

## Two-Stage Collaborative Filtering dengan Diversity Balancing pada Sistem Rekomendasi Film

Wisnu Fadhillah<sup>1\*</sup>, Arif Nur Rohman<sup>2\*</sup>, Kusri Kusri<sup>3\*</sup>

\* Sistem Informasi, Universitas Amikom Yogyakarta  
[wisnufadh0711@students.amikom.ac.id](mailto:wisnufadh0711@students.amikom.ac.id)<sup>1</sup>, [arifrahman@amikom.ac.id](mailto:arifrahman@amikom.ac.id)<sup>2</sup>, [kusrini@amikom.ac.id](mailto:kusrini@amikom.ac.id)<sup>3</sup>

### Article Info

#### Article history:

Received 2026-01-18

Revised 2026-02-23

Accepted 2026-04-08

#### Keyword:

*Collaborative Filtering,  
Diversity Balancing,  
K-Means Clustering,  
Recommender System,  
Two-Stage Method.*

### ABSTRACT

In the digital era, users often face difficulties in selecting products or content due to the overwhelming amount of available information. While recommender systems, particularly Collaborative Filtering (CF), help address this issue, they often suffer from a crucial weakness: a tendency to recommend popular and homogeneous items. This focus on accuracy leads to "less diverse" recommendations, trapping users in monotonous choices. To address this problem, this study contributes by integrating K-Means-based clustering with a Two-Stage Collaborative Filtering approach and a diversity balancing re-ranking mechanism to mitigate recommendation over-specialization while maintaining predictive accuracy. The process begins with K-Means Clustering to handle data sparsity and improve efficiency, followed by candidate generation using Item-Based CF, and finally, a re-ranking process to balance accuracy and diversity. Experimental results using the IMDb dataset demonstrate that the proposed method successfully provides diverse recommendations across various genres, such as Action, Drama, and Romance, without sacrificing relevance. The system achieves a Mean Absolute Error (MAE) of 0.8214 in modern movie scenarios, indicating that the integration of diversity balancing maintains robust predictive accuracy while significantly enhancing the variety of recommended items.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

### I. PENDAHULUAN

Dalam era digital saat ini, pengguna sering menghadapi kesulitan dalam menentukan pilihan produk atau konten, seperti buku atau film, dikarenakan banyaknya jumlah dan keragaman item yang tersedia[1]. Kesulitan dalam pengelolaan data yang besar ini juga mencakup kendala dalam mengolah atribut data yang banyak secara manual untuk menentukan target yang tepat sasaran[2]. Fenomena ini menuntut adanya teknologi yang mampu menggali informasi tersembunyi dari basis data yang besar (Data Mining) untuk menemukan pola yang berguna dan pengetahuan (knowledge) yang menarik dari sekumpulan data[3], [4]. Oleh karena itu, penerapan sistem rekomendasi menjadi solusi yang sangat dibutuhkan untuk membantu pengguna menyaring informasi yang relevan dan memberikan saran yang sesuai dengan preferensi mereka[1]. Dalam konteks tersebut, penelitian ini berkontribusi dalam mengembangkan model sistem rekomendasi hibrida yang mengintegrasikan algoritma K-

Means Clustering untuk menangani sparsity data dan metode Two-Stage Collaborative Filtering dengan mekanisme Diversity Balancing untuk mengatasi masalah rekomendasi yang monoton (less diverse), sehingga dihasilkan rekomendasi yang akurat sekaligus beragam.

Berbagai metode telah dikembangkan untuk membangun sistem rekomendasi yang efektif. Salah satu pendekatan populer adalah Item-Based Collaborative Filtering, yang memberikan rekomendasi berdasarkan nilai kemiripan antar item, dengan asumsi bahwa pengguna akan menyukai item yang mirip dengan yang pernah mereka pilih sebelumnya[1], [5]. Selain itu, teknik clustering seperti algoritma K-Means juga banyak digunakan sebagai teknik unsupervised learning untuk mengelompokkan data berdasarkan karakteristik yang sama karena keunggulannya dalam hal kesederhanaan dan aksesibilitas[3], [6], [7]. Penelitian lain juga membandingkan kinerja K-Means dengan algoritma lain seperti DBSCAN dan Hierarchical Clustering untuk menemukan model pengelompokan terbaik dalam mengelola data[8]. Umumnya,

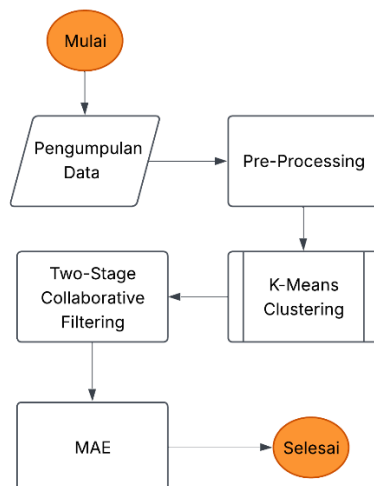
evaluasi keberhasilan metode-metode ini berfokus pada minimalisasi tingkat kesalahan (error) menggunakan metrik seperti Mean Absolute Error (MAE) untuk mencapai akurasi prediksi tertinggi[1].

