

Penerapan Data Mining untuk Analisa Tingkat Kriminalitas Dengan Algoritma Association Rule Metode FP-Growth

Dwi Winarti, M.Kom¹, Elinda Revita, M.Kom², Efri Yandani S, M.Kom³

Fakultas Ilmu Komputer Universitas Dharmas Indonesia
Jl.Lintas Sumatera KM.18 Koto Baru Dharmasraya
Sumatera Barat

Email: dwiwinarti@undhari.ac.id, revita.elinda.inda@gmail.com, efriyandani@gmail.com

ABSTRAK

Kriminalitas berasal dari kata crime yang artinya sebuah tindakan yang melanggar hukum. Sedangkan pengertian tindak pidana adalah segala tindakan yang disengaja atau tidak, telah terjadi atau baru percobaan, yang dapat merugikan orang lain dalam hal badan, jiwa, harta benda, kehormatan, dan lainnya serta dapat diancam hukuman penjara. Banyaknya golongan atau jenis kejahatan dalam KUHP berarti begitu juga banyaknya kepentingan hukum yang dilindungi oleh hukum pidana. perbuatan pidana itu dapat dilihat pada penjelasan pasal 338 KUHP Kejahatan ini disebutkan makar mati atau pembunuhan dalam peristiwa ini perlu bukti suatu perbuatan yang mengakibatkan kematian orang lain dan kematian disengaja dan tidak disengaja dikenakan pasal 359 KUHP. Data Mining digunakan untuk menemukan pola-pola tersembunyi dan memberikan informasi. Data Mining untuk pendeteksian kejahatan yang sering terjadi secara bersamaan disebut Association Rule (aturan asosiasi).

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

1. PENDAHULUAN

Kriminalitas merupakan tindakan yang bisa merugikan jiwa orang lain dan pelaku itu sendiri. Kejahatan yang dilakukan sangat berdampak pada kehidupan sosial. Tindakan ini bisa menyebabkan seseorang mengalami trauma atau pun hal-hal yang lain. Kejahatan yang dilakukan bisa berupa perjudian, perampokan, pembunuhan, dan lain-lain. Pelaku tindak pidana harus diproses oleh pihak yang berwajib dan dihukum sesuai dengan kejahatan yang dilakukan. Secara hukum, kejahatan didefinisikan sebagai tindakan atau kelalaian yang dilarang oleh hukum yang dapat dihukum dengan pidana penjara dan atau denda. Pembunuhan, perampokan, pencurian, pemerkosaan, mengemudi mabuk, pembuangan anak, dan tidak membayar pajak adalah semua contoh umum kriminalitas.

1.1 Knowledge Discovery in Databases (KDD)

Istilah *Data Mining* dan *knowledge discovery in database* (KDD) sering kali digunakan untuk mencari informasi yang tersembunyi pada sebuah database yang besar. KDD akan membantu untuk mengidentifikasi dan mengamati hal-hal yang ingin diketahui, dan mengolah data menjadi informasi dan berkaitan satu sama lain. Proses KDD salah satunya adalah *Data Mining*. Berikut proses KDD secara garis besar (Ali Ikhwan et al, 2015):

a. *Data Selection*

Pada proses ini dilakukan pemilihan himpunan data, menciptakan himpunan data target, atau memfokuskan pada subset *variable* (sampel data) dimana penemuan (*discovery*) akan dilakukan. Hasil seleksi disimpan dalam suatu berkas yang terpisah dari basis data operasional.

b. *Pre-Processing dan Cleaning Data*

Pre-Processing dan *Cleaning* data dilakukan membuang data yang tidak konsisten dan *noise*, duplikasi data, memperbaiki kesalahan data, dan bisa diperkaya dengan data *eksternal* yang relevan.

c. *Transformation*

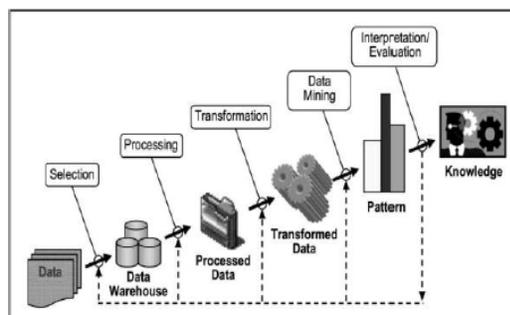
Proses ini *mentransformasikan* atau menggabungkan data ke dalam yang lebih tepat untuk melakukan proses *mining* dengan cara melakukan peringkasan (*agregasi*).

