



Perbandingan Algoritma K-Means dan K-Medoids Dalam Pengelompokan Kelas Untuk Mahasiswa Baru Program Magister

Jhiro Faran¹, Rima Tamara Aldisa^{2,*}

¹Fakultas Teknologi Komunikasi dan Informatika, Magister Teknologi Informasi, Universitas Nasional, Jakarta
Jl. Sawo Manila No.61, RT.14/RW.7, Pejaten Bar., Ps. Minggu, Kota Jakarta Selatan, Daerah Khusus Ibukota Jakarta, Indonesia

²Fakultas Teknologi Komunikasi dan Informatika, Sistem Informasi, Universitas Nasional, Jakarta
Jl. Sawo Manila No.61, RT.14/RW.7, Pejaten Bar., Ps. Minggu, Kota Jakarta Selatan, Daerah Khusus Ibukota Jakarta, Indonesia

Email: ¹jhirofaran2022@student.unas.ac.id, ^{2,*}rimatamaraa@gmail.com^{2*}

Email Koresponding: rimatamaraa@gmail.com

Submitted: 03/01/2024; Accepted: 21/01/2024; Published: 22/01/2024

Abstrak—Penelitian ini membahas perbandingan dua algoritma pengelompokan, yaitu K-Means dan K-Medoids, dalam konteks pengelompokan kelas untuk mahasiswa baru program magister. Pemilihan algoritma pengelompokan yang tepat dapat membantu perguruan tinggi mengoptimalkan alokasi sumber daya dan memaksimalkan pengalaman belajar mahasiswa. K-Means adalah salah satu algoritma clustering yang populer, yang bekerja dengan membagi data ke dalam sejumlah kelompok yang homogen berdasarkan jarak antara titik data dan pusat kluster. Sementara itu, K-Medoids adalah variasi dari K-Means yang menggunakan titik data aktual sebagai representasi kluster, yang menjadikannya lebih tahan terhadap outlier. Penelitian ini melibatkan dataset mahasiswa baru program magister yang mencakup berbagai atribut, seperti nilai ujian masuk, latar belakang pendidikan, dan preferensi jurusan. Hasil perbandingan antara K-Means dan K-Medoids dilakukan dengan mempertimbangkan metrik evaluasi clustering seperti SSE (Sum of Squared Errors) dan Silhouette Score. Hasil eksperimen menunjukkan bahwa kinerja K-Means dan K-Medoids berbeda tergantung pada karakteristik dataset. K-Means cenderung menghasilkan kelompok yang lebih homogen, tetapi lebih sensitif terhadap outlier. Sebaliknya, K-Medoids cenderung lebih stabil dalam mengatasi outlier, tetapi mungkin menghasilkan kelompok yang kurang homogen. Oleh karena itu, pemilihan algoritma clustering yang sesuai harus didasarkan pada tujuan dan karakteristik khusus dari populasi mahasiswa baru program magister. Penelitian ini memberikan wawasan berharga bagi perguruan tinggi dalam perencanaan alokasi kelas, mentor, dan sumber daya lainnya untuk mahasiswa baru. Keputusan yang tepat dalam pengelompokan kelas dapat meningkatkan retensi mahasiswa, kepuasan belajar, dan keberhasilan akademis. Selain itu, penelitian ini juga merangsang diskusi lebih lanjut dalam menggabungkan metode clustering yang berbeda untuk mencapai hasil yang lebih optimal dalam pengelompokan kelas mahasiswa baru program magister.

Kata Kunci: Data Mining; Algoritma K-Means; Algoritma K-Medoids; Mahasiswa Program Magister

Abstract—This research discusses a comparison of two grouping algorithms, namely K-Means and K-Medoids, in the context of class grouping for new master's program students. Choosing the right clustering algorithm can help universities optimize resource allocation and maximize student learning experiences. K-Means is a popular clustering algorithm, which works by dividing data into a number of homogeneous groups based on the distance between data points and the cluster center. Meanwhile, K-Medoids is a variation of K-Means that uses actual data points as a cluster representation, which makes it more resistant to outliers. This research involves a dataset of new master's program students which includes various attributes, such as entrance exam scores, educational background, and major preferences. The comparison results between K-Means and K-Medoids were carried out by considering clustering evaluation metrics such as SSE (Sum of Squared Errors) and Silhouette Score. Experimental results show that the performance of K-Means and K-Medoids differs depending on the characteristics of the dataset. K-Means tends to produce more homogeneous groups, but is more sensitive to outliers. In contrast, K-Medoids tend to be more stable in dealing with outliers, but may produce less homogeneous groups. Therefore, the selection of an appropriate clustering algorithm should be based on the specific goals and characteristics of the new master's program student population. This research provides valuable insight for colleges in planning the allocation of classes, mentors, and other resources for new students. The right decisions in class grouping can increase student retention, learning satisfaction, and academic success. In addition, this research also stimulates further discussion in combining different clustering methods to achieve more optimal results in grouping classes of new master's program students.

Keywords: Data Mining; K-Means Algorithm; K-Medoids Algorithm; Master's Program Students

1. PENDAHULUAN

Penerimaan mahasiswa baru dalam program magister memiliki implikasi yang sangat signifikan dalam pengelolaan pendidikan tinggi. Perguruan tinggi dan universitas di seluruh dunia memiliki tanggung jawab besar untuk mengatur komposisi kelas dan kelompok mahasiswa dengan cermat, dengan tujuan mencapai hasil akademik yang telah ditetapkan dan memenuhi standar kualitas yang tinggi. Dalam hal ini, pengelompokan kelas menjadi elemen utama dalam memastikan bahwa pengalaman belajar mahasiswa berjalan secara efisien, memungkinkan mereka untuk mengoptimalkan potensi akademik mereka, dan mencapai hasil yang optimal sesuai dengan tujuan pendidikan yang telah ditetapkan. Keputusan mengenai bagaimana cara mengelompokkan mahasiswa baru di dalam kelas memiliki dampak yang signifikan pada berbagai aspek pendidikan tinggi. Ini mencakup alokasi sumber daya, seperti penugasan pengajar, penentuan ruang kuliah yang tepat, serta penyusunan materi pendidikan yang sesuai dengan tingkat kemampuan dan kebutuhan mahasiswa [1][2].



