

Optimasi *Bundling* Produk Toko Roti berbasis Waktu menggunakan Algoritma FP-Growth

Nur Fitrianti Fahrudin¹, Rifki Maulana¹, Mira Musrini Barmawi¹

¹ Program studi Sistem Informasi, Institut Teknologi Nasional, Bandung, Indonesia
Email: nurfitrianti@itenas.ac.id¹

Received 2 September 2024 | Revised 8 September 2024 | Accepted 15 September 2024

ABSTRAK

Penelitian ini bertujuan untuk mengeksplorasi penggunaan teknik asosiasi untuk mengidentifikasi pola tersembunyi dalam data transaksi penjualan. Analisis pola pembelian pelanggan yang terkandung dalam sebuah data transaksi dilakukan pada dataset milik sebuah Toko Roti. Dataset memiliki atribut utama seperti nomor transaksi, item, kemudian variabel waktu seperti daytime, daypart dan daytype. Guna memaksimalkan hasil rekomendasi, dataset dibagi kedalam 6 bagian berdasarkan waktu pembelian dengan memanfaatkan atribut DayPart dan DayType. Selanjutnya algoritma FP-Growth dipilih karena kemampuannya mengidentifikasi sekumpulan item yang sering muncul dalam database transaksional dengan efisiensi tinggi. Berdasarkan penelitian yang telah dilakukan, penelitian ini merekomendasikan 6 rules yang diambil masing-masing dataset. Aturan-aturan yang dihasilkan ini nantinya dapat digunakan sebagai rekomendasi bundling produk pada waktu tertentu. Untuk mendapatkan rule yang kuat dalam data transaksi toko roti dimasukkan nilai minimum support berkisar diantara 0.02 (20%) – 0.06 (60%) dan nilai minimum confidence diantara 0.03 (30%) – 0.06 (60%) semua rules yang di diperoleh memiliki nilai nilai lift ratio lebih dari 1 yang menunjukkan adanya korelasi dan manfaat dari rules tersebut. Penentuan nilai minimum support dan confidence dipengaruhi dari jumlah transaksi yang terkandung pada setiap dataset

Kata kunci: Data Transaksi, Data Mining, Teknik Asosiasi, FP – Growth, Lift Ratio

ABSTRACT

This study aims to explore the use of association techniques to identify hidden patterns in sales transaction data. The analysis of customer purchasing patterns contained in transaction data is conducted using a dataset from a bakery. The dataset includes key attributes such as transaction number, item, and time-related variables such as daytime, daypart, and daytype. To maximize recommendation results, the dataset is divided into six segments based on purchase time using the DayPart and DayType attributes. The FP-Growth algorithm is selected due to its efficiency in identifying frequently occurring itemsets within transactional databases. Based on the conducted analysis, the study recommends six rules derived from each dataset segment. These rules can be used for product bundling recommendations at specific times. To obtain strong rules, the transaction data of the bakery includes a minimum support value ranging from 0.02 (20%) to 0.06 (60%) and a minimum confidence value ranging from 0.03 (30%) to 0.06 (60%). All obtained rules have lift ratios greater than 1, indicating a correlation and benefit of the rules. The determination of minimum support and confidence values is influenced by the number of transactions within each dataset.

.Keywords: Transaction Data, Data Mining, Association Techniques, FP – Growth, Lift Ratio.

1. PENDAHULUAN

Seiring dengan pertumbuhan industri ritel yang pesat, memahami perilaku pembelian konsumen sangatlah penting untuk meningkatkan penjualan dan kepuasan pelanggan. *Bundling* produk merupakan sebuah strategi pemasaran yang menyatukan dua atau lebih produk dalam satu paket penjualan dengan harga yang telah ditentukan [1]. Pendekatan ini umum diterapkan di berbagai sektor, seperti ritel, teknologi, dan jasa, dengan tujuan untuk meningkatkan volume penjualan, mengoptimalkan laba, serta menawarkan nilai tambah kepada pelanggan. Optimasi *bundling* produk bertujuan untuk menentukan kombinasi produk yang paling efektif dalam menarik perhatian pelanggan sekaligus menguntungkan bagi bisnis [1]. Proses ini melibatkan analisis data penjualan untuk mengidentifikasi pola pembelian pelanggan, termasuk produk yang sering dibeli bersama, frekuensi pembelian, serta variabel lain seperti waktu transaksi. Dengan pendekatan berbasis data, bisnis dapat merancang paket *bundling* yang relevan, menarik, dan sesuai dengan kebutuhan pasar. Data mining menyediakan alat yang ampuh untuk mengekstraksi informasi berharga dari data transaksional [2]. memungkinkan bisnis mengidentifikasi pola pembelian dan mengembangkan strategi pemasaran yang lebih efektif. Data mining melibatkan penemuan pola dalam kumpulan data besar menggunakan basis data, statistika, dan teknik pembelajaran mesin [3][4]. Data mining bertujuan untuk mengekstrak informasi yang berguna dari data dan mengubahnya menjadi informasi yang mudah dimengerti serta dapat digunakan lebih lanjut [3]. Data mining digunakan di berbagai industri untuk menemukan pola dan hubungan tersembunyi dalam kumpulan data, sehingga memudahkan dalam pengambilan keputusan [5]. Dalam lingkungan bisnis, data mining dapat digunakan untuk berbagai tujuan, termasuk perkiraan penjualan, analisis perilaku pelanggan, manajemen rantai pasokan, dan deteksi penipuan. Teknik penambangan data yang umum digunakan meliputi klasifikasi, pengelompokan, regresi, dan asosiasi. Market Basket Analysis (MBA) adalah contoh teknik analisis asosiasi data mining yang paling populer, terutama di industri ritel [5].


