

Membangun Algoritma Rekomendasi Sederhana untuk Linimasa Twitter dengan SVD

Anas Ghazi Al Gifari - 13523159^{1,2}

Program Studi Teknik Informatika

Sekolah Teknik Elektro dan Informatika

Institut Teknologi Bandung, Jl. Ganesha 10 Bandung 40132, Indonesia

¹13523159@std.stei.itb.ac.id, ²anasghassie75@gmail.com

Abstrak—Dalam makalah ini, sebuah sistem rekomendasi berbasis analisis interaksi pengguna terhadap tweet telah dirancang dan diimplementasikan. Sistem ini menggunakan metode Singular Value Decomposition (SVD) untuk mengekstraksi hubungan laten antara pengguna dan konten, serta cosine similarity untuk menentukan tingkat kesesuaian antara preferensi pengguna dan tweet. Dengan mempertimbangkan relevansi waktu melalui bobot eksponensial peluruhan, sistem ini memberikan prioritas lebih tinggi kepada tweet yang lebih baru. Data yang digunakan berupa sampel data sintetis, yang merepresentasikan matriks interaksi antara pengguna dan tweet, serta waktu unggah tweet.

Langkah-langkah pengembangan melibatkan pembuatan matriks interaksi berbobot waktu, dekomposisi matriks, dan penghitungan skor kesamaan untuk menghasilkan rekomendasi. Masking skor dilakukan untuk memastikan bahwa tweet yang sudah diinteraksi oleh pengguna tidak muncul kembali dalam daftar rekomendasi. Hasil rekomendasi berupa lima tweet teratas untuk setiap pengguna menunjukkan bahwa sistem mampu memberikan saran konten yang sesuai dengan preferensi pengguna berdasarkan pola interaksi historis.

Hasil analisis menunjukkan efektivitas pendekatan yang digunakan dalam menghasilkan rekomendasi yang relevan. Namun, implementasi ini memiliki keterbatasan karena menggunakan data sintetis yang tidak sepenuhnya merepresentasikan kondisi nyata. Sebagai pengembangan lebih lanjut, implementasi ini dapat divalidasi menggunakan data aktual dan dioptimalkan dengan algoritma yang lebih kompleks untuk meningkatkan akurasi dan kualitas rekomendasi.

Keywords—Sistem Rekomendasi, Singular Value Decomposition, Cosine Similarity.

I. PENDAHULUAN

Twitter, atau yang sekarang dikenal dengan sebutan X, merupakan salah satu platform media sosial terbesar di dunia yang digunakan oleh jutaan pengguna setiap harinya. Dengan melimpahnya tweet yang diunggah setiap tahun, upaya menyajikan konten yang sesuai kepada pengguna pun menjadi kian penting. Sehubungan dengan hal ini, algoritma rekomendasi memegang peranan utama dalam meningkatkan pengalaman pengguna, menjaga interaksi, dan memastikan bahwa konten yang ditampilkan sesuai dengan preferensi dan kebutuhan pengguna.

Sistem rekomendasi adalah salah satu cabang dari kecerdasan buatan yang dirancang untuk memperkirakan konten yang mungkin menarik bagi pengguna tertentu. Di Twitter, rekomendasi tidak hanya membantu pengguna menemukan tweet yang sesuai, tapi juga mendorong penyebaran informasi, meningkatkan interaksi sosial, dan memperkuat ekosistem komunitas daring. Algoritma rekomendasi Twitter terbagi menjadi beberapa tahap, yaitu pengumpulan kandidat sumber, pemeringkatan dengan machine learning, dan penyaringan akhir untuk menjamin kualitas konten yang direkomendasikan [1].

Pada makalah ini, penulis membangun sebuah model sederhana untuk algoritma rekomendasi tweet dengan pendekatan matematis menggunakan teknik dekomposisi nilai singular (Singular Value Decomposition atau SVD), sebuah teknik dekomposisi matriks yang memisahkan matriks menjadi dua buah matriks ortogonal dan sebuah matriks diagonal yang memuat nilai singular. SVD memungkinkan analisis hubungan laten antara pengguna dengan tweet dalam ruang vektor berdimensi lebih rendah. Melalui representasi ini, dapat diidentifikasi tweet yang paling relevan untuk direkomendasikan kepada pengguna berdasarkan pola interaksi sebelumnya.

