

Analisis Kinerja Logistic Regression untuk Klasifikasi Multikelas Dampak Penggunaan AI pada Mahasiswa

Performance Analysis of Logistic Regression for Multiclass Classification of the Impact of AI Use on Students

Firman Aziz¹; Irmawati^{2,*}

¹ IRMEX Digital Akademika, Makassar 90155, Indonesia

² Universitas Pancasakti, Makassar 90121, Indonesia

¹ irmawati@irmexdigikal.com; ² firman.aziz@unpacti.ac.id

* Corresponding author

Abstrak

Penelitian ini bertujuan untuk menganalisis kinerja model Logistic Regression dalam klasifikasi multikelas dampak penggunaan Artificial Intelligence (AI) pada mahasiswa. Dataset yang digunakan berasal dari platform Kaggle dan terdiri dari 1000 observasi dengan tiga kategori target: Positive, Neutral, dan Negative. Dua pendekatan Logistic Regression yang dibandingkan adalah One-vs-Rest (OvR) dan Multinomial Logistic Regression. Evaluasi dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score dengan skenario pembagian data 80:20. Hasil eksperimen menunjukkan bahwa kedua pendekatan menghasilkan performa yang identik dengan akurasi 94,43% dan rata-rata F1-score 0,92. Temuan ini menunjukkan bahwa pada dataset yang digunakan, pendekatan OvR memberikan performa yang setara dengan pendekatan multinomial. Namun demikian, penelitian ini tidak menggunakan uji signifikansi statistik maupun cross-validation, sehingga hasil bersifat evaluatif dan terbatas pada dataset yang dianalisis. Penelitian ini menekankan pentingnya pemilihan model yang sederhana dan interpretable dalam analisis data pendidikan berbasis AI.

Kata Kunci: Regresi Logistik; Klasifikasi Multikelas; Kecerdasan Buatan; Perilaku Siswa; Penambangan Data Pendidikan; Pembelajaran Mesin

Abstract

This study aims to analyze the performance of the Logistic Regression model in multiclass classification of the impact of Artificial Intelligence (AI) use on college students. The dataset used comes from the Kaggle platform and consists of 1000 observations with three target categories: Positive, Neutral, and Negative. Two Logistic Regression approaches were compared: One-vs-Rest (OvR) and Multinomial Logistic Regression. Evaluation was conducted using accuracy, precision, recall, and F1-score metrics with an 80:20 data split scenario. The experimental results showed that both approaches produced identical performance with an accuracy of 94.43% and an average F1-score of 0.92. These findings indicate that on the dataset used, the OvR approach provides equivalent performance to the multinomial approach. However, this study did not use statistical significance tests or cross-validation, so the results are evaluative and limited to the analyzed dataset. This study emphasizes the importance of selecting a simple and interpretable model in AI-based educational data analysis.

Keywords: Logistic Regression; Multiclass Classification; Artificial Intelligence; Student Behavior; Educational Data Mining; Machine Learning

Pendahuluan

Perkembangan pesat teknologi **Artificial Intelligence (AI)** telah membawa transformasi signifikan dalam berbagai sektor, termasuk pendidikan. Integrasi AI dalam lingkungan pembelajaran memungkinkan personalisasi materi, peningkatan efisiensi proses belajar, serta akses yang lebih luas terhadap sumber pengetahuan digital [1]–[3]. Pemanfaatan AI juga mendorong munculnya berbagai platform pembelajaran cerdas yang mampu menyesuaikan kebutuhan individu mahasiswa secara dinamis. Meskipun memberikan banyak manfaat, penggunaan AI yang intensif juga menimbulkan berbagai tantangan. Sejumlah penelitian menunjukkan bahwa penggunaan teknologi digital secara berlebihan dapat berdampak pada penurunan kemampuan berpikir kritis, berkurangnya interaksi sosial, serta meningkatnya risiko gangguan kesehatan mental [4]–[6]. Selain itu, penggunaan platform digital yang tidak terkontrol juga berkaitan dengan gangguan pola tidur dan penurunan performa akademik mahasiswa [7].

