



Pengembangan Sistem Rekomendasi Buku Menggunakan Metode *Hybrid Filtering* dalam Layanan Perpustakaan Modern

Sukma Kartikasari

Universitas Airlangga Surabaya
sukmakartikasari@staf.unair.ac.id

Shiefti Dyah Alyusi

Universitas Airlangga Surabaya
shiefti@staf.unair.ac.id

Siti Muzaroh

Universitas Airlangga Surabaya
muza@staf.unair.ac.id

Received: 24 Februari 2025 Accepted: 5 Juni 2025 Published: 23 Juni 2025

ABSTRACT - In the digital era, libraries are required to provide services that adapt to users' evolving needs. As book collections – both digital and physical – continue to grow, machine learning technology offers an effective approach to delivering personalized book recommendations based on users' preferences or borrowing history. This study focuses on developing a book recommendation system utilizing machine learning algorithms to analyze borrowing behavior patterns, genre preferences, and user interaction history. The system is developed using a hybrid filtering approach, which combines collaborative filtering and content-based filtering. The data used includes book metadata (title, category, and author) as well as users' borrowing records. Evaluation results indicate good system performance, with a precision score of 80%, recall of 72%, and F1-score of 75%. These findings suggest that the hybrid filtering approach can produce more accurate and relevant book recommendations. Consequently, the system can assist users in finding book collections that align with their interests and preferences, thereby improving efficiency and convenience in locating reading materials within the library.

Keywords: Book Recommendation System; Machine Learning; Hybrid Filtering; Digital Library; User Behavior Analysis

ABSTRAK - Di era digital, perpustakaan dituntut untuk menyediakan layanan yang adaptif terhadap kebutuhan pengguna. Seiring bertambahnya koleksi buku, baik dalam bentuk digital maupun fisik, teknologi pembelajaran mesin menawarkan pendekatan yang efektif untuk menyajikan rekomendasi buku yang sesuai berdasarkan preferensi atau riwayat peminjaman pengguna. Penelitian ini berfokus pada pengembangan sistem rekomendasi buku berbasis algoritma pembelajaran mesin

yang menganalisis pola perilaku peminjaman, preferensi genre, dan riwayat interaksi pengguna. Sistem dikembangkan menggunakan pendekatan hybrid filtering, yaitu kombinasi antara collaborative filtering dan content-based filtering. Data yang digunakan mencakup metadata buku (judul, kategori, dan pengarang) serta riwayat peminjaman pengguna. Hasil evaluasi menunjukkan kinerja sistem yang baik, dengan nilai precision sebesar 80%, recall sebesar 72%, dan F1-score sebesar 75%. Temuan ini menunjukkan bahwa pendekatan hybrid filtering mampu menghasilkan rekomendasi buku yang lebih akurat dan relevan. Dengan demikian, sistem ini dapat membantu pengguna menemukan koleksi buku yang sesuai dengan minat dan preferensi mereka, sehingga meningkatkan efisiensi dan kenyamanan dalam mencari bahan bacaan di perpustakaan.

Kata kunci: Sistem Rekomendasi Buku; Pembelajaran Mesin; Hybrid Filtering; Perpustakaan Digital; Analisis Perilaku Pengguna

A. PENDAHULUAN

Perpustakaan modern dihadapkan pada tantangan besar dalam mengelola dan menyajikan koleksi buku yang semakin bertambah, baik digital maupun fisik. Dengan jumlah koleksi yang terus meningkat, perpustakaan membutuhkan sistem yang membantu pengguna dalam menemukan buku yang relevan secara efisien. Sistem rekomendasi peminjaman buku merupakan salah satu solusi yang berpotensi meningkatkan keterlibatan pengguna dengan perpustakaan. Namun, banyak perpustakaan di Indonesia masih belum mengadopsi teknologi ini secara memadai.

Berdasarkan penelitian sebelumnya, tantangan dalam pengembangan sistem rekomendasi di perpustakaan meliputi minimnya data terkait preferensi pengguna, keterbatasan teknologi, serta kurangnya pemahaman mengenai

pembelajaran mesin di kalangan pengelola perpustakaan (Ritdrix & Wirawan, 2018)

Terdapat permasalahan utama yang dihadapi perpustakaan adalah bagaimana memberikan rekomendasi buku yang sesuai dengan preferensi pengguna tanpa keterlibatan manual yang berlebihan. Algoritma pembelajaran mesin dapat memanfaatkan data historis untuk mendeteksi pola peminjaman, memberikan rekomendasi personalisasi.

