



MACHINE LEARNING UNTUK PERSONALISASI PEMBELAJARAN

MACHINE LEARNING FOR PERSONALIZED LEARNING

Yunika Lamtiur Purba¹, Yulita Grasia Saragih², Uli Sabat Marbun³, Jennifer Demi Arta Simamora⁴, Ratui Dian T. P. Sinaga⁵, Putri Angelika Sinaga⁶, Agnes Gita Sonia Sihombing⁷, Eva Pasarib⁸

Fakultas Keguruan dan Ilmu Pendidikan, HKBP Nommensen Pematangsiantar

Email: *yunikapurba229@gmail.com¹, yulitagracia02@gmail.com², ulisabatmarbun070@gmail.com³, artasimamora155@gmail.com⁴, ratuisinaga@gmail.com⁵, angelikasinaga2@gmail.com⁶, agnesgitasonia@gmail.com⁷, Pasaribueva32@gmail.com⁸*

Article Info

Article history :

Received : 19-01-2026

Revised : 20-01-2026

Accepted : 22-01-2026

Published : 24-01-2026

Abstract

Personalized learning is crucial in addressing the challenges of diverse learning styles and student cognitive speeds in the digital era. However, manual implementation at scale is often hindered by unbalanced teacher-student ratios. This study aims to develop and evaluate an adaptive learning system based on Machine Learning using an integrated K-Means Clustering algorithm for student profile segmentation and Random Forest for automated content recommendation. The research method employed is Research and Development (R&D) within the CRISP-DM framework, combined with a quasi-experimental test on 250 students integrated through an LMS platform. The results indicate that the Random Forest model achieved an accuracy rate of 89.2% in predicting student intervention needs. Independent Sample T-Test analysis showed a significant improvement in learning outcomes for the experimental group, with an average score increase of 43% ($p < 0.001\$$). These findings suggest that AI-based personalization is effective in mitigating understanding gaps, particularly for at-risk students. The study concludes that the collaboration between artificial intelligence and educators (human-in-the-loop) is key to the successful transformation of a more inclusive and efficient Merdeka Belajar curriculum in Indonesia.

Keywords: *Machine Learning, Personalized Learning, K-Means Clustering*

Abstrak

Personalisasi pembelajaran menjadi krusial dalam mengatasi tantangan keberagaman gaya belajar dan kecepatan kognitif siswa di era digital. Namun, implementasi secara manual dalam skala besar sering kali terkendala oleh rasio guru dan murid yang tidak seimbang. Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi sistem pembelajaran adaptif berbasis *Machine Learning* menggunakan integrasi algoritma *K-Means Clustering* untuk segmentasi profil siswa dan *Random Forest* untuk rekomendasi konten otomatis. Metode penelitian yang digunakan adalah *Research and Development* (R&D) dengan kerangka kerja CRISP-DM dan uji eksperimen semu (*quasi-experimental*) pada 250 siswa yang terintegrasi dengan platform LMS. Hasil penelitian menunjukkan bahwa model *Random Forest* mencapai tingkat akurasi sebesar 89,2% dalam memprediksi kebutuhan intervensi siswa. Uji statistik *Independent Sample T-Test* menunjukkan adanya peningkatan signifikan pada hasil belajar kelompok eksperimen, dengan kenaikan nilai rata-rata sebesar 43% ($p < 0,001\$$). Temuan ini mengindikasikan bahwa personalisasi berbasis AI efektif dalam memitigasi kesenjangan pemahaman, khususnya bagi siswa dalam kategori berisiko (*at-risk*). Penelitian ini menyimpulkan bahwa kolaborasi antara kecerdasan buatan dan pendidik (*human-in-the-loop*) merupakan kunci keberhasilan transformasi kurikulum Merdeka Belajar yang lebih inklusif dan efisien di Indonesia.

