

LITERATURE REVIEW: PENDEKATAN MACHINE LEARNING DAN DEEP LEARNING UNTUK PREDIKSI KELULUSAN MAHASISWA

Kiki Pradina^{1*}, Muhamad Amirul Haq², Ashr Hafiizh Tantri³
^{1,2,3}Informatika, Universitas Muhammadiyah Surabaya, Surabaya, Indonesia

*Penulis korespondensi: kiki.pradina2004@gmail.com

ABSTRAK

Ketidaktepatan waktu kelulusan mahasiswa masih menjadi tantangan utama di perguruan tinggi, baik di Indonesia maupun dunia. Berbagai penelitian telah mengembangkan metode *machine learning* untuk membantu proses prediksi kelulusan mahasiswa secara dini berdasarkan data akademik, demografi, dan perilaku. Evolusi algoritma *machine learning* bertujuan untuk menjawab permasalahan akurasi prediksi dari berbagai faktor yang mempengaruhi kelulusan. Prediksi kelulusan menggunakan *machine learning* menarik untuk diteliti sebagai referensi penentuan strategi intervensi yang tepat ke depannya. Penelitian ini bertujuan untuk mengelompokkan perjalanan penggunaan algoritma *machine learning* pada prediksi kelulusan mahasiswa sehingga dapat mengindikasikan algoritma terbaik untuk prediksi kelulusan mendatang. Penelitian ini menggunakan pendekatan *literature review* terhadap 30 jurnal terindeks periode 2021–2025 yang dianalisis berdasarkan algoritma, akurasi, kelebihan, kelemahan, dan konteks dataset. Secara umum, algoritma *machine learning* yang digunakan dalam prediksi kelulusan didominasi oleh *Random Forest* (RF), *Support Vector Machine* (SVM), dan *deep learning* (CNN, LSTM, Bi-LSTM, CNN-BiGRU). Penelitian ini mengungkapkan bahwa CNN-BiGRU mencapai akurasi tertinggi sebesar 97,48%, diikuti SVM setelah hyperparameter tuning sebesar 96%, serta *Random Forest* dengan SMOTE mencapai 92,59%. Penanganan ketidakseimbangan data menggunakan SMOTE terbukti menjadi faktor penting dalam meningkatkan recall kelas minoritas hingga 92,59% pada algoritma KNN. Berdasarkan hasil *literature review*, CNN-BiGRU merupakan algoritma terbaik dalam pendekatan *machine learning* untuk prediksi kelulusan mahasiswa dengan akurasi tertinggi sebesar 97,48%. Temuan ini dapat menjadi acuan bagi peneliti maupun institusi pendidikan tinggi dalam memilih pendekatan *machine learning* yang optimal untuk membangun sistem prediksi kelulusan mahasiswa yang akurat dan efektif.

Kata kunci: *deep learning*, *literature review*, *machine learning*, prediksi kelulusan

1 PENDAHULUAN

Ketidaktepatan waktu kelulusan mahasiswa masih menjadi tantangan utama di perguruan tinggi, baik di Indonesia maupun di berbagai negara lain. Permasalahan ini berdampak luas, mulai dari penurunan efisiensi pendidikan, pembengkakan biaya operasional kampus, hingga rendahnya daya saing lulusan di dunia kerja. Sebagai contoh, tingkat kelulusan tepat waktu di salah satu perguruan tinggi di Indonesia tercatat hanya sebesar 38,43% (Pawitra et al., 2024), sementara pada jenjang pascasarjana, banyak mahasiswa yang tidak menyelesaikan studi sesuai durasi yang ditetapkan akibat data akademik yang belum dimanfaatkan secara optimal untuk keperluan prediksi (Riadi et al., 2024). Kondisi ini mendorong kebutuhan akan sistem deteksi dini yang mampu mengidentifikasi mahasiswa berisiko terlambat lulus atau bahkan putus studi (dropout), sehingga intervensi akademik dapat dilakukan secara lebih tepat sasaran dan efisien.

