Jurnal Riset Multidisiplin Edukasi
https://journal.hasbaedukasi.co.id/index.php/jurmie
Halaman : 659 - 680

ANALISIS REKOMENDASI PRODUK E-COMMERCE BERDASARKAN PREFERENSI KATEGORI DAN BATAS ANGGARAN MENGGUNAKAN ALGORITMA ASSOCIATION RULE MINING

Rafa Prayata Raki Putra[1], Tata Sutabri[2]
Teknik Infromatika, Institut Teknologi Indonesia, Tangerang Selatan, Indonesia [1,2]
Email: rafaprayatarakiputra@gmail.com

Informasi

Volume : 3
Nomor : 11
Bulan : November
Tahun : 2026
E-ISSN : 3062-9624

Abstract

The growth of e-commerce has generated large volumes of transaction data that can be utilized to identify purchasing patterns and support product recommendation systems. However, recommendations based solely on product popularity or product associations may not fully meet users' needs, particularly when users have specific category preferences and budget constraints. This study aims to analyze the application of Association Rule Mining using the Apriori algorithm for e-commerce product recommendations by considering users' category preferences and budget limits. The dataset used in this research is the Olist Brazilian E-Commerce Public Dataset. The research stages include data preprocessing, transaction construction, training and testing data splitting, association rule generation, recommendation filtering, and evaluation using Precision@10, Recall, Hit Rate, Coverage, and F1-score@10. Three recommendation approaches are compared: Apriori, Popularity, and Hybrid. The preprocessing stage produced 111,047 valid transaction-item records from 97,277 unique transactions. A total of 3,178 transactions containing more than one product were used to construct the Apriori model. Following the final correction of association-rule candidate generation, the Hybrid approach achieved a Precision@10 of 0.02078, Recall of 0.18250, Hit Rate of 0.19207, Coverage of 1.00000, and F1-score@10 of 0.03731. These results were higher than those of the Popularity approach, which achieved a Precision@10 of 0.02010, Recall of 0.17567, Hit Rate of 0.18524, Coverage of 1.00000, and F1-score@10 of 0.03607. These findings indicate that combining association-rule-based recommendations with a popularity-based fallback mechanism produces better evaluation results than using popularity alone under the tested scenarios. Nevertheless, the contribution of association rules remains constrained by the limited number of generated candidates and the characteristics of the transaction dataset.

Keyword: *Association Rule Mining, Apriori, E-Commerce, Recommendation System, Category Preference, Budget Constraint.*

Abstrak
Perkembangan e-commerce menghasilkan data transaksi dalam jumlah besar yang dapat dimanfaatkan untuk mengidentifikasi pola pembelian dan mendukung penyusunan rekomendasi produk. Namun, rekomendasi yang hanya didasarkan pada popularitas atau keterkaitan antarproduk belum tentu sesuai dengan kebutuhan pengguna, khususnya ketika pengguna memiliki preferensi kategori dan batas anggaran tertentu. Penelitian ini bertujuan menganalisis penerapan Association Rule Mining menggunakan algoritma Apriori dalam rekomendasi produk e-commerce dengan mempertimbangkan preferensi kategori dan batas anggaran pengguna. Dataset yang digunakan adalah Olist Brazilian E-Commerce Public Dataset. Tahapan penelitian meliputi preprocessing data, pembentukan transaksi, pembagian data latih dan data uji, pembentukan aturan asosiasi, pengembangan mekanisme penyaringan rekomendasi, serta evaluasi menggunakan Precision@10, Recall, Hit Rate, Coverage, dan F1-score@10. Penelitian membandingkan tiga pendekatan, yaitu Apriori, Popularity, dan Hybrid. Hasil preprocessing menghasilkan 111.047 baris data transaksi yang valid, dengan 97.277 transaksi unik. Sebanyak 3.178 transaksi yang memuat lebih dari satu produk digunakan dalam proses pembentukan model Apriori. Pada evaluasi akhir setelah perbaikan pembentukan kandidat aturan asosiasi, pendekatan Hybrid memperoleh Precision@10 sebesar 0,02078, Recall sebesar 0,18250, Hit Rate sebesar 0,19207, Coverage sebesar 1,00000, dan F1-score@10 sebesar 0,03731. Hasil tersebut lebih tinggi dibandingkan pendekatan Popularity yang memperoleh Precision@10 sebesar 0,02010, Recall sebesar 0,17567, Hit Rate sebesar 0,18524, Coverage sebesar 1,00000, dan F1-score@10 sebesar 0,03607. Temuan ini menunjukkan bahwa penggabungan rekomendasi berbasis aturan asosiasi dengan mekanisme fallback popularitas memberikan hasil evaluasi yang lebih baik dibandingkan penggunaan popularitas saja pada skenario pengujian penelitian. Meskipun demikian, kontribusi aturan asosiasi masih dibatasi oleh jumlah kandidat yang dapat dihasilkan dan karakteristik transaksi pada dataset.

Kata Kunci : *Association Rule Mining, Apriori, E-Commerce, Sistem Rekomendasi, Preferensi Kategori, Batas Anggaran.*

A. PENDAHULUAN

Perkembangan teknologi informasi telah mendorong perubahan dalam aktivitas perdagangan melalui pemanfaatan platform electronic commerce (e-commerce). Platform e-commerce memungkinkan konsumen memperoleh informasi, membandingkan, dan membeli berbagai jenis produk secara daring. Aktivitas tersebut menghasilkan data transaksi yang dapat dimanfaatkan untuk memahami kecenderungan pembelian konsumen serta mendukung pengembangan layanan yang lebih sesuai dengan kebutuhan pengguna.

Salah satu pemanfaatan data transaksi dalam e-commerce adalah pengembangan sistem rekomendasi produk. Sistem rekomendasi berfungsi membantu pengguna menemukan produk yang relevan berdasarkan informasi tertentu, seperti riwayat pembelian, karakteristik produk, maupun pola interaksi antarpengguna. Dalam konteks perdagangan elektronik, rekomendasi yang relevan dapat membantu mempersempit pilihan produk ketika jumlah produk yang tersedia semakin banyak.

Salah satu pendekatan yang dapat digunakan untuk menganalisis pola pembelian adalah Association Rule Mining (ARM). Metode ini bertujuan menemukan hubungan atau keterkaitan

antaritem berdasarkan kemunculannya dalam sekumpulan transaksi. Algoritma Apriori merupakan salah satu algoritma yang digunakan untuk membentuk aturan asosiasi melalui pencarian frequent itemsets dengan mempertimbangkan nilai minimum support dan minimum confidence. Aturan yang dihasilkan dapat menggambarkan keterkaitan produk yang muncul secara bersamaan dalam transaksi historis.

Meskipun demikian, rekomendasi yang dihasilkan berdasarkan pola asosiasi belum tentu secara langsung sesuai dengan kebutuhan pengguna. Produk yang memiliki keterkaitan dengan produk pemicu belum tentu termasuk kategori yang sedang diminati pengguna. Selain itu, harga produk yang direkomendasikan dapat melampaui kemampuan atau batas pengeluaran yang telah ditentukan pengguna. Kondisi tersebut menunjukkan bahwa keterkaitan produk berdasarkan transaksi historis perlu dipadukan dengan mekanisme penyaringan yang mempertimbangkan preferensi pengguna.