d. *Data Mining*

Proses *Data Mining* yaitu proses mencari pola atau informasi menarik dalam data terpilih dengan menggunakan teknik, metode atau algoritma tertentu sesuai dengan tujuan dari proses KDD secara keseluruhan.

e. *Interpretation / Evaluasi*

Proses untuk menerjemahkan pola-pola yang dihasilkan dari *Data Mining*. Mengevaluasi (menguji) apakah pola atau informasi yang ditemukan bersesuaian atau bertentangan dengan fakta atau hipotesa sebelumnya. Pengetahuan yang diperoleh dari pola-pola yang terbentuk dipresentasikan dalam bentuk visualisasi. Tahapan proses KDD dapat dilihat pada gambar 2.1:



Gambar 2.1 Tahapan dalam KDD

1.2 Data Mining

Aplikasi basis data semakin berkembang dan telah banyak diterapkan diberbagai bidang di antaranya dalam bidang industri, administrasi pemerintah dan dalam bidang lainnya. Sehingga data yang dihasilkan dari bidang-bidang tersebut sangat besar. Dalam hal ini memerlukan teknik pengolahan data, sehingga dari data yang diolah tersebut dapat menghasilkan pengetahuan atau informasi yang berguna bagi masing-masing bidang tersebut. Informasi yang ditemukan ini selanjutnya dapat diaplikasikan untuk aplikasi manajemen, melakukan *query processing*, pengambilan keputusan dan lain sebagainya. *Data*

Mining adalah proses ekstraksi informasi dari kumpulan data melalui penggunaan Algoritma dan teknik yang melibatkan bidang ilmu statistik, mesin pembelajaran, dan sistem manajemen *Database*. *Data Mining* digunakan untuk ekstraksi informasi penting yang tersembunyi dari *dataset* yang besar. Dengan adanya *Data Mining* maka akan didapatkan suatu permata berupa pengetahuan di dalam kumpulan data – data yang banyak jumlahnya (Robi Yanto dan Riri Khoiriah, 2015).

1.3 Association Rules

Association Rule untuk menemukan relasi atau korelasi diantara himpunan item. Dalam teknik ini antara satu *item* dengan *item* lainnya saling berkaitan. Fungsi *Association Rules* seringkali disebut dengan "*market basket analysis*", yang digunakan untuk menemukan relasi atau korelasi diantara himpunan item. *Market Basket Analysis* adalah dari kebiasaan membeli *customer* dengan mencari asosiasi dan korelasi antara item-item berbeda yang diletakkan *customer* dalam keranjang belanjanya. Sebagai contoh di swalayan seorang pelanggan membeli gula bersamaan dengan membeli teh dan roti, dengan pengetahuan tersebut pemilik pasar swalayan dapat mengatur penempatan barangnya atau merancang kampanye pemasaran dengan memakai kupon diskon untuk kombinasi barang tertentu. Analisis asosiasi atau *Association Rule Mining* adalah teknik *Data Mining* untuk menemukan aturan suatu kombinasi *item*. Salah satu tahap analisis asosiasi yang menarik perhatian banyak peneliti untuk menghasilkan Algoritma yang efisien adalah analisis pola frekuensi tinggi (*frequent pattern mining*). Penting tidaknya suatu asosiasi dapat diketahui dengan dua tolok ukur, yaitu : *support* dan *confidence* (Sri Rahayu Siregar, 2014).

