

# Aplikasi Jaringan Syaraf Tiruan (Artificial Neural Networks) Dalam Modelisasi Curah Hujan Limpasan Dengan Perbandingan Dua Algoritma Pelatihan (Studi Kasus: DAS Tukad Jogading)

*by Putu Ardana*

---

**Submission date:** 15-May-2023 08:32AM (UTC+0700)

**Submission ID:** 2093161684

**File name:** KonTekS\_Solo\_-\_Isi.pdf (511.96K)

**Word count:** 4644

**Character count:** 27273

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/316921562>

# Aplikasi Jaringan Syaraf Tiruan (Artificial Neural Networks) Dalam Modelisasi Curah Hujan Limpaan Dengan Dua Algoritma Pelatihan (Studi Kasus : DAS Tukad Jogading)

Preprint · October 2013

DOI: 10.13140/RS.2.2.30014.84808

CITATIONS

0

READS

1,950

1 author:



Putu Doddy Heka Ardana  
Universitas Ngurah Rai

19 PUBLICATIONS 1 CITATION

[SEE PROFILE](#)

**Aplikasi Jaringan Syaraf Tiruan (*Artificial Neural Networks*)  
Dalam Modelisasi Curah Hujan Limpasan Dengan  
Perbandingan Dua Algoritma Pelatihan  
(Studi Kasus: DAS Tukad Jogading)**

*Putu Doddy Heka Ardana*<sup>1</sup>

<sup>1</sup>Jurusan Teknik Sipil, Universitas Ngurah Rai, Jln. Padma Penatih Denpasar  
Email: doddyhekaardana@gmail.com

**ABSTRAK**

Pengalihragaman curah hujan menjadi limpasan pada daerah aliran sungai adalah suatu fenomena hidrologi yang sangat kompleks, dimana ini merupakan proses nonlinear, dengan waktu yang berubah-ubah dan terdistribusi secara spasial. Untuk mendekati fenomena tersebut, maka telah dikembangkan suatu analisa sistem hidrologi dengan menggunakan model yang merupakan penyederhanaan kenyataan alam yang sebenarnya. Model tersebut dibentuk oleh satu set persamaan matematis yang mencerminkan perilaku dari parameter dalam hidrologi.

Pada penelitian ini, analisis mengenai hubungan curah hujan-limpasan untuk daerah aliran sungai (DAS) digunakan model *Artificial Neural Networks* (ANN). ANN merupakan salah satu bentuk kecerdasan buatan yang mempunyai kemampuan untuk belajar dari data dan tidak membutuhkan waktu yang lama dalam eksekusi model. ANN *multi layer perceptron* dengan metode *back propagation* dengan perbandingan 2 (dua) algoritma pelatihan (*gradient descent* dan *adaptive learning rate*) digunakan untuk mempelajari hubungan hujan-limpasan pada DAS Tukad Jogading serta memverifikasi model tersebut secara statistik berdasarkan nilai *mean square error* (MSE), *root mean square error* (RMSE), kesalahan absolute rata-rata (KAR) dan nilai koefisien korelasi (r).

Hasil penelitian menunjukkan bahwa penggunaan model ANN metode *back propagation* dapat diterapkan dalam modelisasi hubungan curah hujan limpasan. Dari enam model arsitektur jaringan yang diterapkan, model 6 dengan pelatihan *gradient descent* berarsitektur 4-10-5-1 memberikan hasil yang paling optimum dengan tingkat nilai kesalahan absolute rata-rata (KAR) 1,7548 dengan nilai koefisien korelasi 91,64 % pada proses pembelajaran. Pada proses pengujian, model 5 berarsitektur 3-10-5-1 memberikan nilai KAR 1,0241 dengan nilai koefisien korelasi 69,77 %. Sedangkan model 6 dengan pelatihan *adaptive learning rate* berarsitektur 4-10-5-1 memberikan hasil yang paling optimum nilai KAR 1,3217 dengan nilai koefisien korelasi 90,78% pada proses pembelajaran. Pada proses pengujian, model 3 berarsitektur 4-5-1 memberikan nilai KAR 1,4771 dengan nilai koefisien korelasi 69,01%. Dari hasil tersebut terlihat bahwa ANN memiliki kemampuan yang cukup baik dalam merepresentasikan fluktuasi debit yang acak ke dalam bentuk model buatan yang memiliki fluktuasi yang hampir sama dan juga dapat diterapkan dalam modelisasi curah hujan limpasan walaupun hasil pengujian (testing) hasilnya tidak terlalu akurat karena masih terjadi penyimpangan.

Kata kunci: pemodelan curah hujan limpasan, DAS, *artificial neural networks*, metode *back propagation*, *gradient descent*, *adaptive learning rate*

**1. PENDAHULUAN**

Proses hidrologi secara sederhana dapat digambarkan dengan adanya hubungan antara unsur masukan yakni hujan, proses dan keluaran yaitu berupa aliran (Hadi, 2006). Hubungan curah hujan-limpasan merupakan masalah penting dalam hidrologi dan menjadi komponen yang paling mendasar dalam proses evaluasi sumber daya air (Junsawang, et.al., 2007). Hubungan curah hujan limpasan, khususnya pengalihragaman curah hujan menjadi limpasan, pada suatu daerah aliran sungai adalah suatu fenomena hidrologi yang sangat kompleks. Dimana, proses ini adalah non linear dengan waktu yang berubah-ubah dan terdistribusi secara spasial (Rajurkar, et.al., 2003). Untuk mendekati fenomena tersebut, maka telah dikembangkan suatu analisa sistem hidrologi dengan menggunakan model yang merupakan penyederhanaan kenyataan alam yang sebenarnya (Hadihardaja dan Sutikno, 2005).

