

Pemodelan Hybrid Prediksi Dampak Generative AI terhadap Retensi Keterampilan Belajar Mahasiswa

Ardiansyah¹, Noor Afy Shovmayanti²

^{*1} Program Studi Teknologi Informasi, Universitas Muhammadiyah Klaten, Klaten

² Program Studi Ilmu Komunikasi, Fakultas Sosial dan Humaniora, Universitas Muhammadiyah Klaten, Klaten

Email: ^{*1}ardiansyah@umkla.ac.id, ²noorafyshow@umkla.ac.id

ABSTRACT — The growing adoption of Generative Artificial Intelligence (GenAI) technology in the field of education has sparked global concerns regarding the potential decline in students' cognitive abilities and the loss of their analytical independence. On the other hand, the majority of previous studies have employed a one-size-fits-all approach that generalizes the impact of artificial intelligence without accounting for the specific behavioral heterogeneity of its users. This gap in the literature serves as the research gap for this study, which proposes Hybrid Machine Learning to predict fluctuations in the Skill Retention Score metric. The K-Means algorithm was implemented to segment the data, predictive modeling using the CatBoost Regressor through SHAP (Semi-Supervised Heterogeneous Adaptive Predictor) explainable AI. The segmentation results confirmed the existence of the following profiles: Cluster 0 (The Heavy Dependent) and Cluster 1 (The Traditional User). Based on these two clusters, the STEM field was found to be the top field in the use of Artificial Intelligence (AI) for the purpose of debugging computational code. Model evaluation revealed that AI adoption behavior variables significantly dictate skill degradation only among extreme users ($R^2 = 0.3131$), compared to conventional users ($R^2 = 0.1797$). Furthermore, the Shapley value analysis found that AI is proven to be safe as a support assistant or learning assistant if the dependency level remains between 1 and 6; however, if usage exceeds 6, it will affect cognitive retention. In other words, the Shapley value analysis successfully identified the tipping point of the cognitive offloading phenomenon. Nevertheless, a total ban on AI use was found to be ineffective in preserving academic retention scores. Therefore, a transition toward institutional regulations regarding the adoption of artificial intelligence is needed, one that is more adaptive, accountable, and specifically tailored to high-risk demographics, particularly in STEM fields.

KEYWORDS — K-Means; CatBoost; SHAP; GenAI; Skill Retention; Cognitive Offloading;

INTISARI — Peningkatan adopsi teknologi *Generative Artificial Intelligence* (GenAI) pada bidang Pendidikan memicu kekhawatiran global terkait potensi menurunnya kognitif serta hilangnya kemandirian analitis mahasiswa. Dilain sisi, mayoritas penelitian terdahulu menggunakan pendekatan *One-Size-Fits-All* yang mengeneralisasi dampak kecerdasan buatan tanpa mempertimbangkan heterogenitas perilaku spesifik dari penggunaanya. Hal tersebut menjadi *Gap Research* untuk penelitian yang dilakukan dengan mengusulkan Hybrid Machine Learning untuk memprediksi fluktuatif metrik *Skill Retention Score*. Algoritma K-Means diimplementasikan untuk membagi data, yang dilanjutkan pemodelan prediktif menggunakan CatBoost Regressor melalui interpretasi *Explainable AI* (SHAP). Hasil segmentasi membuktikan eksistensi profil yaitu: kluster 0 (*The Heavy Dependent*), Kluster 1 (*The Traditional User*). Berdasarkan kedua Kluster temukan bidang STEM merupakan bidang teratas dalam penggunaan kecerdasan buatan dengan tujuan untuk *debugging code* komputasional. Evaluasi model ditemukan bahwa variable perilaku adopsi AI mendikte degradasi keterampilan secara signifikan hanya pada pengguna ekstrem ($R^2 = 0.3131$), dibandingkan pengguna konvensional ($R^2 = 0.1797$). Lebih lanjut, analisis nilai Shapley menemukan AI terbukti aman sebagai asisten pendukung atau asisten belajar jika skala tergantungan masih di skala 1-6, namun jika penggunaan diatas 6 akan mempengaruhi retensi kognitif. Dengan kata lain Analisis nilai Shapley secara krusial berhasil mengisolasi keberadaan titik kritis (*Tipping Point*) dari fenomena *Cognitive Offloading*. Meskipun begitu pelarangan penggunaan AI secara total ditemukan tidak efektif untuk menyelamatkan skor retensi akademik. Sehingga diperlukan transisi regulasi institusional terhadap adopsi kecerdasan buatan yang lebih adaptif, akuntabel serta secara khusus pada demografi beresiko tinggi yaitu bidang STEM.

