

Perancangan Sistem Rekomendasi Pemilihan Model Artificial Intelligence Menggunakan Metode Content Based Filtering

Valen Purwaixna Saputra^{1*}, Bayu Susilo Aji Nugroho², Adi Tegar Setiawan³, Atik Setyaningsih⁴,
Febrian Maulana⁵, Vihi Atina⁶

¹Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa Surakarta

^{1*}230103079@mhs.udb.ac.id

²Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa Surakarta

²230103053@mhs.udb.ac.id

³Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa Surakarta

³230103044@mhs.udb.ac.id

⁴Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa Surakarta

⁴230103052@mhs.udb.ac.id

⁵Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa Surakarta

⁵230103060@mhs.udb.ac.id

Abstrak— Perkembangan teknologi Artificial Intelligence (AI) yang semakin pesat menghadirkan berbagai model AI dengan karakteristik dan kemampuan yang berbeda-beda sehingga pengguna sering mengalami kesulitan dalam menentukan model yang paling sesuai dengan kebutuhannya. Penelitian ini bertujuan untuk merancang sistem rekomendasi pemilihan platform Artificial Intelligence menggunakan metode Content-Based Filtering (CBF) berdasarkan kemiripan karakteristik setiap model AI. Dataset penelitian terdiri atas 40 model AI yang direpresentasikan menggunakan enam atribut, yaitu Context Window, Intelligence Index, Price, Speed (Token/s), Latency, dan End-to-End Response Time. Sebelum dilakukan proses perhitungan, seluruh atribut dinormalisasi menggunakan metode Min-Max Normalization untuk menyamakan rentang nilai data. Selanjutnya, tingkat kemiripan antar model dihitung menggunakan metode Cosine Similarity dan diurutkan berdasarkan nilai similarity tertinggi. Hasil penelitian menunjukkan bahwa model MiMo-V2-Omni-0327 memperoleh nilai similarity tertinggi sebesar 0,9945 terhadap model acuan MiMo-V2-Omni, diikuti oleh Step 3.7 Flash, MiniMax-M3, MiMo-V2.5-Pro, dan DeepSeek V4 Pro (High). Hasil tersebut menunjukkan bahwa metode Content-Based Filtering yang dipadukan dengan Cosine Similarity mampu menghasilkan rekomendasi model Artificial Intelligence berdasarkan kemiripan karakteristik setiap model sehingga dapat membantu pengguna dalam memilih platform AI yang sesuai dengan kebutuhannya.

Kata kunci— Artificial Intelligence, Content-Based Filtering, Cosine Similarity, Sistem Rekomendasi, Platform AI.

Abstract— The rapid development of Artificial Intelligence (AI) technology has led to the emergence of numerous AI models with diverse characteristics and capabilities, making it difficult for users to determine the most suitable model for their needs. This study aims to design a recommendation system for selecting Artificial Intelligence platforms using the Content-Based Filtering (CBF) method based on the similarity of AI model characteristics. The dataset consists of 40 AI models represented by six numerical attributes: Context Window, Intelligence Index, Price, Speed (Token/s), Latency, and End-to-End Response Time. Before similarity calculation, all attributes were normalized using the Min-Max Normalization method to ensure a consistent data scale. Similarity between AI models was then calculated using Cosine Similarity, and the recommendation results were ranked according to the highest similarity scores. The results indicate that MiMo-V2-Omni-0327 achieved the highest similarity score of 0.9945 with the reference model MiMo-V2-Omni, followed by Step 3.7 Flash, MiniMax-M3, MiMo-V2.5-Pro, and DeepSeek V4 Pro (High). These findings demonstrate that the proposed Content-Based Filtering approach combined with Cosine Similarity is capable of providing AI model recommendations based on the similarity of model characteristics, thereby assisting users in selecting AI platforms that best match their requirements.

Keywords— Artificial Intelligence, Content-Based Filtering, Cosine Similarity, Recommendation System, AI Platform.

I. PENDAHULUAN

Perkembangan teknologi Artificial Intelligence (AI) dalam beberapa tahun terakhir mengalami peningkatan yang sangat pesat dan telah memberikan dampak signifikan pada berbagai aspek kehidupan. Berbagai platform AI seperti

ChatGPT, Gemini, Claude, Copilot, Perplexity, dan DeepSeek menawarkan kemampuan yang beragam, mulai dari pembuatan konten, analisis data, pemrograman, penerjemahan bahasa, hingga dukungan pengambilan keputusan [1], [2]. Kehadiran berbagai layanan tersebut

memberikan banyak alternatif bagi pengguna untuk menyelesaikan pekerjaan secara lebih efektif dan efisien.

