

Dominansi Fitur Perilaku Keuangan dan Tren Akademik pada Deteksi Dini Kelulusan Mahasiswa dengan XGBoost

Widya Dharma Sidi

Program Studi Ilmu Komputer, Program Pascasarjana, Universitas Pendidikan Ganesha, Singaraja, Bali

Email: daridharma@gmail.com

Email Penulis Korespondensi: daridharma@gmail.com*

Submitted: 19/02/2026; Accepted: 14/03/2026; Published: 31/03/2026

Abstrak—Ketepatan waktu kelulusan merupakan indikator krusial bagi keberlanjutan institusi pendidikan tinggi. Namun, metode pemantauan konvensional sering kali luput mendeteksi mahasiswa berisiko secara dini karena hanya mengandalkan atribut demografi statis dan mengabaikan dinamika perilaku mahasiswa. Penelitian ini bertujuan mengembangkan model deteksi dini keterlambatan lulus yang berfokus pada fitur perilaku keuangan dan tren akademik pada *dataset* berskala kecil dan tidak seimbang di Universitas PGRI Mahadewa Indonesia menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). Tantangan berupa ketidakseimbangan data (*imbalanced data*) dengan *baseline accuracy* sebesar 67,61% diatasi melalui teknik *Synthetic Minority Over-sampling Technique* (SMOTE). Hasil eksperimen menunjukkan performa model yang andal dengan rata-rata F1-Score sebesar 81,56% dan Recall 80,81%, yang membuktikan efektivitas sistem sebagai solusi dalam meminimalkan kesalahan deteksi pada mahasiswa berisiko. Analisis *Feature Importance* mengungkapkan bahwa variabel perilaku dinamis lebih dominan dibandingkan faktor demografi statis. IPS Semester 4 (Gain 0,269) dan Frekuensi Tunggalan (Gain 0,151) ditemukan sebagai prediktor paling signifikan. Temuan ini mengonfirmasi bahwa performa akademik di fase menengah dan kedisiplinan administrasi keuangan merupakan indikator kritis kelulusan. Penelitian ini merekomendasikan penerapan Sistem Deteksi Hibrida pada akhir semester 4 untuk memberikan intervensi tepat sasaran bagi mahasiswa di “Zona Merah”.

Kata Kunci: *Educational Data Mining*, Kelulusan Tepat Waktu, XGBoost, SMOTE, Perilaku Keuangan.

Abstract—Timely graduation is a crucial indicator for the sustainability of higher education institutions. However, conventional monitoring methods often fail to detect at-risk students early because they rely solely on static demographic attributes and ignore the dynamics of student behavior. This study aims to develop an early detection model for delayed graduation focusing on financial behavior features and academic trends on a small-scale and imbalanced dataset at Universitas PGRI Mahadewa Indonesia using the *Extreme Gradient Boosting* (XGBoost) algorithm. The challenge posed by data imbalance, characterized by a baseline accuracy of 67.61%, was addressed using the *Synthetic Minority Over-sampling Technique* (SMOTE). Experimental results demonstrate robust model performance, achieving an average F1-Score of 81.56% and a Recall of 80.81%, which evidences the system's effectiveness as a solution in minimizing detection errors regarding at-risk students. Feature Importance analysis reveals that dynamic behavioral variables significantly outweigh static demographic factors. Specifically, the 4th Semester GPA (Gain 0.269) and Tuition Arrears Frequency (Gain 0.151) were identified as the most significant predictors. These findings confirm that mid-stage academic performance and financial administrative discipline are critical indicators of graduation. This study recommends implementing a Hybrid Detection System at the end of the 4th semester to facilitate targeted interventions for students falling into the 'Red Zone'.

Keywords: Educational Data Mining, Timely Graduation, XGBoost, SMOTE, Financial Behavior.

1. PENDAHULUAN

Keberlanjutan dan kredibilitas sebuah institusi pendidikan tinggi di era modern sangat bergantung pada efisiensi *output* yang dihasilkan, di mana salah satu indikator kinerja utamanya adalah ketepatan waktu kelulusan mahasiswa. Dalam konteks kebijakan nasional, standar ini telah diatur secara ketat. Berdasarkan Permendikti Saintek No. 39 Tahun 2025 [1], perguruan tinggi diwajibkan untuk merancang kurikulum yang memungkinkan mahasiswa mencapai kompetensi lulusan sebelum batas waktu studi yang ditetapkan. Kepatuhan terhadap standar ini tidak hanya bersifat administratif, tetapi juga berdampak langsung pada penilaian eksternal institusi. Badan Akreditasi Nasional Perguruan Tinggi (BAN-PT), melalui instrumen IAPS 4.0, menempatkan persentase kelulusan tepat waktu sebagai komponen penilaian berbobot tinggi yang secara signifikan menentukan peringkat akreditasi program studi, sebagaimana tertuang dalam Peraturan Badan Akreditasi Nasional Perguruan Tinggi Nomor 5 Tahun 2019 [2]. Peringkat akreditasi ini pada akhirnya menjadi cerminan kualitas institusi di mata masyarakat dan calon mahasiswa.

Dari perspektif mahasiswa, kegagalan menyelesaikan studi tepat waktu khususnya melebihi delapan semester memiliki konsekuensi yang fatal, baik secara sosial maupun finansial. Studi yang dilakukan oleh Herbaut & Geven [3] menunjukkan bahwa faktor keuangan sangat berpengaruh pada kemungkinan mahasiswa untuk putus kuliah (*drop out*). Risiko ini semakin kritis bagi mahasiswa penerima beasiswa, seperti Kartu Indonesia Pintar (KIP) Kuliah. Mengacu pada Pedoman Pendaftaran KIP Kuliah 2025 [4], pendanaan beasiswa dibatasi secara ketat hanya untuk maksimal delapan semester. Jika mahasiswa melampaui batas ini, mereka harus menanggung biaya pendidikan secara mandiri, yang sering kali menjadi beban tak tertanggung dan memicu tingginya angka putus

kuliah. Oleh karena itu, kemampuan institusi untuk mengidentifikasi potensi keterlambatan sejak dini bukan sekadar kebutuhan administratif, melainkan strategi mitigasi risiko yang krusial.