Preferensi kategori dan batas anggaran merupakan dua aspek yang dapat digunakan untuk membatasi ruang rekomendasi. Preferensi kategori memungkinkan pengguna menentukan kelompok produk yang ingin dipertimbangkan, sedangkan batas anggaran membatasi kandidat berdasarkan perkiraan harga produk. Dengan demikian, rekomendasi tidak hanya didasarkan pada hubungan antarproduk, tetapi juga memperhatikan batasan yang ditentukan pengguna.

Penelitian ini menggunakan Olist Brazilian E-Commerce Public Dataset sebagai sumber data transaksi. Dataset tersebut menyediakan informasi transaksi pembelian, identitas produk, harga, dan kategori produk. Karakteristik dataset memperlihatkan bahwa sebagian besar transaksi hanya memuat satu produk. Kondisi tersebut menjadi tantangan dalam penerapan Association Rule Mining karena pembentukan aturan asosiasi membutuhkan transaksi yang memiliki keterkaitan antaritem. Oleh sebab itu, penelitian ini menggunakan transaksi yang memuat lebih dari satu produk dalam pembentukan model Apriori.

Selain pendekatan Apriori, penelitian ini menerapkan pendekatan Popularity sebagai pembanding dan mekanisme Hybrid sebagai kombinasi keduanya. Pendekatan Popularity digunakan untuk menghasilkan rekomendasi berdasarkan tingkat popularitas produk pada data latih. Sementara itu, Hybrid memanfaatkan kandidat dari aturan asosiasi terlebih dahulu, kemudian melengkapi rekomendasi menggunakan popularitas apabila kandidat Apriori belum mencukupi.

Penggunaan ketiga pendekatan tersebut memungkinkan penelitian tidak hanya mengamati kemampuan algoritma Apriori dalam menemukan hubungan antarproduk, tetapi

juga mengevaluasi bagaimana aturan asosiasi dapat digunakan bersama mekanisme rekomendasi alternatif ketika kandidat yang dihasilkan terbatas.

Penelitian Terdahulu

Penelitian mengenai sistem rekomendasi berbasis pola transaksi telah dilakukan dengan berbagai pendekatan. Salah satu pendekatan yang digunakan adalah Association Rule Mining, yang memanfaatkan hubungan antaritem dalam transaksi untuk menghasilkan informasi mengenai kecenderungan pembelian produk.

Prasetio (2025) membahas penerapan algoritma Apriori dalam menemukan aturan asosiasi untuk mendukung rekomendasi produk. Pendekatan tersebut memperlihatkan penggunaan pola pembelian sebagai dasar pembentukan hubungan antarproduk. Penelitian tersebut menjadi salah satu landasan dalam penggunaan Apriori pada penelitian ini. Namun, penelitian yang dilakukan sekarang mengarahkan penerapan aturan asosiasi pada mekanisme rekomendasi yang juga mempertimbangkan preferensi kategori dan batas anggaran pengguna.

Dogan (2023) melalui penelitian berjudul A Recommendation System in E-Commerce with Profit-Support Fuzzy Association Rule Mining (P-FARM) membahas penerapan association rule mining dengan mempertimbangkan aspek profitabilitas. Fokus tersebut memperlihatkan bahwa aturan asosiasi dapat dikembangkan dengan mempertimbangkan tujuan bisnis tertentu. Berbeda dengan pendekatan tersebut, penelitian ini menitikberatkan pada penyaringan kandidat rekomendasi berdasarkan preferensi kategori dan batas anggaran konsumen, bukan pada optimalisasi keuntungan penjual.

Hu et al. (2018) melalui penelitian Learning Within-Session Budgets from Browsing Trajectories membahas pemodelan anggaran pengguna berdasarkan pola aktivitas penelusuran dalam suatu sesi. Penelitian tersebut memberikan perspektif bahwa batas anggaran merupakan informasi penting dalam memahami perilaku konsumen. Sementara itu, penelitian ini menggunakan batas anggaran sebagai parameter penyaringan kandidat produk yang dihasilkan melalui aturan asosiasi dan popularitas produk.

Berdasarkan ketiga penelitian tersebut, dapat diketahui bahwa hubungan antarproduk, aspek profitabilitas, dan pemodelan anggaran pengguna telah menjadi perhatian dalam pengembangan sistem rekomendasi. Akan tetapi, ketiganya memiliki fokus yang berbeda. Penelitian ini diarahkan pada pengintegrasian aturan asosiasi berbasis Apriori dengan preferensi kategori dan batas anggaran sebagai mekanisme penyaringan rekomendasi produk. Selain itu, penelitian ini membandingkan pendekatan Apriori, Popularity, dan Hybrid untuk

mengamati kontribusi penggunaan aturan asosiasi ketika dikombinasikan dengan mekanisme fallback popularitas.

1.3 Research Gap

Berdasarkan kajian penelitian terdahulu, terdapat beberapa aspek yang menjadi dasar pengembangan penelitian ini.Pertama, penggunaan Association Rule Mining pada sistem rekomendasi berfokus pada identifikasi keterkaitan produk berdasarkan pola transaksi. Hasil aturan asosiasi dapat memberikan informasi mengenai produk yang memiliki kecenderungan muncul bersama, tetapi belum secara otomatis menjamin bahwa produk tersebut sesuai dengan kategori yang sedang diminati pengguna.

Kedua, penelitian mengenai rekomendasi berbasis profitabilitas menunjukkan bahwa aturan asosiasi dapat dikembangkan dengan mempertimbangkan aspek bisnis. Namun, pertimbangan keuntungan penjual memiliki orientasi berbeda dengan kebutuhan konsumen yang ingin memperoleh rekomendasi sesuai kategori dan batas pengeluaran.

Ketiga, penelitian mengenai pemodelan anggaran pengguna memperlihatkan pentingnya informasi anggaran dalam memahami perilaku konsumen. Akan tetapi, pemodelan anggaran berdasarkan aktivitas penelusuran berbeda dengan penggunaan batas anggaran sebagai penyaring kandidat produk yang diperoleh dari aturan asosiasi.

Berdasarkan perbedaan fokus tersebut, ruang penelitian yang dikaji dalam penelitian ini adalah penerapan aturan asosiasi Apriori yang dipadukan dengan preferensi kategori dan batas anggaran sebagai parameter penyaringan rekomendasi. Penelitian ini juga mengevaluasi pendekatan Hybrid untuk mengatasi keterbatasan kandidat yang dihasilkan oleh aturan asosiasi.

