

Rekomendasi Resep Masakan Menggunakan Metode *Content-Based Filtering* dan *Collaborative Filtering*

Dzaky Fadli Firmansyah¹, Rakha Asyraf², Khonif Zakaria³, Nauval Rizky Ramadhan⁴,
Suleiman Abdulsalam Mohamed Hussein Alnaham⁵, Panca Aziz Saputra⁶

^{1,2,3,4,5}Informatika, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto, Indonesia

⁶Informatika, Fakultas Teknik, Universitas Jenderal Soedirman, Indonesia

surrel: ¹zaaaaf1654@gmail.com, ²rasyraf7@gmail.com, ³oniefzk11@gmail.com, ⁴nauvalrizkyr13@gmail.com, ⁵salnaham95s@gmail.com,
⁶pancaaziz321@gmail.com

Info Artikel

Sejarah artikel:

Diterima 01-25-2026

Revisi 28-06-2026

Diterima 17-08-2026

Kata kunci:

Rekomendasi Resep
Content-Based Filtering
Collaborative Filtering
Implicit Feedback
TF-IDF

ABSTRAK

Pertumbuhan pesat platform kuliner digital telah menyebabkan kelebihan informasi yang menyulitkan pengguna untuk menemukan resep yang sesuai dengan preferensi mereka. Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi sistem rekomendasi resep dengan membandingkan metode Content-Based Filtering (CBF) dan Item-Based Collaborative Filtering (CF). Menggunakan dataset Food.com yang memuat lebih dari 230.000 resep dan 1,1 juta interaksi pengguna, sistem ini menerapkan TF-IDF untuk representasi teks dan memproses rating pengguna menjadi umpan balik implisit (implicit feedback). Kinerja kedua metode dievaluasi menggunakan metrik Precision@K, Recall@K, dan HitRate@K (K=50). Hasil penelitian menunjukkan bahwa Collaborative Filtering secara signifikan mengungguli Content-Based Filtering, dengan capaian HitRate@50 sebesar 0,1830 berbanding 0,0538 pada CBF. Meskipun CBF mampu memberikan relevansi semantik berdasarkan bahan dan tags, pendekatan CF terbukti lebih efektif dalam menangkap preferensi kolektif pengguna dalam skala data besar. Penelitian ini menyimpulkan bahwa Collaborative Filtering menawarkan akurasi yang lebih tinggi, sementara Content-Based Filtering tetap penting untuk mengatasi keterbatasan data interaksi awal serta melengkapi ekosistem rekomendasi.

Penulis yang sesuai:

Dzaky Fadli Firmansyah

Informatika, Fakultas Ilmu Komputer, Universitas Amikom Purwokerto

Email: zaaaaf1654@gmail.com

1. PENDAHULUAN

Perkembangan teknologi informasi dan meningkatnya penggunaan internet telah mendorong pertumbuhan pesat platform kuliner digital yang menyediakan ribuan hingga jutaan resep makanan[1]. Kondisi ini menimbulkan permasalahan *information overload*, di mana pengguna kesulitan menemukan resep yang

sesuai dengan preferensi dan kebutuhannya[2]. Sistem rekomendasi menjadi solusi penting untuk membantu pengguna dalam menyaring informasi dan memberikan saran resep yang relevan secara personal[3]. Dalam konteks ini, sistem rekomendasi resep makanan berperan sebagai alat bantu pengambilan keputusan yang mampu meningkatkan pengalaman pengguna serta efisiensi pencarian informasi kuliner.

Berbagai penelitian sebelumnya telah mengembangkan sistem rekomendasi resep masakan menggunakan pendekatan *Content-Based Filtering* (CBF), yaitu metode yang merekomendasikan item berdasarkan kemiripan karakteristik konten dengan preferensi pengguna[4]. Salah satu penelitian dilakukan oleh Vena Kurnia Sari *et al.* [5] yang membangun sistem rekomendasi resep masakan berbasis CBF dengan memanfaatkan data resep dari situs Cookpad, meliputi nama resep, bahan, durasi memasak, dan cara memasak. Representasi teks pada penelitian tersebut menggunakan teknik *text mining Term Frequency-Inverse Document Frequency* (TF-IDF) dan pengukuran kemiripan menggunakan *cosine similarity* untuk menentukan tingkat relevansi antara input pengguna dan data resep yang tersedia[5].

Di sisi lain, pendekatan *Collaborative Filtering* (CF) memanfaatkan interaksi historis pengguna, seperti rating atau riwayat penggunaan, untuk menemukan pola kesamaan antar pengguna atau antar item[3]. Metode ini terbukti efektif dalam menangkap preferensi kolektif, namun memiliki kendala seperti *cold-start problem* dan ketergantungan pada ketersediaan data pengguna[6]. Beberapa penelitian terdahulu pada sistem rekomendasi resep masih menunjukkan keterbatasan, antara lain penggunaan dataset yang sangat kecil (± 10 resep), belum diterapkannya metrik evaluasi kuantitatif seperti *precision* dan *recall*, serta belum adanya integrasi preferensi kolektif pengguna dalam proses rekomendasi[5].