Dalam konteks tersebut, penting untuk memahami dampak penggunaan AI terhadap mahasiswa secara komprehensif, tidak hanya dari sisi akademik tetapi juga aspek perilaku dan psikologis. Oleh karena itu, pendekatan berbasis data menjadi sangat relevan untuk mengidentifikasi pola dan hubungan kompleks dalam perilaku mahasiswa. Teknik **machine learning** telah banyak digunakan untuk menganalisis data pendidikan dan memodelkan perilaku pengguna secara sistematis [8]–[10]. Berbagai algoritma machine learning seperti Support Vector Machine (SVM), Decision Tree, Random Forest, dan Neural Network telah широко digunakan dalam penelitian sebelumnya untuk memprediksi performa akademik dan menganalisis perilaku mahasiswa [11]–[13]. Meskipun memiliki tingkat akurasi yang tinggi, model-model tersebut umumnya memiliki kompleksitas yang tinggi sehingga sulit diinterpretasikan, yang menjadi kendala dalam penerapannya pada bidang pendidikan [14]. Sebagai alternatif, **Logistic Regression** merupakan metode klasifikasi yang banyak digunakan karena kesederhanaannya, efisiensi komputasi, serta kemampuannya dalam memberikan interpretasi yang jelas terhadap hubungan antar variabel [15]. Dalam permasalahan klasifikasi multikelas, Logistic Regression dapat diimplementasikan melalui dua pendekatan utama, yaitu **One-vs-Rest (OvR)** dan **Multinomial Logistic Regression**. Pendekatan OvR mengubah permasalahan multikelas menjadi beberapa klasifikasi biner, sedangkan pendekatan multinomial secara langsung memodelkan probabilitas setiap kelas menggunakan fungsi softmax [16], [17]. Meskipun kedua pendekatan tersebut telah banyak digunakan, masih terdapat beberapa kesenjangan dalam penelitian sebelumnya. Pertama, sebagian besar studi lebih berfokus pada model kompleks tanpa mengeksplorasi secara mendalam potensi model sederhana seperti Logistic Regression. Kedua, penelitian yang menggunakan Logistic Regression umumnya hanya menjadikannya sebagai model baseline tanpa melakukan analisis komparatif terhadap variasi pendekatan yang tersedia. Ketiga, masih terbatas penelitian yang secara khusus mengkaji perbandingan pendekatan OvR dan multinomial dalam konteks klasifikasi multikelas dampak penggunaan AI pada mahasiswa. Selain itu, belum banyak penelitian yang mengevaluasi apakah pendekatan yang lebih kompleks seperti multinomial benar-benar memberikan peningkatan performa yang signifikan dibandingkan pendekatan yang lebih sederhana seperti OvR, khususnya pada dataset dengan karakteristik yang relatif linear seperti data perilaku mahasiswa. Hal ini menunjukkan adanya kebutuhan untuk melakukan evaluasi empiris yang lebih mendalam terhadap kedua pendekatan tersebut.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menganalisis kinerja Logistic Regression dalam klasifikasi multikelas dampak penggunaan AI pada mahasiswa serta membandingkan performa antara pendekatan One-vs-Rest dan Multinomial Logistic Regression. Kontribusi utama penelitian ini meliputi: (1) analisis dampak penggunaan AI pada mahasiswa dalam tiga kategori utama (positive, neutral, negative), (2) perbandingan empiris dua pendekatan Logistic Regression dalam konteks klasifikasi multikelas, (3) temuan bahwa kedua pendekatan menghasilkan performa yang setara pada dataset yang digunakan, serta (4) penegasan bahwa model yang lebih sederhana tetap dapat memberikan kinerja optimal tanpa meningkatkan kompleksitas model.

