

Penentuan Rekomendasi Paket Promosi Menggunakan Algoritma *Frequent Pattern Growth* Di *The Javanese Café*

Dwi Astuti^[1], Samsinar^{[2]*}

Program Studi Sistem Informasi, Fakultas Teknologi Informasi^{[1], [2]}
Universitas Budi Luhur
Jakarta, Indonesia

dwiastuti0603@gmail.com^[1], samsinar@budiluhur.ac.id^{[2]*}

Abstract— *Data analysis and processing is very important to support business development. One example is The Javanese Café which requires analysis and processing to determine promotional menu package recommendations. To carry out data analysis and processing, of course you need technology to make these activities easier. The technology that can be used to overcome this problem is data mining. Data mining has an association rule method which functions to form association patterns. Researchers also use the FP-Growth algorithm to speed up the data processing process. The sales transaction data processing resulted in 14 association patterns with the highest confidence values and 9 menu items with the lowest support values. Then the results were analyzed again and produced 4 recommendations for promotional menu packages that could be used to support product marketing strategies.*

Keywords— *Data Mining, Association Rule, FP-Growth, Purchase Pattern*

Abstrak— Analisis dan pengolahan data sangatlah penting untuk mendukung perkembangan bisnis. Salah satu contohnya pada *The Javanese Café* yang membutuhkan analisa dan pengolahan untuk menentukan rekomendasi paket menu promosi. Untuk melakukan analisis dan pengolahan data tentunya membutuhkan sebuah teknologi agar dapat mempermudah kegiatan tersebut. Teknologi yang dapat dimanfaatkan untuk mengatasi permasalahan tersebut adalah data mining. Data mining mempunyai metode *association rule* yang berfungsi untuk membentuk pola asosiasi. Peneliti juga memanfaatkan algoritma *FP-Growth* untuk mempercepat proses pengolahan data. Dari proses pengolahan data transaksi penjualan, menghasilkan 14 pola asosiasi dengan nilai *confidence* tertinggi dan 9 item menu dengan nilai *support* terendah. Kemudian hasil tersebut dianalisa kembali dan menghasilkan 4 rekomendasi paket menu promosi yang dapat digunakan untuk menunjang strategi pemasaran produk.

Kata Kunci— *Data Mining, Association Rule, FP-Growth, Pola Pembelian*

I. PENDAHULUAN

Era globalisasi saat ini telah melahirkan banyak bisnis baru dan tingkat persaingan yang tinggi, salah satunya adalah usaha di bidang kuliner. Usaha ini sangat menjanjikan karena kebutuhan pangan konsumen semakin hari semakin meningkat [1]. Untuk menghadapi persaingan bisnis yang tinggi, pelaku bisnis harus merancang berbagai taktik

pemasaran agar kelangsungan bisnis terjaga. Salah satu cara agar bisnis tetap kompetitif dengan para pesaing adalah melalui promosi. Sebagai salah satu bentuk pemasaran [2], promosi bertujuan untuk mewujudkan peningkatan kesadaran terhadap produk, mengembangkan preferensi merek di pasar sasaran, mengoptimalkan pemasaran dan pangsa pasar, mendorong pembelian berulang produk yang sama, memperkenalkan produk baru serta memikat pembeli baru [3].

The Javanese Café merupakan suatu usaha yang lahir akibat perkembangan bisnis di bidang kuliner. Tingginya tingkat persaingan menyebabkan penurunan penjualan pada *The Javanese Café*, sehingga pihak *supervisor cafe* ingin melakukan promosi secara berkala untuk meningkatkan penjualan. Namun, untuk melakukan tindakan tersebut, manajemen tidak mempunyai acuan untuk memilih item menu yang akan ditawarkan kepada pelanggan. Oleh karena itu, untuk mengatasi permasalahan tersebut perlu dilakukan pengolahan dan analisis terhadap data transaksi penjualan. Dalam melakukan pengolahan dan analisis data membutuhkan sebuah teknologi untuk mempermudah serta mempercepat kegiatan tersebut. Teknologi yang dapat dimanfaatkan sebagai solusi dari permasalahan tersebut adalah *data mining*.

Data mining adalah serangkaian proses yang menghasilkan wawasan baru dengan menggali sejumlah data besar untuk menemukan pola dan aturan tertentu [4]. Teknik dalam *data mining* yang dapat dimanfaatkan untuk mengatasi masalah pada penelitian ini adalah *association rule*. Teknik asosiasi berfungsi untuk mendeteksi pola yang paling kerap muncul dalam himpunan *itemset* [5]. Proses analisis menggunakan bantuan algoritma *FP-Growth* untuk membuat aturan asosiasi dalam bentuk “*If Then*”. Algoritma *FP-Growth* merupakan salah satu algoritma yang bisa diimplementasikan pada teknik *association rules*. Fungsi algoritma *FP-Growth* yaitu untuk mengidentifikasi item yang paling kerap muncul pada himpunan data dalam sebuah *database* [6].

