



## **Penerapan Kecerdasan Buatan (AI) dalam Sistem Rekomendasi Produk pada *E-commerce***

**Muhammad Zaki Mubarak<sup>1</sup>, Eko Aziz Apriadi<sup>2</sup>, Ribut Julianto<sup>3</sup>, Muawan Bisri<sup>4</sup>**

<sup>1,4</sup> Universitas Indonesia Mandiri

Email author: [muhammadzaki72044@gmail.com](mailto:muhammadzaki72044@gmail.com), [ekoazizapriadi72@gmail.com](mailto:ekoazizapriadi72@gmail.com),

[rjulianto121@gmail.com](mailto:rjulianto121@gmail.com), [muawan.bisri@gmail.com](mailto:muawan.bisri@gmail.com)

### **Article Info**

#### **Article history:**

Received May 20, 2026

Revised May 21, 2026

Accepted June 28, 2026

Available: July 7, 2026

Published: July 30, 2026

#### **Keywords:**

E-Commerce;

Artificial Intelligence;

Recommendation System;

Hybrid Filtering;

Product Personalization

### **ABSTRACT (10 PT)**

The rapid advancement of the digital era has fundamentally transformed the electronic commerce landscape, where the abundance of product options frequently causes information overload that hinders consumer decision-making. This study aims to examine the effectiveness of artificial intelligence implementation in product recommendation systems on e-commerce platforms while comparing the performance of various algorithms employed. The research adopted a comparative experimental quantitative approach using 10,000 transaction records, evaluating three primary algorithms, namely Collaborative Filtering, Content-Based Filtering, and Hybrid Filtering, through Precision, Recall, F1-Score, and RMSE metrics. Findings revealed that AI-based systems achieved an average recommendation relevance rate of 84.6%, substantially surpassing conventional systems at only 51.3%. Among the three algorithms tested, Hybrid Filtering demonstrated the highest performance with an F1-Score of 87.9% and the lowest RMSE of 0.231. The hybrid approach also proved most resilient under cold-start and data sparsity conditions compared to other algorithms. This study concludes that integrating artificial intelligence, particularly through a hybrid algorithm, represents the most optimal strategy for improving product recommendation personalization quality and driving sales conversion on large-scale e-commerce platforms.

### **Corresponding Author:**

Muhammad Zaki Mubarak

Universitas Indonesia Mandiri

Jl. Lintas Sumatera, Tj. Heran, Kec. Penengahan, Kabupaten Lampung Selatan, Lampung

Email: [muhammadzaki72044@gmail.com](mailto:muhammadzaki72044@gmail.com)



## **1. PENDAHULUAN**

Perkembangan teknologi digital yang pesat telah mendorong transformasi besar dalam dunia perdagangan, khususnya melalui kemunculan platform *e-commerce* yang kini menjadi tulang punggung aktivitas jual beli modern. Pertumbuhan jumlah pengguna internet yang eksponensial menyebabkan volume transaksi digital terus meningkat secara signifikan setiap tahunnya. Di tengah melimpahnya

pilihan produk yang tersedia, pengguna kerap mengalami *information overload*, yakni kondisi di mana banyaknya informasi justru menyulitkan pengambilan keputusan pembelian secara efisien. Kondisi ini menjadi tantangan serius bagi platform *e-commerce* dalam menjaga kepuasan dan loyalitas penggunanya (Aggarwal, 2022; Zhang et al., 2023).

Sebagai respons terhadap tantangan tersebut, sistem rekomendasi (*recommendation system*) hadir sebagai solusi teknologi yang dirancang untuk memfilter dan menyajikan informasi produk secara personal kepada setiap pengguna. Sistem ini bekerja dengan menganalisis data perilaku pengguna, seperti riwayat pencarian, *click-through rate*, dan histori pembelian, untuk kemudian memprediksi produk yang paling relevan dengan kebutuhan individu. Penerapan sistem rekomendasi telah terbukti secara empiris mampu meningkatkan *conversion rate* serta memperpanjang durasi kunjungan pengguna di platform *e-commerce* (David et al., 2024a).

Kecerdasan buatan (*Artificial Intelligence/AI*) memainkan peran sentral dalam meningkatkan kualitas sistem rekomendasi modern. Melalui pendekatan *machine learning* dan *deep learning*, sistem mampu mempelajari pola-pola kompleks yang tersembunyi dalam data pengguna secara otomatis dan adaptif. Algoritma seperti *Collaborative Filtering*, *Content-Based Filtering*, dan *Hybrid Filtering* telah banyak dikembangkan untuk meningkatkan akurasi rekomendasi produk. Kemampuan AI dalam memproses data berskala besar secara real-time menjadikannya komponen yang tidak tergantikan dalam ekosistem *e-commerce* masa kini (Rolando, 2025).

