

IMPLEMENTASI SISTEM REKOMENDASI PRODUK *TREATMENT* KECANTIKAN MENGGUNAKAN ALGORITMA SINGULAR VALUE DECOMPOSITION (STUDI KASUS : TYALASHES STUDIO)

Rilla Aswilyarti, Ahmad Fauzi

Sistem Informasi, Universitas Islam Negeri Imam Bonjol Padang
Sungai Bangek, Balai Gadang, Kec. Koto Tengah, Kota Padang, Sumatra Barat, Indonesia
rillaaswilyarti@gmail.com

ABSTRAK

Tyalashes Studio adalah sebuah bisnis UMKM yang berlokasi di Jalan Taman Ria, Kota Manokwari, Papua Barat dan bergerak di bidang *treatment* kecantikan. Tyalashes Studio ini menawarkan berbagai layanan perawatan kecantikan seperti perawatan wajah, perawatan mata, perawatan kuku, dan perawatan tubuh. Namun, Tyalashes Studio menghadapi tantangan dalam mencapai target penjualan produk *treatment* kecantikan yang ditawarkan. Masalah ini berpotensi menghambat pertumbuhan bisnis dan kepuasan pelanggan. Untuk mengatasi hal tersebut, penelitian ini bertujuan untuk memberikan rekomendasi produk dengan menggunakan Singular Value Decomposition (SVD) untuk menghasilkan rekomendasi produk yang akurat. SVD dipilih karena mampu mengidentifikasi pola tersembunyi dalam data dan memberikan rekomendasi yang relevan meskipun data bersifat *sparce*. Dataset penelitian terdiri dari 300 data *rating* dan 7 produk, yang dibagi menjadi 70% data *training* dan 30% data *testing*. Hasil evaluasi menunjukkan akurasi RMSE sebesar 0,9324, yang menggambarkan efektivitas Algoritma SVD dalam menghasilkan rekomendasi yang dapat meningkatkan penjualan produk di Tyalashes Studio.

Kata kunci : Tyalashes Studio, Singular Value Decomposition (SVD), Sistem Rekomendasi, Collaborative Filtering, RMSE

1. PENDAHULUAN

Treatment kecantikan merupakan layanan yang bertujuan untuk meningkatkan penampilan dan kesehatan kulit secara keseluruhan. *Treatment* kecantikan melibatkan penggunaan berbagai teknik, produk, dan peralatan khusus yang dirancang untuk mengatasi berbagai masalah kulit serta menjaga kecantikan alami kulit. Ada beberapa jenis *treatment* kecantikan, seperti *facial treatment*, *body treatment* dan *hair treatment* [1].

Bagi seorang wanita, tampil cantik dan menarik merupakan bagian tak terpisahkan dari gaya hidup. Di kota-kota besar, bisnis *treatment* sangat menjanjikan karena jumlah peminatnya yang cukup besar, terutama para wanita yang ingin tampil stylish [2].

Pertumbuhan Industri kecantikan Indonesia tumbuh 21,9% yang ditandai oleh peningkatan jumlah perusahaan dari 913 pada 2022 menjadi 1.010 pada 2023 [3], [4].

Nilai ekspor produk kosmetik, wewangian, dan essential oils mencapai Rp 11,562 triliun pada Januari-November 2023 [3].


UMKM mendominasi pertumbuhan ini, dengan jumlah perusahaan naik 20,6% dari 819 pada 2021 menjadi 913 pada 2022 [5].

Dalam konteks ini, Tyalashes Studio merupakan bisnis UMKM yang bergerak di bidang *treatment* kecantikan. Tyalashes Studio memberikan layanan seperti *face treatment*, *eye care*, *nail service* dan *body care*. Tyalashes Studio berlokasi di Jalan Taman Ria, Kota Manokwari, Papua Barat, 98312. Selain itu, Tyalashes Studio juga melayani secara *home care* khusus untuk wilayah Kota Manokwari. Adapun harga

yang ditawarkan oleh Tyalashes Studio relatif murah dengan kualitas yang baik. Saat ini, Tyalashes Studio melakukan promosi melalui media sosial seperti *Instagram*, *Facebook*, dan *TikTok*. Untuk pemesanan jasa *treatment* kecantikan konsumen dapat menggunakan aplikasi *WhatsApp*.

Berdasarkan wawancara dengan owner Tyalashes Studio pada tanggal 21 Maret 2024, diketahui target dari penjualan produk *treatment* kecantikan di Tyalashes Studio pada tahun 2021-2023 yaitu menjangkau 1000 konsumen. Namun pada kenyataannya, jumlah konsumen yang datang ke Tyalashes Studio pada tahun 2021-2023, hanya sekitar 200-300 konsumen saja. Dengan demikian, target pembelian konsumen pada tahun 2021-2023 belum tercapai. Owner Tyalashes Studio berharap agar pencapaian target pada tahun 2024 dan seterusnya dapat meningkat dibandingkan tahun-tahun sebelumnya.

Rumusan masalah yang diangkat dari latar belakang dapat dijelaskan melalui Gambar 1 sebagai berikut:



Gambar 1. Fishbone rumusan masalah

Gambar 1. menjelaskan permasalahan yang dihadapi oleh Tyalashes Studio saat ini, yaitu tidak tercapainya target penjualan produk perawatan kecantikan. Faktor-faktor penyebabnya yaitu: pertama, produk yang tersedia tidak sesuai dengan keinginan konsumen dan branding produk yang kurang dikenali; kedua, kualitas layanan yang tidak dapat memuaskan kebutuhan konsumen dan pengalaman yang tidak konsisten; ketiga, sumber daya manusia yang mengalami kekurangan tenaga kerja serta keterbatasan dalam pengembangan kreativitas; dan terakhir, promosi dan pemasaran yang kurang efektif serta keterbatasan dalam penghimpunan data konsumen. Dari berbagai faktor tersebut, peneliti memutuskan untuk fokus pada salah satu faktor, yaitu produk yang dibeli tidak sesuai dengan keinginan konsumen.

