

Knowledge Discovery of AI Usage Dependency Patterns in Learning Activities Using Random Forest, XGBoost, Logistic Regression with SHAP-Based Interpretation

Fidela Tertia Alfino ^{1*}, Puti Chalisa Wardhana ^{2*}, A. Salwa Aurelya Putri ^{3*}, Athiyyah Nuha Rotifa ^{4*},
Ken Ditha Tania ^{5*}, Ahmad Rifai ^{6*}, Dedy Kurniawan ^{7*}

* Sistem Informasi, Universitas Sriwijaya

fidelaalfino2006@gmail.com ¹, putichalisa07@gmail.com ², asalwaaurelyaputri@gmail.com ³, athiyyah2201@gmail.com ⁴

Article Info

Article history:

Received 2026-04-10

Revised 2026-05-04

Accepted 2026-05-25

Keyword:

AI dependency,
Knowledge Discovery,
Machine Learning,
SHAP,
XGBoost.

ABSTRACT

The increasing use of Artificial Intelligence (AI) in education has influenced various learning activities. However, excessive AI usage has the potential to create dependency patterns that may affect students' learning independence and critical thinking abilities. This study aims to analyze patterns of AI usage dependency in learning activities using a machine learning approach and to interpret the factors influencing such dependency. The analysis was conducted using a publicly available dataset representing usage intensity, session duration, AI assistance level, repeated usage behavior, and students' academic characteristics. The research stages consisted of data preprocessing, categorical variable encoding, feature engineering, the construction of the Knowledge Dependency Level variable, class imbalance handling using SMOTE, and model evaluation using Stratified 5-Fold Cross Validation. The dataset was divided into 80% training data and 20% testing data, then modeled using Logistic Regression, Random Forest, and XGBoost. The results showed that XGBoost achieved the best performance with an accuracy of 0.6845, precision of 0.7288, recall of 0.6845, F1-score of 0.7028, and an AUC value of 0.860, indicating better discrimination capability compared to Random Forest and Logistic Regression. To support the knowledge discovery process, an interpretative analysis using SHAP was conducted to identify the contribution of each feature to the classification results. The interpretation revealed that SatisfactionRating was the most dominant feature influencing the prediction of AI usage dependency levels, followed by FinalOutcome, while academic factors such as StudentLevel and Discipline contributed relatively less. These findings transform previously implicit AI usage behavior patterns into explicit knowledge.



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

I. PENDAHULUAN

Kemajuan teknologi informasi dan komunikasi turut mendorong perkembangan pesat pada bidang *Artificial Intelligence* (AI). AI merupakan cabang ilmu komputer yang dikembangkan untuk memungkinkan komputer melakukan tugas sama baiknya dengan yang dikerjakan oleh manusia [1]. Pemanfaatan teknologi AI dalam beberapa tahun terakhir telah berkembang dan diterapkan di berbagai bidang kehidupan, termasuk pada sektor pendidikan. Pemanfaatan AI dalam sektor pendidikan berkontribusi dalam meningkatkan

efisiensi dan efektivitas proses pembelajaran serta mempermudah akses terhadap kegiatan belajar [2]. Penelitian yang dilakukan oleh Techasermwattanakul & Suwannathachote (2025) melakukan *review* terhadap 18 artikel tentang penggunaan *generative AI* dalam pendidikan, seperti ChatGPT sebagai *teaching assistant*, *feedback generator*, dan alat bantu lain. Hasilnya menunjukkan AI digunakan untuk mendukung pembelajaran, menciptakan/memperbaiki media pembelajaran, serta menilai dan memberi umpan balik pada siswa [3].

Meskipun AI mampu memberikan kemudahan dalam mendukung proses pembelajaran, penggunaan yang berlebihan berpotensi menurunkan kemampuan berpikir kritis mahasiswa. Ketika AI mengambil peran dalam proses berpikir, mahasiswa dapat kehilangan kesempatan untuk mengembangkan kemampuan pemecahan masalah secara mandiri [4]. Fenomena ini sejalan dengan konsep *cognitive offloading*, yaitu kecenderungan mahasiswa memanfaatkan teknologi seperti *Generative Artificial Intelligence* (GAI) untuk meringankan beban kognitif, sehingga proses pengolahan informasi menjadi lebih instan namun berisiko mengurangi keterlibatan kognitif, khususnya pada *working memory* [5]. Sebagai contoh, generasi digital saat ini cenderung lebih bergantung pada AI dibandingkan menggunakan buku sebagai sumber utama informasi [6].

Berbagai penelitian menunjukkan bahwa penggunaan *generative AI* seperti ChatGPT dalam pembelajaran berpotensi menimbulkan ketergantungan berlebihan yang dapat menurunkan kemampuan analisis, kreativitas, serta meningkatkan risiko praktik akademik tidak etis seperti plagiarisme, tentunya memengaruhi proses kognitif dan perilaku belajar mahasiswa [7]. Studi di pendidikan tinggi Zimbabwe juga mengungkapkan bahwa mahasiswa yang memiliki pola ketergantungan terhadap AI generatif dapat mengalami penurunan pada capaian akademik masing-masing individu [8]. Studi lain yang melibatkan 72 siswa dalam survei mengenai persepsi dan preferensi penggunaan AI pada siswa SMA RUSHD menunjukkan bahwa sebanyak 95,8% responden telah memanfaatkan AI dalam aktivitas pembelajaran. Namun, temuan tersebut juga mengungkap adanya kekhawatiran bahwa ketergantungan terhadap AI dapat menurunkan kemampuan berpikir kritis serta pemahaman terhadap informasi yang tidak selalu dapat diandalkan kebenarannya [9]. Penelitian yang melibatkan 107 responden dari kalangan Generasi Z juga menunjukkan bahwa mayoritas responden menggunakan AI secara rutin dan merasa mulai bergantung dengan penggunaan AI [10]. Pada tingkat pendidikan universitas menemukan bukti empiris yang menunjukkan adanya hubungan antara frekuensi penggunaan AI yang tinggi dengan dampak akademik yang dapat merugikan mahasiswa, seperti penurunan kinerja akademik dan kemampuan kognitif, serta berbagai dampak negatif lainnya terhadap hasil belajar [11].

Penelitian mengenai dampak penggunaan *generative AI* terhadap efektivitas pembelajaran di pendidikan tinggi Indonesia telah dilakukan dengan membandingkan beberapa algoritma, hasilnya menunjukkan bahwa algoritma *Random Forest* menghasilkan kinerja terbaik dengan akurasi 87% dalam menganalisis *feature importance* yang paling berpengaruh dalam efektivitas pembelajaran [12]. Temuan ini juga didukung oleh penelitian lain yang menunjukkan bahwa *Random Forest* mampu menangani pola data yang kompleks dan berdimensi tinggi serta menghasilkan performa klasifikasi yang baik berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score* [13],[14],[15]. Studi pada sektor *e-commerce* menunjukkan bahwa *Random Forest* mampu

mengidentifikasi faktor perilaku pelanggan secara akurat, terutama ketika dikombinasikan dengan pendekatan interpretabilitas SHAP untuk mengungkap variabel yang berkontribusi terhadap keputusan model. [16].

Selain *Random Forest*, algoritma *XGBoost* telah digunakan dalam penelitian yang mendeteksi kecenderungan adiksi internet dan media sosial, menunjukkan bagaimana algoritma ini dapat dipakai dalam penelitian perilaku berbasis data [17]. Dalam bidang pendidikan, *XGBoost* terbukti mampu meningkatkan performa klasifikasi, misalnya pada klasifikasi gaya belajar siswa SMP dengan akurasi hingga 84% [18]. Selain itu, pada berbagai bidang seperti kesehatan dan energi, *XGBoost* menunjukkan performa yang kompetitif dalam tugas klasifikasi dan prediksi, serta dapat diintegrasikan dengan SHAP untuk mengidentifikasi fitur dominan yang memengaruhi hasil model secara lebih transparan [19],[20],[21].

Logistic Regression juga digunakan sebagai model *baseline* karena memiliki struktur yang lebih sederhana dan mudah diinterpretasikan melalui hubungan linear antarvariabel. Penelitian menunjukkan bahwa *Logistic Regression* dipilih sebagai *baseline* karena mampu memberikan interpretasi melalui *odds ratio* dan pada kasus prediksi kekambuhan kanker tiroid justru memperoleh akurasi tertinggi sebesar 83%, sedikit lebih baik dibandingkan *Random Forest* dan *XGBoost* yang masing-masing sebesar 82% [22]. Penelitian lain yang menggunakan SHAP juga menegaskan bahwa *Logistic Regression* merupakan *baseline* yang andal dalam analisis perilaku, dengan akurasi awal sebesar 80% sebelum ditingkatkan melalui *ensemble* dan optimasi *Bayesian* menjadi 84%, serta diperkuat dengan interpretasi SHAP [23]. Temuan tersebut menunjukkan bahwa *Logistic Regression* tetap relevan sebagai pembanding dasar sebelum menggunakan model yang lebih kompleks.

Penelitian ini memiliki keterkaitan dengan penelitian terdahulu yang membahas penerapan *machine learning*, *data mining*, dan *knowledge discovery* dalam bidang pendidikan. Penelitian lain yang relevan dengan judul, "*Utilizing Random Forest and XGBoost Data Mining Algorithms for Anticipating Students' Academic Performance*", penelitian ini menerapkan *Random Forest* dan *XGBoost* untuk memprediksi performa akademik siswa berdasarkan data perilaku dan akademik [24]. Meskipun menggunakan algoritma yang sama, penelitian tersebut lebih menekankan pada prediksi prestasi akademik sebagai *output*, sedangkan penelitian pengusul memanfaatkan *Random Forest* dan *XGBoost* untuk mengklasifikasikan pola ketergantungan penggunaan AI berdasarkan variabel interaksi pengguna. Selain itu, penelitian yang berjudul, "*Analisis Kelayakan Penerima Program Keluarga Harapan (PKH) di Kecamatan Pujud Kabupaten Rokan Hilir Menggunakan Logistic Regression*" menjelaskan bahwa *Logistic Regression* merupakan model *baseline* yang umum digunakan dalam klasifikasi data pendidikan karena memiliki interpretabilitas yang baik serta mampu memberikan performa yang stabil dibandingkan model kompleks [25]. Meskipun menggunakan

algoritma yang sama, penelitian tersebut lebih menekankan pada prediksi prestasi akademik sebagai *output*, sedangkan penelitian pengusul memanfaatkan *Random Forest*, *XGBoost*, *Logistic Regression* sebagai *baseline* untuk mengklasifikasikan pola ketergantungan penggunaan AI berdasarkan variabel interaksi pengguna.

