

Analisis Pola Pembelian Menu Coffee Shop Menggunakan Algoritma FP-Growth sebagai Dasar Rekomendasi Menu pada Sistem Kasir

Martianova Lusia Sihombing^{1*}, Marchel Hamonangan Ritonga² Darwis Robinson Manalu³

^{1*} Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Methodist Indonesia, Kota Medan, Provinsi Sumatera Utara, Indonesia.

^{2,3} Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Methodist Indonesia, Kota Medan, Provinsi Sumatera Utara, Indonesia.

Corresponding Email: novalusia362@gmail.com^{1*}

Histori Artikel:

Dikirim 05 Juli 2026; *Diterima dalam bentuk revisi* 15 Agustus 2026; *Diterima* 26 Agustus 2026; *Diterbitkan* 28 September 2026. Semua hak dilindungi oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) STMik Indonesia Banda Aceh.

Abstrak

Data transaksi dalam sistem kasir memiliki potensi tidak hanya sebagai pencatatan penjualan, tetapi juga untuk mengidentifikasi pola pembelian pelanggan yang dapat mendukung pengambilan keputusan bisnis. Sayangnya, pemanfaatan data transaksi di coffee shop seringkali terbatas pada laporan penjualan, sehingga keterkaitan antar menu belum dimanfaatkan secara optimal. Penelitian ini bertujuan untuk menganalisis pola pembelian menu dengan algoritma Frequent Pattern Growth (FP-Growth) dan menginterpretasikan aturan asosiasi yang dihasilkan sebagai dasar rekomendasi menu pada sistem kasir. Menggunakan pendekatan kuantitatif dan metode deskriptif, penelitian ini menganalisis dataset publik The Bread Basket yang berisi lebih dari 9.000 transaksi. Data dipraproses dengan RapidMiner Studio melalui tahapan seleksi atribut dan transformasi. Algoritma FP-Growth diterapkan dengan parameter minimum support 5% dan minimum confidence 20%, menghasilkan dua aturan asosiasi: Bread → Coffee dan Cake → Coffee. Aturan Cake → Coffee menunjukkan hubungan positif dengan nilai support 0,055 dan confidence 0,527, sedangkan Bread → Coffee tidak menunjukkan hubungan positif meskipun memiliki support lebih tinggi. Temuan ini menunjukkan bahwa algoritma FP-Growth efektif dalam mengidentifikasi pola pembelian yang mendukung logika rekomendasi menu.

Kata Kunci: Association Rule Mining; Fp-Growth; Market Basket Analysis; Rekomendasi Menu; Sistem Kasir.

Abstract

Transaction data in cash register systems has the potential to serve not only as sales records but also to identify customer purchasing patterns that can support business decision-making. Unfortunately, the utilization of transaction data in coffee shops is often limited to sales reports, resulting in suboptimal use of the relationships between menu items. This study aims to analyze menu purchasing patterns using the Frequent Pattern Growth (FP-Growth) algorithm and to interpret the resulting association rules as a basis for menu recommendations in the cash register system. Employing a quantitative approach and descriptive methods, this research analyzes the public dataset The Bread Basket, which contains over 9,000 transactions. Data preprocessing was conducted using RapidMiner Studio through attribute selection and transformation stages. The FP-Growth algorithm was applied with a minimum support parameter of 5% and a minimum confidence of 20%, yielding two association rules: Bread → Coffee and Cake → Coffee. The Cake → Coffee rule demonstrates a positive relationship with a support value of 0.055 and confidence of 0.527, while Bread → Coffee does not indicate a positive association despite having a higher support value. These findings suggest that the FP-Growth algorithm is effective in identifying purchasing patterns that support menu recommendation logic.

Keyword: Association Rule Mining; FP-Growth; Market Basket Analysis; Menu Recommendation; Cash Register System.

1. Pendahuluan

Digitalisasi proses bisnis telah meningkatkan jumlah data transaksi yang dihasilkan oleh sistem kasir pada berbagai sektor usaha, termasuk industri makanan dan minuman. Data transaksi tersebut tidak lagi hanya berfungsi sebagai media pencatatan penjualan, tetapi juga menjadi sumber informasi yang dapat dimanfaatkan untuk memahami perilaku pembelian pelanggan. Kebutuhan pemanfaatan data tersebut semakin relevan karena sektor penyediaan makanan dan minuman memiliki jumlah usaha yang besar dan tingkat persaingan yang tinggi di Indonesia (Badan Pusat Statistik, 2025). Setiap transaksi yang tersimpan berpotensi memberikan informasi mengenai jenis menu yang sering dibeli, kombinasi item dalam satu pembelian, serta kecenderungan permintaan pelanggan terhadap menu tertentu. Apabila data tersebut dianalisis secara tepat, pelaku usaha dapat memperoleh dasar yang lebih kuat dalam menyusun strategi penjualan dan layanan.

Usaha coffee shop menjadi salah satu jenis bisnis kuliner yang memiliki variasi produk cukup banyak, seperti kopi sebagai sajian utama, serta *bread*, *pastry*, dan *cake* sebagai menu pendamping. Batas operasional antara coffee shop dan *bakery-cafe* modern saat ini semakin melebur, di mana keduanya saling mengandalkan kombinasi minuman dan makanan ringan untuk meningkatkan penjualan. Namun, dalam praktik bisnis sehari-hari, data transaksi dari sistem kasir umumnya masih digunakan sebatas untuk menghitung pendapatan, mengidentifikasi menu terlaris, atau membuat laporan periodik. Padahal, data transaksi juga dapat memperlihatkan pola keterkaitan antar menu yang dibeli pelanggan secara bersamaan. Informasi semacam ini penting karena dapat membantu pelaku usaha merancang paket menu, strategi *cross-selling*, dan rekomendasi menu pendamping secara lebih berbasis data. Oleh karena itu, diperlukan suatu metode analisis yang mampu mengekstraksi pola pembelian dari data transaksi sehingga menghasilkan informasi yang dapat mendukung pengambilan keputusan, seperti penyusunan strategi *cross-selling* maupun rekomendasi menu.

