

## **A Systematic Review of Random Forest and Logistic Regression Algorithms for Predicting Student Readiness in LSP-P1 Competency Certification at Vocational High Schools**

Muhammad Zainal Abidin<sup>1</sup>, Antonius Wahyu Sudrajat<sup>2</sup>, Johannes Petrus<sup>3\*</sup>

<sup>1-3</sup>Magister Sistem Informasi, Fakultas Ilmu Komputer dan Rekayasa Universitas MDP

<sup>1-3</sup>Jln. Rajawali No. 14 Palembang

Email: [zainalabidin86@guru.smk.belajar.id](mailto:zainalabidin86@guru.smk.belajar.id), [wahyu.sudrajat@mdp.ac.id](mailto:wahyu.sudrajat@mdp.ac.id), [johannes@mdp.ac.id](mailto:johannes@mdp.ac.id)<sup>3\*</sup>

### **Abstract**

*Assessing student readiness for LSP-P1 Competency Certification in Indonesian vocational schools is still commonly performed manually, resulting in subjective and potentially inaccurate decisions. Although existing studies have applied machine learning algorithms such as Random Forest and Logistic Regression to predict academic performance, limited research specifically focuses on vocational certification readiness within the Indonesian LSP-P1 context. This study applies a Systematic Literature Review (SLR) following Kitchenham and Charters guidelines to examine research trends, predictor variables, and key findings from previous studies. The review reveals that both algorithms are promising for readiness prediction; however, no study has explicitly addressed their application for LSP-P1 readiness at the SMK level. This work identifies research gaps and highlights opportunities for future development of data-driven decision support systems.*

**Key Words:** *Systematic Literature Review, Random Forest, Logistic Regression, LSP-P1, Vocational Education*

### **Abstrak**

Penentuan kesiapan siswa dalam mengikuti Sertifikasi Kompetensi LSP-P1 di SMK selama ini masih dilakukan secara manual dan cenderung subjektif, sehingga berisiko menghasilkan keputusan yang kurang akurat. Padahal, sejumlah penelitian telah menerapkan algoritma machine learning seperti Random Forest dan Logistic Regression untuk prediksi performa siswa, namun belum banyak yang berfokus pada konteks pendidikan vokasi dan sertifikasi kompetensi di Indonesia. Penelitian ini melakukan Systematic Literature Review (SLR) menggunakan panduan Kitchenham & Charters untuk mengidentifikasi tren, variabel prediktor, dan temuan utama dari penelitian sebelumnya. Hasil analisis menunjukkan bahwa kedua algoritma memiliki potensi untuk diimplementasikan pada prediksi kesiapan siswa mengikuti LSP-P1, namun belum ada penelitian yang secara spesifik mengkaji implementasinya dalam konteks SMK dan kebijakan vokasi nasional. Penelitian ini memberikan arah riset lanjutan dan peluang pengembangan sistem pendukung keputusan berbasis data.

**Kata Kunci:** *Systematic Literature Review, Random Forest, Logistic Regression, LSP-P1, SMK*

### **Pendahuluan**

Pendidikan vokasi memiliki orientasi utama untuk menghasilkan lulusan yang kompeten sesuai kebutuhan industri. Salah satu instrumen resmi penjaminan mutu kompetensi di Sekolah Menengah Kejuruan (SMK) adalah Sertifikasi Kompetensi LSP-P1, yang bertujuan untuk memastikan kemampuan siswa memenuhi standar kompetensi berbasis SKKNI. Namun, penentuan kesiapan siswa dalam mengikuti sertifikasi ini di sebagian besar satuan pendidikan masih dilakukan secara manual melalui penilaian subjektif guru, sehingga berpotensi menimbulkan keterlambatan intervensi dan ketidaktepatan dalam pemetaan kesiapan siswa.

Seiring berkembangnya teknologi data dan kecerdasan buatan, machine learning telah banyak digunakan dalam domain pendidikan untuk melakukan prediksi kelulusan, kesiapan akademik, dan performa belajar siswa [1], [2]. Berbagai penelitian sebelumnya telah menerapkan algoritma seperti *Decision Tree*, *Naïve Bayes*, *K-Nearest Neighbor*, *Random Forest*, dan *Logistic Regression* untuk

memprediksi hasil belajar dan kesuksesan akademik berbasis data historis [1], [2], [3], [4], [5]. Khususnya, algoritma RF dikenal unggul dalam memodelkan data kompleks dan non-linear, sedangkan LR unggul pada interpretabilitas model serta efisiensi komputasi [1], [5].

Penelitian mengenai prediksi performa peserta didik telah banyak dilakukan, baik di tingkat sekolah maupun perguruan tinggi [1], [2], [3], [5]. Namun demikian, sebagian besar fokus penelitian masih berada pada konteks prediksi kelulusan akademik umum dan bukan pada kesiapan mengikuti sertifikasi kompetensi vokasi, terlebih dalam konteks standar LSP-P1 di SMK. Hal ini menunjukkan adanya *research gap*, yakni belum adanya *systematic mapping* yang secara khusus mengidentifikasi penggunaan algoritma *Random Forest* dan *Logistic Regression* dalam prediksi kesiapan siswa mengikuti sertifikasi kompetensi berbasis BNSP.

Berdasarkan celah penelitian tersebut, penelitian ini melakukan *Systematic Literature Review* (SLR) untuk memetakan, menganalisis, serta mensintesis temuan-temuan penelitian terdahulu terkait penggunaan kedua algoritma tersebut. Tujuan utama penelitian ini adalah:

1. Mengidentifikasi tren penelitian terkait prediksi kompetensi siswa menggunakan algoritma RF dan LR.
2. Menganalisis variabel yang dominan digunakan sebagai indikator kesiapan siswa.
3. Memetakan kelebihan dan kekurangan tiap algoritma berbasis temuan literatur.
4. Mengidentifikasi potensi pengembangan riset selanjutnya pada konteks sertifikasi kompetensi di SMK.

Dengan demikian, hasil tinjauan ini diharapkan dapat menjadi dasar ilmiah untuk pengembangan model prediksi readiness berbasis *machine learning* serta bahan pertimbangan dalam pengambilan keputusan berbasis data (*data-driven decision making*) pada lingkungan pendidikan vokasi.

