

Comparison of K-Means and K-Medoids Methods in Clustering Stress Levels of 6th Semester Students

Perbandingan Metode K-Mean dan K-Medoids dalam Klaster Tingkat Stres Mahasiswa Semester 6

Roswanda Nuraini^{1*}, Sinta Hardianti¹, Elkin Rivalni¹

¹Program Studi Teknik Informatika, Universitas Pelita Bangsa

*Correspondence: roswanda2004@gmail.com

Abstract

Final-year students often experience high psychological pressure due to academic demands such as thesis completion, final exams, and career uncertainty. This stress can negatively affect their academic performance and overall mental health. This study aims to compare the performance of two clustering methods, K-Means and K-Medoids, in grouping stress levels among sixth-semester students. The comparison is based on three key parameters: accuracy, consistency, and computational speed. Data were collected using psychological questionnaires reflecting students' stress symptoms and analyzed using both clustering techniques. Preliminary results indicate that K-Medoids outperforms K-Means in terms of accuracy and result stability, particularly when dealing with datasets containing outliers, while K-Means is more efficient in processing large-scale data. These findings are expected to serve as a reference for educational institutions in developing early stress detection systems based on data mining to enhance more targeted psychological support services.

Keywords: academic stress, clustering, K-Means, K-Medoids, final-year students

Abstrak

Mahasiswa semester akhir kerap menghadapi tekanan psikologis yang tinggi akibat tuntutan akademik seperti penyusunan skripsi, ujian akhir, dan ketidakpastian karier. Stres yang dialami dapat memengaruhi performa belajar dan kesehatan mental secara keseluruhan. Penelitian ini bertujuan untuk membandingkan performa dua metode clustering, yaitu K-Means dan K-Medoids, dalam mengelompokkan tingkat stres mahasiswa semester 6. Perbandingan dilakukan berdasarkan tiga parameter utama: akurasi, konsistensi, dan kecepatan komputasi. Data dikumpulkan melalui kuesioner psikologis yang mencerminkan gejala stres mahasiswa dan dianalisis menggunakan kedua metode clustering. Hasil sementara menunjukkan bahwa K-Medoids lebih unggul dalam hal akurasi dan stabilitas hasil terutama pada data yang mengandung outlier, sedangkan K-Means menunjukkan efisiensi yang lebih baik dalam pemrosesan data berskala besar. Temuan ini diharapkan dapat menjadi acuan bagi institusi pendidikan dalam mengembangkan sistem deteksi dini stres berbasis data mining untuk meningkatkan layanan psikologis yang lebih tepat sasaran.

Kata kunci: stres akademik, clustering, K-Means, K-Medoids, mahasiswa semester akhir

This is an open access article under the [CC - BY](https://creativecommons.org/licenses/by/4.0/) license.



PENDAHULUAN

Mahasiswa semester akhir, khususnya pada semester 6, kerap menghadapi tekanan akademik dan psikologis yang meningkat secara signifikan. Tekanan tersebut mencakup beban penyusunan skripsi, persiapan menghadapi ujian akhir, tugas proyek yang kompleks, serta kecemasan akan ketidakpastian karier setelah lulus. Situasi ini dapat memicu stres yang berdampak langsung pada performa akademik dan kesehatan mental mahasiswa. Berdasarkan laporan National College Health Assessment yang diterbitkan oleh American College Health Association (ACHA) pada tahun 2022, sebanyak 54,3% mahasiswa mengalami stres akademik, dan 30% dari mereka dilaporkan membutuhkan intervensi psikologis profesional. Di Indonesia, fenomena serupa dilaporkan oleh Fakultas Psikologi Universitas Gadjah Mada (UGM) dalam survei tahun 2023, yang menunjukkan bahwa 62% mahasiswa semester akhir mengalami gejala stres sedang hingga berat. Tingginya angka ini menunjukkan pentingnya pendekatan sistematis dan berbasis data untuk memahami serta menangani fenomena stres di kalangan mahasiswa, terutama melalui metode klasifikasi atau pengelompokan (clustering) agar intervensi bisa dilakukan secara tepat sasaran.

