

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/316921653>

# Resilient Backpropagation Neural Network Dalam Modelisasi Curah Hujan – Limpasan Studi Kasus: DAS Tukad Nyuling

Preprint · April 2013

DOI: 10.13140/RG.2.2.10196.76169

---

CITATIONS

0

READS

248

1 author:



Putu Doddy Heka Ardana  
Universitas Ngurah Rai

19 PUBLICATIONS 1 CITATION

[SEE PROFILE](#)

# ***Resilient Backpropagation Neural Network* Dalam Modelisasi Curah Hujan – Limpasan**

## **Studi Kasus: DAS Tukad Nyuling**

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

### **ABSTRAK**

Penelitian ini menyelidiki tentang kegunaan *Resilient Backpropagation Neural Network* di dalam analisis mengenai hubungan curah hujan-limpasan untuk daerah aliran sungai (DAS). Beberapa algoritma pembelajaran *neural network* telah dijelaskan dalam beberapa penelitian ataupun literatur. Penelitian-penelitian yang telah dilakukan tersebut meliputi penggambaran dan arsitektur yang cocok diterapkan di dalam aplikasi yang berbeda misalnya dalam prediksi curah hujan, prediksi banjir, dan lain-lain. Pada penelitian ini, *Resilient Backpropagation Neural Network* digunakan untuk menggambarkan transformasi curah hujan-limpasan pada salah satu DAS yang ada di Bali yakni DAS Tukad Nyuling 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 *Resilient Backpropagation Neural Network* 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) 1,0059 dengan nilai koefisien korelasi 99,17 % pada proses *training* dan pada proses pengujian, menghasilkan nilai KAR 0,6414 dengan nilai koefisien korelasi 58,71%. Dari hasil tersebut terlihat bahwa *Resilient Backpropagation Neural Network* memiliki kemampuan yang cukup baik dalam menggambarkan fluktuasi debit yang acak ke dalam bentuk model buatan 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, *Resilient Backpropagation Neural Network*

## **1. PENDAHULUAN**

Proses hidrologi secara sederhana dapat digambarkan dengan adanya hubungan antara unsur masukan yakni hujan, proses dan keluaran yaitu berupa aliran (Hadihardaja, 2005). 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) dimana proses hidrologi ini bersifat non linear dan sangat.

*Artificial Neural Network* telah terbukti menjadi model alternatif dari model tradisional yang efisien dalam memodelkan variabel sumber daya air baik secara kualitatif dan kuantitatif. 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).

Berdasarkan hasil penelitian mengenai hubungan curah hujan-limpasan dengan model ANN pada suatu DAS, di dalam analisis banyak menggunakan fungsi pembelajaran dalam ANN berupa fungsi dengan algoritma dasar *gradient descent* 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 guna lebih memahami bagaimana kinerja dan implementasi dari ANN tersebut. Obyek studi yang diambil adalah DAS Tukad Nyuling di Karangasem yang memiliki luas 24,93 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 *Resilient Backpropagation Neural Network*, dikerjakan dengan bantuan *software* MATLAB versi 7.0.1 Release 14.

## **2. TUJUAN PENELITIAN**

Adapun tujuan penelitian ini adalah untuk mengkaji dan menggambarkan penerapan model *Resilient Backpropagation Neural Network* di dalam modelisasi hubungan curah hujan limpasan pada DAS Tukad Nyuling.

## **3. LOKASI STUDI**

Lokasi studi adalah daerah aliran sungai (DAS) Tukad Nyuling yang berada di Kabupaten Karangasem Propinsi Bali. Daerah aliran sungai (DAS) Tukad Nyuling memiliki luas kurang dari 100 km<sup>2</sup> yakni 24,93 km<sup>2</sup> (Anonim, 2007) dengan bentuk daerah pengaliran secara umum memanjang (Anonim, 2009). Data yang diambil untuk digunakan dalam pengalihragaman 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