Berdasarkan keterbatasan tersebut, penelitian ini mengusulkan pendekatan sistem rekomendasi resep yang mengombinasikan *Content-Based Filtering* dan *Collaborative Filtering* untuk menghasilkan rekomendasi yang lebih akurat dan relevan[7]. Sistem yang diusulkan memanfaatkan dataset resep dalam jumlah dan variasi yang lebih besar, serta menambahkan data interaksi pengguna sebagai dasar pembentukan preferensi kolektif[8]. Pendekatan hibrida ini diharapkan mampu mengatasi kelemahan masing-masing metode ketika digunakan secara tunggal, khususnya dalam meningkatkan kualitas personalisasi rekomendasi.

Selain itu, kualitas sistem rekomendasi dalam penelitian ini dievaluasi menggunakan metrik *precision* dan *recall*[9], yang memberikan gambaran kuantitatif mengenai tingkat relevansi rekomendasi yang dihasilkan[10]. Penggunaan metrik evaluasi ini menjadi penting untuk menilai performa model secara objektif dan terukur, serta memungkinkan perbandingan dengan penelitian sebelumnya[11]. Dengan demikian, sistem yang dikembangkan tidak hanya dinilai dari sisi fungsionalitas, tetapi juga dari sisi kinerja dan akurasi rekomendasi.

Nilai kebaruan dari penelitian ini terletak pada integrasi pendekatan CBF dan CF dalam domain rekomendasi resep makanan dengan dataset yang lebih besar, evaluasi menggunakan metrik *precision* dan *recall*, serta pemanfaatan preferensi kolektif pengguna. Inovasi ini diharapkan dapat memberikan kontribusi bagi pengembangan sistem rekomendasi di bidang kuliner digital dan menjadi referensi bagi penelitian selanjutnya dalam pengembangan sistem rekomendasi berbasis data yang lebih komprehensif dan adaptif.


2. METODE

Metode yang diterapkan dalam penelitian ini terdiri atas beberapa tahapan utama. Tahap awal dimulai dengan pengumpulan dataset yang diperoleh dari platform Kaggle, yaitu Food.com Recipes and Interactions. Dataset tersebut kemudian melalui proses transformasi dan praproses data agar siap digunakan dalam pemodelan sistem rekomendasi, yang mencakup pembersihan data, perubahan rating eksplisit menjadi implicit feedback, serta pembagian data latih dan data uji berbasis waktu.

Tahap selanjutnya adalah perhitungan tingkat kemiripan menggunakan dua pendekatan sistem rekomendasi, yaitu *Content-Based Filtering* dan *Collaborative Filtering*. Pada pendekatan *Content-Based Filtering*, kemiripan antar resep dihitung melalui representasi vektor TF-IDF dan pengukuran *cosine similarity*. Sementara itu, pendekatan *Collaborative Filtering* menggunakan metode item-based dengan menilai kesamaan pola interaksi pengguna terhadap resep.

Hasil perhitungan kemiripan digunakan untuk memperoleh skor prediksi yang selanjutnya dijadikan dasar dalam menentukan peringkat rekomendasi resep bagi pengguna. Kinerja sistem kemudian diuji dan

dievaluasi dengan membandingkan hasil rekomendasi terhadap data uji menggunakan metrik Precision@K, Recall@K, dan HitRate@K guna mengukur relevansi, cakupan, serta keberhasilan sistem dalam menghasilkan rekomendasi sesuai preferensi pengguna. Seluruh rangkaian proses tersebut dirangkum dalam bentuk alur penelitian yang menggambarkan tahapan mulai dari pengambilan dataset hingga evaluasi sistem, sebagaimana ditunjukkan pada gambar berikut.



Gambar 2.1. Alur Penelitian

2.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini diperoleh dari platform Kaggle yang bersumber dari Food.com. Dataset yang digunakan terdiri atas dua bagian, yaitu dataset recipes yang berisi informasi resep masakan dan dataset interactions yang merepresentasikan interaksi pengguna terhadap resep.

2.2. Preprocessing Data

Tahap preprocessing data dilakukan untuk memastikan data yang digunakan dalam penelitian berada dalam kondisi bersih, relevan, dan sesuai dengan kebutuhan sistem rekomendasi yang dikembangkan. Proses ini mencakup pembersihan data, transformasi interaksi pengguna menjadi implicit feedback, penyaringan pengguna dan item, pengolahan teks untuk representasi konten, serta pembagian data latih dan data uji secara berbasis waktu.

