

# Penerapan *Data Mining* Menggunakan Algoritma *FP-Growth* Pada Data Penjualan PT CML BATAMINDO

## *Implementation Data Mining Using FP-Growth Algorithm on Sales Data PT CML BATAMINDO*

Stanley<sup>1)</sup>, Mariska Putri Pratiwi<sup>2)</sup>

<sup>1)</sup>Teknik Informatika, Teknik dan Komputer, Universitas Putera Batam

Jalan R.Soeprapto, Muka Kuning, Batam, Kepulauan Riau

Telp : (+62) 857-7571-0743

E-mail : pb190210055@upbatam.ac.id<sup>1)</sup>, mariska.pratiwi@puterabatam.ac.id<sup>2)</sup>

### **Abstract**

*Information technology advancements enable companies to do analysis data more in-depth to enhance sales, an useful datamining to use for this is FP-Growth (Frequent Pattern Growth) algorithm. Which will use full for transaction record from January 2024 to December 2024 period are among the data used the analysis process involves data preprocessing, FP-Tree Construction and Frequent Itemsets Generated based on predetermined minimum support and confidence level in the analysis process. The result show that the FP-Growth algorithm effectively identify some association rules when working with big datasets FP-Growth speed and scalability are strongest points. The analysis revealed that 2 itemsets had minimum support 30% and confidence 70% is "BS" and "SO".*

*Keywords: Apriori, Association Rule, Data Mining, FP-Growth, Sales Analys*

### **Abstrak**

Kemajuan teknologi informasi memungkinkan perusahaan melakukan analisis data lebih mendalam untuk meningkatkan penjualan. Salah satu teknik *data mining* yang berguna untuk tujuan ini adalah algoritma *FP-Growth* (*Frequent Pattern Growth*). Algoritma ini akan memanfaatkan catatan transaksi dari periode Januari 2024 hingga Desember 2024 sebagai data yang dianalisis. Proses analisis melibatkan pra-pemrosesan data, konstruksi *FP-Tree*, dan pembangkitan *itemset* frekuensi berdasarkan nilai *minimum support* dan *confidence* yang telah ditentukan. Hasil penelitian menunjukkan bahwa algoritma *FP-Growth* secara efektif mengidentifikasi beberapa aturan asosiasi saat bekerja dengan *dataset* besar, dengan kecepatan dan skalabilitas sebagai keunggulan utamanya. Analisis mengungkapkan bahwa terdapat 2 *itemset* dengan *minimum support* 30% dan *confidence* 70%, yaitu 'BS' dan 'SO'.

*Kata kunci: Apriori, Aturan Asosiasik, Data Mining, FP-Growth, Analisa Penjualan*

### **1. Pendahuluan**

Dalam perkembangan teknologi pengolahan data dalam sektor komersil kebutuhan akan pengolahan data menjadi sangat penting, karena menghasilkan data yang akurat bagi para pemangku kepentingan data sehingga memposisikan pengolahan data yang akurat sebagai komponen yang penting bagi perusahaan yang ingin mengoptimalkan proses kerja.

Dalam objek penelitian yang dilaksanakan banyaknya data yang akan diolah menggunakan *data mining* yang melibatkan penggunaan berbagai teknik dan algoritma komputer untuk menggali, mengelompokkan, dan menganalisis data dengan tujuan mendapatkan pola-pola yang berulang, hingga perusahaan dapat mengenali pola

yang mungkin tersembunyi dan mengidentifikasi hubungan yang bermanfaat[1].

