

PENGARUH ARSITEKTUR ANFIS PADA PERAMALAN CUACA

Candra Dewi

Program Studi Informatika/Ilmu Komputer, Universitas Brawijaya
E-mail: dewi_candra@ub.ac.id¹

ABSTRACT

Dalam proses pembelajaran dengan *Adaptive Neuro Fuzzy Inference System* (ANFIS), selain parameter laju pembelajaran dan *error* harap, jumlah *neuron* dalam tiap lapisan juga sangat mempengaruhi hasil pembelajaran. Dengan demikian, pengujian untuk mendapatkan arsitektur jaringan yang optimal perlu untuk dilakukan. Adapun dalam arsitektur ANFIS, bagian lapisan yang memegang peranan adalah lapisan pertama dan lapisan kedua, dimana lapisan pertama yang merupakan fuzzyfikasi dari *input* dan lapisan kedua mewakili jumlah aturan *fuzzy* dalam proses inferensi. Pada penelitian ini diimplementasikan pengujian arsitektur ANFIS untuk peramalan cuaca, terutama untuk mengetahui jumlah *neuron* yang paling baik pada lapisan pertama dan kedua.

Hasil uji coba menunjukkan bahwa kombinasi persentase 40%, 50% dan 60% data latih menghasilkan nilai akurasi dan RMSE yang cukup stabil pada beberapa kombinasi neuron (antara 2 sampai 6) pada lapisan pertama dan kedua. Disamping itu dapat diketahui bahwa kombinasi jumlah neuron yang optimal adalah antara 2 sampai 4.

Keywords: *Arsitektur ANFIS, peramalan cuaca, Fuzzy C-Means, lapisan pertama, lapisan kedua*

1. INTRODUCTION

Adaptive Neuro Fuzzy Inference System (ANFIS) merupakan salah satu metode yang sering digunakan untuk prediksi dan peramalan, dengan akurasi yang cukup bagus (Singla dkk, 2011). ANFIS merupakan gabungan antara konsep jaringan syaraf tiruan propagasi balik dengan konsep logika *fuzzy*. Jaringan syaraf tiruan propagasi balik

mempunyai kelebihan dalam mengenali suatu data/obyek berdasarkan sekumpulan fitur yang menjadi masukan sistem. Sedangkan sistem berbasis *fuzzy* bisa dinyatakan dengan pengetahuan berbentuk “if-then” yang memberikan keuntungan tidak memerlukan analisis matematik untuk pemodelan. Selain itu sistem *fuzzy* juga bisa memproses penalaran dan pengetahuan manusia yang berorientasi pada aspek kualitatif.

Metode ANFIS terdiri dari 5 lapisan yang mana tiap lapisannya memiliki perlakuan yang berbeda. Pengujian *performance* ANFIS seringkali dilakukan untuk mengetahui besarnya parameter ANFIS seperti laju pembelajaran. Namun demikian, arsitektur jaringan juga merupakan bagian yang memegang peranan untuk mendapatkan kondisi jaringan yang optimal.

Beberapa penelitian yang melakukan pengujian untuk mendapatkan arsitektur ANFIS yang optimal untuk beberapa kasus telah dilakukan oleh beberapa peneliti. Pada penelitian yang dilakukan oleh Sheng dan Gao (2004) dilakukan pengujian tipe fungsi keanggotaan dan jumlah fungsi keanggotaan. Sedangkan penelitian yang dilakukan oleh Puspitasari dkk (2013) menggunakan inferensi statistik R^2 incremental untuk mendapatkan jumlah neuron pada lapisan input, jumlah fungsi keanggotaan dan jumlah aturan. Selanjutnya Fallahpour dan Moghassem (2013) melakukan pengujian arsitektur ANFIS untuk memprediksi kekuatan rotor dari *spun yarn*. Dari penelitian-penelitian ini terlihat bahwa pengujian dilakukan terutama untuk mengetahui jenis fungsi keanggotaan dan jumlah *neuron* pada lapisan pertama sampai ketiga pada ANFIS. Namun demikian pada penelitian-penelitian ini tidak ada *threshold* jumlah neuron yang harus diujikan pada tiap lapisan. Puspitasari (2013) membatasi jumlah maksimal neuron adalah tiga sehingga tidak diketahui hasil pengujian dengan jumlah neuron diatas tiga. Selain itu penentuan jumlah neuron hanya didasarkan pada nilai R^2 yang

