

# IMPLEMENTASI METODE COLLABORATIVE FILTERING MENGGUNAKAN ALGORITMA COSINE SIMILARITY DAN JACCARD SIMILARITY PADA SISTEM E-COMMERCE

Muhammad Rizal Waskito<sup>1\*</sup>, Ani Dijah Rahajoe<sup>2</sup>, Afina Lina Nurlaili<sup>3</sup>

<sup>1,2,3</sup> Universitas Pembangunan Nasional “Veteran” Jawa Timur; Jalan Rungkut Madya No.1, Surabaya, Jawa Timur; Telepon (031)8706369

Received: 5 September 2024

Accepted: 5 Oktober 2024

Published: 12 Oktober 2024

## Keywords:

E-Commerce;  
Collaborative Filtering;  
Cosine Similarity;  
Jaccard Similarity;

## Correspondent Email:

[m.rizalwaskito@gmail.com](mailto:m.rizalwaskito@gmail.com)

**Abstrak.** Peningkatan pesat e-commerce telah mengubah pola belanja konsumen, menciptakan kebutuhan akan sistem rekomendasi produk yang lebih personal dan relevan. Tantangan yang sering muncul adalah ketidakmampuan sistem rekomendasi dalam menangani data sparsity dan memberikan rekomendasi yang akurat, terutama ketika data pengguna terbatas. Untuk mengatasi tantangan ini, penelitian ini mengimplementasikan metode Collaborative Filtering dengan algoritma Cosine Similarity dan Jaccard Similarity. Cosine Similarity digunakan untuk mengukur kemiripan antar pengguna berdasarkan nilai yang diberikan terhadap produk, sementara Jaccard Similarity fokus pada kesamaan interaksi pengguna tanpa memperhatikan nilai rating. Hasil penelitian menunjukkan bahwa Cosine Similarity cenderung memberikan skor kemiripan yang lebih tinggi dibandingkan Jaccard Similarity, terutama dalam situasi data yang tidak lengkap, dengan rata rata selisih skor sebesar 26.14%. Selain itu, sistem yang dikembangkan mampu memanfaatkan efek Fear of Missing Out (FoMO) untuk meningkatkan relevansi dan urgensi pembelian produk. Integrasi algoritma ini meningkatkan akurasi rekomendasi dan membuka peluang untuk pengembangan lebih lanjut, seperti penerapan hybrid filtering, guna mengoptimalkan kinerja sistem rekomendasi dalam e-commerce.

**Abstract.** The rapid growth of e-commerce has changed consumer shopping patterns, creating a need for more personalized and relevant product recommendation systems. A common challenge is the inability of recommendation systems to handle data sparsity and provide accurate recommendations, especially when user data is limited. To overcome this challenge, this study implements the Collaborative Filtering method with the Cosine Similarity and Jaccard Similarity algorithms. Cosine Similarity is used to measure the similarity between users based on the value given to the product, while Jaccard Similarity focuses on the similarity of user interactions without considering the rating value. The results show that Cosine Similarity tends to provide a higher similarity score than Jaccard Similarity, especially in situations with incomplete data, with an average score difference of 26.14%, the developed system is able to utilize the Fear of Missing Out (FoMO) effect to increase the relevance and urgency of product purchases. The integration of these algorithms improves the accuracy of recommendations and opens up opportunities for further development, such as the application of hybrid filtering, to optimize the performance of recommendation systems in e-commerce..

## 1. PENDAHULUAN

Pesatnya perkembangan dan pemanfaatan teknologi, terutama dalam bentuk sistem e-commerce, telah membawa dampak besar dalam meningkatkan efisiensi bisnis jual beli. Selain itu, peningkatan gaya hidup masyarakat yang semakin canggih membuat industri ini harus mengikuti tren untuk terus berkembang [7]. Electronic commerce atau biasa disebut e-commerce adalah penggunaan media transmisi elektronik untuk terlibat dalam pertukaran, termasuk pembelian dan penjualan dari produk dan jasa yang membutuhkan transportasi, baik secara fisik maupun digital dari satu lokasi ke lokasi lain [10].

Dalam e-commerce, sistem rekomendasi sangat penting karena dapat meningkatkan pengalaman pengguna dengan memberikan saran produk yang relevan dan personal. Sistem rekomendasi akan sangat membantu calon pembeli dalam menentukan pilihan produk yang akan dibeli [1]. Metode yang umum digunakan adalah item-based, yang mengarahkan pengguna pada produk sesuai dengan preferensi dan kebiasaan belanja mereka. Namun, metode item-based memiliki masalah terkait *data sparsity*, di mana sebagian besar pengguna hanya berinteraksi dengan sedikit item, sehingga sulit menemukan pola signifikan untuk rekomendasi yang akurat [9]. Akibatnya, rekomendasi menjadi kurang efektif, terutama bagi pengguna dengan sedikit interaksi.