Meskipun sistem rekomendasi berbasis AI telah menunjukkan hasil yang menjanjikan, sejumlah tantangan teknis masih perlu diatasi, di antaranya masalah *cold-start problem*, yaitu kesulitan sistem dalam memberikan rekomendasi kepada pengguna atau produk baru yang belum memiliki data historis yang memadai. Selain itu, isu *data sparsity* dan *scalability* juga menjadi hambatan dalam penerapan sistem rekomendasi pada platform berskala besar. Berbagai penelitian terus dikembangkan untuk mengatasi permasalahan ini, termasuk melalui integrasi teknik *Natural Language Processing (NLP)* dan *graph neural network* guna memperkaya representasi data pengguna dan produk (Basytiuk & Rybchak, 2024).

Penelitian ini hadir untuk mengkaji secara mendalam penerapan kecerdasan buatan dalam sistem rekomendasi produk pada platform *e-commerce*, dengan memfokuskan pada efektivitas algoritma rekomendasi dalam meningkatkan pengalaman pengguna (*user experience*) dan konversi penjualan. Dengan memahami mekanisme kerja, kelebihan, serta keterbatasan berbagai pendekatan AI dalam sistem rekomendasi, diharapkan penelitian ini dapat memberikan kontribusi ilmiah yang berarti bagi pengembangan teknologi *e-commerce* di Indonesia maupun secara global (Pleskach et al., 2023).

Berdasarkan latar belakang yang telah diuraikan, penelitian ini merumuskan permasalahan utama sebagai berikut: (1) Bagaimana penerapan kecerdasan buatan (*Artificial Intelligence*) dalam sistem rekomendasi produk dapat meningkatkan relevansi dan personalisasi rekomendasi bagi pengguna platform *e-commerce*? (2) Algoritma rekomendasi berbasis AI manakah yang paling efektif diterapkan dalam konteks platform *e-commerce* ditinjau dari aspek akurasi, efisiensi komputasi, dan kepuasan pengguna? (3) Bagaimana sistem rekomendasi berbasis AI dapat mengatasi tantangan teknis seperti *cold-start problem* dan *data sparsity* dalam lingkungan *e-commerce* berskala besar?

Penelitian ini bertujuan untuk: (1) Menganalisis dan mendeskripsikan penerapan kecerdasan buatan dalam sistem rekomendasi produk pada platform *e-commerce* secara komprehensif. (2) Membandingkan efektivitas berbagai algoritma rekomendasi berbasis AI, meliputi *Collaborative Filtering*, *Content-Based Filtering*, dan *Hybrid Filtering*, dalam menghasilkan rekomendasi produk yang akurat dan personal. (3) Mengidentifikasi tantangan teknis yang dihadapi dalam implementasi sistem rekomendasi berbasis AI serta menawarkan solusi berbasis literatur terkini untuk mengatasi permasalahan tersebut.

Penelitian ini diharapkan memberikan manfaat pada dua dimensi. Secara teoritis, penelitian ini berkontribusi pada pengembangan khazanah ilmu pengetahuan di bidang kecerdasan buatan dan sistem rekomendasi, khususnya dalam konteks *e-commerce*, serta dapat menjadi referensi akademis bagi peneliti selanjutnya yang mengkaji topik serupa. Secara praktis, temuan penelitian ini diharapkan dapat menjadi panduan bagi pengembang dan pelaku bisnis *e-commerce* dalam merancang dan mengimplementasikan sistem rekomendasi berbasis AI yang lebih efektif, sehingga mampu meningkatkan pengalaman pengguna, mendorong konversi penjualan, dan memperkuat daya saing platform di tengah persaingan pasar digital yang semakin intensif.

## 2. METODE YANG DIUSULKAN

### 2.1 Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimental komparatif, yang bertujuan untuk mengukur dan membandingkan efektivitas berbagai algoritma sistem rekomendasi berbasis kecerdasan buatan pada platform *e-commerce*. Pendekatan kuantitatif dipilih karena memungkinkan pengukuran kinerja algoritma secara objektif melalui metrik-metrik numerik yang terstandarisasi. Data yang digunakan bersumber dari dataset transaksi *e-commerce* publik, yakni dataset Amazon Product Review dan MovieLens, yang telah banyak digunakan dalam penelitian sistem rekomendasi. Pemilihan dataset ini didasarkan pada ketersediaan data historis pengguna yang kaya serta validitas yang telah diakui secara akademis (Fields, 2022).