Penelitian yang dilakukan oleh Asa Dilla Safitri dkk memberikan hasil bahwa sistem rekomendasi yang dikembangkan mampu memberikan rekomendasi buku dengan nilai *similarity* yang tinggi, mencapai tingkat akurasi sebesar 0,6% (Asa Dilla Safitri et al., 2024).

Dari hasil perancangan dan pembuatan sistem rekomendasi buku pada SMKN 1 Bangil menunjukkan bahwa

sistem rekomendasi ini dapat menjadi inovasi dalam percepatan dalam layanan untuk menemukan buku apa yang dibutuhkan, dalam implementasinya setidaknya siswa melakukan peminjaman 1 (satu) buku (Rokhim & Saikhu, 2016).

Penelitian lainnya menunjukkan tingkat kepuasan terhadap hasil yang diberikan sistem rekomendasi dari pengguna menunjukkan nilai skor CSAT sebesar 80% yang mana tergolong "Excellent CAST" (Yanisa Putri et al., 2024).

Penelitian ini bertujuan untuk merancang sistem rekomendasi peminjaman buku berbasis algoritma pembelajaran mesin yang lebih relevan dan mudah diimplementasikan oleh perpustakaan modern di Indonesia. Studi ini juga diharapkan dapat memperkaya literatur mengenai sistem rekomendasi berbasis algoritma dalam konteks perpustakaan.

Penelitian ini menerapkan metode *hybrid recommendation* yang menggabungkan keunggulan *collaborative filtering* (CF) dan *content-based filtering* (CBF) untuk menghasilkan rekomendasi yang lebih akurat dan fleksibel. Metode ini diharapkan mampu mengatasi kelemahan yang ditemukan pada masing-

masing pendekatan jika digunakan terpisah (Tommy et al., 2020)

Penelitian sebelumnya oleh (Arfisko, 2022) tentang sistem rekomendasi film menggunakan metode *Hybrid Collaborative Filtering* dan *Content-Based Filtering* menunjukkan bahwa metode ini efektif dalam menyaring dan mengidentifikasi produk atau informasi yang relevan bagi pengguna. Selain itu, penelitian oleh (Ifada et al., 2020) membandingkan kinerja *Collaborative Filtering* dan *Hybrid approaches* untuk rekomendasi film, dan menemukan bahwa meskipun pendekatan *hybrid* memiliki kelebihan dalam beberapa kasus, *Collaborative Filtering* sering kali memberikan hasil yang lebih unggul dalam metrik tertentu (Ifada et al., 2020).

Dalam *collaborative filtering*, rekomendasi disusun berdasarkan pola perilaku pengguna atau interaksi antar item, namun sistem ini sering kali mengalami masalah data *sparsity*, terutama pada pengguna atau item baru yang interaksinya masih minim. Sebaliknya, *content-based filtering* menggunakan karakteristik item yang sesuai dengan preferensi pengguna, namun sering kali menghasilkan rekomendasi yang terlalu seragam,

sehingga mengurangi kemungkinan eksplorasi preferensi lain (Burke, 2002)

Dengan mengombinasikan kedua pendekatan tersebut, *hybrid recommendation* dapat memanfaatkan kekuatan CF untuk menghasilkan rekomendasi yang lebih relevan bagi pengguna dengan data interaksi yang kaya, serta memanfaatkan informasi konten dalam CBF untuk mendukung rekomendasi bagi pengguna atau item baru. Misalnya, sistem hibrida dapat menggunakan *collaborative filtering* untuk menentukan item populer yang digemari pengguna lain dengan preferensi serupa, lalu menyaringnya menggunakan *content-based filtering* berdasarkan karakteristik tertentu yang sesuai dengan minat spesifik pengguna (Burke, 2002). Hal ini memungkinkan sistem untuk tetap memberikan rekomendasi yang relevan meskipun pengguna memiliki riwayat interaksi terbatas.

Ada beberapa teknik dalam membangun sistem rekomendasi hibrida, termasuk pendekatan *weighted hybrid*, *switching hybrid*, dan *cascading hybrid*. Pada *weighted hybrid*, skor rekomendasi yang dihasilkan oleh CF dan CBF digabungkan dengan bobot tertentu pada masing-masing metode. Pendekatan ini

memungkinkan pengelola sistem untuk mengatur kontribusi setiap metode sesuai kebutuhan dan jenis data yang tersedia. Sebagai contoh, bobot CF dapat ditingkatkan jika data interaksi pengguna cukup banyak, atau bobot CBF diperbesar bila data interaksi terbatas (Burke, 2002).

