

Analisis Komparatif Algoritma Naïve Bayes dan XGBoost untuk Mengklasifikasikan Performa Akademik Mahasiswa Berdasarkan Tingkat Ketergantungan AI

Aryanti Aryanti¹, Juriawan Raja Saputra², M. Taufik Permana³,
Putri Nabila⁴, Ibnu Asrafi⁵

¹Program Studi Sarjana Terapan Teknik Telekomunikasi, Politeknik Negeri Sriwijaya, Sumatera Selatan, Indonesia

²Jurusan Teknik Mesin, Politeknik Negeri Sriwijaya Palembang, Sumatera Selatan, Indonesia

Email : aryanti@polsri.ac.id, juriawanrajasaputra@gmail.com, taufikhello26@gmail.com,

putrinabilala15@gmail.com, lbnuasrafi2015@gmail.com

Article Information

Article history

Received 29 April 2026

Revised 23 May 2026

Accepted 26 June 2026

Available 27 June 2026

Keywords

Artificial Intelligence

ChatGPT

Classification

Naïve Bayes

XGBoost

Corresponding Author:

Aryanti Aryanti,
Politeknik Negeri Sriwijaya,
Email : aryanti@polsri.ac.id

Abstract

While Artificial Intelligence (AI) integrates into higher education to streamline information retrieval, comprehension, and academic task completion, over-reliance on these tools may jeopardize student outcomes. Extant literature predominantly examines AI adoption rates, dependency levels, and user sentiments; however, comparative analyses of machine learning models for classifying academic performance relative to AI usage intensity remain scarce. To address this gap, this study evaluates and compares the efficacy of Naïve Bayes and XGBoost algorithms in predicting student performance based on their AI engagement. Utilizing the Academic Outcomes & AI Dependency Analysis Dataset—comprising 8,000 instances and 26 features—the methodology encompasses data preprocessing, normalization, partitioning, model training, and evaluation via accuracy, precision, recall, and F1-score. The empirical results demonstrate that XGBoost outperforms Naïve Bayes, achieving a superior accuracy of 84.17% compared to 79.03%. Consequently, XGBoost proves to be a more robust model for classifying academic performance driven by AI usage, offering valuable insights for the advancement of educational data analytics.

Keywords : *Artificial Intelligence, ChatGPT, Classification, Naïve Bayes, XGBoost.*

Abstrak

Artificial Intelligence (AI) telah menjadi bagian penting dalam pendidikan tinggi karena membantu mahasiswa memperoleh informasi, memahami materi, dan menyelesaikan tugas akademik secara lebih efisien. Namun, penggunaan AI yang berlebihan berpotensi memengaruhi performa akademik mahasiswa. Penelitian sebelumnya umumnya berfokus pada adopsi AI, tingkat ketergantungan, dan analisis sentimen penggunaan AI, sedangkan studi yang membandingkan algoritma machine learning untuk klasifikasi performa akademik berdasarkan tingkat penggunaan AI masih terbatas. Penelitian ini bertujuan membandingkan kinerja algoritma Naïve Bayes dan XGBoost dalam mengklasifikasikan performa akademik mahasiswa berdasarkan tingkat penggunaan *Artificial Intelligence*. Dataset yang digunakan adalah Academic Outcomes & AI Dependency Analysis Dataset yang terdiri dari 8.000 data dan 26 atribut. Tahapan penelitian meliputi preprocessing, normalisasi, pembagian data, pelatihan model, dan evaluasi menggunakan akurasi, presisi, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa XGBoost memperoleh akurasi tertinggi sebesar 84,17%, lebih baik dibandingkan Naïve Bayes sebesar 79,03%. Temuan ini menunjukkan bahwa XGBoost lebih efektif untuk klasifikasi performa akademik mahasiswa berbasis penggunaan AI serta berkontribusi pada pengembangan educational data analytics.

Kata Kunci : *Artificial Intelligence, ChatGPT, Klasifikasi, Naïve Bayes, XGBoost.*

Copyright©2026 Aryanti Aryanti, Juriawan Raja Saputra, M. Taufik Permana, Putri Nabila, Ibnu Asrafi

This is an open access article under the [CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.



1. Pendahuluan

Perkembangan *Artificial Intelligence (AI)* menjadi salah satu perubahan penting dalam dunia pendidikan tinggi karena mampu mendukung proses pembelajaran mahasiswa secara lebih cepat dan efisien. Teknologi AI seperti *ChatGPT* banyak digunakan mahasiswa dalam menggali informasi, menguasai bahan pembelajaran, serta menyusun aktivitas perkuliahan (Hamka et al., 2025). Namun, pemanfaatan AI yang melebihi batas normal dapat menimbulkan berbagai permasalahan, seperti menurunnya kemampuan berpikir kritis, meningkatnya ketergantungan terhadap teknologi, dan potensi terjadinya plagiarisme akademik (Antonius et al., 2025). Oleh karena itu, analisis terhadap pengaruh penggunaan AI terhadap performa akademik mahasiswa menjadi penting untuk memahami dampak pemanfaatan AI dalam proses pembelajaran di pendidikan tinggi.