Model ini dirancang untuk memberikan pemahaman dasar mengenai cara kerja algoritma rekomendasi dengan mempertimbangkan keterbatasan data dan kompleksitas algoritma. Meskipun algoritma rekomendasi yang digunakan oleh Twitter pada kenyataannya jauh lebih rumit karena melibatkan model pembelajaran yang mendalam, pendekatan ini memberikan gambaran awal tentang prinsip-prinsip yang menjadi dasar dari sistem rekomendasi.

Makalah ini bertujuan untuk mengeksplorasi penerapan SVD dalam membangun sistem rekomendasi tweet yang berfokus pada pengembangan algoritma sederhana. Selain itu, makalah ini juga bertujuan untuk memberikan pemahaman mengenai hubungan antara teknik reduksi dimensi dan sistem rekomendasi, serta memberikan kontribusi terhadap literatur sistem rekomendasi berbasis matriks. Dengan demikian, hasil makalah ini diharapkan dapat memberikan wawasan yang bermanfaat mengenai penerapan SVD, khususnya pada pengembangan sistem rekomendasi dan pengolahan data.

II. DASAR TEORI

A. Sistem Rekomendasi

Sistem rekomendasi adalah teknologi yang bertujuan untuk memperkirakan preferensi pengguna terhadap hal-hal tertentu berdasarkan data historis. Sistem ini banyak diterapkan di berbagai bidang seperti e-commerce, layanan streaming, dan media sosial. Pada platform seperti Twitter, yang sekarang dikenal dengan sebutan X, sistem rekomendasi membantu memilah-milah hingga miliaran tweet untuk menampilkan konten yang sesuai bagi pengguna.

Pada umumnya, sistem rekomendasi dapat dibagi menjadi tiga kategori utama.

1. Content-based Filtering: Pendekatan ini merekomendasikan item kepada pengguna berdasarkan kemiripan fitur antara item dan preferensi pengguna. Misalnya, jika pengguna sering menyukai tweet bernuansa gaya bahasa formal, sistem dapat merekomendasikan tweet lain yang memiliki pola serupa. Dengan kata lain, Pendekatan ini bergantung pada representasi eksplisit dari fitur item, seperti teks, gaya penulisan, atau metadata lainnya.
2. Collaborative Filtering: Pendekatan ini memanfaatkan pola interaksi pengguna dengan item yang ada untuk memberikan rekomendasi. Collaborative Filtering dapat dibagi lagi menjadi dua kategori.
 - a. User-based Collaborative Filtering: Mencari pengguna dengan preferensi serupa untuk merekomendasikan item yang disukainya.
 - b. Item-based Collaborative Feeling: Mencari item yang sering diakses bersama oleh pengguna untuk merekomendasikan item yang serupa.Sebagai contoh, apabila seorang pengguna sering menyukai tweet yang telah disukai oleh pengguna lain, sistem akan merekomendasikan tweet tambahan dari pengguna serupa.
3. Hybrid Systems: Pendekatan hybrid memadukan content-based dan collaborative filtering untuk mengoptimalkan akurasi dan menangani kekurangan masing-masing metode.

Terkait dengan Twitter, pendekatan collaborative filtering kerap dijadikan landasan karena memungkinkan analisis pola interaksi antarpengguna (seperti like, retweet, dan reply) untuk menemukan hubungan laten antara pengguna dengan tweet. Sistem rekomendasi berbasis collaborative filtering sangat efektif dalam menangkap preferensi laten pengguna secara langsung tanpa memerlukan metadata eksplisit [2].

Oleh karena itu, makalah ini berfokus pada pendekatan collaborative filtering menggunakan dekomposisi matriks sebagai landasan eksplorasi awal algoritma rekomendasi.

