

# Penerapan *Content-based Filtering* pada Sistem Rekomendasi Barbershop di Kabupaten Sleman

## *Implementation of Content-based Filtering in a Barbershop Recommendation System in Sleman Regency*

<sup>1</sup>Reza Andriansah\*, <sup>2</sup>Arif Nur Rohman, <sup>3</sup>Ika Nur Fajri

<sup>1,2,3</sup>Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Amikom Yogyakarta

<sup>1,2,3</sup>Jl. Ring Road Utara Condong Catur Depok Sleman, Yogyakarta

\*e-mail: <sup>1</sup>[rezandriansah12@students.amikom.ac.id](mailto:rezandriansah12@students.amikom.ac.id), <sup>2</sup>[arifrahman@amikom.ac.id](mailto:arifrahman@amikom.ac.id), <sup>3</sup>[fajri@amikom.ac.id](mailto:fajri@amikom.ac.id)

(**received:** 29 April 2026, **revised:** 14 August 2026, **accepted:** 15 August 2026)

### Abstrak

Kabupaten Sleman, Daerah Istimewa Yogyakarta, memiliki 209 barbershop yang tersebar di 13 dari 17 kecamatan. Banyaknya pilihan barbershop menyebabkan konsumen kesulitan dalam menentukan barbershop yang sesuai preferensi. Penelitian ini membangun sistem rekomendasi barbershop menggunakan metode Content-Based Filtering (CBF) dengan Cosine Similarity. Dataset diperoleh melalui web scraping dari Google Maps dengan fitur nama, kecamatan, rating, jumlah ulasan, dan kategori layanan. Eksperimen bobot dilakukan untuk menentukan bobot optimal fitur kecamatan dengan menguji variasi 1×, 2×, 3×, dan 4×, dan ditemukan bobot 3,0× menghasilkan performa terbaik. Evaluasi pada 78 sampel menggunakan Precision@N, Recall@N, dan F1-Score menghasilkan Recall@10 = 0,3205 dan F1-Score@10 = 0,1307. Nilai Precision@10 tercatat rendah (0,0821), disebabkan oleh distribusi rating dataset yang homogen (4,3–5,0) sehingga hampir seluruh barbershop dalam satu kecamatan memenuhi kriteria ground truth. Meski demikian, hasil ini menunjukkan sistem mampu memberikan rekomendasi barbershop yang relevan di Kabupaten Sleman, khususnya dari sisi cakupan (recall) item relevan, sementara nilai precision yang rendah mengindikasikan perlunya fitur pembeda tambahan pada penelitian selanjutnya.

**Kata kunci:** barbershop, content-based filtering, cosine similarity, web scraping, sistem rekomendasi

### Abstract

Sleman Regency, Special Region of Yogyakarta, is home to 209 barbershops distributed across 13 of its 17 districts. The wide range of available barbershops can make it difficult for consumers to identify options that match their preferences. This study develops a barbershop recommendation system using Content-Based Filtering (CBF) with Cosine Similarity. The dataset was collected through web scraping from Google Maps, incorporating features such as barbershop name, district, rating, number of reviews, and service category. A feature-weighting experiment was conducted to determine the optimal weight for the district feature by testing 1×, 2×, 3×, and 4× weighting schemes. The results showed that a 3.0× weight achieved the best performance. Evaluation on 78 samples using Precision@N, Recall@N, and F1-score produced a Recall@10 of 0.3205 and an F1-score@10 of 0.1307. The Precision@10 of 0.0821 was relatively low due to the homogeneous rating distribution in the dataset (4.3–5.0), which caused most barbershops within the same district to satisfy the ground-truth criteria. Nevertheless, the results demonstrate that the proposed system can provide relevant barbershop recommendations in Sleman Regency, particularly in terms of recall-based coverage of relevant items. The relatively low precision indicates the need for additional discriminative features, such as price, distance, specific services, facilities, or user preferences, to improve recommendation quality in future research.

**Keywords:** barbershop, content-based filtering, cosine similarity, web scraping, recommendation system

## 1 Pendahuluan

Kabupaten Sleman, Daerah Istimewa Yogyakarta, mencatat pertumbuhan usaha barbershop yang signifikan seiring meningkatnya kebutuhan layanan perawatan diri di kalangan masyarakat urban. Berdasarkan hasil web scraping dari Google Maps, terdapat 209 barbershop yang tersebar di 13 dari 17 kecamatan, dengan Kecamatan Depok sebagai kecamatan dengan jumlah terbanyak yaitu 55 barbershop (26,3%). Banyaknya pilihan ini menimbulkan tantangan bagi konsumen dalam menentukan barbershop yang sesuai preferensi tanpa panduan terstruktur [1], sehingga dibutuhkan sistem rekomendasi sebagai solusi.

