



Implementasi Algoritma Fp-Growth Pada Persediaan Barang Elektrikal

Andre Wilson Gultom

Program Studi Teknik Informatika, STMIK Budi Darma, Medan, Indonesia

¹andre.wilson414@gmail.com

Abstrak - PT. Asia Sinar Inti Abadi merupakan suatu perusahaan yang bergerak dalam bidang penjualan komponen elektrikal, berbagai komponen tentang elektrikan yang diperjual belikan seperti didalam perakitan panel. Untuk meningkat penjualan maka pihak manajemen harus menata pola atau tataletak komponen yang sering diminati pembeli sehingga menghasilkan omset besar. Permasalahan yang terjadi selama ini pola peletakan komponen tidak teratur sehingga para pembeli kebingungan dalam memilih komponen elektrikal yang dibutuhkan.

Salah satu solusi yang ditawarkan untuk mengembangkan dan memperbaiki manajemen pengelolaan tata letak barang elektrikal pada PT. Asia Sinar Inti Abadi dengan menggunakan algoritma FP Growt, dimana setiap itemset dapat ketahu sehingga penjualan yang sering dibeli oleh konsumen dapat diletakan pada bagian yang mudah dilihat maupun mudah didapatkan.

Hasil dari Pengimplementasian Algoritma FP Growt dengan menggunakan aplikasi berbasis desktop dapat mempermudah bagian manajemen dalam memutuskan tataletak barang elektrikal yang sering digunakan, dimana komponen yang sering digunakan akan diletakan pada bagian yang mudah dilihat calon pembeli. Dengan menggunakan metode FP Growt dapat mengetahui berapa besar confidence setiap item set beserta nilai support.

Kata Kunci : Komponen Elektrikal, support dan confidence, Algoritma Fp Growt.

Abstract - PT. Asia Sinar Inti Abadi is a company that operates in the field of selling electrical components, various electrical components that are bought and sold, such as in panel assembly. To increase sales, management must organize the pattern or layout of components that are often in demand by buyers, resulting in large turnover. The problem that has occurred so far is that the pattern of component placement is irregular so that buyers are confused in choosing the electrical components needed.

One of the solutions offered is to develop and improve the management of the layout of electrical goods at PT. Asia Sinar Inti Abadi uses the FP Growth algorithm, where each itemset can be identified so that sales that are frequently purchased by consumers can be placed in a section that is easy to see and easy to get.

The results of implementing the FP Growth Algorithm using a desktop-based application can make it easier for management to decide on the layout of frequently used electrical goods, where frequently used components will be placed in parts that are easily seen by potential buyers. By using the FP Growth method, you can find out how much confidence each item set has along with the support value.

Keywords: Electrical components, support and confidence, Fp Growth algorithm.

1. PENDAHULUAN

Pemanfaatan teknologi informasi sekarang telah diterapkan hampir di semua aspek kehidupan, seperti yang terjadi pada PT. Asia Sinar Inti Abadi. Dimana persediaan barang sangat identik dengan penjualan barang sehingga dapat mengolah dan mengumpulkan data stok barang yang ada dan juga transaksi penjualan yang sering terjual kepada konsumen. Namun pemanfaatan data transaksinya belum maksimal, baru sebatas untuk laporan peningkatan dan penurunan penjualan serta persediaan barang, sehingga pertumbuhan yang pesat dari akumulasi data menyebabkan "rich of data but poor of information".[1]

PT. Asia Sinar Inti Abadi merupakan suatu perusahaan yang bergerak dalam bidang penjualan barang elektrikal seperti penjualan bahan-bahan listrik yang dilakukan instalasi baik di perumahan maupun di pabrik, berbagai komponen elektrikal yang dijual dan diperlukan persediaan barang sehingga proses persediaan barang harus diberikan stadrat minimum dan maksimum agar data persediaan barang tetap ada. Pada umumnya perusahaan mengumpulkan informasi melalui sistem database, kemudian nantinya data tersebut diolah sehingga dapat diketahui tingkat dan volume penjualan serta pembelian maupun persediaan barang pada waktu tertentu. Terkadang hasil dari pengolahan data tersebut tidak mendapatkan hasil yang efektif karena besarnya volume data yang diolah dan kesulitan untuk melihat asosiasi antara penjualan barang yang satu dengan yang lain sehingga dapat dilakukan persediaan barang secara maksimal. Dengan demikian perlu adanya suatu sistem yang dapat mendukung perusahaan dalam mengambil keputusan, secara cepat dan juga tepat. maka diperlukan suatu sistem pengolahan database melalui aplikasi data mining dengan metode Frequent Pattern Growth (FP-Growth) [1].

Dalam penelitian ini, algoritma yang dipakai adalah *Frequent Pattern Growth (FP-Growth)*, dimana pencarian *frequent itemset* dilakukan dengan cara membangkitkan struktur data *Tree* atau disebut dengan *Frequent Pattern Tree (FP-Tree)*. *FP-Tree* memerlukan dua kali scanning database untuk menemukan *frequent itemsets* (data yang paling sering muncul) Algoritma ini menggunakan metode *divide and conquer* untuk memecah masalah menjadi sub masalah yang lebih kecil sehingga mempermudah menemukan pola.

