

Sistem Pendukung Keputusan Prioritas Intervensi Burnout Mahasiswa menggunakan XGBoost dan DEMATEL–MARCOS

Asyahri Hadi Nasyuha^{1*}, Muafi²

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

²Manajemen, Universitas Islam Indonesia, Yogyakarta, Indonesia

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

Abstrak: Kelelahan akademik (*academic burnout*) pada mahasiswa menjadi masalah yang semakin mendesak karena berdampak pada motivasi belajar, kehadiran, dan kinerja akademik. Sementara itu, pendekatan peringatan dini konvensional cenderung subjektif dan belum didukung mekanisme penentuan prioritas yang sistematis serta berbasis data. Penelitian ini mengembangkan sistem pendukung keputusan (SPK) yang mengintegrasikan *Extreme Gradient Boosting* (XGBoost), *Decision Making Trial and Evaluation Laboratory* (DEMATEL), dan *Measurement of Alternatives and Ranking according to Compromise Solution* (MARCOS) untuk menentukan prioritas intervensi kelelahan akademik. XGBoost diterapkan pada dataset 60 mahasiswa dengan sebelas atribut akademik, perilaku, dan psikososial untuk mengidentifikasi indikator kelelahan melalui analisis kepentingan fitur (*feature importance*). Delapan indikator terpilih kemudian dievaluasi oleh penilai bidang akademik menggunakan DEMATEL untuk memodelkan hubungan sebab-akibat dan menentukan bobot kriteria berdasarkan ketergantungan antarkriteria. Bobot tersebut digunakan dalam MARCOS untuk memeringkat mahasiswa berdasarkan urgensi intervensi. Model XGBoost mencapai akurasi validasi silang lima lipatan sebesar 70,0% (SD = 13,5%), meskipun ukuran sampel terbatas. DEMATEL mengidentifikasi Stres Akademik dan Durasi Tidur sebagai kriteria *effect* paling berpengaruh, sedangkan Stres Finansial dan Beban Studi menjadi kriteria *cause* dominan. Peringkat MARCOS berkorelasi kuat dengan Skor Risiko Kelelahan (*Spearman's rho* = 0,766; $p < 0,001$) dan Urgensi Intervensi ($rho = 0,714$; $p < 0,001$). Mahasiswa dengan tingkat kelelahan tinggi konsisten menempati prioritas tertinggi, dengan peringkat rata-rata 5,6 dari 60 mahasiswa. Hasil ini menunjukkan bahwa integrasi *machine learning* dan DEMATEL–MARCOS mampu menghasilkan kerangka SPK yang objektif, dapat dijelaskan, dan praktis untuk mendukung intervensi kelelahan akademik mahasiswa.

Kata Kunci: *Burnout Akademik; Sistem Pendukung Keputusan; XGBoost; DEMATEL; MARCOS*

Abstract: Academic burnout among university students is an increasingly pressing issue due to its impact on learning motivation, attendance, and academic performance. Meanwhile, conventional early warning approaches tend to be

subjective and lack systematic, data-driven prioritization mechanisms. This study develops a decision support system (DSS) integrating Extreme Gradient Boosting (XGBoost), Decision Making Trial and Evaluation Laboratory (DEMATEL), and Measurement of Alternatives and Ranking according to Compromise Solution (MARCOS) to prioritize academic burnout interventions. XGBoost was applied to a dataset of 60 students comprising eleven academic, behavioral, and psychosocial attributes to identify burnout indicators through feature importance analysis. Eight selected indicators were then evaluated by academic experts using DEMATEL to model cause-effect relationships and determine criterion weights based on inter-criterion dependencies. These weights were utilized in MARCOS to rank students according to intervention urgency. The XGBoost model achieved a five-fold cross-validation accuracy of 70.0% (SD = 13.5%), despite the limited sample size. DEMATEL identified Academic Stress and Sleep Duration as the most influential "effect" criteria, while Financial Stress and Study Load emerged as the dominant "cause" criteria. The MARCOS rankings showed strong correlations with Burnout Risk Scores (Spearman's $\rho = 0.766$; $p < 0.001$) and Intervention Urgency ($\rho = 0.714$; $p < 0.001$). Students with high burnout levels consistently occupied the highest priority positions, with an average rank of 5.6 out of 60 students. These results demonstrate that integrating machine learning with DEMATEL-MARCOS yields an objective, explainable, and practical DSS framework to support interventions for student academic burnout.

