

SISTEM REKOMENDASI PEMILIHAN ANIME MENGGUNAKAN USER-BASED COLLABORATIVE FILTERING

Nazhif Muafa Roziqin¹⁾, M. Faisal²⁾

1. Universitas Islam Negeri Maulana Malik Ibrahim Malang, Indonesia
2. Universitas Islam Negeri Maulana Malik Ibrahim Malang, Indonesia

Article Info

Kata Kunci: Sistem Rekomendasi; User-Based Collaborative Filtering; Data Science; Anime; Machine Learning

Keywords: Recommendation System; User-Based Collaborative Filtering; Data Science; Anime; Machine Learning

Article history:

Received 27 November 2023

Revised 11 December 2023

Accepted 25 December 2023

Available online 1 March 2024

DOI :

<https://doi.org/10.29100/jipi.v9i1.4222>

* Corresponding author.

Nazhif Muafa Roziqin

E-mail address:

200605110160@student.uin-malang.ac.id

ABSTRAK

Dalam era digital saat ini, banyak orang memiliki akses ke internet dan menikmati menonton anime sebagai hiburan. Namun, dengan banyaknya pilihan anime yang tersedia, seringkali sulit bagi seseorang untuk memilih anime yang ingin ditonton. Oleh karena itu, diperlukan sistem rekomendasi yang dapat membantu pengguna dalam memilih anime sesuai dengan preferensinya. Penelitian ini menggunakan metode User-based collaborative filtering (UCF) dalam pembuatan sistem rekomendasi anime. Metode UCF menggunakan kesamaan preferensi antara pengguna untuk merekomendasikan anime kepada pengguna lain. Dalam penelitian ini, data anime dan data rating pengguna diperoleh dari platform Kaggle.com. Tahapan penelitian meliputi pengumpulan data, pembersihan data, pemodelan machine learning, pemberian rekomendasi, dan penampilan hasil rekomendasi. Evaluasi kinerja dilakukan dengan menggunakan metode Mean Absolute Error (MAE). Hasil penelitian ini adalah sebuah sistem rekomendasi anime yang dapat memberikan rekomendasi 5 anime teratas berdasarkan preferensi pengguna. Evaluasi kinerja menunjukkan bahwa sistem rekomendasi ini memiliki MAE sebesar 2.9449, yang menunjukkan kualitas yang baik. Dengan demikian, sistem rekomendasi ini dapat membantu pengguna dalam memilih anime yang sesuai dengan preferensi mereka.

ABSTRACT

In today's digital age, many people have access to the internet and enjoy watching anime as entertainment. However, with so many anime options available, it is often difficult for someone to choose the anime they want to watch. Therefore, a recommendation system is needed that can assist users in choosing anime according to their preferences. This research uses the User-based collaborative filtering (UCF) method in creating an anime recommendation system. The UCF method uses the similarity of preferences between users to recommend anime to other users. In this research, anime data and user rating data are obtained from the Kaggle.com platform. The research stages include data collection, data cleaning, machine learning modelling, recommendation giving, and recommendation result display. Performance evaluation is carried out using the Mean Absolute Error (MAE) method. The result of this research is an anime recommendation system that can provide recommendations for the top 5 anime based on user preferences. The performance evaluation shows that this recommendation system has an MAE of 2.9449, which indicates good quality. Thus, this recommendation system can assist users in selecting anime that match their preferences.

I. PENDAHULUAN

DALAM era digital seperti sekarang, hampir semua orang memiliki akses ke internet dan banyak orang yang gemar menonton anime sebagai bentuk hiburan. Namun, dengan begitu banyaknya pilihan anime yang tersedia di dunia maya, seringkali sulit bagi seseorang untuk memilih anime mana yang ingin ditonton. Oleh karena itu, dibutuhkan suatu sistem rekomendasi yang dapat membantu pengguna dalam memilih anime sesuai dengan preferensinya. Anime adalah sebutan untuk animasi atau gambaran yang dibuat di Jepang, dengan gaya penggambaran yang unik dibandingkan dengan animasi dari negara lain. Anime sering memiliki ciri-ciri seperti mata yang cukup besar, mulut yang lebih kecil, dan hidung yang lebih mancung. Anime dapat berupa komik atau gambaran, serta video dengan durasi sekitar 24 menit per episode[1].

