

Sistem Rekomendasi Minat Siswa Berbasis AI Untuk Peningkatan Perencanaan Pendidikan Strategis

AI-BASED STUDENT INTEREST RECOMMENDER SYSTEMS FOR ENHANCED STRATEGIC EDUCATIONAL PLANNING

Kunsuswandono Suryo Bagus Sutojo^{1)*} 

¹ SMK Atisa Dipamkara, Kota Tangerang, Indonesia, kunsuswandono.suryo@student.pradita.ac.id

Abstrak

Perencanaan strategis di sekolah menengah atas semakin memerlukan perkakas yang akurat untuk menyelaraskan minat siswa dengan jalur akademik dan ekstrakurikuler. Namun, banyak institusi masih bersandar pada asesmen manual dan bimbingan yang digeneralisasi, yang kerap gagal mencerminkan preferensi dan potensi unik setiap siswa. Kajian ini memperkenalkan sistem pemberi rekomendasi minat siswa berbasis AI yang dirancang untuk menunjang perencanaan pendidikan strategis pada jenjang sekolah menengah atas. Sistem ini memanfaatkan teknik *Collaborative Filtering* untuk menganalisis pola dari kinerja akademik, partisipasi klub siswa, dan pilihan mata pelajaran elektif di seluruh 1.200 profil siswa sekolah menengah atas. Model faktorisasi matriks hibrida yang digabungkan dengan penyaringan berbasis ketetanggaan (*neighborhood-based filtering*) diimplementasikan untuk meningkatkan personalisasi dalam rekomendasi. Hasilnya menunjukkan bahwa sistem ini mencapai akurasi 87,6% dalam merekomendasikan jalur akademik dan program ekstrakurikuler yang relevan. Selain itu, administrator sekolah melaporkan peningkatan pengambilan keputusan dalam perencanaan kurikulum dan alokasi sumber daya berdasarkan wawasan dari sistem tersebut. Riset ini menyoroti nilai integrasi sistem pemberi rekomendasi berbasis AI ke dalam perencanaan strategis sekolah menengah atas. Hal ini tidak hanya menunjang bimbingan siswa, tetapi juga upaya institusional untuk menyampaikan program pendidikan yang lebih personal dan efektif yang selaras dengan aspirasi siswa dan sasaran sekolah.

Kata kunci: Kecerdasan Buatan; Sistem Rekomendasi; *Collaborative Filtering*; Perencanaan Edukasi; Sekolah Menengah Atas

Abstract

Strategic planning in high schools increasingly requires accurate tools to align student interests with academic and extracurricular pathways. However, many institutions still rely on manual assessments and generalized guidance, which often fail to reflect the unique preferences and potentials of each student. This study introduces an AI-based student interest recommender system designed to support strategic educational planning at the high school level. The system utilizes collaborative filtering techniques to analyze patterns from academic performance, student club participation, and elective subject choices across 1,200 high school student profiles. A hybrid matrix factorization model combined with neighborhood-based filtering was implemented to enhance personalization in recommendations. The results demonstrate that the system achieved 87.6% accuracy in recommending relevant academic tracks and extracurricular programs. Additionally, school administrators reported improved decision-making in curriculum planning and resource allocation based on the system's insights. This research highlights the value of integrating AI-driven recommender systems into high school strategic planning. It supports

not only student guidance but also institutional efforts to deliver more personalized and effective educational programs aligned with student aspirations and school goals.

Keywords: Artificial Intelligence; Recommender System; Collaborative Filtering; Educational Planning; High School

Article history: Received 30 November 2025, Accepted 24 December 2025, Available online 30 April 2026

1 PENDAHULUAN

Pesatnya kemajuan transformasi digital dalam pendidikan telah mendorong lembaga-lembaga untuk mengadopsi teknologi kecerdasan buatan (AI) guna menopang pengambilan keputusan strategis. Pada jenjang sekolah menengah atas, salah satu tantangan utama adalah menyelaraskan minat siswa dengan jalur akademik dan program ekstrakurikuler dengan cara yang mencerminkan preferensi dan potensi pribadi mereka. Sayangnya, banyak sekolah masih bersandar pada bimbingan manual atau alur umum yang gagal mempersonalisasi perencanaan pendidikan secara efektif.

