

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori


2.1.1 *Information Overload* pada e-Commerce

Information overload merupakan kondisi ketika konsumen mengalami kesulitan dalam mengambil keputusan karena jumlah informasi atau pilihan yang tersedia melebihi kapasitas kognitif yang dimiliki (Lv and Liu, 2022; Qiu *et al.*, 2025). Dalam konteks e-commerce, kondisi ini semakin sering terjadi karena platform menyediakan ribuan hingga jutaan produk yang dapat diakses secara bersamaan oleh pengguna. Penelitian oleh Lv dan Liu (2022) menunjukkan bahwa *information overload* tidak hanya memperlambat proses pengambilan keputusan, tetapi juga dapat meningkatkan kecenderungan konsumen untuk mengembalikan produk (*consumer return intention*). Hal ini disebabkan oleh kelelahan dalam berpikir saat memilih produk (*decision fatigue*) serta beban kognitif yang tinggi (*cognitive burden*) yang dialami pengguna.

Untuk mengatasi permasalahan tersebut, sistem rekomendasi berperan sebagai solusi yang membantu pengguna menyaring informasi dengan menampilkan sebagian kecil produk yang dianggap relevan, sehingga pengguna tidak perlu menelusuri seluruh pilihan yang tersedia. Dengan demikian, sistem rekomendasi berkontribusi dalam mempercepat proses pengambilan keputusan dan meningkatkan kenyamanan pengalaman berbelanja pengguna (Isinkaye, Folajimi and Ojokoh, 2015; Abdul Hussien, Rahma and Abdul Wahab, 2021).

2.1.2 Sistem Rekomendasi

Sistem rekomendasi adalah sistem yang digunakan untuk memberikan saran produk atau item yang relevan kepada pengguna dari sejumlah besar pilihan yang tersedia (Pazzani and Billsus, 2007; Isinkaye, Folajimi and Ojokoh, 2015). Sistem ini bekerja dengan memanfaatkan data yang tersedia, baik berupa karakteristik produk maupun informasi perilaku pengguna, untuk menghasilkan rekomendasi yang relevan bagi setiap individu (Abdul Hussien, Rahma and Abdul Wahab, 2021).



Gambar 2. 1 Taksonomi Sistem Rekomendasi

(Sumber: Sharaf *et al.*, 2022)

Berdasarkan pendekatannya, sistem rekomendasi umumnya dibagi menjadi tiga jenis utama sebagaimana ditampilkan pada Gambar 2.1, yaitu penyaringan berbasis kolaboratif (*collaborative filtering*), penyaringan berbasis konten (*content-based filtering*), dan pendekatan gabungan (*hybrid recommender system*). Masing-masing pendekatan memiliki kelebihan dan keterbatasan yang berbeda (Burke,

2002; Pazzani and Billsus, 2007; Sharaf *et al.*, 2022). Tabel 2.1 berikut menyajikan perbandingan dari ketiga pendekatan tersebut.


Tabel 2. 1 Klasifikasi Pendekatan dalam Sistem Rekomendasi

Pendekatan	Prinsip Kerja	Kelebihan	Keterbatasan
<i>Collaborative Filtering</i>	Rekomendasi berdasarkan pola pengguna serupa	1) Tidak perlu domain knowledge 2) Menemukan unexpected items	1) <i>Cold-start problem</i> 2) <i>Sparsity data</i> 3) <i>Popularity bias</i>
<i>Content-Based Filtering</i>	Rekomendasi berdasarkan kesamaan atribut item	1) Tidak ada <i>cold-start</i> 2) Explainable 3) Item baru bisa direkomendasi	1) <i>Over-specialization</i> 2) Perlu <i>feature engineering</i> 3) Limited novelty
<i>Hybrid</i>	Kombinasi CF dan CBF	1) Mengatasi kelemahan masing-masing 2) Akurasi lebih tinggi	1) Kompleksitas implementasi lebih tinggi

Dalam konteks e-commerce, sistem rekomendasi terbukti berkontribusi terhadap peningkatan kinerja platform, seperti meningkatnya konversi pembelian, rata-rata nilai transaksi, serta loyalitas pelanggan (Abdul Hussien, Rahma and Abdul Wahab, 2021; Didi Riswan, Heri Eko Rahmadi Putra and Risfan Nazar Saputra, 2024).