Seiring dengan berkembangnya dunia digital (komputer), sejumlah model telah dikembangkan untuk menirukan proses ini. Baik itu model empiris (*black box model*), model konseptual (*physical process based*), model kontinyu (*continuous events*), *lumped* model, model distribusi dan model *single* (Setiawan dan Rudyanto, 2004).

Model-model tersebut dibentuk oleh satu set persamaan matematis yang mencerminkan perilaku dari parameter dalam hidrologi, sehingga parameter-parameter yang terkandung dalam persamaan tersebut mempunyai arti fisik (Adidarma, dkk., 2004).

Dalam beberapa tahun terakhir, *Artificial Neural Networks* (ANN) sebagai salah satu bentuk model kotak hitam (*black box model*), telah berhasil digunakan secara optimal untuk memodelkan hubungan non linier *input-output* dalam suatu proses hidrologi yang kompleks dan berpotensi menjadi salah satu alat pengambil keputusan yang menjanjikan dalam hidrologi (Dawson dan Wilby, 2001). ANN merupakan salah satu bentuk kecerdasan buatan yang mempunyai kemampuan untuk belajar dari data dan tidak membutuhkan waktu yang lama dalam pembuatan model (Setiawan dan Rudiyanto, 2004). Model ini menggunakan satu set persamaan matematis linier dan non linier yang tidak memperhitungkan sama sekali proses fisiknya, yang terpenting dalam model ini adalah *output* yang dihasilkan mendekati yang sebenarnya (Adidarma, dkk., 2004). Selain itu, ANN juga mampu mengidentifikasi struktur model dan juga efektif dalam menghubungkan *input* serta *output* simulasi dan model peramalan (Setiawan dan Rudiyanto, 2004).

Penggunaan model ANN antara lain telah diterapkan dalam memodelkan hubungan curah hujan-limpasan dalam suatu DAS (Sharma and Murthy, 1998; Abdulla and Badranih, 2000; Setiawan dan Rudiyanto, 2004; Hadihardaja dan Sutikno, 2005; Kalteh, 2008). Dari hasil studi yang dilakukan oleh Setiawan dan Rudiyanto (2004), dilakukan pemodelan curah hujan-limpasan untuk DAS Cidanau dengan luas daerah pengaliran 226,2 km<sup>2</sup>. Data selama empat tahun (1996-1999) dianalisis dengan model *artificial neural networks* metode *back propagation*. Didapatkan model ANN dapat memprediksi dengan baik limpasan yang terjadi dalam DAS, dimana diperoleh nilai koefisien korelasi sebesar 0,962 atau 96,2% dan *root mean square error* (RMSE) 0,959. Sedangkan dari hasil studi yang dilakukan oleh Hadihardaja dan Sutikno (2005), dilakukan pemodelan curah hujan-limpasan untuk DAS Way Sekamung-Pujorahayu dengan luas daerah pengaliran 1696 km<sup>2</sup>. Data yang dipergunakan adalah data selama kurun waktu 19 tahun yakni dari tahun 1983 sampai tahun 2001. Data curah hujan merupakan *input* sedangkan data debit merupakan variabel *output*. Pada penelitian tersebut digunakan empat arsitektur jaringan dengan model jaringan banyak lapisan (*multilayer net*) dan menggunakan metode pembelajaran *back propagation*. Dari hasil penelitian tersebut diperoleh koefisien korelasi tertinggi sebesar 0,813 atau 81,3% dengan nilai *mean square error* (MSE) 0,008 dan nilai kesalahan absolute rata-rata (KAR) 0,447. Hal ini berarti ANN dapat diterapkan dalam modelisasi hubungan curah hujan-limpasan.

Berdasarkan hasil penelitian mengenai hubungan curah hujan-limpasan dengan model ANN, penggunaan obyek studi penelitian adalah DAS dengan luas area lebih besar dari 100 km<sup>2</sup>. Didapatkan hasil bahwa, model ANN telah dapat diterapkan dengan baik. Tetapi, untuk DAS dengan luas area kurang dari 100 km<sup>2</sup>, model ANN masih belum jelas penerapannya dikarenakan hubungan curah hujan-limpasan cenderung mengarah ke proses linieritas (Sohail, et.al, 2008). Terkait dengan luasan DAS, Indonesia memiliki 5.590 DAS. Keragaman geografis menyebabkan luas masing-masing DAS umumnya kecil, sekitar 86,6% dengan luas kurang dari 500 km<sup>2</sup>. Dari prosentase tersebut, sekitar 40% DAS dengan luas kurang dari 500 km<sup>2</sup> terdapat di wilayah Bali dan Nusa Tenggara (Amron, 1998 dalam Sunaryo, dkk., 2004). Selain itu, penggunaan fungsi pembelajaran dalam ANN yang banyak digunakan adalah fungsi dengan algoritma dasar *gradient descent* yang mana hanya menggunakan 1 (satu) fungsi pelatihan saja.

