

Segmentasi Risiko dan Alokasi Dukungan Kesejahteraan Mahasiswa menggunakan K-Means Clustering dan CRITIC-COPRAS

Asyahri Hadi Nasyuha^{1*}, Muafi²

¹)Sistem Informasi, Fakultas Ilmu Komputer, Universitas Teknologi Digital Indonesia, Yogyakarta, Indonesia

²)Manjemen, Universitas Islam Indonesia, Yogyakarta, Indonesia

^{1*}asyahrihadi@gmail.com ²muafi@uii.ac.id

Abstrak: Selain mengidentifikasi mahasiswa berisiko burnout akademik, perguruan tinggi memerlukan mekanisme berbasis bukti untuk mensegmentasi populasi mahasiswa dan mengalokasikan sumber daya dukungan kesejahteraan yang terbatas secara proporsional. Penelitian ini mengusulkan kerangka kerja sistem pendukung keputusan yang menggabungkan K-Means clustering dengan metode pembobotan objektif CRiteria Importance Through Intercriteria Correlation (CRITIC) dan metode perangkingan COMplex PROportional ASsessment (COPRAS) untuk mensegmentasi mahasiswa dan memprioritaskan alokasi dukungan kesejahteraan. Menggunakan dataset 60 mahasiswa dengan delapan indikator psikososial dan perilaku yang dapat diintervensi, K-Means mengelompokkan mahasiswa ke dalam tiga segmen risiko (Tinggi/Sedang/Rendah), dievaluasi menggunakan silhouette score (0,133–0,163 untuk $k=2-5$) dan dipilih $k=3$ agar selaras dengan skema intervensi tiga tingkat institusi. CRITIC menurunkan bobot kriteria berbasis data dan korelasi tanpa elisitasi pakar, berbeda dari pendekatan berbasis preferensi. Bobot tersebut menjadi masukan COPRAS untuk menghitung skor signifikansi relatif (Q_i) dan merangking mahasiswa berdasarkan prioritas alokasi dukungan. Klaster risiko tinggi menangkap empat dari lima mahasiswa berlabel burnout Tinggi (80%) dan menunjukkan rata-rata Burnout Risk Score tertinggi (41,60) dibanding klaster sedang (37,03) dan rendah (30,09). Peringkat prioritas COPRAS berkorelasi signifikan dengan indikator burnout independen (ρ Spearman = 0,706 terhadap Burnout Risk Score, 0,749 terhadap Support Need, dan 0,529 terhadap Intervention Urgency, seluruhnya $p < 0,001$), dengan rata-rata peringkat menurun monoton menurut Burnout Level (Tinggi=7,0; Sedang=23,3; Rendah=43,1, dari 60). Temuan ini menunjukkan bahwa segmentasi tak-berpengawas dipadukan pembobotan multi-kriteria objektif dapat menjadi basis transparan, dapat direplikasi, dan efisien sumber daya untuk alokasi dukungan kesejahteraan mahasiswa, melengkapi pendekatan prediktif berbasis pembelajaran terawasi pada penelitian sebelumnya.

Kata Kunci: Kesejahteraan Mahasiswa; Sistem Pendukung Keputusan; K-Means clustering; CRITIC; COPRAS

Abstract: Beyond identifying students at risk of academic burnout, higher education institutions also need an evidence-based mechanism to segment the student population and allocate limited wellbeing-support resources proportionally. This study proposes a decision support framework combining K-Means clustering with the CRiteria Importance Through Intercriteria Correlation (CRITIC) objective weighting method and the COmplex PROportional ASsessment (COPRAS) ranking method to segment students and prioritize wellbeing-support allocation. Using a dataset of 60 students with eight actionable psychosocial and behavioral indicators, K-Means partitioned students into three risk-based segments (High/Moderate/Low), evaluated via silhouette scores (0.133-0.163 for $k = 2-5$) and set at $k = 3$ to align with the institution's three-tier intervention scheme. CRITIC derived data-driven, correlation-based criteria weights without expert elicitation, unlike preference-based weighting. These weights fed into COPRAS to compute a relative significance score (Q_i) and rank students by support-allocation priority. The High-risk cluster captured four of five dataset-labelled High-burnout students (80%) and showed the highest mean Burnout Risk Score (41.60) versus Moderate-risk (37.03) and Low-risk (30.09) clusters. The COPRAS ranking correlated significantly with independent burnout indicators (Spearman's $\rho = 0.706$ with Burnout Risk Score, 0.749 with Support Need, and 0.529 with Intervention Urgency, all $p < 0.001$), with mean ranks decreasing monotonically across Burnout_Level categories (High = 7.0, Moderate = 23.3, Low = 43.1, out of 60). These findings indicate that unsupervised segmentation combined with objective multi-criteria weighting can provide a transparent, replicable, resource-efficient basis for allocating student wellbeing support, complementing supervised prediction-based approaches used in prior studies.

