

PENERAPAN METODE CLASSIFICATION BASED ON FUZZY ASSOCIATION RULE (CFAR) UNTUK EVALUASI KINERJA KARYAWAN PT.SIERAD PRODUCE, Tbk

Nike Kartika Sari¹; Dian Eka R²; Lailil Muflikhah³

Program Studi Informatika/Ilmu Komputer Universitas Brawijaya

E-mail: nikekartikasari@gmail.com¹; dian-mac@yahoo.com²; laililmf@gmail.com³

ABSTRAK

Evaluasi kinerja karyawan merupakan faktor penting untuk mendapatkan informasi dalam pengembangan Sumber Daya Manusia (SDM) suatu perusahaan. Evaluasi kinerja karyawan dilakukan berdasarkan kriteria-kriteria sesuai dengan kebijakan perusahaan. Setiap karyawan memiliki nilai yang berbeda untuk setiap kriterianya. Dengan mengetahui kemampuan masing-masing karyawan, perusahaan lebih mudah menentukan langkah-langkah berikutnya dalam usaha meningkatkan kinerja karyawan. Hal ini akan menjadi suatu permasalahan jika dikaitkan dengan keputusan dalam pengembangan SDM selanjutnya.

Penelitian ini mengimplementasikan *Classification based on Fuzzy Association Rule* (CFAR) untuk evaluasi kinerja karyawan. Metode CFAR mampu mengintegrasikan *classification* dan *fuzzy association rule*. Langkah-langkah metode CFAR adalah memetakan atribut-atribut kuantitatif ke dalam himpunan *fuzzy*, kemudian membangkitkan rule klasifikasi menggunakan algoritma *apriori*. Rule yang dihasilkan dilatih menggunakan data latih dan akan dimasukkan dalam *classifier* jika rule mengklasifikasi data latih dengan benar. Rule yang ada dalam *classifier* akan digunakan untuk menentukan kelas dari data uji. Hasil pengujian yang dilakukan menunjukkan tingkat akurasi tertinggi dengan prosentase 89%. Hasil ini diperoleh pada saat *minimum support* 15% dan saat *minimum confidence* 85% pada 300 data latih.

Kata kunci : evaluasi kinerja, *fuzzy*, *classification*, *fuzzy association rule*, algoritma *apriori*, CFAR.

ABSTRACT

Employee performance evaluation is a fundamental factor to get the information in term of Human Resources (HR) development in company. Employee performance evaluation is based on criteria in accordance with company policy. Each employee has a different value for each criteria. By knowing the capabilities of each employee, it will be easier for company to determine the next steps in effort to improve employee performance. It would be a problem if it is associated with subsequent decisions in human resource development.

This study implements *Classification based on Fuzzy Association Rule* (CFAR) for the evaluation of employee performance. CFAR method is capable to integrate fuzzy classification association rules. CFAR method is to map quantitative attributes into fuzzy set, and then generate classification rules using *apriori* algorithm. The results of generate classification rule are trained using trained data and will be put in classifier if the rule classify the data correctly. The rule in the classifier will be used to determine the class of the test data. The results of this research showed the highest level of accuracy with a percentage of 89%. This result was obtained at 15% minimum support and minimum confidence at 85% on 300 trained data.

Key words : Employee performance evaluation, *fuzzy*, *classification*, *fuzzy association rule*, *apriori* algorithm, CFAR.

I. PENDAHULUAN

1.1. Latar Belakang

Evaluasi kinerja karyawan merupakan faktor penting untuk mendapatkan informasi dalam

pengembangan Sumber Daya Manusia (SDM) perusahaan tersebut. Berhasilnya suatu perusahaan sangat dipengaruhi oleh SDM yang berkualitas. Dengan mengetahui kemampuan masing-masing

karyawan, perusahaan lebih mudah menentukan langkah-langkah berikutnya dalam usaha meningkatkan kinerja karyawan. Evaluasi kinerja karyawan dilakukan berdasarkan kriteria-kriteria sesuai dengan kebijakan perusahaan. Kriteria-kriteria tersebut cukup sulit apabila dinyatakan secara tegas. Seorang karyawan yang bekerja dengan disiplin tentunya akan mendapatkan penilaian yang lebih tinggi dari karyawan yang tidak disiplin. Namun, bisa pula karyawan yang mempunyai keahlian komputer akan mempunyai nilai lebih besar bila dibanding dengan karyawan yang tidak punya keahlian komputer. Nilai dari perbandingan hal-hal diatas bersifat tidak tegas atau kabur (*fuzzy*) yang memungkinkan terjadinya kesalahan dalam evaluasi kinerja karyawan suatu perusahaan. Himpunan *fuzzy* dinilai sesuai untuk mengatasi masalah batas tegas. Himpunan *fuzzy* memberikan transisi yang "halus" antara anggota dan non-anggota dalam himpunan [6].

Dalam permasalahan yang terdiri dari atribut-atribut dengan nilai kuantitatif, diusulkan metode *Classification based on Fuzzy Association Rule* (CFAR) karena lebih efektif dan memiliki akurasi lebih baik dibandingkan dengan metode *Classification based on Association* (CBA). Dari penelitian Chen dan Guoqing (2008) diketahui bahwa akurasi metode CFAR untuk *dataset* penyakit jantung sekitar 85,55% dan *dataset wine* sekitar 93,33% lebih baik dibandingkan dengan CBA dengan akurasi 83,33% untuk *dataset* penyakit jantung dan 86,57% untuk *dataset wine* [2].