Berkaitan dengan hal tersebut, dipandang perlu dilakukan suatu penelitian mengenai pemodelan hubungan curah hujan-limpasan dengan model *Artificial Neural Networks* dengan algoritma fungsi pembelajaran yang berbeda pada DAS dengan luas area kurang dari 100 km<sup>2</sup> guna lebih memahami bagaimana kinerja dari ANN tersebut dan apakah aplikasi ini cocok diimplementasikan untuk DAS dengan luas kurang dari 100 km<sup>2</sup>. Obyek studi yang diambil adalah DAS Tukad Jogading di Jembrana yang memiliki luas 32,38 m<sup>2</sup>. Verifikasi model dilakukan secara statistik berdasarkan nilai *mean square error* (MSE), *root mean square error* (RMSE), kesalahan absolute rata-rata (KAR) dan nilai koefisien korelasi (r). Model ANN yang digunakan untuk analisis menggunakan metode *Multi Layer Perceptron* (MLP) *back propagation* dimana dibandingkan antara fungsi pembelajaran beralgoritma *gradient descent* dengan fungsi pembelajaran beralgoritma *adaptive learning rate*, dikerjakan dengan bantuan *software* MATLAB versi 7.0.1 Release 14.

## 2. TUJUAN PENELITIAN

Adapun tujuan penelitian ini adalah sebagai berikut:

- a. Mengkaji penerapan model *Artificial Neural Networks* dengan metode *multi layer perceptron* (MLP) *back propagation* dengan perbandingan fungsi pembelajaran beralgoritma *gradient descent* dan fungsi pembelajaran beralgoritma *adaptive learning rate* di dalam modelisasi hubungan curah hujan limpasan untuk beberapa DAS dengan luas kurang dari 100 km<sup>2</sup> di Propinsi Bali.
- b. Mengkaji tingkat kinerja model *Artificial Neural Networks* dengan metode *multi layer perceptron* (MLP) metode *back propagation* dengan perbandingan fungsi pembelajaran beralgoritma *gradient descent* dan fungsi pembelajaran beralgoritma *adaptive learning rate* di dalam penggambaran hubungan curah hujan limpasan untuk beberapa DAS dengan luas kurang dari 100 km<sup>2</sup> di Propinsi Bali.

### 3. LOKASI STUDI

Lokasi studi adalah daerah aliran sungai (DAS) Tukad Jogading yang berada di Kabupaten Jembrana Propinsi Bali. Daerah aliran sungai (DAS) Tukad Jogading memiliki luas kurang dari 100 km<sup>2</sup> yakni 32,38 km<sup>2</sup> (Anonim, 2007) dengan bentuk daerah pengaliran secara umum memanjang (Anonim, 2009). Data yang diambil untuk digunakan dalam pengalirragaman curah hujan menjadi limpasan adalah data iklim (data temperatur, kecepatan angin, kelembaban relatif, kelembaban maksimum, dan lama penyinaran) dan data hidrologi (data curah hujan, data debit dan evapotranspirasi). Data iklim menggambarkan kondisi cuaca di suatu daerah studi, dan faktor iklim bulanan yang terkumpul selama 10 (sepuluh) tahun yakni dari tahun 1994 – 2003. Data iklim ini didapat dari stasiun klimatologi Negara. Sedangkan ketersediaan data hidrologi berupa data curah hujan bulanan yang didapat dari stasiun hujan Dauh Waru, stasiun hujan Pohsanten, dan stasiun hujan Negara. Data curah hujan yang terkumpul sebanyak 10 tahun dari tahun 1994 – 2003.

### 4. METODOLOGI

#### 4.1 Teknik Analisis Data

##### 4.1.1 Analisis data hujan

Dalam penelitian ini, data hidrologi yang digunakan bersumber dari beberapa stasiun hujan, dan data tersebut berupa data curah hujan bulanan pada beberapa stasiun hujan. Data curah hujan bulanan digunakan sebagai data masukan (*input*) di dalam pemodelan. Analisis data hujan ini meliputi uji konsistensi data, curah hujan rata-rata areal (*areal rainfall*) dan perbaikan data hujan.

##### 1. Uji Konsistensi Data

Pada suatu seri data hujan, bisa terjadi *nonhomogenitas* data dan ketidaksamaan (*inconsistency*) data. Data tidak homogen maupun tidak konsisten menyebabkan hasil analisis tidak teliti. Oleh karena itu sebelum data tersebut dipakai untuk analisis, terlebih dahulu harus dilakukan uji konsistensi.

Uji konsistensi dilakukan dengan metode RAPS (*Rescaled Adjusted Partial Sums*) dengan menggunakan data dari stasiun itu sendiri yaitu pengujian dengan kumulatif penyimpangan terhadap nilai rata-rata dibagi dengan akar kumulatif rerata penyimpangan terhadap nilai reratanya.

##### 2. Hujan wilayah

Curah hujan yang diperlukan untuk pengalirragaman hujan limpasan adalah curah hujan rata-rata di seluruh daerah yang bersangkutan. Stasiun-stasiun pengamat hujan yang tersebar pada suatu daerah aliran sebagai hujan titik (*point rainfall*).

