

Implementasi Fuzzy C-Means dan Possibilistik C-Means Pada Data Performance Mahasiswa

Gadis Retno Apsari¹, Mohammad Syaiful Pradana², Novita Eka Chandra³

¹Universitas Islam Darul Ulum Lamongan, gadisretnoapsari57@gmail.com

²Universitas Islam Darul Ulum Lamongan, syaifulp@unisda.ac.id

³Universitas Islam Darul Ulum Lamongan, novitaeka@unisda.ac.id

Abstract. Students are the most important component in a university, especially private universities especially Universitas Islam Darul 'ulum (Unisda) Lamongan. One of the most important roles of students for higher education is achievement. This study aims to determine the role of Fuzzy Clustering in classifying student performance data. The data includes GPA (Grade Point Average), ECCU (Extra-Curricular Credit Unit), attendance, and students' willingness to learn. So that groups of students who have the potential to have achievements can be identified. In this case, the grouping of student performance data uses Fuzzy Clustering by applying the Fuzzy C-Means (FCM) and Possibilistic C-Means (PCM) algorithms with the help of Matlab. In the FCM algorithm, the membership degree is updated so as to produce a minimum objective function value. Meanwhile, the PCM algorithm uses a T matrix, which shows the peculiarities of the data which are also based on minimizing the objective function.

Keywords: *Students Performance Data, Fuzzy Clustering, Fuzzy C-Means (FCM), Possibilistic C-Means (PCM).*

Abstrak Mahasiswa merupakan komponen terpenting dalam sebuah Perguruan Tinggi terutama Perguruan Tinggi Swasta seperti Universitas Islam Darul 'ulum (Unisda) Lamongan. Salah satu peranan terpenting mahasiswa untuk perguruan tinggi adalah prestasi. Penelitian ini bertujuan untuk mengetahui peranan *Fuzzy Clustering* dalam mengelompokkan data performance mahasiswa. Data tersebut meliputi IPK (Indeks Prestasi Kumulatif), SKEK (Satuan Kredit Ekstra Kurikuler), presensi, dan kemauan belajar mahasiswa. Sehingga kelompok mahasiswa yang berpotensi memiliki prestasi dapat diketahui. Dalam hal ini pengelompokan data performance mahasiswa menggunakan *Fuzzy Clustering* dengan menerapkan algoritma *Fuzzy C-Means* (FCM) dan *Possibilistic C-Means* (PCM) dengan bantuan *Matlab*. Pada algoritma FCM, derajat keanggotaan diupdate sehingga menghasilkan nilai fungsi objective yang minimum. Sedangkan algoritma PCM menggunakan suatu matriks *T*, yang menunjukkan kekhasan dari suatu data juga didasarkan pada minimisasi fungsi obyektif.

Kata kunci: *Data Performance Mahasiswa, Fuzzy Clustering, Fuzzy C-Means (FCM), Possibilistic C-Means (PCM).*

1 Pendahuluan

Mahasiswa merupakan komponen terpenting dalam sebuah Perguruan Tinggi terutama Perguruan Tinggi Swasta seperti Universitas Islam Darul ‘ulum (Unisda) Lamongan. Salah satu peranan terpenting mahasiswa untuk perguruan tinggi adalah prestasi. Peranan mahasiswa dilingkungan Perguruan Tinggi sangatlah dibutuhkan. Terlebih jika mahasiswa mempunyai kemauan yang tinggi dalam menuntut ilmu, sehingga dapat mengharumkan nama Perguruan Tinggi.

Hal yang perlu dilakukan untuk mengetahui mahasiswa berprestasi tersebut dengan cara mengelompokkan mahasiswa berdasarkan aspek-aspek kemahasiswaan seperti: IPK (Indeks Prestasi Kumulatif), SKEK (Satuan Kredit Ekstra Kurikuler), presensi kehadiran dan kemauan belajar mahasiswa. Pengelompokkan data bertujuan untuk mengetahui kelompok mahasiswa yang berpotensi untuk menjadi mahasiswa berprestasi.

