



Optimalisasi Penentuan Tata Letak Barang Menggunakan Algoritma FP-Growth Pada Data Transaksi Penjualan

Rohiqim Mahtum^{1*}, Zaehol Fatah²

¹Teknologi Informasi Fakultas Sains & Teknologi, Universitas Ibrahimy

²Sistem Informasi Fakultas Sains & Teknologi, Universitas Ibrahimy

^{1*}mahtumrohiqim28@gmail.com, ²zaeholfatah@gmail.com

Article History:

Received Nov 24th, 2024

Revised Nov 25th, 2024

Accepted Nov 26th, 2024

Abstrak

Penentuan tata letak barang yang optimal di sebuah toko memiliki peran penting dalam meningkatkan efisiensi operasional dan pengalaman pelanggan. Dalam penelitian ini, diusulkan penerapan algoritma FP-Growth untuk menganalisis pola asosiasi dari data transaksi penjualan guna mengoptimalkan tata letak barang. Algoritma FP-Growth dipilih karena kemampuannya dalam menemukan asosiasi frekuensi tinggi antar produk tanpa harus melalui tahap pencarian kandidat yang memerlukan waktu komputasi besar. Dengan menganalisis hubungan antar produk yang sering dibeli bersamaan, hasil penelitian ini memberikan rekomendasi penempatan produk yang strategis untuk memaksimalkan peluang pembelian dan meningkatkan kepuasan pelanggan. Studi kasus dilakukan pada data transaksi sebuah toko ritel yang diperoleh di situs penyedia dataset Kaggle, dengan hasil menunjukkan peningkatan efisiensi dalam pengaturan tata letak barang serta potensi peningkatan penjualan. Implementasi FP-Growth terbukti efektif dalam mengurangi waktu analisis dan memberikan hasil yang akurat dalam menentukan hubungan antar produk. Penelitian ini diharapkan dapat menjadi acuan bagi pengelola toko ritel dalam mengoptimalkan tata letak barang secara lebih ilmiah dan data-driven.

Kata Kunci : Tata Letak, FP-Growth, Asosiasi, data transaksi, Penjualan.

Abstract

Determining the optimal layout of goods in a store has an important role in improving operational efficiency and customer experience. In this research, it is proposed to apply the FP-Growth algorithm to analyze association patterns from sales transaction data in order to optimize the layout of goods. The FP-Growth algorithm was chosen because of its ability to find high frequency associations between products without having to go through the candidate search stage which requires a large amount of computing time. By analyzing the relationship between products that are often purchased together, the results of this research provide recommendations for strategic product placement to maximize purchasing opportunities and increase customer satisfaction. A case study was conducted on transaction data from a retail store obtained on the Kaggle dataset provider site, with the results showing increased efficiency in organizing the layout of goods and the potential for increasing sales. The implementation of FP-Growth has proven to be effective in reducing analysis time and providing accurate results in determining relationships between products. It is hoped that this research can become a reference for retail store managers in optimizing the layout of goods in a more scientific and data-driven manner.

Keyword : Layout, FP-Growth, Association, transaction data, sale.

PENDAHULUAN

Penentuan tata letak barang yang optimal dan efisien di toko ritel merupakan salah satu faktor penting dalam meningkatkan penjualan dan pengalaman pelanggan. Tata letak yang tepat dapat membantu para pelanggan untuk menemukan produk dengan lebih mudah, meningkatkan waktu kunjungan serta mengoptimalkan penjualan barang bagi pemilik toko. Sebaliknya, tata letak yang kurang efektif dapat membuat pelanggan menjadi bingung, mengurangi tingkat kepuasan pelanggan, serta menurunkan potensi penjualan. Oleh karena itu banyak pemilik toko ritel memutar otak untuk mencari strategi yang optimal dalam pengaturan produk di ruang jual agar menarik daya minat pelanggan.



Salah satu pendekatan yang dapat diterapkan dalam menentukan tata letak barang adalah dengan memanfaatkan data transaksi penjualan untuk menemukan pola hubungan antar produk. Data mining atau penambangan data telah terbukti efektif dalam mengidentifikasi pola tersembunyi dari data transaksi yang besar dan kompleks. Salah satu teknik yang populer dalam hal ini adalah algoritma FP-Growth (Frequent Pattern Growth), yang dirancang untuk menemukan pola asosiasi antar produk yang sering dibeli bersamaan oleh pelanggan. Dengan menggunakan algoritma ini, pengelola toko dapat memperoleh wawasan tentang produk-produk yang memiliki keterkaitan dan meletakkannya secara strategis untuk meningkatkan peluang pembelian.

