

SISTEM REKOMENDASI PEMESANAN SPAREPART DENGAN ALGORITMA FP-GROWTH (STUDI KASUS PT. ROSALIA SURAKARTA)

Nur Rohman Ardani¹⁾, Nur Fitriana²⁾

¹⁾Magister Teknik Informatika STMIK AMIKOM Yogyakarta

²⁾Teknik Informatika STMIK Sinar Nusantara Surakarta
Jl Ring road Utara, Condongcatur, Sleman, Yogyakarta 55281
Jl. KH. Samanhudi 84 - 86 Solo

Email : master.ardani@gmail.com¹⁾, missfitriana@gmail.com²⁾

Abstrak

Bisnis adalah salah satu bidang yang tidak dapat lepas dari kebutuhan akan informasi. Ketepatan, kecepatan dan keakuratan dalam mengolah data menjadi informasi sangatlah diperlukan. Semakin cepat informasi dapat diperoleh maka sebuah perusahaan dapat menentukan sebuah strategi bisnis yang efektif dan efisien. Salah satu keuntungan adanya kecepatan informasi adalah adanya sistem rekomendasi. Rekomendasi merupakan model aplikasi dari hasil observasi pengolahan data sebelumnya dan keadaan pelanggan dalam membeli suatu produk. Dalam hal ini dapat sistem rekomendasi dapat diterapkan dalam pembelian sparepart di PT. Rosalia.

Association Rule Mining merupakan salah satu teknik yang dapat digunakan dalam mengasosiasikan data sehingga menemukan pola hubungan yang terbentuk secara tidak langsung dari sebuah data. Dalam menemukan sebuah pola maka diperlukan pembacaan data berulang kali sehingga diperlukan adanya algoritma dan metode tertentu yang efisien. Dalam hal tersebut, penelitian ini menggunakan algoritma FP-Growth untuk pendekatan nilai asosiasi data. Hasil yang dicapai dalam penelitian ini adalah adanya rule sistem rekomendasi pembelian sparepart dengan minimum support 0.15 dan minimum confidence 0.8

Kata kunci:Rekomendasi, sparepart, Assosiation Rule, FP-Growth.

1. Pendahuluan

Bisnis merupakan salah satu bidang yang memiliki kebutuhan informasi yang sangat besar. Kecepatan informasi yang didapat dapat mempengaruhi strategi bisnis yang dibuat oleh perusahaan dalam upaya mewujudkan visi dan misi perusahaan. Ketepatan dan validnya suatu informasi dapat juga menunjang dalam ketepatan pemilihan strategi bisnis dalam sebuah perusahaan. Dalam hal ini informasi yang cepat, tepat, akurat, dan efisien sangat dibutuhkan dalam sebuah perusahaan. Oleh karena itu alasan yang melandasi penulis untuk mengambil judul *Sistem Rekomendasi*

Pemesanan Sparepart Dengan Algoritma Fp-Growth adalah diharapkan dapat membantu manager dalam mengatur sistem pemesanan sparepart yang secara tidak langsung akan berkaitan dengan sistem anggaran perusahaan.

Penggalan data yang banyak dibutuhkan algoritma yang tepat. *FP-Growth* merupakan salah satu algoritma yang dapat digunakan untuk menentukan himpunan data yang sering muncul (*frequent itemset*) dalam sebuah kumpulan data [2]. *FP-Growth* merupakan perkembangan terhadap algoritma apriori, dimana terdapat perbedaan dalam scanning database dan akurasi rulesnya. *FP-Growth* lebih memberikan keuntungan karena hanya dilakukan satu atau dua kali saja scanning database sedangkan Apriori perlu melakukan scanning database berulang-ulang. Pada Apriori akurasi rules nya lebih tinggi daripada *FP-Growth*. Walaupun pada dasarnya kedua algoritma ini memiliki tujuan yang sama yaitu menentukan *frequent itemset*.

