

Implementasi Extreme Gradient Boosting (XGBoost) untuk Klasifikasi Penggunaan Ulang Asisten AI

Fitri Permata Sari¹, Rini Budiarni²

Informatika, Sekolah Tinggi Teknologi Payakumbuh

¹fitriprmts@gmail.com, ²rinibudiarni@gmail.com

Abstract

This study applies the Extreme Gradient Boosting (XGBoost) algorithm to categorize the UsedAgain variable, which reflects students' tendency to reuse AI assistants in the learning process. A synthetic dataset taken from Kaggle containing 10,000 data points and 11 attributes was processed through several steps, including preprocessing, converting categorical variables to numeric, class balancing using the SMOTE method, and hyperparameter settings to achieve the best model configuration. The test results show that the XGBoost model with the best parameters (learning_rate = 0.1; max_depth = 5; n_estimators = 200; subsample = 0.8) achieved an accuracy of 93.25%, a precision of 87.09%, a recall of 91.25%, and an F1-score of 89.12%. These findings indicate that XGBoost is effective in identifying student interaction patterns with AI assistants. The main contribution of this research is to provide a strong analytical basis for understanding the behavioral factors of students in utilizing AI assistants, so that the model results can support educational institutions in designing more adaptive and targeted technology-based learning strategies.

Keywords: Asistant AI, Clasification, XGBoost, SMOTE, Hyperparameter

Abstrak

Penelitian ini menerapkan algoritma Extreme Gradient Boosting (XGBoost) untuk mengkategorikan variabel UsedAgain, yang mencerminkan kecenderungan mahasiswa untuk kembali menggunakan asisten AI dalam proses pembelajaran. Dataset sintetis yang diambil dari Kaggle yang berisi 10.000 data dan 11 atribut diproses melalui beberapa langkah, termasuk preprocessing, konversi variabel kategori ke numerik, penyeimbangan kelas dengan metode SMOTE, serta pengaturan hyperparameter untuk mencapai konfigurasi model yang terbaik. Hasil dari pengujian menunjukkan bahwa model XGBoost dengan parameter terbaik (learning_rate = 0,1; max_depth = 5; n_estimators = 200; subsample = 0,8) memperoleh akurasi sebesar 93,25%, precision 87,09%, recall 91,25%, dan F1-score 89,12%. Temuan ini mengindikasikan bahwa XGBoost efektif dalam mengidentifikasi pola interaksi mahasiswa dengan asisten AI. Kontribusi utama penelitian ini adalah memberikan dasar analitik yang kuat untuk memahami faktor-faktor perilaku mahasiswa dalam memanfaatkan asisten AI, sehingga hasil model dapat mendukung institusi pendidikan dalam merancang strategi pembelajaran berbasis teknologi yang lebih adaptif dan tepat sasaran.

Kata kunci: Asisten AI, Klasifikasi, XGBoost, SMOTE, Hyperparameter.

© 2025 Author
Creative Commons Attribution 4.0 International License



1. Pendahuluan

Sektor pendidikan mengalami transformasi yang signifikan karena kemajuan dalam teknologi kecerdasan buatan, termasuk penciptaan asisten AI yang dirancang untuk membantu mahasiswa dalam kegiatan belajar mereka [1]. Asisten AI dapat digunakan untuk meningkatkan keterampilan dan wawasan mahasiswa, serta mendukung proses pembelajaran di perguruan tinggi, alat ini juga bisa membantu dalam belajar secara mandiri [2].

Efektivitas serta penerimaan mahasiswa terhadap teknologi kecerdasan buatan (AI) menunjukkan perbedaan yang signifikan, dipengaruhi oleh berbagai faktor seperti level pendidikan, bidang studi, frekuensi penggunaan teknologi, dan jenis serta tingkat kesulitan tugas akademik yang harus diselesaikan. Maka dari itu, penerapan AI dalam pendidikan tinggi memerlukan strategi yang fleksibel dan sesuai dengan konteks [3]. Penyesuaian ini bertujuan agar integrasi teknologi AI dapat sejalan dengan metode belajar mahasiswa, sehingga dapat memaksimalkan hasil belajar secara berkelanjutan dan disesuaikan dengan kebutuhan individu [4].

