

ANALISIS KLASTER KARAKTERISTIK MAHASISWA PENDIDIKAN MATEMATIKA UNIVERSITAS LAMBUNG MANGKURAT

Dadang Juandi^{*1}, Rizki Amalia², Siti Nur Asmah¹, Yuni Suryaningsih²

¹Pendidikan Matematika, Universitas Pendidikan Indonesia, Bandung, Indonesia

²Pendidikan Matematika, Universitas Lambung Mangkurat, Banjarmasin, Indonesia

*Penulis Korespondensi (dadang.juandi@upi.edu)

DOI: <http://dx.doi.org/10.20527/edumat.v13i2.22555>

Received : 20 Mei 2025 Accepted : 23 Oktober 2025 Published : 31 Oktober 2025

Abstrak: Penelitian ini merupakan penelitian deskriptif kuantitatif dengan tujuan untuk mengetahui profil karakteristik mahasiswa S1 Program Studi Pendidikan Matematika Universitas Lambung Mangkurat berdasarkan karakteristik belajarnya. Data dikumpulkan melalui instrumen angket karakteristik mahasiswa, kemudian dianalisis menggunakan metode analisis kluster nonhierarki K-Means. Sebanyak 96 mahasiswa menjadi subjek penelitian dengan 12 variabel yang distandardisasi dalam bentuk z-score meliputi jenis kelamin, usia, semester, IPK, waktu belajar per minggu, waktu belajar kelompok per minggu, frekuensi bertanya di kelas per minggu, minat terhadap matematika, gaya belajar, konsistensi dalam membuat jadwal belajar, percaya diri dalam menghadapi ujian, dan kecemasan dalam ujian matematika. Hasil analisis menunjukkan terbentuknya tiga kluster dengan karakteristik berbeda. Kluster pertama terdiri dari mahasiswa semester awal yang aktif dan memiliki intensitas belajar tinggi. Kluster kedua mencakup mahasiswa tingkat akhir dengan keterlibatan belajar rendah dan kecemasan tinggi. Kluster ketiga terdiri dari mahasiswa yang konsisten, aktif bertanya, dan memiliki minat tinggi terhadap matematika. Temuan ini menunjukkan pentingnya pendekatan pembelajaran yang disesuaikan dengan profil karakteristik mahasiswa.

Kata kunci: analisis kluster, karakteristik mahasiswa, pendidikan matematika

Abstract: This study is a quantitative descriptive study to determine the profile characteristics of undergraduate students in the Mathematics Education Study Program at Lambung Mangkurat University based on their learning characteristics. Data were collected through a student characteristics questionnaire instrument, then analyzed using the K-Means non-hierarchical cluster analysis method. A total of 96 students became research subjects with 12 variables standardised in the form of z-scores including gender, age, semester, GPA, study time per week, group study time per week, frequency of asking questions in class per week, interest in mathematics, learning style, consistency in making a study schedule, confidence in facing exams, and anxiety in mathematics exams. The analysis showed the formation of three clusters with different characteristics. The first cluster consists of early-semester students who are active and have high learning intensity. The second cluster includes final year students with low learning engagement and high anxiety. The third cluster consists of students who are consistent, active in asking questions, and highly

interested in mathematics. This finding shows the importance of customised learning approaches that fit the profile of student characteristics.

Keywords: *cluster analysis, student characteristics, mathematics education*

PENDAHULUAN

Pembelajaran matematika di lingkungan pendidikan tinggi merupakan aspek penting dalam pengembangan kemampuan analisis dan pemecahan masalah mahasiswa. Namun, setiap mahasiswa memiliki karakteristik yang berbeda dalam memahami dan menguasai materi matematika. Perbedaan ini dapat dipengaruhi oleh berbagai faktor seperti latar belakang akademik, gaya belajar, minat, motivasi, serta kemampuan kognitif. Oleh karena itu, penting untuk memahami pola karakteristik mahasiswa dalam pembelajaran matematika agar proses pengajaran dapat lebih efektif dan tepat sasaran (Fadillahsyah & Hasanuddin, 2025; Marsh & Martin, 2011; Tall, 2008).

Analisis klaster merupakan salah satu metode statistika untuk melakukan proses pengelompokan objek atau kasus menjadi kelompok-kelompok yang lebih kecil dimana setiap kelompok berisi objek yang mirip satu sama lain (Ediyanto et al., 2013; Johnson & Wincern, 1982) sehingga analisis ini dapat digunakan untuk mengelompokkan mahasiswa berdasarkan karakteristik tertentu agar mahasiswa dapat dikelompokkan ke dalam beberapa klaster berdasarkan kemiripan karakteristik yang dimiliki. Metode ini memungkinkan pengajar untuk merancang strategi pembelajaran yang lebih sesuai dengan kebutuhan setiap kelompok mahasiswa.

Analisis klaster juga dapat diartikan sebagai teknik multivariat yang mempunyai tujuan utama untuk mengelompokkan objek-objek berdasarkan karakteristik yang dimilikinya ke dalam kelompok yang relatif homogen, yang disebut klaster. Objek atau

kasus dalam setiap kelompok cenderung mirip satu sama lain dan berbeda jauh atau tidak sama dengan objek dari klaster lainnya (Awalluddin & Taufik, 2017; Rokhimah & Kismiantini, 2022). Suatu klaster dikatakan baik jika memenuhi syarat homogenitas (kesamaan) yang tinggi antara anggota dalam satu klaster (*within cluster*) dan heterogenitas (perbedaan) yang tinggi antara klaster yang satu dengan klaster lainnya (*between cluster*) (Han et al., 2011; Jain, 2010; R. Xu & Wunsch, 2005).

