
ARTIFICIAL NEURAL NETWORKS UNTUK PEMODELAN CURAH HUJAN-LIMPASAN PADA DAERAH ALIRAN SUNGAI (DAS) DI PULAU BALI

IGB. Sila Dharma¹⁾, IGA. Adnyana Putera¹⁾ dan Putu Doddy Heka Ardana²⁾

¹⁾Jurusan Teknik Sipil Fakultas Teknik Universitas Udayana. Deanpasar-Bali

²⁾Jurusan Teknik Sipil Fakultas Teknik Universitas Ngurah Rai. Bali

Email : siladharna@gmail.com

Abstract

Rainfall-runoff transformation of a watershed is one of the most complex hydrology phenomena, non-linear process, time-varying and spatial distribution. Rainfall-runoff relationships play an important role in water resource management planning and therefore, different types of models with various degrees of complexity have been developed for this purpose. The application of Artificial Neural Networks (ANNs) on rainfall-runoff modelling has studied more extensively in order to appreciate and fulfil the potential of this modelling approach. Back propagation method has used in this study for modelling monthly rainfall for small size catchments areas. ANN model developed in this study successfully predicts relationship for rainfall-runoff with 90.14% accuracy on learning process and 72.41% accuracy on testing process. These results show that ANN provides a systematic approach for runoff estimation and represents improvement in prediction accuracy.

Key words: *artificial neural networks, rainfall-runoff modelling, back propagation method*

1. Pendahuluan

Hubungan curah hujan-limpasan merupakan fenomena hidrologi yang kompleks, sehubungan dengan adanya proses yang tidak linier, bervariasi terhadap waktu dan merupakan distribusi yang spasial. Hubungan curah hujan-limpasan ini sangat penting artinya dalam bidang manajemen sumber daya air (Junsawang *et al.*, 2007) sehingga berbagai tipe model dengan tingkat kompleksitas yang bervariasi telah dikembangkan. Model-model ini dapat dikategorikan dalam tiga kategori umum yaitu model *black-box* atau model teoritis, model konseptual dan model fisik. Model *black-box* umumnya merupakan model empiris tanpa didasarkan atas transfer input-output fisik. Model konseptual umumnya berhubungan dengan elemen fisik yang disederhanakan dalam bentuk formulasi matematik linier ataupun non-linier. Model konseptual ini dikatakan cukup *reliabel* dalam meramalkan parameter-parameter penting dalam hidrograf (Kitanidis and Bras, 1980a; Kitanidis and Bras, 1980b).

Saat ini pendekatan pemodelan secara teoretis banyak dilakukan dengan mengadopsi teknik jaringan Syaraf Tiruan (*artificial neural network*,

ANN). ANN merupakan salah satu bentuk kecerdasan buatan yang mempunyai kemampuan untuk belajar dari data dan tidak membutuhkan waktu lama dalam pembuatan model (Setiawan dan Rudiyanto, 2004). Keuntungan dari penggunaan ANN adalah kemampuannya untuk mempelajari hubungan yang tidak diketahui yang sudah ada sebelumnya antara data input dan output dari setiap sistim. Selain itu pemodelan dengan ANN memiliki atribut yang diinginkan dan kemampuan belajar dari contoh-contoh tanpa memerlukan data fisik secara eksplisit.

Aplikasi ANN dalam memodelkan hubungan curah hujan-limpasan dalam suatu DAS telah banyak dilakukan sejak dekade lalu (Sharma and Murthy, 1998; Abdulla and Badranih, 2000; Tokar and Johnson, 1999; Sobri Harun *et al.*, 2002; Thurumalaiah and Deo, 2000). Pada umumnya studi-studi terdahulu dilakukan pada obyek studi dengan luas DAS yang besar. Sohail *et al.* (2008) menjelaskan bahwa untuk DAS dengan luas kurang dari 100 km², model ANN masih belum jelas penerapannya dikarenakan hubungan curah hujan-limpasan mengarah pada proses linearitas. Studi ini dilakukan untuk mengkaji kinerja ANN dalam memodelkan

hubungan curah hujan-limpasan pada beberapa DAS di Pulau Bali, yang sebagian besar merupakan DAS dengan luasan kecil ($< 100 \text{ km}^2$) dengan metode *Multi Layer Perceptron* (MLP) dengan pelatihan metode *back propagation*. *Back propagation* merupakan algoritma pelatihan yang terawasi dan digunakan oleh *perceptron* dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyi.

2. Jaringan Syaraf Tiruan (*Artificial Neural Networks, ANNs*)


Jaringan syaraf tiruan (ANN) adalah sistem pemroses informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi, yang merupakan representasi tiruan dari otak manusia, yang berisi berjuta-juta sel syaraf (neuron) dan berfungsi untuk memproses informasi. Neuron mempunyai karakteristik yang sama dalam ANN, terdiri dalam kelompok-kelompok yang disebut layer. Neuron-neuron dalam satu layer terhubung dalam layer-layer lainnya yang berdekatan. Kekuatan hubungan antar neuron yang berdekatan direpresentasikan dalam kekuatan hubungan atau bobot.