Kemudian penelitian yang berjudul, “*Optimisation of Knowledge Management (KM) with Machine Learning (ML) Enabled*” menjelaskan bahwa algoritma *machine learning* mampu mengidentifikasi pola tersembunyi dari data berskala besar [26]. Selain itu, pada Penelitian dengan judul “*Student Retention Using Educational Data Mining and Predictive Analytics: A Systematic Literature Review*” menjelaskan bahwa penerapan *data mining* dalam sistem berbasis AI memungkinkan transformasi data operasional menjadi *insight* strategis melalui proses eksplorasi dan ekstraksi pola [27]. Selanjutnya penelitian yang berjudul, “*Educational data mining*” menjelaskan bahwa analisis data interaksi siswa dalam sistem pembelajaran digital memungkinkan pengambilan pola perilaku belajar menggunakan teknik klasifikasi, *clustering*, dan *association rule mining* [28].

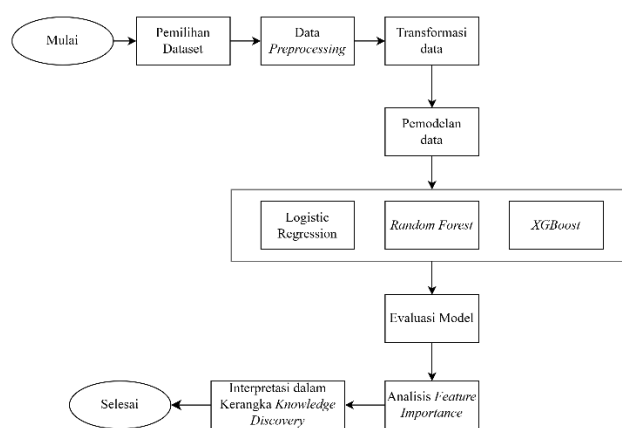
Penelitian yang menerapkan *Random Forest* dan *XGBoost* dalam bidang pendidikan masih didominasi oleh fokus pada prediksi hasil belajar, *dropout*, atau performa akademik mahasiswa. Berdasarkan ulasan singkat dari literatur penelitian sebelumnya memberikan peluang baru penelitian, yang difokuskan untuk menganalisis pola ketergantungan penggunaan AI dalam aktivitas pembelajaran. Selain itu, penelitian ini menambahkan *Logistic Regression* sebagai *baseline* sederhana agar perbandingan kinerja *Random Forest* dan *XGBoost* menjadi lebih objektif. Penelitian ini penting untuk menganalisis faktor dominan yang berasosiasi dengan terbentuknya ketergantungan penggunaan AI. Novelty penelitian ini terletak pada perbandingan, *Random Forest*, *XGBoost*, dan *Logistic Regression* kemudian hasil akurasi model terbaik diinterpretasikan menggunakan SHAP melalui pendekatan *knowledge discovery*.

Penelitian ini menerapkan tahapan analisis data yang meliputi prapemrosesan, analisis korelasi antar fitur menggunakan *correlation heatmap*, penanganan ketidakseimbangan kelas menggunakan SMOTE, serta evaluasi model melalui *stratified cross-validation*, *confusion matrix*, dan *ROC curve* untuk memastikan stabilitas performa klasifikasi. Untuk meminimalkan *data leakage*, pemodelan dilakukan tanpa menggunakan variabel pembentuk kategori target sebagai fitur prediksi. Selanjutnya, model *Random Forest*, *XGBoost*, dan *Logistic Regression* dibandingkan untuk mengidentifikasi model terbaik, kemudian hasil klasifikasi diinterpretasikan menggunakan SHAP untuk menjelaskan kontribusi variabel prediktor independen terhadap keputusan model [21]. Pendekatan ini diarahkan untuk mendukung *knowledge discovery* melalui identifikasi pola perilaku penggunaan AI yang sebelumnya bersifat implisit [29]. Secara lebih rinci, tujuan penelitian ini adalah untuk: (1) mengklasifikasikan tingkat ketergantungan penggunaan AI dalam aktivitas pembelajaran yang dibentuk

berdasarkan pola interaksi pengguna, (2) membandingkan kinerja *Random Forest*, *XGBoost*, dan *Logistic Regression* dalam mengidentifikasi pola ketergantungan tersebut, (3) menganalisis faktor-faktor dominan dari variabel prediktor independen yang berasosiasi dengan tingkat ketergantungan penggunaan AI, serta (4) mengeksplorasi interpretasi model menggunakan SHAP untuk mendukung pemahaman pola perilaku penggunaan AI dalam proses pembelajaran.

II. METODE

Penelitian dilaksanakan melalui tahapan yang tersusun secara berurutan dari tahap pemahaman *dataset* hingga interpretasi hasil pemodelan dalam kerangka *knowledge discovery*. Alur dari penelitian digambarkan melalui *flowchart* seperti pada Gambar 1.



Gambar 1. Tahapan Penelitian

A. Pemahaman Dataset

Dataset yang digunakan dalam penelitian ini berjudul “*AI Assistant Usage in Student Life*”, yang diperoleh dari <https://www.kaggle.com/datasets/ayeshasal89/ai-assistant-usage-in-student-life-synthetic> dan tersedia secara publik melalui platform Kaggle dan berlisensi MIT. *Dataset* ini bersifat *synthetic*, yaitu data yang dihasilkan melalui proses simulasi berdasarkan pola perilaku penggunaan AI dalam aktivitas pembelajaran. *Dataset* terdiri dari 10.000 entri, di mana setiap data merepresentasikan satu sesi interaksi mahasiswa dengan AI. Setiap sesi memuat 11 atribut, yang mencerminkan konteks akademik, karakteristik interaksi, serta evaluasi pengalaman penggunaan AI. Struktur indikator dan deskripsi dataset dapat dilihat pada Tabel 1.

TABEL I
INDIKATOR DATASET “AI ASSISTANT USAGE IN STUDENT LIFE”

No	Atribut	Deskripsi
1	SessionID	Identitas unik setiap sesi interaksi
2	StudentLevel	Tingkat akademik (High School, Undergraduate, Graduate)
3	Discipline	Bidang studi mahasiswa

4	SessionDate	Tanggal sesi penggunaan AI
5	SessionLengthMin	Durasi interaksi (menit)
6	TotalPrompts	Jumlah prompt/pesan dalam satu sesi
7	TaskType	Jenis tugas (Coding, Writing, Research, dll.)
8	AI_AssistanceLevel	Tingkat bantuan AI (skala 1-5)
9	FinalOutcome	Hasil akhir sesi penggunaan
10	UsedAgain	Indikator penggunaan ulang AI
11	SatisfactionRating	Tingkat kepuasan pengguna (skala 1-5)

Dataset ini tidak mengandung nilai kosong (*missing value*) dan telah tersusun dalam format yang siap untuk proses analisis eksploratif maupun pemodelan *machine learning*. Pemeriksaan kualitas data dilakukan dengan mengidentifikasi keberadaan *missing value* menggunakan fungsi *isnull()* dan validasi melalui *data information summary* yang dapat dilihat pada Gambar 2.

```

RangeIndex: 10000 entries, 0 to 9999
Data columns (total 11 columns):
#   Column                Non-Null Count  Dtype
---  -
0   SessionID              10000 non-null   object
1   StudentLevel           10000 non-null   object
2   Discipline              10000 non-null   object
3   SessionDate            10000 non-null   object
4   SessionLengthMin       10000 non-null   float64
5   TotalPrompts           10000 non-null   int64
6   TaskType               10000 non-null   object
7   AI_AssistanceLevel     10000 non-null   int64
8   FinalOutcome           10000 non-null   object
9   UsedAgain              10000 non-null   bool
10  SatisfactionRating     10000 non-null   float64
dtypes: bool(1), float64(2), int64(2), object(6)
memory usage: 791.1+ KB

```

Gambar 2. Pemeriksaan Kualitas Data

Pemeriksaan *missing value* dilakukan dengan menggunakan fungsi *df.isnull().sum()* pada Python untuk menampilkan lokasi serta jumlah nilai kosong pada masing-masing kolom dataset sebagai bagian dari tahap pemeriksaan kualitas data [30]. Hasil pemeriksaan menunjukkan seluruh atribut memiliki jumlah *non-null value* yang sesuai dengan total observasi, sehingga dataset dinyatakan lengkap dan tidak memerlukan proses imputasi data. Distribusi data dirancang untuk memahami pola penggunaan AI, yang mencakup variasi tingkat pendidikan, jenis tugas akademik, intensitas interaksi, persepsi bantuan, serta tingkat kepuasan pengguna. Kombinasi variabel tersebut memungkinkan pembentukan indikator terukur terkait tingkat ketergantungan mahasiswa terhadap AI.

Penggunaan dataset *synthetic* membantu penelitian tetap berjalan tanpa membuka data asli mahasiswa, tetapi kualitasnya tetap bergantung pada pola data sumber. Sebuah

penelitian menjelaskan bahwa model yang dilatih menggunakan data *synthetic* dapat mengalami penurunan performa ketika diterapkan pada data asli sehingga tetap memerlukan validasi pada *private dataset* [31]. Oleh karena itu, hasil klasifikasi dalam penelitian ini tidak digunakan untuk memberi label negatif kepada mahasiswa, melainkan untuk memahami pola ketergantungan penggunaan AI secara lebih bertanggung jawab. Interpretasi hasil juga dibatasi sebagai hubungan asosiatif, bukan kausal. Dengan mempertimbangkan kualitas data, potensi bias, dan aspek etika interpretasi, *dataset* ini tetap memberikan dasar yang memadai untuk menganalisis pola ketergantungan penggunaan AI dalam aktivitas pembelajaran secara lebih terstruktur.

B. Data Preprocessing

Preprocessing pada penelitian ini dilakukan untuk membersihkan data yang tidak berkaitan, sehingga data siap untuk analisis selanjutnya [32]. Menurut riset nasional, teknik penanganan nilai hilang seperti imputasi *mean*, *interpolasi*, dan *KNN Imputer* telah diuji dalam konteks *machine learning* dan terbukti meningkatkan kualitas data sehingga model dapat mempelajari pola dengan lebih akurat tanpa dipengaruhi noise akibat *missing values* [33]. Tahapan ini meliputi:

- 1) *Konversi Tipe Data*: Pada variabel *usedAgain* yang semula bertipe data boolean, dilakukan konversi tipe data menjadi numerik untuk memastikan konsistensi analisis. Konversi ini bertujuan agar variabel dapat diproses dalam tahap normalisasi dan perhitungan skor komposit.
- 2) *Penghapusan Kolom Tidak Relevan*: Kolom yang tidak digunakan dalam proses klasifikasi akan dihapus dari *dataset*. Contohnya, kolom *SessionID* dan *SessionDate* dihilangkan karena merupakan informasi temporal sementara *DependencyScore* merupakan variabel komposit sementara.
- 3) *Encoding Variabel Kategorikal*: Pada variabel yang bertipe object seperti *StudentLevel*, *Discipline*, *TaskType*, dan *FinalOutcome*, dikonversi menjadi numerik unik menggunakan metode *Label Encoding*.
- 4) *Dataset dibagi menjadi dua bagian, yaitu*: Fitur (*y*) sebagai seluruh variabel prediktor yang digunakan sebagai input model. Sementara Target (*X*) sebagai variabel *Knowledge_Dependency_Level*, yaitu hasil kategorisasi tingkat ketergantungan pengetahuan (*Low*, *Medium*, *High*).
- 5) *Pembagian Data Latih dan Data Uji*: *Dataset* dibagi kedalam dua subset menggunakan metode *train-test split* menggunakan proporsi 80:20, di mana 80% data untuk pelatihan dan 20% untuk pengujian. Parameter *random_state = 42* untuk memastikan konsistensi hasil [34]. Selain itu, penelitian ini juga menerapkan *Stratified K-Fold Cross Validation* sebagai teknik resampling dengan membagi data ke dalam beberapa *fold* yang digunakan secara bergantian sebagai data pelatihan dan data validasi untuk memperoleh evaluasi model yang lebih stabil dan objektif [35].

