

# Penerapan Algoritma Apriori Dalam Pengendalian Kualitas Produk

Omar Pahlevi

Universitas Bina Sarana Informatika  
Jl. Kamal Raya No. 18 Cengkareng, Jakarta Barat  
omar.opi@bsi.ac.id

Anton Sugandi

STMIK Pranata Indonesia  
Jl. Cut Meutiah No. 28 Bekasi  
ants.konohamaru@gmail.com

Ita Dewi Sintawati

Universitas Bina Sarana Informatika  
Jl. Kamal Raya No. 18 Cengkareng, Jakarta Barat  
ita.ids@bsi.ac.id

**Abstrak**— Penelitian ini dilakukan untuk mengetahui *defect* apa saja yang sering muncul pada proses *injection* dan kombinasi *item defect* apa saja yang sering terjadi, untuk melakukan pengendalian kualitas produk yang bersangkutan. Metode analisis yang digunakan adalah analisis kuantitatif dengan menggunakan metode algoritma *apriori* yang dapat mengelola nilai *input* yang sesuai dengan kriteria-kriteria pada *item* yang mempunyai nilai *support* dan *confidence* tertentu dengan perhitungan *RapidMiner*. Algoritma *apriori* merupakan salah satu algoritma dalam *data mining* yang dapat digunakan dalam *association rule* untuk menentukan *frequent itemset* yang berfungsi untuk membantu menemukan pola dalam sebuah data. Dengan menggunakan algoritma *apriori*, dapat menghasilkan pola kombinasi sebanyak 17 (tujuh belas) *rules* dengan nilai *support* sebesar 70% dan nilai *confidence* tertinggi dari 17 (tujuh belas) *rules* tersebut sebesar 93% yang terdapat dalam *rule Lock Broken → Discolour*.

**Kata Kunci**— algoritma *apriori*, *association rules*, pengendalian kualitas produk

## I. PENDAHULUAN

Persaingan dalam dunia industri manufaktur maupun jasa semakin ketat dengan memasuki era globalisasi. Dalam strategi *marketing mix*, langkah yang pertama dilakukan adalah strategi produk [2]. Hal ini penting karena yang akan dijual adalah produk dan konsumen akan mengenal perusahaan melalui produk yang ditawarkan. Pada strategi produk yang perlu diingat adalah yang berkaitan dengan produk secara utuh, mulai dari nama produk, bentuk, isi, pembungkus.

Dalam arti yang sederhana produk dikatakan sesuatu yang dapat memenuhi kebutuhan dan keinginan konsumen. Berkaitan dengan produk, Phillip Kotler menjelaskan pengertian produk adalah sesuatu yang dapat ditawarkan ke pasar untuk mendapatkan perhatian untuk dibeli, digunakan atau dikonsumsi agar dapat memenuhi keinginan dan kebutuhan [2].

Saat ini teknologi informasi berkembang begitu cepat sehingga kebutuhan terhadap informasi semakin meningkat. Informasi tidak akan bernilai apabila tidak dikelola dengan baik. Akan tetapi jika data yang tersedia tersebut berjumlah besar maka cara konvensional tidak lagi mampu untuk menganalisa data yang ada. Maka dari itu dibutuhkan metode yang dapat menganalisis, meringkas dan mengekstrak data untuk menjadi sebuah informasi yang berguna. Tidak hanya mengandalkan data yang ada saja, perlu diadakannya analisis data untuk menggali potensi-potensi yang ada [6].

Penelitian ini serupa dengan penelitian yang telah dilakukan sebelumnya, yaitu [9] dalam penelitiannya “Menambang data atau upaya untuk menggali informasi dan pengetahuan yang berharga pada *database* yang sangat besar disebut *data mining* atau *Knowledge Discovery in Database* disingkat KDD. Salah satu algoritma yang paling populer pada teknik *data mining* adalah algoritma *apriori*. Sedangkan

dalam penemuan pola kombinasi hubungan antar *item-sets* digunakan *Association Rules* (Aturan Asosiasi). Data mining telah diimplementasikan ke berbagai bidang, diantaranya bidang bisnis atau perdagangan, bidang pendidikan, dan telekomunikasi. Dibidang bisnis misalnya hasil implementasi *data mining* menggunakan algoritma *apriori* dapat membantu para pebisnis dalam kebijakan pengambilan keputusan terhadap apa yang berhubungan dengan persediaan barang.