Dalam menjalankan operasional perusahaan menghadapi salah satu tantangan adalah kurangnya mengenai pola penjualan perusahaan, maka dari itu perlu dilakukan untuk analisis *data mining* terhadap data perusahaan sehingga penelitian ini akan bermanfaat untuk menambah pemahaman tentang tren pembelian, produk yang memiliki peminat yang besar juga pola penjualan secara bersamaan. Oleh karena itu, dalam *data mining association rule* selalu menjadi tantangan bahwa frekuensi *itemsets* dan aturan asosiasi yang ada mungkin keliru karena data transaksi data transaksi baru dengan basis data tambahan kedalam basis data asli maka beberapa frekuensi *itemsets* dan aturan baru harus dibuat

dengan begitu sebagai solusi penerapan menggunakan algoritma *fp-growth* dapat memungkinkan perusahaan untuk mengotomisasi analisis data penjualan serta dapat mendeteksi pola-pola yang bernilai dengan cara cepat serta sesuai tanpa melakukan kalkulasi manual yang memerlukan banyak durasi sehingga algoritma *fp-growth* dapat menangani data transaksi yang besar dengan lebih efisien. Menurut [2] masalah utama yang menantang dalam *data mining association rule* bahwa frekuensi *itemsets* dan aturan asosiasi yang ada mungkin terjadi keliru karena data transaksi baru atau basis data tambahan ditambahkan ke basis data asli.

## 2. Tinjauan Pustaka

Faktor-faktor yang mendukung penyelesaian penelitian ini tentang penemuan pengetahuan dalam basis data (*Knowledge Discovery in Database / KDD*) dengan mendapatkan informasi melalui basis data yang telah tersedia[3], *data mining*, algoritma *fp-growth*, penerapan rumus algoritma dan pembahasan mengenai perangkat lunak pendukung.

### 2.1 Knowledge Discovery in Database (KDD)

KDD melibatkan pengumpulan dan pengaplikasian data *historical*, untuk mengidentifikasi kesamaan, pola, atau asosiasi dalam basis data yang luas yang belum ditemukan sebelumnya dan mengandung nilai dengan mengintegrasikan *output* dari proses penggalian data perolehan pengetahuan dan informasi dapat diolah menjadi *output* yang lebih valid dalam pengambilan keputusan[4].

Sebagai peneliti berikut langkah-langkah yang dipertimbangkan dalam penggunaan KDD untuk mendukung penelitian:

1. Seleksi, merujuk pada pemilihan data dari *dataset* operasional sebelum proses ekstraksi KDD dimulai, data yang terpilih untuk digunakan akan disimpan terpisah dari *database* utama seperti penjualan yang diambil dari beberapa barang tertentu pada periode penjualan Januari 2024 – Desember 2024.
2. Tahap pra-pemrosesan langkah awal pada proses *data mining* yang berfokus pada pembersihan data pada tahap ini mencakup berbagai bentuk kegiatan termasuk penghapusan data duplikat, verifikasi konsistensi data, koreksi ketidakakuratan data, dan prosedur pembersihan terkait data lainnya.
3. Transformasi mengacu pada proses modifikasi kumpulan data yang terpilih untuk memenuhi persyaratan khusus dari proses *data mining*.
4. *Data mining* proses sistematis penemuan pola dengan mengekstrak data yang bermakna dari sumber informasi yang telah terpilih.
5. Interpretasi / evaluasi sebagai tahap akhir pada proses KDD yang melibatkan analisis pola informasi yang ditemukan melalui *data mining* hasil interpretasi harus disajikan dalam format

dipahami dengan mudah oleh pembaca dan digunakan untuk memeriksa kesesuaian pola informasi dengan fakta atau hipotesis yang ada.

### 2.2 Data Mining

Sebuah proses iteratif dan interaktif yang bertujuan untuk menemukan pola yang dapat membantu pengambilan keputusan di masa mendatang analisis data yang dihasilkan dihasilkan bisa memberikan pengetahuan yang berguna hingga dapat dipelajari dan dipahami secara mendalam[5].

Menurut [6]terdapat banyak persamaan dari *data mining* seperti *knowledge discovery*, *knowledge extraction*, *data archaeology*, dan analisa data atau analisa pola. Beberapa operasi penambangan data yang paling umum adalah menambang aturan asosiasi, klasifikasi, pengelompokkan, regresi, dan deteksi *outlier*[7]. salah satu algoritma penggunaan *data mining* untuk memproses suatu penelitian diantaranya algoritma *fp-growth*. Menurut [8] penggunaan penambangan data bisa perluas wawasan bisnis dari pola data transaksi pembelian. Ini memungkinkan perusahaan untuk mengidentifikasi preferensi juga tren pembelian sehingga dapat menyesuaikan penawaran produk secara akurat [9].

