

Penentuan Pola Penjualan Sparepart Mesin Fotocopy Pada CV. Andalan Menggunakan Algoritma FP-Growth

Muhamad Reza Vahlefi¹, Yahya Iskandar², Abidin³, Satia Suhada⁴

Sistem Informasi, Teknologi Informasi, Universitas Nusa Mandiri

Jl. Kamal Raya No.18, Ringroad Barat, Cengkareng, Jakarta Barat, (021)8005722

muhamadreza vahlefi@gmail.com, i.am.djotricks@gmail.com, protectiveafina@gmail.com,

satia.shq@nusamandiri.ac.id

Abstrak--CV. ANDALAN yang bergerak dibidang barang dan jasa berpusat di Jakarta, sebuah perusahaan yang menjual sparepart fotocopy. Semakin berkembangnya persaingan dalam dunia bisnis menuntut para pengembang untuk menemukan suatu yang dapat meningkatkan penjualan dan pemasaran produk di perusahaannya, salah satunya adalah dengan memanfaatkan teknologi untuk membantu memprediksi sparepart yang paling sering diminati oleh konsumen. Selama ini pihak CV. ANDALAN kurangnya menganalisa persediaan sparepart di gudang, disamping itu juga pihak perusahaan tidak mengetahui apakah produk penjualan tahun sebelumnya lebih meningkat dibanding tahun berikutnya, dan produk apa saja yang paling laris pada perusahaan sedangkan jumlah data yang begitu besar bisa menjadi masalah dan kewalahan dalam menghitung produk yang ada pada perusahaan tersebut. Oleh karena itu dibutuhkan suatu inovasi baru yang dapat menyediakan suatu informasi yang strategis yaitu data mining. Dengan diadakannya asosiasi pada transaksi sparepart fotocopy menggunakan algoritma FP-Growth diharapkan CV. ANDALAN dapat segera mengetahui produk apa saja yang paling diminati oleh konsumen. Sehingga diharapkan mampu meningkatkan penjualan sparepart fotocopy, agar tidak terjadi kerugian pada CV. ANDALAN.

Kata kunci: Data Mining, Algoritma FP-Growth, Asosiasi, Fotocopy

Abstract – CV. ANDALAN engaged in goods and services based in Jakarta, a company that sells photocopier spare parts. The growing competition in the business world demands developers to find something that can increase sales and marketing of products in their company, one of which is by utilizing technology to help predict the spare parts that are most often in demand by consumers. So far CV. ANDALAN lack of analyzing the inventory of spare parts in the warehouse, besides that the company does not know if the previous year's sales products are more increased than the following year, and what products are the best-selling in the company while the amount of data is so large can be a problem and overwhelmed in calculating the products in the company. Therefore, a new innovation is needed that can provide a strategic information that is data mining. With the holding of associations on photocopier spare parts transactions using FP-Growth algorithm, CV. ANDALAN is expected to immediately know what products are most in demand by consumers. So it is expected to increase the sales of photocopier spare parts, so as not to occur losses on CV. ANDALAN.

Keywords: Data Mining, FP-Growth Algorithm, Asosiation, Photocopier

I. PENDAHULUAN

Persaingan dalam penjualan khususnya dalam penjualan sparepart mesin fotocopy semakin pesat. Agar dapat meningkatkan penjualan produk yang dijual, para penjual harus mempunyai strategi[1]. Banyak cara untuk meningkatkan penjualan, salah satu cara yang bisa dilakukan adalah dengan memanfaatkan data transaksi penjualan. CV. ANDALAN yang bergerak dibidang barang dan jasa berpusat di Jakarta, sebuah perusahaan yang menjual sparepart fotocopy.

Semakin berkembangnya persaingan dalam dunia bisnis menuntut para pengembang untuk menemukan suatu yang dapat meningkatkan penjualan dan pemasaran produk di perusahaannya, salah satunya adalah dengan memanfaatkan teknologi untuk membantu memprediksi sparepart yang paling sering diminati oleh konsumen. Mengingat masalah yang terjadi selama ini pihak CV. ANDALAN kurangnya menganalisa persediaan sparepart di gudang, disamping itu juga pihak perusahaan tidak mengetahui apakah produk

* Korepondensi.

Alamat E-mail : jurnal.larik@bsi.ac.id.

Diterima 30 July 2021; Direvisi 20 January 2021; Diterima 21 January 2021

© 2021 Jurnal Larik.

penjualan tahun sebelumnya lebih meningkat dibanding tahun berikutnya, dan produk apa saja yang paling laris pada perusahaan sedangkan jumlah data yang begitu besar bisa menjadi masalah dan kewalahan dalam menghitung produk yang ada pada perusahaan tersebut. Oleh karena itu dibutuhkan suatu inovasi baru yang dapat menyediakan suatu informasi yang strategis yaitu data mining.

