

Pengaruh Dataset Ekuatorial Terhadap Akurasi Evolving Neural Network Prediksi Curah Hujan

Liliana Swastina¹⁾, Bambang Lareno²⁾

Teknik Informatika, STMIK Indonesia Banjarmasin

Jln. Pangeran Hidayatullah – Banua Anyar

e-mail: lilisera@gmail.com, blareno@gmail.com

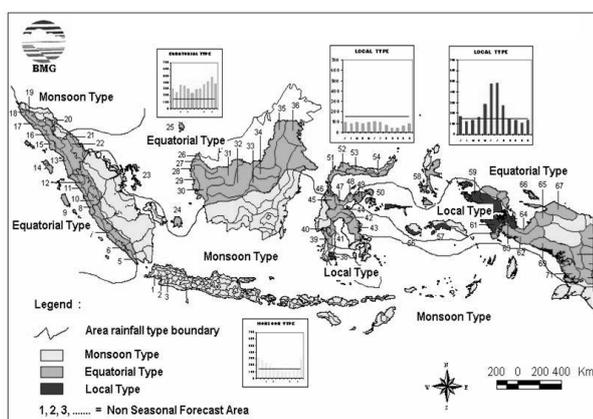
Abstrak

Terdapat beberapa penelitian berkait prediksi curah hujan. Namun beberapa pendekatan belum teruji pada pola hujan berbeda. Secara umum curah hujan di Indonesia terbagi menjadi 3 pola. Dengan demikian ada ruang untuk menguji pengaruh pola hujan terhadap akurasi prediksi. Penelitian ini berfokus pada menguji bagaimana pengaruh dataset pola hujan terhadap akurasi prediksi evolving neural network curah hujan. Jenis pola yang diuji adalah pola ekuatorial dan monsun. Penelitian dilakukan dengan metode penelitian eksperimen. Dari hasil penelitian dapat dinyatakan bahwa pada pola ekuatorial hasil akurasi ENN konsisten lebih baik dari BPNN. Sedangkan pada pola monsun, hasil akurasi ENN secara umum lebih baik dari akurasi BPNN. Selain itu pada pola ekuatorial, hasil akurasi ENN lebih rendah dari akurasi pada pola monsun. Pola ekuatorial berpengaruh relatif negatif bila dibanding dengan pola monsun terhadap ENN.

Kata kunci: jaringan syaraf tiruan, prediksi rentet waktu, algoritma genetika

1. Pendahuluan

Indonesia secara umum memiliki tiga tipe pola curah hujan: monsun, ekuatorial dan lokal (gambar 1). Monsun adalah pola curah hujan dengan satu puncak, sementara ekuatorial adalah pola curah hujan dengan dua puncak, sedangkan lokal adalah pola curah hujan dengan satu puncak dengan bentuk berlawanan dengan monsun[1].



Gambar 1. Model umum tipe pola curah hujan

BMKG telah mengupayakan pendekatan dengan statistik, wavelet, anfis dan Tisean dalam bentuk aplikasi HyBMKG untuk prakiraan curah hujan[1]. Namun ketika diuji oleh Irman Sonjaya, dkk[2], untuk tipe monsun, ekuatorial dan lokal, pendekatan aplikasi tersebut hanya memberikan hasil prakiraan yang cukup baik dan hanya untuk tipe monsun. Selain itu tidak melibatkan pengaruh fitur suhu dan kelembaban dalam pengenalan pola curah hujan. Muh.Ishak Gumarang, dkk[3], menggunakan *Backpropagation Neural Network* (BPNN) untuk mengestimasi curah hujan, suhu dan kelembaban di kota Pontianak yang bertipe ekuatorial, tetapi tidak memperhitungkan suhu dan kelembaban sebagai fitur untuk estimasi curah hujan. Sementara Rahmat Hidayat, dkk[4] menguji pengaruh fitur suhu dan kelembaban terhadap akurasi BPNN untuk curah hujan di Kalimantan Selatan, yang bertipe monsun. Mereka menyatakan fitur kelembaban berpengaruh positif secara konsisten terhadap akurasi BPNN. Hasil ini belum teruji untuk tipe ekuatorial.