Anime semakin dikenal di luar Jepang, terlihat dari banyaknya judul anime yang tersedia di situs-situs terkenal seperti Netflix, Amazon Prime, dan Google Play[2]. Selain itu, terdapat juga banyak acara pameran anime seperti Anime Expo, Anime Matsuri, dan Comic Fest yang menunjukkan popularitasnya di kalangan penggemar anime[3].

Pada tahun 2021, sebanyak 18.350 anime telah rilis, termasuk anime yang belum tamat dan sudah tamat. Anime mencakup beberapa genre tertentu seperti shojo untuk penonton wanita dan shonen untuk pria. Banyaknya genre membuat penonton merasa bingung untuk memilih anime yang sesuai dengan preferensi mereka. Oleh karena itu diperlukan suatu sistem yang dapat menawarkan rekomendasi anime kepada pengguna sebagai solusi untuk membantu mereka memilih anime yang akan ditonton[4].

Collaborative filtering adalah Teknik yang paling banyak digunakan pada sistem rekomendasi [5] Algoritma ini juga banyak digunakan dalam sistem komersial[6]. Metode-metode sistem rekomendasi secara garis besar dapat dibagi menjadi beberapa kategori sebagai berikut: collaborative filtering (CF), content-based filtering (CB filtering), dan metode hibrida [7]. Metode yang akan digunakan dalam penelitian ini adalah user-based collaborative filtering (UCF). UCF merupakan metode filtrasi kolaboratif dimana sistem merekomendasikan item kepada pengguna berdasarkan kesamaan preferensi antara pengguna tersebut dengan pengguna lainnya[8]. Dengan menggunakan teknik ini, diharapkan bahwa hasil rekomendasi akan lebih akurat dan relevan dengan preferensi setiap individu.

Pada beberapa penelitian sebelumnya telah dilakukan untuk mengembangkan sistem rekomendasi anime menggunakan algoritma user-based collaborative filtering. Pada penelitian oleh Arfiani Nur Khusna, dkk. merancang sistem rekomendasi untuk pemilihan gadget shield dengan menggunakan user-based collaborative filtering. Berdasarkan hasilnya, disimpulkan bahwa telah dibuat sistem rekomendasi gadget shield yang mampu memberikan rekomendasi produk terhadap user. Sistem rekomendasi tersebut telah diuji oleh 20 user sistem dengan menggunakan questioner *User Acceptance Test* (UAT). Hasil pengujian UAT menunjukkan bahwa sistem rekomendasi berbasis Collaborative Filtering yang diimplementasikan memiliki kelayakan pakai sebesar 86.86%. Selain itu, sistem juga berhasil menghasilkan akurasi rekomendasi sebesar 90.08% berdasarkan pengujian RMSE.

Pada Penelitian terdahulu oleh Glenn Ferio, dkk. yang berjudul "Sistem Rekomendasi Mata Kuliah Pilihan Menggunakan Metode User Based Collaborative Filtering Berbasis Algoritma Adjusted Cosine Similarity". Dari penelitian tersebut melibatkan perancangan sistem, implementasi, dan pengujian sebuah aplikasi. Hasilnya menunjukkan bahwa algoritma Adjusted Cosine Similarity sangat sesuai digunakan untuk data dengan nilai subjektif seperti nilai mata kuliah dan nilai rating. Sementara itu, algoritma Cosine Similarity lebih baik digunakan untuk data tanpa nilai subjektif, seperti kemiripan teks berdasarkan kata-kata dalam teks. Kelebihan dari algoritma Adjusted Cosine Similarity adalah kemampuannya dalam memprediksi mahasiswa dengan nilai rata-rata tinggi yang berpotensi memiliki nilai rata-rata rendah. Namun, algoritma Adjusted Cosine Similarity dengan filter K-Nearest Neighbors memiliki kelemahan, di mana prediksi mata kuliah hanya bisa dilakukan jika mata kuliah pilihan sudah diambil oleh mahasiswa pada daftar Top-K Similarity yang ditentukan. Selain itu, konversi nilai mahasiswa dari kurikulum lama ke kurikulum baru masih terbatas pada tabel yang dibuat oleh Admin, yang mengharuskan pengetahuan Admin untuk menentukan daftar mata kuliah yang mempelajari studi yang sama dalam kurikulum yang berbeda[10].