Content-Based Filtering (CBF) dipilih sebagai metode karena cocok untuk dataset dengan fitur deskriptif tanpa memerlukan data historis interaksi pengguna [8]. Namun, penerapan CBF pada data multi-tipe kombinasi fitur numerik (rating, jumlah ulasan), fitur teks (nama barbershop), dan fitur kategorikal (kecamatan) memunculkan persoalan teknis yang belum banyak dibahas secara empiris: bagaimana menyeimbangkan kontribusi masing-masing tipe fitur dalam perhitungan Cosine Similarity. Fitur kategorikal seperti kecamatan yang direpresentasikan melalui one-hot encoding secara default hanya berkontribusi sebagai vektor biner sparse dengan magnitudo kecil dibandingkan fitur numerik hasil normalisasi atau fitur teks hasil pembobotan TF-IDF. Tanpa penyesuaian skala, fitur kecamatan berisiko under-weighted terhadap fitur lain, sehingga kemiripan geografis antar-item tidak cukup berpengaruh terhadap hasil rekomendasi padahal pada sistem rekomendasi berbasis lokasi, kedekatan geografis umumnya merupakan faktor keputusan yang dominan bagi pengguna [4][6].

Penelitian pada domain sistem rekomendasi berbasis konten [5] dan rekomendasi berbasis lokasi [6] menunjukkan efektivitas CBF secara umum, namun keduanya tidak secara spesifik menguji skala pembobotan fitur kategorikal-lokasi secara sistematis. Sebagian besar studi CBF berbasis lokasi memperlakukan fitur lokasi sebagai filter biner (termasuk/tidak termasuk area tertentu) atau menggunakan bobot tetap tanpa validasi empiris, sehingga pemilihan skala bobot yang tepat untuk fitur kategorikal relatif terhadap fitur numerik dan teks masih menjadi masalah terbuka khususnya pada domain dengan jumlah kategori (kecamatan) yang banyak dan distribusi data yang tidak merata antar kategori, seperti pada kasus barbershop di Kabupaten Sleman.

Berdasarkan celah tersebut, penelitian ini mengusulkan eksperimen pembobotan fitur kecamatan secara empiris dengan menguji beberapa variasi skala bobot ( $1\times$ ,  $2\times$ ,  $3\times$ ,  $4\times$ ) terhadap performa sistem rekomendasi, diukur menggunakan Precision@N, Recall@N, dan F1-Score. Pendekatan ini memungkinkan penentuan bobot optimal berdasarkan bukti kuantitatif, bukan asumsi tetap, sekaligus memberikan gambaran umum mengenai trade-off yang terjadi ketika bobot fitur kategorikal terlalu rendah (faktor geografis kurang dominan) maupun terlalu tinggi (mendominasi secara berlebihan sehingga mengorbankan kontribusi fitur kualitas dan popularitas).

Penelitian ini memberikan kontribusi dengan membangun sistem rekomendasi barbershop di Kabupaten Sleman menggunakan CBF dengan fitur multi-tipe (numerik, teks, kategorikal). Kontribusi tersebut diwujudkan melalui eksperimen bobot fitur kecamatan ( $1\times$ ,  $2\times$ ,  $3\times$ ,  $4\times$ ) untuk menemukan nilai optimal secara empiris pada perhitungan Cosine Similarity, didukung oleh pengumpulan dataset 209 barbershop melalui web scraping Google Maps. Sistem yang dihasilkan selanjutnya dievaluasi menggunakan Precision@N, Recall@N, dan F1-Score untuk mengukur relevansi rekomendasi yang dihasilkan.

## 2 Tinjauan Literatur

Lops et al. [5] mendefinisikan sistem rekomendasi sebagai sistem yang memprediksi preferensi pengguna terhadap item dan merekomendasikan item paling relevan. Klasifikasi sistem rekomendasi ke dalam tiga pendekatan utama Collaborative Filtering, sebagaimana dibahas dalam tinjauan analitis metode content-based dan collaborative filtering [2] dan studi penerapannya yang lebih baru pada domain hiburan [3]; Content-Based Filtering; serta Hybrid Filtering tetap menjadi taksonomi dasar yang digunakan hingga tinjauan komprehensif terkini [9][10][18]. Studi empiris Jozani et al. [21] pada pasar aplikasi mobile membuktikan bahwa pemilihan metode yang tepat sesuai karakteristik data termasuk ketersediaan data interaksi pengguna sangat berpengaruh terhadap kualitas rekomendasi, yang mendasari pemilihan CBF pada penelitian dengan data non-interaktif seperti barbershop.

Pada domain CBF, representasi fitur merupakan faktor penentu utama keberhasilan sistem. Studi yang sama [5] menyimpulkan bahwa representasi fitur yang tepat merupakan kunci keberhasilan sistem rekomendasi berbasis konten, khususnya ketika item direpresentasikan oleh kombinasi fitur dengan tipe data berbeda. Zhang et al. [11] mencatat bahwa rating merupakan sinyal yang sangat informatif dalam sistem rekomendasi berbasis deep learning, namun tidak membahas bagaimana sinyal numerik semacam ini seharusnya diseimbangkan terhadap fitur bertipe lain saat digabungkan dalam satu vektor. Fajriansyah et al. [12] menerapkan TF-IDF dan Cosine Similarity untuk rekomendasi film dengan Precision = 0,75, memvalidasi efektivitas kombinasi kedua teknik tersebut, tetapi penelitian tersebut hanya menggunakan fitur teks tunggal sehingga persoalan pembobotan antar-tipe fitur belum relevan pada kasus itu.