Di sisi yang lain, berdasar optimasi yang digunakan, salah satu pendekatan untuk menetapkan nilai bobot pada *neural network* adalah optimasi melalui algoritma genetika. Algoritma ini, selain Pei-Chann Chang and Yen-Wen Wang[5] untuk perhitungan produksi papan PCB, juga telah diterapkan oleh Li Chungui, Xu Shu'an, dan Wen Xin untuk prediksi arus lalu lintas[6]. Ganji Huang dan Lingzhi Wang melatih *neural network* untuk peramalan hidrologi[7]. Ketiga penelitian tersebut mengusulkan *neural network* yang berevolusi. Model ini menyerap beberapa manfaat dari algoritma genetika dan *neural network*. Hasil perbandingan menunjukkan bahwa model yang disarankan dapat meningkatkan akurasi prediksi. Penelitian Liliana, dkk[8] mengkonfirmasi peningkatan dengan pendekatan tersebut. ENN memberikan hasil lebih baik dibanding BPNN. Ketika fitur kelembaban juga diterapkan pada pendekatan ini, hasilnya juga lebih baik dibanding BPNN[9]. Meski demikian, hasil ini belum teruji untuk tipe ekuatorial.

Berdasarkan hal-hal tersebut, ada ruang untuk meneliti pengaruh tipe hujan ekuatorial akurasi algoritma *evolving neural network* dengan atau tanpa fitur kelembaban. Dengan demikian, penelitian ini berfokus pada: Menguji pengaruh tipe hujan ekuatorial terhadap akurasi algoritma *evolving neural network*.

2. Metode Penelitian

Penelitian ini memakai data metode penelitian eksperimen komparasi, yang terdiri: (1)Metode Pengumpulan data dan pengolahan data awal, (2)Metode yang diusulkan, (3)Eksperimen dan pengujian model, (4)Hasil eksperimen dan (5)Evaluasi dan validasi hasil.

2.1. Pengumpulan Data

Penelitian ini memakai data curah hujan dan kelembaban yang didapatkan dari BMKG – Stasiun Klimatologi Syamsudinoor, Kalimantan Selatan (Monsunal) dan Stasiun Klimatologi Supadio, Kalimantan Barat (Ekuatorial). Data yang dibutuhkan dalam penelitian ini adalah: Data sekunder berupa data curah hujan, kelembaban dan suhu bulanan 2001 – 2010. Data primer berupa data hasil komputasi algoritma prediksi.

2.2. Pengolahan Data Awal

Data yang didapatkan dari instansi terkait masih berupa data yang terdiri dari berbagai parameter, sehingga harus direkapitulasi terlebih dahulu. Rekapitulasi tersebut dilakukan dengan memperhatikan kebutuhan. Sehingga data hasil proses ini adalah data dengan atribut: Waktu, Curah hujan, dan Kelembaban. Tiap baris data adalah data setiap bulan selama 10 tahun, sehingga tersedia 120 baris data. Data yang digunakan kemudian ditransformasi sehingga berada dalam rentang 0-1, transformasi ini tidak mengubah pola data, hanya besarnya saja.

2.3. Metode/Model yang diusulkan

Metode yang digunakan adalah perbandingan antara akurasi yang dihasilkan oleh pelatihan dengan data curah hujan bulanan, baik monsunal maupun ekuatorial. Pelatihan data menggunakan Algoritma *Evolving Neural Network* (ENN) dan Algoritma *Backpropagation Neural Network* (BPNN).

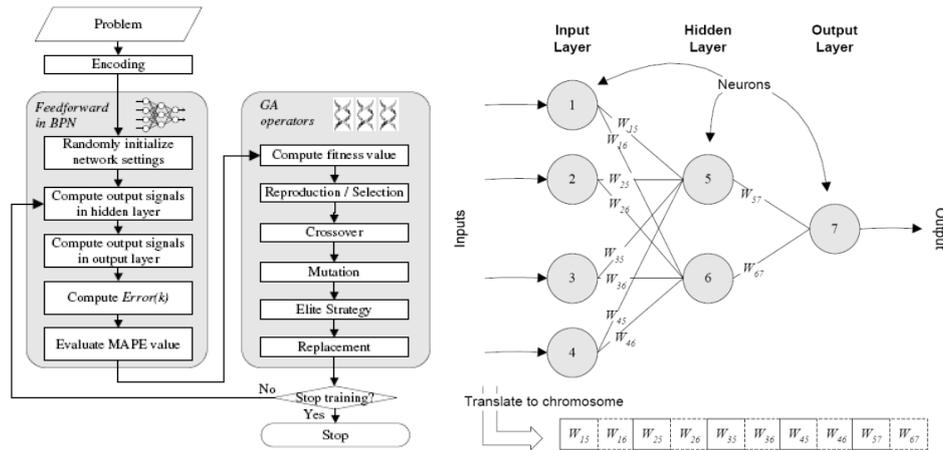
2.3.1. Backpropagation Neural Network (BPNN)