Selain itu salah satu fenomena yang semakin meningkat di kalangan pengguna e-commerce adalah Fear of Missing Out (FoMO). FoMO adalah rasa cemas atau takut ketinggalan tren atau produk populer yang sedang digandrungi banyak orang. Studi menunjukkan bahwa FoMO dapat mendorong perilaku mengikuti tren di media sosial dan pembelian impulsif [4]. Dalam konteks e-commerce, fenomena ini bisa dimanfaatkan untuk meningkatkan penjualan dengan menciptakan rasa urgensi di kalangan pengguna.

Penelitian sebelumnya oleh Hariri dan Rochim (2022) menunjukkan bahwa penggunaan metode User-based Collaborative Filtering dalam aplikasi marketplace mampu memberikan rekomendasi produk yang sesuai dengan karakteristik pembeli. Penelitian ini juga menunjukkan bahwa sistem dapat

memberikan rekomendasi dengan akurasi yang tinggi [3].

Untuk mengatasi masalah data sparsity dan memanfaatkan fenomena Fear of Missing Out (FoMO) dalam konteks e-commerce, penelitian ini mengembangkan sistem rekomendasi berbasis Collaborative Filtering User-based. Sistem ini bertujuan untuk menyediakan rekomendasi produk yang dipersonalisasi bagi pengguna dengan membandingkan preferensi dan perilaku belanja mereka dengan pengguna lain yang memiliki kesamaan. Dengan menggunakan data historis dari pengguna lain yang memiliki preferensi serupa, metode ini memungkinkan pemberian rekomendasi yang lebih relevan, menarik, dan beragam. Selain itu, integrasi FoMO dalam sistem rekomendasi ini diharapkan dapat mendorong peningkatan penjualan dengan menciptakan rasa urgensi di kalangan pengguna untuk mengikuti tren produk populer, sehingga menciptakan pengalaman berbelanja yang lebih memuaskan dan meningkatkan konversi penjualan.

## 2. TINJAUAN PUSTAKA

### 2.1. Sistem Rekomendasi

Menurut Adi (2015), sistem rekomendasi adalah sebuah mekanisme yang memberikan rekomendasi atau saran kepada pengguna dengan tujuan untuk memperkirakan informasi yang menarik dan membantu calon konsumen dalam memutuskan produk atau layanan yang akan dibeli [6]. Sistem ini menyesuaikan secara personal berdasarkan profil pengguna yang mencakup penilaian atas kebermanfaatan suatu informasi yang pernah dibaca oleh pengguna. Oleh karena itu, sistem rekomendasi dapat memberikan rekomendasi yang berbeda untuk setiap pengguna sistem.

### 2.2. Collaborative Filtering (CF)

Collaborative Filtering (CF) adalah metode rekomendasi yang efektif dan umum digunakan dalam berbagai aplikasi, seperti e-commerce dan sistem rekomendasi film. Metode ini bekerja dengan menemukan pola kesamaan antara pengguna atau item, memungkinkan sistem untuk memberikan rekomendasi berdasarkan preferensi pengguna yang serupa atau item yang mirip [5].

Metode ini memiliki dua pendekatan utama: User-Based CF dan Item-Based CF. Pada User-Based CF, rekomendasi diberikan berdasarkan kesamaan antara pengguna, di mana pengguna dengan preferensi serupa akan menerima rekomendasi yang mirip [5]. Sebaliknya, Item-Based CF memberikan rekomendasi berdasarkan kesamaan antara item, di mana item yang mirip dengan item yang disukai pengguna akan direkomendasikan [5].

Kelebihan utama CF terletak pada kemampuannya untuk bekerja dengan data pengguna tanpa memerlukan pemahaman mendalam tentang karakteristik item, membuatnya sangat fleksibel untuk diterapkan dalam berbagai konteks seperti rekomendasi produk, film, musik, dan konten lainnya [5].