## Metode Penelitian

Penelitian ini menggunakan metode *Systematic Literature Review* (SLR) yang merujuk pada prosedur yang direkomendasikan oleh Kitchenham & Charters. Pemilihan prosedur ini didasarkan pada fakta bahwa pedoman SLR tersebut merupakan standar paling luas digunakan dalam penelitian rekayasa perangkat lunak, *data science*, dan *machine learning*, karena menawarkan alur kerja yang sistematis, transparan, dapat direplikasi, serta mendefinisikan secara rinci tahapan pencarian, seleksi, ekstraksi, dan sintesis literatur [6]. Meskipun pedoman SLR lain seperti PRISMA banyak digunakan dalam penelitian bidang kesehatan dan ilmu sosial [7], pendekatan Kitchenham & Charters lebih sesuai untuk konteks penelitian berbasis komputasi karena dirancang untuk studi yang mengevaluasi algoritma, model, dan eksperimen berbasis data. Dengan demikian, penerapan panduan Kitchenham & Charters dipandang paling tepat untuk memperoleh sintesis berbasis bukti ilmiah dalam konteks kajian algoritma prediksi kesiapan siswa menggunakan *machine learning*. Selain itu, penelitian ini tetap mengintegrasikan PRISMA Flow Diagram sebagai pelengkap dokumentasi proses penyaringan literatur guna meningkatkan transparansi pelaporan hasil penelusuran publikasi [7]. Tahapan metodologi ini dibagi menjadi lima proses utama, yaitu: (1) *Define Review Objective*, (2) *Specify Research Questions*, (3) *Develop Search Strategy*, (4) *Specify Study Selection Criteria*, serta (5) *Extract and Synthesize Data* [8], [9], [10].

### 1. Define Review Objective

Tujuan utama dari penelitian ini adalah melakukan pemetaan ilmiah mengenai penggunaan algoritma *Random Forest* dan *Logistic Regression* dalam memprediksi kesiapan atau performa siswa, serta menilai potensi penerapannya pada konteks Sertifikasi Kompetensi LSP-P1 di SMK. Berdasarkan penelitian sebelumnya, kedua algoritma tersebut telah digunakan secara luas dalam sistem prediksi berbasis *machine learning* pada bidang pendidikan [1], [3], [5], namun terdapat kesenjangan penelitian ketika dikaitkan dengan konteks sertifikasi kompetensi vokasi. Dengan

demikian, tujuan khusus penelitian ini meliputi:

- Mengidentifikasi model prediksi yang relevan untuk konteks kesiapan siswa vokasi.
- Mengevaluasi variabel yang paling dominan digunakan sebagai predictor.
- Membandingkan kinerja dan karakteristik algoritma RF dan LR.
- Mengidentifikasi research gap untuk pengembangan penelitian lanjutan.

## 2. Specify Research Questions

Penyusunan *research questions* dilakukan agar penelitian ini tidak hanya memetakan penggunaan algoritma *machine learning* pada bidang pendidikan, tetapi juga melengkapi temuan penelitian sebelumnya yang belum mengkaji secara spesifik: (1) algoritma apa yang paling relevan untuk prediksi kesiapan siswa pada pendidikan vokasi, (2) bagaimana efektivitas *Random Forest* dan *Logistic Regression* dalam konteks pendidikan, (3) variabel apa saja yang dominan memengaruhi prediksi kesiapan siswa, (4) perbandingan kelebihan dan keterbatasan masing-masing algoritma, serta (5) celah penelitian (research gap) terkait penerapan model prediksi kesiapan siswa menuju Sertifikasi Kompetensi LSP-P1 di SMK. Dengan demikian, setiap RQ dirancang untuk mengisi kekosongan literatur yang belum dijelaskan secara memadai pada penelitian sebelumnya.

**Tabel 1** *Research Question*

| ID  | Research Question                                                                                                                                                                             | Motivation                                                                                                                                                                              |
|-----|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| RQ1 | Model <i>machine learning</i> apa saja yang digunakan untuk memprediksi kesiapan atau performa siswa?                                                                                         | Untuk mengidentifikasi algoritma paling relevan dan banyak digunakan dalam penelitian prediksi performa pendidikan sebagai dasar pemetaan teknologi dan tren ilmiah.                    |
| RQ2 | Bagaimana penerapan algoritma <i>Random Forest</i> dan <i>Logistic Regression</i> dalam konteks prediksi pendidikan?                                                                          | Untuk mengetahui kesesuaian dan efektivitas kedua algoritma berdasarkan konteks evaluasi yang digunakan dalam penelitian sebelumnya                                                     |
| RQ3 | Variabel apa saja yang digunakan sebagai faktor prediksi dalam model berbasis <i>Random Forest</i> dan <i>Logistic Regression</i> ?                                                           | Untuk mengetahui variabel dan indikator terhadap prediksi kesiapan siswa sehingga dapat dijadikan acuan dalam pengembangan model prediksi di lingkungan SMK dan LSP-P1                  |
| RQ4 | Apa kelebihan dan kekurangan masing-masing algoritma berdasarkan bukti empiris penelitian sebelumnya?                                                                                         | Untuk membandingkan performa, interpretabilitas, kompleksitas model, serta potensi implementasi praktis sebagai dasar rekomendasi penggunaan algoritma.                                 |
| RQ5 | Apa <i>research gap</i> terkait penerapan <i>machine learning</i> , khususnya <i>Random Forest</i> dan <i>Logistic Regression</i> pada konteks kesiapan Sertifikasi Kompetensi LSP-P1 di SMK? | Untuk menemukan celah penelitian yang belum diteliti serta memberikan arah pengembangan riset dan implementasi sistem pendukung keputusan berbasis data pada lembaga pendidikan vokasi. |

Dengan demikian, setiap RQ dirancang untuk menjawab aspek yang belum dipetakan secara eksplisit pada literatur terdahulu sehingga SLR ini dapat menghasilkan sintesis temuan berbasis bukti yang langsung relevan untuk konteks kesiapan siswa SMK menghadapi Sertifikasi Kompetensi LSP-P1. Penyusunan *research questions* sejalan dengan prinsip SLR yang bertujuan menghasilkan analisis komprehensif berbasis bukti [8], [10].

### 3. Develop Search Strategy

Pemilihan strategi pencarian pada penelitian ini tidak hanya bertujuan mengumpulkan artikel yang relevan, tetapi juga melengkapi keterbatasan penelusuran pada penelitian terdahulu, yang pada umumnya hanya memanfaatkan satu atau dua basis data internasional dan kurang merepresentasikan konteks pendidikan vokasi di Indonesia. Oleh karena itu, basis data internasional yang berfokus pada komputasi dan machine learning seperti IEEE Xplore, ScienceDirect, SpringerLink, dan Scopus disertakan untuk memperoleh publikasi bereputasi tinggi dan terkini, sedangkan Google Scholar, SINTA 1–2, serta ResearchGate/Academia ditambahkan untuk memastikan cakupan literatur nasional dan akses repositori terbuka tidak terlewat. Dengan cara ini, strategi pencarian dirancang untuk menghasilkan cakupan literatur yang lebih komprehensif dan kontekstual, sekaligus memastikan proses SLR mengidentifikasi studi yang relevan pada berbagai level publikasi—baik internasional maupun nasional—yang diperlukan untuk memetakan perkembangan riset prediksi kesiapan siswa di pendidikan vokasi [1], [2], [3], [5], [11].

