

## BAB V

### PENUTUP

#### 5.1 Kesimpulan

Berdasarkan hasil analisis, implementasi perangkat lunak, dan pengujian algoritma pada Sistem Rekomendasi Film menggunakan pendekatan komparatif (*Collaborative*, *Content-Based*, dan *Demographic Filtering*), penelitian ini menghasilkan beberapa kesimpulan utama sebagai berikut:

##### 1. Keberhasilan Implementasi Arsitektur *Microservices* yang Terintegrasi

Sistem rekomendasi ini telah berhasil dibangun dan diimplementasikan menggunakan arsitektur *Microservices* yang memisahkan lingkungan *frontend* dan *backend*. Antarmuka pengguna (*client-side*) berhasil dikembangkan menggunakan *framework* Next.js (TypeScript) yang dirilis secara langsung melalui platform *cloud* Vercel. Sementara itu, mesin komputasi analitik (*server-side*) yang memproses algoritma *Machine Learning* dibangun menggunakan Python (Flask) dan berjalan secara independen pada *container* Hugging Face Spaces. Pemisahan ini terbukti mampu menangani beban pemrosesan *dataset* MovieLens (100.000 observasi *rating* dan 9.000 katalog film) tanpa menyebabkan *bottleneck* atau penurunan performa pada sisi antarmuka pengguna.

##### 2. Validasi Integritas Data pada Matriks SVD

Penelitian ini menyimpulkan bahwa algoritma *Singular Value Decomposition* (SVD) sangat bergantung pada batasan ruang lingkup matriks data yang telah dilatih (*trained data*). Sistem telah berhasil menerapkan protokol validasi ketat (*guarding*) pada sisi *frontend* yang mengunci *input* interaksi *Collaborative Filtering* hanya untuk *User ID* 1

hingga 671. Pendekatan ini secara efektif mencegah terjadinya anomali komputasi (*out-of-bounds error*) pada *backend*, sehingga memastikan setiap hasil prediksi *rating* yang dikeluarkan oleh sistem bersifat valid dan secara matematis dapat dipertanggungjawabkan sesuai dengan pangkalan data *MovieLens*.

### 3. Perumusan Metrik *Recommendation Quality Score* (RQS)

Penelitian ini berhasil membuktikan bahwa metrik akurasi tunggal (seperti RMSE) tidak cukup untuk merepresentasikan kepuasan pengguna. Oleh karena itu, sistem telah mengimplementasikan evaluasi multikriteria melalui *Recommendation Quality Score* (RQS) yang menggunakan pendekatan pembobotan heuristik dengan rasio 40% Akurasi, 30% Personalisasi, dan 30% Diversitas. Metrik agregat ini terbukti mampu mengukur dan memvisualisasikan kualitas hasil rekomendasi secara waktu nyata (*real-time*) dengan menyeimbangkan ketepatan prediksi matematis dan keberagaman tontonan.

### 4. Superioritas *Collaborative Filtering* (SVD) Berdasarkan Skor RQS

Melalui pengujian empiris yang dievaluasi dengan skor RQS, algoritma *Collaborative Filtering* menggunakan metode SVD terbukti sebagai pendekatan yang paling superior dibandingkan dua metode lainnya.

- o Metode *Demographic Filtering* menghasilkan skor RQS terendah (berkisar antara 45.00 hingga 48.00) karena pendekatannya yang bersifat generalisasi (populer) terkena penalti pada kriteria personalisasi.
- o Metode *Content-Based Filtering* menghasilkan skor RQS menengah (berkisar antara 75.00 hingga 85.00) karena meskipun memiliki personalisasi yang tinggi berdasarkan atribut kemiripan *genre*,

algoritma ini rentan terhadap fenomena *Filter Bubble* yang membatasi nilai diversitas.

- o Metode *Collaborative Filtering* (SVD) secara konsisten menghasilkan skor RQS tertinggi (berkisar antara 88.00 hingga 98.00). Hal ini membuktikan bahwa kemampuan SVD dalam mengekstraksi korelasi laten (*latent factors*) dari pola interaksi pengguna mampu memberikan rekomendasi yang sangat akurat dan personal, namun tetap menyajikan elemen kejutan (*serendipity*) lintas *genre* yang menjaga nilai diversitas tetap optimal.

## 5.2 Saran

Meskipun sistem rekomendasi film ini telah beroperasi dengan baik sesuai dengan perancangan teori, masih terdapat beberapa ruang untuk pengembangan lebih lanjut. Oleh karena itu, penulis memberikan beberapa saran untuk penelitian selanjutnya, yaitu:

### 1. Penggunaan Dataset Berskala Masif dan Dinamis

Penelitian ini masih menggunakan spesifikasi *MovieLens Small Dataset* (100.000 rating, 671 pengguna). Untuk penelitian selanjutnya, disarankan untuk mengimplementasikan dataset yang lebih masif, seperti *MovieLens 20M* atau *25M Dataset*, serta membangun saluran pembaruan data secara dinamis (*dynamic data pipeline*). Hal ini akan meningkatkan akurasi faktor laten pada matriks SVD secara signifikan saat menghadapi interaksi pengguna riil yang terus bertambah.

### 2. Penerapan Algoritma *Deep Learning*

Untuk meningkatkan kualitas metrik Personalisasi dan Diversitas, penelitian di masa depan dapat membandingkan algoritma matriks faktorisasi konvensional (SVD) dengan pendekatan berbasis jaringan saraf

tiruan (*Artificial Neural Networks*), seperti *Neural Collaborative Filtering* (NCF) atau model *Autoencoders*. Metode tersebut dinilai lebih tangguh dalam memodelkan interaksi non-linear antara pengguna dan item film.

### 3. Kalibrasi Bobot Heuristik melalui *A/B Testing*

Distribusi pembobotan heuristik RQS (40-30-30) pada penelitian ini ditetapkan berdasarkan perancangan logika fungsional sistem. Penelitian selanjutnya disarankan untuk melakukan pengujian langsung kepada responden manusia (*User Acceptance Testing* atau *A/B Testing*) untuk melakukan kalibrasi bobot yang lebih empiris. Umpan balik langsung dari pengguna dapat digunakan untuk memvalidasi apakah persentase bobot tersebut benar-benar merepresentasikan kepuasan (*user satisfaction*) di dunia nyata.

