

IMPLEMENTASI ALGORITMA *FP-GROWTH* UNTUK OPTIMASI PELETAKAN BARANG SEWA DI BAYTI ADVENTURE

Muhammad Sadad Ulinnuha, Hardian Oktavianto,
B. Satria Bakti, Dudi Irawan, Ginanjar Abdurrahman
Teknik Informatika, Universitas Muhammadiyah Jember
Jalan Karimata No. 49 Jember, Indonesia
sadadulinnuha@gmail.com

ABSTRAK

Bisnis rental *outdoor* merupakan salah satu jenis usaha yang menyediakan jasa persewaan alat-alat *hiking* dan *camping*. Banyaknya variasi dan jumlah perlengkapan yang tersedia menuntut adanya pengelolaan tata letak barang yang baik. Namun demikian, beberapa perusahaan rental *outdoor* seperti *Bayti Adventure* masih menghadapi kesulitan dalam pengelolaan tata letak barang secara optimal, dimana pelanggan sering kesulitan menemukan barang yang dibutuhkan sehingga waktu pelayanan menjadi lebih lama. Berdasarkan hal tersebut, penelitian ini bertujuan untuk mengidentifikasi pola penyewaan barang yang sering disewa secara bersamaan dengan menerapkan algoritma *FP-Growth* dalam menganalisis data transaksi, serta menguji kekuatan aturan asosiasi yang dihasilkan menggunakan *lift ratio* dan *conviction* guna mengetahui kekuatan hubungan dan implikasi antar *item*. Metodologi yang digunakan mengikuti kerangka kerja sistematis yang meliputi pengumpulan data 715 transaksi periode 2024, *preprocessing data*, serta penerapan algoritma *FP-Growth*. Analisis dilakukan dengan menetapkan ambang batas *minimum support* 30% dan *minimum confidence* 60%. Hasil penelitian menunjukkan adanya tujuh aturan asosiasi yang signifikan, seperti korelasi kuat antara Lampu Tenda (LT) dengan Tenda (T), serta Kompor (K) dengan Gas (G). Temuan ini membuktikan bahwa algoritma *FP-Growth* efektif dalam mengidentifikasi pola frekuensi tinggi dan memberikan landasan akurat bagi penataan ruang inventaris guna meningkatkan efisiensi operasional layanan di *Bayti Adventure*.

Kata kunci : algoritma *fp-growth*, aturan asosiasi, peletakan barang

1. PENDAHULUAN

Bisnis rental *outdoor* merupakan salah satu jenis usaha yang menyediakan jasa persewaan alat-alat *hiking* dan *camping*. Aktivitas *hiking* dan *camping* memerlukan berbagai perlengkapan khusus yang lebih praktis untuk disewa daripada dibeli. Banyaknya variasi dan jumlah perlengkapan yang tersedia menuntut adanya pengelolaan tata letak barang yang baik. Efisiensi tata letak yang strategis dalam pengelolaan barang sewa dapat meningkatkan kenyamanan serta mendukung efisiensi operasional perusahaan. Selain itu, strategi penyusunan barang berdasarkan pola pembelian pelanggan juga dapat mempermudah pelanggan dalam menemukan barang yang diinginkan [1].

Namun demikian, beberapa perusahaan rental *outdoor* masih menghadapi kesulitan dalam pengelolaan tata letak barang secara optimal. *Bayti Adventure* merupakan salah satu perusahaan yang mengalami permasalahan tersebut, di mana pelanggan sering kesulitan menemukan barang yang dibutuhkan sehingga waktu pelayanan menjadi lebih lama. Berdasarkan data transaksi sepanjang tahun 2023 yang mencapai 818 transaksi, kondisi ini berdampak pada menurunnya tingkat kepuasan pelanggan. Permasalahan ini menunjukkan bahwa data transaksi yang tersedia belum dimanfaatkan secara optimal untuk mendukung pengambilan keputusan, khususnya dalam penentuan tata letak barang yang efektif.

Untuk mengatasi permasalahan tersebut, diperlukan pendekatan berbasis data yang mampu

mengidentifikasi pola hubungan antar *item* yang sering disewa secara bersamaan. Salah satu pendekatan yang dapat digunakan adalah *association rules mining* dengan algoritma *FP-Growth*. Algoritma *FP-Growth* merupakan pengembangan dari algoritma *Apriori* yang menggunakan konsep *frequent itemsets* untuk menentukan aturan asosiasi pada data transaksi [2]. Berbeda dengan *Apriori*, algoritma ini tidak menghasilkan kandidat, melainkan memanfaatkan struktur pohon (*tree*) untuk menemukan pola secara lebih efisien [3]. Penelitian sebelumnya menunjukkan bahwa penerapan algoritma *FP-Growth* mampu menghasilkan aturan asosiasi yang optimal dengan nilai *support* dan *confidence* tertentu serta didukung oleh pengujian *lift* yang menunjukkan peluang *cross-selling* yang baik [2].