Dalam konteks pembelajaran matematika, mahasiswa seringkali memiliki beragam karakteristik, seperti gaya belajar, motivasi, kemampuan awal, dan sikap terhadap matematika, yang dapat memengaruhi hasil belajar mereka. Analisis klaster dapat membantu pendidik dan peneliti mengidentifikasi kelompok mahasiswa dengan profil serupa, sehingga strategi pembelajaran dapat disesuaikan untuk meningkatkan efektivitas pengajaran (Hair et al., 2019). Analisis klaster juga dapat mengeksplorasi karakteristik siswa dalam pembelajaran matematika. Siswa dapat dikelompokkan menjadi tiga klaster berdasarkan tingkat kecemasan dan minat terhadap matematika (Liu et al., 2020) dan mengidentifikasi perbedaan kemampuan pemecahan masalah matematis melalui pendekatan klasterisasi (Septaria & Fauzi, 2021). Selain itu, dapat mengelompokkan mahasiswa berdasarkan jalur masuk, asal sekolah, dan nilai matematika sehingga menghasilkan tiga klaster dengan profil yang berbeda (Lathifaturrahmah et al., 2017).

Analisis klaster dibagi menjadi dua metode, yaitu *Hierarchical Method* (Metode

Hierarki) dan *Nonhierarchical Method* (Metode Nonhierarki). Metode hierarki digunakan untuk objek yang tidak terlalu banyak, dan jumlah kelompok yang hendak dibentuk belum diketahui. Pengelompokan ini disajikan dalam bentuk dendrogram, yang mirip dengan struktur diagram pohon (*tree diagram*). Dalam metode ini terdapat dua prosedur, yaitu *agglomerative* (penggabungan) dan *divisive* (pemisahan). Metode *agglomerative* diawali dengan mengelompokkan dua atau lebih individu yang mempunyai kesamaan (jarak paling dekat). Selanjutnya kelompok dibentuk kembali berdasarkan kesamaan antar kelompok (jarak antar kelompok terdekat) sehingga terjadi penggabungan kelompok, dan begitu seterusnya dilakukan prosedur yang sama. Sedangkan metode *divisive* kebalikan dari metode *agglomerative*. Pada tahap awal, semua individu dibagi menjadi dua kelompok, yang kemudian masing-masing kelompok dibagi lagi menjadi dua, dan demikian seterusnya. Pada metode nonhierarki, klaster dibentuk secara langsung melalui algoritma tertentu tanpa memerlukan langkah-langkah bertahap seperti dalam metode hierarki. Salah satu keunggulan utama dari metode nonhierarki adalah kemampuannya untuk menangani data dalam jumlah besar dengan lebih efisien (Everitt et al., 2011; Jain, 2010; Tan et al., 2019; Usman & Sobari, 2013).

Salah satu metode nonhierarki pada analisis klaster adalah K-Means. K Means adalah metode pengelompokan non-hierarkis yang mempartisi data ke dalam klaster berdasarkan karakteristik bersama, meminimalkan variasi dalam klaster dan memaksimalkan variasi di antara mereka. Objek dengan karakteristik serupa dikelompokkan bersama, sedangkan objek dengan karakteristik berbeda ditempatkan dalam klaster terpisah, memaksimalkan kesamaan intra-cluster dan meminimalkan kesamaan antar-

cluster (Santhi et al., 2011; Y. Xu et al., 2018). Pendapat lain mengatakan K-Means adalah metode analisis klaster non-hierarkis yang mempartisi data ke dalam klaster berdasarkan kesamaan. Objek dengan karakteristik serupa dikelompokkan bersama, sedangkan objek dengan karakteristik berbeda ditetapkan ke klaster terpisah, memastikan homogenitas dalam klaster (Messakh et al., 2023; Ningrat et al., 2016; Suyal & Sharma, 2024). Analisis klaster dengan metode K-Means dapat mengelompokkan mahasiswa berdasarkan variabel seperti IPK, jumlah SKS, semester, dan faktor-faktor lainnya sehingga menghasilkan empat klaster dengan karakteristik yang berbeda-beda (M. P. Lawuna et al., 2024) dan dapat juga untuk mengkategorikan kemampuan komunikasi matematis serta kemampuan pemecahan masalah menjadi kategori tinggi, sedang, dan rendah (Dwitasari & Yudhanegara, 2024).

Masalah utama yang diangkat dalam penelitian ini adalah kebutuhan untuk memahami karakteristik belajar mahasiswa pendidikan matematika di Universitas Lambung Mangkurat, yang memiliki variasi dalam aspek seperti waktu belajar, gaya belajar, dan kecemasan ujian. Pemahaman ini penting karena dapat membantu dalam merancang pendekatan pembelajaran yang lebih tepat dan disesuaikan dengan kebutuhan individu mahasiswa.

Berdasarkan beberapa penelitian yang telah disampaikan sebelumnya, belum banyak yang menggunakan metode K-Means untuk mengelompokkan karakteristik terutama karakteristik mahasiswa yang bertujuan untuk mengetahui pendekatan pembelajaran yang tepat digunakan dalam kelas sesuai karakteristik mahasiswa. Kebaruan dari penelitian ini terletak pada penggunaan analisis klaster metode nonhierarki K-Means untuk mengelompokkan mahasiswa berdasarkan karakteristik belajar mereka.

