

Implementasi Content-Based Filtering dan Cosine Similarity untuk Rekomendasi Kafe Berdasarkan Konsep Ruang di Yogyakarta

Muhammad Niswandi¹, Titik Rahmawati¹, Agung Priyanto¹

¹Program Studi Informatika, Fakultas Teknik, Universitas Sarjanawiyata Tamansiswa, Yogyakarta, Indonesia

Email: 2022018007@ustjogja.ac.id, titik.rahmawati@ustjogja.ac.id, agungprie@ustjogja.ac.id

INFORMASI ARTIKEL

Histori artikel:

Naskah masuk, 15 Juni 2026

Direvisi, 22 Juli 2026

Diiterima, 31 Juli 2026

ABSTRAK

Abstract- The rapid growth of cafés in Yogyakarta provides many alternatives for studying, working, meetings, and socializing, but information on indoor and outdoor space concepts and supporting facilities remains scattered across online maps, social media, and unstructured reviews. This study developed a web-based café recommendation system using Content-Based Filtering and Cosine Similarity to match user preferences with café attributes. The study followed sequential stages of problem identification, literature review, data collection, attribute validation, system design, implementation, and testing. Field observations, Google Maps, and social media produced a validated dataset of 50 cafés distributed across 14 districts, 20 binary facility attributes, and 218 café-facility relationships. User preferences and café profiles were represented as 20-dimensional binary vectors, and recommendation scores were ranked by cosine similarity. Evaluation included manual verification of the algorithm, black-box testing, Playwright automation, and descriptive analysis of three attribute scenarios. All three automated tests passed in 16.8 seconds. Mean similarity values were 0.3682 for indoor, 0.2379 for outdoor, and 0.4286 for combined attributes. The combined scenario also produced no zero-similarity score among the 50 cafés, which practically gives users a broader candidate pool while preserving rank differentiation. These values represent mathematical profile fit rather than perceived user relevance because respondent relevance labels were not available. The system can process newly registered cafés without historical ratings.

Kata Kunci:

Rekomendasi kafe; content-based filtering; cosine similarity; indoor; outdoor; aplikasi web.

Abstrak- Pertumbuhan kafe di Kota Yogyakarta menyediakan banyak alternatif tempat untuk belajar, bekerja, rapat, dan bersosialisasi, tetapi informasi tentang konsep ruang indoor, outdoor, dan fasilitas pendukung masih tersebar pada peta daring, media sosial, serta ulasan yang tidak terstruktur. Penelitian ini mengembangkan sistem rekomendasi kafe berbasis web menggunakan Content-Based Filtering dan Cosine Similarity untuk mencocokkan preferensi pengguna dengan atribut kafe. Penelitian dilaksanakan melalui tahap identifikasi masalah, studi literatur, pengumpulan data, validasi atribut, perancangan sistem, implementasi, dan pengujian. Observasi lapangan, Google Maps, dan media sosial menghasilkan dataset tervalidasi yang terdiri atas 50 kafe pada 14 kemantren, 20 atribut fasilitas biner, dan 218 relasi kafe-fasilitas. Preferensi pengguna dan profil kafe direpresentasikan sebagai vektor biner berdimensi 20, kemudian skor rekomendasi diurutkan berdasarkan Cosine Similarity. Evaluasi mencakup verifikasi manual algoritma, pengujian black-box, otomatisasi Playwright, dan analisis deskriptif pada tiga skenario atribut. Seluruh tiga pengujian otomatis berhasil dalam 16,8 detik. Rata-rata similarity mencapai 0,3682 untuk indoor, 0,2379 untuk outdoor, dan 0,4286 untuk gabungan. Skenario gabungan juga tidak menghasilkan skor nol pada 50 kafe, sehingga secara praktis pengguna memperoleh cakupan kandidat yang lebih luas dengan urutan rekomendasi yang tetap berbeda. Nilai tersebut menunjukkan kecocokan matematis profil, bukan relevansi yang dirasakan pengguna, karena label relevansi dari responden belum tersedia. Sistem dapat memproses kafe baru tanpa riwayat penilaian.