Untuk melakukan analisa *data mining* perlu dipertimbangkan sebuah proses yang sistematis agar hasil yang diberikan akurat sebagai berikut:

1. Langkah awal sebelum analisis diperlukan pemahaman yang komprehensif pada masalah yang dihadapi untuk dapat mendapatkan solusi yang optimal.
2. Mengidentifikasi dan menghilangkan data yang tidak akurat juga langkah penting dalam fase ini, melakukan transformasi data serta memilih *subset dataset* yang relevan.
3. Pembangunan dan validasi model tahap dimana kinerja prediktif terbaik ditentukan dan jenis pemodelan yang tepat dipilih.
4. Implementasi sebagai tahap terakhir dalam proses *data mining* dimana pencarian pola berurutan (*sequence mining*) dengan mencari sejumlah pola informasi yang terjadi secara bersamaan.

### 2.3 Algoritma FP-Growth

Algoritma *fp-growth* menggunakan struktur data pohon (*fp-tree*) sebagai basis operasinya, dengan adanya *fp-tree* algoritma yang diimplementasikan dalam penelitian ini dapat langsung mengekstrak *frequent itemset*. Menurut [10] dalam penerapan algoritma apriori dan *fp-growth* hasil yang ditunjukkan bahwa algoritma diatas merupakan metode tercepat dalam pengujian. algoritma *fp-growth* akan digunakan untuk mengidentifikasi set item yang sering muncul. Proses ekstraksi melibatkan pembangunan struktur pohon data (*fp-tree*) [11].

Proses ini melibatkan pengolahan data dan perhitungan dalam menentukan aturan asosiasi yang relevan, dua parameter yang penting dalam menentukan aturan adalah *support* dan *confidence*, *support* mengukur probabilitas sejumlah data yang muncul secara bersamaan, sementara *confidence* mengukur seberapa sering pola antara dua data muncul secara bersamaan. Kedua parameter ini digunakan sebagai batas ambang menentukan keberhasilan aturan.

## 2.4 Penerapan Rumus FP-Growth

Pemanfaatan struktur *fp-tree* dapat mengurangi ketergantungan pada total transaksi yang massif hingga mengungkap informasi tentang *itemset* yang sering muncul maka penerapan *fp-growth* dalam *association rule mining* sangatlah efisien. Menurut [12] Fp-Growth mengevaluasi sejauh mana algoritma dapat mengidentifikasi pola dengan efisien.

$$\text{Confident } P(A \cap B) = \frac{\sum(A \cap B)}{\sum A} \times 100\%$$

Rumus *confident* pada transaksi A terhadap B.

$$\text{Support A} = \frac{\text{Jumlah Transaksi Yang Mengandung A}}{\text{Total Transaksi}} \times 100\%$$

Rumus *support* dengan 1 *item*.

$$\frac{\text{Support (A,B)}}{\frac{\text{Jumlah Transaksi Yang Mengandung A dan B}}{\text{Total Transaksi}}} \times 100\%$$

Rumus *support* dengan 2 *item*.

Rumus-rumus diatas akan digunakan untuk penerapan penelitian dengan menggunakan algoritma *fp-growth*.

## 2.5 Software Pendukung

Menurut [13] *software RapidMiner* memudahkan dalam perolehan angka dengan akurasi yang besar bersumber pada algoritma, aplikasi ini juga mampu menyajikan hasil analisis secara intuitif melalui fitur visualisasi data dan pembuatan laporan juga kegunaan *RapidMiner* bisa diterapkan dalam aplikasi bisnis, komersial dan penelitian. Dalam penelitian [8] *RapidMiner* menyediakan modul yang bisa dipergunakan dalam membangun model *FP-Growth* dan analisis pola pembelian.

## 3. Metodologi Penelitian

Meliputi analisis, arsitektur dan metode yang dipakai untuk menyelesaikan permasalahan.