Meskipun metode klasterisasi telah digunakan dalam beberapa studi sebelumnya, penelitian ini mengisi celah dengan fokus pada karakteristik mahasiswa Pendidikan Matematika, khususnya di Universitas Lambung Mangkurat. Penelitian ini juga menggunakan 12 variabel karakteristik, termasuk gaya belajar, kecemasan ujian, dan frekuensi bertanya, yang memberikan gambaran lebih menyeluruh dan komprehensif mengenai faktor-faktor yang mempengaruhi proses belajar mahasiswa sehingga diharapkan dapat memberikan kontribusi dalam merancang pendekatan pembelajaran yang lebih sesuai dengan profil karakteristik masing-masing klaster mahasiswa.

Oleh karena itu, tujuan penelitian ini untuk mengetahui profil karakteristik mahasiswa S1 Program Studi (Prodi) Pendidikan Matematika Jurusan Pendidikan Matematika dan IPA (PMIPA) Fakultas Keguruan dan Ilmu Pendidikan (FKIP) Universitas Lambung Mangkurat (ULM) dengan mengelompokkan karakteristik mahasiswa berdasarkan 12 variabel (jenis kelamin, usia, semester, IPK, waktu belajar per minggu, waktu belajar kelompok per minggu, frekuensi bertanya di kelas per minggu, minat terhadap matematika, gaya belajar, konsistensi dalam membuat jadwal belajar, percaya diri dalam menghadapi ujian, dan kecemasan dalam ujian matematika) menggunakan analisis klaster metode nonhierarki K-Means. Hasil penelitian ini diharapkan tidak sekadar memberikan wawasan baru secara teoritis, tetapi juga dapat digunakan sebagai dasar dalam memilih pendekatan pembelajaran yang tepat digunakan dalam kelas sesuai dengan profil karakteristik mahasiswa S1 Prodi Pendidikan Matematika PMIPA FKIP ULM.

METODE

Jenis penelitian ini adalah penelitian deskriptif kuantitatif, yaitu jenis penelitian yang bertujuan untuk mendeskripsikan atau menggambarkan karakteristik, fenomena, atau variabel secara sistematis, faktual, dan akurat dengan menggunakan data numerik (kuantitatif) (Creswell, 2014; Sugiyono, 2017). Subjek penelitian adalah mahasiswa S1 Program Studi Pendidikan Matematika PMIPA FKIP Universitas Lambung Mangkurat sebanyak 96 mahasiswa yang terdiri dari 26 mahasiswa Angkatan 2022, 24 mahasiswa Angkatan 2023, 22 mahasiswa Angkatan 2024, dan 24 mahasiswa Angkatan 2025.

Teknik pengumpulan data dalam penelitian ini menggunakan survei. Survei digunakan sebagai teknik pengumpulan data untuk memperoleh informasi terkait karakteristik mahasiswa yang menjadi subjek penelitian. Penggunaan survei ini bertujuan untuk mendapatkan gambaran yang representatif mengenai berbagai karakteristik mahasiswa.

Instrumen yang digunakan dalam penelitian ini adalah angket karakteristik mahasiswa. Angket disusun oleh tim peneliti dengan mengacu pada indikator karakteristik belajar mahasiswa dari berbagai sumber relevan (Hair et al., 2019; Liu et al., 2020; Marsh & Martin, 2011). Proses penyusunan angket dilakukan melalui beberapa tahap, yaitu: (1) penentuan indikator setiap variabel berdasarkan kajian teori dan hasil penelitian terdahulu; (2) penyusunan butir pernyataan dengan skala pengukuran yang sesuai (nominal, ordinal, atau Likert 1–5); (3) penilaian kelayakan isi oleh tiga dosen ahli pendidikan matematika. Berdasarkan hasil uji validitas isi, rata-rata nilai Aiken's V adalah 0,89. Koefisien Aiken's V berada pada rentang 0,80–1,00, yang menunjukkan tingkat kesepakatan tinggi antar ahli terhadap relevansi butir (Azwar, 2015). Dengan

demikian, angket ini dinilai layak digunakan untuk mengumpulkan data karakteristik mahasiswa Pendidikan Matematika Universitas Lambung Mangkurat.

Teknik analisis data pada penelitian ini menggunakan analisis kluster metode nonhierarki K-Means berbantuan aplikasi IBM SPSS Statistik 26. K-Means adalah metode klusterisasi yang berusaha membagi data menjadi k kluster, dimana setiap data di dalam suatu kluster lebih mirip satu sama lain daripada dengan data di kluster lain. Metode ini dimulai dengan dengan terlebih dahulu menentukan jumlah kluster yang diinginkan dalam penelitian, yaitu mengelompokkan mahasiswa sebanyak $n = 96$ ke dalam $k = 3$ kluster berdasarkan $p = 12$ variabel sehingga $k \leq n$. Metode ini digunakan untuk mengelompokkan mahasiswa berdasarkan karakteristik-karakteristik tertentu yang relevan dengan tujuan penelitian. Dengan menggunakan metode ini, peneliti dapat

mengidentifikasi pola atau kesamaan dalam data yang ada, sehingga dapat diketahui berbagai kelompok yang memiliki karakteristik serupa di antara mahasiswa.

HASIL DAN PEMBAHASAN

Hasil dari analisis kluster menggunakan metode nonhierarki K-Means yang bertujuan mengklusterisasikan karakteristik mahasiswa Pendidikan Matematika Universitas Lambung Mangkurat dengan menggunakan aplikasi IBM SPSS Statistik 26 adalah sebagai berikut.