Penggunaan *machine learning* di dunia pendidikan tinggi semakin meningkat, terutama untuk menganalisis dan memprediksi kinerja akademik mahasiswa. Berbagai algoritma *machine learning* mampu mengidentifikasi pola perilaku belajar serta meningkatkan akurasi prediksi performa akademik, sehingga dapat membantu institusi pendidikan dalam pengambilan keputusan berbasis data (Wang, J., & Yu, 2025). Banyak studi yang sudah dilakukan sebelumnya menggunakan algoritma *machine learning* untuk memprediksi dan mengklasifikasi prestasi belajar siswa berdasarkan hal-hal seperti cara belajar, kegiatan di internet, dan penggunaan teknologi dalam pendidikan. Algoritma *Naïve Bayes* sering dipakai karena cara kerja yang mudah, cepat, dan efektif untuk mengklasifikasikan data yang berupa kategori atau teks (Endraswari et al., 2025). Di sisi lain, algoritma *XGBoost* terkenal sebagai salah satu metode *boosting* yang memiliki akurasi tinggi dalam mengklasifikasikan data yang rumit (Baidoo-anu & Ansah, 2023). Penelitian tentang penggunaan *Artificial Intelligence (AI)* pada siswa juga menunjukkan bahwa *machine learning* dapat menganalisis cara siswa menggunakan *ChatGPT* dan bagaimana hal itu berdampak pada kegiatan belajar mereka (Hakim, 2025). Selain itu, beberapa studi sebelumnya telah menggunakan metode seperti *Random Forest*, *Gradient Boosting*, *Support Vector Machine*, dan *LightGBM* untuk memprediksi bagaimana siswa akan berperilaku dalam hal akademik dengan mengandalkan data dari pendidikan online (Ramadhan et al., 2026).

Meskipun kedua algoritma ini menunjukkan hasil yang baik dalam banyak klasifikasi dalam penelitian, masih terdapat kekurangan dalam penelitian yang membahas prestasi akademik mahasiswa terkait dengan penggunaan *Artificial Intelligence*. Sebagian besar penelitian sebelumnya lebih fokus pada analisis bagaimana orang merasa tentang penggunaan AI, bagaimana teknologi diadopsi, atau mengklasifikasikan seberapa tergantung siswa pada *ChatGPT* (Endraswari et al., 2025). Selain itu, penelitian sebelumnya juga menggunakan data, analisis, dan cara yang berbeda, seperti bagaimana orang menggunakan teknologi, bagaimana mereka menerima sistem AI, dan

memikirkan risiko dalam akademik (Monalisa et al., 2025). Penelitian yang membandingkan performa algoritma *Naïve Bayes* dan *XGBoost* dalam klasifikasi prestasi belajar mahasiswa merujuk pada penggunaan *Artificial Intelligence* masih terbatas. Oleh karena itu, diperlukan lebih banyak studi untuk memahami algoritma mana yang paling tepat untuk proses klasifikasi ini.

Berdasarkan kesenjangan penelitian tersebut, penelitian ini merumuskan masalah pada belum adanya kajian yang secara khusus membandingkan performa algoritma *Naïve Bayes* dan *XGBoost* dalam mengklasifikasikan performa akademik mahasiswa berdasarkan tingkat penggunaan *Artificial Intelligence*. Hal ini penting untuk dikaji mengingat pemilihan algoritma yang tepat akan sangat menentukan keakuratan hasil klasifikasi yang dihasilkan. Dengan demikian, pertanyaan utama dalam penelitian ini adalah bagaimana perbandingan performa algoritma *Naïve Bayes* dan *XGBoost* dalam mengklasifikasikan performa akademik mahasiswa berdasarkan tingkat penggunaan AI, serta algoritma manakah yang menghasilkan tingkat akurasi lebih tinggi dalam konteks tersebut.

Kebaruan penelitian ini terletak pada perbandingan performa algoritma *Naïve Bayes* dan *XGBoost* dalam mengklasifikasikan performa akademik mahasiswa berdasarkan tingkat penggunaan *Artificial Intelligence* menggunakan *Academic Outcomes & AI Dependency Analysis Dataset*. Penelitian ini bertujuan membandingkan kinerja kedua algoritma tersebut dalam mengidentifikasi hubungan antara penggunaan AI dan performa akademik mahasiswa. Penelitian ini dibatasi pada penerapan dua algoritma *machine learning*, yaitu *Naïve Bayes* dan *XGBoost*, dengan memanfaatkan *dataset* publik yang diperoleh dari Kaggle. Hasil penelitian diharapkan dapat memberikan kontribusi dalam pengembangan penerapan *machine learning* pada bidang pendidikan serta menjadi referensi bagi penelitian selanjutnya terkait pemanfaatan *Artificial Intelligence* di lingkungan pendidikan tinggi.

2. Kajian Terdahulu

Proses pembelajaran di universitas telah berubah karena perkembangan AI. Mahasiswa memanfaatkan teknologi AI seperti *ChatGPT* untuk mencari informasi, memahami materi, dan menyusun tugas akademik (Crompton & Burke, 2023). Penggunaan AI dapat meningkatkan efektivitas pembelajaran, tetapi penggunaan berlebihan berpotensi menurunkan kemampuan berpikir kritis dan kemandirian belajar mahasiswa (Z et al., 2025). *Machine learning* banyak digunakan untuk menganalisis prestasi akademik siswa karena mampu mengidentifikasi pola hubungan antar data, seiring peningkatan penggunaan AI dalam pendidikan (Albreiki Balqis, Zaki Nazar, 2021). Dalam proses klasifikasi, algoritma *Naïve Bayes* dan *XGBoost* sering digunakan karena memiliki kemampuan prediksi yang baik pada data akademik dan perilaku penggunaan teknologi (Azis, 2024) (Bayu et al., 2025).

2.1 Algoritma *Naïve Bayes*

Nilai atribut dari metode klasifikasi statistik *Naïve Bayes* digunakan untuk memperkirakan kemungkinan suatu data terhadap kelas tertentu (Zamri, 2022). Algoritma ini menggunakan teori Bayes untuk memprediksi kejadian yang mungkin dengan menggunakan data atau pengalaman sebelumnya (Putri et al., 2022). *Naïve Bayes* sering dipakai untuk klasifikasi karena cara menghitungnya mudah, cepat, dan bagus dalam menangani data yang besar (Zamri, 2022). Hasil algoritma *Naïve Bayes* mencakup:

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)} \quad (1)$$

Keterangan dari persamaan (1) diatas yaitu:

$P(A|B)$ = probabilitas A dan B terjadi bersama-sama

$P(B|A)$ = probabilitas B dan A terjadi bersama-sama

$P(A)$ = probabilitas kejadian

$P(B)$ = probabilitas kejadian B.