Penelitian yang dilakukan oleh [5] untuk mengukur sejauh mana proses pengendalian kualitas yang dilakukan pada suatu perusahaan, dimana hasilnya dibandingkan dengan standar yang diterapkan oleh perusahaan tersebut. Hasil dari penelitian ini menunjukkan bahwa pengendalian kualitas produk pada PT Bosowa Media Grafika (Tribun Timur) masih belum terkendali, dengan rata-rata kerusakan produk sebesar 4,47 % per hari. Jenis kerusakan yang paling banyak terjadi adalah tinta kabur dengan total 57.555 eksamplar atau 78% dari total produk cacat pada bulan Desember 2011. Dari hasil observasi lapangan dan wawancara, faktor-faktor yang menjadi penyebab kerusakan ini adalah faktor manusia, mesin, lingkungan, metode kerja dan bahan baku.

Pada penelitian ini akan digunakan metode *association rule mining* dengan algoritma *apriori* yang berfungsi untuk membentuk kandidat kombinasi *item* yang mungkin, lalu diuji apakah kombinasi tersebut memenuhi parameter *minimum support* dan *minimum confidence*, dimana pengguna dapat menentukan nilai ambang data ini diambil dari data LQC (*Line Quality Control*) di PT Juahn Indonesia

## II. TINJAUAN PUSTAKA

### A. Data Mining

Menurut Tan (2006) dalam [7] mendefinisikan *data mining* sebagai proses untuk mendapatkan informasi yang berguna dari gudang basis data yang besar. *Data mining* juga dapat diartikan sebagai pengekstrakan informasi baru yang diambil dari bongkahan data besar yang membantu dalam pengambilan keputusan. Istilah *data mining* kadang disebut juga *knowledge discovery*.

Menurut [4] 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 (*Clustering*)

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* (analisis keranjang belanja) atau algoritma *apriori*, sebagaimana yang akan dibahas dalam penelitian ini.

### B. Association Rules Mining

Menurut [3] Aturan asosiasi (*association rule*) adalah teknik data mining untuk menemukan aturan asosiatif antara suatu kombinasi data mining untuk menemukan aturan asosiatif antara suatu kombinasi item. Aturan asosiasi (*association rules*) atau analisis afinitas (*affinity analysis*) berkenaan dengan studi tentang ‘apa bersama apa’.

Dalam menentukan suatu aturan asosiasi, terdapat suatu ukuran ketertarikan (*interestingness measure*) yang didapatkan dari hasil pengolahan data dengan data perhitungan tertentu. Pada umumnya terdapat dua ukuran ketertarikan dalam aturan asosiasi, yaitu :

- Support*, adalah probabilitas konsumen membeli beberapa produk secara bersamaan dari jumlah seluruh transaksi [8]. Ukuran ini menentukan apakah suatu item/itemset layak untuk dicari nilai confidence-nya (misal dari keseluruhan transaksi yang ada, seberapa besar tingkat dominasi yang menunjukkan bahwa item X dan Y dibeli secara bersamaan).
- Confidence* atau tingkat kepercayaan merupakan probabilitas kejadian beberapa produk yang dibeli bersamaan dimana salah satu produk sudah pasti dibeli (misal, seberapa sering *item* Y dibeli apabila konsumen membeli item X) [8].

