

PREDIKSI DEBIT DAN SEDIMEN PADA DAS BERHUTAN JATI DENGAN PEMODELAN JARINGAN SYARAF TIRUAN (*Artificial Neural Network*)

(*Prediction of Water Discharge and Sediment in Teak Forested Area using Artificial Neural Network Model*)

Nining Wahyuningrum*

Balai Penelitian Teknologi Kehutanan Pengelolaan Daerah Aliran Sungai
Jl. Jend. A. Yani - Pabelan, Kartasura PO BOX 295 Surakarta, Jawa Tengah, Indonesia 57102
Telp. +62 271716709, Fax. +62 271716959

Article Info

Article History:

Received 11 October 2016;
received in revised form 01
March 2017; accepted 07
March 2017.

Available online since 31
March 2017

Kata kunci:
Prediksi
Hujan
Debit
Sedimen
JST

ABSTRAK

Informasi tentang hubungan curah hujan, debit aliran dan sedimen diperlukan dalam perencanaan pengelolaan DAS. Hubungan ini dikenal sangat nonlinear dan kompleks. Meskipun debit dan sedimen sudah dimonitor secara terus menerus, namun kadang kala informasinya tidak atau kurang lengkap. Dalam kondisi ini pemodelan sangat diperlukan. Tujuan penelitian adalah membuat model untuk memprediksi hasil air (*direct runoff*) dan sedimen bulanan dengan menggunakan Jaringan Syaraf Tiruan (JST). Model yang diuji menggunakan data hujan pada saat t-3 dan t-4 sebagai *input*, dan debit dan sedimen pada t+3 dan t+4 sebagai *output*. Data yang digunakan merupakan data tahun 2001 sampai dengan tahun 2014. Hasil penelitian menunjukkan bahwa dari beberapa model yang diuji terdapat 2 model untuk prediksi debit dan 2 model untuk prediksi sedimen. Model tersebut terpilih karena mempunyai MSE terkecil, R² terbesar dan K yang memuaskan (0,5-0,65). Dengan demikian, model-model tersebut dapat digunakan untuk memprediksi debit dan sedimen untuk jangka t+3 dan t+4. Prediksi debit t+3 dan t+4 dapat menggunakan persamaan berturut-turut $Q_{t+3} = 0,64 Q_{t-3} + 0,05$ dan $Q_{t+4} = 0,65 Q_{t-4} + 0,074$, sedangkan prediksi sedimen t+3 dan t+4 menggunakan persamaan $QS_{t+3} = 0,45 QS_{t-3} + 0,052$ dan $QS_{t+4} = 0,45 QS_{t-4} + 0,052$. Pemodelan dengan JST ini dapat diaplikasikan untuk memprediksi debit dan sedimen di lokasi yang lain dengan arsitektur yang disesuaikan dengan kondisi data yang tersedia.

Keywords:

Prediction
Rainfall
Discharge
Sediment
ANN

ABSTRACT

Information on the relationship of rainfall with discharge and sediment are required in watershed management. This relationship is known to be highly nonlinear and complex. Although discharge and sediment has been monitored continuously, but sometimes the information is not or less complete. In this condition, modeling is indispensable. The research objective is to create a model to predict the monthly direct runoff and sediment using Artificial Neural Network (ANN). The model was tested using rainfall data at t-3 and t-4 as input, and discharge and sediment at t+3 and t+4 as output. The data used is the data from 2001 to 2014. The results showed that of some models tested there are two models for the prediction of discharge and two models for sediment. The model was chosen because it has the smallest MSE, the largest R² and satisfying K (0.5 to 0.65). Thus, these models can be used to predict discharge and sediment for a period of t+3 and t+4. Prediction of discharge of t+3 and t+4 may use $Q_{t+3} = 0,64 Q_{t-3} + 0,05$ and $Q_{t+4} = 0,65 Q_{t-4} + 0,074$ respectively, while for predicting sediment of t+3 and t+4 may use equations $QS_{t+3} = 0,45 QS_{t-3} + 0,052$ and $QS_{t+4} = 0,45 QS_{t-4} + 0,052$. This ANN modeling can be applied to predict the flow and sediment in other locations with an architecture adapted to the conditions of available data.

* Corresponding author. Tel.: +62 81393241218
E-mail address: nining0709@yahoo.com (N. Wahyuningrum)

I. PENDAHULUAN

Pengelolaan Daerah Aliran Sungai (DAS) adalah upaya manusia dalam mengatur hubungan timbal balik antara sumberdaya alam dengan manusia di dalam DAS dan segala aktivitasnya, agar terwujud kelestarian dan keserasian ekosistem serta meningkatnya kemanfaatan sumberdaya alam bagi manusia secara berkelanjutan. Dalam pengelolaan DAS tersebut informasi mengenai fluktuasi hasil air dan sedimen sangat diperlukan. Hal ini dapat dijadikan sebagai dasar untuk penilaian keberhasilan pengelolaan DAS, mengingat bahwa kegiatan manusia, seperti perubahan penggunaan lahan dalam suatu DAS akan berdampak pada kondisi DAS (Chow *et al.*, 2012; Nunes *et al.*, 2011; Pramono dan Wahyuningrum, 2010; Shamsuddin *et al.*, 2014). Hasil air yang berlebihan akan menimbulkan masalah banjir, sebaliknya kurangnya pasokan air berdampak pada kekeringan. Oleh karena itu air sangat dibutuhkan sebagai sebab yang menopang kehidupan semua makhluk dalam suatu DAS, maka ketersediaannya pada rentang waktu tertentu perlu untuk diketahui. Informasi mengenai fluktuasi sedimen juga diperlukan untuk memprediksi besarnya tanah yang terangkat dalam aliran air akibat adanya erosi.

Informasi tentang curah hujan dengan debit aliran dan sedimen diperlukan dalam perencanaan pengelolaan DAS. Hubungan ini sangat *nonlinear* dan kompleks karena banyak faktor yang memengaruhi. Selain curah hujan, besar kecilnya debit dan sedimen juga tergantung pada berbagai faktor, seperti lengas tanah, penggunaan lahan, geomorfologi, evapotranspirasi, infiltrasi, distribusi dan durasi curah hujan, dan sebagainya (López-Vicente, dan Navas, 2010; Woznicki, dan Nejadhashemi, 2013). Meskipun debit dan sedimen sudah dimonitor secara terus menerus, namun kadang kala informasinya tidak atau kurang lengkap. Dalam kondisi ini pemodelan sangat diperlukan.

Direktorat Jenderal Sumber Daya Air (Ditjen SDA) menginformasikan bahwa pada tahun 2010 kebutuhan air baku nasional mencapai 175.179 juta m³/tahun dan pada tahun 2030 diperkirakan menjadi 276.125 juta m³/tahun, meningkat tajam hampir dua kali lipat dalam waktu 20 tahun (SDA, 2013). Kondisi ini perlu diantisipasi sejak dini dengan melakukan prediksi-prediksi hasil air untuk jangka waktu tertentu. Prediksi diperlukan untuk memperkirakan hasil air di masa akan datang dengan menggunakan data yang ada. Oleh sebab itu diperlukan model sederhana yang mampu memprediksi hasil air secara akurat dengan data yang sederhana dan mudah diperoleh. Prediksi tersebut dapat dilakukan dengan

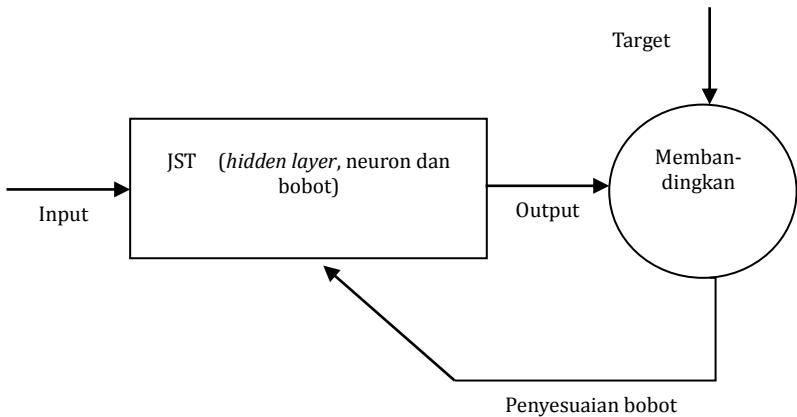
pemodelan, baik dengan menyusun model baru maupun mengaplikasikan model yang sudah tersedia disertai validasi sesuai dengan kondisi DAS yang spesifik (Sikorska *et al.*, 2012). Model merupakan penyederhanaan dari realitas yang kompleks (Voinov, 2008).

Tujuan dari penelitian ini adalah membuat model untuk memprediksi debit aliran sungai (*direct runoff*) dan sedimen bulanan pada DAS berhutan jati (*Tectona grandis*) dengan menggunakan Jaringan Syaraf Tiruan (JST). Dibandingkan dengan model regresi linier, model JST ini lebih akurat (El-shafie *et al.*, 2011; Mittal *et al.*, 2012).

II. METODE PENELITIAN

Pada penelitian ini disusun model kuantitatif dengan metode Jaringan Syaraf Tiruan (JST). JST ini telah banyak digunakan dalam ilmu hidrologi untuk memprediksi arus sungai (Partal, 2009; Phukoethphim *et al.*, 2014; Tiwari *et al.*, 2012; Vafakhah, 2012), memprediksi curah hujan (Arif *et al.*, 2012), evapotranspirasi (Adamala *et al.*, 2014; Jahanbani, dan El-Shafie, 2011; Zanetti *et al.*, 2007), banjir secara *real time* (Ghalkhani *et al.*, 2013), dan banjir regional (Aziz *et al.*, 2014) serta memprediksi kualitas air sungai (Asadollahfardi, *et al.*, 2012; Huang dan Liu, 2010). Model yang dihasilkan oleh mereka rata-rata memberikan nilai efisiensi dan korelasi tinggi, misalnya yang dihasilkan oleh Tiwari *et al.* (2012) memberikan nilai efisiensi 85%, atau Partal (2009) memberikan koefisien korelasi 0,90. Kelebihan dari JST bila dibandingkan dengan metode yang lain yaitu bahwa JST relatif lebih sederhana dan tidak membutuhkan algoritma tertentu dan satu-satunya persyaratan jaringan ini adalah adanya kumpulan contoh yang representatif untuk kemudian JST akan secara otomatis menyesuaikan *output* yang dihasilkan berdasar hasil pelatihan (*input*) (Mittal *et al.*, 2012).