Salah satu cara untuk mengatasi permasalahan tersebut adalah dengan menggunakan sistem rekomendasi. Sistem rekomendasi merupakan alat penting dalam dunia digital, terutama dalam domain produk. Sistem ini dirancang untuk memberikan saran produk yang relevan kepada pengguna berdasarkan analisis data perilaku dan preferensi mereka. Dengan meningkatnya jumlah pilihan produk, sistem rekomendasi membantu mengatasi masalah *overload* informasi dengan menyajikan rekomendasi yang dipersonalisasi, sehingga pengguna dapat membuat keputusan pembelian yang lebih baik dan cepat [6].

Sistem ini berperan krusial dalam membantu pelanggan menemukan produk yang sesuai, meningkatkan penjualan, dan kepuasan pelanggan. Personalisasi pengalaman belanja memungkinkan perusahaan memberikan saran relevan berdasarkan preferensi dan kebiasaan pelanggan, sehingga meningkatkan keterlibatan dan efisiensi pencarian produk[7], [8], [9].

Namun, dampak dari kurangnya sistem rekomendasi yang efektif dapat menyebabkan hilangnya peluang penjualan dan ketidakpuasan konsumen. Ketika produk yang ditawarkan tidak sesuai dengan preferensi konsumen, hal ini berpotensi mengakibatkan konsumen beralih ke kompetitor yang menawarkan pengalaman belanja yang lebih baik. Selain itu, ketidakpuasan pelanggan dapat merugikan reputasi bisnis, yang pada gilirannya mempengaruhi pertumbuhan dan keberlanjutan usaha.

Dalam konteks ini, penelitian ini mengusulkan penggunaan algoritma Singular Value Decomposition (SVD) dengan pendekatan Collaborative Filtering. SVD tidak hanya dapat mengidentifikasi pola tersembunyi dalam data yang bersifat *sparse* atau tidak lengkap, namun juga dapat meningkatkan efisiensi komputasi dengan mengurangi dimensi data. Dengan menggunakan SVD, rekomendasi produk yang dihasilkan menjadi lebih relevan dan personal dibandingkan dengan metode yang tidak memanfaatkan algoritma SVD [10].

Berdasarkan latar belakang dan rumusan masalah di atas, pertanyaan dalam penelitian ini adalah sebagai

berikut: Pertama, bagaimana cara mengimplementasikan sistem rekomendasi produk *treatment* kecantikan menggunakan algoritma Singular Value Decomposition (SVD) pada Tyalashes Studio? Kedua, berapa hasil akurasi yang diperoleh dengan menggunakan *Root Mean Square Error* (RMSE) pada algoritma SVD?

2. TINJAUAN PUSTAKA

2.1. Sistem Rekomendasi

Sistem rekomendasi adalah kumpulan algoritma yang belajar dari data dan membuat rekomendasi kepada klien, biasanya digunakan untuk membantu pengguna dalam menemukan restoran dan produk lainnya[11].

Dapat disimpulkan bahwa, dengan mengumpulkan dan memproses data ini, sistem dapat menghasilkan rekomendasi yang dipersonalisasi, membantu pengguna menemukan produk yang mungkin mereka sukai atau butuhkan[6]. Sistem rekomendasi merupakan sistem yang bertujuan membantu memberikan rekomendasi bagi pengguna untuk menentukan suatu *item* atau produk yang menarik [12].

2.2. Singular Value Decomposition (SVD)

Singular Value Decomposition (SVD) merupakan metode faktorisasi matriks yang umum digunakan dalam sistem rekomendasi, khususnya dalam konteks *Model-Based Collaborative Filtering*. SVD berfungsi untuk mengurangi dimensi data dan mengekstrak fitur-fitur laten dari matriks interaksi pengguna-*item*, sehingga memungkinkan sistem untuk memprediksi preferensi pengguna terhadap *item* yang belum mereka interaksikan. Dengan menggunakan SVD, kita dapat mengidentifikasi pola dalam data dan memberikan rekomendasi yang lebih akurat berdasarkan kesamaan antara pengguna dan *item*.

SVD memecah sebuah matriks R menjadi sebuah aproksimasi dari matriks R asli. Secara matematis, SVD mendekomposisi matriks R menjadi sebuah matriks diagonal dan dua matriks uniter (*unitary matrix*). SVD mengurangi dimensi matriks *rating* R dengan mengekstrak faktor-faktor laten dan memetakan setiap pengguna ke setiap *item* dalam ruang laten berdimensi R [13].

SVD dapat didefinisikan sebagai berikut:

$$R = U S V^T \quad (1)$$

Keterangan :

R : matriks *rating* berukuran $m \times n$

U : matriks singular kiri ortogonal berukuran $m \times r$ yang mewakili matriks fitur *user*

S : matriks diagonal singular value berukuran $r \times r$

V^T : matriks singular kanan ortogonal berukuran $r \times n$ yang menunjukkan kemiripan antara *item* dan faktor laten

U mewakili berapa banyak *user* yang "menyukai" setiap fitur, dan V^T mewakili seberapa relevan setiap fitur dengan setiap produk.

2.3. Model SVD

Pada pembuatan model ini data yang sudah ada akan diubah menjadi sebuah matriks. Sebagai contoh data sample yang diambil sebanyak 5 user secara acak dari dataset, lalu dijadikan tabel seperti dibawah ini :

Tabel 1 Dataset sample

	P4	P5	P6	P7	P8	P9	P12
U1	0	3	4	0	0	0	0
U20	0	4	4	0	0	0	0
U75	0	5	0	3	0	0	0
U93	0	4	4	0	0	0	0
U117	0	5	5	0	0	0	0

Keterangan :

U1 – U117 : menjelaskan user atau konsumen

P4 – P12 : menjelaskan produk

Nilai dalam Tabel 1 menjelaskan *rating* yang telah diberikan oleh user terhadap produk dan untuk kolom yang nilainya 0 menjelaskan user yang belum memberikan *rating* terhadap produk tersebut.

