

Implementasi Algoritma Frequent Pattern Growth, Collaborative Filtering Dan Eclat Untuk Rekomendasi Produk Pada PT. JOENoes IKAMULYA

Suzuki Syofian^{1a,*}, Rama Sugiyanto^{2b}, Irvan Y^{3c}, Suhendro Y. irianto^{4d}

^{a,b,d} Institut Informatika dan Bisnis Darmajaya

^c Universitas Darma Persada

^a suzukiumb@gmail.com

^b Ramasy2095@gmail.com

^c irfanustianiy@gmail.com

^d suhendro@darmajaya.ac.id

Abstract

This study aims to implement the Frequent Pattern Growth, Collaborative Filtering, and Eclat algorithms as a method for recommending products to consumers of PT. Joenoës Ikamulya. Companies are facing difficulties in determining the products that are in demand by consumers because of the increase in customer service. In order to increase product sales and expand market share, product recommendation systems to consumers are the right solution. The Frequent Pattern Growth method is used to find data sets that appear most frequently in large data sets. In this case, the algorithm generates a data tree structure called an FP Tree, which maps each transaction data into the path of the FP Tree. Collaborative Filtering leverages customer decision history to investigate reliable affiliates. By considering this affiliation, the resulting product recommendations are more accurate. Eclat's algorithm is used to find itemsets that appear frequently. Through a depth-first search on a database with a vertical layout, this algorithm is able to change a database with a horizontal layout to a vertical layout. This study integrates these three algorithms in a product recommendation system for PT. Joenoës Ikamulya. By implementing the Frequent Pattern Growth, Collaborative Filtering, and Eclat algorithms, it is hoped that the company can provide product suggestions or recommendations that match the interests and buying habits of other consumers, so as to increase sales and expand market share.

Keywords : Sistem rekomendasi; Fp Growth; Collaborative Filtering; Eclat

Abstrak

Penelitian ini bertujuan untuk mengimplementasikan algoritma Frequent Pattern Growth, Collaborative Filtering, dan Eclat sebagai metode untuk merekomendasikan produk kepada konsumen PT. Joenoës Ikamulya. Perusahaan menghadapi kesulitan dalam menentukan produk yang diminati oleh konsumen karena peningkatan layanan pelanggan. Dalam rangka meningkatkan penjualan produk dan memperluas pangsa pasar, sistem rekomendasi produk kepada konsumen menjadi solusi yang tepat. Metode Frequent Pattern Growth digunakan untuk mencari himpunan data yang paling sering muncul dalam kumpulan data besar. Dalam hal ini, algoritma menghasilkan struktur pohon data yang disebut FP Tree, yang memetakan setiap data transaksi ke dalam lintasan FP Tree. Collaborative Filtering memanfaatkan riwayat keputusan pelanggan untuk menyelidiki afiliasi yang dapat diandalkan. Dengan mempertimbangkan afiliasi ini, rekomendasi produk yang dihasilkan menjadi lebih akurat. Algoritma Eclat digunakan untuk menemukan itemset yang sering muncul. Melalui pencarian depth-first pada database dengan tata letak vertikal, algoritma ini mampu mengubah database dengan tata letak horizontal menjadi tata letak vertikal. Penelitian ini mengintegrasikan ketiga algoritma tersebut dalam sistem rekomendasi produk untuk PT. Joenoës Ikamulya. Dengan menerapkan algoritma Frequent Pattern Growth, Collaborative Filtering, dan Eclat, diharapkan perusahaan dapat memberikan saran atau rekomendasi produk yang sesuai dengan minat dan kebiasaan pembelian konsumen lain, sehingga dapat meningkatkan penjualan dan memperluas pangsa pasar.

Keywords : Sistem rekomendasi; Fp Growth; Collaborative Filtering; Eclat

1. PENDAHULUAN

1.1 Latar Belakang

Saat ini, IT atau teknologi telah digunakan di banyak bidang, seperti pemerintahan, pendidikan, kesehatan, ekonomi, dan lainnya, untuk meningkatkan hasil dan memudahkan pekerjaan. Teknologi digunakan dalam bidang ekonomi atau perdagangan untuk meningkatkan kinerja dan meningkatkan daya saing dengan perusahaan lain dalam industri yang sama; hal ini juga berkontribusi positif pada perluasan pemasaran produk.

PT. Joenoes Ikamulya menjual berbagai jenis sabun. Perusahaan menghadapi kesulitan dalam menentukan produk yang lebih diminati oleh konsumen karena peningkatan layanan pelanggan. Jika perusahaan belum melakukan analisis untuk mengembangkan produk sesuai dengan minat konsumen, mereka harus menemukan cara untuk memenuhi kebutuhan konsumen. Salah satu cara untuk melakukan ini adalah dengan mengetahui keinginan konsumen atau memberikan produk yang sesuai dengan keinginan mereka. Ketika sebuah produk dapat melihat keinginan dan kebutuhan pelanggan, itu pasti akan meningkatkan penjualan.

Dalam hal ini, metode atau algoritma diperlukan untuk mengidentifikasi pola pembelian konsumen agar mereka dapat memberikan saran atau rekomendasi produk yang sesuai dengan apa yang biasa dibeli oleh pelanggan lain. Pemecahan masalah yang tepat untuk meningkatkan penjualan produk dan memperluas pangsa pasar adalah sistem rekomendasi produk kepada konsumen. Frequency Pattern Growth, Collaborative Filtering, dan Eclat adalah algoritma atau metode yang dapat digunakan untuk masalah tersebut.

Salah satu alternatif yang cukup efektif untuk mencari himpunan data yang paling sering muncul (himpunan item sering) dalam kumpulan data yang sangat besar adalah algoritma peningkatan pola sering. Penggalan himpunan item sering dilakukan dengan menghasilkan struktur pohon data, juga dikenal sebagai FP Tree, yang merupakan struktur penyimpanan data yang dimampatkan. FPTree memetakan setiap data transaksi ke dalam setiap lintasan FPTree (Ardianto & Fitriana, 2019).

