

PREDIKSI DROPOUT MAHASISWA MENGGUNAKAN METODE MACHINE LEARNING: TINJAUAN KOMPARATIF ENSEMBLE, DECISION TREE, DAN NEURAL NETWORK

Yudistira Dwi Permana,^{1,*} Efi Rohman², Linda Evan Englista³

¹ Teknik Rekayasa Perangkat Lunak, Politeknik Krakatau.

*Corresponding author: yudisdwi02@gmail.com

Article history

Received:

04-01-2026

Accepted:

25-02-2026

Published:

01-03-2026

Copyright © 2024
Jurnal Manajemen
dan Teknik

Open Access

Abstrak

Dropout mahasiswa merupakan permasalahan serius yang berdampak terhadap kualitas pendidikan tinggi secara global. Penelitian ini menyajikan tinjauan komparatif terhadap berbagai metode machine learning yang telah digunakan untuk memprediksi risiko dropout mahasiswa, meliputi metode ensemble (*AdaBoost*, *XGBoost*, *Random Forest*, *voting heterogen*), *decision tree* (C4.5), dan *Artificial Neural Network* (ANN). Studi ini mengkaji beberapa penelitian terdahulu yang mencakup konteks pembelajaran *blended*, pendidikan teknik, hingga pendidikan dasar dan menengah. Hasil kajian menunjukkan bahwa metode ensemble lanjutan seperti *AdaBoost* dan *XGBoost* konsisten menghasilkan akurasi tertinggi (hingga 97%), diikuti ANN (77,3%), *Random Forest* (75,5%), dan *Decision Tree* (70,1%-86,8%). Fitur yang paling signifikan dalam prediksi dropout meliputi nilai akademik, frekuensi interaksi dengan sistem LMS, kesehatan mental, hubungan mahasiswa-dosen, dan faktor sosial-ekonomi. Penelitian ini menyimpulkan bahwa pemilihan metode perlu disesuaikan dengan karakteristik dataset, ketersediaan fitur, serta kebutuhan interpretabilitas model. Pendekatan *explainable machine learning* (XAI) sangat direkomendasikan agar prediksi dapat dimanfaatkan secara efektif oleh institusi pendidikan.

Kata Kunci: Dropout Mahasiswa, Machine Learning, Ensemble Learning, Decision Tree, Neural Network

Abstract

Student dropout is a serious problem affecting the quality of higher education globally. This study presents a comparative review of machine learning methods used to predict student dropout risk, including ensemble methods (AdaBoost, XGBoost, Random Forest, heterogeneous voting), decision tree (C4.5), and Artificial Neural Network (ANN). The study examines five prior research studies covering blended learning, engineering education, and primary to secondary education contexts. Results indicate that advanced ensemble methods such as AdaBoost and XGBoost consistently achieve the highest accuracy (up to 97%), followed by ANN (77.3%), Random Forest (75.5%), and Decision Tree (70.1%-86.8%). The most significant features for dropout prediction include academic grades, LMS interaction frequency, mental health, student-faculty relationships, and socioeconomic factors. This study concludes that method selection should be tailored to dataset characteristics, feature availability, and interpretability needs. Explainable machine learning (XAI) approaches are strongly recommended to make predictions actionable for educational institutions.

Keywords: Student Dropout, Machine Learning, Ensemble Learning, Decision Tree, Neural Network

1.0 PENDAHULUAN

1.1. Latar Belakang

Dropout atau putus kuliah mahasiswa merupakan fenomena yang kompleks dan menjadi tantangan serius bagi institusi pendidikan tinggi di seluruh dunia. Fenomena ini tidak hanya berdampak negatif bagi mahasiswa secara individual dalam hal prospek karier dan penghasilan, tetapi juga mempengaruhi kualitas pendidikan nasional dan pertumbuhan ekonomi suatu bangsa [9]. Di negara-negara berkembang seperti Brasil, tingkat *dropout* di jenjang pendidikan menengah mencapai lebih dari 10%, sementara di jenjang pendidikan tinggi teknik angkanya bahkan lebih tinggi [13].

Berbagai faktor telah diidentifikasi berkontribusi terhadap keputusan mahasiswa untuk *dropout*, yang dapat dikategorikan menjadi faktor personal (kesehatan, motivasi, kondisi keluarga), faktor internal universitas (hubungan dengan dosen, kurikulum, sistem birokrasi), dan faktor eksternal (kondisi pasar kerja, nilai profesi) [13]. Kerumitan interaksi antar faktor-faktor ini menjadikan prediksi *dropout* sebagai tantangan analitik yang tidak dapat diselesaikan dengan metode statistik konvensional semata.

