



Metode Peramalan Jaringan Saraf Tiruan Menggunakan Algoritma *Backpropagatin* (Studi Kasus Peramalan Curah Hujan Kota Palembang)

I M Sofian¹, Y Apriani²✉

¹Magister Fisika, Universitas Sriwijaya, Indonesia

²Prodi Teknik Elektro, Universitas Muhammadiyah Palembang, Indonesia

Info Artikel

Sejarah Artikel:

Diterima 11 Juli 2017

Disetujui 23 September 2017

Dipublikasikan 1 Oktober 2017

Keywords:

Artificial neural network, backpropagation, rainfall

Abstrak

Penelitian bertujuan untuk memprediksi curah hujan bulanan menggunakan jaringan syaraf tiruan (JST) dengan suatu fungsi pelatihan *backpropagation*. Penelitian ini menggunakan data curah hujan di Stasiun Klimatologi Kelas I Palembang dari tahun 2014 sampai tahun 2016. Analisis dilakukan terhadap tingkat korelasi antara output jaringan dengan data observasi dan dari nilai MSE yang dihasilkan jaringan. Hasil penelitian menunjukkan jaringan terbaik dengan jumlah neuron 12 pada lapisan input, pada lapisan tersembunyi terdapat 3 lapis terdiri dari 50-20-20 neuron, 1 neuron pada lapisan output, data latih tahun 2014 dengan target tahun 2015, data uji tahun 2015 dengan target tahun 2016. Adapun parameter JST $lr=0,1$, $mc=0,9$, $epochs=1000$, $te=20$, $e=0,001$ yang mempunyai korelasi terhadap data observasi sebesar 0,99276 dengan nilai MSE 0,00086145 (proses pelatihan). Sementara pada proses pengujian, korelasi terhadap data observasi sebesar 0,79544 dengan nilai MSE 0,25528. Jaringan ini kemudian digunakan untuk proses prediksi curah hujan tahun 2017.

Abstract

The study aims to predict monthly rainfall using artificial neural network (ANN) with a backpropagation training function. This research uses rainfall data at Climatology Station Class I Palembang from 2014 until 2016. The analysis is done to determine correlation level between network output with observation data and from value of MSE produced by network. The results show the best network with the number of 12 neurons in the input layer, in the hidden layer there are 3 layers consisting of 50-20-20 neurons, 1 neuron in the output layer, training data of 2014 with a target of 2015, test data of 2015 with the target year 2016. The JST parameter $lr = 0,1$, $mc = 0,9$, $epochs = 1000$, $te = 20$, $e = 0,001$ have correlation to observation data equal to 0,99276 with value of MSE 0.00086145 (training process). While in the testing process, the correlation to observation data of 0.79544 with the value of MSE 0.25528. This network is then used for the rainfall prediction process in 2017.

© 2017 Universitas Negeri Semarang

✉ Alamat korespondensi:

E-mail: yosi_apriani@um-palembang.ac.id

ISSN 0215-9945

PENDAHULUAN

Curah hujan merupakan komponen penting dalam siklus hidrologi yang paling kompleks dan sulit dipahami serta dimodelkan, karena kompleksitas proses atmosfer yang menghasilkan hujan serta variasi yang luar biasa diberbagai skala, baik dalam skala ruang dan waktu (French *et al.* 1992). Analisis terhadap variabel data curah hujan kebanyakan dilakukan untuk mengetahui intensitas curah hujan (Chen & Liu 2012; Richard & Rao 2014; May 2004). Dengan demikian, analisis yang diperoleh dapat berperan dalam monitoring pengelolaan sumber daya air dan bencana alam (Prabawadhani *et al.* 2016; Narulita 2016).

Analisis curah hujan berupa data *timeseries* menjadi perhatian besar selama abad terakhir. Secara sederhana, analisis data *timeseries* dilakukan dalam proses peramalan curah hujan. Hal ini menjadi salah satu tanggung jawab penting bagi pelayanan meteorologi di seluruh dunia. Permasalahan utama dalam hal analisis dan prediksi curah hujan *timeseries* adalah tingkat kesalahan yang semakin meningkat dari waktu ke waktu dalam melakukan prediksi. Hal ini dapat terjadi karena kondisi ketidakpastian juga meningkat seiring dengan perubahan musim dan iklim (Wilks 1998; Patel & Parekh 2014; Kajornit *et al.* 2014).

