



Analisis Pola Pembelian Konsumen Menggunakan Algoritma *FP-Growth* pada Data Transaksi *Restaurant Burger*

Nindya Alifia Khumaira ¹, Dadang Priyanto ², Hairani ², Galih Hendro Martono ², Moch. Syahrir ², Husain ¹

1. Program Studi Teknologi Informasi, Universitas Bumigora, Indonesia

2. Program Studi Ilmu Komputer, Universitas Bumigora, Indonesia

* Korespondensi: nindyaalifia005@gmail.com

Sitasi: N. A. Khumaira, D. Priyanto, H. Hairani, G. H. Martono, M. Syahrir, dan H. Husain, "Analisis Pola Pembelian Konsumen Menggunakan Algoritma *FP-Growth* pada Data Transaksi *Restaurant Burger*," *Jurnal Teknologi Informasi dan Multimedia*, vol. 8, no. 3, pp. 497–509, 2026. <https://doi.org/10.35746/jtim.v8i3.983>

Diterima: 06-03-2026

Direvisi: 13-06-2026

Disetujui: 20-06-2026



Copyright: © 2026 oleh para penulis.

Karya ini dilisensikan di bawah Creative Commons Attribution-ShareAlike 4.0 International License. (<https://creativecommons.org/licenses/by-sa/4.0/>).

Abstract—Fast-food restaurants generate large volumes of transaction data that can be utilized to understand customer purchasing behavior and support business decision-making. However, transaction data are often used only for operational reporting, limiting their potential for identifying product association patterns. This study aims to apply the Frequent Pattern Growth (FP-Growth) algorithm to discover frequent itemsets and association rules from burger restaurant transaction data and implement the results in a web-based application. The dataset used consists of 2,001 burger restaurant transactions collected from Kaggle, covering the period 2021–2023. The research process included data preprocessing, transaction transformation, FP-Tree construction, frequent itemset extraction, and association rule generation using a minimum support threshold of 2 transactions and a minimum confidence threshold of 60%. The results revealed that the most frequent items were Save Point Sundae (191 transactions), Health Potion Smoothie (181 transactions), and Cheat Code Cookies (164 transactions). Several association rules achieved a confidence value of 100%, indicating a strong co-occurrence relationship between products. Furthermore, the rules Avatar Avocado → Cosmic Rings and Cosmic Rings → Avatar Avocado obtained a lift ratio of 1.50, demonstrating a positive association between the two items. These findings indicate that FP-Growth is effective in identifying customer purchasing patterns and can support promotional strategies, product bundling, and inventory management through data-driven decision-making.

Keywords: FP-Growth; data mining; association rules; market basket analysis; burger restaurant

Abstrak—Restoran cepat saji menghasilkan data transaksi dalam jumlah besar yang dapat dimanfaatkan untuk memahami perilaku pembelian pelanggan dan mendukung pengambilan keputusan bisnis. Namun, data transaksi sering kali hanya digunakan sebagai laporan operasional sehingga potensinya untuk mengidentifikasi pola keterkaitan antarproduk belum dimanfaatkan secara optimal. Penelitian ini bertujuan menerapkan algoritma *Frequent Pattern Growth (FP-Growth)* untuk menemukan *frequent itemset* dan *association rules* pada data transaksi restoran burger serta mengimplementasikan hasilnya ke dalam aplikasi berbasis web. Dataset yang digunakan terdiri atas 2.001 transaksi restoran burger periode 2021–2023 yang diperoleh dari Kaggle. Tahapan penelitian meliputi *preprocessing* data, transformasi transaksi, pembentukan *FP-Tree*, ekstraksi *frequent itemset*, dan pembentukan aturan asosiasi dengan parameter *minimum support* sebesar 2 transaksi dan *minimum confidence* sebesar 60%. Hasil penelitian menunjukkan bahwa item dengan frekuensi kemunculan tertinggi adalah *Save Point Sundae* (191 transaksi), *Health Potion Smoothie* (181 transaksi), dan *Cheat Code Cookies* (164 transaksi). Beberapa aturan asosiasi memiliki nilai *confidence* sebesar 100%, yang menunjukkan hubungan kemunculan yang sangat kuat antarproduk. Selain itu, aturan *Avatar Avocado* → *Cosmic Rings* dan *Cosmic Rings* → *Avatar Avocado* memiliki nilai *lift ratio* sebesar 1,50 yang mengindikasikan adanya asosiasi positif antara kedua item. Hasil penelitian

menunjukkan bahwa algoritma *FP-Growth* efektif dalam mengidentifikasi pola pembelian pelanggan dan dapat dimanfaatkan untuk mendukung strategi promosi, penyusunan paket produk, serta pengelolaan persediaan berbasis data.

Kata kunci: *FP-Growth*; *data mining*; *association rules*; *market basket analysis*; restoran burger.

1. Pendahuluan

Industri kuliner di Indonesia mengalami pertumbuhan signifikan seiring perubahan gaya hidup masyarakat dan meningkatnya kebutuhan terhadap layanan makanan yang praktis [1]. Data Badan Pusat Statistik menunjukkan bahwa sektor penyediaan akomodasi serta makan dan minum mencatat pertumbuhan tahunan sebesar 7,88% hingga 11,54% sepanjang tahun 2023 [2]. Transformasi digital turut mempercepat perubahan pola konsumsi masyarakat melalui meningkatnya penggunaan platform layanan pesan antar makanan [3]. Indonesia bahkan tercatat sebagai pasar terbesar layanan pesan antar makanan di Asia Tenggara dengan nilai transaksi mencapai US\$5,4 miliar pada tahun 2024 [4]. Kondisi ini mendorong pelaku usaha kuliner, termasuk restoran cepat saji, untuk mengoptimalkan strategi bisnis berbasis data guna mempertahankan daya saing [5].

Dalam lingkungan persaingan yang semakin kompetitif, pemahaman terhadap perilaku konsumen menjadi faktor krusial dalam pengambilan keputusan strategis [6]. Setiap transaksi penjualan menyimpan informasi penting mengenai preferensi dan pola pembelian pelanggan [7]. Data transaksi yang dikelola secara sistematis dapat dimanfaatkan untuk mendukung pengelolaan persediaan, perancangan paket produk, serta strategi promosi yang lebih efektif dan tepat sasaran [8]. Restoran cepat saji berbasis menu burger sebagai salah satu segmen usaha kuliner menghasilkan data transaksi yang berpotensi dimanfaatkan untuk memperoleh informasi yang bernilai bagi pengambilan keputusan bisnis [9].

