

Tinjauan Literatur Sistematis: Prediksi Dini Risiko Penurunan Prestasi Akademik Berbasis *Machine Learning*

Roni Habibi^{*1}, Audyardha Nasywa Andini²

^{1,2}Sarjana Terapan Teknik Informatika, Universitas Logistik dan Bisnis Internasional, Indonesia
Email: ¹roni.habibi@ulbi.ac.id, ²714220020@std.ulbi.ac.id

Abstrak

Penurunan performa akademik merupakan permasalahan penting dalam pendidikan karena dapat berdampak pada keberhasilan belajar, motivasi, dan keberlanjutan studi peserta didik. Perkembangan *Educational Data Mining* (EDM), *Machine Learning* (ML), dan *Learning Analytics* mendorong pemanfaatan sistem prediktif untuk mendeteksi risiko akademik sejak dini. Meskipun demikian, sebagian besar penelitian masih menitikberatkan pada prediksi hasil pembelajaran akhir dibandingkan identifikasi dini yang mendukung intervensi preventif. Penelitian ini bertujuan mensintesis perkembangan penelitian terkait prediksi dini risiko penurunan performa akademik serta mengidentifikasi faktor prediktif, pendekatan yang digunakan, dan arah pengembangan sistem *academic early warning*. Kajian dilakukan melalui metode *Systematic Literature Review* (SLR) dengan mengikuti pedoman PRISMA 2020. Proses seleksi menghasilkan 60 studi primer yang dipublikasikan pada periode 2020–2026 dan dianalisis menggunakan pendekatan deskriptif serta tematik. Hasil penelitian menunjukkan bahwa pendekatan ML, khususnya *Random Forest*, *XGBoost*, *Support Vector Machine*, dan *Logistic Regression*, merupakan metode yang paling banyak digunakan, dengan *Random Forest* muncul pada 30 dari 60 studi primer. Sebagian besar penelitian melaporkan akurasi prediksi berada pada kisaran 80%–99%, sementara beberapa model *deep learning* dan *hybrid learning* mampu mencapai akurasi di atas 98%, sehingga menunjukkan peningkatan performa prediksi dibandingkan pendekatan konvensional. Faktor akademik masih menjadi prediktor utama, namun penelitian terkini semakin mengintegrasikan faktor perilaku, keterlibatan belajar, aktivitas digital, pola temporal, dan faktor psikososial. Selain itu, ditemukan bahwa aspek interpretabilitas, adaptivitas, generalisasi lintas institusi, dan dukungan intervensi akademik masih menjadi tantangan utama. Penelitian ini menegaskan pentingnya pengembangan sistem *early warning* yang lebih interpretatif, adaptif, dan berorientasi pada intervensi untuk mendukung pengambilan keputusan pendidikan secara preventif.

Kata kunci: *academic early warning system, educational data mining, machine learning, penurunan performa akademik, student performance prediction.*

Systematic Literature Review Early Prediction of Academic Performance Decline Risk Using Machine Learning

Abstract

Academic performance decline is a significant issue in education because it can affect learning achievement, student motivation, and study persistence. Advances in Educational Data Mining (EDM), Machine Learning (ML), and Learning Analytics have encouraged the adoption of predictive systems to identify academic risks at an early stage. Nevertheless, most existing studies continue to emphasize the prediction of final learning outcomes rather than early identification aimed at supporting preventive interventions. This study aims to synthesize recent research on the early prediction of academic performance decline risk and to identify predictive factors, methodological approaches, and future directions for the development of academic early warning systems. The study employed a Systematic Literature Review (SLR) following the PRISMA 2020 guidelines. A total of 60 primary studies published between 2020 and 2026 were selected and analyzed using descriptive and thematic approaches. The findings indicate that ML-based approaches, particularly Random Forest, XGBoost, Support Vector Machine, and Logistic Regression, remain the most widely used methods, with Random Forest appearing in 30 of the 60 primary studies. Most studies reported predictive accuracies ranging from approximately 80% to 99%, while several deep learning and hybrid learning models achieved accuracies exceeding 98%, demonstrating superior predictive performance compared with conventional approaches. Academic factors continue to serve as the primary predictors; however, recent studies increasingly incorporate behavioral factors, learning engagement, digital activities, temporal patterns, and psychosocial factors. In addition, challenges related to model interpretability, adaptability, cross-institutional generalizability, and support for academic interventions remain

significant concerns. This study highlights the importance of developing more interpretable, adaptive, and intervention-oriented early warning systems to support preventive educational decision-making.

Keywords: *academic early warning system, educational data mining, machine learning, student performance prediction, student risk prediction*

1. PENDAHULUAN

Penurunan performa akademik merupakan tantangan penting dalam pendidikan karena umumnya terjadi secara bertahap [1], [2]. Sebelum mengalami kegagalan akademik yang serius, siswa atau mahasiswa sering menunjukkan berbagai tanda awal, seperti menurunnya keterlibatan belajar, partisipasi yang tidak konsisten, penurunan hasil evaluasi, serta berkurangnya interaksi dalam lingkungan pembelajaran [3], [4], [5]. Jika tidak terdeteksi sejak dini, kondisi tersebut dapat berdampak pada motivasi belajar, persistensi akademik, kondisi psikologis, dan keberlanjutan studi [6], [7], [8]. Oleh karena itu, identifikasi dini terhadap siswa yang berisiko mengalami penurunan performa akademik menjadi bagian penting dari strategi intervensi preventif.

Perkembangan *Educational Data Mining* (EDM) dan *Machine Learning* (ML) telah mendorong pemanfaatan *predictive analytics* dalam pendidikan melalui analisis data yang berasal dari *learning management systems*, platform pembelajaran daring, sistem evaluasi, dan rekam jejak aktivitas belajar [9], [10]. Berbagai penelitian telah menggunakan algoritma *machine learning* untuk memprediksi performa akademik, mengklasifikasikan status kelulusan, dan memperkirakan risiko *dropout* sebagai bagian dari pengembangan *early academic risk prediction*. Hingga saat ini, sebagian besar studi lebih diarahkan pada prediksi capaian akhir pembelajaran (*outcome-oriented prediction*) dibandingkan deteksi dini yang mendukung intervensi preventif (*intervention-oriented prediction*) [11], [12]. Akibatnya, prediksi sering dilakukan ketika penurunan performa akademik telah terlihat, sehingga peluang intervensi dini menjadi terbatas.

Sebagai respons terhadap keterbatasan tersebut, penelitian mulai menyoroti indikator awal risiko penurunan performa akademik. Perubahan pola kehadiran, konsistensi pengumpulan tugas, perilaku belajar daring, partisipasi forum, dan tingkat keterlibatan belajar terbukti dapat menjadi sinyal awal kesulitan akademik [1], [13]. Selain itu, pendekatan *deep learning* berbasis temporal, seperti *Long Short-Term Memory* (LSTM) dan *hybrid CNN-LSTM*, digunakan untuk menangkap pola aktivitas belajar secara berurutan dan meningkatkan sensitivitas deteksi risiko sejak dini [14], [15]. Faktor psikososial, termasuk stres, kecemasan, kondisi emosional, dan motivasi belajar, juga mulai diintegrasikan sebagai indikator potensial risiko akademik [6], [16]. Perkembangan ini menunjukkan pergeseran dari prediksi performa akademik yang bersifat statis menuju sistem *early warning* yang lebih dinamis, multidimensional, dan berorientasi pada intervensi.

Meskipun demikian, literatur tinjauan sistematis masih menunjukkan sejumlah keterbatasan. Sebagian besar *Systematic Literature Review* berfokus pada perbandingan algoritma, akurasi prediksi, seleksi fitur, atau klasifikasi *dropout* [9], [11], sementara kajian mengenai kemampuan model dalam mengidentifikasi sinyal awal penurunan performa akademik untuk mendukung intervensi preventif masih relatif terbatas. Banyak model juga masih bergantung pada indikator akademik konvensional, seperti nilai dan kehadiran, tanpa mengintegrasikan keterlibatan belajar, aktivitas *Learning Management System* (LMS), pola temporal pembelajaran, dan faktor psikososial secara komprehensif [3], [9]. Selain itu, perbedaan karakteristik dataset, strategi evaluasi, metode validasi, dan waktu prediksi menyebabkan rendahnya keterbandingan hasil antarpelitian. Walaupun metrik seperti Accuracy, F1-score, dan AUC banyak digunakan, masih sedikit penelitian yang mengevaluasi sejauh mana model prediktif mampu mendukung intervensi akademik yang praktis, interpretatif, dan tepat waktu [3].

Meskipun berbagai penelitian telah menunjukkan perkembangan yang signifikan dalam prediksi dini risiko penurunan performa akademik, implementasinya masih belum merata pada berbagai jenjang pendidikan. Sebagian besar penelitian yang dikaji berfokus pada konteks pendidikan tinggi atau lingkungan pembelajaran digital yang menghasilkan data perilaku belajar secara rinci, seperti aktivitas *Learning Management System* (LMS), interaksi forum, dan jejak pembelajaran daring [9], [11]. Sementara itu, penerapan pendekatan *early prediction of academic performance decline risk* pada jenjang pendidikan menengah, termasuk sekolah menengah pertama (SMP), masih relatif terbatas. Padahal, sekolah pada umumnya telah memiliki data akademik dan non-akademik yang dikumpulkan secara rutin, seperti nilai mata pelajaran, riwayat capaian akademik, kehadiran, serta aktivitas siswa. Kondisi tersebut menunjukkan bahwa hasil-hasil penelitian mengenai prediksi dini masih memiliki peluang untuk diadaptasi dan diimplementasikan pada berbagai konteks pendidikan, termasuk pendidikan menengah, guna mendukung pengembangan sistem *academic early warning* yang lebih aplikatif.