Pemahaman terhadap pola interaksi mahasiswa dengan asisten AI menjadi penting untuk mengidentifikasi faktor-faktor yang memengaruhi hasil belajar dan kecenderungan perilaku mereka, seperti tingkat kepuasan serta keinginan untuk menggunakan layanan itu lagi [5]. Penggunaan asisten AI memberikan keuntungan dalam belajar dan aktivitas sehari-hari, meskipun ada ketidakpastian tentang data yang disajikan, karena dipengaruhi oleh pandangan tentang manfaat dan kemudahan dalam memakai teknologi tersebut. [6]. Analisis data interaksi antara mahasiswa dan asisten AI diperlukan untuk mendapatkan pemahaman mendalam yang bermanfaat bagi pengembang teknologi serta lembaga pendidikan untuk meningkatkan asisten AI dalam konteks pembelajaran [7].

Studi awal yang dilaksanakan Dava, Penerapan algoritma XGBoost dengan memanfaatkan teknik oversampling serta penyesuaian parameter adalah metode klasifikasi yang sangat efektif dalam menilai kualitas air. Evaluasi terhadap 2400 dataset yaitu 1200 data kelas air minum dan 1200 data kelas air tidak layak minum menghasilkan *accuracy* sebesar 82,29%, *precision* 78,62%, *recall* 85,90%, dan *f1-score* 82,09% [8]. Penelitian kedua oleh Thesa, penerapan algoritma XGBoost dalam klasifikasi varietas kacang kering dengan fokus pada penanganan ketidakseimbangan kelas melalui pembobotan kelas, dimana evaluasi model pada data uji menunjukkan *accuracy* 93%, dengan hasil *precision*, *recall*, dan *f1-score* yang seimbang pada setiap kelas [9].

Penelitian ketiga oleh Rizky tentang Prediksi keberlangsungan hidup pasien gagal jantung menggunakan algoritma XGBoost dengan metode optimasi *hyperparameter tuning* yang melebihi model lainnya dan meraih nilai AUC mencapai 0.94 [10]. Penelitian berikutnya oleh Wijaya untuk mengoptimalkan *hyperparameter tuning* dalam XGBoost merupakan langkah penting untuk memperoleh performa model yang optimal. Hasil penilaian menunjukkan bahwa metode optimalisasi pencarian grid menghasilkan performa terbaik pada model XGBoost dengan peningkatan nilai evaluasi dari 97,31 menjadi 98,41 [11].

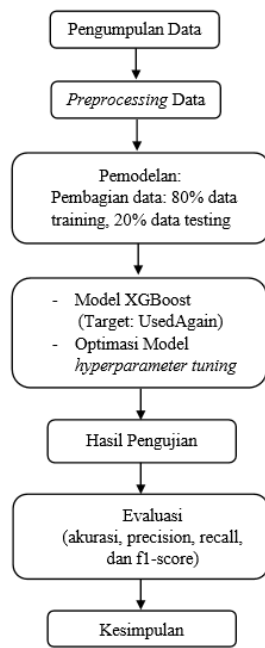
Kajian yang telah dilakukan sebelumnya yang menggunakan algoritma XGBoost umumnya lebih terfokus pada area teknis seperti analisis kualitas air, klasifikasi produk pertanian, ramalan kesehatan, dan analisis data penjualan. Hal ini menyebabkan belum adanya penelitian yang mengeksplorasi bidang pendidikan atau perilaku pengguna teknologi pembelajaran berbasis kecerdasan buatan. Selain itu, belum ada kajian yang secara khusus memprediksi kecenderungan mahasiswa dalam menggunakan asisten AI (UsedAgain) dengan menganalisis berbagai variabel perilaku yang relevan, termasuk tingkat pendidikan, bidang studi, durasi penggunaan, jumlah permintaan, jenis tugas, dan tingkat interaksi dengan AI. Penelitian sebelumnya juga belum mengintegrasikan proses preprocessing untuk variabel kategorikal, penyeimbangan kelas menggunakan SMOTE, serta optimasi hyperparameter dalam satu kerangka analisis yang utuh untuk memahami dinamika penggunaan asisten AI. Dengan begitu, terdapat kekurangan dalam penelitian mengenai penerapan XGBoost untuk memahami pola interaksi mahasiswa dengan asisten AI, yang akan dijawab oleh penelitian ini melalui pengembangan model klasifikasi yang menyeluruh.