Meskipun restoran *burger* menghasilkan data transaksi dalam jumlah besar, pemanfaatan data transaksi untuk mendukung pengambilan keputusan bisnis masih belum optimal [10]. Data transaksi pada banyak usaha kuliner masih lebih sering dimanfaatkan sebagai laporan operasional dibandingkan sebagai sumber informasi untuk mengidentifikasi pola pembelian pelanggan [11]. Kondisi tersebut menyebabkan pihak restoran mengalami kesulitan dalam menentukan kombinasi paket menu yang sesuai dengan preferensi pelanggan, menyusun strategi promosi yang tepat sasaran, serta memperkirakan kebutuhan persediaan bahan baku secara akurat [12]. Akibatnya, restoran berisiko mengalami ketidaksesuaian stok bahan baku, kurang efektifnya program promosi, hingga peluang penjualan yang tidak dimanfaatkan secara maksimal [12].

Permasalahan lainnya terletak pada tingginya jumlah transaksi dan banyaknya variasi menu yang membuat proses identifikasi pola pembelian pelanggan sulit dilakukan secara manual [13]. Analisis yang hanya berdasarkan intuisi atau pengalaman manajemen sering kali menghasilkan keputusan yang kurang tepat karena tidak didukung oleh pola data yang valid. Selain membutuhkan waktu yang lama, proses analisis manual juga tidak mampu mengolah data transaksi dalam jumlah besar secara efisien [14]. Oleh karena itu, diperlukan metode analisis data yang mampu menemukan pola keterkaitan antarproduk secara cepat dan akurat untuk mendukung pengambilan keputusan bisnis restoran.

Perkembangan teknologi digital pada sektor kuliner telah meningkatkan penggunaan layanan pemesanan makanan secara daring dan menghasilkan data transaksi dalam jumlah yang semakin besar [3]. Data tersebut menyimpan berbagai informasi mengenai preferensi pelanggan yang dapat dimanfaatkan untuk mendukung

pengambilan keputusan bisnis. Selain itu, keberagaman pilihan menu dan pola pembelian pelanggan menyebabkan hubungan antarproduk menjadi semakin kompleks [15]. Oleh karena itu, diperlukan metode analisis yang mampu mengidentifikasi keterkaitan antarproduk secara efektif sehingga informasi yang dihasilkan dapat dimanfaatkan untuk mendukung pengambilan keputusan bisnis restoran secara lebih tepat dan berbasis data.

Pendekatan *data mining* menjadi solusi untuk mengekstraksi pola tersembunyi dari data transaksi dalam jumlah besar [16]. Salah satu teknik yang umum digunakan adalah *Market Basket Analysis* (MBA) untuk menemukan aturan asosiasi (*association rules*) antarproduk yang sering dibeli secara bersamaan [17]. Dalam implementasinya, algoritma *Frequent Pattern Growth* (*FP-Growth*) memiliki keunggulan dibandingkan algoritma Apriori karena tidak memerlukan proses pembangkitan kandidat secara eksplisit, melainkan membangun struktur *FP-Tree* yang lebih efisien dari sisi waktu dan penggunaan memori [18]. Keunggulan tersebut menjadikan *FP-Growth* sesuai untuk analisis data transaksi berskala besar pada sektor ritel dan kuliner [19].

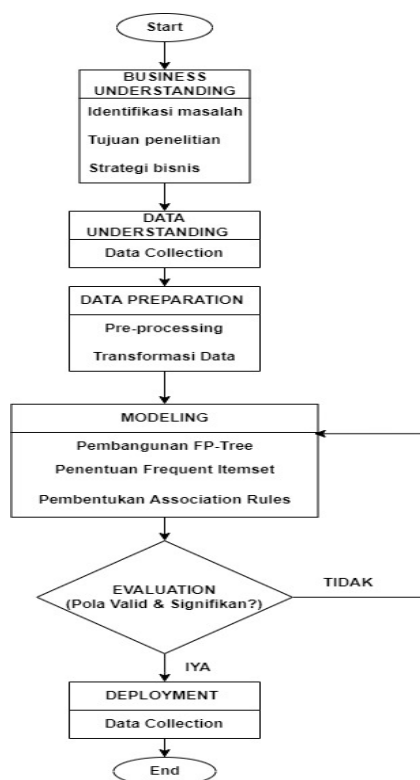
Berbagai penelitian terdahulu telah membuktikan efektivitas algoritma *FP-Growth* dalam menganalisis pola pembelian konsumen pada berbagai sektor usaha. Penelitian pada kedai seblak berhasil mengidentifikasi sejumlah aturan asosiasi produk yang sering dibeli secara bersamaan sehingga dapat mendukung pengelolaan stok dan penyusunan strategi pemasaran yang lebih efektif [20]. Penelitian lain yang menerapkan algoritma *FP-Growth* pada data transaksi konter penjualan berhasil menemukan pola keterkaitan antarproduk yang dapat dimanfaatkan sebagai dasar dalam penyusunan strategi penjualan [21]. Selain itu, penerapan algoritma *FP-Growth* pada data transaksi toko suku cadang kendaraan juga menghasilkan aturan asosiasi yang kuat sehingga membantu proses pengambilan keputusan terkait penjualan dan persediaan produk [22].