TABEL II
DATA LATIH DAN DATA UJI

Dataset	Split Data	Jumlah
Data Training	80%	8.000
Data Testing	20%	2.000
Total	100%	10.000

C. Transformasi Data

Transformasi data dilakukan untuk membentuk variabel target *Knowledge Dependency Level*, yang menggambarkan tingkat ketergantungan pengguna terhadap AI dalam memperoleh dan memproses pengetahuan. Ketergantungan diukur melalui empat indikator perilaku, yaitu *Session Length*, *Total Prompts*, *AI Assistance Level*, dan *Used Again*. Karena perbedaan skala antar variabel, dilakukan normalisasi menggunakan *Min-Max Scaling* yang mengubah seluruh nilai ke rentang 0–1, sehingga setiap indikator memiliki kontribusi yang seimbang dalam pembentukan skor komposit. Normalisasi dilakukan dengan persamaan (1) berikut.

$$X' = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Nilai X' merepresentasikan hasil normalisasi dari data X_i , sedangkan X_{min} dan X_{max} masing-masing menunjukkan nilai minimum dan maksimum pada suatu fitur [36]. Setelah dinormalisasi, keempat indikator kemudian digabungkan menjadi *Dependency Score* (DS) menggunakan metode *weighted linear aggregation*, yaitu penjumlahan setiap indikator yang telah dinormalisasi dengan mempertimbangkan bobotnya masing-masing [37], sebagaimana ditunjukkan pada Persamaan (2) berikut.

$$DS = \sum_{i=1}^n w_i X'_i \quad (2)$$

Nilai w_i merepresentasikan bobot indikator ke- i , sedangkan X'_i adalah nilai indikator yang telah dinormalisasi menggunakan *Min-Max Scaling* dan n adalah jumlah indikator yang digunakan dalam pembentukan skor komposit, yang pada penelitian ini terdiri dari empat indikator, yaitu *Session Length*, *Total Prompts*, *AI Assistance Level*, dan *Used Again*.

Perhitungan skor dilakukan menggunakan metode *weighted linear aggregation*, yang selanjutnya menghasilkan nilai *Dependency Score* untuk dikategorikan menjadi tiga tingkat menggunakan metode *fixed interval* pada rentang skala 0–1 untuk memudahkan interpretasi hasil [38], sebagaimana ditunjukkan pada Persamaan (3) berikut.

$$Interval = \frac{Nilai\ Maksimum - Nilai\ Minimum}{Jumlah\ Kategori} \quad (3)$$

Berdasarkan perhitungan tersebut, klasifikasi tingkat ketergantungan ditetapkan sebagaimana yang disajikan pada Tabel 3.

TABEL III
INTERVAL SKOR KLASIFIKASI TINGKAT KETERGANTUNGAN AI

No	Rentang Skor Indeks	Kategori
1	$\leq 0,33$	<i>Low Dependency</i>
2	0,34–0,66	<i>Medium Dependency</i>
3	$> 0,66$	<i>High Dependency</i>

Pendekatan tiga kategori (*Low*, *Medium*, *High*) digunakan karena tingkat ketergantungan tidak bersifat biner, melainkan menunjukkan gradasi perilaku dari rendah hingga tinggi. Pembagian interval 0–0,33 (*Low*), 0,34–0,66 (*Medium*), dan $>0,66$ (*High*) juga sejalan dengan berbagai penelitian yang mengelompokkan indeks atau skor ke dalam tiga tingkat untuk mempermudah interpretasi dan analisis perilaku, seperti pada pengukuran indeks kerentanan sosial dan analisis korelasi yang membedakan kategori rendah, sedang, dan tinggi berdasarkan rentang nilai tertentu [39],[40]. Dengan demikian, kategorisasi ini tidak hanya bersifat matematis, tetapi juga mempertimbangkan representasi konseptual bahwa ketergantungan pengguna terhadap AI berkembang secara bertahap, dari penggunaan terbatas, penggunaan moderat, hingga penggunaan intensif.

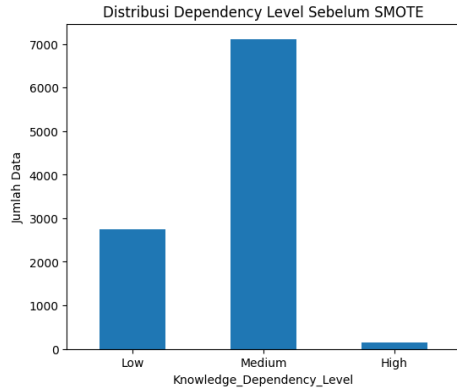
Pendekatan ini menjadikan data perilaku yang sebelumnya bersifat implisit diubah menjadi variabel klasifikasi yang eksplisit dan dapat digunakan dalam pemodelan *supervised learning*.

Dalam penelitian ini juga diperhatikan potensi data *leakage*, yaitu kondisi ketika informasi yang seharusnya tidak tersedia saat pelatihan model secara tidak sengaja ikut digunakan, seperti data uji atau variabel yang memiliki hubungan langsung dengan target. Hal ini dapat menyebabkan model terlihat memiliki akurasi tinggi, namun sebenarnya tidak mampu melakukan prediksi secara akurat pada data baru [41]. Untuk menghindari hal tersebut, penelitian ini menerapkan *machine learning pipeline* yang memastikan setiap tahapan, mulai dari *preprocessing* hingga pemodelan, dilakukan secara terstruktur dan konsisten. Pendekatan ini membantu meminimalkan kebocoran data serta menjaga validitas hasil model [42].

Dalam penelitian ini, variabel target *Knowledge Dependency Level* dibentuk dari indikator perilaku penggunaan AI, yaitu *SessionLengthMin*, *TotalPrompts*, *AI_AssistanceLevel*, dan *UsedAgain*. Oleh karena itu, dalam proses pemodelan, perhatian khusus diberikan agar model tidak secara langsung hanya mereplikasi hubungan matematis dari variabel-variabel tersebut, melainkan mempelajari pola klasifikasi secara keseluruhan. Sebagai upaya meminimalkan risiko tersebut, variabel lain yang bersifat eksternal seperti *StudentLevel*, *Discipline*, *TaskType*, *FinalOutcome*, dan *SatisfactionRating* tetap dipertahankan sebagai fitur tambahan, sehingga model tidak hanya bergantung pada indikator pembentuk target, tetapi juga mempertimbangkan karakteristik pengguna secara lebih luas.


Untuk mengatasi permasalahan ketidakseimbangan kelas (*class imbalance*), penelitian ini menerapkan teknik *Synthetic Minority Over-sampling Technique* (SMOTE).

SMOTE merupakan metode *oversampling* yang bekerja dengan menghasilkan data sintesis pada kelas minoritas berdasarkan kedekatan antar data, sehingga distribusi kelas menjadi lebih seimbang tanpa hanya menduplikasi data yang sudah ada [43]. Distribusi kelas sebelum penerapan SMOTE ditunjukkan pada Gambar 3.



Gambar 3. Dependency Level Sebelum SMOTE

Adanya ketidakseimbangan yang cukup signifikan pada kelas *Medium Dependency* yang mendominasi jumlah data, sementara kelas *High Dependency* yang memiliki jumlah yang sangat kecil. Kondisi ini berpotensi menyebabkan model cenderung bias terhadap kelas mayoritas dan kurang optimal dalam mengenali pola pada kelas minoritas. Selain itu, untuk memahami hubungan antar fitur, dilakukan analisis menggunakan *correlation heatmap* seperti yang ditunjukkan pada Gambar 4.



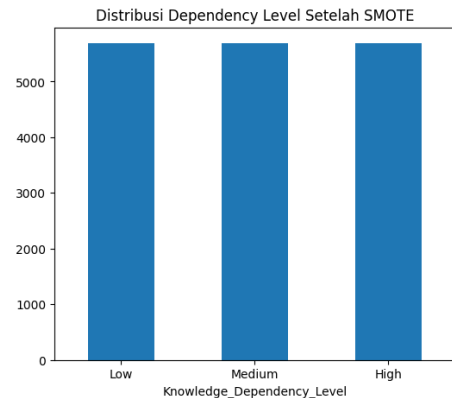
Gambar 4. Correlation Heatmap

Heatmap merupakan teknik visualisasi dua dimensi yang merepresentasikan kekuatan hubungan antar variabel melalui perbedaan warna. Nilai korelasi positif menunjukkan bahwa peningkatan suatu fitur diikuti dengan peningkatan nilai variabel lain, sedangkan korelasi negatif menunjukkan hubungan yang berlawanan arah [44].

Berdasarkan hasil visualisasi, sebagian besar fitur memiliki nilai korelasi yang rendah terhadap variabel

Knowledge Dependency Level, yang menunjukkan tidak adanya hubungan linier yang kuat. Namun, variabel *SatisfactionRating* menunjukkan korelasi sedang terhadap target, sehingga dapat dianggap memiliki kontribusi dalam proses klasifikasi. Analisis ini membantu memastikan tidak terjadi multikolinearitas yang tinggi antar fitur sekaligus memberikan gambaran awal mengenai keterkaitan variabel dalam *dataset*.

Setelah penerapan SMOTE pada data latih, distribusi kelas menjadi seimbang seperti yang ditunjukkan pada Gambar 5.



Gambar 5. Dependency Level Setelah SMOTE

Setiap kategori yakni *Low*, *Medium*, dan *High Dependency*, memiliki jumlah data yang sama. Dengan distribusi yang lebih seimbang ini, model diharapkan dapat belajar secara lebih optimal pada seluruh kelas, khususnya dalam meningkatkan kemampuan deteksi terhadap kelas minoritas.