Persoalan pembobotan menjadi lebih signifikan pada sistem rekomendasi berbasis lokasi, di mana fitur kategorikal-geografis harus digabungkan dengan fitur numerik dan teks. Zheng [6] membuktikan bahwa data lokasi merupakan komponen inti dalam sistem berbasis tempat, dan model yang mengintegrasikan fitur geografis secara memadai menghasilkan rekomendasi yang lebih relevan dibandingkan model yang mengabaikan atau meremehkan kontribusi fitur tersebut. Zhang et al. [4] menunjukkan CBF dengan fitur lokasi dan kemiripan kategori menghasilkan rekomendasi POI (point-of-interest) yang akurat berdasarkan pola aktivitas pengguna, namun bobot kontribusi fitur lokasi terhadap fitur lain ditentukan secara heuristik tanpa pengujian variasi skala. Baral dan Li [7] menunjukkan sistem rekomendasi berbasis lokasi (C-MHRS) secara konsisten menghasilkan performa lebih baik dibandingkan baseline non-lokasi, tetapi juga tidak melaporkan eksperimen sistematis terhadap besaran bobot fitur lokasi itu sendiri. Survei terbaru oleh Sánchez dan Bellogín [22] terhadap sistem rekomendasi berbasis lokasi (POI) turut mengonfirmasi bahwa strategi pembobotan pengaruh geografis pada sebagian besar pendekatan masih bersifat heuristik atau ditentukan oleh struktur model, bukan divalidasi melalui eksperimen variasi bobot secara sistematis. Keempat studi ini secara konsisten menunjukkan bahwa fitur lokasi penting, namun belum satupun yang menjadikan skala pembobotan fitur lokasi sebagai variabel yang diuji secara empiris celah inilah yang menjadi fokus penelitian ini.

Dari sisi teknis representasi vektor, TF-IDF [14] dan Cosine Similarity [15][24] terbukti efektif digunakan bersama dalam CBF untuk mengukur kemiripan antar-item berbasis teks. Namun, ketika fitur teks digabungkan dengan fitur numerik dan kategorikal dalam satu matriks fitur, perbedaan skala antar-tipe fitur dapat menyebabkan salah satu tipe fitur mendominasi atau justru terabaikan dalam perhitungan cosine similarity. Noori et al. [16] menunjukkan bahwa kombinasi normalisasi fitur dengan cosine similarity efektif menjaga keseimbangan kontribusi antar-fitur pada sistem rekomendasi berbasis konten, namun tidak secara khusus menjawab bagaimana fitur kategorikal hasil one-hot encoding yang secara default bersifat biner dan sparse seharusnya diberi bobot relatif terhadap fitur numerik maupun teks. Studi terapan CBF pada domain produk lokal oleh Azizah dan Rozi [23] turut menegaskan bahwa representasi fitur campuran (numerik dan kategorikal) memerlukan penyesuaian bobot agar salah satu jenis fitur tidak mendominasi hasil similaritas secara tidak proporsional.

Pada aspek pengumpulan data, Naing et al. [13] menegaskan bahwa Selenium WebDriver efektif digunakan untuk membangun sistem pengumpulan data terstruktur berbasis web scraping, sebuah pendekatan yang mendasari metode pengumpulan dataset 209 barbershop pada penelitian ini.

Berdasarkan tinjauan di atas, dapat disimpulkan bahwa penelitian-penelitian sebelumnya pada CBF berbasis lokasi [4][6][7][22] secara konsisten mengonfirmasi pentingnya fitur geografis, tetapi memperlakukan bobot fitur tersebut sebagai nilai tetap atau heuristik, bukan sebagai parameter yang divalidasi secara empiris. Novelty penelitian ini terletak pada domain spesifik barbershop di Kabupaten Sleman yang belum diteliti pada konteks CBF berbasis lokasi, didukung oleh dataset hasil web scraping Google Maps yang mencakup 13 kecamatan. Lebih lanjut, penelitian ini melakukan eksperimen empiris terhadap variasi skala bobot fitur kecamatan (1×, 2×, 3×, 4×) menggunakan Cosine Similarity untuk menemukan titik optimal antara kontribusi fitur lokasi, kualitas (rating), dan popularitas (jumlah ulasan) pengujian sistematis semacam ini belum dilakukan pada penelitian berbasis lokasi sebelumnya [6][7].

Perbandingan ketiga metode sistem rekomendasi disajikan pada Tabel 1.

**Tabel 1 Perbandingan metode sistem rekomendasi**


<http://sistemasi.ftik.unisi.ac.id>

| Aspek                | CBF                      | Collaborative           | Hybrid            |
|----------------------|--------------------------|-------------------------|-------------------|
| Data yang dibutuhkan | Fitur konten item        | Interaksi pengguna      | Fitur + interaksi |
| Cold-start problem   | Tidak ada                | Ada                     | Sebagian          |
| Kebutuhan data       | Rendah                   | Tinggi                  | Sangat tinggi     |
| Transparansi         | Tinggi                   | Rendah                  | Sedang            |
| Cocok untuk          | Dataset fitur deskriptif | Dataset interaksi besar | Dataset lengkap   |

Berdasarkan Tabel 1, CBF dipilih karena dataset barbershop hanya memiliki fitur konten tanpa data interaksi pengguna.