Terdapat beberapa penelitian terdahulu terkait penetapan promosi produk dengan memanfaatkan algoritma

FP-Growth, yaitu penelitian yang dilakukan oleh [7] menghasilkan 2 rule yang mempunyai nilai *confidence* 79,1 % dan 58,8%. Sedangkan penelitian yang dilakukan [8] mempunyai hasil 3 rule yang semua nilai *confidence* 100%. Algoritma *FP-Growth* diterapkan pada penelitian ini karena untuk memperoleh *frequent itemset* tidak membutuhkan *generate candidate*, melainkan memanfaatkan konsep penyusunan *tree*, sehingga proses pengolahan data lebih cepat.

Tujuan penelitian ini adalah mengidentifikasi pola pembelian pada data transaksi penjualan *The Javanese Cafe* menggunakan algoritma *Frequent Pattern Growth (FP-Growth)* sebagai acuan untuk menentukan rekomendasi menu promosi. Sehingga pola yang dihasilkan diharapkan dapat membantu perusahaan untuk mendapatkan rekomendasi menu promosi.

II. METODE PENELITIAN

A. Metode Pengumpulan Data

Data yang digunakan pada penelitian ini berasal dari data sekunder, yang bersumber dari data transaksi penjualan *The Javanese Café* periode Bulan Maret 2022 sampai Bulan Maret 2023 dengan jumlah 6.674 record. Data sekunder merupakan data yang sengaja dikumpulkan untuk memberikan informasi berupa dokumentasi seperti catatan atau gambar [9]. Pada data transaksi penjualan *The Javanese Café* terdapat 9 atribut, yang terdiri dari *id* transaksi, tanggal, waktu, nama produk, jumlah, kategori produk, nominal, pembayaran dan nama *merchant* yang dapat dilihat pada Tabel 1 berikut:

TABEL I. SAMPEL DATA TRANSAKSI PENJUALAN

ID Transaksi	Tanggal	Waktu	Nama Produk	Jumlah	Kategori Produk	Nominal	Pembayaran	Nama Merchant
46766829	01/03/2022	14:22:07	Blood Vampire	1	Fresh	Rp15.000	Cash	Javanese Cafe
46766829	01/03/2022	14:22:07	Javanese Sampler	1	Canulin	Rp11.000	Cash	Javanese Cafe
46769033	01/03/2022	14:47:50	Blue Ocean	1	Fresh	Rp12.000	Cash	Javanese Cafe

B. Data Preprocessing

Sebelum dataset diolah menggunakan *tools*, terdapat beberapa kegiatan yang harus dilakukan, yaitu :

a. Membersihkan Data (*Data Cleaning*)

Pada tahap ini dilakukan pembersihan terhadap data pada Tabel 1. dengan menghapus beberapa atribut yaitu *id* transaksi, waktu, jumlah, kategori produk, nominal, pembayaran, dan nama merchant, sehingga menghasilkan data sepeti Tabel 2.

TABEL II. DATA HASIL PEMBERSIHAN ATRIBUT

Tanggal	Nama Produk
01/03/2022	Blood Vampire, Javanese Sampler
01/03/2022	Blue Ocean

b. Transformasi Data (*Data Transformation*)

Sebelum melakukan proses transformasi data, dilakukan pengkodean terhadap nama produk, karena nama produk

yang terlalu panjang. Daftar kode produk bisa dilihat pada Tabel 3 berikut:

TABEL III. KODE PRODUK

Kode	Nama Produk	Kode	Nama Produk
M1	Air Mineral	M26	Taro
M2	Teh	M27	Coklat Hazelnut
M3	Lemon Tea	M28	Thai Tea
M4	Lemon Tea Jumbo	M29	Blue Ocean
M5	Es Teh Jumbo	M30	Selasih Fantasy
M6	Wedang Uwuh	M31	Red Delight
M7	Kopi Tubruk Susu	M32	Blood Vampire
M8	Kopi Tubruk	M33	Cinamond Crush
M9	Vietnam Drip	M34	French Fries
M10	Caffe Latte	M35	Jamur Krispi
M11	Cappuccino	M36	Tahu Krispi
M12	Black Americano	M37	Javanese Sampler
M13	Espresso	M38	Siomay
M14	Mocha Latte	M39	Roti Bakar
M15	V-60	M40	Croffle
M16	CoffeeMilk Original	M41	Cireng Krispi
M17	CoffeeMilk Brown Sugar	M42	Donat Kentang
M18	CoffeeMilk Hazelnut	M43	Nasi Ayam Matah
M19	CoffeeMilk Matcha	M44	Nasi Ayam Geprek
M20	Americano Ice	M45	Nasgor Krengsengan
M21	Japanese Ice	M46	Nasgor Terasi
M22	CoffeeMilk Vanila	M47	Nasgor Rawon
M23	Coklat	M48	Indomie Rebus
M24	Red Velvet	M49	Indomie Goreng
M25	Matcha		

Transformasi data dilakukan untuk mengubah tipe data *categorical* menjadi *binomial*. Proses transformasi menghasilkan data pada Tabel 4.

