



## Penerapan Collaborative Filtering untuk Sistem Rekomendasi Film

Rachel Junita Pangemanan<sup>1</sup>, Nasya Emanuel Soekamto<sup>2</sup>, Glerio Adrian<sup>3</sup>, Ade Yusupa<sup>4</sup>, Victor Tarigan<sup>5</sup>

<sup>1,2,3,4,5</sup>Program Studi Informatika, Teknik Elektro, Fakultas Teknik, Universitas Sam Ratulangi

<sup>1</sup>[rachelpangemanan026@student.unsrat.ac.id](mailto:rachelpangemanan026@student.unsrat.ac.id), <sup>2</sup>[nasyasoekamto026@student.unsrat.ac.id](mailto:nasyasoekamto026@student.unsrat.ac.id),

<sup>3</sup>[glerioadrian026@student.unsrat.ac.id](mailto:glerioadrian026@student.unsrat.ac.id), <sup>4</sup>[ade@unsrat.ac.id](mailto:ade@unsrat.ac.id), <sup>5</sup>[victortarigan@unsrat.ac.id](mailto:victortarigan@unsrat.ac.id)

### Abstract

Recommender systems play a crucial role in helping users navigate the vast amount of available content. This study implements and evaluates User-Based and Item-Based Collaborative Filtering methods for a movie recommendation system using the MovieLens 100K dataset. The dataset is preprocessed and split for evaluation using RMSE, MAE, Precision, Recall, and F1-Score metrics to assess the accuracy and relevance of recommendations. The results indicate that Item-Based Collaborative Filtering outperforms User-Based Collaborative Filtering in terms of prediction accuracy and recommendation relevance. This advantage is attributed to the stability of item relationships compared to the dynamic nature of user preferences. To further clarify the findings, a comparative analysis of the generated recommendations is provided, along with visualizations of performance metrics. Despite its effectiveness, challenges such as sparsity and limited ratings for certain movies remain. Future research could explore hybrid approaches that integrate Collaborative Filtering with deep learning or content-based methods to enhance recommendation quality and mitigate cold-start issues.

Keywords: *Collaborative Filtering, Movie Recommendation, User-Based, Item-Based, Evaluation Metrics*

### Abstrak

Sistem rekomendasi berperan penting dalam membantu pengguna menemukan konten yang relevan di tengah banyaknya informasi yang tersedia. Penelitian ini mengimplementasikan dan mengevaluasi metode User-Based dan Item-Based Collaborative Filtering untuk sistem rekomendasi film menggunakan dataset MovieLens 100K. Dataset ini dipersiapkan dan dibagi untuk evaluasi menggunakan metrik RMSE, MAE, Precision, Recall, dan F1-Score guna menilai akurasi prediksi dan relevansi rekomendasi. Hasil penelitian menunjukkan bahwa metode Item-Based Collaborative Filtering memiliki performa lebih baik dibandingkan User-Based Collaborative Filtering dalam hal akurasi prediksi dan relevansi rekomendasi. Keunggulan ini disebabkan oleh stabilitas hubungan antar-item dibandingkan preferensi pengguna yang lebih dinamis. Untuk memperjelas temuan, analisis perbandingan hasil rekomendasi disajikan bersama visualisasi metrik performa. Meskipun efektif, metode ini masih menghadapi tantangan seperti sparsity dan keterbatasan jumlah rating pada beberapa film. Penelitian selanjutnya dapat mengeksplorasi pendekatan hibrida yang menggabungkan Collaborative Filtering dengan deep learning atau content-based filtering guna meningkatkan kualitas rekomendasi serta mengatasi masalah cold-start.

Kata kunci: *Collaborative Filtering, Rekomendasi Film, User-Based, Item-Based, Metrik Evaluasi*

### 1. Pendahuluan

Sistem rekomendasi menjadi salah satu solusi utama dalam menghadapi lonjakan jumlah informasi di era digital. Dalam industri hiburan, khususnya platform penyedia layanan film dan serial, sistem rekomendasi berperan penting dalam membantu pengguna menemukan konten yang sesuai dengan preferensi mereka tanpa harus mencari secara manual di antara ribuan pilihan yang tersedia. Salah satu pendekatan yang banyak digunakan dalam sistem rekomendasi adalah

*Collaborative Filtering*, yang terbagi menjadi dua metode utama, yaitu *User-Based Collaborative Filtering* dan *Item-Based Collaborative Filtering* [1][15][16]. Selain itu, metode *machine learning* telah banyak diterapkan dalam analisis sentimen pengguna terhadap berbagai produk dan layanan, termasuk dalam industri otomotif, sebagaimana yang ditunjukkan dalam penelitian mengenai analisis sentimen mobil listrik di media sosial [14].



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

Dalam *User-Based Collaborative Filtering*, sistem memberikan rekomendasi berdasarkan kesamaan preferensi antar pengguna. Metode ini mengasumsikan bahwa pengguna yang memiliki riwayat interaksi serupa akan memiliki preferensi yang mirip terhadap item tertentu. Pendekatan ini bekerja dengan menghitung kesamaan antara pengguna berdasarkan rating yang diberikan terhadap film yang sama, biasanya menggunakan metrik seperti *cosine similarity* atau *Pearson correlation coefficient*. Setelah itu, sistem mengidentifikasi pengguna dengan tingkat kesamaan tertinggi dan memprediksi rating suatu film berdasarkan rata-rata rating yang diberikan oleh pengguna-pengguna tersebut [4][6].

Sementara itu, *Item-Based Collaborative Filtering* menganalisis hubungan antar-item dengan menggunakan pola rating dari banyak pengguna untuk mengidentifikasi item yang serupa. Dalam metode ini, sistem pertama-tama membangun matriks kesamaan antar film berdasarkan pola rating pengguna, kemudian memberikan rekomendasi film yang memiliki kemiripan tertinggi dengan film yang sudah ditonton atau disukai pengguna. Keunggulan dari pendekatan ini adalah stabilitas hubungan antar-item yang tidak terlalu dipengaruhi oleh perubahan preferensi individu pengguna, sehingga dapat menghasilkan rekomendasi yang lebih konsisten dalam jangka panjang [4][6].

Kedua metode ini telah diterapkan dalam berbagai sistem rekomendasi, termasuk dalam domain film, musik, dan e-commerce, dengan tujuan meningkatkan pengalaman pengguna melalui rekomendasi yang lebih personal [5][7]. Namun, meskipun telah banyak diterapkan, pendekatan *Collaborative Filtering* masih menghadapi sejumlah tantangan. Salah satunya adalah masalah *cold-start*, yang terjadi ketika pengguna baru atau item baru belum memiliki cukup data untuk menghasilkan rekomendasi yang akurat [6]. Selain itu, terdapat pula permasalahan terkait *sparsity*, di mana sebagian besar pengguna hanya memberikan rating pada sejumlah kecil item, sehingga matriks interaksi menjadi jarang terisi dan sulit untuk diolah secara efektif [8].