Tantangan nyata terkait isu ini teridentifikasi di Universitas PGRI Mahadewa Indonesia (UPMI Bali), khususnya pasca-merger. Data historis angkatan 2020 dan 2021 mencatat tingkat kelulusan tidak tepat waktu mencapai 32,39%. Tingginya angka ini mengindikasikan kegagalan metode pemantauan konvensional yang hanya mengandalkan Indeks Prestasi Kumulatif (IPK). Di sinilah peran *Educational Data Mining* (EDM) menjadi sangat relevan. Namoun dan Alshantqi [5] menjelaskan bahwa EDM mampu menyingkap pola tersembunyi dari perilaku belajar mahasiswa yang sering kali luput dari pengamatan manual. Secara fundamental, EDM bertujuan untuk mengubah data mentah dari sistem pendidikan menjadi informasi yang berguna bagi pendidik dan administrator [6], [7]. Dengan EDM, institusi dapat beralih dari pendekatan reaktif ke pendekatan proaktif berbasis data.

Namun, penerapan EDM di tingkat institusi sering kali terhambat oleh karakteristik data yang berskala kecil dan tidak seimbang (*imbalanced data*). Dalam situasi seperti ini, penerapan algoritma standar tanpa penyesuaian sangat berisiko. Vabalas dkk. [8] memperingatkan bahwa penggunaan *machine learning* pada sampel terbatas dapat menyebabkan bias yang signifikan dan menghasilkan akurasi semu, di mana model seolah-olah berkinerja baik padahal hanya memprediksi kelas mayoritas.

Selain masalah data, terdapat kesenjangan (*gap*) mendasar pada pemilihan fitur prediktor dalam penelitian-penelitian terdahulu. Mayoritas penelitian EDM cenderung berfokus pada atribut demografi statis dan nilai semester awal, sebagaimana dilakukan oleh Hermawati [9]. Walaupun beberapa studi telah mencoba memasukkan faktor ekonomi, variabel yang digunakan umumnya terbatas pada data proksi yang bersifat pasif saat pendaftaran, seperti 'Penghasilan Orang Tua' atau 'Status Pekerjaan Orang Tua' dalam studi Pawitra, Hung, dan Jati [10]. Padahal, tinjauan literatur menunjukkan bahwa pemilihan fitur yang tepat adalah kunci utama dalam meningkatkan akurasi prediksi keberhasilan akademik [11]. Pendekatan pasif ini memiliki kelemahan fundamental karena orang tua dengan profil penghasilan tinggi tidak menjamin kelancaran administrasi keuangan mahasiswa secara *real-time*. Seorang mahasiswa bisa saja memiliki latar belakang ekonomi mampu, namun memiliki perilaku administrasi yang buruk (sering menunggak), yang secara langsung mencerminkan penurunan komitmen studi. Oleh karena itu, untuk mendapatkan prediksi yang akurat, diperlukan pergeseran paradigma evaluasi. Dari sekadar melihat atribut demografi saat pendaftaran, menjadi pemantauan tren akademik di fase menengah dan observasi perilaku keuangan yang dinamis secara berkelanjutan. Kedua elemen inilah yang menjadi inti permasalahan sekaligus solusi yang dieksplorasi dalam penelitian ini.


Untuk mengatasi tantangan data kecil dan ketidakseimbangan kelas tersebut, penelitian ini mengembangkan model deteksi dini menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). Algoritma ini dipilih karena memiliki mekanisme regularisasi yang terbukti lebih tahan terhadap gangguan (*noise*) dan *overfitting* pada data kecil dibandingkan model tunggal lainnya, sebagaimana dijelaskan oleh Chen [12] serta Grinsztajn, Oyallon, dan Varoquaux [13]. Selanjutnya, untuk menangani ketidakseimbangan data (rasio 1:2,09), model dioptimasi dengan teknik *Synthetic Minority Over-sampling Technique* (SMOTE). Teknik ini, yang diperkenalkan oleh Chawla dkk. [14] dan divalidasi efektivitasnya oleh Putri dan Rachmatika [15], bekerja dengan meningkatkan sensitivitas deteksi pada kelas minoritas melalui pembangkitan data sintetis.

Merespons celah tersebut, penelitian ini menawarkan kebaruan (*novelty*) melalui pemanfaatan variabel perilaku finansial yang bersifat aktif dan dinamis, yaitu Frekuensi Tunggakan. Berbeda dengan penelitian Putra, Prasetya, dan Mayadi [16] yang menggunakan data publik global dengan fitur makroekonomi umum, maupun studi lain yang bergantung pada proksi ekonomi pasif, penelitian ini mengekstrak rekam jejak perilaku administratif sesungguhnya dari data internal institusi. Hipotesis yang diajukan adalah bahwa pengintegrasian perilaku finansial aktif ini bersama Performa Akademik Fase Menengah (semester 3 dan 4) merupakan indikator yang jauh lebih jujur dan kuat dalam memprediksi kelulusan dibandingkan sekadar atribut demografi statis saat awal masuk. Tujuan akhirnya adalah menyediakan landasan empiris bagi manajemen kampus untuk merancang intervensi yang tepat sasaran sebelum mahasiswa memasuki semester akhir.

2. METODOLOGI PENELITIAN

2.1. Alur Penelitian

Penelitian ini dilaksanakan melalui serangkaian tahapan sistematis untuk memastikan validitas model prediksi pada dataset terbatas. Alur penelitian dimulai dari pengumpulan data hingga evaluasi performa model dan analisis fitur. Secara visual, tahapan penelitian digambarkan dalam Gambar 1 berikut:



Gambar 1. Diagram Alir (Flowchart) Tahapan Penelitian

Tahapan detail dari alur di atas dijelaskan sebagai berikut:

1. **Pengumpulan Data (Data Acquisition):** Mengambil data mentah dari pangkalan data Sistem Informasi Akademik (SIADAD) Universitas PGRI Mahadewa Indonesia.
2. **Pra-pemrosesan Data (Data Pre-processing):** Meliputi pembersihan data (*data cleaning*) dengan menghapus entri yang tidak lengkap (*listwise deletion*), seleksi sampel menggunakan teknik *Purposive Sampling*, serta pengujian multikolinearitas melalui matriks korelasi.
3. **Pembagian & Penanganan Data:** Data dibagi menggunakan *Stratified 10-Fold Cross-Validation*. Pada setiap iterasi, teknik SMOTE (*Synthetic Minority Over-sampling Technique*) diterapkan khusus pada data latih untuk menyeimbangkan kelas tanpa memicu kebocoran data (*data leakage*), sementara data uji dibiarkan asli.
4. **Pemodelan & Komparasi (Modeling & Comparison):** Pembangunan model prediksi dan pengujian perbandingan kinerja antara algoritma *Extreme Gradient Boosting* (XGBoost) yang dioptimasi melalui *Hyperparameter Tuning* dengan *Grid Search*, dengan algoritma pembanding yaitu *Random Forest*, *Decision Tree*, dan *Logistic Regression*.
5. **Evaluasi & Analisis:** Pengujian performa menggunakan metrik *Recall*, *Precision*, *F1-Score*, dan evaluasi indikasi *overfitting* (perbandingan akurasi *Training vs Testing*), dilanjutkan dengan analisis *Feature Importance* serta interpretasi *SHapley Additive exPlanations* (SHAP) untuk menentukan variabel dominan dan arah dampaknya.