Berdasarkan hal tersebut, penelitian ini bertujuan untuk mengidentifikasi pola penyewaan barang yang sering disewa secara bersamaan serta menerapkan algoritma *FP-Growth* dalam menganalisis data transaksi pada *Bayti Adventure*. Selain itu, penelitian ini juga bertujuan untuk menguji kekuatan aturan asosiasi yang dihasilkan menggunakan *lift ratio* dan *conviction* guna mengetahui kekuatan hubungan dan implikasi antar *item*.

Adapun rencana penyelesaian masalah dalam penelitian ini dilakukan dengan mengolah data transaksi menggunakan algoritma *FP-Growth* untuk menghasilkan aturan asosiasi berdasarkan *frequent itemsets*. Selanjutnya, aturan yang diperoleh diuji menggunakan *lift ratio* dan *conviction* untuk menilai

kualitas dan kekuatan hubungan antar *item*. Hasil analisis tersebut kemudian digunakan sebagai dasar dalam memberikan rekomendasi penataan tata letak barang yang lebih optimal, sehingga diharapkan dapat meningkatkan efisiensi operasional dan kualitas pelayanan pada *Bayti Adventure*.

2. TINJAUAN PUSTAKA

Sebelum melakukan penelitian ini, penulis terlebih dahulu melakukan studi literatur dengan berbagai referensi yang relevan, baik berupa buku, jurnal ilmiah nasional maupun internasional, serta sumber daring yang berkaitan dengan algoritma *FP-Growth*. Studi literatur ini bertujuan untuk memahami konsep dasar yang digunakan serta mengidentifikasi penelitian terdahulu yang memiliki keterkaitan dengan topik penelitian, khususnya konsep aturan asosiasi.

Penelitian yang dilakukan oleh [4] dengan judul “Analisis Perbandingan Algoritma Apriori dan *FP-Growth* dalam Pembentukan Pola Asosiasi Keranjang Belanja Pelanggan.” Menunjukkan bahwa penelitian menggunakan algoritma *Apriori* dan Algoritma *FP-Growth* dengan nilai *support* 60% dan nilai *confidence* 20%. Penggunaan dari kedua algoritma tersebut menghasilkan 3 kombinasi *itemset* yang sama. Akan tetapi, algoritma *FP-Growth* mampu menghasilkan aturan asosiasi yang kuat dibandingkan dengan algoritma *Apriori*.

Penelitian lain oleh [5] dalam “Penerapan Algoritma Apriori untuk Analisa Pola Penempatan Barang Berdasarkan Data Transaksi Penjualan.” Membuktikan bahwa Toko Berkah Baru mengalami permasalahan penempatan barang yang kurang efisien. Algoritma *Apriori* diimplementasikan dalam penelitian ini. Analisis terhadap 31 transaksi penjualan dengan nilai minimum *support* sebesar 6% dan nilai *confidence* 60% menghasilkan lima aturan asosiasi. Penerapan algoritma ini mendukung optimalisasi penempatan barang serta meningkatkan penjualan secara optimal. Namun, Algoritma *Apriori* kurang efisien untuk *dataset* besar.

Penelitian terakhir yaitu [6] memiliki judul “Penerapan Algoritma Apriori untuk Menentukan Tata Letak Barang (Studi Kasus: Swalayan S&M Mart).” Menghasilkan bahwa algoritma *Apriori* diterapkan dalam penelitian ini untuk menganalisis 2.024 data transaksi penjualan periode 2020–2021. Alat bantu (*tool*) yang digunakan adalah *Rapidminer*. Penghitungan menggunakan nilai minimum *support* 30% dan nilai *confidence* 80% menghasilkan lima belas aturan asosiasi. Aturan tersebut menjadi dasar untuk optimalisasi tata letak barang dan pengadaan promo diskon terhadap pembelian barang yang terjadi bersamaan. Algoritma *Apriori* efektif untuk menemukan *frequent itemset*, tetapi membutuhkan waktu yang lama dalam pemrosesan data.

2.1. Data Mining

Data mining, menurut [7] adalah proses menemukan pola atau informasi berguna dari kumpulan data besar menggunakan teknik seperti statistik, matematika, dan kecerdasan buatan. *Data mining* adalah analisis otomatis data kompleks untuk menemukan tren atau pola penting yang seringkali tidak terlihat sebelumnya. Tujuan *data mining* adalah untuk menemukan pola tersembunyi dan menghasilkan pengetahuan yang dapat membantu pengambilan keputusan dalam berbagai bidang, seperti bisnis, keuangan, dan pendidikan.

