

TINJAUAN SISTEMATIS LITERATUR: TREN, DATA, DAN METODE MACHINE LEARNING DALAM PREDIKSI KELULUSAN

Rudy Ansari^{1,2*}, Sunardi³, Imam Riadi⁴

¹Program Studi Informatika, Fakultas Teknologi Industri, Universitas Ahmad Dahlan,

²Program Studi Informatika, Fakultas Teknik, Universitas Muhammadiyah Banjarmasin,

³Program Studi Teknik Elektro, Fakultas Teknologi Industri, Universitas Ahmad Dahlan,

⁴Program Studi Sistem Informasi, Fakultas Sains dan Teknologi Terapan, Universitas Ahmad Dahlan.

*2436083028@webmail.uad.ac.id

Jl. Ahmad Yani (Ringroad Selatan), Tamanan, Banguntapan, Bantul, Yogyakarta, Indonesia.

Article history: Received: 17 November 2025; Revised: 25 December 2025; Accepted: 31 December 2025

Abstract

While research on student graduation prediction has proliferated, a significant academic gap remains in the integrative synthesis of evolving methodologies and heterogeneous dataset structures. This Systematic Literature Review (SLR) aims to bridge this gap by analyzing research trends, datasets, and methods published between 2020 and 2025. The selection process followed inclusion and exclusion criteria based on the PRISMA protocol, resulting in 75 selected articles from an initial pool of 199 articles indexed in the Scopus database (Quartiles 1–4). The analysis identifies four primary research topics: prediction/classification 59%, dataset analysis 35%, clustering 5%, and estimation 1%. Random Forest (RF) emerged as the most dominant algorithm due to its robustness and interpretability in handling educational data. This study contributes to the field by mapping current Machine Learning (ML) trends, identifying the most frequently utilized datasets, and highlighting critical research gaps in student graduation prediction for the 2020–2025 period.

Keywords: *Systematic Literature Review; Student Graduation; Machine Learning; PRISMA; Random Forest.*

Abstrak

Meskipun penelitian mengenai prediksi kelulusan mahasiswa telah banyak dipublikasikan, terdapat kesenjangan riset akademik yang signifikan dalam sintesis integratif terhadap evolusi metodologi dan heterogenitas struktur *dataset*. *Systematic Literature Review* (SLR) ini bertujuan untuk menganalisis tren penelitian, *dataset*, dan metode yang diterbitkan antara tahun 2020 hingga 2025. Proses seleksi mengikuti kriteria inklusi dan eksklusi berdasarkan protokol PRISMA, dengan total 75 artikel terpilih dari 199 artikel yang bersumber dari jurnal terindeks Scopus dengan Kuartil 1–4. Hasil analisis mengungkapkan empat topik utama: prediksi/klasifikasi 59%, analisis *dataset* 35%, pengelompokan 5%, dan estimasi 1%. *Random Forest* (RF) menjadi algoritma yang paling mendominasi karena ketangguhan dan aspek interpretabilitasnya dalam mengolah data pendidikan. Studi ini memberikan kontribusi dengan memetakan tren metode *Machine Learning* (ML) terkini, *dataset* yang paling sering digunakan, serta mengidentifikasi *gap* riset dalam prediksi kelulusan mahasiswa pada periode 2020–2025.

Kata Kunci: *Systematic Literature Review; Kelulusan Mahasiswa; Machine Learning; PRISMA; Random Forest.*



Pendahuluan

Saat ini, algoritma canggih dipilih berdasarkan kebutuhan spesifik seperti *Random Forest* (RF) dan *Support Vector Machine* (SVM) mendominasi karena ketangguhannya pada dataset besar [1]. sementara *Neuro-Fuzzy* (ANFIS) diandalkan untuk transparansi aturan yang mudah dipahami pendidik [2]. Sebaliknya, untuk menangani data sekuensial yang merekam jejak aktivitas harian siswa, penggunaan *Deep Learning* seperti *Bidirectional Long Short-Term Memory* (BLSTM) dan *Conditional Random Fields* (CRF) telah menjadi tren [3]. Namun, ada perdebatan mendasar tentang relevansi model-model tersebut. Banyak penelitian terjebak pada penggunaan fitur yang sangat luas dan kompleks yang seringkali tidak tersedia bagi manajemen universitas di awal masa studi. Akibatnya, ada perbedaan antara kecanggihan teknis model dengan *feasibility* implementasinya [4].

Dalam hal variabel prediktor yang paling signifikan, hasilnya tidak konsisten. Teorema "*No Free Lunch*" memvalidasi hal ini secara ilmiah, karena tidak ada algoritma yang sempurna untuk semua konteks pendidikan [5]. Sebagai contoh, ada perbedaan pendapat tentang apakah nilai sekolah menengah atau *High School Grade Point Average* (HSGPA) lebih penting daripada nilai mata kuliah inti semester awal atau apakah nilai sekolah menengah HSGPA lebih penting. Selain itu, data perilaku *real-time*, seperti pola prokrastinasi dalam sistem pendidikan online, terbukti lebih menunjukkan kegagalan akademik daripada variabel statis yang dominan [6]. Ketidakkonsistenan ini menunjukkan bahwa model prediksi sangat tergantung pada konteks lokal dan kualitas data yang tersedia [7]. Sistem *hybrid ensemble* yang memanfaatkan data perilaku multisumber atau *digital trails*, seperti aktivitas perpustakaan, log internet, dan keterlibatan LMS, dapat diintegrasikan melalui penggunaan algoritma klasifikasi tunggal berbasis data akademik statis [8]. Mengejar akurasi matematis tertinggi tidak lagi menjadi tujuan utama. Sebaliknya, fokus saat ini adalah pada pembuatan model yang dapat diinterpretasikan atau dapat dijelaskan, dan dapat diterapkan untuk pengambilan kebijakan secara *real-time* [9]. Namun, tinjauan literatur sistematis *Systematic Literature Review* (SLR) sebelumnya seringkali memiliki kelemahan karena cakupan *database* yang terbatas dan ketidakjelasan metodologis tentang cara terbaik untuk memilih algoritma [10].

Oleh karena itu, penelitian ini menggunakan pendekatan *Systematic Literature Review* (SLR) yang holistik untuk memetakan lanskap prediksi kelulusan, mengoreksi bias metodologis, serta mensintesis tren dan fitur paling krusial. Dengan mengevaluasi ketidakkonsistenan literatur saat ini, studi ini bertujuan membangun fondasi sistem prediksi yang akurat secara matematis dan relevan bagi kebutuhan institusi pendidikan.

Metode

1. Metode Peninjauan

Metode peninjauan yang digunakan mempunyai tiga tahapan, yaitu perencanaan, pelaksanaan, dan pelaporan [11]. Proses ini terdiri dari tiga tahap utama: Perencanaan untuk mendefinisikan kebutuhan, pertanyaan penelitian, dan protokol. Pelaksanaan yang mencakup identifikasi, seleksi, penilaian kualitas, ekstraksi, hingga sintesis data, serta Pelaporan untuk mengomunikasikan temuan kepada pihak terkait.

2. Pertanyaan Penelitian

Pertanyaan penelitian atau *Research Question* (RQ) ditetapkan berdasarkan kerangka *Population, Intervention, Comparison, Outcome, and Context* (PICOC) untuk menjaga fokus dan relevansi tinjauan dalam mengeksplorasi prediksi kelulusan mahasiswa [12]. Struktur PICOC dari pertanyaan ditunjukkan pada Tabel 1.