---

<sup>1</sup> Pengajar pada PS Teknik Sipil UNR

Susunan. Sedangkan ketersediaan data hidrologi berupa data curah hujan bulanan yang didapat dari stasiun hujan Pidpid, stasiun hujan Bebandem, dan stasiun hujan Amlapura. 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.

$$S_o^* = 0, S_k^* = \sum_{i=1}^{k=1} (Y_i - Y') \text{ dengan } k = 1, 2, 3, \dots, n \quad (1)$$

$$S_k^{**} = \frac{S_k^*}{D_y} \quad (2)$$

$$D_y^2 = \frac{\sum_{i=1}^n (Y_i - Y')^2}{n} \quad (3)$$

$$Q = \max |S_k^{**}| \quad (4)$$

$$0 \leq k \leq n$$

$$R = \max S_k^{**} - \min S_k^{**} \quad (5)$$

$$0 \leq k \leq n$$

Dengan melihat nilai statistik, maka dapat dicari nilai  $Q/\sqrt{n}$  dan  $R/\sqrt{n}$ . Hasil yang dapat dibandingkan nilai  $Q/\sqrt{n}$  syarat dan  $R/\sqrt{n}$ . Sebagai syarat jika  $Q/\sqrt{n}$  dan  $R/\sqrt{n}$  dihitung lebih kecil maka data masih dalam batasan konsisten. Syarat nilai  $Q/\sqrt{n}$  dan  $R/\sqrt{n}$  sesuai dengan tabel dari Sri Harto (1990).

##### 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:

$$\bar{R} = \sum_{i=1}^n \frac{A_i \cdot R_i}{A} \quad (6)$$

##### 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). Metode perkiraan yang digunakan adalah sebagai berikut (Wanielista, 1990; Dunne dan Leopold, 1978 dalam Asdak, 2004):

$$P_x = \frac{(P_A + P_B + P_C)}{3} \quad (7)$$

#### 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 ( $E_{to}$ ) di daerah Indonesia dianalisis dengan menggunakan rumus Penman yang telah disederhanakan (Anonim, 2006):

$$E_{to} = c.[W(0,75.R_s - R_n)] + (1 - w).f(U).(e_a - e_d) \quad (8)$$

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 ( $n$ ), seperti ditunjukkan dalam formulasi sebagai berikut :

$$\Delta E = E_p \left( \frac{m}{20} \right) (18 - n) \quad (9)$$

Dari formulasi diatas dapat dianalisis bahwa evapotranspirasi potensial akan sama dengan evapotranspirasi aktual (atau  $\Delta E = 0$ ) jika:

- Evapotranspirasi terjadi pada hutan primer atau hutan sekunder. Dimana daerah ini memiliki harga *exposed surface* ( $m$ ) sama dengan 0 (nol).
- Banyaknya hari hujan dalam bulan yang diamati pada daerah itu sama dengan 18 hari.

Jadi evapotranspirasi aktual adalah evapotranspirasi potensial yang memperhitungkan faktor *exposed surface* dan jumlah hari hujan dalam bulan yang bersangkutan. Sehingga evapotranspirasi aktual adalah evapotranspirasi yang sebenarnya terjadi atau *actual evapotranspiration*, dihitung sebagai berikut:

$$E_{aktual} = EP - \Delta E \quad (10)$$

#### 4.2 Pemodelan Resilient Backpropagation Neural Network

##### 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 dengan menggunakan persamaan sebagai berikut (Santosa, 2007):


$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} (BA - BB) + (BB) \quad (11)$$

##### 4.2.2 Penentuan Arsitektur Jaringan

Pengaturan dari syaraf-syaraf dalam lapisan (*layer*) dan pola hubungan antar lapisan-lapisan disebut arsitektur jaringan. Berdasarkan syaraf 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:

a. 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.



