

ANALISIS ASOSIASI PADA TRANSAKSI PENJUALAN DARING MENGUNAKAN ALGORITMA APRIORI DAN FP-GROWTH

Agustinus Cahya Putra¹, Muhammad Habibi²

Program Studi Teknik Informatika
Fakultas Teknik dan Teknologi Informasi
Universitas Jendral Achmad Yani Yogyakarta

agustinuscputra@gmail.com¹, muhammadhabibi17@gmail.com²

Abstrak

Dalam proses bisnisnya, Rumah Warna hanya mengarsipkan data penjualan yang masuk dan tidak mengolahnya sama sekali. Hal ini menyebabkan pihak manajerial kesulitan dalam mengambil keputusan khususnya dalam pengembangan strategi pemasaran untuk penjualan daring. Berdasarkan permasalahan tersebut dalam penelitian ini akan diusulkan dan dilakukan solusi dengan menerapkan data mining guna menemukan informasi strategis dengan menggunakan metode asosiasi dengan algoritma apriori dan frequent pattern growth (fp-growth). Pada proses data mining tahap yang dilakukan adalah data selection, preprocessing, transformasi, data mining dan evaluasi. Pada tahap data mining akan dibagi menjadi dua proses dikarenakan menggunakan dua algoritma yaitu apriori dan fp-growth. Data yang diambil adalah sebanyak 10.230 data transaksi penjualan. Dalam penelitian ini akan mengambil minimum support 10% dan minimum confidence 50%. Kemudian hasilnya akan dibandingkan dan mengambil aturan asosiasi yang terbaik sebagai informasi strategis terbaik. Hasil penelitian ini diperoleh 6 aturan asosiasi yang didapat dari perhitungan algoritma apriori dan fp-growth. Informasi strategis terbaik adalah kombinasi antar item dari perhitungan algoritma apriori dan fp-growth yang memiliki nilai support dan confidence paling tertinggi, yaitu support 43% dan confidence 74% adalah "Jika membeli Tas Selempang maka juga akan membeli Tas Ransel".

Kata Kunci: *data mining, association rule, apriori, fp-growth, pemasaran.*

1. Pendahuluan

Rumah Warna adalah perusahaan yang bergerak dalam bidang *fashion* yang berfokus pada segmen pasar wanita. Produk tas adalah produk utama dari Rumah Warna yang terdiri dari tas ransel, tas selempang, tas anak dan tas cangklong. Sekarang sudah menambah jenis produknya seperti dompet, *softcase laptop* dan bantal. Dalam proses bisnisnya Rumah Warna memasarkan produknya secara luring seperti mengikuti *event*, membuka stan dan sudah merambah ke *franchise*. Dan sekarang Rumah Warna mencoba menjual produknya secara daring agar dapat menjangkau konsumen lebih luas.

Dalam proses bisnis penjualan daring yang dijalankan Rumah Warna bisa dikatakan sudah baik. Mereka sudah membangun *website e-commerce* dengan alamat www.store.rumahwarna.com dan memanfaatkan sosial media. Serta

mempunyai sistem informasi penjualan untuk menginput data penjualan mereka. Namun ketersediaan data penjualan yang besar di Rumah Warna tidak digunakan semaksimal mungkin, sehingga data hanya berfungsi sebagai arsip saja dan tidak dimanfaatkan secara optimal. Ini membuat para pihak manajerial kesulitan dalam mengambil keputusan terkhusus untuk pengembangan strategi pemasaran untuk penjualan daring.

Berdasarkan permasalahan di atas, dalam penelitian ini akan diusulkan dan dilakukan solusi dengan menerapkan data mining menggunakan metode asosiasi dengan algoritma apriori dan FP-Growth. Algoritma Apriori dan FP-Growth membantu untuk menggali/menambang item yang sering digunakan dan yang sering diamati dalam basis data (Setiabudi dkk, 2011). Metode ini dapat dimanfaatkan untuk menggali informasi strategis bagi perusahaan terhadap data-data yang menumpuk. Dalam penelitian ini nantinya hasil dari perhitungan nanti akan dibandingkan dan diharapkan hasil dari data mining ini untuk selanjutnya dapat digunakan sebagai pertimbangan dalam membuat strategi pemasaran dan penjualan yang efektif. Analisis *data mining* ini akan dilakukan dengan menggunakan Aplikasi Weka versi 3-8-2.

