

Implementasi Sistem Rekomendasi Film Berbasis Collaborative Filtering: Studi Kasus MovieLens

Fakhrusy Syuyukh¹, Galih Wasis Wicaksono^{2*}, Ilyas Nuryasin³

^{1,2,3} Informatics, Engineering Faculty, Universitas Muhammadiyah Malang, Indonesia

Email: fakhrusy syuyukh@webmail.umm.ac.id¹, galih.w.w@umm.ac.id², ilyas@umm.ac.id³

Abstract

Movie recommendation systems often face challenges such as data sparsity and cold-start. This study compares three Collaborative Filtering (CF) approaches: User-Based, Item-Based, and Singular Value Decomposition (SVD) on the MovieLens dataset. Evaluation is performed using RMSE, MAE, Precision@10, and Recall@10 metrics. The results show that SVD with $n_factors = 50$ provides the best accuracy (RMSE 0.8695; MAE 0.6682), while Item-Based with $k = 10$ excels in recommendation relevance (Precision@10 0.5510; Recall@10 0.6267). This study provides a reference in selecting a recommendation algorithm based on the context of system needs.

Keywords: Collaborative Filtering, Movie Recommendation System, Singular Value Decomposition, MovieLens Dataset, K-Nearest Neighbors.

Abstrak

Sistem rekomendasi film sering menghadapi tantangan seperti data sparsity dan cold-start. Penelitian ini membandingkan tiga pendekatan Collaborative Filtering (CF): User-Based, Item-Based, dan Singular Value Decomposition (SVD) pada dataset MovieLens. Evaluasi dilakukan menggunakan metrik RMSE, MAE, Precision@10, dan Recall@10. Hasil menunjukkan bahwa SVD dengan $n_factors = 50$ memberikan akurasi terbaik (RMSE 0,8695; MAE 0,6682), sedangkan Item-Based dengan $k = 10$ unggul dalam relevansi rekomendasi (Precision@10 0,5510; Recall@10 0,6267). Penelitian ini memberikan acuan dalam pemilihan algoritma rekomendasi berdasarkan konteks kebutuhan sistem.

Kata kunci: Collaborative Filtering, Sistem Rekomendasi Film, Singular Value Decomposition, MovieLens Dataset, K-Nearest Neighbors.

1. PENDAHULUAN

Perkembangan teknologi digital telah merevolusi cara masyarakat mengakses hiburan, terutama melalui platform streaming seperti Netflix dan Amazon Prime. Perpustakaan konten yang terus berkembang menghadirkan kemudahan sekaligus tantangan: banyaknya pilihan justru memicu fenomena *information overload*, yang membuat pengguna kesulitan dalam menemukan konten yang benar-benar sesuai dengan preferensi mereka.

Dalam konteks ini, sistem rekomendasi menjadi salah satu solusi teknologi paling krusial untuk mengatasi tantangan tersebut. Sistem ini berfungsi dengan menyaring informasi berdasarkan preferensi pengguna, sehingga dapat meningkatkan kepuasan, keterlibatan, dan retensi pengguna melalui penyajian konten yang personal dan relevan [1], [2], [3]. Di antara berbagai pendekatan yang telah dikembangkan, Collaborative Filtering (CF) merupakan salah satu teknik paling populer dan banyak digunakan. CF bekerja dengan menganalisis pola interaksi pengguna di masa lalu untuk memprediksi item yang mungkin disukai di masa depan.

CF menunjukkan performa yang baik dalam mengatasi tantangan-tantangan umum seperti *data sparsity* dan *cold-start*, serta telah terbukti efektif dalam

berbagai domain aplikasi. Salah satu benchmark yang banyak digunakan dalam penelitian sistem rekomendasi adalah dataset MovieLens, yang menawarkan data interaksi pengguna yang kaya dan terstruktur dengan baik [4], [5]. Dataset ini sangat mendukung eksplorasi beragam teknik CF, termasuk pendekatan berbasis tetangga seperti User-Based dan Item-Based CF, serta pendekatan berbasis dekomposisi matriks seperti Singular Value Decomposition (SVD), yang telah terbukti meningkatkan akurasi sistem rekomendasi [6], [7], [8].