2.2. Association Rules Mining

Association rule mining adalah teknik dalam *data mining* yang digunakan untuk menemukan hubungan tersembunyi atau pola menarik di antara *item-item* dalam kumpulan data besar. Teknik ini diterapkan dalam suatu transaksi untuk menganalisis *item* tertentu yang sering muncul bersama, seperti analisis keranjang belanja (*market basket analysis*) [8]. Algoritma ini bekerja dengan menentukan empat metrik utama untuk meminimalisir terjadinya efisiensi kekurangan dalam menghasilkan aturan. Empat metrik utama tersebut adalah sebagai berikut.

2.3. Support

Support menunjukkan *dataset* himpunan beberapa *item* tertentu yang sering muncul secara bersamaan. Menurut [9], penghitungan nilai *support* menggunakan rumus (1).

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

2.4. Confidence

Metrik ini mengukur tingkat kepercayaan terhadap suatu aturan asosiasi. Dengan kata lain, probabilitas *item B* terjadi dengan syarat *item A* juga terjadi. Nilai *confidence* dari *item A* adalah jumlah seluruh transaksi yang terdapat *item A* dibagi dengan banyak seluruh transaksi [9] sebagaimana dinyatakan dalam rumus (2).

$$\text{Confidence (A} \rightarrow \text{B)} = \frac{\text{Banyak transaksi yang mengandung item A dan B}}{\text{Banyak transaksi yang mengandung item A}} \quad (2)$$

2.5. Lift Ratio

Lift ratio adalah suatu ukuran yang digunakan dalam analisis asosiasi untuk mengevaluasi ketergantungan hubungan antara dua *item* atau peristiwa dalam *dataset*. Tujuan utama dari *lift ratio* untuk menilai apakah dua *item* yang muncul bersamaan terjadi lebih sering dibandingkan dengan jika mereka terjadi secara independen satu sama lain. Rumus (3) digunakan dalam penghitungan *lift ratio* adalah sebagai berikut.

$$\text{Lift Ratio} = \frac{\text{Support (A} \rightarrow \text{B)}}{\text{Support (A)} \times \text{Support (B)}} \quad [10] \quad (3)$$

Menurut [11], Penentuan nilai hubungan aturan asosiasi jika $\text{Lift(A} \rightarrow \text{B)} > 1$ diinterpretasikan sebagai tingkat ketergantungan positif (kuat),

$Lift(A \rightarrow B) = 1$ diinterpretasikan sebagai tidak ada ketergantungan kejadian A dan kejadian B, berikut (Bakti, dan $Lift(A \rightarrow B) < 1$ diinterpretasikan sebagai tingkat ketergantungan negatif (lemah).

2.6. Conviction

Conviction mengukur tingkat keyakinan aturan $A \rightarrow B$. Menurut [11], rumus (4) digunakan dalam penghitungan *conviction* dinyatakan sebagai berikut.

$$Conviction = \frac{1 - Support(B)}{1 - Confidence(A \rightarrow B)} \quad (4)$$

Range nilai dari *conviction* berada pada interval $[0, \infty]$. Semakin nilai *conviction* lebih dari 1, semakin kuat suatu aturan asosiasi bersangkutan [11], $Conv(A \rightarrow B) > 1$ diinterpretasikan sebagai tingkat aturan asosiasi yang kuat, $Conv(A \rightarrow B) = 1$ diinterpretasikan sebagai tidak memiliki kekuatan sebagai aturan asosiasi, dan $Conv(A \rightarrow B) < 1$ diinterpretasikan sebagai tingkat aturan asosiasi yang lemah.


2.7. Threshold (Ambang Batas)

Threshold adalah ambang batas atau nilai batas yang digunakan sebagai kriteria dalam suatu proses pengambilan keputusan. Dalam aturan asosiasi (*association rule*), *threshold* terdiri dari *minimum support* dan nilai *minimum confidence*. *Minimum support* merupakan batas nilai *minimum* untuk mengukur frekuensi kemunculan *itemset* dalam *dataset*, sedangkan *minimum confidence* adalah batas *minimum* tingkat kepercayaan terhadap sebuah *rule* dalam penentuan aturan asosiasi [8]. Penentuan nilai *minimum support* dan *minimum confidence* bersifat kustomisasi (pemegang keputusan). Jika, hasil penghitungan nilai *support* dan *confidence* tidak memenuhi batas *threshold* maka akan dieliminasi.

2.8. Algoritma FP-Growth

FP-Growth dibangun dengan pendekatan *divide and conquer*, yaitu membagi data ke dalam beberapa pola bersyarat dan mencari himpunan *item* yang sering muncul secara rekursif pada setiap *subset* tersebut [12]. Langkah utamanya melibatkan dua kali pemindaian data, yaitu pertama untuk menghitung frekuensi setiap *item* dan kedua untuk membentuk struktur *FP-Tree* berdasarkan urutan frekuensi tersebut.

3. METODE PENELITIAN



Gambar 1. Bagan alir tahapan penelitian

Tahapan pelaksanaan penelitian ini terdiri dari enam langkah. Berikut adalah bagan alir tahapan pelaksanaan penelitian yang dilakukan.