Data cleaning dilakukan pada dataset interaksi dengan menghapus data yang memiliki nilai kosong pada atribut penting, yaitu identitas pengguna, identitas resep, nilai rating, dan waktu interaksi. Selanjutnya, dilakukan penyeragaman tipe data dengan mengonversi atribut identitas menjadi bilangan bulat serta atribut waktu menjadi format datetime. Tahap ini bertujuan untuk mencegah inkonsistensi data dan kesalahan pemrosesan pada tahap selanjutnya.

Transformasi implicit feedback dilakukan dengan mengubah rating eksplisit menjadi representasi biner. Interaksi dengan nilai rating yang memenuhi atau melebihi ambang batas tertentu dianggap sebagai indikasi ketertarikan pengguna terhadap item, sedangkan interaksi di bawah ambang batas tersebut tidak dipertimbangkan. Pendekatan ini digunakan untuk menyederhanakan data interaksi dan menyesuaikannya dengan karakteristik sistem rekomendasi berbasis implicit feedback.

Penyaringan pengguna dan item dilakukan untuk meningkatkan kualitas data dan mengurangi noise. Pengguna yang memiliki jumlah interaksi positif di bawah batas minimum dikeluarkan dari dataset karena dianggap tidak memiliki informasi preferensi yang cukup. Selain itu, dilakukan pembatasan jumlah item berdasarkan tingkat popularitasnya untuk memastikan bahwa hanya item dengan tingkat interaksi yang memadai yang digunakan dalam proses pemodelan. Langkah ini juga membantu mengendalikan kompleksitas komputasi.

Text preprocessing diterapkan pada data konten resep yang digunakan dalam pendekatan content-based filtering. Atribut teks seperti nama resep, tag, bahan, dan deskripsi diproses dengan cara mengonversi struktur list menjadi teks, menggabungkan seluruh atribut menjadi satu representasi teks, serta melakukan normalisasi huruf menjadi huruf kecil. Proses ini bertujuan untuk menghasilkan representasi teks yang konsisten dan siap digunakan pada tahap ekstraksi fitur.

Pembagian data latih dan data uji dilakukan secara time-aware dengan mempertimbangkan urutan waktu interaksi setiap pengguna. Interaksi yang lebih lama digunakan sebagai data latih, sedangkan interaksi terbaru digunakan sebagai data uji. Pendekatan ini dipilih untuk mensimulasikan kondisi penggunaan sistem rekomendasi di dunia nyata, di mana model dilatih menggunakan data historis dan dievaluasi berdasarkan prediksi terhadap interaksi di masa mendatang.

2.3. Content-Based Filtering

Content-Based Filtering merupakan salah satu pendekatan dalam sistem rekomendasi yang memanfaatkan riwayat aktivitas pengguna untuk mengenali kecenderungan atau pola minat. Metode ini bekerja dengan menganalisis preferensi pengguna yang telah terbentuk sebelumnya, kemudian membangun suatu model yang digunakan untuk mencocokkan karakteristik atau atribut item sehingga rekomendasi yang dihasilkan sesuai dengan minat pengguna [12].

2.4. Collaborative Filtering

Collaborative filtering merupakan metode dalam sistem rekomendasi yang melakukan prediksi dengan memanfaatkan opini dan riwayat preferensi pengguna lain untuk menentukan item yang berpotensi disukai oleh seorang pengguna. Metode ini memiliki kelebihan karena tetap mampu memberikan rekomendasi meskipun konten item sulit dianalisis, namun juga memiliki kelemahan, yaitu tidak dapat menghasilkan rekomendasi ketika belum tersedia penilaian terhadap item yang direkomendasikan serta berpotensi menghasilkan tingkat akurasi yang rendah apabila jumlah data yang digunakan masih terbatas [13].

2.5. Evaluasi

Evaluasi kinerja sistem rekomendasi pada penelitian ini dilakukan untuk mengukur sejauh mana metode Content-Based Filtering dan Collaborative Filtering mampu menghasilkan rekomendasi resep yang relevan sesuai dengan preferensi pengguna. Proses evaluasi dilakukan dengan membandingkan daftar rekomendasi yang dihasilkan sistem terhadap data uji (test set) yang merepresentasikan interaksi aktual pengguna di masa mendatang. Evaluasi difokuskan pada skenario top-K recommendation, di mana sistem memberikan sejumlah K rekomendasi teratas kepada setiap pengguna.

Metode evaluasi yang digunakan dalam penelitian ini meliputi Precision@K, Recall@K, dan HitRate@K. Ketiga metrik tersebut dipilih karena umum digunakan dalam penelitian sistem rekomendasi berbasis implicit feedback dan mampu memberikan gambaran menyeluruh mengenai kualitas rekomendasi dari sisi ketepatan, cakupan, dan keberhasilan sistem.