2.2. Sumber Data dan Populasi

Data penelitian bersumber dari data historis mahasiswa jenjang Sarjana (S-1) angkatan 2020 dan 2021. Populasi target difilter menggunakan kriteria eksklusi ketat: mahasiswa jalur Rekognisi Pembelajaran Lampau (RPL), mahasiswa pindahan, dan mahasiswa yang *Drop Out* sebelum semester ke-4 tidak diikutsertakan. Setelah proses pembersihan data, diperoleh total sampel bersih sebanyak 707 data mahasiswa.

Mengingat penelitian ini menggunakan data historis akademik dan finansial, prosedur pengumpulan data dilakukan dengan mematuhi protokol etika perlindungan privasi. Seluruh data mentah yang diekstrak dari pangkalan data institusi telah melalui proses anonimisasi (*data anonymization*). Atribut identitas personal, seperti Nama Mahasiswa dan Nomor Induk Mahasiswa (NIM), telah dihapus secara permanen sebelum tahapan pra-pemrosesan (*pre-processing*) dimulai. Selain itu, akses dan pemanfaatan *dataset* ini telah memperoleh persetujuan (*ethical approval*) dari pihak otoritas Universitas PGRI Mahadewa Indonesia, dengan ketentuan bahwa data tersebut digunakan secara eksklusif untuk keperluan riset pengembangan sistem peringatan dini institusi dan hasil prediksi tidak digunakan untuk mendiskriminasi mahasiswa secara individual.

Berdasarkan analisis distribusi kelas, ada karakteristik data yang sangat tidak seimbang (*imbalanced*), dengan hanya 229 siswa (32,39%) yang Lulus Tidak Tepat Waktu dan 478 siswa (67,61%) yang Lulus Tepat Waktu. Rasio ketidakseimbangan sebesar 1:2,09 ini dapat menyebabkan bias mayoritas pada model prediksi.

2.3. Variabel Penelitian

Penelitian ini menggunakan satu variabel target dan dua belas variabel prediktor (fitur) yang dikelompokkan ke dalam tiga dimensi utama:

a. **Variabel Dependen (Label):** Status Kelulusan, yang bersifat biner:

1. *Kelas 0 (Tepat Waktu):* Masa studi ≤ 8 semester.
2. *Kelas 1 (Tidak Tepat Waktu):* Masa studi > 8 semester .

b. **Variabel Independen (Fitur/Atribut):**

Tabel 1. Variabel Independen (Fitur)

Dimensi	Nama Variabel (Fitur)	Definisi / Keterangan
Akademik	IPS Semester 1 s.d. 4	Nilai Indeks Prestasi Semester mahasiswa dari semester 1 hingga 4.
	Delta IPS	Selisih antara nilai semester akhir (Semester 4) dan semester awal (Semester 1) untuk melihat tren performa.
	Kelompok Keilmuan	Kategori bidang studi atau program studi mahasiswa.
Perilaku Keuangan	Frekuensi Tunggakan	Akumulasi jumlah semester di mana mahasiswa terdata mengalami keterlambatan atau kegagalan pembayaran biaya pendidikan melewati tenggat waktu yang ditetapkan kampus selama 4 semester pertama. Skala diukur dari 0 hingga 4: nilai 0 merepresentasikan kedisiplinan penuh (tidak pernah menunggak di semester 1 s.d. 4), sedangkan nilai 4 menunjukkan mahasiswa berulang kali menunggak di setiap semester pada fase tersebut.
	Status Beasiswa	Status penerimaan beasiswa mahasiswa
Demografi	Jenis Kelamin	Atribut biologis mahasiswa (Laki-laki/Perempuan).
	Usia Masuk	Usia mahasiswa saat pertama kali mendaftar.
	Asal Sekolah	Jenis sekolah menengah asal (SMA/SMK/MA).
	Kategori Wilayah	Asal daerah tempat tinggal mahasiswa.

2.4. Penanganan *Imbalanced Data* dengan SMOTE

Untuk mengatasi masalah ketidakseimbangan kelas yang dapat menurunkan sensitivitas model terhadap mahasiswa berisiko, penelitian ini menerapkan teknik *Synthetic Minority Over-sampling Technique* (SMOTE). Teknik yang diperkenalkan oleh Chawla dkk. [14] ini bekerja dengan mensintesis sampel baru untuk kelas minoritas berdasarkan prinsip *K-Nearest Neighbors*, bukan sekadar menduplikasi data lama.

Penerapan SMOTE dalam penelitian ini dilakukan secara hati-hati untuk mencegah kebocoran data (*data leakage*). Sebagaimana disarankan dalam praktik terbaik penambangan data, SMOTE hanya diterapkan pada data latih (*training set*) di setiap lipatan pengujian, sedangkan data uji (*testing set*) dibiarkan tetap asli. Pendekatan ini sejalan dengan penelitian Putri dan Rachmatika [15], yang membuktikan bahwa SMOTE efektif meningkatkan akurasi deteksi pada kelas minoritas tanpa mengorbankan validitas pengujian.

Algoritma dan Skenario Pengujian

Model klasifikasi dibangun menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). Algoritma ini dipilih berdasarkan studi Chen [12] yang menonjolkan efisiensi komputasi dan skalabilitasnya. Selain itu, Grinsztajn, Oyallon, dan Varoquaux [13] menekankan bahwa model berbasis *tree* seperti XGBoost sering kali mengungguli *deep learning* pada data tabular, terutama karena adanya mekanisme regularisasi yang mencegah *overfitting*. Optimasi model dilakukan melalui *Grid Search* untuk menemukan parameter terbaik. Konfigurasi final yang digunakan dapat dilihat pada tabel 2.