Pertama, peneliti akan melakukan mengubah dataset pada Tabel 1 ke dalam bentuk matriks R. Selanjutnya matriks R diubah menjadi matriks R^T , dengan cara menukar baris dengan kolom. untuk mencari nilai determinan dari matriks R dan R^T , peneliti melakukan perkalian dari matriks R dan matriks R^T . sehingga peneliti dapat mencari nilai eigen dan vektor eigen dari matriks RR^T .

$$R = \begin{bmatrix} 0 & 3 & 4 & 0 & 0 & 0 & 0 \\ 0 & 4 & 4 & 0 & 0 & 0 & 0 \\ 0 & 5 & 0 & 3 & 0 & 0 & 0 \\ 0 & 4 & 4 & 0 & 0 & 0 & 0 \\ 0 & 5 & 5 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (2)$$

Selanjutnya lakukan transpose dari matriks R menjadi matriks R^T :

$$R^T = \begin{bmatrix} 0 & 3 & 4 & 0 & 0 & 0 & 0 \\ 0 & 4 & 4 & 0 & 0 & 0 & 0 \\ 0 & 5 & 0 & 3 & 0 & 0 & 0 \\ 0 & 4 & 4 & 0 & 0 & 0 & 0 \\ 0 & 5 & 5 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (3)$$

Hasil perkalian dari matriks R dan matriks RR^T :

$$RR^T = \begin{bmatrix} 25 & 28 & 15 & 28 & 35 \\ 28 & 32 & 20 & 32 & 40 \\ 15 & 20 & 34 & 20 & 25 \\ 28 & 32 & 20 & 32 & 40 \\ 35 & 40 & 25 & 40 & 50 \end{bmatrix} \quad (4)$$

Nilai eigen dan vektor eigen dari matriks RR^T :

$$\begin{aligned} v_1 &= \begin{bmatrix} 0.3946 \\ 0.4556 \\ 0.3239 \\ 0.4556 \\ 0.5695 \end{bmatrix}, \lambda_1 = 152.47 \\ v_2 &= \begin{bmatrix} 0.8882 \\ -0.2369 \\ 0.1052 \\ -0.2369 \\ -0.2962 \end{bmatrix}, \lambda_2 = 0.165 \\ v_3 &= \begin{bmatrix} -0.2354 \\ -0.1304 \\ 0.9402 \\ -0.1304 \\ -0.1630 \end{bmatrix}, \lambda_3 = 20.36 \\ v_4 &= \begin{bmatrix} -0.0000 \\ -0.0093 \\ -0.0000 \\ 0.7844 \\ -0.6201 \end{bmatrix}, \lambda_4 = 7.91 \times 10^{-17} \\ v_5 &= \begin{bmatrix} 0.0000 \\ -0.4743 \\ 0.0000 \\ -0.4623 \\ 0.7492 \end{bmatrix}, \lambda_5 = 3.78 \times 10^{-15} \end{aligned} \quad (5)$$

Keterangan:

v : vektor eigen

λ : nilai eigen

Setelah mendapatkan nilai eigen, maka didapat matriks S dengan nilai akar nilai eigen menjadi nilai matriks diagonal S berurutan dari yang terbesar ke yang terkecil.

$$S = \begin{bmatrix} \sqrt{152.47} & 0 & 0 & 0 & 0 \\ 0 & \sqrt{0.165} & 0 & 0 & 0 \\ 0 & 0 & \sqrt{20.36} & 0 & 0 \\ 0 & 0 & 0 & \sqrt{7.91 \times 10^{-17}} & 0 \\ 0 & 0 & 0 & 0 & \sqrt{3.78 \times 10^{-15}} \end{bmatrix}$$

$$S = \begin{bmatrix} 12.35 & 0 & 0 & 0 \\ 0 & 4.51 & 0 & 0 \\ 0 & 0 & 0.41 & 0 \\ 0 & 0 & 0 & 8.90 \times 10^{-19} \end{bmatrix} \quad (6)$$

Matriks U, Matriks S dan Matriks V^T :

$$U = \begin{bmatrix} 0.3946 & 0.2354 & -0.8882 & -2.46 \times 10^{-16} & -4.24 \times 10^{-16} \\ 0.4556 & 0.1304 & 0.2369 & 0.5687 & 0.6292 \\ 0.3239 & -0.9402 & -0.1052 & 3.56 \times 10^{-18} & 7.85 \times 10^{-18} \\ 0.4556 & 0.1304 & 0.2369 & 0.3574 & -0.7691 \\ 0.5695 & 0.1630 & 0.2962 & -0.7409 & 0.1119 \end{bmatrix}$$

$$S = \begin{bmatrix} 12.3481 & 4.5123 & 0.4065 & 4.77 \times 10^{-16} & 0 \\ 1.11 \times 10^{-16} & 0.7528 & 0.6536 & 0.0787 & 0 & 0 & 0 \\ 2.78 \times 10^{-17} & -0.4734 & 0.6206 & -0.6251 & 0 & 0 & 0 \\ 1.39 \times 10^{-15} & 0.4574 & -0.4333 & -0.7766 & 0 & 0 & 0 \\ 1 & -5.55 \times 10^{-16} & 6.66 \times 10^{-16} & 1.15 \times 10^{-15} & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (7)$$

2.4. Pengujian

Pengujian sistem rekomendasi melibatkan evaluasi metode dan algoritma yang digunakan untuk memberikan rekomendasi kepada pengguna. Proses ini mencakup pengukuran berbagai metrik kinerja, seperti *Root Mean Square Error* (RMSE). Tujuan utama dari pengujian ini adalah untuk menentukan seberapa akurat dan relevan rekomendasi yang dihasilkan oleh sistem dibandingkan dengan preferensi

pengguna yang sebenarnya. Pengujian yang baik tidak hanya ditunjukkan untuk menentukan kesalahan pada sistem tetapi juga untuk dapat ditemukannya data uji yang dapat menemukan kesalahan secara lebih teliti dan cepat. Pada penelitian ini, pengujian dilakukan untuk dapat mengetahui berapa hasil akurasi rekomendasi produk yang diberikan *rating* oleh *user* [12].