Penelitian ini dilakukan mengacu pada penelitian terdahulu dengan judul "Market Basket Analysis dengan algoritma *FP-Growth* pada data transaksi penjualan di swalayan" (Dwi jayanti, 2014). Penelitian ini menjelaskan tentang market basket analysis yang digunakan untuk mengetahui produk – produk yang sering dibeli secara bersamaan oleh konsumen. Algoritma yang digunakan salah satunya yaitu algoritma *FP-Growth* dan menghasilkan informasi berupa



pola-pola pembelian yang dilakukan oleh konsumen. Informasi yang telah ditemukan dapat digunakan untuk keperluan pemasaran salah satunya desain layout barang .

Dari hasil penelitian sebelum nya yang dilakukan oleh Rizky Fitria, Warnia Nengsih, dan Dini Hidayatul Qudsi, yang dipublikasikan pada jurnal penelitian sistem informasi volume 13 nomor 2, tahun 2017 yang berjudul “Implementasi Igoritma FP-GROWTH Dalam Penentuan Pola Hubungan Kecelakaan Lalu Lintas”. Berdasarkan hasil penelitian nilai minimum confidence didapatkan nilai minimum support yang tepat berhubungan dalam asosiasi tersebut.[2]

Dari hasil penelitian sebelum nya yang dilakukan oleh Ali Ikhwan, Dicky Nofriansyah, Sriani, yang dipublikasikan pada jurnal penelitian sistem informasi volume 14 nomor 3, tahun 2015 yang berjudul ” Penerapan Data mining Dengan Algoritma Fp-GROWTH Untuk mendukung Strategi Promosi Pendidikan”. Dari penelitian yang dilakukan ada beberapa atribut yang tidak digunakan dalam rule yang dihasilkan, sehingga pemilihan atribut di dalam data set sangat penting.[3]

Algoritma Apriori merupakan algoritma untuk menemukan *frequent itemset* atau item yang sering muncul di data transaksi (Irliana dan Vydia, 2013). Algoritma lain yang dapat digunakan untuk menemukan frequent itemset yaitu FP-Growth (Triyanto, 2014). Chen dan Lin (2007) pada penelitiannya menggunakan algoritma FP-Growth untuk menentukan kategori, sub kategori dan item produk yang sering dibeli oleh konsumen berdasarkan data penjualan.

2. METODOLOGI PENELITIAN

2.1 Data Mining

Data Mining adalah serangkaian proses untuk menggali nilai tambah dari suatu kumpulan data berupa pengetahuan yang selama ini tidak diketahui secara manual. Patut diingat bahwa kata mining sendiri berarti usaha untuk mendapatkan sedikit barang berharga dari sejumlah besar material dasar. Karena itu Data Mining sebenarnya memiliki akar yang panjang dari bidang ilmu seperti kecerdasan buatan (*artificial intelligent*), machine learning, statistik dan database.

Data mining adalah proses menerapkan metode ini untuk data dengan maksud untuk mengungkap pola-pola tersembunyi. Dengan arti lain Data mining adalah proses untuk penggalian pola-pola dari data. Data mining menjadi alat yang semakin penting untuk mengubah data tersebut menjadi informasi. Hal ini sering digunakan dalam berbagai praktek profil, seperti pemasaran, pengawasan, penipuan deteksi dan penemuan ilmiah. Telah digunakan selama bertahun-tahun oleh bisnis, ilmuwan dan pemerintah untuk menyaring volume data seperti catatan perjalanan penumpang penerbangan, data sensus dan supermarket scanner data untuk menghasilkan laporan riset pasar. Alasan utama untuk menggunakan data mining adalah untuk membantu dalam analisis koleksi pengamatan perilaku.

Data tersebut rentan terhadap *collinearity* karena diketahui keterkaitan.

Fakta yang tak terelakkan data mining adalah bahwa subset/set data yang dianalisis mungkin tidak mewakili seluruh domain, dan karenanya tidak boleh berisi contoh-contoh hubungan kritis tertentu dan perilaku yang ada di bagian lain dari domain . Untuk mengatasi masalah semacam ini, analisis dapat ditambah menggunakan berbasis percobaan dan pendekatan lain, seperti Choice Modelling untuk data yang dihasilkan manusia. Dalam situasi ini, yang melekat dapat berupa korelasi dikontrol untuk, atau dihapus sama sekali, selama konstruksi desain eksperimental.

Beberapa teknik yang sering disebut-sebut dalam literatur Data Mining dalam penerapannya antara lain: clustering, classification, association rule mining, neural network, genetic algorithm dan lain-lain. Yang membedakan persepsi terhadap Data Mining adalah perkembangan teknik-teknik Data Mining untuk aplikasi pada database skala besar. Sebelum populernya Data Mining, teknik-teknik tersebut hanya dapat dipakai untuk data skala kecil saja.