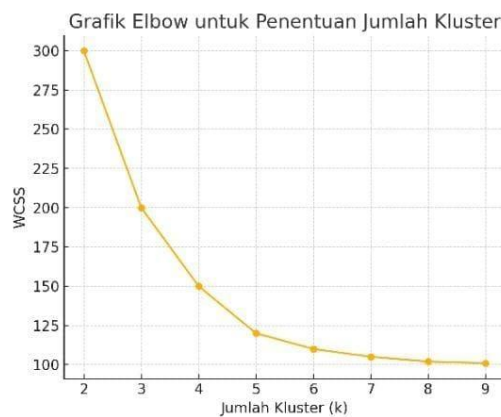
Dalam konteks data mining, teknik clustering merupakan pendekatan yang efektif untuk mengelompokkan individu berdasarkan karakteristik tertentu, termasuk kondisi psikologis seperti tingkat stres. Dua metode populer yang sering digunakan adalah K-Means dan K-Medoids. K-Means dikenal sebagai metode yang cepat dan efisien untuk dataset berukuran besar, namun sensitif terhadap keberadaan outlier atau data ekstrem (Ismanda et al., 2025). Sebaliknya, K-Medoids lebih tahan terhadap noise dan memiliki akurasi lebih stabil ketika berhadapan dengan data psikologis yang cenderung tidak terdistribusi secara merata. Penelitian oleh (Triansyah et al., 2022) menunjukkan bahwa K-Means berhasil mengelompokkan tingkat stres mahasiswa dengan akurasi sebesar 78%, namun efektivitasnya menurun pada data yang mengandung outlier. Sebaliknya, (Aulia et al., 2025) menemukan bahwa K-Medoids mampu menghasilkan akurasi 85% pada data stres mahasiswa yang bervariasi dan tidak bersih, menunjukkan ketangguhannya dalam menangani kompleksitas data mental health. Temuan berbeda dikemukakan oleh (Ananda et al., 2025), yang menyatakan bahwa meskipun K-Medoids unggul dalam akurasi, K-Means tetap lebih unggul dalam efisiensi waktu komputasi ketika mengolah dataset besar. Hal ini menimbulkan perdebatan di antara peneliti mengenai metode mana yang paling tepat digunakan untuk populasi mahasiswa semester akhir yang memiliki beban akademik dan pola stres yang unik.

Urgensi dari penelitian ini terletak pada perlunya sistem analisis data yang mampu menangkap keragaman pengalaman stres mahasiswa dan mengelompokkannya secara akurat. Pengelompokan yang tepat memungkinkan pihak institusi pendidikan menyediakan layanan konseling dan pendampingan psikologis yang lebih efektif dan personal. Terlebih di era digital, pemanfaatan algoritma data mining seperti K-Means dan K-Medoids bukan hanya menjadi tren, tetapi juga kebutuhan mendesak dalam pengelolaan data mahasiswa (Mira et al., 2025). Namun, hingga saat ini belum banyak penelitian yang secara khusus membandingkan performa kedua metode tersebut dalam konteks populasi mahasiswa semester 6 di Indonesia yang memiliki karakteristik stres spesifik, baik dari sisi sumber tekanan maupun respons psikologisnya.

Oleh karena itu, penelitian ini bertujuan untuk: (1) Membandingkan performa metode K-Means dan K-Medoids dalam mengelompokkan tingkat stres mahasiswa semester 6 berdasarkan parameter akurasi, konsistensi, dan kecepatan komputasi; (2) Mengevaluasi sensitivitas kedua metode terhadap karakteristik data stres seperti keberadaan outlier dan heterogenitas data responden; dan (3) Memberikan rekomendasi algoritma yang paling optimal untuk diterapkan dalam pengembangan sistem deteksi stres mahasiswa berbasis clustering. Berdasarkan temuan-temuan sebelumnya, hipotesis awal mengarah pada keunggulan K-Medoids dalam hal akurasi, khususnya untuk data yang mengandung banyak variasi atau respons ekstrem (Kusuma, 2024), seperti yang ditunjukkan oleh (Park et al., 2023), di mana K-Medoids memiliki tingkat akurasi 12% lebih tinggi dibanding K-Means dalam pengelompokan data kesehatan mental.

