

PENINGKATAN KINERJA SISTEM REKOMENDASI WISATA MELALUI PENERAPAN ALGORITMA COLLABORATIVE FILTERING DAN K-NEAREST NEIGHBORS DENGAN METODE KLASTERISASI K-MEANS

M Ferrari Firmansyah, Abdul Aziz, Moh Ahsan

Program Studi Teknik Informatika, S1, Fakultas Sains dan Teknologi
Universitas.PGRI.Kanjuruhan.Malang, Jalan S.Supriadi No.48.Malang, Indonesia
mferrarifirmansyah@gmail.com

ABSTRAK

Sistem rekomendasi wisata mengolah data wisata menjadi informasi yang disajikan untuk user. Banyak metode yang bisa digunakan untuk membuat system rekomendasi. Dalam penerapan system rekomendasi pasti ada kelemahan yang harus diperbaiki. kelemahan yang sering terjadi dalam penggunaan system rekomendasi adalah kecepatan dan akurasi yang rendah. Untuk mengatasi hal tersebut digunakan algoritma sebagai solusi. Algoritma collaborative Filtering digunakan untuk meningkatkan akurasi sedangkan untuk meningkatkan kecepatan menggunakan algoritma K Nearest Neighbors dan K-Means. Untuk mengetahui peningkatan kecepatan diukur dari kecepatan proses rekomendasi dan untuk mengetahui peningkatan akurasi diukur menggunakan precision, recall dan F1- Score. Setelah Pengukuran diketahui bahwa Collaborative Filtering dan K-Nearest Neighbors dengan Klasifikasi K-Means memiliki akurasi rekomendasi yang lebih tinggi dengan peningkatan Precision dari 0.06 menjadi 0.35, Recall dari 0.06 menjadi 0.36, dan F1-Score dari 0.06 menjadi 0.35. Namun Kecepatannya lebih rendah yaitu 0.0919808 second per proses sedangkan tanpa algoritma 0.002626 second per proses. Penggunaan algoritma Collaborative Filtering, K-Means Clustering, dan K-Nearest Neighbors tidak dapat meningkatkan kecepatan sistem rekomendasi namun dapat meningkatkan akurasinya. Hal ini disebabkan oleh waktu yang dibutuhkan untuk menjalankan algoritma.

Kata kunci : Collaborative Filtering, K-Means, K-Nearest Neighbors (KNN), Sistem Rekomendasi

1. PENDAHULUAN

Sistem rekomendasi beroperasi dengan cara data diolah untuk dijadikan item yang disajikan kepada user. Dengan adanya sistem rekomendasi user dapat memanfaatkannya untuk berbagai hal. Contoh pemanfaatan sistem rekomendasi dalam jurnal penelitian yang peneliti baca antara lain digunakan untuk pemilihan mobil, pemilihan buku dalam perpustakaan, dan pemilihan film.[1] Dalam penelitian lain, sistem rekomendasi juga digunakan untuk memilih destinasi wisata.[2]

Banyak algoritma yang dapat diterapkan dalam sistem rekomendasi, Algoritma Fuzzy dapat digunakan untuk sistem rekomendasi wisata.[3] Algoritma Decision Tree dan Support Vector Machine (SVM) juga dapat untuk membuat Sistem Aplikasi Rekomendasi Objek Wisata.[4] Algoritma K-Nearest Neighbors dapat diterapkan pada sistem rekomendasi hotel. Berdasarkan hasil eksperimen, rata-rata kemiripan sebesar 84.50%.[5] Pengabungan Algoritma K-Nearest Neighbors dan Algoritma Collaborative Filtering pernah dilakukan dan diterapkan pada sistem rekomendasi E- Commerce dalam penelitian sebelumnya.[6]

Dari banyaknya algoritma yang dapat digunakan untuk membuat sistem rekomendasi tentunya ada kekurangan dan kelebihan. Algoritma Collaborative Filtering yang diterapkan pada sistem rekomendasi mempunyai kelemahan yaitu waktu proses yang lama ketika dihadapkan dengan data yang besar.[6] Metode Collaborative Filtering memang memiliki kelemahan dalam hal waktu eksekusi.[7]

Namun dalam penelitian terdahulu metode Collaborative Filtering memiliki akurasi yang tinggi. Hal itu ditunjukkan oleh hasil pengukuran dengan menggunakan MAE, yang menunjukkan bahwa nilai MAE rata-ratanya hanya 0,572039 dan waktu eksekusi yang cukup lama, yaitu 6,4 detik.[8]

untuk sistem rekomendasi ada pada kecepatan dan skalabilitas. Banyaknya item dan data menjadi besar sehingga memakan waktu untuk komputasi. Untuk mengatasi masalah ini dibutuhkan teknik pengelompokan agar data yang diolah dapat dibatasi.[9]

Masalah kecepatan yang ada pada Algoritma Collaborative Filtering jika dibiarkan akan berdampak pada kinerja sistem rekomendasi wisata.[8] Selain itu jika tidak ada solusi perbaikan atau peningkatan sistem akan berdampak pada akurasinya juga.[10] Dampak yang akan terjadi jika ini tidak diatasi untuk rentang waktu yang lama maka sistem rekomendasi tidak akan bisa melakukan rekomendasi lagi.

