Penerapan Algoritma MKNN-X Untuk Prediksi Curah Hujan

Bambang Lareno Teknik Informatika STMIK Indonesia Banjarmasin, Indonesia e-mail: blareno@gmail.com

Abstrak - Telah banyak penelitian mengenai prediksi curah hujan berbasis neural network, dan umumnya memakai data bulanan. Termasuk penggunaan algoritma nearest neighbor. Namun hasil sebelumnya belum memuaskan. Berdasarkan hal tersebut, maka penelitian ini bertujuan untuk menguji akurasi Algoritma Modified K-Nearest Neighbor-X (MKNN-X) lebih lanjut dalam memprediksi curah hujan dan membandingkannya dengan hasil prediksi Back Propagation Neural Network dan hasil prediksi nearest neighbor terdahulu. Dari hasil penelitian dapat disimpulkan bahwa terjadi peningkatan akurasi Algoritma MKNN-X rata-rata 19,82% untuk prediksi 12 bulan dan 16,48% untuk 24 bulan. MKNN-X belum dapat memprediksi lebih akurat dari pada BPNN dalam memprediksi curah hujan. Akurasi terbaik yang hasilkan MKNN-X baru mecapai 73,58%. Akurasi terbaik untuk prediksi 12 bulan, dihasilkan oleh BPNN-lm, 82,46%.

Kata kunci: timeseries, sequence, prediksi curah hujan, nearest neighbor

A. PENDAHULUAN

Prakiraan curah hujan, sebagai salah satu data klimatologi, mempunyai peran yang penting sebagai salah satu bahan pertimbangan bagi pembuat keputusan. khususnva dalam lingkungan kementerian terkait. Hal ini karena informasi besaran curah hujan mempunyai nilai ekonomi dalam berbagai kegiatan, mulai dari pertanian sampai dengan pengendalian banjir. Selain itu pencatatan curah hujan yang akurat, rapi dan periodik dapat digunakan untuk analisa pola iklim [1]. Jadi data curah hujan termasuk data rentet waktu (time-series), sehingga dapat dianalisa diprediksi dengan pendekatan neural network [2].

BMKG telah mengupayakan pendekatan dengan statistik, wavelet, ANFIS dan Tisean dalam bentuk aplikasi HyBMKG untuk prakiraan curah hujan [3]. Gumarang, dkk menggunakan BPNN untuk mengestimasi curah hujan di kota Pontianak [4]. Charaniya tertarik untuk merancang model neural network untuk prediksi hujan daerah Nagpur, India. Namun pola dan intensitas hujan India cukup berbeda dengan Indonesia [5]. Budi Warsito telah menerapkan algoritma neural network dengan learning Levenberg-Marquardt untuk memprediksi curah hujan kota Semarang [6]. Data yang dipergunakan adalah data curah hujan bulanan kota Sementara itu, Muhammad dan Bambang [7] menggunakan algoritma klasifikasi yang dimodifikasi untuk menganalisa data rentet waktu, seperti Nearest Neighbor. Namun akurasi terbaik yang dicapai baru mencapai 70,47%.

Berdasarkan latar belakang di atas, maka perlu untuk menguji lebih jauh akurasi prediksi Nearest Neighbor curah hujan. Sehinggga Question Research: "Bagaimana mengevaluasi akurasi algoritma Nearest-Neighbor curah hujan sehingga diperoleh peningkatan akurasi?"

B. 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.

B.1. Pengumpulan Data

Penelitian ini memakai data curah hujan dan kelembaban yang didapatkan dari BMKG Kalimanatan Barat. Data yang dibutuhkan dalam penelitian ini adalah: data curah hujan (mm) bulanan periode 1990 – 2012 (23 tahun) dari Stasiun Klimatologi Supadio BMKG Provinsi Kalimantan Barat.