KATA KUNCI — K-Means; CatBoost; SHAP; GenAI; Retensi Keterampilan; Pengalihan Beban Kognitif;

I. PENDAHULUAN

Generative Artificial Intelligence atau yang dikenal dengan GenAI pada proses pembelajaran mahasiswa bidang Pendidikan telah mengalami pergeseran paradigma [1], [2]. GenAI memberikan penawaran efisiensi pada proses pembelajaran mahasiswa, mulai dari tahapan brainstorming hingga

implementasi ide [3], [4]. Meskipun menawarkan efisiensi pada proses pembelajaran mahasiswa, muncul kekhawatiran dari sisi akademis [2], [5], [6] yang signifikan tentang fenomena *cognitive offloading* atau kecenderungan mahasiswa untuk mendelegasikan proses kognitif internal ke GenAI [7].

Kekhawatiran tersebut akan memunculkan ketergantungan berlebih terhadap GenAI. Hal tersebut dapat memicu penurunan daya ingat serta pemahaman fundamental dari suatu bidang yang pelajari dalam jangka panjang atau secara metrik sebagai retensi keterampilan mahasiswa.

Penelitian [8], [9], [10], [11] terdahulu telah melakukan pengukuran kecerdasan buatan atau *Artificial Intelligence* (AI) terhadap performa akademik. Namun, mayoritas penelitian menggunakan pendekatan *One-Size-Fits-All*, yang dimana seluruh populasi mahasiswa dievaluasi sebagai satu kelompok yang homogen. Pendekatan ini memiliki kekurangan dalam menangkap heterogenitas perilaku dari mahasiswa seperti: Dampak kecerdasan buatan pada mahasiswa yang menggunakan secara pasif sebagai asisten belajar dan mahasiswa yang menggunakan kecerdasan buatan ekstrem untuk menjawab pertanyaan. Ketidakmampuan dalam memisahkan persona pengguna seringkali menghasilkan model prediksi dengan tingkat akurasi serta daya penjelas (R^2 Score) menjadi rendah, sehingga kesimpulan yang diberikan menjadi bias.

Berdasarkan kesenjangan yang telah dipaparkan diatas, Penelitian ini mengusulkan arsitektur *Hybrid Machine Learning* yang mengintegrasikan pendekatan berbeda. Penelitian ini pada mulanya memisahkan mahasiswa dengan pesona mirip dengan menentukan variable penggunaan AI, jam belajar trasional, serta tingkat kecemasan, pemisahan kategori dilakukan menggunakan algoritma K-Means. Tahapan selanjutnya, penggunaan algoritma CatBoost dilatih secara independent disetiap klaster atau segmen untuk memprediksi *Skill Retention Score*.

Lebih lanjut, penelitian yang dilakukan mengintegrasikan pendekatan *Explainable AI* (XAI) melalui metode *Shapley Additive explanation* (SHAP) yang bertujuan untuk mengkuantifikasi serta memvisualisasi letak *tipping point* tingkat ketergantungan AI mulai memberikan dampak deskruktif terhadap kognitif mahasiswa di setiap klaster. Secara keseluruhan, penelitian ini bertujuan untuk membuktikan secara empiris dampak GenAI terhadap retensi belajar tidak bersifat homogen, namun bergantung pada klaster perilaku mahasiswa.

II. TINJAUAN PUSTAKA

A. GENERATIVE AI DALAM EKOSISTEM PENDIDIKAN DAN FENOMENA COGNITIVE OFFLOADING

Generative Artificial Intelligence (GenAI) telah mengubah metode pembelajaran dengan kemampuan pemahaman Bahasa alami serta mensintesis informasi secara instant [12]. Meskipun telah terbukti mampu meningkatkan efisiensi penggunaan GenAI menjadi hal yang perlu dikaji lebih dalam lagi [2], [5], [6] terkhusus untuk *Cognitive Offloading* pada mahasiswa. Konteks Pendidikan, delegasi kognitif perimplikasi langsung dengan *Skill Retention* yang dapat menghilangkan kapasitas mahasiswa dalam memecahkan sebuah masalah secara mandiri [7].

