

Pengaruh Jenis Pola Hujan Indonesia Terhadap Akurasi Prediksi Neural Network Curah Hujan

Bambang Lareno¹⁾, Liliana Swastina²⁾

Teknik Informatika, STMIK Indonesia Banjarmasin

Jln. Pangeran Hidayatullah – Banua Anyar

e-mail: [1\)blareno@gmail.com](mailto:blareno@gmail.com), [2\)lilisera@gmail.com](mailto:lilisera@gmail.com)

Abstrak

Pola hujan daerah di Indonesia berbeda-beda. Secara umum terbagi menjadi tiga jenis pola. Dengan demikian ada ruang untuk menguji pengaruh pola hujan terhadap akurasi prediksi. Sehingga penelitian ini berfokus pada menguji bagaimana pengaruh jenis pola hujan terhadap akurasi prediksi curah hujan algoritma berbasis neural network. Jenis pola yang diuji adalah pola ekuatorial dan musonal. Penelitian dilakukan dengan metode penelitian eksperimen. Dari hasil penelitian dapat disimpulkan bahwa dapat dinyatakan bahwa pola hujan berpengaruh terhadap akurasi prediksi algoritma neural network besaran curah hujan. Hasilnya, pada parameter RMSE dan MAD, maka akurasi neural network pada data musonal lebih baik daripada data ekuatorial. Sedangkan jika menggunakan parameter MAPE, akurasi neural network dengan data ekuatorial lebih baik dari musonal. Dengan demikian diharapkan masing-masing wilayah menyesuaikan model prediksi dengan pola hujan di daerahnya, sehingga solusi yang dihasilkan lebih efektif.

Kata kunci: jaringan syaraf tiruan, prediksi rentet waktu, levenberg marquardt, scaled conjugate gradient

1. Pendahuluan

Indonesia secara umum memiliki tiga pola curah hujan: musonal, ekuatorial dan lokal (gambar 1). Musonal adalah pola curah hujan dengan satu puncak, sementara ekuatorial adalah pola curah hujan dengan batas yang tidak jelas antara musim kemarau dan hujan, atau bisa disebut hujan sepanjang tahun dengan dua puncak curah hujan. Sedangkan lokal adalah pola curah hujan dengan satu puncak dengan bentuk berlawanan dengan musonal [1].



Gambar 1. Model umum 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 musonal, ekuatorial dan lokal, pendekatan aplikasi tersebut hanya memberikan hasil prakiraan yang cukup baik dan hanya untuk jenis musonal. Muh.Ishak Gumarang, dkk[3], menggunakan *Backpropagation Neural Network* (BPNN) untuk mengestimasi curah hujan, suhu dan kelembaban di kota Pontianak yang berjenis ekuatorial, tetapi tidak membandingkannya dengan pola musonal. Sementara Rahmat Hidayat, dkk[4] menguji pengaruh fitur suhu dan kelembaban terhadap akurasi BPNN untuk curah hujan di Kalimantan Selatan, yang berjenis musonal, namun belum teruji untuk jenis ekuatorial.

Berdasarkan hal-hal tersebut, ada ruang untuk meneliti pengaruh tipe hujan ekuatorial dan monsunal terhadap akurasi algoritma *neural network*. Dengan demikian, penelitian ini berfokus pada: Menguji pengaruh tipe hujan ekuatorial dan monsunal terhadap akurasi algoritma *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 Banjarmasin, Kalimantan Selatan (Monsunal) dan Stasiun Klimatologi Supadio, Pontianak, 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. Berdasarkan *related research* pada pendahuluan, fitur kelembaban lebih baik dari fitur suhu. Sehingga data hasil proses ini adalah data dengan atribut: Waktu, Curah hujan, Kelembaban dan Tipe Hujan. Tiap baris data adalah data setiap bulan selama 10 tahun, sehingga tersedia 120 baris data. Total baris data bergantung dengan struktur yang digunakan. Data yang digunakan kemudian ditransformasi sehingga berada dalam rentang 0-1, untuk fungsi aktivasi sigmoid. 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 *Backpropagation Neural Network* (BPNN). *Backpropagation* merupakan algoritma pembelajaran yang terawasi (*supervised*) dan biasanya digunakan oleh *perceptron* dengan banyak lapisan untuk menghitung bobot-bobot yang terhubung dengan neuron-neuron yang ada pada *hidden layer*. Algoritma *backpropagation* menggunakan *error output* untuk mengubah nilai bobot-bobotnya dalam arah mundur (*backward*). Untuk mendapatkan *error* ini, tahap perambatan maju (*forward propagation*) harus dikerjakan lebih dulu. Pada saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi yang dapat dideferensialkan, seperti sigmoid[5].