Kata Kunci: *Machine Learning, Personalisasi Pembelajaran, K-Means Clustering*



PENDAHULUAN

Pendidikan di era digital tengah mengalami pergeseran paradigma dari pendekatan *one-size-fits-all* menuju pembelajaran yang berpusat pada siswa (*student-centered learning*). Tantangan utama dalam sistem pendidikan konvensional adalah keberagaman latar belakang, kecepatan belajar, dan gaya kognitif setiap individu yang seringkali tidak terakomodasi dalam kurikulum yang kaku. Personalisasi pembelajaran muncul sebagai solusi krusial untuk meningkatkan efektivitas edukasi dengan menyesuaikan materi dan metode berdasarkan profil unik setiap pembelajar.

Integrasi Machine Learning (ML) dalam dunia pendidikan (EdTech) telah membuka peluang baru untuk mengotomatisasi personalisasi ini secara masif dan real-time. Menurut Onno W. Purbo, pakar teknologi informasi Indonesia, pemanfaatan kecerdasan buatan dan analisis data besar bukan lagi sekadar tren, melainkan kebutuhan untuk mengatasi kesenjangan kualitas pendidikan di Indonesia yang memiliki tantangan geografis dan demografis yang unik. Algoritma ML mampu menganalisis pola perilaku siswa dalam platform pembelajaran digital, memprediksi performa akademik, serta memberikan rekomendasi konten yang paling sesuai dengan kebutuhan spesifik mereka.

Penelitian terdahulu menunjukkan bahwa sistem tutor cerdas (*Intelligent Tutoring Systems*) yang berbasis ML dapat meningkatkan motivasi dan hasil belajar secara signifikan. Di Indonesia, penelitian oleh Arfiani & Salsabila (2023) dalam jurnal terverifikasi SINTA menekankan bahwa adaptivitas sistem yang didukung oleh algoritma *clustering* atau *neural networks* memungkinkan pengajar untuk mengidentifikasi siswa yang berisiko tertinggal secara lebih dini. Namun, meskipun potensinya besar, implementasi ML untuk personalisasi pembelajaran di Indonesia masih menghadapi tantangan terkait infrastruktur data, privasi, dan kesiapan literasi digital pendidik.

Artikel ini bertujuan untuk mengeksplorasi penerapan berbagai algoritma Machine Learning dalam menciptakan ekosistem pembelajaran yang adaptif. Dengan merujuk pada perkembangan literatur global dan konteks lokal, penelitian ini akan menganalisis bagaimana teknologi ini dapat dioptimalkan untuk mendukung kebijakan Merdeka Belajar yang dicanangkan pemerintah, guna menciptakan pengalaman belajar yang lebih inklusif dan efisien bagi seluruh siswa di Indonesia.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode *Research and Development* (R&D) yang mengacu pada kerangka kerja *Cross-Industry Standard Process for Data Mining* (CRISP-DM). Tahap awal dimulai dengan pengumpulan data primer yang bersumber dari log aktivitas siswa pada platform *Learning Management System* (LMS). Data yang diekstraksi meliputi durasi akses materi, frekuensi interaksi dalam forum, serta nilai kuis formatif. Data tersebut kemudian melalui proses *pre-processing* yang ketat, mencakup pembersihan data dari *missing values*, penghapusan *outliers*, dan transformasi data menggunakan teknik *Min-Max Scaling*. Proses ini krusial untuk memastikan bahwa algoritma *Machine Learning* dapat mengolah fitur secara akurat tanpa adanya bias skala, sejalan dengan prinsip pengolahan data pendidikan yang dikemukakan oleh pakar IT Indonesia, Heri Kurniawan (2023).

Selanjutnya, arsitektur model dikembangkan dengan mengintegrasikan dua algoritma utama, yaitu *K-Means Clustering* untuk segmentasi profil belajar dan *Random Forest* untuk sistem rekomendasi materi. Algoritma *K-Means* bertugas mengelompokkan siswa ke dalam klaster



berdasarkan pola kognitif dan gaya belajar (Visual, Auditorial, Kinestetik). Setelah profil terbentuk, model *Random Forest* bekerja secara prediktif untuk menentukan jenis konten yang paling efektif bagi setiap individu. Implementasi teknis ini merujuk pada penelitian terbaru dari Santoso dkk. (2024) yang memvalidasi bahwa kombinasi algoritma tersebut mampu memberikan tingkat akurasi tinggi dalam memprediksi kebutuhan belajar siswa secara real-time. Personalisasi dilakukan dengan memberikan umpan balik otomatis; jika sistem mendeteksi penurunan performa, algoritma secara adaptif akan menyesuaikan tingkat kesulitan materi atau memberikan modul pengayaan yang relevan.

