

APLIKASI METODE GENERALIZED REDUCED GRADIENT DALAM PEMODELAN CURAH HUJAN-LIMPASAN MENGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN)

Iwan K. Hadihardaja¹, Sugeng Sutikno²

ABSTRACT

The rainfall run off modelling is necessary until now days, for fulling data or make data longer. Artificial neural network can made the alternative rainfall run off modelling. The implementation Artificial neural networ for modelling on the water resources which is done by researcher to get an accurate result. Artificial neural networ is one of artificial intelligent that is imitation of representation from brain of human. This model is the black box modelling, so in the implementation were not need complecity of scient among the other aspect in the process of rainfall run off modelling. The case study applied to the river flow on the way Sekampung river in Lampung Province. The data used is rainfall data and stream flow data in the middle of the month on the water level station Pujorahayu, for 19 years from 1983 up to 2001. The rainfall data is input and stream flow is a variable output. Learning method that is used reduced gradient. From the result of this research got correlation coefficient 0,790 or 79 % the tallest. The conclusion of this research is the generally ANN can implementated in the rainfall run off modeling, although the result is not too accurate because of there is still deviation.

Keywords : rainfall-runoff, artificial neural network, black box, generalized reduced gradient

PENDAHULUAN

Perencanaan, pengelolaan dan pengembangan sumberdaya air selalu memerlukan analisa terhadap variabel hidrologi seperti curah hujan, dan aliran sungai. Untuk keperluan analisa hidrologi diperlukan data hidrologi yang panjang, tetapi sering dijumpai data yang tersedia tidak lengkap atau bahkan tidak ada sama sekali. Sesuai dengan karakteristik fenomena hidrologi suatu daerah pengaliran sungai, aliran sungai berubah-ubah tidak beraturan, oleh karena itu sukar untuk meramalkan besarnya debit yang melintasi penampang sungai secara pasti pada suatu saat tertentu. Untuk mendekati fenomena

tersebut maka perlu dikembangkan suatu analisa sistem hidrologi dengan menggunakan model yang merupakan penyederhanaan kenyataan alam yang sebenarnya.

Salah satu alternatif model yang dapat dikembangkan untuk pemodelan hidrologi adalah dengan menggunakan jaringan syaraf tiruan (*artificial neural network*). Artificial neural network (ANN) yang merupakan salah satu bentuk kecerdasan buatan telah banyak diaplikasikan dalam bidang computer, teknik listrik, fisika, financial, dan lain-lain. Penerapan ANN dalam bidang sumberdaya air antara lain telah diterapkan untuk mencari hubungan limpasan dan sedimen (Hadihardaja, 2002)

¹ Pengajar Departemen Teknik Sipil FTSP - ITB

² - Pengajar Jurusan Teknik Sipil Fakultas Teknik
Universitas Subang
- Mahasiswa Program S2-Teknik Sipil
Insitut Teknologi Bandung

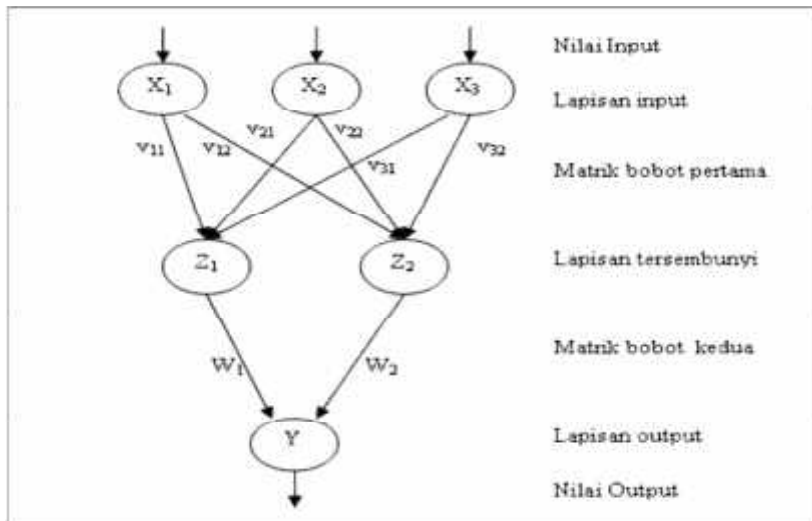
dan pemodelan multivariate deret waktu (Saragih dan Hadihardaja, 2003). Kedua model tersebut sama-sama menggunakan metode *Generalized Reduced Gradient* (GRG). Pada penelitian ini pemodelan curah-hujan limpasan menggunakan metode *Backpropagation*.

