

Metode Hybrid (SVD++-KNN) pada Sistem Rekomendasi Film dan Preferensi Artis Musik

Diterima:

3 Juli 2026

Revisi:

21 Juli 2026

Terbit:

23 Juli 2026

Maswadi Ra'uf, *Ilham Saifudin, Luluk Handayani

Universitas Muhammadiyah Jember

Abstrak— Latar Belakang: Sistem rekomendasi berbasis *collaborative filtering* telah banyak digunakan untuk membantu pengguna menemukan konten yang sesuai preferensi, namun masih menghadapi tantangan terkait keragaman data. **Tujuan:** Penelitian ini mengevaluasi efektivitas metode *weighted hybrid SVD++-KNN* dalam meningkatkan akurasi sistem rekomendasi film dan preferensi artis musik. **Metode:** Penelitian ini menggunakan pendekatan eksperimen kuantitatif pada dataset MovieLens 1M dan Last.FM. Data dibagi menjadi 80% data latih dan 20% data uji dengan validasi *hold-out*. Model menggabungkan algoritma SVD++ dan KNN, kemudian dievaluasi menggunakan metrik RMSE dan MAE. **Hasil:** Pada dataset MovieLens diperoleh nilai RMSE 0,8594 dan MAE 0,6747 pada $\alpha = 0,8$, sedangkan pada dataset Last.FM diperoleh RMSE 0,2632 dan MAE 0,1955 pada $\alpha = 0,9$. **Kesimpulan:** Metode *weighted hybrid SVD++-KNN* meningkatkan akurasi sistem rekomendasi pada kedua dataset. Penyesuaian nilai alpha sesuai dengan karakteristik dataset dapat meningkatkan kinerja model, sehingga metode ini menjadi alternatif yang efektif untuk sistem rekomendasi berbasis kolaborasi.

Kata Kunci— Sistem Rekomendasi; SVD++; K-Nearest Neighbor; Weighted Hybrid; Collaborative Filtering

Abstract— Background: Collaborative Filtering-based recommendation systems are widely used to assist users in finding content aligned with their preferences, yet they continue to face challenges arising from data diversity. **Objective:** This study evaluates the effectiveness of the *weighted hybrid SVD++-KNN* method for improving the accuracy of movie recommendation and music artist preference systems. **Methods:** A quantitative experimental approach was employed using the MovieLens 1M and Last.FM datasets. The data were split into 80% for training, 20% for testing, and a hold-out validation set. The model combined SVD++ and KNN and was evaluated using RMSE and MAE. **Results:** On the MovieLens dataset, RMSE of 0.8594 and MAE of 0.6747 were achieved at $\alpha = 0.8$, while on the Last.FM dataset, RMSE of 0.2632 and MAE of 0.1955 were obtained at $\alpha = 0.9$. **Conclusion:** Adjusting the alpha value according to dataset characteristics can improve model performance, making this method an effective alternative for collaborative recommendation systems.

Keywords— Recommendation Systems; SVD++; K-Nearest Neighbor; Weighted Hybrid; Collaborative Filtering

This is an open access article under the CC BY-SA License.



Penulis Korespondensi:

Ilham Saifudin,
Teknik Informatika,
Universitas Muhammadiyah Jember,
Email: ilham.saifudin@unmuhjember.ac.id

I. PENDAHULUAN

Kemajuan teknologi informasi telah mengubah cara masyarakat mengakses dan menikmati konten hiburan digital, khususnya film, serta membentuk preferensi terhadap artis musik. Perkembangan platform digital telah meningkatkan jumlah konten yang tersedia, sehingga pengguna sering mengalami kesulitan menemukan film atau artis musik yang sesuai dengan minat dan preferensi mereka. Kondisi ini menegaskan pentingnya sistem rekomendasi sebagai solusi untuk membantu pengguna memperoleh rekomendasi yang relevan berdasarkan pola interaksi dan preferensi (Saifudin & Widiyaningtyas, 2024a). Dengan menyediakan konten yang lebih sesuai dengan kebutuhan pengguna, sistem rekomendasi juga dapat mendukung proses pengambilan keputusan (Kumar et al., 2023).

Salah satu sistem rekomendasi dari penerapan aplikasi Artificial Intelligence (AI) dalam membantu pengguna menemukan item yang sesuai dengan preferensinya adalah sistem rekomendasi yang biasanya dikembangkan menggunakan tiga pendekatan utama, yaitu filtrasi berbasis konten, filtrasi kolaboratif, dan sistem rekomendasi hibrida (Saifudin & Widiyaningtyas, 2024a). Di antara ketiga pendekatan tersebut, collaborative filtering mampu memanfaatkan pola interaksi antarpengguna tanpa memerlukan fitur khusus pada setiap item, sehingga menjadi metode yang paling banyak digunakan (Anwar et al., 2022). Namun, metode ini memiliki beberapa kelemahan yaitu kekurangan data menyebabkan matriks interaksi pengguna dan item menjadi sangat jarang terisi, sehingga mengurangi akurasi prediksi (Vahidi Farashah et al., 2021). Karakteristik data yang berbeda memengaruhi kinerja algoritma rekomendasi, sehingga diperlukan metode yang mampu menghasilkan prediksi yang konsisten pada berbagai jenis dataset (Ekstrand et al., 2024).

