

Analisis Pola Pembelian pada Data Penjualan CanNgopi menggunakan Algoritma FP-Growth

Shanty Valencia^{1*}, Wahyu Tisno Atmojo²

^{1,2}Program Studi Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Pradita

*email: shanty.valencia@student.pradita.ac.id

DOI: <https://doi.org/10.31603/komtika.v8i2.12672>

Received: 18-11-2024, Revised: 29-11-2024, Accepted: 30-11-2024

ABSTRACT

CanNgopi faces challenges in determining the best-selling products and designing marketing strategies, such as bundling programs, due to the high volume of transactions and product variations. This study aims to analyze consumer purchasing behavior and identify items that are frequently bought together. Monthly transaction data were processed using RapidMiner through stages of preprocessing, frequent itemset analysis, and the application of the FP-Growth algorithm to generate association rules. The results of this analysis can be utilized to design more targeted marketing strategies, such as product recommendations based on customer purchasing patterns. The association rules show a support value of 0.13 (13%) and a confidence value of 0.97 (97%). The low support value indicates that this product combination does not frequently appear across all transactions, while the high confidence value reflects a strong likelihood that customers who purchase products in the snack, signature, and non-coffee categories will also buy the pasta package. This study also highlights the importance of data analysis and visualization in business decision-making. By utilizing the FP-Growth algorithm, CanNgopi can identify popular menu combinations, enhance customer experience, and optimize marketing strategies and business operations.

Keywords: Association Rules, Business, Data Analysis, FP-Growth, Purchasing Patterns.

ABSTRAK

CanNgopi menghadapi tantangan dalam menentukan produk yang paling laris dan merancang strategi pemasaran, seperti program bundling, akibat tingginya volume transaksi dan variasi produk. Penelitian ini bertujuan untuk menganalisis perilaku pembelian konsumen dan mengidentifikasi item yang sering dibeli bersama. Data transaksi bulanan diproses menggunakan RapidMiner, melalui tahapan preprocessing, analisis itemset frekuen, dan penerapan algoritma FP-Growth untuk menghasilkan aturan asosiasi. Hasil analisis ini dapat dimanfaatkan untuk merancang strategi pemasaran yang lebih tepat sasaran, seperti rekomendasi produk berdasarkan pola pembelian pelanggan. Hasil aturan asosiasi menunjukkan nilai support sebesar 0,13 (13%) dan nilai confidence sebesar 0,97 (97%). Nilai support yang rendah mengindikasikan bahwa kombinasi produk ini tidak sering muncul di seluruh transaksi, sedangkan nilai confidence yang tinggi mencerminkan kemungkinan besar bahwa pelanggan yang membeli produk dalam kategori snack, signature, dan non-coffee juga akan membeli paket pasta. Penelitian ini juga menyoroti pentingnya analisis data dan visualisasi dalam pengambilan keputusan bisnis. Dengan menggunakan algoritma FP-Growth, CanNgopi dapat mengidentifikasi kombinasi menu yang populer, meningkatkan pengalaman pelanggan, serta mengoptimalkan strategi pemasaran dan operasional bisnis.

Kata Kunci: Aturan Asosiasi, Bisnis, Analisis Data, FP-Growth, Pola Pembelian.

PENDAHULUAN

Dalam bisnis ritel diperlukan berbagai macam strategi serta kreatifitas yang unik dengan tujuan agar dapat meningkatkan performa omzet bisnis [1]. Pengelolaan data penjualan yang tepat dapat membantu perusahaan dalam memahami perilaku konsumen, khususnya pola pembelian. Pola pembelian adalah kecenderungan atau kebiasaan konsumen dalam membeli

produk-produk tertentu secara bersamaan [2]. pola pembelian dapat memberikan informasi yang berguna bagi bisnis untuk mengidentifikasi preferensi konsumen dan mengoptimalkan strategi penjualan. Dengan menganalisis pola ini, perusahaan dapat membuat keputusan yang lebih baik terkait promosi produk, penempatan produk, dan strategi pemasaran yang sering terjadi. Pemanfaatan data penjualan ini dapat mendukung pengambilan keputusan yang lebih baik dalam strategi pemasaran, pengelolaan stok, hingga peningkatan layanan pelanggan [3].