JARINGAN SYARAF TIRUAN (ARTIFICIAL NEURAL NETWORK)

Jaringan syaraf tiruan (ANN) merupakan salah satu representasi tiruan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia tersebut. Otak manusia berisi berjuta-juta sel syaraf (*neuron*) yang bertugas untuk memproses informasi.

Masing-masing sel saling berinteraksi sehingga mendukung kemampuan kerja otak. Setiap sel syaraf akan memiliki satu inti sel yang bertugas untuk melakukan pemrosesan informasi.

Seperti halnya otak manusia, jaringan syaraf juga terdiri dari beberapa neuron, yang ada hubungan antara neuron-neuron tersebut. Neuron-neuron akan mentransformasikan informasi yang diterima melalui sambungan keluarnya menuju neuron-neuron yang lain. Dalam jaringan syaraf hubungan ini dikenal dengan nama bobot. Informasi tersebut disimpan pada suatu nilai tertentu pada bobot tersebut. Struktur neuron pada jaringan syaraf ditunjukkan pada Gambar 1.



Gambar 1. Struktur neuron jaringan syaraf

Neuron-neuron buatan tersebut bekerja dengan cara yang sama dengan neuron-neuron biologis. Informasi atau masukan (*input*) akan dikirim ke neuron dengan bobot kedatangan tertentu. Input akan diproses oleh suatu fungsi perambatan yang akan menjumlahkan nilai-nilai semua bobot yang datang. Hasil penjumlahan akan

dibandingkan dengan suatu nilai ambang (*threshold*) tertentu melalui fungsi aktivasi setiap neuron. Apabila input tersebut melewati suatu nilai ambang tertentu, maka neuron tersebut akan diaktifkan, tetapi kalau tidak, maka neuron tersebut tidak akan diaktifkan. Apabila neuron diaktifkan, maka neuron akan mengirimkan output

melalui bobot-bobot outputnya ke semua neuron yang berhubungan dengannya, demikian seterusnya.

Secara umum jaringan syaraf tiruan terdiri dari 3 (tiga) lapisan yaitu :


- *Input layer*, terdiri dari neuron-neuron yang menerima sebuah input dari lingkungan luar. Neuron tersebut tidak melakukan suatu perubahan dalam masukan, tetapi hanya mengirimkannya ke elemen pemroses (*processing elements*) yang berdekatan dengan lapisan tersembunyi (*hidden layer*).
- *Hidden layer*, terdiri dari neuron-neuron yang mempunyai tipe menerima masukan yang dipindahkan dari input layer, melakukan perubahan di dalamnya, dan melemparkan output ke lapisan berikutnya.
- *Output layer*, terdiri dari neuron-neuron yang menerima output dari *hidden layer* dan mengirimkannya kepada pemakai.

APLIKASI MODEL ANN UNTUK DAS WAY SEKAMPUNG-PUJORAHAYU


Data curah hujan yang digunakan sebagai data masukan diperoleh dari stasiun penakar hujan yang berada dalam wilayah DAS Way Sekampung-Pujorahayu sebanyak sembilan stasiun pencatat hujan. Data debit

diambil pada pos duga air Pujorahayu. Pada penelitian ini di gunakan data curah hujan dan data debit tengah bulanan selama 19 tahun dari tahun 1983 sampai tahun 2001. Data dibagi menjadi tiga bagian data yang akan digunakan sebagai data pembelajaran (*training*), data pengujian (*testing*), dan data validasi. Data training digunakan data tahun 1983 sampai 1992. Data testing digunakan data tahun 1995 sampai tahun 2001. Data validasi digunakan data tahun 1994 sampai tahun 1995.