BPNN diaplikasikan menggunakan Matlab 2009b dengan algoritma learning yang berbeda: Algoritma *Learning Levenberg Marquardt* (trainlm) dan Algoritma *Learning Scaled Conjugate Gradient* (trainscg). Algoritma BPNN akan diterapkan pada data curah hujan bulanan melalui suatu model simulasi. Evaluasi dilakukan dengan mengamati hasil prediksi dibandingkan dengan data sebenarnya.

2.3.2. Evolving Neural Network

Evolving Neural Network adalah sebuah cara pembobotan antar neuron pada *layer* berbeda dengan menggunakan prinsip algoritma genetika (GA). Gambar 2 menjelaskan struktur algoritma ENN[5][10].

Setiap gen mempresentasikan bobot antara dua neuron di *layer* berbeda. Sebuah kromosom dibangun dari rangkaian gen yang diilustrasikan dalam gambar 2. Contoh, gen pertama dalam untaian kromosom adalah W15, yaitu bobot yang menghubungkan neuron 1 dan neuron 5. Gen kedua adalah W16, yaitu bobot penghubung neuron 1 dan 6. Demikian seterusnya.



Gambar 2. Struktur ENN (kiri), Proses encoding kromosom (kanan)

2.4. Eksperimen dan Pengujian Model/Metode

Data 2001-2008 (96 data) akan dipergunakan sebagai data *training* dan data 2009-2010 (24 data) akan digunakan sebagai data *checking*. Baik monsunal maupun ekuatorial. Untuk mengevaluasi akurasi dan peramalan kinerja model berbeda, penelitian ini mengadopsi tiga indeks evaluasi: *Percentage Error* (MAPE), *Root Mean Square Error* (RMSE) dan *Mean Absolute Deviation* (MAD).

Pengukuran kinerja dilakukan dengan menghitung rata-rata *error* yang terjadi melalui besaran RMSE, MAD dan MAPE. Semakin kecil nilai RMSE, MAD dan MAPE, menyatakan semakin dekat nilai prediksi dengan nilai sebenarnya.

2.5. Evaluasi dan Validasi

Evaluasi dilakukan dengan mengamati hasil prediksi menggunakan algoritma BPNN dan ENN. Validasi dilakukan dengan mengukur hasil prediksi dibandingkan dengan data asal, sehingga diketahui akurasi masing-masing algoritma. Selain itu, membandingkan hasil antara akurasi yang dihasilkan data monsunal dengan ekuatorial. Dengan demikian dapat diketahui pengaruh tipe pola hujan terhadap akurasi algoritma neural network dalam memprediksi curah hujan.

3. Hasil dan Pembahasan

3.1. Hasil Pengujian Model/Metode

3.1.1. BPNN

Dengan menggunakan Matlab, proses pengujian struktur BPNN dilakukan. Hasilnya uji untuk masing-masing struktur ditampilkan dalam tabel 1.

Tabel 1. Hasil Pengujian Struktur

Arsitektur FFNN			BPNN (RMSE) Monsunal	BPNN (RMSE) Ekuatorial
Input	Hidden-1	Out	Lm	Seg
4	2	1	67,0963	92,1555
4	4	1	85,7207	77,4082
4	6	1	83,0223	79,0237
6	2	1	94,5886	84,4312
6	4	1	73,5925	95,7929
6	6	1	85,0709	97,9180
6	12	1	77,2930	81,4687
12	2	1	98,9822	89,8655
12	6	1	75,2210	86,7654
12	12	1	84,3001	84,5655

Berdasarkan hasil uji struktur BPNN pada tabel 1, terlihat bahwa nilai terkecil masing-masing terdapat pada struktur 4-2-1 dan 4-4-1. Sedangkan ekuatorial, 4-2-1 dan 4-6-1. Karena nilai lm dan scg 4-6-1 untuk tidak terpaut jauh dengan 4-2-1, maka struktur 4-2-1 dan 4-4-1 yang dipakai untuk pengujian lebih lanjut.