Sebuah ANN umumnya terdiri dari tiga layer yaitu *input layer*, *hidden layer* dan *output layer*. Layer input (*input layer*) terdiri dari neuron-neuron yang menerima sebuah input dari lingkungan luar. Input yang dimasukkan merupakan penggambaran dari suatu masalah. Layer tersembunyi (*hidden layer*) terdiri dari neuron-neuron yang menerima masukan dari input layer, dan kemudian membawa output ke layer berikutnya. Lapisan *output* disebut unit-unit *output*, terdiri dari neuron-neuron yang menerima output dari *hidden layer* dan mengirimkannya kepada pemakai.

Rosenblatt (1957) dalam Hung *et al.*, (2009) memperkenalkan pertama kali bentuk yang paling sederhana dari jaringan syaraf tiruan yang disebut *perceptron*, yang hanya terdiri dari satu layer. Input diberikan langsung ke unit output melalui koneksi bobot. Tahun 1960 dikembangkan *multi layer perceptron* (MLP) dan lambat laun menjadi topologi neural network yang banyak digunakan dalam berbagai bidang, dan termasuk ke dalam kategori *feedforward network*. Dalam jaringan ini, selain unit input dan output, ada unit-unit lain (sering disebut dengan layer tersembunyi/*hidden layer*).

Dimungkinkan pula ada beberapa layer tersembunyi. Sama seperti pada unit input dan output, unit-unit dalam satu layer tidak saling berhubungan. *Multilayer perceptron* berarti jaringan dengan satu atau lebih layer dari *node input* dan *output*. Metode ini dikatakan dapat mengatasi batasan-batasan yang ada pada metode satu *layer perceptron* (Lippmann, 1987). Dalam sebuah *feed-forward network*, koneksi berbobot memberikan aktivasi hanya pada arah maju dari *input layer* ke *output layer*. Disisi lain, dalam sebuah jaringan yang berulang, koneksi berbobot tambahan digunakan untuk memberikan masukan kepada aktivasi sebelumnya kembali ke jaringan. Struktur dari sebuah *feed-forward ANN* metode MLP diperlihatkan pada Gambar 1.

Keluaran yang dihasilkan oleh ANN untuk suatu pola masukan tertentu tergantung dari nilai (bobot) hubungan antar neuron dalam ANN tersebut. Dalam ANN, untuk aplikasi pengenalan pola diperlukan suatu pelatihan awal agar bisa digunakan didalam menerima input dari luar. Sebuah ANN dapat menyelesaikan persoalan yang rumit apabila digunakan nilai bobot yang tepat antar neuron-neuron pada lapisan yang berbeda. Nilai bobot yang tepat didapatkan melalui proses pelatihan (*training*). Proses pelatihan merupakan suatu proses untuk mengubah bobot antar neuron sehingga sebuah jaringan dapat menyelesaikan sebuah persoalan.



Gambar 1. Struktur sebuah *feed-forward ANN*

Langkah penting dalam pengembangan sebuah model ANN adalah penentuan bobot matrik melalui pelatihan (*training*). Ada dua tipe mekanisme training yaitu *supervised training* dan *unsupervised training*.

Supervised training memerlukan supervisi dari luar untuk memandu proses training. Algoritma ini menggunakan sejumlah pasangan data input-output yang dipergunakan sebagai contoh, dimana data yang dipergunakan sebagai contoh sebaiknya menggunakan data yang sudah diketahui kebenarannya. Output dari jaringan lalu dibandingkan dengan data output yang diharapkan (output contoh) untuk mendapatkan selisih antara output perkiraan dengan output sebenarnya. Selisih inilah yang dipergunakan untuk mengubah bobot jaringan sehingga diperoleh output yang sama atau mendekati target. Mekanisme sebuah supervised training yang disebut algoritma *back-propagation training* (Rumelhart *et al.*, 1986) umumnya banyak digunakan dalam aplikasi-aplikasi *enjinering*. Karena ANN tidak mempertimbangkan fisik dari permasalahan, ANN merupakan sebuah model *black-box* namun dapat mendeteksi proses fisik dalam model ANN yang sudah ditraining (Wilby *et al.*, 2003; Jain *et al.*, 2004; Sudeer and Jain, 2004)

3. Material dan Metodologi

3.1 Lokasi Studi

Lokasi studi adalah beberapa Daerah Aliran Sungai (DAS) di pulau Bali dengan luas kurang dari 100 km² yaitu DAS Tukad Nyuling dengan luas 24,93