B. Nilai Eigen dan Vektor Eigen

Nilai eigen (λ) dan vektor eigen (x) merupakan konsep dasar dalam aljabar linear yang menggambarkan sifat


transformasi matriks terhadap suatu vektor. Untuk sebuah matriks persegi A , hubungan ini dirumuskan dengan persamaan

$$Ax = \lambda x$$

dengan ketentuan:

- A : Matriks persegi ($n \times n$).
- x : Vektor eigen tidak nol.
- λ : Nilai eigen yang mengukur skala perubahan vektor v .

Dalam hal ini, nilai eigen juga dapat diartikan sebagai nilai representasi atau nilai karakteristik dari matriks A yang menyebabkan ketika vektor eigen dari matriks A dikalikan dengan matriks A , arahnya dapat menjadi berlawanan atau sama sekali tidak berubah. Sementara itu, panjangnya dikalikan dengan nilai eigennya itu sendiri.



Gambar 1. Grafik Perkalian Vektor Eigen Matriks A
Sumber:

<https://informatika.stei.itb.ac.id/~rinaldi.munir/AljabarGeometri/2023-2024/Algeo-19-Nilai-Eigen-dan-Vektor-Eigen-Bagian1-2023.pdf>

Nilai eigen menunjukkan seberapa besar skala (peregangan atau penyusutan) yang diterapkan pada vektor eigen tersebut. Jika $|\lambda| > 1$, vektor diperbesar. Sebaliknya, jika $0 < |\lambda| < 1$, vektor diperkecil. Hasil arah vektor eigen yang menjadi berlawanan atau sama sekali tidak berubah bergantung pada tanda dari nilai eigen.

Untuk menghitung nilai eigen dan vektor eigen yang diperlukan, berikut ini adalah tahapan yang dapat diikuti.

$$\begin{aligned} Ax &= \lambda x \\ IAx &= I\lambda x \\ Ax &= \lambda Ix \\ (\lambda I - A)x &= 0 \dots (1) \end{aligned}$$

Supaya memiliki solusi non-trivial ($x \neq 0$), haruslah berlaku persamaan karakteristik $\det(\lambda I - A) = 0$. Akar-akar karakteristik yang diperoleh dari persamaan tersebut, yaitu $\lambda_1, \lambda_2, \dots, \lambda_n$, adalah nilai eigen dari matriks A . Dengan mensubstitusi masing-masing nilai eigen ke persamaan (1), didapat vektor eigen yang berkorespondensi dengan nilai eigennya masing-masing.

C. Singular Value Decomposition (SVD)

Singular Value Decomposition merupakan salah satu metode untuk memecah matriks berukuran $m \times n$ menjadi tiga matriks, yaitu U , Σ , dan V , sedemikian sehingga memenuhi persamaan


$$A = U\Sigma V^T$$

dengan ketentuan:

- U : Matriks ortogonal berukuran $m \times m$.
- V : Matriks ortogonal berukuran $n \times n$.
- Σ : Matriks diagonal berukuran $m \times n$ yang elemen diagonal utamanya berupa nilai-nilai singular dari matriks A .

Proses dekomposisi matriks menggunakan SVD dapat dilakukan melalui langkah-langkah berikut.

1. Menentukan vektor-vektor singular kanan (v_1, v_2, \dots, v_n) yang merupakan vektor eigen dari matriks $A^T A$, kemudian menormalisasinya dengan membagi setiap vektor dengan panjangnya.
2. Menentukan vektor-vektor singular kiri (u_1, u_2, \dots, u_m) dengan membagi Av_i dengan nilai singular σ_i yang tidak nol, untuk $1 \leq i \leq m$, lalu menormalisasinya dengan membagi setiap vektor dengan panjangnya.
3. Membentuk matriks Σ berukuran $m \times n$ dengan elemen-elemen diagonal utamanya berupa nilai singular yang tidak nol. Urutan nilai elemen disusun secara menurun.