Keywords: : *Student wellbeing; Decision Support System; K-Means clustering; CRITIC; COPRAS*

1. PENDAHULUAN

Burnout akademik merupakan kondisi kelelahan emosional, sinisme terhadap aktivitas perkuliahan, dan penurunan efikasi diri akademik yang timbul akibat tekanan studi yang berkepanjangan [1]. Beban tugas akademik yang tinggi dan kurangnya dukungan sosial secara konsisten dilaporkan berkontribusi terhadap peningkatan burnout mahasiswa [2], sementara mahasiswa yang menjalani peran ganda sebagai pekerja paruh waktu menunjukkan kerentanan yang lebih tinggi terhadap kelelahan akademik [3]. Kondisi ini diperparah oleh tekanan finansial dan beban tugas akhir yang bersamaan dengan tuntutan akademik reguler [4], [5], sehingga strategi coping individual saja dinilai tidak cukup tanpa dukungan sistemik dari institusi [6].

Sebagian besar penelitian terdahulu mengenai deteksi burnout mahasiswa berbasis komputasi berfokus pada pendekatan klasifikasi terawasi (supervised learning), yaitu memprediksi status atau tingkat burnout seorang mahasiswa berdasarkan label yang telah diketahui [7], [8], [9], [10], [11]. Pendekatan ini efektif untuk skrining dini, tetapi memiliki dua keterbatasan praktis bagi unit kemahasiswaan. Pertama, pendekatan klasifikasi bergantung pada ketersediaan label burnout yang valid dan representatif, yang pada kenyataannya jarang tersedia secara rutin di tingkat institusi karena memerlukan instrumen psikometrik terstandardisasi. Kedua, keluaran klasifikasi berupa label kategori (misalnya "berisiko" atau "tidak berisiko") tidak secara langsung memberikan informasi mengenai bagaimana populasi mahasiswa dapat disegmentasi secara keseluruhan untuk kepentingan perencanaan program dukungan kesejahteraan yang bersifat proporsional dan berjenjang, bukan sekadar biner.

Pendekatan pembelajaran tak-berpengawas (unsupervised learning), khususnya algoritma klusterisasi seperti K-Means, menawarkan alternatif yang tidak bergantung pada label dan mampu mengungkap struktur pengelompokan alami dalam data psikososial mahasiswa berdasarkan kemiripan karakteristik [12], [13]. Segmentasi semacam ini memungkinkan unit kemahasiswaan merancang program dukungan yang berjenjang (tiered support) sesuai profil risiko masing-masing segmen, alih-alih pendekatan seragam untuk seluruh populasi. Namun demikian, hasil klusterisasi semata belum menjawab kebutuhan operasional untuk menentukan mahasiswa mana secara individual yang perlu diprioritaskan lebih dahulu ketika kapasitas layanan konseling terbatas, sehingga diperlukan lapisan Multi-Criteria Decision Making (MCDM) tambahan untuk menghasilkan peringkat prioritas yang eksplisit.

Pada lapisan MCDM, pemilihan metode pembobotan kriteria menjadi krusial. Metode berbasis panel ahli seperti DEMATEL memerlukan elisitasi penilaian pakar yang bersifat subjektif dan memakan sumber daya [15], [16], sedangkan metode perangsingan seperti MARCOS memerlukan definisi solusi ideal dan anti-ideal yang eksplisit [17]. Sebagai alternatif yang sepenuhnya objektif dan berbasis data, metode CRiteria Importance Through Intercriteria Correlation (CRITIC) menurunkan bobot kriteria dari kontras (variabilitas) dan konflik (korelasi) antar-kriteria di dalam data itu sendiri, tanpa memerlukan input subjektif tambahan [14]. Bobot CRITIC tersebut kemudian dapat dipasangkan dengan metode COMplex PROportional ASsessment (COPRAS), yang merangsang alternatif berdasarkan rasio signifikansi relatif terhadap solusi terbaik dan terburuk secara proporsional, dan telah terbukti efektif dipadukan dengan CRITIC pada berbagai studi kasus keputusan multi-kriteria di Indonesia [14].

Penelitian ini juga melanjutkan pola penelitian sistem pendukung keputusan dan analitik data yang telah dikembangkan penulis pada berbagai domain, termasuk decision support system berbasis MCDM [21], [22], [23], [24] dan segmentasi berbasis data besar [25], dengan prinsip metodologis yang konsisten, yaitu memadukan metode pembobotan objektif dengan metode perangsingan yang transparan dan dapat direplikasi. Sebagai perbandingan metodologis, penelitian klusterisasi berbasis Random Forest dan algoritma ensemble lain juga telah diterapkan pada berbagai konteks segmentasi dan klasifikasi risiko [18], [19], [20].

Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan kerangka kerja hibrida yang menggabungkan K-Means clustering, CRITIC, dan COPRAS untuk mensegmentasi mahasiswa berdasarkan profil risiko burnout sekaligus menghasilkan peringkat prioritas alokasi dukungan kesejahteraan pada tingkat individu. Berbeda dari pendekatan klasifikasi terawasi yang memerlukan label burnout sebagai target pelatihan, kerangka kerja yang diusulkan bersifat sepenuhnya tak-berpengawas pada tahap segmentasi dan objektif pada tahap pembobotan kriteria, sehingga lebih mudah diterapkan pada institusi yang belum memiliki data burnout berlabel. Kontribusi utama penelitian ini adalah: (1) kerangka kerja integrasi klusterisasi dan MCDM objektif yang tidak bergantung pada label maupun elisitasi pakar; (2) validasi empiris hasil segmentasi dan peringkat prioritas terhadap indikator burnout independen dalam dataset; dan (3) perbandingan metodologis dengan pendekatan berbasis machine learning terawasi dan MCDM berbasis panel ahli yang telah digunakan pada penelitian-penelitian sebelumnya.