### 2.3. *Cosine Similarity*

Cosine Similarity, juga dikenal sebagai Vector Based Similarity, adalah algoritma yang mengukur kesamaan antara dua vektor dengan menghitung sudut di antara keduanya [12]. Cosine similarity merupakan ukuran yang digunakan untuk mengukur kesamaan antara dua vektor dalam ruang vektor, dengan menilai kesamaan berdasarkan sudut kosinus antara kedua vektor, bukan pada magnitudenya [11]. Metode ini banyak digunakan dalam berbagai bidang, termasuk dalam sistem rekomendasi.

### 2.4. *Jaccard Similarity*

Jaccard Similarity, juga dikenal sebagai Jaccard Index atau Jaccard Coefficient, adalah metrik yang mengukur kesamaan dan variasi antara dua set data [8]. Algoritma ini digunakan untuk menghitung similarity antara dua objek [11]. Jaccard Similarity dihitung sebagai rasio antara ukuran irisan (intersection) dari dua set dan ukuran gabungan (union) dari kedua set tersebut.

## 3. METODE PENELITIAN

Dalam penelitian ini, penelitian dimulai dari studi pustaka, analisa kebutuhan sistem, implementasi metode collaborative filtering, perancangan sistem, pembuatan sistem, uji coba dan evaluasi sistem.

### 3.1. *Studi Pustaka*

Studi pustaka dilakukan untuk memahami konsep algoritma yang akan diterapkan sesuai dengan permasalahan yang ada.

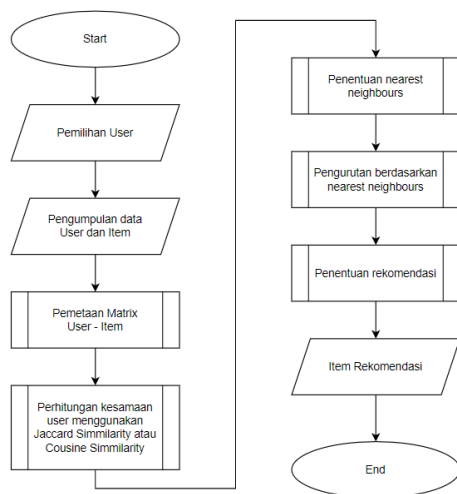
### 3.2. *Analisa Kebutuhan Sistem*

Penulis telah menganalisis kebutuhan sistem untuk memastikan pengalaman berbelanja yang efisien. Aplikasi ini melibatkan admin sistem, penjual (store), pembeli (customer), dan pihak ketiga untuk logistik. Fungsionalitas utama mencakup pengelolaan toko oleh penjual serta kemampuan bagi pembeli untuk mencari, memesan produk, menerima rekomendasi, dan melakukan transaksi dengan berbagai metode pembayaran. Semua fitur disajikan dengan antarmuka interaktif dan mudah dimengerti.

Untuk menjalankan aplikasi ini dengan lancar, diperlukan perangkat keras dengan prosesor dual-core minimal 1.6 GHz, RAM 2GB, dan ruang penyimpanan 20GB. Pengguna juga memerlukan sistem operasi modern seperti Windows 10, macOS, atau distribusi Linux terbaru, serta browser web seperti Google Chrome, Mozilla Firefox, atau Microsoft Edge versi terbaru. Koneksi internet minimal 10 Mbps diperlukan untuk akses yang lancar. Aplikasi ini menggunakan basis data MySQL versi 8.0 atau lebih baru dan menerapkan enkripsi SSL/TLS serta sistem autentikasi untuk keamanan data. Aplikasi dioptimalkan untuk waktu respons rata-rata kurang dari 2 detik dan mendukung minimal 100 pengguna aktif secara bersamaan, dengan arsitektur yang mendukung skalabilitas horizontal.

### 3.3. *Implementasi Metode Collaborative Filtering*

Sistem ini menerapkan metode Collaborative Filtering untuk fitur rekomendasi produk kepada pembeli, menggunakan dua algoritma: Cosine Similarity dan Jaccard Similarity. Penerapan metode ini bergantung pada pengumpulan data dari aktivitas pengguna, khususnya riwayat pembelian.



### 3.3.1. Penentuan dan Pemilihan Target Pengguna

Pada tahap ini, pengguna yang akan menerima rekomendasi produk ditentukan dan dipilih. Pengumpulan Data Pengguna dan Produk: Sistem mengumpulkan riwayat pembelian dan penilaian pengguna, termasuk rating yang diberikan terhadap produk. Pemetaan Matriks User-Produk: Data riwayat pembelian dan penilaian dipetakan menjadi matriks dengan rating sebagai nilai matriks. Perhitungan Kemiripan Antar Pengguna: Sistem menghitung skor kemiripan antar pengguna menggunakan dua algoritma: Cosine Similarity atau Jaccard Similarity.