FP-Growth dikenal karena keefisiensinya dibandingkan dengan algoritma pencarian pola lain, seperti Apriori, yang membutuhkan proses perhitungan kandidat berulang kali (Dwi Insani & Al Fatta, 2023). FP-Growth bekerja dengan membangun struktur data FP-Tree yang memungkinkan eksplorasi pola-pola frekuensi tinggi tanpa harus mengulang proses pemindaian basis data. Hal ini menjadikan FP-Growth sebagai metode yang sangat sesuai untuk dataset transaksi yang besar dan kompleks, seperti yang sering ditemui di toko ritel.

Penelitian ini bertujuan untuk mengoptimalkan tata letak barang di toko dengan memanfaatkan algoritma FP-Growth dalam menganalisis data transaksi penjualan. Melalui identifikasi pola asosiasi antar produk, diharapkan penelitian ini dapat memberikan rekomendasi yang valid dan berbasis data untuk penempatan produk yang lebih strategis. Selain itu, penelitian ini juga mengeksplorasi bagaimana algoritma FP-Growth dapat diterapkan secara praktis dalam konteks ritel untuk meningkatkan efektivitas tata letak barang dan pada akhirnya dapat meningkatkan penjualan.

Dengan demikian, penelitian ini memberikan kontribusi pada pemanfaatan teknologi data mining, khususnya algoritma FP-Growth, dalam konteks optimasi operasional di sektor ritel. Temuan penelitian ini diharapkan tidak hanya bermanfaat bagi pengelola toko, tetapi juga bagi para peneliti dan praktisi yang ingin menerapkan pendekatan serupa dalam industri lain yang berkaitan dengan penjualan dan tata letak produk.

Landasan Teori

Data Mining

Data mining merupakan proses untuk mengekstraksi pengetahuan atau informasi berharga dari kumpulan data yang besar dan rumit. Tujuan utamanya adalah menemukan pola, hubungan, atau informasi yang tidak langsung terlihat dalam data, sehingga bisa memberikan wawasan yang lebih mendalam dan bernilai (Mai et al., 2022).

Definisi lain, Data Mining merupakan serangkaian langkah yang bertujuan untuk menemukan informasi atau pengetahuan tersembunyi dari data berukuran besar. Pengetahuan tersebut diperoleh melalui proses ekstraksi dan pemilihan atribut penting yang relevan serta berdampak pada prediksi. Proses ini dilakukan dengan memanfaatkan teknik statistik, kecerdasan buatan, dan pembelajaran mesin (Yogianto et al., 2024).

Proses data mining menggunakan berbagai teknik statistik, matematika, dan kecerdasan buatan untuk menganalisis data secara sistematis dan otomatis. Hasil dari data mining ini dapat dimanfaatkan untuk mendukung pengambilan keputusan, mengidentifikasi tren pasar, meningkatkan efisiensi operasional, atau merancang strategi bisnis (Gede et al., n.d.).

Pengelompokan Data Mining

Berdasarkan tugas dan fungsinya data mining dibagi menjadi beberapa kelompok diantaranya yaitu:

a. *Description*

Peneliti dan analis sering kali ingin menemukan cara sederhana untuk menggambarkan pola dan tren yang ada dalam data. Sebagai contoh, petugas pemilu mungkin tidak menyadari bahwa kandidat yang dianggap kurang profesional akan mendapatkan dukungan yang minim dalam pemilihan presiden. Penggambaran pola dan tren ini sering kali memberikan penjelasan yang mungkin terkait dengan fenomena tersebut.

b. *Classification*

Klasifikasi melibatkan variabel target yang bersifat kategori. Sebagai contoh, tingkat pendapatan dapat dikelompokkan menjadi tiga kategori: pendapatan tinggi, sedang, dan rendah.

Contoh lain dari klasifikasi dalam bisnis dan penelitian meliputi:

1. Menentukan apakah suatu transaksi kartu kredit merupakan penipuan atau bukan.
2. Memperkirakan apakah pengajuan hipotek dari seorang nasabah merupakan kredit yang baik atau buruk.
3. Mendiagnosis penyakit seorang pasien untuk mengetahui ke dalam kategori penyakit apa ia termasuk.

c. *Prediction*

Prediksi serupa dengan klasifikasi dan estimasi, namun perbedaannya adalah hasil dari prediksi mengacu pada nilai yang akan terjadi di masa depan. Contoh prediksi dalam bisnis dan penelitian meliputi:

1. Prediksi harga beras dalam tiga bulan mendatang.
2. Prediksi persentase peningkatan kecelakaan lalu lintas tahun depan jika batas kecepatan minimum dinaikkan.