Oleh karena itu, penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi metode *User-Based Collaborative Filtering* serta *Item-Based Collaborative Filtering* dalam sistem rekomendasi film menggunakan dataset MovieLens 100K [9]. Dataset MovieLens 100K merupakan salah satu dataset yang banyak digunakan dalam penelitian sistem rekomendasi karena memiliki data rating dari ribuan pengguna terhadap ratusan film dalam skala yang masih dapat dikelola secara komputasional [9]. Penelitian sebelumnya menunjukkan bahwa dataset ini sering digunakan sebagai basis untuk menguji berbagai metode rekomendasi, baik berbasis *Collaborative Filtering*, *Content-Based Filtering*, maupun pendekatan hibrida

[3][10]. Dalam penelitian ini, efektivitas metode *User-Based* dan *Item-Based* akan dibandingkan menggunakan metrik evaluasi seperti *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), Precision, Recall, dan *F1-Score* untuk menilai tingkat akurasi prediksi rating yang diberikan oleh sistem rekomendasi [2][11]. Selain itu, untuk memberikan pemahaman yang lebih mendalam mengenai efektivitas masing-masing metode, hasil rekomendasi yang dihasilkan akan dianalisis dan divisualisasikan.

Beberapa penelitian terdahulu telah membahas penerapan *Collaborative Filtering* dalam sistem rekomendasi film. Misalnya, penelitian oleh Wang [1] mengusulkan pendekatan *Content-Based Collaborative Filtering* yang menggabungkan informasi fitur film dengan pendekatan *Collaborative Filtering* untuk meningkatkan akurasi rekomendasi. Penelitian lain oleh Yadav et al. [2] mengusulkan pendekatan hibrida yang menggabungkan *User-Based* dan *Item-Based Collaborative Filtering* dengan metode *deep learning* untuk meningkatkan kualitas rekomendasi. Sementara itu, penelitian oleh Fitriyeh et al. [3] membahas dampak pemberian bobot pada metode *User-Based* dan *Item-Based* dalam meningkatkan performa sistem rekomendasi film. Penelitian oleh Nagapraveena et al. [4] lebih berfokus pada penerapan *Collaborative Filtering* dalam sistem rekomendasi film dan mengevaluasi performanya menggunakan dataset yang berbeda. Selain itu, penelitian oleh Ifada et al. [5] membandingkan pendekatan *Collaborative Filtering* dengan metode hibrida dalam konteks sistem rekomendasi film, menunjukkan bahwa pendekatan hibrida dapat memberikan hasil yang lebih baik dalam beberapa kasus.

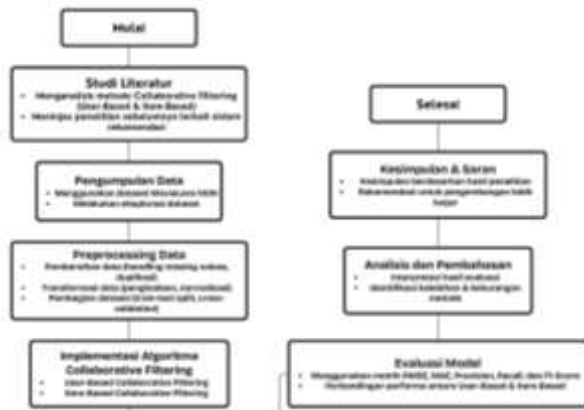
Berbeda dengan penelitian-penelitian sebelumnya, penelitian ini akan secara khusus membandingkan metode *User-Based* dan *Item-Based Collaborative Filtering* secara langsung menggunakan dataset MovieLens 100K dan mengevaluasi performanya berdasarkan metrik RMSE, MAE, Precision, Recall, dan *F1-Score*. Studi ini bertujuan untuk mengidentifikasi metode yang lebih optimal dalam memberikan rekomendasi film dengan akurasi yang lebih baik, serta memahami kelebihan dan keterbatasan masing-masing pendekatan [7][12].

Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem rekomendasi yang lebih baik, khususnya dalam industri hiburan. Selain itu, penelitian ini juga dapat menjadi dasar bagi pengembangan sistem rekomendasi yang lebih kompleks dengan menggabungkan metode tradisional *Collaborative Filtering* dengan teknik yang lebih canggih seperti *deep learning* dan *matrix factorization*. Dengan demikian, penelitian ini tidak hanya mengevaluasi efektivitas metode yang sudah ada, tetapi

juga memberikan dasar untuk pengembangan sistem rekomendasi yang lebih inovatif dan adaptif terhadap kebutuhan pengguna [13].

## 2. Metode Penelitian

Studi ini menerapkan penyaringan kolaboratif pada sistem rekomendasi film dengan dataset MovieLens 100K, membandingkan efektivitas metode berbasis pengguna dan berbasis item dalam memberikan rekomendasi yang relevan.



Gambar 1. Bagan Alir Penelitian

### 2.1 Dataset dan Persiapan Data

Dataset yang digunakan dalam penelitian ini adalah MovieLens 100K dari GroupLens Research, yang berisi 100.000 peringkat dari 943 pengguna terhadap 1.682 film, dengan setiap pengguna memberikan setidaknya 20 peringkat. Dataset ini disediakan dalam format teks terpisah tab (.data dan .item), yang mencakup informasi ID pengguna, ID film, rating (1–5), dan timestamp, serta metadata tambahan seperti genre film.

Sebelum digunakan, data melalui tahap pembersihan untuk menghilangkan kemungkinan duplikasi dan memastikan konsistensi nilai peringkat. Selain itu, timestamp dikonversi ke format yang lebih mudah dibaca jika diperlukan. Dataset kemudian dibagi menjadi training set (80%) dan test set (20%) untuk menguji performa model. Selain itu, tersedia skema cross-validation 5-fold (u1.base – u5.base) yang memungkinkan evaluasi model dengan data yang lebih bervariasi.

Persiapan ini bertujuan untuk memastikan bahwa metode penyaringan kolaboratif dapat secara optimal menganalisis pola preferensi pengguna dan meningkatkan akurasi rekomendasi.

#### 2.1.1 Pembersihan Data

Langkah pertama dalam persiapan dataset adalah pembersihan data, yang mencakup identifikasi dan penanganan data yang tidak lengkap, duplikat, atau tidak valid. Meskipun MovieLens 100K sudah dikurasi,

validasi tetap diperlukan untuk memastikan tidak ada data hilang atau rusak. Studi sebelumnya, seperti oleh Fitriyeh et al. [3], menyoroti dampak ketidaksempurnaan data terhadap kualitas rekomendasi. Oleh karena itu, tahap ini mencakup beberapa langkah utama:

1. Pengecekan data yang hilang: Data yang memiliki nilai kosong atau tidak lengkap dapat dihapus atau diisi menggunakan metode imputasi tertentu.
2. Penghapusan data duplikat: Jika terdapat data yang tercatat lebih dari sekali, maka hanya satu entri yang dipertahankan.
3. Validasi skala peringkat: Memastikan bahwa semua peringkat berada dalam rentang yang benar (1-5). Jika terdapat nilai di luar rentang ini, data tersebut dapat dihapus atau dikoreksi.
4. Pembersihan metadata: Beberapa atribut seperti genre film terkadang memiliki inkonsistensi atau kesalahan penulisan yang dapat diperbaiki.