Market Basket Analysis (MBA) merupakan suatu teknik yang menganalisis perilaku pembelian konsumen dengan cara mengidentifikasi produk atau item yang sering dibeli secara bersamaan ketika bertransaksi [6]. MBA ini dapat digunakan untuk menentukan *bundling* produk. Teknik ini sangat berguna dalam mengungkap hubungan tersembunyi antar produk dan membantu pengecer mengambil keputusan strategis seperti desain produk, promosi, dan rekomendasi penjualan [7]. Terdapat beberapa algoritma yang digunakan untuk analisis MBA, di antaranya adalah Apriori dan FP-Growth [8]. Algoritma Apriori merupakan salah satu algoritma pertama yang digunakan untuk menemukan aturan asosiasi [5]. Algoritma ini bekerja berdasarkan prinsip bahwa setiap subset dari himpunan item yang sering muncul juga harus sering muncul [6]. Algoritma Apriori melibatkan dua tahap utama yaitu mengidentifikasi *frequent itemset* dan membuat aturan asosiasi [9]. Algoritma Apriori adalah salah satu algoritma paling awal yang digunakan untuk menemukan aturan asosiasi dalam data [10]. Meskipun algoritma ini memiliki banyak keunggulan, seperti kesederhanaan dan kemampuannya untuk menghasilkan aturan asosiasi yang kuat, ada beberapa kelemahan seperti efisiensi yang rendah karena melakukan banyak pemindaian *database* [11], konsumsi memori yang tinggi, reduksi kandidat [12], keterbatasan dalam penanganan data *sparsity*. Untuk mengatasi kelemahan-kelemahan tersebut, algoritma lain seperti FP-Growth (*Frequent Pattern Growth*) dikembangkan. FP-Growth menggunakan struktur data FP-Tree (*Frequent Pattern Tree*) untuk menyimpan data dalam bentuk yang lebih terkompresi dan efisien, sehingga mengurangi kebutuhan untuk menghasilkan dan memeriksa banyak kandidat *itemsets* [13][14]. FP-Growth hanya memerlukan dua pemindaian *database* dan lebih efisien dalam hal penggunaan memori dan waktu komputasi [15]. Algoritma Apriori memerlukan pembuatan kandidat *itemset* untuk menentukan *itemset* yang sering muncul [5]. FP-Growth menggunakan struktur data FP-Tree yang lebih kompak dan tidak memerlukan pembuatan kandidat *itemset* secara berulang-ulang, sehingga lebih efektif dibandingkan algoritma Apriori, terutama pada dataset yang besar. Namun,

untuk *dataset* yang sangat besar atau dengan pola item yang sangat beragam, penggunaan memori FP-Tree dapat menjadi tantangan [16]. Hal ini membuat kinerja algoritma FP-Growth lebih cepat jika dibandingkan dengan algoritma Apriori.

Penelitian ini bertujuan untuk menganalisis pola pembelian konsumen pada transaksi penjualan toko roti menggunakan algoritma FP-Growth. Analisis dilakukan menggunakan data transaksi yang diambil dari sumber publik guna mengidentifikasi pola-pola pembelian yang signifikan dan memberikan rekomendasi yang praktis bagi toko roti dalam meningkatkan penjualan dan efisiensi operasional. *Dataset* yang digunakan dalam penelitian ini diambil dari Kaggle. Kaggle menyediakan berbagai set data publik yang dapat diakses secara bebas untuk tujuan penelitian dan analisis. Set data yang dipilih berisi informasi transaksi penjualan di toko roti, termasuk item-item yang dibeli, jumlah transaksi, dan waktu pembelian. Hasil dari penelitian ini diharapkan dapat memberikan informasi berharga tentang pasangan produk apa saja yang sering dibeli pelanggan berdasarkan histori transaksi. Dengan adanya informasi ini diharapkan dapat menjadi rekomendasi toko roti untuk mengelola strategi pemasaran produk sehingga kedepannya dapat memberikan peningkatan pendapatan karena bisa menjual banyak produk sekaligus dalam sebuah *bundling* produk dan juga bisa mengetahui produk mana yang harus banyak diproduksi.

2. METODOLOGI

Penelitian ini terbagi kedalam 4 bagian utama yaitu pengumpulan data, *pre-processing*, modeling, dan interpretasi hasil. Kerangka penelitian yang disajikan dalam diagram alir pada Gambar 1 ini menunjukkan proses penelitian yang akan dilalui serta menggambarkan keseluruhan penelitian. Adapun Metodologi Penelitian atau tahapan yang akan dijalani yaitu:



Gambar 1. Metodologi Penelitian

2.1 Pengumpulan Data

Tahap pertama dalam penelitian ini yaitu pengumpulan data, pengumpulan data yang dilakukan dengan cara mengambil sebuah *dataset* transaksi toko roti milik The Bread Basket dari situs kaggle.com. Data ini mencakup menu makanan dan minuman yang dipesan oleh konsumen dalam periode 30 Oktober 2016 sampai 04 September 2017 memiliki jumlah data sebanyak 20507 data dengan transaksi sebanyak

9465 data transaksi dan memiliki format csv. Berikut pada Tabel 1 merupakan penjelasan atribut pada data transaksi toko roti.

Tabel 1. Atribut Data Transaksi

Nama Atribut	Keterangan
<i>TransactionNo</i>	Merupakan nomor unik urutan untuk setiap transaksi pelanggan.
<i>Items</i>	Merupakan nama dari produk yang dibeli oleh pelanggan.
<i>DateTime</i>	Merupakan tanggal dan waktu saat transaksi dilakukan. (DD/MM/YYYY HH:MM)
<i>DayPart</i>	Merupakan bagian hari saat transaksi dilakukan. (Afternoon/Evening/Morning/Night)
<i>DayType</i>	Merupakan tipe hari saat transaksi dilakukan. (Weekend/Weekday)

Total items yang terdapat didalam dataset adalah 93 item, yang terdiri dari minuman dan makanan.