Jaringan saraf tiruan (JST) merupakan sistem pemrosesan informasi yang terdiri dari komponen-komponen sederhana yang beroperasi secara paralel. Komponen-komponen ini terinspirasi oleh sistem saraf manusia. Fungsi jaringan ditentukan terutama oleh hubungan antara komponen-komponennya. JST bisa dilatih untuk melakukan fungsi tertentu dengan menyesuaikan nilai-nilai koneksi (bobot) antara elemen. Umumnya JST disesuaikan atau dilatih sehingga *input* tertentu membawa ke *target output* tertentu (Gambar 1). Jaringan disesuaikan berdasar perbandingan *output* dan *target* sedemikian rupa sehingga *output* jaringan sesuai dengan *target*. Biasanya digunakan pasangan *input-target* untuk melatih jaringan (Demuth dan Beale, 2002).



Gambar 1. Diagram penyesuaian dan pelatihan dalam JST (Demuth dan Beale, 2002)
Figure 1. Diagram adjustment and training in ANN (Demuth & Beale, 2002)

Pemrosesan informasi terletak pada sejumlah komponen yang dinamakan neuron. Sinyal merambat antara satu neuron ke neuron-neuron yang lainnya melalui suatu jaringan penghubung. Tiap jalur penghubung memiliki bobot dan mengalikan besarnya nilai sinyal yang masuk (*input*). Tiap neuron menerapkan fungsi aktivasi yang menjumlahkan semua masukan untuk menentukan sinyal keluarannya (*output*). Tiap jaringan ditentukan oleh arsitektur jaringan, bobot pada koneksi dan fungsi aktivasi (Widodo, dan Handayanto, 2012).

Susunan neuron dan pola keterkaitan antar *layer*, disebut arsitektur jaringan (*net architecture*). Arsitektur JST diklasifikasikan sebagai *single layer* (lapisan tunggal) dan *multilayer* (lapisan majemuk). Untuk menentukan banyak *layer* yang digunakan, *input layer* tidak diikutsertakan sebagai *layer* yang digunakan. Banyaknya *layer* yang disertakan dalam JST menunjukkan banyaknya nilai bobot yang berhubungan antar *layer* tersebut, karena itu nilai bobot merupakan hal yang penting dalam jaringan syaraf tiruan. Skema JST sederhana dapat dilihat pada Gambar 2.

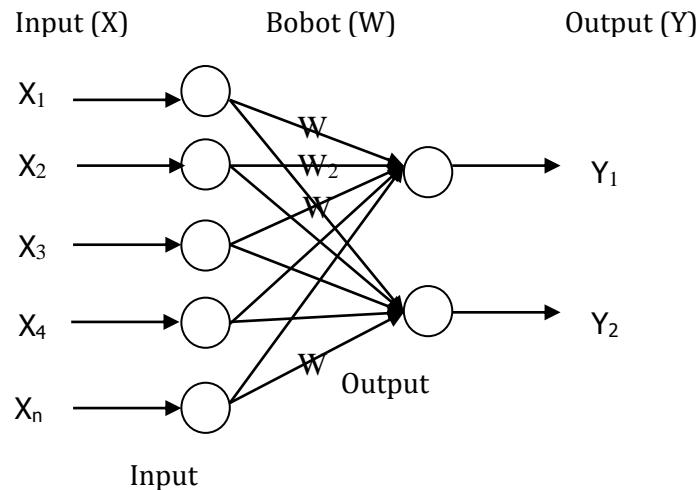
JST bekerja dengan suatu metode pembelajaran (*learning method*) yaitu suatu proses yang parameter bebas dalam JST melakukan adaptasi terhadap lingkungan tempat JST tersebut dipasang. Tipe pembelajaran ditentukan berdasarkan cara yang digunakan untuk merubah parameter JST. Secara garis besar ada dua tipe pembelajaran yaitu *supervised* dan *unsupervised learning*. Pada *supervised learning* target kelas ditentukan lebih awal sedangkan pada *unsupervised learning* tidak ditentukan. Kebanyakan penerapan JST menggunakan *supervised learning* (Widodo dan Handayanto, 2012). Proses *learning* terjadi pada saat pengaturan bobot (*weight*) dan bias. Perambatan balik (*backpropagation*) merupakan salah satu

metode yang paling umum digunakan untuk proses *learning*. Dalam metode ini, bobot-bobot tersebut diatur untuk meminimalisasi nilai kuadrat beda antara *output* model dan *output* taksiran, atau secara umum disebut sebagai SSE (*sum of square errors*). Untuk dapat menghasilkan *output* diperlukan fungsi aktivasi yang memformulasikan *output* dari setiap neuron. Fungsi aktivasi tersebut antara lain *linier* (berupa garis lurus biner dan bipolar) dan logaritmik (logaritmik biner dan bipolar). Dalam bahasa pemrograman *Matlab* kedua fungsi aktivasi tersebut berturut-turut dengan fungsi tranfer *purelin*, *logsig* dan *tansig* (Widodo dan Handayanto, 2012).

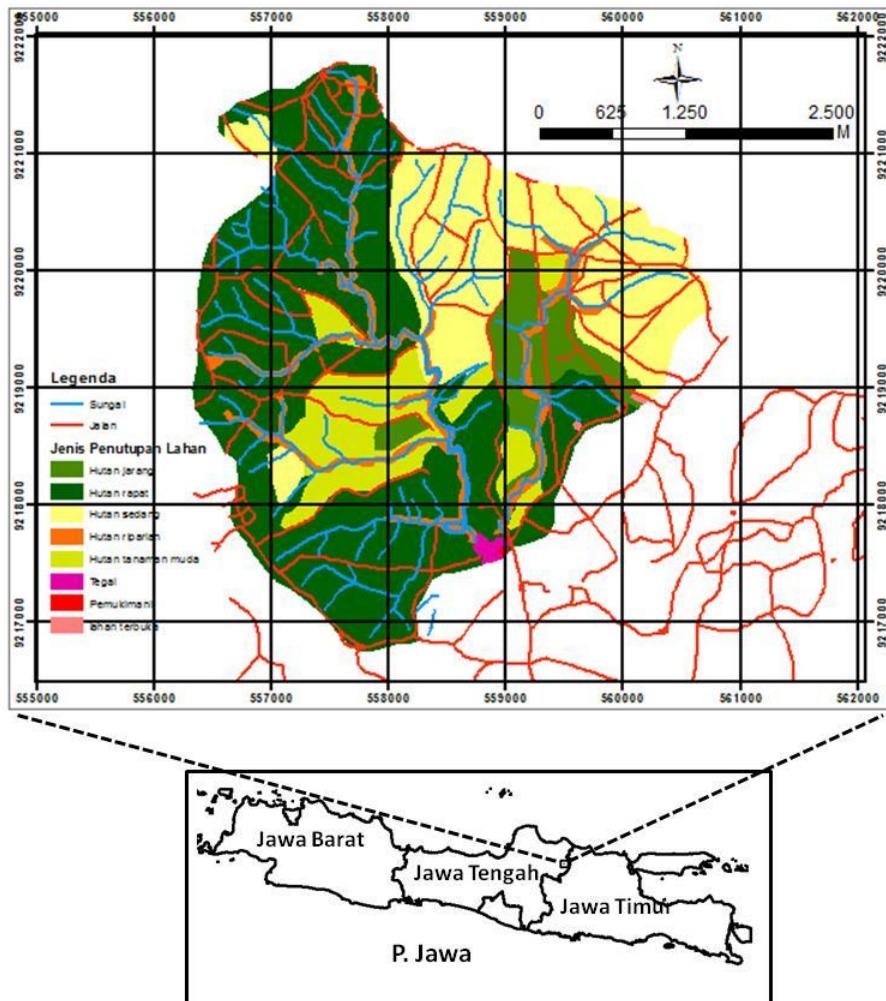
Dalam penelitian ini digunakan DAS sebagai unit analisis. Data penelitian merupakan data primer yang diukur langsung di lapangan melalui survei lapangan maupun pemasangan alat-alat dalam SPAS (Stasiun Pengamatan Arus Sungai). Aplikasi sistem informasi geografis (SIG) digunakan untuk membantu menganalisis peta-peta tematik, sedangkan untuk melakukan pemodelan digunakan *software Matlab R2014a*.

A. Tempat dan Waktu

Penelitian dilakukan di Sub Das Cemoro yang memiliki luas 13,47 km². Secara administratif Sub Das ini terletak di Kabupaten Blora, Provinsi Jawa Tengah. Secara geografis terletak di antara -7,088° s/d -7,037°LS dan 111,505° s/d 111,554° BT. Lokasi Sub Das Cemoro dapat dilihat pada Gambar 3. Lokasi DAS berhutan jati ini dipilih karena karakter lahananya yang khas, yaitu mempunyai batuan induk kapur dengan batas musim penghujan dan kemarau yang sangat jelas dan kondisi penutupannya yang didominasi oleh hutan jati. Pengelolaan hutan dilakukan oleh Perhutani, KPH Cepu. Penelitian dilakukan pada tahun 2011-2014.



Gambar 2. Jaringan Syaraf Tiruan Sederhana (Widodo, dan Handayanto, 2012)
Figure 2. Simple Neural Network (Widodo, and Handayanto, 2012)



Sumber: Peta RBI, Peta Penutupan Lahan

Source: RBI map, Land Cover Map

Gambar 3. Lokasi penelitian: Sub Das Cemoro
Figure 3. Study area: Cemoro Sub Watershed

B. Bahan dan Alat Penelitian

Alat dan bahan yang digunakan dalam penelitian ini adalah SPAS (Stasiun Pengamatan Arus Sungai), AWLR (*Automatic Water Level Recorder*), ARR (*Automatic Rainfall Recorder*), GPS (*Global Position System*), Peta RBI 1:25.000, Peta sistem lahan 1:25.000, Peta Geohidrologi 1:25.000, DEM Aster 30 x 30 m, *Software Matlab R2014a*.

1. Survei lapangan

Survei lapangan dilakukan pada tahun 2011 untuk mengecek kondisi aktual di lapangan dengan berpedoman pada peta-peta tematik, seperti peta sistem lahan dan peta RBI. Data yang dikumpulkan antara lain jenis tanah, kedalaman tanah, kemiringan lahan dan jenis penutupan lahan.

2. Pengukuran parameter hidrologi

a. Pengukuran curah hujan

Curah hujan sebagai input dalam suatu DAS diukur dari stasiun hujan Ngawenan yang mencatat hujan harian secara otomatis.

b. Pengukuran debit pada variasi tinggi muka air

Tinggi muka air dilihat dari pencatatan AWLR. Pengukuran debit ini dilakukan untuk membuat hubungan antara tinggi muka air dan debit (*discharge rating curve*), seperti yang terlihat pada Gambar 4.

c. Pemantauan tinggi muka air

Pemantauan tinggi muka air dilakukan dengan pemasangan AWLR. Data debit sungai diperoleh dari data tinggi muka air dikonversi menjadi debit dengan bantuan *discharge rating curve* (hubungan antara tinggi muka air dan debit).

d. Pengambilan contoh suspensi sedimen

Contoh suspensi ini merupakan dasar perhitungan besarnya sedimen. Tingkat sedimentasi didapatkan dengan mengalikan kandungan suspensi dengan debit. Contoh suspensi diambil pada setiap ketinggian muka air tertentu untuk menyusun *suspended rating curve*. Diagram alir prosedur pengukuran debit dan sedimen dapat dilihat pada Gambar 4.