2. METODE PENELITIAN

2.1 Desain dan Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain hibrida tiga tahap yang menggabungkan pembelajaran tak-berpengawas untuk segmentasi dan Multi-Criteria

Decision Making (MCDM) objektif untuk pembobotan kriteria dan perangkingan prioritas. Tahapan penelitian terdiri dari: (1) segmentasi mahasiswa berbasis profil risiko menggunakan K-Means clustering; (2) pembobotan kriteria secara objektif menggunakan CRITIC; dan (3) perangkingan prioritas alokasi dukungan menggunakan COPRAS. Kerangka kerja ini sejalan dengan pola penelitian sistem pendukung keputusan multi-metode yang telah dikembangkan pada berbagai domain lain [21], [24].

2.2 Dataset dan Kriteria

Dataset penelitian sama dengan yang digunakan pada kajian pendahuluan terkait, terdiri dari 60 mahasiswa dengan sebelas atribut akademik, perilaku, dan psikososial. Delapan indikator yang bersifat actionable digunakan sebagai kriteria segmentasi dan perangkingan: Beban Studi (Study_Load_Hours_Week), Tekanan Tugas (Assignment_Pressure), Stres Akademik (Academic_Stress), Durasi Tidur (Sleep_Hours_Day), Stres Finansial (Financial_Stress), Dukungan Sosial (Social_Support), Kerja Paruh Waktu (Part_Time_Work_Hours), dan Waktu Layar (Screen_Time_Hours_Day). Indikator hasil (GPA, Academic_Satisfaction, Attendance_Rate) serta indikator burnout turunan (Burnout_Label, Burnout_Risk_Score, Burnout_Level, Intervention_Urgency, Support_Need) tidak disertakan sebagai kriteria input, melainkan digunakan semata sebagai variabel validasi eksternal pasca-analisis. Seluruh kriteria distandardisasi (z-score) sebelum proses klasterisasi untuk menyetarakan skala pengukuran yang berbeda-beda.

2.3 Segmentasi dengan K-Means Clustering

K-Means mengelompokkan n mahasiswa ke dalam k klaster dengan meminimalkan jumlah kuadrat jarak Euclidean antara setiap titik data dan centroid klasternya melalui iterasi pembaruan centroid hingga konvergen [12]. Jumlah klaster optimal (k) ditentukan melalui evaluasi silhouette score untuk $k = 2$ sampai 5, dengan koefisien silhouette untuk titik data k -i dirumuskan pada Persamaan (1):

$$s(i) = \frac{b(i) - a(i)}{\max} \quad (1)$$

dengan $a(i)$ adalah rata-rata jarak titik i terhadap seluruh titik lain dalam klaster yang sama (kekompakan/cohesion), $b(i)$ adalah rata-rata jarak minimum titik i terhadap titik-titik pada klaster tetangga terdekat (pemisahan/separation), dan $\max$ pada penyebut merujuk pada nilai maksimum antara $a(i)$ dan $b(i)$. Nilai $s(i)$ berkisar antara -1 hingga 1 , dengan nilai mendekati 1 menunjukkan pengelompokan yang baik. Meskipun evaluasi silhouette menunjukkan skor tertinggi pada $k = 5$ ($0,163$), penelitian ini secara operasional memilih $k = 3$ karena selarasnya dengan skema intervensi tiga tingkat (Rendah/Sedang/Tinggi) yang lazim diadopsi unit kemahasiswaan, sebuah pertimbangan interpretabilitas praktis yang umum digunakan ketika perbedaan skor evaluasi statistik antar-nilai k tergolong tipis [13]. Setiap klaster kemudian diberi label risiko (Tinggi/Sedang/Rendah) berdasarkan peringkat skor komposit risiko rata-rata, yaitu selisih rata-rata z-score kriteria peningkat-risiko (Beban Studi, Tekanan Tugas, Stres Akademik, Stres Finansial, Kerja Paruh Waktu, Waktu Layar) terhadap rata-rata z-score kriteria protektif (Durasi Tidur, Dukungan Sosial).

2.4 Pembobotan Kriteria Objektif dengan CRITIC

CRITIC menurunkan bobot kriteria berdasarkan dua komponen: kontras (variabilitas) dan konflik (korelasi antar-kriteria), sehingga kriteria dengan variasi tinggi dan berkorelasi rendah terhadap kriteria lain memperoleh bobot lebih besar [14]. Sebelum penghitungan bobot, matriks keputusan dinormalisasi ke rentang $0-1$ dengan orientasi searah urgensi dukungan menggunakan Persamaan (2), dengan kriteria peningkat-risiko diperlakukan

sebagai benefit (nilai tinggi = urgensi tinggi) dan kriteria protektif diperlakukan sebagai cost (nilai tinggi = urgensi rendah):