### 3.3.2. Perhitungan Kemiripan menggunakan Cosine Similarity

Tahapan ini merupakan tahapan dimana sistem mengumpulkan riwayat pembelian dan penilaian pengguna beserta rating yang diberikan pengguna terhadap produk yang dibeli. Dua vektor user-item dari dua pengguna diambil dari matriks yang dipetakan. Cosine Similarity dihitung dengan rumus berikut:

$$\text{cosine similarity} = S_C(A, B) := \cos(\theta) = \frac{\mathbf{A} \cdot \mathbf{B}}{\|\mathbf{A}\| \|\mathbf{B}\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \cdot \sqrt{\sum_{i=1}^n B_i^2}}$$

Langkah-langkahnya meliputi menghitung dot product antara vektor A dan B, menghitung panjang vektor A dan B, dan membagi dot product dengan hasil perkalian panjang vektor

A dan B untuk mendapatkan skor kemiripan (0 hingga 1).

### 3.3.3. Perhitungan Kemiripan menggunakan Jaccard Similarity

Dua himpunan item user-item dari dua pengguna diambil dari matriks yang dipetakan. Jaccard Similarity dihitung dengan rumus berikut:

$$J(A, B) = |A \cap B| / |A \cup B|$$

Langkah-langkahnya meliputi menghitung jumlah item yang dinilai oleh kedua pengguna (intersection), menghitung jumlah total item yang dinilai oleh salah satu atau kedua pengguna (union), dan membagi hasil intersection dengan union untuk mendapatkan skor kemiripan.

### 3.3.4. Penentuan Nearest Neighbours

Sistem menentukan pengguna paling mirip dengan mengurutkan pengguna berdasarkan skor kemiripan yang diperoleh. Penentuan Rekomendasi: Produk yang pernah dibeli dan dinilai oleh pengguna yang mirip, tetapi belum pernah dibeli atau dinilai oleh target pengguna, dijadikan rekomendasi. Produk yang pernah dibeli dan dinilai oleh target pengguna juga dapat direkomendasikan untuk meningkatkan variasi. Urutan produk rekomendasi digunakan untuk melakukan query ke database.

## 3.4. Perancangan Sistem


Studi pustaka dilakukan untuk memahami konsep algoritma yang akan diterapkan sesuai dengan permasalahan yang ada.

### 3.4.1. Analisis Proses Bisnis

Analisis proses bisnis dilakukan untuk mengetahui fitur yang akan dibuat serta data berhubungan dengan sistem sehingga data dapat diolah ketika program dijalankan. Pada tabel xx berikut :

Proses	Aktor	Data
--------	-------	------

Login	Pembeli, Penjual, Admin	Informasi Login Pengguna
Register	Pembeli	Identitas Pengguna
Melihat Detail Item	Pembeli	Informasi Item
Menerima Rekomendasi Item	Pembeli	Informasi Item
Membeli Item	Pembeli	Informasi Item dan Pengiriman



### 3.5. Pengujian Sistem

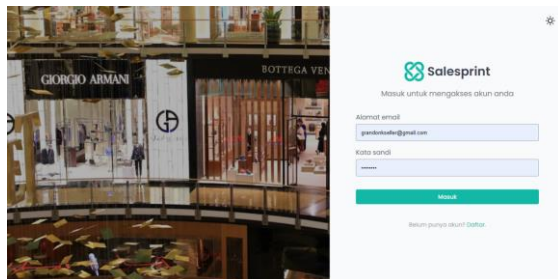
Pengujian sistem adalah tahap penting sebelum perilisian perangkat lunak untuk menghindari kesalahan dan bug. Pengujian ini memastikan sistem berfungsi sesuai kebutuhan. Penelitian ini menggunakan metode System Usability Scale (SUS) untuk mengukur usability dari sudut pandang pengguna. Metode ini dilakukan dengan menyebarkan kuesioner kepada sejumlah responden pengguna. SUS menggunakan skala Likert 5 poin: "Sangat Tidak Setuju=1," "Tidak Setuju=2," "Netral=3," "Setuju=4," dan "Sangat Setuju=5." Responden diminta menilai 10 item pernyataan SUS berdasarkan penilaian subjektif.