Pengelompokan kelas yang efektif memiliki dampak besar pada manajemen sumber daya di perguruan tinggi, termasuk alokasi pengajar, pemanfaatan ruang kuliah, dan penyusunan materi pendidikan. Selain itu, pengelompokan yang baik juga membantu mengurangi beban pengajar dengan meminimalkan perbedaan kemampuan dan preferensi mahasiswa dalam satu kelas. Oleh karena itu, penentuan algoritma pengelompokan yang cocok dan efisien menjadi tantangan penting dalam pengaturan pendidikan tinggi. Keputusan yang tepat dapat meningkatkan pengalaman belajar mahasiswa, mengoptimalkan pemanfaatan sumber daya, serta berkontribusi pada kesuksesan akademik dan retensi mahasiswa, menjadikan aspek ini krusial dalam upaya meningkatkan kualitas pendidikan tinggi secara keseluruhan. Pengelompokan kelas yang efektif memungkinkan perguruan tinggi untuk mengalokasikan sumber daya dengan bijak,

Pengelompokan kelas adalah elemen penting dalam manajemen pendidikan tinggi yang memengaruhi pengalaman belajar dan efisiensi sumber daya [3][4]. Dalam pengelompokan mahasiswa baru program magister, K-Means dan K-Medoids menjadi algoritma clustering yang relevan. K-Means membagi data menjadi kelompok berdasarkan jarak ke pusat kluster, sedangkan K-Medoids menggunakan titik data aktual sebagai representasi kluster, lebih tahan terhadap outlier [5][6]. Dalam konteks ini, permasalahan yang dihadapi adalah bagaimana menciptakan kelompok yang homogen berdasarkan atribut seperti nilai ujian masuk, latar belakang pendidikan, dan preferensi jurusan. Variabilitas besar antara mahasiswa baru membuatnya semakin kompleks, dengan outlier yang memerlukan perhatian khusus. Pertimbangan lain termasuk jumlah mahasiswa dalam satu kelas, distribusi kelompok, dan seimbangannya beban pengajar. Keputusan yang tepat dalam memilih algoritma pengelompokan sangat memengaruhi pengalaman belajar, retensi, dan kesuksesan akademik mahasiswa [7][8].

Oleh karena itu, penelitian perbandingan antara K-Means dan K-Medoids dalam pengelompokan kelas untuk mahasiswa baru program magister menjadi relevan dan penting. Kualitas pengelompokan kelas dapat memengaruhi pengalaman belajar mahasiswa dan efisiensi pengelolaan sumber daya. Sebagai contoh, jika mahasiswa dengan tingkat kemampuan yang mirip ditempatkan dalam satu kelas, maka pengajar dapat lebih fokus pada metode pengajaran yang lebih spesifik dan sesuai dengan tingkat tersebut. Selain itu, pengelompokan kelas yang baik juga dapat meminimalkan perbedaan antara mahasiswa dalam satu kelas, yang dapat meningkatkan interaksi sosial dan kolaborasi dalam lingkungan pembelajaran. Namun, pengelompokan kelas yang kurang tepat dapat menghasilkan masalah yang melibatkan perbedaan yang signifikan antara mahasiswa dalam satu kelas, sehingga pengajar harus menghadapi tantangan dalam merancang kurikulum yang sesuai untuk semua tingkatan kemampuan tersebut. Oleh karena itu, pemilihan algoritma pengelompokan yang paling cocok dan efektif menjadi sangat penting dalam konteks pendidikan tinggi [9].

Dalam penelitian ini, akan fokus pada dua algoritma utama dalam clustering, yaitu K-Means dan K-Medoids. K-Means adalah metode yang membagi data ke dalam kelompok berdasarkan jarak antara titik data dan pusat kluster. Setiap titik data akan diatributkan ke kluster yang memiliki pusat terdekat dengannya. Sementara K-Medoids, variasi dari K-Means, menggunakan titik data aktual sebagai representasi kluster, yang membuatnya lebih tahan terhadap outlier. Hasil eksperimen akan memberikan wawasan tentang kinerja relatif dari dua algoritma ini dalam konteks pengelompokan mahasiswa baru program magister [10][11].

Berdasarkan penelitian terkait yang diteliti oleh Sevi Dian Nirwana Dkk pada tahun 2022 yang membahas tentang perbandingan algoritma K-Means dan K-Medoids Dalam Clustering Rata-rata penambahan kasus Covid-19. Pada penelitian tersebut menyimpulkan bahwa Dari clustering yang dilakukan, tidak terdapat perbedaan yang signifikan antara algoritma K-Means dengan K-Medoids. Sehingga keduanya optimal dalam melakukan clustering rata-rata penambahan kasus Covid-19 di Provinsi Sumatera Selatan. Berdasarkan DBI terkecil yang dihasilkan dari masing-masing algoritma, menunjukkan bahwa jumlah K cluster yang optimal pada Algoritma K-Means adalah 2 cluster yang anggotanya terbagi antara Kota Palembang di luar wilayah Kota Palembang dengan DBI 0,078 [12].

Selanjutnya penelitian terkait kedua yang diteliti pada tahun 2022 oleh Gideon bartolomeus Dkk dengan judul “Analisa perbandingan algoritma K-Means, K-Medoids, dan X-Means untuk pengelompokan kinerja pegawai”. Penelitian tersebut menyimpulkan bahwa Berdasarkan hasil yang diuji dalam performance davies bouldin index pada setiap algoritma yang diterapkan pada penelitian ini, algoritma k-means menjadi metode yang terbaik dalam menentukan data kinerja pegawai ke dalam kriteria cluster yang dibutuhkan, karena memiliki nilai DBI paling terkecil, di mana cluster yang dihasilkan dalam metode k-means kriteria nilai tinggi (C1) berjumlah 3 pegawai, sedangkan nilai rendah (C0) berjumlah 25 pegawai [13].

Berikutnya penelitian yang diteliti oleh Mufidah Herviany Dkk pada tahun 2021 yang membahas tentang Perbandingan Algoritma K-Means dan K-Medoids untuk PePengelompokan Daerah Rawan tanah Longsor. Menyimpulkan bahwa pengelompokan dengan menggunakan metode K-Means lebih optimal dibandingkan dengan menggunakan metode K-Medoids pada data kejadian tanah longsor Provinsi Jawa Barat pada tahun 2019 dengan jumlah k paling optimal adalah $k = 6$. Perolehan cluster dominan, menunjukkan bahwa kluster 2 merupakan kluster dengan jumlah daerah paling banyak. Dan jumlah kejadian terbanyak terletak pada kluster 5 dengan jumlah daerah adalah 4 daerah dan jumlah kejadian sebanyak 106 kejadian [14].