Kedua ukuran (*support* dan *confidence*) berguna dalam menentukan aturan asosiasi, yaitu untuk dibandingkan dengan batasan (*threshold*) yang ditentukan oleh pengguna. Batasan tersebut umumnya terdiri atas *minimum support* dan *minimum confidence*. Langkah-langkah dalam pembentukan aturan asosiasi meliputi dua tahap, yaitu:

#### a. Analisis Pola Frekuensi Tinggi

Tahap ini mencari kombinasi *item* yang memenuhi syarat minimum dari nilai *support* dalam basis data. *Support* untuk aturan “X => Y” adalah probabilitas atribut atau kumpulan atribut X dan Y yang terjadi secara bersamaan dalam suatu transaksi [8]. Bentuk persamaan matematis dari nilai *support* [1] adalah:

$$\text{Support}(X \Rightarrow Y) = P(X \cap Y) \quad (1)$$

Dengan keterangan:

$X \Rightarrow Y$  = item yang muncul bersamaan

$P(X \cap Y)$  = probabilitas transaksi yang mengandung X dan Y dibagi dengan jumlah transaksi seluruhnya.

#### b. Pembentukan aturan asosiasi

Setelah semua pola frekuensi tinggi ditemukan, kemudian dicari aturan asosiasi yang memenuhi syarat minimum untuk *confidence* dengan menghitung *confidence* dari aturan if X then Y. Bentuk rumus matematika dari *confidence* [1] adalah:

$$\text{Confidence}(X \Rightarrow Y) = P(Y | X) \quad (2)$$

Dengan keterangan:

$P(X|Y)$  = item yang muncul bersamaan

$X \cap Y$  = probabilitas transaksi yang mengandung X dan Y dibagi dengan jumlah transaksi yang mengandung X.

### C. Algoritma Apriori

Menurut [3] Algoritma *apriori* adalah jenis aturan asosiasi pada *data mining*. Algoritma ini ditujukan untuk mencari kombinasi *itemset* yang mempunyai suatu nilai keseringan tertentu sesuai kriteria atau *filter* yang diinginkan. Algoritma ini diajukan oleh R. Agrawal dan R. Srikant tahun 1994.

Hasil dari algoritma ini dapat digunakan untuk membantu dalam pengambilan keputusan pihak manajemen. Algoritma *apriori* melakukan pendekatan iteratif yang dikenal dengan pencarian *level-wise*, dimana k-itemset digunakan untuk mengeksplorasi atau menemukan (k+1)- itemset. Oleh karena itu, algoritma *apriori* dibagi menjadi beberapa tahap yang disebut iterasi. Tiap iterasi menghasilkan pola frekuensi tinggi dengan panjang yang sama dimulai dari iterasi pertama yang menghasilkan pola frekuensi tinggi dengan panjang satu.

Di iterasi pertama ini, *support* dari setiap *item* dihitung dengan men-scan *database*. Setelah *support* dari setiap *item* didapat, item yang memiliki *support* diatas *minimum support* dipilih sebagai pola frekuensi tinggi dengan panjang 1 atau sering disebut Large 1-itemset atau disingkat L1. Iterasi kedua menghasilkan 2-itemset yang tiap set-nya memiliki dua item. Pertama dibuat kandidat 2-itemset atau disingkat C2 dari kombinasi semua 1-itemset. Lalu untuk tiap kandidat 2-itemset ini dihitung *support*-nya dengan men-scan *database*. *Support* disini artinya jumlah transaksi dalam *database* yang mengandung kedua item dalam C2. Setelah *support* dari semua C2 didapatkan, C2 yang memenuhi syarat *minimum support* dapat ditetapkan sebagai 2-itemset yang juga merupakan pola frekuensi tinggi dengan panjang 2 atau Large 2-itemset (L2).

Untuk selanjutnya pada iterasi ke-k dapat dibagi lagi menjadi beberapa bagian :

- Pembentukan kandidat itemset, Kandidat k-itemset (Ck) dibentuk dari kombinasi (k-1)-itemset yang didapat dari iterasi sebelumnya. Hal ini disebut juga dengan proses join. Setelah proses join dilakukan, selanjutnya proses prune yang bertujuan untuk menghasilkan Lk. Proses prune merupakan proses pemangkasan kandidat k-itemset yang subset-

nya yang berisi (k-1)-item yang tidak termasuk dalam pola frekuensi tinggi dengan panjang k-1.

