan modifikasi bobot untuk menurunkan kesalahan yang terjadi. Ketiga fase tersebut diulang-ulang terus hingga kondisi penghentian dipenuhi (Fausset, 1996).

Algoritma pelatihan untuk jaringan dengan satu layar tersembunyi dengan fungsi aktivasi sigmoid biner adalah sebagai berikut :

- Langkah 0 : Inisialisasi semua bobot dengan bilangan acak kecil
- Langkah 1 : Jika kondisi penghentian belum terpenuhi, lakukan langkah 2-9
- Langkah 2 : Untuk setiap pasang data pelatihan lakukan langkah 3-8

Fase I : Propagasi maju

- Langkah 3 : Tiap unit masukan menerima sinyal dan meneruskannya ke unit tersembunyi di atasnya
- Langkah 4: Hitung semua keluaran di unit tersembunyi z_j ($j = 1, \dots, p$)

$$z_net_j = v_{j0} + \sum_{i=1}^n x_i v_{ji}$$

- Langkah 5 : Hitung semua keluaran jaringan di unit y_k ($k = 1, 2, \dots, m$)

$$y_net_k = w_{k0} + \sum_{i=1}^n z_i w_{ki}$$

$$y_k = f(y_net_k) = \frac{1}{1 + e^{-y_net_k}}$$

Fase II : Propagasi mundur

- Langkah 6 : Hitung faktor unit keluaran berdasarkan kesalahan disetiap unit keluaran y_k ($k = 1, 2, \dots, m$)

$$\partial_k = (t_k - y_k) f'(y_net_k) = (t_k - y_k) y_k (1 - y_k)$$

∂_k merupakan unit kesalahan yang akan dipakai dalam perubahan bobot layar di bawahnya (langkah 7). Hitung suku perubahan bobot w_{kj} (yang akan dipakai nanti untuk merubah bobot w_{kj}) dengan laju percepatan α)

$$\Delta w_{kj} = \alpha \partial_k z_j \quad k = 1, 2, \dots, m ; \quad j = 0, 1, \dots, p$$

- Langkah 7 : Hitung faktor ∂_k unit tersembunyi berdasarkan kesalahan disetiap unit tersembunyi z_j ($j = 1, 2, \dots, p$)

$$\partial_net_j = \sum_{k=1}^m \partial_k w_{kj}$$

Faktor ∂ unit tersembunyi :

$$\partial_j = \partial_{net_j}(z_{net_j}) = \partial_{net_j}^2$$

Hitung suku perubahan bobot v_{ji} (yang akan dipakai nanti untuk merubah bobot v_{ji})

$$\Delta v_{ji} = \alpha \partial_j z_i \quad ; j = 1, 2, \dots, p \quad ; i = 0, 1, \dots, n$$

Fase III : Perubahan bobot

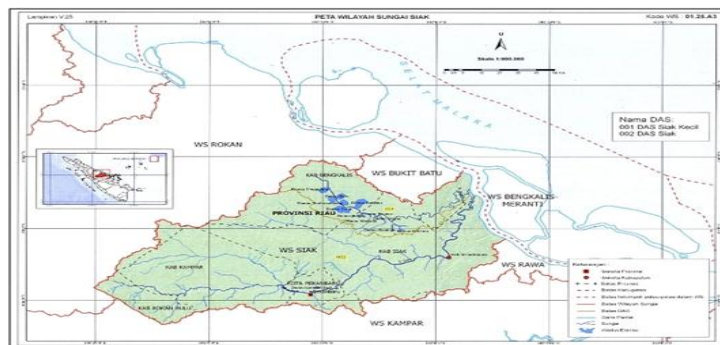
- Langkah 8 : Hitung semua perubahan bobot perubahan bobot garis yang menuju ke unit keluaran :

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} \quad (k = 1, \dots, m \quad ; j = 0, 1, \dots, p)$$

Setelah pelatihan selesai dilakukan, jaringan dapat dipakai untuk pengenalan pola. Dalam hal ini, hanya propagasi maju (langkah 4 dan 5) saja yang dipakai untuk menentukan keluaran jaringan.

3. METODOLOGI

Penelitian ini dilakukan pada DAS Siak bagian Hulu dengan lokasi stasiun duga air otomatis Pantai Cermin. Lokasi penelitian dapat dilihat pada Gambar 3 seperti di bawah ini.



