

## PENERAPAN ALGORITMA *FP-GROWTH* UNTUK MENGANALISA POLA TRANSAKSI PEMBELIAN OBAT OLEH KOSUMEN

(Studi Kasus : Apotek Anza Farma Kabupaten Anambas)  
Maizatul Akmar<sup>1</sup>, Tekad Matulatan<sup>2</sup>, Nola Ritha<sup>3</sup>  
150155201026@student.umrah.ac.id

Program Studi Teknik Informatika, Fakultas Teknik, Universitas Maritim Raja Ali Haji

### Abstract

*Anza Farma Pharmacy is one of the pharmacies that serve drug sales in Anambas Regency. Anza Farma pharmacies serve thousands of transactions/month by selling prescription, non-prescription and concoction drugs. There are many transactions that occur at the pharmacy, but the transaction data has not been used to its full potential. The researcher then builds an application or system by utilizing data mining techniques using the fp-growth algorithm to obtain information in the form of connectedness of drug purchases by consumers. System or application test results by inputting 0.10 for minimum support and 0.50 for minimum confidence, namely the formation of 5 association rules with the highest rule being Betadine => Hansaplast (if a customer buys betadine then buys hansaplast) with a support value of 18.36% and the confidence value is 94.84% followed by the lift value 5.1389, and the conviction 15.8034 and the cosine 0.97143. These results are very helpful for the Anza Farma pharmacy to find out which drug items are related.*

**Keywords:** *Fp-Growth Algorithm, Association, Data Mining*

### I. Pendahuluan

Teknologi informasi pada saat ini telah berkembang pesat, dan perkembangan tersebut tidak bisa lepas dari perkembangan manusia. Teknologi saat ini digunakan dalam berbagai hal salah satunya usaha yang bergerak dibidang obat-obatan. Obat merupakan kebutuhan yang penting dalam pelayanan kesehatan guna mengobati suatu penyakit. Obat dapat dibeli di apotek, rumah sakit atau tempat penyedia obat lainnya. Lestari Y.D(2017). Setiap harinya terjadi transaksi penjualan dan pembelian obat. Setiap apotek harus memiliki sistem pengolahan data agar data transaksi tersebut dapat digunakan dalam membuat laporan bulanan atau tahunan. Laporan dari data transaksi tersebut dapat kita olah menjadi informasi yang berguna dan bermanfaat bagi pemilik apotek.

Obat sering kali dibeli dalam satu atau lebih jenis yang berbeda dalam satu transaksi, untuk itu obat satu jenis dengan jenis lainnya memiliki keterkaitan atau hubungan antar satu dengan lainnya. Asosiasi inilah yang dapat dimanfaatkan untuk perencanaan strategi kedepan. Pihak apotek perlu mengetahui data transaksi produk yang dibeli oleh pelanggan.

Apotik Anza farma merupakan salah satu Apotik yang melayani penjualan obat yang berada di Kabupaten Anambas. Apotek Anza Farma merupakan salah satu apotek di Anambas yang terletak di Jl. A.Yani laut Gg. Todak. Apotek Anza Farma melayani ribuan

transaksi/bulan dengan melayani penjualan obat yang menggunakan resep, tanpa resep, dan racikan obat. Banyaknya transaksi yang terjadi diapotek tersebut, namun data transaksi belum dimanfaatkan secara maksimal. Dengan memanfaatkan data transaksi tersebut dapat menghasilkan informasi yang berguna, seperti mengetahui keterhubungan pembelian obat berdasarkan suatu jenis penyakit.

Berdasarkan masalah yang dijabarkan di atas, maka peneliti ingin membantu pemilik apotek untuk menemukan informasi yang terkandung di dalam data transaksi penjualan dengan melakukan penelitian dengan judul Penerapan Algoritma *Fp-Growth* Untuk Menganalisa Pola Transaksi Pembelian Obat Oleh Konsumen.

## II. Tinjauan Pustaka

### 2.1 Aturan Asosiasi

*Association rule* (aturan asosiatif) adalah salah satu teknik utama dalam Data mining dan merupakan bentuk yang paling umum dipakai dalam menemukan pattern atau poladari suatu kumpulan data. *Association rule* berusaha menemukan aturan-aturan tertentu yang mengasosiasikan data yang satu dengan data yang lain. Untuk mencari *association rule* dari suatu kumpulan data, pertama-tama harus dicari lebih dulu yang disebut "*frequent itemset*" (sekumpulan item yang sering muncul bersamaan) adalah antara 0 – 100%. Support dari suatu *association rule* adalah proporsi dari transaksi dalam database yang mengandung A dan B, yaitu:

$$Support(A) = \frac{\Sigma \text{Transaksi mengandung A}}{\text{Total transaksi}} * 100\% \quad (1)$$