Berdasarkan kesenjangan tersebut, diperlukan sintesis penelitian yang secara khusus berfokus pada *early prediction of academic decline risk* dalam perspektif *intervention-oriented prediction* dan *academic early warning systems*. Berbeda dengan SLR sebelumnya yang meninjau prediksi performa akademik secara umum atau

klasifikasi *dropout*, penelitian ini menitikberatkan pada identifikasi indikator awal penurunan performa akademik sebelum terjadi kegagalan pembelajaran yang lebih serius. Tinjauan ini tidak hanya membahas perkembangan algoritma *Machine Learning* dan *Educational Data Mining*, tetapi juga mengevaluasi keterkaitan faktor akademik, *behavioral engagement*, pola temporal aktivitas belajar, dan faktor psikososial dalam mendukung deteksi dini risiko akademik. Selain itu, penelitian ini juga mengidentifikasi berbagai upaya untuk meningkatkan interpretabilitas model prediksi dalam konteks pendidikan, termasuk pemanfaatan *Explainable Artificial Intelligence* (XAI) dan pendekatan lain yang bertujuan meningkatkan transparansi, *usability*, serta implementabilitas sistem prediksi pada konteks pendidikan nyata. Dengan menempatkan prediksi sebagai bagian dari sistem intervensi preventif berbasis *learning analytics*, penelitian ini berkontribusi pada pengembangan *predictive analytics* pendidikan yang lebih adaptif, *interpretable*, dan berorientasi pada pengambilan keputusan berbasis data.

Berdasarkan kesenjangan penelitian yang telah diidentifikasi, *Systematic Literature Review* ini disusun untuk memberikan sintesis dan evaluasi kritis terhadap penelitian terkini mengenai *early prediction of academic performance decline risk* menggunakan pendekatan EDM dan ML. Hasil sintesis diharapkan dapat menjadi landasan konseptual bagi pengembangan sistem *academic early warning* pada berbagai konteks pendidikan, termasuk pendidikan menengah yang masih memiliki peluang pengembangan lebih lanjut. Tinjauan ini berfokus pada tren penelitian, metode prediksi, indikator utama risiko penurunan performa akademik, isu interpretabilitas model, serta pengembangan sistem prediksi yang berorientasi pada intervensi. Secara khusus, penelitian ini menjawab tiga pertanyaan utama: (1) pendekatan *Machine Learning* dan *Educational Data Mining* apa yang paling umum digunakan serta bagaimana pengaruhnya terhadap performa prediksi; (2) faktor akademik, perilaku, keterlibatan belajar, pola temporal, dan psikososial apa yang paling sering dikaitkan dengan indikator awal penurunan performa akademik; dan (3) apa saja *research gap* serta arah pengembangan masa depan dalam membangun sistem *early warning* yang interpretatif, adaptif, dan berorientasi pada intervensi akademik. Dengan fokus pada deteksi dini penurunan performa akademik, penelitian ini diharapkan dapat memperkaya pengembangan *predictive analytics* yang lebih implementatif dan preventif dalam lingkungan pendidikan.

2. METODE PENELITIAN

Kajian ini menerapkan pendekatan *Systematic Literature Review* (SLR) untuk mengevaluasi dan mengidentifikasi, mengintegrasikan, dan mengevaluasi hasil-hasil penelitian yang membahas prediksi dini risiko penurunan performa akademik menggunakan pendekatan *Educational Data Mining* (EDM), *Machine Learning* (ML), dan *Learning Analytics*. Pendekatan SLR dipilih karena memungkinkan proses telaah literatur dilakukan secara terstruktur, transparan, dan mudah direplikasi sehingga dapat memberikan gambaran mengenai perkembangan penelitian, kecenderungan metodologis, serta kesenjangan kajian pada bidang prediksi risiko akademik. Seluruh tahapan *review* mengikuti pedoman *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA 2020) guna menjaga konsistensi dan transparansi selama proses penelusuran, penyaringan, hingga pemilihan literatur.


Penelusuran literatur dilakukan menggunakan *platform* WATASE UAE, yang mendukung eksplorasi dan pengelolaan literatur ilmiah melalui integrasi metadata dari berbagai sumber publikasi akademik. Strategi pencarian disusun dengan memanfaatkan sejumlah kata kunci yang berkaitan dengan *academic performance decline risk*, *early academic risk prediction*, *at-risk students prediction*, *academic failure prediction*, *dropout risk prediction*, *machine learning for student performance prediction*, *educational data mining student performance*, dan *student success prediction*. Untuk menjaga relevansi penelitian terhadap perkembangan terkini, pencarian literatur dibatasi pada publikasi yang terbit pada periode 2020-2026.

Pemilihan artikel dilakukan dengan mengacu pada kriteria inklusi dan eksklusi yang telah ditetapkan guna memastikan setiap studi yang ditinjau relevan dengan tujuan penelitian. Kriteria tersebut meliputi aspek topik penelitian, pendekatan metodologis, kualitas publikasi, ketersediaan dokumen, serta periode publikasi. Rincian kriteria inklusi dan eksklusi yang diterapkan dalam proses seleksi dapat dilihat pada pada Tabel 1.

Tabel 1. Kriteria Inklusi dan Eksklusi

Kriteria	Inklusi	Eksklusi
Tahun Publikasi	2020-2026	Sebelum 2020
Metode	EDM, ML, atau Learning Analytics	Tidak menggunakan pendekatan tersebut
Jenis Publikasi	Artikel dan Prosiding Konferensi	<i>Review</i> , <i>editorial</i> , <i>book chapter</i> , dan tesis
Kualitas	Publikasi Q1-Q4	Di luar Q1-Q4
Bahasa	Bahasa Inggris	Selain Bahasa Inggris

Tahapan seleksi artikel dilaksanakan dengan mengacu pada kerangka PRISMA 2020, yaitu terdiri atas empat fase, yaitu *identification*, *screening*, *eligibility*, dan *included*. Berdasarkan proses pencarian awal diperoleh sebanyak 434 artikel. Setelah melalui tahapan penyaringan berdasarkan kriteria yang telah ditetapkan dan evaluasi relevansi penelitian, diperoleh sebanyak 60 artikel dinyatakan memenuhi kriteria dan ditetapkan yang digunakan dalam sintesis literatur. Rangkaian proses seleksi tersebut disajikan pada Gambar 1.



Gambar 1. Diagram PRISMA

Setelah proses seleksi artikel selesai dilakukan, tahap berikutnya adalah ekstraksi data (data extraction) terhadap 60 studi primer yang memenuhi seluruh kriteria inklusi. Proses ekstraksi dilakukan secara sistematis dengan mengidentifikasi dan mencatat informasi penting dari setiap artikel, meliputi identitas publikasi (penulis dan tahun), pendekatan penelitian, algoritma atau metode yang digunakan, karakteristik dataset, faktor atau variabel prediktor yang dianalisis, metrik evaluasi model, temuan utama, serta research gap dan arah pengembangan yang diusulkan. Informasi tersebut selanjutnya digunakan sebagai dasar dalam proses analisis deskriptif, analisis tematik, serta penyusunan tabel komparatif untuk menjawab *research questions* yang telah ditetapkan.

Untuk menjaga kualitas studi yang dianalisis, setiap artikel dievaluasi berdasarkan kesesuaiannya dengan kriteria inklusi dan eksklusi yang telah ditetapkan. Selain mempertimbangkan reputasi publikasi pada jurnal atau prosiding bereputasi (Q1–Q4), proses penilaian juga dilakukan melalui pemeriksaan manual terhadap relevansi topik penelitian, kesesuaian pendekatan metodologis dengan fokus kajian, serta kelengkapan informasi yang diperlukan dalam proses sintesis, seperti metode yang digunakan, hasil evaluasi model, dan temuan penelitian. Dengan demikian, hanya artikel yang memenuhi seluruh kriteria tersebut yang digunakan dalam proses analisis dan sintesis literatur.

Data yang telah diekstraksi selanjutnya dianalisis menggunakan kombinasi *descriptive analysis* dan *thematic analysis*. Analisis deskriptif digunakan untuk menggambarkan distribusi publikasi berdasarkan tahun, tren penelitian, serta karakteristik umum studi yang dianalisis. Sementara itu, analisis tematik digunakan untuk mengelompokkan dan mensintesis penelitian berdasarkan tujuan prediksi, pendekatan metodologis, algoritma *machine learning* yang digunakan, karakteristik fitur dan dataset, metrik evaluasi model, serta pengembangan *educational early warning systems*. Hasil sintesis selanjutnya digunakan untuk menjawab *research questions* yang telah ditetapkan dan mengidentifikasi tren penelitian, tantangan, serta peluang pengembangan penelitian di masa mendatang terkait prediksi dini risiko penurunan performa akademik.

3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil sintesis terhadap 60 studi primer yang diperoleh melalui proses *Systematic Literature Review* (SLR). Analisis dilakukan untuk menggambarkan karakteristik penelitian, tren perkembangan bidang prediksi dini risiko penurunan performa akademik, serta mendukung pembahasan yang diarahkan untuk menjawab *research questions* yang telah ditetapkan. Hasil sintesis disajikan dalam bentuk distribusi publikasi,

karakteristik penelitian, dan kecenderungan metodologis yang berkembang pada bidang *Educational Data Mining* (EDM), *Machine Learning* (ML), *Learning Analytics*, dan *Educational Early Warning Systems*.

3.1. Hasil


3.1.1. Karakteristik Studi Terpilih

Hasil seleksi artikel sebagaimana dijelaskan pada bagian metode menghasilkan 60 studi primer yang memenuhi seluruh kriteria inklusi dan selanjutnya digunakan dalam proses sintesis literatur. Analisis terhadap studi-studi tersebut dilakukan dengan mempertimbangkan beberapa aspek, meliputi kualitas publikasi, tren publikasi tahunan, sebaran geografis penelitian, pendekatan yang digunakan, area kajian, serta metode analisis yang diterapkan.

Tabel 2. Distribusi Publikasi Kategori


No	Kategori	Jumlah
1	Q1	29
2	Q2	25
3	Q3	5
4	Q4	1
Total		60

Berdasarkan Tabel 2, studi yang terpilih berasal dari publikasi internasional bereputasi yang tersebar pada kategori Q1 hingga Q4. Distribusi tersebut menunjukkan bahwa penelitian mengenai prediksi risiko penurunan performa akademik telah dipublikasikan pada berbagai tingkat kualitas jurnal internasional, sehingga memberikan cakupan literatur yang cukup luas dan representatif untuk dianalisis.




Gambar 2. Tren Publikasi Penelitian Tahun 2020-2026

Gambar 2 menunjukkan tren publikasi penelitian terkait prediksi risiko penurunan performa akademik selama periode 2020-2026. Secara keseluruhan, tren publikasi menunjukkan peningkatan yang konsisten dari tahun ke tahun, dengan jumlah publikasi tertinggi tercatat pada tahun 2025. Temuan ini menunjukkan bahwa pemanfaatan *Educational Data Mining*, *Machine Learning*, dan *Learning Analytics* dalam mendukung prediksi performa akademik semakin memperoleh perhatian dari komunitas akademik.