Penelitian terdahulu menunjukkan adanya tren integrasi pendekatan CF dengan metode lain guna memperkuat kualitas rekomendasi. Misalnya, Zhang et al. menggabungkan CF dengan Content-Based Filtering untuk mengatasi kendala cold-start, sementara Herlocker et al. [10] menyusun kerangka evaluasi sistem rekomendasi yang komprehensif. Bobadilla et al. [11] menyarankan penggunaan pendekatan model-based seperti SVD sebagai solusi yang scalable untuk dataset berskala besar.

Selain pendekatan tradisional, CF kini juga telah dikombinasikan dengan teknik kecerdasan buatan yang lebih maju. Wu et al. [12] mengembangkan DeepCF berbasis arsitektur neural network, Sun et al. [13] memanfaatkan Graph Convolutional Networks (GCN), dan Wang et al. [14] mengintegrasikan representasi konten melalui pendekatan Collaborative Deep Learning (CDL). Di sisi lain, Zhao et al. [15] mengeksplorasi pendekatan Reinforcement Learning (RL) untuk menangkap dinamika preferensi pengguna yang berubah seiring waktu, sementara Beel et al. [16] meneliti penerapan CF lintas domain, seperti dalam literatur ilmiah, yang membuka peluang baru dalam adaptasi sistem rekomendasi untuk berbagai konteks.

Meskipun banyak pendekatan baru terus bermunculan, CF tetap menjadi fondasi utama dari sistem rekomendasi modern karena kematangan konsep, fleksibilitas, dan efektivitasnya. Oleh karena itu, penting dilakukan evaluasi komprehensif terhadap performa berbagai algoritma CF dalam konteks dataset standar seperti MovieLens untuk mengidentifikasi pendekatan yang paling efektif dan efisien.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi tiga pendekatan utama Collaborative Filtering—yaitu User-Based CF, Item-Based CF, dan SVD—pada dataset MovieLens. Tujuan akhirnya adalah untuk mengidentifikasi pendekatan yang paling optimal dalam menghasilkan rekomendasi film yang akurat dan personal. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan sistem rekomendasi yang adaptif dan efisien, serta menjadi panduan praktis bagi peneliti dan pengembang dalam merancang sistem rekomendasi yang unggul.

2. METODOLOGI PENELITIAN

Implementasi sistem rekomendasi film berbasis Collaborative Filtering dengan dataset MovieLens mengikuti alur sistematis yang terdiri dari persiapan data, eksplorasi data, implementasi model, evaluasi performa, dan optimasi parameter [17]. Tahapan ini memastikan sistem rekomendasi berjalan optimal dan memberikan hasil yang relevan bagi pengguna.

Data yang digunakan dalam penelitian ini diperoleh dari dataset MovieLens, yang telah menjadi standar dalam penelitian sistem rekomendasi film [18], [19]. Dataset ini menyediakan informasi rating yang diberikan oleh pengguna terhadap berbagai film, serta metadata seperti genre dan judul film. Proses pra-pemrosesan data dimulai dengan memuat data melalui fungsi `load_movielens_data()` yang membaca file `ratings.csv` dan `movies.csv`. Data rating kemudian dipersiapkan untuk library Surprise dengan membuat objek Reader yang mendefinisikan skala rating (0.5-5) dan membagi dataset menjadi training set (80%) dan test set (20%) menggunakan fungsi `train_test_split()` dengan `random_state=40` untuk memastikan reproduksibilitas hasil.