Collaborative Filtering memiliki kelebihan yang dapat menyelidiki afiliasi yang dapat diandalkan, terutama afiliasi yang dapat berasal dari riwayat keputusan pelanggan, sehingga dengan kelebihan ini, rekomendasi produk yang dihasilkan dapat lebih akurat (Mustofa, 2018).

Algoritma Eclat (Equivalence Class Transformation), menurut Kaur dan Grag (2014), digunakan untuk menemukan itemset yang sering muncul. Pada dasarnya, algoritma Eclat melakukan pencarian depth-first pada database dengan tata letak vertikal. Database yang memiliki tata letak horizontal harus terlebih dahulu diubah menjadi tata letak vertikal.

Berdasarkan uraian di atas penelitian ini dibuat dengan judul “IMPLEMENTASI ALGORITMA FREQUENT PATTERN GROWTH, COLLABORATIVE FILTERING DAN ECLAT UNTUK REKOMENDASI PRODUK PADA PT. JOENoes IKAMULYA”

1.2 Rumusan Masalah

Rumusan masalah yang dapat diambil dalam penelitian ini adalah bagaimana membuat sebuah sistem rekomendasi produk dengan melihat pola pembelian konsumen yang dapat membantu meningkatkan penjualan produk dan menarik minat konsumen.

2. KERANGKA TEORI

2.1. Data Mining

Data mining adalah proses yang memanfaatkan satu atau lebih metode pembelajaran komputer (machine learning) untuk secara otomatis menganalisis dan mengekstraksi pengetahuan (Sianturi, 2018). Pembelajaran berbasis induksi, juga dikenal sebagai definisi, adalah proses pembentukan definisi-definisi konsep umum yang dilakukan dengan melihat contoh spesifik dari konsep yang akan dipelajari. Knowledge Discovery in Databases (KDD) adalah pendekatan saintifik untuk data mining. Di sini, data mining adalah satu langkah dari proses KDD.

2.2. Sistem Rekomendasi

Sistem rekomendasi adalah sebuah aplikasi yang berfungsi untuk memprediksi suatu item yang menarik bagi user, contohnya rekomendasi film, musik, buku, berita dan lain sebagainya.

Dalam sistem rekomendasi, ada dua jenis filtrasi: kolaboratif dan berbasis konten. Filter kolaboratif adalah algoritma sistem rekomendasi yang memberikan rekomendasi berdasarkan data dari pengguna lain. Filter berbasis konten mengumpulkan isi dari profil pengguna, deskripsi produk, atau hal-hal lain yang berhubungan dengan keputusan pengguna untuk membeli item tertentu (Badriyah, Fernando, & Syarif, 2018).

2.3. Knowledge Discovery in Database

Knowledge discovery in database (KDD) adalah proses keseluruhan non-trivial untuk mencari dan mengidentifikasi pola (pattern) dalam data, di mana pola-pola tersebut ditemukan dan diubah secara akurat menjadi informasi yang mudah dipahami. KDD juga didefinisikan sebagai ekstraksi informasi potensial, implisit, dan tidak dikenal dari sekumpulan data (Fajrin & Maulana, 2018).

2.4. Association Rule Mining

Analisis asosiasi, juga disebut sebagai analisis aturan asosiasi, adalah metode data mining yang digunakan untuk menemukan aturan asosiasi antara kombinasi item. Salah satu metode analisis asosiasi adalah dasar dari metode analisis asosiasi lainnya. Analisis pola frekuensi tinggi, juga dikenal sebagai penggalian pola frekuensi tinggi, adalah tahap analisis asosiasi yang menarik perhatian banyak peneliti karena sangat penting untuk menghasilkan algoritma yang efisien. (Abdullah, 2018).

2.5. Minimum Support dan Minimum Confidence

Minimum support yaitu parameter yang digunakan sebagai batasan frekuensi kejadian atau *support count* yang harus dipenuhi suatu kelompok data untuk dapat dijadikan aturan. Untuk mencari nilai *supportcount* dapat ditentukan dengan rumus berikut (Masnur, 2015):

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

Untuk nilai support dari 2 item atau lebih diperoleh dengan rumus:

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

Minimum confidence adalah sebuah parameter yang menjelaskan minimum level dari nilai *confidence* yang harus ditentukan agar dapat terbentuknya suatu aturan asosiasi yang berkualitas. Berikut rumus untuk menentukan nilai *confidence*:

$$\text{Confidence P (B|A)} = \frac{\text{Jumlah Transaksi Mengandung A dan B}}{\text{Jumlah Total Transaksi Mengandung A}}$$

Suatu aturan asosiasi dapat dibentuk dengan mencari kombinasi dari item yang dapat terbentuk dengan *support* lebih besar atau sama dengan minimum support yang ditentukan. Kuat tidaknya aturan asosiasi ditunjukkan berdasarkan *lift ratio* nya. *Lift ratio* merupakan ukuran seberapa pentingna aturan asosiasi. *Lift ratio* dapat dihitung dengan membandingkan nilai *confidence* dengan nilai *benchmark confidence*. *Benchmark confidence* merupakan suatu perbandingan antara jumlah dari semua item consequent terhadap jumlah total dari seluruh transaksi.

$$\text{Benchmark Confidence} = \frac{\text{Item Consequent}}{\text{Total Transaksi}}$$

$$\text{Lift Ratio (A,B)} = \frac{\text{Confidence P (B|A)}}{\text{Support (B)}}$$

Sebuah rule dapat dikatakan valid apabila mempunyai nilai *Lift ratio* > 1, artinya aturan tersebut memiliki manfaat. Nilai *lift ratio* yang semakin tinggi menunjukkan kekuatan asosiasi yang lebih besar.

2.6. Algoritma FP Growth

Algoritma FP-Growth merupakan pengembangan dari algoritma apriori, sehingga kekurangan dari algoritma apriori diperbaiki oleh algoritma FP-Growth. Algoritma apriori memerlukan pembuatan kandidat untuk mendapatkan set item sering, tetapi algoritma FP-Growth tidak perlu membuat kandidat karena menggunakan konsep pembangunan pohon dalam pencarian set item sering, FP-Tree. Dengan menggunakan FP-Tree, mereka dapat langsung mengekalkan set item sering (Idayani, Sutardi, & Muchlis, 2017).