2.2 Preprocessing

Data *preprocessing* bertujuan untuk mempersiapkan data set agar dapat mudah dianalisis pada tahapan selanjutnya yaitu pemodelan [9]. Proses ini penting dilakukan karena data set sering kali belum memiliki format yang sesuai, berikut merupakan tahapan dari *preprocessing* data dalam penelitian ini :

1) Data Selection

Pada tahap ini membagi data kedalam 8 dataset, dengan menggunakan atribut *DayPart* dan *DayType* sebagai acuan. Atribut Day Part terdiri atas 4 yaitu: *Morning*, *Afternoon*, *Evening*, *Night* dan untuk atribut *Day Type* terdapat 2 value yaitu: *Weekend*, *Weekday*. Dikarenakan penulis ingin memberikan rekomendasi pasangan produk makanan berdasarkan 8 waktu periode. Sehingga nantinya toko dapat memberikan rekomendasi pasangan produk berdasarkan waktu terjadinya transaksi pembelian seperti yang ditunjukkan oleh Tabel 2.

Tabel 2. Pembagian Dataset

No.	Day Part	Day Type	Jumlah Transaksi	Keterangan
1.	Morning	Weekday	2648	Senin – Jumat, 07.00-11.59
2.	Morning	Weekend	1455	Sabtu – Minggu, 07.00 – 11.59
3.	Afternoon	Weekday	3325	Senin – Jumat, 12.00 – 16.59
4.	Afternoon	Weekend	1764	Sabtu – Minggu, 12.00 – 16.59
5.	Evening	Weekday	169	Senin – Jumat, 17.00 – 20.59
6.	Evening	Weekend	92	Sabtu – Minggu, 17.00 – 20.59
7.	Night	Weekday	3	Senin – Jumat, 21.00 – 23.59
8.	Night	Weekend	9	Sabtu – Minggu, 21.00 – 23.59
Total			9465	

Pada Tabel 2 dapat dilihat untuk dataset nomor 7 yaitu transaksi yang terjadi pada hari senin- jumat pada pukul 21.00-23.59 hanya terdapat 3 transaksi dan dataset nomor 8 yaitu transaksi yang terjadi pada hari sabtu-minggu pada pukul 21.00-23.59 hanya terdapat 9 transaksi. Berdasarkan hasil ini penulis memutuskan untuk tidak melakukan analisis asosiasi pada kedua dataset dikarenakan jumlah transaksi yang terjadi sangat minimum sekali. Sehingga frequent item set yang ada tidak akan membentuk pola asosiasi yang kuat.

2) Pemilihan Atribut Data.

Tahapan selanjutnya adalah melakukan pemilihan atribut data. Atribut yang tidak digunakan dalam proses pemodelan, akan diseleksi atau dihapus. Sehingga hasil akhir yang tersisa hanya atribut – atribut

yang digunakan untuk pemodelan saja. Pada tahap ini hanya diperlukan atribut ‘TransactionNo’ dan ‘Items’ saja karena yang dicari adalah pola asosiasi item berdasarkan transaksinya saja.

3) Transformasi Data

Setelah atribut data dipilih, tahap berikutnya adalah proses transformasi data menggunakan Rapid Miner. Transformasi data ini adalah proses mengubah data yang telah diseleksi, ke dalam bentuk yang sesuai dengan teknik pemodelan asosiasi. Dalam proses transformasi data ini terdapat 3 tahap yaitu Aggregate, Rename, dan Set Role.

2.3 Modelling Algoritma FP-Growth

Tahap pemodelan asosiasi dengan menggunakan algoritma FP-Growth (*Frequent Pattern Growth*) terdiri atas 8 langkah [17] sebagai berikut :

- 1) *Menentukan Minimum Support*, penentuan nilai minimum *support* dan minimum *confidence* dalam data *mining* sering kali disesuaikan dengan kebutuhan spesifik dan sifat dataset yang digunakan. Menurut Daniel T. Larose dalam bukunya *Data Mining Methods and Models* [18], nilai-nilai ini dapat diatur berdasarkan tujuan analisis dan karakteristik *dataset*, seperti ukuran data dan distribusi frekuensi item. Hal ini untuk memastikan pola yang ditemukan relevan dan dapat digunakan untuk pengambilan keputusan yang praktis. Sebagai contoh, bila ingin menemukan data yang memiliki hubungan asosiasi yang kuat, minimum *support* dan minimum *confidence* bisa diberi nilai yang tinggi [19]. Sebaliknya, bila ingin melihat banyaknya variasi data tanpa terlalu memedulikan kuat atau tidaknya hubungan asosiasi antara datanya, nilai minimumnya dapat diisi rendah. Jangan lupa juga untuk memperhatikan jumlah item yang tersedia dalam *dataset* dan jumlah transaksi yang ada. Semakin banyak item yang ada, tentunya nilai *support*-nya akan menjadi kecil.
- 2) *Mencari Frequent Itemset*, Setelah dilakukan transformasi data masuk ke dalam algoritma FP – Growth langkah awal yang dilakukan adalah mencari *frequent itemset* atau mencari jumlah kemunculan item yang tersedia dalam seluruh transaksi. Proses ini dilakukan agar selanjutnya dapat memodelkan FP – Tree.
- 3) *Menghitung Nilai Support 1-itemset*, Setelah mendapatkan daftar menu item yang sering kali dibeli oleh pelanggan, maka langkah berikutnya adalah menghitung nilai *support* yang dimiliki oleh masing-masing item tersebut [20]. Sehingga nantinya dapat diurutkan berdasarkan nilai *support* yang terbesar, hingga nilai *support* yang terkecil. Setelah melakukan proses penghitungan *support* dan melakukan pengurutan item berdasarkan *support* atau kemunculan yang terbesar ke yang terkecil. Selanjutnya melakukan proses pengurutan item dalam TID berdasarkan setiap kemunculan item. Berikut adalah Persamaan 1 untuk menghitung nilai *support* [21] [22]:

$$\text{Nilai Support (X)} = \frac{\text{Jumlah transaksi yang mengandung X}}{\text{Total Transaksi}} \quad (1)$$