Pada penelitian dari I Dewa Agung Cahya Putra dalam artikelnya berjudul "Sistem Rekomendasi Anime dengan Metode Content Based Filtering". Dari artikel tersebut, dibuat sistem rekomendasi anime menggunakan content-based filtering dengan TF-IDF dan cosine similarity. Fitur "genre" digunakan sebagai parameter. Evaluasi model menunjukkan presisi 88.1%, tetapi saat diintegrasikan ke website, presisi turun menjadi 72.8%. Diperlukan penyesuaian dan peningkatan performa model[11].

Pada artikel jurnal ini nantinya akan dibahas tentang konsep dasar dari UCF serta implementasinya dalam pembuatan sistem rekomendasi pemilihan anime. Dalam penelitian ini, akan diimplementasikan pivot tabel dan tambahan metode pearson correlation. Selain itu juga akan dilakukan evaluasi terhadap kinerja dari sistem tersebut melalui beberapa percobaan dan perbandingan terhadap metode-metode lainnya[9].

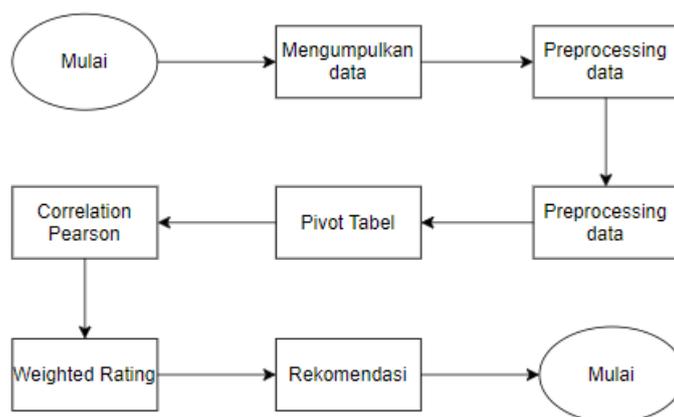
II. METODE PENELITIAN

User collaborative filtering (UCF) merupakan metode pendekatan dalam sistem rekomendasi yang dapat menyaring item yang mungkin disukai pengguna berdasarkan rekasi pengguna lain yang memiliki selera serupa. Teknik bekerja dengan mencari sekelompok besar orang dan menemukan sekelompok kecil pengguna tertentu. Lalu Teknik ini melihat item yang mereka sukai lalu menggabungkannya untuk membuat daftar saran.

Dalam penelitian ini, metode user-based collaborative filtering digunakan untuk memberikan rekomendasi pemilihan anime kepada pengguna[12]. user based filtering menggunakan teknik statistika untuk mengidentifikasi hubungan antara pengguna yang memiliki kesamaan dalam menilai anime. Sistem akan menemukan pengguna

dengan korelasi yang tinggi berdasarkan preferensi anime mereka, dan kemudian merekomendasikan anime kepada pengguna dengan selera yang sama[13].

Dalam model user-based collaborative filtering, preferensi anime pengguna diolah untuk mendapatkan data pengguna. Jika dua orang memiliki preferensi yang sama, maka mereka memiliki selera yang serupa terhadap anime, jadi anime yang disukai oleh orang tersebut akan direkomendasikan kepada orang lain yang memiliki selera yang serupa. Artikel ini bertujuan untuk memberikan rekomendasi pemilihan anime yang sesuai dengan preferensi pengguna berdasarkan kesamaan preferensi pengguna dengan menggunakan metode filtering berbasis pengguna[13].



Gambar. 1. Teknik analisis data dengan User Collaborative Filtering

A. Pengumpulan Data

Pada tahap ini dilakukan proses pencarian dan pengumpulan dataset. Dataset pada penelitian ini diperoleh dari platform Kaggle.com dengan mengumpulkan beberapa dataset dalam bentuk csv. Kaggle merupakan situs/platform yang resmi untuk mengadakan perlombaan-perlombaan di bidang Data Science, situs ini juga merupakan sumber belajar Data Science[14]. Dataset tersebut berupa data anime dan data rating dari penonton anime tersebut. Tujuan dari tahap ini adalah untuk mengumpulkan data guna membangun sistem rekomendasi.