B. K-MEANS CLUSTERING

Penelitian terdahulu yang membahas terkait GenAI terhadap performa akademik sebagian besar menggunakan pendekatan populasi tunggal atau yang dikenal dengan *One-Size-Fits-All* [13]. Pendekatan analitik tersebut memiliki keterbatasan yang sangat penting karena mengasumsikan seluruh populasi mahasiswa merespons dan mengintegrasikan teknologi kecerdasan buatan dengan pola kognitif yang serupa atau homogen. Walaupun, literatur terbaru membutuhkan pembuktian secara empiris [10]. Dilain sisi, keragaman perilaku

pengguna dalam model prediktif dapat membuat model menjadi bias dan dapat berakibatkan gagal dalam membedakan variabel seperti *Cognitive Offloading* [14].

Kelemahan tersebut dapat diatasi menggunakan algoritma unsupervised learning seperti K-Means [15]. K-Means digunakan untuk mengkategorikan data menjadi beberapa perilaku dengan meminimalkan intra-klaster sehingga segmentasi menjadi terukur [16]. Penentuan jumlah klaster optimal pada umumnya divalidasi dengan metrik *Silhouette Score* yang bertujuan untuk memastikan pengelompokan bersifat obyektif dan data-driven [15].

C. CATBOOST REGRESSOR

Pemodelan data prediksi yang memiliki fitur numerik dan kategorikal, algoritma *Gradient Boosting Decision Tree* (GBDT) seringkali inefisiensi komputasi. Sedangkan Algoritma seperti XGBoost atau LightGBM memerlukan tahapan prapemrosesan berupa *One-Hot End coding* untuk data kategorikal, yang rentan terhadap overfitting [17]. Hadirnya Algoritma *Categorical Boosting* (CatBoost) menjawab kelemahan daripada algoritma yang telah disebutkan diatas. CatBoost memiliki keunggulan untuk memproses data kategorikal dengan Teknik *Ordered Target Statistics* [18].

Integrasian antara CatBoost dengan K-Means menawarkan kelebihan untuk mempelajari pola interaksi non-linear yang kompleks antara *Skill Retention Score* secara spesifik untuk setiap persona. Stabilitas arsitektur pada CatBoost dapat memastikan optimalisasi training time tanpa harus mengorbankan akurasi prediksi, menjadikan standar yang sangat direkomendasikan untuk analisis analitik modern [17], [18].


D. EXPLAINABLE AI (XAI) MELALUI PENDEKATAN SHAP

Kompleksitas dari algoritma CatBoost memunculkan kelemahan yang bersifat black-box yang dimana proses pengambilan keputusan matematis dibalik prediksi tersebut sangat sulit untuk di pahami oleh manusia [19]. Sehingga kesenjangan ini harus di jembatani oleh paradigma *Explainable Artificial Intelligence* (XAI) melalui metode *Shapley Additive exPlanations* (SHAP) [19].

Penggunaan SHAP dapat mengidentifikasi dan memeringkat arah dampak variabel yang paling signifikan mempengaruhi *Skill Retention* pada masing-masing klaster persona [20]. Transparansi algoritmik tersebut dapat menjadi fondasi utama dalam merumuskan kebijakan yang berbasis bukti atau *Evidence-Based Policy*.

III. METODOLOGI

Penelitian yang dilakukan tergambarkan pada Gambar 1 dibawah ini.



Gambar 1. Alur penelitian yang dilakukan.

A. PENGUMPULAN DAN PRAPEMROSESAN DATA

Penelitian yang dilakukan menggunakan data skunder yang didapatkan pada platform Kaggle dengan jumlah 50.000 sampel observasi [21]. Dataset sekunder tersebut merepresentasikan profil demografis, perilaku, dan riwayat akademis penggunaan GenAI pada lingkungan Pendidikan Tinggi, namun dataset yang digunakan tidak menyebutkan secara spesifik negara bagian tempat pengumpulan data. Meskipun begitu variabel pada penelitian yang dilakukan adalah *Skill Retention Score*, metrik berlanjut yang mengukur kemampuan kognitif mahasiswa.

Selanjutnya, prapemrosesan data dilakukan pembagian dataset 80:20, *Missing Value*, imputasi fitur numerik menggunakan nilai median yang dikalkulasikan secara eksklusif dari data pelatihan, sedangkan fitur kategorikal yang kosong diisikan dengan label “Unknown”.