- 4) *Pembentukan FP-Tree*, Setelah mendapatkan data berupa TID yang terurut dan memiliki nilai berdasarkan minimum *support*. Langkah selanjutnya adalah pembentukan FP – Tree yang nantinya akan menghasilkan sebuah pola kombinasi .
- 5) *Conditional Pattern Base*, Setelah proses pembentukan FP-Tree, langkah selanjutnya yaitu mengidentifikasi conditional pattern base. *Conditional pattern base* ini, dicari berdasarkan data FP-Tree paling terakhir. *Conditional pattern base* adalah sub-*database* yang berisi *prefix path* (lintasan *prefix*) dan *suffix pattern* (pola akhiran) [23]. FP-Tree yang telah dibangun sebelumnya digunakan untuk membangkitkan *conditional pattern base*
- 6) *Conditional FP-Tree*, selanjutnya adalah melakukan pembentukan Conditional FP – Tree. Tahap ini dilakukan dengan melakukan pemisahan dari *itemset* dengan *pattern base* yang sudah ada. Pada tahap ini, *support count* dari setiap item pada setiap *Conditional pattern base* perlu dijumlahkan, selanjutnya setiap item yang memiliki jumlah *support count* lebih besar sama dengan minimum *support count* akan dibangkitkan dengan *Conditional FP-Tree*.

- 7) *Menghitung Nilai Support dan Confidence*, setelah mendapatkan hasil berupa *subset* yang memenuhi syarat, dari proses *conditional FP-Tree* maka untuk tahap selanjutnya adalah menghitung nilai minimum *support* dan minimum *confidence* yang telah ditentukan sebelumnya. Berikut adalah Persamaan 2 untuk menghitung nilai *confidence*:

$$\text{Confidence } (X \cap Y) = \frac{\text{Jumlah transaksi yang mengandung } X \text{ dan } Y}{\text{Jumlah transaksi yang mengandung } X} \quad (2)$$

- 8) *Pembentukan Rules*, pada tahapan ini menjelaskan hasil dari pemodelan yang dilakukan dengan menggunakan algoritma FP-Growth, informasi berupa hubungan antar dua *itemset* atau lebih dari data transaksi yang ada terbentuk sehingga dapat dilihat pola pembelian para pelanggan.

2.4 Lift Ratio

Lift ratio adalah suatu ukuran untuk mengetahui kekuatan aturan asosiasi (*association rule*) yang telah terbentuk. Nilai lift ratio biasanya digunakan sebagai penentu apakah aturan asosiasi valid atau tidak valid [24]. Cara kerja metode ini adalah membagi *confidence* dengan *expected confidence*. Nilai dari *expected confidence* dapat dilihat pada Persamaan 3 berikut:

$$\text{Expected Confidence} = \frac{\text{Jumlah transaksi yang mengandung } Y}{\text{Jumlah transaksi}} \quad (3)$$


Setelah mendapatkan nilai *expected confidence*, selanjutnya menentukan nilai lift ratio dari hasil bagi *confidence* dengan *expected confidence*. Nilai dari lift ratio dapat dilihat pada Persamaan 4 berikut:

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

Jika *Lift Ratio* dari sebuah *rules* adalah < 1 , maka kemunculan A dengan kemunculan B memiliki korelasi negatif dan dapat disebutkan bahwa jika penjualan item A meningkat, maka penjualan B menjadi menurun. Jika *Lift Ratio* bernilai 1, maka kemunculan item A dan B bersifat independen dan tidak berkorelasi satu sama lain. Sedangkan jika *Lift Ratio* bernilai > 1 maka korelasi antar item bernilai positif, sehingga apabila item A dan item B akan dibeli bersamaan [25] [26].

2.4 Interpretasi Hasil

Pada tahapan ini aturan atau rule yang dihasilkan dari proses asosiasi dipilih. Analisis berdasarkan nilai *confident* dan nilai *support*. Dilakukan analisis aturan asosiasi yang ditemukan secara detail untuk memahami hubungan antar elemen dalam konteks bisnis. Aturan yang memiliki *confidence* dan *lift* yang tinggi dipilih, karena cenderung lebih bermakna. Implementasi ini dilakukan menggunakan aplikasi RapidMiner dengan desain proses yang dapat dilihat pada Gambar 2.



Gambar 2. Tahapan Market Basket Analysis menggunakan Rapid Miner

3. HASIL DAN PEMBAHASAN

3.1 Inisialisasi Nilai Minimum *Support* dan *Confidence* untuk setiap *dataset*

Langkah awal melibatkan pengaturan nilai minimum *support*, yang berfungsi untuk menghitung semua itemset yang sering muncul dalam *dataset*, serta pengaturan nilai minimum *confidence*, yang berfungsi untuk menghasilkan aturan asosiasi dari himpunan itemset yang sering muncul. Berikut pada Tabel 3 nilai yang dimasukkan ke dalam masing-masing *dataset*, setiap *dataset* memiliki nilai minimum *support* dan minimum *confidence* yang beragam tergantung banyaknya jumlah transaksi dalam *dataset*.