Penelitian ini mengimplementasikan *Classification based on Fuzzy Association Rule* (CFAR) untuk evaluasi kinerja karyawan. Metode CFAR mampu mengintegrasikan *classification* dan *fuzzy association rule*. Langkah-langkah metode CFAR adalah memetakan atribut-atribut kuantitatif ke dalam himpunan *fuzzy*, kemudian membangkitkan *rule* klasifikasi

menggunakan algoritma apriori. *Rule* yang dihasilkan dilatih menggunakan data latih dan akan dimasukkan dalam *classifier* jika *rule* mengklasifikasi data latih dengan benar.

1.2. Rumusan Masalah

Rumusan masalah dalam penulisan skripsi ini adalah:

1. Bagaimana menerapkan *Classification based on Fuzzy Association Rule Mining* (CFAR) dalam evaluasi kinerja karyawan.
2. Bagaimana pengaruh *minimum support* dan *minimum confidence* terhadap jumlah *rule* yang terbentuk dan akurasi metode CFAR dalam evaluasi kinerja karyawan.

1.3. Batasan Masalah

Batasan masalah dalam penulisan skripsi ini adalah:

1. Data yang dijadikan pelatihan dan pengujian pada skripsi ini adalah data penilaian kinerja karyawan berdasarkan *behavior* karyawan PT Sierad Produce, Tbk semester 1 tahun 2011.
2. Kategori yang dihasilkan dari proses klasifikasi adalah evaluasi kinerja karyawan yang di *training* atau tidak.
3. Setiap atribut kecuali atribut kelas pada data memiliki 5 variabel linguistik.

1.4. Tujuan

Tujuan yang ingin dicapai dari skripsi ini adalah:

1. Menerapkan *Classification based on Fuzzy Association Rule Mining* (CFAR) dalam evaluasi kinerja karyawan.
2. Menghitung pengaruh *minimum support* dan *minimum confidence* terhadap jumlah *rule* yang terbentuk dan akurasi metode CFAR dalam penilaian evaluasi kinerja karyawan.

1.5. Data Mining

Data *mining* adalah serangkaian proses penemuan informasi baru dengan mencari pola atau aturan dari kumpulan data yang berukuran besar. Suatu pola

yang menarik adalah pola yang tidak diketahui sebelumnya dan berguna. Informasi dari data *mining* dapat digunakan sebagai perbaikan pengambilan keputusan di masa mendatang berdasarkan pola yang ada [10].

1.6. Himpunan Fuzzy

Himpunan *fuzzy* merupakan suatu keadaan yang menunjukkan bahwa suatu *item* dalam semesta pembicaraan tidak hanya berada pada 0 atau 1, namun juga terdapat nilai yang terletak diantaranya. Dengan kata lain, masih ada nilai-nilai yang terletak antara benar dan salah.

1.7. Association Rule

Dalam data *mining*, tugas *association rule* adalah mencari pola atau aturan yang tersembunyi untuk mengukur hubungan antara dua atribut atau lebih. *Association rule* meliputi 2 tahap, yaitu [4]:

1. Mencari kombinasi yang paling sering terjadi dari suatu *itemset*.
2. Membangkitkan *association rule* dari *frequent itemset* yang telah dibuat sebelumnya.

1.8. Algoritma Apriori

Pendekatan yang umum digunakan untuk menemukan aturan asosiasi adalah algoritma *Apriori*. Algoritma *apriori* adalah suatu algoritma yang mencari *frequent itemset*. *Itemset* adalah sekumpulan *item*. *Frequent itemset* adalah suatu *itemset* yang memenuhi *min_support*. Suatu *itemset* yang memuat k *item* disebut k -*itemset*. Algoritma ini menggunakan pengetahuan awal yaitu *itemset* mana saja yang paling sering muncul dengan melakukan pendekatan iteratif dimana k -*itemset* digunakan untuk mengeksplorasi $(k+1)$ *itemset*. Pertama-tama cari *frequent 1-itemset* (L_1), gunakan L_1 untuk mencari *frequent 2-itemset* (L_2) dan seterusnya sampai tidak ada lagi *frequent k-itemset* ditemukan [1].

1.9. Classification based on Fuzzy Association Rule

Classification based on Fuzzy Association Rule (CFAR) merupakan metode yang mengintegrasikan masalah klasifikasi dengan teknik *fuzzy association rule mining*. Secara umum, CFAR terdiri dari dua tahap yaitu menemukan atau membangkitkan FCAR dan memilih atau memangkas FCAR untuk membangun sistem klasifikasi (*classifier*) [5].

II. METODE PENELITIAN

2.1. Studi Literatur

Studi literatur menjelaskan dasar teori yang digunakan sebagai penunjang dan pendukung penulisan skripsi

2.2. Perancangan Sistem

Secara umum sistem yang dibangun adalah perangkat lunak yang mengimplementasikan *classification based on fuzzy association rule* (CFAR) untuk klasifikasi kinerja karyawan. *Fuzzy association rule* digunakan untuk menemukan sejumlah aturan dimana bagian konsekuennya berupa atribut kelas. Kemudian aturan-aturan yang terbentuk akan dipilih untuk membentuk *classifier*. Aturan-aturan yang ada dalam *classifier* nantinya akan digunakan untuk mengidentifikasi data uji.