Data mining merupakan penggalian data yang tersembunyi dari database[2]. Dengan data mining, kita dapat melakukan pengklasifikasian, memprediksi, memperkirakan dan mendapatkan informasi lain dari kumpulan data dalam jumlah yang besar[3]. Salah satu metode yang terdapat dalam data mining dan yang digunakan untuk penelitian ini adalah metode Asosiasi (*Association*), analisis asosiasi dikenal juga sebagai salah satu teknik data mining yang menjadi dasar dari berbagai teknik data mining lainnya. Hal terpenting dalam teknik data mining merupakan aturan untuk menemukan pola frekuensi tinggi antara himpunan *itemset* yang disebut dengan *Association Rule* (Aturan Asosiasi)[4]. Salah satu teknik yang digunakan untuk menentukan pola tersebut yaitu dengan menggunakan algoritma *Frequent Pattern Growth (FP-Growth)* yaitu pengembangan dari metode *Apriori* yang merupakan salah satu alternatif untuk menentukan himpunan data yang paling sering muncul (*frequent itemset*) dalam sebuah kumpulan data dengan membangkitkan struktur data Tree atau disebut dengan *Frequent Pattern Tree (FP-Tree)*[5].

Penelitian tentang penerapan aturan asosiasi menggunakan Algoritma FP-Growth telah dilakukan oleh Maulana dan Fajrin (2018) membahas tentang analisis pola pembelian sparepart motor dengan algoritma FP-Growth, Penelitian lain oleh Nastuti (2019) membahas tentang penentuan paket hemat sembako dengan menggunakan algoritma FP-Growth, Rahmawati dan Merlina (2018) metode data mining terhadap data penjualan sparepart fotocopy dengan menggunakan algoritma Apriori. Penelitian kali ini diharapkan memberikan nilai lebih berupa kemudahan bagi pengelola penjualan sparepart dalam menentukan produk yang menjadi peminat konsumen.

II. METODE PENELITIAN

Dalam melakukan penelitian agar hasilnya bisa maksimal, dengan mengikuti kaidah-kaidah (metode) yang telah ditetapkan. Metode yang telah diajarkan di bangku perkuliahan sarjana. Metodologi penelitian ini memuat tentang kerangka

kerja penelitian yang akan dibahas metodologi penelitian, tahapan penelitian, teknik pengumpulan data dan menganalisis data. Pada penelitian ini digunakan juga metode algoritma yaitu algoritma *FP-Growth*.

FP-Growth sendiri merupakan algoritma pencarian *frequent itemsets* yang didapat dari *FP-tree* dengan menjelajahi *tree* dari bawah menuju keatas. Algoritma *FP-Growth* merupakan pengembangan dari algoritma Apriori. Sehingga kekurangan dari algoritma Apriori diperbaiki di algoritma *FP-Growth*. Algoritma inimenefukan *frequent itemset* yang berakhiran *suffix* tertentu dengan menggunakan metode *divide and conquer* untuk memecah *problem* menjadi *subproblem* yang lebih kecil. Adapun pseudocode dari algoritma *FP-Growth* sebagai berikut

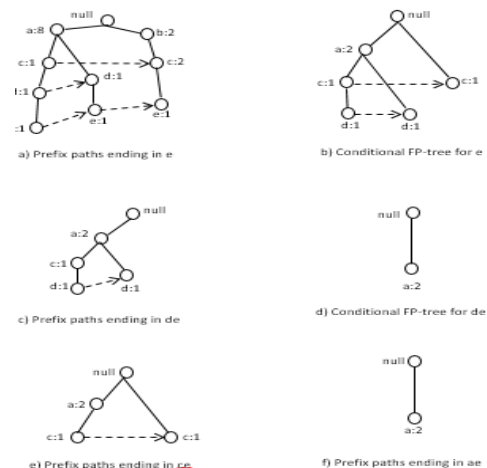
```

procedure FPGrowth(Tree,  $\alpha$ )
if Tree contains a single path P then
  for each  $\beta$  = comb. of nodes in P do
    pattern =  $\beta \cup \alpha$ 
    sup = min(sup of the nodes in  $\beta$ )
  else
    for each  $a_i$  in the header of Tree do
      generatepattern =  $\beta \cup \alpha$ 
      sup =  $a_i$ .support
      construct  $\beta$ 's conditional pattern base
      FPtree = construct  $\beta$ 's conditional FP-tree
      If FPtree != 0 then
        FPGrowth(FPtree,  $\beta$ )
  
```

Gambar 1. Fp-Growth

Untuk menemukan *frequent itemset*, dimana itemsets yang dicari adalah itemsets berakhiran *e*, berdasarkan *Introduction of Data Mining*. Berikut langkah-langkah berdasarkan *Introduction of Data Mining*.