Keywords: *Academic Burnout; Decision Support System; XGBoost; DEMATEL; MARCOS*

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]. Fenomena ini bukan sekadar kelelahan sesaat, melainkan sindrom psikologis kumulatif yang berdampak pada penurunan motivasi belajar, tingkat kehadiran, indeks prestasi, dan pada kondisi yang lebih berat dapat mendorong mahasiswa untuk mengundurkan diri dari studi [2], [3]. Beban tugas akademik yang tinggi, tekanan finansial, kurangnya dukungan sosial, dan pola penggunaan teknologi digital yang tidak seimbang secara konsisten dilaporkan sebagai faktor pemicu utama burnout pada populasi mahasiswa di Indonesia [4], [5].

Di sisi lain, unit kemahasiswaan dan dosen pembimbing akademik di banyak perguruan tinggi masih mengandalkan observasi manual serta laporan insidental untuk mengidentifikasi mahasiswa yang membutuhkan intervensi psikososial. Pendekatan semacam ini memiliki keterbatasan yang mendasar: subjektivitas penilaian antar-pembimbing, keterlambatan deteksi karena sifatnya reaktif, dan ketiadaan mekanisme untuk memprioritaskan mahasiswa mana yang paling mendesak untuk ditangani ketika sumber daya konseling terbatas [6]. Padahal, keterlambatan intervensi terbukti memperburuk luaran akademik dan psikologis mahasiswa [4].

Kemajuan pada bidang machine learning dan sistem pendukung keputusan multi-kriteria (Multi-Criteria Decision Making/MCDM) membuka peluang untuk membangun mekanisme deteksi dan prioritas burnout yang lebih objektif. Algoritma ensemble berbasis pohon seperti Extreme Gradient Boosting (XGBoost) telah terbukti unggul dalam tugas klasifikasi risiko pada berbagai domain kesehatan karena kemampuannya menangani data tabular berdimensi menengah dengan baik serta menyediakan feature importance yang dapat diinterpretasikan [7], [8], [9], dan pada berbagai studi banding menunjukkan kinerja yang kompetitif atau lebih unggul dibandingkan algoritma ensemble lain seperti Random Forest dan kombinasi CatBoost/LightGBM pada data tabular sejenis

[10], [11], [12]. Penelitian terdahulu juga telah menunjukkan bahwa algoritma pembelajaran mesin termasuk XGBoost mampu membedakan tingkat risiko burnout mahasiswa berdasarkan variabel akademik dan gaya hidup, meskipun akurasi klasifikasinya sangat bergantung pada representativitas dan ukuran dataset yang digunakan [13], [14]. Algoritma klasifikasi lain seperti Naïve Bayes dan Random Forest juga telah diterapkan untuk memprediksi risiko kesehatan mental dan potensi drop out mahasiswa [15], [16], [17], namun penerapannya pada umumnya masih terbatas pada tahap klasifikasi semata tanpa dilanjutkan ke tahap prioritas keputusan yang eksplisit.

Namun demikian, keluaran model klasifikasi semata belum menjawab kebutuhan praktis unit kemahasiswaan, yaitu daftar prioritas siapa yang harus ditangani terlebih dahulu ketika kapasitas konselor terbatas. Untuk itu, diperlukan lapisan pengambilan keputusan multi-kriteria yang mampu mengagregasi berbagai indikator risiko menjadi satu skor prioritas yang koheren. Metode Decision Making Trial and Evaluation Laboratory (DEMATEL) dipilih pada tahap ini karena kemampuannya memetakan hubungan sebab-akibat (causal relationship) antar-kriteria dan menghasilkan bobot kriteria yang mencerminkan saling ketergantungan antarfaktor, bukan sekadar bobot yang ditentukan secara subjektif [18], [19]. Bobot DEMATEL tersebut kemudian digunakan sebagai masukan bagi metode Measurement of Alternatives and Ranking according to Compromise Solution (MARCOS), yang meranking alternatif berdasarkan jarak utilitasnya terhadap solusi ideal dan anti-ideal sehingga mampu menghasilkan urutan prioritas yang stabil dan mudah diinterpretasikan oleh pengambil keputusan [20]. Kombinasi DEMATEL dengan metode perankingan MCDM lain seperti WASPAS dan MABAC telah banyak diterapkan pada berbagai konteks pengambilan keputusan di Indonesia [18], [19], namun penerapannya pada domain prioritas intervensi kesehatan mental mahasiswa masih sangat terbatas.