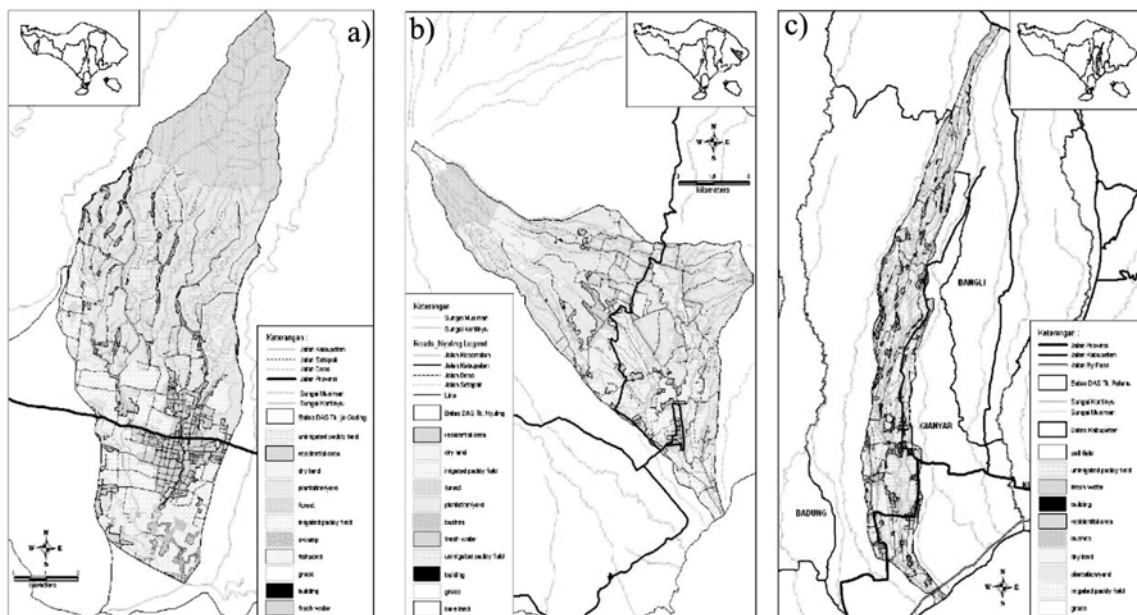
km² dan panjang sungai 13 km, DAS Tukad Jogading dengan luas 32,38 km² dan panjang 19,20 km dan DAS Tukad Petanu dengan luas 59,30 km² dan panjang 37 km seperti terlihat pada Gambar 2.

3.2 Data dan Perangkat Lunak

Data yang dipergunakan berupa data curah hujan wilayah, data debit dan data evapotranspirasi bulanan selama 10 tahun dari tahun 1994-2003 yang diperoleh dari tiga stasiun pengamatan hujan yang terdapat/dekat dengan masing-masing DAS. Sumber data diperoleh dari Unit Hidrologi Dinas Pekerjaan Umum Propinsi Bali dan BMKG Wilayah III Denpasar. Perangkat lunak untuk pemrograman memakai MATLAB Release 14 yang memiliki beberapa fitur yang dikelompokkan berdasarkan aplikasi tertentu (*Toolbox*) yang berkaitan dengan *Artificial Neural Networks* yaitu *Neural Network Tools*.

3.3 Prosedur Pemodelan

Prosedur pemodelan dengan ANN dilakukan dengan tahapan yaitu persiapan data, pemilihan arsitektur, pelatihan (training) dan pengujian (testing). Kedekatan data hasil pemodelan dan pengamatan dihitung dengan mean square error (MSE), koefisien korelasi, dan kesalahan absolute rata-rata (KAR).



Gambar 2. Daerah Aliran Sungai (DAS) pada Lokasi Studi a) DAS Tk.Jogading, b) DAS Tk.Nyuling dan c) DAS Tk. Petanu

3.4 Aplikasi Pemodelan Artificial Neural Networks


Data training dan data testing menggunakan data curah hujan, evapotranspirasi dan debit dari tahun 1994-2003 untuk tiga DAS yaitu DAS Tk.Nyuling, Tk. Jogading dan Tk. Petanu. Untuk training dipergunakan data tahun 1994-1999 dan untuk testing dipergunakan data tahun 2000-2003. Proses normalisasi dilakukan untuk merubah nilai data input dan output ke dalam skala -1 sampai 1 dengan menggunakan persamaan sebagai berikut (Santosa, 2007):

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}(BA - BB) + (BB) \quad (1)$$


dimana X' dan X masing-masing adalah data yang diskala dan data asli. X_{\max} dan X_{\min} masing-masing batas atas data yang diskala dan batas bawah data

yang diskala. BA dan BB merupakan batas atas dan batas bawah dimana dalam hal ini diambil masing-masing 1 dan -1. Enam struktur ANN digunakan untuk uji coba, dimana masing-masing adalah:

- Model 1 (2-5-1)
Model 1 dengan 2 node input layer yang ditentukan dari hujan dalam DAS dan evapotranspirasi, 5 node hidden layer, dan 1 node output layer yaitu limpasan t, seperti pada Gambar 3.
- Model 2 (3-5-1)
Model 2 dengan 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, seperti Gambar 4.