Dalam satu dekade terakhir, perkembangan pesat bidang *machine learning* (ML) dan *data mining* telah membuka peluang baru untuk menganalisa dan memprediksi risiko *dropout* secara lebih akurat dan dini [14]. Sistem manajemen pembelajaran (LMS) seperti *Moodle* menghasilkan data log aktivitas mahasiswa secara masif, yang berpotensi besar untuk dimanfaatkan sebagai basis prediksi. Dengan prediksi yang akurat dan tepat waktu, institusi pendidikan dapat melakukan intervensi preventif sebelum mahasiswa benar-benar memutuskan untuk keluar.

Urgensi penelitian ini semakin meningkat seiring dengan semakin luasnya penerapan pembelajaran bauran (*blended learning*) yang mengintegrasikan perkuliahan tatap muka dengan aktivitas daring. Dalam setting *blended learning*, dosen semakin sulit memantau keterlibatan mahasiswa secara individual, sehingga sistem prediksi berbasis ML menjadi semakin relevan [14]. Selain itu, pandemi COVID-19 yang akselerasi transformasi digital pendidikan turut meningkatkan volume data digital mahasiswa yang tersedia, sekaligus meningkatkan risiko *dropout* akibat ketidaksiapan adaptasi.

1.2. Review Studi Terdahulu

Sejumlah penelitian telah dilakukan untuk memprediksi *dropout* mahasiswa menggunakan berbagai pendekatan *machine learning*. Dalam studi [14] mengembangkan model prediksi *dropout* tingkat mata kuliah menggunakan metode ensemble heterogen berbasis voting dan boosting (AdaBoost, XGBoost) pada data LMS Moodle dari 110 mahasiswa selama 13 minggu. Penelitian ini mengikuti kerangka CRISP-DM dan menunjukkan bahwa ensemble lanjutan mampu meningkatkan akurasi 2-4% dibanding metode tunggal, dengan akurasi hingga 97,06% pada kuartal keempat.

Dalam studi [13] menggunakan algoritma *decision tree* C4.5 untuk mengidentifikasi faktor-faktor penyebab

dropout mahasiswa teknik di Universidade de Brasília, Brasil. Dengan sampel 91 mahasiswa dan 29 kriteria, model mencapai akurasi 86,81%. Hasil penting dari penelitian ini adalah ditemukannya bahwa interaksi dengan dosen, kesehatan mental, dan relevansi kurikulum merupakan faktor penentu utama keputusan *dropout*.

Pada penelitian [18] membandingkan tiga algoritma ML yaitu *Decision Tree* (DT), *Random Forest* (RF), dan *Artificial Neural Network* (ANN) pada dataset *dropout* mahasiswa yang lebih besar (4.424 mahasiswa, 37 fitur) dari UCI *Machine Learning Repository*. ANN menghasilkan akurasi tertinggi (77,3%), diikuti RF (75,5%) dan DT (70,1%). Penelitian ini menggunakan validasi silang 10-fold dan mengklasifikasikan mahasiswa ke dalam tiga kelas: *Dropout*, *Enrolled*, dan *Graduate*.

Pada penelitian [9] mengusulkan pendekatan *end-to-end* yang menggabungkan ekstraksi data dari sistem akademik, pengayaan dengan data sosial-ekonomi regional, *feature engineering* temporal, serta teknik *explainable machine learning* (SHAP) untuk memprediksi *dropout* di 19 sekolah Brasil. XGBoost menjadi *classifier* terbaik dengan AUC-PR hingga 89,5% dan recall hingga 93%. Penelitian ini menekankan pentingnya interpretabilitas model agar hasil prediksi dapat dimanfaatkan oleh tim akademik.

Dalam studi [2] memperkenalkan pendekatan novel berbasis *grammatical evolution* untuk *feature selection* dan *construction* pada jaringan *Radial Basis Function* (FSC4RBF) yang diaplikasikan untuk memprediksi nilai dan durasi studi mahasiswa di enam departemen Universitas Ioannina, Yunani. FSC4RBF mencapai MSE terendah pada 9 dari 12 dataset regresi dan akurasi tertinggi pada semua dataset klasifikasi, mengungguli LM-BP, BFGS-BP, SGD, RBFNN, DT, BN, SVM, dan NNC.

Perbedaan penelitian ini dengan penelitian terdahulu terletak pada pendekatan komparatif lintas konteks dan metode yang lebih komprehensif. Sementara penelitian terdahulu cenderung berfokus pada satu metode atau satu konteks institusional, kajian ini mengintegrasikan temuan dari beragam pendekatan ML (ensemble, *decision tree*, ANN, dan *novel grammar-based method*) dan konteks pendidikan yang beragam (LMS berbasis Moodle, pendidikan teknik Brasil, pendidikan dasar-menengah, hingga universitas Eropa), sehingga menghasilkan gambaran yang lebih holistik dan dapat dijadikan panduan pemilihan metode yang tepat.