RMSE merupakan metrik yang digunakan untuk mengukur akurasi model dalam sistem rekomendasi, khususnya dalam konteks prediksi *rating* atau nilai yang diberikan oleh pengguna terhadap *item*. RMSE dihitung dengan cara mengambil akar kuadrat dari rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi. Dalam sistem rekomendasi, semakin kecil nilai RMSE, semakin baik model tersebut dalam memprediksi preferensi pengguna.

RMSE digunakan untuk membedakan kinerja model dalam periode kalibrasi dengan periode validasi serta untuk membandingkan kinerja model individual dengan model prediksi lainnya [12].

$$RMSE = \sqrt{\sum (y' - y)^2 / n} \quad (8)$$

Keterangan:

n = Jumlah data.

e = Error.

y' = Nilai output (prediksi)

y = Nilai aktual

3. METODE PENELITIAN

Penelitian ini menggunakan dataset penjualan di Tyalashes Studio selama dua tahun, dari tahun 2021 hingga 2023. Berikut adalah tahapan penelitian yang dilakukan:

3.1. Pengumpulan Data

Data dikumpulkan dari Tyalashes Studio, mencakup daftar produk, transaksi yang mencatat produk yang dibeli oleh konsumen, *rating* yang diberikan oleh konsumen, serta ID konsumen. Data ini diorganisir dalam format yang siap untuk dianalisis.

3.2. Pra-pemrosesan Data

Setelah pengumpulan, data yang diperoleh dibersihkan dan diproses. Tahapan ini meliputi penghapusan data yang tidak relevan atau duplikat, serta pengisian nilai yang hilang jika diperlukan. Data yang bersih akan memudahkan proses analisis selanjutnya.

3.3. Pembuatan Model Rekomendasi

Model rekomendasi dibangun menggunakan algoritma Singular Value Decomposition (SVD). Dalam tahap ini, data *rating* yang sudah diproses digunakan untuk membangun matriks yang merepresentasikan hubungan antara konsumen dan produk.

SVD akan digunakan untuk memprediksi *rating* yang belum diberikan oleh konsumen terhadap produk yang mungkin mereka minati.

3.4. Pengujian Model

Setelah model dibangun, dilakukan pengujian dengan membagi dataset menjadi data training (70%) dan data testing (30%). Data training digunakan untuk melatih model, sedangkan data testing digunakan untuk mengukur performa model.

3.5. Evaluasi Model

Performa rekomendasi produk dievaluasi dengan menghitung nilai Root Mean Square Error (RMSE). RMSE digunakan untuk mengukur sejauh mana prediksi *rating* dari model mendekati *rating* yang sebenarnya diberikan oleh konsumen.

Evaluasi ini penting untuk memastikan bahwa rekomendasi yang dihasilkan oleh model SVD akurat dan dapat diandalkan.

3.6. Analisis Hasil

Hasil evaluasi dianalisis untuk menentukan efektivitas model dalam memberikan rekomendasi produk. Jika hasil RMSE menunjukkan nilai yang rendah, maka model dianggap berhasil dalam memprediksi *rating* dengan akurat.

3.7. Penyusunan Rekomendasi

Berdasarkan hasil evaluasi, rekomendasi produk yang relevan akan disusun untuk Tyalashes Studio. Rekomendasi ini bertujuan untuk membantu meningkatkan penjualan dan memenuhi kebutuhan konsumen.

Dengan mengikuti tahapan penelitian ini, diharapkan dapat diperoleh hasil yang signifikan dalam pengembangan sistem rekomendasi produk di Tyalashes Studio, yang pada akhirnya dapat meningkatkan kepuasan konsumen dan penjualan.

4. HASIL DAN PEMBAHASAN

4.1. Visualisasi Data

Dataset dalam penelitian ini terdiri dari berbagai produk *treatment* kecantikan yang telah diberi *rating* oleh *user*. Yang terdiri dari Kolom *Product_Name* mencakup produk seperti *Japanese Manicure*, *Japanese Padicure*, *Korean Nail Art*, *Natural/Volume*, *Remove Eyelash*, dan *Russian*. Kolom *Count* menunjukkan jumlah *rating* yang diberikan oleh *user* untuk setiap produk. Kolom *Mean* menjelaskan rata-rata *rating*, sedangkan kolom *STD* menunjukkan deviasi standar, yang mengukur variabilitas *rating*; deviasi yang lebih rendah menunjukkan *rating* yang lebih dekat dengan rata-rata. Kolom *Min* mencatat *rating* terendah yang diterima setiap produk.


Rating digambarkan dalam bentuk kuartil. Kuartil pertama (25%) menunjukkan bahwa 25% *rating* berada di bawah angka ini, mencerminkan variasi pengalaman *user*. Kuartil kedua (50%) atau rata-rata adalah nilai tengah, di mana setengah *rating* berada di bawah dan setengah di atas angka ini. Kuartil ketiga (75%) menunjukkan bahwa 75% *rating* berada di bawahnya, membantu memahami batas atas *rating*

yang dianggap baik. Nilai maksimum (Max) mencerminkan *rating* tertinggi yang diterima produk, menunjukkan potensi terbaik dalam kepuasan *user*.


Dengan memahami *rating*, peneliti dapat mengevaluasi kualitas produk dan *respons user*. Misalnya, jika persentase 25% dan 50% menunjukkan *rating* rendah tetapi nilai maksimum tinggi, ini dapat mengindikasikan bahwa meskipun ada pengguna yang sangat puas, banyak yang mengalami ketidakpuasan. Data menunjukkan bahwa sebagian besar produk memiliki *rating* rata-rata yang tinggi, dengan produk *Russian* sebagai yang paling populer berdasarkan jumlah *rating*. *Japanese Manicure* dan *Japanese Padicure* juga memiliki *rating* rata-rata yang tinggi, menunjukkan kepuasan konsumen.