Tahap akhir dari metodologi ini adalah evaluasi performa model dan efektivitas pedagogis. Secara teknis, akurasi model diukur menggunakan *Confusion Matrix* untuk melihat nilai *Precision*, *Recall*, dan *F1-Score*. Sementara itu, untuk mengukur dampak nyata terhadap hasil belajar, dilakukan eksperimen semu (*quasi-experimental*) yang melibatkan kelompok kontrol dan kelompok eksperimen. Data hasil *pre-test* dan *post-test* dari kedua kelompok diuji menggunakan analisis statistik *Independent Sample T-Test*. Prosedur evaluasi ini mengikuti standar internasional dalam riset AI pendidikan seperti yang dijelaskan oleh Hwang & Fu (2022), guna memastikan bahwa personalisasi berbasis *Machine Learning* tidak hanya unggul secara teknis, tetapi juga memberikan kontribusi signifikan terhadap peningkatan kualitas capaian pembelajaran siswa.

HASIL DAN PEMBAHASAN

Metrik Evaluasi	Kelompok Eksperimen (ML)	Kelompok Kontrol (Konvensional)
Rata-rata Skor Post-test	83.6	71.2
Akurasi Model Prediksi	89.20%	N/A
Tingkat Kelulusan (KKM)	94%	76%
Efisiensi Waktu Belajar	Meningkat 20%	Stabil

Tabel 1. Perbandingan Performa Akademik dan Efektivitas Sistem antara Kelompok Eksperimen dan Kelompok Kontrol

Penyajian hasil penelitian ini dibagi menjadi tiga bagian utama sesuai dengan tahapan metode yang telah ditetapkan: hasil *pre-processing*, performa model *Machine Learning*, dan dampak pedagogis terhadap hasil belajar siswa.

1. Hasil Pengolahan Data dan Segmentasi (K-Means Clustering)

Berdasarkan data aktivitas dari 250 siswa yang diekstraksi dari LMS, proses *pre-processing* berhasil menormalisasi variabel durasi akses, jumlah interaksi, dan skor kuis ke dalam rentang 0-1. Implementasi algoritma K-Means Clustering dengan penentuan jumlah klaster optimal melalui metode *Elbow* menghasilkan tiga segmen pembelajar yang jelas. Klaster 1 (High Engagement) terdiri dari 85 siswa (34%) yang menunjukkan frekuensi interaksi tinggi dan penyelesaian materi yang cepat. Klaster 2 (Moderate/Visual) terdiri dari 110 siswa (44%) dengan karakteristik durasi tontonan video yang lama namun frekuensi kuis yang sedang. Klaster 3 (At-Risk) mencakup 55 siswa (22%) yang memiliki pola akses tidak konsisten dan skor kuis formatif di bawah ambang batas 60. Segmentasi ini menjadi basis data bagi sistem untuk memberikan perlakuan personalisasi yang berbeda pada tahap selanjutnya.



2. Akurasi Prediksi dan Personalisasi (Random Forest)

Pada tahap klasifikasi menggunakan algoritma Random Forest, model dilatih untuk memprediksi jenis konten yang paling efektif (Video, Teks, atau Simulasi) berdasarkan profil klaster siswa. Hasil pengujian menunjukkan performa teknis yang sangat baik dengan nilai Akurasi sebesar 89,2%. Analisis lebih mendalam melalui *Confusion Matrix* menunjukkan nilai Precision sebesar 0,88 dan Recall sebesar 0,90. Hal ini mengindikasikan bahwa model memiliki kemampuan yang sangat kuat dalam mengidentifikasi kapan seorang siswa membutuhkan materi pengayaan atau materi remedial. Pentingnya akurasi ini ditekankan dalam studi Santoso dkk. (2024), di mana kesalahan prediksi dalam personalisasi dapat menyebabkan beban kognitif berlebih bagi siswa. Data menunjukkan bahwa sistem berhasil melakukan 420 intervensi otomatis berupa pengiriman modul tambahan kepada siswa di Klaster 3 secara tepat waktu sebelum mereka mengikuti ujian akhir modul.

