

SISTEM REKOMENDASI PRODUK UNTUK PELANGGAN PERUSAHAAN DISTRIBUSI MENGUNAKAN METODE COLLABORATIVE FILTERING DAN K-MEANS CLUSTERING

Dennis Sebastian¹, Bagus Mulyawan², Novario Jaya Perdana³

¹⁾²⁾³⁾ Teknik Informatika Universitas Tarumanagara

Jl. Letjen S. Parman No. 1, Jakarta Barat 11440 Indonesia

E-mail: ¹dennis.535190033@stu.untar.ac.id, ²bagus@fti.untar.ac.id, ³novariojp@fti.untar.ac.id

Abstrak

PT Enseval merupakan perusahaan distribusi yang memiliki banyak jenis produk yang ditawarkan. Banyaknya produk yang ditawarkan dapat membuat salesman Enseval kesulitan untuk menawarkan produk yang cocok dan sesuai untuk pelanggan. Keterampilan salesman untuk menawarkan produk ke pelanggan sangat mempengaruhi penjualan barang distribusi. Maka dari itu, pada kesempatan ini akan dibangun sistem rekomendasi produk untuk pelanggan PT Enseval menggunakan metode k-means dan collaborative filtering. Perancangan aplikasi dibuat untuk memudahkan salesman dalam merekomendasikan produk ke pelanggan dan membantu pelanggan dalam memilih produk. Data yang akan digunakan merupakan data transaksi sales periode 2021 - 2022. Uji coba dengan metode collaborative filtering untuk menentukan akurasi menggunakan mean absolute error (MAE) mendapatkan nilai 0,114678277 dan rekoemendasi dengan menggunakan gabungan metode k-means dan collaborative filtering mendapatkan rata-rata MAE sebesar 0.158411487. Kedua hasil MAE memiliki akurasi yang cukup baik karena semua hasil scenario memiliki kesalahan (error) yang mendekati angka 0. Berdasarkan hasil tersebut, dapat ditarik kesimpulan bahwa metode k-means kurang efektif digabungkan dengan metode collaborative filtering dalam memberikan rekomendasi produk dalam sistem aplikasi ini.

Kata Kunci : Collaborative Filtering, K-Means, Mean Absolute Error, Sistem Rekomendasi

Abstract

PT Enseval is a distribution company that has many types of products to offer. The number of products offered can make it difficult for Enseval salesmen to offer products that are suitable and suitable for customers. Salesman skills to offer products to customers greatly affect the sales of goods distribution. Therefore, on this occasion a product recommendation system will be built for PT Enseval's customers using the k-means method and collaborative filtering. Application design is made to make it easier for salesmen to recommend products to customers and assist customers in choosing products. The data that will be used is sales transaction data for the period 2021 –2022. Trials using the collaborative filtering method to determine accuracy using the mean absolute error (MAE) get a value of 0.114678277 and recommendations using the combined k-means and collaborative filtering methods get an average MAE of 0.158411487. Both MAE results have fairly good accuracy because all scenario results have an error close to 0. Based on these results, it can be concluded that the k-means method is less effective when combined with collaborative filtering in providing product recommendations in this application system.

Keywords : Collaborative Filtering, K-Means, Mean Absolute Error, Recommendation System

1. PENDAHULUAN

PT. Enseval Putra Megatrading, Tbk merupakan perusahaan farmasi multinasional yang bermarkas di Jakarta, Indonesia. Perusahaan ini didirikan pada tahun 1972 dan memproduksi berbagai macam-macam barang farmasi. Dalam perkembangannya, PT Enseval tumbuh menjadi distributor umum, tidak hanya dalam produk farmasi, tetapi juga dengan berbagai macam produk konsumen. PT Enseval memiliki ribuan jenis produk yang ditawarkan ke pelanggan mereka. Pelanggan PT Enseval mulai dari toko kelontong, apotek, supermarket, rumah sakit, klinik, tempat makan dan minum, pedagang besar farmasi, koperasi, dan lain-lain. Kegiatan penawaran produk yang dilakukan oleh PT Enseval ke pelanggan adalah melalui salesman. Seorang salesman akan menawarkan dan menyarankan produk ke pelanggan.