Standardisasi Data

Data yang dikumpulkan dari 96 responden dengan 12 variabel memiliki variabilitas satuan, sehingga perlu dilakukan standarisasi atau transformasi variabel tersebut ke bentuk Z-score. Hasil perhitungan menggunakan SPSS untuk keperluan standarisasi data disajikan dalam Tabel 1.

Tabel 1 Nilai Statistik Deskriptif

No.	Variabel	Std. Deviation
1.	Jenis kelamin	.416
2.	Usia	1.175
3.	Semester	2.283
4.	IPK	.341
5.	Waktu belajar per minggu (jam)	14.849
6.	Waktu belajar kelompok per minggu (jam)	6.594
7.	Frekuensi bertanya di kelas per minggu	2.850
8.	Minat terhadap matematika	.670
9.	Gaya belajar	.812
10.	Konsistensi dalam membuat jadwal belajar	1.036
11.	Percaya diri dalam menghadapi ujian	.857
12.	Kecemasan dalam ujian	1.140

Nilai standar deviasi inilah yang dijadikan dasar dalam penentuan nilai Z-score. Selanjutnya dilakukan 2 uji asumsi dalam analisis kluster, yaitu asumsi bahwa sampel mewakili populasi dan tidak terjadi multikolinearitas.

Uji Asumsi dalam Analisis Kluster

Asumsi sampel mewakili populasi. Sebelum melakukan analisis kluster, perlu dilakukan uji asumsi untuk memastikan bahwa data sampel yang digunakan cukup representatif terhadap populasi. Salah satu cara untuk menguji kelayakan data tersebut adalah

dengan menggunakan nilai Kaiser-Meyer-Olkin (KMO), yang mengukur kecukupan sampel (sampling adequacy). Nilai KMO yang memadai menunjukkan bahwa pola hubungan antar variabel cukup kuat untuk dianalisis lebih lanjut melalui analisis kluster. Kriteria yang digunakan untuk menentukan apakah sampel tersebut mewakili populasi seperti pada Tabel 2.

Tabel 2 Kriteria Nilai KMO

Nilai KMO	Keterangan
KMO > 0,5	Sample representatif
KMO < 0,5	Sampel tidak representatif

Sumber: (Zaki et al., 2022)

Berdasarkan perhitungan menggunakan SPSS maka diperoleh nilai KMO seperti yang disajikan pada Tabel 3.

Tabel 3 Nilai KMO

KMO and Bartlett's Test			
Kaiser-Meyer-Olkin Measure of Sampling Adequacy.			.584
Bartlett's Test of Sphericity	Approx. Chi-Square		290.938
	df		66
	Sig.		.000

Berdasarkan Tabel 3 diatas diperoleh bahwa nilai KMO sebesar 0,584 yang berarti bahwa nilai KMO > 0,5. Maka dapat disimpulkan bahwa sampel yang diambil representative atau mewakili populasi.

Asumsi Multikolinearitas

Uji asumsi multikolinearitas ini bertujuan untuk memastikan bahwa variabel-variabel yang digunakan tidak saling berkorelasi tinggi satu sama lain, sehingga masing-masing variabel memberikan kontribusi yang unik dalam proses pembentukan kluster. Hal ini penting untuk menghindari ketidaksesuaian

dalam interpretasi hasil dalam analisis kluster yang diakibatkan oleh hubungan linear antar variabel. Penentuan multikolinearitas dapat dilihat dari nilai *Variance Inflation Factor* (VIF), dengan kriteria: $VIF < 10$ artinya tidak ada masalah multikolinearitas. $VIF \geq 10$ artinya menunjukkan adanya masalah multikolinearitas yang signifikan, yang berarti variabel independen tersebut memiliki korelasi yang sangat tinggi dengan variabel lainnya.

Berdasarkan perhitungan menggunakan SPSS maka diperoleh nilai VIF seperti yang disajikan pada Tabel 4.

Tabel 4 Hasil Uji Multikolinearitas

Model	Collinearity Statistics	
	Tolerance	VIF
Zscore: Usia	.241	4.155
Zscore: Semester	.238	4.201
Zscore: IPK	.710	1.409
Zscore: Waktu Belajar Perminggu (jam)	.631	1.586
Zscore: Waktu Belajar Kelompok Perminggu (jam)	.671	1.490
Zscore: Frekuensi bertanya dalam kelas	.929	1.076
Zscore: Minat belajar matematika	.653	1.532
Zscore: Gaya Belajar	.903	1.107
Zscore: Konsistensi dalam membuat jadwal belajar	.805	1.242
Zscore: Percaya diri dalam menghadapi ujian	.739	1.353
Zscore: Kecemasan dalam ujian	.809	1.236

Berdasarkan Tabel 4 terlihat bahwa nilai VIF semua variabel kurang dari 10, yang artinya tidak terjadi masalah multikolinearitas. Berdasarkan hasil uji asumsi yang telah dilakukan dapat disimpulkan bahwa ke-2 asumsi dalam analisis klaster telah terpenuhi sehingga proses analisis klaster dapat dilakukan.

Proses Clustering

Analisis klaster dengan metode Nonhierarki yaitu K-Means Clustering dilakukan dengan menggunakan IBM SPSS Statistic 26. Pada

analisis klaster ini ditentukan bahwa jumlah klaster yang akan dibentuk sebanyak 3 klaster. Berikut output analisis klaster menggunakan K-Means menggunakan SPSS. Initial Cluster

Pada tahapan initial cluster ini dapat diketahui tampilan awal proses klastering dengan melihat hasil sementara proses pengelompokan data sebelum dilakukan proses iterasi yang menunjukkan nilai pusat atau *centroid* klaster awal dari data yang sebelumnya telah dilakukan standarisasi (Puspita, 2021) seperti pada Tabel 5.