Gambar 1. Arsitektur jaringan model 1

b. Model 2 (3-5-1)

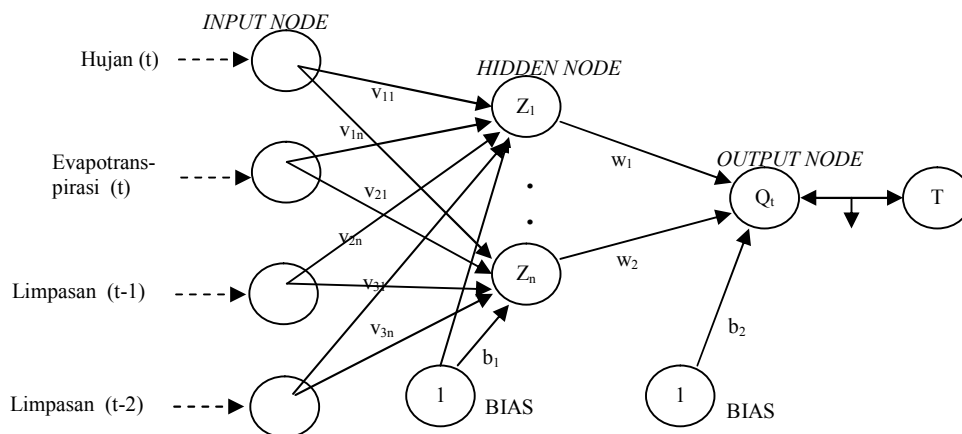
Model 2 menggunakan 3 *node input layer* yang ditentukan dari hujan dalam DAS, evapotranspirasi, limpasan t-1, 5 *node hidden layer* dan 1 *node output layer* yaitu limpasan t.



Gambar 2. Arsitektur jaringan model 2

c. Model 3 (4-5-1)

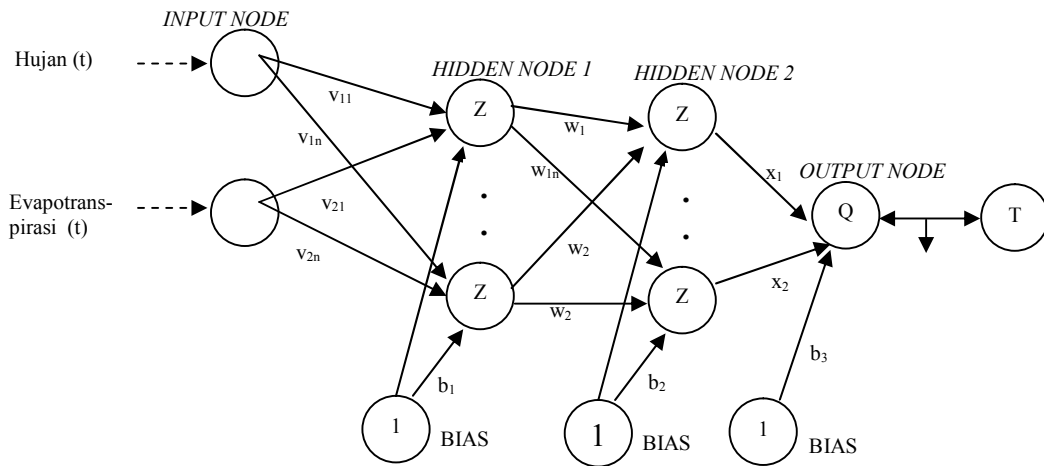
Model 3 menggunakan 4 *node input layer* yang ditentukan dari hujan dalam DAS, evapotranspirasi, limpasan t-1, limpasan t-2, 5 *node hidden layer* dan 1 *node output layer* yaitu limpasan t.