Namun, banyaknya pilihan platform AI yang tersedia juga menimbulkan permasalahan baru bagi pengguna. Setiap platform memiliki karakteristik, fitur, keunggulan, serta keterbatasan yang berbeda. Sebagai contoh, terdapat AI yang lebih unggul dalam pembuatan kode program, sementara platform lain lebih optimal untuk kebutuhan pencarian informasi, analisis data, atau pembuatan konten kreatif [1], [2]. Perbedaan tersebut sering kali membuat pengguna mengalami kesulitan dalam menentukan platform AI yang paling sesuai dengan kebutuhan yang dimiliki. Akibatnya, proses pemilihan menjadi kurang efektif karena pengguna harus melakukan pencarian dan perbandingan secara manual terhadap berbagai alternatif yang tersedia.

Permasalahan tersebut dapat diatasi dengan memanfaatkan sistem rekomendasi. Sistem rekomendasi merupakan suatu pendekatan yang digunakan untuk membantu pengguna dalam menemukan item yang sesuai berdasarkan karakteristik tertentu sehingga dapat mendukung proses pengambilan keputusan [3], [4], [5]. Dalam perkembangannya, sistem rekomendasi telah banyak diterapkan pada berbagai bidang, seperti e-commerce, hiburan, pendidikan, dan layanan digital karena mampu meningkatkan relevansi informasi yang diterima oleh pengguna [6], [7]. Salah satu metode [8].

Salah satu metode yang banyak digunakan dalam pengembangan sistem rekomendasi adalah Content-Based Filtering (CBF). Metode ini bekerja dengan menganalisis atribut atau karakteristik yang dimiliki suatu item, kemudian menghitung tingkat kesamaan dengan item lainnya untuk menghasilkan rekomendasi yang relevan [3], [9], [10], [11]. Pendekatan ini memiliki keunggulan karena dapat menghasilkan rekomendasi berdasarkan kemiripan atribut setiap item yang dianalisis [9], [10], [11].

Metode Content-Based Filtering telah diterapkan pada berbagai penelitian sebelumnya. Penelitian pada sistem rekomendasi film menunjukkan bahwa metode ini mampu

menghasilkan rekomendasi berdasarkan kesamaan genre dan atribut film [4]. Selain itu, metode ini juga diterapkan pada rekomendasi artikel ilmiah [12], video pembelajaran daring [6], produk e-commerce [13], destinasi wisata [7], serta rekomendasi restoran [14]. Hasil dari berbagai penelitian tersebut menunjukkan bahwa metode Content-Based Filtering memiliki kemampuan yang baik dalam mengidentifikasi kemiripan antar item sehingga mampu menghasilkan rekomendasi yang relevan sesuai kebutuhan pengguna [15].


Meskipun penerapan sistem rekomendasi berbasis Content-Based Filtering telah banyak dilakukan pada berbagai domain, penelitian yang berfokus pada rekomendasi pemilihan platform Artificial Intelligence masih relatif terbatas. Padahal, jumlah platform AI yang terus bertambah menyebabkan pengguna membutuhkan bantuan dalam menentukan layanan yang paling sesuai dengan kebutuhan spesifik mereka. Oleh karena itu, diperlukan suatu sistem yang mampu memberikan rekomendasi platform AI berdasarkan karakteristik dan fitur yang dimiliki oleh masing-masing layanan.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk merancang sistem rekomendasi pemilihan Artificial Intelligence menggunakan metode Content-Based Filtering. Sistem yang dikembangkan memanfaatkan informasi mengenai fitur dan karakteristik dari berbagai platform AI untuk menghasilkan rekomendasi yang sesuai dengan kebutuhan pengguna. Diharapkan hasil penelitian ini dapat memfasilitasi pengguna dalam menemukan alternatif platform Artificial Intelligence yang paling mendekati kriteria dan kebutuhan spesifik mereka melalui proses pencocokan karakteristik model menggunakan pendekatan Content-Based Filtering [3], [4], [9].

II. METODOLOGI PENELITIAN

Penelitian ini menggunakan metode Content-Based Filtering (CBF) untuk membangun sistem rekomendasi pemilihan platform Artificial Intelligence berdasarkan kemiripan karakteristik antar model AI. Metode ini memanfaatkan atribut

yang dimiliki setiap model AI sebagai dasar dalam proses perhitungan tingkat kemiripan (similarity)[3], [9], [10]. Tahapan penelitian dimulai dari pengumpulan data, normalisasi atribut, perhitungan nilai kemiripan menggunakan metode Cosine Similarity, proses pemeringkatan, hingga penyajian hasil rekomendasi kepada pengguna. Alur penelitian yang dilakukan ditunjukkan pada Gambar 1.