### 3.1 Desain Penelitian

Dalam penelitian yang dilakukan penulis menggunakan desain penelitian sebagai berikut:



Gambar 1 Desain Penelitian

Berdasarkan desain penelitian diatas kerangka kerja yang digunakan oleh peneliti dalam pengumpulan data, analisa data dan mencapai hasil penelitian, berikut penjelasan setiap langkah yang dilalui:


1. Studi literatur, peneliti melakukan tinjauan literatur terhadap perusahaan guna mengenali tantangan yang dihadapi dalam konteks ini, peneliti mengusulkan untuk mengidentifikasi pola penjualan.
2. Pengumpulan data, peneliti mengumpulkan data penjualan dengan mengambil sampel dari periode Januari 2024 hingga Desember 2024.
3. Identifikasi data, melanjutkan tahapan sebelumnya peneliti akan memasuki tahap analisis data dengan menetapkan nilai minimum *support* dan *confidence* untuk masing-masing item yang dihitung.
4. Mengolah data dengan aplikasi *RapidMiner* yang menyediakan fitur komputasi untuk proses analisis data, dimana data penjualan barang yang telah melalui tahap penyaringan dengan menerapkan teknik algoritma *fp-growth*.
5. Proses validasi data, dalam tahap ini melibatkan evaluasi kesesuaian data guna memverifikasi hasil seperti pencarian pola penjualan, data yang diuji dengan menerapkan teknik algoritma *fp-growth* dan bantuan *software RapidMiner* dalam memvalidasi keakuratannya.
6. Temuan (hasil) penelitian, tahap terakhir yang digunakan untuk peneliti mencari hasil yang diharapkan seperti mengidentifikasi produk-produk paling laris.

### 3.2 Algoritma FP-Growth

Penelitian memanfaatkan algoritma *fp-growth* sebagai sarana mengelola data untuk mengidentifikasi pola penjualan melalui aturan asosiasi, Berikut tahapannya:

1. Dengan penggunaan algoritma *fp-growth*, langkah pertama yaitu mencari item dengan tingkat

- penjualan tertinggi kemudian menyusunnya secara berurutan dari paling tinggi hingga paling rendah.
2. Memberikan singkatan atau inisial pada *item* agar mempermudah penulisan *fp-tree*.
3. Memberikan *suffix* dan *prefix* pada alur yang dilalui untuk mencapai tujuan dari *root*.
4. Melakukan perhitungan untuk membuat *conditional pattern base* sehingga hasilnya dapat diimplementasikan kedalam *conditional pattern tree*.
5. Hasil akhir berupa *frequent pattern itemsets generated* untuk mengetahui pola barang yang terjual.



### 3.2.1 Data Transaksi

Jumlah sampel data penjualan yang diambil berupa 10 data transaksi yang memiliki 7 tipe barang yang dijual.

| INV No.       | DESCRIPTION |
|---------------|-------------|
| CML 24/01/052 | BZ          |
| CML 24/01/052 | SO          |
| CML 24/01/052 |             |
| CML 24/03/029 | BISA        |
| CML 24/03/029 | SO          |
| CML 24/03/031 |             |
| CML 24/03/046 | BZ          |
| CML 24/03/046 | BT          |
| CML 24/03/046 | MM          |
| CML 24/05/057 | BZ          |
| CML 24/05/057 | BT          |
| CML 24/05/057 | SO          |
| CML 24/05/057 |             |
| CML 24/05/061 | BZ          |
| CML 24/05/061 | BISA        |
| CML 24/09/064 | BZ          |
| CML 24/09/064 | BT          |
| CML 24/10/064 | BZ          |
| CML 24/10/064 | BT          |
| CML 24/10/064 | BISA        |
| CML 24/11/109 | BT          |
| CML 24/11/109 | BS          |
| CML 24/11/109 | MM          |
| CML 24/12/091 | BZ          |
| CML 24/12/091 | BS          |
| CML 24/12/091 | MM          |

### 3.2.2 Langkah FP-Tree

Ketika data penjualan dilakukan sortir berdasarkan frekuensi dan nilai *support* yang diinginkan maka langkah selanjutnya peletakkan data sesuai dengan data transaksi yang telah diurutkan kedalam *fp-tree*.