Perangkat lunak yang dibangun menggunakan data evaluasi kinerja karyawan pada PT Sierad Produce, tbk. Perangkat lunak ini akan menguji keakuratan hasil klasifikasi data evaluasi kinerja karyawan terhadap data sebenarnya. Parameter yang digunakan dalam pengujian yaitu *minimum support* dan *minimum confidence*. Sistem ini bertujuan untuk menentukan apakah seorang karyawan mengikuti *training/pelatihan* atau tidak mengikuti *training/pelatihan* berdasarkan beberapa atribut yang digunakan.

2.3. Implementasi

Perangkat lunak yang digunakan dalam pengembangan program enkripsi citra digital dan uji coba adalah:

1. Sistem operasi *Windows 7* 64-bit sebagai tempat aplikasi dijalankan.
2. *NetBeans IDE 7.0* sebagai *programming software development* dalam pembuatan aplikasi klasifikasi penilaian kinerja karyawan.
3. Bahasa pemrograman *Java*

2.4. Pengujian dan Analisa


Pengujian yang dilakukan yaitu pengujian untuk mengetahui pengaruh perubahan nilai *minimum support* dan *minimum confidence* terhadap jumlah *rule* yang terbentuk dan terhadap akurasi klasifikasi. Kemudian dilakukan analisa terhadap hasil pengujian.

III. PERANCANGAN

Pada perancangan sistem klasifikasi data kinerja karyawan, diperlukan dua proses utama yaitu proses pembentukan aturan dan proses pengujian.

3.1. Proses Pembentukan Aturan

Proses pembentukan aturan (*rules*) merupakan proses untuk mendapatkan sejumlah aturan *fuzzy* menggunakan algoritma FCAR. Proses ini terdiri dari 4 subproses yaitu transformasi ke data *fuzzy*, normalisasi, *mining* FCAR dan proses membangun *classifier*. Masukan yang diperlukan pada proses ini yaitu data kinerja karyawan pada PT Sierad Produce, Tbk, *minimum support* (*min_sup*) dan *minimum confidence* (*min_conf*) yang diberikan oleh pengguna sedangkan keluaran proses berupa aturan *fuzzy* yang disebut *fuzzy class association rule* (FCAR). Alur proses pembentukan aturan (*rules*) pada gambar 1 adalah sebagai berikut :



Gambar 1 Flowchart Proses Pembentukan Aturan

3.1.1. Transformasi ke Data Fuzzy

Proses ini mengubah nilai kuantitatif pada setiap atribut menjadi derajat keanggotaan *fuzzy* beserta linguistiknya berdasarkan fungsi keanggotaan masing-masing atribut. Fungsi keanggotaan *fuzzy* ditunjukkan pada persamaan 1 [7].

$$\mu[x] = \begin{cases} 0; & x \leq a \text{ atau } x \geq d \\ \frac{(x-a)}{(b-a)}; & a \leq x \leq b \\ 1; & b \leq x \leq c \\ \frac{(d-x)}{(d-c)}; & c \leq x \leq d \end{cases} \quad \dots(1)$$

3.1.2. Normalisasi

Normalisasi dilakukan untuk setiap linguistik pada setiap atribut agar nilai derajat keanggotaan atribut tersebut berjumlah 1. Perhitungan normalisasi dilakukan dengan membagi derajat keanggotaan untuk linguistik ke-*k* pada atribut ke-*j* pada baris (data) ke-*i* dengan jumlah total derajat keanggotaan atribut ke-*j* pada data ke-*i* seperti pada persamaan 2 [2].

$$t'_i[i_j] = \begin{cases} t_i[i_j] / \sum_{j=1}^{q_k} t_i[i_j] & \text{jika } i_j \text{ adalah fuzzy} \\ t_i[i_j] & \text{jika } i_j \text{ kategori} \end{cases} \quad \dots(2)$$

3.1.3. Proses Mining FCAR

Proses *mining* FCAR (Fuzzy Class Association Rules) merupakan proses penerapan algoritma FCAR untuk membentuk aturan dari data yang telah dinormalisasi. Masukan yang diperlukan pada proses *mining* FCAR ialah data yang ternormalisasi, *minimum support* (*min_sup*) dan *minimum confidence* (*min_conf*). Proses ini memiliki 2 subproses yaitu membangkitkan *frequent 1-itemset* L1 dan pembangkitan *rule*.

Langkah awal yang dilakukan pada proses ini yaitu subproses membangkitkan *frequent 1-itemset* L1 dengan cara menghitung kardinalitas skalar setiap linguistik untuk setiap atribut menggunakan persamaan 3 [5].

$$Card(a_j^k) = \sum_{i=1}^n \mu_{a_j^k}^l(x_{ij}) \quad (j = 1, \dots, m; k = 1, \dots, l) \quad \dots (3)$$

Perhitungan kardinalitas skalar dilakukan dengan menjumlahkan derajat keanggotaan pada setiap *record* untuk setiap linguistik pada atribut. Kardinalitas skalar yang lebih atau sama dengan *minimum support* (*min_sup*) akan dimasukkan dalam *frequent 1-itemset* L1.