B. SEGMENTASI PERILAKU MENGGUNAKAN K-MEANS

Tahapan ini bertujuan untuk ekstraksi persona mahasiswa berdasarkan perilaku adopsi kecerdasan buatan. Proses klastering mempertimbangkan fitur numerik antara lain: Jam penggunaan GenAI mingguan, Keberagaman Alat, Tingkat Ketergantungan AI, Tingkat Kecemasan, Jam Belajar Tradisional. Meskipun begitu, variabel yang disebutkan memiliki rentang metrik yang fluktuatif, sehingga normalisasi data diperlukan. Normalisasi data menggunakan *Standard Scaler* untuk mengubah seluruh variabel rata-rata 0 dan 1.

Selanjutnya, K-means di implementasikan untuk membagi data ke dalam sub-populasi yang homogen. Selain itu, pemanfaatan *Silhouette Score* untuk menghindari bias subjektif dalam penentuan jumlah klaster menggunakan *Silhouette Score* yang pada umumnya bernilai antar -1 sampai 1, Score tersebut didapatkan dengan menggunakan persamaan (1)(2). Berdasarkan pelabelan tersebut, dataset dibagi menjadi 2 kelompok independent: *Heavy dependent* (Klaster 0) dan Tradisional User (Klaster 1). Semua tahapan menggunakan persamaan klustering (1) dan *Silhouette Score* (2) dibawah ini [22], [23]:

$$J = \sum_{k=1}^k \sum_{x_i \in C_k} ||x_i - \mu_k||^2 \quad (1)$$

$$S(i) = \frac{b(i)-a(i)}{\max(a(i),b(i))} \quad (2)$$

C. PEMODELAN PREDIKTIF BERBASIS KLASTER

Algoritma CatBoost dikonfigurasi untuk memproses arsitektur data tabular yang kompleks secara hibrida (numerik dan kategorikal) tanpa menggunakan transformasi *One-Hot Encoding*, sehingga tidak memberatkan perangkat dari sisi komputasi memori. Konfigurasi model CatBoost menggunakan *epochs* 300, *learning rate* 0.05 dan *depth* 6 untuk setiap subset data latih dan klasternya. Selain itu, proses evaluasi menggunakan metrik *Mean Absolute Error* (MAE) persamaan (3), *Root Mean Square Error* (RMSE) persamaan (4), dan koefisien Determinasi (R^2) persamaan (5). Berikut persamaan untuk menghitung metrix tersebut [24], [25]:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_e(i) - \hat{y}_e(i)| \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$


D. INTERPRETASI MODEL DAN EKSTRAKSI WAWASAN

Tahapan akhir pada penelitian yang dilakukan yaitu interpretasi dari hasil pemodelan prediktif. Pendekatan black-box yang mengintegrasikan arsitektur *Explainable AI* (XAI). Sedangkan Metode *Shapley Additive exPlanations* (SHAP) di implementasikan pada objek *TreeExplainer* dari Model CatBoost yang telah dilatih. Pendekatan analitik visual SHAP yang digunakan pada penelitian ini adalah SHAP Summary Plot, SHAP Dependence Plot.

IV. HASIL DAN PEMBAHASAN

A. ANALISIS EKSPLORATORI DAN KORELASI VARIABEL (EDA)

Tahapan EDA dilakukan sebelum melakukan implementasi pemodelan prediktif yang kompleks, analisis korelasi linier Pearson dilakukan untuk memetakan hubungan antar variabel numerik dalam data. Hasil pemetaan divisualisasikan menggunakan matriks korelasi (*Heatmap*) terlihat pada Gambar 2.



Gambar 2. Heatmap korelasi Pearson antar variabel numerik.


Berdasarkan Gambar 2 Heatmap diatas ditemukan terdapat hubungan positif yang moderat ($r = 0.67$) antara durasi penggunaan AI dan tingkat dependensi psikologis tetapi temuan yang paling krusial pada korelasi antar seluruh variabel prediktor dengan variabel target Skill Retention Score. Koefisien korelasi yang dihasilkan sangat lemah, seperti pada variabel Penggunaan AI Mingguan ($r = -0.12$) dan Ketergantungan AI ($r = -0.08$).

Lemahnya korelasi linear global ini memberikan justifikasi empiris bahwa dampak adopsi AI terhadap retensi kognitif bersifat sangat kompleks, asimetris, dan non-linear. Hasil temuan ini sekaligus menggugurkan kelayakan penggunaan model regresi linier tradisional. Sehingga, dilakukan tahapan lanjutan yaitu arsitektur hybrid yang diawali membagi heterogenitas data menggunakan K-Means Clustering sebelum masuk ke pemodelan menggunakan CatBoost.