Pengaturan dari saraf-saraf dalam lapisan (*layers*) dan pola hubungannya diantara lapisan-lapisan disebut arsitektur jaringan. Berdasarkan syaraf masukan arsitektur jaringan pada penelitian ini tentukan menjadi 2 (dua) arsitektur jaringan. Arsitektur 1 memiliki 9 syaraf masukan (*input node*), ditentukan dari jumlah stasiun pengamat hujan dalam DAS. Arsitektur 2 memiliki 10 syaraf masukan yaitu 9 dari jumlah stasiun pengamat hujan dan 1 dari debit aliran sungai untuk periode sebelumnya. Jumlah syaraf pada lapisan tersembunyi (*hidden layer*) dipakai 4 syaraf dan 6 syaraf. Jumlah syaraf pada lapisan keluaran (*output layer*) dalam penelitian ini adalah satu syaraf yaitu debit aliran sungai. Variasi arsitektur ANN dalam dalam penelitian ini disajikan pada Gambar 2 dan 3.



Gambar 2. Arsitektur 1



Gambar 3. Arsitektur 2

Syaraf Z_j menerima masukan dari syaraf-syaraf X_i yang sudah diberi bobot v_{ij} , masukan tersebut kemudian diaktivasi dan menghasilkan z_j , selanjutnya syaraf Z_j mengirim z_j ke syaraf output Q . hubungan dari syaraf Z_j ke syaraf output Q diberi bobot hubung w_{jk} . Nilai output y dari syaraf output Y didapat dengan mengaktifasi jumlah dari z_j yang sudah diberi bobot hubung.

$$z_j = f\left(\sum v_{ij} \times X_i\right) \dots\dots\dots (1)$$

dimana :

- z_j = output dari syaraf Z_j
- $f(\bullet)$ = fungsi aktivasi
- v_{ij} = bobot hubung dari input i ke hidden node j
- X_i = nilai input

$$q_k = f\left(\sum w_{jk} \times z_j\right) \dots\dots\dots (2)$$

dimana :

- q_k = output ke k
- $f(\bullet)$ = fungsi aktivasi
- w_{jk} = bobot hubung dari syaraf Z_j ke syaraf output Y
- z_j = nput dari syaraf Z_j ke syaraf output Y

Fungsi aktivasi (*activation functions*) berguna untuk memeras fungsi output supaya berada dalam nilai ambang (*threshold*) yang diinginkan , yaitu berada antara nilai 0 sampai 1 atau -1 sampai 1. Dalam penelitian ini digunakan fungsi aktivasi sigmoid atau fungsi logistik (*logistic functions*). Fungsi sigmoid ini digunakan untuk jaringan syaraf yang dilatih dengan menggunakan metode backpropagation. Fungsi sigmoid memiliki nilai pada rentang 0 (nol) sampai 1 (satu). Fungsi sigmoid dirumuskan sebagai :

$$y = f(x) = \frac{1}{1 + e^{-\sigma x}} \dots\dots\dots (3)$$

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. Bentuk dari fungsi objektif ini bermacam-macam, dalam penelitian ini di gunakan kesalahan absolute rata-rata (KAR). Persamaan untuk menghitung mengitung KAR menggunakan persamaan

yang di formulasikan oleh Adidarma, Hadihardaja dan Legowo at al. (2004) yaitu:

Kesalahan Absolut Rata-Rata (KAR) =

$$\frac{1}{n} \sum \frac{Abs(Q_{comp} - Q_{obs})}{Q_{obs}} \dots\dots\dots (4)$$

dimana :

- Q_{comp} = debit hasil perhitungan
- Q_{obs} = debit hasil pengamatan
- n = banyak data

Penerapan Kesalahan absolut rata-rata (KAR) dalam penelitian ini karena menurut Adidarma, Hadihardaja dan Legowo (2004), Nilai KAR lebih memperhatikan debit kecil daripada debit besar sehingga sangat bermanfaat bagi pengembangan sumberdaya air. Fungsi objektif seperti KAR dilakukan dengan pertimbangan penyimpangan terhadap data pengamatan menjadi pusat perhatian sehingga debit rendah menjadi lebih berarti.