2. Tetapkan pola frekuensi tinggi. Pola frekuensi tinggi yang memuat k-item atau k-itemset yang ditetapkan dari kandidat k-itemset yang support-nya lebih besar dari minimum support. Bila tidak didapat pola frekuensi tinggi baru maka seluruh proses dihentikan. Bila tidak, maka k ditambah satu dan kembali ke bagian 1.

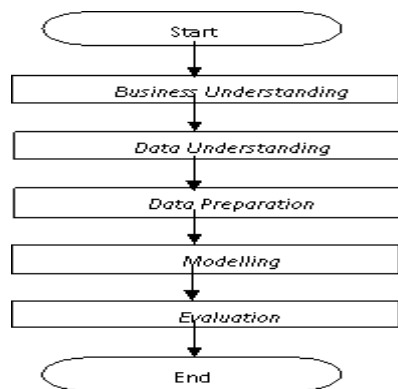
### III. METODE PENELITIAN

#### A. Obyek Penelitian

Penelitian ini dilakukan pada PT Juahn Indonesia berdasarkan identifikasi masalah yang akan difokuskan untuk mencari analisa tentang jenis defect apa saja yang terjadi dan faktor apa saja yang menyebabkan defect tersebut terjadi pada proses injection di PT Juahn Indonesia.

#### B. Desain Penelitian

Pada penelitian ini menggunakan model *Cross-Standard Industry for Data Mining (CRISP-DM)*, yaitu seperti terlihat pada diagram di bawah ini: [7]



Gambar 1. Diagram Tahap Penelitian

##### a. Business Understanding

Pembuatan analisis menggunakan algoritma Apriori agar dapat diketahui jenis *defect* apa yang sering terjadi pada proses injection. Data yang akan digunakan dalam penelitian berupa data proses LQC (Line Quality Control) Injection periode Januari 2014 sampai dengan Desember 2016.

##### b. Data Understanding

Dalam tahap ini ditentukan beberapa Spesifikasi data dari bagian administrasi LQC (Line Quality Control) PT Juahn Indonesia yang akan digunakan untuk mencari dalam klasifikasi jenis *defect* yang sering terjadi di proses injection. Kandidat data tersebut didapatkan dari bagian administrasi LQC (Line Quality Control) dan beberapa penyesuaian agar

penilaian yang dilakukan lebih akurat. Dalam penelitian ini data yang digunakan sejumlah 4259 data, yang kemudian dibagi menjadi dua bagian yaitu sebagai *data training* dan *data testing*. Persentase untuk pembagian data yang digunakan yaitu 80 : 20, yang menghasilkan 3407 data sebagai *data training* dan 852 data untuk *data testing*.

##### c. Data Preparation

Sebelum tahap pengolahan data, perlu dilakukan tahap persiapan (*preprocessing*), dengan tujuan untuk mencari field data yang kosong (*missing value*) dan data dengan format yang tidak sesuai (*noise*), agar akurasi dari hasil pengolahan data dapat meningkat.

##### d. Modelling

Data transaksi merupakan data yang diperoleh dari inpeksi harian. Setelah data transaksi *defect* telah didapatkan, kemudian mengubah data tersebut dalam bentuk tabular. Untuk mempermudah dan mempercepat proses perhitungan maka dapat menggunakan alat bantu analisis yaitu rapidminer. Untuk tahap pertama akan dilakukan pemrosesan *data training* sehingga akan menghasilkan nilai *support* dan *confidence* pada transaksi dari *item* yang muncul. Berikut proses menggunakan rapidminer dalam pemrosesan algoritma *apriori (Association Rules)*. Data awal merupakan data training yang didapat dari laporan transaksi inspection bagian injection periode Januari 2014 sampai dengan Juni 2016. Data akhir didapat dari data awal yang diolah sehingga data akhir langsung dapat digunakan untuk mendapatkan aturan asosiasi. Data akhir terdiri dari atribut dan nilai atribut yang telah diubah dalam bentuk tabular. Atribut merupakan data item defect yang ada pada laporan hasil inspection di proses injection. Nilai support kandidat pertama pada gambar diatas didapatkan dengan perhitungan sebagai berikut.