Gambar 2. Singular Value Decomposition

Sumber:

<https://informatika.stei.itb.ac.id/~rinaldi.munir/AljabarGeometri/2023-2024/Algeo-21-Singular-value-decomposition-Bagian1-2023.pdf>

Untuk tujuan praktis seperti sistem rekomendasi, matriks hasil dekomposisi $A = U\Sigma V^T$ dapat direduksi untuk menghilangkan komponen dengan nilai singular kecil yang dinilai tidak signifikan. Proses ini mengurangi dimensi data dengan memilih sejumlah r nilai singular terbesar dari matriks diagonal Σ . Sebagai hasilnya, matriks A dapat direduksi menjadi aproksimasi.

$$A' = U_r \Sigma_r V_r^T$$

dengan ketentuan:

- U_r : Submatriks dari U yang hanya mempertahankan r kolom pertama.
- Σ_r : Matriks diagonal berukuran $r \times r$ yang berisi r nilai singular terbesar.
- V_r^T : Submatriks dari V^T yang hanya mempertahankan r baris pertama.

Pendekatan ini menghasilkan matriks aproksimasi A' yang lebih kecil dibandingkan matriks asli A , tapi tetap mampu menangkap hubungan laten yang cukup signifikan antara pengguna dengan item.

D. Cosine Similarity

Cosine Similarity adalah sebuah metrik yang digunakan untuk mengukur tingkat kemiripan antara dua vektor dalam ruang multidimensi berdasarkan besar sudut di antara keduanya. Nilai Cosine Similarity dihitung dengan menggunakan persamaan

$$\text{Cosine Similarity}(u, t) = \frac{u \cdot t}{\|u\| \|t\|}$$

dengan ketentuan:

- u dan t : Vektor yang dibandingkan.
- $u \cdot t$: Hasil perkalian dot product antara kedua vektor.
- $\|u\|$ dan $\|t\|$: Norm atau panjang masing-masing vektor.

Nilai Cosine Similarity berkisar antara -1 hingga 1 . Angka 1 menunjukkan vektor searah dan identik, 0 menunjukkan tidak ada kesamaan arah atau ortogonal, dan -1 menunjukkan vektor berlawanan arah. Dalam kaitannya dengan sistem rekomendasi, Cosine Similarity sering digunakan untuk mengukur kemiripan preferensi atau pola laten antara pengguna dengan item.

E. Relevansi Waktu

Dalam sistem rekomendasi dinamis, waktu memiliki pengaruh penting pada relevansi item. Khususnya untuk linimasa media sosial seperti Twitter karena relevansi sebuah tweet cenderung menurun seiring berjalannya waktu. Relevansi waktu dapat dimodelkan dengan menggunakan fungsi peluruhan eksponensial.

$$w(t) = e^{-\lambda \Delta t}$$

dengan ketentuan:

- Δt : $t_{now} - t_{tweet}$, dengan t_{now} adalah waktu saat ini dan t_{tweet} adalah waktu ketika tweet diunggah.
- λ : Konstanta peluruhan yang menentukan tingkat penurunan relevansi seiring berjalannya waktu.

III. IMPLEMENTASI

A. Persiapan Sampel Data Sintetis

Untuk mendemonstrasikan sistem rekomendasi ini,

digunakan sampel data sintetis yang berbentuk matriks interaksi antara pengguna dengan tweet. Sampel ini dirancang untuk menggambarkan pola interaksi hipotetis dalam sistem rekomendasi, sekaligus menjaga kerangka implementasi tetap sederhana dan terfokus.

```
# Matriks Interaksi Awal
A = [
  [2, 0, 1, 0, 2, 1, 0, 0, 1, 0, 0, 3, 0, 1, 2, 0, 0, 2, 1, 1],
  [0, 3, 0, 2, 1, 0, 2, 0, 0, 0, 2, 0, 1, 0, 0, 0, 2, 0, 1, 2],
  [1, 0, 0, 0, 2, 0, 0, 3, 0, 0, 0, 1, 2, 2, 0, 0, 1, 3, 0, 0],
  [0, 0, 3, 0, 0, 2, 0, 2, 0, 0, 1, 0, 0, 2, 1, 0, 0, 1, 0, 4],
  [2, 0, 0, 1, 1, 0, 0, 1, 0, 2, 0, 0, 0, 1, 0, 2, 0, 0, 2, 0],
  [0, 2, 0, 3, 0, 2, 1, 0, 0, 0, 2, 0, 0, 0, 1, 0, 2, 0, 0, 2],
  [3, 1, 0, 0, 0, 0, 2, 0, 0, 1, 0, 2, 0, 4, 0, 1, 2, 0, 0, 1],
  [1, 0, 2, 0, 0, 0, 0, 0, 2, 0, 0, 1, 0, 0, 0, 0, 2, 0, 2, 0],
  [0, 0, 0, 1, 0, 2, 0, 0, 2, 0, 0, 1, 0, 2, 0, 0, 0, 1, 2, 1],
  [2, 0, 3, 0, 0, 0, 1, 0, 1, 1, 0, 0, 2, 0, 0, 2, 0, 0, 2, 3]
]
```

