

PREDIKSI PERFORMA DAN DROPOUT MAHASISWA MENGGUNAKAN METODE ENSEMBLE LEARNING: KAJIAN SISTEMATIS BERBASIS BLENDED LEARNING

Yudistira Dwi Permana, Shodik Nuryadhin, Ainin Najmi

Teknik Rekayasa Perangkat Lunak, Politeknik Krakatau

Jl. SA. Tirtayasa No.49, Banten, Indonesia

yudisdwi02@gmail.com

ABSTRAK

Seiring meluasnya penerapan blended learning di pendidikan tinggi yang menuntut pemantauan dini terhadap performa dan risiko dropout mahasiswa, temuan riset terkait model prediksi masih tersebar dan belum dibandingkan secara komprehensif sehingga belum jelas metode ensemble mana yang paling unggul, prediktor apa yang paling berpengaruh, serta kapan waktu intervensi paling optimal, kajian sistematis ini bertujuan membandingkan efektivitas XGBoost, AdaBoost, Decision Tree C4.5, dan ensemble heterogen, mengidentifikasi faktor penentu utama berbasis eksplanabilitas, serta memetakan dinamika akurasi prediksi secara temporal untuk menetapkan jendela intervensi, dilakukan sintesis beberapa studi terkemuka periode 2022–2025 dengan membandingkan kinerja model menggunakan akurasi, presisi, recall, F1-score, dan metrik kurva (termasuk AUC-PR) serta merangkum analisis SHAP dan evaluasi kinerja per kuartal pembelajaran (Q1–Q4), metode ensemble secara konsisten mengungguli klasifikasi tunggal sebesar 2–10% pada metrik utama; XGBoost mencapai AUC-PR 89,5%, presisi 95%, dan recall 93%, sementara kombinasi AdaBoost–XGBoost mencapai akurasi 97,06% pada kuartal keempat; SHAP menunjukkan prediktor paling berpengaruh meliputi indikator performa akademik, tingkat penyelesaian tugas, jumlah interaksi LMS, kondisi kesehatan mental, dan variabel sosial ekonomi, serta analisis temporal mengonfirmasi akurasi meningkat dari Q1 (85–88%) ke Q3 (94–97%) sehingga minggu ke-9 hingga ke-10 merupakan jendela intervensi optimal bagi institusi tinggi Indonesia untuk mengimplementasikan sistem peringatan dini mahasiswa berisiko.

Kata kunci : *ensemble learning; prediksi dropout; blended learning; XGBoost; AI yang dapat dijelaskan; performa mahasiswa*

1. PENDAHULUAN

Tingginya angka dropout mahasiswa merupakan persoalan serius dalam sistem pendidikan tinggi Indonesia karena berdampak langsung pada kerugian sosial-ekonomi, baik bagi mahasiswa (hilangnya kesempatan pengembangan kompetensi dan karier) maupun bagi institusi (hilangnya investasi pendidikan, menurunnya capaian kinerja, serta inefisiensi sumber daya akademik). Berdasarkan data Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi, rata-rata angka putus kuliah nasional berada pada kisaran 15–20% per tahun, dengan program studi teknik dan sains dilaporkan cenderung lebih tinggi [1]. Kondisi ini menegaskan bahwa strategi penanganan dropout perlu bergerak dari pendekatan reaktif menuju upaya preventif yang mampu mendeteksi risiko sejak dini.

Perkembangan pembelajaran digital dalam ekosistem blended learning memperkuat peluang penerapan pencegahan dropout berbasis data. Learning Management System (LMS) seperti Moodle, Canvas, dan Edmodo menghasilkan jejak digital mahasiswa yang kaya—mulai dari log akses materi, waktu belajar, skor kuis, frekuensi interaksi forum, hingga pola pengumpulan tugas [2]. Data multidimensional ini membentuk representasi perilaku belajar yang dapat dianalisis secara sistematis untuk membaca keterlibatan (engagement), kemajuan akademik, dan sinyal risiko yang sering tidak terlihat pada evaluasi konvensional, sehingga berpotensi

menjadi fondasi sistem peringatan dini (early warning system).