Beberapa metode dan teknik yang digunakan dalam klasifikasi dan estimasi juga bisa diterapkan pada prediksi, tergantung pada situasi yang tepat.

d. *Estimation*



Estimasi mirip dengan klasifikasi, tetapi variabel targetnya lebih bersifat numerik daripada kategori. Model dibangun berdasarkan catatan lengkap yang menyediakan nilai variabel target untuk prediksi. Kemudian, pada tahap berikutnya, nilai variabel target diperkirakan berdasarkan nilai variabel prediktor. Sebagai contoh, estimasi tekanan darah sistolik pada pasien rumah sakit dapat dilakukan dengan memperhitungkan usia, jenis kelamin, indeks massa tubuh, dan kadar natrium darah. Hubungan antara tekanan darah sistolik dan variabel prediktor selama proses pembelajaran akan menghasilkan model estimasi. Model ini nantinya bisa digunakan untuk memperkirakan nilai pada kasus baru.

Contoh lain adalah memperkirakan nilai indeks prestasi kumulatif (IPK) mahasiswa pascasarjana dengan melihat IPK mahasiswa saat mengikuti program sarjana.

e. *Clustering*

Pengelompokan (clustering) adalah proses mengelompokkan catatan, pengamatan, atau objek berdasarkan kesamaan, membentuk kelas-kelas yang serupa. Kluster merupakan sekumpulan catatan yang mirip satu sama lain, tetapi berbeda dengan catatan di kluster lain.

Pengelompokan berbeda dari klasifikasi karena tidak melibatkan variabel target. Algoritma clustering tidak bertujuan untuk mengklasifikasikan, mengestimasi, atau memprediksi nilai variabel target. Sebaliknya, algoritma ini membagi seluruh data menjadi kelompok-kelompok yang serupa (homogen), di mana kesamaan catatan dalam satu kelompok adalah yang tertinggi, sedangkan kesamaan dengan catatan di kelompok lain adalah yang terendah.

Contoh pengelompokan dalam bisnis dan penelitian meliputi:

1. Mengidentifikasi kelompok konsumen untuk menargetkan pemasaran produk bagi perusahaan dengan anggaran terbatas.
2. Dalam audit akuntansi, memisahkan perilaku keuangan yang baik dari yang mencurigakan.
3. Mengelompokkan ekspresi gen untuk menemukan kesamaan perilaku di antara sejumlah besar gen.

f. *Association*

Tugas asosiasi dalam data mining adalah mengidentifikasi atribut-atribut yang muncul bersamaan. Dalam dunia bisnis, ini sering disebut sebagai analisis keranjang belanja.

Contoh asosiasi dalam bisnis dan penelitian meliputi:

1. Menganalisis jumlah pelanggan dari perusahaan telekomunikasi seluler yang kemungkinan akan merespons positif penawaran peningkatan layanan.
2. Menemukan produk di supermarket yang sering dibeli bersamaan dan produk yang tidak pernah dibeli bersama (Luthfi, 2009).

Association Rules (Aturan Asosiasi)

Asosiasi adalah teknik yang digunakan untuk mengidentifikasi hubungan antar item dalam satu set item. Aturan asosiasi diperoleh melalui pencarian frequent itemset, yaitu kombinasi item yang paling sering muncul dalam sebuah itemset dan harus memenuhi syarat minimal support dan minimum confidence. Support dan confidence digunakan untuk mengukur pentingnya aturan asosiasi tersebut (Mambaya et al., 2021).

a. *Support*

Support adalah sebuah metrik yang mengukur seberapa sering suatu itemset muncul dalam dataset. Metrik ini juga membantu menyaring itemset yang jarang muncul sehingga proses pencarian pola menjadi lebih efisien dan relevan. Secara formal, support dari suatu itemset A didefinisikan sebagai:

$$\text{Support } A = \frac{\text{Jumlah Transaksi mengandung } A}{\text{Total Transaksi}} \quad (1)$$

Dan cara untuk menentukan support dari 2 item yaitu item A dan B menggunakan rumus sebagai berikut ini:

$$\text{Support } (A,B) = \frac{\text{Jumlah Transaksi yang mengandung } A \text{ dan } B}{\text{Total Transaksi}} \quad (2)$$

b. *Confidence*

Confidence adalah sebuah ukuran yang menggambarkan tingkat keterkaitan antara dua item secara kondisional, berdasarkan suatu kondisi tertentu. Contohnya, confidence mengukur seberapa sering item B dibeli oleh konsumen ketika konsumen juga membeli item A (Munanda & Monalisa, 2021).

$$\text{Confidence } P(B|A) = \frac{\text{Jumlah Transaksi mengandung } A \text{ dan } B}{\text{Jumlah Transaksi mengandung } A} \times 100\% \quad (3)$$

c. *Lift Ratio*

Lift ratio adalah salah satu metode yang efektif untuk menilai kekuatan aturan asosiasi. Metode ini bekerja dengan membagi nilai confidence dengan expected confidence. Berikut ini adalah rumus untuk menghitung expected confidence.



$$\text{Expected Confidence (X=>Y)} = \frac{\text{Banyak Transaksi yang memuat Y}}{\text{Total banyak transaksi}} \quad (4)$$