Tabel 1. Ringkasan PICOC

No.	PICOC	Deskripsi	Alasan Pemilihan
1	Population	Mahasiswa di jenjang pendidikan tinggi.	Fokus pada mahasiswa berisiko <i>dropout</i> karena berdampak langsung pada mutu akreditasi institusi pendidikan.
2	Intervention	Penerapan <i>Machine Learning</i> (ML) dan <i>Data</i>	ML dan DM karena dapat memproses dataset besar dan menemukan pola perilaku siswa yang tidak terlihat dengan metode

No.	PICOC	Deskripsi	Alasan Pemilihan
		<i>Mining</i> (DM) untuk statistik tradisional. prediksi kelulusan.	
3	Comparison	Perbandingan performa antar berbagai algoritma.	Perbandingan diperlukan untuk mengidentifikasi model yang paling stabil dan akurat dalam menangani karakteristik data pendidikan.
4	Outcome	Status kelulusan, serta efektivitas metrik performa.	Hasil penting bagi manajemen universitas untuk membuat keputusan tentang intervensi dini terhadap mahasiswa.
5	Context	Institusi pendidikan tinggi dengan berbagai sumber data.	Konteks ini dipilih untuk variasi data perilaku dan akademik mahasiswa dalam lingkungan pembelajaran modern.

Berdasarkan Tabel 1, pertanyaan penelitian ditetapkan seperti pada Tabel 2.

Tabel 2. Pertanyaan penelitian

ID	Pertanyaan Penelitian	Motivasi
RQ1	Bagaimana tren publikasi dan fokus sub-topik penelitian dalam prediksi kelulusan mahasiswa sejak tahun 2020?	Mengidentifikasi evolusi riset dan area spesifik yang paling banyak diminati.
RQ2	Jenis dataset dan fitur apa yang paling dominan digunakan untuk memprediksi kelulusan?	Mengidentifikasi sumber data yang terbukti paling berpengaruh terhadap prediksi.
RQ3	Algoritma <i>Machine Learning</i> apa yang paling sering digunakan dan bagaimana perbaikan metode yang diusulkan?	Memetakan algoritma standar dan inovasi teknis dalam literatur terbaru.
RQ4	Bagaimana performa dari model-model prediksi yang ada dalam literatur primer?	Mengevaluasi efektivitas model untuk memastikan validitas hasil
RQ5	Apa saja tantangan utama dan peluang riset masa depan dalam domain prediksi kelulusan?	Memberikan panduan bagi peneliti selanjutnya mengenai celah (<i>gap</i>) yang belum terpecahkan.

Pertanyaan penelitian tersebut menjadi pedoman ekstraksi dan sintesis data untuk menjawab RQ1 hingga RQ5. Tujuannya adalah memberikan gambaran komprehensif mengenai kemajuan algoritma *machine learning*, efektivitas fitur dataset, serta metrik performa dalam literatur terbaru terkait prediksi kelulusan mahasiswa.

3. Strategi Pencarian

Metode pencarian disusun secara sistematis untuk menjawab pertanyaan penelitian (RQ). Untuk memastikan transparansi dan reproduksibilitas penelitian, prosedur ini mengikuti protokol *Preferred Reporting Items for Systematic Reviews and Meta-analysis* (PRISMA) 2020 [13]. Pencarian literatur dilakukan melalui database *Scopus* dan *Web of Science* (WoS) karena reputasi indeks jurnal berkualitas tinggi (Q1-Q4) serta cakupannya yang luas pada bidang *educational data mining* dan *machine learning*. Studi ini dibatasi pada artikel terbitan Januari 2020 hingga Juni 2025 untuk menangkap tren teknologi terbaru pasca pandemi. Pencarian literatur dilakukan secara komprehensif menggunakan string pencarian dengan operator *Boolean* AND dan OR. Operator OR digunakan untuk mencakup variasi istilah yang relevan, sementara kriteria pencarian diterapkan pada metadata Judul, Abstrak, dan Kata Kunci dengan kata kunci berikut:

String Pencarian: ("student" OR "undergraduate") AND ("graduation" OR "academic performance" OR "dropout") AND ("prediction" OR "classification" OR "detection") AND ("machine learning" OR "data mining") AND ("accuracy" OR "model")

4. Kriteria Inklusi dan Eksklusi

Penelitian ini menetapkan Kriteria Inklusi (KI) dan Eksklusi (KE) sebagai filter sistematis untuk menjamin objektivitas, relevansi, dan kualitas artikel yang dipilih. Kriteria tersebut memastikan hanya studi dengan kontribusi data valid terhadap pertanyaan penelitian yang disertakan, sebagaimana dirinci dalam Tabel 3.


Tabel 3. Kriteria Inklusi dan Eksklusi

No	Kriteria	Keterangan
1	Inklusi	Bidang akademik di perguruan tinggi menggunakan data

		Membahas dan membandingkan kinerja model/metode
		Hanya versi jurnal yang di pilih
		Artikel yang sudah ditarik
2	Eksklusi	Artikel yang tidak ditulis dalam Bahasa Inggris
		Artikel yang tidak dapat diakses
		Artikel yang doi scopusnya tidak resmi

5. Prosedur Seleksi Studi

Gambar 1 menunjukkan proses PRISMA. Setelah *string* dimasukkan maka didapat sebanyak 320 dokumen dari *platform* wataseuake.web.id dengan database scopus.



Gambar 1. Proses Identifikasi menggunakan Metode PRISMA

6. Ekstraksi Data

Tabel 4 menunjukkan sebanyak 75 artikel terpilih diekstraksi berdasarkan empat properti utama untuk menjawab seluruh pertanyaan penelitian dalam tinjauan ini.

Tabel 4. Ekstraksi Pertanyaan

No	Properti	Pertanyaan Penelitian
1	Penulis, tahun, nama jurnal	RQ1
2	Jenis dataset, fitur dominan, algoritma, dan perbaikan metode	RQ2, RQ3
3	Nilai akurasi dan metrik performa lainnya	RQ4
4	Tantangan dan saran penelitian masa depan	RQ5

7. Penilaian Kualitas Studi dan Sintesis Data

Instrumen penilaian kualitas yang digunakan *Critical Appraisal Skills Programme* (CASP) dalam studi ini merupakan adaptasi dari CASP *Critical Appraisal Tool* 2018 dan pedoman penilaian kualitas untuk rekayasa perangkat lunak oleh *Kitchenham* dan *Charters* [1]. Kriteria disesuaikan untuk menjamin relevansi domain ML, meliputi aspek validasi data, pemilihan algoritma, dan metrik performa [10]. Setiap pertanyaan dinilai menggunakan skala: 1 (Ya), 0,5 (Sebagian), atau 0 (Tidak).

Tabel 5. Kriteria Penilaian

No	Kriteria Penilaian	Keterangan
Q1	Fokus Penelitian Jelas?	Apakah paper memiliki tujuan yang jelas?
Q2	Kesesuaian Dataset?	Apakah dataset yang digunakan relevan dan dijelaskan ukurannya?
Q3	Kualitas Prapemrosesan Data?	Apakah dijelaskan cara menangani data hilang atau data tidak seimbang?
Q4	Justifikasi Algoritma?	Apakah peneliti menjelaskan alasan pemilihan algoritma ML?
Q5	Prosedur Validasi?	Apakah menggunakan metode validasi yang kuat?
Q6	Metrik Performa Jelas?	Apakah hasil dilaporkan dengan metrik standar?
Q7	Analisis Fitur/Variabel?	Apakah ada penjelasan mengenai fitur yang paling berpengaruh?
Q8	Interpretasi Hasil?	Apakah hasil didiskusikan dan dibandingkan dengan penelitian sebelumnya?
Q9	Generalisasi Hasil?	Apakah temuan dapat diterapkan di institusi lain ataupun satu kampus saja?

No	Kriteria Penilaian	Keterangan
Q10	Kontribusi Ilmiah?	Apakah paper memberikan saran praktis atau riset masa depan?

Berdasarkan kriteria Tabel 5, seluruh literatur terpilih dievaluasi secara menyeluruh untuk menjamin kekuatan metodologi, validitas data, dan kontribusi ilmiahnya. Setiap artikel diberi skor dengan ketentuan: 1 (terpenuhi), 0,5 (sebagian), atau 0 (tidak terpenuhi), dengan skor maksimum 10.

