

Penerapan Artificial Neural Network di Bidang Hidrologi

Dyah Indriana Kusumastuti

Staf Pengajar Fakultas Teknik Universitas Lampung

Abstrak

Dasar pemikiran dari penelitian ini adalah penggabungan pendekatan matematis dengan metode yang umum dipakai di bidang hidrologi. Di samping penelitian yang bersandar pada proses fisik dan pemodelannya, pengembangan algoritma matematika yang baru serta metode-metodenya dapat memperkuat dan memperkaya pemodelan hidrologi. *Artifial Neural Network (ANN)* atau Jaringan Syaraf Tiruan dimodelkan dengan meniru proses kerja pada jaringan saraf manusia, dimana pemecahan masalah dilakukan berdasarkan informasi eksternal maupun internal yang mengalir melalui jaringan saraf tersebut. Dalam pemodelan hidrologi informasi tersebut umumnya berupa data hujan serta data aliran. Dalam penelitian ini penerapan ANN di bidang hidrologi digunakan untuk memprediksi transformasi hujan-aliran, khususnya untuk memprediksi data hujan serta data aliran yang hilang. Hasil penelitian menunjukkan bahwa ANN mampu digunakan dalam pemodelan hujan-aliran.

Kata kunci: *Artificial Neural Network*, Jaringan Syaraf Tiruan, hidrologi

PENDAHULUAN**LATAR BELAKANG**

Dengan berkembang pesatnya sistem komputer, maka ilmu yang meliputi komputasi juga berkembang pesat. Kemampuan komputer yang mampu mengolah data dengan kapasitas cukup besar serta kemampuan komputasinya yang semakin cepat menyebabkan bermunculannya teknik-teknik pemodelan bertipe data-driven. Pada saat ini terdapat beberapa teknik pemodelan data driven seperti *Artificial Neural Network*, *Nearest Neighbour Techniques*, *Genetic Algorithm*, maupun *Chaos Theory*.

Artificial Neural Network yang diterjemahkan menjadi Jaringan Syaraf Tiruan memiliki sistem kerja yang meniru syaraf manusia. Kemampuannya untuk mengenali pola berdasarkan input dan output yang telah lampau, membuat *Artificial Neural Network* menjadi satu teknik yang banyak dipakai untuk pengenalan pola maupun prediksi (Smith, 1993). Di bidang kedokteran, *Artificial Neural Network* dapat digunakan untuk mengenali kanker payudara pada wanita. *Artifical Neural Network* juga dapat diaplikasikan untuk memprediksi nilai saham. Dalam aplikasinya *Artificial Neural Network* juga dapat digunakan untuk pemodelan di bidang hidrologi (Minns dan Hall, 1996).

Pengetahuan tentang alur hidrologi (*hydrologic pathways*) dimana air mengalir di bawah maupun di atas tanah menuju sungai merepresentasikan komponen penting bagi pemahaman hidrologi di muka bumi (Sivapalan, 2001). Pemahaman hidrologi menyangkut pemahaman proses pengalihragaman dari satu set masukan menjadi satu set keluaran melalui satu proses dalam sistem hidrologi. Masukan yang dimaksud di sini umumnya berupa hujan, sedangkan keluaran berupa aliran. Kedua komponen tersebut merupakan komponen penting dalam pemodelan hidrologi dengan *Artificial Neural Network*.

RUANG LINGKUP

Penelitian ini meliputi daerah studi DAS Way Tulang Bawang yang terletak di Propinsi Lampung. Data hujan dan aliran yang digunakan berupa data harian. Beberapa stasiun terdapat beberapa data yang hilang, baik data dari stasiun hujan maupun pengukur aliran. Sehingga perlu dilakukan pengisian data hujan dan aliran yang hilang, sebelum dilakukan pemodelan hujan-aliran.

MAKSUD DAN TUJUAN

Tujuan umum dari penelitian ini untuk menyelidiki aplikasi ANN dalam pemodelan hujan-aliran.

Tujuan khusus untuk menyelidiki aplikasi ANN dalam :

1. memprediksi data hujan yang hilang
2. memprediksi data aliran yang hilang

METODOLOGI

ARTIFICIAL NEURAL NETWORK

Artificial Neural Network disusun oleh elemen-elemen pemroses yang berada pada lapisan-lapisan yang berhubungan dan diberi bobot. Dengan input yang diberikan, network ini dapat memodifikasi bobot yang akan dihasilkannya, sehingga akan menghasilkan output yang konsisten sesuai dengan input yang diberikan. Setiap elemen pemroses melaksanakan operasi matematika yang sudah ditentukan dan menghasilkan sebuah output dari satu atau beberapa input.