2.2 Posisi Data Mining Dalam Berbagai Disiplin Ilmu

Para ahli berusaha menentukan posisi data *mining* di antara bidang-bidang yang lain. Hal ini dikarenakan ada kesamaan antara sebagian bahasan dalam data *mining* dengan bahasan di bidang lain. Memang tidak seratus persen sama, tetapi ada sejumlah kesamaan karakteristik dalam beberapa hal. Kesamaan bidang data *mining* dengan bidang statistik adalah penyampelan, estimasi, dan pengujian hipotesis. Kesamaan dengan kecerdasan buatan (*artificial intelligence*), pengenalan

Pola (*pattern recognition*), dan pembelajaran mesin (*machine learning*), adalah algoritma pencarian, teknik pemodelan, dan teori pembelajaran, seperti yang ditunjukkan pada bidang lain yang juga memengaruhi data *mining* adalah teknologi basis data, yang mendukung penyediaan penyimpanan yang efisien, pengindeksan, dan pemrosesan *query*. Teknik komputasi paralel sering digunakan untuk memberikan kinerja yang tinggi untuk ukuran set data yang besar, sedangkan komputasi terdistribusi dapat digunakan untuk menangani masalah ketika data tidak dapat disimpan di suatu tempat.

2.3 Pekerjaan Dalam Data Mining

Pekerjaan yang berkaitan dengan data *mining* dapat dibagi menjadi empat kelompok, yaitu model prediksi (*prediction modelling*), analisis kelompok (*cluster analysis*), analisa asosiasi (*association analysis*), dan deteksi anomali (*anomaly detection*).



1. Model Prediksi

Model prediksi berkaitan dengan pembuatan sebuah model yang dapat melakukan pemetaan dari setiap himpunan variabel ke setiap targetnya, kemudian menggunakan model tersebut untuk memberikan nilai target pada himpunan baru yang didapat. Ada dua jenis model prediksi, yaitu klasifikasi dan *regresi*. Klasifikasi digunakan untuk variabel target diskret, sedangkan *regresi* untuk variabel target kontinu. Misalnya, pekerjaan untuk melakukan deteksi jenis penyakit pasien berdasarkan sejumlah nilai parameter penyakit yang diderita masuk dalam jenis klasifikasi di sini target yang diharapkan disebut *diskret*, hanya beberapa jenis kemungkinan nilai target yang didapatkan, tidak ada nilai deret waktu (*time series*) yang harus didapatkan untuk mendapatkan nilai akhir target. Sementara, pekerjaan prediksi jumlah penjualan yang didapatkan pada tiga bulan ke depan termasuk regresi karena mendapatkan nilai penjualan bulan ketiga, nilai penjualan bulan kedua harus didapatkan dan untuk mendapatkan nilai penjualan kedua, nilai penjualan pertama harus didapatkan. Di sini ada nilai deret waktu yang harus dihitung untuk sampai pada target akhir yang diinginkan, ada nilai kontinu yang harus dihitung untuk mendapatkan nilai target akhir yang diinginkan.

2. Analisis Kelompok

Contoh pekerjaan yang berkaitan dengan analisis kelompok (*cluster analysis*) adalah bagaimana caranya mengetahui pola kelompok pembelian barang oleh para konsumen pada waktu tertentu. Dengan mengetahui pola kelompok pembelian tersebut, perusahaan/pengecer dapat menentukan jadwal promosi yang dapat diberikan sehingga omset penjualan bisa ditingkatkan. Analisis kelompok melakukan pengelompokan data-data ke dalam sejumlah kelompok (*cluster*) berdasarkan kesamaan karakteristik masing-masing data pada kelompok-kelompok yang ada. Data-data yang masuk dalam batas kesamaan dengan kelompoknya akan bergabung dalam kelompok tersebut, dan akan terpisah dalam kelompok tersebut, dan akan terpisah dalam kelompok yang berbeda jika keluar dari batas kesamaan dengan kelompok tersebut.