Dengan demikian, kontribusi penelitian ini terletak pada penerapan mekanisme rekomendasi yang menggabungkan pola keterkaitan produk berdasarkan transaksi historis dengan dua batasan pengguna, yaitu kategori produk dan anggaran. Evaluasi komparatif terhadap pendekatan Apriori, Popularity, dan Hybrid digunakan untuk mengetahui karakteristik hasil rekomendasi dari masing-masing pendekatan.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk:

1. Menerapkan algoritma Apriori dalam mengidentifikasi hubungan antarproduk berdasarkan transaksi pembelian pada Olist Brazilian E-Commerce Public Dataset.
2. Mengembangkan mekanisme rekomendasi produk yang mempertimbangkan preferensi kategori dan batas anggaran pengguna.

3. Membandingkan kinerja pendekatan Apriori, Popularity, dan Hybrid berdasarkan metrik Precision@10, Recall, Hit Rate, Coverage, dan F1-score@10.
4. Menganalisis kemampuan pendekatan Hybrid dalam melengkapi keterbatasan kandidat rekomendasi yang dihasilkan oleh aturan asosiasi.

B. METODE PENELITIAN

2.1 Jenis dan Tahapan Penelitian

Penelitian ini merupakan penelitian kuantitatif berbasis eksperimen dengan memanfaatkan data transaksi e-commerce. Eksperimen dilakukan melalui penerapan algoritma Apriori, pengembangan mekanisme penyaringan rekomendasi, serta perbandingan beberapa pendekatan rekomendasi menggunakan data latih dan data uji.

Tahapan penelitian disusun untuk memastikan bahwa proses pembentukan model dan evaluasi dilakukan secara terpisah. Data latih digunakan untuk membangun aturan asosiasi dan metadata rekomendasi, sedangkan data uji digunakan untuk mengevaluasi kesesuaian rekomendasi terhadap produk yang benar-benar muncul dalam transaksi pengujian.

Gambar 1. Tahapan penelitian

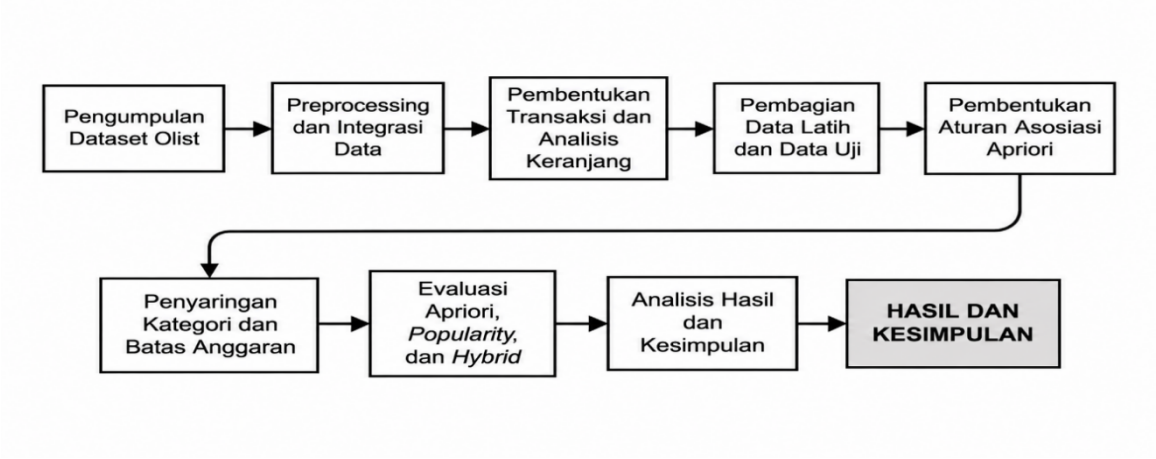

2.2 Dataset Penelitian

Dataset yang digunakan adalah Olist Brazilian E-Commerce Public Dataset, yaitu dataset transaksi e-commerce yang menyediakan informasi mengenai aktivitas pembelian produk. Data yang digunakan dalam penelitian ini terdiri atas tiga berkas utama.

Tabel 1. Sumber dataset penelitian

Nama dataset	Informasi yang digunakan
olist_order_items_dataset.csv	Identitas transaksi, produk, harga, dan informasi item pesanan

olist_products_dataset.csv	Identitas dan kategori produk
product_category_name_translation.csv	Penerjemahan nama kategori produk ke bahasa Inggris

Ketiga dataset digabungkan berdasarkan identitas produk dan kategori yang tersedia. Informasi harga produk digunakan sebagai dasar penyaringan anggaran, sedangkan identitas transaksi dan produk digunakan dalam pembentukan keranjang transaksi.

Harga pada dataset dinyatakan dalam Brazilian Real (BRL). Penelitian ini menggunakan harga produk dan tidak memasukkan biaya pengiriman (freight value) dalam perhitungan batas anggaran.

2.3 Preprocessing Data

Tahap preprocessing dilakukan untuk memastikan data yang digunakan memiliki informasi produk, kategori, dan harga yang dapat diproses.

Tahapan preprocessing meliputi:

1. Membaca ketiga berkas dataset.
2. Menggabungkan data transaksi dengan metadata produk.
3. Menggabungkan informasi terjemahan kategori produk.
4. Menghapus baris yang tidak memiliki kategori produk.
5. Menghapus baris yang tidak memiliki nilai harga numerik yang valid.
6. Menyimpan hasil pengolahan sebagai data bersih dan metadata produk.

Hasil preprocessing ditunjukkan pada Tabel 2.

Tabel 2. Hasil preprocessing dataset

Keterangan	**Jumlah**
Data transaksi sebelum preprocessing	112.650
Data transaksi setelah preprocessing	111.047
Data yang dihapus	1.603
Jumlah transaksi unik	97.277
Jumlah produk unik	32.341
Jumlah kategori produk	73

Penghapusan sebanyak 1.603 baris dilakukan karena terdapat informasi kategori atau harga yang tidak memenuhi kebutuhan pemrosesan. Setelah proses tersebut, data yang

digunakan telah memiliki informasi kategori dan harga yang valid.

2.4 Pembentukan Transaksi

Setelah preprocessing, data dikelompokkan berdasarkan identitas pesanan (order_id) untuk membentuk keranjang transaksi. Setiap transaksi direpresentasikan sebagai himpunan produk yang dibeli secara bersamaan.Hasil analisis menunjukkan bahwa sebagian besar transaksi hanya berisi satu produk. Distribusi jumlah produk dalam transaksi disajikan pada Tabel 3.

Tabel 3. Distribusi jumlah produk per transaksi

Jumlah produk	Jumlah transaksi
1	94.099
2	2.799
3	289
4	68
5	8
6	10
7	3
8	1
Total	97.277

Berdasarkan distribusi tersebut, terdapat 3.178 transaksi yang memuat lebih dari satu produk. Transaksi tersebut digunakan dalam pembentukan model Apriori karena transaksi dengan satu produk tidak memberikan pasangan item yang dapat digunakan untuk membentuk aturan asosiasi.

Pemilihan transaksi multi-produk bertujuan mempertahankan informasi keterkaitan antarproduk yang dibutuhkan oleh algoritma Apriori. Meskipun demikian, pembatasan tersebut menyebabkan model asosiasi dibangun dari sebagian kecil keseluruhan transaksi. Kondisi ini menjadi salah satu karakteristik penting yang dipertimbangkan dalam interpretasi hasil penelitian.