B. Preprocessing data

Tahap ini merupakan tahap persiapan sebelum dilakukan analisis data. Tahap ini melibatkan pembersihan data untuk mengatasi masalah seperti nilai yang hilang, duplikasi, atau outlier. Data yang telah dikumpulkan perlu diproses agar siap untuk digunakan dalam membangun model rekomendasi. Beberapa langkah yang dapat dilakukan antara lain menghilangkan nilai yang hilang, menghilangkan duplikasi, atau melakukan normalisasi data. Namun, dalam penelitian ini, fokusnya hanya pada penghapusan missing value atau data yang tidak terdefinisi (NaN) serta penghapusan tabel-tabel yang dianggap tidak relevan untuk menyederhanakan proses pengolahan data.

C. Pivot Table

Pivot tabel merupakan salah satu teknik dalam analisis data yang digunakan untuk mengubah struktur data tabular menjadi bentuk yang lebih terstruktur dan mudah dipahami. Pivot dapat membantu dalam proses data rating sehingga dapat digunakan dalam sebuah model. Pivot adalah suatu teknik dalam pengolahan data yang digunakan untuk mengubah bentuk data dari baris menjadi kolom atau sebaliknya. Dalam user-based collaborative filtering, pivot digunakan untuk mengubah data rating dari bentuk baris menjadi bentuk kolom sehingga dapat digunakan dalam pembuatan model[15]

D. Correlation Pearson

Correlation Pearson adalah sebuah metode statistik yang digunakan untuk mengukur hubungan linier antara dua variabel. Ini adalah salah satu metode yang paling umum digunakan untuk mengevaluasi hubungan antara dua variabel kontinu. Metode ini dinamai dari Karl Pearson, seorang ahli statistik Inggris yang memperkenalkannya pada awal abad ke-20.

Correlation Pearson menghasilkan koefisien korelasi antara -1 hingga 1. Koefisien korelasi 1 menunjukkan hubungan positif sempurna, sedangkan -1 menunjukkan hubungan negatif sempurna. Jika koefisien korelasi mendekati 0, itu menunjukkan tidak ada hubungan linier antara variabel tersebut.

E. *Weighted Rating*

Weighted Rating merupakan hasil perkalian dari nilai korelasi antar pengguna dan nilai rating anime yang telah diberikan. Dengan menggunakan *weighted rating*, pengguna acak dapat menerima rekomendasi anime yang relevan berdasarkan kesesuaian preferensi dengan pengguna lain yang memiliki korelasi tinggi.

Dengan menggunakan *weighted rating*, rekomendasi anime dapat disesuaikan dengan preferensi pengguna acak berdasarkan kesamaan preferensi dengan pengguna lain yang memiliki korelasi tinggi. Anime-anime dengan *weighted rating* tinggi akan dianggap lebih sesuai dan lebih mungkin direkomendasikan kepada pengguna acak.

F. *Rekomendasi*

Pada tahap ini akan ditampilkan hasil rekomendasi sistem kepada user. Beberapa rekomendasi diberikan berdasarkan pada kesamaan seleara random user dari tingkat kesamaan yang paling tinggi hingga top 5 rekomendasi berdasarkan user random tersebut.

G. *Evaluasi*

Pada tahap ini program akan di evaluasi dengan menggunakan *Mean Average Precision* (MAP). MAP merupakan metrik yang digunakan untuk mnegukur kualitas suatu sistem peringkat atau model yang memberikan urutan terhadap sejumlah item. MAP menggambarkan sejauh manásistem tersebut dalam keberhasilan dalam menempatkan item yang relevan pada posisi teratas.

III. HASIL DAN PEMBAHASAN

A. *Hasil Pengumpulan Data*

Setelah melakukan pencarian dataset, diperoleh dataset anime dan rating dari user kepada anime tersebut yang terdiri dari :

- 1) *Anime.csv* : berisi informasi tentang daftar anime. Berisi genre, judul, type, dan rating anime tersebut
- 2) *Rating.csv* : berisi data rating user kepada daftar anime yang telah diberikan oleh *Anime.csv*

Dataset-dataset ini merupakan data utama yang penting untuk melakukan rekoemendasi

B. *Preprocessing Data*

Setelah melakuakn pengumpulan data, dilakukan proses penyiapan data. Data-data yang tidak digunakan akan dibuang. Contoh pada penelitian ini adalah anime yang tidak memiliki rating oleh user akan dihapus kemudian datasetnya digabung ke dalam sebuah dataframe df dengan menggunakan "anime_id". Sehingga pada tahap ini dihasilkan hasil akhir seperti pada tabel 1.