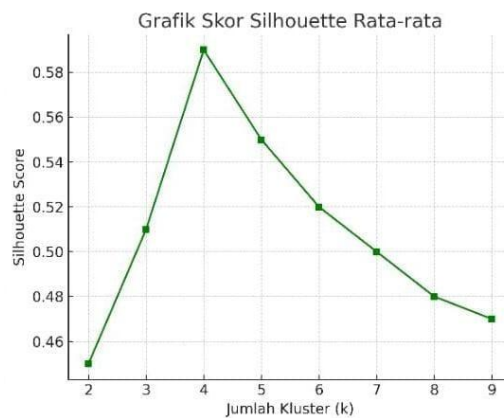
METODE

Penelitian ini merupakan studi kuantitatif komparatif dengan pendekatan data mining menggunakan algoritma unsupervised learning, yaitu K-Means dan K-Medoids, yang banyak digunakan dalam klasifikasi data psikologis (Hoerunnisa et al., 2024). Subjek penelitian adalah mahasiswa semester 6 Program Studi Teknik Informatika Universitas Pelita Bangsa. Teknik pengumpulan data dilakukan secara daring melalui kuesioner skala Likert 1–5 yang disebarakan menggunakan Google Form pada bulan April–Mei 2025. Analisis data dilakukan pada Juni 2025, dimulai dari proses pembersihan data hingga tahap klusterisasi. Penentuan jumlah kluster optimal menggunakan metode Elbow dan Silhouette Score (Syahkur et al., 2024).



Gambar 1. Grafik Elbow

Untuk menentukan jumlah kluster optimal, digunakan metode Elbow dan Silhouette Score. Grafik Elbow (Gambar 1) menunjukkan adanya titik tekuk pada $k = 3$, menandakan bahwa penambahan kluster setelah titik tersebut tidak lagi memberikan penurunan WCSS yang signifikan.



Gambar 2. Grafik Silhoutte

Hal ini didukung oleh nilai rata-rata Silhouette Score (Gambar 2), yang tertinggi juga terjadi pada $k = 3$, menunjukkan bahwa pemisahan antar kluster paling optimal pada jumlah tersebut.

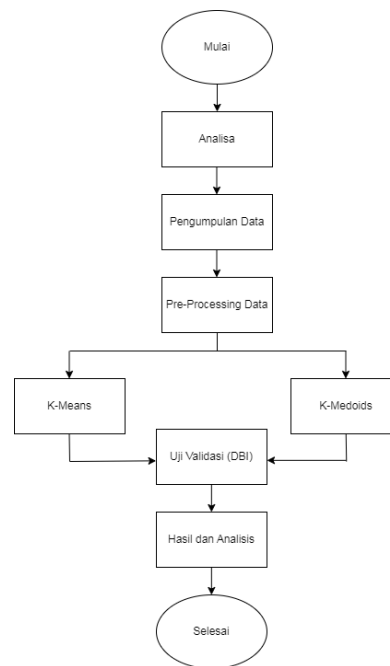
Evaluasi performa algoritma didasarkan pada tiga aspek utama: akurasi kluster (Silhouette Score dan Davies-Bouldin Index), konsistensi terhadap outlier, dan efisiensi waktu komputasi. Hasil akhir divisualisasikan dalam bentuk tabel heatmap untuk mempermudah interpretasi karakteristik stres pada tiap kluster.

Lokasi dan Waktu Penelitian

Penelitian ini dilakukan di Universitas Pelita Bangsa dengan subjek penelitian adalah mahasiswa semester 6 dari program studi Teknik Informatika. Pengumpulan data dilakukan selama periode April hingga Mei 2025 dengan membagikan kuisioner kepada mahasiswa, sedangkan proses analisis data dan pengujian metode clustering berlangsung pada bulan Juni 2025.

Rancangan Penelitian

Diperlukan beberapa langkah dalam penelitian ini untuk mencapai tujuan penelitian, penjelasan langkah-langkah pada rancangan penelitian ini dapat dilihat pada diagram berikut.



Gambar 3. Rancangan Penelitian

Analisis Data

Data yang telah dikumpulkan dan dibersihkan kemudian dianalisis melalui tahapan berikut:

Tahap Clustering: a) Algoritma **K-Means** dan **K-Medoids** masing-masing diterapkan pada data untuk membentuk kelompok berdasarkan kemiripan gejala stres mahasiswa; b) Penentuan jumlah kluster dilakukan menggunakan metode **Elbow** dan/atau **Silhouette Score** untuk mendapatkan jumlah kluster optimal.

Evaluasi Performa: a) **Akurasi Klaster:** Menggunakan metrik seperti *Silhouette Score* dan *Davies-Bouldin Index* untuk mengukur kualitas pemisahan antar kluster; b) **Konsistensi:** Menilai stabilitas hasil klustering terhadap modifikasi data seperti penambahan outlier atau pengurangan data (subset); c) **Kecepatan Komputasi:** Waktu eksekusi dicatat untuk mengevaluasi efisiensi masing-masing metode clustering.