Tabel 1. Kerangka

Nama File	Deskripsi	Fungsi Pemrosesan	Informasi yang Terkandung
<code>ratings.csv</code>	File yang berisi data rating pengguna terhadap film	<code>load_movielens_data()</code>	Rating yang diberikan pengguna terhadap berbagai film
<code>movies.csv</code>	File yang berisi informasi metadata film	<code>load_movielens_data()</code>	Metadata film seperti genre dan judul film

Langkah-langkah pra-pemrosesan ini bertujuan untuk meningkatkan kualitas data sebelum diterapkan dalam model rekomendasi, sekaligus mengatasi tantangan umum dalam Collaborative Filtering [3], [20]. Dalam penelitian ini, kami mengimplementasikan dan membandingkan tiga pendekatan utama Collaborative Filtering. Pertama adalah K-Nearest Neighbors (KNN) yang merupakan algoritma berbasis instance yang digunakan dalam sistem rekomendasi dengan cara mencari sekumpulan objek atau item yang paling mirip berdasarkan metrik kesamaan tertentu, seperti cosine similarity atau Pearson correlation [21]. KNN dapat diterapkan dalam dua pendekatan: User-Based Collaborative Filtering yang mencari pengguna dengan pola rating serupa, dan Item-Based Collaborative Filtering yang membandingkan kesamaan antar-item. Implementasi KNN dilakukan menggunakan library Surprise dengan parameter utama berupa nilai k (10, 20, 30, 40, dan 50), metrik cosine similarity, dan konfigurasi `user_based` untuk menentukan pendekatan yang digunakan.

Kedua adalah Singular Value Decomposition (SVD), teknik matrix factorization yang digunakan untuk mengurangi dimensi data guna meningkatkan akurasi rekomendasi. Implementasi SVD menggunakan library Surprise dengan parameter `n_factors` (jumlah faktor laten) yang diuji dengan nilai 20, 50, 100, 150, dan 200, serta `n_epochs=20` untuk menentukan jumlah iterasi pelatihan [22]. Untuk mengevaluasi performa algoritma CF, kami menggunakan empat metrik standar [21]. RMSE (Root Mean Square Error) mengukur rata-rata akar kuadrat dari selisih antara rating prediksi dan rating sebenarnya, memberikan penalti lebih besar pada kesalahan yang besar. MAE (Mean Absolute Error) mengukur rata-rata absolut dari selisih antara rating prediksi dan rating sebenarnya. Precision@10 menghitung proporsi item yang relevan ($\text{rating} \geq 4.0$) dari 10 rekomendasi teratas,

sedangkan Recall@10 mengukur proporsi item relevan yang berhasil direkomendasikan dari seluruh item relevan.

Eksperimen dilakukan dengan variasi parameter untuk ketiga algoritma: User-Based CF dan Item-Based CF dengan nilai $k = 10, 20, 30, 40, 50$, serta SVD dengan nilai $n_factors = 20, 50, 100, 150, 200$. Untuk setiap konfigurasi, model dilatih menggunakan training set dan dievaluasi pada test set dengan menghitung metrik RMSE, MAE, Precision@10, dan Recall@10 untuk perbandingan performa model.

- RMSE (Root Mean Square Error): Mengukur rata-rata akar kuadrat dari selisih antara rating prediksi dan rating sebenarnya, memberikan penalti lebih besar pada kesalahan yang besar.
- MAE (Mean Absolute Error): Mengukur rata-rata absolut dari selisih antara rating prediksi dan rating sebenarnya.
- Precision@10: Proporsi item yang relevan ($\text{rating} \geq 4.0$) dari 10 rekomendasi teratas.
- Recall@10: Proporsi item relevan yang berhasil direkomendasikan dari seluruh item relevan.

3. HASIL DAN PEMBAHASAN

Implementasi sistem rekomendasi film berbasis Collaborative Filtering menggunakan dataset MovieLens telah menghasilkan sejumlah temuan penting. Dataset MovieLens yang digunakan memiliki karakteristik dengan 610 pengguna, 9.742 film, 100.836 rating, dan densitas rating 1,70% yang menunjukkan sparse matrix yang umum dalam sistem rekomendasi. Distribusi rating menunjukkan kecenderungan pengguna untuk memberikan rating positif dengan mayoritas rating berada pada nilai 3,5 hingga 4,0, mengindikasikan bias positif yang umum ditemukan dalam sistem penilaian publik. Analisis aktivitas pengguna menunjukkan variasi signifikan, dengan sebagian besar pengguna memberikan rating untuk 20-150 film, sementara terdapat sejumlah kecil pengguna aktif yang memberikan rating untuk lebih dari 500 film. Evaluasi ketiga pendekatan CF dilakukan menggunakan metrik RMSE, MAE, Precision@10, dan Recall@10 dengan hasil yang ditampilkan pada Tabel 2 berikut:

Tabel 2. Perbandingan Performa Algoritma Collaborative Filterings

Algoritma	Parameter	RMSE	MAE	Precision @10	Recall@10	Waktu Pelatihan (s)
User-Based CF	$k=10$	0.9858	0.7581	0.6381	0.6732	1.98
User-Based CF	$k=20$	0.9747	0.7508	0.6435	0.6771	1.96
User-Based CF	$k=30$	0.9722	0.7493	0.6425	0.6774	2.08
User-Based CF	$k=40$	0.9726	0.7508	0.6425	0.6762	2.19
User-Based CF	$k=50$	0.9734	0.7519	0.6433	0.6766	2.30
Item-Based CF	$k=10$	1.0214	0.7965	0.5510	0.6267	27.87
Item-Based CF	$k=20$	0.9937	0.7748	0.5595	0.6353	18.39
Item-Based CF	$k=30$	0.9853	0.7683	0.5628	0.6351	17.55
Item-Based CF	$k=40$	0.9787	0.7626	0.5723	0.6399	19.05
Item-Based CF	$k=50$	0.9732	0.7580	0.5722	0.6367	21.99
SVD	$n_factors=20$	0.8701	0.6692	0.6456	0.6766	1.04

Algoritma	Parameter	RMSE	MAE	Precision @10	Recall@10	Waktu Pelatihan (s)
SVD	n_factors=50	0.8695	0.6682	0.6469	0.6771	1.21
SVD	n_factors=100	0.8750	0.6725	0.6453	0.6763	1.45
SVD	n_factors=150	0.8754	0.6728	0.6405	0.6731	1.80
SVD	n_factors=200	0.8784	0.6748	0.6466	0.6767	1.76

Penelitian ini telah mengimplementasikan dan mengevaluasi tiga pendekatan utama dalam Collaborative Filtering (CF) untuk sistem rekomendasi film, yaitu User-Based Collaborative Filtering, Item-Based Collaborative Filtering, dan algoritma Singular Value Decomposition (SVD), dengan menggunakan dataset MovieLens sebagai studi kasus. Ketiga pendekatan tersebut dianalisis secara komprehensif berdasarkan metrik evaluasi yang mencakup akurasi prediksi—dengan Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE)—serta metrik evaluasi relevansi seperti Precision@10 dan Recall@10. Hasil penelitian menunjukkan bahwa metode SVD secara konsisten memberikan performa yang lebih unggul dibandingkan dengan pendekatan User-Based dan Item-Based CF.

Secara khusus, algoritma SVD dengan jumlah faktor laten (n_factors) sebesar 50 menunjukkan performa terbaik dalam hal akurasi, dengan nilai RMSE mencapai 0,8695 dan MAE sebesar 0,6682. Selain itu, SVD juga mencatat nilai Precision@10 tertinggi sebesar 0,6469, yang menunjukkan bahwa mayoritas rekomendasi yang diberikan berada di antara item yang benar-benar disukai oleh pengguna. Meskipun demikian, nilai Recall@10 tertinggi dicapai oleh pendekatan User-Based CF dengan parameter $k = 30$, yang berarti pendekatan ini lebih berhasil dalam menjangkau lebih banyak item relevan dalam daftar rekomendasi. Namun, hal ini tidak serta-merta menjadikannya metode yang paling efektif secara keseluruhan, karena trade-off antara precision dan recall perlu dipertimbangkan dalam konteks aplikasi nyata.