Analisis pola interaksi antara mahasiswa dan asisten AI dengan penerapan algoritma mampu mengidentifikasi serta memodelkan faktor-faktor yang berkontribusi secara signifikan untuk mendapatkan informasi yang relevan dengan kebutuhan akademik [12]. Kebaruan dari penelitian ini yaitu pemanfaatan algoritma XGBoost sebagai metode utama berdasarkan karakteristiknya yang telah terbukti unggul dalam berbagai bidang untuk mengelola data yang bersifat kompleks, mencegah overfitting, dan menawarkan tingkat ketepatan prediksi yang lebih tinggi [13], untuk menjelaskan kecenderungan mahasiswa dalam menggunakan asisten AI (UsedAgain), yang merupakan subjek yang belum pernah diulas dalam studi sebelumnya. Berbeda dengan penelitian sebelumnya yang lebih menekankan pada aspek teknis di luar pendidikan, studi ini menggabungkan analisis perilaku pengguna dengan metode pembelajaran mesin dengan memanfaatkan berbagai variabel penting seperti tingkat pendidikan, bidang studi, lama sesi, jumlah

permintaan, tipe tugas, dan tingkat interaksi dengan AI. Selain itu, penelitian ini juga menyatukan tahapan pra-pemrosesan untuk kategori, penyeimbangan kelas dengan teknik SMOTE, dan pengaturan hyperparameter dalam satu kerangka kerja pemodelan yang menyeluruh, sehingga menghasilkan model klasifikasi yang lebih akurat dan representatif dalam konteks pembelajaran berbasis teknologi. Kontribusi ini tidak hanya memperluas penggunaan XGBoost dalam bidang pendidikan, tetapi juga menyediakan dasar analitis bagi lembaga untuk lebih memahami pola interaksi mahasiswa dengan asisten AI secara mendalam [14].

2. Metode Penelitian

Gambar 1 menunjukkan alur penelitian yang menggambarkan langkah-langkah yang diambil, mulai dari pengumpulan informasi hingga evaluasi hasil dan penyusunan kesimpulan, guna memastikan bahwa proses penelitian berjalan secara terarah dan terukur.



Gambar 1. Alur Penelitian

2.1. Pengumpulan Data

Peneliti melakukan proses pengumpulan data pada tahap ini sebagai dasar utama dalam pelaksanaan penelitian. Data diperoleh dari Kaggle pada tautan <https://www.kaggle.com/datasets/ayeshasal89/aiassitant-usage-in-student-life-synthetic>, yang merupakan informasi bertema *AI Assistant Usage in Student Life*. Dataset ini dikembangkan untuk merepresentasikan perilaku mahasiswa dalam memanfaatkan asisten kecerdasan buatan (AI) selama kegiatan belajar, baik dalam konteks akademik maupun non-akademik. File data tersedia dalam format *Comma-Separated Values* (CSV),

yang memudahkan proses pemrosesan awal dan analisis menggunakan bahasa pemrograman Python.

2.2. Preprocessing Data

Preprocessing data merupakan serangkaian proses pengolahan data guna mempersiapkan data agar dapat digunakan dalam analisis lebih lanjut atau pemodelan *machine learning*. Kualitas hasil analisis sangat dipengaruhi oleh kualitas data yang digunakan, sehingga tahap ini menjadi fondasi utama dalam memastikan keakuratan model yang dibangun. Salah satu langkah utama pada tahap ini adalah transformasi variabel kategorikal menjadi format numerik, karena sebagian besar algoritma *machine learning* hanya dapat mengolah data numerik. Melalui proses ini, variabel kategorikal yang semula berbentuk teks atau label dapat diubah menjadi representasi numerik yang sesuai. Pendekatan ini memungkinkan model untuk memahami setiap kategori secara independen tanpa mengasumsikan adanya hubungan ordinal di antara nilai-nilai kategorikal tersebut.

2.3. Pemodelan

Pada tahap pemodelan, kumpulan data dipisah yaitu: data untuk proses latih sebanyak 80% dan data untuk proses uji sebesar 20%. Ini dilakukan agar model dapat belajar dari dataset training dan dinilai secara objektif dengan menggunakan dataset testing yang belum pernah diakses sebelumnya. Model ini diharapkan dapat memiliki kemampuan generalisasi yang baik dan menghindari masalah *overfitting*. Selanjutnya dilakukan *class balancing* menggunakan teknik *oversampling* pada data training untuk mengatasi ketidakseimbangan antara kelas yang dapat berdampak pada kinerja model pembelajaran mesin.

