

Mereduksi Error Prediksi Pada Sistem Rekomendasi Menggunakan Pendekatan Collaborative Filtering Berbasis Model Matrix Factorization

Annas Al Amin¹, Andi Sunyoto², Hanif Al Fatta³

Magister Teknik Informatika Universitas Amikom Yogyakarta^{1,2,3}

annas.am@students.amikom.ac.id, andi@amikom.ac.id, hanif.a@amikom.ac.id

Abstrak – Sistem pemberi rekomendasi banyak digunakan pada banyak *website* seperti *marketplace*, streaming film, *e-commerce*, dll untuk menghasilkan rekomendasi *item* yang sesuai dan disukai kepada setiap penggunanya. Pendekatan tradisional collaborative filtering berbasis memory saat ini masih banyak digunakan dalam sistem rekomendasi. Pendekatan ini bertumpu pada *rating* yang diberikan oleh pengguna terhadap suatu *item* sebagai pendekatan dasar untuk menghitung kesamaan respon pengguna terhadap produk untuk memberikan rekomendasi *item*, namun kelemahannya error prediksi yang dihasilkan saat memberikan rekomendasi *item* tinggi. Penelitian ini bertujuan untuk mereduksi error prediksi dari pendekatan collaborative filtering berbasis memory dengan menggunakan collaborative filtering berbasis model matrix factorization supaya dapat memperbaiki metode pada penelitian sebelumnya. Pendekatan collaborative filtering berbasis model matrix factorization merupakan salah satu pendekatan dalam sistem rekomendasi yang mampu mengurangi error prediksi untuk menghasilkan rekomendasi *item* yang akurat. Metode yang diusulkan telah dievaluasi sebanyak 5 kali iterasi menggunakan root mean squared error untuk mengukur error prediksi. Hasilnya, pendekatan collaborative filtering berbasis model matrix factorization yang kami usulkan mampu menghasilkan error prediksi terkecil sebesar 0,6814 sedangkan collaborative filtering berbasis memory menghasilkan error prediksi lebih besar yaitu 2,984.

Kata kunci: Sistem Rekomendasi; Collaborative Filtering; Matrix Factorization; SVD;

Abstract - The recommender system is widely used on many websites such as marketplaces, streaming movies, and e-commerce to produce recommendations for each user's suitable and liked items. The traditional memory-based collaborative filtering approach is still being used in recommendation systems. This approach relies on users' rating to an item as a fundamental approach to calculating the similarity of user responses to products to provide item recommendations, but the weakness is high prediction errors. This study aims to reduce predictive errors from the memory-based collaborative filtering approach by using collaborative filtering based on the matrix factorization model to improve the previous studies' method. The collaborative filtering approach based on the matrix factorization model is one approach in the recommendation system that can reduce prediction errors to produce accurate item recommendations. The proposed method has been evaluated for five iterations using the root mean squared error to measure the prediction error. As a result, the collaborative filtering approach based on the matrix factorization model that we propose can produce a minor prediction error of 0.6814 while memory-based collaborative filtering produces a more significant prediction error of 2.984.

Keyword : Recommender System; Collaborative Filtering; Matrix Factorization; SVD;

1. Latar Belakang

Sistem rekomendasi merupakan salah satu sistem pendukung yang banyak digunakan pada berbagai jenis *website* seperti streaming film, *ecommerce*, *marketplace*, dll untuk memberikan rekomendasi *item* yang mungkin disukai kepada penggunanya. Saat ini pendekatan yang banyak digunakan pada sistem rekomendasi adalah Collaborative Filtering (CF) berbasis memory yang merupakan model tradisional pada sistem rekomendasi. Pendekatan CF berbasis memory merupakan salah satu pendekatan umum yang banyak digunakan untuk merekomendasikan suatu *item* kepada penggunanya menggunakan data *rating* yang