3.1. Pengumpulan Data

Proses pengumpulan data dilakukan secara komprehensif melalui dua pendekatan utama, yakni metode dokumentasi dan studi literatur. Peneliti mengekstraksi data historis dari catatan pembukuan tahunan perusahaan untuk mendapatkan basis transaksi yang riil. Secara simultan, pendalaman teori dilakukan dengan menelaah berbagai referensi akademik seperti jurnal ilmiah, buku teks, serta materi edukasi audio-visual yang relevan dengan teknik *association rule mining* dan manajemen inventori untuk memperkuat landasan teoretis penelitian.

3.2. Analisis Kebutuhan

Fokus penelitian diarahkan pada pola perilaku penyewaan pelanggan dengan mengambil sampel data transaksi dari Bayti Adventure. Data yang dianalisis mencakup periode 1-6 Januari 2024. Melalui identifikasi *item* yang sering disewa secara bersamaan, penelitian ini bertujuan untuk menyusun skema penempatan barang yang lebih efisien. Ruang lingkup ini memastikan bahwa rekomendasi yang dihasilkan nantinya benar-benar berbasis pada frekuensi kemunculan *item* secara faktual di lokasi penelitian.

Tabel 1. Data Transaksi Persewaan 1-6 Januari 2024

TID	Tanggal	Nama	Item	Unit
T1	01/01/2024	Indah	Jaket	2
T2	01/01/2024	Sofyan	Kompor	1
			Grill	1
			Gas	1
T3	01/01/2024	Triutami	Kompor	1
			Matras	1
T4	02/01/2024	Syafiq	Tenda	2
			Jaket	1
T5	02/01/2024	Zainal	Tenda	1
			Matras	2
			Gas	1
T6	02/01/2024	Syahrul	Kompor	1
			Grill	1
			Gas	1
T7	03/01/2024	Riska	SB	10
			Tenda	3
			Kompor	2
			Matras	5
			Cooking Set	2
			Kursi Lipat	2
T8	05/01/2024	Naufal	Grill	1
			Gas	2
T9	05/01/2024	Lailatul	Tenda	1
			Kompor	1
			Gas	1
T10	06/01/2024	Dia	Cooking Set	1
			Trackpole	3
			Sepatu	1

3.3. Pengolahan Data

Transformasi data mentah menjadi informasi siap olah melibatkan prosedur *data preprocessing* yang ketat, meliputi pembersihan, transformasi, dan pengodean data. Data transaksi awal yang mengandung informasi personal seperti nama dan alamat pelanggan direduksi (*cleaning*) agar hanya menyisakan atribut relevan seperti ID Transaksi dan jenis barang. Selanjutnya, dilakukan *label encoding* dengan memberikan inisial tertentu pada setiap *item* (misalnya 'T' untuk Tenda dan 'K' untuk Kompor) guna menyederhanakan proses komputasi pada tahap perhitungan algoritma.


3.4. Penerapan Metode Algoritma FP-Growth

Menurut [13], langkah-langkah utama dalam algoritma *FP-Growth* adalah sebagai berikut.

- Penyiapan *dataset* transaksi yang berisikan *item-item*.
- Penghitungan frekuensi kemunculan *item* (*frequent item*).
- Pengurutan *item-item* berdasarkan frekuensi kemunculan (*frequent item*) secara *descending* (dari nilai terbesar ke nilai terkecil).
- Pembentukan *itemset* pola transaksi dari *dataset* berdasarkan *frequent item* yang diurutkan secara *descending* (dari nilai terbesar ke nilai terkecil).
- Dengan *itemset* yang telah diurutkan secara *descending* pada langkah sebelumnya, proses pembangunan *FP-Tree* dilakukan berdasarkan urutan transaksi pada *dataset*.
- Pembentukan *conditional pattern base*, yaitu mendata *leaf item* (*item* daun) dari *FP-Tree* yang diikuti *ancestor* atau urutan *node* dari *root* hingga *node* terakhir (sebelum *item* daun) yang terhubung dalam satu jalur. Banyak kejadian *itemset* (*frequent itemset*) juga dihitung pada tahap ini.
- Pembangkitan *conditional FP-Tree* pada setiap pola untuk menemukan semua *frequent itemsets* secara bertahap menggunakan acuan nilai *minimum support* yang telah ditemukan.

3.4. Implementasi Data pada Rapidminer

Dataset diimpor ke dalam aplikasi tools *Rapidminer* menggunakan operator *FP-Growth* dan operator *Association Rules Mining* sehingga dapat menghasilkan *item* yang memenuhi *minimum support*, nilai *minimum confidence*, serta hasil *association rules mining* ditampilkan. Ilustrasi pengolahan *dataset* dapat ditunjukkan pada gambar (2).