Berbagai penelitian telah mengembangkan metode *machine learning* untuk menjawab permasalahan tersebut dengan memanfaatkan data akademik, demografi, dan perilaku mahasiswa. Algoritma klasik seperti *Random Forest* (RF) dan *Support Vector Machine* (SVM)

banyak digunakan karena kehandalannya dalam menangani data multifaktorial, misalnya pada prediksi performa siswa berbasis nilai sebelumnya, kehadiran, dan latar belakang orang tua (Wania et al., 2025; Gusnina et al., 2022). Selain itu, SVM dengan hyperparameter tuning terbukti mampu mencapai akurasi hingga 96% pada konteks prediksi performa siswa (Ahmed, 2024), sementara penerapan SVM untuk prediksi kelulusan tepat waktu mahasiswa Indonesia juga menunjukkan akurasi yang tinggi (Haryatmi & Hervianti, 2021). Di sisi lain, pendekatan *deep learning* seperti CNN, LSTM, Bi-LSTM, dan model *hybrid* CNN-BiGRU mulai banyak diteliti karena kemampuannya menangkap pola data yang lebih kompleks dan non-linear, dengan model CNN-BiGRU bahkan tercatat mencapai akurasi tertinggi sebesar 97,48% dalam mengidentifikasi mahasiswa berisiko dropout (Adefemi et al., 2025). Permasalahan ketidakseimbangan data (*class imbalance*), di mana jumlah mahasiswa yang tidak lulus tepat waktu jauh lebih sedikit dibandingkan yang lulus tepat waktu, juga menjadi tantangan tersendiri yang umumnya diatasi dengan teknik SMOTE untuk meningkatkan recall pada kelas minoritas (Putra et al., 2025).

Meskipun studi-studi tersebut menunjukkan hasil yang menjanjikan, variasi algoritma, dataset, dan metrik evaluasi yang digunakan antar penelitian menyebabkan belum adanya kesimpulan yang seragam mengenai algoritma *machine learning* mana yang paling optimal untuk prediksi kelulusan mahasiswa. Sebagian penelitian unggul pada akurasi keseluruhan namun lemah dalam menangani data tidak seimbang, sementara penelitian lain unggul dalam interpretabilitas model namun memerlukan sumber daya komputasi yang lebih besar, seperti pada pendekatan Bi-LSTM yang dipadukan dengan SHAP untuk meningkatkan transparansi prediksi (Kalita et al., 2025). Kesenjangan inilah yang mendasari perlunya kajian literatur yang sistematis untuk memetakan perkembangan algoritma *machine learning* dari waktu ke waktu, sekaligus mengidentifikasi algoritma dengan performa terbaik berdasarkan bukti empiris dari berbagai konteks penelitian yang telah dipublikasikan.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengelompokkan perjalanan penggunaan algoritma *machine learning* pada prediksi kelulusan mahasiswa melalui pendekatan *literature review* terhadap 30 jurnal terindeks periode 2021–2025, yang dianalisis berdasarkan algoritma, akurasi, kelebihan, kelemahan, dan konteks dataset, sehingga dapat mengindikasikan algoritma terbaik untuk dijadikan acuan dalam pengembangan sistem prediksi kelulusan mahasiswa di masa mendatang.

2 METODE

Penelitian ini menggunakan pendekatan studi pustaka (*literature review*) untuk mengkaji perkembangan algoritma *machine learning* dalam memprediksi kelulusan mahasiswa

2.1 Jenis Penelitian

Penelitian ini menggunakan pendekatan studi pustaka (*literature review*) yang bertujuan menganalisis dan membandingkan berbagai algoritma *machine learning* yang digunakan untuk memprediksi kelulusan mahasiswa (Pelima et al., 2024). Pendekatan ini dipilih karena mampu memetakan perkembangan metode prediksi secara menyeluruh, mengidentifikasi celah penelitian, serta merumuskan arah pengembangan di masa mendatang (Holicza & Kiss, 2023; Gaftandzhieva et al., 2022).

2.2 Sumber Data

Sumber data penelitian ini berupa artikel jurnal terindeks yang dipublikasikan pada rentang tahun 2021–2025, diakses melalui basis data ilmiah seperti *Google Scholar*, *Scopus*, *ScienceDirect*, *Springer*, MDPI, *IEEE Xplore*, serta repositori jurnal nasional terakreditasi SINTA. Pemilihan rentang lima tahun terakhir dilakukan untuk menjaga kemutakhiran (recency) referensi yang diacu, mengingat teknik *machine learning* dan *deep learning*

berkembang sangat pesat pada periode tersebut, sebagaimana tercermin dari munculnya pendekatan-pendekatan baru seperti CNN-BiGRU (Adefemi et al., 2025), Bi-LSTM berbasis SHAP (Kalita et al., 2025), serta optimasi berbasis algoritma genetika (Chen & Liu, 2024; Li, 2025).