*Fp-tree* diatas merupakan hasil akhir dari pembentukan *fp-tree* yang telah ditentukan berdasarkan data penjualan yang telah di sort.

### 3.2.3 Conditional Fp-tree, Conditional Pattern Base, dan Frequent Pattern

Saat pembentukan konstruksi *fp-tree* selesai, kemudian analisis selanjutnya adalah pencarian *frequent pattern bases* guna mendapatkan *Conditional Pattern Base* dan *Conditional FP-Tree*. Maka analisis ini terlibat terhadap urutan dalam *fp-tree* yang sudah ada dengan tujuan mencari seluruh *frequent itemset* maka diperlukan pembentukan cabang pohon yang mencerminkan urutan jalan dengan *support* terendah, yaitu “MM” dan proses ini dilakukan secara berurutan dari yang terkecil hingga yang terbesar.

Pada tahap pembangkitan *Conditional FP-Tree*, setiap *itemset* dalam *Conditional Pattern Base* dihitung total kemunculannya *itemset* yang frekuensi dibawah 30% akan dihapus, sesuai dengan syarat minimum *support* yang telah ditentukan, berikut proses ini tercermin pada tabel dibawah ini:

| Item | Conditional Pattern Base      |
|------|-------------------------------|
| MM   | (BT,BS=1),(BZ,BS=1),(BZ,BT=1) |
| SO   | (BZ=1),(BZ,BT=1),(BS=1)       |
| BS   | (BT=1),(BZ=2),(BZ,BT=1)       |
| BT   | (BZ=4),                       |
| BZ   | Null                          |

Dengan demikian, tahap ini menjamin bahwa hanya *itemset* yang memenuhi nilai *support* yang telah ditentukan akan diproses dalam tahap analisis berikutnya melalui *Conditional FP-Tree* seperti dibawah ini:

Tabel 3 Conditional FP-Tree

| Item | Conditional FP-Tree |
|------|---------------------|
| MM   | BZ=2 BS=2           |
| SO   | BZ=2 BS=1           |
| BS   | BZ=3, BT=2          |
| BT   | (BZ=4)              |
| BZ   | Null                |

Setelah memperoleh Conditional FP-Tree, langkah selanjutnya adalah menghasilkan Frequent Pattern Generated, hanya frequent itemset dengan nilai support diatas 30% yang akan diidentifikasi, pada tahap ini fokus analisis adalah mencari dua frequent itemset.

Tabel 4 Frequent Itemsets Generated

| Item | Frequent Itemsets Generated          |
|------|--------------------------------------|
| MM   | (BZ,MM=2),(BS,MM=2),(BZ,BS,M<br>M=2) |
| SO   | (BZ, SO=2) (BS,SO=1)                 |
| BS   | (BZ,BS=3) (BT,BS=2) (BZ,BT,BS=2)     |
| BT   | (BZ, BT=4),                          |
| BZ   | Null                                 |

### 3.2.4 Association Rule

Frequent Itemsets Generated yang diperoleh akan digunakan untuk jalur tunggal dalam Association Rule, dengan asumsi nilai support 30% dan confidence 70% pola penjualan akan diidentifikasi.

$$Confidence P(A \cap B) = \frac{\sum(A \cap B)}{\sum A} \times 100\%$$

Rumus confidence 2 itemsets.

$$P(BZ \cap BT) = \frac{\sum(5)}{\sum 7} \times 100\% = 71\%$$

$$P(BZ \cap BS) = \frac{\sum(5)}{\sum 7} \times 100\% = 71\%$$

$$P(BS \cap SO) = \frac{\sum(3)}{\sum 4} \times 100\% = 75\%$$

Perhitungan untuk nilai confidence frequent itemsets.

$$\text{Support} = \frac{\text{Frekuensi Nilai Kemunculan A dan B}}{\text{Seluruh Transaksi}} \times 100\%$$

Rumus Support 2 Itemset.

$$P(BS \cap SO) = \frac{\sum(5)}{\sum 10} \times 100\% = 50\%$$

Hasil komputasi diatas, memperoleh aturan asosiasi baru yang memenuhi parameter yang telah ditetapkan (support 30%, confidence 70%), muncul produk dengan nilai confidence mendominasi adalah “BT” yang diikuti

dengan “SO”, dengan nilai confidence mencapai 71% dan nilai support 50%. Hal ini menunjukkan bahwa penjualan antara kedua barang ini memberikan pola yang sesuai dengan nilai yang telah ditentukan.