Meski machine learning telah banyak digunakan untuk prediksi performa dan dropout, implementasi di level institusi masih menghadapi tantangan metodologis dan operasional. Salah satu kendala utama adalah karakteristik data pendidikan yang sering tidak seimbang (imbalanced) antara kelas dropout dan non-dropout, yang dapat mendorong model menghasilkan akurasi “tampak tinggi” tetapi lemah mendeteksi mahasiswa berisiko, atau sebaliknya memunculkan false positive yang berpotensi menimbulkan intervensi yang tidak tepat sasaran. Dalam konteks ini, metode ensemble machine learning (misalnya XGBoost, AdaBoost, dan Random Forest) dilaporkan mampu meningkatkan performa prediksi dan stabilitas model dibanding klasifikasi tunggal, termasuk peningkatan sekitar 2–10% pada metrik tertentu serta penurunan kesalahan klasifikasi yang merugikan [3], [4].

Namun, temuan riset terkait ensemble dalam blended learning masih tersebar dan belum dipetakan secara komparatif untuk menjawab kebutuhan implementasi yang praktis: metode ensemble mana yang paling konsisten unggul pada berbagai metrik, fitur prediktor apa yang paling berpengaruh lintas studi, dan kapan sepanjang semester prediksi mencapai reliabilitas yang cukup untuk dijadikan dasar intervensi. Di sisi lain, aspek eksplanabilitas juga

semakin krusial karena model yang tidak transparan berisiko menyulitkan dosen wali/konselor dalam memahami alasan risiko dan merancang tindak lanjut yang etis; teknik seperti SHAP dan LIME memang menjanjikan, tetapi sintesis lintas studi mengenai pola prediktor dominan masih terbatas [2]. Dengan demikian, terdapat kebutuhan akan kajian yang merangkum bukti secara sistematis agar keputusan desain sistem peringatan dini tidak bertumpu pada satu studi atau satu dataset saja.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan menyusun kajian sistematis terhadap studi-studi terkemuka yang meneliti prediksi performa dan dropout mahasiswa menggunakan metode ensemble learning dalam lingkungan blended learning. Secara khusus, kajian ini diarahkan untuk mengidentifikasi metode ensemble yang paling efektif berdasarkan metrik performa yang dilaporkan, merangkum fitur prediktor paling berpengaruh melalui temuan explainable AI (terutama SHAP), menganalisis dinamika temporal performa prediksi sepanjang semester untuk menentukan jendela intervensi yang paling optimal, serta menarik implikasi implementasi yang relevan bagi perguruan tinggi di Indonesia [2]–[4].

Untuk mencapai tujuan tersebut, penelitian ini menerapkan pendekatan kajian sistematis dengan alur: penentuan pertanyaan kajian dan kriteria inklusi-eksklusi, penelusuran dan seleksi artikel periode 2022–2025, ekstraksi data inti (algoritma, karakteristik dataset, fitur, skema validasi, serta metrik evaluasi), lalu sintesis komparatif kinerja model (akurasi, presisi, recall, F1-score, dan metrik kurva yang relevan) dengan perhatian khusus pada isu imbalance dan risiko false positive/false negative [3], [4]. Selanjutnya, kajian mensintesis hasil eksplanabilitas (misalnya SHAP/LIME) untuk memetakan prediktor dominan yang dapat ditindaklanjuti [2], serta menyusun analisis temporal (berbasis fase perkuliahan/minggu/kuartal) guna menetapkan waktu intervensi yang paling strategis. Tahap akhir difokuskan pada perumusan rekomendasi implementasi yang realistis bagi sistem peringatan dini di konteks perguruan tinggi Indonesia, termasuk prinsip tata kelola data dan penggunaan model yang transparan.