3. Analisis Asosiasi

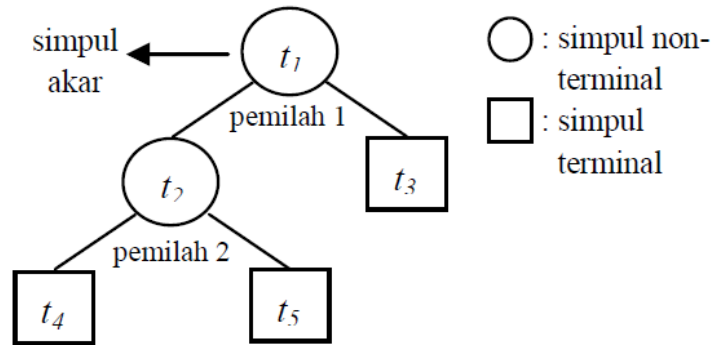
Analisis asosiasi (*association analysis*) digunakan untuk menemukan pola yang menggambarkan kekuatan hubungan fitur dalam data. Pola yang ditemukan biasanya merepresentasikan bentuk aturan implikasi atau subset fitur. Tujuannya adalah untuk menemukan pola yang menarik dengan cara yang efisien. Penerapan yang paling dekat dengan kehidupan sehari-hari adalah analisis data keranjang belanja. Sebagai contoh, pembeli adalah ibu rumah tangga yang akan membeli kebutuhan rumah tangga di sebuah supermarket. Jika ibu tersebut membeli beras, sangat besar kemungkinannya bahwa ibu itu juga akan membeli barang lain, misalnya minyak, telur, dan tidak mungkin atau jarang membeli barang lain seperti topi atau buku. Dengan mengetahui hubungan yang lebih kuat antara beras dengan telur dari pada beras dengan topi, pengecer dapat menentukan barang-barang yang sebaiknya disediakan dalam jumlah yang cukup banyak.

4. Deteksi Anomali

Pekerjaan deteksi anomali (*anomaly detection*) berkaitan dengan pengamatan sebuah data dari jumlah data yang secara signifikan mempunyai karakteristik yang berbeda dari sisa data yang lain. Data-data yang karakteristik menyimpang (berbeda) dari data yang lain disebut *outlier*. Algoritma deteksi anomali yang baik harus mempunyai laju deteksi yang tinggi dan laju yang rendah. Deteksi anomali dapat diterapkan pada sistem jaringan untuk mengetahui pola data yang memasuki jaringan sehingga penyusupan bisa ditemukan, jika pola kerja data yang datang berbeda. Perilaku kondisi cuaca yang mengalami anomali juga dapat dideteksi dengan algoritma ini.

2.3.1 Classification and Regression Tree (CART)

CART merupakan metode eksplorasi data yang didasarkan pada teknik pohon keputusan. Metode ini diperkenalkan oleh Leo Breiman, Jerome H. Friedman, Richard A. Olshen dan Charles J. Stone. CART menghasilkan pohon klasifikasi saat peubah respons berupa data kategorik (nominal), sedangkan pohon regresi dihasilkan saat peubah respons berupa data numerik (interval dan rasio). Peubah penjelas yang dianalisis dapat berupa kategorik, numerik, maupun campuran keduanya (Breiman *et al.* 1984). CART menghasilkan pohon yang tersusun atas banyak simpul (*node*) yang terbentuk dari proses pemilahan *rekursif biner*. Setiap pemilahan memisahkan sebuah gugus data menjadi dua gugus data yang lebih kecil dan saling lepas. Nilai peubah respon pada setiap gugus data hasil pemilahan akan lebih homogen dibandingkan dengan sebelum dilakukan pemilahan (Breiman *et al.* 1984). Pemilahan dilakukan pada simpul non-terminal, yaitu simpul yang memenuhi kriteria pemilahan. Pemilahan dimulai dengan memilah gugus data lengkap atau simpul akar, kemudian dihentikan saat suatu simpul memenuhi kriteria berhenti memilah. Simpul tersebut dinamakan simpul terminal.



Gambar 1. Struktur Pohon pada Metode CART.

Pohon diilustrasikan dalam Gambar 1. Pohon disusun oleh simpul t_1, t_2, \dots, t_5 (Gambar 1). Setiap pemilah (*split*) memilah simpul non-terminal menjadi dua simpul yang saling lepas. Hasil prediksi respons suatu amatan terdapat pada simpul terminal. Pembangunan pohon klasifikasi CART meliputi 3 (tiga) hal, yaitu:

1. Pemilihan pemilah (*split*)
2. Penentuan simpul terminal
3. Penandaan label kelas

3. HASIL DAN PEMBAHASAN

4.1 Analisis Permasalahan

PT. Asia Sinar Inti Abadi merupakan suatu perusahaan yang bergerak dalam bidang penjualan barang elektrikal seperti Kabel, MCB, MCCB, ACB, Kontektor, *smart Relay*, Perakitan *Box Panel* dan lain sebagainya. Pada umumnya perusahaan mengumpulkan informasi melalui sistem database, kemudian nantinya data tersebut diolah sehingga dapat diketahui tingkat dan volume penjualan serta pembelian pada waktu tertentu. Terkadang hasil dari pengolahan data tersebut tidak mendapatkan hasil yang efektif karena besarnya volume data yang diolah dan kesulitan untuk melihat asosiasi antara penjualan barang yang satu dengan yang lain. Dengan demikian perlu adanya suatu sistem yang dapat mendukung perusahaan dalam mengambil suatu keputusan secara cepat dan tepat. Oleh karena itu diperlukan suatu sistem dengan algoritma *FP-Growth*.