Tabel 2. Hasil Pengujian BPNN Dengan dan Tanpa Fitur Kelembaban (Monsunal)

Ars.	RMSE		MAPE		MAD	
	Lm	Scg	Lm	Scg	Lm	Scg
CH tanpa fitur kelembaban (CH)						
4-2-1	30,04	38,32	11,62	24,83	26,52	30,56
4-4-1	26,1	39,76	18,33	18,61	23,28	31,83
CH Dengan fitur kelembaban (CHK)						
4-2-1	26,24	35,45	11,72	22,44	22,46	29,84
4-4-1	25,74	39,66	16,75	19,97	22,69	31,4
Perbaikan						
	12,65	7,49	-0,10	2,39	15,31	2,36
%	1,38	0,25	1,58	-1,36	2,53	1,35

Data Uji dengan fitur kelembaban pada struktur 4-2-1 dan 4-4-1, menghasilkan RMSE: 35,45 dan 25,74; MAPE: 11,72 % dan 19,97 %; sedangkan MAD: 29,84 dan 22,69. Perbaikan akurasi BPNN berkisar -1,36% sampai 15,31% (Tabel 2), dengan anomali pada parameter MAPE yang menunjukkan penurunan akurasi (pengaruh negatif).

Tabel 3. Hasil Pengujian BPNN Dengan dan Tanpa Fitur Kelembaban (Ekuatorial)

Ars.	RMSE		MAPE		MAD	
	Lm	Scg	Lm	Scg	Lm	Scg
CH tanpa fitur kelembaban (CH)						
4-2-1	47,71	45,13	15,5	15	41,58	39,54
4-4-1	48,64	42,32	15,31	13,93	42,64	34,66
CH Dengan fitur kelembaban (CHK)						
4-2-1	45,78	39,87	14,15	13,11	39,45	33,72
4-4-1	47,33	40,71	14,53	13,65	40,56	32,99
Perbaikan						
	4,05	11,66	1,35	1,89	5,12	14,72
%	2,69	3,80	0,78	0,28	4,88	4,82

Data Uji dengan fitur pada struktur 4-2-1 dan 4-4-1, menghasilkan RMSE: 45,78 dan 39,87; MAPE: 14,15 % dan 13,65 %; sedangkan MAD: 39,45 dan 32,99. Perbaikan akurasi BPNN berkisar 0,28% sampai 14,15% (Tabel 3).

Secara umum, akurasi BPNN pada pola monsunal lebih baik dari pola ekuatorial. Perbaikan akurasi karena pengaruh fitur kelembaban lebih tinggi pada pola ekuatorial 4-4-1, sedangkan pada 4-2-1, perbedaan tersebut lebih tipis. Perbaikan akurasi terutama terlihat pada RMSE-scg dan MAD-scg.

3.1.2 Evolutionary Neural Network (ENN)

Lima parameter penting algoritma genetika menurut Suyanto[10], yaitu: tipe *crossover* dan nilainya, tipe mutasi dan nilainya serta tipe seleksi. Dalam pengujian akan digunakan ukuran populasi 50 sebagai populasi awal untuk percobaan. Dengan data curah hujan sebagai *input* dan *target*, dilakukan tiga kali percobaan algoritma genetika (tanpa *neural network*) dengan populasi 50, dan parameter masing-masing operator di-*set* sesuai level rencana. Hasilnya, operator GA: *crossover* dua titik, mutasi satu titik, seleksi elitis, laju *crossover* = 0.8, dan laju mutasi = 0.3. Selanjutnya untuk pengujian, struktur NN yang dipergunakan adalah 4-2-1 dan 4-4-1. Hasilnya pengujian di tunjukkan Tabel 4 dan Tabel 5.