1.3. Tujuan dan Manfaat Penelitian

Penelitian ini bertujuan untuk: (1) mengkaji dan membandingkan berbagai metode *machine learning* yang telah digunakan dalam prediksi *dropout* mahasiswa, (2) mengidentifikasi fitur-fitur yang paling signifikan dalam mempengaruhi prediksi *dropout*, (3) menganalisis kelebihan dan keterbatasan masing-masing metode berdasarkan konteks dataset dan tingkat pendidikan, serta (4) memberikan rekomendasi pemilihan metode yang tepat berdasarkan karakteristik permasalahan.

Manfaat penelitian ini secara teoritis adalah memberikan kontribusi pada pengembangan ilmu

educational data mining dan *learning analytics*. Secara praktis, hasil penelitian dapat menjadi acuan bagi institusi pendidikan dalam merancang sistem *early warning dropout* yang efektif, serta bagi peneliti dalam mengembangkan model prediksi yang lebih akurat dan dapat diinterpretasikan.

2.0 METODE

2.1. Objek Penelitian dan Perolehan Data

Objek penelitian ini adalah beberapa studi primer yang membahas prediksi dropout mahasiswa menggunakan *machine learning*, yang dipublikasikan pada rentang tahun 2020-2024. Data penelitian diperoleh melalui studi literatur sistematis dari basis data ilmiah Elsevier *ScienceDirect*, *Procedia Computer Science*, *Expert Systems with Applications*, dan *Intelligent Methods in Engineering Sciences*. Kriteria inklusi meliputi: (a) fokus pada prediksi *dropout* atau kinerja akademik, (b) menggunakan metode *machine learning* atau *data mining*, (c) menyertakan evaluasi performa model yang terukur, dan (d) diterbitkan dalam jurnal atau prosiding ilmiah terindeks.

2.2. Variabel dan Perlakuan pada Objek Penelitian

Variabel penelitian meliputi: (a) variabel independen berupa fitur-fitur mahasiswa dan konteks pendidikan (nilai akademik, data interaksi LMS, karakteristik demografis, faktor sosial-ekonomi, hubungan dengan dosen), dan (b) variabel dependen berupa status *dropout*/tidak *dropout*, nilai akhir, atau durasi studi. Variasi perlakuan pada penelitian-penelitian yang dikaji mencakup perbedaan: jenis metode ML yang digunakan, ukuran dan sumber dataset, titik prediksi (*temporal prediction points*), teknik *balancing data*, dan metode evaluasi model.

Penelitian [14] membagi timeline prediksi menjadi empat kuartal (Q1-Q4) untuk menganalisis dampak waktu prediksi terhadap akurasi. [13] menggunakan 29 kriteria faktor *dropout* yang diperoleh dari survei mahasiswa. Di Penelitian [18] mengklasifikasikan output menjadi tiga kelas (Dropout, Enrolled, Graduate). [9] membedakan prediksi antar jenjang pendidikan (prasekolah, pendidikan dasar, pendidikan menengah) dan antar trimester akademik. [2] memisahkan masalah regresi (prediksi nilai numerik) dan klasifikasi (prediksi kategori nilai dan durasi studi).

2.3. Metode Pemecahan Masalah

Metode yang dikaji dalam penelitian ini dibagi menjadi tiga kategori utama. Pertama, metode *ensemble* yang menggabungkan prediksi dari beberapa model. *Ensemble* dapat bersifat homogen (menggunakan algoritma yang sama dengan data berbeda, contoh: *Random Forest*, *AdaBoost*, *XGBoost*) atau heterogen (menggunakan algoritma berbeda, contoh: voting antara LR, RF, DT, KNN, SVM). Kelebihan metode *ensemble* adalah kemampuannya mengurangi *variance* dan bias, serta menghasilkan prediksi yang lebih kuat. Keterbatasannya adalah kompleksitas komputasi yang lebih tinggi dan interpretabilitas yang lebih rendah dibanding model tunggal [14].

Kedua, metode *decision tree* yang membangun model berupa struktur pohon keputusan hierarkis. Algoritma C4.5 yang digunakan oleh [13] merupakan salah satu dari sepuluh algoritma *data mining* terbaik. Kelebihan *decision tree* adalah interpretabilitasnya yang tinggi karena aturan keputusan dapat dibaca secara langsung. Keterbatasannya adalah kecenderungan *overfitting* pada dataset kecil dan perlu pemangkasan (*pruning*) yang cermat. Metode ini telah banyak digunakan dalam *educational data mining* dan terbukti efektif pada dataset berukuran kecil [13].