Dari perspektif efisiensi komputasi, SVD terbukti lebih unggul dalam proses pelatihan dibandingkan algoritma K-Nearest Neighbors (KNN) yang digunakan pada pendekatan User-Based dan Item-Based CF. Waktu pelatihan yang lebih singkat serta skalabilitas yang lebih baik menjadikan SVD sebagai pilihan yang lebih praktis dan efisien untuk diimplementasikan dalam sistem rekomendasi berskala besar. Penelitian ini juga menekankan pentingnya proses tuning parameter, karena peningkatan nilai parameter seperti jumlah tetangga (k) atau jumlah faktor laten (n_factors) tidak selalu berbanding lurus dengan peningkatan performa model. Oleh karena itu, diperlukan pendekatan eksperimental dan validasi silang yang cermat untuk menemukan konfigurasi parameter yang optimal.

Lebih lanjut, analisis konten dari hasil rekomendasi menunjukkan bahwa model SVD mampu memahami pola preferensi pengguna dengan lebih baik. Hal ini ditunjukkan dengan kemampuannya dalam menghasilkan daftar rekomendasi yang tidak hanya relevan, tetapi juga beragam dan tidak monoton. Dengan kemampuannya untuk menangkap representasi laten dari interaksi pengguna-item, SVD berpotensi untuk memberikan pengalaman pengguna yang lebih personal dan memuaskan.

Secara keseluruhan, penelitian ini menyimpulkan bahwa algoritma SVD merupakan pendekatan Collaborative Filtering yang paling unggul baik dari segi akurasi, efisiensi, maupun kualitas rekomendasi. Untuk pengembangan di masa depan, disarankan integrasi pendekatan hybrid yang menggabungkan Collaborative Filtering dengan Content-Based Filtering, guna mengatasi permasalahan klasik seperti cold-start dan sparsity. Pendekatan hybrid ini diharapkan mampu meningkatkan performa sistem secara keseluruhan dengan memanfaatkan informasi tambahan seperti metadata film, genre, atau profil pengguna.

Tabel 3. Rekomendasi Film untuk Pengguna ID 1

Judul Film	Genre	Rating Estimasi
Monty Python and the Holy Grail (1975)	Adventure Comedy Fantasy	5.0
Hours, The (2002)	Drama Romance	5.0
Monty Python and the Holy Grail (1975)	Crime Drama Thriller	4.98
Shawshank Redemption, The (1994)	Crime Drama	4.98
Rosemary's Baby (1968)	Drama Horror Thriller	4.97
Monty Python's The Meaning of Life (1983)	comedy	4.94
Inside Job (2010)	Documentary	4.93
Lost in Translation (2003)	Comedy Drama Romance	4.93
Rear Window (1954)	Mystery Thriller	4.92
Eternal Sunshine of the Spotless Mind (2004)	Drama Romance Sci-Fi	4.92

Tabel 3 menyajikan hasil rekomendasi sepuluh film teratas untuk pengguna ID 1, yang dihasilkan oleh model SVD berdasarkan prediksi rating tertinggi. Hasil menunjukkan bahwa sistem mampu mengidentifikasi film-film yang belum ditonton namun diprediksi sangat relevan, dengan nilai estimasi berkisar antara 4,92 hingga 5,0. Film seperti *Monty Python and the Holy Grail (1975)* dan *The Hours (2002)* memperoleh estimasi skor sempurna, menandakan potensi kesesuaian yang tinggi terhadap preferensi pengguna.

Dominasi genre Drama, baik sebagai genre utama maupun campuran, mengindikasikan kecenderungan minat pengguna terhadap narasi emosional dan karakterisasi mendalam. Di sisi lain, keberagaman genre seperti Comedy, Thriller, Romance, dan Documentary menunjukkan bahwa sistem juga mempertimbangkan aspek diversitas dalam rekomendasi, tidak hanya fokus pada genre dominan.