Untuk mempercepat sistem rekomendasi wisata yang menggunakan Algoritma Collaborative Filtering dilakukan dengan cara mengklasifikasi data pelanggan berdasarkan histori kunjungan wisata. Banyak algoritma dan teknik klasifikasi yang bisa digunakan. Dalam penelitian sebelumnya algoritma K Nearest Neighbor diterapkan pada sistem rekomendasi wisata dan didapatkan hasil tingkat eror 3,8.[11] Optimasi algoritma Collaborative Filtering dapat dilakukan dengan cara digabungkan dengan algoritma klasifikasi seperti K-Nearest Neighbors. Penggabungan algoritma Collaborative Filtering dengan Algoritma K-Nearest

Neighbors dinilai berhasil dengan skor kesamaan rata-rata 84,50% [5]

Dalam penelitian ini, klusterisasi dilakukan dengan memanfaatkan algoritma K-Means. Dibanding algoritma klusterisasi lain K-Means lebih mudah diaplikasikan. Banyak penelitian yang menggunakan K-Means untuk klusterisasi. Karena itu K-Means digunakan dalam penelitian ini.[12]

Klasifikasi menggunakan Algoritma K-Nearest Neighbors dapat meningkatkan sistem rekomendasi wisata. Oleh karena itu algoritma K-Nearest Neighbors dipilih dalam penelitian ini. Peningkatan kecepatan juga mempengaruhi kinerja sistem rekomendasi wisata. Presentase peningkatan kinerja sistem rekomendasi wisata dapat dilihat setelah membandingkan sebelum menggunakan K-Nearest Neighbors dan setelah menggunakannya.

2. TINJAUAN PUSTAKA

2.1. Sistem Rekomendasi

Sistem rekomendasi adalah alat bermanfaat yang memberikan saran yang disesuaikan kepada user untuk item yang mungkin berguna atau menarik bagi mereka. Dalam konteks e-commerce, saran tersebut dapat berupa rekomendasi produk atau jasa.[6] Sistem rekomendasi adalah alat canggih yang memanfaatkan berbagai sumber data dan algoritma untuk mengidentifikasi pola dan memprediksi perilaku user. Dengan menganalisis preferensi user, riwayat pembelian, dan informasi demografis, sistem ini dapat mengantisipasi produk atau layanan apa yang mungkin menarik atau berharga bagi user tertentu. Kemampuan prediktif ini sangat berguna dalam bidang e-commerce, dimana pengecer dapat memanfaatkan sistem rekomendasi untuk mempersonalisasi pengalaman berbelanja, meningkatkan kepuasan pelanggan, dan pada akhirnya mendorong penjualan. Secara keseluruhan, sistem rekomendasi memainkan peran penting dalam ekonomi digital modern, memungkinkan bisnis berinteraksi dengan pelanggan pada tingkat yang lebih personal dan mendorong keterlibatan dan penjualan. Seiring dengan terus berkembangnya teknologi, sistem rekomendasi kemungkinan akan menjadi semakin canggih dan tersebar luas, sehingga membentuk cara kita berinteraksi dengan platform digital dan membuat keputusan pembelian.[11]

2.2. Collaborative Filtering

Collaborative Filtering adalah teknik rekomendasi yang memanfaatkan data rating pengguna untuk menghasilkan rekomendasi item yang kemungkinan besar akan disukai oleh pengguna. Teknik ini bekerja dengan cara mencari kemiripan user berdasarkan data rating yang telah dikumpulkan. Kemiripan user dapat diukur dengan berbagai metode, seperti *cosine similarity*, *Pearson correlation coefficient*, atau *Jaccard index*. Berdasarkan kemiripan user yang telah ditemukan, sistem rekomendasi akan menghasilkan rekomendasi untuk

user yang sedang dituju. Rekomendasi ini dapat berupa daftar item yang telah diberikan rating tinggi oleh user yang mirip dengan user yang sedang dituju.[6]