Ketiga, metode *Artificial Neural Network* (ANN) yang terinspirasi dari sistem saraf biologis dan mampu mempelajari hubungan *non-linear* yang kompleks. ANN mengungguli DT dan RF dalam dataset berukuran besar dan kompleks [18]. Keempat, metode FSC4RBF yang merupakan pendekatan novel berbasis *grammatical evolution* untuk *feature construction* pada RBF network yang diperkenalkan oleh [2]. Metode ini relatif baru dan belum banyak diaplikasikan pada domain pendidikan, namun menunjukkan hasil yang menjanjikan dengan akurasi tertinggi di antara metode yang dibandingkan dalam studinya.

2.4. Alat dan Bahan Penelitian

Studi-studi yang dikaji menggunakan berbagai alat komputasi dan perangkat lunak. [14] menggunakan Python 3.8 dengan distribusi Anaconda, *library* Scikit-learn, Pandas, NumPy, Matplotlib, Seaborn, Imblearn (untuk SMOTE), dan SHAP untuk interpretasi model. [13] menggunakan platform RapidMiner untuk analisis *data mining* dan penerapan algoritma C4.5. Pada penelitian [18] juga menggunakan Python dengan Scikit-learn untuk implementasi DT, RF, dan ANN. [9] menggunakan Python dengan Scikit-learn dan XGBoost, dijalankan pada komputer dengan Intel Xeon W-1290P CPU @3.70 GHz, RAM 64 GB, dan GPU NVIDIA 2080 TI. [2] mengembangkan implementasi FSC4RBF sendiri dalam bahasa pemrograman yang tidak disebutkan secara eksplisit, dengan parameter evolusi gramatikal yang telah dioptimasi.

Teknik validasi yang digunakan secara konsisten di seluruh studi adalah k-fold *cross-validation* (umumnya k=10), yang membagi dataset menjadi k subset dan secara bergantian menggunakan satu subset sebagai data uji dan sisanya sebagai data latih, sehingga setiap data poin digunakan baik untuk pelatihan maupun pengujian. Teknik ini dipilih karena mampu memberikan estimasi performa yang lebih reliabel dan mengurangi masalah *overfitting* [18].

3.0 HASIL DAN PEMBAHASAN

3.1. Perbandingan Performa *Machine Learning*

Berdasarkan kajian terhadap beberapa studi, diperoleh gambaran komprehensif mengenai performa berbagai metode ML dalam memprediksi *dropout* mahasiswa. Tabel 1 merangkum perbandingan performa metode-metode tersebut berdasarkan matrik akurasi.

Table 1: Perbandingan Performa Metode

Metode	Dataset	Matrik	
		Akurasi	Lainnya

Ensemble Voting + AdaBoost + XGBoost	LMS Moodle	97,06%	F1: 0.96, Recall: 0.95
Decision Tree C4.5	91 mhs, Teknik Brasil	86,81%	Precision : 88,89%
ANN	4.424 mhs, UCI	77,3%	F-score: 76,2%
Random Forest	4.424 mhs, UCI	75,5%	F-score: 74,2%
Decision Tree	4.424 mhs, UCI	70,1%	F-score: 70,0%
XGBoost	49.619 siswa Brasil	AUC-PR: 89,5%	Recall: 93,9%
FSC4RBF	Mahasiswa Ioannina	90,90% (Maths)	MSE terendah di 9/12 dataset

Dari Tabel 1 terlihat bahwa metode *ensemble* lanjutan (AdaBoost + XGBoost) menghasilkan akurasi tertinggi (97,06%) pada dataset LMS Moodle. Namun perlu dicatat bahwa perbandingan langsung antar studi tidak sepenuhnya valid karena perbedaan dataset, jumlah kelas, dan matrik evaluasi yang digunakan. Studi [14] menggunakan dataset yang jauh lebih kecil (110 mahasiswa) dibanding pada penelitian [18] (4.424 mahasiswa), sehingga akurasi yang lebih tinggi pada dataset kecil belum tentu mencerminkan performa yang lebih baik secara umum.

Hal menarik adalah hasil yang relatif moderat dari ANN (77,3%) pada dataset besar dari [18], padahal ANN dikenal mampu menangani kompleksitas data yang tinggi. Ini mengindikasikan bahwa performa ANN sangat dipengaruhi oleh arsitektur jaringan, optimasi *hyperparameter*, dan karakteristik dataset. Pada studi ini, ANN menggunakan konfigurasi dengan 100 neuron tersembunyi, fungsi aktivasi logistik, dan solver Adam, yang mungkin belum optimal untuk karakteristik dataset *dropout* UCI.