Pada algoritma Apriori diperlukan generate candidate untuk mendapatkan frequent itemsets. Akan tetapi, di algoritma *FP-Growth* generate candidate tidak dilakukan karena *FP-Growth* menggunakan konsep pembangunan tree dalam pencarian frequent itemsets. Hal tersebutlah yang menyebabkan algoritma *FP-Growth* lebih cepat dari algoritma Apriori.

Adapun manfaat yang dapat diperoleh dari penelitian ini adalah sebagai berikut :

1. Diharapkan dapat membantu dalam memberikan rekomendasi yang tepat dalam pemesanan *sparepart* sehingga menjaga stok *sparepart* stabil.
2. Adanya efisiensi waktu dalam proses pemesanan karena dengan adanya sistem rekomendasi dapat dilakukan prediksi pemesanan sebelum *stock* habis.
3. Dapat memberikan gambaran strategi dalam mengatur anggaran keuangan yang secara tidak langsung terkait dengan anggaran perusahaan dalam pengadaan pemesanan *sparepart*.

Metode yang digunakan dalam penelitian ini adalah metode eksperimen dengan tahapan, sebagai berikut :

1. Pengumpulan Data
2. Penerapan Algoritma *FP-Growth*
3. Evaluasi Hasil
4. Dokumentasi Eksperiment

PT. Rosalia merupakan salah satu perusahaan yang bisnisnya berkembang sangat cepat. Perseroan Terbatas Rosalia ini melebarkan sayap di banyak aspek bisnis yang ada, seperti bisnis travel, transportasi, engineering, bahkan laundry.

Dari banyak bisnis tersebut tidak lepas dengan sebuah peralatan teknologi. Sebuah peralatan teknologi tidak lepas dari sparepart yang mendukung. Sparepart memiliki jangka waktu penggunaan sehingga adanya *service* berkala yang membuat adanya sistem transaksi sparepart. Pada PT. Rosalia setiap transaksi dicatat dalam sistem dan disimpan dalam *database* sistem.

Transaksi pembelian sparepart hampir dilakukan setiap harinya sehingga transaksi yang dicatat di setiap *record* hingga kini jumlahnya mencapai belasan ribu. Dari data tersebut dapat dihasilkan informasi baru yang mampu mendukung kinerja perusahaan agar dapat menentukan *strategi bisnis* yang handal. Penggunaan Sistem Pendukung Keputusan diharapkan dapat membantu dalam perencanaan pengadaan transaksi sparepart. Adanya teknik *Data Mining* dapat membuat sebuah sistem perkiraan untuk penganggaran *sparepart* yang lebih sering disebut dengan sistem rekomendasi.

Penggalian data merupakan cara yang cukup efektif untuk mengetahui berbagai pola atau hubungan yang terkait dari sebuah data. Penggalian data dilakukan terhadap kumpulan data yang sangat besar yang disebut *Data Warehouse*. Dari penggalian data akan didapatkan sebuah informasi baru yang bermanfaat bagi pengguna informasi tersebut. Dalam hal ini penelitian difokuskan dalam penggalian data untuk menemukan sistem rekomendasi yang tepat dan efisien dalam transaksi sparepart.

Adapun perumusan masalah pada penelitian ini adalah sebagai berikut : “Bagaimana membangun model sistem pendukung keputusan dengan teknik data mining yang dapat memberikan rekomendasi terhadap transaksi sparepart yang dilakukan oleh manajer”.

Tujuan penelitian ini dilakukan adalah sebagai berikut :

- 1 Menghasilkan model sistem pendukung keputusan yang dapat memberikan rekomendasi dalam penentuan pembelian sparepart berdasarkan data-data histori sebelumnya.
- 2 Model Sistem Pendukung Keputusan ini dapat mencari *minimum support* dan *minimum confidence*.