Pemodelan ANN, khusus bagi kaidah pelatihan yang menggunakan algoritma backpropagation, biasanya dikategorikan menjadi single layer dan multi layer. Tiap unit pada lapisan (*layer*) yang sama atau dapat disebut neuron memiliki tingkah laku yang sama dalam pemrosesan sinyal data. Penentuan penggunaan jenis fungsi (dalam penelitian ini digunakan fungsi *sigmoid*) dan pola koneksi pembobot antar lapisan merupakan hal terpenting.

Single Layer Perceptron

Network ini terdiri dari layer input dengan beberapa unit input, satu layer pembobot dan layer output yang terdiri atas beberapa unit output dimana masing-masing unit input terhubung secara penuh dengan masing-masing unit output, tetapi setiap unit output tidak terhubung dengan unit input maupun unit output lainnya. Pada network ini masing-masing unit input menerima sinyal informasi dari luar dan melalui koneksi yang ada, dilakukan proses pembobotan untuk masing-masing sinyal yang akhirnya akan direspon oleh masing-masing unit output. Pembobot untuk satu unit output tidak akan berpengaruh pada unit output yang lain.

Multi Layer Perceptron

Sistem kerja dari *Multi layer* ini sama seperti *single layer*, hanya pada strukturnya terdapat tambahan beberapa layer untuk pembobot. Jadi pada pemodelan ini terdapat tambahan satu atau beberapa layer lagi di antara input layer dan output layer yang sering disebut lapisan tersembunyi (*hidden layer*). Sehingga terdapat lapisan pembobot antara *input layer*, *hidden layer* dan *output layer*. Kelebihan dari struktur jenis ini jika dibandingkan dengan single layer yaitu dapat menyelesaikan masalah kompleks yang mungkin tidak dapat diselesaikan oleh jaringan *single layer* secara sempurna. Namun proses pelatihannya membutuhkan waktu yang relatif lebih lama.

Gambar 1. *Multi layer perceptron***Backpropagation**

Backpropagation adalah kaidah training atau pelatihan untuk menemukan pembobotan yang memungkinkan fungsi yang digunakan mencapai fungsi target sedekat mungkin. Pertama, satu set nilai dari variabel independen (input) dimuatkan ke dalam input layer, dimana masing-masing unit hanya mengirimkan nilainya tanpa melakukan perhitungan apa-apa. Masing-masing *hidden* unit menghitung jumlah pembobotan dari input dan faktor pembobot. Berikutnya, masing-masing *hidden* unit menghitung fungsi *sigmoid* dari jumlah tersebut dan mengirimkan hasilnya ke semua unit output. Masing-masing unit output melakukan perhitungan serupa.

Unit output diberi informasi tentang nilai target, yang selanjutnya mengantarkan jumlah error tersebut kembali kepada *hidden* unit. Untuk masing-masing set perhitungan terdapat perambatan maju melalui network untuk menentukan output jaringan yang aktual, disertai perambatan mundur untuk menentukan bagaimana pembobot harus diubah.

4. Pertimbangan Praktis

Beberapa pertimbangan praktis harus dipertimbangkan ketika menggunakan ANN, seperti kemungkinan terdapatnya local minimum dan kriteria penghentian yang dapat mempengaruhi kinerja model ANN.

Local minimum

Analog dari suatu *local minimum* seperti menempatkan sebuah bola pada suatu permukaan dan membiarkannya menggelinding sampai tenang pada titik terendah di permukaan tersebut. Keberadaan titik rendah yang lebih dari satu dapat menimbulkan masalah, karena bola dapat saja terhenti di titik yang rendah namun bukan yang terendah di permukaan tersebut. Cara yang mudah untuk menghindari *local minimum* adalah dengan mencoba memulai lagi dengan pembobot awal yang berbeda. Hal ini serupa dengan memulai dari titik yang berbeda pada lanskap energi dan diperiksa apakah nilai minimum yang lebih rendah dapat tercapai.

Kriteria penghentian

Untuk memulai *backpropagation*, suatu nilai awal diberikan kepada masing-masing pembobot. *Backpropagation* berlanjut hingga kriteria penghentian tercapai. Ada 3 (tiga) kriteria umum: jumlah iterasi, *mean square error* dari *training set*, serta *mean square error* dari *validation set*. Di antara ketiganya, *cross validasi* memiliki nilai lebih sebagai kriteria penghentian.

Software yang digunakan dan pencocokan hasil

Software yang digunakan dalam penelitian ini adalah NeuroSolutions. Untuk mengetahui tingkat pencocokan dari hasil pemodelan digunakan koefisien efisiensi.