2.5 Pembagian Data Latih dan Data Uji

Transaksi multi-produk dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan random_state=42.

Tabel 4. Pembagian data latih dan data uji

Jenis data	Jumlah transaksi	Persentase
Data latih	2.542	80%
Data uji	636	20%
Total	3.178	100%

Pembagian dilakukan berdasarkan identitas transaksi untuk mencegah satu transaksi yang sama masuk ke dalam data latih dan data uji. Hasil audit menunjukkan tidak terdapat tumpang tindih identitas transaksi pada pembagian tersebut.

Data latih digunakan untuk membangun aturan asosiasi, menentukan metadata harga produk, menentukan kategori produk, dan menghitung popularitas produk. Sementara itu, data uji digunakan untuk membentuk target evaluasi berdasarkan produk yang benar-benar muncul dalam transaksi pengujian.

2.6 Penerapan Association Rule Mining dengan Algoritma Apriori

Algoritma Apriori digunakan untuk menemukan kombinasi item yang sering muncul dalam transaksi. Proses ini diawali dengan mengubah data transaksi menjadi representasi biner atau transaction matrix, kemudian mencari frequent itemsets berdasarkan nilai minimum support.

Nilai support menunjukkan proporsi transaksi yang mengandung suatu itemset terhadap keseluruhan transaksi. Persamaan support dituliskan sebagai berikut:

$$Support(A) = \frac{Jumlah\ transaksi\ yang\ memuat\ A}{Jumlah\ seluruh\ transaksi}$$

Confidence digunakan untuk mengukur tingkat kepercayaan suatu aturan asosiasi. Persamaannya adalah:

$$Ketik\ Confidence(A \rightarrow Ketik\ B) \frac{Support(A \cup B)}{Support(A)}$$

Sementara itu, lift digunakan untuk mengukur kekuatan hubungan antara antecedent dan consequent dibandingkan dengan kemunculan consequent secara independen.

$$Lift(A \rightarrow B) \frac{Confidence(A \rightarrow B)}{Support(B)}$$

Nilai lift lebih besar dari satu menunjukkan bahwa kemunculan consequent memiliki keterkaitan positif terhadap antecedent dalam data transaksi yang dianalisis.

Dalam penelitian ini, parameter awal Apriori diuji menggunakan beberapa kombinasi

minimum support dan minimum confidence. Hasil eksperimen parameter pada data latih disajikan pada Tabel 5.

Tabel 5. Hasil eksperimen parameter Apriori pada data latih

Minimum support	Minimum confidence	Frequent itemsets	Rules
0,001	0,1	303	96
0,001	0,3	303	81
0,001	0,5	303	67
0,002	0,1	61	20
0,002	0,3	61	16
0,002	0,5	61	12
0,005	0,1	13	4
0,005	0,3	13	4
0,005	0,5	13	4

Berdasarkan eksperimen tersebut, penelitian menggunakan minimum support sebesar 0,001 dan minimum confidence sebesar 0,1. Pemilihan parameter tersebut mempertimbangkan jumlah aturan asosiasi yang dapat diperoleh agar kandidat rekomendasi yang dihasilkan tidak terlalu terbatas.

Aturan asosiasi kemudian dibatasi pada aturan dengan antecedent tunggal untuk membentuk pemetaan produk pemicu terhadap produk tujuan. Hasil pembentukan model menghasilkan 93 aturan asosiasi dengan antecedent tunggal, 72 produk pemicu unik, dan 90 kandidat produk dari seluruh consequent.

2.7 Pengembangan Mekanisme Rekomendasi

Penelitian ini membandingkan tiga pendekatan rekomendasi.

2.7.1 Pendekatan Apriori

Pendekatan Apriori menghasilkan kandidat rekomendasi berdasarkan aturan asosiasi yang terbentuk dari data latih. Produk yang digunakan sebagai pemicu akan dicocokkan dengan antecedent aturan asosiasi. Produk pada consequent kemudian dijadikan kandidat rekomendasi.

Kandidat tersebut disaring berdasarkan kategori yang dipilih pengguna dan batas anggaran. Produk pemicu tidak dimasukkan kembali sebagai rekomendasi.

2.7.2 Pendekatan Popularity

Pendekatan Popularity menghasilkan rekomendasi berdasarkan popularitas produk pada data latih. Popularitas dihitung berdasarkan frekuensi kemunculan produk dalam transaksi.

Produk yang memiliki tingkat popularitas lebih tinggi diprioritaskan sebagai kandidat rekomendasi. Kandidat kemudian disaring berdasarkan kategori dan batas anggaran yang ditentukan pengguna.

2.7.3 Pendekatan Hybrid

Pendekatan Hybrid menggabungkan hasil rekomendasi Apriori dengan pendekatan Popularity. Proses rekomendasi terlebih dahulu menggunakan kandidat yang dihasilkan oleh aturan asosiasi. Apabila jumlah kandidat belum mencukupi jumlah rekomendasi yang ditentukan, sistem melengkapi daftar rekomendasi menggunakan produk populer.

Dengan demikian, pendekatan Hybrid tidak menggantikan aturan asosiasi, tetapi menggunakan popularitas sebagai mekanisme pelengkap ketika kandidat berbasis Apriori belum mencukupi.

2.8 Preferensi Kategori dan Batas Anggaran

Penyaringan rekomendasi dilakukan berdasarkan dua parameter pengguna, yaitu kategori produk dan batas anggaran.

Kategori digunakan untuk membatasi rekomendasi agar hanya menampilkan produk dari kelompok yang dipilih. Sementara itu, batas anggaran digunakan untuk membatasi harga estimasi produk agar tidak melebihi nilai anggaran pengguna.

Harga estimasi kandidat dihitung menggunakan median harga produk pada data latih. Penggunaan median bertujuan memperoleh nilai representatif yang tidak terlalu dipengaruhi oleh nilai harga ekstrem.

Batas anggaran pengujian ditentukan berdasarkan distribusi harga produk pada data latih.

Tabel 6. Penentuan batas anggaran

Kuantil	Nilai anggaran
Persentil 25 (Q1)	BRL 34,7875
Persentil 50 (Median)	BRL 59,90
Persentil 75 (Q3)	BRL 107,0675

Produk yang memenuhi kategori pilihan dan memiliki harga estimasi tidak melebihi anggaran akan dipertahankan sebagai kandidat rekomendasi.

Perlu diperhatikan bahwa harga tersebut merupakan estimasi berdasarkan data historis, bukan harga terkini yang ditawarkan oleh penjual.

2.9 Evaluasi Sistem Rekomendasi

Evaluasi dilakukan untuk membandingkan hasil rekomendasi dari pendekatan Apriori, Popularity, dan Hybrid. Metrik yang digunakan terdiri atas Precision@10, Recall, Hit Rate, Coverage, dan F1-score@10.