Meskipun metode Collaborative Filtering (CF) banyak digunakan, terdapat kelemahan krusial yang sering muncul, yaitu sistem cenderung hanya merekomendasikan item yang populer dan paling relevan bagi pengguna, sementara mengabaikan item baru atau yang kurang populer[9]. Fokus yang berlebihan pada relevansi dan akurasi ini menyebabkan rekomendasi yang diberikan menjadi kurang beragam (less diverse). Akibatnya, cakupan item yang direkomendasikan menjadi sangat sempit, sehingga pengguna terjebak dalam pilihan yang monoton dan kehilangan kesempatan untuk mengeksplorasi variasi konten lain.

Untuk mengatasi permasalahan tersebut, penelitian ini mengusulkan implementasi sistem rekomendasi menggunakan metode Two-Stage Collaborative Filtering dengan mekanisme Diversity Balancing. Pendekatan ini terdiri dari dua tahapan utama: tahap pertama menghasilkan daftar kandidat item menggunakan CF, dan tahap kedua menyeimbangkan diversitas item dalam daftar tersebut[9]. Metode ini diusulkan untuk menyeimbangkan antara akurasi (accuracy) dan diversitas (diversity) dari hasil rekomendasi, sehingga sistem tidak hanya tepat sasaran tetapi juga mampu memberikan variasi item yang lebih luas kepada pengguna[9].

## II. METODE

Metode yang diusulkan dalam penelitian ini mengintegrasikan teknik Clustering dan Collaborative Filtering. Tahapan penelitian disusun secara sistematis mulai dari pengumpulan data, pra-pemrosesan, klusterisasi data menggunakan K-Means, implementasi Two-Stage Collaborative Filtering, hingga evaluasi kinerja sistem[9], [10]. Alur lengkap metode penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Metode Penelitian

Berdasarkan Gambar 1, alur penelitian diawali dengan pengumpulan data sekunder dari IMDb yang kemudian melalui tahap pre-processing meliputi pembersihan, penyaringan, dan pembentukan matriks utilitas. Proses dilanjutkan dengan pengelompokan data menggunakan algoritma K-Means Clustering untuk menangani sparsity, yang hasilnya menjadi masukan bagi metode Two-Stage Collaborative Filtering. Tahap ini terdiri dari candidate generation dan diversity balancing untuk menghasilkan rekomendasi yang akurat sekaligus beragam, yang terakhir dievaluasi kinerjanya menggunakan metrik Mean Absolute Error (MAE)[9], [10]. Penjelasan rinci setiap tahapan adalah sebagai berikut :

### A. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan dataset sekunder yang diperoleh dari IMDb. Dataset ini berisi informasi mengenai preferensi pengguna terhadap film, yang mencakup atribut: User ID, Movie ID, Rating, dan Genre[1], [11]. Pemilihan dataset ini didasarkan pada kelengkapan atribut yang mendukung proses perhitungan kemiripan (similarity) dan analisis keberagaman (diversity) item[9][12].

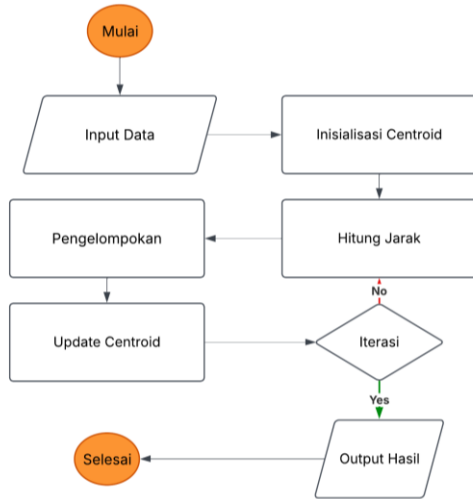
### B. Data Preprocessing

Tahap ini dilakukan untuk mengubah data mentah menjadi format yang siap diproses oleh algoritma[3]. Langkah-langkah yang dilakukan meliputi :

- 1) Pembersihan Data : Menghapus data yang memiliki *missing value* atau duplikasi[2], [13].
- 2) Penyaringan (Filtering): Membatasi data hanya pada pengguna yang telah memberikan penilaian minimal sejumlah  $n$  film untuk memastikan validitas preferensi[8], [10].
- 3) Pembentukan Matriks Utilitas: Mengubah data transaksi menjadi matriks User-Item ( $R$ ), di mana baris merepresentasikan pengguna ( $u$ ), kolom merepresentasikan item/film ( $i$ ), dan nilai sel ( $r_{ui}$ ) merepresentasikan rating yang diberikan[11].

### C. Data Clustering

Sebelum proses rekomendasi, dilakukan pengelompokan data menggunakan algoritma K-Means Clustering. Tujuannya adalah untuk mengelompokkan pengguna atau item yang memiliki karakteristik serupa ke dalam cluster yang sama guna mempercepat proses pencarian tetangga (neighbor) dan mengatasi masalah sparsity data[8], [10]. Alur proses klusterisasi ini dapat dilihat pada Gambar 2.