Gambar 1. Tahap Penelitian

A. Pengumpulan Data

Tahap pertama penelitian adalah mengumpulkan dataset model Artificial Intelligence yang diperoleh dari website Artificial Analysis[1]. Dataset yang digunakan terdiri dari 40 model AI yang memiliki karakteristik berbeda-beda. Setiap model direpresentasikan menggunakan enam atribut numerik, yaitu :

1. Context Window

Ini merujuk pada batasan maksimum jumlah teks (diukur dalam satuan token) yang dapat diproses dan "diingat" oleh model AI dalam satu kali percakapan atau permintaan (input dan output). Semakin besar context window (misalnya 128K atau 256K token), semakin banyak informasi, dokumen, atau baris kode yang dapat dianalisis oleh AI sekaligus tanpa melupakan konteks awal[1].

2. Intelligence Index

Atribut ini merupakan nilai atau skor agregat (biasanya berdasarkan skor benchmark standar seperti MMLU, HumanEval, dan sebagainya) yang

merepresentasikan tingkat kecerdasan, kemampuan penalaran (reasoning), pemecahan masalah, dan pemahaman logika dari sebuah model AI. Semakin tinggi indeksinya, semakin baik kemampuan model dalam menangani tugas yang kompleks[1],[2].

3. Price

Jumlah biaya penggunaan model AI (biasanya dalam bentuk API), yang umumnya dihitung dalam satuan dolar per 1.000 atau 1.000.000 token (baik untuk input maupun output). Atribut ini menjadi faktor penting untuk mengukur efisiensi anggaran bagi pengguna atau developer[1].

4. Speed (Token per Second)

Kecepatan model (*throughput*) dalam menghasilkan atau memproduksi teks balasan, diukur berdasarkan jumlah token yang dapat dihasilkan dalam satu detik. Kecepatan yang tinggi sangat dibutuhkan untuk aplikasi yang memerlukan interaksi real-time[1].

5. Latency

Waktu jeda atau keterlambatan (*Time to First Token / TTFT*) sejak pengguna mengirimkan prompt hingga model AI memberikan token pertama dari balasannya. Latensi yang rendah menunjukkan bahwa model memberikan respons awal dengan lebih cepat[1].

6. End-to-End Response Time

Total waktu keseluruhan yang dihabiskan sejak pengguna mengirimkan permintaan (*input*) hingga menerima seluruh balasan (*output*) secara lengkap. Atribut ini merupakan kombinasi dari Latency dan waktu yang dibutuhkan selama proses Speed (*Token/s*) hingga proses pembuatan teks selesai sepenuhnya[1].

Atribut tersebut dipilih karena mampu merepresentasikan kemampuan, efisiensi, dan performa masing-masing model AI sehingga dapat digunakan sebagai dasar dalam proses rekomendasi berbasis konten (Content-Based Filtering)[9], [10].

B. Normalisasi Data

Sebelum dilakukan proses perhitungan similarity, seluruh atribut dinormalisasi menggunakan metode Min-Max Normalization agar setiap atribut memiliki rentang nilai yang sama, yaitu antara 0 hingga 1. Normalisasi dilakukan untuk menghindari dominasi atribut yang memiliki nilai lebih besar terhadap atribut lainnya sehingga setiap atribut memberikan kontribusi yang seimbang pada proses perhitungan kemiripan[9], [10].

$$x^1 = \frac{x - \min(x)}{\max(x) - \min(x)}$$

C. Perhitungan Similarity

Setelah proses normalisasi selesai, setiap model AI direpresentasikan dalam bentuk vektor numerik. Selanjutnya dilakukan perhitungan tingkat kemiripan menggunakan metode Cosine Similarity. Metode ini menghitung tingkat kesamaan dua buah vektor berdasarkan sudut yang terbentuk di antaranya sehingga semakin besar nilai similarity, semakin tinggi pula tingkat kemiripan kedua model AI[9], [14].

$$\text{Similarity}(A, B) = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \times \sqrt{\sum_{i=1}^n B_i^2}}$$

D. Pemeringkatan Rekomendasi

Nilai similarity yang diperoleh kemudian diurutkan dari nilai terbesar ke nilai terkecil. Model AI dengan nilai similarity tertinggi dianggap memiliki karakteristik yang paling mendekati model AI acuan sehingga ditempatkan pada urutan pertama rekomendasi. Tahap pemeringkatan ini merupakan bagian penting dalam metode Content-Based Filtering karena menentukan relevansi hasil rekomendasi yang diterima pengguna [3], [10].

E. Penyajian Hasil Rekomendasi

Tahap terakhir adalah menyajikan hasil rekomendasi kepada pengguna melalui antarmuka sistem. Sistem akan menampilkan lima model AI dengan nilai similarity tertinggi (Top-5 Recommendation) beserta informasi nilai kemiripan masing-masing. Pendekatan ini

diharapkan dapat membantu pengguna memperoleh alternatif model AI yang memiliki karakteristik paling sesuai dengan kebutuhan pengguna [9], [10].

