

Hybrid K-Means Clustering dan MARCOS dalam Sistem Pendukung Keputusan Pemilihan Mahasiswa Berprestasi Berbasis Konsistensi Nilai Akademik

Annisa Elfina Augustia¹, Andreas Adi Trinoto², Erlin Windia Ambarsari^{3*}

^{1,2,3}Teknik Informatika, Universitas Indraprasta PGRI, Indonesia

¹annisaelfina16@gmail.com, ²a.trinoto@gmail.com, ^{3*}erlinunindra@gmail.com

Abstrak: Penelitian ini bertujuan untuk mengatasi kelemahan sistem seleksi mahasiswa berprestasi yang sering kali hanya mengandalkan nilai akumulatif (IPK) tanpa mempertimbangkan stabilitas performa akademik mahasiswa. Ketimpangan nilai yang ekstrem antara komponen Tugas, UTS, dan UAS dianggap sebagai hambatan bagi dosen pengampu dalam mengevaluasi dinamika belajar yang sesungguhnya. Oleh karena itu, diusulkan sebuah model pendukung keputusan *hybrid* yang mengintegrasikan algoritma K-Means Clustering dan metode MARCOS. Dalam implementasinya, algoritma K-Means digunakan sebagai penyaring awal untuk mendeteksi anomali data melalui fitur *Mean* dan Standar Deviasi. Berdasarkan metode *Elbow*, ditemukan bahwa jumlah kluster optimal adalah dua ($k=2$), yang membagi 129 data mahasiswa menjadi 80 mahasiswa dengan profil nilai konsisten (Kluster Normal) dan 49 mahasiswa dengan nilai yang fluktuatif (Kluster Anomali). Validasi kluster menunjukkan *Silhouette Score* sebesar 0,4869. Mahasiswa pada Kluster Normal kemudian diperingkat menggunakan metode MARCOS yang mempertimbangkan bobot kriteria, yaitu Tugas (20%), UTS (30%), dan UAS (50%). Hasil uji sensitivitas melalui Koefisien Korelasi Spearman menunjukkan nilai sebesar 0,9418, yang secara kuantitatif membuktikan bahwa posisi mahasiswa pada peringkat teratas tetap stabil dan tidak tergoyahkan meskipun dilakukan simulasi perubahan bobot kriteria. Penelitian ini menyimpulkan bahwa penggabungan K-Means dan MARCOS menghasilkan sistem evaluasi yang lebih objektif, transparan, dan tahan terhadap bias subjektif, sehingga sangat layak diterapkan untuk menyeleksi kandidat dengan prestasi yang konsisten.

Kata Kunci: Konsistensi Akademik; Sistem Pendukung Keputusan; K-Means Clustering; Metode MARCOS; Pemingkatan Mahasiswa

Abstract: This study aims to address the shortcomings of the selection system for high-achieving students, which often relies solely on cumulative grade point average (GPA) without considering the stability of students' academic performance. Extreme disparities in grades between assignments, midterm exams, and final exams are considered an obstacle for instructors in evaluating actual learning dynamics. Therefore, a hybrid decision support model is proposed that integrates the K-Means Clustering algorithm and the MARCOS

method. In its implementation, the K-Means algorithm is used as an initial filter to detect data anomalies through the Mean and Standard Deviation features. Based on the Elbow method, it was found that the optimal number of clusters is two ($k=2$), which divides the 129 student data points into 80 students with consistent grade profiles (Normal Cluster) and 49 students with fluctuating grades (Anomaly Cluster). Cluster validation showed a Silhouette Score of 0.4869. Students in the Normal Cluster were then ranked using the MARCOS method, which considered the following weighted criteria: Assignments (20%), Midterm Exam (30%), and Final Exam (50%). The results of the sensitivity test using Spearman's correlation coefficient yielded an average value of 0.9418, quantitatively indicating that the top-ranked students' positions remain stable and unshaken even when simulations of changes in criterion weights are conducted. This study concludes that the combination of K-Means and MARCOS produces an evaluation system that is more objective, transparent, and resistant to subjective bias, making it highly suitable for selecting candidates with consistent performance.

Keywords: Academic Consistency; Decision Support System; K-Means Clustering; MARCOS Method; Student Ranking

1. PENDAHULUAN

Nilai akademik berfungsi sebagai alat ukur pencapaian dari hasil upaya mahasiswa di dunia pendidikan[1]. Secara umum, komponen utama yang menjadi indikator pencapaian tersebut meliputi nilai tugas, UTS, dan UAS. Ketiga penilaian ini kemudian diakumulasikan ke dalam Indeks Prestasi Semester (IPS) untuk satu semester berjalan, serta nilai keseluruhan semester yang ditempuh mahasiswa dalam bentuk Indeks Prestasi Kumulatif (IPK)[2]. Nilai IPK inilah yang menjadi pertimbangan dalam pemilihan mahasiswa berprestasi[3].

Namun, pada realitasnya, nilai tersebut terkadang sulit dijadikan standardisasi untuk mengukur apakah mahasiswa tersebut benar-benar memahami keseluruhan substansi keilmuan[4]. Oleh sebab itu, dosen pengampu tidak mendapat gambaran secara keseluruhan penguasaan materi yang diterima oleh mahasiswa[5]. Faktor utama yang dijadikan perhatian terdapat kejomplangan nilai di antara nilai Ujian setiap mahasiswa, misalkan didapati nilai UTS 50, namun UAS 100 [6], [7].

Jika ini dikaitkan dengan mahasiswa berprestasi, maka dosen pengampu tidak dapat mengevaluasi dinamika proses belajar mahasiswa yang sesungguhnya. Keterbatasan evaluasi berbasis agregat ini membuat dosen tidak memiliki alat ukur untuk mengetahui rancangan materi kuliah dapat diasimilasi oleh mahasiswa. Oleh karena itu, penelitian ini memfokuskan pada inkonsistensi nilai untuk mengevaluasi strategi pengajaran ke depan.