Tabel 2. Hasil Optimasi Hyperparameter (Grid Search)

Parameter	Nilai Optimal	Fungsi Utama
Learning Rate	0,1	Mengontrol bobot kontribusi setiap pohon baru untuk mencegah <i>overfitting</i> .
Max Depth	7	Batas kedalaman pohon; nilai 7 menunjukkan model menangkap interaksi fitur yang cukup kompleks.
Gamma	0,1	Parameter regularisasi untuk mengontrol pemecahan simpul (<i>split</i>); semakin tinggi nilainya, model semakin konservatif.
N_Estimators	100	Jumlah total pohon keputusan yang dibangun dalam <i>ensemble</i> .
Subsample	0,8	Rasio sampel data yang digunakan untuk melatih setiap pohon (mencegah <i>overfitting</i>).

Validasi model menggunakan skema *Stratified 10-Fold Cross-Validation*. Metode ini membagi dataset menjadi 10 bagian dengan proporsi kelas yang terjaga (stratifikasi) di setiap bagiannya. Penggunaan validasi silang ini sangat krusial pada dataset berskala kecil untuk menghindari bias estimasi, sebagaimana diperingatkan oleh Vabalas dkk. [8], yang menyatakan bahwa validasi pada sampel terbatas rentan menghasilkan akurasi yang tidak stabil jika tidak dilakukan secara iteratif. Meskipun Precision tetap diperhitungkan sebagai komponen pembentuk F1-Score, prioritas utama evaluasi dititikberatkan pada Recall untuk memastikan sistem mampu meminimalisir False Negative (kegagalan mendeteksi mahasiswa yang terlambat lulus), serta F1-Score sebagai indikator keseimbangan model secara keseluruhan.

2.5. Evaluasi Model

Metrik evaluasi difokuskan pada *Recall*, *Precision*, dan *F1-Score*. Mengingat karakteristik data yang tidak seimbang, akurasi global sering kali bias ke kelas mayoritas. Oleh karena itu, performa model diukur berdasarkan komponen *Confusion Matrix*, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) dengan formulasi matematis sebagai berikut:

a. Recall (Sensitivitas)

Metrik ini mengukur kemampuan model dalam menemukan kembali seluruh kejadian positif (mahasiswa terlambat). Dalam konteks deteksi dini, nilai *Recall* yang rendah sangat berbahaya karena berarti membiarkan mahasiswa berisiko lolos tanpa terdeteksi (*False Negative*).

$$Recall = \frac{TP}{(TP + FN)} \times 100\% \quad (1)$$

b. Precision (Presisi)

Mengukur seberapa akurat model saat menyatakan seorang mahasiswa akan terlambat.

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (2)$$

c. F1-Score

Merupakan *harmonic mean* dari *Precision* dan *Recall*. Metrik ini memberikan gambaran performa yang lebih objektif pada *imbalanced dataset* dibandingkan akurasi biasa.


$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan analisis komprehensif terhadap kinerja model prediksi yang dikembangkan serta interpretasi mendalam mengenai faktor-faktor determinan yang memengaruhi ketepatan waktu kelulusan

mahasiswa. Diskusi dibagi menjadi tiga sub-bab utama: evaluasi kinerja algoritma, analisis dominansi fitur (*feature importance*), dan implikasi manajerial bagi institusi.

Sebelum membangun dan mengevaluasi model, tahap pra-pemrosesan memverifikasi kelayakan 12 variabel prediktor melalui analisis korelasi. Hasil visualisasi matriks korelasi menunjukkan bahwa sebagian besar variabel independen tidak memiliki redundansi. Korelasi positif tertinggi yang ditemukan adalah sebesar 0,84 antara variabel IPS Semester 3 dan IPS Semester 4, disusul korelasi 0,80 antara IPS Semester 1 dan 2. Angka ini merupakan hal yang rasional mengingat sifat sekuensial dari performa akademik mahasiswa. Karena tidak ada nilai korelasi yang menyentuh ambang batas multikolinearitas ekstrem (misalnya $r > 0,90$), seluruh fitur dinilai layak dipertahankan. Selain itu, algoritma XGBoost yang digunakan sebagai pemodelan utama merupakan model berbasis *tree* yang secara inheren kebal terhadap multikolinearitas dan mampu menyeleksi fitur secara otomatis selama proses pemecahan simpul (*node splitting*) berlangsung. Hasil lengkap dari matriks korelasi dapat dilihat pada gambar 2.




Gambar 2. Matriks Korelasi Antar Variabel

3.1. Evaluasi Kinerja Model: XGBoost dan Efektivitas SMOTE

Langkah pertama dalam mengevaluasi keberhasilan penelitian ini adalah membandingkan kinerja model *Extreme Gradient Boosting* (XGBoost) yang diusulkan terhadap *baseline accuracy*. Berdasarkan distribusi data awal, diketahui bahwa jika sebuah sistem hanya menebak seluruh mahasiswa akan lulus tepat waktu (tanpa mempelajari pola apa pun), sistem tersebut akan menghasilkan akurasi sebesar 67,61% (ZeroR). Angka ini menjadi ambang batas bawah yang harus dilampaui. Namun, akurasi semata bukanlah metrik yang bijak dalam kasus data tidak seimbang (*imbalanced dataset*), karena model dapat terjebak dalam bias mayoritas—memprediksi semua benar pada kelas mayoritas tetapi gagal total mendeteksi kelas minoritas (mahasiswa terlambat).