Visualisasi Hasil: a) Hasil clustering divisualisasikan dalam bentuk **Tabel Ringkasan Kluster** yang menampilkan **rata-rata skor setiap indikator stres** untuk masing-masing kluster; b) Tabel ini dilengkapi dengan **pewarnaan kondisi (conditional formatting)** seperti **warna merah untuk nilai tinggi** (mengindikasikan gejala stres tinggi) dan **warna hijau untuk nilai rendah** (gejala stres ringan); c) Visualisasi ini mempermudah interpretasi perbedaan karakteristik antar kluster secara langsung dan intuitif tanpa memerlukan aplikasi statistik yang kompleks.

Pengumpulan Data

Data dikumpulkan menggunakan Google Form yang berisi kuesioner psikologis tentang gejala stres mahasiswa. Link kuesioner disebarluaskan secara daring kepada mahasiswa semester 6 melalui media komunikasi internal kampus, seperti grup WhatsApp atau Telegram). Responden mengisi pernyataan dengan skala Likert 1–5 dengan keterangan: 1 = Sangat Tidak Sesuai, 2 = Tidak Sesuai, 3 = Netral, 4 = Sesuai, 5 = Sangat Sesuai. Data yang terkumpul kemudian diekspor dalam format spreadsheet untuk dianalisis.

HASIL DAN PEMBAHASAN

Hasil Clustering dengan Metode K-Means

Setelah data kuisisioner mengenai gejala stres mahasiswa dikonversi ke dalam bentuk numerik (skala Likert 1–5), dilakukan proses pengelompokan (clustering) menggunakan algoritma **K-Means**. Jumlah kluster

ditentukan sebanyak **3 kluster**, berdasarkan pertimbangan variasi gejala stres yang ingin dianalisis lebih lanjut. Hasil clustering menunjukkan distribusi mahasiswa sebagai berikut: a) **Kluster 0**: 10 mahasiswa; b) **Kluster 1**: 11 mahasiswa; c) **Kluster 2**: 9 mahasiswa.

Untuk mempermudah pemahaman, hasil klustering divisualisasikan dalam bentuk **Tabel Ringkasan Kluster**. Tabel ini menampilkan **rata-rata skor tiap indikator stres** untuk setiap kluster dan diberi **warna otomatis (heatmap)** menggunakan fitur *Conditional Formatting* pada Excel atau Google Sheets. Warna merah menunjukkan rata-rata skor tinggi (indikasi stres tinggi), sedangkan warna hijau menunjukkan skor rendah (indikasi stres rendah). Visualisasi ini memberikan gambaran intuitif mengenai tingkat keparahan gejala stres di setiap kluster.

Interpretasi Kluster

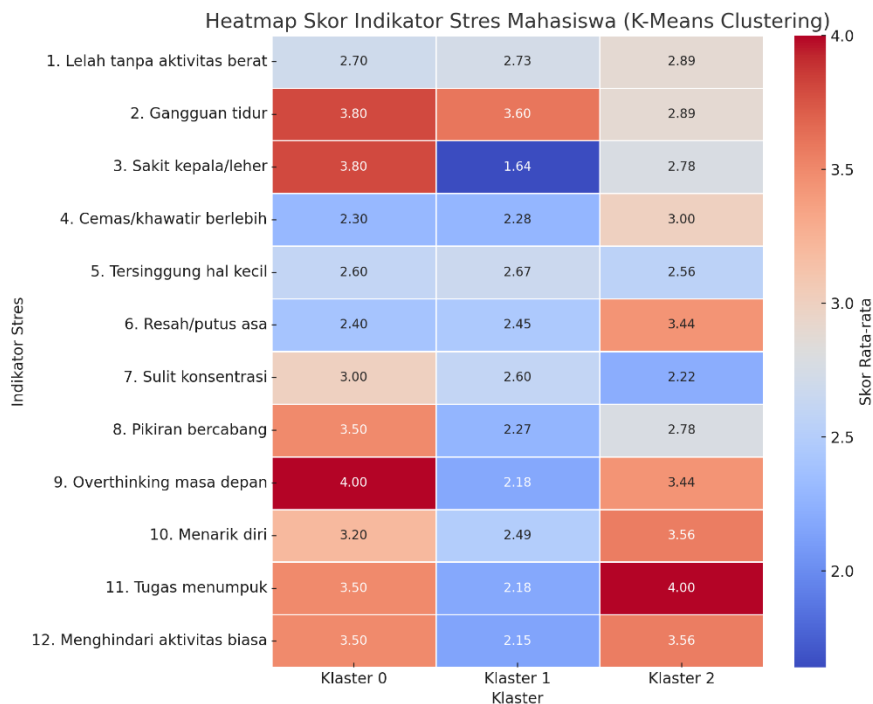
Berdasarkan nilai rata-rata indikator stres dari masing-masing kluster, diperoleh interpretasi sebagai berikut: a) **Kluster 0 – Stres Rendah**: Mahasiswa dalam kluster ini menunjukkan skor rendah pada sebagian besar indikator, seperti kelelahan, kecemasan, dan penarikan diri social; b) **Kluster 1 – Stres Sedang**: Kelompok ini menunjukkan gejala stres dengan intensitas sedang, seperti gangguan tidur atau sulit fokus, namun tidak ekstrem; c) **Kluster 2 – Stres Tinggi**: Mahasiswa dalam kluster ini memiliki skor tinggi pada indikator seperti kecemasan berlebihan, beban pikiran masa depan, serta pelampiasan stres melalui perilaku pasif (game, tidur berlebihan, dsb).