FP-Growth adalah algoritma yang dapat digunakan tanpa menggunakan generasi kandidat untuk menentukan himpunan data yang sering muncul (itemset sering muncul) dalam kumpulan data. Ini adalah evolusi dari algoritma apriori, dan perbedaannya terletak pada akurasi aturannya dan kecepatan scanning database. (Ardani dan Fitriana, 2016).

Metode FP-Growth dibagi menjadi tiga tahap utama yaitu :

1. Tahap pembangkitan conditional pattern base
2. Tahap pembangkitan Fp-tree
3. Tahap pencarian frequent itemset (Larasati, Nasrun, & Ahmad, 2015).

2.7. Collaborative Filtering

Collaborative Filtering menggunakan pendapat pengguna lain untuk memprediksi apa yang mungkin disukai dan diminati pengguna. Kualitas rekomendasi yang diberikan oleh metode ini sangat bergantung pada pendapat pengguna lain (neighbor) tentang suatu item. Belakangan diketahui bahwa kualitas rekomendasi yang diberikan dari metode ini dapat ditingkatkan dengan melakukan reduksi neighbor, yang berarti hanya beberapa pengguna dengan tingkat kesamaan atau kemiripan tertinggi yang dapat dihitung.

Collaborative Filtering memberikan rekomendasi berdasarkan kumpulan pendapat, minat, dan ketertarikan dari beberapa user, yang biasanya diberikan dalam bentuk rating yang diberikan user untuk suatu item. Untuk mendapatkan data rating dari user, ini digunakan dalam sistem rekomendasi. Metode penyaringan kolaboratif terbagi menjadi dua jenis: penyaringan kolaboratif berbasis pengguna, yang juga dikenal sebagai penyaringan memori, dan penyaringan kolaboratif berbasis item, yang juga dikenal sebagai penyaringan model.

Dalam pendekatan kolaborasi berbasis user, sistem memberikan rekomendasi kepada user item-item yang disukai atau dinilai oleh user—user lain yang memiliki banyak kesamaan. Misalnya, jika user a menyukai atau menilai item 1,2 dan 3, dan user b menyukai item 1,2 dan 4, sistem akan merekomendasikan item 3 kepada user b dan item 4 kepada user a. Keunggulan dari pendekatan ini adalah bahwa itu dapat menghasilkan rekomendasi yang sesuai dengan kebutuhan seseorang.

Metode *Collaborative Filtering Item-Based* didasarkan pada kemiripan item. Metode ini didasarkan pada fakta bahwa ada kemiripan antara item yang diberi nilai oleh seorang user dan item yang telah diberi nilai oleh orang lain. Item yang telah diberi nilai oleh user akan berfungsi sebagai patokan untuk mencari sejumlah item lainnya yang memiliki hubungan dengan item yang telah diberi nilai oleh orang lain. Motivasi utama dari metode ini adalah bahwa user akan mendapatkan lebih banyak item.

2.8. Algoritma Eclat

Menurut Samodra, Susanto, dan Raharjo (2015) dalam artikel jurnal teknologi berjudul "Implementasi Algoritma Eclat untuk Pengolahan Pattern Berkala pada Penjualan Barang", algoritma Eclat adalah program yang digunakan untuk menemukan set item yang paling sering keluar. Algoritma ini melakukan pencarian depth first pada kisi bagian dan menemukan dukungan untuk set item dengan memotong daftar transaksi.

Pada algoritma ECLAT, proses pembentukan itemset dimulai dengan mengubah bentuk transaksi. Jika item pada transaksi berbentuk horizontal, maka bentuknya diubah menjadi vertikal dengan menggabungkan daftar TID pada transaksi yang memiliki item yang sama (Saxena & Gadhiya, 2014).

2.9. Website

Menurut (Rukiastindari & Mado, 2019) World Wide Web, atau lebih dikenal sebagai web, adalah suatu layanan sajian informasi yang menggunakan konsep hyperlink (tautan), yang memudahkan surfer (sebutan para pemakai komputer yang melakukan browsing atau penelusuran informasi melalui internet). Keunggulan ini telah menjadikan web sebagai layanan yang paling cepat berkembang.

2.10. Database

Menurut (Setiyowati & Sri Siswanti, 2021) Database adalah kumpulan semua catatan data operasional suatu organisasi atau perusahaan yang disusun dan disimpan di komputer dengan metode tertentu sehingga mampu memberikan informasi terbaik yang dibutuhkan pengguna. Database (basis data), juga dikenal sebagai "pangkalan data", adalah kumpulan data yang disimpan secara sistematis di sebuah perangkat komputer dan dapat diperiksa melalui program komputer yang digunakan untuk mendapatkan informasi dari basis data tersebut. Sistem manajemen basis data, juga dikenal sebagai DBMS, adalah nama perangkat lunak yang digunakan untuk mengelola dan memanggil query basis data.

3. HASIL DAN PEMBAHASAN

3.1. Metode

Metode yang digunakan dalam penelitian ini adalah algoritma *Frequent Collaborative Filtering*, *Eclat*, dan *FP Growth*. Algoritma *Frequent Collaborative Filtering* digunakan untuk mencari pola pembelian konsumen dan memberikan rekomendasi produk yang umum dibeli oleh konsumen lainnya. Algoritma *Eclat* digunakan untuk mencari item-item yang muncul pada rekomendasi yang diberikan kepada pengguna. Sedangkan algoritma *FP Growth* digunakan untuk menggali frequent itemset yang paling sering muncul dalam data transaksi.

3.2. Implementasi Algoritma *FP Growth*

Pada tahap ini dilakukan penambangan data yang merupakan hasil dari pra-proses yang akan diolah oleh sistem. Pengujian yang dilakukan menggunakan minimum support 5% dan minimum confidence 35%.

3.2.1. Pembentukan Itemset

Itemset merupakan kumpulan item yang memenuhi syarat *minimum support* yang dibentuk dalam sebuah tabel. Berikut *Itemset* dari setiap pengujian.