Penerapan teknik *Synthetic Minority Over-sampling Technique* (SMOTE) pada data latih terbukti berhasil mengatasi tantangan tersebut. Sebagaimana dijelaskan oleh Chawla dkk. [14], SMOTE bekerja dengan memperluas wilayah keputusan kelas minoritas, sehingga algoritma tidak lagi mengabaikan data yang jumlahnya sedikit. Hasil eksperimen menggunakan *10-Fold Cross-Validation* menunjukkan bahwa model XGBoost mampu mencapai rata-rata akurasi global sebesar 88,12%, melampaui *baseline* secara signifikan. Namun, dalam pemodelan *machine learning* yang menggunakan *dataset* berskala kecil, algoritma *ensemble* berbasis pohon (seperti XGBoost) rentan terhadap risiko *overfitting* model menghafal data latih dengan sangat baik namun gagal menggeneralisasi data baru. Untuk meninjau risiko ini, penelitian menganalisis selisih kinerja antara fase pelatihan (*training*) dan pengujian (*testing*) pada setiap lipatan validasi silang. Hasil pengujian iteratif (*10-Fold CV*) menunjukkan bahwa rata-rata akurasi model pada data latih (yang telah diseimbangkan dengan SMOTE) mencapai 99,99%, sementara rata-rata akurasi pada data uji berada di angka 88,12%. Terdapat selisih (*gap*) performa yang mengindikasikan adanya kecenderungan *overfitting* parsial pada model. Mengingat ukuran sampel yang terbatas (707 entri), fenomena ini merupakan batasan komputasional yang lazim terjadi. Meskipun demikian, evaluasi per lipatan (seperti terlihat pada fluktuasi akurasi uji yang terjaga di rentang 81,69% hingga 92,96%) membuktikan bahwa kinerja prediktif model pada data yang belum pernah dilihat (*unseen data*) tetap stabil dan tidak anjlok secara drastis. Kestabilan kemampuan generalisasi ini merupakan hasil dari penerapan parameter regularisasi pada konfigurasi algoritma, khususnya *gamma* (0,1) dan *subsample* (0,8), yang secara efektif mengerem laju *overfitting* agar tidak merusak fungsi deteksi dini sistem. Gambar 3 merepresentasikan hasil akumulasi prediksi dari 10 lipatan

pengujian (*10-Fold Cross Validation*). Visualisasi ini krusial untuk menunjukkan di mana letak kesalahan model secara spesifik.



Gambar 3. *Confusion Matrix Agregat Model XGBoost (10-Fold CV)*

- True Negative (TN):** Model berhasil memprediksi 438 mahasiswa yang faktualnya lulus tepat waktu dengan benar.
- True Positive (TP):** Model berhasil mendeteksi 185 mahasiswa yang faktualnya terlambat lulus.
- False Negative (FN):** Terdapat 44 mahasiswa yang diprediksi tepat waktu, namun kenyataannya terlambat.
- False Positive (FP):** Terdapat 40 mahasiswa yang diprediksi terlambat, namun kenyataannya lulus tepat waktu.

Dari matriks tersebut, metrik *Recall* (Sensitivitas) tercatat sebesar 80,81%. Dalam konteks sistem peringatan dini akademik, *Recall* adalah metrik yang paling kritis. Nilai 80,81% mengindikasikan bahwa dari seluruh populasi mahasiswa yang berisiko terlambat, sistem mampu "menangkap" atau mengidentifikasi lebih dari 80% di antaranya. Kemampuan ini sangat vital untuk mencegah *drop-out*, karena kegagalan mendeteksi risiko (*False Negative*) berarti membiarkan mahasiswa bermasalah tanpa intervensi hingga akhirnya mereka gagal studi. Tingginya nilai ini membuktikan bahwa kombinasi XGBoost dan SMOTE efektif meminimalkan risiko tersebut. Di sisi lain, nilai *Precision* sebesar 83,08% menunjukkan tingkat kepercayaan prediksi. Artinya, ketika sistem memberikan label "Berisiko" pada seorang mahasiswa, probabilitas bahwa mahasiswa tersebut benar-benar akan terlambat adalah sekitar 83%. Meskipun terdapat sejumlah *False Positive* (40 mahasiswa), hal ini dianggap sebagai *trade-off* yang dapat diterima dalam manajemen pendidikan. Memberikan bimbingan konseling kepada mahasiswa yang sebenarnya aman (*False Positive*) jauh lebih baik daripada membiarkan mahasiswa berisiko lolos tanpa terdeteksi.

Keseimbangan antara kemampuan deteksi (*Recall*) dan ketepatan prediksi (*Precision*) tercermin dalam nilai *F1-Score* sebesar 81,56%. Nilai ini menegaskan bahwa model memiliki performa yang robust dan tidak bias ke salah satu kelas. Capaian ini sejalan dengan tinjauan meta-analisis yang dilakukan oleh Burgos dkk. [17], yang menyimpulkan bahwa teknik *ensemble learning* (seperti XGBoost) secara konsisten menunjukkan performa prediksi yang lebih superior dibandingkan algoritma tunggal dalam pemodelan kinerja siswa selama satu dekade terakhir.

Tabel 3. Rekapitulasi Metrik Evaluasi Model (Rata-rata 10-Fold)

Metrik Evaluasi	Capaian (%)	Interpretasi Singkat
Accuracy	88,12%	Ketepatan prediksi secara global.
Precision	83,08%	Tingkat kepercayaan saat sistem memprediksi terlambat.
Recall	80,81%	Kemampuan sistem menemukan mahasiswa yang berisiko (Sensitivitas).
F1-Score	81,56%	Keseimbangan harmonis antara Precision dan Recall.

Untuk menguji keandalan XGBoost, penelitian ini melakukan uji komparatif dengan tiga algoritma *machine learning* lainnya: *Random Forest* (RF), *Decision Tree* (DT), dan *Logistic Regression* (LR). Seluruh algoritma dilatih menggunakan konfigurasi yang sama (*Stratified 10-Fold Cross-Validation* dan SMOTE). Hasil komparasi performa disajikan pada tabel 4.

Tabel 4. Perbandingan Kinerja XGBoost dengan Algoritma Klasifikasi Lainnya

Algoritma	Accuracy	Precision	Recall (Sensitivitas)	F1-Score
XGBoost (Usulan)	88,12%	83,08%	80,81%	81,56%
Random Forest	88,96%	85,70%	79,90%	82,39%
Decision Tree	82,74%	72,67%	77,69%	74,62%
Logistic Regression	87,41%	82,01%	79,49%	80,31%


Keterangan: Seluruh model dievaluasi menggunakan data latih yang telah diseimbangkan dengan SMOTE.

Merujuk pada tabel 4, hasil komparasi menunjukkan dinamika performa yang menarik. Algoritma *Random Forest* secara marginal mengungguli XGBoost pada metrik Akurasi global (88,96%) dan F1-Score (82,39%). Namun, **XGBoost mencatat performa tertinggi pada metrik *Recall*** sebesar 80,81%, dibandingkan RF (79,90%) maupun model lainnya.