### 3 Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental. Alur metodologi penelitian secara lengkap disajikan pada Gambar 1.



**Gambar 1 Alur Metodologi Penelitian**

Pengumpulan data dilakukan melalui web scraping Google Maps menggunakan Selenium WebDriver Python dengan 18 query (kata kunci 'barbershop' + nama kecamatan Sleman). Atribut yang dikumpulkan: nama, alamat, kecamatan, rating, jumlah ulasan, kategori layanan, dan nomor telepon. Proses menghasilkan 209 data barbershop unik dari 13 kecamatan.

Tahap preprocessing diawali dengan penghapusan duplikat berdasarkan kombinasi nama dan alamat, dilanjutkan dengan penghapusan data tanpa nilai rating untuk menjaga kualitas dataset. Selain itu, teks dinormalisasi ke huruf kecil (lowercase), sementara kecamatan diekstraksi dari alamat menggunakan pencocokan kata kunci. Data yang tidak memiliki kecamatan valid pada akhirnya turut dihapus dari dataset.

Vektor fitur setiap barbershop dibentuk dari kombinasi tiga jenis komponen. Fitur numerik (rating dan ulasan) dinormalisasi menggunakan Min-Max Scaler persamaan (1) dengan bobot 2,0×:

$$X' = (X - X_{min}) / (X_{max} - X_{min}) \dots(1)$$

Sementara itu, fitur teks (nama barbershop) direpresentasikan menggunakan TF-IDF dengan bobot 1,0×, sedangkan fitur kecamatan direpresentasikan melalui one-hot encoding. Untuk menentukan bobot optimal fitur kecamatan secara empiris, dilakukan eksperimen dengan menguji empat variasi bobot: 1×, 2×, 3×, dan 4×. Setiap variasi dievaluasi menggunakan Recall@10 dan F1-Score@10 sebagai metrik utama (lihat Tabel 9). Komponen vektor fitur dengan bobot terpilih disajikan pada Tabel 2.

**Tabel 2 Komponen vektor fitur CBF**

| Fitur           | Jenis       | Normalisasi      | Bobot |
|-----------------|-------------|------------------|-------|
| Rating          | Numerik     | Min-Max Scaler   | 2,0×  |
| Jumlah Ulasan   | Numerik     | Min-Max Scaler   | 2,0×  |
| Kecamatan       | Kategorikal | One-Hot Encoding | 3,0×  |
| Nama Barbershop | Teks        | TF-IDF           | 1,0×  |

Kemiripan antar barbershop dihitung Cosine Similarity persamaan (2) menghasilkan matriks 209×209:

$$\cos(A,B) = (A \cdot B) / (\|A\| \times \|B\|) \dots(2)$$

Skor rekomendasi akhir dihitung menggunakan kombinasi rating (bobot 0,6) dan popularitas (bobot 0,4) sebagaimana dirumuskan pada persamaan (3):

$$\text{Skor} = 0,6 \times (\text{rating}/5) + 0,4 \times (\log(\text{ulasan}+1)/\log(\text{max}+1)) \dots(3)$$

Evaluasi menggunakan Precision@N persamaan (4), Recall@N persamaan (5), dan F1-Score persamaan (6) pada 78 sampel dengan ground truth barbershop rating  $\geq 4,0$  di kecamatan yang sama:

$$\text{Precision@N} = |\text{Relevan} \cap \text{TopN}| / N \dots(4)$$

$$\text{Recall@N} = |\text{Relevan} \cap \text{TopN}| / |\text{Relevan}| \dots(5)$$

$$\text{F1-Score} = 2 \times (P \times R) / (P + R) \dots(6)$$

#### 4 Hasil dan Pembahasan

Web scraping menghasilkan 209 data barbershop dari 13 kecamatan Kabupaten Sleman. Statistik deskriptif dataset disajikan pada Tabel 3.

**Tabel 3 Statistik deskriptif dataset barbershop sleman**

| Atribut                              | Nilai        |
|--------------------------------------|--------------|
| Total data barbershop                | 209          |
| Kecamatan tercakup                   | 13 kecamatan |
| Rata-rata rating (setelah pembaruan) | 4,7 / 5,0    |
| Rata-rata jumlah ulasan              | 1.444 ulasan |
| Rating tertinggi                     | 5,0          |
| Rating terendah                      | 4,3          |
| Dimensi matriks fitur                | 209 × 23     |
| Dimensi matriks similarity           | 209 × 209    |

Distribusi barbershop menunjukkan Kecamatan Depok mendominasi (55 barbershop, 26,3%), diikuti Godean (26, 12,4%) dan Ngaglik (23, 11,0%). Distribusi lengkap disajikan pada Tabel 4.