Pendekatan *switching hybrid* menerapkan kedua metode bergantian, misalnya menggunakan CBF untuk pengguna baru tanpa riwayat interaksi, sementara CF diterapkan pada pengguna dengan riwayat interaksi lengkap. Cara ini mengatasi keterbatasan pada kedua metode tersebut dengan memastikan rekomendasi tetap diberikan, meskipun data interaksi tidak tersedia (Adomavicius & Tuzhilin, 2005)

Pendekatan *cascading hybrid* mengurutkan rekomendasi dari satu metode (misalnya CF) dan menyaringnya dengan metode lain (CBF) menggunakan kriteria tertentu. Teknik ini mempersempit pilihan yang luas dengan menggunakan preferensi pengguna yang lebih spesifik, sehingga hanya item paling relevan yang ditampilkan. Pendekatan ini sangat cocok untuk dataset besar dan memungkinkan rekomendasi lebih terfokus, karena setiap tahap penyaringan menggunakan kriteria tambahan (Burke, 2002).

Penelitian menunjukkan bahwa sistem hibrida umumnya memiliki kinerja lebih baik dibandingkan sistem CF atau CBF yang berdiri sendiri, khususnya dalam mengatasi masalah *cold start* dan data *sparsity* (Melville et al., 2002). Misalnya, (Melville et al., 2002) menemukan bahwa sistem hibrida yang menggabungkan CF dan CBF dapat meningkatkan akurasi dan relevansi rekomendasi pada platform dengan variasi preferensi pengguna yang tinggi. (Burke, 2002) juga mencatat bahwa sistem hibrida menawarkan fleksibilitas lebih dalam menghasilkan rekomendasi, dengan memanfaatkan kekuatan dan mengurangi kelemahan dari kedua pendekatan dasar. Temuan ini menunjukkan bahwa sistem rekomendasi berbasis *hybrid* mampu beradaptasi dengan kebutuhan perpustakaan modern yang memiliki data pengguna dinamis dan koleksi beragam, sehingga memungkinkan rekomendasi lebih komprehensif dan beragam.

B. LANDASAN TEORI

Collaborative Filtering (CF) merupakan salah satu teknik utama dalam sistem rekomendasi yang memanfaatkan informasi dan preferensi

pengguna lain untuk menghasilkan rekomendasi (Saputra et al., 2025).

Collaborative filtering bekerja dengan mengidentifikasi pola perilaku pengguna berdasarkan riwayat interaksi dengan item tertentu, seperti buku yang pernah dipinjam. CF terbagi menjadi dua: berbasis pengguna (*user-based CF*) dan berbasis item (*item-based CF*), di mana CF berbasis pengguna memberikan rekomendasi dengan memperhitungkan kemiripan riwayat peminjaman antar pengguna, sementara CF berbasis item melihat kesamaan antar item berdasarkan preferensi pengguna (Koren et al., 2009). Walaupun CF efektif dan mudah diterapkan, metode ini masih menghadapi tantangan seperti data *sparsity*, yaitu sulitnya memberikan rekomendasi bagi pengguna yang memiliki sedikit riwayat peminjaman (Sarwar et al., 2001).

Content-Based Filtering (CBF) merupakan teknik yang dapat menghasilkan sebuah rekomendasi sesuai dengan atribut (Tommy et al., 2020). CBF merekomendasikan item berdasarkan karakteristik kontennya, seperti genre, kata kunci, atau deskripsi buku. Pendekatan ini sesuai untuk perpustakaan, mengingat metadata buku

biasanya lengkap dan terstruktur. Meskipun CBF dapat menghasilkan rekomendasi yang lebih spesifik, metode ini terbatas pada item-item yang serupa dengan preferensi pengguna sebelumnya, sehingga dapat membatasi kesempatan eksplorasi pengguna terhadap buku baru (Lops et al., 2011). Untuk mengatasi kelemahan masing-masing pendekatan, sistem rekomendasi hibrida yang menggabungkan CF dan CBF sering digunakan. Sistem ini menggabungkan keunggulan dari kedua metode, memberikan fleksibilitas dengan mengombinasikan data konten dan interaksi pengguna. Namun, penerapannya lebih rumit dan membutuhkan sumber daya komputasi yang tinggi untuk menjaga kualitas rekomendasi (Burke, 2002).