Dengan diterapkannya analisis data mining dengan menggunakan dan membandingkan hasil dari 2 algoritma yang nantinya akan didapat informasi strategis yaitu hasil kombinasi antar item yang dapat membantu pihak manajerial dalam mengambil keputusan strategis khususnya untuk strategi pemasaran Rumah Warna guna meningkatkan bisnis perusahaan.

2. Kajian Literatur

2.1 Data Mining

Data mining adalah proses yang menggunakan teknik statistik, matematika, kecerdasan buatan, dan *machine learning* untuk mengekstraksi dan mengidentifikasi informasi yang bermanfaat dan pengetahuan yang terkait dari berbagai basis data besar (Kusrini dan Luthfi, 2010). Dalam melakukan tahap-tahap data mining atau sering disebut dengan *Knowledge Discovery in Database* (KDD) dibagi menjadi beberapa tahap. Tahap-tahap tersebut bersifat interaktif dimana pemakai terlibat langsung atau dengan perantara *knowledge base*. Tahapan-tahapan tersebut, diantaranya (Mabrur dan Lubis, 2012):

1. *Data Selection:*

Data Selection atau Seleksi data yang dilakukan didalam sekelompok data sebelum tahap pencarian informasi dalam KDD dimulai.

2. *Preprocessing / Cleaning:*

Sebelum dilakukannya proses didalam *data mining*, tahap ini diwajibkan untuk melakukan proses pembersihan dengan tujuan menghapus data yang duplikat, mengecek yang tidak konsisten, dan memperbaiki *error* yang ada didalam data, seperti contoh *error* didalam tata huruf. informasi eksternal.

3. *Transformation:*

Tahap ini merupakan tahap dimana akan dilakukan transformasi data yang telah diseleksi, didalam tahap ini proses yang kreatif sangat bergantung pada pencarian pola atau jenis informasi didalam data, sehingga data yang telah mengalami tahap transformasi tersebut sesuai saat digunakan dalam proses *data mining*.

4. *Data mining:*

Salah satu tahap didalam proses *data mining* yaitu menemukan pola atau informasi yang didalam data yang telah terseleksi. Ada banyak variasi didalam metode, teknik, dan algoritma yang terdapat pada *data mining*. Kesesuaian metode atau algoritma sangat bergantung pada proses dan tujuan yang terdapat pada KDD.

5. *Interpretation / Evaluation:*

Merupakan tahap dilakukannya penerjemahan pola yang dilakukan didalam *data mining* tahap dilakukan dengan tujuan agar pola informasi yang dihasilkan nantinya dapat dimengerti oleh pihak yang berkepentingan. Didalam tahap ini juga dilakukan investigasi terhadap informasi dan pola yang ditemukan bertentangan dengan fakta atau tidak.

2.2 Algoritma Apriori

Algoritma Apriori adalah algoritma yang digunakan untuk menyelesaikan penemuan *item set* secara bertahap yang sering muncul melalui elemen item yang semakin banyak (Liu, 2010). Algoritma apriori merupakan algoritma paling terkenal untuk menemukan pola frekuensi tinggi. Pola frekuensi tinggi adalah pola-pola item di dalam suatu database yang memiliki frekuensi atau *support* di atas ambang batas tertentu yang disebut dengan istilah minimum *support* dan *confidence*. Pola

frekuensi tinggi ini digunakan untuk menyusun aturan asosiatif. Contoh aturan asosiasi yang terbentuk umumnya dinyatakan dalam bentuk:

$$\{\text{roti, mentega}\} \Rightarrow \{\text{susu}\} (\text{support} = 40\%, \text{confidence} = 50\%).$$

Aturan asosiasi tersebut memiliki arti "50% dari transaksi pada *database* yang memuat *item* roti dan mentega kemungkinan juga memuat *item* susu. Sedangkan 40% dari seluruh transaksi yang terjadi memuat ketiga *item* tersebut (Kusrini dan Luthfi, 2010).

2.3 Support dan Confidence

Ada dua parameter penting yang berfungsi untuk pembentukan *rules* yaitu *support* dan *confidence* sehingga dihasilkan aturan asosiasi yang kuat (*strong rules*). *Support* adalah persentase kombinasi suatu item dalam *database*, sedangkan *confidence* adalah kuatnya hubungan antar item dalam aturan asosiasi (Kusrini dan Luthfi, 2010).