Selanjutnya penelitian terkait yang diterbitkan pada tahun 2019 oleh Insanul Kamila Dkk yang berjudul “Perbandingan Algoritma K-Means dan K-Medoids untuk pengelompokan Data Transaksi Muat di Provinsi Jambi”. Pada penelitian tersebut menyimpulkan bahwa Perbandingan antar kedua algoritma clustering, K-Medoids dan K-Means tidak menunjukkan perbedaan yang signifikan mengenai pengelompokan data. Adapun dalam pengolahannya, K-Means hanya membutuhkan waktu rata-rata 1 detik sedangkan pengolahan data pada K-



Medoids membutuhkan waktu rata-rata 1 menit 38 detik yang artinya apabila makin tinggi iterasi dan pengelompokan yang ditentukan, maka pengolahan data akan semakin lama [15].

Penelitian ini diharapkan dapat memberikan panduan yang berguna bagi perguruan tinggi dalam merancang pengelompokan kelas yang lebih efektif dan efisien untuk mahasiswa baru program magister. Keputusan yang tepat dalam pemilihan algoritma clustering dapat meningkatkan pengalaman belajar, tingkat retensi, dan kesuksesan akademik mahasiswa, yang merupakan faktor penting dalam meningkatkan kualitas pendidikan tinggi secara keseluruhan. Selain itu, penelitian ini juga merangsang diskusi lebih lanjut dalam menggabungkan metode clustering yang berbeda untuk mencapai hasil yang lebih optimal dalam pengelompokan kelas mahasiswa baru program magister.

2. METODOLOGI PENELITIAN

2.1 Data Mining

Data mining adalah proses ekstraksi dan analisis yang cermat dari data yang luas dan kompleks untuk mengidentifikasi pola, informasi, atau pengetahuan yang berharga dan tersembunyi. Tujuan utama dari data mining adalah untuk mengungkap wawasan yang dapat digunakan dalam pengambilan keputusan, prediksi, serta mendukung perencanaan strategis [16]. Data mining melibatkan berbagai metode statistik, matematika, teknik komputasi, dan kecerdasan buatan. Ini melibatkan eksplorasi data untuk menemukan hubungan yang mungkin tidak terlihat pada pandangan pertama. Proses ini mencakup pembersihan dan transformasi data, pengelompokan, klasifikasi, analisis asosiasi, dan pembuatan model prediktif [17][18].

2.2 Algoritma K-MeansClustering

Algoritma K-Means merupakan salah satu teknik pengelompokan data yang digunakan dalam analisis data dan data mining. Tujuannya adalah untuk mengelompokkan data atau observasi ke dalam kelompok-kelompok homogen berdasarkan kesamaan karakteristik tertentu [19][20]. Proses K-Means dimulai dengan pemilihan jumlah kluster yang diinginkan (K) dan penempatan acak titik awal sebagai pusat kluster. Selanjutnya, data dipetakan ke kluster yang memiliki pusat terdekat, dan pusat kluster dihitung ulang berdasarkan data yang ada di dalam kluster tersebut. Proses ini berulang hingga tidak ada perubahan signifikan dalam penempatan data ke kluster dan pusat kluster tetap stabil. Adapun langkah-langkah algoritma K-means ialah sebagai berikut :

- Menentukan jumlah nilai K sebagai total cluster
- Mengambil sejumlah titik acak sebanyak nilai K
- Melakukan perhitungan jarak menggunakan rumus Euclidean Distance antara setiap data input dan setiap centroid, sehingga ditemukan jarak terdekat antara data dan centroid. Berikut rumus persamaan euclidean Distance:

$$d(x_i, \mu_j) = \sqrt{\sum (x_i - \mu_j)^2} \tag{1}$$

Keterangan:

x_i : data kriteria

μ_j = centroid pada cluster ke - j

- Mengelompokkan setiap data berdasarkan kedekatannya dengan centroid yang memiliki jarak terkecil.
- Mengganti nilai centroid dengan nilai baru yang dihitung sebagai rata-rata dari data dalam cluster yang bersangkutan, menggunakan rumus yang sesuai:

$$\mu_j(t + 1) = \frac{1}{N_{sj}} \sum_{x_j \in S_j} x_j \tag{2}$$

Keterangan :

$\mu_j(t + 1)$: centroid baru pada iterasi ke (t + 1)

N_{sj} : banyak data pada cluster S_j

- Teruskan perulangan dari langkah 2 hingga 5 sampai tidak ada perubahan dalam anggota setiap cluster.

2.3 Algoritma K-Medoids

Algoritma K-medoids adalah metode dalam analisis kluster yang digunakan untuk mengelompokkan data menjadi K kelompok berdasarkan kedekatan antara data-data dalam kelompok yang sama [21]. Algoritma ini berawal dengan inisialisasi K medoid awal, menghitung jarak antara data-data dan medoid, membentuk kluster, dan menghitung total jarak. Kemudian, algoritma mencoba memperbaharui medoid dengan mencari perubahan yang menghasilkan total jarak terkecil, dan langkah-langkah ini diulangi hingga medoid tidak berubah atau jumlah iterasi maksimum tercapai. Hasil akhir dari algoritma ini adalah K kluster, masing-masing dengan medoid yang mewakili kelompok tersebut [22]. Adapun langkah penyelesaian algoritma K-Medoids sebagai berikut :

- Pilih jumlah kluster yang akan dibentuk (K)
- Pilih secara acak pusat kluster sesuai dengan jumlah K yang akan dibentuk.



- c. Mengukur atau menghitung jarak (cost) dengan menggunakan rumus jarak Euclidean distance dengan menggunakan rumus berikut ini :

$$d_{\text{Euclidean}}(X, Y) = \sqrt{\sum_{i=1}^n (X_i - Y_i)^2} \tag{3}$$

- d. Tentukan posisi kluster berdasarkan nilai minimum dari jarak Cost (C1 hingga Cn).
- e. Lakukan perhitungan total jarak minimum antara medoid (titik pusat kluster) yang telah ditentukan sebelumnya.
- f. Pilih titik medoid baru (non-medoid) secara acak dari sampel data untuk iterasi berikutnya (menggunakan data yang bukan medoid sebelumnya).
- g. Melakukan perhitungan jarak (cost) dengan menerapkan rumus jarak Euclidean seperti yang dijelaskan pada langkah 3, serta melanjutkan dengan melaksanakan langkah 4 dan 5.
- h. Menyusun jumlah keseluruhan simpangan (S).

$$S = \text{Medoid Cost Baru} - \text{Medoid Cost Lama} \tag{4}$$

Apabila nilai S kurang dari nol ($S < 0$), maka langkah 6 akan diulangi hingga mendapatkan nilai simpangan (S) yang lebih besar dari nol ($S > 0$). Sebaliknya, jika nilai S lebih besar dari Nol ($S > 0$), maka proses perhitungan dianggap selesai.