2.3 Kriteria Seleksi Artikel

Artikel yang dipilih dibatasi pada pustaka primer berupa artikel jurnal, dengan kriteria inklusi sebagai berikut: (1) membahas penerapan algoritma *machine learning* atau *deep learning* untuk prediksi kelulusan, performa akademik, atau dropout mahasiswa (Pawitra et al., 2024; Hermanto et al., 2024; Putra et al., 2025), (2) mencantumkan metode, hasil, dan metrik evaluasi seperti akurasi, presisi, recall, F1-score, atau AUC secara eksplisit (Haryatmi & Hervianti, 2021; Riadi et al., 2024; Gusnina et al., 2022), dan (3) berasal dari jurnal terindeks bereputasi, baik internasional (Q1–Q4) maupun nasional (SINTA 1–3). Adapun kriteria eksklusi meliputi: (1) artikel berupa prosiding, buku, atau laporan teknis; (2) artikel yang tidak mencantumkan metrik evaluasi secara eksplisit; dan (3) artikel yang membahas prediksi di luar konteks pendidikan tinggi. Berdasarkan kriteria tersebut, terkumpul 30 artikel yang memenuhi syarat untuk dianalisis lebih lanjut, dengan komposisi 9 artikel Q1, 5 artikel Q2, 6 artikel Q3, 1 artikel Q4, 7 artikel SINTA 2, dan 2 artikel SINTA 3.

2.4 Teknik Analisis Data

Analisis dilakukan secara deskriptif-kualitatif dengan mengelompokkan setiap artikel berdasarkan algoritma yang digunakan, hasil akurasi yang dicapai, kelebihan dan kelemahan metode, serta konteks dataset penelitian (Pelima et al., 2024). Setiap artikel diekstraksi informasinya ke dalam tabel sintesis yang memuat judul, tahun terbit, penulis, metode, hasil penelitian, permasalahan penelitian, state of the art, dan gap penelitian. Perbandingan antar algoritma dilakukan dengan menyandingkan nilai akurasi tertinggi yang dilaporkan pada masing-masing studi, khususnya antara kelompok algoritma *machine learning* klasik seperti *Random Forest* (Wania et al., 2025; Gusnina et al., 2022), *Support Vector Machine* (Haryatmi & Hervianti, 2021; Ahmed, 2024), *K-Nearest Neighbor* dan *Naive Bayes* (Riadi et al., 2024; Hermanto et al., 2024), dengan kelompok algoritma *deep learning* seperti CNN-BiGRU (Adefemi et al., 2025), Bi-LSTM (Kalita et al., 2025), dan *Deep Neural Network* (Darenoh et al., 2024). Analisis juga mencakup identifikasi pola penanganan ketidakseimbangan data melalui teknik SMOTE (Hermanto et al., 2024; Putra et al., 2025; Adefemi et al., 2025).

3 HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil kajian terhadap 30 artikel yang telah memenuhi kriteria inklusi dan eksklusi, dipublikasikan dalam rentang tahun 2021–2025, dan berasal dari jurnal bereputasi internasional (Q1–Q4) maupun nasional (SINTA 1–3). Pembahasan mencakup distribusi algoritma yang digunakan, perbandingan akurasi antar algoritma, penanganan ketidakseimbangan data, serta tren pengembangan penelitian.

3.1 Distribusi Algoritma Yang Digunakan

Berdasarkan hasil kajian terhadap 30 artikel yang terpilih, ditemukan beragam algoritma *machine learning* yang digunakan untuk memprediksi kelulusan mahasiswa. Distribusi penggunaan algoritma tersebut disajikan pada Tabel 1.