- Langkah pertama adalah mengumpulkan semua lintasan yang mengandung *node e*. *Initial paths* ini disebut *Prefix paths*. Berikut gambar dari lintasan yang mengandung *node e* beserta tahapan-tahapan lainnya



Gambar II. Contoh pengaplikasian Algoritma FP-Growth.


2. Dari *prefix paths* yang ditunjukkan pada Gambar III(a), nilai support count untuk *e* didapat dari menambahkan support count yang berhubungan dengan node *e*. Asumsikan minimum support adalah 2, sehingga $\{e\}$ diklasifikasi sebagai frequent item set dikarenakan memiliki nilai support count sebanyak 3.
3. Dikarenakan $\{e\}$ adalah *frequent*, maka algoritma harus menyelesaikan *subproblems* dari pencarian *frequent itemsets* yang berakhiran *de*, *ce*, *be*, dan *ae*. Sebelum memulai menyelesaikan *subproblems* tersebut, *prefix path* harus diubah terlebih dahulu menjadi *conditional FP-tree*. *Conditional FP-tree* dapat diperoleh dengan langkah berikut:
 - a. *Support count* beserta *prefix path* harus diperbaharui terlebih dahulu karena beberapa transaksi tidak mengandung item *e*.
 - b. *Prefix paths* dipotong, dengan cara melepas node *e*. Node ini dapat di lepas karena *support counts* berhubungan dengan *prefix paths* telah diperbaharui untuk mencerminkan hanya transaksi yang mengandung *e* dan *subproblems* dari pencarian *frequent itemsets* yang berakhiran *de*, *ce*, *be*, dan *ae* tidak lagi membutuhkan informasi node *e*.
 - c. Setelah pembaharuan *support count* bersama dengan *prefix path*, beberapa item tidak lagi *frequent*. Sebagai contoh, node *b* hanya muncul sekali dan memiliki nilai *support count* 1, yang berarti hanya ada 1 transaksi yang mengandung *b* dan *e*. Maka *b* dapat diabaikan dari *subsequent analysis* karena semua *itemset* yang berakhiran *be* pasti tidak *infrequent*. Gambar III(b) menunjukkan *Conditional FP-tree* untuk *e*, dimana nilai *b* dan *e* telah dieliminasi.

FP-Growth menggunakan *conditional FP-tree* dari *e* untuk menyelesaikan *subproblem* dari pencarian *frequent itemset* yang berakhiran *de*, *ce*, dan *ae*. Untuk menentukan $\{d, e\}$ termasuk *frequent itemset* atau tidak, dapat diketahui dengan cara menambahkan jumlah node *d*, dimana nilai *support count* nya sebesar 2. Maka $\{d, e\}$ termasuk *frequent itemset*. Langkah selanjutnya, algoritma akan membangun *conditional FP-tree* untuk *de* menggunakan langkah 3. Setelah memperbarui *support count* dan melepas *infrequent item c*, *conditional FP-tree* untuk *de* dapat dilihat pada Gambar III(d). Karena *conditional FP-tree* berisi

hanya satu item, *a*, yang mana memiliki *support count* yang sama dengan *minimum support*, maka algoritma mengekstrak $\{a, d, e\}$ dan melanjutkan *subproblem* selanjutnya, yaitu *ce*. Setelah dilakukan proses *prefix path* untuk *c* ditemukan hanya $\{c, e\}$ yang *frequent*. Dilanjutkan *subproblem* selanjutnya dimana ditemukan $\{a, e\}$ sebagai sisa *frequent Itemset*.

A. Tahapan Penelitian

Tahapan penelitian yang dipakai pada penelitian ini yaitu *CRISP-DM*, merupakan singkatan dari *Cross-Industry Standard Process for Data Mining*. Adapun tahapan *Cross-Industry Standard Process for Data Mining* dapat dijelaskan sebagai berikut:



Gambar III. Tahapan CRISP-DM

1. Business Understanding

Tahap pertama dalam *CRISP-DM* dan termasuk bagian yang cukup vital yaitu *Business Understanding*. Tahap ini dibutuhkan pengetahuan dari objek bisnis, bagaimana cara membangun atau mendapatkan data, dan bagaimana untuk mencocokkan tujuan pemodelan untuk tujuan bisnis sehingga dapat membangun model terbaik. Kegiatan yang harus dilakukan yaitu: menentukan tujuan dan persyaratan dengan jelas secara keseluruhan, menerjemahkan tujuan tersebut serta menentukan batasan dalam perumusan masalah data mining, dan selanjutnya mempersiapkan strategi awal untuk mencapai tujuan tersebut.