Meskipun algoritma *FP-Growth* telah banyak diterapkan dan terbukti efektif pada berbagai sektor usaha, sebagian besar penelitian terdahulu masih berfokus pada sektor selain restoran cepat saji berbasis menu *burger*. Selain itu, hasil analisis yang dihasilkan umumnya hanya disajikan dalam bentuk tabel atau laporan statis sehingga belum sepenuhnya mendukung kebutuhan manajemen dalam memahami pola pembelian pelanggan secara cepat dan interaktif. Oleh karena itu, penelitian ini tidak hanya menerapkan algoritma *FP-Growth* pada data transaksi restoran burger, tetapi juga mengintegrasikan hasil analisis ke dalam aplikasi berbasis web yang mampu menyajikan informasi secara visual dan interaktif guna menyediakan media visualisasi yang dapat membantu pengguna memahami pola keterkaitan antarproduk secara lebih mudah dan informatif.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menerapkan algoritma *Frequent Pattern Growth* (*FP-Growth*) dalam menganalisis pola pembelian pelanggan pada dataset transaksi restoran burger yang diperoleh dari *platform Kaggle*. Dataset publik tersebut digunakan sebagai studi kasus untuk menguji penerapan algoritma *FP-Growth* dalam menemukan pola keterkaitan antarproduk yang sering dibeli secara bersamaan oleh pelanggan. Analisis dilakukan dengan menentukan nilai *minimum support* untuk memperoleh *frequent itemset*, kemudian membentuk *association rules* berdasarkan nilai *confidence*. Hasil analisis diimplementasikan dalam aplikasi berbasis web yang menampilkan *frequent itemset*, *association rules*, serta visualisasi pola pembelian secara interaktif. Kontribusi utama penelitian ini terletak pada penerapan algoritma *FP-Growth* dan integrasinya dengan sistem visualisasi berbasis web dalam analisis transaksi restoran burger, sehingga dapat membantu pengguna dalam memahami pola pembelian pelanggan secara lebih mudah dan mendukung pengambilan keputusan yang berbasis data.

2. Bahan dan Metode

Penelitian ini menggunakan dua pendekatan, yaitu *data mining* untuk mengolah pola asosiasi dan metode pengembangan sistem untuk merancang aplikasi berbasis web. Pendekatan ini bertujuan menghasilkan temuan pola sekaligus sistem informasi yang dapat dimanfaatkan secara langsung oleh pengguna. Jenis penelitian yang digunakan adalah kuantitatif, yaitu metode berbasis komputasi dan statistik yang berfokus pada analisis matematis atau numerik terhadap data [23]. Pendekatan ini bersifat objektif dan terstruktur dalam menguji hipotesis melalui pengumpulan dan analisis data secara sistematis.



Gambar 1. Tahapan Penelitian

Penelitian ini mengacu pada kerangka kerja *CRISP-DM* yang diimplementasikan dalam alur penelitian.

1. Data Collection

Dataset yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari platform Kaggle dan dapat diakses melalui tautan berikut: <https://www.kaggle.com/datasets/suhailaehab/simulated-burger-restaurant-data>. Berikut adalah contoh beberapa data transaksi yang terdapat dalam dataset:

Tabel 1. Data Kaggle

Area	Category	Item	Description	Date	Orders	Type of Order
Mystic Falls	Sides	Black Hole Fries	Fries with a dark garlic truffle sauce.	2/27/2023	136	Dining
Cyber City	Drinks	Health Smoothie	A blend of red fruits with a secret energy mix.	1/28/2022	141	Dining
Neo Tokyo	Sides	Supernova Sweet Potato Fries	Sweet and spicy sweet potato fries with starlight mayo.	12/14/2021	153	Takeaway

Area	Category	Item	Description	Date	Orders	Type of Order
Neo Tokyo	Burgers	Epic Stack	A double beef patty with epic layers of crispy bacon, melted cheddar, and our secret Epic Sauce.	3/3/2023	23	Takeaway
Arcadia Bay	Burgers	Retro Reuben	Corned beef, sauerkraut, Swiss cheese, and thousand island dressing on a rye bun.	7/1/2023	119	Takeaway
Neo Tokyo	Desserts	Cheat Code Cookies	Cookies with chocolate chips and candies.	11/12/2021	166	Takeaway
Neo Tokyo	Sides	Cosmic Rings	Onion rings with cosmic seasoning and intergalactic sauce.	5/9/2022	40	Takeaway

Dataset tersebut berisi 2.001 transaksi restoran burger periode 2021–2023 dalam format CSV dengan tujuh atribut, yaitu *Area*, *Category*, *Item*, *Description*, *Date*, *Orders*, dan *Type of Order*. Data yang digunakan bersifat *semi-dummy* (simulasi), yaitu data yang dirancang menyerupai transaksi nyata, tetapi telah dimodifikasi untuk keperluan analisis dan penelitian. Meskipun demikian, struktur dan karakteristik data tetap merepresentasikan kondisi transaksi riil sehingga tetap relevan untuk proses data mining. Pada tahap awal dilakukan analisis deskriptif dengan menghitung nilai frekuensi, *support*, *confidence*, dan *lift* untuk mengidentifikasi kecenderungan pola transaksi. Nilai *lift* yang lebih besar dari 1 menunjukkan adanya hubungan asosiasi yang kuat antaritem. Dalam penelitian ini, parameter yang digunakan adalah:

a. Minimum Support = 2

Pemilihan minimum support sebesar 2 didasarkan pada jumlah dataset yang cukup besar, yaitu 2.001 transaksi, sehingga nilai support yang relatif rendah memungkinkan sistem mendeteksi pola yang jarang muncul tetapi masih berpotensi memberikan informasi yang bernilai. Dengan demikian, suatu itemset dianggap memenuhi syarat apabila muncul minimal dua kali dalam keseluruhan transaksi.

b. Minimum *Confidence* = 0,6 (60%)

Minimum *confidence* sebesar 0,6 (60%) dipilih karena menunjukkan bahwa suatu aturan asosiasi memiliki tingkat kepercayaan yang cukup tinggi, yaitu item consequent muncul pada sedikitnya 60% transaksi yang mengandung item antecedent. Nilai tersebut dipilih untuk menjaga keseimbangan antara jumlah aturan yang dihasilkan dan kekuatan hubungan antaritem. Apabila nilai *confidence* ditetapkan terlalu rendah, aturan yang terbentuk cenderung banyak tetapi kurang relevan. Sebaliknya, jika ditetapkan terlalu tinggi, terdapat kemungkinan banyak pola yang sebenarnya menarik menjadi tidak terdeteksi. Oleh karena itu, nilai 60% dianggap cukup representatif untuk menghasilkan aturan asosiasi yang memiliki tingkat kepercayaan yang baik tanpa mengurangi jumlah aturan secara signifikan. Pada hasil analisis, ditemukan beberapa aturan dengan nilai *confidence* sebesar 100%. Kondisi ini terjadi karena setiap transaksi yang mengandung item antecedent tertentu selalu diikuti oleh item consequent yang sama. Secara matematis, nilai *confidence* dihitung menggunakan persamaan:

$$Confidence(A \rightarrow B) = \frac{\text{Jumlah transaksi yang mengandung A dan B}}{\text{Jumlah transaksi yang mengandung A}} \times 100\%$$