Gambar 3. Peta Lokasi Penelitian

Kebutuhan Data Penelitian

Data yang digunakan dalam penelitian yang bersumber dari Balai Wilayah Sungai (BWS) Sumatera III Provinsi Riau yaitu data sekunder dari pos duga air otomatis Pantai Cermin yang telah dikonversi menjadi debit dari tahun 2002 - 2012 dengan persamaan *rating curve* $Q = 14,78 \times (H + 0,384)^{1,580}$.

Analisis Penelitian

Analisis penelitian yang dimaksud adalah memodelkan debit aliran di stasiun pos duga air otomatis Pantai Cermin untuk mengetahui jangkauan ketepatan peramalan untuk beberapa hari ke depan yang secara garis besar tahapan analisis yang dilakukan adalah sebagai berikut:

1. Mempersiapkan data debit aliran yang selanjutnya dilakukan pendistribusian data untuk pengembangan model hidrologi runtun waktu untuk peramalan debit sungai menggunakan Algoritma ANFIS dengan komposisi sebagai berikut
 - Proses training data sebanyak 70% dari total data debit dari tahun 2002 – 2010.
 - Proses testing data sebanyak 30% dari total data debit dari tahun 2002 – 2010
 - Proses checking data sebanyak 100% dari total data debit dari tahun 2002 – 2010
 - Proses peramalan data debit dari tahun 2011-2012
2. Penetapan skema untuk membangun model peramalan debit aliran sungai menggunakan ANFIS
3. Melakukan input data untuk proses training data sebanyak 70% dari tahun 2002-2012 ke program bantu MATLAB 7.0. Pada proses training data ini dilakukan penyetelan parameter *range of influence* (RoI) serta jumlah epoch sehingga akan diperoleh nilai koefisien korelasi (R) terbaik untuk berbagai skema.
4. Melakukan input data untuk proses testing data sebanyak 30% dari tahun 2002-2012 ke program bantu MATLAB 7.0. Pada proses testing data dilakukan dengan menguji sistem *neuro fuzzy* berdasarkan parameter-parameter hasil proses training data sehingga akan diperoleh nilai koefisien korelasi (R) untuk berbagai skema.
5. Melakukan input data untuk proses validasi data , yaitu proses terakhir setelah proses training data dan testing data dilaksanakan. Proses validasi dilakukan dengan menggunakan parameter yang sama yang digunakan dalam tahap training data dan dihitung untuk masing – masing skema namun menggunakan keseluruhan data yang ada. Selanjutnya hasil validasi masing – masing skema dihitung koefisien korelasi (R) .
6. Melakukan input data untuk proses peramalan data tahun 2002-2012 ke program bantu MATLAB 7.0. Menetapkan hasil peramalan debit aliran sungai terbaik berdasarkan uji parameter statistik koefisien korelasi tertinggi

Uji Ketelitian Model

Uji ketelitian model dilakukan menggunakan uji parameter statistik koefisien korelasi (R) sebagai berikut :

$$R = \frac{\sum_{i=1}^{i=N} Q_p Q_m}{\left[\sum_{i=1}^{i=N} \Delta Q_p^2 \sum_{i=1}^{i=N} \Delta Q_m^2 \right]^{1/2}}$$

$$\Delta Q_p = Q_{pi} - \bar{Q}_p \text{ dan } \Delta Q_{mi} = Q_{mi} - \bar{Q}_{mi}$$

dengan Q_p adalah debit pengukur (m^3/dt), Q_m adalah debit model (m^3/dt) dan n adalah jumlah sampel.

Menurut **Camelio dkk, (2010)** bahwa klasifikasi derajat hubungan berdasarkan hasil nilai koefisien korelasi antara hasil simulasi Model dan data hasil pengukuran (*observed*), untuk R sama dengan 0 memiliki derajat hubungan tidak ada korelasi, $0 < R < 0.25$ memiliki derajat hubungan korelasi sangat lemah, $0.25 < R < 0.50$ memiliki derajat hubungan korelasi cukup, $0.50 < R < 0.75$ memiliki derajat hubungan korelasi kuat, $0.75 < R < 0.99$ derajat hubungan korelasi sangat kuat dan R sama dengan 1 derajat hubungan korelasi sempurna.