$$\text{Support (A)} = \frac{\text{Jumlah transaksi mengandung A}}{\text{Transaksi Total}} \quad (3)$$

Nilai Support Shortmold

$$\text{Support (Shortmold)} = 25/30 \times 100 = 83 \%$$

Nilai support kandidat kedua pada gambar diatas didapatkan dengan perhitungan sebagai berikut.

$$\text{Support (A,B)} = \frac{\sum \text{Transaksi mengandung A dan B}}{\sum \text{Transaksi}} \quad (4)$$

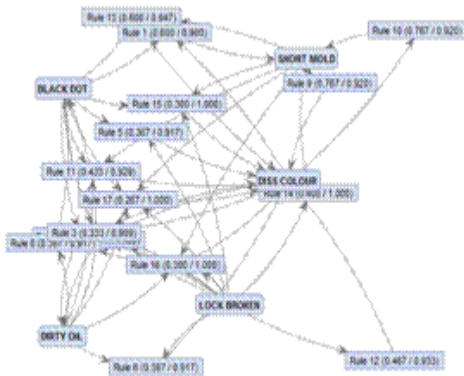
Nilai Support Shortmold & Diss colour

$$\text{Support (Shortmold \& Diss colour)} = 33/30 \times 100 = 76 \%$$



No.	Premises	Conclusion	Support	Confid.	Lift	Gain	g-8	Lift	Confid.
1	DISS COLOUR, BLACK DOT	SHORT MOLD	0.600	0.900	0.900	-0.72	0.044	1.000	1.000
2	DISS COLOUR, BLACK DOT, LOCK BROK	DIRTY OIL	0.333	0.909	0.976	-0.401	0.077	1.000	0.909
3	DISS COLOUR, DIRTY OIL, LOCK BROKE	BLACK DOT	0.333	0.909	0.976	-0.401	0.052	1.000	0.909
4	BLACK DOT, DIRTY OIL, LOCK BROKEN	DISS COLOUR	0.333	0.909	0.976	-0.401	0.028	1.000	0.909
5	BLACK DOT, LOCK BROKEN	DISS COLOUR	0.367	0.917	0.976	-0.431	0.023	1.000	0.917
6	DIRTY OIL, LOCK BROKEN	DISS COLOUR	0.367	0.917	0.976	-0.431	0.023	1.000	0.917
7	BLACK DOT, LOCK BROKEN	DIRTY OIL	0.367	0.917	0.976	-0.431	0.027	1.000	0.917
8	DIRTY OIL, LOCK BROKEN	BLACK DOT	0.367	0.917	0.976	-0.431	0.060	1.000	0.917
9	SHORT MOLD	DISS COLOUR	0.767	0.920	0.964	-0.901	0.072	1.000	0.920
10	DISS COLOUR	SHORT MOLD	0.767	0.920	0.964	-0.901	0.072	1.000	0.920
11	SHORT MOLD, BLACK DOT, DIRTY OIL	DISS COLOUR	0.433	0.920	0.977	-0.501	0.044	1.000	0.920
12	LOCK BROKEN	DISS COLOUR	0.467	0.933	0.976	-0.531	0.050	1.000	0.933
13	SHORT MOLD, BLACK DOT	DISS COLOUR	0.600	0.947	0.980	-0.661	0.072	1.000	0.947
14	SHORT MOLD, LOCK BROKEN	DISS COLOUR	0.400	1	1	-0.400	0.057	1.000	1
15	SHORT MOLD, BLACK DOT, LOCK BROKE	DIRTY OIL	0.300	1	1	-0.300	0.050	1.000	1
16	SHORT MOLD, DIRTY OIL, LOCK BROKE	DISS COLOUR	0.300	1	1	-0.300	0.050	1.000	1
17	SHORT MOLD, BLACK DOT, DIRTY OIL, L	DISS COLOUR	0.267	1	1	-0.267	0.044	1.000	1