Tabel 5 Centroid Awal Klaster

	Initial Cluster Centers		
	Cluster		
	1	2	3
Zscore: Jenis Kelamin	.52639	-1.87995	.52639
Zscore: Usia	-.96602	-.11521	-1.81682
Zscore: Semester	-1.35031	.40144	-1.35031
Zscore: IPK	.99978	-4.07336	-.67172
Zscore: Waktu Belajar Perminggu (jam)	4.52132	-1.03475	2.16420
Zscore: Waktu Belajar Kelompok Perminggu (jam)	5.50611	-.86332	-.10505
Zscore: Frekuensi bertanya dalam kelas	.85886	-.89541	6.12167
Zscore: Minat belajar matematika	.27992	-1.21298	.27992
Zscore: Gaya Belajar	1.03895	-1.42374	-.19240
Zscore: Konsistensi dalam membuat jadwal belajar	.48254	-2.41269	-.48254
Zscore: Percaya diri dalam menghadapi ujian	2.08972	-1.40934	-.24299
Zscore: Kecemasan dalam ujian	-.63062	-.63062	.24677

Iterasi Analisis Klaster

Dua belas item dimasukkan melalui proses iterasi seperti terlihat pada Tabel 6.

Tabel 6 Iterasi Analisis Klaster

Iteration	Iteration History ^a		
	Change in Cluster Centers		
	1	2	3
1	5.211	5.489	5.958
2	.833	.396	.795
3	.391	.274	.347
4	.000	.119	.200
5	.000	.191	.319
6	.212	.150	.226
7	.000	.047	.070
8	.000	.000	.000

a. Convergence achieved due to no or small change in cluster centers. The maximum absolute coordinate change for any center is .000. The current iteration is 8. The minimum distance between initial centers is 8.770.

Tabel 6 menunjukkan bahwa proses iterasi dilakukan sebanyak 8 kali. Proses ini dilakukan untuk mendapatkan klaster yang tepat. Terlihat jarak minimum antar pusat klaster yang dihasilkan dari hasil iterasi adalah 8,770.

Jarak Antar Klaster

Tujuan dari melihat jarak antar pusat klaster (*distance between final cluster centers*)

adalah untuk menilai sejauh mana klaster yang terbentuk benar-benar berbeda satu sama lain, mendukung validitas dan kemudahan interpretasi hasil klasterisasi, semakin besar jaraknya, semakin kuat dugaan bahwa masing-masing klaster memiliki karakteristik yang unik (Hair et al., 2014). Hasil *between final cluster centers* seperti pada Tabel 7.

Tabel 7 Jarak antar klaster

Distances between Final Cluster Centers			
Cluster	1	2	3
1		3.641	2.971
2	3.641		2.611
3	2.971	2.611	

Berdasarkan Tabel 7 diperoleh klaster 1 dan klaster 2 yang memiliki jarak terbesar (3.641), artinya kedua klaster ini paling berbeda dalam hal karakteristik responden. Klaster 2 dan Klaster 3 memiliki jarak terkecil (2.611 artinya kedua klaster ini paling mirip satu sama lain dibanding kombinasi lainnya.

Jumlah Anggota Klaster

Jumlah anggota klaster yang dihasilkan adalah klaster 1 berjumlah 12 data mahasiswa, klaster 2 berjumlah 50 data mahasiswa

dan klaster 3 berjumlah 34 data mahasiswa. Total keseluruhan mahasiswa yang mengisi data adalah 96 orang.

Pengujian Tingkat Signifikan

Uji ANOVA dilakukan untuk melihat uji tingkat signifikansi antar klaster dan mengetahui perbedaan tiap klaster. Jika menggunakan F hitung dalam analisis klaster, kriterianya adalah semakin tinggi F hitung semakin besar perbedaan antara ketiga klaster yang dibuat, maka semakin tinggi Tingkat signifikansi dan F hitung. Hasil tes ANOVA ada pada Tabel 8.

Tabel 8 ANOVA

	Cluster		Error		F	Sig.
	Mean Square	df	Mean Square	df		
Zscore: Jenis Kelamin	6.228	2	.888	93	7.016	.001
Zscore: Usia	19.230	2	.608	93	31.632	.000
Zscore: Semester	23.312	2	.520	93	44.816	.000
Zscore: IPK	.226	2	1.017	93	.223	.801
Zscore: Waktu Belajar Perminggu (jam)	18.341	2	.627	93	29.249	.000
Zscore: Waktu Belajar Kelompok Perminggu (jam)	17.314	2	.649	93	26.671	.000
Zscore: Frekuensi bertanya dalam kelas	6.061	2	.891	93	6.801	.002
Zscore: Minat belajar matematika	3.562	2	.945	93	3.769	.027
Zscore: Gaya Belajar	.263	2	1.016	93	.259	.772

ANOVA								
			Cluster		Error		F	Sig.
			Mean Square	df	Mean Square	df		
Zscore:	Konsistensi dalam membuat jadwal belajar		5.487	2	.904	93	6.073	.003
Zscore:	Percaya diri dalam menghadapi ujian		11.887	2	.766	93	15.520	.000
Zscore:	Kecemasan dalam ujian		8.629	2	.836	93	10.323	.000
The F tests should be used only for descriptive purposes because the clusters have been chosen to maximize the differences among cases in different clusters. The observed significance levels are not corrected for this and thus cannot be interpreted as tests of the hypothesis that the cluster means are equal.								