2. TINJAUAN PUSTAKA

Dari penelitian sebelumnya [1] menyajikan tinjauan literatur sistematis yang komprehensif tentang penerapan AI dalam prediksi performa mahasiswa pada lingkungan blended learning, mencakup 143 studi yang diterbitkan antara 2020 dan 2024. Kajian ini mengidentifikasi tiga dimensi utama yang mempengaruhi performa mahasiswa: perilaku belajar (durasi belajar online, pola akses materi, frekuensi interaksi forum), faktor sosial (latar belakang demografis, lingkungan keluarga, kondisi ekonomi), dan kondisi emosional (motivasi, kecemasan, kedisiplinan diri).

Temuan penting dari [3] adalah tren peningkatan penggunaan deep learning, dengan tingkat pertumbuhan gabungan (CAGR) 38,5% dari 2020 hingga 2024, dibandingkan 29,7% untuk machine learning konvensional. Namun demikian, metode ensemble klasik seperti XGBoost dan CatBoost tetap unggul untuk dataset berukuran kecil hingga menengah (kurang dari 1.000 rekaman), yang merupakan skala dataset yang umum ditemui di perguruan tinggi Indonesia. Model LSTM dan CNN baru menunjukkan keunggulan yang signifikan pada dataset berskala besar (lebih dari 10.000 rekaman).

Pada penelitian [2] mengusulkan pipeline end-to-end untuk prediksi dropout mahasiswa menggunakan data dari 19 sekolah swasta di Brasil, mencakup 299.722 baris data dan 137 fitur. Metodologi penelitian ini menonjol karena tiga inovasi utama: pengayaan data dengan indikator sosial-ekonomi wilayah (GDP per kapita dan Human Development Index dari IBGE), rekayasa fitur temporal yang mengukur akumulasi nilai ($N_{\text{kumulatif}}$) dan perubahan nilai antar-trimester (ΔN), serta penerapan SHAP untuk eksplanabilitas prediksi pada level individu mahasiswa.

Hasil eksperimen menggunakan XGBoost menunjukkan peningkatan dramatis sepanjang tahun akademik: AUC-PR dari 38,22% pada Trimester 1 meningkat menjadi 89,50% pada Trimester 3, dengan presisi 95,23% dan recall 93,93%. Analisis SHAP mengungkap perbedaan pola fitur yang signifikan antar jenjang pendidikan: jenjang pra-sekolah didominasi oleh variabel biaya pendidikan dan HDI kota, jenjang dasar oleh nilai mata pelajaran Pendidikan Jasmani dan Seni, sementara jenjang menengah oleh nilai kumulatif Bahasa Portugis dan Geografi.

Penelitian [3] meneliti faktor penyebab dropout pada mahasiswa Teknik di Universitas Brasília (UnB) menggunakan algoritma Decision Tree C4.5. Dengan survei terhadap 91 mahasiswa dan 29 kriteria potensial penyebab dropout, penelitian ini menghasilkan pohon keputusan dengan akurasi 86,81% berdasarkan confusion matrix. Keunikan studi ini terletak pada inkorporasi dimensi kesehatan mental sebagai variabel prediktif, suatu aspek yang sering diabaikan dalam penelitian berbasis data LMS. Pohon keputusan yang dihasilkan menempatkan variabel "Interaksi dengan Dosen" sebagai akar pohon (node utama), dengan percabangan berdasarkan kondisi kesehatan mental. Mahasiswa yang berinteraksi dengan dosen namun mengalami gangguan kesehatan mental memiliki probabilitas dropout sebesar 91,11%, sementara tanpa gangguan kesehatan mental probabilitas tersebut turun menjadi 66,66%. Temuan ini mengindikasikan bahwa intervensi akademik semata tidak cukup tanpa dukungan kesehatan mental yang memadai.