Penelitian ini diharapkan dapat memberikan kontribusi dalam bidang **educational data mining**, khususnya dalam pemilihan model klasifikasi yang efektif, efisien, dan mudah diinterpretasikan untuk analisis data pendidikan berbasis AI.

Metode

A. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk menganalisis kinerja algoritma **Logistic Regression** dalam klasifikasi multikelas. Fokus utama penelitian adalah membandingkan dua pendekatan dalam Logistic Regression, yaitu **One-vs-Rest (OvR)** dan **Multinomial Logistic Regression**, dalam mengklasifikasikan dampak penggunaan Artificial Intelligence (AI) pada mahasiswa.

B. Dataset dan Variabel Penelitian

Dataset yang digunakan dalam penelitian ini merupakan data terstruktur yang menggambarkan perilaku penggunaan media digital berbasis AI pada mahasiswa. Dataset terdiri dari beberapa atribut yang mencerminkan aspek demografis, perilaku, dan psikologis.

Variabel Input (Fitur):

1. Age (Usia)
2. Gender (Jenis Kelamin)
3. Academic Level (Tingkat Pendidikan)
4. Country (Negara)

5. Avg_Daily_Usage_Hours (Rata-rata penggunaan harian)
6. Most_Used_Platform (Platform yang paling sering digunakan)
7. Affects_Academic_Performance (Pengaruh terhadap akademik)
8. Sleep_Hours_Per_Night (Jam tidur per malam)
9. Mental_Health_Score (Skor kesehatan mental)

Dataset penelitian terdiri dari 1000 observasi dengan tiga kelas target (Positive, Neutral, Negative).

C. *Pra-pemrosesan Data*

Tahapan pra-pemrosesan dilakukan untuk memastikan kualitas data sebelum digunakan dalam proses pelatihan model. Langkah-langkah yang dilakukan meliputi:

1. Pembersihan Data
Menghapus atau menangani data yang tidak lengkap (missing values).
2. Transformasi Data Kategorikal
Variabel kategorikal seperti *Gender*, *Academic Level*, dan *Most Used Platform* dikonversi menggunakan teknik One-Hot Encoding.
3. Normalisasi Data Numerik
Fitur numerik dinormalisasi menggunakan metode StandardScaler untuk meningkatkan stabilitas model.
4. Pembagian Data (Train-Test Split)
Dataset dibagi menjadi: 80% data latih (training set) dan 20% data uji (testing set) dengan metode *random sampling*.

D. *Pengembangan Model*

Penelitian ini menggunakan dua pendekatan Logistic Regression:

1. One-vs-Rest (OvR)
Pendekatan ini membagi permasalahan multikelas menjadi beberapa klasifikasi biner. Setiap model bertugas membedakan satu kelas terhadap kelas lainnya.
2. Multinomial Logistic Regression
Pendekatan ini menggunakan fungsi softmax untuk memodelkan probabilitas semua kelas secara simultan dalam satu model.

Kedua model dilatih menggunakan parameter:

- Solver: *lbfgs*
- Maksimum iterasi: 1000

E. *Evaluasi Model*

Kinerja model dievaluasi menggunakan beberapa metrik klasifikasi, yaitu:

1. Accuracy

$$accuracy = \frac{\sum_j T_i}{N} \quad (1)$$

Mengukur tingkat ketepatan prediksi secara keseluruhan.

2. Precision :Mengukur ketepatan prediksi pada masing-masing kelas.
3. Recall: Mengukur kemampuan model dalam mendeteksi seluruh data pada setiap kelas.
4. F1-Score: Merupakan rata-rata harmonis antara precision dan recall.

Hasil dan Diskusi

Penelitian ini bertujuan untuk menganalisis kinerja algoritma Logistic Regression dalam klasifikasi multikelas terhadap dampak penggunaan Artificial Intelligence (AI) pada mahasiswa. Berdasarkan hasil eksperimen yang telah dilakukan, diperoleh performa model yang menunjukkan hasil yang sangat baik dan konsisten.