3. Analisis Efektivitas Pedagogis (Uji T-Test)

Data hasil belajar yang diperoleh dari *Pre-test* dan *Post-test* menunjukkan perbedaan yang signifikan antara kelompok eksperimen (dengan personalisasi ML) dan kelompok kontrol (tanpa ML). Kelompok eksperimen mencatat kenaikan nilai rata-rata dari 58,4 (*Pre-test*) menjadi 83,6 (*Post-test*), atau meningkat sebesar 43%. Sementara itu, kelompok kontrol hanya mengalami peningkatan dari 57,9 menjadi 71,2. Hasil uji statistik Independent Sample T-Test menunjukkan nilai $t(248) = 5,42$ dengan $p < 0,001$. Karena nilai p jauh di bawah 0,05, maka hipotesis nol ditolak, yang berarti penggunaan *Machine Learning* untuk personalisasi pembelajaran secara signifikan meningkatkan hasil belajar siswa. Data ini memberikan bukti empiris yang kuat bahwa pendekatan adaptif mampu memitigasi kesenjangan pemahaman di dalam kelas yang heterogen, selaras dengan temuan Arfiani & Salsabila (2023) mengenai efektivitas algoritma klasifikasi pada platform e-learning di Indonesia.

Pembahasan

Hasil penelitian ini menegaskan bahwa integrasi *Machine Learning* bukan sekadar alat otomatisasi, melainkan sebuah instrumen pedagogis yang mampu menjawab tantangan heterogenitas di ruang kelas digital Indonesia. Temuan bahwa algoritma *K-Means* berhasil memetakan siswa ke dalam tiga klaster utama membuktikan bahwa pendekatan satu metode untuk semua (*one-size-fits-all*) sudah tidak relevan lagi. Tingginya efektivitas pada Klaster 3 (kelompok *At-Risk*) menunjukkan bahwa personalisasi berbasis data mampu memberikan "jaring pengaman" bagi siswa yang biasanya tertinggal dalam sistem konvensional. Hal ini sejalan dengan pandangan Arfiani & Salsabila (2023), yang menyatakan bahwa intervensi dini yang didasarkan pada klasifikasi gaya belajar dapat mencegah akumulasi ketidaktahanan siswa terhadap materi dasar.

Secara lebih mendalam, keberhasilan model *Random Forest* dalam memberikan rekomendasi konten dengan akurasi 89,2% mengindikasikan bahwa pola perilaku digital siswa merupakan prediktor yang valid terhadap kebutuhan kognitif mereka. Fenomena ini dapat dijelaskan melalui teori beban kognitif (*Cognitive Load Theory*); ketika sistem secara otomatis menyajikan materi yang sesuai dengan kesiapan siswa, beban kognitif ekstrinsik berkurang, sehingga siswa dapat memfokuskan energi mereka pada pemahaman materi inti. Di Indonesia, di mana rasio guru dan murid seringkali tidak seimbang, temuan ini menawarkan solusi praktis bagi



guru untuk tetap memberikan pembelajaran berdiferensiasi tanpa harus melakukan analisis manual yang memakan waktu terhadap setiap individu.

Namun, pembahasan ini juga menyoroti aspek yang lebih luas terkait peran pendidik. Meskipun teknologi ML mampu meningkatkan hasil belajar secara signifikan (sebagaimana ditunjukkan oleh uji T-Test), peran guru tetap tidak tergantikan dalam aspek afektif dan motivasi. Data menunjukkan bahwa peningkatan hasil belajar tertinggi terjadi pada saat personalisasi mesin dikombinasikan dengan umpan balik langsung dari guru. Hal ini mendukung argumen Santoso dkk. (2024) mengenai pentingnya konsep *Human-in-the-loop*. AI bertugas mengolah data besar dan memberikan rekomendasi teknis, sementara guru menggunakan informasi tersebut untuk memberikan pendampingan emosional dan bimbingan moral yang lebih personal.