CanNgopi, sebagai salah satu bisnis kuliner, juga dihadapkan pada tantangan untuk mengoptimalkan operasionalnya melalui pemanfaatan data penjualan yang dimiliki [4]. Melalui data tersebut, CanNgopi dapat menganalisis pola pembelian pelanggan, seperti produk yang sering dibeli bersama, frekuensi pembelian, hingga preferensi produk berdasarkan waktu. Namun, tanpa analisis yang tepat, data penjualan tersebut hanya menjadi kumpulan angka yang kurang bermakna. Meskipun pelaporan hasil penjualan dan data transaksi penjualan biasanya hanya sekedar arsip dan tidak diketahui manfaatnya di masa depan, namun hasil penjualan dapat digunakan untuk memprediksi permintaan konsumen terhadap suatu barang [5].

Laporan Cara efektif untuk menganalisis pola pembelian adalah dengan menggunakan algoritma FP-Growth (Frequent Pattern Growth). Pertumbuhan FP merupakan suatu cara untuk menggambarkan pola pembelian konsumen dan barang-barang yang sering terjadi secara bersamaan, terutama barang-barang yang sering dibeli konsumen, sehingga memungkinkan data dianalisis dengan menentukan pola-pola terkait [6]. Algoritma ini memungkinkan identifikasi item-item yang sering muncul bersamaan dalam transaksi, sehingga dapat membantu dalam memahami asosiasi antar produk [7]. Penerapan FP-Growth memungkinkan pengelola CanNgopi untuk mendapatkan wawasan mendalam mengenai preferensi konsumen dan memaksimalkan peluang penjualan berdasarkan temuan pola-pola tersebut.

Untuk mempermudah proses analisis, RapidMiner sebuah alat analisis data yang mendukung berbagai algoritma *data mining*. Dengan RapidMiner, proses ekstraksi pola dari data penjualan dapat dilakukan lebih cepat dan efisien tanpa memerlukan kemampuan pemrograman yang mendalam [8]. Dengan latar belakang ini, penelitian ini menganalisis pola pembelian menggunakan algoritma FP-Growth, sebuah algoritma data mining untuk mengidentifikasi kumpulan item yang sering ditemukan dalam kumpulan dataset transaksi. Dengan menggunakan RapidMiner [9] untuk menganalisis data penjualan di CanNgopi. Hasil penelitian ini diharapkan dapat memberikan rekomendasi strategis kepada manajemen untuk meningkatkan penjualan dan kepuasan pelanggan [10].


Penelitian sebelumnya menunjukkan berbagai pendekatan dalam menganalisis pola pembelian konsumen menggunakan algoritma data mining. Robby Takdirillah mengungkapkan bahwa penerapan algoritma Apriori dalam menganalisis data transaksi dapat memberikan wawasan yang mendalam untuk mendukung strategi penjualan yang lebih efektif [11]. Eling Che Vidiya dan Gusmelia Testiana lebih lanjut menyoroti efektivitas algoritma Apriori dengan menghasilkan pola pembelian yang memiliki nilai support sebesar 0,320 (32%) dan confidence 0,941 (94,1%), yang menunjukkan bahwa algoritma ini mampu menghasilkan aturan korelasi yang relevan dalam konteks pemasaran [12]. Selain itu, Ike Septi Nindyaa mengusulkan penggunaan kombinasi algoritma Apriori dan ECLAT untuk merekomendasikan desain produk yang lebih tepat sasaran berdasarkan aturan asosiasi yang dihasilkan [13].

Namun, meskipun algoritma Apriori banyak digunakan, penelitian ini berkontribusi dengan menerapkan algoritma FP-Growth yang lebih efisien dalam menangani dataset besar. Berbeda dengan penelitian-penelitian sebelumnya yang cenderung berfokus pada analisis pola transaksi, penelitian ini juga melibatkan tahapan penting lainnya seperti normalisasi data, pembentukan frequent itemset, serta evaluasi aturan asosiasi [14]. Selain itu, penggunaan RapidMiner sebagai platform analisis memberikan kemudahan dalam visualisasi data yang lebih mudah dipahami, serta mendukung proses analisis yang lebih sistematis dan terstruktur.