Kombinasi database internasional dan nasional ini dirancang untuk mengurangi bias publikasi dan memastikan keberagaman perspektif penelitian, sebagaimana direkomendasikan dalam praktik SLR bidang komputasi.

**Tabel 2 Database/Repository**

| No | Database/Repository      | Alasan Pemilihan                                                   |
|----|--------------------------|--------------------------------------------------------------------|
| 1  | IEEE Xplore              | Relevan untuk penelitian dan <i>machine learning</i>               |
| 2  | ScienceDirect (Elsevier) | Banyak menyediakan artikel bidang pendidikan, komputasi dan sosial |
| 3  | SpringerLink             | Mendukung publikasi bidang AI, sistem pendidikan dan data mining   |
| 4  | Scopus Indexed Resources | Standar acuan kualitas riset global                                |
| 5  | Google Scholar           | Menjangkau publikasi pendidikan dan repositori terbuka             |
| 6  | SINTA 1 & 2              | Mendukung konteks penelitian pendidikan vokasi Indonesia           |
| 7  | ResearchGate/Academia    | Alternatif akses duplikasi file publikasi ilmiah                   |

Penggunaan *Boolean Operator (AND, OR)*, *Truncation*, dan *Synonym Expansion* diterapkan untuk meningkatkan relevansi penelusuran literatur dan mencegah hilangnya artikel penting hanya karena perbedaan istilah pencarian. Teknik ini membantu memperluas hasil penelusuran tanpa mengabaikan relevansi topik, khususnya karena istilah-istilah dalam penelitian *machine learning* pada bidang pendidikan sering memiliki variasi terminologi di antara penulis. Selain itu, kombinasi teknik pencarian ini memastikan bahwa proses identifikasi artikel berjalan secara sistematis dan tidak bias, sehingga studi yang terpilih benar-benar merepresentasikan perkembangan riset terkini pada topik prediksi kesiapan siswa menggunakan algoritma *machine learning*.

**Tabel 3 SLR Keyword**

| SLR Element        | Keyword / Boolean Query                                              | Tujuan                                         |
|--------------------|----------------------------------------------------------------------|------------------------------------------------|
| Topic Focus        | "Random Forest" OR "Logistic Regression"                             | Menyeleksi algoritma yang dibandingkan         |
| Research Domain    | "Student readiness" OR "student performance" OR "student competency" | Mengarahkan konteks pendidikan                 |
| Vocational Context | "vocational" OR "SMK" OR "LSP-P1" OR "competency certification"      | Membatasi pada pendidikan vokasi & sertifikasi |
| Methodology        | "Machine learning" OR "prediction" OR "classification"               | Mengidentifikasi jenis pendekatan riset        |
| Exclusion          | NOT "medical" NOT "financial" NOT "industry manufacturing"           | Mengeliminasi distorsi bidang lain             |
| Publication Window | Published: 2021–2025                                                 | Menjamin pembaruan tren data dan relevansi     |

Pencarian difokuskan pada artikel publikasi 2021–2025 untuk memastikan kesesuaian dengan perkembangan algoritma machine learning terbaru dalam bidang pendidikan [1], [3], [4]. Batasan rentang waktu ini juga mencegah penggunaan temuan lama yang tidak lagi relevan dengan praktik dan teknologi vokasi saat ini. Dengan demikian, hasil SLR yang diperoleh dapat merepresentasikan kondisi terkini dalam penelitian prediksi kesiapan siswa.

#### 4. Specify Selection Criteria

Proses seleksi dilakukan dalam dua tahapan, yaitu seleksi awal (*screening*) dan seleksi lanjutan (*eligibility*). Tahap *screening* digunakan untuk menyaring artikel berdasarkan judul dan abstrak guna memastikan kesesuaian awal dengan ruang lingkup penelitian, sedangkan tahap *eligibility* dilakukan dengan membaca *full-text* untuk memutuskan kelayakan artikel berdasarkan kriteria inklusi dan eksklusi yang telah ditetapkan. Kriteria seleksi dirumuskan sebagai berikut:

**Tabel 4** Selection Criteria

| Kategori             | Inclusion Criteria (IC)                                   | Exclusion Criteria (EC)                              |
|----------------------|-----------------------------------------------------------|------------------------------------------------------|
| Jenis Dokumen        | Artikel Ilmiah peer-reviewed (jurnal/konferensi)          | Thesis, skripsi, blog, berita, dokumen non-ilmiah    |
| Periode Publikasi    | Tahun 2021-2025                                           | Di luar periode tersebut                             |
| Metode               | Melibatkan <i>machine learning</i> , khususnya RF atau LR | Tidak menggunakan RF atau LR                         |
| Domain Penelitian    | Lingkup pendidikan, performa, readiness, kompetensi       | Fokus pada medis, finansial, manufaktur, cuaca       |
| Ketersediaan Dokumen | Full-text dapat diakses                                   | Hanya abstrak / tidak bisa diunduh                   |
| Relevansi Konteks    | Fokus pada performa, kesiapan, evaluasi, kompetensi siswa | Tidak berhubungan dengan pendidikan atau sertifikasi |

Pendekatan seleksi mengikuti prinsip *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) untuk mengurangi bias publikasi [9], [10]. Penerapan kriteria inklusi (IC) dan eksklusi (EC) dilakukan secara berurutan pada tahap *screening* dan *eligibility* agar hanya artikel yang sesuai dengan ruang lingkup riset yang dianalisis lebih lanjut. Mekanisme ini memastikan bahwa studi yang dipilih bukan hanya memenuhi tema machine learning untuk prediksi performa pendidikan, tetapi juga relevan secara langsung dengan konteks kesiapan atau kompetensi siswa, sehingga proses SLR benar-benar menghasilkan kumpulan literatur yang kredibel, representatif, dan sesuai tujuan penelitian.

#### 5. Extract and Synthesize Data

Tahap ini dilakukan dengan melakukan ekstraksi informasi utama dari artikel terpilih, meliputi:

- Informasi bibliografi (penulis, tahun, negara)
- Jenis algoritma dan metodologi eksperimen
- Sumber dan karakteristik dataset
- Variabel input (akademik & non-akademik)
- Metrik evaluasi (accuracy, precision, recall, f1-score, AUC)
- Hasil temuan utama dan kontribusi penelitian

Proses sintesis dilakukan secara narrative synthesis dan comparative analysis untuk memetakan tren dan memberikan pemahaman komprehensif [8], [9].