Harlianto et al. (2025) mengembangkan metode weighted hybrid SVD-KNN, yang terbukti lebih akurat daripada metode tunggal, meskipun belum memanfaatkan implicit feedback pengguna dan masih terbatas pada domain film. Selanjutnya, Widiyaningtyas et al. (2025) mengusulkan algoritma SVD-GSetRank yang berfokus pada peningkatan nilai Precision dan Normalized Discounted Cumulative Gain (NDCG). Namun, implementasinya masih terbatas pada evaluasi model dan belum diterapkan pada aplikasi berbasis web. Selain itu, Wang et al. (2020) menunjukkan bahwa algoritma SVD++ mampu meningkatkan akurasi prediksi dengan memanfaatkan implicit feedback. Temuan-temuan ini menunjukkan peluang untuk mengembangkan metode yang dapat mempertahankan akurasi pada berbagai karakteristik dataset sekaligus dapat diimplementasikan dalam sistem rekomendasi berbasis web.

Berdasarkan penelitian sebelumnya, SVD++ dipilih karena kemampuannya memanfaatkan implicit feedback pengguna untuk menghasilkan prediksi yang lebih akurat dibandingkan SVD konvensional (Wang et al., 2020). Sementara itu, KNN efektif dalam mendeteksi kemiripan


antaritem berdasarkan pola interaksi pengguna (Kouki et al., 2020). Penggabungan kedua algoritma melalui pendekatan weighted hybrid diharapkan dapat menggabungkan keunggulan metode berbasis latent factor dan memory-based collaborative filtering, sehingga dapat meningkatkan kualitas rekomendasi pada dataset dengan karakteristik yang berbeda (Hssina et al., 2021).

Perbedaan penelitian ini dengan penelitian sebelumnya adalah bahwa penelitian ini menggabungkan algoritma SVD++ dan K-Nearest Neighbor (KNN) dengan pendekatan weighted hybrid untuk memanfaatkan keunggulan metode berbasis latent factor dan memory-based collaborative filtering. Penelitian ini menguji kinerja metode pada dua dataset yang berbeda, yaitu MovieLens 1M dan Last.FM. Selain itu, model yang dikembangkan diintegrasikan ke dalam aplikasi berbasis web yang dapat memberikan rekomendasi film dan preferensi artis musik secara interaktif. Ini berbeda dengan penelitian sebelumnya yang hanya berfokus pada satu domain atau mengevaluasi model tanpa implementasi. Diharapkan metode ini dapat menghasilkan sistem rekomendasi yang lebih akurat untuk berbagai jenis data.

Tujuan penelitian ini adalah mengevaluasi konsistensi kinerja metode weighted hybrid SVD++–KNN pada dataset MovieLens dan Last.FM yang memiliki fitur berbeda, serta menerapkan model ke dalam aplikasi berbasis web. Selain itu, penelitian ini juga bertujuan untuk menganalisis pengaruh parameter alpha terhadap kinerja model dengan menggunakan metrik RMSE dan MAE.

II. METODE

Eksperimen kuantitatif digunakan untuk mengevaluasi kinerja algoritma *weighted hybrid* SVD++–KNN pada sistem rekomendasi berbasis filter kolaboratif. Penelitian ini menggunakan dua dataset, yaitu MovieLens 1M untuk menggambarkan domain film dan Last.FM untuk menggambarkan preferensi terhadap artis musik. Studi literatur, pengumpulan dataset, *pre-processing*, pembuatan model, penggabungan model dengan *weighted hybrid*, *hyperparameter tuning*, penerapan model pada website, dan evaluasi menggunakan metrik (RMSE) dan (MAE). Gambar 1 menunjukkan alur penelitian yang diadaptasi dari tahapan pengembangan sistem rekomendasi yang dikemukakan oleh (Saifudin & Widiyaningtyas, 2024).



Gambar 1. Alur Penelitian

Dataset

Dua dataset yang berbeda digunakan dalam penelitian ini, yaitu MovieLens 1M yang berisi data rating eksplisit pengguna terhadap film dan Last.FM yang berisi data *implicit feedback* berupa jumlah *play count* pengguna terhadap artis musik. Penggunaan dua dataset bertujuan untuk mengevaluasi konsistensi performa metode pada karakteristik data yang berbeda, khususnya tingkat *sparsity*. Karakteristik kedua dataset tersebut menjadi dasar untuk menilai sejauh mana metode mampu mempertahankan akurasi dalam berbagai kondisi data.