Clustering adalah suatu alat untuk analisa data yang memecahkan permasalahan penggolongan. Suatu algoritma *clustering* dikatakan sebagai algoritma *fuzzy clustering* jika dan hanya jika algoritma tersebut menggunakan parameter strategi adaptasi secara *soft competitive (non - crisp)* [1]. Sebagian besar algoritma *fuzzy clustering* didasarkan atas optimasi fungsi obyektif atau modifikasi dari fungsi obyektif tersebut. Dalam hal ini pengelompokan data performance mahasiswa menggunakan *Fuzzy Clustering* dengan menerapkan algoritma *Fuzzy C-Means* (FCM) dan *Possibilistic C-Means* (PCM) dengan bantuan *Matlab*.

Penelitian ini bertujuan untuk mengetahui peranan *Fuzzy Clustering* dalam mengelompokkan data performance mahasiswa. Data yang sudah dikelompokkan maka diharapkan data tersebut akan mempermudah Perguruan Tinggi dalam mengetahui potensi mahasiswa berdasarkan kriteria yang diberikan.

2 Tinjauan Pustaka

Clustering merupakan teknik multivariat yang bertujuan untuk mengelompokkan atau meng*cluster* suatu objek menjadi beberapa bagian berdasarkan karakteristik dan kemungkinan yang sama sehingga setiap anggota pada satu *cluster* mempunyai kesamaan yang tinggi dan sangat berbeda pada satu *cluster* dengan *cluster* yang lain. *Clustering* biasanya diterapkan pada pengambilan keputusan, *image segmentation*, klasifikasi susunan gambar atau pola. Pada analisis *cluster* terdapat dua tipe pengelompokkan yaitu *crisp clustering* dan *fuzzy clustering* sedangkan menurut [2] pada *fuzzy clustering* terdapat partisi possibilistik (*possibilistic partition*). Pada proses pengelompokkan *crisp clustering* pembentukan kelompok dilakukan hingga setiap objek berada tepat pada satu kelompok dan mengabaikan kemungkinan jika suatu objek tersebut berada pada kelompok lain [3]. Akan tetapi jika objek yang akan dikelompokkan tersebut berada pada dua kelompok atau lebih maka di perlukan suatu metode yaitu *fuzzy clustering*. *Fuzzy clustering* merupakan metode pengelompokkan suatu objek dengan mempertimbangkan derajat keanggotaan pada himpunan *fuzzy* sebagai dasar pembobotan [4].

Metode *fuzzy clustering* merupakan metode untuk meng*cluster* atau menentukan kelompok yang optimal dalam suatu ruang vektor yang jaraknya didasarkan pada bentuk normal *Euclidian*. Setiap data dilengkapi dengan derajat

keanggotaan himpunan *fuzzy* sehingga data mempunyai nilai kemungkinan untuk bisa bergabung pada setiap kelompok yang ada sehingga, data tidak terfokus pada satu kelompok saja akan tetapi juga mempunyai kemungkinan untuk menjadi anggota kelompok yang lain dengan derajat keanggotaan yang berbeda-beda [5]. Adapun yang termasuk pada metode *fuzzy clustering* yaitu *Fuzzy C-Means* (FCM).

Pada *fuzzy clustering* terdapat partisi *possibilistik* (*possibilistic partition*). Partisi *possibilistik* (*possibilistic partition*) merupakan metode untuk mengcluster dengan menjelaskan *possibilistic* dan *probabilistic* yang diinterpretasikan pada matriks kekhasan atau *typicality value*. *Possibilistic partition* merupakan metode untuk menentukan kelompok yang optimal dalam suatu ruang vektor yang jaraknya didasarkan pada bentuk normal *Euclidian*. Pada *possibilistic partition* jumlah nilai anggota suatu data pada semua *cluster* tidak harus satu akan tetapi untuk menjamin suatu data menjadi anggota paling tidak satu *cluster* maka diharuskan ada nilai keanggotaan yang lebih dari nol. Selain menunjukkan nilai kemungkinan dari suatu data cenderung pada kelompok tertentu, *possibilistic partition* juga menunjukkan nilai yang jauh dari *cluster* tertentu. Semakin tinggi nilai *possibilistic* pada suatu data maka semakin besar kemungkinan suatu data masuk pada kelompok tertentu. Adapun metode yang termasuk *possibilistic partition* ialah *Possibilistic C-Means* (PCM) dan campuran antara *Fuzzy C-Means* (FCM) pada *fuzzy clustering* dengan *Possibilistic C-Means* (PCM) pada *possibilistic partition* ialah metode *Possibilistic Fuzzy C-Means* (PFCM) [2].