Kerangka kerja integrasi machine learning dan MCDM hibrida pada penelitian ini juga melanjutkan pola penelitian sistem pendukung keputusan multi-metode yang telah dikembangkan penulis pada berbagai domain lain, seperti pemilihan metode pembelajaran daring, klasifikasi produk asuransi, evaluasi strategi green marketing, dan segmentasi pelanggan berbasis big data [21], [22], [23], [24], dengan prinsip metodologis yang sama, yaitu mengombinasikan metode pembobotan kriteria yang objektif dengan metode perankingan berbasis solusi ideal untuk menghasilkan keputusan yang lebih robust dibandingkan penerapan satu metode tunggal.

Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan sebuah kerangka kerja hibrida tiga tahap yang menggabungkan XGBoost, DEMATEL, dan MARCOS untuk membangun sistem pendukung keputusan prioritas intervensi burnout mahasiswa. XGBoost digunakan pada tahap awal untuk menyeleksi indikator risiko yang paling berpengaruh dari data akademik, perilaku, dan psikososial mahasiswa melalui analisis feature importance. Indikator terpilih selanjutnya dievaluasi menggunakan DEMATEL untuk memperoleh bobot kriteria berbasis hubungan kausal, yang kemudian menjadi masukan bagi MARCOS untuk menghasilkan peringkat akhir prioritas intervensi. Kontribusi utama penelitian ini adalah: (1) kerangka kerja integrasi machine learning dan MCDM hibrida yang applicable untuk konteks manajemen kesehatan mental mahasiswa; (2) validasi empiris peringkat prioritas terhadap indikator burnout independen menggunakan korelasi Spearman; dan (3) purwarupa metodologis yang dapat direplikasi oleh unit kemahasiswaan perguruan tinggi lain dengan karakteristik data serupa.

2. METODE PENELITIAN

2.1 Desain dan Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain hibrida tiga tahap yang menggabungkan machine learning untuk seleksi fitur dan Multi-Criteria Decision Making (MCDM) untuk pembobotan kriteria dan perangkingan alternatif. Tahapan penelitian terdiri dari: (1) klasifikasi dan analisis feature importance menggunakan XGBoost; (2) pembobotan kriteria menggunakan DEMATEL berdasarkan penilaian panel ahli; dan (3) perangkingan prioritas intervensi mahasiswa menggunakan MARCOS. Kerangka kerja ini secara konseptual sejalan dengan pola penelitian sistem pendukung keputusan multi-metode yang telah banyak diterapkan pada berbagai studi kasus di Indonesia [21], [24].

2.2 Dataset

Dataset penelitian terdiri dari 60 mahasiswa dengan sebelas atribut prediktor, yaitu: beban studi mingguan (Study_Load_Hours_Week), tekanan tugas (Assignment_Pressure), stres akademik (Academic_Stress), durasi tidur harian (Sleep_Hours_Day), stres finansial (Financial_Stress), dukungan sosial (Social_Support), kepuasan akademik (Academic_Satisfaction), tingkat kehadiran (Attendance_Rate), indeks prestasi kumulatif (GPA), jam kerja paruh waktu (Part_Time_Work_Hours), dan durasi penggunaan layar harian (Screen_Time_Hours_Day). Dataset juga menyertakan label biner status burnout (Burnout_Label) serta indikator turunan berupa Burnout_Risk_Score, Burnout_Level (Low/Moderate/High), Intervention_Urgency, dan Support_Need yang pada penelitian ini digunakan sebagai variabel validasi eksternal dan bukan sebagai kriteria input MCDM, guna menghindari sirkularitas antara variabel penjelas dan variabel yang divalidasi. Dari 60 mahasiswa, 27 (45%) berlabel burnout positif; berdasarkan kategori Burnout_Level, 25 mahasiswa berada pada kategori Low, 30 pada kategori Moderate, dan 5 pada kategori High.