Untuk mengubah data transaksi menjadi informasi yang bernilai, salah satu pendekatan yang banyak digunakan adalah *data mining*. *Data mining* merupakan proses sistematis untuk menggali dan mengidentifikasi pola, hubungan, maupun informasi yang bernilai dari kumpulan data dalam jumlah besar dengan memanfaatkan berbagai teknik analisis, seperti statistik, *machine learning*, *kecerdasan buatan*, dan sistem basis data. Proses ini bertujuan menghasilkan pengetahuan baru yang valid, bermanfaat, serta dapat digunakan sebagai dasar dalam pengambilan keputusan. Selain itu, *data mining* merupakan salah satu tahapan penting dalam proses *Knowledge Discovery in Databases* (KDD), yang berfokus pada ekstraksi pengetahuan dari data yang sebelumnya belum diketahui (Hewage *et al.*, 2023; Srirahayu & Pribadie, 2023).

Dalam penerapan *data mining*, berbagai teknik dapat digunakan sesuai dengan tujuan analisis yang ingin dicapai. Untuk mengidentifikasi hubungan atau keterkaitan antar item pada data transaksi, salah satu teknik yang banyak digunakan adalah *association rule mining*. Teknik ini bertujuan menemukan hubungan atau pola keterkaitan antar item dalam suatu basis data transaksi melalui pembentukan aturan asosiasi (*association rules*). Aturan tersebut menunjukkan kecenderungan kemunculan suatu item atau sekumpulan item secara bersamaan dengan item lainnya, sehingga pola pembelian pelanggan yang sebelumnya tidak terlihat dapat diidentifikasi dan dimanfaatkan sebagai dasar pengambilan keputusan. Aturan asosiasi umumnya dinyatakan dalam bentuk $X \rightarrow Y$, dengan X sebagai antecedent dan Y sebagai consequent, sedangkan kekuatan hubungan antar item dievaluasi menggunakan ukuran support, confidence, dan lift (Jr Iztok *et al.*, 2023; Mokkaem *et al.*, 2023).

Untuk memperoleh aturan asosiasi secara efisien, diperlukan algoritma yang mampu menemukan *frequent itemsets* dengan waktu komputasi yang lebih singkat. Salah satu algoritma yang banyak digunakan untuk membentuk aturan asosiasi adalah *Frequent Pattern Growth* (FP-Growth). Algoritma ini dikembangkan untuk menemukan *frequent itemsets* secara efisien melalui pembentukan struktur *Frequent Pattern Tree* (FP-Tree) tanpa menghasilkan *candidate itemsets*. Pendekatan tersebut mampu mengurangi jumlah pemindaian basis data dan kompleksitas komputasi, sehingga proses penambangan pola menjadi lebih cepat dibandingkan metode yang masih bergantung pada pembangkitan *candidate itemset*, terutama ketika diterapkan pada dataset transaksi berukuran besar.

Karakteristik tersebut menjadikan FP-Growth banyak dipilih dalam analisis data transaksi dibandingkan algoritma yang masih bergantung pada pembangkitan *candidate itemsets* (Fernandez-Basso *et al.*, 2024; Lin *et al.*, 2011). Dengan karakteristik tersebut, FP-Growth menjadi salah satu algoritma yang banyak digunakan untuk menganalisis pola pembelian pada data transaksi, khususnya dalam penerapan *Market Basket Analysis*.

Efektivitas algoritma FP-Growth dalam menemukan pola asosiasi telah banyak dibuktikan melalui berbagai penelitian yang menerapkan pendekatan *Market Basket Analysis*. Berbagai penelitian menunjukkan bahwa pendekatan ini mampu menghasilkan aturan asosiasi yang dapat dimanfaatkan untuk mendukung rekomendasi produk, penyusunan paket penjualan, serta strategi *cross-selling* yang lebih efektif (Merliani *et al.*, 2022; Saputra *et al.*, 2023). Selain itu, penerapan *Market Basket Analysis* juga terbukti memberikan informasi mengenai kombinasi produk yang sering dibeli secara bersamaan sehingga dapat menjadi dasar dalam pengambilan keputusan bisnis pada berbagai sektor ritel maupun kuliner (Alfitra *et al.*, 2024; Amelia *et al.*, 2024; Putra *et al.*, 2024; Wulandari *et al.*, 2025). Pada sektor kuliner, penerapan FP-Growth telah digunakan untuk mengidentifikasi pola pemesanan pelanggan, menyusun rekomendasi menu, hingga mendukung strategi pemasaran berbasis data (Annur *et al.*, 2025; Fahreza *et al.*, 2025; Hidayatullah *et al.*, 2024). Selain itu, penelitian Hery dan Widjaja (2024) menunjukkan bahwa FP-Growth memiliki efisiensi yang lebih baik dibandingkan *Apriori* dalam menemukan *frequent itemsets* pada data transaksi.