## 4. Hasil dan Pembahasan


### 4.1 Penggunaan RapidMiner

Dalam penelitian ini, implementasi algoritma fp-growth di RapidMiner untuk data penjualan yang didapatkan dari narasumber diperlukan struktur standar tabulasi yang ditampilkan pada contoh gambar dibawah ini:

| Row No. | BZ | BT | BS | SO | MM | BC | SS |
|---------|----|----|----|----|----|----|----|
| 1       | 1  | 0  | 0  | 1  | 0  | 1  | 0  |
| 2       | 0  | 0  | 1  | 1  | 0  | 0  | 0  |
| 3       | 0  | 0  | 0  | 0  | 0  | 1  | 0  |
| 4       | 1  | 1  | 0  | 0  | 1  | 0  | 0  |
| 5       | 1  | 1  | 0  | 1  | 0  | 0  | 1  |
| 6       | 1  | 0  | 1  | 0  | 0  | 0  | 0  |
| 7       | 1  | 1  | 0  | 0  | 0  | 0  | 0  |
| 8       | 1  | 1  | 1  | 0  | 0  | 0  | 0  |
| 9       | 0  | 1  | 1  | 0  | 1  | 0  | 0  |
| 10      | 1  | 1  | 0  | 0  | 1  | 0  | 0  |

Gambar 2 Tabulasi

Tabel tabulasi dibuat dari setiap transaksi yang terdapat dalam seluruh dataset yang kemudian algoritma fp-growth akan diterapkan.



Gambar 3 FP-Growth

Pada proses fp-growth peneliti akan melakukan penentuan nilai minimal support dan confidence agar data yang dilalui melalui algoritma fp-growth dapat mendapatkan hasil yang sesuai dengan batasan penelitian yakni meneliti kalkulasi 1 itemsets hingga 3 itemsets.




Gambar 4 Proses RapidMiner

Pada bagian proses fp-growth kita akan menarik hasil frequency kedalam aturan asosiasi sehingga hasil dari implementasi aturan asosiasi akan menjadi output pola penjualan antar itemsets.

Setelah menyusun proses yang ditentukan maka peneliti akan mencari hasil akhir dari *association rule* yang akan mengeluarkan 3 tipe *result* yakni sebagai berikut:

| No. | Premises | Conclusion | Support |
|-----|----------|------------|---------|
| 3   | BC       | SO         | 0.600   |
| 4   | BC       | BT         | 0.600   |
| 12  | SO       | BC         | 0.600   |
| 13  | BT       | BC         | 0.600   |
| 8   | BT       | SO         | 0.500   |
| 9   | BC, SO   | BT         | 0.500   |
| 10  | BT       | BC, SO     | 0.500   |
| 11  | BC, BT   | SO         | 0.500   |
| 18  | SO, BT   | BC         | 0.500   |
| 14  | BS       | BC         | 0.400   |
| 5   | BS       | SO         | 0.300   |
| 6   | BS       | BC, SO     | 0.300   |
| 7   | BC, BS   | SO         | 0.300   |
| 15  | MM       | BC         | 0.300   |
| 16  | MM       | SO         | 0.300   |
| 17  | MM       | BT         | 0.300   |
| 19  | SO, BS   | BC         | 0.300   |