Itemset 1

Tabel 1. *Itemset 1* dengan *min support* 5%

No	Item List	Jumlah	Support
1	PORSTEX WL500MLX12	9	42.86
2	PORSTEX WL1000MLX12	8	38.1
3	PORSTEX WB1000MLX12	5	23.81
4	DD SHAMPO GRAPE 125MLX24 BTL	4	19.05
5	PORSTEX WB500MLX12	4	19.05
6	PORSTEX REGF.LILAC 700MLX12	3	14.29
7	FACIAL W STRW 50GRX24	3	14.29
8	DD SHAMPOSTRAW 125MLX24	3	14.29
9	HAND SOAP PREM G.TEA 375MLX24	3	14.29
10	PORSTEX WB2000MLX6	3	14.29
11	PORSTEX WL2000MLX6	3	14.29
12	PORSTEX REGO.BLUE 700MLX12	3	14.29
13	DD SHAMPOSTRW 45MLX72	2	9.52
14	HAND SOAPLEMON 375MLX24	2	9.52
15	HAND SOAP STRAWBERRY 375MLX24	2	9.52
16	DD SHAMPOORANGE 125MLX24	2	9.52
17	FACIAL W GRAPE 50GRX24 TUBE	2	9.52
18	FACIAL W ORG50GRX24 TUBE	2	9.52
19	DD SHAMPOSTRW (P) 250MLX12	2	9.52
20	SHAMPO STRW 200MLX24 POUCH	2	9.52
21	GLASS CLNFRSH BLUE 500MLX12 SPRAY	2	9.52
22	DD PKT2T.BRUSH	2	9.52
23	DD SHAMPOAPPLE 125MLX24	2	9.52
24	YURI DISINFECTANT SPRAY 500ML X 12	2	9.52

Pada tabel 1 terlihat *Itemset 1* yang lolos berjumlah 24 item yang nilai *supportnya* melebihi atau sama dengan *minimum support count* pada pengujian *minimum support 5%*. Untuk membentuk *Itemset 1* dapat menggunakan rumus berikut:

$$\text{Support} = \frac{\text{Jumlah Transaksi untuk Porstek WL}}{\text{Total Transaksi}}$$

$$\text{Support} = \frac{9}{21} = 0,4286 = 42,86$$

Itemset 2

Tabel 2. *Itemset 2* dengan *min support 5%* dan *minimal confidence 35%*

No	Item1 –Item2	Jumlah	Support	Confident
1	PORSTEX WL500MLX12- PORSTEX WL 1000MLX12	5	23.81	55.56
2	PORSTEX WL500MLX12- PORSTEX WB 1000MLX12	4	19.05	44.44
3	PORSTEX WL 500MLX12-DD SHAMPO GRAPE 125MLX24 BTL	4	19.05	44.44
4	PORSTEX WL 500MLX12- PORSTEX WB 500MLX12	4	19.05	44.44
5	PORSTEX WL 1000MLX12- PORSTEX WB 1000MLX12	4	19.05	50
6	PORSTEX WL 1000MLX12- DD SHAMPO GRAPE 125MLX24 BTL	3	14.29	37.5
7	PORSTEX WL 1000MLX12- PORSTEX WB 500MLX12	3	14.29	37.5
8	PORSTEX WB 1000MLX12- PORSTEX WB 500MLX12	2	9.52	40
9	PORSTEX WB 1000MLX12- PORSTEX WB 2000MLX6	2	9.52	40
10	PORSTEX WB 1000MLX12- PORSTEX REG O.BLUE 700MLX12	2	9.52	40
11	DD SHAMPO GRAPE 125MLX24 BTL-PORSTEX WB 500MLX12	2	9.52	50
12	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO STRAW 125MLX24	3	14.29	75
13	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO ORANGE 125MLX24	2	9.52	50
14	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO STRW (P) 250MLX12	2	9.52	50
15	DD SHAMPO GRAPE 125MLX24 BTL-DD PKT2 T.BRUSH	2	9.52	50
16	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO APPLE 125MLX24	2	9.52	50
17	PORSTEX WB 500MLX12- FACIAL W STRW 50GRX24	2	9.52	50
18	PORSTEX WB 500MLX12-DD SHAMPO STRAW 125MLX24	2	9.52	50
19	PORSTEX WB 500MLX12-DD SHAMPO STRW (P) 250MLX12	2	9.52	50
20	DD SHAMPO STRAW 125MLX24-DD SHAMPO	2	9.52	66.67

	STRW (P) 250MLX12			
21	DD SHAMPO STRAW 125MLX24-DD PKT2 T.BRUSH	2	9.52	66.67
22	DD SHAMPO STRAW 125MLX24-DD SHAMPO APPLE 125MLX24	2	9.52	66.67
23	DD PKT2 T.BRUSH-DD SHAMPO APPLE 125MLX24	2	9.52	100

Pada tabel 2 terlihat 23 *frequent itemset* terbentuk dari 2 *itemset* dengan nilai *support* 5% dan *confidence* 35%. 23 *item* diatas adalah *item* yang memenuhi *minimum support* dan *minimum confidence*. Untuk perhitungan pada *itemset* 2 menggunakan rumus berikut:

$$Support = \frac{5}{21} = 0,2381 = 23,81$$

Sedangkan untuk perhitungan nilai *confidence* pada *itemset* 2 didapat menggunakan rumus sebagai berikut:

$$Confidence = \frac{5}{9} = 0,5556 = 55,56$$

Itemset 3

Tabel 3. *Itemset* 3 dengan *min support* 5% dan *minimal confidence* 35%

No	Item1 -Item2 -Item3	Jumlah	Support	Confident
1	DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12- DD SHAMPO STRAW 125MLX24	2	9.52	100
2	DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12- DD SHAMPO STRW (P) 250MLX12	2	9.52	100
3	DD SHAMPO GRAPE 125MLX24BTL-DD PKT2 T.BRUSH- DD SHAMPO APPLE 125MLX24	2	9.52	100
4	PORSTEX WB 500MLX12- DD SHAMPO STRAW 125MLX24- DD SHAMPO STRW (P) 250MLX12	2	9.52	100
5	DD SHAMPO STRAW 125MLX24- DD PKT2 T.BRUSH- DD SHAMPO APPLE 125MLX24	2	9.52	100