Menghitung nilai *support* 1-*itemset* menggunakan persamaan 1:

1-*itemset*:

$$\text{Support} (A) = \frac{\text{Jumlah transaksi yang mengandung A}}{\text{Jumlah transaksi}} \times 100\% \quad (1)$$

Menghitung nilai *support* 2-*itemset* menggunakan persamaan 2:

2-*itemset*:

$$\text{Support} (A \rightarrow B) = \frac{\text{Jumlah transaksi yang mengandung A dan B}}{\text{Jumlah transaksi}} \times 100\% \quad (2)$$

Menghitung nilai *confidence* itemset menggunakan persamaan 3:

2 *itemset*:

$$\text{Confidence} (A \rightarrow B) = \frac{\text{Jumlah transaksi yang mengandung A dan B}}{\text{Jumlah transaksi yang mengandung A}} \times 100\% \quad (3)$$

2.4 Algoritma FP-Growth

FP-Growth merupakan pengembangan dari algoritma apriori. Pada algoritma apriori diperlukan *generate candidate* untuk memperoleh *frequent itemsets*. Akan tetapi, pada algoritma FP-Growth, *generate candidate* tidak dilakukan karena FP-Growth menggunakan konsep pembangunan *tree* yang disebut dengan *Frequent Pattern-Tree* (FP-Tree) dalam pencarian *frequent itemsets*. Hal tersebut yang menyebabkan algoritma FP- Growth lebih cepat dari algoritma Apriori. Sehingga kekurangan dari algoritma apriori diperbaiki oleh algoritma *FP-Growth* (Samuel, 2008). Algoritma FP-growth dapat

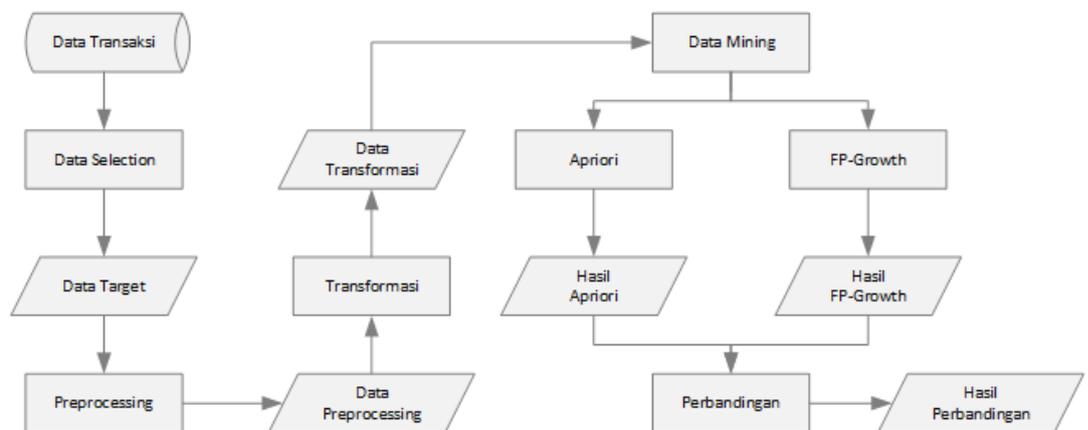
diimplementasikan dalam waktu yang singkat dan menghasilkan akurasi yang tinggi ketika digunakan untuk menganalisa *asosiation rule* (Song dan Wei, 2011).

Metode *FP-Growth* dapat dibagi menjadi 3 tahapan utama yaitu sebagai berikut:

- a. Tahap Pembangkitan *conditional pattern base*.
- b. Tahap pembangkitan *conditional FP-Tree*.
- c. Tahap pencarian *frequent itemset*.

3. Metode Penelitian

Jalannya penelitian akan dilakukan sesuai dengan tahapan data mining atau KDD yang meliputi data selection, preprocessing/cleaning, transformasi, data mining dan evaluasi. Proses data mining dibagi menjadi dua proses dikarenakan menggunakan dua algoritma yaitu algoritma apriori dan algoritma *FP-Grwoth*. Kemudian hasilnya akan dibandingkan dan mengambil aturan asosiasi yang terbaik. Tahapan penelitian penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

Dalam penelitian ini, sumber data yang digunakan untuk mendukung penelitian adalah data primer dan data sekunder.