2.1.3 Content-Based Filtering

Content-Based Filtering (CBF) merupakan pendekatan dalam sistem rekomendasi yang memberikan saran item berdasarkan kesamaan atribut atau karakteristik antar item (Pazzani and Billsus, 2007; Isinkaye, Folajimi and Ojokoh, 2015). Pendekatan ini bekerja dengan merepresentasikan setiap item dalam bentuk vektor fitur, kemudian menghitung tingkat kemiripan antar item untuk menentukan rekomendasi yang relevan. Tahapan CBF dimulai dari ekstraksi fitur (*feature extraction*) dari atribut item seperti nama, kategori, atau deskripsi, dilanjutkan dengan pembangunan profil pengguna (*user profile*) berdasarkan riwayat interaksi, dan diakhiri dengan perhitungan kemiripan untuk menghasilkan daftar rekomendasi (Salton and Buckley, 1988; Pazzani and Billsus, 2007; Nurcahya and Supriyanto, 2020).



Gambar 2. 2 Arsitektur Content-Based Filtering

(Sumber: Roy and Dutta, 2022)

Salah satu kelebihan utama dari pendekatan ini adalah kemampuannya menjelaskan alasan rekomendasi yang diberikan karena didasarkan pada kesamaan atribut yang dimiliki oleh item. Selain itu, CBF dapat digunakan pada kondisi data pengguna yang terbatas sehingga mampu mengatasi permasalahan *cold-start* (Lops, de Gemmis and Semeraro, 2011; Halimatussa'diyah and Dini, 2025). Akan tetapi, pendekatan CBF memiliki keterbatasan berupa kecenderungan sistem merekomendasikan item yang terlalu mirip dengan riwayat interaksi pengguna, permasalahan ini yang dikenal dengan *over-specialization*, akibatnya bisa mengurangi keberagaman rekomendasi dan juga kemungkinan pengguna dalam menemukan item baru yang berbeda (Pazzani and Billsus, 2007; Nurcahya and Supriyanto, 2020).

2.1.4 TF-IDF dan Cosine Similarity

Dalam sistem rekomendasi, atribut teks produk perlu diubah menjadi sebuah representasi numerik agar dapat diproses dan dipahami oleh komputer. Salah satu metode yang paling umum digunakan dalam proses ini adalah *Term Frequency–Inverse Document Frequency* atau lebih dikenal dengan TF-IDF, metode ini bekerja dengan mengukur tingkat kepentingan suatu kata dalam sebuah dokumen terhadap keseluruhan koleksi dokumen (Salton and Buckley, 1988).

Nilai TF-IDF untuk sebuah kata t pada dokumen d dalam koleksi D dihitung menggunakan formula berikut:

$$TF - IDF(t, d, D) = TF(t, d) \times IDF(t, D) \quad (\text{Persamaan 2.1})$$

dimana $TF(t, d)$ adalah frekuensi relatif kemunculan kata t dalam dokumen d , dan $IDF(t, D)$ dihitung sebagai :

$$IDF(t, D) = \log \frac{|D|}{|\{d \in D: t \in d\}|} \quad (\text{Persamaan 2.2})$$

Dengan formula ini, kata yang sering muncul pada suatu produk namun jarang dijumpai pada produk lain mendapat bobot tinggi, karena kata tersebut lebih mampu membedakan karakteristik antar produk. Sebaliknya, kata yang muncul di hampir semua produk mendapat bobot rendah karena tidak memiliki daya pembeda yang signifikan. Tabel 2.2 menyajikan contoh perhitungan TF-IDF pada konteks produk e-commerce.

Tabel 2. 2 Contoh Perhitungan TF-IDF untuk Produk

Produk	Teks	TF	IDF	TF-IDF
P1	"Samsung Galaxy S21 5G"	0.25	0.52	0.13
P2	"Samsung Galaxy Note 20"	0.33	0.52	0.17
P3	"iPhone 13 Pro Max"	0.00	0.52	0.00

Setelah representasi TF-IDF dihasilkan, tingkat kemiripan antar vektor diukur menggunakan *cosine similarity*. Metode ini mengukur kedekatan antar dua vektor berdasarkan sudut yang dibentuk keduanya, sehingga mampu menilai kesamaan konten tanpa dipengaruhi oleh perbedaan panjang deskripsi. Formula *cosine similarity* antara dua vektor $\vec{a}$ dan $\vec{b}$ adalah:

$$\text{similarity}(\vec{a}, \vec{b}) = \frac{\vec{a} \cdot \vec{b}}{||\vec{a}|| \cdot ||\vec{b}||} \quad (\text{Persamaan 2.3})$$

Nilai *cosine similarity* berada dalam rentang $[0, 1]$, di mana nilai mendekati 1 menunjukkan kemiripan konten yang tinggi dan nilai mendekati 0 menunjukkan konten yang tidak berhubungan. Tabel 2.3 menyajikan panduan interpretasi nilai *cosine similarity* dalam konteks produk e-commerce.