2.4. Model XGBoost

Pada tahap ini, algoritma XGBoost digunakan sebagai model utama untuk melakukan klasifikasi terhadap variabel target yaitu *UsedAgain*. XGBoost dipilih karena dikenal memiliki performa tinggi dalam berbagai masalah klasifikasi berkat kemampuannya menangani data yang kompleks, performa prediksi yang stabil, serta fitur optimasi yang efisien. Selanjutnya dilakukan *Optimasi hiperparameter tuning* untuk menemukan pengaturan parameter yang optimal, yang dapat meningkatkan kinerja serta menjaga keseimbangan antara kompleksitas model dan kemampuannya dalam menggeneralisasi data yang baru. Parameter XGBoost yang digunakan dalam penelitian ini yaitu: *learning_rate*, *n_estimators*, *max_depth* dan *subsample*.

2.5. Hasil Pengujian

Di tahap ini, peneliti menganalisis hasil dari klasifikasi variabel target yaitu *UsedAgain* untuk menilai seberapa akurat algoritma XGBoost dengan

memanfaatkan *confusion matrix*. Analisis pengujian *Confusion Matrix* menghasilkan nilai matriks sesuai keterangan berikut: True Positif (TP) menampilkan hasil nilai TRUE UsedAgain diklasifikasikan sebagai TRUE atau kelas positif, False Positif (FP) menampilkan hasil nilai FALSE UsedAgain diklasifikasikan sebagai TRUE, False Negatif (FN) menampilkan hasil nilai TRUE UsedAgain diklasifikasikan sebagai FALSE dan True Negatif (TN) menampilkan hasil nilai FALSE UsedAgain diklasifikasikan sebagai FALSE atau kelas negatif.

2.6. Evaluasi

Pada tahap evaluasi, dilakukan penilaian performa dari masing-masing model XGBoost yang digunakan dalam memprediksi a variabel target UsedAgain. Penilaian performa model dilakukan dengan memanfaatkan indikator penting seperti tingkat *accuracy*, *presisi*, *recall*, dan *skor f1* sebagai berikut:

- a. Akurasi merupakan rasio total perkiraan yang benar dibandingkan dengan seluruh prediksi yang dilakukan. Angka akurasi dapat dihitung dengan menggunakan Persamaan 1:

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

- b. *Precision* menghitung bagian dari prediksi positif yang sesuai dengan nilai positif yang sebenarnya. Nilai *Precision* bisa dihitung dengan menggunakan Persamaan 2:

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (2)$$

- c. *Recall* yang juga disebut sebagai sensitivitas, menilai seberapa banyak kasus positif yang benar-benar terdeteksi oleh model. Nilai *recall* bisa dihitung dengan Persamaan 3:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3)$$

- d. F1-Score merupakan hasil bagi antara precision dan recall, yang bertujuan untuk mencapai kestabilan antara kedua ukuran tersebut. Angka F1-Score dihitung menggunakan Persamaan 4:

$$\text{F1-Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (4)$$

3. Hasil dan Pembahasan

Bab ini menguraikan dengan mendetail setiap langkah yang telah dilalui dalam metode penelitian. Ulasan ini mencakup hasil-hasil yang diperoleh dari setiap langkah serta analisis yang menghubungkan temuan tersebut dengan tujuan dari studi ini.

3.1. Pengumpulan Data

Peneliti mengumpulkan dataset untuk penelitian ini yang diperoleh dari situs web kaggle.com “<https://www.kaggle.com/datasets/ayeshasal89/ai-assistant-usage-in-student-life-synthetic>”. Data yang diperoleh dari situs kaggle itu memiliki format CSV. Dataset terdiri dari 11 atribut dan 10.000 *record* data. Di dalam Atribut terdapat 1 atribut label.

Berikut adalah sampel data AI Assistant Usage Student Life pada Tabel 1.

Tabel 1. Dataset AI Assistant Usage Student Life

SessionID	StudentLevel	...	TaskType	UsedAgain
SESSION00001	Undergraduate	...	Studying	TRUE
SESSION00002	Undergraduate	...	Studying	TRUE
SESSION00003	Undergraduate	...	Coding	TRUE
SESSION00004	Undergraduate	...	Coding	TRUE
...
SESSION09997	High School	...	Writing	TRUE
SESSION09998	Undergraduate	...	Studying	TRUE
SESSION09999	Undergraduate	...	Writing	FALSE
SESSION10000	Undergraduate	...	Writing	TRUE

Dataset AI Assistant Usage Student Life yang diolah pada penelitian ini terdiri dari 10 atribut. 6 atribut dijadikan variabel input dan 1 atribut dijadikan variabel target pada proses klasifikasi menggunakan algoritma XGBoost. Pemilihan atribut dilakukan melalui analisis awal untuk memastikan bahwa variabel yang digunakan memiliki relevansi yang signifikan terhadap tujuan penelitian, yaitu memprediksi kecenderungan mahasiswa untuk menggunakan kembali (reuse) asisten AI dalam proses belajar. Atribut-atribut tersebut dipaparkan pada Tabel 2.