Algoritma *FP-Growth* adalah salah satu alternatif algoritma yang dapat digunakan untuk menentukan himpunan data yang paling sering muncul (*frequent itemset*) dalam sekumpulan data. Struktur data yang digunakan untuk mencari *frequent itemset* dengan algoritma *FP-Growth* adalah perluasan dari sebuah pohon *prefix*, yang biasa disebut *FP-Tree*. Dengan menggunakan *FP-Tree*, algoritma *FP-Growth* dapat langsung mengekstrak *frequent itemset* dari *FP-Tree* yang telah dibentuk dengan menggunakan *prinsip divided and conquer*.

Salah satu tahap analisis asosiasi yang menarik perhatian banyak peneliti untuk menghasilkan algoritma yang efisien adalah analisis pola *frekuensi itemset*. renting tidaknya suatu asosiasi dapat diketahui dengan dua tolak ukur, yaitu; *support* dan *confidence*. *Support* (nilai penunjang) adalah persentase kombinasi *item* tersebut dalam database, sedangkan *confidence* (nilai kepastian) adalah kuatnya hubungan *antar-item* dalam aturan asosiasi.

Analisis kebutuhan adalah suatu proses yang sistematis dari pengembangan kebutuhan. Analisis kebutuhan merupakan cara yang efektif untuk mengidentifikasi masalah-masalah yang muncul dalam sebuah penelitian. Dalam analisis kebutuhan perlu dilakukan suatu perencanaan, pengumpulan data dan analisis data dalam menentukan pola persediaan barang elektrikal.

4.2 Algoritma Sistem FP-Growth

Algoritma *FP-Growth* dibagi menjadi tiga langkah utama, namun terlebih dahulu dilakukan pembentukan pohon dengan menggunakan algoritma *FP-Tree*.

Bentuk Algoritma *FP-Growth*

Input : *FP-Tree Tree*

Output : Rt Sekumpulan lengkap pola *frequent*

Proses : *FP-Growth (Tree, α)*

If tree mengandung single path p Then untuk tiap kombinasi (dinotasikan β) dari node-node dalam β

Else untuk tiap al dalam header dari tree Do

{ Bangkitkan pola Bangun $\beta = a1 \ \alpha$ dengan support = a1

support If tree $\beta = \theta$ Then panggil *FP-Growth (Tree, β)* }

Adapun langkah dalam memproses data mining dengan algoritma *FP-Growth* yaitu :

1. *FP-Tree* merupakan struktur penyimpanan data yang dimampatkan. *FP-Tree* dibangun dengan memetakan setiap data transaksi ke dalam setiap lintasan tertentu dalam *FP-Tree*. Karena dalam setiap transaksi yang dipetakan, mungkin ada transaksi yang memiliki item yang sama, maka lintasannya memungkinkan untuk saling menimpa. Semakin banyak data transaksi yang memiliki item yang sama, maka proses pemampatan dengan struktur data *FP-tree* semakin efektif. Kelebihan dari *FP-tree* adalah hanya memerlukan dua kali pemindaian data transaksi yang terbukti sangat efisien.

Tabel 1 Persediaan Barang Elektrikal


TID	Persediaan Barang
1	ACB, 1200A , 3P , Fix, Schineder
2	ACB, 2500A , 3P , Fix, Schineder

Lanjutan Tabel 1 Persediaan Barang Elektrikal

TID	Persediaan Barang
3	ACB, 3200A , 3P , Fix, Schineder
4	ACB, 4000A , 3P , Fix, Schineder
5	ACB, 5000A , 3P , Fix, Schineder
6	MCCB, 100A, 3P, Schineder
7	MCCB, 250A, 3P, Schineder
8	MCCB, 400A, 3P, Schineder
9	MCCB, 630A, 3P, Schineder
10	MCCB, 800A, 3P, Schineder
11	MCCB, 1000A, 3P, Schineder
12	Kontektor, 12A, 3P, Schineder
13	Kontektor, 21A, 3P, Schineder
14	Kontektor, 63A, 3P, Schineder
15	Kontektor, 115A, 3P, Schineder
16	Kontektor, 150A, 3P, Schineder
17	Termal Over Load, 12A, 3P, Schineder
18	Termal Over Load, 21A, 3P, Schineder
19	Termal Over Load, 75A, 3P, Schineder
20	Termal Over Load, 110A, 3P, Schineder
21	MCB, 2A, 3P, Schineder
22	MCB, 6A, 3P, Schineder
23	MCB, 10A, 3P, Schineder
24	MCB, 16A, 3P, Schineder
25	Terminal Diagram, 100A, Wetmuler

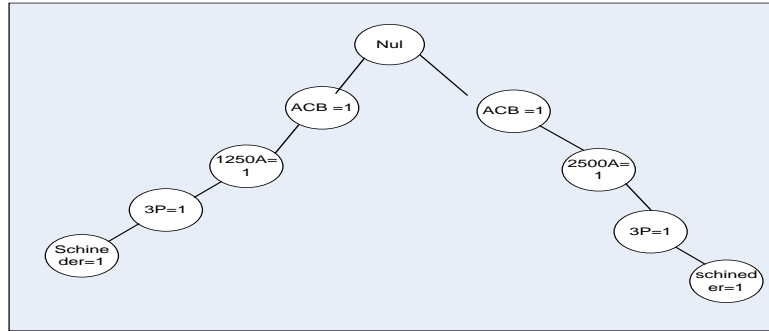
Setelah mengetahui data persediaan barang pada PT. Asia Sinar Inti Abadi, maka langkah selanjutnya adalah membentuk pohon *FP-Tree* untuk mengetahui jenis barang dan juga pola pemakaian komponen yang sering digunakan konsumen pada saat melakukan transaksi.