3. HASIL DAN PEMBAHASAN

3.1 Analisa

pada tahap analisa, penulis memperoleh 50 data mahasiswa mahasiswa pendaftar program magister. Yang mana 50 data tersebut yang nantinya akan digunakan pada penerapan Algoritma K-Means dan Algoritma K-Medoids. Pada pengolahan data dengan menggunakan algoritma K-Means dan K-Medoids memerlukan data. dan Data Tersebut dilihat pada tabel 1 dibawah ini:

Tabel 1. Data Pendaftar Program Magister

No.	Nama Mahasiswa	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL
1	Dwina	3,90	95	500
2	Riskah	3,85	90	495
3	Mirzah	3,90	95	495
4	Wiyudah	3,85	90	490
5	Fadilah	3,80	80	500
6	Yuni	3,85	85	450
7	Nola	3,90	90	475
8	Tessa	3,85	90	480
9	Siti Apsah	3,90	90	495
10	Putra	3,90	85	495
11	Febri	3,85	90	495
12	Rian	3,90	95	495
13	Ardin	3,90	95	495
14	Sandi	3,90	95	495
15	Alwi	3,90	95	495
16	Cintia	3,90	95	495
17	Nisa	3,90	95	495
18	Syila	3,90	95	495
19	Seyla	3,90	95	495
20	Sekar	3,75	80	480
21	Joko	3,80	85	480
22	Amel	3,85	95	500
23	Safrial	3,85	90	495
24	Arga	3,85	90	495
25	Amri	3,85	95	500
26	Tesi	3,85	95	500
27	Kitty adel	3,85	95	500
28	Yesika	3,85	95	500
29	Petra	3,85	95	500
30	Bentra	3,85	95	500
31	Sinta	3,85	95	500
32	Putra	3,85	95	500

No.	Nama Mahasiswa	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL
33	Seyla	3,85	95	500
34	Satriasdi	3,85	85	500
35	Ade andreas	3,85	95	500
36	Arkan	3,85	90	495
37	Fikri	3,75	90	475
38	Putri	3,85	90	495
39	Rayni	3,85	90	495
40	Rahma	3,85	85	495
41	Amaluddin	3,85	80	495
42	Melysa	3,90	85	495
43	Meli	3,85	90	495
44	Ali	3,80	85	450
45	Imran	3,75	85	475
46	Siska	3,85	85	495
47	Desi	3,85	90	495
48	Yani	3,85	85	495
49	Utami	3,90	90	500
50	Ikram	3,90	90	490

3.2 Penerapan Algoritma K-Means

Adapun langkah perhitungan menggunakan algoritma K-Means dapat dilihat berikut ini :

Iterasi ke-1

a. Menentukan jumlah nilai K (Cluster)

b. Pemilihan Titik pusat awal sebanyak nilai Cluster.

Pemilihan lokasi awal untuk pusat centroid digunakan dalam pengelompokan atau pengelompokan setiap data dalam penelitian. Penentuan pusat centroid awal dilakukan secara acak, sehingga data mana yang digunakan menjadi bebas. Untuk centroid awal dapat dilihat pada tabel 2 dibawah ini:

Tabel 2. Data Centroid Awal

No.	Centroid	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL	Cluster
1	Centroid 1	3,90	95	500	Cluster 1 (Kelas A)
2	Centroid 2	3,85	90	495	Cluster 2 (Kelas B)

c. Menghitung jarak terdekat ke Centroid (untuk cluster 1 dan 2 disesuaikan dengan rumus masing-masing).

1. Jarak data nomor 1 dengan titik centroid 1

$$= \sqrt{(3,90 - 3,90)^2 + (95 - 95)^2 + (500 - 500)^2} = 0$$

2. Jarak data nomor 1 dengan titik centroid 2

$$= \sqrt{(3,85 - 3,90)^2 + (90 - 95)^2 + (495 - 500)^2} = 7,071244586$$

Selanjutnya untuk hasil perhitungan jarak minimum data nomor 3 hingga data ke 50 dapat dilihat pada tabel 3 dibawah ini. Untuk langkah perhitungannya sesuaikan dengan perhitungan data nomor 1.

Tabel 3. Hasil Perhitungan jarak minimum Iterasi ke-1

No.	Nama Mahasiswa	Cluster 1	Cluster 2	Jarak Terdekat	Kelompok Data
1	Dwina	0	7,071244586	0	Cluster1
2	Riskah	7,071244586	0	0	Cluster2
3	Mirzah	5	5,000249994	5	Cluster1
4	Wiyudah	11,18045169	5	5	Cluster2
5	Fadilah	15,00033333	11,18045169	11,18045169	Cluster2
6	Yuni	50,99021965	45,27692569	45,27692569	Cluster2
7	Nola	25,49509757	20,0000625	20,0000625	Cluster2
8	Tessa	20,61558876	15	15	Cluster2
9	Siti Apsah	7,071067812	0,05	0,05	Cluster2
10	Putra	11,18033989	5,000249994	5,000249994	Cluster2
11	Febri	7,071244586	0	0	Cluster2
12	Rian	5	5,000249994	5	Cluster1
13	Ardin	5	5,000249994	5	Cluster1
14	Sandi	5	5,000249994	5	Cluster1
15	Alwi	5	5,000249994	5	Cluster1
16	Cintia	5	5,000249994	5	Cluster1