Data Pre-processing

Selanjutnya, *pre-processing* meningkatkan kualitas data. Dataset MovieLens 1M memiliki data penilaian yang berada pada rentang 1–5, sehingga dapat digunakan secara langsung. Di sisi lain, dataset Last.FM memerlukan proses transformasi karena menggunakan *implicit feedback* berupa jumlah pemain. Nilai *play count* ditransformasikan ke dalam rentang penilaian 1–5 dengan menggunakan fungsi logaritmik yang dikombinasikan dengan normalisasi min-max,

sehingga distribusi data menjadi lebih proporsional dan nilai ekstrem berkurang. (Amiri et al., 2024; Zhang et al., 2023). Persamaan transformasi tersebut ditunjukkan pada Persamaan (1)

$$r_{ui} = 1 + 4 \times \frac{x_{ui} - x_{min}}{x_{max} - x_{min}} \quad (1)$$

dimana $r_{u,i}$ menyatakan rating hasil normalisasi pada skala 1-5 yang digunakan sebagai masukan algoritma SVD++, $w_{u,i}$ merupakan nilai *play count* interaksi pengguna u terhadap artis musik i , sedangkan $\log(1 + w_{u,i})$ Digunakan untuk mengurangi pengaruh nilai *play count* yang terlalu besar agar tidak menimbulkan bias. Selanjutnya, $\min(w)$ dan $\max(w)$ Masing-masing merupakan nilai minimum dan maksimum hasil transformasi logaritmik yang digunakan sebagai batas bawah dan batas atas dalam proses normalisasi. Konstanta 1 dan 4 digunakan untuk memetakan hasil normalisasi ke dalam rentang rating 1-5.

Representasi User-Item

Setelah proses *pre-processing* selesai, data direpresentasikan dalam bentuk matriks *user-item* yang menunjukkan hubungan antara pengguna dan item. Representasi matriks tersebut dinyatakan dalam Persamaan (2).

$$R = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ r_{21} & r_{22} & \cdots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{m1} & r_{m2} & \cdots & r_{mn} \end{bmatrix} \quad (2)$$

dimana R merupakan matriks *user-item*, r_{ui} adalah rating yang diberikan oleh pengguna u terhadap item i , m menyatakan jumlah pengguna, dan n menyatakan jumlah item.

Singular Value Decomposition Plus Plus (SVD++)

Algoritma SVD++ merupakan pengembangan dari metode faktorisasi matriks yang dapat memanfaatkan *implicit feedback* pengguna untuk menghasilkan prediksi yang lebih akurat dibandingkan SVD konvensional (Mahalisa et al., 2025). Studi ini menggunakan SVD++ dan proses dekomposisi matriks untuk mempelajari hubungan laten antara pengguna dan item. Persamaan prediksi rating ditunjukkan pada Persamaan (3).

$$\hat{r}_{ui} = \mu + b_u + b_i + q_i^T \left(p_u + |N(u)|^{-1/2} \sum_{j \in N(u)} y_j \right) \quad (3)$$

dimana $\hat{r}_{ui}$ merupakan prediksi rating pengguna u terhadap item i , μ adalah rata-rata global rating, b_u dan b_i masing-masing menyatakan bias pengguna dan bias item, p_u dan q_i merupakan vektor faktor laten pengguna dan item, sedangkan y_j adalah faktor *implicit feedback* dari item yang pernah berinteraksi dengan pengguna. Sementara itu, $N(u)$ menyatakan himpunan item yang pernah berinteraksi dengan pengguna u . Adanya komponen *implicit feedback* memungkinkan metode SVD++ menghasilkan prediksi yang lebih akurat dibandingkan metode

SVD standar karena mampu memanfaatkan informasi interaksi pengguna secara lebih komprehensif.

K-Nearest Neighbor (KNN)

Metode *K-Nearest Neighbors* (KNN) adalah metode kolaborasi filter berdasarkan memori. Berdasarkan sudut yang terbentuk antara dua vektor penilaian, *cosine similarity* menentukan tingkat kemiripan antara dua item. Semakin kecil sudut yang terbentuk, semakin tinggi tingkat kemiripan antara kedua item tersebut. Sistem rekomendasi sering menggunakan metode ini karena mampu mengukur kesamaan pola interaksi pengguna terhadap suatu item (Anwar et al. 2022). Nilai kemiripan digunakan untuk memprediksi nilai pengguna pada item yang belum pernah dinilai sebelumnya. Perhitungan kemiripan tersebut dinyatakan dalam Persamaan (4).

$$\text{Sim}(i, j) = \frac{\sum_{u \in U} r_{u,i} \times r_{u,j}}{\sqrt{\sum_{u \in U} r_{u,i}^2} \sqrt{\sum_{u \in U} r_{u,j}^2}} \quad (4)$$

dimana $\text{Sim}(i, j)$ menyatakan tingkat kemiripan antara item i dan item j , $r_{u,i}$ merupakan rating yang diberikan oleh pengguna u terhadap item i , $r_{u,j}$ merupakan rating yang diberikan oleh pengguna u terhadap item j , sedangkan U adalah himpunan pengguna yang memberikan rating pada kedua item tersebut. Nilai *cosine similarity* berada pada rentang -1 hingga 1, di mana nilai yang semakin mendekati 1 menunjukkan tingkat kemiripan yang semakin tinggi antara kedua item.