$$r_{ij} = \frac{x_{ij} - x_{j,\min}}{x_{j,\max} - x_{j,\min}} \quad (2)$$

(untuk kriteria protektif, arah pembilang dibalik menjadi $x_{j,\max} - x_{ij}$ sehingga arah normalisasi tetap konsisten terhadap urgensi dukungan). Derajat kontras setiap kriteria diukur melalui simpangan baku nilai ternormalisasi pada Persamaan (3):

$$\sigma_j = \sqrt{\frac{\sum_{i=1}^n (r_{ij} - \bar{r}_j)^2}{n-1}} \quad (3)$$

Konflik antar-kriteria dihitung dari matriks korelasi Pearson (r_{jk}) antar-kriteria ternormalisasi pada Persamaan (4), dan jumlah informasi (C_j) setiap kriteria pada Persamaan (5):

$$Konflik_j = \sum_{k=1}^m (1 - r_{jk}) \quad (4)$$

$$C_j = \sigma_j \times Konflik_j \quad (5)$$

Bobot akhir setiap kriteria dinormalisasi pada Persamaan (6) sehingga $\sum w_j = 1$:

$$w_j = \frac{C_j}{\sum_{k=1}^m C_k} \quad (6)$$

2.5 Tahap 3 Perangkingan Prioritas dengan COPRAS

COPRAS merangking alternatif berdasarkan rasio signifikansi relatif terhadap kombinasi kriteria benefit dan cost secara proporsional, tanpa memerlukan solusi ideal eksplisit sebagaimana pada metode berbasis jarak [14]. Matriks keputusan dinormalisasi dengan metode penjumlahan pada Persamaan (7), kemudian dibobotkan dengan bobot CRITIC (w_j) pada Persamaan (8):

$$r_{ij} = \frac{x_{ij}}{\sum_{i=1}^n x_{ij}} \quad (7)$$

$$y_{ij} = r_{ij} \times w_j \quad (8)$$

Jumlah komponen benefit (S^+i , kriteria peningkat-urgensi) dan komponen cost (S^-i , kriteria protektif) untuk setiap mahasiswa dihitung pada Persamaan (9):

$$S^+i = \sum_{j \in \text{benefit}} y_{ij}, \quad S^-i = \sum_{j \in \text{cost}} y_{ij} \quad (9)$$

Skor signifikansi relatif Q_i dihitung pada Persamaan (10), dengan $S^-{\min}$ adalah nilai minimum S^-i di antara seluruh alternatif:

$$Q_i = S^+i + \frac{S^-{\min} \times \sum_{i=1}^n S^-i}{S^-i \times \sum_{i=1}^n \frac{S^-{\min}}{S^-i}} \quad (10)$$

Derajat utilitas U_i (%) dihitung pada Persamaan (11), dan mahasiswa dengan nilai Q_i (dan U_i) tertinggi menempati peringkat prioritas alokasi dukungan teratas:

$$U_i = \frac{Q_i}{Q_{\max}} \times 100\% \quad (11)$$

2.6 Validasi


Validitas hasil klasterisasi diuji dengan membandingkan komposisi Burnout_Level pada setiap klaster K-Means (analisis tabulasi silang) serta gradien rata-rata Burnout_Risk_Score antar-klaster. Validitas konvergen peringkat prioritas COPRAS diuji dengan korelasi Spearman antara skor Q_i dengan tiga indikator burnout independen dalam dataset (Burnout_Risk_Score, Intervention_Urgency, Support_Need), serta analisis distribusi peringkat terhadap kategori Burnout_Level.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Segmentasi K-Means


Evaluasi silhouette score untuk $k = 2$ hingga 5 menghasilkan nilai 0,1335; 0,1384; 0,1505; dan 0,1630 secara berurutan (Gambar 1), menunjukkan peningkatan kualitas pemisahan klaster yang landai seiring bertambahnya k , tanpa titik siku (elbow) yang tajam

pola yang lazim ditemukan pada data survei psikososial dengan konstruk yang saling tumpang tindih secara kontinu. Sebagaimana dijelaskan pada bagian metodologi, penelitian ini memilih $k = 3$ (silhouette = 0,1384) atas pertimbangan interpretabilitas dan keselarasan dengan skema intervensi tiga tingkat, meskipun secara statistik murni $k = 5$ memberikan skor sedikit lebih tinggi.



Gambar 1. Evaluasi jumlah kluster optimal

Tabel 1 menyajikan profil rata-rata tiap kluster. Kluster Risiko Tinggi ($n=21$) dicirikan oleh beban studi tertinggi (41,76 jam/minggu), stres akademik tertinggi (5,76), dan waktu layar tertinggi (9,11 jam/hari). Menariknya, Kluster Risiko Rendah ($n=17$) justru memiliki stres finansial rata-rata tertinggi (7,76) di antara ketiga kluster, namun tetap tergolong risiko rendah karena diimbangi oleh durasi tidur (7,26 jam) dan dukungan sosial (8,35) tertinggi. Temuan ini mengindikasikan bahwa faktor protektif dapat menetralkan dampak faktor risiko tunggal yang tinggi, sebuah pola yang konsisten dengan model job demands-resources pada literatur burnout yang menekankan peran penyeimbang sumber daya psikososial [1].