Gambar 3. Distribusi Negara Asal Penelitian

Berdasarkan Gambar 3, penelitian pada bidang ini berasal dari berbagai negara dengan kontribusi terbesar berasal dari China, diikuti oleh Saudi Arabia, Taiwan, India, Portugal, dan Malaysia. Distribusi tersebut menunjukkan bahwa penelitian mengenai prediksi performa akademik telah berkembang secara global, meskipun sebagian besar kontribusi publikasi masih berasal dari kawasan Asia [17], [18], [3], [6], [8].




Gambar 4. Distribusi Metode Penelitian

Gambar 4 menunjukkan distribusi metode penelitian yang digunakan dalam studi yang direview. Hasil analisis menunjukkan bahwa pendekatan *experimental research* merupakan metode yang paling dominan digunakan dibandingkan pendekatan lainnya. Dominasi pendekatan experimental menunjukkan bahwa sebagian besar penelitian berfokus pada pengembangan, pengujian, dan evaluasi model prediksi berbasis data untuk mengukur efektivitas algoritma yang digunakan [18], [19], [20], [21].



Gambar 5. Distribusi Area Kajian Penelitian

Gambar 5 menunjukkan distribusi area kajian penelitian. Area *socioeconomic and demographic factors* menjadi topik yang paling banyak diteliti, diikuti oleh *digital learning environment*, *at-risk student detection*, dan *behavioral and engagement analysis*. Sementara itu, area *psychological and cognitive factors* memiliki proporsi yang relatif lebih kecil dibandingkan area penelitian lainnya. Temuan ini menunjukkan bahwa penelitian pada bidang prediksi performa akademik masih banyak berfokus pada faktor sosial, demografis, dan perilaku pembelajaran sebagai sumber informasi utama dalam proses prediksi [15], [16], [22], [23].



Gambar 6. Distribusi Jenis Metode Analisis

Berdasarkan Gambar 6, metode *prediction* merupakan metode menjadi analisis yang paling banyak diterapkan pada studi yang ditinjau. Selain itu, metode *analysis*, *regression*, *classification*, dan *clustering* juga digunakan meskipun dengan proporsi yang lebih kecil [24], [25], [26], [27]. Dominasi pendekatan prediktif

menunjukkan bahwa sebagian besar penelitian diarahkan untuk mengembangkan model yang mampu mengidentifikasi risiko penurunan performa akademik secara lebih dini.

Secara keseluruhan, hasil analisis menunjukkan bahwa penelitian mengenai prediksi risiko penurunan performa akademik terus mengalami perkembangan dalam beberapa tahun terakhir. Karakteristik studi yang direview menunjukkan dominasi pendekatan eksperimental, penggunaan metode analisis prediktif, serta fokus penelitian pada faktor sosial, demografis, dan lingkungan pembelajaran digital. Temuan-temuan tersebut memberikan gambaran umum mengenai perkembangan penelitian pada bidang ini dan menjadi dasar untuk pembahasan lebih lanjut dalam menjawab *research questions* yang telah ditetapkan.

Tabel 3. Klasifikasi Algoritma Prediksi yang Digunakan pada Studi Terpilih

Kategori	Algoritma	Jumlah Studi
Machine Learning	<i>Random Forest</i> (RF)	30
	<i>Support Vector Machine</i> (SVM)	23
	<i>Decision Tree</i> (DT)	23
	<i>Logistic Regression</i> (LR)	18
	<i>K-Nearest Neighbors</i> (KNN)	19
	<i>Artificial Neural Network</i> (ANN)	14
Deep Learning	<i>Multi-Layer Perceptron</i> (MLP)	6
	<i>Deep Neural Network</i> (DNN)	5
	<i>Convolutional Neural Network</i> (CNN)	5
	<i>Long Short-Term Memory</i> (LSTM)	4

Tabel 3 menunjukkan bahwa pendekatan *Machine Learning* masih menjadi metode yang paling dominan dalam penelitian prediksi dini risiko penurunan performa akademik. *Random Forest* merupakan algoritma yang paling banyak digunakan, diikuti oleh *Support Vector Machine* (SVM), *Decision Tree*, *Logistic Regression*, dan *K-Nearest Neighbors* (KNN). Berdasarkan hasil sintesis studi primer, dominasi tersebut menunjukkan bahwa algoritma berbasis *supervised learning* dipilih karena mampu memberikan performa prediksi yang stabil pada berbagai karakteristik dataset pendidikan serta relatif mudah diimplementasikan. Beberapa penelitian juga memanfaatkan *Random Forest* sebagai model utama karena mampu menangani hubungan nonlinier dan mengurangi risiko *overfitting*, sedangkan *Logistic Regression* dan SVM lebih sering digunakan sebagai model pembandingan ketika interpretabilitas dan efisiensi komputasi menjadi pertimbangan utama.

Di sisi lain, pendekatan *Deep Learning* seperti *Artificial Neural Network* (ANN), *Deep Neural Network* (DNN), *Convolutional Neural Network* (CNN), dan *Long Short-Term Memory* (LSTM) menunjukkan peningkatan penggunaan terutama pada penelitian yang memanfaatkan data pembelajaran digital dan data temporal. Hasil sintesis menunjukkan bahwa model *Deep Learning* umumnya dipilih ketika penelitian bertujuan menangkap pola hubungan yang lebih kompleks dibandingkan algoritma *Machine Learning* konvensional. Meskipun beberapa studi melaporkan performa prediksi yang lebih tinggi, model tersebut juga memiliki keterbatasan berupa kebutuhan data yang lebih besar, proses pelatihan yang lebih kompleks, dan tingkat interpretabilitas yang relatif lebih rendah. Temuan ini mengindikasikan adanya pergeseran tren penelitian menuju pemanfaatan model yang lebih kompleks seiring meningkatnya ketersediaan data pendidikan berbasis digital.

3.1.2. Analisis Variabel dan Tren Penelitian

Untuk memperoleh pemahaman yang lebih mendalam mengenai fokus penelitian dan karakteristik variabel yang digunakan variabel yang digunakan dalam pengembangan model prediksi risiko penurunan performa akademik, dilakukan analisis terhadap variabel penelitian, metadata artikel, hubungan antarvariabel, serta distribusi variabel yang paling sering digunakan pada studi-studi terpilih. Hasil analisis divisualisasikan menggunakan *word cloud* dan *network visualization* untuk mengidentifikasi pola penelitian yang berkembang dalam bidang ini.




Gambar 7. Wordcloud Variabel Penelitian

Berdasarkan Gambar 7, variabel *Student Academic Performance*, *Academic Performance Decline Risk*, dan *Student Performance* merupakan istilah yang paling dominan muncul dalam literatur. Temuan ini menunjukkan bahwa sebagian besar penelitian berfokus pada pengukuran dan prediksi capaian akademik sebagai indikator utama dalam mengidentifikasi mahasiswa yang berisiko mengalami penurunan performa. Selain itu, variabel lain seperti *Academic Achievement*, *Student Engagement*, *Student Behavioral Engagement*, *Prior Academic Performance*, *Parental Involvement*, dan *Learning Motivation* juga banyak digunakan sebagai faktor prediktif. Hal tersebut mengindikasikan bahwa kajian pada area ini mempertimbangkan aspek akademik sekaligus faktor perilaku, motivasi, serta lingkungan belajar dalam membangun model prediksi yang lebih komprehensif.




Gambar 8. Wordcloud Metadata Artikel

Gambar 8 menunjukkan dominasi istilah seperti *prediction of student academic achievement*, *prediction of student performance and dropout*, *machine learning predictive models*, dan *learning analytics intervention*. Kemunculan istilah-istilah tersebut menunjukkan bahwa penelitian semakin berorientasi pada pengembangan sistem prediktif untuk mendeteksi mahasiswa berisiko sejak dini. Selain itu, istilah seperti *prediction accuracy*, *decision tree and feature selection methods*, serta *application of machine learning techniques* juga muncul dengan frekuensi yang tinggi, yang mengindikasikan bahwa peningkatan performa model dan optimasi metode prediksi masih menjadi fokus utama penelitian. Secara umum, hasil visualisasi metadata menunjukkan bahwa perkembangan penelitian bergerak menuju pemanfaatan *predictive learning analytics* yang mendukung pengambilan keputusan pendidikan berbasis data.



Gambar 9. Grafik Hubungan Antarvariabel

Berdasarkan Gambar 9, faktor *parental involment* menunjukkan hubungan yang kuat dengan performa akademik dan menjadi salah satu faktor yang paling banyak dikaji dalam literatur. Selain itu, berbagai penelitian juga menyoroti hubungan antara latar belakang akademik, *behavioral engagement*, tingkat kehadiran, motivasi belajar, serta keterlibatan mahasiswa dalam proses pembelajaran terhadap capaian akademik. Beberapa studi juga mengaitkan aktivitas pembelajaran digital, seperti penggunaan sumber belajar, aktivitas kuis, dan pemanfaatan *platform* pembelajaran daring, dengan performa akademik maupun risiko penurunan prestasi. Temuan ini menunjukkan bahwa performa akademik dipengaruhi oleh kombinasi berbagai faktor sehingga tidak hanya bergantung pada indikator akademik semata.



Gambar 10. Grafik Variabel

Berdasarkan Gambar 10, hasil visualisasi menunjukkan bahwa penelitian mengenai prediksi risiko penurunan performa akademik masih didominasi oleh variabel yang berkaitan langsung dengan capaian akademik, seperti *student academic performance*, *academic performance decline risk*, dan *student performance*. Di samping itu, berbagai variabel pendukung juga banyak digunakan, antara lain *student engagement*, *prior academic performance*, kehadiran mahasiswa, motivasi belajar, partisipasi dalam pembelajaran, serta karakteristik mata kuliah. Keragaman variabel tersebut menunjukkan bahwa penelitian mulai mengadopsi pendekatan yang lebih holistik dengan mengintegrasikan faktor akademik, perilaku, dan lingkungan pembelajaran untuk meningkatkan kemampuan prediksi model.