Gambar 3. Arsitektur jaringan model 1




Gambar 4. Arsitektur jaringan model 2

c. Model 3 (4-5-1)


Model 3 dengan 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, seperti Gambar 5

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

Model 4 dengan 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, seperti Gambar 6.



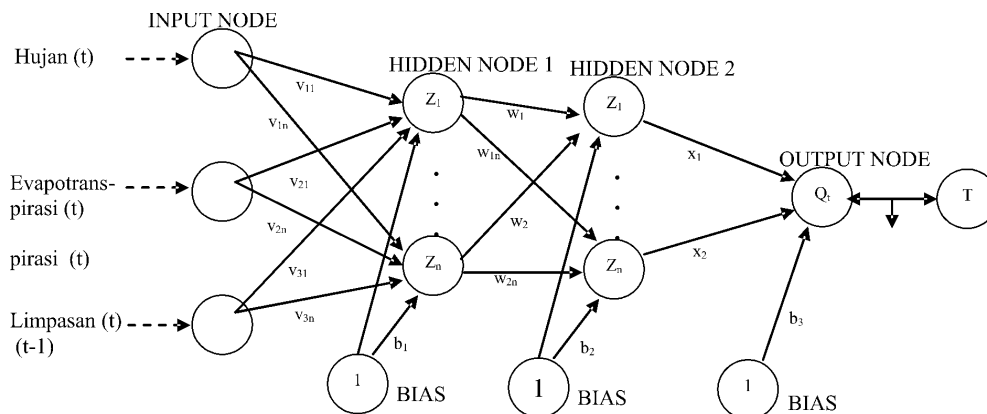
Gambar 5. Arsitektur jaringan model 3




Gambar 6. 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, seperti Gambar 7.

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, seperti Gambar 8.



Gambar 7. Arsitektur jaringan model 5



Gambar 8. Arsitektur jaringan model 6

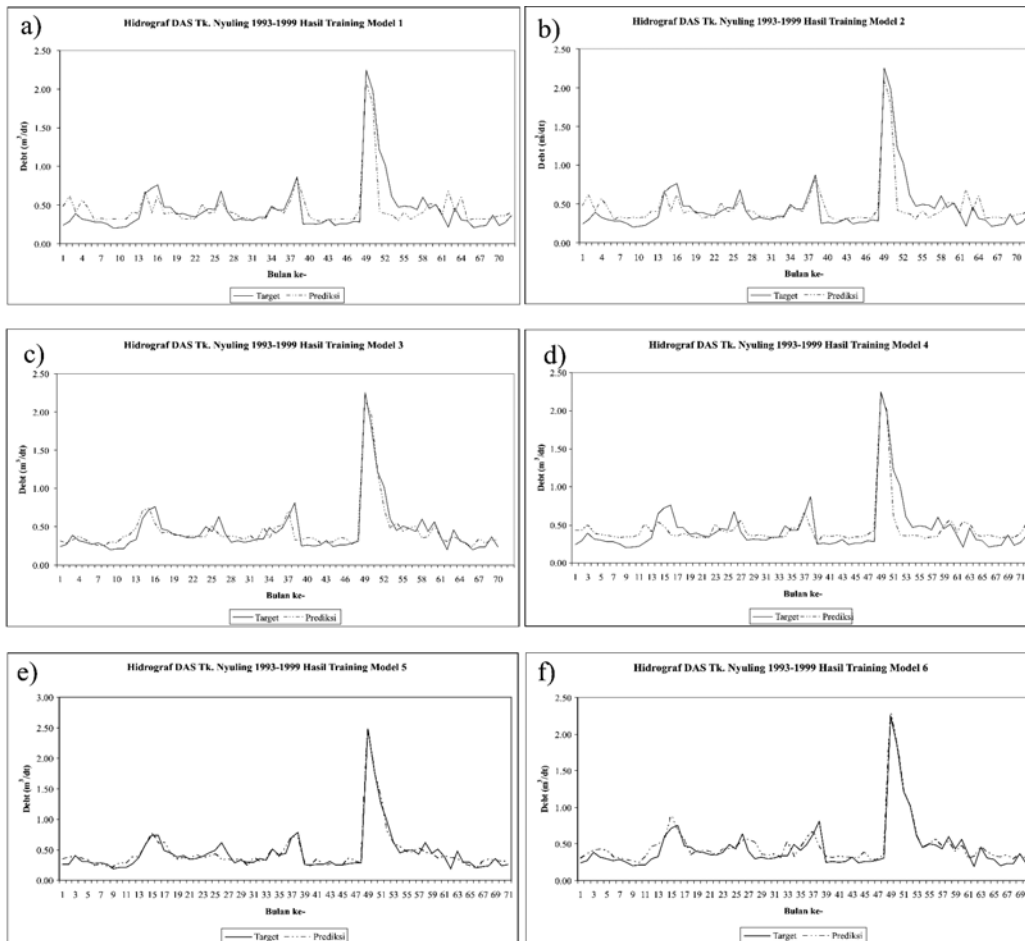
4. Hasil dan Pembahasan

Kinerja masing-masing model jaringan dalam memodelkan hubungan curah hujan-limpasan untuk tiga DAS dihitung dengan *mean square error* (MSE),

koefisien korelasi (r), dan kesalahan absolute rata-rata (KAR). Parameter statistika untuk masing-masing model diperlihatkan pada Tabel 1-3. Tabel 1 memperlihatkan kinerja ANN untuk DAS Tk. Nyuling.