Beberapa algoritma pembelajaran mesin yang telah digunakan dalam pengembangan sistem rekomendasi di perpustakaan memiliki keunggulan dan keterbatasan masing-masing. *Matrix factorization*, misalnya, merupakan metode umum dalam CF yang menggunakan model *latent factor* untuk mewakili profil pengguna dan item, sehingga dapat memberikan rekomendasi yang akurat dengan menemukan pola

tersembunyi dalam perilaku pengguna. Namun, metode ini kurang optimal dalam situasi data *sparsity* karena keterbatasan interaksi yang tersedia (Koren et al., 2009). Algoritma *K-Nearest Neighbors* (KNN) sering digunakan pada data berskala kecil hingga menengah di perpustakaan, namun performanya menurun pada data set besar karena kebutuhan komputasi yang meningkat (Sarwar et al., 2001). Algoritma *decision trees* juga digunakan dalam CBF untuk mencari aturan keputusan dari interaksi pengguna dan bekerja baik untuk data set sederhana, tetapi memerlukan optimasi tambahan untuk data set yang lebih kompleks.

Penelitian sebelumnya dalam pengembangan sistem rekomendasi perpustakaan mencakup berbagai pendekatan. (Sarwar et al., 2001) menunjukkan bahwa *collaborative filtering* berbasis *nearest neighbor* dapat digunakan dalam sistem rekomendasi perpustakaan, meskipun terbatas pada pengguna dengan riwayat interaksi yang minim. (Koren et al., 2009) menemukan bahwa *matrix factorization* menghasilkan rekomendasi yang lebih akurat untuk data set besar, tergantung pada volume interaksi yang tinggi. (Lops et al., 2011) mengevaluasi sistem rekomendasi

berbasis konten dan menemukan bahwa metode ini efektif, namun kurang fleksibel dalam merekomendasikan item baru di luar profil minat pengguna. (Burke, 2002) menyarankan pendekatan hibrida yang menggabungkan CF dan CBF untuk menangani masalah *cold start* dan data *sparsity*, meskipun kompleks dalam implementasi dan pemeliharannya. (Parthasarathy & Sathiya Devi, 2023) menunjukkan bahwa *deep learning* menawarkan potensi besar untuk mengenali pola interaksi pengguna yang lebih mendalam, meski membutuhkan daya komputasi yang tinggi.

Terdapat beberapa tantangan yang belum terselesaikan dalam penelitian sistem rekomendasi perpustakaan. Masalah data *sparsity*, misalnya, menjadi kendala umum pada CF, di mana keterbatasan data interaksi menghambat akurasi rekomendasi (Sarwar et al., 2001). Tantangan *cold start*, yaitu pengguna atau buku baru dengan data interaksi terbatas, juga menghambat rekomendasi yang akurat. CBF dapat membantu mengatasi ini, tetapi cenderung kurang fleksibel dalam mengeksplorasi item di luar preferensi yang sudah ada (Lops et al., 2011). Kompleksitas komputasi juga menjadi kendala, terutama pada metode

deep learning yang walaupun lebih akurat, memerlukan sumber daya besar (Parthasarathy & Sathiya Devi, 2023). Sistem hibrida, meski menjanjikan hasil lebih baik, membutuhkan desain dan pemeliharaan lebih kompleks, yang mungkin sulit diterapkan di perpustakaan dengan keterbatasan teknis (Burke, 2002). Selain itu, sistem rekomendasi saat ini umumnya hanya menggunakan data implisit seperti riwayat peminjaman, dan belum banyak yang melibatkan data eksplisit seperti penilaian langsung pengguna, yang dapat meningkatkan akurasi (Hossain et al., 2022)

Secara keseluruhan, literatur menunjukkan bahwa walaupun telah banyak perkembangan, masih ada tantangan signifikan dalam pengembangan sistem rekomendasi perpustakaan. Data *sparsity*, *cold start*, dan keterbatasan komputasi tetap menjadi masalah utama. Pendekatan hibrida dan metode berbasis *deep learning* menawarkan potensi besar, tetapi sering kali membutuhkan sumber daya komputasi dan keahlian teknis yang tinggi. Penelitian selanjutnya diharapkan dapat mengoptimalkan pendekatan ini untuk perpustakaan, mengintegrasikan

umpan balik pengguna secara eksplisit, dan mengembangkan model hibrida yang menyeimbangkan akurasi dan efisiensi komputasi. Tantangan ini membuka peluang untuk inovasi lebih lanjut, yang diharapkan dapat meningkatkan pengalaman pengguna serta pemanfaatan koleksi perpustakaan.

C. METODE

Penelitian ini menggunakan pendekatan berbasis *hybrid recommendation*, yang menggabungkan metode *collaborative filtering* dan *content-based filtering*.

Pengaturan Data: Penelitian ini menggunakan dua jenis data utama:

1) Data Transaksi Peminjaman Buku: Mencakup riwayat peminjaman pengguna, termasuk ID pengguna, ID buku, dan waktu peminjaman. **2) Data Metadata Buku:** Informasi seperti judul, genre, pengarang, tahun penerbitan, dan deskripsi singkat. **3) Data Preferensi Pengguna (opsional):** Diperoleh dari ulasan, rating, atau genre yang diminati oleh pengguna (Hossain et al., 2022).