Gambar 3. Arsitektur jaringan model 3

d. Model 4 (2-10-5-1)

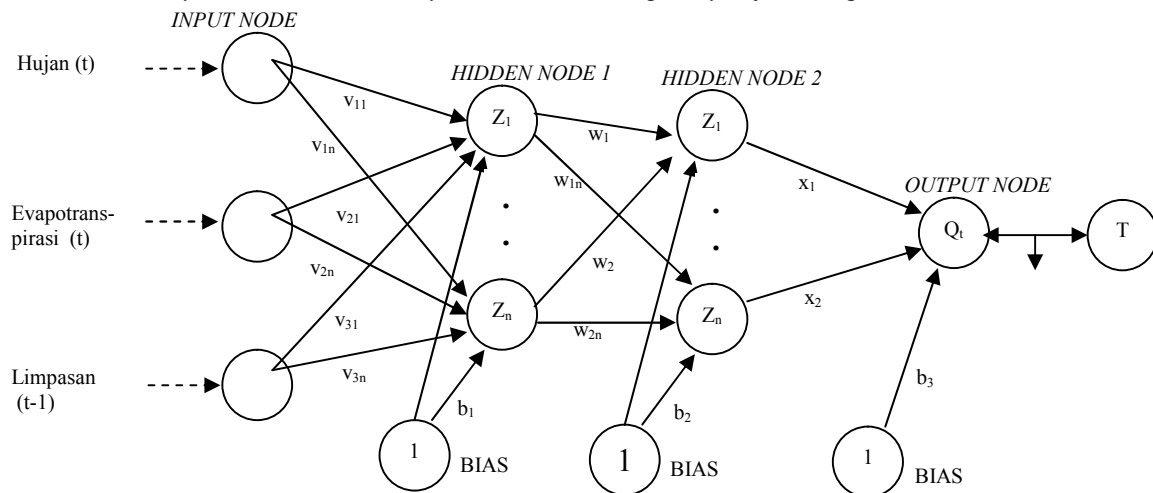
Model 4 menggunakan 2 *node input layer* yang ditentukan dari hujan dalam DAS dan evapotranspirasi, 10 *node hidden layer 1*, 5 *node hidden layer 2* dan 1 *node output layer* yaitu limpasan  $t$ .



Gambar 4. Arsitektur jaringan model 4

e. Model 5 (3-10-5-1)

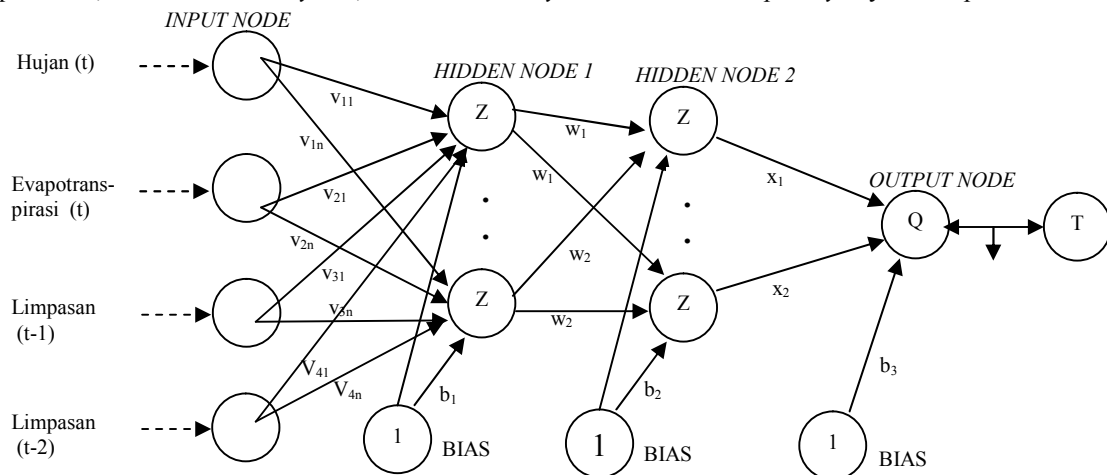
Model 5 menggunakan 3 *node input layer* yang ditentukan dari hujan dalam DAS, evapotranspirasi, limpasan  $t-1$ , 10 *node hidden layer 1*, 5 *node hidden layer 2* dan 1 *node output layer* yaitu limpasan  $t$ .



Gambar 5. Arsitektur jaringan model 5

f. 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  $t$ .