Table 1 Distribusi Penggunaan Algoritma *Machine learning* Pada 30 Jurnal

Kategori	Algoritma	Frekuensi	Persentase	Referensi
Classical ML	SVM	6	20,0%	(Holiczka & Kiss, 2023), (Gusnina et al., 2022), (Ahmed, 2024), (Haryatmi

				& Hervianti, 2021), (Gaftandzhieva et al., 2022), (Pelima et al., 2024)
	Decision Tree	5	16,7%	(Holiczka & Kiss, 2023), (Gusnina et al., 2022), (Ahmed, 2024), (Hermanto et al., 2024), (Yuliansyah et al., 2021)
	Naive Bayes	6	20,0%	(Ahmed, 2024), (Salam & Zeniarja, 2023), (Riadi et al., 2024), (Hermanto et al., 2024), (Yuliansyah et al., 2021), (Riadi et al., 2024)
	KNN	6	20,0%	(Holiczka & Kiss, 2023), (Ahmed, 2024), (Riadi et al., 2024), (Hermanto et al., 2024), (Yuliansyah et al., 2021), (Gaftandzhieva et al., 2022)
Ensemble	<i>Random Forest</i>	13	43,3%	(Pawitra et al., 2024), (Holiczka & Kiss, 2023), (Wania et al., 2025), (Chen & Liu, 2024), (Gusnina et al., 2022), (Putra et al., 2025), (Hermanto et al., 2024), (Sejati et al., 2022), (Gaftandzhieva et al., 2022), (Alfahid, 2024), (Gunawan & Paputungan, 2025), (Pelima et al., 2024)
	XGBoost / CatBoost	5	16,7%	XGBoost: (Putra et al., 2025), (Gaftandzhieva et al., 2022), (Alfahid, 2024) CatBoost: (Marcolino et al., 2025), (Villar & de Andrade, 2024)
<i>Deep learning</i>	CNN / LSTM / BiGRU	7	23,3%	CNN: (Salam & Zeniarja, 2023), (Arya et al., 2024), (Segura et al., 2025) LSTM: (Adefemi et al., 2025), (Arya et al., 2024) BiGRU: (Adefemi et al., 2025)

Berdasarkan Tabel 1, *Random Forest* merupakan algoritma yang paling dominan digunakan dengan frekuensi 13 dari 30 artikel (43,3%), diikuti oleh SVM, Naive Bayes, dan KNN masing-masing sebanyak 6 artikel (20,0%). Tingginya penggunaan RF disebabkan oleh kemampuannya dalam menangani data multidimensi, ketahanannya terhadap overfitting, serta kemampuannya menghasilkan informasi feature importance yang berguna untuk interpretasi model (Wania et al., 2025; Gusnina et al., 2022). Algoritma *deep learning* seperti CNN, LSTM, dan BiGRU muncul pada 7 artikel (23,3%), mencerminkan tren yang semakin berkembang menuju penggunaan arsitektur yang lebih kompleks untuk meningkatkan akurasi prediksi (Adefemi et al., 2025; Kalita et al., 2025).

3.2 Perbandingan Akurasi Antar Algoritma

Dari 30 artikel yang dikaji, dipilih enam algoritma yang paling representatif untuk dibandingkan berdasarkan akurasi tertinggi yang dilaporkan, mencakup kelompok *deep learning*, *classical machine learning*, dan *ensemble*. Perbandingan tersebut disajikan pada Tabel 2.

Table 2 Perbandingan Akurasi Tertinggi Antar Algoritma

Algoritma	Dataset	Akurasi Tertinggi	Peneliti & Tahun
-----------	---------	-------------------	------------------

CNN-BiGRU	IPK, usia, kehadiran, nilai tugas, sosial ekonomi, interaksi LMS	97,48%	(Adefemi et al., 2025)
GGCNN (GA+CNN)	Demografi, nilai masa lalu, IPK, karakteristik kursus	97%	(Li, 2025)
CNN + Naive Bayes	IPK, usia, jenis kelamin, IPS per semester, jumlah SKS, jalur masuk	96,1%	(Salam & Zeniarja, 2023)
SVM (tuned)	IPK, usia, jenis kelamin, kehadiran, nilai ujian sebelumnya, sosial ekonomi	96,0%	(Ahmed, 2024)
SVM linear	Usia, jenis kelamin, IPK, IPS semester 1–4, jurusan, jumlah SKS	94,4%	(Haryatmi & Hervianti, 2021)
RF	IP semester 1–6, jumlah SKS, usia, jenis kelamin, sosial ekonomi, jalur masuk	90,88%	(Hermanto et al., 2024)