Walaupun berbagai penelitian telah membuktikan efektivitas algoritma FP-Growth dalam menemukan pola pembelian pelanggan, sebagian besar penelitian masih berfokus pada identifikasi aturan asosiasi sebagai hasil akhir analisis atau sebagai dasar penyusunan strategi pemasaran dan paket penjualan. Pemanfaatan aturan asosiasi tersebut sebagai dasar penyusunan logika rekomendasi menu yang dapat diintegrasikan ke dalam sistem kasir masih relatif terbatas. Oleh karena itu, penelitian ini tidak hanya menghasilkan aturan asosiasi dari pola pembelian pelanggan, tetapi juga menafsirkan aturan yang memenuhi nilai *support*, *confidence*, dan *lift* sebagai dasar penyusunan logika rekomendasi menu yang dapat diimplementasikan pada sistem kasir. Dengan demikian, penelitian ini tidak hanya berkontribusi pada analisis pola pembelian pelanggan, tetapi juga memberikan rancangan pemanfaatan hasil aturan asosiasi sebagai dasar pengembangan fitur rekomendasi menu pada sistem kasir.

Untuk mengimplementasikan tujuan tersebut, penelitian ini menggunakan dataset *The Bread Basket* yang merupakan data transaksi nyata dari sebuah *bakery* di Edinburgh. Dataset tersebut dipilih karena memuat transaksi pembelian berbagai produk makanan dan minuman yang memiliki karakteristik serupa dengan menu yang umum dijumpai pada *coffee shop* modern, sehingga relevan untuk menganalisis pola pembelian menu (Mittal, n.d.). Berdasarkan latar belakang tersebut, penelitian ini bertujuan menganalisis pola pembelian menu pada *coffee shop* menggunakan algoritma FP-Growth terhadap dataset *The Bread Basket* untuk menghasilkan aturan asosiasi berdasarkan nilai *support*, *confidence*, dan *lift* sebagai dasar penyusunan logika rekomendasi menu pada sistem kasir.

2. Metode Penelitian

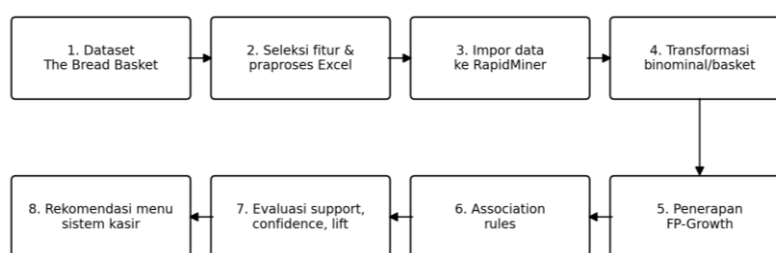
Penelitian ini menggunakan pendekatan kuantitatif dengan metode deskriptif untuk menganalisis pola pembelian menu berdasarkan data transaksi menggunakan algoritma *Frequent Pattern Growth* (FP-Growth). Pendekatan kuantitatif digunakan karena proses analisis menghasilkan ukuran numerik berupa nilai *support*, *confidence*, dan *lift* sebagai indikator kekuatan aturan asosiasi. Sementara itu, metode deskriptif digunakan untuk mengidentifikasi dan menafsirkan pola keterkaitan antar menu yang muncul pada data transaksi tanpa melakukan pengujian hubungan kausal antarvariabel. Tahapan penelitian meliputi pengumpulan dataset, praproses data, penerapan algoritma FP-Growth, pembentukan aturan asosiasi, serta evaluasi hasil sebagai dasar penyusunan logika rekomendasi menu pada sistem kasir.

Penelitian ini menggunakan dataset publik *The Bread Basket* yang diperoleh melalui platform *Kaggle*. Dataset tersebut merupakan data transaksi nyata dari *The Bread Basket*, sebuah *bakery* yang berlokasi di Edinburgh, dengan total 20.507 baris data yang merepresentasikan lebih dari 9.000 transaksi penjualan. Dataset terdiri atas empat atribut utama, yaitu *Transaction*, *Item*, *Date*, dan *Time* (Mittal, n.d.). Dataset dipilih karena memuat transaksi berbagai produk makanan dan minuman yang memiliki karakteristik serupa dengan menu yang umum dijumpai pada coffee shop, sehingga relevan untuk menganalisis pola pembelian pelanggan menggunakan algoritma FP-Growth. Karakteristik dataset yang digunakan pada penelitian ini disajikan pada Tabel 1.

Tabel 1. Karakteristik Dataset Penelitian

Aspek	Keterangan
Nama dataset	<i>The Bread Basket</i>
Sumber data	<i>Kaggle</i>
Jenis data	Data sekunder transaksi penjualan menu <i>bakery-cafe</i>
Jumlah entri awal	20.507 entri
Jumlah transaksi unik	9.465 transaksi
Jumlah item unik	94 item
Atribut awal	<i>Date</i> , <i>Time</i> , <i>Transaction</i> , <i>Item</i>
Atribut yang digunakan	<i>Transaction</i> dan <i>Item</i>
Perangkat pengolahan	<i>Excel</i> untuk seleksi fitur dan praproses; <i>RapidMiner</i> untuk FP-Growth dan <i>association rules</i>
Fokus analisis	Kombinasi item menu yang dibeli dalam satu transaksi

Tahapan penelitian disusun secara sistematis untuk memastikan proses pembentukan aturan asosiasi menggunakan algoritma FP-Growth dapat dilakukan secara terstruktur dan menghasilkan informasi yang sesuai dengan tujuan penelitian. Proses penelitian dimulai dari pengumpulan dataset, dilanjutkan dengan tahap praproses data, pembentukan *frequent itemsets* menggunakan algoritma FP-Growth, pembentukan aturan asosiasi (*association rules*), serta evaluasi aturan berdasarkan nilai *support*, *confidence*, dan *lift*. Alur penelitian secara keseluruhan ditunjukkan pada Gambar 1.