diberikan oleh pengguna pada suatu *item*. Ide utamanya untuk memprediksi *item* yang mungkin disukai oleh pengguna berdasarkan kemiripan preferensi pengguna lain dalam memberikan *rating* pada *item* tersebut [1]. Pendekatan ini juga merupakan salah satu yang paling sukses, dan sering diimplementasikan untuk sistem rekomendasi pada berbagai macam *website* atau aplikasi karena model yang dihasilkan dalam memberikan rekomendasi *item personalized* kepada penggunanya [2], [3], [4]. Selain pendekatan CF terdapat pendekatan lain yang juga sering digunakan pada sistem rekomendasi yaitu Content Based Filtering (CBF), pendekatan ini memanfaatkan

kemiripan data konten beberapa *item* seperti kategori, deskripsi, spesifikasi, nama *item*, atau atribut lain sebagai dasar untuk memberikan rekomendasi *item* kepada pengguna. Pendekatan ini mampu memberikan rekomendasi *item* kepada pengguna tanpa menggunakan informasi *rating* pada *item* tersebut karena data yang digunakan adalah konten *itemnya*.

Walaupun pendekatan CF masih banyak digunakan pada sistem rekomendasi, namun terdapat beberapa kelemahan pada pendekatan tersebut, kelemahan pertama, jika terdapat *item* yang sama sekali belum pernah diberi rating oleh pengguna, maka *item* tersebut tidak bisa direkomendasikan oleh sistem (*Cold Start Problem*) [5], kelemahan kedua, pendekatan ini mengabaikan informasi konten dari *item* yang sebenarnya bisa digunakan sebagai dasar untuk memberikan rekomendasi *item*, dan kelemahan ketiga, pendekatan CF berbasis memory memerlukan komputasi yang tinggi karena setiap ada data *rating* baru, model harus di *training* lagi sehingga akan memakan banyak *resource* dan waktu [6]. Tujuan penelitian ini untuk mereduksi error prediksi dari pendekatan tradisional CF berbasis memory dari penelitian sebelumnya menggunakan pendekatan CF berbasis model Matrix Factorization (MF) untuk memperbaiki error prediksi pada pendekatan tradisional CF. Pendekatan CF berbasis model MF memiliki beberapa kelebihan. Pertama, sistem tetap dapat memberikan rekomendasi *item* kepada pengguna baru yang belum memberikan rating *item* sama sekali [7], kedua, model yang dihasilkan mampu memberikan rekomendasi *item* secara *personalized*, sehingga setiap pengguna bisa mendapatkan rekomendasi *item* yang berbeda atau bervariasi [8], ketiga, dapat mengurangi beban komputasi karena proses training hanya dilakukan sekali sehingga model dapat dengan cepat memberikan rekomendasi *item* yang tepat kepada pengguna serta dapat mengurangi error prediksi lebih kecil dibandingkan dengan metode CF berbasis *memory* karena menggunakan basis model MF. Model yang dihasilkan dari pendekatan CF berbasis model MF ini dapat memberikan rekomendasi *item* yang *personalized* kepada penggunanya, beda dengan metode CBF yang rekomendasi *itemnya* belum *personalized*. Dengan demikian, pendekatan CF berbasis model MF mampu menghasilkan rekomendasi *item* *personalized*, dan mampu mereduksi error prediksi lebih kecil dibandingkan dengan pendekatan tradisional CF berbasis memory,

sehingga pendekatan CF berbasis model MF mampu memperbaiki pendekatan tradisional CF pada penelitian sebelumnya.

2. Kajian Pustaka

Banyak peneliti lain yang sudah mencoba menggunakan teknik dan pendekatan baru untuk mereduksi error prediksi pada sistem rekomendasi, dan memperbaiki pendekatan tradisional CF berbasis memory yang masih banyak digunakan sampai saat ini.