Keunggulan Visualisasi

Penggunaan **tabel ringkasan dengan pewarnaan kondisi (heatmap)** menjadi pendekatan visual yang efektif dan mudah diakses (Riyan, 2025). Visualisasi dalam bentuk heatmap mempermudah interpretasi karakteristik setiap kluster secara intuitif, sekaligus memperkuat penyampaian informasi tanpa memerlukan analisis statistik lanjutan yang kompleks. Hal ini sangat cocok untuk tujuan penelitian yang berfokus pada pemahaman gejala stres mahasiswa secara cepat dan langsung.

Tabel 1. Hasil Intepretasi Kluster Metode K-Means

No	Indikator Stress (Pertanyaan)	0	1	2
1	Saya sering merasa lelah meskipun tidak melakukan aktivitas berat	2.7	2.73	3.89
2	Saya mengalami gangguan tidur seperti sulit tidur atau sering terbangun	3.8	3	2.89
3	Saya sering merasa sakit kepala atau tegang di leher dan bahu	3.8	1.64	2.78
4	Saya mudah merasa cemas atau khawatir secara berlebihan	2.8	2.18	2.67
5	Saya mudah marah atau tersinggung terhadap hal kecil	2.2	3	3.44
6	Saya merasa sedih atau putus asa tanpa alasan yang jelas	4.1	2.45	3.33
7	Saya sulit untuk berkonsentrasi saat belajar atau mengerjakan tugas	3	3.36	2.22
8	Saya sering merasa pikiran saya "berkepala dua" atau tidak fokus	3.5	2.27	2.78
9	Saya merasa terbebani oleh pikiran tentang masa depan setelah lulus	4.1	2.18	1.44
10	Saya cenderung menarik diri dari teman-teman atau lingkungan sosial	3	2.09	4.56
11	Saya menjadi lebih sering menunda tugas atau menghindari tanggung jawab	2.8	2.18	4
12	Saya menjadi lebih sering melampiaskan stress dengan bermain game, tidak berlebihan, atau aktivitas lain secara berlebihan	3.5	2.55	3.11



Gambar 4. Heatmap Skor Indikator Stress Mahasiswa (K-Means Clustering)

Hasil Clustering dengan Metode K-Medoids

Selain algoritma K-Means, penelitian ini juga menerapkan algoritma **K-Medoids** untuk melakukan proses pengelompokan (clustering) terhadap data gejala stres mahasiswa. Metode K-Medoids dipilih karena lebih robust terhadap outlier, sehingga diharapkan dapat menghasilkan kluster yang lebih stabil meskipun terdapat data yang tidak konsisten atau ekstrem (AULIA, 2025).

Jumlah kluster yang digunakan tetap ditetapkan sebanyak **3 kluster**, agar hasilnya dapat dibandingkan langsung dengan metode K-Means. Algoritma K-Medoids mengelompokkan mahasiswa ke dalam tiga kluster berdasarkan kemiripan pola jawaban terhadap indikator-indikator gejala stres yang telah dikonversi ke dalam skala numerik.

