

# Model *Switching Hybrid* untuk Menangani *User* dan *Item Cold-Start*

<http://dx.doi.org/10.28932/jutisi.v12i1.12779>

Riwayat Artikel

Received: 22 Juli 2025 | Final Revision: 08 Februari 2026 | Accepted: 17 Februari 2026

Creative Commons License 4.0 (CC BY – NC)



Muhammad Ilman Aqilaa<sup>✉#1</sup>, Muhammad Yusril Helmi Setyawan<sup>#2</sup>, Cahyo Prianto<sup>#3</sup>

<sup>#</sup> Sarjana Terapan Teknik Informatika, Universitas Logistik dan Bisnis Internasional  
Jl. Sariasih No.54, Sarijadi, Kec. Sukasari, Bandung, 40151, Indonesia

<sup>1</sup>ilmanaqilaa2@gmail.com

<sup>2</sup>yusrilhelmi@ulbi.ac.id

<sup>3</sup>cahyo@ulbi.ac.id

✉Corresponding author: ilmanaqilaa2@gmail.com

**Abstrak** — Sistem rekomendasi menghadapi tantangan signifikan dalam kondisi *cold-start*, yaitu saat informasi tentang pengguna atau *item* masih terbatas. Penelitian ini mengusulkan pendekatan *hybrid switching* yang secara adaptif mengombinasikan *Content-Based Filtering* (CBF), *Collaborative Filtering* (CF) *User-Based*, dan *CF Item-Based* berdasarkan jumlah interaksi pengguna dan *item*. Evaluasi dilakukan melalui pengujian skenario *cold-start* terhadap satu pengguna, pengukuran akurasi menggunakan RMSE (*Root Mean Squared Error*) dan MAE (*Mean Absolute Error*) dengan *5-Fold Cross-Validation*, serta uji adaptivitas terhadap berbagai tingkat kondisi *cold-start* (5%, 20%, dan 50%). Hasil eksperimen menunjukkan bahwa model *hybrid* mampu menangani seluruh skenario *cold-start* secara efektif, dengan melakukan *fallback* ke metode CBF atau *CF User-Based* saat data tidak mencukupi, dan memilih *CF Item-Based* ketika informasi sudah memadai. Model ini mencatatkan performa terbaik dengan RMSE rata-rata sebesar 0.8165 dan MAE sebesar 0.6592, serta standar deviasi rendah, yang menunjukkan kestabilan performa antar-*fold*. Selain itu, sistem *hybrid* menunjukkan kemampuan adaptasi dinamis terhadap tingkat kelengkapan data, dengan pergeseran penggunaan algoritma *fallback* seiring meningkatnya kondisi *cold-start*. Dengan demikian, pendekatan *hybrid switching* tidak hanya unggul dari segi akurasi, tetapi juga fleksibel dan robust, menjadikannya solusi untuk meningkatkan kualitas sistem rekomendasi dalam skenario data yang tidak lengkap.

**Kata kunci**— *Cold-start*; *Hybrid Switching*; Sistem Rekomendasi.

## *Switching Hybrid Model for Handling User and Item Cold-Start*

**Abstract** — Recommender systems face significant challenges under *cold-start* conditions, where information about users or items is still limited. This study proposes a *hybrid switching* approach that adaptively combines *Content-Based Filtering* (CBF), *User-Based Collaborative Filtering* (CF), and *Item-Based CF* based on the number of user and item interactions. The evaluation was conducted through *cold-start* scenario testing for a single user, accuracy measurement using RMSE (*Root Mean Squared Error*) and MAE (*Mean Absolute Error*) with *5-Fold Cross-Validation*, and adaptivity testing under varying levels of *cold-start* conditions (5%, 20%, and 50%). Experimental results show that the hybrid model effectively handles all *cold-start* scenarios by falling back to CBF or *CF User-Based* when data is insufficient and choose for *CF Item-Based* when sufficient information is available. The model achieved the best performance with an average RMSE of 0.8165 and MAE of 0.6592, along with low standard deviations, indicating stable performance across folds. Furthermore, the hybrid system demonstrated dynamic adaptability to data completeness levels, with a gradual shift in *fallback* algorithm usage as *cold-start* severity increased. Therefore, the *hybrid switching* approach not only excels in accuracy but also offers flexibility and robustness, making it an effective solution for improving the quality of recommender systems in scenarios with incomplete data.

Keywords— *Cold-Start; Recommendation System; Switching Hybrid.*

## I. PENDAHULUAN

Perkembangan pesat teknologi informasi telah mendorong munculnya berbagai platform digital seperti *e-commerce*, layanan *streaming*, media sosial, hingga sistem pembelajaran daring [1]. Seiring dengan melimpahnya pilihan konten dan produk di platform-platform tersebut, muncul tantangan baru: bagaimana menyajikan informasi yang tepat, sesuai minat dan kebutuhan pengguna, secara cepat dan efisien [2]. Untuk memenuhi kebutuhan tersebut, sistem rekomendasi memiliki peranan yang sangat penting dalam meningkatkan kualitas layanan kepada pengguna [3].

Sistem rekomendasi bekerja dengan memanfaatkan data interaksi historis pengguna seperti riwayat pembelian, penilaian film, klik, maupun pencarian. Data ini kemudian diolah untuk menyajikan rekomendasi yang relevan dan dipersonalisasi, sehingga pengguna tidak perlu lagi menyaring ribuan bahkan jutaan *item* secara manual [4]. Dalam praktiknya, dua pendekatan utama yang sering digunakan adalah CBF dan CF. CBF menghasilkan rekomendasi berdasarkan kesamaan konten dengan preferensi pengguna, sedangkan CF memanfaatkan pola kesamaan antar pengguna untuk menyarankan *item* [5].

Kedua pendekatan tersebut terbukti efektif dalam berbagai skenario. Namun, keduanya memiliki keterbatasan ketika dihadapkan pada kondisi data historis yang sangat terbatas. Permasalahan ini dikenal dengan istilah *Cold-Start problem*, yaitu kondisi ketika sistem rekomendasi mengalami kesulitan dalam memberikan hasil rekomendasi yang akurat karena informasi interaksi yang dimiliki tidak mencukupi [6]. Permasalahan *Cold-Start* dapat diklasifikasikan menjadi dua bentuk utama: *User Cold-Start*, yang disebabkan oleh pengguna baru yang belum memiliki cukup riwayat interaksi; dan *Item Cold-Start*, di mana *item* baru belum memiliki penilaian atau ulasan dari pengguna lain [7]. Situasi ini berdampak pada turunnya kualitas rekomendasi yang dihasilkan, sehingga sistem tidak mampu memberikan rekomendasi yang bersifat personal, mengurangi kepuasan pengguna [8].

Beberapa penelitian terdahulu telah menunjukkan hasil yang menjanjikan dari metode *switching hybrid*. Misalnya, Khasanah et al. [9] menggabungkan SVM dan *item-based* CF dalam sebuah sistem *switching*. Meskipun model SVM mendominasi hasil prediksi, akurasi yang rendah menjadi perhatian karena keterbatasan fitur dan tingkat *sparsity* data yang tinggi. Penelitian lain oleh Rizki dan Rianto [10] menunjukkan bahwa pendekatan *switching* dengan menggabungkan TF-IDF, KNN, CBF, dan CF berhasil mencapai akurasi yang cukup tinggi, yaitu 83,62% untuk label kategori produk. Ini menunjukkan bahwa *switching* mampu secara adaptif memilih algoritma terbaik berdasarkan kondisi input.