Berdasarkan Tabel 8 diperoleh variabel yang paling membedakan anggota ketiga kluster adalah semester, karena mempunyai nilai F yang paling tinggi yaitu 44,816. Variabel yang mempunyai nilai sig > 0,05 adalah IPK, minat belajar matematika dan gaya belajar, artinya tidak berbeda secara signifikan antar kluster, sedangkan delapan variabel yang lainnya mempunyai nilai sig < 0,05 artinya variabel-

variabel tersebut berbeda secara signifikan antar kluster.

Interpretasi K-Means Cluster


Hasil akhir pusat kluster dapat dilihat informasi tentang proses standarisasi berdasarkan z-score seperti yang disajikan pada Tabel 9.

**Tabel 9 Final Kluster
Final Cluster Centers**

	Cluster		
	1	2	3
Zscore: Jenis Kelamin	.52639	.18950	-.46446
Zscore: Usia	-.89512	.59946	-.56564
Zscore: Semester	-.91237	.66421	-.65476
Zscore: IPK	-.07789	-.04358	.09159
Zscore: Waktu Belajar Perminggu (jam)	1.63104	-.27306	-.17410
Zscore: Waktu Belajar Kelompok Perminggu (jam)	1.58841	-.24154	-.20541
Zscore: Frekuensi bertanya dalam kelas	-.16446	-.28492	.47705
Zscore: Minat belajar matematika	-.21771	-.19781	.36774
Zscore: Gaya Belajar	.11544	-.06926	.06111
Zscore: Konsistensi dalam membuat jadwal belajar	-.16085	-.27022	.45415
Zscore: Percaya diri dalam menghadapi ujian	.43738	-.47626	.54601
Zscore: Kecemasan dalam ujian	-.33816	.40470	-.47579

Interpretasi terhadap nilai *Final Cluster Centers* dalam bentuk z-score didasarkan pada prinsip bahwa nilai positif menunjukkan bahwa skor berada di atas rata-rata, sedangkan nilai negatif menunjukkan bahwa skor berada di bawah rata-rata. Sementara itu nilai yang mendekati nol

mencerminkan bahwa skor tersebut mendekati nilai rata-rata populasi. Prinsip ini merupakan dasar dari proses standarisasi skor Z (Hair et al., 2014). Berdasarkan Tabel 9, maka diperoleh diagram hasil final kluster seperti pada Gambar 1.



Gambar 1 Diagram Final Klaster

Berdasarkan Tabel 9 dan Gambar 1, diperoleh karakteristik pada masing-masing klaster adalah:

1. Klaster 1 terdiri dari variabel jenis kelamin, waktu belajar per minggu, waktu belajar kelompok per minggu, gaya belajar dan percaya diri dalam menghadapi ujian berada di atas rata-rata total.
2. Klaster 2 terdiri dari variabel jenis kelamin, usia, semester dan kecemasan dalam ujian berada di atas rata-rata total.
3. Klaster 3 terdiri dari IPK, frekuensi bertanya dalam kelas, minat belajar matematika, gaya belajar, konsistensi dalam membuat jadwal belajar, percaya diri dalam menghadapi ujian berada di atas rata-rata total.

Analisis klaster yang dilakukan dalam penelitian ini menghasilkan tiga kelompok mahasiswa dengan karakteristik yang berbeda, berdasarkan 12 variabel yang telah distandardisasi dalam bentuk z-score. Perbedaan mencolok antar klaster tampak pada variabel intensitas waktu belajar, semester, frekuensi bertanya dalam kelas, serta tingkat percaya diri dan kecemasan menghadapi ujian. Klaster pertama dicirikan

oleh mahasiswa yang memiliki intensitas waktu belajar individu dan kelompok yang sangat tinggi ($Z = 1,63$ dan $Z = 1,59$), berada di semester awal ($Z = -0,91$), berusia lebih muda ($Z = -0,89$), dan memiliki tingkat kepercayaan diri menghadapi ujian yang lebih baik ($Z = 0,44$). Selain itu, kelompok ini didominasi oleh mahasiswa laki-laki. Berdasarkan karakteristik tersebut, klaster ini mencerminkan mahasiswa yang aktif dalam kegiatan belajar, terutama dalam mengalokasikan waktu untuk belajar secara mandiri maupun bersama. Temuan ini diperkuat oleh Liu et al. (2020) yang menemukan bahwa siswa dengan minat tinggi terhadap matematika dan keterlibatan belajar aktif cenderung memiliki kecenderungan akademik yang positif. Dukungan serupa juga ditemukan dalam studi Lawuna et al. (2024) yang menunjukkan bahwa mahasiswa pada semester awal cenderung memiliki motivasi belajar lebih tinggi, terutama dalam penguasaan materi dasar matematika.

Klaster kedua terdiri atas mahasiswa yang berada di semester dan usia lebih tinggi ($Z = 0,66$ dan $Z = 0,60$), namun memiliki waktu belajar yang rendah ($Z = -0,27$ untuk individu dan $Z = -0,24$ untuk

kelompok), serta tingkat kecemasan ujian yang relatif tinggi ($Z = 0,40$). Komposisi mahasiswa pada klaster ini juga masih didominasi oleh laki-laki. Karakteristik ini mencerminkan kecenderungan mahasiswa tingkat akhir yang mulai mengalami penurunan intensitas belajar atau menghadapi tekanan akademik tertentu. Temuan ini konsisten dengan penelitian Septaria & Fauzi (2021) yang menunjukkan bahwa mahasiswa dengan kemampuan pemecahan masalah matematis yang rendah cenderung mengalami partisipasi belajar yang rendah dan tekanan akademik yang lebih tinggi. Menurut Hair et al. (2019) juga mengungkapkan bahwa klaster mahasiswa dengan keterlibatan rendah dalam pembelajaran sering kali ditandai oleh skor z yang negatif pada indikator kebiasaan belajar, sebagaimana tercermin pada klaster ini.