III. HASIL DAN PEMBAHASAN

A. Pengumpulan data

Penelitian ini menggunakan dataset yang terdiri atas 40 model Artificial Intelligence (AI) yang diperoleh dari berbagai penyedia layanan AI melalui platform Artificial Analysis . Data yang dikumpulkan mencakup enam atribut, yaitu Context Window, Intelligence Index, Price, Speed (Token/s), Latency, dan End-to-End Response Time. Keenam atribut tersebut selanjutnya digunakan sebagai dasar dalam proses normalisasi data dan perhitungan tingkat kemiripan menggunakan metode Content-Based Filtering dengan pendekatan Cosine Similarity [4], [5]. Sebagai representasi dataset penelitian, sebagian data ditampilkan pada Tabel 1, sedangkan proses pengolahan dilakukan terhadap keseluruhan dataset yang berjumlah 40 model AI.

Tabel 1. Sampel Dataset Penelitian

N o	Model AI	Context Window	Intelligence Index	Price (\$)	Speed (tok/s)
1	Phi-4 Mini	128K	8	0,00	21
2	Phi-4 Multimodal	128K	10	0,00	17
3	Granite 4.0 H Small	128K	11	0,08	388
4	Janus 1.7 Large	256K	11	2,60	60
5	Sarvam 30B (High)	65,5K	12	0,03	166
6	Command A	256K	13	3,25	66
7	Llama 4 Scout	10M	14	0,22	110
8	Qwen 3.5 32B	262K	15	0,03	353
9	NVIDIA Nemotron Nano 128 V2 VL	128K	15	0,24	287
10	Nova 2.0 Lite	1M	18	0,52	124

B. Hasil Normalisasi

Seluruh atribut pada dataset memiliki rentang nilai yang berbeda sehingga dilakukan proses normalisasi menggunakan metode Min-Max Normalization. Proses ini bertujuan untuk menyamakan skala setiap atribut agar seluruh

atribut memiliki kontribusi yang seimbang pada saat proses perhitungan Cosine Similarity.

Berdasarkan hasil normalisasi, seluruh nilai atribut berhasil ditransformasikan ke dalam rentang 0 hingga 1. Sebagai contoh, atribut Context Window yang memiliki rentang sangat besar terlebih dahulu ditransformasikan menggunakan fungsi logaritma sebelum dilakukan normalisasi sehingga distribusi data menjadi lebih proporsional.

Tabel 2. Data Normalisasi Permodel

Model AI	CW	Intelligence	Price	Speed	Latency	E2e	Preview
Phi-4 Mini	0,1332	0,0000	0,0000	0,0052	0,4781	0,1410	gpt-oss-120b (low)
Phi-4 Multi modal	0,4693	0,0377	0,0000	0,0000	0,0037	0,1780	Nova 2.0 Lite (low)
Granite 4.0 H Small	0,4693	0,0566	0,0184	0,4781	0,0644	0,0603	Magistral Medium 1.2
Janus 1.7 Large	0,5537	0,0566	0,5977	0,0554	0,0644	0,0498	Qwen 3.5 35B A3B
Sarvam 30B (High)	0,0000	0,0755	0,0069	0,1920	0,0104	0,0927	Nova 2.0 Pro Preview (low)
Command and A	0,2711	0,0943	0,7471	0,0631	0,0083	0,0451	Mercury 2
Llama 4 Scout	1,0000	0,1132	0,0506	0,1198	0,0039	0,0225	Nova 2.0 Lite (high)
Qwen 3.5 2B	0,2757	0,1321	0,0069	0,4330	0,0005	0,0000	NVIDIA
NVIDIA IA							Nemotron 3 Super
Nemotron Nano 12B v2 VL	0,1332	0,1321	0,0552	0,3479	0,0017	0,0457	Command and A+
Nova 2.0 Lite	0,5421	0,1887	0,1195	0,1379	0,0063	0,0215	Step 3.5 Flash 2603
Sarvam 105B (high)	0,1332	0,1887	0,0092	0,1224	0,0114	0,1380	Ring-2.6-1T
Nova Premier	0,5421	0,2075	0,5011	0,0193	0,0177	0,1048	DeepSeek V4 Pro
Nemotron 3 Nano Omni 30B A3B Reasoning	0,2711	0,2453	0,0230	0,3634	0,0045	0,0463	GPT-5.5 (Non-reasoning)
Nova 2.0 Pro	0,2711	0,2830	0,4897	0,1302	0,0050	0,0215	MiMo-V2-Omni
							Step 3.7 Flash
							MiMo-V2-Omni-0327
							Nemotron 3 Ultra
							GPT-5.4 mini (xhigh)