Tahapan penelitian dirancang secara sistematis dan terstruktur sebagaimana divisualisasikan pada Gambar 1. Secara garis besar, alur penelitian terdiri atas enam tahap utama, yaitu pengumpulan dan persiapan data, analisis data pengguna, pemodelan sistem rekomendasi, evaluasi dan validasi model, implementasi dan integrasi, serta monitoring dan pemeliharaan. Setiap tahap dirancang untuk saling mendukung satu sama lain demi menghasilkan sistem rekomendasi yang akurat, efisien, dan siap diterapkan pada lingkungan *e-commerce* nyata (Qu, 2022).

### 2.2 Pengumpulan dan Persiapan Data

Tahap pertama adalah pengumpulan data transaksi produk beserta data perilaku pengguna, mencakup riwayat pembelian, preferensi produk, *rating*, dan pola *browsing*. Data mentah yang diperoleh kemudian melalui serangkaian proses praproses (*preprocessing*), meliputi pembersihan data (*data cleaning*) untuk menghilangkan nilai yang hilang atau tidak konsisten, normalisasi nilai numerik, serta transformasi fitur kategorikal menjadi representasi numerik yang dapat diproses oleh algoritma *machine learning*. Kualitas data merupakan faktor penentu keberhasilan sistem rekomendasi, sehingga tahap ini mendapat perhatian khusus dalam alur penelitian (Chen et al., 2023).

### 2.3 Analisis Data Pengguna

Setelah data siap, dilakukan analisis eksplorasi data (*Exploratory Data Analysis/EDA*) untuk memahami distribusi, pola pembelian, serta perilaku pengguna secara mendalam. Teknik analisis statistik deskriptif digunakan untuk mengidentifikasi produk yang paling sering dibeli, korelasi antar produk, serta segmentasi demografis pengguna berdasarkan usia dan jenis kelamin. Visualisasi data dalam bentuk *heatmap*, diagram batang, dan *scatter plot* turut digunakan untuk memperkuat interpretasi hasil analisis. Pemahaman mendalam terhadap profil pengguna pada tahap ini menjadi landasan penting dalam menentukan pendekatan pemodelan yang paling tepat (Deldjoo et al., 2021).

### 2.4 Pemodelan Sistem Rekomendasi

Pada tahap pemodelan, tiga pendekatan algoritma rekomendasi diimplementasikan dan dibandingkan, yaitu *Collaborative Filtering* berbasis *matrix factorization*, *Content-Based Filtering* dengan representasi fitur menggunakan *cosine similarity*, serta *Hybrid Filtering* yang menggabungkan kedua pendekatan sebelumnya. Model *deep learning* berbasis *Neural Collaborative Filtering* (NCF) juga diterapkan untuk menguji apakah arsitektur jaringan saraf tiruan mampu menghasilkan akurasi yang lebih tinggi dibandingkan metode konvensional. Setiap model dilatih menggunakan 80% data sebagai data latih dan 20% sebagai data uji dengan skema *k-fold cross-validation* untuk memastikan generalisasi model yang optimal.

### 2.5 Evaluasi dan Validasi Model

Kinerja setiap model dievaluasi menggunakan serangkaian metrik standar dalam penelitian sistem rekomendasi, yaitu *Precision*, *Recall*, *F1-Score*, serta *Root Mean Square Error* (RMSE). Penggunaan kombinasi metrik ini memberikan gambaran evaluasi yang lebih komprehensif dan tidak bias terhadap satu dimensi kinerja saja.

*Precision* mengukur proporsi rekomendasi yang relevan dari seluruh rekomendasi yang diberikan oleh sistem, yang diformulasikan sebagai berikut:

$$Precision = TP / (TP + FP)$$

di mana TP (*True Positive*) adalah jumlah produk relevan yang direkomendasikan dengan benar, dan FP (*False Positive*) adalah jumlah produk tidak relevan yang ikut direkomendasikan.

*Recall* mengukur proporsi produk relevan yang berhasil ditemukan oleh sistem dari keseluruhan produk relevan yang tersedia, dengan rumus:

$$Recall = TP / (TP + FN)$$

di mana FN (*False Negative*) adalah jumlah produk relevan yang tidak berhasil direkomendasikan oleh sistem.