Rumus untuk menghitung lift ratio.

$$\text{Lift(X=>Y)} = \frac{\text{Confidence (X=>Y)}}{\text{Expected Confidence}} \quad (5)$$

Algoritma FP-Growth

Algoritma Frequent Pattern Growth (FP-Growth) merupakan salah satu metode yang dapat digunakan untuk menemukan himpunan item yang sering muncul (frequent itemsets) dalam suatu kumpulan data. FP-Growth menggunakan pendekatan pembentukan pohon, yang dikenal sebagai FP-Tree, dalam proses pencarian frequent itemsets tanpa perlu menghasilkan kandidat seperti pada algoritma Apriori. Dengan memanfaatkan FP-Tree, algoritma FP-Growth mampu menemukan frequent itemsets secara langsung, membuatnya lebih efisien dibandingkan algoritma Apriori.

Proses pencarian frequent itemsets dalam FP-Growth dilakukan melalui dua tahap utama, yaitu pembentukan FP-Tree dan penerapan algoritma FP-Growth itu sendiri untuk menemukan frequent itemsets. Struktur data yang digunakan dalam algoritma ini merupakan pengembangan dari pohon prefix yang disebut FP-Tree. FP-Growth kemudian menggunakan pohon ini untuk mengekstrak frequent itemsets dengan menerapkan prinsip divide and conquer, sehingga mempercepat proses pencarian (Dewi, 2019).

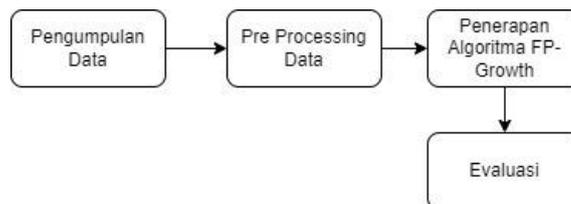
Rapid Miner

RapidMiner adalah sebuah platform perangkat lunak analisis data yang digunakan untuk penambangan data (data mining), pembelajaran mesin (machine learning), dan analisis prediktif (predictive analytics). RapidMiner menawarkan lingkungan visual yang memudahkan pengguna untuk merancang, menguji, dan menjalankan berbagai proses analisis tanpa harus menulis kode secara manual. Perangkat lunak ini mendukung berbagai metode analisis data seperti klasifikasi, klusterisasi, regresi, dan deteksi anomali, serta menyediakan integrasi dengan berbagai sumber data.

Salah satu kelebihan utama dari RapidMiner adalah kemampuannya untuk mendukung berbagai tahap dalam siklus penambangan data, termasuk pemrosesan data (data preprocessing), pemodelan (modeling), evaluasi (evaluation), dan penerapan (deployment). Dengan fitur drag-and-drop serta antarmuka yang intuitif, RapidMiner memungkinkan ilmuwan data dari berbagai latar belakang untuk melakukan analisis mendalam tanpa perlu pengetahuan pemrograman yang mendalam (Hofmann, 2016).

METODE

Tahapan-tahapan yang dilakukan dalam mendukung penelitian kali ini terdapat beberapa langkah sebagaimana yang terdapat pada gambar berikut ini:



Gambar 1. Metode Penelitian

Pengumpulan Data

Pada penelitian ini, sumber data yang digunakan diperoleh dari salah satu platform penyedia layanan data sains terkemuka di internet, yaitu Kaggle. Kaggle merupakan komunitas yang populer di kalangan ilmuwan data dan analisis, menyediakan berbagai dataset yang dapat diakses secara gratis untuk keperluan penelitian dan pengembangan (Hadianti et al., n.d.). Dalam konteks penelitian ini, data yang dipilih adalah data penjualan yang berasal dari toko ritel. Data penjualan ini mencakup berbagai informasi penting, seperti jumlah produk yang terjual, kategori barang, harga, serta waktu transaksi. Dengan menggunakan dataset ini, penelitian bertujuan menganalisis tren penjualan, mengidentifikasi pola pembelian konsumen, dan mengeksplorasi faktor-faktor yang memengaruhi kinerja penjualan di toko ritel tersebut. Data yang komprehensif ini diharapkan dapat memberikan wawasan yang lebih dalam mengenai dinamika pasar ritel dan membantu dalam pengambilan keputusan strategis.

Tahap Preprocessing Data

Preprocessing data adalah serangkaian langkah yang dilakukan untuk menyiapkan data mentah sebelum digunakan dalam proses analisis atau pengolahan lebih lanjut. Proses ini sangat penting karena kualitas data yang rendah dapat mempengaruhi hasil analisis dan model yang dibangun. Preprocessing biasanya mencakup beberapa tahap, seperti pengumpulan data, pembersihan data, dan transformasi data, yang masing-masing memiliki tujuan tertentu dalam meningkatkan kualitas dan relevansi dataset.