Gambar 3 hubungan tren negative merepresentasikan adanya eskalasi tingkat ketergantungan mahasiswa terhadap GenAI secara linier yang diikuti oleh tren penurunan skor retensi keterampilan.


Gambar 3 juga memberikan informasi sebaran titik data yang padat pada setiap level dependensi, dipadukan dengan kemiringan garis tren yang persisten menurun, memberikan landasan observasional empiris yang memvalidasi hipotesis

Cognitive Offloading. Hasil gambar ini menjadi bukti kuantitatif substansial bahwa pendelegasian beban analitis secara ekstrem ke GenAI berkontribusi terhadap degradasi kapasitas memori jangka panjang serta menghilangkan kemandirian kognitif mahasiswa.



Gambar 3. Hubungan tren negatif antara tingkat ketergantungan AI dan skor retensi keterampilan mahasiswa.

Selanjutnya, Gambar 4 Distribusi retensi keterampilan berdasarkan kebijakan institusi, menunjukkan ineffectivitas penerapan pelarangan total (*Strict Ban*). Berdasarkan Gambar 4 ditemukan bahwa kebijakan pelarangan tidak menghasilkan metrik retensi kognitif yang lebih baik dibandingkan dengan kebijakan yang permisif. Konvergensi nilai median dan sebaran data secara empiris membuktikan bahwa pendekatan represif berupa pelarangan tidak efektif dalam memitigasi *Cognitive Offloading*.



Gambar 4. Distribusi retensi keterampilan berdasarkan kebijakan, menunjukkan ineffectivitas penerapan pelarangan total (*Strict Ban*).

B. PROFILING MAHASISWA (K-MEANS)

Profiling mahasiswa dilakukan untuk ekstraksi divergensi latar belakang akademik yang sangat signifikan antar pengguna berinsensitas tinggi dan pengguna konvensional. Komparasi distribusi mayoritas jurusan yang menyusun kedua klaset terperinci pada Tabel I.

TABEL I
MAYORITAS JURUSAN PADA KLASTER 0 DAN 1

Major Kategori	Score Klaster 0	Score Klaster 1
STEM	39.19	26.70
Business	24.16	25.31
Humanities	15.34	21.78
Medical	11.46	13.43
Arts	9.84	12.79

Berdasarkan Tabel I diatas, tergambaran dominasi dari bidang STEM dengan presentasi 39.19% unggul dibandingkan bidang lainnya di Klaster 0 (*Heavy Dependent*). Sebaliknya, Klaster 1 (*The Traditional User*) persebaran yang lebih

berimbang. Meskipun bidang STEM tetap menjadi urutan teratas.

Eksplorasi lebih dalam pada Klaster 0 menemukan tujuan penggunaan GenAI. Temuan data pada Tabel II memberikan informasi bahwa tujuan penggunaan GenAI untuk *Debugging/Troubleshooting*. Hal tersebut selaras dengan ditemukan adanya degradasi keterampilan mahasiswa jika penggunaan GenAI berlebihan. Pernyataan ini dapat dilihat pada Gambar 5 dan 6 secara Grafik.

TABEL II
TUJUAN PENGGUNAAN KECERDASAN BUATAN PADA KLASTER 0

Tujuan Penggunaan	Score
<i>Debugging/Troubleshooting</i>	27.55
<i>Ideation</i>	21.41
<i>Copywriting/Drafting</i>	21.17
<i>Summarizing Reading</i>	17.03
<i>Direct Answer Generation</i>	12.84

C. TRAINING DAN PREDIKSI

Setelah profiling mahasiswa dilakukan, tahapan selanjutnya tahapan untuk memvalidasi secara kuantitatif variable-variable observasi mampu memprediksi luaran akademik mahasiswa. Pelatihan dilakukan menggunakan algoritma CatBoost di setiap klaster. Pendekatan pemodelan independent di implementasikan untuk membuktikan hipotesis bahwa mekanisme degradasi kognitif bersifat asimetris dan tidak dapat di generalisasi menggunakan pendekatan regresi tunggal atau *One-size-fits-all*.

Pengukuran tingkat akurasi prediksi serta seberapa besar presentase varians dari *Skill Retention* yang berhasil diinterpretasikan oleh variable prediktor, evaluasi kinerja model diukur menggunakan metrik: *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan Koefisien Determinasi (R^2). Hasil evaluasi model dapat dilihat pada Tabel III dibawah ini.