Data Mining

Datamining adalah salah satu ilmu computer yang sering digunakan untuk pengolahan data untuk memberikan pola atau hubungan tertentu sehingga dihasilkan informasi yang bermanfaat bagi penggunanya, *Data Mining* seringkali dikaitkan dengan *machine learning*, *Artificial Intelligent*, dan *Statistic*. Data mining adalah proses yang menggunakan teknik statistik, matematika, kecerdasan buatan, dan mesin learning untuk mengekstraksi dan mengidentifikasi informasi yang bermanfaat dan pengetahuan yang terkait berbagai database besar (baca pengertian database)[5]. Lalu Larose berpendapat bahwa data mining adalah bidang yang digabung dari beberapa bidang keilmuan yang menyatukan teknik dari pembelajaran mesin, pengenalan pola, statistik, database, dan visualisasi untuk pengenalan permasalahan pengambilan informasi dari database yang besar. Sedangkan menurut Pang-Ning Tan dalam bukunya yang berjudul *Introduction to Data Mining*, definisi Data Mining adalah sebagai berikut: “*Process of automatically discovering useful information in large data repositories.*”[6].

Dalam pengolahannya Data mining memiliki tahapan-tahapan :

- a. Pembersihan Data (*Cleaning Data*), untuk menghilangkan *noise* data yang tidak konsisten.
- b. Integrasi Data (*Data Integration*), Integrasi data dimana sumber yang terpecah disatukan.
- c. Pemilihan Data (*Data Selection*), Pengembalian data yang relevan kedalam database.
- d. Transformasi Data (*Data Transformation*), Pengubahan data yang sesuai sehingga tidak adanya duplikat data yang bermakna sama namun memiliki karakteristik yang berbeda.
- e. Penambangan Data (*Data Mining*), proses esensial di mana metode yang intelegen digunakan untuk mengekstrak pola data.
- f. Evaluasi Pola (*Pattern Evaluation*), untuk mengidentifikasi pola yang benar-benar menarik yang mewakili pengetahuan berdasarkan atas beberapa tindakan yang menarik.
- g. Presentasi Pengetahuan (*Knowledge Presentation*), gambaran teknik visualisasi dan pengetahuan digunakan untuk memberikan pengetahuan yang telah ditambang kepada user.

Teknik Data Mining dengan *Assosiation Rule Mining*

Association rule merupakan suatu proses pada *data mining* untuk menentukan semua aturan asosiatif yang memenuhi syarat minimum untuk support (minsup) dan confidence (minconf) pada sebuah database. Kedua syarat tersebut akan digunakan untuk *interesting association rules* dengan dibandingkan dengan batasan yang telah ditentukan, yaitu minsup dan minconf. [1]

Dengan menggunakan pola asosiasi dapat memberikan gambaran terhadap atribut, atau karakteristik yang sering muncul dalam proses transaksi.

Misal $I = \{a_1, a_2, \dots, a_n\}$ adalah kumpulan dari item. Dan basis data transaksi $DB = \{T_1, T_2, \dots, T_n\}$, dimana T_i ($i \in [1..n]$) adalah sekumpulan transaksi yang mengandung item di I .

Dua tahap *Asosiation Rule Mining*, yaitu :

- a. Penentuan *frequency itemset*
 Penentuan *frequency itemset* harus memenuhi minimum support (*Itemset, support, dan confidence*)
- b. *Rule Generation*
Frequency itemset digunakan untuk memperoleh *Asosiation Rule*. *Asosiation Rule* harus memenuhi minimum support dan minimum confident.