Analisis inkonsistensi dilakukan dengan memilah anomali data yang diperoleh dari daftar nilai akumulatif mahasiswa. Ketika ditemukan nilai inkonsistensi yang berfluktuasi secara ekstrem, data tersebut akan dipisahkan dari *subset* utama. Kumpulan data inkonsistensi ini diamati secara mendalam untuk menganalisis seberapa banyak mahasiswa yang mengalami pola fluktuasi yang serupa. Persentase inkonsistensi nilai dapat menjadi indikator objektif bahwa dosen pengampu perlu mengevaluasi kembali metode pengajarannya. Sementara itu, *subset* nilai mahasiswa yang menunjukkan kestabilan akan dilanjutkan ke tahap pemeringkatan.

Dengan demikian, deteksi anomali data dapat dilakukan melalui dua pendekatan, yaitu klasifikasi dan pengelompokan (*clustering*)[8]. Pendekatan klasifikasi memerlukan data yang telah memiliki label tersurat, seperti label "normal" dan "anomali" [9]. Sebaliknya, pendekatan pengelompokan dilakukan berdasarkan kemiripan karakteristik data tanpa memerlukan pelabelan terlebih dahulu [10], [11]. Dikarenakan data *subset* pada penelitian

ini belum menentukan data mana yang dikategorikan sebagai anomali, maka pendekatan yang digunakan dalam penelitian ini adalah model pengelompokan[12].

Data akademik dalam penelitian ini memiliki atribut numerik dengan skala yang konsisten. Sifat data inilah yang menjadikan algoritma K-Means Clustering sebagai pendekatan yang paling relevan. Algoritma tersebut meminimalkan varians internal untuk membentuk dua kluster, sehingga pemisahan antara data normal dan anomali dapat ditentukan secara objektif berdasarkan jarak titik data ke *centroid*.


Validasi pendekatan ini didukung oleh Ditya & Tanti [13] yang menerapkan K-Means pada lalu lintas jaringan LAN. Dengan menentukan nilai $k=2$ menggunakan metode *Elbow*, penelitian tersebut mampu mengklasifikasikan data ke dalam kategori normal dan anomali dengan presisi 100%. Sejalan dengan studi tersebut, Ismanda et al. [14] menggunakan K-Means untuk mengelompokkan data transaksi digital ke dalam tiga kluster optimal, di mana anomali terbukti terkonsentrasi pada kluster tertentu sehingga pola data yang menyimpang dapat diidentifikasi secara efektif tanpa memerlukan pelabelan data terlebih dahulu.

Setelah kluster normal teridentifikasi melalui K-Means, langkah selanjutnya adalah memetakan mahasiswa dengan performa unggul secara objektif. Data yang diproses pada tahap ini difokuskan hanya pada *subset* mahasiswa di dalam kluster normal. Penyaringan ini memastikan bahwa dosen pengampu hanya mengevaluasi mahasiswa dengan profil capaian nilai (UTS, UAS, dan tugas) yang konsisten dan seimbang. Untuk mengimplementasikan pemeringkatan tersebut, penelitian ini menggunakan Sistem Pendukung Keputusan (SPK) berbasis metode MARCOS [15]. Pemilihan MARCOS didasarkan pada kemampuannya mengintegrasikan solusi ideal dan anti-ideal, sehingga mampu memetakan posisi setiap mahasiswa secara komprehensif terhadap standar performa tertinggi dan terendah secara stabil [16].

Mengacu pada kebutuhan tersebut, penelitian ini mengusulkan sebuah model hybrid yang mengintegrasikan K-Means Clustering dan MARCOS. Arsitektur *hybrid* pada metode MARCOS sendiri telah terbukti secara literatur sangat andal dan stabil ketika diterapkan dalam sistem seleksi yang melibatkan evaluasi berbagai kriteria multidimensi [17]. Perpaduan kedua metode ini diharapkan mampu menutupi kelemahan evaluasi akademik klasik.

2. METODE PENELITIAN

Penelitian ini menerapkan pendekatan *hybrid* menggunakan algoritma K-Means Clustering dan metode MARCOS untuk menentukan pemeringkatan mahasiswa berprestasi. Seluruh tahapan eksperimen, mulai dari ekstraksi data mentah, pemodelan, hingga validasi hasil, diimplementasikan menggunakan bahasa pemrograman Python 3 yang dieksekusi di dalam lingkungan komputasi awan (*cloud computing*) Google Colab. Kerangka kerja yang menggambarkan seluruh alur sistem secara terstruktur disajikan pada Gambar 1.



Gambar 1. Kerangka Kerja Hybrid K-Means dan MARCOS

Ekstraksi dan Prapemrosesan Data Akademik

Data penelitian bersumber dari dokumen rekapitulasi hasil studi mahasiswa di lingkungan Universitas Indraprasta PGRI (UNINDRA). Pengambilan dataset ini tidak dibatasi pada satu mata kuliah spesifik, melainkan menggunakan sampel dari berbagai mata kuliah dengan syarat utama memiliki struktur dan format penilaian baku yang seragam. Keseragaman format yang memuat komponen nilai Tugas, UTS, dan UAS ini sangat penting agar mesin pembelajaran dapat membaca dan memetakan matriks nilai secara presisi.

Proses pembacaan tabel dan ekstraksi teks dari berkas PDF tersebut dieksekusi secara otomatis menggunakan pustaka *pdfplumber* pada lingkungan Python 3. Setelah data berhasil ditarik, prapemrosesan langsung diarahkan untuk membuang baris teks non-nilai (seperti header mata kuliah, nama dosen, dan kolom tanda tangan) yang ikut terbaca selama pemindaian dokumen.

