



Sistem Rekomendasi Novel Menggunakan Pendekatan *Hybrid* Berbasis *Best Matching 25 (BM25)* dan *Matrix Factorization*

Sattyo Ardicta Pradana¹, Ilham Saifudin^{2*}, Lutfi Ali Muharom³

^{1,2,3} Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Jember
sattyo789@gmail.com, ilham.saifudin@unmuhjember.ac.id, lutfi.muharom@unmuhjember.ac.id

Abstract

In the digital era, the number of novels available on digital platforms has grown rapidly, making it difficult for readers to choose titles that match their interests. Previous studies on reading recommender systems have generally focused on books in general and relied on a single approach, either content-based filtering or collaborative filtering, each of which has limitations in handling long narrative texts or the cold-start problem. This study proposes a hybrid recommender system for novels that combines *Best Matching 25 (BM25)* to measure content relevance based on the title, genre, and synopsis, and *Matrix Factorization* to model user preferences from rating data. The two scores are combined using a weighted hybrid scheme with $\alpha = 0.6$, after the *BM25* score is min-max normalized to be comparable to the 1-5 rating scale produced by *Matrix Factorization*. The dataset consists of Goodreads books for novel content and Goodbooks-10k for user ratings, filtered to include only novel items, resulting in 8,480 novels, 16,220 users, and 640,396 ratings after preprocessing. System performance was evaluated using *NDCG@10* and *Precision@10* on a Top-10 recommendation list. The evaluation results show that the hybrid approach achieved an *NDCG@10* of 0.943 and a *Precision@10* of 0.488, with an average runtime of 136.46 seconds for 15,813 users. Further testing on α , data split, and Top-N variations confirmed that *Matrix Factorization* contributes more dominantly to ranking quality, while *BM25* remains important for maintaining content-based relevance. These findings indicate that the hybrid *BM25* and *Matrix Factorization* approach can produce novel, relevant, and computationally efficient recommendations.

Keywords: Novel Recommendation, Hybrid Recommender System, *BM25*, *Matrix Factorization*, *NDCG*

Abstrak

Pada era digital, jumlah novel yang tersedia di berbagai platform digital berkembang sangat pesat sehingga menyulitkan pembaca dalam memilih judul yang sesuai dengan minat dan preferensinya. Penelitian terdahulu mengenai sistem rekomendasi bacaan umumnya masih berfokus pada buku secara umum dan menggunakan pendekatan tunggal, baik *content-based filtering* maupun *collaborative filtering*, yang masing-masing memiliki keterbatasan dalam menangani teks naratif panjang atau permasalahan *cold-start*. Penelitian ini mengusulkan sistem rekomendasi novel berbasis *hybrid* yang mengombinasikan metode *Best Matching 25 (BM25)* untuk mengukur relevansi konten berdasarkan judul, genre, dan sinopsis, serta *Matrix Factorization* untuk memodelkan preferensi pengguna berdasarkan data rating. Kedua skor digabungkan menggunakan skema *hybrid* berbobot dengan nilai $\alpha = 0.6$, setelah skor *BM25* dinormalisasi menggunakan normalisasi min-max agar sebanding dengan skala rating 1-5 yang dihasilkan oleh *Matrix Factorization*. Dataset yang digunakan terdiri dari Goodreads-books untuk konten novel dan Goodbooks-10k untuk data rating pengguna, yang disaring sehingga hanya memuat item novel, menghasilkan 8.480 novel, 16.220 pengguna, dan 640.396 rating setelah *pre-processing*. Kinerja sistem dievaluasi menggunakan *NDCG@10* dan *Precision@10* pada daftar rekomendasi Top-10. Hasil evaluasi menunjukkan bahwa pendekatan *hybrid* memperoleh nilai *NDCG@10* sebesar 0,943 dan *Precision@10* sebesar 0,488, dengan rata-rata runtime 136,46 detik untuk 15.813 pengguna. Pengujian lanjutan terhadap variasi α , data split, dan Top-N menunjukkan bahwa *Matrix Factorization* memberikan kontribusi yang lebih dominan terhadap kualitas pemeringkatan, sedangkan *BM25* tetap penting untuk menjaga relevansi berbasis konten. Temuan ini menunjukkan bahwa pendekatan *hybrid BM25* dan *Matrix Factorization* dapat menghasilkan rekomendasi novel yang relevan dan efisien secara komputasi.

Kata Kunci: Rekomendasi Novel, Sistem Rekomendasi *Hybrid*, *BM25*, *Matrix Factorization*, *NDCG*

1. Pendahuluan

Pada era digital saat ini, perkembangan teknologi informasi memberikan dampak signifikan terhadap literasi dan penyediaan konten bacaan digital. Kemudahan akses terhadap novel melalui berbagai platform daring membuat pilihan bacaan semakin beragam. Novel tidak hanya berfungsi sebagai hiburan, tetapi juga sebagai media pembelajaran dan pengembangan imajinasi. Namun, melimpahnya pilihan novel justru menyulitkan pembaca dalam menentukan bacaan yang sesuai dengan minat dan preferensinya.

Pada platform digital, tersedia ribuan hingga jutaan judul novel dengan variasi genre, penulis, alur cerita, dan gaya bahasa. Kondisi tersebut membuat proses pemilihan bacaan secara manual menjadi kurang efisien dan berpotensi

menghasilkan pilihan yang tidak sesuai dengan kebutuhan pengguna. Oleh karena itu, diperlukan sistem yang mampu membantu pembaca memperoleh rekomendasi novel yang lebih terarah dan relevan (Kheng et al., 2025). Penelitian terdahulu mengenai sistem rekomendasi bacaan umumnya masih berfokus pada buku secara umum dan menggunakan pendekatan tunggal, seperti *content-based filtering* dengan metode *TF-IDF* atau teknik kesamaan konten lainnya (Ardiansyah et al., 2023; Ridhwanullah et al., 2024). Pendekatan berbasis konten tersebut dinilai kurang optimal dalam menangani teks naratif panjang seperti sinopsis novel, sementara pendekatan berbasis kolaboratif sering menghadapi permasalahan *cold-start* ketika data interaksi pengguna masih terbatas (Nesmaoui et al., 2023).