- a. Pengumpulan Data: Pada tahap ini, data dikumpulkan dari berbagai sumber, seperti basis data, file teks, atau API. Data yang dikumpulkan harus relevan dengan masalah yang akan dipecahkan.
- b. Pembersihan Data: Proses ini meliputi identifikasi dan perbaikan data yang tidak lengkap, tidak konsisten, atau mengandung kesalahan. Dalam tahap ini, penghapusan data duplikat, penanganan nilai yang hilang, dan perbaikan kesalahan pencatatan dilakukan untuk memastikan integritas data.
- c. Transformasi Data: Data yang sudah bersih kemudian diubah ke dalam format yang sesuai untuk analisis. Ini dapat melibatkan normalisasi, pengkodean kategori, atau penggabungan data dari berbagai sumber menjadi satu dataset yang komprehensif.
- d. Reduksi Dimensi: Dalam beberapa kasus, data yang terlalu besar atau kompleks dapat disederhanakan tanpa menghilangkan informasi penting, melalui teknik seperti PCA (Principal Component Analysis) untuk meningkatkan efisiensi pemrosesan.

Dengan melakukan preprocessing, data menjadi lebih siap untuk analisis, sehingga menghasilkan model yang lebih akurat dan dapat diandalkan (Bhatia, 2019).

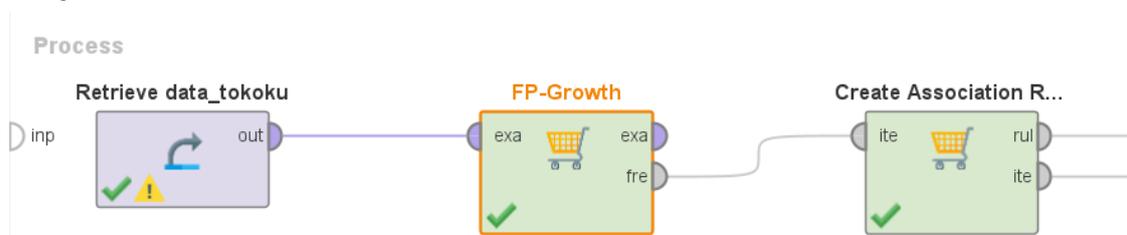
Data yang sudah melalui tahap preprocessing sebagaimana gambar berikut:

Customer	Gula	Kopi	Aqua	Popok	Sprei	Sabun	Sampo	Kemeja	Celana	Boneka
1	1	1	1	0	0	0	1	1	0	0
2	1	1	1	0	1	1	0	0	1	1
3	0	0	0	1	1	0	0	0	0	1
4	1	0	1	0	0	0	0	0	0	0
5	0	0	1	1	0	0	1	0	0	0
6	1	1	0	0	0	1	0	0	0	0
7	0	0	0	0	0	1	0	0	0	1
8	0	0	1	1	1	1	1	1	1	0
9	1	1	0	0	0	0	0	0	0	1
10	0	0	1	0	0	0	1	0	0	0
11	1	1	1	0	0	0	0	0	0	0
13	0	0	0	0	0	1	1	1	0	0

Gambar 2. Data Uji

Implementasi Algoritma FP-Growth

Pada penelitian ini implementasi algoritma FP-Growth dilakukan dengan bantuan aplikasi RapidMiner 10.03.001. sebagaimana gambar berikut:



Gambar 3 Implementasi di Rapid Miner

- **Retrive Data Penjualan**
Operator Retrieve Data Penjualan digunakan untuk mengambil data yang telah melalui tahap praproses dan siap diolah menggunakan model di Rapid Miner. Setelah data dipersiapkan melalui berbagai tahapan praproses, operator ini berperan dalam memastikan data tersebut dapat dimasukkan ke dalam alur pemrosesan berikutnya, sehingga analisis lebih lanjut atau pembuatan model prediktif dapat dilakukan secara optimal.
- **FP-Growth**
Operator ini berfungsi untuk menghasilkan frequent item set yang nantinya akan digunakan oleh operator berikutnya dalam proses pembuatan aturan asosiasi. Dengan menentukan nilai support dari data transaksi yang telah dimasukkan ke dalam model, operator ini membantu mengidentifikasi pola frekuensi item yang sering muncul bersama-sama, sehingga dapat digunakan sebagai dasar dalam analisis lebih lanjut untuk menemukan hubungan atau asosiasi antar item.
- **Create Association Rules**
Operator ini digunakan untuk menghasilkan aturan asosiasi dengan menetapkan nilai minimal confidence dari item atau itemset pada data transaksi yang telah dimasukkan ke dalam model. Dengan cara ini, operator ini membantu dalam menemukan pola asosiasi antar item yang memenuhi ambang batas confidence tertentu, sehingga aturan-aturan yang dihasilkan dapat lebih akurat dalam merepresentasikan hubungan antar item dalam dataset.