Gambar 5 Data Result



Gambar 6 Graph Result

#### Association Rules

Association Rules

```

[SO] --> [BT] (confidence: 0.714)
[SO] --> [BC, BT] (confidence: 0.714)
[BC] --> [SO] (confidence: 0.750)
[BC] --> [BT] (confidence: 0.750)
[BT] --> [SO] (confidence: 0.750)
[BT] --> [BC, SO] (confidence: 0.750)
[BS] --> [BC, SO] (confidence: 0.750)
[BC, BS] --> [SO] (confidence: 0.750)
[BT] --> [SO] (confidence: 0.833)
[BC, SO] --> [BT] (confidence: 0.833)
[BT] --> [BC, SO] (confidence: 0.833)
[BC, BT] --> [SO] (confidence: 0.833)
[SO] --> [BC] (confidence: 0.857)
[BT] --> [BC] (confidence: 1.000)
[BS] --> [BC] (confidence: 1.000)
[MM] --> [BC] (confidence: 1.000)
[MM] --> [SO] (confidence: 1.000)
[MM] --> [BT] (confidence: 1.000)
[SO, BT] --> [BC] (confidence: 1.000)
[SO, BS] --> [BC] (confidence: 1.000)
[MM] --> [BC, SO] (confidence: 1.000)
[BC, MM] --> [SO] (confidence: 1.000)
[SO, MM] --> [BC] (confidence: 1.000)
[MM] --> [BC, BT] (confidence: 1.000)
[BC, MM] --> [BT] (confidence: 1.000)
[BT, MM] --> [BC] (confidence: 1.000)
[MM] --> [SO, BT] (confidence: 1.000)
[SO, MM] --> [BT] (confidence: 1.000)
[BT, MM] --> [SO] (confidence: 1.000)

```

Gambar 7 Result Description

Hasil yang diberikan dari 3 *result* diatas memberikan 28 *rules* yang terdiri dari 1 *itemsets* hingga 3 *itemsets* dengan nilai minimal *support* 30% dan nilai *confidence* 70%.

## 5. Kesimpulan

### 5.1 Simpuln

Dengan melakukan *data analysis* pada data narasumber dari Januari 2024 hingga Desember 2024 dengan total

10 sampel transaksi dan *itemset* berjumlah 1 hingga 3 *set*, dari penelitian ini mendapat berbagai Kesimpulan dengan pola tren dan pola transaksi perusahaan selama periode diatas, sebagai berikut:

1. Dalam perhitungan manual yang diterapkan menghasilkan beberapa aturan *itemset* yang memiliki nilai *support* diatas 30% dan *confidence* 70%, dari hasil penerapan ditemukan bahwa terdapat dua *itemset*, yaitu “BS” dan “SO” yang memenuhi nilai *support* dan *confidence*.
2. Dengan penerapan algoritma yang tersedia dalam *software RapidMiner*, perhitungan bisa dilakukan dengan efisien selama proses analisis juga dapat melakukan perhitungan melibihi tiga *itemset* dan mengevaluasi semua kemungkinan yang memenuhi atau tidak memenuhi nilai persyaratan nilai *support* dan *confidence*.

### 5.2 Saran

Penelitian yang telah dilaksanakan memberikan wawasan mengenai algoritma *fp-growth* dan menyediakan beberapa masukan untuk penelitian di masa depan sebagai berikut:

1. Penggunaan algoritma *FP-Growth* menjadi lebih efisien saat diterapkan pada data berskala besar yang melibatkan banyak variabel, sehingga dapat menghasilkan perhitungan dan hasil yang lebih akurat.
2. Temuan dari penelitian *FP-Growth* diharapkan mampu memberikan kerangka acuan dalam perhitungan komputasi *FP-Tree*, sekaligus menjadi landasan bagi penelitian lanjutan terkait hasil dari pembentukan struktur pohon untuk setiap *item*.

## Daftar Rujukan

- [1] P. Simanjuntak and E. Elisa, “Data Mining Untuk Menentukan Pemilihan Celular Card Di Kota Batam,” *Journal Information System ...*, vol. 4, no. 2, pp. 1–5, 2019, [Online]. Available: <https://ejournal.medan.uph.edu/index.php/isd/article/view/28390Ahttps://ejournal.medan.uph.edu/index.php/isd/article/download/283/143>
- [2] W. Thurachon and W. Kreesuradej, “Incremental Association Rule Mining with a Fast Incremental Updating Frequent Pattern Growth Algorithm,” *IEEE Access*, vol. 9, pp. 55726–55741, 2021, doi: 10.1109/ACCESS.2021.3071777.
- [3] Annisa Farah and Edy Rahman Syahputra, “Analisis Sentimen terhadap Ulasan Cashless Menggunakan Metode Knowledge Discovery Databases Berbasis Web,” *Jurnal ilmiah Sistem Informasi dan Ilmu Komputer*, vol. 5, no. 1, pp.