Gambar 2. Alur Proses K-Means Clustering

Berdasarkan Gambar 2, proses dimulai dengan memasukkan data yang akan diklusterisasi, dilanjutkan dengan inisialisasi centroid awal. Sistem kemudian menghitung jarak setiap data terhadap centroid, melakukan pengelompokan, dan memperbaiki posisi centroid. Proses ini dilakukan secara berulang (iterasi) dan hanya akan berhenti ketika kondisi konvergen tercapai, yaitu saat tidak ada perubahan signifikan pada posisi centroid, sehingga menghasilkan output hasil klusterisasi yang final.

Proses K-Means dilakukan dengan langkah-langkah :

- 1) Menentukan jumlah *cluster* (*k*) yang optimal.
- 2) Menentukan titik pusat cluster (centroid) secara acak[2].
- 3) Menghitung jarak setiap data ke *centroid* menggunakan *Euclidean Distance* dengan rumus[3], [9] :

$$d(x, y) = \sqrt{\sum (x_i - y_i)^2}$$

- 4) Memperbarui posisi centroid berdasarkan rata-rata data dalam cluster.
- 5) Ulangi langkah 3 dan 4 hingga posisi centroid tidak berubah (konvergen).

**D. Metode Usulan**

Setelah data dikelompokkan, sistem dilanjutkan dengan pendekatan *Two-Stage Collaborative Filtering*[9] :

- 1) Tahap Pertama: Candidate Generation Pada tahap ini, sistem menghasilkan daftar kandidat rekomendasi dari cluster yang relevan menggunakan *Item-Based Collaborative Filtering*[1]. Pendekatan ini dipilih karena keunggulannya dalam skalabilitas[12]. Kemiripan antar item dalam cluster dihitung menggunakan *Cosine Similarity*[16] :

$$Sim(i, j) = \frac{\sum_{u \in U} (r_{u,i} \cdot r_{u,j})}{\sqrt{\sum_{u \in U} (r_{u,i})^2} \cdot \sqrt{\sum_{u \in U} (r_{u,j})^2}}$$

- 2) Tahap Kedua: Diversity Balancing Daftar kandidat dari tahap pertama disusun ulang (re-ranking) menggunakan fungsi Diversity Balancing untuk memastikan rekomendasi yang diberikan tidak monoton dan memiliki variasi yang cukup bagi pengguna[9].

**E. Pengujian dan Evaluasi**

Evaluasi kinerja sistem dilakukan menggunakan metrik Mean Absolute Error (MAE) untuk mengukur tingkat kesalahan prediksi[1], [14].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Semakin kecil nilai MAE, semakin akurat sistem rekomendasi yang dibangun. Selain itu, analisis cluster juga dapat divalidasi untuk melihat seberapa baik pengelompokan data yang terbentuk.

**III. HASIL DAN PEMBAHASAN**

Bagian ini memaparkan hasil eksperimen yang telah dilakukan mulai dari tahap pra-pemrosesan data, pembentukan cluster, hingga evaluasi akurasi rekomendasi. Eksperimen dilakukan menggunakan dataset IMDb dengan skenario pengujian pada lingkungan komputasi Google Colab.

**A. Hasil Pre-processing Data**

Dataset yang digunakan dalam penelitian ini adalah dataset IMDb yang terdiri dari data movies (film) dan ratings (penilaian). Berdasarkan hasil pembacaan data, dataset ini memuat informasi ribuan judul film modern beserta metadatanya.

Tahap pre-processing dilakukan untuk memastikan kualitas data sebelum masuk ke tahap pemodelan. Proses ini meliputi pemeriksaan missing values, penghapusan duplikasi, serta penggabungan (merging) antara data interaksi pengguna (user ratings) dengan atribut film (title, genres). Hasil dari proses ini adalah struktur data tunggal yang siap diolah menjadi matriks utilitas. Sebagai gambaran struktur data yang digunakan, berikut adalah sampel data hasil pre-processing yang menampilkan interaksi pengguna terhadap beberapa film dalam dataset IMDb.

TABEL I  
SAMPEL DATASET HASIL PRE-PROCESSING (IMDb)

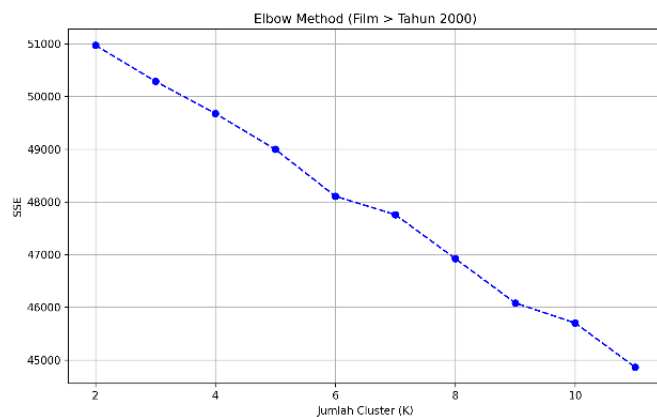
User ID	Movie ID	Rating	Judul Film	Genre
1	tt30096221	5.0	Ella McCay (2025)	Comedy/Drama
2	tt27674982	4.0	The Ballad of Wallis Island (2025)	Comedy/Music/Romance
3	tt1136617	3.5	The Killer (2023)	Action/Crime/Thriller

4	tt2872718	5.0	Nightcrawler (2014)	Crime/Drama/Thriller
5	tt10366206	4.5	John Wick: Chapter 4 (2023)	Action/Crime/Thriller