Terinspirasi oleh kesuksesan sistem pemberi rekomendasi dalam ranah seperti e-commerce dan hiburan, institusi pendidikan telah mulai memanfaatkan teknologi serupa untuk mempersonalisasi pengalaman belajar. Di antara teknik-teknik ini, Collaborative Filtering (CF) telah muncul sebagai teknik unggulan yang mengidentifikasi pola berdasarkan kemiripan antar pengguna, memungkinkan rekomendasi yang lebih personal dan didukung data.

Kajian ini mengusulkan sistem pemberi rekomendasi minat siswa berbasis AI menggunakan Collaborative Filtering untuk membantu sekolah menengah atas meningkatkan perencanaan strategis pendidikan mereka. Sistem ini dirancang tidak hanya untuk menyediakan saran akademik dan ekstrakurikuler yang relevan kepada siswa, tetapi juga berfungsi sebagai perkakas penunjang keputusan bagi perencana institusi dalam mengembangkan kurikulum yang adaptif, mengalokasikan sumber daya secara efisien, dan meramalkan permintaan program.

Selain tantangan penyelarasan minat, sekolah juga menghadapi keterbatasan sumber daya manusia dan waktu dalam memberikan bimbingan yang terindividualisasi. Konselor dan guru kerap mengelola sejumlah besar siswa dengan latar belakang dan aspirasi yang beragam, sehingga sulit untuk menawarkan dukungan yang benar-benar personal. Seiring dengan tumbuhnya tuntutan akan pendidikan yang berpusat pada siswa, sistem pemberi rekomendasi berbasis AI menghadirkan solusi praktis. Sistem ini dapat memroses data dalam volume besar secara efisien dan memberikan saran berbasis bukti, menghemat waktu seraya meningkatkan keakuratan pengambilan keputusan dalam perencanaan akademik dan pengembangan siswa.

Implementasi sistem pemberi rekomendasi berbasis Collaborative Filtering selaras dengan pergeseran yang lebih luas menuju pendidikan berbasis data, yang menekankan peran analitik dalam meningkatkan mutu pengajaran dan layanan institusional. Dengan mengintegrasikan sistem semacam itu ke dalam perencanaan strategis pendidikan, sekolah dapat merancang alur belajar yang lebih luwes dan responsif yang disesuaikan dengan kebutuhan siswa yang terus berkembang. Selain itu, sistem ini memungkinkan pelacakan berkelanjutan terhadap minat dan kemajuan siswa, yang sangat krusial untuk membangun kurikulum adaptif dalam lanskap pendidikan yang senantiasa berubah. Oleh karena itu, kajian ini berpotensi memberikan sumbangan yang signifikan terhadap transformasi teknologi pendidikan.

2 METODE PENELITIAN

Metodologi ini melibatkan pengumpulan dan prapemrosesan data siswa, termasuk nilai akademik, pilihan mata pelajaran elektif, dan preferensi ekstrakurikuler. Dengan menggunakan data ini, akan dikembangkan matriks interaksi pengguna-item. Dua pendekatan Collaborative Filtering akan diterapkan: penyaringan berbasis pengguna (user-based filtering) untuk menemukan siswa dengan minat serupa dan penyaringan berbasis item (item-based filtering) untuk mengidentifikasi jalur akademik yang paling sering dipilih oleh profil-profil serupa.