Precision@10 mengukur proporsi rekomendasi relevan terhadap jumlah maksimum rekomendasi yang ditentukan.

$$Precision@10 = \frac{Jumlah\ rekomendasi\ relevan}{10}$$

Recall mengukur proporsi produk relevan yang berhasil ditemukan oleh sistem.

$$Recall = \frac{Jumlah\ rekomendasi\ relevan}{Jumlah\ seluruh\ skenario}$$

Hit Rate mengukur proporsi skenario yang menghasilkan minimal satu rekomendasi relevan.

$$HitRate = \frac{Skenario\ dengan\ rekomendasi\ relevan}{Jumlah\ seluruh\ skenario}$$

Coverage mengukur proporsi skenario yang berhasil menghasilkan rekomendasi.

$$Coverage = \frac{Skenario\ yang\ menghasilkan\ rekomendasi}{Jumlah\ seluruh\ skenario}$$

F1-score@10 dihitung sebagai rata-rata harmonis antara Precision@10 dan Recall.

$$F1@10 = 2 \times \frac{Precision@10 \times Recall}{Precision@10 + Recall}$$

Evaluasi dilakukan pada skenario pengujian yang memiliki produk relevan berdasarkan transaksi data uji. Dengan demikian, hasil evaluasi menggambarkan kinerja metode pada skenario yang memiliki target relevan dan tidak dimaksudkan sebagai representasi seluruh kemungkinan kombinasi kategori, anggaran, dan produk pemicu.

C. HASIL DAN PEMBAHASAN

3.1 Karakteristik Dataset dan Implikasinya terhadap Association Rule Mining

Hasil preprocessing menghasilkan 111.047 baris data transaksi yang valid, dengan 97.277 transaksi unik. Dari keseluruhan transaksi tersebut, sebanyak 94.099 transaksi hanya

berisi satu produk, sedangkan 3.178 transaksi lainnya memuat lebih dari satu produk.

Proporsi transaksi satu produk yang dominan menjadi karakteristik penting dalam penelitian ini. Association Rule Mining membutuhkan kemunculan bersama antaritem untuk membentuk aturan asosiasi. Oleh karena itu, transaksi yang hanya berisi satu produk tidak dapat memberikan pasangan produk yang diperlukan dalam pembentukan aturan asosiasi.

Penggunaan 3.178 transaksi multi-produk memungkinkan proses Apriori dilakukan pada data yang memiliki potensi keterkaitan antarproduk. Akan tetapi, jumlah transaksi yang digunakan menjadi lebih kecil dibandingkan keseluruhan data hasil preprocessing. Kondisi ini dapat membatasi jumlah pola asosiasi yang dapat ditemukan serta memengaruhi kemampuan model dalam menghasilkan kandidat rekomendasi.

Temuan tersebut menunjukkan bahwa ukuran dataset secara keseluruhan tidak selalu mencerminkan banyaknya informasi yang dapat digunakan untuk membangun aturan asosiasi. Karakteristik isi transaksi juga berpengaruh terhadap kemampuan algoritma dalam menemukan hubungan antarproduk.

Dengan demikian, penggunaan transaksi multi-produk dalam penelitian ini merupakan penyesuaian terhadap karakteristik dataset, bukan sekadar pengurangan data. Keputusan tersebut dilakukan agar aturan asosiasi yang dibentuk benar-benar berasal dari transaksi yang mengandung lebih dari satu item.

3.2 Analisis Hasil Pembentukan Aturan Asosiasi

Eksperimen parameter menunjukkan bahwa nilai minimum support dan minimum confidence memengaruhi jumlah aturan asosiasi yang dihasilkan.

Pada minimum support 0,001 dan minimum confidence 0,1, proses pembentukan aturan menghasilkan 96 aturan pada eksperimen data latih sebelum penyaringan antecedent. Ketika minimum confidence dinaikkan menjadi 0,3 dan 0,5, jumlah aturan menurun menjadi 81 dan 67 aturan.

Pada minimum support 0,002, jumlah aturan yang dihasilkan lebih sedikit, yaitu 20, 16, dan 12 aturan untuk masing-masing nilai minimum confidence. Sementara itu, pada minimum support 0,005 hanya terbentuk empat aturan untuk setiap nilai minimum confidence yang diuji.

Hasil tersebut menunjukkan bahwa peningkatan nilai minimum support menyebabkan lebih sedikit kombinasi item yang memenuhi kriteria frekuensi kemunculan. Peningkatan minimum confidence juga memperketat kriteria pembentukan aturan sehingga aturan dengan tingkat kepercayaan lebih rendah tidak dipertahankan.

Pemilihan minimum support 0,001 dan minimum confidence 0,1 dilakukan untuk

mempertahankan lebih banyak kandidat aturan yang dapat digunakan dalam sistem rekomendasi. Namun, jumlah aturan yang lebih banyak tidak secara otomatis menunjukkan kualitas rekomendasi yang lebih tinggi. Oleh karena itu, evaluasi pada data uji tetap diperlukan untuk mengukur relevansi produk yang dihasilkan.

Hasil audit aturan asosiasi menunjukkan bahwa 93 aturan memiliki antecedent tunggal. Dari aturan tersebut, 90 aturan memiliki satu produk consequent dan tiga aturan memiliki dua produk consequent. Setelah seluruh produk consequent diperhitungkan, terbentuk 90 kandidat produk yang terhubung dengan 72 produk pemicu.

Perbaikan pembentukan kandidat dengan memasukkan seluruh produk consequent diperlukan agar informasi aturan asosiasi tidak hilang ketika satu aturan memiliki lebih dari satu produk tujuan. Dengan demikian, kandidat rekomendasi yang digunakan dalam evaluasi telah mempertimbangkan seluruh produk pada consequent, bukan hanya satu produk yang dipilih dari setiap aturan.

3.3 Analisis Penerapan Preferensi Kategori dan Batas Anggaran

Penyaringan kategori dan batas anggaran merupakan bagian penting dalam mekanisme rekomendasi penelitian ini. Kedua parameter tersebut digunakan untuk mengarahkan kandidat rekomendasi agar sesuai dengan batasan yang ditentukan pengguna.

Kategori produk digunakan untuk memastikan bahwa kandidat rekomendasi berasal dari kelompok produk yang dipilih. Sementara itu, batas anggaran memastikan bahwa harga estimasi kandidat tidak melebihi nilai pengeluaran yang ditentukan.

Hasil audit fungsi rekomendasi menunjukkan bahwa seluruh pemeriksaan kategori, harga, pengecualian produk pemicu, dan validitas metadata produk memperoleh hasil sesuai kriteria. Hal tersebut menunjukkan bahwa mekanisme penyaringan telah diterapkan secara konsisten pada ketiga pendekatan rekomendasi.

Penggunaan median harga dari data latih juga bertujuan menghindari penggunaan informasi harga dari data uji dalam proses pembentukan kandidat. Dengan pendekatan tersebut, penyaringan anggaran dilakukan berdasarkan informasi yang tersedia pada data pelatihan.