Penelitian internasional oleh Li et al. (2024) menegaskan bahwa sistem rekomendasi novel perlu mempertimbangkan karakteristik khusus novel dan perilaku pembaca untuk menghasilkan rekomendasi yang relevan. Namun, sebagian besar penelitian yang ada masih menggunakan teknik pengolahan teks konvensional dan belum banyak mengombinasikan analisis relevansi konten teks dengan pemodelan preferensi pembaca dalam satu pendekatan yang terintegrasi. Hal ini menunjukkan bahwa kajian sistem rekomendasi yang secara khusus berfokus pada novel masih relatif terbatas.


Pendekatan berbasis konten umumnya hanya memanfaatkan kemiripan teks dan genre, sehingga rekomendasi yang dihasilkan cenderung kurang bervariasi. Sementara itu, *collaborative filtering* sering mengalami permasalahan *cold-start* dan *sparsity* ketika data interaksi pengguna masih terbatas. Oleh karena itu, pendekatan *hybrid* banyak digunakan karena mampu menggabungkan keunggulan kedua metode tersebut untuk meningkatkan kualitas rekomendasi serta mengakomodasi berbagai karakteristik data dan preferensi pengguna secara lebih efektif (AL-Ghuribi et al., 2025; Chaudhari et al., 2024; Yusufida, 2025). Integrasi metode *BM25* dan *Matrix Factorization* dinilai mampu menghasilkan rekomendasi yang lebih relevan dan lebih personal sesuai preferensi pengguna. Pendekatan *hybrid filtering* juga terbukti mampu meningkatkan minat baca pada sistem rekomendasi buku serta meningkatkan relevansi rekomendasi pada domain lain seperti kursus daring melalui kombinasi non-negative *Matrix Factorization* dan keyword-based filtering ((Zuliuskandar et al., 2025).

Selain itu, tinjauan literatur menunjukkan bahwa pendekatan *model-based collaborative filtering*, khususnya *Matrix Factorization*, mampu mengurangi permasalahan *cold-start*, data *sparsity*, dan *scalability* sehingga menjadi salah satu metode yang paling banyak digunakan dalam pengembangan sistem rekomendasi modern (Saifudin et al., 2024). Selanjutnya, penelitian terbaru menunjukkan bahwa pengembangan metode berbasis *Matrix Factorization* yang dikombinasikan dengan teknik pemeringkatan (*ranking*) dapat meningkatkan kualitas rekomendasi pada metrik Top-N seperti *NDCG* dan *Precision*, sekaligus mempertahankan efisiensi waktu komputasi (Widiyaningtyas et al., 2025).

Berdasarkan kondisi tersebut, penelitian ini berfokus pada novel sebagai objek kajian, bukan buku secara umum, dengan memperhatikan karakteristik teks naratif dan preferensi pembaca, sehingga penelitian ini menjadi inovatif. Penelitian ini menerapkan pendekatan *weighted hybrid* dengan mengombinasikan metode *Best Matching 25 (BM25)* untuk mengukur relevansi konten teks novel dan *Matrix Factorization* untuk memodelkan preferensi laten pembaca berdasarkan data rating, guna mengatasi keterbatasan metode tunggal yang banyak digunakan pada penelitian sebelumnya. Penelitian ini bertujuan untuk menganalisis efektivitas pendekatan *hybrid* tersebut dalam menghasilkan rekomendasi akhir, sekaligus mengevaluasi kualitas rekomendasi yang dihasilkan berdasarkan metrik *Normalized Discounted Cumulative Gain (NDCG@10)* dan *Precision@10*. Dataset yang digunakan merupakan data sekunder yang diperoleh dari repositori publik Kaggle, terdiri atas *Goodreads-books* untuk konten novel dan *Goodbooks-10k* untuk data rating pengguna.

2. Metode Penelitian

Penelitian ini menggunakan metode pendekatan kuantitatif eksperimental untuk membangun sistem rekomendasi *hybrid*. Pendekatan eksperimental dipilih karena sejalan dengan karakteristik penelitian rekayasa perangkat lunak berbasis *machine learning*, yang menekankan pengujian sistematis terhadap model untuk mengukur pengaruhnya terhadap suatu variabel atau hasil tertentu (Chaudhari et al., 2024). Pendekatan kuantitatif dipilih karena penelitian ini melibatkan pemrosesan data numerik dan pengukuran kinerja sistem menggunakan parameter statistik yang objektif, sedangkan metode eksperimental diterapkan melalui serangkaian uji coba model algoritma *BM25* dan *Matrix Factorization* untuk memvalidasi kualitas rekomendasi berdasarkan metrik *NDCG* dan *Precision*. Tahapan penelitian meliputi studi literatur, penyiapan dataset, *pre-processing* data, implementasi *BM25*, implementasi *Matrix Factorization*, penggabungan skor *hybrid*, evaluasi model, serta implementasi antarmuka *website*, sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Alur metode penelitian

2.1. Dataset

Dataset yang digunakan merupakan data sekunder yang diperoleh dari platform *Kaggle* dan bersifat *open source*, yang terdiri atas dua sumber, yaitu *Goodreads-books* sebagai sumber data konten novel (judul, penulis, genre, dan sinopsis) dan *Goodbooks-10k* sebagai sumber data rating pengguna (*user_id*, *book_id*, dan rating). Karena dataset awal mencakup berbagai jenis bacaan, dilakukan seleksi item berdasarkan atribut genre dan karakteristik naratif sinopsis untuk memastikan hanya item novel yang digunakan dalam proses pemodelan. Sinkronisasi antara dataset konten dan dataset rating dilakukan menggunakan atribut *book_id* sebagai kunci utama, kemudian dilakukan filtering terhadap pengguna dan novel yang memiliki jumlah interaksi yang sangat sedikit.