Nilai *confidence* digunakan untuk mengukur tingkat kepercayaan suatu aturan asosiasi. *Confidence* menunjukkan seberapa besar kemungkinan *item consequent* (B) muncul ketika *item antecedent* (A) muncul. Semakin tinggi nilai *confidence*, semakin kuat hubungan antara kedua item tersebut

2. *Pre-Processing Data*

Tahap ini meliputi penghapusan duplikasi, penanganan *missing value*, dan reduksi atribut. Berdasarkan pemeriksaan, tidak ditemukan data duplikasi maupun nilai hilang. Proses yang dilakukan hanya reduksi atribut dari tujuh menjadi tiga atribut utama: *Item*, *Date*, dan *Type of Order*, karena paling relevan untuk pembentukan itemset dan segmentasi transaksi.

3. *Transformasi Data*

Data dikonversi ke format *list of transactions*, yaitu kumpulan item per transaksi berdasarkan kombinasi *Date* dan *Type of Order*. Format ini diperlukan untuk penerapan algoritma *FP-Growth*.

4. *Data Mining (FP-Growth)*

Tahapan implementasi meliputi:

- 1) Pembuatan *header table* berdasarkan nilai minimum support
- 2) Pembangunan struktur *FP-Tree*
- 3) Ekstraksi *frequent itemset*
- 4) Pembentukan *association rules* dengan perhitungan *confidence*

Dalam pembentukan *association rules* digunakan beberapa ukuran evaluasi, yaitu *support*, *confidence*, dan *lift ratio*. *Support* digunakan untuk mengukur frekuensi kemunculan suatu itemset dalam seluruh transaksi. Perhitungan *support* ditunjukkan pada Persamaan (1).

$$Support(A) = \frac{Jumlah\ transaksi\ yang\ mengandung\ A}{Total\ transaksi} \dots\dots\dots (1)$$

Untuk *itemset* yang terdiri atas lebih dari satu *item*, *support* dihitung menggunakan Persamaan (2).

$$Support(A \cap B) = \frac{Jumlah\ transaksi\ yang\ mengandung\ A\ dan\ B}{Total\ transaksi} \dots\dots\dots (2)$$

Confidence digunakan untuk mengukur tingkat kepercayaan bahwa item B akan muncul apabila item A muncul dalam suatu transaksi. Nilai *confidence* dihitung menggunakan Persamaan (3).

$$Confidence(A \rightarrow B) = \frac{Support(A \cap B)}{Support(A)} \dots\dots\dots (3)$$

Selain itu, digunakan *lift ratio* untuk mengukur kekuatan hubungan antara antecedent dan consequent. Nilai *lift* lebih besar dari 1 menunjukkan adanya hubungan asosiasi positif antaritem. Perhitungan *lift ratio* ditunjukkan pada Persamaan (4).

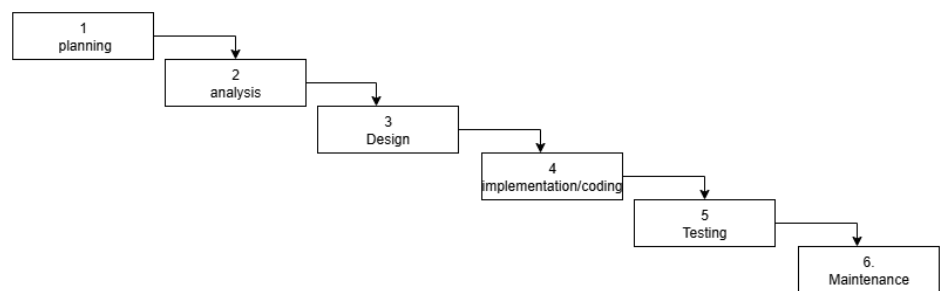
$$Lift(A \rightarrow B) = \frac{Confidence(A \rightarrow B)}{Support(B)} \dots\dots\dots (4)$$

Keterangan:

- A = antecedent (item awal)
- B = consequent (item tujuan)
- Support(A) = nilai support item A
- Support(A ∩ B) = nilai support item A dan B
- Confidence(A → B) = tingkat kepercayaan aturan asosiasi

- $Lift(A \rightarrow B)$ = tingkat kekuatan hubungan antara A dan B

Hasil proses *data mining* berupa *frequent itemset* dan *association rules* selanjutnya diimplementasikan ke dalam sebuah aplikasi berbasis web agar dapat dimanfaatkan secara praktis oleh pengguna. Oleh karena itu, selain menggunakan pendekatan CRISP-DM untuk analisis data, penelitian ini juga menerapkan metode pengembangan sistem untuk membangun perangkat lunak yang mengintegrasikan algoritma FP-Growth. Metode pengembangan sistem yang digunakan adalah model *Waterfall*, yang dipilih karena memiliki tahapan terstruktur dan sesuai untuk pengembangan sistem dengan kebutuhan yang telah terdefinisi secara jelas.



Gambar 2. *Waterfall Model* [24]

Tahapan pengembangan meliputi:

1. Perencanaan (*Planning*)

Menentukan tujuan pengembangan sistem, ruang lingkup, spesifikasi perangkat lunak dan perangkat keras, serta jadwal pelaksanaan penelitian.

2. Analisis Kebutuhan (*Requirement Analysis*)

Mengidentifikasi kebutuhan fungsional (unggah data CSV, prapemrosesan, proses *FP-Growth*, serta tampilan *frequent itemset* dan *association rules*) serta kebutuhan nonfungsional (kemudahan penggunaan, kecepatan proses, dan akurasi perhitungan).

3. Perancangan Sistem (*System Design*)

Merancang arsitektur sistem, struktur basis data, alur algoritma, serta desain antarmuka pengguna. Tahap ini menghasilkan *blueprint* sistem sebelum implementasi.