Pada tabel 3 terlihat ada 5 *frequent item* yang terbentuk dari 3 *itemset*. 5 *frequent item* diatas adalah *item* yang memenuhi *minimum support* dan *minimum confidence*. Pada *frequent item* ke 2 terlihat jika membeli DD Shampo Grape 125MLX24BTL dan Porstex WB 500MLX12 maka akan membeli DD Shampo Straw 125MLX24.

$$Support = \frac{2}{21} = 0,0952 = 9,25$$

$$Confidence = \frac{2}{2} = 1 = 100$$

3.2.2. Aturan Asosiasi

Aturan asosiasi adalah sebuah fungsi untuk dapat menemukan kombinasi item berdasarkan *frequent itemset* yang dibentuk sebelumnya. Untuk mengetahui keakuratan suatu aturan asosiasi dapat ditentukan dengan mengetahui nilai *lift ratio* nya. Untuk menghitung nilai *lift ratio* didapat dengan perhitungan *benchmark confidence* dengan total transaksi yang ada pada data yang digunakan. Berikut merupakan aturan asosiasi yang terbentuk dari setiap pengujian yang dilakukan oleh system.

Minimum support 5% dan *minnum confidence* 35%

Tabel 4. Aturan asosiasi dengan *min support* 5% dan *min confidence* 35%

No	Item1 - Item2 - Item3	Confident	Lift Ratio
1	DD SHAMPO GRAPE 125MLX24 BTL-PORSTEXWB 500MLX12-DD SHAMPO STRAW 125MLX24	100	10.5 %
2	DD SHAMPO GRAPE 125MLX24 BTL-PORSTEXWB 500MLX12-DD SHAMPO STRW (P) 250MLX12	100	10.5 %
3	DD SHAMPO GRAPE 125MLX24 BTL-DD PKT2 T.BRUSH-DD SHAMPO APPLE 125MLX24	100	10.5 %
4	PORSTEX WB 500MLX12-DD SHAMPO STRAW 125MLX24-DD SHAMPO STRW (P) 250MLX12	100	10.5 %
5	DD SHAMPO STRAW 125MLX24-DD PKT2 T.BRUSH-DD SHAMPO APPLE 125MLX24	100	10.5 %

Pada tabel 4 merupakan hasil dari aturan asosiasi dengan *minimum support* 5% dan *minimum confidence* 35%. Jumlah aturan yang terbentuk sebanyak 5 aturan dan dapat dikatakan valid karena nilai *lift rationya* > 1.

3.3 Implementasi Algoritma Eclat

Pada tahap ini dilakukan penambangan data yang merupakan hasil dari pra proses yang akan diolah oleh sistem. Pengujian yang dilakukan menggunakan *minimum support* 5% dan *minimum confidence* 35%.

3.3.1 Pembentukan Itemset

Itemset merupakan kumpulan item yang memenuhi syarat *minimum support* yang dibentuk dalam sebuah tabel. Berikut *itemset* dari setiap pengujian.

Itemset 1

Tabel 5. *Itemset* 1 dengan *support* 5%

No	Item List	Jumlah	Support
1	PORSTEX WL1000MLX12	8	38.1
2	PORSTEX REGF.LILAC	3	14.29

	700MLX12		
3	DD SHAMPOSTRW 45MLX72	2	9.52
4	PORSTEX WL500MLX12	9	42.86
5	HAND SOAP LEMON 375MLX24	2	9.52
6	HAND SOAP STRAWBERRY 375MLX24	2	9.52
7	DD SHAMPO GRAPE 125MLX24 BTL	4	19.05
8	DD SHAMPOORANGE 125MLX24	2	9.52
9	FACIAL W GRAPE 50GRX24 TUBE	2	9.52
10	FACIAL W ORG50GRX24 TUBE	2	9.52
11	PORSTEX WB500MLX12	4	19.05
12	FACIAL W STRW 50GRX24	3	14.29
13	DD SHAMPOSTRAW 125MLX24	3	14.29
14	DD SHAMPOSTRW (P) 250MLX12	2	9.52
15	SHAMPO STRW 200MLX24POUCH	2	9.52
16	GLASS CLNFRSH BLUE 500MLX12SPRAY	2	9.52
17	HAND SOAPPREM G.TEA 375MLX24	3	14.29
18	PORSTEX WB2000MLX6	3	14.29
19	PORSTEX WL2000MLX6	3	14.29
20	DD PKT2T.BRUSH	2	9.52
21	DD SHAMPO APPLE 125MLX24	2	9.52
22	PORSTEX WB1000MLX12	5	23.81
23	PORSTEX REGO.BLUE 700MLX12	3	14.29
24	YURI DISINFECTANT SPRAY 500MLX 12	2	9.52

Pada tabel 5 terlihat *itemset* I terdapat 24 item yang nilai nya memenuhi atau sama dengan *minimum support* 5% dalam pengujian.

Itemset 2

Tabel 6. *Itemset 2* dengan *min support* 5% dan *confidence* 35%.

No	Item1 -Item2	Jumlah	Support	Confident
1	PORSTEX WL 1000MLX12- PORSTEX WL 500MLX12	5	23.81	62.5
2	PORSTEX WL 1000MLX12- DD SHAMPO GRAPE 125MLX24 BTL	3	14.29	37.5
3	PORSTEX WL 1000MLX12- PORSTEX WB 500MLX12	3	14.29	37.5
4	PORSTEX WL 1000MLX12- PORSTEX WB 1000MLX12	4	19.05	50