TABEL III
MATRIK EVALUASI MODEL

Evaluasi	Klaster 0	Klaster 1
MAE	9.5401	9.4296
RMSE	11.7126	11.6871
R^2 Score	0.3131	0.1797

Berdasarkan Tabel III menunjukan kedua model angka komputasional yang relatif seimbang, tingkat kesalah prediksi yang stabil pada kedua populasi data. Namun, temuan yang paling fundamental dan menjadi kebaruan dari pemodelan ini terletak pada disparitas nilai koefisien determinasi (R^2). Disparitas metrik memberikan pembuktian empiris yang valid untuk klaster 0, intensitas dan perilaku pengguna GenAI bertindak sebagai prediktor utama yang mendikte degradasi kognitif mahasiswa. Sebaliknya, rendahnya daya prediksi pada klaster 1 mengkonfirmasi bahwa bagi pengguna pasif bukan faktor dominan yang mendistrupsi retensi keterampilan belajar.


D. GRAFIK SHAP SUMMARY DAN DEPENDENCE PLOT

Analisis *Explainable AI* menggunakan SHAP merepresentasikan bahwa distribusi nilai Shapley, pada Gambar 5 dibawah, variabel *Prompt Engineering Skill* dan *Weekly GenAI Hours* menjadi prediktor paling dominan. Lebih jauh, sebaran warna pada *Weekly GenAI Hours* merepresentasikan korelasi negatif yang kuat, titik berwarna merah merepresentasikan durasi penggunaan AI yang sangat tinggi terkonsentrasi di bagian kiri sumbu 0 atau sumbu negatif.

Temuan ini membuktikan secara empiris bahwa intensitas penggunaan GenAI yang berlebihan akan berdampak langsung ke degradasi retensi keterampilan. Namun sebaliknya variabel *Traditional Study Hours* mendapatkan hasil positif terhadap daya ingat.

Meskipun begitu variabel ketergantungan AI bukan faktor yang paling dominan secara keseluruhan, grafik SHAP *Dependence Plot* menampilkan adanya *tipping point* pada grafik dibawahnya dengan kata lain penggunaan AI dalam batas wajar tidak memberikan efek yang berbahaya bagi daya ingat mahasiswa ditujukan dengan Skala 2 sampai 6, jika diatas 6 akan berdampak pada turunnya performa kognitif dari mahasiswa.

SHAP Summary: Faktor Penentu Retention (Klaster 0 - The Heavy Dependent)




Gambar 5. Shap Summary dan value Klaster 0

Selanjutnya, Gambar 6 SHAP *Summary* dan Value untuk klaster 1 merepresentasikan hasil pola predictor yang sangat berbanding terbalik dengan kelompok ekstrim. SHAP summary plot sendiri merepresentasikan bahwa retensi kognitif untuk klaster 1 sepenuhnya bergantung oleh metode konvensional yang dimana variable *Traditional Study Hours* menjadi faktor numerik paling dominan dengan kontribusi positif yang berbanding lurus terhadap durasi belajar.

Sebaliknya, variable Ketergantungan AI terdegradasi ke hierarki paling bawah. Lebih jauh, SHAP *Dependence Plot* menggambarkan rentang dependensi mahasiswa pasif hanya terbatas skala 1-7, dengan fluktuasi dampak yang sangat sempit dan stagnan di garis ekuilibrium 0. Secara empiris, visualisasi di Gambar 6 menegaskan bahwa mahasiswa berintensitas rendah, interaksi moderat dengan GenAI sama sekali tidak berdampak

degradasi kognitif, melainkan tetap terlindungi secara solid oleh ketekunan belajar secara tradisional dari mahasiswa itu sendiri.

SHAP Summary: Faktor Penentu Retention (Klaster 1 - The Traditional User)



Gambar 6. Shap Summary dan value Klaster 1

V. KESIMPULAN

Penelitian yang telah dilakukan menemukan bahwa dampak GenAI terhadap retensi keterampilan belajar bersifat asimetris dan tidak dapat digeneralisasi. Pemanfaatan arsitektur Hybrid Machine Learning, K-Means berhasil mengungkap kerentanan kognitif yang ekstrem pada mahasiswa pada bidang STEM. Sub-Populasi ini mendemonstrasikan perilaku *Cognitive Offloading* dengan mendelegasikan beban penyelesaian masalah analitis secara intensif kepada GenAI atau kecerdasan buatan.