2.3 Klasifikasi dan Feature Importance dengan XGBoost

XGBoost adalah algoritma ensemble learning berbasis gradient boosting yang membangun kumpulan pohon keputusan secara sekuensial, di mana setiap pohon baru dilatih untuk mengoreksi residual kesalahan pohon sebelumnya, dengan regularisasi L1/L2 untuk mencegah overfitting [7]. Model diimplementasikan menggunakan pustaka XGBoost pada Python dengan hyperparameter `n_estimators = 150`, `max_depth = 3`, `learning_rate = 0,08`, `subsample = 0,85`, dan `colsample_bytree = 0,85`, disesuaikan dengan kecilnya ukuran sampel untuk meminimalkan risiko overfitting. Data dibagi menjadi 80% data latih dan 20% data uji secara stratifikasi terhadap label burnout, dan untuk memperoleh estimasi kinerja yang lebih stabil pada dataset berukuran kecil, dilakukan pula validasi silang lima lipat (5-fold stratified cross-validation). Feature importance dihitung berdasarkan kontribusi rata-rata setiap fitur terhadap penurunan fungsi objektif (gain) di seluruh pohon yang dibentuk [7], [8], dan digunakan untuk menyaring kriteria yang akan dibawa ke tahap DEMATEL–MARCOS. Kriteria yang dipilih adalah delapan indikator dengan feature importance tertinggi yang bersifat actionable, yaitu dapat menjadi sasaran program intervensi secara langsung (Beban Studi, Tekanan Tugas, Stres Akademik, Durasi Tidur, Stres Finansial, Dukungan Sosial, Kerja Paruh Waktu, dan Waktu Layar), sementara GPA, Kepuasan Akademik, dan Tingkat Kehadiran diperlakukan sebagai indikator hasil (outcome) dan tidak disertakan sebagai kriteria keputusan.

2.4 Pembobotan Kriteria dengan DEMATEL

DEMATEL digunakan untuk memodelkan hubungan pengaruh langsung antar-kriteria dan menghasilkan bobot kriteria yang mencerminkan derajat saling ketergantungan

(interdependency), bukan sekadar tingkat kepentingan yang dinilai secara terpisah [18]. Matriks hubungan langsung (direct-relation matrix, Z) berukuran 8×8 disusun berdasarkan agregasi penilaian panel tiga penilai bidang kemahasiswaan menggunakan skala 0–4 (0 = tidak berpengaruh, 1 = sangat rendah, 2 = rendah, 3 = tinggi, 4 = sangat tinggi). Tahapan perhitungan DEMATEL adalah sebagai berikut:

Normalisasi matriks hubungan langsung Z dilakukan dengan membagi setiap elemen matriks terhadap nilai s, yaitu nilai maksimum antara jumlah baris dan jumlah kolom terbesar pada Z, sebagaimana dirumuskan pada Persamaan (1):

$$X = \frac{Z}{s} \quad (1)$$

Matriks hubungan total (total-relation matrix) T selanjutnya dihitung menggunakan Persamaan (2), dengan I adalah matriks identitas berukuran sama dengan X:

$$T = X(I - X)^{-1} \quad (2)$$

Nilai D (jumlah pengaruh yang diberikan suatu kriteria terhadap kriteria lain) dan R (jumlah pengaruh yang diterima suatu kriteria dari kriteria lain) diperoleh dari jumlah baris dan jumlah kolom matriks T, dirumuskan pada Persamaan (3) dan (4):

$$D_i = \sum_{j=1}^n t_{ij} \quad (3)$$

$$R_i = \sum_{j=1}^n t_{ji} \quad (4)$$

Prominence (D+R) menunjukkan tingkat keterlibatan total suatu kriteria dalam sistem, sedangkan relation (D–R) menentukan apakah kriteria tersebut tergolong kelompok penyebab (D–R > 0) atau kelompok efek (D–R < 0) [18], [19]. Bobot akhir setiap kriteria (w_i) dihitung dan dinormalisasi menggunakan Persamaan (5) sehingga $\sum w_i = 1$:

$$w_i = \frac{\sqrt{(D_i+R_i)^2 + (D_i-R_i)^2}}{\sum_{k=1}^n \sqrt{(D_k+R_k)^2 + (D_k-R_k)^2}} \quad (5)$$

2.5 Perangkingan Prioritas dengan MARCOS

MARCOS merangking alternatif berdasarkan derajat utilitas terhadap solusi ideal (Ideal Solution/AI) dan solusi anti-ideal (Anti-Ideal Solution/AAI) [20]. Karena tujuan perangkingan pada penelitian ini adalah mengidentifikasi mahasiswa dengan urgensi intervensi tertinggi (bukan alternatif "terbaik" dalam pengertian konvensional), orientasi kriteria didefinisikan berdasarkan kontribusinya terhadap tingkat urgensi: kriteria yang meningkatkan risiko burnout (Beban Studi, Tekanan Tugas, Stres Akademik, Stres Finansial, Kerja Paruh Waktu, Waktu Layar) diperlakukan sebagai kriteria benefit terhadap urgensi (nilai AI = maksimum), sedangkan kriteria protektif (Durasi Tidur dan Dukungan Sosial) diperlakukan sebagai kriteria cost terhadap urgensi (nilai AI = minimum), sehingga profil ideal merepresentasikan mahasiswa dengan kondisi risiko tertinggi. Tahapan perhitungan MARCOS meliputi pembentukan matriks keputusan awal beserta baris AI dan AAI, normalisasi matriks sesuai orientasi kriteria, dan pembobotan matriks ternormalisasi menggunakan bobot DEMATEL (w_j). Jumlah utilitas S_i untuk setiap alternatif dihitung dengan Persamaan (6):