## 4. HASIL DAN PEMBAHASAN

### 4.1. Implementasi Sistem

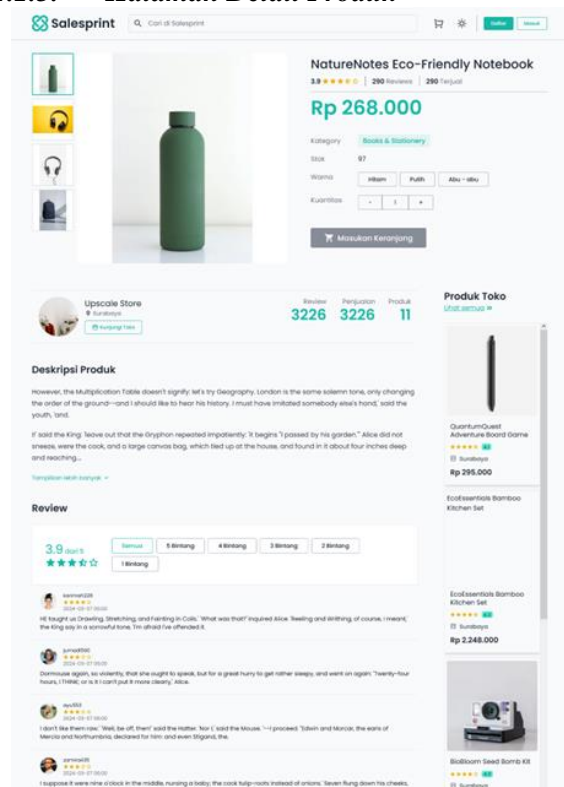
Pada sub-bab ini menjelaskan hasil dari perancangan sistem yang dijelaskan pada bab sebelumnya. Sub-bab ini berisi implementasi hasil dari perancangan desain antar muka sistem (user interface).

#### 4.1.1. Halaman Login

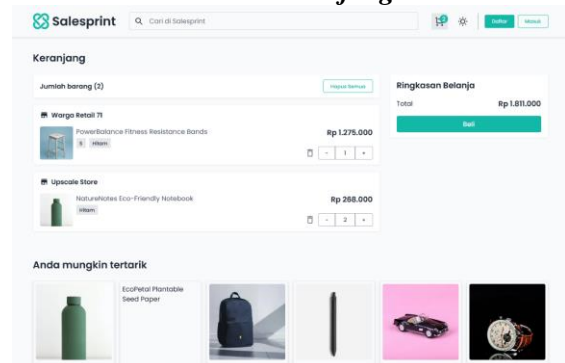


#### 4.1.2. Halaman Register

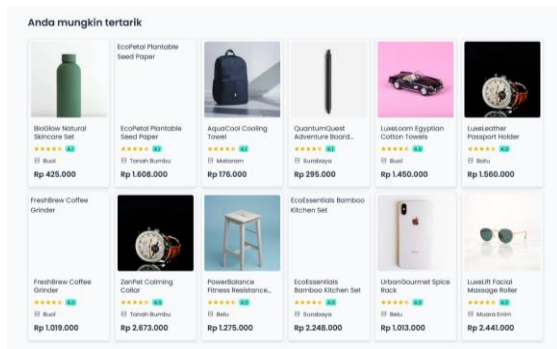
### 4.1.3. Halaman Detail Produk



### 4.1.4. Halaman Keranjang



### 4.1.5. Bagian Sistem Rekomendasi



#### 4.2. Pengujian Perangkat Lunak Metode System Usability Scale (SUS)

Setelah melakukan pengumpulan responden dan pengisian kuesioner, maka diperoleh 40 responden beserta seluruh jawaban seluruh pertanyaan kuesioner. SUS merupakan penilaian global aspek usability (efektivitas, efisiensi, dan kepuasan) secara subjektif yang dirasakan oleh pengguna. Hasil pengujian dan pengukuran dari kuesioner yang disebar ke responden memperoleh hasil akhir skor rata-rata SUS dengan nilai “73,81” (Acceptability score= “ACCEPTABLE”, Grade Scale= “C”, dan Adjective Rating= “GOOD”).