Untuk mengubah hujan titik (*point rainfall*) menjadi hujan wilayah (*regional rainfall*) digunakan pendekatan dengan metode *Polygon Thiessen*. Metode *Polygon Thiessen* banyak digunakan untuk menghitung hujan rerata kawasan karena memberikan koreksi terhadap kedalaman hujan sebagai fungsi luas daerah yang dianggap mewakili. Persamaan hujan wilayah dengan metode *Polygon Thiessen* adalah sebagai berikut:

##### 3. Perbaikan data hujan

Di dalam pengukuran hujan sering dialami dua masalah. Pertama adalah tidak tercatatnya data hujan karena rusaknya alat atau pengamat tidak mencatat data. Kedua adalah karena adanya perubahan kondisi di lokasi pencatatan selama satu periode pencatatan, seperti pemindahan atau perbaikan stasiun, perubahan prosedur pengukuran atau karena penyebab lain. Kedua masalah tersebut perlu diselesaikan dengan melakukan koreksi berdasarkan data dari beberapa stasiun di sekitarnya (Triatmodjo, 2008).

##### 4.1.2 Evapotranspirasi

Evapotranspirasi adalah proses evaporasi dan transpirasi yang berkaitan dengan apa yang terjadi pada tanah yang tertutup oleh tumbuh-tumbuhan. Analisis evapotranspirasi ini meliputi perhitungan evapotranspirasi potensial dan evapotranspirasi aktual. Perhitungan perkiraan evapotranspirasi potensial ( $E_p$ ) di daerah Indonesia dianalisis dengan menggunakan rumus Penman yang telah disederhanakan (Anonim, 2006).

Jika dalam evapotranspirasi potensial air yang tersedia dari yang diperlukan oleh tanaman selama proses transpirasi berlebihan, maka dalam evapotranspirasi aktual ini jumlah air tidak berlebihan atau terbatas. Jadi evapotranspirasi aktual adalah evapotranspirasi yang terjadi pada kondisi air yang tersedia terbatas. Evapotranspirasi aktual dipengaruhi oleh proporsi permukaan luar yang tidak tertutupi tumbuhan hijau (*exposed surface*) pada musim kemarau. Selain *exposed surface*, evapotranspirasi aktual juga dipengaruhi oleh jumlah hari hujan ( $n$ ) dalam bulan yang bersangkutan. Menurut Mock dalam Anonim (2006), rasio antara selisih evapotranspirasi potensial dan evapotranspirasi aktual dengan evapotranspirasi potensial dipengaruhi oleh *exposed surface* ( $m$ ) dan jumlah hari hujan ( $n$ ).

## 4.2 Pemodelan *Artificial Neural Networks*

### 4.2.1 *Input Data*

Sebelum memulai pembelajaran, terlebih dahulu dikumpulkan data yang dapat dipercaya. Kemudian membagi data tersebut ke dalam set pembelajaran (*training*) dan set pengujian (*testing*) sesuai dengan teknik *Holdout*. Set pelatihan digunakan untuk melatih jaringan, sedangkan set test digunakan setelah pelatihan jaringan selesai, yaitu untuk menguji apakah jaringan menghasilkan *output* sesuai dengan yang diinginkan pada waktu *input* yang belum pernah dipelajari oleh jaringan dimasukkan (Puspitaningrum, 2006). Data *training* dan data *testing* menggunakan data curah hujan, evapotranspirasi dan debit dalam beberapa tahun yang diambil dari suatu DAS. Dalam penelitian ini sebanyak 60% data (data tahun 1993-1999) digunakan sebagai data *input* yang nantinya akan dijadikan data dalam proses pembelajaran.

Data *input* dan *output* dalam jaringan *back propagation* sebelum digunakan, harus dilakukan proses normalisasi atau *preprocessing* terhadap data. Proses normalisasi dilakukan untuk merubah nilai data *input* dan *output* ke dalam skala -1 sampai 1.

### 4.2.2 Penentuan Arsitektur Jaringan <sup>1</sup>

Pengaturan dari syaraf-syaraf dalam lapisan (*layer*) dan pola hubungan antar lapisan-lapisan disebut arsitektur jaringan. Berdasarkan syarat masukan arsitektur jaringan, pada penelitian ini ditentukan menjadi 6 (enam) arsitektur jaringan yang didasari atas syaraf masukan (*input node*). Enam struktur *artificial neural networks multilayer* digunakan untuk uji coba (jumlah *node* mengindikasikan untuk masing-masing model dalam masing-masing *layer*). Berikut adalah keenam model tersebut:

- Model 1 (2-5-1)  
Model 1 menggunakan 2 *node input layer* yang ditentukan dari hujan dalam DAS dan evapotranspirasi, 5 *node hidden layer* dan 1 *node output layer* yaitu limpasan t.
- Model 2 (3-5-1)  
Model 2 menggunakan 3 *node input layer* yang ditentukan dari hujan dalam DAS, evapotranspirasi, limpasan t-1, 5 *node hidden layer* dan 1 *node output layer* yaitu limpasan t.
- Model 3 (4-5-1)  
Model 3 menggunakan 4 *node input layer* yang ditentukan dari hujan dalam DAS, evapotranspirasi, limpasan t-1, limpasan t-2, 5 *node hidden layer* dan 1 *node output layer* yaitu limpasan t.
- Model 4 (2-10-5-1)  
Model 4 menggunakan 2 *node input layer* yang ditentukan dari hujan dalam DAS dan evapotranspirasi, 10 *node hidden layer* 1, 5 *node hidden layer* 2 dan 1 *node output layer* yaitu limpasan t.
- Model 5 (3-10-5-1)  
Model 5 menggunakan 3 *node input layer* yang ditentukan dari hujan dalam DAS, evapotranspirasi, limpasan t-1, 10 *node hidden layer* 1, 5 *node hidden layer* 2 dan 1 *node output layer* yaitu limpasan t.
- Model 6 (4-10-5-1)  
Model 6 menggunakan 4 *node input layer* yang ditentukan dari hujan dalam DAS, evapotranspirasi, limpasan t-1, limpasan t-2, 10 *node hidden layer* 1, 5 *node hidden layer* 2 dan 1 *node output layer* yaitu limpasan t.