III. HASIL DAN PEMBAHASAN

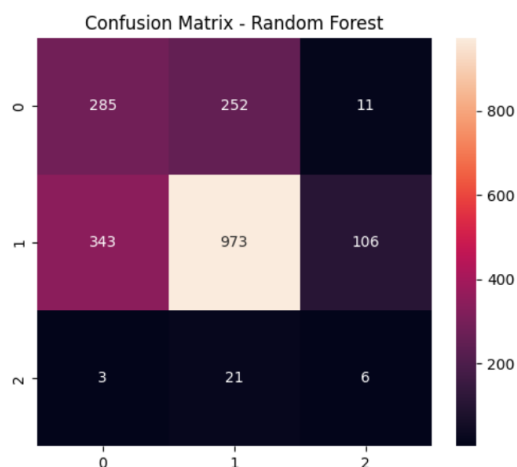
Bagian ini menyajikan hasil pemodelan data menggunakan algoritma *Logistic Regression*, *Random Forest* dan *XGBoost* dengan skema pembagian data 80:20 serta penerapan SMOTE untuk menangani ketidakseimbangan distribusi kelas pada data pelatihan. Kinerja model dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Model dengan performa terbaik selanjutnya dianalisis menggunakan pendekatan interpretabilitas SHAP untuk mengidentifikasi kontribusi setiap variabel terhadap hasil prediksi serta mengungkap pola ketergantungan penggunaan AI dalam aktivitas pembelajaran, sehingga menghasilkan pengetahuan berbasis data yang dapat mendukung pemahaman dan pengambilan keputusan pembelajaran secara lebih terstruktur.

A. Pemodelan Data

Tahap ini dilakukan pemodelan data menggunakan algoritma *Logistic Regression* serta dua algoritma *ensemble learning* berbasis *decision tree*, yaitu *Random Forest* dan *Extreme Gradient Boosting (XGBoost)* untuk memprediksi variabel *Knowledge_Dependency_Level*. Sebelum proses pelatihan model dilakukan, data pelatihan diseimbangkan menggunakan SMOTE untuk mengatasi ketidakseimbangan distribusi kelas. Pemodelan awal dilakukan menggunakan

metode *Stratified K-Fold Cross Validation* dengan konfigurasi jumlah *fold* (k) = 5, *shuffle* = *True* dan *random_state* = 42. Pendekatan ini diterapkan guna menjaga masing-masing *fold* memiliki distribusi kategori yang proporsional serta mengestimasi kesalahan prediksi secara lebih akurat [45]. Validasi ini dilakukan untuk memperoleh nilai rata-rata akurasi dari lima iterasi pelatihan menggunakan *accuracy score*.

1) *Pemodelan Menggunakan Random Forest*: Model *Random Forest* bertujuan membentuk sejumlah pohon keputusan dengan $n_estimators = 200$ dan *random_state* = 42 untuk memastikan replikasi hasil eksperimen. Hasil klasifikasi diperoleh melalui proses *majority voting*, di mana kelas dengan suara terbanyak ditetapkan sebagai prediksi akhir. Pendekatan *ensemble* seperti ini juga diterapkan dalam penelitian klasifikasi penyakit jantung dimana *Random Forest* menunjukkan kinerja yang kompetitif dan konsisten ketika digunakan pada data medis dengan berbagai jenis atribut, sehingga mendukung pilihannya untuk tugas klasifikasi perilaku penggunaan AI dalam studi ini [46]. Berdasarkan hasil validasi silang diperoleh rata-rata akurasi sebesar 0.632, sehingga dinyatakan model memiliki kemampuan klasifikasi yang cukup baik pada data latih. Distribusi prediksi model terhadap setiap kelas ditunjukkan pada Gambar 6.



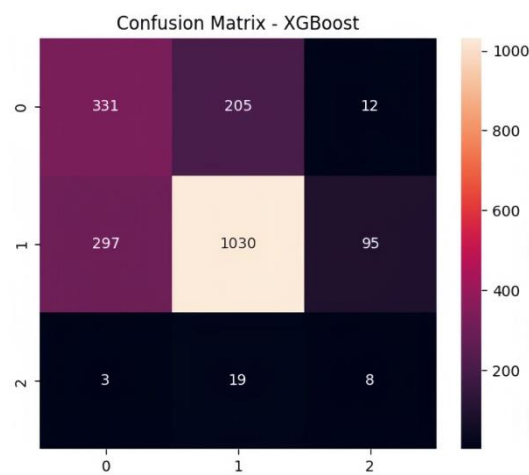
Gambar 6. Confusion Matrix Model Random Forest

Berdasarkan *confusion matrix* diatas, dapat di rincikan bahwa dari 548 data aktual kelas 0 (*Low*), di peroleh 258 data berhasil diidentifikasi secara tepat, sementara 252 data salah diprediksi ke kelas 1 (*Medium*) dan 11 data salah diprediksi ke kelas 2 (*High*). Pada kelas 1 yang mencakup 1.422 data aktual, sebanyak 973 data berhasil diidentifikasi secara tepat dengan 343 data salah diprediksi sebagai kelas 0 dan 106 data salah diprediksi sebagai kelas 2. Sementara itu, dari 30 data di kelas 2, 6 data terklasifikasi secara akurat, sedangkan 21 data salah diprediksi ke kelas 1 dan 3 data salah diprediksi ke kelas 0.

Hasil *confusion matrix* menunjukkan bahwa *Random Forest* masih kesulitan membedakan kelas *Low* dan *Medium*, terlihat dari tingginya kesalahan dari kedua kategori tersebut.

Selain itu, kinerja pada kelas *High* belum optimal karena jumlah data yang terbatas. Temuan ini mengindikasikan bahwa pola ketergantungan penggunaan AI pada antar kategori memiliki pola yang cukup berdekatan, sehingga proses pemisahan antar kelas masih menjadi tantangan bagi model klasifikasi

2) *Pemodelan Menggunakan XGBoost*: Model *Extreme Gradient Boosting (XGBoost)* digunakan sebagai model kedua dalam penelitian ini dengan parameter $n_estimators = 200$, *learning_rate* = 0.1, *max_depth* = 5, *random_state* = 42, dan *eval_metric* = 'mlogloss'. Model ini menggunakan metode *boosting* untuk membangun pohon keputusan secara bertahap guna meminimalkan kesalahan prediksi. Keunggulan *XGBoost* ini ditunjukkan pula dalam studi klasifikasi penyakit gagal jantung, di mana *XGBoost* mampu memberikan nilai prediksi yang kuat dibandingkan metode lainnya [47]. Berdasarkan hasil validasi, didapat rata-rata akurasi sebesar 0,9958, yang secara marginal lebih tinggi dibandingkan dengan performa *Random Forest*. Distribusi hasil prediksi model ditunjukkan pada Gambar 7.



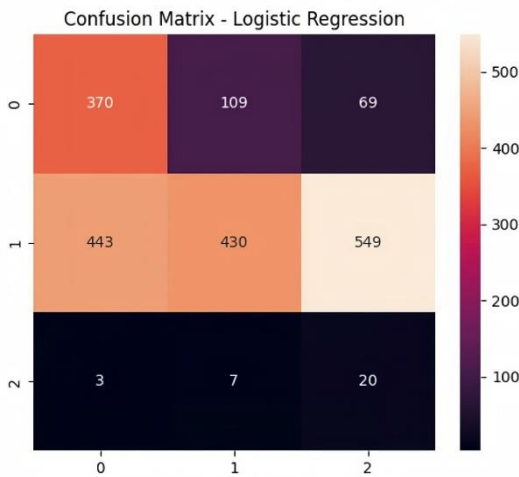
Gambar 7. Confusion Matrix Model XGBoost

Berdasarkan *confusion matrix* diatas dirincikan bahwa dari 548 data aktual kelas 0 (*Low*), di peroleh 331 data berhasil diidentifikasi secara tepat dengan 250 data salah diprediksi ke kelas 1 (*Medium*) dan 12 data salah diprediksi ke kelas 2 (*High*). Pada kelas 1 mencakup 1.422 data dengan 1.030 data diprediksi tepat, sementara 297 data salah diprediksi ke kelas 0 dan 95 data salah diprediksi sebagai kelas 2. Pada kelas 2 (*High*) terdapat 30 data dengan 8 data terklasifikasi secara akurat, sedangkan 19 data salah diklasifikasikan sebagai kelas 1 dan 3 data salah diprediksi ke kelas 0.

Hasil *confusion matrix* menunjukkan bahwa model *XGBoost* memiliki kemampuan klasifikasi yang lebih baik dalam mengenali kategori *Medium* dibandingkan model lainnya, yang terlihat dari jumlah prediksi benar yang lebih tinggi pada kelas tersebut. Namun, model masih kesulitan membedakan kelas *Low* dan *Medium* karena pola yang serupa, serta performa pada kelas *High* terbatas akibat jumlah

data yang lebih sedikit. Secara keseluruhan, hasil ini menunjukkan bahwa *XGBoost* mampu mempelajari pola hubungan antar variabel secara lebih efektif sehingga menghasilkan performa klasifikasi yang lebih stabil pada penelitian ini.

3) *Pemodelan Menggunakan Logistic Regression*: *Logistic Regression* digunakan sebagai model *baseline* untuk membandingkan performa klasifikasi dengan algoritma *ensemble learning* yang digunakan dalam penelitian ini. Model dibangun menggunakan parameter *max_iter* = 1000 dan *random_state* = 42 untuk memastikan proses pelatihan berjalan optimal dan hasil eksperimen dapat direplikasi. Berdasarkan hasil evaluasi diperoleh nilai akurasi sebesar 0,41, yang menunjukkan bahwa *Logistic Regression* memiliki kemampuan klasifikasi yang relatif terbatas. Distribusi prediksi model terhadap setiap kelas ditunjukkan pada Gambar 8.



Gambar 8. Confusion Matrix Model Logistic Regression

Berdasarkan *confusion matrix* diatas, dapat di rincikan bahwa dari 548 data aktual kelas 0 (*Low*), sebanyak 370 data berhasil diklasifikasikan dengan tepat, sedangkan 109 data salah diprediksi ke kelas 1 (*Medium*) dan 69 data lainnya diprediksi ke kelas 2 (*High*). Pada kelas 1 yang mencakup 1.422 data aktual, sebanyak 430 data berhasil diidentifikasi secara benar dengan 443 data salah diprediksi sebagai kelas 0 dan 594 data sebagai kelas 2. Sementara itu, dari 30 data di kelas 2, sebanyak 20 data terklasifikasi secara akurat, sedangkan 7 data salah diprediksi sebagai kelas 1 dan 3 data salah diprediksi ke kelas 0.

Hasil *confusion matrix* menunjukkan bahwa *Logistic Regression* masih kurang optimal dalam mengklasifikasikan kelas *Medium*, ditandai dengan tingginya kesalahan prediksi ke kelas lain. Hal ini mengindikasikan bahwa hubungan antar variabel tidak sepenuhnya linear sehingga model belum mampu memisahkan tiap kategori dengan baik. Meskipun demikian, model masih menunjukkan kemampuan yang cukup baik dalam mengenali kelas *Low* dan *High* dibandingkan kelas *Medium*.

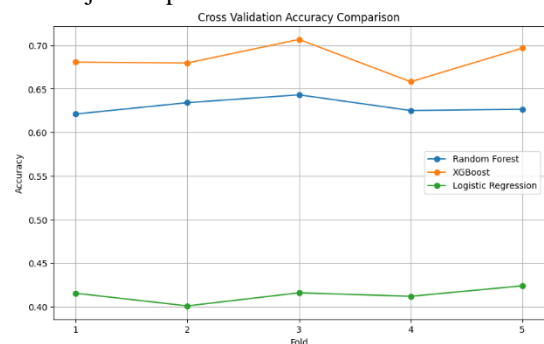
B. Evaluasi Model

Tahap evaluasi model merupakan bagian penting dalam penelitian ini yang bertujuan untuk mengukur kinerja algoritma dalam melakukan klasifikasi *Knowledge Dependency Level*. Pada penelitian ini digunakan tiga algoritma, yaitu *Logistic Regression* sebagai model *baseline*, serta *Random Forest* dan *XGBoost*.