Widayanti et al. [1] juga menyumbangkan pemahaman penting dengan menunjukkan bahwa penggabungan CF dan CBF tidak hanya meningkatkan akurasi tetapi juga memperkaya diversitas dan menangani masalah *cold-start*. Sementara itu, Naufal et al. [11] mengimplementasikan *switching hybrid* untuk sistem rekomendasi mata kuliah pilihan dengan pendekatan berbasis kesamaan dan histori akademik mahasiswa, yang dievaluasi menggunakan MAE serta *precision-recall*.

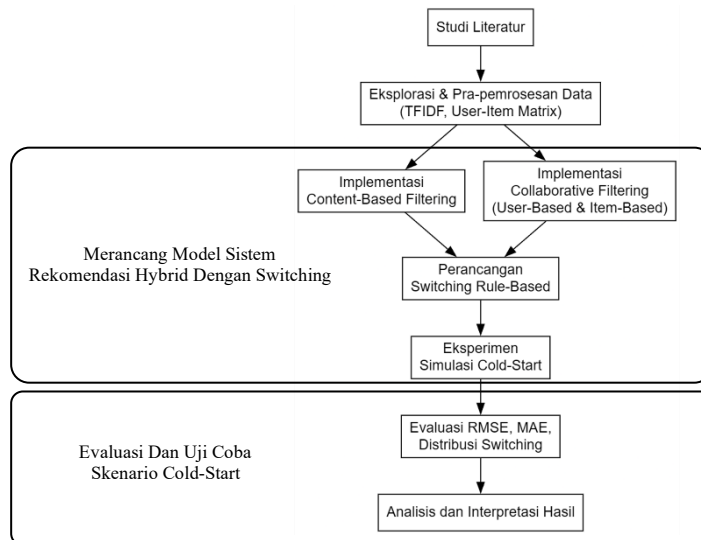
Meskipun berbagai penelitian sebelumnya telah menunjukkan potensi pendekatan *hybrid* dan *switching* dalam mengatasi permasalahan *cold-start*, sebagian besar studi masih memiliki keterbatasan tertentu. Beberapa penelitian berfokus pada domain atau dataset spesifik tanpa evaluasi menyeluruh pada skenario *user* dan *item cold-start* secara terpisah, sementara penelitian lain menerapkan mekanisme *switching* yang relatif kompleks dan sulit direplikasi. Selain itu, belum banyak studi yang secara sistematis merangkum dan membandingkan pendekatan *switching hybrid* berbasis aturan sederhana dengan menggunakan dataset *benchmark* yang umum digunakan.

Berdasarkan celah penelitian tersebut, penelitian ini memposisikan diri untuk mengkaji dan mengimplementasikan model *Hybrid Recommendation System* dengan strategi *switching rule-based* yang sederhana, transparan, dan mudah diimplementasikan. Penelitian ini bertujuan untuk mengevaluasi efektivitas pendekatan *switching* antara CBF dan CF dalam menangani kondisi *cold-start*, baik pada pengguna maupun *item*, menggunakan dataset *MovieLens* sebagai *benchmark*. Kontribusi utama dari penelitian ini adalah penyajian analisis sistematis serta evaluasi kinerja model *hybrid switching* yang adaptif, sehingga diharapkan dapat memberikan pemahaman yang lebih jelas mengenai peran strategi *switching* sederhana dalam meningkatkan kualitas rekomendasi pada kondisi keterbatasan data.

## II. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental. Pendekatan ini dipilih karena penelitian difokuskan pada pengembangan dan pengujian model *Hybrid Recommendation System* dengan strategi *switching rule-based* untuk menangani masalah *Cold-Start* pada sistem rekomendasi.

Metode penelitian pada Gambar 1 dilakukan melalui beberapa tahap utama, mulai dari pengumpulan data, pra-pemrosesan, implementasi CBF dan CF, perancangan logika *switching*, hingga evaluasi performa menggunakan simulasi *Cold-Start*. Dataset yang digunakan adalah *MovieLens*, yang banyak digunakan sebagai *benchmark* penelitian sistem rekomendasi.



Gambar 1. Alur Metodologi Penelitian

### A. Studi Literatur

Pada tahap awal, dilakukan studi literatur untuk memahami permasalahan *Cold-Start*, pendekatan CBF, CF, dan teknik penggabungan metode *hybrid*. Studi literatur dilakukan dengan menelaah berbagai referensi jurnal internasional, artikel ilmiah melalui proses *Systematic Literature Review* (SLR), dan dokumentasi terkait dataset *MovieLens*.

### B. Pengumpulan Dan Preprocessing Data

Data yang digunakan dalam penelitian ini bersumber dari dataset *MovieLens* 32M yang disediakan oleh *GroupLens Research*, yang mencakup sekitar 32 juta *rating* yang diberikan oleh 200.948 pengguna terhadap 87.585 judul film. Mengingat keterbatasan perangkat keras yang digunakan dalam proses pelatihan dan evaluasi model, dilakukan teknik *sampling* terhadap dataset tersebut sehingga menghasilkan *subset* data sebanyak 100.000 entri *rating* pada Gambar 2 dari 943 pengguna terhadap 1.682 film pada Gambar 3.

```

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 100000 entries, 0 to 99999
Data columns (total 5 columns):
#   Column      Non-Null Count  Dtype
---  -
0   userId      100000 non-null  int64
1   movieId     100000 non-null  int64
2   rating      100000 non-null  float64
3   timestamp   100000 non-null  int64
4   title       100000 non-null  object
dtypes: float64(1), int64(3), object(1)
memory usage: 3.8+ MB
None
    
```

Gambar 2. Dataset *Ratings*

Selain informasi *rating*, dataset juga menyediakan data deskriptif seperti judul dan *genre* film. Untuk melengkapi informasi konten, dilakukan proses *scraping* data melalui *Application Programming Interface* (API) dari The Movie Database (TMDb), yang menyediakan atribut tambahan seperti nama sutradara, aktor utama, dan sinopsis film (*overview*).

```
<class 'pandas.core.frame.DataFrame'>  
RangeIndex: 1682 entries, 0 to 1681  
Data columns (total 9 columns):  
#   Column                Non-Null Count  Dtype  
---  ---  
0   movieId                1682 non-null   int64  
1   title                  1682 non-null   object  
2   genres                 1682 non-null   object  
3   overview               1680 non-null   object  
4   director               1682 non-null   object  
5   main_cast              1680 non-null   object  
6   release_year          1680 non-null   float64  
7   vote_average           1680 non-null   float64  
8   popularity             1680 non-null   float64  
dtypes: float64(3), int64(1), object(5)  
memory usage: 118.4+ KB
```