Berdasarkan Tabel 2, algoritma CNN-BiGRU menempati posisi tertinggi dengan akurasi 97,48%, mengungguli seluruh algoritma lain yang dibandingkan dalam kajian ini (Adefemi et al., 2025). Keunggulan CNN-BiGRU terletak pada kemampuannya mengekstraksi fitur spasial melalui lapisan CNN sekaligus menangkap ketergantungan temporal secara dua arah melalui BiGRU, sehingga mampu memodelkan pola kompleks dalam data akademik mahasiswa secara lebih komprehensif. Di posisi kedua, GGCNN yang mengoptimasi parameter jaringan dengan Genetic Algorithm mencapai akurasi 97% (Li, 2025), menunjukkan bahwa optimasi berbasis evolusioner mampu meningkatkan performa arsitektur *deep learning* secara signifikan. Temuan ini diperkuat oleh studi lain yang juga menerapkan pendekatan *deep learning*, seperti Bi-LSTM yang mencapai akurasi 88,23% (Kalita et al., 2025) dan DNN dengan Optuna yang mencapai 86,61% (Darenoh et al., 2024), yang secara umum mengungguli algoritma *machine learning* klasik pada dataset yang lebih kompleks. CNN yang dikombinasikan dengan Naive Bayes mencapai akurasi 96,1% (Salam & Zeniarja, 2023), membuktikan bahwa ekstraksi fitur berbasis *deep learning* dari data tabular yang dikonversi ke format image dapat meningkatkan kemampuan representasi data secara substansial. Dari kelompok *machine learning* klasik, SVM dengan hyperparameter tuning mencapai akurasi yang sangat kompetitif sebesar 96,0% (Ahmed, 2024), bahkan mendekati performa algoritma *deep learning*. RF sebagai algoritma ensemble paling populer mencapai akurasi 90,88% (Hermanto et al., 2024), menunjukkan bahwa algoritma ini tetap relevan dan kompetitif meskipun tidak selalu menjadi yang tertinggi dalam hal akurasi. Perbedaan akurasi antar algoritma juga dipengaruhi oleh jenis dan kualitas fitur yang digunakan, di mana studi yang mengintegrasikan fitur akademik, demografis, dan sosial ekonomi secara bersamaan cenderung menghasilkan akurasi yang lebih tinggi (Pawitra et al., 2024; Wania et al., 2025).

3.3 Penanganan Ketidakseimbangan Data

Ketidakseimbangan kelas (*class imbalance*) merupakan tantangan umum yang ditemukan pada dataset prediksi kelulusan mahasiswa. Hermanto et al. (2024) melaporkan bahwa tanpa penanganan ketidakseimbangan data, model RF mencapai akurasi 90,88%, namun recall kelas minoritas sangat rendah. Setelah diterapkan SMOTE, KNN mengalami peningkatan akurasi paling signifikan dari 87,72% menjadi 92,59%, sementara RF sedikit menurun menjadi 89,81%. Hal ini penting karena dalam konteks prediksi kelulusan, kesalahan dalam mengidentifikasi mahasiswa berisiko (*false negative*) memiliki konsekuensi yang jauh lebih besar dibandingkan kesalahan sebaliknya. Putra et al. (2025) mengkonfirmasi bahwa RF tetap unggul dibandingkan XGBoost meskipun keduanya menggunakan SMOTE, dengan akurasi 80,56%. Adefemi et al. (2025) menggunakan SMOTE dalam pipeline CNN-BiGRU dan

menghasilkan peningkatan performa yang signifikan secara statistik ($p < 0,05$). Selain SMOTE, Rebelo Marcolino et al. (2025) menggunakan ADASYN yang dikombinasikan dengan optimasi multi-objective NSGA-II pada CatBoost, menghasilkan F1-score 0,86 dan AUC 0,95. Temuan ini menegaskan bahwa pemilihan teknik penanganan ketidakseimbangan data harus disesuaikan dengan karakteristik dataset dan tujuan prediksi yang ingin dicapai, bukan sekadar diterapkan secara generik (Holicza & Kiss, 2023).