Tabel 2. Attribute Dataset AI Assistant Usage Student Life


No.	Atribut	Jenis Data	Variabel
1	SessionID	Kategorikal	-
2	StudentLevel	Kategorikal	Input
3	Dicipline	Kategorikal	Input
4	SessionDate	Numerik	-
5	SessionLengthMin	Numerik	Input
6	TotalPrompts	Numerik	Input
7	TaskType	Kategorikal	Input
8	AI_AsistantceLevel	Numerik	Input
9	FinalOutcome	Kategorikal	-
10	UsedAgain	Kategorikal	Target

3.2. Preprocessing Data

Variabel kategorikal pada tahap preprocessing data dikonversi menjadi numerik agar dapat digunakan dalam algoritma pembelajaran mesin, terutama XGBoost yang hanya mengolah data dalam bentuk angka. Teknik yang diterapkan adalah One-Hot Encoding, di mana setiap kategori dalam variabel diubah menjadi kolom biner (0 atau 1). Dalam dataset ini, variabel kategorikal seperti StudentLevel, Discipline, dan TaskType dikenali dengan tipe data object. Proses encoding ini menghasilkan beberapa kolom baru yang mewakili setiap kategori unik dari variabel tersebut. Tahapan preprocessing bertujuan untuk meningkatkan kualitas, konsistensi, dan keterbacaan data oleh algoritma XGBoost sehingga proses pelatihan model dapat berjalan optimal serta menghasilkan hasil klasifikasi yang akurat dan dapat diandalkan.


3.3. Pemodelan

Dataset yang berjumlah 10.000 *record* yang telah melalui proses preprocessing dipisah menjadi dua, yakni data untuk proses latih (training set) sebesar 80% yaitu 8000 data dan data untuk proses uji (testing set) sebesar 20% yaitu 2000 data. Training set digunakan untuk melatih dan mengoptimalkan model, termasuk saat tuning hyperparameter. Testing set digunakan hanya sekali di akhir, untuk mengevaluasi performa model yang sudah selesai dilatih dan dituning. Gambar 3 merupakan hasil dari proses *preprocessing* dibagi menjadi dua bagian.




Gambar 3. Hasil Split Data

Selanjutnya, dilakukan penyetaraan kelas menggunakan SMOTE, yang merupakan metode *oversampling* untuk menangani ketidakseimbangan antara kategori. Ketidakseimbangan ini dapat memengaruhi hasil dari model pembelajaran mesin, karena model cenderung lebih memprioritaskan kategori yang memiliki jumlah sampel lebih banyak dibandingkan yang jumlahnya lebih sedikit. Proses penyeimbangan ini menggunakan metode *oversampling* untuk menduplikasi contoh dari kategori minoritas, sehingga jumlah sampel dalam kategori tersebut setara dengan kategori mayoritas. Gambar 4 merupakan gambaran kelas sebelum menggunakan SMOTE.



Gambar 4. Hasil Split Data

Gambar 4 menggambarkan bahwa sebelum penerapan SMOTE, terdapat ketidakseimbangan dalam data pada variabel UsedAgain. Kelas UsedAgain = False terdiri dari 4880 sampel, sementara kelas UsedAgain = True memiliki 2120 sampel. Ketidakseimbangan ini bisa berakibat model klasifikasi lebih cenderung untuk menguasai pola dari kelas yang lebih banyak. Gambar 5 merupakan hasil penyetaraan kelas menggunakan SMOTE.



Gambar 5. Distribusi Kelas Setelah SMOTE

Setelah menerapkan *oversampling* menggunakan metode SMOTE, distribusi dari data target menjadi seimbang antara kategori FALSE dan TRUE. Ini terlihat pada grafik, di mana masing-masing kategori memiliki jumlah data sebanyak 4880. Dengan distribusi kelas yang merata, model klasifikasi diharapkan dapat belajar dengan lebih efektif karena tidak bias terhadap kelas yang lebih banyak. Teknik SMOTE berfungsi dengan menciptakan data sintesis baru berdasarkan sampel-sampel yang ada, sehingga tidak hanya menyalin data, tetapi juga menciptakan variasi baru yang tetap sesuai dengan pola data yang asli.