4. Implementasi (*Implementation*)

Mengembangkan aplikasi berbasis web dan mengintegrasikan algoritma FP-Growth untuk memproses data transaksi secara otomatis.

5. Pengujian (*Testing*)

Melakukan uji fungsionalitas, validasi hasil perhitungan algoritma, serta verifikasi kesesuaian output dengan perhitungan manual guna memastikan keakuratan dan keandalan sistem.

6. Pemeliharaan (*Maintenance*)

Melakukan perbaikan kesalahan serta penyesuaian sistem agar tetap stabil dan dapat digunakan secara optimal.

3. Hasil

3.1. Preprocessing Data

Tahap *preprocessing* dilakukan untuk mempersiapkan data transaksi sebelum dianalisis menggunakan algoritma *FP-Growth*. Dataset yang digunakan terdiri dari 2.001 transaksi restoran *burger* periode 2021–2023 yang diperoleh dari *Kaggle*. Pada tahap ini dilakukan beberapa proses, yaitu:

1. Pemeriksaan data kosong (*missing value*);
2. Penghapusan data duplikat (*duplicate data*);
3. Transformasi data transaksi ke dalam format *basket transaction*;
4. Pengelompokan item berdasarkan nomor transaksi.

Hasil *preprocessing* menunjukkan bahwa seluruh data transaksi dapat digunakan tanpa kehilangan data yang signifikan. Setelah proses transformasi, setiap transaksi direpresentasikan sebagai kumpulan item menu yang dibeli dalam satu transaksi.

Tabel 2. Hasil *Preprocessing Data*

<i>Item</i>	<i>Date</i>	<i>Type of Order</i>
<i>Cheat Code Cookies</i>	11/2/2021	<i>Online</i>
<i>Black Hole Fries</i>	11/2/2021	<i>Online</i>
<i>Next Level Veggie</i>	11/2/2021	<i>Online</i>
<i>Health Potion Smoothie</i>	11/3/2021	<i>Dining</i>
<i>Save Point Sundae</i>	11/3/2021	<i>Dining</i>
<i>Quantum Fries</i>	11/3/2021	<i>Dining</i>
<i>Quantum Fries</i>	11/3/2021	<i>Dining</i>
<i>Epic Stack</i>	11/4/2021	<i>Online</i>
<i>Health Potion Smoothie</i>	11/4/2021	<i>Dining</i>
<i>Mana Milkshake</i>	11/4/2021	<i>Dining</i>
<i>Quantum Fries</i>	11/5/2021	<i>Dining</i>
<i>Retro Reuben</i>	11/5/2021	<i>Online</i>
<i>Black Hole Fries</i>	11/5/2021	<i>Takeaway</i>
<i>Save Point Sundae</i>	11/6/2021	<i>Takeaway</i>
<i>Health Potion Smoothie</i>	11/6/2021	<i>Online</i>
<i>Save Point Sundae</i>	11/6/2021	<i>Online</i>


3.2. Frequent Itemset

Berdasarkan implementasi algoritma *FP-Growth* terhadap *dataset* sebanyak 2.001 transaksi restoran burger periode 2021–2023, diperoleh sejumlah *frequent itemset* dengan nilai *support* tertinggi. Hasil pengolahan data tersebut ditampilkan pada Tabel 1.

Tabel 3. Hasil *Frequent Itemset* pada Restoran *Burger*

<i>Itemset</i>	<i>Support</i>
Save Point Sundae	191
Health Potion Smoothie	181
Cheat Code Cookies	164
Black Hole Fries	91
Retro Reuben	88
Byte-Size Tots	87
Power-Up Fries	83
Supernova Sweet Potato Fries	82
Pixel Pepperjack	76
Stealth Mode Mushroom	66

Berdasarkan Tabel 3, *item* dengan nilai *support* tertinggi adalah *Save Point Sundae* dengan jumlah 191 transaksi, diikuti oleh *Health Potion Smoothie* sebanyak 181 transaksi dan *Cheat Code Cookies* sebanyak 164 transaksi. Visualisasi hasil *frequent itemset* ditunjukkan pada Gambar 3.



Gambar 3. Visualisasi Frequent Itemset

3.3. Association Rules

Setelah diperoleh *frequent itemset*, tahap selanjutnya adalah pembentukan aturan asosiasi (*association rules*) menggunakan parameter minimum support sebesar 2 transaksi dan minimum *confidence* sebesar 0,6 (60%). Nilai minimum support yang rendah dipilih untuk memungkinkan sistem mengidentifikasi pola pembelian yang jarang muncul namun berpotensi memberikan informasi yang bermanfaat. Hasil pembentukan aturan asosiasi ditunjukkan pada Tabel 4.

Tabel 4. Hasil *Association Rules* pada Restoran Burger

<i>Antecedent</i>	<i>Consequent</i>	<i>Support</i>	<i>Confidence</i>	<i>Lift</i>
Avatar Avocado	Stealth Mode Mushroom	2	1,00	1,00
Avatar Avocado	Pixel Pepperjack	2	1,00	1,00
Avatar Avocado	Save Point Sundae	2	1,00	1,00
Avatar Avocado	XP Soda	2	1,00	1,00
XP Soda	Avatar Avocado	2	1,00	1,00
Avatar Avocado	Black Hole Fries	2	1,00	1,00
Avatar Avocado	Supernova Sweet Potato Fries	2	1,00	1,00
Avatar Avocado	Cosmic Rings	3	1,00	1,50
Cosmic Rings	Avatar Avocado	3	1,00	1,50

Beberapa aturan asosiasi yang dihasilkan memiliki nilai *confidence* sebesar 1,00 (100%), yang menunjukkan bahwa seluruh transaksi yang mengandung *antecedent* selalu mengandung *consequent*. Namun demikian, nilai *confidence* yang tinggi tidak selalu menunjukkan kekuatan hubungan yang tinggi karena perlu dipertimbangkan bersama nilai *support* dan *lift ratio*. Pada penelitian ini, sebagian besar aturan memiliki nilai *support* yang relatif rendah, yaitu hanya muncul pada 2–3 transaksi dari total 2.001 transaksi. Oleh karena itu, interpretasi hasil dilakukan dengan mempertimbangkan ketiga metrik tersebut secara bersamaan agar hubungan yang ditemukan tidak hanya memiliki tingkat kepastian tinggi, tetapi juga relevan secara statistik dan bisnis.