TABEL IV
PERBANDINGAN KINERJA MODEL KLASIFIKASI

Model	Metrik	Nilai
<i>Logistic Regression</i>	<i>Accuracy</i>	0.41
	<i>Precision</i>	0.6847
	<i>Recall</i>	0.41
	<i>F1-Score</i>	0.4603
<i>Random Forest</i>	<i>Accuracy</i>	0.632
	<i>Precision</i>	0.6797
	<i>Recall</i>	0.632
	<i>F1-Score</i>	0.6522
<i>XGBoost</i>	<i>Accuracy</i>	0.6845
	<i>Precision</i>	0.7288
	<i>Recall</i>	0.6845
	<i>F1-Score</i>	0.7028

Berdasarkan hasil evaluasi, *XGBoost* menghasilkan performa terbaik dibandingkan model lainnya pada hampir seluruh metrik evaluasi. Model ini mencapai nilai *accuracy* sebesar 0,6845 dan *F1-score* sebesar 0,7028, yang menunjukkan kemampuan klasifikasi yang lebih baik dibandingkan *Random Forest* maupun *Logistic Regression*. *Random Forest* menunjukkan performa yang cukup stabil dengan *accuracy* sebesar 0,6320, namun masih berada di bawah *XGBoost*. Sementara itu, *Logistic Regression* sebagai model *baseline* memiliki performa paling rendah, yang mengindikasikan bahwa model linear sederhana kurang mampu menangkap pola kompleks dalam data. Untuk memastikan bahwa performa model tidak hanya bergantung pada satu kali pembagian data, dilakukan proses validasi tambahan menggunakan *Stratified 5-Fold Cross Validation* seperti ditunjukkan pada Gambar 9.

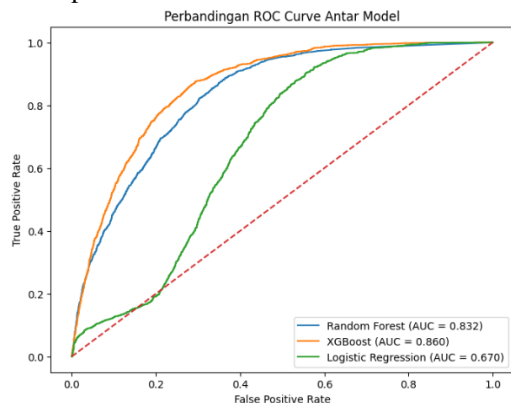


Gambar 9. Akurasi Cross Validation Antar Model

Berdasarkan hasil *Cross Validation*, *XGBoost* memperoleh rata-rata akurasi validasi yang paling tinggi, yaitu sebesar 0,6845 dan menunjukkan kestabilan model yang lebih baik selama proses validasi dibanding model lainnya.

Random Forest juga menunjukkan performa yang cukup konsisten meskipun dengan nilai akurasi yang lebih rendah, yaitu sebesar 0,6320. Sedangkan *Logistic Regression* memiliki performa paling rendah pada seluruh *fold* validasi, yaitu 0,41. Hasil ini memperkuat bahwa pendekatan *ensemble learning*, khususnya *XGBoost*, lebih efektif dalam mempelajari pola hubungan antar variabel pada klasifikasi tingkat ketergantungan penggunaan AI.

Selain menggunakan metrik evaluasi dan *cross validation*, kemampuan model dalam membedakan setiap kelas juga dianalisis menggunakan *ROC Curve* dan nilai *AUC* yang ditunjukkan pada Gambar 10.



Gambar 10. Hasil Evaluasi ROC Curve dan AUC

Berdasarkan hasil pengujian, *XGBoost* memperoleh nilai *AUC* sebesar 0,860, diikuti *Random Forest* sebesar 0,832, dan *Logistic Regression* sebesar 0,670. Nilai *AUC* yang lebih tinggi menunjukkan kemampuan diskriminasi model yang lebih baik dalam membedakan kategori tingkat ketergantungan penggunaan AI. Kurva ROC *XGBoost* yang berada lebih dekat ke sudut kiri atas menunjukkan bahwa model ini memiliki keseimbangan yang lebih baik antara *true positive rate* dan *false positive rate* dibandingkan model lainnya. Sementara itu, *Logistic Regression* menunjukkan kemampuan diskriminasi yang lebih rendah karena kurva ROC cenderung berada lebih dekat dengan garis diagonal, yang menandakan keterbatasan model linear dalam mempelajari pola hubungan yang lebih kompleks pada data.

C. Interpretasi dalam Kerangka Knowledge Discovery

Hasil pemodelan klasifikasi menggunakan algoritma *Logistic Regression*, *Random Forest*, dan *XGBoost* tidak hanya memberikan metrik performa teknis, tetapi juga berfungsi untuk mengekstraksi pengetahuan dari data. Proses *knowledge discovery* dilakukan melalui interpretasi SHAP model klasifikasi dengan performa terbaik. Proses *knowledge discovery* dilakukan melalui interpretasi SHAP pada model dengan kinerja terbaik untuk mengungkap pola tersembunyi dan menghasilkan pemahaman yang lebih bermakna [48]. SHAP sendiri didasarkan pada nilai Shapley dari *game theory*, yang menghitung kontribusi setiap fitur terhadap prediksi dengan membandingkan prediksi aktual dan nilai dasar (*baseline*), sehingga memberikan penjelasan transparan


mengenai pengaruh masing-masing fitur terhadap hasil prediksi [49]. Pendekatan SHAP telah diterapkan dalam berbagai penelitian *machine learning* nasional, termasuk klasifikasi risiko penyakit jantung menggunakan *Random Forest*, yang menunjukkan bahwa metode ini efektif dalam menjelaskan hasil prediksi sekaligus mengidentifikasi fitur yang paling berpengaruh terhadap *output* model [50]. Berdasarkan hasil evaluasi, *XGBoost* menunjukkan kinerja paling optimal dengan akurasi 68,45% serta peningkatan *recall* pada kelas *High Dependency* sebesar 0,27. Berikut adalah interpretasi hasil penelitian dalam kerangka *Knowledge Discovery* berdasarkan model dengan akurasi performa terbaik yaitu algoritma *XGBoost*.

1) *Feature Importance*: Analisis *feature importance* dilakukan untuk mengukur kontribusi setiap variabel terhadap keputusan klasifikasi model *XGBoost* melalui rata-rata nilai absolut SHAP (*mean |SHAP value|*) yang diuraikan per kelas, sebagaimana ditampilkan pada Gambar 7.

SatisfactionRating mendominasi dengan nilai *mean |SHAP|* tertinggi ($\approx 3,2$), di mana segmen *Class 2 (High Dependency)* menyumbang porsi terbesar dibanding kelas lainnya. Hal ini mengindikasikan bahwa kepuasan mahasiswa terhadap pengalaman interaksi AI merupakan penentu utama terbentuknya ketergantungan intensif, pengalaman memuaskan yang berulang secara bertahap memperkuat perilaku penggunaan hingga AI bergeser dari alat bantu menjadi mekanisme utama penyelesaian tugas. *FinalOutcome* berada di posisi kedua ($\approx 0,8$) dengan distribusi kontribusi yang lebih merata antara *Class 0 (Low)* dan *Class 2 (High)*, menunjukkan bahwa hasil akhir sesi relevan dalam membedakan kedua ujung spektrum ketergantungan. Sementara itu, *Discipline* ($\approx 0,62$), *TaskType* ($\approx 0,55$), dan *StudentLevel* ($\approx 0,52$) memperlihatkan kontribusi yang jauh lebih kecil meski tetap didominasi segmen *High Dependency*.


Temuan ini mengungkap bahwa pola ketergantungan terhadap AI lebih banyak dibentuk oleh dimensi afektif-evaluatif penggunaan dibandingkan latar belakang akademik seperti jenjang pendidikan, bidang studi, maupun jenis tugas. Artinya, ketergantungan bukan eksklusif pada kelompok akademik tertentu, melainkan dapat berkembang pada siapa saja yang secara berulang memperoleh pengalaman positif dari interaksi dengan AI.

Pendekatan interpretasi menggunakan SHAP ini sejalan dengan praktik *explainable machine learning* yang diterapkan dalam penelitian [16] pada *Journal of Applied Informatics and Computing*, di mana *XGBoost* digunakan tidak hanya untuk memperoleh performa klasifikasi yang optimal, tetapi juga untuk mengidentifikasi kontribusi masing-masing fitur terhadap hasil prediksi melalui analisis SHAP. Dengan demikian, interpretasi dalam penelitian ini tidak berhenti pada evaluasi akurasi model, melainkan juga menekankan transparansi dan pemahaman terhadap mekanisme internal model.



Gambar 11. Feature Importance XGBoost


2) *SHAP Summary Plot*: Kontribusi setiap fitur terhadap prediksi model dianalisis menggunakan *SHAP summary plot* sebagai interpretasi global. Visualisasi ini menunjukkan distribusi nilai SHAP untuk menggambarkan arah dan besarnya pengaruh fitur terhadap probabilitas kelas tertentu [21]. Nilai SHAP positif menunjukkan peningkatan probabilitas kelas tertentu, sedangkan nilai negatif menunjukkan penurunan probabilitas. Setiap titik merepresentasikan satu observasi data, dengan gradasi warna pada titik mencerminkan nilai asli fitur dan menunjukkan nilai fitur dari rendah (biru) hingga tinggi (merah) [20]. Fitur-fitur pada *summary plot* diurutkan berdasarkan rata-rata nilai absolut SHAP (mean |SHAP|), sehingga variabel yang berada di posisi teratas merupakan faktor yang paling dominan dalam menentukan prediksi. Interpretasi SHAP ini hanya menggunakan variabel prediktor independen untuk menjaga validitas interpretasi dan meminimalkan risiko *data leakage*, sehingga interpretasi berfokus pada faktor yang berasosiasi dengan tingkat *dependency*, bukan pada variabel pembentuk label.