Sistem kemudian melakukan penyaringan *string* untuk menghilangkan karakter non-numerik pada kolom nilai, menyelaraskan baris kosong (*missing values*) akibat mahasiswa yang tidak mengikuti ujian, serta mengonversi tipe data menjadi format *float* agar kompatibel dengan komputasi mesin. *Output* dari tahap ini adalah matriks data bersih yang berisi Nomor Pokok Mahasiswa (NPM) beserta tiga fitur nilai utama yang siap diolah lebih lanjut.

Rekayasa Fitur Konsistensi Nilai

Untuk mentransformasi data nilai mentah menjadi indikator perilaku belajar mahasiswa, dilakukan rekayasa fitur dengan menghitung dua variabel statistik baru dari baris data Tugas, UTS, dan UAS setiap mahasiswa:

1. Fitur Rata-rata (*Mean*): Dihitung sebagai variabel yang merepresentasikan tingkat capaian akademik kumulatif mahasiswa dari ketiga komponen nilai.
2. Fitur Standar Deviasi (*Standard Deviation*): Dihitung khusus sebagai parameter kuantitatif untuk mengukur deviasi atau fluktuasi nilai internal mahasiswa. Fitur ini menangkap inkonsistensi performa; skor standar deviasi yang tinggi menunjukkan adanya kesenjangan ekstrem antar komponen nilai (misalnya, nilai UTS tinggi namun nilai Tugas sangat rendah).

Kedua fitur baru ini disusun menjadi matriks input dua dimensi yang akan digunakan sebagai basis pemisahan data pada tahap *clustering*.

Segmentasi Data Menggunakan K-Means dan Elbow Method

Matriks fitur konsistensi mahasiswa dikelompokkan menggunakan algoritma K-Means. Penentuan jumlah kluster optimal (*k*) dilakukan secara empiris dengan mengevaluasi nilai *Within-Cluster Sum of Squares* (WCSS) pada rentang $k=1$ hingga $k=10$ [18]. Titik sudut (*elbow*) yang dihasilkan menjadi dasar penentuan parameter $k=2$. Jarak spasial antar data nilai dihitung menggunakan metrik *Euclidean Distance* melalui persamaan berikut [19]:

$$d(x, c) = \sqrt{\sum_{i=1}^n (x_i - c_i)^2} \quad (1)$$

Proses iterasi K-Means menghasilkan dua titik pusat (*centroid*) yang membagi mahasiswa ke dalam dua kelompok:

1. Kluster Anomali (Inkonsisten) dikenali secara otomatis dari koordinat *centroid* yang memiliki nilai standar deviasi tinggi. Data pada kluster ini diisolasi dan dikeluarkan dari kandidat pemeringkatan.
2. Kluster Normal (Konsisten) dikenali dari koordinat *centroid* dengan standar deviasi rendah dan sebaran nilai yang stabil. *Subset* data mahasiswa dalam kluster inilah yang diteruskan ke tahap pengambilan keputusan.

Validitas pemisahan ruang kluster ini diukur menggunakan metrik *Silhouette Score* untuk memastikan tidak ada pencilaan data akademik yang tumpang tindih.

Pemeringkatan Mahasiswa Berprestasi dengan MARCOS

Mahasiswa yang berada dalam Kluster Normal dikompilasi ke dalam matriks keputusan metode MARCOS untuk ditentukan urutan prestasinya. Karakteristik kriteria nilai Tugas, UTS, dan UAS seluruhnya ditentukan sebagai kriteria keuntungan (benefit criteria). Langkah komputasi MARCOS diimplementasikan secara spesifik sebagai berikut [15]:

1. Pembentukan Matriks Ekstensi

Menentukan Solusi Ideal (x_{ai}) berdasarkan nilai maksimum dan Solusi Anti-Ideal (x_{aai}) berdasarkan nilai minimum dari sebaran data mahasiswa di kluster normal untuk masing-masing kriteria (Tugas, UTS, UAS).

2. Normalisasi Matriks Keputusan

Oleh karena seluruh kriteria bersifat benefit, transformasi elemen matriks dinormalisasi dengan membandingkan capaian nilai setiap mahasiswa (x_{ij}) terhadap Solusi Ideal (x_{ai}) pada kriteria yang bersesuaian melalui rumus:

$$n_{ij} = \frac{x_{ij}}{x_{ai}} \quad (2)$$

3. Pembentukan Matriks Terbobot

Untuk pembobotan, dilakukan dengan menggunakan elemen hasil normalisasi dikalikan dengan bobot preferensi kriteria. Penetapan bobot ini diadopsi dari pedoman standar evaluasi akademik yang berlaku di Universitas Indraprasta PGRI (UNINDRA), di mana proporsi penilaian akhir ditetapkan sebesar 20% untuk Tugas, 30% untuk UTS, dan 50% untuk UAS. Oleh karena itu, matriks bobot diinisialisasi dengan nilai $w_{Tugas} = 0,20$; $w_{UTS} = 0,30$; $w_{UAS} = 0,50$. Matriks terbobot (v_{ij}) dibentuk melalui perkalian elemen normalisasi dengan bobot tersebut:

$$v_{ij} = n_{ij}xw_j \quad (3)$$

4. Perhitungan Derajat Utilitas (K_i^+ dan K_i^-)

Tahap ini diawali dengan menghitung total akumulasi nilai terbobot dari setiap mahasiswa ($S_i = \sum_{j=1}^n v_{ij}$). Selanjutnya, derajat utilitas diukur sebagai rasio nilai tersebut terhadap total nilai terbobot solusi ideal (S_{ai}) dan solusi anti-ideal (S_{aai}):

$$K_i^+ = \frac{S_i}{S_{ai}}, K_i^- = \frac{S_i}{S_{aai}} \quad (4)$$

5. Penentuan Fungsi Utilitas Akhir ($f(K_i)$)

Menghitung fungsi utilitas setiap mahasiswa terhadap solusi ideal ($f(K_i^+)$) dan anti-ideal ($f(K_i^-)$) menggunakan persamaan:

$$f(K_i^+) = \frac{K_i^-}{K_i^+ + K_i^-}, f(K_i^-) = \frac{K_i^+}{K_i^+ + K_i^-} \quad (5)$$