Hasil penilaian kualitas terhadap 75 artikel terpilih menunjukkan semuanya berada dalam kategori *High Quality*, yang menegaskan kredibilitas literatur dasar studi ini. Rincian skor untuk setiap artikel tersedia pada Tabel 6.

Tabel 6. Hasil Penilaian Kualitas Literatur (*Quality Assessment Score*)

No	Penulis (Tahun)	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10	Total	Kualitas
1	Jin (2025)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
2	Hooper (2025)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
3	Kord (2025)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
4	Masood (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
5	Yang (2024)	1	1	0,5	1	1	1	0,5	1	0,5	1	8,5	High
6	Zanellati (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
7	Zhang (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
8	Pelima (2024)	1	1	1	1	1	1	1	1	1	1	10	High
9	Ahmed (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
10	Zaiter (2024)	1	1	0,5	1	1	1	0,5	1	0,5	1	8,5	High
11	Bakare (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
12	Choi (2024)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
13	Dong (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
14	El-Sabagh (2024)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
15	Fang (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
16	Ghorbani (2024)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
17	Hsieh (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
18	Jiang (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
19	Khan (2024)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
20	Liu (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
21	Beane (2024)	1	1	0,5	1	1	1	0,5	1	0,5	1	8,5	High
22	Messoudi (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
23	Junejo (2024)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
24	Khairy (2024)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
25	Yu (2024)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
26	Wang (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
27	Issaro (2023)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
28	Lopez (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
29	Asad (2023)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
30	Mehdi (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
31	Wyness (2023)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
32	Al-Radaideh (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
33	Chen (2023)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
34	Canas (2023)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
35	Garcia (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
36	Gupta (2023)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
37	Haider (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
38	Iqbal (2023)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
39	Gollapalli (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
40	Kim (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
41	Li (2023)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
42	Ma (2023)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
43	Nasir (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
44	Lozano (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
45	Park (2023)	1	1	0,5	1	1	1	0,5	1	0,5	1	8,5	High
46	Messoudi (2022)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
47	Qureshi (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
48	Salehi (2023)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
49	Tuan (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High

No	Penulis (Tahun)	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10	Total	Kualitas
50	Usman (2023)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
51	Xu (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
52	Yagci (2022)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
53	Zohair (2023)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
54	Alturki (2022)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
55	Kamal (2022)	1	1	0,5	1	1	1	0,5	1	0,5	1	8,5	High
56	Zhao (2021)	1	1	1	1	1	1	1	1	1	1	10	High
57	Kabathova (2021)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
58	Aguiar (2022)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
59	Al-Fahdawi (2022)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
60	Maurya (2021)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
61	Hasan (2022)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
62	Khan (2022)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
63	Liao (2022)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
64	Mueen (2022)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
65	Yousafzai (2021)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
66	Zambrano (2020)	1	1	1	1	1	1	0,5	1	0,5	1	9,0	High
67	He (2020)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
68	Injadat (2020)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
69	Uliyan (2021)	1	1	0,5	1	1	1	0,5	1	0,5	1	8,5	High
70	Adekitan (2021)	1	1	0,5	1	1	1	1	1	0	1	8,5	High
71	Sekeroglu (2021)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
72	Rabelo(2025)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
73	Yan (2020)	1	1	0,5	1	1	1	1	1	0,5	1	9,0	High
74	Mengash (2020)	1	1	1	1	1	1	1	1	0,5	1	9,5	High
75	Yang (2020)	1	1	1	1	1	1	1	1	0,5	1	9,5	High

Evaluasi terhadap 75 studi primer menggunakan instrumen CASP menunjukkan kualitas metodologi yang sangat tinggi dengan skor rata-rata 9,28, di mana 74 makalah (98,67%) masuk kategori *High Quality*. Meskipun terdapat keterbatasan pada aspek generalisasi (Q9) akibat penggunaan dataset spesifik, hanya satu studi yang tergolong *Low Quality* karena kurangnya detail teknis. Secara keseluruhan, tingginya kualitas studi primer ini menjamin reliabilitas dan validitas temuan dalam tinjauan sistematis ini.

Pembahasan

1. Analisis Kualitas Studi


Evaluasi terhadap 75 artikel (2020–2025) menggunakan instrumen CASP menunjukkan kualitas metodologi yang sangat tinggi: 74 studi (98,67%) berkategori *High Quality* (skor >8) dan hanya satu (1,33%) berkategori *Low Quality*. Tingginya standar literatur ini menjamin kredibilitas dan reliabilitas temuan teknis mengenai algoritma serta fitur dalam tinjauan ini seperti terlihat pada Tabel 7.

Tabel 7. Ringkasan penilaian CASP (n=75)

Kategori Kualitas	Rentang Skor	Jumlah Paper	Persentase
High Quality	8,0 – 10,0	74	98,67%
Medium Quality	5,0 – 7,5	0	0,00%
Low Quality	< 5,0	1	1,33%
TOTAL		75	100%


2. Tren Publikasi

Analisis terhadap 75 studi primer menunjukkan pertumbuhan konsisten publikasi *Educational Data Mining* (EDM) sejak 2020. Lonjakan signifikan terjadi pada 2022–2023 akibat adopsi masif pembelajaran daring pasca-pandemi, hingga mencapai puncak volume publikasi pada 2024, khususnya dalam topik prediksi kelulusan mahasiswa seperti terlihat pada Gambar 2.



Gambar 2. Distribusi artikel tahun 2020-2025

Gambar 3 menunjukkan bahwa *IEEE Access* merupakan jurnal yang paling banyak menerbitkan artikel terkait topik prediksi kelulusan mahasiswa di antara literatur terpilih.



Gambar 3. Jumlah Publikasi Artikel yang Terkait dengan Topik

2. Peneliti Paling Aktif

Guna menjawab RQ2, tercatat enam peneliti aktif dengan dua publikasi selama 2020–2025: *Cristobal Romero* (2020–2021); *Najat Messoudi*, *Bahloul Bensassi*, dan *Jafar K. Nagiri* (2022 dan 2024); serta *Fiza Murtaza* dan *Amanullah Yasin* (2024–2025). Rekam jejak mereka menjadikannya referensi utama karena keahlian mendalam dalam metodologi dan pola penelitian prediksi kelulusan.

3. Topik Penelitian di Bidang Prediksi Kelulusan Mahasiswa

Analisis terhadap 75 artikel (2020–2025) untuk menjawab RQ2 mengidentifikasi empat topik utama dalam prediksi kelulusan yaitu prediksi/klasifikasi menggunakan algoritma klasifikasi, pengelompokan (*Clustering*) berdasarkan kinerja mahasiswa, estimasi untuk memperkirakan jumlah kelulusan, serta analisis dataset yang berfokus pada pra-pemrosesan data. Topik pertama, Prediksi/Klasifikasi, berfokus pada analisis prestasi dan perilaku mahasiswa (akademik, demografi, kebiasaan) menggunakan algoritma seperti DT dan NN [14]. Studi komparatif melibatkan berbagai metode seperti *Linear Support Vector Machine* (L-SVM) dan *Radial Support Vector Machine* (R-SVM), *Gaussian Process* (GP), DT, RF, NN, *AdaBoost* (ADB), dan NB yang diuji pada dataset seragam dengan metrik evaluasi komprehensif [15]. Di antara metode tersebut, Random Forest (RF) terbukti paling efektif dalam mengenali perbedaan kategoris untuk prediksi [16] serta menunjukkan performa unggul dalam mendeteksi stres mahasiswa dibandingkan teknik ML lainnya [17].