Precision@K digunakan untuk menilai tingkat ketepatan sistem dalam menyajikan rekomendasi yang relevan kepada pengguna berdasarkan daftar rekomendasi top-K yang dihasilkan.

$$\text{Precision@K} = \frac{\text{Relevant items in Top-K}}{K} \quad (1)$$

Recall@K digunakan untuk menilai sejauh mana sistem mampu menjangkau dan menemukan seluruh item yang relevan bagi pengguna dalam daftar rekomendasi top-K [14].

$$\text{Recall@K} = \frac{\text{Relevant items in Top-K}}{\text{Total relevant items}} \quad (2)$$

HitRate@K (HR@K) merupakan metrik yang digunakan untuk mengukur persentase pengguna yang memperoleh setidaknya satu item relevan dalam daftar rekomendasi top-K, dengan K sebagai bilangan positif. Metrik ini menilai jumlah item yang perlu direkomendasikan agar pengguna dapat menemukan minimal satu item yang sesuai dengan preferensinya. Tujuan utama pengukuran HR@K adalah memperoleh nilai yang tinggi pada K yang relatif kecil, karena semakin besar nilai K maka daftar rekomendasi akan semakin panjang dan secara alami meningkatkan peluang munculnya item relevan [15].

Evaluasi diterapkan pada seluruh pengguna yang memenuhi syarat pengujian dengan nilai K ditetapkan sebesar 50. Nilai akhir Precision@K, Recall@K, dan HitRate@K diperoleh dari hasil perhitungan rata-rata seluruh pengguna yang diuji. Hasil pengukuran tersebut kemudian dimanfaatkan untuk membandingkan kinerja metode *Content-Based Filtering* dan *Collaborative Filtering* dalam menghasilkan rekomendasi resep yang sesuai dengan preferensi pengguna.

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan Google Colaboratory sebagai platform pengembangan sistem rekomendasi resep masakan dengan menerapkan metode Content-Based Filtering dan Collaborative Filtering. Kinerja kedua metode tersebut dievaluasi menggunakan metrik Precision, Recall, dan HitRate, serta diuji pada pengguna baru.

3.1. Dataset

Penelitian ini menggunakan dataset Food.com Recipes and Interactions yang terdiri dari dua berkas utama, yaitu dataset resep dan dataset interaksi pengguna. Dataset resep menyediakan informasi deskriptif mengenai setiap resep, sedangkan dataset interaksi merepresentasikan hubungan antara pengguna dan resep melalui aktivitas pemberian rating. Kedua dataset ini saling melengkapi dan menjadi fondasi utama dalam pembangunan sistem rekomendasi berbasis content based filtering dan collaborative filtering.

Dataset resep memuat 231.637 entri resep yang mencakup atribut seperti recipe_id, nama resep, tags, deskripsi, serta bahan masakan. Informasi ini dimanfaatkan sebagai sumber fitur tekstual dalam proses ekstraksi karakteristik resep menggunakan pendekatan TF-IDF. Contoh sebagian data pada dataset resep ditampilkan pada Tabel 1 untuk memberikan gambaran struktur dan isi data yang digunakan.

Tabel 1. Dataset Recipes

recipe_id	name	tags
137739	arriba baked winter squash mexican style	['60-minutes-or-less', 'time-to-make', 'course', 'main-ingredient', 'cuisine', 'preparation', 'occasion', 'north-american', 'side-dishes', 'vegetables', 'mexican', 'easy', 'fall', 'holiday-event', 'vegetarian', 'winter', 'dietary', 'christmas', 'seasonal', 'squash']
31490	a bit different breakfast pizza	['30-minutes-or-less', 'time-to-make', 'course', 'main-ingredient', 'cuisine', 'preparation', 'occasion', 'north-american', 'breakfast', 'main-dish', 'pork', 'american', 'oven', 'easy', 'kid-friendly', 'pizza', 'dietary',
112140	all in the kitchen chili	['time-to-make', 'course', 'preparation', 'main-dish', 'chili', 'crock-pot-slow-cooker', 'dietary', 'equipment', '4-hours-or-less']
44061	amish tomato ketchup for canning	['weeknight', 'time-to-make', 'course', 'main-ingredient', 'cuisine', 'preparation', 'occasion', 'north-american', 'canning', 'condiments-etc', 'vegetables', 'american', 'heirloom-historical', 'holiday-event', 'vegetarian', 'dietary', 'amish-mennonite', 'northeastern-united-states', 'number-of-servings', 'technique', '4-hours-or-less']

Berdasarkan Tabel 1, dapat dilihat bahwa setiap resep memiliki sekumpulan tags yang merepresentasikan karakteristik resep, seperti jenis masakan, bahan utama, teknik memasak, hingga kategori diet. Informasi tersebut berperan penting dalam mengukur kesamaan antar resep pada metode content based filtering.

Selain dataset resep, penelitian ini juga menggunakan dataset interaksi yang berisi 1.132.367 catatan interaksi pengguna terhadap resep. Dataset ini mencakup atribut user_id, recipe_id, rating, liked, dan tanggal interaksi (date). Dataset interaksi digunakan untuk merepresentasikan preferensi pengguna dan membangun matriks interaksi pada metode collaborative filtering. Contoh dataset interaksi ditunjukkan pada Tabel 2.

