

Penerapan Metode Association Rule Dalam Menganalisa Data Penjualan Obat Menggunakan Algoritma FP-GROWTH (Studi Kasus Rumah Sakit Haji Medan)

Ibnu Rusydi

Universitas Dharmawangsa, Medan, Indonesia
Email: ibnurusydi@dharmawangsa.ac.id

Abstrak

Data transaksi penjualan merupakan harta yang sangat berharga dalam proses bisnis. Tidak hanya digunakan untuk menghitung laba dan rugi, namun data transaksi dalam jumlah yang besar juga dapat digunakan untuk berbagai kepentingan untuk menghasilkan pengetahuan baru (knowledge) di dalam database transaksi. Cara yang dapat dilakukan untuk pengolahan data dan menghasilkan pengetahuan baru dari data tersebut adalah dengan menggunakan teknik data mining. Adapun teknik yang digunakan dalam hal ini adalah Algoritma FP-Growth. Struktur data yang digunakan adalah tree yang disebut dengan FP-Tree. Dengan menggunakan FP-Tree, Algoritma FP-growth dapat langsung mengekstrak frequent Itemset dari FP-Tree. Penelitian dilakukan dengan mengumpulkan data terkait dimana pada penelitian ini studi kasus di Apotek Rumah Sakit Haji Medan yang mana variable-variable yang diambil adalah data transaksi obat perhari. Hasil penelitian ini adalah berupa suatu pengetahuan baru dari data penjualan tersebut dengan mengimplementasikan Algoritma FP-Growth yang menggunakan konsep pembangunan FP-Tree dalam mencari Frequent Itemset yang berguna untuk kepentingan kemajuan pengelolaan di tempat studi kasus diambil.

Kata Kunci : Data Mining, Association Rules, Frequent Itemset, FP-Growth.

Abstract

Sales transaction data is a very valuable asset in business processes. Not only is it used to calculate profits and money, but large amounts of transaction data can also be used for various purposes to generate new knowledge (knowledge) in the transaction database. Ways that can be done for data processing and generate new knowledge from the data is to use data mining techniques. The technique used in this case is the FP-Growth Algorithm. The data structure used is a tree called FP-Tree. By using FP-Tree, FP-growth Algorithm can directly extract Itemset from FP-Tree. Research conducted by collecting data related to research in the case studio at Medan Haji Hospital Pharmacy where the variables taken are daily drug transaction data. The results of this study are part of the new knowledge of this sales data by applying the FP-Growth Algorithm that uses the concept of FP-Tree development in finding Frequent Itemset that is useful for the development of investment plans in the study areas taken.

Keywords: Data Mining, Association Rules, Frequent Itemset, FP-Growth.

1. Pendahuluan

1.1 Latar Belakang Masalah

Data transaksi penjualan merupakan harta yang sangat berharga dalam proses bisnis. Tidak hanya digunakan untuk menghitung laba dan rugi, namun data transaksi dalam jumlah yang besar juga dapat digunakan untuk berbagai kepentingan untuk menghasilkan pengetahuan baru (*knowledge*) di dalam database transaksi.

Apotik Rumah Sakit Haji Medan salah satu Apotik yang melayani pendistribusian obat yang akan ditebus atau dibeli oleh pasien yang sedang berobat di Rumah Sakit tersebut. Apotik tersebut juga melayani pembelian konsumen yang tidak khusus berobat di Rumah Sakit. Rumah Sakit Haji Medan memiliki transaksi yang sangat banyak setiap harinya. Data transaksi di Apotik ini sebagaimana sama seperti di Apotik-apotik pada umumnya hanya dipergunakan untuk mengetahui laba, rugi dan stok persediaan barang saja.

Berdasarkan Hal diatas maka penulis akan meneliti data-data transaksi penjualan yang ada dirumah sakit tersebut untuk menghasilkan pengetahuan baru yaitu berupa pola-pola transaksi yang saling berkaitan. Melalui data-data transaksi tersebut akan dicari berbagai informasi tentang kebiasaan para pasien/konsumen dalam bertransaksi, misalnya dapat diketahui produk-produk apa saja yang sering ditebus/dibeli secara bersamaan dalam tiap transaksi. Dengan adanya pengetahuan tersebut maka Apotik Rumah Sakit Haji Medan akan lebih optimal dalam meningkatkan transaksi penjualan, memaksimalkan pelayanan kepada konsumen, tetap tersedianya berbagai jenis obat dan manajemen penyimpanan di gudang yang efektif. Sebagai contoh menemukan bahwa produk A biasanya dibeli secara bersamaan dengan produk B, maka pengetahuan ini akan memberikan input atau masukan ketika Apotik akan menambah persediaan kembali. Dan juga bermanfaat ketika menyusun barang di Gudang penyimpanan, maka Produk A dapat disusun berdekatan dengan Produk B untuk memudahkan ketika pencarian.