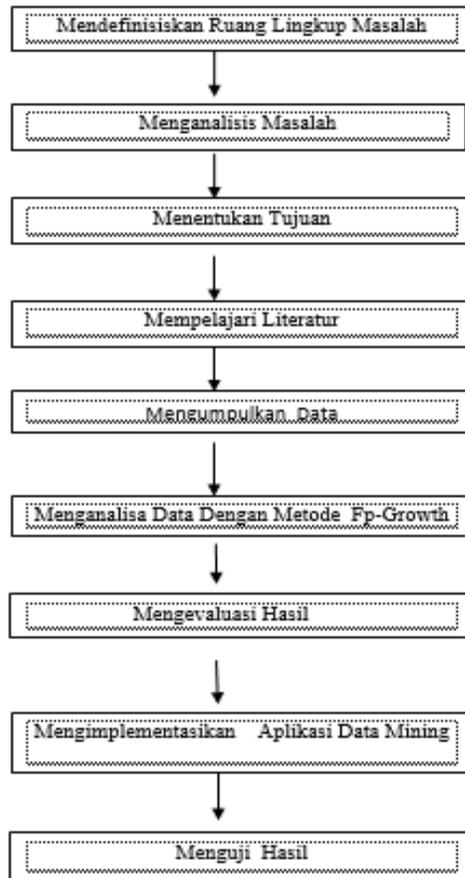
1.4 Algoritma FP-Growth

Sebelum muncul Algoritma *Fp-Growth* merupakan perkembangan dari Algoritma *Apriori*. Algoritma *Apriori* mempunyai banyak kelemahan dan dikembangkan dengan Metode *Fp-Growth*. *Fp-Growth* adalah Algoritma yang dapat menemukan pola yang sering muncul dari sekumpulan data dan struktur data yang digunakan adalah *Fp-Tree* pada Algoritma *Fp-Growth*. Akan tetapi, pada Algoritma *FP-Growth generate candidate* tidak dilakukan karena *FP-Growth* menggunakan konsep pembangunan *tree* dalam pencarian *frequent itemsets*. *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* (Ririanti, 2014).

2. Metodologi Penelitian

2.1 Pendahuluan

Pada bab ini akan diuraikan kerangka kerja penelitian, kerangka kerja ini merupakan langkah-langkah yang akan dilakukan dalam penyelesaian masalah yang akan dibahas. Adapun kerangka kerja penelitian ini dapat dilihat pada gambar 3.1:



Gambar 3.1 Kerangka Kerja Penelitian

Berdasarkan kerangka kerja pada gambar 3.1 maka masing-masing langkahnya dapat diuraikan sebagai berikut:

1. Mendefinisikan Ruang Lingkup Masalah

Ruang lingkup masalah yang akan diteliti harus ditentukan terlebih dahulu, karena mampu menentukan serta mendefinisikan batasan masalah yang akan diteliti, maka tidak akan pernah didapat suatu solusi yang terbaik dari masalah tersebut. Jadi langkah pertama ini merupakan langkah terpenting dalam penulisan ini.

2. Menganalisis Masalah

Pada tahap ini mengumpulkan data yang telah diambil sesuai dengan kasus dan menganalisa data, sehingga akan mendapat gambaran sesuai dengan permasalahan yang dibahas.

3. Menentukan tujuan

Pada tahap ini tujuan dari peneliti untuk menganalisa dan mengetahui tingkat kriminalitas yang sering terjadi pada daerah tertentu. Sehingga dapat dijadikan sebagai acuan untuk pihak polisi untuk meminimalisir tingkat kejahatan.

4. Mempelajari Literatur

Pada tahap ini untuk memperkuat penulis dalam penelitian maka digunakan referensi dari jurnal-jurnal ilmiah, buku, *tutorial* tentang penggunaan Aplikasi *Data Mining* untuk mempermudah proses penelitian.

5. Mengumpulkan Data

Pada tahap ini peneliti mengumpulkan data Kriminal yang diperoleh dari kantor Polsek Rimbo Ilir jenis data *primer* yaitu data-data laporan kejahatan yang terdapat di Polsek Rimbo Ilir. Serta melakukan observasi lapangan yang terkait dengan tindakan Kriminal. Dalam pengumpulan ada beberapa tahap yaitu:

a. Diskusi atau Wawancara

Pada tahap ini akan dilakukan wawancara kepada pihak yang terkait khususnya kepada pegawai yang terdapat di Polsek tersebut.

b. Penelitian Laboratorium (*Laboratory Research*)

Pada tahap ini dimaksudkan untuk melakukan pengujian terhadap penerapan *Data Mining* dengan menggunakan Algoritma *Association Rule* metode *Fp-Growth*. Pada penelitian Laboratorium ini peneliti tidak terlepas dari piranti atau perangkat yang digunakan, perangkat ini dapat digunakan untuk membantu penulis melakukan pengujian.