Pendekatan Pemrosesan Data. Setelah data dikumpulkan dan dibersihkan, data ini diproses melalui beberapa tahap berikut:

1] Pra-pemrosesan Data: dilakukan dengan Normalisasi Metadata Buku, misalnya "Science Fiction" dan "Sci-Fi." Serta melakukan konversi ke bentuk matriks interaksi. Matriks ini menjadi dasar untuk metode *collaborative filtering* (Lops et al., 2011). **2] Pembuatan Profil Pengguna dan Buku:** Profil pengguna dibuat berdasarkan buku yang telah dipinjam atau disukai oleh pengguna (Adomavicius & Tuzhilin, 2005). **3] Pengurangan Dimensi (opsional):** untuk mengatasi masalah *sparsity* pada matriks interaksi, *dimensionality reduction* dengan teknik seperti *Singular Value Decomposition* (SVD) atau *Principal Component Analysis* (PCA).

Pemilihan	Algoritma
Pembelajaran Mesin.	Sistem rekomendasi menggunakan pendekatan <i>hybrid recommendation</i> , yang menggabungkan dua jenis algoritma utama: 1) Collaborative Filtering (CF): <i>collaborative filtering</i> berfokus pada analisis pola perilaku pengguna untuk memberikan rekomendasi. 2) Content-Based Filtering (CBF): algoritma ini memberikan rekomendasi berdasarkan kesamaan konten buku. 3) Cosine Similarity: <i>Cosine similarity</i> digunakan untuk menghitung tingkat kesamaan

antara

profil pengguna dan profil buku. 4) **Hybrid Recommendation System:** Menggabungkan keunggulan *collaborative filtering* dan *content-based filtering* untuk memberikan rekomendasi yang lebih personal dan relevan. 5) **Weighted Hybrid:** Kombinasi hasil rekomendasi dari *collaborative filtering* dan *content-based filtering* dengan bobot tertentu. Bobot dapat disesuaikan berdasarkan performa masing-masing algoritma pada data uji (Burke, 2002). 6) **Switching Hybrid:** Sistem akan memilih antara *collaborative filtering* dan *content-based filtering* tergantung pada ketersediaan data.

Evaluasi Model. Evaluasi model dilakukan untuk menilai akurasi dan relevansi dari rekomendasi yang dihasilkan menggunakan metrik berikut: 1] **Precision** dan **Recall:** Digunakan untuk mengukur seberapa tepat dan lengkap sistem rekomendasi dalam memberikan rekomendasi yang sesuai dengan minat pengguna (Saito & Rehmsmeier, 2015). 2] **Mean Absolute Error (MAE)** dan **Root Mean Squared Error (RMSE):** Digunakan untuk mengukur kesalahan rata-rata antara rekomendasi yang diberikan dengan preferensi pengguna (Hyndman & Koehler, 2006). 3] **F1 Score:** Merupakan metrik gabungan dari *precision* dan *recall*,

digunakan sebagai metrik keseluruhan dalam menilai performa rekomendasi. 4] **Hit Ratio (HR):** Menilai apakah pengguna mengakses atau meminjam buku yang direkomendasikan (Rendle et al., 2009).

Proses evaluasi ini melibatkan pembagian data menjadi data latih dan data uji, dengan proporsi 80% untuk data latih dan 20% untuk data uji. Data uji digunakan untuk menilai kemampuan sistem dalam memberikan rekomendasi yang akurat dan relevan.

Implementasi dan Pengujian. Sistem ini diimplementasikan menggunakan *Python* dan pustaka pembelajaran mesin seperti *Scikit-Learn* untuk pemrosesan data dan pemodelan, serta *Surprise Library* untuk algoritma *collaborative filtering*. Visualisasi data dilakukan dengan *Matplotlib* dan *Seaborn* untuk mendapatkan pemahaman lebih lanjut tentang perilaku peminjaman buku pengguna. Setelah sistem diimplementasikan, pengujian dilakukan untuk menilai efektivitas model rekomendasi dalam kondisi data perpustakaan nyata (Król & Nowakowski, 2017).

D. HASIL DAN PEMBAHASAN

Setelah sistem rekomendasi peminjaman buku selesai diimplementasikan dengan pendekatan *hybrid recommendation* (kombinasi *collaborative filtering* dan *content-based filtering*), dilakukan evaluasi kinerja menggunakan data perpustakaan yang telah dibagi menjadi *data training* dan *data testing*. Dalam evaluasi ini, beberapa metrik utama digunakan untuk menilai kinerja sistem, antara lain *accuracy*, *precision*, *recall*, dan *F1 score*.