Gambar 6. Arsitektur jaringan model 6

### 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:

1. Inisialisasi bobot awal (ambil bobot awal dengan nilai random yang kecil). Pembobot awal pada ANN diberi nilai secara acak.
2. Lakukan tahap perambatan maju (*forward propagation*) untuk mendapatkan *error*. Perhitungan *forward propagation* dimulai dengan menjumlahkan hasil perkalian *input*  $x_i$  dengan pembobot  $v_{ij}$ . Dan menghasilkan  $z\_in_j$  yang merupakan nilai *input* ke fungsi aktivasi *hidden layer*. Kemudian output  $z_j$  pada *hidden layer* unit  $j$  merupakan hasil fungsi aktivasi  $f$  dengan masukan  $z\_in_j$ . Hal ini telah diformulasikan dalam persamaan berikut:

$$z\_in_j = b_{1j} + \sum_{i=1}^n x_i v_{ij} \quad ; \quad z_j = f(z\_in_j)$$

Nilai *output* pada *hidden layer* kemudian dikalikan dengan pembobot  $w_{jk}$  dan menghasilkan nilai  $y\_in_k$  yang merupakan nilai *input* fungsi aktivasi *output layer*. Nilai *output*  $y$  pada *output layer* dihitung dengan menggunakan fungsi aktivasi  $f$  dengan masukan  $y\_in_k$ . Hal ini telah diformulasikan dalam persamaan berikut:

$$y\_in_k = b_{2k} + \sum_{j=1}^p z_j w_{jk}$$

$$y = f(y\_in_k)$$

dengan fungsi aktivasi berupa:

- *Input layer* ke *hidden layer* 1 dan *hidden layer* 1 ke *hidden layer* 2

$$\text{Fungsi sigmoid} \rightarrow y = f(x) = \frac{1}{1 + e^{-\alpha x}} \quad (12)$$

- *Hidden layer* 2 ke *output layer*

$$\text{Fungsi identitas} \rightarrow f(x) = x \quad (13)$$

3. Tahap perambatan mundur (*backward propagation*) merupakan suatu proses pelatihan (pengkoreksian) nilai pembobot pada ANN. Pada jaringan ANN struktur multilayer dengan fungsi sigmoid, akan menyebabkan gradiennya akan mendekati nol dikarenakan input yang diberikan banyak. Gradien yang mendekati nol ini berimplikasi pada rendahnya perubahan bobot yang mana bias menyebabkan algoritma akan sangat lambat untuk mendekati nilai optimumnya. Untuk itu digunakan *Resilent Backpropagation* untuk mengeliminasi besarnya efek dari turunan parsial dengan cara menggunakan tanda turunannya saja dan mengabaikan besarnya nilai turunan. Tanda turunan ini akan menentukan arah perbaikan bobot-bobot. *Resilent Backpropagation* (dalam MATLAB versi 7.0.1 *Release* 14 menggunakan fungsi *trainrp*). Parameter-parameter yang digunakan dalam proses analisis dengan menggunakan MATLAB:

*net.trainParam.epochs* = jumlah epoch maksimum yang boleh dilakukan selama proses pelatihan

*net.trainParam.goal* = target nilai fungsi kinerja

*net.trainParam.lr* = laju pembelajaran

*net.trainParam.delt\_inc* = kenaikan bobot

*net.trainParam.delt\_dec* = penurunan bobot

*net.trainParam.delt0* = perubahan bobot awal

*net.trainParam.deltmax* = maksimum perubahan bobot

*net.trainParam.show* = jumlah epoch yang akan ditunjukkan kemajuannya

### 4.2.4 Proses Pengujian

Pengujian arsitektur jaringan syaraf tiruan (*artificial neural networks*) 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)**

