

Penerapan Data Mining Menggunakan Algoritma *Fp-Growth* dalam Analisis Data Penjualan

Camila Rustam[✉], Sarjon Defit, Gunadi Widi Nurcahyo

Fakultas Ilmu Komputer, Universitas Putra Indonesia YPTK, Padang, 25221, Indonesia

camilarustam18@gmail.com

Abstract

The significant growth of sales data over time, especially in large-scale businesses, by conducting manual analysis can be inefficient and less able to reveal hidden patterns. Changes in consumer purchasing patterns can affect sales strategies at CV Tiga Putra. The problems faced by CV Tiga Putra, such as the absence of grouping of goods that are in demand and those that are not in demand by consumers, cause a buildup of goods that result in losses. This study aims to improve sales strategies and optimize the results of sales data analysis by utilizing the FP Growth algorithm. Data Mining is a method commonly used to search for information in big data. *Fp-Growth* is one of the algorithms applied to identify records that frequently appear in a data set. The data used is sales data for 2 weeks in March 2024 with 30 items of goods and 12 transaction data. The method used is the *Fp-Growth* algorithm. The application of a minimum support value of 75% and a minimum confidence value of 80% is used to support the performance of the *Fp-Growth* algorithm. The results of the analysis are that there are 36 pieces of knowledge from a combination of 2 items that meet the minimum support and confidence values. One of the association rules is 'If you buy Spix Mie Goreng 500 (K26) then you will buy Golda (K8)' with a support value of 75% and a confidence value of 82%. This study successfully implemented Data Mining using the *Fp-Growth* algorithm to improve CV Tiga Putra's sales strategy, so that the company can be more effective in reducing losses. This study also contributed to a significant increase in profits at CV Tiga Putra based on the use of sales data analysis that occurred in the previous period.

Keywords: *Sales Data, Fp-Growth, Data Mining, Big Data, Association Rule*

Abstrak

Pertumbuhan data penjualan dari waktu ke waktu yang signifikan terlebih pada bisnis berskala besar dengan melakukan analisa secara manual dapat menjadi tidak efisien dan kurang mampu mengungkapkan pola yang tersembunyi. Perubahan pola pembelian konsumen dapat mempengaruhi strategi penjualan di CV Tiga Putra. Permasalahan yang dihadapi pada CV Tiga Putra seperti tanpa adanya pengelompokan barang yang diminati dan yang tidak diminati oleh konsumen sehingga menyebabkan terjadinya penumpukan barang yang mengakibatkan kerugian. Penelitian ini bertujuan untuk meningkatkan strategi penjualan dan mengoptimalkan hasil analisis data penjualan dengan memanfaatkan algoritma FP Growth. Data Mining adalah metode yang umum digunakan untuk mencari informasi dalam big data. *Fp-Growth* adalah salah satu dari algoritma yang diterapkan untuk mengidentifikasi catatan yang sering muncul dalam kumpulan data. Data yang digunakan data penjualan selama 2 minggu pada bulan Maret 2024 dengan 30 item barang dan 12 data transaksi. Metode yang digunakan adalah algoritma *Fp-Growth*. Penerapan nilai minimum support 75% dan nilai minimum confidence 80% digunakan untuk mendukung kinerja algoritma *Fp-Growth*. Hasil Analisa ialah terdapat 36 pengetahuan dari kombinasi 2 item yang memenuhi nilai minimum support dan confidence. Salah satu rule asosiasinya yakni 'Jika membeli Spix Mie Goreng 500 (K26) maka akan membeli Golda (K8)' dengan nilai support 75% dan nilai confidence 82%. Penelitian ini berhasil menerapkan Data Mining menggunakan algoritma *Fp-Growth* untuk meningkatkan strategi penjualan CV Tiga Putra, sehingga perusahaan dapat lebih efektif dalam mengurangi kerugian. Penelitian ini juga memberikan kontribusi dalam peningkatan keuntungan secara signifikan pada CV Tiga Putra berdasarkan pemanfaatan analisis data penjualan yang terjadi pada periode sebelumnya.

Kata kunci: Data Penjualan, *Fp-Growth*, Data Mining, Big Data, Rule Asosiasi

KomtekInfo is licensed under a Creative Commons Attribution-Share Alike 4.0 International License.



1. Pendahuluan

Tren konsumen yang sering berubah dengan cepat merupakan salah satu tantangan terbesar dalam dunia bisnis terutama pada manajemen penjualan. Fenomena seperti perubahan gaya hidup, perubahan preferensi konsumen dan perkembangan teknologi dapat mempengaruhi apa dan bagaimana konsumen membeli suatu produk. Pertumbuhan data penjualan dari waktu ke waktu yang signifikan terlebih pada bisnis berskala

besar dengan melakukan analisa secara manual dapat menjadi tidak efisien dan kurang mampu mengungkapkan pola yang tersembunyi. Perubahan pola pembelian konsumen dapat mempengaruhi strategi penjualan. CV Tiga Putra adalah perusahaan yang bergerak di bidang makanan ringan dan minuman. Berbagai barang yang tersedia di perusahaan tersebut tanpa dikelompokkan barang yang diminati oleh konsumen dalam jumlah yang tidak relevan dengan yang tidak diminati sehingga terjadi penumpukan

barang dan penjualan barang yang mengakibatkan kerugian.