Penelitian selanjutnya [5] menyajikan tinjauan literatur sistematis yang komprehensif tentang penerapan algoritma machine learning untuk prediksi performa mahasiswa di institusi pendidikan tinggi.

Kajian ini mengidentifikasi enam model ML utama yang efektif: Decision Tree, Artificial Neural Networks (ANNs), Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Linear Regression, dan Naïve Bayes (NB). Analisis terhadap berbagai studi menunjukkan bahwa ANN memiliki tingkat akurasi tertinggi, namun penggunaannya masih terbatas karena memerlukan keahlian teknis khusus untuk implementasi efektif. Kajian ini mengungkapkan tren peningkatan penelitian dalam domain Educational Data Mining (EDM) dengan penerapan berbagai algoritma ML yang menunjukkan potensi besar dalam mengidentifikasi dan meningkatkan area performa akademik mahasiswa.

Penelitian [8] mengimplementasikan berbagai algoritma supervised machine learning untuk memprediksi performa akademik mahasiswa menggunakan dataset dari Wollo University's Kombolcha Institute of Technology yang mencakup 32,582 data mahasiswa dari tahun 2017-2022. Studi ini mengidentifikasi delapan variabel utama yang mempengaruhi performa: student ID, gender, region, entrance result, number of previous attempts, studied credits, disability status, dan final result. Hasil penelitian menunjukkan bahwa setelah dilakukan hyperparameter tuning dengan repeated k-fold cross-validation, SVM Linear mencapai akurasi tertinggi 96.0% (meningkat dari 95.4%), Decision Tree 93.4% (meningkat dari 90.9%), dan Naïve Bayes 83.3% (meningkat dari 77.3%), membuktikan efektivitas parameter optimization dalam meningkatkan performa prediksi.

Studi [9] mengeksplorasi metodologi Educational Data Mining dengan fokus pada prediksi risiko dropout dan performa mahasiswa melalui pendekatan clustering. Penelitian ini mengimplementasikan algoritma K-Means clustering menggunakan metode Elbow untuk mengidentifikasi pola distribusi performa mahasiswa, mengklasifikasikan mahasiswa ke dalam tiga kategori utama (Grade A, Grade B, dan Grade C). Hasil clustering mengungkapkan bahwa mahasiswa Grade A mayoritas berasal dari wilayah Oromia, Addis Ababa, dan Amhara, sementara mahasiswa Grade C cenderung berasal dari South Region, Somalia Region, dan Sidamo Region, menunjukkan korelasi kuat antara faktor geografis dan hasil akademik mahasiswa.

Penelitian [14] menganalisis performa berbagai algoritma machine learning dengan menggunakan metrik evaluasi komprehensif meliputi Precision, Recall, Accuracy, dan Kappa Statistic. Kajian komparatif ini menunjukkan bahwa SVM unggul dalam margin maximization dan kemampuan menangani nonlinear relationships, sementara Decision Tree memberikan keunggulan dalam interpretability dan identifikasi feature importance. Naïve Bayes menunjukkan performa terendah karena keterbatasan dalam strong independence assumption dan sensitivitas terhadap feature correlations, namun

tetap valuable untuk analisis baseline dengan computational efficiency yang tinggi.

Studi [16] memberikan kontribusi dalam pengembangan framework prediktif yang dapat diimplementasikan untuk early intervention dan personalized learning support di institusi pendidikan tinggi. Penelitian ini menekankan pentingnya data preprocessing yang mencakup data cleaning, categorization, dan reduction untuk memastikan kualitas input data yang optimal. Meskipun terdapat keterbatasan seperti fokus pada single institution dan sensitivitas terhadap parameter tuning, hasil penelitian menunjukkan bahwa pendekatan machine learning dengan hyperparameter optimization yang tepat mampu menghasilkan predictive models yang akurat untuk meningkatkan student outcomes melalui identifikasi mahasiswa berisiko dan pengalokasian resources yang lebih efektif.