C. Analisis Data

1. Debit Aliran dan debit sedimen

Kurva hubungan antara debit dan TMA (*discharge rating curve*) disusun dengan formula sebagai berikut (Pramono *et al.*, 2000):

$$Q = a(H_1 - H_0)^b \quad (1)$$

Dalam hal ini:

a, b = koefisien

H_1 = Tinggi Muka Air pada t 1 (cm)

H_0 = Tinggi Muka Air pada t 0 (cm)

Disusun curva hubungan antara debit sedimen dengan debit aliran (*suspended rating curve*) (Pramono, *et.al*, 2000):

$$Q_s = a Q^b \quad (2)$$

Dalam hal ini:

a, b = koefisien

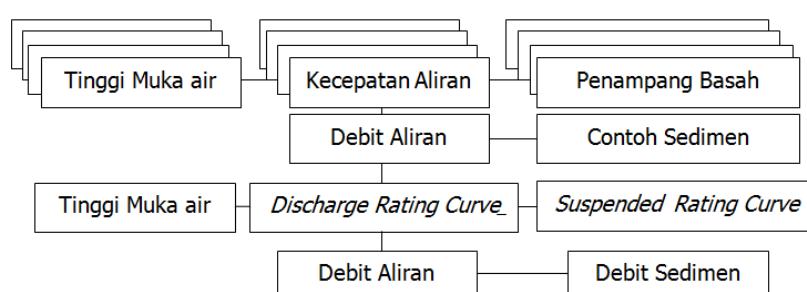
Q_s = Debit sedimen (m^3/dtk)

Q = Debit Aliran (m^3/dtk)

Setelah diketahui grafik hubungan antara tinggi muka air dengan debit dan hubungan antara debit dengan sedimen, maka pada setiap titik ketinggian muka air yang tercatat oleh AWLR dapat diprediksi besarnya debit dan sedimen. Pada penelitian ini digunakan data seri tahun 2001-2014.

2. Pembuatan model dengan metode JST

Data yang digunakan untuk menyusun model adalah data hujan dan debit aliran data hujan bulanan, debit bulanan merupakan hasil pengukuran selama 13 tahun dari tahun 2001-2014. Selanjutnya dilakukan praproses untuk memilih data hujan yang berpasangan dengan data debit (pasangan *input-target*). Artinya pada tanggal/bulan yang sama terdapat data hujan-debit dan hujan-sedimen. Selanjutnya dilakukan proses pelatihan, validasi dan pengujian yang dilakukan dengan *software Matlab R2014a* dengan perintah *nntool*. Model yang diuji adalah model untuk dengan menggunakan data hujan sebagai *input*, debit aliran dan sedimen *target* sekaligus sebagai *output*.



Gambar 4. Diagram alir penyusunan *discharge rating curve* dan *suspended rating curve*
Figure 4. Flow chart of *discharge rating curve* and *suspended rating curve* developments

Penyusunan model dilakukan dengan membuat kombinasi fungsi aktivasi dan metode pembelajaran. Diagram alir yang menerangkan prosedur penyusunan model dapat dilihat pada Gambar 5. Praproses data merupakan proses normalisasi data. Dalam analisis menggunakan JST normalisasi data ini penting untuk menghilangkan dimensi satuan data dan membatasi data pada selang angka tertentu, yaitu antara 0,0 sampai dengan 1,0 (Mehr *et al.*, 2015). Normalisasi data dilakukan dengan cara membagi data dengan nilai maksimumnya.

3. Pengujian kualitas model

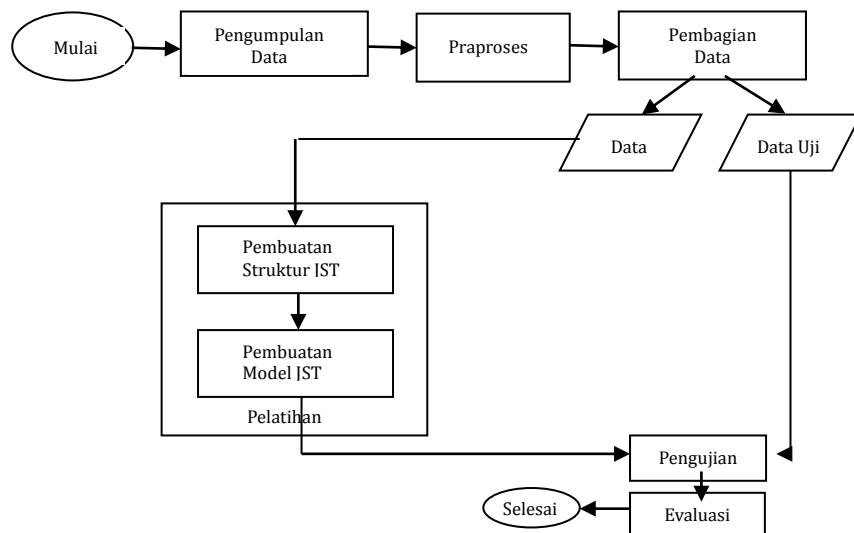
Model yang tersusun akan diuji kualitasnya dengan menghitung koefisien efisiensi Nash dan Sutcliffe (1970), dengan rumus:

$$K = 1 - \frac{\sum(Q_{akt} - Q_{pred})^2}{\sum(Q_{akt} - \bar{Q}_{pred})^2} \quad (3)$$

Dalam hal ini:

- K : Koefisien efisiensi
- Q_{akt} : Debit pengukuran (m^3/dtk)
- Q_{pred} : Debit yang dihasilkan oleh model (output) ((m^3/dtk))
- \bar{Q}_{akt} : Rata-rata Debit yang dihasilkan oleh model (output) ((m^3/dtk))

Nilai K mengindikasikan seberapa bagus data yang diukur terhadap data yang diprediksi dan sesuai dengan grafik 1:1. K bernilai $-\infty$ sampai dengan 1, nilai 1 merupakan nilai yang paling optimal. K antara 0 sampai dengan 1 secara umum merupakan nilai yang dapat diterima sedangkan $K < 0$ mengindikasikan bahwa rata-rata data yang diukur merupakan prediktor yang paling baik bila dibandingkan dengan data yang diprediksi sehingga nilai tersebut tidak dapat diterima. Nilai K yang mendekati satu mengindikasikan bahwa hasil prediksi mendekati nilai aktual pengukuran (Moriasi *et al.*, 2007). Untuk mengetahui apakah model layak diaplikasikan maka dihitung nilai koefisien determinasi (R^2). Nilai R^2 ini menerangkan proporsi varian data aktual yang diukur yang dapat diterangkan oleh model. R^2 bernilai antara 0 sampai dengan 1. Nilai R^2 yang lebih tinggi mengindikasikan *error* yang lebih kecil, biasanya $R^2 > 0,5$ dapat diterima (Moriasi *et al.*, 2007). Nilai R^2 ini mengindikasikan kuatnya hubungan antara nilai prediksi dengan nilai sebenarnya (Mehr *et al.*, 2015). Model yang tersusun juga dihitung nilai *mean square error* nya (MSE), semakin kecil nilai MSE menunjukkan bahwa model semakin mendekati kondisi aktualnya (Moriasi, *et.al*, 2007).



Gambar 5. Diagram alir penyusunan model berbasis JST
Figure 5. Flow diagram of neural network modeling

Tabel 1. Klasifikasi nilai K

Table 1. Classification of K value

No.	Klasifikasi (Classification)	K
1.	Sangat Baik (Very good)	$0,75 < K \leq 1,00$
2.	Baik (Good)	$0,65 < K \leq 0,75$
3.	Memuaskan (Satisfactory)	$0,50 < K \leq 0,65$
4.	Kurang Memuaskan (Unsatisfactory)	$\leq 0,50$

Sumber: Moriasi *et al.* (2007)

Source: Moriasi *et al.* (2007)

III. HASIL DAN PEMBAHASAN

A. Karakteristik Biofisik

Penutupan lahan Sub Das Cemoro didominasi oleh hutan (99,5%) dengan kelerengan dominan masuk pada kategori datar seluas 83,7%. Dari peta geologi terlihat bahwa terdapat dua formasi dengan luas yang hampir sama yaitu formasi Ledok dan formasi Mundu. Kedua jenis formasi tersebut merupakan tanah sedimen klastik dengan ukuran butir yang berbeda. Formasi ledok mempunyai ukuran butir yang lebih kasar dibanding formasi Mundu. Dari peta geohidrologi, Sub Das Cemoro mempunyai lapisan *aquifer* dengan produksi air tanah langka dan sedikit. Dari stasiun hujan Ngawenan diperoleh rata-rata hujan bulanan 134 mm sedangkan rata-rata jumlah hujan tahunan 1608,78 mm. Hujan tertinggi terjadi pada bulan Januari dan terendah pada bulan Agustus. Jenis tanah dominan menurut peta sistem lahan adalah vertisol. Vertisol adalah tanah hitam dan subur, dapat terbentuk dari berbagai macam bahan induk tanah, mineral liatnya didominasi oleh smektit, dan mempunyai sifat yang retak-retak bila kering (Prasetyo, 2007). Dari hasil pengamatan Dariah *et al.* (2004), jenis vertisol mempunyai permeabilitas lambat, struktur gumpal, kandungan pasir 0,6 %, pasir halus 17,4 %, Debu 18,7%, liat 63,4% dan C organic 0,81%.