Gambar 12. SHAP Summary Plot Low Dependency


Pada kelas *Low Dependency*, fitur yang paling dominan adalah *SatisfactionRating*. Pada plot terlihat bahwa nilai rendah (biru) pada *SatisfactionRating* cenderung menghasilkan nilai SHAP positif, sedangkan nilai tinggi (merah) lebih banyak berada pada sisi negatif. Hal ini menunjukkan bahwa tingkat kepuasan penggunaan AI yang lebih rendah berasosiasi dengan peningkatan probabilitas model memprediksi kelas *Low Dependency*. Kondisi ini mengindikasikan bahwa penggunaan AI belum menjadi komponen utama dalam proses belajar mahasiswa, sehingga masih bersifat pelengkap dan tidak mendominasi aktivitas kognitif. Fitur *FinalOutcome* juga menunjukkan kontribusi, namun pengaruhnya relatif lebih kecil, meskipun pengaruhnya tidak sebesar *SatisfactionRating*. Sementara itu, fitur lain seperti *TaskType*, *Discipline*, dan *StudentLevel* memiliki distribusi nilai SHAP yang lebih terpusat di sekitar nol, yang menandakan kontribusinya terhadap prediksi kelas

ini cenderung terbatas. Temuan ini sejalan dengan penelitian yang dilakukan di Universitas Riau yang menunjukkan bahwa pemanfaatan AI yang tepat berpengaruh positif terhadap kemandirian belajar mahasiswa, terutama dalam meningkatkan kemampuan mengatur proses belajar, mengambil inisiatif, dan mengelola pembelajaran secara mandiri [51]. Dengan demikian, pada kelas *Low Dependency*, mengindikasikan bahwa rendahnya kepuasan terhadap AI berasosiasi dengan kecenderungan model mengklasifikasikan pengguna pada *Low Dependency*, tanpa menunjukkan keterlibatan AI yang dominan dalam aktivitas belajar.



Gambar 13. SHAP Summary Plot Medium Dependency

Pada kelas *Medium Dependency*, *SatisfactionRating* tetap menjadi fitur paling dominan, diikuti oleh *Discipline*, *FinalOutcome*, *TaskType*, dan *StudentLevel*. Berbeda dengan kelas *Low Dependency*, pada kelas ini nilai tinggi (merah) pada *SatisfactionRating* mulai lebih banyak muncul pada sisi positif nilai SHAP, yang menunjukkan bahwa tingkat kepuasan yang lebih tinggi terhadap penggunaan AI mulai berasosiasi dengan peningkatan probabilitas model memprediksi kelas *Medium Dependency*. Selain itu, fitur *Discipline* dan *FinalOutcome* juga menunjukkan kontribusi yang lebih terlihat, Distribusi nilai SHAP yang lebih menyebar pada beberapa fitur menunjukkan bahwa kelas ini terbentuk dari kombinasi beberapa variabel dengan kontribusi moderat. Kondisi ini mencerminkan di mana beberapa faktor mulai berperan secara bersamaan dalam membentuk kecenderungan penggunaan AI. Dengan demikian, *Medium Dependency* dapat dipahami sebagai fase penggunaan yang masih adaptif, di mana AI berperan sebagai alat bantu belajar tanpa sepenuhnya menggantikan inisiatif akademik mahasiswa. Namun, terdapat potensi penurunan kemandirian jika ketergantungan terlalu tinggi [52].




Gambar 14. SHAP Summary Plot High Dependency

Pada kelas *High Dependency*, *SatisfactionRating* kembali menjadi fitur dengan kontribusi paling dominan dan memiliki

rentang nilai SHAP yang paling besar dibandingkan dua kelas lainnya. Pada plot terlihat bahwa nilai tinggi (merah) pada fitur ini secara konsisten berada pada sisi positif nilai SHAP, sedangkan nilai rendah (biru) dominan berada pada sisi negatif. Hal ini menunjukkan bahwa tingkat kepuasan yang tinggi terhadap penggunaan AI berasosiasi kuat dengan peningkatan probabilitas model memprediksi kelas *High Dependency*. Fitur *Discipline* dan *FinalOutcome* juga memberikan kontribusi tambahan, namun pengaruhnya tetap berada di bawah *SatisfactionRating*, sementara *StudentLevel* dan *TaskType* memiliki nilai SHAP yang relatif terpusat di sekitar nol, yang menunjukkan bahwa kontribusinya terhadap prediksi kelas ini cenderung terbatas. Pola ini mengindikasikan bahwa pada tingkat ketergantungan tinggi, persepsi terhadap manfaat AI menjadi faktor yang paling berperan dalam model, sedangkan faktor akademik lainnya berfungsi sebagai variabel pendukung. Tingginya ketergantungan terhadap AI berasosiasi dengan kecenderungan menurunnya inisiatif berpikir mandiri [52]. Hal ini memperlihatkan bahwa kepuasan tinggi terhadap AI berasosiasi dengan prediksi *High Dependency* dalam model.


3) *SHAP Waterfall Plot*: Interpretasi lokal dilakukan menggunakan *SHAP waterfall plot* untuk menjelaskan bagaimana variabel prediktor independen berkontribusi terhadap keputusan model pada masing-masing kelas *Knowledge Dependency Level*. Satu sampel representatif di masing-masing kelas ketergantungan. Sampel dipilih berdasarkan probabilitas prediksi tertinggi menggunakan fungsi *predict_proba*, sehingga interpretasi merepresentasikan karakteristik paling kuat dari tiap kelas. Nilai SHAP kemudian divisualisasikan menggunakan *shap.plots.waterfall()* untuk menunjukkan bagaimana setiap fitur menggeser *output* model dari nilai dasar (*base value*) menuju prediksi akhir ($f(x)$).



Gambar 15. SHAP Waterfall Plot Low Dependency


Pada kelas *Low Dependency*, nilai dasar model sebesar $E[f(x)] = -0.008$ meningkat menjadi $f(x) = 2.812$. Kontributor terbesar berasal dari *SatisfactionRating* (+1.98) dan *FinalOutcome* (+0.68), diikuti oleh *Discipline* (+0.07), *StudentLevel* (+0.07), dan *TaskType* (+0.02). Temuan ini menunjukkan bahwa pada sampel dengan probabilitas tertinggi untuk kelas ini, faktor persepsi pengguna terhadap AI (*SatisfactionRating*) merupakan faktor yang paling besar dalam menggeser prediksi model menuju kelas *Low Dependency*. Sementara itu, variabel akademik seperti bidang

ilmu, tingkat pendidikan, dan jenis tugas tidak memberikan perubahan signifikan terhadap *output* model. Secara konseptual, pola ini mengindikasikan bahwa pada kondisi *Low Dependency*, penggunaan AI cenderung tidak terintegrasi secara intens dalam proses belajar, melainkan bersifat situasional. Model mengidentifikasi bahwa pada ketergantungan rendah, persepsi terhadap AI menjadi kontributor utama dalam sampel ini, dengan kontribusi fitur lain relatif lebih kecil.



Gambar 16. SHAP Waterfall Plot Medium Dependency

Pada kelas *Medium Dependency*, *output* model bergerak dari $E[f(x)] = 0.107$ menuju $f(x) = 3.708$. Fitur dengan kontribusi terbesar meliputi *SatisfactionRating* (+1.52), *Discipline* (+1.06), *FinalOutcome* (+0.72), serta kontribusi tambahan dari *StudentLevel* (+0.3) dan *TaskType* (+0.01). Pada kelas ini terlihat bahwa kontribusi fitur menjadi lebih terdistribusi, tidak hanya didominasi oleh satu variabel. Hal ini mengindikasikan bahwa prediksi *Medium Dependency*, prediksi model tidak hanya dipengaruhi oleh persepsi terhadap AI, tetapi juga oleh konteks akademik pengguna, khususnya bidang ilmu yang ditekuni. Kontribusi fitur *Discipline* menunjukkan bahwa konteks bidang ilmu berasosiasi dengan variasi prediksi *Medium Dependency*. Temuan ini mengindikasikan adanya fase transisi, di mana penggunaan AI mulai terintegrasi dalam proses belajar dan dipengaruhi oleh karakteristik disiplin ilmu. Dengan kata lain, ketergantungan tingkat sedang tidak didorong oleh satu faktor dominan, melainkan oleh kombinasi antara persepsi penggunaan AI dan konteks akademik.



Gambar 17. SHAP Waterfall Plot High Dependency

Pada kelas *High Dependency*, nilai dasar model $E[f(x)] = -0.135$ meningkat menjadi $f(x) = 1.074$. Kontributor positif utama adalah *SatisfactionRating* (+1.10) dan *FinalOutcome* (+0.36). Namun berbeda dengan kelas lain, terdapat kontribusi negatif dari *TaskType* (-0.18) dan *StudentLevel*

(-0.17), yang mengindikasikan bahwa karakteristik akademik tertentu berasosiasi dengan penurunan kecenderungan model dalam memprediksi ketergantungan tinggi, serta kontribusi kecil dari *Discipline* (+0.09). Pola ini menunjukkan bahwa meskipun kepuasan terhadap penggunaan AI tetap menjadi faktor dominan dalam mendorong prediksi ke kelas *High Dependency*, terdapat variabel lain yang justru menahan peningkatan probabilitas tersebut. Hal ini memperkuat bahwa ketergantungan tinggi terhadap AI tidak hanya berkaitan dengan faktor akademik, tetapi lebih dipengaruhi oleh persepsi dan pengalaman penggunaan teknologi itu sendiri. Temuan ini sejalan dengan penelitian yang menunjukkan bahwa persepsi dan pemahaman pengguna terhadap AI memengaruhi tingkat ketergantungan dalam penggunaannya. Pengguna dengan pemahaman yang lebih rendah cenderung lebih bergantung pada AI, sementara pemahaman yang lebih baik mendorong penggunaan yang lebih kritis dan terkontrol. Oleh karena itu, dominasi *SatisfactionRating* dalam mendorong prediksi *High Dependency* dapat diinterpretasikan sebagai indikasi bahwa pengalaman positif tanpa diimbangi kontrol kognitif dapat meningkatkan kecenderungan ketergantungan [53].

Interpretasi SHAP secara global (*summary plot*) dan lokal (*waterfall plot*) menunjukkan bahwa seluruh kontribusi model berasal dari variabel prediktor independen (*SatisfactionRating*, *Discipline*, *FinalOutcome*, *TaskType*, dan *StudentLevel*), sehingga interpretasi tetap valid tanpa melibatkan variabel pembentuk label. Hasilnya konsisten memperlihatkan bahwa *SatisfactionRating* menjadi faktor paling dominan, di mana nilai rendah mendorong prediksi *Low Dependency* dan nilai tinggi mulai berasosiasi dengan peningkatan probabilitas *Medium Dependency* dan menjadi lebih konsisten pada *High Dependency*, sementara fitur lain berperan sebagai pendukung dengan kontribusi terbatas atau kontekstual, yang juga terlihat pada *waterfall plot* ketika pergeseran nilai prediksi terutama didorong oleh *SatisfactionRating* dengan kontribusi tambahan dari *FinalOutcome* dan pada kelas tertentu seperti *Medium Dependency* juga dipengaruhi cukup kuat oleh *Discipline*.