Knowledge Discovery in Databases (KDD) adalah proses menemukan informasi baru, lebih berharga, dan lebih mudah dipahami dari kumpulan data yang besar dan kompleks. Proses KDD menginterpretasikan hasil yang diperoleh dari dataset yang dikombinasikan dengan pengetahuan lain [1]. Meski mempunyai konsep yang hampir sama, namun tetap saling berkaitan. Salah satu langkah dalam keseluruhan proses KDD adalah penambahan data [2].

Data Mining adalah proses pengumpulan atau pengerukan informasi penting dari data besar (*Big Data*). Proses ini biasanya menggunakan metode matematika, statistika, bahkan *Artificial Intelligence* [3]. Data Mining adalah metode yang umum digunakan untuk mencari informasi dalam *big data*. Penambahan data menggunakan berbagai teknik seperti aturan asosiasi [4]. Aturan asosiasi adalah teknik yang digunakan dalam proses data mining yang membantu menentukan korelasi antar data yang diproses untuk mendapatkan aturan [5]. *Association rule mining* adalah teknik Data Mining yang mengekstraksi hubungan menarik (ketergantungan) dan pola / koneksi antar variabel dari kumpulan data besar yang tampaknya independen, dan menghasilkan kesimpulan dan keputusan yang dapat ditindaklanjuti [6]. Menemukan asosiasi-asosiasi dalam bentuk aturan-aturan sangatlah penting dalam konteks prediksi keadaan yang dapat dipahami [7].

Fp-Growth adalah salah satu dari algoritma yang diterapkan untuk mengidentifikasi catatan yang sering muncul dalam kumpulan data. Tujuan dari *Fp-Growth* adalah untuk menghasilkan pola yang sering muncul, yang pada gilirannya memungkinkan identifikasi setiap peristiwa atau rangkaian yang terjadi sekaligus dalam database [8]. Algoritma ini tidak menghasilkan kandidat (*candidate generation*), melainkan menerapkan konsep *Fp-tree* untuk mencari sekumpulan objek yang sering muncul [9].

Penelitian terdahulu yakni pada penelitian yang dilakukan oleh Fathurrahman dkk menunjukkan bahwa perbandingan algoritma apriori dengan *Fp-Growth* terhadap *market basket analysis* pada data penjualan *bakery* dengan jumlah dataset 20.508, data yang berasal dari website *kaggle* yang diunggah kuila pada tahun 2022. Hasil penelitian pembentukan aturan asosiasi dengan apriori nilai *confidence* tertinggi yakni 54,06% atas nama *alfajores (coffe)* sedangkan nilai *confidence* terendah yakni 33,86% atas nama *pastry (bread)*. Sementara itu *Fp-Growth* dalam pembentukan aturan asosiasi nilai *confidence* tertinggi yakni 55,21% atas nama *pastry (coffe)* sedangkan nilai *confidence* terendah yakni 33,86% atas nama *pastry (bread)*. Oleh karena itu, Apriori dan *Fp-Growth* menunjukkan perbedaan dalam pola kombinasi [10].

Penelitian yang dilakukan oleh Vidiya & Testiana menganalisis pola pembelian pada *lathansa café* dan ramen dengan algoritma *Fp-Growth* berbantuan Rapidminer. Jumlah data yang diperoleh yakni sebanyak 50 data dengan 8 item. Pada hasil aturan asosiasi dapat diperoleh nilai *support* 32% dan nilai *confidence* 94,1%. Nilai Tertinggi yang diperoleh 'jika membeli martabak sayur maka akan membeli paket hemat A' [11]. Selanjutnya pada penelitian yang dilakukan oleh Sugianto dan Sukmawati menerapkan *Fp-Growth* pada pola transaksi percetakan. Jumlah data sebanyak 704 record dengan 102 record berasal dari outlet dalam rentang waktu 6 bulan dan 602 record dari *marketplace* shopee dalam periode 12 bulan. Dataset terdiri dari 7 *field*. Hasil penelitian menunjukkan adanya keterkaitan antara dua produk, yaitu Buku Yasin L 208hl (Lengkap / memakai siku dan pita rumbai 208 halaman) dan Buku Yasin L 224hl (Lengkap/memakai siku dan pita rumbai 224 halaman). Kedua produk ini memiliki nilai *support* tertinggi sebesar 11,5% dari total transaksi, menunjukkan bahwa keduanya sering dibeli bersamaan. Selain itu, nilai *confidence* untuk keterkaitan antara kedua produk ini mencapai 100%, artinya jika pelanggan membeli Buku Yasin L 208hl, mereka pasti akan membeli juga Buku Yasin L 224hl [12].