HASIL DAN PEMBAHASAN

Pada tabel berikut ini merupakan hasil pemodelan dari data yang peneliti uji menggunakan RapidMiner berdasarkan nilai support paling tinggi menggunakan algoritma FP-Growth.

Table 0.1. Hasil Pemodelan dengan FP-Growth pada Rapid Miner.

Support	Item 1	Item 2	Item 3	Item 4
0.667	Sabun			
0.583	Kopi			
0.583	Sampo			
0.500	Gula			
0.417	Aqua			
0.417	Sprei			
0.333	Popok			
0.250	Boneka			
0.250	Celana			
0.417	Sabun	Kopi		
0.500	Sabun	Sampo		
0.333	Sabun	Gula		
0.333	Sabun	Aqua		
0.250	Sabun	Sprei		
0.250	Sabun	Popok		
0.250	Sabun	Boneka		
0.250	Sabun	Celana		
0.250	Kopi	Sampo		
0.500	Kopi	Gula		
0.333	Kopi	Aqua		
0.333	Kopi	Sprei		
0.250	Kopi	Popok		
0.250	Sampo	Sprei		
0.250	Sampo	Boneka		
0.250	Sampo	Celana		
0.250	Gula	Aqua		
0.333	Gula	Sprei		
0.250	Gula	Popok		
0.250	Sprei	Popok		
0.250	Sprei	Boneka		
0.250	Sabun	Kopi	Sampo	
0.333	Sabun	Kopi	Gula	
0.250	Sabun	Kopi	Aqua	
0.250	Sabun	Sampo	Sprei	
0.250	Sabun	Sampo	Boneka	
0.250	Sabun	Sampo	Celana	
0.250	Sabun	Sprei	Boneka	
0.250	Kopi	Gula	Aqua	
0.333	Kopi	Gula	Sprei	
0.250	Kopi	Gula	Popok	
0.250	Sampo	Sprei	Boneka	
0.250	Sabun	Sampo	Sprei	Boneka



Dilihat dari hasil pengujian tersebut terdapat beberapa item yang memiliki nilai support yang tinggi serta menemukan pola frekuensi item yang sering muncul bersama-sama. Semakin tinggi nilai support maka akan semakin bagus (Ardianto & Fitriyah, 2019).

Hasil Association Rules

Hasil pengujian pembentukan Association Rules menunjukkan bahwasannya item Sampo dan Sabun sering dibeli secara bersamaan dengan nilai Support 0,5 dan nilai confidence 0,857 disusul dengan item Kopi dan Gula dengan nilai Support 0,5 dan Confidence 0,857. Untuk lebih jelasnya akan disajikan hasil perhitungan di rapid miner dengan tabel berikut :

Table 0.2. Hasil Association Rules

Premises (If)	Conclusion (Then)	Confidence	Support
Sampo	Sabun	0.8571428571428571	0.5
Kopi	Gula	0.8571428571428571	0.5
Boneka	Sabun	1.0	0.25
Celana	Sabun	1.0	0.25
Gula	Kopi	1.0	0.5
Boneka	Sampo	1.0	0.25
Celana	Sampo	1.0	0.25
Boneka	Sprei	1.0	0.25
Kopi, Sampo	Sabun	1.0	0.25
Sabun, Gula	Kopi	1.0	0.3333333333333333
Sabun, Sprei	Sampo	1.0	0.25
Sampo, Sprei	Sabun	1.0	0.25
Boneka	Sabun, Sampo	1.0	0.25
Sabun, Boneka	Sampo	1.0	0.25
Sampo, Boneka	Sabun	1.0	0.25
Celana	Sabun, Sampo	1.0	0.25
Sabun, Celana	Sampo	1.0	0.25
Sampo, Celana	Sabun	1.0	0.25
Sabun, Sprei	Boneka	1.0	0.25
Boneka	Sabun, Sprei	1.0	0.25
Sabun, Boneka	Sprei	1.0	0.25
Sprei, Boneka	Sabun	1.0	0.25
Gula, Aqua	Kopi	1.0	0.25
Kopi, Sprei	Gula	1.0	0.3333333333333333
Gula, Sprei	Kopi	1.0	0.3333333333333333
Kopi, Popok	Gula	1.0	0.25
Gula, Popok	Kopi	1.0	0.25
Sampo, Sprei	Boneka	1.0	0.25
Boneka	Sampo, Sprei	1.0	0.25
Sampo, Boneka	Sprei	1.0	0.25
Sprei, Boneka	Sampo	1.0	0.25
Sabun, Sprei	Sampo, Boneka	1.0	0.25
Sampo, Sprei	Sabun, Boneka	1.0	0.25
Sabun, Sampo, Sprei	Boneka	1.0	0.25
Boneka	Sabun, Sampo, Sprei	1.0	0.25
Sabun, Boneka	Sampo, Sprei	1.0	0.25
Sampo, Boneka	Sabun, Sprei	1.0	0.25
Sabun, Sampo, Boneka	Sprei	1.0	0.25
Sprei, Boneka	Sabun, Sampo	1.0	0.25
Sabun, Sprei, Boneka	Sampo	1.0	0.25



