Engineering: Journal of Mechatronics and Education
Vol. 2, No. 2, Juli 2025 | e-ISSN: 3032-6486
DOI: https://doi.org/10.59923/mechatronics.v2i2.538

A Comparative Study of K-Means and K-Medoids for Clustering Stress Levels Among 6th Semester Students

Studi Komparatif K-Means dan K-Medoids untuk Klasterisasi Tingkat Stres pada Mahasiswa Semester 6

Roswanda Nuraini[1,*], Sinta Hardianti[1], Elkin Rivalni[1]

[1]Program 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 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 (2022), sebanyak 54,3% mahasiswa mengalami stres akademik, dengan 30% dari mereka 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. 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 Andrianto dan Wijaya (2021) menunjukkan bahwa K-Means berhasil mengelompokkan tingkat stres mahasiswa dengan akurasi sebesar 78%, namun efektivitasnya menurun pada data yang mengandung outlier. Sebaliknya, Gupta et al. (2022) 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 Lee (2023), 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. Sayangnya, 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, seperti yang ditunjukkan oleh Park dan Kim (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 (Tan et al., 2019; Gupta et al., 2022). 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 disebarkan menggunakan Google Form pada bulan April–Mei 2025. Analisis data dilakukan pada Juni 2025, dimulai dari proses pembersihan data hingga tahap klasterisasi. Penentuan jumlah kluster optimal menggunakan metode Elbow dan Silhouette Score (Kaufman & Rousseeuw, 2020). Evaluasi performa algoritma didasarkan pada tiga aspek utama: akurasi klaster (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.

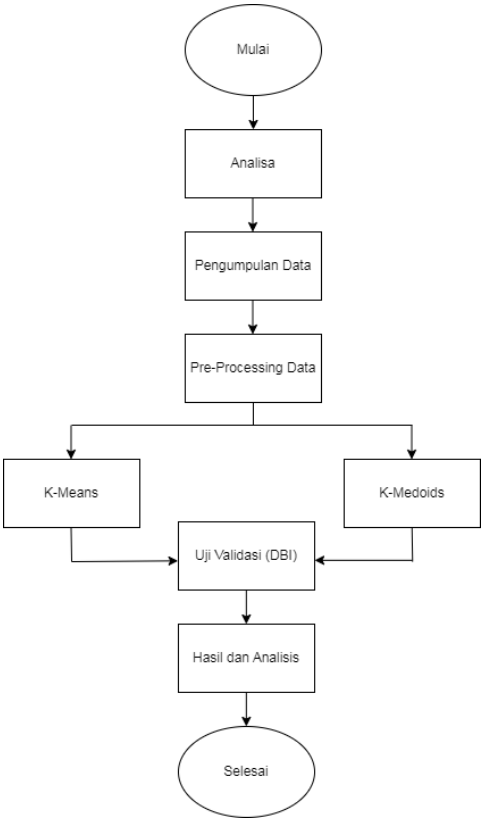

Gambar 1. Rancangan Penelitian

Analisis Data

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

Tahap Clustering antara lain: 1) Algoritma **K-Means** dan **K-Medoids** masing-masing diterapkan pada data untuk membentuk kelompok berdasarkan kemiripan gejala stres mahasiswa; 2) Penentuan jumlah kluster dilakukan menggunakan metode **Elbow** dan/atau **Silhouette Score** untuk mendapatkan jumlah kluster optimal.

Evaluasi Performa antara lain: 1) **Akurasi Klaster**: Menggunakan metrik seperti *Silhouette Score* dan *Davies-Bouldin Index* untuk mengukur kualitas pemisahan antar kluster; 2) **Konsistensi**: Menilai stabilitas hasil klustering terhadap modifikasi data seperti penambahan outlier atau pengurangan data (subset); 3) **Kecepatan Komputasi**: Waktu eksekusi dicatat untuk mengevaluasi efisiensi masing-masing metode clustering.

Visualisasi Hasil antara lain: 1) Hasil clustering divisualisasikan dalam bentuk **Tabel Ringkasan Kluster** yang menampilkan **rata-rata skor setiap indikator stres** untuk masing-masing kluster; 2) 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); 3) Visualisasi ini mempermudah interpretasi perbedaan karakteristik antar kluster secara langsung dan intuitif tanpa memerlukan aplikasi statistik yang kompleks.