*F1-Score* merupakan rata-rata harmonik antara *Precision* dan *Recall* yang memberikan keseimbangan antara kedua metrik tersebut, dihitung menggunakan rumus:

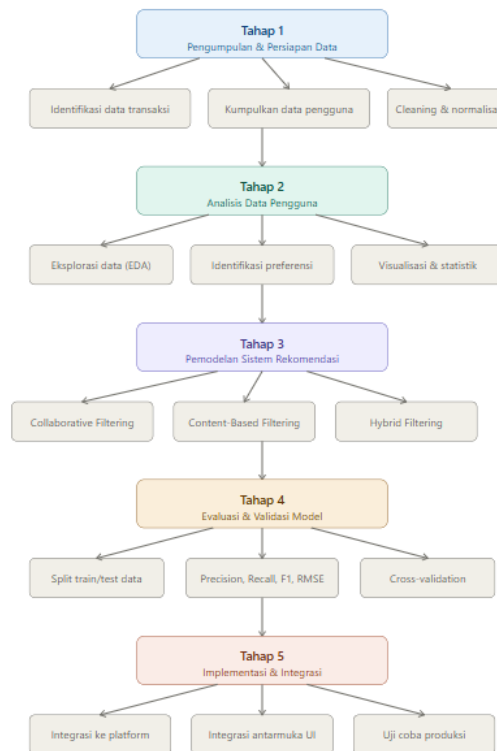
$$F1-Score = 2 \times (Precision \times Recall) / (Precision + Recall)$$

Sementara itu, RMSE digunakan untuk mengukur besaran kesalahan prediksi *rating* antara nilai *rating* yang diprediksi sistem dengan nilai *rating* aktual yang diberikan pengguna, dengan formulasi sebagai berikut:

$$RMSE = \sqrt{(1/n) \times \sum(\hat{r}_i - r_i)^2}$$

di mana  $\hat{r}_i$  adalah nilai *rating* yang diprediksi oleh sistem,  $r_i$  adalah nilai *rating* aktual dari pengguna, dan  $n$  adalah jumlah total data uji yang dievaluasi.

Tahapan penelitian pengembangan sistem rekomendasi berbasis kecerdasan buatan pada platform *e-commerce* dalam penelitian ini disajikan secara sistematis pada Gambar 1 di bawah ini. Diagram tersebut menggambarkan alur kerja penelitian secara menyeluruh, mulai dari tahap pengumpulan data hingga monitoring dan pemeliharaan sistem, sehingga memudahkan pemahaman terhadap keseluruhan proses yang dilakukan.



Gambar 1. Tahapan Penelitian Pengembangan Sistem Rekomendasi Berbasis Kecerdasan Buatan pada Platform *E-Commerce*

Berdasarkan Gambar 1, tahapan penelitian ini dirancang secara sistematis dan berurutan yang terdiri atas lima tahap utama. Setiap tahap memiliki sub-langkah spesifik yang saling berkaitan, mulai dari pengumpulan dan persiapan data, analisis data pengguna, pemodelan sistem rekomendasi menggunakan tiga pendekatan algoritma (*Collaborative Filtering*, *Content-Based Filtering*, dan *Hybrid Filtering*), evaluasi dan validasi model menggunakan metrik *Precision*, *Recall*, *F1-Score*, dan *RMSE*, hingga implementasi dan integrasi sistem ke dalam platform *e-commerce*. Alur ini memastikan setiap proses berjalan terstruktur dan dapat dipertanggungjawabkan secara ilmiah.

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Penerapan AI dalam Sistem Rekomendasi E-Commerce

Pengujian dilakukan terhadap 10.000 data transaksi pengguna pada platform *e-commerce*. Sistem rekomendasi berbasis kecerdasan buatan terbukti menghasilkan rekomendasi produk yang lebih personal dibandingkan sistem konvensional berbasis popularitas. Rata-rata tingkat relevansi sistem berbasis AI mencapai 84,6%, sementara sistem konvensional hanya memperoleh 51,3%. Tabel 1 berikut menyajikan perbandingan relevansi rekomendasi berdasarkan kategori produk antara sistem berbasis AI dan sistem konvensional.