Dan yang terakhir pada penelitian [4] mengevaluasi metode ensemble untuk prediksi dropout dini menggunakan data LMS Moodle dari 110 mahasiswa Computer Science di Constantine the Philosopher University, Slovakia. Penelitian ini mengimplementasikan metodologi CRISP-DM dan membandingkan dua kategori model: ensemble dasar (LR, RF, DT, KNN, SVM dengan pemungutan suara mayoritas) dan ensemble lanjutan (AdaBoost dan XGBoost). Teknik SMOTE diterapkan untuk mengatasi ketidakseimbangan kelas (75,46% lulus vs 24,54% gagal).

Secara keseluruhan hasil tinjauan pustaka menunjukkan superioritas konsisten AdaBoost+XGBoost atas metode ensemble dasar sebesar 2–4% pada semua metrik. Pada Q4, ensemble lanjutan mencapai akurasi 97,06%, presisi 0,97, recall 0,95, dan F1-score 0,96. Analisis SHAP mengidentifikasi bahwa skor ujian (A1–A3), ujian tengah semester (T), dan penyelesaian tugas terkini (Z11–Z16) merupakan prediktor paling berpengaruh. Penting dicatat bahwa peneliti merekomendasikan Q3 sebagai momen intervensi optimal, karena akurasi sudah mencapai 94,24% sementara masih cukup waktu untuk intervensi efektif.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kajian sistematis komparatif terhadap berbagai artikel ilmiah yang membahas penerapan ensemble machine learning dalam prediksi dropout dan performa akademik mahasiswa. Pendekatan ini sesuai dengan panduan systematic review yang menekankan sintesis kuantitatif untuk memperoleh gambaran menyeluruh mengenai efektivitas metode ensemble dalam konteks pendidikan tinggi. Literature review difokuskan pada artikel ilmiah yang memiliki struktur lengkap, yaitu abstrak, pendahuluan, metode, hasil, dan analisis performa model.

Pencarian artikel dilakukan melalui beberapa database ilmiah terindeks, yaitu ScienceDirect, IEEE Xplore, dan Google Scholar. Penggunaan berbagai

database dimaksudkan untuk memperluas cakupan sumber sekaligus meminimalkan bias pencarian. Kata kunci yang digunakan meliputi ensemble learning, ensemble machine learning, random forest, XGBoost, gradient boosting, student dropout prediction, academic performance, educational data mining, dan learning analytics, mengikuti terminologi penelitian kontemporer dalam bidang educational data mining. Adapun kriteria seleksi artikel meliputi:

- Artikel diterbitkan pada periode 2022–2025
- Artikel bersumber dari jurnal bereputasi (Q1–Q3 Scopus/WoS) atau prosiding konferensi internasional terindeks
- Artikel menerapkan metode ensemble machine learning pada dataset nyata dari institusi pendidikan tinggi
- Artikel menyertakan minimal tiga metrik evaluasi yang dapat dibandingkan (akurasi, presisi, recall, F1-score, atau AUC)

4. HASIL DAN PEMBAHASAN

4.1. Perbandingan Metode Ensemble

Tabel 1. Perbandingan Performa Metode Ensemble Pada Prediksi Dropout Mahasiswa

No	Ref	Metode	Hasil
1	[6][16]	Random Forest (Bagging Ensemble)	Accuracy: 95%; 75,5%
2	[3][13]	Hybrid Tree-based + Logistic / Text-based Model	AUC: 0,87
3	[12][15]	Boosting / Voting-based Ensemble (CatBoost, Voting Classifier)	F1-score: 0,80
4	[8]	Explainable Ensemble Machine Learning	AUC-PR: 89,5%; Precision: 95%; Recall: 93%
5	[4][7]	Bayesian-based Models (BBN, Bayesian Deep Learning)	AUC: 84%
6	[2][11]	Decision Tree (Model Pembanding)	Accuracy: 86,81%
7	[5][9]	Meta-analysis & Systematic Review	Accuracy: 70%–95%
8	[18]	ML berbasis LMS & Data Akademik	Accuracy: 85%