Dalam konteks sistem peringatan dini akademik, metrik *Recall* (Sensitivitas) memegang peranan yang jauh lebih krusial dibandingkan metrik lainnya. Kegagalan sistem dalam mendeteksi mahasiswa yang sebenarnya berisiko terlambat lulus (*False Negative*) membawa konsekuensi manajerial yang jauh lebih fatal (risiko *drop-out*) dibandingkan sistem yang terlalu protektif memprediksi keterlambatan pada mahasiswa yang sebenarnya aman (*False Positive*). Oleh karena itu, XGBoost tetap dipertahankan dan diusulkan sebagai model terbaik dalam penelitian ini karena terbukti paling sensitif dalam 'menangkap' kelompok mahasiswa kelas minoritas yang berisiko, selaras dengan tujuan utama pencegahan keterlambatan studi.


3.2. Analisis Determinan Faktor Kelulusan (*Feature Importance*)

Setelah memastikan validitas model, fokus analisis beralih pada "kotak hitam" algoritma untuk memahami variabel apa yang sebenarnya menjadi penentu kelulusan. Analisis *Feature Importance* berdasarkan skor *Information Gain* memberikan wawasan empiris yang membantah beberapa asumsi konvensional dan mengonfirmasi hipotesis penelitian mengenai pentingnya perilaku dinamis.



Gambar 4. Peringkat Dominansi Fitur Berdasarkan Information Gain

Meskipun skor *Information Gain* berhasil mengidentifikasi variabel yang paling berpengaruh, metrik tersebut memiliki batasan karena tidak mampu menjelaskan arah dampak dari masing-masing fitur terhadap hasil prediksi. Untuk menutupi kelemahan tersebut, penelitian ini menerapkan metode interpretasi *SHapley Additive exPlanations* (SHAP).



Gambar 5. Distribusi Dampak Fitur terhadap Probabilitas Keterlambatan Lulus (*SHAP Summary Plot*)

Berdasarkan *SHAP Summary Plot* (Gambar 5), setiap titik merepresentasikan satu observasi mahasiswa. Posisi titik di sumbu horizontal (*SHAP value*) menunjukkan arah dampak fitur: nilai *SHAP* positif (ke arah kanan) mendorong prediksi menuju kelas 'Terlambat Lulus', sedangkan nilai negatif (ke arah kiri) mendorong menuju kelas 'Tepat Waktu'. Warna titik merepresentasikan nilai asli dari atribut tersebut (merah berarti nilai tinggi, biru berarti nilai rendah).

Analisis interpretasi lokal ini mengungkap pola perilaku prediktif yang sangat tegas. Pada variabel IPS Semester 4, titik-titik berwarna biru (mengindikasikan nilai IPS rendah) secara konsisten menyebar jauh di area *SHAP* positif. Hal ini mengonfirmasi empiris bahwa performa akademik yang memburuk di pertengahan studi secara drastis mendorong probabilitas keterlambatan. Sebaliknya, pada variabel Frekuensi Tunggakan, titik-titik berwarna merah (mengindikasikan frekuensi menunggak yang tinggi) memanjang secara terpusat ke arah area kanan (*SHAP* positif).

Pendekatan visual *SHAP* ini memvalidasi secara utuh bahwa sistem peringatan dini tidak cukup jika hanya mengandalkan data demografi statis. Sebagaimana yang terlihat pada bagian paling bawah plot (Gambar 5), variabel seperti Asal Sekolah, Jenis Kelamin, dan Status Beasiswa hanya menumpuk rapat di sekitar garis vertikal nol. Hal ini menegaskan bahwa faktor-faktor demografi tersebut secara praktis tidak memiliki dampak atau daya dorong yang berarti terhadap risiko kelulusan mahasiswa.

a. Fenomena Recency Effect pada Performa Akademik

Temuan paling menonjol dari penelitian ini adalah dominansi variabel akademik fase menengah. IPS Semester 4 menempati peringkat pertama sebagai fitur paling berpengaruh dengan skor *Gain* 0,269, diikuti oleh IPS Semester 3 dengan skor 0,123. Sebaliknya, IPS Semester 1 memiliki pengaruh yang jauh lebih kecil (*Gain* 0,043) dan berada di peringkat bawah.

Temuan ini mengindikasikan adanya fenomena *Recency Effect*, di mana performa terkini mahasiswa memiliki daya prediksi yang jauh lebih kuat dibandingkan performa masa lalu (awal masuk). Hal ini sejalan dengan temuan Hermawati [9], yang juga menemukan bahwa informasi akademik pada tahun kedua lebih prediktif. Mahasiswa tahun pertama sering kali masih dalam fase euforia atau adaptasi, di mana nilai mereka mungkin belum mencerminkan ketahanan akademik yang sebenarnya. Namun, ketika memasuki semester 3 dan 4, beban kurikulum mulai meningkat dan seleksi alamiah mulai terjadi. Penurunan nilai pada fase ini sering kali menjadi indikator awal dari kejenuhan (*burnout*) atau ketidakmampuan mengikuti standar akademik program studi. Oleh karena itu, penelitian ini berargumen bahwa memantau tren nilai di semester 4 jauh lebih efektif daripada hanya melihat IPK kumulatif yang mungkin masih terdongkrak oleh nilai-nilai mata kuliah dasar di semester awal.

b. Frekuensi Tunggakan sebagai Indikator Perilaku Aktif

Salah satu kontribusi *novelty* terbesar dari penelitian ini adalah validasi terhadap variabel Frekuensi Tunggakan yang menempati peringkat kedua terpenting dengan skor *Gain* 0,151. Variabel ini secara signifikan mengalahkan fitur demografi dan akademik awal.

Temuan ini memberikan kritik konstruktif terhadap penelitian-penelitian sebelumnya, seperti studi oleh Pawitra, Hung, dan Jati [10], yang cenderung menggunakan data ekonomi pasif seperti "Penghasilan Orang Tua" atau "Status Pekerjaan Orang Tua". Data pasif tersebut memiliki kelemahan: orang tua dengan penghasilan tinggi belum tentu menjamin kelancaran pembayaran kuliah anaknya (bisa karena faktor prioritas pengeluaran atau masalah komunikasi keluarga). Sebaliknya, "Frekuensi Tunggakan" adalah data perilaku aktif yang mencerminkan realitas likuiditas dan komitmen mahasiswa secara *real-time*.