paling seimbang dan tidak dilakukan pengujian lebih lanjut terhadap akurasi jaringan dalam dilakukan oleh Fallahpour dan Moghassem (2013) juga tidak dijelaskan lebih lanjut mengenai *threshold* jumlah neuron yang akan diujikan. Pada penelitian ini, akan dilakukan optimasi jumlah neuron dengan berdasarkan jumlah *cluster* terbaik melalui proses *clustering*. Selanjutnya dilakukan pengujian akurasi jaringan dengan jumlah neuron sesuai dengan jumlah *cluster* terbaik. Pengujian juga dilakukan terhadap jumlah neuron yang mendekati jumlah *cluster* terbaik. Dengan demikian akan diketahui apakah jumlah *cluster* terbaik juga akan menghasilkan arsitektur jaringan yang paling optimal.

Adapun pada arsitektur ANFIS, salah satu lapisan yang merupakan lapisan adaptif adalah lapisan pertama, dimana setiap simpul pada lapisan ini adalah simpul adaptif (Jang, 1997). Sebagai langkah awal pada lapisan pertama adalah melakukan *clustering* masukan untuk menghitung besarnya parameter *premis* fungsi keanggotaan parameter yang didekati dengan fungsi bell. Namun demikian, dalam proses *clustering* juga dapat dilakukan perhitungan jumlah *cluster* optimal dengan nilai kesalahan yang rendah. Adapun jumlah *cluster* optimal ini dapat digunakan sebagai acuan dalam memilih jumlah *neuron* dalam lapisan pertama. Dengan berdasarkan pada asumsi ini, maka perlu dilakukan pengujian untuk mengetahui apakah jumlah *cluster* yang optimal akan selalu menghasilkan akurasi jaringan yang terbaik.

Pada penelitian sebelumnya, telah diimplementasikan proses peramalan cuaca dengan menggunakan ANFIS (Dewi, 2013; Kartikasari, 2012). Pada penelitian yang dilakukan Dewi (2013), dilakukan pengujian untuk mengetahui teknik *clustering* yang lebih baik antara C-Means dan Fuzzy K-Means. Namun demikian dalam penelitian-penelitian ini belum dilakukan pengujian jumlah neuron yang optimal pada tiap layer. Oleh karena itu pada penelitian ini akan dilakukan pengujian jumlah neuron optimal terutama pada lapisan pertama dan kedua dengan menggunakan

proses peramalan. Dalam penelitian yang jumlah *cluster* terbaik yang terbentuk dari proses *clustering* parameter masukan.

2. METODOLOGI

2.1. Data yang Digunakan

Data yang digunakan dalam penelitian ini berupa data sekunder dari data pengamatan Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Kecamatan Karangploso, Kabupaten Malang. Data yang digunakan mulai data bulan Januari 2011 sampai dengan Januari 2012. Data yang digunakan meliputi data harian suhu, kelembaban udara, kecepatan angin dan tekanan udara.

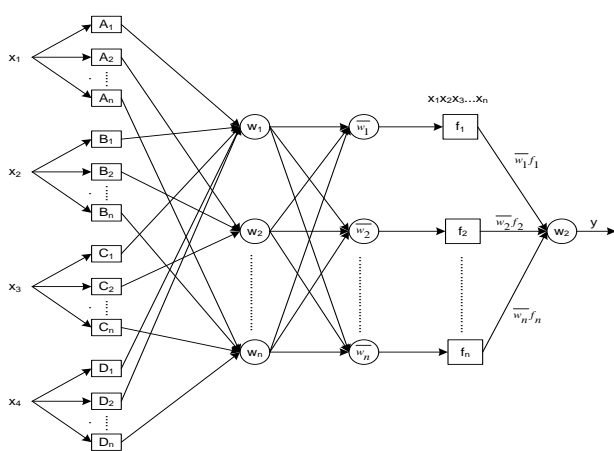
Keseluruhan data terbagi dalam tiga kategori yaitu data musim kemarau, penghujan dan peralihan. Adapun data-data yang masuk dalam musim kemarau adalah data bulan Juni sampai September dan data-data yang masuk dalam musim penghujan adalah data bulan Nopember sampai April. Sedangkan data bulan Mei dan Oktober termasuk data transisi dari musim penghujan ke musim kemarau atau sebaliknya.