Tabel 3. Jumlah Nilai Minimum *Support* Dan Minimum *Confidence* Sample Data

No	Jenis Data	Minimum <i>Support</i>	Minimum <i>Confidence</i>
1	<i>Morning – Weekday</i>	0.03	0.3
2	<i>Morning – Weekend</i>	0.04	0.4
3	<i>Afternoon – Weekday</i>	0.06	0.5
4	<i>Afternoon – Weekend</i>	0.05	0.5
5	<i>Evening – Weekday</i>	0.02	0.5
6	<i>Evening – Weekend</i>	0.06	0.6

Perbedaan nilai minimum *support* dan nilai minimum *confidence* pada setiap *dataset* terjadi karena jumlah transaksi yang ada juga beragam.

3.2 Aturan Asosiasi untuk setiap Dataset

1) *Dataset “Morning – Weekday”*

Untuk proses pengujian pertama, dilakukan dengan menggunakan data transaksi Morning – Weekday yaitu data pembelian pelanggan di hari senin - jumat ketika pagi hari pukul 07.00 – 11.59. Data *Sample* yang digunakan merupakan data Morning – Weekday. Berisikan 5174 data dengan 2648 transaksi. Untuk sample data tersebut terlampir pada Tabel 3.

Tabel 3. Sample Data Morning - Weekday

<i>TransactionNo</i>	<i>Items</i>	<i>DateTime</i>	<i>Daypart</i>	<i>DayType</i>
81	Coffee	31/10/2016 08.28	Morning	Weekday
81	Cake	31/10/2016 08.28	Morning	Weekday
82	Tartine	31/10/2016 08.47	Morning	Weekday
82	Bread	31/10/2016 08.47	Morning	Weekday
83	Coffee	31/10/2016 08.57	Morning	Weekday
83	Bread	31/10/2016 08.57	Morning	Weekday
84	Bread	31/10/2016 09.04	Morning	Weekday

Data kemudian dimodelkan menggunakan algoritma FP-Growth. Setelah mendapatkan hasil berupa *frequent itemset* atau *frequency pattern growth*, maka langkah berikutnya adalah menampilkan hasil berupa aturan asosiasi yang telah memenuhi *minimum support* 3% dan *minimum confidence* 30%. Berikut merupakan hasil association rules Morning – Weekday.

Table 4. Hasil Association Rules transaksi Morning – Weekday

No	Premises	Conclusion	Support	Confidence	Lift	Coviction
1	Pastry	Bread	0.043	0.306	0.884	0.942
2	Tea	Coffee	0.042	0.349	0.659	0.723
3	Medialuna	Coffee	0.043	0.579	1.093	1.117
4	Pastry	Coffee	0.082	0.586	1.107	1.137
5	Cake	Coffee	0.034	0.589	1.113	1.146
6	Cookies	Coffee	0.032	0.592	1.117	1.152
7	Toast	Coffee	0.040	0.718	1.356	1.669

Pada Tabel 4 dapat dilihat, hasil pembentukan *association rules* berjumlah 7 rules. Berdasarkan hasil analisis penulis memilih *rule* nomor 7 yang memiliki nilai *confidence* yang paling tinggi yaitu 0.718 dan juga nilai *lift ratio* lebih dari 1 yaitu 1.356. Aturan nomor 7 Toast → Coffee dapat di uraikan menjadi *jika pelanggan memesan Toast, maka pelanggan juga akan memesan Coffee* dengan nilai *support* 0.040 atau 4% dari semua transaksi dalam *database* mengandung kedua item dan nilai *confidence* (kemungkinan) 0.718 atau 71% artinya dari semua transaksi yang mengandung toast, 71% juga mengandung *coffee*. Ini menunjukkan seberapa besar kemungkinan *coffee* akan dibeli saat *toast* dibeli. Nilai lift ratio 1.356 yang menunjukkan bahwa aturan yang dihasilkan memiliki korelasi positif dengan kekuatan asosiasi atau keterkaitan yang tinggi. Untuk meningkatkan pendapatan perusahaan, representasi pengetahuan yang dapat digunakan untuk memberikan rekomendasi produk kepada pelanggan melalui pemberian *product bundling* dengan menu Toast & Coffee pada waktu Morning – Weekday atau Senin – Jumat pukul 07.00 – 11.59.

2) Dataset “Morning – Weekend”

Pengujian kedua dilakukan dengan menggunakan data transaksi Morning – Weekend yaitu data pembelian pelanggan di hari sabtu dan minggu ketika pagi hari pukul 07.00 – 11.59. Berisikan 3230 data dengan 1455 transaksi. Dapat dilihat pada Tabel 5 dalam proses pengujian data Morning – Weekday ini, dilakukan pemodelan dengan algoritma FP – Growth dengan memasukkan nilai minimal *support* sebesar 0.04 dan memasukkan nilai minimal *confidence* sebesar 0.4. Sehingga didapatkan hasil *association rules* berjumlah 3 aturan.

Tabel 5. Hasil Association Rules transaksi Morning – Weekend

No	Premises	Conclusion	Support	Confidence	Lift	Coviction
1	Pastry	Coffee	0.068	0.495	1.013	1.013
2	Medialuna	Coffee	0.076	0.601	1.230	1.282
3	Hot Chocolate	Coffee	0.042	0.622	1.274	1.354

Berdasarkan hasil analisis maka dipilih aturan nomor 3 yaitu Hot chocolate → Coffee yang artinya *Jika pelanggan memesan Hot Chocolate, maka pelanggan juga akan memesan Coffee* dengan nilai *support* 4% dan nilai *confidence* (kemungkinan) 62% dengan nilai lift ratio 1.274 yang menunjukkan bahwa aturan yang dihasilkan memiliki korelasi positif dengan kekuatan asosiasi atau keterkaitan yang tinggi. Untuk meningkatkan pendapatan perusahaan, representasi pengetahuan yang dapat digunakan untuk memberikan rekomendasi produk kepada pelanggan melalui pemberian *product bundling* dengan menu Hot Chocolate & Coffee pada waktu Morning – Weekend atau Sabtu – Minggu pukul 07.00 – 11.59.