3.4 Tren Dan Arah Pengembangan

Analisis terhadap 30 artikel mengungkapkan tren yang jelas menuju integrasi antara akurasi tinggi dan interpretabilitas model. Pendekatan hibrida yang menggabungkan kekuatan beberapa algoritma, seperti CNN-BiGRU dan GGCNN, semakin banyak dikembangkan untuk mengatasi keterbatasan model tunggal. Di sisi lain, penggunaan teknik explainability seperti SHAP dan analisis sensitivitas mencerminkan kesadaran yang semakin tinggi akan pentingnya transparansi model dalam konteks pendidikan. Villar & de Andrade, (2024) menunjukkan bahwa LightGBM dan CatBoost dengan Optuna secara signifikan mengungguli metode ML tradisional dengan efisiensi komputasi yang lebih baik. Penelitian di bidang ini perlu lebih banyak mengeksplorasi integrasi data non-akademik seperti faktor psikologis, motivasi, dan kondisi sosial ekonomi mahasiswa, sebagaimana direkomendasikan oleh sebagian besar artikel yang dikaji (Wania et al., 2025; Gunawan & Papatungon, 2025; Pelima et al., 2024).

4 KESIMPULAN

Penelitian ini bertujuan untuk memetakan perkembangan penggunaan algoritma *machine learning* dalam prediksi kelulusan mahasiswa melalui kajian terhadap 30 artikel jurnal terindeks periode 2021–2025. Hasil kajian menunjukkan bahwa algoritma *deep learning* hibrida, khususnya CNN-BiGRU, terbukti menjadi pendekatan yang paling unggul dalam hal akurasi prediksi, sementara *Random Forest* tetap menjadi algoritma yang paling banyak digunakan karena keseimbangan optimalnya antara akurasi, interpretabilitas, dan efisiensi komputasi. Temuan ini relevan bagi institusi pendidikan tinggi yang membutuhkan sistem deteksi dini mahasiswa berisiko tidak lulus tepat waktu, karena pemilihan algoritma yang tepat dapat menentukan efektivitas intervensi akademik yang diberikan. Penanganan ketidakseimbangan data menggunakan SMOTE terbukti menjadi faktor penting dalam meningkatkan kemampuan model mendeteksi mahasiswa berisiko, dan tren penelitian terkini menunjukkan pergeseran menuju pendekatan yang tidak hanya akurat tetapi juga interpretable melalui teknik *explainability* seperti SHAP, agar sistem prediksi dapat diimplementasikan secara praktis di lingkungan akademik. Penelitian selanjutnya disarankan untuk mengeksplorasi integrasi data non-akademik seperti faktor psikologis, motivasi, dan kondisi sosial ekonomi mahasiswa, serta mengembangkan model yang mampu beradaptasi secara real-time terhadap perubahan data akademik, dan menguji model pada dataset lintas institusi untuk meningkatkan generalisasi hasil prediksi.

DAFTAR PUSTAKA

- Adefemi, K. O., Mutanga, M. B., & Jugoo, V. (2025). *Hybrid Deep learning Models for Predicting Student Academic Performance. Mathematical and Computational Applications*, 30(3), 59. <https://doi.org/10.3390/mca30030059>
- Ahmed, E. (2024). Student Performance Prediction Using *Machine learning Algorithms. Applied Computational Intelligence and Soft Computing*, 2024. <https://doi.org/10.1155/2024/4067721>
- Chen, M., & Liu, Z. (2024). Predicting performance of students by optimizing tree components of *Random Forest* using genetic algorithm. *Heliyon*, 10(12). <https://doi.org/10.1016/j.heliyon.2024.e32570>