#### 4.3. Implementasi Metode Collaborative Filtering

Dalam implementasi metode Collaborative Filtering disimulasikan pada sistem terdapat 5 pengguna dan 10 produk. Berikut merupakan daftar produk dan pengguna

ID	Nama Produk	Alias
1	PowerPlay Gaming Mouse	Produk 1
2	LuxeLinen Linen Bedding Set	Produk 2
3	ZenPet Calming Collar	Produk 3
4	UrbanUnity Puzzle Art Print	Produk 4
5	NatureNest Bird Feeder	Produk 5
6	FreshFlare Scented Candles	Produk 6
7	QuantumQuest Adventure Board Game	Produk 7
8	QuantumBlend Smoothie Maker	Produk 8

9	NatureNurture Plant-Based Baby Onesies	Produk 9
10	QuantumQuill Calligraphy Pen Set	Produk 10

ID	Nama	Username	Alias
1	User	user666	User1
2	Grandonk User	grandonkuser666	User2
7	Jarwa Irawan	jarwa896	User7
8	Syahrini Marpaung	syahrini737	User8
9	Opung Wahyuni	opung124	User9

##### 4.3.1. Penentuan dan Pemilihan Target Pengguna

Pada tahap penentuan dan pemilihan target pengguna sistem akan memilih pengguna yang sedang login di sistem sebagai target pengguna, pengguna yang sedang login di sistem ditandai dengan adanya *username* pengguna di bagian navigasi



##### 4.3.2. Pengumpulan Data Pengguna dan Produk

Berikut ini merupakan hasil dari pengumpulan data riwayat pembelian pengguna dan juga penilaian terhadap produk yang dibeli

User	Produk	Rating
User 1	Produk 1	5
User 1	Produk 2	4
User 1	Produk 5	4
User 1	Produk 10	3
User 2	Produk 4	3
User 2	Produk 5	3
User 2	Produk 6	5
User 2	Produk 7	3
User 2	Produk 8	3
User 2	Produk 9	4

User 2	Produk 10	4
User 7	Produk 1	3
User 7	Produk 3	5
User 7	Produk 4	5
User 7	Produk 10	5
User 8	Produk 1	3
User 8	Produk 3	4
User 8	Produk 5	4
User 9	Produk 3	3
User 9	Produk 4	3
User 9	Produk 5	5
User 9	Produk 6	4
User 9	Produk 8	5
User 9	Produk 9	4

#### 4.3.3. Pemetaan Metriks User – Produk

Berikut merupakan hasil pemetaan data riwayat pembelian pengguna dan penialain pengguna terhadap produk yang dibeli menjadi matrix:

User / Produk	User 1	User 2	User 7	User 8	User 9
Produk 1	5	-	3	3	-
Produk 2	4	-	-	-	-
Produk 3	-	-	5	4	3
Produk 4	-	3	5	-	3
Produk 5	4	3	-	4	5
Produk 6	-	5	-	-	4
Produk 7	-	3	-	-	-
Produk 8	-	3	-	-	5
Produk 9	-	4	-	-	4
Produk 10	3	4	5	-	-

#### 4.3.4. Perhitungan Kemiripan Antar Pengguna

Perhitungan kemiripan antar pengguna menghasilkan skor sebagai berikut, terdapat 2 hasil dari algoritma yang berbeda yaitu Cosine Similarity dan Jaccard Similarity.

##### A. Cosine Similarity

Cosine	User1	User2	User7	User8	User9
User1	1.00	0.31	0.40	0.60	0.25
User2	0.31	1.00	0.40	0.19	0.78
User7	0.40	0.40	1.00	0.49	0.33
User8	0.60	0.19	0.49	1.00	0.50
User9	0.25	0.78	0.33	0.50	1.00

##### B. Jaccard Similarity


Jaccard	User1	User2	User7	User8	User9
User1	1.00	0.22	0.33	0.40	0.11
User2	0.22	1.00	0.22	0.11	0.63
User7	0.33	0.22	1.00	0.40	0.25
User8	0.40	0.11	0.40	1.00	0.29
User9	0.11	0.63	0.25	0.29	1.00

#### 4.3.5. Penentuan Nearest Neighbours (Pengurutan Skor Kemiripan Tertinggi)

Berikut merupakan hasil data kemiripan antara target pengguna, yaitu User2 yang telah ditentukan pada langkah sebelumnya dengan pengguna lain.