Copyright © 2026 LPPM - STMIK IKMI Cirebon
This is an open access article under the CC-BY license

Penulis Korespondensi:

Nama Penulis Korespondensi

Muhammad Niswandi

Program Studi Informatika, Fakultas Teknik, Universitas Sarjanawiyata Tamansiswa, Yogyakarta
Indonesia

1. Pendahuluan

Industri kafe di Kota Yogyakarta berkembang seiring dengan karakteristik kota sebagai pusat pendidikan, pariwisata, kebudayaan, dan ekonomi kreatif. Keberadaan mahasiswa, pekerja lepas, wisatawan, komunitas, dan pelaku usaha menciptakan permintaan terhadap ruang publik yang tidak hanya menyediakan makanan dan minuman, tetapi juga mendukung aktivitas produktif. Kafe telah berkembang menjadi ruang ketiga yang digunakan untuk mengerjakan tugas, bekerja secara daring, menyelenggarakan diskusi, melakukan pertemuan, dan membangun interaksi sosial.

Perkembangan tersebut menghasilkan pilihan kafe dengan karakteristik yang semakin beragam. Sebagian kafe menyediakan ruangan indoor berpendingin udara dengan meja kerja dan stopkontak. Sebagian lainnya menonjolkan area outdoor, taman, rooftop, area merokok, atau suasana terbuka. Terdapat pula kafe yang menggabungkan area indoor dan outdoor serta menyediakan fasilitas tambahan seperti Wi-Fi, ruang pertemuan, sofa, rak buku, konsep vintage, specialty coffee, dan operasional 24 jam.

Banyaknya pilihan belum sepenuhnya diikuti oleh ketersediaan informasi terstruktur. Informasi pada Google Maps dan media sosial cenderung berfokus pada lokasi, foto, rating, menu, dan ulasan umum. Pengguna masih harus membaca banyak ulasan atau mengunjungi akun media sosial masing-masing kafe untuk mengetahui apakah suatu tempat menyediakan AC, meja kerja, stopkontak, rooftop, area merokok, atau ruang pertemuan. Proses pencarian tersebut memerlukan waktu dan tidak selalu menghasilkan keputusan yang sesuai dengan kebutuhan pengguna.

Sistem rekomendasi mengurangi kompleksitas pilihan dengan menyaring alternatif berdasarkan profil atau preferensi pengguna. *Content-Based Filtering* (CBF) sesuai untuk data atribut kafe karena membandingkan fitur item dengan profil pengguna dan dapat menjelaskan atribut yang mendasari suatu rekomendasi [1], [2]. Berbeda dengan *Collaborative Filtering*, CBF tidak bergantung pada rating atau riwayat interaksi pengguna lain. Kafe baru dapat langsung diproses setelah atributnya dimasukkan ke basis data sehingga masalah *item cold-start* dapat dikurangi.

Penelitian terdahulu pada objek kafe menggunakan pendekatan, dataset, dan evaluasi yang berbeda. Refkrisnatta dan Handayani

menerapkan *Item-Based Collaborative Filtering* di Semarang dengan data perilaku pengguna [3]. Putra, Susanto, dan Lestari menggunakan CBF dan *Cosine Similarity* pada tujuh atribut fasilitas kafe di Solo dan melaporkan nilai similarity tertinggi 0,9977 [4]. Putro dkk. menerapkan *Item-Based Collaborative Filtering* pada kategori fasilitas kedai kopi di Surakarta dan melaporkan akurasi confusion matrix sebesar 85,7% [5]. Apsiswanto dan Pamungkas menggunakan *Weighted Product* berbasis bobot kriteria [6], sedangkan Irfan dkk. menggunakan TOPSIS dan data spasial untuk pemilihan lokasi usaha kafe [7]. Afoudi dkk. menggabungkan CBF dan *Collaborative Filtering* berbasis jaringan saraf pada dataset MovieLens untuk meningkatkan precision dan akurasi [8].

Perbandingan tersebut menunjukkan bahwa nilai hasil penelitian sebelumnya tidak dapat dibandingkan secara langsung karena objek, jumlah atribut, sumber data, definisi relevansi, dan metrik evaluasinya berbeda. Nilai similarity maksimum pada penelitian CBF hanya menunjukkan kedekatan dua vektor, sedangkan akurasi pada penelitian *Collaborative Filtering* bergantung pada label dan rancangan pengujian. Dalam literatur yang ditelaah, belum terdapat penelitian yang secara bersamaan memusatkan rekomendasi pada konsep ruang indoor dan outdoor di Kota Yogyakarta, menggunakan 20 atribut biner yang dapat diamati, memvalidasi atribut melalui observasi lapangan, mencakup seluruh 14 kemantren, dan membandingkan distribusi skor pada skenario indoor, outdoor, serta gabungan. Fokus atribut ruang didukung temuan servicescape yang membedakan faktor kenyamanan indoor dan outdoor serta pengaruh tatanan ruang terhadap aktivitas pengunjung [9], [10].