Rekomendasi yang mencakup film klasik dan kontemporer menunjukkan kapabilitas model dalam mengenali kualitas sinematik lintas waktu. Kemampuan SVD dalam menangkap preferensi laten pengguna terbukti efektif dalam menghasilkan rekomendasi yang relevan, personal, dan beragam. Hal ini memperkuat temuan sebelumnya bahwa pendekatan ini unggul dalam hal akurasi sekaligus pengalaman pengguna yang lebih personal.

4. SIMPULAN

Penelitian ini telah mengimplementasikan dan mengevaluasi tiga pendekatan utama Collaborative Filtering User-Based CF, Item-Based CF, dan SVD untuk sistem rekomendasi film menggunakan dataset MovieLens. Penelitian ini menunjukkan bahwa algoritma Singular Value Decomposition (SVD) secara konsisten mengungguli pendekatan User-Based dan Item-Based Collaborative Filtering (CF), baik dari segi akurasi prediksi (RMSE dan MAE) maupun efisiensi komputasi. SVD dengan $n_factors = 50$ memberikan performa terbaik (RMSE 0,8695; MAE 0,6682), serta *Precision@10* tertinggi (0,6469), meskipun *Recall@10* tertinggi dicapai oleh User-Based CF dengan $k = 30$.

Dari sisi efisiensi, SVD juga lebih cepat dalam proses pelatihan dibandingkan pendekatan KNN, menjadikannya pilihan optimal dalam implementasi sistem rekomendasi. Penentuan parameter optimal terbukti penting, karena peningkatan nilai parameter tidak selalu meningkatkan performa. Analisis konten rekomendasi mengindikasikan bahwa SVD mampu menangkap preferensi pengguna dan menghasilkan rekomendasi yang relevan serta beragam. Secara keseluruhan, SVD merupakan pendekatan CF yang unggul dan efisien untuk sistem rekomendasi film. Ke depan, integrasi pendekatan hybrid dengan Content-Based Filtering disarankan untuk mengatasi masalah cold-start dan meningkatkan personalisasi.

DAFTAR PUSTAKA

- [1] P. Meel, F. Bano, A. Goswami, and S. Gupta, "Movie Recommendation Using Content-Based and Collaborative Filtering," pp. 301–316, 2020, doi: 10.1007/978-981-15-5113-0_22.
- [2] M. S. A. N. Goyal, "Collaborative Filtering Movie Recommendation System," *Int. J. Mod. Trends Sci. Technol.*, Jan. 2021, doi: 10.46501/ijmtst061291.
- [3] U. Thakker, R. Patel, and M. Shah, "A comprehensive analysis on movie recommendation system employing collaborative filtering," *Multimed. Tools Appl.*, vol. 80, pp. 28647–28672, Jun. 2021, doi: 10.1007/s11042-021-10965-2.
- [4] S. Peng, S. Siet, S. Ilkhomjon, D.-Y. Kim, and D.-S. Park, "Integration of Deep Reinforcement Learning with Collaborative Filtering for Movie Recommendation Systems," *Appl. Sci.*, Jan. 2024, doi: 10.3390/app14031155.
- [5] Y. Mu and Y. Wu, "Multimodal Movie Recommendation System Using Deep Learning," *Mathematics*, Feb. 2023, doi: 10.3390/math11040895.
- [6] V. Subramaniyaswamy, L. Ravi, M. Chandrashekhar, A. Challa, and V. Varadharajan, "A personalised movie recommendation system based on collaborative filtering," *Int J High Perform Comput Netw*, vol. 10, pp. 54–63, Mar. 2017, doi: 10.1504/IJHPCN.2017.10003762.
- [7] Y.-C. Hou, "Application of Neural Graph Collaborative Filtering in Movie Recommendation System," *2021 IEEE Int. Conf. Electron. Technol. Commun. Inf. ICETCI*, pp. 113–116, Aug. 2021, doi: 10.1109/ICETCI53161.2021.9563481.
- [8] J. Zhao, "Research and improvement of movie recommendation based on a collaborative filtering algorithm," *Appl. Comput. Eng.*, Oct. 2023, doi: 10.54254/2755-2721/14/20230791.
- [9] W. Zhang and J. Wang, "A Collective Bayesian Poisson Factorization Model for Cold-start Local Event Recommendation," in *Proceedings of the 21th ACM SIGKDD*