3. ADAPTIVE NEURO FUZZY INFERENCE SYSTEM (ANFIS)

ANFIS adalah gabungan dari dua sistem yaitu sistem logika *fuzzy* dan jaringan syaraf tiruan. Sistem *neuro-fuzzy* berdasar pada sistem inferensi *fuzzy* yang dilatih menggunakan algoritma pembelajaran yang diturunkan dari sistem jaringan syaraf tiruan. Dengan demikian, sistem ANFIS memiliki semua kelebihan yang dimiliki oleh sistem inferensi *fuzzy* dan sistem jaringan syaraf tiruan. Arsitektur ANFIS juga sama dengan *radial base function* dengan sedikit batasan tertentu. Dapat dikatakan bahwa ANFIS merupakan suatu metode yang dalam penentuan aturannya digunakan algoritma pembelajaran terhadap sekumpulan data. Hal ini yang membuat basis aturan-aturan dapat beradaptasi.

3.1 Arsitektur Jaringan ANFIS untuk Peramalan Cuaca

Sistem dalam bentuk program aplikasi ini menerima parameter masukan terdiri dari empat parameter, yakni unsur cuaca yang meliputi suhu (temperatur), kelembaban udara, kecepatan angin, dan tekanan udara. Sedangkan *output*/hasil terdiri dari satu keluaran, yaitu kondisi cuaca yang meliputi cuaca cerah, berawan, dan hujan. Pada lapisan pertama, *input* dikelompokkan menjadi sejumlah *n cluster*. Pada lapisan selanjutnya digunakan *m* aturan dalam proses inferensi masukan. Rancangan arsitektur jaringan ANFIS yang digunakan dalam penelitian ini ditunjukkan pada Gambar 1.



Gambar 1 Arsitektur ANFIS untuk peramalan cuaca

Salah satu bentuk arsitektur ANFIS yang sangat dikenal adalah model Takagi-Sugeno-Kang. Pada aplikasi ini sistem inferensi *fuzzy* yang diterapkan adalah inferensi Sugeno dengan layer sebanyak 5.

Salah satu lapisan adaptif adalah lapisan pertama. Setiap simpul *i* pada lapisan ini adalah simpul adaptif dengan fungsi simpul untuk membangkitkan derajat keanggotaan:

$$O_{1,i} = \mu_{A_i}(x) \quad , \quad i = 1, 2, 3, \dots, n \quad (1)$$

atau

$$O_{1,i} = \mu_{B_i}(y) \quad , \quad i = 3, 4, \dots, n \quad (2)$$

dengan *x* dan *y* adalah masukan bagi simpul ke-*i*, dan *A_i* adalah label bahasa (*linguistik label*) seperti misalnya dingin, sejuk, dan lain-lain. Dengan kata lain, *O_{1,i}* adalah tingkat keanggotaan dari himpunan *fuzzy* *A* = (*A₁*, *A₂*, *B₁*, *B₂*). Fungsi keanggotaan parameter dari *A* dapat didekati

dengan fungsi bell (Jang, J.-S. R. 1997) seperti ditunjukkan pada persamaan 3.

$$\mu_{A_1}(x) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^2} \quad (3)$$

Dimana *a* dan *c* adalah parameter dari fungsi keanggotaan atau disebut sebagai parameter *premis* dan $\mu_{A_1}(x)$ adalah derajat keanggotaan. Salah satu cara untuk mendapatkan nilai dari parameter premis adalah dengan menggunakan teknik *clustering*. Adapun dalam penelitian ini digunakan *clustering Fuzzy C-Means*.

Pada lapisan kedua, setiap simpul diberi label \bar{w}_i , bersifat non-adaptif (parameter tetap) yang mempunyai keluaran berupa perkalian dari semua sinyal masuk.

$$O_{2,i} = \bar{w}_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i = 1, 2, \dots, n \quad (4)$$

Masing-masing keluaran simpul menyatakan derajat pengaktifan (kuat penyulutan/*firing strength*) dari aturan *fuzzy*. Dimana $\mu_A(x)$ adalah derajat keanggotaan himpunan *A*, dan $\mu_B(y)$ adalah derajat keanggotaan himpunan *B*.

Setiap simpul pada lapisan ketiga diberi label \bar{w} , juga bersifat non-adaptif. Masing-masing simpul menampilkan derajat pengaktifan ternormalisasi dengan bentuk :

$$O_{3,i} = \bar{w} = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2, \dots, n \quad (5)$$

Output yang dihasilkan dari proses ini disebut dengan kuat penyulutan ternormalisasi. Apabila dibentuk lebih dari dua aturan, fungsi dapat diperluas dengan membagi *w_i* dengan jumlah total *w* untuk semua aturan.