Untuk mendapatkan nilai *support* item A dapat diperoleh dengan rumus 1.

$$Support(A) = \frac{\text{Jumlah transaksi mengandung item A}}{\text{Total Transaksi}} \quad (1)$$

Sedangkan menurut Larose (2005), untuk menemukan support dari dua item yaitu item A dan item B digunakan rumus 2.

$$Support(A, B) = \frac{\text{jumlah transaksi mengandung } A \cap B}{\text{total transaksi}} \quad (2)$$

Setelah ditemukan *minimum support* maka langkah selanjutnya adalah menemukan *minimum confidence* yang merupakan ukuran ketepatan suatu *rule* yang terkandung dalam Item A dan Item B dapat menggunakan rumus 3.

$$Confidence(A, B) = \frac{\text{jumlah transaksi mengandung } A \cap B}{\text{jumlah transaksi mengandung A}} \quad (3)$$

Hasil dari tahap ini akan ditemukan *frequency itemset candidate* yang sesuai dengan nilai *minimum support* dan *minimum confidence*.

Algoritma FP-Growth

FP-Growth merupakan salah satu algoritma yang dapat digunakan untuk menentukan himpunan data yang sering muncul (*frequent itemset*) dalam sebuah kumpulan data [2]. *FP-Growth* merupakan perkembangan terhadap algoritma apriori, dimana terdapat perbedaan dalam scanning database dan akurasi rulesnya. *FP-Growth* lebih memberikan keuntungan karena hanya dilakukan satu atau dua kali saja scanning database sedangkan Apriori perlu melakukan scanning database berulang-ulang. Pada Apriori akurasi rules nya lebih tinggi daripada *FP-Growth* namun karena scanning yang dilakukan berulang kali membuat kecepatan lebih lambat daripada *FP-Growth*. Walaupun pada dasarnya kedua algoritma ini memiliki tujuan yang sama yaitu menentukan *frequent itemset*.

Dalam mencari *frequent itemset* algoritma *FP-Growth* menggunakan struktur data yang didapatkan dari perluasan pohon prefix atau sering kali disebut *FP-tree*. Dari *FP-Tree* didapatkan hasil extract *frequent itemset* menggunakan prinsip *divide* dan *conquer* yang memecah

masalah menjadi sub-sub masalah sehingga permasalahan tersebut lebih efisien dan akses memori lebih cepat.

Algoritma *FP-Growth* pada dasarnya dibagi menjadi tiga tahapan utama, yaitu [3] :

1. Tahap pembangkitan *conditional pattern base*
2. Tahap pembangkitan *conditional FP-Tree*
 Sebuah *FP-tree* adalah kompak struktur data yang mewakili set data dalam bentuk pohon yang memiliki cabang . Setiap transaksi dibaca dan kemudian dipetakan ke jalur di *FP-Tree* . Hal ini dilakukan sampai semua transaksi sudah dibaca.

Pembangunan *FP-tree* dibagi menjadi tiga langkah utama, yaitu [3] :

- a. *Scanning* data set untuk menentukan jumlah dukungan dari setiap item
 - b. Membuang data yang tidak perlu dan membuat *order list* dari item yang terbanyak muncul dengan urutan menurun.
 - c. *Scanning* data menetapkan satu transaksi pada suatu waktu untuk membuat *FP-tree*.
 Jika sebuah transaksi yang unik akan membentuk jalur yang baru dan node baru dengan hitungan dimulai dari 1.
 Kelebihan *FP-tree* dapat menggunakan dua kali *scanning* data saja .
3. Tahap pencarian *frequent itemset*

2. Pembahasan

Untuk membangun sistem rekomendasi pembelian sparepart pada PT Rosalia menggunakan *FP-Growth* diawali dengan pembentukan *FP-tree* dari data transaksi pembelian. contoh data yang digunakan berjumlah 12 data yang diambil secara random dari transaksi dari PT Rosalia. Tabel 1 adalah contoh data transaksi.