No.	Nama Mahasiswa	Cluster 1	Cluster 2	Jarak Terdekat	Kelompok Data
17	Nisa	5	5,000249994	5	Cluster1
18	Syila	5	5,000249994	5	Cluster1
19	Seyla	5	5,000249994	5	Cluster1
20	sekar	25,00045	18,02803373	18,02803373	Cluster2
21	Joko	22,36090338	15,81146736	15,81146736	Cluster2
22	Amel	0,05	7,071067812	0,05	Cluster1
23	Safrial	7,071244586	0	0	Cluster2
24	Arga	7,071244586	0	0	Cluster2
25	Amri	0,05	7,071067812	0,05	Cluster1
26	Tesi	0,05	7,071067812	0,05	Cluster1
27	Kitty adel	0,05	7,071067812	0,05	Cluster1
28	Yesika	0,05	7,071067812	0,05	Cluster1
29	Petra	0,05	7,071067812	0,05	Cluster1
30	Bentra	0,05	7,071067812	0,05	Cluster1
31	Sinta	0,05	7,071067812	0,05	Cluster1
32	Putra	0,05	7,071067812	0,05	Cluster1
33	Seyla	0,05	7,071067812	0,05	Cluster1
34	Satriasdi	10,000125	7,071067812	7,071067812	Cluster2
35	Ade andreas	0,05	7,071067812	0,05	Cluster1
36	Arkan	7,071244586	0	0	Cluster2
37	Fikri	25,49553883	20,00025	20,00025	Cluster2
38	Putri	7,071244586	0	0	Cluster2
39	Rayni	7,071244586	0	0	Cluster2
40	Rahma	11,18045169	5	5	Cluster2
41	Amaluddin	15,81146736	10	10	Cluster2
42	melysa	11,18033989	5,000249994	5,000249994	Cluster2
43	Meli	7,071244586	0	0	Cluster2
44	Ali	50,99029319	45,2769533	45,2769533	Cluster2
45	Imran	26,92624185	20,61577066	20,61577066	Cluster2
46	Siska	11,18045169	5	5	Cluster2
47	Desi	7,071244586	0	0	Cluster2
48	Yani	11,18045169	5	5	Cluster2
49	Utami	5	5,000249994	5	Cluster1
50	Ikram	11,18033989	5,000249994	5,000249994	Cluster2

- d. Pengelompokan setiap data berdasarkan kedekatan dengan centroid (jarak terpendek). Berdasarkan tabel 7 di atas data telah dikelompokkan kedalam 3 centroid berdasarkan jarak minimum dari masing-masing cluster yang telah dihitung.
- e. Proses pembaruan nilai centroid melibatkan perhitungan rata-rata cluster yang bersangkutan, sehingga mendapatkan nilai centroid baru. setelah didapatkan hasil pengelompokan cluster berdasarkan jarak minimum maka dilakukan perhitungan iterasi dengan menggunakan nilai centroid yang baru. berikut didapatkan hasil nilai centroid baru dengan cara:

Tabel 4. Pusat Cluster/Centroid Baru Iterasi 2

Centroid	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL
Centroid 1	3,875	94,77272727	497,9545455
Centroid 2	3,842857143	87,14285714	488,0357143

- f. Jika hasil pengelompokan pusat cluster/centroid berpindah, selanjutnya ulangi langkah ke 3. Dan jika data yang di kelompokkan tidak berpindah. Maka proses perhitungan iterasi selesai. Setelah dilakukan proses perhitungan, maka didapatkan hasil bahwa proses iterasi terhenti pada iterasi ke-5. Yang dimana hasil pusat cluster/centroid iterasi 5 hasil pengelompokan clusternya sama (tidak ada letak centroid yang berubah. Berikut dapat dilihat hasil perhitungan jarak iterasi ke 4 dan ke 5 pada tabel 9 dan tabel 10.

Tabel 5. Jarak Minimum Iterasi 4

No.	Nama Mahasiswa	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL	C1	C2	Jarak Terpendek	Kelompok Data
1	Dwina	3,90	95	500	7,936268253	24,62234757	7,936268253	Cluster1
2	Riskah	3,85	90	495	1,805560363	18,2003434	1,805560363	Cluster1

No.	Nama Mahasiswa	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL	C1	C2	Jarak Terpendek	Kelompok Data
3	Mirzah	3,90	95	495	6,702894765	20,15589244	6,702894765	Cluster1
4	Wiyudah	3,85	90	490	5,933337397	13,46300487	5,933337397	Cluster1
5	Fadilah	3,80	80	500	9,380041957	23,04886114	9,380041957	Cluster1
6	Yuni	3,85	85	450	45,81586386	27,50004545	27,50004545	Cluster2
7	Nola	3,90	90	475	20,76150065	5,591064299	5,591064299	Cluster2
8	Tessa	3,85	90	480	15,78269247	5,590393546	5,590393546	Cluster2
...
50	Ikram	3,90	90	490	5,933512956	13,4632834	5,933512956	Cluster1

Tabel 6. Jarak minimum iterasi 5

No.	Nama Mahasiswa	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL	C1	C2	Jarak Terpendek	Kelompok Data
1	Dwina	3,90	95	500	114,1465407	1982,777581	114,1465407	Cluster1
2	Riskah	3,85	90	495	119,8103715	1988,569453	119,8103715	Cluster1
3	Mirzah	3,90	95	495	119,1089113	1987,702678	119,1089113	Cluster1
4	Wiyudah	3,85	90	490	124,7478462	1993,492781	124,7478462	Cluster1
5	Fadilah	3,80	80	500	116,9706053	1985,420612	116,9706053	Cluster1
6	Yuni	3,85	85	450	165,0440097	2033,752313	165,0440097	Cluster1
7	Nola	3,90	90	475	139,5866496	2008,264658	139,5866496	Cluster1
8	Tessa	3,85	90	480	134,6366411	2003,340577	134,6366411	Cluster1
...
50	Ikram	3,90	90	490	124,7474759	1993,492397	124,7474759	Cluster1

Selanjutnya setelah dilakukan proses perhitungan , maka didapatkan hasil pengelompokan data mahasiswa sebagai C1 sebanyak 50 data yaitu Sebagai data yang lulus dalam pengelompokan kelas. Dari tabel ini, dapat dilihat bahwa seluruh mahasiswa termasuk dalam "Cluster1". Cluster ini didasarkan pada perhitungan jarak terpendek, yang mengindikasikan bahwa mahasiswa-mahasiswa dalam tabel memiliki kesamaan dalam atribut yang diukur. Dalam kasus ini, kemungkinan mereka memiliki prestasi akademik yang sejenis, seperti nilai IPK yang tinggi dan nilai Ujian Saringan Masuk serta TOEFL yang baik. Maka dapat disimpulkan bahwa pengelompokan di ambil dari iterasi ke 4 yaitu nilai cluster 1 terdiri dari 40 data dan nilai cluster 2 terdiri dari 10 data.