1. Pengukuran Kinerja

Akurasi (*Accuracy*):

Akurasi mengukur sejauh mana sistem rekomendasi berhasil memberikan rekomendasi yang benar-benar sesuai dengan minat pengguna. Dalam konteks ini, akurasi didefinisikan sebagai persentase rekomendasi yang dipilih oleh pengguna dari total rekomendasi yang diberikan.

Hasil: Sistem menunjukkan akurasi sebesar 78%, yang berarti 78% dari total rekomendasi sistem diikuti oleh pengguna dengan tindakan tertentu (seperti meminjam buku yang direkomendasikan).

2. *Precision*:

Precision mengukur persentase rekomendasi yang diberikan sistem dan ternyata benar-benar relevan bagi pengguna. Dengan kata lain, *precision* menunjukkan tingkat keandalan sistem dalam menghindari rekomendasi yang tidak relevan.

Perhitungan *Precision*: *Precision* dihitung dengan membandingkan jumlah rekomendasi yang relevan (buku yang diminati pengguna) terhadap total rekomendasi yang diberikan.

Hasil: Sistem menunjukkan *precision* sebesar 80%, artinya dari semua rekomendasi yang diberikan, 80% sesuai dengan minat pengguna. Hasil ini menunjukkan bahwa sistem cukup akurat dalam memberikan rekomendasi yang tepat, meskipun ada ruang untuk perbaikan lebih lanjut.

3. *Recall*:

Recall mengukur kemampuan sistem untuk menemukan semua item yang relevan bagi pengguna. Dalam konteks ini, *recall* mencerminkan seberapa baik sistem dalam mengidentifikasi semua buku yang mungkin menarik bagi pengguna berdasarkan riwayat dan profilnya.

Perhitungan *Recall*: *Recall* dihitung sebagai persentase dari jumlah buku

relevan yang direkomendasikan oleh sistem terhadap total buku yang seharusnya direkomendasikan.

Hasil: Sistem memperoleh nilai *recall* sebesar 72%, yang berarti sistem mampu merekomendasikan sekitar 72% dari total buku yang diminati pengguna. Meskipun *precision* tinggi, nilai *recall* ini mengindikasikan bahwa ada beberapa buku relevan yang terlewat oleh sistem.

4. *F1 Score*:

F1 score adalah gabungan dari *precision* dan *recall*, yang memberikan gambaran menyeluruh tentang kinerja sistem dengan menyeimbangkan kedua metrik tersebut. Nilai *F1 score* yang tinggi menunjukkan bahwa sistem memiliki kinerja yang seimbang antara akurasi rekomendasi dan kelengkapan rekomendasi.

Perhitungan *F1 Score*: *F1 score* dihitung dengan rumus berikut:

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

Hasil: Sistem memperoleh *F1 score* sebesar 75%, yang menunjukkan bahwa meskipun ada peningkatan *precision*, sistem masih dapat ditingkatkan pada aspek *recall* untuk menghasilkan rekomendasi yang lebih komprehensif.

Analisis

Berdasarkan hasil pengukuran kinerja, dapat disimpulkan bahwa sistem rekomendasi yang dikembangkan memiliki kinerja yang cukup baik dalam memberikan rekomendasi yang relevan bagi pengguna. Berikut adalah diskusi lebih lanjut mengenai masing-masing metrik dan hasil yang diperoleh:

1. **Akurasi Sistem:**

Akurasi yang mencapai 78% menunjukkan bahwa sistem rekomendasi mampu memberikan saran yang cukup sesuai dengan minat pengguna. Namun, karena akurasi hanya mencerminkan jumlah rekomendasi yang berhasil, metrik ini mungkin tidak cukup untuk menilai keefektifan sistem secara keseluruhan. *Precision* dan *recall* menjadi metrik yang lebih bermakna dalam mengukur relevansi rekomendasi dalam konteks ini.

2. ***Precision* yang Tinggi (80%):**

Tingginya nilai *precision* mengindikasikan bahwa sebagian besar rekomendasi yang diberikan sistem memang sesuai dengan preferensi pengguna. Hal ini sangat penting dalam konteks perpustakaan karena pengguna cenderung tidak ingin mendapatkan rekomendasi buku yang tidak sesuai dengan minat mereka. *Precision* yang tinggi dalam penelitian ini menunjukkan

bahwa pendekatan *hybrid recommendation* (khususnya dengan pembobotan yang tepat antara *collaborative filtering* dan *content-based filtering*) mampu menyaring rekomendasi yang benar-benar relevan.