Kemudian, skor utilitas akhir MARCOS ($f(K_i)$) yang menjadi landasan keputusan dihitung dengan formula:

$$f(K_i) = \frac{K_i^+ + K_i^-}{1 + \frac{1-f(K_i^+)}{f(K_i^+)} + \frac{1-f(K_i^-)}{f(K_i^-)}} \quad (6)$$

Urutan peringkat mahasiswa berprestasi disusun secara menurun (descending) berdasarkan nilai $f(K_i)$ dari yang tertinggi hingga terendah.

Analisis Sensitivitas Stabilitas Peringkat

Untuk menguji ketahanan model hybrid terhadap perubahan kebijakan distribusi bobot nilai, dilakukan analisis sensitivitas [20], [21]. Pengujian ini mengevaluasi stabilitas posisi mahasiswa terbaik di bawah empat skenario pembobotan yang dirancang secara distingtif:

1. Skenario 1 (Regulasi Aktual UNINDRA): Menggunakan bobot acuan dasar sesuai kebijakan institusi, yaitu Tugas = 20%, UTS = 30%, dan UAS = 50%.
2. Skenario 2 (Bobot Sama Rata): Menghilangkan hirarki kepentingan dengan membagi bobot secara merata, yaitu Tugas = 33,3%, UTS = 33,3%, dan UAS = 33,3%. Skenario ini menguji pengaruh jika aspek proses dan ujian akhir dianggap setara.
3. Skenario 3 (Dominasi Tugas / Aspek Proses): Menitikberatkan porsi terbesar pada kinerja harian dengan konfigurasi Tugas = 50%, UTS = 25%, dan UAS = 25%.
4. Skenario 4 (Dominasi UTS / Aspek Tengah Semester): Menggeser prioritas pada evaluasi paruh semester dengan konfigurasi Tugas = 25%, UTS = 50%, dan UAS = 25%.

Tingkat pergeseran peringkat antar skenario diukur secara matematis menggunakan Koefisien Korelasi Peringkat Spearman (r_s) [22]:

$$r_s = 1 - \frac{6 \sum d_i^2}{n(n^2-1)} \quad (7)$$

Dimana d_i adalah selisih urutan peringkat mahasiswa pada skenario uji terhadap skenario dasar (Skenario 1), dan n melambangkan jumlah sampel mahasiswa yang dievaluasi. Nilai korelasi yang mendekati angka 1 membuktikan bahwa model hybrid memiliki stabilitas tinggi dan objektif terhadap perubahan kebijakan pembobotan.

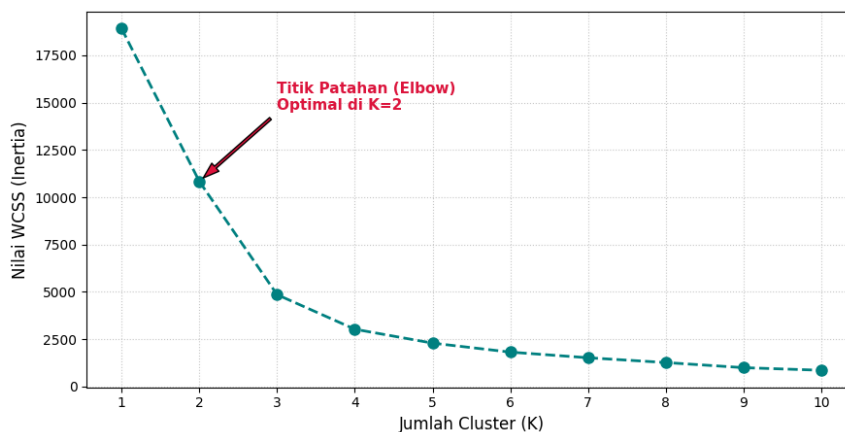
3. HASIL DAN PEMBAHASAN

Hasil Penelitian

Tahap awal penelitian ini dimulai dengan proses ekstraksi data dari empat dokumen PDF, yang berhasil mengumpulkan 129 data mahasiswa. Setelah melalui tahap prapemrosesan untuk menelaraskan format dan membersihkan teks, dipastikan bahwa keseluruhan dataset telah utuh tanpa adanya data kosong (*missing values*). Kelengkapan data ini menjadi dasar yang kuat karena memungkinkan seluruh 129 observasi diproses langsung ke tahap analisis kluster tanpa memerlukan teknik imputasi data.