Tabel 2. 3 Interpretasi Nilai Cosine Similarity

Rentang Nilai	Interpretasi	Contoh
0.9 - 1.0	Sangat Mirip	Produk identik atau varian minor
0.7 - 0.9	Mirip	Produk merek sama, kategori sama

0.5 - 0.7	Cukup Mirip	Kategori sama, merek berbeda
0.3 - 0.5	Kurang Mirip	Kategori berbeda, fungsi mirip
0.0 - 0.3	Tidak Mirip	Produk tidak berhubungan


Berdasarkan penelitian terdahulu mengenai sistem rekomendasi pada domain e-commerce membuktikan bahwa kombinasi antara metode TF-IDF dan *cosine similarity* efektif digunakan dalam sistem rekomendasi berbasis konten untuk menghasilkan rekomendasi yang relevan dan konsisten (Fiarni, Maharani and Calista, 2019; Nurcahya and Supriyanto, 2020; Adam and Grivin, 2025).

2.1.5 *Popularity Bias dan Long-Tail Problem*

Popularity bias adalah sebuah kecenderungan sistem rekomendasi dalam merekomendasikan item dengan tingkat popularitas yang tinggi secara berlebihan, sementara item dengan popularitas rendah cenderung kurang memperoleh eksposur meskipun berpotensi untuk relevan bagi segmen pengguna tertentu (Klimashevskaja *et al.*, 2024). Fenomena ini banyak ditemukan pada sistem rekomendasi berbasis *collaborative filtering*, di mana item dengan jumlah interaksi yang banyak lebih sering direkomendasikan sehingga membentuk sebuah *feedback loop* yang semakin memperkuat dominasi item populer dalam sebuah katalog rekomendasi (Carnovalini, Rodà and Wiggins, 2025).

Berdasarkan kajian literatur, *popularity bias* umumnya membentuk pola distribusi *heavy-tailed*, di mana sebagian kecil item dalam katalog memperoleh porsi interaksi dan eksposur yang sangat besar (*short head*), sementara sebagian

besar item lainnya berada pada wilayah *long-tail* dengan tingkat interaksi yang rendah. Meskipun item *long-tail* memiliki eksposur yang lebih sedikit, berbagai penelitian menunjukkan bahwa item pada kategori ini tidak selalu memiliki kualitas lebih rendah dibandingkan item populer, melainkan hanya kurang terekspos oleh sistem rekomendasi yang ada (Abdollahpouri *et al.*, 2021a; Qin, 2021).



Gambar 2. 3 Distribusi Popularitas Item dalam Fenomena *Long-Tail*

(Sumber: Abdollahpouri, Burke and Mobasher, 2019)

Long-tail problem merupakan kondisi di mana mayoritas item dalam katalog jarang atau tidak pernah direkomendasikan oleh sistem meskipun berpotensi bisa relevan untuk pengguna (Abdollahpouri *et al.*, 2021a; Qin, 2021). Dalam konteks e-commerce, permasalahan ini bisa berdampak luas. Contohnya bagi konsumen, dominasi item yang populer akan mengurangi keberagaman rekomendasi dan peluang menemukan produk yang berpotensi sesuai dengan preferensi. Lalu bagi pelaku usaha berskala kecil atau baru memulai, kondisi ini

menyebabkan rendahnya visibilitas produk untuk dilihat oleh pengguna meskipun kualitasnya bisa saja baik. Sementara bagi platform, ketimpangan eksposur produk ini berpotensi menghambat optimalisasi nilai bisnis jangka panjang.

2.1.6 Hybrid Recommender System

Hybrid Recommender System adalah pendekatan yang menggabungkan dua atau lebih metode rekomendasi dengan tujuan untuk meningkatkan kualitas hasil rekomendasi dan mengatasi keterbatasan dari satu pendekatan rekomendasi saja (Burke, 2002). Dalam konteks e-commerce, pendekatan *hybrid* menjadi sangat penting karena sistem tidak hanya dituntut menghasilkan rekomendasi yang akurat, tetapi juga mampu mengatasi permasalahan dari satu metode rekomendasi, contohnya dalam mengendalikan permasalahan *popularity bias*.