Tabel 1. Transaksi pembelian sparepart

Transaksi	Id Sparepart
192	269,270,271,272,468
401	468,271,270,269
423	245,272
465	240,244,276,283,284
466	361,360,352,319,318
467	360,361,283,284,286,314
770	279,204
1296	204,270
1802	279,284
1971	272,245,240
2153	259,270
20536	270,468

Pembentukan FP-Tree

Tahap awal adalah melakukan filter terhadap data sparepart yang memiliki nilai support diatas *Minimum support* yang telah ditentukan yaitu 0.15, dan data di tabel 2 adalah hasil perhitungan data sample dengan item

sparepart yang memiliki nilai *support* diatas dari *minimum support* yang telah ditentukan.

Tabel 2 Frekuensi item dengan min support ≥ 0.15

Sparepart	Frekuensi	Nilai support
270	5	0.4
272	3	0.25
284	3	0.25
468	3	0.25
279	2	0.16
204	2	0.16
240	2	0.16
245	2	0.16
269	2	0.16
271	2	0.16
283	2	0.16
361	2	0.16

Tabel 3 adalah nama sparepart yang digunakan dalam data di table 2. Dari hasil data item yang memiliki nilai *support* lebih dari nilai *min support* yang ditentukan, maka tabel 1 dapat di *filtering* dengan menghilangkan item sparepart yang tidak memenuhi nilai minimum support dan mengurutkan susunan item berdasarkan pada tabel 2 untuk pembuatan *FP-Tree*

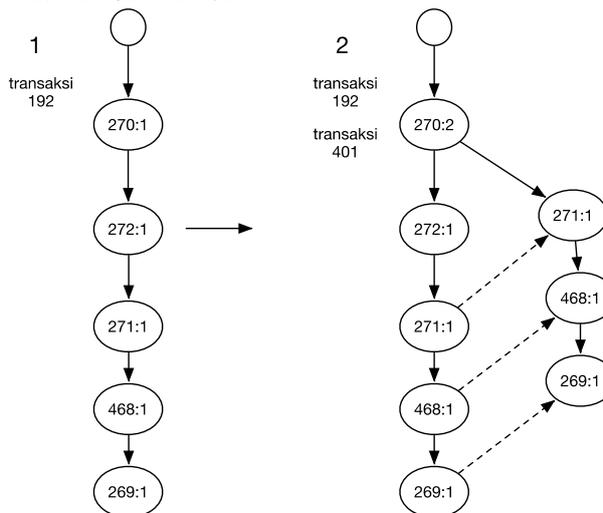
Tabel 3 Transaksi yang telah diurutkan sesuai frekuensi item

Transaksi	Id Sparepart
192	270,272,271,468,269
401	270,271,468, 269
423	272,245
465	284,240,283
466	361
467	284,283,361
770	279,204
1296	270,204
1802	279,284
1971	272,245,240
2153	270
20536	270,468

Dari data pada tabel 4 akan menjadi acuan dalam membangun *FP-Tree*, berikut langkah membangun *FP-Tree*.

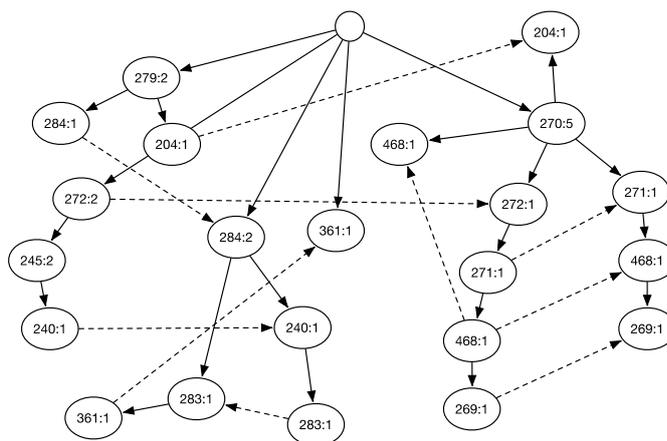
1. *FP-Tree* untuk pusat root diberi label dengan null.
2. Setiap simpul dalam *FP-Tree* mengandung tiga informasi penting, yaitu label item, menginformasikan jenis item yang direpresentasikan simpul tersebut, *support count*, merepresentasikan jumlah lintasan transaksi yang melalui simpul tersebut, dan pointer penghubung yang menghubungkan simpul-simpul dengan label item sama antarlintasan, ditandai dengan garis panah putus-putus.