Dengan menggunakan teknologi di bidang *Artificial Intelligence* (AI), yaitu teknologi Jaringan

Syaraf Tiruan (JST), maka identifikasi pola data dari sistem peramalan curah hujan dapat dilakukan dengan metode pendekatan pembelajaran. Berdasarkan kemampuan belajar yang dimilikinya, maka JST dapat dilatih untuk mempelajari dan menganalisa pola data masa lalu dan berusaha mencari suatu formula atau fungsi yang akan menghubungkan pola data pada masa lalu dengan keluaran yang diinginkan pada saat ini (Kustiyo *et al.* 2006; Sharma & Nijhawan 2015). Hasil JST dalam identifikasi data bergantung pada algoritma pembelajaran, arsitektur jaringan, dan pemilihan parameter kendali (Saxena *et al.* 2014; Garay *et al.* 2010). Salah satu algoritma JST yang umum digunakan adalah JST *backpropagation* (propagasi balik). Algoritma ini merupakan salah satu arsitektur JST yang dapat digunakan untuk memperoleh keluaran yang lebih akurat (dengan kesalahan atau *error* minimum). Untuk itulah pada penelitian ini dilakukan peramalan curah hujan bulanan dengan menggunakan JST propagasi balik untuk mendukung peramalan curah hujan di Kota Palembang.

METODE

Penelitian ini menggunakan data sekunder curah hujan bulanan kota Palembang tahun 2014-2016 (Tabel 1). Data bersumber dari Stasiun Klimatologi Palembang.

Tabel 1. Data curah hujan bulanan kota Palembang tahun 2014-2016

Tahun	JAN	FEB	MAR	APR	MEI	JUN	JUL	AGU	SEP	OKT	NOV	DES
2014	182.7	17.6	116	350.4	92.2	107.8	112.2	63	32.6	1.4	249.2	343.2
2015	221.6	132.2	390.5	375.6	177.9	170.2	21.4	21.2	5.3	0.2	193.4	323
2016	277.6	228.7	251.4	367.4	333.6	105.2	93.5	212.6	341.1	472.1	465.7	341.4

Penelitian ini menggunakan algoritma pembelajaran *backpropagation* dengan model jaringan *multilayer feedforward network* sehingga struktur dasar jaringan terdiri dari lapisan masukan, tersembunyi dan keluaran. Metode pelatihan yang digunakan dalam penelitian ini adalah pelatihan *supervised* dan dilakukan dengan fungsi pelatihan (traingdx). Proses yang dilakukan dalam pelatihan sesuai dengan Mislán *et al.* (2015) sebagai berikut.

Penyiapan data masukan dan keluaran

a. Normalisasi

Proses pelatihan *supervised* membutuhkan pasangan data masukan dan keluaran aktual untuk dipelajari. Data masukan dibutuhkan sebagai masukan, dan data keluaran dibutuhkan sebagai target jaringan. Sebelum diproses, data dinormalisasi terlebih dahulu. Normalisasi terhadap data dilakukan agar keluaran jaringan sesuai dengan fungsi aktivasi yang digunakan. Data-data tersebut dinormalisasi dalam interval [0, 1] karena dalam

prediksi curah hujan, nilai curah hujan pasti bernilai positif atau 0. Selain itu juga terkait fungsi aktivasi yang diberikan yaitu sigmoid biner. Menurut Fausett (1994), fungsi sigmoid adalah fungsi asimtotik (tidak pernah mencapai 0 ataupun 1) maka transformasi data hendaknya dilakukan pada interval yang lebih kecil yaitu [0.1 , 0.9] dengan menggunakan Persamaan 1.

$$x' = \frac{0,8(x-a)}{b-a} + 0,1 \quad (1)$$

a adalah data minimum, *b* adalah data maksimum, *x* adalah data yang akan dinormalisasi dan *x'* adalah data yang telah ditransformasi.

b. Pembuatan pola data masukan, target, uji

Data latih menggunakan data curah hujan pada bulan ke-1 s.d bulan ke-24 (tahun 2014-2015) sedangkan data uji menggunakan data curah hujan pada bulan ke-13 s.d bulan ke-36 (tahun 2015-2016). Pola data masukan untuk proses pelatihan dan pengujian jaringan ditunjukkan pada Tabel 2 dan Tabel 3.