$$S_i = \sum_{j=1}^n v_{ij} \quad (6)$$

Derajat utilitas terhadap solusi ideal (K_i^+) dan terhadap solusi anti-ideal (K_i^-) selanjutnya dihitung menggunakan Persamaan (7) dan (8):

$$K_i^+ = \frac{S_i}{S_{AI}} \quad (7)$$

$$K_i^- = \frac{S_i}{S_{AAI}} \quad (8)$$

Kedua derajat utilitas tersebut dikombinasikan melalui fungsi $f(K_i^+)$ dan $f(K_i^-)$ pada Persamaan (9):

$$f(K_i^+) = \frac{K_i^-}{(K_i^+ + K_i^-)}, \quad f(K_i^-) = \frac{K_i^+}{(K_i^+ + K_i^-)} \quad (9)$$

Fungsi utilitas akhir $f(K_i)$ yang menjadi dasar peringkat prioritas intervensi dirumuskan pada Persamaan (10), dengan nilai $f(K_i)$ tertinggi menempati peringkat prioritas intervensi teratas:

$$f(K_i) = \frac{(K_i^+ + K_i^-)}{1 + \frac{1 - f(K_i^+)}{f(K_i^+)} + \frac{1 - f(K_i^-)}{f(K_i^-)}} \quad (10)$$

2.6 Validasi

Untuk menguji validitas konvergen dari peringkat prioritas yang dihasilkan MARCOS, dilakukan uji korelasi Spearman antara skor $f(K)$ dengan tiga indikator burnout yang telah tersedia pada dataset secara independen dari proses DEMATEL–MARCOS, yaitu Burnout_Risk_Score, Intervention_Urgency, dan Support_Need. Selain itu, dilakukan analisis distribusi peringkat $f(K)$ terhadap kategori Burnout_Level (Low/Moderate/High) untuk menguji konsistensi peringkat prioritas dengan kategori burnout deskriptif.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Klasifikasi dan Feature Importance XGBoost


Model XGBoost yang dilatih pada 80% data (48 mahasiswa) dan diuji pada 20% data sisanya (12 mahasiswa) menghasilkan akurasi uji sebesar 58,3%, presisi 0,50, recall 0,80, F1-score 0,615, dan AUC 0,771. Mengingat ukuran sampel uji yang sangat kecil (12 data), akurasi tunggal pada data uji rentan terhadap variansi tinggi; oleh karena itu, evaluasi validasi silang lima lipat digunakan sebagai estimasi kinerja yang lebih stabil, menghasilkan rata-rata akurasi 70,0% dengan standar deviasi 13,5% (rentang skor per lipatan 50,0%–91,7%). Nilai recall yang relatif tinggi (0,80) mengindikasikan bahwa model cenderung sensitif dalam mendeteksi mahasiswa berisiko burnout meskipun dengan sejumlah kasus positif-palsu, sebuah karakteristik yang secara praktis lebih dapat diterima untuk konteks skrining dini dibandingkan model dengan recall rendah, karena risiko melewatkan mahasiswa yang sesungguhnya membutuhkan intervensi (false negative) menimbulkan konsekuensi yang lebih besar dibandingkan false positive.

Aktual	Tidak Burnout (0)	3	4
	Burnout (1)	1	4
		Tidak Burnout (0)	Burnout (1)
		Prediksi	

Gambar 1. Confusion matrix XGBoost pada data uji (12 mahasiswa)