Tabel 4. Hasil Pengujian ENN Dengan dan Tanpa Fitur Kelembaban (Monsunal)

Ars.	RMSE	MAPE	MAD
CH tanpa fitur kelembaban (CH)			
4-2-1	27,62	12,37	24,61
4-4-1	26,86	16,73	25,09
CH Dengan fitur kelembaban (CHK)			
4-2-1	23,80	11,55	21,83
4-4-1	25,14	11,86	22,95
Perbaikan			
	13,83	0,82	11,30
%	6,40	4,87	8,53

Pada tabel 4, Pengujian dengan fitur kelembaban menghasilkan RMSE: 23,80 dan 25,14; MAPE 11,55% dan 11,85%; dan MAD = 21,83 dan 22,95. Peningkatan akurasi berkisar 0,82% - 13,83%.

Tabel 5. Hasil Pengujian ENN Dengan dan Tanpa Fitur Kelembaban (Ekuatorial)

Ars.	RMSE	MAPE	MAD
CH tanpa fitur kelembaban (CH)			
4-2-1	35,22	11,94	31,62
4-4-1	36,19	12,37	32,91
CH Dengan fitur kelembaban (CHK)			
4-2-1	33,70	10,83	29,07
4-4-1	35,63	11,44	30,73
Perbaikan			
%	4,32	1,11	8,06
	1,55	0,93	6,59

Pada tabel 5, pengujian dengan fitur kelembaban menghasilkan RMSE: 33,70 dan 35,63; MAPE 10,83% dan 11,44%; dan MAD = 29,07 dan 30,73. Peningkatan akurasi berkisar 0,93% - 8,06%.

Secara umum, akurasi ENN pada pola musonal lebih baik dari pola ekuatorial. Perbaikan akurasi karena pengaruh fitur kelembaban lebih tinggi pada pola musonal.

3.2. Evaluasi dan Validasi Hasil

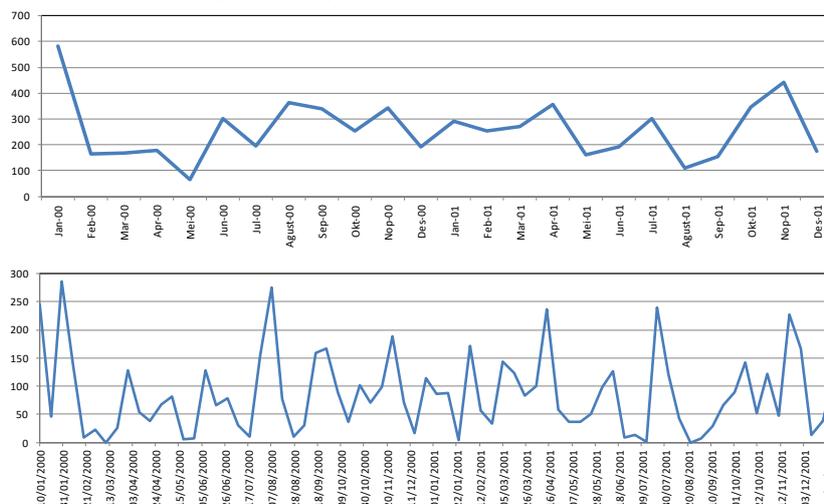
Pada Tabel 6 terlihat bahwa perbaikan akurasi BPNN pada pola ekuatorial lebih baik dari musonal, sementara akurasi ENN mengalami perbaikan lebih tinggi pada pola musonal.

Tabel 6. Persentase Perbaikan Akurasi

Pola	Ars.	RMSE	MAPE	MAD	Rata-rata peningkatan
BPNN					
Ekuatorial	4-2-1	7,85	1,62	9,92	6,46
	4-4-1	3,25	0,53	4,85	2,88
Monsunal	4-2-1	10,07	1,145	8,83	6,68
	4-4-1	0,82	0,11	1,94	0,96
ENN					
Ekuatorial	4-2-1	4,32	1,11	8,06	4,50
	4-4-1	1,55	0,93	6,59	3,02
Monsunal	4-2-1	13,83	0,82	11,30	8,65
	4-4-1	6,40	4,87	8,53	6,60

Selain itu, berdasarkan Tabel 1 dan 2, pada pola musonal, hasil akurasi ENN secara umum lebih baik dari akurasi BPNN. Sedangkan pada pola ekuatorial (Tabel 3 dan 4), hasil akurasi ENN konsisten lebih baik dari BPNN.