Gambar dibawah ini adalah hasil dari pembentukan dari transaksi 192 dan 401



Gambar 1 Hasil pembentukan FP-Tree setelah pembacaan transaksi 192 dan 401

Seluruh transaksi yang terdapat di tabel 3 dibentuk satu persatu sampai selesai sehingga menjadi *FP-Tree* dibawah ini :



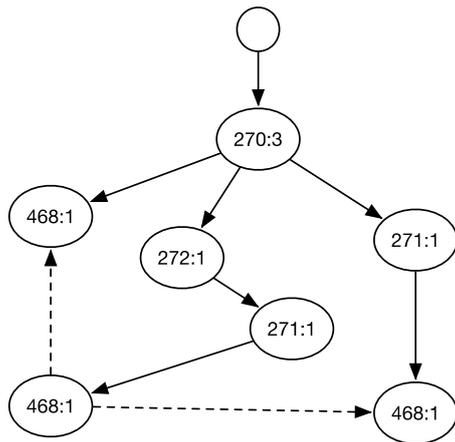
Gambar 2 Hasil pembentukan FP-Tree keseluruhan

Perhitungan FP-Growth

Peran Algoritma *FP-Growth* adalah menemukan pola *frequent itemset* dari *FP-Tree* yang telah dibentuk sebelumnya.

Setelah pembuatan *FP-Tree* selesai, algoritma *FP-Growth* mencari semua subsets yang memungkinkan dengan cara membangkitkan *conditional FP-Tree* dan mencari *frequent itemset*.

Tahap pertama mengambil *conditional pattern base* pada *FP-Tree* dengan melakukan scan pada *FP-Tree* dengan awalan path dari bawah ke atas. Contoh untuk item 468



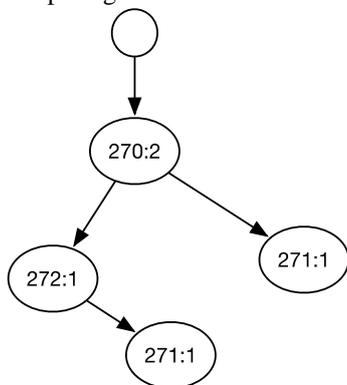
Gambar 3 Tree yang diakhiri item 468

Dari tree yang berakhir dengan item 468 dapat diambil sebagai *conditional pattern base*.

Tabel 4 Conditional Pattern Base

Sparepart	Conditional Pattern Base
468	{270:1},{270,271:1},{270,272,271:1}

Setelah ditemukan *conditional pattern base* selanjutnya adalah menemukan *conditional FP-Tree*. Dari gambar 3 untuk menentukan *conditional FP-Tree* langkah pertama adalah menghapus item 468 dan menghitung ulang *support count* seperti gambar 4



Gambar 4 Tree setelah item 468 dihilangkan

Selanjutnya menghilangkan item yang *support count* tidak memenuhi *minimum support* seperti pada gambar 4 item 272 hanya memiliki 1 kali kemunculan bersama item 468 sehingga dapat dihilangkan dan menghasilkan *conditional FP-Tree* pada tabel 5. Untuk item yang lain dapat menggunakan cara yang sama untuk menentukan *conditional pattern base* dan *conditional FP-Tree* seperti contoh sebelumnya.