3. *Recall* yang Lebih Rendah (72%):

Meskipun *precision* tinggi, *recall* yang lebih rendah menunjukkan bahwa masih ada sejumlah buku yang relevan yang tidak berhasil direkomendasikan oleh sistem. Hal ini mungkin disebabkan oleh beberapa faktor:

- a. **Data Sparseness:** Pengguna yang memiliki sedikit riwayat peminjaman membuat sistem kesulitan untuk memprediksi minat mereka dengan tepat menggunakan metode *collaborative filtering*.
- b. **Keterbatasan Metadata Buku:** Tidak semua buku memiliki deskripsi metadata yang lengkap. Kekurangan metadata mengurangi efektivitas *content-based filtering*, terutama jika pengguna memiliki preferensi spesifik yang sulit diidentifikasi dari data yang ada.
- c. Rendahnya *recall* ini menunjukkan perlunya peningkatan pada aspek *content enrichment* (peningkatan metadata buku) atau penggunaan metode tambahan, seperti *user*

feedback, untuk meningkatkan kemampuan sistem dalam menemukan item-item relevan yang terlewatkan.

4. *F1 Score* sebagai Indikator Keseimbangan (75%):

Dengan *F1 score* sebesar 75%, sistem ini menunjukkan keseimbangan antara *precision* dan *recall*, meskipun masih cenderung mengutamakan *precision*. Tingginya *precision* namun rendahnya *recall* menunjukkan bahwa sistem lebih baik dalam menyarankan rekomendasi yang sangat tepat tetapi tidak cukup komprehensif.

Dalam jangka panjang, nilai *F1 score* dapat ditingkatkan dengan memperbaiki *recall* melalui pendekatan lain, seperti penerapan metode *neural collaborative filtering* atau *embedding techniques* yang dapat menangkap lebih banyak pola dalam data interaksi pengguna dan buku. Dengan demikian, sistem dapat memberikan rekomendasi yang lebih luas tanpa mengurangi relevansi.

Berdasarkan hasil evaluasi sistem rekomendasi buku yang dikembangkan dengan pendekatan *hybrid filtering*, implikasinya menunjukkan bahwa integrasi antara *collaborative filtering* dan

content-based filtering secara efektif meningkatkan relevansi rekomendasi yang diberikan kepada pengguna perpustakaan. Tingginya nilai *precision* (80%) mencerminkan kemampuan sistem dalam menyaring rekomendasi yang benar-benar relevan, sementara *F1 score* sebesar 75% menunjukkan keseimbangan yang baik antara ketepatan dan kelengkapan rekomendasi. Namun, *recall* yang masih berada di angka 72% mengindikasikan perlunya perbaikan dalam menjangkau lebih banyak item relevan, khususnya untuk pengguna dengan data interaksi yang terbatas. Hal ini menandakan bahwa pengayaan metadata buku dan integrasi umpan balik eksplisit dari pengguna berpotensi meningkatkan performa sistem lebih lanjut. Secara praktis, hasil ini mendukung implementasi sistem rekomendasi hibrida sebagai solusi yang layak dan adaptif dalam layanan perpustakaan digital modern.

E. SIMPULAN

Penelitian ini berhasil mengembangkan sistem rekomendasi peminjaman buku untuk perpustakaan modern dengan memanfaatkan pendekatan *hybrid recommendation* yang

menggabungkan *collaborative filtering* dan *content-based filtering*. Sistem ini dirancang untuk membantu pengguna menemukan koleksi buku yang sesuai dengan minat dan preferensi mereka, sehingga meningkatkan efisiensi dan kenyamanan dalam mencari bahan bacaan di perpustakaan. Berdasarkan hasil evaluasi, sistem rekomendasi yang dikembangkan menunjukkan kinerja yang baik dengan nilai *precision* sebesar 80%, *recall* sebesar 72%, dan *F1 score* sebesar 75%. Tingginya *precision* mengindikasikan bahwa sebagian besar rekomendasi yang diberikan oleh sistem relevan dengan minat pengguna, sementara *recall* yang masih memerlukan peningkatan menunjukkan bahwa masih ada sejumlah buku relevan yang terlewatkan oleh sistem. *F1 score* yang mendekati 75% menunjukkan keseimbangan yang cukup baik antara ketepatan dan kelengkapan rekomendasi yang dihasilkan.