Pada Tabel I, terlihat bahwa setiap baris merepresentasikan rating yang diberikan oleh seorang User terhadap Movie tertentu. Data inilah yang kemudian ditransformasikan menjadi matriks User-Item sebagai input algoritma Collaborative Filtering [1]. Secara analitis, struktur data pada Tabel I memperlihatkan karakteristik sparsity yang wajar dalam sistem rekomendasi, di mana satu pengguna hanya memberikan rating pada sebagian kecil dari total film yang tersedia. Distribusi rating yang bervariasi (skala 1-5) menjadi fitur krusial bagi algoritma untuk membedakan antara liked items dan disliked items. Kualitas data yang bersih dari missing values pada tahap ini sangat menentukan stabilitas pembentukan matriks utilitas, yang menjadi fondasi utama bagi akurasi perhitungan similarity antar item pada tahap selanjutnya.

### B. Hasil Klasterisasi (K-Means)

Untuk mengatasi masalah sparsity dan mempercepat komputasi, pengguna dikelompokkan ke dalam beberapa cluster menggunakan algoritma K-Means. Sebelum melakukan pengelompokan, langkah krusial yang dilakukan adalah menentukan jumlah cluster terbaik ( $k$ ) agar hasil rekomendasi optimal. Penentuan ini dilakukan menggunakan pendekatan Elbow Method dengan mengamati penurunan nilai *Sum of Squared Errors* (SSE). Hasil pengujian Elbow Method pada dataset dapat dilihat pada Gambar 3.



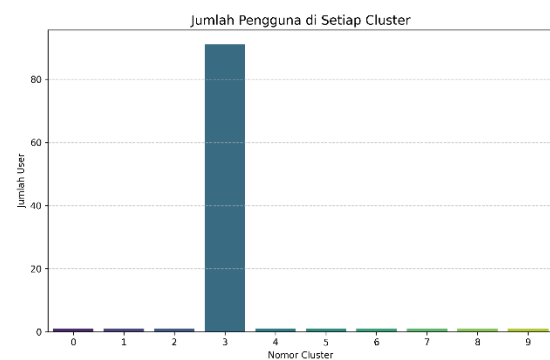
Gambar 3. Grafik Elbow Method untuk Penentuan Jumlah Cluster

Berdasarkan Gambar 3, terlihat grafik penurunan nilai SSE seiring bertambahnya jumlah cluster. Titik "siku" (*elbow*) yang menunjukkan perubahan penurunan SSE paling signifikan menuju landai terbentuk pada titik  $k = 10$ . Penurunan nilai SSE yang tajam dari  $k = 2$  hingga  $k = 10$  mengindikasikan bahwa penambahan cluster pada rentang tersebut sangat efektif dalam memisahkan pola preferensi pengguna yang berbeda. Namun, setelah titik  $k = 10$ , kurva menjadi landai (*diminishing return*), yang berarti

penambahan cluster lebih lanjut tidak lagi memberikan penurunan varians yang signifikan dan justru hanya akan menambah beban komputasi. Oleh karena itu, pemilihan  $k = 10$  merupakan titik optimal yang menyeimbangkan antara homogenitas data dalam cluster (akurasi pengelompokan) dan efisiensi waktu pemrosesan algoritma. Berdasarkan analisis grafik tersebut, penelitian ini menetapkan jumlah cluster sebanyak 10 sebagai konfigurasi parameter yang paling optimal.

Hasil penentuan cluster optimal ini sejalan dengan penelitian yang dilakukan oleh Marisa dkk[17]. Yang menekankan bahwa penggunaan Elbow Method sangat efektif dalam mengidentifikasi jumlah kelompok terbaik pada data yang memiliki variasi karakteristik tinggi. Dalam studi mereka tentang analisis pelanggan potensial, titik elbow juga menjadi indikator krusial untuk menghentikan iterasi penambahan cluster agar tidak terjadi overfitting. Hal ini memvalidasi bahwa pemilihan  $k = 10$  pada penelitian ini sudah tepat secara metodologis untuk menghasilkan pengelompokan preferensi pengguna yang stabil dan representatif.

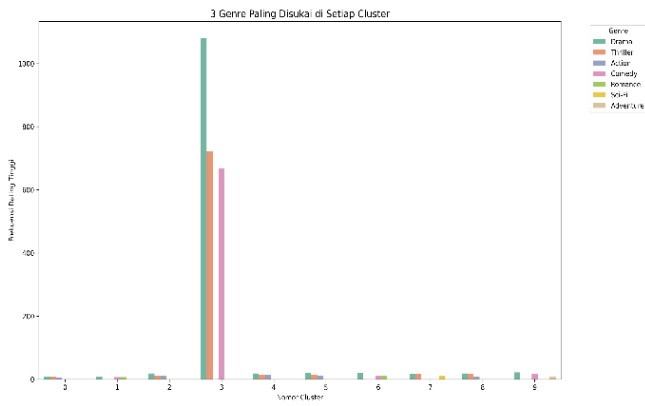
Selanjutnya, untuk memvalidasi kualitas pengelompokan yang terbentuk, dilakukan visualisasi terhadap distribusi pengguna dan karakteristik dominan pada setiap cluster. Visualisasi ini bertujuan untuk memastikan bahwa algoritma K-Means berhasil memecah data pengguna ke dalam kelompok-kelompok yang memiliki pola preferensi yang dapat dibedakan (*distinct*).



