

## Implementasi Data Mining Untuk Analisa Tingkat Pelanggaran Lalu Lintas Dengan Algoritma Association Rule

**Yera Wahda Wahdi**

UNIVERSITAS PUTERA BATAM

e-mail : [Yerawahdawahdi@yahoo.com](mailto:Yerawahdawahdi@yahoo.com)

**Abstract:** Kepolisian berkaitan dengan fungsinya sebagai pengayom masyarakat diharapkan mampu mengambil tindakan dalam menyikapi pelanggaran lalu lintas dengan melakukan operasi razia dalam mengungkap pelanggaran yang dapat dilakukan dengan menggunakan teknik analisis dari kebiasaan seberapa sering pelanggaran lalu lintas dilakukan. Pendeteksian pelanggaran lalu lintas yang sering terjadi secara bersamaan disebut *Association Rule*.

**Kata Kunci :** Data Mining, FP-Growth

### 1. PENDAHULUAN

#### 1.1 Latar Belakang Masalah

Pelanggaran lalu lintas sudah membudaya di masyarakat, tidak tekecuali terjadi di wilayah Kota Padang. Dengan statusnya sebagai ibukota provinsi dan kota besar yang memiliki tingkat kepadatan penduduk paling tinggi di Provinsi Sumatera Barat, tentunya menjadikan Kota Padang sebagai Kota yang mempunyai tingkat kepadatan kendaraan bermotor paling tinggi jika dibandingkan dengan wilayah lainnya. Kota Padang merupakan salah satu kota besar yang memiliki data jumlah kecelakaan terbesar terbukti dari data tahun 2012 hingga 2013, Kota Padang berada diposisi peringkat pertama kasus kecelakaan terbanyak di Provinsi Sumatera Barat. Pada tahun 2012 , di Kota Padang tercatat 540 kasus kecelakaan, dengan rincian 80 korban meninggal dunia [1].

Kepolisian berkaitan dengan fungsinya sebagai pengayom masyarakat diharapkan mampu mengambil tindakan dalam menyikapi pelanggaran lalu lintas dengan melakukan operasi razia dalam mengungkap pelanggaran yang dapat dilakukan dengan menggunakan teknik analisis dari kebiasaan seberapa sering pelanggaran lalu lintas dilakukan. Pendeteksian pelanggaran lalu lintas yang sering terjadi secara bersamaan disebut *Association Rule*.

Analisis asosiasi dikenal juga sebagai salah satu teknik data mining yang menjadi dasar dari berbagai teknik data

mining lainnya. Khususnya salah satu tahap dari analisis asosiasi yang disebut analisis pola frekuensi tinggi (*frequent pattern mining*) menarik perhatian banyak peneliti untuk menghasilkan algoritma yang efisien. Penting tidaknya suatu aturan asosiatif dapat diketahui dengan dua parameter, *support* (nilai penunjang) yaitu persentase kombinasi item tersebut dalam database dan *confidence* [2].

Dalam penelitian ini, algoritma yang digunakan adalah *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)* [3].

#### 1.2 Perumusan Masalah

Berdasarkan latar belakang yang diuraikan, maka terdapat beberapa hal yang menjadi permasalahan penelitian, yaitu :

1. Bagaimana menerapkan teknik *Association Rule* pada data pelanggaran lalu lintas hingga diketahui pola hubungannya dengan pengguna jalan ?
2. Bagaimana menganalisa tingkat pelanggaran lalu lintas dengan menggunakan *Data Mining Association Rule* untuk melihat jenis kesalahan?
3. Bagaimana menguji pola yang telah ditemukan dengan

memanfaatkan *software* aplikasi yang menerapkan teknik *Data Mining* aturan asosiasi dengan algoritma Apriori?

### 1.3 Batasan Masalah

Agar lebih jelas dan terarah serta tidak terjadinya banyak masalah yang akan timbul, maka penulis hanya akan memberikan batasan-batasan sebagai berikut :

1. Tools yang digunakan adalah RapidMiner
2. Penelitian dilakukan pada POLRESTA Padang  
Menggunakan *Data Mining Association Rule* untuk menghasilkan rules dan Algoritma FP-Growth untuk menemukan pola kombinasi *itemset*.