Gambar 2. Profil rata-rata kriteria per kluster (K-Means, $k=3$)

Tabel 1. Profil rata-rata kriteria dan Burnout Risk Score per kluster

Kriteria	Risiko Tinggi ($n=21$)	Risiko Sedang ($n=22$)	Risiko Rendah ($n=17$)
Beban Studi (jam/minggu)	41.76	38.41	36.41
Tekanan Tugas	4.10	8.09	7.35
Stres Akademik	5.76	6.45	5.06
Durasi Tidur (jam)	5.82	5.81	7.26

Stres Finansial	4.43	3.45	7.76
Dukungan Sosial	4.19	5.64	8.35
Kerja Paruh Waktu (jam)	22.14	8.86	18.18
Waktu Layar (jam)	9.11	6.98	8.89
Burnout Risk Score (rata-rata)	41.60	37.03	30.09


Tabulasi silang antara klaster dan kategori Burnout_Level pada dataset (Gambar 3) menunjukkan bahwa 4 dari 5 mahasiswa berlabel burnout "High" (80%) berada pada Klaster Risiko Tinggi, dan tidak satu pun mahasiswa berlabel "High" berada pada Klaster Risiko Rendah. Meskipun demikian, kategori "Moderate" tersebar cukup merata pada ketiga klaster (11, 10, dan 9 mahasiswa), sehingga indeks kesesuaian Adjusted Rand Index antara pelabelan klaster dan Burnout_Level tergolong rendah (-0,007), yang secara statistik wajar mengingat proses klasterisasi murni berbasis kemiripan multivariat delapan kriteria tanpa memanfaatkan label burnout sama sekali. Meski demikian, gradien rata-rata Burnout_Risk_Score antar-klaster bersifat monoton dan konsisten (Tinggi 41,60 > Sedang 37,03 > Rendah 30,09), memberikan bukti pendukung validitas segmentasi pada tingkat agregat.



Gambar 3. Distribusi silang klaster K-Means terhadap kategori Burnout_Level

3.2 Hasil Pembobotan Kriteria CRITIC

Tabel 2 menyajikan hasil perhitungan CRITIC. Stres Finansial memperoleh bobot tertinggi (13,83%), diikuti Tekanan Tugas (13,58%) dan Stres Akademik (13,52%), sementara Kerja Paruh Waktu memperoleh bobot terendah (10,50%). Berbeda dengan hasil pembobotan berbasis panel ahli pada pendekatan causal-relationship seperti DEMATEL [15], [16], bobot CRITIC murni mencerminkan variabilitas dan independensi statistik antar-kriteria dalam data yang teramati, sehingga Stres Finansial memperoleh bobot tinggi karena tingkat variasi (kontras) antar-mahasiswa yang besar dan korelasinya relatif rendah terhadap kriteria lain, bukan karena dianggap paling "penting" secara konseptual oleh penilai. Perbedaan filosofis pembobotan ini menjadikan CRITIC dan DEMATEL saling melengkapi: DEMATEL cocok digunakan ketika pemahaman hubungan sebab-akibat antar-faktor menjadi prioritas analitis, sedangkan CRITIC lebih sesuai ketika objektivitas penuh dan independensi terhadap penilaian subjektif menjadi pertimbangan utama, misalnya pada tahap awal implementasi sistem ketika panel ahli belum tersedia.




Gambar 4. Bobot kriteria hasil CRITIC

Tabel 2. Hasil perhitungan CRITIC: kontras, konflik, dan bobot kriteria

Kriteria	σ_j	Konflik _j	C _j	Bobot (w_j)
C5 Stres Finansial	0.3283	7.9711	2.6166	0.1383
C2 Tekanan Tugas	0.3394	7.5705	2.5695	0.1358
C3 Stres Akademik	0.3494	7.3236	2.5589	0.1352
C6 Dukungan Sosial	0.3322	7.4600	2.4782	0.1310
C4 Durasi Tidur	0.3128	7.3972	2.3139	0.1223
C8 Waktu Layar	0.2986	7.4713	2.2306	0.1179
C1 Beban Studi	0.3124	6.9351	2.1666	0.1145
C7 Kerja Paruh Waktu	0.2834	7.0100	1.9864	0.1050

3.3 Hasil Perangkingan Prioritas COPRAS

Perangkingan COPRAS terhadap 60 mahasiswa menghasilkan skor Q_i berkisar antara 0,0123 hingga 0,0233 (U_i 52,78%–100%). Tabel 3 menyajikan sepuluh mahasiswa dengan prioritas dukungan tertinggi. Mahasiswa STU045 menempati peringkat pertama ($Q_i = 0,0233$, $U_i = 100\%$), konsisten dengan kategori Burnout_Level "High" serta Burnout_Risk_Score tertinggi kedua pada dataset (76,90). Dari sepuluh peringkat teratas, tiga mahasiswa berkategori "High" dan tujuh berkategori "Moderate", mengindikasikan bahwa COPRAS turut menangkap mahasiswa kategori Moderate dengan kombinasi faktor risiko yang secara agregat tinggi meskipun belum mencapai ambang kategori High deskriptif sebuah nilai tambah praktis untuk deteksi dini sebelum kondisi memburuk menjadi kategori High.