Gambar 3. Sampel Data Sintetis Interaksi Antara Pengguna dengan Tweet
Sumber: Dokumentasi Pribadi

Sampel data sintetis ini disusun dalam struktur matriks A berukuran 10×20 dengan baris merepresentasikan 10 pengguna dan kolom merepresentasikan 20 tweet. Elemen A_{ij} menunjukkan skor interaksi pengguna i terhadap tweet j . Nilai dari skor tersebut ditentukan seperti berikut.

- 0: Tidak ada interaksi.
- 1: Salah satu dari jenis interaksi (like, retweet, reply, atau quote retweet).
- 2— 4: Kombinasi dari dua atau lebih jenis interaksi.

Setiap tweet dalam matriks memiliki informasi tentang waktu unggahannya. Waktu ini dinyatakan dalam jumlah jam sejak tweet tersebut diunggah.

```
# Waktu (jam) yang telah berlalu sejak tweet diunggah
Delta_t = [2, 14, 3, 15, 8, 5, 8, 20, 10, 1, 6, 9, 13, 4, 11, 7, 12, 9, 6]
```

Gambar 4. Sampel Data Sintetis Waktu Unggahan Tweet
Sumber: Dokumentasi Pribadi

Bobot relevansi waktu akan dihitung menggunakan fungsi peluruhan eksponensial:

$$w_j = e^{-\lambda \Delta t_j}$$

dengan ketentuan:

- $\Delta t_j: t_{now} - t_{tweet}$.
- $\lambda = 0.01$ sebagai konstanta peluruhan.

B. Membangun Sistem Rekomendasi

Pada realisasi fungsi peluruhan ini, data sintetis yang menyatakan waktu unggahan tweet digunakan untuk menghitung bobot relevansi waktu. Setelah itu, setiap kolom dalam matriks interaksi dikalikan dengan bobot yang sesuai.

```
# Fungsi peluruhan waktu
def compute_time_weights(times):
    times = np.array(times)
    return np.exp(-0.01 * times)

# Memperbarui matriks interaksi dengan bobot waktu
w_j = compute_time_weights(Delta_t)
weighted_A = A * w_j
```

Gambar 5. Perhitungan bobot relevansi waktu
Sumber: Dokumentasi Pribadi

Tweet yang lebih baru memiliki bobot relevansi lebih tinggi dibandingkan yang lama. Selanjutnya, setiap kolom dalam matriks interaksi dikalikan dengan bobot relevansi waktu yang sesuai.

Matriks berbobot ini kemudian diolah menggunakan Singular Value Decomposition (SVD) untuk menangkap hubungan laten antara pengguna dan tweet. Setelah SVD diimplementasikan, skor rekomendasi dihitung menggunakan metrik cosine similarity.

```
# SVD
U, Sigma, VT = np.linalg.svd(weighted_A, full_matrices=False)

# Normalisasi vektor pengguna (U) dan tweet (VT.T)
normalized_U = normalize(U, axis=1) # Baris pengguna
normalized_VT = normalize(VT, axis=1) # Kolom tweet

# Hitung cosine similarity
cosine_similarity_scores = np.dot(normalized_U, normalized_VT)
```

Gambar 6. Dekomposisi Matriks dan Perhitungan Cosine Similarity
Sumber: Dokumentasi Pribadi

Sebelum menyelesaikan algoritma rekomendasi, akan dipelakukan masking skor. Tweet yang sudah diinteraksi sebelumnya oleh pengguna diberi nilai $-\infty$ sehingga tidak akan dipertimbangkan dalam rekomendasi.

```
# Masking
mask = np.where(np.array(A) > 0, -np.inf, 0) # Tweet yang sudah diinteraksi = -inf
masked_scores = cosine_similarity_scores + mask
```