B.2. Pengolahan Data Awal

Data yang didapatkan dari instasi terkait masih berupa data curah hujan harian, sehingga harus direkapitulasi terlebih dahulu. Rekapitulasi tersebut dilakukan dengan memperhatikan kebutuhan. Kemudian data disesuaikan dengan panjang sequence data (x) dan jumlah k yang diinginkan.

C.3. Metode/Model yang diusulkan

Metode yang digunakan adalah perbandingan antara besaran yang dihasilkan oleh pelatihan dengan data curah hujan bulanan sebenarnya. Kemudian dibandingkan dengan hasil penelitian terdahulu. Pelatihan data menggunakan Modified K-Nearest Neighbor-X (MKNN-X)

Untuk yang langkah pertama, data $\{x1, x2, \ldots, X_n\}$ menjadi rentetan yang akan dianalisis. Setelah itu, dicari panjang subsequences k (anggap sepanjang ws) dalam rentet data yang dianalisis, yang paling dekat dengan akhiran vektor subsequence (suffix) $\{x_n$ -ws $+1, \ldots, X_n\}$, dengan ws> 1, adalah tetangga terdekat terbaik [8]. k-subsequences terbentuk dalam:

$$\{x_{q1}, x_{q1+1}, \dots, x_{q1+ws-1}\}, \dots, \{x_{qk}, x_{qk+1}, \dots, x_{qk+ws-1}\}$$

...(1)

di mana $1 \le qi \le n$ -ws, $i = \{1, 2, ..., k\}$. Ukuran Lp dapat digunakan untuk menghitung jarak antara akhiran tiap utaian dan tetangganya. Nilai-nilai k dan ws adalah parameter dari model prediksi [9].

Ada dua pendekatan untuk langkah kedua di atas. Pendekatan pertama yaitu pekerjaan Giles, dkk [10] yang fokus memprediksi arah variasi untuk nilai berikutnya. Ada tiga hal yang mereka telaah: (1)meningkatkan tren, (2)tren menurun dan (3) nilai konstan. Mereka menganggap bahwa kecenderungan akan konstan ketika variasi yang ada tidak melebihi nilai (persen) yang telah ditetapkan. Pendekatan kedua didasarkan pada menghitung nilai prediksi [11] [12]. Penelitian ini mengikuti pendekatan kedua.

Jadi, untuk memprediksi nilai p berikutnya, perlu menghasilkan nilai $\{x_{n+1}, ..., X_{n+p}\}$. Proses ini merupakan langkah berulang, setiap langkah akan memprediksi nilai xn berikutnya, x_{n+i} ($1 \le i \le p$). Untuk memprediksi nilai x_{n+1} , perlu perhitungan posisi relatif sequence tetangga terdekat terpilih, sebut saja $\{x_a, x_{a+1}, ..., x_{a+ws-1}\}$ dengan sequence dari suffix $\{x_{n+i-ws}, ..., x_{n+i-1}\}$. Jarak (Δ) didapatkan dari selisih data pertama sequence terpilih dengan data pertama suffix:

$$\Delta_a = x_{n+i-ws} - x_a \qquad \dots (2)$$

Sehingga dengan mengadopsi jarak *Manhattan* didapat jarak relatif (d):

$$d = \sum_{j=0}^{ws-1} |x_{n+i-ws+j} - x_{a+j} - \Delta_a|$$
... (3)

Dengan demikian, didapatkan:

$$x_{n+i} = x_{q_t^i + ws} + \Delta_a \tag{4}$$

Persamaan $(2) \rightarrow (4)$:

$$x_{n+i} = x_{q_t^i + ws} + x_{n+i-ws} - x_{q_t^i}$$
 ... (5)

Algoritma KNN yang digunakan dalam bentuk pseudocode sebagai berikut[13]:

Input data curah hujan secara series $\{x_1, x_2,..., x_n\}$ **For** i = 1 to p

Cari sequence terdekat:

 $\{x_{q1}, x_{q1+1}, ..., x_{q1+ws-1}\}, ..., \{x_{qk}, x_{qk+1}, ..., x_{qk+ws-1}\}\$ dengan sequence suffix:

 $\{\ X_{n\,+\,i\,-\,ws}\,,\;\dots\,,\,X_{n\,+\,i\,-1}\}$

Kemudian hitung dan perkirakan nilai x_{n+1} berdasarkan nilai:

 $X_{q1+ws}^{i}, \ldots, X_{qk+ws}^{i}$

Kemudian tambahkan nilai x_{n+1} sebagai data terakhir $\{x_1, \ldots, x_{n+1-1}\}$

Next i

Output Series hasil prediksi $\{x_{n+1}, \dots, x_{n+p}\}$

Sebagai contoh [7], misalkan ada data yang berasal dari data hujan selama 60 bulan. Panjang ws yang ditentukan=5, maka akan didapatkan banyaknya sequence=9 dengan satu suffix dan satu tetangga terdekat (k=1) Artinya sequence yang akan menjadi tetangga terdekat adalah subsequence 1 sampai 9 (perhatikan Tabel 1), yaitu { xq1, x q1+1, ..., xq1+ 5-1}, ..., { xq9, xq9+1, ..., xq9+ 5-1} atau {117, 317, ..., 249.9}, ..., {326.1, ..., 213} dengan suffix {68.1, ..., 213}

Tabel 1. Data Sequence panjang 5 bulan (M1NN-5) dengan k=1, jumlah sequence 9

Sequence=9	1	2	3	4	5	Pred
Subsequence1	117,0	317,0	170,0	273,7	249,9	106,8
Subsequence2	247,7	63,9	351,7	274,8	423,9	438,6
Subsequence3	364,7	89,9	202,4	175,5	397,3	219,0
Subsequence4	76,6	27,5	65,3	172,7	349,7	316,2
Subsequence5	376,7	193,2	285,7	253,8	215,6	163,8
Subsequence6	221,4	86,5	236,1	245,6	329,7	247,5
Subsequence7	448,6	148,9	298,9	214,4	575,8	180,7
Subsequence8	289,2	94,8	171,9	270,2	398,4	207,9
Subsequence9	326,1	209,8	460,3	376,0	213,0	368,5
Suffix	68,1	74,8	10,3	292,5	414,2	332,3

Dalam proses pencocokan, misalnya subsequence4 terpilih sebagai sequence tetangga terdekat (persamaan 2 dan 3) maka nilai perkiraan x_{n+1} didapatkan (persamaan 6) dengan menambahkan nilai ws subsequence4 dengan nilai awal sequence, kemudian dikurang dengan nilai awal sub sequence4, $x_{n+1} = 316,2 + 68,1 - 76,6 = 307,7$.

Selisih absolut dengan data sebenarnya (error) = 332,3 - 307,7 = 24,6.

Kemudian dicari tetangga terdekat berikutnya sejumlah k tetangga, untuk mendapatkan nilai prediksi akhir.

C.4. Eksperimen dan Pengujian Model/Metode

Data 1990-2010 digunakan untuk sequence tetangga terdekat dan data 2011-2012 digunakan sebagai data uji.

Jurnal GEMA AKTUALITA, Vol. 4 No. 2, Desember 2015

C.5. Evaluasi dan Validasi

Evaluasi dilakukan dengan mengamati hasil prediksi menggunakan algoritma BPNN dan KNN. Validasi dilakukan dengan mengukur hasil prediksi dibandingkan dengan data aktual, sehingga akurasi masing-masing algoritma. Pengukuran kinerja dilakukan dengan menghitung error yang terjadi melalui besaran Percentage Error (MAPE), Root Mean Square Error (RMSE) dan Mean Absolute Deviation (MAD). Semakin kecil nilai error menyatakan semakin dekat nilai prediksi dengan nilai sebenarnya. Dengan demikian dapat diketahui algoritma mana yang lebih akurat dalam memprediksi curah hujan.