TABEL IV. HASIL TRANSFORMASI DATA

Tang gal	TI D	M 1	M 2	M 3	M 4	M 5	M 6	M 7	M 8	...	M 49	Ju mla h Item
01/03 /2022	1	0	0	0	0	0	0	0	0	...	0	2
01/03 /2022	2	0	0	0	0	0	0	0	0	...	0	1
...
31/03 /2023	66	0	0	0	0	0	0	0	1		0	2
74												

c. Reduksi Data (*Data Reduction*)

Pada tahap reduksi data, aktivitas yang dilakukan adalah menyeleksi data dengan jumlah item per transaksi lebih dari satu. Karena data yang akan diolah adalah data yang memiliki item dengan jumlah minimal dua item dalam satu transaksi, seperti data pada Tabel 5.

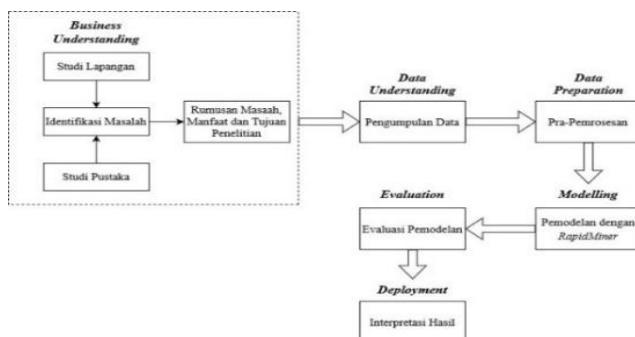
TABEL V. DATA HASIL REDUKSI

Tang gal	TI D	M 1	M 2	M 3	M 4	M 5	M 6	M 7	M 8	...	M 49	Ju mla h item
01/03	1	0	0	0	0	0	0	0	0	...	0	2

/2022											
01/03 /2022	2	0	0	0	0	0	0	0	0	1	3
...
31/03 /2023	47	0	0	0	0	0	0	0	1	0	2

C. Tahapan Penelitian

Pelaksanaan penelitian mengimplementasikan metode pengembangan *Cross-Industry Standard Process for Data Mining* (CRISP-DM) sebagai tahapan penelitian. CRISP-DM merupakan konsorsium perusahaan yang dibangun pada tahun 1996 oleh Komisi Eropa yang ditetapkan sebagai prosedur standar penambangan data sehingga bisa digunakan di beragam bidang industri [10]. Gambar 1. berikut merupakan gambaran alur proses CRISP-DM beserta penjelasannya.



Gambar 1. Tahap CRISP-DM

D. Association Rule

Aturan asosiasi adalah teknik penambangan data yang digunakan untuk mengidentifikasi item satu dengan item lainnya dalam database [11]. Untuk menetapkan hubungan antar item, harus mencakup persyaratan minimum support dan minimum *confidence*, yang mempunyai rentang nilai dari 0% hingga 100% [12], berikut merupakan penjelasan mengenai nilai *support* dan *confidence* [13].

a. Support

Support adalah representasi dari gabungan item pada database. Misalnya, jika ditemukan item A dan item B dalam database, maka nilai supportnya adalah persentase transaksi pada database yang berisi item A dan B. Berikut rumus yang digunakan untuk menentukan nilai *support*:

$$Support A = \frac{\sum \text{Transaksi mengandung } A}{\sum \text{Transaksi}} \quad (1)$$

Sedangkan nilai *support* untuk 2 item diperoleh dengan rumus:

$$Support (A, B) = \frac{\sum \text{Transaksi mengandung } A \text{ dan } B}{\sum \text{Transaksi}} \quad (2)$$

b. Confidence

Confidence pada aturan asosiasi adalah ukuran untuk menetapkan aturan, yaitu penyajian transaksi dalam basis

data yang berisi A dan B. Nilai *confidence* bisa diketahui dengan rumus berikut ini:

$$Confidence = P(B|A) = \frac{\sum \text{Transaksi mengandung } A \text{ dan } B}{\sum \text{Transaksi mengandung } A} \quad (3)$$

E. Algorithm FP-Growth

Algoritma *FP-Growth* adalah metode alternatif untuk mendeteksi kumpulan data yang paling kerap muncul (*frequent itemset*) tanpa memerlukan generasi kandidat [14]. Sebelum melakukan proses pada fase utama, terdapat beberapa langkah khusus untuk menyiapkan *dataset*, yaitu mencari *frequent itemset*, membuat susunan berlandaskan prioritas, *dataset* diatur berlandaskan prioritas, dan membuat *fp-tree*. Setelah langkah khusus terpenuhi, selanjutnya menyelesaikan tiga fase utama dari algoritma *FP-Growth*, yaitu Fase Pembangkitan *Conditional Pattern Base*, Fase Pembangkitan *Conditional FP-Tree*, dan Fase Pembangkitan *Frequent Itemset* [15].