2.2 Algoritma *XGBoost*

XGBoost, yang sering disebut sebagai *Extreme Gradient Boosting*, adalah cara untuk meningkatkan model dengan membangun secara bertahap. Ini dilakukan untuk mengurangi kesalahan yang ada dalam prediksi dari langkah-langkah sebelumnya. Algoritma ini mampu menangani hubungan nonlinier yang kompleks pada data serta menghasilkan performa prediksi yang baik dalam proses klasifikasi (Solang & Adu, 2026). Model prediksi *XGBoost* pada iterasi ke- m biasanya dirumuskan sebagai berikut (Solang & Adu, 2026):

$$F_m(x) = F_{m-1}(x) + \rho_m h_m(x) \quad (2)$$

Keterangan dari persamaan (2) diatas yaitu:

$F_m(x)$: hasil prediksi pada iterasi ke- m

$F_{m-1}(x)$: hasil prediksi pada iterasi sebelumnya

ρ_m : *learning rate*

$h_m(x)$: *Decision Tree* baru untuk memperbaiki kesalahan prediksi

2.3 Perbandingan Penelitian Terdahulu

Sebagai upaya untuk memahami perkembangan penelitian mengenai pemanfaatan *Artificial Intelligence* dan *machine learning* dalam bidang pendidikan, dilakukan telaah terhadap sejumlah penelitian terdahulu yang relevan. Penelaahan tersebut mencakup algoritma yang digunakan, karakteristik *dataset*, capaian performa model, serta keterbatasan yang masih ditemukan pada masing-masing penelitian. Analisis ini bertujuan untuk mengidentifikasi kesenjangan penelitian yang ada sekaligus menegaskan kontribusi penelitian ini dalam membandingkan algoritma *Naïve Bayes* dan *XGBoost*

untuk klasifikasi performa akademik mahasiswa berdasarkan tingkat penggunaan *Artificial Intelligence*. Ringkasan penelitian terdahulu disajikan pada Tabel 1.

Tabel 1. Perbandingan *State-of-the-art* Penelitian Terdahulu

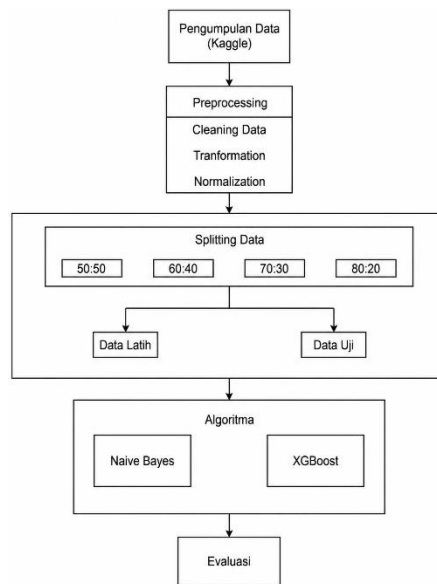
No	Peneliti	Metode	Dataset	Akurasi	Keterbatasan
1.	(Endraswari et al., 2025)	Naive Bayes	Kuesioner 58 mahasiswa	83,3%	<i>Dataset</i> kecil dan hanya satu algoritma
2.	(Aulia, 2026)	<i>Support Vector Machine (SVM)</i>	1.104 komentar mahasiswa	79,44%	Hanya menggunakan SVM dan analisis sentimen.
3.	(Das & Eliseev, 2025)	<i>XGBoost</i>	Survei 388 mahasiswa	80,1%	Sampel terbatas dan tidak membandingkan algoritma lain.
4.	(Das & Eliseev, 2025)	<i>XGBoost, Random Forest, dan SVM</i>	Survei penggunaan <i>ChatGPT</i> mahasiswa	92% (<i>XGBoost</i>)	Belum mengkaji ketergantungan AI secara spesifik dan tidak menggunakan Naive Bayes.

Berdasarkan sintesis penelitian terdahulu pada Tabel 1, masih terdapat beberapa kesenjangan penelitian terkait analisis dampak penggunaan *Artificial Intelligence* terhadap performa akademik mahasiswa. Sebagian besar penelitian terdahulu hanya berfokus pada klasifikasi ketergantungan terhadap *ChatGPT*, analisis sentimen penggunaan AI, atau prediksi performa akademik secara terpisah. Selain itu, mayoritas penelitian menggunakan satu algoritma klasifikasi sehingga belum memberikan perbandingan performa antaralgoritma secara komprehensif.

Penelitian yang secara khusus mengkaji hubungan antara tingkat ketergantungan *Artificial Intelligence* dan performa akademik mahasiswa dengan membandingkan algoritma *Naive Bayes* dan *XGBoost* masih terbatas. Oleh karena itu, penelitian ini menerapkan pendekatan machine learning menggunakan dataset publik yang memuat informasi penggunaan *Artificial Intelligence* dan capaian akademik mahasiswa. Kebaruan penelitian ini terletak pada analisis dan perbandingan performa algoritma *Naive Bayes* dan *XGBoost* dalam mengklasifikasikan performa akademik mahasiswa berdasarkan tingkat penggunaan *Artificial Intelligence*. Kontribusi penelitian ini terhadap bidang *Educational Data Mining* adalah memberikan evaluasi komparatif terhadap dua algoritma klasifikasi yang dapat digunakan untuk memodelkan hubungan antara penggunaan *Artificial Intelligence* dan performa akademik mahasiswa. Sementara itu, pada bidang *Learning Analytics*, hasil penelitian ini menyediakan informasi prediktif yang dapat dimanfaatkan oleh dosen maupun institusi pendidikan untuk mengidentifikasi mahasiswa yang berpotensi mengalami penurunan performa akademik akibat tingkat ketergantungan terhadap *Artificial Intelligence*, sehingga dapat mendukung penyusunan strategi pembelajaran dan intervensi akademik yang lebih tepat sasaran.