Tabel 5 Conditional FP-Tree

Sparepart	Conditional FP-Tree
468	{270,271:1}

Setelah *conditional FP-Tree* terbentuk, langkah selanjutnya adalah melakukan subsets dari *conditional FP-tree* terhadap item sehingga menghasilkan *frequent item sets* pada tabel 7

Tabel 7 Hasil Frequent Item Sets

Sparepart	Frequent Item Sets
270	{270}
272	{272}
284	{284}
468	{468},{270,468},{271,468}
279	{279}
204	{204}
240	{240}
245	{245},{272,245}
269	{269},{270,269},{468,269},{271,269}, {270,271,269},{468,271,269}, {270,468,269},{270,468,272,269}
271	{271},{270,271},{270,468,271}, {468,271}
283	{283},{284,283}
361	{361}

Untuk menemukan *Association Rule* yang terdapat pada *frequent item sets* dapat dilakukan dengan membuat subset dari semua *frequent item set* kemudian dari subset yang dihasilkan, apabila nilai *confidence* yang dihasilkan pada subset yang terbentuk lebih besar dari nilai *minimum confidence* yang ditentukan maka *Association Rule* tersebut dapat digunakan.

Dari perhitungan *confidence* terhadap pola yang terbentuk diatas, maka *Association Rule* yang memenuhi syarat *confidence* $\geq 0,8$ adalah

- [468] --> [270] (confidence: 1.000)
- [271] --> [270] (confidence: 1.000)
- [269] --> [270] (confidence: 1.000)
- [271] --> [468] (confidence: 1.000)
- [269] --> [468] (confidence: 1.000)
- [283] --> [284] (confidence: 1.000)
- [245] --> [272] (confidence: 1.000)
- [271] --> [269] (confidence: 1.000)
- [269] --> [271] (confidence: 1.000)
- [271] --> [270, 468] (confidence: 1.000)
- [270, 271] --> [468] (confidence: 1.000)
- [468, 271] --> [270] (confidence: 1.000)
- [269] --> [270, 468] (confidence: 1.000)
- [270, 269] --> [468] (confidence: 1.000)
- [468, 269] --> [270] (confidence: 1.000)
- [271] --> [270, 269] (confidence: 1.000)
- [270, 271] --> [269] (confidence: 1.000)
- [269] --> [270, 271] (confidence: 1.000)
- [270, 269] --> [271] (confidence: 1.000)
- [271, 269] --> [270] (confidence: 1.000)
- [271] --> [468, 269] (confidence: 1.000)
- [468, 271] --> [269] (confidence: 1.000)
- [269] --> [468, 271] (confidence: 1.000)

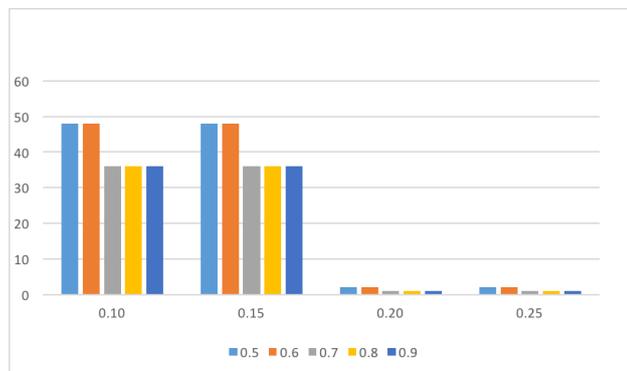
[468, 269] --> [271] (confidence: 1.000)
 [271, 269] --> [468] (confidence: 1.000)
 [271] --> [270, 468, 269] (confidence: 1.000)
 [270, 271] --> [468, 269] (confidence: 1.000)
 [468, 271] --> [270, 269] (confidence: 1.000)
 [270, 468, 271] --> [269] (confidence: 1.000)
 [269] --> [270, 468, 271] (confidence: 1.000)
 [270, 269] --> [468, 271] (confidence: 1.000)
 [468, 269] --> [270, 271] (confidence: 1.000)
 [270, 468, 269] --> [271] (confidence: 1.000)
 [271, 269] --> [270, 468] (confidence: 1.000)
 [270, 271, 269] --> [468] (confidence: 1.000)
 [468, 271, 269] --> [270] (confidence: 1.000)