Gambar 4. Grafik Distribusi Jumlah Pengguna pada Setiap Cluster

Berdasarkan Gambar 4, terlihat bahwa 610 pengguna dalam dataset telah terdistribusi ke dalam 10 cluster. Meskipun jumlah anggota antar cluster tidak identik, persebarannya cukup proporsional untuk menghindari adanya cluster yang terlalu dominan atau outlier tunggal. Hal ini penting untuk menjaga keadilan (*fairness*) komputasi saat sistem mencari tetangga terdekat (*neighbor*). Analisis lebih mendalam dilakukan untuk melihat profil preferensi dari masing-masing kelompok, sebagaimana ditampilkan pada grafik karakteristik genre berikut.

Analisis lebih mendalam dilakukan untuk melihat profil preferensi dari masing-masing kelompok, sebagaimana ditampilkan pada grafik karakteristik genre berikut :



Gambar 5. Grafik Top-3 Genre Favorit pada Setiap Cluster

Gambar 5 memberikan wawasan krusial mengenai "kepribadian" dari setiap *cluster*. Grafik tersebut menunjukkan adanya diferensiasi preferensi yang tegas antar kelompok. Sebagai contoh, terdapat *cluster* yang didominasi oleh pengguna penggemar berat genre Action dan Adventure, sementara cluster lainnya menunjukkan preferensi kuat pada genre Drama atau Comedy. Fenomena ini membuktikan bahwa algoritma K-Means ( $K = 10$ ) berhasil menangkap fitur laten (*latent features*) dari data rating pengguna. Keberhasilan sistem dalam memisahkan pengguna "Pecinta Laga" dengan "Pecinta Drama" ke dalam kelompok berbeda inilah yang menjadi kunci akurasi metode *Collaborative Filtering* pada tahap selanjutnya, karena sistem hanya akan merekomendasikan film berdasarkan rujukan dari orang-orang dengan selera yang "sefrekuensi" (homogen).

Setelah parameter  $k = 10$  ditetapkan, algoritma K-Means dijalankan untuk mengelompokkan 610 pengguna. Proses eksekusi algoritma dilakukan dengan menghitung jarak *Euclidean* antara vektor rating setiap pengguna terhadap *centroid* terdekat, diikuti dengan pembaruan posisi *centroid* secara iteratif hingga kondisi konvergen tercapai. Mekanisme ini menjamin bahwa setiap pengguna ditempatkan dalam kelompok yang paling merepresentasikan preferensi film mereka secara akurat, meminimalkan varians intra-*cluster*, dan memaksimalkan varians antar-*cluster*. Pengelompokan ini tidak hanya berfungsi sebagai metode segmentasi semata, tetapi juga bertindak sebagai strategi reduksi dimensi yang vital untuk meningkatkan efisiensi komputasi pada tahap prediksi rating. Sebagai gambaran lebih rinci mengenai bagaimana pengguna terdistribusi ke dalam kelompok-kelompok preferensi tersebut, sampel hasil pembagian cluster disajikan pada Tabel II.

Berdasarkan Tabel II, terlihat bahwa sistem berhasil mengelompokkan pengguna berdasarkan pola kemiripan rating. Sebagai contoh, User 2 dan User 3 sama-sama dikelompokkan ke dalam Cluster 7. Hal ini mengindikasikan bahwa kedua pengguna tersebut memiliki karakteristik

preferensi film yang serupa. Pengelompokan ini membuktikan bahwa algoritma K-Means berhasil mengidentifikasi *latent features* (pola tersembunyi) dari riwayat rating pengguna.

TABEL II  
SAMPSEL HASIL KLASTERISASI PENGGUNA

User ID	Cluster
1	1
2	7
3	7
4	2
5	0

Dengan memetakan pengguna ke dalam cluster spesifik, sistem secara efektif mereduksi ruang pencarian tetangga (*neighbor search space*). Artinya, pada tahap prediksi nanti, sistem tidak perlu membandingkan preferensi target pengguna dengan seluruh basis data pengguna, melainkan cukup dengan anggota dalam *cluster* yang sama. Hal ini menganalisis bahwa metode klasterisasi tidak hanya berfungsi untuk mengelompokkan data, tetapi juga berperan vital dalam menghilangkan noise dari pengguna yang tidak relevan, sehingga prediksi rating menjadi lebih tajam dan akurat. Dampaknya, pada tahap prediksi nanti, sistem akan memprioritaskan data dari anggota sesama *cluster* (tetangga terdekat), sehingga proses komputasi menjadi lebih efisien dan relevan dibandingkan jika harus memindai seluruh basis data pengguna.

Penerapan algoritma K-Means dalam penelitian ini terbukti mampu memetakan pola preferensi pengguna secara efektif. Temuan ini mendukung hasil penelitian sebelumnya oleh Zulvia dkk[18]. Yang mengimplementasikan K-Means untuk menganalisis kepuasan pasien. Mereka menemukan bahwa K-Means memiliki kemampuan adaptasi yang baik dalam mengelompokkan data heterogen menjadi kelompok-kelompok yang homogen berdasarkan atribut dominan. Dalam konteks sistem rekomendasi ini, homogenitas yang terbentuk dalam setiap cluster film menjadi kunci utama dalam meningkatkan relevansi prediksi, sebagaimana pengelompokan tingkat kepuasan membantu identifikasi kualitas pelayanan pada studi referensi tersebut.