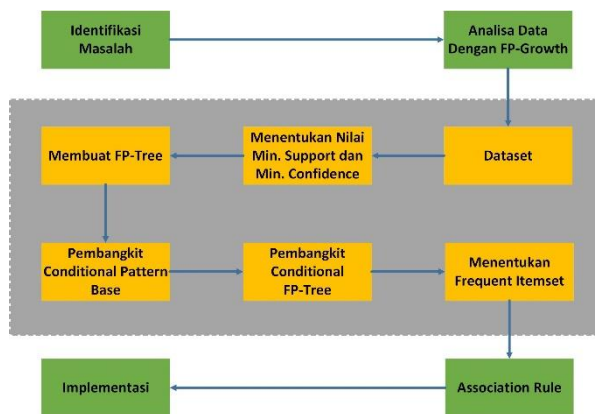
Penelitian yang dilakukan oleh Fauzi dkk mengimplementasikan Data Mining pada penjualan pakaian dengan *Fp-Growth*. Dengan data yang diambil selama 9 bulan (Desember 2021 – Agustus 2022). Data sampel adalah 15 buah transaksi. Hasil penelitian yakni pada hasil pencarian manual didapatkan 8 *rule* yang memiliki *confidence* tertinggi sebesar 87,5% ialah Jika pelanggan membeli item b (Jilbab) maka akan membeli item a (Gamis) dengan *Support* 53,33%. Pada pengujian hasil *association rule* dengan Rapidminer yakni memiliki *confidence* 100 % pada item a (Gamis) dan item b (Jilbab) dengan perhitungan *support* 53,3% [13]. Selanjutnya penelitian yang dilakukan oleh Yao dkk menunjukkan kajian keyakinan agama dikalangan mahasiswa dengan algoritma *Fp-Growth* dengan melakukan survei kuesioner dengan total 262 kuesioner online dan 200 kuesioner offline. Nilai *min. support* (Dukungan) sebesar 0,1 dan nilai *min. confidence* (Kepercayaan diri) sebesar 0,6. Hasil aturan asosiasinya dengan nilai *confidence* sebesar 83% dan nilai *support* sebesar 31% pada siswa yang memiliki keyakinan agama dengan mencari etika yang akan mengarah pada keyakinan agama melalui dilema dan tantangan pribadi [14].

Berdasarkan penelitian terdahulu telah menggunakan algoritma *Fp-Growth* untuk menganalisis perilaku pembelian konsumen di berbagai industri seperti toko roti, kafe, percetakan, dan pakaian, maka penelitian ini menerapkan algoritma yang sama pada konteks makanan ringan dan minuman. Penelitian ini bertujuan untuk meningkatkan strategi penjualan dan mengoptimalkan hasil analisis data penjualan dengan

memanfaatkan algoritma FP Growth. Oleh karena itu, penelitian ini diharapkan dapat memberikan solusi praktis bagi pengelola CV Tiga Putra dalam mengoptimalkan strategi penjualan dan mengurangi risiko kerugian.

2. Metodologi Penelitian

Kerangka penelitian adalah konsep yang mengatur alur, metode, langkah - langkah atau tahapan - tahapan penelitian sehingga sesuai dengan rencana awal dan menemukan solusi yang tepat untuk suatu permasalahan. Kerangka kerja yang jelas diperlukan untuk mendukung terciptanya penelitian ini. Adapun kerangka penelitian yang digunakan dapat dilihat pada Gambar 1.



Gambar 1. Kerangka Penelitian

Kerangka penelitian data mining ini memiliki konsep seperti analisis asosiasi yang berbeda mulai dari identifikasi masalah, analisa data dengan Fp-Growth, asosiasi rule dan implementasinya. Pada analisa data dengan Fp-Growth, terdapat beberapa tata cara yang akan digunakan dalam menganalisa yakni dataset, menentukan nilai support dan confidence, membuat Fp-Tree, pembangkit conditional pattern base, pembangkit conditional Fp-Tree dan menentukan frequent itemset.

2.1 Identifikasi Masalah

Sebelum memulai penelitian, terlebih dahulu mengidentifikasi permasalahan yang ada sehingga dapat dijadikan objek penelitian. Pelajari cara menyelidiki target dan cara menemukan masalah yang terdeteksi serta cara memecahkan masalah. Masalah yang teridentifikasi adalah bagaimana menganalisis data penjualan dengan menggunakan algoritma *Fp-Growth* untuk meningkatkan strategi penjualan. Permasalahannya yakni bagaimana cara agar perusahaan dapat meningkatkan strategi penjualan dan mendapatkan keuntungan serta pola pembelian konsumen terhadap suatu barang.

2.2 Analisa Data dengan *Fp-Growth*

Tahap analisis data dengan algoritma *Fp-Growth* ini, peneliti mengelola data penjualan ke dalam perhitungan algoritma *Fp-Growth* menyiapkan dataset. Setelah itu

tentukan nilai *minimum support*, kemudian buat Fp-Tree. Dari yang sudah dicari, dapat ditentukan *condition pattern base* dan *condition* Fp-Tree. Setelah itu dapat menentukan *frequent itemset*-nya dari aturan asosiasi. Aturan asosiasi didapatkan berdasarkan nilai *minimum support* dan *minimum confidence*.

2.2.1 Dataset

Tahap dataset ini, data transformasi lah yang akan digunakan dalam penelitian ini. Dataset ini berupa data transaksi penjualan selama 2 minggu akan dilakukan seleksi data menjadi 12 transaksi sehingga terbentuk lah data transformasi yang akan bisa dilanjutkan pada tahap selanjutnya.