DeepS eek V4 Pro (High)	0,5421	0,7925	0,0414	0,0554	0,0107	0,2544	Claud e Opus 4.8 (max)	0,5421	1,0000	0,9425	0,0644	0,1641	0,1934																									
Claud e Sonnet 4.6 (max)	0,5421	0,8302	0,5655	0,0515	1,0000	1,0000	MiMo -V2- Omni- 0327	0,2711	0,6981	0,0782	0,0773	0,0215	0,2093																									
Grok 4.3 (high)	0,5421	0,8491	0,1471	0,2423	0,0896	0,0913	C. Hasil Perhitungan Cosine Similarity dan Rekomendasi Setelah seluruh atribut dinormalisasi menggunakan metode Min-Max Normalization sebagaimana ditunjukkan pada Tabel 2, data hasil normalisasi digunakan sebagai masukan dalam proses perhitungan Cosine Similarity untuk mengukur tingkat kemiripan antara model AI acuan dengan seluruh model pada dataset. Perhitungan Cosine Similarity dilakukan menggunakan Persamaan (1). $Similarity(A, B) = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \times \sqrt{\sum_{i=1}^n B_i^2}}$ Keterangan: A menyatakan vektor model AI acuan; B menyatakan vektor model AI pembanding; dan n menyatakan jumlah atribut yang digunakan. Sebagai contoh, perhitungan dilakukan antara model MiMo-V2-Omni sebagai model acuan dan MiMo-V2-Omni-0327 sebagai model pembanding menggunakan data hasil normalisasi pada Tabel 2. Berdasarkan hasil perhitungan menggunakan Persamaan (1), diperoleh nilai Cosine Similarity sebesar 0,9945. Nilai tersebut menunjukkan bahwa kedua model memiliki tingkat kemiripan yang sangat tinggi karena mendekati nilai maksimum, yaitu 1. Tabel 3. Contoh Data Hasil Normalisasi untuk Perhitungan Cosine Similarity <table><tr><th>Model</th><th>Dot Product</th><th>Norma Acuan</th><th>Norma Kandidat</th><th>Cosine Similarity</th></tr><tr><td>Phi-4 Mini</td><td>0,0677</td><td>0,7508</td><td>0,1943</td><td>0,4642</td></tr><tr><td>Phi-4 Multimodal</td><td>0,1003</td><td>0,7508</td><td>0,2256</td><td>0,5922</td></tr><tr><td>Granite 4.0 H Small</td><td>0,1226</td><td>0,7508</td><td>0,5076</td><td>0,3217</td></tr><tr><td>Jamba 1.7 Large</td><td>0,1260</td><td>0,7508</td><td>0,6630</td><td>0,2531</td></tr></table>							Model	Dot Product	Norma Acuan	Norma Kandidat	Cosine Similarity	Phi-4 Mini	0,0677	0,7508	0,1943	0,4642	Phi-4 Multimodal	0,1003	0,7508	0,2256	0,5922	Granite 4.0 H Small	0,1226	0,7508	0,5076	0,3217	Jamba 1.7 Large	0,1260	0,7508	0,6630	0,2531
Model	Dot Product	Norma Acuan	Norma Kandidat	Cosine Similarity																																		
Phi-4 Mini	0,0677	0,7508	0,1943	0,4642																																		
Phi-4 Multimodal	0,1003	0,7508	0,2256	0,5922																																		
Granite 4.0 H Small	0,1226	0,7508	0,5076	0,3217																																		
Jamba 1.7 Large	0,1260	0,7508	0,6630	0,2531																																		
MiMo -V2.5- Pro	0,5421	0,8679	0,0414	0,0335	0,0204	0,3673																																
Mini Max- M3	0,5421	0,8868	0,0506	0,0335	0,0146	0,3579																																
Qwen 3.7 Max	0,5421	0,9245	0,3287	0,1173	0,0151	0,1696																																
Claud e Opus 4.7 (max)	0,5421	0,9245	0,9425	0,0477	0,1110	0,1540																																