3.4. Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan bahwa sistem berbasis web mampu mengimplementasikan algoritma *FP-Growth* secara akurat. *Dataset* yang digunakan

berjumlah 2.001 transaksi dalam format CSV. Parameter yang digunakan dalam pengujian yaitu *minimum support* = 2 dan *minimum confidence* = 0,6. Hasil pengujian menunjukkan bahwa sistem mampu:

1. Memproses *dataset* tanpa kesalahan (*error*);
2. Menghasilkan *frequent itemset*;
3. Menghasilkan *association rules* sesuai dengan algoritma.

Selain itu, hasil yang diperoleh telah sesuai dengan validasi konseptual dan perhitungan manual, sehingga implementasi sistem dinyatakan berjalan dengan baik.

Tampilan antarmuka sistem saat pengaturan parameter ditunjukkan pada Gambar 4.

Gambar 4. Pengaturan *Minimum Support* dan *Minimum Confidence*

4. Pembahasan

4.1. Analysis of Frequent Itemsets

Berdasarkan hasil implementasi algoritma *FP-Growth* terhadap 2.001 transaksi restoran *burger* periode 2021–2023, diperoleh sejumlah *frequent itemset* dengan nilai *support* tertinggi yang didominasi oleh kategori *dessert* dan minuman, seperti Save Point Sundae, Health Potion Smoothie, dan Cheat Code Cookies. Tingginya nilai *support* pada ketiga produk tersebut menunjukkan bahwa produk-produk tersebut memiliki frekuensi kemunculan yang tinggi dalam transaksi pelanggan dibandingkan produk lainnya.

Secara umum, hasil ini mengindikasikan bahwa pelanggan restoran burger tidak hanya berfokus pada menu utama, tetapi juga memiliki kecenderungan untuk membeli produk pelengkap sebagai bagian dari pengalaman konsumsi mereka. Fenomena ini menunjukkan bahwa keberhasilan penjualan restoran tidak hanya ditentukan oleh produk utama, melainkan juga oleh kemampuan restoran dalam menawarkan produk pendamping yang sesuai dengan preferensi pelanggan.

Dari sudut pandang *data mining*, nilai *support* yang tinggi menunjukkan bahwa suatu produk memiliki kontribusi besar terhadap keseluruhan transaksi. Oleh karena itu, produk-produk tersebut dapat dikategorikan sebagai produk unggulan (*best seller*) yang memiliki tingkat permintaan relatif stabil. Informasi ini penting bagi manajemen dalam melakukan perencanaan persediaan, pengendalian stok, serta penentuan prioritas promosi.

Selain itu, visualisasi *frequent itemset* menunjukkan adanya perbedaan frekuensi yang cukup signifikan antara tiga produk teratas dengan produk lainnya. Hal ini mengindikasikan bahwa preferensi pelanggan cenderung terpusat pada produk tertentu

dan tidak tersebar secara merata. Dengan kata lain, terdapat sejumlah produk yang menjadi pilihan dominan pelanggan dibandingkan produk lainnya.

Temuan penelitian ini sejalan dengan penelitian Rudi Kurniawan dkk yang menerapkan algoritma *FP-Growth* pada data transaksi kedai seblak. Penelitian tersebut berhasil mengidentifikasi beberapa produk yang memiliki tingkat kemunculan tinggi dalam transaksi sehingga dapat dimanfaatkan untuk mendukung pengelolaan stok dan strategi pemasaran. Kesamaan hasil tersebut menunjukkan bahwa algoritma *FP-Growth* mampu mengidentifikasi pola pembelian pelanggan secara efektif pada berbagai jenis usaha kuliner [20].

Namun demikian, terdapat perbedaan karakteristik hasil yang diperoleh. Pada penelitian Rudi Kurniawan dkk, produk yang dominan berasal dari menu utama, sedangkan pada penelitian ini produk dengan frekuensi tertinggi justru didominasi oleh kategori *dessert* dan minuman. Perbedaan tersebut menunjukkan bahwa karakteristik perilaku konsumen pada restoran *burger* memiliki pola yang berbeda dibandingkan usaha kuliner lainnya. Dengan demikian, strategi bisnis yang diterapkan perlu disesuaikan dengan karakteristik pelanggan pada masing-masing sektor usaha.

4.2. *Analysis of Association Rules*

Berdasarkan hasil pembentukan *association rules*, diperoleh beberapa aturan yang memiliki nilai confidence sebesar 1,00 (100%). Nilai tersebut menunjukkan bahwa setiap transaksi yang mengandung item pada bagian *antecedent* selalu diikuti oleh item pada bagian *consequent*. Sebagai contoh, aturan *Avatar Avocado* → *Cosmic Rings* memiliki confidence sebesar 100%, yang berarti seluruh transaksi yang mengandung *Avatar Avocado* juga mengandung *Cosmic Rings*.

Meskipun demikian, evaluasi aturan asosiasi tidak dapat hanya didasarkan pada nilai confidence. Dalam analisis asosiasi, terdapat tiga ukuran utama yang perlu diperhatikan, yaitu support, confidence, dan *lift ratio*. Nilai support menunjukkan frekuensi kemunculan suatu kombinasi item dalam keseluruhan transaksi, sedangkan confidence menunjukkan tingkat kepastian hubungan antar-item. Adapun *lift ratio* digunakan untuk mengukur kekuatan hubungan antara dua item dibandingkan dengan kemunculan item tersebut secara acak.

Hasil penelitian menunjukkan bahwa sebagian besar aturan memiliki nilai support yang relatif rendah, yaitu hanya muncul sebanyak 2–3 transaksi dari total 2.001 transaksi. Hal ini menunjukkan bahwa pola yang ditemukan belum merepresentasikan mayoritas transaksi pelanggan. Oleh karena itu, meskipun nilai confidence mencapai 100%, hasil tersebut perlu diinterpretasikan secara hati-hati karena kemungkinan masih dipengaruhi oleh jumlah kemunculan yang terbatas.