Sementara itu, klaster ketiga menunjukkan karakteristik mahasiswa yang aktif dalam bertanya di kelas ($Z = 0,48$), memiliki konsistensi dalam membuat jadwal belajar ($Z = 0,45$), dan menunjukkan minat terhadap matematika yang tinggi ($Z = 0,37$). Mereka juga memiliki kepercayaan diri yang baik ($Z = 0,55$) dan tingkat kecemasan yang rendah ($Z = -0,48$). Klaster ini mayoritas diisi oleh mahasiswa perempuan ($Z = -0,46$) dan umumnya berasal dari semester awal. Karakteristik ini menggambarkan mahasiswa yang terorganisasi, proaktif, dan memiliki pendekatan belajar yang lebih strategis. Hasil ini sejalan dengan temuan Lathifaturrahmah et al. (2017) yang menyebutkan bahwa mahasiswa baru dari jalur reguler cenderung lebih terstruktur dalam pendekatan belajarnya. Hal ini juga diperkuat oleh Alfrina et al. (2019) yang menunjukkan bahwa keterampilan belajar dan sikap proaktif dalam pembelajaran merupakan faktor penting dalam pencapaian akademik mahasiswa.

Secara umum, hasil klasterisasi ini menegaskan bahwa mahasiswa pendidikan matematika memiliki karakteristik belajar yang beragam dan tidak bersifat homogen. Profil yang terbentuk dari analisis ini dapat menjadi dasar bagi dosen dan institusi untuk merancang strategi pembelajaran yang lebih diferensiatif dan responsif terhadap kebutuhan masing-masing kelompok mahasiswa. Strategi pembelajaran berbasis data seperti ini mendukung pendekatan *learner-centered*, di mana proses pembelajaran disesuaikan dengan kondisi aktual peserta didik. Menurut Hair et al. (2019) menekankan bahwa penggunaan data empiris dalam merancang strategi pengajaran dapat meningkatkan relevansi dan efektivitas proses pembelajaran di pendidikan tinggi.

PENUTUP

Berdasarkan hasil analisis terhadap 96 mahasiswa dan 12 variabel yang telah distandardisasi dalam bentuk z -score, diperoleh tiga klaster dengan karakteristik yang berbeda. Klaster pertama berisi mahasiswa semester awal yang memiliki intensitas belajar tinggi, baik secara individu maupun kelompok, serta menunjukkan kepercayaan diri yang baik. Klaster kedua didominasi oleh mahasiswa tingkat akhir dengan waktu belajar yang rendah dan kecemasan ujian yang tinggi. Sementara itu, klaster ketiga berisi mahasiswa yang konsisten dalam belajar, aktif bertanya, memiliki minat tinggi terhadap matematika, serta umumnya berasal dari semester awal dan berjenis kelamin perempuan. Hasil ini menunjukkan bahwa karakteristik belajar mahasiswa tidak bersifat homogen, melainkan terbagi ke dalam profil tertentu yang dapat diidentifikasi secara sistematis melalui pendekatan analisis klaster.

Berdasarkan hasil penelitian, disarankan kepada dosen dan pengelola

program studi pendidikan matematika untuk menerapkan pendekatan pembelajaran yang diferensiatif, sesuai dengan karakteristik tiap klaster mahasiswa. Bagi mahasiswa pada klaster dengan keterlibatan rendah, perlunya intervensi akademik seperti bimbingan belajar, mentoring, atau penugasan terstruktur untuk meningkatkan partisipasi dan motivasi belajar. Selain itu, mahasiswa pada klaster aktif dapat difasilitasi lebih lanjut dengan model pembelajaran kolaboratif dan proyek berbasis pemecahan masalah. Untuk penelitian selanjutnya, disarankan agar melibatkan jumlah responden yang lebih besar dan mempertimbangkan variabel tambahan seperti gaya kognitif, penggunaan teknologi dalam belajar, atau faktor sosial ekonomi agar profil klaster yang dihasilkan lebih komprehensif dan kontekstual.

DAFTAR RUJUKAN

- Alfrina, Hatidja, D., & Titaley, J. (2019). Analisis Cluster Terhadap Prestasi Mahasiswa Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sam Ratulangi Berdasarkan Nilai Akhir Mata Kuliah Wajib Tahun 2018. *d'CartesianN: Jurnal Matematika dan Aplikasi*, 8(1), 36–44. <https://doi.org/10.35799/dc.8.1.2019.24593>
- Azwar, S. (2015). *Reliabilitas dan Validitas (Edisi ke-4)*. Pustaka Pelajar.
- Creswell, J. W. (2014). *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches (4th ed.)*. London: Sage Publications.
- Dwitasari, D., & Yudhanegara, M. R. (2024). Analisis Klaster untuk Hubungan antara Kemampuan Komunikasi Matematis dengan Kemampuan Pemecahan Masalah Menggunakan K-Means. *Jurnal Educatio*, 10(3), 1025–1033. <https://doi.org/10.31949/educatio.v10i3.8234>
- Ediyanto, Mara, M. N., & Satyahadewi, N. (2013). Pengklasifikasian Karakteristik Dengan Metode K-Means Klaster Analysis. *BIMASTER: Buletin Ilmiah Matematika, Statistika dan Terapannya*, 2(2), 133–136. <https://doi.org/10.26418/bbimst.v2i02.3033>
- Everitt, B. S., Landau, S., Leese, M., & Stahl, D. (2011). *Cluster analysis (5th ed.)*. Wiley.
- Fadillahsyah, M. F., & Hasanuddin. (2025). Pengaruh lingkungan belajar terhadap motivasi belajar mahasiswa Pendidikan Matematika. *Jurnal Trigonometri*, 2(2), 89–97. <https://doi.org/10.30599/4zp6h476>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2014). *Multivariate Data Analysis (7th ed.)*. London: Pearson Education.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate Data Analysis (8th ed.)*. Boston: Cengage.
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques (3rd ed.)*. Morgan Kaufmann Publishers.
- Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651–666. <https://doi.org/10.1016/j.patrec.2009.09.011>
- Johnson, R. A., & Wincern, D. W. (1982). *Applied Multivariate Statistical Analysis*. Prentice Hal, Inc., New Jersey.
- Lathifaturrahmah, S., Fadilah, A., & Zulfikar, A. (2017). Penerapan Two Step Cluster Analysis untuk