6. Menganalisa Data dengan Menggunakan *Fp-Growth*

Pada tahap ini peneliti akan menganalisis data yang sudah didapat. Analisis dengan menggunakan *rule* asosiasi untuk mendapatkan nilai *support* dan *confidence*. Nilai yang akan diambil adalah nilai *support* yang lebih besar dari minimum *support* dan nilai *confidence* yang besar. Salah satu teknik yang digunakan adalah *Fp-Growth* metode ini lebih efisien dari *Apriori*, *Fp-Growth* akan menghasilkan *frequent Itemset* tanpa harus melakukan *candidates generation*. Dengan penggunaan Algoritma ini diharapkan akan menghasilkan *rules* dari pola kombinasi *Itemset* yang *interesting*, sehingga dapat diketahui tingkat Kriminalitas yang sering dilakukan.

7. Mengevaluasi Hasil

Pada tahap ini dilakukan evaluasi terhadap *rule-rule frequent* yang diperoleh dari hasil pengolahan *Data Mining*. Selanjutnya *rule* tersebut dipilih secara acak untuk diuji atau dipilih rasionya dengan menggunakan alat ukur yang bernama *confidence rasio* dengan rumus :

$$Confidance=P(B|A) = \frac{\text{Jumlah Transaksi Mengandung A dan B}}{\text{Jumlah Transaksi mengandung A}} \quad (4)$$

Dengan rumus tersebut dapat diperoleh hasil seberapa besar kemungkinan kejahatan yang sering muncul.

8. Mengimplementasikan Aplikasi *Data Mining*

Pada tahap ini dilakukan implementasi terhadap *Knowledge* yang dihasilkan pada tahap sebelumnya untuk memastikan bahwa Aplikasi yang dikembangkan bebas dari kesalahan, maka

akan dilakukan *testing* (uji coba) pada Aplikasi tersebut. Implementasi dilakukan dengan menggunakan Aplikasi *Data Mining Rapid Miner* yang mencakup uji coba pada hasil *Data Mining*. Pada tahap ini juga akan dilakukan evaluasi terhadap hasil penelitian. Evaluasi dilakukan mencakup hasil dan manfaat.

9. Menguji Hasil

Pada tahap ini akan dibandingkan hasil yang diolah dengan cara perhitungan manual dan diolah menggunakan *tools Rapid Miner 5.3*. Tahap pengujian ini meliputi:

1. *Rules* yang sudah didapatkan akan diuji kembali menggunakan sistem data dengan pengujian sistem *Rapid Miner 5.3*.
2. Pada awalnya data Kriminal di transformasikan ke dalam *Microsoft Excel*, kemudian data Kriminal akan *diimportkan* ke *Microsoft Excel* dari data tersebut akan diperoleh dan dijadikan sebagai data tabel transaksi frekuensi *item* pada *Rapid Miner*.
3. Algoritma *Association Rule* digunakan untuk menemukan aturan asosiatif antara satu kombinasi *item* ke kombinasi item lainnya. Algoritma *Fp-Growth* akan melengkapi proses dalam menentukan *minimum support* dan syarat *minimum* dalam menentukan *confidence* dan akan terbentuk hasil yang berupa *Fp-Tree* dan *rule-rule* akan terlihat jelas. Hasil dari *rule-rule* tersebut sebagai *ekstrak* dari data yang diolah berupa pengetahuan baru (*Knowledge*) yang akan memberikan acuan dalam menganalisa tingkat kejahatan .

3. HASIL DAN PEMBAHASAN

3.1 Analisa Data

Algoritma *Fp-Growth* adalah Algoritma yang digunakan untuk menentukan pola yang sering muncul. Dibandingkan dengan Algoritma Apriori Algoritma *Fp-growth* ini memberikan alternatif yang lebih cepat dalam menentukan itemset yang sering muncul. Pencarian frequent itemset dilakukan dengan cara membangkitkan struktur data tree atau disebut dengan *Fp-Tree*. Metode *Fp-Growth* dapat dibagi menjadi tiga langkah yaitu sebagai:

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

Ketiga tahap tersebut merupakan langkah yang akan dilakukan untuk mendapat frequent itemset.