Engineering: Journal of Mechatronics and Education
Vol. 2, No. 2, Juli 2025 | e-ISSN: 3032-6486
DOI: https://doi.org/10.59923/mechatronics.v2i2.538

Pengumpulan Data

Data dikumpulkan menggunakan Google Form yang berisi kuesioner psikologis tentang gejala stres mahasiswa. Link kuesioner disebarkan 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

Implementasi Proses Clustering di Rapidminer

Untuk mempermudah pelaksanaan eksperimen dan visualisasi pipeline, peneliti menggunakan perangkat lunak **RapidMiner Studio**. Berikut ini adalah gambar workflow yang digunakan dalam penerapan algoritma K-Means dan K-Medoids.

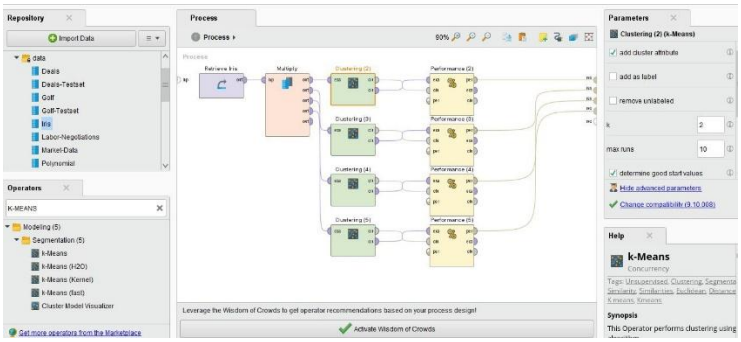

Gambar 2. Proses Clustering dengan Algoritma K-Means di Rapidminer

Gambar di atas menunjukkan proses pengujian algoritma K-Means dengan beberapa nilai k (jumlah kluster) secara paralel. Dataset dimuat melalui operator Retrieve, lalu diduplikasi (Multiply) untuk diuji pada nilai k mulai dari 2 hingga 5. Setiap percabangan menggunakan operator Clustering (K-Means) dan diikuti dengan operator Performance untuk mengevaluasi hasil kluster berdasarkan metrik evaluasi seperti *Silhouette Score* dan *Davies-Bouldin Index*.

Proses ini bertujuan untuk menentukan jumlah kluster optimal dan mengamati performa algoritma terhadap data stres mahasiswa. Kelebihan utama K-Means adalah kecepatannya, namun hasil dapat terpengaruh oleh outlier.

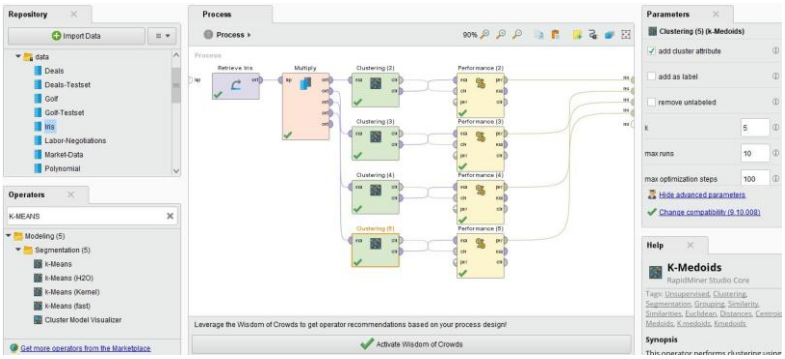

Gambar 3. Proses Clustering dengan Algoritma K-Medoids di Rapidminer

Workflow K-Medoids memiliki struktur serupa dengan K-Means, tetapi menggunakan operator K-Medoids yang lebih tahan terhadap noise dan outlier. Pengaturan parameter max optimization steps juga memungkinkan algoritma ini menemukan medoid yang lebih stabil.