Selanjutnya, evaluasi dari pemodelan CatBoost yang diinterpretasikan melalui SHAP secara definitive menemukan *tipping point* pada skala ketergantungan psikologis. Selama interaksi berada pada tingkat moderat atau skala 1-6, kecerdasan buatan terbukti aman difungsikan sebagai asisten pendukung. Namun, ketika skala diatas 6 akan menjadi pemicu utama kerusakan kognitif mandiri mahasiswa. Meskipun begitu, institusi Pendidikan segera melakukan penyesuaian regulasi represif menuju strategi pedagogis adaptif, dengan menitik beratkan audit penggunaan kecerdasan buatan pada rumpun STEM.

Penelitian yang dilakukan memiliki keterbatasan utama yaitu penggunaan data sekunder berskala global, hal ini dapat berpotensi memiliki deviasi terhadap dinamika sosio-akademik pada institusi lokal. Sehingga untuk peneliti selanjutnya dapat menggunakan data primer serta melakukan pemantauan

degradasi kognitif mahasiswa secara *real-time* disetiap semester. Selain itu, eksplorasi algoritma dapat menggunakan *Deep Learning* yang adaptif terhadap data tabular atau mengintegrasikan *Natural Language Processing* (NLP) untuk analisis teks prompt mahasiswa secara langsung sehingga dapat menggambarkan pola perilaku adopsi AI yang lebih komprehensif.