2.3. K-Nearest Neighbors

KNN atau *K-Nearest Neighbors*, merupakan satu dari banyak algoritma klasifikasi yang paling banyak digunakan dan dikenal karena kesederhanaannya dan kemudahan implementasinya. Ia tergolong dalam kategori algoritma pembelajaran malas (*lazy learning*), yang berarti KNN tidak membangun model eksplisit dari data pelatihan. Sebaliknya, KNN menyimpan semua data pelatihan dan menunda proses klasifikasi hingga data uji baru diterima. Cara kerja KNN didasarkan pada prinsip kedekatan. Ketika sebuah data uji baru masuk, KNN akan mencari K tetangga terdekatnya dalam ruang fitur data pelatihan. Nilai K ditentukan sebelumnya dan mewakili jumlah tetangga yang akan dipertimbangkan. Tetangga ini dipilih berdasarkan jarak mereka ke data uji, dengan jarak yang lebih kecil menunjukkan kedekatan yang lebih besar. Setelah tetangga terdekat ditemukan, KNN akan memprediksi kelas data uji berdasarkan kelas mayoritas di antara tetangga-tetangga tersebut. Dari itu, jika sebagian besar tetangga terdekat termasuk dalam kelas tertentu, maka data uji juga akan diklasifikasikan ke dalam kelas tersebut.[6]

2.4. K Means

Algoritma K-Means adalah salah satu metode klustering yang paling sering digunakan. Metode ini mengelompokkan objek data ke dalam k kelompok, di mana k adalah jumlah kelompok yang telah ditentukan sebelumnya. Algoritma K-Means mengukur kedekatan antar objek data menggunakan jarak Euclidean, dan objek data dengan jarak Euclidean terdekat akan dikelompokkan bersama dalam satu kelompok.[12]

2.5. Sistem

Sistem adalah kumpulan elemen yang saling terhubung dan berinteraksi untuk mencapai tujuan tertentu. Elemen-elemen dalam sistem bisa berupa individu, objek, atau proses. Sistem memiliki karakteristik tertentu, yaitu sasaran, batas, lingkungan, komponen, *interface*, dan input-proses-output. Sistem dapat dikelompokkan berdasarkan sifatnya, tujuannya, atau tingkat kompleksitasnya. Sistem memiliki peran penting dalam kehidupan manusia, seperti mengelola organisasi, menghasilkan produk, memberikan layanan, dan meningkatkan kesejahteraan Masyarakat.[13].

2.6. Pariwisata

Pariwisata adalah sektor yang sangat penting dalam perekonomian sebuah negara, termasuk Indonesia. Sektor ini dapat memberikan kontribusi signifikan terhadap pertumbuhan ekonomi, menciptakan lapangan kerja, dan meningkatkan pendapatan masyarakat. Indonesia memiliki potensi

pariwisata yang sangat besar, dengan berbagai destinasi menarik mulai dari wisata budaya, wisata minat khusus, hingga wisata alam[2]

3. METODE PENELITIAN

Metode penelitian kuantitatif diterapkan dalam penelitian ini untuk mengumpulkan dan menganalisis data berupa angka, dengan tujuan untuk menghasilkan informasi ilmiah. Data yang digunakan didapat dari google maps dan data register user. Data pariwisata berupa daftar lokasi wisata yang terdaftar dalam google maps. Dan data register user berupa data username, email, password dan rekomendasi. Dari data tersebut diterapkan Collaborative Filtering untuk mencari kesamaan preferensi antara user sehingga dapat diterapkan dalam sistem rekomendasi wisata. Kemudian sistem rekomendasi wisata dapat dihitung kecepatannya dari saat hanya menggunakan Algoritma Collaborative Filtering normal sampai diterapkannya Algoritma K-Nearest Neighbors dengan klasifikasi K-Means. Dari hasil perhitungan dapat dianalisis dan dibandingkan untuk mengetahui gap diantaranya. Gap dapat menunjukkan apakah ada peningkatan atau penurunan ketika sebelum diterapkan Algoritma K Nearest Neighbor dengan klasifikasi K-Means dan ketika sudah diterapkan Algoritma K Nearest Neighbor dengan klasifikasi K-Means pada sistem rekomendasi wisata. Peningkatan kinerja bisa dilihat dari meningkatnya kecepatan dan akurasi sistem rekomendasi wisata.

3.1. Prosedur Penelitian



Gambar 1. Prosedur penelitian

Dalam prosedur penelitian ini memuat langkah-langkah yang akan dilakukan dalam penelitian secara terencana dan teratur untuk mencapai tujuan penelitian. Langkah-langkah tersebut bertujuan untuk memecahkan permasalahan penelitian dan menghasilkan hasil yang berkualitas. Prosedur disusun secara jelas agar alur tahapan penelitian yang dilakukan selaras dengan tujuan penelitian. Alur tahapan penelitian meliputi pengumpulan data, *Collaborative Filtering*, *Collaborative Filtering* dengan Penerapan Algoritma *K-Nearest Neighbors* dengan klasifikasi *K-Means*, dan analisis. Untuk lebih rinci dan jelas Alur tahapan penelitian disajikan dalam gambar 1.