3 Metode Penelitian

3.1 Fuzzy C – Means (FCM)

Fuzzy C – Means (FCM) adalah suatu teknik pengclusteran data yang mana perbedaan tiap – tiap titik data dalam sebuah *cluster* ditentukan oleh derajat keanggotaan. Teknik ini pertama kali diperkenalkan oleh Jim Bezdek pada tahun 1981. Konsep dasar *Fuzzy C – Means*, pertama kali adalah menentukan pusat *cluster*, yang akan menandai lokasi rata-rata untuk tiap-tiap *cluster*. Pada kondisi awal, pusat *cluster* ini masih belum akurat. Tiap-tiap titik data memiliki derajat keanggotaan tiap-tiap titik data secara berulang, maka akan dapat dilihat bahwa pusat *cluster* akan bergerak menuju lokasi yang tepat. Perulangan ini didasarkan pada minimalisasi fungsi obyektif yang menggambarkan jarak dari titik data yang diberikan ke pusat *cluster* yang terbobot oleh derajat keanggotaan titik data tersebut.

Algoritma *Fuzzy C – Means* (FCM) sebagai berikut:

1. *Input* data yang akan di *cluster* X , berupa matriks berukuran $n \times m$ (n = jumlah sampel data, m = atribut setiap data). X_{ij} = data sampel ke- i ($i = 1, 2, \dots, n$), atribut ke- j ($j = 1, 2, \dots, m$).
2. Tentukan:
 - a. Jumlah *cluster* = c
 - b. Pangkat = w
 - c. Maksimum iterasi = $MaxIter$
 - d. Error terkecil = ξ
 - e. Fungsi obyektif awal = $P_0 = 0$
 - f. Iterasi awal = $t = 1$

3. Bangkitkan bilangan random $\mu_{ik}, i = 1, 2, \dots, n; k = 1, 2, \dots, c$; sebagai elemen-elemen matriks partisi awal U .

$$Q_j = \sum_{k=1}^c \mu_{ik} \quad (1)$$

dengan $j = 1, 2, \dots, n$. Hitung:

$$\mu_{ik} = \frac{\mu_{ik}}{Q_j} \quad (2)$$

4. Hitung pusat *cluster* ke- k : V_{kj} , dengan $k = 1, 2, \dots, c$; dan $j = 1, 2, \dots, m$

$$V_{kj} = \frac{\sum_{i=1}^n ((\mu_{ik})^w \cdot X_{ij})}{\sum_{i=1}^n (\mu_{ik})^w} \quad (3)$$

5. Hitung perubahan *matriks* partisi:

$$\mu_{ik} = \frac{[\sum_{j=1}^m (X_{ij} - V_{kj})^2]^{-1}}{\sum_{k=1}^c [\sum_{j=1}^m (X_{ij} - V_{kj})^2]^{-1}} \quad (4)$$

6. Cek kondisi berhenti:

- a. Jika: $(|Pt - Pt - 1| < \xi)$ atau $(t > MaxIter)$ maka berhenti;
- b. Jika tidak: $t = t + 1$, ulangi langkah ke- 4.

3.2 Possibilistic C – Means (PCM)

Possibilistic C – Means (PCM) menggunakan suatu matriks T , yang menunjukkan kekhasan dari suatu data. *Possibilistic C – Means (PCM)* juga didasarkan pada minimisasi fungsi obyektif yang diberikan. Nilai keanggotaan pada setiap titik data dapat di interpretasikan pada derajat kesesuaian atau derajat kemungkinan.

Algoritma *Possibilistic C – Means (PCM)* diberikan sebagai berikut [6].