Hasil penelitian ini tidak hanya menghasilkan rekomendasi produk yang lebih sesuai dengan pola pembelian pelanggan, tetapi juga memberikan wawasan strategis yang dapat diimplementasikan oleh pelaku bisnis untuk meningkatkan efektivitas pemasaran dan kepuasan pelanggan [15]. Dengan menggunakan algoritma FP-Growth, kafe seperti CanNgopi dapat mengidentifikasi kombinasi menu yang sering dipesan bersama, sehingga dapat merancang paket menu yang lebih menarik dan relevan bagi pelanggan.

METODE

Penelitian ini dilakukan melalui beberapa tahapan, yaitu: perencanaan dan studi literatur, pengumpulan data, pra-pemrosesan data, pemrosesan data, analisis, dan pembahasan. Tahapan pertama adalah pengumpulan data, yang terdiri dari data sekunder berupa transaksi penjualan di CanNgopi sebanyak 345 transaksi selama bulan September 2024.



Gambar 1. Metode Penelitian

Tahapan pertama adalah pengambilan data, yang terdiri dari data sekunder berupa transaksi penjualan di CanNgopi sebanyak 345 transaksi selama bulan September 2024. Data transaksi mencakup kategori dan item, seperti pada Tabel 1.

Tabel 1. Transaksi Data

Outlet	Category	Items
Can Ngopi SDC	Pasta, Non-Coffee, Snack, Pasta	Aglio e Olio, Iced Milo Dinosaur, French Fries, Aglio e Olio
Can Ngopi SDC	Signature	Fried Kwetiaw
Can Ngopi SDC	Coffee	Iced Latte
Can Ngopi SDC	Snack, Non-Coffee, Dessert, Pizza	French Fries, Air Mineral, Sausage & Mushroom Pizza
Can Ngopi SDC	Signature	Yang Chow Fried Rice
Can Ngopi SDC	Burger & Sandwich, Snack, Burger & Sandwich, Snack	Potato Wedges, Philly Cheesesteak Burger, Potato Wedges
Can Ngopi SDC	Snack, Snack, Non-Coffee, Snack	Fish Finger, Mozzarella Fries, Air Mineral, French Fries
Can Ngopi SDC	Coffee, Signature	Kopi Susu Can Ngopi, Yang Chow Fried Rice
Can Ngopi SDC	Non-Coffee, Non-Coffee	Iced Matcha, Iced Lemon Tea
Can Ngopi SDC	Signature, Non-Coffee	XO fried rice, Air Mineral
Can Ngopi SDC	Coffee	Hot Americano
Can Ngopi SDC	Signature	Philly beef fried rice
Can Ngopi SDC	Pasta	Bolognaise

Data yang digunakan dalam penelitian ini mencakup informasi kategori makanan dan menu yang tersedia di CanNgopi, seperti pada Tabel 2.

Tabel 2. Kategori Produk CanNgopi

No	Kategori makanan	Menu
1	Pasta	Aglio E Olio, Bolognese, Lasagna
2	Non-Coffee	Air Mineral, Choco Mint, Ice Cube, Matcha, Tea, Lemon Tea, Iced Milo Dinosaur, Thai Tea
3	Coffee	Coffee Strawberry, Espresso, Hazelnut Latte, Americano, Cappuccino, Latte Ice, Kopi Enak Banget, Affogato
4	Snack	Banana Cake Slice, Cheesy Cassava, Chicken Bomb, Chicken Wing, Cireng Cocoli, Potato Wedges
5	Breakfast	Egg Benedict, French Toast, Omelette and Beef Sausage, Pancake
6	Baked Rice Cheesy	Cheesy Fish Rise, Cheesy Chicken Rice, Cheesy Beef Rice
7	Dessert	Apple Pie A La Mode, Cheese Cake, Creme Brulee, Flavours Pudding, Ice Cream
8	Mocktail	Pineapple Cooler, Purple Squash, Rosemary Jasmine Tea, Shirley Temple, Virgin Mojito
9	Pizza	Philly Beef Pizza, Sausage & Mushroom Pizza, Chicken Bechamel Pizza
10	Burger & Sandwich	Philly Cheesesteak Burger, Roasted Chicken Burger, Crispy Chicken Burger, Croque Monsieur, Croque Monsieur
11	Soup	Mushroom Cream Soup, Zuppa Soup
345	Signature	Traditional Fried Rice, XO Fried Rice, Yang Chow Fried Rice, Kwetiau Siram, Soto Ayam