Input : *FP-Tree Tree*

Output : Rt Sekumpulan lengkap pola frequent

Methode : *FP-Growth (Tree, null)*

Procedure : *FP-Growth (Tree, α)*

```

{
01: if Tree mengandung single path P;
02: then untuk tiap kombinasi (dinotasikan  $\beta$ ) dari node-node dalam path do
03: bangkitkan pola  $\beta \alpha$  dengan support dari node-node dalam path do  $\beta$ ;
04: else untuk tiap  $a_1$  dalam header dari tree do
}
05: bangkitkan pola
06: bangun  $\beta = a_1 \alpha$  dengan support =  $a_1$  support
07: if Tree  $\beta =$ 

```

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. Langkah ini sangat berpengaruh untuk langkah selanjutnya dalam menentukan rule asosiasinya.

3.2 Sumber Data

Sumber data yang digunakan masih merupakan data mentah yang belum diolah dan merupakan data kriminal yang mencangkup laporan kejahatan di Polsek Rimbo Ilir Kabupaten Tebo data yang dicatat dan diambil memiliki atribut jenis kelamin, umur, pekerjaan, dan jenis kejahatan. Contoh uji coba dari data kriminal seperti pada tabel 4.1:

Tabel 4.1. Data Kriminal

No	Nama	JKL	Umur	Pekerjaan	Jenis Kejahatan
1	Karnita	PR(A2)	Remaja(B1)	Ex mahasiswa(C1)	Penganiayaan
2	Adi Septiono	Lk(A1)	Dewasa(B2)	Petani(C3)	perjudian
3	Zaini Hasan	Lk(A1)	Paruh Baya(B3)	karyawan (C4)	Pencurian
4	Bambang Suseno	Lk(A1)	paruh Baya	Petani	pembunuhan
5	Ripan	lk(A1)	Dewasa	Petani	pencurian
6	Fatimah	Pr(A2)	Dewasa	Honorer(C2)	Pencurian
7	Mustari	Lk(A1)	Dewasa	Petani	pencurian
8	Sutarmin	Lk(A1)	Paruh Baya	Petani	penculikan
9	PTN VI RIMBO				Pencurian
10	Yarlina	Pr(A2)	Dewasa	Petani	pencurian
11	Purwanti	Pr(A2)	Paruh Baya	Petani	Pencurian
12	Sarbaini	Lk(A1)	Dewasa	Petani	Pencurian
13	Adismanto	Lk(A1)	Dewasa	Petani	Pencurian
14	Sayuti Gustiranda	Lk(A1)	Dewasa	Swasta	Penipuan
15	Mirdawati	Pr(A2)	Dewasa	Tani	Pencurian
16	Jamin	lk(A1)	Tua(B4)	Tani	Penipuan/pengeleparan
17	Abdurrahman	Lk(A1)	Paruh Baya	Wiraswasta(C5)	Pencurian
18	JASMIDI	Lk(A1)	Paruh Baya	Tani	pengeleparan
19	Suharno	Lk(A1)	Paruh Baya	Tani	Pencurian
20	Arpan	Lk(A1)	Paruh Baya	Tani	pengancaman
21	Pit Restu Nugroho	Lk(A1)	Dewasa	Wiraswasta	pengeleparan
22	Ade Chandra kurniawan	Lk(A1)	Dewasa	karyawan	Pencurian dengan KEKERASAN
23	Muzir Efendi	Lk(A1)	Paruh Baya	Wiraswasta	pengeleparan
24	Sutono	Lk(A1)	Paruh Baya	Tani	Pencurian dengan Pemberatan
25	Sudarman	Lk(A1)	dewasa	Tani	Pencurian

3.3 4.2.1 Pengkodean Data

Data yang sudah didapatkan belum bisa langsung diolah, data yang sudah dikumpulkan *di-transformasikan* dan diberikan kode agar mudah dalam pemrosesan atau pengolahan *Data Mining*. *Atribut* yang dipakai adalah jenis, kelamin, umur, pekerjaan, dan jenis kejahatan. Seperti pada Tabel 4.2:

Tabel 4.2 Hasil Transformasi Data Kriminal

NO	ITEM
1	A1, B2, C3, D3
2	A1, B3, C4, D2
3	A1, B3, C3, D4
4	A1, B2, C3, D2
5	A1, B2, C3, D2
6	A1, B3, C3, D5
7	A1, B2, C4, D2
8	A1, B2, C3, D2
9	A1, B2, C3, D2
10	A1, B2, C5, D6
11	A1, B4, C3, D6
12	A1, B3, C5, D2
13	A1, B3, C3, D6
14	A1, B3, C3, D2
15	A1, B3, C3, D7
16	A1, B2, C5, D6
17	A1, B2, C4, D2
18	A1, B3, C5, D6,
19	A1, B3, C3, D2,
20	A1, B2, C3, D2
21	A2, B1, C1, D1
22	A2, B2, C2, D2
23	A2, B2, C3, D2
24	A2, B3, C3, D2
25	A2, B2, C3, D2

Langkah selanjutnya menghitung frekuensi dan nilai *support* untuk Mencari *Frequent itemset*, maka diambil dari nilai yang sering muncul dan menentukan minimum *supportnya*. Dari item yang terpilih akan terlihat nilai yang paling besar yang bisa dijadikan *support* dan jika tidak memenuhi nilai *support* maka akan dieliminasi. Tabel 4.2 merupakan hasil transformasi dari atribut yang ada pada data mentah.

Tabel 4.3 Frekuensi Kemunculan

Item	Frekuensi
A1	20
C3	16
D2	15
B2	12
B3	10
A2	5
C5	4
D6	3
C4	3
D3	2
D5	2
B4	1
C1	1
C2	1
D1	1
D4	1
B1	1
D7	1

Sehingga hasilnya dapat dilihat pada tabel 4.4:

Tabel 4.4 Tabel *Support*

Item	Frekuensi	Support
A1	20	0,8
C3	16	0,64
D2	15	0,6
B2	12	0,48
B3	10	0,4
A2	5	0,2
C5	4	0,16
D6	3	0,12
C4	3	0,12
D3	2	0,08
D5	2	0,08
B4	1	0,04
C1	1	0,04
C2	1	0,04
D1	1	0,04
D4	1	0,04
B1	1	0,04
D7	1	0,04

Pada tabel 4.4 akan dilihat nilai *Support* yang terpilih dan akan dijadikan *item* untuk proses *FP-Growth*.

4.2.2 Proses Data Mining *FP-Growth*

Penelusuran *database* yang pertama digunakan untuk menghitung nilai *support* dari masing-masing *item* dan memiliki *item* yang memenuhi nilai minimum *support*. Dalam kasus ini peneliti menggunakan nilai minimum *support* yaitu 30%. Setelah diperoleh *frequent list* hapus *item* yang tidak memenuhi minimum *support* 30% frekuensi kemunculan dapat dilihat pada tabel Tabel 4.3:

Tabel 4.5 Frekuensi Kemunculan

Item	Frekuensi
A1	20
C3	16
D2	15
B2	12
B3	10

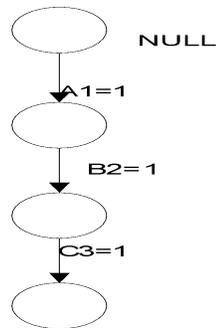
Kemudian urutkan item pada tiap transaksi berdasarkan frekuensi paling tinggi dan terbentuk *item* yang terdiri dari 25 *set* dapat dilihat pada tabel 4.6

Tabel 4.6 Item Yang Terbentuk

TID	Item
1	A1, B2, C3
2	A1, B3, D2
3	A1, B3, C3
4	A1, B2, C3, D2
5	A1, B2, C3, D2
6	A1, B3, C3
7	A1, B2, D2
8	A1, B2, C3, D2
9	A1, B2, C3, D2
10	A1, B2
11	A1, C3
12	A1, B3, D2
13	A1, B3, C3
14	A1, B3, C3, D2
15	A1, B3, C3
16	A1, B2
17	A1, B2, D2
18	A1
19	A1, B3, C3, D2
20	A1, B2, C3, D2
21	
22	B2, D2
23	B2, C3, D2
24	B3, C3, D2
25	B3, C3, D2

Dari tabel 4.5 akan dibentuk pohon *conditional Fp-Tree* langkah selanjutnya adalah membentuk pohon *FP-Tree*:

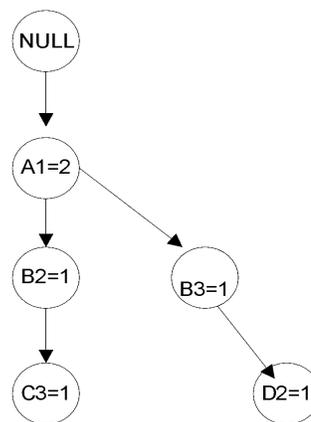
Gambar 4.1 memberikan ilustrasi mengenai pembentukan *FP-tree* setelah pembacaan TID 1:



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

Gambar 4.1 adalah penjelasan tentang pembentukan *Fp-Tree* setelah pembacaan didapat setelah melakukan TID 1 yaitu berisi Null-A1=1 (Laki-laki), B2=1 (dewasa), C3=1(Petani), D2=1(Pencurian).

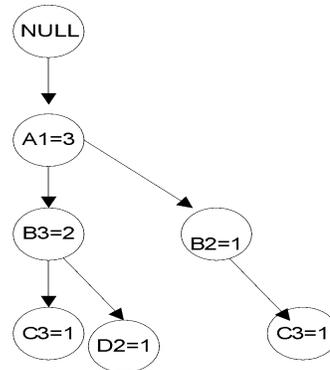
Pembentukan *Fp-Tree* untuk pembacaan TID 2 pada gambar 4.2:



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

Gambar 4.2 adalah penjelasan tentang pembentukan *Fp-Tree* setelah pembacaan didapat setelah melakukan TID 2 yaitu berisi Null-A1=2 (Laki-laki), D2=1(Pencurian).

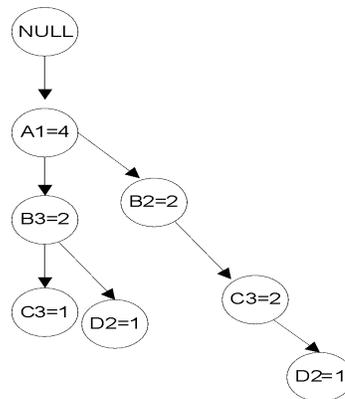
Pembentukan *Fp-Tree* untuk pembacaan TID 3 pada gambar 4.3:



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

Gambar 4.3 adalah penjelasan tentang pembentukan *Fp-Tree* setelah pembacaan didapat setelah melakukan TID 3 yaitu berisi Null-A1=3 (Laki-laki), C3=1(Petani).

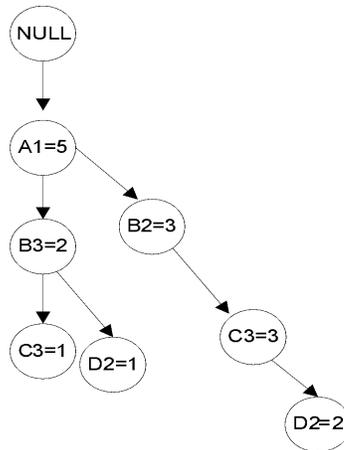
Pembentukan *Fp-Tree* untuk pembacaan TID 4 pada gambar 4.3:



Gambar 4.4: Hasil Pembentukan *FP-tree* Setelah Pembacaan TID 4

Gambar 4.4 adalah penjelasan tentang pembentukan *Fp-Tree* setelah pembacaan didapat setelah melakukan TID 4 yaitu berisi Null-A1=4 (Laki-laki), B2=2(Dewasa), C3=2(Petani), D2(pencurian)=2.

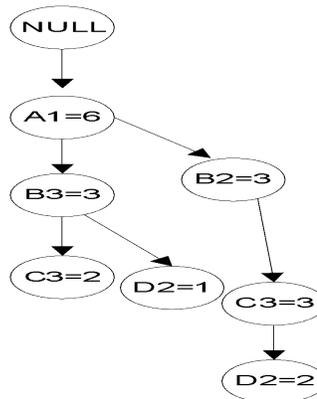
Pembentukan *Fp-Tree* untuk pembacaan TID 5 pada gambar 4.5:



Gambar 4.5: Hasil Pembentukan *FP-tree* Setelah Pembacaan TID 5

Gambar 4.5 adalah penjelasan tentang pembentukan *FP-Tree* setelah pembacaan didapat setelah melakukan TID 5 yaitu berisi Null-A1=5 (Laki-laki), B2=3(Dewasa), C3=3(Petani), D2(pencurian)=3.