Dimulai dari peneliti pertama [5] menggunakan pendekatan Hybrid dengan kombinasi pendekatan Knowledge Based Recommender dan CF, peneliti tidak hanya menggunakan data *rating item* tetapi juga memanfaatkan data interaksi dari *profile* pengguna terhadap *item* sebagai salah satu *input* untuk sistem rekomendasinya. Hasil error prediksi dari model hybrid ini diukur menggunakan Root Mean Square Deviation (RMSE) dan menghasilkan error prediksi sebesar 0,347. Lalu peneliti kedua [9] melakukan perbandingan waktu eksekusi pendekatan CF berbasis memory, CBF, dan HF dengan memanfaatkan algoritma Adjusted Cosine Similarity untuk menghitung kemiripan *rating* yang diberikan antar pengguna pada suatu *item* dan algoritma Weighted Sum untuk prediksi *rating item*. Pada penelitian ini hanya dilakukan pembuktian mengenai waktu eksekusi tercepat dari ketiga metode yang digunakan, hasilnya metode CBF memiliki waktu eksekusi lebih cepat dibandingkan dengan metode CF dan HF. Namun kelemahannya, algoritma Weighted Sum yang digunakan untuk prediksi *rating item* tidak cocok untuk digunakan pada pengguna yang hanya memiliki rating yang sedikit karena dapat menghasilkan error prediksi yang tinggi. Terdapat peneliti lain [10] yang juga mengimplementasikan pendekatan CF berbasis memory untuk membantu Flazzstore yang merupakan toko penjualan *casing* smartphone untuk memberikan rekomendasi *item* kepada calon pembelinya. Peneliti menggunakan algoritma Pearson Correlation Based Similarity untuk menghitung kemiripan *rating* antar *item*, kemudian hasil dari perhitungan kemiripan antar *item* akan dilakukan prediksi *rating item* menggunakan algoritma Weighted Average of Deviation. Hasil penelitian setelah dilakukan evaluasi prediksi menggunakan metode MAE mendapatkan error prediksi sebesar 0,572039 dengan waktu eksekusi selama 6,4 detik, namun kelemahan dari algoritma yang dipakai ini jika data *item* semakin banyak tetapi data *ratingnya* malah semakin sedikit akan

menyebabkan *sparsity* data, dan menghasilkan error prediksi yang tinggi. Disisi lain terdapat peneliti [8] yang memanfaatkan umpan balik secara implisit dari pengguna berupa kemiripan *rating* antar pengguna, dan perilaku positif pengguna yang didapat dari konversi *rating* yang diberikan. Jika pengguna memberikan *rating* tidak kurang dari 3 maka perilakunya dianggap positif, tetapi jika kurang dari 3 maka perilakunya negatif. Dengan cara ini, peneliti dapat mengatasi permasalahan data *sparsity* sehingga dapat mereduksi error prediksi dari sistem rekomendasi. Peneliti ketiga [11] juga mengusulkan metode baru dengan nama K-RecSys untuk mereduksi error prediksi pada pendekatan tradisional CF yang digunakan untuk *e-commerce fashion retail*. Metode ini menggunakan data klik pada *item* yang sudah pernah dilihat oleh pengguna saat mengunjungi toko *online*, dan data penjualan *item* yang didapat dari toko *offline* untuk memberikan rekomendasi *item* berdasarkan kategori yang sama dan kategori yang berbeda. Hasil metode yang diusulkan oleh peneliti diukur dengan membagi 2 kelompok rekomendasi *item*, kelompok *Control Group* dari sistem rekomendasi lama, dan *Experimental Group* dari sistem rekomendasi baru yang diusulkan oleh peneliti. Setelah dilakukan pengujian, hasil rekomendasi dari *Experimental Group* banyak mendapatkan interaksi terbanyak dibandingkan dengan *Control Group*, dengan demikian model yang diusulkan oleh peneliti memiliki performa yang lebih baik. Permasalahan *sparsity* data untuk mereduksi error prediksi pada sistem rekomendasi juga diatasi oleh peneliti [12] dengan mengusulkan model Fusion Matrix Factorization untuk mengukur multi factor similarity antar pengguna. Peneliti menggunakan algoritma Extreme Behavior Similarity Measure dan Linier Similarity, setelah mendapatkan *multi factor similarity* atau *neighbor matrix*, lalu digabungkan dengan original *matrix* yang dinamakan proses Fusing untuk mendapatkan matriks prediksi berdasarkan representasi faktor laten dari pengguna dan item. Hasil model dari peneliti ini mendapatkan nilai RMSE dan MAE terkecil dibandingkan dengan pendekatan tradisional CF.