5	PORSTEX WL 500MLX12- DD SHAMPO GRAPE 125MLX24 BTL	4	19.05	44.44
6	PORSTEX WL 500MLX12- PORSTEX WB 500MLX12	4	19.05	44.44
7	PORSTEX WL 500MLX12- PORSTEX WB 1000MLX12	4	19.05	44.44
8	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO ORANGE 125MLX24	2	9.52	50
9	DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12	2	9.52	50
10	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO STRAW 125MLX24	3	14.29	75
11	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO STRW (P) 250MLX12	2	9.52	50
12	DD SHAMPO GRAPE 125MLX24 BTL-DD PKT2 T.BRUSH	2	9.52	50
13	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO APPLE 125MLX24	2	9.52	50
14	PORSTEX WB 500MLX12- FACIAL W STRW 50GRX24	2	9.52	50
15	PORSTEX WB 500MLX12- DD SHAMPO STRAW 125MLX24	2	9.52	50
16	PORSTEX WB 500MLX12- DD SHAMPO STRW (P) 250MLX12	2	9.52	50
17	PORSTEX WB 500MLX12- PORSTEX WB 1000MLX12	2	9.52	50
18	DD SHAMPO STRAW 125MLX24- DD SHAMPO STRW (P) 250MLX12	2	9.52	66.67
19	DD SHAMPO STRAW 125MLX24- DD PKT2 T.BRUSH	2	9.52	66.67

20	DD SHAMPO STRAW 125MLX24- DD SHAMPO APPLE 125MLX24	2	9.52	66.67
21	PORSTEX WB 2000MLX6- PORSTEX WB 1000MLX12	2	9.52	66.67
22	DD PKT2 T.BRUSH- DD SHAMPO APPLE 125MLX24	2	9.52	100
23	PORSTEX WB 1000MLX12- PORSTEX REG O.BLUE 700MLX12	2	9.52	40

Pada tabel 6 terlihat pembentukan *itemset* 2 membuat hasil dengan 23 item yang nilai nya sama atau lebih dari *minimum support* 5% dan *minimum confidence* 35%.

Itemset 3

Tabel 7. *Itemset* 3 dengan *min support* 5% dan *confidence* 35%

No	Item1 -Item2 -Item3	Jumlah	Support	Confident
1	DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12-DD SHAMPO STRAW 125MLX24	2	9.52	100
2	DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12-DD SHAMPO STRW (P) 250MLX12	2	9.52	100
3	DD SHAMPO GRAPE 125MLX24 BTL-DD PKT2 T.BRUSH-DD SHAMPO APPLE 125MLX24	2	9.52	100
4	PORSTEX WB 500MLX12-DD SHAMPO STRAW 125MLX24-DD SHAMPO STRW (P) 250MLX12	2	9.52	100
5	DD SHAMPO STRAW 125MLX24- DD PKT2 T.BRUSH- DD SHAMPO APPLE 125MLX24	2	9.52	100

Terlihat pada tabel 7, *frequent item* yang terbentuk dari *itemset* 3 yaitu 5 item dengan nilai yang memenuhi *minimum support* dan *minimum confidence*. Pada item1 terlihat jika membeli DD Shampo Grape 125MLX24 BTL dan Porstex WB 500MLX12 maka akan membeli DD ShampoStraw 125MLX24.

Itemset 4

Tabel 8. Itemset 4 dengan *min support* 5% dan *confidence* 35%

No	Item1 -Item2 -Item3 - Item4	Jumlah	Support	Confident
1	PORSTEX WL 1000MLX12- PORSTEX WL 500MLX12- DD SHAMPO STRAW 125MLX24- DD SHAMPO STRW (P) 250MLX12	2	9.52	100
2	PORSTEX WL 1000MLX12- DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12- DD SHAMPO STRAW 125MLX24	2	9.52	100
3	PORSTEX WL 1000MLX12- DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12- DD SHAMPO STRW (P) 250MLX12	2	9.52	100
4	PORSTEX WL 1000MLX12- DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO STRAW 125MLX24- DD SHAMPO STRW (P) 250MLX12	2	9.52	100
5	PORSTEX WL 1000MLX12- PORSTEX WB 500MLX12- DD SHAMPO STRAW 125MLX24- DD SHAMPO STRW (P) 250MLX12	2	9.52	100
6	PORSTEX WL 500MLX12- DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12- DD SHAMPO STRAW 125MLX24	2	9.52	100
7	PORSTEX WL 500MLX12- DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12- DD SHAMPO STRW (P) 250MLX12	2	9.52	100
8	PORSTEX WL 500MLX12- DD SHAMPO GRAPE 125MLX24 BTL-DD PKT2 T.BRUSH- DD SHAMPO APPLE 125MLX24	2	9.52	100

9	PORSTEX WL 500MLX12- PORSTEX WB 500MLX12- DD SHAMPO STRAW 125MLX24- DD SHAMPO STRW (P) 250MLX12	2	9.52	100
10	DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12- DD SHAMPO STRAW 125MLX24- DD SHAMPO STRW (P) 250MLX12	2	9.52	100
11	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO STRAW 125MLX24- DD PKT2 T.BRUSH- DD SHAMPO APPLE 125MLX24	2	9.52	100

Terlihat pada tabel 8 diatas *itemset* 4 membentuk 11 item dari *minimum support* 5% dan *minimum confidence* 35%. 11 item tersebut nilai nya memenuhi dari *minimum support* dan *minimum confidence*. Pada item1 memiliki pola yaitu jika membeli Porstex WL 1000MLX12, Porstex WL 500MLX12 dan DD Shampo Straw 125MLX24 makaakan membeli DD Shampo Straw (P) 250MLX12.

3.3.2 Aturan Asosiasi

Minimum support 5% dan *minmum confidence* 35%

Tabel 9. Aturan asosiasi dengan *min support* 5% dan *min confidence* 35%

No	Item1 - Item2 -Item3 - Item4	Confident	Lift Ratio
1	PORSTEX WL 1000MLX12- PORSTEX WL 500MLX12-DD SHAMPO STRAW 125MLX24-DD SHAMPO STRW (P)250MLX12	100	10.5 %
2	PORSTEX WL 1000MLX12-DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12-DD SHAMPO STRAW 125MLX24	100	10.5 %
3	PORSTEX WL 1000MLX12-DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12-DD SHAMPO STRW (P) 250MLX12	100	10.5 %
4	PORSTEX WL 1000MLX12-DD SHAMPO GRAPE 125MLX24 BTL- DD SHAMPO STRAW 125MLX24- DD SHAMPO STRW (P) 250MLX12	100	10.5 %
5	PORSTEX WL 1000MLX12- PORSTEX WB 500MLX12-DD SHAMPO STRAW 125MLX24-DD SHAMPO STRW (P) 250MLX12	100	10.5 %
6	PORSTEX WL 500MLX12-DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12-DD SHAMPO STRAW 125MLX24	100	10.5 %
7	PORSTEX WL 500MLX12-DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12-DD SHAMPO STRW (P) 250MLX12	100	10.5 %
8	PORSTEX WL 500MLX12-DD SHAMPO GRAPE 125MLX24 BTL- DD PKT2 T.BRUSH-DD SHAMPO APPLE 125MLX24	100	10.5 %