Pembentukan *FP-Tree* untuk pembacaan TID 6 pada gambar 4.6:



Gambar 4.6: Hasil Pembentukan *FP-tree* Setelah Pembacaan TID 6

5. KESIMPULAN

Dari hasil penelitian yang diuraikan dari bab 1 sampai bab v maka dapat ditarik suatu kesimpulan:

1. Penggunaan *Algoritma Fp-Growth* ini dapat mempermudah dalam pencarian *frequent itemset* karena menggunakan *Fp-Tree*. Sehingga dapat menghasilkan pola yang sering muncul berdasarkan keempat *variabel* yaitu dapat dilihat dari jenis kelamin, umur, pekerjaan dan kasus .
2. Dari semua data jika tidak memenuhi *minimum support* maka akan otomatis tereliminasi dan tidak diikuti dalam proses selanjutnya. Hanya *variabel* yang akan menjadi kandidat untuk proses selanjutnya .
3. Dari nilai *confidence* dan *support* yang diberikan bahwa yang melaporkan tindak kriminal rata-rata jenis kelamin laki-laki, berumur dewasa dan berprofesi sebagai petani kasus yang sering dilaporkan adalah kasus pencurian.
4. *Algoritma Fp-Growth* dapat digunakan untuk mengetahui tingkat kejahatan yang sering muncul sehingga berguna untuk pihak berwajib bahwa tingkat kriminalitas yang sering terjadi di wilayah tersebut adalah pencurian karena memiliki nilai presentase yang tinggi.
5. Progam *Rapid Miner* suatu *tools* yang mampu mengolah data yang besar sehingga dapat menghasilkan *rules* dan *itemset* yang relevan.

Daftar Pustaka

- [1] Abdullah Saad Almalaise Alghamdi “Efficient Implementation of FP Growth Algorithm-Data Mining on Medical Data”.
- [2] Ali Ikhwan dkk “ Penerapan Data Mining dengan Algoritma Fp-Growth untuk Mendukung Strategi Promosi Pendidikan” (Studi Kasus Kampus STMIK Triguna Dharma), 2015.
- [3] Bhavesh V, and Dr.Chirag Thaker “FP Growth Algorithm for finding patterns in Semantic Web”.
- [4] Budanis Dwi Meilani dan Azmuri Wahyu Azinar “Penentuan Pola Yang Sering Muncul Untuk Penerima Kartu Jaminan Kesehatan Masyarakat (JAMKESMAS) Menggunakan Metode Fp-Growth. IDeaTech 2015.
- [5] Devender Banga and Sunitha Cheepuriseti “ Proxy Driven FP-Growth Based Prefetching.” IJAET, India, 2014.
- [6] Emha Taufiq Luthfi “Penerapan Data Mining Algoritma Asosiasi Untuk Meningkatkan Penjualan” , ISSN: 1411-3201 2009.
- [7] Fadlina“ Data Mining Untuk Analisa Tingkat Kejahatan Jalanan Dengan Algoritma Association Rule Metode Apriori.”Vol 111 no 1 ,Sumatera Barat ” 2014.

[8] Goldie Gunadi dan Dana Indra Sensus “ Penerapan Metode Data Mining Market Basket Analysis Terhadap Data Penjualan Produk Baru Dengan Menggunakan Algoritma Apriori dan Frequent Pattern Growth (FP-Growth).” *Telematika* Vol.4 No.1, 2012.

[9] Kusriani dan Luthfi, E. T., 2009. *Algoritma Data Mining*. Yogyakarta : Penerbit Andi.

[10] Ririanti “ Implementasi Algoritma FP-Growth Pada Aplikasi Prediksi Persediaan Sepeda Motor .” *PIBD* Vol.VI No.1, 2014.

[11] Sri Rahayu Siregar Implementasi Data Mining Pada Penjualan Tiket Pesawat Menggunakan Algoritma Apriori .” *PIBD* Vol.VII No.1, 2014.