Tabel Quality Assessment (QA Metric Scoring)

Metode penilaian menggunakan skala 0–2, dengan ketentuan:

0 = Tidak memenuhi / tidak dijelaskan

1 = Dijelaskan sebagian / tidak lengkap



**Tabel 5** *Quality Assesment Metric Scoring*


| No  | QA Item               | Pertanyaan Penilaian Kualitas                                     | Skor (0-2) |
|-----|-----------------------|-------------------------------------------------------------------|------------|
| QA1 | Relevansi topik       | Apakah topik penelitian selaras dengan RQ?                        | 0 / 1 / 2  |
| QA2 | Kejelasan tujuan      | Apakah tujuan penelitian dijelaskan secara jelas dan terukur?     | 0 / 1 / 2  |
| QA3 | Kualitas metodologi   | Apakah metodologi ilmiah dijelaskan jelas dan dapat direplikasi?  | 0 / 1 / 2  |
| QA4 | Dataset & Variabel    | Apakah dataset, variabel, dan sumber data disajikan dengan jelas? | 0 / 1 / 2  |
| QA5 | Algoritma & Parameter | Apakah penggunaan RF/LR dijelaskan secara teknis dan benar?       | 0 / 1 / 2  |
| QA6 | Evaluasi Model        | Apakah metrik (accuracy, precision, recall dsb.) dijelaskan?      | 0 / 1 / 2  |
| QA7 | Kesesuaian konteks    | Apakah terkait pendidikan vokasi/readiness/ sertifikasi?          | 0 / 1 / 2  |
| QA8 | Kontribusi & novelty  | Apakah ada kontribusi ilmiah yang jelas?                          | 0 / 1 / 2  |

Proses ekstraksi data tidak hanya mengumpulkan informasi pokok dari masing-masing artikel, tetapi juga dilengkapi dengan proses penilaian kualitas (*Quality Assessment/QA*) untuk memastikan bahwa artikel yang dianalisis memiliki kontribusi ilmiah yang layak. Delapan indikator QA (QA1–QA8) digunakan untuk menilai kesesuaian tujuan penelitian, kejelasan metodologi, kelengkapan dataset dan variabel, ketepatan penggunaan algoritma *Random Forest* maupun *Logistic Regression*, kecukupan pelaporan metrik evaluasi, kesesuaian konteks pendidikan vokasi, serta tingkat novelty penelitian. Skor QA kemudian digunakan sebagai dasar untuk menentukan apakah sebuah artikel dimasukkan ke tahap sintesis akhir, sehingga hasil analisis tidak hanya didasarkan pada relevansi tema, tetapi juga pada kualitas akademik dan kredibilitas penelitian. Dengan demikian, proses sintesis yang dilakukan benar-benar merepresentasikan literatur bermutu pada bidang prediksi kesiapan atau performa siswa menggunakan *machine learning*.

**Tabel 6** *Quality Decision Rule (Accepted / Rejected)*

| Total Skor | Kategori  | Keputusan SLR          | Keterangan                            |
|------------|-----------|------------------------|---------------------------------------|
| 13-16      | Excellent | √ Accepted (utama)     | Sangat relevan & berkualitas tinggi   |
| 10-12      | Good      | √ Accepted (pendukung) | Relevan namun perlu dikaji kritis     |
| 7-9        | Moderate  | △ Conditional          | Perlu alasan mengapa masih disertakan |
| <7         | Poor      | X Rejected             | Tidak layak dipertimbangkan           |

Untuk memastikan proses peninjauan literatur dilakukan secara sistematis, transparan, dan dapat ditelusuri, penelitian ini mengikuti tahapan *Systematic Literature Review* (SLR) berdasarkan pedoman Kitchenham & Charters yang meliputi penetapan tujuan tinjauan, perumusan pertanyaan penelitian, pengembangan strategi penelusuran, penerapan kriteria seleksi, serta proses ekstraksi dan sintesis data. Selain itu, sebagai upaya meningkatkan akuntabilitas dan meminimalkan potensi bias dalam penyaringan studi, penelitian ini juga menyajikan PRISMA Flowchart sebagai bentuk pelaporan visual terhadap jumlah studi yang teridentifikasi, terseleksi, dan terinklusi pada tahap analisis akhir. Integrasi metode SLR Kitchenham & Charters dengan pelaporan berbasis PRISMA ini memungkinkan proses seleksi literatur tervalidasi dengan baik, terstruktur, serta memenuhi standar transparansi dan replikasi penelitian ilmiah.



**Gambar 1** PRISMA Flowchart

## Hasil dan Pembahasan

Bagian ini menyajikan hasil utama dari proses *Systematic Literature Review* (SLR) yang telah dilakukan berdasarkan tahapan metodologis sebelumnya. Analisis ini mencakup rangkaian proses identifikasi, seleksi, penilaian kualitas, serta ekstraksi dan sintesis data dari seluruh studi yang memenuhi kriteria inklusi. Hasil penelitian dipaparkan secara sistematis untuk mengungkap pola temuan, tren penelitian, serta jawaban terhadap pertanyaan penelitian yang telah ditetapkan.

### 1. Hasil Identifikasi dan Seleksi Studi

Penelusuran literatur pada berbagai basis data menghasilkan 98 artikel yang teridentifikasi pada tahap awal. Setelah eliminasi 8 duplikasi, dilakukan proses *title and abstract screening* untuk memastikan kesesuaian awal terhadap ruang lingkup penelitian sehingga 20 artikel dikeluarkan. Sebanyak 70 artikel kemudian dianalisis pada tahap *full-text eligibility review*, di mana 34 artikel tereksklusi karena tidak memenuhi kriteria, yaitu: (1) tidak menerapkan algoritma *Random Forest* atau *Logistic Regression* ( $n = 15$ ), dan (2) tidak relevan dengan konteks prediksi kesiapan siswa dalam sertifikasi kompetensi pada pendidikan vokasi, khususnya LSP-P1 di SMK ( $n = 19$ ). Dengan demikian, 36 artikel memenuhi seluruh kriteria serta digunakan untuk analisis dan sintesis akhir pada penelitian ini.