Permasalahan yang akan dibahas dalam hal ini yaitu penerapan metode *Association Rule* dengan Algoritma *FP-Growth* dapat diterapkan dalam pengelolaan data transaksi penjualan obat dan bagaimana pola hubungan aturan assosiatif antara suatu kombinasi item dan membentuk pola kombinasi *itemsets* dengan menggunakan Algoritma *FP-Growth*.

2. Kajian Literatur Dan Pengembangan Hipotesis

2.1 Knowledge Discovery in Databases (KDD)

Knowledge Discovery in Database (KDD) adalah keseluruhan proses non-trivial untuk mencari dan mengidentifikasi pola (*pattern*) dalam data, dimana pola yang ditemukan bersifat sah, baru, dapat bermanfaat dan dapat dimengerti. *Data Mining* sering dianggap sebagai bagian dari *knowledge discovery in database* (KDD) yaitu sebuah proses mencari pengetahuan yang bermanfaat dari data (Ali, *et al* 2015).

2.2 Data Mining

Kennedi, *et al* (2013) *Data Mining* disebut juga *Knowledge Discovery in Database* (KDD) didefinisikan sebagai ekstraksi informasi potensial, implisit dan tidak dikenal dari sekumpulan data. Proses *Knowlegde Discovery in Database* melibatkan hasil proses *Data Mining* (proses pengekstrak kecenderungan suatu pola data), kemudian mengubah hasilnya secara akurat menjadi informasi yang mudah dipahami.

2.3 Association Rule

Association Rule adalah teknik *Data Mining* untuk menemukan aturan assosiatif antara suatu kombinasi item. Algoritma aturan asosiasi akan menggunakan data latihan, sesuai dengan pengertian data mining, untuk menghasilkan pengetahuan. Pengetahuan apakah yang hendak dihasilkan dalam aturan asosiasi. Pengetahuan untuk mengetahui item-item belanja yang sering dibeli secara bersamaan dalam suatu waktu. Aturan asosiasi yang berbentuk “if...then...” atau “jika...maka...” merupakan pengetahuan yang dihasilkan dari fungsi aturan asosiasi Fadlina (2014).

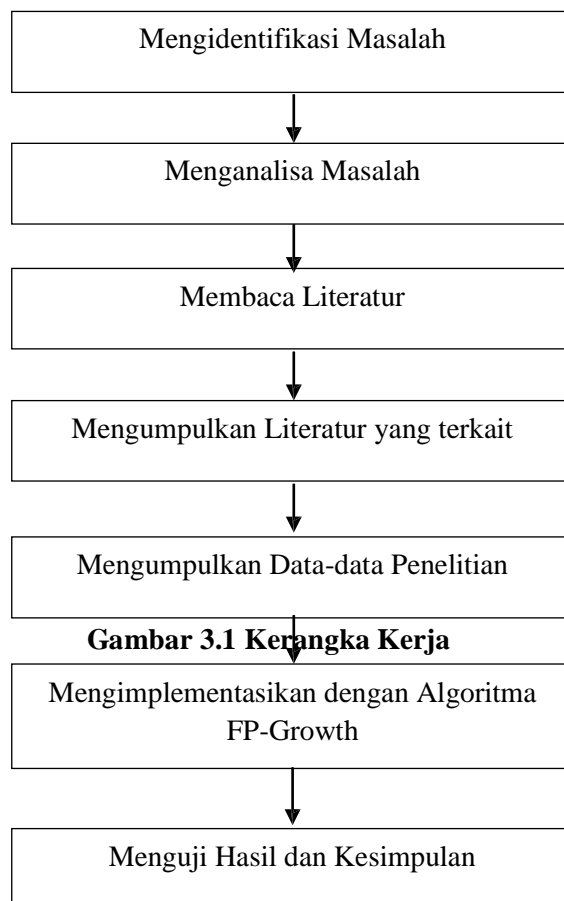
2.4 FP-Growth

FP-Growth adalah salah satu alternatif algoritma yang dapat digunakan untuk menentukan himpunan data yang paling sering muncul (*frequent item set*) dalam sekumpulan data. Algoritma *FP-Growth* merupakan pengembangan dari algoritma *Apriori* Ririanti (2014).