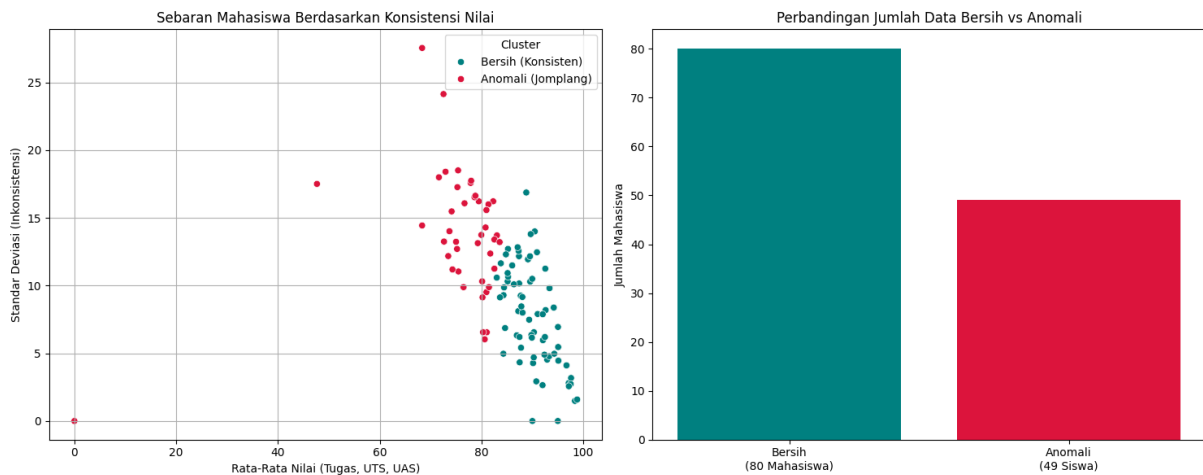
Untuk mengidentifikasi konsistensi nilai mahasiswa, algoritma K-Means diterapkan pada *dataset* tersebut. Penentuan jumlah kluster optimal dilakukan melalui evaluasi Within-Cluster Sum of Squares (WCSS) menggunakan metode *Elbow*. Evaluasi penentuan nilai K optimum ini divisualisasikan pada Gambar 2.

Metode Elbow: Menentukan Jumlah K Optimal



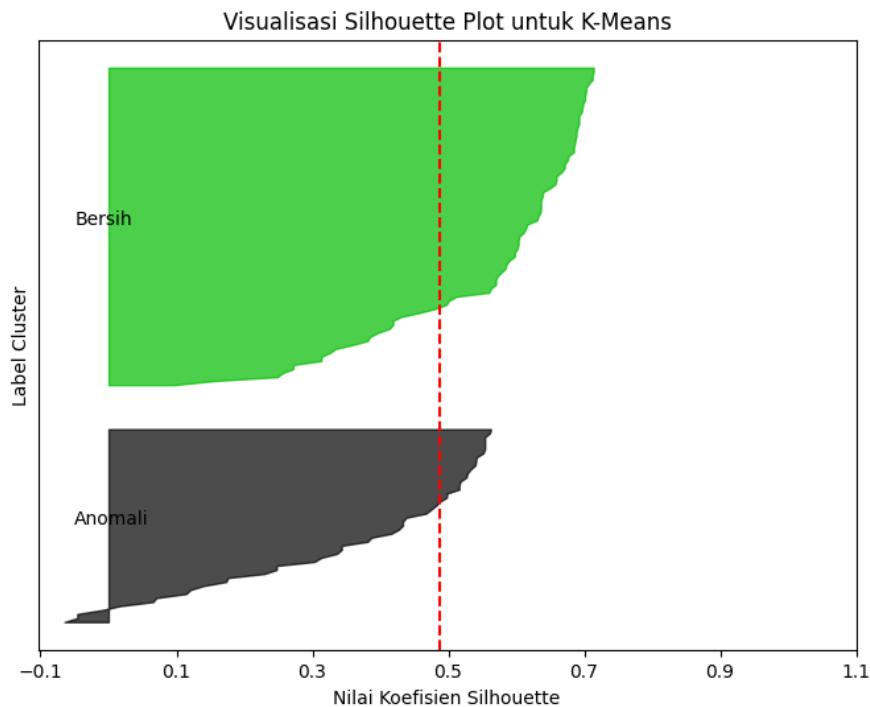
Gambar 2. Penentuan Nilai K Optimum Menggunakan Metode Elbow

Berdasarkan titik patahan optimal pada $k=2$, segmentasi data menghasilkan 80 mahasiswa (62,0%) pada kluster normal yang memiliki pola nilai konsisten, dan 49 mahasiswa (38,0%) pada kluster anomali yang pola nilainya inkonsisten. Distribusi spasial terkait tingkat konsistensi mahasiswa beserta perbandingan jumlah data bersih dan anomali disajikan secara menyeluruh pada Gambar 3.



Gambar 3. Sebaran Konsistensi dan Jumlah Data Bersih Mahasiswa

Sebagai bentuk validasi empiris terhadap kualitas pemisahan kluster tersebut, metrik *Silhouette Score* digunakan dan menghasilkan nilai rata-rata sebesar 0,4869. Visualisasi dari skor tersebut dapat dilihat pada Gambar 4.



Gambar 4. Visualisasi *Silhouette Plot* untuk Validasi Kluster

Setelah data anomali berhasil disaring, tahap pemeringkatan difokuskan secara eksklusif pada 80 mahasiswa di klaster normal. Evaluasi ini menggunakan metode MARCOS dengan mempertimbangkan bobot standar institusi, yaitu Tugas (20%), UTS (30%), dan UAS (50%). Hasil 80 mahasiswa dengan kinerja terbaik yang sudah diurutkan dan disajikan pada Gambar 5.