Sedangkan nilai *support* dari dua item diperoleh dari rumus berikut :

$$Support(A \rightarrow B) = \frac{\Sigma \text{Transaksi mengandung A dan B}}{\text{Jumlah Transaksi}} * 100\% \quad (2)$$

Untuk mencari nilai confidence dapat menggunakan rumus berikut :

$$Confidence P(A \setminus B) = \frac{\Sigma \text{Transaksi mengandung A dan B}}{\Sigma \text{Transaksi mengandung A}} * 100\% \quad (3)$$

Arisandi, D. (2016)

### 2.2 Lift Rasio

*Lift* digunakan untuk mengukur seberapa penting aturan yang telah terbentuk berdasarkan nilai support dan confidence. Nilai lift yang lebih besar dari 1 menunjukkan bahwa A dan B muncul lebih sering bersamaan. Apabila nilai lift lebih besar dari 1, maka aturan tersebut dapat disimpulkan memberi manfaat. Untuk menghitung lift menggunakan rumus sebagai berikut:

$$Lift(A \Rightarrow B) = \frac{confidence(A \Rightarrow B)}{support(B)} \quad (4)$$

Manimaran & Velmurugan (2015)

### 2.3 Conviction

Conviction digunakan untuk mengukur tingkat implikasi. Conviction menyatakan bahwa conviction ( $A \Rightarrow B$ )  $\neq$  conviction ( $B \Rightarrow A$ ). nilai conviction didapat dari rumus dibawah ini:

$$\text{Conviction}(A \Rightarrow B) = \frac{1 - \text{support } B1}{1 - \text{confidence } (A \Rightarrow B)} \quad (5)$$

Manimaran & Velmurugan (2015)

### 2.4 Cosine

Cosine Ini digunakan untuk mengukur kesamaan antara LHS dan RHS. Semakin dekat cosine ( $X \Rightarrow Y$ ) ke 1, semakin banyak transaksi yang mengandung item X juga mengandung item Y. Sebaliknya, semakin dekat cosine ( $X \Rightarrow Y$ ) ke 0, semakin banyak transaksi mengandung item X tanpa mengandung item Y. Nilai cosine didapat dari rumus dibawah ini:

$$\text{Cosine}(A \Rightarrow B) = \frac{P(A, B)}{\sqrt{P(A)P(B)}} \quad (6)$$

Manimaran & Velmurugan (2015)

### 2.5 Data Mining

Data mining merupakan proses memperoleh informasi dengan mencari pola dan hubungan yang tersembunyi pada tumpukan data. Data mining merupakan salah satu disiplin ilmu yang sebagian besar terbuka untuk dunia. Data mining juga disebut sebagai Knowledge Discovery in Database (KDD), yaitu kegiatan pengumpulan, pemakaian data lampau untuk menemukan pola atau hubungan terhadap data yang ukurannya besar. Data mining ini juga bisa digunakan untuk membantu dalam pengambilan keputusan. Berdasarkan fungsinya data mining dikelompokkan menjadi beberapa kelompok sebagai berikut :

1. Deskripsi (*description*), untuk memberi ringkasan untuk data yang jumlahnya sangat besar dan banyak jenisnya.
2. Estimasi (*estimation*), untuk menebak – nebak nilai yang belum diketahui, contoh menerka penghasilan seseorang berdasarkan informasi pekerjaan orang tersebut.
3. Prediksi (*prediction*), untuk memperkirakan nilai yang mungkin akan terjadi di masa yang akan datang, contoh prediksi stok bahan baku untuk beberapa bulan yang akan datang.
4. Klasifikasi (*classification*), untuk membagi data menjadi beberapa label kelas untuk objek yang sudah diketahui hasilnya dan memperkirakan kelas berdasarkan objek yang belum diketahui labelnya.
5. Pengelompokan (*clustering*), untuk mengelompokkan sejumlah data yang mempunyai suatu karakteristik tertentu.
6. Asosiasi (*association*), untuk mengetahui pola pengelompokan data dalam suatu kondisi tertentu. Setiawan & Anugrah (2019)

### 2.6 Algoritma Fp-Growth

*Fp-Growth* adalah algoritma untuk menemukan *frequent itemset* tanpa melalui proses penggenerasian kandidat seperti pada algoritma *apriori*. Algoritma *Fp-Growth* merupakan pengembangan dari algoritma *apriori* yang mengadopsi prinsip *divide-and-conquer* yaitu dengan cara mengkompresi database dan merepresentasikan *frequent itemset* ke dalam bentuk