1. Tentukan:
 - a. Matriks X berukuran $n \times m$, dengan $n =$ jumlah data yang akan di *cluster*, dan $m =$ jumlah variabel.
 - b. Jumlah *cluster* $= c$
 - c. Pangkat $= w$
 - d. Maksimum iterasi $= MaxIter$
 - e. Error terkecil $= \xi$
 - f. Koefisien untuk menghitung $\gamma = K$
2. Panggil algoritma FCM, hasil akhir dari proses *clustering*, yaitu matriks partisi U dan pusat *cluster* V , gunakan untuk menghitung:

$$\gamma_i = K \frac{\sum_{k=1}^n (\mu_{ik})^w (d_{ik})^2}{\sum_{k=1}^n (\mu_{ik})^w} \quad (5)$$

dengan:

$$d_{ik} = d(x_k - v_i) = [\sum_{j=1}^m (X_{kj} - V_{ij})^2]^{-1} \quad (6)$$

3. Tetapkan iterasi awal $t = 1$, dan $\Delta = 1$;
4. Hitung matriks kekhasan, T , sebagai berikut:

$$t_{ik} = \left[1 + \left(\frac{(d_{ik})^2}{\gamma_i} \right)^{\frac{1}{w-1}} \right]^{-1} ; 1 \leq i \leq C; 1 \leq j \leq m \quad (7)$$

5. Hitung pusat *cluster* V , untuk setiap *cluster*:

4 Hasil dan Pembahasan

4.1 Pengelompokkan Menggunakan Algoritma *Fuzzy C – Means* (FCM)

Data-data mahasiswa dikelompokkan menjadi empat *cluster*. Pada Langkah pertama diberikan nilai awal untuk jumlah *cluster*, pangkat, maksimum iterasi dan kriteria pemberhentian sebagai berikut:

1. Matriks X berukuran 32×4
2. Jumlah *cluster* yang akan dibentuk = $c = 4$
3. Pangkat = $w = 2$
4. Maksimum iterasi = $MaxIter = 100$
5. Kriteria pemberhentian = $\xi = 10^{-6}$

Setelah ditetapkan nilai awal pada langkah pertama, langkah selanjutnya yaitu bangkitkan bilangan random μ_{ik} sebagai elemen–elemen matriks partisi awal U . Selanjutnya menghitung pusat *cluster*. Dari hasil pengelompokkan menggunakan diperoleh pusat *cluster* V terakhir pada iterasi ke – 8, sebagai berikut:

$$V = \begin{matrix} & \begin{matrix} 3.76 & 3.56 & 3.77 & 3.74 \end{matrix} \\ \begin{matrix} 14.99 \\ 91.75 \\ 60.18 \end{matrix} & \begin{matrix} 3.30 & 89.54 & 90.20 & 92.65 \\ 58.67 & 59.95 & 59.89 \end{matrix} \end{matrix}$$

Nilai pada kolom ke – 1, 2, 3, dan 4 adalah nilai dari $C1, C2, C3$ dan $C4$. Nilai pada baris ke – 1 adalah nilai IPK, nilai pada baris ke – 2 adalah perolehan jumlah SKEK, nilai pada baris ke – 3 adalah jumlah presentase presensi dan nilai pada baris ke – 4 adalah hasil presentase kemauan belajar. Nilai *cluster* V didapatkan berupa matriks berukuran 4×4 karena, jumlah *cluster* (c) yang dibentuk = 4 dan jumlah indikator aspek-aspek kemahasiswaan yang digunakan = 4, diantaranya nilai IPK, jumlah SKEK, presentase presensi dan presentase kemauan belajar.

Langkah selanjutnya memperbaiki matriks partisi. Pada iterasi ke – 8, nilai mutlak terbesar antara U^8 dan U^7 adalah $\Delta = 1.3944e - 007 < \xi$, sehingga proses berhenti dan menghasilkan matriks partisi baru.