2

PENGISIAN DATA HUJAN YANG HILANG

Pengisian data hujan yang hilang dilakukan dengan arsitektur *Multi Layer Perceptron* untuk melatih network. Input bagi ANN dipilih untuk mendeskripsikan periode waktu yang memiliki pengaruh pada hujan sekarang. Input yang berbeda dicobakan dan hasilnya dibandingkan hingga mendapatkan hasil terbaik. Dari beberapa kali percobaan diketahui bahwa input yang paling sesuai adalah hujan yang terjadi pada hari sebelumnya, hari ini dan hari berikutnya yang berasal dari stasiun hujan sekitar yang sebelumnya sudah diuji memiliki korelasi yang baik dengan stasiun hujan tersebut. Sebagai contoh, jika terdapat 3 stasiun hujan sekitar yang berkorelasi baik, maka hujan P_x pada stasiun x dihitung :

$$P_x = f(P_A^{n-1}, P_A^n, P_A^{n+1}, P_B^{n-1}, P_B^n, P_B^{n+1}, P_C^{n-1}, P_C^n, P_C^{n+1}) \quad (1)$$

2

PENGISIAN DATA ALIRAN YANG HILANG

Pengisian data aliran yang hilang sedikit berbeda dengan pengisian data hujan yang hilang. Untuk pengisian data hujan yang hilang Persamaan 1 dapat diterapkan pada stasiun hujan manapun, sedangkan untuk pengisian data aliran yang hilang tergantung pada lokasi stasiun pengukur. Jika stasiun pengukur terletak di hulu, maka tidak diperlukan informasi tentang aliran dari stasiun pengukur aliran yang lain sehingga semua input berupa hujan dari stasiun hujan sekitar. Pengisian data aliran yang hilang harus dilakukan dari arah hulu ke hilir.

Aliran Harian

Pemodelan ANN untuk mengisi data aliran harian yang hilang meliputi penyelidikan waktu konsentrasi dari satu pengukur hujan ke pengukur aliran serta karakteristik tampungan DAS. Uji coba perlu dilakukan untuk mendapatkan algoritma yang tepat yang dapat mendeskripsikan transformasi aliran pada lokasi tersebut.

Pengisian data aliran harian untuk daerah hulu dideskripsikan dalam persamaan 2.

$$Q_x = f(P_i^{t-r}, P_i^{t-r-1}, P_i^{t-r-2}, P_i^{t-r-3}, P_i^{t-r-4}, P_i^{t-r-5}, P_i^{t-r-6}) \quad (2)$$

Dimana r bisa berbeda untuk stasiun pengukur satu dengan lainnya dan nilainya bisa 0, 1, 2, 3, dan seterusnya. Variabel pertama mewakili waktu konsentrasi dari stasiun hujan menuju pengukur aliran.

Rerata aliran bulanan

Pengisian rerata aliran bulanan daerah hulu DAS menggunakan algoritma berikut :

$$Q_x^t = g(P_1^t, P_2^t, P_3^t, \dots, P_i^t) \quad (3)$$

dimana P_i^t adalah hujan bulanan di stasiun i pada waktu t .

Pengisian rerata aliran bulanan daerah tengah DAS menggunakan algoritma :

$$Q_x^t = g(Q_y^t, P_1^t, P_2^t, \dots, P_i^t) \quad (4)$$

Dimana Q_y^t adalah rerata aliran bulanan pada pengukur aliran y yang terletak di hulu pengukur aliran x .

Pengisian rerata aliran bulanan pada outlet DAS memperhitungkan semua data aliran yang sebelum outlet. Hal ini dapat dilakukan dengan menjumlahkan semua aliran di sebelah hulunya menjadi single input, dan tidak menggunakannya sebagai input yang terpisah. Metode untuk DAS bagian hilir adalah :

$$Q_x^t = g\left(\sum_{i=1}^n Q_y^t, P_1^t, P_2^t, \dots, P_i^t\right) \quad (5)$$

HASIL DAN PEMBAHASAN

Aplikasi ANN untuk pengisian data hujan yang hilang dilakukan pada sebuah stasiun hujan, yaitu stasiun hujan Kemuning, dengan koefisien efisiensi sebesar 0,8532.

Hasil dari pengisian data aliran harian yang hilang disajikan pada Tabel 1. Dapat dilihat bahwa koefisien korelasi untuk training data masih belum memuaskan yang mungkin disebabkan karena data aliran harian yang tidak akurat, karena tidak adanya data tentang variasi aliran sepanjang hari. Hal ini berarti aliran terukur tersebut tidak dapat dianggap sebagai rerata aliran harian. Dengan alasan tersebut maka pengisian data aliran harian tidak diteruskan. Fokus penelitian ditujukan pada pengisian data rerata aliran bulanan yang hilang, dengan asumsi bahwa data ini lebih dapat mewakili kondisi aliran bulanan.