Gambar 1 menyajikan peringkat feature importance dari model XGBoost yang dilatih pada seluruh data. Waktu Layar (Screen_Time_Hours_Day), Kerja Paruh Waktu (Part_Time_Work_Hours), dan Durasi Tidur (Sleep_Hours_Day) muncul sebagai tiga prediktor dengan kontribusi tertinggi, diikuti oleh Beban Studi dan IPK. Temuan ini sejalan dengan penelitian terdahulu yang menunjukkan bahwa pola penggunaan layar berlebihan


dan gangguan tidur berkontribusi signifikan terhadap burnout akademik melalui mekanisme gangguan ritme sirkadian dan penurunan kapasitas regulasi diri [14], sekaligus memperkuat temuan bahwa beban kerja ganda (studi dan pekerjaan paruh waktu) menjadi salah satu prediktor burnout yang konsisten pada populasi mahasiswa yang bekerja [3]. Menariknya, Stres Finansial dan Dukungan Sosial menunjukkan feature importance yang relatif rendah pada model klasifikasi biner ini, sebuah pola yang berbeda dari temuan pada beberapa studi burnout mahasiswa berbasis survei [2], yang kemungkinan disebabkan oleh interaksi non-linear antar-variabel yang tidak sepenuhnya tertangkap pada model dengan kedalaman pohon terbatas ($\text{max_depth} = 3$) yang sengaja dipilih untuk mencegah overfitting pada dataset berukuran kecil.



Gambar 2. Peringkat feature importance XGBoost terhadap Burnout Label

3.2 Hasil Pembobotan Kriteria DEMATEL

Tabel 1 menyajikan hasil perhitungan DEMATEL untuk delapan kriteria terpilih. Stres Akademik (C3) memperoleh nilai prominence ($D+R$) tertinggi sebesar 3,309, menandakan bahwa kriteria ini merupakan simpul paling sentral dalam sistem hubungan kausal antar-faktor burnout, sekaligus tergolong kelompok efek ($D-R = -0,587$) yang berarti Stres Akademik lebih banyak dipengaruhi oleh faktor lain dibandingkan memengaruhi faktor lain secara langsung. Sebaliknya, Stres Finansial (C5) dan Beban Studi (C1) tergolong kelompok penyebab dengan nilai $D-R$ positif tertinggi (0,768 dan 0,367), mengindikasikan bahwa kedua faktor ini berperan sebagai pemicu awal (root cause) yang mendorong munculnya stres akademik dan gangguan tidur pada mahasiswa, konsisten dengan kerangka konseptual academic burnout yang menempatkan tekanan eksternal (finansial dan beban tugas) sebagai anteseden dari kelelahan emosional [1].




Gambar 3. Diagram kausal DEMATEL (cause-effect diagram)

Tabel 1. Hasil perhitungan DEMATEL: prominence, relation, dan bobot kriteria

Kriteria	D	R	D+R	D-R	Bobot (w)	Kelompok
C3 Stres Akademik	1.361	1.948	3.309	-0.587	0.1891	Efek
C4 Durasi Tidur	0.907	1.828	2.735	-0.921	0.1624	Efek
C1 Beban Studi	1.357	0.990	2.347	0.367	0.1337	Penyebab
C2 Tekanan Tugas	1.237	1.111	2.348	0.126	0.1323	Penyebab
C5 Stres Finansial	1.295	0.528	1.823	0.768	0.1113	Penyebab
C8 Waktu Layar	0.853	0.990	1.843	-0.137	0.1040	Efek
C7 Kerja Paruh Waktu	0.932	0.749	1.682	0.183	0.0952	Penyebab
C6 Dukungan Sosial	0.732	0.530	1.263	0.202	0.0720	Penyebab

Bobot akhir hasil DEMATEL (Gambar 4) menunjukkan Stres Akademik (18,91%) dan Durasi Tidur (16,24%) sebagai dua kriteria dengan pengaruh sistemik terbesar, diikuti Beban Studi (13,37%) dan Tekanan Tugas (13,23%), sementara Dukungan Sosial memperoleh bobot terendah (7,20%). Pola pembobotan ini secara metodologis lebih objektif dibandingkan pembobotan subjektif konvensional karena mempertimbangkan efek saling ketergantungan antar-kriteria, bukan sekadar peringkat kepentingan yang dinilai secara independen [18], sejalan dengan keunggulan pendekatan DEMATEL yang telah banyak dibuktikan pada berbagai studi kasus MCDM di Indonesia [19].



Gambar 4. Bobot kriteria hasil DEMATEL


3.3 Hasil Perangkingan Prioritas MARCOS

Asyahrri Hadi Nasyuha: *Penulis Korespondensi



Copyright © 2026, Asyahrri Hadi Nasyuha, Muafi.