Pada lapisan keempat, setiap simpul pada lapisan ini berupa simpul adaptif dengan fungsi simpul :

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y) \quad (6)$$

atau

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (c_{i1}x_1 + c_{i2}x_2 + \dots + c_{in}x_n + c_{i0}) \quad (7)$$

Dimana \bar{w}_i adalah derajat pengaktifan (kuat penyulutan) ternormalisasi dari lapisan 3 dan $\{p_i, q_i\}$ merupakan himpunan parameter dari simpul ini, y_i adalah output dan $\{c_{i1}, c_{i2}, \dots, c_{in}, c_{i0}\}$ adalah parameter-parameter pada simpul(neuron) tersebut. Parameter-parameter pada lapisan ini dinamakan parameter konsekuen.

Pada lapisan kelima, simpul tunggal pada lapisan ini diberi label Σ , yang mana menghitung semua keluaran sebagai penjumlahan dari semua sinyal yang masuk.

$$O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (8)$$

atau

$$O_{5,i} = \sum_i \bar{w}_i y_i = \frac{\sum_i w_i y_i}{\sum_i w_i} \quad (9)$$

3.2 Fuzzy C-Means Clustering

Fuzzy C-Means (FCM) adalah suatu teknik pengelompokan data yang keberadaan setiap titik data dalam suatu cluster ditentukan oleh derajat keanggotaan. Konsep dasar FCM yaitu menentukan pusat *cluster* yang akan menandai lokasi rata-rata untuk setiap *cluster*. Adapun caranya dengan memperbaiki pusat *cluster* dan derajat keanggotaan setiap titik data secara berulang, sehingga pusat *cluster* akan bergerak menuju lokasi yang tepat. Perulangan ini didasarkan pada minimisasi fungsi obyektif yang menggambarkan jarak dari titik data yang diberikan ke pusat *cluster* yang terbobot oleh derajat keanggotaan titik data tersebut (Kusumadewi, 2010).

Output dari FCM merupakan deretan pusat cluster dan beberapa derajat keanggotaan untuk tiap-tiap titik data. Algoritma FCM adalah sebagai berikut (Kusumadewi, 2010):

1. Menentukan matriks X yang merupakan data yang akan di-*cluster*, berukuran k x j, dengan k adalah jumlah data yang akan di-

cluster dan j adalah jumlah variabel/atribut (kriteria).

$$\begin{bmatrix} X_{11} & X_{12} & \dots & X_{1j} \\ X_{21} & X_{22} & \dots & X_{2j} \\ \vdots & \vdots & \ddots & \vdots \\ X_{k1} & X_{k2} & \dots & X_{kj} \end{bmatrix}$$

2. Menentukan :

- a. Jumlah cluster yang akan dibentuk ($n > c \geq 2$).
- b. Pembobot ($w > 1$).
- c. Maksimum iterasi (max n).
- d. Kriteria penghentian/treshold (ϵ = nilai positif yang sangat kecil).
- e. Fungsi obyektif awal (P_0).
- f. Matriks partisi awal U (derajat keanggotaan dalam cluster) dengan ukuran k x i; matriks partisi biasanya dibuat acak, dengan k = jumlah data yang akan di-*cluster* dan i = jumlah cluster

$$\begin{bmatrix} U_{11} & U_{12} & \dots & U_{1i} \\ U_{21} & U_{22} & \dots & U_{2i} \\ \vdots & \vdots & \ddots & \vdots \\ U_{k1} & U_{k2} & \dots & U_{ki} \end{bmatrix}$$

3. Hitung pusat cluster (V) untuk setiap cluster, menggunakan persamaan 10.

$$V_{ij} = \frac{\sum_{k=1}^n (\mu_{ik})^w \cdot x_{kj}}{\sum_{k=1}^n (\mu_{ik})^w} \quad (10)$$

Dimana V_{ij} adalah pusat cluster pada cluster ke-i dan atribut ke-j, μ_{ik} adalah data partisi (pada matriks U) pada cluster ke-i dan data ke-k, X_{kj} adalah data (pada matriks U) pada atribut ke-j dan data ke-k dan w adalah pembobot.