2. Data Understanding

Secara garis besar data understanding untuk memeriksa data, sehingga dapat mengidentifikasi masalah yang terdapat dalam data. Tahap ini memberikan analitik untuk sebuah penelitian dengan membuat ringkasan

(summary) dan mengidentifikasi potensi masalah dalam data.

3. Data Preparation

Data Preparation tentu untuk memperbaiki masalah dalam data, kemudian membuat *variabel derived*. Tahap ini jelas membutuhkan pemikiran yang matang dan usaha yang cukup tinggi untuk memastikan data tersebut tepat untuk algoritma yang digunakan.

4. Modeling

Tahap modeling ini secara garis besar untuk membuat model prediktif atau deskriptif. Tahap ini dilakukan metode statistika dan *Machine Learning* untuk penentuan terhadap teknik *data mining*, alat bantu *data mining*, dan algoritma *data mining* yang akan diterapkan. Lalu selanjutnya melakukan penerapan teknik dan algoritma data mining tersebut kepada data dengan alat bantu.

5. Evaluation

Melakukan interpretasi terhadap hasil dari data mining yang dihasilkan dalam proses pemodelan pada tahap sebelumnya. Evaluasi dilakukan terhadap model yang diterapkan pada tahap sebelumnya dengan tujuan agar model yang ditentukan dapat sesuai dengan tujuan yang ingin dicapai dalam tahap pertama.

6. Deployment

Tahap *deployment* atau rencana penggunaan model merupakan tahap yang paling dihargai dari proses *CRISP-DM*. Perencanaan untuk *Deployment* dimulai selama *Business Understanding* berjalan dan harus menggabungkan tidak hanya bagaimana untuk menghasilkan nilai model, tetapi juga bagaimana mengkonversi skor keputusan.

III. HASIL DAN PEMBAHASAN

Pengolahan data dilakukan ini adalah data yang sudah dilakukan proses pembersihan data menggunakan aplikasi database yaitu Microsoft Excel 2016. Pada tahapan ini, mengimplementasi algoritma *FP-Growth* untuk mengolah data yang telah diproses sesuai dengan masukan data. Proses pada algoritma ini adalah membentuk *FP-Tree*, *conditional pattern base*, *conditional FP-Tree*, dan pencarian *frequent itemset*. Berikut ini adalah penerapan analisis penjualan sparepart fotocopy.

menggunakan metode *FP-Growth*. Berikut 9 transaksi produk sparepart CV. ANDALAN.

ID Transaksi	Item.Set
T1	Cabel Tm, Cru, Way Clut
T2	Cru, Dadf
T3	Cru, Toner
T4	Cabel Tm, Cru, Dadf
T5	Cabel Tm, Toner
T6	Cru, Toner
T7	Cabel Tm, Toner
T8	Cabel Tm, Cru, Toner, Way Clut
T9	Cabel Tm, Cru, Toner

Tabel I. Data Transaksi Sparepart

Tahap selanjutnya adalah tahap dimana *dataset* yang telah dibatasi dengan menggunakan *support count* yang telah ditentukan, sehingga yang tidak memenuhi *support count* akan dihilangkan, kemudian dibangun menjadi sebuah *Tree*. Berikut ini adalah tabel dengan semua barang yang dalam satu transaksi sudah disatukan.

Setelah frekuensi setiap item diperoleh, kemudian dibatasi dengan *support count*. Jika frekuensi item tidak kurang dari *support count*, maka item tersebut akan dihapus dan tidak dipakai dalam proses data mining. Analisis penjualan sparepart fotocopy ini menggunakan *support count* $\xi=2$, dan *minimum confidence* = 60%. Beberapa item yang tidak memenuhi minimum *support count* dihilangkan.