- International Conference on Knowledge Discovery and Data Mining*, Sydney NSW Australia: ACM, Aug. 2015, pp. 1455–1464. doi: 10.1145/2783258.2783336.
- [10] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, “Evaluating collaborative filtering recommender systems,” *ACM Trans. Inf. Syst.*, vol. 22, no. 1, pp. 5–53, Jan. 2004, doi: 10.1145/963770.963772.
 - [11] J. Bobadilla, F. Ortega, A. Hernando, and A. Gutiérrez, “Recommender systems survey,” *Knowl.-Based Syst.*, vol. 46, pp. 109–132, Jul. 2013, doi: 10.1016/j.knosys.2013.03.012.
 - [12] Y. Wu, C. DuBois, A. X. Zheng, and M. Ester, “Collaborative Denoising Auto-Encoders for Top-N Recommender Systems,” in *Proceedings of the Ninth ACM International Conference on Web Search and Data Mining*, San Francisco California USA: ACM, Feb. 2016, pp. 153–162. doi: 10.1145/2835776.2835837.
 - [13] X. Wang, X. He, M. Wang, F. Feng, and T.-S. Chua, “Neural Graph Collaborative Filtering,” in *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*, Jul. 2019, pp. 165–174. doi: 10.1145/3331184.3331267.
 - [14] H. Wang, N. Wang, and D.-Y. Yeung, “Collaborative Deep Learning for Recommender Systems,” in *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Sydney NSW Australia: ACM, Aug. 2015, pp. 1235–1244. doi: 10.1145/2783258.2783273.
 - [15] X. Zhao, L. Zhang, L. Xia, Z. Ding, D. Yin, and J. Tang, “Deep Reinforcement Learning for List-wise Recommendations,” Jun. 27, 2019, *arXiv*: arXiv:1801.00209. doi: 10.48550/arXiv.1801.00209.
 - [16] J. Beel, B. Gipp, S. Langer, and C. Breitinger, “Research-paper recommender systems: a literature survey,” *Int. J. Digit. Libr.*, vol. 17, no. 4, pp. 305–338, Nov. 2016, doi: 10.1007/s00799-015-0156-0.
 - [17] A. A. Patoulia, A. Kiourtis, A. Mavrogiorgou, and D. Kyriazis, “A Comparative Study of Collaborative Filtering in Product Recommendation,” *Emerg. Sci. J.*, vol. 7, no. 1, pp. 1–15, Oct. 2022, doi: 10.28991/ESJ-2023-07-01-01.
 - [18] X. Li and D. Li, “An Improved Collaborative Filtering Recommendation Algorithm and Recommendation Strategy,” *Mob Inf Syst*, vol. 2019, pp. 3560968–3560968, May 2019, doi: 10.1155/2019/3560968.
 - [19] Y. Wang, “Research on recommendation algorithm based on collaborative filtering of fusion model,” *J. Phys. Conf. Ser.*, vol. 1774, Jan. 2021, doi: 10.1088/1742-6596/1774/1/012058.
 - [20] L. V. Nguyen, Q.-T. Vo, and T.-H. Nguyen, “Adaptive KNN-Based Extended Collaborative Filtering Recommendation Services,” *Big Data Cogn Comput*, vol. 7, p. 106, May 2023, doi: 10.3390/bdcc7020106.
 - [21] K. R. Putra and I. F. Rahman, “Pemanfaatan Metode Collaborative Filtering dengan Algoritma KNN pada Sistem Rekomendasi Produk”.
 - [22] F. Ortega, A. Hernando, J. Bobadilla, and J. H. Kang, “Recommending items to group of users using Matrix Factorization based Collaborative Filtering,” *Inf. Sci.*, vol. 345, pp. 313–324, Jun. 2016, doi: 10.1016/j.ins.2016.01.083.