Dari hasil *running* program dapat dilihat kecenderungan suatu data untuk masuk pada masing-masing *cluster*. Mahasiswa ke 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 18, 19, 20, 21, 23, 24, 25, 26, 27, 28, 29, 30, dan 32 masuk dalam *cluster* pertama. Mahasiswa ke 1 dan 17 masuk dalam *cluster* kedua. Mahasiswa ke 2, 13, 22 dan 31 masuk dalam *cluster* keempat. Tidak ada mahasiswa yang masuk dalam *cluster* ketiga.

Selanjutnya, dari pusat *cluster* V , dapat disimpulkan bahwa:

a. Secara Numeris

- 1) *Cluster* I adalah mahasiswa yang memiliki rata-rata nilai IPK 3.76, jumlah SKEK 14.99, presentase kehadiran 91.75% dan kemauan belajar 60.18%.

- 2) *Cluster II* adalah mahasiswa yang memiliki rata-rata nilai IPK 3.56, jumlah SKEK 3.30, presentase kehadiran 89.54% dan kemauan belajar 58.67%.
- 3) *Cluster III* adalah mahasiswa yang memiliki rata-rata nilai IPK 3.77, jumlah SKEK 15.66, presentase kehadiran 90.20% dan kemauan belajar 59.95%.
- 4) *Cluster IV* adalah mahasiswa yang memiliki rata-rata nilai IPK 3.74, jumlah SKEK 15.50, presentase kehadiran 92.65% dan kemauan belajar 59.89%.

b. Secara Linguistik

Untuk membuat kesimpulan secara linguistik, menentukan kriteria bentuk linguistik berdasarkan kategori yang dijelaskan pada Tabel 1 berikut.

Tabel 1. Kriteria Bentuk Linguistik

IPK	SKEK	Presensi	Kemauan Belajar	Kategori
$x > 3.70$	$x > 15$	$x > 90$	$x > 60$	Tinggi
$3.00 < x \leq 3.70$	$5 < x \leq 15$	$50 < x \leq 90$	$0 < x \leq 60$	Sedang
$x \leq 3.00$	$x \leq 5$	$x \leq 50$	$x \leq 30$	Rendah

Tabel 2. Hasil Kesimpulan Linguistik pada Algoritma FCM

No.	<i>Cluster</i>	IPK	SKEK	Presensi	Kemauan Belajar
1	<i>Cluster 1</i>	3.76/Tinggi	14.99/Sedang	91.75/Tinggi	60.18/Tinggi
2	<i>Cluster 2</i>	3.56/Sedang	3.30/Rendah	89.54/Sedang	58.67/Sedang
3	<i>Cluster 3</i>	3.77/Tinggi	15.66/Tinggi	90.20/Tinggi	59.95/Sedang
4	<i>Cluster 4</i>	3.74/Tinggi	15.50/Tinggi	92.65/Tinggi	59.89/Sedang

Dapat disimpulkan bahwa:

1. *Cluster I* adalah mahasiswa yang memiliki rata-rata nilai IPK tinggi, jumlah SKEK sedang, presentase kehadiran tinggi dan kemauan belajar tinggi.
2. *Cluster II* adalah mahasiswa yang memiliki rata-rata nilai IPK sedang, jumlah SKEK rendah, presentase kehadiran sedang dan kemauan belajar sedang.
3. *Cluster III* adalah mahasiswa yang rata-rata memiliki nilai IPK tinggi, jumlah SKEK tinggi, presentase kehadiran tinggi dan kemauan belajar sedang.
4. *Cluster IV* adalah mahasiswa yang rata-rata memiliki nilai IPK tinggi, jumlah SKEK tinggi, presentase kehadiran tinggi dan kemauan belajar sedang.

Dari kesimpulan secara numeris dan linguistik maka dapat diketahui bahwa antara *cluster III* dan *cluster IV* memiliki kriteria yang sama atau pola yang sama.