PEMBELAJARAN DENGAN TEKNIK OPTIMASI

Proses pembelajaran ANN yang diterapkan dalam penelitian ini adalah dengan menggunakan Program non linier iteratif yang di kembangkan dari Reduced-Gradient Methods. Metode ini mencoba mempertahankan kelayakan setiap iterasi. Pendekatan tersebut memiliki beberapa keuntungan. Jika setiap estimasi dari solusi adalah layak, algoritma dapat dihentikan sebelum konvergen dan solusi pendekatannya tetap dapat di gunakan. Proses konvergensi dapat dilihat pada setiap iterasi yang diukur langsung dengan menggunakan nilai dari fungsi objektifnya (Nash, 1996 dalam Saragih and Hadihardaja at al. 2003). Kerugian dalam penggunaan metode ini adalah dalam hal biaya perhitungannya, karena setiap iterasi relatif memerlukan banyak waktu.

Pembelajaran dengan metode reduced gradient dalam penelitian ini digunakan

untuk mengoptimasi bobot hubungan dari ANN. Suatu algoritma pembelajaran diterapkan untuk meminimalkan fungsi kesalahan (*error function*), E dari ANN yang didefinisikan sebagai :

$$E = \frac{1}{2} \sum_{D=1}^S (T_D - O_D)^2 \dots\dots\dots (5)$$

dimana :

- S = jumlah data.
- T = target yang diperoleh dari data pengukuran.
- O = nilai keluaran yang di bangkitkan oleh fungsi ANN.

Prosedur meminimalkan E menggunakan suatu proses iteratif dari gradient descent, dimana di hitung gradient :

$$\nabla E = \left(\frac{\partial E}{\partial w_1}, \frac{\partial E}{\partial w_2}, \dots, \frac{\partial E}{\partial w_k} \right) \dots\dots\dots (6)$$

dalam metode ini di harapkan mendapatkan nilai kesalahan minimum dimana $\nabla E = 0$.

Metode reduced gradient yang di terapkan dalam proses pembelajaran ANN pada penelitian ini memiliki fungsi tujuan (*objective function*) dan fungsi kendala (*constrain function*). Prinsip formulasi metode reduced gradient untuk pembelajaran ANN memiliki prinsip yang sama seperti diberikan dalam Hadihardaja at al (2003) untuk memprediksi sedimen berdasarkan debit aliran air yang secara substansi sama dengan permasalahan dalam penelitian ini, yaitu:

Fungsi tujuan, adalah meminimalkan kesalahan (*minimize error*) atau E yang di hitung dari :

Kesalahan untuk setiap pola masukan, dihitung sebagai :

$$e = \frac{1}{2} \sum_{k=1}^m (T_k - O_k)^2 \dots\dots\dots (7)$$

Sehingga rata-rata kesalahan system atau mean square error (MSE) untuk semua pola masukan adalah :

$$E = \frac{1}{2N} \sum_{p=1}^N \sum_{k=1}^m (T_{p,k} - O_{p,k})^2 \dots\dots\dots (8)$$

dimana :

- m = jumlah syaraf output
- $O_{p,k}$ = nilai output ANN O_k pada pola ke-p
- $T_{p,k}$ = nilai target T_k untuk pola ke-p
- N = jumlah data

Fungsi kendala, yang dalam hal ini adalah menentukan besarnya nilai keluaran dari ANN dapat ditulis sebagai berikut :

$$O_{p,k} = \sum_{j=1}^q z_j w_{jk} + b_k \dots\dots\dots (9)$$

$$z_j = \frac{1}{1 + \text{Exp}\left(-\sigma \left[\sum_{i=1}^n x_i w_{ij} + b_j \right] \right)} \dots\dots\dots (10)$$

dimana :

- w_{ij}, w_{jk}, b_j, b_k = variable bebas
- n = jumlah syaraf masukan (*input node*)
- q = jumlah syaraf tersembunyi (*hidden node*)
- σ = parameter kecuraman dari fungsi aktivasi
- k = jumlah yang dimodelkan = 1, ..., m