Contoh data dari *Goodreads Books Dataset* ditunjukkan pada Tabel 1.

Tabel 1. Data *Goodreads Books Dataset*

No	book_id	Author	Title	Genre	Synopsis (Potongan)
1	1	Suzanne Collins	<i>The Hunger Games</i>	<i>Dystopia, Young Adult</i>	<i>In the ruins of a place once known as North America...</i>
2	2	J.K. Rowling	<i>Harry Potter and the Order of the Phoenix</i>	<i>Fantasy</i>	<i>Harry returns to Hogwarts and discovers that...</i>
3	3	Stephenie Meyer	<i>Twilight</i>	<i>Romance, Fantasy</i>	<i>About an ordinary girl who falls in love with a vampire...</i>
...	...	...	...	...	...

Selanjutnya, contoh data *Goodbooks-10k Dataset* ditunjukkan pada Tabel 2.

Tabel 2. Data *Goodbooks-10k Dataset*

No	UserId	BookId	Rating
1	1	3	4
2	1	5	5
3	2	10	3
4	3	7	4
...	...	...	...

Kedua dataset kemudian diintegrasikan menggunakan atribut *book_id* sebagai kunci utama, sehingga setiap data novel memiliki informasi konten serta data rating pengguna. Sebelum proses integrasi dilakukan, data terlebih dahulu melalui tahap pembersihan untuk menghapus nilai kosong (*missing value*), data duplikat, serta atribut yang tidak digunakan dalam penelitian. Setelah proses tersebut selesai, diperoleh sebanyak 8.480 data novel, 16.220 pengguna aktif, dan 640.396 data rating yang digunakan untuk tahap pelatihan dan evaluasi sistem.

2.2 Pre-processing

Tahap *pre-processing* dilakukan untuk mempersiapkan dataset novel agar berada dalam kondisi bersih, konsisten, dan siap digunakan dalam proses perhitungan relevansi konten maupun pelatihan model. Pada data teks, *pre-processing* meliputi case folding, penghapusan karakter khusus, penghapusan spasi berlebih, dan normalisasi teks pada atribut judul, genre, dan sinopsis, sebagaimana lazim diterapkan pada tahap persiapan data *content-based*

DOI: <https://doi.org/10.69693/ijmst.v4i2.12786>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

filtering (Ridhwanullah et al., 2024), yang selanjutnya digunakan sebagai representasi konten untuk perhitungan *BM25*. Pada data rating, dilakukan penyesuaian skala dan penghapusan data yang tidak konsisten sebelum digunakan untuk melatih model *Matrix Factorization*. Setelah data dibersihkan, dataset dibagi menjadi data latih dan data uji dengan beberapa skenario perbandingan untuk membandingkan performa sistem pada berbagai proporsi pembagian data.

2.3 Implementasi *Best Matching 25 (BM25)*

Metode *Best Matching 25 (BM25)* digunakan untuk menghitung tingkat relevansi antar-novel berdasarkan kemiripan teks sinopsis. *BM25* mempertimbangkan frekuensi kemunculan kata, panjang dokumen, dan tingkat kepentingan setiap istilah sehingga mampu menghasilkan peringkat dokumen yang lebih relevan (Fahmi Ilmi et al., 2022; Peng et al., 2021). Perhitungan skor relevansi dilakukan menggunakan Persamaan (1).

$$Skor(d, q) = \sum_{t \in q} IDF(t) \cdot \frac{f(t, d)(k_1 + 1)}{f(t, d) + k_1(1 - b + b \frac{|d|}{avgdl})} \quad (1)$$

dengan $Score(D, Q)$ merupakan skor relevansi dokumen D terhadap *query* Q , tf adalah frekuensi kemunculan istilah pada dokumen, dengan $TF(t, d)$ merupakan frekuensi kemunculan istilah t pada dokumen d , $IDF(t)$ adalah *Inverse Document Frequency*, $|d|$ menyatakan panjang dokumen, $avgdl$ adalah rata-rata panjang dokumen, sedangkan k_1 dan b merupakan parameter *BM25* yang mengatur pengaruh frekuensi istilah dan normalisasi panjang dokumen (Fahmi Ilmi et al., 2022).

Nilai *BM25* yang diperoleh kemudian dinormalisasi agar memiliki rentang nilai yang sebanding dengan hasil prediksi *Matrix Factorization* sebelum dilakukan proses penggabungan menggunakan pendekatan *weighted hybrid*.

2.4 Implementasi *Matrix Factorization*

Matrix Factorization digunakan untuk memodelkan preferensi pengguna berdasarkan data rating dengan memfaktorkan matriks pengguna-item menjadi dua matriks faktor laten sehingga dapat memprediksi rating novel yang belum pernah diberikan pengguna (Ardiansyah et al., 2023; Bojorque et al., 2025). Prediksi rating dihitung menggunakan Persamaan (2).

$$\hat{R}_{ui} = P_u \cdot Q_i \quad (2)$$

dengan $\hat{R}_{ui}$ merupakan prediksi rating pengguna terhadap novel, P_u adalah vektor faktor laten pengguna, sedangkan Q_i merupakan vektor faktor laten novel. Hasil prediksi tersebut digunakan sebagai representasi preferensi pengguna dalam proses rekomendasi (Saputra et al., 2024; Xu et al., 2025).