3.2. Pengumpulan Data


Ini adalah tahap pengumpulan data yang diperlukan dalam penelitian, yaitu data pengguna dan data pariwisata. Data user meliputi variable username, email, password dan rekomendasi. Data pariwisata meliputi variable nama pariwisata dan jenis pariwisata. Periode pengumpulan data user dalam 30 hari dengan Batasan minimal 50 item setiap variable data. Data user didapatkan dari register user dan data dummy untuk tambahan jika kurang dari 50 user. Data pariwisata dikumpulkan dengan teknik scrapping yang bersumber dari google maps. Setelah data yang dibutuhkan sudah terkumpul dapat dilakukan pengujian pada sistem rekomendasi wisata. Jenis pariwisata dibagi menjadi lima sesuai gambar dibawah:



Gambar 2. Jenis wisata


3.3. Implementasi

Sistem rekomendasi wisata dalam penelitian ini menggunakan Algoritma *Collaborative Filtering*. Model *Collaborative Filtering* yang diterapkan adalah *User-Based Collaborative Filtering*. *User-Based Collaborative Filtering* bekerja dengan cara membandingkan dan memfilter user berdasarkan preferensi yang sama. Untuk lebih memahami analogi dan memperjelas, kita bisa melihat gambar dibawah ini:




Gambar 3. Mekanisme collaborative filtering

Kebutuhan teknik pengelompokan data dalam aplikasi rekomendasi wisata didasari oleh semakin banyaknya user yang menyebabkan pertambahan data. Dalam hal ini dipakai *K-Nearest Neighbors* untuk melakukan klasifikasi dan *K-Means* untuk klasterisasi.



Gambar 4. Jenis wisata

Algoritma *K Nearest Neighbor* mengklasifikasi data histori kunjungan. Mekanismenya dengan memilih Nilai k tetangga terdekat sesuai dengan kebutuhan. Dalam penelitian ini digunakan $k = 5$, maka algoritma *K Nearest Neighbor* akan memilih 5 tetangga terdekat dari data histori kunjungan dan dikelompokkan menurut jenis wisata. Misalnya 3 dari 5 tetangga terdedat histori kunjungan user adalah wisata alam maka sistem akan menyimpulkan bahwa user menyukai wisata alam.



Gambar 5. Mekanisme k nearest neighbors

Algoritma *K-Means* mengklasterisasi data user berdasarkan histori kunjungan. Mekanismenya adalah dengan memilih K sebagai pusat data dan mengelompokkannya sesuai pusat data tersebut. Misalnya dalam data ada 5 kali kemunculan wisata alam, 2 kali kemunculan wisata belanja dan 4 kali kemunculan wisata Sejarah maka algoritma *K-Means* akan mengelompokkannya menjadi wisata alam 1, wisata belanja 1, wisata sejarah 1.



Gambar 6. Mekanisme k means

3.4. Analisis

Setelah menyelesaikan semua tahapan, tahap analisis dapat dilakukan. Untuk analisis kecepatan, peneliti mengukur kecepatan sistem rekomendasi wisata yang menggunakan Algoritma Collaborative Filtering, serta sistem rekomendasi yang menggabungkan Algoritma Collaborative Filtering dengan Algoritma *K-Nearest Neighbors* dan klasifikasi *K-Means*. Kemudian dilakukan perbandingan antara data kecepatan yang telah diukur. Peningkatan akan diketahui setelah data kecepatan dibandingkan.

3.5. Pengukuran Kecepatan

Kecepatan sistem rekomendasi diukur berdasarkan waktu yang diperlukan untuk menghasilkan rekomendasi. Pengukuran ini dilakukan dengan menghitung waktu pemrosesan dari saat permintaan rekomendasi diterima hingga rekomendasi diberikan kepada pengguna. Waktu ini biasanya diukur dalam milidetik (ms).

- Total Processing Time:** Waktu total yang dihabiskan oleh sistem untuk menghasilkan rekomendasi. Ini mencakup waktu pemrosesan data, penerapan algoritma, dan penyajian hasil.
- Average Response Time:** Rata-rata waktu yang diperlukan oleh sistem untuk memberikan rekomendasi kepada pengguna. Ini dihitung dengan mengukur waktu pemrosesan untuk beberapa permintaan rekomendasi dan menghitung rata-rata dari waktu-waktu tersebut.

3.6. Pengukuran akurasi

Untuk mengukur akurasi sistem rekomendasi, digunakan beberapa metrik, yaitu precision, recall, dan F1-score. Metrik-metrik ini membantu memberikan gambaran yang lebih lengkap tentang performa sistem.

a. Precision (Presisi): Precision mengukur persentase item yang direkomendasikan oleh sistem yang benar-benar diminati oleh pengguna. Precision dihitung sebagai jumlah True Positives (TP) dibagi dengan jumlah True Positives dan False Positives (FP).