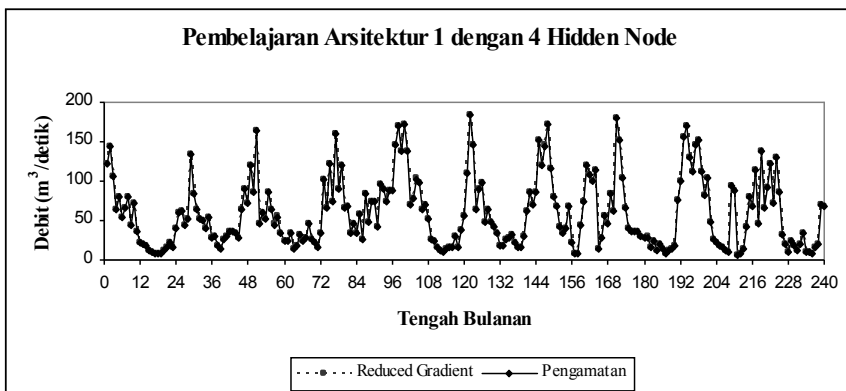
Pembelajaran dengan metode reduced gradient ini dikerjakan dengan menggunakan program Excel, dimana untuk proses pembelajaran dengan meminimumkan MSE (*Mean Square Error*) dipakai tools dari program Excel yaitu Solver, yang mampu mengoptimasi fungsi-fungsi non linier dengan variabel bebas yang banyak dalam waktu relatif singkat.

ANALISA DAN DISKUSI


Pembelajaran dengan metode reduced gradient terhadap dua pola arsitektur yaitu arsitektur 1 dengan 4 dan 6 lapisan tersembunyi, arsitektur 2 dengan 4 dan 6 lapisan tersembunyi, menghasilkan hidrograf seperti pada gambar 4 sampai 7 di bawah ini. Mean square error (MSE) hasil proses pembelajaran disajikan pada tabel 1 di bawah ini.

Tabel 1. Mean square error (MSE) hasil proses pembelajaran Reduced Gradient


| Arsitektur | Hidden Node | MSE |
|------------|-------------|------------|
| 1 | 4 | 1.6756E-11 |
| | 6 | 2.0396E-08 |
| 2 | 4 | 4.2566E-11 |
| | 6 | 1.0443E-10 |




Gambar 4. Hidrograf hasil pembelajaran metoda backpropagation arsitektur 1 dengan 4 hidden node



Gambar 5. Hidrograf hasil pembelajaran metoda backpropagation arsitektur 1 dengan 6 hidden node



Gambar 6. Hidrograf hasil pembelajaran metoda backpropagation arsitektur 2 dengan 4 hidden node



Gambar 7. Hidrograf hasil pembelajaran metoda backpropagation arsitektur 2 dengan 6 hidden node

Aplikasi Metode Generalized Reduced Gradient dalam Pemodelan Curah Hujan - Limpasan
Menggunakan Artificial Neural Network (ANN)

Pembelajaran dengan metode reduced gradient menghasilkan kesalahan absolut rata-rata dan parameter statistika seperti disajikan pada table 2 sebagai berikut :

Tabel 2. Parameter Statistika hasil pembelajaran metoda reduced gradient

| No | Arsitektur | KAR | Data Max | Data Min | Data Rata-rata | Standar Deviasi | Koefisien Skewnes | Koefisien Korelasi |
|------------|------------|-------|----------|----------|----------------|-----------------|-------------------|--------------------|
| 1 | A1-4 | 0.001 | 184.197 | 6.662 | 59.199 | 43.569 | 0.913 | 1.000 |
| 2 | A1-6 | 0.002 | 184.194 | 6.704 | 59.213 | 43.547 | 0.913 | 1.000 |
| 5 | A2-4 | 0.000 | 184.200 | 6.700 | 59.200 | 43.569 | 0.913 | 1.000 |
| 6 | A2-6 | 0.000 | 184.197 | 6.700 | 59.201 | 43.567 | 0.913 | 1.000 |
| Pengamatan | | | 184.200 | 6.700 | 59.200 | 43.569 | 0.913 | |

Berdasarkan parameter statistika menunjukkan bahwa semua pola arsitektur memiliki kesalahan absolut rata-rata (KAR) mendekati nol dan parameter statistika yang sangat dekat dengan data hasil pengamatan.

Dari proses pembelajaran dihasilkan bobot hubungan, bobot-bobot hubungan ini kemudian digunakan untuk membangkitkan


data sintetis atau disebut pengujian (*testing*). Hasil data bangkitan dihitung MSE dan KAR-nya, kemudian dipilih bobot yang menghasilkan data bangkitan yang memiliki nilai KAR terkecil untuk setiap arsitektur, kemudian dihitung parameter statistiknya. Proses pengujian menghasilkan parameter statistika untuk masing-masing arsitektur seperti pada tabel 3 di bawah ini.