Banyaknya produk yang ditawarkan dapat membuat salesman Enseval kesulitan untuk menawarkan produk yang cocok dan sesuai untuk pelanggan tersebut. Keterampilan salesman untuk menawarkan produk ke pelanggan sangat mempengaruhi penjualan barang distribusi. Banyaknya jumlah produk yang ditawarkan dan kurang tersedianya informasi pasar, membuat pelanggan sulit untuk memesan produk yang sesuai dengan kondisi pasarnya. Terkadang banyak produk yang dibeli tidak sesuai dengan kondisi pasarnya menyebabkan pemasokan barang yang kurang efektif dan perputaran barang yang lambat dapat menjadi stok mati.

Menumpuknya stok mati ini tentunya akan merugikan pelanggan karena arus kas pelanggan menjadi terhambat. Maka dari itu, sistem rekomendasi dapat menjadi solusi pelanggan PT Enseval dalam memilih produk yang ditawarkan. Dengan adanya sistem rekomendasi, pelanggan dapat memilih produk yang direkomendasikan agar dapat menghindari pemasokan barang yang kurang efektif dan dapat membantu meningkatkan penjualan. Oleh karena itu, pada kesempatan kali ini akan dibangun sistem rekomendasi sebagai rancangan pembuatan website untuk membantu pelanggan dalam memilih produk serta salesman dalam merekomendasikan produk distribusi di PT Enseval.

2. METODE PENELITIAN

2.1 Klasterisasi

Klasterisasi atau *clustering* adalah metode pengelompokan data. Menurut Tan, 2006 *clustering* adalah sebuah proses untuk mengelompokkan data ke dalam beberapa *cluster* atau kelompok sehingga data dalam satu *cluster* memiliki tingkat kemiripan yang maksimum dan data antar *cluster* memiliki kemiripan yang minimum. Klasterisasi merupakan proses partisi satu *set* objek data ke dalam himpunan bagian yang disebut dengan *cluster*. Objek yang di dalam *cluster* memiliki kemiripan karakteristik antar satu sama lainnya dan berbeda dengan *cluster* yang lain. Hasil *clustering* yang baik akan menghasilkan tingkat kesamaan yang tinggi dalam satu kelas dan tingkat kesamaan yang rendah antar kelas. Kesamaan yang dimaksud merupakan pengukuran secara numerik terhadap dua buah objek. Nilai kesamaan antar kedua objek akan semakin tinggi jika kedua objek yang dibandingkan memiliki kemiripan yang tinggi. Begitu juga dengan sebaliknya. Kualitas hasil *clustering* sangat bergantung pada metode yang dipakai [1].

2.2 K-Means

K-means memiliki dua pengertian yaitu “*K*” dan “*Means*”. “*K*” dimaksudkan sebagai konstanta jumlah klaster yang diinginkan, sedangkan “*Means*” dalam hal ini berarti nilai suatu rata-rata dari suatu grup data yang dalam hal ini didefinisikan sebagai *cluster*, sehingga *k-means* dapat diartikan sebagai suatu metode penganalisaan data atau metode *data mining* yang

melakukan proses pemodelan tanpa supervisi (*unsupervised*) dan merupakan salah satu metode yang melakukan pengelompokan data dengan sistem partisi [2].

Algoritma *k-means* merupakan model *centroid*. Model *centroid* adalah model yang menggunakan titik tengah suatu *cluster* yang berupa nilai. *Centroid* digunakan untuk menghitung jarak suatu objek data termasuk dalam suatu *cluster* jika memiliki jarak terpendek terhadap *centroid cluster* tersebut.

Berikut merupakan tahap-tahap proses *k-means* adalah:

1. Menentukan jumlah *K* sebagai jumlah kluster yang ingin dibentuk.
2. Menentukan nilai random untuk pusat kluster awal (*centroid*) sebanyak *k* yang dibutuhkan.
3. Menghitung jarak setiap data *input* terhadap masing-masing *centroid* menggunakan rumus jarak *Euclidean* (*Euclidean Distance*) hingga ditemukan jarak yang paling dekat dari setiap data dengan *centroid*. Berikut merupakan persamaan *Euclidian Distance* [3]:

$$d(x_i, \mu_j) = \sqrt{\sum (x_i - \mu_j)^2} \quad (1)$$

Keterangan :