C. HASIL DAN PEMBAHASAN

C.1. Hasil Pengujian Model/Metode

C.1.1. BPNN

Dengan menggunakan Matlab proses pengujian dengan BPNN dilakukan. Hasilnya ditampilkan pada Tabel 2 [7].

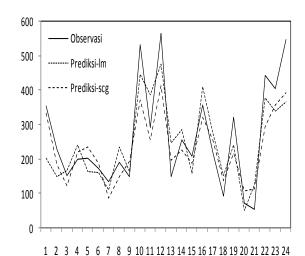
Tabel 2. Nilai RMSE Data Supadio

	Supadio					
	lm	scg	Rata-rata			
	104,057	75,466				
	113,877	78,303				
	102,884	78,990				
	122,653	91,256				
	114,443	89,211				
	101,621	99,614				
	106,322	83,956				
	100,395	97,276				
	103,118	91,600				
	129,740	102,861				
MAX	129,740	102,861	116,300			
MIN	100,395	75,466	87,931			
AVG	109,911	88,853	99,382			
MEDIAN	105,189	90,233	97,711			
STDEV	9,965	9,476	9,721			

Untuk mendapatkan error prediksi yang tervalidasi, data pisah mejadi 2 bagian. Data P1 sampai P263 untuk data pelatihan (data training), sedangkan data P241 sampai P264 untuk data uji. Berdasarkan RMSE hasil pelatihan pada arsitektur terbaik 4-4-1, pada Tabel 2, terlihat bahwa algoritma learning menggunakan scg lebih baik dari pada lm. Sedangkan untuk hasil data uji, yang ditampilkan pada tabel 3, menunjukkan bahwa learning lm lebih baik dari scg.

Tabel 3. Nilai Error Prediksi Data Uji 12 Bulan [7]

Data		Prediksi		MA	MAPE		RMSE		MAD	
Uji	Aktual	lm	scg	lm	scg	lm	scg	lm	scg	
1	229,1	148,9	184,3	0,35	0,20	6432,0	2007,0	80,20	44,80	
2	151,7	165,7	123,2	0,09	0,19	196,0	812,2	14,00	28,50	
3	198,5	240,5	221,8	0,21	0,12	1764,0	542,9	42,00	23,30	
4	204	165,2	235,2	0,19	0,15	1505,4	973,4	38,80	31,20	
5	173,5	161,3	189,6	0,07	0,09	148,8	259,2	12,20	16,10	
6	135,7	109,3	87,2	0,19	0,36	697,0	2352,3	26,40	48,50	
7	190,1	233,9	148,3	0,23	0,22	1918,4	1747,2	43,80	41,80	
8	147,9	164,4	194,4	0,11	0,31	272,3	2162,3	16,50	46,50	
9	533,2	446,6	373,4	0,16	0,30	7499,6	25536,0	86,60	159,80	
10	292,8	386,8	256,7	0,32	0,12	8836,0	1303,2	94,00	36,10	
11	566,1	476,6	414,8	0,16	0,27	8010,3	22891,7	89,50	151,30	
12	147,8	245,8	285,8	0,66	0,93	9604,0	19044,0	98,00	138,00	
			MAPE	17,44%	19,40%					
			RMSE			62,51	81,46			
			MAD					53,50	63,83	



Gambar 1. Perbandingan hasil prediksi dengan data observasi Supadio [7]

Pada Tabel 3, terlihat bahwa perhitungan akurasi untuk data 12 bulan menghasilkan MAPE-lm 17,44% dan MAPE-scg 19,40%. RMSE-lm 62,51 dan RMSE-scg 81,46. MAD-lm 53,50 dan RMSE-scg 63,83.