F. Lift Ratio

Nilai *lift ratio* berguna untuk menyatakan keabsahan mekanisme transaksi dalam memberikan informasi tentang benar tidaknya produk A dan produk B dibeli dalam waktu yang bersamaan. Jika nilai *lift ratio* > 1 maka transaksi dikatakan sah, artinya produk A sebenarnya dibeli bersamaan dengan produk B [16]. Untuk menghitung nilai *lift ratio* bisa dilakukan dengan rumus berikut:

$$Lift Ratio = \frac{Confidence}{Expected Confidence} \quad (4)$$

Sedangkan *expected confidence* dihitung dengan rumus berikut ini:

$$Expected Confidence = \frac{\sum \text{Banyak Transaksi Mengandung } B}{\sum \text{Transaksi}} \quad (5)$$

Jika perhitungan menghasilkan nilai kurang dari 1 maka terdapat korelasi negatif. Sedangkan hasil perhitungan yang nilainya lebih besar dari 1, terdapat korelasi positif. Namun ketika hasil perhitungan nilainya sama dengan 1 maka tidak ada korelasi antara X dan Y [17].

III. HASIL DAN PEMBAHASAN

A. Perhitungan FP-Growth

Perhitungan algoritma FP-Growth akan dilakukan menggunakan 10 sampel item menu dan 20 sampel data transaksi penjualan. Sampel item menu yang digunakan yaitu Vietnam Drip, Caffe Latte, Cappuccino, Black Americano, Mocha Latte, Coklat Hazelnut, French Fries, Tahu Krispi, Roti Bakar dan Croffle. Sedangkan sampel data transaksi dapat dilihat pada Tabel 6:

TABEL VI. SAMPEL DATA TRANSAKSI

TID	Item Transaksi
6	M14, M34

TID	Item Transaksi
10	M10, M36
11	M11, M12, M34
16	M11, M12, M36
25	M9, M36
32	M27, M34, M36
41	M10, M12, M39
44	M11, M12, M40
71	M9, M12, M36
73	M9, M11, M36
139	M10, M34, M39
148	M10, M34
189	M9, M12, M36, M39
215	M10, M11, M40
228	M9, M34
243	M10, M36, M39
297	M9, M11, M34, M36, M40
306	M12, M34
307	M10, M14, M39
316	M12, M34

Item Menu	Frekuensi	<i>Support</i>
M12	8	0,4
M10	7	0,35
M9	6	0,3
M11	6	0,3
M39	5	0,25
M40	3	0,15
M14	2	0,1

- c. *Dataset* diatur berdasarkan prioritas. Setiap transaksi disusun berdasarkan item menu yang mempunyai frekuensi tertinggi menuju item menu yang mempunyai frekuensi rendah.

TABEL IX. DATASET BERDASARKAN PRIORITAS

TID	Item Transaksi
6	M34, M14
10	M36, M10
11	M34, M12, M11
16	M36, M12, M11
25	M36, M9
32	M34, M36
41	M12, M10, M39
44	M12, M11, M40
71	M36, M12, M9
73	M36, M9, M11
139	M34, M10, M39
148	M34, M10
189	M36, M12, M9, M39
215	M10, M11, M40
228	M34, M9
243	M36, M10, M39
297	M34, M36, M9, M11, M40
306	M34, M12
307	M10, M39, M14
316	M34, M12

Setelah menentukan sampel data, langkah selanjutnya melakukannya empat fase khusus algoritma *FP-Growth* yaitu:

- a. Mencari frekuensi kemunculan menggunakan persamaan (1). Nilai minimum *support* yang ditetapkan adalah 0,1, item menu akan dihapus jika tidak memenuhi nilai minimum *support*, seperti yang terlihat pada Table 7.

TABEL VII. FREKUENSI KEMUNCULAN ITEM MENU

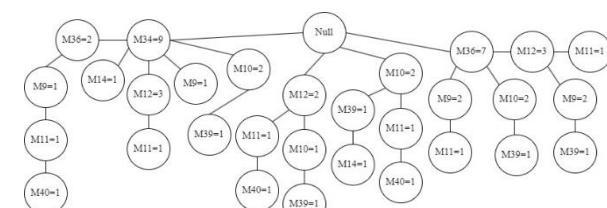
Item Menu	Frekuensi	Proses Support	Support
M9	6	(6/20)	0,3
M10	7	(7/20)	0,35
M11	6	(6/20)	0,3
M12	8	(8/20)	0,4
M14	2	(2/20)	0,1
M27	1	(1/20)	0,05
M34	9	(9/20)	0,45
M36	9	(9/20)	0,45
M39	5	(5/20)	0,25
M40	3	(3/20)	0,15

- b. Membuat susunan item menu berdasarkan prioritas. Tabel 8 merupakan hasil penyusunan item menu berdasarkan frekuensi kemunculan.

TABEL VIII. FREKUENSI KEMUNCULAN ITEM MENU BERDASARKAN PRIORITAS

Item Menu	Frekuensi	<i>Support</i>
M34	9	0,45
M36	9	0,45

- d. Membuat *fp-tree* berdasarkan pembacaan dari setiap TID. Hasil pembacaan semua TID dapat dilihat pada Gambar 2.