Berdasarkan kesenjangan tersebut, penelitian ini bertujuan mengembangkan sistem rekomendasi kafe berbasis web menggunakan CBF dan *Cosine Similarity*. Kontribusi penelitian mencakup dataset 50 kafe dari seluruh kemantren di Kota Yogyakarta, representasi 20 atribut fasilitas dalam vektor biner, pengecekan silang antara sumber daring dan observasi, transparansi detail perhitungan, serta analisis komparatif skenario indoor, outdoor, dan gabungan. Hipotesis penelitian menyatakan bahwa kombinasi atribut yang lebih lengkap meningkatkan cakupan kecocokan dan rata-rata similarity, tetapi tidak selalu menghasilkan nilai maksimum individual yang lebih tinggi.

2. Metode Penelitian

2.1 Tahapan penelitian

Penelitian menggunakan alur pengembangan sekuensial yang mengadaptasi model Waterfall. Pendekatan ini dipilih karena kebutuhan utama, atribut rekomendasi, proses komputasi, dan

luaran sistem telah didefinisikan sejak tahap awal [11], [12]. Tahapan penelitian terdiri atas identifikasi masalah dan studi literatur, pengumpulan data, validasi atribut, analisis kebutuhan, perancangan sistem, implementasi CBF, pengujian, perbandingan skenario, dan penarikan kesimpulan.



Gambar 1. Tahapan penelitian sistem rekomendasi kafe

Pada tahap identifikasi masalah dilakukan analisis terhadap kesulitan pengguna dalam menemukan kafe berdasarkan konsep ruang dan fasilitas. Studi literatur digunakan untuk mengkaji sistem rekomendasi, CBF, *Cosine Similarity*, kenyamanan ruang kafe, metode Waterfall, serta teknik evaluasi perangkat lunak dan sistem rekomendasi.

2.2 Pengumpulan dan validasi data

Data dikumpulkan melalui tiga sumber. Observasi lapangan digunakan untuk memeriksa fasilitas secara langsung. Google Maps digunakan untuk melengkapi nama, alamat, rating, jam operasional, dan tautan lokasi. Instagram dan TikTok digunakan sebagai sumber visual tambahan untuk memeriksa konsep ruang dan fasilitas. Setiap atribut dicatat dalam format biner agar dapat dibandingkan secara konsisten.

Teknik pengambilan sampel menggunakan *purposive sampling* dengan dua kriteria, yaitu

objek berfungsi sebagai kafe produktif untuk minum kopi, belajar, bekerja, rapat, atau bersantai, serta memiliki informasi fasilitas yang dapat diverifikasi. Sebanyak 50 kafe dipilih dengan cakupan seluruh 14 kemantren di Kota Yogyakarta. Setiap kemantren diwakili 3 sampai 6 kafe. Cakupan ini memberikan representasi geografis dan variasi konsep ruang, tetapi tidak dimaksudkan sebagai sampel probabilistik untuk mengestimasi seluruh populasi kafe.

Data awal divalidasi melalui pengecekan silang antara kondisi lapangan dan sumber daring karena foto, ulasan, jam operasional, serta daftar fasilitas dapat tidak sesuai dengan kondisi aktual. Dataset akhir terdiri atas 50 kafe, 20 atribut, dan 218 relasi kafe-fasilitas, dengan rata-rata 4,36 atribut per kafe. Ukuran dataset dipilih agar seluruh wilayah kota dan keragaman konsep ruang dapat tercakup sekaligus memungkinkan pemeriksaan atribut secara langsung pada setiap objek.

2.3 Representasi profil

Setiap kafe direpresentasikan sebagai *item profile*, sedangkan pilihan pengguna direpresentasikan sebagai *user profile*. Kedua profil menggunakan vektor biner berdimensi 20. Nilai 1 menunjukkan bahwa fasilitas tersedia atau dipilih, sedangkan nilai 0 menunjukkan bahwa fasilitas tidak tersedia atau tidak dipilih. Format yang sama memastikan setiap dimensi dibandingkan dengan atribut yang sejenis.