Distribusi *rating* dapat dilihat pada Gambar 2 dalam bentuk *box plot*. Produk *Russian* memiliki *rating* rata-rata sebesar 3.9, produk *Remove Eyelash* memiliki *rating* rata-rata 3.9, produk *Korean* memiliki *rating* rata-rata 3.8, produk *Japanese Padicure* dengan *rating* 4.2, produk *Natural/Volume* memiliki *rating* rata-rata 3.8, produk *Japanese Manicure* 4.3, dan produk *Nail Art* 3.7. Produk *Russian* menonjol dengan *rating* tertinggi, sementara *Nail Art* memiliki *rating* terendah. Variabilitas *rating* pada beberapa produk menunjukkan pengalaman konsumen yang beragam, yang dapat dieksplorasi lebih lanjut untuk meningkatkan kualitas.

Jumlah (Count) pembelian produk perawatan kecantikan menunjukkan bahwa produk *Russian* memiliki jumlah pembelian tertinggi yaitu sebesar 209. Produk *Remove Eyelash* memiliki pembelian sebesar 12, sementara *Natural/Volume* mencapai 26, dan *Korean* sebesar 38. *Japanese Padicure* dan *Japanese Manicure* memiliki jumlah pembelian yang hampir seimbang namun lebih rendah dibandingkan produk lainnya berkisar antara 5-3. *Nail Art* memiliki jumlah pembelian sedikit lebih tinggi daripada *Japanese Padicure* dan *Japanese Manicure* yaitu sebesar 7. Secara keseluruhan, produk *Russian* mendominasi jumlah pembelian, menunjukkan preferensi konsumen terhadap produk tersebut. Count produk dapat dilihat pada Gambar 3.



Gambar 2. Distribusi Rating



Gambar 3. Count Produk

4.2. Implementasi Algoritma SVD

Setelah peneliti mengisi nilai yang hilang (NaN) dalam *DataFrame* atau menggantinya dengan angka 0, peneliti mengubah *DataFrame* tersebut menjadi bentuk matriks agar dapat dioperasikan seperti matriks R. NaN (Not a Number) merupakan istilah yang digunakan dalam pengolahan data untuk menunjukkan nilai yang tidak terdefinisi atau hilang. Nilai ini sering muncul dalam dataset ketika data tidak tersedia atau tidak dapat diukur. Mengisi atau mengganti nilai NaN sangat penting untuk memastikan bahwa analisis data dapat dilakukan dengan baik, karena nilai yang hilang dapat memengaruhi hasil analisis dan pemodelan. Dengan mengatasi masalah ini, peneliti dapat melanjutkan pengolahan data dengan lebih akurat.

$$R = \begin{bmatrix} 0 & 0 & \dots & 3 & 4 \\ 0 & 0 & \dots & 0 & 2 \\ 0 & 0 & \dots & 0 & 5 \\ \vdots & \vdots & \ddots & \dots & \dots \\ 0 & 0 & \dots & 0 & 4 \\ 0 & 0 & \dots & 0 & 3 \\ 0 & 0 & \dots & 0 & 4 \end{bmatrix} \quad (9)$$

Untuk menghitung kesamaan antara *user*, peneliti perlu melakukan normalisasi data. Misalnya, peneliti memiliki matriks R yang terdiri dari berbagai nilai, seperti dibawah ini:

$$R = \begin{bmatrix} -1 & -1 & \dots & 2 & 3 \\ -0.2857 & -0.2857 & \dots & -0.2857 & 1.7143 \\ -0.7143 & -0.7143 & \dots & -0.7143 & 4.2857 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ -0.5714 & -0.5714 & \dots & -0.5714 & 3.4286 \\ -0.4286 & -0.4286 & \dots & -0.4286 & 2.5714 \\ -0.5714 & -0.5714 & \dots & -0.5714 & 3.4286 \end{bmatrix} \quad (10)$$

Dengan menggunakan matriks R, peneliti dapat menghitung kesamaan antar *user* dengan cara yang sesuai, sehingga peneliti bisa mendapatkan rekomendasi yang lebih akurat berdasarkan data yang telah dinormalisasi.

Selanjutnya, peneliti menghitung algoritma Singular Value Decomposition (SVD) untuk memprediksi *rating* yang diberikan oleh *user* sistem

rekomendasi menggunakan pendekatan *Collaborative Filtering*. Misalnya, peneliti memiliki matriks R yang berisi nilai-nilai sebagai berikut:

$$R = \begin{bmatrix} -4.2188 \times 10^{-15} & -3.5527 \times 10^{-15} & \dots & 3 & 4 \\ -1.6098 \times 10^{-15} & -2.1094 \times 10^{-15} & \dots & -1.7764 \times 10^{-15} & 2 \\ -1.2212 \times 10^{-15} & -1.2212 \times 10^{-15} & \dots & -7.7716 \times 10^{-16} & 5 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ -1.5543 \times 10^{-15} & -1.6653 \times 10^{-15} & \dots & -8.8818 \times 10^{-16} & 4 \\ -1.2212 \times 10^{-15} & -1.3323 \times 10^{-15} & \dots & -6.6613 \times 10^{-16} & 3 \\ -1.5543 \times 10^{-15} & -1.6653 \times 10^{-15} & \dots & -8.8818 \times 10^{-16} & 4 \end{bmatrix} \quad (11)$$

Dengan menggunakan algoritma SVD pada matriks R, peneliti dapat menganalisis struktur dataset dan memprediksi bagaimana *rating* yang mungkin diberikan oleh *user* berdasarkan pola yang ada dalam data *rating*, sehingga dapat meningkatkan akurasi dalam sistem rekomendasi.