Tabel 2. Data curah hujan normalisasi (data latih)

Pola	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Target
1	0.41	0.13	0.30	0.69	0.26	0.28	0.29	0.21	0.15	0.10	0.52	0.68	0.48
2	0.13	0.30	0.69	0.26	0.28	0.29	0.21	0.15	0.10	0.52	0.68	0.48	0.32
...
12	0.68	0.48	0.32	0.76	0.74	0.40	0.39	0.14	0.14	0.11	0.10	0.43	0.65

Tabel 3. Data curah hujan normalisasi (data uji)

Pola	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Target
1	0.48	0.32	0.76	0.74	0.40	0.39	0.14	0.14	0.11	0.10	0.43	0.65	0.57
2	0.32	0.76	0.74	0.40	0.39	0.14	0.14	0.11	0.10	0.43	0.65	0.57	0.49
...
12	0.65	0.57	0.49	0.53	0.72	0.67	0.28	0.26	0.46	0.68	0.90	0.89	0.68

Pembuatan disain dan parameter JST *backpropagation*

Arsitektur JST propagasi balik yang dibuat dalam peneliti ini terdiri dari 12 neuron (lapis masukan), 50-20-20 (lapis tersembunyi), 1 neuron (lapis keluaran). Sementara untuk parameter terdiri dari: lr=0,1; mc=0,9; epochs=1000; show=20; goal=0,001. Fungsi aktivasi di masing-masing koneksi: logsig, logsig, puelin, purline. Dan fungsi pelatihan traingdx. Arsitektur JST *backpropagasi* 12-50-20-20-1 terlihat pada Gambar 1.



Gambar 1. Arsitektur JST *backpropagasi* 12-50-20-20-1

Pengujian dan peramalan

Pengujian dilakukan bertujuan untuk mengetahui tingkat keakuratan sistem JST yang telah dibuat dalam memprediksi data curah hujan

pada tahun tertentu. Sedangkan peramalan bertujuan untuk meramalkan data curah hujan yang akan datang (tahun 2017).

Langkah JST *backpropagation* dalam peramalan

Langkah dalam proses peramalan terdiri dari umpan maju (menghitung semua keluaran jaringan di unit), umpan balik (menghitung faktor δ unit keluaran dan tersembunyi berdasarkan kesalahan di setiap unit), perubahan bobot.

HASIL DAN PEMBAHASAN

Pada sesi ini menjelaskan tentang hasil curah hujan menggunakan JST *backpropagation* dengan arsitektur 12-50-20-20-1. Pada proses pelatihan, koefisien korelasi (R) yang dihasilkan adalah sebesar 0,99276 dengan nilai *Mean Square Error* (MSE) 0,00086145 dan epochs 99. Berdasarkan pada nilai koefisien korelasi dan nilai MSE yang diperoleh pada proses pelatihan, bahwa

JST *backpropagation* dapat memprediksi curah hujan dengan sangat baik dengan menggunakan persamaan $y=target+5.9$. Pada proses pengujian, koefisien korelasi yang dihasilkan sebesar 0,79544 dengan nilai MSE 0,25528.

Nilai koefisien korelasi dan nilai MSE yang dihasilkan pada proses pengujian menunjukkan bahwa jaringan syaraf tiruan propagasi balik cukup baik untuk memprediksi curah hujan. Kedua nilai tersebut dapat ditingkatkan performansinya dengan cara memperbanyak data latih serta mengubah-ubah parameter yang mempengaruhi performansi jaringan seperti error goal, jumlah epoch, arsitektur jaringan, jenis fungsi aktivasi, dll.

Dari hasil peramalan curah hujan Kota Palembang tahun 2017 (Gambar 2), menunjukkan bahwa terdapat satu puncak musun hujan di bulan September sebesar 482,02 mm dan satu puncak musun kering di bulan Juni sebesar 56,96 mm. Hasil peramalan tersebut cocok didemonstrasikan di wilayah Kota Palembang. Dimana, wilayah ini terletak di zona monsun yang memiliki tipikal satu puncak hujan dan satu puncak kemarau (Aldrian & Susanto 2003).