3.4 Model XGBoost

Target yang digunakan untuk implementasi metode XGBoost adalah UsedAgain, target ini diharapkan bisa membuat model klasifikasi yang tepat dan bisa dipercaya, karena XGBoost bisa mempelajari hubungan rumit antar fitur dan memberi penekanan lebih pada kesalahan yang terjadi saat proses latihan, sehingga model lebih mampu menyesuaikan diri dengan data yang ada. Setelah model klasifikasi didapatkan dilanjutkan dengan optimasi menggunakan Hiperparameter Tuning untuk mendapatkan kombinasi parameter terbaik. Berikut Gambar 6 merupakan hasil klasifikasi algoritma XGBoost dengan optimasi *Hiperparameter Tuning* pada variabel UsedAgain.


Hasil Algoritma XGBoost Best Parameters untuk Variabel UsedAgain:				
learning_rate	max_depth	n_estimators	subsample	
0.1	5	200	0.8	

Gambar 6. Hasil Klasifikasi XGBoost dengan Optimasi Teknik Hyperparameter Tuning

Berdasarkan temuan dari *GridSearchCV*, parameter yang paling sesuai untuk algoritma XGBoost pada variabel *UsedAgain* adalah *learning_rate* = 0.1, *max_depth* = 5, *n_estimators* = 200, dan *subsample* = 0.8. Angka *learning rate* 0.1 menjadikan proses pembelajaran lebih terjamin, kedalaman pohon 5 menjaga keseimbangan antara kompleksitas dan kemampuan generalisasi, jumlah pohon 200 meningkatkan tingkat akurasi, dan *subsample* 0.8 membantu menghindari *overfitting*. Kombinasi ini menunjukkan bahwa model XGBoost mampu menghasilkan prediksi yang tepat serta tetap kuat saat dihadapkan dengan data baru

3.5 Hasil Pengujian

Hasil pengujian penerapan algoritma *Extreme Gradient Boosting* (XGBoost) menggunakan optimasi teknik *hyperparameter tuning* pada variabel target *UsedAgain* digambarkan melalui *confusion matrix*, yang menunjukkan kinerja *classification modeling* berdasarkan prediksi hasil yang benar dan salah pada masing-masing kategori kelas. *Confusion matrix* menjadi alat evaluasi penting dalam mengukur sejauh mana model mampu membedakan antara kelas positif (mahasiswa yang akan menggunakan kembali asisten AI) dan kelas negatif (mahasiswa yang tidak akan menggunakannya kembali). Hasil analisis ditampilkan pada Gambar 7, yang memperlihatkan distribusi prediksi terhadap data uji setelah model mencapai konfigurasi parameter optimal.



Gambar 7. Hasil Analisis Penerapan Algoritma XGBoost

Berdasarkan hasil analisis dengan *confusion matrix*, model XGBoost menunjukkan kinerja luar biasa dalam membedakan kategori *UsedAgain*. Dari keseluruhan data pengujian, sebanyak 1.312 data

dari kategori FALSE dan 553 data dari kategori TRUE berhasil diidentifikasi dengan tepat, sementara hanya ada 82 kesalahan dalam kategori FALSE dan 53 kesalahan dalam kategori TRUE. Ini menunjukkan bahwa model mempunyai tingkat kesalahan yang cukup rendah, serta mampu mendeteksi kedua kategori dengan seimbang. Berdasarkan hal tersebut, bisa disimpulkan bahwa model XGBoost yang diimplementasikan pada penelitian ini dapat memberikan prediksi yang tepat dan terpercaya dalam mengklasifikasikan variabel *UsedAgain*.

3.6. Evaluasi

Pada tahap evaluasi, dilakukan evaluasi terhadap *accuracy*, *precision*, *recall* dan *f1-score*. Akurasi menilai seberapa besar proporsi prediksi yang tepat oleh model. Presisi mengukur keakuratan prediksi positif dari model, dengan penekanan pada pengurangan false positive, sangat krusial dalam situasi di mana kesalahan positif dapat berdampak buruk. *Recall* mengevaluasi seberapa baik model dalam mendeteksi semua data positif yang sebenarnya, sehingga mengurangi false negative. *F1-Score* menyediakan satu metrik yang menyeimbangkan kedua aspek tersebut. Berikut hasil evaluasi penerapan algoritma XGBoost pada penelitian ini.