- a. Data primer merupakan data yang diperoleh dari dalam perusahaan dimana kasus penelitian dilakukan. Dalam penelitian ini data primer yang digunakan adalah data transaksi penjualan daring pada data transaksi penjualan Rumah Warna selama 10 bulan terakhir yaitu terhitung dari tanggal 1 Agustus 2017 sampai dengan 30 Juni 2018 dengan data sebanyak 10.230 data transaksi.

- b. Data sekunder yang digunakan dalam penelitian adalah data di luar data primer atau sering disebut dengan kamus. Pada proses transformasi untuk data penjualan Rumah Warna menggunakan kamus yang berisi jenis-jenis produk yang ada di Rumah Warna.

3.1 Data Selection

Pertama dilakukan adalah meng-*import* file yang berisi data transaksi penjualan Rumah Warna ke dalam jupyter notebook. Data transaksional yang didapat adalah berformat *xlsx*. Kemudian melakukan inisialisasi pada file excel yang akan di-*import* seperti pada. Kemudian memilih 3 atribut yaitu No, Tgl_Pesan dan Produk seperti pada Gambar 2. Tiga atribut tersebut adalah yang paling relevan dalam proses pencarian *association rules*.

	NO	Tgl_Pesan	Produk
1	1	Kamis, 31 Ags 2017 [PO#737]	Tania Tosca x 1
2	2	Kamis, 31 Ags 2017 [PO#736]	Tania Pink Muda x 1
3	3	Kamis, 31 Ags 2017 [PO#735]	Tas Galena Hitam x 1
4	4	Kamis, 31 Ags 2017 [PO#734]	Vintesa Abu x 1, Tania Tosca x 1
5	5	Kamis, 31 Ags 2017 [PO#733]	Imoet Pink Fanta x 1

Gambar 2. Tampilan *Data Selection*

3.2 Preprocessing

Dalam tahap *preprocessing* pertama merubah format *type data* kolom Produk menjadi string. Kemudian jika terdapat transaksi lebih dari satu produk maka dilakukan pemisahan data produk dalam kolom Produk menggunakan fungsi split dengan koma tetapi masih dalam satu array seperti pada Gambar 3.

	NO	Tgl_Pesan	Produk
1	1	Kamis, 31 Ags 2017 [PO#737]	[Tania Tosca x 1]
2	2	Kamis, 31 Ags 2017 [PO#736]	[Tania Pink Muda x 1]
3	3	Kamis, 31 Ags 2017 [PO#735]	[Tas Galena Hitam x 1]
4	4	Kamis, 31 Ags 2017 [PO#734]	[Vintesa Abu x 1, Tania Tosca x 1]
5	5	Kamis, 31 Ags 2017 [PO#733]	[Imoet Pink Fanta x 1]

Gambar 3. Hasil *Preprocessing*

3.3 Transformasi

Pada tahap transformasi menggunakan data diluar data utama atau sering disebut dengan kamus. Kamus ini berisi jenis-jenis produk yang ada di Rumah Warna. Kamus ini berfungsi untuk mencocokkan data *item* barang yang ada pada atribut Produk dengan data *item* barang yang terdapat di kamus. Kemudian membuat membuat atribut baru yaitu Anak, Cangklong, Dompel, Ransel, Selempang dan *Sling Bag*. Jika data pada kolom jenis produk sama dengan kolom jenis-jenis produk, maka kolom jenis produk maka akan ditambahkan nilai 1, jika tidak sama maka akan tetap 0 seperti pada Gambar 4.

NO	Tgl_Pesan	Produk	Jenis_Produk	Ransel	Cangklong	Selempang	Sling Bag	Anak	Dompel
1	Kamis, 31 Ags 2017 [PO#737]	[Tania Tosca x 1]	[Ransel]	1	0	0	0	0	0
2	Kamis, 31 Ags 2017 [PO#736]	[Tania Pink Muda x 1]	[Ransel]	1	0	0	0	0	0
3	Kamis, 31 Ags 2017 [PO#735]	[Tas Galena Hitam x 1]	[Ransel]	1	0	0	0	0	0
4	Kamis, 31 Ags 2017 [PO#734]	[Vintesa Abu x 1, Tania Tosca x 1]	[Selempang, Ransel]	1	0	1	0	0	0
5	Kamis, 31 Ags 2017 [PO#733]	[Imoet Pink Fanta x 1]	[Ransel]	1	0	0	0	0	0

Gambar 4. Tampilan Perubahan Nilai Atribut Jenis-jenis Produk

Kemudian Setelah itu membuat atribut Jumlah yang menampung hasil penjumlahan dari atribut Anak, Cangklong, Dompel, Selempang, Ransel dan Sling Bag seperti pada Gambar 5.