Gambar di bawah ini memberikan ilustrasi mengenai pembentukan *FP-tree* :

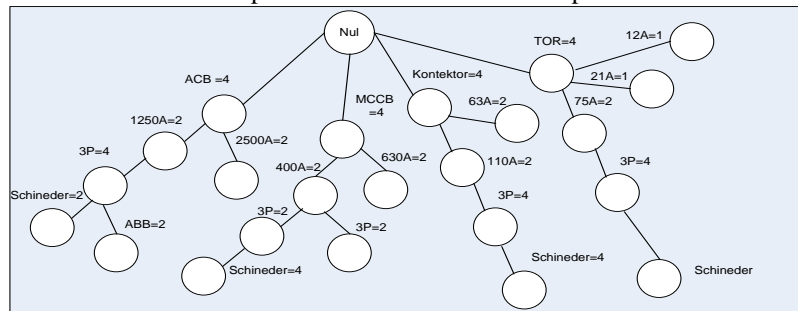


Gambar 1: Hasil pembentukan *FP-tree* setelah pembacaan TID 1

2. Setelah melakukan pembentukan pohon *Fp-Tree* dari pembacaan TID 1 maka langkah selanjutnya dilakukan pembacaan Tid 2 untuk membentuk hasil dari Pola persediaan barang elektronik dengan Algoritma *FP-Growth* seperti pada gambar dibawah ini:



Gambar 2 Hasil pembentukan *FP-tree* setelah pembacaan TID 2



Gambar 3 Hasil pembentukan *FP-tree*

3. Setelah mengetahui pembentukan *FP-Tree* maka langkah selanjutnya melakukan perhitungan Dari *frequent itemset* yang didapat dari pembentukan *Fp-Tree* dan *FP-Growth* maka dapat dihitung nilai *Support* dan *Confidence* setiap item set.

a Pembentukan *Itemset*

Berikut ini adalah penyelesaian dengan kasus berdasarkan data yang sudah disediakan pada tabel 3.1 Proses pembentukan C1 atau disebut dengan 1 itemset dengan jumlah minimum support = 100%, dengan rumus sebagai berikut:

$$\text{Support (A)} = \frac{\text{Jumlah Transaksi Mengandung A}}{\text{Total Transaksi}} * \dots\dots$$

Keterangan :

Support (A) : Hasil Pembagian dari jumlah transaksi / total transaksi

Jumlah transaksi : Banyaknya transaksi A

Total Transaksi : Total keseluruhan transaksi

Maka dari data diatas dapat dihitung untuk nilai suport setiap item seperti dibawah ini :

Tabel 2 Nilai *Support* dari setiap *Item Set*

No	Transaksi	Perhitungan	Support
1	ACB, 1200A , 3P , Fix, Schineder	1/25	0.04
2	ACB, 2500A , 3P , Fix, Schineder	1/25	0.04
3	ACB, 3200A , 3P , Fix, Schineder	1/25	0.04
4	ACB, 4000A , 3P , Fix, Schineder	1/25	0.04
5	ACB, 5000A , 3P , Fix, Schineder	1/25	0.04
6	MCCB, 100A, 3P, Schineder	1/25	0.04
7	MCCB, 250A, 3P, Schineder	1/25	0.04
8	MCCB, 400A, 3P, Schineder	1/25	0.04
9	MCCB, 630A, 3P, Schineder	1/25	0.04
10	MCCB, 800A, 3P, Schineder	1/25	0.04
11	MCCB, 1000A, 3P, Schineder	1/25	0.04
12	Kontektor, 12A, 3P, Schineder	1/25	0.04
13	Kontektor, 21A, 3P, Schineder	1/25	0.04

Lanjutan Tabel 2 Nilai Support dari setiap Item Set

No	Transaksi	Perhitungan	Support
14	Kontektor, 63A, 3P, Schineder	1/25	0.04
15	Kontektor, 115A, 3P, Schineder	1/25	0.04
16	Kontektor, 150A, 3P, Schineder	1/25	0.04
17	Termal Over Load, 12A, 3P, Schineder	1/25	0.04
18	Termal Over Load, 21A, 3P, Schineder	1/25	0.04
19	Termal Over Load, 75A, 3P, Schineder	1/25	0.04
20	Termal Over Load, 110A, 3P, Schineder	1/25	0.04
21	MCB, 2A, 1P, Schineder	1/25	0.04
22	MCB, 6A, 1P, Schineder	1/25	0.04
23	MCB, 10A, 1P, Schineder	1/25	0.04
24	MCB, 16A, 1P, Schineder	1/25	0.04
25	Terminal Diagram, 100A, Wetmuler	1/25	0.04