Pendekatan CF berbasis memory pada sistem rekomendasi bisa menghasilkan error prediksi yang tinggi, namun peneliti [13] dapat mengatasinya dengan menggunakan teknik *clustering* pada pendekatan hybrid. Algoritma K-Means Clustering digunakan oleh peneliti untuk mengelompokkan *item* berdasarkan

kemiripan *rating item*, lalu menggunakan algoritma Weighted Average of Deviation untuk memprediksi *rating* dalam *cluster*. Teknik *cluster* ini dapat mereduksi error prediksi dari CF berbasis memory namun memakan banyak waktu untuk proses komputasi. Terdapat teknik lain dalam mereduksi error prediksi dan mengatasi *sparsity* data pada sistem rekomendasi dengan mengkombinasikan pendekatan Matrix Factorization dan Deep Learning seperti yang dilakukan oleh peneliti [14] untuk memperbaiki pendekatan CF. Peneliti menggunakan algoritma NMF untuk mengurangi tingkat error, lalu dilakukan pengukuran dampak dari representasi fitur yang dihitung dengan rumus Quadratic Polynomial Regression untuk mendapatkan fitur laten dengan meningkatkan Item-average Clustering. Hasil klasifikasi algoritma CF berdasarkan analisis Deep Learning menggunakan rumus perhitungan Non Linearity dari item pengguna menghasilkan sistem rekomendasi dengan pendekatan hybrid. Hasil model baru yang diusulkan oleh peneliti ini dapat mereduksi error prediksi pada estimasi MSE dan mengatasi permasalahan *sparsity* data sehingga dapat meningkatkan kualitas pada sistem rekomendasi.

Dari penelitian yang sudah diuraikan diatas, kebanyakan peneliti hanya fokus untuk mereduksi error prediksi dan mengatasi permasalahan *sparsity* data dari pendekatan tradisional CF tanpa membandingkan hasilnya dengan hasil dari penelitian sebelumnya. Perbedaan pada penelitian ini adalah algoritma yang digunakan pada pendekatan CF, lalu membandingkan error prediksi dari metode yang kami usulkan dengan pendekatan tradisional CF dari penelitian sebelumnya supaya dapat dilihat perbedaan performanya menggunakan dataset yang sama, dan juga untuk menghasilkan rekomendasi *item* yang sudah *personalized*.

3. Perancangan Sistem / Metode Penelitian

Tahapan keseluruhan proses penelitian yang akan dilakukan bisa dilihat pada **gambar 1**.



Gambar 1. Alur Keseluruhan Penelitian

a. Persiapan Dataset

Dataset didapatkan dari MovieLens [15] dalam ekstensi atau format csv, MovieLens merupakan sebuah sistem rekomendasi yang dikembangkan oleh GroupLens. Dataset ini bersifat *open source* dan telah banyak digunakan untuk kebutuhan penelitian yang terkait dengan sistem rekomendasi. Dataset ini memiliki atribut atau variabel yang dibutuhkan untuk penelitian ini yang meliputi metadata, konten *item*, dan *rating item* pengguna yang berkisar dari 1 sampai 5. Dataset ini bisa didapatkan secara gratis oleh semua dengan *download* melalui *website* Kaggle atau langsung dari sumber pembuatnya yaitu GroupLens. Detail dataset dapat dilihat pada **tabel 1**.

Tabel 1. Detail Dataset

Nama Atribut	Jumlah Data
Metadata (Genres, Cast, Keywords, Director)	3706
Movie Title	3706
User ID	6040
Rating Movie	1000209

b. Data Preprocessing

Berdasarkan **gambar 1** tahap 1 setelah menyiapkan dataset, langkah selanjutnya adalah Data Preprocessing, pertama akan dilakukan proses seleksi data atribut / variabel dari dataset yang dibutuhkan untuk penelitian ini, pada detail dataset di **tabel 1** atribut yang dibutuhkan adalah *Movie Title*, *User ID*, dan