### 2. Hasil Ekstraksi dan Relevansi

Ekstraksi dilakukan terhadap 36 artikel yang terinklusi berdasarkan unsur berikut: tahun publikasi, algoritma utama, Domain, Relevansi, dan alasan. Ringkasan data penelitian disajikan pada tabel berikut:

**Tabel 7 Relevansi**

| No | Tahun | Algoritma Utama       | Domain                   | Relevansi | Alasan                                                         |
|----|-------|-----------------------|--------------------------|-----------|----------------------------------------------------------------|
| 1  | 2024  | Neural Network, C4.5  | Prediksi kinerja         | R2        | Algoritma bukan RF/LR namun domain pendidikan relevan          |
| 2  | 2023  | C4.5                  | Prediksi kelulusan SMK   | R2        | Domain sangat relevan SMK, algoritma bukan RF/LR               |
| 3  | 2019  | N/A                   | Non-ML – hukum           | R3        | Tidak relevan topik ML & pendidikan                            |
| 4  | 2024  | ML (unspecified)      | Prediksi mahasiswa       | R2        | Algoritma tidak jelas, domain pendidikan berbeda               |
| 5  | 2024  | Data mining (general) | Prediksi kinerja         | R2        | Domain relevan, algoritma tidak spesifik RF/LR                 |
| 6  | 2024  | Random Forest         | Prediksi kelulusan SMK   | R1        | Algoritma cocok + domain SMK                                   |
| 7  | 2023  | ML (unspecified)      | Prediksi nilai mahasiswa | R2        | Domain tidak SMK & algoritma non-spesifik                      |
| 8  | 2025  | EDM (comparative)     | Prediksi kinerja         | R2        | Domain relevan, algoritma tidak spesifik                       |
| 9  | 2023  | Review ML             | Tinjauan umum            | R2        | Review relevan ML namun tanpa RF/LR eksperimen                 |
| 10 | 2024  | Review ML/aplikatif   | Prediksi akademik        | R2        | Relevan teori namun tidak spesifik RF/LR                       |
| 11 | 2021  | Supervised ML         | Prediksi Kinerja         | R2        | ML relevan tetapi algoritma spesifik                           |
| 12 | 2023  | ML (unspecified)      | Dropout                  | R2        | Prediksi pendidikan relevan, algoritma tidak jelas             |
| 13 | 2021  | ML                    | Multikelas grade         | R2        | Domain relevan, algoritma tidak spesifik                       |
| 14 | 2023  | ML + Data Balancing   | Dropout                  | R2        | Relevan metode, bukan fokus RF/LR                              |
| 15 | 2023  | ML                    | E-learning               | R2        | Prediksi kinerja relevan, bukan RF/LR                          |
| 16 | 2023  | ML                    | Penilaian pengetahuan    | R2        | Domain relevan pendidikan, algoritma not specific              |
| 17 | 2024  | ML (comparative)      | LMS online               | R2        | Domain relevan pendidikan jarak jauh, algoritma tidak spesifik |
| 18 | 2024  | Hybrid ML             | Prediksi kinerja         | R2        | Domain relevan, algoritma bukan RF/LR                          |
| 19 | 2023  | ML                    | Prediksi kedokteran      | R2        | Domain kesehatan, bukan SMK                                    |
| 20 | 2025  | Survey study          | Survei prediksi akademik | R2        | Wawasan teori relevan, bukan eksperimen RF/LR                  |
| 21 | 2024  | ML                    | Prediksi kinerja siswa   | R2        | Domain relevan, algoritma tidak jelas                          |
| 22 | 2024  | EDM                   | Analisis                 | R2        | Analisis pendidikan relevan,                                   |




| No | Tahun | Algoritma Utama      | Domain                           | Relevansi | Alasan                                                                                   |
|----|-------|----------------------|----------------------------------|-----------|------------------------------------------------------------------------------------------|
| 23 | 2024  | LR, NB, RF           | kinerja<br>Prediksi argumen      | R1        | bukan prediksi RF/LR<br>Melibatkan RF/LR, meski domain topik argumen bukan akademik umum |
| 24 | 2024  | Analitik EEG/ET      | Neuro-cognitive                  | R3        | Tidak relevan dengan ML pendidikan tradisional                                           |
| 25 | 2022  | ML                   | Prediksi kinerja                 | R2        | Domain relevan, algoritma tidak spesifik                                                 |
| 26 | 2025  | ML + class imbalance | Prediksi kinerja                 | R2        | Fokus metode balancing, bukan fokus RF/LR                                                |
| 27 | 2023  | LR & RF              | Prediksi kualifikasi siswa       | R1        | Algoritma relevan & konteks prediksi siswa                                               |
| 28 | 2025  | ML                   | E-Learning                       | R2        | Domain relevan, algoritma tidak spesifik                                                 |
| 29 | 2024  | ML                   | Optimalisasi perjalanan akademik | R2        | Domain pendidikan, bukan prediksi kinerja/kelulusan                                      |
| 30 | 2024  | ML klasifikasi       | Prediksi hasil ujian             | R2        | Domain relevan, bukan RF/LR                                                              |
| 31 | 2025  | ML                   | E-Learning                       | R2        | Domain relevan, algoritma tidak spesifik                                                 |
| 32 | 2022  | Review digital logs  | Learning analytics               | R2        | Review pendukung teori                                                                   |
| 33 | 2024  | ML + Simulation      | Big data prediksi kinerja        | R2        | Domain relevan, algoritma tidak spesifik                                                 |
| 34 | 2023  | RF Regression        | Prediksi nilai numerik           | R1        | Menggunakan RF meskipun tipe regresi                                                     |
| 35 | 2022  | RF + balancing       | Prediksi kinerja VLE             | R1        | RF digunakan meski konteks e- learning                                                   |
| 36 | 2024  | ML Comparative       | Dropout & success                | R2        | Domain relevan, namun tanpa algoritma spesifik RF/LR                                     |

#### a. Ringkasan Relevansi


Dari 98 artikel yang diidentifikasi, hanya 6 artikel yang tergolong sangat relevan (R1) karena langsung membahas penggunaan Random Forest atau Logistic Regression dalam prediksi performa siswa. Sebanyak 27 artikel masuk kategori relevan parsial (R2), dan 3 artikel dinilai tidak relevan (R3). Hasil ini menunjukkan bahwa penelitian yang benar-benar sejalan dengan fokus kajian masih terbatas, sehingga menguatkan adanya kesenjangan riset pada topik prediksi kesiapan siswa untuk sertifikasi kompetensi.