2.2.2 Menentukan Nilai Minimum Support dan Minimum Confidence

Penelitian ini diperlukan hasil penerapakan dari nilai *support* sehingga dapat melakukan tahap selanjutnya. Pada tahap ini peneliti menentukan nilai minimum *support*nya sebesar 75% dan menentukan nilai minimum *confidence* sebesar 80%. Untuk perhitungan nilai *support* pada setiap item yaitu [15]:

$$Support(A) = \frac{\sum \text{Transaksi yang mengandung } A}{\sum \text{Transaksi}} \quad (1)$$

Dengan menghitung nilai support dapat menentukan seberapa sering kombinasi item tertentu akan tercermin dalam data transaksi penjualan. Analisis data penjualan dapat mengungkap pola dan gabungan yang signifikan. Perhitungan nilai *support* pada kombinasi item yaitu [15] :

$$Support(A, B) = \frac{\sum \text{Transaksi yang mengandung } A, B}{\sum \text{Transaksi}} \times 100\% \quad (2)$$

Selain nilai support, pengukuran lainnya yakni seperti confidence juga berperan penting dalam menganalisis hubungan antar item. Confidence dapat digunakan untuk menentukan seberapa sering suatu aturan asosiasi terbukti benar dalam data transaksi penjualan. Perhitungan nilai *confidence* yaitu [15] :

$$Confidence(A, B) = \frac{\sum \text{Transaksi yang mengandung } A \text{ dan } B}{\sum \text{Transaksi } A} \times 100\% \quad (3)$$

2.2.3 Membuat FP-Tree

Tahap pembuatan FP-tree, berisikan alur transaksi berdasarkan item yang sudah diurutkan sebelumnya. Dalam tahap ini, setiap transaksi dibagi menjadi beberapa item dan dihubungkan sesuai dengan urutan elemen untuk membentuk struktur pohon yang efisien untuk analisis lebih lanjut. Tahap ini akan menghasilkan satu FP-Tree yang terdiri dari 12 transaksi.

2.2.4 Pembangkit Conditional Pattern Base

Tahap pembangkit conditional pattern base ini, berisikan jalur prefix (lintasan prefix) atau pola suffix. Diperoleh dari FP-Tree yang akan membuat pola lintasan berdasarkan itemset sehingga sesuai dengan itemnya. Proses ini melibatkan pemetaan lintasan item dari akar pohon ke node yang terkait, sehingga menciptakan pola lintasan yang mencerminkan itemset yang sering muncul bersama dengan item tersebut.

2.2.5 Pembangkit Conditional FP-Tree

Tahap pembangkit conditional FP-Tree, berisikan pengembangan hasil yang sesuai dengan conditional pattern base. Ini merupakan langkah penting untuk menemukan pola frekuensi elemen yang lebih spesifik. Pada fase ini, setiap elemen yang muncul pada FP-Tree dianalisis secara detail untuk membentuk sub-tree yang mewakili pola terkait dengan elemen tersebut. Hasil dari conditional FP-Tree digunakan untuk membuat aturan asosiasi yang lebih detail dan bermakna.

2.2.6 Menentukan Frequent Itemset

Tahap frequent itemset, menggabungkan item dari setiap hasil conditional fp-tree sehingga menghasilkan pola frekuensi yang dihasilkan. Proses ini menggabungkan item-item yang sering muncul bersamaan dalam data transaksi penjualan untuk mengidentifikasi pola hubungan yang kuat. Dengan menggunakan frequent itemset dapat memungkinkan dalam mengevaluasi hubungan penting antar itemset dan mengembangkan aturan untuk mengatur dalam membuat strategi penjualan atau keputusan bisnis.

2.3 Association Rule

Setelah ditemukan hasil frequent itemsetnya, langkah selanjutnya cari rule asosiasinya. Aturan asosiasi didapatkan berdasarkan nilai *minimum support* dan *minimum confidence*. Dengan menetapkan nilai ambang batas support dan confidence dapat menyaring aturan yang tidak penting dan fokus pada pola yang memberikan wawasan berharga.

2.4 Implementasi

Tahapan ini yaitu melakukan implementasi. Pada tahap ini akan melakukan perhitungan untuk meningkatkan penjualan barang di masa yang akan datang menggunakan *Fp-Growth* secara manual. Implementasi ini melibatkan penerapan aturan asosiasi yang teridentifikasi untuk merancang penerapan strategi pemasaran yang lebih efektif dan mengoptimalkan penawaran barang.

3. Hasil dan Pembahasan

Data yang akan digunakan yakni data penjualan pada bulan Maret 2024 selama 2 minggu. Data yang diperoleh akan digunakan untuk meningkatkan strategi penjualan. Proses pengolahan data menggunakan algoritma *Fp-Growth* yakni dengan Microsoft Excel.

Berikut bagan alur dalam menganalisa data terdapat pada Gambar 2.



Gambar 2. Bagan Alur Analisa Data

Data transaksi penjualan pada CV tiga Putra dari tanggal 4 Maret sampai 16 Maret 2024 yakni selama 2 minggu yang diperoleh langsung dari pimpinan dari CV Tiga Putra. Data ini berjumlah 763 data. Pada tahap alur analisa datanya yakni data transaksi penjualan akan dikumpulkan kemudian dilakukan analisa data dengan menggunakan algoritma *Fp-Growth* sehingga mendapatkan hasil analisa datanya.