### 4.2.3 Proses Pembelajaran (*Learning and Training Process*)

Proses pembelajaran dalam *artificial neural networks* bertujuan untuk mengubah faktor bobot sehingga diperoleh bobot hubungan yang diinginkan. Di dalam penelitian ini, proses pembelajaran yang dipakai adalah metode perambatan mundur (*back propagation*).

Terdapat beberapa langkah penyusunan algoritma untuk pembelajaran *back propagation*, yaitu:

- Inisialisasi bobot awal (ambil bobot awal dengan nilai random yang kecil). Pembobot awal pada ANN diberi nilai secara acak.
- Lakukan tahap perambatan maju (*forward propagation*) untuk mendapatkan *error* dimana digunakan fungsi aktivasi berupa:
  - Input layer* ke *hidden layer* 1 dan *hidden layer* 1 ke *hidden layer* 2  
Fungsi sigmoid  $\rightarrow y = f(x) = \frac{1}{1 + e^{-ax}}$  (1)
  - Hidden layer* 2 ke *output layer*  
Fungsi identitas  $\rightarrow f(x) = x$  (2)
- Tahap perambatan mundur (*backward propagation*) merupakan suatu proses pelatihan (pengkoreksian) nilai pembobot pada ANN. Hal ini dilakukan dengan mengurangi/menurunkan total *error system* untuk semua data melalui koreksi pembobot dengan *Gradient Descent Method* (dalam MATLAB versi 7.0.1 *Release* 14 menggunakan fungsi *traingd*) maupun *Adaptive Learning Rate* (dalam MATLAB versi 7.0.1 *Release* 14 menggunakan fungsi *traingda*).



#### 4.2.4 Proses Pengujian

Pengujian arsitektur jaringan syaraf tiruan (*ANN*) digunakan untuk mengetahui apakah arsitektur jaringan yang telah dilatih telah dapat mengenali pola-pola data, selain data latih, dengan baik atau tidak. Untuk menilai kedekatan atau kecocokan data hasil pemodelan dengan data hasil pengamatan, dilakukan uji kecocokan dengan menggunakan fungsi objektif atau fungsi kesalahan yang merupakan persamaan dari perhitungan dan pengamatan. Dalam penelitian ini, sebanyak 40% data (data tahun 2000 – 2003) digunakan untuk proses pengujian dengan fungsi objektif untuk perhitungan kesalahan berupa parameter statistik, antara lain:

a. **Mean Square Error (MSE)** :  $MSE(t) = \frac{1}{n} \sum_{j=1}^n (y_j(t) - d_j(t))^2$  (3)

b. **Root Mean Square Error (RMSE)** :  $RMSE(t) = \sqrt{\frac{\sum_{j=1}^n (y_j(t) - d_j(t))^2}{n}}$  (4)

c. **Kesalahan Absolute Rata-Rata (KAR)** :  $KAR = \frac{1}{n} \sum \frac{Abs(Q_{comp} - Q_{obs})}{Q_{obs}}$  (5)

### 5. ANALISA DAN DISKUSI

Berikut diberikan beberapa hasil analisis berdasarkan data-data iklim dan data hidrologi:

#### 5.1 Data Iklim

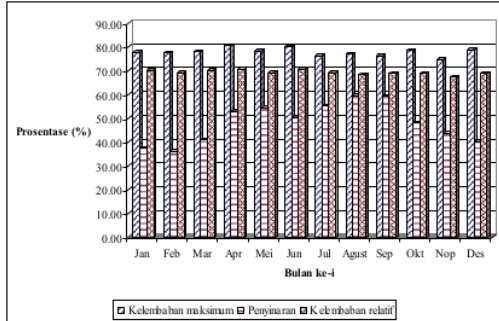
Data ini menggambarkan kondisi cuaca di suatu daerah studi, dan faktor iklim yang terkumpul selama 10 (sepuluh) tahun yakni dari tahun 1994 – 2003. Data iklim ini didapat dari stasiun klimatologi Negara, dengan data yang tercatat adalah data temperatur, kecepatan angin, kelembaban relatif, kelembaban maksimum, dan lama penyinaran. Berdasarkan data temperatur (°C) dan kecepatan angin (km/hari) rata-rata bulanan pada daerah studi sesuai Tabel 4.2 berikut:

**Tabel 1. Data temperatur dan kecepatan angin rerata bulanan (1994-2003) DAS Tk. Jogading**

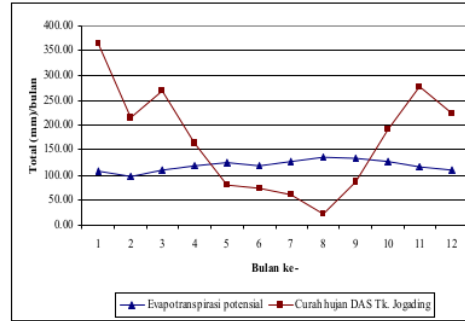
Iklim	Bulan											
	Jan	Feb	Mar	Apr	Mei	Jun	Jul	Agust	Sep	Okt	Nop	Des
T (°C)	25.09	25.12	25.00	24.77	24.41	23.98	23.36	23.30	24.07	24.78	25.23	25.12
Kec (km/hari)	116.82	112.09	97.71	114.29	137.46	161.19	182.67	225.18	234.59	200.80	169.29	106.37

Sumber: Hasil perhitungan, 2013

Sedangkan data kelembaban maksimum, penyinaran matahari dan kelembaban relatif sesuai Gambar berikut:



Gambar 1. Data kelembaban dan penyinaran (1994-2003) DAS Tk. Jogading



Gambar 2. Curah Hujan dan Evapotranspirasi DAS Tk. Jogading

#### 5.2 Data Hidrologi dan Evapotranspirasi

Ketersediaan data hidrologi berupa data curah hujan bulanan yang didapat dari stasiun hujan Dauh Waru, stasiun hujan Pohsanten, dan stasiun hujan Negara. Data curah hujan yang terkumpul sebanyak 10 tahun dari tahun 1994 – 2003. Hasil perhitungan curah hujan daerah dan evapotranspirasi tersebut dapat dilihat pada Gambar 2 di atas. Dari hasil analisis curah hujan daerah rata-rata pertahun sebesar 2024,69 mm, dan ini menunjukkan potensi curah hujan yang relatif tinggi. Sedangkan evapotranspirasi tertinggi sebesar 135,87 mm/bulan terjadi di bulan Agustus dan terendah sebesar 96,39 mm/bulan pada bulan Pebruari.

### 5.3 Hubungan Curah Hujan Limpasan ANN Backpropagation dengan Algoritma Pembelajaran Gradient Descent (traingd) dan Adaptive Learning Rate (traingda)

Dari hasil pembelajaran (*training*) dan pengujian (*testing*), baik dengan algoritma pembelajaran *Gradient Descent* (*learngd*) dan *Adaptive Learning Rate* (*traingda*), untuk masing-masing pola arsitektur dihitung parameter statistika yaitu koefisien korelasi (*r*), *mean square error* (MSE), *root mean square error* (RMSE), dan *kesalahan absolute rata-rata* (KAR). Parameter statistika untuk arsitektur model 1 dengan 2 *node input layer*, 5 *node hidden layer* dan 1 *node output layer* (2-5-1), arsitektur model 2 dengan 3 *node input layer*, 5 *node hidden layer* dan 1 *node output layer* (3-5-1), arsitektur model 3 dengan 4 *node input layer*, 5 *node hidden layer* dan 1 *node output layer* (4-5-1), arsitektur model 4 dengan 2 *node input layer*, 10 *node hidden layer* 1, 5 *node hidden layer* 2 dan 1 *node output layer* (2-10-5-1), arsitektur model 5 dengan 3 *node input layer*, 10 *node hidden layer* 1, 5 *node hidden layer* 2 dan 1 *node output layer* (3-10-5-1), arsitektur model 6 dengan 4 *node input layer*, 10 *node hidden layer* 1, 5 *node hidden layer* 2 dan 1 *node output layer* (4-10-5-1) disajikan dalam Tabel 2 dan Tabel 3. Dalam proses pembelajaran, berdasarkan parameter statistika menunjukkan bahwa model 6 dengan arsitektur 4-10-5-1 memberikan hasil yang paling optimum dengan nilai koefisien korelasi terbesar yakni 0,9164 dan nilai KAR 1,7548 untuk algoritma pembelajaran *gradient descent* dan 0,9078 dan nilai KAR 1,3217 untuk algoritma pembelajaran *adaptive learning rate*. Sehingga disimpulkan model 6 dengan arsitektur 4-10-5-1 menghasilkan data bangkitan yang paling optimum pada proses pembelajaran.

Dari Tabel 2 dan Tabel 3 diketahui bahwa model 5 dengan algoritma pembelajaran *gradient descent* yang berarsitektur 3-10-5-1 memiliki nilai koefisien korelasi sebesar 0,6977 dengan nilai KAR 1,0241 sedangkan pada pembelajaran *adaptive leaning rate*, model 3 dengan arsitektur 4-5-1 memberikan nilai koefisien korelasi sebesar 0,6901 dengan nilai KAR 1,4771. Dapat disimpulkan bahwa model 5 dengan algoritma pembelajaran *gradient descent* yang berarsitektur 3-10-5-1 dan model 3 dengan algoritma pembelajaran *adaptive leaning rate* berarsitektur 4-5-1 mempunyai hubungan atau korelasi yang cukup kuat antara data aktual dan data prediksi.

Secara umum, model *artificial neural networks* dengan algoritma pembelajaran *gradient descent* dan dengan algoritma pembelajaran *adaptive learning rate* memiliki kemampuan yang bagus dalam merepresentasi fluktuasi debit yang acak ke dalam bentuk model buatan yang memiliki fluktuasi yang hampir sama dan juga dapat diterapkan dalam modelisasi curah hujan limpasan walaupun hasil pengujian (*testing*) hasilnya tidak terlalu akurat karena masih terjadi penyimpangan.