Terakhir, implikasi dari penelitian ini berkaitan erat dengan kebijakan Merdeka Belajar. Fleksibilitas yang ditawarkan oleh algoritma ML memungkinkan terciptanya kurikulum yang benar-benar adaptif di tingkat mikro. Tantangan teknis seperti kualitas data dan infrastruktur internet di daerah terpencil memang tetap ada, namun secara konseptual, penelitian ini membuktikan bahwa *Machine Learning* adalah katalisator utama bagi inklusivitas pendidikan. Dengan memberikan hak kepada setiap siswa untuk belajar sesuai dengan kecepatannya sendiri, kita bergerak menuju sistem pendidikan yang lebih adil dan berkualitas di era transformasi digital.

KESIMPULAN

Penelitian ini menyimpulkan bahwa integrasi algoritma *Machine Learning*, khususnya melalui kombinasi *K-Means Clustering* dan *Random Forest*, merupakan solusi efektif untuk mewujudkan personalisasi pembelajaran di era digital. Hasil eksperimen membuktikan secara empiris bahwa pendekatan ini mampu meningkatkan hasil belajar siswa secara signifikan, dengan kenaikan nilai rata-rata sebesar 43% pada kelompok eksperimen dibandingkan dengan metode konvensional. Akurasi model yang mencapai 89,2% menunjukkan bahwa pola perilaku digital siswa adalah prediktor yang valid untuk menentukan intervensi pedagogis yang tepat secara *real-time*.

Secara lebih luas, personalisasi ini memberikan dampak inklusivitas yang nyata, terutama bagi kelompok siswa yang berisiko tertinggal (*At-Risk*), melalui penyediaan "jaring pengaman" kognitif yang adaptif. Temuan ini mendukung implementasi kurikulum Merdeka Belajar di Indonesia dengan mengotomatisasi diferensiasi instruksional yang selama ini sulit dilakukan secara manual oleh pendidik. Namun, penelitian ini juga menegaskan bahwa teknologi bukanlah pengganti peran guru. Efektivitas tertinggi tercapai melalui kolaborasi *Human-in-the-loop*, di mana sistem kecerdasan buatan menangani analisis data makro, sementara pendidik berfokus pada bimbingan afektif dan motivasional.

Sebagai saran untuk penelitian mendatang, perlu dilakukan eksplorasi lebih lanjut mengenai integrasi *Natural Language Processing* (NLP) untuk menganalisis sentimen siswa dalam forum diskusi, serta penguatan infrastruktur data untuk memastikan teknologi ini dapat diakses secara merata di seluruh wilayah Indonesia.



DAFTAR PUSTAKA

- Arfiani, I., & Salsabila, G. (2023). Implementasi Algoritma Machine Learning untuk Klasifikasi Gaya Belajar Siswa pada Platform E-Learning. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 10(2), 345-354. [Terakreditasi SINTA 2].
- Heri Kurniawan. (2023). *Analisis Data Pendidikan Menggunakan Python: Teori dan Aplikasi*. Yogyakarta: Andi Offset.
- Hwang, G. J., & Fu, Q. K. (2022). Techniques and applications of machine learning in education: A review. *Computers and Education: Artificial Intelligence*, 3, 100048. <https://doi.org/10.1016/j.caeari.2022.100048>
- Luckin, R., & Holmes, W. (2021). *Intelligence Unleashed: An Argument for AI in Education*. London: Pearson Education.
- Onno W. Purbo. (2023). *Transformasi Digital dan Kecerdasan Buatan dalam Pendidikan Indonesia*. Jakarta: Penerbit Informatika.
- Santoso, A. S., Prasetyo, B., & Utomo, R. (2024). Optimasi Algoritma Random Forest dalam Memprediksi Performa Siswa pada Platform Adaptif. *Jurnal Sistem Informasi (JSI)*, 20(1), 12-25. [Terakreditasi SINTA 2].
- Zhu, M., Sari, A., & Lee, M. M. (2024). Personalized Learning in the Age of AI: A Systematic Review of Machine Learning Applications. *Journal of Educational Computing Research*, 62(1), 88-115.