Burke (2002) mengidentifikasi sebanyak tujuh strategi penggabungan metode rekomendasi dalam sistem *hybrid* sebagaimana disajikan pada Tabel 2.4.

Tabel 2. 4 Strategi Metode Hybrid

Strategi	Deskripsi
<i>Weighted</i>	Menggabungkan skor dari berbagai metode menggunakan bobot tertentu
<i>Switching</i>	Beralih antar metode berdasarkan kondisi atau kriteria tertentu
<i>Mixed</i>	Menyajikan hasil dari berbagai metode secara bersamaan
<i>Cascade</i>	Satu metode memfilter kandidat untuk metode berikutnya
<i>Feature Combination</i>	Menggabungkan fitur dari berbagai sumber data

<i>Feature Augmentation</i>	Output satu metode menjadi input metode lain
<i>Meta-level</i>	Model yang dihasilkan satu metode menjadi input metode lain

Penelitian ini menggunakan strategi *weighted hybrid* karena kesederhanaan implementasi, transparansi proses rekomendasi, dan kemampuannya dalam mengontrol kontribusi dari komponen melalui parameter bobot secara eksplisit. Strategi ini memungkinkan penggabungan skor kemiripan konten dengan skor pengendalian popularitas secara langsung dalam satu formula, sehingga sistem dapat tetap mengendalikan relevansi rekomendasi produk sekaligus mengurangi dominasi item populer (Burke, 2002; Li, Zhang and Zhang, 2021).

2.1.7 Evaluasi Sistem Rekomendasi

Evaluasi sistem rekomendasi bertujuan menilai kemampuan sistem dalam menghasilkan rekomendasi yang relevan dan bermanfaat bagi pengguna (Isinkaye, Folajimi and Ojokoh, 2015). Dalam konteks penelitian yang berfokus pada mitigasi *popularity bias*, evaluasi tidak cukup hanya menggunakan metrik akurasi, tetapi perlu diperluas dengan metrik *beyond-accuracy* untuk menilai aspek pemerataan eksposur produk secara komprehensif.

Secara umum, metrik evaluasi sistem rekomendasi dikelompokkan ke dalam dua kategori utama sebagai berikut.

1) *Accuracy Metrics*

Kelompok metrik ini mengukur kemampuan sistem merekomendasikan item yang relevan berdasarkan *ground truth* pengguna. Tiga metrik utama yang

digunakan adalah *Precision@K* yang mengukur proporsi item relevan dalam K rekomendasi teratas, *Recall@K* yang mengukur proporsi item relevan yang berhasil ditemukan dari seluruh item relevan yang tersedia, dan *NDCG@K* (*Normalized Discounted Cumulative Gain*) yang mempertimbangkan posisi item relevan dalam daftar rekomendasi dengan memberikan bobot lebih tinggi pada posisi teratas.

2) *Beyond-Accuracy Metric*

Kelompok metrik ini mengevaluasi aspek keberagaman dan pemerataan rekomendasi yang tidak tertangkap oleh metrik akurasi. *Long-tail Coverage* mengukur proporsi item *long-tail* dalam daftar rekomendasi — nilai tinggi menunjukkan sistem berhasil memberikan eksposur kepada item yang kurang populer. *Average Popularity* mengukur rata-rata tingkat popularitas item yang direkomendasikan — nilai rendah mengindikasikan *popularity bias* yang lebih kecil. *Diversity* mengukur tingkat keberagaman konten antar item dalam satu daftar rekomendasi, sementara *Catalog Coverage* mengukur proporsi keseluruhan katalog yang berhasil direkomendasikan kepada pengguna.

Ringkasan seluruh metrik evaluasi yang digunakan dalam penelitian ini disajikan pada Tabel 2.5.