BPNN diaplikasikan menggunakan Matlab 2009b dengan algoritma *learning* yang berbeda: Algoritma *Learning Levenberg Marquardt* (*trainlm*) dan Algoritma *Learning Scaled Conjugate Gradient* (*trainscg*)[6], sebagai pembanding. Algoritma BPNN akan diterapkan pada data curah hujan bulanan melalui suatu model simulasi. Evaluasi dilakukan dengan mengamati hasil prediksi dibandingkan dengan data sebenarnya.

2.4. Eksperimen dan Pengujian Model/Metode

Data P1 sampai P90 (90 data) akan dipergunakan sebagai data *training* dan P91-P108 (18 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).

Root Mean Square Error adalah penjumlahan kuadrat *error* atau selisih antara nilai sebenarnya (aktual) dan nilai prediksi, kemudian membagi jumlah tersebut dengan banyaknya waktu data peramalan dan kemudian menarik akarnya[7], atau dapat dirumuskan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum(Aktual - Prediksi)^2}{n}} \dots\dots\dots(1)$$

Mean Absolute Deviation adalah nilai absolut dari penyimpangan data terhadap *mean*[8], atau dapat dirumuskan sebagai berikut:

$$MAD = \frac{\sum|Aktual - Prediksi|}{n} \dots\dots\dots(2)$$

Mean Absolute Percentage Error adalah nilai *absolute* dari persentase *error* data terhadap *mean*[9], atau dapat dirumuskan sebagai berikut:

$$MAPE = \frac{\sum \frac{|Aktual - Prediksi|}{Aktual} \times 100}{n} \dots\dots\dots(3)$$

Pengukuran kinerja dilakukan dengan menghitung rata-rata error yang terjadi melalui besaran RMSE, MAPE dan MAD. Semakin kecil nilai RMSE, MAPE dan MAD, 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 musonal dengan ekuatorial. Dengan demikian dapat diketahui pengaruh jenis 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

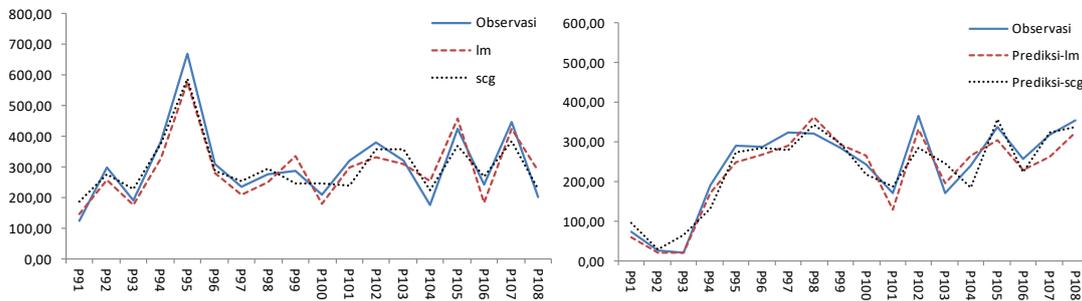
Arsitektur FFNN			BPNN (RMSE) Monsunal		BPNN (RMSE) Ekuatorial	
Input	Hidden-1	Out	Lm	Scg	Lm	Scg
4	2	1	67,0963	92,1555	75,0613	79,6374
4	4	1	85,7207	77,4082	86,9167	82,9245
4	6	1	83,0223	79,0237	85,0824	79,2668
6	2	1	94,5886	84,4312	96,0289	89,4540
6	4	1	73,5925	95,7929	79,2709	93,3985
6	6	1	85,0709	97,9180	86,5090	93,0210
6	12	1	77,2930	81,4687	85,4206	87,1265
12	2	1	98,9822	89,8655	92,5943	91,7814
12	6	1	75,2210	86,7654	88,5740	90,4159
12	12	1	84,3001	84,5655	85,4643	87,6559