3. Metodologi Penelitian

Penelitian ini dilakukan untuk membuat model yang bisa mengklasifikasikan kinerja akademik mahasiswa berdasarkan penggunaan *Artificial Intelligence (AI)*. Penelitian ini membahas perbandingan antara dua algoritma, yaitu *Naïve Bayes* dan *XGBoost*. Langkah-langkah dalam penelitian ini diawali dari: (1) Mengumpulkan Data; (2) Praproses; (3) Pembagian Data; (4) Evaluasi. Proses penelitian bisa dilihat pada gambar 1.



Gambar 1. Alur Penelitian

3.1 Pengumpulan Data

Data utama dalam penelitian ini bersumber dari *dataset* publik yang bernama *Academic Outcomes & AI Dependency Analysis*. *Dataset* tersebut tersedia di situs *Kaggle* dan mencakup 8.000 data dengan 26 fitur yang berbeda-beda.. Fitur-fitur tersebut menggambarkan aspek-aspek penting mengenai penggunaan kecerdasan buatan, metode belajar siswa, serta prestasi akademik mereka. *Dataset* terakhir diperbarui pada tahun 2026, sehingga informasi yang dimuat dianggap sangat *Komprehensif* dan presisi. Secara umum, kumpulan data ini menjadi dasar yang kokoh untuk melakukan penelitian yang mendalam mengenai pengaruh penggunaan AI terhadap prestasi belajar siswa yang menjadi subjek penelitian ini.

3.2 Preprocessing Data

Preprocessing data merupakan tahapan awal dalam pengolahan data yang dilakukan sebelum proses analisis maupun pemodelan *machine learning*. Tahap ini dilakukan sebagai

proses persiapan data agar data dapat diolah dengan baik pada proses *machine learning* (Solang & Adu, 2026). *Data cleaning*, transformasi data, dan normalisasi data adalah beberapa langkah awal yang dilakukan dalam studi ini (Solang & Adu, 2026).

1. *Data cleaning*

Data cleaning dilakukan untuk menangani missing value pada *dataset*, baik dengan menghapus data yang kosong maupun menggantinya menggunakan nilai rata-rata pada masing-masing atribut (Suryanegara, G. A. B., & Purbolaksono, 2021).

2. *Data Transformation*

Data transformation merupakan proses mengubah data ke dalam format tertentu untuk meningkatkan kualitas data sehingga lebih mudah digunakan pada tahap analisis maupun pemodelan *machine learning* (Prasojo, B., & Haryatmi, 2021).

3. *Normalizaton*

Proses mengubah angka menjadi jangkauan nilai tertentu, seperti 0 hingga 1, dikenal sebagai normalisasi data. Ini dilakukan untuk membuat proses klasifikasi data lebih mudah (Arief, 2021).

3.3 *Splitting Data*

Splitting Data merupakan proses pemisahan kumpulan data menjadi dua bagian, yaitu data yang digunakan untuk melatih model dan data yang digunakan untuk menguji model, dengan perbandingan yang telah ditentukan sebelumnya. langkah selanjutnya dalam proses ini adalah melakukan pembagian data (Ariyani et al., 2022). Dalam penelitian ini, kumpulan data terbagi menjadi dua bagian, yaitu data untuk pelatihan dan data untuk pengujian, tujuannya adalah untuk menilai kemampuan model dalam memprediksi data baru. Penelitian terdahulu menggunakan metode pembagian data dengan rasio seperti 50:50, 60:40, dan 70:30 (Sholekhah et al., 2024). Oleh karena itu, penelitian ini menggunakan ketiga skenario tersebut serta menambahkan split data 80:20 untuk menganalisis pengaruh proporsi data training terhadap performa algoritma *Naïve Bayes* dan *XGBoost*.

1. Setengah dari data, yaitu 50 persen, dipakai untuk melatih model dan setengah lagi untuk menguji model.
2. Enam puluh persen dari data digunakan untuk melatih model, sedangkan empat puluh persen sisanya untuk menguji model.
3. Tujuh puluh persen dari data digunakan untuk melatih model dan tiga puluh persen lainnya untuk menguji model.
4. Delapan puluh persen dari data digunakan untuk pelatihan model, sedangkan dua puluh persen untuk pengujian model.

3.4 Algoritma

Studi ini memanfaatkan dua algoritma untuk mengklasifikasikan data: *Naïve Bayes* (NB) dan *Extreme Gradient Boosting (XGBoost)*. *Naïve Bayes* memakai cara probabilitas untuk mengidentifikasi kategori data, sementara *XGBoost* mengandalkan

teknik yang berfokus pada *Decision Tree* untuk meningkatkan kemampuan prediksi model.

3.5 Evaluasi

Pada tahap ini, cara untuk memprediksi dipakai untuk menilai seberapa baik kerja dari algoritma *Naïve Bayes* (NB) dan *Extreme Gradient Boosting* (XGBoost). Evaluasi ini dilakukan dengan cara membandingkan seberapa akurat kedua algoritma dengan menggunakan dataset yang identik dan mengaplikasikan metode pembagian data yang sama, ialah dengan rasio 50:50, 60:40, 70:30, dan 80:20.