b Pembentukan Association Rules

Setelah semua pola *frekuensi* tinggi ditemukan, baru dicari *association rules* yang memenuhi syarat minimum *confidence*, dengan menghitung *confidence* aturan asosiasi A ke B. Untuk melihat kuat tidaknya aturan asosiasi adalah membandingkannya dengan nilai *benchmark*, dimana diasumsikan kejadian item dari *consequent* dalam suatu transaksi adalah independent dengan kejadian dari *antecedent* dari suatu aturan asosiasi. Nilai estimasi dari *confidence benchmark* dihitung dari data suatu aturan dengan rumus Minimal *confidence* Nilai *Confidence* dari aturan A ke B diperoleh dengan rumus berikut:

$$Confidence = p(A|B) = \frac{\text{Jumlah Transaksi Mengandung A dan B}}{\text{Total Transaksi Mengandung A}}$$

Keterangan :

Confidence = p(A|B) : Hasil Pembagian dari A,B / Total transaksi A

Jumlah transaksi : Banyaknya transaksi A dan B

Total Transaksi : Total keseluruhan transaksi A

Hasil perhitungan nilai *confidence* dapat dilihat pada tabel dibawah ini:

Tabel 3 Association Rules Confidence

No	Nama Barang	Perhitungan	Cofin- dence %
1	ACB, 1200A , 3P , Fix, Schineder	1/6	0.166
2	ACB, 2500A , 3P , Fix, Schineder	1/6	0.166
3	ACB, 3200A , 3P , Fix, Schineder	1/6	0.166
4	ACB, 4000A , 3P , Fix, Schineder	1/6	0.166
5	ACB, 5000A , 3P , Fix, Schineder	1/6	0.166
6	MCCB, 100A, 3P, Schineder	1/6	0.166
7	MCCB, 250A, 3P, Schineder	1/19	0.052
8	MCCB, 400A, 3P, Schineder	1/19	0.052
9	MCCB, 630A, 3P, Schineder	1/19	0.052
10	MCCB, 800A, 3P, Schineder	1/19	0.052
11	MCCB, 1000A, 3P, Schineder	1/19	0.052
12	Kontektor, 12A, 3P, Schineder	1/19	0.052
13	Kontektor, 21A, 3P, Schineder	1/19	0.052
14	Kontektor, 63A, 3P, Schineder	1/19	0.052
15	Kontektor, 115A, 3P, Schineder	1/19	0.052

16	Kontektor, 150A, 3P, Schineder	1/19	0.052
17	Termal Over Load, 12A, 3P, Schineder	1/19	0.052
18	Termal Over Load, 21A, 3P, Schineder	1/19	0.052
19	Termal Over Load, 75A, 3P, Schineder	1/19	0.052
20	Termal Over Load, 110A, 3P, Schineder	1/19	0.052
21	MCB, 2A, 1P, Schineder	1/19	0.052
22	MCB, 6A, 1P, Schineder	1/19	0.052
23	MCB, 10A, 1P, Schineder	1/19	0.052
24	MCB, 16A, 1P, Schineder	1/19	0.052
25	Terminal Diagram, 100A, Wetmuler	1/19	0.052

Setelah mengetahui nilai setiap itemset dalam perhitungan pola persediaan barang elektrikal pada PT. Asia Sinar Inti Abadi, maka dilakukan pengelompokan nilai support setiap transaksi untuk mengetahui nilai tertinggi dari *confidence* seperti pada tabel dibawah ini:

Tabel 4. Association Rules Support & Confidence

No	Nama Barang	Perhitungan	Nilai Support	Perhitungan	Confidence %
1	ACB, 1200A , 3P , Fix, Schineder	2/25	0.08	2/6	0.333
2	ACB, 2500A , 3P , Fix, Schineder	2/25	0.08	2/6	0.333
3	ACB, 3200A , 3P , Fix, Schineder	1/25	0.04	1/6	0.166
4	MCCB, 100A, 3P, Schineder	1/25	0.04	1/6	0.166
5	MCCB, 250A, 3P, Schineder	2/25	0.08	2/19	0.105
6	MCCB, 400A, 3P, Schineder	1/25	0.04	1/19	0.052
7	Kontektor, 12A, 3P, Schineder	1/25	0.04	1/19	0.052
8	Kontektor, 21A, 3P, Schineder	1/25	0.04	1/19	0.052
9	Termal Over Load, 63A, 3P, Schineder	1/25	0.04	1/19	0.052
10	Kontektor, 110A, 3P, Schineder	2/25	0.08	2/19	0.105
11	Termal Over Load, 12A, 3P, Schineder	2/25	0.08	2/19	0.105
12	Termal Over Load, 21A, 3P, Schineder	1/25	0.04	1/19	0.052
13	Termal Over Load, 75A, 3P, Schineder	1/25	0.04	1/19	0.052
14	MCB, 2A, 1P, Schineder	3/25	0.12	3/19	0.157
15	MCB, 6A, 1P, Schineder	2/25	0.08	2/19	0.105
16	MCB, 10A, 1P, Schineder	1/25	0.04	1/19	0.052
17	Terminal Diagram, 100A, Wetmuler	1/25	0.04	1/19	0.052