3.1 Dataset

Dataset yang digunakan data transformasi yang mempunyai nilai dalam bentuk biner. Data transformasi didapat dari hasil seleksi data penjualan selama 2 minggu yang terdiri dari 12 transaksi. 12 transaksi didapatkan berdasarkan tanggal. Pada 12 transaksi terdapat 30 Itemset yang diberi kode 'K'. Dataset terdapat pada Tabel 1.

Tabel 1. Dataset

Tran saksi	1	2	3	4	5	6	7	8	9	10	11	12
K1	1	1	0	1	1	0	1	0	0	1	0	0
K2	1	0	1	1	1	0	0	1	1	1	1	1
K3	1	1	1	1	1	1	1	1	1	1	1	1
K4	1	0	1	0	1	1	1	0	0	0	0	0
K5	0	0	0	1	0	1	1	0	1	1	1	1
K6	0	1	0	1	0	0	1	1	0	1	1	1
K7	0	1	1	0	1	0	1	1	0	1	1	1
K8	1	1	0	1	1	1	1	1	1	0	1	1
K9	1	1	1	1	1	1	1	1	1	1	0	0
K10	1	1	0	1	1	1	1	1	1	1	0	1
.....
K28	1	1	1	1	1	1	1	1	1	0	1	1
K29	1	1	1	1	0	0	0	0	0	0	1	0
K30	1	1	1	1	1	1	1	1	1	1	1	1

Dataset yang digunakan yakni data transaksi penjualan dengan 30 item yang teridentifikasi K1 hingga K30. Setiap baris mewakili item dan setiap kolom mewakili transaksi penjualan. Nilai 0 dan 1 memiliki arti masing-masing, yakni nilai 1 menunjukkan bahwa barang tersebut dibeli pada suatu transaksi tertentu sedangkan nilai 0 sebaliknya.

3.2 Menentukan Nilai Minimum Support dan Minimum Confidence

Nilai minimum *support* ditentukan sebesar 75% dan confidence sebesar 80% , sehingga mendapatkan hasil asosiasi rule-nya yang diidentifikasi untuk membantu bisnis memahami perilaku pembelian konsumen. Tabel

berikut menunjukkan nilai dukungan untuk satu set item yang ditemukan pada Tabel 2.

Tabel 2. Perhitungan Nilai Support

Item	Frekuensi	Nilai Support	Nilai Support %
K3	12	12/12 = 1,000	100%
K16	12	1,000	100%
K30	12	1,000	100%
K22	11	0,917	92%
K26	11	0,917	92%
K8	10	0,833	83%
K9	10	0,833	83%
K10	10	0,833	83%
K15	10	0,833	83%
K24	10	0,833	83%
K2	9	0,750	75%
K14	9	0,750	75%
K28	9	0,750	75%

Dari hasil perhitungan *support* dapat disimpulkan item yang sering muncul dengan nilai minimum *support* diatas 75% ada 13 item yakni K3, K16, K30, K22, K26, K8, K9, K10, K15, K24, K2, K14 dan K28. Selanjutnya dataset yang diurutkan berdasarkan priority pada Tabel 3.


Tabel 3. Dataset yang diurutkan berdasarkan priority

TID	Itemset
1	K3, K16, K30, K22, K26, K8, K9, K10, K15, K24, K2, K28
2	K3, K16, K30, K22, K26, K8, K9, K10, K15, K24, K28
3	K3, K16, K30, K22, K26, K9, K15, K24, K2, K28
4	K3, K16, K30, K22, K26, K8, K9, K10, K15, K24, K2, K14,
5	K3, K16, K30, K22, K26, K8, K9, K10, K15, K24, K2, K14,
6	K3, K16, K30, K22, K26, K8, K9, K10, K15, K24, K14
7	K3, K16, K30, K26, K8, K9, K10, K15, K14
8	K3, K16, K30, K22, K26, K8, K9, K10, K24, K2, K14, K28
9	K3, K16, K30, K22, K26, K8, K9, K24, K2, K14, K28
10	K3, K16, K30, K22, K26, K9, K10, K15, K2, K14
11	K3, K16, K30, K22, K8, K15, K24, K2, K28
12	K3, K16, K30, K22, K26, K8, K10, K15, K24, K2, K14, K28

Dataset pada Tabel 3 tersebut mencantumkan item berbeda-beda yang terkait dengan transaksi tertentu dan diidentifikasi oleh TID (ID Transaksi). Setiap itemset terdiri dari kombinasi item berbeda-beda. Dataset ini digunakan unyuk mendeteksi pola frekuensi barang dan mengidentifikasi hubungan antar barang dalam transaksi.

3.3 Membuat FP-Tree

Pada tahap ini, langkah yang dilakukan yakni membuat Fp-Tree berdasarkan item yang sudah diurutkan sebelumnya. Tahap ini akan menghasilkan satu Fp-Tree yang terdiri dari 12 transaksi. Pembuatan Fp-tree diawali dari TID 1 atau transaksi 1 sampai dengan TID 12 atau transaksi 12. Berikut hasil FP-Tree setelah melakukan pembacaan 12 transaksi pada Gambar 3.




Gambar 3. FP-Tree

Gambar 2 menyajikan Fp-Tree yang dibuat dari TID1 hingga TID12 menunjukkan struktur pohon yang mencerminkan pola frekuensi item dari data transaksi penjualan. Setiap node pada Fp-Tree mewakili sebuah elemen dan cabang-cabangnya mewakili jalur awalan dari transaksi yang sering terjadi. Visualisasi Fp-Tree ini memudahkan dalam mengidentifikasi kelompok item yang sering muncul bersamaan dan memahami hubungan antar item di seluruh transaksi.