Knowledge discovery yang diperoleh menunjukkan bahwa tingkat ketergantungan AI lebih kuat diasosiasikan dengan persepsi dan pengalaman penggunaan dibandingkan karakteristik akademik, serta membentuk pola bertahap dari penggunaan sebagai alat bantu hingga kecenderungan dominan, tanpa menyiratkan hubungan kausal. Temuan ini selaras dengan penelitian yang menunjukkan bahwa persepsi positif terhadap AI berkaitan dengan meningkatnya kemandirian dan regulasi belajar [54]. Penelitian oleh Failandri et al. (2026) yang menemukan bahwa ketergantungan mahasiswa berada pada tingkat moderat dan dipengaruhi oleh persepsi manfaat, kemudahan akses, serta dipengaruhi oleh kesadaran terhadap risiko penurunan berpikir kritis sebagai faktor pengendali [55], penelitian lain mengungkap bahwa penggunaan AI meningkatkan efektivitas belajar namun berpotensi menurunkan motivasi dan kemandirian ketika ketergantungan meningkat [56].

D. Kontribusi Penelitian dan Implikasi

Kontribusi penelitian ini adalah menyediakan dasar berbasis data bagi institusi untuk mengidentifikasi pola ketergantungan AI dan merumuskan kebijakan yang adaptif. Berbeda dari penelitian sebelumnya yang berfokus pada performa model, penelitian ini menekankan interpretasi berbasis SHAP untuk memahami faktor yang berasosiasi dengan ketergantungan AI dalam bidang pendidikan. Meningkatnya *SatisfactionRating* berasosiasi dengan ketergantungan tinggi. Temuan ini bersifat asosiasi, sehingga perlu kehati-hatian dalam interpretasi dan generalisasi ke konteks pendidikan lain. Berdasarkan pola bertahap *low*, *medium*, hingga *high dependency*, beberapa implikasi yang dapat dipertimbangkan adalah:

- Penguatan literasi AI: Mahasiswa dan tenaga pendidik perlu dibekali pemahaman penggunaan AI secara kritis agar AI tetap berfungsi sebagai alat bantu, bukan pengganti proses berpikir.
- Penyusunan pedoman penggunaan AI: Institusi dapat menetapkan aturan penggunaan AI dalam tugas akademik untuk menjaga transparansi dan tanggung jawab.
- *Monitoring* penggunaan AI: Evaluasi berkala (misalnya melalui survei atau pola penggunaan) dapat membantu mendeteksi kecenderungan *dependency* lebih awal.
- Perhatian pada aspek etika dan bias: Interpretasi perilaku mahasiswa berbasis data perlu mempertimbangkan privasi, keadilan, dan potensi bias agar tidak menimbulkan kesimpulan yang keliru.

Pendekatan ini memungkinkan hasil penelitian dimanfaatkan sebagai dasar awal bagi institusi pendidikan dalam merancang kebijakan penggunaan AI yang lebih adaptif, dengan tetap mempertimbangkan batasan data dan konteks penggunaannya.

IV. KESIMPULAN

Penelitian ini berhasil mengklasifikasikan tingkat ketergantungan penggunaan AI dalam aktivitas pembelajaran melalui pembentukan *Dependency Score* berbasis normalisasi *Min-Max* dan *weighted linear aggregation* yang menghasilkan tiga kategori *Knowledge Dependency Level* (*Low*, *Medium*, *High*). Hasil evaluasi menunjukkan bahwa *XGBoost* memiliki performa terbaik dibandingkan *Random Forest* dan *Logistic Regression*, terutama dalam meningkatkan kemampuan deteksi pada kelas minoritas yang ditunjukkan melalui nilai *F1-score* dan *recall* yang lebih tinggi. Interpretasi menggunakan SHAP mengungkap bahwa variabel eksternal seperti *SatisfactionRating* dan *FinalOutcome* lebih dominan dalam memengaruhi tingkat ketergantungan dibandingkan latar belakang akademik, sehingga menunjukkan bahwa ketergantungan tidak hanya dipengaruhi intensitas penggunaan, tetapi juga persepsi dan pengalaman pengguna terhadap AI. Namun, penelitian ini memiliki keterbatasan karena menggunakan dataset *synthetic* yang belum sepenuhnya merepresentasikan kondisi nyata serta pembentukan target berbasis skor komposit yang

menyederhanakan perilaku kompleks. Oleh karena itu, penelitian selanjutnya disarankan menggunakan data riil, menambah variabel perilaku, dan mengeksplorasi model lain agar hasil lebih *generalizable* serta mampu menggambarkan dinamika ketergantungan AI secara lebih komprehensif.

DAFTAR PUSTAKA

- [1] E. Wahyudinarti, P. Andini Rachmatika, and R. Nurul Ain, "Meningkatkan Efektivitas Pembelajaran Mahasiswa Dengan AI," *JATI (Jurnal Mhs. Tek. Inform.,* vol. 9, no. 1, pp. 488–491, 2025, doi: 10.36040/jati.v9i1.12279.
- [2] E. Suryokta, W. Taruklimbong, and H. Sihotang, "Peluang dan Tantangan Penggunaan AI (Artificial Intelligence) dalam Pembelajaran Kimia," *J. Pendidik. Tambusai,* vol. 7, no. 3, pp. 26745–26757, 2023.
- [3] P. Techasermwattanukul and P. Suwannathachote, "The Application Of Generative Ai In Educational Research: A Systematic Literature Review," *J. Educ. Innov.,* vol. 27, no. 1, pp. 160–174, 2025, doi: 10.71185/jeiejournals.v27i1.278408.
- [4] J. A. Firdaus, R. I. Ummah, R. R. Aprialini, A. Fithriyyah, Mahsus, and A. Faizin, "Ketergantungan Penggunaan Kecerdasan Buatan (AI) pada Tugas Akademik Mahasiswa Terhadap Kemampuan Berpikir Kritis dan Kreatif," *J. Kependidikan,* vol. 14, no. 1, pp. 1203–1214, 2025.
- [5] T. N. Mahmud *et al.*, "Cognitive Offloading dalam Penggunaan Generative Artificial Intelligence (GAI) dan Perannya terhadap Working Memory Mahasiswa: Scoping Review," *J. Pendidik. MIPA,* vol. 16, no. 2, pp. 488–500, 2026.
- [6] Lukman, R. Agustina, and R. Aisy, "Problematika Penggunaan Artificial Intelligence untuk Pembelajaran di Kalangan Mmahasiswa," *J. Madaniyah,* vol. 13, pp. 1–14, 2023.
- [7] S. Marisa, D. Rachman, R. H. Puspita, and Y. Rahmawati, "The Dark Side of Dependency: Negative Consequences of EFL Students' Use of ChatGPT for Academic Writing," *Borneo Educ. J.,* vol. 7, no. 2, pp. 255–274, 2025, doi: 10.24903/bej.v7i2.2069.
- [8] Z. Revesai, "Generative AI dependency: the emerging academic crisis and its impact on student performance—a case study of a university in Zimbabwe," *Cogent Educ.,* vol. 12, no. 1, p., 2025, doi: 10.1080/2331186X.2025.2549787.
- [9] Kurniahtunnisa, P. T. Agustina, M. Y. Manuel, M. Rukmana, and K. Lestari, "Analisis Penggunaan Artificial Intelligence (AI) dalam Pembelajaran IPA di Sekolah: Persepsi dan Preferensi Siswa SMA," *J. HOMEPAGE* <http://ejurnal.unima.ac.id/index.php/sciening> Pengaruh, vol. Vol.3 No., no. 2, pp. 64–70, 2024, doi: 10.53682/slj.v5i2.10431.
- [10] S. Rahmadani, D. Z. Rizky, and N. Aini, "Eksplorasi Kebiasaan Gen-Z dalam Menggunakan AI untuk Beraktivitas Seharian," vol. 5, no. 3, pp. 327–339, 2025.
- [11] M. Abbas, F. A. Jam, and T. I. Khan, "Is it harmful or helpful? Examining the causes and consequences of generative AI usage among university students," *Int. J. Educ. Technol. High. Educ.,* vol. 21, no. 1, 2024, doi: 10.1186/s41239-024-00444-7.
- [12] S. Sallu and H. Hendriadi, "Random Forest Machine Learning Analysis of Generative AI's Impact on Learning Effectiveness in Indonesian Higher Education," *J. Tek. Inform.,* vol. 6, no. 5, pp. 3635–3651, 2025, doi: 10.52436/1.jutif.2025.6.5.3635.
- [13] T. Agustina, M. Masrizal, and I. Irmayanti, "Performance Analysis of Random Forest Algorithm for Network Anomaly Detection using Feature Selection," *Sinkron,* vol. 8, no. 2, pp. 1116–1124, 2024, doi: 10.33395/sinkron.v8i2.13625.
- [14] Florentina Tatrini Kurniati and Dian Pramana, "Identifikasi Objek Menggunakan Random Forest dan Multi-Fitur," *J. Sist. dan Inform.,* vol. 17, no. 2, pp. 130–136, 2023, doi: 10.30864/jsi.v17i2.590.
- [15] G. Airlangga, "Application of Traditional Machine Learning Techniques for the Classification of Human DNA Sequences: A Comparative Study of Random Forest and XGBoost," *J. Inform. Univ. Pamulang,* vol. 9, no. 1, pp. 23–30, 2024, doi: 10.32493/informatika.v9i1.39353.
- [16] D. Amanda Ardhani and K. D. Tania, "Knowledge Discovery on E-Commerce Customer Churn Using Interpretable Machine Learning: A Comparative Study of SHAP-Based Classifiers," *J. Appl. Informatics Comput.,* vol. 9, no. 5, pp. 2695–2702, 2025, doi: 10.30871/jaic.v9i5.10811.
- [17] R. Rismala, L. Novamizanti, K. N. Ramadhani, Y. S. Rohmah, S. Parjuangan, and D. Mahayana, "Kajian Ilmiah dan Deteksi Adiksi Internet dan Media Sosial di Indonesia Menggunakan XGBoost," *J. Edukasi dan Penelit. Inform.,* vol. 7, no. 1, p. 1, 2021, doi: 10.26418/jp.v7i1.43606.
- [18] Christine Eirene, Dian Syafitri, Neny Sulistianingsih, Khasnur Hidjah, and Hairani Hairani, "Classification of Learning Styles of Junior High School Students Using Random Forest & XGBoost Algorithm," *J. Bumigora Inf. Technol.,* vol. 7, no. 1, pp. 15–24, 2025, doi: 10.30812/bite.v7i1.4913.
- [19] F. I. Adani and H. Amalia, "Penerapan Metode Algoritma XGBoost untuk Prediksi Risiko Penyakit Jantung," *J. Insa. J. Inf. Syst. Manag. Innov.,* vol. 5, no. 2, pp. 117–125, 2025, doi: 10.31294/j-insan.v5i2.10000.
- [20] M. A. R. Yudha and M. Rahardi, "Comparative Analysis of Random Forest and XGBoost Models for Cervical Cancer Risk Prediction using SHAP-based Explainable AI," *J. Appl. Informatics Comput.,* vol. 9, no. 6, pp. 3198–3211, 2025, doi: 10.30871/jaic.v9i6.10357.
- [21] M. Safii, Husain, Ika Okta Kirana, Sasha Aiko Leana, and Yuli Indahwati Gultom, "Model Prediksi Penjadwalan Produksi Energi Terbarukan dengan Algoritma XGBoost dan Analisis Interpretatif Menggunakan SHAP," *J. Sist. Inf. Triguna Dharma (JURSI TGD),* vol. 4, no. 4, pp. 794–801, 2025, doi: 10.53513/jursi.v4i4.11443.
- [22] S. R. Ais and U. P. Sanjaya, "Perbandingan Algoritma Random Forest, XGBoost, dan Logistic Regression untuk Prediksi Risiko Kekambuhan Kanker Tiroid," *Edumatic J. Pendidik. Inform.,* vol. 9, no. 1, pp. 324–332, 2025, doi: 10.29408/edumatic.v9i1.29644.
- [23] Jeffry, A. I. S. Azis, and E. T. J. Kandakon, "Integrating Bayesian Optimization into Ensemble Logistic Regression for Explainable AI-Based Customer Behavior Analysis," *Sink. J. dan Penelit. Tek. Inform.,* vol. 9, no. 4, pp. 1900–1911, 2025.
- [24] M. Kumar, J. Wadhwa, and A. Qtaishat, "Utilizing Random Forest and XGBoost Data Mining Algorithms for Anticipating Students' Academic Performance," vol. 16, no. 2, pp. 29–44, 2024, doi: 10.5815/ijmecs.2024.02.03.
- [25] C. Adipradana, I. Taufiq, and A. N. Izzati, "Analisis Kelayakan Penerima Program Keluarga Harapan (PKH) di Kecamatan Pujud Kabupaten Rokan Hilir Menggunakan Logistic Regression," vol. 1, pp. 77–86, 2026.
- [26] M. Anshari, M. Syafrudin, A. Tan, and N. L. Fitriyani, "Optimisation of Knowledge Management (KM) with Machine Learning (ML) Enabled," no. ML, pp. 1–15, 2023.
- [27] D. A. Shafiq, M. Marjani, R. Ahamed, A. Habeeb, and D. Asirvatham, "Student Retention Using Educational Data Mining and Predictive Analytics: A Systematic Literature Review," *IEEE Access,* vol. 10, no. July, pp. 72480–72503, 2022, doi: 10.1109/ACCESS.2022.3188767.
- [28] E. Kalita *et al.*, "Educational data mining: a 10 - year review," *Discov. Comput.,* 2025, doi: 10.1007/s10791-025-09589-z.
- [29] A. Risyahputri, D. Kurniawan, and K. Ditha Tania, "Comparison of XGBoost and LSTM in Knowledge Discovery for GrokAI Mobile Application Sentiment Analysis," *Technol. Sci.,* vol. 7, no. 3, pp. 1637–1648, 2025, doi: 10.47065/bits.v7i3.8651.
- [30] E. Hermawan, S. Darmawan Panjaitan, and E. Faja Ripanti, "Sistem Prediksi Banjir Rob Kota Pontianak Berbasis Machine Learning Menggunakan Framework Streamlit," *JEPIN (Jurnal Edukasi dan Penelit. Inform.,* vol. 10, no. 3, pp. 351–361, 2024.
- [31] B. Flanagan, R. Majumdar, and H. Ogata, "Fine Grain Synthetic Educational Data: Challenges and Limitations of Collaborative Learning Analytics," *IEEE Access,* vol. 10, pp. 26230–26241, 2022, doi: 10.1109/ACCESS.2022.3156073.
- [32] A. Azrul, A. I. Purnamasari, and I. Ali, "Analisis Sentimen