4. Hasil dan Pembahasan

Hasil evaluasi menunjukkan bahwa algoritma XGBoost secara konsisten menghasilkan performa yang lebih unggul dibandingkan Naïve Bayes pada seluruh rasio pembagian data yang diujikan. Keunggulan ini disebabkan oleh mekanisme ensemble berbasis *boosting* yang dimiliki XGBoost, di mana model dibangun secara bertahap dengan memperbaiki kesalahan prediksi dari iterasi sebelumnya, sehingga mampu menangkap hubungan yang lebih kompleks antar fitur dalam data. Berbeda dengan XGBoost, Naïve Bayes mengandalkan asumsi bahwa setiap fitur bersifat independen satu sama lain, padahal dalam data perilaku penggunaan AI oleh mahasiswa, fitur-fitur tersebut cenderung saling berkaitan. Kondisi ini menjadikan Naïve Bayes kurang optimal dalam menangani kompleksitas data pada penelitian ini, meskipun tetap relevan digunakan pada dataset yang lebih sederhana karena proses komputasinya yang ringan dan efisien (Endraswari et al., 2025).. Temuan ini selaras dengan hasil penelitian terdahulu yang menyatakan bahwa metode *boosting* seperti XGBoost pada umumnya menghasilkan tingkat akurasi lebih tinggi ketika dihadapkan pada dataset dengan fitur yang kompleks dan saling berkorelasi (Baidoo-anu & Ansah, 2023).

Hasil penelitian ini membawa implikasi yang signifikan bagi dunia pendidikan tinggi dan pengembangan AI dalam proses pembelajaran. Secara praktis, institusi pendidikan dapat memanfaatkan algoritma XGBoost sebagai instrumen untuk mendeteksi mahasiswa yang berpotensi mengalami penurunan performa akademik akibat ketergantungan berlebihan terhadap teknologi AI, sehingga tindakan preventif dapat dilakukan lebih awal dan lebih tepat sasaran. Selain itu, penelitian ini menegaskan bahwa pemilihan algoritma *machine learning* dalam konteks pendidikan harus mempertimbangkan karakteristik dan kompleksitas data yang tersedia agar hasil klasifikasi yang diperoleh dapat dijadikan landasan pengambilan keputusan yang andal. Untuk penelitian selanjutnya, disarankan agar mengeksplorasi penggunaan teknik *hyperparameter tuning* atau kombinasi beberapa algoritma sekaligus guna meningkatkan akurasi dan ketahanan model klasifikasi performa akademik mahasiswa secara lebih menyeluruh.

4.1 Pengumpulan Data dan *Preprocessing*

Penelitian ini memakai kumpulan data AI Impact on Student Performance yang terdiri dari 8.000 informasi tentang mahasiswa. *Dataset* tersebut memuat beberapa atribut, seperti *ai_usage_hours_per_week*, *ai_generated_content_percentage*, *ai_dependency_score*, *last_exam_score*, *assignment_scores_avg*, *concept_understanding_score*, *social_media_hours*, dan *grade_level*. Penelitian ini menggunakan *student_performance_label* sebagai variabel target dengan tiga kategori, yaitu Low, Medium, dan High.

Tahap *preprocessing* meliputi transformasi data kategorikal menggunakan *one-hot encoding* dan normalisasi data numerik menggunakan metode standardisasi. Studi ini menggunakan 22 fitur dalam proses klasifikasi. Penelitian ini juga menerapkan empat metode pembagian data, yaitu dengan rasio 50:50, 60:40, 70:30, dan 80:20. Tujuannya adalah untuk mengevaluasi tingkat konsistensi dan kinerja model ketika perbandingan proporsi antara data latih dan data uji diubah-ubah.

4.2 Perbandingan Hasil Evaluasi pada Setiap Rasio Split

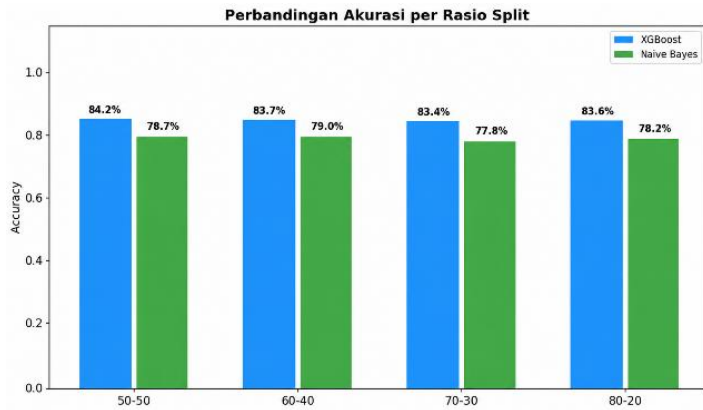
Tabel 1 menunjukkan perbandingan performa algoritma *XGBoost* dan *Naïve Bayes* berdasarkan empat metrik evaluasi pada setiap skenario pembagian data.

Tabel 2. Perbandingan Hasil Evaluasi pada Setiap Rasio Split

Rasio	Model	Akurasi	Presisi	Recall	F1
50:50	<i>XGBoost</i>	84,17%	84,05%	84,17%	83,97%
50:50	Naive Bayes	78,70%	78,89%	78,70%	77,86%
60:40	<i>XGBoost</i>	83,69%	83,54%	83,69%	83,47%
60:40	Naive Bayes	79,03%	79,36%	79,03%	78,17%
70:30	<i>XGBoost</i>	83,38%	83,26%	83,38%	83,19%
70:30	Naive Bayes	77,79%	78,03%	77,79%	76,84%
80:20	<i>XGBoost</i>	83,56%	83,48%	83,56%	83,36%
80:20	Naive Bayes	78,19%	78,59%	78,19%	72,22%

Dalam seluruh skenario pengujian, algoritma *XGBoost* mengalahkan *Naïve Bayes*, menurut data di Tabel 1. *XGBoost* memperoleh akurasi tertinggi sebesar 84,17% pada rasio split 50:50, sedangkan *Naïve Bayes* mencapai akurasi tertinggi sebesar 79,03% pada rasio 60:40. Nilai akurasi *XGBoost* juga cenderung stabil pada setiap skenario pembagian data, yaitu 84,17%, 83,69%, 83,38%, dan 83,56%.