Setelah nilai kemiripan antaritem diperoleh, langkah berikutnya adalah memperkirakan nilai penilaian pengguna untuk item yang belum pernah dinilai. Dalam proses prediksi penilaian, nilai kemiripan digunakan sebagai bobot. Item dengan nilai kemiripan tertinggi dipilih sebagai tetangga terdekat untuk memperkirakan penilaian item yang belum pernah diberikan oleh pengguna. (Anwar et al., 2022). Persamaan prediksi rating ditunjukkan pada Persamaan (5).

$$\hat{r}_{ui} = \frac{\sum_{j \in N(i)} \text{Similarity}(i, j) \cdot r_{uj}}{\sum_{j \in N(i)} |\text{Similarity}(i, j)|} \quad (5)$$

dimana $\hat{r}_{ui}$ merupakan prediksi rating pengguna u terhadap item i , $\text{Similarity}(i, j)$ menunjukkan tingkat kemiripan antara item i dan item j , r_{uj} merupakan rating pengguna u terhadap item tetangga j , dan $N(i)$ adalah himpunan item yang memiliki tingkat kemiripan tertinggi terhadap item i .

Weighted Hybrid SVD++-KNN

Prediksi akhir diperoleh melalui pendekatan *weighted hybrid* dengan menggabungkan hasil prediksi SVD++ dan KNN menggunakan parameter bobot (α). Pendekatan ini bertujuan memanfaatkan keunggulan kedua algoritma sehingga mampu meningkatkan akurasi sistem rekomendasi dibandingkan dengan penggunaan metode tunggal (Pratama et al., 2025). Kombinasi kedua algoritma tersebut dinyatakan pada Persamaan (6)

$$\hat{r}_{ui}^{Hybrid} = \alpha \hat{r}_{ui}^{SVD++} + (1 - \alpha) \hat{r}_{ui}^{KNN} \quad (6)$$

dimana $\hat{r}_{ui}^{Hybrid}$ merupakan prediksi rating akhir yang dihasilkan oleh model hybrid, $\hat{r}_{ui}^{SVD++}$ merupakan prediksi rating yang dihasilkan oleh model SVD++, $\hat{r}_{ui}^{KNN}$ merupakan prediksi rating yang dihasilkan oleh model KNN, dan α merupakan parameter bobot yang mengatur kontribusi masing-masing model terhadap prediksi akhir.

Evaluasi Model

Evaluasi model dilakukan untuk mengetahui seberapa baik prediksi yang dihasilkan oleh algoritma SVD++-KNN. Dua metrik evaluasi digunakan dalam penelitian ini, yaitu *Root Mean Square*(RMSE) dan *Mean Absolute Error* (MAE). Kedua metrik ini digunakan karena keduanya mampu mengukur perbedaan antara nilai aktual dan nilai prediksi, sehingga memberikan gambaran kuantitatif tentang kinerja model. (Ma'ruf & Qoiriah, 2022).

Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) adalah metrik evaluasi yang mengukur prediksi dengan memberikan penalti yang lebih besar untuk kesalahan dengan perbedaan yang signifikan. Karena lebih sensitif terhadap kesalahan prediksi yang signifikan, RMSE banyak digunakan untuk mengevaluasi kinerja sistem rekomendasi. (Ramadhani et al., 2025). Perhitungan nilai RMSE ditunjukkan pada Persamaan (7).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (r_i - \hat{r}_i)^2}{n}} \quad (7)$$

dimana r_i merupakan rating aktual, $\hat{r}_i$ merupakan rating hasil prediksi, dan n menyatakan jumlah data yang dievaluasi.

Mean Absolute Error (MAE)

Penelitian ini juga menggunakan *Mean Absolute Error* (MAE) untuk menghitung rata-rata antara nilai prediksi dan nilai aktual tanpa memberikan penalti yang lebih berat untuk kesalahan tertentu. Nilai MAE yang lebih rendah menunjukkan bahwa hasil prediksi model lebih dekat dengan nilai sebenarnya (Aisyiah & Cahyani, 2024). Nilai MAE dihitung seperti yang ditunjukkan pada Persamaan (8).

$$MAE = \frac{\sum_{i=1}^n |r_i - \hat{r}_i|}{n} \quad (8)$$

dimana r_i merupakan rating aktual, $\hat{r}_i$ merupakan rating hasil prediksi, dan n menyatakan jumlah data yang dievaluasi.