Tabel 1 menyajikan ringkasan performa keempat metode ensemble yang dikaji. XGBoost [2] menunjukkan performa terbaik dalam konteks dataset besar dan tidak seimbang, dengan AUC-PR 89,5% yang secara khusus robust terhadap ketidakseimbangan kelas. Sementara itu, kombinasi AdaBoost+XGBoost [4] mencapai akurasi tertinggi (97,06%) pada dataset yang lebih kecil namun homogen secara kontekstual.

4.2. Analisis Fitur Prediktor

Sintesis analisis SHAP dari beberapa studi mengungkap hierarki fitur yang konsisten namun bervariasi menurut konteks. Pada level teratas, indikator performa akademik—nilai kumulatif (N_kumulatif), skor ujian, dan tingkat penyelesaian tugas—menjadi prediktor terkuat di semua studi. Hal ini mengonfirmasi bahwa perilaku belajar aktif dan pencapaian akademik merupakan sinyal paling andal untuk deteksi dini dropout.

Temuan yang paling signifikan secara praktis adalah peran kesehatan mental sebagai prediktor kuat yang independen dari performa akademik. [3] menemukan bahwa mahasiswa dengan gangguan kesehatan mental memiliki probabilitas dropout 91,11% bahkan ketika mereka berinteraksi aktif dengan dosen—menunjukkan bahwa interaksi

Seluruh artikel yang memenuhi kriteria kemudian dianalisis secara komparatif untuk mengidentifikasi empat fokus utama kajian, yaitu: (1) efektivitas metode ensemble dibandingkan algoritma lainnya, (2) fitur-fitur prediktor yang paling berpengaruh, (3) dinamika temporal prediksi sepanjang periode akademik, dan (4) implikasi untuk implementasi di pendidikan tinggi Indonesia. Analisis dilakukan dengan pendekatan naratif-komparatif yang menggabungkan elemen meta-analisis kualitatif agar mampu menyajikan gambaran komprehensif tentang penerapan ensemble machine learning dalam prediksi akademik. Harmonisasi metrik dilakukan untuk memungkinkan perbandingan yang valid mengingat heterogenitas dalam pilihan metrik antar studi.

akademik yang baik tidak dapat mengkompensasi tekanan psikologis yang berat. Implikasi ini mendukung integrasi skrining kesehatan mental dalam sistem peringatan dini.

Variabel sosial-ekonomi, terutama HDI kota dan biaya pendidikan, muncul sebagai prediktor signifikan pada jenjang pra-sekolah dalam studi [2]. Temuan ini konsisten dengan literatur yang lebih luas tentang faktor penentu dropout di negara berkembang, termasuk Indonesia, di mana aksesibilitas ekonomi dan ketimpangan regional masih menjadi hambatan utama keberlanjutan studi mahasiswa.

4.3. Dinamika Temporal Prediksi

Analisis temporal menunjukkan pola peningkatan akurasi yang konsisten sepanjang semester di semua studi. Pada Q1 (minggu 1–3), akurasi berkisar antara 85,30–88,49%, mencerminkan keterbatasan data di awal semester. Memasuki Q2 (minggu 4–6), peningkatan signifikan terlihat seiring dengan tersedianya skor tugas dan kuis awal. Q3 (minggu 7–9) menghasilkan akurasi 91,18–94,24%, yang [4] diidentifikasi sebagai jendela intervensi optimal karena kombinasi akurasi tinggi dan ketersediaan waktu untuk intervensi efektif.

Pada Q4 (minggu 10–12), akurasi mencapai puncaknya (94,12–97,06%), namun utilitas prediktif

menurun karena keterbatasan waktu yang tersisa untuk intervensi. Temuan ini memiliki implikasi langsung: institusi pendidikan sebaiknya menetapkan protokol intervensi otomatis pada minggu ke-9 atau ke-10, memanfaatkan jendela optimal di mana akurasi sudah sangat tinggi (>93%) namun masih tersedia waktu 3–4 minggu untuk program pembinaan intensif.