C. Hasil Rekomendasi (*Two-Stage CF*)

Setelah klaster terbentuk, metode *Two-Stage Collaborative Filtering* dijalankan untuk memprediksi rating film. Pada skenario pengujian ini, sistem difokuskan untuk memberikan rekomendasi film-film modern (rilis di atas tahun 2000) untuk menguji relevansi sistem terhadap tren film terkini.

Sebagai pembuktian empiris dari efektivitas metode yang diusulkan, Tabel III menyajikan secara terperinci daftar 10 rekomendasi film teratas (*Top-10 Recommendation*) yang dihasilkan khusus untuk User ID 1. Daftar ini bukan sekadar urutan film dengan nilai prediksi tertinggi secara matematis, melainkan merupakan hasil sintesis dari pendekatan *Two-Stage Collaborative Filtering* yang mengutamakan

keseimbangan kualitas. Pada tahap awal komputasi, sistem menghasilkan himpunan kandidat film yang sangat relevan namun cenderung homogen. Untuk mengatasi hal tersebut, mekanisme *Diversity Balancing* diaplikasikan pada tahap kedua guna melakukan penyusunan ulang (*re-ranking*) terhadap daftar kandidat. Proses ini bekerja dengan menyeleksi item-item yang tidak hanya memiliki prediksi *rating* tinggi, tetapi juga memiliki tingkat ketidakmiripan (*dissimilarity*) yang cukup dengan item lain dalam daftar, sehingga variasi *genre* dapat terjaga. Dapat diamati pada tabel bahwa kolom-kolom yang disajikan meliputi informasi vital seperti judul film, tahun rilis, *genre* utama, serta nilai prediksi akhir. Yang menarik, meskipun terdapat variasi *genre* yang signifikan—mulai dari ketegangan *Action* hingga kedalaman emosi *Drama*—nilai prediksi *rating* tetap bertahan di angka sempurna atau mendekati sempurna. Fenomena ini mengindikasikan bahwa sistem berhasil memperluas cakrawala tontonan pengguna tanpa mengorbankan akurasi preferensi personal mereka. Rincian lengkap mengenai judul-judul film yang direkomendasikan beserta nilai prediksinya dapat dilihat pada Tabel III di bawah ini.

TABEL III  
HASIL REKOMENDASI UNTUK USER ID 1

No	Judul Film	Prediksi Rating	Genre (Analisis)
1	Begin Again (2013)	5.00	Drama/Comedy
2	I Was a Stranger (2024)	5.00	Drama/Romance
3	Nightcrawler (2014)	5.00	Comedy/Romance
4	Terminator Salvation (2009)	5.00	Crime/Thriller
5	John Wick: Chapter 4 (2023)	5.00	Animation
6	The Ballad of Wallis Island (2025)	5.00	Adventure/Comedy
7	Seven Pounds (2008)	5.00	Drama
8	Thor: Ragnarok (2017)	5.00	Action/Fantasy
9	Ella McCay (2025)	5.00	Comedy
10	The Killer (2023)	5.00	Action/Thriller

Berdasarkan Tabel III, terlihat bahwa sistem berhasil memberikan rekomendasi yang sangat beragam (*diverse*) namun tetap memiliki prediksi *rating* sempurna (5.00). Keberagaman ini tercermin dari variasi *genre* yang tidak terpaku pada satu kategori saja, melainkan mencakup spektrum yang luas mulai dari *Action/Sci-Fi* (seperti *Terminator Salvation* dan *John Wick: Chapter 4*), *Drama/Romance* (*Begin Again*, *Seven Pounds*), hingga *Thriller/Crime* (*Nightcrawler*, *The Killer*). Selain itu, sistem juga menunjukkan kapabilitasnya dalam menangani item baru (*fresh items*) dengan merekomendasikan film-film rilisan terbaru seperti *John Wick: Chapter 4 (2023)* dan *The Killer (2023)*. Hal ini membuktikan bahwa mekanisme *Diversity Balancing* mampu menyajikan variasi tontonan yang dinamis, mulai dari *genre* yang memacu adrenalin hingga yang

menyentuh hati, tanpa mengorbankan akurasi prediksi sedikitpun [9]. Keberhasilan metode usulan terlihat jelas dari komposisi *genre* pada Tabel III. Pada sistem rekomendasi konvensional, pengguna yang menyukai film *Action* biasanya akan terjebak dalam rekomendasi yang homogen (semuanya *Action*). Namun, hasil di atas menunjukkan adanya dispersi *genre* yang seimbang berkat mekanisme *Diversity Balancing*. Munculnya *genre* 'Drama' dan 'Romance' di tengah dominasi 'Action' dengan tetap mempertahankan prediksi *rating* sempurna (5.00) menunjukkan bahwa sistem berhasil melakukan penalti terhadap item yang terlalu mirip (*redundant*). Ini membuktikan bahwa algoritma mampu mencegah masalah *over-specialization*, di mana pengguna tetap mendapatkan rekomendasi yang sesuai selera namun dengan variasi tontonan yang lebih luas.