4.3. Evaluasi Algoritma SVD

Evaluasi algoritma Singular Value Decomposition (SVD) dilakukan untuk mengukur tingkat akurasi model yang telah dibuat. Pengukuran akurasi dilakukan menggunakan metode RMSE. Dalam proses evaluasi, data dibagi menjadi dua bagian, yaitu 70% untuk data *training* dan 30% untuk data *testing*. Data *training* digunakan untuk membangun model, sementara data *testing* digunakan untuk memprediksi *rating*. Sebagai implementasi, peneliti menggunakan *userid* 21 yang telah memberikan *rating* pada produk 6 dan produk 5. Prediksi *rating* yang diperoleh adalah 3,972833 untuk produk 6 dan 3,931458 untuk produk 5. Berdasarkan data *testing*, hasil evaluasi menunjukkan nilai RMSE sebesar 0,9324, yang menunjukkan tingkat akurasi model yang baik. Hasil prediksi user 21 dapat dilihat pada Tabel 2.

Tabel 2 Hasil Prediksi User 21

use rid	produ ctId	product_n ame	categ ory	rati ng	rating_pr ediksi
21	6	Russian	Eye Care	3	3.972833
21	5	Remove Eyelash	Eye Care	4	3.931458

4.4. Hasil Rekomendasi

Dataset *Data_Product* mencakup kolom *Product_Id*, *Product_Name*, *Category* dan *Image*. Dataset *Data_Product*, yang dapat dilihat pada Gambar 4.

	Product_Id	Product_Name	Category	Image
0	p01	Totok Wajah	Face Treatment	/content/drive/MyDrive/Colab Notebooks/datakec...
1	p02	Ear Candle	Face Treatment	/content/drive/MyDrive/Colab Notebooks/datakec...
2	p03	Lash Lift	Face Treatment	/content/drive/MyDrive/Colab Notebooks/datakec...
3	p04	Natural/Volume	Eye Care	/content/drive/MyDrive/Colab Notebooks/datakec...
4	p05	Remove Eyelash	Eye Care	/content/drive/MyDrive/Colab Notebooks/datakec...

Gambar 4. Dataset *Data_Product*

Dataset *Rating* mencakup kolom *User_Id*, *Product_Id* dan *Rating*. Dataset *Rating* yang dapat dilihat pada Gambar 5.

	User_Id	Product_Id	Rating
0	U1	p06	4
1	U2	p06	4
2	U3	p06	4
3	U4	p06	5
4	U1	p05	3

Gambar 5. Dataset *Rating*

Selanjutnya, dua dataset di atas, *Data_Product* dan *Rating*, akan digabungkan berdasarkan *Product_Id*. Informasi produk, *rating*, dan gambar akan digunakan untuk analisis atau visualisasi dataset selanjutnya. Gabungan Dataset *Data_Product* dan *Rating* dapat dilihat pada Gambar 6.

	User_Id	Product_Id	Product_Name	Category	Rating	Image
0	U1	p06	Russian	Eye Care	4	/content/drive/MyDrive/Colab Notebooks/datakec...
1	U2	p06	Russian	Eye Care	4	/content/drive/MyDrive/Colab Notebooks/datakec...
2	U3	p06	Russian	Eye Care	4	/content/drive/MyDrive/Colab Notebooks/datakec...
3	U4	p06	Russian	Eye Care	5	/content/drive/MyDrive/Colab Notebooks/datakec...
4	U1	p05	Remove Eyelash	Eye Care	3	/content/drive/MyDrive/Colab Notebooks/datakec...
5	U3	p05	Remove Eyelash	Eye Care	4	/content/drive/MyDrive/Colab Notebooks/datakec...
6	U5	p06	Russian	Eye Care	5	/content/drive/MyDrive/Colab Notebooks/datakec...
7	U6	p06	Russian	Eye Care	3	/content/drive/MyDrive/Colab Notebooks/datakec...
8	U7	p06	Russian	Eye Care	3	/content/drive/MyDrive/Colab Notebooks/datakec...
9	U8	p06	Russian	Eye Care	4	/content/drive/MyDrive/Colab Notebooks/datakec...

Gambar 6. Gabungan dataset data *product* dan *rating*

Peneliti mengubah format data dalam kolom *userid* dan *productId* di *DataFrame*, lalu menyimpan hasilnya ke dalam kolom *userid* dan *productId*. Peneliti kemudian menghapus U pada kolom *userid*, dan menghapus p0 pada kolom *productId*. Menghapus U pada Kolom *Userid* dan p0 pada Kolom *ProductId* dapat dilihat pada Gambar 7.

	userid	productId	Product_Id	Product_Name	Category	Rating
0	1	6	p06	Russian	Eye Care	4
1	2	6	p06	Russian	Eye Care	4
2	3	6	p06	Russian	Eye Care	4
3	4	6	p06	Russian	Eye Care	5
4	1	5	p05	Remove Eyelash	Eye Care	3
...	...	...	...	...	...	...
295	284	12	p12	Nail Art	Nail Service	3
296	285	12	p12	Nail Art	Nail Service	3
297	286	12	p12	Nail Art	Nail Service	3
298	287	9	p09	Japanese Manicure	Nail Service	4
299	288	9	p09	Japanese Manicure	Nail Service	5

300 rows x 6 columns

Gambar 7. Menghapus u pada kolom *userid* dan p0 pada kolom *productId*

Membuat tabel pivot yang mengubah data menjadi bentuk matriks, yang mana setiap baris mewakili *userid*, setiap kolom mewakili *product_name*, dan nilai di setiap sel menunjukkan

rating yang diberikan oleh *user* tertentu terhadap produk tertentu. Mengubah Dataset Menjadi Bentuk Matriks dapat dilihat pada Gambar 8.