Gambar 3. Dataset Movies

Pada Gambar 4, seluruh data ini kemudian dipersiapkan melalui tahap pra-pemrosesan yang meliputi pembersihan data (*data cleaning*), yaitu penghapusan entri kosong serta penyesuaian format penulisan ID pengguna dan identitas film untuk memastikan konsistensi dan kelengkapan data sebelum digunakan dalam proses pemodelan sistem rekomendasi berbasis konten dan kolaboratif.

```
# Menangani missing values:  
enriched['overview'] = enriched['overview'].fillna("")  
enriched['director'] = enriched['director'].fillna("Unknown")  
enriched['main_cast'] = enriched['main_cast'].fillna("")  
  
print("Cek sisa missing values setelah diisi:")  
print(enriched[['overview', 'director', 'main_cast']].isnull().sum())  
  
Cek sisa missing values setelah diisi:  
overview      0  
director      0  
main_cast     0  
dtype: int64
```

Gambar 4. Proses Pembersihan Data Kosong

### C. Term Frequency – Inverse Document Frequency (TF-IDF)

TF-IDF merupakan metode yang digunakan untuk menghitung bobot suatu kata dalam sebuah dokumen relatif terhadap kumpulan dokumen lainnya. Metode ini banyak digunakan dalam sistem rekomendasi berbasis konten CBF untuk merepresentasikan deskripsi *item*, seperti *genre* film, sinopsis, atau *metadata* lainnya dalam bentuk vektor fitur numerik [12]. Rumus TF-IDF terdapat pada Persamaan 1. Kombinasi dari TF dan IDF menghasilkan nilai TF-IDF:

$$TF - IDF(t, d) = TF(t, d) - IDF(t) \quad (1)$$

TF-IDF membantu dalam mengekstrak kata-kata yang paling relevan dari suatu dokumen, sehingga dapat digunakan untuk membandingkan kemiripan antara *item* atau antara preferensi pengguna dan deskripsi *item*.

### D. Cosine Similarity

*Cosine Similarity* adalah metode untuk mengukur tingkat kemiripan antara dua vektor dalam ruang berdimensi banyak berdasarkan sudut kosinus di antara keduanya [13]. Dalam sistem rekomendasi, *Cosine Similarity* sering digunakan untuk menghitung kesamaan antar *item* atau antar pengguna berdasarkan representasi vektornya, seperti yang dihasilkan oleh TF-IDF [14]. Rumus *Cosine Similarity* antara dua vektor A dan B adalah pada Persamaan 2:

$$Cosine\ Similarity(A, B) = \frac{A \cdot B}{||A|| ||B||} \quad (2)$$

### E. Implementasi Model Content-Based Filtering

CBF merupakan salah satu pendekatan dalam sistem rekomendasi yang berfokus pada karakteristik atau fitur dari *item* itu sendiri [15]. CBF bekerja dengan menganalisis kesamaan antara *item* berdasarkan atribut kontennya, seperti *genre*, deskripsi, aktor, sutradara, atau informasi lain yang melekat pada *item*. Pendekatan ini mengasumsikan bahwa jika seorang pengguna menyukai suatu *item*, maka juga akan menyukai *item* lain yang memiliki kemiripan dalam hal konten [16]. Berbeda dengan *Collaborative Filtering* yang bergantung pada interaksi pengguna, CBF tidak memerlukan data historis pengguna lain, sehingga lebih tahan terhadap masalah *cold-start item* [17]. Salah satu teknik umum yang digunakan dalam CBF adalah representasi teks melalui TF-IDF (*Term Frequency-Inverse Document Frequency*) dan pengukuran kemiripan dengan *cosine similarity*.

Implementasi model CBF dalam penelitian ini dilakukan dengan memanfaatkan sejumlah atribut deskriptif dari film, seperti sinopsis (*overview*), *genre*, sutradara, dan pemeran utama. Seluruh informasi ini terlebih dahulu diproses untuk menghilangkan nilai kosong, lalu digabungkan menjadi satu representasi teks yang disebut *combined features*. Representasi tersebut kemudian dikonversi ke bentuk numerik menggunakan metode TF-IDF, yang memungkinkan pengukuran tingkat kemiripan antar film berdasarkan karakteristik kontennya. Untuk mempermudah proses pencarian dan pemetaan rekomendasi, dibangun pula struktur indeks dua arah antara judul film dan posisinya dalam matriks TF-IDF. Proses pemberian rekomendasi dilakukan melalui fungsi *recommend\_cbf()*, yang menghitung nilai *cosine similarity* antara film referensi dengan seluruh film lainnya. Hasilnya adalah daftar film dengan tingkat kemiripan tertinggi, sehingga pengguna mendapatkan rekomendasi berdasarkan kesamaan konten dengan film yang disukai atau telah ditonton sebelumnya.

### F. Implementasi Model Collaborative Filtering

CF merupakan pendekatan populer dalam sistem rekomendasi yang berfokus pada pemanfaatan data interaksi historis antara pengguna dan *item*, seperti penilaian (*rating*), klik, atau pembelian [1]. Pendekatan ini tidak memerlukan informasi konten dari *item*, melainkan mendasarkan prediksi pada pola kesamaan dalam perilaku pengguna. CF terbagi menjadi dua tipe utama, yaitu *user-based* dan *item-based*. Pada *user-based* CF, sistem mencari pengguna lain yang memiliki pola interaksi atau preferensi serupa dengan pengguna target, lalu merekomendasikan *item* yang disukai oleh pengguna-pengguna serupa tersebut [18]. Sementara itu, *item-based* CF mengidentifikasi *item* lain yang mirip dengan *item* yang pernah diberi *rating* tinggi oleh pengguna target, berdasarkan kesamaan pola penilaian dari banyak pengguna [19]. Kedua pendekatan ini bertujuan untuk mengungkap hubungan implisit dalam data interaksi pengguna-*item* dan sangat berguna dalam memberikan rekomendasi meskipun deskripsi *item* tidak diketahui.

Model CF dalam penelitian ini diimplementasikan melalui dua pendekatan utama, yaitu *item-based* dan *user-based*, yang keduanya memanfaatkan pola historis interaksi antara pengguna dan film tanpa melibatkan informasi konten dari film tersebut. Langkah awal implementasi melibatkan pemetaan ulang ID pengguna dan judul film ke dalam indeks numerik, yang kemudian digunakan untuk membentuk matriks interaksi pengguna-*item* dalam format *sparse* menggunakan struktur *Compressed Sparse Row (CSR)*.

Pada pendekatan *item-based*, sistem menghitung tingkat kemiripan antar film berdasarkan pola penilaian (*rating*) yang diberikan oleh pengguna. Sebaliknya, pendekatan *user-based* mengukur kemiripan antar pengguna untuk menghasilkan rekomendasi yang dipersonalisasi berdasarkan preferensi dari pengguna-pengguna yang memiliki pola penilaian serupa. Kedua pendekatan ini menggunakan *cosine similarity* sebagai metode pengukuran kesamaan, yang memungkinkan sistem untuk mengidentifikasi relasi implisit dalam data interaksi. Dengan demikian, CF mampu mengungkap pola rekomendasi kolektif yang tidak bergantung pada atribut konten, dan tetap relevan meskipun informasi deskriptif film tidak tersedia.