Gambar 2. Pembentukan FP-Tree Setelah Pembacaan Seluruh TID

Setelah pembentukan *Fp-Tree* selesai langkah berikutnya melakukan tiga fase utama algoritma *frequent pattern growth* yaitu:

a. Fase Pembangkitan *Conditional Pattern Base*

Dibentuk berdasarkan *FP-Tree* pada Gambar 2. Tabel 10 berikut merupakan hasil dari proses *conditional pattern base*:

TABEL X. CONDITIONAL PATTERN BASE

Prefix	Conditional Pattern Base
M14	{M34=1}, {M10,M39=1}
M40	{M34,M36,M9,M11=1}, {M12,M11=1}, {M10,M11=1}
M39	{M34,M10=1}, {M12,M10=1}, {M10=1}, {M36,M10=1}, {M36,M12,M9=1}
M11	{M34,M36,M9=1}, {M34,M12=1}, {M12=1}, {M10=1}, {M36,M9=1}, {M36,M12=1}
M9	{M34,M36=1}, {M34=1}, {M36=2}, {M36,M12=2}
M10	{M34=2}, {M12=1}, {M36=2}
M12	{M34=3}, {M36=3}
M36	{M34=2}

b. Fase Pembangkitan *Conditional FP-Tree*

Pada fase ini, support count dari setiap item dalam conditional pattern base akan diakumulasi. Jika hasil akumulasi support count lebih besar atau sama dengan nilai minimum support yang telah ditentukan, maka item tersebut akan di-generate kembali. Tabel 11 berikut adalah hasil conditional FP-Tree yang terbentuk:

TABEL XI. CONDITIONAL FP-TREE

Prefix	Conditional FP-Tree
M40	{M11=3}
M39	{M36=2}, {M10=4}
M11	{M34=2}, {M36=3}, {M36, M9=2}, {M12=3}
M9	{M34=2}, {M36=5, M12=2}
M10	{M34=2}, {M36=2}
M12	{M34=3}, {M36=3}
M36	{M34=2}

c. Fase Pembangkitan *Frequent Itemset*

Kombinasi *item conditional FP-Tree* menjadi dasar pembentukan frequent itemset. Sehingga menghasilkan pembentukan frequent itemset pada Tabel 12 berikut:

TABEL XII. FREQUENT ITEMSET

Prefix	Frequent Itemset
M40	{M11, M40=3}
M39	{M36, M39=2}, {M10, M39=4}
M11	{M34, M11=2}, {M36, M11=3}, {M36, M9, M11=2}, {M12, M11=3}
M9	{M34, M9=2}, {M36, M9=5}, {M12, M9=2}, {M36, M12, M9=2}
M10	{M34, M10=2}, {M36, M10=2}
M12	{M34, M12=3}, {M36, M12=3}
M36	{M34, M36=2}

Nilai minimum *support* yang ditetapkan adalah 0,1 serta nilai minimum *confidence* 0,5. Perhitungan nilai *support* memanfaatkan persamaan (2), sedangkan nilai *confidence* dihitung menggunakan persamaan (3). Tabel 13 berikut menunjukkan pola asosiasi yang mencakup nilai minimum *support* dan minimum *confidence*:

TABEL XIII. POLA YANG MENCAKUP NILAI MINIMUM SUPPORT DAN NILAI MINIMUM CONFIDENCE

No	Rule	Support	Confidence
1	If {M11} Then {M40}	3/20 = 0,15	3/5 = 0,5
2	If {M40} Then {M11}	3/20 = 0,15	3/3 = 1
3	If {M10} Then {M39}	4/20 = 0,2	4/7 = 0,57
4	If {M39} Then {M10}	4/20 = 0,2	4/5 = 0,8
5	If {M11} Then {M39}	3/20 = 0,15	3/6 = 0,5
6	If {M36, M11} Then {M9}	2/20 = 0,1	2/3 = 0,67
7	If {M11, M9} Then {M36}	2/20 = 0,1	2/2 = 1
8	If {M11} Then {M12}	3/20 = 0,15	3/6 = 0,5
9	If {M36} Then {M9}	5/20 = 0,25	5/9 = 0,56
10	If {M9} Then {M36}	5/20 = 0,25	5/6 = 0,83
11	If {M36, M12} Then {M9}	2/20 = 0,1	2/3 = 0,67
12	If {M12, M9} Then {M36}	2/20 = 0,1	2/2 = 1

B. Pengujian Lift Ratio

Pengujian dengan lift ratio dilakukan guna mengetahui kekuatan pola asosiasi, yang dihitung menggunakan persamaan (4), sedangkan nilai expected confidence akan dihitung menggunakan persamaan (5):