NO	Tgl_Pesan	Produk	Jenis_Produk	Ransel	Cangklong	Selempang	Sling Bag	Anak	Dompel	OrderID	Jumlah
1	Kamis, 31 Ags 2017 [PO#737]	[Tania Tosca x 1]	[Ransel]	1	0	0	0	0	0	[PO#737]	1.0
2	Kamis, 31 Ags 2017 [PO#736]	[Tania Pink Muda x 1]	[Ransel]	1	0	0	0	0	0	[PO#736]	1.0
3	Kamis, 31 Ags 2017 [PO#735]	[Tas Galena Hitam x 1]	[Ransel]	1	0	0	0	0	0	[PO#735]	1.0
4	Kamis, 31 Ags 2017 [PO#734]	[Vintesa Abu x 1, Tania Tosca x 1]	[Selempang, Ransel]	1	0	1	0	0	0	[PO#734]	2.0

Gambar 5. Hasil Penambahan Atribut dan Penjumlahan

Angka 1 setiap atribut jenis-jenis produk akan diubah menjadi "Y" dan 0 pada setiap atribut jenis-jenis produk akan diubah menjadi "?". Perubahan nilai pada atribut tersebut digunakan nantinya pada proses data mining menggunakan aplikasi Weka. Kemudian memilih atribut OrderID, Anak, Cangklong, Dompel, Ransel, Selempang, Sling Bag, dan Jumlah. Atribut-atribut tersebut adalah atribut yang akan dinantinya *export* dan kemudian diproses pada tahap data mining menggunakan Weka. Pemilhan atribut dapat dilihat pada Gambar 6.

	OrderID	Anak	Cangklong	Dompet	Ransel	Selempang	Sling Bag	Jumlah
1	[PO#737]	?	?	?	Y	?	?	1
2	[PO#736]	?	?	?	Y	?	?	1
3	[PO#735]	?	?	?	Y	?	?	1
4	[PO#734]	?	?	?	Y	Y	?	2
5	[PO#733]	?	?	?	Y	?	?	1

Gambar 6. Tampilan Atribut Terpilih

Karena dalam penelitian ini menggunakan metode asosiasi, maka data yang digunakan adalah transaksi yang memiliki ≥ 2 pada atribut Jumlah yang berarti memiliki minimal terjadi pembelian 2 jenis produk. Kemudian menghapus nilai pada atribut Jumlah yang bernilai 0 dan 1, nantinya hanya menyisakan nilai dengan jumlah ≥ 2 seperti pada Gambar 6. Hasil dari proses tersebut dapat dilihat pada Gambar 7.

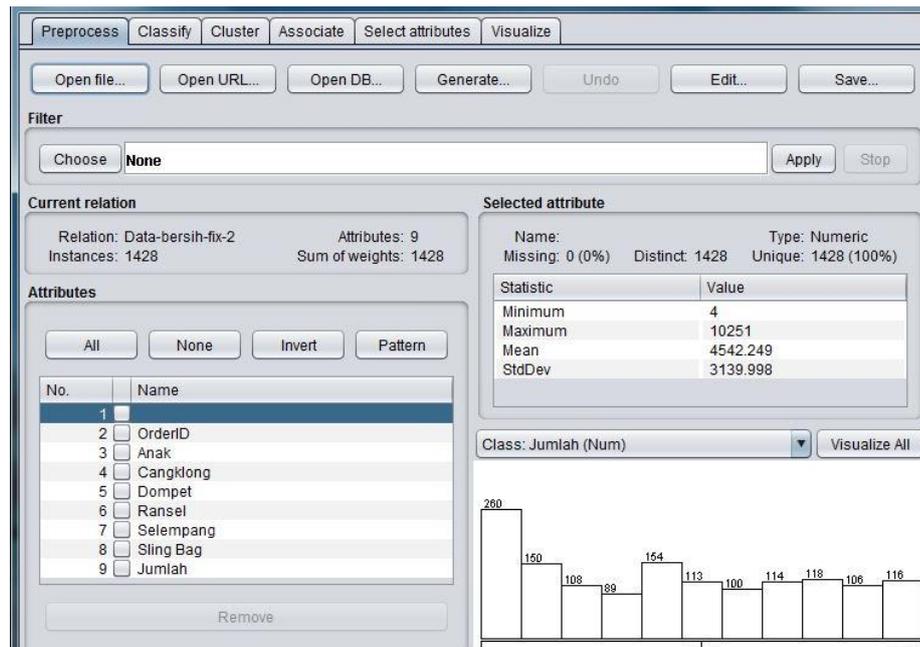
	OrderID	Anak	Cangklong	Dompet	Ransel	Selempang	Sling Bag	Jumlah
4	[PO#734]	?	?	?	Y	Y	?	2
7	[PO#731]	?	?	Y	Y	?	Y	3
9	[PO#729]	?	Y	?	?	Y	?	2
11	[PO#727]	?	?	Y	Y	?	?	2
14	[PO#724]	?	?	Y	Y	Y	?	3