TABEL 1. CONTOH DATA MINAT SISWA

Nama Siswa	Matematika	IPAS	Musik	Olahraga	Informatika
Erick	1	1	1	0	1
Vanessa	1	1	1	0	0
Christian	0	1	1	1	1
Joy	0	1	1	1	0
Vee	0	0	1	1	0

Langkah pertama adalah mengumpulkan data minat siswa dan memrosesnya menjadi matriks utilitas. Setiap baris dalam matriks di atas dapat dianggap sebagai vektor minat. Hitunglah seberapa serupa satu siswa dengan siswa lainnya menggunakan Rumus Similiaritas Kosinus (Cosine Similarity Formula).

$$\text{Similiaritas Kosinus}(A, B) = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}}$$

TABEL 2. DATA MINAT SISWA YANG TELAH DIHITUNG DENGAN RUMUS SIMILIARITAS KOSINUS

Nama Siswa	Matematika	IPAS	Musik	Olahraga	Informatika	Total
Erick	1	1	1	0	1	4
Vanessa	1	1	1	0	0	3
A · B	1	1	1	0	0	3
$\ A\ ^2$	1	1	1	0	1	4
$\ B\ ^2$	1	1	1	0	0	3
						0.8660254038

Nama Siswa	Matematika	IPAS	Musik	Olahraga	Informatika	Total
Joy	0	1	1	1	0	3
Vee	0	0	1	1	0	2
A · B	0	0	1	1	0	2
$\ A\ ^2$	0	1	1	1	0	3
$\ B\ ^2$	0	0	1	1	0	2
						0.8164965809

Skor similaritas untuk minat di antara dua peserta didik adalah 0,8660254038. Nilai ini sangat dekat dengan 1, yang mengindikasikan bahwa mereka memiliki minat yang sangat serupa.

TABEL 3. DAFTAR DATA K-NN

Nama Siswa	k-NN
Erick	0.8660254038
Vanessa	0.8660254038
Joy	0.8164965809
Vee	0.8164965809

Setelah menghitung skor similaritas di antara peserta didik sasaran dan semua peserta didik yang lain, kita mengurutkannya dari yang tertinggi hingga yang terendah. Kemudian, kita memilih k peserta didik yang paling serupa (mirip). Kelompok peserta didik ini disebut tetangga terdekat k (k-nearest neighbors atau k-NN).

TABEL 4. CONTOH SASARAN DATA

Siswa Target	Minat Target	k=2	Minat k=2
Erick	Matematika, IPAS, Musik & Informatika	Vanessa	Matematika, IPAS & Musik

Langkah akhir adalah mengidentifikasi setiap minat yang dimiliki oleh peserta didik tersebut, yang belum dimiliki oleh peserta didik sasaran. Minat-minat ini akan menjadi masukan untuk rekomendasi. Dengan demikian, sistem akan merekomendasikan Informatika kepada Vanessa. Logikanya adalah, karena Vanessa memiliki minat yang sangat serupa dengan Erick, ada kemungkinan besar Vanessa juga akan menyukai Informatika.

Evaluasi model akan dilaksanakan menggunakan metrik sistem pemberi rekomendasi standar seperti Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE).

TABEL 5. CONTOH KUMPULAN DATA SISWA

ID Siswa	Nilai Tugas (Input Model)	Nilai Kuis (Input Model)	Nilai Aktual Ujian (y_i)	Nilai Prediksi Ujian (\hat{y}_i)
242510015	85	78	80	82
242510016	70	75	72	70
242510017	92	88	95	90
242510020	65	70	68	75

$$e_i = Y_i - \hat{Y}_i$$

$$\text{Kuadrat Selisih} = (Y_i - \hat{Y}_i)^2$$

Untuk menghitung Root Mean Square Error (RMSE), dibutuhkan himpunan data untuk setiap peserta didik. Setelah itu, hitung Selisih (Residu) dan Kuadratkan Selisih tersebut dari data peserta didik.

$$\text{SSE} = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Setelah itu, jumlahkan semua nilai selisih kuadrat dari semua peserta didik untuk memperoleh Jumlah Kuadrat Galat (Sum of Squared Errors - SSE). Setelah itu, bagi total selisih kuadrat dengan jumlah observasi (N) untuk memperoleh Galat Kuadrat Rata-Rata

(Mean Squared Error - MSE) dan akhirnya, ambil akar kuadrat dari MSE untuk memperoleh Galat Kuadrat Rata-Rata Akar (Root Mean Square Error - RMSE).