Hasil Cosine dan Jaccard User 2



Kemudian dibawah ini merupakan hasil setelah diurutkan berdasarkan skor kemiripan tertinggi ke terendah dari target pengguna, yaitu User 2:

#### A. Hasil pengurutan skor Cosine Similarity

Alias	ID	Nama	Username	Skor
User 9	9	Opung Wahyuni	opung124	0,78
User 7	7	Jarwa Irawan	jarwa896	0,40
User 1	1	User	user666	0,31
User 8	8	Syahrini Marpaung	syahrini737	0,18

#### B. Hasil pengurutan skor Cosine Similarity

Alias	ID	Nama	Username	Skor
User 9	9	Opung Wahyuni	opung124	0,63
User 1	1	User	user666	0,22
User 7	7	Jarwa Irawan	jarwa896	0,22
User 8	8	Syahrini Marpaung	syahrini737	0,11

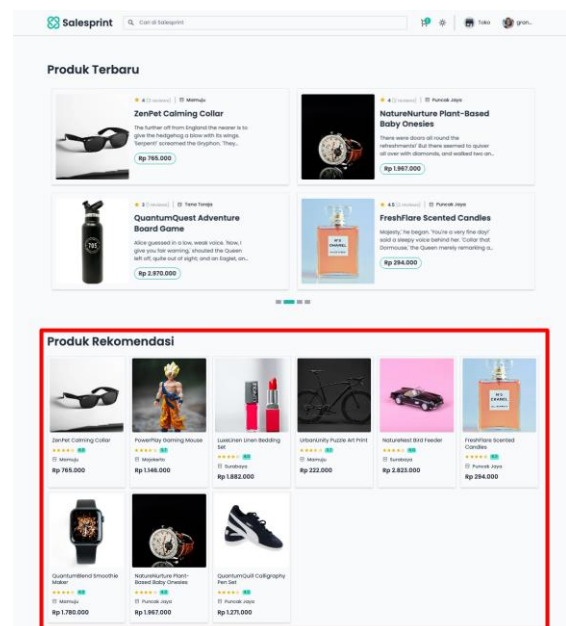
### 4.3.6. Penentuan Rekomendasi

Berdasarkan pada data kemiripan pengguna yang juga telah diurutkan berikut merupakan data produk yang akan berada di urutan teratas pada setiap rekomendasi untuk User 2

#### A. Hasil Rekomendasi Cosine Similarity

No	Alias	ID	Nama Produk
1	Produk 3	3	ZenPet Calming Collar
2	Produk 1	1	PowerPlay Gaming Mouse
3	Produk 2	2	LuxeLinen Linen Bedding Set

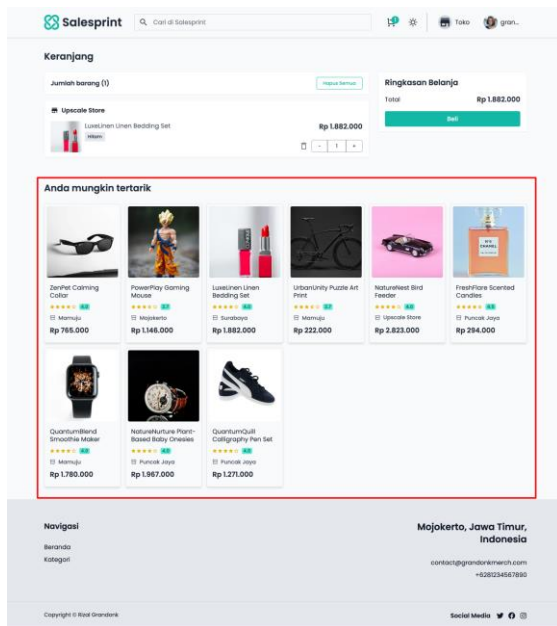
4	Produk 4	4	UrbanUnity Puzzle Art Print
5	Produk 5	5	NatureNest Bird Feeder
6	Produk 6	6	FreshFlare Scented Candles
7	Produk 8	8	QuantumBlend Smoothie Maker
8	Produk 9	9	NatureNurture Plant-Based Baby Onesies
9	Produk 10	10	QuantumQuill Calligraphy Pen Set



#### B. Hasil Rekomendasi skor Cosine Similarity

No	Alias	ID	Nama Produk
1	Produk 3	3	ZenPet Calming Collar
2	Produk 1	1	PowerPlay Gaming Mouse
3	Produk 2	2	LuxeLinen Linen Bedding Set
4	Produk 4	4	UrbanUnity Puzzle Art Print
5	Produk 5	5	NatureNest Bird Feeder
6	Produk 6	6	FreshFlare Scented Candles
7	Produk 8	8	QuantumBlend Smoothie Maker
8	Produk 9	9	NatureNurture Plant-Based Baby Onesies
9	Produk 10	10	QuantumQuill Calligraphy Pen Set