Namun, harga estimasi berbasis median memiliki keterbatasan. Harga suatu produk dapat berubah antartransaksi, sehingga median harga tidak selalu menggambarkan harga yang berlaku pada setiap transaksi. Oleh sebab itu, harga estimasi digunakan dalam proses pembentukan rekomendasi, sedangkan evaluasi relevansi menggunakan harga aktual produk pada transaksi pengujian.

Pemisahan tersebut penting karena proses rekomendasi dan proses evaluasi memiliki fungsi berbeda. Harga estimasi digunakan untuk menentukan apakah kandidat layak direkomendasikan, sedangkan harga aktual digunakan untuk menentukan apakah produk pada transaksi uji memenuhi batas anggaran yang sedang dievaluasi.

3.4 Perbandingan Kinerja Pendekatan Apriori, Popularity, dan Hybrid

Hasil evaluasi akhir setelah perbaikan pembentukan kandidat aturan asosiasi ditampilkan pada Tabel 7.

Tabel 7. Perbandingan hasil evaluasi akhir

Metrik	Apriori	Hybrid	Popularity
Jumlah skenario	1.463	1.463	1.463
Precision@10	0,00697	0,02078	0,02010
Recall	0,06699	0,18250	0,17567
Hit Rate	0,06972	0,19207	0,18524
Coverage	0,11483	1,00000	1,00000
Total rekomendasi	271	14.530	14.530
Total rekomendasi relevan	102	304	294
F1-score@10	0,01263	0,03731	0,03607

Hasil evaluasi menunjukkan bahwa pendekatan Apriori menghasilkan Precision@10 sebesar 0,00697 dan Recall sebesar 0,06699. Nilai Coverage yang diperoleh sebesar 0,11483 menunjukkan bahwa pendekatan Apriori hanya berhasil menghasilkan rekomendasi pada sebagian kecil skenario pengujian.

Keterbatasan tersebut berkaitan dengan jumlah kandidat yang dihasilkan oleh aturan asosiasi. Model Apriori hanya memiliki 90 kandidat produk yang terhubung dengan 72 produk pemicu. Setelah dilakukan penyaringan berdasarkan kategori dan batas anggaran, sebagian kandidat tidak dapat digunakan karena tidak memenuhi kriteria yang ditentukan.

Kondisi tersebut menunjukkan bahwa aturan asosiasi dapat memberikan rekomendasi yang didasarkan pada hubungan antarproduk, tetapi jumlah kandidat yang tersedia belum mencukupi untuk menghasilkan rekomendasi pada seluruh skenario pengujian.

Pendekatan Popularity menghasilkan Precision@10 sebesar 0,02010, Recall sebesar 0,17567, dan Hit Rate sebesar 0,18524. Coverage sebesar 1,00000 menunjukkan bahwa

pendekatan tersebut berhasil menghasilkan rekomendasi pada seluruh skenario pengujian.

Kemampuan pendekatan Popularity dalam menghasilkan rekomendasi secara konsisten berasal dari penggunaan daftar produk populer sebagai sumber kandidat. Berbeda dengan Apriori yang bergantung pada keberadaan aturan asosiasi untuk produk pemicu tertentu, Popularity memiliki ruang kandidat yang lebih luas berdasarkan frekuensi pembelian produk pada data latih.

Pendekatan Hybrid memperoleh Precision@10 sebesar 0,02078, Recall sebesar 0,18250, Hit Rate sebesar 0,19207, dan Coverage sebesar 1,00000. Hasil tersebut merupakan nilai tertinggi di antara ketiga pendekatan pada evaluasi akhir.

Dibandingkan Popularity, Hybrid mengalami peningkatan Precision@10 sebesar 0,00068 dan Recall sebesar 0,00683. Peningkatan tersebut menunjukkan bahwa penggunaan kandidat berbasis aturan asosiasi sebagai prioritas, kemudian dilengkapi menggunakan popularitas, memberikan hasil evaluasi yang lebih baik pada skenario pengujian penelitian.

Meskipun demikian, selisih antara Hybrid dan Popularity relatif kecil. Oleh karena itu, hasil tersebut tidak dapat diartikan bahwa Apriori secara mandiri memiliki kinerja yang lebih baik daripada Popularity. Peningkatan yang diperoleh merupakan hasil dari kombinasi dua sumber kandidat rekomendasi.

Temuan ini memperlihatkan bahwa peran Apriori dalam pendekatan Hybrid adalah menyediakan kandidat berdasarkan keterkaitan produk historis, sedangkan Popularity membantu mempertahankan ketersediaan rekomendasi ketika kandidat asosiasi tidak mencukupi. Dengan demikian, pendekatan Hybrid dapat dipahami sebagai mekanisme rekomendasi gabungan yang mengutamakan pola asosiasi dan menggunakan popularitas sebagai pelengkap.

3.5 Analisis Coverage dan Keterbatasan Kandidat Apriori

Perbedaan Coverage antara Apriori dan dua pendekatan lainnya menjadi salah satu temuan utama penelitian.

Apriori memperoleh Coverage sebesar 0,11483, sedangkan Hybrid dan Popularity memperoleh Coverage sebesar 1,00000. Nilai tersebut menunjukkan bahwa Apriori hanya dapat menghasilkan rekomendasi pada sekitar 11,483% skenario pengujian, sementara dua pendekatan lainnya dapat menghasilkan rekomendasi pada seluruh skenario.

Perbedaan tersebut tidak hanya berkaitan dengan proses penyaringan kategori dan anggaran, tetapi juga dipengaruhi oleh ketersediaan kandidat sebelum penyaringan dilakukan.

Aturan asosiasi yang terbentuk berasal dari transaksi multi-produk yang jumlahnya

relatif kecil dibandingkan keseluruhan transaksi. Selain itu, tidak semua produk pemicu memiliki aturan asosiasi yang menghasilkan kandidat sesuai kategori dan anggaran pengguna.

Dalam kondisi tersebut, pendekatan Apriori tidak dapat menghasilkan rekomendasi ketika tidak terdapat kandidat yang memenuhi seluruh kriteria. Sebaliknya, Hybrid mengatasi keterbatasan tersebut melalui mekanisme fallback popularitas.

Hasil ini memperlihatkan bahwa penggunaan aturan asosiasi saja belum cukup untuk menjamin ketersediaan rekomendasi pada seluruh skenario. Penggabungan dengan pendekatan alternatif menjadi salah satu strategi untuk mengatasi keterbatasan tersebut.

Akan tetapi, Coverage yang tinggi tidak selalu menunjukkan bahwa seluruh rekomendasi memiliki relevansi yang tinggi. Coverage hanya menggambarkan keberhasilan sistem dalam menghasilkan rekomendasi, sedangkan Precision, Recall, dan Hit Rate memberikan informasi tambahan mengenai relevansi rekomendasi tersebut.

Oleh sebab itu, penilaian terhadap ketiga pendekatan perlu dilakukan dengan mempertimbangkan seluruh metrik secara bersamaan.

3.6 Analisis Stabilitas Berdasarkan Random Seed

Pengujian stabilitas dilakukan menggunakan lima nilai random seed, yaitu 42, 21, 7, 100, dan 2026. Tujuan pengujian adalah mengamati perubahan hasil evaluasi ketika pembagian transaksi latih dan transaksi uji dilakukan menggunakan nilai random seed yang berbeda. Hasil pengujian stabilitas yang tersimpan pada notebook ditampilkan pada Tabel 8.