$$MSE_{(t)} = \frac{1}{n} \sum_{j=1}^n (y_j(t) - d_j(t))^2 \quad (14)$$

- b. **Root Mean Square Error (RMSE)**

$$RMSE(t) = \sqrt{\frac{\sum_{j=1}^n (y_j(t) - d_j(t))^2}{n}} \quad (15)$$

- c. **Kesalahan Absolute Rata-Rata (KAR)**

$$KAR = \frac{1}{n} \sum \frac{Abs(Q_{comp} - Q_{obs})}{Q_{obs}} \quad (16)$$

## 5. ANALISA DAN DISKUSI

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

### 5.1 Data Iklim

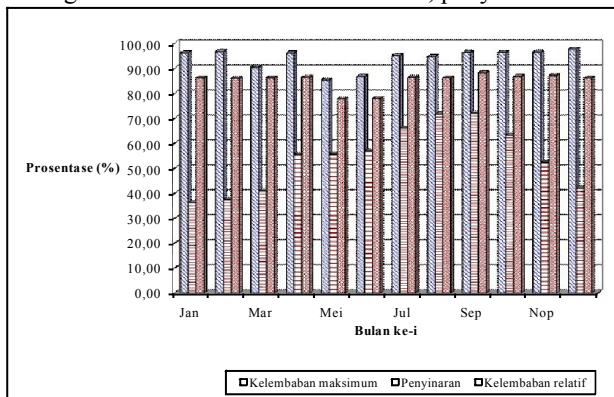
Data ini menggambarkan kondisi cuaca di suatu daerah studi, dan faktor iklim yang terkumpul selama 10 (sepuluh) tahun yakni dari tahun 1994 – 2003. Data iklim ini didapat dari stasiun klimatologi Susuan, dengan data yang tercatat adalah data temperatur, kecepatan angin, kelembaban relatif, kelembaban maksimum, dan lama penyinaran. Berdasarkan data temperatur (°C) dan kecepatan angin (km/hari) rata-rata bulanan pada daerah studi sesuai Tabel 1 berikut:

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

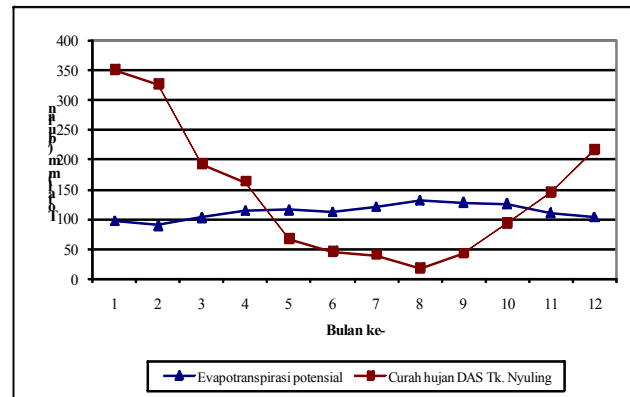
Iklim	Bulan											
	Jan	Feb	Mar	Apr	Mei	Jun	Jul	Agust	Sep	Okt	Nop	Des
T (0°C)	26,11	26,16	26,51	26,90	24,03	23,60	23,07	25,64	26,19	27,09	27,17	26,67
Kec (km/hari)	50,06	72,40	62,83	46,55	31,28	31,78	30,31	35,16	37,15	47,04	43,13	46,94

Sumber: Pusat Litbang Pengairan Departemen Pekerjaan Umum, BMKG

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



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



Gambar 2. Curah Hujan dan Evapotranspirasi DAS Tk. Nyuling

### 5.2 Data Hidrologi dan Evapotranspirasi

Ketersediaan data hidrologi berupa data curah hujan bulanan yang didapat dari stasiun hujan Pidpid, stasiun hujan Bebandem, dan stasiun hujan Amlapura. 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 1702,06 mm, dan ini menunjukkan potensi curah hujan yang relatif tinggi. Sedangkan evapotranspirasi tertinggi sebesar 130,89 mm/bulan terjadi di bulan Agustus dan terendah sebesar 89,16 mm/bulan pada bulan Pebruari.