Tabel 2. 5 Kategori Evaluasi Sistem Rekomendasi

Kategori	Metrik	Tujuan Pengukuran
<i>Accuracy</i>	<i>Precision@K</i>	Relevansi rekomendasi
	<i>Recall@K</i>	Cakupan item relevan
	<i>NDCG@K</i>	Kualitas ranking
<i>Beyond-Accuracy</i>	<i>Coverage</i>	Eksposur katalog

<i>Long-Tail Coverage</i>	Eksposur produk <i>long-tail</i>
<i>Average Popularity</i>	Tingkat <i>popularity bias</i>
<i>Diversity</i>	Keberagaman rekomendasi

Dalam penelitian ini, evaluasi dilakukan dengan mengombinasikan kedua kelompok metrik tersebut untuk memperoleh penilaian yang komprehensif terhadap *trade-off* antara relevansi rekomendasi dan peningkatan eksposur item *long-tail* (Abdollahpouri, Burke and Mobasher, 2019; Qin, 2021).

2.2 Penelitian Terkait

Beberapa penelitian terdahulu yang relevan dengan topik penelitian ini yaitu membahas sistem rekomendasi dirangkum pada Tabel 2.6.

Tabel 2. 6 Komparasi Penelitian

No	Judul, Penulis, Tahun	Metodologi	Hasil	Perbandingan Penelitian
1.	<i>Combining XGBoost and Hybrid Filtering Algorithm in E-commerce Recommendation System</i> (Sinaga and Wibowo, 2025)	Hybrid (XGBoost + CBF + CF)	Meningkatkan <i>precision</i> , <i>F1-score</i> , dan <i>hit ratio</i> , efektif pada <i>cold-start</i> ; <i>recall</i> rendah dan belum mengevaluasi <i>fairness distribution</i> / <i>popularity bias</i>	Fokus pada akurasi dan permasalahan <i>cold-start</i> ; tidak membahas <i>popularity bias</i> dan <i>long-tail</i>
2.	<i>A Hybrid Recommender System for Health Supplement e-Commerce based on Customer Data Implicit Ratings</i> (Keikhosrokiani and Man Fye, 2024)	Hybrid (CF + CBF, TF-IDF, Cosine)	Akurasi dan ranking metrics baik; masih mengalami <i>sparsity</i> dan isu skalabilitas	Tidak mengevaluasi <i>popularity bias</i> dan <i>long-tail exposure</i>

3.	<i>E-commerce Recommender System Using PCA and K-Means Clustering</i> (Andra and Baizal, 2022)	Collaborative Filtering (PCA + K-Means)	Error prediksi rendah (RMSE, MAE); hanya fokus akurasi	Tidak mempertimbangkan diversity, fairness, atau popularity bias
4.	<i>Hybrid Algorithm Based on Content and Collaborative Filtering in Recommendation System Optimization and Simulation</i> (Li, Zhang and Zhang, 2021)	Hybrid (CBF + CF + K-Means)	Meningkatkan performa dan mengatasi sparsity; fokus pada akurasi	Tidak membahas long-tail exposure atau popularity bias
5.	Penerapan Sistem Rekomendasi <i>Content Based Filtering</i> pada Pemilihan Skincare di Camelia (Alliya, Widyaningsih and Nurmalitasari, 2024)	CBF (Naïve Bayes similarity)	Precision dan recall baik; skala data terbatas	Tidak mengevaluasi beyond-accuracy dan popularity bias
6.	Implementasi Metode <i>Content-Based Filtering</i> Dengan Pendekatan	CBF (<i>Euclidean Distance</i>)	F1-score baik; dataset terbatas	Tidak membahas fairness dan popularity bias

Euclidean Distance Dalam Sistem
Rekomendasi Produk *Skincare*

(Halimatussa'diyah and Dini, 2025)

7.	Pengembangan Sistem Rekomendasi Berbasis Kecerdasan Buatan untuk Meningkatkan Pengalaman Pengguna di Platform e-Commerce	<i>ML-based Recommender</i>	Klaim pengalaman evaluasi kualitatif	peningkatan pengguna;	Tidak menjelaskan metrik teknis dan popularity bias
----	--	-----------------------------	--------------------------------------	-----------------------	---

(Didi Riswan dkk., 2024)

8.	Sistem Rekomendasi Pembelian Produk Kesehatan pada E-Commerce ABC berbasis <i>Graph Database Amazon Neptune</i> menggunakan Metode <i>Hybrid Content-Collaborative Filtering</i>	Hybrid (Graph DB + CF + CBF)	Implementasi fokus sistem	real-time;	Tidak mengevaluasi beyond-accuracy dan long-tail
----	--	------------------------------	---------------------------	------------	--

(Dinda Maristha, Santoso and Sari Dewi, 2021)