Gambar 1. Alur Penelitian

Berdasarkan tahapan penelitian pada Gambar 1, proses analisis diawali dengan tahap praproses (*preprocessing*) untuk menyiapkan data transaksi agar sesuai dengan kebutuhan algoritma FP-Growth. Tahap ini bertujuan meningkatkan kualitas data, menghilangkan inkonsistensi, serta mentransformasikan data transaksi ke dalam format yang dapat diproses untuk pembentukan *frequent itemsets* dan aturan asosiasi. Seluruh proses praproses dilakukan menggunakan perangkat lunak *RapidMiner Studio*.

Tahap praproses diawali dengan pemuatan dataset menggunakan operator *Retrieve*, kemudian atribut *Transaction* ditetapkan sebagai identitas transaksi melalui operator *Set Role*. Selanjutnya, data ditransformasikan menggunakan operator *Pivot* sehingga setiap transaksi direpresentasikan sebagai kombinasi item yang dibeli. Nilai yang tidak memiliki item pada suatu transaksi ditangani

menggunakan operator *Replace Missing Values*, kemudian seluruh data dikonversi ke dalam format biner (*binominal*) menggunakan operator *Numerical to Binominal* agar sesuai dengan kebutuhan algoritma FP-Growth. Tahapan ini menghasilkan struktur data yang siap digunakan dalam proses pembentukan *frequent itemsets*.



Gambar 2. Alur Operator RapidMiner dalam Penerapan Algoritma FP-Growth

Konfigurasi operator yang digunakan pada setiap tahapan implementasi algoritma FP-Growth di *RapidMiner* disajikan pada Tabel 2. Konfigurasi tersebut menjelaskan fungsi masing-masing operator sehingga proses analisis dapat direplikasi pada penelitian selanjutnya.

Tabel 2. Konfigurasi Operator RapidMiner Berdasarkan File Proses .rmp

No.	Operator RapidMiner	Konfigurasi/Fungsi
1	<i>Retrieve Dataset_BreadBasket</i>	Mengambil dataset dari <i>Local Repository RapidMiner</i> .
2	<i>Set Role</i>	Menetapkan <i>Transaction</i> sebagai id.
3	<i>Pivot</i>	Group by <i>Transaction</i> , <i>Item</i> menjadi kolom, dan aggregation count untuk membentuk matriks basket.
4	<i>Replace Missing Values</i>	Mengganti nilai kosong hasil pivot dengan 0.
5	<i>Numerical to Binominal</i>	Mengubah hasil hitung item menjadi format binominal/dummy coded columns.
6	<i>FP-Growth</i>	Input format: items in dummy coded columns; minimum support: 0.05; opsi find min number of itemsets dinonaktifkan agar ambang support diterapkan secara ketat.
7	<i>Create Association Rules</i>	Criterion: confidence; minimum confidence: 0.20.

Setelah proses praproses selesai dilakukan, pembentukan *frequent itemsets* dan aturan asosiasi dilakukan menggunakan algoritma FP-Growth. Pada penelitian ini digunakan nilai minimum *support* sebesar 5% dan minimum *confidence* sebesar 20%. Nilai minimum *support* digunakan untuk menyaring kombinasi item yang memiliki frekuensi kemunculan memadai dalam keseluruhan transaksi, sedangkan minimum *confidence* digunakan untuk memastikan bahwa aturan asosiasi yang dihasilkan memiliki tingkat kepercayaan yang cukup untuk dianalisis lebih lanjut. Parameter tersebut dipilih untuk memperoleh aturan asosiasi yang representatif tanpa menghasilkan terlalu banyak aturan yang kurang relevan terhadap pola pembelian pelanggan. Nilai minimum *support* sebesar 5% dan minimum *confidence* sebesar 20% dipilih agar aturan asosiasi yang dihasilkan tidak terlalu sedikit maupun terlalu banyak sehingga tetap mampu merepresentasikan pola pembelian pelanggan secara optimal.

Tabel 3. Parameter Pengujian FP-Growth

Parameter	Nilai	Keterangan
Minimum support	0.05 atau 5%	Ambang kemunculan minimum kombinasi item dalam seluruh transaksi
Minimum confidence	0.20 atau 20%	Ambang keyakinan minimum hubungan antecedent terhadap consequent
Lift ratio	> 1	Digunakan untuk memilih aturan yang memiliki hubungan positif
Find min number of itemsets	Tidak diaktifkan	Digunakan agar minimum <i>support</i> 0.05 tetap menjadi ambang utama dan hasil tidak berubah karena pencarian jumlah itemset minimum.

Aturan asosiasi yang dihasilkan selanjutnya dievaluasi menggunakan tiga ukuran utama, yaitu *support*, *confidence*, dan *lift*. Ketiga ukuran tersebut digunakan untuk menilai frekuensi kemunculan kombinasi item, tingkat kepercayaan suatu aturan, serta kekuatan hubungan antara antecedent dan consequent. Perhitungan masing-masing ukuran dilakukan menggunakan Persamaan (1), Persamaan (2), dan Persamaan (3).

Persamaan (1) Support

$$Support(X \rightarrow Y) = \frac{n(X \cap Y)}{N}$$

dengan:

- $Support(X \rightarrow Y)$ = nilai support aturan asosiasi
- $n(X \cap Y)$ = jumlah transaksi yang mengandung item X dan Y secara bersamaan
- N = jumlah seluruh transaksi

Nilai support menunjukkan proporsi kemunculan kombinasi item X dan Y terhadap keseluruhan transaksi. Semakin besar nilai support, semakin sering kombinasi item tersebut muncul pada dataset.

Persamaan (2) Confidence

$$Confidence(X \rightarrow Y) = \frac{n(X \cap Y)}{n(X)}$$

dengan:

- $Confidence(X \rightarrow Y)$ = nilai confidence aturan asosiasi
- $n(X \cap Y)$ = jumlah transaksi yang mengandung X dan Y
- $n(X)$ = jumlah transaksi yang mengandung X

Nilai *confidence* menunjukkan tingkat kepercayaan bahwa item Y akan muncul apabila item X telah muncul dalam suatu transaksi.