### 5.3 Hubungan Curah Hujan Limpasan dengan *Resilent Backpropagation*

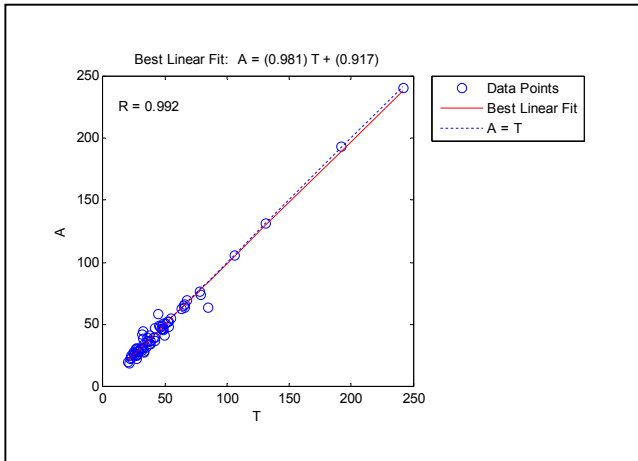
Dari hasil pembelajaran (*training*) dan pengujian (*testing*) dengan algoritma pembelajaran *Resilent Backpropagation*, untuk masing-masing pola arsitektur dihitung parameter statistika yaitu koefisien korelasi ( $r$ ), *mean square error* (MSE), *root mean square error* (RMSE), dan kesalahan absolute 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. Dalam proses pembelajaran (*training*), berdasarkan parameter statistika menunjukkan bahwa model 6 dengan arsitektur 4-10-5-1 memberikan hasil yang paling optimum dengan nilai koefisien korelasi terbesar yakni 0,9917 dan nilai KAR 1,0059. Sehingga disimpulkan model 6 dengan arsitektur 4-10-5-1 menghasilkan data bangkitan yang paling optimum pada proses pembelajaran.

Dari Tabel 2 diketahui bahwa model 6 juga memberikan hasil yang cukup baik. Ini dapat dilihat dari 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 0,5871 dengan nilai KAR 0,6414. Dapat disimpulkan bahwa model 6 mempunyai hubungan atau korelasi yang cukup kuat antara data aktual dan data prediksi. Secara umum, model *Resilent Backpropagation* memiliki kemampuan yang cukup baik dalam menggambarkan fluktuasi debit yang acak ke dalam bentuk model buatan dan juga dapat diterapkan dalam modelisasi curah hujan limpasan walaupun hasil pengujian (*testing*) hasilnya tidak terlalu akurat karena masih terjadi penyimpangan.

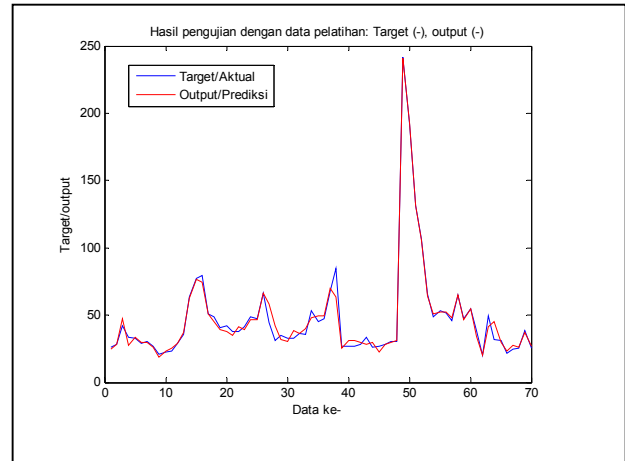


Tabel 2. Kinerja model dengan *Resilent Backpropagation*


Model	DAS Tukad Nyuling								
	MSE Jaringan	Training/Kalibrasi				Testing/Verifikasi			
		r	MSE	RMSE	KAR	r	MSE	RMSE	KAR
Model 1	0,0251849	0,8649	3398,955	58,3006	0,9798	0,0504	11234,026	105,9907	2,2504
Model 2	0,00449147	0,9776	3425,162	58,5249	0,9943	0,4781	11164,143	105,6605	2,1449
Model 3	0,0114589	0,9424	3462,763	58,8452	1,0081	0,3128	11090,95	105,3136	1,0596
Model 4	0,0099576	0,9489	3398,955	58,3006	1,0026	0,0199	11234,026	105,9907	2,3223
Model 5	0,00211473	0,9895	3425,162	58,5249	1,0003	0,4844	11164,143	105,6605	1,1090
Model 6	0,00168374	0,9917	3462,763	58,8452	1,0059	0,5871	11090,95	105,3136	0,6414