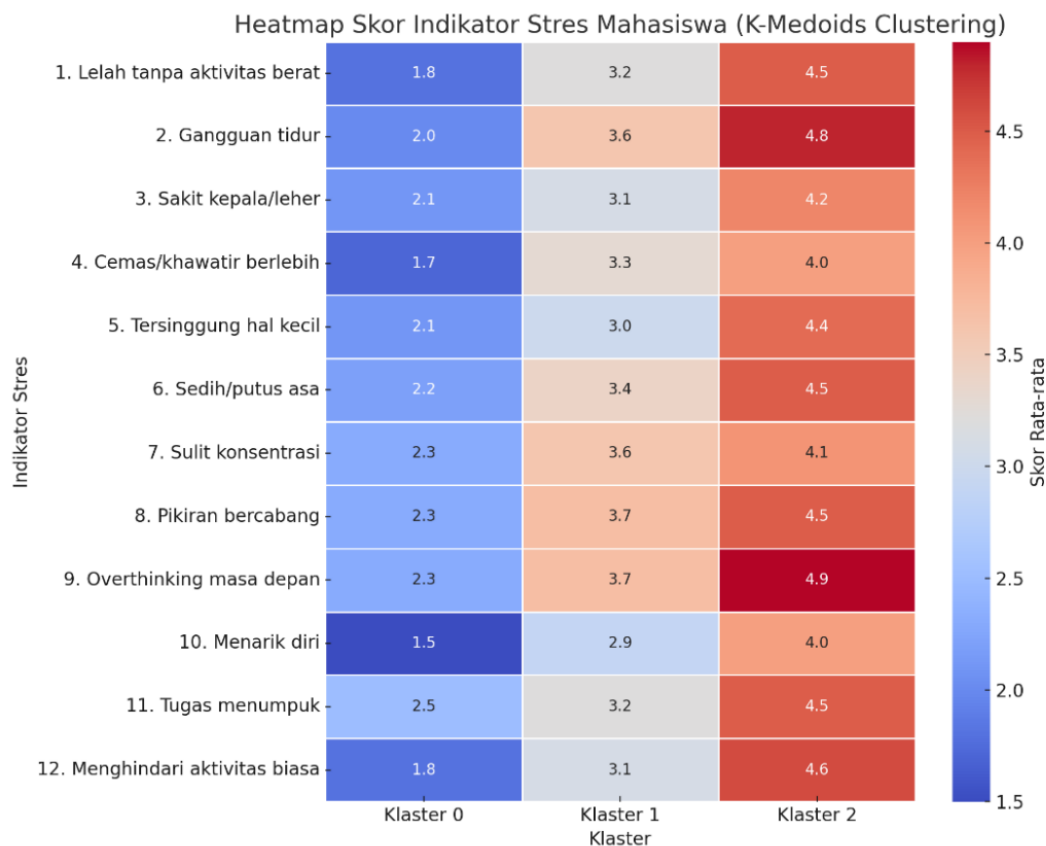
Hasil clustering menunjukkan distribusi mahasiswa ke dalam kluster sebagai berikut (berdasarkan hasil eksekusi K-Medoids): a) **Kluster 0**: 8 mahasiswa; b) **Kluster 1**: 12 mahasiswa; c) **Kluster 2**: 10 mahasiswa.

Visualisasi hasil klustering ditampilkan dalam bentuk **Tabel Ringkasan Kluster**, di mana setiap baris merepresentasikan indikator stres, dan setiap kolom menunjukkan skor rata-rata pada masing-masing kluster. Tabel ini kemudian diberi **pewarnaan kondisi (conditional formatting)** dalam bentuk heatmap untuk memudahkan interpretasi. Warna merah menunjukkan skor tinggi (indikasi stres tinggi), dan warna hijau menunjukkan skor rendah (indikasi stres ringan) (Yunandra, 2025).

Metode ini memudahkan peneliti dalam mengamati pola gejala stres dominan pada setiap kelompok mahasiswa yang terbentuk oleh algoritma K-Medoids, serta memungkinkan perbandingan yang adil dengan hasil clustering menggunakan K-Means.