Rating Movie karena pada pendekatan ini tidak membutuhkan data konten *item* dari atribut metadata. Setelah itu akan dilakukan filter data *rating* pengguna dari atribut *User ID* untuk menemukan pengguna yang telah memberikan *rating* pada item sekitar 150 sampai 200 *rating*. Setelah difilter didapatkan 518 pengguna dengan jumlah 89290 *rating*. Proses filter data *rating* pengguna ini dilakukan agar jumlah data *rating* setiap pengguna saat dilakukan evaluasi error prediksi nanti memiliki jumlah yang seimbang. Pada tahap testing dan evaluasi error prediksi dari model menggunakan data dari atribut *Rating Movie* sebanyak 89290 data *training* dan 17858 data *testing* untuk dilakukan proses evaluasi sebanyak 5 kali iterasi atau perulangan menggunakan RMSE untuk memaksimalkan perkiraan tingkat kesalahan yang terjadi, lalu hasilnya akan dibandingkan dengan pendekatan tradisional CF berbasis memory pada penelitian sebelumnya menggunakan dataset yang sama.

c. Collaborative Filtering Berbasis Model Matrix Factorization

Collaborative filtering merupakan suatu konsep dimana opini dari pengguna lain yang ada digunakan untuk memprediksi *item* yang mungkin disukai/diminati oleh seorang pengguna. Kualitas rekomendasi yang diberikan dengan menggunakan metode ini sangat bergantung dari opini pengguna lain (*neighbor*) terhadap suatu *item*. CF memberikan rekomendasi berdasarkan kumpulan dari pendapat, minat dan ketertarikan beberapa *user* lain yang biasanya diberikan dalam bentuk *rating* yang diberikan *user* terhadap suatu *item*. Berdasarkan **gambar 1** tahap 2 setelah melalui data preprocessing, selanjutnya adalah Proses *Training* dan Hasil menggunakan pendekatan CF berbasis model MF untuk menghasilkan rekomendasi *item* yang *personalized* dengan memprediksi *rating item* menggunakan salah satu metode Matrix Factorization yaitu Singular Value Decomposition (SVD), hasil rekomendasi *item* dari model ini akan diurutkan berdasarkan nilai prediksi *rating* tertinggi ke terendah. Rekomendasi *item* dari pendekatan ini juga dapat mengatasi kelemahan pada pendekatan CBF yang belum bisa menghasilkan rekomendasi produk secara *personalized*. Rumus SVD dapat dilihat pada **persamaan 1**.

$$R = M(\Sigma)U^T \quad (1)$$

Dimana variabel R merupakan matriks yang merepresentasikan *rating* pengguna terhadap setiap *item*, variabel M merupakan eigenvector dari matrix RR^T , variabel U merupakan eigenvector dari matrix R^TR , dan (Σ) merupakan assosiasi eigenvalues menjadi matriks diagonal.

c. Root Mean Squared Error (RMSE)

RMSE merupakan salah satu metode yang digunakan untuk mengevaluasi performa hasil prediksi dari suatu metode atau algoritma. Setelah tahap prediksi *rating item* dilakukan, tahap terakhir adalah mengevaluasi performa pendekatan CF berbasis model MF dengan mengestimasi error prediksi *rating* menggunakan rumus RMSE, lalu membandingkan hasilnya dengan pendekatan CF berbasis memory pada penelitian sebelumnya menggunakan dataset yang sama. Teknik ini diterapkan dengan penjumlahan nilai *rating* sebenarnya dikurangi dengan hasil nilai prediksi *rating* lalu dipangkatkan, setelah itu dibagi dengan jumlah data, lalu diakarkan. RMSE merupakan cara untuk mengevaluasi model dengan mengukur tingkat error prediksi yang dihasilkan oleh model [8]. Rumus RMSE dapat dilihat pada **persamaan 2**.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - P_i)^2}{n}} \quad (2)$$

Dimana variabel A_i merupakan nilai *rating item* sebenarnya, variabel P_i merupakan nilai prediksi *rating item*, dan variabel n merupakan jumlah data *rating* sebenarnya.