Matrix Factorization dipilih karena terbukti efektif dalam memodelkan preferensi pengguna berdasarkan data rating pada berbagai domain rekomendasi, seperti rekomendasi destinasi wisata (Saputra et al., 2024) dan rekomendasi makanan berbasis *collaborative filtering*. Karena nilai $\hat{R}_{ui}$ masih berada pada skala internal model, dilakukan proses scaling menggunakan persamaan (4) agar hasil prediksi berada pada skala rating aktual 1-5

$$R_{ui} = R_{min} + (\hat{R}_{ui} \times (R_{max} - R_{min})) \quad (3)$$

Hasil prediksi rating kemudian dinormalisasi agar dapat digabungkan dengan skor *BM25* pada proses *weighted hybrid*.

2.5 Implementasi *Hybrid*

Tahap ini merupakan integrasi dari dua metode yang telah dilakukan sebelumnya. Pendekatan yang digunakan adalah *weighted hybrid*, di mana skor *Matrix Factorization* dan skor *BM25* yang telah dinormalisasi digabungkan melalui pembobotan, sejalan dengan konsep bahwa integrasi metode *BM25* dan *Matrix Factorization* mampu menghasilkan rekomendasi yang lebih relevan dan personal sesuai preferensi pengguna dibandingkan dengan penggunaan metode tunggal (Maramis et al., 2025; Xu et al., 2025), menggunakan persamaan (4).

$$Skor_{Hybrid}(u, i) = \alpha \cdot Skor_{BM25}(i) + (1 - \alpha) \cdot \hat{R}_{ui} \quad (4)$$

dengan *Hybrid Score* merupakan skor akhir rekomendasi novel, *BM25* adalah skor relevansi konten, $\hat{R}_{ui}$ merupakan prediksi rating hasil *Matrix Factorization*, sedangkan α merupakan bobot penggabungan kedua metode yang bernilai antara 0 dan 1 (Kant Yadav et al., 2023).

Seluruh novel kemudian diurutkan berdasarkan nilai *Hybrid Score* secara menurun, sehingga novel dengan skor tertinggi direkomendasikan kepada pengguna.

2.6 Evaluasi Sistem

Kinerja sistem dievaluasi menggunakan metrik *Normalized Discounted Cumulative Gain (NDCG)*, *Precision*, dan waktu komputasi. *NDCG* digunakan untuk mengukur kualitas pemeringkatan rekomendasi, sedangkan *Precision*

mengukur ketepatan item relevan yang direkomendasikan kepada pengguna (Kong et al., 2024; Rajesh et al., 2025) Pengujian dilakukan menggunakan tiga skenario pembagian data (70:30, 80:20, dan 90:10) serta beberapa variasi nilai *Alpha* dan jumlah rekomendasi *Top-N*.
DCG dihitung menggunakan persamaan (5).

$$DCG@N = \sum_{i=1}^K \frac{2^{rel_i} - 1}{\log_2(i + 1)} \quad (5)$$

dengan *DCG@N* merupakan nilai *Discounted Cumulative Gain* pada *N* rekomendasi teratas, *rel_i* adalah tingkat relevansi item pada posisi ke-*i*, sedangkan *N* merupakan jumlah rekomendasi yang dievaluasi.
IDCG dihitung menggunakan Persamaan (6).

$$IDCG@N = \sum_{i=1}^K \frac{2^{rel_i^*} - 1}{\log_2(i + 1)} \quad (6)$$

dengan *IDCG@N* merupakan nilai *Discounted Cumulative Gain ideal*, *rel_i^{ideal}* adalah nilai relevansi ideal pada posisi ke-*i*, sedangkan *N* merupakan jumlah rekomendasi yang dievaluasi.
 Selanjutnya, nilai *NDCG* dihitung menggunakan Persamaan (7).

$$NDCG@N = \frac{DCG@N}{IDCG@N} \quad (7)$$

dengan *NDCG@N* merupakan nilai normalisasi antara *DCG@N* dan *IDCG@N* sehingga menghasilkan nilai evaluasi pada rentang 0 hingga 1.

Selain itu, *Precision* dihitung menggunakan Persamaan (8).

$$Precision = \frac{\text{Jumlah item relevan pada Top - N}}{\text{Jumlah item yang direkomendasikan pada Top - N}} \quad (8)$$

dengan jumlah item relevan pada *Top-N* merupakan banyaknya novel relevan yang berhasil direkomendasikan, sedangkan jumlah item yang direkomendasikan pada *Top-N* adalah total novel yang ditampilkan pada daftar rekomendasi. Nilai *Precision* yang lebih tinggi menunjukkan tingkat ketepatan rekomendasi yang semakin baik (Askari et al., 2023).

Semakin tinggi nilai *NDCG* dan *Precision*, semakin baik kualitas rekomendasi yang dihasilkan. Sebaliknya, waktu komputasi yang lebih rendah menunjukkan bahwa sistem memiliki efisiensi komputasi yang lebih baik.

3. Hasil dan Pembahasan

Pengujian dilakukan menggunakan dataset novel yang diperoleh dari *Goodreads-books* dan *Goodbooks-10k* dengan beberapa skenario parameter. Kinerja sistem dievaluasi menggunakan metrik Normalized Discounted Cumulative Gain (*NDCG*), *Precision*, dan waktu komputasi untuk menganalisis kualitas rekomendasi yang dihasilkan.

3.1 Hasil

Hasil penelitian mencakup proses *pre-processing* data dan pelatihan model, hasil evaluasi utama, hasil pengujian parameter *alpha*, data split, dan *Top-N*, serta implementasi antarmuka *website* sebagai media penggunaan sistem rekomendasi.

3.1.1 Pre-processing

Proses *pre-processing* menghasilkan dataset akhir yang siap digunakan pada tahap pemodelan sistem rekomendasi. Ringkasan hasil *pre-processing* ditunjukkan pada Tabel 3.