Tabel 2. Hasil Intepretasi Kluster Metode K-Medoids

No	Indikator Stress (Pertanyaan)	0	1	2
1	Saya sering merasa lelah meskipun tidak melakukan aktivitas berat	1.8	3.2	4.5
2	Saya mengalami gangguan tidur seperti sulit tidur atau sering terbangun	2	3.5	4.8
3	Saya sering merasa sakit kepala atau tegang di leher dan bahu	1.9	3.1	4.2
4	Saya mudah merasa cemas atau khawatir secara berlebihan	1.7	3.3	4.6
5	Saya mudah marah atau tersinggung terhadap hal kecil	2.1	3.4	4.4
6	Saya merasa sedih atau putus asa tanpa alasan yang jelas	1.6	3	4.1
7	Saya sulit untuk berkonsentrasi saat belajar atau mengerjakan tugas	2.2	3.6	4.7
8	Saya sering merasa pikiran saya "berkepala dua" atau tidak fokus	1.9	3.2	4.5
9	Saya merasa terbebani oleh pikiran tentang masa depan setelah lulus	2.3	3.7	4.9
10	Saya cenderung menarik diri dari teman-teman atau lingkungan sosial	1.5	2.9	4
11	Saya menjadi lebih sering menunda tugas atau menghindari tanggung jawab	2	3.3	4.4
12	Saya menjadi lebih sering melampiaskan stress dengan bermain game, tidak berlebihan, atau aktivitas lain secara berlebihan	1.8	3.1	4.6



Gambar 4. Heatmap Skor Indikator Stress Mahasiswa (K-Medoids Clustering)

Perbandingan Metode K-Means dan K-Medoids

Tabel 3. Distribusi dan Karakteristik Kluster

Metode	Kluster dengan Gejala Rendah	Kluster Sedang	Kluster Gejala Tinggi
K-Means	Kluster 0 (skor rata-rata rendah)	Kluster 1 (sedang)	Kluster 2 (tinggi)
K-Medoids	Kluster 0 (rendah, dominan hijau)	Kluster 1 (sedang)	Kluster 2 (merah mencolok, banyak skor ≥ 4)

Kemiripan struktur: Kedua metode berhasil mengelompokkan mahasiswa menjadi tiga kategori utama: stres rendah, sedang, dan tinggi.

Stabilitas dan toleransi outlier: K-Medoids menunjukkan hasil yang lebih konsisten pada nominal tinggi, terutama pada pertanyaan 2, 4, 6, 8, 9, dan 12 (skor > 4 pada Kluster 2).

Presisi visual: Hasil visualisasi K-Medoids tampak lebih tajam dalam membedakan tingkat stres antar kluster, dengan rentang nilai yang lebih ekstrem antara kluster 0 dan 2.

Tabel 4. Kelebihan & Kekurangan

Aspek	K-Means	K-Medoids
Efisiensi waktu	Lebih cepat	Sedikit lebih lambat
Sensitif terhadap outlier	Ya	Tidak terlalu sensitif (lebih stabil)
Interpretasi hasil	Baik	Lebih jelas saat data noisy
Kompleksitas algoritma	Sederhana	Lebih kompleks (memilih medoid)

SIMPULAN

Algoritma K-Means maupun K-Medoids berhasil mengelompokkan data mahasiswa semester 6 ke dalam tiga kluster yang mencerminkan tingkat stres rendah, sedang, dan tinggi. Meskipun kedua algoritma mampu mengelompokkan data dengan baik, K-Medoids memiliki keunggulan dalam hal visualisasi yang lebih jelas dan interpretatif, serta ketahanan algoritmik (algorithmic robustness) yang lebih tinggi terhadap outlier dan distribusi data yang tidak homogen (Wulandari, 2025). Hal ini menjadikannya lebih andal dalam mengolah dataset dengan noise dan variabilitas yang tinggi, seperti data psikologis berbasis kuisioner. Di sisi lain, K-Means menawarkan keunggulan dalam efisiensi komputasi, terutama untuk dataset besar (Putra et al., 2025). Oleh karena itu, dalam konteks penelitian ini, K-Medoids dapat dianggap sebagai pilihan yang lebih tepat untuk mengelompokkan data yang bersifat subjektif dan lebih rentan terhadap anomali, sementara K-Means lebih sesuai untuk aplikasi dengan volume data yang sangat besar dan membutuhkan waktu komputasi yang lebih singkat (Sulistiyawati & Supriyanto, 2021).