Dalam pencarian *frequent itemset*, Algoritma *FP-Growth* menggunakan konsep pembangunan *tree* bukan membangkitkan semua kemungkinan kombinasi *item* sehingga memiliki waktu kompilasi yang lebih cepat. Struktur data *tree* yang digunakan algoritma *FP-Growth* disebut dengan *FP-tree*.

3. Metode Penelitian

Dalam metodologi penelitian ada urutan kerangka kerja yang harus diikuti, urutan kerangka kerja ini adalah gambaran dari langkah-langkah yang harus dilalui agar penelitian ini bisa berjalan dengan baik serta sesuai yang diharapkan. Kerangka kerja yang harus diikuti bisa dilihat pada gambar 3.1:



4. Hasil dan Pembahasan

Frequent Pattern Growth (FP-Growth) adalah salah satu alternatif algoritma yang dapat digunakan untuk menentukan himpunan data yang paling sering muncul (*frequent itemset*) dalam sebuah kumpulan data. Pada Algoritma *Apriori* diperlukan *generate candidate* untuk mendapatkan *frequent itemsets*. Akan tetapi, di Algoritma *FP-Growth* *generate candidate* tidak dilakukan karena *FP-Growth* menggunakan konsep pembangunan *tree* dalam pencarian *frequent itemsets*. Hal tersebutlah yang menyebabkan algoritma *FP-Growth* lebih cepat dari algoritma *Apriori* (Erwin, 2009).

Karakteristik algoritma *FP-Growth* adalah struktur data yang digunakan adalah *tree* yang disebut dengan *FP-Tree*. Dengan menggunakan *FP-Tree*, algoritma *FP-growth* dapat langsung mengekstrak *frequent Itemset* dari *FP-Tree*. Penggalan itemset yang *frequent* dengan menggunakan algoritma *FP-Growth* akan dilakukan dengan cara membangkitkan struktur data *tree* atau disebut dengan *FPTree*. Metode *FP-Growth* dapat dibagi menjadi 3 tahapan utama yaitu sebagai :

1. Tahap pembangkitan *conditional pattern base*,
2. Tahap pembangkitan *conditional FP-Tree*, dan
3. Tahap pencarian *frequent itemset*.

Penelitian ini menggunakan proses asosiasi dalam menganalisa penjualan obat yang akan diproses dengan pembangunan *FP-tree* dalam pencarian *frequent itemsets* untuk menghasilkan suatu *output*. Data data tersebut mempunyai beberapa kriteria yang merupakan syarat dalam pembangunan *FP-tree*. Kumpulan *frequent itemsets* dicari dengan melakukan *scanning database* kemudian hasilnya diakumulasikan dengan tiap *items* lainnya dan dikelompokkan untuk mendapatkan *frequent itemsets* yang memenuhi nilai minimum *support*. Setelah didapatkan *frequent itemsets*, lalu *frequent itemsets* yang memiliki nilai kurang dari minimum *support* akan dipangkas atau dibuang. Sehingga akan didapatkan *frequent itemsets* yang memenuhi *minimum support* dan disusun dengan urutan menurun.

Untuk melakukan proses asosiasi dalam menganalisa data penjualan tersebut, sampel data yang digunakan adalah data transaksi penjualan obat di Apotek Rumah Sakit Haji selama satu tahun terakhir.

4.1 Pemilihan Variabel

Data sampel yang diuji dalam penelitian ini sebanyak 30 transaksi data penjualan obat, *format* seperti berikut :

1. ID Transaksi
2. Product Code
3. Product
4. Product Group

Adapun yang diambil sebagai variabel dalam asosiasi adalah mengenai Id Transaksi, Product code, Product, Product Group dan empat variabel ini akan dijadikan acuan untuk membentuk algoritma *FP-Growth* dibagi menjadi tiga langkah utama, namun terlebih dahulu dilakukan pembentukan pohon dengan menggunakan algoritma *FP-Tree*. *Frequent Patern Tree (FP-Tree)* adalah representasi pemasukan data yang dipadatkan.