Product_Name	Japanese Manicure	Japanese Padicure	Korean	Nail Art	Natural/Volume	Remove Eyelash	Russian
userid							
1	0.0	0.0	0.0	0.0	0.0	3.0	4.0
10	0.0	0.0	0.0	0.0	0.0	0.0	2.0
100	0.0	0.0	0.0	0.0	0.0	0.0	5.0
101	0.0	0.0	0.0	0.0	0.0	0.0	2.0
102	0.0	0.0	0.0	0.0	0.0	0.0	4.0
...	...	...	...	...	...	...	...
95	0.0	0.0	0.0	0.0	0.0	0.0	5.0
96	0.0	0.0	0.0	0.0	0.0	0.0	4.0
97	0.0	0.0	0.0	0.0	0.0	0.0	4.0
98	0.0	0.0	0.0	0.0	0.0	0.0	3.0
99	0.0	0.0	0.0	0.0	0.0	0.0	4.0

288 rows x 7 columns

Gambar 8. Mengubah dataset menjadi bentuk matriks

Mengubah matriks prediksi *rating* yang dihasilkan dari dekomposisi SVD menjadi *DataFrame pandas*, dengan menambahkan indeks *userid* dan memastikan struktur data yang tepat untuk analisis selanjutnya. Hasil SVD masing-masing *rating* produk dapat dilihat pada Gambar 9.

Product_Name	Japanese Manicure	Japanese Padicure	Korean	Nail Art	Natural/Volume	Remove Eyelash	Russian
userid							
1	-4.218947e-15	-3.552714e-15	-3.330699e-15	-4.884981e-15	-1.554312e-15	3.000000e+00	4.0
10	-1.609823e-15	-2.109424e-15	-1.498801e-15	-3.330699e-16	-1.776357e-15	-1.776357e-15	2.0
100	-1.221245e-15	-1.221245e-15	-1.110223e-15	-1.110223e-16	-2.886580e-15	-7.771561e-16	5.0
101	-1.221245e-15	-1.276750e-15	-9.992007e-16	-8.326673e-16	-1.443290e-15	-6.661339e-16	2.0
102	-2.684535e-15	-2.775558e-15	-1.110223e-15	-1.887379e-15	-3.219647e-15	-1.665335e-15	4.0
...	...	...	...	...	...	...	...
95	-1.887379e-15	-1.998401e-15	-1.554312e-15	-8.881784e-16	-1.776357e-15	-9.992007e-16	5.0
96	-1.554312e-15	-1.665335e-15	-1.443290e-15	-8.881784e-16	-1.554312e-15	-8.881784e-16	4.0
97	-1.554312e-15	-1.665335e-15	-1.443290e-15	-8.881784e-16	-1.554312e-15	-8.881784e-16	4.0
98	-1.221245e-15	-1.332269e-15	-1.110223e-15	-6.661339e-16	-1.165734e-15	-6.661339e-16	3.0
99	-1.554312e-15	-1.665335e-15	-1.443290e-15	-8.881784e-16	-1.554312e-15	-8.881784e-16	4.0

288 rows x 7 columns

Gambar 9. Hasil svd masing-masing *rating* produk

Selanjutnya, menghasilkan rekomendasi produk berdasarkan prediksi *rating* untuk *user* dengan Id tertentu dalam gambar ini menggunakan *userid* 1 dan menampilkan 7 produk teratas beserta gambar produk menggunakan 5 sub-plot untuk visualisasi. Produk-produk ini merupakan hasil prediksi dari model yang memprediksi produk mana yang kemungkinan besar disukai oleh *user* berdasarkan pola *rating* yang diberikan. Hasil 5 Rekomendasi Produk Teratas dapat dilihat pada Gambar 10.

5 Rekomendasi Produk Teratas



Gambar 10. Hasil 5 rekomendasi produk teratas

Menampilkan jumlah *ratings* sebanyak 300, jumlah produk unik sebanyak 7, dan jumlah keseluruhan *user* unik sebanyak 288. Jumlah *Rating*, Produk dan *User* dapat dilihat pada Gambar 11.

Number of ratings: 300
Number of product: 7
Number of users: 288

Gambar 11. Menampilkan jumlah *rating*, produk dan *user*

Menampilkan hasil dari model SVD yang dilatih pada dataset pelatihan (*trainset*) dan diuji menggunakan dataset pengujian (*testset*). Prediksi *rating* yang dihasilkan dari model SVD digunakan untuk mengevaluasi kinerja model dalam memprediksi *rating* yang belum diberikan oleh *user*. Pada tabel tersebut, peneliti dapat melihat prediksi *rating* untuk produk dengan *productId* 6, yang diberi *rating* oleh *userid* 85, memberikan *rating real* sebesar 4.0, sedangkan *rating* prediksi yang dihasilkan adalah 3.972833; *userid* 5, memberikan *rating real* sebesar 5.0, dengan *rating* prediksi yang sama, yaitu 3.972833; *userid* 16, memberikan *rating real* sebesar 3.0, sementara *rating* prediksi adalah 3.972833; *userid* 1, memberikan *rating real* sebesar 4.0, sedangkan *rating* prediksi yang dihasilkan adalah 3.893624; Terakhir *userid* 106, memberikan *rating real* sebesar 3.0, dengan *rating* prediksi yang sama, yaitu 3.972833.

Dari hasil tersebut, peneliti dapat mengevaluasi seberapa baik model SVD dalam memprediksi *rating* yaitu: pertama kualitas prediksi, untuk *userid* 85 dan *userid* 5, prediksi mendekati *rating real*, yang menunjukkan bahwa model dapat merekomendasikan produk dengan akurat kepada *user* yang puas. Namun, untuk *userid* 16 dan *userid* 106, meskipun prediksi 3.972833 lebih tinggi dari *rating real* mereka (3.0), ini menunjukkan bahwa model mungkin tidak sepenuhnya memahami preferensi *user* ini, yang cenderung memberikan *rating* lebih rendah. Dalam hal *userid* 1, prediksi 3.893624 juga sedikit lebih rendah dari *rating real* 4.0, menunjukkan bahwa ada ruang untuk perbaikan dalam akurasi prediksi. Kedua interpretasi *rating*, Secara keseluruhan, *rating* prediksi yang berada di kisaran 3.9 hingga 4.0 dapat dianggap cukup baik, tetapi tidak sepenuhnya mencerminkan kepuasan yang dinyatakan oleh *user*. *Rating* yang lebih tinggi (seperti 5.0 dari *userid* 5) menunjukkan kepuasan yang sangat tinggi, sedangkan *rating* di bawah 4.0 mungkin mengindikasikan bahwa *user* tersebut tidak sepenuhnya puas dengan produk tersebut.