**Tabel 4 Distribusi barbershop per kecamatan di kabupaten sleman**

| No | Kecamatan | Jumlah Barbershop | Persentase |
|----|-----------|-------------------|------------|
| 1  | Depok     | 55                | 26,3%      |
| 2  | Godean    | 26                | 12,4%      |
| 3  | Ngaglik   | 23                | 11,0%      |
| 4  | Gamping   | 21                | 10,0%      |
| 5  | Berbah    | 17                | 8,1%       |
| 6  | Kalasan   | 17                | 8,1%       |
| 7  | Prambanan | 17                | 8,1%       |
| 8  | Mlati     | 13                | 6,2%       |
| 9  | Minggir   | 11                | 5,3%       |
| 10 | Sleman    | 6                 | 2,9%       |
| 11 | Moyudan   | 1                 | 0,5%       |
| 12 | Seyegan   | 1                 | 0,5%       |
| 13 | Tempel    | 1                 | 0,5%       |
|    | Total     | 209               | 100%       |

Tabel 5 menampilkan 8 sampel data barbershop dengan rating aktual yang telah diverifikasi secara manual dari Google Maps.

**Tabel 5 Sampel data barbershop kabupaten sleman**

| No | Nama Barbershop     | Kecamatan | Rating | Ulasan | Kategori        |
|----|---------------------|-----------|--------|--------|-----------------|
| 1  | Limanol Barbershop  | Mlati     | 4,9    | 2.080  | T. Cukur Rambut |
| 2  | The Guns Barbershop | Depok     | 4,7    | 4.390  | T. Cukur Rambut |
| 3  | Blue Barbershop     | Mlati     | 4,7    | 1.350  | T. Cukur Rambut |
| 4  | Dk Barbershop &     | Depok     | 5,0    | 620    | T. Cukur Rambut |
| 5  | Arfa Barbershop UGM | Depok     | 4,5    | 2.930  | T. Cukur Rambut |
| 6  | Faris Barbergames   | Depok     | 4,9    | 3.040  | T. Cukur Rambut |
| 7  | Mr. Fox Barbershop  | Mlati     | 4,4    | 1.620  | T. Cukur Rambut |
| 8  | Coolcuts Everyday   | Depok     | 4,9    | 530    | T. Cukur Rambut |

Tabel 6 dan Tabel 7 menyajikan contoh hasil rekomendasi sistem untuk dua kecamatan berbeda, yaitu Kecamatan Depok (kecamatan dengan barbershop terbanyak, 55 barbershop) dan Kecamatan Ngaglik (kecamatan terbanyak ketiga, 23 barbershop), dengan rating minimum 4,0.

**Tabel 6 Hasil rekomendasi barbershop di kecamatan depok (Top-5)**

| Rank | Nama Barbershop        | Kecamatan | Rating | Ulasan | Skor   |
|------|------------------------|-----------|--------|--------|--------|
| 1    | Faris Barbergames      | Depok     | 4,9    | 3.040  | 0,9705 |
| 2    | The Guns Barbershop    | Depok     | 4,7    | 4.390  | 0,9640 |
| 3    | Arfa Barbershop UGM    | Depok     | 4,5    | 2.930  | 0,9207 |
| 4    | Dk Barbershop &        | Depok     | 5,0    | 620    | 0,9067 |
| 5    | Boediman.Jr Barbershop | Depok     | 4,3    | 2.630  | 0,8916 |

Berdasarkan Tabel 6, Faris Barbergames mendapat skor tertinggi (0,9705) karena kombinasi rating tinggi (4,9) dan jumlah ulasan terbanyak (3.040). Dk Barbershop & Coffeeshop berada di posisi keempat (0,9067) meskipun memiliki rating sempurna (5,0), karena jumlah ulasannya (620) lebih rendah. Hal ini membuktikan skor rekomendasi persamaan (3) mampu mempertimbangkan keseimbangan kualitas dan popularitas secara proporsional.

**Tabel 7 Hasil rekomendasi barbershop di kecamatan ngaglik (Top-5)**


| Rank | Nama Barbershop                     | Kecamatan | Rating | Ulasan | Skor   |
|------|-------------------------------------|-----------|--------|--------|--------|
| 1    | Barberking Barbershop Jogja – Jakal | Ngaglik   | 4,8    | 16.730 | 0,9760 |
| 2    | Maxcoolin Barbershop                | Ngaglik   | 4,7    | 3.530  | 0,9000 |
| 3    | Delapan Barbershop & Shoescare      | Ngaglik   | 4,8    | 2.210  | 0,8928 |
| 4    | Barbershop Ter The Cut Palagan      | Ngaglik   | 4,7    | 2.430  | 0,8847 |
| 5    | Duo Barbershop Jogjakarta           | Ngaglik   | 4,9    | 1.280  | 0,8823 |

Berdasarkan Tabel 7, Barberking Barbershop Jogja – Jakal mendapat skor tertinggi (0,9760) didorong jumlah ulasan sangat tinggi (16.730). Duo Barbershop Jogjakarta di posisi kelima meskipun memiliki rating tertinggi (4,9), karena jumlah ulasannya (1.280) relatif lebih rendah. Perbandingan Tabel 6 dan Tabel 7 memperlihatkan konsistensi sistem: seluruh rekomendasi berasal dari kecamatan yang diminta, memvalidasi efektivitas bobot kecamatan ( $3,0\times$ ) dalam memprioritaskan kedekatan geografis.