Tingginya pengaruh tunggakan terhadap keterlambatan kelulusan dapat dijelaskan melalui perspektif psikologis dan administratif. Secara psikologis, mahasiswa yang memiliki tunggakan cenderung mengalami beban mental dan rasa malu, yang dapat menurunkan motivasi mereka untuk hadir di kampus atau mengikuti ujian. Secara administratif, banyak institusi menerapkan aturan pemblokiran KRS atau penundaan ujian bagi mahasiswa yang menunggak, yang secara teknis langsung menghambat progres akademik mereka. Korelasi linear antara ketidaktertiban administrasi keuangan dan risiko akademik ini menegaskan bahwa masalah finansial dan akademik tidak dapat dipisahkan dalam manajemen kemahasiswaan. Hal ini memperkuat studi Breier [18] yang menyatakan bahwa kesulitan finansial sering kali menjadi pemicu utama keputusan mahasiswa untuk berhenti kuliah di tengah jalan.

c. Irrelevansi Faktor Demografi

Analisis *Feature Importance* juga menunjukkan bahwa variabel demografi seperti Jenis Kelamin (*Gain* 0,052), Kategori Wilayah (*Gain* 0,057), dan Asal Sekolah memiliki kontribusi yang sangat rendah terhadap prediksi model.

Hasil ini memberikan implikasi positif namun juga peringatan. Positifnya, hal ini menunjukkan bahwa sistem pendidikan di UPMI cukup inklusif; tidak ada bias gender atau bias kedaerahan yang secara sistemik menyebabkan kelompok tertentu lebih sulit lulus. Peringatannya adalah bagi manajemen kampus untuk berhenti menggunakan stereotip demografi dalam memprediksi risiko. Asumsi bahwa "mahasiswa dari wilayah X pasti rajin" atau "lulusan SMK pasti kesulitan di teori" tidak terbukti secara data. Risiko kelulusan bersifat individual dan dinamis, bergantung pada bagaimana mahasiswa tersebut menjalani proses perkuliahannya, bukan dari mana mereka berasal.

3.3. Diskusi dan Implikasi Manajerial: Menuju Sistem Deteksi Hibrida

Berdasarkan sintesis dari evaluasi kinerja model dan analisis fitur, penelitian ini merumuskan rekomendasi strategis bagi Universitas PGRI Mahadewa Indonesia (UPMI Bali). Paradigma lama yang bersifat reaktif menunggu hingga mahasiswa semester akhir bermasalah baru bertindak harus ditinggalkan. Sebagai gantinya, diusulkan penerapan Sistem Deteksi Hibrida (*Hybrid Detection System*) yang dioperasionalkan pada akhir Semester 4.

Sistem Hibrida ini dirancang berdasarkan temuan bahwa kombinasi penurunan akademik dan masalah keuangan adalah prediktor terkuat kegagalan studi. Mekanisme kerja yang disarankan adalah sebagai berikut:

1. **Tahap Skrining Akademik:** Pada akhir semester 4, sistem secara otomatis memfilter mahasiswa yang memiliki IPS (Indeks Prestasi Semester) Semester 4 di bawah ambang batas tertentu, atau mereka yang mengalami penurunan IPS drastis (Delta IPS negatif besar) dibandingkan semester sebelumnya. Ini adalah saringan pertama untuk mendeteksi masalah kognitif atau motivasi.
2. **Tahap Skrining Perilaku Keuangan:** Dari kelompok yang terindikasi masalah akademik tersebut, sistem melakukan irisan data dengan database keuangan untuk melihat variabel "Frekuensi Tunggakan". Mahasiswa yang memiliki performa akademik menurun dan memiliki riwayat tunggakan berulang (>2 kali) dikategorikan sebagai "Zona Merah" (Prioritas Tinggi).

Strategi Intervensi Berjenjang Identifikasi hanyalah langkah awal; keberhasilan sistem bergantung pada intervensi yang dilakukan. Untuk mahasiswa di "Zona Merah", pendekatan tunggal tidak akan efektif. Mahasiswa yang nilainya turun karena harus bekerja paruh waktu untuk membayar kuliah tidak akan tertolong hanya dengan "bimbingan belajar". Mereka membutuhkan solusi finansial.

Oleh karena itu, penelitian ini merekomendasikan intervensi terpadu:

1. **Intervensi Akademik:** Dosen Penasihat Akademik (PA) harus melakukan sesi konseling wajib bagi mahasiswa Zona Merah untuk mengevaluasi beban studi dan menyusun ulang rencana studi yang lebih realistis.
2. **Intervensi Finansial:** Biro kemahasiswaan perlu proaktif menawarkan skema bantuan, baik berupa restrukturisasi pembayaran (cicilan), informasi beasiswa retensi, atau peluang kerja paruh waktu di dalam kampus.

Pendekatan ini sejalan dengan pandangan Herbaut & Geven [3] bahwa kendala keuangan adalah pemicu utama *drop-out*. Dengan menyelesaikan akar masalah finansial, beban kognitif mahasiswa dapat berkurang, sehingga mereka dapat kembali fokus pada perbaikan kinerja akademik di semester-semester selanjutnya (Semester 5-8).

Selain itu, temuan ini juga memvalidasi pentingnya integrasi data antardepartemen. Sering kali, data akademik (SIKAD) dan data keuangan berada di "silo" yang terpisah. Penelitian ini membuktikan bahwa penggabungan kedua jenis data ini mutlak diperlukan untuk mendapatkan gambaran utuh mengenai profil risiko mahasiswa.

Sebagai penutup diskusi, meskipun model ini dikembangkan menggunakan data internal UPMI Bali, kerangka kerja metodologisnya penggunaan XGBoost pada data kecil yang diimbangi dengan SMOTE, serta fokus pada fitur perilaku dinamis sangat relevan untuk diadopsi oleh perguruan tinggi swasta lain di Indonesia yang menghadapi karakteristik masalah serupa. Hal ini sesuai dengan saran Vabalas dkk. [8] mengenai pentingnya validasi metode pada sampel terbatas untuk menghindari bias dalam penelitian pendidikan.