*Frequent Pattern Tree (FP-Tree)* yang menyimpan informasi asosiasi antar *itemset*. Kemudian membagi database terkompresi tersebut ke dalam suatu *set conditional database* dimana pada masing-masing setnya berasosiasi dengan satu *frequent item* atau "*pattern fragment*" dan menambang setiap database secara terpisah. Pada setiap "*pattern fragment*", hanya dataset yang berasosiasi saja yang di perlu di tambang. Adapun langkah-langkah dari algoritma *FP-Growth* adalah sebagai berikut :

1. Scan database dengan cara yang sama seperti algoritma apriori.
2. Langkah berikutnya adalah pembentukan *FP-Tree*. *FP Tree* dibuat dengan cara berikut :
  - a. Pertama, Buat Root dari *Tree* dan di label dengan "*null*".
  - b. Item pada setiap transaksi di proses dalam bentuk list order (diurutkan berdasarkan Descending Support count), selanjutnya adalah pembentukan simpul untuk setiap transaksi. Nilai *support count* akan bertambah 1 jika ada *node* yang sama dalam dalam suatu *prefix*. Untuk *node* yang bersesuaian akan saling terhubung (*linked*).
3. Selanjutnya adalah Menambang *FP-Tree* dengan cara sebagai berikut :
  - a. Membentuk *conditional Pattern Base* ("*sub database*") yang terdiri dari suatu *set prefix path* di dalam *FP-Tree* yang terbentuk bersama dengan *suffix pattern*).
  - b. Membentuk *Conditional FP-Tree*.
  - c. *Frequently Pattern Growth* di dapat dari penggabungan antara *suffix pattern* dengan *Frequently Pattern* yang dihasilkan dari *conditional FP-Tree*. Kadafi (2019)

### III. Hasil Dan Pembahasan

#### 3.1 Analisis Kebutuhan Data

Pada analisis data, data yang digunakan adalah data informasi proses transaksi penjualan obat di Apotek Anza Farma dari bulan oktober tahun 2020 sampai bulan desember tahun 2020. Berikut tabel data transaksi atau pembelian obat pada Apotek Anza Farma, yaitu terdapat pada tabel 1.

**Tabel 3.1** Data transaksi

Atribut	Keterangan
Data nomor transaksi	Data nomor transaksi merupakan data yang membedakan struk transaksi yang satu dengan yang lainnya.
Data nama produk yang di beli	Nama item / nama produk merupakan data dari nama produk yang di beli dalam setiap kali transaksi.

#### 3.2 Perhitungan Manual Algoritma Fp-Growth

Pada tabel 3.2 dibawah ini merupakan sampel data untuk melakukan perhitungan manual, diambil 20 data transaksi, data ini yang akan dilakukan pengolahan dengan menggunakan perhitungan algoritma *fp-growth* sesuai dengan atribut yang telah ditentukan.

**Tabel 3. 2** Data transaksi awal

ID Transaksi	Item Pembelian
1	FACE SHIELD, DISPLOSABLE FACE MASK, DETTOL GEL HINDSANITIZER 50 ML
2	BETADINE, HANSAPLAST, KASA STERIL, DETTOL GEL HANDSANITIZER

ID Transaksi	Item Pembelian
3	DETTOL GEL HANDSANITIZERB 50 ML, BETADINE, HANSAPLAST
4	FRESHCARE, DETTOL GEL HANDSANITIZERB 50 ML, DISPLOSABLE FACE MASK
5	DETTOL GEL HANDSANITIZERB 50 ML, BETADINE, HANSAPLAST
6	BETADINE, HANSAPLAST, KASA STERIL, DETTOL GEL HANDSANITIZERB 50 ML
7	FEMINAX, LACTACYD
8	ENTROSTOP TAB, FRESH CARE STRONG, DETTOL GEL HANDSANITIZERB 50 ML
9	AL-JAZIRA SARI KURMA 360 ML, ENTRASOL, CDR
10	FEMINAX, FRESHCARE, CDR
11	AL-JAZIRA SARI KURMA 360 ML, DISPLOSABLE FACE MASK, DETTOL GEL HANDSANITIZERB 50 ML
12	KASA STERIL , BETADINE , HANSAPLAST
13	FACE SHIELD, DISPLOSABLE FACE MASK, SANGOBION
14	MINYAK KAYU PUTIH LANG 60 ML, DETTOL GEL HANDSANITIZER
15	MINYAK KAYU PUTIH LANG 60 ML, DETTOL GEL HANDSANITIZERB 50 ML, DISPLOSABLE FACE MASK
16	AL- JAZIRA SARI KURMA 360 ML, DISPLOSABLE FACE MASK , MINYAK KAYU PUTIH LANG 60 ML
17	FRESHCARE, TOLAK ANGIN, DISPLOSABLE FACE MASK
18	TOLAK ANGIN, DETTOL GEL HANDSANITIZERB 50 ML, DISPLOSABLE FACE MASK
19	FRESH CARE,FLUCADEX TAB, TOLAK ANGIN CAIR
20	BETADINE , HANSAPLAST