Rumus:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad \text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

di mana:

- **TP (True Positive):** Jumlah item yang direkomendasikan dan diminati oleh pengguna.
- **FP (False Positive):** Jumlah item yang direkomendasikan tetapi tidak diminati oleh pengguna.

b. Recall: Recall mengukur seberapa baik sistem menangkap semua item yang relevan. Recall dihitung sebagai jumlah True Positives (TP) dibagi dengan jumlah True Positives dan False Negatives (FN).

Rumus:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad \text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

di mana:

- **FN (False Negative):** Jumlah item yang diminati oleh pengguna tetapi tidak direkomendasikan oleh sistem.

c. F1-Score: F1-Score adalah harmonic mean dari precision dan recall, memberikan keseimbangan antara keduanya.

Rumus:

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad \text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Definisi TP, TN, FP, dan FN:

- **True Positive (TP):** Item yang direkomendasikan oleh sistem dan benar-benar diminati oleh pengguna.
- **True Negative (TN):** Item yang tidak direkomendasikan oleh sistem dan memang tidak diminati oleh pengguna.
- **False Positive (FP):** Item yang direkomendasikan oleh sistem tetapi tidak diminati oleh pengguna.
- **False Negative (FN):** Item yang diminati oleh pengguna tetapi tidak direkomendasikan oleh sistem.

Dengan demikian, precision mengukur ketepatan rekomendasi yang diberikan, recall mengukur seberapa baik sistem menangkap semua item yang relevan, dan F1-score memberikan gambaran keseimbangan antara precision dan recall.

4. HASIL DAN PEMBAHASAN

hasil pengujian kinerja sistem rekomendasi wisata dengan menerapkan dua pendekatan berbeda: menggunakan algoritma Collaborative Filtering, K-Means Clustering, dan K-Nearest Neighbors, serta tanpa menggunakan algoritma tersebut. Pengukuran kinerja dilakukan dengan mempertimbangkan dua aspek utama, yaitu kecepatan proses dan akurasi sistem rekomendasi. Akurasi diukur menggunakan metrik-metrik yang telah diakui dalam bidang ini, yakni Precision, Recall, dan F1-Score. Sedangkan untuk kecepatan diukur dari kecepatan proses eksekusi program dengan menggunakan *library time* dari python. Hasil dari pengujian ini akan memberikan wawasan mendalam mengenai efektivitas dan efisiensi kedua pendekatan dalam konteks rekomendasi wisata, serta memberikan landasan bagi pengembangan lebih lanjut dalam penelitian ini.

4.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini terdiri dari dua komponen utama, yaitu matriks user-item dan profil pengguna.

- Matriks User-Item:** Matriks ini berisi informasi tentang interaksi pengguna dengan berbagai objek wisata. Setiap baris mewakili seorang pengguna, dan setiap kolom mewakili sebuah objek wisata. Nilai dalam matriks ini menunjukkan tingkat ketertarikan atau rating yang diberikan oleh pengguna untuk objek wisata tersebut.
- Profil Pengguna:** Profil pengguna berisi informasi tentang karakteristik atau preferensi pengguna yang digunakan untuk personalisasi rekomendasi.

4.2. Sistem Rekomendasi Tanpa Algoritma

Pada sistem rekomendasi sebelum menggunakan algoritma, rekomendasi diberikan berdasarkan rating tertinggi dari objek wisata. Sistem ini hanya mempertimbangkan rating secara langsung tanpa analisis lebih lanjut mengenai preferensi pengguna atau kesamaan antar objek wisata.

Langkah-langkah implementasi:

- Mengambil Data Objek Wisata:** Data objek wisata yang telah dikumpulkan digunakan sebagai basis rekomendasi.
- Mengurutkan Berdasarkan Rating:** Objek wisata diurutkan berdasarkan rating tertinggi.
- Memberikan Rekomendasi:** Sistem memberikan rekomendasi objek wisata dengan rating tertinggi kepada pengguna.