III. HASIL DAN PEMBAHASAN

Konfigurasi Pengujian

Konfigurasi pengujian dilakukan untuk mengevaluasi kinerja metode *weighted hybrid* SVD++-KNN dalam menghasilkan sistem rekomendasi pada dua domain yang berbeda, yaitu MovieLens 1M sebagai representasi domain film dan Last.FM adalah representasi preferensi terhadap artis musik. Metode yang diusulkan diuji dengan membandingkannya dengan beberapa algoritma filtrasi kolaboratif, seperti SVD, KNN, SVD++, dan SVD-KNN. Tujuan dari proses evaluasi adalah untuk mengetahui kemampuan metode dalam membuat prediksi yang akurat pada dataset dengan berbagai karakteristik.

Sebelum proses pelatihan model, kedua dataset melalui tahap *pre-processing*. Kemudian, metode validasi *hold-out* digunakan untuk membagi data menjadi 80% data latih dan 20% data uji. Data latih digunakan untuk membuat model rekomendasi, sementara data uji digunakan untuk mengevaluasi kinerja model pada data yang belum pernah digunakan selama proses pelatihan. Tabel 1 menunjukkan karakteristik kedua dataset yang digunakan dalam penelitian ini.

Tabel 1. Karakteristik Dataset

Dataset	Jumlah Data	Data Latih	Data Uji	Sparsity
MovieLens 1M	1.000.209	800.167	200.042	0,964
Last.FM	92.834	74.267	18.567	0,9975

Berdasarkan Tabel 1, dataset MovieLens 1M memiliki tingkat *sparsity* sebesar 0,964, sedangkan dataset Last.FM memiliki tingkat *sparsity* sebesar 0,9975. Hal ini menunjukkan bahwa jumlah interaksi pengguna terhadap item pada dataset Last.FM lebih sedikit dibandingkan dengan MovieLens 1M. Perbedaan karakteristik ini digunakan untuk mengevaluasi konsistensi performa metode *weighted hybrid* SVD++-KNN dalam menghasilkan prediksi pada dataset dengan tingkat *sparsity* yang tinggi.

Evaluasi Prediksi Global

Evaluasi prediksi global dilakukan untuk mengevaluasi kemampuan metode *weighted hybrid* SVD++-KNN dalam memprediksi rating pengguna pada seluruh data uji. Pengujian dilakukan menggunakan metrik kesalahan rata-rata luas (RMSE) dan kesalahan absolut (MAE). Tingkat kesalahan prediksi yang lebih rendah menunjukkan nilai yang lebih rendah, yang berarti akurasi yang lebih tinggi. Pada titik ini, pengujian berbagai nilai parameter alfa (α) dilakukan untuk mengetahui seberapa besar kontribusi algoritma SVD++ dan KNN dalam menghasilkan prediksi akhir.

Tabel 2. Hasil Evaluasi RMSE dan MAE Pada MovieLens

Alpha	RMSE	MAE
0,1	0,9101	0,7159
0,2	0,8962	0,7053
0,3	0,8845	0,6963
0,4	0,8749	0,6888
0,5	0,8675	0,6828
0,6	0,8624	0,6786
0,7	0,8597	0,6759
0,8	0,8594	0,6747
0,9	0,8614	0,6749

Berdasarkan Tabel 2, kontribusi algoritma SVD++ lebih dominan dibandingkan dengan KNN dalam menghasilkan prediksi pada dataset MovieLens. Peningkatan nilai alpha berdampak pada penurunan nilai RMSE dan MAE hingga mencapai nilai optimum pada $\alpha = 0,8$, dengan nilai RMSE 0,8594 dan MAE 0,6747. Namun, ketika nilai alpha ditingkatkan menjadi 0,9, nilai RMSE kembali meningkat, meskipun hanya sedikit. Kondisi ini menunjukkan bahwa, untuk menghasilkan prediksi yang optimal, kontribusi KNN masih diperlukan guna menjaga keseimbangan model *weighted hybrid*.