Secara umum, hasil analisis variabel dan tren penelitian menunjukkan bahwa pengembangan model prediksi risiko penurunan performa akademik telah berkembang dari pendekatan yang hanya mengandalkan data akademik menuju pendekatan yang memanfaatkan berbagai sumber data multidimensi. Faktor akademik telah menjadi komponen utama dalam proses prediksi, namun faktor keterlibatan mahasiswa, motivasi belajar, lingkungan pembelajaran, serta aktivitas digital semakin banyak diintegrasikan untuk memperkuat kinerja model dalam mengidentifikasi mahasiswa berisiko secara komprehensif dan lebih tepat.

3.1.3. Ringkasan Temuan Umum Studi

Untuk memperoleh gambaran yang lebih sistematis mengenai perkembangan metode, performa model, serta arah penelitian pada bidang prediksi risiko penurunan performa akademik, dilakukan analisis komparatif terhadap studi-studi primer yang paling relevan. Ringkasan hasil komparasi disajikan pada Tabel 3.

Tabel 4. Tabel Komparatif

No	Penulis	Model Algoritma	Jenis Pendekatan	Evaluasi Metrik	Gap dan Arah Penelitian
[28]	Bouallegue et al. (2026)	XGBoost Regressor	<i>Machine Learning</i>	Accuracy >91%; R ² = 86,99%	Generalisasi lintas institusi dan prediksi lebih dini masih diperlukan.
[29]	Qiang et al. (2026)	ANN + SPPE + SHAP	<i>Deep Learning Explainable Artificial Intelligence (XAI)</i>	Accuracy meningkat 26,9%	Validasi pada dataset yang lebih besar dan dinamis masih diperlukan.
[30]	Alfaraj et al. (2026)	<i>Structural Equation Modeling (SEM)</i>	<i>Statistical Modeling</i>	r=0.467, β =0.91, R ² =0.299	Integrasi ML dan data perilaku digital belum dieksplorasi.
[7]	Lee & Mendoza (2025)	<i>Linear Mixed Effects Model</i>	<i>Statistical Analysis</i>	B Reading=15.23, Math=12.03	Belum mendukung prediksi individual dan monitoring real-time.
[17]	Xiuguo (2025)	CNN-BiLSTM	<i>Deep Learning Multimodal</i>	Accuracy = 95.5%	Pengujian lintas universitas dan sumber data tambahan diperlukan.
[18]	Alnasyan et al. (2025)	SAINT Transformer	<i>Deep Learning</i>	Accuracy = 94.33%	Interpretabilitas dan temporal learning masih perlu dikembangkan.
[3]	Rizwan et al. (2025)	LSTM, CNN, Hybrid DL	<i>Systematic Literature Review</i>	Mayoritas studi >90% Accuracy	<i>Framework</i> perlu divalidasi menggunakan data MOOC nyata.
[16]	Bielik et al. (2025)	<i>Random Forest Regression</i>	<i>Machine Learning</i>	OOB R ² = 0.12–0.13	Faktor akademik dan perilaku perlu dikombinasikan dengan faktor kesehatan.
[24]	Wang & Yu (2025)	<i>Logistic Regression with Taylor Expansion</i>	<i>Machine Learning</i>	Accuracy = 93.3%; F1 = 96.6%	Faktor psikologis dan emosional belum dipertimbangkan.
[19]	Zhang et al. (2025)	GNN-TINet	<i>Hybrid Deep Learning</i>	Accuracy = 98.5%; AUC = 0.99	Kompleksitas model dan implementasi praktis masih menjadi tantangan.
[20]	Alazmi & Ayub (2025)	EffiXNet	<i>Hybrid Deep Learning</i>	Acc=98.46%, AUC=99.75%	Validasi eksternal dan penyederhanaan model masih diperlukan.
[21]	Lagares et al. (2025)	AutoML Ensemble (AutoGluon)	<i>Ensemble Learning</i>	Acc=95.48%, F1=95.22%	Interpretabilitas dan implementasi real-time masih menjadi tantangan.
[31]	Kesgin et al. (2025)	<i>Logistic Regression</i>	<i>Machine Learning</i>	Acc=96.2%, AUC=98.7%	Ketergantungan pada nilai historis membatasi generalisasi model.

No	Penulis	Model Algoritma	Jenis Pendekatan	Evaluasi Metrik	Gap dan Arah Penelitian
[22]	Angeioplastis et al. (2025)	<i>Neural Network</i>	<i>Educational Data Mining</i>	F1-Score = 0.934	Faktor perilaku dan sosial perlu diintegrasikan.
[32]	Sayed et al. (2025)	Random Forest, XGBoost, Ensemble Model	<i>Machine Learning</i>	Acc=74.25%, R ² =0.38	Perlu dataset lebih beragam dan model nonlinear yang lebih kuat.
[33]	Li (2025)	<i>Genetic Algorithm + Graph Convolutional Neural Network (GGCNN)</i>	<i>Deep Learning</i>	Acc=98%, R ² =0.982	Skalabilitas dan interpretabilitas model masih terbatas.
[25]	Yu et al. (2024)	<i>Random Forest</i>	<i>Machine Learning</i>	Acc=77.08%, F1=0.629	Perlu peningkatan kemampuan prediksi dan validasi dataset besar.
[6]	Zhang et al. (2024)	XGBoost	<i>Machine Learning</i>	Acc=84%, F1=75%	Data psikologis longitudinal dan faktor eksternal perlu ditambahkan.
[34]	Bellaj et al. (2024)	<i>Ensemble Voting Classifier</i>	<i>Machine Learning</i>	Acc=86%, AUC=95%	Perlu integrasi data psikologis dan dataset yang lebih beragam.
[35]	Abdul (2024)	<i>Neural Networkk Shrinking Algorithm</i>	<i>Neural Network</i>	Error=3.76%–6.43%	Generalisasi lintas mata kuliah dan pengajar perlu diuji.
[23]	Arya et al. (2024)	CNN-LSTM	<i>Hybrid Deep Learning</i>	Acc=98.45%	Validasi lintas institusi dan mitigasi <i>overfitting</i> masih diperlukan.
[36]	Cu et al. (2024)	I-ADASYN / I-SMOTE + ML	<i>Machine Learning</i>	F1 hingga 97.1%, ROC meningkat 8%	Fokus masih pada imbalance handling, belum mengeksplorasi faktor risiko secara mendalam.
[37]	Ahmed (2024)	<i>Support Vector Machine</i>	<i>Machine Learning</i>	Acc=96.03%, Recall=98.43%	Faktor perilaku dan psikologis perlu diintegrasikan untuk meningkatkan prediksi.
[26]	Zhang et al. (2024)	KN-CF (Knowledge Graph + CF)	<i>Knowledge Graph Learning</i>	RMSE=0.8929, MAE=0.6418	Belum mendukung identifikasi <i>at-risk student</i> secara langsung.
[8]	Khan et al. (2024)	OTE-OOB Ensemble	<i>Machine Learning</i>	Acc=87.2%, Kappa=0.695	Perlu validasi pada populasi yang lebih luas dan beragam.
[12]	Alalawi et al. (2024)	SPPA Framework	<i>Learning Analytics</i>	Acc=96.6%, F1=98.2%	Integrasi LMS dan faktor non-akademik

No	Penulis	Model Algoritma	Jenis Pendekatan	Evaluasi Metrik	Gap dan Arah Penelitian
					masih perlu dikembangkan.
[38]	Sengupta (2023)	<i>Random Forest</i>	<i>Machine Learning</i>	Acc=85.13%, F1=85.44%	Belum memanfaatkan data <i>real-time</i> dan intervensi adaptif.
[39]	Nachouki et al. (2023)	<i>Random Forest</i>	<i>Machine Learning</i>	Acc=90.33%, MAE=7.11	Faktor psikologis dan perilaku belajar belum dievaluasi.
[40]	Mastour et al. (2023)	<i>Random Forest</i>	<i>Machine Learning</i>	Acc=80.3%, AUC=0.813, R ² =0.80	Generalisasi dan penanganan imbalance masih perlu ditingkatkan.
[4]	Kaensar & Wongnin (2023)	<i>Decision Tree</i>	<i>Predictive Analytics</i>	F1=81.10%, Acc=80.0%	Perlu integrasi data non-LMS dan validasi lintas mata kuliah.
[41]	Al-Azazi & Ghurab (2023)	ANN-LSTM	<i>Deep Learning</i>	Acc=72%, F1=68%	Perlu peningkatan akurasi awal kursus dan penanganan data imbalance.
[42]	Asthana et al. (2023)	<i>Linear Regression</i>	<i>Machine Learning</i>	R ² =0.97, RMSE=0.0149	Validasi pada dataset yang lebih besar masih diperlukan.
[15]	Liu et al. (2023)	MCAG	<i>Hybrid Deep Learning</i>	Acc=94.22%, F1=94.89%	Faktor eksternal dan validasi lintas institusi perlu ditambahkan.
[43]	Chen et al. (2023)	RMHNN	<i>Graph Deep Learning</i>	Acc=93.10%, F1=90.45%	Faktor psikologis dan sosial ekonomi belum terakomodasi.
[44]	Santamaria et al. (2023)	<i>Artificial Neural Network</i>	<i>Deep Learning</i>	Acc=82.4%, F1=89.3%	Perlu penambahan fitur perilaku dan dataset yang lebih beragam.
[2]	Meghji et al. (2023)	<i>SMO Classifier</i>	<i>Educational Data Mining</i>	Acc=93.13%, F1=93.5%	Generalisasi lintas program studi dan faktor non-akademik perlu dikaji.
[45]	Kamal et al. (2022)	<i>Back Propagation Neural Network (BPNN)</i>	<i>Metaheuristic-Based ML</i>	Acc=94%, Sens=95%	Perlu integrasi indikator tambahan dan sistem prediksi adaptif.
[27]	Raheema et al. (2022)	ANFIS	<i>Neuro-Fuzzy System</i>	Acc=99.1%, RMSE=0.0965	Variabel prediktor masih terbatas dan perlu diperluas.
[1]	Queiroga et al. (2022)	<i>Random Forest</i>	<i>Learning Analytics</i>	AUROC=0.91–0.96, F1=0.91–0.95	Otomatisasi data dan pembaruan model masih diperlukan.