4. HASIL DAN PEMBAHASAN

Perancangan Model ANN

Perancangan arsitektur jaringan dengan struktur ANN disesuaikan dengan format training data, yaitu jaringan dengan satu masukan terdiri dari data hasil persamaan *rating curve* berupa debit sungai runtun waktu pada saat waktu t (Q_t) dan satu output yaitu debit sungai pada saat waktu ke $t+1$ (Q_{t+1}). Selanjutnya secara matematis dapat diformulasikan dalam bentuk Persamaan 1 sebagai berikut.

$$Q_{t+1} = f(Q_t) \text{ untuk } n = 1 \quad (1)$$

Langkah selanjutnya dilakukan penyusunan skema konfigurasi model peramalan debit sungai runtun waktu yang diharapkan mampu untuk meramalkan debit sungai untuk satu hari ke depan (H_{t+24}). Ada dua tahap yang sangat penting pada proses peramalan menggunakan struktur ANN algoritma backpropagation yaitu proses training data dan proses testing data (Suprayogi, 2009). Aplikasi dengan struktur ANN membutuhkan data training dan data testing. Keduanya berisi pola *input/output*. Jika training data dipergunakan untuk melatih struktur ANN, testing data digunakan untuk menilai unjuk kerja struktur ANN.

Ada tiga tahap dalam membangun model peramalan debit sungai pada hulu DAS Siak menggunakan pendekatan ANN algoritma Backpropagation yaitu tahapan proses training, proses testing, dan proses validasi model. Penggunaan data pada tahap training, testing dan validasi model untuk membangun model ANN algoritma backpropagation disusun seperti Tabel 1 di bawah ini

Tabel 1. Komposisi Data Pada Tahap Training, Testing dan Validasi Model ANN dan Model W-ANN

Input Data	Tahapan	Awal Data Input	Akhir Data Input	Awal Data Target	Akhir Data Target
Debit Sungai (Q_t)	Training (70%)	20/8/2014	25/11/2014	21/8/2014	26/11/2014
	Testing (30%)	26/11/2014	23/12/2014	27/11/2014	24/12/2014
	Validasi (100%)	20/8/2014	23/12/2014	21/8/2014	24/12/2014

Diskripsi Pola Penggabungan Model Wavelet – ANN

Model Transformasi Wavelet memiliki keunggulan mereduksi *noise* (*denoise*) pada data runtun waktu sedangkan ANN memiliki keunggulan proses peramalan. Dengan menggabungkan antara Transformasi Wavelet yang berfungsi sebagai proses filtering data dan ANN memiliki spesifik generik sebagai proses peramalan dengan harapan akan meningkatkan unjuk kerja model. Ilustrasi penggabungan antara Transformasi Wavelet dan ANN selengkapnya disajikan seperti pada Gambar 4 di bawah ini.



Gambar 4. Diskripsi Penggabungan Model Wavelet- AN

Perancangan Model Wavelet -ANN (W-ANN)

Selanjutnya perancangan arsitektur jaringan dengan struktur W - ANN disesuaikan dengan format training data, yaitu jaringan dengan satu masukan terdiri dari data hasil pengukuran debit runtun waktu pada saat waktu t (Q_t) yang telah dihilangkan *noise* nya menggunakan keluarga Daubechies Wavelet untuk level 1, level 2 dan level 3 dan satu output yaitu debit pada saat waktu ke $t+1$ (Q_{t+1}). Selanjutnya secara matematis dapat diformulasikan dalam bentuk persamaan 2 sebagai berikut.

$$Q_{t+1} = f(dB L n Q_t) \text{ untuk } n = 1, 2 \text{ dan } 3 \quad (2)$$

Training Model ANN

Proses training model dipergunakan untuk melatih struktur ANN. Pada tahap training model menggunakan metode ANN algoritma backpropagation terlebih dahulu dilakukan proses uji parameter statistik koefisien korelasi (R) untuk mendapatkan nilai R yang terbaik dari enam parameter model ANN yaitu neurons, transfer function, epochs, max fail, learning rate, dan momentum. Adapun nilai hasil pengujian enam parameter selanjutnya disajikan seperti pada Tabel 2 di bawah ini.

Tabel 2. Nilai Parameter Terbaik dari Model ANN pada Tahap Training Data

Uji Statistik	neuron	Transfer function		Parameter			
		layer 1	layer 2	epochs	max fail	learning rate	momentum
Nilai R	15	tansig	pureline	10000	10000	0,01	0,90
	0.967	0.969	0.969	0.972	0.972	0.972	0.972

Sumber : Hasil Analisis

Testing Model ANN dan W-ANN

Setelah dilakukan proses training data yang bertujuan untuk melatih struktur ANN maka langkah selanjutnya dilakukan proses testing data model ANN dan W-ANN dengan menggunakan 30% data selain data yang digunakan proses training. Adapun hasil selengkapnya disajikan seperti pada Tabel 3 di bawah ini