$d(x_i, \mu_j)$ = jarak antara x dan μ
 x_i = data pusat kluster ke i
 μ_j = data pada setiap data ke j
 n = jumlah data

4. Mengklusterisasikan setiap data berdasarkan jarak dengan *centroid* (nilai yang terkecil).
5. Memperbaharui *centroid* baru yang di peroleh dari rata-rata kluster yang diperoleh dengan menggunakan rumus [4]:

$$\mu_j (t + 1) = \frac{1}{N_{sj}} \sum_{j \in s_j} x_j \quad (2)$$

Keterangan :

$\mu_j (t+1)$ = titik centroid baru dari kluster ke t
 N_{sj} = banyaknya data pada kluster ke j
 x_j = data ke j pada kluster t

6. Melakukan perulangan dari langkah tiga hingga lima, sampai anggota tiap kluster tidak ada yang berubah.

2.3 Collaborative Filtering

Metode collaborative filtering memberikan hasil rekomendasi berdasarkan feedback atau sumber informasi yang didapat dari pengguna. Salah satu contoh penerapan metode collaborative filtering adalah sistem rekomendasi makanan dengan membentuk matriks pengguna yang berisikan preferensi dari pengguna, data matriks ini dibentuk dari data pemesanan atau penilaian pengguna [6]. Metode *collaborative filtering* ini menyeleksi data bersumber pada konsumen yang memiliki kesamaan karakteristik, sehingga dapat memberikan sebuah informasi baru kepada konsumen. Karena yang diberikan oleh sistem merupakan informasi yang bersumber pada pola satu kelompok konsumen yang hampir sama. Ide utama dalam sistem rekomendasi collaborative filtering adalah untuk memanfaatkan opini user lain yang ada untuk memprediksi item yang mungkin akan disukai/diminati oleh seorang user [7]. *Item-based collaborative filtering* memberikan hasil rekomendasi kepada pengguna dengan memperhitungkan nilai kemiripan yang

dimiliki suatu produk atau item dengan yang lainnya, perhitungan nilai kemiripan ini dilihat berdasarkan nilai rating / pembelian dari pengguna [8].

Rating dapat dikumpulkan dengan cara eksplisit, implisit, atau keduanya bersamaan. Rating eksplisit adalah ketika seorang user secara langsung diminta untuk memberikan opini terhadap suatu item. Rating implisit mengandung arti bahwa sistem secara otomatis mendapatkan preferensi user secara pasif dengan me-monitor aksi pengguna [8], misalnya ketika seseorang membeli sesuatu produk maka pengguna tersebut dianggap tertarik atau menyukai item tersebut. Dengan cara ini, user profile dapat dibentuk tanpa melibatkan effort tambahan dari pengguna. Dalam memprediksi hasil rekomendasi menggunakan metode collaborative filtering, dibutuhkan dua komponen utama yaitu pengguna (u_m) dan produk (i_n). Kedua komponen tersebut akan membentuk hubungan matrix berupa rating matrix, dimana setiap user memberikan rating terhadap sebuah item secara eksplisit maupun implisit. Tabel rating matrix dapat dilihat pada tabel sebagai berikut.

Tabel 1 Rating Matriks

	u_1	u_2	u_3	...	u_n
i_1	1		4	...	1
i_2	3		5	...	
i_3	4	2	5	...	
...		3		...	
i_m				...	
...		3		...	
i_m				...	

Metode collaborative filtering akan melakukan perhitungan nilai kemiripan antara produk x dengan produk lainnya berdasarkan penilaian yang diberikan oleh pengguna. Nilai kemiripan antara kedua produk dapat dihasilkan dengan menghitung rating dari keduanya menggunakan rumus pearson correlation pada persamaan berikut:

$$sim(k, l) = \frac{\sum_{u=1}^m (r_{u,k} - \bar{r}_k)(r_{u,l} - \bar{r}_l)}{\sqrt{\sum_{u=1}^m (r_{u,k} - \bar{r}_k)^2} \sqrt{\sum_{u=1}^m (r_{u,l} - \bar{r}_l)^2}} \quad (3)$$

Dimana $sim(k, l)$ merupakan nilai kemiripan antara produk k dan produk l , $r_{u,k}$ merupakan rating pengguna u pada produk k , \bar{r}_k merupakan rata-rata rating produk k , $r_{u,l}$ adalah rating pengguna u pada produk l dan \bar{r}_l merupakan rata-rata rating produk l .