Tabel 1. Kinerja Model Hasil Training dan Verifikasi DAS Tk. Nyuling

Model	MSE	DAS Tukad Nyuling			
		Training/Kalibrasi		Testing/Verifikasi	
		Koef. Korelasi	KAR	Koef. Korelasi	KAR
Model 1	0.021	0.843	0.300	0.004	1.124
Model 2	0.013	0.936	0.227	0.734	0.907
Model 3	0.011	0.945	0.200	0.681	0.627
Model 4	0.025	0.863	0.306	0.145	0.884
Model 5	0.005	0.973	0.157	0.719	0.337
Model 6	0.008	0.961	0.203	0.777	0.524




Gambar 9. Hidrograf Hasil Training di Tk. DAS Nyuling; (a) Model 1, (b) Model 2, (c) Model 3, (d) Model 4, (e) Model 5, dan (f) Model 6.

Model 5 dengan arsitektur jaringan 3-10-5-1 mempunyai nilai mean square error dan KAR terkecil masing-masing 0,005 dan 0,157, dengan koefisien korelasi paling besar yakni 0,973 atau 97,3% dari semua model yang sudah dilakukan proses training. Sedangkan pada proses testing, Model 5 dengan arsitektur jaringan 3-10-5-1 memberikan nilai mean square error dan KAR terkecil masing-masing 0,005 dan 0,337, dengan koefisien korelasi sebesar 0,719 atau 71,9%. Hasil training dan testing untuk setiap arsitektur jaringan dalam bentuk hidrograf disajikan pada Gambar 9 dan 10.

Tabel 2 memperlihatkan hasil pemodelan ANN


untuk DAS Tk. Jogading. Dari tabel tersebut dapat dilihat kinerja jaringan terbaik diberikan oleh model 6 dengan nilai KAR sebesar 0,816 dan koefisien korelasi paling besar yakni 0,916 atau 91,6% dari semua model pada proses training. Pada proses pengujian, model 5 memberikan nilai KAR sebesar 0,579 dan memiliki koefisien korelasi sebesar yaitu 0,700 atau 70%. Dari hasil analisis untuk mendapatkan tingkat kinerja model, model 5 memberikan hasil yang paling optimum untuk menggambarkan hubungan hujan-limpasan yang terjadi di DAS tersebut. Hasil training dan testing untuk setiap arsitektur jaringan dalam bentuk hidrograf disajikan pada Gambar 11 dan 12.




Gambar 10. Hidrograf Hasil Verifikasi di DAS Tk. Nyuling; (a) Model 1, (b) Model 2, (c) Model 3, (d) Model 4, (e) Model 5, dan (f) Model 6.

Tabel 2. Kinerja Model Hasil Training dan Verifikasi DAS Tk. Jogading

Model	MSE	DAS Tukad Jogading			
		Training/Kalibrasi		Testing/Verifikasi	
		Koef. Korelasi	KAR	Koef. Korelasi	KAR
Model 1	0.113	0.661	1.150	0.242	0.645
Model 2	0.095	0.765	0.766	0.556	0.495
Model 3	0.092	0.776	0.854	0.633	0.431
Model 4	0.079	0.855	0.748	0.249	0.662
Model 5	0.070	0.862	0.577	0.700	0.579
Model 6	0.053	0.916	0.816	0.554	0.640



Gambar 11. Hidrograf Hasil Training di DAS Tk. Jogading; (a) Model 1, (b) Model 2, (c) Model 3, (d) Model 4, (e) Model 5, dan (f) Model 6.