3.4 Pembangkit Conditional Pattern Base

Conditional Pattern Base membuat pola lintasan berdasarkan itemset sehingga sesuai dengan itemnya. Pola lintasan tersebut salah satunya pola lintasan item K24 pada Gambar 4.



Gambar 4. Lintasan yang mengandung akhiran item K24

Gambar 4 tersebut lintasan yang akhirnya mengandaung item K24 yang menunjukkan pola awalan transaksi yang berpuncak pada item K24. Lintasan itu menunjukkan bagaimana item K24 terganggu dengan item lain di Fp-Tree yang mendahuluinya. Analisis historis ini menunjukkan bahwa memungkinkan dalam

mengidentifikasi kelompok item yang penting dan menjadi fokus dalam strategi pemasaran atau rekomendasi barang.

3.5 Pembangkit Conditional FP-Tree

Conditional Pattern Base sudah ditemukan maka langkah selanjutnya yakni menentukkan Conditional Fp-Tree. Dalam menentukan Conditional Fp-Tree dapat dilihat dan disesuaikan dengan Conditional Pattern Base. Conditional Fp-Tree yang dihasilkan dapat dilihat pada Tabel 4.

Tabel 4. Conditional FP-Tree

Item	Conditional FP-Tree
K28	{K3, K16, K30 K22 : 9} {K26, K8, K2 : 8} {K9, K15, K24 : 7} {K10 : 6} {K14 : 5}
K14	{K3, K16, K30, K26 : 8} {K22, K8, K9, K10 : 7} {K15, K24, K2 : 6}
K2	{K3, K16, K30, K22 : 9} {K26, K24 : 8} {K8, K9, K15 : 7} {K10 : 6}
K24	{K3, K16, K30, K22 : 10} {K26, K8 : 9} {K9, K15 : 8} {K10 : 7}
K15	{K3, K16, K30 : 10} {K22, K26 : 9} {K8, K9, K10 : 8}
K10	{K3, K16, K30, K26 : 9} {K22, K9 : 8} {K8 : 7}
K9	{K3, K16, K30, K26 : 10} {K22 : 9} {K8 : 8}
K8	{K3, K16, K30 : 10} {K22, K26 : 9}
K26	{K3, K16, K30 : 11} {K22 : 10}
K22	{K3, K16, K30 : 11}
K30	{K3, K16 : 12}
K16	{K3 : 12}

Tabel 4 berikut menunjukkan Conditional Fp-Tree untuk berbagai item dan memperlihatkan pola penetapan item dalam transaksi tertentu. Setiap baris menunjukkan seberapa sering item muncul bersamaan dengan item lainnya. Contohnya pada K28 sering muncul bersamaan dengan K3, K16, K30, K22, K8 dan K24 dalam 8 transaksi.

3.6 Menentukan Frequent Itemset

Setelah mendapatkan conditional Fp-Tree, langkah selanjutnya yakni melakukan pembangkitan frequent Itemset. Frequent itemset dapat dilihat pada Tabel 5 dan Tabel 6.

Tabel 5. Frequent Itemset

Item	Frequent Itemset
K28	{K3, K16, K30, K22, K28} {K26, K8, K2, K28} {K9, K15, K24, K28} {K10, K28} {K14, K28}
K14	{K3, K16, K30, K26, K14} {K22, K8, K9, K10, K14} {K15, K24, K2, K14}
K2	{K3, K16, K30, K22, K2} {K26, K24, K2} {K8, K9, K15, K2} {K10, K2}
K24	{K3, K16, K30, K22, K24} {K26, K8, K24} {K9, K15, K24} {K10, K24}

Tabel 5. Frequent Itemset Lanjutan

Item	Frequent Itemset
K15	{K3, K16, K30, K15} {K22, K26, K15} {K8, K9, K10, K15}
K10	{K3, K16, K30, K26, K10} {K22, K9, K10} {K8, K10}

K9	{K3, K16, K30, K26, K9} {K22, K9} {K8, K9}
K8	{K3, K16, K30, K8} {K22, K26, K8}
K26	{K3, K16, K30, K26} {K22, K26}
K22	{K3, K16, K30, K22}
K30	{K3, K16, K30}
K16	{K3, K16}
K30	{K3}

Tabel 5 tersebut menunjukkan kumpulan item umum yang dapat dihasilkan dari item berbeda dan menunjukkan kombinasi item yang sering muncul bersamaan dalam transaksi. Setiap baris menunjukkan cara kerja item penting seperti K28 atau K14 sering muncul dengan banyak item lain dalam beberapa transaksi sehingga membentuk kumpulan item frekuensi yang kuat. Abalisis frequent itemset membantu dalam mengidentifikasi pola penting dalam data transaksi penjualan sehingga dapat digunakan dalam mengembangkan aturan korelasi guna membantu strategi bisnis.