Dua puluh atribut dipilih berdasarkan fokus konsep ruang, kajian kenyamanan kafe, dan hasil observasi [9], [10]. Atribut dikelompokkan menjadi konsep ruang utama, yaitu indoor, outdoor, semi-outdoor, dan rooftop; fasilitas produktivitas dan kenyamanan, yaitu AC, Wi-Fi, area merokok, colokan atau pengisi daya, meja kerja, dan ruang pertemuan; serta fasilitas pendukung, yaitu musik langsung, ramah hewan, spot foto, sofa, ramah mahasiswa, konsep heritage atau vintage, taman, harga terjangkau, buka 24 jam, dan specialty coffee. Jumlah 20 atribut digunakan karena seluruh atribut dapat diamati secara langsung, dikodekan secara biner, dan ditemukan secara berulang pada sampel, sehingga cakupan informasi tetap luas tanpa memasukkan variabel subjektif seperti kualitas layanan atau rasa makanan.

2.4 Perhitungan Cosine Similarity

Nilai kemiripan antara vektor preferensi pengguna A dan vektor atribut kafe B dihitung menggunakan persamaan *Cosine Similarity* [13]:

$$\text{Cosine Similarity}(A, B) = \frac{\sum_{i=1}^n (A_i \times B_i)}{\sqrt{\sum_{i=1}^n A_i^2} \times \sqrt{\sum_{i=1}^n B_i^2}}$$

Nilai berada pada rentang 0–1. Nilai mendekati 1 menunjukkan kesesuaian tinggi. Nilai 0 menunjukkan tidak terdapat atribut yang sama. Apabila magnitudo salah satu vektor bernilai nol, nilai kemiripan ditetapkan menjadi nol untuk mencegah pembagian dengan nol.

Sistem membentuk vektor pengguna berdasarkan fasilitas yang dipilih, mengambil seluruh kafe aktif dari basis data, membentuk vektor setiap kafe, dan menghitung nilai kemiripan secara berulang. Hasil kemudian diurutkan secara menurun. Nilai tertinggi ditempatkan sebagai rekomendasi utama.

2.5 Perancangan dan implementasi sistem

Perancangan menggunakan use case diagram, activity diagram, sequence diagram, class diagram, dan flowchart. Sistem mempunyai dua aktor, yaitu pengguna dan

administrator. Pengguna dapat melihat daftar kafe, memilih fasilitas, memperoleh rekomendasi, melihat detail kafe, dan membuka lokasi pada Google Maps. Administrator dapat masuk ke dasbor, mengelola data kafe, mengelola fasilitas, mengunggah foto, memperbarui data, dan menghapus data.

Aplikasi dikembangkan menggunakan PHP dan Laravel dengan pola Model–View–Controller. Antarmuka menggunakan Blade, Tailwind CSS, Vite, dan JavaScript. Basis data produksi menggunakan PostgreSQL melalui Supabase, sedangkan foto dikelola melalui Cloudinary. Aplikasi ditempatkan pada lingkungan serverless hosting. Implementasi juga menyimpan log preferensi dan hasil rekomendasi untuk mendukung evaluasi.

2.6 Pengujian

Pengujian fungsional dilakukan menggunakan *black-box testing*. Pengujian menilai kesesuaian keluaran aktual dengan hasil yang diharapkan tanpa menganalisis struktur kode. Skenario mencakup validasi pilihan fasilitas, perhitungan kemiripan, pengurutan hasil, pencarian kafe, tampilan detail, autentikasi administrator, penambahan, perubahan, penghapusan data, unggah foto, dan proses keluar.

Evaluasi algoritmik dilakukan melalui tiga langkah. Pertama, hasil komputasi aplikasi dibandingkan dengan perhitungan manual untuk memverifikasi *dot product*, magnitudo, skor *Cosine Similarity*, dan urutan peringkat. Kedua, Playwright digunakan untuk mengulang alur utama secara otomatis. Ketiga, performa peringkat dianalisis secara deskriptif melalui nilai minimum, maksimum, rata-rata, median, dan jumlah kafe dengan similarity sekurang-kurangnya 0,70 pada skenario indoor, outdoor, dan gabungan.

Precision@K, *Recall@K*, *Mean Average Precision*, dan *NDCG@K* memerlukan *ground truth* berupa label relevansi dari pengguna atau responden [14], [15]. Data tersebut belum tersedia dalam laporan penelitian, sehingga metrik tersebut tidak dihitung untuk mencegah klaim performa yang tidak didukung data. Evaluasi penelitian ini dibatasi pada ketepatan komputasi, kelayakan fungsional, dan distribusi skor. Evaluasi berbasis responden ditempatkan sebagai kebutuhan penelitian lanjutan.