3) Dataset “Afternoon – Weekday”

Untuk proses pengujian ketiga, dilakukan dengan menggunakan data Afternoon – Weekday yaitu data pembelian konsumen di hari Senin - Jumat ketika siang hari pukul 12.00 – 16.59. *Dataset* memiliki 7273 data dengan 3325 transaksi. Dapat dilihat pada Tabel 6 dalam proses pengujian data Afternoon – Weekday ini, dilakukan perhitungan dengan algoritma FP – Growth dengan memasukkan nilai minimal *support* sebesar 0.06 dan memasukkan nilai minimal *confidence* sebesar 0.5. Sehingga akan mendapatkan hasil *association rules* berjumlah 2 *rules*.

Tabel 6. Hasil Association Rules Afternoon – Weekday

No	Premises	Conclusion	Support	Confidence	Lift	Coviction
1	Sandwich	Coffee	0.061	0.511	1.116	1.109
2	Cake	Coffee	0.066	0.528	1.152	1.147

Berdasarkan hasil analisis maka dipilih aturan nomor 3 yaitu Hot chocolate → Coffee yang artinya *Jika pelanggan memesan Cake*, maka pelanggan juga akan memesan *Coffee* dengan nilai *support* 66% dan nilai *confidence* (kemungkinan) 52% dengan nilai lift ratio 1.152 yang menunjukkan bahwa aturan yang dihasilkan memiliki korelasi positif dengan kekuatan asosiasi atau keterkaitan yang tinggi. Untuk meningkatkan pendapatan perusahaan, representasi pengetahuan yang dapat digunakan untuk memberikan rekomendasi produk kepada pelanggan melalui pemberian *product bundling* dengan menu Cake & Coffee pada waktu Afternoon – Weekday atau Senin – Jumat pukul 12.00 – 16.59.

4) Dataset “Afternoon – Weekend”

Untuk proses pengujian ke-empat, dilakukan dengan menggunakan data Afternoon – Weekend yaitu data pembelian konsumen di hari Sabtu – Minggu ketika siang hari pukul 12.00 – 16.59. *Dataset* memiliki 4296 data dengan 1764 transaksi. Berdasarkan Tabel 7 dalam proses pengujian data Afternoon – Weekend ini, dilakukan perhitungan dengan algoritma FP – Growth dengan memasukkan nilai minimal *support* sebesar 0.05 dan memasukkan nilai minimal *confidence* sebesar 0.5. Sehingga akan mendapatkan hasil *association rules* berjumlah 2 *rules*.

Tabel 7. Hasil Association Rules Afternoon – Weekend

No	Premises	Conclusion	Support	Confidence	Lift	Coviction
1	Cake	Coffee	0.083	0.523	1.130	1.126
2	Sandwich	Coffee	0.064	0.592	1.277	1.315

Berdasarkan hasil analisis maka dipilih aturan nomor 2 yaitu Sandwich → Coffee yang artinya *Jika pelanggan memesan Sandwich*, maka pelanggan juga akan memesan *Coffee* dengan nilai *support* 64% dan nilai *confidence* (kemungkinan) 59% dengan nilai lift ratio 1.277 yang menunjukkan bahwa *rule* ini memiliki korelasi positif dengan kekuatan asosiasi yang tinggi. Untuk meningkatkan pendapatan perusahaan, representasi pengetahuan yang dapat digunakan untuk memberikan rekomendasi produk kepada pelanggan melalui pemberian *product bundling* dengan menu Sandwich & Coffee pada waktu Afternoon – Weekend atau hari Sabtu – Minggu pukul 12.00 – 16.59.

5) Dataset “Evening – Weekday”

Untuk proses pengujian ke-lima, dilakukan dengan menggunakan data Evening – Weekday yaitu data pembelian konsumen di hari Senin - Jumat ketika sore hari pukul 17.00 – 20.59. *Dataset* memiliki 356 data dengan 169 transaksi. Berdasarkan Tabel 8, dalam proses pengujian data Evening – Weekday ini, dilakukan perhitungan dengan algoritma FP – Growth dengan memasukkan nilai minimal *support*

sebesar 0.02 dan memasukkan nilai minimal *confidence* sebesar 0.5. Sehingga akan mendapatkan hasil *association rules* berjumlah 5 *rules*.

Tabel 8. Hasil Association Rules Evening – Weekday

No	Premises	Conclusion	Support	Confidence	Lift	Coviction
1	Hot Chocolate	Coffee	0.041	0.500	1.432	1.302
2	Cake	Coffee	0.071	0.571	1.637	1.519
3	Alfajores	Coffee	0.047	0.571	1.637	1.519
4	Juice	Coffee	0.024	0.571	1.637	1.519
5	Pastry	Tea	0.030	0.625	2.780	2.067

Berdasarkan hasil analisis maka dipilih aturan nomor 5 yaitu Pastry → Tea yang artinya *Jika pelanggan memesan Pastry, maka pelanggan juga akan memesan Teh* dengan nilai *support* 30% dan nilai *confidence* (kemungkinan) 62% dengan nilai lift ratio 2.780 yang menunjukkan bahwa aturan yang dihasilkan memiliki korelasi positif dengan kekuatan asosiasi atau keterkaitan yang tinggi. Untuk meningkatkan pendapatan perusahaan, representasi pengetahuan yang dapat digunakan untuk memberikan rekomendasi produk kepada pelanggan melalui pemberian *product bundling* dengan menu Pastry & Tea pada waktu Evening – Weekday atau Senin – Jumat pukul 17.00 – 20.59.