TABEL I
 DESKRIPSI SETELAH PROSES PREPROCESSING DATA

Index	Anime_id	Rating_x	User_id	Rating_y	Members
Count	6339607.0	6339374.0	6337239.0	6337239.0	6339607.0
mean	8908.833035864842	7.674397984722152	36747.914720432	7.8084965708252	184506.11148246
std	8887.263343301913	0.6709264403766532	665	44	255
min	1.0	1.67	21013.406377312	1.5724961361706	190950.39618470
25%	1239.0	7.29	163	773	97
50%	6213.0	7.7	1.0	1.0	5.0
75%	14123.0	8.15	18984.0	7.0	46781.0
max	34527.0	10.0	36815.0	8.0	117091.0
			54873.0	9.0	256325.0
			73516.0	10.0	1013917.0

C. *Pivot Table*

Pada tahap ini anime yang memiliki total rating kurang dari 1000 akan dihapus dari data. Kemudian untuk Menyusun ulang data dalam bentuk yang lebih sesuai untuk perhitungan *correlation pearson*, dibuatlah sebuah pivot tabel dengan menggunakan fungsi *pivot_table* pada Pandas. Pivot tabel tersebut digunakan untuk menyusun data rating anime berdasarkan *user_id* sebagai indeks, *anime_id* sebagai kolom, dan *rating* sebagai nilai. Pivot tabel ini memungkinkan pengelompokkan user dan anime yang ditonton.

Hasil dari pivot tabel adalah sebuah dataFrame yang berisi rating anime oleh setiap user. Setiap baris mewakili user (*user_id*) dan setiap kolom mewakili anime yang ditonton (*anime_id*) dengan nilai rating yang diberikan oleh pengguna. Contoh hasil dari pivot tabel ditunjukkan pada gambar 2.

anime_id	1	5	6	7	15	16	18	19	20	22
user_id										
1.00000	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
2.00000	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN
3.00000	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	8.00000	NaN
5.00000	NaN	NaN	8.00000	NaN	6.00000	NaN	6.00000	NaN	6.00000	5.00000
7.00000	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	7.00000

Gambar. 2 Pivot *common_movie*

D. Correlation Person

Setelah dipilih pengguna acak sebagai pengguna referensi, langkah selanjutnya adalah mengidentifikasi anime-anime yang telah ditonton oleh pengguna acak tersebut. Dalam implementasi kode di atas, ini dilakukan dengan mencari kolom-kolom dalam pivot table *common_movie* yang memiliki nilai tidak NaN untuk pengguna acak tersebut.

Setelah anime-anime yang ditonton oleh pengguna acak telah diidentifikasi, langkah selanjutnya adalah menghitung korelasi Pearson antara pengguna acak tersebut dengan pengguna lain dalam hal preferensi anime. Ini dilakukan dengan membangun DataFrame baru yang berisi rating anime yang ditonton oleh pengguna acak dan pengguna-pengguna lain yang juga telah menonton sebagian besar anime yang ditonton oleh pengguna acak. DataFrame ini disebut *final_df*.

Selanjutnya, DataFrame *final_df* diubah menjadi bentuk korelasi dengan menggunakan metode *corr()* dengan metode Pearson sebagai parameternya. Hasilnya adalah DataFrame *corr_df* yang berisi pasangan pengguna dan nilai korelasi Pearson antara mereka seperti pada tabel 2. DataFrame ini kemudian diurutkan dan nilai-nilai duplikat dihapus.

TABEL II
TABEL DATAFRAME FINAL_DF

no	User_id_1	User_id_2	corr
0	51562	29013	-0.75104
1	49586	5056	-0.74118
2	60526	54170	-0.71361
3	7904	60526	-0.71027
4	5056	67082	-0.70725
....			