Setelah melakukan perhitungan terhadap nilai kemiripan, akan dihitung nilai prediksi untuk produk yang baru dengan menggunakan rumus weighted sum pada persamaan berikut.

$$P(u, j) = \frac{\sum_{i=1}^k (rating(U, I_i) * sim_{i,j})}{\sum_{i=1}^k |sim_{i,j}|} \quad (4)$$

Dimana $P(u, j)$ merupakan prediksi pengilaian pengguna u terhadap produk j , $rating(U, I_i)$ merupakan rate pengguna u pada produk i , dan $sim_{i,j}$ adalah nilai kemiripan antara produk I dan produk j .

Alur penerapan metode collaborative filtering pada sistem yang akan dibuat dengan memanfaatkan rumus yang telah diketahui adalah sebagai berikut.

1. Menyiapkan data transaksi pelanggan sesuai dengan kelompok *cluster*.
2. Melakukan perhitungan rata-rata rating dan menjumlahkannya.
3. Menghitung nilai similarity antara item *i* dan item *j* yang memiliki rating dengan rumus perhitungan similarity dengan rumus Pearson Correlation.
4. Menghitung nilai prediksi produk dengan menggunakan rumus Weighted Sum.
5. Mengeluarkan hasil rekomendasi dengan mengurutkan dari nilai prediksi tertinggi

2.5 Min-Max Normalization

Metode normalisasi data adalah proses membuat beberapa variabel memiliki rentang nilai yang sama, tidak ada yang terlalu besar maupun terlalu kecil sehingga dapat membuat analisis statistik menjadi lebih mudah [9]. Perbedaan rentang nilai pada setiap atribut dalam proses transformasi data menyebabkan tidak berfungsinya atribut yang memiliki nilai jauh lebih kecil dibandingkan dengan atribut-atribut lainnya, sehingga data yang telah dinormalisasi dengan metode decimal scaling lebih baik hasilnya secara signifikan daripada klasifikasi tanpa melakukan transformasi data [10].

Min-Max Normalization merupakan metode normalisasi dalam *data mining* merupakan proses penskalaan nilai atribut dari data menjadi skala tertentu. Normalisasi ini digunakan untuk menyamakan skala atribut data kedalam skala yang lebih kecil seperti 0 sampai 1 [11]. *Min-Max Normalization* melakukan transformasi linear pada atribut data asli sehingga menghasilkan keseimbangan nilai perbandingan antar data saat sebelum dan sesudah proses. Berikut merupakan persamaan *Min-Max Normalization* [12]:

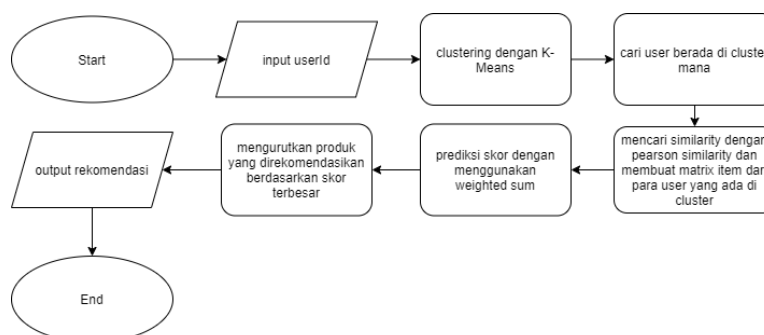
$$X^I = \frac{X - X_{min}}{X_{max} - X_{min}} \tag{11}$$

Dimana X^I merupakan data atribut yang akan dinormalisasi, X_{max} merupakan nilai tertinggi atribut tersebut, dan X_{min} merupakan nilai terendah atribut tersebut.

3. HASIL DAN PEMBAHASAN

3.1 Rancangan Sistem

Metode penelitian yang digunakan pada pembuatan website sistem rekomendasi yaitu menggunakan metode Collaborative Filtering (CF) dan k-means Clustering dimana setiap metode memiliki peranan yang berbeda. Metode k-means untuk mengelompokkan pelanggan yang mempunyai karakteristik yang sama satu sama lainnya dan karakteristik yang berbeda dengan data yang ada di dalam kelompok yang lain ke dalam beberapa kelompok. Metode Collaborative Filtering (CF) akan menghitung nilai similarity (kemiripan) item dengan item lainnya oleh user sebagai cara untuk menentukan pilihan terbaik.