B. Hujan, Debit Aliran, dan Sedimen Bulanan

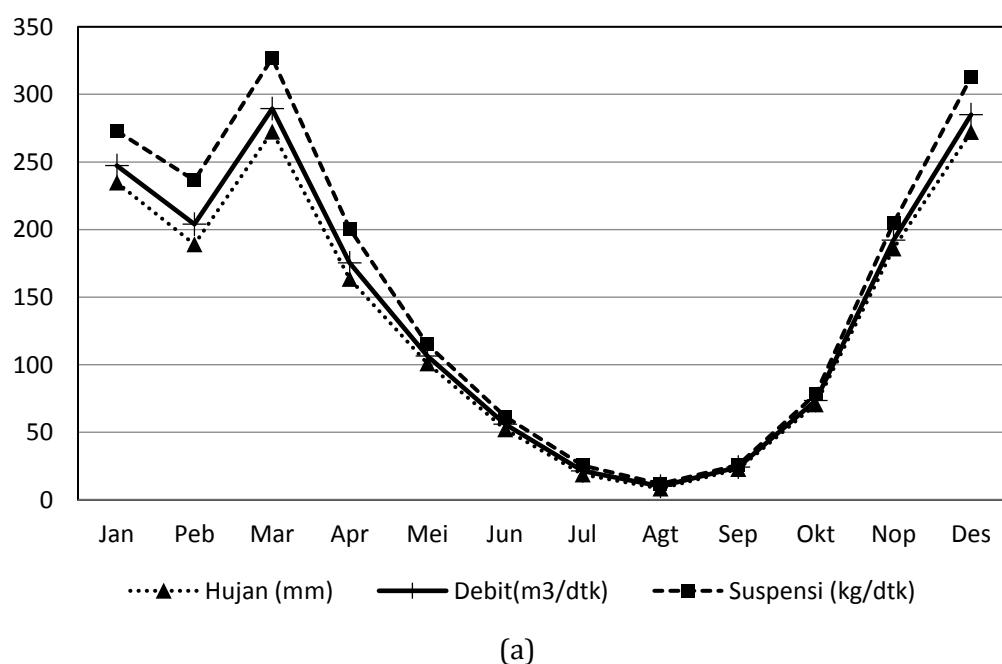
Hasil pengukuran hujan dan perhitungan debit serta sedimen selama tahun 2001 sampai dengan 2014 menunjukkan bahwa ketiga

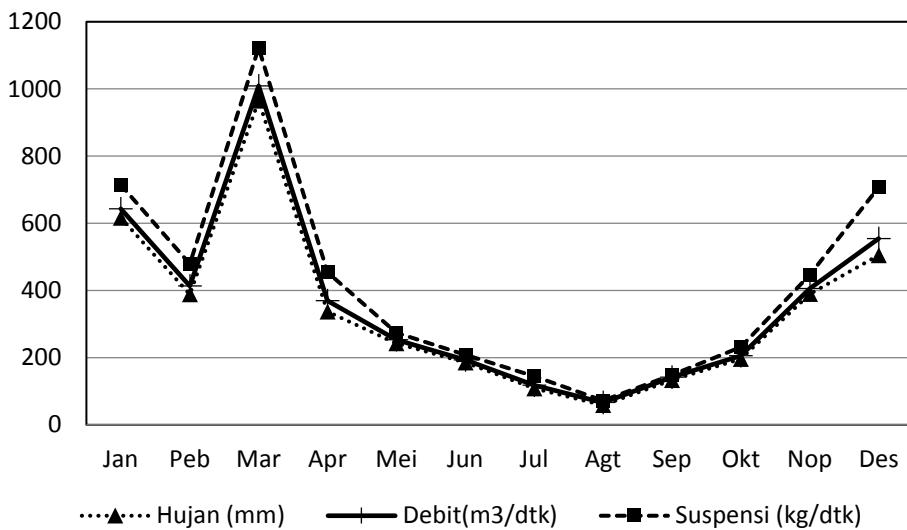
parameter tersebut mempunyai pola yang mirip (Gambar 6a). Dari gambar tersebut jelas terlihat bahwa musim kemarau terjadi antara bulan Juli, Agustus dan September, namun bila dilihat dari nilai minimumnya (Gambar 6c) nilai terendah terjadi pada bulan Juli, Agustus, September dan Oktober. Nilai maksimum terjadi pada bulan Maret (Gambar 6b). Hasil pengukuran debit dan sedimen yang digunakan dalam penyusunan model ini, secara lengkap dapat dilihat pada Lampiran 1.

Data hujan, debit dan suspensi bulanan secara lengkap dapat dilihat pada Lampiran 1. Data tersebut kemudian dinormalkan yaitu dibagi dengan nilai maksimumnya dan selanjutnya diproses dalam JST.

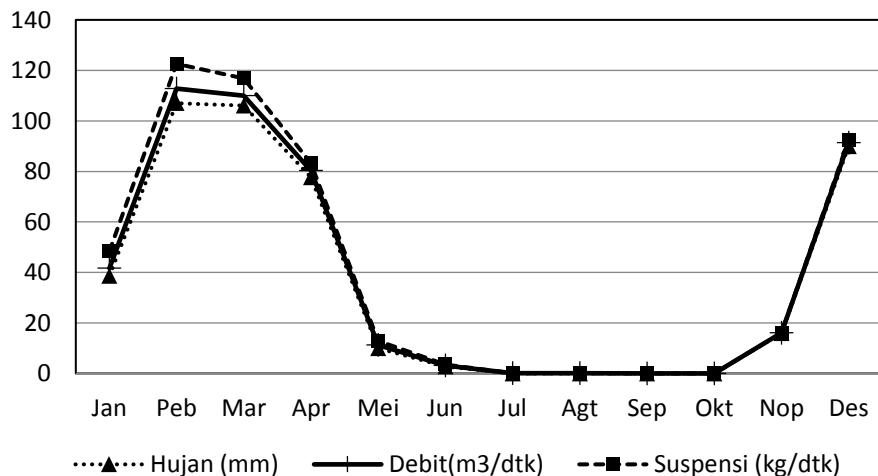
C. JST Propagasi Balik untuk Pemodelan Debit dan Sedimen

Dalam penyusunan model digunakan metode Lavenberg-Marquardt yang bertujuan untuk meminimalkan eror (*mean square error*) pada saat pelatihan. Tujuan pelatihan dalam JST ini adalah untuk menyesuaikan bobot agar selisih antara *output* hasil pengukuran dengan *output* model kecil, dengan menggunakan satu set pasangan data *input* dan target/*output*. Data untuk pelatihan, pengujian dan validasi model dipilih secara random. Diujicobakan beberapa kombinasi arsitektur JST dengan 4 lapisan input, 2 lapisan tersembunyi dan 1 lapisan output, dengan beberapa kombinasi jumlah neuron dan fungsi transfer/aktivasi. Variabel input yang digunakan adalah hujan sedangkan variabel target adalah debit aliran dan sedimen.





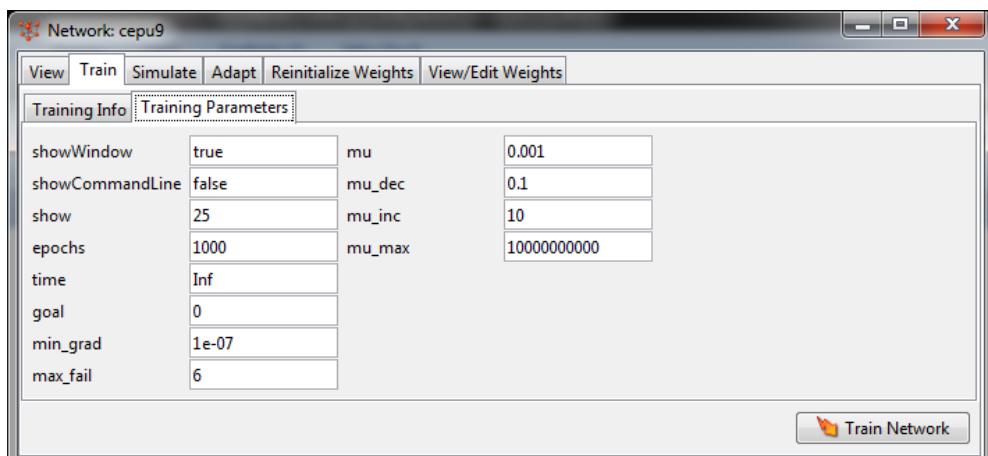
(b)



(c)

Gambar 6. Hujan, debit dan sedimen bulanan, rerata (a), maksimum (b) dan minimum (c) selama tahun 2001-2014.

Figure 6. Monthly rainfall, discharge and sediment, average (a), maximum (b), and minimum (c) during 2011-2014



Gambar 7. Parameter yang digunakan dalam proses pelatihan dengan Matlab R2014a

Figure 7. Parameters used in training process by Matlab R2014a

Dari Gambar 7 terlihat jumlah iterasi maksimal adalah 1000, nilai MSE 0, tingkat pembelajaran 0,001, rasio peningkatan tingkat pembelajaran 10, rasio penurunan tingkat pembelajaran 1×10^{-7} , kegagalan maksimum validasi 6, kenaikan MSE maksimal 10, penurunan MSE minimum 1×10^{-5} . Untuk input dan output digunakan variabel hujan, debit aliran dan sedimen yang merupakan data dari tahun 2001 sampai dengan tahun 2014 (minus tahun 2005) yang tercatat di SPAS Sub Das Cemoro.

1. JST untuk pemodelan debit aliran

Rangkuman arsitektur JST yang diujikan untuk pemodelan debit dapat dilihat pada Tabel 2. Dari Tabel 2 tersebut terlihat bahwa dari enam model yang dicobakan, bila dilihat dari nilai K, R^2 dan MSE, dapat disimpulkan bahwa untuk memprediksi debit aliran pada 3 bulan ke depan ($t+3$) dan 4 bulan ke depan ($t+4$) dapat digunakan

Model 1 dan Model 5. Kedua model tersebut mempunyai nilai MSE terkecil, R^2 terbesar dan K terbesar. Nilai K kedua model tersebut masuk dalam kategori memuaskan, yaitu antara 0,50 s/d 0,65 (Moriasi *et al.*, 2007). Hubungan antara nilai debit pengukuran langsung (*target*) dan debit prediksi (*output*) pada tahap pelatihan (*training*), validasi (*validation*) dan pengujian (*test*) dapat dilihat pada Gambar 8. Dari gambar tersebut terlihat bahwa Model 1 mampu menerangkan 80% data. Dengan demikian, Model 1 ini dapat digunakan untuk memprediksi debit aliran untuk jangka waktu 3 bulan ke depan. Dari Gambar 8 terlihat bahwa untuk memprediksi debit 3 bulan yang akan datang dapat menggunakan persamaan: $Q_{t+3} = 0,64 Q_{t-3} + 0,05$. Gambar 9 memperlihatkan grafik fluktuasi yang searah antara nilai debit pengukuran dengan debit prediksi yang dihasilkan oleh Model 1