Setelah itu, pengguna-pengguna yang memiliki nilai korelasi Pearson di atas 0.50 dipilih sebagai pengguna teratas. DataFrame *top_users* berisi pasangan pengguna dengan nilai korelasi di atas ambang batas tersebut. DataFrame ini kemudian digunakan untuk melakukan penilaian pada anime-anime yang telah ditonton oleh pengguna-pengguna teratas. Seperti ditunjukkan pada tabel 3.

TABEL III
TABEL DATAFRAME TOP_USERS

no	User_id_1	User_id	corr	Anime_id	Rating
0	10965	57823	0.50020	1	10
1	10965	57823	0.50020	5	10
2	10965	57823	0.50020	6	9
3	10965	57823	0.50020	18	9
4	10965	57823	0.50020	20	7

E. Weighted Rating

Weighted Rating digunakan untuk memberikan bobot pada nilai rating anime berdasarkan tingkat korelasi (*corr*) antara pengguna dan nilai rating anime yang telah diberikan. Pada penelitian ini, pengguna dengan korelasi yang lebih tinggi memiliki pengaruh yang lebih besar dalam menentukan nilai *weighted rating*. Sebagai contoh, ketika pengguna acak memiliki korelasi yang tinggi dengan pengguna lain yang memberikan rating tinggi kepada suatu anime, maka *weighted rating* dari anime tersebut akan cenderung tinggi. Sebaliknya jika pengguna acak memiliki korelasi yang rendah dengan pengguna lain yang memberikan rating rendah kepada anime tersebut, maka nilai *weighted rating* akan cenderung rendah.

Pada tahap pertama, DataFrame ``top_users_rating`` dibentuk dengan menggabungkan DataFrame ``top_users`` dengan DataFrame ``rating``. Hal ini dilakukan untuk memperoleh data rating anime yang diberikan oleh pengguna-pengguna teratas yang memiliki korelasi Pearson tinggi dengan pengguna acak. DataFrame ini terdiri dari kolom-kolom seperti `user_id`, `anime_id`, `rating`, dan `corr`.

Setelah itu, pada tahap kedua, dilakukan penambahan kolom baru bernama "weighted_rating" ke DataFrame ``top_users_rating``. Kolom ini dihasilkan dengan mengalikan nilai korelasi antara pengguna dengan nilai rating anime yang telah diberikan. Langkah ini memberikan bobot pada rating berdasarkan tingkat korelasi dengan pengguna acak. Tabel 4 menunjukkan DataFrame ``top_users_rating`` setelah penambahan kolom "weighted_rating".

TABEL IV
 TABEL DATAFRAME TOP USERS RATING SETELAH PENAMBAHAN WEIGHTTED RATING

no	User_id_1	User_id	corr	Anime_id	Rating	Weighted_rating
0	10965	57823	0.50020	1	10	5.00199
1	10965	57823	0.50020	5	10	5.00199
2	10965	57823	0.50020	6	9	4.50179
3	10965	57823	0.50020	18	9	4.50179
4	10965	57823	0.50020	20	7	3.50139

Pada tahap ketiga, DataFrame ``top_users_rating`` dikelompokkan berdasarkan `anime_id` dan dilakukan perhitungan rata-rata dari kolom "weighted_rating". Hasilnya disimpan dalam DataFrame ``recommendation_df``. DataFrame ini berisi rata-rata weighted rating untuk setiap anime yang direkomendasikan. Tabel 2 menunjukkan contoh dari DataFrame ``recommendation_df`` seperti pada tabel 5.

TABEL V
 TABEL DATAFRAME RECOMMENDATION_DF

no	Anime_id	Weighted_rating
0	1	5.47145
1	5	5.10854
2	6	4.99204
3	7	4.31107
4	8	3.83513

Selanjutnya, pada tahap keempat, anime-anime yang memiliki nilai rata-rata weighted rating di atas 5.5 dipilih dari DataFrame ``recommendation_df``. Anime-anime ini diurutkan berdasarkan nilai weighted rating secara menurun. Hasilnya disimpan dalam DataFrame ``movies_to_be_recommend``. Tabel 6 menunjukkan contoh dari DataFrame ``movies_to_be_recommend``.