Tabel 4.1 Data Penjualan Obat

ID Transaksi	Product Code	Product	Product Group
253140	ATU1	Atracurium Hameln 25	Atracurium
253140	CDX2	Cytodrox 500Mg Box / 10 Str	Cytodrox
253140	CET4	Ceteron 4Mg / Box 2 Str @ 6 Cp	Ceteron
253140	DNM2	Denomix Cream 10 Gr/Tube	Denomix
253140	DXR2	Doxorubin Inj 50 Mg 25 Ml/Vial	Doxorubin
253140	FLT9	Fleet Enema	Fleet
253140	FSC1	Fusycom Cream 5G/Tube	Fusycom
253140	MPD1	Mepirilid 1 Mg 30 Tab/Box	Mepirilid
253140	NPN1	Nopantin 300Mg 30Caps/Box	Nopantin
253140	NSG1	Neostigmine-Hameln 05Mg/Ml	Neostigmine
253140	PFC1	Profecom 100 Mg Box 10 Supp	Profecom
253140	PSY1	Posyd Inj 100 Mg	Posyd

253140	USF3	Ulsafate Suspensi 100 MI	Ulsafate
253140	VGT1	Vagistin Ovula / Box 10S	Vagistin
244422	CDX2	Cytodrox 500Mg Box / 10 Str	Cytodrox
244422	CET4	Ceteron 4Mg / Box 2 Str @ 6 Cp	Ceteron
244422	FSC1	Fusycom Cream 5G/Tube	Fusycom
220621	ATU2	Atracurium Hameln 50	Atracurium
220621	BNM1	Blenamax Inj. 15 I.U./10 MI	Blenamax
220621	CBS2	Carbosin Inj Rtus 150 Mg/Vial	Carbosin
220621	CBS4	Carbosin Inj 450 Mg / 45 MI	Carbosin
220621	CDX2	Cytodrox 500Mg Box / 10 Str	Cytodrox

Tabel 4.1 Data Penjualan Obat (lanjutan)

ID Transaksi	Product Code	Product	Product Group
220621	DXR1	Doxorubin Inj 10 Mg 5MI/Vial	Doxorubin
220621	DXR2	Doxorubin Inj 50 Mg 25 MI/Vial	Doxorubin
220621	ETX3	Emthexate Injection 5 Mg/Vial	Emthexate
220621	ETX4	Emthexate Injection 50Mg/Vial	Emthexate
220621	FLT9	Fleet Enema	Fleet
220621	FRC2	Fluracedyl Inj.Vial 500Mg/10MI	Fluracedyl
sampai dengan transaksi ke 30: ↓			
219519	PTS2	Platosin Inj Rtus 50 Mg/Vial	Platosin
219519	RCV4	Rescuvolin Inj 50 Mg/10 MI	Rescuvolin
219519	VCT1	Vincristine Sulf Inj 1Mg/1MI	Vincristine

4.2 Pra-Proses

Berdasarkan variabel-variabel yang sudah terpilih, *format* data menjadi seperti tampak pada tabel 4.2 di bawah ini :

Tabel 4.2 Pembentukan Setelah Pemilihan Variabel

TID	ID Transaksi	Product Group
1	253140	Atracurium
		Cytodrox
		Ceteron
		Denomix
		Doxorubin

Tabel 4.2 Pembentukan Setelah Pemilihan Variabel (Lanjutan)

TID	ID Transaksi	Product Group
		Fleet
		Fusycom
		Mepirilid
		Nopantin
		Neostigmine
		Profecom
		Posyd
		Ulsafate
		Vagistin
2	244422	Cytodrox
		Ceteron
		Fusycom
3	220621	Atracurium
		Blenamax
		Carbosin
		Cytodrox
		Doxorubin
		Emthexate
Fleet		

		Fluracedyl
		Fusycom
		Neostigmine
		Phental
		Posyd
		Platosin
		Rescuvolin
		Vinblastine
4	251477	Cytodrox
		Fleet
Sampai dengan transaksi ke- 30		
30		Platosin
		Rescuvolin
		Vincristine