Tabel 8. Ringkasan stabilitas berdasarkan lima random seed

Metode	Rata-rata Precision@10	Standar deviasi Precision	Rata-rata Recall	Standar deviasi Recall	Rata-rata F1@10
Apriori	0,0077	0,0011	0,0667	0,0082	0,0137
Hybrid	0,0231	0,0020	0,1882	0,0138	0,0411
Popularity	0,0223	0,0019	0,1810	0,0136	0,0397

Berdasarkan hasil tersebut, Hybrid memperoleh rata-rata Precision@10, Recall, dan F1-score@10 yang lebih tinggi dibandingkan Popularity pada pengujian lima random seed. Hasil pengujian per seed juga memperlihatkan bahwa Hybrid memperoleh nilai Precision, Recall, dan F1-score@10 yang lebih tinggi dibandingkan Popularity pada seluruh seed yang diuji.

Standar deviasi menunjukkan adanya perubahan hasil antar pembagian data. Namun, nilai rata-rata Hybrid yang lebih tinggi pada kelima pengujian memberikan indikasi bahwa

keunggulan pendekatan Hybrid terhadap Popularity tidak hanya muncul pada satu pembagian data tertentu.

Meskipun demikian, hasil stabilitas tersebut perlu ditafsirkan sesuai versi model yang diuji. Pengujian lima random seed pada notebook dilakukan sebelum pembaruan akhir pembentukan kandidat consequent pada Cell 33–35. Oleh karena itu, hasil stabilitas tersebut tidak boleh diklaim sebagai pengujian ulang terhadap konfigurasi kandidat terbaru yang menghasilkan Tabel 7.

Dengan demikian, Tabel 8 digunakan sebagai hasil pengujian stabilitas versi model sebelumnya, sedangkan Tabel 7 digunakan sebagai hasil evaluasi utama setelah perbaikan pembentukan kandidat. Pengujian stabilitas ulang terhadap versi model terakhir diperlukan apabila hasil stabilitas hendak dijadikan bukti konsistensi konfigurasi final.

3.7 Analisis Paired Cluster Bootstrap

Selain pengujian menggunakan beberapa random seed, notebook memuat analisis paired cluster bootstrap untuk membandingkan pendekatan Hybrid dan Popularity. Pengujian ini dilakukan dengan mengelompokkan skenario berdasarkan identitas transaksi agar pengambilan sampel ulang mempertahankan struktur pengelompokan transaksi.

Hasil yang tersimpan pada notebook ditampilkan pada Tabel 9.

Tabel 9. Hasil paired cluster bootstrap Hybrid terhadap Popularity

Metrik	Selisih rata-rata	Batas bawah CI 95%	Batas atas CI 95%
Precision@10	0,00098	0,00031	0,00182
Recall	0,00975	0,00310	0,01817
Hit Rate	0,00975	0,00310	0,01817

Hasil bootstrap menunjukkan bahwa selisih rata-rata antara Hybrid dan Popularity bernilai positif pada ketiga metrik yang dianalisis. Interval kepercayaan 95% juga berada di atas nol, yang menunjukkan bahwa pada pengambilan sampel ulang yang dilakukan, selisih kinerja cenderung mengarah pada keunggulan Hybrid.

Namun, hasil tersebut perlu dibaca bersama dengan batasan konfigurasi pengujiannya. Pengujian bootstrap pada notebook dilakukan sebelum pembaruan akhir pembentukan kandidat consequent. Jumlah transaksi berpasangan yang digunakan adalah 376 transaksi.

Dengan demikian, hasil bootstrap memberikan indikasi pendukung terhadap perbandingan Hybrid dan Popularity pada konfigurasi pengujian sebelumnya. Hasil ini belum

dapat dianggap sebagai pengujian signifikansi statistik final untuk konfigurasi rekomendasi yang diperbarui pada Cell 33–35.

Proporsi bootstrap positif sebesar 0,9995 juga tidak boleh ditafsirkan sebagai nilai p-value. Nilai tersebut menggambarkan proporsi pengulangan bootstrap yang menghasilkan selisih positif dalam prosedur yang digunakan.

3.8 Implikasi Hasil Penelitian

Hasil penelitian memberikan beberapa implikasi terhadap pengembangan sistem rekomendasi produk e-commerce.

Pertama, pola keterkaitan produk berdasarkan transaksi historis dapat dimanfaatkan sebagai sumber kandidat rekomendasi. Aturan asosiasi memberikan informasi mengenai hubungan antarproduk yang tidak dapat diperoleh hanya dengan mengurutkan produk berdasarkan popularitas.

Kedua, preferensi kategori dan batas anggaran dapat diterapkan sebagai mekanisme penyaringan untuk membatasi ruang rekomendasi. Dengan mekanisme tersebut, kandidat yang ditampilkan tidak hanya mempertimbangkan keterkaitan produk, tetapi juga memenuhi kategori dan batas harga yang ditentukan pengguna.

Ketiga, pendekatan Hybrid memperlihatkan potensi penggunaan beberapa sumber kandidat rekomendasi untuk mengatasi keterbatasan aturan asosiasi. Ketika kandidat Apriori tidak mencukupi, popularitas dapat digunakan sebagai pelengkap untuk menjaga ketersediaan rekomendasi.

Keempat, hasil penelitian menunjukkan bahwa karakteristik dataset berpengaruh terhadap penerapan algoritma. Dominasi transaksi satu produk membatasi jumlah transaksi yang dapat digunakan dalam pembentukan aturan asosiasi. Kondisi tersebut menjadi pertimbangan penting dalam menerapkan Association Rule Mining pada dataset e-commerce yang memiliki karakteristik transaksi serupa.

Secara keseluruhan, penelitian ini memperlihatkan bahwa pengembangan rekomendasi produk berdasarkan pola asosiasi perlu memperhatikan ketersediaan kandidat, preferensi kategori, dan batas anggaran. Kombinasi mekanisme tersebut dapat memberikan pendekatan rekomendasi yang lebih terarah dibandingkan penggunaan aturan asosiasi tanpa mekanisme penyaringan dan pelengkap.

3.9 Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan.Pertama, pembentukan aturan asosiasi hanya menggunakan transaksi yang memiliki lebih dari satu

produk. Dari 97.277 transaksi, hanya 3.178 transaksi yang digunakan dalam pembentukan model Apriori. Hal ini membatasi jumlah informasi keterkaitan produk yang dapat dipelajari.

Kedua, jumlah kandidat produk yang dihasilkan oleh aturan asosiasi masih terbatas. Kondisi tersebut menyebabkan pendekatan Apriori memiliki Coverage lebih rendah dibandingkan Popularity dan Hybrid.

Ketiga, harga estimasi kandidat menggunakan median harga produk berdasarkan data latih. Nilai tersebut tidak selalu menggambarkan harga aktual pada setiap transaksi atau harga produk terkini di platform e-commerce.