Tabel II. Data Transaksi Sparepart Memenuhi support count

No	Nama Produk	Frekuensi	Inisialisasi
1	Cabel Tm	6	I1
2	Cru	7	I2
3	Toner	6	I3
4	Dadf	2	I4
5	Way Clut	2	I5

TID	Item
1	{I2, I1, I5}
2	{I2, I4}
3	{I2, I3}
4	{I2, I1, I4}
5	{I1, I3}
6	{I2, I3,}
7	{I1, I3}
8	{I2,I1, I3, I5}
9	{I2,I1,I3}

Tabel III. Hasil Pengurutan Berdasarkan Priority

Setelah proses pembacaan Transaksi 9 yaitu I2, I1, I3 maka terbentuklah Tree dari semua transaksi yang akan digunakan seperti pada Gambar Hasil pembentukan FP-Tree transaksi I2, I1, I3:



Gambar IV. Pembentukan FP-Tree 9 Transaksi

Setelah *FP-Tree* terbentuk, maka langkah selanjutnya adalah tahap pembangkitan *conditional pattern base*, tahap pembangkitan *conditional FP-Tree*, dan tahap pencarian *frequent itemset*. Pada tahap ini dapat dilakukan dengan melihat kembali *FP-Tree* yang sudah dibuat pada gambar III sebelumnya.

Suffix	Conditional Pattern Base
I5	{I2, I1:1}, {I2, I1, I3:1}
I4	{I2, I1:1}, {I2:1}
I3	{I2, I1:2},{I2:2}, {I1:2}
I2	-
I1	{I2:4}

Tabel IV. Conditional Pattern Base

Pembentukan conditional FP-Tree dilakukan dengan memperbarui count pada node yang memiliki item I5. Beberapa item mungkin menjadi tidak sering muncul sehingga dapat dihilangkan. Hasilnya I2:2, I1:2, terhadap akhiran I5 yang menjadi conditional FP-Tree. Kemunculan node yang memenuhi minimum support akan dimuat sebagai frequent itemset sesuai akhirnya. Proses ini berlanjut sampai semua jalur yang terkait node I4, I3, I2, dan I1. Maka didapat Conditional FP-Tree pada Tabel V.

Tabel V. Conditional FP-Tree

Suffix	Conditional FP-Tree
I5	{I2:2, I1:2}
I4	{I2:2}
I3	{I2:4, I1:2}, {I1:2}
I2	-
I1	{I2:4}

Setelah Conditionaonal FP-Tree terbentuk, Untuk menemukan *frequent itemset* dari tabel V, maka perlu mesubset node pada I5, yang merupakan frequent item set. Maka didapat *Frequent Item Set*

Suffix	Frequent Item Set
I5	{I2, I5:2}, {I1, I5:2}, {I2, I1, I5:2}
I4	{I2, I4:2}
I3	{I2, I3:4}, {I1, I3:4}
I2	-
I1	{I2, I1:4}

pada Tabel VI.

Tabel VI. Frequent Item Set

Dari hasil *frequent item set* algoritma FP-Growth pada tahapan ini proses yang selanjutnya adalah membentuk aturan asosiasi. Tahap ini digunakan untuk menentukan nilai support dan confidence pada setiap itemset dengan rumus yang sudah dijelaskan sebelumnya pada dasar teori. Pada kasus di atas, pada penelitian ini nilai *minimum support* = 2(0,2) dan *minimum confidence* = 60%, maka aturan asosiasi yang tidak memenuhi ketentuan minimum support count dan minimum confident akan dihilangkan sehingga diperoleh hasil aturan asosiasinya sebagai berikut:

Tabel VII. Nilai Support pada Suffix I5

No	Aturan Asosiasi	Count	Support
1	I5=>I2	2	$\frac{2}{9} \times 100\% \times =0,22(22\%)$
2	I5=>I1	2	$\frac{2}{9} \times 100\% \times =0,22(22\%)$
3	I5=>I2,I1	2	$\frac{2}{9} \times 100\% \times =0,22(22\%)$
4	I2,I5=>I1	2	$\frac{2}{9} \times 100\% \times =0,22(22\%)$
5	I1,I5=>I2	2	$\frac{2}{9} \times 100\% \times =0,22(22\%)$

Keterangan aturan asosiasi yang terbentuk memenuhi minimum support dan minimum confident menjadi sebagai berikut:

1. Jika Way Clut maka Cru dengan support: {0,22}
2. Jika Way Clut maka Cable Tm dengan support: {0,22}
3. Jika Way Clut maka Cru dan Cable Tm dengan support: {0,22}
4. Jika Cru maka Way Clut dan Cable Tm dengan support: {0,22}
5. Jika Cable Tm maka Way Clut dan Cru dengan support: {0,22}

Setelah didapatkan aturan asosiasi yang menentukan support maka selanjutnya adalah perhitungan untuk mencari confident.