### G. Perancangan Model Hybrid dengan Strategi Switching

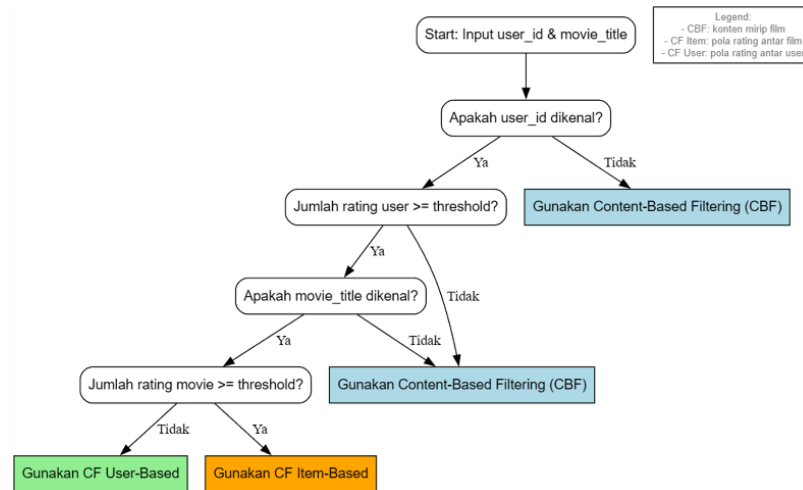
*Hybrid recommendation system* merupakan pendekatan yang menggabungkan dua atau lebih teknik rekomendasi untuk mengatasi keterbatasan dari masing-masing metode tunggal [20]. Dalam konteks penelitian ini, model *hybrid* dirancang untuk mengintegrasikan CBF dan CF guna meningkatkan akurasi, adaptivitas, dan ketahanan sistem terhadap berbagai kondisi data. Salah satu strategi utama yang digunakan adalah *switching hybrid*, yaitu mekanisme pemilihan otomatis metode yang paling sesuai berdasarkan konteks atau kondisi data tertentu [1]. Berbeda dari pendekatan kombinasi (*weighted* atau *feature augmentation*), *switching* tidak menggabungkan hasil dari beberapa metode, tetapi memilih satu metode yang paling relevan pada saat prediksi dilakukan.

Model *hybrid* dalam penelitian ini dirancang menggunakan strategi *switching*, yaitu pemilihan otomatis antara metode CBF dan CF berdasarkan tingkat ketersediaan dan kelengkapan data pengguna maupun *item*. Fungsi *recommend\_hybrid()* dikembangkan untuk menangani beragam skenario, seperti pengguna baru (*cold-start user*), pengguna dengan sedikit interaksi, atau *item* yang belum memperoleh cukup banyak *rating*. Dalam kondisi tersebut, sistem secara otomatis melakukan *fallback* ke pendekatan CBF. Jika *item* belum memiliki cukup data namun pengguna termasuk aktif, sistem akan memilih pendekatan CF *user-based*. Sebaliknya, apabila kedua entitas baik pengguna maupun *item* telah memiliki jumlah interaksi yang memadai, maka sistem akan menerapkan CF *item-based* sebagai metode utama. Pendekatan *switching* ini terbukti

efektif dalam menjaga relevansi hasil rekomendasi pada kondisi data yang bervariasi, serta mampu secara signifikan mengurangi dampak dari permasalahan *cold-start*.

Pada implementasinya Gambar 5, logika *switching* ditentukan menggunakan ambang batas (*threshold*) interaksi yang ditetapkan secara empiris, yaitu 5 *rating*. Jika seorang pengguna memiliki kurang dari 5 interaksi, maka akan diklasifikasikan sebagai *cold-start* dan direkomendasikan menggunakan pendekatan CBF. Sebaliknya, jika pengguna memiliki  $\geq 5$  interaksi namun *item* yang dituju memiliki  $< 5$  *rating*, maka sistem akan mengaktifkan *fallback* ke CF *user-based*. Dalam kondisi ideal ketika baik pengguna maupun *item* memiliki  $\geq 5$  interaksi—CF *item-based* akan digunakan sebagai metode *default*.

Penetapan nilai *threshold* ini didasarkan pada hasil uji coba awal, yang menunjukkan bahwa di bawah ambang tersebut, korelasi antar *item* maupun antar pengguna menjadi kurang stabil akibat tingginya *sparsity* pada data interaksi.



Gambar 5. Alur *Switching Hybrid*

Dibawah ini Gambar 6 adalah *pseudocode* dari sistem *switching hybrid* yang digunakan:

```

Input:
user_id, movie_title
rating_user : jumlah rating yang telah diberikan oleh user
rating_movie : jumlah rating yang diterima oleh movie
THRESHOLD_USER = 5
THRESHOLD_ITEM = 5

Procedure RekomendasiHybrid(user_id, movie_title):

if user_id tidak ditemukan:
return Gunakan_ContentBasedFiltering(user_id, movie_title)

if rating_user < THRESHOLD_USER:
return Gunakan_ContentBasedFiltering(user_id, movie_title)

if movie_title tidak ditemukan:
return Gunakan_ContentBasedFiltering(user_id, movie_title)

if rating_movie < THRESHOLD_ITEM:
if rating_user >= THRESHOLD_USER:
return Gunakan_CF_UserBased(user_id, movie_title)
else:
return Gunakan_ContentBasedFiltering(user_id, movie_title)

else:
return Gunakan_CF_ItemBased(user_id, movie_title)
    
```

Gambar 6. Pseudocode *Switching Hybrid*

Untuk memastikan bahwa pemilihan nilai *threshold* memiliki dasar yang jelas, dilakukan eksperimen pembandingan dengan beberapa nilai ambang interaksi, yaitu 5, 10, dan 20 interaksi. Evaluasi dilakukan menggunakan metrik RMSE dan MAE untuk menilai kestabilan performa model pada masing-masing *threshold*. Berdasarkan hasil evaluasi tersebut, *threshold* lima interaksi digunakan pada eksperimen utama sebagai dasar mekanisme *switching*.

TABEL 1.  
PERBANDINGAN PERFORMA MODEL PADA BERBAGAI NILAI THRESHOLD

Threshold	RMSE	MAE
5	0.8168	0.6607
10	0.8168	0.6606
20	0.8342	0.6709

Hasil eksperimen perbandingan menunjukkan bahwa *threshold* 5 dan 10 interaksi menghasilkan nilai RMSE yang sama, serta nilai MAE yang relatif serupa. Sebaliknya, pada *threshold* dua puluh interaksi terjadi penurunan performa yang ditunjukkan oleh meningkatnya nilai RMSE dan MAE.

Berdasarkan hasil eksperimen perbandingan, *threshold* lima interaksi dipilih sebagai ambang batas pada mekanisme *switching*. Meskipun *threshold* sepuluh menunjukkan performa yang sebanding, *threshold* lima memberikan keuntungan dalam hal cakupan pengguna dan *item* yang lebih luas tanpa mengurangi kestabilan performa prediksi. Penggunaan *threshold* yang lebih tinggi cenderung mengurangi fleksibilitas sistem dan berdampak pada penurunan performa. Oleh karena itu, *threshold* lima interaksi dipilih sebagai nilai yang paling seimbang.