**Tabel 8** Ringkasan Relevansi

| Relevansi               | Jumlah   | Catatan                                             |
|-------------------------|----------|-----------------------------------------------------|
| R1 (Highly Relevant)    | 6 studi  | Dasar utama pembahasan & kesimpulan                 |
| R2 (Partially Relevant) | 27 studi | Dapat digunakan sebagai pendukung teori, tren & gap |
| R3 (Not Relevant)       | 3 studi  | Layak dikeluarkan dari pembahasan akhir             |



**Gambar 2** Distribusi Tingkat Relevansi



**Gambar 3** Jumlah Tingkat Relevansi

**b. Matrix Komparatif Khusus Algoritma RF dan LR**

Berikut tabel fokus inti penelitian berdasarkan 6 artikel R1:

**Tabel 9** Ringkasan Relevansi

| No | Penulis/Tahun              | Algoritma                    | Domain            | Metrik Utama                    | Temuan Utama                                          |
|----|----------------------------|------------------------------|-------------------|---------------------------------|-------------------------------------------------------|
| 6  | Fatunnisa & Marcos (2024)  | RF                           | Kelulusan SMK TKJ | Accuracy, Precision, Recall, F1 | RF menunjukkan performa baik prediksi kelulusan siswa |
| 23 | Wahyuningsih et al. (2024) | LR, NB, RF                   | Argumen akademik  | Accuracy, Precision, Recall     | RF paling efektif dibanding LR & NB                   |
| 27 | Nugroho et al. (2023)      | LR & RF                      | Kualifikasi siswa | Accuracy, Precision, Recall     | RF unggul, LR stabil dan interpretable                |
| 34 | Doz et al. (2023)          | RF Regression                | Prediksi nilai    | RMSE, MAE, R <sup>2</sup>       | RF efektif dalam regresi nilai fuzzy                  |
| 35 | Jawad et al. (2022)        | RF & Data Balancing          | Kinerja VLE       | AUC, Accuracy                   | Balancing + RF tingkatkan prediksi kinerja            |
| 36 | Villar & de Andrade (2024) | ML Comparative (included RF) | Dropout & Success | Accuracy, Precision, Recall     | RF kompetitif dalam prediksi dropout                  |

Kesimpulan awal dari analisis komparatif menunjukkan bahwa algoritma *Random Forest* memiliki keunggulan dalam hal akurasi dan ketahanannya terhadap kompleksitas data serta variasi fitur, sehingga lebih stabil digunakan pada skenario dengan struktur data yang beragam. Sebaliknya, *Logistic Regression* menonjol dalam aspek interpretabilitas dan efisiensi model, menjadikannya pilihan yang lebih sesuai apabila transparansi hasil dan kemudahan implementasi menjadi prioritas. Selain itu, temuan ini juga mengindikasikan bahwa penerapan kedua algoritma tersebut dalam konteks pendidikan vokasi, khususnya terkait prediksi kesiapan siswa menghadapi sertifikasi kompetensi, masih sangat terbatas dan membutuhkan eksplorasi lebih lanjut.

c. Temuan Utama Berdasarkan Research Questions

**Tabel 10** Temuan Utama *Research Questions*

| Research Question | Temuan Utama                                                                                                                        |
|-------------------|-------------------------------------------------------------------------------------------------------------------------------------|
| RQ1               | Algoritma yang paling banyak digunakan adalah Random Forest, diikuti Logistic Regression, Decision Tree, SVM, dan Naïve Bayes.      |
| RQ2               | RF terbukti unggul dalam akurasi prediktif pada dataset kompleks; LR unggul dalam interpretasi model dan efisiensi komputasi.       |
| RQ3               | Variabel yang paling berpengaruh: nilai akademik, kehadiran, hasil prakerin, nilai simulasi sertifikasi, dan data perilaku belajar. |
| RQ4               | RF: akurasi tinggi, tetapi interpretasi rendah — LR: interpretatif, komputasi ringan namun akurasi terpengaruh kompleksitas data.   |
| RQ5               | Belum ditemukan penelitian yang secara eksplisit menerapkan prediksi kesiapan sertifikasi LSP-P1 di SMK Indonesia.                  |

## Pembahasan

Hasil telaah sistematis terhadap 36 artikel yang memenuhi inklusi menunjukkan bahwa penggunaan model *machine learning* dalam memprediksi kinerja dan kesiapan peserta didik telah mengalami perkembangan signifikan dalam berbagai domain pendidikan. Namun, distribusi relevansi menunjukkan bahwa hanya enam artikel (16.7%) yang secara langsung menggunakan atau membandingkan algoritma *Random Forest* maupun *Logistic Regression*, serta memiliki kedekatan konteks prediksi kesiapan atau performa siswa. Hal ini mengindikasikan bahwa penggunaan kedua algoritma tersebut masih terbatas pada penelitian yang bersifat umum, seperti prediksi kelulusan, nilai akademik, atau keberhasilan pembelajaran daring, bukan pada ranah kesiapan sertifikasi vokasi berbasis kompetensi seperti LSP-P1 di SMK.

Secara performa, *Random Forest* (RF) ditemukan lebih unggul pada sebagian besar studi yang masuk kategori R1. Model ini menunjukkan akurasi yang lebih tinggi, kemampuan generalisasi yang lebih baik, serta ketahanan terhadap *noise* dan *multidimensional features*. Hal tersebut selaras dengan karakteristik RF sebagai model *ensemble learning* yang mampu menangani *non-linear interaction*, *feature interaction*, serta ketidakseimbangan data. Sementara itu, *Logistic Regression* (LR) tetap menunjukkan performa yang kompetitif pada beberapa studi, meskipun akurasinya cenderung lebih rendah dibanding RF. Kelebihan LR terletak pada interpretabilitas model, kemudahan implementasi, efisiensi perhitungan, serta kemampuannya dalam menjelaskan kontribusi variabel prediktor terhadap keputusan model, yang sangat relevan dalam konteks pendidikan yang menuntut transparansi kebijakan. Meskipun dominasi RF dalam performa prediksi ditemukan pada sebagian besar studi, konteks penelitian menunjukkan bahwa RF lebih cocok untuk situasi dengan kompleksitas variabel tinggi, data multikategori, dan kebutuhan akurasi prediktif maksimal, sedangkan LR lebih direkomendasikan untuk penelitian berbasis keputusan normatif atau kebijakan akademik, di mana transparansi dan kemudahan interpretasi lebih diutamakan. Dengan demikian, pemilihan algoritma semestinya tidak hanya berorientasi pada akurasi, tetapi juga mempertimbangkan kebutuhan praktis sekolah, kesiapan pengelolaan data, tujuan analisis, serta implementasi kebijakan pendidikan yang berbasis risiko (*risk-*

*based educational intervention*).

Selain itu, hasil SLR ini menunjukkan adanya *research gap* yang cukup jelas: sebagian besar studi masih berfokus pada prediksi akademik, bukan kesiapan sertifikasi kompetensi vokasi yang menuntut pengukuran berbasis *skill performance indicators*, seperti kesiapan praktik, pemahaman standar kompetensi industri, *job-ready mindset*, dan *professional behaviour*. Dengan demikian, penelitian selanjutnya direkomendasikan untuk menggunakan kombinasi variabel akademik, non-akademik, serta indikator kompetensi vokasional sesuai Standar Kompetensi Kerja Nasional Indonesia (SKKNI) dan *scheme booklet* LSP-P1.