Hasil evaluasi menunjukkan bahwa baik pendekatan One-vs-Rest (OvR) maupun Multinomial Logistic Regression menghasilkan performa yang identik. Nilai akurasi yang diperoleh sebesar 94,43%, dengan rata-rata precision sebesar 0,93, recall sebesar 0,91, dan F1-score sebesar 0,92. Hasil ini menunjukkan bahwa kedua pendekatan memiliki kemampuan yang setara dalam mengklasifikasikan data ke dalam tiga kategori utama, yaitu *Positive*, *Neutral*, dan *Negative*. Tabel 1 berikut menyajikan hasil perbandingan kinerja kedua model yang digunakan dalam penelitian ini:

Tabel 1. Perbandingan kinerja model

<i>Model</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Logistic Regression (OvR)	0.944	0.93	0.91	0.92
Multinomial Logistic Regression	0.944	0.93	0.91	0.92

Berdasarkan tabel tersebut, dapat dilihat bahwa tidak terdapat perbedaan nilai pada seluruh metrik evaluasi antara kedua model. Hal ini menunjukkan bahwa penggunaan pendekatan multinomial tidak memberikan peningkatan performa dibandingkan pendekatan OvR pada dataset yang digunakan.

Analisis lebih lanjut dilakukan untuk melihat performa model pada masing-masing kelas. Hasil evaluasi menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengklasifikasikan kelas *Negative* dan *Positive*, dengan nilai precision dan recall yang tinggi, masing-masing mencapai di atas 0,95. Sementara itu, kelas *Neutral* menunjukkan performa yang relatif lebih rendah, khususnya pada nilai recall sebesar 0,80. Perbedaan ini menunjukkan bahwa model mengalami kesulitan dalam mengidentifikasi data yang berada pada kategori *Neutral*, yang cenderung memiliki karakteristik yang berada di antara dua kelas lainnya. Hal ini menyebabkan terjadinya overlap antar kelas, sehingga meningkatkan kemungkinan kesalahan klasifikasi.

Berdasarkan hasil eksperimen yang telah dilakukan, penelitian ini menghasilkan sejumlah temuan yang memberikan kontribusi penting dalam analisis klasifikasi multikelas menggunakan Logistic Regression pada data perilaku mahasiswa. Temuan pertama menunjukkan bahwa tidak terdapat perbedaan signifikan antara pendekatan One-vs-Rest (OvR) dan Multinomial Logistic Regression, di mana kedua metode menghasilkan performa yang identik pada seluruh metrik evaluasi. Hasil ini mengindikasikan bahwa kompleksitas tambahan pada pendekatan multinomial tidak selalu berbanding lurus dengan peningkatan kinerja model. Dalam konteks dataset yang memiliki karakteristik tertentu, khususnya dengan hubungan antar variabel yang relatif sederhana, pendekatan OvR yang lebih sederhana terbukti sudah cukup optimal.

Temuan ini sejalan dengan prinsip *Occam's Razor* dalam machine learning, yang menyatakan bahwa model yang lebih sederhana sebaiknya dipilih selama mampu memberikan performa yang setara dengan model yang lebih kompleks. Dalam konteks penelitian ini, penggunaan Logistic Regression dengan pendekatan OvR menjadi pilihan yang lebih efisien karena memiliki kompleksitas komputasi yang lebih rendah serta lebih mudah diinterpretasikan, tanpa mengorbankan akurasi model. Hal ini menjadi relevan terutama dalam bidang pendidikan, di mana transparansi dan interpretabilitas model sangat dibutuhkan untuk mendukung pengambilan keputusan.

Temuan kedua berkaitan dengan tingginya performa model secara keseluruhan, yang mengindikasikan bahwa data yang digunakan memiliki pola yang cenderung linear. Logistic Regression sebagai model linear mampu menangkap hubungan antar variabel dengan baik, sehingga menghasilkan tingkat akurasi yang tinggi. Hal ini menunjukkan bahwa variabel-variabel yang digunakan dalam penelitian, seperti durasi penggunaan AI, kualitas tidur, dan skor kesehatan mental, memiliki hubungan yang cukup jelas dalam membedakan kategori dampak penggunaan AI pada mahasiswa.