Jika dilanjutkan untuk data 24 bulan, perhitungan akurasi untuk data 24 bulan menghasilkan MAPE-lm 29,50% dan MAPE-scg 32,37%. RMSE-lm 79,19 dan RMSE-scg 76,93. MAD-lm 69,17 dan MAD-scg 63,23. Ditampilkan dalam bentuk grafik, terlihat sebagaimana gambar 1. [7]

C.1.2 Modified K Nearest Neighbor

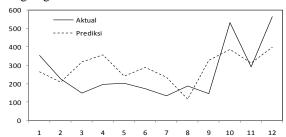
Misalnya model data yang diperlukan MKNN untuk data sequence 12 bulan dengan

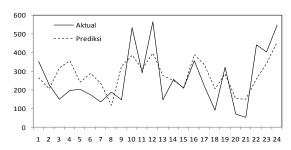
horison prediksi 1 bulan. Hasilnya ditampilkan pada Tabel 4

Tabel 4. Nilai Error Prediksi M3NN-12

Data Uji	Aktual	Prediksi	MAPE	RMSE	MAD
1	355,3	264,1	0,26	8317,4	91,20
2	229,1	206,8	0,10	497,3	22,30
3	151,7	318	1,10	27655,7	166,30
4	198,5	356,7	0,80	25027,2	158,20
5	204	241,4	0,18	1398,8	37,40
6	173,5	288,5	0,66	13225,0	115,00
7	135,7	234,4	0,73	9741,7	98,70
8	190,1	116,3	0,39	5446,4	73,80
9	147,9	326	1,20	31719,6	178,10
10	533,2	385,2	0,28	21904,0	148,00
11	292,8	312,5	0,07	388,1	19,70
12	566,1	398,1	0,30	28224,0	168,00
	Nilai Error Prediksi		50,46%	120,26	106,39

Dari tabel 4.6, terlihat bahwa perhitungan akurasi untuk data 12 bulan menghasilkan MAPE = 50,46%, RMSE = 120,26 dan MAD = 106,39. Sedangkan untuk horison prediksi 24 bulan, menghasilkan MAPE = 51,78%, RMSE = 107,79 dan MAD = 92,45. Secara grafik, ditunjukkan dengan gambar 2.





Gambar 2. Perbandingan hasil prediksi M3NN-12 untuk data uji 12 bulan (atas) dan 24 bulan (bawah)

Demikian dilakukan untuk *Modified Nearest Neighbor* dengan k dan x berbeda.

C.2. Evaluasi dan Validasi Hasil

Hasil terbaik untuk setiap pengujian ditampilkan pada tabel 5. Pada Tabel 5 terlihat bahwa error terkecil untuk prediksi 12 bulan, dihasilkan oleh BPNN-lm, yaitu MAPE 17,44% (akurasi 82,46%), Sedangkan untuk prediksi 24 bulan, MAPE terbaik dihasilkan BPNN-lm, 29,5% (atau akurasi 70,5%). Sedangkan RMSE dan MAD, dihasilkan oleh BPNN-scg [7].

Tabel 5. Nilai Agregat Akurasi

Akurasi		12 Bulan		24 Bulan			
	MAPE	RMSE	MAD	MAPE	RMSE	MAD	
BPNN-lm	17,44%	87,97	70,04	29,50%	79,19	69,17	
BPNN-scg	19,40%	104,09	80,76	32,37%	76,93	63,23	
1NN-12	75,83%	208,10	160,58	118%	219,94	180,67	
1NN-8	52,18%	198,80	148,28	84,68%	149,68	159,73	
1NN-6	65,82%	198,93	157,03	59,26%	122,58	140,46	
1NN-5	28,03%	111,12	79,56	48,61%	148,58	111,92	
1NN-4	74,46%	180,92	147,06	78,08%	128,15	148,24	
3NN-12	50,46%	120,26	106,39	51,76%	107,79	92,45	
3NN-8	55,41%	176,81	144,69	66,65%	107,79	141,08	
2NN-6	50,67%	159,60	128,33	56,85%	164,70	132,19	
2NN-5	26,42%	84,41	68,19	43,11%	128,78	101,47	
2NN-4	51,25%	134,63	119,48	66,21%	139,38	126,70	

Sedangkan untuk MKNN-X, akurasi terbaik dihasilkan oleh 2NN-5, yaitu sebesar 73,58% (MAPE 26,42%) untuk prediksi 12 bulan, sedangkan yang 24 bulan, sebesar 56,89% (MAPE 43,11%).