Setelah dilakukan pengujian menggunakan python, hasil pengukuran pertama sistem rekomendasi tanpa algoritma adalah sebagai berikut:

```
Total processing time (without algorithms): 0.003000 seconds
Precision (without algorithms): 0.06
Recall (without algorithms): 0.06
F1-Score (without algorithms): 0.06
```

Gambar 7. Tangkapan layar hasil pengukuran pertama sistem rekomendasi tanpa algoritma

Hasil yang didapat yaitu:

a. Kecepatan:

Kecepatan didapat dari *processing time* dibagi dengan banyaknya proses.

$$\frac{\text{Total processing time}}{\text{Banyaknya Proses}} = \text{Hasil Kecepatan}$$

Dengan demikian hasilnya adalah sebagai berikut:

$$\begin{aligned} \frac{\text{Total processing time}}{\text{Banyaknya Proses}} &= \frac{0.003000}{1} \\ &= 0.003000 \text{ Second} \end{aligned}$$

b. Akurasi:

Akurasi diukur dengan metrik Precision, Recal dan F1- Score. Hasil pengukuran langsung bisa didapatkan karena menggunakan library dari python yaitu ScikitLearn. Berikut adalah Hasilnya:

Precision : 0.6
Recal : 0.6
F-1 Score : 0.6

Untuk memastikan keakuratannya pengujian dilakukan 5 kali percobaan dengan catatan hasil sebagai berikut:

4.3. Hasil Kecepatan (Total Processing time)

Hasil kecepatan didapat dari *processing time* dibagi dengan banyaknya proses.

Tabel 1. Hasil pengujian kecepatan sistem rekomendasi tanpa algoritma

Pengujian	Hasil Kecepatan
Pengujian Pertama	0.003000 second
Pengujian Kedua	0.003467 second
Pengujian ketiga	0.001331 second
Pengujian Keempat	0.003336 second
Pengujian Kelima	0.001997 second

Dari hasil yang didapat bisa dihitung rata – rata kecepatannya, Hasilnya adalah:

$$\begin{aligned} \Sigma \text{ Hasil Kecepatan} &= 0.003000+0.003467+0.001331+0.003336+0.001997 \\ \text{Pengujian} &= 5 \\ \text{Hasil} &= 0.0026262 \end{aligned}$$

Dengan demikian rata – rata kecepatan sistem rekomendasi tanpa menggunakan algoritma adalah 0.0026262 Second per proses.

4.4. Hasil Akurasi

Hasil akurasi yang didapatkan dengan data yang sama konsisten yaitu:

Precision : 0.6
Recal : 0.6
F-1 Score : 0.6

Dengan demikian bisa disimpulkan bahwa sistem rekomendasi yang tidak menggunakan algoritma memiliki kecepatan proses yang tinggi yaitu 0.0026262 Second per proses. Namun rendahnya precision menunjukkan bahwa banyak item yang direkomendasikan oleh sistem ternyata tidak diminati oleh pengguna (banyak FP). Rendahnya recall menunjukkan bahwa banyak item yang diminati oleh pengguna tidak berhasil direkomendasikan oleh sistem (banyak FN). Hasil tangkapan layar pengukuran di lampiran.

4.5. Sistem Rekomendasi Dengan Algoritma

Sistem rekomendasi ini menggunakan kombinasi algoritma Collaborative Filtering, K-Means Clustering, dan K-Nearest Neighbors untuk memberikan rekomendasi yang lebih personalisasi dan akurat. Berikut langkah-langkah implementasinya:

- Collaborative Filtering:** Menghitung matriks kesamaan pengguna.
- K-Means Clustering:** Mengelompokkan pengguna berdasarkan profil mereka.
- K-Nearest Neighbors Classification:**

Mengklasifikasikan pengguna untuk rekomendasi. Setelah dilakukan pengujian menggunakan python, hasil pengukuran pertama sistem rekomendasi adalah sebagai berikut:

```
Total processing time: 0.096339 seconds
Precision (With Algorithm): 0.35
Recall (With Algorithm): 0.36
F1-Score (With Algorithm): 0.35
```

Gambar 8. Tangkapan layar hasil pengukuran pertama sistem rekomendasi tanpa algoritma

Dari hasil tersebut didapatkan yaitu:

a. Kecepatan:

Kecepatan didapat dari *processing time* dibagi dengan banyaknya proses.

$$\frac{\text{Total processing time}}{\text{Banyaknya Proses}} = \text{Hasil Kecepatan}$$

Dengan demikian hasilnya adalah sebagai berikut:

$$\begin{aligned} \frac{\text{Total processing time}}{\text{Banyaknya Proses}} &= \frac{0.096339}{1} \\ &= 0.096339 \text{ Second} \end{aligned}$$

b. Akurasi:

Akurasi diukur dengan metrik Precision, Recal dan F1- Score. Hasil pengukuran langsung bisa didapatkan karena menggunakan library dari python yaitu ScikitLearn. Berikut adalah Hasilnya:
Precision : 0.35
Recal : 0.36
F-1 Score : 0.35

Untuk memastikan keakuratannya pengujian dilakukan 5 kali percobaan dengan catatan hasil sebagai berikut:

a. Hasil Kecepatan (Total Processing time)

Hasil kecepatan didapat dari *processing time* dibagi dengan banyaknya proses.