Gambar 2. Tampilan output data association rules



Gambar 3. Tampilan grafik association rules

Gambar 4. Tampilan description association rules

Nilai confidence pada gambar diatas didapatkan dengan perhitungan sebagai berikut.

$$\text{Confidence} = P(B|A) = \frac{\sum \text{Transaksi mengandung A dan B}}{\sum \text{Transaksi mengandung A}} \quad (5)$$

Nilai Confidence transaksi Shortmold & Discolour

$$\text{Confidence} = P(\text{Shortmold} | \text{Discolour}) = \frac{39}{25} * 100 = 92\%$$

$$\text{Confidence} = P(\text{Discolour} | \text{Shortmold}) = \frac{23}{25} * 100 = 92\%$$

#### IV. PEMBAHASAN

Percobaan pada penelitian ini menggunakan tools RapidMiner Studio Ver. 6.3.0. Algoritma yang digunakan adalah Apriori dan aturan Asosiasi yang digunakan adalah nilai support dan nilai confidence. Dari percobaan yang telah dilakukan menggunakan algoritma Apriori, diketahui bahwa dengan nilai support sebesar 0.7 atau 70% dan nilai confidence 0.90 atau 90 menghasilkan nilai confiden paling tinggi sebesar 100% dan dapat menghasilkan rule terbanyak dengan total 17 rules dan 5 Itemset. 17 rule dan 4 Itemset tersebut adalah sebagai berikut:

No	Premises	Conclusion	Support	Confid.
1	DISS COLOUR, BLACK DOT	SHORT MOLD	0.600	0.900
2	DISS COLOUR, BLACK DOT, LOCK BROK	DIRTY OIL	0.333	0.909
3	DISS COLOUR, DIRTY OIL, LOCK BROKE	BLACK DOT	0.333	0.909
4	BLACK DOT, DIRTY OIL, LOCK BROKEN	DISS COLOUR	0.333	0.909
5	BLACK DOT, LOCK BROKEN	DISS COLOUR	0.367	0.917
6	DIRTY OIL, LOCK BROKEN	DISS COLOUR	0.367	0.917
7	BLACK DOT, LOCK BROKEN	DIRTY OIL	0.367	0.917
8	DIRTY OIL, LOCK BROKEN	BLACK DOT	0.367	0.917
9	SHORT MOLD	DISS COLOUR	0.767	0.920
10	DISS COLOUR	SHORT MOLD	0.767	0.920
11	SHORT MOLD, BLACK DOT, DIRTY OIL	DISS COLOUR	0.433	0.920
12	LOCK BROKEN	DISS COLOUR	0.467	0.933
13	SHORT MOLD, BLACK DOT	DISS COLOUR	0.600	0.947
14	SHORT MOLD, LOCK BROKEN	DISS COLOUR	0.400	1
15	SHORT MOLD, BLACK DOT, LOCK BROKE	DIRTY OIL	0.300	1
16	SHORT MOLD, DIRTY OIL, LOCK BROKE	DISS COLOUR	0.300	1
17	SHORT MOLD, BLACK DOT, DIRTY OIL, L	DISS COLOUR	0.267	1

Gambar 5. Kandidat item set

- Shortmold → Disscolour (Supp = 0.76 & Conf= 0.92). Hal tersebut berarti jika defect shortmold muncul maka defect Disscolour juga akan muncul dengan tingkat confidence sebesar 92% dan minimum support sebesar 76%.
- Disscolour → Shortmold (Supp = 0.76 & Conf= 0.92). Hal tersebut berarti jika defect Disscolour muncul maka defect Shortmold juga akan muncul dengan tingkat confidence sebesar 92% dan minimum support sebesar 76%.
- Lock Broken → Disscolour (Supp = 0.46 & Conf= 0.93). Hal tersebut berarti jika defect Lock Broken muncul maka defect Disscolour juga akan muncul dengan tingkat confidence sebesar 93% dan minimum support sebesar 50%.
- Disscolour, Black Dot → Shortmold (Supp = 0.6 & Conf= 0.9). Hal tersebut berarti jika defect Disscolour, Black Dot muncul maka defect Shortmold juga akan muncul dengan tingkat