#### H. Eksperimen dan Evaluasi

Eksperimen dan evaluasi dalam penelitian ini dirancang untuk mengukur kinerja tiga pendekatan utama dalam sistem rekomendasi, yaitu CBF, CF, dan model *hybrid* dengan strategi *switching*, dalam menghasilkan rekomendasi yang relevan serta mengatasi tantangan *cold-start*. Evaluasi dilakukan menggunakan metrik regresi berupa *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE) untuk menilai tingkat akurasi prediksi *rating*. Untuk memastikan validitas dan stabilitas hasil, proses evaluasi menggunakan pendekatan *5-Fold Cross-Validation*, di mana data dibagi menjadi lima *subset* yang digunakan secara bergantian sebagai data pelatihan dan pengujian. Dengan pendekatan ini, setiap model diuji sebanyak lima kali pada *subset* data yang berbeda, sehingga diperoleh rata-rata dan standar deviasi dari performa model secara menyeluruh.

Model CBF dievaluasi berdasarkan tingkat kesamaan konten antar *item*, sementara model CF dinilai dari kemiripan antar *item* (*item-based*) maupun antar pengguna (*user-based*). Sementara itu, model *hybrid* diuji secara menyeluruh untuk mengevaluasi performanya dalam berbagai skenario, termasuk kondisi dengan keterbatasan data. Hasil evaluasi menunjukkan bahwa model *hybrid* mampu menjaga keseimbangan antara akurasi dan relevansi, serta menunjukkan kestabilan yang lebih tinggi dibandingkan pendekatan tunggal. Untuk memperoleh pemahaman yang lebih menyeluruh, pengujian dan evaluasi dibagi ke dalam tiga tahap utama:

##### 1) Pengujian Cold Start Terhadap Satu User

Terdapat lima skenario yang akan dilakukan terhadap model *hybrid* yang sudah dibangun, skenario tersebut terdapat pada Tabel 2:

TABEL 2.  
SKENARIO COLD-START YANG AKAN DI UJI

Simulasi	Situasi Dunia Nyata	Algoritma yang Diharapkan	Tujuan Pengujian
a. Cold-Start user (baru)	User baru, belum pernah <i>rating</i>	CBF	Uji <i>fallback</i> saat user tidak dikenali
b. Cold-Start user (<5 rating)	User pasif, interaksi masih sangat sedikit	CBF	Validasi ambang minimal interaksi sebelum CF aktif
c. Cold-Start item (baru)	Item baru, belum pernah <i>dirating</i>	CBF	Uji ketergantungan konten <i>item</i> dalam CBF saat CF tidak bisa digunakan
d. Cold-Start item (rating sedikit)	Item hanya punya 1-4 <i>rating</i> , terlalu minim untuk korelasi	CF <i>user-based</i> / CBF	Tes fleksibilitas <i>switching</i> dalam kondisi ambigu (cukup/tidak cukup data)
e. Non-cold (cukup data)	User aktif dan <i>item</i> populer → data lengkap	CF <i>item-based</i>	Konfirmasi optimalitas sistem dalam kondisi ideal

##### 2) Evaluasi RMSE dan MAE

Penelitian ini menggunakan pendekatan *k-fold cross-validation* sebanyak lima lipatan (*5-fold*) untuk mengevaluasi performa model secara menyeluruh. Metode ini membagi data *rating* ke dalam lima *subset* yang seimbang, di mana pada setiap iterasi, satu *subset* digunakan sebagai data uji sementara empat lainnya digunakan untuk pelatihan. Dengan demikian,

seluruh data memperoleh kesempatan yang sama untuk berperan sebagai data uji, sehingga hasil evaluasi menjadi lebih representatif dan tidak bergantung pada satu skenario pemisahan data tertentu.

Pada setiap iterasi *fold*, dilakukan pembentukan ulang struktur pemetaan ID pengguna dan judul film ke indeks numerik. Matriks interaksi kemudian disusun dalam format *sparse matrix* menggunakan pendekatan CSR. Untuk model CBF, dilakukan ekstraksi fitur konten film melalui teknik TF-IDF *vectorization* terhadap gabungan atribut seperti sinopsis, *genre*, sutradara, dan pemeran utama. Sementara itu, model CF baik *item-based* maupun *user-based* menghitung tingkat kemiripan berdasarkan pola interaksi pengguna terhadap *item*.

Setiap model menghasilkan prediksi *rating* terhadap data uji, yang selanjutnya dibandingkan dengan nilai aktual untuk menghitung nilai RMSE dan MAE sebagai indikator akurasi. Evaluasi ini mencakup empat pendekatan utama: CF *item-based*, CF *user-based*, CBF, dan model *hybrid switching*. Hasil dari setiap *fold* dikumpulkan untuk dihitung rata-rata dan standar deviasi, guna memperoleh gambaran umum mengenai akurasi dan stabilitas performa masing-masing model. Pendekatan ini memberikan penilaian yang lebih komprehensif dan objektif, serta memungkinkan analisis terhadap kestabilan dan efektivitas model rekomendasi yang diusulkan.

### 3) Evaluasi Adaptivitas Model Terhadap Data *Cold-Start*

Untuk mengevaluasi kemampuan adaptif model *hybrid* dalam merespons kondisi data yang terbatas, dilakukan analisis terhadap distribusi strategi *fallback* yang diaktifkan secara otomatis berdasarkan jumlah interaksi pengguna dan *item*.

Logika *switching* pada model *hybrid* mengelompokkan kondisi data ke dalam tiga kategori utama:

- Fallback* ke CBF ketika pengguna atau *item* mengalami *cold-start*,
- CF *User-Based* ketika *item* belum memiliki cukup data, namun pengguna tergolong aktif, dan
- CF *Item-Based* sebagai pendekatan utama ketika kedua entitas memiliki jumlah interaksi yang mencukupi.

Analisis dilakukan dengan menelusuri seluruh prediksi yang dihasilkan pada data uji untuk mengidentifikasi metode apa yang dipilih oleh sistem dalam tiap kasus. Hasil distribusi pemilihan metode ini kemudian divisualisasikan dalam bentuk *pie chart*, untuk memberikan gambaran yang lebih jelas mengenai sejauh mana sistem dapat menyesuaikan pendekatannya terhadap kondisi data yang bervariasi.

## I. Analisis dan Interpretasi Hasil

Tahapan analisis dan interpretasi hasil merupakan langkah akhir dalam metodologi penelitian ini, yang bertujuan untuk menafsirkan makna dari seluruh proses eksperimen dan evaluasi yang telah dilakukan. Setelah seluruh metrik evaluasi dikumpulkan, baik dalam bentuk RMSE, MAE, maupun distribusi *switching* antar metode rekomendasi, dilakukan analisis menyeluruh terhadap performa masing-masing pendekatan.

Analisis dilakukan dengan membandingkan performa model dalam kondisi *cold-start* ringan hingga berat, mengamati stabilitas hasil melalui nilai deviasi standar antar *fold*, serta meninjau pola *switching* adaptif yang terjadi pada model *hybrid*. Selain itu, dilakukan interpretasi terhadap kecenderungan sistem dalam memilih pendekatan tertentu (CBF, CF *User-Based*, atau CF *Item-Based*) berdasarkan kelengkapan data pengguna dan *item*.