6) Dataset “Evening – Weekend”

Untuk proses pengujian ke-enam, dilakukan dengan menggunakan data Evening – Weekend yaitu data pembelian konsumen di hari Sabtu - Minggu ketika sore hari pukul 17.00 – 20.59. Dataset memiliki 164 data dengan 92 transaksi. Berdasarkan Tabel 9 proses pengujian data Evening – Weekend ini, dilakukan perhitungan dengan algoritma FP – Growth dengan memasukkan nilai minimal *support* sebesar 0.06 dan memasukkan nilai minimal *confidence* sebesar 0.6.

Tabel 9. Hasil Association Rules Evening – Weekend

No	Premises	Conclusion	Support	Confidence	Lift	Coviction
1	Postcard	Tshirt	0.065	0.600	2.629	1.929

Berdasarkan hasil analisis maka dipilih aturan nomor 3 yaitu Postcard → Tshirt yang artinya *Jika pelanggan membeli Postcard, maka pelanggan juga akan membeli T-Shirt* dengan nilai *support* 65% dan nilai *confidence* (kemungkinan) 60% dengan nilai lift ratio 2.629 yang menunjukkan bahwa aturan yang dihasilkan memiliki korelasi positif dengan kekuatan asosiasi atau keterkaitan yang tinggi. Untuk meningkatkan pendapatan perusahaan, representasi pengetahuan yang dapat digunakan untuk memberikan rekomendasi produk kepada pelanggan melalui pemberian *product bundling* dengan produk Postcard & T-Shirt pada waktu Evening – Weekend atau Sabtu – Minggu pukul 17.00 – 20.59.

4. KESIMPULAN

Berdasarkan data dan hasil penelitian dapat diambil kesimpulan bahwa data mining dengan teknik asosiasi menggunakan algoritma FP-Growth dapat memberikan pengetahuan dari sekumpulan data transaksi pelanggan toko roti dengan memperlihatkan hubungan antara kombinasi item – item yang ada. Adapun aturan asosiasi yang dihasilkan untuk setiap jenis dataset adalah sebagai berikut:

- Morning – Weekday, jika *memesan* Toast maka akan *memesan* Coffee dengan nilai *support* 0.040 (40%) dan nilai *confidence* 0.718 (71%).
- Morning – Weekend, jika *memesan* Hot Chocolate maka akan *memesan* Coffee dengan nilai *support* 0.042 (42%) dan nilai *confidence* 0.622 (62%)

- c. Afternoon – Weekday, jika memesan Cake maka akan memesan Coffee dengan nilai *support* 0.066 (60%) dan nilai *confidence* 0.528 (52%).
- d. Afternoon – Weekend, jika memesan Sandwich maka akan memesan Coffee dengan nilai *support* 0.064 (64%) dan nilai *confidence* 0.592 (59%).
- e. Evening – Weekday, jika memesan Pastry maka akan memesan Coffee dengan nilai *support* 0.066 (66%) dan nilai *confidence* 0.625 (62%).
- f. Evening – Weekend, jika membeli Postcard maka akan membeli Tshirt dengan nilai *support* 0.065 (65%) dan nilai *confidence* 0.600 (60%).

Untuk semua rules yang di pilih memiliki nilai lift ratio lebih dari 1 yang menunjukkan adanya korelasi dan manfaat dari rules tersebut. Adapun hasil aturan yang di dapat berdasarkan percobaan yang telah dilakukan menggunakan minimum *support* dan minimum *confidence* yang berbeda tentunya menghasilkan jumlah aturan asosiasi yang berbeda. Dalam rangka menampilkan aturan asosiasi yang kuat tentunya nilai minimum *support* dan nilai minimum *confidence* sangat berpengaruh, semakin tinggi maka hasil aturan asosiasi yang dibentuk akan semakin sedikit dan memiliki hubungan asosiasi yang kuat.

Dengan membagi dataset pelanggan berdasarkan waktu pembelian, diketahui bahwa pola pembelian pada waktu tertentu ini berbeda beda. Hal ini dapat memberikan wawasan tentang preferensi konsumen dan kebiasaan belanja mereka. Dengan memanfaatkan algoritma FP-Growth, proses analisis data transaksi dapat dilakukan secara efisien untuk mengidentifikasi pola asosiasi antar produk, sehingga dapat mengoptimalkan *bundling* produk yang lebih tepat sasaran.