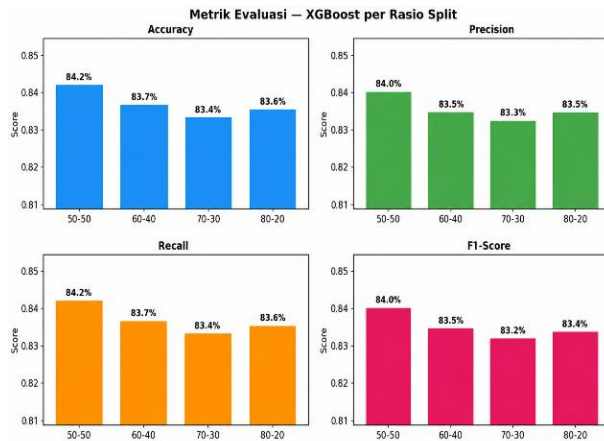
Gambar 1 menunjukkan perbandingan akurasi kedua algoritma secara visual. *XGBoost* secara konsisten mencapai nilai akurasi yang lebih tinggi dibandingkan Naive Bayes, dengan rata-rata selisih sekitar 5,4%. Temuan ini menunjukkan bahwa metode *ensemble* berbasis *boosting* lebih efektif dalam mengenali pola data *non-linear* jika dibandingkan dengan Naive Bayes yang menggunakan asumsi independensi antar fitur.



Gambar 2. Perbandingan Akurasi per Rasio Split

4.3 Evaluasi Performa *XGBoost* pada Setiap Rasio Split

Gambar 3 menunjukkan hasil evaluasi algoritma *XGBoost* menggunakan empat metrik, akurasi, ketepatan, *recall*, dan skor F1, pada setiap rasio split data. Setiap metrik menghasilkan nilai yang relatif konsisten pada setiap skenario pengujian, sehingga model tidak menunjukkan masalah ketidakseimbangan kelas yang signifikan. *XGBoost* memperoleh ketepatan 84,2%, ketepatan 84,0%, *recall* 84,2%, dan skor F1 84,0% pada rasio split 50:50.

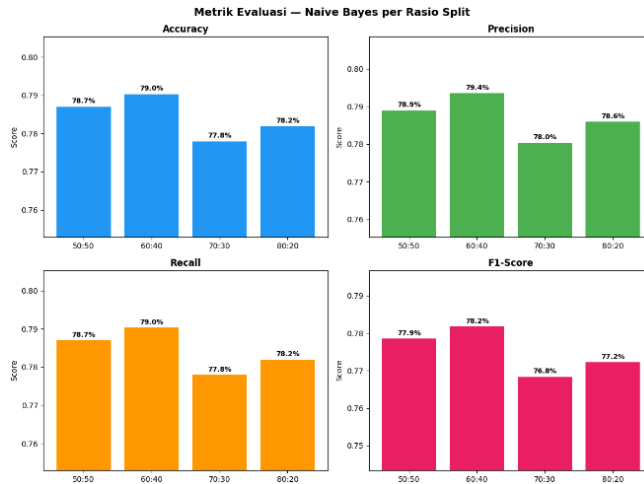


Gambar 3. Performa *XGBoost* pada Setiap Rasio Split

4.4 Evaluasi Performa *XGBoost* pada Setiap Rasio Split

Gambar 4 menunjukkan hasil evaluasi algoritma Naive Bayes menggunakan empat metrik: akurasi, ketepatan, pengembalian, dan skor F1. Secara keseluruhan, nilai evaluasi *Naive Bayes* berada pada rentang 77% hingga 79%, sehingga performanya masih lebih rendah dibandingkan *XGBoost*. *Naive Bayes* memperoleh akurasi tertinggi sebesar

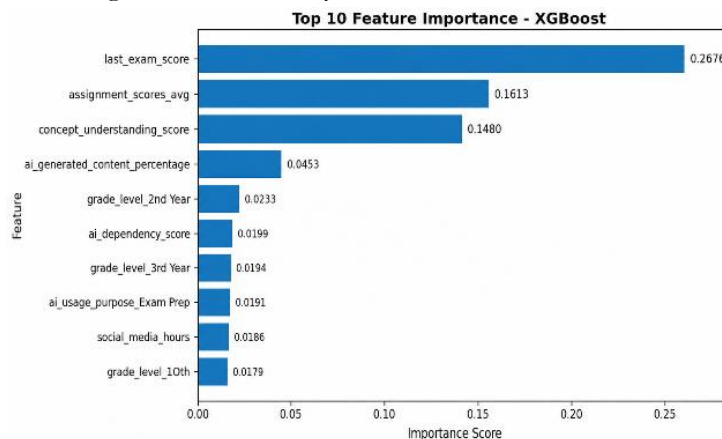
79,0% pada rasio split 60:40 dan menunjukkan performa yang relatif stabil pada seluruh skenario pengujian. Selisih performa sekitar 4–5% terhadap *XGBoost* menunjukkan bahwa asumsi independensi antar fitur pada *Naïve Bayes* kurang optimal dalam menangani data dengan hubungan antar fitur yang saling berkorelasi.



Gambar 4. Performa *Naïve Bayes* pada Setiap Rasio Split

4.5 Analisis *Feature importance XGBoost*

Dengan menggunakan algoritma *XGBoost*, analisis atribut penting dilakukan untuk menemukan atribut yang paling memengaruhi proses klasifikasi performa akademik siswa. Hasil pada Gambar 5 menunjukkan bahwa *last_exam_score* dan *assignment_scores_avg* memberikan kontribusi terbesar terhadap model, kemudian diikuti oleh *concept_understanding_score* dan *ai_generated_content_percentage*. Sementara itu, atribut seperti *social_media_hours*, *grade_level*, dan *ai_dependency_score* memberikan pengaruh yang lebih rendah dibandingkan atribut lainnya.