Gambar 2. Peramalan curah hujan kota Palembang tahun 2017

SIMPULAN

Model JST *backpropagation* dapat digunakan sebagai algoritma prediksi curah hujan dan menghasilkan akurasi peramalan yang baik. Hasil peramalan ini cocok didemonstrasikan di wilayah Kota Palembang, karena wilayah ini terletak di zona monsun yang memiliki tipikal satu puncak hujan dan satu puncak kemarau.

UCAPAN TERIMA KASIH

Penulis ucapkan terima kasih kepada Stasiun Klimatologi Kota Palembang dan

Universitas Sriwijaya dalam menyediakan data serta dukungan dalam menyelesaikan penelitian ini.

DAFTAR PUSTAKA

- Aldrian E & Susanto RD. 2003. Identification of three dominant rainfall regions within Indonesia and their relationship to sea surface temperature. *Int J Climatol* 23: 1435-1452.
- Chen F W & Liu CW. 2012. Estimation of the Spatial Rainfall Distribution Using Inverse Distance Weighting (IDW) in the Middle of Taiwan. *Paddy Water Environ.* 10(3): 209-222
- Fausett L. 1994. *Fundamental of Neural Network: Architecture, Algorithms, and Application*, New Jersey: Prentice Hall. Hal: 221.
- French MN, Krajewski WF, Cuykendall RR. 1992. Rainfall forecasting in space and time using a neural network. *J Hydrol.* 137: 1-31.
- Garay VG, Irigoyen E, Artaza F. 2010. *GENNET-Toolbox: An Evolving Genetic Algorithm for Neural Network Training*. Edited by R.Goebel et al., HAIS International Conference, Part II, LNAI 6076. pp.368-375.
- Kajornit J, Wong KW, Fung CC, Ong YS. 2014. *An Integrated Intelligent Technique For Monthly Rainfall Time Series Prediction*. IEEE International Conference on Fuzzy Systems, IEEE. 1632-1639.
- Kustiyo A, Buono A, Apriyanti N. 2006. Optimasi Jaringan Syaraf Tiruan dengan Algoritma Genetika untuk Peramalan Curah Hujan. *Jurnal Ilmiah Ilmu Komputer.* 4(1).
- May W. 2004. Variability and extremes of daily rainfall during the Indian summer monsoon in the period 1901-1989. *Glob Planet Change* 44: 83-105.
- Mislan, Havaluddin, S.Hardwinarto, Sumaryono, & M. Aipassa. 2015. Rainfall Monthly Prediction Based on Artificial Neural Network: A Case Study in Tenggarong Station, East Kalimantan-Indonesia. *Procedia Comput Sci* 59:142-151
- Narulita I. 2016. Distribusi spasial dan temporal curah hujan di das cerucuk, pulau belitung. *Ris Geo Tam.* 26(2): 141-154
- Patel J & Parekh F. 2014. Forecasting Rainfall Using Adaptive NeuroFuzzy Inference System (ANFIS). *Int J Appl Innov Eng Manag.* 3(6): 262-269.
- Prabawadhani DR, Harsono B, Seto TH, Prayogo MBR. 2016. Karakteristik temporal dan spasial curah hujan penyebab banjir di wilayah dki jakarta dan sekitarnya. *Jurnal Sains dan Teknologi Modifikasi Cuaca.* 17(1): 21-24

- Richard M & Rao G. 2014. Artificial neural networks in temporal and spatial variability studies and prediction of rainfall. *J Hydraul Eng.* 20(1): 1-6
- Saxena A, Verma N, Tripathi KC. 2014. Neuro-Genetic Hybrid Approach for Rainfall Forecasting. *IJCSIT.* 5(2): 1291-1295
- Sharma A & Nijhawan G. 2015. Rainfall Prediction Using Neural Network. *IJCST.* 3(3): 65-69
- Wilks DS. 1998. Multi-site generalization of a daily stochastic precipitation generation model. *J Hydrol.* 210: 178-191.