3.2. Dampak Waktu Prediksi terhadap Akurasi

Salah satu temuan penting yang konsisten di beberapa studi adalah adanya korelasi positif antara waktu prediksi (semakin mendekati akhir semester) dengan akurasi prediksi. [14] secara eksplisit mendemonstrasikan fenomena ini dengan membagi semester menjadi empat kuartal prediksi.

Table 2: Performa Ensemble Method

Kuartal	Akurasi (Basic)	Akurasi (Advanced)	F1 (Advanced)
Q1	85,30%	88,49%	0.88
Q1-Q2	88,24%	91,34%	0.90

Q1-Q3	91,18%	94,24%	0.94
Q1-Q4	94,12%	97,06%	0.96

Dari Tabel 2 terlihat peningkatan akurasi yang konsisten dari Q1 (85,30%) hingga Q4 (94,12%) untuk metode *ensemble* dasar, dan dari 88,49% hingga 97,06% untuk metode *ensemble* lanjutan. Pola ini masuk akal secara pedagogis: semakin banyak data interaksi yang tersedia (nilai tugas, tes, dan ujian tengah semester), semakin akurat model dapat mengidentifikasi mahasiswa yang berisiko dropout.

Temuan serupa juga dilaporkan oleh [9] yang membagi tahun akademik menjadi tiga trimester. Mereka menemukan peningkatan AUC-PR yang signifikan dari trimester pertama (0,3822) ke trimester ketiga (0,8950). Peningkatan terbesar terjadi antara trimester pertama dan kedua, yang mengindikasikan bahwa data dari paruh pertama tahun akademik sudah cukup informatif untuk menghasilkan prediksi yang lebih reliable.

Implikasi praktis dari temuan ini adalah bahwa intervensi paling efektif sebaiknya dilakukan pada paruh kedua semester (Q3), di mana akurasi prediksi sudah cukup tinggi (>91%) namun masih ada waktu yang cukup untuk melakukan intervensi pedagogis. [14] merekomendasikan kuartal ketiga sebagai momen intervensi yang optimal, karena selisih akurasi antara Q3 dan Q4 relatif kecil (~3%) sementara waktu intervensi di Q3 jauh lebih memadai.

3.3. Fitur Signifikan dalam Prediksi Dropout

Identifikasi fitur yang paling berpengaruh dalam prediksi *dropout* merupakan aspek kritis yang memiliki implikasi langsung bagi kebijakan pendidikan. Berbagai studi menggunakan teknik *feature importance* yang berbeda-beda untuk mengidentifikasi fitur tersebut.

Pada penelitian [14] menggunakan SHAP (*SHapley Additive exPlanations*) untuk menginterpretasi model AdaBoost. Hasilnya menunjukkan bahwa pada kuartal awal (Q1), nilai tes (A1) bersama dua tugas terakhir (Z4, Z5) memiliki pengaruh paling signifikan, diikuti oleh jumlah percobaan mahasiswa dalam mata kuliah (AT). Seiring berjalannya semester, bobot nilai ujian tengah semester (T) dan tes-tes (A1-A3) semakin dominan.

Dalam studi [9] menemukan bahwa fitur paling penting bervariasi antar jenjang pendidikan. Pada jenjang prasekolah, biaya pendidikan dan faktor sosial-ekonomi regional (HDI kota, harapan lama sekolah) menjadi prediktor utama. Pada jenjang pendidikan dasar, nilai kumulatif dalam mata pelajaran Pendidikan Jasmani, Seni, dan Bahasa Portugis paling berpengaruh. Temuan ini mengindikasikan bahwa penurunan nilai dalam mata pelajaran yang seharusnya 'mudah' mungkin mencerminkan masalah yang lebih dalam, seperti kesulitan adaptasi, masalah dengan orang tua, atau bahkan kasus perundungan.

Studi [13] menemukan bahwa *root variable* pada *decision tree* adalah hubungan dengan dosen. Mahasiswa yang mengalami masalah kesehatan mental dan kurangnya interaksi dengan dosen memiliki probabilitas *dropout* 91,11%, sementara ketiadaan interaksi dengan dosen dikombinasikan dengan persepsi kurikulum yang tidak relevan dan masalah kesehatan mental menghasilkan probabilitas *dropout* 100%.