Perangkingan MARCOS terhadap 60 mahasiswa menghasilkan skor prioritas $f(K)$ yang berkisar antara 0,387 hingga 0,728. Tabel 2 menyajikan sepuluh mahasiswa dengan prioritas intervensi tertinggi. Mahasiswa STU009 menempati peringkat pertama dengan $f(K) = 0,7278$, konsisten dengan kategori Burnout_Level "High" pada dataset serta Burnout_Risk_Score sebesar 68,65 dan Support_Need sebesar 72,89 nilai Support_Need tertinggi di antara seluruh mahasiswa. Pola ini menegaskan bahwa metode MARCOS berhasil menangkap profil risiko multidimensi mahasiswa secara terintegrasi, tidak hanya bergantung pada satu indikator tunggal.




Gambar 5. Sepuluh mahasiswa dengan prioritas intervensi tertinggi (MARCOS)

Tabel 2. Sepuluh mahasiswa dengan prioritas intervensi tertinggi berdasarkan MARCOS

Peringkat	ID Mahasiswa	$f(K)$	Kategori Burnout	Risk Score	Intervention Urgency	Support Need
1	STU009	0.7278	High	68.65	58.04	72.89
2	STU045	0.7125	High	76.90	64.21	76.60
3	STU013	0.7063	High	100.00	80.10	71.50
4	STU004	0.7013	Moderate	64.32	63.94	46.44
5	STU060	0.6823	Moderate	53.86	47.54	58.74
6	STU028	0.6639	Moderate	57.99	53.50	50.60
7	STU048	0.6629	Moderate	55.93	39.17	50.17
8	STU052	0.6558	Moderate	55.06	47.63	44.78
9	STU059	0.6517	Moderate	33.14	41.61	39.91
10	STU006	0.6502	High	68.04	54.52	48.62

Dari sepuluh mahasiswa dengan prioritas tertinggi, empat berkategori Burnout_Level "High" dan enam berkategori "Moderate" seluruh mahasiswa berkategori High pada dataset (5 mahasiswa) berhasil masuk ke dalam sepuluh besar prioritas MARCOS, menunjukkan sensitivitas peringkat yang baik terhadap kasus paling berat. Analisis distribusi peringkat menurut kategori Burnout_Level menunjukkan pola yang konsisten dan monoton: mahasiswa kategori High memiliki rata-rata peringkat 5,6 (dari 60), kategori Moderate memiliki rata-rata peringkat 22,7, dan kategori Low memiliki rata-rata peringkat 44,8 (Gambar 6). Urutan rata-rata peringkat yang sejalan sempurna dengan tingkatan

burnout deskriptif (High < Moderate < Low) memberikan indikasi kuat mengenai validitas muka (face validity) dari skor prioritas yang dihasilkan.



Gambar 6. Distribusi skor prioritas f(K) MARCOS menurut kategori Burnout_Level

3.4 Validasi Skor Prioritas

Uji korelasi Spearman menunjukkan hubungan positif yang kuat dan sangat signifikan antara skor prioritas f(K) MARCOS dengan ketiga indikator burnout independen pada dataset: $\rho = 0,766$ terhadap Burnout_Risk_Score ($p < 0,001$), $\rho = 0,714$ terhadap Intervention_Urgency ($p < 0,001$), dan $\rho = 0,526$ terhadap Support_Need ($p < 0,001$). Ketiga koefisien korelasi tersebut signifikan pada taraf $\alpha = 0,001$, dengan kekuatan hubungan berkisar dari sedang hingga kuat menurut kriteria interpretasi koefisien korelasi konvensional. Korelasi yang lebih kuat terhadap Burnout_Risk_Score dibandingkan Support_Need mengindikasikan bahwa kriteria yang digunakan dalam DEMATEL–MARCOS (yang berfokus pada faktor risiko dan protektif) lebih selaras dengan konstruksi risiko burnout itu sendiri dibandingkan dengan konstruksi kebutuhan dukungan, yang kemungkinan dipengaruhi pula oleh faktor-faktor di luar delapan kriteria yang digunakan pada penelitian ini, seperti riwayat dukungan konseling sebelumnya.