3.7 Association Rule

Aturan asosiasi adalah langkah terakhir dalam algoritma Fp-Growth . Setelah menemukan frequent itemset dari Fp-Growth , dapat ditentukan aturan asosiasinya. Aturan asosiasi yang akan kita hitung adalah dengan kombinasi 2 item. Nilai minimum support yakni 75% dan nilai minimum confidence 80%. Hasil rule yang terbentuk yakni dapat dilihat pada tabel 6 berikut ini.

Tabel 6. Association Rule yang terbentuk

Kombinasi 2 Itemset	Frekuensi	Support	Confidence
K16, K30	12	100%	100%
K3, K16	12	100%	100%
K3, K30	12	100%	100%
K16, K22	11	92%	92%
K16, K26	11	92%	92%
K3, K22	11	92%	92%
K3, K26	11	92%	92%
K30, K22	11	92%	92%
K30, K26	11	92%	92%
K22, K24	10	83%	91%
K22, K26	10	83%	91%
K26, K9	10	83%	91%

Tabel 6. Association Rule yang terbentuk Lanjutan

Kombinasi 2 Itemset	Frekuensi	Support	Confidence
K16, K15	10	83%	83%
K16, K24	10	83%	83%
K16, K8	10	83%	83%
K16, K9	10	83%	83%
K3, K15	10	83%	83%
K3, K24	10	83%	83%
K3, K8	10	83%	83%
K3, K9	10	83%	83%
K30, K15	10	83%	83%
K30, K24	10	83%	83%
K30, K8	10	83%	83%

K30, K9	10	83%	83%
K8, K24	9	75%	90%
K22, K15	9	75%	82%
K22, K2	9	75%	82%
K22, K28	9	75%	82%
K22, K8	9	75%	82%
K22, K9	9	75%	82%
K26, K10	9	75%	82%
K26, K15	9	75%	82%
K26, K24	9	75%	82%
K26, K8	9	75%	82%

Hasil pada Tabel 6 tersebut, dapat disimpulkan bahwa ada 34 kombinasi 2 item yang memenuhi nilai minimum *support* dan minimum *confidence*. Berikut ada 10 pengetahuan yang didapatkan dan dicantumkan yakni :

1. K3 => K16 dengan nilai *support* 100% dan nilai *confidence* 100% ialah 'Jika membeli Aqua 600 ML, maka akan membeli Le Mineral'.
2. K3 => K30 dengan nilai *support* 100% dan nilai *confidence* 100% ialah 'Jika membeli Aqua 600 ML, maka akan membeli X Teh Cincau'.
3. K16 => K30 dengan nilai *support* 100% dan nilai *confidence* 100% ialah 'Jika membeli Le Mineral, maka akan membeli X Teh Cincau'.
4. K16 => K26 dengan nilai *support* 92% dan nilai *confidence* 92% ialah 'Jika membeli Le Mineral, maka akan membeli Spix Mie Goreng 500'.
5. K16 => K22 dengan nilai *support* 92% dan nilai *confidence* 92% ialah 'Jika membeli Le Mineral, maka akan membeli Pocari Sweat Botol Kecil'.
6. K3 => K24 dengan nilai *support* 83% dan nilai *confidence* 83% ialah 'Jika membeli Aqua 600 ML, maka akan membeli Soya Master'.
7. K3 => K8 dengan nilai *support* 83% dan nilai *confidence* 83% ialah 'Jika membeli Aqua 600 ML, maka akan membeli Golda'.
8. K26 => K15 dengan nilai *support* 75% dan nilai *confidence* 82% ialah 'Jika membeli Spix Mie Goreng 500, maka akan membeli Lasegar Kaleng'.
9. K26 => K24 dengan nilai *support* 75% dan nilai *confidence* 82% ialah 'Jika membeli Spix Mie Goreng 500, maka akan membeli Soya Master'.
10. K22 => K8 dengan nilai *support* 75% dan nilai *confidence* 82% ialah 'Jika membeli Pocari Sweat Botol Kecil, maka akan membeli Golda'.

4. Kesimpulan

Kesimpulan dari penelitian ini menegaskan pentingnya penerapan algoritma FP Growth ketika menganalisis data penjualan untuk meningkatkan strategi penjualan CV Tiga Putra. Dengan menganalisis 12 transaksi dalam selama dua minggu, penelitian mampu mengidentifikasi 34 kombinasi 2 item dengan nilai *support* minimal 75% dan nilai keyakinan minimal 80%. Pola pembelian yang terungkap seperti item K3, K16 dan K30 yang muncul di setiap transaksi memberikan wawasan berharga bagi perusahaan untuk mengembangkan strategi penjualan.

Penelitian ini juga menunjukkan bahwa algoritma FP Growth membantu perusahaan mengekstrak informasi penting dari data penjualan yang besar dan kompleks. Dengan menggunakan teknologi data mining ini, perusahaan dapat mengoptimalkan manajemen inventaris, mengurangi risiko penumpukan inventaris, dan merespons perubahan tren konsumen dengan lebih cepat. Oleh karena itu, penerapan algoritma FP Growth di CV Tiga Putra dapat menjadi model yang efektif bagi perusahaan lain dalam mengelola data penjualan untuk meningkatkan profitabilitas dan efisiensi operasional.