Langkah selanjutnya ialah membentuk kandidat Ck dari *frequent 1-itemset* L1 dan menghitung *support* setiap kandidat. Nilai *support* sebuah item diperoleh dengan rumus berikut[8] :

$$Support(A) = \frac{\text{Jumlah transaksi mengandung } A}{\text{Total transaksi}} \quad \dots (4)$$

Sedangkan nilai *support* dari 2 item diperoleh dengan rumus sebagai berikut:

$$Support(A, B) = \frac{\sum \text{Transaksi mengandung } A \text{ dan } B}{\sum \text{Transaksi}} \quad \dots (5)$$

Support yang lebih atau sama dengan *minimum support* selanjutnya akan dimasukkan dalam *frequent 2-itemset* L2. Proses ini berulang hingga tidak ada lagi himpunan *itemset* dalam Lk. Subproses selanjutnya yaitu pembangkitan *rule* yang merupakan proses untuk membuat aturan dari himpunan *frequent itemset* yang dihasilkan tahapan sebelumnya. Aturan

yang dibuat ialah aturan klasifikasi *fuzzy* yang mana bagian konsekuennya merupakan atribut kelas[1].

Setiap aturan yang dibentuk akan dihitung nilai *confidence*-nya menggunakan persamaan 6 [8].

$$Confidence = \frac{\sum \text{Transaksi mengandung } A \text{ dan } B}{\sum \text{Transaksi mengandung } A} \quad \dots (6)$$

Aturan dengan *confidence* yang lebih besar atau sama dengan *minimum confidence* (*min_conf*) yang telah ditentukan akan disimpan untuk digunakan pada proses selanjutnya yaitu membangun *classifier*.

3.1.4. Membangun Classifier

Proses membangun *classifier* bertujuan untuk melatih aturan (FCAR) yang diperoleh dari proses pembentukan aturan (*rules*). Pelatihan dilakukan dengan menghitung nilai *DF* setiap *rule*. *DF* merupakan perkalian derajat keanggotaan *items* pada data ke-n yang bersesuaian dengan *rule* ke-*r* seperti pada rumus 7 .

$$DF = (d) * Conf(r) \quad \dots (7)$$


dimana *Conf(r)* adalah nilai *confidence* aturan *r* dan $\mu_F(d)$ derajat keanggotaan atribut pada *record d* yang bersesuaian dengan aturan *r* [2].

Kemudian memilih aturan secara berurutan hingga *record* terklasifikasi dengan benar untuk setiap aturan *RightN* dan *WrongN* digunakan untuk menyimpan jumlah data yang diklasifikasikan benar atau salah. Proses ini dilakukan untuk setiap *record*. Aturan terburuk yaitu aturan yang nilai *RightN*-nya sama dengan 0 dan satu aturan dengan nilai (*RightN*/(*RightN*+*WrongN*)) terkecil akan dihapus dari *classifier*.

3.2. Proses Pengujian

Proses pengujian merupakan proses untuk mengetahui tingkat keakuratan aturan yang terbentuk. Proses ini terdiri dari 3 subproses yaitu transformasi ke data *fuzzy*, normalisasi dan perhitungan *discriminant function*. Masukan yang diperlukan pada proses pengujian berupa data uji yang terbentuk

dari proses sebelumnya. Sedangkan keluarannya berupa hasil klasifikasi kelas yaitu menentukan apakah seorang karyawan mengikuti *training*/pelatihan atau tidak mengikuti *training*/pelatihan. Alur proses pengujian pada gambar 2 adalah sebagai berikut :



Gambar 2 Flowchart Proses Pengujian

3.2.1. Perhitungan *discriminant function*

Untuk mengidentifikasi atau mengklasifikasikan data uji, dilakukan perhitungan *discriminant function* setiap kelas untuk setiap FCAR sesuai dengan persamaan 8, kemudian membandingkan *discriminant function* setiap kelas dan kelas yang nilai *discriminant function*nya tertinggi akan digunakan untuk mengklasifikasi data uji.

$$g_h(y) = \frac{\sum_{1 \leq k \leq M, i=C_k} \prod_{j=1}^{l_k} B(i, k)[X(j, k)(y)]}{\sum_{k=1}^M \prod_{j=1}^{l_k} B(i, k)[X(j, k)(y)]} \quad \dots(8)$$

dimana $X(j, k)(y)$ adalah nilai atribut $X(j, k)$ pada sampel y , $B(i, k)[X(j, k)(y)]$ adalah derajat keanggotaan $X(j, k)(y)$ pada fuzzy set $B(j, k)$. Setelah *discriminant function* untuk setiap kelas dihitung, maka diambil label kelas dengan nilai *discriminant function*nya terbesar untuk mengklasifikasi sampel y [9].

IV. HASIL DAN PEMBAHASAN

Terdapat 2 pengujian yang dilakukan yaitu pengujian untuk mengetahui pengaruh perubahan nilai *minimum support* dan *minimum confidence* terhadap jumlah *rule* yang terbentuk melalui proses membangkitkan *rule* dan pengujian untuk mengetahui pengaruh *minimum support* dan *minimum confidence* terhadap akurasi klasifikasi.