Tabel 3. Ringkasan dataset setelah *Pre-processing*

Keterangan	Jumlah
Novel final	8.480
User final	16.220
Rating final	640.396
Sparsity	99,534%

Hasil *pre-processing* menunjukkan bahwa dataset akhir terdiri atas 8.480 novel dan 16.220 pengguna aktif dengan total 640.396 data rating. Nilai sparsity yang tinggi (99,534%) menunjukkan bahwa sebagian besar kombinasi pengguna-novel tidak memiliki interaksi rating, sebagaimana umumnya ditemukan pada sistem *collaborative filtering*. Meskipun demikian, jumlah data rating yang tersedia masih cukup besar sehingga *Matrix Factorization* tetap dapat mempelajari pola preferensi pengguna secara efektif.

3.1.2 Implementasi *Best Matching 25 (BM25)* dan *Matrix Factorization*

Model *BM25* berhasil menghitung skor relevansi novel berdasarkan kesesuaian kata kunci yang dimasukkan pengguna dengan judul, genre, dan sinopsis novel. Setiap novel memperoleh skor relevansi yang menunjukkan tingkat kemiripan konten dengan kebutuhan pengguna.

Selanjutnya, *Matrix Factorization* dilatih menggunakan data rating pada *Goodbooks-10k Dataset* untuk mempelajari pola preferensi pengguna. Model menghasilkan prediksi rating terhadap novel yang belum pernah dinilai sehingga mampu memberikan rekomendasi yang bersifat personal.

Skor *BM25* dan hasil prediksi *Matrix Factorization* selanjutnya digunakan sebagai masukan dalam proses *weighted hybrid*.

3.1.3 Hasil Hybrid

Pendekatan *weighted hybrid* berhasil menggabungkan skor relevansi *BM25* dengan hasil prediksi *Matrix Factorization* sehingga menghasilkan *Hybrid Score* sebagai dasar pemeringkatan novel. Seluruh kandidat novel diurutkan berdasarkan nilai *Hybrid Score* secara menurun untuk menghasilkan rekomendasi Top-10.

Sebagai contoh pengujian, pengguna memilih novel "*Worlds Collide*" sebagai novel acuan. Hasil rekomendasi Top-10 ditunjukkan pada Tabel 4.

Tabel 4. Hasil Rekomendasi

Rank	Judul Novel	Penulis	Rating	Match (%)	Hybrid Score
1	<i>An Author's Odyssey</i>	Chris Colfer	4,43	100,0	0,972
2	<i>The Wishing Spell</i>	Chris Colfer	4,25	91,2	0,886
3	<i>Beyond the Kingdoms</i>	Chris Colfer	4,43	90,6	0,880
4	<i>A Grimm Warning</i>	Chris Colfer	4,46	85,4	0,830
5	<i>A Tale of Magic...</i>	Chris Colfer	4,26	57,5	0,558
6	<i>The Enchantress Returns</i>	Chris Colfer	4,44	55,2	0,537
7	<i>The Last Ever After</i>	Soman Chainani	4,25	51,5	0,501
8	<i>The Ladies of Grace Adieu</i>	Susanna Clarke	3,87	50,7	0,492
9	<i>Once Upon a Crime</i>	Michael Buckley	4,28	50,1	0,487
10	<i>Stargazer</i>	Patrick Carman	4,12	48,2	0,469

Berdasarkan Tabel 4, novel "*An Author's Odyssey*" memperoleh *Hybrid Score* tertinggi sebesar 0,972, diikuti oleh "*The Wishing Spell*" dan "*Beyond the Kingdoms*". Sebagian besar novel yang direkomendasikan berasal dari penulis yang sama, yaitu Chris Colfer, karena memiliki kemiripan tema, genre, dan alur cerita. Selain itu, sistem juga mampu merekomendasikan novel dari penulis lain yang memiliki karakteristik serupa berdasarkan hasil penggabungan *BM25* dan *Matrix Factorization*.

Hasil tersebut menunjukkan bahwa pendekatan *weighted hybrid* mampu menghasilkan rekomendasi novel yang relevan dengan mempertimbangkan kesamaan konten dan preferensi pengguna berdasarkan data rating.

3.1.4 Hasil evaluasi utama

Evaluasi utama dilakukan menggunakan konfigurasi $\alpha = 0,6$, $Top-N = 10$. Hasil evaluasi utama ditunjukkan pada Tabel 5.


Tabel 5. Hasil evaluasi utama

α	$NDCG@10$	$Precision@10$	Runtime (detik)
0,6	0,943	0,488	136,46

Hasil evaluasi menunjukkan nilai $NDCG@10$ sebesar 0,943 dan $Precision@10$ sebesar 0,488, dengan runtime evaluasi 136,46 detik untuk 15.813 pengguna. Nilai $NDCG$ yang mendekati 1 menunjukkan bahwa sistem mampu menempatkan novel yang relevan pada posisi awal daftar rekomendasi, sedangkan nilai $Precision$ menunjukkan bahwa hampir separuh novel yang direkomendasikan sesuai dengan preferensi pengguna berdasarkan data uji. Secara keseluruhan, hasil ini menunjukkan bahwa pendekatan *hybrid BM25* dan *Matrix Factorization* mampu menghasilkan rekomendasi novel dengan kualitas pemeringkatan yang baik serta efisiensi komputasi yang memadai.


3.1.5 Implementasi Sistem (Website)

Model sistem rekomendasi diimplementasikan dalam bentuk aplikasi berbasis web menggunakan *framework Flask* pada *Python*. Sistem menyediakan fitur pencarian novel berdasarkan judul, penulis, dan genre, serta menampilkan rekomendasi novel menggunakan pendekatan *weighted hybrid* yang menggabungkan metode *Best Matching 25 (BM25)* dan *Matrix Factorization*.