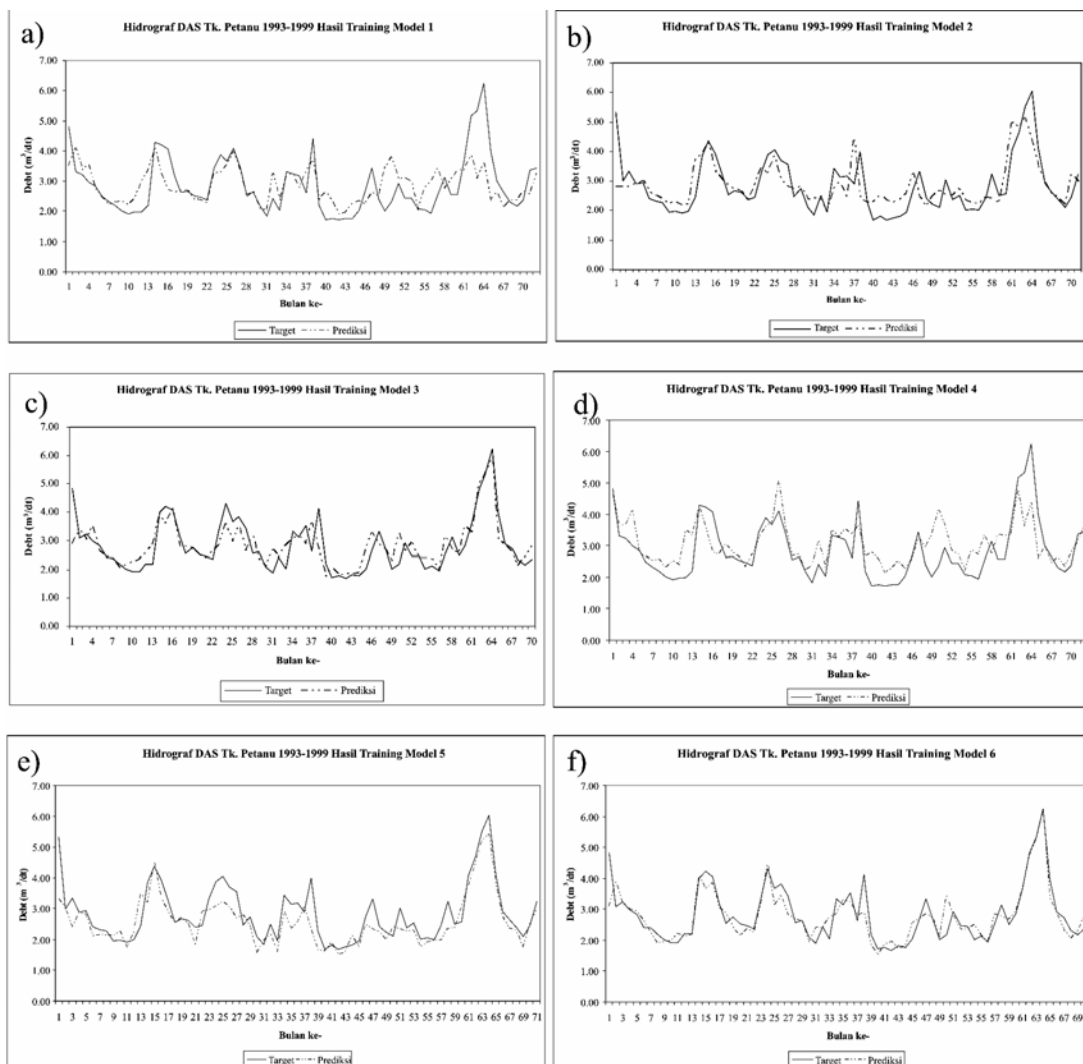
Gambar 12. Hidrograf Hasil Verifikasi di DAS Tk. Jogading; (a) Model 1, (b) Model 2, (c) Model 3, (d) Model 4, (e) Model 5, dan (f) Model 6.

Tabel 3 menunjukkan kinerja jaringan untuk DAS Tk. Petanu. Kinerja terbaik diberikan oleh model 6 dengan nilai KAR sebesar 0,100 dan koefisien korelasi paling besar yakni 0,891 atau 89,1%. Dari hasil analisis untuk mendapatkan tingkat kinerja model,