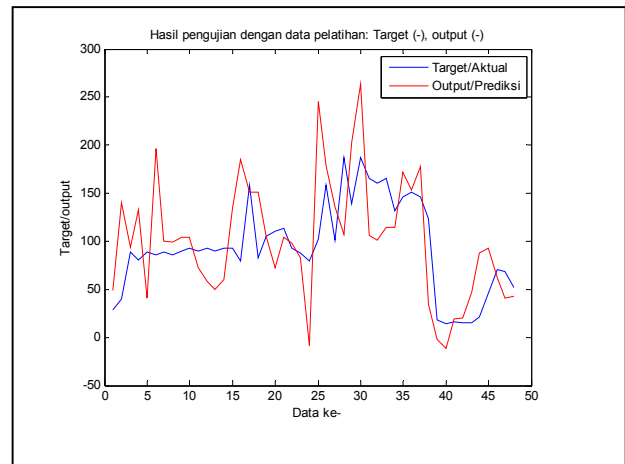
Gambar 3. Persamaan koefisien korelasi hasil *training Resilent Backpropagation* model 6



Gambar 4. Hidrograf hasil *training Resilent Backpropagation* model 6



Gambar 5. Persamaan koefisien korelasi hasil *testing Resilent Backpropagation* model 6



Gambar 6. Hidrograf hasil *testing Resilent Backpropagation* model 6

## 6. KESIMPULAN DAN SARAN

### 6.1 Kesimpulan :

Dari hasil penelitian dan pembahasan dapat diambil kesimpulan sebagai berikut:

1. Penerapan model jaringan syaraf buatan (*artificial neural network*) metode *Resilent Backpropagation* di dalam modelisasi curah hujan limpasan memberikan hasil yang relatif baik pada proses pembelajaran (*training*) dan proses pengujian (*testing*).
2. Dalam proses pembelajaran (*training*), berdasarkan parameter statistika menunjukkan bahwa model 6 dengan arsitektur 4-10-5-1 memberikan hasil yang paling optimum dengan nilai koefisien korelasi terbesar yakni 0,9917 dan nilai KAR 1,0059. Sehingga disimpulkan model 6 dengan arsitektur 4-10-5-1 menghasilkan data bangkitan yang paling optimum pada proses pembelajaran. Model 6 juga memberikan hasil yang cukup baik. Ini dapat dilihat dari

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 0,5871 dengan nilai KAR 0,6414.

3. Secara umum, model *Resilient Backpropagation* memiliki kemampuan yang cukup baik dalam menggambarkan fluktuasi debit yang acak ke dalam bentuk model buatan dan juga dapat diterapkan dalam modelisasi curah hujan limpasan walaupun hasil pengujian (*testing*) hasilnya tidak terlalu akurat karena masih terjadi penyimpangan

## 6.2 Saran

Untuk kesempurnaan hasil penelitian berikutnya, di dalam melakukan pemodelan diharapkan untuk mencoba beberapa model arsitektur ANN lainnya serta dengan melakukan beberapa perubahan nilai di dalam parameter-parameternya. Selain itu keakuratan data pendukung (data hidrologi maupun data klimatologi) juga harus diperhatikan.

## DAFTAR PUSTAKA

- 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.
- 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.
- Kusumadewi, S. (2004). *Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB dan Excel Link*. Graha Ilmu, Yogyakarta.
- Setiawan, B.I., Rudiyanto. (2004). "Aplikasi Neural Networks Untuk Prediksi Aliran Sungai", *Prosiding Semiloka Teknologi Simulasi dan Komputasi serta Aplikasi 2004 – BPPT*, Jakarta.
- 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.