Langkah selanjutnya adalah membuat simbol atau pengkodean dari nama-nama produk, dan sekaligus penghitungan frekuensi dan nilai *support*. Selanjutnya untuk Mencari *Frequent itemset*, maka diambil dari nilai *frequency* yang paling sering muncul, dan dalam penelitian ini penulis menentukan minimum *supportnya* adalah 20%.

$$= \frac{20 * 30}{100} = 6$$

Tabel 4.3 Frekuensi Itemset

Product Group	Simbol Itemset	Frekuensi	Support	
Atracurium	A	5	5/30	16,66%
Blenamax	B	1	1/30	3%
Carbosin	C	4	4/30	13,33%
Ceteron	D	4	4/30	13,33%
Comdipin	E	2	2/30	6,67%
Cytodrox	F	8	8/30	26,67%
Denomix	G	2	2/30	6,67%
Dobutamin	H	1	1/30	3%
Doxorubin	I	3	3/30	10%
Emthexate	J	1	1/30	3%
Fleet	K	8	8/30	26,67%
Fluracedyl	L	3	3/30	10%
Fusycom	M	14	14/30	46,67%
Mepirilid	N	4	4/30	13%
Neostigmine	O	7	7/30	23,33%
Nopantin	P	2	2/30	6,67%
Phental	Q	1	1/30	3%
Platosin	R	2	2/30	6,67%
Posyd	S	3	3/30	10%
Profecom	T	2	2/30	6,67%
Rescuvolin	U	2	2/30	6,67%
Ulsafate	V	17	17/30	56,67%

Vagistin	W	6	6/30	20%
Vinblastine	X	1	1/30	3%
Vincristine	Y	1	1/30	3%
	Z			

Setelah pencarian nilai *support* 20% maka hasil yang diambil seperti terlihat pada tabel diatas adalah *frequency* yang nilai minimumnya bernilai 6 dan diatasnya:

- Ulsafate (V) = 17
- Fusycom (M) = 14
- Cytodrox (F) = 8
- Fleet (K) = 8
- Neostigmine (O) = 7
- Vagistin (W) = 6

Tabel 4.4 Frequent Itemset yang Terbentuk

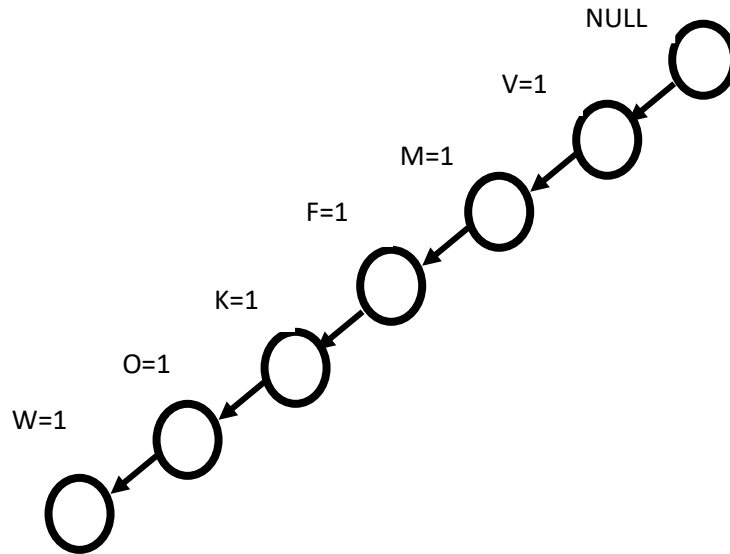
TID	ITEM
1	V, M, F, K, O, W
2	M, F
3	M, F, K, O
4	F, K, W
5	V, M, W
6	V
7	F
8	V, M, K, W
9	F
10	M
11	M
12	V, O
13	V, O
14	K
15	V
16	V, M, K, O
17	V, M
18	V, F, W
19	M
20	-
21	-
22	V
23	V, M, F, K
24	V, W
25	V, K
26	V, M

27	O
28	V
29	V, M, O
30	M

Tabel 4.4 diatas menggambarkan *Frequent Itemset* yang terbentuk dari 30 transaksi berdasarkan pengkodean yang telah dibuat.