Gambar 2 Diagram Alur Penentuan Rekomendasi Produk

Proses perancangan sistem yang dibuat dapat dilihat dari diagram alur pada gambar 2. Pada tahap awal, data transaksi pelanggan dalam kurun waktu 1 tahun akan diolah dengan menggunakan metode *k-means*. Metode *K-means* akan mengelompokkan pelanggan ke dalam beberapa cluster sesuai dengan kemiripan atau karakteristik pelanggan dengan menggunakan atribut total jenis produk farmasi dan barang konsumen yang dibeli oleh pelanggan.

Lalu, setelah mendapatkan hasil cluster pelanggan, akan digunakan metode *Collaborative Filtering* (CF) untuk mencari rekomendasi produk untuk pelanggan. Lalu, setelah mendapatkan hasil cluster pelanggan, akan digunakan metode *Item-Based Collaborative Filtering* (CF) untuk mencari rekomendasi produk untuk pelanggan. Perhitungan dengan metode ini hanya akan menggunakan data transaksi pelanggan dari cluster yang sama dengan pelanggan yang ingin dicari rekomendasinya. Untuk mendapatkan hasil rekomendasi produk, akan dibuat *matrix item* dengan cara menghitung *similarity* antar *item* dengan menggunakan rumus *Pearson Correlation* pada persamaan (3) serta menghitung prediksi *rating* dengan menggunakan rumus *Weighted Sum* pada persamaan (4). Penentuan data *rating* pada *item-user matrix* berasal dari jumlah pembelian produk *x* oleh *user y*. Jumlah pembelian produk *x* oleh *user y* merupakan cara agar data yang diperoleh secara implisit dapat membentuk *item-user matrix*.

3.2 Hasil Pengujian Metode K-Means

Dilakukan uji coba terhadap algoritma *K-means* menggunakan data transaksi sales yang berasal dari periode 25 september 2021 – 25 september 2022. Pengujian akan dilakukan menggunakan atribut total jenis produk farmasi dan total jenis produk barang konsumen yang dibeli oleh pelanggan dengan jumlah cluster sebanyak. Selanjutnya akan dilakukan perhitungan menggunakan rumus pada persamaan (3) hingga ditemukan jarak yang paling dekat dari setiap data dengan *centroid*. Setelah itu, iterasi akan terus dilakukan sampai anggota tiap *cluster* tidak berubah dengan memperbaharui titik *centroid* dengan persamaan (4). Berikut merupakan hasil clustering yang titik *centroid* berhenti pada iterasi ke 21 pada algoritma *K-Means*.



Gambar 3 Plot Hasil Klasterisasi Iterasi 21

Setelah itu dilakukan evaluasi pengujian algoritma untuk menentukan kinerja proses clustering pada akan menggunakan rumus Davies Bouldin Index. . Dalam proses perhitungan tersebut didapatkan nilai DBI sebesar 0.7183746826. Setelah itu, dilakukan juga pengujian dengan menggunakan *Silhouette Coefficient*. Dalam proses perhitungan, didapatkan hasil *Silhouette Score* sebesar 0.74792190916. Kesimpulan yang dapat diambil yaitu proses klasterisasi yang telah dilakukan telah berjalan optimal, karena besar hasil DBI mendekati nilai 0 dan juga berdasarkan nilai *silhouette coefficient* dapat dikatakan telah berjalan dengan optimal karena hasil nilai *silhouette coefficient* mendekati nilai 1.

3.3 Hasil Pengujian Metode *Collaborative Filtering*

Metode Collaborative Filtering dihitung dengan menggunakan data rating produk sebagai variabel utama. Data rating menggunakan data transaksi pelanggan dari cluster yang sama yang telah dihitung dengan menggunakan metode k-means dengan pelanggan yang ingin dihitung rekomendasinya. Untuk melakukan perhitungan collaborative filtering secara manual akan digunakan data dummy untuk dijadikan sampel untuk penerapan. Data rating dapat dilihat pada tabel berikut.