Gambar 2. Pengolahan *dataset* menggunakan operator *fp-growth* dan *association rules mining*

4. HASIL DAN PEMBAHASAN

Hasil penelitian ini menyajikan data yang diperoleh dari tahap pengolahan dataset menggunakan algoritma *FP-Growth*. Pembahasan difokuskan pada hasil aturan asosiasi dengan diperkuat menggunakan metrik pengitungan *lift ratio* dan *conviction*.

4.1. Pengumpulan Data

Transformasi data mentah menjadi informasi siap olah melibatkan prosedur data preprocessing yang ketat, meliputi pembersihan, transformasi, dan pengodean data.

4.2. Data Collection

Dataset yang digunakan berjumlah 715 *dataset* pada tahun 2024 yang telah didapatkan melalui tahap rekaman tahunan yang telah dicatat sebelumnya. Guna mendukung transparansi penelitian, keseluruhan *dataset* ulasan yang digunakan dalam penelitian ini dapat diakses secara terbuka melalui tautan: https://docs.google.com/document/d/1-b_iEu152Dly7ePcouy_r0stMiOCn7Mt/edit.

4.3. Data Cleaning

Data transaksi awal yang mengandung informasi personal seperti nama dan alamat pelanggan direduksi (*cleaning*) agar hanya menyisakan atribut relevan seperti ID Transaksi dan jenis barang. Guna menyederhanakan proses komputasi pada tahap perhitungan algoritma. Guna mendukung transparansi penelitian, keseluruhan *dataset* ulasan yang digunakan dalam penelitian ini dapat diakses secara terbuka melalui tautan:

https://docs.google.com/document/d/1ytI7aaGAFA_mW9eNeXsNjBUzB2PyyJsi/edit#heading=h.kgf44reqlprc

4.4. Data Transformation

Selanjutnya, dilakukan *label encoding* dengan memberikan inisial tertentu pada setiap *item* (misalnya 'T' untuk Tenda dan 'K' untuk Kompor). Berikut merupakan *item-item* yang akan diproses menggunakan metode penghitungan algoritma *FP-Growth*.

Tabel 2. Label Encoding

No	Item	Inisial	No	Item	Inisial
1	Tenda	T	13	Carrier	CR
2	Matras	M	14	Kursi Lipat	KL
3	Sleeping Bag	SB	15	Meja Lipat	ML
4	Gas	G	16	Power Bank	PB
5	Kompor	K	17	Gelas Carabiner	GC
6	Grill	R	18	Jaket	J
7	Cooking Set	C	19	Hydropack	HY
8	Nesting	N	20	Sepatu	SP
9	Headlamp	H	21	Sarung Tangan	ST
10	Lampu Tenda	LT	22	Masker Gas	MG
11	Flysheet	F	23	Tripod	TR
12	Trackpole	TP			

4.5. Penyiapan Dataset

Tahap penyiapan dataset merupakan proses inisialisasi seluruh itemset transaksi yang telah dihimpun dari data transaksi tahun 2024. Setiap transaksi direpresentasikan dalam bentuk pasangan *Transaction ID* (TID) dan *itemset* yang muncul pada transaksi tersebut. Dataset ini menjadi dasar utama dalam proses penambangan pola asosiasi karena seluruh perhitungan selanjutnya bergantung pada kelengkapan dan konsistensi data transaksi yang digunakan. Guna mendukung transparansi penelitian, keseluruhan dataset ulasan yang digunakan dalam penelitian ini dapat diakses secara terbuka melalui tautan: <https://docs.google.com/document/d/1BjLwSNxAJkTE5-365itCTZpOJfoCJBeS/edit#heading=h.xkv81odvwr0z>

4.6. Penentuan *minimum support* dan *mininum confidence*

Nilai *minimum support* yang digunakan dalam kasus contoh data transaksi di atas adalah 0,14 (14%). Nilai *minimum confidence* yang digunakan adalah 0,40 (40%).

4.7. Penghitungan *frequent itemset*.

Penghitungan *frequent itemset* dilakukan dengan menghitung frekuensi kemunculan setiap *item* tunggal pada seluruh data transaksi. Tahap ini bertujuan untuk mengetahui *item-item* yang paling sering muncul dan berpotensi membentuk pola asosiasi. Hasil penghitungan frekuensi seluruh *item* ditampilkan pada tabel berikut.

Tabel 3. Hasil Perhitungan *Frequent Itemset*.

No	Item	Frekuensi	No	Item	Frekuensi
1	T	256	13	C	59
2	M	166	14	KL	78
3	SB	83	15	ML	46
4	G	253	16	PB	107
5	K	197	17	GC	15
6	GR	79	18	J	96
7	CS	81	19	HY	21
8	N	12	20	S	94
9	H	124	21	ST	38
10	LT	108	22	MG	29
11	F	26	23	TR	32
12	TP	87			

4.8. Penyusunan *itemset* secara *descending*

Itemset kemudian disusun berdasarkan frekuensi kemunculan dari nilai terbesar hingga terkecil. Pengurutan ini bertujuan untuk mempermudah proses seleksi *item* yang memenuhi ambang batas *minimum support*. *Item* dengan frekuensi tertinggi ditempatkan pada urutan teratas, sedangkan *item* dengan frekuensi rendah berada di bagian bawah.