Topik kedua adalah *Clustering* merupakan teknik *unsupervised learning* untuk mengelompokkan data tanpa label. Penggabungan klasifikasi dan *clustering* dapat meningkatkan akurasi prediksi dengan mereduksi fitur tanpa menghapus data asli [18]. Perbaikan algoritma *k-Means* dilakukan dengan mengoptimalkan dataset melalui sistem pembobotan terintegrasi, lalu mengelompokkan

data perilaku mahasiswa sebagai sampel awal uji coba [19]. Algoritma pengelompokan *k-Means* menggunakan data untuk melacak perilaku mahasiswa dan menentukan kluster dalam data yang tidak mempunyai label atau target [20]. Topik ketiga adalah Estimasi, Penerapan *Multi-Layer Perceptron* (MLP) dan *eXtream Gradient Boosting Regression* (XGBR) secara *real-time* menunjukkan bahwa buruknya kualitas udara kelas dapat menurunkan kenyamanan, konsentrasi, dan prestasi akademik mahasiswa selama perkuliahan [21].

Topik selanjutnya, Analisis Dataset, memanfaatkan data multisumber (daring, luring, dan perilaku kampus) untuk memprediksi kinerja akademik. Pola perilaku mahasiswa dievaluasi secara sistematis menggunakan metode linier, nonlinier, hingga *deep learning* (DL) [8]. Pada dataset tidak seimbang, algoritma RF digunakan melalui proses *resampling* untuk menentukan data optimal sebelum seleksi fitur [22]. Sementara itu, pada pendekatan DL, pemeringkatan fitur (*feature ranking*) diterapkan guna mengidentifikasi variabel yang paling relevan terhadap prestasi akademik [23].

Tinjauan terhadap 75 artikel (2020–2025) yaitu dominasi topik prediksi dan klasifikasi (59%), diikuti analisis dataset (35%) yang kian diperhatikan karena peran krusial kualitas data terhadap performa algoritma. Sebaliknya, *Clustering* (5%) dan Estimasi (1%) masih rendah. Meskipun *clustering* berpotensi memprofilkan siswa secara individual, kompleksitas interpretasi hasilnya membuat metode ini kurang populer dibandingkan klasifikasi biner yang lebih aplikatif bagi pengambilan kebijakan.

4. Dataset yang digunakan

Dataset memainkan peran penting dalam berbagai bidang, termasuk penelitian ilmiah, analisis bisnis, dan pengembangan kecerdasan buatan [24]. Data penelitian terdiri dari data privat yang dikumpulkan langsung melalui institusi (demografi, sosial-ekonomi, dsb.) dan data publik yang tersedia secara terbuka di platform seperti UCI, Mendeley, atau Kaggle. Hasil analisis untuk RQ2 menunjukkan bahwa selama lima tahun terakhir, peneliti sangat dominan menggunakan data privat 91% dibandingkan data publik.

5. Metode yang digunakan

Tabel 8 menjawab RQ2 dan RQ3 dengan menunjukkan bahwa *Random Forest* (RF) adalah metode yang paling sering digunakan (22 kali) antara tahun 2020–2025, melampaui SVM, LR, DT, NB, XGBoost, dan ANN. RF mencatatkan kinerja terbaik dengan akurasi 77%–94%, sementara penggunaan teknik *oversampling* terbukti signifikan dalam meningkatkan performa model saat menangani data yang tidak seimbang (*imbalanced data*) [4]. Metode RF akurasinya menjadi meningkat adalah karena penggabungan model.

Tabel 8. Metode yang Paling Sering Digunakan dari Tahun 2020-2025

No	Metode	Jumlah
1	<i>Random Forest</i> (RF)	22
2	<i>Support Vector Machine</i> (SVM)	11
3	<i>Linear Regression</i> (LR)	10
4	<i>Decision Tree</i> (DT)	8
5	<i>Naïve Bayes</i> (NB)	5
6	<i>Extreme Gradient Boosting</i> (XGBoost)	5
7	<i>Artificial Neural Networks</i> (ANN)	4

RF menjadi algoritma yang paling dominan digunakan dibandingkan ANN karena keunggulannya dalam menangani ketidakseimbangan data pendidikan yang sering terjadi. Sebagai metode *ensemble*, RF lebih stabil terhadap gangguan dan menawarkan transparansi melalui fitur penting seperti IPK atau jarak tinggal, berbeda dengan ANN yang bersifat *black box*. Selain itu, algoritma konvensional seperti RF dan XGBoost terbukti lebih efisien dan akurat untuk skala dataset pendidikan yang umumnya berjumlah ratusan hingga ribuan sampel.

6. Tren penelitian pada topik (RQ4)

a. Pemilihan Fitur

Pemilihan fitur sangat krusial untuk mempercepat waktu pelatihan, mencegah *overfitting*, dan menghindari dimensi berlebih. Akurasi sistem prediksi meningkat melalui penggunaan atribut yang lebih beragam, guna meminimalisir kesalahan klasifikasi akibat data yang kurang representative [25]. Proses penilaian kelulusan mahasiswa menjadi lebih tepat jika *dataset* yang digunakan memiliki jumlah yang cukup banyak dan mencakup berbagai atribut yang beragam [26]. Penelitian mendatang cenderung melibatkan fitur dan basis data yang lebih luas. Pengetahuan ini membantu peneliti memilih metode serta pendekatan *data mining* yang paling tepat berdasarkan berbagai teknik yang tersedia [27].

Pemilihan fitur untuk meningkatkan akurasi model dilakukan melalui tiga pendekatan metode Filter mengukur korelasi fitur secara mandiri menggunakan statistik seperti *Pearson* atau *Chi-Square*, metode *Wrapper* mengevaluasi kombinasi fitur berdasarkan performa prediksi menggunakan teknik seperti *Recursive Feature Elimination* (RFE), dan metode *Embedded* mengintegrasikan seleksi fitur selama proses pelatihan melalui teknik regularisasi seperti *Ridge* atau *Lasso* [29]. Kombinasi XGBoost dan seleksi fitur ASHO mengungguli metode tradisional pada seluruh metrik evaluasi (presisi, akurasi, *recall*, dan F1-score), membuktikan efektivitas integrasi teknik seleksi fitur tingkat lanjut dengan algoritma prediktif yang tangguh [30]. Pembelajaran mesin merupakan aspek sederhana dari proses tersebut, sementara pemilihan fitur dari sejumlah besar data yang disediakan oleh *platform* MOOC merupakan bagian yang krusial [31]. *Pre-processing* data merupakan langkah penting dalam proses penemuan pengetahuan, yang melibatkan pembersihan data, reduksi data, transformasi data, dan pemilihan fitur [32].

b. Imbalance Data

Imbalanced data terjadi saat distribusi kelas tidak merata, menyebabkan model bias terhadap mayoritas. Masalah ini sangat krusial dalam klasifikasi karena dapat mendistorsi akurasi jika tidak ditangani [37]. Berbagai teknik seperti SMOTE, ROS, dan ADASYN digunakan untuk menyeimbangkan dataset [33], [34]. Implementasi teknik ini pada algoritma DT dan RF terbukti efektif dengan capaian akurasi hingga 97,9% [35]. Selain akurasi, penggunaan metrik skor F1 sangat disarankan karena lebih objektif dalam mengidentifikasi risiko pada seluruh kelas data mahasiswa [36]. XGBoost terbukti sedikit lebih unggul dibanding RF dalam menjaga keseimbangan akurasi dan rekognisi kasus positif [38]. Penggunaan SMOTE secara signifikan meningkatkan *recall* melalui *oversampling* deterministik, yang pada gilirannya mengoptimalkan skor F1 dan kinerja keseluruhan kedua model tersebut [39]. Di sisi lain, ekspektasi kinerja yang tinggi berdampak positif pada motivasi pengguna, di mana penerapan teknologi seperti *virtual reality* terbukti mampu meningkatkan semangat, kecepatan, dan hasil belajar akademik mahasiswa [40].

Meta analisis untuk menjawab RQ4 menunjukkan bahwa seleksi fitur dan penanganan data tidak seimbang adalah kunci peningkatan performa model. Penggunaan data mentah hanya menghasilkan akurasi 70–75%, sedangkan implementasi SMOTE [33], [39] yang dikombinasikan dengan perbaikan fitur mampu mendongkrak akurasi hingga 85–97,9%. Mengingat akurasi standar bisa menyesatkan pada data tidak seimbang, tren terkini menempatkan skor F1 sebagai metrik utama karena kemampuannya menyeimbangkan *precision* dan *recall* dalam mendeteksi kelas minoritas yang berisiko *dropout*.