Tabel 3. Hasil Evaluasi RMSE dan MAE Pada Last.FM

Alpha	RMSE	MAE
0,1	0,3200	0,2305
0,2	0,3084	0,2240
0,3	0,2980	0,2181
0,4	0,2889	0,2128
0,5	0,2810	0,2077
0,6	0,2743	0,2034
0,7	0,2691	0,1999
0,8	0,2653	0,1972
0,9	0,2632	0,1955

Berdasarkan Tabel 3, nilai RMSE dan MAE turun secara bertahap seiring dengan peningkatan nilai alpha, hingga mencapai nilai tertinggi pada $\alpha = 0,9$, yaitu 0,2632 untuk RMSE dan 0,1955 untuk MAE. Berbeda dengan MovieLens, nilai kesalahan pada rentang alpha yang diuji tidak meningkat. Hal ini menunjukkan bahwa dataset Last.FM dengan tingkat *sparsity* yang lebih tinggi lebih cocok dimodelkan menggunakan pendekatan berbasis *latent factor* melalui algoritma SVD++. Kontribusi SVD++ yang lebih besar dapat meningkatkan akurasi prediksi.

Secara keseluruhan, hasil analisis menunjukkan bahwa parameter alfa memengaruhi kinerja metode Hybrid Weighted SVD++–KNN. Nilai alpha optimum yang berbeda pada kedua

dataset menunjukkan bahwa proporsi kontribusi antara algoritma SVD++ dan KNN dalam menghasilkan prediksi dipengaruhi oleh karakteristik data, terutama tingkat *sparsity*. Oleh karena itu, memilih nilai alpha salah satu elemen yang sangat penting untuk meningkatkan ketepatan sistem rekomendasi.

Evaluasi Rekomendasi *Top-N*


Selain evaluasi prediksi global, penelitian ini juga melakukan evaluasi rekomendasi *Top-N* untuk membandingkan performa metode *weighted hybrid* SVD++-KNN dengan algoritma pembanding, yaitu SVD, KNN, SVD-KNN, SVD++, dan SVD++-KNN sebelum proses pengaturan hyperparameter. Untuk menilai skenario Top-5 dan Top-10, metrik *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE) digunakan. Tabel 4 menunjukkan hasil evaluasi kedua dataset.

Tabel 4. Hasil Evaluasi *Top-N* Pada Dataset MovieLens dan Last.FM


Dataset	Algorithm	RMSE		MAE	
		Top-5	Top-10	Top-5	Top-10
MovieLens 1 M	SVD	0,8182	0,8399	0,6240	0,6485
	KNN	0,8735	0,8903	0,6895	0,7005
	(SVD-KNN)	0,8070	0,8322	0,6420	0,6581
	SVD++	0,8048	0,8283	0,6058	0,6341
	(SVD++-KNN) Sebelum Tuning	0,7913	0,8175	0,6123	0,6362
	(SVD++-KNN) Setelah Tuning	0,7871	0,8121	0,6112	0,6336
Last.FM	SVD	0,2930	0,2732	0,2215	0,2039
	KNN	0,3657	0,3390	0,2625	0,2423
	(SVD-KNN)	0,2923	0,2730	0,2213	0,2041
	SVD++	0,2933	0,2753	0,2234	0,2064
	(SVD++-KNN) Sebelum Tuning	0,2929	0,2746	0,2231	0,2060
	(SVD++-KNN) Setelah Tuning	0,2908	0,2676	0,2190	0,1995

Temuan penelitian ini adalah metode *weighted hybrid* SVD++-KNN, setelah melalui *hyperparameter* tuning, mencapai nilai RMSE dan MAE terendah dibandingkan dengan metode lain pada kedua dataset. Selain itu, penelitian ini mengungkap bahwa karakteristik dataset, terutama tingkat *sparsity*, memengaruhi nilai alpha optimal serta kontribusi algoritma SVD++ dan KNN dalam menghasilkan prediksi yang akurat. Berdasarkan Tabel 4, metode *weighted hybrid* SVD++-KNN setelah *hyperparameter tuning* mencapai hasil terbaik pada kedua dataset. Metode ini mencapai nilai RMSE terendah sebesar 0,7871 pada skenario Top-5 dan 0,8121 pada

skenario Top-10 pada dataset MovieLens 1M. Di sisi lain, pada dataset Last.FM, dengan metode yang sama, mencapai nilai RMSE terendah sebesar 0,2908 pada skenario Top-5 dan 0,2676 pada skenario Top-10. Hasil menunjukkan bahwa proses *hyperparameter tuning* dapat menghasilkan prediksi yang lebih akurat dibandingkan dengan model sebelum dilakukan tuning. Selanjutnya, perbandingan nilai RMSE dan MAE pada skenario Top-5 dan Top-10 divisualisasikan menggunakan diagram batang pada Gambar 2 dan Gambar 3.



Gambar 2. Perbandingan RMSE dan MAE Top-5




Gambar 3. Perbandingan RMSE dan MAE Top-10

Berdasarkan Gambar 2 dan Gambar 3, setelah dilakukan *hyperparameter tuning*, metode *weighted* hybrid SVD++-KNN menurunkan nilai RMSE dan MAE dibandingkan dengan model sebelum tuning. Hasil tersebut menunjukkan kinerja optimasi parameter model dan menghasilkan rekomendasi yang lebih akurat pada kedua dataset.