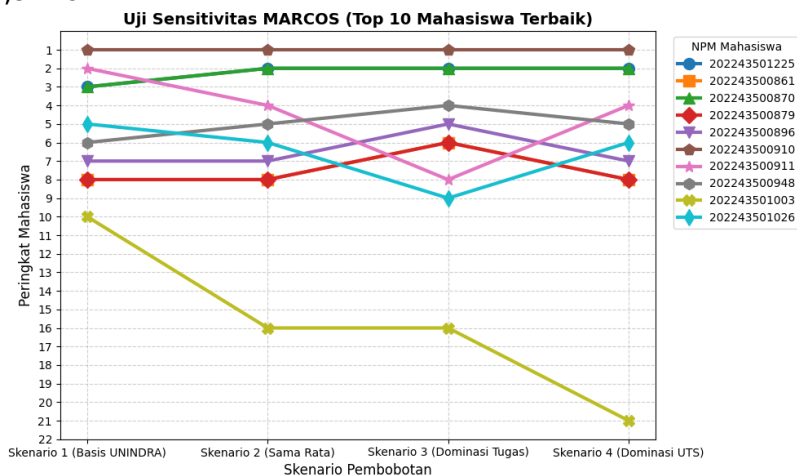
--- HASIL PERANKINGAN MAHASISWA BERPRESTASI (MARCOS) ---

| Peringkat | NPM | Tugas | UTS | UAS | Rata_Rata | Skor_MARCOS |
|-----------|--------------|-------|-------|------|-----------|-------------|
| 1 | 202243500910 | 97.0 | 100.0 | 99.4 | 98.800000 | 0.758513 |
| 2 | 202243500911 | 94.0 | 100.0 | 98.8 | 97.600000 | 0.751566 |
| 3 | 202243501225 | 98.0 | 100.0 | 97.1 | 98.366667 | 0.751271 |
| 4 | 202243500870 | 98.0 | 100.0 | 97.1 | 98.366667 | 0.751271 |
| 5 | 202243501026 | 95.0 | 100.0 | 96.5 | 97.166667 | 0.744323 |
| ... | ... | ... | ... | ... | ... | ... |
| 76 | 202243500786 | 98.0 | 85.0 | 72.6 | 85.200000 | 0.623398 |
| 77 | 202243500905 | 98.0 | 85.0 | 72.6 | 85.200000 | 0.623398 |
| 78 | 202243500917 | 97.0 | 85.0 | 72.4 | 84.800000 | 0.621082 |
| 79 | 202243501023 | 95.0 | 75.0 | 79.0 | 83.000000 | 0.620411 |
| 80 | 202243500962 | 92.0 | 85.0 | 73.9 | 83.633333 | 0.619061 |

80 rows x 6 columns

Gambar 5. Hasil Perankingan Mahasiswa Berprestasi

Guna memastikan bahwa hasil perankingan tersebut tidak bias terhadap kebijakan pembobotan awal, dilakukan pengujian stabilitas model melalui empat skenario pembobotan yang berbeda. Perbandingan pergerakan peringkat 10 mahasiswa terbaik dari uji sensitivitas ini ditampilkan pada Gambar 6. Secara kuantitatif, tingkat pergeseran peringkat tersebut diukur menggunakan Koefisien Korelasi Spearman yang membandingkan Skenario 1 (basis) dengan skenario uji lainnya. Hasil komputasi menunjukkan nilai korelasi untuk Skenario 2 (Bobot Sama Rata) sebesar 0,9751, Skenario 3 (Dominasi Tugas) sebesar 0,9323, dan Skenario 4 (Dominasi UTS) sebesar 0,9180. Pengujian ini menghasilkan nilai rata-rata Koefisien Korelasi Spearman yang sangat tinggi, yaitu sebesar 0,9418.



Gambar 6. Grafik Pergerakan Peringkat pada Uji Sensitivitas

Pembahasan

Temuan dari proses klasterisasi K-Means mengungkapkan sebuah wawasan penting mengenai profil akademik mahasiswa. Fakta bahwa 38% dari total observasi tergolong dalam klaster anomali membuktikan bahwa metode *hybrid* yang diusulkan efektif bertindak sebagai penyaring kualitas data. Pendekatan ini mengatasi kelemahan sistem penilaian konvensional yang sering kali bias terhadap mahasiswa dengan nilai rata-rata tinggi, padahal secara faktual mereka memiliki kesenjangan performa yang ekstrem pada salah satu komponen penilaian. Meskipun demikian, evaluasi terhadap kualitas klaster secara empiris menghasilkan nilai *Silhouette Score* sebesar 0,4869. Nilai ini menunjukkan bahwa pemisahan antara pola nilai yang konsisten dan fluktuatif berada pada tingkat separasi yang moderat (sedang), bukan pemisahan yang sangat baik atau mutlak. Keterbatasan kualitas klaster ini mengindikasikan bahwa meskipun anomali ekstrem berhasil disaring, masih terdapat kemungkinan tumpang tindih (*overlap*) karakteristik pada data mahasiswa yang letaknya berdekatan dengan batas antar klaster. Dampak dari separasi moderat ini terhadap proses seleksi mahasiswa berprestasi adalah sistem tidak dapat sepenuhnya dilepas tanpa pengawasan (*unattended*). Diperlukan tinjauan manual atau analisis lebih lanjut dari pihak pengambil keputusan khusus untuk mahasiswa yang posisinya berada di area ambang batas (*borderline*) klaster normal, guna mencegah kandidat potensial gugur secara prematur karena kesalahan klasifikasi di perbatasan.

Lebih lanjut, hasil evaluasi menggunakan metode MARCOS memperlihatkan profil mahasiswa berprestasi yang sesungguhnya. Mahasiswa pada tiga peringkat teratas menunjukkan stabilitas posisi yang mutlak di seluruh skenario uji sensitivitas. Ketahanan model *hybrid* ini dibuktikan secara empiris oleh rata-rata nilai Koefisien Korelasi Spearman yang mencapai 0,9418. Nilai korelasi yang sangat mendekati angka 1,0 ini menandakan bahwa kedekatan hubungan antar-peringkat di setiap skenario berjalan searah secara konsisten. Hal ini membuktikan bahwa indikator keunggulan dalam model ini bukan sekadar hasil akumulasi angka, melainkan representasi dari ketangguhan (*robustness*) performa di seluruh komponen penilaian (Tugas, UTS, dan UAS). Kestabilan ini menegaskan bahwa mahasiswa terbaik yang direkomendasikan oleh sistem memiliki prestasi yang tahan terhadap berbagai perubahan kebijakan bobot institusi.