Persamaan (3) Lift

$$Lift(X \rightarrow Y) = \frac{Confidence(X \rightarrow Y)}{Support(Y)}$$

dengan:

- $Lift(X \rightarrow Y)$ = nilai lift aturan asosiasi
- $Confidence(X \rightarrow Y)$ = nilai confidence aturan

$Support(Y)$ = nilai support item Y

Berdasarkan Tabel 4, algoritma *FP-Growth* menghasilkan dua aturan asosiasi yang memenuhi nilai minimum *support* sebesar 5% dan minimum *confidence* sebesar 20%. Selanjutnya, masing-masing aturan dianalisis berdasarkan nilai *support*, *confidence*, dan *lift* untuk menentukan kekuatan hubungan antaritem serta kelayakannya sebagai dasar rekomendasi menu pada sistem kasir. Meskipun aturan ini memiliki frekuensi kemunculan yang relatif tinggi dibandingkan aturan lainnya, nilai *lift* yang lebih kecil dari 1 menunjukkan bahwa kemunculan *Coffee* tidak dipengaruhi secara positif oleh pembelian *Bread*. Dengan demikian, hubungan antara kedua item tersebut tidak cukup kuat untuk dijadikan dasar rekomendasi menu pada sistem kasir.

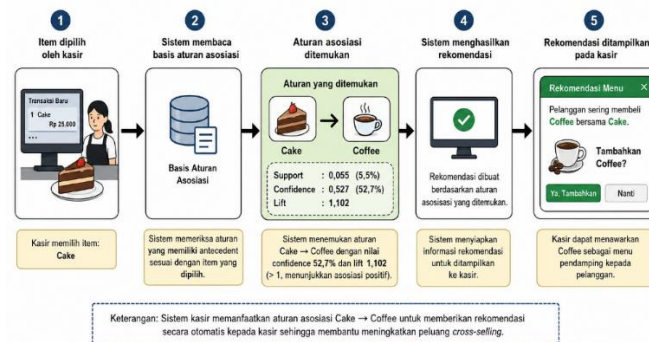
Aturan *Cake* → *Coffee* menghasilkan nilai *support* sebesar 0,055, *confidence* sebesar 0,527, dan *lift* sebesar 1,102. Nilai *support* menunjukkan bahwa kombinasi *Cake* dan *Coffee* muncul pada sekitar 5,5% dari seluruh transaksi. Nilai *confidence* sebesar 52,7% mengindikasikan bahwa lebih dari separuh transaksi yang mengandung *Cake* juga disertai pembelian *Coffee*. Selain itu, nilai *lift* yang lebih besar dari 1 menunjukkan bahwa pembelian *Cake* meningkatkan peluang munculnya *Coffee* dibandingkan dengan peluang kemunculan *Coffee* secara umum. Oleh karena itu, aturan *Cake* → *Coffee* menunjukkan hubungan asosiasi yang positif dan layak dijadikan dasar rekomendasi menu pendamping pada sistem kasir.

Perbandingan kedua aturan menunjukkan bahwa nilai *support* yang lebih tinggi tidak selalu menghasilkan aturan asosiasi yang lebih baik. Meskipun aturan *Bread* → *Coffee* memiliki nilai *support* lebih besar dibandingkan *Cake* → *Coffee*, nilai *lift* yang berada di bawah 1 menunjukkan bahwa hubungan antara kedua item tersebut tidak memiliki asosiasi positif. Sebaliknya, aturan *Cake* → *Coffee* memiliki *support* yang lebih rendah, tetapi didukung oleh nilai *confidence* yang lebih tinggi dan *lift* di atas 1, sehingga menunjukkan hubungan yang lebih kuat dan lebih relevan untuk diterapkan sebagai dasar rekomendasi menu. Hasil ini menunjukkan bahwa evaluasi aturan asosiasi sebaiknya tidak hanya mempertimbangkan frekuensi kemunculan (*support*), tetapi juga memperhatikan tingkat kepercayaan (*confidence*) dan kekuatan hubungan (*lift*) agar rekomendasi yang dihasilkan lebih akurat.

3.1.3 Implikasi Hasil terhadap Rekomendasi Menu pada Sistem Kasir

Hasil aturan asosiasi yang diperoleh pada penelitian ini tidak hanya memberikan informasi mengenai pola pembelian pelanggan, tetapi juga dapat dimanfaatkan sebagai dasar penyusunan logika rekomendasi menu pada sistem kasir. Aturan *Cake* → *Coffee* yang memiliki nilai *support* sebesar 0,055, *confidence* sebesar 0,527, dan *lift* sebesar 1,102 menunjukkan adanya hubungan positif antara kedua item sehingga layak digunakan sebagai dasar pemberian rekomendasi secara otomatis. Dalam implementasinya, ketika kasir memasukkan item *Cake* ke dalam transaksi, sistem dapat melakukan pemeriksaan terhadap basis aturan asosiasi yang telah terbentuk. Apabila ditemukan aturan *Cake* → *Coffee*, sistem akan menampilkan rekomendasi kepada kasir untuk menawarkan *Coffee* sebagai menu pendamping kepada pelanggan. Mekanisme tersebut memungkinkan rekomendasi diberikan secara konsisten berdasarkan pola transaksi yang diperoleh dari data historis, bukan semata-mata berdasarkan pengalaman atau intuisi kasir.