Data latih yang digunakan dibagi menjadi tiga, yaitu 100 *record* data, 200 *record* data, dan semua data (300 *record*). Pada dua data latih pertama, data diambil secara acak sebanyak 10 kali perulangan. Masing-masing data latih tersebut diuji dengan mengubah nilai *minimum support* dan *minimum confidence* yang telah ditentukan. *Rule* yang terbentuk untuk masing-masing dijumlahkan dan diambil nilai rata-ratanya. Data uji yang digunakan untuk 100, 200 dan 300 *record* data latih adalah data latih itu sendiri atau masing-masing.

4.1 Pengaruh *minimum support* dan *minimum confidence* terhadap jumlah *rule* dalam *classifier*

Pengujian jumlah *rule* yang terbentuk dilakukan pada 3 macam data latih dengan jumlah data berbeda. Pengujian untuk masing-masing data latih dilakukan sebanyak 88 kali dengan mengubah nilai *minimum support* dan *minimum confidence* untuk mendapatkan jumlah *rule* yang terbentuk.


Rata-rata jumlah *rule* yang terbentuk dan jumlah *rule* dalam *classifier* dari 100 *record* data dapat dilihat pada table 1, table 2, dan gambar 1.

Tabel 1 Rata-rata Jumlah *Rule* yang Terbentuk (100 *record*)

MinConf (%)	Jumlah Rule							
	MinSup (%)							
	15	20	25	30	35	40	45	50
50	537	95	28	12	4	1	0	0
55	515	86	28	9	4	1	0	0
60	485	77	23	7	2	1	0	0
65	348	64	18	5	1	1	0	0
70	371	50	12	3	1	0	0	0
75	248	32	9	2	1	0	0	0
80	116	18	5	1	0	0	0	0
85	23	7	3	1	0	0	0	0
90	14	3	2	0	0	0	0	0
95	7	1	0	0	0	0	0	0
100	0	0	0	0	0	0	0	0

Tabel 2 Rata-rata Jumlah Rule Dalam Classifier (100 record)

MinConf (%)	Jumlah Rule									
	MinSup (%)									
	15	20	25	30	35	40	45	50		
50	32	25	16	8	3	1	0	0		
55	32	24	14	6	3	1	0	0		
60	31	23	13	4	2	1	0	0		
65	31	21	11	3	1	0	0	0		
70	30	19	7	2	1	0	0	0		
75	28	15	5	1	0	0	0	0		
80	25	7	3	1	0	0	0	0		
85	17	5	2	0	0	0	0	0		
90	12	3	1	0	0	0	0	0		
95	5	0	0	0	0	0	0	0		
100	0	0	0	0	0	0	0	0		



Gambar 3 Grafik jumlah rule dalam classifier pada 100 record

Tabel 1 menunjukkan bahwa rata-rata jumlah rule terbanyak yang dibentuk adalah 537 rule saat *minimum support* 15% dan *minimum confidence* 50%. Tabel 2 dan gambar 3 menunjukkan bahwa rata-rata jumlah rule terbanyak dalam classifier adalah 32 rule saat *minimum support* 15% dan *minimum confidence* 50%. Sedangkan, jumlah rule terkecil (sama) yaitu 0 atau tidak menghasilkan rule sama sekali. Kurva yang dihasilkan pada semua *minimum confidence* terus menurun hingga ke titik nol untuk setiap perubahan *minimum support*.


Rata-rata jumlah rule yang terbentuk dan jumlah rule dalam classifier dari 200 record data dapat dilihat pada table 3, table 4, dan gambar 4.

Tabel 3 Rata-rata Jumlah Rule yang Terbentuk (200 record)

MinConf (%)	Jumlah Rule									
	MinSup (%)									
	15	20	25	30	35	40	45	50		
50	616	89	30	11	6	1	0	0		
55	591	83	26	8	4	1	0	0		
60	562	72	21	6	3	1	0	0		
65	507	58	14	4	1	1	0	0		
70	396	39	7	1	0	0	0	0		
75	247	19	3	1	0	0	0	0		
80	66	8	2	0	0	0	0	0		
85	8	4	2	0	0	0	0	0		
90	2	1	1	0	0	0	0	0		
95	0	0	0	0	0	0	0	0		
100	0	0	0	0	0	0	0	0		

Tabel 4 Rata-rata Jumlah Rule Dalam Classifier (200 record)

MinConf (%)	Jumlah Rule									
	MinSup (%)									
	15	20	25	30	35	40	45	50		
50	54	33	18	10	4	1	0	0		
55	52	32	17	7	3	1	0	0		
60	51	31	15	4	2	1	0	0		
65	50	28	12	3	1	1	0	0		
70	47	28	6	1	0	0	0	0		
75	41	15	2	0	0	0	0	0		
80	23	7	1	0	0	0	0	0		
85	7	3	1	0	0	0	0	0		
90	1	1	0	0	0	0	0	0		
95	0	0	0	0	0	0	0	0		
100	0	0	0	0	0	0	0	0		



Gambar 4 Grafik jumlah rule dalam classifier pada 200 record

Tabel 3 menunjukkan bahwa rata-rata jumlah rule terbanyak yang dibentuk adalah 616 rule saat *minimum support* 15% dan *minimum confidence* 50%. Tabel 4 dan gambar 4 menunjukkan bahwa rata-rata jumlah rule terbanyak dalam classifier adalah 54 rule saat *minimum support* 15% dan *minimum confidence* 50%. Sedangkan, jumlah rule terkecil (sama) yaitu 0 atau tidak menghasilkan rule sama sekali. Kurva yang dihasilkan pada semua *minimum confidence* terus menurun hingga ke titik nol untuk setiap perubahan *minimum support*.