4. Implementasi Sistem dan Hasil

Berdasarkan **gambar 1** tahap 3 Evaluasi dan Perbandingan akan dilakukan pembuktian bahwa pendekatan CF berbasis model MF mampu mengurangi error prediksi lebih kecil dibandingkan dengan pendekatan CF berbasis memory dari penelitian sebelumnya, proses evaluasi ini dilakukan untuk membandingkan hasil performa model pendekatan CF berbasis model MF dengan CF berbasis memory berdasarkan hasil nilai RMSE terkecil, jika error prediksi semakin kecil maka akurasi dari model semakin baik, tetapi jika error prediksi semakin besar maka akurasi dari model semakin buruk. Proses evaluasi akan dilakukan sebanyak 5 kali iterasi menggunakan 89290 data *training* dan 17858 data *testing* yang detail pembagian dataset setiap iterasinya bisa dilihat pada **gambar 2**. Setiap evaluasi akan dihitung nilai RMSE dan

dibandingkan perbedaan error prediksi dari kedua pendekatan, lalu tahap akhir akan dirata-rata nilai RMSE dari 5 iterasi untuk memutuskan model pendekatan yang terbaik berdasarkan nilai RMSE yang terkecil. Hasil evaluasi dan perbandingan error prediksi dari kedua pendekatan bisa dilihat pada **gambar 3**.

Iterasi 1	Data Testing	Data Training	Data Training	Data Training	Data Training
Iterasi 2	Data Training	Data Testing	Data Training	Data Training	Data Training
Iterasi 3	Data Training	Data Training	Data Testing	Data Training	Data Training
Iterasi 4	Data Training	Data Training	Data Training	Data Testing	Data Training
Iterasi 5	Data Training	Data Training	Data Training	Data Training	Data Testing
Data Testing	20%				

Gambar 2. Detail Pembagian Dataset



Gambar 3. Hasil Evaluasi dan Perbandingan

Berdasarkan hasil evaluasi dan perbandingan error prediksi dari kedua pendekatan pada **gambar 3**, dapat dilihat bahwa setelah dilakukan evaluasi sebanyak 5 kali iterasi, pendekatan CF berbasis model MF mampu menghasilkan error prediksi terkecil pada iterasi ke 1 dengan nilai RMSE 0,671, sedangkan pada pendekatan CF berbasis memory nilai RMSE paling kecil pada iterasi ke 2 sebesar 2,9465. Dari 5 iterasi yang telah dilakukan, pendekatan CF berbasis model MF menghasilkan rata-rata nilai RMSE terkecil yaitu 0,6814, sedangkan pendekatan CF berbasis memory mendapatkan rata-rata nilai RMSE lebih besar yaitu 2,984. Dari hasil evaluasi ini dapat dilihat bahwa pendekatan yang kami usulkan mempunyai performa lebih baik dibandingkan dengan pendekatan tradisional CF berbasis memory pada penelitian sebelumnya.

5. Kesimpulan

Berdasarkan hasil evaluasi dan perbandingan error prediksi yang telah dilakukan pada penelitian ini, dapat disimpulkan bahwa pendekatan CF berbasis MF yang kami usulkan mampu mengurangi error prediksi lebih kecil dibandingkan dengan pendekatan tradisional CF berbasis memory, dari hasil evaluasi sebanyak 5 kali iterasi yang telah dilakukan, pendekatan yang kami usulkan mampu menghasilkan rata-rata error prediksi terkecil sebesar 0,6814, sedangkan pendekatan CF berbasis memory menghasilkan rata-rata error prediksi lebih besar yaitu 2,984. Berdasarkan hasil evaluasi, pendekatan Collaborative Filtering berbasis model Matrix Factorization lebih baik dibandingkan dengan Collaborative Filtering berbasis memory dari penelitian sebelumnya. Jadi, pendekatan yang kami usulkan berhasil mereduksi error prediksi dari sistem rekomendasi dan dapat memperbaiki error prediksi yang dihasilkan dari pendekatan CF berbasis memory.