Evaluasi sistem menggunakan 78 sampel barbershop disajikan pada Tabel 8.

**Tabel 8 Hasil evaluasi sistem rekomendasi CBF**

| Metrik Evaluasi | Top-3  | Top-5  | Top-10 |
|-----------------|--------|--------|--------|
| Precision@N     | 0,1026 | 0,0923 | 0,0821 |
| Recall@N        | 0,0846 | 0,1154 | 0,3205 |
| F1-Score        | 0,0927 | 0,1026 | 0,1307 |



**Gambar 2 Grafik perbandingan nilai evaluasi CBF**

Berdasarkan Tabel 8 dan Gambar 2, nilai Recall@10 = 0,3205 menunjukkan sistem berhasil menemukan 32,05% barbershop relevan dari seluruh item relevan, melampaui penelitian serupa [7]. Nilai Precision yang relatif rendah pada seluruh nilai N (0,1026 pada Top-3 hingga 0,0821 pada Top-10) disebabkan oleh distribusi rating dataset yang bersifat extreme positive skewness, dengan rentang 4,3–5,0 dan rata-rata 4,7 (Tabel 3). Pada kondisi distribusi rating yang sangat miring seperti ini, kriteria ground truth berbasis ambang rating ( $\geq 4,0$ ) menjadi kurang diskriminatif karena hampir seluruh barbershop dalam satu kecamatan memenuhi ambang tersebut sekaligus, sehingga jumlah item yang dianggap "relevan" ( $|Relevant|$ ) menjadi sangat besar relatif terhadap ukuran Top-N pada persamaan (4). Akibatnya, Precision@N secara struktural sulit mencapai nilai tinggi berapa pun kualitas rekomendasi yang dihasilkan sistem, karena metrik ini dihitung sebagai proporsi item relevan dari N item teratas bukan dari keseluruhan item relevan yang berhasil dijangkau. Recall@N, sebaliknya, secara langsung mengukur proporsi item relevan yang berhasil ditemukan dari keseluruhan populasi relevan (persamaan 5), sehingga tidak terpengaruh oleh besarnya  $|Relevant|$  dengan cara yang sama.


Oleh karena itu, pada dataset dengan karakteristik rating yang homogen dan condong tinggi sebagaimana lazim ditemukan pada data ulasan Google Maps [17] Recall dan F1-Score merupakan indikator performa yang lebih representatif dibandingkan Precision semata, karena F1-Score tetap mempertimbangkan kontribusi Recall dalam keseimbangannya (persamaan 6). Interpretasi ini konsisten dengan Herlocker et al. [17], yang menyatakan bahwa evaluasi berbasis akurasi klasifikasi seperti Precision perlu ditafsirkan secara hati-hati pada dataset dengan distribusi rating yang tidak seimbang, karena definisi "relevan" yang longgar dapat menggelembungkan ukuran ground truth secara sistematis. Peningkatan Recall yang signifikan dari Top-3 (0,0846) ke Top-10 (0,3205) mengonfirmasi efektivitas pembobotan kecamatan dalam menjangkau lebih banyak item relevan, konsisten dengan temuan Zheng [6], meskipun demikian keterbatasan Precision pada studi ini tetap perlu diperhitungkan sebagai trade-off yang melekat pada desain ground truth berbasis ambang rating, bukan semata kelemahan algoritma CBF itu sendiri.

Untuk memvalidasi pemilihan bobot kecamatan  $3,0\times$  secara eksperimental, dilakukan pengujian dengan empat variasi bobot:  $1\times$ ,  $2\times$ ,  $3\times$ , dan  $4\times$ . Setiap variasi dievaluasi pada 78 sampel

menggunakan metrik Recall@10 dan F1-Score@10. Hasil eksperimen disajikan pada Tabel 9 dan Gambar 3.

**Tabel 9 Hasil eksperimen variasi bobot fitur kecamatan**

| Metrik       | Bobot 1× | Bobot 2× | Bobot 3× | Bobot 4× | Terbaik |
|--------------|----------|----------|----------|----------|---------|
| Precision@10 | 0,0513   | 0,0718   | 0,0821   | 0,0769   | 3×      |
| Recall@10    | 0,1282   | 0,2436   | 0,3205   | 0,2949   | 3×      |
| F1-Score@10  | 0,0731   | 0,0985   | 0,1307   | 0,1189   | 3×      |



**Gambar 3 Grafik perbandingan performa berdasarkan variasi bobot kecamatan**

Berdasarkan Tabel 9 dan Gambar 3, bobot kecamatan 3,0× menghasilkan performa terbaik pada semua metrik: Precision@10 = 0,0821, Recall@10 = 0,3205, dan F1-Score@10 = 0,1307. Bobot 1,0× menghasilkan performa terendah karena kecamatan hanya memiliki kontribusi sama dengan fitur lain, sehingga faktor geografis kurang dominan. Bobot 2,0× menunjukkan peningkatan signifikan namun belum optimal. Bobot 4,0× mengalami penurunan dibandingkan 3,0× karena pembobotan yang terlalu besar menyebabkan kecamatan mendominasi secara berlebihan sehingga mengorbankan kontribusi fitur rating dan popularitas. Pola ini mengonfirmasi bobot 3,0× merupakan titik optimal yang menyeimbangkan faktor lokasi, kualitas (rating), dan popularitas (jumlah ulasan) dalam sistem rekomendasi barbershop di Kabupaten Sleman.