Tabel 1. Skenario evaluasi komparatif berdasarkan kelompok atribut

Skenario	Fokus atribut	Tujuan
Indoor	Indoor, AC, Wi-Fi, colokan, meja kerja, ruang pertemuan, dan fasilitas terkait	Menilai kesesuaian tempat produktif di dalam ruangan
Outdoor	Outdoor, semi-outdoor, rooftop, area merokok, taman, dan fasilitas terkait	Menilai kesesuaian ruang terbuka
Gabungan	Seluruh atribut indoor dan outdoor yang relevan	Menilai rekomendasi dengan informasi yang lebih lengkap

3. Hasil dan Pembahasan

3.1 Implementasi aplikasi

Sistem berhasil diimplementasikan sebagai aplikasi web yang terdiri atas halaman beranda, daftar kafe, detail kafe, formulir preferensi, hasil rekomendasi, halaman informasi aplikasi, login administrator, dan dasbor pengelolaan data. Halaman beranda menampilkan fungsi utama dan beberapa kafe populer. Halaman daftar kafe menyediakan pencarian nama, filter fasilitas, informasi rating, lokasi, jam operasional, dan pagination.

Pada halaman rekomendasi, pengguna memilih satu atau lebih fasilitas. Pilihan yang aktif diberikan penanda visual dan jumlah fasilitas terpilih ditampilkan secara dinamis. Setelah formulir dikirim, sistem membentuk *user vector*, menghitung kemiripan dengan 50 profil kafe, dan menampilkan peringkat.

Transparansi algoritma diterapkan melalui fitur detail vektor dan perhitungan. Pengguna atau penguji dapat melihat susunan vektor biner, jumlah atribut yang cocok, nilai *dot product*, magnitudo vektor, dan hasil akhir *Cosine Similarity*. Fitur tersebut penting karena hasil rekomendasi tidak hanya ditampilkan sebagai peringkat, tetapi juga dapat ditelusuri dasar matematisnya.

Pada skenario Work from Cafe, pengguna memilih empat atribut, yaitu indoor, AC, Wi-Fi, dan colokan atau pengisi daya. Blanco Coffee & Books, Estuary Cafe, Dua Coffee Malioboro, dan Couvee Ahmad Dahlan masing-masing memperoleh similarity 0,8944. Keempat kafe memenuhi seluruh atribut yang dipilih, tetapi juga memiliki satu atribut tambahan. Tambahan tersebut memperbesar magnitudo item vector sehingga skor berada di bawah 1,0000. Contoh ini menunjukkan bahwa *Cosine Similarity* mempertimbangkan komposisi seluruh vektor, bukan hanya jumlah atribut yang cocok.

3.2 Verifikasi perhitungan algoritma

Perhitungan manual menunjukkan hasil yang sama dengan keluaran aplikasi. Nilai 1,0000 diperoleh ketika vektor pengguna dan vektor kafe identik. Sebagai ilustrasi, untuk dua vektor:

$$A=[1,0,1,1], B=[1,0,1,1]$$

diperoleh *dot product* sebesar 3 dan $\|A\| = \|B\| = \sqrt{3}$, sehingga $\text{Cos}(A,B) = 3/(\sqrt{3} \times \sqrt{3}) = 1,0000$.

Apabila kafe hanya memenuhi dua dari empat atribut, nilai kemiripan menurun sesuai komposisi vektornya. Kesamaan antara perhitungan manual dan aplikasi membuktikan bahwa fungsi pembentukan vektor, perkalian elemen, perhitungan magnitudo, serta pengurutan nilai telah diimplementasikan secara konsisten.

3.3 Hasil pengujian fungsional

Pengujian pada sisi pengguna memperlihatkan bahwa sistem dapat menampilkan halaman, menerima pilihan fasilitas, memberikan validasi ketika tidak ada fasilitas dipilih, menjalankan algoritma, mengurutkan hasil, dan membuka informasi detail. Pada sisi administrator, autentikasi, penambahan data, perubahan data, penghapusan, pengelolaan fasilitas, unggah foto, dan logout dapat dijalankan.

Tiga skenario otomatis pada laporan akhir memperoleh status *passed*. Tidak terdapat pengujian berstatus *failed*, *flaky*, atau *skipped*. Total waktu eksekusi adalah 16,8 detik menggunakan Firefox. Hasil tersebut menunjukkan bahwa alur utama yang diuji dapat dijalankan secara konsisten pada lingkungan pengujian, tetapi belum mengukur beban tinggi, keamanan, atau kepuasan pengguna.