#### 2.1.2 Transformasi Data

Setelah data dibersihkan, langkah selanjutnya adalah melakukan transformasi agar data dapat digunakan dalam algoritma penyaringan kolaboratif. Transformasi ini melibatkan perubahan format data agar sesuai dengan model yang akan diterapkan. Beberapa transformasi yang dilakukan adalah sebagai berikut:

1. Pengkodean ID pengguna dan film: Karena ID pengguna dan film dalam dataset MovieLens 100K berbentuk numerik namun tidak berurutan, dilakukan pemetaan ulang agar lebih terstruktur untuk analisis lebih lanjut.
2. Matriks pengguna-item: Dataset MovieLens 100K perlu diubah menjadi bentuk matriks pengguna-item, di mana setiap baris mewakili pengguna, setiap kolom mewakili film, dan nilai dalam matriks adalah peringkat yang diberikan oleh pengguna terhadap film tersebut. Jika seorang pengguna belum memberi peringkat pada film tertentu, maka nilai dalam matriks tersebut akan dibiarkan kosong atau diisi dengan metode tertentu, seperti pengisian rata-rata peringkat [4].
3. Normalisasi data: Peringkat dalam dataset dapat dinormalisasi untuk mengurangi bias yang muncul akibat perbedaan skala penilaian antar pengguna. Beberapa metode normalisasi yang sering digunakan adalah pengurangan nilai rata-rata pengguna atau skala min-max.
4. Ekstraksi fitur tambahan: Untuk meningkatkan efektivitas penyaringan kolaboratif, beberapa penelitian seperti yang dilakukan oleh Wang [1] menunjukkan bahwa menambahkan fitur tambahan seperti genre atau informasi temporal

dapat membantu dalam menyusun rekomendasi yang lebih akurat.

### 2.1.3 Pembagian Data

Tahap akhir dari persiapan data adalah pembagian dataset menjadi subset yang digunakan untuk pelatihan dan pengujian model. Langkah ini penting untuk mengevaluasi performa sistem rekomendasi secara objektif dan memastikan model dapat bekerja dengan baik pada data yang belum pernah dilihat sebelumnya.

1. Pembagian train-test split: Dataset MovieLens 100K dibagi menjadi 80% data latih dan 20% data uji, sebagaimana dilakukan dalam beberapa penelitian sebelumnya [5,6]. Pembagian ini menggunakan metode random split dengan parameter `random_state=42` untuk memastikan replikasi hasil.
2. Cross-validation: Untuk meningkatkan keandalan evaluasi model, digunakan *k-fold cross-validation* dengan nilai *k* tertentu [7]. Dalam metode ini, dataset dibagi menjadi *k* bagian (*folds*), di mana setiap iterasi menggunakan satu bagian sebagai data uji dan sisanya sebagai data latih. Pendekatan ini membantu mengurangi kemungkinan bias akibat pemisahan data yang tidak merata.
3. Penggunaan metode leave-one-out: Selain *k-fold cross-validation*, *leave-one-out cross-validation* (LOOCV) diterapkan pada metode penyaringan kolaboratif berbasis pengguna. Teknik ini mensimulasikan pengalaman rekomendasi dengan menghapus satu interaksi pengguna-item dari data latih dan menggunakan sisanya untuk prediksi [8]. LOOCV memungkinkan model diuji pada skenario di mana hanya satu rating dari pengguna yang tidak diketahui, meningkatkan pemahaman terhadap perilaku model pada data yang sangat terbatas.

Dengan langkah-langkah tersebut, dataset MovieLens 100K siap digunakan untuk penyaringan kolaboratif berbasis pengguna dan item, memastikan data berkualitas untuk rekomendasi yang lebih akurat.

## 2.2 Implementasi Algoritma Filtrasi Kooperatif

Implementasi algoritma filtrasi kooperatif dalam sistem rekomendasi film menggunakan dua pendekatan utama: user-based collaborative filtering dan item-based collaborative filtering. Kedua metode ini diterapkan pada dataset MovieLens 100K, yang berisi ulasan film dari berbagai pengguna [9]. Penyaringan kolaboratif didasarkan pada prinsip bahwa pengguna dengan preferensi serupa di masa lalu cenderung memiliki kesamaan preferensi di masa depan. Dengan pendekatan ini, sistem dapat mengenali pola dalam data ulasan dan

memberikan rekomendasi yang lebih personal [3], [4]. Sebelum implementasi, dilakukan persiapan data, termasuk penanganan nilai yang hilang, normalisasi, dan pemisahan dataset menjadi data pelatihan serta pengujian. Setelah itu, metode user-based dan item-based diterapkan untuk menganalisis keterkaitan antar pengguna dan item berdasarkan kesamaan ulasan.

### 2.2.1 Penyaringan Kolaboratif Berbasis Pengguna (User-Based CF)

Penyaringan kolaboratif berbasis pengguna mengidentifikasi kesamaan antara pengguna berdasarkan riwayat penilaian mereka terhadap film yang telah ditonton. Metode ini menggunakan metrik kesamaan seperti korelasi Pearson atau cosine similarity untuk menghitung tingkat kesamaan antar pengguna [8]. Langkah-langkah dalam pendekatan ini adalah sebagai berikut:

1. Membentuk matriks pengguna-item dari dataset MovieLens 100K, di mana setiap baris mewakili pengguna dan setiap kolom mewakili film.
2. Menghitung kesamaan antara pengguna menggunakan formula cosine similarity:

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

Cosine Similarity digunakan dalam penyaringan kolaboratif berbasis pengguna untuk mengukur kesamaan antara dua pengguna berdasarkan riwayat rating mereka terhadap film yang sama. Dalam rumusnya, *u* dan *v* adalah dua pengguna, *r<sub>u,i</sub>* adalah rating yang diberikan oleh pengguna *u* terhadap film *i*, dan *I* adalah himpunan film yang telah diberi rating oleh kedua pengguna tersebut. Cosine Similarity dihitung dengan membagi hasil perkalian rating dari kedua pengguna dengan hasil perkalian panjang vektor rating mereka. Nilai yang dihasilkan berkisar antara -1 hingga 1, di mana nilai lebih tinggi menunjukkan kesamaan preferensi yang lebih kuat antara dua pengguna.