9	PORSTEX WL 500MLX12- PORSTEX WB 500MLX12-DD SHAMPO STRAW 125MLX24-DD SHAMPO STRW (P) 250MLX12	100	10.5 %
10	DD SHAMPO GRAPE 125MLX24 BTL- PORSTEX WB 500MLX12-DD SHAMPO STRAW 125MLX24-DD SHAMPO STRW (P) 250MLX12	100	10.5 %
11	DD SHAMPO GRAPE 125MLX24 BTL-DD SHAMPO STRAW 125MLX24-DD PKT2 T.BRUSH-DD SHAMPO APPLE 125MLX24	100	10.5 %

3.4 Implementasi Collaborative Filtering

Metode Collaborative Filtering dihitung dengan menggunakan data rating produk sebagai variabel utama tetapi pada kali ini penggunaan datanya memanfaatkan kuantitas jumlah pembelian dari pelanggan lainnya. Jumlah pembelian didapatkan secara eksplisit dari sistem. Sistem akan mengolah data tersebut mulai dari jumlah barang yang paling sedikit hingga paling banyak dengan menggunakan skala satu sampai seterusnya. Data digunakan untuk memperoleh perhitungan statistik yang hasilnya menunjukkan produk yang jumlahnya paling banyak dibeli.

Tabel 10. Bobot Prediksi

#	C 1	C 2	C 3	C 4	C 5	C 6	C 7	C 8	C 9	C 10	C 11	C 12	C 13	C 14	C 15	C 16	C 17	C 18	C 19	C 20
B- AGA3 81	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B- AGA3 83	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B- AGA3 84	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
B- BIO6	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
B- BIOH J427	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B- DDM GV97	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
B- DDMS 97	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
B- DDPG 13A	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B- DDPG 14B	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B- DDPO 13A	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
B- DDPS 13A	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	0	0	0	0	0
B- DDPS 14B	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
B- DDPS 15B	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
B- DDR6 7A	1	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	0	0

B-DDRA 67A	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
B-DDRO 67A	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B-DDRS 67A	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	0	0
B-DDRS 75	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B-DDSA 12	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
B-DDSG 12	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
B-DDSO 12	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
B-DPS	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
B-DPW G91	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
B-DPW O91	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
B-DPWS 91	0	0	1	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0
B-DSG1 64	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
B-DTPS 18	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
B-GLA3 26	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B-GLA3 26.	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B-GLA3 28	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B-GLA3 30	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B-HSA3 04	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B-HSA3 08	0	1	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B-HSA3 09	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B-HSP24 6	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B-HSP24 7	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B-HSP24 8	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
B-HSP24 9	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
B-HSP27 A	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B-HSP27 C	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B-HSP27 E	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B-HSR2 27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0

B- HSR2 28	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0
B- HSR2 31	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0
B- LYS33	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B- MAT3 61	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B- MAT3 63	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B- POR2 97	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
B- POR3 7	1	1	1	0	1	0	0	1	0	1	0	1	0	0	0	0	0	1	0	1	0
B- POR3 9	0	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0
B- POR5 4	1	1	0	0	0	1	1	0	1	1	1	0	0	0	0	1	0	0	0	0	0
B- POU4 0	0	1	1	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0
B- POU4 2	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0
B- POU5 5	0	1	0	0	0	1	1	0	0	0	1	0	0	0	0	0	0	0	0	0	1
B- PSR80	0	1	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
B- PSRL 79	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	1	0	0	0
B- TAF3 24	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
B- YDS3 70	0	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0

Berdasarkan data diatas, didapatkan nilai bahwa sistem akan merekomendasikan khusus kepada customer 20 untuk membeli Porstex WL 500MLX12 (POR37) dan Porstex WB 1000MLX12 (POU55). Rekomendasi terbentuk dari hasil transaksi yang pernah dilakukan oleh customer 20.

4. KESIMPULAN

Berdasarkan hasil dari penelitian dan pengujian yang dilakukan menggunakan metode *Algoritma FP Growth*, *collaborative filtering* dan *eclat* pada data transaksi penjualan produk sabun dapat disimpulkan sebagai berikut:

Sistem rekomendasi produk kepada customer merupakan salah satu strategi yang tepat agar dapat meningkatkan penjualan produk. Dengan menggunakan *Algoritma FP Growth*, *collaborative filtering* dan *eclat* dapat membantu sistem rekomendasi dalam mencari peluang kemungkinan barang yang akan dibeli oleh customer.

Penelitian yang dilakukan menggunakan perhitungan *Algoritma FP Growth* dan *eclat* dengan *minimum support* 5%, 6%, 8% dan *minimum confidence* 35%, 45%, 55%, menghasilkan beberapa *itemset* dan akan terbentuk *frequent itemset*. Dari hasil *frequent itemset* tersebut maka akan menentukan semakin tinggi nilai dari *minimum support* dan *confidence* yang diuji, semakin sedikit jumlah *itemset*. Untuk perhitungan *collaborative filtering* menghasilkan nilai pengurutan rekomendasi khusus kepada pelanggan berdasarkan kuantitas jumlah pembelian dari pelanggan lain.

UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih yang sebesar-besarnya atas bantuan, dukungan, dan kontribusi yang telah diberikan dalam penyelesaian jurnal ini. Tanpa bantuan dari berbagai pihak, penulisan jurnal ini tidak akan menjadi mungkin.