Gambar 4 Implementasi web

Berdasarkan Gambar 4, hasil sistem rekomendasi CBF diimplementasikan ke dalam antarmuka website "Barbershop Sleman" untuk memvalidasi penerapan model secara praktis. Antarmuka menyediakan direktori barbershop dengan fitur pencarian berdasarkan nama atau alamat, serta filter kecamatan yang memanfaatkan bobot fitur lokasi  $3,0\times$  sebagaimana telah divalidasi pada Bagian 4. Barbershop dengan label "Populer" ditampilkan berdasarkan skor kombinasi rating dan jumlah ulasan pada persamaan (3), konsisten dengan hasil rekomendasi pada Tabel 6 dan Tabel 7. Implementasi ini menunjukkan bahwa sistem rekomendasi yang dibangun dapat diterapkan pada antarmuka nyata yang siap digunakan pengguna, sekaligus menjawab arahan pengembangan lanjutan yang disebutkan pada Bagian 5.

## 5 Kesimpulan

Penelitian ini berhasil membangun sistem rekomendasi barbershop di Kabupaten Sleman menggunakan Content-Based Filtering dengan Cosine Similarity, memanfaatkan dataset 209 barbershop dari 13 kecamatan hasil web scraping Google Maps yang menghasilkan matriks fitur berukuran  $209\times 23$  dan matriks similarity  $209\times 209$ ; evaluasi pada 78 sampel menghasilkan  $\text{Recall}@10 = 0,3205$  (melampaui penelitian serupa),  $\text{F1-Score}@10 = 0,1307$ , dan  $\text{Precision}@10 = 0,0821$ , di mana nilai Precision yang rendah ini konsisten dengan karakteristik ground truth berbasis ambang rating pada dataset dengan distribusi rating yang homogen. Lebih lanjut, eksperimen bobot membuktikan secara empiris bahwa bobot kecamatan  $3,0\times$  menghasilkan performa terbaik dibandingkan bobot  $1,0\times$ ,  $2,0\times$ , dan  $4,0\times$  pada semua metrik evaluasi, dengan validasi yang konsisten pada pengujian di dua kecamatan berbeda (Depok dan Ngaglik) hal ini menjadi kontribusi utama penelitian. Meski demikian, penelitian ini memiliki sejumlah keterbatasan, yaitu cakupan data yang hanya meliputi 13 dari 17 kecamatan akibat keterbatasan hasil scraping Google Maps, fitur yang digunakan masih terbatas pada nama, rating, jumlah ulasan, dan kecamatan tanpa mencakup fitur harga dan fasilitas, sifat data yang statis dan tidak diperbarui secara real-time, serta desain ground truth berbasis ambang rating tunggal ( $\geq 4,0$ ) yang membatasi daya diskriminasi Precision pada dataset dengan distribusi rating homogen. Oleh karena itu, penelitian selanjutnya disarankan untuk menambahkan fitur harga dan fasilitas, menerapkan analisis sentimen ulasan berbahasa Indonesia (misalnya menggunakan IndoBERT), mengembangkan antarmuka website interaktif agar pengguna dapat mengakses sistem secara langsung, mengeksplorasi definisi ground truth yang lebih ketat atau bertingkat, serta mempertimbangkan pendekatan Hybrid CBF dengan Collaborative Filtering guna meningkatkan nilai Precision.