Tabel 2. Ringkasan hasil pengujian otomatis

Komponen pengujian	Hasil
Skenario otomatis	3
Berhasil	3
Gagal	0
Flaky	0
Dilewati	0
Waktu eksekusi	16,8 detik
Status fungsi utama	Sesuai kebutuhan

Hasil pengujian membuktikan kelayakan fungsional, bukan relevansi rekomendasi secara eksternal. Pengujian lanjutan perlu melibatkan responden untuk membentuk *ground truth*, kemudian menghitung *Precision@K*, *Recall@K*, *MAP*, atau *NDCG@K*, serta mengukur pengalaman pengguna dengan instrumen usability yang sesuai.

3.4 Hasil validasi atribut


Validasi menghasilkan dataset akhir sebanyak 50 kafe dengan 20 atribut dan 218 relasi fasilitas. Penggunaan data tervalidasi meningkatkan keterpercayaan *item profile* karena fasilitas diperiksa melalui beberapa sumber. Atribut seperti jam operasional, koneksi Wi-Fi, stopkontak, area merokok, dan rooftop dapat berubah, sehingga tanggal validasi dan riwayat pembaruan perlu disimpan pada implementasi berikutnya.

Dataset sebelum validasi tidak disimpan sebagai tabel biner terpisah. Oleh karena itu, perubahan rata-rata similarity, korelasi peringkat, dan jumlah kafe yang berpindah posisi akibat validasi belum dapat dihitung. Keterbatasan ini mencegah analisis kausal tentang pengaruh validasi. Penelitian berikutnya harus menjalankan *user vector* yang sama pada dataset sebelum dan sesudah validasi, kemudian menghitung perubahan skor dan *rank displacement*.

3.5 Perbandingan skenario atribut

Skenario indoor menghasilkan rata-rata similarity 0,3682, median 0,4000, nilai maksimum 0,8452, dan lima kafe dengan skor sekurang-kurangnya 0,70. Skenario outdoor menghasilkan rata-rata 0,2379, median 0,2000, nilai maksimum 0,6325, dan tidak memiliki kafe dengan skor sekurang-kurangnya 0,70. Skenario gabungan menghasilkan rata-rata tertinggi 0,4286, median 0,3873, nilai maksimum 0,7171, dan satu kafe dengan skor sekurang-kurangnya 0,70. Nilai minimum gabungan sebesar 0,2236,

sedangkan nilai minimum indoor dan outdoor adalah 0,0000.



Gambar 2. Perbandingan rata-rata Cosine Similarity pada tiga skenario

Skenario	Rata-rata / median / maks.	Peringkat 1
Indoor	0,3682 / 0,4000 / 0,8452	Eplus Co-working Cafe
Outdoor	0,2379 / 0,2000 / 0,6325	Kopi Kebon
Gabungan	0,4286 / 0,3873 / 0,7171	Eplus Co-working Cafe

Rata-rata tertinggi dan tidak adanya skor nol pada skenario gabungan menunjukkan bahwa penggunaan sepuluh atribut memberi lebih banyak titik kecocokan antara *user vector* dan *cafe vector*. Secara praktis, pengguna memperoleh lebih banyak kandidat yang tetap dapat diurutkan. Skenario indoor memiliki rata-rata lebih tinggi daripada outdoor karena atribut indoor produktif, seperti AC, Wi-Fi, meja kerja, dan colokan, lebih banyak ditemukan dalam dataset. Atribut rooftop, taman, semi-outdoor, dan area terbuka memiliki distribusi lebih terbatas.

Eplus Co-working Cafe menempati peringkat pertama pada skenario indoor dengan skor 0,8452 dan skenario gabungan dengan skor 0,7171. Kopi Kebon menempati peringkat pertama pada skenario outdoor dengan skor 0,6325. Perubahan peringkat ini menunjukkan bahwa hasil tidak bersifat tetap. Sistem merespons kelompok atribut yang dipilih pengguna dan menempatkan kafe dengan komposisi paling dekat pada posisi teratas.