Gambar 2. Halaman Beranda

Gambar 2 menunjukkan halaman beranda yang menyediakan fitur pencarian novel berdasarkan judul, penulis, dan genre. Selain itu, halaman ini juga menampilkan daftar novel populer dan kategori genre untuk memudahkan pengguna menemukan novel sesuai dengan preferensi.



Gambar 3. Halaman Detail Novel dan Hasil Rekomendasi

Gambar 3 menunjukkan halaman detail novel yang menyajikan informasi berupa judul, penulis, genre, rating, dan sinopsis novel. Pada bagian bawah halaman ditampilkan daftar rekomendasi novel yang telah diurutkan berdasarkan nilai *Hybrid Score*. Rekomendasi tersebut dihasilkan melalui penggabungan skor relevansi *BM25* dan hasil prediksi *Matrix Factorization* sehingga mampu mempertimbangkan kesamaan konten dan preferensi pengguna.

3.2 Pembahasan

3.5.1 Perbandingan dengan penelitian terdahulu

Penelitian ini dibandingkan dengan penelitian Rajesh dan Kumar (2025) mengenai model rekomendasi berbasis LightGCN, yang menghasilkan nilai *NDCG@10* sebesar 0,435. Perbandingan kedua penelitian ditunjukkan pada Tabel 6.

Tabel 6. Perbandingan dengan penelitian terdahulu

Aspek	Rajesh & Kumar (2025)	Penelitian Usulan
DOI: https://doi.org/10.69693/ijmst.v4i2.12786		
Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)		

Objek penelitian	Rekomendasi umum	Novel
Metode	LightGCN	<i>Weighted hybrid BM25 dan Matrix Factorization</i>
Metrik evaluasi	<i>NDCG@10</i>	<i>NDCG@10, Precision@10, waktu komputasi</i>
Hasil <i>NDCG@10</i>	0,435	0,943
Hasil <i>Precision@10</i>	Tidak digunakan	0,488


Meskipun nilai *NDCG@10* pada penelitian ini secara numerik lebih tinggi dibandingkan dengan penelitian Rajesh dan Kumar (2025), kedua nilai tersebut tidak dapat dibandingkan secara langsung sebagai bukti keunggulan mutlak salah satu metode, karena kedua penelitian menggunakan objek, dataset, fitur, dan skenario pengujian yang berbeda. Perbedaan utama penelitian ini terletak pada penggunaan pendekatan *weighted hybrid* yang menggabungkan relevansi konten teks melalui *BM25* dan preferensi laten pengguna melalui *Matrix Factorization*, serta pelaporan waktu komputasi sebagai indikator efisiensi yang tidak dilaporkan dalam penelitian pembandingan. Dengan demikian, kontribusi penelitian ini bukan untuk membuktikan bahwa pendekatan *hybrid* secara mutlak lebih baik daripada metode pada penelitian terdahulu, melainkan untuk menunjukkan bahwa integrasi *BM25* dan *Matrix Factorization* dapat diterapkan untuk menghasilkan rekomendasi novel berbasis peringkat yang relevan dan efisien.

3.2.2 Hasil Pengujian Parameter (*Alpha*, Data Split, dan *Top-N*)

Pengujian parameter *alpha* dilakukan untuk menganalisis pengaruh pembobotan antara *BM25* dan *Matrix Factorization* terhadap kualitas rekomendasi. Hasil pengujian disajikan pada Tabel 7 dan Gambar 4.

Tabel 7. Hasil pengujian variasi *alpha*

<i>Alpha</i>	<i>NDCG@10</i>	<i>Precision@10</i>	Runtime (dtk)
0,1	0,846	0,471	134,89
0,3	0,910	0,480	136,05
0,5	0,936	0,486	132,56
0,6	0,943	0,488	130,71
0,7	0,947	0,490	131,71
0,9	0,952	0,492	133,42




Gambar 4. Pengaruh nilai *alpha* terhadap *NDCG@10* dan *Precision@10*

Berdasarkan Tabel 7 dan Gambar 4, peningkatan nilai *alpha* memberikan pengaruh positif secara konsisten terhadap *NDCG@10* dan *Precision@10*, dari 0,846 dan 0,471 pada *alpha* 0,1 menjadi 0,952 dan 0,492 pada *alpha* 0,9. Hal ini menunjukkan bahwa *Matrix Factorization* memiliki kontribusi yang lebih dominan dibandingkan *BM25*, karena data rating pengguna memberikan sinyal preferensi yang lebih langsung dibandingkan dengan informasi konten. Runtime evaluasi pada seluruh konfigurasi *alpha* relatif stabil pada rentang 130-137 detik, sehingga perubahan *alpha* tidak berpengaruh signifikan terhadap waktu komputasi. Meskipun *alpha* 0,9 memberikan performa tertinggi, penelitian ini tetap memilih *alpha* 0,6 sebagai konfigurasi utama karena mampu mempertahankan kontribusi *BM25* secara seimbang sehingga karakteristik *hybrid* dari sistem tetap terjaga.

Pengujian data split dilakukan untuk menganalisis pengaruh proporsi data latih dan data uji terhadap kinerja sistem. Hasil pengujian ditunjukkan pada Tabel 8 dan Gambar 5.