Gambar 7. Hasil Penghapusan nilai 1

Langkah terakhir adalah meng-*export* data yang sudah siap untuk dimasukkan ke dalam aplikasi Weka.

3.4 Data Mining

Untuk aplikasi Weka sendiri hanya bisa membaca file dengan format *Attribute Relation File Format* (ARRF) tetapi sebelumnya file excel yang akan dimasukkan ke dalam aplikasi Weka harus berformat *comma separates value* (CSV). Pada tahap preprocess Weka dipilih atribut yang akan dipakai pada saat proses asosiasi nanti. Atribut tersebut antara lain Anak, Cangklong, Dompet, Ransel, Selempang, dan *Sling Bag* lalu disimpan dalam format .arff. Hasil dari proses tersebut dapat dilihat pada Gambar 8.



Gambar 8. Hasil proses Data Mining

Dalam penelitian ini akan mengambil *minimum support* 10% dan *minimum confidence* 50%. Hasil aturan asosiasi yang dihasilkan akan menjadi informasi strategis bagi pihak Rumah Warna. Dari hasil yang didapat menggunakan software Weka untuk algoritma apriori ditemukan 6 aturan asosiasi seperti pada Gambar 9.

```

Apriori
=====

Minimum support: 0.1 (143 instances)
Minimum metric <confidence>: 0.5
Number of cycles performed: 18

Generated sets of large itemsets:

Size of set of large itemsets L(1): 6
Size of set of large itemsets L(2): 5
Size of set of large itemsets L(3): 1

Best rules found:

1. Selempang=Y 839 ==> Ransel=Y 620 <conf:(0.74)> lift:(0.94) lev:(-0.03) [-36] conv:(0.83)
2. Anak=Y 288 ==> Ransel=Y 210 <conf:(0.73)> lift:(0.93) lev:(-0.01) [-15] conv:(0.79)
3. Cangklong=Y 253 ==> Ransel=Y 178 <conf:(0.7)> lift:(0.9) lev:(-0.01) [-19] conv:(0.73)
4. Dompet=Y 690 ==> Ransel=Y 468 <conf:(0.68)> lift:(0.87) lev:(-0.05) [-71] conv:(0.67)
5. Ransel=Y 1117 ==> Selempang=Y 620 <conf:(0.56)> lift:(0.94) lev:(-0.03) [-36] conv:(0.93)
6. Dompet=Y Selempang=Y 310 ==> Ransel=Y 165 <conf:(0.53)> lift:(0.68) lev:(-0.05) [-77] conv:(0.46)

```

Gambar 9. Hasil Aturan Asosiasi Apriori

Dari hasil yang didapat menggunakan software Weka untuk algoritma fp-growth ditemukan 6 aturan asosiasi seperti pada Gambar 10

```

FPGrowth found 6 rules (displaying top 6)
1. [Selempang=Y]: 839 ==> [Ransel=Y]: 620 <conf:(0.74)> lift:(0.94) lev:(-0.03) conv:(0.83)
2. [Anak=Y]: 288 ==> [Ransel=Y]: 210 <conf:(0.73)> lift:(0.93) lev:(-0.01) conv:(0.79)
3. [Cangklong=Y]: 253 ==> [Ransel=Y]: 178 <conf:(0.7)> lift:(0.9) lev:(-0.01) conv:(0.73)
4. [Dompel=Y]: 690 ==> [Ransel=Y]: 468 <conf:(0.68)> lift:(0.87) lev:(-0.05) conv:(0.67)
5. [Ransel=Y]: 1117 ==> [Selempang=Y]: 620 <conf:(0.56)> lift:(0.94) lev:(-0.03) conv:(0.93)
6. [Selempang=Y, Dompel=Y]: 310 ==> [Ransel=Y]: 165 <conf:(0.53)> lift:(0.68) lev:(-0.05) conv:(0.46)

```

Gambar 10. Hasil Aturan Asosiasi FP-Growth

3.5 Evaluasi

Informasi strategis yang berupa aturan asosiasi yang didapat dari 1.428 data dengan *minimum support* 10% dan *minimum confidence* 50% untuk algoritma apriori dan fp-growth. Tabel nilai *support* dan *confidence* dapat dilihat pada Tabel 1.