Tabel 2. Dataset Interactions

user_id	recipe_id	rating	liked	date
38094	40893	4	1	2003-02-17



1293707	40893	5	1	2011-12-21
8937	44394	4	1	2002-12-01
126440	85009	5	1	2010-02-27
57222	85009	5	1	2011-10-01

Dataset interaksi merepresentasikan perilaku pengguna dalam memberikan penilaian terhadap resep. Nilai rating digunakan sebagai dasar pembentukan implicit feedback, dengan asumsi bahwa rating yang tinggi mencerminkan preferensi positif pengguna terhadap suatu resep. Dataset ini dipilih karena memiliki skala besar serta karakteristik yang sesuai untuk eksperimen sistem rekomendasi berbasis konten maupun kolaboratif.

Setelah dilakukan proses penyaringan dan penyesuaian sesuai kebutuhan eksperimen, jumlah resep yang digunakan dibatasi menjadi 50.000 item paling populer. Sementara itu, jumlah pengguna yang memenuhi kriteria evaluasi adalah sebanyak 5.966 pengguna.

3.2. Preprocessing Data

Tahapan preprocessing dilakukan untuk memastikan kualitas data serta kesesuaiannya dengan pendekatan sistem rekomendasi yang digunakan. Langkah pertama adalah pembersihan data dengan menghapus entri interaksi yang memiliki nilai kosong pada atribut penting, seperti `user_id`, `recipe_id`, `rating`, dan `date`. Seluruh atribut kemudian dikonversi ke tipe data yang sesuai, termasuk konversi tanggal ke format `datetime`.

Selanjutnya, sistem menerapkan pendekatan implicit feedback dengan mendefinisikan interaksi sebagai “like” apabila rating yang diberikan pengguna bernilai 4 atau lebih. Interaksi dengan rating di bawah ambang batas tersebut tidak digunakan dalam proses pelatihan maupun evaluasi. Pendekatan ini bertujuan untuk memfokuskan sistem pada sinyal preferensi positif yang lebih stabil dibandingkan dengan rating eksplisit penuh.

Untuk meningkatkan reliabilitas evaluasi, dilakukan seleksi pengguna berdasarkan jumlah minimal interaksi positif. Pengguna yang memiliki kurang dari 20 interaksi like dieliminasi dari dataset. Selain itu, dilakukan pembagian data latih dan data uji secara *time-aware* untuk setiap pengguna, yaitu interaksi yang lebih lama digunakan sebagai data latih, sedangkan interaksi terbaru digunakan sebagai data uji. Proporsi data uji ditetapkan sebesar 20 persen dengan batas minimum jumlah interaksi pada masing-masing subset.

Pada sisi konten, atribut teks dari setiap resep dibentuk dengan menggabungkan nama resep, tag, bahan, dan deskripsi. Seluruh teks dinormalisasi ke huruf kecil dan diproses menggunakan TF-IDF untuk membangun representasi vektor konten resep.

3.3. Penerapan Metode Filtering

Penelitian ini menerapkan dua pendekatan utama dalam sistem rekomendasi, yaitu Content-Based Filtering dan Collaborative Filtering berbasis item. Kedua metode digunakan untuk mengevaluasi efektivitas pendekatan berbasis konten dan pendekatan berbasis pola kolektif pengguna dalam konteks dataset berskala besar dengan implicit feedback.

Pada pendekatan Content-Based Filtering, sistem merepresentasikan setiap resep sebagai vektor fitur menggunakan metode TF-IDF. Fitur teks dibentuk dari penggabungan atribut nama resep, tag, bahan, dan deskripsi. Profil pengguna kemudian dibangun sebagai agregasi vektor dari resep-resep yang pernah disukai oleh pengguna pada data latih. Untuk meningkatkan relevansi terhadap minat terbaru, profil pengguna tidak dihitung secara rata-rata, melainkan menggunakan pembobotan berbasis waktu. Interaksi yang lebih baru diberikan bobot lebih besar menggunakan fungsi peluruhan eksponensial berdasarkan urutan waktu interaksi.

Pendekatan Collaborative Filtering yang digunakan bersifat item-based. Metode ini menghitung kemiripan antaritem berdasarkan kesamaan pola pengguna yang menyukai item tersebut. Matriks item-pengguna dibentuk dari data latih dan dinormalisasi untuk memastikan kontribusi setiap item tetap seimbang. Dalam proses rekomendasi, item yang pernah disukai pengguna digabungkan untuk membentuk vektor preferensi, yang selanjutnya digunakan untuk menghitung skor kemiripan terhadap item lain. Sama seperti pada pendekatan berbasis konten, bobot interaksi terbaru turut diperhitungkan agar rekomendasi lebih adaptif terhadap perubahan preferensi pengguna.