Tabel 2. Rangkuman arsitektur JST yang diuji untuk pemodelan debit

Table 2. Summary of ANN net architecture tested for discharge modeling

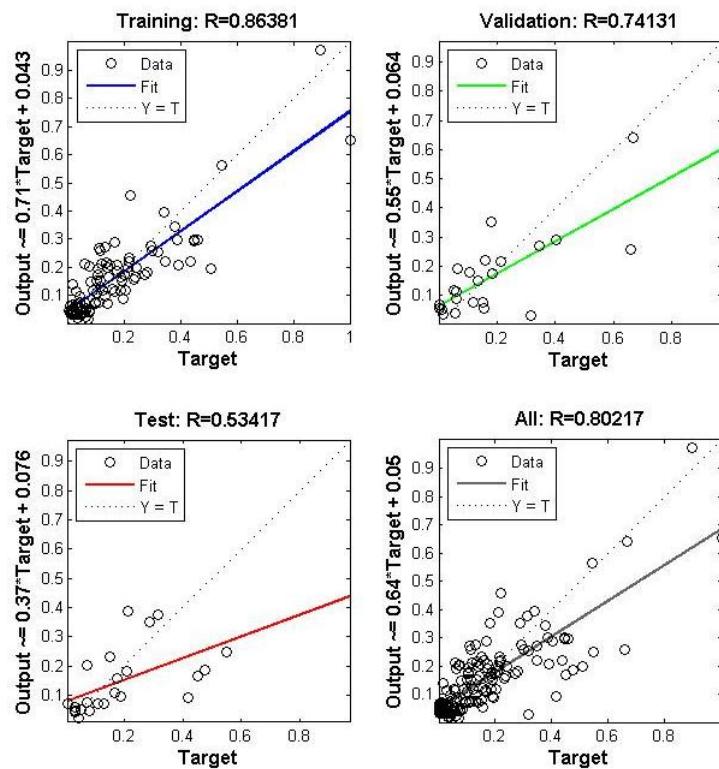
Model	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
Arsitektur JST (Architecture of ANN)						
Input	CH _{t-1}					
	CH _{t-2}					
	CH _{t-3}					
	CH _{t-4}					
Target	Q _{t-3}	Q _{t-3}	Q _{t-3}	Q _{t-4}	Q _{t-4}	Q _{t-4}
Output	Q _{t+3}	Q _{t+3}	Q _{t+3}	Q _{t+4}	Q _{t+4}	Q _{t+4}
Neuron lapisan input (Neuron of input layers)	4	4	4	4	4	4
Neuron lapisan tersembunyi (Neuron of 1st hidden layer)	1	10	10	10	10	10
Neuron lapisan tersembunyi (Neuron of 2st hidden layer)	2	1	1	1	1	1
Neuron lapisan output (Neuron of output layer)		1	1	1	1	1
Fungsi aktivasi lapisan tersembunyi (Activation function of hidden layer)	Learngdm	Learngdm	Learngdm	Learngdm	Learngdm	Learngdm
Fungsi aktivasi lapisan output (Activation function of output layer)	Tansig	Logsig	Purelin	Tansig	Logsig	Purelin
Hasil (Result)						
MSE	0,005	0,007	0,01	0,011	0,006	0,012
R Training	0,86	0,81	0,71	0,50	0,86	0,78
R Validasi	0,74	0,82	0,85	0,73	0,54	0,54
R Test	0,53	0,53	0,85	0,74	0,68	0,64
R Total	0,80	0,78	0,74	0,61	0,80	0,73
K	0,64	0,59	0,53	0,32	0,64	0,53

Sumber: Analisis data (2014)

Source: Data analyses (2014)

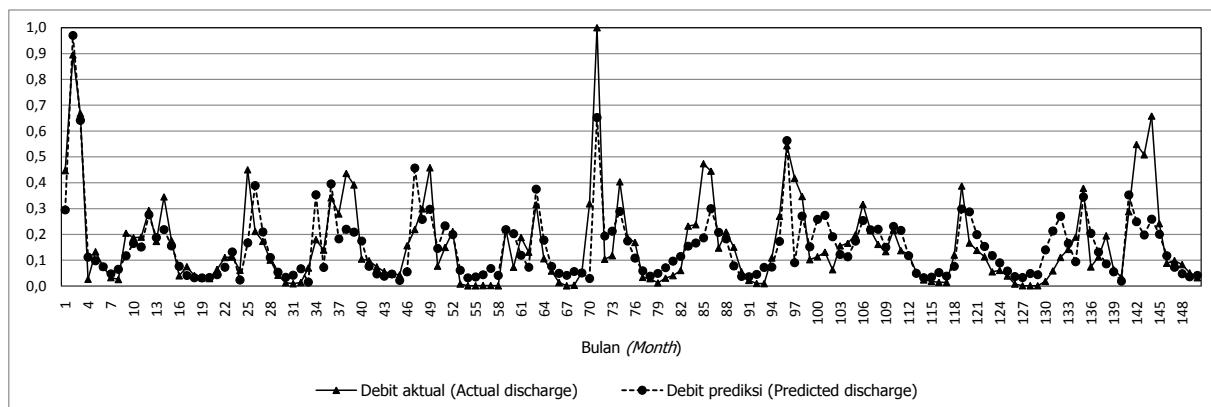
Keterangan (Remarks):

- | | | | |
|-------------------|-----------------------------------|------------------|--------------------------------------|
| CH _{t-1} | :Hujan pada t-1 (Rainfall in t-1) | Q _{t+3} | :Debit aliran t+3 (Discharge in t+3) |
| CH _{t-2} | :Hujan pada t-2 (Rainfall in t-2) | Q _{t+4} | :Debit aliran t+4 (Discharge in t+4) |
| CH _{t-3} | :Hujan pada t-3 (Rainfall in t-3) | Q _{t-3} | :Debit aliran t-3 (Discharge in t-3) |
| CH _{t-4} | :Hujan pada t-4 (Rainfall in t-4) | Q _{t-4} | :Debit aliran t-4 (Discharge in t-4) |



Gambar 8. Hubungan antara debit aktual (*target*) dan debit prediksi (*output*) pada tahap pelatihan (*training*), validasi (*validation*) dan pengujian (*test*) yang dihasilkan oleh Model 1

Figure 8. The relationship between the actual discharge (*target*) and the predicted discharge (*output*) at the stage of training (*training*), validation (*validation*) and testing (*test*) resulted from Model 1



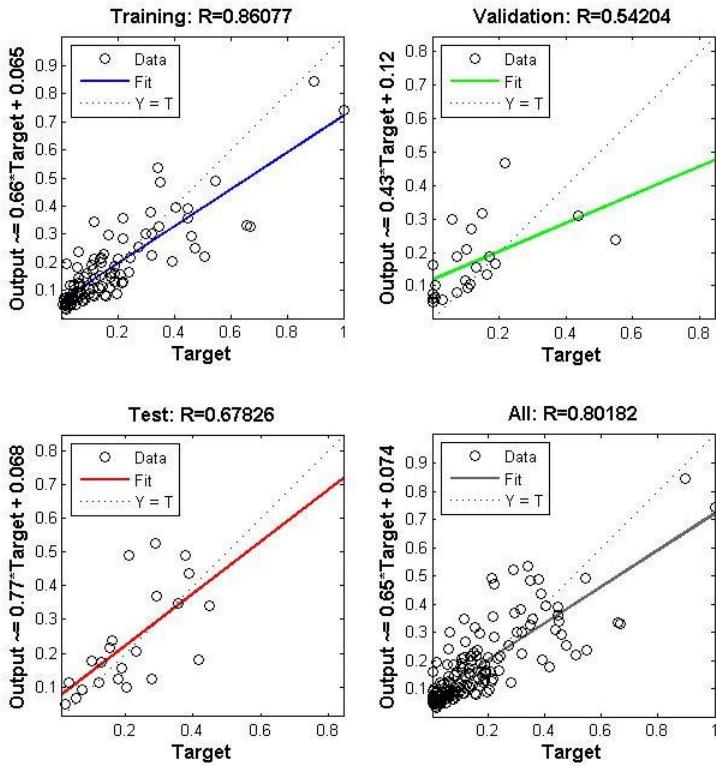
Gambar 9. Fluktuasi debit aktual dan debit prediksi Model 1

Figure 9. Fluctuations of the actual discharge and predicted discharge resulted from Model 1

Untuk memprediksi debit aliran dalam jangka waktu 4 bulan ke depan dapat menggunakan Model 5. Dari Gambar 10 dan Gambar 11 terlihat bahwa prediksi yang dihasilkan dari Model 5 ini memberikan hasil yang memuaskan. Dengan persamaan: $Q_{t+4} = 0,65 Q_{t-4} + 0,074$ (Gambar 10) prediksi debit 4 bulan ke depan dapat dilakukan.

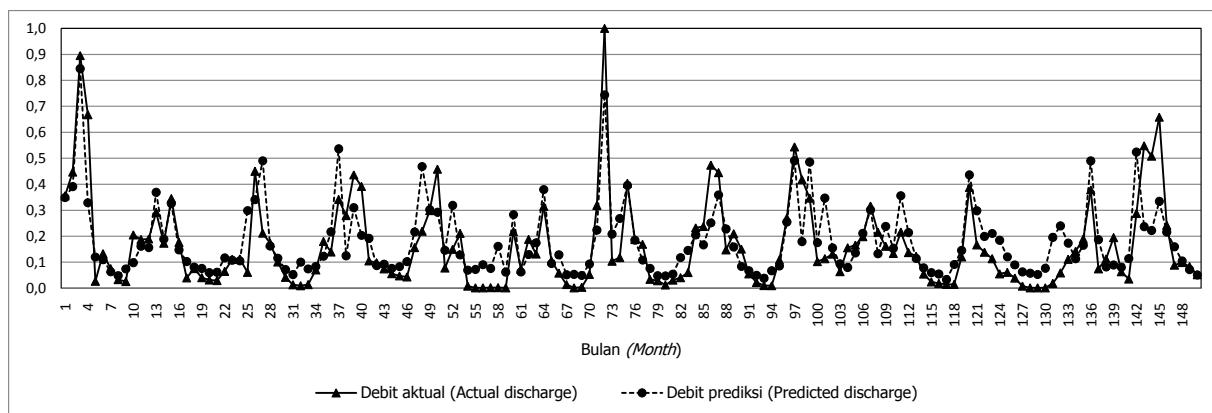
Nilai K yang diperoleh dari Model 1 dan Model 5 mendekati nilai K yang dihasilkan oleh Agarwal, *et al.* (2009) yang memprediksi aliran permukaan di DAS di DAS Vamsadhara India dengan menggunakan data harian, yaitu 0,639. Namun

demikian, nilai R^2 dari kedua model tersebut masih lebih kecil dibandingkan nilai R^2 yang diperoleh Albaradeyia *et al.* (2011) yang berkisar antara 0,8 sampai dengan 0,96. Model prediksi hujan debit dengan JST ini juga telah digunakan untuk memprediksi di beberapa DAS seperti di DAS Temon (Yulianto *et al.*, 2014) yang memprediksi kekeringan berdasarkan data hujan bulanan dan debit bulanan dengan *threshold* (batas) tertentu. Model prediksi ini juga memberikan hasil yang memuaskan dengan hasil prediksi yang mendekati hasil pengukuran.