Tabel 4. Urutan *Itemset* Secara *Descending*

No	Item	Frekuensi	No	Item	Frekuensi
1	T	256	13	GR	79
2	G	253	14	KL	78
3	K	197	15	C	59
4	M	166	16	ML	46
5	H	124	17	ST	38
6	LT	108	18	TR	32
7	PB	107	19	MG	29
8	J	96	20	F	26
9	S	94	21	HY	21
10	TP	87	22	GC	15
11	SB	83	23	N	12
12	CS	81			

4.9. Penghitungan nilai *support*

Berikut merupakan contoh penghitungan menggunakan Rumus 2.1 untuk mengetahui hasil nilai *support item* T pada data yang ditunjukkan dalam Tabel 4. menggunakan rumus (1).

$$Support(T) = \frac{256}{715} = 0,35$$

Hasil dari penghitungan nilai *support* di atas adalah 0,35 atau 35%. Hasil perhitungan menunjukkan nilai di atas 14% sehingga nilai *support item* T memenuhi ambang batas *minimal support*. Hasil perhitungan nilai *support item* tunggal yang memenuhi nilai *minimum support* dapat diperhatikan pada Tabel 5 berikut.

Tabel 5. Hasil Nilai *Support Item Tunggal*

Item	Frekuensi	Support		Status
		Desimal	Persentase	
T	256	0,35	35%	Diterima
G	253	0,35	35%	Diterima
K	197	0,27	27%	Diterima
M	166	0,23	23%	Diterima
H	124	0,17	17%	Diterima
LT	108	0,15	15%	Diterima
PB	107	0,14	14%	Diterima

4.10. Pengurutan *dataset* secara *descending*.

Tahap terakhir adalah mengurutkan *item* dalam setiap transaksi berdasarkan nilai *support* tertinggi ke terendah. *Item* yang tidak memenuhi *minimum support* dieliminasi dari transaksi tersebut. Proses ini bertujuan untuk menghasilkan *dataset* yang lebih ringkas dan relevan untuk pembentukan struktur *FP-Tree* atau algoritma asosiasi lanjutan.

Tabel 6. Urutan *Dataset* Secara *Descending*

TID	Itemsets	Itemsets Terurut
1	J	Tidak memenuhi nilai <i>minimum support</i>
2	G, K, GR	G, K
3	M, K	K, M
4	T, J	T
5	T, M, G	T, G, M
.....		

Guna mendukung transparansi penelitian, keseluruhan dataset ulasan yang digunakan dalam penelitian ini dapat diakses secara terbuka melalui tautan:

<https://docs.google.com/document/d/1WAnxC-x652Rp5FUEq2M3LoFP5gX4uBzj/edit#heading=h.14eq21h5wmmn>

4.11. Pembentukan *FP-Tree*

Berikutnya, pembentukan *FP-Tree* dilakukan dengan menggunakan hasil perhitungan frekuensi yang paling tinggi ke paling rendah berdasarkan cara yang telah dijelaskan pada Subbab 3.2.6. Gambar 3 merupakan pembentukan pohon yang dihasilkan. Guna mendukung transparansi penelitian, hasil gambar pembentukan *FP-Tree* dalam penelitian ini dapat diakses secara terbuka melalui tautan: https://drive.google.com/file/d/124tmivyXbFLvmBoSu_1bDN5svNKM7s8y/view?usp=drive_link

4.12. Pembentukan *Conditional Pattern Base (CPB)*

Peninjauan kembali *FP-Tree* yang telah dibangun merupakan tahapan dalam penyusunan jalur *conditional pattern base*. Penyusunan dimulai dari *node item* dengan *count* (nilai frekuensi) terendah hingga *count* tertinggi. Berikut adalah tabel untuk sufiks dan *conditional pattern base* yang terbentuk berdasarkan *FP-Tree* di atas. Tabel 8 guna mendukung transparansi penelitian, keseluruhan dataset ulasan yang digunakan dalam penelitian ini dapat diakses secara terbuka melalui tautan:

https://docs.google.com/document/d/1E4YPFHpD5fvSkUZCCB_-Enzd34ory2Ht/edit

Tabel 7. Sufiks Untuk *Conditional Pattern Base*

Sufiks	PB	LT	H	K	M	G	T
Count	107	108	124	197	166	253	256

Tabel 8. *Conditional Pattern Base* setiap *Node*

Sufiks	CPB	Count
K	{G}	91
	{T}	23
	{T, G}	63
	Null	-
...	...	...