### 1.4 Tujuan Penelitian

Dalam melakukan penelitian ini ada beberapa tujuan yang ingin dicapai oleh penulis yaitu :

1. Untuk mengetahui bentuk-bentuk pelanggaran lalu lintas yang terjadi di wilayah POLRESTA Padang dan mengetahui kewenangan aparat kepolisian dalam penyidikan tindak pidana pelanggaran lalu lintas
2. Menganalisa pelanggaran lalu lintas di polresta padang dengan menggunakan *Association Rule*
3. Merancang metode *Association Rule* untuk penanganan pelanggaran lalu lintas sehingga dapat meningkatkan efektifitas dan efesiensi kinerja kepolisian.
4. Membangun suatu pengetahuan baru dalam menganalisa tingkat pelanggaran lalu lintas sehingga dapat meningkatkan kesadaran dan ketertiban pengguna jalan.
5. Menguji data pelanggaran lalu lintas dengan menggunakan Tools RapidMiner. sehingga informasi ini dapat membantu kepolisian dalam mengatasi tingkat pelanggaran lalu lintas.

## 2. LANDASAN TEORI

Landasan teori merupakan panduan untuk membahas tentang teori pemecahan masalah yang dihadapi. Dalam hal ini akan dikemukakan beberapa teori yang berhubungan dengan masalah yang dibahas dalam penelitian ini.

Teori-teori yang menjadi landasan dalam penulisan tesis ini antara lain teori Data Mining, Algoritma FP-Growth dengan aturan asosiasi.

### 2.1 Data Mining

*Data mining* merupakan penemuan informasi baru dengan mencari pola atau aturan tertentu dari sejumlah data yang sangat besar [4]. *Data mining* atau sering disebut sebagai *knowledge discovery in database* (KDD) adalah kegiatan yang meliputi pengumpulan, pemakaian data historis untuk menemukan keteraturan, pola atau hubungan dalam data berukuran besar. Keluaran *data mining* ini bisa dipakai untuk membantu pengambilan keputusan di masa depan. Pengembangan KDD ini menyebabkan penggunaan *pattern recognition* semakin berkurang karena telah menjadi bagian data mining [5].

### 2.2 Pengelompokan Data Mining

Goldie Gunadi dan Dana Indra Sensuse (2012) menyatakan bahwa menurut Larose dalam bukunya yang berjudul "*Discovering Knowledge in Data: An Introduction to Data Mining*", *Data Mining* dibagi menjadi beberapa kelompok berdasarkan tugas/pekerjaan yang dapat dilakukan, yaitu :

1. Deskripsi  
Terkadang peneliti dan analisis secara sederhana ingin mencoba mencari cara untuk menggambarkan pola dan kecenderungan yang terdapat dalam data. Deskripsi dari pola kecenderungan sering memberikan kemungkinan penjelasan untuk suatu pola atau kecenderungan.
2. Estimasi  
Estimasi hampir sama dengan klasifikasi, kecuali variabel target estimasi lebih ke arah numerik dari pada ke arah kategori. Model dibangun menggunakan baris data (*record*) lengkap yang menyediakan nilai dari variabel target sebagai nilai prediksi. Selanjutnya, pada peninjauan berikutnya estimasi nilai dari variabel target dibuat berdasarkan nilai variabel prediksi.
3. Prediksi  
Prediksi hampir sama dengan klasifikasi dan estimasi, kecuali bahwa dalam prediksi nilai dari hasil akan ada

di masa mendatang. Beberapa metode dan teknik yang digunakan dalam klasifikasi dan estimasi dapat pula digunakan (untuk keadaan yang tepat) untuk prediksi.

#### 4. Klasifikasi

Dalam klasifikasi, terdapat target variabel kategori. Sebagai contoh, penggolongan pendapatan dapat dipisahkan dalam tiga kategori, yaitu pendapatan tinggi, pendapatan sedang, dan pendapatan rendah.

#### 5. Pengklasteran (*Clusterring*)

Pengklasteran merupakan pengelompokan *record*, pengamatan, atau memperhatikan dan membentuk kelas obyek-obyek yang memiliki kemiripan. Klaster adalah kumpulan *record* yang memiliki kemiripan satu dengan yang lainnya dan memiliki ketidakmiripan *record* dalam klaster yang lain. Berbeda dengan klasifikasi, pada pengklasteran tidak ada variabel target. Pengklasteran tidak melakukan klasifikasi, mengestimasi, atau memprediksi nilai dari variabel target, akan tetapi, algoritma pengklasteran mencoba untuk melakukan pembagian terhadap keseluruhan data menjadi kelompok-kelompok yang memiliki kemiripan (homogen), yang mana kemiripan *record* dalam satu kelompok akan bernilai maksimal, sedangkan kemiripan dengan *record* dalam kelompok lain akan bernilai minimal.