TABEL XIV. HASIL PERHITUNGAN NILAI LIFT RATIO

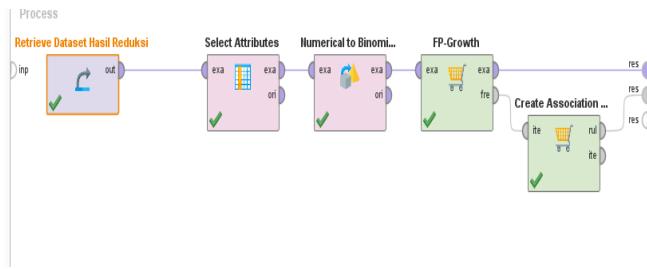
No	Rule	Support	Confidence	Expected Confidence	Lift
1	If {M11} Then {M40}	0,15	0,5	0,15	3,333
2	If {M40} Then {M11}	0,15	1	0,3	3,333
3	If {M10} Then {M39}	0,2	0,57	0,25	2,280
4	If {M39} Then {M10}	0,2	0,8	0,35	2,285
5	If {M11} Then {M39}	0,15	0,5	0,45	1,111
6	If {M36, M11} Then {M9}	0,1	0,67	0,3	2,233
7	If {M11, M9} Then {M36}	0,1	1	0,45	2,222
8	If {M11} Then {M12}	0,15	0,5	0,4	1,250
9	If {M36} Then {M9}	0,25	0,56	0,3	1,866
10	If {M9} Then {M36}	0,25	0,83	0,45	1,844
11	If {M36, M12} Then {M9}	0,1	0,67	0,3	2,233
12	If {M12, M9} Then {M36}	0,1	1	0,45	2,222

Semua pola menghasilkan nilai lift ratio > 1, sehingga semua pola tersebut memiliki korelasi positif. Pada 12 rule yang terbentuk terdapat beberapa rule yang memiliki item menu yang sama. Oleh karena itu rule tersebut harus dipilih salah satu, dengan mempertimbangkan nilai confidence yang lebih besar untuk dipilih.

C. Implementasi RapidMiner

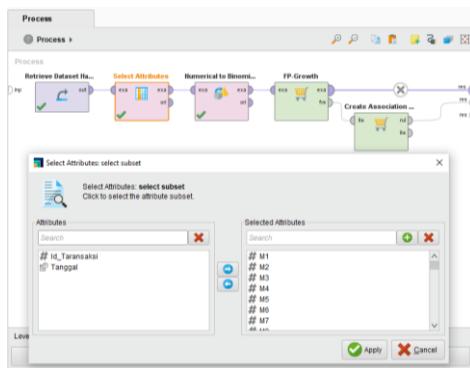
Software RapidMiner digunakan untuk melakukan pengujian terhadap dataset, sehingga korelasi antar rule yang

terbentuk dapat diketahui. Desain pengujian ditunjukkan pada Gambar 3 berikut:



Gambar 3. Desain Pengujian pada RapidMiner

Terdapat 5 operator yang digunakan pada desain pengujian, dimana dalam setiap operator mempunyai fungsi masing-masing. Operator pertama berfungsi untuk mengimport dataset yang sudah terbentuk pada proses persiapan data. Setelah dataset diimport, atribut data akan diseleksi menggunakan operator *select attribute* seperti yang terlihat pada Gambar 4 berikut.



Gambar 4. Operator Select Attribute

Proses selanjutnya yaitu mengubah tipe data yang semula mempunyai tipe numerik akan diubah menjadi tipe binomial menggunakan operator *Numerical to Binomial*, sehingga akan menghasilkan data seperti Gambar 5 berikut.

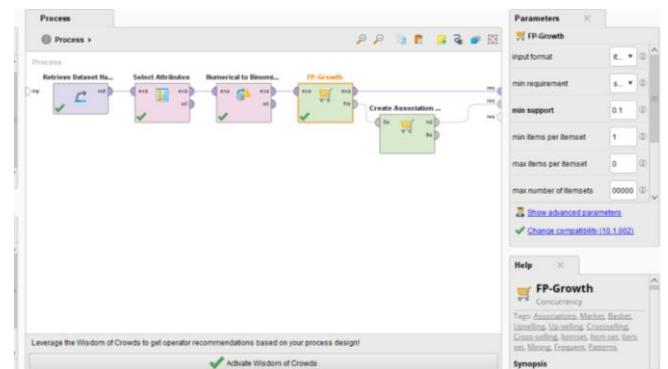
Tabel hasil data yang dihasilkan oleh operator *Numerical to Binomial*. Tabel ini menunjukkan 14 baris data dengan 10 kolom yang diberi label M1 hingga M10. Setiap kolom menunjukkan nilai true atau false.

Row No.	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
1	false									
2	false	true	false							
3	false									
4	false									
5	false	false	false	true	true	false	false	false	false	false
6	false									
7	false	false	false	false	false	false	true	true	false	false
8	false	true	false							
9	false									
10	false	true								
11	false	false	false	false	false	false	true	true	false	false
12	false									
13	false	false	true	false						
14	false	true	false	false						

Gambar 5. Hasil Data berdasarkan Operator Numerical to Binomial

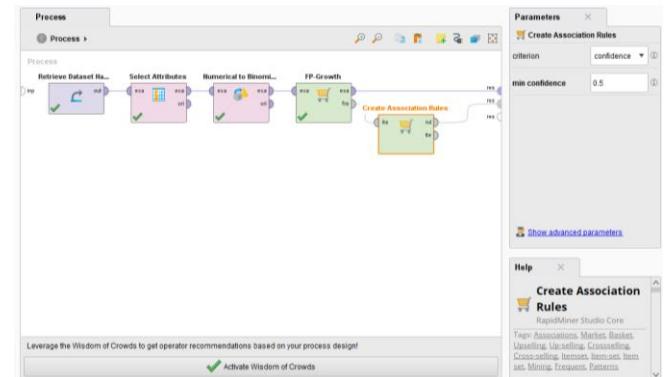
Tahap berikutnya adalah penerapan algoritma FP-Growth. Pada operator FP-Growth, kegiatan yang dilakukan adalah menentukan nilai minimum *support* untuk menyeleksi

dataset. Nilai minimum *support* yang digunakan pada penelitian ini adalah 0.1 seperti yang terlihat pada Gambar 6 berikut :