7. Peluang Riset Masa Depan (*Future Research*)

Berdasarkan evaluasi di atas dan menjawab RQ5, peluang riset masa depan mencakup:

1. *Explainable AI* (XAI): Mengembangkan model yang tidak hanya akurat secara statistik tetapi juga dapat memberikan rekomendasi intervensi pedagogis yang jelas bagi dosen.
2. Generalisasi Lintas Institusi: Melakukan studi *cross university* menggunakan teknik *Transfer Learning* untuk mengatasi keterbatasan data privat.
3. Integrasi Data Dinamis: Memasukkan data perilaku dari *Learning Management System* (LMS) secara *real-time* untuk memberikan peringatan dini sebelum keterlambatan kelulusan terjadi.

Hasil

Tabel 9 merangkum studi primer periode 2020–2025 yang disusun kronologis berdasarkan tahun publikasi. Informasi yang disajikan meliputi identitas artikel, jurnal publikasi, jenis dataset, metode yang digunakan, serta topik utama yang berkembang sepanjang periode tersebut.

Tabel 9. Daftar Artikel pada Topik Prediksi Kelulusan Mahasiswa

Tahun	Studi Primer	Topik	Dataset	Method	Publikasi
2020	[37][38][39][40][41][42][43][44][21][6]	Prediksi/Klasifikasi Analisis Dataset Klaster	9 Private 1 Public	RF, GBRT, KNN, SVM, XGBoost, LSTM, FTT, LR, BiLSTM, NN, ADB, NB, CART	- Applied Intelligence - Applied Sciences - EPJ Data Science - IEEE Access - Information - International Journal of Emerging Technologies in Learning (ijET) - Soft Computing
2021	[45][22][46][47][32][48][18][3][49][8][50]	Prediksi/Klasifikasi Estimasi Analisis Dataset	10 Private 1 Public	BPNN, RBM, LSTM, DNN, RF, GBRT, BLSTM, CRF, MLP, Deep Belief Networks (DBN), PSO, SMOTE, SGFP, LGBM, XGB, MLP	- Applied Artificial Intelligence - Applied Sciences - IEEE Access - Neural Computing and Applications - Sustainability
2022	[51][52][53][35][41][19][9][54][55][56][5][57][51]	Prediksi/Klasifikasi Analisis Dataset Klaster	10 Private 3 Public	RF, XGBR, SVM, KNN, ANN, Harris Hawks Optimization (HHO), Henry Gas Solubility Optimization (HGSO), Variational Auto Encoder (VAE), NB, SVM, RFE, Support Vector Regression (SVR), deep neural network (DNN), DT, SMOTE, ADASYN, ROS, SMOTE-ENN, J48, MLP, ANFIS	- Advances in Multimedia - Alexandria Engineering Journal - Computers - Education and Information Technologies - IEEE Access - International Journal of Modern Education and Computer Science - Scientific Programming - Smart Learning Environments
2023	[29][58][59][60][61][7][62][63][64][17][65][66]	Prediksi/Klasifikasi Analisis Dataset	12 Private 1 Public	BPNN, SVM, NB, KNN, RF, LR, NN, CNN, BOA, LDA, QDA, GB, XGBoost, Light GBM, Extra Trees, DANN, GRU, Long Short-Term Memory (LSTM), SVR, SMOTE	- Education and Information Technologies - Education Economics - IEEE Access - PeerJ Computer Science - Sustainability
2024	[67][68][28][69][30][70][71][72][73][10][74][20][75][24][23][76][15][33][34][77]	Prediksi/Klasifikasi Analisis Dataset Klaster	21 Private	SMOTE, RF, LSTM, RNN, GRU, NB, J48, SVM, RL, XGBoost, GLM, EDA, DT, Partition Around Medoids (PAM), Expectation Maximization (EM), dan K-Means, Pearson Correlation (PC), EMT, BO, GAO, WOA, Gradient Boosting Decision Tree (GBDT), Bayesian Belief Network (BNN), ADASYN, Regresi Proses Gaussian (GPR)	- Applied Computational Intelligence and Soft Computing - Education and Information Technologies - Electronics - IEEE Access - IEEE Transactions on Learning Technologies - Education and Computer Science - Journal of Intelligence - Sustainability
2025	[78][79][80][60][16][81]	Analisis Dataset Prediksi/Kualifikasi	6 Private 1 Public	LR, RF, KNN, NB, SVM, SMOTE, ANN, Feature-Wise Attention Layer (FWAL), Kolmogorov Arnold Networks (KAN), GCN, DT, NB	- Alexandria Engineering Journal - Big Data and Cognitive Computing - Risks - Social Network Analysis and Mining

Kesimpulan dan Saran

Tinjauan sistematis terhadap 75 artikel jurnal berkualitas tinggi (2020–2025) menunjukkan evolusi metodologi prediksi kelulusan mahasiswa, yang kini beralih dari penggunaan algoritma tunggal menuju pendekatan pra-pemrosesan data yang lebih kompleks dan sistematis. Temuan empiris menunjukkan bahwa penanganan *imbalanced data* melalui SMOTE dan seleksi fitur lebih krusial

daripada sekadar memilih algoritma mutakhir, di mana integrasi teknik ini mampu mendongkrak akurasi dari 70–75% ke rentang 85–97,9%. Implikasinya, institusi dapat memanfaatkan RF untuk intervensi dini berbasis variabel kunci (IPK atau aktivitas LMS), sementara pengembang harus beralih fokus ke arah *Explainable AI* (XAI) guna menjamin transparansi keputusan bagi para pendidik. Meskipun komprehensif, penelitian ini mencatat keterbatasan signifikan berupa ketergantungan pada data privat (91%) yang menghambat validasi eksternal, serta isu generalisasi antar-institusi dan aspek etika privasi. Sebagai langkah solutif, agenda riset mendatang diusulkan untuk mengadopsi pendekatan XAI demi transparansi manajemen, mengeksplorasi *Transfer Learning* untuk mengatasi hambatan akses data antar-kampus, serta mengintegrasikan data perilaku dinamis dari log LMS harian guna menciptakan sistem peringatan dini yang lebih proaktif dan akurat.