- Mengelompokkan Mahasiswa Berdasarkan Jalur Masuk dan Asal Sekolah di IAIN Antasari Banjarmasin. *Jurnal Pendidikan Matematika*, 3(1), 45–54.
- Lawuna, M. P., Zega, Y., & Mendrofa, R. N. (2024). Analisis Cluster Mahasiswa Pendidikan Matematika Universitas Nias. *Jurnal Cendekia: Jurnal Pendidikan Matematika*, 8(2), 946–961.
<https://doi.org/10.31004/cendekia.v8i2.2940>
- Lawuna, S., Santoso, D., & Wahyuni, A. (2024). Analisis Kluster K-Means pada Mahasiswa Pendidikan Matematika Berdasarkan Prestasi Akademik dan Faktor Sosial Ekonomi. *Jurnal Cendekia: Jurnal Pendidikan Matematika*, 8(2), 134–145.
- Liu, X., Koirala, H., & Corliss, S. (2020). Cluster Analysis of Students' Mathematics Anxiety and Interest Patterns. *Journal of Educational Research*, 113(2), 123–135.
- Marsh, H. W., & Martin, A. J. (2011). Academic self-concept and academic achievement: Relations and causal ordering. *British Journal of Educational Psychology*, 81(1), 59–77.
- Messakh, G. C., Hayati, M. N., & Sifriyani. (2023). Penerapan Metode K-Means dalam Pengelompokan Kabupaten/Kota di Kalimantan Berdasarkan Indikator Pendidikan. *Jurnal EKSPONENSIAL*, 14(2), 57–66.
<http://jurnal.fmipa.unmul.ac.id/index.php/exponensial57>
- Ningrat, D. R., Maruddani, D. A. I., & Wuryandari, T. (2016). Analisis Cluster dengan Algoritma K-Means dan Fuzzy C-Means Clustering untuk Pengelompokan Data Obligasi Korporasi. *Jurnal Gaussian*, 5(4), 641–650.
- Puspita, R. N. (2021). Analisis K-Means Cluster Pada Kabupaten/Kota Di Provinsi Banten Berdasarkan Indikator Indeks Pembangunan Manusia. *Jurnal Lebesgue: Jurnal Ilmiah Pendidikan Matematika, Matematika Dan Statistika*, 2(3), 267–281.
- Santhi, M. V. B. T., Sai Leela, V. R. N. S. S. V., Anitha, P. U., & Nagamalleswari, D. (2011). Enhancing K-Means Clustering Algorithm. *IJCST*, 2(4), 73–77.
- Septaria, K., & Fauzi, M. A. (2021). Analisis Kluster Kemampuan Pemecahan Masalah Matematis Siswa SMA. *Jurnal Riset Pendidikan Matematika*, 8(1), 45–58.
- Sugiyono. (2017). *Metode Penelitian Kuantitatif, Kualitatif, dan R&D*. Bandung: Alfabeta.
- Suyal, M., & Sharma, S. (2024). A Review on Analysis of K-Means Clustering Machine Learning Algorithm based on Unsupervised Learning. *Journal of Artificial Intelligence and Systems*, 6(1), 85–95.
<https://doi.org/10.33969/ais.2024060106>
- Tall, D. (2008). The transition to formal thinking in mathematics. *Mathematics Education Research Journal*, 20, 5–24.
<https://doi.org/10.1007/BF03217474>
- Tan, P. N., Steinbach, M., & Kumar, V. (2019). *Introduction to data mining (2nd ed.)*. Pearson.
- Usman, H., & Sobari, N. (2013). *Aplikasi Teknik Multivariate untuk Riset*

- Pemasaran. PT RajaGrafindo Persada.
- Xu, R., & Wunsch, D. (2005). Survey of Clustering Algorithms. *IEEE Transactions on Neural Networks*, 16(3), 645–678. <https://doi.org/10.1109/TNN.2005.845141>
- Xu, Y., Fu, X., Li, H., Dong, G., & Wang, Q. (2018). A K-means Algorithm Based on Feature Weighting. *MATEC Web of Conferences*, 232. <https://doi.org/10.1051/mateconf/201823203005>
- Zaki, A., Irwan, & Sembe, I. A. (2022). Penerapan K-Means Clustering dalam Pengelompokan Data (Studi Kasus Profil Mahasiswa Matematika FMIPA UNM). *Journal of Mathematics, Computations, and Statistics*, 5(2), 163–176. <http://www.ojs.unm.ac.id/jmathcos>