Selanjutnya, hasil penelitian menunjukkan bahwa kelas *Neutral* merupakan kelas yang paling sulit diklasifikasikan. Hal ini terlihat dari nilai recall yang lebih rendah dibandingkan kelas lainnya, serta distribusi kesalahan pada confusion matrix yang didominasi oleh kesalahan prediksi pada kelas ini. Kondisi ini menunjukkan bahwa kelas *Neutral* memiliki karakteristik yang ambigu dan berada di antara dua kelas ekstrem, yaitu *Positive* dan *Negative*. Dalam konteks data perilaku manusia, fenomena ini merupakan hal yang umum terjadi, karena batas antar kategori tidak selalu bersifat tegas. Hal ini juga menunjukkan bahwa pendekatan klasifikasi berbasis label diskrit memiliki keterbatasan dalam merepresentasikan kondisi yang bersifat kontinu atau gradual.

Temuan ini membuka peluang untuk penelitian lanjutan yang dapat mempertimbangkan pendekatan lain, seperti probabilistic classification atau fuzzy classification, untuk menangani ambiguitas pada kelas *Neutral*. Selain itu, penggunaan metode berbasis *ensemble learning* atau *deep learning* juga dapat dieksplorasi untuk meningkatkan kemampuan model dalam membedakan kelas yang memiliki karakteristik tumpang tindih.

Temuan berikutnya menunjukkan bahwa variabel yang berkaitan dengan perilaku dan kondisi psikologis mahasiswa memiliki peran yang signifikan dalam proses klasifikasi. Variabel seperti durasi penggunaan harian, kualitas tidur, dan skor kesehatan mental terbukti menjadi indikator penting dalam menentukan apakah dampak penggunaan AI bersifat positif, netral, atau negatif. Hal ini menunjukkan bahwa dampak penggunaan AI tidak dapat dilihat hanya dari sisi teknologi, tetapi juga harus mempertimbangkan kondisi individu pengguna secara holistik.

Dari sudut pandang praktis, hasil ini memberikan implikasi bahwa institusi pendidikan perlu memperhatikan keseimbangan antara penggunaan teknologi dan kesehatan mental mahasiswa. Penggunaan AI yang optimal bukan hanya ditentukan oleh intensitas penggunaan, tetapi juga oleh bagaimana teknologi tersebut digunakan dalam konteks yang sehat dan terkontrol.

Secara keseluruhan, hasil penelitian ini menegaskan bahwa Logistic Regression tetap menjadi metode yang relevan dan efektif dalam analisis data pendidikan, khususnya untuk klasifikasi multikelas dengan tingkat kompleksitas data yang moderat. Temuan bahwa pendekatan sederhana dapat menghasilkan performa yang optimal juga memberikan kontribusi penting dalam pemilihan model yang efisien dan interpretable, yang menjadi kebutuhan utama dalam pengembangan sistem berbasis AI di bidang pendidikan.