## Kesimpulan

Penelitian ini melakukan *Systematic Literature Review* (SLR) untuk mengidentifikasi dan menganalisis penggunaan algoritma Random Forest dan Logistic Regression dalam prediksi performa dan kesiapan siswa, dengan fokus relevansi terhadap sertifikasi kompetensi LSP-P1 di SMK. Dari 98 artikel awal yang diidentifikasi, hanya 36 yang memenuhi kriteria inklusi, dan enam di antaranya secara langsung relevan dengan kedua algoritma tersebut. Temuan ini menunjukkan bahwa riset terkait prediksi kesiapan siswa SMK menuju sertifikasi berbasis kompetensi masih sangat terbatas, terutama dibandingkan studi yang berfokus pada prediksi nilai akademik, kelulusan, atau keterlibatan dalam pembelajaran.

Hasil analisis komparatif menunjukkan bahwa *Random Forest* memiliki keunggulan dalam akurasi, kemampuan menangani variabel yang beragam, serta ketahanan terhadap *noise*. Sementara itu, *Logistic Regression* menawarkan interpretabilitas yang tinggi dan kemudahan implementasi, sehingga tetap relevan untuk konteks pendidikan yang membutuhkan transparansi dalam pengambilan keputusan. Dengan demikian, kedua algoritma tersebut memiliki potensi signifikan untuk mendukung proses asesmen kesiapan siswa, tetapi memerlukan penyesuaian lebih lanjut agar sesuai dengan karakteristik data vokasional dan standar kompetensi industri.

Secara keseluruhan, penelitian ini menegaskan adanya kebutuhan untuk memperluas penelitian prediktif dalam konteks pendidikan vokasi, khususnya terkait kesiapan siswa mengikuti uji sertifikasi LSP-P1. Temuan ini memberikan dasar teoretis dan praktis bagi peneliti serta lembaga pendidikan untuk mengembangkan model prediksi yang lebih komprehensif dan aplikatif.

## Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Universitas MDP atas dukungan yang diberikan selama proses penyelesaian penelitian ini. Penulis juga menyampaikan apresiasi kepada Bapak Antonius Wahyu Sudrajat dan Bapak Johannes Petrus selaku pembimbing yang telah memberikan arahan dan masukan yang sangat berarti. Selain itu, penulis berterima kasih kepada SMK Negeri 8 Palembang atas dukungan dan fasilitas yang diberikan selama penelitian berlangsung, serta kepada Sherly Devyanes atas bantuan teknis yang telah diberikan.

## Daftar Pustaka

- [1] S. Sulika, R. Kusumawati, and Y. M. Arif, "Classification of Students' Academic Performance Using Neural Network and C4.5 Model," *Int. J. Adv. Data Inf. Syst.*, vol. 5, no. 1, pp. 29–38, Mar. 2024, doi: 10.59395/ijadis.v5i1.1311.
- [2] S. Lestari and B. Dina, "KLASIFIKASI KETEPATAN KELULUSAN SISWA PADA SMK YADIKA 9 BINTARA JAYA KOTA BEKASI MENGGUNAKAN ALGORITMA C4.5," *J. Indones. Manaj. Inform. dan Komun.*, vol. 4, no. 3, pp. 1618–1632, Sep. 2023, doi: 10.35870/jimik.v4i3.389.
- [3] A. Fatunnisa and H. Marcos, "Prediksi Kelulusan Tepat Waktu Siswa SMK Teknik Komputer Menggunakan Algoritma Random Forest," *J. Manaj. Inform.*, vol. 14, no. 1, pp. 101–111, Apr.

- 2024, doi: 10.34010/jamika.v14i1.12114.
- [4] M. K. Nguyen, V. T. Huynh, and H. D. Nguyen, "Predicting graduation grades using Machine Learning: A case study of Can Tho University students," *CTU J. Innov. Sustain. Dev.*, vol. 15, no. ISDS, pp. 83–92, Oct. 2023, doi: 10.22144/ctujoisd.2023.038.
- [5] N. R. Yadav and S. S. Deshmukh, "Prediction of Student Performance Using Machine Learning Techniques: A Review," 2023, pp. 735–741. doi: 10.2991/978-94-6463-136-4\_63.
- [6] B. Kitchenham and S. Charters, Guidelines for performing Systematic Literature Reviews in Software Engineering, EBSE Technical Report, Keele University and Durham University, 2007.
- [7] M. J. Page et al., "PRISMA 2020 statement: An updated guideline for reporting systematic reviews," *BMJ*, vol. 372, p. n71, 2021, doi: 10.1136/bmj.n71.
- [8] E. Fadhilah and Yusdani, "Fikih Perempuan Progresif," *At-Thullab J. Mhs. Stud. Islam*, vol. 1, no. 1, pp. 1–24, Dec. 2019, doi: 10.20885/tullab.vol1.iss1.art1.
- [9] "Prediksi Kinerja Calon Mahasiswa Berdasarkan Nilai Seleksi Masuk Menggunakan Pendekatan Machine Learning," *J. Ilm. Komputasi*, vol. 23, no. 2, Jun. 2024, doi: 10.32409/jikstik.23.2.3589.
- [10] "Predicting Students' Academic Performance Via Machine Learning Algorithms: An Empirical Review and Practical Application," *Comput. Eng. Intell. Syst.*, Sep. 2024, doi: 10.7176/CEIS/15-1-09.
- [11] M. M. Hussain, S. Akbar, S. A. Hassan, M. W. Aziz, and F. Urooj, "Prediction of Student's Academic Performance through Data Mining Approach," *J. Informatics Web Eng.*, vol. 3, no. 1, pp. 241–251, Feb. 2024, doi: 10.33093/jiwe.2024.3.1.16.
- [12] Y. Lou and K. F. Colvin, "Performance prediction using educational data mining techniques: a comparative study," *Discov. Educ.*, vol. 4, no. 1, p. 112, May 2025, doi: 10.1007/s44217-025-00502-w.
- [13] I. El Guabassi, Z. Bousalem, R. Marah, and A. Qazdar, "Comparative Analysis of Supervised Machine Learning Algorithms to Build a Predictive Model for Evaluating Students' Performance," *Int. J. Online Biomed. Eng.*, vol. 17, no. 02, pp. 90–105, Feb. 2021, doi: 10.3991/ijoe.v17i02.20025.
- [14] C. H. Cho, Y. W. Yu, and H. G. Kim, "A Study on Dropout Prediction for University Students Using Machine Learning," *Appl. Sci.*, vol. 13, no. 21, p. 12004, Nov. 2023, doi: 10.3390/app132112004.
- [15] S. D. A. Bujang et al., "Multiclass Prediction Model for Student Grade Prediction Using Machine Learning," *IEEE Access*, vol. 9, pp. 95608–95621, 2021, doi: 10.1109/ACCESS.2021.3093563.
- [16] N. Mduma, "Data Balancing Techniques for Predicting Student Dropout Using Machine Learning," *Data*, vol. 8, no. 3, p. 49, Feb. 2023, doi: 10.3390/data8030049.
- [17] 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, no. 10, pp. 184–203, May 2023, doi: 10.3991/ijet.v18i10.35841.
- [18] N. Alruwais and M. Zakariah, "Evaluating Student Knowledge Assessment Using Machine Learning Techniques," *Sustainability*, vol. 15, no. 7, p. 6229, Apr. 2023, doi: 10.3390/su15076229.
- [19] F. E. Arévalo-Cordovilla and M. Peña, "Comparative Analysis of Machine Learning Models for Predicting Student Success in Online Programming Courses: A Study Based on LMS Data and External Factors," *Mathematics*, vol. 12, no. 20, p. 3272, Oct. 2024, doi: 10.3390/math12203272.
- [20] V. K. S. P. S. Prakash, K. Krinkin, and Y. A. Shichkina, "Student Performance Prediction: A Co-Evolutionary Hybrid Intelligence model," *Procedia Comput. Sci.*, vol. 235, pp. 436–446, 2024, doi: 10.1016/j.procs.2024.04.043.
- [21] H. Mastour, T. Dehghani, E. Moradi, and S. Eslami, "Early prediction of medical students' performance in high-stakes examinations using machine learning approaches," *Heliyon*, vol. 9, no. 7, p. e18248, Jul. 2023, doi: 10.1016/j.heliyon.2023.e18248.