Tahap pra-pemrosesan data meliputi beberapa tahapan sebagai berikut:

a. Pembersihan Data (*Data Cleaning*)

Proses ini adalah menghapus data duplikat dan tidak relevan, menangani nilai kosong menggunakan metode pengisian seperti rata-rata, median, atau interpolasi, dan memperbaiki format data agar konsisten, seperti penyeragaman format tanggal atau angka menggunakan excel.

b. Normalisasi

Normalisasi data bertujuan untuk menyamakan skala data agar analisis lebih akurat. Metode yang digunakan meliputi *Min-Max Normalization* dan *Z-Score Normalization*.


c. Transformasi Data

Discretization Mengonversi data kontinu menjadi kategori, Generasi atribut baru berdasarkan formula tertentu, Penggabungan atau pemisahan atribut sesuai kebutuhan, Mengubah data menjadi bentuk biner (0 dan 1) agar dapat diproses oleh RapidMiner, terutama untuk algoritma yang membutuhkan format data biner, seperti analisis asosiasi menggunakan algoritma FP-Growth.

Tahap pemrosesan data dengan FP-Growth meliputi identifikasi itemset sering (*Frequent Itemset*), penerapan FP-Growth dan penentuan asosiasi rule. *Frequent Itemset* adalah kumpulan item (*itemset*) dalam *dataset* yang sering muncul bersama-sama dengan frekuensi kemunculan melebihi ambang batas tertentu yang disebut *minimum support threshold*. Dalam konteks data mining, frequent itemset adalah langkah penting dalam algoritma seperti Apriori atau FP-Growth untuk menemukan hubungan atau pola tersembunyi dalam data transaksi [16].

Tujuan utama dari proses ini adalah menemukan kombinasi item yang sering muncul bersama dalam suatu dataset transaksi. Hasil dari identifikasi ini biasanya digunakan untuk memahami pola pembelian, menyusun strategi pemasaran, atau merancang rekomendasi produk.

Algoritma FP-Growth adalah metode dalam data mining untuk menemukan pola item dalam data transaksi. FP-Growth bekerja secara efisien tanpa perlu memindai *dataset* berkali-kali seperti beberapa algoritma lainnya, karena menggunakan struktur data khusus yang disebut FP-Tree (*Frequent Pattern Tree*). FP-Growth berbeda dengan Apriori dalam hal pendekatan pencarian *frequent itemset*. Apriori menghasilkan kandidat *itemset* dan memindai dataset berkali-kali, sementara FP-Growth menggunakan struktur FP-Tree untuk langsung mengekstrak *frequent itemset* tanpa menghasilkan kandidat [17]. Selain itu, Apriori memerlukan banyak pemindaian dataset, sedangkan FP-Growth hanya memindai dataset dua kali, menjadikannya lebih efisien. Dengan menggunakan FP-Tree, FP-Growth memproses data lebih cepat dan efisien dibandingkan Apriori, yang tidak menggunakan struktur data khusus. Karena itu, FP-Growth lebih unggul dalam kecepatan dan efisiensi, terutama untuk dataset yang besar. Tahapan dalam algoritma FP-Growth seperti pada Gambar 2.



Gambar 2. Flowchart Algoritma FP-Growth

Association Rule adalah teknik dalam data mining yang digunakan untuk menemukan hubungan atau pola asosiasi antar *item* dalam dataset, terutama dalam konteks transaksi. Aturan asosiasi ini digunakan untuk menggali pola pembelian atau perilaku lainnya yang terjadi bersamaan dalam data, seperti dalam analisis pasar atau rekomendasi produk. Secara umum, aturan asosiasi memiliki bentuk $\{Item\ A\} \rightarrow \{Item\ B\}$ yang artinya, jika *Item A* dibeli, maka ada kemungkinan besar *Item B* juga akan dibeli. Aturan ini menghubungkan dua item atau lebih yang sering muncul bersama dalam suatu transaksi.