Gambar 5. Sepuluh mahasiswa dengan prioritas dukungan tertinggi (COPRAS)

Tabel 3. Sepuluh mahasiswa dengan prioritas dukungan tertinggi berdasarkan COPRAS

Peringkat	ID Mahasiswa	Q_i	U_i (%)	Kategori Burnout	Risk Score	Support Need
1	STU045	0.0233	100.00	High	76.90	76.60
2	STU009	0.0220	94.62	High	68.65	72.89
3	STU060	0.0206	88.37	Moderate	53.86	58.74
4	STU013	0.0205	87.87	High	100.00	71.50
5	STU024	0.0203	87.40	Moderate	38.29	66.73
6	STU010	0.0190	81.50	Moderate	51.02	48.96
7	STU042	0.0189	81.23	Moderate	44.76	64.14
7	STU059	0.0189	81.24	Moderate	33.14	39.91
9	STU028	0.0188	80.69	Moderate	57.99	50.60
10	STU008	0.0186	79.90	High	74.60	59.07

3.4 Validasi Peringkat Prioritas

Uji korelasi Spearman menunjukkan hubungan positif yang signifikan antara skor Q_i COPRAS dengan ketiga indikator burnout independen: $\rho = 0,706$ terhadap Burnout_Risk_Score ($p < 0,001$), $\rho = 0,749$ terhadap Support_Need ($p < 0,001$), dan $\rho = 0,529$ terhadap Intervention_Urgency ($p < 0,001$). Analisis distribusi peringkat menurut Burnout_Level (Gambar 6) menunjukkan pola monoton yang konsisten: mahasiswa kategori High memiliki rata-rata peringkat 7,0 (dari 60), kategori Moderate 23,3, dan kategori Low 43,1 pola yang sejalan dengan temuan pada kajian pendahuluan menggunakan pendekatan DEMATEL–MARCOS [17], mengindikasikan bahwa kedua kerangka kerja metodologis yang berbeda (satu berbasis machine learning dan panel ahli, satu lagi berbasis klasterisasi dan bobot objektif) menghasilkan kesimpulan praktis yang konvergen mengenai mahasiswa mana yang paling membutuhkan dukungan.



Gambar 6. Validasi nilai Q_i COPRAS terhadap kategori Burnout_Level

3.5 Implikasi Praktis dan Keterbatasan

Secara praktis, kerangka kerja K-Means–CRITIC–COPRAS ini menawarkan dua keluaran yang saling melengkapi bagi unit kemahasiswaan: segmentasi tingkat populasi untuk perencanaan program dukungan berjenjang, dan peringkat prioritas tingkat individu untuk alokasi layanan konseling langsung. Karena tidak memerlukan label burnout maupun elisitasi panel ahli, kerangka kerja ini relatif lebih mudah diterapkan pada tahap awal implementasi sistem pendukung keputusan dibandingkan pendekatan klasifikasi terawasi

[7], [8], [9] atau pendekatan berbasis panel ahli [15], [17], meskipun pada tahap lanjut kombinasi ketiga pendekatan tersebut (terawasi, tak-berpengawas, dan berbasis panel) berpotensi saling memperkuat validitas keputusan.

Penelitian ini memiliki sejumlah keterbatasan. Pertama, nilai silhouette score yang diperoleh (0,13–0,16) tergolong rendah menurut konvensi umum, mengindikasikan struktur klaster yang tidak terlalu tegas dipisahkan kondisi yang lazim terjadi pada data psikososial dengan konstruk kontinu dan saling tumpang tindih, namun tetap memerlukan kehati-hatian dalam interpretasi keanggotaan klaster individual. Kedua, pemilihan $k=3$ didasarkan pada pertimbangan interpretabilitas praktis, bukan semata-mata kriteria statistik optimal; penelitian lanjutan dapat mengeksplorasi metode penentuan k lain seperti Gap Statistic atau validasi silang klaster. Ketiga, sebagaimana pada kajian pendahuluan, validasi yang dilakukan bersifat validitas konvergen terhadap indikator dalam dataset yang sama; validasi eksternal dengan instrumen burnout terstandarisasi pada populasi yang lebih besar dan beragam akan memperkuat generalisasi temuan.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan dan memvalidasi kerangka kerja sistem pendukung keputusan yang menggabungkan K-Means clustering, CRITIC, dan COPRAS untuk mensegmentasi mahasiswa berdasarkan profil risiko burnout sekaligus memprioritaskan alokasi dukungan kesejahteraan. K-Means dengan $k=3$ menyegmentasi mahasiswa ke dalam klaster Risiko Tinggi, Sedang, dan Rendah dengan gradien Burnout_Risk_Score yang monoton (41,60; 37,03; 30,09) dan menangkap 80% mahasiswa berlabel burnout Tinggi ke dalam klaster Risiko Tinggi. CRITIC menghasilkan bobot kriteria yang sepenuhnya objektif dan berbasis data, dengan Stres Finansial, Tekanan Tugas, dan Stres Akademik sebagai tiga kriteria berbobot tertinggi. Peringkat prioritas COPRAS terbukti valid secara statistik, ditunjukkan oleh korelasi Spearman yang signifikan terhadap Burnout_Risk_Score ($\rho=0,706$) dan Support_Need ($\rho=0,749$), serta konsistensi peringkat rata-rata yang monoton menurut kategori Burnout_Level. Kontribusi utama penelitian ini adalah kerangka kerja segmentasi dan prioritasasi yang tidak bergantung pada label burnout maupun elisitasi panel ahli, sehingga dapat menjadi pelengkap yang praktis bagi pendekatan berbasis machine learning terawasi dan MCDM berbasis panel ahli yang telah dikembangkan pada penelitian sebelumnya. Penelitian lanjutan disarankan untuk mengeksplorasi metode penentuan jumlah klaster alternatif, memperluas ukuran sampel, dan melakukan validasi eksternal menggunakan instrumen burnout terstandarisasi.