Rata-rata jumlah rule yang terbentuk dan jumlah rule dalam classifier dari 300 record data dapat dilihat pada table 5, table 6, dan gambar 5.

Tabel 5 Pengujian Jumlah Rule yang Terbentuk (300 record)

MinConf (%)	Jumlah Rule									
	MinSup (%)									
	15	20	25	30	35	40	45	50		
50	427	94	29	11	6	2	0	0		
55	425	93	28	10	6	2	0	0		
60	408	84	24	7	4	2	0	0		
65	384	76	20	5	2	2	0	0		
70	339	54	11	3	1	1	0	0		
75	234	36	4	1	0	0	0	0		
80	130	13	1	0	0	0	0	0		
85	17	5	1	0	0	0	0	0		
90	2	0	0	0	0	0	0	0		
95	0	0	0	0	0	0	0	0		
100	0	0	0	0	0	0	0	0		

Tabel 6 Jumlah Rule Dalam Classifier (300 record)

MinConf (%)	Jumlah Rule							
	MinSup (%)							
	15	20	25	30	35	40	45	50
50	63	44	23	9	5	1	0	0
55	62	44	23	9	5	1	0	0
60	62	43	20	6	3	1	0	0
65	60	42	18	4	1	1	0	0
70	59	36	10	2	0	0	0	0
75	57	26	3	0	0	0	0	0
80	41	11	0	0	0	0	0	0
85	14	4	0	0	0	0	0	0
90	1	0	0	0	0	0	0	0
95	0	0	0	0	0	0	0	0
100	0	0	0	0	0	0	0	0



Gambar 5 Grafik jumlah rule dalam classifier pada 300 record

Tabel 5 menunjukkan bahwa rata-rata jumlah rule terbanyak yang dibentuk adalah 427 rule saat *minimum support* 15% dan *minimum confidence* 50%. Tabel 6 dan gambar 3 menunjukkan bahwa rata-rata jumlah rule terbanyak dalam classifier adalah 63 rule saat *minimum support* 15% dan *minimum confidence* 50%. Sedangkan, jumlah rule terkecil (sama) yaitu 0 atau tidak menghasilkan rule sama sekali. Kurva yang dihasilkan pada semua *minimum confidence* terus menurun hingga ke titik nol untuk setiap perubahan *minimum support*.

Hasil pengujian diatas, dari 3 macam data latih dengan jumlah data yang berbeda, diketahui bahwa semakin tinggi *minimum support* dan *minimum confidence* yang digunakan, maka semakin sedikit rule yang terbentuk. Perubahan nilai *minimum support* dan *minimum confidence* berpengaruh terhadap jumlah rule yang terbentuk. Nilai *minimum support* yang merupakan batasan kemunculan suatu items bersamaan yang semakin tinggi akan menghasilkan *frequent itemsets* yang semakin sedikit sehingga mengakibatkan semakin kecil kemungkinan kandidat rule yang akan dibentuk. Ditambah lagi

jika nilai *minimum confidence* yang digunakan semakin tinggi, kemungkinan kandidat rule yang memenuhi nilai tersebut juga akan semakin sedikit. Rule yang dibangkitkan pada semua data latih akan mengalami proses membangun classifier. Berdasarkan hasil uji coba diketahui bahwa jumlah rule yang masuk dalam classifier lebih sedikit dari pada jumlah rule awal yang dibangkitkan. Jumlah rule dalam classifier pada semua *minimum confidence* yang digunakan cenderung menurun seiring dengan kenaikan nilai *minimum support*.


4.2 Pengujian pengaruh *minimum support* dan *minimum confidence* terhadap akurasi

Pengujian pengaruh *minimum support* dan *minimum confidence* terhadap akurasi dilakukan pada data uji 100 record, 200 record dan 300 record data menggunakan rule yang dibangkitkan oleh 3 data latih pada pengujian pertama yang telah melewati proses membangun classifier. Hasil klasifikasi sistem kemudian dibandingkan dengan kelas aktual pada data uji.

Rata-rata hasil pengujian akurasi menggunakan rule dalam classifier dari 100 data latih dapat dilihat pada tabel 7 dan gambar 6.