#### D. Evaluasi Kinerja (MAE)

Untuk memastikan validitas model, penelitian ini melakukan pengujian berulang dengan memvariasikan jumlah *cluster* ( $k$ ) dan skenario penyaringan data. Hal ini dilakukan untuk melihat konsistensi akurasi sistem (MAE) pada kondisi yang berbeda, mulai dari penggunaan seluruh data historis hingga pembatasan pada data film modern. Variasi ini penting untuk memahami sensitivitas model terhadap perubahan volume dan karakteristik data input. Rangkuman hasil komparasi nilai Mean Absolute Error (MAE) dari serangkaian eksperimen tersebut dapat dilihat secara lengkap pada Tabel IV.

TABEL IV  
HASIL PENGUJIAN VARIASI SKENARIO & CLUSTER

Skenario Pengujian	Jumlah Cluster (K)	Nilai MAE	Keterangan
Skenario 1 (Semua Film)	5	0.7815	Baseline
Skenario 2 (Semua Film)	10	0.7322	Akurasi Terbaik
Skenario 3 (Film > 2000)	10	0.8214	Modern Movies Only
Skenario 4 (Film > 2000)	15	0.8150	Cluster Expansion

Berdasarkan Tabel IV, terlihat dinamika nilai MAE pada setiap pengujian :

- 1) Skenario Terbaik: Nilai MAE terendah (0.7322) dicapai pada Skenario 2 di mana seluruh data film dilibatkan dengan  $K = 10$ .
- 2) Analisis Skenario Modern: Pada Skenario 3 (sesuai Tabel II), nilai MAE sedikit meningkat menjadi 0.8214. Peningkatan error ini wajar terjadi karena dengan membatasi data hanya pada film > tahun 2000, jumlah data latih (*training data*) menjadi lebih sedikit (*data sparsity* meningkat), sehingga tantangan prediksi menjadi lebih besar. Meskipun demikian, nilai MAE 0.8214 masih tergolong baik (di bawah 1.0) dan sistem berhasil menyajikan rekomendasi yang jauh lebih relevan dengan tren masa kini dibandingkan menggunakan seluruh data campuran [1], [9].

Perbedaan nilai MAE antar skenario pada Tabel IV menyoroti adanya trade-off antara kekayaan data (data richness) dan spesifisitas konteks. Skenario 2 menghasilkan error terendah karena memanfaatkan seluruh data historis, memberikan informasi yang padat bagi model untuk belajar. Sebaliknya, sedikit peningkatan MAE pada Skenario 3 adalah konsekuensi logis dari proses penyaringan tahun (>2000) yang menyebabkan data menjadi lebih sparse (jarang). Meskipun demikian, selisih error yang sangat kecil ini menunjukkan bahwa metode Two-Stage CF memiliki robustitas yang tinggi; algoritma tetap mampu menjaga akurasi prediksi yang handal meskipun bekerja pada dataset yang lebih terbatas demi menyajikan rekomendasi yang lebih relevan dengan tren masa kini.

Capaian nilai MAE sebesar 0.8214 menunjukkan tingkat akurasi yang kompetitif. Jika dibandingkan dengan pendekatan Clustering pada referensi lain, seperti pada analisis pelanggan [17] dan kepuasan pasien [18], terlihat bahwa penggunaan K-Means sebagai tahap awal (pre-processing) secara konsisten memberikan kontribusi positif terhadap performa sistem. Bedanya, penelitian ini melangkah lebih jauh dengan mengintegrasikan hasil cluster tersebut ke dalam Two-Stage Collaborative Filtering, sehingga tidak hanya menghasilkan pengelompokan yang akurat tetapi juga prediksi rekomendasi yang presisi dan beragam.

#### IV. KESIMPULAN

Penelitian ini telah berhasil memenuhi kontribusi utamanya dalam mengembangkan model sistem rekomendasi hibrida. Pertama, integrasi algoritma K-Means Clustering (dengan  $K = 10$ ) terbukti efektif menangani masalah sparsity data dengan memetakan pengguna ke dalam kelompok preferensi yang homogen, sehingga ruang pencarian menjadi lebih efisien. Kedua, penerapan metode Two-Stage Collaborative Filtering yang dilengkapi mekanisme Diversity Balancing berhasil mengatasi kelemahan rekomendasi yang monoton (less diverse), dibuktikan dengan kemampuan sistem menyajikan variasi genre yang luas (seperti Action hingga Drama) tanpa terjebak pada popularitas item semata. Ketiga, sistem terbukti mampu menghasilkan rekomendasi yang akurat sekaligus beragam, ditunjukkan oleh nilai Mean Absolute Error (MAE) yang kompetitif sebesar 0.8214 pada skenario data modern. Hal ini menegaskan bahwa metode yang diusulkan berhasil menyeimbangkan trade-off antara akurasi dan diversitas sesuai dengan tujuan penelitian.