- confidence sebesar 90% dan minimum support sebesar 60%
- e. Black Dot, Lock Broken  $\rightarrow$  Discolour (Supp = 0.6 & Conf= 0.9). Hal tersebut berarti jika defect Black Dot, Lock Broken muncul maka defect Discolour juga akan muncul dengan tingkat confidence sebesar 90% dan minimum support sebesar 60%.
- f. Dirty Oil, Lock Broken  $\rightarrow$  Discolour (Supp = 0.36 & Conf= 0.91). Hal tersebut berarti jika defect Dirty Oil, Lock Broken muncul maka defect Discolour juga akan muncul dengan tingkat confidence sebesar 91% dan minimum support sebesar 40%.
- g. Black Dot, Lock Broken  $\rightarrow$  Dirty Oil (Supp = 0.36 & Conf= 0.91). Hal tersebut berarti jika defect Black Dot, Lock Broken muncul maka defect Dirty Oil juga akan muncul dengan tingkat confidence sebesar 91% dan minimum support sebesar 40%.
- h. Shortmold, Black Dot  $\rightarrow$  Discolour (Supp = 0.6 & Conf= 0.94). Hal tersebut berarti jika defect Shortmold, Black Dot muncul maka defect Discolour juga akan muncul dengan tingkat confidence sebesar 94% dan minimum support sebesar 60%.
- i. Dirty Oil, Lock Broken  $\rightarrow$  Black Dot (Supp = 0.36 & Conf= 0.91). Hal tersebut berarti jika defect Dirty Oil, Lock Broken muncul maka defect Black Dot juga akan muncul dengan tingkat confidence sebesar 91% dan minimum support sebesar 40%.
- j. Shortmold, Lock Broken  $\rightarrow$  Discolour (Supp = 0.4 & Conf= 1.00). Hal tersebut berarti jika defect Shortmold, Lock Broken muncul maka defect Discolour juga akan muncul dengan tingkat confidence sebesar 100% dan minimum support sebesar 40%.
- k. Discolour, Blackdot, Lock Broken  $\rightarrow$  Dirty Oil (Supp = 0.33 & Conf= 0.90). Hal tersebut berarti jika defect Discolour, Blackdot, Lock Broken muncul maka defect Dirty Oil juga akan muncul dengan tingkat confidence sebesar 90% dan minimum support sebesar 30%.
- l. Discolour, Dirty Oil, Lock Broken  $\rightarrow$  Blackdot (Supp = 0.33 & Conf= 0.90). Hal tersebut berarti jika defect Discolour, Dirty Oil, Lock Broken muncul maka defect Blackdot juga akan muncul dengan tingkat confidence sebesar 90% dan minimum support sebesar 30%.
- m. Blackdot, Dirty Oil, Lock Broken  $\rightarrow$  Discolour (Supp = 0.33 & Conf= 0.90). Hal tersebut berarti jika defect Blackdot, Dirty Oil, Lock Broken muncul maka defect Discolour juga akan muncul dengan tingkat confidence sebesar 90% dan minimum support sebesar 30%.
- n. Shortmold, Blackdot, Dirty Oil  $\rightarrow$  Discolour (Supp = 0.43 & Conf= 0.92). Hal tersebut berarti jika defect Shortmold, Blackdot, Dirty Oil muncul maka defect Discolour juga akan muncul dengan tingkat confidence sebesar 92% dan minimum support sebesar 43%.
- o. Shortmold, Blackdot, Lock Broken  $\rightarrow$  Discolour (Supp = 0.3 & Conf= 1.0). Hal tersebut berarti jika defect Shortmold, Blackdot, Dirty Oil muncul maka defect Discolour juga akan muncul dengan tingkat confidence sebesar 100% dan minimum support sebesar 30%.
- p. Shortmold, Dirty Oil, Lock Broken  $\rightarrow$  Discolour (Supp = 0.3 & Conf= 1.0). Hal tersebut berarti jika defect Shortmold, Blackdot, Dirty Oil muncul maka defect Discolour juga akan muncul dengan tingkat confidence sebesar 100% dan minimum support sebesar 30%.
- q. Shortmold, Blackdot, Dirty Oil, Lock Broken  $\rightarrow$  Discolour (Supp = 0.26 & Conf= 1.0). Hal tersebut berarti jika defect Shortmold, Blackdot, Dirty Oil muncul maka defect Discolour juga akan muncul dengan tingkat confidence sebesar 100% dan minimum support sebesar 30%.
- Dari pembahasan di atas terdapat rules dengan nilai confidence paling tinggi yaitu Shortmold, Lock Broken  $\rightarrow$  Diss Colour dengan nilai confidence sebesar 100% dan nilai support sebesar 40%. Karena keterkaitan Shortmold, Lock Broken  $\rightarrow$  Diss Colour cukup tinggi maka pihak PT Juahn Indonesia terutama *Quality Control* nya harus lebih diperketat lagi dan harus cepat menangani *problem defect* tersebut