Berdasarkan hasil uji struktur BPNN musonal 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 yang dipakai untuk pengujian lebih lanjut.

Tabel 2. Hasil Pengujian

Pola	Ekuatorial Observasi	Prediksi		Monsunal Observasi	Prediksi	
		lm	scg		lm	scg
P91	121,90	147,34	184,86	73,00	60,48	94,25
P92	299,50	258,61	276,13	24,60	21,58	28,31
P93	189,50	174,76	228,05	20,90	19,28	64,43
P94	381,90	326,58	376,65	189,20	169,37	133,07
P95	668,00	576,29	589,23	291,70	248,41	274,91
P96	309,20	279,00	288,06	287,40	268,28	285,88
P97	233,50	209,44	252,20	324,30	290,74	280,12
P98	274,10	249,70	294,10	320,60	361,49	343,42
P99	286,10	334,92	246,07	285,10	294,04	296,01
P100	210,20	179,22	245,26	243,00	265,23	217,14
P101	320,80	297,12	236,86	171,00	130,24	186,73
P102	381,20	331,74	359,26	365,70	331,98	283,64
P103	320,00	310,14	357,22	171,70	195,57	245,64
P104	174,00	254,31	225,68	240,40	263,96	183,58
P105	423,70	459,11	367,64	338,20	303,17	356,62
P106	242,10	183,88	269,57	256,50	227,80	224,73
P107	447,90	425,81	381,75	317,50	261,16	325,11
P108	202,60	285,41	226,04	354,70	324,37	337,72

Untuk mendapatkan RMSE yang tervalidasi, data pisah menjadi 2 bagian. Data P1 sampai P89 untuk data pelatihan (data *training*), sedangkan data P90 sampai P108 untuk *checking*. Hasilnya ditampilkan pada Tabel 2 dan Gambar 2.



Gambar 2. Perbandingan hasil observasi dan prediksi data ekuatorial (kiri), monsonal (kanan)

3.2. Evaluasi dan Validasi Hasil

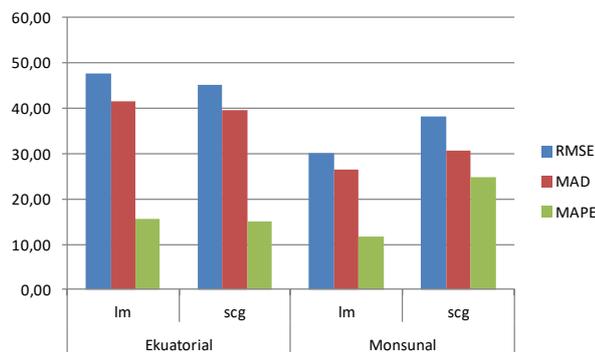
Data pada Tabel 2 dievaluasi dengan parameter RMSE, MAD dan MAPE, hasilnya ditampilkan pada Tabel 3.