3.3 Penerapan Algoritma K-Medoids

Berikut ini dapat dilihat proses dalam melakukan perhitungan dengan menggunakan algoritma K-Medoids :

- Memilih jumlah kluster yang akan dibentuk
- memilih secara acak pusat kluster sesuai dengan jumlah K yang akan dibentuk.

Tabel 7. Pusat Medoids iterasi 1

No.	Centroid	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL	Cluster
1	Centroid 1	3,90	95	500	Cluster 1 (Kelas A)
2	Centroid 2	3,85	90	495	Cluster 2 (Kelas B)

- Mengukur atau menghitung jarak (cost) dengan menggunakan rumus jarak Euclidean distance dengan menggunakan rumus berikut ini :

- Jarak data nomor 1 dengan titik centroid 1

$$= \sqrt{(3,90 - 3,90)^2 + (95 - 95)^2 + (500 - 500)^2} = 0$$

- Jarak data nomor 1 dengan titik centroid 2

$$= \sqrt{(3,85 - 3,90)^2 + (90 - 95)^2 + (495 - 500)^2} = 7,07124486$$

Tabel 8. Jarak minimum iterasi 1 perhitungan Medoid

No.	Nama Mahasiswa	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL	C1	C2	Jarak Terpendek	kelompok data
1	Dwina	3,90	95	500	0	7,071244586	0	Cluster1

No.	Nama Mahasiswa	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL	C1	C2	Jarak Terpendek	kelompok data
2	Riskah	3,85	90	495	7,071244586	0	0	Cluster2
3	Mirzah	3,90	95	495	5	5,000249994	5	Cluster1
4	Wiyudah	3,85	90	490	11,18045169	5	5	Cluster2
5	Fadilah	3,80	80	500	15,00033333	11,18045169	11,18045169	Cluster2
6	Yuni	3,85	85	450	50,99021965	45,27692569	45,27692569	Cluster2
7	Nola	3,90	90	475	25,49509757	20,0000625	20,0000625	Cluster2
8	Tessa	3,85	90	480	20,61558876	15	15	Cluster2
9	Siti Apsah	3,90	90	495	7,071067812	0,05	0,05	Cluster2
10	Putra	3,90	85	495	11,18033989	5,000249994	5,000249994	Cluster2
11	Febri	3,85	90	495	7,071244586	0	0	Cluster2
12	Rian	3,90	95	495	5	5,000249994	5	Cluster1
13	Ardin	3,90	95	495	5	5,000249994	5	Cluster1
14	Sandi	3,90	95	495	5	5,000249994	5	Cluster1
15	Alwi	3,90	95	495	5	5,000249994	5	Cluster1
16	Cintia	3,90	95	495	5	5,000249994	5	Cluster1
17	Nisa	3,90	95	495	5	5,000249994	5	Cluster1
18	Syila	3,90	95	495	5	5,000249994	5	Cluster1
19	Seyla	3,90	95	495	5	5,000249994	5	Cluster1
20	Sekar	3,75	80	480	25,00045	18,02803373	18,02803373	Cluster2
21	Joko	3,80	85	480	22,36090338	15,81146736	15,81146736	Cluster2
22	Amel	3,85	95	500	0,05	7,071067812	0,05	Cluster1
23	Safrial	3,85	90	495	7,071244586	0	0	Cluster2
24	Arga	3,85	90	495	7,071244586	0	0	Cluster2
25	Amri	3,85	95	500	0,05	7,071067812	0,05	Cluster1
26	Tesi	3,85	95	500	0,05	7,071067812	0,05	Cluster1
27	Kitty adel	3,85	95	500	0,05	7,071067812	0,05	Cluster1
28	Yesika	3,85	95	500	0,05	7,071067812	0,05	Cluster1
29	Petra	3,85	95	500	0,05	7,071067812	0,05	Cluster1
30	Bentra	3,85	95	500	0,05	7,071067812	0,05	Cluster1
31	Sinta	3,85	95	500	0,05	7,071067812	0,05	Cluster1
32	Putra	3,85	95	500	0,05	7,071067812	0,05	Cluster1
33	Seyla	3,85	95	500	0,05	7,071067812	0,05	Cluster1
34	Satriasdi	3,85	85	500	10,000125	7,071067812	7,071067812	Cluster2
35	Ade andreas	3,85	95	500	0,05	7,071067812	0,05	Cluster1
36	Arkan	3,85	90	495	7,071244586	0	0	Cluster2
37	Fikri	3,75	90	475	25,49553883	20,00025	20,00025	Cluster2
38	Putri	3,85	90	495	7,071244586	0	0	Cluster2
39	Rayni	3,85	90	495	7,071244586	0	0	Cluster2
40	Rahma	3,85	85	495	11,18045169	5	5	Cluster2
41	Amaluddin	3,85	80	495	15,81146736	10	10	Cluster2
42	Melysa	3,90	85	495	11,18033989	5,000249994	5,000249994	Cluster2
43	Meli	3,85	90	495	7,071244586	0	0	Cluster2
44	Ali	3,80	85	450	50,99029319	45,2769533	45,2769533	Cluster2
45	Imran	3,75	85	475	26,92624185	20,61577066	20,61577066	Cluster2
46	Siska	3,85	85	495	11,18045169	5	5	Cluster2
47	Desi	3,85	90	495	7,071244586	0	0	Cluster2
48	Yani	3,85	85	495	11,18045169	5	5	Cluster2
49	Utami	3,90	90	500	5	5,000249994	5	Cluster1
50	Ikram	3,90	90	490	11,18033989	5,000249994	5,000249994	Cluster2
Jumlah								
Kedekatan						313,8617327		

- d. Menentukan posisi kluster berdasarkan nilai minimum dari jarak Cost (C1 hingga Cn).
- e. Lakukan perhitungan total jarak minimum antara medoid (titik pusat kluster) yang telah ditentukan sebelumnya.
- f. Pilih titik medoid baru (non-medoid) secara acak dari sampel data untuk iterasi berikutnya (menggunakan data yang bukan medoid sebelumnya).

Tabel 9. Iterasi baru Pusat Medoids baru

No.	Centroid	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL
3	Centroid 1	3,90	95	495
4	Centroid 2	3,85	90	490

g. Melakukan perhitungan jarak (cost) dengan menerapkan rumus jarak Euclidean seperti yang dijelaskan pada langkah 3, serta melanjutkan dengan melaksanakan langkah 4 dan 5.