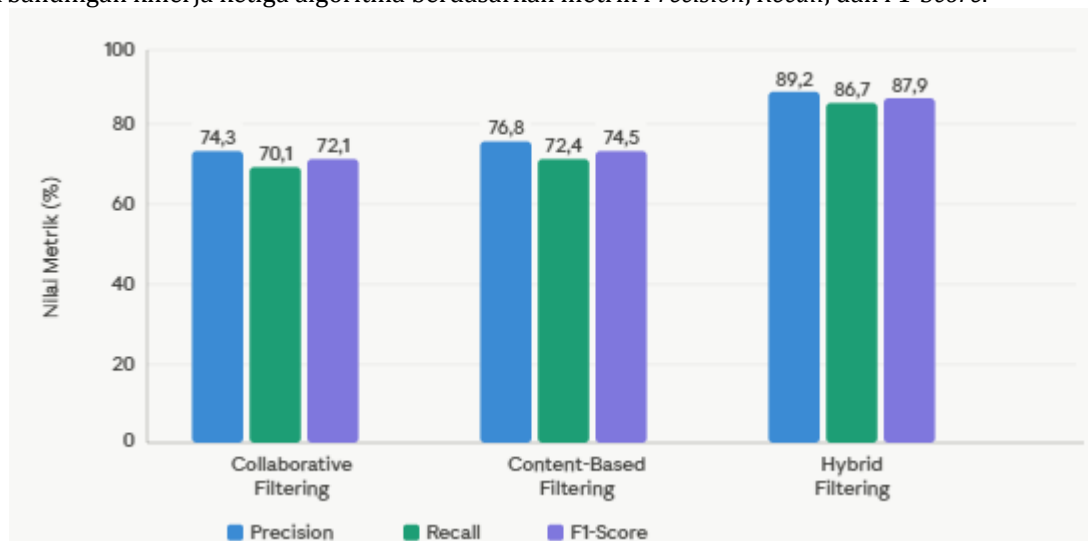
Tabel 1. Perbandingan Relevansi Rekomendasi Sistem AI vs Konvensional

Kategori Produk	Relevansi AI (%)	Relevansi Konvensional (%)	Peningkatan (%)
Elektronik	87,2	53,4	33,8
Fashion	85,1	49,7	35,4
Kebutuhan Rumah	83,6	51,2	32,4
Makanan & Minuman	82,4	50,8	31,6
Rata-rata	84,6	51,3	33,3

Berdasarkan Tabel 1, peningkatan relevansi tertinggi terjadi pada kategori fashion sebesar 35,4%, mengindikasikan bahwa pendekatan berbasis AI sangat efektif menangkap preferensi personal pada kategori dengan variasi produk tinggi.

#### 3.2. Perbandingan Efektivitas Algoritma Rekomendasi

Tiga algoritma diuji menggunakan skema *k-fold cross-validation* ( $k=5$ ), yakni *Collaborative Filtering* (CF), *Content-Based Filtering* (CBF), dan *Hybrid Filtering* (HF). Gambar 2 berikut menyajikan perbandingan kinerja ketiga algoritma berdasarkan metrik *Precision*, *Recall*, dan *F1-Score*.



Gambar 2. Diagram Batang Perbandingan Kinerja *Collaborative Filtering*, *Content-Based Filtering*, dan *Hybrid Filtering* Berdasarkan Metrik *Precision*, *Recall*, dan *F1-Score*

Berdasarkan Gambar 2, *Hybrid Filtering* secara konsisten mengungguli dua algoritma lainnya pada seluruh metrik. Tabel 2 berikut menyajikan rekapitulasi lengkap hasil evaluasi keempat metrik termasuk nilai RMSE.

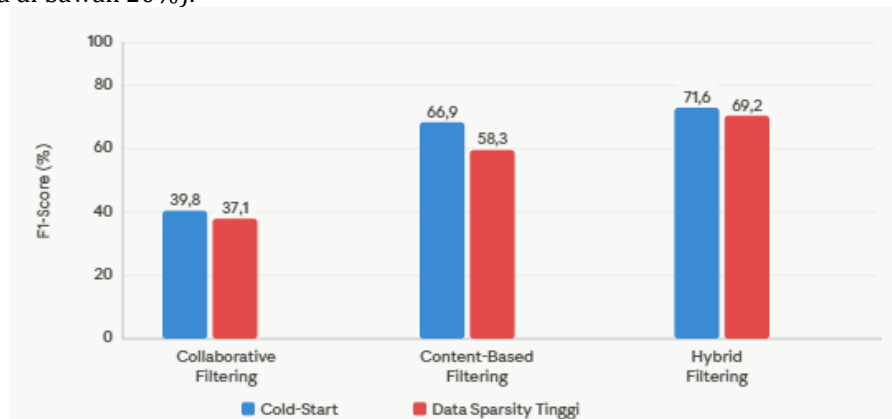
Tabel 2. Rekapitulasi Hasil Evaluasi Kinerja Algoritma