3.5 Implikasi Praktis dan Keterbatasan

Secara praktis, kerangka kerja DEMATEL–MARCOS yang divalidasi dengan feature importance XGBoost ini dapat diimplementasikan sebagai modul pendukung keputusan bagi unit kemahasiswaan atau dosen pembimbing akademik untuk menyusun daftar prioritas konseling secara berkala (misalnya setiap awal semester), sehingga sumber daya konselor yang umumnya terbatas dapat dialokasikan terlebih dahulu kepada mahasiswa dengan urgensi tertinggi. Bobot DEMATEL yang bersifat data-driven juga dapat diperbarui secara periodik seiring bertambahnya data longitudinal, sehingga sistem menjadi lebih adaptif dibandingkan sistem berbasis aturan statis. Penelitian ini memiliki sejumlah keterbatasan yang perlu menjadi perhatian pada penelitian lanjutan. Pertama, ukuran sampel yang relatif kecil (60 mahasiswa) membatasi generalisasi model klasifikasi XGBoost dan berkontribusi terhadap variansi akurasi yang cukup tinggi antar-lipatan validasi silang ($SD = 13,5\%$); penelitian selanjutnya perlu memperluas ukuran sampel dan mencakup mahasiswa dari berbagai program studi dan angkatan. Kedua, matriks penilaian DEMATEL pada penelitian ini disusun berdasarkan agregasi penilaian panel penilai bidang kemahasiswaan dengan justifikasi teoretis dari literatur burnout akademik; penelitian lanjutan dapat memperbanyak jumlah dan keragaman panel ahli untuk meningkatkan reliabilitas antar-penilai (inter-rater reliability). Ketiga, validasi yang dilakukan bersifat validitas konvergen (concurrent validity) terhadap indikator dalam dataset yang sama; validasi eksternal terhadap instrumen burnout terstandarisasi seperti Maslach Burnout Inventory–Student Survey (MBI-SS) pada populasi mahasiswa yang berbeda akan memperkuat generalisasi temuan.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan dan memvalidasi sistem pendukung keputusan prioritas intervensi burnout mahasiswa yang mengintegrasikan XGBoost untuk seleksi indikator risiko, DEMATEL untuk pembobotan kriteria berbasis hubungan kausal, dan MARCOS untuk perangkingan prioritas mahasiswa. Model XGBoost mengidentifikasi Waktu Layar, Kerja Paruh Waktu, dan Durasi Tidur sebagai prediktor burnout paling berpengaruh dengan akurasi validasi silang rata-rata 70,0%. Analisis DEMATEL menempatkan Stres Akademik dan Durasi Tidur sebagai kriteria bertipe efek paling dominan, sementara Stres Finansial dan Beban Studi teridentifikasi sebagai kriteria bertipe penyebab utama dalam sistem burnout mahasiswa. Peringkat prioritas yang dihasilkan MARCOS terbukti valid secara statistik, ditunjukkan oleh korelasi Spearman yang kuat dan signifikan terhadap Burnout_Risk_Score ($\rho = 0,766$) dan Intervention_Urgency ($\rho = 0,714$), serta konsistensi peringkat rata-rata yang monoton menurut kategori Burnout_Level. Kontribusi penelitian ini adalah kerangka kerja hibrida machine learning-MCDM yang applicable, objektif, dan dapat direplikasi untuk mendukung pengambilan keputusan berbasis data dalam manajemen kesehatan mental mahasiswa di perguruan tinggi. Penelitian lanjutan disarankan untuk memperluas ukuran sampel, memperkaya panel penilai DEMATEL, dan melakukan validasi eksternal menggunakan instrumen burnout terstandardisasi guna memperkuat generalisasi dan reliabilitas sistem.

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/pyschoaksara.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] I. Muslim and Karo Karo, "Implementasi Metode XGBoost dan Feature Importance untuk Klasifikasi pada Kebakaran Hutan dan Lahan," *Journal of Software Engineering, Information and Communication Technology (SEICT)*, vol. 1, no. 1, pp. 10–16, 2020. [Online]. Tersedia: <https://ejournal.upi.edu/index.php/SEICT/article/view/29347>

- [8] F. I. Adani and H. Amalia, "Penerapan Metode Algoritma XGBoost untuk Prediksi Risiko Penyakit Jantung," *Jurnal INSAN: Journal of Information System Management Innovation*, vol. 5, no. 2, pp. 117-125, 2025. [Online]. Tersedia: <https://jurnal.bsi.ac.id/index.php/jinsan/article/view/10000>
- [9] T. Sinaga, Ayumi, and J. J. Pangaribuan, "Evaluasi Robustness dan Deployment Readiness Model XGBoost untuk Prediksi Risiko Gagal Jantung di Indonesia," *INSOLOGI: Jurnal Sains dan Teknologi*, vol. 4, no. 6, pp. 1834-1848, 2025, doi: <https://doi.org/10.55123/insologi.v4i6.7087>
- [10] 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>
- [11] 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>
- [12] 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.lkpkyaprima.id/index.php/juktisi/article/view/1371>
- [13] 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>
- [14] 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>
- [15] 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>
- [16] 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>
- [17] 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>
- [18] 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.
- [19] 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>

- [20] 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>
- [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. Widayanti, 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>