Temuan mendukung hipotesis pada tingkat rata-rata dan cakupan kandidat, tetapi tidak pada nilai maksimum individual. Skenario gabungan mempunyai rata-rata tertinggi, sedangkan maksimum tertinggi justru diperoleh skenario

indoor. Penambahan atribut dapat memperbesar peluang kecocokan, tetapi juga memperbesar magnitudo vektor. Skor suatu kafe dapat turun ketika banyak atribut tambahan tidak cocok. Karena itu, interpretasi harus mempertimbangkan distribusi atribut, kepadatan vektor, dan tujuan skenario, bukan hanya jumlah atribut.

3.6 Perbandingan dengan metode lain

CBF memberikan keuntungan pada *item cold-start*. Kafe baru dapat direkomendasikan segera setelah atributnya dimasukkan dan divalidasi. Pada *Collaborative Filtering*, item baru umumnya belum memiliki interaksi atau rating yang cukup. Keunggulan ini relevan pada ekosistem kafe yang dinamis, tetapi sangat bergantung pada ketepatan dan kemutakhiran *item profile*.

CBF tetap memiliki keterbatasan *overspecialization*. Sistem cenderung menampilkan kafe yang sangat mirip dengan pilihan eksplisit dan belum memanfaatkan minat laten. Pengguna baru juga harus memilih fasilitas sebelum menerima rekomendasi. Dengan demikian, *item cold-start* dapat dikurangi, tetapi *user cold-start* dan kebutuhan eksplorasi belum sepenuhnya diselesaikan.

Hasil penelitian ini tidak dapat dibandingkan langsung dengan similarity 0,9977 pada studi CBF di Solo [4] atau akurasi 85,7% pada studi *Collaborative Filtering* di Surakarta [5]. Studi tersebut menggunakan atribut, dataset, definisi relevansi, dan metrik yang berbeda. Kontribusi komparatif penelitian ini terletak pada fokus konsep ruang, cakupan 14 kemantren, validasi lapangan, transparansi vektor, serta analisis distribusi tiga skenario. Dibandingkan pendekatan *hybrid* [8], sistem ini lebih sederhana dan dapat menjelaskan atribut yang cocok, tetapi belum memanfaatkan data perilaku untuk meningkatkan personalisasi dan keberagaman.

4. Kesimpulan

Penelitian berhasil mengembangkan sistem rekomendasi kafe berbasis web menggunakan *Content-Based Filtering* dan *Cosine Similarity*. Sistem memproses 50 kafe dari 14 kemantren, 20 atribut fasilitas, dan 218 relasi kafe-fasilitas yang telah diperiksa silang. Preferensi pengguna dan profil kafe direpresentasikan sebagai vektor biner berdimensi 20. Perhitungan manual dan aplikasi menghasilkan nilai yang sama, termasuk 1,0000 ketika kedua vektor identik.

Fungsi utama pengguna dan administrator berjalan sesuai skenario. Tiga pengujian

otomatis berhasil dalam 16,8 detik. Rata-rata similarity adalah 0,3682 untuk indoor, 0,2379 untuk outdoor, dan 0,4286 untuk gabungan. Skenario gabungan menghasilkan cakupan kandidat terluas tanpa skor nol, sedangkan skenario indoor menghasilkan nilai maksimum tertinggi. Eplus Co-working Cafe berada pada peringkat pertama untuk indoor dan gabungan, sedangkan Kopi Kebon berada pada peringkat pertama untuk outdoor.

Secara praktis, pengguna dapat mempersempit pencarian berdasarkan kebutuhan ruang dan melihat atribut yang menjelaskan posisi rekomendasi. Pengelola kafe dapat menggunakan struktur atribut untuk memperbarui informasi fasilitas dan memahami faktor yang meningkatkan kecocokan terhadap kebutuhan pengguna, tetapi skor similarity tidak boleh ditafsirkan sebagai rating kualitas usaha. Keterbatasan penelitian meliputi tidak tersedianya dataset sebelum validasi, *ground truth* responden, dan data perilaku. Penelitian berikutnya perlu menghitung *Precision@K*, *Recall@K*, *MAP*, dan *NDCG@K*, melakukan evaluasi usabilitas, menyimpan riwayat perubahan atribut, serta mengembangkan metode *hybrid*.