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Kami membagi himpunan data menjadi subset pelatihan (80%) dan pengujian (20%). Metrik evaluasi mencakup Galat Mutlak Rata-Rata (Mean Absolute Error - MAE), Galat Kuadrat Rata-Rata Akar (Root Mean Square Error - RMSE), dan akurasi Top-N. Sebuah antarmuka pengguna juga dirancang untuk interaksi peserta didik dan konselor. Pada gambar berikut adalah sebuah contoh implementasi dari Root Mean Squared Error (RMSE) dalam bahasa pemrograman Python.

```
import pandas as pd
import numpy as np
from sklearn.metrics import mean_squared_error

data_siswa = {
    'ID_Siswa': ['S001', 'S002', 'S003', 'S004', 'S005', 'S006', 'S007', 'S008', 'S009', 'S010'],
    'Nilai_Aktual_Ujian': [85, 70, 92, 65, 78, 88, 72, 95, 60, 80],
    'Nilai_Prediksi_Ujian': [83, 72, 90, 68, 75, 90, 70, 93, 63, 77]
}

df_nilai = pd.DataFrame(data_siswa)

print("Data Nilai Siswa:")
print(df_nilai)

y_aktual = df_nilai['Nilai_Aktual_Ujian']
y_prediksi = df_nilai['Nilai_Prediksi_Ujian']

perbedaan = y_aktual - y_prediksi
print(f"\nPerbedaan (Residual) per Siswa:\n{perbedaan}")

kuadrat_perbedaan = perbedaan**2
print(f"\nKuadrat Perbedaan per Siswa:\n{kuadrat_perbedaan}")

sse = np.sum(kuadrat_perbedaan)
print(f"\nSum of Squared Errors (SSE): {sse}")

N = len(y_aktual)
mse = sse / N
print(f"Mean Squared Error (MSE): {mse}")

rmse = np.sqrt(mse)
print(f"Root Mean Squared Error (RMSE): {rmse:.2f}")

rmse_sklearn = np.sqrt(mean_squared_error(y_aktual, y_prediksi))
print(f"\nRMSE menggunakan Scikit-learn: {rmse_sklearn:.2f}")
```

GAMBAR 1. ROOT MEAN SQUARED ERROR (RMSE) DALAM BAHASA PEMROGRAMAN PYTHON

```
Data Nilai Siswa:
  ID_Siswa  Nilai_Aktual_Ujian  Nilai_Prediksi_Ujian
0   S001           85           83
1   S002           70           72
2   S003           92           90
3   S004           65           68
4   S005           78           75
5   S006           88           90
6   S007           72           70
7   S008           95           93
8   S009           60           63
9   S010           80           77
```

GAMBAR 2. OUTPUT ROOT MEAN SQUARED ERROR (RMSE) DALAM BAHASA PEMROGRAMAN PYTHON

```
Perbedaan (Residual) per Siswa:
0  2
1 -2
2  2
3 -3
4  3
5 -2
6  2
7  2
8 -3
9  3
dtype: int64

Kuadrat Perbedaan per Siswa:
0  4
1  4
2  4
3  9
4  9
5  4
6  4
7  4
8  9
9  9
dtype: int64
```