Sampo, Sprei, Boneka	Sabun	1.0	0.25
----------------------	-------	-----	------

Berikut hasil association rules dalam bentuk Deskripsi hasil perhitungan menggunakan rapid miner:

Association Rules

- [Aqua] --> [Sabun] (confidence: 0.800)
- [Aqua] --> [Kopi] (confidence: 0.800)
- [Sprei] --> [Kopi] (confidence: 0.800)
- [Sprei] --> [Gula] (confidence: 0.800)
- [Sabun, Kopi] --> [Gula] (confidence: 0.800)
- [Sprei] --> [Kopi, Gula] (confidence: 0.800)
- [Sampo] --> [Sabun] (confidence: 0.857)
- [Kopi] --> [Gula] (confidence: 0.857)
- [Boneka] --> [Sabun] (confidence: 1.000)
- [Celana] --> [Sabun] (confidence: 1.000)
- [Gula] --> [Kopi] (confidence: 1.000)
- [Boneka] --> [Sampo] (confidence: 1.000)
- [Celana] --> [Sampo] (confidence: 1.000)
- [Boneka] --> [Sprei] (confidence: 1.000)
- [Kopi, Sampo] --> [Sabun] (confidence: 1.000)
- [Sabun, Gula] --> [Kopi] (confidence: 1.000)
- [Sabun, Sprei] --> [Sampo] (confidence: 1.000)
- [Sampo, Sprei] --> [Sabun] (confidence: 1.000)
- [Boneka] --> [Sabun, Sampo] (confidence: 1.000)
- [Sabun, Boneka] --> [Sampo] (confidence: 1.000)
- [Sampo, Boneka] --> [Sabun] (confidence: 1.000)
- [Celana] --> [Sabun, Sampo] (confidence: 1.000)
- [Sabun, Celana] --> [Sampo] (confidence: 1.000)
- [Sampo, Celana] --> [Sabun] (confidence: 1.000)
- [Sabun, Sprei] --> [Boneka] (confidence: 1.000)
- [Boneka] --> [Sabun, Sprei] (confidence: 1.000)
- [Sabun, Boneka] --> [Sprei] (confidence: 1.000)
- [Sprei, Boneka] --> [Sabun] (confidence: 1.000)
- [Gula, Aqua] --> [Kopi] (confidence: 1.000)
- [Kopi, Sprei] --> [Gula] (confidence: 1.000)
- [Gula, Sprei] --> [Kopi] (confidence: 1.000)
- [Kopi, Popok] --> [Gula] (confidence: 1.000)
- [Gula, Popok] --> [Kopi] (confidence: 1.000)
- [Sampo, Sprei] --> [Boneka] (confidence: 1.000)
- [Boneka] --> [Sampo, Sprei] (confidence: 1.000)
- [Sampo, Boneka] --> [Sprei] (confidence: 1.000)
- [Sprei, Boneka] --> [Sampo] (confidence: 1.000)
- [Sabun, Sprei] --> [Sampo, Boneka] (confidence: 1.000)
- [Sampo, Sprei] --> [Sabun, Boneka] (confidence: 1.000)
- [Sabun, Sampo, Sprei] --> [Boneka] (confidence: 1.000)
- [Boneka] --> [Sabun, Sampo, Sprei] (confidence: 1.000)
- [Sabun, Boneka] --> [Sampo, Sprei] (confidence: 1.000)
- [Sampo, Boneka] --> [Sabun, Sprei] (confidence: 1.000)
- [Sabun, Sampo, Boneka] --> [Sprei] (confidence: 1.000)
- [Sprei, Boneka] --> [Sabun, Sampo] (confidence: 1.000)
- [Sabun, Sprei, Boneka] --> [Sampo] (confidence: 1.000)
- [Sampo, Sprei, Boneka] --> [Sabun] (confidence: 1.000)

Terlihat hasil dari association rules tersebut hasilnya sama dengan penyajian dalam bentuk tabel sebelumnya terlihat asosiasi dari item Sampo dan Sabun serta Kopi dan Gula memiliki nilai Support dan Confidence yang tinggi sehingga dapat diambil keputusan bahwasannya untuk mengoptimalkan penjualan maka perlu mendekatkan item Sampo dan Sabun kemudian item Kopi dan Gula secara berdekatan karena keempat item tersebut memiliki potensi yang tinggi untuk dibeli secara bersamaan oleh pelanggan.