4. KESIMPULAN

Penelitian ini membuktikan bahwa algoritma XGBoost yang dioptimasi dengan SMOTE efektif untuk memprediksi ketepatan waktu kelulusan mahasiswa pada dataset kecil dan tidak seimbang di UPMI Bali. Model yang dikembangkan berhasil mengurangi bias kelas mayoritas (baseline accuracy 67,61%) dan menghasilkan performa prediksi yang baik, dengan rata-rata F1-Score 81,56% dan Recall 80,81%. Nilai Recall yang tinggi menunjukkan bahwa model mampu mendeteksi sebagian besar mahasiswa yang berisiko terlambat lulus, sehingga dapat meminimalkan kesalahan identifikasi mahasiswa bermasalah. Hasil analisis Feature Importance menunjukkan bahwa faktor paling berpengaruh bukanlah latar belakang demografis, melainkan variabel perilaku dinamis. IPS Semester 4 menjadi prediktor terkuat (Gain 0,269), diikuti oleh Frekuensi Tunggakan (Gain 0,151). Temuan ini menegaskan bahwa performa akademik pada fase pertengahan studi dan kedisiplinan administrasi keuangan lebih relevan dalam memprediksi keterlambatan kelulusan dibandingkan data statis saat awal masuk kuliah. Secara praktis, penelitian ini merekomendasikan UPMI Bali untuk menerapkan Sistem Deteksi Hibrida yang berfokus pada mahasiswa Zona Merah, khususnya mereka yang mengalami penurunan nilai signifikan pada akhir Semester 4 dan memiliki riwayat tunggakan berulang. Intervensi yang disarankan mencakup bimbingan akademik intensif serta dukungan pembiayaan. Meski demikian, penelitian ini masih memiliki keterbatasan pada cakupan data yang hanya berasal dari satu institusi, dua angkatan, dan 707 sampel. Penelitian selanjutnya disarankan melakukan validasi eksternal serta menambahkan variabel perilaku lain seperti LMS, absensi, pengulangan mata kuliah, organisasi, dan riwayat konseling.

REFERENCES

- [1] *Permendikti Saintek No. 39 Tahun 2025*. 2025. Accessed: Dec. 27, 2025. [Online]. Available: <https://peraturan.bpk.go.id/Details/333967/permendikti-saintek-no-39-tahun-2025>
- [2] *Peraturan Badan Akreditasi Nasional Perguruan Tinggi Nomor 5 Tahun 2019*. 2019. Accessed: Dec. 27, 2025. [Online]. Available: <https://www.banpt.or.id/wp-content/uploads/2019/10/Peraturan-BAN-PT-No.-5-Tahun-2019-Instrumen-APS-1.pdf>
- [3] E. Herbaut and K. Geven, “What works to reduce inequalities in higher education? A systematic review of the (quasi-)experimental literature on outreach and financial aid,” *Res. Soc. Stratif. Mobil.*, vol. 65, p. 100442, Feb. 2020, doi: 10.1016/J.RSSM.2019.100442.
- [4] *Pedoman Pendaftaran KIP Kuliah 2025*. Pusat Pembiayaan dan Asesmen Pendidikan Tinggi Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia, 2025.
- [5] A. Namoun and A. Alshantqi, “Predicting student performance using data mining and learning analytics techniques: A systematic literature review,” Jan. 01, 2021, *MDPI AG*. doi: 10.3390/app11010237.
- [6] R. Baker, “Data mining for education,” *International encyclopedia of education*, vol. 7, no. 3, pp. 112–118, 2010.
- [7] C. Romero and S. Ventura, “Educational Data Mining: A Review of the State of the Art,” *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, vol. 40, pp. 601–618, Dec. 2010, doi: 10.1109/TSMCC.2010.2053532.
- [8] A. Vabalas, E. Gowen, E. Poliakoff, and A. J. Casson, “Machine learning algorithm validation with a limited sample size,” *PLoS One*, vol. 14, no. 11, Nov. 2019, doi: 10.1371/journal.pone.0224365.
- [9] M. Hermawati, “Penerapan Algoritma C4.5 dengan Optimasi Particle Swarm Optimization untuk Prediksi Kelulusan Mahasiswa,” *Faktor Exacta*, vol. 16, no. 3, Oct. 2023, doi: 10.30998/faktorexacta.v16i3.17296.
- [10] M. A. S. Pawitra, H.-C. Hung, and H. Jati, “A Machine Learning Approach to Predicting On-Time Graduation in Indonesian Higher Education,” *Elinvo (Electronics, Informatics, and Vocational Education)*, vol. 9, no. 2, pp. 294–308, Dec. 2024, doi: 10.21831/elinvo.v9i2.77052.
- [11] E. Alyahyan and D. Düstegör, “Predicting academic success in higher education: literature review and best practices,” Dec. 01, 2020, *Springer*. doi: 10.1186/s41239-020-0177-7.
- [12] T. Chen, “XGBoost: A Scalable Tree Boosting System,” *Cornell University*, 2016.
- [13] L. Grinsztajn, E. Oyallon, and G. Varoquaux, “Why do tree-based models still outperform deep learning on typical tabular data?,” in *Advances in Neural Information Processing Systems*, S. Koyejo, S. Mohamed, A. Agarwal, D. Belgrave, K. Cho, and A. Oh, Eds., Curran Associates, Inc., 2022, pp. 507–520. [Online]. Available: https://proceedings.neurips.cc/paper_files/paper/2022/file/0378c7692da36807bdec87ab043cdadc-Paper-Datasets_and_Benchmarks.pdf
- [14] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: synthetic minority over-sampling technique,” *Journal of artificial intelligence research*, vol. 16, pp. 321–357, 2002.
- [15] S. A. Putri and R. Rachmatika, “Penerapan Algoritma Random Forest dan SMOTE untuk Prediksi Risiko Putus Sekolah Siswa Sekolah Menengah Kejuruan,” *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 5, no. 3, pp. 903–910, 2025.
- [16] H. Putra, K. Nasution, and E. Rilvani, “Prediksi Kelulusan Mahasiswa Tepat Waktu Menggunakan Decision Tree: Studi Perbandingan Algoritma Id3 Dan C4. 5,” *Jurnal Media Akademik (JMA)*, vol. 3, no. 7, 2025.
- [17] C. Burgos, M. L. Campanario, D. de la Peña, J. A. Lara, D. Lizcano, and M.-A. Martínez, “Data mining for modeling students’ performance: A tutoring action plan to prevent academic dropout,” *Comput. Electr. Eng.*, vol. 66, pp. 541–556, 2017, [Online]. Available: <https://api.semanticscholar.org/CorpusID:49419679>
- [18] M. Breier, “From ‘financial considerations’ to ‘poverty’: Towards a reconceptualisation of the role of finances in higher education student drop out,” *High. Educ. (Dordr.)*, vol. 60, pp. 657–670, Dec. 2010, doi: 10.1007/s10734-010-9343-5.