Gambar 6. Operator FP-Growth

Selain menetukan nilai minimum *support* diperlukan pula penentuan nilai minimum *confidence* untuk mengukur kekuatan kombinasi pola yang terbentuk. Nilai minimum *confidence* yang digunakan pada penelitian ini yaitu 0.5 dan dapat disetting pada operator *Create Association Rule*.



Gambar 7. Create Association Rule

Dari desain pengujian tersebut menghasilkan 14 pola asosiasi dan 9 menu dengan nilai support terendah. Hasil tersebut kemudian dianalisa sehingga menghasilkan rekomendasi paket menu yang dapat dilihat pada Tabel 16.

AssociationRules

```
Association Rules
[M40] --> [M1] (confidence: 0.513)
[M23] --> [M34] (confidence: 0.535)
[M19] --> [M36] (confidence: 0.556)
[M39] --> [M10] (confidence: 0.567)
[M44] --> [M3] (confidence: 0.580)
[M22] --> [M34] (confidence: 0.584)
[M30] --> [M34] (confidence: 0.592)
[M11] --> [M40] (confidence: 0.598)
[M20] --> [M34] (confidence: 0.635)
[M27] --> [M34] (confidence: 0.673)
[M14] --> [M34] (confidence: 0.684)
[M10] --> [M39] (confidence: 0.773)
[M26] --> [M34] (confidence: 0.781)
[M31] --> [M34] (confidence: 0.837)
```

Gambar 6. Hasil Pola Asosiasi

TABEL XV. ITEM MENU DENGAN SUPPORT TERENDAH

No	Kode Produk	Support
1	M4	15%
2	M13	18%
3	M33	18%
4	M1	18%
5	M21	22%
6	M47	23%
7	M49	23%
8	M46	25%
9	M6	26%

TABEL XVII. HASIL PAKET PROMOSI

No	Paket Promosi yang terbentuk
1	Produk yang sering dibeli dengan tingkat kepercayaan 87,3% dibundling promo dengan produk <i>Cinamond Crush</i> yang mempunyai presentase support 18%
2	Produk yang sering dibeli dengan tingkat kepercayaan 77,3% dibundling promo dengan produk <i>Espresso</i> yang mempunyai presentase support 18%
3	Produk yang sering dibeli dengan tingkat kepercayaan 63,5% dibundling promo dengan produk <i>Japanese Ice</i> yang mempunyai presentase support 22%
4.	Produk yang sering dibeli dengan tingkat kepercayaan 58% dibundling promo dengan produk Nasgor Rawon yang mempunyai presentase support 23% atau dengan produk Nasgor Terasi yang mempunyai presentase support 25%

I. KESIMPULAN

Berdasarkan analisis dan pengujian menggunakan software *RapidMiner* dan Algoritma *FP-Growth* terhadap data transaksi penjualan *The Javanese Café*, menghasilkan 4 rekomendasi paket menu promosi yang dapat menunjang strategi pemasaran yaitu; (a) Produk yang sering dibeli dengan tingkat kepercayaan 87,3% dibundling promo dengan produk *Cinamond Crush* yang mempunyai presentase support 18%; (b) Produk yang sering dibeli dengan tingkat kepercayaan 77,3% dibundling promo dengan produk *Espresso* yang mempunyai presentase support 18%; (c) Produk yang sering dibeli dengan tingkat kepercayaan 63,5% dibundling promo dengan produk *Japanese Ice* yang mempunyai presentase support 22%; (d) Produk yang sering dibeli dengan tingkat kepercayaan 58% dibundling promo dengan produk Nasgor Rawon yang mempunyai presentase support 23% atau dengan produk Nasgor Terasi yang mempunyai presentase support 25%.

Pada penelitian selanjutnya dapat menggunakan dataset terbaru dan periode waktu lebih lama, sehingga jumlah transaksi yang lebih besar tersebut dapat menghasilkan nilai

data transaksi penjualan dengan tingkat akurasi yang lebih tinggi. Serta dapat menggunakan algoritma *association rule* yang berbeda sehingga dapat mengetahui algoritma mana yang lebih cocok untuk diterapkan.