REFERENCES

- [1] N. R. Langgi, N. Made, and F. Pratiwi, "Analisis Academic Burnout pada Mahasiswa Fakultas Keguruan dan Ilmu Pendidikan," *Ekuitas: Jurnal Pendidikan Ekonomi*, vol. 12, no. 2, pp. 386–392, 2024. [Online]. Tersedia: https://www.researchgate.net/publication/390757394_Analisis_Academic_Burnout_pada_Mahasiswa_Fakultas_Keguruan_dan_Ilmu_Pendidikan
- [2] D. Z. Oktaviani and Marsofiyati, "Pengaruh Beban Tugas Akademik dan Dukungan Sosial terhadap Tingkat Burnout Mahasiswa Pendidikan Administrasi Perkantoran," *Harmoni Pendidikan: Jurnal Ilmu Pendidikan*, vol. 2, no. 1, pp. 322–336, 2024, doi: <https://doi.org/10.62383/hardik.v2i1.1102>
- [3] P. A. Andreas, S. F. Firmansyah, and H. H. Pradana, "Studi Fenomenologi Burnout pada Mahasiswa yang Kuliah dan Bekerja," *Psycho Aksara: Jurnal Penelitian Psikologi*, vol. 3, no. 2, pp. 154–178, 2025, doi: <https://doi.org/10.28926/psychoaksara.v3i2.1726>
- [4] A. Firdaus, N. Yuliyanasari, and G. N. Djalillah, "Potensi Kejadian Burnout pada Mahasiswa Kedokteran di Masa Pandemi Covid-19," *Hang Tuah Medical Journal*, vol. 18, no. 2, p. 114, 2021, doi: <https://doi.org/10.30649/htmj.v18i2.464>