Referensi

- [1] E. Ahmed, "Student Performance Prediction Using Machine Learning Algorithms," *Appl. Comput. Intell. Soft Comput.*, vol. 2024, no. 1, p. 4067721, Jan. 2024, doi: 10.1155/2024/4067721.
- [2] R. Mehdi and M. Nachouki, "A neuro-fuzzy model for predicting and analyzing student graduation performance in computing programs," *Educ. Inf. Technol.*, vol. 28, no. 3, pp. 2455–2484, Mar. 2023, doi: 10.1007/s10639-022-11205-2.
- [3] D. Uliyan, A. S. Aljaloud, A. Alkhalil, H. S. A. Amer, M. A. E. A. Mohamed, and A. F. M. Alogali, "Deep Learning Model to Predict Students Retention Using BLSTM and CRF," *IEEE Access*, vol. 9, pp. 135550–135558, 2021, doi: 10.1109/ACCESS.2021.3117117.
- [4] S. Alturki, L. Cohausz, and H. Stuckenschmidt, "Predicting Master's students' academic performance: an empirical study in Germany," *Smart Learn. Environ.*, vol. 9, no. 1, p. 38, Dec. 2022, doi: 10.1186/s40561-022-00220-y.
- [5] L. K. Smirani, H. A. Yamani, L. J. Menzli, and J. A. Boulahia, "Using Ensemble Learning Algorithms to Predict Student Failure and Enabling Customized Educational Paths," *Sci. Program.*, vol. 2022, pp. 1–15, Apr. 2022, doi: 10.1155/2022/3805235.
- [6] Y. Yang, D. Hooshyar, M. Pedaste, M. Wang, Y.-M. Huang, and H. Lim, "Predicting course achievement of university students based on their procrastination behaviour on Moodle," *Soft Comput.*, vol. 24, no. 24, pp. 18777–18793, Dec. 2020, doi: 10.1007/s00500-020-05110-4.
- [7] R. Asad, S. Altaf, S. Ahmad, and H. Mahmoud, "Machine Learning-Based Hybrid Ensemble Model Achieving Precision Education for Online Education Amid the Lockdown Period of COVID-19 Pandemic in Pakistan," *MDPI Sustain.*, Mar. 2023, doi: <https://doi.org/10.3390/su15065431>.
- [8] L. Zhao *et al.*, "Academic Performance Prediction Based on Multisource, Multifeature Behavioral Data," *IEEE Access*, vol. 9, pp. 5453–5465, 2021, doi: 10.1109/ACCESS.2020.3002791.
- [9] J. Dai, "Improving Random Forest Algorithm for University Academic Affairs Management System Platform Construction," *Adv. Multimed.*, vol. 2022, pp. 1–9, July 2022, doi: 10.1155/2022/8064844.
- [10] L. R. Pelima, Y. Sukmana, and Y. Rosmansyah, "Predicting University Student Graduation Using Academic Performance and Machine Learning: A Systematic Literature Review," *IEEE Access*, vol. 12, pp. 23451–23465, 2024, doi: 10.1109/ACCESS.2024.3361479.
- [11] A. Kumar, B. Naqvi, and A. Wolff, "Exploring the energy informatics and energy citizenship domains: a systematic literature review," *Energy Inform.*, vol. 6, no. 1, Aug. 2023, doi: 10.1186/s42162-023-00268-1.
- [12] S. Nirmani, M. Shahin, H. Khalajzadeh, and X. Liu, "A systematic literature review on task recommendation systems for crowdsourced software engineering," *Inf. Softw. Technol.*, vol. 184, p. 107753, Aug. 2025, doi: 10.1016/j.infsof.2025.107753.

- [13] R. Shrestha, R. Knez, T. Acharya, and P. C. Bhattarai, "Ethical discourse on pro-environmental behavior: a systematic literature review using PRISMA," *Discov. Sustain.*, vol. 6, no. 1, p. 461, May 2025, doi: 10.1007/s43621-025-01296-5.
- [14] S. Yu, L. Zhong, and Y. Liu, "User Behavior Analysis and Prediction Model Construction in Higher Education Management Information Systems," *Appl. Math. Nonlinear Sci.*, vol. 9, no. 1, p. 20243300, Jan. 2024, doi: 10.2478/amns-2024-3300.
- [15] N. T. H. Thuy, N. T. V. Ha, N. N. Trung, V. T. T. Binh, N. T. Hang, and V. T. Binh, "Comparing the Effectiveness of Machine Learning and Deep Learning Models in Student Credit Scoring: A Case Study in Vietnam," *Risks*, vol. 13, no. 5, p. 99, May 2025, doi: 10.3390/risks13050099.
- [16] G. Wyness, L. Macmillan, J. Anders, and C. Dilnot, "Grade expectations: how well can past performance predict future grades?," *Educ. Econ.*, vol. 31, no. 4, pp. 397–418, July 2023, doi: 10.1080/09645292.2022.2113861.
- [17] R. Rois, M. Ray, A. Rahman, and S. K. Roy, "Prevalence and predicting factors of perceived stress among Bangladeshi university students using machine learning algorithms," *J. Health Popul. Nutr.*, vol. 40, no. 1, p. 50, Dec. 2021, doi: 10.1186/s41043-021-00276-5.
- [18] S. Fida, N. Masood, N. Tariq, and F. Qayyum, "A Novel Hybrid Ensemble Clustering Technique for Student Performance Prediction," *JUCS - J. Univers. Comput. Sci.*, vol. 28, no. 8, pp. 777–798, Aug. 2022, doi: 10.3897/jucs.73427.
- [19] S. Yang and W. Xie, "Applications and Challenges of Statistics in Large-Scale Data Mining," *Appl. Math. Nonlinear Sci.*, vol. 9, no. 1, p. 20241653, Jan. 2024, doi: 10.2478/amns-2024-1653.
- [20] H. Sokout, T. Usagawa, and S. Mukhtar, "Learning Analytics: Analyzing Various Aspects of Learners' Performance in Blended Courses. The Case of Kabul Polytechnic University, Afghanistan," *Int. J. Emerg. Technol. Learn. IJET*, vol. 15, no. 12, p. 168, June 2020, doi: 10.3991/ijet.v15i12.13473.
- [21] P. K. Sharma *et al.*, "IndoAirSense: A framework for indoor air quality estimation and forecasting," *Atmospheric Pollut. Res.*, vol. 12, no. 1, pp. 10–22, Jan. 2021, doi: 10.1016/j.apr.2020.07.027.
- [22] V. P. Romero and C. M. L. Alvarez, "Developing a Model to Predict Self-Reported Student Performance during Online Education Based on the Acoustic Environment," *MDPI Sustain.*, May 2024, doi: <https://doi.org/10.3390/su16114411>.
- [23] B. Tang, S. Li, and C. Zhao, "Predicting the Performance of Students Using Deep Ensemble Learning," *J. Intell.*, vol. 12, no. 12, p. 124, Dec. 2024, doi: 10.3390/jintelligence12120124.
- [24] J. E. Alderman *et al.*, "Tackling algorithmic bias and promoting transparency in health datasets: the STANDING Together consensus recommendations," *Lancet Digit. Health*, vol. 7, no. 1, pp. e64–e88, Jan. 2025, doi: 10.1016/S2589-7500(24)00224-3.
- [25] I. Riadi and R. Umar, "Prediksi Kelulusan Tepat Waktu Berdasarkan Riwayat Akademik Menggunakan Metode Naïve Bayes," *Decode J. Pendidik. Teknol. Inf.*, vol. 4, no. 1, pp. 191–203, Jan. 2024, doi: 10.51454/decode.v4i1.308.
- [26] I. Riadi, R. Umar, and R. Anggara, "Prediksi Kelulusan Tepat Waktu Berdasarkan Riwayat Akademik Menggunakan Metode K-Nearest Neighbor," *J. Teknol. Inf. Dan Ilmu Komput.*, vol. 11, no. 2, pp. 249–256, Apr. 2024, doi: 10.25126/jtiik.20241127330.
- [27] I. Riadi, R. Umar, and R. Anggara, "Comparative Analysis of Naive Bayes and K-NN Approaches to Predict Timely Graduation using Academic History," *Int. J. Comput. Digit. Syst.*, vol. 15, no. 1, pp. 1163–1174, Sept. 2024, doi: 10.12785/ijcds/160185.
- [28] Huawei Technologies Co., Ltd., *Artificial Intelligence Technology*. Singapore: Springer Nature Singapore, 2023. doi: 10.1007/978-981-19-2879-6.