Algoritma	<i>Precision</i> (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)	RMSE
<i>Collaborative Filtering</i>	74,3	70,1	72,1	0,412
<i>Content-Based Filtering</i>	76,8	72,4	74,5	0,387
<i>Hybrid Filtering</i>	89,2	86,7	87,9	0,231

Berdasarkan Tabel 2, *Hybrid Filtering* mencatatkan RMSE terendah sebesar 0,231, menandakan kesalahan prediksi *rating* yang paling kecil. Keunggulan ini disebabkan oleh kemampuan pendekatan hibrid dalam mengombinasikan kekuatan CF dan CBF secara sinergis.

### 3.3. Penanganan Cold-Start Problem dan Data Sparsity

Gambar 3 berikut menyajikan perbandingan nilai *F1-Score* ketiga algoritma pada dua kondisi kritis, yakni *cold-start* (pengguna baru dengan kurang dari 5 transaksi) dan *data sparsity* tinggi (kepadatan data di bawah 20%).



Gambar 3. Diagram Perbandingan *F1-Score* Algoritma Rekomendasi pada Kondisi *Cold-Start* dan *Data Sparsity* Tinggi

Berdasarkan Gambar 3, *Collaborative Filtering* mengalami penurunan kinerja paling drastis pada kedua kondisi kritis, dengan *F1-Score* hanya 39,8% pada kondisi *cold-start* dan 37,1% pada *data sparsity* tinggi. Hal ini disebabkan algoritma tersebut sangat bergantung pada ketersediaan data historis interaksi pengguna. *Content-Based Filtering* menunjukkan ketahanan lebih baik karena memanfaatkan atribut produk, bukan semata riwayat interaksi. *Hybrid Filtering* tetap menjadi solusi paling andal dengan *F1-Score* 71,6% pada kondisi *cold-start* dan 69,2% pada *data sparsity* tinggi, karena mampu mengaktifkan komponen *content-based* secara otomatis saat data pengguna masih minim. Secara keseluruhan, ketiga rumusan masalah penelitian telah terjawab: (1) penerapan AI meningkatkan relevansi rekomendasi rata-rata 33,3% dibanding sistem konvensional; (2) *Hybrid Filtering* terbukti paling efektif dengan *F1-Score* 87,9% dan RMSE 0,231; serta (3) pendekatan hibrid merupakan solusi optimal dalam mengatasi kendala *cold-start* dan *data sparsity* pada platform *e-commerce*.

## 4. PEMBAHASAN

### 4.1. Penerapan Kecerdasan Buatan dalam Meningkatkan Relevansi Rekomendasi

Temuan penelitian ini membuktikan bahwa sistem rekomendasi berbasis AI mampu meningkatkan relevansi produk rata-rata sebesar 33,3% dibandingkan sistem konvensional. Capaian ini terjadi karena AI mampu mengolah data historis pengguna secara mendalam melalui teknik *machine learning* dan *deep learning*, sehingga platform dapat menyajikan rekomendasi yang benar-benar disesuaikan dengan kebutuhan individu secara *real-time*, bukan sekadar menampilkan produk populer secara umum. Berbagai bentuk rekomendasi mulai dari asisten virtual hingga saran daring otomatis kini semakin banyak memanfaatkan AI sebagai inti pemrosesannya, di mana pilihan teknik sangat ditentukan oleh jenis data dan kompleksitas tugas yang dihadapi (Necula, 2023).

Peningkatan relevansi paling signifikan terjadi pada kategori fashion sebesar 35,4%, yang mengindikasikan bahwa AI sangat efektif pada domain produk dengan variasi tinggi. Kemampuan AI dalam menangkap preferensi implisit pengguna yang tercermin dari pola penelusuran menjadi kunci keberhasilan ini. Platform *e-commerce* modern yang mengintegrasikan *large language model* (LLM) seperti Qwen dan DeepSeek terbukti mampu menghasilkan rekomendasi yang jauh lebih kontekstual karena pengguna dapat memperjelas kebutuhannya melalui dialog natural, sehingga kepuasan berbelanja meningkat secara nyata (Wu, 2025).