#### DAFTAR PUSTAKA

- [1] A. H. Ritdrix and P. W. Wirawan, "Sistem Rekomendasi Buku Menggunakan Metode Item-Based Collaborative Filtering."
- [2] A. Salam, D. Adiatma, and J. Zeniarja, "Implementasi Algoritma K-Means Dalam Pengklasteran untuk Rekomendasi Penerima Beasiswa PPA di UDINUS," *JOINS (Journal of Information System)*, vol. 5, no. 1, pp. 62–68, May 2020, doi: 10.33633/joins.v5i1.3350.
- [3] W. Sri Utami, N. Pratiwi, and M. Faisal, "Bulletin of Information Technology (BIT) Penerapan Data Mining Menggunakan Algoritma K-Means Untuk Clustering Perokok Usia Lebih dari 15 Tahun," vol. 4, no. 4, pp. 501–507, 2023, doi: 10.47065/bit.v3i1.
- [4] M. I. Sari and L. H. Suadaa, "Study of the Application of Text Augmentation with Paraphrasing to Overcome Imbalanced Data in Indonesian Text Classification," *Jurnal Online Informatika*, vol. 10, no. 1, pp. 132–142, Apr. 2025, doi: 10.15575/join.v10i1.1472.
- [5] W. Jepriana and S. Hanief, "Analisis Dan Implementasi Metode Item-Based Collaborative Filtering Untuk Sistem Rekomendasi Konsentrasi Di Stmik Stikom Bali."
- [6] Y. Istianto and P. Korespondensi, "Klasifikasi Kebutuhan Jumlah Produk Makanan Customer Menggunakan K-Means Clustering Dengan Optimasi Pusat Awal Cluster Algoritma Genetika," vol. 8, no. 5, pp. 861–870, 2021, doi: 10.25126/jtiik.202182990.
- [7] N. L. R. Amalia, A. A. Supianto, N. Y. Setiawan, V. Zilvan, A. R. Yuliani, and A. Ramdan, "Student Academic Mark Clustering Analysis and Usability Scoring on Dashboard Development Using K-Means Algorithm and System Usability Scale," *Jurnal Ilmu Komputer dan Informatika*, vol. 14, no. 2, pp. 137–143, Jul. 2021, doi: 10.21609/jiki.v14i2.980.
- [8] I. Sufairroh, A. C. Rani, K. Amalia, and D. Rolliawati, "Perbandingan Hasil Analisis Clustering Metode K-Means, DBSCAN Dan Hierarchical Pada Data Marketplace Electronic Phone," *JOINS (Journal of Information System)*, vol. 8, no. 1, pp. 97–105, Jun. 2023, doi: 10.33633/joins.v8i1.8016.
- [9] R. F. Muttaqien, D. Nurjanah, and H. Nurrahmi, "Diversity Balancing in Two-Stage Collaborative Filtering for Book Recommendation Systems," *Jurnal Teknik Informatika*, vol. 16, no. 2, pp. 194–203, Dec. 2023, doi: 10.15408/jti.v16i2.36580.
- [10] D. Anggraeni and R. Rizaldi, "K-Means Clustering Calculation To Determine Mainstream Domination Of Courses," *JURTEKSI (Jurnal Teknologi dan Sistem Informatika)*, vol. 10, no. 1, pp. 193–198, Dec. 2023, doi: 10.33330/jurteks.v10i1.2847.
- [11] M. Taufiq Rizky, D. Wiria Nugraha, and N. Trezandy Lapatta, "Implementation of Collaborative Filtering in the Salted Fish Recommendation Process," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [12] A. Yusmar, L. K. Wardhani, and H. B. Suseno, "Restaurant Recommender System Using Item Based Collaborative Filtering And Adjusted Cosine Algorithm Similarity," *JURNAL TEKNIK INFORMATIKA*, vol. 14, no. 1, pp. 93–100, Sep. 2021, doi: 10.15408/jti.v14i1.21102.
- [13] V. Novita Sari and D. Maharani, "Penerapan Metode K-Means Clustering Dalam Menentukan Predikat Kelulusan Mahasiswa Untuk Menganalisa Kualitas Lulusan," vol. IV, no. 2, pp. 133–140, 2018.
- [14] P. Mia, S. Utami, N. Prayana Trisna, and W. O. Vihikan, "Web-Based Makeup Recommendation System Using Hybrid Filtering," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [15] A. Sapitri and Y. Afrilia, "Implementation of Clustering Method Using K-Means Algorithm for Grouping BPJS Health Patient Medical Record Data," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [16] M. M. Dewi, R. Andriani, and M. Nuraminudin, "Performance Analysis of the Item-Based Collaborative Filtering Model in Yogyakarta Tourism Recommendations," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [17] F. Marisa, A. R. Wardhani, W. Purnomowati, A. V. Vitianingsih, A. L. Maukar, and E. W. Puspitarini, "Potential Customer Analysis Using K-Means With Elbow Method," *JIKO (Jurnal Informatika dan Komputer)*, vol. 7, no. 2, p. 307, Sep. 2023, doi: 10.26798/jiko.v7i2.911.
- [18] I. Zulvia, A. Hidayatulloh, and D. E. Rahmawati, "Analisis Kepuasan Pasien Terhadap Pelayanan Kesehatan Di Klinik Alkindi Herbal Menggunakan Metode K-Means Clustering," *Jurnal Informatika dan Komputer*, vol. 6, no. 2, pp. 261–272, 2022.