No	Penulis	Model Algoritma	Jenis Pendekatan	Evaluasi Metrik	Gap dan Arah Penelitian
[46]	Huynh-Cam et al. (2022)	<i>Random Forest, SVM</i>	<i>Machine Learning</i>	Acc=98.6–100%, AUC=1.00	Prediksi jangka panjang dan faktor perilaku belum dieksplorasi.
[47]	Tao et al. (2022)	<i>Deep Neural Network (DNN)</i>	<i>Deep Learning</i>	MAE=0.0865, PUDA=80.95%	Faktor perilaku dan data eksternal perlu diintegrasikan.
[48]	Yağcı (2022)	<i>Random Forest</i>	<i>Machine Learning</i>	Acc=74.6%, AUC=0.86	Variabel prediktor masih sangat terbatas dan perlu diperluas.
[49]	Yu et al. (2022)	<i>Graph Neural Network (GNN)</i>	<i>Graph Deep Learning</i>	Grade Error=0.22%, Rank Error=1.67%	Perlu validasi dengan data yang lebih besar dan beragam.
[50]	Reyes et al. (2022)	<i>Structural Equation Modeling (SEM)</i>	<i>Statistical Modeling</i>	CFI=0.929, RMSEA=0.038, R ² =0.24	Belum mendukung prediksi otomatis berbasis machine learning.
[5]	Su et al. (2022)	<i>Neural Network</i>	<i>Machine Learning</i>	Acc=81.3%, F1=88.0%	Ukuran sampel kecil dan konteks pembelajaran terbatas.
[14]	Chen et al. (2022)	<i>Conv-LSTM</i>	<i>Deep Learning</i>	Acc=91%, F1=91%	Kompleksitas model dan interpretabilitas masih menjadi tantangan.
[51]	Wang et al. (2022)	<i>Support Vector Classifier (SVC)</i>	<i>Machine Learning</i>	Acc=86.18%, Recall=82.83%	Perlu integrasi data perilaku digital dan data akademik aktual.
[52]	Feng et al. (2022)	<i>K-Means + CNN</i>	<i>Hybrid Learning</i>	Acc=88.89%– 92.50%	Dataset kecil dan validasi model masih terbatas.
[53]	Nabil et al. (2021)	<i>Deep Neural Network (DNN)</i>	<i>Deep Learning</i>	Acc=89%, F1=89%	Prediksi masih bergantung pada data akademik historis saja.
[54]	Lincke et al. (2021)	<i>XGBoost</i>	<i>Machine Learning</i>	Acc=94%, F1=89.5%	Faktor demografis dan konteks belajar belum dimanfaatkan optimal.
[10]	Zhang et al. (2021)	<i>Random Forest</i>	<i>Educational Data Mining</i>	Acc=75%, ANN=82–94%	Perlu dataset terbuka dan model yang lebih spesifik terhadap domain pendidikan.
[55]	Nuankaew et al. (2021)	<i>Decision Tree + Forward Selection</i>	<i>Machine Learning</i>	Acc=82.29%, Precision=85.59%	Validasi lintas institusi dan pengembangan sistem monitoring masih diperlukan.
[56]	Aslam et al. (2021)	<i>Dense Neural Network</i>	<i>Deep Learning</i>	Acc=96.4%, F1=96.2%	Perlu pengujian pada dataset yang lebih besar dan seimbang.

No	Penulis	Model Algoritma	Jenis Pendekatan	Evaluasi Metrik	Gap dan Arah Penelitian
[11]	Sekeroglu et al. (2021)	<i>Neural-Based Models</i> (SLR)	<i>Systematic Literature Review</i>	Neural models dominan 32.95% studi	Standarisasi evaluasi dan dataset global masih menjadi kebutuhan utama.
[9]	Albreiki et al. (2021)	<i>Ensemble & Deep Learning</i> (SLR)	<i>Systematic Literature Review</i>	Acc=75–96% (berbagai studi)	Fitur temporal dan data dinamis masih kurang dimanfaatkan.
[57]	Maurya et al. (2021)	<i>Stochastic Gradient Descent</i> (SGD)	<i>Machine Learning</i>	Acc=91.17%, AUC=0.67	Faktor non-akademik seperti soft skills dan pengalaman perlu ditambahkan.
[58]	Bujang et al. (2021)	<i>Random Forest</i>	<i>Machine Learning</i>	Acc=99.5%, F1=99.5%	Perlu eksplorasi teknik balancing dan ensemble yang lebih beragam.
[59]	Zhang et al. (2020)	<i>Graph Regularized Robust Matrix Factorization</i> (GRMF)	<i>Matrix Factorization</i>	Acc=65.4%	Penanganan sparsity dan noise data masih perlu ditingkatkan.
[13]	Hasan et al. (2020)	<i>Random Forest</i>	<i>Learning Analytics</i>	Acc=88.3%, F1=93.3%	Integrasi dashboard analitik dan evaluasi multi-kursus perlu dikembangkan.
[60]	Hooshyar et al. (2020)	PPP + <i>Neural Network</i>	<i>Educational Data Mining</i>	Acc=96.5%, F1=97.5%	Faktor risiko selain procrastination perlu diintegrasikan.

Tabel 3 menyajikan ringkasan komparatif dari 60 studi primer yang membahas prediksi risiko penurunan prestasi akademik menggunakan berbagai pendekatan analitik, mulai dari metode statistik, *machine learning*, *deep learning*, hingga pendekatan *hybrid* dan *educational data mining*. secara umum, penelitian pada bidang ini menunjukkan peningkatan pemanfaatan teknik kecerdasan buatan untuk mengidentifikasi mahasiswa berisiko secara lebih akurat dan lebih dini. Berbagai model seperti *Random Forest*, XGBoost, SVM, *Logistic Regression*, *Artificial Neural Network*, CNN-LSTM, *Transformer*, hingga *Graph Neural Network* telah diterapkan dengan tingkat performa yang bervariasi [1], [6], [17], [18], [19]. Selain itu, beberapa studi tinjauan sistematis juga menunjukkan bahwa pendekatan berbasis *deep learning* dan model *ensemble* menjadi tren dominan dalam penelitian prediksi performa akademik selama beberapa tahun terakhir [3], [9], [11].

Berdasarkan analisis terhadap model yang digunakan, pendekatan *machine learning* masih menjadi metode yang paling banyak diterapkan, terutama *Random Forest*, XGBoost, *Logistic Regression*, dan *Support Vector Machine* [1], [6], [31], [37], [54]. *Random Forest* merupakan algoritma yang paling banyak diterapkan karena mampu mengolah data pendidikan yang heterogen dan menghasilkan performa yang relatif stabil pada berbagai dataset [1], [25], [38], [39], [58]. Di sisi lain, penelitian yang lebih baru menunjukkan pergeseran menuju model *deep learning* dan *hybrid learning* seperti CNN-BiLSTM, CNN-LSTM, SAINT Transformer, GGCNN, MCAG, GNN-TINet, serta EffiXNey yang mampu mencapai akurasi di atas 94% bahkan mendekati 99% pada beberapa kasus [17], [18], [19], [20], [33], [23]. Temuan ini menunjukkan adanya kecenderungan pemanfaatan model yang lebih kompleks untuk menangkap hubungan nonlinier pada pola temporal dalam data akademik.

Dari sisi performa, sebagian besar studi melaporkan hasil yang sangat baik dengan nilai akurasi berada pada rentang 80%-99%, sementara beberapa model *deep learning* dan *ensemble* berhasil mencapai akurasi di atas 95% [17], [20], [21], [37], [27], [46], [56], . Selain akurasi, metrik seperti F1-Score, AUC, AUROC, *Recall*, dan R² juga banyak digunakan untuk mengevaluasi kemampuan model dalam mengidentifikasi mahasiswa berisiko secara lebih seimbang [24], [19], [34], [58]. Namun demikian, tingginya performa model belum selalu diikuti oleh kemampuan generalisasi yang baik karena sebagian besar penelitian masih menggunakan dataset tunggal, konteks institusi yang terbatas, serta data akademik historis sebagai sumber informasi utama [2], [16], [25], [44], [53].

Analisis terhadap *research gap* menunjukkan adanya beberapa tantangan yang muncul secara konsisten pada berbagai penelitian. Tantangan tersebut meliputi keterbatasan generalisasi lintas institusi, minimnya integrasi faktor non-akademik seperti kondisi psikologis, sosial-ekonomi, perilaku belajar, dan aktivitas digital mahasiswa, serta rendahnya perhatian terhadap aspek interpretabilitas dan implementasi *real-time* [29], [30], [24], [22], [37], [43], [47]. Selain itu, beberapa studi juga menyoroti kebutuhan akan penggunaan data longitudinal, validasi eksternal, serta penerapan *early warning systems* yang mampu memberikan intervensi secara adaptif [28], [18], [38], [45], [55]. Temuan ini menunjukkan bahwa penelitian selanjutnya perlu mengarah pada pengembangan model prediksi yang tidak hanya memiliki akurasi tinggi, tetapi juga mampu diimplementasikan secara praktis, transparan, dan adaptif dalam lingkungan pendidikan yang beragam.

3.2. Pembahasan

3.2.1. RQ1 Bagaimana pendekatan *Machine Learning* dan *Educational Data Mining* yang paling umum digunakan dalam prediksi dini risiko penurunan performa akademik serta bagaimana pengaruhnya terhadap performa prediksi?

Berdasarkan sintesis terhadap 60 studi primer, pendekatan *Machine Learning* (ML) merupakan metode yang paling dominan digunakan dalam prediksi dini risiko penurunan performa akademik dibandingkan pendekatan *Educational Data Mining* (EDM), *Learning Analytics*, maupun metode statistik konvensional. Algoritma yang paling sering diterapkan meliputi *Random Forest*, *XGBoost*, *Logistic Regression*, *Support Vector Machine* (SVM), dan *Decision Tree* [1], [6], [26], [35], [54]. Dominasi pendekatan tersebut menunjukkan bahwa model berbasis ML dinilai efektif dalam menangani karakteristik data pendidikan yang kompleks, heterogen, dan multidimensional. Secara khusus, *Random Forest* menjadi algoritma yang paling banyak digunakan karena mampu menangani data dengan jumlah fitur yang besar, mengurangi risiko *overfitting*, dan memberikan performa yang relatif stabil pada berbagai konteks pendidikan [1], [25], [38], [39], [58].