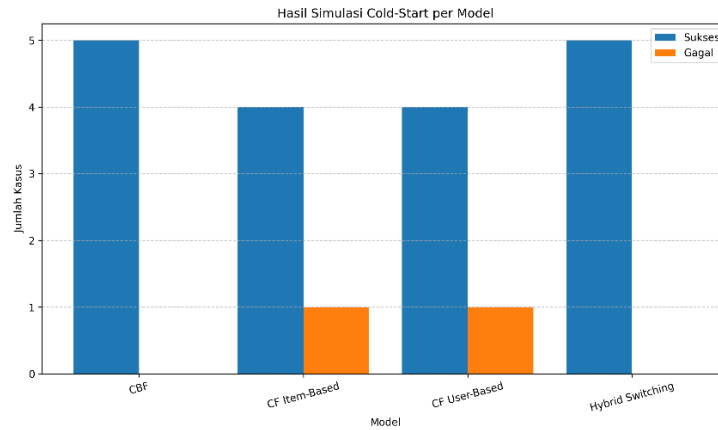
Interpretasi hasil dilakukan untuk menjawab pertanyaan penelitian utama, khususnya terkait efektivitas dan adaptivitas sistem *hybrid switching* dalam menghadapi tantangan *cold-start*. Dengan pendekatan ini, diperoleh kesimpulan menyeluruh yang menjelaskan kekuatan model *hybrid* dalam menjaga akurasi serta fleksibilitasnya dalam kondisi data yang dinamis.

## III. HASIL DAN PEMBAHASAN

Berdasarkan eksperimen yang sudah dilakukan berikut adalah hasil dan pembahasan setelah dilakukannya eksperimen.

### A. Pengujian *Cold-Start* Terhadap Satu User

Hasil pengujian ditampilkan pada Gambar 7, di mana keempat model CBF, CF *item-based*, CF *user-based*, dan *Hybrid Switching* diberi lima skenario uji yang sama. Dalam evaluasi ini, model dinyatakan berhasil jika mampu menghasilkan rekomendasi yang valid, dan gagal jika tidak dapat memberikan prediksi. Pendekatan ini bertujuan untuk mengamati ketangguhan masing-masing model terhadap keterbatasan data, serta menilai sejauh mana model *hybrid* dapat menyesuaikan strategi rekomendasinya secara adaptif.



Gambar 7. Visualisasi Pengujian *Cold-Start* Terhadap *User*

Hasilnya menunjukkan bahwa model CBF dan *Hybrid Switching* berhasil memberikan rekomendasi pada seluruh skenario (5 dari 5 kasus). Hal ini menandakan keandalan keduanya dalam menangani *Cold-Start*, khususnya karena CBF tidak memerlukan histori interaksi pengguna. Model *CF item-based* dan *CF user-based* masing-masing mengalami satu kegagalan ketika diuji pada *item* atau *user* yang tidak dikenali dalam data pelatihan. Ini memperkuat bahwa model CF memiliki keterbatasan ketika menghadapi entitas yang belum pernah muncul sebelumnya dalam data *rating*.

Secara keseluruhan, pengujian ini menunjukkan bahwa strategi *hybrid switching* yang diterapkan mampu melakukan *fallback* secara adaptif ke model yang sesuai, tergantung pada kondisi data, dan menjadi solusi paling andal dalam menghadapi masalah *Cold-Start*.

#### B. Evaluasi RMSE, MAE

Evaluasi performa dilakukan menggunakan *5-Fold Cross-Validation* untuk memastikan stabilitas dan generalisasi model pada distribusi data yang berbeda. Empat pendekatan yang diuji meliputi: *CF Item-Based*, *CF User-Based*, CBF, dan model *Hybrid Switching* yang diusulkan. Hasil evaluasi per *fold* disajikan pada Tabel 3, sementara ringkasan rata-rata dan standar deviasi dari masing-masing metrik evaluasi disajikan pada Tabel 4.

TABEL 3.  
HASIL EVALUASI RMSE DAN MAE 5-FOLD

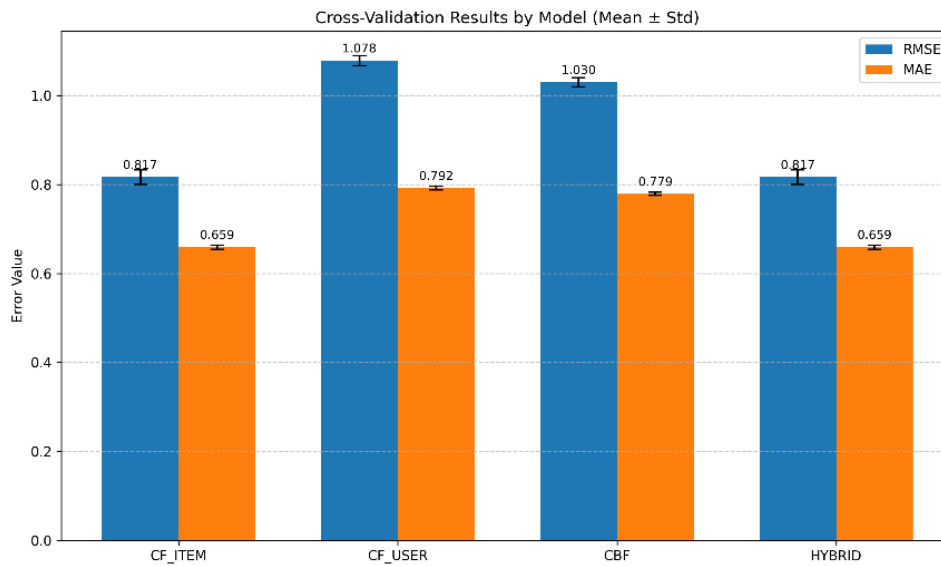
Fold	CF_ITEM (RMSE/MAE)	CF_USER (RMSE/MAE)	CBF (RMSE/MAE)	HYBRID (RMSE/MAE)
1	0,8168 / 0,6607	1,0853 / 0,7947	1,0425 / 0,7834	0,8168 / 0,6607
2	0,8167 / 0,6608	1,0841 / 0,7956	1,0251 / 0,7774	0,8167 / 0,6608
3	0,8090 / 0,6559	1,0851 / 0,7890	1,0347 / 0,7799	0,8090 / 0,6559
4	0,8452 / 0,6659	1,0821 / 0,7936	1,0353 / 0,7817	0,8452 / 0,6659
5	0,7950 / 0,6526	1,0556 / 0,7854	1,0124 / 0,7725	0,7950 / 0,6526

TABEL 4.  
RINGKASAN EVALUASI

Model	RMSE ( $\mu \pm \sigma$ )	MAE ( $\mu \pm \sigma$ )
CF_ITEM	0,8165 $\pm$ 0,0164	0,6592 $\pm$ 0,0046
CF_USER	1,0784 $\pm$ 0,0115	0,7917 $\pm$ 0,0039
CBF	1,0300 $\pm$ 0,0104	0,7790 $\pm$ 0,0038
HYBRID	0,8165 $\pm$ 0,0164	0,6592 $\pm$ 0,0046

Berdasarkan hasil evaluasi, model *Hybrid* dan *CF Item-Based* menunjukkan performa terbaik dan identik, dengan nilai RMSE rata-rata sebesar 0,8165 dan MAE sebesar 0,6592, serta standar deviasi yang rendah (RMSE  $\pm$  0,0164; MAE  $\pm$  0,0046). Hal ini mengindikasikan bahwa model *hybrid* secara efektif memilih pendekatan *CF Item-Based* pada sebagian besar kasus, khususnya ketika data historis pengguna dan *item* mencukupi, namun tetap mampu menangani *cold-start* dengan *fallback* ke

metode lain bila diperlukan. Visualisasi perbandingan performa rata-rata setiap model berdasarkan RMSE dan MAE dapat dilihat pada Gambar 8.