Pendekatan ini berpotensi mendukung strategi *cross-selling* karena rekomendasi diberikan berdasarkan hubungan antaritem yang telah teridentifikasi melalui proses *data mining*. Dengan demikian, sistem kasir tidak hanya berfungsi sebagai alat pencatatan transaksi, tetapi juga sebagai sistem pendukung keputusan yang membantu meningkatkan peluang penjualan produk pendamping berdasarkan pola pembelian pelanggan. Implementasi konseptual aturan asosiasi pada sistem kasir ditunjukkan pada Gambar 4. Ilustrasi tersebut menggambarkan alur pemanfaatan aturan *Cake* → *Coffee* sebagai dasar pemberian rekomendasi menu pendamping secara otomatis ketika kasir melakukan proses transaksi.



Gambar 4. Ilustrasi Logika Rekomendasi Menu pada Sistem Kasir Berdasarkan Aturan Asosiasi

Berdasarkan ilustrasi tersebut, sistem kasir dapat memberikan rekomendasi menu secara otomatis berdasarkan aturan asosiasi yang telah terbentuk. Pendekatan ini memungkinkan proses *cross-selling* dilakukan secara lebih konsisten karena rekomendasi didasarkan pada pola pembelian historis pelanggan, bukan hanya pada pengalaman atau intuisi kasir. Dengan demikian, hasil analisis tidak berhenti pada identifikasi pola transaksi, tetapi juga dapat dimanfaatkan sebagai dasar pengembangan fitur rekomendasi menu pada sistem kasir.

3.1.4 Pembahasan Hasil Penelitian

Hasil penelitian menunjukkan bahwa kualitas suatu aturan asosiasi tidak dapat ditentukan hanya berdasarkan tingginya nilai *support*. Aturan dengan frekuensi kemunculan yang tinggi belum tentu memiliki hubungan yang kuat apabila nilai *lift* menunjukkan hubungan yang tidak positif. Oleh karena itu, evaluasi aturan asosiasi perlu mempertimbangkan kombinasi nilai *support*, *confidence*, dan *lift* agar aturan yang dipilih benar-benar mencerminkan keterkaitan antaritem yang bermakna. Temuan penelitian ini memperlihatkan bahwa aturan *Cake* → *Coffee* lebih layak digunakan sebagai dasar rekomendasi dibandingkan *Bread* → *Coffee* karena memiliki hubungan asosiasi yang positif. Hasil tersebut menunjukkan bahwa algoritma *FP-Growth* tidak hanya mampu menemukan kombinasi item yang sering muncul, tetapi juga membantu mengidentifikasi hubungan antarproduk yang memiliki potensi untuk dimanfaatkan dalam strategi *cross-selling*.

Hasil penelitian ini sejalan dengan penelitian Hery dan Widjaja (2024) yang menunjukkan bahwa algoritma *FP-Growth* mampu menghasilkan aturan asosiasi untuk mengidentifikasi pola pembelian pelanggan pada dataset *The Bread Basket*. Namun demikian, penelitian ini memiliki fokus yang berbeda karena tidak hanya berhenti pada identifikasi pola transaksi, tetapi juga menginterpretasikan aturan asosiasi sebagai dasar penyusunan logika rekomendasi menu yang dapat diintegrasikan ke dalam sistem kasir. Dengan demikian, penelitian ini memberikan kontribusi tambahan berupa pemanfaatan hasil *association rule mining* sebagai pendukung pengambilan keputusan dalam proses pelayanan penjualan.

3.1.5 Keterbatasan Penelitian

Meskipun penelitian ini berhasil menghasilkan aturan asosiasi yang dapat dimanfaatkan sebagai dasar rekomendasi menu pada sistem kasir, masih terdapat beberapa keterbatasan yang perlu diperhatikan dalam menginterpretasikan hasil penelitian. Pertama, dataset yang digunakan merupakan dataset publik *The Bread Basket* yang berasal dari sebuah *bakery* di Edinburgh, sehingga karakteristik transaksi yang diperoleh belum sepenuhnya merepresentasikan pola pembelian pada coffee shop di Indonesia. Oleh karena itu, hasil aturan asosiasi yang diperoleh berpotensi berbeda apabila diterapkan pada dataset transaksi dari coffee shop dengan karakteristik pelanggan dan variasi menu yang berbeda. Kedua, penelitian ini menggunakan parameter minimum *support* sebesar 5% dan minimum *confidence* sebesar 20% dalam proses pembentukan aturan asosiasi. Pemilihan parameter tersebut menghasilkan dua aturan asosiasi yang memenuhi kriteria analisis. Penggunaan

nilai parameter yang berbeda dimungkinkan menghasilkan jumlah maupun karakteristik aturan asosiasi yang berbeda sehingga dapat memberikan alternatif rekomendasi menu yang lebih beragam. Ketiga, penelitian ini membatasi pemanfaatan hasil analisis pada penyusunan logika rekomendasi menu sebagai rancangan konseptual. Implementasi rekomendasi ke dalam sistem kasir serta pengujian terhadap pengguna belum dilakukan sehingga efektivitas rekomendasi dalam meningkatkan penjualan maupun keberhasilan strategi *cross-selling* belum dapat dievaluasi secara empiris.

Berdasarkan keterbatasan tersebut, penelitian selanjutnya disarankan menggunakan data transaksi dari coffee shop lokal dengan jumlah transaksi yang lebih besar, mengevaluasi beberapa kombinasi nilai minimum *support* dan minimum *confidence*, serta mengembangkan dan menguji implementasi fitur rekomendasi menu secara langsung pada sistem kasir. Pengujian terhadap pengguna maupun evaluasi dampak rekomendasi terhadap peningkatan nilai transaksi juga dapat dilakukan untuk memperoleh gambaran yang lebih komprehensif mengenai efektivitas penerapan algoritma *FP-Growth* dalam mendukung pengambilan keputusan pada bisnis coffee shop.