Temuan ini sejalan dengan literatur yang menunjukkan bahwa hubungan mahasiswa-dosen merupakan faktor protektif yang kuat terhadap *dropout* sebagaimana dikutip dalam [13]. Interaksi positif dengan dosen dapat mengkompensasi faktor-faktor negatif lain yang mungkin mendorong mahasiswa untuk keluar. Implikasinya, program mentoring dan peningkatan aksesibilitas dosen dapat menjadi intervensi yang *cost-effective* dalam mengurangi angka *dropout*. Tabel 3 merangkum fitur-fitur kunci yang ditemukan signifikan dalam berbagai studi.

Table 3: Fitur Signifikan dalam Prediksi Dropout

Fitur	Fitur Spesifik
Akademik - Nilai	Nilai tes, tugas, ujian tengah semester, nilai kumulatif
Interaksi LMS	Jumlah percobaan mengakses kursus, frekuensi login
Sosial-Psikologis	Kesehatan mental, hubungan dengan dosen
Kurikulum	Relevansi kurikulum dengan pasar kerja
Sosial-Ekonomi	Biaya pendidikan, HDI kota, harapan lama sekolah
Demografis	Usia, jenis kelamin, status beasiswa, debtor

3.4. Kelebihan dan Keterbatasan

Setiap metode ML yang dikaji memiliki *trade-off* antara akurasi, interpretabilitas, dan kebutuhan komputasi. *Decision Tree* C4.5 unggul dalam interpretabilitas karena menghasilkan aturan keputusan yang mudah dipahami oleh praktisi pendidikan tanpa latar belakang teknis. Namun, keterbatasannya adalah rentan *overfitting* terutama pada dataset kecil, dan performa yang kurang optimal pada permasalahan klasifikasi kompleks dengan banyak kelas [18].

Random Forest, sebagai *meta-ensemble* dari banyak *decision tree*, menghasilkan performa yang lebih stabil dan akurat dibanding *tree* tunggal. Dalam studi [14], *Random Forest* menjadi *classifier* terbaik di antara metode-metode dasar dengan selisih 1-3% dibanding metode lain, kecuali KNN yang hampir 10% lebih rendah. Kelebihan RF adalah *robustness* terhadap *noise* dan *outlier*, serta kemampuannya mengidentifikasi *feature importance* secara *built-in*.

ANN, meskipun menghasilkan akurasi tertinggi dalam studi [18], memiliki keterbatasan dalam hal interpretabilitas (*black-box model*) dan kebutuhan komputasi yang lebih tinggi. ANN cocok untuk dataset besar dengan pola yang kompleks dan *non-linear*, namun memerlukan *tuning hyperparameter* yang cermat untuk menghasilkan performa optimal.

Metode AdaBoost dan XGBoost, sebagai *advanced ensemble methods*, secara konsisten menghasilkan performa terbaik dalam studi [14]. XGBoost juga terbukti menjadi *classifier* terbaik dalam studi [9] untuk semua jenjang pendidikan dan semua trimester. Kelebihan XGBoost termasuk kemampuannya

menangani data *imbalanced* dan *missing values* secara *built-in*, serta mendukung regularisasi untuk mencegah *overfitting*.

FSC4RBF yang diperkenalkan [2] menunjukkan potensi yang menjanjikan sebagai metode novel yang menggabungkan *feature construction* otomatis dengan jaringan syaraf RBF. Meskipun belum banyak dibandingkan dengan studi lain, metode ini menghasilkan akurasi tertinggi di antara semua metode yang dibandingkan dalam studinya sendiri. Keterbatasannya adalah *overhead* komputasi yang signifikan dari proses evolusi gramatikal dan keterbatasan pada operasi aritmatika dasar dalam proses *feature construction*.

3.4. Teknik *Explainability* dan Penanganan Data *Imbalanced*

Dua isu teknis yang secara konsisten disoroti dalam studi-studi yang dikaji adalah kebutuhan akan model yang dapat diinterpretasi (*explainable*) dan penanganan ketidakseimbangan kelas (*class imbalance*). Masalah *class imbalance* hampir selalu hadir dalam dataset *dropout*, karena secara alami mahasiswa yang *dropout* merupakan minoritas dibanding yang lulus. Pada dataset [14], rasio antara mahasiswa lulus (83) dan gagal (27) sekitar 3:1. [9] melaporkan tingkat *dropout* yang bahkan lebih rendah, yakni sekitar 2-3% per tahun akademik.

Teknik SMOTE (*Synthetic Minority Oversampling Technique*) yang digunakan oleh [14] terbukti efektif dalam mengatasi masalah ini dengan membuat titik data sintetis baru pada kelas minoritas. Penggunaan SMOTE membantu menghindari bias model yang cenderung memprediksi semua sampel sebagai kelas mayoritas (*non-dropout*), yang meskipun menghasilkan akurasi tinggi namun gagal mengidentifikasi mahasiswa yang benar-benar berisiko.