3. Memilih sekelompok pengguna dengan kesamaan tertinggi sebagai tetangga pengguna target.
4. Menggunakan rata-rata tertimbang dari rating yang diberikan oleh tetangga terdekat untuk memprediksi rating pengguna target terhadap film yang belum ditonton:

$$\hat{r}_{u,i} = \bar{r}_u + \frac{\sum_{v \in N} \text{Sim}(u, v) \cdot (r_{v,i} - \bar{r}_v)}{\sum_{v \in N} |\text{Sim}(u, v)|}$$

Formula ini digunakan dalam prediksi rating pada penyaringan kolaboratif berbasis pengguna.  $\bar{r}_u$  adalah rata-rata rating yang diberikan oleh pengguna  $u$ ,  $N$  merupakan himpunan tetangga pengguna  $u$  yang memiliki kesamaan preferensi, dan  $r_{u,i}$  adalah rating yang diprediksi untuk pengguna  $u$  terhadap film  $i$ . Prediksi rating dilakukan dengan mempertimbangkan rata-rata rating pengguna serta kontribusi dari tetangga terdekatnya, di mana rating yang diberikan oleh tetangga diberi bobot berdasarkan tingkat kesamaan mereka dengan pengguna target. Pendekatan ini membantu meningkatkan akurasi rekomendasi dengan memanfaatkan preferensi pengguna yang memiliki pola penilaian serupa.

Metode ini efektif dalam memberikan rekomendasi berbasis pengalaman pengguna lain, namun memiliki keterbatasan dalam menghadapi masalah cold-start, di mana pengguna baru yang belum memberikan banyak rating akan sulit mendapatkan rekomendasi yang akurat [1].

### 2.2.2 Penyaringan Kolaboratif Berbasis Item (Item-Based CF)

Penyaringan kolaboratif berbasis item menggunakan pendekatan yang berbeda, yaitu dengan mengidentifikasi kesamaan antar film berdasarkan pola rating yang diberikan oleh pengguna. Pendekatan ini lebih stabil terhadap perubahan data dibandingkan metode berbasis pengguna karena kesamaan antar item cenderung lebih konstan seiring waktu [7]. Langkah-langkah dalam pendekatan ini adalah sebagai berikut:

1. Membentuk matriks pengguna-item dari dataset MovieLens 100K.
2. Menghitung kesamaan antara item menggunakan formula cosine similarity:

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

Formula ini digunakan dalam penyaringan kolaboratif berbasis item untuk menghitung kesamaan antara dua film,  $i$  dan  $j$ , berdasarkan pola rating dari pengguna.  $r_{u,i}$  merupakan rating yang diberikan oleh pengguna  $u$  terhadap film  $i$ , sementara  $U$  adalah himpunan pengguna

yang telah memberikan rating pada kedua film tersebut. Dengan membandingkan pola rating dari pengguna yang sama terhadap kedua film, sistem dapat menentukan tingkat kemiripan antar film. Semakin tinggi kesamaan yang dihitung, semakin besar kemungkinan kedua film tersebut memiliki karakteristik atau daya tarik yang mirip bagi pengguna lain, sehingga dapat digunakan untuk memberikan rekomendasi yang lebih relevan. [3][10]

3. Memilih sekelompok item dengan kesamaan tertinggi terhadap film yang telah ditonton oleh pengguna target.
4. Memperkirakan rating pengguna terhadap film yang belum ditonton menggunakan formula:

$$\hat{r}_{u,i} = \frac{\sum_{j \in S} \text{Sim}(i, j) \cdot r_{u,j}}{\sum_{j \in S} |\text{Sim}(i, j)|}$$

$S$  adalah himpunan film yang memiliki kemiripan tinggi dengan film  $i$  berdasarkan pola rating pengguna lain. Film-film dalam  $S$  dipilih menggunakan metrik kesamaan, seperti Cosine Similarity, untuk menentukan hubungan antarfilm. Jika pengguna  $u$  telah memberi rating pada film dalam  $S$ , sistem dapat memanfaatkannya untuk memprediksi rating pengguna terhadap film  $i$ , sehingga menghasilkan rekomendasi yang lebih akurat.

Pendekatan ini memiliki keunggulan dalam mengatasi masalah cold-start bagi pengguna baru, karena rekomendasi didasarkan pada karakteristik film daripada histori pengguna [6]. Dengan demikian, bahkan pengguna yang belum memberikan banyak rating tetap dapat memperoleh rekomendasi yang relevan. Namun, metode ini menghadapi tantangan dalam merekomendasikan film dengan sedikit rating, karena terbatasnya data yang tersedia untuk menghitung kesamaan antarfilm [4]. Dalam penelitian ini, kedua pendekatan penyaringan kolaboratif dibandingkan berdasarkan akurasi rekomendasi menggunakan metrik evaluasi seperti Root Mean Squared Error (RMSE) dan Mean Absolute Error (MAE), yang akan dibahas lebih lanjut dalam bagian evaluasi kinerja [11].

### 2.3 Evaluasi dan Metode Penelitian Kinerja

Evaluasi sistem rekomendasi dalam penelitian ini menilai performa metode collaborative filtering, khususnya pendekatan berbasis pengguna dan item. Kinerja diukur menggunakan metrik seperti RMSE, MAE, Precision, Recall, dan F1-Score, yang membantu

menganalisis akurasi dan relevansi rekomendasi bagi pengguna [1][3][4][5].

1. Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE)

RMSE dan MAE adalah metrik yang digunakan untuk mengukur sejauh mana perbedaan antara peringkat yang diprediksi oleh sistem dan peringkat aktual dari pengguna. RMSE lebih sensitif terhadap kesalahan yang besar karena menggunakan kuadrat dari perbedaan antara prediksi dan nilai aktual, sedangkan MAE mengukur rata-rata kesalahan secara absolut [2], [4]. Rumus untuk RMSE:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (r_i - \hat{r}_i)^2}$$

Formula ini digunakan untuk mengukur akurasi sistem rekomendasi dengan menghitung selisih antara rating aktual yang diberikan oleh pengguna dan rating yang diprediksi oleh sistem.  $N$  adalah jumlah data uji yang digunakan dalam evaluasi,  $r_i$  merupakan rating sebenarnya yang diberikan oleh pengguna terhadap item ke- $i$ , dan  $\hat{r}_i$  = rating aktual pengguna terhadap item ke- $i$ ,  $\hat{r}_i$  adalah rating yang diprediksi oleh sistem. Semakin kecil selisih antara rating aktual dan prediksi, semakin akurat sistem rekomendasi.

Sementara itu, rumus untuk MAE Adalah:

$$MAE = \frac{1}{N} \sum_{i=1}^N |r_i - \hat{r}_i|$$

RMSE dan MAE digunakan dalam penelitian ini untuk membandingkan akurasi prediksi antara metode user-based dan item-based collaborative filtering. Nilai RMSE dan MAE yang lebih kecil menunjukkan bahwa sistem memiliki prediksi yang lebih akurat [1], [3].