Tabel 2. Hasil pengujian kecepatan sistem rekomendasi dengan algoritma

Pengujian	Hasil Kecepatan
Pengujian Pertama	0.096339 second
Pengujian Kedua	0.095111 second
Pengujian Ketiga	0.084310 second
Pengujian Keempat	0.091485 second
Pengujian Kelima	0.092659 second

Dari hasil yang didapat bisa dihitung rata – rata kekepatannya, Hasilnya adalah:

$$\Sigma \text{ Hasil Kecepatan} = \frac{0.096339 + 0.095111 + 0.084310 + 0.091485 + 0.092659}{5} =$$

$$\text{Pengujian} = 5$$

$$\text{Hasil} = 0.0919808$$

Dengan demikian rata – rata kecepatan sistem rekomendasi tanpa menggunakan algoritma adalah 0.0919808 Second per proses.

b. Hasil Akurasi

Hasil akurasi yang didapatkan dengan data yang sama konsisten yaitu:

$$\text{Precision} : 0.35$$

$$\text{Recal} : 0.36$$

$$\text{F-1 Score} : 0.35$$

Dengan demikian bisa disimpulkan bahwa sistem rekomendasi yang tidak menggunakan algoritma memiliki kecepatan proses yang lebih rendah yaitu 0.0919808 Second per proses. Precision yang lebih tinggi menunjukkan bahwa lebih banyak item yang direkomendasikan oleh sistem memang diminati oleh pengguna (lebih sedikit FP). Recall yang lebih tinggi menunjukkan bahwa sistem berhasil merekomendasikan lebih banyak item yang diminati oleh pengguna (lebih sedikit FN).

4.6. Analisis Perbandingan sistem rekomendasi

Pengujian kecepatan mendapatkan hasil yang disajikan dalam tabel sebagai berikut:

Tabel 3. Perbandingan hasil kecepatan sistem rekomendasi

Pengujian	Tanpa Algoritma	Dengan Algoritma
Pertama	0.003000 second	0.096339 second
Kedua	0.003467 second	0.095111 second
Ketiga	0.001331 second	0.084310 second
Keempat	0.003336 second	0.091485 second
kelima	0.001997 second	0.092659 second


Dari hasil pengujian, sistem rekomendasi tanpa menggunakan algoritma memiliki rata-rata kecepatan proses yang lebih tinggi yaitu 0.002626 second per proses dibandingkan dengan menggunakan algoritma

yaitu 0.0919808 second per proses. Perbedaan ini disebabkan oleh waktu yang dibutuhkan untuk menjalankan algoritma Collaborative Filtering, K-Means Clustering, dan K-Nearest Neighbors.



Gambar 9. Grafik perbandingan kecepatan sistem rekomendasi

Sistem rekomendasi dengan menggunakan algoritma menunjukkan peningkatan yang signifikan dalam hal akurasi. Precision meningkat dari 0.06 menjadi 0.35, Recall meningkat dari 0.06 menjadi 0.36, dan F1-Score meningkat dari 0.06 menjadi 0.35. Hal ini menunjukkan bahwa penggunaan algoritma Collaborative Filtering, K-Means Clustering, dan K-Nearest Neighbors mampu menghasilkan rekomendasi yang lebih relevan bagi pengguna.



Gambar 10. Grafik perbandingan akurasi

5. KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian dan analisis yang telah dilakukan, dapat disimpulkan bahwa: Algoritma Collaborative Filtering dengan algoritma K-Nearest Neighbors klasterisasi K-Means tidak dapat meningkatkan kecepatan sistem rekomendasi wisata namun dapat meningkatkan akurasinya. Penggunaan algoritma Collaborative Filtering, K-Means Clustering, dan K-Nearest Neighbors mampu meningkatkan akurasi sistem rekomendasi secara signifikan dengan peningkatan Precision dari 0.06 menjadi 0.35, Recall dari 0.06 menjadi 0.36, dan F1-

Score dari 0.06 menjadi 0.35. Sistem rekomendasi wisata tanpa menggunakan algoritma Collaborative Filtering, K-Means Clustering, dan K-Nearest Neighbors memiliki kecepatan yang lebih tinggi namun akurasi yang sangat rendah. Terdapat trade-off antara kecepatan dan akurasi di mana penggunaan algoritma meningkatkan akurasi namun menurunkan kecepatan proses. Untuk penelitian selanjutnya, disarankan: Mengoptimalkan algoritma yang digunakan untuk meningkatkan kecepatan proses tanpa mengorbankan akurasi. Menggunakan dataset yang lebih besar dan beragam untuk menguji kinerja sistem rekomendasi dalam skala yang lebih besar. Menerapkan teknik-teknik lain seperti matrix factorization atau deep learning untuk meningkatkan kinerja sistem rekomendasi.