#### 6. Asosiasi

Tugas asosiasi dalam *Data Mining* adalah untuk menemukan atribut yang muncul dalam satu waktu. Salah satu implementasi dari asosiasi adalah *market basket analysis* atau analisis keranjang belanja, sebagaimana yang akan dibahas dalam penelitian ini.

### 2.3 Association Rule

Analisis asosiasi atau *association rule mining* adalah teknik data mining untuk menemukan aturan asosiatif 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 [6].

### 2.4 Tahapan Association Rules

Analisis asosiasi dikenal juga sebagai salah satu teknik data mining yang menjadi dasar dari berbagai teknik data mining lainnya. Khususnya salah satu tahap dari analisis asosiasi yang disebut analisis pola frekuensi tinggi (*frequent pattern mining*) menarik perhatian banyak peneliti untuk menghasilkan algoritma yang efisien. Penting tidaknya suatu aturan asosiatif dapat diketahui dengan dua parameter, *support* (nilai penunjang) yaitu persentase kombinasi item tersebut dalam database dan *confidence* [7].

#### A. Data Preparation.

Pada banyak bidang keilmuan, terutama komputer sains, diperlukan data yang berkualitas melalui proses *preparation* dari data mentah. Dalam prakteknya, ditemukan bahwa data *cleaning* dan *preparation* membutuhkan total usaha 80% dari usaha untuk merekayasa data, sehingga menjadikan data *preparation* sebagai proses yang krusial. Pentingnya proses ini dapat dilihat dari tiga aspek, yakni:

1. Data *real world* merupakan data kotor. Data *real world* bisa mengandung data yang tidak, terdapat *noise*, tidak konsisten, yang dikarenakan:
  - a. Tidak lengkap (*incomplete*), yaitu kekurangan nilai atribut atau hanya mengandung agregat data (contoh : address = " ")
  - b. *Noise*, yaitu masih mengandung *error* dan *outliers*.
  - c. Tidak konsisten (*inconsistent*), yaitu data yang mengandung discrepansi dalam code dan nama atau singkatnya datanya tidak konsisten.
2. Sistem *mining* dengan performa tinggi membutuhkan data yang berkualitas. Data *preparation* atau *preparation* menghasilkan dataset yang lebih sedikit daripada dataset

yang asli, ini bias meningkatkan efisiensi dari data mining. Langkah ini mengandung:

- a. Memilih data yang relevan
  - b. Mengurangi data
3. Data yang berkualitas menghasilkan pola yang berkualitas. Dengan data *preparation*, maka data yang dihasilkan adalah data yang berkualitas, yang mengarah pada pola yang berkualitas pula dengan:
- a. Mengembalikan data yang tidak lengkap
  - b. membenarkan eror, atau menghilangkan *outliers*
  - c. Membenahi data yang bertentangan.

### 2.5 Algoritma FP-Growth

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 (David, 2008). Algoritma FP-Growth merupakan pengembangan dari algoritma Apriori. Sehingga kekurangan dari algoritma Apriori diperbaiki oleh algoritma FP-Growth [8].

FP-Growth menggunakan konsep pembangunan tree dalam pencarian frequent itemsets. Hal tersebutlah yang menyebabkan algoritma FP-Growth lebih cepat dari algoritma Apriori. 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.

FP-tree merupakan struktur penyimpanan data yang dimampatkan. FP-tree dibangun dengan memetakan setiap data transaksi ke dalam setiap lintasan tertentu dalam FP-tree. Karena dalam setiap transaksi yang dipetakan, mungkin ada transaksi yang memiliki item yang sama, maka lintasannya memungkinkan untuk saling menimpa. Semakin banyak data transaksi yang memiliki item yang sama, maka proses pemampatan dengan struktur data FP-tree semakin efektif. Kelebihan dari FP-tree adalah hanya memerlukan dua kali pemindaian data transaksi yang terbukti sangat efisien. Misal  $I = \{a_1, a_2, \dots, a_n\}$