KESIMPULAN

Algoritma FP-Growth sangat efektif untuk mencari pola asosiasi, dengan mencari nilai Support serta nilai Confidence dari dataset sehingga dapat mengetahui pola asosiasi yang ada didalamnya. Sebagaimana hasil pengujian dataset diatas yang menunjukkan pola Asosiasi yang kuat dari Item Sampo dan Sabun serta Item Kopi dan Gula dengan nilai Support masing - masing 0.5 yang artinya terdapat 50% pembeli dengan pola asosiasi tersebut, dan nilai Kepastian atau Confidence masing - masing 0.857.

Dengan menempatkan item-item yang sering dibeli secara bersamaan, diharapkan dapat meningkatkan daya beli dari pelanggan, serta mendorong penjualan lewat strategi pemasaran yang lebih terarah. Pengimplementasian dengan Algoritma FP-Growth ini menjadi bukti bahwasannya analisis data mining dapat mendukung inovasi-inovasi dalam berbisnis sehingga menjadi formula yang efektif dalam strategi bisnis.

DAFTAR PUSTAKA

- Ardianto, A., & Fitriah, D. (2019). Penerapan Algoritma FP-Growth Rekomendasi Trend Penjualan ATK Pada CV. Fajar Sukses Abadi. *Jurnal Telekomunikasi Dan Komputer*, 9(1), 49. <https://doi.org/10.22441/incomtech.v9i1.3263>
- Bhatia, P. (2019). *Data Mining and Data Warehousing: Principles and Practical Techniques*. Cambridge University Press.
- Dewi, R. P., H. R. (2019). *Data Mining konsep dan aplikasi dalam bisnis*. Andi.
- Dwi Insani, F., & Al Fatta, H. (2023). PERBANDINGAN ALGORITMA APRIORI DAN FP-GROWTH UNTUK REKOMENDASI ITEM PAKET PADA KONTEN PROMOSI DI PERUSAHAAN MU-MART. In *Jurnal Bisnis Digital dan Sistem Informasi* (Vol. 4, Issue 2).
- Dristyan, F., & Syafnur, A. (2019, September). Aplikasi Web Usage Mining Menggunakan Metode Association Rule Dengan Algoritma Fp-Growth Untuk Mengetahui Pola Browsing Pengunjung Website. In *Prosiding Seminar Nasional Riset Information Science (SENARIS)* (Vol. 1, pp. 1060-1065).
- Gede, I., Sudipa, I., & Darmawiguna, M. (n.d.). *BUKU AJAR DATA MINING*. <https://www.researchgate.net/publication/377415198>
- Hadianti, S., Yosep Tember, F., Mandiri, N., Raya, J., No, J., Melayu, C., & Timur, J. (n.d.). ANALISIS SENTIMENT COVID-19 DI TWITTER MENGGUNAKAN METODE NAIVE BAYES DAN SVM. *Jurnal Teknologi Informasi*, 6(1). www.Kaggle.com.
- Hofmann, M., & K. R. (2016). *RapidMiner: Data Mining Use Cases and Business Analytics Applications*. CRC Press.
- luthfi, E. and A. U. (2009). *Algortima Data Mining*. Penerbit Andi.
- Mai, P., Tarigan, S., Tata Hardinata, J., Qurniawan, H., Safii, M., Winanjaya, R., Studi, P., Informasi, S., Tunas, S., & Pematangsiantar, B. (2022). *IMPLEMENTASI DATA MINING MENGGUNAKAN ALGORITMA APRIORI DALAM MENENTUKAN PERSEDIAAN BARANG (STUDI KASUS: TOKO SINAR HARAHAHAP)* (Vol. 12, Issue 2). <https://jurnal.umj.ac.id/index.php/just-it/index>
- Mambaya, J., Sofwan Adha, M., & Yacobus Padang, S. (2021). *Evaluasi Pola Penataan Barang Di Toko Jaya dengan Algoritma FP-Growth 33 INFINITY* (Vol. 1, Issue 2).
- Munanda, E., & Monalisa, S. (2021). PENERAPAN ALGORITMA FP-GROWTH PADA DATA TRANSAKSI PENJUALAN UNTUK PENENTUAN TATALETAK BARANG 1. *Jurnal Ilmiah Rekayasa Dan Manajemen Sistem Informasi*, 7(2), 173–184.
- Yogianto, A., Homaidi, A., & Fatah, Z. (2024). Implementasi Metode K-Nearest Neighbors (KNN) untuk Klasifikasi Penyakit Jantung. *G-Tech: Jurnal Teknologi Terapan*, 8(3), 1720–1728. <https://doi.org/10.33379/gtech.v8i3.4495>