Langkah selanjutnya adalah membentuk pohon FP-Tree:

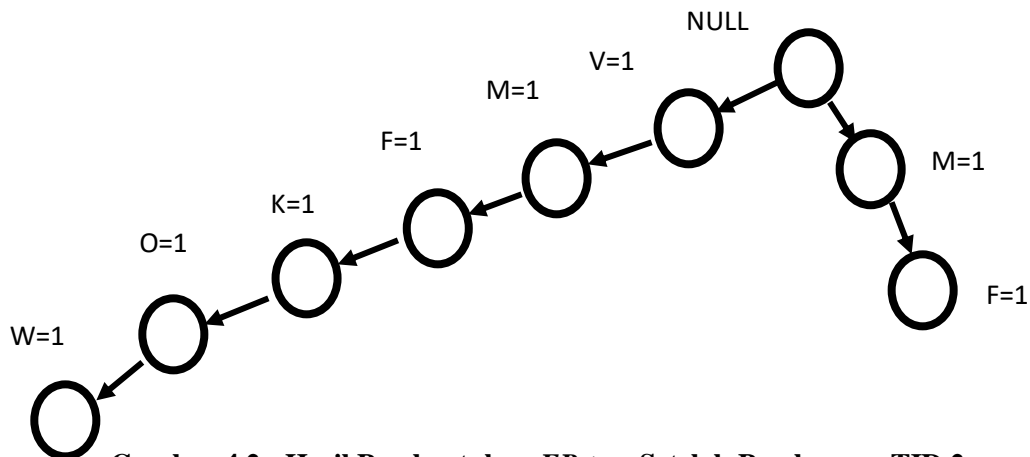
Gambar di bawah ini memberikan ilustrasi mengenai pembentukan *FP-tree* setelah pembacaan TID1



Gambar 4.1: Hasil Pembentukan *FP-tree* Setelah Pembacaan TID 1


Gambar didapat setelah melakukan TID 1, Yaitu berisi : NULL V (Ulsafate)=1, M (Fusycom)=1, F (Cytodrox)=1, K (Fleet)=1, O (Neostigmine)=1, W (Vagistin) =1

Selanjutnya pembentukan *FP-tree* untuk pembacaan TID 2:



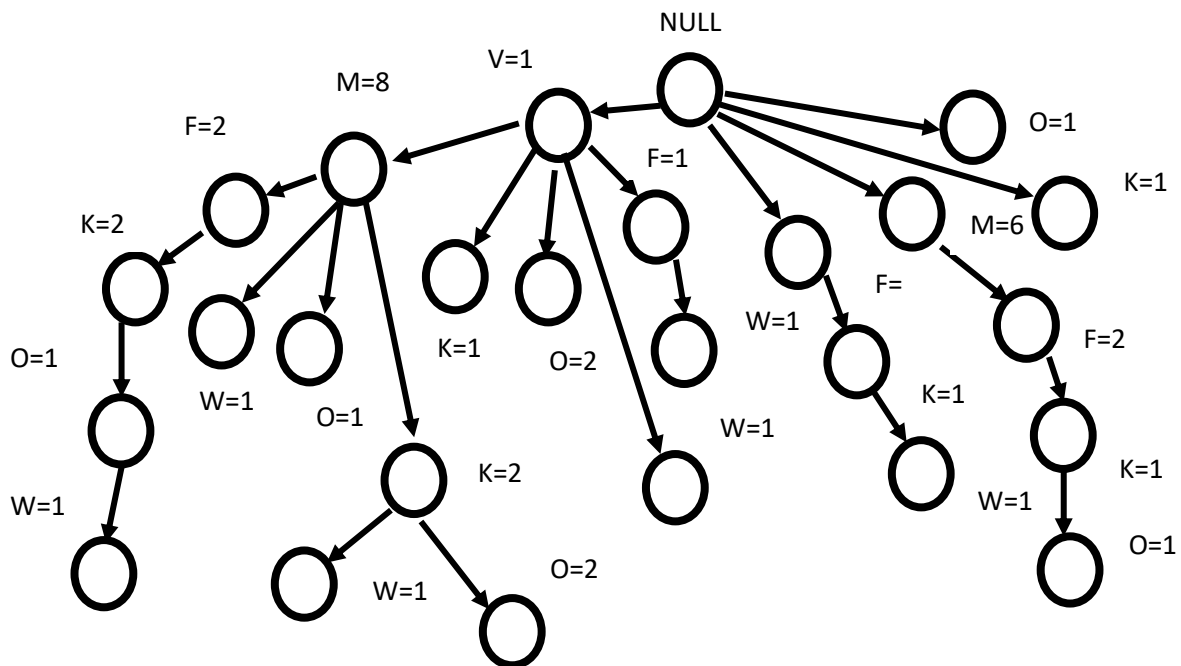
Gambar 4.2 : Hasil Pembentukan *FP-tree* Setelah Pembacaan TID 2