Tabel 2 Data Rating

	U1	U2	U3	Un	Avg
ITEM1	20	18			8.6
ITEM2			5	25	15.5
ITEM3		15	14		7.5
ITEM4	15			15	12.5
....	
ITEM N		5			4.67

Setelah mendapatkan contoh *rating matrix* dari pengguna x produk, maka akan dilakukan tahap normalisasi dengan menggunakan rumus *Min-Max Normalization* pada persamaan (5).

Tabel 3 Data rating normalisasi

	U1	U2	U3	Un	Avg
ITEM1	1	0.78			0.45
ITEM2			0.45	0.85	0.48
ITEM3		0.28	0.24		0.33
ITEM4	0.76			0.12	0.65
....	
ITEM N		0.12				0.38

Dari seluruh data rating yang ada kemudian digunakan untuk menghitung kemiripan antar produk menggunakan persamaan (5). Nilai kemiripan antar produk dapat dilihat pada tabel berikut.

Tabel 4 Nilai Kemiripan antar produk

	ITEM1	ITEM2	ITEM3	ITEM N
ITEM1	1	-0,35	0,12	0,54
ITEM2	-0,35	1	-0,01	-0,17
ITEM3	0,12	-0,01	1	0,51
ITEM4	0,34	0,40	-0,21	-0,12
....
ITEM N	0,54	-0,17	0,51	1

Setelah mendapatkan nilai kemiripan antar produk, hasil tersebut digunakan dalam menghitung nilai prediksi tiap pengguna terhadap produk. Tabel berikut menguraikan hasil prediksi yang didapatkan menggunakan persamaan (4).

Tabel 5 Nilai prediksi rating user

User	ITEM	Nilai Prediksi
U1	item5	0,121
	item14	0,092
	item8	0,052
U2	Item13	0,069
	Item11	0,016
	Item4	0,005
U3	Item14	0,101
	Item2	0,095
	item5	0,062
...		
Un	item11	0,093
	item9	0,031
	item14	0,017

Berdasarkan data di atas, didapatkan nilai prediksi bahwa user 1 mendapatkan nilai prediksi penilaian sebesar 0,121 untuk produk item 5, 0.092 untuk produk item 14, 0.052 untuk produk item 8 dan terus berlanjut hingga user terakhir. Dari hasil di atas, maka sistem akan merekomendasikan produk tersebut kepada para user dan diurutkan berdasarkan nilai prediksi tertinggi.

3.4 Hasil Pengujian *Means Absolute Error*

Berikut adalah hasil perbandingan Mean Absolute Error metode collaborative filtering dan gabungan antara metode k-means dan collaborative filtering menggunakan data transaksi sales yang berasal dari periode 25 september 2021 – 25 september 2022:

Tabel 5 Nilai MAE

No	Metode		MAE
1.	Collaborative Filtering		0.114678277
2.	K-Means + Collaborative Filtering	Cluster 0	0.148915929
		Cluster 1	0.165700409
		Cluster 2	0.168181787
		Cluster 3	0.150847821
		MEAN Cluster	0.158411487

Dari data tabel 5 diatas menunjukkan bahwa metode collaborative filtering memperoleh nilai Mean Absolute Error sebesar 0.114678277. Pengujian dengan menggunakan metode k-means dan collaborative filtering memperoleh hasil MAE sebesar 0.148915929 pada *cluster* 0, 0.165700409 pada *cluster* 1, 0.168181787 pada *cluster* 2, dan 0.150847821 pada *cluster* 3. Dari hasil tersebut, didapatkan rata-rata hasil perhitungan MAE sebesar 0.158411487.

Metode collaborative filtering menghasilkan nilai Mean Absolute Error yang lebih baik dari rata-rata Mean Absolute Error metode Metode k-means dan collaborative filtering dengan perbandingan $0.11467 < 0.158411$. Jika nilai Mean Absolute Error mendekati 0, maka hasil prediksi akan semakin akurat.