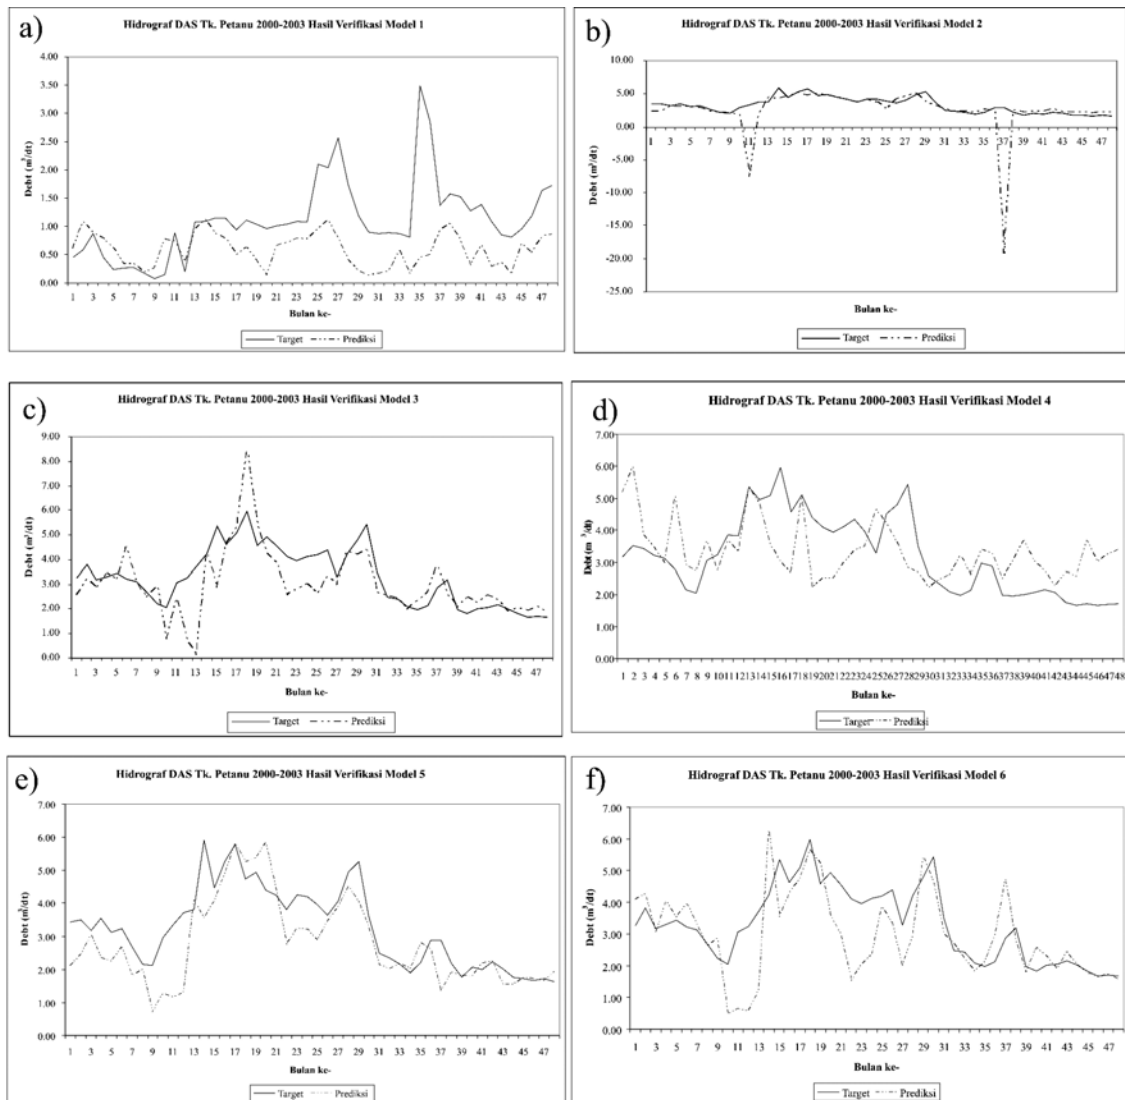
model 6 memberikan hasil yang paling optimum. Untuk menggambarkan hubungan hujan-limpasan yang terjadi di DAS Tukad Petanu. Hasil training dan testing untuk setiap arsitektur jaringan dalam bentuk hidrograf disajikan pada Gambar 13 dan 14.

Tabel 3. Kinerja Model Hasil Training dan Verifikasi DAS Tk. Petanu

Model	MSE	DAS Tukad Petanu			
		Training/Kalibrasi		Testing/Verifikasi	
		Koef. Korelasi	KAR	Koef. Korelasi	KAR
Model 1	0.110	0.575	0.184	0.166	0.296
Model 2	0.076	0.737	0.154	0.316	0.375
Model 3	0.055	0.818	0.137	0.712	0.212
Model 4	0.093	0.701	0.197	0.227	0.358
Model 5	0.056	0.869	0.132	0.754	0.197
Model 6	0.035	0.891	0.100	0.605	0.240



Gambar 13. Hidrograf Hasil Training di DAS Tk. Petanu; (a) Model 1, (b) Model 2, (c) Model 3, (d) Model 4, (e) Model 5, dan (f) Model 6.



Gambar 14. Hidrograf Hasil Verifikasi di DAS Tk. Petanu; (a) Model 1, (b) Model 2, (c) Model 3, (d) Model 4, (e) Model 5, dan (f) Model 6.

Berdasarkan hasil pemodelan untuk ketiga DAS, dilakukan proses perataan dari semua variabel yang mempengaruhi kinerja model untuk mendapatkan tingkat kinerja model secara umum. Tabel 4 menunjukkan hasil perataan yang dimaksud. Berdasarkan tabel terlihat bahwa secara umum model 5 memberikan hasil yang paling optimum untuk

menggambarkan hubungan curah hujan dengan limpasan dengan tingkat kinerja jaringan sebesar 0,063. Model 5 memberikan nilai KAR terkecil sebesar 0,289 dengan nilai koefisien korelasi 0,901 atau 90,1% pada proses training. Pada proses pengujian, model 5 memberikan nilai KAR terkecil sebesar 0,371 dengan nilai koefisien korelasi 0,724 atau 72,4%.