[9] memilih AUC-PR dan Kolmogorov-Smirnov (KS) sebagai matrik evaluasi utama, karena kedua metrik ini lebih kokoh terhadap *class imbalance* dibanding akurasi biasa. Pendekatan ini penting karena dalam konteks *dropout prediction*, biaya salah klasifikasi antara *false negative* (mahasiswa berisiko tidak terdeteksi) dan *false positive* (mahasiswa aman dianggap berisiko) tidak simetris.

Teknik SHAP yang digunakan oleh [14] dan dalam studi [9] memungkinkan tim akademik untuk memahami mengapa suatu mahasiswa diprediksi *dropout*, tidak hanya mengetahui bahwa mahasiswa tersebut berisiko. Interpretasi ini sangat penting untuk merancang intervensi yang tepat sasaran dan menghindari stigmatisasi.

4.0 KESIMPULAN

Kajian komparatif terhadap beberapa penelitian prediksi dropout mahasiswa menggunakan machine learning menghasilkan beberapa kesimpulan penting. 1) Metode *ensemble* lanjutan (AdaBoost, XGBoost) secara konsisten menghasilkan performa prediksi terbaik dengan akurasi mencapai 97,06%, diikuti oleh ANN (77,3%), *Random Forest* (75,5%), dan *Decision Tree* (70,1%-86,81%). Namun, pemilihan metode harus mempertimbangkan *trade-off* antara akurasi,

interpretabilitas, dan ketersediaan sumber daya komputasi. 2) Akurasi prediksi meningkat secara signifikan seiring bertambahnya data yang tersedia selama semester, dengan kuartal ketiga semester direkomendasikan sebagai titik intervensi optimal karena keseimbangan antara akurasi yang tinggi (>91%) dan waktu intervensi yang masih memadai. 3) Fitur yang paling konsisten berpengaruh terhadap prediksi dropout meliputi nilai akademik (tugas, tes, ujian), frekuensi interaksi dengan sistem pembelajaran, kesehatan mental, hubungan mahasiswa-dosen, dan faktor sosial-ekonomi. Temuan ini mengkonfirmasi bahwa dropout adalah fenomena multidimensional yang tidak dapat dijelaskan oleh satu faktor tunggal. 4) Teknik *explainable machine learning* (terutama SHAP) dan penanganan *class imbalance* (terutama SMOTE) merupakan komponen esensial dalam pengembangan sistem prediksi *drop out* yang bertanggung jawab dan efektif. Tanpa kedua komponen ini, sistem prediksi berisiko menghasilkan *output* yang bias atau tidak dapat dimanfaatkan secara praktis oleh institusi pendidikan. Penelitian selanjutnya disarankan untuk mengeksplorasi pendekatan *deep learning* pada dataset yang lebih besar, integrasi data *multimodal* (akademik, sosial-emosional, dan kontekstual), serta pengembangan sistem rekomendasi intervensi yang berbasis pada *output* prediksi.