Untuk mengatasi kondisi keterbatasan riwayat interaksi pengguna, sistem menyediakan mekanisme fallback berupa rekomendasi item populer. Rekomendasi ini digunakan ketika pengguna tidak memiliki jumlah interaksi yang memadai pada data latih, sehingga sistem tetap dapat menghasilkan rekomendasi yang relevan.

Dengan menerapkan kedua metode filtering tersebut, sistem rekomendasi tidak hanya mampu menangkap kesamaan konten antar resep, tetapi juga memanfaatkan informasi kolektif dari perilaku pengguna lain. Pendekatan ini memungkinkan analisis perbandingan kinerja antara Content-Based Filtering dan Collaborative Filtering dalam menghasilkan rekomendasi yang relevan..

3.4. Evaluasi Kinerja Sistem Rekomendasi

Evaluasi kinerja sistem dilakukan menggunakan metrik Precision@K, Recall@K, dan HitRate@K dengan nilai K sebesar 50. Evaluasi ini diterapkan pada 5.966 pengguna yang memiliki data uji valid. Precision@K mengukur proporsi rekomendasi yang relevan, Recall@K mengukur cakupan item relevan yang berhasil direkomendasikan, sedangkan HitRate@K mengukur probabilitas sistem dalam menghasilkan setidaknya satu rekomendasi yang relevan.

Hasil evaluasi menunjukkan bahwa pendekatan Content-Based Filtering memperoleh nilai Precision@50 sebesar 0,00129, Recall@50 sebesar 0,00596, dan HitRate@50 sebesar 0,0538. Nilai tersebut mengindikasikan bahwa pendekatan berbasis konten memiliki keterbatasan dalam menangkap preferensi pengguna yang bersifat kompleks, terutama pada dataset dengan tingkat keragaman konten yang tinggi.

Sebaliknya, pendekatan Collaborative Filtering menunjukkan kinerja yang lebih baik dengan nilai Precision@50 sebesar 0,00537, Recall@50 sebesar 0,02421, dan HitRate@50 sebesar 0,1830. Peningkatan yang signifikan pada seluruh metrik menunjukkan bahwa pemanfaatan informasi kolektif antar pengguna mampu meningkatkan relevansi rekomendasi secara keseluruhan.

Secara keseluruhan, hasil evaluasi mengonfirmasi bahwa pendekatan Collaborative Filtering lebih efektif pada skenario dataset berskala besar dengan implicit feedback. Sementara itu, Content-Based Filtering tetap berperan sebagai solusi pelengkap, khususnya pada kondisi keterbatasan atau ketiadaan riwayat interaksi pengguna.

3.5. Contoh Rekomendasi pada Satu Pengguna

Untuk memberikan gambaran konkret mengenai cara kerja sistem rekomendasi, dilakukan demonstrasi hasil rekomendasi pada satu pengguna yang termasuk dalam kelompok eligible user. Pengguna yang dipilih memiliki user_id 1533 dengan indeks pengguna 0 pada data latih.

Sebagai dasar pembentukan profil pengguna, digunakan riwayat interaksi positif pada data latih yang telah diurutkan berdasarkan waktu interaksi terbaru. Dua puluh interaksi terakhir digunakan sebagai representasi preferensi pengguna, dengan penerapan pembobotan berbasis waktu (recency weighting). Ringkasan sebagian riwayat interaksi pengguna tersebut ditunjukkan pada Tabel 3.

Tabel 3. Riwayat interaksi pengguna dengan pemobotan berbasis waktu

index	recipe_id	name	date	rating	recency_rank	weight
0	14750	potatoes again	2005-05-18	5	0	1.000000
1	81473	broccoli with cheddar vinaigrette	2005-05-12	5	1	0.977160
2	13813	pumpkin upside down cake	2005-05-05	5	2	0.954842
3	110139	chicken fried rice oamc	2005-05-05	5	3	0.933033
4	113227	onion patties	2005-04-22	5	4	0.911722

Berdasarkan data latih tersebut, pengguna memiliki riwayat interaksi positif yang cukup beragam, dengan dominasi resep berbahan dasar kentang, ayam, dan sayuran. Interaksi disusun berdasarkan urutan waktu terbaru, di mana interaksi paling baru diberikan bobot tertinggi, sedangkan interaksi yang lebih lama mengalami penurunan bobot secara eksponensial. Hal ini tercermin dari nilai bobot (weight) yang menurun seiring bertambahnya nilai recency rank, meskipun seluruh interaksi memiliki nilai rating yang tinggi.



Penerapan pembobotan berbasis waktu ini bertujuan untuk memastikan bahwa preferensi terbaru pengguna memberikan kontribusi yang lebih besar dalam proses pembentukan profil pengguna. Dengan demikian, profil pengguna yang terbentuk tidak hanya merepresentasikan kesukaan historis, tetapi juga mencerminkan minat terkini pengguna.