DAFTAR PUSTAKA

- [1] N. Indah Putri *et al.*, “Sistem Rekomendasi Hibrid Pemilihan Mobil Berdasarkan Profil Pengguna Dan Profil Barang,” *TEMATIK*, vol. 8, no. 1, pp. 56–68, 2021, Accessed: Feb. 03, 2024. [Online]. Available: <https://doi.org/10.38204/tematik.v8i1.566>
- [2] R. Oktavika, “Sistem Rekomendasi Wisata Dengan Menggunakan Algoritma Collaborative Filtering,” *Jurnal Teknologi Pintar*, vol. 3, no. 1, 2023.
- [3] E. Sugiharto, I. -, and I. D. Wijaya, “Sistem Rekomendasi Tempat Wisata di Malang Raya Dengan Metode Fuzzy Berbasis Web,” *JURNAL APLIKASI DAN INOVASI IPTEKS “SOLIDITAS” (J-SOLID)*, vol. 4, no. 1, p. 8, Feb. 2021, doi: 10.31328/js.v4i1.1731.
- [4] R. Oktafiani and R. Rianto, “Perbandingan Algoritma Support Vector Machine (SVM) dan Decision Tree untuk Sistem Rekomendasi Tempat Wisata,” *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 9, no. 2, pp. 113–121, Aug. 2023, doi: 10.25077/teknosi.v9i2.2023.113-121.
- [5] A. Muliawan, T. Badriyah, and I. Syarif, “Membangun Sistem Rekomendasi Hotel dengan Content Based Filtering Menggunakan K-Nearest Neighbor dan Haversine Formula,” *Technomedia Journal*, vol. 7, no. 2, pp. 231–247, Sep. 2022, doi: 10.33050/tmj.v7i2.1893.
- [6] D. Aisha and R. Kusumawati, “Implementasi Metode Algoritma Collaborative Filtering Dan K-Nearest Neighbor Pada Sistem Rekomendasi E-Commerce,” *JUISIK*, vol. 2, no. 3, 2022.
- [7] Romindo, Jefri Junifer Pangaribuan, Okky Putra Barus, and Jusin, “Penerapan Metode Collaborative Filtering Dan Knowledge Item Based Terhadap Sistem Rekomendasi Kamera DSLR,” *SATIN - Sains dan Teknologi Informasi*, vol. 8, no. 2, pp. 89–100, Dec. 2022, doi: 10.33372/stn.v8i2.883.
- [8] B. Prasetyo, H. Haryanto, S. Astuti, E. Z. Astuti, and Y. Rahayu, “Implementasi Metode Item-Based Collaborative Filtering dalam Pemberian Rekomendasi Calon Pembeli Aksesoris Smartphone,” *Eksplora Informatika*, vol. 9, no. 1, pp. 17–27, Sep. 2019, doi: 10.30864/eksplora.v9i1.244.
- [9] Z. Munawar *et al.*, “Sistem Rekomendasi Hibrid Menggunakan Algoritma Apriori Mining Asosiasi,” *TEMATIK*, vol. 8, no. 1, pp. 84–95, 2021, Accessed: Feb. 03, 2024. [Online]. Available: <https://doi.org/10.38204/tematik.v8i1.567>
- [10] R. Bunga, F. Batista, and R. Ribeiro, “From Implicit Preferences to Ratings: Video Games Recommendation based on Collaborative Filtering,” *SCITEPRESS – Science and Technology Publications, Lda.*, vol. Volume 01C3K, pp. 209–216, 2021, Accessed: Feb. 03, 2024. [Online]. Available: <https://dx.doi.org/10.5220/0010655900003064>
- [11] M. Islamiyah, P. Subekti, T. Dwi Andini, and S. Asia Malang, “Pemanfaatan Metode Item Based Collaborative Filtering Untuk Rekomendasi Wisata Di Kabupaten Malang,” *Jurnal Ilmiah Teknologi Informasi Asia*, vol. 13, no. 2, 2019.
- [12] E. Mayoana Fitri, R. Randy Suryono, and A. Wantoro, “Klasterisasi Data Penjualan Berdasarkan Wilayah Menggunakan Metode K-Means Pada Pt XYZ,” *Jurnal Komputasi*, vol. 11, no. 2, 2023, Accessed: Feb. 03, 2024. [Online]. Available: <http://dx.doi.org/10.23960%2Fkomputasi.v11i2.12582>
- [13] N. ' Mah, K. Ayyiyah, R. Kusumaningrum, and R. Rismiyati, “Film Recommender System Menggunakan Metode Neural Collaborative Filtering Film Recommender System Using Neural Collaborative Filtering Method,” *Jurnal Teknologi Informasi Dan Ilmu Komputer*, vol. 10, no. 3, pp. 699–708, 2023, doi: 10.25126/jtiik.2023106616