Tabel 8. Hasil pengujian variasi data split

Split	<i>NDCG@10</i>	<i>Precision@10</i>	Runtime (dtk)
90:10	0,924	0,303	139,05
80:20	0,943	0,488	146,78
70:30	0,951	0,626	146,44
60:40	0,953	0,721	148,20




Gambar 5. Pengaruh proporsi data split terhadap *NDCG@10* dan *Precision@10*

Hasil pengujian data split menunjukkan bahwa *NDCG@10* dan *Precision@10* meningkat seiring dengan berkurangnya proporsi data latih, dengan kenaikan *Precision@10* yang cukup signifikan dari konfigurasi 90:10 hingga 60:40. Fenomena ini menunjukkan bahwa hasil evaluasi sangat dipengaruhi oleh distribusi data uji, bukan semata-mata oleh kualitas model. Oleh karena itu, konfigurasi 80:20 tetap dipilih sebagai konfigurasi utama karena memberikan keseimbangan antara kemampuan model dalam mempelajari data dan objektivitas hasil evaluasi. Pengujian *Top-N* dilakukan pada $N = 5, 10, 20$, dan 30 dengan hasil yang ditunjukkan pada Tabel 9 dan Gambar 6.

Tabel 9. Hasil pengujian variasi *Top-N*

<i>Top-N</i>	<i>NDCG</i>	<i>Precision</i>	Runtime (dtk)
5	0,919	0,716	135,19
10	0,943	0,488	134,42
20	0,948	0,275	136,52
30	0,948	0,186	134,70



Gambar 6. Pengaruh nilai *Top-N* terhadap *NDCG* dan *Precision*

Nilai *Precision* menurun seiring bertambahnya N , dari 0,716 pada *Top-5* menjadi 0,186 pada *Top-30*, karena semakin banyak item yang direkomendasikan, semakin besar peluang masuknya novel dengan relevansi yang lebih rendah. Sebaliknya, nilai *NDCG* meningkat dari 0,919 menjadi 0,948 karena metrik ini mempertimbangkan posisi

DOI: <https://doi.org/10.69693/ijmst.v4i2.12786>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

item relevan dalam daftar, sehingga sistem tetap mampu menempatkan novel yang relevan pada posisi atas meskipun daftar rekomendasi diperluas. Konfigurasi Top-10 tetap dipilih sebagai konfigurasi utama karena memberikan jumlah rekomendasi yang proporsional dengan kebutuhan pengguna dalam menemukan novel yang relevan.

3.2.3 Kelebihan dan Keterbatasan Penelitian

Pendekatan *hybrid* yang menggabungkan *Best Matching 25 (BM25)* dan *Matrix Factorization* mampu memanfaatkan informasi konten novel serta preferensi pengguna secara bersamaan sehingga menghasilkan rekomendasi yang lebih relevan. Pengujian menunjukkan bahwa sistem memiliki kualitas pemeringkatan yang baik berdasarkan nilai *NDCG* dan *Precision*, serta waktu komputasi yang relatif efisien. Selain itu, penggunaan parameter α memberikan fleksibilitas dalam mengatur kontribusi kedua metode sehingga sistem dapat menghasilkan rekomendasi yang lebih seimbang.

Penelitian ini masih memiliki beberapa keterbatasan. Dataset yang digunakan memiliki tingkat *sparsity* yang tinggi sehingga dapat memengaruhi proses pembelajaran *Matrix Factorization*. Selain itu, representasi konten novel masih terbatas pada atribut judul, genre, dan sinopsis, serta sistem belum mampu menangani permasalahan *cold-start* secara optimal. Oleh karena itu, penelitian selanjutnya dapat memanfaatkan informasi tambahan seperti ulasan pengguna, metadata novel, atau model representasi teks yang lebih modern untuk meningkatkan kualitas rekomendasi.

4. Kesimpulan

Penelitian ini berhasil mengimplementasikan *Hybrid Recommender System* yang mengombinasikan metode *Best Matching 25 (BM25)* dan *Matrix Factorization* pada sistem rekomendasi novel berbasis web menggunakan framework Flask. Metode *BM25* digunakan untuk mengukur relevansi konten novel berdasarkan judul, genre, dan sinopsis, sedangkan *Matrix Factorization* digunakan untuk memodelkan preferensi pengguna berdasarkan data rating. Integrasi kedua metode tersebut mampu menghasilkan sistem rekomendasi yang dapat memberikan rekomendasi novel secara interaktif sesuai dengan preferensi pengguna.

Berdasarkan hasil evaluasi, sistem memperoleh nilai *NDCG@10* sebesar 0,943, *Precision@10* sebesar 0,489, dengan *runtime* evaluasi 136,46 detik untuk memproses 15.813 pengguna. Hasil pengujian juga menunjukkan bahwa variasi nilai α , pembagian data, dan *Top-N* memengaruhi kinerja sistem. Penelitian selanjutnya dapat memanfaatkan sumber informasi yang lebih beragam serta metode representasi teks yang lebih modern untuk meningkatkan kualitas dan personalisasi rekomendasi.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Jember, atas dukungan fasilitas dan sarana yang diberikan selama penelitian ini berlangsung. Terima kasih juga disampaikan kepada dosen pembimbing atas bimbingan, arahan, dan masukan yang sangat berarti dalam penyusunan penelitian ini, serta kepada seluruh pihak yang telah membantu proses pengumpulan data melalui repositori publik *Kaggle*, khususnya penyedia dataset *Goodreads-books* dan *Goodbooks-10k*, yang menjadi sumber data utama dalam penelitian ini. Ucapan terima kasih juga ditujukan kepada keluarga, rekan mahasiswa, dan semua pihak yang tidak dapat disebutkan satu per satu atas dukungan moral dan motivasi selama proses penelitian hingga penulisan artikel ini selesai.