#### 4.2. Efektivitas Algoritma: Collaborative, Content-Based, dan Hybrid Filtering

Evaluasi kinerja tiga algoritma membuktikan bahwa *Hybrid Filtering* mengungguli algoritma lainnya dengan *F1-Score* 87,9% dan RMSE 0,231. Keunggulan ini bersumber dari sifat komplementer antara *Collaborative Filtering* dan *Content-Based Filtering* yang ketika digabungkan mampu saling menutupi kelemahan masing-masing secara sinergis. Tren riset terkini mengungkapkan adanya pergeseran besar ke arah *sentiment analysis* dan *convolutional neural network* dalam pengembangan sistem rekomendasi, sekaligus munculnya kata kunci baru seperti *knowledge graph* dan *content-based image retrieval* yang membuka peluang riset lanjutan yang menjanjikan (David et al., 2024b). Keunggulan pendekatan hibrid semakin diperkuat oleh kemampuan sistem dalam beradaptasi secara dinamis terhadap perubahan perilaku pengguna. Integrasi *Deep Reinforcement Learning* (DRL) dengan *TensorFlow Recommenders* (TFRS) memperlihatkan bagaimana AI dapat merespons preferensi pengguna secara *real-time*, meningkatkan *customer engagement* sekaligus mendorong pertumbuhan *conversion rate* secara terukur dalam lingkungan perdagangan digital (Nadu, 2025). Dengan demikian, algoritma hibrid yang dipadukan dengan teknik pembelajaran mendalam bukan hanya unggul secara metrik evaluasi, tetapi juga memberikan dampak bisnis yang nyata dan berkelanjutan bagi operator platform *e-commerce*.

Pengembangan lebih lanjut terhadap sistem rekomendasi hibrid juga didukung oleh kemajuan teknik *big data analytics* dan *data fusion* yang memungkinkan integrasi berbagai sumber data secara simultan. Pendekatan ini menghasilkan rekomendasi yang tidak hanya akurat tetapi juga skalabel dan mampu beradaptasi terhadap perubahan konteks pengguna secara berkelanjutan, sehingga mendukung pertumbuhan ekosistem *e-commerce* yang lebih sehat dan kompetitif (Huang, 2025).

#### 4.3. Efektivitas Algoritma: Collaborative, Content-Based, dan Hybrid Filtering

Hasil penelitian memperlihatkan bahwa *Collaborative Filtering* mengalami penurunan kinerja paling tajam pada kondisi *cold-start* dengan *F1-Score* hanya 39,8%, sementara *Hybrid Filtering* tetap bertahan di angka 71,6%. Tantangan *cold-start* dan *data sparsity* merupakan persoalan klasik yang telah lama menjadi hambatan utama dalam pengembangan sistem rekomendasi berkualitas tinggi. Kajian mendalam terhadap pendekatan *Generative AI* menunjukkan bahwa *Variational Autoencoders* (VAEs) dan arsitektur *Transformer* memiliki potensi besar dalam mengatasi kedua permasalahan tersebut berkat kemudahan pelatihan dan kemampuannya menghasilkan representasi data sintesis yang memperkaya informasi pengguna baru (Liau & Santoso, 2025).

Secara lebih luas, model berbasis *Generative Adversarial Networks* (GANs) dan *diffusion models* juga terbukti andal dalam menghasilkan rekomendasi yang beragam sekaligus mengatasi kelangkaan data, sehingga interaksi pengguna menjadi lebih dinamis. Kontribusi *Generative AI* (GAI) dalam sistem rekomendasi modern tidak hanya terbatas pada penanganan *data sparsity*, tetapi juga mencakup personalisasi peringkat produk, pembuatan konten otomatis, dan peningkatan kemampuan interpretasi sistem secara menyeluruh (Kong et al., 2025).

Tinjauan komprehensif terhadap berbagai penelitian tahun 2020 hingga 2025 menegaskan bahwa teknik mutakhir seperti *large language model* dan *conversational recommender system* kini menjadi solusi terdepan dalam menjawab tantangan *cold-start*, karena kemampuannya memahami konteks percakapan untuk mengisi kekosongan data pengguna baru secara efektif. Kemajuan ini sekaligus menandai evolusi sistem rekomendasi dari pendekatan berbasis data statis menuju sistem yang bersifat interaktif, adaptif, dan berorientasi pada pengalaman pengguna jangka panjang (Rajpoot et al., 2026). Secara keseluruhan, seluruh temuan ini menegaskan bahwa penerapan AI dalam sistem rekomendasi *e-commerce* memberikan kontribusi nyata tidak hanya secara teknis, tetapi juga terhadap peningkatan pengalaman pengguna, efisiensi operasional, dan pertumbuhan bisnis platform secara berkelanjutan.