4. Hitung nilai obyektif (P_n) dengan persamaan 11.

$$P_n = \sum_{k=1}^n \sum_{i=1}^c (\mu_{ik})^w (d_{ik})^2 \quad (11)$$

Dimana P_n adalah nilai obyektif pada iterasi ke-n dan d_{ik} adalah fungsi ukuran jarak Euclidean pada pusat cluster ke-i dan data ke-k,

5. Perbaiki derajat keanggotaan setiap data pada setiap *cluster* (perbaiki matriks partisi).

$$\mu_{ik} = \left[\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{2/(w-1)} \right]^{-1}$$

(12)

dengan:

$$d_{ik} = d(x_k - v_i) = \left[\sum_{j=1}^m (x_{kj} - v_{ij})^2 \right]^{1/2}$$

(13)

dimana d_{ik} adalah jarak Euclidean pada pusat cluster ke-i dan data ke-k dan d_{jk} adalah jarak Euclidean pada pusat cluster ke-j dan data ke-k dan X_{kj} adalah data (pada matriks U) pada atribut ke-j dan data ke-k.

6. Hentikan iterasi jika pusat cluster V tidak berubah. Alternatif kriteria penghentian yang lain adalah jika perubahan nilai error kurang dari *threshold* $|P_n - P_{n-1}| < \epsilon$ dan ketika perulangan melebihi maksimum iterasi ($n > \max n$). Jika iterasi belum berhenti, kembali ke langkah 4. Jika iterasi berhenti, ditentukan cluster dari tiap-tiap data. Cluster dipilih berdasarkan nilai matriks partisi terbesar.
7. Setelah selesai, maka didapatkanlah data yang telah tercluster yang akan dimasukkan untuk pencarian rumus mean dan standar deviasi. Nilai mean dan standar deviasi ini merupakan nilai a dan c dalam persamaan 3.

3.3 Akurasi Hasil Pengujian

Untuk menentukan hasil akurasi dari pengujian data, digunakan *Root Mean Square Error* atau yang biasa disebut RMSE. RMSE merupakan akar rata-rata total kuadrat *error* yang terjadi antara *output* proses dan *output* target, semakin kecil nilai RMSE maka besar tingkat keberhasilan proses pelatihan (El-Sheimy, 2001). RMSE dapat dihitung dengan menggunakan persamaan 14.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \bar{y}_i)^2}{N}}$$

(14)

Dimana N adalah banyaknya data, y_i adalah target jaringan dan \bar{y}_i adalah output nilai risiko atau output jaringan.

4. HASIL DAN PEMBAHASAN

Pengujian dilakukan setelah dilakukan pelatihan pada sistem dengan berbagai kombinasi antara data latih dan data uji. Pengujian dilakukan untuk menghitung nilai akurasi, RMSE dan jumlah iterasi.

Pada langkah pertama, dilakukan pengujian FCM untuk mendapatkan jumlah cluster optimal yang nantinya digunakan sebagai acuan jumlah neuron pada ANFIS. Selanjutnya dilakukan pengujian untuk mendapatkan arsitektur ANFIS yang optimal.

Adapun data-data yang masuk dalam musim kemarau adalah data bulan Juni sampai September dan data-data yang masuk dalam musim penghujan adalah data bulan Nopember sampai April. Sedangkan data bulan Mei dan Oktober termasuk data transisi dari musim penghujan ke musim kemarau atau sebaliknya.

4.1 Hasil Pengujian FCM

Sebelum dilakukan pengujian pada ANFIS, terlebih dahulu dilakukan pengujian pada FCM untuk mengetahui jumlah cluster optimal. Pengujian ini dilakukan pada beberapa persentasi data latih, pada data musim kemarau dan musim penghujan. Hasil pengujian FCM ditunjukkan pada Tabel 1, Tabel 2 dan Tabel 3.

Tabel 1 Hasil pengujian FCM menggunakan persentase data latih

Data Latih (%)	Akurasi pada Tiap Jumlah Cluster				
	2	3	4	5	6
40	20	37	27	5	28
50	9	27	8	14	32
60	41	24	11	31	15
Rata-rata	23,3	29,3	15,3	16,7	25,0

Tabel 2 Hasil pengujian FCM pada musim kemarau

Data Latih (Bulan)	Akurasi pada Tiap Jumlah Cluster				
	2	3	4	5	6
Jun	60	30	27	30	17
Jun-Jul	57	51	21	18	20
Jun-Agt	59	25	21	13	13
Rata-rata	58,7	35,3	23,0	20,3	16,7

Tabel 3 Hasil pengujian FCM pada musim penghujan

Data Latih (Bulan)	Akurasi pada Tiap Jumlah Cluster				
	2	3	4	5	6
Nop	17	7	33	17	13
Jan	16	45	26	29	3
Nop-Des	10	31	26	10	10
Rata-rata	14,3	27,7	28,3	18,7	8,7

Dari hasil pengujian dengan menggunakan persentase data latih (Tabel 1) menunjukkan bahwa rata-rata akurasi terbaik ditunjukkan pada jumlah *cluster* sebanyak 3. Selanjutnya berdasarkan hasil pengujian pada musim kemarau Tabel 2 menunjukkan bahwa rata-rata akurasi terbaik adalah pada jumlah *cluster* sebanyak 2. Sedangkan dari hasil pengujian pada musim penghujan (

Tabel 3) menunjukkan bahwa rata-rata akurasi terbaik adalah pada jumlah *cluster* sebanyak 4.