2. Precision, Recall, dan F1-Score

Selain metrik berbasis error, evaluasi sistem rekomendasi juga dilakukan dengan menggunakan Precision, Recall, dan F1-Score. Metrik-metrik ini sering digunakan untuk mengukur kualitas rekomendasi berdasarkan relevansi hasil yang diberikan kepada pengguna [4], [6]. Precision mengukur proporsi item yang direkomendasikan yang benar-benar relevan dengan preferensi pengguna. Rumus untuk Precision adalah:

$$Precision = \frac{TP}{TP + FP}$$

Formula ini digunakan untuk mengukur efektivitas sistem rekomendasi dalam memberikan item yang benar-benar relevan bagi pengguna. Precision menunjukkan proporsi item yang direkomendasikan oleh sistem yang benar-benar relevan dibandingkan dengan total item yang direkomendasikan. Dalam formula ini, True Positive (TP) adalah jumlah item yang direkomendasikan dan relevan, sementara False Positive (FP) adalah jumlah item yang direkomendasikan tetapi ternyata tidak relevan. Precision bernilai tinggi menunjukkan bahwa sistem mampu memberikan rekomendasi yang lebih tepat sasaran dengan sedikit kesalahan dalam menyertakan item yang tidak relevan.

Recall mengukur berapa banyak item relevan yang berhasil direkomendasikan dibandingkan dengan total item relevan yang tersedia. Rumus untuk Recall adalah:

$$Recall = \frac{TP}{TP + FN}$$

Formula ini digunakan untuk mengukur sejauh mana sistem rekomendasi dapat menangkap semua item yang relevan bagi pengguna. Recall menghitung proporsi item relevan yang berhasil direkomendasikan dibandingkan dengan total item relevan yang tersedia. Dalam formula ini, False Negative (FN) adalah jumlah item yang sebenarnya relevan tetapi tidak direkomendasikan oleh sistem, yang berarti pengguna mungkin melewatkan item yang seharusnya mereka sukai. Semakin kecil nilai FN, semakin baik kinerja sistem dalam menjangkau item yang relevan.

F1-Score digunakan untuk menggabungkan nilai Precision dan Recall dalam satu metrik yang memberikan keseimbangan antara keduanya. Rumus F1-Score adalah:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Metrik Precision, Recall, dan F1-Score digunakan dalam penelitian ini untuk mengevaluasi seberapa baik sistem dapat memberikan rekomendasi yang relevan dengan



preferensi pengguna. F1-Score yang lebih tinggi mengindikasikan bahwa sistem rekomendasi lebih baik dalam menyeimbangkan Precision dan Recall [3], [5].

### 3. Pengujian dan Validasi Model

Pengujian dilakukan dengan teknik validasi data menggunakan metode k-fold cross-validation, di mana dataset dibagi menjadi beberapa bagian (folds) untuk memastikan hasil evaluasi yang lebih robust dan menghindari bias akibat distribusi data yang tidak merata. Dalam penelitian ini, digunakan teknik 5-fold cross-validation [7], [8].

Pada setiap iterasi, model dilatih menggunakan k - 1 bagian dari dataset dan diuji menggunakan bagian yang tersisa. Hasil evaluasi dari semua iterasi kemudian dirata-ratakan untuk mendapatkan estimasi kinerja model yang lebih akurat.

### 4. Perbandingan Kinerja Metode User-Based dan Item-Based Collaborative Filtering

Setelah evaluasi menggunakan RMSE, MAE, Precision, Recall, dan F1-Score, hasil dari metode user-based dan item-based collaborative filtering dibandingkan untuk menentukan efektivitasnya dalam merekomendasikan film. Hasil ini kemudian dianalisis dengan penelitian sebelumnya, seperti oleh Fitriyeh et al. [3], yang menunjukkan bahwa kombinasi kedua metode dapat meningkatkan akurasi, serta Nagapraveena et al. [4], yang menyatakan bahwa item-based lebih unggul pada data berskala besar. Evaluasi sistematis ini memberikan wawasan mendalam tentang efektivitas collaborative filtering pada dataset MovieLens 100K.

## 3. Hasil dan Pembahasan

### 3.1 Hasil

Bagian ini membahas hasil evaluasi metode User-Based Collaborative Filtering (CF) dan Item-Based Collaborative Filtering (CF) secara rinci. Evaluasi dilakukan menggunakan metrik RMSE, MAE, Precision, Recall, dan F1-Score untuk mengukur akurasi rekomendasi. Hasil disajikan dalam bentuk tabel serta divisualisasikan melalui bar chart dan line chart guna memperjelas perbandingan performa kedua metode. Analisis lebih lanjut mencakup keunggulan dan kelemahan masing-masing metode serta faktor-faktor yang memengaruhi performanya.

#### 3.1.1 Evaluasi Kinerja Model

Evaluasi kinerja model dilakukan dengan mengukur akurasi prediksi rating menggunakan RMSE dan MAE serta menilai relevansi rekomendasi dengan Precision,

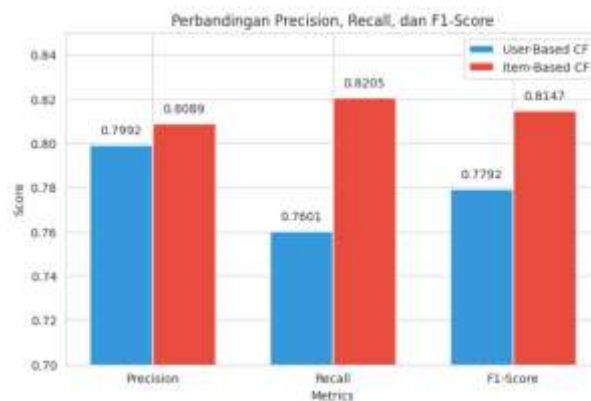
Recall, dan F1-Score. Hasil eksperimen menunjukkan bahwa Item-Based Collaborative Filtering (CF) memiliki performa lebih baik dibandingkan User-Based CF. Item-Based CF mencatat RMSE sebesar 0.8970 dan MAE sebesar 0.6912, lebih rendah dibandingkan User-Based CF yang memiliki RMSE 0.9275 dan MAE 0.7164, menandakan prediksi rating yang lebih akurat. Dari segi relevansi rekomendasi, Item-Based CF juga unggul dengan Precision 0.8089, Recall 0.8205, dan F1-Score 0.8147, dibandingkan dengan User-Based CF yang memperoleh Precision 0.7992, Recall 0.7601, dan F1-Score 0.7792. Keunggulan Item-Based CF dapat dikaitkan dengan kestabilannya terhadap perubahan data pengguna dan ketahanannya terhadap masalah cold-start, yang sering menjadi kendala pada User-Based CF. Oleh karena itu, dalam konteks dataset MovieLens 100K, metode berbasis item terbukti cenderung lebih optimal dalam menghasilkan rekomendasi yang lebih akurat dan relevan. Berikut adalah tabel evaluasi kinerja model:

Tabel 1. Evaluasi Kinerja Model

Metode	RMSE	MAE	Precision	Recall	F1-Score
User-Based CF	0.9275	0.7164	0.7992	0.7601	0.7792
Item-Based Cf	0.8970	0.6912	0.8089	0.8205	0.8147

#### 3.1.2 Visualisasi Hasil Evaluasi

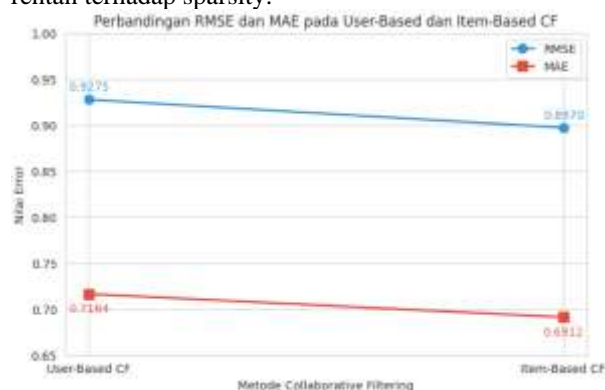
Visualisasi hasil evaluasi ditampilkan dalam dua grafik yang merepresentasikan kinerja metode Collaborative Filtering berbasis pengguna (User-Based CF) dan berbasis item (Item-Based CF).