Dari tabel 3.2 dapat diketahui bahwa terdapat 20 jenis transaksi dengan beberapa pola item – item yang dibeli. Dari table tersebut dapat dilakukan penyiapan dataset. Pada penyiapan data set ini memuat nama item obat dan diberi kode huruf agar dapat memudahkan dalam perhitungannya nanti. Pada tabel 3. 3 merupakan tabel penyiapan dataset.

**Tabel 3. 3** Penyiapan data set

Transaksi Id	Items
1	FCS, DSM, DGS
2	BTN, HNS, KST, DGS
3	DGS, BTN, HNS
4	FRS, DGS, DSM
5	DGS, BTN, HNS
6	BTN, HNS, KST, DGS
7	FMN, LTC
8	ENT, FRS, DGS
9	AJS, ENS, CDR
10	FMN, FRS, CDR
11	AJS, DSM, DGS
12	KST, BTN, HNS

13	FCS, DSM, SGB
14	MKP, DGS
15	MKP, DGS, DSM
16	AJS, DSM, MKP
17	FRS, TAD, DSM
18	TAD, DGS, DSM
19	FRS, FLC, TAC
20	BTN, HNS

Setelah dilakukan penyiapan dataset, langkah selanjutnya adalah melakukan pencarian frekuensi kemunculan tiap item dapat dilihat pada table 3.4 dibawah ini:

**Tabel 3. 4** Pencarian frequent item

Itemset	Support count
FCS	2
DSM	8
DGS	11
BTN	6
HNS	6
KST	3
FRS	5
FMN	2
LTC	1
ENT	1
AJS	3
ENS	1
CDR	2
SGB	1
MKP	3
TAD	2
FLC	1
TAC	1

Setelah dilakukan pemindaian pertama, didapat item yang memiliki frekuensi diatas support count = 2. Ke dua belas item inilah yang akan berpengaruh dan akan dimasukkan kedalam *fp-tree*. Selebihnya dibuang karena tidak berpengaruh signifikan. Pada tabel 3.5 merupakan item item yan telah memenuhi support count .

**Tabel 3. 5** Item yang memenuhi support count

Itemset	Support count
DGS	11
DSM	8
BTN	6
HNS	6
FRS	5
KST	3
AJS	3

MKP	3
FCS	2
FMN	2
CDR	2
TAD	2

Setelah didapat item yang memenuhi support count, kemudian tahap selanjutnya yaitu mengurutkan dataset. Mengurutkan dataset ini berdasarkan priority, atau mengurutkan kemunculan item berdasarkan frekuensi yang paling tinggi. Pada tabel 3.6 dibawah ini merupakan dataset yang telah diurutkan.

**Tabel 3. 6** Pengurutan dataset berdasarkan priority

Transaksi Id	Items
1	DGS, DSM, FCS
2	DGS, BTN, HNS, KST
3	DGS, BTN, HNS
4	DGS, DSM, FRS
5	DGS, BTN, HNS
6	DGS, BTN, HNS, KST
7	FMN
8	DGS, FRS
9	AJS, CDR
10	FRS, FMN, CDR
11	DGS, DSM, AJS
12	BTN, HNS, KST
13	DSM, FCS
14	DGS, MKP
15	DGS, DSM, MKP
16	DSM, AJS, MKP
17	DSM, FRS, TAD
18	DGS, DSM, TAD
19	FRS
20	BTN, HNS

Setelah melakukan pengurutan dataset berdasarkan priority, tahap selanjutnya adalah melakukan pembangunan *fp-tree*. *Fp-tree* di bangun dengan membaca dataset satu transaksi



didapatkan melalui *fp-tree* yang dibangun sebelumnya. Pada tahap pembangkitan conditional pattern base ini akan dilakukan pengurutan frekuensi dimulai dari yang terkecil sampai yang terbesar. Setelah melakukan pembangkitan conditional pattern base, tahap selanjutnya adalah melakukan pembangkitan conditional *fp-tree*. Pada tabel 3.11 dibawah ini merupakan pembangkitan conditional *fp-tree*.