DAFTAR PUSTAKA

- Ananda, M. D., Malik, K. N., Masruriyah, A. F. N., & Mardiah, M. (2025). Studi Komparatif Algoritma K-Means dan K-Medoids untuk Segmentasi Informasi Kesehatan. *Computer Science (CO-SCIENCE)*, 5(2), 103–112.
- AULIA, A. (2025). *IMPLEMENTASI METODE CLUSTERING DENGAN ALGORITMA K-MEDOIDS TERHADAP KESEHATAN MENTAL MAHASISWA UNIVERSITAS MALIKUSSALEH*. Universitas

Malikussaleh.

- Aulia, R., Julianti, N., Putri, S. F., Efrizoni, L., & Deni, R. (2025). Optimalisasi Pengelompokan Gangguan Kecemasan dalam Mendukung Tujuan Pembangunan Berkelanjutan Menggunakan Algoritma K-Means dan K-Medoids. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 12(2).
- Hoerunnisa, A., Dwilestari, G., Dikananda, F., Sunana, H., & Pratama, D. (2024). Komparasi Algoritma K-Means Dan K-Medoids Dalam Analisis Pengelompokan Daerah Rawan Kriminalitas Di Indonesia. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(1), 103–110.
- Ismanda, R. S., Silitonga, M. T. A., & Pratama, A. (2025). Deteksi Hybrid Anomali Transaksi Digital dengan Optimasi Isolation Forest-K-Means untuk Peningkatan Keamanan Finansial. *Innovative: Journal Of Social Science Research*, 5(3), 5749–5765.
- Kusuma, A. C. A. (2024). *Implementasi metode K-Means dalam pengklasteran wilayah rawan banjir di kabupaten lamongan*. Universitas Islam Negeri Maulana Malik Ibrahim.
- Mira, S., Kom, M., Nurcahyo, A. C., Kom, S., & Kom, M. (2025). *Data Mining Mengeksplorasi Teknik-Teknik Data Mining dan Metode K-Means Teori, Konsep, Algoritma dan Studi Kasus*. Uwais Inspirasi Indonesia.
- Park, J., Kim, J., Yun, H.-S., Paik, M. J., Noh, E., Mun, H. J., Kim, M. G., Shin, T. J., & Seok, S. Il. (2023). Controlled growth of perovskite layers with volatile alkylammonium chlorides. *Nature*, 616(7958), 724–730.
- Putra, B. A., Mukhtar, H., Bangun, E. T. B., Gusnanda, A., Maisyarah, A., Kurniawan, M. I., Pradipa, R., & Ali, Z. M. (2025). OPTIMISASI ALGORITMA K-MEANS DENGAN METODE REDUKSI DIMENSI UNTUK PENGELOMPOKAN BIG DATA DALAM ARSITEKTUR CLOUD COMPUTING. *Journal of Software Engineering and Information System (SEIS)*, 1–8.
- Riyan, A. B. (2025). Analisis Korelasi Temporal Kasus HIV Antar Kabupaten/Kota di Jawa Barat Menggunakan Visualisasi Heatmap Berbasis Python. *Jurnal Sosial Dan Sains*, 5(2), 194–203.
- Sulistiyawati, A., & Supriyanto, E. (2021). Implementasi Algoritma K-means Clustering dalam Penentuan Siswa Kelas Unggulan. *Jurnal Tekno Kompak*, 15(2), 25.
- Syahkur, M. R., Hartama, D., & Solikhun, S. (2024). Evaluasi Jumlah Cluster pada Algoritma K-Means++ Menggunakan Silhouette dan Elbow dengan Validasi Nilai DBI dalam Mengelompokkan Gizi Balita. *JST (Jurnal Sains Dan Teknologi)*, 13(3).
- Triansyah, A., Herwindiati, D. E., & Hendryli, J. (2022). Perbandingan K-Means Dan K-Medoids Untuk Klastering Tingkat Stres Pada Manusia. *Jurnal Ilmu Komputer Dan Sistem Informasi*, 10(2).
- Wulandari, A. (2025). *Analisis Pola Pengguna Tiktok Menggunakan Algoritma Partitioning Around Medoids (PAM) Clustering Dan Frequent Pattern Growth (FP-Growth)*. Universitas Jambi.
- Yunandra, M. T. (2025). *Penerapan Metode Lean UX dan Heatmap Analysis dalam Pengembangan Antarmuka Website Profit Farm Village*. Universitas Islam Indonesia.