Tabel 3. Hasil Proses Testing Data dari model ANN dan W-ANN

Model	ANN	W-ANN	Tingkat Korelasi
Nilai R	0.978	0.97456	Sangat Kuat

Sumber : Hasil Analisis

Validasi Model Model ANN dan W-ANN

Validasi model menurut Refsgaard (2000) merupakan upaya memvalidasi penggunaan model untuk memperoleh perkiraan yang dapat digunakan oleh para pengelola sumberdaya air. validasi model merupakan proses terakhir setelah proses training dan proses testing. Hasil analisis proses validasi data dengan input data 100% menggunakan program Toolbox Matlab 7.0 yang hasilnya disajikan Tabel 4 di bawah ini yang mendiskripsikan hubungan antara varian Model peramalan debit sungai menggunakan ANN dan W-ANN dengan data Observasi.

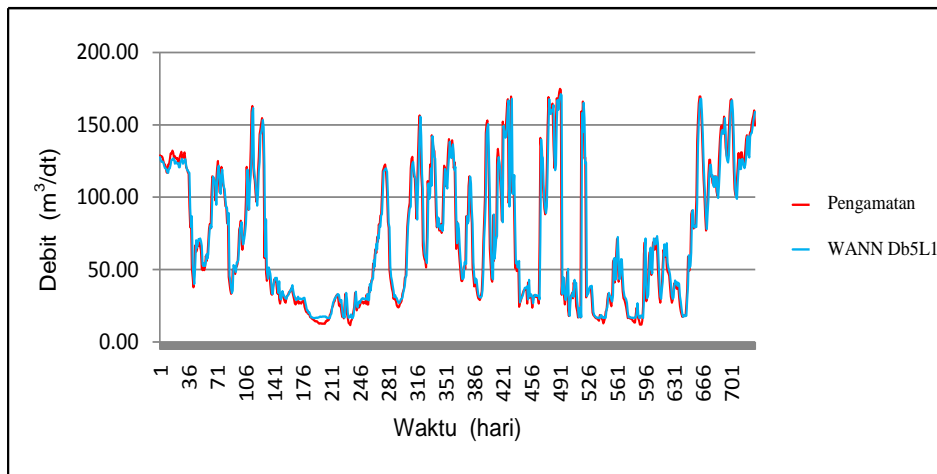
Tabel 4. Hasil Proses Validasi Data dari model ANN dan W-ANN

Model	ANN	W-ANN	Tingkat Korelasi
Nilai R	0.942	0.965	Sangat Kuat

Sumber : Hasil Analisis

Hasil Peramalan Debit Sungai Menggunakan ANN dan W-ANN

Rekomendasi penggunaan model setelah melalui proses training, testing dan validasi model, yang mendiskripsikan unjuk kerja model W-ANN untuk kebutuhan peramalan debit sungai satu hari ke depan (Q_{t+1}) dan data pengukuran yang mendiskripsikan grafik pola hubungan antara nilai debit sebagai fungsi waktu antara Model W-ANN Db Level 1 dan Hasil Pengukuran (observed) yang selengkapnya disajikan seperti pada Gambar 5 di bawah ini.



Gambar 5. Grafik Hubungan Nilai Debit sebagai Fungsi Waktu Model W-ANN Db Level 1 dan Hasil Observasi

Dengan merujuk Gambar 5 di atas, yang mendiskripsikan grafik hubungan antara nilai debit sebagai fungsi waktu antara hasil Model W-ANN Db Level 1 dan Hasil Pengukuran (observed) membuktikan bahwa model W-ANN merupakan model terbaik bila dibandingkan ANN untuk kebutuhan peramalan debit sungai satu hari ke depan ($t + 1$) yang diuji menggunakan nilai koefisien korelasi dengan nilai berturut-turut 0.951 dan 0.948 dengan klasifikasi model W-ANN dan ANN memiliki derajat hubungan sangat kuat ($0.75 < R < 0.99$).

5. KESIMPULAN

Berdasarkan hasil analisis dan pembahasan di atas, maka dapat disimpulkan bahwa pola penggabungan metode transformasi wavelet untuk proses filtering data dan ANN sebagai salah satu komponen softcomputing yang memiliki keunggulan spesifik (generik) pengenalan pola data, maka model W-ANN adalah model terbaik untuk kebutuhan peramalan debit sungai satu hari ke depan ($t + 1$) di Sungai Siak bila dibandingkan ANN yang diuji menggunakan parameter statistik koefisien korelasi dengan nilai berturut – turut 0.951 dan 0.948 dan kedua model baik W-ANN dan ANN memiliki derajat hubungan sangat kuat $0.75 < R < 0.99$ sehingga model W-ANN sangat layak untuk dijadikan sebagai salah satu input data untuk pengembangan Sistem Deteksi Dini Banjir di Sungai Siak.