## Referensi

- [1] D. Roy and M. Dutta, "A Systematic Review and Research Perspective on Recommender Systems," *Journal of Big Data*, Vol. 9, No. 1, Article 59, 2022, DOI: 10.1186/s40537-022-00592-5.
- [2] M. Shevchenko, "An Analytical Review of Content-based and Collaborative Filtering in Recommender Systems," *Advanced Information Technology*, Vol. 1, No. 4, 2025, DOI: 10.17721/AIT.2025.1.07.
- [3] S. Salloum and D. Rajamanthri, "Implementation and Evaluation of Movie Recommender Systems using Collaborative Filtering," *Journal of Advances in Information Technology*, Vol. 12, No. 3, pp. 189–196, Aug. 2021, DOI: 10.12720/jait.12.3.189-196.
- [4] H. Zhang, M. Gan, and X. Sun, "POI Recommendation Scheme based on User Activity Patterns and Category Similarity," *Applied Sciences*, Vol. 14, No. 23, p. 10997, 2024, DOI: 10.3390/app142310997.
- [5] P. Lops, M. de Gemmis, and G. Semeraro, "Content-based Recommender Systems: State of the Art and Trends," in *Recommender Systems Handbook*, F. Ricci, L. Rokach, B. Shapira, and P. B. Kantor, Eds., Springer, New York, NY, USA, 2011, pp. 73–105.
- [6] Y. Zheng, "Location-based Social Networks: Users," in *Computing with Spatial Trajectories*, Y. Zheng and X. Zhou, Eds., Springer, New York, NY, USA, 2011, pp. 243–276.
- [7] R. Baral and T. Li, "C-MHRS: Concept-based Mobile Hotel Recommendation System," in *Proc. 16th IEEE Int. Conf. Mobile Data Management (MDM)*, Pittsburgh, PA, USA, 2015, pp. 188–193.
- [8] E. Hasan, M. Rahman, C. Ding, J. X. Huang, and S. Raza, "Review-based Recommender Systems: A Survey of Approaches, Challenges and Future Perspectives," *ACM Computing Surveys*, Vol. 58, No. 1, Article 25, pp. 1–41, 2025, DOI: 10.1145/3742421.
- [9] Z. Xia, A. Sun, J. Xu, Y. Peng, R. Ma, and M. Cheng, "Contemporary Recommendation Systems on Big Data and Their Applications: A Survey," *IEEE Access*, Vol. 12, pp. 196914–196928, 2024, DOI: 10.1109/ACCESS.2024.3517492.
- [10] S. Raza, M. Rahman, S. Kamawal, A. Toroghi, A. Raval, F. Navah, and A. Kazemeini, "A Comprehensive Review of Recommender Systems: Transitioning from Theory to Practice," *Computer Science Review*, Vol. 59, p. 100849, 2026, DOI: 10.1016/j.cosrev.2025.100849.
- [11] S. Zhang, L. Yao, A. Sun, and Y. Tay, "Deep Learning based Recommender System: A Survey and New Perspectives," *ACM Computing Surveys*, Vol. 52, No. 1, pp. 1–38, Feb. 2019.
- [12] M. Fajriansyah, P. P. Adikara, and A. W. Widodo, "Sistem Rekomendasi Film menggunakan Content based Filtering," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK)*, Vol. 5, No. 6, pp. 2188–2199, 2021.
- [13] I. Naing, N. Funabiki, K. H. Wai, and S. T. Aung, "A Reference Paper Collection System using Web Scraping," *Electronics*, Vol. 13, No. 14, p. 2700, 2024, DOI: 10.3390/electronics13142700.
- [14] G. Salton and C. Buckley, "Term-Weighting Approaches in Automatic Text Retrieval," *Information Processing & Management*, Vol. 24, No. 5, pp. 513–523, 1988.
- [15] G. Salton and M. J. McGill, *Introduction to Modern Information Retrieval*, McGraw-Hill, New York, NY, USA, 1983.
- [16] M. N. Noori, J. Ahamed, and M. Ahmed, "Matrix Factorization and Cosine Similarity based Recommendation System For Cold Start Problem in E-Commerce Industries," *International Journal of Computing and Digital Systems*, Vol. 15, No. 1, pp. 775–787, 2024, DOI: 10.12785/ijcds/150156.
- [17] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl, "Evaluating Collaborative Filtering Recommender Systems," *ACM Transactions on Information Systems*, Vol. 22, No. 1, pp. 5–53, Jan. 2004.
- [18] S.-Y. Lim, N. Hashim, and L. L. Thanh, "Recommender Systems: A Comprehensive Review of Models, Approaches and Evaluation Metrics," *Journal of Informatics and Web Engineering*, Vol. 4, No. 3, pp. 166–190, Oct. 2025, DOI: 10.33093/jiwe.2025.4.3.10.
- [19] Ahmadian et al., "Hybrid Models for Emotion Classification and Sentiment Analysis in Indonesian Language," *Applied Computational Intelligence and Soft Computing*, Vol. 2024, <http://sistemasi.ftik.unisi.ac.id>

- Article 2826773, 2024, DOI: 10.1155/2024/2826773.
- [20] H. Salehi, M. Radman, and A. Selamat, "A Hybrid Recommender System Combining Collaborative and Content-based Filtering with Feature Weighting," *Multimedia Tools and Applications*, Vol. 81, No. 12, pp. 16997–17022, Mar. 2022.
  - [21] M. Jozani, C. Z. Liu, and K.-K. R. Choo, "An Empirical Study of Content-based Recommendation Systems in Mobile App Markets," *Decision Support Systems*, Vol. 169, p. 113954, 2023.
  - [22] P. Sánchez and A. Bellogín, "Point-of-Interest Recommender Systems based on Location-based Social Networks: A Survey from an Experimental Perspective," *ACM Computing Surveys*, Vol. 54, No. 11s, Article 223, Sep. 2022, DOI: 10.1145/3510409.
  - [23] N. Azizah and A. F. Rozi, "Sistem Rekomendasi Produk Somethinc menggunakan Metode Content-based Filtering," *Jurnal Teknologi Dan Sistem Informasi Bisnis*, Vol. 6, No. 3, pp. 461–468, Jul. 2024, DOI: 10.47233/jteksis.v6i3.1411.
  - [24] F. Fkih, "Similarity Measures for Collaborative Filtering-based Recommender Systems: Review and Experimental Comparison," *Journal of King Saud University - Computer and Information Sciences*, Vol. 34, No. 9, pp. 7645–7669, 2022, DOI: 10.1016/j.jksuci.2021.09.014.