Meskipun model SVD ini sudah menunjukkan kemampuan dalam memprediksi *rating*, penting untuk terus memperbaiki model SVD agar lebih akurat dalam memahami preferensi *user* dan memberikan rekomendasi yang lebih relevan. Salah satu cara untuk melakukannya adalah dengan menambahkan lebih banyak data pelatihan, teknik analisis data lainnya untuk meningkatkan akurasi prediksi atau menggunakan algoritma yang lainnya. Hasil prediksi menggunakan *Trainset* dan *Testset* dapat dilihat pada Tabel 3.

Tabel 3. Hasil prediksi menggunakan *trainset* dan *testset*

userid	productId	rating	rating_prediksi
85	6	4	3.972833
5	6	5	3.972833
16	6	3	3.972833
1	6	4	3.893624
106	6	3	3.972833

5. KESIMPULAN DAN SARAN

Berdasarkan penelitian yang telah dilakukan, peneliti menyimpulkan bahwa implementasi pendekatan Collaborative Filtering menggunakan algoritma SVD pada sistem rekomendasi *treatment* kecantikan di Tyalashes Studio menunjukkan hasil yang baik. Penelitian ini menggunakan dataset yang terdiri dari 300 data *rating* dan 7 data produk yang diberikan *rating* oleh *user*. Dataset tersebut kemudian dibagi menjadi dua bagian, yaitu 70% untuk data *training* dan 30% untuk data *testing*. Hasil evaluasi keseluruhan menunjukkan bahwa akurasi sistem, diukur dengan nilai RMSE sebesar 0,9324.

Berdasarkan hasil yang diperoleh, peneliti memberikan beberapa saran untuk penelitian selanjutnya, yaitu mengembangkan sistem rekomendasi menjadi aplikasi berbasis *mobile* atau *web* agar konsumen lebih mudah mengakses rekomendasi produk dan meningkatkan interaksi pengguna. Selain itu, disarankan untuk memperluas dataset dengan menambahkan lebih banyak data *rating* dan produk, sehingga model dapat dilatih dengan lebih baik dan menghasilkan rekomendasi yang lebih akurat. Terakhir, analisis dampak implementasi sistem rekomendasi terhadap penjualan dan kepuasan pelanggan di Tyalashes Studio juga penting untuk menilai keberhasilan sistem yang diterapkan.

DAFTAR PUSTAKA

- [1] T. Paramitha, "Ini Jenis Treatment Favorit untuk Merawat Wajah, Body hingga Organ Intim," www.viva.co.id.
- [2] Pawoon, "Peluang Bisnis Eyelash Extension di Kota Besar." [Online]. Available: <https://www.pawoon.com/peluang-bisnis-eyelash-extension-di-kota-besar/>
- [3] H. Limanseto, "Hasilkan Produk Berdaya Saing Global, Industri Kosmetik Nasional Mampu Tembus Pasar Ekspor dan Turut Mendukung Penguatan Blue Economy," www.ekon.go.id.
- [4] D. Prabowo, "Demi Kebutuhan Penampilan, Industri Kecantikan Terus Meningkat," Kontan.co.id.
- [5] L. Hasibuan, "Industri Kecantikan Tahan Krisis, Laris Manis Meski Pandemi," CNBC Indonesia.
- [6] R. Auliarahman, "Sistem Rekomendasi: Tingkatkan pengalaman pengguna dengan saran yang relevan dan dipersonalisasi," RADYA DIGITAL. [Online]. Available: <https://radyadigital.com/id/blog/sistem-rekomendasi-tingkatkan-pengalaman-pengguna-dengan-saran-yang-relevan-dan-dipersonalisasi>
- [7] N. Lelyana, *Kepemimpinan Situasional dalam Manajemen Strategis: Mengelola Perubahan dengan Fleksibilitas dan Keberanian*. Bandung: Indonesia Emas Group, 2023.
- [8] D. Mokoginta, *PENGANTAR TEKNOLOGI INFORMASI*. Batam: Yayasan Cendikia Mulia Mandiri, 2024.
- [9] A. M. Thantawi, *Kupas Tuntas Mengenal BIG DATA*. Jambi: PT. Sonpedia Publishing Indonesia, 2023.
- [10] R. Akbar, D. Richasdy, and R. Dharayani, "Sistem Rekomendasi Buku Dengan Collaborative Filtering Menggunakan Metode Singular Value Decomposition (SVD)," *e-Proceeding of Engineering*, vol. 10, no. 5, pp. 5013–5019, 2023.
- [11] S. G, T. V, V. J, V. S, and R. M, "Restaurant recommendation system," *International Journal of Innovative Research in Advanced Engineering*, vol. 9, no. 8, pp. 207–211, Aug. 2022, doi: 10.26562/ijirae.2022.v0908.11.
- [12] F. R. Hariri and L. W. Rochim, "Sistem Rekomendasi Produk Aplikasi Marketplace Berdasarkan Karakteristik Pembeli Menggunakan Metode User Based Collaborative Filtering," *Teknika*, vol. 11, no. 3, pp. 208–217, Nov. 2022, doi: 10.34148/teknika.v11i3.538.
- [13] N. Bhalse and R. Thakur, "Algorithm for movie recommendation system using collaborative filtering," *Mater Today Proc*, Feb. 2021, doi: 10.1016/j.matpr.2021.01.235.