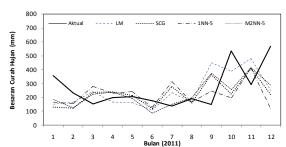
Hasil ini lebih baik dari penelitian KNN sebelumnya [7]. Sebagai contoh, untuk prediksi 12 bulan: berdasarkan parameter MAPE, akurasi NN-12 dari sebelumnya 24,17% (MAPE 75,83%) naik menjadi 49,54% (MAPE 50,46). Terjadi peningkatan akurasi sebesar 33,46%.

Rata-rata peningkatan akurasi adalah 19,82% untuk prediksi 12 bulan dan 16,49 untuk prediksi 24 bulan. (Lihat Tabel 6). Peningkatan terbesar terjadi pada KNN-12, yaitu sebesar 36,47 untuk prediksi 12 bulan dan 51,94 untuk prediksi 24 bulan.

Tabel 5. Peningkatan Akurasi

	12 Bulan				24 Bulan			
Akurasi	MAPE	RMSE	MAD	MAPE	RMSE	MAD	12 Bulan	24 Bulan
NN-12	33,46%	42,21%	33,75%	55,99%	50,99%	48,83%	36,47%	51,94%
NN-8	-6,20%	11,06%	2,42%	21,29%	27,99%	11,68%	2,43%	20,32%
NN-6	23,02%	19,77%	18,28%	4,07%	-34,37%	5,89%	20,36%	-8,13%
NN-5	5,73%	24,04%	14,29%	11,33%	13,32%	9,34%	14,69%	11,33%
NN-4	31,17%	25,59%	18,76%	15,20%	-8,76%	14,53%	25,17%	6,99%
Rata-rata peningkatan akurasi						19,82%	16,49%	

Gambar 3 menunjukan pola hasil prediksi 12 bulan masing-masing algoritma. Sedangkan gambar 4 memperlihatkan pergerakan nilai MAPE untuk BPNN-lm, BPNN-scg, 1NN-5 dan 2NN-5.



Gambar 3. Perbandingan hasil prediksi untuk data uji 12 bulan

Dengan demikian, ada peningkatan akurasi KNN, namun belum sebaik yang dapat dilakukan oleh BPNN-lm dan scg.

Pergerakan Nilai MAPE 100,0% — LM — SCG — M2NN-5 — - KNN-5 40,0% 20,0% 1 2 3 4 5 6 7 8 9 10 11 12

Gambar 3. Perbandingan hasil prediksi untuk data uji 12 bulan

D. KESIMPULAN

Dari hasil penelitian yang dilakukan dari tahap awal hingga pengujian, dan pengukuran, dapat disimpulkan bahwa terjadi peningkatan akurasi Algoritma MKNN-X rata-rata 19,82% untuk prediksi 12 bulan dan 16,48% untuk 24 bulan. MKNN-X belum dapat memprediksi lebih akurat dari pada BPNN dalam memprediksi curah hujan. Akurasi terbaik yang hasilkan MKNN-X baru mecapai 73,58%. Akurasi terbaik untuk prediksi 12 bulan, dihasilkan oleh BPNN-lm, 82,46%.

E. SARAN

Berapa hal perlu disampaikan untuk pengujian yang lebih baik, yaitu:

- Perlu pengujian dengan model folding, sehingga mengurangi efek data uji yang ekstrem.
- 2. Perlu melibatkan fitur suhu dan kelembaban, dan menguji pengaruhnya terhadap akurasi algoritma nearest neighbor.
- 3. Perlu data tambahan dari wilayah lain yang memiliki pola hujan berbeda, khususnya yang memiliki pola hujan lokal.
- 4. Selain itu, perlu data hujan yang lebih banyak (20 sampai 30 tahun) sehingga masing-masing algoritma mendapatkan pelatihan yang cukup untuk mengenali pola hujan.