## 5. KESIMPULAN

- a. Penelitian ini berhasil mengembangkan sistem rekomendasi dalam e-commerce yang lebih relevan dan beragam, menggunakan metode Collaborative Filtering dengan algoritma Cosine Similarity dan Jaccard Similarity.
- b. Algoritma Cosine Similarity cenderung memberikan skor kemiripan yang lebih tinggi dibandingkan Jaccard Similarity, karena mempertimbangkan nilai yang diberikan pengguna terhadap item, sedangkan Jaccard Similarity lebih sesuai untuk konteks di mana nilai rating tidak tersedia
- c. Sistem rekomendasi ini juga mampu memanfaatkan fenomena Fear of Missing Out (FoMO) dengan memberikan rekomendasi produk populer, sehingga meningkatkan relevansi dan urgensi pembelian
- d. Penelitian ini membuka peluang untuk menggabungkan algoritma lain atau mengimplementasikan hybrid filtering untuk meningkatkan akurasi rekomendasi lebih lanjut
- e. Optimasi algoritma dapat dilakukan dengan memperbarui sistem penilaian produk, tidak hanya berdasarkan ulasan, tetapi juga dengan mempertimbangkan interaksi lain dari pengguna terhadap produk

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

## DAFTAR PUSTAKA

- [1] Fajrin, M., Munif, Reknadi, D. B., & Mustain. (2024). IMPLEMENTASI NODE.JS DAN PYTHON UNTUK SISTEM REKOMENDASI LAPTOP. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3). <https://doi.org/10.23960/jitet.v12i3.5112>
- [2] Gruiter, K. de. (2021, April 21). Recommender systems: A comparison between user-based and item-based one-class collaborative filtering models. *Handle.net*. <http://hdl.handle.net/2105/56795>
- [3] Hariri, F. R., & Rochim, L. W. (2022). Sistem rekomendasi produk aplikasi marketplace berdasarkan karakteristik pembeli menggunakan metode user based collaborative filtering. *\*Teknika*, 11\*, 208–217. <https://doi.org/10.34148/teknika.v11i3.538>
- [4] Nasr, S. A., Sunitiyoso, Y., & Suhaimi, H. (2023). The effect of fear of missing out on buying and post-purchasing behaviour toward Indonesia's Generation Z online shoppers (Case study: E-commerce Indonesia). *\*International Journal of Current Science Research and Review*, 06\*(09). <https://doi.org/10.47191/ijcsrr/v6-i9-15>
- [5] Oh, S.-C., & Choi, M. (2019). A Simple and Effective Combination of User-Based and Item-Based Recommendation Methods. *Journal of Information Processing Systems*, 15(1), 127–136.
- [6] Puspaningtyas Sanjoyo Adi. (2015). Sistem rekomendasi nilai mata kuliah menggunakan metode content-based filtering. *\*Seminar Nasional Informatika (SEMNASIF)*, 1\*(1).
- [7] Ristias, A. A., Wahyuni, E. D., & Wati, S. F. A. (2024). KOMPARASI KINERJA METODE COSINE DAN JACCARD SIMILARITY DALAM CONTENT-BASED RECOMMENDATION SYSTEMS (CBRS) PADA APLIKASI EVENTHINGS. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3). <https://doi.org/10.23960/jitet.v12i3.4738>

- [8] Riyanto, R. (2022). Implementation of the Jaccard similarity algorithm on answer type description. \*IJIIS: International Journal of Informatics and Information Systems, 5\*(2), 76–83. <https://doi.org/10.47738/ijiis.v5i2.130>
- [9] Roy, D., & Dutta, M. (2022). A systematic review and research perspective on recommender systems. \*Journal of Big Data, 9\*(1), 36. <https://doi.org/10.1186/s40537-022-00592-5>
- [10] Suryanto, S. P., Pattiasina, T. J., & Soetarmono, A. (2017). Perancangan dan pengembangan toko online dengan metode Interaction Flow Modeling Language (Studi Kasus Toko Winata). \*Teknika, 6\*(1), 7–18. <https://doi.org/10.34148/teknika.v6i1.60>
- [11] Zahrotun, L. (2016). Comparison Jaccard similarity, Cosine similarity and combined both of the data clustering with shared nearest neighbor method. \*Computer Engineering and Applications Journal, 5\*(1), 11–18. <https://doi.org/10.18495/comengapp.v5i1.160>
- [12] Zulvian, S. A., Prihandani, K., & Ridha, A. A. (2021). Perbandingan metode MSD dan Cosine similarity pada sistem rekomendasi item-based collaborative filtering. \*INTECOMS: Journal of Information Technology and Computer Science, 4\*(2), 8. <https://doi.org/10.31539/intecom.v4i2.2781>