Sarvam 30B (high)	0,0843	0,7508	0,2265	0,4958
Command A	0,1504	0,7508	0,8042	0,2492
Llama 4 Scout	0,3595	0,7508	1,0150	0,4718
Qwen3.5 2B	0,1932	0,7508	0,5301	0,4855
NVIDIA Nemotron Nano 12B v2 VL	0,1585	0,7508	0,4017	0,5257
Nova 2.0 Lite	0,2864	0,7508	0,6027	0,6329
Sarvam 105B (high)	0,2002	0,7508	0,2960	0,9008
Nova Premier	0,3088	0,7508	0,7744	0,5312
Nemotron 3 Nano Omni 30B A3B Reasoning	0,2720	0,7508	0,5181	0,6992
Nova 2.0 Pro Preview	0,2746	0,7508	0,6409	0,5707
gpt-oss-120b (low)	0,2763	0,7508	0,5468	0,6730
Nova 2.0 Lite (low)	0,4087	0,7508	0,6810	0,7994
Magistral Medium 1.2	0,3590	0,7508	0,7562	0,6323
Qwen3.5 35B A3B	0,3817	0,7508	0,5671	0,8964
Nova 2.0 Pro Preview (low)	0,4237	0,7508	0,7572	0,7453
Mercury 2	0,4240	0,7508	1,1145	0,5067
Nova 2.0 Lite (high)	0,5635	0,7508	0,8438	0,8895
NVIDIA Nemotron 3 Super	0,5292	0,7508	0,7875	0,8951
Command A+	0,4511	0,7508	0,6366	0,9439
Step 3.5 Flash 2603	0,4938	0,7508	0,6750	0,9745
Ring-2.6-1T	0,4879	0,7508	0,6696	0,9707
DeepSeek V4 Pro	0,5485	0,7508	0,8022	0,9107
GPT-5.5 (Non-reasoning)	0,5686	0,7508	1,2920	0,5863
MiMo-V2-Omni	0,5636	0,7508	0,7508	1,0000
Step 3.7 Flash	0,5481	0,7508	0,7377	0,9897
MiMo-V2-Omni-0327	0,5866	0,7508	0,7856	0,9945
Nemotron 3 Ultra	0,6092	0,7508	0,8389	0,9673
GPT-5.4 mini (xhigh)	0,6406	0,7508	0,8964	0,9520
DeepSeek V4 Pro (High)	0,7305	0,7508	0,9957	0,9772
Claude Sonnet 4.6 (max)	0,9393	0,7508	1,8181	0,6882
Grok 4.3 (high)	0,7471	0,7508	1,0543	0,9439
MiMo-V2.5-Pro	0,8038	0,7508	1,0887	0,9834

MiniMax-M3	0,8140	0,7508	1,1010	0,9848
Qwen3.7 Max	0,8036	0,7508	1,1399	0,9390
Claude Opus 4.7 (max)	0,7971	0,7508	1,4406	0,7370
Claude Opus 4.8 (max)	0,8579	0,7508	1,5002	0,7617

D. Hasil Pemeringkatan Rekomendasi

Berdasarkan nilai Cosine Similarity yang diperoleh pada tahap sebelumnya, sistem melakukan proses pemeringkatan (ranking) terhadap seluruh model Artificial Intelligence secara menurun (descending). Proses pemeringkatan dilakukan untuk mengurutkan model AI berdasarkan tingkat kemiripannya dengan model acuan, sehingga model dengan nilai similarity tertinggi ditempatkan pada urutan teratas.

Model MiMo-V2-Omni sebagai model acuan memiliki nilai Cosine Similarity sebesar 1,0000 terhadap dirinya sendiri. Oleh karena itu, model tersebut tidak disertakan dalam daftar rekomendasi. Sistem selanjutnya memilih lima model AI dengan nilai Cosine Similarity tertinggi sebagai rekomendasi utama bagi pengguna. Hasil pemeringkatan rekomendasi disajikan pada Tabel 4.

Tabel 4. Hasil Pemeringkatan Rekomendasi


Ranking	Model	Cosine Similarity
1	MiMo-V2-Omni-0327	0,9945
2	Step 3.7 Flash	0,9897
3	MiniMax-M3	0,9848
4	MiMo-V2.5-Pro	0,9834
5	DeepSeek V4 Pro (High)	0,9772

Berdasarkan hasil pemeringkatan, model MiMo-V2-Omni-0327 menempati peringkat pertama dengan nilai Cosine Similarity sebesar 0,9945, diikuti oleh Step 3.7 Flash (0,9897), MiniMax-M3 (0,9848), MiMo-V2.5-Pro (0,9834), dan DeepSeek V4 Pro (High) (0,9772). Nilai similarity yang tinggi pada kelima model tersebut menunjukkan bahwa karakteristiknya sangat mendekati model acuan berdasarkan atribut yang digunakan dalam penelitian. Dengan

demikian, model-model tersebut dapat direkomendasikan sebagai alternatif yang relevan bagi pengguna dalam memilih model Artificial Intelligence yang sesuai dengan kebutuhannya.

E. Implementasi Antarmuka Sistem

Pada penelitian ini dilakukan perancangan sistem rekomendasi berbasis web yang bertujuan membantu pengguna dalam memilih platform Artificial Intelligence berdasarkan tingkat kemiripan karakteristik model AI. Sistem dirancang agar pengguna dapat memilih salah satu model AI sebagai model acuan, kemudian sistem akan melakukan proses normalisasi data, menghitung nilai Cosine Similarity, serta menghasilkan daftar rekomendasi berdasarkan nilai kemiripan tertinggi.