Tabel 1. Perbandingan hasil koefisien efisiensi untuk hasil training aliran harian dan rerata aliran bulanan

SUB DAS	Lokasi	Stasiun pengukur	Koefisien Efisiensi	
			Harian	Aliran bulanan
Pakuan Ratu	Hulu	Sukajaya	0,6448	0,9384
		Tanjung Agung	0,6758	0,9328
		Rantau Jangkung	0,6886	0,9396
		Rantau Temiang	0,5963	0,9119
	Tengah	Sumberjaya	-	0,9048
		Banjarmasin	-	0,9128
		Negeri Batin	-	0,9180
	Hilir	Pakuan Ratu	-	0,9177
Gunung Katun	Hulu	Ogan Enam	0,5782	0,8999
	Tengah	Kotabumi	-	0,9402
	Hilir	Gunung Katun	-	0,8971

Ketika kurang berhasil memberikan korelasi yang baik antara aliran harian terukur dan terhitung, maka hasil untuk rerata aliran bulanan dapat dianggap memuaskan (Tabel 1). Meskipun data aliran harian tidak dapat dianggap mewakili aliran pada hari tersebut, namun data aliran harian tersebut masih dapat memberikan informasi yang lebih baik tentang apa yang terjadi selama satu bulan.

Overfitting

Di dalam pemetaan input terhadap output, network berusaha untuk memperoleh pencocokan sedekat mungkin antara hasil hitungan dan target. Akan tetapi, semestinya network tidak perlu melakukan pencocokan terlalu dekat. Karena kemungkinan terjadi bahwa network bukannya menemukan fungsi yang mendeskripsikan hubungan fundamental antar data poin, namun malah mencoba mencari fungsi yang menghubungkan masing-masing data poin bahkan termasuk data poin yang kurang valid. Untuk mencegah *overfitting* bisa dilakukan dengan membatasi jumlah hidden node maupun banyaknya pelatihan. Salah satu contoh adalah hasil training rerata aliran bulanan untuk Gunung Katun (Tabel 2). Ketika koefisien efisiensi untuk pelatihan mencapai

angka yang sangat memuaskan, yaitu 0,9883, yang diperoleh dengan banyak pelatihan 5000 *epoch*, maka koefisien korelasi untuk hasil verifikasi menurun tajam sampai 0,0974.

Tabel 2. *Training epoch* sebagai indikasi *overfitting*

Training epoch	Koefisien efisiensi untuk training	Koefisien korelasi untuk verifikasi
1000	0,8771	0,3645
3000	0,8971	0,3665
5000	0,9883	0,0974

KESIMPULAN

1. Dalam pemodelan hujan aliran kualitas data hujan dan aliran sangat signifikan. Data yang tidak konsisten akan menyebabkan hasil pemodelan kurang memuaskan.
2. Keterbatasan data aliran harian yang tidak mewakili aliran harian rerata menyebabkan pemodelan pengisian data aliran harian kurang memuaskan. Sementara itu pengisian rerata aliran bulanan dapat dianggap memuaskan karena data yang tersedia dapat mewakili rerata aliran bulanan saat itu. Pengisian rerata aliran bulanan menggunakan metode yang berbeda tergantung pada lokasi stasiun pengukur.

DAFTAR PUSTAKA

1. Minns, A.W. dan Hall, M.J. 1996. *Artificial neural networks as rainfall-runoff models*, Hydrological Sciences Journal, Vol.41, No.3, 399-417.
2. Smith, M. 1993. *Neural Networks for Statistical Modelling*. Van Nostrand Reinhold, New York.
3. Sivapalan, M., Kumar, P. dan Harris, D. 2001. *Preface: Nonlinear propagation of multi-scale dynamics through hydrologic subsystems*. Adv. In Water Resour., 24, 935-940.

Penerapan Artificial Neural Network di Bidang Hidrologi

ORIGINALITY REPORT

10%

SIMILARITY INDEX

PRIMARY SOURCES

1	repository.lppm.unila.ac.id Internet	46 words — 2%
2	spektrum.unram.ac.id Internet	38 words — 2%
3	ft-sipil.unila.ac.id Internet	22 words — 1%
4	media.neliti.com Internet	21 words — 1%
5	unesdoc.unesco.org Internet	21 words — 1%
6	www.scribd.com Internet	20 words — 1%
7	sinta.unud.ac.id Internet	16 words — 1%
8	digital.library.adelaide.edu.au Internet	13 words — 1%
9	P. W. Christensen. "Formulation and comparison of algorithms for frictional contact problems", International Journal for Numerical Methods in Engineering, 05/15/1998	11 words — 1%

10	asmaranidara.wordpress.com	8 words — < 1%
	Internet	

11	repository.ub.ac.id	6 words — < 1%
	Internet	

EXCLUDE QUOTES OFF
EXCLUDE BIBLIOGRAPHY ON

EXCLUDE MATCHES OFF