4.13. Pembentukan *Conditional FP-Tree*

Tahap pembuatan *conditional FP-Tree* dibentuk berdasarkan frekuensi kemunculan *item* dalam *itemset*. Sebagai ilustrasi, pembentukan *conditional FP-Tree* untuk menuju sufiks K, terdapat tiga jalur, yaitu CPB: {G}, CPB: {T} dan CPB: {T, G} yang terletak satu jalur, dan CPB: Null. *Node* {G} tidak terletak pada satu jalur dengan *node* {T} dan {T, G}. Dengan demikian, frekuensi kemunculan (*count*) G untuk sufiks K dapat dinyatakan sebagai berikut.

$$K \rightarrow \{G\}: 91; \quad \text{nilai support } \{G\} = 0,127$$

Sementara itu, *node* K dilalui sebanyak dua kali pada jalur yang sama, yaitu pada prefiks {T} dan {T, G}. Nilai *support* sufiks K yang sejajar didapatkan dari penjumlahan *count* $K \rightarrow \{T\}: 23$ dengan *count* $K \rightarrow \{T, G\}: 63$. Frekuensi kemunculan (*count*) dari T untuk sufiks K yang sejajar adalah sebagai berikut.

$$K \rightarrow \{T\}: 23; K \rightarrow \{T, G\}: 63$$

$$\text{Count total} = \text{count}(K \rightarrow \{T\}) + \text{count}(K \rightarrow \{T, G\}) = 23 + 63 = 86$$

$$\text{Support} = \frac{\text{Total count}}{\text{Banyak seluruh transaksi}} = \frac{86}{715} = 0,120$$

Untuk sufiks dengan CPB adalah Null, *count* untuknya diabaikan. Dengan demikian, setiap kasus yang memiliki CPB: Null tereliminasi.

Minimal support yang ditentukan adalah 0,1 (10%). Dari contoh di atas, *node item* G dan T memiliki nilai *support* masing-masing sebesar 0,127 dan 0,120. Artinya, *node item* G dan T pada sufiks K adalah diterima karena nilai *support*-nya memenuhi ambang batas *minimal support*. Guna mendukung transparansi penelitian, keseluruhan dataset ulasan yang digunakan dalam penelitian ini dapat diakses secara terbuka melalui tautan: <https://docs.google.com/document/d/1WAnxC-https://docs.google.com/document/d/1DHI9aRJevQgMRK3an93RIAfmZudmApLD/edit>

4.14. Pembentukan *Frequent Pattern*

Frequent pattern merupakan kombinasi *itemset* yang dibentuk dari sufiks dan *item* hasil pembentukan *FP-Tree*. Hasil pembentukan *CFP-Tree* menunjukkan bahwa sufiks yang memenuhi nilai *minimum support* adalah sufiks LT, M, K, dan G. Sebagai ilustrasi adalah pembentukan *frequent pattern* sufiks G dengan CPF-

Tree {T: 111}. Frequent pattern yang terbentuk adalah {{T, G}: 111}. Artinya, frekuensi dari kombinasi {T, G} adalah 111 dengan nilai support 0,16. Hasil keseluruhan frequent itemset yang diperoleh adalah sebagai berikut.

Tabel 9. Pembentukan Frequent Pattern

Sufiks	CFP-Tree	Frequent Pattern	Support
{LT}	{T}	{T, LT} = 88	0,12
{M}	{T}	{T, M} = 134	0,19
{K}	{G}	{G, K} = 91	0,13
	{T}	{T, K} = 86	0,12
{G}	{T}	{T, G} = 111	0,16

4.15. Pembentukan Aturan Asosiasi

Aturan-aturan asosiasi (association rules) disusun berdasarkan frequent pattern yang diperoleh dengan cara membentuk himpunan bagiannya. Himpunan bagian yang diambil adalah selain himpunan kosong dan himpunan dirinya sendiri (frequent pattern tersebut). Sebagai contoh adalah sufiks LT yang memiliki frequent pattern {T, LT} sehingga:

$$S = \{T, LT\}$$

Himpunan bagian: {}, {T}; {LT}, dan {T, LT}

Himpunan yang diambil: {T} dan {LT}

Untuk $H = \{T\}$, aturan asosiasi yang didapatkan:

$$\Rightarrow H \rightarrow (S - H)$$

$$\Rightarrow \{T\} \rightarrow (\{T, LT\} - \{T\})$$

$$\Rightarrow \{T\} \rightarrow \{LT\}$$

Untuk $H = \{LT\}$, aturan asosiasi yang didapatkan:

$$\Rightarrow H \rightarrow (S - H)$$

$$\Rightarrow \{LT\} \rightarrow (\{T, LT\} - \{LT\})$$

$$\Rightarrow \{LT\} \rightarrow \{T\}$$

Frequent pattern {T, LT} menghasilkan aturan asosiasi:

a. $\{T\} \rightarrow \{LT\}$: artinya, jika item K dipilih, item G dipilih berikutnya.

b. $\{LT\} \rightarrow \{T\}$: artinya, jika item G dipilih, item K dipilih berikutnya.