- [5] W. Sia'tang, K. Napolion, and A. A. Oktaviani, "Risk Factors for Burnout in the Preparation of Student Final Projects," *Jurnal Ilmiah Kesehatan Sandi Husada*, vol. 13, no. 1, pp. 102–110, 2024, doi: <https://doi.org/10.35816/jiskh.v13i1.1183>
- [6] Khoirunnisah, Marsofiyati, and E. D. Utari, "Literatur Review: Pengaruh Strategi Coping dalam Mengatasi Burnout Akademik Mahasiswa," *Academia: Jurnal Inovasi Riset Akademik*, vol. 5, no. 2, pp. 131–138, 2025. [Online]. Tersedia: <https://www.jurnalp4i.com/index.php/academia/article/view/4970>
- [7] J. J. Hidayat, F. F. Azhari, T. M. Husna, A. N. Fahmayani, N. N. Pradana, and C. Setyowati, "Perbandingan Kinerja Algoritma Machine Learning dalam Prediksi Kesehatan Mental dan Burnout Mahasiswa," *Jurnal Surya Informatika*, vol. 16, no. 1, pp. 32–42, 2026, doi: <https://doi.org/10.48144/suryainformatika.v16i1.2420>
- [8] O. S. Rinyuakng Rolin, W. Nugraha, and R. Sa'adah, "Komparasi Algoritma Machine Learning untuk Prediksi Risiko Burnout Akademis Akibat Penggunaan Generative AI," *Jurnal Komputer Teknologi Informasi Sistem Komputer (JUKTISI)*, vol. 5, no. 2, pp. 1503–1512, 2026, doi: <https://doi.org/10.62712/juktisi.v5i2.1366>
- [9] N. Supriani, S. W. Ningrum, and A. G. Nugraheni, "Penerapan Algoritma Naïve Bayes dalam Machine Learning untuk Klasifikasi Faktor-Faktor yang Mempengaruhi Kesehatan Mental Siswa," *Technology and Informatics Insight Journal*, vol. 4, no. 2, pp. 19–29, 2025, doi: <https://doi.org/10.32639/y35c0d63>
- [10] M. Z. Ramadhany et al., "Klasifikasi Mahasiswa Berpotensi Drop Out (DO) Menggunakan Algoritma Random Forest," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 10, no. 2, pp. 3543–3548, 2026. [Online]. Tersedia: <https://www.ejournal.itn.ac.id/jati/article/download/17666/9315>
- [11] A. R. Azis, "Analisis Komparasi Algoritma Machine Learning dalam Prediksi Performa Akademik Mahasiswa: Literature Review," *Jurnal Ilmu Komputer dan Informatika*, vol. 4, no. 2, pp. 143–148, 2025, doi: <https://doi.org/10.54082/jiki.212>
- [12] Y. I. Kurniawan, P. R. Anugrah, R. M. Sugihono, F. A. Abimanyu, and L. Afuan, "Pengelompokan Prioritas Negara yang Membutuhkan Bantuan Menggunakan Clustering K-Means dengan Elbow dan Silhouette," *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 3, no. 10, pp. 455–463, 2023, doi: <https://doi.org/10.52436/1.jpti.343>
- [13] Y. P. Anggriani, A. Arif, and Febriansyah, "Implementation of the K-Means Clustering Algorithm in Determining Productive Oil Palm Blocks at PT Arta Prigel," *JISA (Jurnal Informatika dan Sains)*, vol. 7, no. 1, pp. 53–58, 2024, doi: <https://doi.org/10.31326/jisa.v7i1.2008>
- [14] R. Sugianto and H. Sulistiani, "Sistem Pendukung Keputusan Pemilihan Guru Terbaik Menggunakan Kombinasi Metode Pembobotan CRITIC dan COPRAS," *Journal of Information System Research (JOSH)*, vol. 6, no. 1, pp. 164–175, 2024, doi: <https://doi.org/10.47065/josh.v6i1.5841>
- [15] Y. K. Gulo, "Sistem Pendukung Keputusan Pemilihan Calon Barista dengan Menggunakan Metode DEMATEL dan WASPAS (Studi Kasus: Coffee Corner Medan)," *Kajian Ilmiah Informatika dan Komputer*, vol. 1, no. 2, pp. 210–217, 2021.
- [16] R. Dermawan and S. Sinurat, "Penerapan Metode Multi-Attributive Border Approximation Area Comparison (MABAC) dalam Penentuan Akademi Kebidanan (AKBID) Terbaik," *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 1, pp. 1–8, 2021, doi: <https://doi.org/10.47065/josyc.v3i1.820>
- [17] S. Badiwibowo Atim and Y. E. Wibawa, "Sistem Pendukung Keputusan Pemberian Kredit Koperasi Simpan Pinjam Menggunakan Metode MARCOS dan Rank Order Centroid," *Jurnal Ilmiah Informatika dan Ilmu Komputer (JIMA-ILKOM)*, vol. 3, no. 1, pp. 1–12, 2024, doi: <https://doi.org/10.58602/jima-ilkom.v3i1.22>
- [18] M. Muhajir and J. Widiastuti, "Random Forest Method Approach to Customer Classification Based on Non-Performing Loan in Micro Business," *JOIN: Jurnal Online Informatika*, vol. 7, no. 2, pp. 177–183, 2022, doi: <https://doi.org/10.15575/join.v7i2.842>
- [19] P. H. Gunawan and I. V. Paputungan, "Detection of Graduation Potential in Prospective Students Using the Random Forest Algorithm," *Sistemasi: Jurnal Sistem Informasi*, vol. 14, no. 5, pp. 2055–2065, 2025. [Online]. Tersedia: <https://doaj.org/article/b254779a22ff45d680c2419026afd99e>
- [20] N. Yuniza, Lisnawanty, and K. Handayani, "Perbandingan Kinerja CatBoost, LightGBM, dan XGBoost dengan Teknik SMOTE dan Bayesian Optimization untuk Prediksi Customer Churn pada

- Platform E-commerce," *Jurnal Komputer Teknologi Informasi Sistem Komputer (JUKTISI)*, vol. 5, no. 2, pp. 1490–1502, 2026. [Online]. Tersedia: <https://ejurnal.lkpkaryaprima.id/index.php/juktisi/article/view/1371>
- [21] Marsono, A. H. Nasyuha, Y. Syahra, and I. Mariami, "Decision Support System for Selecting Online Teaching Methods Using the Fuzzy MCDM Algorithm," *Sinkron: Jurnal dan Penelitian Teknik Informatika*, vol. 8, no. 3, 2024. [Online]. Tersedia: <https://jurnal.polgan.ac.id/index.php/sinkron/article/view/13731>
- [22] A. H. Nasyuha, H. Tujantri, O. Veza, S. Nurarif, and M.-Y. Chung, "Comparison of WSM and Weight Product Methods with WSM-Score and Vector Approaches," *Sinkron: Jurnal dan Penelitian Teknik Informatika*, vol. 9, no. 2, pp. 947–958, 2025, doi: <https://doi.org/10.33395/sinkron.v9i2.14817>
- [23] Marsono, A. H. Nasyuha, E. R. Widyayanti, and M.-Y. H. Chung, "Evaluation of Green Marketing Strategy Using Fuzzy AHP-Based Decision Support System," *Sinkron: Jurnal dan Penelitian Teknik Informatika*, vol. 10, no. 3, 2026, doi: <https://doi.org/10.33395/sinkron.v10i3.16277>
- [24] E. Prayitno, I. J. Perdana, and A. H. Nasyuha, "Implementasi Data Mining dan Machine Learning untuk Segmentasi Pelanggan: Pendekatan Hybrid Menggunakan Big Data," *Jurnal Ilmiah FIFO*, vol. 17, no. 1, pp. 57–62, 2025. [Online]. Tersedia: <https://sinta.kemdiktisaintek.go.id/authors/profile/6165218/?view=googlescholar>