Daftar Rujukan

- [1] I. Ramdhani, "Perbandingan Metode Data Mining Model Klasifikasi Naive Bayes, Decision Tree Dan K-Nearest Neighbour Dalam Memprediksi Ketepatan Kelulusan Mahasiswa Prodi Teknik Informatika di Universitas Pamulang," *J. Ilmu Komput.*, vol. VI, no. 01, pp. 88–94, 2023, [Online]. Available: <https://jurnal.pranataindonesia.ac.id/index.php/jik/article/view/15670><https://jurnal.pranataindonesia.ac.id/index.php/jik/article/download/156/105>
- [2] A. Srirahayu and L. S. Pribadie, "Review Paper Data Mining Klasifikasi Data Mining," *J. Ilm. Inform. Glob.*, vol. 14, no. 1, 2023, doi: 10.36982/jiig.v14i1.2981.
- [3] M. Rianto, R. Rusdiah, and H. Ichwan, "Penerapan Data Mining Dengan Metode Naïve Bayes Dan Learning Vector Quantization Credit Rating Dalam Memprediksi Kelayakan Pemberian Kredit Oleh PT. BPR Lebak Sejahtera," *Respati*, vol. 17, no. 1, pp. 69–76, 2022, doi: 10.35842/jtir.v17i1.443.
- [4] Salmon, S. Lailiyah, Nursobah, and R. Andrea, "Penerapan Algoritma Hash Based Terhadap Penentuan Rekomendasi Produk Transaksi Penjualan Sparepart Sepeda Motor," vol. 8, no. 2, pp. 866–877, 2024, doi: 10.30865/mib.v8i2.7410.
- [5] D. B. Akbar, P. Palupiningsih, and B. Prayitno, "Implementasi Algoritma Fp-Growth Untuk Penentuan Rekomendasi Produk UMKM Berdasarkan Frekuensi Pembelian," *J. TEKNOINFO*, vol. 17, no. 2, pp. 493–501, 2023, doi: <https://doi.org/10.33365/jti.v17i2.2585>.
- [6] V. K. Rai, S. Chakraborty, and S. Chakraborty, "Association Rule Mining for Prediction of Covid-19," *Decis. Mak. Appl. Manag. Eng.*, vol. 6, no. 1, pp. 365–378, 2023, doi: 10.31181/dmame0317102022r.
- [7] S. Mohammed *et al.*, "A statistical method for predicting quantitative variables in association rule mining," *Inf. Syst.*, vol. 118, p. 102253, 2023, doi: 10.1016/j.is.2023.102253.
- [8] S. R. Wakchaure and R. G. Vishwakarma, "Sequential Pattern Mining Using Apriori and Fp Growth Algorithm," *J. Data Acquis. Process.*, vol. 38, no. 3, pp. 1451–1462, 2023, doi: 10.5281/zenodo.9854883.
- [9] Yulani, R. Kurniawan, and Y. A. Wijaya, "IMPLEMENTASI ALGORITMA FP-GROWTH PADA DATA TRANSAKSI PENJUALAN SEBLAK JONTOR," *JIKA (Jurnal Inform. Univ. Muhammadiyah Tangerang)*, vol. 8, no. 1, pp. 112–122, 2024.
- [10] M. Fathurrahman, A. Rizky Pratama, T. Al-Mudzakir, and U. Buana Perjuangan, "Perbandingan Algoritma Apriori Dan Fp Growth Terhadap Market Basket Analysis Pada Data Penjualan Bakery," *Kesatria J. Penerapan Sist. Inf. (Komputer dan Manajemen)*, vol. 4, no. 2, pp. 266–274, 2023, [Online]. Available: <https://tunasbangsa.ac.id/pkm/index.php/kesatria/article/view/161>
- [11] E. C. Vidiya and G. Testiana, "Analisis Pola Pembelian di Lathansa Cafe & Ramen dengan Menggunakan Algoritma FP-Growth Berbantuan RapidMiner," *G-Tech J. Teknol. Terap.*, vol. 7, no. 3, pp. 1118–1126, 2023, doi: 10.33379/gtech.v7i3.2739.
- [12] C. A. Sugianto and D. Sukmawati, "Penerapan Algoritma FP-Growth Untuk Mengetahui Pola Pada Data Transaksi Percetakan (Studi Kasus Java Printing Batujajar)," vol. 05, no.

- 01, pp. 20–26, 2023.
- [13] R. Fauzi, A. W. Aranski, N. Nopriadi, and E. Hutabri, “Implementasi Data Mining Pada Penjualan Pakaian dengan Algoritma FP-Growth,” *JURIKOM (Jurnal Ris. Komputer)*, vol. 10, no. 2, p. 436, 2023, doi: 10.30865/jurikom.v10i2.5795.
- [14] W. Yao, S. Yan, and Y. Wang, *A Study on Religious Beliefs among College Students Based on FP-Growth Algorithm*, no. Icbdss 2023. Atlantis Press International BV, 2023. doi: 10.2991/978-94-6463-276-7_29.
- [15] Edbert and S. P. Tamba, “Penerapan Data Mining Algoritma Apriori Dalam Menentukan Stok Bahan Baku Pada Restoran Nelayan Menggunakan Metode Association Rule,” *J. Sist. Inf. dan Ilmu Komput. Prima (JUSIKOM PRIMA)*, vol. 5, no. 2, pp. 97–102, 2022, doi: 10.34012/jurnalsisteminformasidanilmukomputer.v5i2.2407.