Tabel 1. Tabel Nilai *Support* dan *Confidence*

o	N	Aturan Asosiasi	Support	Confidence
1		Selempang g ==> Ransel	$(620/1428) \times 100$ % = 43%	$(620/839) \times 100$ = 74%
2		Anak ==> Ransel	$(210/1428) \times 100$ % = 15%	$(210/288) \times 100$ = 73%
3		Cangklong g ==> Ransel	$(178/1428) \times 100$ % = 12%	$(178/253) \times 100$ = 70%
4		Dompel ==> Ransel	$(468/1428) \times 100$ % = 33%	$(468/690) \times 100$ = 68%
5		Ransel ==> Selempang	$(620/1428) \times 100$ % = 43%	$(620/1117) \times 100$ % = 56%
6		Dompel, Selempang ==> Ransel	$(165/1428) \times 100$ % = 12%	$(165/310) \times 100$ = 53%

Disisi lain hasil analisis pengujian menunjukkan bahwa algoritma Apriori dan FP-Growth menunjukkan bahwa aturan asosiasi yang terbentuk dari kedua algoritma yaitu sama banyaknya. Dari hasil kerja kedua algoritma semakin besar *minimum support* dan *minimum confidence*nya maka aturan asosiasi yang terbentuk semakin sedikit bahkan bisa tidak ada. Dapat disimpulkan bahwa kedua algoritma tersebut layak diimplementasikan untuk rekomendasi strategi pemasaran berdasarkan aturan asosiasi.

4. Penutup

Dalam penelitian ini, telah berhasil melakukan analisis data mining pada data transaksi Rumah Warna. Hasil kombinasi antar item dari perhitungan algoritma apriori dan fp growth yang memiliki nilai *support* dan *confidence* paling besar yaitu

support 43% dan *confidence* 74% adalah “Jika membeli Tas Selempang maka juga akan membeli Tas Ransel”.

Dengan *minimum support* 10% dan *minimum confidence* 50% menghasilkan 6 aturan asosiasi pada algoritma apriori dan juga menghasilkan 6 aturan asosiasi pada algoritma fp-growth. Pengujian dengan menggunakan aplikasi Weka antara algoritma apriori dan algoritma fp-growth memiliki hasil jumlah aturan asosiasi yang dihasilkan sama banyaknya.

DAFTAR PUSTAKA

- Kusrini dan Luthfi, E.T., 2010. *Algoritma Data Mining*. Yogyakarta: Andi Offset.
- Liu, Y., 2010. Study on application of apriori algorithm in data mining. *ICCMS 2010 - 2010 International Conference on Computer Modeling and Simulation*, 3, 111–114. <https://doi.org/10.1109/ICCMS.2010.398>
- Mabrur, A.G. dan Lubis, R., 2012. Penerapan Data Mining Untuk Memprediksi Kriteria Nasabah Kredit. *Jurnal Komputer dan Informatika (KOMPUTA)*, 1(1), pp.53-57.
- Samuel, D., 2008. Penerapan Struktur FP-Tree dan Algoritma FP-Growth dalam Optimasi Penentuan Frequent Itemset.
- Setiabudi, D. H., Budhi, G. S., Purnama, I. W. J., dan Noertjahyana, A., 2011. Data mining market basket analysis' using hybrid-dimension association rules, case study in Minimarket X. *Proceedings of the International Conference on Uncertainty Reasoning and Knowledge Engineering, URKE 2011*, 1, 196–199. <https://doi.org/10.1109/URKE.2011.6007796>
- Song, Y., dan Wei, R., 2011. Research on application of data mining based on FP-growth algorithm for digital library. *2011 2nd International Conference on Mechanic Automation and Control Engineering, MACE 2011 - Proceedings*, 1525–1528. <https://doi.org/10.1109/MACE.2011.5987239>