DAFTAR PUSTAKA

- [1] R. G. & S. M. J. W. F. & S. Ramdhani, “Strategi Product Bundling Dengan Pendekatan Market Basket Analysis dan Cost Plus Pricing Pada Kedai Kopi,” *Pros. Semin. Nas. Penelit. LPPM UMJ*, 2023.
- [2] M. R. Kumar, J. Venkatesh, and A. M. J. M. Z. Rahman, “Data mining and machine learning in retail business: developing efficiencies for better customer retention,” *J. Ambient Intell. Humaniz. Comput.*, no. 0123456789, 2021.
- [3] Anggun Pastika Sandi and Vina Widya Ningsih, “Implementasi Data Mining Sebagai Penentu Persediaan Produk Dengan Algoritma Fp-Growth Pada Data Penjualan Sinarmart,” *J. Publ. Ilmu Komput. dan Multimed.*, vol. 1, no. 2, pp. 111–122, 2022.
- [4] P.-N. Tan, Steinbach, M., and V. Kumar, *Introduction to Data Mining (3rd ed.)*. 2019.
- [5] N. F. FAHRUDIN, “Penerapan Algoritma Apriori untuk Market Basket Analysis,” *MIND J.*, vol. 1, no. 2, pp. 13–23, 2019.
- [6] E. Elisa, “Market Basket Analysis Pada Mini Market Ayu Dengan Algoritma Apriori,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 2, no. 2, pp. 472–478, 2018.
- [7] J. P. B. Saputra, S. A. Rahayu, and T. Hariguna, “Market Basket Analysis Using FP-Growth Algorithm to Design Marketing Strategy by Determining Consumer Purchasing Patterns,” *J. Appl. Data Sci.*, vol. 4, no. 1, pp. 38–49, 2023.
- [8] C. Satria, A. Anggrawan, and Mayadi, “Recommendation System of Food Package Using Apriori and FP-Growth Data Mining Methods,” *J. Adv. Inf. Technol.*, vol. 14, no. 3, pp. 454–462, 2023.
- [9] H. Maulidiya and A. Jananto, “Asosiasi Data Mining Menggunakan Algoritma Apriori dan FP-Growth sebagai Dasar Pertimbangan Penentuan Paket Sembako,” *Proceeding SENDIU 2020*, vol. 6, pp. 36–42, 2020.
- [10] D. Listriani, A. H. Setyaningrum, and F. E. M.A, “Penerapan Metode Asosiasi Menggunakan Algoritma Apriori Pada Aplikasi Pola Belanja Konsumen (Studi Kasus Toko Buku Gramedia Bintaro),” *J. Tek. Inform. Vol 9 No. 2, Univ. Islam Negeri Jakarta*, vol. 9, no. 2, pp. 120–127, 2016.
- [11] I. A. Ashari, A. Wirasto, D. N. Triwibowo, and Purwono, “Implementasi Market Basket Analysis dengan Algoritma Apriori untuk Analisis Pendapatan Usaha Retail,” *J. Manajemen, Tek. Inform. dan*

- Rekayasa Kompute*, vol. 21, 2022.
- [12] B. P. Patel, N. Gupta, R. K. Karn, and Y. Rana, "Optimization of association rules mining Apriori algorithm based on ACO," *Int. J. Emerg. Technol.*, vol. 2, no. 1, pp. 87–92, 2011.
 - [13] F. Achmad, O. Nurdiawan, and Y. Arie Wijaya, "Analisa Pola Transaksi Pembelian Konsumen Pada Toko Ritel Kesehatan Menggunakan Algoritma Fp-Growth," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 1, pp. 168–175, 2023.
 - [14] Erwin, "Analisis Market Basket Dengan Algoritma," *J. Generic*, vol. 4, pp. 26–30, 2009.
 - [15] E. W. Pujiharto, K. Kusri, and A. Nasiri, "Analisis Perbandingan Kinerja Algoritma Apriori, FP-Growth dan Eclat dalam menemukan Pola Frekuensi pada Dataset INA-CBG'S," *CogITo Smart J.*, vol. 9, no. 2, pp. 340–354, 2023.
 - [16] A. K. Singh, A. Kumar, and A. K. Maurya, "An empirical analysis and comparison of apriori and FP-growth algorithm for frequent pattern mining," *Proc. 2014 IEEE Int. Conf. Adv. Commun. Control Comput. Technol. ICACCT 2014*, no. 97, pp. 1599–1602, 2015.
 - [17] E. Kusri, *Algoritma Data Mining*. Yogyakarta: Andi, 2009.
 - [18] D. T. Larose, *Data Mining Methods & Models*. Wiley-Interscience, 2006.
 - [19] Md. Rabiul Islam; Mst. Sahela Rahman; Md. Julker Nayeem, *Association Rules Mining for a Specific Time Period in a Day in Large Transactional Database*. 2023.
 - [20] F. Elahe and K. Zhang, "Mining Frequent Itemsets Along with Rare Itemsets Based on Categorical Multiple Minimum Support," vol. 18, no. 6, pp. 109–114, 2016.
 - [21] W. P. Nurmawati *et al.*, "Market Basket Analysis with Apriori Algorithm and Frequent Pattern Growth (Fp-Growth) on Outdoor Product Sales Data," *Int. J. Educ. Res. Soc. Sci.*, vol. 2, no. 1, pp. 132–139, 2021.
 - [22] L. Samboteng, Rulinawaty, M. R. Kasmad, M. Basit, and R. Rahim, "Market Basket Analysis of Administrative Patterns Data of Consumer Purchases Using Data Mining Technology," *J. Appl. Eng. Sci.*, vol. 20, no. 2, pp. 339–345, 2022.
 - [23] S. G. Setyorini, Mustakim, J. Adhiva, and S. A. Putri, "Penerapan Algoritma FP-Growth dalam Penentuan Pola Pembelian Konsumen," *Semin. Nas. Teknol. Informasi, Komun. dan Ind.*, pp. 180–186, 2020.
 - [24] E. Munanda and S. Monalisa, "Penerapan Algoritma Fp-Growth Pada Data Transaksi Penjualan Untuk Penentuan Tataletak," *J. Ilm. Rekayasa dan Manaj. Sist. Inf.*, vol. 7, no. 2, pp. 173–184, 2021.
 - [25] P. Palupiningsih and B. Prayitno, "Implementasi Algoritma Fp-Growth Untuk Penentuan Rekomendasi Produk UMKM berdasarkan Frekuensi Pembelian," *J. Teknoinfo*, vol. 17, pp. 493–501, 2023.
 - [26] Muhammad Alvin, Alwis Nazir, M Fikry, Jasril, and Fadhilah Syafria, "Implementasi Algoritma Fp-Growth Untuk Mengetahui Faktor Yang Berpengaruh Terhadap Kemampuan Membaca Al-Quran Siswa," *J. RESTIKOM Ris. Tek. Inform. dan Komput.*, vol. 2, no. 2, pp. 66–78, 2022.