Berdasarkan profil pengguna tersebut, sistem kemudian menghasilkan rekomendasi menggunakan pendekatan Content-Based Filtering. Daftar rekomendasi Top-10 yang dihasilkan ditampilkan pada Tabel 4.

Tabel 4. Hasil Rekomendasi dari Content-Based Filtering

index	recipe_id	name	score
0	17415	chicken mashed potatoes	0.160724
1	26398	zesty baked fries	0.160688
2	56376	baked tomato	0.158325
3	16393	comfort potatoes for the waistline	0.157725
4	2462	home fried potatoes	0.152776
5	10837	fresh tomato spaghetti sauce	0.152635
6	253670	the best potato wedges on here	0.152370
7	22829	authentic italian spaghetti sauce	0.150622
8	341023	stuffed baby red potatoes	0.150585
9	4368	garlic mashed potatoes iii	0.149379

Hasil rekomendasi Top-10 dari pendekatan Content-Based Filtering menunjukkan bahwa sistem merekomendasikan resep yang memiliki tingkat kemiripan konten tinggi dengan riwayat interaksi pengguna. Rekomendasi didominasi oleh resep berbasis kentang dan olahan sederhana, seperti mashed potatoes, baked fries, dan potato wedges. Nilai skor kemiripan TF-IDF yang relatif berdekatan mengindikasikan bahwa item rekomendasi memiliki kedekatan semantik yang konsisten dengan preferensi pengguna.

Selanjutnya, sistem juga menghasilkan rekomendasi menggunakan pendekatan Collaborative Filtering berbasis item. Daftar rekomendasi Top-10 yang dihasilkan ditampilkan pada Tabel 5.

Tabel 5. Hasil Rekomendasi dari Collaborative Filtering

index	recipe_id	name	score
0	211506	thai style burgers	0.130446
1	116388	fantastic apricot cold chicken	0.125930
2	59290	shrimp and cheddar patties	0.122878
3	116406	fish burgers with a herb sauce	0.121930
4	61742	sauteed greens with lemon	0.119650
5	55631	couscous fruity salad	0.117271
6	150380	balsamic basil carrots	0.116510
7	211554	fruitful bran muffins	0.116479
8	12345	tomato pasta salad	0.114023
9	116436	oven baked potato wedges	0.113610

Pada pendekatan Collaborative Filtering berbasis item, sistem menghasilkan rekomendasi yang juga relevan dengan preferensi pengguna. Hal ini menunjukkan bahwa pola interaksi pengguna lain yang menyukai resep serupa turut berkontribusi dalam menentukan rekomendasi. Kemunculan beberapa resep berbahan kentang dan sayuran pada hasil rekomendasi mengindikasikan adanya keselarasan antara preferensi konten pengguna dan pola kolektif pengguna lain.

Contoh ini memperlihatkan bahwa sistem rekomendasi mampu memanfaatkan riwayat interaksi pengguna secara efektif. Selain itu, penerapan recency weighting terbukti berperan dalam menyesuaikan rekomendasi terhadap minat terbaru pengguna. Demonstrasi ini sekaligus mendukung hasil evaluasi kuantitatif pada subbab sebelumnya, yang menunjukkan kinerja sistem yang lebih unggul pada pendekatan Collaborative Filtering.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem rekomendasi resep masakan dengan menerapkan metode Content-Based Filtering dan Collaborative Filtering menggunakan dataset Food.com Recipes and Interactions. Tujuan penelitian untuk menghasilkan rekomendasi resep yang relevan berdasarkan preferensi pengguna dapat tercapai, sebagaimana ditunjukkan pada hasil evaluasi kinerja sistem.

Berdasarkan pengujian menggunakan metrik Precision@K, Recall@K, dan HitRate@K, metode Collaborative Filtering berbasis item menunjukkan kinerja yang lebih baik dibandingkan Content-Based Filtering. Hal ini membuktikan bahwa pemanfaatan pola preferensi kolektif pengguna mampu meningkatkan relevansi rekomendasi pada dataset berskala besar dengan pendekatan implicit feedback. Sementara itu, Content-Based Filtering tetap memiliki peran penting, khususnya dalam kondisi keterbatasan riwayat interaksi pengguna.

Hasil penelitian ini menunjukkan kesesuaian antara tujuan penelitian yang dirumuskan pada bagian pendahuluan dengan hasil dan pembahasan yang diperoleh. Sistem yang dikembangkan tidak hanya mampu memberikan rekomendasi secara personal, tetapi juga dievaluasi secara kuantitatif sehingga kinerjanya dapat diukur secara objektif.

Sebagai pengembangan lanjutan, penelitian selanjutnya dapat mengimplementasikan pendekatan hybrid yang menggabungkan Content-Based Filtering dan Collaborative Filtering secara langsung, serta mengeksplorasi metode berbasis pembelajaran mesin lanjutan untuk meningkatkan akurasi dan adaptivitas sistem rekomendasi resep masakan.