adalah kumpulan dari item. Dan basis data transaksi  $DB = \{T_1, T_2, \dots, T_n\}$ , di mana  $T_i$  ( $i \in [1..n]$ ) adalah sekumpulan transaksi yang mengandung item di  $I$ . Sedangkan *support* adalah penghitung (*counter*) frekuensi kemunculan transaksi yang mengandung suatu pola. Suatu pola dikatakan sering muncul (*frequent pattern*) apabila *support* dari pola tersebut tidak kurang dari suatu konstanta  $\epsilon$  (batas ambang minimum *support*) yang telah didefinisikan sebelumnya. Permasalahan mencari pola frequent dengan batas ambang minimum *support count*  $\epsilon$  inilah yang dicoba untuk dipecahkan oleh FP-Growth dengan bantuan Struktur FP-tree.

Penggalan itemset yang frequent dengan menggunakan algoritma FP-Growth akan dilakukan dengan cara membangkitkan struktur data tree (FP-Tree). Metode FP-Growth dapat dibagi menjadi 3 tahapan utama yaitu sebagai berikut [9]:

1. Tahap Pembangkitan conditional pattern base  
*Conditional Pattern Base* merupakan subdatabase yang berisi *prefix path* (lintasan prefix) dan *suffix pattern* (pola akhiran). Pembangkitan *conditional pattern base* didapatkan melalui FP-tree yang telah dibangun sebelumnya.
2. Tahap pembangkitan conditional FP-Tree  
Pada tahap ini, *support count* dari setiap item pada setiap *conditional pattern base* dijumlahkan, lalu setiap item yang memiliki jumlah *support count* lebih besar sama dengan minimum *support count*  $\epsilon$  akan dibangkitkan dengan *conditional FP-tree*.
3. Tahap pencarian frequent itemset  
Apabila Conditional FP-tree merupakan lintasan tunggal (*single path*), maka didapatkan *frequent itemset* dengan melakukan kombinasi item untuk setiap *conditional FP-tree*. Jika bukan lintasan tunggal, maka dilakukan pembangkitan FP-growth secara rekursif.

Ketiga tahap tersebut merupakan langkah yang akan dilakukan untuk mendapat frequent

itemset, yang dapat dilihat pada algoritma berikut:

Input : *FP-Tree Tree*

Output : Rt sekumpulan lengkap pola frequent

Method : FP-growth (Tree, null)

Procedure : FP-growth (Tree, \_)

```
{
01: if Tree mengandung single path P;
02: then untuk tiap kombinasi (dinotasikan
_) dari node-node dalam path do
03: bangkitkan pola _ _ dengan support
dari
node-node dalam _;
04: else untuk tiap a1 dalam header dari
Tree
do
{
05: bangkitkan pola
06: bangun _ = a1 _ dengan support = a1.
support
07: if Tree _ = _
08: then panggil FP-growth (Tree, _)
} }
```

### 3. ANALISA DAN PEMBAHASAN

#### 3.1 Analisa Data mining dengan Algoritma FP-Growth

Dalam penelitian ini menerapkan *Data Mining* aturan asosiasi dengan algoritma *FP-Growth* dalam menganalisa data pelanggaran lalu lintas di Polresta Padang untuk mendapatkan pola pelanggaran yang terjadi. Pola yang ada menggambarkan sebab dan akibat terjadinya pelanggaran lalu lintas di Polresta.

Pada proses pencarian aturan asosiasi pelanggaran lalu lintas semua itemset yang ada dianggap sebagai input pada *Data Mining*. Seluruh *itemset* diolah menggunakan algoritma *FP-Growth* sehingga terbentuk hubungan asosiasi antar *itemset* dengan memenuhi *minimum support* dan *minimum confidence* untuk menetapkan data yang valid. Data yang dihasilkan dianalisa dengan aturan asosiasi “if” –

“then”. Untuk mencapai semua tahapan tersebut maka langkah pertama yang dilakukan adalah mengumpulkan data. Untuk melakukan penggalian data pelanggaran lalu lintas, penulis menggunakan algoritma *FP-Growth*.