DAFTAR PUSTAKA

- [1] Sasmita Ahmad Kadarsah, "Standardisasi Metadata Klimatologi Dalam Penelitian Perubahan Iklim Di Indonesia," in *Prosiding PPI Standardisasi* 2010, Banjarmasin, 2010, pp. 1-18.
- [2] Akashdeep Gupta, Anjali Gautam, Chirag Jain, Himanshu Prasad, and Neeta Verma, "Time Series Analysis of Forecasting Indian Rainfall,"

- International Journal of Inventive Engineering and Sciences (IJIES), vol. I, no. 6, pp. 42-45, May 2013.
- [3] Irman Sonjaya, Toni Kurniawan, Miftahul Munir, Mustika Wiratri, and Khairullah, "Uji Aplikasi HyBMG Versi 2.0Untuk Prakiraan Curah HujanPola Monsunal Ekuatorial dan Lokal," *Buletin Meteorologi Klimatologi dan Geofisika*, vol. 5, no. 3, pp. 323-339, September 2009.
- [4] Muh.Ishak Gumarang, Lyra Andromeda, and Bintoro S. Nugroho, "Estimasi Curah Hujan, Suhu dan Kelembaban Udara Dengan Menggunakan Jaringan Syaraf Tiruan Backpropagation," *Jurnal Aplikasi Fisika*, vol. V, no. 1, pp. 54-61, Februari 2009.
- [5] N.A. Charaniya and S.V. Dudul, "Design of Neural Network Models for Daily Rainfall Prediction," *International Journal of Computer Applications* (0975 8887), vol. 61, no. 14, pp. 23-27, January 2013.
- [6] Budi Warsito and Sri Sumiyati, Prediksi Curah Hujan Kota Semarang Dengan FeedForward NN Menggunakan Algoritma Quasi Newton BFGS dan Levenberg-Marquardt, 2005.
- [7] Muhammad and Bambang Lareno, "Modified Nearest Neighbor Untuk Prediksi Curah Hujan," in *Konferensi Nasional Sistem & Informatika 2015 STMIK STIKOM Bali*, Bali, 2015.
- [8] Xing Zhengzheng, Pei Jian, and Philip S. Yu, "Early Prediction on Time Series: A Nearest Neighbor Approach," *NSERC Discovery*, 2010.
- [9] Dominique Guegan and Patrick Rakotomarolahy, "The Multivariate k-Nearest Neighbor Model for Dependent Variables: One-Sided Estimation and Forecasting," Paris School of Economics, CES-MSE, Université Paris 1 Panthéon-Sorbonne, Paris, Documents de travail du Centre d'Economie de la Sorbonne ISSN: 1955-611X, 2010.
- [10] C.L. Giles, S. Lawrence, and A.C., Tsoi, "Noisy Time Series Prediction using Recurrent Neural Networks and Grammatical Inference," *Machine Learning*, vol. 44, no. 1-2, pp. 161-183(23), Springer, 2001.
- [11] E.A. Plummer, Time Series Forecasting with Feed-Forward Neural Networks: Guidelines and limitations., 2000.

Jurnal GEMA AKTUALITA, Vol. 4 No. 2, Desember 2015

- [12] S. Yakowitz, "Nearest-neighbor methods for time-series analysis," *Journal of Time Series Analysis*, vol. 8, no. 2, pp. 235-247, 1987.
- [13] Adela Sasu, "k-Nearest Neighbor Algorithm For Univariate Time Series Prediction," Bulletin of the Transilvania University of Brasov, vol. 5(54), no. 2, Series III: Mathematics, Informatics, Physics, pp. 147-152, 2012.