REFERENSI

- [1] Y. Wu, K. Ono, dan M. Watanabe, "OPTIMIZING USER EXPERIENCE OF OLDER ADULTS ON ONLINE RECIPE SHARING PLATFORMS".
- [2] J.-C. Zhang, A. M. Zain, K.-Q. Zhou, X. Chen, dan R.-M. Zhang, "A review of recommender systems based on knowledge graph embedding," *Expert Syst. Appl.*, vol. 250, hlm. 123876, Sep 2024, doi: 10.1016/j.eswa.2024.123876.
- [3] H. Papadakis, A. Papagrigoriou, C. Panagiotakis, E. Kosmas, dan P. Fragopoulou, "Collaborative filtering recommender systems taxonomy," *Knowl. Inf. Syst.*, vol. 64, no. 1, hlm. 35–74, Jan 2022, doi: 10.1007/s10115-021-01628-7.
- [4] S. Bangale, A. Haspe, B. Khemani, dan S. Malave, "Recipe Recommendation System Using Content-Based Filtering," *SSRN Electron. J.*, 2022, doi: 10.2139/ssrn.4102283.
- [5] V. Kurnia Sari, D. Hartanti, dan E. Purwanto, "Sistem Rekomendasi Resep Masakan Menggunakan Metode Content Based Filtering Berdasarkan Preferensi Pengguna," *Infotek J. Inform. Dan Teknol.*, vol. 8, no. 2, hlm. 345–355, Jul 2025, doi: 10.29408/jit.v8i2.30625.
- [6] J. Guan, B. Chen, dan S. Yu, "A hybrid similarity model for mitigating the cold-start problem of collaborative filtering in sparse data," *Expert Syst. Appl.*, vol. 249, hlm. 123700, Sep 2024, doi: 10.1016/j.eswa.2024.123700.
- [7] R. Widayanti, "Improving Recommender Systems using Hybrid Techniques of Collaborative Filtering and Content-Based Filtering," *J. Appl. Data Sci.*, vol. 4, no. 3, hlm. 289–302, Sep 2023, doi: 10.47738/jads.v4i3.115.
- [8] G. Adomavicius dan J. Zhang, "Impact of data characteristics on recommender systems performance," *ACM Trans. Manag. Inf. Syst.*, vol. 3, no. 1, hlm. 1–17, Apr 2012, doi: 10.1145/2151163.2151166.
- [9] A. Bellogin, P. Castells, dan I. Cantador, "Precision-oriented evaluation of recommender systems: an algorithmic comparison," dalam *Proceedings of the fifth ACM conference on Recommender systems*, Chicago Illinois USA: ACM, Okt 2011, hlm. 333–336. doi: 10.1145/2043932.2043996.
- [10] M. Erdt, A. Fernandez, dan C. Rensing, "Evaluating Recommender Systems for Technology Enhanced Learning: A Quantitative Survey," *IEEE Trans. Learn. Technol.*, vol. 8, no. 4, hlm. 326–344, Okt 2015, doi: 10.1109/TLT.2015.2438867.
- [11] F. Fouss dan M. Saelens, "Evaluating Performance of Recommender Systems: An Experimental Comparison," dalam *2008 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology*, Sydney, Australia: IEEE, Des 2008, hlm. 735–738. doi: 10.1109/WIAT.2008.252.
- [12] R. Ardiansyah, M. Ari Bianto, dan B. D. Saputra, "Sistem Rekomendasi Buku Perpustakaan Sekolah menggunakan Metode Content-Based Filtering," *J. CoSciTech Comput. Sci. Inf. Technol.*, vol. 4, no. 2, hlm. 510–518, Okt 2023, doi: 10.37859/coscitech.v4i2.5131.
- [13] H. Hartatik, S. D. Nurhayati, dan W. Widayani, "Sistem Rekomendasi Wisata Kuliner di Yogyakarta dengan Metode Item-Based Collaborative Filtering," *J. Autom. Comput. Inf. Syst.*, vol. 1, no. 2, hlm. 55–63, Nov 2021, doi: 10.47134/jacis.v1i2.8.
- [14] A. R. Hanum, E. S. Pramukantoro, dan D. P. Kartikasari, "STUDI PERBANDINGAN KINERJA TF-IDF DAN INDOBERT UNTUK REKOMENDASI RESEP BERDASARKAN KETERSEDIAAN BAHAN MAKANAN BERBASIS WEBSITE".
- [15] M. K. Najafabadi, R.-A. Chen, J. Rezazadeh, A. Beheshti, dan N. Shabani, "From theory to practice: The evolution and comparative analysis of homogeneous vs. heterogeneous Graph Neural Networks in recommender systems," *Neurocomputing*, vol. 624, hlm. 129446, Apr 2025, doi: 10.1016/j.neucom.2025.129446.