Hasil Evaluasi Model XGBoost (Best Params):				
Accuracy : 0.9325				
Precision: 0.8709				
Recall : 0.9125				
F1-score : 0.8912				
Classification Report:				
	precision	recall	f1-score	support
FALSE	0.96	0.94	0.95	1394
TRUE	0.87	0.91	0.89	606
accuracy			0.93	2000
macro avg	0.92	0.93	0.92	2000
weighted avg	0.93	0.93	0.93	2000

Gambar 8. Evaluasi Hasil Klasifikasi XGBoost

Berdasarkan hasil penilaian, model XGBoost dengan pengaturan terbaik berhasil mencapai tingkat akurasi 93,25%, dengan precision 87,09%, recall 91,25%, dan F1-score 89,12% untuk kategori positif (*UsedAgain* = TRUE). Laporan klasifikasi menunjukkan bahwa model ini memiliki kinerja yang seimbang di kedua kategori, dengan kategori FALSE mendapatkan precision 0,96 dan recall 0,94, sedangkan kategori TRUE memperoleh precision 0,87 dan recall 0,91. Nilai rata-rata makro dan rata-rata berbobot masing-masing sebesar 0,92 hingga 0,93 menunjukkan bahwa model tidak hanya akurat secara keseluruhan, tetapi juga mampu membedakan kedua kategori dengan konsisten. Secara keseluruhan, kombinasi parameter yang optimal memungkinkan model untuk memberikan performa prediksi yang optimal dan kemampuan generalisasi

yang baik dalam memperkirakan variabel UsedAgain.

Hasil ini menunjukkan bahwa algoritma XGBoost mampu menangkap pola-pola kompleks yang terdapat dalam data perilaku mahasiswa ketika berinteraksi dengan asisten AI. Nilai *precision* dan *recall* yang tinggi diartikan bahwa model memiliki keseimbangan antara ketepatan prediksi terhadap kelas positif serta kemampuan mendeteksi mahasiswa yang benar-benar cenderung menggunakan kembali asisten AI. Hal ini menandakan bahwa model tidak hanya akurat, tetapi juga reliabel dalam konteks penerapan nyata pada data pendidikan yang bersifat dinamis

4. Kesimpulan

Penelitian ini menunjukkan bahwa algoritma Extreme Gradient Boosting (XGBoost), yang telah dioptimalkan melalui tuning hyperparameter, dapat mengklasifikasikan variabel UsedAgain dengan tingkat akurasi 93,25%, precision 87,09%, recall 91,25%, dan F1-score 89,12%. Model yang dihasilkan menunjukkan distribusi prediksi yang seimbang dan tingkat kesalahan yang rendah, sehingga dapat disimpulkan bahwa XGBoost efektif dalam menganalisis pola interaksi mahasiswa dengan asisten AI dan berpotensi mendukung pengambilan keputusan berbasis data di sektor pendidikan. Penelitian ini memiliki keterbatasan dataset yang bersifat sintetis dan tidak berasal dari data mahasiswa yang sebenarnya, sehingga pola perilaku yang dimodelkan mungkin belum sepenuhnya mencerminkan dinamika penggunaan asisten AI di dunia nyata, sehingga memengaruhi kemampuan generalisasi model, karena hasil prediksi yang diperoleh mungkin tidak dapat diterapkan secara langsung pada populasi mahasiswa di dunia nyata tanpa adanya pengujian validasi tambahan dengan menggunakan data empiris.

Untuk penelitian yang akan datang, disarankan untuk menggunakan dataset nyata dari lembaga pendidikan agar pola perilaku yang dihasilkan lebih representatif, menambah variasi variabel yang dapat memengaruhi penggunaan kembali asisten AI, membandingkan kinerja XGBoost dengan algoritma lain seperti Random Forest atau LightGBM, serta mengintegrasikan pendekatan explainable AI (XAI) untuk memberikan pemahaman yang lebih mendalam tentang faktor-faktor yang memengaruhi keputusan mahasiswa dalam memanfaatkan asisten AI.