Gambar 10. Hubungan antara debit aktual (*target*) dan debit prediksi (*output*) pada tahap pelatihan (*training*), validasi (*validation*) dan pengujian (*test*) yang dihasilkan oleh Model 5

Figure 10. The relationship between the actual discharge (*target*) and the predicted discharge (*output*) at the stage of training (*training*), validation (*validation*) and testing (*test*) resulted from Model 5



Gambar 11. Fluktuasi debit aktual dan debit prediksi yang dihasilkan oleh Model 5

Figure 11. Fluctuations of the actual discharge and predicted discharge resulted from Model 5

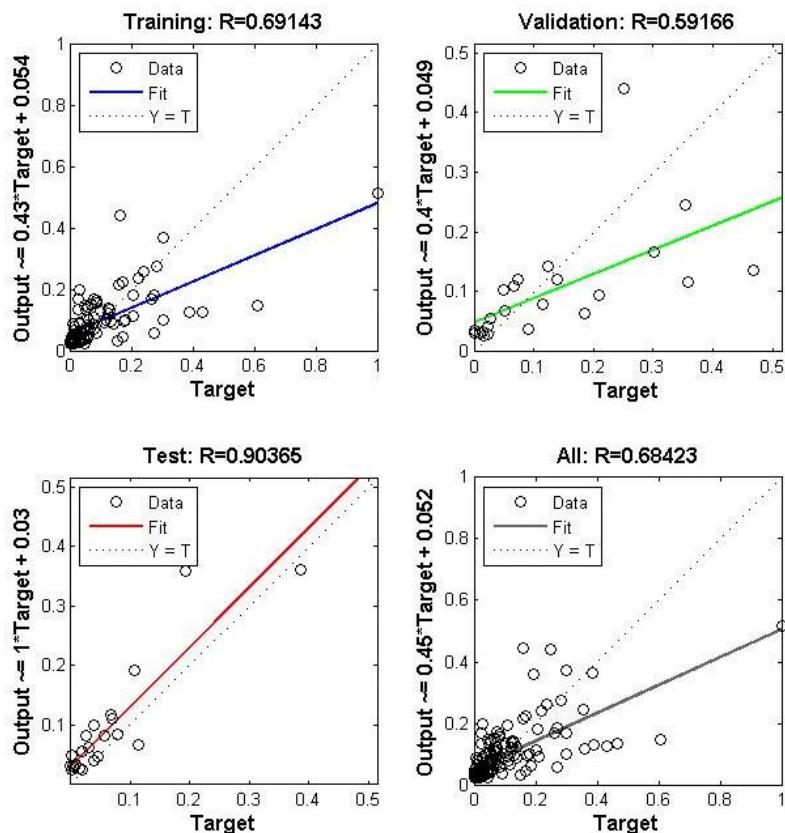
2. JST propagasi balik untuk pemodelan sedimen

Rangkuman arsitektur JST yang diujikan untuk pemodelan sedimen dapat dilihat pada Tabel 3. Dari Tabel 3 tersebut terlihat bahwa dari ke enam model yang dicobakan, bila dilihat dari nilai K, R² dan MSE, dapat disimpulkan bahwa untuk memprediksi debit aliran pada 3 bulan ke depan (t+3) dan 4 bulan ke depan (t+4) dapat digunakan Model 7 dan Model 10. Kedua model tersebut memiliki MSE terkecil, masing-masing

adalah 0,006 dan 0,005. Nilai K yang dihasilkan juga masuk dalam kategori memuaskan menurut Moriasi, et al. (2007), masing-masing yaitu 0,59 dan 0,62. Nilai K ini lebih bagus dari yang dihasilkan oleh Agarwal, et.al. (2009) dalam memprediksi sedimen di DAS Vamsadhara India yang memberikan hasil yang K yang lebih kecil yaitu 0,448 dengan menggunakan data harian. Sementara itu Nourani dan Kalantari (2010) menghasilkan nilai K yang memuaskan yaitu antara 0,76 sampai dengan 0,96.

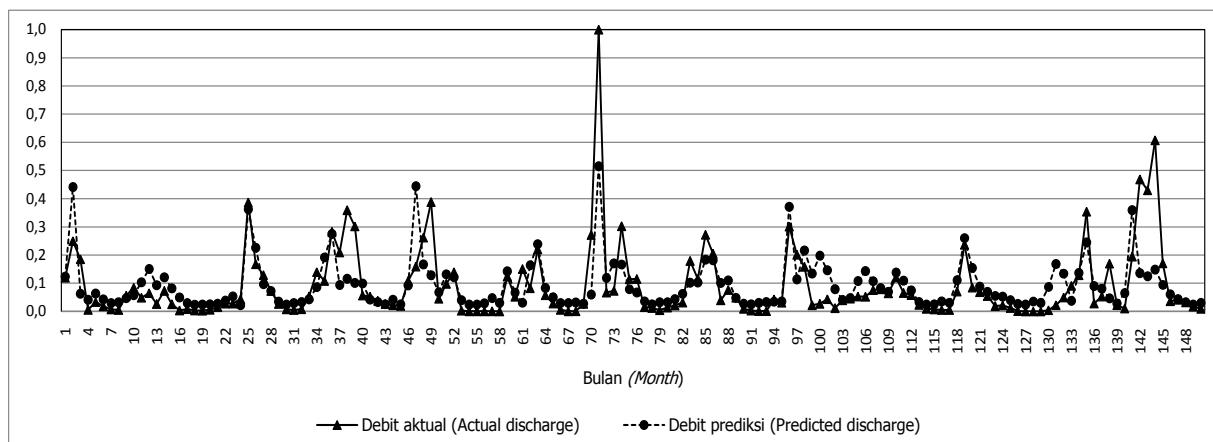
Dari nilai R^2 , dari Model 7 menghasilkan $R^2 = 0,68$, sedangkan dari Model 10 menghasilkan $R^2 = 0,80$. Hal ini mengindikasikan bahwa 0,68 dan 0,80 variasi data sedimen dapat diterangkan oleh Model 7 dan Model 10. Dengan demikian, maka kedua model ini dapat digunakan untuk memprediksi besarnya sedimen. Persamaan: QS_{t+3}

$= 0,45 QS_{t-3} + 0,052$ (Gambar 12) dapat digunakan untuk memprediksi sedimen untuk jangka waktu 3 bulan ke depan dengan menggunakan data sedimen 3 bulan sebelumnya. Hasil prediksi sedimen $t+3$ dengan Model 7 tersebut mempunyai fluktuasi yang mirip dengan fluktuasi sedimen hasil pengukuran (Gambar 13).



Gambar 12. Hubungan antara sedimen aktual (*target*) dan sedimen prediksi (*output*) pada tahap pelatihan (*training*), validasi (*validation*) dan pengujian (*test*) yang dihasilkan oleh Model 7

Figure 12. The relationship between the actual sediment (*target*) and the predicted sediment (*output*) at the stage of training (*training*), validation (*validation*) and testing (*test*) resulted from Model 7



Gambar 13. Fluktuasi debit aktual dan debit prediksi yang dihasilkan oleh Model 7

Figure 13. Fluctuations of the actual discharge and predicted discharge resulted from Model 7

Tabel 3. Rangkuman arsitektur JST yang diuji untuk pemodelan sedimen
Table 3. Summary of ANN net architecture tested for sediment modeling

Model	Model 7	Model 8	Model 9	Model 10	Model 11	Model 12
Arsitektur JST (<i>Architecture of ANN</i>)						
Input	CH t-1					
	CH t-2					
	CH t-3					
	CH t-4					
Target	QS t-3	QS t-3	QS t-3	QS t-4	QS t-4	QS t-4
Output	QS t+3	QS t+3	QS t+3	QS t+4	QS t+4	QS t+4
Neuron lapisan input (<i>Neuron of input layers</i>)	4	4	4	4	4	4
Neuron lapisan tersembunyi 1 (<i>Neuron of 1st hidden layer</i>)	10	10	10	10	10	10
Neuron lapisan tersembunyi 2 (<i>Neuron of 2st hidden layer</i>)	1	1	1	1	1	1
Neuron lapisan output (<i>Neuron of output layer</i>)	1	1	1	1	1	1
Fungsi aktivasi lapisan tersembunyi (<i>Activation function of hidden layer</i>)	Learngdm	Learngdm	Learngdm	Learngdm	Learngdm	Learngdm
Fungsi aktivasi lapisan output (<i>Activation function of output layer</i>)	Tansig	Logsig	Purelin	Tansig	Logsig	Purelin
Hasil (<i>Result</i>)						
MSE	0,006	0,004	0,013	0,005	0,007	0,01
R Training	0,69	0,75	0,56	0,86	0,57	0,52
R Validasi	0,59	0,71	0,77	0,64	0,79	0,81
R Test	0,90	0,32	0,36	0,70	0,60	0,32
R Total	0,68	0,64	0,53	0,80	0,60	0,51
K	0,59	0,39	0,30	0,62	0,36	0,26

Sumber: Analisis data (2014)

Source: Data analyses (2014)

Keterangan (Remarks):

CH t-1 :Hujan pada t-1(*Rainfall in t-1*)
CH t-2 :Hujan pada t-2(*Rainfall in t-2*)
CH t-3 :Hujan pada t-3(*Rainfall in t-3*)
CH t-4 :Hujan pada t-4(*Rainfall in t-4*)

QS t+3 :Sedimen pada t+3 (*Sediment in t+3*)
QS t+4 :Sedimen pada t+4(*Sediment in t+4*)
QS t-3 :Sedimen pada t-3 (*Sediment in t-3*)
QS t-4 :Sedimen pada t-4 (*Sediment in t-4*)

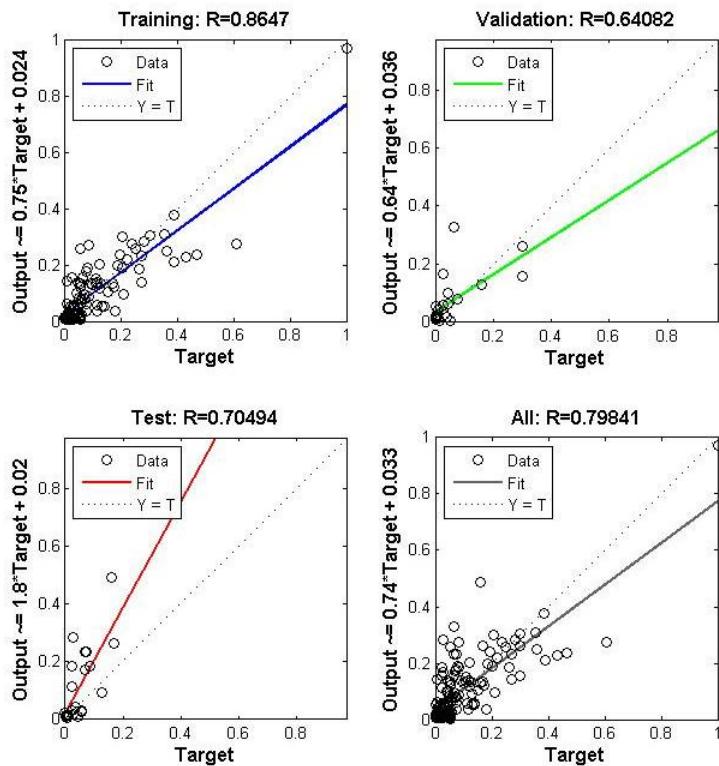
Untuk memprediksi sedimen dalam jangka 4 bulan ke depan dapat menggunakan persamaan: $QS_{t+4} = 0,74 QS_{t-4} + 0,033$ (Gambar 14). Hasil prediksi dengan Model 10 tersebut memberikan menghasilkan fluktuasi yang searah dengan sedimen aktualnya (Gambar 15).