Aturan *Avatar Avocado* → *Cosmic Rings* dan *Cosmic Rings* → *Avatar Avocado* memiliki nilai *lift ratio* sebesar 1,50. Nilai tersebut menunjukkan adanya hubungan positif antara kedua item karena *lift ratio* lebih besar dari 1. Dengan kata lain, pelanggan yang membeli salah satu produk tersebut memiliki kecenderungan lebih tinggi untuk membeli produk lainnya dibandingkan apabila pembelian terjadi secara acak. Sebaliknya, aturan dengan nilai *lift ratio* mendekati 1 menunjukkan bahwa hubungan antar-item relatif lemah atau cenderung independen.

Temuan ini menunjukkan bahwa penggunaan algoritma *FP-Growth* mampu mengidentifikasi pola keterkaitan antarproduk dalam data transaksi restoran burger. Informasi tersebut dapat dimanfaatkan sebagai dasar penyusunan strategi pemasaran, pengembangan paket promosi, serta rekomendasi produk yang sesuai dengan kebiasaan pembelian pelanggan.

4.3. *Implikasi Manajerial*

Hasil analisis menunjukkan bahwa pola pembelian pelanggan dapat dimanfaatkan untuk mendukung strategi bisnis, antara lain:

- a) Penentuan Paket *Bundling* Produk;
- b) Rekomendasi Menu Tambahan (*Cross-Selling*);
- c) Optimasi Tata Letak Menu;
- d) Perencanaan Stok Bahan Baku.

Item dengan nilai *support* tinggi dapat dijadikan sebagai produk unggulan (*best seller*), sedangkan pasangan *item* dengan nilai *lift* tinggi dapat digunakan sebagai dasar dalam strategi pemasaran.

5. Kesimpulan

Penelitian ini berhasil menerapkan algoritma *Frequent Pattern Growth* (*FP-Growth*) untuk menganalisis pola pembelian pelanggan pada dataset transaksi restoran burger sebanyak 2.001 transaksi. Hasil analisis menunjukkan bahwa item dengan frekuensi kemunculan tertinggi (*frequent itemset*) adalah *Save Point Sundae* (191 transaksi), *Health Potion Smoothie* (181 transaksi), dan *Cheat Code Cookies* (164 transaksi). Selain itu, proses pembentukan *association rules* menghasilkan beberapa aturan dengan nilai *confidence* sebesar 100%.

Evaluasi menggunakan *lift ratio* menunjukkan bahwa aturan *Avatar Avocado* → *Cosmic Rings* dan *Cosmic Rings* → *Avatar Avocado* memiliki nilai *lift* sebesar 1,50, yang mengindikasikan adanya hubungan asosiasi positif antara kedua produk tersebut. Temuan ini menunjukkan bahwa algoritma *FP-Growth* mampu mengidentifikasi pola keterkaitan antarproduk yang dapat dimanfaatkan untuk mendukung strategi promosi, penyusunan paket menu, dan pengelolaan persediaan. Implementasi hasil analisis ke dalam aplikasi berbasis web juga memudahkan pengguna dalam memahami pola pembelian pelanggan secara lebih cepat dan interaktif.

6. Saran

Penelitian selanjutnya disarankan menggunakan dataset transaksi riil dengan jumlah data yang lebih besar agar pola yang diperoleh lebih representatif. Selain itu, penelitian dapat membandingkan kinerja algoritma *FP-Growth* dengan algoritma asosiasi lainnya, seperti *Apriori* atau *ECLAT*, serta menambahkan metrik evaluasi lain untuk meningkatkan kualitas analisis. Pengembangan sistem juga dapat diarahkan pada penyediaan fitur rekomendasi produk otomatis berdasarkan hasil *association rules* guna mendukung pengambilan keputusan bisnis secara lebih optimal.

Ucapan Terima Kasih: Artikel ini merupakan pengembangan dari penelitian skripsi yang telah diselesaikan oleh penulis sebagai salah satu persyaratan untuk memperoleh gelar sarjana.

Referensi

- [1] I. Ariyanti, "Ekosistem Kuliner Indonesia Berstandar Global," *Pedagogy: Jurnal Ilmiah Ilmu Pendidikan*, vol. 10, no. 1, pp. 81-88, 2023.
- [2] H. Budu, and I. W. Sukadana, "Analisis Faktor-Faktor Yang Memengaruhi Penyerapan Tenaga Kerja Pada Sub Sektor Hotel Di Kabupaten / Kota Provinsi Bali (2014 - 2024)," *Jurnal Mahasiswa Manajemen dan Akuntansi*, vol. 5, no. 1, pp. 481-498, 2026. <https://doi.org/10.30640/jumma45.v5i1.5899>
- [3] J. D. S. Amory, M. Mudo, and R. J., "Transformasi Ekonomi Digital Dan Evolusi Pola Konsumsi: Tinjauan Literatur Tentang Perubahan Perilaku Belanja Di Era Internet," *J. Minfo Polgan*, Vol. 14, No. 1, Pp. 28-37, 2025, <https://doi.org/10.33395/Jmp.V14i1.14608>.
- [4] Rizki Damayanti, *Hubungan Indonesia-Rusia: Pandangan Masyarakat Indonesia*. Jakarta: Universitas Bakrie Press, 2025.
- [5] M. Fajrul and R. F. Sapyana, "Strategi Peningkatan Daya Saing Umkm Kuliner Di Era Digital: Studi Kasus Pada Pelaku Usaha Di Kota Semarang," *Mamen J. Manaj.*, vol. 4, no. 2, pp. 143-157, 2025, <https://doi.org/10.55123/Mamen.v4i2.5066>.