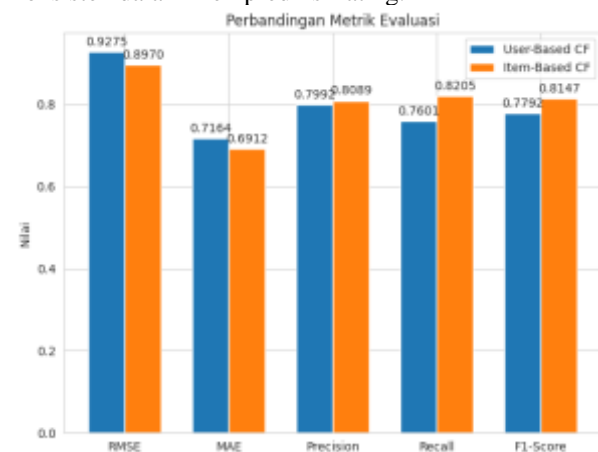
Gambar 2. Bar Chart Perbandingan Nilai Precision, Recall dan F1-Score

Gambar 2 menunjukkan perbandingan Precision, Recall, dan F1-Score antara User-Based dan Item-Based Collaborative Filtering (CF). Item-Based CF

unggul di semua metrik, dengan Precision 0.8089 vs. 0.7992, Recall 0.8205 vs. 0.7601, dan F1-Score 0.8147 vs. 0.7792. Keunggulan ini menunjukkan bahwa metode berbasis item lebih efektif dalam menangkap preferensi pengguna dan memberikan rekomendasi yang lebih akurat. Hal ini kemungkinan disebabkan oleh stabilitas hubungan antar item dibandingkan hubungan antar pengguna yang lebih dinamis dan rentan terhadap sparsity.



Gambar 3. Line Chart Perbandingan Nilai RMSE dan MAE  
 Gambar 3 membandingkan nilai RMSE dan MAE antara User-Based dan Item-Based Collaborative Filtering (CF). Item-Based CF menunjukkan error lebih rendah, menandakan prediksi rating yang lebih akurat. RMSE turun dari 0.9275 (User-Based CF) menjadi 0.8970, sementara MAE berkurang dari 0.7164 menjadi 0.6912. Keunggulan ini disebabkan oleh stabilitas hubungan antar item yang lebih konsisten dibandingkan kesamaan antar pengguna yang lebih dinamis. Secara keseluruhan, Item-Based CF terbukti lebih akurat dan konsisten dalam memprediksi rating.



Gambar 4. Bar Chart Perbandingan Metrik Evaluasi  
 Gambar 4 menunjukkan bahwa metode Item-Based Collaborative Filtering memiliki RMSE dan MAE yang lebih rendah dibandingkan User-Based, menandakan prediksi rating yang lebih akurat dan lebih mendekati nilai sebenarnya. Selain itu, dalam metrik klasifikasi, metode Item-Based juga unggul dengan nilai Precision, Recall, dan F1-Score yang lebih tinggi, menunjukkan bahwa metode ini lebih baik dalam merekomendasikan film yang relevan bagi pengguna. Perbedaan ini dapat

disebabkan oleh karakteristik Item-Based yang lebih stabil dalam mengenali pola kesamaan antar item, sementara User-Based lebih rentan terhadap data yang jarang (sparse). Dengan demikian, berdasarkan hasil evaluasi, metode Item-Based Collaborative Filtering menunjukkan performa yang lebih unggul dalam meningkatkan akurasi dan relevansi rekomendasi dibandingkan User-Based Collaborative Filtering.

### 3. 2 Pembahasan

Bagian ini membahas hasil evaluasi performa dari metode User-Based Collaborative Filtering (CF) dan Item-Based CF berdasarkan metrik evaluasi yang telah digunakan.

#### 3. 2. 1 Analisis Perbandingan User-Based CF dan Item-Based CF

Metode User-Based Collaborative Filtering (CF) dan Item-Based CF memiliki pendekatan yang berbeda untuk memberikan rekomendasi film kepada pengguna. CF Berbasis Pengguna melibatkan preferensi pengguna untuk menilai film, membuatnya efektif dalam situasi cold-start. Namun, ini dapat sensitif terhadap perubahan preferensi pengguna, menyebabkan masalah kinerja saat waktu rating singkat [1]. CF Berbasis Item lebih stabil karena hubungan antara peringkat item dari semua pengguna, sehingga lebih akurat untuk perubahan data [3]. Hasil evaluasi menunjukkan bahwa CF Berbasis Item memiliki nilai RMSE dan MAE yang lebih tinggi daripada CF Berbasis Pengguna, memberikan prediksi yang lebih akurat berdasarkan data item [4].

Selain akurasi prediksi, efektivitas kedua metode juga dapat dianalisis dari segi relevansi rekomendasi menggunakan metrik Precision, Recall, dan F1-Score. Hasil eksperimen menunjukkan bahwa Item-Based CF memiliki nilai Precision dan Recall yang lebih tinggi dibandingkan User-Based CF, yang berarti metode ini lebih efektif dalam merekomendasikan film yang sesuai dengan preferensi pengguna [5]. Keunggulan ini disebabkan oleh kemampuan Item-Based CF dalam mengidentifikasi pola kesamaan antar film yang lebih stabil dibandingkan hubungan antar pengguna yang cenderung dinamis. Namun, pendekatan ini juga memiliki keterbatasan, terutama pada kasus di mana item memiliki sedikit rating, sehingga sulit untuk menentukan kemiripan antar item secara akurat [6][17]. Dengan demikian, meskipun Item-Based CF lebih unggul dalam banyak aspek, pemilihan metode terbaik tetap bergantung pada karakteristik data yang digunakan serta tujuan sistem rekomendasi yang ingin dicapai.