Tujuan utama dari aturan asosiasi adalah untuk mengungkap pola dan hubungan dalam data, serta menemukan informasi yang mungkin belum diketahui oleh Perusahaan. Proses mendapatkan aturan asosiasi dimulai dengan pencarian *frequent itemset*, yaitu kombinasi item yang paling sering muncul, yang harus memenuhi kriteria minimum *support* dan *confidence*. Untuk menilai kekuatan aturan asosiasi, dua ukuran utama yang digunakan adalah *support* dan *confidence*. *Support* mengukur frekuensi kemunculan kombinasi *item* dalam seluruh transaksi.

Untuk menghitung nilai *support* dari item A dan B, digunakan rumus seperti pada persamaan (1).

$$Support(itemset) = \frac{Jumlah\ transaksi\ itemset}{Jumlah\ transaksi\ dataset} \quad (1)$$

Confidence menunjukkan seberapa besar kemungkinan item B akan dibeli jika item A dibeli. Rumus untuk menghitung *confidence* seperti pada persamaan (2).

$$Confidence(A \rightarrow B) = \frac{Support(A \cup B)}{Support(A)} \quad (2)$$

Selain itu, *lift ratio* dapat digunakan untuk mengevaluasi seberapa besar keterkaitan antara item A dan B dibandingkan dengan kondisi jika keduanya *independent*

$$Lift(A \rightarrow B) = \frac{Confidence(A \rightarrow B)}{Support(B)} \quad (3)$$

Nilai *confidence* (A, B) memberikan gambaran tentang seberapa kuat hubungan antar item dalam konteks pembelian di CanNgopi, yang dapat memberikan wawasan penting untuk strategi pemasaran dan penataan produk.

HASIL DAN PEMBAHASAN

Data hasil pengumpulan 345 transaksi pembelian pada bulan September 2024 ditampilkan pada Tabel 3. Dengan berbagai jenis item menu. Item-item tersebut berasal dari berbagai kategori, termasuk *pasta*, *non-coffee*, *coffee*, *snack*, *signature*, *soup*, *burger & sandwich*, *pizza*, *mocktail*, *dessert*, *baked rice cheesy*, *breakfast*, serta minuman khas lainnya seperti "*Aglio e Olio*," "*Iced Latte*," "*French Fries*," "*Yang Chow Fried Rice*," dan "*Kopi Susu Can Ngopi*." Setiap transaksi mencatat kombinasi item yang berbeda sesuai dengan pesanan yang dilakukan oleh pelanggan.

Tabel 3. Data Transaksi Pembelian

Outlet	Category	Items
Can Ngopi SDC	Non-Coffee, Snack, Pasta	Aglio E Olio, Bolognese, Lasagna
Can Ngopi SDC	Snack, Non-Coffee, Signature	Chicken Wing, Iced Tea, Philly beef fried rice
Can Ngopi SDC	Pasta, Coffee	Bolognese, Coffee strawberry
Can Ngopi SDC	Signature, Pasta	Philly beef fried rice, Aglio e Olio
Can Ngopi SDC	Pasta	Aglio e Olio

Proses pra-pemrosesan data meliputi pembersihan, normalisasi, dan transformasi data. Pembersihan data dilakukan dengan menghapus duplikat dan data yang tidak relevan, serta menangani nilai kosong dengan menggantinya menggunakan rata-rata atau fitur Go To Special → Blanks. Format data yang tidak konsisten, seperti tanggal dan angka, dapat diperbaiki menggunakan Text to Columns atau rumus TRIM, dan data yang tidak relevan dapat dihapus. Normalisasi bertujuan menyamakan skala data agar lebih akurat, menggunakan metode seperti *Min-Max Normalization* (mengubah nilai ke rentang tertentu) dan *Z-Score Normalization*

(mengubah data ke distribusi standar). Transformasi data mencakup discretization (mengonversi data kontinu menjadi kategori), pembuatan atribut baru, serta penggabungan atau pemisahan atribut sesuai kebutuhan. Untuk beberapa algoritma, seperti FP-Growth dalam analisis asosiasi, data perlu diubah menjadi format binomial (0 dan 1) seperti pada Tabel 4.