Untuk Frekuensi kemunculan tiap *item* dari data transaksi dapat dilihat pada tabel berikut :

Tid	Itemset	Frekuensi
1	Pelajar	6
2	Karyawan	5
3	Supir	3
4	Mobil	4
5	Motor	7
6	Bus Truck	3
7	SIM	ii
S	STNK	6
9	Perlengkapan	10
10	Rambu-rambu	6

#### 3.2 Pembentukan FP-Tree

TID	Dataset Pelanggaran
1	(a.e <sup>Td</sup> )
2	CMj)
3	
4	
5	(a.e <sup>TU</sup> )
6	(a.d <sup>4i4j</sup> )
7	<t=esl
S	
9	(=fgf)
10	(M4)
11	(a.e <sup>Ji4</sup> )
12	
13	
14	

Dari Tabel diatas, langkah selanjutnya yang harus dilakukan adalah membentuk jalur FP-Tree. Dimana hasil pembentukan jalur 1 sampai 14 dapat dilihat di gambar berikut :



**3.3 Penerapan FP-Growth**

Setelah tahap pembangunan *FP-tree* data pelanggar yang ada, selanjutnya diterapkan algoritma *FP-growth* untuk mencari *frequent itemset*. Algoritma *FP-growth* dibagi menjadi tiga langkah yaitu *Conditional Pattern Base*, *Conditional FP-Tree*, dan *Frequent Itemset*.

*Conditional Pattern Base* merupakan *subdatabase* yang berisi *prefix path* (lintasan prefix) dan *suffix pattern* (pola akhiran). Pembangkitan *conditional pattern base* didapatkan melalui *FP-tree* yang telah dibangun. Dari hasil pembentukan *FP-Tree* sebelumnya maka langkah yang dilakukan adalah membangkitkan *conditional FP-Tree* untuk lintasan yang mengandung *suffix j* sampai *suffix a*

Hasil dari pembangkitan *FP-Tree* maka didapatkan *Conditional Pattern Base*. Hasilnya dapat dilihat pada tabel berikut :

Suffix	Conditional Pattern Base
j	{(i,d,g:1),(i,dJix1),(b,e,ga:1),(b,d:1),M&...}
i	{(a,e,gh:4),(a,dji:1),(b,e,g:2),(b,d:1)...}
h	{(a,c,s:3),(a,d:1),(c,f,g:1)>
S	{(a,e:4),(a,d:1),(b,e:3),(c,f:2)}
f	{(c:2)}
E	{(a:4),(b:3)}
D	{K*:2Hb:2)}

*Support count* dari setiap *item* pada *conditional pattern base* dijumlahkan, lalu *item* yang memiliki jumlah *support count* lebih besar sama dengan minimum *support count %* akan dibangkitkan dengan *conditional FP-tree*.

Suffix	Conditional Pattern Base	Condition al FP-
J		
I	{(a, egJi:4),(a, d3i:1),(b, ^:2),(b, ...}	{(a:5,b:3, ...}
R	{(w3i(a, ±l),(ci5l)}	{(a:2,s:4)}
G	{(a ,e:4),(a ,d: 1 ...}	{(a:2,e:7,f ...}
F	tfc:2)3	
E	{MW>3»	{(a:4,b:3)}
D		{(a:2,b:2)}

Apabila *Conditional FP-tree* merupakan lintasan tunggal, maka didapatkan *frequent itemset* dengan melakukan kombinasi *item* untuk setiap *conditional FP-tree*. Jika bukan lintasan tunggal, maka dilakukan pembangkitan *FP-growth* secara rekursif.

Suffi x	Conditional Pattern Base	Frequent Itemset
J	{(Mg IKxdtoil Id xgjim.d: 1	(dj):3,(gj)>
I	((3,egdi:4Mxd4i:1),(b,eg:2),	(a4):5,(bj)
H		C&h)4
G	{(a,e:4),(a,d:l),(b,e:3),(c,f:2	(<&?)
F	{(<=2)5	
E		(a,e):4,
D	{(a:2),(b:2)J	

selanjutnya menghitung nilai *support* dan *confidence*-nya. Item yang dihitung nilai *support* dan *confidence*-nya yaitu: {d,j}, {g,j}, {a,i}, {b,i}, {g,i}, {h,i}, {g,h}, {e,g}, {a,e}, {b,e}.

$$\text{Support}(A) = \frac{\text{Jumlah Transaksi mengandung A}}{\text{Total Transaksi}}$$

sedangkan nilai *support* dari 2 item diperoleh dari rumus berikut:

$$\text{Support}(A \cap B) = \frac{\text{Jumlah Transaksi mengandung A dan B}}{\text{Total Transaksi}}$$