Gambar 5. Performa *Naïve Bayes* pada Setiap Rasio Split

Hasil tersebut menunjukkan bahwa faktor akademik, seperti nilai ujian, rata-rata nilai tugas, dan tingkat pemahaman konsep, menjadi faktor utama dalam menentukan performa akademik mahasiswa. Selain itu, penggunaan *Artificial Intelligence* juga memengaruhi hasil klasifikasi, terutama pada tingkat ketergantungan AI dan persentase konten yang dihasilkan AI selama proses pembelajaran.

5. Kesimpulan

Penelitian ini membandingkan performa algoritma *Naïve Bayes* dan *XGBoost* dalam mengklasifikasikan kinerja akademik mahasiswa menggunakan *dataset* publik *Academic Outcomes & AI Dependency Analysis* dari *Kaggle*. *XGBoost* unggul secara konsisten dengan akurasi tertinggi 84,17% pada rasio 50:50, sedangkan *Naïve Bayes* mencapai 79,03% pada rasio 60:40. Nilai *precision*, *recall*, dan *F1-score* *XGBoost* yang stabil di seluruh skenario menunjukkan model mampu menangani hubungan *non-linear* antarfitur dengan baik.

Hasil analisis *feature importance* menunjukkan bahwa *last_exam_score* dan *assignment_scores_avg* merupakan faktor paling berpengaruh terhadap klasifikasi, diikuti *concept_understanding_score* dan *ai_generated_content_percentage*. Temuan ini menegaskan capaian akademik tetap menjadi penentu utama, sementara intensitas dan ketergantungan terhadap *Artificial Intelligence* memberikan kontribusi yang lebih kecil. Secara praktis, pendekatan ini berpotensi dimanfaatkan institusi pendidikan sebagai dasar analitik untuk memetakan performa akademik mahasiswa.

Secara teoretis, hasil ini memperkuat relevansi metode *ensemble* berbasis *boosting* untuk pemodelan data akademik. Adapun keterbatasan penelitian ini terletak pada penggunaan satu *dataset* publik dan dua algoritma, sehingga hasilnya belum tentu dapat digeneralisasi pada konteks lain. Oleh karena itu, penelitian selanjutnya direkomendasikan menggunakan *dataset* yang lebih ekstensif dan beragam, menambahkan algoritma pembanding seperti *Random Forest*, *LightGBM*, dan *Support Vector Machine*, serta menerapkan *cross-validation k-fold* dan optimasi *hyperparameter* untuk memperoleh hasil yang lebih stabil.

6. Ucapan Terima Kasih

Penulis menyampaikan penghargaan dan terima kasih untuk seluruh pihak yang sudah memotivasi selama proses penelitian dan pembuatan artikel ini. Ucapan terima kasih yang khusus ditujukan kepada dosen pembimbing karena telah memberi bantuan, masukan, serta arahan yang konstruktif sehingga penelitian ini dapat diselesaikan dengan baik. Penulis juga mengapresiasi semua pihak yang telah berkontribusi, baik secara langsung maupun tidak langsung, dalam pelaksanaan penelitian ini.

7. Pernyataan Penulis

Penulis menjelaskan bahwa tidak ada konflik kepentingan dalam publikasi artikel ini. Penulis juga memastikan bahwa semua data dan tulisan yang ada adalah hasil karya sendiri, tanpa menjiplak, dan penulis bertanggung jawab sepenuhnya atas keaslian dan kebenaran artikel ini.

Bibliografi

- Albreiki Balqis, Zaki Nazar, A. H. (2021). A Systematic Literature Review of Student' Performance Prediction Using Machine Learning Techniques. *Education Sciences*. <https://doi.org/https://doi.org/10.3390/educsci11090552>
- Antonius, J., Siallagan, S., Aurelia, T., Yuya, P., & Arshyara, S. (2025). Penggunaan Kecerdasan Buatan AI Mengakibatkan Krisis Pemikiran Kritis Pelajar dalam Dunia Pendidikan Indonesia. *Pendas: Jurnal Ilmiah Pendidikan Dasar*, 8(2018), 47679–47683. <https://doi.org/https://doi.org/10.23969/jp.v10i04.37423>
- Arief, M. (2021). Perbandingan Support Vector Machine dan Modified Balanced Random Forest dalam Deteksi Pasien Penyakit Diabetes. *JURNAL RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 1(10), 393–399. <https://teknosi.fti.unand.ac.id/index.php/teknosi/article/view/1555>
- Ariyani, V., Putri, P., Budi, A., & Eridani, D. (2022). Perbandingan kinerja algoritme naïve bayes dan k- nearest neighbor (knn) untuk prediksi harga rumah. *Jurnal ilmiah teknik elektro*, 4. <https://doi.org/https://doi.org/10.14710/transmisi.24.4.162-171>
- Aulia, G. (2026). The Impact of ChatGPT on Students ' Academic Performance Using the Support Vector Machine Algorithm Pengaruh ChatGPT Terhadap Peforma Akademik Mahasiswa Menggunakan Algoritma Support Vector Machine. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 6(April), 619–631. <https://doi.org/https://doi.org/10.57152/malcom.v6i2.2630>
- Azis, A. R. (2024). Analisis Komparasi Algoritma Machine Learning dalam Prediksi Performa Akademik Mahasiswa : Literature Review. *Jurnal Ilmu Komputer Dan Informatika (JIKI)*, 4(2), 143–150. <https://doi.org/https://doi.org/10.54082/jiki.212>
- Baidoo-anu, D., & Ansah, L. O. (2023). Education in the Era of Generative Artificial Intelligence (AI): Understanding the Potential Benefits of ChatGPT in Promoting Teaching and Learning. *Journal of AI Volume:*, 7(December), 52–62. <https://doi.org/10.61969/jai.1337500>
- Bayu, M., Alfarizi, A., Witanti, W., & Komarudin, A. (2025). Prediksi Kinerja Akademik Siswa Bimbingan Belajar Menggunakan Algoritma Extreme Gradient Boosting (XGBoost). *Building of Informatics, Technology and Science (BITS)*, 7(1), 584–594. <https://doi.org/10.47065/bits.v7i1.7387>
- Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education : the state of the field. *International Journal of Educational Technology in Higher Education*. <https://doi.org/10.1186/s41239-023-00392-8>
- Das, S., & Eliseev, A. (2025). Predicting ChatGPT Use in Assignments : Implications for AI-Aware Assessment Design. *ArXiv Preprint ArXiv:2508.12013.*, 1–15.