Gambar didapat setelah melakukan TID 2, yaitu: $NULL - M(\text{Fusycm})=1, F(\text{Cytodrox})=1$
 Selanjutnya pembentukan *FP-tree* untuk pembacaan TID 3:



Gambar 4.3 : Hasil Pembentukan *FP-tree* Setelah Pembacaan TID 3

Begitu selanjutnya sampai pembentukan *FP-tree* untuk pembacaan TID 30:



Gambar 4.4 : Hasil Pembentukan *FP-tree* Setelah Pembacaan TID 30

Gambar didapat setelah melakukan TID 30 yang dijumlahkan, yaitu berisi Null
 $V(\text{Ulsafate})=17, M(\text{Fusycm})=14, F(\text{Cytodrox})=8, K(\text{Fleet})=8, O(\text{Neostigmine})=7, W(\text{Vagistin})=6$.

Setelah mencari *frequent itemset* untuk beberapa akhiran *suffix* maka didapat hasil yang dirangkum dalam tabel berikut:

Tabel 4.5 Daftar Frequent Itemset Diurutkan Berdasarkan Hubungan Akhiran

Suffix	Frequent Itemset
W	{{V, M, F, K, O, W}}, {{V, M, K, W}}, {{V, M, W}}, {{V, F, W}}, {{V, W}}, {{F, K, W}}.
O	{{V, M, F, K, O}}, {{V, M, K, O}}, {{V, M, O}}, {{V, O}}, {{M, F, K, O}}.
K	{{V, M, F, K}}, {{V, M, K}}, {{V, K}}, {{M, F, K}}, {{F, K}}, {{M, K}}
F	{{V, M, F}}, {{V, F}}, {{M, F}}.
M	{{V, M}}.
V	{{V}}.

Tahap selanjutnya adalah menghitung nilai support dan confidence dan memfilter itemset berdasarkan minimum support dan confidence dan selanjutnya menentukan aturan asosiasi dari nilai-nilai yang telah didapat:

Tabel 4.6 Aturan Asosiasi (Association Rule)

No	Itemset	Qty	Support %	Confidence %
1	V, M	8	26,66	47,05
2	M, V	8	26,66 %	57,14
3	V, F	3	10	17,64
4	F, V	3	10	37,50
5	V, K	5	16,66	29,41
6	K, V	5	16,66	62,50
7	V, O	5	16,66	29,41
8	O, V	5	16,66	71,42
9	V, W	5	16,66	29,41
10	W, V	5	16,66	83,33
11	M, K	5	16,66	35,71
12	K, M	5	16,66	62,50
13	M, F	4	13,33	28,57
14	F, K	4	13,33	50
15	V, M, F	2	6,66	25
16	V, M, K	4	13,33	50
17	V, M, O	3	10	37,5
18	V, M, W	3	10	37,5
19	V, F, W	2	6,66	66,66
20	M, F, K	3	10	75
21	F, K, W	2	6,66	50
22	V, M, K, W	2	6,66	50
23	V, M, K, O	2	6,66	50
24	M, F, K, O	2	6,66	66,66
25	V, M, F, K	2	6,66	100
26	V, M, F, K, O	1	3,33	50
27	V, M, F, K, O, W	1	3,33	100

Setelah didapat aturan asosiasi seperti tabel diatas maka ditentukan besaran *support* dan *confidence* yang akan digunakan, Minimum *support* yang digunakan pada penelitian ini adalah 15% dan minimum *confidence* 25%.