4.2 Pengelompokkan Menggunakan Algoritma *Possibilistic C- Means (PCM)*

Data-data tersebut akan dikelompokkan menjadi empat *cluster*. Pada pertama diberikan nilai awal untuk jumlah *cluster*, pangkat, maksimum iterasi, kriteria pemberhentian dan koefisien untuk menghitung $\gamma = K$ sebagai berikut:

- a. Matriks X berukuran 32×4
- b. Jumlah *cluster* yang akan dibentuk = $c = 4$
- c. Pangkat = $w = 2$
- d. Maksimum iterasi = $MaxIter = 100$
- e. Kriteria pemberhentian = $\xi = 10^{-6}$
- f. Koefisien untuk menghitung $\gamma = K = 1$

Selanjutnya, panggil algoritma FCM, hasil akhir dari proses *clustering* yaitu matriks partisi U dan pusat *cluster* V dan tetapkan iterasi awal $t = 1$ dan $\Delta = 1$. Setelah melalui proses iterasi pada *Matlab* maka didapatkan matriks kekhasan T . Dari hasil *Matlab* diperoleh pusat *cluster* V terakhir pada iterasi ke- 12, sebagai berikut:

$$V = \begin{matrix} & 3.72 & 3.26 & 3.74 & 3.75 \\ & 13.09 & 1.15 & 13.70 & 15.42 \\ & 91.79 & 86.23 & 90.83 & 91.33 \\ & 59.73 & 62.74 & 59.62 & 61.04 \end{matrix}$$

Nilai pada kolom $ke - 1, 2, 3,$ dan 4 adalah nilai dari C_1, C_2, C_3 dan C_4 . Nilai pada baris $ke - 1$ adalah nilai IPK, nilai pada baris $ke - 2$ adalah perolehan jumlah SKEK, nilai pada baris $ke - 3$ adalah jumlah presentase presensi dan nilai pada baris $ke - 4$ adalah hasil presentase kemauan belajar. Nilai *cluster* V didapatkan matriks berukuran 4×4 karena, jumlah *cluster* (c) yang dibentuk = 4 dan jumlah indikator aspek-aspek kemahasiswaan yang digunakan = 4 , diantaranya nilai IPK, jumlah SKEK, presentase presensi dan presentase kemauan belajar.

Dari hasil pengelompokkan menggunakan *Matlab* berhenti pada iterasi $ke - 12$. Nilai mutlak terbesar antara T^{12} dan T^{11} adalah $\Delta = 9.9440e - 007 < \xi$, sehingga proses iterasi dihentikan, karena sudah konvergen dan menghasilkan matriks kekhasan T pada iterasi terakhir.

Dari hasil *running* program dapat dilihat kecenderungan suatu data untuk masuk pada masing - masing *cluster* seperti terlihat pada Tabel 4.3. Data $ke - 3, 4, 8, 9, 10, 11, 12, 13, 14, 15, 16, 18, 19, 20, 21, 22, 25, 26, 27, 29,$ dan 32 cenderung untuk masuk *cluster* yang pertama. Data $ke - 1, 17$ dan 24 cenderung masuk ke *cluster* yang kedua. Data $ke - 5, 6, 7, 23, 28,$ dan 30 cenderung masuk ke *cluster* ketiga dan data $ke - 2$ dan 31 cenderung masuk ke *cluster* yang keempat.

Selanjutnya, dari pusat *cluster* V dapat disimpulkan bahwa:

- a. Secara Numeris
 1. *Cluster* I adalah mahasiswa yang memiliki rata-rata nilai IPK 3.72, jumlah SKEK 13.09, presentase kehadiran 91.79% dan kemauan belajar 59.73%.

2. *Cluster II* adalah mahasiswa yang rata-rata memiliki nilai IPK 3.26, jumlah SKEK 1.15, presentase kehadiran 86.23% dan kemauan belajar 62.74 %.
3. *Cluster III* adalah mahasiswa yang memiliki rata-rata nilai IPK 3.74, jumlah SKEK 13.70, presentase kehadiran 90.83% dan kemauan belajar 59.62%.
4. *Cluster IV* adalah mahasiswa yang memiliki rata-rata nilai IPK 3.75, jumlah SKEK 15.42, presentase kehadiran 91.33% dan kemauan belajar 61.04%.