Hasil ini berlaku bagi data bulanan, sedangkan untuk data harian atau data dasarian, hasilnya mungkin berbeda. Karena pada data harian atau dasarian, kurva lebih fluktuatif, sementara pada data bulanan, kurva sudah lebih halus (Gambar 3)



Gambar 3. Besaran hujan bulanan (atas) dan hujan dasarian (bawah) periode 2000-2001

4. Simpulan

Dari hasil penelitian yang dilakukan dari tahap awal hingga pengujian, dan pengukuran, dapat disimpulkan:

1. Pada pola ekuatorial hasil akurasi ENN konsisten lebih baik dari BPNN. Sedangkan pada pola monsunial, hasil akurasi ENN secara umum lebih baik dari akurasi BPNN.
2. Pada pola ekuatorial, hasil akurasi ENN lebih rendah dari akurasi pada pola monsunial. Pola ekuatorial berpengaruh relatif negatif bila dibanding dengan pola monsunial terhadap ENN.
3. Fitur kelembaban berpengaruh positif terhadap peningkatan akurasi ENN, baik pada pola monsunial maupun ekuatorial.

Daftar Pustaka

- [1] Kadarsah, Sasmita A. *Standardisasi Metadata Klimatologi Dalam Penelitian Perubahan Iklim Di Indonesia*. In *Prosiding PPI Standardisasi 2010*; 2010; Banjarmasin. p. 1-18.
- [2] Sonjaya I, Kurniawan T, Munir M, Wiratri M, Khairullah. Uji Aplikasi HyBMG Versi 2.0 Untuk Prakiraan Curah Hujan Pola Monsunal Ekuatorial dan Lokal. *Buletin Meteorologi Klimatologi dan Geofisika*. 2009 September; 5(3): p. 323-339.
- [3] Gumarang MI, Andromeda L, Nugroho BS. Estimasi Curah Hujan, Suhu dan Kelembaban Udara Dengan Menggunakan Jaringan Syaraf Tiruan Backpropagation. *Jurnal Aplikasi Fisika*. 2009 Februari; V(1): p. 54-61.
- [4] Hidayat R, Lareno B, Muklis IF. *Pengaruh Fitur Suhu Dan Kelembaban Terhadap Akurasi Neural Network Prakiraan Curah Hujan*. In *Konferensi Nasional Sistem Informasi 2015 Universitas Klabat*; 2015; Manado. p. 199-203.
- [5] Chang PC, Wang YW, Tsai CY. Evolving Neural Network for Printed Circuit Board Sales. *Expert System Application*. 2005; 29(1): p. 83-92.
- [6] Chungui L, Shu'an X, Xin W. *Traffic Flow forecasting Algorithm Using Simulated Annealing Genetic BP Network*. In *2010 International Conference on Measuring Technology and Mechatronics Automation*; 2010. p. 1043-1046.
- [7] Huang G, Wang L. *Hybrid Neural Network Models for Hydrologic Time Series Forecasting Based on Genetic Algorithm*. In *2011 Fourth International Joint Conference on Computational Sciences and Optimization*; 2011. p. 1347-1350.
- [8] Swastina L, Cipta SP, Lareno B. *Penerapan Algoritma Evolving Neural Network Untuk Prediksi Curah Hujan*. In *Konferensi Nasional Sistem & Informatika*; 2014; Bali. p. 802-806.
- [9] Lareno B, Swastina L, Tan F. *Pengaruh Fitur Kelembaban Terhadap Akurasi Algoritma Evolving Neural network Prediksi Curah Hujan*. In *Seminar Nasional Teknologi Informasi dan Multimedia 2015 STMIK AMIKOM*; 2015; Yogyakarta. p. 3.8-49 - 3.8.54, ISSN : 2302-3805.
- [10] Suyanto. *Evolutionary Computing: Komputasi Berbasis 'Evolusi' dan 'Genetika'* Bandung: Informatika; 2008.