Selain dominasi model *machine learning* tradisional, hasil sintesis juga menunjukkan peningkatan penggunaan pendekatan *Deep Learning* dan *hybrid learning* dalam beberapa tahun terakhir. Berbagai model seperti CNN-BiLSTM, CNN-LSTM, SAINT Transformer, *Graph Neural Network* (GNN), GNN-TINet, MCAG, serta EffiXNet mulai banyak digunakan untuk menangkap hubungan nonlinier dan pola temporal yang kompleks dalam data akademik [17], [18], [19], [20], [33], [23]. Perkembangan ini menunjukkan adanya pergeseran dari pendekatan prediktif berbasis fitur statis menuju model yang mampu memanfaatkan informasi perilaku, aktivitas digital, dan riwayat pembelajaran secara lebih mendalam. Temuan ini juga sejalan dengan hasil studi tinjauan sebelumnya yang menunjukkan bahwa model ensemble dan deep learning menjadi tren utama dalam penelitian prediksi performa akademik modern [3], [9], [11].

Dari sisi performa prediksi, model *ensemble* dan *deep learning* secara umum menunjukkan hasil yang lebih unggul dibandingkan algoritma tradisional. Beberapa penelitian melaporkan tingkat akurasi di atas 95%, bahkan mendekati 99% pada model seperti EffiXNet, GNN-TINet, GGCNN, ANFIS, dan berbagai pendekatan *ensemble learning* [19], [20], [21], [33], [27], [46]. Sementara itu, algoritma yang lebih sederhana seperti *Logistic Regression*, *Decision Tree*, dan SVM tetap menunjukkan performa yang kompetitif dengan keunggulan pada aspek interpretabilitas dan kemudahan implementasi [4], [24], [37], [51]. Dengan demikian, dapat disimpulkan bahwa pendekatan *Machine Learning* masih menjadi metode yang paling umum digunakan dalam prediksi dini risiko penurunan performa akademik, sedangkan model *ensemble* dan *deep learning* memberikan kontribusi terbesar terhadap peningkatan akurasi prediksi, walaupun masih terdapat kendala dalam aspek generalisasi, kerumitan model, dan interpretasi hasil.

3.2.2. RQ2 Faktor akademik, perilaku, keterlibatan belajar, pola temporal, dan psikososial apa saja yang paling sering dikaitkan dengan indikator awal penurunan performa akademik?

Berdasarkan sintesis terhadap 60 studi primer, faktor akademik merupakan kelompok faktor yang paling sering dikaitkan dengan indikator awal penurunan performa akademik. Variabel yang paling dominan meliputi nilai akademik sebelumnya (prior academic performance), GPA, nilai kuis, nilai ujian, hasil tugas, tingkat penyelesaian pekerjaan rumah, serta riwayat kegagalan mata kuliah [33], [26], [41], [42], [56]. Temuan ini juga sejalan dengan hasil visualisasi pada Gambar 7 dan Gambar 10 menunjukkan dominasi variabel seperti *student academic performance*, *academic achievement*, dan *prior academic performance*. Beberapa penelitian bahkan menemukan bahwa nilai semester awal, GPPA pra-perkuliahan, dan performa pada mata kuliah prasyarat merupakan prediktor yang sangat kuat dalam mengidentifikasi mahasiswa yang berpotensi mengalami penurunan prestasi akademik pada periode berikutnya [39], [41], [42], [36].

Selain faktor akademik, faktor perilaku dan keterlibatan belajar (learning engagement) juga menjadi indikator yang sangat sering digunakan dalam model prediksi. Faktor-faktor tersebut meliputi tingkat kehadiran, partisipasi

kelas, aktivitas pada *Learning Management Systems* (LMS), frekuensi login, akses sumber belajar, aktivitas forum diskusi, interaksi pembelajaran digital, durasi belajar, serta penyelesaian tugas dan kuis [28], [21], [32], [25], [6], [23].

Faktor lain yang juga banyak dikaitkan dengan risiko penurunan performa akademik adalah faktor temporal dan psikososial. Faktor temporal mencakup pola perkembangan nilai dari waktu ke waktu, riwayat performa akademik, progres belajar longitudinal, serta perubahan perilaku belajar selama proses pembelajaran berlangsung [25], [6], [37], [47]. Sementara itu, faktor psikososial meliputi motivasi belajar, *self-regulation*, *growth mindset*, metacognitive awareness, kesehatan mental, dukungan orang tua (*parental involvement*), pengaruh teman sebaya, dan kondisi sosial-ekonomi [3], [26], [4], [54], [60]. Temuan ini memperlihatkan bahwa penurunan performa akademik tidak dapat dijelaskan hanya melalui kemampuan akademik, melainkan juga merupakan hasil interaksi antara faktor akademik, perilaku belajar, keterlibatan mahasiswa, dinamika temporal, dan kondisi psikososial. Oleh karena itu, penelitian terkini mulai mengarah pada pemanfaatan data multidimensi untuk meningkatkan akurasi identifikasi mahasiswa berisiko secara lebih dini dan komprehensif.

3.2.3. RQ3 Apa saja *research gap* dan arah pengembangan masa depan dalam membangun sistem *early warning* yang interpretatif, adaptif, dan berorientasi pada intervensi akademik?

Berdasarkan studi yang direview, terdapat tiga *research gap* utama dalam pengembangan *academic early warning systems*. Pertama, meskipun banyak penelitian berhasil mencapai performa prediksi yang tinggi, sebagian besar model masih berfokus pada akurasi prediksi dan bergantung pada data akademik historis seperti nilai dan kehadiran. Integrasi faktor perilaku, psikologis, sosial, dan kesehatan masih relatif terbatas, padahal faktor-faktor tersebut berpotensi menjadi indikator awal penurunan performa akademik yang lebih sensitif [16], [24], [37], [39], [43]. Temuan ini menunjukkan perlunya pengembangan model yang lebih multidimensional untuk meningkatkan kemampuan deteksi dini risiko akademik.

Kedua, aspek interpretabilitas dan adaptivitas model masih menjadi tantangan yang signifikan. Sejumlah penelitian berbasis deep learning dan model hibrida menunjukkan performa yang sangat tinggi, namun sering kali sulit dijelaskan dan diimplementasikan dalam lingkungan pendidikan nyata [19], [20], [21], [33]. Walaupun konsep *Explainable Artificial Intelligence* (XAI) mulai diperkenalkan guna meningkatkan transparansi model [29], pemanfaatannya masih terbatas. Selain itu, banyak model belum mampu melakukan pembelajaran temporal dan pembaruan secara real-time sehingga kurang responsif terhadap perubahan perilaku belajar siswa yang bersifat dinamis [18], [38].

Ketiga, mayoritas penelitian masih menggunakan konteks institusi atau dataset tertentu sehingga kemampuan generalisasi dan penerapan lintas lingkungan pendidikan belum teruji secara memadai [17], [23], [28], [35]. Dengan mempertimbangkan kondisi tersebut, penelitian selanjutnya perlu difokuskan pada pengembangan sistem *early warning* yang tidak hanya akurat, tetapi juga interpretatif, adaptif, dan berorientasi pada intervensi akademik. Integrasi data akademik, perilaku digital, dan faktor psikososial, pemanfaatan teknik XAI, serta pengembangan dashboard intervensi yang mampu memberikan rekomendasi tindakan bagi guru atau dosen menjadi langkah penting untuk mewujudkan sistem pendukung keputusan yang lebih aplikatif dan preventif dalam pendidikan [12], [13], [29].

Tabel 5. Perbandingan Penelitian Terdahulu dan Arah Pengembangan Sistem

Ref	SMP	<i>Academic Score</i>	<i>Attendance</i>	<i>Extracurricular</i>	<i>Explainable</i>	<i>Early Warning</i>	<i>Intervention</i>
[31]	✓	✓	✓		✓	✓	
[29]	✓	✓	✓	✓	✓		
[8]		✓	✓			✓	
[28]		✓				✓	
<i>Proposed Future Research</i>	✓	✓	✓	✓	✓	✓	✓

Catatan: Aktivitas ekstrakurikuler diusulkan sebagai peluang pengembangan penelitian berdasarkan masih terbatasnya pembahasan mengenai indikator non-akademik pada studi-studi yang direview.

Tabel 5 menunjukkan bahwa penelitian terdahulu telah memanfaatkan berbagai faktor untuk memprediksi performa akademik, seperti nilai akademik, kehadiran, aktivitas pembelajaran digital, serta pendekatan *early warning*. Beberapa penelitian juga telah menerapkan *Explainable Artificial Intelligence* (XAI) dan mengembangkan sistem pada konteks pendidikan menengah. Namun demikian, hasil sintesis menunjukkan bahwa

sebagian besar penelitian masih berfokus pada faktor-faktor akademik dan perilaku belajar, sedangkan pemanfaatan indikator non-akademik yang merepresentasikan keterlibatan siswa dalam lingkungan sekolah masih relatif terbatas. Salah satu contoh indikator yang masih jarang dieksplorasi adalah aktivitas ekstrakurikuler, padahal secara konseptual aktivitas tersebut berpotensi merefleksikan keterlibatan siswa, kedisiplinan, kemampuan manajemen waktu, dan interaksi sosial yang dapat melengkapi informasi akademik dalam proses identifikasi dini risiko penurunan performa akademik.

Berdasarkan temuan tersebut, arah pengembangan penelitian selanjutnya adalah membangun sistem *academic early warning* yang mengintegrasikan data akademik, kehadiran, perilaku belajar, serta indikator non-akademik yang masih belum banyak dimanfaatkan dalam penelitian sebelumnya, termasuk aktivitas ekstrakurikuler apabila tersedia pada konteks institusi yang diteliti. Integrasi indikator tersebut perlu didukung dengan pendekatan *Explainable Artificial Intelligence* (XAI) dan mekanisme rekomendasi intervensi akademik sehingga sistem tidak hanya mampu mengidentifikasi tingkat risiko siswa, tetapi juga memberikan informasi yang lebih mudah dipahami serta mendukung pengambilan keputusan yang lebih efektif bagi guru maupun pihak sekolah.