Setelah di dapat nilai *support* dan *confidence* dari keseluruhan kombinasi pada data warehouse dengan perhitungan *fp-tree* dan *FP-Growth* maka didapat nilai support dan *confidence* yang paling tinggi dan akurat yaitu kombinasi {MCB, 2A, 1P, Schineder, } , yang mempunyai nilai support : $3/25 = 0,12$ dan nilai confidence : $3/19 = 0,157$

4. KESIMPULAN

Berdasarkan uraian yang telah di buat tentang Implementasi Algoritma FP-GROWTH Pada Persediaan barang Elektrikal (Studi Kasus : PT. Asia Sinar Inti Abadi), maka dapat dibuat beberapa kesimpulan yaitu: Data yang digunakan dalam pengujian sistem pola persediaan barang elektrikal dengan algoritma FP-Growth berdasarkan data transaksi yang ada pada PT. Asia Sinar Inti Abadi, sehingga data tersebut diolah dan menghasilkan sistem yang baru demi meningkatkan data persediaan barang kedepannya. Algoritma FP- Growth sangat baik digunakan untuk menentukan pola tataletak barang untuk meningkatkan persediaan barang, karena dari pola tersebut konsumen yang berbelanja dengan cepat dapat mengetahui dan memilih komponen elektrikal yang mana yang mereka butuhkan tanpa mencari tempat yang lain, sehingga algoritma FP- Growth dapat dimplementasikan dala persediaan barang..



REFERENCES

- [1] N. A. Sari, "Sistem Pakar Mendiagnosa Penyakit Demam Berdarah Menggunakan Metode Certainty Factor," *Pelita Inform. Budi Darma*, vol. IV, no. 3, pp. 100–103, 2013, doi: 10.1016/B0-12-369400-0/00993-5.
- [2] M. Arhami, *Konsep Dasar Sistem Pakar*. Yogyakarta: Andi, 2005.
- [3] B. H. Hayadi, *Sistem Pakar*. Yogyakarta: Deepublish, 2018.
- [4] Abdul Karim, "Implementasi Metode Multi-Objective Optimization On The Basis Of Ratio Analysis dalam Seleksi Mahasiswa Program Indonesia Pintar," *Bull. Comput. Sci. Res.*, vol. 3, no. 5, pp. 351–356, 2023, doi: 10.47065/bulletincsr.v3i5.283.
- [5] A. Karim, S. Esabella, M. A. Hanafiah, and ..., "Sistem Pakar Deteksi Penyakit Otitis dengan Perbandingan Metode Certainty Factor, Teorema Bayes, dan Dempster Shafer," *J. Media ...*, vol. 7, pp. 2003–2013, 2023, doi: 10.30865/mib.v7i4.6595.
- [6] A. Karim, "Implementation of the Multi-Objective Optimization Method on the Basic of Ratio Analysis (MOORA) and Entropy Weighting in New Employee Recruitment," vol. 5, no. 2, pp. 704–712, 2024, doi: 10.47065/josh.v5i2.4859.
- [7] N. Nurliadi and A. Karim, "Sistem Pendukung Keputusan Penerimaan Analis Di Pusat Penelitian Kelapa Sawit Menggunakan Metode Complex Proportional Assessment (Copras)," *Bul. Ilm. Inform. Teknol.*, vol. 2, no. 1, pp. 32–42, 2023.
- [8] Kusri, *Aplikasi Sistem Pakar*. Yogyakarta: Andi, 2008.
- [9] K. Irianto, *Memahami Berbagai macam Penyakit*. Bandung: Alfabeta, 2015.
- [10] Dicky Nofriansyah, M.Kom (2012). Konsep Data Mining Vs Sistem Pendukung Keputusan. Yogyakarta: Cv Budi Utama)
- [11] Fajar Astuti Hermawati, (2009). Konsep dasar Data Mining . Yogyakarta: ANDI.
- [12] Kusrin, Emha Taufiq Luthfi,(2009). Algoritma Data Mining. Yogyakarta: ANDI.
- [13] Eko Prasetyo, (2012). Kosep data mining dan Sistem pendukung keputusan. Jakarta: PT. Elex Media Komputindo.
- [14] Kusumadewi Dkk. (2006) Fuzzy Multiattribute Decision Making. Jogjakarta: Graha Ilmu.
- [15] Fathansyah. (2007) Basis Data. Bandung Informatika.
- [16] Rosa.A.S, (2014)Pemodelan sistem Rekayasa perangkat lunak. Jakarta: PT. Elex Media Komputindo
- [17] http://www.ilmu_komputer.com