**Tabel 3. 8** Pembangkitan conditional *fp-tree*

Item	Conditional <i>fp-tree</i>
TAD	-
CDR	-
FMN	-
FCS	-
MKP	<DGS : 2>
AJS	-
KST	-
FRS	-
HNS	<BTN : 4> <BTN: 2>
BTN	<DGS : 4>
DSM	<DGS : 5>
DGS	-

Setelah melakukan pembangkitan conditional pattern base, selanjutnya akan dilakukan pembangkitan conditional *fp-tree*. Pada tahap ini, support count dari setiap item pada setiap conditional pattern base dijumlahkan, lalu setiap yang memiliki jumlah support count lebih besar sama dengan minimum support count akan dibangkitkan dengan conditional *fp-tree*.

Kemudian tahap selanjutnya akan dilakukan pembangkitan frequent pattern. Pada tabel 3.9 dibawah ini merupakan tahap pembangkitan frequent pattern.

**Tabel 3. 9** Pembangkitan frequent pattern

Item	Frequent Pattern
TAD	{-}
CDR	{ - }
FMN	{ - }
FCS	{-}
MKP	{DGS, MKP: 2}
AJS	{-}
KST	{-}
FRS	{-}
HNS	{ BTN, HNS : 6}
BTN	{ DGS, BTN : 4}
DSM	{ DGS, DSM : 5}
DGS	{-}

Apabila conditional *fp-tree* merupakan lintasan tunggal (single path), maka didapatkan frequent pattern dengan melakukan kombinasi item untuk setiap conditional *fp-tree*. Jika bukan lintasan tunggal, maka dilakukan pembangkitan *fp-growth*.

### 3.10 Menghitung Nilai Support dan Confidence

#### a. Mencari nilai support dari 2 kombinasi item

Pada langkah selanjutnya yaitu mencari 2 kombinasi *itemset* dengan menggunakan formulasi 2 *itemset* dapat dilihat dari persamaan sebagai berikut :

$$Support = \frac{\text{Transaksi mengandung A dan B}}{\text{Jumlah Transaksi}} * 100\% \quad (7)$$

$$Support = \frac{\text{Transaksi mengandung DGS dan DSM}}{\text{Jumlah Transaksi}} * 100\%$$

$$Support = \frac{5}{20} * 100\% = 25\%$$

Hingga pada nama obat berikutnya dengan menampilkan hasil dari support 2 produk *itemset* dapat dilihat pada tabel 3.10 dengan menggunakan perhitungan persamaan (7) yang telah dilakukan.

**Tabel 3. 10** Kombinasi dua item

No	Kombinasi 2 <i>Itemset</i>	Jumlah Transaksi	<i>Support</i>
1	DGS, DSM	5	25%
2	DGS, BTN	4	20%
3	DGR, FRS	2	10%
4	DGS, HNS	4	20%
5	DSM, FCS	2	10%
6	DSM,AJS	2	10%
7	DSM, FRS	2	10%
8	DSM, TAD	2	10%
9	BTN, HNS	6	30%
10	BTN, KST	3	15%

Berdasarkan hasil perhitungan *support* dari dua kombinasi *item* di dapatkan 4 transaksi yang memenuhi minimum support 20% ditunjukkan pada Tabel 3.11

**Tabel 3. 11** Hasil perhitungan support dari dua kombinasi item

No	Nama Obat	Support
1	DGS, DSM	25%
2	DGS, BTN	20%
3	DGS, HNS	20%
4	BTN, HNS	30%

#### b. Mencari nilai confidence dari 2 kombinasi item

Setelah semua pola frekuensi tinggi ditemukan, barulah dicari aturan asosiasi yang memenuhi syarat minimum untuk confidence dengan menghitung confidence aturan asosiatif A→B. Nilai Confidence dari aturan A→B diperoleh dengan menggunakan persamaan (8) sebagai berikut:

$$Confidence = \frac{\text{Transaksi mengandung A dan B}}{\text{Transaksi mengandung A}} * 100 \% \quad (8)$$

$$Confidence = \frac{\text{Transaksi mengandung DGS dan DSM}}{\text{Transaksi mengandung DGS}} * 100 \%$$

$$Confidence = \frac{5}{11} * 100 = 45,4545\%$$

Hingga pada kategori produk berikutnya dengan menampilkan hasil dari confidence 2 produk itemset dapat dilihat pada Tabel 3.12 dengan menggunakan perhitungan persamaan (8) yang telah dilakukan.