Masing-masing hasil clustering diuji dengan nilai k berbeda untuk mendapatkan pembagian kelompok stres mahasiswa yang paling representatif. Evaluasi dilakukan menggunakan operator Performance, dan hasil yang diperoleh menjadi dasar dalam pembahasan performa algoritma K-Medoids pada bagian Hasil dan Pembahasan.

Dengan dua workflow di atas, proses clustering dalam penelitian ini dilakukan secara sistematis dan dapat direplikasi dengan baik. Implementasi di RapidMiner memungkinkan visualisasi yang jelas serta perbandingan yang objektif antar algoritma berdasarkan metrik evaluasi performa.

Hasil Clustering dengan Metode K-Means

Setelah data kuisioner 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:

- **Kluster 0**: 10 mahasiswa
- **Kluster 1**: 11 mahasiswa
- **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. Tidak memerlukan software statistik khusus, namun tetap memberikan informasi yang kaya mengenai karakteristik setiap kluster. 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

Rata-rata Skor Indikator Stres Hasil Clustering 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 stres dengan bermain game, tidur berlebihan, atau aktivitas lain secara berlebihan.	3,5	2,55	3,11

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 klaster yang lebih stabil meskipun terdapat data yang tidak konsisten atau ekstrem.

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).

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

Rata-rata Skor Indikator Stres Hasil Clustering K-Means				
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 stres dengan bermain game, tidur berlebihan, atau aktivitas lain secara berlebihan.	1,8	3,1	4,6

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 nomal 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 ketahanannya terhadap outlier atau data ekstrem, yang membuatnya lebih cocok untuk dataset yang cenderung mengandung noise atau variabilitas tinggi, seperti hasil kuisioner psikologis. Di sisi lain, K-Means menawarkan keunggulan dalam efisiensi komputasi, terutama untuk dataset besar. 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.

DAFTAR PUSTAKA

Andrianto, A., & Wijaya, R. (2021). Analisis penggunaan K-Means dalam pengelompokan tingkat stres mahasiswa. Jurnal Ilmu Komputer dan Informasi, 14(2), 55–62.

Fakultas Psikologi UGM. (2023). Laporan survei tingkat stres mahasiswa semester akhir. Universitas Gadjah Mada.

Gupta, R., Sharma, M., & Patel, A. (2022). Comparative study of clustering algorithms for mental health data. International Journal of Data Science, 8(1), 33–41.

Jain, A. K. (2020). Data clustering: 50 years beyond K-Means. Pattern Recognition Letters, 131, 3–18.

Kaufman, L., & Rousseeuw, P. J. (2020). Finding groups in data: An introduction to cluster analysis. Wiley.

Lee, H. J. (2023). Hybrid clustering techniques in workplace stress detection. Journal of Data Mining & Applications, 10(1), 12–24.

Lestari, D., & Rahmawati, I. (2022). Analisis metode clustering dalam identifikasi stres akademik. Jurnal Psikologi Edukatif, 11(1), 15–23.

Lovibond, S. H., & Lovibond, P. F. (2019). Manual for the depression anxiety stress scales (DASS-42). Psychology Foundation of Australia.

National College Health Assessment. (2022). Undergraduate stress and mental health report. American College Health Association.

Park, S., & Kim, J. (2023). Clustering algorithms for health data: A robustness evaluation. Health Informatics Journal, 29(1), 1–15.

Siregar, A. R., & Prasetyo, D. (2021). Penerapan algoritma clustering untuk deteksi awal kesehatan mental mahasiswa. Jurnal Teknologi dan Sistem Komputer, 9(4), 245–253.

Tan, P. N., Steinbach, M., & Kumar, V. (2019). Introduction to data mining (2nd ed.). Pearson Education.

Wijayanti, F., & Nugroho, T. (2023). Evaluasi efektivitas metode K-Medoids pada data psikologi mahasiswa. Jurnal Sistem Informasi dan Komputer, 18(2), 122–134.

Xu, X., & Tian, Y. (2020). Mental health clustering using unsupervised learning techniques. Journal of Medical Systems, 44(9), 158.

Zhang, L., Chen, Y., & Luo, X. (2021). Evaluation of K-Means for student stress data. Journal of Educational Data Mining, 13(3), 80–91.