4. KESIMPULAN

Berdasarkan hasil perancangan dan hasil pengujian yang di dapatkan, dapat ditarik beberapa kesimpulan seperti:

1. Dengan menggunakan metode K-Means Clustering didapatkan empat kelas hasil klasterisasi yang hasilnya cukup baik, berdasarkan data sales transaksi periode 25 september 2021 – 25 september 2022. Kesimpulan ini diperkuat dengan besaran nilai DBI yang di dapatkan untuk klasterisasi 4 klaster sebesar 0.7183746826 yang berada di level mendekati 0 dan nilai silhouette coefficient sebesar 0.747921909 yang mendekati nilai 1.
2. Metode *k-means* kurang efektif digabungkan dengan metode *collaborative filtering* dalam memberikan rekomendasi produk dalam sistem aplikasi ini karena pada metode Collaborative Filtering, jumlah data transaksi dan kebenaran data yang digunakan sangat mempengaruhi akurasi hasil rekomendasi.

DAFTAR PUSTAKA

- [1] Irwansyah, Edy, Clustering, <https://socs.binus.ac.id/2017/03/09/clustering/>, diakses tanggal 10 September 2022.
- [2] Lestari, Widhi., 2019, Clustering Data Mahasiswa Menggunakan Algoritma K-Means Untuk Menunjang Strategi Promosi (Studi Kasus: STMIK Bina Bangsa Kendari), *SIMKOM*, Vol. 4, No. 2.
- [3] Haviluddin., 2021, Implementasi Metode K-Means Untuk Pengelompokan Rekomendasi Tugas Akhir., *Informatika Mulawarman: Jurnal Ilmiah Ilmu Komputer*, Vol. 16, No. 1, hal. 13-18.
- [4] Wakhidah, Nur., 2010, Clustering menggunakan k-means algorithm, *Jurnal Transformatika*, Vol. 8, No. 1, hal. 33-39.
- [5] Nugroho, Fajar, dan Rahayu, Mina Ismu., 2020, SISTEM REKOMENDASI PRODUK UKM DI KOTA BANDUNG MENGGUNAKAN ALGORITMA COLLABORATIVE FILTERING, *Jurnal Riset Sistem Informasi dan Teknologi Informasi (JURSISTEKNI)*, Vol. 2, No. 3, hal. 23-31.
- [6] Girsang, Abba., Sistem Rekomendasi Content Based, <https://mti.binus.ac.id/2020/11/17/sistem-rekomendasi-content-based/>, diakses tanggal 10 September 2022.
- [7] Prasetyo, Bondan., 2019, Implementasi Metode Item-Based Collaborative Filtering dalam Pemberian Rekomendasi Calon Pembeli Aksesoris Smartphone, *Jurnal Eksplora Informatika*, Vol. 9, No. 1, hal. 17-27.
- [8] Sarwar, Badrul, Karypis George, Konstan, Joseph and Riedl, John., Item-Based Collaborative Filtering Recommendation Algorithms, <https://dl.acm.org/doi/10.1145/371920.372071>, diakses tanggal 10 September 2022.
- [9] Nasution, Darnisa Azzahra, Khotimah, Hidayah Husnul, dan Chamidah, Nurul., 2019, PERBANDINGAN NORMALISASI DATA UNTUK KLASIFIKASI WINE MENGGUNAKAN ALGORITMA K-NN, *Journal of Computer Engineering System and Science*, Vol. 4, No. 1, hal. 78–82.

- [10] Aziz, Arafa Rahman, Warsito, Budi, dan Prahutama, Alan., 2021, PENGARUH TRANSFORMASI DATA PADA METODE LEARNING VECTOR QUANTIZATION TERHADAP AKURASI KLASIFIKASI DIAGNOSIS PENYAKIT JANTUNG, *Jurnal Gaussian*, Vol. 10, No. 1, hal 21-30.
- [11] Pramesti, Dyang Falila, Furqon, Muhammad Tanzil, dan Dewi, Candra., 2017, Implementasi Metode K-Medoids Clustering Untuk Pengelompokkan Data Potensi Kebakaran Hutan/Lahan Berdasarkan Persebaran Titik Panas (Hotspot), *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 1, No. 9, hal. 723-732.
- [12] Wijayanti, Ratna Ayu, Furqon, Muh Tanzil, and Adinugroho, Sigit., 2018, Penerapan Algoritme Support Vector Machine Terhadap Klasifikasi Tingkat Risiko Pasien Gagal Ginjal., *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 2, No. 10, hal. 3500-3507.