GAMBAR 3. OUTPUT ROOT MEAN SQUARED ERROR (RMSE) DALAM BAHASA PEMROGRAMAN PYTHON

Dan pada gambar berikut adalah sebuah contoh implementasi dari Mean Squared Error (MSE) dalam bahasa pemrograman Python.

```
import pandas as pd
import numpy as np
from sklearn.metrics import mean_squared_error

data_siswa = {
    'ID Siswa': ['S001', 'S002', 'S003', 'S004', 'S005', 'S006', 'S007', 'S008', 'S009', 'S010'],
    'Nilai_Aktual_Ujian': [85, 70, 92, 65, 78, 88, 72, 95, 60, 80],
    'Nilai_Prediksi_Ujian': [83, 72, 90, 68, 75, 90, 70, 93, 63, 77]
}

df_nilai = pd.DataFrame(data_siswa)

print("Data Nilai Siswa:")
print(df_nilai)

y_aktual = df_nilai['Nilai_Aktual_Ujian']
y_prediksi = df_nilai['Nilai_Prediksi_Ujian']

perbedaan = y_aktual - y_prediksi
print(f"\nPerbedaan (Residual) per Siswa:\n{perbedaan}")

kuadrat_perbedaan = perbedaan**2
print(f"\nKuadrat Perbedaan per Siswa:\n{kuadrat_perbedaan}")

sse = np.sum(kuadrat_perbedaan)
print(f"\nSum of Squared Errors (SSE): {sse}")

N = len(y_aktual)
mse = sse / N
print(f"Mean Squared Error (MSE): {mse:.2f}") # Format ke 2 desimal

mse_sklearn = mean_squared_error(y_aktual, y_prediksi)
print(f"\nMSE menggunakan Scikit-learn: {mse_sklearn:.2f}")
```

GAMBAR 4. MEAN SQUARED ERROR (MSE) DALAM BAHASA PEMROGRAMAN PYTHON

```
Data Nilai Siswa:
  ID_Siswa  Nilai_Aktual_Ujian  Nilai_Prediksi_Ujian
0   S001           85           83
1   S002           70           72
2   S003           92           90
3   S004           65           68
4   S005           78           75
5   S006           88           90
6   S007           72           70
7   S008           95           93
8   S009           60           63
9   S010           80           77
```

Perbedaan (Residual) per Siswa:

```
0    2
1   -2
2    2
3   -3
4    3
5   -2
6    2
7    2
8   -3
9    3
dtype: int64
```

Kuadrat Perbedaan per Siswa:

```
0    4
1    4
2    4
3    9
4    9
5    4
6    4
7    4
8    9
9    9
dtype: int64
```

```
Sum of Squared Errors (SSE): 60
Mean Squared Error (MSE): 6.00
```

GAMBAR 5. OUTPUT MEAN SQUARED ERROR (MSE) DALAM BAHASA PEMROGRAMAN PYTHON

3 HASIL DAN PEMBAHASAN

Sistem tersebut mencapai akurasi Top-5 rata-rata sebesar 87,6%, yang mengindikasikan bahwa program yang direkomendasikan memiliki kesesuaian yang erat dengan pilihan peserta didik. MAE dan RMSE berada dalam ambang batas yang dapat diterima (MAE = 0,59, RMSE = 0,71). Umpan balik dari pengujian purwarupa menunjukkan peningkatan keyakinan di antara konselor dalam memberi saran lintasan peserta didik.

TABEL 5. HASIL

Aspect of Analysis	Findings	Strategic Implications
Total number of students	200 students from multiple public high schools in West Java	Adequate for testing the simulation of a recommendation system
Recommendation accuracy	87.6% of system recommendations matched actual student academic track choices	Collaborative filtering model is effective for personalizing educational pathways
Academic tracks included	Science (IPA), Social Science (IPS), Language (Bahasa)	System can differentiate tracks based on scores and interest profiles
Average subject scores	Math, English, and Science scores centered around ± 75	Reflects realistic academic performance distribution among high school students
Student interests (extracurriculars)	Robotics, Debate, Biology Club, Theater, Journalism, etc.	Interests help shape more holistic student profiles for better recommendations
Mismatch rate	Approximately 12–15% of students received different recommendations from actual track choices	Indicates potential need for hybrid recommendation models or counselor intervention
School variety	5 different public high schools	The model adapts well to diverse educational environments
Limitations (cold start, data bias)	Cold start problem for new students; possible bias due to limited diversity in training data	Suggests integrating hybrid models and feedback loops involving teachers or counselors
Future development potential	Include psychological, career preference, and longitudinal academic data	Enables institutions to plan long-term policies using more comprehensive student data