**Tabel 3. 12** Hasil confidence

No	Nama Kombinasi Obat	Jumlah Transaksi	Confidence
1	DGS, DSM	5	45,45%
2	BTN, HNS	6	100%

Data berikut merupakan gabungan hasil perhitungan Support dan confidence dari dua kombinasi item dapat dilihat pada tabel 3.13

**Tabel 3. 13** Hasil support dan confidence dari dua kombinasi

No	Nama Kombinasi Obat	Jumlah Transaksi	Support	Confidence
1	DGS, DSM	5	25%	45,45%
2	BTN, HNS	6	30%	100%

### 3.11 Menghitung Nilai Lift Rasio

Lift digunakan untuk mengukur seberapa penting aturan yang telah terbentuk berdasarkan nilai support dan confidence. Untuk menghitung lift menggunakan rumus sebagai berikut:

$$Lift(A \Rightarrow B) = \frac{confidence(A \Rightarrow B)}{support(B)} \quad (9)$$

$$Lift(A \Rightarrow B) = \frac{0,4545}{0,4} = 1.13625$$

### 3.12 Menghitung Nilai Conviction

Conviction digunakan untuk mengukur tingkat implikasi. Untuk menghitung conviction menggunakan rumus dibawah ini:

$$Conviction(A \Rightarrow B) = \frac{1 - support(B)}{1 - confidence(A \Rightarrow B)} \quad (10)$$

$$Conviction(A \Rightarrow B) = \frac{1 - 0,4}{1 - 0,4545} = 1.0999$$

### 3.13 Menghitung nilai Cosine

Cosine Ini digunakan untuk mengukur kesamaan antara LHS dan RHS. Nilai cosine didapat dari rumus dibawah ini:

$$Cosine(A \Rightarrow B) = \frac{P(A,B)}{\sqrt{P(A)P(B)}} \quad (12)$$

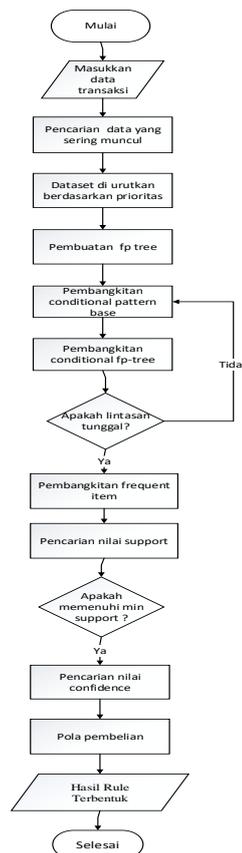
$$Cosine(A \Rightarrow B) = \frac{0,25}{\sqrt{0,55 * 0,4}} = 0.533003$$

Seluruh nilai *interesting measure* yang dapat dilihat pada tabel 3.14

**Tabel 3.14.**Nilai Interesting Measure

No	A=>B	Support	Confidence	Lift	Conviction	Cosine
1	DGS=>DSM	25%	45.45%	1.13625	1.0999	0.5333003
2	BTN=>HNS	30%	100%	3.333	-	1

a. Perancangan Proses Perhitungan Dengan Algoritma *Fp-Growth*



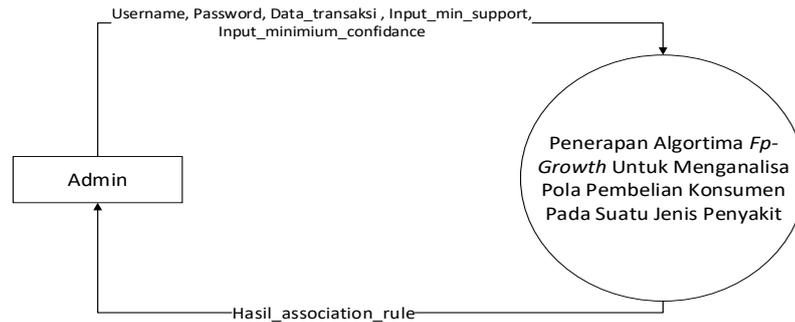
**Keterangan :**

Keterangan :

- a. Sistem dimulai
- b. Data transaksi
- c. Pencarian item yang sering muncul
- d. Dataset diurutkan berdasarkan proiritas
- e. Pembuatan *fp-tree*
- f. Pembangkitan *conditional pattern base*
- g. Pembangkitan *conditional fp-tree*
- h. Tahap selanjutnya apakah terdapat lintasan tunggal
- i. Pembangkitan *frequent item*
- j. Pencarian nilai *support*
- k. Apakah memenuhi min support
- l. Pencarian nilai *confidence*
- m. Pola pembelian
- n. Hasil rule terbentuk
- o. Selesai