Tabel 10. Jarak minimum iterasi 2 perhitungan Medoid

No	Nama Mahasiswa	Nilai IPK (S1)	Nilai Ujian Saringan Masuk	Nilai Test TOEFL	C1	C2	Jarak Terpendek	kelompok data
1	Dwina	3,90	95	500	5	11,18045169	5	Cluster1
2	Riskah	3,85	90	495	5,000249994	5	5	Cluster2
3	Mirzah	3,90	95	495	0	7,071244586	0	Cluster1
4	Wiyudah	3,85	90	490	7,071244586	0	0	Cluster2
5	Fadilah	3,80	80	500	15,81170453	14,14222401	14,14222401	Cluster2
6	Yuni	3,85	85	450	46,0977494	40,31128874	40,31128874	Cluster2
7	Nola	3,90	90	475	20,61552813	15,00008333	15,00008333	Cluster2
8	Tessa	3,85	90	480	15,81146736	10	10	Cluster2
9	Siti Apsah	3,90	90	495	5	5,000249994	5	Cluster1
10	Putra	3,90	85	495	10	7,071244586	7,071244586	Cluster2
11	Febri	3,85	90	495	5,000249994	5	5	Cluster2
12	Rian	3,90	95	495	0	7,071244586	0	Cluster1
13	Ardin	3,90	95	495	0	7,071244586	0	Cluster1
14	Sandi	3,90	95	495	0	7,071244586	0	Cluster1
15	Alwi	3,90	95	495	0	7,071244586	0	Cluster1
16	Cintia	3,90	95	495	0	7,071244586	0	Cluster1
17	Nisa	3,90	95	495	0	7,071244586	0	Cluster1
18	Syila	3,90	95	495	0	7,071244586	0	Cluster1
19	Seyla	3,90	95	495	0	7,071244586	0	Cluster1
20	Sekar	3,75	80	480	21,21373376	14,14248917	14,14248917	Cluster2
21	Joko	3,80	85	480	18,02803373	11,18045169	11,18045169	Cluster2
22	Amel	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
23	Safrial	3,85	90	495	5,000249994	5	5	Cluster2
24	Arga	3,85	90	495	5,000249994	5	5	Cluster2
25	Amri	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
26	Tesi	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
27	Kitty adel	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
28	Yesika	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
29	Petra	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
30	Bentra	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
31	Sinta	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
32	Putra	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
33	Seyla	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
34	Satriasdi	3,85	85	500	11,18045169	11,18033989	11,18033989	Cluster2
35	Ade andreas	3,85	95	500	5,000249994	11,18033989	5,000249994	Cluster1
36	Arkan	3,85	90	495	5,000249994	5	5	Cluster2
37	Fikri	3,75	90	475	20,61607383	15,00033333	15,00033333	Cluster2
38	Putri	3,85	90	495	5,000249994	5	5	Cluster2
39	Rayni	3,85	90	495	5,000249994	5	5	Cluster2
40	Rahma	3,85	85	495	10,000125	7,071067812	7,071067812	Cluster2
41	Amaluddin	3,85	80	495	15,00008333	11,18033989	11,18033989	Cluster2
42	Melysa	3,90	85	495	10	7,071244586	7,071244586	Cluster2
43	Meli	3,85	90	495	5,000249994	5	5	Cluster2
44	Ali	3,80	85	450	46,09783075	40,31131975	40,31131975	Cluster2
45	Imran	3,75	85	475	22,36118288	15,81170453	15,81170453	Cluster2
46	Siska	3,85	85	495	10,000125	7,071067812	7,071067812	Cluster2
47	Desi	3,85	90	495	5,000249994	5	5	Cluster2
48	Yani	3,85	85	495	10,000125	7,071067812	7,071067812	Cluster2
49	Utami	3,90	90	500	7,071067812	10,000125	7,071067812	Cluster1
50	Ikram	3,90	90	490	7,071067812	0,05	0,05	Cluster2



Jumlah kedekatan	350,7400847
------------------	-------------

h. Menyusun jumlah keseluruhan simpangan (S).

Tabel 11. Jumlah keseluruhan simpangan (S)

Selisih Kedekatan	
Rumus = jumlah kedekatan Iterasi 2 - jumlah kedekatan Iterasi Ke 1	
selisih kedekatan	36,87835196
jika selisih iterasi > 0, maka iterasi berhenti dan cluster ada pada iterasi sebelumnya	

4. KESIMPULAN

Dalam analisis data pendaftar program magister yang melibatkan 50 mahasiswa, dua algoritma clustering, yaitu K-Means dan K-Medoids, telah diterapkan. Pada langkah awal K-Means, pusat kluster awal dipilih secara acak, dan data mahasiswa dikelompokkan berdasarkan jarak terpendek ke pusat kluster terdekat. Setelah beberapa iterasi, K-Means menghasilkan dua kluster dengan 40 mahasiswa dalam Kluster 1 dan 10 mahasiswa dalam Kluster 2. Di sisi lain, K-Medoids juga dimulai dengan pemilihan pusat kluster acak dan perhitungan jarak dengan rumus Euclidean distance. Setelah beberapa iterasi, K-Medoids juga menghasilkan dua kluster, dengan data yang serupa dalam Kluster 1 dan Kluster 2. Meskipun kedua algoritma menghasilkan hasil yang mirip dalam pengelompokan mahasiswa, perbedaan dalam pemilihan pusat kluster dan perhitungan jarak dapat memengaruhi hasil akhir. Keduanya adalah alat yang berguna untuk analisis data, dan pemilihan di antara keduanya harus disesuaikan dengan konteks dan karakteristik data yang sedang dihadapi.