- [29] B. Albreiki, T. Habuza, and N. Zaki, "Extracting topological features to identify at-risk students using machine learning and graph convolutional network models," *Int. J. Educ. Technol. High. Educ.*, vol. 20, no. 1, p. 23, Apr. 2023, doi: 10.1186/s41239-023-00389-3.
- [30] M. A. Aslam, F. Murtaza, M. E. U. Haq, A. Yasin, and M. A. Azam, "A Human-Centered Approach to Academic Performance Prediction Using Personality Factors in Educational AI," *Information*, vol. 15, no. 12, p. 777, Dec. 2024, doi: 10.3390/info15120777.
- [31] S. A. A. Balabied and H. F. Eid, "Utilizing random forest algorithm for early detection of academic underperformance in open learning environments," *PeerJ Comput. Sci.*, vol. 9, p. e1708, Nov. 2023, doi: 10.7717/peerj-cs.1708.
- [32] M. Bellaj, A. B. Dahmane, S. Boudra, and M. L. Sefian, "Educational Data Mining: Employing Machine Learning Techniques and Hyperparameter Optimization to Improve Students' Academic Performance," *Int. J. Online Biomed. Eng. IJOE*, vol. 20, no. 03, pp. 55–74, Feb. 2024, doi: 10.3991/ijoe.v20i03.46287.
- [33] K. R. Mahmudah, F. Indriani, Y. Takemori-Sakai, Y. Iwata, T. Wada, and K. Satou, "Classification of Imbalanced Data Represented as Binary Features," *Appl. Sci.*, vol. 11, no. 17, p. 7825, Aug. 2021, doi: 10.3390/app11177825.
- [34] 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.
- [35] L. Vives *et al.*, "Prediction of Students' Academic Performance in the Programming Fundamentals Course Using Long Short-Term Memory Neural Networks," *IEEE Access*, vol. 12, pp. 5882–5898, 2024, doi: 10.1109/ACCESS.2024.3350169.
- [36] A. Zanellati, S. P. Zingaro, and M. Gabbrielli, "Balancing Performance and Explainability in Academic Dropout Prediction," *IEEE Trans. Learn. Technol.*, vol. 17, pp. 2086–2099, 2024, doi: 10.1109/TLT.2024.3425959.
- [37] S. Farshidi *et al.*, "Understanding user intent modeling for conversational recommender systems: a systematic literature review," *User Model. User-Adapt. Interact.*, vol. 34, no. 5, pp. 1643–1706, Nov. 2024, doi: 10.1007/s11257-024-09398-x.
- [38] S. Sarmini, S. Sunardi, and A. Fadlil, "Performa Random Forest dan XGBoost pada Deteksi Penipuan E-Commerce Menggunakan Augmentasi Data CGAN," *Build. Inform. Technol. Sci. BITS*, vol. 6, no. 3, pp. 1919–1931, Dec. 2024, doi: 10.47065/bits.v6i3.6430.
- [39] S. Sarmini, S. Sunardi, and A. Fadlil, "Evaluating The Effectiveness of Augmentation and Classifier Algorithms for Fraud Detection: Comparing CGAN and SMOTE with Random Forest and XGBoost," *Appl. Inf. Syst. Manag. AISM*, vol. 8, no. 2, pp. 221–230, Oct. 2025, doi: 10.15408/aism.v8i2.46308.
- [40] S. Sunardi, A. Ramadhan, E. Abdurachman, A. Trisetyarso, and M. Zarlis, "Acceptance of augmented reality in video conference based learning during COVID-19 pandemic in higher education," *Bull. Electr. Eng. Inform.*, vol. 11, no. 6, pp. 3598–3608, Dec. 2022, doi: 10.11591/eei.v11i6.4035.
- [41] A. I. Adekitan and O. Salau, "Toward an improved learning process: the relevance of ethnicity to data mining prediction of students' performance," *SN Appl. Sci.*, vol. 2, no. 1, p. 8, Jan. 2020, doi: 10.1007/s42452-019-1752-1.
- [42] A. Al-Azawei and M. A. A. Al-Masoudy, "Predicting Learners' Performance in Virtual Learning Environment (VLE) based on Demographic, Behavioral and Engagement Antecedents," *Int. J. Emerg. Technol. Learn. IJET*, vol. 15, no. 09, p. 60, May 2020, doi: 10.3991/ijet.v15i09.12691.

- [43] Y. He *et al.*, "Online At-Risk Student Identification using RNN-GRU Joint Neural Networks," *Information*, vol. 11, no. 10, p. 474, Oct. 2020, doi: 10.3390/info11100474.
- [44] J. López Zambrano, J. A. Lara, and C. Romero, "Towards Portability of Models for Predicting Students' Final Performance in University Courses Starting from Moodle Logs," *Appl. Sci.*, vol. 10, no. 1, p. 354, Jan. 2020, doi: 10.3390/app10010354.
- [45] H. A. Mengash, "Using Data Mining Techniques to Predict Student Performance to Support Decision Making in University Admission Systems," *IEEE Access*, vol. 8, pp. 55462–55470, 2020, doi: 10.1109/ACCESS.2020.2981905.
- [46] M. Injadat, A. Moubayed, A. B. Nassif, and A. Shami, "Multi-split optimized bagging ensemble model selection for multi-class educational data mining," *Appl. Intell.*, vol. 50, no. 12, pp. 4506–4528, Dec. 2020, doi: 10.1007/s10489-020-01776-3.
- [47] I. Smirnov, "Estimating educational outcomes from students' short texts on social media," *EPJ Data Sci.*, vol. 9, no. 1, p. 27, Dec. 2020, doi: 10.1140/epjds/s13688-020-00245-8.
- [48] A. Esteban, C. Romero, and A. Zafra, "Assignments as Influential Factor to Improve the Prediction of Student Performance in Online Courses," *Appl. Sci.*, vol. 11, no. 21, p. 10145, Oct. 2021, doi: 10.3390/app112110145.
- [49] P. Hai tao *et al.*, "Predicting academic performance of students in Chinese-foreign cooperation in running schools with graph convolutional network," *Neural Comput. Appl.*, vol. 33, no. 2, pp. 637–645, Jan. 2021, doi: 10.1007/s00521-020-05045-9.
- [50] P. Nuankaew, P. Nasa ngium, and W. S. Nuankaew, "Application for Identifying Students Achievement Prediction Model in Tertiary Education: Learning Strategies for Lifelong Learning," *Int. J. Interact. Mob. Technol. IJIM*, vol. 15, no. 22, p. 22, Nov. 2021, doi: 10.3991/ijim.v15i22.24069.
- [51] L. S. Maurya, M. S. Hussain, and S. Singh, "Developing Classifiers through Machine Learning Algorithms for Student Placement Prediction Based on Academic Performance," *Appl. Artif. Intell.*, vol. 35, no. 6, pp. 403–420, May 2021, doi: 10.1080/08839514.2021.1901032.
- [52] J. Kabathova and M. Drlik, "Towards Predicting Student's Dropout in University Courses Using Different Machine Learning Techniques," *Appl. Sci.*, vol. 11, no. 7, p. 3130, Apr. 2021, doi: 10.3390/app11073130.
- [53] B. K. Yousafzai *et al.*, "Student-Performulator: Student Academic Performance Using Hybrid Deep Neural Network," *Sustainability*, vol. 13, no. 17, p. 9775, Aug. 2021, doi: 10.3390/su13179775.
- [54] Y. Baashar *et al.*, "Evaluation of postgraduate academic performance using artificial intelligence models," *Alex. Eng. J.*, vol. 61, no. 12, pp. 9867–9878, Dec. 2022, doi: 10.1016/j.aej.2022.03.021.
- [55] E. Çakıt and M. Dağdeviren, "Predicting the percentage of student placement: A comparative study of machine learning algorithms," *Educ. Inf. Technol.*, vol. 27, no. 1, pp. 997–1022, Jan. 2022, doi: 10.1007/s10639-021-10655-4.
- [56] N. Messaoudi, J. K. Naciri, and B. Bensassi, "Students' Results Prediction Using Machine Learning Algorithms and Online Learning during the COVID-19 Pandemic," *Int. J. Mod. Educ. Comput. Sci.*, vol. 16, no. 4, pp. 17–34, Aug. 2024, doi: 10.5815/ijmecs.2024.04.02.
- [57] 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, July 2022, doi: 10.1155/2022/2581951.
- [58] C. Liu, H. Wang, and Z. Yuan, "A Method for Predicting the Academic Performances of College Students Based on Education System Data," *Mathematics*, vol. 10, no. 20, p. 3737, Oct. 2022, doi: 10.3390/math10203737.