Tabel VIII. Nilai Confident pada Suffix I5

No	Aturan Asosiasi	Count	Confident
1	I5=>I2	2	$\frac{2}{2} \times 100\% = 100\%$
2	I5=>I1	2	$\frac{2}{2} \times 100\% = 100\%$
3	I5=>I2,I1	2	$\frac{2}{2} \times 100\% = 100\%$
4	I2,I5=>I1	2	$\frac{2}{2} \times 100\% = 100\%$
5	I1,I5=>I2	2	$\frac{2}{2} \times 100\% = 100\%$

Keterangan aturan asosiasi yang terbentuk memenuhi minimum confident menjadi sebagai berikut:

1. Jika Way Clut maka Cru confident: {100%}.
2. Jika Way Clut maka Cable Tm confident: {100%}.
3. Jika Way Clut maka Cru dan Cable Tm dengan confident: {100%}.
4. Jika Cru maka Way Clut dan Cable TM confident: {100%}.
5. Jika Cable Tm maka Way Clut dan Cru confident: {100%}.
6. Jika Dadf maka Cru dengan confident: {100%}.
7. Jika Toner maka Cru dengan confident: {66%}.
8. Jika Cable Tm maka Toner dengan confident: {66%}.
9. Jika Toner maka Cable Tm dengan confident: {66%}.
10. Jika Cable Tm maka Cru dengan confident: {66%}.

Setelah didapatkan aturan asosiasi yang dapat, tahapan berikutnya adalah melakukan perhitungan lift ratio yang telah didapat sebagai berikut berikut:

Tabel IX. Nilai Lift Ratio pada Suffix I5

No	Aturan Asosiasi	Lift Ratio
1	I5=>I2	$\frac{100\%}{(\frac{7}{9} \times 100)}$ =1,286
2	I5=>I1	$\frac{100\%}{(\frac{6}{9} \times 100)}$ =1,500
3	I5=>I2,I1	$\frac{100\%}{(\frac{4}{9} \times 100)}$ =2,250
4	I2,I5=>I1	$\frac{100\%}{(\frac{6}{9} \times 100)}$ =1,286
5	I1,I5=>I2	$\frac{100\%}{(\frac{7}{9} \times 100)}$ =1,286

Keterangan aturan asosiasi yang terbentuk setelah menghitung nilai Lift Ratio sebagai berikut:

1. Jika Way Clut maka Cru dengan Lift: 1.286.
2. Jika Way Clut maka Cable Tm dengan Lift: 1.500.
3. Jika Way Clut maka Cru dan Cable Tm Lift: 2.250.
4. Jika Cru maka Way Clut dan Cable Tm dengan Lift: 1.286.
5. Jika Cable Tm maka Way Clut dan Cru dengan Lift: 1.286.
6. Jika Dadf maka Cru dengan Lift: 1.286.
7. Jika Toner maka Cru dengan Lift: 0.857.
8. Jika Cable Tm maka Toner dengan Lift: 1.
9. Jika Toner maka Cable Tm dengan Lift: 1.
10. Jika Cable Tm maka Cru dengan Lift: 0.857.

Nilai Lift ratio yang lebih besar dari 1 memiliki aturan yang kuat untuk item tersebut. Maka didapat strong rules terpadat pada Way Clut maka

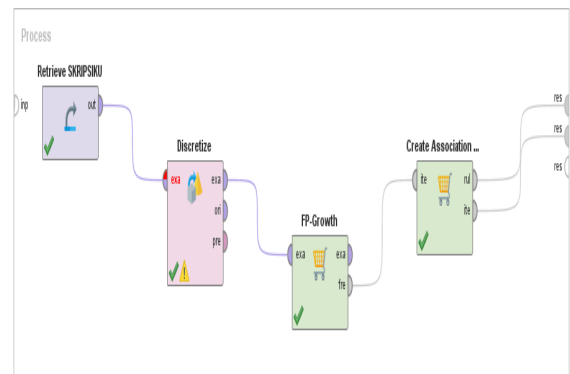
Cru dan Cable Tm dengan Lift ratio terbesar yaitu 2.250.