4. KESIMPULAN

Penelitian ini melakukan *Systematic Literature Review* terhadap 60 studi primer yang membahas prediksi dini risiko penurunan performa akademik menggunakan pendekatan *Educational Data Mining*, *Machine Learning*, dan *Learning Analytics*. Hasil sintesis menunjukkan bahwa pendekatan *machine learning*, khususnya *Random Forest*, *XGBoost*, *Support Vector Machine*, dan *Logistic Regression*, masih menjadi metode yang paling banyak digunakan, sementara model *deep learning* dan *hybrid learning* menunjukkan kecenderungan peningkatan performa prediksi. Selain itu, faktor akademik seperti nilai dan riwayat capaian belajar tetap menjadi prediktor utama, namun penelitian terkini semakin mengintegrasikan faktor perilaku, keterlibatan belajar, aktivitas digital, pola temporal, serta faktor psikososial untuk meningkatkan kemampuan deteksi dini risiko akademik.

Kajian ini juga menunjukkan bahwa pengembangan sistem prediksi telah bergerak dari sekadar menghasilkan akurasi tinggi menuju pembangunan *academic early warning systems* yang lebih komprehensif. Meskipun demikian, masih terdapat berbagai tantangan, antara lain keterbatasan generalisasi model lintas institusi, rendahnya integrasi data multidimensi, serta kurangnya interpretabilitas dan dukungan intervensi akademik yang praktis. Berdasarkan temuan tersebut, penelitian selanjutnya perlu diarahkan pada perancangan sistem *early warning* yang mampu beradaptasi, interpretatif, dan berorientasi pada intervensi melalui integrasi data akademik, perilaku belajar, aktivitas digital, serta faktor psikososial guna mendukung pengambilan keputusan pendidikan yang lebih efektif dan preventif.

Secara praktis, hasil sintesis penelitian ini dapat menjadi referensi bagi pengembang *academic early warning system*, institusi pendidikan, serta pengambil kebijakan dalam merancang sistem prediksi yang tidak hanya berorientasi pada akurasi, tetapi juga mampu mendukung intervensi akademik secara tepat waktu. Temuan mengenai pentingnya integrasi faktor akademik, perilaku belajar, aktivitas digital, pola temporal, dan faktor psikososial dapat dijadikan dasar dalam pengembangan sistem yang lebih adaptif, interpretatif, dan sesuai dengan kebutuhan institusi pendidikan. Selain itu, hasil sintesis ini juga diharapkan dapat menjadi acuan bagi peneliti dan pengembang teknologi pendidikan dalam merancang model prediksi yang lebih implementatif, transparan, dan mampu mendukung pengambilan keputusan berbasis data pada berbagai konteks pendidikan.

DAFTAR PUSTAKA

- [1] E. M. Queiroga, M. Francisco, B. Machado, V. R. Paragarino, T. T. Primo, and C. Cechinel, "Early Prediction of At-Risk Students in Secondary Education: A Countrywide K-12 Learning Analytics Initiative in Uruguay," *Information*, vol. 13, pp. 1–25, 2022, doi: 10.3390/info13090401.
- [2] A. F. Meghji, N. A. Mahoto, Y. Asiri, H. Alshahrani, A. Sulaiman, and A. Shaikh, "Early Detection of Student Degree-level Academic Performance Using Educational Data Mining," *PeerJ Comput. Sci.*, vol. 9, pp. 1–29, 2023, doi: 10.7717/peerj-cs.1294.
- [3] S. Rizwan, C. K. E. N. Nee, S. Member, and S. Garfan, "Identifying the Factors Affecting Student Academic Performance and Engagement Prediction in MOOC Using Deep Learning: A Systematic Literature Review," *IEEE Access*, vol. 13, no. December 2024, pp. 18952–18982, 2025, doi: 10.1109/ACCESS.2025.3533915.
- [4] C. Kaensar and W. Wongnin, "Analysis and Prediction of Student Performance Based on Moodle Log Data using Machine Learning Techniques," *Int. J. Emerg. Technol. Learn.*, vol. 18, pp. 184–203, 2021, doi: 10.3991/ijet.v18i10.35841.
- [5] Y. Su, Y. Lin, and T. Liu, "Applying Machine Learning Technologies to Explore Students' Learning

- Features and Performance Prediction,” *Front. Media SA*, vol. 16, no. December, pp. 1–9, 2022, doi: 10.3389/fnins.2022.1018005.
- [6] T. Zhang, Z. Zhong, W. Mao, Z. Zhang, and Z. Li, “A New Machine-Learning-Driven Grade-Point Average Prediction Approach for College Students Incorporating Psychological Evaluations in the Post-COVID-19 Era,” *Electronics*, vol. 13, pp. 1–19, 2024, doi: 10.3390/electronics13101928.
- [7] H. Ji and L. Norman, “Does parental support amplify growth mindset predictions for student achievement and persistence ? Cross - cultural findings from 76 countries / regions,” *Soc. Psychol. Educ.*, vol. 28, no. 1, pp. 1–31, 2025, doi: 10.1007/s11218-025-10038-4.
- [8] Z. Khan, A. Ali, D. M. Khan, and S. Aldahmani, “Regularized Ensemble Learning for Prediction and Risk Factors Assessment of Students At Risk in the Post - COVID Era,” *Sci. Rep.*, no. 0123456789, pp. 1–12, 2024, doi: 10.1038/s41598-024-66894-1.
- [9] B. Albreiki, N. Zaki, and H. Alashwa, “A Systematic Literature Review of Student ’ Performance Prediction Using Machine Learning Techniques,” *Educ. Sci.*, vol. 11, 2021, doi: 10.3390/educsci11090552.
- [10] Y. Zhang, Y. Yun, R. An, J. Cui, H. Dai, and X. Shang, “Educational Data Mining Techniques for Student Performance Prediction : Method Review and Comparison Analysis,” *Front. Psychol.*, vol. 12, no. December, pp. 1–19, 2021, doi: 10.3389/fpsyg.2021.698490.
- [11] B. Sekeroglu, R. Abiyev, A. Ilhan, M. Arslan, and J. B. Idoko, “Systematic Literature Review on Machine Learning and Student Performance Prediction : Critical Gaps and Possible Remedies,” *Appl. Sci.*, vol. 11, p. 10907, 2021, doi: 10.3390/app112210907.
- [12] K. Alalawi, R. Athauda, and R. Chiong, *An Extended Learning Analytics Framework Integrating Machine Learning and Pedagogical Approaches for Student Performance Prediction and Intervention*, vol. 35, no. 3. Springer New York, 2025. doi: 10.1007/s40593-024-00429-7.
- [13] R. Hasan, S. Palaniappan, S. Mahmood, and A. Abbas, “Predicting Student Performance in Higher Educational Institutions Using Video Learning Analytics and Data Mining Techniques,” *Appl. Sci.*, vol. 10, p. 3894, 2020, doi: 10.3390/app10113894.
- [14] H. Chen, E. Prasetyo, S. Tseng, K. T. Putra, S. S. Kusumawardani, and C. Weng, “Week-Wise Student Performance Early Prediction in Virtual Learning Environment Using a Deep Explainable Artificial Intelligence,” *Appl. Sci.*, vol. 12, pp. 1–16, 2022.
- [15] Y. U. Liu, Y. Hui, D. Hou, and X. Liu, “A Novel Student Achievement Prediction Method Based on Deep Learning and Attention Mechanism,” *IEEE Access*, vol. 11, no. July, pp. 87245–87255, 2023, doi: 10.1109/ACCESS.2023.3305248.
- [16] V. Bielik, V. Nosál, L. Nechalová, M. Špánik, K. Žilková, and M. Grendar, “The Prediction Model of Academic Achievement Based on Cardiorespiratory Fitness and BMI Status for Ninth-grade Students,” *BMC Pediatr.*, vol. 25, 2025, doi: 10.1186/s12887-024-05353-2.
- [17] W. Xiuguo, “A Unified Deep Learning Framework for Student Performance Prediction With Multimodal Data in a Blended,” *Int. J. Intell. Syst.*, vol. 2025, 2025, doi: 10.1155/int/7978546.
- [18] B. A. Alnasyan, M. Basher, and M. O. Alassafi, “A Comprehensive Comparative Analysis of Deep Learning Models for Student Performance Prediction in Virtual Learning Environments : Leveraging the OULA Dataset and Advanced Resampling Techniques,” *IEEE Access*, vol. 13, no. May, pp. 75953–75972, 2025, doi: 10.1109/ACCESS.2025.3564719.
- [19] X. Zhang, Y. Zhang, A. L. Chen, M. Yu, and L. Z. Id, “Optimizing Multi Label Student Performance Prediction with GNN-TINet : A Contextual Multidimensional Deep Learning Framework,” *PLoS One*, vol. 20, pp. 1–25, 2025, doi: 10.1371/journal.pone.0314823.
- [20] M. Alazmi, “Enhancing student success prediction in higher education with swarm optimized enhanced efficientNet attention,” *PLoS One*, vol. 20, pp. 1–29, 2025, doi: 10.1371/journal.pone.0326966.
- [21] J. Antonio, L. Rodríguez, N. Díaz-díaz, C. David, and B. González, “A Comparative Analysis of Student Performance Prediction : Evaluating Optimized Deep Learning Ensembles Against Semi-Supervised Feature Selection-Based Models,” *Appl. Sci.*, vol. 15, 2025, doi: 10.3390/app15094818.
- [22] A. Angeioplastis, J. Aliprantis, and M. Konstantakis, “Predicting Student Performance and Enhancing Learning Outcomes : A Data-Driven Approach Using Educational Data Mining Techniques,” *Computers*, vol. 14, pp. 1–21, 2025, doi: 10.3390/computers14030083.
- [23] M. Arya and A. Motwani, “A CNN – LSTM-based Deep Learning Model for Early Prediction of Student