3.2 Pembahasan

Tahap praproses data sangat penting dalam menyiapkan dataset untuk algoritma *FP-Growth*, yang sejalan dengan penelitian sebelumnya oleh Alfitra et al. (2024) yang menekankan pentingnya analisis keranjang belanja untuk mempersiapkan data sebelum penerapan algoritma. Proses praproses yang dilakukan meliputi seleksi atribut, transformasi data transaksi ke dalam bentuk matriks transaksi, penanganan nilai kosong, dan konversi data ke format binominal. Seperti yang dijelaskan oleh Amelia et al. (2024), pemilihan atribut yang tepat, yakni hanya menggunakan *Transaction* dan *Item*, memungkinkan analisis lebih fokus pada hubungan antaritem, sehingga meningkatkan efisiensi analisis.

Transformasi data ke dalam bentuk matriks menggunakan operator *Pivot* di *RapidMiner Studio* merupakan langkah yang penting, karena memungkinkan representasi setiap transaksi sebagai kombinasi item yang dibeli. Penanganan nilai kosong dengan mengubah nilai yang tidak memiliki item menjadi 0 juga penting untuk memastikan matriks transaksi terwakili dengan baik, sebagaimana diungkapkan oleh Fahreza et al. (2025) dalam penerapan *market basket analysis*. Konversi data ke format binominal memastikan bahwa setiap item direpresentasikan berdasarkan keberadaan atau ketidakteradaannya, yang sangat sesuai untuk algoritma *FP-Growth*.

Setelah tahap praproses selesai, dataset dianalisis menggunakan algoritma *FP-Growth* untuk membentuk *frequent itemsets* dan menghasilkan aturan asosiasi. Dengan menetapkan nilai minimum *support* sebesar 5% dan minimum *confidence* sebesar 20%, hasil analisis menunjukkan bahwa algoritma *FP-Growth* menghasilkan dua aturan asosiasi yang memenuhi kriteria tersebut, yaitu aturan *Bread* → *Coffee* dan *Cake* → *Coffee*. Temuan ini sejalan dengan penelitian Hery dan Widjaja (2024), yang menunjukkan bahwa algoritma *FP-Growth* mampu menemukan pola pembelian yang relevan dalam konteks penjualan.

Meskipun aturan *Bread* → *Coffee* memiliki nilai *support* yang lebih tinggi, nilai *lift* yang lebih rendah menunjukkan bahwa pembelian *Coffee* tidak dipengaruhi secara positif oleh pembelian *Bread*, sehingga tidak layak dijadikan dasar rekomendasi menu. Sebaliknya, aturan *Cake* → *Coffee* menunjukkan bahwa kombinasi ini muncul pada sekitar 5,5% dari seluruh transaksi, dan lebih dari separuh transaksi yang mengandung *Cake* juga melibatkan pembelian *Coffee*. Nilai *lift* yang lebih besar dari 1 menandakan bahwa pembelian *Cake* meningkatkan kemungkinan pembelian *Coffee*, menjadikannya dasar rekomendasi menu yang lebih valid. Penelitian ini juga mendukung temuan Hidayatullah et al. (2024) yang menunjukkan bahwa analisis aturan asosiasi dapat digunakan untuk memprediksi menu yang dipesan di kafe.

Hasil aturan asosiasi ini dapat dimanfaatkan untuk menyusun logika rekomendasi menu dalam sistem kasir. Dalam praktiknya, ketika kasir memasukkan item *Cake* ke dalam transaksi, sistem dapat memeriksa basis aturan asosiasi yang telah terbentuk. Jika aturan *Cake* → *Coffee* ditemukan, sistem akan menampilkan rekomendasi kepada kasir untuk menawarkan *Coffee* sebagai menu pendamping. Pendekatan ini mendukung strategi *cross-selling* yang lebih efektif, karena rekomendasi diberikan

berdasarkan hubungan antaritem yang telah teridentifikasi melalui proses *data mining*, seperti yang dijelaskan oleh Saputra et al. (2023).

4. Kesimpulan dan Saran

Penelitian ini berhasil menganalisis pola pembelian menu menggunakan algoritma *Frequent Pattern Growth* (FP-Growth) pada dataset *The Bread Basket*. Melalui proses praproses data dan pembentukan aturan asosiasi dengan parameter minimum *support* sebesar 5% dan minimum *confidence* sebesar 20%, diperoleh dua aturan asosiasi yang memenuhi kriteria analisis, yaitu *Bread* → *Coffee* dan *Cake* → *Coffee*. Hasil evaluasi menunjukkan bahwa aturan *Cake* → *Coffee* merupakan aturan yang paling layak digunakan sebagai dasar rekomendasi menu karena memiliki nilai *support* sebesar 0,055, *confidence* sebesar 0,527, dan *lift* sebesar 1,102 yang menunjukkan adanya hubungan asosiasi positif. Sebaliknya, meskipun aturan *Bread* → *Coffee* memiliki nilai *support* yang lebih tinggi, nilai *lift* di bawah 1 menunjukkan bahwa hubungan antaritem tersebut tidak cukup kuat untuk digunakan sebagai dasar rekomendasi. Hasil penelitian menunjukkan bahwa algoritma *FP-Growth* mampu mengidentifikasi pola pembelian pelanggan yang dapat dimanfaatkan sebagai dasar penyusunan logika rekomendasi menu pada sistem kasir. Penerapan aturan asosiasi tersebut berpotensi mendukung strategi *cross-selling* dengan memberikan rekomendasi menu pendamping berdasarkan pola transaksi historis pelanggan. Dengan demikian, penelitian ini menunjukkan bahwa pemanfaatan teknik *association rule mining* tidak hanya menghasilkan informasi mengenai pola pembelian pelanggan, tetapi juga dapat mendukung pengembangan fitur rekomendasi menu sebagai bagian dari sistem pendukung keputusan pada sistem kasir.