Menghitung nilai *Confidence* :

$$\text{Confidence} = \frac{\text{Support}(A \cap B)}{\text{Support}(A)}$$

Adapun hasil dari nilai *support* dan nilai *confidence* untuk lebih jelasnya dapat dilihat pada tabel berikut :

Jika Melanggar	Maka Akan Melanggar	Support	Confidence
Mobil	Rambu-rambu	21,43%	75%
Rambu-rambu	Mobil	21,43%	50%
SIM	Rambu-rambu	21,43%	27,27%
Rambu-rambu	SIM	21,43%	50%
Pelajar	Perlengkapan	35,71%	83,33%
Perlengkapan	Pelajar	35,71%	50%
Mobil	Perlengkapan	21,43%	60%
Perlengkapan	Mobil	21,43%	30%
SIM	Perlengkapan	42,86%	54,55%
Perlengkapan	SIM	42,86%	60%
STNK	Perlengkapan	35,71%	83,33%
Perlengkapan	STNK	35,71%	50%
SIM	STNK	28,57%	36,36%
STNK	SIM	28,57%	66,67%
Motor	SIM	50%	100%
SIM	Motor	50%	63,64%
Pelajar	Motor	28,57%	66,67%
Motor	Pelajar	28,57%	37,14%
Karyawan	Motor	21,43%	60%
Motor	Karyawan	21,43%	42,86%

*rule* dapat dilihat pada tabel berikut :

lJbt.Xtelan ggar	Msa Akan Melanggar	Support	Confidence
Pelajar	Parian Ekap	35,71%	83,33%
SIM	Parlanskapan	42,86%	54,55%
STNK	Parian Ekap	35,71%	83,33%
Motor	SIM	50%	100%

Dari *rule* yang dihasilkan diatas, jika item a (pelajar) maka melanggar item i (perlengkapan), jika item g (SIM) maka melanggar item i (Perlengkapan), jika item h (STNK) maka melanggar item (Perlengkapan), jika item e (Motor) maka melanggar item g (SIM).

#### 4. SIMPULAN

Algoritma *FP-Growth* merupakan salah satu metode yang tepat untuk diterapkan pada data pelanggaran lalu lintas karena membantu kepolisian dalam menganalisis pola pelanggaran yang sering dilanggar. Hal ini membantu kepolisian untuk meningkatkan kinerja Kepolisian.

Dari hasil analisis menunjukkan bahwa pelanggaran yang sering dilanggar tersebut tepat sesuai dengan data yang didapat. Hal ini terjadi dikarenakan masih kurangnya kepedulian pengendara untuk mematuhi aturan yang ada.

#### DAFTAR PUSTAKA

- [1] POLRESTA PADANG
- [2] Pramudiono, Iko. 2003. Pengantar Data Mining : Menambang Permata Pengetahuan di Gudang Data. <http://www.ilmukomputer.com>, tanggal akses 24 April 2014.
- [3] Erwin, 2009. Analisis Market Basket Dengan Algoritma Apriori dan FP-Growth. *Jurnal Generic*, vol. 4.
- [4] Irdiansyah, Enur. (2010). "Penerapan Data Mining Pada Penjualan Produk Minuman Di PT. Pepsi Cola Indobeverages Menggunakan Metode Clustering". Bandung. Universitas Komputer Indonesia.
- [5] Subekti Mujiasih (2011). Pemanfaatan Data Mining Untuk Prakiraan Cuaca

- [6] Sani Susanto dan Dedy Suryadi (2010). Pengantar Data Mining. Yogyakarta. Penerbit Andi.97.
- [7] Nugroho Wandu. et all (2012). Pengembangan Sistem Rekomendasi Penelusuran Buku dengan Pengendalian Association Rule Menggunakan Algoritma Apriori (Studi Kasus Badan Perpustakaan dan Kearsipan Provinsi Jawa Timur)
- [8] Kusriani dan Emha Taufiq Luthfi (2009). Algoritma Data Mining. Yogyakarta. Penerbit Andi.3-12.
- [9] R.Agrawal, C. Aggarwal, dan V. V. V. Prasad. "A tree projection algorithm for generation of frequent itemsets". Pada J. Parallel dan Distributed Computing, 2000.