REFERENCES

- [1] A. Salam, D. Adiatma, and J. Zeniarja, "Implementasi Algoritma K-Means Dalam Pengklasteran untuk Rekomendasi Penerima Beasiswa PPA di UDINUS," JOINS (Journal Inf. Syst., vol. 5, no. 1, pp. 62–68, 2020, doi: 10.33633/joins.v5i1.3350.
- [2] Baskoro, Sriyanto, and L. Setya Rini, "Prediksi Penerima Beasiswa dengan Menggunakan Teknik Data Mining di Universitas Muhammadiyah Pringsewu," Semin. Nas. Has. Penelit. dan Pengabd. Masy. Inst. Inform. dan Bisnis Darmajaya, pp. 87–94, 2021.
- [3] E. Fammaldo and L. Hakim, "Penerapan Algoritma K-Means Clustering Untuk Pengelompokan Tingkat Kesejahteraan Keluarga Untuk Program Kartu Indonesia Pintar," J. Ilm. Teknol. Infomasi Terap., vol. 5, no. 1, pp. 23–31, 2019, doi: 10.33197/jitter.vol5.iss1.2018.249.
- [4] S. A. Rahmah and J. Antares, "Klasterisasi Seleksi Mahasiswa Calon Penerima Beasiswa Yayasan Menggunakan K-Means Clustering," INFORMATIKA, vol. 13, no. 2, pp. 25–30, 2022.
- [5] F. Firzada and Y. Yuhandri, "Klasterisasi Tingkat Masa Studi Tepat Waktu Mahasiswa Menggunakan Algoritma K-Medoids," J. Sistim Inf. dan Teknol., pp. 162–168, 2021.
- [6] E. Rahmah, "Penerapan Algoritma K-Medoids Clustering untuk menentukan Strategi Promosi Pada Data Mahasiswa (Studi Kasus: STIKES PERINTIS PADANG)," Penerapan Algoritma K-Medoids Clust. untuk menentukan Strateg. Promosi Pada Data Mhs. (Studi Kasus STIKES PERINTIS PADANG), vol. 5, no. 03, pp. 556–564, 2022.
- [7] D. APRIZA and S. Samsuryadi, "Perbandingan Metode Euclidean Distance Dengan Coefficient Correlation Pada Klasifikasi Penyakit Multiple Sclerosis Lesion ...," 2019, [Online]. Available: https://repository.unsri.ac.id/23207/%0Ahttps://repository.unsri.ac.id/23207/52/RAMA_55201_09121402019_0004027101_01_front_ref.pdf.
- [8] A. Fauzy, "Perbandingan Algoritma K-Means dan Algoritma K-Medoids dalam Pengelompokan Komoditas Tanaman Biofarmaka di Provinsi Jawa Tengah Tahun 2018," 2020.
- [9] V. Agustin, "Perbandingan Analisis Clustering K-Means Dan K-Medoids Pada Data Penyakit Di Indonesia Tahun 2019," 2021.
- [10] A. Athifaturrofifah, R. Goejantoro, and D. Yuniarti, "Perbandingan Pengelompokan K-Means dan K-Medoids Pada Data Potensi Kebakaran Hutan/Lahan Berdasarkan Persebaran Titik Panas," EKSPONENSIAL, vol. 10, no. 2, pp. 143–152, 2020.
- [11] A. Lesmana, "Perbandingan Algoritma K-Means dan K-Medoids Dalam Penclustering Data Penjualan PT. United Teknologi Integrasi." Universitas Mercu Buana Jakarta-Menteng, 2022.
- [12] S. D. Nirwana, M. I. Jambak, and A. Bardadi, "Perbandingan Algoritma K-Means Dan K-Medoids Dalam Clustering Rata-Rata Penambahan Kasus Covid-19 Berdasarkan Kota/Kabupaten Di Provinsi Sumatera Selatan," JSiI (Jurnal Sist. Informasi), vol. 9, no. 2, pp. 126–131, 2022, doi: 10.30656/jsii.v9i2.5127.
- [13] G. B. Kaligis and S. Yulianto, "Analisa Perbandingan Algoritma K-Means, K-Medoids, Dan X-Means Untuk Pengelompokan Kinerja Pegawai," IT-Explore J. Penerapan Teknol. Inf. dan Komun., vol. 1, no. 3, pp. 179–193, 2022, doi: 10.24246/itexplore.v1i3.2022.pp179-193.
- [14] M. Herviany, S. Putri Delima, T. Nurhidayah, and Kasini, "Comparison of K-Means and K-Medoids Algorithms for Grouping Landslide Prone Areas in West Java Province," MALCOM Indones. J. Mach. Learn. Comput. Sci., vol. 1, no. 1, pp. 34–40, 2021.
- [15] I. Kamila, U. Khairunnisa, and M. Mustakim, "Perbandingan Algoritma K-Means dan K-Medoids untuk Pengelompokan Data Transaksi Bongkar Muat di Provinsi Riau," J. Ilm. Rekayasa dan Manaj. Sist. Inf., vol. 5, no. 1, pp. 119–125, 2019.



- [16] N. S. L. Zulfa and A. Hadiana, “Kajian Data Mining Menggunakan Algoritma K-Means Dan K-Medoids Dalam Strategi Promosi (Studi Kasus: Universitas Islam Al-Ihya Kuningan),” *J. Fak. Tek. Kuningan*, vol. 2, no. 2, pp. 57–62, 2021.
- [17] N. A. Manihuruk, M. Zarlis, E. Irawan, H. S. Tambunan, and I. Irawan, “Penerapan Data Mining Dalam Mengelompokkan Calon Penerima Beasiswa Dengan Menggunakan Algoritma K-Means,” *KOMIK (Konferensi Nas. Teknol. Inf. dan Komputer)*, vol. 4, no. 1, 2020.
- [18] A. Supriyadi, A. Triayudi, and I. D. Sholihati, “Perbandingan Algoritma K-Means Dengan K-Medoids Pada Pengelompokan Armada Kendaraan Truk Berdasarkan Produktivitas,” *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 6, no. 2, pp. 229–240, 2021, doi: 10.29100/jupi.v6i2.2008.
- [19] B. G. Sudarsono and S. P. Lestari, “Clustering Penerima Beasiswa Yayasan Untuk Mahasiswa Menggunakan Metode K-Means,” *J. Media Inform. Budidarma*, vol. 5, no. 1, pp. 258–263, 2021.
- [20] D. J. Lubis and M. B. Tamam, “Penerapan K-Means Untuk Pengelompokkan Beasiswa Santri di Pondok Pesantren Miftahul Huda Bogor,” *Teknois J. Ilm. Teknol. Inf. dan Sains*, vol. 12, no. 1, pp. 7–20, 2022, doi: 10.36350/jbs.v12i1.125.
- [21] A. Supriyadi, A. Triayudi, and I. D. Sholihati, “Perbandingan algoritma k-means dengan k-medoids pada pengelompokan armada kendaraan truk berdasarkan produktivitas,” *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 6, no. 2, pp. 229–240, 2021.
- [22] N. A. S. Z. Abidin, R. D. Avila, A. Hermatyar, and R. Rismayani, “Perbandingan Algoritma K-Means dan K-Medoids untuk Pengelompokan Daerah Produksi Kakao,” *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 2, pp. 383–391, 2022.