DAFTAR PUSTAKA

- [1] Ahmed, E. (2024). Student Performance Prediction Using Machine Learning Algorithms. *Applied Computational Intelligence and Soft Computing*, 2024. <https://doi.org/10.1155/2024/4067721>
- [2] Christou, V., Tsoulos, I., Loupas, V., Tzallas, A. T., Gogos, C., Karvelis, P. S., Antoniadis, N., Glavas, E., & Giannakeas, N. (2023). Performance and early drop prediction for higher education students using machine learning. *Expert Systems with Applications*, 225. <https://doi.org/10.1016/j.eswa.2023.120079>
- [3] Coussement, K., Phan, M., de Caigny, A., Benoit, D. F., & Raes, A. (2020). Predicting student dropout in subscription-based online learning environments: The beneficial impact of the logit leaf model. *Decision Support Systems*, 135. <https://doi.org/10.1016/j.dss.2020.113325>
- [4] Delen, D., Topuz, K., & Eryarsoy, E. (2020). Development of a Bayesian Belief Network-based DSS for predicting and understanding freshmen student attrition. *European Journal of Operational Research*, 281(3), 575–587. <https://doi.org/10.1016/j.ejor.2019.03.037>
- [5] Dwi Permana, Y., Nuryadhin, S., & Najmi, A. (2026.). Prediksi Performa Dan Dropout Mahasiswa Menggunakan Metode Ensemble Learning: Kajian Sistematis Berbasis Blended Learning. In *Jurnal Mahasiswa Teknik Informatika: Vol 10 No. 2*.
- [6] Fahd, K., Venkatraman, S., Miah, S. J., & Ahmed, K. (2022). Application of machine learning in higher education to assess student academic performance, at-risk, and attrition: A meta-analysis of literature. *Education and Information Technologies*, 27(3), 3743–3775. <https://doi.org/10.1007/s10639-021-10741-7>
- [7] Hassan, M. A., Muse, A. H., & Nadarajah, S. (2024). Predicting Student Dropout Rates Using Supervised Machine Learning: Insights from the 2022 National Education Accessibility Survey in Somaliland. *Applied Sciences (Switzerland)*, 14(17). <https://doi.org/10.3390/app14177593>
- [8] Huang, J., Yang, K., Wang, Q., Yang, P., Ruan, Z., Wang, J., & Zhang, Z. Q. (2025). Bayesian deep multi-instance learning for student performance prediction based on campus big data. *Neurocomputing*, 647. <https://doi.org/10.1016/j.neucom.2025.130538>
- [9] Krüger, J. G. C., Britto, A. de S., & Barddal, J. P. (2023). An explainable machine learning approach for student dropout prediction. *Expert Systems with Applications*, 233. <https://doi.org/10.1016/j.eswa.2023.120933>
- [10] Lykourantzou, I., Giannoukos, I., Nikolopoulos, V., Mpardis, G., & Loumos, V. (2009). Dropout prediction in e-learning courses through the combination of machine learning techniques. *Computers and Education*, 53(3), 950–965. <https://doi.org/10.1016/j.compedu.2009.05.010>
- [11] Lyu, H., Shan, P., Hou, C., & Duan, S. (2025). Artificial intelligence for student performance prediction in blended learning: A systematic literature review. In *Neurocomputing* (Vol. 658). Elsevier B.V. <https://doi.org/10.1016/j.neucom.2025.131659>
- [12] Maldonado, S., Miranda, J., Olaya, D., Vásquez, J., & Verbeke, W. (2021). Redefining profit metrics for boosting student retention in higher education. *Decision Support Systems*, 143. <https://doi.org/10.1016/j.dss.2021.113493>
- [13] Mariano, A. M., de Magalhães Lelis Ferreira, A. B., Santos, M. R., Castilho, M. L., & Bastos, A. C. F. L. C. (2022). Decision trees for predicting dropout in Engineering Course students in Brazil. *Procedia Computer Science*, 214(C), 1113–1120. <https://doi.org/10.1016/j.procs.2022.11.285>
- [14] Pecuchova, J., & Drlik, M. (2023). Predicting Students at Risk of Early Dropping Out from Course Using Ensemble Classification Methods. *Procedia Computer Science*, 225, 3223–3232. <https://doi.org/10.1016/j.procs.2023.10.316>
- [15] Phan, M., de Caigny, A., & Coussement, K. (2023). A decision support framework to incorporate textual data for early student dropout prediction in higher education. *Decision Support Systems*, 168. <https://doi.org/10.1016/j.dss.2023.113940>
- [16] Pradnyana, G. A., Anggraeni, W., Yuniarno, E. M., & Purnomo, M. H. (2025). An explainable ensemble model for revealing the level of depression in social media by considering personality traits and sentiment polarity pattern. *Online Social Networks and Media*, 46. <https://doi.org/10.1016/j.osnem.2025.100307>
- [17] Rebelo Marcolino, M., Reis Porto, T., Thompsen Primo, T., Targino, R., Ramos, V., Marques Queiroga, E., Munoz, R., & Cechinel, C. (2025). Student dropout prediction through machine learning optimization: insights from moodle log data. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-93918-1>
- [18] SULAK, S. A., & KOKLU, N. (2025). Predicting Student Dropout Using Machine Learning

- Algorithms. *Intelligent Methods in Engineering Sciences*. <https://doi.org/10.58190/imiens.2024.103>
- [19] Ticona, J. J., Nonato, L. G., Silva, C. T., & Gomez-Nieto, E. (2025). SDR-Explorer: A user-friendly visual tool to support preventing student dropouts in higher education. *Computers and Graphics*, 132. <https://doi.org/10.1016/j.cag.2025.104375>
- [20] Vaarma, M., & Li, H. (2024). Predicting student dropouts with machine learning: An empirical study in Finnish higher education. *Technology in Society*, 76. <https://doi.org/10.1016/j.techsoc.2024.102474>
- [21] V.D.E. Vogelsmeier, L., Oliveira, E., Misiejuk, K., López-Pernas, S., & Saqr, M. (2025). Delving into the psychology of Machines: Exploring the structure of self-regulated learning via LLM-generated survey responses. *Computers in Human Behavior*, 173. <https://doi.org/10.1016/j.chb.2025.108769>