- 344–360, Mar. 2025, doi: 10.55606/juisik.v5i1.1507.
- [4] K. Sari, M. Khaibar, P. Adithia, and S. Amir, “Menyusun Display Barang dengan Data Mining Assosiation Rule Menggunakan Rapid Miner Algoritma FP-GROWTH Arranging Item Displays Using Data Mining Association Rules Rapid Miner FP-Growth Algorithm,” 2024. [Online]. Available: <https://jurnal.unity-academy.sch.id/index.php/jirsi/index>
- [5] A. Dogan and D. Birant, “Machine learning and data mining in manufacturing,” *Expert Syst Appl*, vol. 166, p. 114060, Mar. 2021, doi: 10.1016/J.ESWA.2020.114060.
- [6] S. Komariyah, Saeful Anwar, and Bani Nurhakim, “Implementasi Data Mining FP-Growth Untuk Analisis Pola Pembelian Pada Transaksi Penjualan,” *Jurnal Manajemen Dan Bisnis Ekonomi*, vol. 1, no. 2, pp. 62–75, 2023, doi: 10.54066/jmbe-itb.v1i2.128.
- [7] R. Khajuria, A. Sharma, S. Sharma, A. Sharma, J. N. Baliya, and P. Singh, “Performance analysis of frequent pattern mining algorithm on different real-life dataset,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 29, no. 3, pp. 1355–1363, 2023, doi: 10.11591/ijeecs.v29.i3.pp1355-1363.
- [8] E. C. Vidiya and G. Testiana, “Analisis Pola Pembelian di Lathansa Cafe & Ramen dengan Menggunakan Algoritma FP-Growth Berbantuan RapidMiner,” *G-Tech: Jurnal Teknologi Terapan*, vol. 7, no. 3, pp. 1118–1126, 2023, doi: 10.33379/gtech.v7i3.2739.
- [9] A. Adri, N. D. Rumlaklak, and D. R. Sina, “Implementasi Algoritma Apriori Untuk Analisa Data Penjualan (Studi Kasus: Toko Ud. Suryani),” *Jurnal Komputer dan Informatika*, vol. 9, no. 2, pp. 182–188, 2021, doi: 10.35508/jicon.v9i2.5132.
- [10] D. Dwiputra, A. Mulyo Widodo, H. Akbar, and G. Firmansyah, “Evaluating the Performance of Association Rules in Apriori and FP-Growth Algorithms: Market Basket Analysis to Discover Rules of Item Combinations,” *Journal of World Science*, vol. 2, no. 8, pp. 1229–1248, 2023, doi: 10.58344/jws.v2i8.403.
- [11] A. H. Nasyuha *et al.*, “Frequent pattern growth algorithm for maximizing display items,” *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 19, no. 2, pp. 390–396, 2021, doi: 10.12928/TELKOMNIKA.v19i2.16192.
- [12] A. Fairuzindah, I. Rabithah, A. Islami, N. Rexa, S. Anggraini, and E. Sunandi, “Implementasi Market Basket Analysis dengan Algoritma Frequent Pattern Growth pada Data Transaksional di Electronic Commerce,” *JDMIS: Journal of Data Mining and Information Systems*, vol. 3, no. 2, pp. 101–107, doi: 10.54259/jdmis.v3i2.4593.
- [13] P. I. Lestari and M. Andriansyah, “Analisis K-Nearest Neighbor Berdasarkan Forward Selection Untuk Prediksi Status Mahasiswa Non Aktif Pada STMIK Bani Saleh,” *Jurnal Informatika: Jurnal Pengembangan IT (JPIT)*, vol. 6, no. 3, pp. 181–186, 2021, [Online]. Available: <http://pddiktiadmin.kemdikbud.go.id/admin/ke-mahasiswaan/d>