Gambar 8. Perbandingan Performa Rata-Rata


Sementara itu, pendekatan CF *User-Based* dan CBF menunjukkan performa yang secara konsisten lebih rendah. CF *User-Based* memiliki RMSE tertinggi yaitu  $1,0784 \pm 0,0115$  dan MAE  $0,7917 \pm 0,0039$ , yang mengindikasikan bahwa model ini kurang efektif pada kondisi data yang *sparsity* tinggi. Demikian pula, model CBF mencatatkan RMSE  $1,0300 \pm 0,0104$  dan MAE  $0,7790 \pm 0,0038$ , mengonfirmasi bahwa dependensi pada fitur konten saja kurang memadai untuk memberikan prediksi akurat secara umum.

Pada kondisi data historis yang relatif lengkap, performa model *hybrid* dengan strategi *switching* menunjukkan hasil yang identik dengan pendekatan CF *item-based*. Hal ini dapat dijelaskan karena mekanisme *switching* cenderung memilih algoritma CF ketika jumlah interaksi pengguna telah mencukupi. Pada kondisi tersebut, kontribusi komponen *content-based* menjadi minimal, sehingga perilaku model *hybrid* secara efektif menyerupai CF murni. Temuan ini menunjukkan bahwa keunggulan utama pendekatan *hybrid* bukan terletak pada peningkatan performa pada kondisi data lengkap, melainkan pada kemampuannya beradaptasi terhadap keterbatasan data.

Selain itu, nilai standar deviasi yang rendah ( $< 0,02$  untuk RMSE dan  $< 0,005$  untuk MAE) di semua model menunjukkan bahwa proses *cross-validation* berjalan stabil dan tidak terdapat perbedaan performa yang signifikan antar *fold*. Dengan demikian, hasil ini memperkuat validitas bahwa *Hybrid Switching* tidak hanya memberikan akurasi tinggi, tetapi juga *robust* terhadap variasi data, menjadikannya pendekatan yang layak untuk diadopsi dalam skenario rekomendasi yang menghadapi masalah *cold-start*.


### C. Evaluasi Adaptivitas Model Terhadap Data Cold-Start

Pada skenario *Cold-Start* sebesar 5%, seperti ditunjukkan pada Gambar 9, sistem rekomendasi sepenuhnya mengandalkan metode CF *item-based*. Hal ini mengindikasikan bahwa sebagian besar pengguna dan *item* dalam dataset telah memiliki jumlah interaksi yang mencukupi, sehingga sistem tidak perlu melakukan *fallback* ke metode lain seperti CBF atau CF *user-based*. Visualisasi berupa diagram *pie* menunjukkan bahwa 100% rekomendasi berhasil dihasilkan melalui pendekatan CF *item-based*, menandakan kondisi data yang relatif matang dalam skenario ini.




Gambar 9. Visualisasi Distribusi Switching Kondisi Cold-Start 5%

Ketika proporsi *Cold-Start* meningkat menjadi 20%, seperti terlihat pada Gambar 10, sistem mulai menunjukkan perilaku adaptif. Sebagian besar kasus (88,6%) masih dapat ditangani oleh metode *CF item-based*, namun sejumlah kecil mulai dialihkan secara otomatis ke *CF user-based* (6,0%) dan *CBF* (5,4%) sebagai *fallback*. Temuan ini mengindikasikan bahwa ketika informasi mengenai *item* mulai terbatas, sistem mampu beralih ke pendekatan alternatif guna mempertahankan kualitas rekomendasi.



Gambar 10. Visualiasi Distribusi Switching Cold-Start 20%

Pada skenario *Cold-Start* ekstrem sebesar 50%, sebagaimana ditampilkan pada Gambar 11, model *hybrid* memperlihatkan performa *switching* yang optimal. Distribusi penggunaan metode mulai terbagi lebih seimbang, dengan *CF item-based* digunakan pada 46,7% kasus, diikuti oleh *CF user-based* sebesar 30,6%, dan *CBF* sebagai *fallback* sebanyak 22,7%. Hasil ini menunjukkan bahwa strategi *switching* yang bersifat adaptif mampu bekerja secara efektif, di mana sistem secara dinamis memilih pendekatan yang paling sesuai berdasarkan tingkat kelengkapan data pengguna maupun *item*.



Gambar 11. Visualisasi Distribusi Switching Kondisi Cold-Start 50%

Pada kondisi *cold-start* ekstrem, mekanisme *switching* memungkinkan sistem untuk melakukan *fallback* ke pendekatan *content-based* ketika data interaksi tidak mencukupi. Secara praktis, mekanisme ini mencegah sistem menghasilkan rekomendasi yang tidak stabil atau tidak relevan akibat *sparsity* data. Dengan demikian, meskipun pendekatan *content-based* secara umum memiliki keterbatasan dalam personalisasi, pengguna baru tetap dapat memperoleh rekomendasi awal yang masuk akal hingga data interaksi yang lebih kaya tersedia. Hal ini menunjukkan bahwa strategi *switching* berperan penting dalam menjaga keberlangsungan layanan rekomendasi pada tahap awal penggunaan.

Meskipun hasil penelitian menunjukkan performa yang stabil, terdapat beberapa keterbatasan yang perlu diperhatikan. Eksperimen dilakukan menggunakan satu dataset *benchmark*, yaitu *MovieLens*, sehingga generalisasi hasil ke *domain* atau jenis data lain masih memerlukan kajian lebih lanjut. Selain itu, konfigurasi parameter yang digunakan pada model bersifat tetap dan belum mengeksplorasi pengaruh variasi parameter terhadap performa sistem. Penelitian selanjutnya dapat mempertimbangkan penggunaan *dataset* yang beragam serta eksplorasi parameter yang lebih luas untuk memperoleh pemahaman yang lebih komprehensif.

#### IV. SIMPULAN

Penelitian ini menunjukkan bahwa pendekatan *Hybrid Recommendation System* dengan strategi *switching rule-based* mampu memberikan performa yang stabil dan adaptif pada berbagai kondisi kelengkapan data. Model yang dikembangkan dapat secara otomatis menyesuaikan pendekatan rekomendasi yang digunakan, dengan memanfaatkan *collaborative filtering* ketika data interaksi mencukupi, serta beralih ke pendekatan berbasis konten atau *user-based* pada kondisi *cold-start*. Temuan ini menegaskan bahwa keunggulan utama pendekatan *hybrid* terletak pada kemampuannya menjaga keberlangsungan rekomendasi secara konsisten, bukan semata-mata pada peningkatan akurasi numerik.