4.4. Implikasi untuk Pendidikan Tinggi Indonesia

Berdasarkan sintesis komprehensif keempat studi, terdapat empat rekomendasi implementasi untuk perguruan tinggi Indonesia. Pertama, institusi perlu memprioritaskan pengumpulan data LMS yang terstruktur, mencakup log aktivitas mahasiswa, skor tugas per pekan, dan jumlah interaksi. Data ini merupakan fondasi yang tidak tergantikan untuk model prediksi yang akurat [1][4]. Kedua, integrasi skrining kesehatan mental ke dalam sistem monitoring akademik sangat direkomendasikan, mengingat temuan [3] yang menunjukkan pengaruh kuat kesehatan mental bahkan di atas faktor interaksi sosial.

Ketiga, penggunaan XGBoost atau AdaBoost dengan integrasi SHAP merupakan pendekatan teknis yang paling terbukti efektif dan dapat diimplementasikan bahkan pada skala kecil (<200 mahasiswa per kelas). Alat SHAP memungkinkan interpretasi yang dapat dipahami oleh konselor akademik non-teknis [2]. Keempat, kalibrasi model secara lokal sangat diperlukan karena karakteristik mahasiswa Indonesia—termasuk variabel sosial-ekonomi, pola interaksi budaya, dan sistem penilaian—berbeda secara signifikan dari konteks studi yang dikaji (Brasil dan Slovakia). Fine-tuning menggunakan dataset lokal diperkirakan dapat meningkatkan akurasi 5–15%.

5. KESIMPULAN DAN SARAN

Kajian sistematis ini telah mensintesis bukti dari beberapa studi terkemuka dan mengonfirmasi bahwa metode ensemble machine learning merupakan pendekatan yang unggul untuk prediksi performa dan dropout mahasiswa dalam lingkungan blended learning. XGBoost dan AdaBoost secara konsisten mengungguli klasifikasi tunggal dengan peningkatan 2–10% pada semua metrik, mencapai akurasi hingga 97,06% pada kondisi optimal. Keunggulan ini tidak hanya bersifat statistis tetapi juga praktis, mengingat bahwa setiap peningkatan akurasi berarti lebih sedikit mahasiswa berisiko yang tidak terdeteksi.

Kontribusi utama kajian ini meliputi identifikasi hierarki fitur prediktor yang konsisten lintas studi—dengan performa akademik, pola interaksi LMS, dan kesehatan mental sebagai triad faktor utama—serta penetapan jendela intervensi optimal pada minggu ke-9 hingga ke-10 semester. Temuan ini memberikan landasan empiris yang kuat bagi perancangan sistem peringatan dini berbasis bukti di perguruan tinggi Indonesia.

Penelitian lanjutan disarankan untuk: (1) mengembangkan dan memvalidasi model prediksi

menggunakan dataset dari perguruan tinggi Indonesia yang merepresentasikan keragaman regional dan karakteristik mahasiswa lokal, (2) menginvestigasi integrasi data multimodal termasuk data kesehatan mental dan indikator sosial-ekonomi regional, dan (3) merancang studi longitudinal untuk mengevaluasi efektivitas intervensi berbasis prediksi model ensemble dalam konteks nyata. Pengembangan framework standar untuk implementasi dan evaluasi sistem peringatan dini di Indonesia juga merupakan agenda riset yang mendesak.

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] 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>
- [6] 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>
- [7] 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>
- [8] 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>
- [9] 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>
- [10] 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>
- [11] 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>
- [12] 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>
- [13] 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>
- [14] 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>
- [15] 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>
- [16] 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>
- [17] 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>
- [18] 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>
- [19] 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>