Pembahasan Hasil penelitian

Untuk memberikan gambaran mengenai performa setiap algoritma, hasil evaluasi divisualisasikan menggunakan diagram batang pada Gambar 4.




Gambar 4. Perbandingan RMSE dan MAE pada Berbagai Algoritma

Berdasarkan Gambar 4, algoritma SVD++ menghasilkan kinerja yang lebih baik dibandingkan KNN karena mampu memanfaatkan *implicit feedback* serta mempelajari faktor laten antara pengguna dan item. Sebaliknya, karena KNN menggunakan *cosine similarity* untuk menghitung kemiripan antaritem, kinerja sangat dipengaruhi oleh banyaknya interaksi pengguna. Dalam dataset dengan tingkat *sparsity* tinggi, jumlah item dengan kemiripan yang memadai semakin berkurang, sehingga kinerja metode berbasis KNN cenderung menurun. Oleh karena itu, kontribusi SVD++ yang menggunakan faktor laten menjadi sangat penting dalam meningkatkan akurasi prediksi.

Setelah hyperparameter *tuning*, penggabungan algoritma SVD++-KNN menunjukkan hasil yang lebih baik dibandingkan dengan metode tunggal atau model sebelum tuning. Temuan ini menunjukkan bahwa kombinasi SVD++ dan KNN dapat memanfaatkan keunggulan masing-masing algoritma, sehingga menghasilkan prediksi yang lebih akurat. Hasil penelitian ini sejalan dengan temuan penelitian yang dilakukan oleh Wang et al. (2020) dan Harlianto et al. (2025), yang menemukan bahwa metode hybrid dapat meningkatkan kinerja sistem rekomendasi jika dibandingkan dengan menggunakan satu algoritma.


Implementasi Website

Model Weighted SVD++-KNN dengan parameter terbaik diterapkan pada aplikasi berbasis web yang menggunakan framework Flask. Website ini dibuat sebagai media untuk menampilkan hasil rekomendasi yang didasarkan pada prediksi model berdasarkan domain film dan preferensi artis musik. Website ini tidak hanya menawarkan fitur pencarian, tetapi juga menampilkan rekomendasi Top-5 dan Top-10 yang dibuat menggunakan Hybrid SVD++-KNN.



Gambar 5. Website Rekomendasi Film

Berdasarkan Gambar 5, website menyediakan detail film yang dipilih serta daftar rekomendasi Top-10 yang dibuat berdasarkan hasil prediksi metode *weighted hybrid* SVD++–KNN. Rekomendasi ini disusun berdasarkan skor prediksi tertinggi, sehingga pengguna dapat memperoleh daftar film yang sangat relevan dengan preferensi pengguna.



Gambar 6. Website Rekomendasi Music

Gambar 6 menunjukkan website daftar rekomendasi Top-10 artis musik berdasarkan hasil prediksi model terhadap data *play count* pengguna pada dataset Last.FM. Hasil implementasi menunjukkan bahwa metode *weighted hybrid* SVD++–KNN bekerja dengan baik pada kedua domain penelitian, yaitu film dan preferensi artis musik, sehingga pengguna dapat memperoleh rekomendasi secara interaktif melalui aplikasi berbasis web. Sistem ini telah diimplementasikan secara daring dan dapat diakses melalui tautan: <https://sistem-rekomendasi-beige.vercel.app/>

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa metode *weighted hybrid* SVD++–KNN mampu menghasilkan sistem rekomendasi yang konsisten pada dataset MovieLens 1M dan Last.FM serta

berhasil diimplementasikan pada aplikasi berbasis web. Implementasi menggunakan dua dataset, yaitu MovieLens 1M dan Last.FM, yang berhasil diintegrasikan ke dalam website sehingga pengguna dapat memperoleh rekomendasi interaktif berdasarkan hasil prediksi model.

Metode weighted hybrid menunjukkan hasil yang lebih baik setelah penyesuaian hyperparameter, berdasarkan evaluasi menggunakan metrik Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE). Selain itu, hasil penelitian ini menunjukkan bahwa atribut dataset memengaruhi nilai alpha secara signifikan. Dengan demikian, penentuan bobot yang tepat dapat meningkatkan ketepatan sistem rekomendasi pada domain film dan preferensi artis musik.

Keterbatasan penelitian ini adalah pengujian yang hanya dilakukan pada dua dataset, yaitu MovieLens 1M dan Last.FM, serta menggunakan metrik evaluasi RMSE dan MAE. Sebagai tindak lanjut, penelitian berikutnya dapat membandingkan metode weighted hybrid SVD++–KNN dengan pendekatan hybrid lain atau teknik berbasis deep learning, serta menggunakan dataset yang lebih beragam. Selain itu, menambahkan metrik evaluasi seperti Precision, Recall, dan Normalized Discounted Cumulative Gain (NDCG) akan memberikan gambaran performa sistem rekomendasi yang lebih lengkap.