3. Implementasi Model

Jaringan arsitektur JST yang terbangun dapat diaplikasikan untuk membantu kegiatan mitigasi kekeringan dan banjir serta sedimen yang terangkat. Dengan JST ini dapat diprediksi debit dan sedimen untuk 4 bulan ke depan. Antisipasi kekeringan dan banjir dapat dilakukan 4 bulan sebelumnya. Ketersediaan maupun ketidaktersediaan air dapat diprediksi lebih

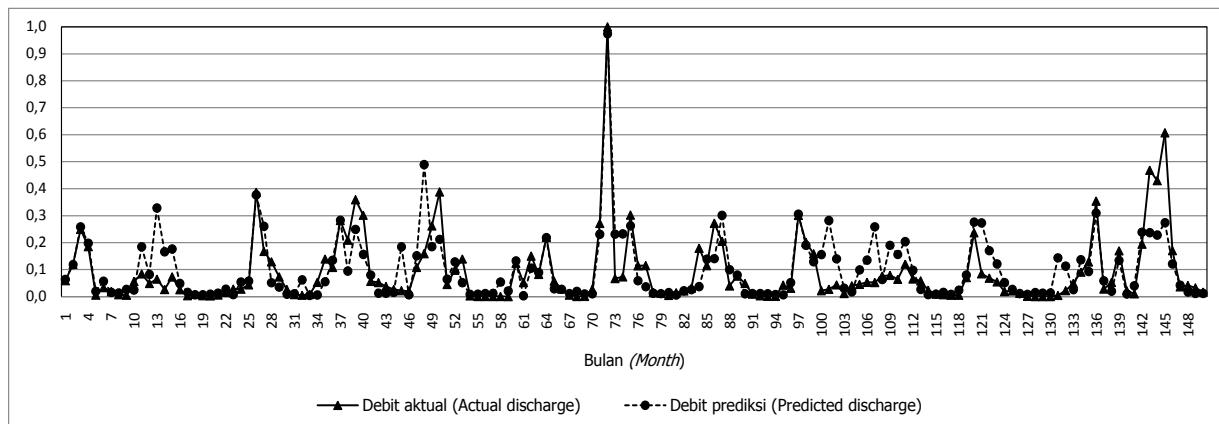
dahulu. Di lokasi penelitian, petani dapat menentukan jenis komoditi pertanian yang akan ditanam pada musim tanam berikutnya serta menentukan tata waktu pengolahan lahan. Demikian juga dengan Perum Perhutani sebagai pengelola hutan, dapat menentukan kegiatan-kegiatan tumpangsari, terutama menyusun tata waktu penanaman.

Dalam rangka pengembangan model, data bisa diperoleh dari beberapa DAS/Sub Das dengan kondisi biofisik yang lebih bervariasi. Data biofisik ini dapat dijadikan sebagai salah satu *input* dalam penyusunan model sehingga pengaruh kondisi biofisik dapat diketahui. Dengan demikian, implementasi model dapat mencakup lokasi yang lebih luas lagi.



Gambar 14. Hubungan antara sedimen aktual (*target*) dan sedimen prediksi (*output*) pada tahap pelatihan (*training*), validasi (*validation*) dan pengujian (*test*) yang dihasilkan oleh Model 10

Figure 14. The relationship between the actual sediment (*target*) and the predicted sediment (*output*) at the stage of training (*training*), validation (*validation*) and testing (*test*) resulted from Model 10



Gambar 15. Fluktuasi debit aktual dan debit prediksi yang dihasilkan oleh Model 10

Figure 15. Fluctuations of the actual discharge and predicted discharge resulted from Model 10

IV. KESIMPULAN DAN SARAN

A. Kesimpulan

Pemodelan untuk prediksi debit dan sedimen dapat menggunakan arsitektur JST. Dari beberapa arsitektur JST yang dicobakan, didapatkan dua model untuk prediksi debit dan dua model untuk prediksi sedimen. Model tersebut adalah Model 1 (satu) untuk prediksi debit tiga bulan ke depan dan Model 5 (lima) untuk prediksi debit tiga bulan ke depan, dengan arsitektur JST seperti pada Tabel 2. Model untuk prediksi sedimen adalah

Model 7 (tujuh) untuk prediksi sedimen tiga bulan ke depan dan Model 10 (sepuluh) untuk prediksi sedimen empat bulan ke depan, dengan arsitektur JST seperti pada Tabel 3. Model tersebut terpilih karena memberikan nilai MSE terkecil, R^2 terbesar dan K yang memuaskan.

Model prediksi debit dan sedimen dapat menggunakan data hujan sebagai input. Dengan menggunakan data hujan t-1, t-2, t-3 dan t-4 dapat digunakan untuk memprediksi debit dan sedimen dalam jangka 3 dan 4 bulan ke depan.

B. Saran

Aplikasi pemodelan debit dan sedimen ini dapat diujicobakan sekaligus diaplikasikan di DAS yang lain dengan arsitektur yang disesuaikan dengan kondisi data yang ada.

UCAPAN TERIMA KASIH

Terima kasih diucapkan kepada BPTKPDas Solo yang sudah menyediakan fasilitas untuk melakukan penelitian dan Edy Sulasmiko yang telah mengumpulkan dan membantu mengolah data hidrologi serta membantu survei di lapangan.

DAFTAR PUSTAKA

- Adamala, S., Raghuvanshi, N. S., Mishra, A. dan Tiwari, M. K. (2014). Evapotranspiration Modeling Using Second-Order Neural Networks. *Journal Hydrology Engineering*, 19(6), 1131-1140.
- Agarwal, A., Rai, R. K. dan Upadyay, A. (2009). Forecasting of Runoff and Sediment Yield Using Artificial Neural Networks. *J. Water Resource and Protection*, 1, 368-375.
- Albaradeyia, I., Hani, A. dan Shahrour, I. (2011). WEPP and ANN Models for Simulating Soil Loss and Runoff in a Semi-Arid Mediterranean Region. *Environ Monit Assess*, 180, 537-556.
- Peraturan Pemerintah Republik Indonesia tentang Pengelolaan Daerah Aliran Sungai Nomor 37 Tahun 2012 (2012).
- Arif, F. M., Gernowo, R., Setyawan, A. dan Febrianty, D. (2012). Analisa data curah hujan stasiun klimatologi Semarang dengan model jaringan syaraf tiruan. *Berkala Fisika*, 15(1), 21-26.
- Asadollahfardi, G., Taklifi, A. dan Ghanbari, A. (2012). Application of Artificial Neural Network to Predict TDS in Talkheh Rud River. *Journal of Irrigation and Drainage Engineering*, 138(4), 363-370.
- Aziz, K., Rahman, A., Fang, G. dan Shrestha, S. (2014). Application of artificial neural networks in regional flood frequency analysis: a case study for Australia. *Stoch Environ Res Risk Assess* 28, 541-554.
- Chow, M. F., Yusop, Z. dan Toriman, M. E. (2012). Modelling Runoff Quantity and Quality in Tropical Urban Catchments Using Storm Water Management Model. *Int. J. Environ. Sci. Technol.*, 9, 737-748.
- Dariah, A., Subagyo, H., Tafakresnanto, C. dan Marwanto, S. (2004). Kepekaan Tanah Terhadap Erosi *Konservasi Tanah pada Lahan Kering Berlereng*. Bogor: Pusat Penelitian dan Pengembangan Tanah dan Agroklimat.
- Demuth, H. dan Beale, M. (2002). *Neural Network Toolbox For Use with MATLAB*. Massachusetts: The Mathworks Inc.
- El-shafie, A., Mukhlisin, M., Najah, A. A. dan Taha, M. R. (2011). Performance of Artificial Neural Network and Regression Techniques for Rainfall-Runoff Prediction. *International Journal of the Physical Sciences* 6(8), 1997-2003.
- Ghalkhani, H., Golian, S., Saghabian, B., Farokhnia, A. dan Shamseldin, A. (2013). Application of surrogate artificial intelligent models for real-time flood routing. *Water and Environment Journal*, 27, 535-548.
- Huang, Y. dan Liu, L. (2010). Multiobjective Water Quality Model Calibration Using a Hybrid Genetic Algorithm and Neural Network-Based Approach. *Journal of Environment Engineering*, 136(10), 1020-1031.
- Jahanbani, H. dan El-Shafie, A. H. (2011). Application of artificial neural network in estimating monthly time series reference evapotranspiration with minimum and maximum temperatures. *Paddy Water Environ*, 9, 207-220.
- López-Vicente, M. dan Navas, A. (2010). Relating Soil Erosion and Sediment Yield to Geomorphic Features and Erosion Processes at the Catchment Scale in the Spanish Pre-Pyrenees. *Environmental Earth Sciences*, 61, 143-158.
- Mehr, A. D., Nazemosadat, M. J., Kahya, E. dan Sahin, A. (2015). Successive-Station Monthly Streamflow Prediction Using Different Artificial Neural Network Algorithms. *International Journal Environment Science Technology*, 12, 2191-2200.
- Mittal, P., Chowdhury, S., Roy, S., Bhatia, N. dan Srivastav, R. (2012). Dual Artificial Neural Network for Rainfall-Runoff Forecasting. *Journal of Water Resource and Protection*, 4, 1024-1028.
- Moriasi, D. N., Arnold, J. G., Liew, M. W. V., Bingner, R. L., Harmel, R. D. dan Veith, T. L. (2007). Model Evaluation on Guidelines for Systematic Quantification of Accuracy in Watershed Simulation. *Transactions of the ASABE*, 50(3), 885-900.
- Nash, J. E. dan Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I -A discussion of principles. *Journal of Hydrology*, 10 (3), 282-290.
- Nourani, V. dan Kalantari, O. (2010). Integrated Artificial Neural Network for Spatiotemporal Modeling of Rainfall Runoff Sediment Processes. *Environmental Engineering Science*, 27(6), 411-422.
- Nunes, A. N., de Almeida, A. C. dan Coelho, C. O. A. (2011). Impacts of land use and cover type on runoff and soil erosion in a marginal area of Portugal. *Applied Geography*, 31, 637-699.
- Partal, T. (2009). River flow forecasting using different artificial neural network algorithms and wavelet transform. *Can. J. Civ. Eng.*, 36, 26-39.
- Peraturan Pemerintah Republik Indonesia tentang Pengelolaan Daerah Aliran Sungai Nomor 37 Tahun 2012 (2012).
- Phukoetphim, P., Shamseldin, A. Y. dan Melville, B. W. (2014). Knowledge Extraction from Artificial