- Pengguna Twitter Terhadap Perkembangan Artificial Intelligence Dengan Penerapan Algoritma Long Short-Term Memory (LTSM),” vol. 8, no. 1, pp. 413–421, 2024.
- [33] A. Widianti and I. Pratama, “Penanganan Missing Values Dan Prediksi Data Timbunan,” vol. 9, no. 2, pp. 242–251, 2024.
- [34] H. L. Wati, N. Anggraeni, S. Kolbiah, U. Hendar, and N. Agustina, “Perbandingan Algoritma Random Forest Dan Naratif: Jurnal Ilmiah Nasional Riset Aplikasi Dan Teknik Informatika,” vol. 07, no. 01, pp. 64–71, 2025.
- [35] M. Irawan, R. N., Hindrayani, K. M., & Idhom, “Penerapan Cross Validation sebagai Analisis Sentimen Pelayanan Publik Kereta Api Lokal Daop 8 Menggunakan Metode Multinomial Naïve Bayes,” *G-Tech J. Teknol. Terap.*, vol. 6, no. 2, pp. 295–305, 2022.
- [36] P. P. Alloreng, A. Erna, M. Bagussahrir, and S. Alam, “Analisis Performa Normalisasi Data untuk Klasifikasi K-Nearest Neighbor pada Dataset Penyakit,” vol. 9, no. 3, pp. 178–191, 2024.
- [37] C. Wastu *et al.*, “Pengukuran Indeks Pembangunan Perkebunan Di Jawa Timur Dengan Pendekatan Indeks Komposit Dan Analisis Faktor Measurement Of Plantation Development Index In East Java,” vol. 23, no. 02, pp. 331–344, 2025.
- [38] M. H. Bisri, N. A. Setianto, and M. Bata, “Analisis Potensi Sda Dan Sdm Usaha Kelompok Ternak Sapi Potong Sistem Semi Intensif Integrasi Sapi-Sawit Di Bangka Tengah : " Pendekatan Indeks Komposit ",” pp. 161–167, 2025.
- [39] A. W. Jeremy, J. Kelleher, J. Magid, B. R. Jackson, M. E. Pennini, and D. Kushner, “Dispensing of Oral Antiviral Drugs for Treatment of COVID-19 by Zip Code – Level Social Vulnerability — United States, December 23, 2021–May 21, 2022 Jeremy,” vol. 71, no. 25, pp. 825–829, 2022.
- [40] E. Barth, J. Tadeu, V. De Resende, and K. H. Marigule, “Multivariate analysis methods improve the selection of strawberry genotypes with low cold requirement,” *Sci. Rep.*, pp. 1–12, 2022, doi: 10.1038/s41598-022-15688-4.
- [41] R. Z. Arifin, H. Firmansyah, and W. Asriyani, “Prediksi Kelulusan Siswa Berdasarkan Data Demografis dan Akademik pada Dataset Student Performance,” vol. 4, no. 2, pp. 13300–13307, 2025.
- [42] B. A. C. Permana, Zulkipli, M. Wasil, and Harianto, “Improving Imbalanced Polycystic Ovary Syndrome Classification Using a Leakage-Free Machine Learning Pipeline,” vol. 9, no. January, pp. 538–547, 2026.
- [43] A. Setiawan, R. Yanti, E. Ali, and H. Yenni, “Optimasi Klasifikasi Tingkat Obesitas Pada Remaja Berdasarkan Pola Hidup Menggunakan SVM Dengan Teknik Smote,” pp. 224–235, 2025, doi: 10.33364/algoritma/v.22-2.2509.
- [44] Amiruddin and R. Ishak, “Implementasi Seleksi Fitur Klasifikasi Waktu Kelulusan Mahasiswa Menggunakan Correlation Matrix With Heatmap,” vol. 4, pp. 169–174, 2022.
- [45] A. I. Pradana and V. Atina, “Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa,” pp. 239–248, 2024, doi: 10.33364/algoritma/v.21-1.1618.
- [46] C. Arafat *et al.*, “Perbandingan Algoritma Random Forest Dan Xgboost Untuk Klasifikasi Penyakit Jantung Berdasarkan Data Medis,” vol. 15, no. 2, pp. 430–435, 2025.
- [47] J. P. Angraini, C. G. Z. A. and A. Desiani, “Komputika : Sistem Komputer Perbandingan Algoritma Random Forest dan Extreme Gradient Boosting (XGBoost) dalam Klasifikasi Penyakit Gagal Jantung Comparison of Random Forest and Extreme Gradient Boosting (XGBoost) Algorithms in Heart Failure Disease C,” vol. 12, no. 2, 2025, doi: 10.34010/komputika.v14i2.16618.
- [48] M. N. Ramadhani, K. D. Tania, and M. Afrina, “Knowledge Discovery in Sharia Mobile Banking Reviews Using Aspect- Based Sentiment Analysis and Machine Learning,” vol. 10, no. 1, pp. 640–650, 2026.
- [49] O. B. Limet *et al.*, “Pemilihan Fitur Untuk Prediksi Kematangan Kelapa Sawit Menggunakan Explainable AI (XAI) Feature Selection for Oil Palm Ripeness Prediction Using Explainable AI,” vol. 7, no. 2, pp. 137–150, 2025.
- [50] L. N. Hapsari, I. Fannani, Y. Rahmawati, and A. Muhariya, “Explainable Machine Learning untuk Prediksi Risiko Penyakit Jantung Menggunakan Random Forest dan Analisis SHAP,” *REMIK Ris. dan E-Jurnal Manaj. Inform. Komput.*, vol. 10, no. 1, pp. 190–199, 2026, doi: http://doi.org/10.33395/remik.v10i1.15766.
- [51] N. Ardana, H. Indrawati, and F. Trisnawati, “Pengaruh Pemanfaatan Teknologi Artificial Intelligence terhadap Kemandirian Belajar (Studi pada Mahasiswa Jurusan Pendidikan IPS Universitas Riau),” *JiIP (Jurnal Ilm. Ilmu Pendidikan)*, vol. 8, no. 8, pp. 9688–9699, 2025.
- [52] U. Hanifah and N. Novebri, “Ketergantungan Penggunaan Aplikasi AI dalam Keefektivitasan Belajar pada Mahasiswa Manajemen Pendidikan Islam,” *J. Manaj. dan Pendidik. Agama Islam*, vol. 3, no. 1, pp. 265–273, 2024, doi: 10.61132/jmpai.v3i1.866.
- [53] Kurniahtunnisa, M. Y. Manuel, M. Aini, and T. P. Agustina, “Persepsi dan Sikap Siswa Terhadap Penggunaan Artificial Intelligence,” *Sch. J. Pendidik. dan Kebud.*, vol. 15, no. 1, pp. 47–59, 2025.
- [54] L. K. Dewi and N. I. Lahizha, “Integrasi Artificial Intelligence (AI) dalam Sistem Pembelajaran Adaptif untuk Meningkatkan Belajar Mandiri Mahasiswa,” *JiIP (Jurnal Ilm. Ilmu Pendidikan)*, vol. 8, no. September, pp. 10916–10921, 2025.
- [55] M. A. Failandri, M. Fatkhunihad, L. Shodik, M. R. Rizqiyanto, and D. A. Nugroho, “Analisis Tingkat Ketergantungan Mahasiswa Informatika Terhadap Penggunaan AI,” *J. REKAYASA Inf. SWADHARMA*, vol. 06, no. 1, 2026.
- [56] Nisma and F. I. Lisanty, “Hubungan Intensitas Penggunaan Aplikasi AI Dengan Efektivitas Belajar Pada Mahasiswa Kebidanan,” *ILLEA J. Heal. Sci. Public Heal. Med.*, vol. 1, no. 2, 2025.