TABEL VI
 TABEL DATAFRAME MOVIES TO BE RECOMMEND

no	Anime_id	Weighted_rating
3945	6579	6.95078
5502	14129	6.28995
5107	11189	6.25570
1647	1839	6.00122
3247	4398	5.99076

F. Rekomendasi

Pada tahap ini akan ditampilkan hasil akhir dari rekomendasi. Pada tahap ini DataFrame `movies_to_be_recommended` digabungkan dengan DataFrame `movie` untuk mendapatkan nama anime yang direkomendasikan. Hasilnya disimpan dalam DataFrame `recommended_anime`. Tabel 7 menunjukkan contoh dari DataFrame `recommended_anime`.

TABEL VII
 TABEL DATAFRAME RECOMMENDED ANIME

no	Anime_id	Weighted_rating	Nama Anime
0	6579	6.95078	Chikyuu Bouei Kazoku
1	14129	6.28995	Starless: 21 st Century
2	11189	6.25570	Pair
3	1839	6.00122	Jaginu-kun
4	4398	5.99076	Kuro Nyago
62	7158	5.53745	Dr. Slump Movie 09
63	4714	5.52966	The Rapeman
64	19291	5.52240	Pokemon XY
65	17873	5.52240	Pokemon Best Wishes Season 2
66	17115	5.52240	Pokemon Best Wishes

G. Evaluasi

Pada tahap ini dilakukan proses analisis kinerja rekomendasi dengan menggunakan MAP. MAP adalah singkatan dari *Mean Average Precision*. MAP adalah salah satu metode evaluasi yang umum digunakan dalam data science. MAP digunakan untuk mengukur sejauh mana rekomendasi yang diberikan relevan bagi pengguna. Perhitungan MAP pada penelitian ini menggunakan *loop for* dan mendapatkan nilai 0.0368 yang jika di persenkan menjadi 3.68% sehingga bisa dikatakan rekomendasi sistem pemilihan anime dengan menggunakan pivot dan correlation pearson saat ini jauh lebih rendah persentasinya jika dibandingkan dengan menggunakan hybrid Content Based Collaborative Filtering yang telah dilakukan sebelumnya dan mendapatkan nilai 40 persen.

IV. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan tentang pembuatan sistem rekomendasi pemilihan anime dengan metode User-based collaborative filtering, didapatkan hasil berupa sistem rekomendasi yang mampu memberikan rekomendasi anime kepada pengguna berdasarkan rating dari pengguna lain. Sistem ini dapat memberikan rekomendasi anime 5 besar yang sesuai dengan minat pengguna berdasarkan data pengguna, rating, dan genre anime. Selain itu, sistem ini juga mempertimbangkan data audiens historis dan preferensi pengguna untuk menghasilkan rekomendasi yang relevan dan sesuai dengan minat pengguna.

Penelitian ini diharapkan dapat memberikan manfaat yang signifikan bagi pecinta anime dalam menemukan anime yang sesuai dengan preferensi mereka. Selain itu, penelitian ini juga berpotensi untuk meningkatkan pengalaman menonton anime dan memperluas pengetahuan pengguna tentang anime yang mungkin belum mereka ketahui sebelumnya. Namun penelitian ini masih merupakan model yang perlu dikembangkan lebih lanjut menjadi sistem informasi yang dapat diimplementasikan baik berbasis website maupun aplikasi mobile. Dengan demikian, diharapkan penelitian selanjutnya dapat mengembangkan sistem rekomendasi ini menjadi lebih kompleks dan dapat memberikan pengalaman yang lebih baik bagi pengguna dalam memilih anime sesuai dengan minat dan preferensinya.

UCAPAN TERIMA KASIH

Kami ingin menyampaikan terima kasih yang tulus kepada seluruh tim penelitian atas kerja sama, dedikasi, dan kontribusi yang mereka berikan dalam memperkaya penelitian ini. Kolaborasi yang erat dan semangat tim ini telah membantu mengatasi berbagai tantangan yang kami hadapi selama penelitian. Kami juga ingin mengucapkan terima kasih yang sebesar-besarnya kepada keluarga dan teman-teman kami yang memberikan dukungan moral dan motivasi selama proses penelitian ini. Dukungan emosional dan pemahaman yang mereka berikan telah memberi kami kekuatan untuk terus maju dan mengatasi setiap rintangan. Tanpa kerjasama dan kontribusi mereka, penelitian ini tidak akan berhasil. Kami mengucapkan terima kasih sekali lagi atas segala upaya dan kebaikan yang telah diberikan.