Kesimpulan

Penelitian ini bertujuan untuk menganalisis kinerja algoritma Logistic Regression dalam klasifikasi multikelas terhadap dampak penggunaan Artificial Intelligence (AI) pada mahasiswa. Berdasarkan hasil eksperimen, diperoleh bahwa pendekatan One-vs-Rest (OvR) dan Multinomial Logistic Regression menghasilkan performa yang identik dengan tingkat akurasi sebesar 94,43% serta nilai rata-rata F1-score sebesar 0,92, yang menunjukkan bahwa tidak terdapat perbedaan signifikan antara kedua pendekatan dalam menangani klasifikasi multikelas pada dataset yang digunakan. Temuan ini mengindikasikan bahwa pendekatan yang lebih sederhana seperti OvR mampu memberikan performa yang setara dengan pendekatan yang lebih kompleks, sehingga lebih efisien dari sisi komputasi dan interpretabilitas. Selain itu, tingginya performa model menunjukkan bahwa data memiliki pola yang cenderung linear dan sesuai untuk dimodelkan menggunakan Logistic Regression. Penelitian ini juga menemukan bahwa kelas *Neutral* merupakan kategori yang paling sulit diklasifikasikan karena memiliki karakteristik yang ambigu dan berada di antara kelas *Positive* dan *Negative*, sehingga sering terjadi overlap dalam proses klasifikasi. Variabel yang berkaitan dengan perilaku dan kondisi psikologis, seperti durasi penggunaan harian, kualitas tidur, dan skor kesehatan mental, terbukti memiliki peran penting dalam menentukan hasil klasifikasi, yang menunjukkan bahwa dampak penggunaan AI tidak hanya dipengaruhi oleh faktor teknologi tetapi juga kondisi individu pengguna. Meskipun penelitian ini telah menghasilkan temuan yang signifikan, penelitian selanjutnya disarankan untuk mengeksplorasi algoritma yang lebih kompleks seperti Random Forest, Gradient Boosting, atau Deep Learning guna menangani pola non-linear, serta mempertimbangkan pendekatan seperti fuzzy classification, probabilistic modeling, atau ensemble learning untuk meningkatkan akurasi pada kelas yang bersifat ambigu seperti *Neutral*. Selain itu, integrasi metode Explainable Artificial Intelligence (XAI) seperti SHAP dapat digunakan untuk meningkatkan interpretabilitas model, sementara perluasan dataset dan implementasi model dalam sistem nyata berbasis AI di bidang pendidikan dapat menjadi arah pengembangan lanjutan guna meningkatkan generalisasi dan manfaat praktis dari penelitian ini.

Deklarasi Kepentingan

Penulis menyatakan bahwa tidak terdapat konflik kepentingan dalam penelitian, analisis data, maupun publikasi artikel ini.

Ucapan Terima Kasih

Penulis ingin mengucapkan terima kasih kepada tim yang telah memberikan bantuan berharga dalam penelitian ini. Penelitian ini tidak menerima pendanaan khusus dari lembaga pemerintah, organisasi komersial, maupun institusi nirlaba.

Ketersediaan Data

Dataset yang digunakan dalam penelitian ini berasal dari platform Kaggle dan digunakan untuk kepentingan penelitian akademik. Data dapat diakses kembali melalui sumber publik yang relevan atau diperoleh dari penulis korespondensi berdasarkan permintaan yang wajar.

Penggunaan Ai Dan Deklarasi Penggunaan Ai Generatif

Penulis menggunakan teknologi AI generatif untuk membantu proses penyusunan awal manuskrip, perbaikan tata bahasa, pengembangan struktur penulisan, serta asistensi dalam penyuntingan akademik. Seluruh isi, analisis, interpretasi hasil, dan kesimpulan penelitian telah ditinjau serta diverifikasi secara penuh oleh penulis dan menjadi tanggung jawab sepenuhnya penulis.

Daftar Pustaka

- [1] L. Chen, P. Chen, and Z. Lin, "Artificial Intelligence in Education: A Review," *IEEE Access*, vol. 8, pp. 75264–75278, 2020, doi: 10.1109/ACCESS.2020.2988510.
- [2] W. Holmes and I. Tuomi, "State of the art and practice in AI in education," *Eur. J. Educ.*, vol. 57, no. 4, pp. 542–570, Dec. 2022, doi:

- 10.1111/EJED.12533;JOURNAL:JOURNAL:14653435;WGROU:STRING:PUBLICATION.
- [3] F. Ouyang, L. Zheng, and P. Jiao, "Artificial intelligence in online higher education: A systematic review of empirical research from 2011 to 2020," *Educ. Inf. Technol.*, vol. 27, no. 6, pp. 7893–7925, Jul. 2022, doi: 10.1007/S10639-022-10925-9/TABLES/4.
- [4] J. M. Twenge, R. A. Sherman, and B. E. Wells, "Sexual Inactivity During Young Adulthood Is More Common Among U.S. Millennials and iGen: Age, Period, and Cohort Effects on Having No Sexual Partners After Age 18," *Arch. Sex. Behav.* 2016 462, vol. 46, no. 2, pp. 433–440, Aug. 2016, doi: 10.1007/S10508-016-0798-Z.
- [5] S. Lerchenfeldt, S. M. Attardi, R. L. Pratt, K. E. Sawarynski, and T. A. H. Taylor, "Twelve tips for interfacing with the new generation of medical students: iGen," *Med. Teach.*, vol. 43, no. 11, pp. 1249–1254, 2021, doi: 10.1080/0142159X.2020.1845305.
- [6] D. A. Parry, B. I. Davidson, C. J. R. Sewall, J. T. Fisher, H. Mieczkowski, and D. S. Quintana, "A systematic review and meta-analysis of discrepancies between logged and self-reported digital media use," *Nat. Hum. Behav.* 2021 511, vol. 5, no. 11, pp. 1535–1547, May 2021, doi: 10.1038/s41562-021-01117-5.
- [7] H. Scott, S. M. Biello, and H. C. Woods, "Social media use and adolescent sleep patterns: cross-sectional findings from the UK millennium cohort study," *BMJ Open*, vol. 9, no. 9, p. e031161, Sep. 2019, doi: 10.1136/BMJOPEN-2019-031161.
- [8] B. Albreiki, N. Zaki, and H. Alashwal, "A Systematic Literature Review of Student' Performance Prediction Using Machine Learning Techniques," *Educ. Sci. 2021, Vol. 11, Page 552*, vol. 11, no. 9, p. 552, Sep. 2021, doi: 10.3390/EDUCSCI11090552.
- [9] E. Ahmed and A. Al-Omari, "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.
- [10] A. Dutt, M. A. Ismail, and T. Herawan, "A Systematic Review on Educational Data Mining," *IEEE Access*, vol. 5, pp. 15991–16005, 2017, doi: 10.1109/ACCESS.2017.2654247.
- [11] A. A. Saa, "Educational Data Mining & Students' Performance Prediction," *IJACSA Int. J. Adv. Comput. Sci. Appl.*, vol. 7, no. 5, 2016, Accessed: Apr. 06, 2026. [Online]. Available: www.ijacsa.thesai.org.
- [12] A. Namoun and A. Alshantqi, "Predicting Student Performance Using Data Mining and Learning Analytics Techniques: A Systematic Literature Review," *Appl. Sci. 2021, Vol. 11, Page 237*, vol. 11, no. 1, p. 237, Dec. 2020, doi: 10.3390/APP11010237.
- [13] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," *Proc. ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, vol. 13-17-August-2016, pp. 785–794, Aug. 2016, doi: 10.1145/2939672.2939785;CSUBTYPE:STRING:CONFERENCE.
- [14] Z. L.- Queue and undefined 2018, "The mythos of model interpretability: In machine learning, the concept of interpretability is both important and slippery.," *dl.acm.orgZC LiptonQueue, 2018•dl.acm.org*, vol. 16, no. 3, pp. 31–57, Jun. 2018, doi: 10.1145/3236386.3241340.
- [15] D. W. . Hosmer, S. Lemeshow, and R. X. . Sturdivant, "Applied logistic regression," p. 500, 2013, Accessed: Apr. 06, 2026. [Online]. Available: https://books.google.com/books/about/Applied_Logistic_Regression.html?id=bRoxQBIZRd4C.
- [16] U. Braga-Neto, "Fundamentals of Pattern Recognition and Machine Learning," *Fundam. Pattern Recognit. Mach. Learn.*, pp. 1–400, Jan. 2024, doi: 10.1007/978-3-031-60950-3/COVER.
- [17] K. Murphy, *Probabilistic machine learning: an introduction*. 2022.