- [6] A.Rahman, "Strategi Pemasaran," *Jurnal Ekonomi Syari'ah*, Vol. 3, No. 3, Pp. 71–82, 2024.
- [7] D. Apriana and C. Yuliansyah, "Mengoptimalkan Penjualan Online Melalui Teknik Data Mining (Studi Kasus E-Commerce)," *AL-MIKRAJ J. Stud. Islam dan Hum.* (E-ISSN 2745-4584), vol. 4, no. 02, pp. 514–527, 2024, <https://doi.org/10.37680/almikraj.v4i02.4774>.
- [8] R. E. Anugrah, Y. A. Saputra, and W. Haryono, "Perancangan Sistem Inventory Berbasis Web untuk Optimalisasi Manajemen Persediaan Barang di PT Bumi Daya Plaza," *Bridg. J. Publ. Sist. Inf. dan Telekomun.*, vol. 2, no. 4, pp. 342–363, 2024, <https://doi.org/10.62951/bridge.v2i4.317>.
- [9] L. M. Harahap, D. Dongoran, and F. D. Situmorang, "Analisis Manajemen Strategik Pada Mcdonald's: Studi Kasus Waralaba Restoran Cepat Saji Dengan Pendekatan Swot Periode Oktober-Desember 2011," *J. Ilmu Manajemen, Bisnis dan Ekon.* JIMBE, vol. 2, no. 1, pp. 44–50, 2024. <https://malaqbipublisher.com/index.php/JIMBE/article/view/270>
- [10] H. Mulyani, "Implementasi Algoritma Apriori Pada Transaksi Penjualan Barang (Studi Kasus: Toko Isna Kabupaten Bintan)," *J. Bangkit Indones.*, vol. 7, no. 1, p. 15, 2018, <https://doi.org/10.52771/bangkitindonesia.v7i1.82>.
- [11] R. Abizal, Y. Syahra, and H. Hafizah, "Implementasi Algoritma Apriori Dalam Menganalisis Pola Penjualan Pada Restoran Sederhana," *J-SISKO TECH (Jurnal Teknol. Sist. Inf. dan Sist. Komput. TGD)*, vol. 5, no. 1, p. 76, 2022, <https://doi.org/10.53513/jsk.v5i1.4794>.
- [12] F Artianshal, D. B. Kluman, R. Febriansyah, P. E. Pali, A. Y. L. Satia, and H. Sutejo, "Prediction of Unselling Menu Items for Bundling and Promotion Strategies in Cafés Using Decision Tree Algorithm," *Jurnal Ilmiah Sistem Informasi (JUSI)*, vol. 5, no. 1, pp. 96-106, 2026. <https://doi.org/10.51903/qc1w9009>
- [13] P. Salsabila, E. Wahyudin, G. Dwilestari, K. Kaslani, and F. Subhiyanto "Penerapan Algoritma Fp-Growth Untuk Mengetahui Pola," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 1, pp. 1221–1228, 2024. <https://doi.org/10.36040/jati.v8i1.8964>
- [14] N. Susi, S. Sugiana, and B. Musty, "Analisis Data Sistem Informasi Monitoring Marketing; Tools Pengambilan Keputusan Strategic," *JUTISI (Jurnal Ilmiah Teknik Informatika dan Sistem Informasi)*, vol. 12, no. 2, pp. 696–708, 2023, <https://doi.org/10.35889/jutisi.v12i2.1240>.
- [15] R. Haryanto, G.Hasan, N.Akbar, and F.Mulyadi, *Perilaku Konsumen. Solok: PT MAFY Literasi Indonesia*, 2024.
- [16] I. Mardani and R. Wirawan, "Pengaruh Bentuk Model Virtual Reality Terhadap Lama Durasi Penggunaan Dan Aktivitas Pengguna," *INFORMATIK: Jurnal Ilmu Komputer*, vol. 14, no. 1, pp. 25–31, 2018. <https://doi.org/10.52958/iftk.v14i1.404>
- [17] D. Rizaldi and A. Adnan, "Market Basket Analysis Menggunakan Algoritma Apriori: Kasus Transaksi 212 Mart Soebrantas Pekanbaru," *J. Stat. dan Apl.*, vol. 5, no. 1, pp. 31–40, 2021, <https://doi.org/10.21009/jsa.05103>.
- [18] F. S. Zikri and M. Ikhsan, "The Comparison Between The Apriori Algorithm And The FP-Growth Algorithm In Determining Frequent Pattern," *INOVTEK Polbeng - Seri Inform.*, vol. 10, no. 2, pp. 615–625, 2025, <https://doi.org/10.35314/s1yanj03>.
- [19] Lintang Mugi Lestari and Irfan Ali, "Penerapan Algoritma FP-Growth Untuk Menentukan Pola Penjualan Toko Ellia Umami," *J. Student Res.*, vol. 1, no. 3, pp. 367–378, 2023, <https://doi.org/10.55606/jsr.v1i3.1267>.
- [20] Y. Yulani, R. Kurniawan, and Y. A. Wijaya, "Implementasi Algoritma Fp-Growth Pada Data Transaksi Penjualan Seblak Jontor," *JIKA (Jurnal Informatika)*, vol. 8, no. 1, pp. 112–122, 2024. <https://doi.org/10.31000/jika.v8i1.10397>
- [21] D. Mahendra and A. D. Sabilla, "Sistem Analisis Pola Pembelian Konsumen Menggunakan Algoritma Fp-Growth," *J. Teknol. Inf. Dan Komun.*, vol. 14, no. 1, pp. 209–217, 2023, <https://doi.org/10.51903/jtikp.v14i1.560>.
- [22] K. M. R. A. Utama, R. Umar, and A. Yudhana, "Penerapan Algoritma Fp-Growth Untuk Penentuan Pola Pembelian Transaksi Penjualan Pada Toko Kgs Rizky Motor," *Dinamik*, vol. 25, no. 1, pp. 20–28, 2020, <https://doi.org/10.35315/dinamik.v25i1.7870>.
- [23] S. Sofwatillah, R. Risnita, M. S. Jailani, and D. A. Saksitha, "Tehnik Analisis Data Kuantitatif Dan Kualitatif Dalam Penelitian Ilmiah," *J. Genta Mulia*, vol. 15, no. 2, pp. 80–91, 2024. <https://ejournal.uncm.ac.id/index.php/gm/article/view/1147>
- [24] I. Afriantoro, W. Hadikristanto, and A. F. Putra, "Rancangan Sistem Pendataan Fisik Kendaraan di PT Tass Engineering Berbasis Web Menggunakan Metode Waterfall," *J. Tek. Informarika dan Komput. MH. Thamrin*, vol. 8, no. 2, pp. 121–134, 2022. <https://doi.org/10.37012/jtik.v8i2.1230>