- | | | | | |
|----|---|--------------------|---|---|
| 9. | Content-based recommender system architecture for similar e-commerce products | CBF (TF-IDF + VSM) | Precision dan recall baik; arsitektur jelas | Tidak membahas popularity bias dan fairness |
|----|---|--------------------|---|---|

(Nurchaya and Supriyanto, 2020)

- | | | | | |
|-----|---|------------------------------------|--|--|
| 10. | EQNet: A Post-Processing Approach to Manage Popularity Bias in Collaborative Filter Recommender Systems | Post-processing re-ranking pada CF | Meningkatkan long-tail coverage dan fairness | Fokus pada CF dan post-processing; bukan CBF |
|-----|---|------------------------------------|--|--|

(Machado, Brandão and Marques-Neto, 2024)

- | | | | | |
|-----|---|-------------------------------|--------------------------------------|--|
| 11. | CauSeR: Causal Session-based Recommendations for Handling Popularity Bias | Deep Learning berbasis kausal | Mengurangi popularity bias; kompleks | Kompleks dan berbasis session, bukan CBF |
|-----|---|-------------------------------|--------------------------------------|--|
-

(Gupta <i>et al.</i> , 2021)				
12.	Mitigating Popularity Bias for Users and Items with Fairness-centric Adaptive Recommendation	Deep Learning end-to-end	Meningkatkan fairness dan mitigasi bias	Kompleks dan tidak fokus pada sistem berbasis konten
(Liu, Fang and Wu, 2023)				
13.	Managing Popularity Bias in Personalized Recommender Systems with Personalized Re-ranking	re-ranking (post-processing)	Meningkatkan long-tail coverage dan fairness	Berbasis CF dan post-processing
(Abdollahpouri, Burke and Mobasher, 2019)				
14.	PBiLoss: Popularity-Aware Regularization to Improve Fairness in Graph-Based Recommender Systems	Regularization loss pada Graph Neural Network (LightGCN)	Menurunkan popularity bias tanpa menurunkan akurasi secara signifikan.	Berbasis GNN dan CF; penelitian ini berbasis hybrid content-based dengan weighting atribut produk.
(Naeimi and Chehreghani, 2025)				

15.	CPFair: Personalized Consumer and Producer Fairness Re-ranking for Recommender Systems (Naghiaei, Rahmani and Deldjoo, 2022)	Optimization-based two-sided fairness re-ranking	Meningkatkan consumer & producer fairness tanpa menurunkan akurasi signifikan.	Mirip pada konsep two-sided fairness, tetapi penelitian ini mengintegrasikan popularity-quality weighting dalam hybrid content-based e-commerce.
16.	<i>Pendekatan Hybrid Content-Based Filtering untuk Mengurangi Popularity Bias pada Sistem Rekomendasi E-Commerce – Penelitian Ini</i>	Hybrid Content-Based + Popularity-Quality Weighting + Re-ranking	Mengevaluasi akurasi, diversity, coverage, long-tail exposure, dan average popularity untuk mengurangi popularity bias tanpa menurunkan relevansi.	Mengisi gap integrasi popularity control pada sistem content-based e-commerce secara eksplisit dan terukur.

Berdasarkan tinjauan terhadap penelitian terdahulu, sebagian besar sistem rekomendasi pada domain e-commerce masih berfokus pada peningkatan akurasi melalui pendekatan *collaborative filtering*, *content-based filtering*, maupun *hybrid*, dengan evaluasi hasil rekomendasi yang didominasi oleh metrik seperti *precision*, *recall*, dan NDCG. Beberapa penelitian terbaru mulai membahas aspek *fairness* dan *popularity bias*, namun umumnya diterapkan pada pendekatan *collaborative filtering*, *graph-based model*, atau pendekatan *deep learning* yang kompleks serta berbasis *post-processing*. Integrasi mekanisme pengendalian *popularity bias* secara langsung dalam sistem berbasis *content-based filtering* pada konteks produk e-commerce masih relatif terbatas. Oleh karena itu, penelitian ini mengisi celah tersebut dengan mengusulkan pendekatan *hybrid content-based filtering* yang mengombinasikan kemiripan konten dan mekanisme *popularity-quality weighting*, serta mengevaluasinya menggunakan metrik *accuracy*, *beyond-accuracy*, dan *long-tail metrics* untuk menilai keseimbangan antara relevansi dan pemerataan eksposur produk.