Administrator menggunakan data rekomendasi teragregasi untuk memberi masukan penyesuaian kurikulum dan peramalan sumber daya. Selain itu, peserta didik mengungkapkan motivasi yang lebih besar ketika diberikan saran yang didorong oleh pilihan. Pendekatan penyaringan kolaboratif mendemonstrasikan adaptabilitas terhadap data baru, mendukung penyempurnaan berkelanjutan.

4 KESIMPULAN

Penelitian ini menyoroti potensi strategis sistem pemberi rekomendasi berbasis AI dalam menyelaraskan penawaran edukasi dengan minat peserta didik pada jenjang sekolah menengah atas. Dengan memanfaatkan penyaringan kolaboratif, sekolah dapat memersonalisasi rencana pembelajaran dengan lebih baik, meningkatkan kepuasan, dan mendukung tujuan institusional melalui perencanaan berbasis data. Pengembangan lebih lanjut dari sistem ini dapat diperluas ke jenjang edukasi yang lain dan menggabungkan variabel yang lebih luas seperti peramalan karier dan pemprofilan sosio-emosional.

DAFTAR PUSTAKA

- Abulibdeh, A. (2025). A scoping review of the strategic integration of artificial intelligence in higher education: Transforming university excellence themes and strategic planning in the digital era. *European Journal of Education*, 60(2), 229–248.
- Chan, T. C. (2023). A comprehensive AI policy education framework for university teaching and learning. *International Journal of Educational Technology in Higher Education*, 20(1), 13.
- George, A., & Wooden, S. (2023). Managing the strategic transformation of higher education through artificial intelligence. *Administrative Sciences*, 13(9), 196.
- Koukaras, P., Dasygenis, M., & Lavdas, M. (2025). Revolutionising educational management with AI and wireless networks: A framework for smart resource allocation and decision-making. *Applied Sciences*, 15(10), 5293.
- Sajja, P. S., & Jha, S. (2023). Artificial intelligence-enabled intelligent assistant for personalized and adaptive learning in higher education. arXiv preprint. arXiv:2309.10892.
- Castro, F., Vellido, A., Nebot, À., & Mugica, F. (2020). Applying Recommender Systems in the Educational Domain: A Review. *Expert Systems with Applications*, 138, 112817.
- Lu, J., Wu, D., Mao, M., Wang, W., & Zhang, G. (2020). Recommender System Application Developments: A Survey. *Decision Support Systems*, 132, 113301.
- Kumar, V., & Thakur, R. (2021). AI-based Recommender Systems in Education: A Strategic Tool for Institutional Planning. *International Journal of Educational Technology in Higher Education*, 18(1), 1–20.
- Liu, T., Wu, Q., Chang, L., & Gu, T. (2022). "A review of deep learning-based recommender systems in e-learning environments". *Artificial Intelligence Review*, 55, 5953–5980.
- Iwendi, C., Ibeke, E., Eggoni, H., Velagala, S., & Srivastava, G. (2022). "Pointer-based item-to-item collaborative filtering recommendation system using a machine learning model". *International Journal of Information Technology & Decision Making*, 21, 463–484.

Kutipan Artikel

Kunsuswandono Suryo Bagus Sutojo (2026), *Sistem Rekomendasi Minat Siswa Berbasis AI Untuk Peningkatan Perencanaan Pendidikan Strategis*, JII, Vol: 08, No: 01, Hal: 23-33: April. DOI: <http://doi.org/10.51170/jii.v8i1.332>