Daftar Rujukan

- [1] Darmawati and Nurhafizah, "Mengintegrasikan Kecerdasan Buatan dalam Pendidikan Tinggi: Kajian Literatur Tentang Peran AI dalam Pembelajaran Mahasiswa," *Naafi: Jurnal Ilmiah Mahasiswa*, vol. 1, no. 4, pp. 93–102, 2024, doi: 10.62387/naafijurnalilmiahmahasiswa.v1i1.84.
- [2] Mochammad Fauzi, Mustari Bisri, Rafli Fadillah Agustio, Riyan Pratama Mulia, and Ines Heidiani Ikasari, "Pemanfaatan Kecerdasan Buatan (AI) Dalam Lingkup Mahasiswa Melaksanakan Pembelajaran," *LOGIC: Jurnal Ilmu Komputer dan Pendidikan*, vol. 3, no. 1, pp. 99–105, 2024, [Online]. Available: <https://journal.mediapublikasi.id/index.php/logic/article/view/4935>
- [3] A. Sri Sugiarto, I Gusti Made Sulindra, "Emanfaatan Teknologi Artificial Intelligence Dalam Efektivitas Pembelajaran Mahasiswa Universitas Samawa," *Jurnal Kependidikan*, vol. 7, no. 2, pp. 19–27, 2022, [Online]. Available: <http://ejournalppmunsa.ac.id/index.php/kependidikan/article/view/1676>
- [4] C. Song, S. Y. Shin, and K. S. Shin, "Implementing the Dynamic Feedback-Driven Learning Optimization Framework: A Machine Learning Approach to Personalize Educational Pathways," *Applied Sciences (Switzerland)*, vol. 14, no. 2, 2024, doi: 10.3390/app14020916.
- [5] A. Salsabilla, A. Farqi, and D. Ridwandono, "Peran Kepercayaan dalam Kesadaran, Penerimaan, dan Adopsi Teknologi AI di Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional 'Veteran' Jawa Timur The Role of Trust in Awareness, Acceptance, and Adoption of AI," vol. 5, no. 4, pp. 1175–1191, 2025.
- [6] T. Tamtomo, "Persepsi Pemelajaran Bahasa Asing Terhadap Penggunaan Aplikasi AI ChatGPT," *Jurnal KIBASP (Kajian Bahasa, Sastra dan Pengajaran)*, vol. 8, pp. 112–133, 2024, [Online]. Available: <https://doi.org/10.31539/kibasp.v8i1.11162>
- [7] S. Hadid, U. Ramadhani, S. Dian Suari, and A. G. Eka Putri, "Analisis Dampak Penggunaan Chatbot Ai Dalam Pembelajaran Di Kalangan Mahasiswa PGSD Universitas Jambi," *Jurnal Pendidikan Terapan*, vol. 02, no. September, pp. 160–166, 2024, doi: 10.61255/jupiter.v2i3.461.
- [8] M. Dava Maulana, A. Id Hadiana, and F. Rakhmat Umbara, "Algoritma Xgboost Untuk Klasifikasi Kualitas Air Minum," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 5, pp. 3251–3256, 2024, doi: 10.36040/jati.v7i5.7308.
- [9] T. A. S. Yusri, D. Rudhistiar, and A. P. Ratnasari, "Klasifikasi Varietas Kacang Menggunakan Xgboost Dengan Penyesuaian Class Weighting," *Jurnal Mnemonic*, vol. 8, no. 1, pp. 115–122, 2025, doi: 10.36040/mnemonic.v8i1.12788.
- [10] M. Rizky Mubarak, R. Herteno, I. Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lambung Mangkurat Jalan Ahmad Yani Km, and K. Selatan, "Hyper-Parameter Tuning Pada Xgboost Untuk Prediksi Keberlangsungan Hidup Pasien Gagal Jantung," *Klik - Kumpulan Jurnal Ilmu Komputer*, vol. 9, no. 2, pp. 391–401, 2022, [Online]. Available: <http://klik.ulm.ac.id/index.php/klik/article/view/484>
- [11] H. Wijaya, D. P. Hostiadi, and E. Triandini, "Optimization XGBoost Algorithm Using Parameter Tuning in Retail Sales Prediction," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 13, no. 3, pp. 769–786, 2024, doi: 10.23887/janapati.v13i3.82214.
- [12] F. Tricahyo and R. Zulfiningrum, "Human-Machine Communication Dalam Interaksi Penggunaan AI," *Jurnal Professional*, vol. 12, no. 1, pp. 83–92, 2025.

- [13] D. Lusiyanthi, S. Musdalifah, A. Sahari, and I. Al Fajri, "Evaluasi Kinerja Algoritma Machine learning pada Dataset Skala Besar," *MathVision : Jurnal Matematika*, vol. 7, no. 1, pp. 84–92, 2025, doi: 10.55719/mv.v7i1.1661.
- [14] Ferry Andika Eminarni, Inayah Inayah, Hikmah Maulidah, and Ngurah Ayu Nyoman Murniati, "Perencanaan Berbasis Data Sebagai Strategi untuk Meningkatkan Kualitas Pendidikan pada Satuan Pendidikan," *Janacitta*, vol. 8, no. 1, pp. 224–231, 2025, doi: 10.35473/janacitta.v8i1.3646.