6. Pustaka

- [1] N. Nassar, A. Jafar, and Y. Rahhal, "A novel deep multi-criteria collaborative filtering model for recommendation system," *Knowledge-Based Syst.*, vol. 187, p. 104811, 2020, doi: 10.1016/j.knosys.2019.06.019.
- [2] S. Jiang, S. C. Fang, Q. An, and J. E. Lavery, "A sub-one quasi-norm-based similarity measure for collaborative filtering in recommender systems," *Inf. Sci. (Ny)*, vol. 487, pp. 142–155, 2019, doi: 10.1016/j.ins.2019.03.011.
- [3] Y. Lv, Y. Zheng, F. Wei, C. Wang, and C. Wang, "AICF: Attention-based item collaborative filtering," *Adv. Eng. Informatics*, vol. 44, no. February, p. 101090, 2020, doi: 10.1016/j.aei.2020.101090.
- [4] K. Li, X. Zhou, F. Lin, W. Zeng, B. Wang, and G. Alterovitz, "Sparse online collaborative filtering with dynamic regularization," *Inf. Sci. (Ny)*, vol. 505, pp. 535–548, 2019, doi: 10.1016/j.ins.2019.07.093.
- [5] S. Rahmawati, D. Nurjanah, and R. Rismala, "Analisis dan Implementasi pendekatan Hybrid untuk Sistem Rekomendasi Pekerjaan dengan Metode Knowledge Based dan Collaborative Filtering," *Indones. J. Comput.*, vol. 3, no. 2, p. 11, 2018, doi: 10.21108/indoic.2018.3.2.210.
- [6] A. S. Tewari, "Generating Items Mereduksi Error Prediksi Pada Sistem Rekomendasi Menggunakan Pendekatan Colaborative Filtering Berbasis Model Matrix Factorization Recommendations by Fusing Content and User-Item based Collaborative Filtering," *Procedia Comput. Sci.*, vol. 167, no. 2019, pp. 1934–1940, 2020, doi: 10.1016/j.procs.2020.03.215.
- [7] S. Natarajan, S. Vairavasundaram, S. Natarajan, and A. H. Gandomi, "Resolving data sparsity and cold start problem in collaborative filtering recommender system using Linked Open Data," *Expert Syst. Appl.*, vol. 149, p. 113248, 2020, doi: 10.1016/j.eswa.2020.113248.
- [8] Y. Hu, F. Xiong, D. Lu, X. Wang, X. Xiong, and H. Chen, "Movie collaborative filtering with multiplex implicit feedbacks," *Neurocomputing*, no. xxxx, 2019, doi: 10.1016/j.neucom.2019.03.098.
- [9] A. E. Wijaya and D. Alfian, "Sistem Rekomendasi Laptop Menggunakan Collaborative Filtering Dan Content-Based Filtering," *J. Comput. Bisnis*, vol. 12, no. 1, pp. 11–27, 2018.
- [10] B. Prasetyo, H. Haryanto, S. Astuti, E. Z. Astuti, and Y. Rahayu, "Implementasi Metode Item-Based Collaborative Filtering dalam Pemberian Rekomendasi Calon Pembeli Aksesoris Smartphone," *Eksplora Inform.*, vol. 9, no. 1, pp. 17–27, 2019, doi: 10.30864/eksplora.v9i1.244.
- [11] H. Hwangbo, Y. S. Kim, and K. J. Cha, "Recommendation system development for fashion retail e-commerce," *Electron. Commer. Res. Appl.*, vol. 28, pp. 94–101, 2018, doi: 10.1016/j.elerap.2018.01.012.
- [12] C. Feng, J. Liang, P. Song, and Z. Wang, "A fusion collaborative filtering method for sparse data in recommender systems," *Inf. Sci. (Ny)*, vol. 521, pp. 365–379, 2020, doi: 10.1016/j.ins.2020.02.052.
- [13] G. Geetha, M. Safa, C. Fancy, and D. Saranya, "A Hybrid Approach using Collaborative filtering and Content based Filtering for Recommender System," *J. Phys. Conf. Ser.*, vol. 1000, no. 1, 2018, doi: 10.1088/1742-6596/1000/1/012101.
- [14] Hanafi, N. Suryana, and A. S. B. H. Basari, "Hybridization approach to eliminate sparse data based on nonnegative matrix factorization & deep learning," *J. Theor. Appl. Inf. Technol.*, vol. 96, no. 14, pp. 4502–4512, 2018.
- [15] F. M. Harper and J. A. Konstan, "The

movielens datasets: History and context," *ACM Trans. Interact. Intell. Syst.*, vol. 5, no. 4, pp. 1–19, 2015, doi: 10.1145/2827872.