Tahap Selanjutnya, Dengan menggunakan *software RapidMiner* tahapan proses untuk algoritma *FP-Growth*

Id transaksi	Cabel Tm	Cru	Toner	dadf	Way Clut
T1	1	1	0	0	1
T2	0	1	0	1	0
T3	0	1	1	0	0
T4	1	1	0	1	0
T5	1	0	1	0	0
T6	0	1	1	0	0
T7	1	0	1	0	0
T8	1	1	1	0	1
T9	1	1	1	0	0
Jumlah	6	7	6	2	2

Tabel X. Perubahan Numeric menjadi Binominal

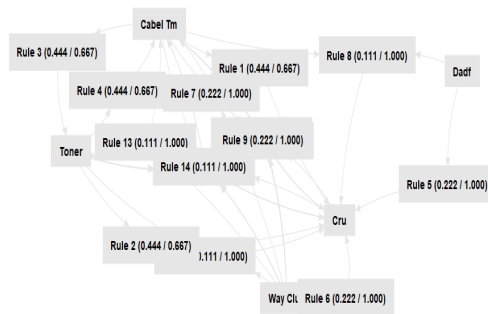
Tahap Selanjutnya, Dengan menggunakan *software RapidMiner* tahapan proses untuk algoritma *FP-Growth*.



Gambar IV. FP-Growth pada RapidMiner

No.	Premises	Conclusion	Support ↓	Confidence	Lift
1	Cabel Tm	Cru	0.444	0.957	0.957
2	Toner	Cru	0.444	0.957	0.857
3	Cabel Tm	Toner	0.444	0.957	1
4	Toner	Cabel Tm	0.444	0.957	1
5	Dadf	Cru	0.222	1	1.286
6	Way Clut	Cru	0.222	1	1.286
7	Way Clut	Cabel Tm	0.222	1	1.500
9	Way Clut	Cru, Cabel Tm	0.222	1	2.250
10	Cru, Way Clut	Cabel Tm	0.222	1	1.500
11	Cabel Tm, Way Clut	Cru	0.222	1	1.286
8	Cabel Tm, Dadf	Cru	0.111	1	1.286
12	Toner, Way Clut	Cru	0.111	1	1.286
13	Toner, Way Clut	Cabel Tm	0.111	1	1.500
14	Toner, Way Clut	Cru, Cabel Tm	0.111	1	2.250
15	Cru, Toner, Way Clut	Cabel Tm	0.111	1	1.500
16	Cabel Tm, Toner, Way Clut	Cru	0.111	1	1.286

Gambar V. Support, Confident dan Lift pada RapidMiner



Gambar VI. Graph Rule menggunakan Rapid Miner

AssociationRules

```

Association Rules
[Cabel Tm] --> [Cru] (confidence: 0.667)
[Toner] --> [Cru] (confidence: 0.667)
[Cabel Tm] --> [Toner] (confidence: 0.667)
[Toner] --> [Cabel Tm] (confidence: 0.667)
[Dadf] --> [Cru] (confidence: 1.000)
[Way Clut] --> [Cru] (confidence: 1.000)
[Way Clut] --> [Cabel Tm] (confidence: 1.000)
[Cabel Tm, Dadf] --> [Cru] (confidence: 1.000)
[Way Clut] --> [Cru, Cabel Tm] (confidence: 1.000)
[Cru, Way Clut] --> [Cabel Tm] (confidence: 1.000)
[Cabel Tm, Way Clut] --> [Cru] (confidence: 1.000)
[Toner, Way Clut] --> [Cru] (confidence: 1.000)
[Toner, Way Clut] --> [Cabel Tm] (confidence: 1.000)
[Toner, Way Clut] --> [Cru, Cabel Tm] (confidence: 1.000)
[Cru, Toner, Way Clut] --> [Cabel Tm] (confidence: 1.000)
[Cabel Tm, Toner, Way Clut] --> [Cru] (confidence: 1.000)

```

Gambar VII. Association Rules pada RapidMiner

Dari pengolahan data penjualan yang dilakukan proses perhitungan menggunakan *RapidMiner* didapatkan jumlah aturan asosiasi sebanyak 16 rule dengan support terendah adalah 10% dan tertinggi 100%, sedangkan confidence terendah adalah 66% dan tertinggi adalah 100%. Dapat diperoleh hasil aturan asosiasi dan frequent itemset. Pada gambar IX bisa dilihat, bahwa yang menjadi frequent itemset adalah kombinasi item Way clut, Cru-CabelTm. Dengan menghasilkan nilai support 0.22 atau 22%, sedangkan nilai confidence sebesar 1 atau 100%. Kekuatan kolerasi yang di dapat oleh kombinasi Way clut Cru dan CabelTm adalah sebesar 2.250. Karena hasil yang didapat lebih dari 1, maka menunjukkan adanya manfaat dari aturan asosiasi tersebut.