DAFTAR PUSTAKA

- [1] L. Aeschliman, "WHAT IS ANIME?," <http://www.bellaonline.com/articles/art4260.asp>, 2022.
- [2] I. Aisyah, "ANIME DAN GAYA HIDUP MAHASISWA," 2019. Accessed: Jun. 06, 2023. [Online]. Available: <https://repository.uinjkt.ac.id/dspace/handle/123456789/45316>
- [3] I. Jayaperwira, A. T. Wibowo, and D. Nurjanah, "Anime rekomendasi menggunakan Collaborative Filtering," Accessed: Jun. 06, 2023. [Online]. Available: https://openlibrary.telkomuniversity.ac.id/pustaka/files/185894/jurnal_eproc/anime-rekomendasi-menggunakan-collaborative-filtering.pdf
- [4] R. P. Raharjo, V. A. Permadi, and N. H. Cahyana, "SISTEMASI: Jurnal Sistem Informasi Pengembangan Model k-NN Collaborative Filtering pada Pendekatan User-Based untuk Sistem Rekomendasi Improvement of KNN Collaborative Filtering Model in User-based Approach on Anime Recommendation System," 2023. [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [5] L. Tommy, C. Kirana, and V. Lindawati, "RECOMMENDER SYSTEM DENGAN KOMBINASI APRIORI DAN CONTENT-BASED FILTERING PADA APLIKASI PEMESANAN PRODUK," 2019.
- [6] Z. D. Zhao and M. S. Shang, "User-based collaborative-filtering recommendation algorithms on hadoop," *3rd International Conference on Knowledge Discovery and Data Mining, WKDD 2010*, pp. 478–481, 2010, doi: 10.1109/WKDD.2010.54.
- [7] Nuurshadieq and A. T. Wibowo, "Leveraging Side Information to Anime Recommender System using Deep learning," *2020 3rd International Seminar on Research of Information Technology and Intelligent Systems, ISRITI 2020*, pp. 62–67, 2020, doi: 10.1109/ISRITI51436.2020.9315363.
- [8] tashim Billah *et al.*, *Penerapan Collaborative Filtering, PCA dan K-Means dalam Pembangunan Sistem Rekomendasi Film*. 2021.
- [9] H. Februriyanti, A. Dwi Laksono, J. Sasongko Wibowo, and M. Siswo Utomo, "IMPLEMENTASI METODE COLLABORATIVE FILTERING UNTUK SISTEM REKOMENDASI PENJUALAN PADA TOKO MEBEL," 2021, [Online]. Available: www.unisbank.ac.id
- [10] G. Ferio, R. Intan, and S. Rostianingsih, "Sistem Rekomendasi Mata Kuliah Pilihan Menggunakan Metode User Based Collaborative Filtering Berbasis Algoritma Adjusted Cosine Similarity."
- [11] I. D. A. C. Putra and I. K. G. Suhartana, "Sistem Rekomendasi Anime dengan Metode Content Based Filtering," 2022. [Online]. Available: <https://www.kaggle.com/CooperUnion/anime-recommendations-database>
- [12] 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 Informatika*, vol. 9, no. 1, pp. 17–27, Sep. 2019, doi: 10.30864/eksplora.v9i1.244.
- [13] A. N. Khusna, K. P. Delasano, and D. C. E. Saputra, "Penerapan User-Based Collaborative Filtering Algorithm," *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 20, no. 2, pp. 293–304, May 2021, doi: 10.30812/matrik.v20i2.1124.
- [14] A. Tangkelayuk and E. Mailoa, "Klasifikasi Kualitas Air Menggunakan Metode KNN, Naïve Bayes Dan Decision Tree," vol. 9, no. 2, pp. 1109–1119, 2022, [Online]. Available: <http://jurnal.mdp.ac.id>
- [15] S. Indrawati, N. Nafi'iyah, and H. Susilo, "PENERAPAN ALGORITMA USER-BASED FILTERING DALAM MEMBERIKAN REKOMENDASI BARANG PADA TOKO BIN WAHAB," *Jurnal Insand Comtech*, vol. 5, no. 1, 2020.