Gambar 2. Halaman Input Sistem Rekomendasi Artificial Intelligence

Gambar 2. menunjukkan halaman utama sistem rekomendasi berbasis web. Pada halaman ini pengguna memilih model Artificial Intelligence sebagai model acuan melalui komponen dropdown. Setelah model dipilih, sistem menampilkan informasi spesifikasi model yang terdiri atas Intelligence Index, Price, Speed (Token/s), Latency, dan Context Window. Selanjutnya, data tersebut digunakan sebagai dasar dalam proses perhitungan kemiripan menggunakan metode Cosine Similarity.



Gambar 3. Halaman Hasil Rekomendasi Sistem

Gambar 3. menampilkan hasil rekomendasi yang dihasilkan setelah proses perhitungan Cosine Similarity selesai dilakukan. Sistem mengurutkan seluruh model AI berdasarkan nilai similarity secara menurun dan menampilkan lima model dengan tingkat kemiripan tertinggi sebagai alternatif terhadap model acuan. Selain nama model, sistem juga menampilkan nilai match serta beberapa informasi pendukung sehingga pengguna dapat membandingkan karakteristik setiap model secara lebih mudah.

F. Pembahasan

Penerapan metode Content-Based Filtering (CBF) pada penelitian ini menunjukkan bahwa karakteristik numerik setiap model Artificial Intelligence dapat dimanfaatkan sebagai dasar dalam menghasilkan rekomendasi yang objektif. Proses normalisasi menggunakan metode Min-Max Normalization berhasil menyamakan rentang nilai setiap atribut sehingga tidak terjadi dominasi atribut tertentu pada proses perhitungan kemiripan. Kondisi tersebut menjadikan setiap atribut memiliki pengaruh yang proporsional dalam menentukan tingkat kesamaan antar model AI.

Metode Cosine Similarity mampu mengukur kedekatan karakteristik antar model berdasarkan representasi vektor dari atribut Context Window, Intelligence Index, Price, Speed (Token/s), Latency, dan End-to-End Response Time [9], [14]. Pendekatan ini memungkinkan sistem mengidentifikasi model AI yang memiliki profil karakteristik serupa berdasarkan atribut yang dimiliki setiap model [3], [9]. Dengan demikian, rekomendasi yang dihasilkan sepenuhnya didasarkan pada kesamaan atribut yang dimiliki setiap model.

Hasil penelitian juga menunjukkan bahwa sistem mampu menyajikan daftar rekomendasi secara terurut berdasarkan tingkat kemiripan terhadap model acuan. Mekanisme pemeringkatan tersebut memberikan kemudahan bagi pengguna dalam membandingkan beberapa alternatif model AI yang memiliki karakteristik mendekati kebutuhan. Rekomendasi yang dihasilkan disusun berdasarkan nilai Cosine Similarity, sehingga model dengan tingkat kemiripan tertinggi terhadap model acuan ditempatkan pada urutan pertama dan dapat dijadikan sebagai alternatif yang relevan bagi pengguna.

Secara keseluruhan, implementasi metode Content-Based Filtering dengan Cosine Similarity pada penelitian ini mampu memberikan pendekatan yang sistematis dalam proses pemilihan platform Artificial Intelligence. Hasil rekomendasi yang dihasilkan menunjukkan bahwa metode tersebut efektif dalam mengidentifikasi model-model AI dengan karakteristik yang serupa sehingga dapat digunakan sebagai pendukung keputusan bagi pengguna dalam memilih platform yang sesuai dengan kebutuhan dan preferensi penggunaan.

IV. KESIMPULAN

Penelitian ini berhasil merancang sistem rekomendasi pemilihan platform Artificial Intelligence menggunakan metode Content-Based Filtering (CBF) dengan pendekatan Cosine Similarity untuk menghitung tingkat kemiripan antar model AI. Sistem memanfaatkan enam atribut, yaitu Context Window, Intelligence Index, Price, Speed (Token/s), Latency, dan End-to-End Response Time sebagai dasar dalam proses rekomendasi. Berdasarkan hasil pengujian terhadap dataset yang terdiri atas 40 model Artificial Intelligence, sistem mampu menghasilkan rekomendasi secara objektif melalui proses perhitungan Cosine Similarity dan pemeringkatan berdasarkan tingkat kemiripan dengan model acuan. Hasil pengujian sistem menunjukkan bahwa apabila model MiMo-V2-Omni digunakan sebagai model acuan, maka MiMo-V2-Omni-0327 menjadi model alternatif

yang paling direkomendasikan dengan nilai Cosine Similarity tertinggi sebesar 0,9945. Hasil tersebut diperoleh berdasarkan perhitungan tingkat kemiripan terhadap enam atribut, yaitu Context Window, Intelligence Index, Price, Speed (Token/s), Latency, dan End-to-End Response Time. Selain MiMo-V2-Omni-0327, sistem juga merekomendasikan Step 3.7 Flash (0,9897), MiniMax-M3 (0,9848), MiMo-V2.5-Pro (0,9834), dan DeepSeek V4 Pro (High) (0,9772) sebagai lima model dengan tingkat kemiripan tertinggi terhadap model acuan. Dengan demikian, penelitian ini menunjukkan bahwa metode Content-Based Filtering dengan pendekatan Cosine Similarity dapat digunakan untuk menghasilkan pemeringkatan model Artificial Intelligence berdasarkan tingkat kemiripan enam atribut numerik, sehingga memberikan alternatif rekomendasi yang sesuai dengan karakteristik model acuan.