- [59] G. Feng, M. Fan, and C. Ao, "Exploration and Visualization of Learning Behavior Patterns From the Perspective of Educational Process Mining," *IEEE Access*, vol. 10, pp. 65271–65283, 2022, doi: 10.1109/ACCESS.2022.3184111.
- [60] S. Gaftandzhieva *et al.*, "Exploring Online Activities to Predict the Final Grade of Student," *Mathematics*, vol. 10, no. 20, p. 3758, Oct. 2022, doi: 10.3390/math10203758.
- [61] S. Garmpis, M. Maragoudakis, and A. Garmpis, "Assisting Educational Analytics with AutoML Functionalities," *Computers*, vol. 11, no. 6, p. 97, June 2022, doi: 10.3390/computers11060097.
- [62] M. Yagcı, "Educational data mining: prediction of students' academic performance using machine learning algorithms," *Smart Learn. Environ.*, vol. 9, no. 1, p. 11, Dec. 2022, doi: 10.1186/s40561-022-00192-z.
- [63] M. Gollapalli *et al.*, "SUNFIT: A Machine Learning-Based Sustainable University Field Training Framework for Higher Education," *MDPI Sustain.*, May 2023, doi: <https://doi.org/10.3390/su15108057>.
- [64] S. Issaro and P. Wannapiroon, "Intelligent Student Relationship Management Platform with Machine Learning for Student Empowerment," *Int. J. Emerg. Technol. Learn. IJET*, vol. 18, no. 04, pp. 66–87, Feb. 2023, doi: 10.3991/ijet.v18i04.32583.
- [65] S. Atalla *et al.*, "An Intelligent Recommendation System for Automating Academic Advising Based on Curriculum Analysis and Performance Modeling," *Mathematics*, vol. 11, no. 5, p. 1098, Feb. 2023, doi: 10.3390/math11051098.
- [66] K. Qin, X. Xie, Q. He, and G. Deng, "Early Warning of Student Performance With Integration of Subjective and Objective Elements," *IEEE Access*, vol. 11, pp. 72601–72617, 2023, doi: 10.1109/ACCESS.2023.3295580.
- [67] Z. Fan and R. Chiong, "Identifying digital capabilities in university courses: An automated machine learning approach," *Educ. Inf. Technol.*, vol. 28, no. 4, pp. 3937–3952, Apr. 2023, doi: 10.1007/s10639-022-11075-8.
- [68] T. S. Lopez, D. P. Perez, V. G. Ruiz, and L. F. Carvajal, "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 Publ.*, vol. 98, no. 3, pp. 282–287, May 2023, doi: 10.6036/10760.
- [69] K. Wang, "Academic Early Warning Model for Students Based on Big Data Analysis," *Int. J. Emerg. Technol. Learn. IJET*, vol. 18, no. 12, pp. 16–31, June 2023, doi: 10.3991/ijet.v18i12.41087.
- [70] D. Sun *et al.*, "A University Student Performance Prediction Model and Experiment Based on Multi-Feature Fusion and Attention Mechanism," *IEEE Access*, vol. 11, pp. 112307–112319, 2023, doi: 10.1109/ACCESS.2023.3323365.
- [71] N. U. R. Junejo *et al.*, "SAPPNet: students' academic performance prediction during COVID-19 using neural network," *Sci. Rep.*, vol. 14, no. 1, p. 24605, Oct. 2024, doi: 10.1038/s41598-024-75242-2.
- [72] D. Khairy, N. Alharbi, M. A. Amasha, M. F. Areed, S. Alkhalaf, and R. A. Abougalala, "Prediction of student exam performance using data mining classification algorithms," *Educ. Inf. Technol.*, vol. 29, no. 16, pp. 21621–21645, Nov. 2024, doi: 10.1007/s10639-024-12619-w.
- [73] J. A. I. S. Masood, N. S. Kalyan Chakravarthy, D. Asirvatham, M. Marjani, D. Abdulkareem Shafiq, and S. Nidamanuri, "A Hybrid Deep Learning Model to Predict High-Risk Students in Virtual Learning Environments," *IEEE Access*, vol. 12, pp. 103687–103703, 2024, doi: 10.1109/ACCESS.2024.3434644.

- [74] M. R. Borna, H. Saadat, A. T. Hojjati, and E. Akbari, "Analyzing click data with AI: implications for student performance prediction and learning assessment," *Front. Educ.*, vol. 9, p. 1421479, Dec. 2024, doi: 10.3389/feduc.2024.1421479.
- [75] D. Monteverde Suárez *et al.*, "Predicting students' academic progress and related attributes in first-year medical students: an analysis with artificial neural networks and Naïve Bayes," *BMC Med. Educ.*, vol. 24, no. 1, p. 74, Jan. 2024, doi: 10.1186/s12909-023-04918-6.
- [76] M. Milicevic, B. Marinovic, and L. Jeftic, "Machine learning methods as auxiliary tool for effective mathematics teaching," *Comput. Appl. Eng. Educ.*, vol. 32, no. 6, p. e22787, Nov. 2024, doi: 10.1002/cae.22787.
- [77] N. G. Cu, T. L. Nghiem, T. H. Ngo, M. T. 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, no. 1, p. 4795606, Jan. 2024, doi: 10.1155/2024/4795606.
- [78] M. S. Ramirez Montoya, R. Morales Menendez, M. Tworek, C. A. Escobar, R. Tariq, and G. C. Tenorio Sepulveda, "Complex competencies for leader education: artificial intelligence analysis in student achievement profiling," *Cogent Educ.*, vol. 11, no. 1, p. 2378508, Dec. 2024, doi: 10.1080/2331186X.2024.2378508.
- [79] 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, no. 10, p. 1928, May 2024, doi: 10.3390/electronics13101928.
- [80] M. A. Aslam, F. Murtaza, M. E. U. Haq, A. Yasin, and N. Ali, "SAPEX-D: A Comprehensive Dataset for Predictive Analytics in Personalized Education Using Machine Learning," *Data*, vol. 10, no. 3, p. 27, Feb. 2025, doi: 10.3390/data10030027.
- [81] B. Alnasyan, M. Basher, M. Alassafi, and K. Alnasyan, "Kanformer: an attention-enhanced deep learning model for predicting student performance in virtual learning environments," *Soc. Netw. Anal. Min.*, vol. 15, no. 1, p. 25, Mar. 2025, doi: 10.1007/s13278-025-01446-7.
- [82] T. Jin, "Methods and reliability study of moral education assessment in universities: A machine learning-based approach," *Alex. Eng. J.*, vol. 125, pp. 20–28, June 2025, doi: 10.1016/j.aej.2025.03.095.
- [83] A. Kord, A. Aboelfetouh, and S. M. Shohieb, "Academic course planning recommendation and students' performance prediction multi-modal based on educational data mining techniques," *J. Comput. High. Educ.*, Jan. 2025, doi: 10.1007/s12528-024-09426-0.
- [84] L. S. Chen, T. T. Huynh Cam, V. C. Nguyen, T. C. Lu, and D. K. Le Huynh, "Predicting Early Employability of Vietnamese Graduates: Insights from Data-Driven Analysis Through Machine Learning Methods," *Big Data Cogn. Comput.*, vol. 9, no. 5, p. 134, May 2025, doi: 10.3390/bdcc9050134.
- [85] S. E. Hooper, N. Ragland, and E. Artemiou, "Random forest models reveal academic and financial factors outweigh demographics in predicting completion of a year-round veterinary program," *J. Am. Vet. Med. Assoc.*, vol. 263, no. 2, pp. 1–9, Feb. 2025, doi: 10.2460/javma.24.08.0501.
- [86] L. Yan and Y. Liu, "An Ensemble Prediction Model for Potential Student Recommendation Using Machine Learning," *Symmetry*, vol. 12, no. 5, p. 728, May 2020, doi: 10.3390/sym12050728.
- [87] N. Messaoudi, G. Moukhliiss, J. K. Naciri, and B. Bensassi, "Machine Learning Algorithms for Quantifying the Role of Prerequisites in University Success," *Int. J. Mod. Educ. Comput. Sci.*, vol. 14, no. 6, pp. 1–12, Dec. 2022, doi: 10.5815/ijmecs.2022.06.01.