#### 3. 2. 2 Perbandingan dengan Penelitian Sebelumnya

Hasil penelitian ini menunjukkan bahwa Item-Based Collaborative Filtering (CF) lebih unggul dalam hal akurasi prediksi dibandingkan User-Based CF, sebagaimana juga ditemukan dalam penelitian sebelumnya. Studi yang dilakukan oleh Fitriyeh et al. [3]



menunjukkan bahwa pemberian bobot pada metode Item-Based CF dapat meningkatkan performa rekomendasi dibandingkan dengan pendekatan berbasis pengguna. Selain itu, penelitian oleh Nagapraveena et al. [4] menegaskan bahwa Item-Based CF lebih efektif dalam menangani masalah sparsity karena pola hubungan antar item cenderung lebih stabil dibandingkan hubungan antar pengguna. Namun, beberapa penelitian lain menunjukkan bahwa kombinasi antara User-Based dan Item-Based CF, atau pendekatan hybrid seperti yang dikembangkan oleh Yadav et al. [2], dapat lebih meningkatkan akurasi sistem rekomendasi. Oleh karena itu, meskipun hasil penelitian ini sejalan dengan studi sebelumnya yang mengunggulkan Item-Based CF, masih terdapat peluang untuk meningkatkan performa dengan menggabungkan pendekatan berbeda.

### 3.2.3 Implikasi Hasil terhadap Bidang Informatika

Hasil penelitian ini memberikan kontribusi penting dalam pengembangan sistem rekomendasi berbasis kecerdasan buatan di bidang informatika, khususnya dalam penerapan Collaborative Filtering. Dengan semakin banyaknya data pengguna yang tersedia di berbagai platform digital, pemilihan metode yang tepat dalam sistem rekomendasi menjadi krusial untuk meningkatkan pengalaman pengguna. Keunggulan Item-Based CF dalam menangani perubahan data dan mengatasi masalah cold-start bagi pengguna baru menjadikannya metode yang lebih dapat diandalkan untuk implementasi di berbagai aplikasi berbasis data besar [6]. Selain itu, temuan ini juga dapat diterapkan dalam berbagai domain lain, seperti e-commerce, layanan streaming, dan platform edukasi daring, di mana personalisasi konten sangat dibutuhkan untuk meningkatkan interaksi pengguna [5]. Dengan perkembangan teknologi yang pesat, penelitian ini juga dapat menjadi dasar bagi eksplorasi lebih lanjut dalam mengintegrasikan Collaborative Filtering dengan teknik lain, seperti deep learning dan content-based filtering.

### 3.2.4 Keterbatasan Penelitian dan Potensi Pengembangan Selanjutnya

Meskipun penelitian ini menunjukkan bahwa Item-Based CF lebih unggul dibandingkan User-Based CF dalam hal akurasi dan relevansi rekomendasi, terdapat beberapa keterbatasan yang perlu diperhatikan. Salah satu tantangan utama adalah ketergantungan pada jumlah rating yang tersedia, di mana film dengan sedikit rating akan sulit untuk direkomendasikan secara akurat [6]. Selain itu, penelitian ini hanya menggunakan dataset MovieLens 100K, sehingga hasilnya mungkin berbeda jika diterapkan pada dataset dengan skala lebih besar atau domain lain [9]. Untuk penelitian selanjutnya, pendekatan hybrid yang menggabungkan User-Based dan Item-Based CF dapat dieksplorasi lebih lanjut guna meningkatkan akurasi rekomendasi, seperti yang telah dibahas dalam studi Yadav et al. [2]. Selain itu,

penerapan teknik deep learning untuk mengatasi masalah sparsity dan cold-start juga dapat menjadi arah pengembangan yang menjanjikan, sebagaimana yang diusulkan oleh Kanmani et al. [7]. Dengan adanya pengembangan ini, diharapkan sistem rekomendasi dapat menjadi lebih cerdas dan adaptif terhadap kebutuhan pengguna.

## 4. Kesimpulan dan Saran

Berdasarkan hasil penelitian, metode Collaborative Filtering telah berhasil diterapkan dalam sistem rekomendasi film, sebagaimana yang diharapkan dalam pendahuluan. Evaluasi menggunakan RMSE, MAE, Precision, Recall, dan F1-Score menunjukkan bahwa metode Item-Based Collaborative Filtering memiliki performa lebih baik dibandingkan User-Based Collaborative Filtering, terutama dalam memberikan rekomendasi yang lebih akurat dan relevan. Hal ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa pendekatan berbasis item lebih stabil dalam menangani perubahan data serta lebih tahan terhadap masalah sparsity dan cold-start.

Dalam penerapan praktis di industri hiburan, sistem rekomendasi berbasis Item-Based Collaborative Filtering dapat dimanfaatkan oleh platform streaming film untuk meningkatkan pengalaman pengguna dengan menyajikan rekomendasi yang lebih tepat sasaran. Selain itu, model ini juga dapat diintegrasikan dengan teknik lain, seperti Content-Based Filtering atau Deep Learning, untuk mengatasi keterbatasan data rating dan meningkatkan kualitas rekomendasi.

Meskipun hasil penelitian menunjukkan efektivitas metode yang digunakan, masih terdapat keterbatasan, terutama dalam hal ketergantungan pada jumlah rating yang tersedia. Untuk pengembangan lebih lanjut, disarankan untuk mengeksplorasi pendekatan hibrida, yang menggabungkan Collaborative Filtering dengan teknik lain seperti Content-Based Filtering atau Deep Learning. Pendekatan ini dapat membantu mengatasi kelemahan utama Collaborative Filtering, seperti masalah sparsity dan cold-start, serta meningkatkan akurasi rekomendasi. Misalnya, dengan menggunakan model neural networks atau autoencoders, sistem dapat belajar representasi yang lebih kompleks dari pola preferensi pengguna. Selain itu, integrasi informasi tambahan seperti metadata film (genre, sutradara, atau aktor) juga dapat meningkatkan kualitas rekomendasi. Dengan menerapkan pendekatan ini, sistem rekomendasi dapat lebih adaptif dan mampu memberikan rekomendasi yang lebih relevan bagi pengguna baru maupun yang memiliki sedikit riwayat interaksi. Seiring berkembangnya teknologi dan meningkatnya kebutuhan akan personalisasi, sistem rekomendasi yang lebih cerdas dan fleksibel akan menjadi kajian menarik serta berpotensi memberikan dampak besar dalam industri hiburan di masa depan.