- 's Performance," *Int. J. Smart Sens. Intell. Syst.*, vol. 17, no. 1, 2024, doi: 10.2478/ijssis-2024-0036.
- [24] J. W. Id and Y. Yu, "Machine Learning Approach to Student Performance Prediction of Online Learning," *PLoS One*, vol. 20, pp. 1–15, 2025, doi: 10.1371/journal.pone.0299018.
- [25] S. Yu, Y. Cai, B. Pan, and M. Leung, "Semi-Supervised Feature Selection of Educational Data Mining for Student Performance Analysis," *Electronics*, vol. 13, pp. 1–23, 2024, doi: 10.3390/electronics13030659.
- [26] Y. Zhang, V. Y. Mariano, and R. P. Bringula, "Prediction of Students' Grade by Combining Educational Knowledge Graph and Collaborative Filtering," *IEEE Access*, vol. 12, no. April, pp. 68382–68392, 2024, doi: 10.1109/ACCESS.2024.3390675.
- [27] M. N. Raheema, A. M. Al-khazzar, and J. S. Hussain, "Prediction of Students' Achievements in E-Learning Courses Based on Adaptive Neuro-Fuzzy Inference System," *Int. J. FUZZY Log. Intell. Syst.*, vol. 22, no. 2, pp. 213–222, 2022, doi: 10.5391/ijfis.2022.22.2.213.
- [28] S. Bouallegue and A. Omri, "Machine Learning Approaches for Early Student Performance Prediction in Programming Education," *Information*, vol. 17, pp. 1–18, 2026, doi: 10.3390/info17010060.
- [29] M. Qiang, Z. Liu, and R. Zhang, "Explainable AI in education : integrating educational domain knowledge into the deep learning model for improved student performance prediction," *Sci. Rep.*, vol. 16, pp. 1–20, 2026, doi: 10.1038/s41598-026-40538-y.
- [30] N. Alkhudair and H. M. Almalag, "Metacognitive awareness and confidence as predictors of academic performance in pharmacy students : insights from grade predictions and structural equation modeling," *Front. Psychol.*, vol. 17, no. February, 2026, doi: 10.3389/fpsyg.2026.1720303.
- [31] K. Kesgin, S. Kiraz, S. Kosunalp, and B. Stoycheva, "Beyond Performance : Explaining and Ensuring Fairness in Student Academic Performance Prediction with Machine Learning," *Appl. Sci.*, vol. 15, no. ML, pp. 1–25, 2025, doi: 10.3390/app15158409.
- [32] A. Fathy *et al.*, "Comparison of machine learning classification and regression models for prediction of academic performance among postgraduate public health students Area Under the Curve High Institute of Public Health," *Sci. Rep.*, vol. 15, pp. 1–10, 2025, doi: 10.1038/s41598-025-31023-z.
- [33] T. Li, "Prediction and Optimization of Student Grades Based on Genetic Algorithm and Graph Convolutional Neural Networks," *Int. J. Comput. Intell. Syst.*, vol. 18, 2025, doi: 10.1007/s44196-025-00775-x.
- [34] M. Bellaj, A. Ben Dahmane, B. Said, and M. L. Selfian, "Educational Data Mining: Employing Machine Learning Techniques and Hyperparameter Optimization to Improve Students' Academic Performance," *Int. J. Online Biomed. Eng.*, vol. 20, no. 3, pp. 55–74, 2024, doi: 10.3991/ijoe.v20i03.46287.
- [35] A. A. Majid, "A Prediction Method of Forecasting University Student Achievements Using an Iterative Neural Network Shrinking Algorithm," *Int. J. Mod. Educ. Comput. Sci.*, vol. 16, no. 6, pp. 56–63, 2024, doi: 10.5815/ijmecs.2024.06.04.
- [36] N. G. Cu, T. L. Nghiem, T. H. Ngo, M. Tuong, L. Nguyen, and H. Q. Phung, "Increment of Academic Performance Prediction of At-Risk Student by Dealing With Data Imbalance Problem," *Appl. Comput. Intell. Soft Comput.*, vol. 2024, 2024, doi: 10.1155/2024/4795606.
- [37] E. Ahmed, "Student Performance Prediction Using Machine Learning Algorithms," *Appl. Comput. Intell. Soft Comput.*, vol. 2024, 2024, doi: 10.1155/2024/4067721.
- [38] S. Sengupta, "Towards Finding a Minimal Set of Features for Predicting Students' Performance Using Educational Data Mining," *Int. J. Mod. Educ. Comput. Sci.*, vol. 15, no. 3, pp. 44–54, 2023, doi: 10.5815/ijmecs.2023.03.04.
- [39] M. Nachouki, E. A. Mohamed, R. Mehdi, and M. A. Naaj, "Trends in Neuroscience and Education Student course grade prediction using the random forest algorithm : Analysis of predictors' importance," *Trends Neurosci. Educ.*, vol. 33, p. 100214, 2023, doi: 10.1016/j.tine.2023.100214.
- [40] H. Mastour, T. Dehghani, E. Moradi, and S. Eslami, "Heliyon Early prediction of Medical Students' Performance in High-stakes Examinations Using Machine Learning Approaches SHapely Additive exPlanations," *Heliyon*, vol. 9, no. 7, p. e18248, 2023, doi: 10.1016/j.heliyon.2023.e18248.
- [41] F. A. Al-azazi and M. Ghurab, "ANN-LSTM : A Deep Learning Model for Early Student Performance Prediction in MOOC," *Heliyon*, vol. 9, no. 4, p. e15382, 2023, doi: 10.1016/j.heliyon.2023.e15382.
- [42] P. Asthana, S. Mishra, and S. Member, "Prediction of Student's Performance With Learning Coefficients Using Regression Based Machine Learning Models," *IEEE Access*, vol. 11, no. July, pp. 72732–72742, 2023, doi: 10.1109/ACCESS.2023.3294700.

-
- [43] Z. Chen, G. Cen, Y. Wei, and Z. Li, "Student Performance Prediction Approach Based on Educational Data Mining," *IEEE Access*, vol. 11, no. October, pp. 131260–131272, 2023, doi: 10.1109/ACCESS.2023.3335985.
 - [44] S. Urbano, X. B. Gradient, V. Machine, X. B. Gradient, and V. Machine, "Implementation of Machine Learning Techniques and Creation of an Artificial Neural Network for the Prediction of the Academic Performance of Students in University Environments That Use E-Learning and Streaming," *DYNA*, vol. 98, no. June, pp. 282–287, 2023, doi: 10.6036/10724.
 - [45] M. Kamal *et al.*, "Metaheuristics Method for Classification and Prediction of Student Performance Using Machine Learning Predictors," *Math. Probl. Eng.*, vol. 2022, pp. 1–5, 2022, doi: 10.1155/2022/2581951.
 - [46] L. Chen, "Learning Performance of International Students and Students with Disabilities : Early Prediction and Feature Selection through Educational Data Mining," *Big Data Cogn. Comput.*, vol. 6, 2022, doi: 10.3390/bdcc6030094.
 - [47] T. Tao, C. Sun, Z. Wu, J. Yang, and J. Wang, "Deep Neural Network-Based Prediction and Early Warning of Student Grades and Recommendations for Similar Learning Approaches," *Appl. Sci.*, vol. 12, p. 7733, 2022.
 - [48] M. Yağcı, "Educational data mining : Prediction of Students ' Academic Performance Using Machine Learning Algorithms," *Smart Learn. Environ.*, vol. 9, 2022, doi: 10.1186/s40561-022-00192-z.
 - [49] Y. Yu, J. Fan, Y. Xian, and Z. Wang, "Graph Neural Network for Senior High Student ' s Grade Prediction," *Appl. Comput. Geosci.*, vol. 12, p. 3881, 2022, doi: 10.3390/app12083881.
 - [50] B. Reyes, S. D. L. Santos, S. M. Gregorio, J. M. Tomás, and L. Galiana, "Prediction of Academic Achievement in Dominican Students : Meditational Role of Learning Strategies and Study Habits and Attitudes Toward Study," *Psychol. Sch.*, vol. 60, no. July 2022, pp. 606–625, 2022, doi: 10.1002/pits.22780.
 - [51] D. Wang and D. Lian, "Analysis and Prediction of Influencing Factors of College Student Achievement Based on Machine Learning," *Front. Psychol.*, vol. 13, no. 1, 2022, doi: 10.3389/fpsyg.2022.881859.
 - [52] G. Feng, M. Fan, and Y. U. Chen, "Analysis and Prediction of Students ' Academic Performance Based on Educational Data Mining," *IEEE Access*, vol. 10, pp. 19558–19571, 2022, doi: 10.1109/ACCESS.2022.3151652.
 - [53] A. Y. A. Nabil, M. Seyam, and A. Abou-elfetouh, "Prediction of Students ' Academic Performance Based on Courses ' Grades Using Deep Neural Networks," *IEEE Access*, vol. 9, pp. 140731–140746, 2021, doi: 10.1109/ACCESS.2021.3119596.
 - [54] A. Lincke, M. Jansen, M. Milrad, and E. Berge, "The Performance of Some Machine Learning Approaches and A Rich Context Model in Student Answer Prediction," *Res. Pract. Technol. Enhanc. Learn.*, vol. 16, 2021, doi: 10.1186/s41039-021-00159-7.
 - [55] P. Nuankaew, P. Nasa-ngium, and W. S. Nuankaew, "Application for Identifying Students Achievement Prediction Model in Tertiary Education," *Int. J. Interact. Mob. Technol.*, vol. 15, pp. 22–43, 2021.
 - [56] N. Aslam, I. U. Khan, L. H. Alamri, and R. S. Almuslim, "An Improved Early Student ' s Performance Prediction Using Deep Learning," *Int. J. Emerg. Technol. Learn.*, vol. 16, pp. 108–122, 2021.
 - [57] L. S. Maurya, S. Hussain, and S. Singh, "Developing Classifiers through Machine Learning Algorithms for Student Placement Prediction Based on Academic Performance Developing Classifiers through Machine Learning Algorithms for Student Placement Prediction Based on," *Appl. Artif. Intell.*, vol. 35, no. 6, pp. 403–420, 2021, doi: 10.1080/08839514.2021.1901032.
 - [58] S. Dianah, A. Bujang, A. L. I. Selamat, R. Ibrahim, and O. Krejcar, "Multiclass Prediction Model for Student Grade Prediction Using Machine Learning," *IEEE Access*, vol. 9, pp. 95608–95621, 2021, doi: 10.1109/ACCESS.2021.3093563.
 - [59] Y. Zhang, "Applied Sciences Graphs Regularized Robust Matrix Factorization and Its Application on Student Grade Prediction," *Appl. Sci.*, vol. 10, pp. 1–19, 2020, doi: 10.3390/app10051755.
 - [60] D. Hooshyar and M. Pedaste, "Mining Educational Data to Predict Students ' Performance through Procrastination Behavior," *Entropy*, vol. 22, 2020, doi: 10.3390/e22010012.