Hasil pengujian jumlah *cluster* ini selanjutnya akan digunakan sebagai acuan untuk pengujian arsitektur ANFIS. Namun demikian, dari pengujian diatas terlihat bahwa akurasi dari pengujian sangat rendah. Dengan demikian, dalam pengujian selanjutnya akan dilakukan uji coba pada sistem ANFIS dengan berbagai kombinasi jumlah neuron untuk mengetahui apakah akurasi sistem ANFIS dengan jumlah *cluster/neuron* 2, 3 dan 4 memiliki nilai yang lebih baik. Oleh karena itu, sebagai pembanding juga dilakukan pengujian pada arsitektur dengan jumlah *neuron* 5 dan 6.

4.2 Hasil Pengujian ANFIS

Pengujian pada sistem ANFIS dilakukan pada beberapa kombinasi jumlah *cluster* yaitu 2 sampai 6. Adapun kombinasi ini diujikan pada lapisan pertama dan kedua pada jaringan ANFIS. Sedangkan untuk nilai *learning rate*, digunakan nilai 0,7 dimana nilai ini adalah *learning rate* terbaik berdasarkan penelitian sebelumnya (Dewi dan Ratnawati, 2013).

Pada skenario pertama, dilakukan pengujian pada data latih 50%, data musim kemarau dan data musim penghujan. Untuk data pada musim kemarau dan penghujan digunakan data latih selama 1 bulan. Adapun hasil pengujian kombinasi jumlah neuron ditunjukkan pada Tabel 4.

Tabel 4 Hasil pengujian kombinasi jumlah neuron

Data Uji	Jml Neuron		Iterasi	Akurasi	RMSE
	Lap 1	Lap 2			
50%	2	3	50	72,54386	0,69290
	3	5	38	70,96491	0,69253
	4	2	23	72,36842	0,68077
	5	4	12	71,84211	0,69992
	6	2	63	71,05263	0,69192
	2	3	5	83,87097	0,58080
Kemarau	3	2	45	90,32258	0,56141
	4	2	47	86,45161	0,61579
	5	5	454	90,32258	1,98662
	6	2	425	88,38710	0,64949
	2	3	53	67,14286	1,77579
	3	2	256	69,28571	0,83355
Peng-hujan	4	2	124	72,85714	1,17862
	5	4	123	76,42857	1,04464
	6	2	160	60,71429	0,80717

Dari tabel terlihat bahwa untuk jumlah neuron genap pada lapisan pertama, akurasi terbaik untuk semua data latih (50%, kemarau, penghujan) ditemukan pada kombinasi jumlah neuron yang sama pada lapisan kedua. Dari pengujian juga terlihat bahwa meskipun dengan data latih 50% memiliki akurasi yang tidak terlalu tinggi, namun demikian memiliki nilai yang cukup stabil jika dibandingkan dengan pengujian pada musim kemarau dan penghujan. Begitu juga dengan nilai RMSE, dimana pada pengujian dengan 50% data memiliki nilai yang cukup stabil dan menunjukkan nilai rata-rata terbaik. Dari hasil yang diperoleh dapat diketahui bahwa meskipun data latih 50% cukup beragam dimana terdiri campuran data pada musim penghujan (sebagian besar) dan data musim peralihan serta diuji dengan data pada musim kemarau, menghasilkan akurasi dan RMSE yang cukup stabil. Hal ini tidak ditemukan pada pengujian dengan data latih pada musim kemarau dan penghujan. Meskipun data latih dan uji pada kedua musim ini cukup seragam dan menghasilkan akurasi yang tinggi (terutama untuk musim kemarau), akan tetapi nilai akurasi dan RMSE yang dihasilkan tidak cukup stabil.