6. DAFTAR PUSTAKA

Camelio, A. S., Farias, N., Celso, A., G., Santos, Artur, M., G., Lourenco, Tatiane, C., Carniero, 2013, Kohonen Neural Networks for Rainfall Run off Modeling : Case Study of Pianco River Basin, Journal of Urban and Environmental Engineering Vol.7 No.1 pp 176-182

- Dadu, K., S., and Deka, P., C., 2013, Multistep Lead Time Forecasting of Hydrologic Time Series Using Daubechies Wavelet – Artificial Neural Network Hybrid Model. *International Journal Sciencetific Engineering and Research (IJSER)* 2013. Vol. 4. 115-124
- Fausset, L., 1996, *Fundamentals of Neural Networks, Architectures, Algorithms, and Applications*, Prentice Hall, Upper Saddle River, New Jersey.
- Hadihardaja, I., K., dan Sutikno., 2005, Pemodelan Curah Hujan–Limpasan Menggunakan Artificial Neural Network (ANN) dengan Metode Backpropagation, *Jurnal Teknik Sipil Institut Teknologi Bandung (ITB)*, vol 12 No 4 Oktober 2005, hal 249-257
- Jang, J.S.R., Sun C.T. dan Mizutani, E., (1997), *Neuro Fuzzy and Soft Computing*. Prentice Hall, London.
- Ju, Q., Yu, Z. Hao, Z. Hao, C. She, G. Ou, and D. Liu, 2008, “Streamflow Simulation With an Integrated Approach of Wavelet Analysis and Artificial Neural Networks”. *Fourth International Conference on Natural Computation*. IEEE Computer Society Publication, 2008.203, 564-570
- Purnomo, M.H, (2005), *Teknologi Soft Computing : Prospek dan Implementasinya Pada Rekayasa Medika dan Elektrik*, Pidato Pengukuhan Untuk Jabatan Guru Besar Dalam Ilmu Artificial Intelligent Pada Fakultas Teknologi Industri (TI) Institut Teknologi Sepuluh Nopember, Surabaya.
- Pratikto, W.A., (1999), *Aplikasi Pemodelan Di Teknik Kelautan*, Pidato Pengukuhan Untuk Jabatan Guru Besar Dalam Bidang Aplikasi Numerik dan Mekanika Fluida Pada Jurusan Teknik Kelautan Fakultas Teknik Kelautan (FTK) Institut Teknologi Sepuluh Nopember, Surabaya.
- Refsgaard, J.C. 2000. *Towards a Formal Approach to Calibration and Validation of Models Using Spatial Data*, Dalam R. Grayson & G. Blöschl. *Spatial Patterns in Catchment Hydrology: Observations and Modelling*. Cambridge University Press, Cambridge, 329 – 354.
- Sudiana, N., Soewandhita, H., (2007), *Pola Konservasi Sumberdaya Air DAS Siak*, *Jurnal Alami* Volume 12 Nomor 1, Tahun 2007.
- Suprayogi, I., 2009, *Model Peramalan Intrusi Air Laut di Estuari Menggunakan Softcomputing*, Disertasi, Bidang Keahlian Manajemen dan Rekayasa Sumberdaya Air, Jurusan Teknik Sipil, Fakultas Teknik Sipil dan Perencanaan (FTSP) Institut Teknologi Sepuluh Nopember Surabaya (ITS), Surabaya
- Iriawan, N., (2005), *Pengembangan Simulasi Stokhastik Dalam Statistika Komputasi Data Driven*, Pidato Pengukuhan Untuk Jabatan Guru Besar Dalam Bidang Statistik Komputasi dan Proses Stokhastik Pada Jurusan Statistik Fakultas Matematika dan Ilmu Pengetahuan Alam (MIPA) Institut Teknologi Sepuluh Nopember, Surabaya
- Yustanti, W., 2004, *Peramalan Data Time Series Menggunakan Metode Gabungan Transformasi Wavelet Dan ANN*, Tesis, Jurusan Teknik Informatika, Fakultas Teknik Informatika, Institut Teknologi Sepuluh Nopember (ITS) Surabaya.

7. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Balai Wilayah Sungai (BWS) III Sumatera yang telah berkenan memberi ijin penggunaan data – data guna mendukung penelitian ini.