Menariknya, kestabilan pada peringkat teratas ini berbanding terbalik dengan dinamika pada ambang batas bawah sepuluh besar. Pengujian sensitivitas mengindikasikan bahwa mahasiswa yang berada pada posisi tersebut (seperti peringkat 10) memiliki kerentanan yang sangat tinggi terhadap perubahan bobot kriteria, yang mana posisinya dapat anjlok secara drastis hingga ke peringkat 21 pada skenario tertentu. Pergeseran peringkat yang signifikan ini terjadi karena kelompok tersebut memiliki variasi profil nilai yang lebih fluktuatif dibandingkan mahasiswa di peringkat puncak, misalnya sangat unggul pada nilai Tugas namun kurang maksimal pada Ujian Akhir. Realitas ini memberikan pandangan strategis bagi institusi bahwa perubahan porsi penilaian di masa depan akan sangat mendisrupsi formasi mahasiswa di batas bawah kelompok unggulan, namun tidak akan menggoyahkan posisi kandidat mahasiswa berprestasi peringkat teratas. Secara keseluruhan, integrasi algoritma K-Means dan metode MARCOS ini menghadirkan kerangka evaluasi multikriteria secara menyeluruh, transparan, dan terbebas dari bias subjektif, sehingga sangat layak diimplementasikan sebagai sistem pendukung keputusan di tingkat program studi.

4. KESIMPULAN

Penelitian ini membuktikan bahwa evaluasi mahasiswa berprestasi tidak cukup jika hanya bersandar pada kalkulasi rata-rata nilai. Pendekatan *hybrid* yang diusulkan menawarkan kerangka kerja yang lebih luas, di mana proses klasterisasi di awal berperan

penting dalam menyaring profil akademik yang fluktuatif sebelum tahapan pemeringkatan multikriteria dilakukan. Hasilnya, institusi mendapatkan rekomendasi kandidat terbaik yang keunggulannya benar-benar merata dan stabil di seluruh instrumen penilaian. Keandalan sistem ini juga telah teruji secara empiris; formasi mahasiswa unggulan terbukti tahan terhadap berbagai simulasi perubahan kebijakan bobot kriteria. Dengan demikian, model pendukung keputusan ini berpotensi menjadi alternatif pendukung keputusan yang menjanjikan dan perlu diuji lebih lanjut pada dataset yang lebih luas guna mewujudkan proses seleksi yang lebih adil, transparan, dan terbebas dari bias subjektif. Di sisi lain, studi ini menyadari adanya keterbatasan karena parameter yang dilibatkan baru sebatas indikator nilai akademik dasar, serta kualitas separasi klaster yang masih berada pada kategori sedang. Sebagai langkah pengembangan ke depan, ruang lingkup sistem perlu diperluas dengan mengintegrasikan instrumen non-akademik, seperti rekam jejak organisasi dan pencapaian ekstrakurikuler. Lebih jauh lagi, sejalan dengan tuntutan akreditasi dan pendidikan tinggi masa kini, rancang bangun sistem pendukung keputusan selanjutnya sangat direkomendasikan untuk bertransisi menuju paradigma *Outcome-Based Education* (OBE). Melalui pendekatan OBE, parameter penilaian dapat dipetakan secara presisi pada pemenuhan Capaian Pembelajaran Lulusan (CPL), sehingga predikat mahasiswa berprestasi benar-benar mencerminkan penguasaan kompetensi secara holistik. Eksplorasi tambahan dengan menggunakan metode pembobotan kriteria yang sepenuhnya dihitung secara objektif oleh sistem, seperti Entropy atau CRITIC, juga disarankan untuk menyempurnakan otomatisasi dan objektivitas model di masa mendatang.

5. REFERENCES

- [1] Y. T. Damanik, I. Irvan, and J. Gultom, "Analisis Perbedaan Indeks Prestasi Kumulatif Mahasiswa Pendidikan Matematika Berdasarkan Tipe Kepribadian Ekstrovert dan Introvert," *MES: Journal of Mathematics Education and Science*, vol. 10, no. 2, pp. 396–404, May 2025, doi: 10.30743/mes.v10i2.10513.
- [2] P. A. K. Widiyanti, R. K. Ningrum, and N. W. D. Ekayani, "Hubungan Nilai Progress Test Dan Indeks Prestasi Mahasiswa Angkatan 2017 Fakultas Kedokteran Dan Ilmu Kesehatan Universitas Warmadewa," *PENDIPA Journal of Science Education*, vol. 8, no. 2, pp. 268–276, Jul. 2024, doi: 10.33369/pendipa.8.2.268-276.
- [3] R. Yohana, I. Armyanti, and D. Yuniarni, "Hubungan Tipe Kepribadian dengan Prestasi Akademik Mahasiswa Program Studi Kedokteran Tahun 2016 Fakultas Kedokteran Universitas Tanjungpura," *Jurnal Cerebellum*, vol. 8, no. 3, pp. 12–22, 2022, doi: 10.26418/jc.v8i3.49052.
- [4] Achmad Efendi and Dahlia, "Pengaruh aspek afektif terhadap prestasi akademik mahasiswa," *Jurnal Pendidikan Ekonomi (JUPE)*, vol. 13, no. 2, pp. 116–126, May 2025, doi: 10.26740/jupe.v13n2.p116-126.
- [5] N. Muin, S. Rabiah, and M. Martini, "Pengaruh Pemberian Tes Formatif Terhadap Peningkatan Hasil Belajar Mahasiswa Prodi Pendidikan Bahasa dan Sastra Indonesia Fakultas Sastra," *Education and Learning Journal*, vol. 5, no. 1, p. 8, Jan. 2024, doi: 10.33096/eljour.v5i1.660.
- [6] J. Pao Ali, "Perbandingan Nilai UTS Dan UAS Pembelajaran Matematik SD -1 Mahasiswa Semester III Program Studi Pendidikan Guru Sekolah Dasar," *OMEGA: Jurnal Keilmuan Pendidikan Matematika*, vol. 5, no. 1, pp. 201–210, Jan. 2026, doi: 10.47662/jkpm.v5i1.1175.
- [7] Nasywa Putri Maulani, Indri Puspita Dewi, Munifah Zahwa Nurhidayat, Moch Yaser Arafat, and Mia Lasmi Wardiyah, "Analisis Korelasi antara Nilai UTS dan Nilai UAS Siswa: Studi pada Mata Pelajaran Matematika Kelas XI SMK Bhakti Kencana Bandung," *Aljabar : Jurnal Ilmuan Pendidikan, Matematika dan Kebumihan*, vol. 1, no. 3, pp. 1–10, Jun. 2025, doi: 10.62383/aljabar.v1i3.563.