- Darenoh, N. V., Bachtiar, F. A., & Perdana, R. S. (2024). Prediction of On-time Student Graduation with *Deep learning* Method. *Journal of ICT Research and Applications*, 18(1), 1–20. <https://doi.org/10.5614/itbj.ict.res.appl.2023.18.1.1>
- Gaftandzhieva, S., Talukder, A., Gohain, N., Hussain, S., Theodorou, P., Salal, Y. K., & Doneva, R. (2022). Exploring Online Activities to Predict the Final Grade of Student. *Mathematics*, 10(20), 1–20. <https://doi.org/10.3390/math10203758>
- Gunawan, P. H., & Paputungan, I. V. (2025). Deteksi Tingkat Potensi Kelulusan Calon Mahasiswa menggunakan Algoritma *Random Forest*. *Sistemasi: Jurnal Sistem Informasi*, 14(5), 2555–2065. <http://sistemasi.ftik.unisi.ac.id>
- Gusnina, M., Wiharto, & Salamah, U. (2022). Student Performance Prediction in Sebelas Maret University Based on the *Random Forest* Algorithm. *Ingenierie Des Systemes d'Information*, 27(3), 495–501. <https://doi.org/10.18280/isi.270317>
- Haryatmi & Hervianti. (2021). Jurnal Resti. *Resti*, 1(10), 19–25.
- Hermanto, D., Desy Iba Ricoida, Desi Pibriana, Rusbandi, & Muhammad Rizky Pribadi. (2024). Analysis of Student Graduation Prediction Using *Machine learning* Techniques on an Imbalanced Dataset: An Approach to Address *Class imbalance*. *Scientific Journal of Informatics*, 11(3), 559–568. <https://doi.org/10.15294/sji.v11i3.5528>
- Holicza, B., & Kiss, A. (2023). Predicting and Comparing Students' Online and Offline Academic Performance Using *Machine learning* Algorithms. *Behavioral Sciences*, 13(4). <https://doi.org/10.3390/bs13040289>
- Kalita, E., Alfarwan, A. M., El Aouifi, H., Kukkar, A., Hussain, S., Ali, T., & Gaftandzhieva, S. (2025). Predicting student academic performance using Bi-LSTM: a *deep learning* framework with SHAP-based interpretability and statistical validation. *Frontiers in Education*, 10(June), 1–18. <https://doi.org/10.3389/feduc.2025.1581247>
- Li, T. (2025). Prediction and Optimization of Student Grades Based on Genetic Algorithm and Graph Convolutional Neural Networks. *International Journal of Computational Intelligence Systems*, 18(1). <https://doi.org/10.1007/s44196-025-00775-x>
- Pawitra, M. A. S., Hung, H.-C., & Jati, H. (2024). A *Machine learning* Approach to Predicting On-Time Graduation in Indonesian Higher Education. *Elinvo (Electronics, Informatics, and Vocational Education)*, 9(2), 294–308. <https://doi.org/10.21831/elinvo.v9i2.77052>
- Pelima, L. R., Sukmana, Y., & Rosmansyah, Y. (2024). Predicting University Student Graduation Using Academic Performance and *Machine learning*: A Systematic Literature review. *IEEE Access*, 12(February), 23451–23465. <https://doi.org/10.1109/ACCESS.2024.3361479>
- Putra, L. G. R., Prasetya, D. D., & Mayadi, M. (2025). Student Dropout Prediction Using *Random Forest* and XGBoost Method. *INTENSIF: Jurnal Ilmiah Penelitian Dan Penerapan Teknologi Sistem Informasi*, 9(1), 147–157. <https://doi.org/10.29407/intensif.v9i1.21191>
- Rebelo Marcolino, M., Reis Porto, T., Thompsen Primo, T., Targino, R., Ramos, V., Marques Queiroga, E., Munoz, R., & Cechinel, C. (2025). Student dropout prediction through *machine learning* optimization: insights from moodle log data. *Scientific Reports*, 15(1), 1–16. <https://doi.org/10.1038/s41598-025-93918-1>
- Riadi, I., Umar, R., & Anggara, R. (2024). Comparative Analysis of Naive Bayes and K-NN Approaches to Predict Timely Graduation using Academic History. *International Journal of Computing and Digital Systems*, 16(1), 1163–1174. <https://doi.org/10.12785/ijcds/160185>
- Salam, A., & Zeniarja, J. (2023). Classification of *deep learning* convolutional neural network feature extraction for student graduation prediction. *Indonesian Journal of Electrical Engineering and Computer Science*, 32(1), 335–341. <https://doi.org/10.11591/ijeecs.v32.i1.pp335-341>

- Villar, A., & de Andrade, C. R. V. (2024). Supervised *machine learning* algorithms for predicting student dropout and academic success: a comparative study. *Discover Artificial Intelligence*, 4(1). <https://doi.org/10.1007/s44163-023-00079-z>
- Wania, R. W., Mukherjee, S., Mondal, S., Mukherjee, S., & Hazra, S. (2025). *Predicting Student Performance Using Random Forest Algorithm Literature review : - Methodology : - Model Training and Evaluation : -. 01(01)*, 1–2.