Tabel 7 Rata-rata Pengujian Akurasi (100 data latih)

MinConf (%)	Akurasi							
	MinSup (%)							
	15	20	25	30	35	40	45	50
50	86,7	80,6	76	56,3	19,5	0	0	0
55	86,7	80,6	76,5	54,4	13,4	0	0	0
60	87,7	79,9	74,3	31,5	0	0	0	0
65	87,7	81,9	78	8,3	0	0	0	0
70	88,3	83,4	46,8	0	0	0	0	0
75	85,7	58,5	39,8	0	0	0	0	0
80	82,3	49,6	8,7	0	0	0	0	0
85	80,7	15,5	0	0	0	0	0	0
90	78,7	8	0	0	0	0	0	0
95	54,3	0	0	0	0	0	0	0
100	0	0	0	0	0	0	0	0




Gambar 6 Grafik akurasi pada 100 record

Tabel 7 menunjukkan bahwa akurasi tertinggi yang diperoleh adalah 88,3% yaitu saat *minimum support* 15% dan *minimum confidence* 70%. Akurasi terendah adalah 0% atau tidak ada akurasi, karena pada proses pembangkitan *rule* tidak ada *rule* yang terbentuk yang memenuhi batasan nilai *minimum confidence* sehingga tidak dapat dilakukan proses klasifikasi pada data uji. Gambar 6 menunjukkan rata-rata akurasi pada semua *minimum confidence* cenderung menurun pada setiap kenaikan *minimum support*.

Rata-rata hasil pengujian akurasi menggunakan *rule* dalam *classifier* dari 100 data latih dapat dilihat pada tabel 8 dan gambar 7.

Tabel 8 Rata-rata Pengujian Akurasi (200 data latih)

MinConf (%)	Akurasi								
	MinSup (%)								
	15	20	25	30	35	40	45	50	
50	81,6	72,2	69,4	36,8	32,3	0	0	0	0
55	81	71,6	66,9	13,8	0	0	0	0	0
60	81	73,3	70,4	7,3	0	0	0	0	0
65	82	75,2	75,1	7,4	0	0	0	0	0
70	84,3	80,6	81,1	0	0	0	0	0	0
75	86	85,2	17,4	0	0	0	0	0	0
80	85,3	50,7	0	0	0	0	0	0	0
85	53,7	0	0	0	0	0	0	0	0
90	0	0	0	0	0	0	0	0	0
95	0	0	0	0	0	0	0	0	0
100	0	0	0	0	0	0	0	0	0




Gambar 7 Grafik akurasi pada 200 record

Tabel 8 menunjukkan bahwa rata-rata akurasi tertinggi yang diperoleh sebesar 86% yaitu saat *minimum support* 15% dan *minimum confidence* 75%. Akurasi terendah yang diperoleh sama seperti pada 100 data latih yaitu sebesar 0% atau dapat dikatakan tidak terjadi proses klasifikasi. Gambar 7 menunjukkan rata-rata akurasi pada semua *minimum confidence* cenderung menurun pada setiap kenaikan *minimum support*.

Hasil pengujian akurasi menggunakan *rule* dalam *classifier* dari 300 data latih (semua data) dapat dilihat pada tabel 9 dan gambar 8.

Tabel 9 Hasil Pengujian Akurasi (300 data latih)

MinConf (%)	Akurasi								
	MinSup (%)								
	15	20	25	30	35	40	45	50	
50	81	68,7	56	0	0	0	0	0	0
55	80,7	68,7	56	0	0	0	0	0	0
60	80,7	69,7	59,3	0	0	0	0	0	0
65	80,7	70,7	63,3	0	0	0	0	0	0
70	80,7	74,7	71,3	0	0	0	0	0	0
75	82,3	80	80	0	0	0	0	0	0
80	86,7	87	0	0	0	0	0	0	0
85	89	0	0	0	0	0	0	0	0
90	0	0	0	0	0	0	0	0	0
95	0	0	0	0	0	0	0	0	0
100	0	0	0	0	0	0	0	0	0



Gambar 8 Grafik akurasi pada 300 record


Berdasarkan tabel 9, akurasi tertinggi yang diperoleh sebesar 89% yaitu saat *minimum support* 15% dengan *minimum confidence* 85%. Sedangkan akurasi terendah adalah 0% atau tidak terjadi proses klasifikasi karena tidak ada *rule* yang dibangkitkan. Gambar 8 menunjukkan rata-rata akurasi pada semua *minimum confidence* cenderung menurun pada setiap kenaikan *minimum support*.

Hasil pengujian yang dilakukan menunjukkan tingkat akurasi tertinggi

dengan prosentase 89,3%. Hasil ini diperoleh pada saat *minimum support* 15% dan saat *minimum confidence* 80% pada 200 data latih menggunakan 50 data uji.

Berdasarkan hasil pengujian akurasi pada data uji menggunakan rule yang dibangkitkan dari 3 macam data latih, diketahui bahwa rata-rata akurasi pada semua *minimum confidence* cenderung menurun pada setiap kenaikan *minimum support*. Penurunan akurasi ke titik nol menunjukkan bahwa tidak ada rule yang dapat digunakan untuk mengklasifikasi data uji sehingga tidak dapat dilakukan perhitungan akurasi. Jika rule yang dibangkitkan sedikit akibat nilai *minimum support* dan *confidence* yang tinggi maka kemungkinan rule yang dibangkitkan dengan bagian konsekuen hanya pada salah satu kelas menjadi besar sehingga peluang data terklasifikasi ke kelas.

Jumlah rule yang dihasilkan tidak mempengaruhi akurasi yang dihasilkan. Dapat dilihat pada gambar 4.9, diketahui pada data latih 100 record akurasi tertinggi yaitu 88,3% dengan jumlah rule yang terbentuk dalam classifier sebanyak 30 rule, pada data latih 200 record akurasi tertinggi yaitu 86% dengan jumlah rule yang terbentuk dalam classifier sebanyak 41 rule, dan pada data latih 300 record akurasi tertinggi yaitu 89% dengan jumlah rule yang terbentuk dalam classifier sebanyak 14 rule.