REFERENSI

- [1] R. Melisa *et al.*, “Critical Thinking in the Age of AI: A Systematic Review of AI’s Effects on Higher Education,” *Educational Process: International Journal*, vol. 14, p. e2025031, 2025.
- [2] W. Milinthapunya, P. Nilsook, and P. Wannapiroon, “Generative AI in Higher Education: A Student Perspective,” in *2025 5th International Conference on Educational Communications and Technology (ICTAECT)*, IEEE, Nov. 2025, pp. 1–6. doi: 10.1109/ICTAECT67351.2025.11391308.
- [3] L. Xia, “Artificial Intelligence Literacy Education: A Scoping Literature Review from 2020–2024,” in *2025 5th International Conference on Artificial Intelligence and Education (ICAIE)*, IEEE, May 2025, pp. 785–789. doi: 10.1109/ICAIE64856.2025.11158088.
- [4] D. Baidoo-Anu and L. Owusu Ansah, “Education in the Era of Generative Artificial Intelligence (AI): Understanding the Potential Benefits of ChatGPT in Promoting Teaching and Learning,” *SSRN Electronic Journal*, 2023, doi: 10.2139/ssrn.4337484.
- [5] T. Gouveia *et al.*, “Lecturer training in Generative AI in Higher Education: pilot study at the School of Education of the Polytechnic Institute of Viseu,” in *2025 International Symposium on Computers in Education (SIIE)*, IEEE, Nov. 2025, pp. 1–4. doi: 10.1109/SIIE68580.2025.11368424.
- [6] R. C. Waliliong, J. Hadinata, M. Basri, and H. Juwitasary, “Exploring the Role of Academic Integrity and External Factors that Influence the Use of Generative AI in Education,” in *2026 6th International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET)*, IEEE, May 2026, pp. 1–6. doi: 10.1109/IRASET68627.2026.11538646.
- [7] S. Chen and F. Liu, “Gen-PBL in Vocational Big Data Education: Exploring Cognitive Offloading Behaviors via Structured GenAI Scaffolding,” in *2026 15th International Conference on Educational and Information Technology (ICEIT)*, IEEE, Mar. 2026, pp. 958–961. doi: 10.1109/ICEIT68991.2026.11521279.
- [8] U. Mittal, S. Sai, V. Chamola, and D. Sangwan, “A Comprehensive Review on Generative AI for Education,” *IEEE Access*, vol. 12, pp. 142733–142759, 2024, doi: 10.1109/ACCESS.2024.3468368.
- [9] Zhong Ziyang, Ketut Agustini, and Kadek Suartama, “Beyond One-Size-Fits-All: Mapping the Impact of Educational Technology Tools on Students’ Critical Thinking,” *Jurnal Edutech Undiksha*, vol. 13, no. 2, pp. 210–219, Dec. 2025, doi: 10.23887/jeu.v13i2.105798.
- [10] N. A. Nunez, R. Fernández-Concha, and G. Cornejo-Meza, “One size does not fit all: customizing teaching and learning strategies with Generative AI,” *Front. Educ. (Lausanne)*, vol. 11, Jan. 2026, doi: 10.3389/educ.2026.1699228.
- [11] C. Fang *et al.*, “Beyond One-Size-Fits-All: Profiling Designers’ Adoption of Generative Artificial Intelligence in Professional Design Practice,” *Int. J. Hum. Comput. Interact.*, pp. 1–27, Apr. 2026, doi: 10.1080/10447318.2026.2658255.
- [12] R. E. M. Gorter, T. Offerman, and A. van der Meulen, “Designing Guidelines for Responsible GenAI Usage in Computer Science Education,” in *2025 International Conference on Education Technology and Computers (ICETC)*, IEEE, Sep. 2025, pp. 719–726. doi: 10.1109/ICETC66579.2025.11387605.
- [13] Y. H. Al-Mamary and A. A. Abubakar, “Empowering ChatGPT adoption in higher education: A comprehensive analysis of university students’ intention to adopt artificial intelligence using self-determination and technology-to-performance chain theories,” *Internet High. Educ.*, vol. 66, p. 101015, Jun. 2025, doi: 10.1016/j.iheduc.2025.101015.
- [14] V. J. Hooper, “Cognitive offloading and the reshaping of human thought: The subtle influence of Artificial Intelligence,” *Colloquia, Academic Journal of Culture and Thought*, vol. 12, pp. 01–14, Dec. 2025, doi: 10.31207/colloquia.v12i1.185.
- [15] F. Qiu *et al.*, “Predicting students’ performance in e-learning using learning process and behaviour data,” *Sci. Rep.*, vol. 12, no. 1, p. 453, Jan. 2022, doi: 10.1038/s41598-021-03867-8.
- [16] S. J. Sultan Alalawi, I. N. Mohd Shahrane, and J. Mohd Jamil, “CLUSTERING STUDENT PERFORMANCE DATA USING k-MEANS ALGORITHMS,” *Journal of Computational Innovation and Analytics (JCIA)*, vol. 2, no. 1, pp. 41–55, Jan. 2023, doi: 10.32890/jcia2023.2.1.3.
- [17] C. Bentéjac, A. Csörgő, and G. Martínez-Muñoz, “A comparative analysis of gradient boosting algorithms,” *Artif. Intell. Rev.*, vol. 54, no. 3, pp. 1937–1967, Mar. 2021, doi: 10.1007/s10462-020-09896-5.
- [18] J. T. Hancock and T. M. Khoshgoftaar, “CatBoost for big data: an interdisciplinary review,” *J. Big Data*, vol. 7, no. 1, p. 94, Dec. 2020, doi: 10.1186/s40537-020-00369-8.
- [19] S. M. Lundberg *et al.*, “From local explanations to global understanding with explainable AI for trees,” *Nat. Mach. Intell.*, vol. 2, no. 1, pp. 56–67, Jan. 2020, doi: 10.1038/s42256-019-0138-9.
- [20] H. Khosravi *et al.*, “Explainable Artificial Intelligence in education,” *Computers and Education: Artificial Intelligence*, vol. 3, p. 100074, 2022, doi: 10.1016/j.caeai.2022.100074.
- [21] N. sisiro, “Impact of AI on students,” 2026. [Online]. Available: <https://www.kaggle.com/datasets/laveshjadon/ai-impact-on-students>
- [22] A. M. Ikotun, A. E. Ezugwu, L. Abualigah, B. Abuhaija, and J. Heming, “K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data,” *Inf. Sci. (N. Y.)*, vol. 622, pp. 178–210, Apr. 2023, doi: 10.1016/j.ins.2022.11.139.
- [23] H. Hu, J. Liu, X. Zhang, and M. Fang, “An Effective and Adaptable K-means Algorithm for Big Data Cluster Analysis,” *Pattern Recognit.*, vol. 139, p. 109404, Jul. 2023, doi: 10.1016/j.patcog.2023.109404.
- [24] C. S. Rajpoot, V. Tiwari, and S. K. Vishwakarma, “An enhanced hybrid recommender system using an adaptive optimization approach,” *Discover Artificial Intelligence*, vol. 6, no. 1, p. 402, Mar. 2026, doi: 10.1007/s44163-026-00999-6.
- [25] L. G. Baca Ruiz, D. Criado-Ramón, M. J. Serrano-Fernández, E. Pérez-Moreiras, and M. del C. Pegalajar Jiménez, “A data-driven analysis to predict energetic intelligence,” *Int. J. Data Sci. Anal.*, vol. 22, no. 1, p. 39, Dec. 2026, doi: 10.1007/s41060-026-01026-8.