Keempat, pengujian dilakukan menggunakan data historis Olist dan belum diterapkan secara langsung pada platform e-commerce aktif. Oleh karena itu, penelitian ini belum mengukur pengaruh rekomendasi terhadap perilaku pengguna, tingkat konversi pembelian, maupun peningkatan penjualan.

Kelima, pengujian stabilitas dan bootstrap yang tersedia pada notebook dilakukan sebelum pembaruan terakhir pembentukan kandidat consequent. Oleh karena itu, hasil tersebut perlu diperbarui apabila hendak digunakan untuk menyatakan stabilitas konfigurasi final.

Keterbatasan tersebut menjadi dasar bagi penelitian lanjutan untuk mengembangkan model dengan cakupan transaksi yang lebih luas, memperkaya kandidat asosiasi, dan menguji rekomendasi menggunakan data interaksi pengguna yang lebih beragam.

D. KESIMPULAN

Penelitian ini menerapkan Association Rule Mining menggunakan algoritma Apriori untuk mendukung rekomendasi produk e-commerce dengan mempertimbangkan preferensi kategori dan batas anggaran pengguna. Berdasarkan hasil pengolahan Olist Brazilian E-Commerce Public Dataset, diperoleh 111.047 baris data transaksi yang valid, dengan 97.277 transaksi unik dan 32.341 produk unik. Dari keseluruhan transaksi tersebut, sebanyak 3.178 transaksi memiliki lebih dari satu produk dan digunakan dalam pembentukan model asosiasi.

Hasil penerapan Apriori pada data latih menghasilkan 93 aturan asosiasi dengan antecedent tunggal, 72 produk pemicu unik, dan 90 kandidat produk setelah seluruh consequent diperhitungkan. Kandidat rekomendasi selanjutnya disaring berdasarkan kategori produk dan batas anggaran yang ditentukan. Hasil audit menunjukkan bahwa mekanisme penyaringan telah memenuhi pemeriksaan kesesuaian kategori, batas harga, pengecualian produk pemicu, dan validitas metadata produk.

Berdasarkan evaluasi akhir setelah perbaikan pembentukan kandidat, pendekatan Hybrid memperoleh hasil terbaik dibandingkan pendekatan Popularity pada seluruh metrik utama yang diuji. Hybrid menghasilkan Precision@10 sebesar 0,02078, Recall sebesar 0,18250, Hit Rate sebesar 0,19207, Coverage sebesar 1,00000, dan F1-score@10 sebesar 0,03731. Sementara itu, Popularity memperoleh Precision@10 sebesar 0,02010, Recall sebesar 0,17567, Hit Rate sebesar 0,18524, Coverage sebesar 1,00000, dan F1-score@10 sebesar 0,03607. Hasil tersebut menunjukkan bahwa penggabungan kandidat berbasis aturan asosiasi dengan mekanisme fallback popularitas memberikan peningkatan hasil evaluasi dibandingkan penggunaan popularitas saja pada skenario pengujian penelitian.

Meskipun demikian, pendekatan Apriori secara mandiri memiliki keterbatasan dalam menghasilkan kandidat rekomendasi. Hal tersebut terlihat dari nilai Coverage sebesar 0,11483, yang lebih rendah dibandingkan Hybrid dan Popularity. Keterbatasan ini berkaitan dengan jumlah kandidat aturan asosiasi yang terbentuk dan karakteristik dataset yang didominasi transaksi satu produk. Dengan demikian, penggunaan mekanisme fallback popularitas berperan dalam menjaga ketersediaan rekomendasi ketika kandidat berbasis Apriori tidak mencukupi.

Secara keseluruhan, penelitian ini menunjukkan bahwa integrasi aturan asosiasi, preferensi kategori, dan batas anggaran dapat digunakan sebagai pendekatan dalam penyusunan rekomendasi produk e-commerce. Kontribusi pendekatan Hybrid terlihat pada kemampuannya menggabungkan keterkaitan produk berdasarkan transaksi historis dengan mekanisme popularitas untuk melengkapi kandidat rekomendasi. Namun, hasil penelitian belum dapat digunakan untuk menyimpulkan adanya peningkatan penjualan atau kepuasan pengguna karena aspek tersebut belum menjadi bagian dari pengujian.

Penelitian selanjutnya disarankan untuk menggunakan dataset dengan proporsi transaksi multi-produk yang lebih besar, mengembangkan strategi pembentukan kandidat asosiasi yang lebih luas, serta melakukan pengujian stabilitas ulang pada konfigurasi model terakhir. Selain itu, pengujian langsung kepada pengguna diperlukan untuk mengetahui relevansi rekomendasi dari sisi pengalaman dan kebutuhan konsumen.

E. DAFTAR PUSTAKA

[1] R. Agrawal and R. Srikant, “Fast algorithms for mining association rules in large databases,” in Proceedings of the 20th International Conference on Very Large Data Bases (VLDB), 1994, pp. 487–499.

[2] O. Dogan, "A recommendation system in e-commerce with profit-support fuzzy association rule mining (P-FARM)," Journal of Theoretical and Applied Electronic Commerce Research, vol. 18, no. 2, pp. 831–847, 2023, doi: 10.3390/jtaer18020043.

[3] D. Hu, R. Louca, L. Hong, and J. McAuley, "Learning within-session budgets from browsing trajectories," in Proceedings of the 12th ACM Conference on Recommender Systems (RecSys '18), 2018, doi: 10.1145/3240323.3240401.

[4] Olist, "Brazilian E-Commerce Public Dataset by Olist," Kaggle. [Online]. Available: https://www.kaggle.com/datasets/olistbr/brazilian-ecommerce. [Accessed: Nov. 8, 2026].

[5] 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, 2004, doi: 10.1145/963770.963772.

[6] A. Gunawardana and G. Shani, "A survey of accuracy evaluation metrics of recommendation tasks," Journal of Machine Learning Research, vol. 10, pp. 2935–2962, 2009.

[7] F. Ricci, L. Rokach, and B. Shapira, Eds., Recommender Systems Handbook, 3rd ed. Cham: Springer, 2022, doi: 10.1007/978-1-0716-2197-4.

[8] T. Sutabri, Analisis Sistem Informasi. Yogyakarta: Penerbit Andi, 2012.

[9] T. Sutabri and D. Napitupulu, Sistem Informasi Bisnis. Yogyakarta: Penerbit Andi, 2019.

[10] R. Juliansyah and T. Sutabri, "Eksplorasi e-commerce menemukan kunci sukses menarik pembeli di industri online," Scientica: Jurnal Ilmiah Sains dan Teknologi, vol. 2, no. 5, pp. 25–29, 2024, doi: 10.572349/scientica.v2i5.688.

[11] G. B. Putri, A. K. Diaz, and T. Sutabri, "Algoritma machine learning untuk klasifikasi review film pada IMDb," Dinamika Informatika: Jurnal Ilmiah Teknologi Informasi, vol. 15, no. 1, pp. 25–31, 2023, doi: 10.35315/informatika.v15i1.9355.