Gambar 7. Masking
Sumber: Dokumentasi Pribadi

Terakhir, tweet dengan skor tertinggi diurutkan dan tweet 5 teratas ditampilkan untuk setiap pengguna pada linimasa masing-masing.

```
# Mengambil 5 tweet dengan skor tertinggi
top_k = 5
final_recommendations_top_k = np.argsort(-masked_scores, axis=1)[: , :top_k]

# Menampilkan rekomendasi For You
for user_id, recs in enumerate(final_recommendations_top_k):
    print(f"Rekomendasi untuk Pengguna {user_id + 1}: {recs + 1}")
```

Gambar 8. Rekomendasi yang diperoleh
Sumber: Dokumentasi Pribadi

C. Hasil Algoritma

Pada implementasi sederhana ini, hanya 5 tweet dengan skor tertinggi yang relevan dan belum diinteraksi yang akan direkomendasikan. Berdasarkan sampel data sintetis yang digunakan, berikut rekomendasi yang ditampilkan.

Rekomendasi untuk Pengguna 1:	[2 11 7 4 10]
Rekomendasi untuk Pengguna 2:	[12 9 18 8 14]
Rekomendasi untuk Pengguna 3:	[4 6 10 9 7]
Rekomendasi untuk Pengguna 4:	[10 5 2 19 7]
Rekomendasi untuk Pengguna 5:	[15 11 6 2 3]
Rekomendasi untuk Pengguna 6:	[1 13 16 10 18]
Rekomendasi untuk Pengguna 7:	[11 9 3 15 6]
Rekomendasi untuk Pengguna 8:	[9 2 12 7 4]
Rekomendasi untuk Pengguna 9:	[16 7 2 11 13]
Rekomendasi untuk Pengguna 10:	[17 4 6 15 12]

Gambar 9. Rekomendasi Tweet yang diterima oleh para pengguna

Sumber: Dokumentasi Pribadi

Berdasarkan hasil rekomendasi yang dihasilkan, terdapat variasi rekomendasi antarpengguna. Setiap pengguna menerima rekomendasi tweet yang berbeda, mencerminkan personalisasi sistem berdasarkan matriks interaksi dan relevansi waktu. Selain itu, terdapat pula pola dominasi tweet. Beberapa tweet mungkin muncul dalam rekomendasi untuk banyak pengguna. Ini dapat menunjukkan bahwa tweet tersebut memiliki skor tinggi di berbagai pengguna.

IV. KESIMPULAN

Dalam makalah ini, sebuah sistem rekomendasi berbasis analisis interaksi pengguna terhadap tweet telah berhasil diimplementasikan. Proses pengembangan sistem mencakup serangkaian langkah yang dimulai dengan pembuatan sampel data sintetis, perhitungan relevansi waktu, dekomposisi matriks menggunakan Singular Value Decomposition (SVD), hingga penghitungan skor rekomendasi berbasis cosine similarity. Sistem ini dirancang untuk memberikan rekomendasi yang relevan dengan mempertimbangkan interaksi historis pengguna dan waktu unggah tweet.

Langkah pertama adalah menentukan matriks interaksi antara pengguna dengan tweet. Matriks ini disesuaikan dengan relevansi waktu menggunakan bobot eksponensial peluruhan. Dengan pendekatan ini, sistem dapat memberikan bobot lebih tinggi pada tweet yang diunggah lebih baru, sehingga meningkatkan relevansi rekomendasi. Setelah matriks diperbarui dengan bobot relevansi waktu, proses dekomposisi SVD dilakukan untuk menangkap hubungan laten antara pengguna dan tweet. Komponen hasil dekomposisi, yaitu matriks U, Sigma, dan VT, memberikan representasi laten yang memungkinkan penghitungan kesamaan antara pengguna dan tweet secara efisien.