## Daftar Rujukan

- [1] Wang, Z. (2023). "A content-based collaborative filtering algorithm for movies and TVS recommendation." *Applied and Computational Engineering*, 15, pp.83-91. Available: <https://www.ewadirect.com/proceedings/ace/article/view/4561>
- [2] Yadav, A., Srivastava, G., dan Kumar, S. (2024). "A Hybrid Approach to Movie Recommendation System." *Journal of Management and Service Science*, 4(1), pp.1-14. Available: <https://jms.a2zjournals.com/index.php/mss/article/view/62>
- [3] Fitriyeh, F., Haqqi, N., Choiriyah, L.M., dan Ifada, N. (2024). "Weighting impact on hybrid user-based and item-based method for movie recommendation system." *Jurnal CoSciTech (Computer Science and Information Technology)*, 5(3), pp.516-525. Available: <https://ejournal.umri.ac.id/index.php/coscitech/article/view/7637>
- [4] Nagapraveena, T., Midhun, A., Rohit, dan Pragna, B. (2024). "Movie Recommendation System Using Collaborative Filtering." *International Journal of Information Technology and Computer Engineering*, 12(2), pp.426-431. Available: <https://ijitce.org/index.php/ijitce/article/view/502>
- [5] Ifada, N., Rahman, T.F., dan Sophan, M.K. (2020). "Comparing Collaborative Filtering and Hybrid based Approaches for Movie Recommendation." *Proceedings of the 6th Information Technology International Seminar (ITIS)*, Surabaya, pp.219-223. Available: [https://www.researchgate.net/publication/348673145\\_Comparing\\_Collaborative\\_Filtering\\_and\\_Hybrid\\_based\\_Approaches\\_for\\_Movie\\_Recommendation](https://www.researchgate.net/publication/348673145_Comparing_Collaborative_Filtering_and_Hybrid_based_Approaches_for_Movie_Recommendation)
- [6] Barman, S.D., Hasan, M., dan Roy, F. (2019). "A genre-based item-item collaborative filtering: facing the cold-start problem." *Proceedings of the 2019 8th International Conference on Software and Computer Applications*, Penang, Malaysia, pp.258-262. Available: [https://www.researchgate.net/publication/333075691\\_A\\_Genre-Based\\_Item-Item\\_Collaborative\\_Filtering\\_Facing\\_the\\_Cold-Start\\_Problem](https://www.researchgate.net/publication/333075691_A_Genre-Based_Item-Item_Collaborative_Filtering_Facing_the_Cold-Start_Problem)
- [7] Kanmani, R.S.A., Surendiran, B., dan Ibrahim, S.P.S. (2021). "Recency augmented hybrid collaborative movie recommendation system." *International Journal of Information Technology and Management*, 13(5), pp.1829-1836. Available: [https://www.researchgate.net/publication/354057257\\_Recency\\_augmented\\_hybrid\\_collaborative\\_movie\\_recommendation\\_system](https://www.researchgate.net/publication/354057257_Recency_augmented_hybrid_collaborative_movie_recommendation_system)
- [8] Nudrat, S., Khan, H.U., Iqbal, S., Talha, M.M., Alarfaj, F.K., dan Almusallam, N. (2022). "Users' Rating Predictions Using Collaborating Filtering Based on Users and Items Similarity Measures." *Computational Intelligence and Neuroscience*, 2022(1), p.2347641. Available: <https://onlinelibrary.wiley.com/doi/10.1155/2022/2347641>
- [9] Harper, F. dan Konstan, J. (2015). "The MovieLens datasets: History and context." *ACM Transactions on Interactive Intelligent Systems*, 5(4), pp.1-19. Available: <https://files.grouplens.org/papers/harper-tiis2015.pdf>
- [10] Fajriansyah, M., Adikara, P.P., dan Widodo, A.W. (2021). "Sistem Rekomendasi Film Menggunakan Content Based Filtering." *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5(6), pp.2188-2199. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/9163>
- [11] Lubis, Y.I., Napitupulu, D.J., dan Dharma, A.S. (2020). "Implementasi Metode Hybrid Filtering (Collaborative dan Content-based) untuk Sistem Rekomendasi Pariwisata." *Proceedings of the 12th Conference on Information Technology and Electrical Engineering*, Yogyakarta, Indonesia, pp.28-35. Available: [https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&cad=rja&uact=8&ved=2ahUKewiz14PGp6WMAxVSS2cHHUgUNDIQFnoECBkQAQ&url=https%3A%2F%2Fitee.ft.ugm.ac.id%2Fdownload51.php%3Ff%3D1T-5%2520-%2520Implementasi%2520Metode%2520Hybrid%2520Filterin%2520g.pdf&usg=AOvVaw1\\_nQuCFyFEr5pxS7KDrbZH&opi=89978449](https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&cad=rja&uact=8&ved=2ahUKewiz14PGp6WMAxVSS2cHHUgUNDIQFnoECBkQAQ&url=https%3A%2F%2Fitee.ft.ugm.ac.id%2Fdownload51.php%3Ff%3D1T-5%2520-%2520Implementasi%2520Metode%2520Hybrid%2520Filterin%2520g.pdf&usg=AOvVaw1_nQuCFyFEr5pxS7KDrbZH&opi=89978449)
- [12] Widiyaningtyas, T., Hidayah, I., dan Adji, T.B. (2021). "User profile correlation-based similarity (UPCSim) algorithm in movie recommendation system." *Journal of Big Data*, 8(1), pp.1-19. Available: [https://www.researchgate.net/publication/350473829\\_User\\_profile\\_correlation-based\\_similarity\\_UPCSim\\_algorithm\\_in\\_movie\\_recommendation\\_system](https://www.researchgate.net/publication/350473829_User_profile_correlation-based_similarity_UPCSim_algorithm_in_movie_recommendation_system)
- [13] Jaja, V.L., Susanto, B., dan Sasongko, L.R. (2020). "Penerapan metode item-based collaborative filtering untuk sistem rekomendasi data MovieLens." *d'Cartesian: Jurnal Matematika dan Aplikasi*, 9(2), pp.78-83. Available: <https://ejournal.unsrat.ac.id/v3/index.php/decartesian/article/view/28274>
- [14] Tarigan, V.T., dan Yusupa, A. (2024). "Perbandingan Algoritma Machine Learning dalam Analisis Sentimen Mobil Listrik di Indonesia pada Media Sosial Twitter/X." *Jurnal Informatika Polinema*, 10(4), pp.479-490. Available: <https://jurnal.polinema.ac.id/index.php/jip/article/view/5130>
- [15] Tarigan, V.T. (2023). "Penerapan metode double exponential smoothing untuk memprediksi jumlah penjualan springbed di PT. Masindo Karya Prima." *Jurnal Informatika Polinema*, 9(3), pp.339-346. Available: <https://jurnal.polinema.ac.id/index.php/jip/article/view/3924>
- [16] Tarigan, V.T., dan Yusupa, A. (2023). "Pembuatan aplikasi data mining untuk memprediksi masa studi mahasiswa menggunakan algoritma Naive Bayes." *Jurnal Informatika Universitas Labuhanbatu*, 11(1), pp.54-62. Available: <https://jurnal.ulb.ac.id/index.php/informatika/article/view/3847/0>
- [17] Komansilan, R., Tarigan, V., dan Yusupa, A. (2024). "Analisis perbandingan metode Trend Moment dan Regresi Linear untuk meramal harga saham Bank BRI." *Jurnal Teknologi Sistem Informasi dan Sistem Komputer TGD*, 7(1), pp.24-32. Available: [https://www.researchgate.net/publication/378997838\\_Analisis\\_Perbandingan\\_Metode\\_Trend\\_Moment\\_dan\\_Regresi\\_Linear\\_Untuk\\_Meramal\\_Harga\\_Saham\\_Bank\\_BRI](https://www.researchgate.net/publication/378997838_Analisis_Perbandingan_Metode_Trend_Moment_dan_Regresi_Linear_Untuk_Meramal_Harga_Saham_Bank_BRI)