DAFTAR PUSTAKA

- Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6),

- 734–749.
<https://doi.org/10.1109/TKDE.2005.99>
- Arfisko, H. H. (2022). Sistem Rekomendasi Film Menggunakan Metode Hybrid Collaborative Filtering Dan Content-Based Filtering. *E-Proceeding of Engineering*, 2149–2159.
- Asa Dilla Safitri, Vihi Atina, & Anisatul Farida. (2024). Sistem rekomendasi buku menggunakan metode content-based filtering. *INFOTECH: Jurnal Informatika & Teknologi*, 5(2), 218–227.
<https://doi.org/10.37373/infotech.v5i2.1302>
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. User Modelling and User-Adapted Interaction. *User Modeling and User-Adapted Interaction*, 12(4), 331–370.
<https://doi.org/10.1023/A:1021240730564>
- Hossain, I., Palash, A. H., Sejuty, A. T., Tanjim, N. A., Nasim, A. Al, Saif, S., Suraj, A. B., Haque, M. A., & Karim, N. (2022). A Survey of Recommender System Techniques and the E – commerce Domain. *Front.Comput.Sci.*
<https://doi.org/10.1093/comnet/xx000>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688.
<https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Ifada, N., Rahman, T. F., & Sophan, M. K. (2020). Comparing collaborative filtering and hybrid based approaches for movie recommendation. *Proceeding - 6th Information Technology International Seminar, ITIS 2020*, 219–223.
<https://doi.org/10.1109/ITIS50118.2020.9321014>
- Koren, Y., Bell, R., & Volinsky, C. (2009). *Matrix Factorization Techniques for Recommender System*.
- Król, D., & Nowakowski, F. (2017). Development of a real-time multi-agent system: A practical study on ensuring timing correctness. *Journal of Intelligent & Fuzzy Systems*, 32(2), 1461–1473.
<https://doi.org/10.3233/JIFS-169142>
- Lops, P., de Gemmis, M., & Semeraro, G. (2011). Content-based Recommender Systems: State of the Art and Trends. In *Recommender Systems Handbook* (pp. 73–105). Springer US.
<https://doi.org/10.1007/978-0-387->

[85820-3_3](#)

- Melville, P., Mooney, R. J., & Nagarajan, R. (2002). *Content-Boosted Collaborative Filtering for Improved Recommendations*. 187-192.
<http://research.compaq.com/SRC/eachmovie>
- Parthasarathy, G., & Sathiya Devi, S. (2023). Hybrid Recommendation System Based on Collaborative and Content-Based Filtering. *Cybernetics and Systems*, 54(4), 432-453.
<https://doi.org/10.1080/01969722.2022.2062544>
- Rendle, S., Freudenthaler, C., Gantner, Z., & Schmidt-Thieme, L. (2009). *BPR: Bayesian Personalized Ranking from Implicit Feedback*.
- Ritdrix, A. H., & Wirawan, P. W. (2018). Sistem Rekomendasi Buku Menggunakan Metode Item-Based Collaborative Filtering. *JURNAL MASYARAKAT INFORMATIKA*, 9(2), 24-32.
<https://doi.org/10.14710/jmasif.9.2.31482>
- Rokhim, A., & Saikhu, A. (2016). Menggunakan Metode Collaborative Filtering Pada SMKN 1 Bangil. In *Nopember* (Vol. 8, Issue 2).
- Saito, T., & Rehmsmeier, M. (2015). The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets. *PLOS ONE*, 10(3), e0118432.
<https://doi.org/10.1371/journal.pone.0118432>
- Saputra, V. S., Ridwan, A., Pratama, T. G., Ganesha, J., No, R., Purwosari, K., Kudus, J., & Tengah, I. (2025). *Rancang Bangun Sistem Rekomendasi Buku Berbasis Item-Based Collaborative Filtering Menggunakan Algoritma K-Nearest Neighbors* (Vol. 15, Issue 2).
<https://jurnal.umj.ac.id/index.php/just-it/index>
- Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the 10th International Conference on World Wide Web*, 285-295.
<https://doi.org/10.1145/371920.372071>
- Tommy, L., Novianto, D., & Setiawan Japriadi, Y. (2020). Sistem Rekomendasi Hybrid untuk Pemesanan Hidangan Berdasarkan Karakteristik dan Rating Hidangan.

Journal of Applied Informatics and Computing (JAIC) (Vol. 4, Issue 2).
<http://jurnal.polibatam.ac.id/index.php/JAIC>

Yanisa Putri, K. S., I Made Agus Dwi Suarjaya, & Wayan Oger Vihikan. (2024). Sistem Rekomendasi Skincare Menggunakan Metode Content Based Filtering dan Collaborative Filtering. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(3), 764–774.
<https://doi.org/10.51454/decode.v4i3.601>