REFERENCES

- [1] E. E. P. Wulandari, "Pengaruh Lokasi, Inovasi Produk, Dan Cita Rasa Terhadap Keputusan Pembelian Pada Eleven Cafe Di Kota Bengkulu," *J. Entrep. dan Manaj. Sains*, vol. 2, no. 1, pp. 74–86, 2021.
- [2] R. P. C. Atmojo and C. Herdinata, "Pengaruh Harga, Promosi Dan Lokasi Terhadap Kepuasan Konsumen Pada Perusahaan Cv. Andindo Duta Perkasa," *PERFORMA J. Manaj. dan Start-Up Bisnis*, vol. 5, no. 5, pp. 379–388, 2020.
- [3] A. E. Nasution, L. P. Putri, and M. T. Lesmana, "Analisis Pengaruh Harga, Promosi, Kepercayaan dan Karakteristik Konsumen Terhadap Keputusan Pembelian Konsumen Pada 212 Mart di Kota Medan," in *Proseding Seminar Nasional Kewirausahaan*, 2019, pp. 194–199.
- [4] Tarigan Fahrul, Azanuddin, and Yanti Nur, "Implementasi Data Mining Menentukan Pola Penjualan Produk Toko Perabot Dua Bersaudara Kualimbaru Dengan Menggunakan Fp-Growth," *J. CyberTech*, vol. 1, no. 2, pp. 115–129, 2021.
- [5] R. Takdirillah, "Penerapan Data Mining Menggunakan Algoritma Apriori Terhadap Data Transaksi Sebagai Pendukung Informasi Strategi Penjualan," *Edumatic J. Pendidik. Inform.*, vol. 4, no. 1, pp. 37–46, 2020.
- [6] A. P. Sandia and V. W. Ningsih, "Implementasi Data Mining Sebagai Penentu Persediaan Produk Dengan Algoritma Fp-Growth Pada Data Penjualan Sinarmart," *JUPIKOM*, vol. 1, no. 2, pp. 111–122, 2022.
- [7] K. T. Wijaya and I. Pratama, "Penerapan Algoritma FP-Growth Untuk Analisis Data Transaksi Penjualan Di Internet Learning Cafe Kaliurang," *J. Nas. Komputasi dan Teknol. Inf.*, vol. 5, no. 4, pp. 642–651, 2022.
- [8] I. Afriyani and I. Ali, "Implementasi Data Mining Terhadap Data Penjualan Pada Industri Kuliner Menggunakan Algoritma Fp-Growth," *E-Link J. Tek. Elektro dan Inform.*, vol. 18, no. 1, pp. 40–49, 2023.
- [9] S. Suhada, D. Ratag, G. Gunawan, D. Wintana, and T. Hidayatulloh, "Penerapan Algoritma Fp-Growth Untuk Menentukan Pola Pembelian Konsumen Pada Ahass Cibadak," *J. Swabumi*, vol. 8, no. 2, pp. 118–126, 2020.
- [10] R. M. Thamrin and R. Andriani, "Perancangan Sistem Informasi Pendaftaran Dan Pengelolaan Data Skripsi Mahasiswa Berbasis Web Design Registration Information System And Web-Based Data Management of Student Thesis," *J. Sisfotenika*, vol. 11, no. 1, pp. 101–110, 2021.
- [11] A. R. Wibowo and A. Jananto, "Implementasi Data Mining Metode Asosiasi Algoritma FP-Growth Pada Perusahaan Ritel," *Inspir. J. Teknol. Inf. dan Komun.*, vol. 10, no. 2, p. 200, 2020, doi: 10.35585/inspir.v10i2.2585.
- [12] F. Febriantho, D. Renald, Y. Yakub, E. Edy, and I, "Penerapan Association Rule Data Mining Untuk Rekomendasi Produk Kosmetik Pada Pt. Fabio Sejahtera Menggunakan Algoritma Apriori," *J. Algor.*, vol. 2, no. 1, pp. 1–11, 2020, doi: 10.31253/algor.v2i1.437.
- [13] J. L. Putra, M. Raharjo, T. A. A. Sandi, Ridwan, and R. Prasetyo, "Implementasi Algoritma Apriori Terhadap Data Penjualan Pada Perusahaan Retail," *J. PILAR Nusa Mandiri*, vol. 15, no. 1, pp. 87–90, 2019.
- [14] N. Hutabarat and J. R. Sagala, "Penerapan Data Mining Untuk Pemesanan Percetakan Bahan Ajar Dengan Algoritma Apriori (Studi Kasus Percetakan Wendy)," *J. Method.*, vol. 4, no. 2, pp. 25–32, 2018.
- [15] C. E. Firman, "Penentuan Pola Yang Sering Muncul Untuk Penjualan Pupuk Menggunakan Algoritma Fp-Growth," *Inform. J. Inform. Manaj. dan Komput.*, vol. 9, no. 2, pp. 1–8, 2017.

- [16] N. D. Andriai, T. W. Utami, and R. Wasodo, "Implementasi Algoritma Fp-Growth Dalam Market Basket Analysis Untuk Menganalisis Pola Belanja Konsumen Pada Data Transaksi Penjualan," 2019.
- [17] R. P. Karina, S. Lestanti, and F. Febrinita, "Penerapan Algoritma Apriori Dalam Seleksi Penjurusan Calon Peserta Didik Baru Di Smak Diponegoro Blitar," *JATI(Jurnal Mhs. Tek. Inform.*, vol. 6, no. 2, pp. 716–724, 2022.