DAFTAR PUSTAKA

- Abdullah, A. (2018). Rekomendasi Paket Produk Guna Meningkatkan Penjualan Dengan Metode FP- Growth. *Khazanah Informatika*.
- Abdulloh, R. (2018). *7 in 1 Pemrograman Web untuk Pemula*. Jakarta: PT. Elex Media Komputindo.
- Ardani, N. R., & Fitriana, N. (2016). SISTEM REKOMENDASI PEMESANAN SPAREPART DENGAN ALGORITMA FP- GROWTH (STUDI KASUS PT. ROSALIA SURAKARTA). *Seminar Nasional Teknologi Informasi dan Multimedia*.
- Ardianto, A., & Fitriana, D. (2019). Penerapan Algoritma FP-Growth Rekomendasi Trend Penjualan ATK Pada CV. Fajar Sukses Abadi. *Jurnal Telekomunikasi dan Komputer*.
- Badriyah, T., Fernando, R., & Syarif, I. (2018). Sistem Rekomendasi ContentBased Filtering Menggunakan Algoritma Apriori. *Konferensi Nasional Sistem Informasi*.
- Fajrin, A. F., & Maulana, A. (2018). PENERAPAN DATA MINING UNTUK ANALISIS POLA PEMBELIAN KONSUMEN DENGAN ALGORITMA FP- GROWTH PADA DATA TRANSAKSI PENJUALAN SPARE PART MOTOR. *Kumpulan jurnal Ilmu Komputer (KLIK)*.
- Hasanah, F. N., & Untari, R. S. (2020). Buku Ajar Rekayasa Perangkat Lunak. Sidoarjo: UMSIDA Press.
- Idayani, R., Sutardi, & Muchlis, F. (2017). PERANCANGAN APLIKASI DATA WAREHOUSE MENGGUNAKAN METODE FP- GROWTH UNTUK MEMREDIKSI PENJUALAN ALAT-ALAT KESEHATAN (STUDI KASUS : APOTEK KIMIA FARMA KOREM). *semanTIK*.
- Kaur, M., & Grag, U. (2014). ECLAT Algorithm for Frequent Itemsets Generation . *International Journal of Computer Systems*.
- Kavitha, & Selvi, T. (2016). Comparative Study on Apriori Algorithm and FpGrowth Algorithm with Pros and Cons. *International Journal of Computer Science Trends and Technology (IJCS T)*.
- Larasati, D. P., Nasrun, M., & Ahmad, U. A. (2015). ANALISIS DAN IMPLEMENTASI ALGORITMA FP- GROWTH PADA APLIKASI SMART UNTUK MENENTUKAN MARKET BASKET ANALYSIS PADA USAHA RETAIL (STUDI KASUS : PT.X). *e-Proceeding of Engineering*.
- Masnur, A. (2015). Analisa Data Mining Menggunakan Market Basket Analysis untuk Mengetahui Pola Beli Konsumen. *SATIN*.
- Mustofa, A. R. (2018). SISTEM REKOMENDASI WISATA DI KEDIRI MENGGUNAKAN METODE ITEM BASE COLLABORATIVE FILTERING. *Universitas Islam Negri Maulana Malik Ibrahim* .
- Novendri, M. S., Saputra, A., & Firman, C. E. (2019). APLIKASI INVENTARIS BARANG PADAMTS NURUL ISLAM DUMAI MENGGUNAKAN PHP DAN MYSQL. *Lentera Dumai*.
- Rozi, Z. A., & SmitDev. (2015). *Bootstrap Design Framework*. Jakarta: PT. Elex Media Komputindo.
- Rudjiono, D., & Saputro, H. (2020). PENGEMBANGAN DESAIN WEBSITE SEBAGAI MEDIA INFORMAS DAN PROMOSI (Studi Kasus: PT.Nada Surya Tunggal Kecamatan Pringapus). *JURNAL ILMIAH KOMPUTER GRAFIS*.
- Rukiastindari, S., & Mado, Y. U. (2019). Rancang Bangun Aplikasi Penjualan Perlengkapan Olahraga (Studi Toko Baratha Sports). *Jurnal Teknik Komputer AMIK BSI*.
- Salamah, U. G. (2021). *Tutorial Visual Studio Code*. Bandung: Media Sains Indonesia.
- Samodra, J. E., Susanto, B., & Raharjo, W. S. (2015). IMPLEMENTASI ALGORITMA ECLAT UNTUK FREQUENT PATTERN MINING PADA PENJUALAN BARANG. *Jurnal Teknologi Media Teknika*.
- Sasmito, G. W. (2017). Penerapan Metode Waterfall Pada Desain Sistem Informasi Geografis Industri Kabupaten Tegal. *Jurnal Informatika: Jurnal Pengembangan IT (JPIT)*.
- Saxena, A., & Gadhiya, S. (2014). A Survey on Frequent Pattern Mining Methods Apriori, Eclat, FP growth. *International Journal of Engineering Development and Research*.
- Setiawan, D. (2017). *Buku Sakti Pemrograman Web: HTML, CSS, PHP, MySQL & Javascript*. Anak Hebat Indonesia.
- Setiyowati, & S. S. (2021). Perancangan Basis Data & Pengenalan SQL Server Management Studio. Semarang: Lembaga Penelitian dan Pengabdian pada Masyarakat Universitas Dian Nuswantoro.
- Sianturi, F. A. (2018). PENERAPAN ALGORITMA APRIORI UNTUK PENENTUAN TINGKAT PESANAN. *Jurnal Mantik Penusa*.
- Sukanto, R. A., & Shalahuddin, M. (2015). *Rekayasa perangkat lunak : terstruktur dan berorientasi objek*. Bandung: Informatika Bandung.
- Tohari, H. (2014). *Astah : analisis serta perancangan sistem informasi melalui pendekatan uml*. Yogyakarta: ANDI.
- Wijaya, A. E., & Alfian, D. (2018). SISTEM REKOMENDASI LAPTOP MENGGUNAKAN COLLABORATIVE FILTERING DAN CONTENT-BASED FILTERING. *Jurnal Computech & Bisnis*.
- Yurindra. (2017). *Software Engineering*. Yogyakarta: Deepublish.
-