Penelitian ini masih memiliki beberapa keterbatasan, yaitu jumlah dataset yang digunakan masih terbatas dan proses perhitungan hanya memanfaatkan atribut numerik sebagai dasar penentuan kemiripan. Oleh karena itu, penelitian selanjutnya dapat dikembangkan dengan menambahkan jumlah model AI pada dataset, memperbarui data secara berkala mengikuti perkembangan teknologi Artificial Intelligence, serta mempertimbangkan penambahan atribut lain yang lebih beragam. Selain itu, metode Content-Based Filtering dapat dikombinasikan dengan metode Collaborative Filtering atau Hybrid Recommendation System untuk meningkatkan kualitas rekomendasi sehingga mampu menghasilkan rekomendasi yang lebih akurat dan sesuai dengan kebutuhan pengguna.

REFERENSI

- [1] A. Analysis, "Artificial Analysis," Artificial Analysis. Accessed: Jul. 10, 2026. [Online]. Available: <https://artificialanalysis.ai/>
- [2] W. X. Zhao *et al.*, "A Survey of Large Language Models," pp. 1–144, 2026.
- [3] P. Khurana and S. Parveen, "Approaches of Recommender System : A Survey," vol. 34, no. 3, pp. 134–138, 2016.
- [4] C. Fiarni, H. Maharani, and N. Calista, "Product

- Recommendation System Design Using Cosine Similarity and Content-based Filtering Methods,” vol. 3, no. 2, pp. 42–48, 2019.
- [5] U. Javed, K. Shaukat, I. A. Hameed, F. Iqbal, T. M. Alam, and S. Luo, “A Review of Content-Based and Context-Based Recommendation Systems,” pp. 274–306.
- [6] F. Ramadhan and A. Musdholifah, “Online Learning Video Recommendation System Based on Course and Syllabus Using Content-Based Filtering,” vol. 15, no. 3, pp. 265–274, 2021.
- [7] M. N. Arkan, A. P. Widodo, and G. Aryotejo, “A Web-Based Tourism Recommendation System for Boyolali Using Content-Based Filtering and Cosine Similarity,” vol. 17, no. April 2025, 2026, doi: 10.14710/jmasif.17.1.72520.
- [8] V. Boppana and P. Sandhya, “Web crawling based context aware recommender system using optimized deep recurrent neural network,” *J. Big Data*, 2021, doi: 10.1186/s40537-021-00534-7.
- [9] M. F. Abdurrafi, D. Handayani, and U. Ningsih, “Content-based filtering using cosine similarity algorithm for alternative selection on training programs,” pp. 204–212, 2023.
- [10] T. Ridwansyah, B. Subartini, and S. Sylviani, “Penerapan Metode Content-Based Filtering pada Sistem Rekomendasi,” vol. 4, no. 2, 2024.
- [11] M. Casillo, F. Colace, D. Conte, M. Lombardi, D. Santaniello, and C. Valentino, “Context - aware recommender systems and cultural heritage: a survey,” *J. Ambient Intell. Humaniz. Comput.*, vol. 14, no. 4, pp. 3109–3127, 2023, doi: 10.1007/s12652-021-03438-9.
- [12] A. Rianti, N. Wachid, A. Majid, and A. Fauzi, “Machine learning journal article recommendation system using content based filtering,” pp. 1–10, 2020.
- [13] Y. S. Anggraeni, S. D. Saputri, T. Azzahra, A. G. Verrel, and I. Artikel, “Implementasi Content-Based Filtering Menggunakan TF-IDF dan Cosine Similarity untuk Rekomendasi Buku Akademik Mahasiswa,” vol. 11, no. 2, pp. 213–225, 2026, doi: 10.30591/jpit.v11i2.10055.
- [14] F. Christyawan, A. N. Rohman, and A. D. Hartanto, “Application of Content-Based Filtering Method Using Cosine Similarity in Restaurant Selection Recommendation System,” vol. 6, no. 3, pp. 1559–1576, 2024, doi: 10.51519/journalisi.v6i3.806.
- [15] S. Qassimi, E. H. Abdelwahed, M. Hafidi, and A. Qazdar, “Towards a folksonomy graph - based context - aware recommender system of annotated books,” *J. Big Data*, 2021, doi: 10.1186/s40537-021-00457-3.