DAFTAR PUSTAKA

- Aisyiah, J., & Cahyani, L. (2024). Sistem Rekomendasi Program Studi Menggunakan Metode Hybrid Recommendation (Studi Kasus: MAN Sumenep). *Jurnal Eksplora Informatika*, 12(1), 59–72. <https://doi.org/10.30864/eksplora.v12i1.992>
- Amiri, B., Shahverdi, N., Haddadi, A., & Ghahremani, Y. (2024). Beyond the Trends: Evolution and Future Directions in Music Recommender Systems Research. *IEEE Access*, 12, 51500–51522. <https://doi.org/10.1109/ACCESS.2024.3386684>
- Anwar, T., Uma, V., Hussain, Md. I., & Pantula, M. (2022). Collaborative Filtering and kNN based recommendation to overcome cold start and sparsity issues: A comparative analysis. *Multimedia Tools and Applications*, 81(25), 35693–35711. <https://doi.org/10.1007/s11042-021-11883-z>
- Ekstrand, M. D., Carterette, B., & Diaz, F. (2024). Distributionally-Informed Recommender System Evaluation. *ACM Transactions on Recommender Systems*, 2(1), 1–27. <https://doi.org/10.1145/3613455>
- Harlianto, R., Saifudin, I., & Suharso, W. (2025). Implementasi Sistem Rekomendasi Film Berbasis Website Menggunakan Pendekatan Collaborative Filtering dengan Metode Weighted Hybridization (SVD-KNN). *Skripsi. Universitas Muhammadiyah Jember*. <https://repository.unmuhjember.ac.id/id/eprint/27243>
- Hssina, B., Grotta, A., & Erritali, M. (2021). Recommendation system using the K-Nearest Neighbors and singular value decomposition algorithms. *International Journal of Electrical and Computer Engineering (IJECE)*, 11(6), 5541. <https://doi.org/10.11591/ijece.v11i6.pp5541-5548>
- Kouki, P., Schaffer, J., Pujara, J., O'Donovan, J., & Getoor, L. (2020). Generating and Understanding Personalized Explanations in Hybrid Recommender Systems. *ACM Transactions on Interactive Intelligent Systems*, 10(4), 1–40. <https://doi.org/10.1145/3365843>

- Kumar, J., Patra, B. K., Sahoo, B., & Babu, K. S. (2023). Group recommendation exploiting characteristics of user-item and collaborative rating of users. *Multimedia Tools and Applications*, 83(10), 29289–29309. <https://doi.org/10.1007/s11042-023-16799-4>
- Ma'ruf, M. A., & Qoiriah, A. (2022). Perbandingan Algoritma Cosine Similarity dan Euclidean Distance pada Sistem Rekomendasi Film dengan Metode Item-Based Collaborative Filtering. *Journal of Informatics and Computer Science (JINACS)*, 04, 160–168. <https://doi.org/10.26740/jinacs.v4n02.p160-168>
- Muflih, M., Ratna, S., & Mahalisa, G. (2025). Development of A Collaborative Recommendation System Based on Singular Value Decomposition (SVD) on E-Commerce Data. *Journal of Applied Informatics and Computing*, 9(6), 3769–3773. <https://doi.org/10.30871/jaic.v9i6.11688>
- Pratama, R. A., Safi'i, Y., Nugraha, M. A., Sobihah, A. S., & Ifada, N. (2025). Perbandingan User-Based dan Item-Based pada Sistem Rekomendasi Film Kombinasi Teknik Reduksi Dimensi dan Clustering. *Jurnal Tekno Insentif*, 19(1), 1–14. <https://doi.org/10.36787/jti.v19i1.1662>
- 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>
- Vahidi Farashah, M., Etebarian, A., Azmi, R., & Ebrahimzadeh Dastjerdi, R. (2021). A hybrid recommender system based-on link prediction for movie baskets analysis. *Journal of Big Data*, 8(1), 32. <https://doi.org/10.1186/s40537-021-00422-0>
- Wang, S., Sun, G., & Li, Y. (2020). SVD++ Recommendation Algorithm Based on Backtracking. *Information*, 11(7), 369. <https://doi.org/10.3390/info11070369>
- Widiyaningtyas, T., Saifudin, I., Zaeni, I. A. E., Maulana, Moh. 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), 289. <https://doi.org/10.1007/s44443-025-00261-6>
- Zhang, Z., Patra, B. G., Yaseen, A., Zhu, J., Sabharwal, R., Roberts, K., Cao, T., & Wu, H. (2023). Scholarly recommendation systems: a literature survey. *Knowledge and Information Systems*, 65(11), 4433–4478. <https://doi.org/10.1007/s10115-023-01901-x>