- [22] J. Pan, Z. Zhao, and D. Han, "Academic Performance Prediction Using Machine Learning Approaches: A Survey," *IEEE Trans. Learn. Technol.*, vol. 18, pp. 351–368, 2025, doi: 10.1109/TLT.2025.3554174.
- [23] E. Ahmed, "Student Performance Prediction Using Machine Learning Algorithms," *Appl. Comput. Intell. Soft Comput.*, vol. 2024, no. 1, Jan. 2024, doi: 10.1155/2024/4067721.
- [24] S. Sarker, M. K. Paul, S. T. H. Thasin, and M. A. M. Hasan, "Analyzing students' academic performance using educational data mining," *Comput. Educ. Artif. Intell.*, vol. 7, p. 100263, Dec. 2024, doi: 10.1016/j.caeai.2024.100263.
- [25] T. Wahyuningsih, D. Manongga, I. Sembiring, and S. Wijono, "Comparison of Effectiveness of Logistic Regression, Naive Bayes, and Random Forest Algorithms in Predicting Student Arguments," *Procedia Comput. Sci.*, vol. 234, pp. 349–356, 2024, doi: 10.1016/j.procs.2024.03.014.
- [26] N. Jamil and A. N. Belkacem, "Advancing Real-Time Remote Learning: A Novel Paradigm for Cognitive Enhancement Using EEG and Eye-Tracking Analytics," *IEEE Access*, vol. 12, pp. 93116–93132, 2024, doi: 10.1109/ACCESS.2024.3422926.
- [27] M. Yağcı, "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.
- [28] T. Althaqafi, F. Saleem, and A. A.-M. AL-Ghamdi, "Enhancing student performance prediction: the role of class imbalance handling in machine learning models," *Discov. Comput.*, vol. 28, no. 1, p. 79, May 2025, doi: 10.1007/s10791-025-09576-4.
- [29] D. R. Nugroho, N. Idris, K. Kurniawan, D. Fitriana, E. Irwansyah, and G. P. Kusuma, "Logistic Regression and Random Forest Comparison in Predicting Students' Qualification Based on Students' Half-Semester Performance," in *2023 11th International Conference on Information and Communication Technology (ICoICT)*, IEEE, Aug. 2023, pp. 214–219. doi: 10.1109/ICoICT58202.2023.10262783.
- [30] J. Wang and Y. Yu, "Machine learning approach to student performance prediction of online learning," *PLoS One*, vol. 20, no. 1, p. e0299018, Jan. 2025, doi: 10.1371/journal.pone.0299018.
- [31] S. M. K, A.-B. A.S., N. A.A., B. G, and A. A.A., "Optimizing Academic Journey for High Schoolers in Oman: A Machine Learning-Enabled AI Model," *Procedia Comput. Sci.*, vol. 235, pp. 2716–2729, 2024, doi: 10.1016/j.procs.2024.04.256.
- [32] 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.
- [33] S. N. Thakur and B. Rawat, "Prediction of Student Performance in E-Learning Environment using Machine Learning Techniques," *Procedia Comput. Sci.*, vol. 259, pp. 1416–1425, 2025, doi: 10.1016/j.procs.2025.04.096.
- [34] C. J. Arizmendi *et al.*, "Predicting student outcomes using digital logs of learning behaviors: Review, current standards, and suggestions for future work," *Behav. Res. Methods*, vol. 55, no. 6, pp. 3026–3054, Aug. 2022, doi: 10.3758/s13428-022-01939-9.
- [35] C. Zhang, J. Yang, M. Li, and M. Deng, "Simulation-Based Machine Learning for Predicting Academic Performance Using Big Data," *Int. J. Gaming Comput. Simulations*, vol. 16, no. 1, pp. 1–20, Jul. 2024, doi: 10.4018/IJGCMS.348052.
- [36] D. Doz, M. Cotič, and D. Felda, "Random Forest Regression in Predicting Students' Achievements and Fuzzy Grades," *Mathematics*, vol. 11, no. 19, p. 4129, Sep. 2023, doi: 10.3390/math11194129.
- [37] K. Jawad, M. A. Shah, and M. Tahir, "Students' Academic Performance and Engagement Prediction in a Virtual Learning Environment Using Random Forest with Data Balancing," *Sustainability*, vol. 14, no. 22, p. 14795, Nov. 2022, doi: 10.3390/su142214795.
- [38] A. Villar and C. R. V. de Andrade, "Supervised machine learning algorithms for predicting student dropout and academic success: a comparative study," *Discov. Artif. Intell.*, vol. 4, no. 1, p. 2, Jan. 2024, doi: 10.1007/s44163-023-00079-z.