- <https://doi.org/https://doi.org/10.48550/arXiv.2508.12013>
- Endraswari, P. M., Tou, N., & Zaliman, I. (2025). Analisis Ketergantungan Mahasiswa Terhadap Chatgpt Dalam Konteks Akademik : Pemodelan Klasifikasi Berbasis Naïve Bayes. *Jurnal Informasi Interaktif Vol.*, 10(3), 199–208. <https://informasiinteraktif.janabadra.ac.id/index.php/jii/article/view/192>
- Hakim, M. F. (2025). Analisis Ketergantungan Mahasiswa Universitas Merangin terhadap ChatGPT dengan Machine Learning. *Jurnal Sistem Informasi, Teknik Komputer Dan Teknologi Pendidikan (JUSTIKPEN)*, 7924(September), 35–41. <https://doi.org/https://doi.org/10.55338/justikpen.v5i1.201>
- Hamka, J. P., Barat, A. T., Utara, K. P., Padang, K., & Barat, S. (2025). Dampak AI terhadap Proses Pembelajaran Mahasiswa Prodi Perpustakaan dan Ilmu Informasi UNP. *Jurnal Pustaka AI (Pusat Akses Kajian Teknologi Artificial Intelligence)*, 5(1), 89–93. <https://doi.org/https://doi.org/10.55382/jurnalpustakaai.v5i1.950>
- Monalisa, S., Kurniawan, M. R., Sena, A. B., Purwani, F., Studi, P., Informasi, S., Islam, U., Raden, N., Palembang, F., & Akademik, P. (2025). Penerapan Model Utaut Untuk Mengukur Dampak Kecerdasan Buatan Terhadap Akademik Mahasiswa. *Jurnal Mahasiswa Sistem Informasi (JMSI)*, 7(1), 373–382. <https://doi.org/https://doi.org/10.24127/jmsi.v7i1.10747>
- Prasojo, B., & Haryatmi, E. (2021). Analisa Prediksi Kelayakan Pemberian Kredit Pinjaman dengan Metode Random Forest. *J. Nas. Teknol. Dan Sist. Inf*, 02, 79–89. <https://teknosi.fti.unand.ac.id/index.php/teknosi/article/view/1555>
- Putri, D. D., Nama, G. F., & Sulistiono, W. E. (2022). Analisis Sentimen Kinerja Dewan Perwakilan Rakyat (Dpr) Pada Twitter Menggunakan Metode Naive Bayes Classifier. *Jurnal Informatika Dan Teknik Elektro Terapan (JITET)*, 10(1), 34–40. <https://doi.org/https://doi.org/10.23960/jitet.v10i1.2262>
- Ramadhan, H. S., Akbar, A. S., Sinaga, K. Y., Muthoharoh, L., Satria, A., & Manullang, M. C. (2026). Sentiment Analysis Of Ai Adoption In Indonesian Higher Education Using Machine Learning And Transformer-Based Models. *ArXiv Preprint ArXiv:2604.27439*. <https://doi.org/https://doi.org/10.48550/arXiv.2604.27439>
- Sholekhah, F., Putri, A. D., & Efrizoni, L. (2024). Comparison of Naive Bayes and K-Nearest Neighbors Algorithms for Metabolic Syndrome Classification. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(April), 507–514. <https://doi.org/https://doi.org/10.57152/malcom.v4i2.1249>
- Solang, E. W., & Adu, F. X. (2026). Machine Learning Evaluation for Hotel Cancellation Prediction with Threshold Adjustment and Cost-Based Evaluation. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 6(January), 193–204. <https://doi.org/https://doi.org/10.57152/malcom.v6i1.2466>
- Suryanegara, G. A. B., & Purbolaksono, M. D. (2021). Peningkatan Hasil Klasifikasi pada Algoritma Random Forest untuk Deteksi Pasien Penderita Diabetes Menggunakan Metode Normalisasi. *JURNAL RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 1(10), 114–122. <https://doi.org/10.29207/resti.v5i1.2880>
- Wang, J., & Yu, Y. (2025). Machine learning approach to student performance prediction of online learning. *PloS One*, 1–15. <https://doi.org/10.1371/journal.pone.0299018>
- Z, I. A., Widaningrum, I., & Litianianda, Y. (2025). Pengembangan Sistem Pendukung

- Keputusan Berbasis Machine Learning untuk Prediksi Kinerja Dosen Menggunakan Data Historis Evaluasi Pembelajaran. *JURIKOM (Jurnal Riset Komputer)*, 12(6), 1026–1035. <https://doi.org/10.30865/jurikom.v12i6.9363>
- Zamri, D. (2022). Comparison of Data Mining Methods for Prediction of Floods with Naïve Bayes and KNN Algorithm. *SENTIMAS: Seminar Nasional Penelitian Dan Pengabdian Masyarakat*, 40–48. <https://journal.irpi.or.id/index.php/sentimas/article/view/353>