Tabel 4. Data Transaksi dalam Binomial

Breakfast	Pasta	Non-Coffee	Coffee	Soup	Snack	Signature
0	1	1	0	0	1	0
0	0	1	0	0	1	1
0	1	0	1	0	0	0
0	1	0	0	0	0	1
0	0	0	1	0	0	0
0	1	0	0	0	0	0

Hasil *frequent itemset* diperoleh melalui proses analisis FP-Growth seperti pada Tabel 5. *Frequent Itemset* ini menjadi dasar untuk membangun aturan asosiasi yang lebih kompleks, seperti mencari kombinasi item yang sering dibeli bersama. Hasil ini dapat dimanfaatkan untuk memahami pola pembelian pelanggan dan membantu pengelola bisnis dalam merancang strategi pemasaran yang lebih efektif, seperti menawarkan promosi *bundling* untuk kategori yang sering muncul bersamaan atau memperkuat stok item yang paling banyak diminati.

Tabel 5. FP-Growth

Item 1	Item 2	Item 3	Item 4
Snack	Pasta		
Snack	Signature		
Signature	Coffee		
Pasta	Snack	Signature	
Pasta	Signature	Coffee	Snack

Nilai *support* dan *confidence* untuk setiap aturan asosiasi ditampilkan pada Tabel 6. Nilai *confidence* tertinggi mencapai 0,968 (96,8%), dengan nilai *support* sebesar 0,319 (31,9%). Dalam analisis ini, nilai *minimum support* yang diterapkan adalah 0,2 (20%), sementara nilai *minimum confidence* yang ditetapkan adalah 0,5 (50%). Selanjutnya, penerapan algoritma FP-Tree dapat diamati pada Gambar 7, yang menyajikan hasil visual dari tahapan analisis tersebut. Support mengukur frekuensi kemunculan kombinasi item dalam seluruh transaksi. Untuk menghitung nilai support dari item A dan B menggunakan rumus persamaan 1. Jika kombinasi (A, B) muncul di 110 dari 345 transaksi maka $support = \frac{110}{345} = 0,319$ atau 31,9%. *Confidence* menunjukkan seberapa besar kemungkinan item B akan dibeli jika item A dibeli. Jika (A, B) muncul di 110 transaksi, dan A muncul di 114 transaksi, $confidence = \frac{110}{114} = 0,968$ atau 96,8%. Selain itu, *lift ratio* dapat digunakan untuk mengevaluasi seberapa besar keterkaitan antara item A dan B dibandingkan dengan kondisi jika keduanya independen. Nilai *lift* > 1 berarti ada hubungan positif antara kedua item.


Tabel 6. Nilai *Support* dan *Confidence*

Premises	Conclusion	Support	Confidence
Soup	Pasta,Snack	0.052	0.857
Signature, Coffee	Pasta	0.064	0.857
Snack, Signature,Coffee	Pasta	0.064	0.857
Signature	Snack	0.378	0.977
Pasta,Signature, Coffee	Snack	0.064	0.857
Pasta, Signature	Snack	0.319	0.882
Non-Coffee	Pasta	0.404	0.927
Snack, Non-Coffee	Pasta	0.298	0.933
Non-Coffee, Signature	Pasta	0.149	0.933
Non-Coffee, Signature	Pasta,Snack	0.149	0.933
Signature	Pasta	0.362	0.944
Snack,Coffee	Pasta	0.213	0.952
Snack	Pasta	0.723	0.958
Coffee	Pasta	0.287	0.964
Snack, Signature	pasta	0.319	0.968

Penerapan FP-Tree dijelaskan pada data penjualan seperti pada Gambar 3 yang menunjukkan hasil visualisasi dari FP-Tree dan menggambarkan hubungan antar *item* dalam data transaksi berdasarkan aturan asosiasi. Setiap *node* mewakili item (misalnya Coffee, Pasta, Snack) dan panah menunjukkan hubungan antar *item* dengan aturan yang dihasilkan.

Setiap aturan (*rule*) ditampilkan dengan nilai *support* dan *confidence*. *Support* menunjukkan seberapa sering kombinasi item muncul, sementara *confidence* mengukur seberapa besar kemungkinan item B dibeli jika item A dibeli. Contohnya, Pasta dan Snack memiliki banyak aturan yang menghubungkannya, dengan nilai *confidence* tinggi, menunjukkan hubungan yang kuat antara keduanya.