- [8] R. S. Nurhalizah, R. Ardianto, and P. Purwono, "Analisis Supervised dan Unsupervised Learning pada Machine Learning: Systematic Literature Review," *Jurnal Ilmu Komputer dan Informatika*, vol. 4, no. 1, pp. 61–72, Aug. 2024, doi: 10.54082/jiki.168.
- [9] D. P. Sari, Z. Halim, I. Irlon, B. Waseso, and S. Saromah, "Implementasi Machine Learning untuk Deteksi Intrusi pada Jaringan Komputer," *Jurnal Minfo Polgan*, vol. 13, no. 2, pp. 1389–1394, Sep. 2024, doi: 10.33395/jmp.v13i2.14074.
- [10] R. Amanda, E. Helmud, and C. Kirana, "Deteksi Anomali Polusi Udara Menggunakan Algoritma Isolation Forest tanpa Label pada Dataset Kualitas Udara Torino," *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 5, no. 9, pp. 2719–2729, Sep. 2025, doi: 10.52436/1.jpti.950.
- [11] E. Windia Ambarsari, D. Desyanti, and D. Fathudin, "Hybrid Chaos-Isolation Forest Framework for Anomaly Detection in Indonesia's Public Procurement," *Bulletin of Informatics and Data Science*, vol. 4, no. 2, pp. 114–123, 2025, doi: 10.61944/bids.v4i2.137.
- [12] A. Pinto, L.-C. Herrera, Y. Donoso, and J. A. Gutierrez, "Enhancing Critical Infrastructure Security: Unsupervised Learning Approaches for Anomaly Detection," *International Journal of Computational Intelligence Systems*, vol. 17, no. 1, p. 236, Sep. 2024, doi: 10.1007/s44196-024-00644-z.
- [13] F. Ditya and L. Tanti, "Model Clustering Anomali Deteksi pada Jaringan LAN dengan Algoritma K-Means," *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 7, no. 2, pp. 657–667, Dec. 2025, doi: 10.30865/json.v7i2.9173.
- [14] R. S. Ismanda, M. T. A. Silitonga, and S. Nur hasanah, "Deteksi Hybrid Anomali Transaksi Digital dengan Optimasi Isolation Forest-K-Means untuk Peningkatan Keamanan Finansial," *Innovative: Journal Of Social Science Research*, vol. 5, no. 3, pp. 5749–5765, Jun. 2025, doi: 10.31004/innovative.v5i3.19791.
- [15] Z. Stevic, D. Pamucar, A. Puska, and P. Chatterjee, "Sustainable supplier selection in healthcare industries using a new MCDM method: Measurement of alternatives and ranking according to COmpromise solution (MARCOS)," *Comput Ind Eng*, vol. 140, p. 106231, Feb. 2020, doi: 10.1016/j.cie.2019.106231.
- [16] M. H. Rewo, I. G. M. Darmawiguna, and G. S. Mahendra, "Pengembangan Sistem Pendukung Keputusan Pemilihan Siswa Terbaik Di SMK Ti Global Singaraja Menggunakan Metode PIPRECIA-MARCOS," *Computer Based Information System Journal*, vol. 13, no. 2, pp. 69–82, Sep. 2025, doi: 10.33884/cbis.v13i2.10683.
- [17] D. S. Wahyuni and A. T. Priandika, "Kombinasi Metode Pembobotan Entropy dan MARCOS Dalam Seleksi Penerimaan Karyawan Divisi Keuangan," *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 3, pp. 1848–1859, Dec. 2024, doi: 10.47065/bits.v6i3.5835.
- [18] M. A. Syakur, B. K. Khotimah, E. M. S. Rochman, and B. D. Satoto, "Integration K-Means Clustering Method and Elbow Method For Identification of The Best Customer Profile Cluster," *IOP Conf Ser Mater Sci Eng*, vol. 336, p. 012017, Apr. 2018, doi: 10.1088/1757-899X/336/1/012017.
- [19] J. Han, J. Pei, and H. Tong, *Data Mining: Concepts and Techniques*, 4th ed. Morgan Kaufmann, 2022.
- [20] I. Mukhametzhanov and D. Pamucar, "A Sensitivity analysis in MCDM problems: A statistical approach," *Decision Making: Applications in Management and Engineering*, vol. 1, no. 2, Oct. 2018, doi: 10.31181/dmame1802050m.
- [21] J. Wieckowski and W. Sałabun, "Sensitivity analysis approaches in multi-criteria decision analysis: A systematic review," *Appl Soft Comput*, vol. 148, p. 110915, 2023, doi: <https://doi.org/10.1016/j.asoc.2023.110915>.
- [22] S. Andryana, T. Mantoro, A. Gunaryati, and A. E. Raffliansyah, "Improving MCDM University Rankings through Statistical Validation Using Spearman's Correlation and



THE Benchmark," Journal of Applied Data Sciences, vol. 6, no. 3, pp. 1876–1888, Sep. 2025, doi: 10.47738/jads.v6i3.796.