Gambar 4.15 Grafik Pengaruh akurasi terhadap jumlah rule yang terbentuk dalam classifier

Berdasarkan gambar 4.9, diketahui bahwa hasil pengujian jumlah rule dan pengujian akurasi, hasilnya tidak berkesinambungan. Hal ini dikarenakan padaperhitungan akurasi pengecekan dilakukan dengan penggabungan seluruh rule dan dilakukan pengecekan kebenaran terhadap data. Oleh karena itu benar atau salahnya rule, tergantung dari kombinasi atribut di dalam satu rule yang dihasilkan sehingga tidak dapat diprediksi dengan semakin banyak rule maka semakin baik pula akurasinya.

V. Kesimpulan

Berdasarkan hasil pengujian dan analisis yang telah dilakukan dapat diambil kesimpulan sebagai berikut :

1. Metode *classification based on fuzzy association rule* (CFAR) dapat diimplementasikan untuk mengklasifikasi evaluasi kinerja karyawan. Proses awal yang dilakukan adalah dengan mentransformasi data latih menjadi data fuzzy menggunakan fungsi keanggotaan untuk masing-masing atribut. Kemudian melakukan pembangkitan rule yang mana bagian konsekuennya merupakan atribut kelas. Rule yang dibangkitkan dilatih menggunakan data latih dan rule yang mengklasifikasikan data latih dengan benar dimasukkan dalam classifier. Rule dalam classifier ini yang akan digunakan untuk mengidentifikasi atau menentukan kelas output data uji. Data uji yang digunakan berasal dari data latih.
2. Parameter *minimum support* dan *minimum confidence* berpengaruh pada proses pembangkitan rule. Semakin tinggi nilai *minimum support* dan *minimum confidence* yang digunakan semakin sedikit rule yang dihasilkan. Sedangkan terhadap akurasi, *minimum support* dan *minimum confidence* berpengaruh ketika nilai yang digunakan semakin tinggi karena pada pasangan *minimum support* dan *minimum confidence* yang tinggi kemungkinan rule yang dihasilkan hanya mewakili salah satu

kelas besar dan kemungkinan tidak menghasilkan *rule* juga besar. Parameter *minimum support* dan *minimum confidence* berpengaruh pada proses pembangkitan *rule*. Semakin tinggi nilai *minimum support* dan *minimum confidence* yang digunakan semakin sedikit *rule* yang dihasilkan. Sedangkan terhadap akurasi, *minimum support* dan *minimum confidence* berpengaruh ketika nilai yang digunakan semakin tinggi karena pada pasangan *minimum support* dan *minimum confidence* yang tinggi kemungkinan *rule* yang dihasilkan hanya mewakili salah satu kelas besar dan kemungkinan tidak menghasilkan *rule* juga besar.

Saran yang dapat diberikan untuk dijadikan bahan dalam penelitian lebih lanjut, antara lain adalah :

1. Menggunakan metode *association rule* selain *apriori* seperti ID3, *pincer search*, FP-Growth, dan lain-lain.
2. Melakukan klasifikasi lebih detail pada target, misalnya target pada penelitian ini adalah karyawan yang mengikuti *training* dan tidak mengikuti *training*, untuk target *training* dapat diklasifikasikan lagi sesuai atribut masing-masing.

DAFTAR PUSTAKA

- [1] Agrawal, R dan Srikant, R. 1994. *Fast Algorithms for Mining Association Rules*. Chile : Proceedings of the 20th International Conference on Very Large Data Bases.
- [2] Chen, Zuoliang., dan Chen, Guoqing. 2008. Building An Associative Classifier Based On Fuzzy Association Rules. *International Journal of Computational Intelligence Systems*.
- [3] Gyenesei, Attila. 2001. *A Fuzzy Approach for Mining Quantitative Association Rule*. Finland : University of Turku.
- [4] Han, Jiawei and Khamber, Micheline. 2001. *Data mining : Concepts and Techniques*. San Francisco, USA : Morgan Kaufmann Publishers.
- [5] Jin, Weiqing. 2004. *Fuzzy Classification Based on Fuzzy Association Rule Mining*. North Carolina State University.
- [6] Kuok, C.M., Fu, A. dan Wong, M.H. 1998. *Mining Fuzzy Association Rule in Database* (Online, <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.55.684>, diakses tanggal 20 Februari 2012).
- [7] Kusumadewi, S dan Purnomo, H. 2010. *Aplikasi Logika Fuzzy untuk Pendukung Keputusan: Jilid 2*. Yogyakarta : Graha Ilmu.
- [8] Kusrini. 2007. *Konsep dan Aplikasi Sistem Pendukung Keputusan*. Penerbit ANDI, Yogyakarta.
- [9] Lu, Jianjiang., Xu, Baowen., dan Yang, Hongji. 2003. *A Classification Method of Fuzzy Association Rules*. Ukraine: IEEE International workshop on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications.
- [10] Santosa, Budi. 2007. *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Yogyakarta : Graha Ilmu.