Tabel 3. Nilai Parameter Pengujian

Parameter	Ekuatorial		Monsonal	
	lm	scg	lm	scg
RMSE	47,71	45,13	30,04	38,32
MAD	41,58	39,54	26,52	30,56
MAPE	15,50	15,00	11,62	24,83

Pada Tabel 3, terlihat bahwa perhitungan untuk pola ekuatorial menghasilkan RMSE-lm 47,71 dan RMSE-scg 45,13. Sedangkan pola monsonal menghasilkan RMSE-lm 30,04 dan RMSE-scg 38,32. Berdasar parameter ini, akurasi dengan pola monsonal lebih baik dari pola ekuatorial. Untuk parameter MAD, terlihat bahwa perhitungan untuk pola ekuatorial menghasilkan lm 41,48 dan scg 39,54. Sedangkan pola monsonal menghasilkan lm 26,52 dan scg 30,56. Berdasar parameter MAD, akurasi dengan pola monsonal lebih baik dari pola ekuatorial. Namun untuk parameter MAPE, akurasi dengan pola ekuatorial lebih baik dari pola monsonal, dengan ekuatorial sekitar 15%, sedangkan monsonal 11,62%-24,83%.

Selain itu, untuk pola ekuatorial, *learning* scg lebih baik dari lm, sedangkan untuk pola monsonal, lm lebih baik dari scg.



Gambar 3. Perbandingan Nilai Parameter

Jadi jika hanya berpatokan pada parameter RMSE (termasuk juga MSE) dan MAD, maka akurasi *neural network* pada pola monsonal lebih baik daripada pola ekuatorial. Sedangkan jika menggunakan parameter MAPE, akurasi *neural network* dengan pola ekuatorial lebih baik dari monsonal

(Gambar 3). Dengan demikian, tingkat akurasi *neural network* untuk curah hujan pada suatu wilayah belum tentu sama pada wilayah lainnya, apalagi jika menggunakan parameter yang berbeda.

Selain itu, berapa hal perlu disampaikan untuk pengujian yang lebih baik, yaitu: perlu data tambahan dari wilayah lain yang memiliki pola hujan sama sebagai pembanding, di samping pengujian untuk jenis pola hujan lokal. Selain itu, perlu data hujan yang lebih banyak sehingga masing-masing algoritma mendapatkan pelatihan yang cukup untuk mengenali pola hujan.

4. Simpulan

Dari hasil penelitian yang dilakukan dari tahap awal hingga pengujian, dan pengukuran, dapat disimpulkan bahwa jenis pola hujan berpengaruh terhadap akurasi *neural network*. Secara umum akurasi *neural network* untuk pola musonial lebih baik dari pola ekuatorial. Berdasar parameter RMSE dan MAD, akurasi *neural network* pada data musonial lebih baik daripada data ekuatorial. Sedangkan jika menggunakan parameter MAPE, akurasi *neural network* dengan data ekuatorial lebih baik dari musonial. Dengan demikian diharapkan masing-masing wilayah dapat menyesuaikan model prediksi *neural network* dengan pola hujan di daerahnya, sehingga solusi yang dihasilkan lebih efektif.

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 Musonial 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] Siang, Jong Jek. *Jaringan Syaraf Tiruan dan Pemrogramannya*. 2nd ed. Yogyakarta: Penerbit Andi; 2009
- [6] The MathWorks. *Neural Network Toolbox: User's Guide ver.7* Beale MH, Hagan MT, Demuth HB, editors.; 2010
- [7] Phang, Ming-bao and Zhao, Xin-ping, *Traffic Flow Prediction of Chaos Time Series by Using Subtractive Clustering for Fuzzy Neural Network Modeling*, in Second International Symposium on Intelligent Information Technology Application, Beijing, 2008, pp. 23-27
- [8] Chang, Pei-Chann and Wang, Yen-Wen, *Using Soft Computing Methods for Time Series Forecasting*, in *Series on Computers and Operations Research (Vol.6) - Recent Advances in Data Mining of Enterprise Data: Algorithms and Applications*, P.M Pardalos, Ed. Singapore: World Scientific, 2007, ch. 4, pp. 189-246.
- [9] Theja, P. V. V. K and Vanajakshi, Lelitha, *Short Term Prediction of Traffic Parameters Using Support Vector Machines Technique*, in Third International Conference on Emerging Trends in Engineering and Technology, 2010, pp. 70-75