Tabel 3. Parameter statistika hasil pengujian


| No | Pola | KAR | MSE | Data Max | Data Min | Data Rata-rata | Standar Deviasi | Koefisien Skewnes | Koefisien Korelasi |
|------------|------|-------|---------|----------|----------|----------------|-----------------|-------------------|--------------------|
| 1 | A1-4 | 0.999 | 652.004 | 170.901 | 24.207 | 46.549 | 19.737 | 2.379 | 0.663 |
| 2 | A1-6 | 0.730 | 539.788 | 161.832 | 7.195 | 47.331 | 32.271 | 0.947 | 0.700 |
| 5 | A2-4 | 0.498 | 405.671 | 197.461 | 6.592 | 47.485 | 40.492 | 1.443 | 0.790 |
| 6 | A2-6 | 0.485 | 512.581 | 270.977 | 6.047 | 46.467 | 43.641 | 2.158 | 0.746 |
| Pengamatan | | | | 301.900 | 4.000 | 47.108 | 46.146 | 2.212 | |

Hasil pengujian untuk setiap pola arsitektur dalam bentuk hidrograf disajikan pada gambar 8 sampai 11, sedangkan dalam


bentuk flow duration curve disajikan dalam gambar 12 sampai 15.




Gambar 8. Hidrograph hasil pengujian arsitektur 1 dengan 4 hidden node




Gambar 9. Hidrograph hasil pengujian Arsitektur 1 dengan 6 hidden node



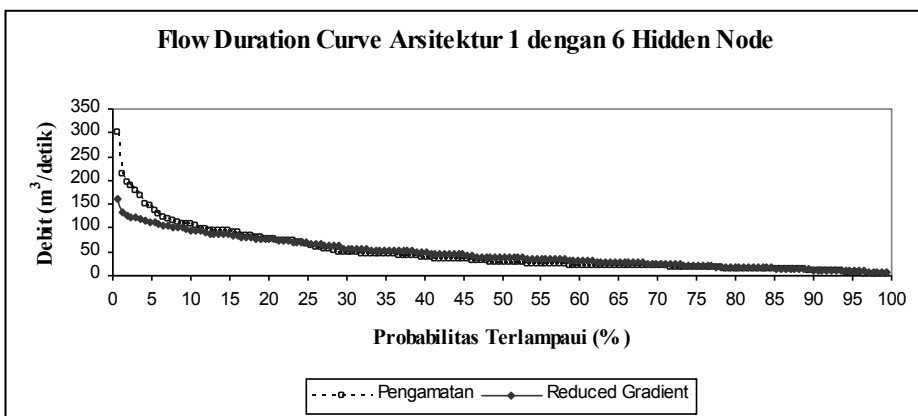
Gambar 10. Hidrograph hasil pengujian arsitektur 2 dengan 4 hidden node




Gambar 11. Hidrograph hasil pengujian arsitektur 2 dengan 6 hidden node




Gambar 12. Flow duration curve arsitektur 1 dengan 4 hidden node



Gambar 13. Flow duration curve arsitektur 1 dengan 6 hidden node



Gambar 14. Flow duration curve arsitektur 2 dengan 4 hidden node



Gambar 15. Flow duration curve arsitektur 2 dengan 6 hidden node

Hasil pengujian menunjukkan bahwa masing-masing arsitektur memiliki parameter statistika yang mendekati data pengamatan. Sehingga sulit ditentukan arsitektur yang paling optimal dalam menghasilkan data sintetis. Untuk menentukan satu arsitektur pilihan ditentukan dengan cara menghitung


kesalahan absolute rata-rata (KAR) dari parameter statistika. Model pilihan ditentukan dari arsitektur yang mempunyai jumlah kesalahan absolute rata-rata (KAR) parameter statistika paling kecil. KAR parameter statistika untuk masing-masing arsitektur disajikan dalam tabel 4.