Kontribusi utama dari penelitian ini adalah penyajian kerangka evaluasi adaptivitas *hybrid switching* yang sistematis, yang memungkinkan analisis perilaku model pada berbagai tingkat keterbatasan data. Kerangka ini memberikan pemahaman yang lebih komprehensif mengenai peran mekanisme *switching* dalam menghadapi permasalahan *cold-start* pada sistem rekomendasi. Sebagai arah penelitian lanjutan, eksplorasi penggunaan dataset dari domain yang berbeda, pengujian pada konfigurasi parameter yang lebih beragam, serta pengembangan mekanisme *threshold* yang bersifat adaptif dinilai berpotensi untuk semakin meningkatkan fleksibilitas dan generalisasi model.

#### DAFTAR PUSTAKA

- [1] R. Widayanti, M. H. R. Chakim, C. Lukita, U. Rahardja, and N. Lutfiani, "Improving Recommender Systems using Hybrid Techniques of Collaborative Filtering and Content-Based Filtering," *Journal of Applied Data Sciences*, vol. 4, no. 3, pp. 289–302, 2023.
- [2] N. T. Al Ghifari, B. Sitohang, and G. A. P. Saptawati, "Addressing Cold Start New User in Recommender System Based on Hybrid Approach: A Review and Bibliometric Analysis," *IT Journal Research and Development*, vol. 6, no. 1, pp. 1–16, 2021.
- [3] C. Ma, Y. Sun, Z. Yang, H. Huang, D. Zhan, and J. Qu, "Content Feature Extraction-Based Hybrid Recommendation for Mobile Application Services," *Computers, Materials and Continua*, vol. 71, no. 3, pp. 6201–6217, 2022.
- [4] R. Yu *et al.*, "Personalized Adaptive Meta Learning for Cold-Start User Preference Prediction," in *Proceedings of the AAAI Conference on Artificial Intelligence*, 35, Association for the Advancement of Artificial Intelligence, 2021, pp. 10772–10780.
- [5] J. Luo, Q. Qin, B. Han, and H. Yang, "Reinforcement Learning to Optimize Lifetime Value in Cold-Start Recommendation," in *Proceedings of the 30th ACM International Conference on Information & Knowledge Management*, Association for Computing Machinery, 2021, pp. 782–791.
- [6] B. Hao, J. Zhang, H. Yin, C. Li, and H. Chen, "Pre-Training Graph Neural Networks for Cold-Start Users and Items Representation," in *Proceedings of the 14th ACM International Conference on Web Search and Data Mining*, Association for Computing Machinery, 2021, pp. 265–273.
- [7] A. Y. Mir, M. Zaman, S. M. K. Quadri, and S. A. Fayaz, "An Adaptive Classification Framework for Handling the Cold Start Problem in Case of News Items," *Revue D Intelligence Artificielle*, 2022.
- [8] S. Kuznetsov and P. Kordik, "Improving Recommendation Diversity and Serendipity With an Ontology-Based Algorithm for Cold Start Environments," *Int. J. Data Sci. Anal.*, vol. 20, pp. 431–443, 2025.
- [9] I. N. Khasanah, A. Romadhony, and E. G. Perdana, "Analisis dan Implementasi Switching Hybrid Recommender System Menggunakan Support Vector Machines Classifier dan Collaborative Filtering Switching," Universitas Telkom, Bandung, 2012. Accessed: Jan. 04, 2026. [Online]. Available: <https://repository.telkomuniversity.ac.id/home/catalog/id/95442/slug/analisis-dan-implementasi-switching-hybrid-recommender-system-menggunakan-support-vector-machines-classifier-dan-collaborative-filtering-switching-hybrid-recommender-system-analysis-and-implementation-with-support-vector-machines-classifier-and-collaborat.html>
- [10] M. Rizki and R. Rianto, "Sistem Rekomendasi Hybrid Menggunakan Metode Switching," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 10, no. 2, pp. 149–160, 2024.
- [11] H. H. Naufal, A. Romadhony, and E. Rachmawati, "Perancangan dan Implementasi Sistem Rekomendasi Pengambilan Mata Kuliah Pilihan Menggunakan Metode Hybrid," Universitas Telkom, 2013. Accessed: Feb. 04, 2026. [Online]. Available: <https://openlibrary.telkomuniversity.ac.id/pustaka/96088/perancangan-dan-implementasi-sistem-rekomendasi-pengambilan-mata-kuliah-pilihan-menggunakan-metode-hybrid.html>
- [12] D. S. A. Tambunan and D. A. Dermawan, "Implementasi Content Based Filtering dalam Sistem Rekomendasi Jurnal Scopus Berbasis Web Untuk Menunjang Pelaksanaan Penelitian dan Tugas Mahasiswa Program Studi Bisnis Digital," *Jurnal Manajemen Informatika*, vol. 12, 2023.
- [13] S. Jawale, S. Nehete, H. Patil, S. Pathak, P. Sapale, and S. Zite, "Cosine Similarity: A Key Driver for Enhanced Recommendation Systems," *International Research Journal of Modernization in Engineering Technology and Science*, vol. 6, no. 4, pp. 1466–1470, 2024.
- [14] A. F. Hidayat, "Evaluasi Keandalan Cosine Similarity dalam Mendeteksi Plagiarisme Kode Program," 2024. Accessed: Jan. 02, 2026. [Online]. Available: [https://informatika.stei.itb.ac.id/~rinaldi.munir/AljabarGeometri/2024-2025/Makalah/Makalah-IF2123-Algeo-2024%20\(56\).pdf](https://informatika.stei.itb.ac.id/~rinaldi.munir/AljabarGeometri/2024-2025/Makalah/Makalah-IF2123-Algeo-2024%20(56).pdf)

- [15] H. H. Arfisko and A. T. Wibowo, "Sistem Rekomendasi Film Menggunakan Metode Hybrid Collaborative Filtering Dan Content-Based Filtering," *eProceedings of Engineering*, vol. 9, 2022.
- [16] P. Aggarwal, V. Tomar, and A. Kathuria, "Comparing Content Based and Collaborative Filtering in Recommender Systems," *International Journal of New Technology and Research*, vol. 3, no. 4, 2017.
- [17] A. Felfernig, M. Wundara, T. N. T. Tran, V.-M. Le, S. Lubos, and S. Polat-Erdeniz, "Sports recommender systems: overview and research directions," *J. Intell. Inf. Syst.*, vol. 62, no. 4, pp. 1125–1164, 2024.
- [18] R. R. Mahendra, F. T. Anggraeny, and H. E. Wahanani, "Implementasi Item-Based Collaborative Filtering Untuk Rekomendasi Film," *Repeater: Publikasi Teknik Informatika dan Jaringan*, vol. 2, no. 3, pp. 213–221, 2024.
- [19] M. Hasan and F. Roy, "An Item–Item Collaborative Filtering Recommender System Using Trust and Genre to Address the Cold-Start Problem," *Big Data and Cognitive Computing*, vol. 3, no. 3, p. 39, 2019.
- [20] Y. Muflifah and M. W. Wardhani, "Implementasi Hybrid Filtering dalam Sistem Rekomendasi Berbasis Web untuk Persewaan Tenda Pe sta," *Jurnal Rekayasa Sistem Informasi dan Teknologi*, vol. 1, no. 4, pp. 361–372, 2024.