b. Data *Flow Diagram*  
1. Diagram Konteks

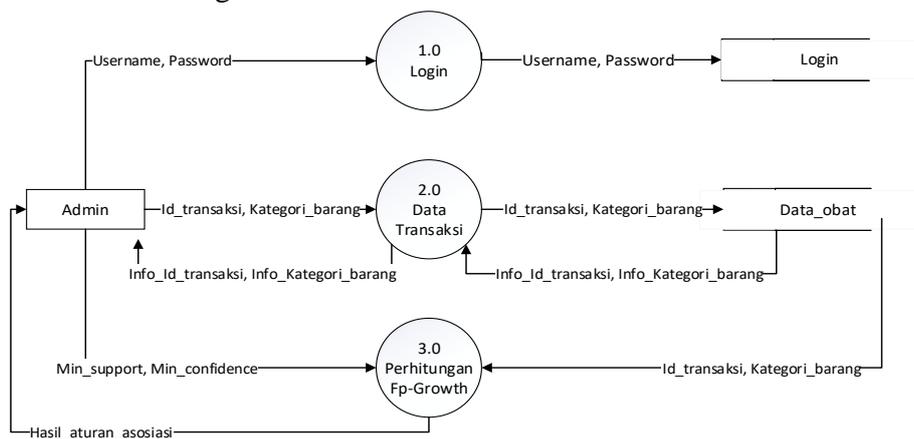
Diagram konteks merupakan diagram yang menjelaskan secara keseluruhan proses utama dalam sebuah system. Diagram tersebut menjelaskan apa yang dimasukkan data yang diterima oleh system. Diagram tersebut dapat dilihat pada gambar 3.2



Gambar 3. 2 Diagram Konteks

Pada DFD Level 0 atau diagram konteks diatas digambarkan secara umum, dimana *admin* dapat melakukan *login*, *input* data transaksi, *input* nilai minimum support, dan *input* nilai confidence yang akan dilakukan pada proses algoritma fp-growth. Kemudian keluaran dari system akan akan memberikan informasi hasil association rule dari nama obat yang dibeli dengan mencari keterhubungannya

## 2. Data Flow Diagram Level 1

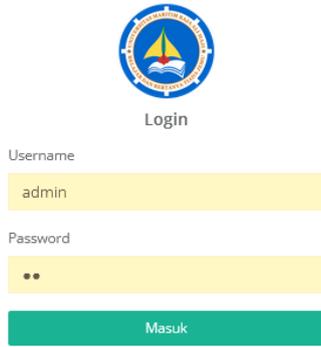


Gambar 3. 3 DFD Level 1

Pada gambar 3.3 DFD Level 1 ini, terdapat 4 proses diantaranya yaitu proses 1.0 *login*, dimana pada proses ini *admin* memasukkan *username* dan *password* agar dapat masuk ke system. Pada proses 2.0 menampilkan data transaksi, pada proses ini system akan menampilkan data transaksi dari *database* data\_obat berupa data transaksi pembelian obat oleh pelanggan. Proses 3.0 proses *Algoritma Fp-Growth* dimana proses ini akan mencari pola keterhubungan atau *association rule* transaksi pada sistem kemudian memasukkan nilai minimum *support* dan nilai minimum *confidence* dari kategori yang kita pilih untuk melihat keterhubungannya dan pada proses ini kita dapat melihat hasil dari keterhubungan dari obat yang di beli pelanggan tersebut.

### 3.14 Implementasi Sistem

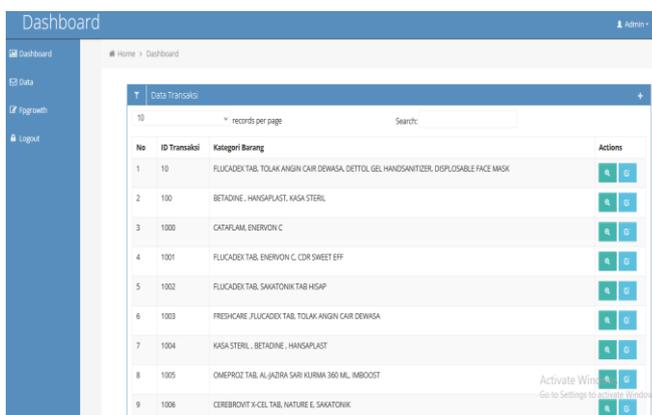
Dibawah ini merupakan implementasi dari perancangan *form* yang dirancang sebelumnya.