Tabel 2. Kinerja model dengan algoritma *Gradien Descent*

Model	DAS Tukad Jogading								
	MSE Jaringan	Training/Kalibrasi				Testing/Verifikasi			
		r	MSE	RMSE	KAR	r	MSE	RMSE	KAR
Model 1	0,1135	0,7066	2579,336	50,7872	1,8347	0,2419	2795,612	52,8736	0,8383
Model 2	0,0952	0,7648	2690,623	51,8712	1,5198	0,5560	6466,113	80,4121	1,1362
Model 3	0,0925	0,7763	2719,523	52,1490	1,5788	0,6326	8193,48	90,5179	1,1030
Model 4	0,0792	0,8546	1992,269	44,6348	1,2336	0,2488	1972,405	44,4118	0,6398
Model 5	0,0700	0,8624	2260,291	47,5425	1,0191	0,6977	5923,812	76,9663	1,0241
Model 6	0,0528	0,9164	3818,604	61,7949	1,7548	0,5539	7912,38	88,9516	1,1684


Sumber: Hasil analisis, 2013

Tabel 3. Kinerja model dengan algoritma *Adaptive Learning Rate*

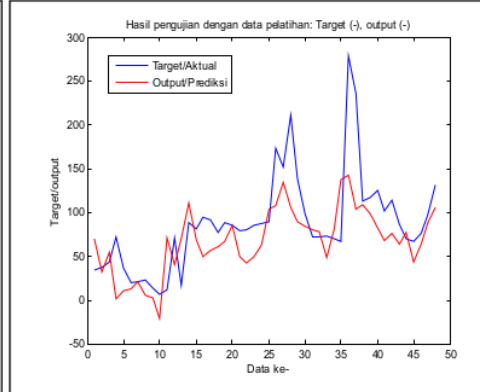
Model	DAS Tukad Jogading								
	MSE Jaringan	Training/Kalibrasi				Testing/Verifikasi			
		r	MSE	RMSE	KAR	r	MSE	RMSE	KAR
Model 1	0,1400	0,6505	3161,830	56,2302	2,3508	0,2652	3023,853	54,9896	0,9397
Model 2	0,1092	0,7834	1914,527	43,7553	0,8918	0,6115	3937,052	62,7459	0,9190
Model 3	0,1284	0,7830	4046,775	63,6143	2,4102	0,6901	10694,03	103,4120	1,4771
Model 4	0,0989	0,7519	2513,622	50,1360	1,6881	0,1883	2688,360	51,8494	0,8200
Model 5	0,0457	0,8955	2971,012	54,5070	1,3580	0,5878	6835,116	82,6748	1,1008
Model 6	0,0412	0,9078	2842,073	53,3111	1,3217	0,5642	5305,50	72,8389	1,1169

Sumber: Hasil analisis, 2013






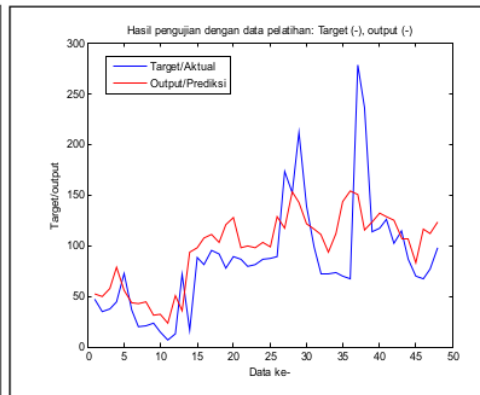
Gambar 3. Hidrograf hasil *training* ANN *gradient descent* model 6



Gambar 4. Hidrograf hasil *testing* ANN *gradient descent* model 5



Gambar 5. Hidrograf hasil *training* ANN *adaptive learning rate* model 6



Gambar 6. Hidrograf hasil *testing* ANN *adaptive learning rate* model 3

## 6. KESIMPULAN DAN SARAN

Dari hasil penelitian dan pembahasan dapat diambil kesimpulan sebagai berikut:

1. Penerapan model jaringan syaraf buatan (*artificial neural network*) metode *backpropagation* dengan algoritma pembelajaran *Gradient Descent* dan *Adaptive Learning Rate* di dalam modelisasi curah hujan limpasan memberikan hasil yang relatif baik pada proses pembelajaran (training) dan proses pengujian (testing).
2. Dalam proses pembelajaran, model 6 dengan arsitektur 4-10-5-1 memberikan hasil yang paling optimum dengan nilai koefisien korelasi terbesar yakni 0,9164 dan nilai KAR 1,7548 untuk algoritma pembelajaran *gradient descent* dan 0,9078 dan nilai KAR 1,3217 untuk algoritma pembelajaran *adaptive learning rate*. Ini berarti model 6 dengan arsitektur 4-10-5-1 menghasilkan data bangkitan yang paling optimum pada proses pembelajaran.
3. Model 5 dengan algoritma pembelajaran *gradient descent* yang berarsitektur 3-10-5-1 memiliki nilai koefisien korelasi sebesar 0,6977 dengan nilai KAR 1,0241 sedangkan pada pembelajaran *adaptive learning rate*, model 3 dengan arsitektur 4-5-1 memberikan nilai koefisien korelasi sebesar 0,6901 dengan nilai KAR 1,4771. Hal tersebut menunjukkan bahwa model 5 dengan algoritma pembelajaran *gradient descent* yang berarsitektur 3-10-5-1 dan model 3 dengan algoritma pembelajaran *adaptive learning rate* berarsitektur 4-5-1 mempunyai hubungan atau korelasi yang cukup kuat antara data aktual dan data prediksi.
4. Secara umum, model *artificial neural networks* dengan algoritma pembelajaran *gradient descent* dan dengan algoritma pembelajaran *adaptive learning rate* memiliki kemampuan yang bagus dalam mereplikasi fluktuasi debit yang acak ke dalam bentuk model buatan yang memiliki fluktuasi yang hampir sama dan juga dapat diterapkan dalam modelisasi curah hujan limpasan walaupun hasil pengujian (*testing*) hasilnya tidak terlalu akurat karena masih terjadi penyimpangan.