Pengujian Perbandingan Jumlah Rule

Pengujian untuk membandingkan hasil jumlah rule yang diperoleh dengan memasukkan min support dan min confidence yang berbeda-beda dengan jumlah dataset sama. Hasil pengujian terdapat pada tabel 6

Tabel 8 Hasil pengujian terhadap jumlah rule

Min Supp	Min Conf				
	0.5	0.6	0.7	0.8	0.9
0.10	48	48	36	36	36
0.15	48	48	36	36	36
0.20	2	2	1	1	1
0.25	2	2	1	1	1



Gambar 3 Grafik perbandingan jumlah rule

Dari grafik pengujian diatas jumlah rule berkurang secara signifikan ketika minimum support sudah lebih dari 0.15 dan minimum confidence lebih dari 0.6. rule yang terbentuk dari nilai minimum tersebut hanya 1 sehingga rule tidak ideal. Sehingga untuk nilai minimum support yang baik adalah kurang dari 0.20 dan minimum confidence lebih dari 0.6

3. Kesimpulan

Kesimpulan yang dapat diambil pada makalah ini adalah

1. Nilai *confidence* yang ditentukan akan mempengaruhi akurasi dalam pembentukan *rule*,

semakin tinggi nilai *confidence* maka *rule* akan semakin akurat

2. Frequent itemset yang dihasilkan oleh FP-Growth pada penelitian dapat menghasilkan 36 *association rule* dapat dimanfaatkan untuk menjadi referensi dan rekomendasi dalam pembelian *sparepart*
3. Nilai minimum support dari data diatas yang paling ideal adalah 0.15 dan minimum confidence lebih dari 0.6.

Dalam penelitian ini sampai pada tahap analisis dari sistem rekomendasi yang akan dibangun dengan menggunakan *FP-Growth* dan belum ada implementasi dalam bentuk aplikasi, untuk tahap selanjutnya penelitian akan dilanjutkan untuk implementasi dalam sebuah aplikasi.

Daftar Pustaka

- [1] Pramesthi Dyah Larasati, Nasrun Muhammad, Ali Umar Ahmad. 2015. *Analysis and implementation of fp-growth algorithm in smart application to determine market basket analysis on retail business*. Universitas Telkom Bandung.
- [2] Ikhwan Ali., Nofriansyah Dicky, Sriani, *Penerapan Data Mining dengan Algoritma Fp-Growth untuk Mendukung Strategi Promosi Pendidikan*. Universitas Putra Indonesia "YPTK" Padang, STMIK TrigunaDharma.
- [3] Han, Jiawei, dan Kamber, Micheline. 2006. *Data Mining : Concepts and Technique*. Morgan Kauffman : San Francisco
- [4] Agus Wiwit Triyanto. 2014. *Assosiation rule mining untuk penentuan rekomendasi promosi produk*. Universitas Muria Kudus
- [5] Efraim Turban, Jay E. Aronson, Ting-Peng Liang: "Decision Support Systems and Intelligent Systems, 7th Edition", Pearson Prentice-Hall, 100 – 139, 2005
- [6] Tan, P., dan Steinbach, M., "Introduction to Data Mining", Addison Wesley, 2006

Biodata Penulis

Nur Rohman Ardani, memperoleh gelar Sarjana Komputer (S.Kom), Jurusan Teknik Informatika STMIK Sinar Nusantara Surakarta, lulus tahun 2012. Saat ini sedang menempuh pendidikan Magister Komputer (M.Kom) Program Pasca Sarjana Magister Teknik Informatika di STMIK AMIKOM Yogyakarta dan sebagai web programmer di PT Skyshi Digital Indonesia Yogyakarta.

Nur Fitriana, Saat ini sedang menempuh pendidikan Sarjana Komputer (S.Kom) jurusan Teknik Informatika di STMIK Sinar Nusantara Surakarta