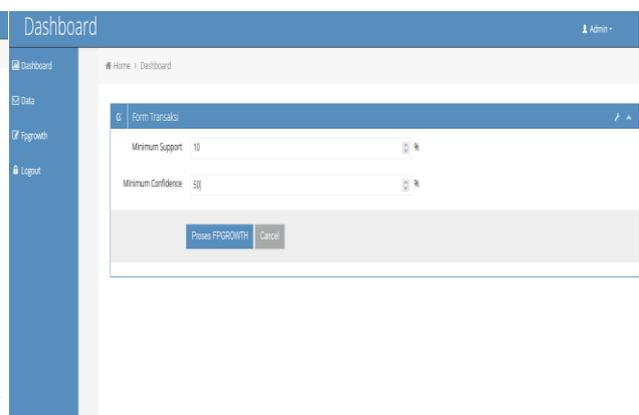
Gambar 3.4 Halaman Login



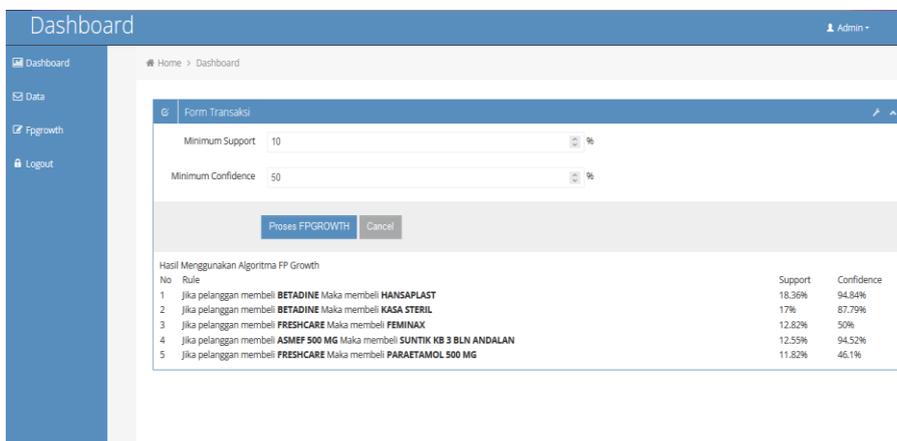
Gambar 3.5 Halaman Beranda



Gambar 3.6 Halaman Data Item



Gambar 3.7 Halaman Perhitungan *Fp-Growth*



Gambar 3.8 Halaman Hasil perhitungan *Fp-Growth*

#### IV. Kesimpulan

Adapun kesimpulan yang dapat diambil dari proses analisa penerapan algoritma *fp-growth* dalam menemukan pola transaksi pembelian obat oleh kosumen pada Apotek Anza Farma, didapatkan nilai *confidence* tertinggi yaitu obat Betadine pasangannya Hansaplast dengan nilai *confidence* 99.51% dan *support* 18.36% disusul dengan nilai *lift* 5.1389, serta nilai *conviction* 15.8034 dan nilai *cosine* 0.97143. Bagi pihak apotek Anza Farma, sistem

rekomendasi produk obat ini berguna untuk meningkatkan penjualan produk mereka. Hasil dari aturan asosiasi ini dapat juga digunakan untuk aplikasi-aplikasi seperti *e-commerce* dan *market place* dalam memberikan informasi kepada pihak konsumen tentang rekomendasi obat yang berkenaan dengan produk obat yang sudah mereka beli.

## V. Daftar Pustaka

- Arisandi, D. , 2016, Analisa Pola Pemilihan Program Studi Bagi Calon Mahasiswa Di Universitas Abdurrab Menggunakan Association Rule, *Rabit : Jurnal Teknologi Dan Sistem Informasi Univrab*, 1(1), 8–12. <https://doi.org/10.36341/rabit.v1i1.8>
- Kadafi, M. , 2019, Penerapan Algoritma FP-GROWTH untuk Menemukan Pola Peminjaman Buku Perpustakaan UIN Raden Fatah Palembang. *Matics*, 10(2), 52. <https://doi.org/10.18860/mat.v10i2.5628>
- Lestari, Y. D. , 2017, Penerapan Data Mining Menggunakan Algoritma Fp-Tree Dan Fp-Growth Pada Data Transaksi Penjualan Obat. *Seminar Nasional Teknologi Informasi dan Komunikasi (SNASTIKOM 2015) ISBN 976-602-19837-9-9*, 60-65.
- Manimaran, J., & Velmurugan, T. , 2015, Analysing the quality of association rules by computing an interestingness measures. *Indian Journal of Science and Technology*, 1-12.
- Setiawan, A., & Anugrah, I. G. , 2019, Penentuan Pola Pembelian Konsumen pada Indomaret GKB Gresik dengan Metode FP-Growth. *Jurnal Nasional Komputasi Dan Teknologi Informasi (JNKTI)*, 2(2), 115. <https://doi.org/10.32672/jnkti.v2i2.1564>