Daftar Pustaka

- [1] F. Ricci, L. Rokach, and B. Shapira, Eds., *Recommender Systems Handbook*, 3rd ed. New York, NY, USA: Springer, 2022, doi: 10.1007/978-1-0716-2197-4.
- [2] C. Musto, M. de Gemmis, P. Lops, F. Narducci, and G. Semeraro, "Semantics and content-based recommendations," in *Recommender Systems Handbook*, 3rd ed., F. Ricci, L. Rokach, and B. Shapira, Eds. New York, NY, USA: Springer, 2022, pp. 251-298, doi: 10.1007/978-1-0716-2197-4_7.
- [3] A. Refkrisnatta and D. Handayani, "Cafe selection recommendation system in Semarang City uses collaborative filtering method with item based filtering algorithm," *JEEE-U: Journal of Electrical and Electronic Engineering-UMSIDA*, vol. 6, no. 2, pp. 95-108, 2022, doi: 10.21070/jeeeu.v6i2.1637.
- [4] F. A. Putra, R. Susanto, and W. Lestari, "Implementasi metode content-based filtering pada sistem rekomendasi kafe di Solo," *Jurnal Riset dan Aplikasi Mahasiswa Informatika*, vol. 6, no. 4, pp. 742-751, 2025.
- [5] B. C. Putro, D. Remawati, S. H. Fitriasih, and K. Sandradewi, "Sistem rekomendasi kedai kopi di Kota Surakarta dengan kategori fasilitas

- menggunakan item-based collaborative filtering,” *JRIS: Jurnal Rekayasa Informasi Swadharma*, vol. 6, no. 1, pp. 93-103, 2026, doi: 10.56486/jris.vol6no1.988.
- [6] U. Apsiswanto and C. A. Pamungkas, “Penerapan metode Weighted Product pada pemilihan kafe bagi mahasiswa pendatang di Kota Metro,” *Jurnal Informatika*, vol. 22, no. 2, pp. 172-182, 2022.
- [7] Irfan, A. A. Ilham, I. Taufik, and D. Suarna, “Sistem rekomendasi penentuan titik usaha kafe menggunakan data spasial dan algoritma TOPSIS,” *Bulletin of Information Technology*, vol. 4, no. 3, pp. 400-407, 2023, doi: 10.47065/bit.v4i3.918.
- [8] Y. Afoudi, M. Lazaar, and M. Al Achhab, “Hybrid recommendation system combined content-based filtering and collaborative prediction using artificial neural network,” *Simulation Modelling Practice and Theory*, vol. 113, Art. no. 102375, 2021, doi: 10.1016/j.simpat.2021.102375.
- [9] P. N. Iswaridewi, O. A. Tanadda, and S. B. Astuti, “Identifikasi faktor pemilihan area indoor dan outdoor di concept café berdasarkan kenyamanan aktivitas pengunjung,” *Serat Rupa Journal of Design*, vol. 8, no. 1, pp. 125-134, 2024.
- [10] Z. Azmiy and K. N. Dewi, “Pengaruh setting ruang terhadap pola interaksi sosial pengunjung di Kafe Mutu Loka, Bandung,” *Indonesian Journal of Multidisciplinary on Social and Technology*, vol. 4, no. 2, pp. 1451-1459, 2026, doi: 10.69693/ijmst.v4i2.9777.
- [11] Y. Anis, E. N. Wahyudi, and H. C. Kurniawan, “Metode Waterfall dalam pengembangan sistem inventaris guna meningkatkan efisiensi manajemen stok barang,” *Jurnal Teknologi dan Sistem Informasi Bisnis*, vol. 6, no. 2, pp. 1-10, 2024.
- [12] M. Mailasari, M. N. Winnarto, and A. Purnamawati, “Penerapan metode Waterfall dalam pengembangan aplikasi schedule maintenance alat produksi,” *Infotek: Jurnal Informatika dan Teknologi*, vol. 7, no. 1, pp. 133-141, 2024, doi: 10.29408/jit.v7i1.24080.
- [13] A. Sanjaya, A. B. Setiawan, U. Mahdiyah, I. N. Farida, and A. R. Prasetyo, “Pengukuran kemiripan makna menggunakan Cosine Similarity dan basis data sinonim kata,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 4, pp. 747-752, 2023, doi: 10.25126/jtiik.2023106864.
- [14] A. Gunawardana, G. Shani, and S. Yogev, “Evaluating recommender systems,” in *Recommender Systems Handbook, 3rd ed.*, F. Ricci, L. Rokach, and B. Shapira, Eds. New York, NY, USA: Springer, 2022, pp. 547-601, doi: 10.1007/978-1-0716-2197-4_15.
- [15] E. Zangerle and C. Bauer, “Evaluating recommender systems: Survey and framework,” *ACM Computing Surveys*, vol. 55, no. 8, Art. no. 170, pp. 1-38, 2022, doi: 10.1145/3556536.