- Neural Networks for Rainfall-Runoff Model Combination Systems. *Journal Hydrology Engineering*, 19(7), 1422-1429.
- Pramono, I. B., Murtiono, U. H., Supangat, A. B. dan Mastur. (2000). Petunjuk Teknis Analisis Data Hujan dan Aliran Sungai. *Info DAS*, 9, 1-39.
- Pramono, I. B. dan Wahyuningrum, N. (2010). Luas optimal hutan jati sebagai pengatur tata air di Daerah Aliran Sungai (DAS) berbahan induk kapur. *Jurnal Penelitian Hutan dan Konservasi Alam*, 7(5). 459-467.
- Prasetyo, B. H. (2007). Perbedaan sifat-sifat tanah vertisol dari berbagai bahan induk. *Jurnal Ilmu-ilmu Pertanian Indonesia*, 9(1), 20-31.
- SDA, D. (2013). Kebutuhan air baku nasional akan meningkat lima kali lipat dalam lima belas tahun ke depan. Retrieved 25 April, 2015, from <http://sda.pu.go.id/index.php/berita-sda/datin-sda/item/346-kebutuhan-air-baku-nasional-akan-meningkat-lima-kali-lipat-dalam-lima-belas-tahun-ke-depan>
- Shamsuddin, S. A., Yusup, Z. dan Noguchi, S. (2014). Influence of plantation establishment on discharge characteristics in a small catchment of tropical forest. *International Journal of Forestry Research*. 2014, 1-10. <http://dx.doi.org/10.1155/2014/408409>
- Sikorska, A. E., Scheidegger, A., Banasik, K. dan Rieckermann, J. (2012). Bayesian Uncertainty Assessment of Flood Predictions in Ungauged Urban Basins for Conceptual Rainfall-Runoff Model. *Hydrology Earth System Science*, 16, 1221-1236.
- Tiwari, M. K., Song, K.-Y., Chatterjee, C. dan Gupta, M. M. (2012). River-Flow Forecasting Using Higher-Order Neural Networks. *Journal Hydrology Engineering*, 17(5), 655-666.
- Vafakhah, M. (2012). Application of artificial neural networks and adaptive neuro-fuzzy inference system models to short-term streamflow forecasting. *Can. J. Civ. Eng.*, 39, 402-414.
- Voinov, A. (2008). *System science and modelling for ecological economics*. Amsterdam, Boston, Heidelberg, London, New York, Oxford: Academic Press, Elsevier.
- Widodo, P. P. dan Handayanto, R. T. (2012). *Penerapan Soft Computing dengan Matlab (Revisi ed. Vol. I)*. Bandung: Rekayasa Sains.
- Woznicki, S. dan Nejadhasemi, A. (2013). Spatial and Temporal Variabilities of Sediment Delivery Ratio. *Water Resources Management*, 27(7), 2483-2499.
- Yulianto, F. E., Hadiani, R. R. dan Setiono. (2014). Pemodelan Hujan Debit untuk Analisis Kekeringan pada DAS Temon. *Matriks Teknik Sipil*, 2(1), 100-107.
- Zanetti, S. S., Sousa, E. F., Oliveira, V. P. S., Almeida, F. T. dan Bernardo, S. (2007). Estimating Evapotranspiration Using Artificial Neural Network and Minimum Climatological Data. *Journal Irrigation and Drainage Engineering*, 133(2), 83-89.

Lampiran 1. Hasil pengukuran dan perhitungan hujan, debit dan suspensi bulanan
Appendix 1. Measurement and calculation of monthly rainfall, discharge and sediment

a. Hasil pengukuran hujan bulanan dalam mm

Tahun	Jan	Peb	Mar	Apr	Mei	Jun	Jul	Agt	Sep	Okt	Nop	Des
2001	165,0	142,0	965,0	205,0	10,0	120,0	35,0	0,0	40,0	112,0	153,0	170,0
2002	228,5	121,3	182,3	93,6	53,0	5,0	2,0	0,0	0,0	7,5	61,5	90,0
2003	38,7	340,1	314,9	77,6	110,0	3,7	1,5	7,0	26,5	119,6	389,7	286,9
2004	345,0	107,0	199,0	135,0	146,0	16,0	37,0	0,0	9,0	11,0	254,0	483,0
2006	283,8	190,0	112,8	208,4	144,7	2,7	1,3	0,0	24,9	35,7	16,0	259,0
2007	110,2	162,8	207,3	337,0	30,5	85,2	0,0	20,9	0,9	97,6	210,4	505,0
2008	261,2	211,3	214,7	85,9	97,6	19,6	0,0	19,9	40,0	145,9	209,7	251,0
2009	241,9	232,5	233,8	125,6	161,4	20,9	9,9	0,5	9,9	46,7	132,8	232,9
2010	616,2	388,4	410,9	221,6	242,4	185,6	108,6	58,3	133,0	195,5	209,6	153,8
2011	161,8	123,5	202,5	139,5	87,9	7,0	0,3	0,0	8,2	63,0	240,7	301,3
2012	182,6	122,7	106,1	78,1	70,4	34,6	0,0	0,0	4,0	46,6	229,4	222,9
2013	208,8	139,5	193,0	296,3	80,1	128,5	24,6	1,3	0,0	0,0	163,1	374,0
2014	208,9	176,8	200,3	121,1	79,3	48,3	23,5	0,0	1,3	38,5	146,5	208,9
Maks	616,2	388,4	965,0	337,0	242,4	185,6	108,6	58,3	133,0	195,5	389,7	505,0
Rerata	234,8	189,1	272,5	163,4	101,0	52,1	18,7	8,3	22,9	70,7	185,9	272,2
Min	38,7	107,0	106,1	77,6	10,0	2,7	0,0	0,0	0,0	16,0	90,0	

b. Hasil perhitungan debit bulanan dalam m³/dtk

Tahun	Jan	Peb	Mar	Apr	Mei	Jun	Jul	Agt	Sep	Okt	Nop	Des
2001	17,46	21,95	43,99	32,80	1,31	6,51	3,69	1,61	1,25	10,08	9,21	9,33
2002	14,34	8,50	16,98	8,66	1,95	3,71	1,98	1,55	1,43	3,17	5,43	5,53
2003	3,00	22,11	10,41	8,52	4,95	2,06	0,63	0,45	0,67	3,45	8,84	6,85
2004	16,77	13,72	21,43	19,24	5,15	4,80	3,64	2,74	2,33	2,13	7,68	10,78
2006	14,68	22,50	3,82	7,36	10,35	0,39	0,06	0,06	0,09	0,10	0,05	10,73
2007	3,60	9,24	6,46	15,49	5,20	2,86	0,70	0,06	0,16	2,59	15,64	49,14
2008	5,11	5,78	19,83	9,20	8,31	1,68	1,41	0,61	1,53	1,99	2,97	11,43
2009	11,68	23,27	21,86	7,24	10,29	7,40	2,70	1,08	0,50	0,48	5,35	13,28
2010	26,71	20,51	17,04	5,02	5,57	6,44	3,13	7,64	8,16	9,75	15,56	10,57
2011	7,94	6,57	10,61	6,74	6,05	2,68	1,18	0,90	0,72	0,71	5,92	19,04
2012	8,19	6,80	5,57	2,71	2,99	1,92	0,39	0,07	0,06	0,07	0,90	2,90
2013	5,46	6,98	9,31	18,61	3,65	5,55	9,56	3,10	0,00	0,00	1,74	14,13
2014	26,94	24,96	32,35	11,88	4,36	4,84	4,08	2,54	1,60	1,27	1,48	1,35
Maks	26,94	24,96	43,99	32,80	10,35	7,40	9,56	7,64	8,16	10,08	15,64	49,14
Rerata	12,45	14,84	16,90	11,80	5,39	3,91	2,55	1,72	1,42	2,75	6,21	12,70
Min	3,00	5,78	3,82	2,71	1,31	0,39	0,06	0,06	0,00	0,00	0,05	1,35

c. Hasil perhitungan sedimen bulanan dalam kg/dtk

Tahun	Jan	Peb	Mar	Apr	Mei	Jun	Jul	Agt	Sep	Okt	Nop	Des
2001	26,88	54,33	113,25	84,11	2,56	15,13	8,24	3,17	2,38	25,44	38,26	22,17
2002	29,57	11,97	33,08	11,61	1,56	3,70	1,59	1,15	2,75	7,01	12,67	12,72
2003	6,68	58,99	25,61	19,73	11,14	4,09	1,16	0,82	1,22	8,07	21,30	16,50
2004	43,10	31,97	54,81	46,10	8,64	7,98	5,72	4,07	3,38	3,03	16,53	24,31
2006	40,03	59,24	6,90	14,97	21,32	0,43	0,04	0,04	0,08	0,09	0,04	18,90
2007	7,94	22,97	12,62	33,61	8,82	4,31	0,87	0,04	0,15	4,13	41,45	152,63
2008	10,25	11,18	46,12	17,46	17,57	2,36	1,85	0,68	2,09	3,20	4,78	27,33
2009	17,53	41,55	31,31	6,06	11,62	7,47	1,43	0,47	0,16	0,17	6,51	4,75
2010	45,97	30,74	24,17	3,32	4,16	6,66	1,74	6,06	6,94	8,10	8,00	11,59
2011	11,99	9,82	18,38	10,00	8,87	3,57	1,41	1,06	0,81	0,80	10,79	36,11
2012	12,92	10,48	8,34	2,89	3,25	1,89	0,22	0,02	0,02	0,02	0,69	3,40
2013	7,58	13,87	19,61	54,01	4,32	8,09	25,95	3,42	0,00	0,00	1,62	29,69
2014	71,52	65,62	92,66	26,05	5,53	6,31	4,96	2,63	1,42	1,04	1,57	1,19
Maks	71,52	65,62	113,25	84,11	21,32	15,13	25,95	6,06	6,94	25,44	41,45	152,63
Rerata	25,54	32,52	37,45	25,38	8,41	5,54	4,24	1,82	1,65	4,70	12,63	27,79
Min	6,68	9,82	6,90	2,89	1,56	0,43	0,04	0,02	0,00	0,00	0,04	1,19