Penelitian ini dilakukan untuk mengetahui hasil produk spare part fotocopy mana yang laris dibeli dan tidak laris pada CV. ANDALAN dan

didapat sudah dari hasil penelitian ini bahwa produk sparepart fotocopy yang paling laris adalah Way Clut, Cru dan CabelTm, dengan nilai support 20%, confident 100% dan nilai lift lebih besar dari 1. Melalui hasil penelitian diharapkan penelitian ini dapat dipublikasikan dalam jurnal ilmiah. Dengan demikian para mahasiswa atau pelajar dapat mendapatkan informasi dan referensi dalam pelaksanaan pembelajaran. Siapapun dapat mengetahui langkah-langkah penerapan algoritma FP-Growth dengan metode association dalam data transaksi penjualan.

Selain itu, penelitian ini juga mengimplementasi data transaksi CV. ANDALAN dengan aplikasi RapidMiner untuk mencari item yang paling laris, diharapkan penelitian ini dapat menjadi bahan pembelajaran juga untuk pengimplementasian data transaksi dengan aplikasi rapidminer pada CV. ANDALAN agar data transaksi yang dihasilkan dapat manfaat untuk kedepannya.

IV. KESIMPULAN DAN SARAN

Dari hasil penelitian yang dilakukan, maka ada beberapa kesimpulan yang dapat diambil berdasarkan pembahasan implementasi Data Mining dalam penjualan sparepart fotocopy dengan menggunakan algoritma FP-Growth sebagai berikut:

1. Dari pengolahan data penjualan yang dilakukan proses perhitungan menggunakan *RapidMiner* didapatkan jumlah aturan asosiasi sebanyak 16 rule dengan support terendah adalah 10% dan tertinggi 100%, sedangkan confidence terendah adalah 66% dan tertinggi adalah 100%. Dapat diperoleh hasil aturan asosiasi dan frequent itemset. Bahwa yang menjadi frequent itemset adalah kombinasi item Way clut, Cru-CabelTm.
2. Dengan menghasilkan nilai support 0.22 atau 22%, sedangkan nilai confidence sebesar 1 atau 100%. Kekuatan kolerasi yang di dapat oleh kombinasi Way clut Cru dan CabelTm adalah sebesar 2.250. Karena hasil yang didapat lebih dari 1 (*strong rule*), maka menunjukkan adanya manfaat dari aturan asosiasi tersebut.

Dari hasil penelitian ini juga, didapatkan beberapa saran yang dapat diperhatikan untuk pengembangan selanjutnya, sebagai berikut:

1. Dalam pengimplementasian data pada CV. ANDALAN, jika semakin besar data yang di dapat atau diambil maka semakin akurat juga untuk hasil yang dicapai, jika melakukan pengembangan dari penelitian ini, sebaiknya

dilakukan penambahan data sampe yang lebih banyak lagi.

2. Selain dapat dilakukan dengan aplikasi RapidMiner, penelitian semacam ini dapat juga menggunakan aplikasi DataMining lainnya seperti WEKA DAN Tanagra.

REFERENSI

- [1] F. Rahmawati and N. Merlina, "Metode Data Mining Terhadap Data Penjualan Sparepart Mesin Fotocopy Menggunakan Algoritma Apriori," *PIKSEL Penelit. Ilmu Komput. Sist. Embed. Log.*, vol. 6, no. 1, pp. 9–20, 2018, doi: 10.33558/piksel.v6i1.1390.
- [2] F. Indriyani and E. Irfiani, "Clustering Data Penjualan pada Toko Perlengkapan Outdoor Menggunakan Metode K-Means," *JUITA J. Inform.*, vol. 7, no. 2, p. 109, 2019, doi: 10.30595/juita.v7i2.5529.
- [3] Y. Irawan, "Penerapan data mining untuk evaluasi data penjualan menggunakan metode clustering dan algoritma hirarki divisive," *Jtiulm*, vol. 3, no. 1, pp. 13–20, 2019.
- [4] Muhammad Rizal, "Analisa Prediksi Penjualan Produk Dengan Menggunakan Metode C4.5 (Studi Kasus : PT. Kawan Lama Ace Hardware)," *J. Ris. Komput.*, vol. 6, no. 5, pp. 545–549, 2019, [Online]. Available: <https://ejournal.stmik-budidarma.ac.id/index.php/jurikom/article/view/1656/1253>.
- [5] A. Maulana and A. A. Fajrin, "Penerapan Data Mining Untuk Analisis Pola Pembelian Konsumen Dengan Algoritma Fp-Growth Pada Data Transaksi Penjualan Spare Part Motor," *Klik - Kumpul. J. Ilmu Komput.*, vol. 5, no. 1, p. 27, 2018, doi: 10.20527/klik.v5i1.100.