Association rules dengan nilai *confidence* tertinggi dijelaskan pada Gambar 4 yang menunjukkan hasil *association rules* dari FP-Growth. Setiap aturan ($A \rightarrow B$) menggambarkan hubungan antar *item*, dengan nilai *confidence* menunjukkan kekuatan hubungan. Contoh: [Coffee] $\rightarrow$ [Non-Coffee] (*confidence*: 0.509) berarti pembelian *Coffee* sering diikuti oleh *Non-Coffee* (50.9%). Pola ini dapat digunakan untuk promosi dan *cross-selling*.



Gambar 3. Penerapan *FP-Tree*

```
[Signature] --> [Snack] (confidence: 0.861)
[Signature, Coffee] --> [Pasta] (confidence: 0.875)
[Signature, Coffee] --> [Snack] (confidence: 0.875)
[Pasta, Signature] --> [Snack] (confidence: 0.882)
[Non-Coffee] --> [Pasta] (confidence: 0.927)
[Snack, Non-Coffee] --> [Pasta] (confidence: 0.933)
[Non-Coffee, Signature] --> [Pasta] (confidence: 0.933)
[Non-Coffee, Signature] --> [Snack] (confidence: 0.933)
[Non-Coffee, Signature] --> [Pasta, Snack] (confidence: 0.933)
[Signature] --> [Pasta] (confidence: 0.944)
[Snack, Coffee] --> [Pasta] (confidence: 0.952)
[Snack] --> [Pasta] (confidence: 0.958)
[Coffee] --> [Pasta] (confidence: 0.964)
[Snack, Signature] --> [Pasta] (confidence: 0.968)
```

Gambar 4. Association Rule

Association rules dengan confidence tertinggi dalam analisis FP-Growth disajikan pada Gambar 5. Semua aturan memiliki hubungan kuat dengan target *item* Pasta.

```
[Signature] --> [Pasta] (confidence: 0.944)
[Snack, Coffee] --> [Pasta] (confidence: 0.952)
[Snack] --> [Pasta] (confidence: 0.958)
[Coffee] --> [Pasta] (confidence: 0.964)
[Snack, Signature] --> [Pasta] (confidence: 0.968)
```

Gambar 5. Pengujian Association Rule dengan nilai Support dan Confidence Tertinggi

[Snack, Signature] → [Pasta] memiliki confidence tertinggi (0.968) yang menunjukkan kombinasi ini hampir selalu diikuti oleh pembelian Pasta. Hasil ini menunjukkan pola belanja yang sangat relevan untuk strategi promosi atau rekomendasi.

KESIMPULAN

Berdasarkan penerapan dan pengujian yang telah dilakukan, dapat disimpulkan bahwa analisis pola pembelian di CanNgopi menggunakan data transaksi penjualan dan algoritma FP-Growth melalui RapidMiner menghasilkan temuan yang berarti. Hasil aturan asosiasi menunjukkan nilai support sebesar 0,319 (31,9%) dan nilai confidence sebesar 0,965 (96,5%). Nilai support yang rendah menunjukkan bahwa kombinasi produk ini tidak terlalu sering muncul dalam seluruh transaksi, sementara nilai confidence yang tinggi mencerminkan kemungkinan yang sangat besar bahwa pelanggan yang membeli produk dalam kategori snack, signature juga akan membeli paket pasta. Temuan ini menunjukkan adanya korelasi signifikan antara kombinasi produk tersebut dalam kebiasaan belanja pelanggan. Melalui analisis data dan visualisasi menggunakan FP-Growth, CanNgopi dapat mengidentifikasi kombinasi menu yang populer, meningkatkan pengalaman pelanggan, dan mengoptimalkan strategi pemasaran serta operasional bisnis.