## DAFTAR PUSTAKA

- Abdulla, F. and Badranih, L.A. (2000). "Application of a Rainfall-Runoff Model to Three Catchments in Iraq". *Journal of Hydrological Sciences*, 45: 13-25.
- Adidarma, W.K., Hadihardaja, I.K., Legowo, S. (2004). "Perbandingan Pemodelan Hujan-Limpasan Antara Artificial Neural Network (ANN) dan NRECA". *Jurnal Teknik Sipil ITB*, Vol. 11 No. 3: 105-115.
- Andina, D. And Pham, D.T. (2007). *Artificial Neural Network*. Computational Intelligence – Springer: 67-92.
- Anonim. (2006). *Laporan Hidrologi*. Departemen Pekerjaan Umum – Direktorat Jenderal Sumber Daya Air Satuan Kerja NVT Pengembangan dan Pengelolaan Sumber Air Bali, Denpasar.
- Asdak, C. (2004). *Hidrologi dan Pengelolaan Daerah Aliran Sungai*. Gadjah Mada University Press, Yogyakarta.
- Dawson, C.W. and Wilby, R.L. (2001). "Hydrological Modelling Using Artificial Neural Networks". *Progress in Physical Geography*, 25-1: 80-108.
- Fausett, L. (1994). *Fundamental of Neural Networks*, Prentice Hall, Engelwood Cliffs, New Jersey.
- Fu, LiMin. (1994). *Neural Networks In Computer Intelligence*, McGraw-Hill Inc., Singapore.
- Hadihardaja, I.K., Sutikno, S. (2005). "Pemodelan Curah Hujan-Limpasan Menggunakan Artificial Neural Network (ANN) dengan Metode Backpropagation". *Jurnal Teknik Sipil ITB*, Vol. 12 No. 4: 249-258.
- Junsawang, P., Asavanant, J., Lursinsap, C. (2007). "Artificial Neural Network Model for Rainfall-Runoff Relationship". *ASIMMOD*, Chiang Mai, Thailand.
- Kalteh, A.M. (2008) "Rainfall-Runoff Modelling Using Artificial Neural Networks (ANNs): Modelling and Understanding". *Caspian J. Env. Sci*, Vol. 6 No. 1: 53-58.
- Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB dan Excel Link*. Graha Ilmu, Yogyakarta.
- Rajurkar, M.P., Kothiyari, U.C., Chaube, U.C. (2002). "Artificial Neural Networks For Daily Rainfall-Runoff Modelling". *Hydrological Science Journal*, 47(6): 865-877.
- Setiawan, B.I., Rudiyanto. (2004). "Aplikasi Neural Networks Untuk Prediksi Aliran Sungai", *Prosiding Semiloka Teknologi Simulasi dan Komputasi serta Aplikasi 2004 – BPPT*, Jakarta.
- Soemarto, C.D. (1999). *Hidrologi Teknik*. Penerbit Erlangga, Jakarta.
- Sohail, A., Watanabe, K., Takeuchi, S. (2008). "Runoff Analysis for a Small Watershed of Tono area Japan by Back Propagation Artificial Neural Network with Seasonal Data". *Water Resour Manage*, 22: 1-22
- Srinivasulu, S., Jain, A. (2008). "Rainfall-Runoff Modelling: Integrating Available Data and Modern Techniques". *Water Science and Technology Library 68*, Springer-Verlag Berlin Heidelberg : 59-70.
- Sunaryo, T.M., dkk. (2004). *Pengelolaan Sumber Daya Air; Konsep dan Penerapannya*. Bayumedia Publishing, Malang.
- Triatmodjo, B. (2008). *Hidrologi Terapan*. Beta Offset, Yogyakarta.

# Aplikasi Jaringan Syaraf Tiruan (Artificial Neural Networks) Dalam Modelisasi Curah Hujan Limpasan Dengan Perbandingan Dua Algoritma Pelatihan (Studi Kasus: DAS Tukad Jogading)

## ORIGINALITY REPORT

15%

SIMILARITY INDEX

14%

INTERNET SOURCES

2%

PUBLICATIONS

2%

STUDENT PAPERS

## MATCHED SOURCE



[ejournal.undip.ac.id](http://ejournal.undip.ac.id)  
Internet Source

3%

3%

★ [ejournal.undip.ac.id](http://ejournal.undip.ac.id)  
Internet Source

Exclude quotes On

Exclude bibliography On

Exclude matches < 2%