Tabel 4. Kinerja Model Rerata

Model	MSE	Kinerja Rerata			
		Training/Kalibrasi		Testing/Verifikasi	
		Koef. Korelasi	KAR	Koef. Korelasi	KAR
Model 1	0.081	0.693	0.545	0.137	0.688
Model 2	0.070	0.812	0.382	0.535	0.592
Model 3	0.063	0.846	0.397	0.675	0.423
Model 4	0.076	0.806	0.417	0.207	0.635
Model 5	0.063	0.901	0.289	0.724	0.371
Model 6	0.056	0.923	0.373	0.645	0.468

5. Simpulan

Model ANN metode *back propagation* dapat diterapkan dalam modelisasi hubungan curah hujan limpasan untuk DAS di Bali yang diperlihatkan melalui hasil proses training maupun testing. Parameter-parameter statistik yang digunakan memberikan hasil yang relatif baik.

Kinerja model ANN menunjukkan bahwa model 5 dengan arsitektur 3-10-5-1 memberikan hasil yang paling optimum dengan tingkat kinerja jaringan 0,063.

Model ini memberikan nilai kesalahan absolute rata-rata (KAR) terkecil 0,289 dengan nilai koefisien korelasi 0,901 pada proses training. Sedangkan pada proses pengujian, model ini memberikan nilai KAR terkecil 0,371 dengan nilai koefisien korelasi 0,724 yang berarti bahwa ANN memiliki kemampuan yang bagus dalam mereplikasi fluktuasi debit yang acak ke dalam bentuk model buatan yang memiliki fluktuasi yang hampir sama.

Daftar Pustaka

Abdulla, F. and L.A. Badranih. 2000. "Application of a Rainfall-Runoff Model to Three Catchments in Iraq". *Journal of Hydrological Sciences*, 45: 13-25

Hung, N.Q, M.S. Babel, S. Weesakul, and N.K. Tripathi. 2009. "An Artificial Neural Network Model for Rainfall Forecasting In Bangkok, Thailand". *Hydrol. Earth Syst. Sci.*, 13: 1413–1425.

Jain, A., K.P. Sudheer and Srinivasulu, S. 2004. "Identification Of Physical Processes Inherent In Artificial Neural Network Rainfall-Runoff Models". *Hydro. Process*, 118 (3): 571-581.

Junsawang, P., J. Asavanant, C. Lursinsap. 2007. "Artificial Neural Network Model for Rainfall-Runoff Relationship", *ASIMMOD*, Chiang Mai, Thailand.

Kitanidis, P.K. and R.L. Bras. 1980a. "Adaptive Filtering Through Detection of Isolated Transient Errors In Rainfall-Runoff Models". *Water Resource Res.*, 16 (4): 740-748.

Kitanidis, P.K. and R.L. Bras. 1980b. "Real-Time Forecasting With a Conceptual Hydrological Model". *Water Resource Res.*, 16 (4): 740-748.

Lippmann, R.P. 1987. "An Introduction To Computing With Neural Nets", *IEEE ASSP Magazine*, 4: 4–22.

Rumelhart, E., G. Hinton and R. Williams, 1986. "Learning Internal Representations by Error Propagation". *Parallel Distributive Process*, 1: 218-362.

Santosa, B., 2007. *Data Mining Terapan dengan MATLAB*, Graha Ilmu, Yogyakarta.

Setiawan, B.I. dan Rudiyanto, 2004. "Aplikasi Neural Networks Untuk Prediksi Aliran Sungai", *Prosiding Semiloka Teknologi Simulasi dan Komputasi serta Aplikasi 2004 – BPPT*, Jakarta.

Sharma, K.D. and J.S.R. Murthy. 1998. "A Practical Approach to Rainfall-Runoff Modelling in Arid Zone Drainage Basins", *Journal of Hydrology Sciences*, 43: 331-348

- Sobri, H., M.K. Amir Hashim, and A.N. Nor Irwan. 2002. "Rainfall-Runoff Modeling Using Artificial Neural Network", *Proceedings of 2nd World Engineering Congress*. Kuching.
- Sohail, A., K. Watanabe, and S. Takeuchi. 2008. "Runoff Analysis for a Small Watershed of Tono area Japan by Back Propagation Artificial Neural Network with Seasonal Data". *Water Resource Manage*, 22: 1-22.
- Sudheer, K.P. and A. Jain. 2004. "Explaining The Internal Behavior of Artificial Neural Network River Flow Models". *Hydrol. Process*, 118 (4): 833-844.
- Thirumalaiah, K., and Deo, M.C. 2000. "Hydrological Forecasting Using Artificial Neural Network", *Journal of Hydrologic Engineering*, 5(2), pp. 180-189.
- Tokar, A.S. and P.A.. Johnson, 1999. "Rainfall-runoff Modeling using Artificial Neural Networks", *Journal of Hydrology Engineering, ASCE*, 4(3), pp.232-239
- Wilby, R.L., R.J. Abrahart, and C.W. Dawson. 2003. "Detection Of Conceptual Model Rainfall-Runoff Processes Inside An Artificial Neural Network", *Hydrol. Sci. J.*, 48 (2): 163-181.