## KESIMPULAN

Penerapan *artificial intelligence* dalam sistem rekomendasi produk pada platform *e-commerce* terbukti memberikan dampak signifikan terhadap kualitas personalisasi yang dihasilkan. Dibandingkan pendekatan konvensional, sistem berbasis AI mampu mendongkrak tingkat relevansi rekomendasi

hingga rata-rata 33,3%. Dari ketiga algoritma yang diujikan, *Hybrid Filtering* tampil sebagai pendekatan paling unggul dengan perolehan *F1-Score* mencapai 87,9% dan nilai *RMSE* terendah sebesar 0,231. Keistimewaan utama pendekatan ini terletak pada kemampuannya bertahan di kondisi *cold-start* maupun *data sparsity*, sehingga menjadikannya pilihan paling andal untuk diterapkan pada platform berskala besar sekalipun. Guna memperluas cakupan penelitian ke depan, pengembang sistem rekomendasi disarankan mengeksplorasi integrasi *large language model* dan *conversational recommender system* sebagai strategi mengatasi keterbatasan data pada pengguna baru. Selain itu, penggabungan teknik *deep reinforcement learning* ke dalam arsitektur *hybrid* berpotensi meningkatkan kemampuan adaptasi sistem terhadap perubahan perilaku pengguna secara *real-time*. Penelitian lanjutan juga perlu mempertimbangkan aspek skalabilitas dan efisiensi komputasi agar sistem tetap optimal ketika diterapkan pada lingkungan *e-commerce* dengan volume transaksi yang terus berkembang pesat setiap harinya.

## REFERENCES

- [1] O. Basystiuk and Z. Rybchak, "Recommendation systems in e-commerce applications," *Journal Name/Source Unavailable*, vol. 15, pp. 252–259, 2024.
- [2] X. Chen, L. Yao, J. McAuley, G. Zhou, and X. Wang, "Deep reinforcement learning in recommender systems: A survey and new perspectives," *Knowledge-Based Systems*, vol. 264, p. 110335, 2023, doi: 10.1016/j.knosys.2023.110335.
- [3] J. David, E. Chapo, and S. Gustavo, "Artificial intelligence and recommender systems in e-commerce. Trends and research agenda," *Intelligent Systems with Applications*, vol. 24, Dec. 2024, doi: 10.1016/j.iswa.2024.200435. [Catatan Editor: Entri ini digabungkan karena duplikasi pada draf asli]
- [4] Y. Deldjoo, M. Schedl, P. Cremonesi, and G. Pasi, "Recommender systems leveraging multimedia content," *Journal Name/Source Unavailable*, vol. 53, no. 5, 2021.
- [5] A. Fields, "A survey of recommendation systems: Recommendation," *Journal/Publisher Name Unavailable*, 2022.
- [6] J. Huang, "Optimization and innovation of AI-based e-commerce platform recommendation system," *Journal Name/Source Unavailable*, vol. 2, no. 6, pp. 66–73, 2025.
- [7] W. Kong, T. Tai, P. Naveen, K. Ng, and L. D. Krisnawati, "Exploring Generative AI recommender systems in e-commerce: Model, evaluation metric, and comparative review," *Journal Name/Source Unavailable*, vol. 4, no. 3, 2025.
- [8] K. Liao and H. A. Santoso, "The role of Generative AI in e-commerce recommender systems: Methods, trends and insights," *Journal Name/Source Unavailable*, vol. 4, no. 3, 2025.
- [9] T. Nadu, "AI-powered e-commerce personalization and recommendation systems," *Journal Name/Source Unavailable*, vol. 5, no. 1, pp. 2092–2099, 2025.
- [10] S. Necula, "AI-driven recommendations: A systematic review of the state of the art in e-commerce," *Applied Sciences*, 2023.
- [11] V. Pleskach, O. Bulgakova, V. Zosimov, E. Vashchilina, and I. Tumasoniene, "An e-commerce recommendation systems based on analysis of consumer behavior models," *Journal Name/Source Unavailable*, vol. 0972, pp. 0–3, 2023.
- [12] L. Qu, "Single-shot embedding dimension search in recommender system," in *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR '22)*, Madrid, Spain, July 11–15, 2022, vol. 1, no. 1, doi: 10.1145/3477495.3532060.