Tabel 4. KAR parameter statistika pengujian metoda reduced gradient

| No | Arsitektur | KAR | KAR | | | | | Jumlah KAR |
|----|------------|-------|----------|----------|----------------|-----------------|-------------------|------------|
| | | | Data Max | Data Min | Data Rata-rata | Standar Deviasi | Koefisien Skwenes | |
| 1 | A1-4 | 0.999 | 0.434 | 5.052 | 0.012 | 0.572 | 0.076 | 7.145 |
| 2 | A1-6 | 0.730 | 0.464 | 0.799 | 0.005 | 0.301 | 0.572 | 2.870 |
| 5 | A2-4 | 0.498 | 0.346 | 0.648 | 0.008 | 0.123 | 0.348 | 1.970 |
| 6 | A2-6 | 0.485 | 0.102 | 0.512 | 0.014 | 0.054 | 0.024 | 1.191 |

Arsitektur 2 dengan 6 hidden (A2-6) memiliki jumlah kesalahan absolut rata-rata (KAR) parameter statistika terkecil yaitu 1,191. Sehingga pola arsitektur 2 dengan 6 hidden node (A2-6) ditentukan sebagai

model yang paling optimum dalam menghasilkan data sintetis. Simpangan data hasil pemodelan terhadap data hasil pengamatan disajikan dalam gambar 16.



Gambar 16. Simpangan data hasil pemodelan terhadap data pengamatan

PENUTUP

Penerapan generalized reduced gradient untuk pemodelan curah hujan limpasan memberikan hasil yang relatif baik pada proses pembelajaran dan proses pengujian. Arsitektur 2 dengan 6 hidden node (A2-6) memiliki jumlah KAR paling kecil yaitu 1,191 dan Sehingga disimpulkan arsitektur 2 dengan 6 hidden node (A2-6) menghasilkan data bangkitan yang paling optimum pada proses pengujian.

Secara umum ANN dapat diterapkan dalam pemodelan curah hujan limpasan walaupun hasilnya tidak terlalu akurat karena masih terjadi penyimpangan. Adanya penyimpangan data hasil pemodelan dengan data hasil pengamatan mungkin disebabkan adanya hal yang tidak diperhitungkan dalam pemodelan ini seperti pengambilan air pada sungai yang menyebabkan berubahnya kondisi alamiah aliran sungai tersebut serta kualitas data yang ada. Guna mendapatkan hasil yang lebih akurat lagi perlu dikembangkan

pemodelan dengan menggunakan arsitektur dan metode pembelajaran yang barangkali lebih sesuai dengan permasalahan ini. Disamping itu perlu diperhatikan kualitas data yang ada dan perlu diperhitungkan adanya pengambilan air yang menyebabkan berubahnya kondisi alamiah sungai.

DAFTAR PUSTAKA

- Hadihardaja I.K, *Stream flow discharge and relation using artificial neural network*, Media Komunikasi Teknik Sipil, 10, 1 – 15.
- Adidarma W.K, Hadihardaja I.K, Legowo Sri, *Perbandingan pemodelan hujan-limpasan antara artificial neural network (ANN) dan NRECA*, Jurnal Teknik Sipil ITB, 11, 105 – 115.
- Saragih D Ferianto, Hadihardaja IK, *Pemodelan Multivariat Deret Waktu Sumberdaya Air Menggunakan Jaringan Saraf Buatan*, Jurnal Pengembangan Keairan Badan Penerbit Undip, 1 Tahun 10, Juli 2003, 58 – 75.

Hadihardaja IK, *Model Pengoperasian Waduk Tunggal dengan Jaringan Syaraf Tiruan*, Jurnal Pengembangan Keairan Badan Penerbit Undip, 2 Tahun 10, Desember 2003, 24 – 33.

Fausett Laurence, *Fundamental of Neural Networks*, Prentice Hall, Englewood cliffs, New Jersey, 1994.

Haykin Simon, *Neural Networks, A Comprehensive Foundation*, Macmillan College Publishing Company, USA, 1994.

Kusumadewi Sri, *Artificial Intelligence (Teknik dan Aplikasinya)*, Graha Ilmu, (2003).

Babovic Vladan and Hristov Bojkov, Ventzi, *Runoff Modelling with Genetic Programming and Artificial Neural Networks*, D2K Technical Report, D2K TR 0401-1, April 2001.