5. Daftar Pustaka

- Alfitra, D., Afdal, M., Fronita, M., & Saputra, E. (2024). Analisa keranjang belanja untuk menentukan tata letak barang menggunakan algoritma *FP-Growth*. *Jurnal Sistem Informasi*, 13(4), 1651–1661. <https://doi.org/10.32520/stmsi.v13i4.4268>
- Amelia, R., Darmansyah, & Rismadin, A. M. (2024). Perbandingan algoritma *Apriori* dan *FP-Growth* dalam pengaplikasian market basket analysis untuk strategi bisnis retail. *Building of Informatics, Technology and Science (BITS)*, 6(1), 279–288. <https://doi.org/10.47065/bits.v6i1.5388>
- Annur, H., Serwin, S., & Anisa, I. N. (2025). Analisis keranjang belanja pelanggan coffee shop menggunakan algoritma *FP-Growth*. *JSIAI (Journal Scientific and Applied Informatics)*, 8(3), 723–728. <https://doi.org/10.36085/jsai.v8i3.8835>
- Badan Pusat Statistik. (2025). Statistik penyediaan makanan minuman 2024. <https://www.bps.go.id/id/publication/2025/12/31/e46a55af756331ede8016b91/statistik-penyediaan-makanan-minuman-2024.html>
- Fahreza, M. Z., Jaman, J. H., & Maulana, I. (2025). Penerapan market basket analysis untuk rekomendasi paket menu menggunakan algoritma *FP-Growth* (Studi kasus: Kafe Shans Juice). *Jurnal Informatika Dan Teknik Elektro Terapan*, 13(3), 129–141. <https://doi.org/10.23960/jitet.v13i3S1.7527>
- Fernandez-Basso, C., Ruiz, M. D., & Martin-Bautista, M. J. (2024). New Spark solutions for distributed frequent itemset and association rule mining algorithms. *Cluster Computing*, 27(2), 1217–1234. <https://doi.org/10.1007/s10586-023-04014-w>

- Hery, & Widjaja, A. E. (2024). Analysis of *Apriori* and *FP-Growth* algorithms for market basket insights: A case study of *The Bread Basket* bakery sales. *Journal of Digital Market and Digital Currency*, 1(1), 63–83. <https://doi.org/10.47738/jdmcdc.v1i1.2>
- Hewage, U. H. W. A., Sinha, R., & Naeem, M. A. (2023). Privacy-preserving data (stream) mining techniques and their impact on data mining accuracy: A systematic literature review. *Artificial Intelligence Review*, 56(9), 10427–10464. <https://doi.org/10.1007/s10462-023-10425-3>
- Hidayatullah, F. Z., Surorejo, S., Andriani, W., & Gunawan, G. (2024). Application of association rule for prediction of menu ordered at café Minapadi. *Jurnal Mandiri IT*, 12(4), 208–214.
- Jr Iztok, F., Fister, I., Fister, D., Podgorelec, V., & Salcedo-Sanz, S. (2023). A comprehensive review of visualization methods for association rule mining: Taxonomy, challenges, open problems and future ideas. *Expert Systems with Applications*, 233. <https://doi.org/10.1016/j.eswa.2023.120901>
- Lin, K.-C., Liao, I.-E., & Chen, Z.-S. (2011). An improved frequent pattern growth method for mining association rules. *Expert Systems with Applications*, 38(5), 5154–5161. <https://doi.org/10.1016/j.eswa.2010.10.047>
- Merliani, N. N., Khoerida, N. I., Triana, L. A., & Subarkah, P. (2022). Penerapan algoritma *Apriori* pada transaksi penjualan untuk rekomendasi menu makanan dan minuman. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 8(1), 9–16. <https://doi.org/10.25077/TEKNOSI.v8i3.2022.009-016>
- Mittal, A. (n.d.). *The Bread Basket*. Retrieved June 6, 2026, from <https://www.kaggle.com/datasets/mittalvasu95/the-bread-basket>
- Mokkadem, A., Pelletier, M., & Raimbault, L. (2023). Association rules and decision rules. *Statistical Analysis and Data Mining: The ASA Data Science Journal*, 16, 411–435. <https://doi.org/10.1002/sam.11620>
- Putra, R. A., Putri, M. A. M., Sinaga, S. M., Octavia, S. F., & Rachman, R. C. (2024). Implementation of association rules algorithm to identify popular topping combinations in orders. *Public Research Journal of Engineering, Data Technology and Computer Science*, 1(2), 95–101. <https://doi.org/10.57152/predatecs.v1i2.863>
- Saputra, J. P. B., Rahayu, S. A., & Hariguna, T. (2023). Market basket analysis using *FP-Growth* algorithm to design marketing strategy by determining consumer purchasing patterns. *Journal of Applied Data Sciences*, 4(1), 38–49. <https://doi.org/10.47738/jads.v4i1.83>
- Srirahayu, A., & Pribadie, L. S. (2023). Review paper data mining klasifikasi data mining. *Jurnal Ilmiah Informatika Global*, 14(1). <https://doi.org/10.36982/jiig.v14i1.2981>
- Wulandari, U. M., Suseno, A. T., & Kholilurrahman, M. (2025). Market basket analysis using *FP-Growth* and *Apriori* on distro store sales transaction. *Jurnal Ilmu Komputer Dan Teknologi Informasi*, 17(1), 12–18. <https://doi.org/10.18860/mat.v17i1.28820>