DAFTAR PUSTAKA

- [1] F. Achmad, O. Nurdiawan, and Y. A. Wijaya, "Analisa pola transaksi pembelian konsumen pada toko ritel kesehatan menggunakan algoritma FP-Growth," *Jurnal Mahasiswa Teknik Informatika*, vol. 7, no. 1, pp. 168–175, 2023.
- [2] I. Afriani and I. Ali, "Implementasi data mining terhadap data penjualan pada industri kuliner menggunakan algoritma FP-Growth," *Jurnal Teknik Elektro dan Informatika*, vol. 18, no. 1, pp. 40–49, 2023.
- [3] D. A. Istiqomah, Y. Astuti, and S. Nurjanah, "Implementasi algoritma FP-Growth dan Apriori untuk persediaan produk," *Jurnal Informatika Polinema*, vol. 8, no. 2, pp. 37–42, 2022, doi: 10.33795/jip.v8i2.845.
- [4] R. Y. Mail and F. Ferdiansyah, "Implementasi algoritma frequent growth (FP-Growth) menentukan asosiasi antar produk," Universitas Bina Darma, Palembang, 2023.
- [5] Z. Munawar and T. F. Rozi, "Membangun aplikasi pelaporan penjualan berbasis web dan android (Studi Kasus di Fried Chicken Dynasty)," *Jurnal Informatika*, vol. 6, no. 1, pp. 1–10, 2019, doi: 10.55222/computing.v6i1.33.
- [6] M. R. Nahjan, N. Heryana, and A. Voutama, "Implementasi RapidMiner dengan metode clustering K-Means untuk analisa penjualan pada Toko OJ Cell," *JATI*, vol. 7, no. 1, pp. 1–7, 2023, doi: 10.30865/json.v4i1.4894.
- [7] E. Nurarofah, R. Herdiana, and N. D. Nuris, "Penerapan asosiasi menggunakan algoritma FP-Growth pada pola transaksi penjualan di Toko Roti," *Jurnal Komputerisasi Akuntansi*, vol. 7, no. 1, pp. 1–10, 2023.
- [8] B. S. Pranata, B. Darma, D. P. Utomo, and A. Voutama, "Penerapan data mining algoritma FP-Growth untuk persediaan sparepart pada bengkel motor (Studi Kasus Bengkel Sinar Service)," *Jurnal Sistem dan Informatika*, vol. 1, no. 2, pp. 1–7, 2020, doi: 10.30865/json.v4i1.4894.
- [9] F. Prasetyo, H. Hasugian, and A. Voutama, "Analisis pola pembelian produk makanan menggunakan algoritma FP-Growth untuk strategi penjualan," *Jurnal IDEALIS*, vol. 7, no. 1, 2024, doi: 10.30865/json.v4i1.4894.

- [10] S. Sutanto and H. Dunan, "Analisis strategi promosi dalam meningkatkan penjualan kopi pada Cafe Sweetcup Coffee, Bandar Lampung," *Jurnal Ekonomi dan Bisnis*, vol. 6, no. 2, 2023.
- [11] R. Takdirillah, "Penerapan Data Mining Menggunakan Algoritma Apriori Terhadap Data Transaksi Sebagai Pendukung Informasi Strategi Penjualan," *Edumatic: Jurnal Pendidikan Informatika*, vol. 4, no. 1, pp. 37–46, Jun. 2020, doi: 10.29408/edumatic.v4i1.2081.
- [12] E. C. Vidiya and G. Testiana, "Analisis pola pembelian di Lathansa Cafe & Ramen dengan menggunakan algoritma FP-Growth berbantuan RapidMiner," *G-Tech: Jurnal Teknologi Terapan*, vol. 7, no. 3, pp. 1118–1126, 2023, doi: 10.33795/jip.v8i2.845.
- [13] I. S. Nindyaa, G. Testiana, and I. D. Jaya, "Implementasi algoritma apriori dan eclat (equivalence class transformation) pada data transaksi penjualan," *Sistem Informasi*, UIN Raden Fatah Palembang, Aug. 2023.
- [14] L. C. Sumartini, D. F. A. Tias, B. Darma, and A. Voutama, "Analisis kepuasan konsumen untuk meningkatkan volume penjualan Kedai Kopi Kala Senja," *E-Bisnis*, vol. 3, no. 2, 2019, doi: 10.37339/e-bis.v3i2.124.
- [15] R. P. Aditya, F. Fahrullah, and N. W. W. Sari, "Implementasi algoritma apriori untuk rekomendasi paket menu pada Cafe ABC berbasis website," *Jurnal Komputer dan Informatika*, vol. 11, no. 2, 2023.
- [16] D. Astuti and S. Samsinar, "Penentuan rekomendasi paket promosi menggunakan algoritma frequent pattern growth di The Java Cafe," *Jurnal Sistem Informasi*, vol. 12, no. 3, 2023.
- [17] P. S. Sinaga, "Analisis penjualan jam tangan dengan metode FP-Growth pada Radatime Ringroad Citywalk," *Jurnal Teknologi Informasi*, vol. 3, no. 2, 2023.