Cosine similarity digunakan untuk mengukur kesamaan antara vektor laten pengguna dan tweet. Untuk memastikan bahwa rekomendasi yang diberikan adalah konten baru, tweet yang sudah diinteraksi oleh pengguna diberi nilai -inf dalam proses masking skor. Sistem ini kemudian menghasilkan daftar rekomendasi berupa lima tweet teratas untuk setiap pengguna berdasarkan skor tertinggi. Analisis hasil menunjukkan pola tertentu, di mana rekomendasi untuk pengguna cenderung mencerminkan

interaksi dan preferensi historis mereka.

Keseluruhan sistem menunjukkan bahwa pendekatan berbasis SVD dan cosine similarity dapat memberikan hasil rekomendasi yang relevan dan bermanfaat. Namun, terdapat beberapa keterbatasan yang perlu dicatat. Sampel data yang digunakan adalah data sintetis sehingga tidak sepenuhnya merepresentasikan pola interaksi nyata di dunia nyata. Selain itu, meskipun relevansi waktu telah diperhitungkan, parameter peluruhan waktu masih dapat dioptimalkan lebih lanjut untuk mencocokkan preferensi pengguna secara lebih presisi.

Sebagai langkah lanjutan, sistem rekomendasi ini dapat dikembangkan dengan menggunakan data aktual untuk validasi sistem dan meningkatkan akurasi rekomendasi. Penggunaan model yang lebih kompleks, seperti metode pembelajaran mendalam, juga dapat dieksplorasi untuk menangkap pola interaksi yang lebih mendalam. Dengan demikian, sistem rekomendasi dapat terus ditingkatkan untuk memberikan pengalaman pengguna yang lebih baik dan sesuai kebutuhan.

V. UCAPAN TERIMA KASIH

Dengan segala kerendahan hati, penulis menyampaikan rasa syukur dan terima kasih yang sebesar-besarnya kepada semua pihak yang telah memberikan dukungan dalam menyelesaikan makalah ini. Proses yang dijalani tidak akan mungkin terselesaikan tanpa bantuan, dukungan, dan kerja sama dari berbagai pihak.

Pertama, penulis mengucapkan terima kasih kepada yang telah memberikan fasilitas dan lingkungan yang kondusif untuk mendukung pengembangan implementasi ini. Penghargaan juga disampaikan kepada pembimbing akademik yang telah memberikan arahan, masukan, dan kritik konstruktif selama proses penelitian berlangsung.

Selain itu, terima kasih disampaikan kepada rekan-rekan sejawat yang telah berbagi wawasan, memberikan motivasi, dan menjadi tempat berdiskusi yang produktif selama penelitian ini berlangsung. Dukungan moral dari keluarga dan sahabat juga menjadi kekuatan utama dalam menyelesaikan tugas ini.

Akhir kata, penulis berharap agar hasil implementasi ini dapat memberikan kontribusi yang berarti bagi pengembangan ilmu pengetahuan, khususnya dalam bidang sistem rekomendasi.

REFERENCES

- [1] X Engineering, "Twitter recommendation algorithm," *X Blog*, Apr. 2023. [Online]. Available: https://blog.x.com/engineering/en_us/topics/open-source/2023/twitter-recommendation-algorithm. [Diakses 1 Januari 2025]
- [2] P. Ricci, L. Rokach, and B. Shapira, *Recommender Systems Handbook*, 2nd ed. New York, NY, USA: Springer, 2015, pp. 1–35.
- [3] <https://informatika.stei.itb.ac.id/~rinaldi.munir/AljabarGeometri/2-023-2024/Algeo-19-Nilai-Eigen-dan-Vektor-Eigen-Bagian1-2023.pdf> [Diakses 2 Januari 2025]
- [4] <https://informatika.stei.itb.ac.id/~rinaldi.munir/AljabarGeometri/2-023-2024/Algeo-21-Singular-value-decomposition-Bagian1-2023.pdf> [Diakses 2 Januari 2025]

PERNYATAAN

Dengan ini saya menyatakan bahwa makalah yang saya tulis ini adalah tulisan saya sendiri, bukan saduran, atau terjemahan dari makalah orang lain, dan bukan plagiasi.

Bandung, 2 Januari 2024



Anas Ghazi Al Gifari