Berdasarkan pertimbangan ini, untuk pengujian selanjutnya akan dilakukan pada data latih yang berbeda dengan menggunakan kombinasi neuron 4 pada lapisan pertama dan 2 pada lapisan kedua. Hasil pengujian dengan berbagai jumlah data latih ditunjukkan pada Tabel 5 sampai dengan Tabel 7.

Tabel 5 Hasil pengujian pada data latih 40%, 50% dan 60% dengan FCM

Persen Data Latih	Persen data Uji					
	30%		40%		50%	
	Aku-rasi	RMSE	Aku-rasi	RMSE	Aku-rasi	RMSE
40%	64,67	0,739	70,88	0,708	73,95	0,692
50%	72,12	0,694	72,86	0,691	72,37	0,681
60%	72,41	0,678	72,75	0,663		

Dari Tabel 5 diketahui bahwa pada pengujian dengan beberapa kombinasi persentase data latih dan uji menghasilkan nilai akurasi dan RMSE yang cukup stabil, kecuali pada data latih 40% dan data uji 30%. Hasil ini tidak berbeda jauh dengan pengujian pada jaringan yang memiliki jumlah neuron 3 pada lapisan pertama dan kedua (Dewi dan Ratnawati, 2013). Selain itu juga menunjukkan bahwa pengujian dengan kombinasi persentase data latih dan uji memiliki nilai yang cukup stabil pada beberapa kombinasi neuron (antara 2 sampai 6) pada lapisan pertama dan kedua.

Tabel 6 Hasil pengujian pada musim penghujan dengan FCM

Data Latih (Bulan)	Data Uji (Bulan)					
	1		2		3	
	Aku-rasi	RMSE	Aku-rasi	RMSE	Aku-rasi	RMSE
Jan	72,86	1,155	77,63	1,000	67,42	0,794
Nop	81,72	0,683	83,87	0,917		
Nop-Des	79,57	0,572				

Tabel 6 menunjukkan hasil pengujian pada musim kemarau. Pengujian menunjukkan bahwa pada musim kemarau, nilai akurasi yang dihasilkan sangat bagus dan begitu juga nilai RMSE cukup kecil, kecuali pada pengujian dengan data latih 3 bulan dan data uji 3 bulan dimana memiliki akurasi yang rendah. Hal ini dimungkinkan karena sebagian data uji berada pada musim penghujan (bulan Nopember), sehingga terdapat beberapa data uji yang tidak dikenali karena memiliki kombinasi yang berbeda dengan data latih. Hasil ini lebih baik dibandingkan dengan pengujian pada kombinasi neuron 3-3 pada lapisan pertama dan lapisan kedua (Dewi dan Ratnawati, 2013).

Tabel 7 Hasil pengujian pada musim kemarau dengan FCM

Data Latih (Bulan)	Data Uji (Bulan)					
	1 Bulan		2 Bulan		3 Bulan	
	Aku-rasi	RMSE	Aku-rasi	RMSE	Aku-rasi	RMSE
Jun	90,32	0,620	93,55	0,487	92,39	0,495
Jun-Jul	100,0	0,262	96,72	0,443	83,70	0,577
Jun-Agt	93,33	0,461	80,87	0,634	60,81	0,859

Berdasarkan hasil pengujian pada musim penghujan Tabel 7 dapat diketahui bahwa nilai akurasi yang dihasilkan jauh lebih baik dan nilai RMSE cukup kecil jika dibandingkan dengan penelitian sebelumnya (Dewi dan Ratnawati, 2013). Seperti telah dijelaskan pada penelitian sebelumnya (Dewi dan Ratnawati, 2013) bahwa variasi data pada musim penghujan cukup besar sehingga ANFIS akan gagal melakukan pengujian untuk mengenali data pada musim ini. Namun demikian, dengan menggunakan parameter yang tepat dan kombinasi neuron yang optimal, maka juga menghasilkan performansi jaringan yang juga optimal.

Dari hasil pengujian kombinasi jumlah neuron menunjukkan bahwa metode FCM tidak dapat digunakan untuk melakukan optimasi dalam menentukan jumlah neuron yang optimal pada lapisan pertama dan kedua sistem ANFIS dalam peramalan cuaca. Berdasarkan data pada Tabel 1 sampai dengan Tabel 3 diketahui bahwa jumlah optimal *cluster* adalah bervariasi antara 2 sampai 4. Dari data ini tidak bisa digunakan untuk mendapatkan jumlah neuron secara pasti. Akan tetapi jika diperhatikan, hasil pengujian kombinasi jumlah neuron juga menunjukkan bahwa nilai optimal ditunjukkan pada variasi antara 2 sampai 4. Dengan demikian, meskipun FCM tidak dapat digunakan untuk menentukan jumlah neuron yang optimal secara pasti, tetapi masih bisa digunakan untuk memperkirakan rentang jumlah neuron yang optimal.