## V. KESIMPULAN

Berdasarkan hasil penilaian untuk nilai *support* dan *confidence* algoritma *apriori* dengan nilai *support* sebesar 0.7 atau 70% dan nilai *confidence* 0.90 atau 90 menghasilkan nilai *confidence* paling tinggi sebesar 100% dan dapat menghasilkan *rule* terbanyak dengan total 17 *rules* dan 4 *Itemset*. 17 *rule* dan 4 *Itemset defect* yang sering muncul pada proses *injection* PT Juahn Indonesia Bekasi dengan nilai *confidence* paling tinggi yaitu *Shortmold, Lock Broken  $\rightarrow$  Diss Colour* dengan nilai *confidence* sebesar 100% dan nilai *support* sebesar 40%.

## REFERENSI

- [1] Han, J., & Kamber, M. (2006). *Data Mining Concept and Tehniques*. San Fransisco: Morgan Kauffman.

- 
- [2] Kasmir. 2008. Kewirausahaan. Jakarta: PT. Raja Grafindo Persada.
- [3] Kusriani,&Luthfi, E. T. (2009). *Algoritma Data Mining*. Yogyakarta: Andi Publishing.
- [4] Larose, D. T. (2005). *Discovering Knowledge in Data*. New Jersey: John Willey & Sons, Inc.
- [5] Ilham, Nur. Muhammad. (2012). *Analisis Pengendalian Kualitas Produk Dengan Menggunakan Statistical Processing Control (SPC) Pada PT Bosowa Media Grafika (Tribun Timur)*. Makassar: Fakultas Ekonomi Dan Bisnis Universitas Hasanuddin Makassar.
- [6] Pahlevi, Omar. 2018. *Data Mining Penentuan Aturan Asosiasi Penjualan Makanan Di Amaria Hotel Jakarta Menggunakan Algoritma Apriori*. Jakarta: Jurnal Sistem Informasi. Volume VII, No. 2 Agustus 2018, Hal. 137-142, STMIK Antar Bangsa.
- [7] Prasetyo, Eko. 2012. *Data Mining Konsep Dan Aplikasi Menggunakan MATLAB*. Yogyakarta: Andi.
- [8] Sumathi, & S., Sivanandam, S.N. (2006). *Introduction to Data Mining and its Applications*.
- [9] Tampubolon, Kennedy, Hoga Saragih, Bobby Reza. *Implementasi Data Mining Algoritma Apriori Pada Sistem Persediaan Alat-Alat Kesehatan*. ISSN: 2339-210X. Informasi dan Teknologi Ilmiah (INTI), Vol: I, No: I, Oktober 2013.
- [10] Yulita, Marsela dan Veronica S. Moertini (2004). *Analisis Keranjang Pasar Dengan Algoritma Hash-Based Pada Transaksi Penjualan Di Apotik*. Bandung: Jurnal Integral Majalah Ilmiah Matematika dan Ilmu Pengetahuan Alam, Vol 9, No 3 (2004), Jurusan Ilmu Komputer Universitas Katolik Parahyangan.