b. Secara Linguistik

Tabel 3. Hasil Kesimpulan Linguistik pada Algoritma PCM

Cluster	IPK	SKEK	Presensi	Kemauan Belajar
Cluster 1	3.72/Tinggi	13.09/Sedang	91.79/Tinggi	59.73/Sedang
Cluster 2	3.26/Sedang	1.15/Rendah	89.23/Sedang	62.74/Tinggi
Cluster 3	3.74/Tinggi	13.70/Sedang	90.83/Tinggi	59.62/Sedang
Cluster 4	3.75/Tinggi	15.42/Tinggi	91.33/Tinggi	61.04/Tinggi

Dapat disimpulkan bahwa:

1. *Cluster I* adalah mahasiswa yang memiliki rata - rata nilai IPK Tinggi, jumlah SKEK sedang, presentase kehadiran tinggi dan kemauan belajar sedang.
2. *Cluster II* adalah mahasiswa yang memiliki rata - rata nilai IPK sedang, jumlah SKEK rendah, presentase kehadiran sedang dan kemauan belajar tinggi.
3. *Cluster III* adalah mahasiswa yang memiliki rata - rata nilai IPK tinggi, jumlah SKEK sedang, presentase kehadiran tinggi dan kemauan belajar sedang.
4. *Cluster IV* adalah mahasiswa yang memiliki rata - rata nilai IPK tinggi, jumlah SKEK tinggi, presentase kehadiran tinggi dan kemauan belajar tinggi.

Dari kesimpulan secara numeris dan linguistik maka dapat diketahui bahwa *cluster IV* adalah *cluster* yang terbaik. Artinya mahasiswa pada *cluster IV* dapat dikatakan memiliki potensi dalam mengembangkan prestasi Perguruan Tinggi.

5 Kesimpulan

Pada algoritma FCM, derajat keanggotaan diupdate sehingga menghasilkan nilai fungsi objective yang minimum. Sedangkan algoritma PCM menggunakan suatu matriks T , yang menunjukkan kekhasan dari suatu data juga didasarkan pada minimisasi fungsi obyektif. Berdasarkan hasil running program, algoritma FCM membutuhkan iterasi sebanyak 8 dengan nilai $\Delta = 1.3944e - 007$, sedangkan algoritma PCM membutuhkan iterasi sebanyak 12 dengan nilai $\Delta =$

9.9440e – 007. Walaupun iterasi PCM yang dihasilkan lebih banyak dibandingkan FCM, namun hasil *cluster* PCM lebih tegas dibandingkan FCM.

6 Daftar Pustaka

- [1] A. Baraldi and P. Blonda, “A survey of fuzzy clustering algorithms for pattern recognition. I,” *IEEE Trans. Syst. Man, Cybern. Part B*, vol. 29, no. 6, pp. 778–785, 1999.
- [2] S. Kusumadewi, S. Hartati, A. Harjoko, and R. Wardoyo, “Fuzzy multi-attribute decision making (fuzzy madm),” *Yogyakarta Graha Ilmu*, pp. 78–79, 2006.
- [3] M. H. Fazel Zarandi and M. Zarinbal, “Image Segmentation: Type-2 Fuzzy Possibilistic C-Mean Clustering Approach,” *Int. J. Ind. Eng. Prod. Res.*, vol. 23, no. 4, pp. 245–251, 2012.
- [4] A. Rohmatullah, D. Rahmalia, and M. S. Pradana, “Klasterisasi Data Pertanian di Kabupaten Lamongan Menggunakan Algoritma K-Means Dan Fuzzy C Means,” *J. Ilm. Teknosains*, vol. 5, no. 2, pp. 86–93, 2019.
- [5] M. A. S. Devi, “Penerapan Fuzzy C-Means dan Fuzzy Subtractive Clustering pada Desa dan Kelurahan di Kabupaten Jember Berdasarkan Indikator Kemiskinan,” 2014.
- [6] N. R. Pal, K. Pal, J. M. Keller, and J. C. Bezdek, “A possibilistic fuzzy c-means clustering algorithm,” *IEEE Trans. fuzzy Syst.*, vol. 13, no. 4, pp. 517–530, 2005.