Reference

- AL-Ghuribi, S. M., Mohd Noah, S. A., Tiun, S., Mohammed, M. A., & Saat, N. I. Y. (2025). Combining review elements for modelling various multi-criteria collaborative recommendation models. *Journal of Big Data*, 12(1). <https://doi.org/10.1186/s40537-025-01222-6>
- Ardiansyah, R., Ari Bianto, M., & Saputra, B. D. (2023). Sistem Rekomendasi Buku Perpustakaan Sekolah menggunakan Metode Content-Based Filtering. *Jurnal CoSciTech (Computer Science and Information Technology)*, 4(2), 510–518. <https://doi.org/10.37859/coscitech.v4i2.5131>
- Askari, A., Abolghasemi, A., Pasi, G., Kraaij, W., & Verberne, S. (2023). Injecting the BM25 Score as Text Improves BERT-Based Re-rankers. <https://doi.org/10.48550/arXiv.2301.09728>
- Bojorque, R., & Hurtado, R. (2025). Matrix Factorization-Based Clustering for Sparse Data in Recommender Systems: A Comparative Study. *Computation*, 13(9). <https://doi.org/10.3390/computation13090213>
- Chaudhari, A., Hitham Seddig, A. A., Sarlan, A., & Raut, R. (2024). A Hybrid Recommendation System: A Review. *IEEE Access*, 12, 157107–157126. <https://doi.org/10.1109/ACCESS.2024.3480693>
- Fahmi Ilmi, M., & Pandu Adikara, P. (2022). Pencarian Dokumen Skripsi menggunakan BM25 dan Faceted Search berdasarkan Kata Kunci Abstrak (Studi Kasus: Universitas Muhammadiyah Sidoarjo) (Vol. 6, Number 9). <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/11531>
- Kant Yadav, K., Kumar Soni, H., Yadav, G., & Sharma, M. (2023). International Journal of Intelligent Systems And Applications In Engineering Collaborative Filtering Based Hybrid Recommendation System Using Neural Network and Matrix Factorization Techniques. In *Original Research Paper International Journal of Intelligent Systems and Applications in Engineering IJISAE* (Vol. 2024, Number 8s). <https://ijisae.org/index.php/IJISAE/article/view/4307>
- Kheng, T., Asri, J. S., Wahyu, S., & Yulhendri, Y. (2025). Penerapan Algoritma BM25 dalam Pencarian Lowongan Pekerjaan pada Website Job Portal. *Bulletin of Computer Science Research*, 5(5), 1029–1038. <https://doi.org/10.47065/bulletincsr.v5i5.760>

- Kong, W.-E., Tai, T.-E., Naveen, P., & Santoso, H. A. (2024). Performance Evaluation on E-Commerce Recommender System based on KNN, SVD, CoClustering and Ensemble Approaches. *Journal of Informatics and Web Engineering*, 3(3), 63–76. <https://doi.org/10.33093/jiwe.2024.3.3.4>
- Li, X., Lipp, J., Shakir, A., Huang, R., & Li, J. (2024). *BMX: Entropy-weighted Similarity and Semantic-enhanced Lexical Search*. <https://doi.org/10.48550/arXiv.2408.06643>
- Maramis, G. D. P., Ranti, M. C. P., & Santa, K. (2025). BM25 Algorithm for Improving Academic Website Search Accuracy. *Indonesian Journal of Innovation Studies*, 27(1). <https://doi.org/10.21070/ijins.v27i1.1799>
- Nesmaoui, R., Louhichi, M., & Lazaar, M. (2023). A Collaborative Filtering Movies Recommendation System based on Graph Neural Network. *Procedia Computer Science*, 220, 456–461. <https://doi.org/10.1016/j.procs.2023.03.058>
- Peng, S., Xie, X., Zhai, J., Jia, Y., & Gong, Y. (2021). A Page-topic Relevance Algorithm Based on BM25 and Paragraph-Semantic Correlation. *Journal of Physics: Conference Series*, 1757(1). <https://doi.org/10.1088/1742-6596/1757/1/012115>
- Rajesh, D. B., & Kumar, A. (2025). Collaborative filtering models an experimental and detailed comparative study. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-15096-4>
- Ridhwanullah, D., Kumarahadi, Y. K., & Raharja, B. D. (2024). Content-Based Filtering pada Sistem Rekomendasi Buku Informatika. *Jurnal Ilmiah SINUS*, 22(2), 57. <https://doi.org/10.30646/sinus.v22i2.840>
- Saifudin, I., & Widiyaningtyas, T. (2024). Systematic Literature Review on Recommender System: Approach, Problem, Evaluation Techniques, Datasets. *IEEE Access*, 12, 19827–19847. <https://doi.org/10.1109/ACCESS.2024.3359274>
- Saputra, D. M., Angelia, N., & Yusliani, N. (2024). Recommender System for Tourist Destinations in Indonesia Using Matrix Factorization Method. *JITSI : Jurnal Ilmiah Teknologi Sistem Informatika*, 5(3), 122–127. <https://doi.org/10.62527/jitsi.5.3.254>
- Widiyaningtyas, T., Saifudin, I., Zaeni, I. A. E., Maulana, M. Z. N., & Caesarendra, W. (2025). Memory-based collaborative filtering based on matrix factorization and Gower's set rank. *Journal of King Saud University - Computer and Information Sciences*, 37(9). <https://doi.org/10.1007/s44443-025-00261-6>
- Xu, J., Liu, Z., Tan, L., Li, T., Peng, T., & Gong, D. (2025). Local Matrix Factorization With Network Embedding For Recommender Systems. *Computing and Informatics*, 44, 223–244. <https://doi.org/10.31577/cai>
- Yusfida, F. (2025). A Hybrid Approach for Recommender Systems Based on Alternating Least Squares and CatBoost. *Jurnal Teknik Informatika (Jutif)*, 6(4), 2825–2836. <https://doi.org/10.52436/1.jutif.2025.6.4.5002>
- Zuliuskandar, V. V., Yusa, M., & Purwandari, E. P. (2025). Hybrid Method Using Non-Negative Matrix Factorization And Keyword-Based Filtering For Recommender System In Moocs. *Jurnal Teknik Informatika (Jutif)*, 6(1), 345–358. <https://doi.org/10.52436/1.jutif.2025.6.1.3605>