5. KESIMPULAN

Berdasarkan implementasi dan uji coba yang dilakukan dapat diambil kesimpulan sebagai berikut:

1. Metode FCM tidak dapat digunakan untuk mengetahui jumlah neuron yang optimal

secara pasti pada lapisan pertama dan kedua. Namun demikian rentang nilai yang dihasilkan bisa digunakan sebagai acuan untuk menentukan kombinasi jumlah neuron pada ANFIS.

2. Berdasarkan pengujian dapat diketahui bahwa kombinasi persentase 40%, 50% dan 60% data latih memiliki nilai akurasi dan RMSE yang cukup stabil pada beberapa kombinasi neuron (antara 2 sampai 6) pada lapisan pertama dan kedua..
3. Arsitektur yang diperoleh dapat menghasilkan akurasi yang lebih baik dan nilai *error* yang lebih rendah jika dibandingkan dengan penelitian sebelumnya (Dewi dan Ratnawati, 2013).

DAFTAR PUSTAKA

- DEWANTO, W. 2002. *Cuaca dan Iklim*. Pakar Raya. Bandung.
- DEWI, C. DAN MUSLIKH, M. 2012. *Perbandingan Akurasi Backpropagation Neural Network dan ANFIS Untuk Memprediksi Cuaca*. Laporan Penelitian DPP/SPP FMIPA, Universitas Brawijaya.
- DEWI, C. DAN RATNAWATI, D. 2013. *Analisa Pengaruh Metode Clustering pada ANFIS untuk Peramalan Cuaca*. Laporan Penelitian DIPA PTIIK, Universitas Brawijaya.
- FALLAHPOUR, A.R. DAN MOGHASSEM, A.R. 2013. *Yarn Strength Modelling Using Adaptive Neuro-Fuzzy Inference System (ANFIS) and Gene Expression Programming (GEP)*. Journal of Engineered Fibers and Fabrics, Volume 8, Issue 4 – 201, pp:6-18.
- HOMAEINEZHAD, M.R., TAVAKKOLI, E., AFSHAR, A., ATYABI, S. A. DAM GHAFARI, A. 2011. *Neuro-ANFIS Architecture for ECG Rhythm-Type Recognition Using Different QRS Geometrical-Based Features*. Iranian Journal of Electrical & Electronic Engineering, Vol. 7, No. 2, June 2011, pp:70-83.
- JANG, J. S. R. SUN, C. T. E. MIZUTANI. 1997. *Neuro-Fuzzy and Soft Computing*. Prentice Hall. London.
- JANTZEN, JAN. 1998. *Neurofuzzy Modelling*. <http://www.iau.dtu.dk/~jj/pubs/nfmod.pdf> diakses tanggal 11 april 2011.
- KARTIKASARI, D.P. DAN DEWI, C. 2012. *Prediksi Cuaca Pada Data Time Series Menggunakan Adaptive Neuro Fuzzy Inference System (ANFIS)*. Laporan Penelitian DIPA PTIIK, Universitas Brawijaya.
- PUSPITASARI, SUTIJO B.S.U DAN SUHARTONO. 2013. *Model Selection in Adaptive Neuro Fuzzy Inference System (ANFIS) by using Inference of R² Incremental for Time Series Forecasting*. International Journal of Science and Research (IJSR), Volume 2 Issue 2, pp. 38-42.
- SHENG, S. DAN GAO, R.X. 2004. *Architectural Effect on ANFIS for Machine Condition Assessment*. ASME 2004 International Mechanical Engineering Congress and Exposition.
- SHEREEF, K DAN S. SANTHOSH BABOO. 2010. *A New Weather Forecasting Technique using Back Propagation Neural Network with Modified Levenberg-Marquardt Algorithm for Learning*. International Journal of Computer Science Issues, Vol. 8, Issue 6, No 2, November 2011, ISSN (Online): 1694-0814.
- SINGLA, P., H. M. RAI, AND SANJAY SINGLA. 2011. *Local Monsoonal Precipitation forecasting using ANFIS Model: a case study for Hisar*. International Journal of Research and Reviews in Computer Science, Vol.2 No.3.
- TJASYONO, B. 2004. *Klimatologi*. Penerbit ITB. Bandung.