Berikut tabel setelah ditentukan minimum *support* dan *confidence*:

Tabel 4.7 Aturan Asosiasi dengan Minimum Support dan Confidence

No	Itemset	Qty	Support %	Confidence %
1	V, M	8	26,66	47,05
2	M, V	8	26,66	57,14
3	V, K	5	16,66	29,41
4	K, V	5	16,66	62,50
5	V, O	5	16,66	29,41
6	O, V	5	16,66	71,42
7	V, W	5	16,66	29,41
8	W, V	5	16,66	83,33
9	M, K	5	16,66	35,71
10	K, M	5	16,66	62,50

5. Kesimpulan

Dari tahap-tahap yang telah dilakukan di atas, maka dapat diambil kesimpulan sebagai berikut:

1. Jika membeli Ulsafate (V) maka akan membeli Fusycom (M) dengan *support* 26,66% dan *confidence* 47,05%.
2. Jika membeli Fusycom (M) maka akan membeli Ulsafate (V) dengan *support* 26,66% dan *confidence* 57,14%.
3. Jika membeli Ulsafate (V) akan membeli Fleet (K) dengan *support* 16,66% dan *confidence* 29,41%.
4. Jika membeli Fleet (K) akan membeli Ulsafate (V) dengan *support* 16,66% dan *confidence* 62,50%.
5. Jika membeli Ulsafate (V) maka akan membeli Neostigmine (O) dengan *support* 16,66% dan *confidence* 29,41%.
6. Jika membeli Neostigmine (O) maka akan membeli Ulsafate (V) dengan *support* 16,66% dan *confidence* 71,42%.
7. Jika membeli Ulsafate (V) maka akan membeli Vagistin (W) dengan *support* 16,66% dan *confidence* 29,41%.
8. Jika membeli Vagistin (W) maka akan membeli Ulsafate (V) dengan *support* 16,66% dan *confidence* 83,33%.
9. Jika membeli Fusycom (M) maka akan membeli Fleet (K) dengan *support* 16,66 % dan *confidence* 35,71%.
10. Jika membeli Fleet (K) maka akan membeli Fusycom (M) dengan *support* 16,66 % dan *confidence* 35,71%.

DAFTAR REFERENSI

1. Amira H. Shalaby, Dr.Mohmoud M.Abd el letif, Dr. Amira Rezk, Prof. Mohamed Hagag “ Suggested Marketing Strategy Using Apriori and FPGrowth Algorithms in retail sales in Egypt “ International Journal Of Computers & Technology Vol. 14, no.11 Tahun 2015.
2. Donny MitraVirgiawan dan Imam Mukhlas “ Aplikasi Association Rule Mining Untuk Menemukan Pola Pada Data Nilai Mahasiswa Matematika ITS ” Jurnal Sains, Surabaya, 2013. Eferi Bulololo “ Implementasi Algoritma Apriori Pada Sistem Persediaan Obat .” Medan, 2013.
3. Fadlina “ Data Mining Untuk Analisa Tingkat Kejahatan Jalanan Dengan Algoritma Association Rule Metode Apriori.”Vol 111 no 1 ,Sumatera Barat ” 2014.
4. Goldie Gunadi dan Dana Indra Sensus “ Penerapan Metode Data Mining Marbet Basket Analysis Terhadap Data Penjualan Produk Baru Dengan Menggunakan Algoritma Apriori dan Frequent Pattern Growth (FP-Growth).” Telematika Vol.4 No.1, 2012.
5. J. Suresh, P. Rushyanth, Ch. Trinath “ Generating associations rule mining using Apriori and FPGrowth Algorithms “ IJCTT volume 4 Issue 4, 2013.

6. Kennedi Tampubolon, Hoga Saragih dan Bobby Reza “ Implementasi Data Mining Algoritma Apriori Pada Sistem Persediaan Alat-alat Kesehatan .” INTI Vol.1 No.1, Medan, 2013.
7. Rahma Novta Miraldi, Antonius Rahmat dan Budi Susanto “ Implementasi Algoritma FP-Growth Untuk Sistem Rekomendasi Buku di Perpustakaan UKDW.”Vol.10 No.1, 2014.
8. Rakesh Kumar Soni, Prof. Neetesh Gupta, Prof. Amit Sinhal “ An FP-Growth Approach to Mining Association Rule .” IJCSMC Vol.2 , 2013. Ririanti “ Implementasi Algoritma FP-Growth Pada Aplikasi Prediksi Persediaan Sepeda Motor .” PIBD Vol.VI No.1, 2014