Aturan asosiasi yang terbentuk untuk keseluruhan frequent pattern berdasarkan cara seperti di atas disajikan dalam Tabel 10 berikut.

Tabel 10. Pembentukan Aturan Asosiasi

Frequent Pattern	Aturan Asosiasi
{T, LT}	$\{T\} \rightarrow \{LT\}$
	$\{LT\} \rightarrow \{T\}$
{T, M}	$\{T\} \rightarrow \{M\}$
	$\{M\} \rightarrow \{T\}$
{T, K}	$\{T\} \rightarrow \{K\}$
	$\{K\} \rightarrow \{T\}$
{G, K}	$\{G\} \rightarrow \{K\}$
	$\{K\} \rightarrow \{G\}$
{T, G}	$\{T\} \rightarrow \{G\}$
	$\{G\} \rightarrow \{T\}$

4.16. Penghitungan Nilai Confidence

Setelah aturan asosiasi didapatkan, nilai confidence dari setiap aturan asosiasi dihitung. Aturan asosiasi yang digunakan adalah yang memenuhi nilai

minimal confidence. Penghitungan aturan asosiasi dari $\{T\} \rightarrow \{LT\}$ dan $\{LT\} \rightarrow \{T\}$ menggunakan rumus (2) adalah sebagai berikut.

$$\text{Count}(\{T, LT\}) = 88; \quad \text{Count}(\{T\}) = 256;$$

$$\text{Confidence}(\{T\} \rightarrow \{LT\}) = \frac{\text{Count}(\{T, LT\})}{\text{Count}(T)} = \frac{88}{256} = 0,34 = 34\%$$

$$\text{Count}(\{LT, T\}) = 88; \quad \text{Count}(\{LT\}) = 108;$$

$$\text{Confidence}(\{LT\} \rightarrow \{T\}) = \frac{\text{Count}(\{LT, T\})}{\text{Count}(LT)} = \frac{88}{108} = 0,81 = 81\%$$

Nilai minimal confidence yang ditetapkan adalah 0,40. Artinya, nilai confidence suatu aturan asosiasi di bawah 0,40 ditolak. Sebaliknya, nilai confidence aturan asosiasi yang sama dengan atau lebih dari 0,4 diterima. Berikut hasil perhitungan lengkap nilai confidence untuk semua aturan asosiasi yang disajikan pada tabel 11.

Tabel 11. Nilai Confidence Aturan Asosiasi

Aturan Asosiasi	Confidence	Status
$\{LT\} \rightarrow \{T\}$	0,81	Diterima
$\{T\} \rightarrow \{M\}$	0,52	Diterima
$\{M\} \rightarrow \{T\}$	0,80	Diterima
$\{K\} \rightarrow \{T\}$	0,46	Diterima
$\{K\} \rightarrow \{G\}$	0,43	Diterima
$\{T\} \rightarrow \{G\}$	0,43	Diterima
$\{G\} \rightarrow \{T\}$	0,43	Diterima

4.17. Penghitungan Lift Ratio

Nilai lift ratio yang dihitung menggunakan rumus (3) adalah untuk mengevaluasi tingkat ketergantungan hubungan (kejadian bersamaan) antara dua itemset. Contoh lift ratio untuk aturan asosiasi $\{T\} \rightarrow \{M\}$ dihitung sebagai berikut.

$$\text{Confidence}(\{T\} \rightarrow \{M\}) = 0,52;$$

$$\text{Support}(\{M\}) = 0,23;$$

$$\text{Lift}(\{T\} \rightarrow \{M\}) = \frac{\text{Confidence}(\{T\} \rightarrow \{M\})}{\text{Support}(\{M\})} = \frac{0,52}{0,23} = 2,26$$

Hasil perhitungan lift ratio seluruh aturan asosiasi diperlihatkan pada tabel berikut.

Tabel 12. Nilai Lift Ratio Aturan Asosiasi

Aturan Asosiasi	Lift Ratio	Korelasi
$\{LT\} \rightarrow \{T\}$	2,25	Sangat kuat
$\{T\} \rightarrow \{M\}$	2,26	Sangat kuat
$\{M\} \rightarrow \{T\}$	2,22	Sangat kuat
$\{K\} \rightarrow \{T\}$	1,27	Sangat kuat
$\{K\} \rightarrow \{G\}$	1,19	Sangat kuat
$\{T\} \rightarrow \{G\}$	1,19	Sangat kuat
$\{G\} \rightarrow \{T\}$	1,19	Sangat kuat

4.18. Penghitungan Conviction

Nilai conviction bertujuan untuk mengukur tingkat keyakinan implikasi antara dua itemset. Contoh penghitungan conviction untuk aturan asosiasi $\{T\} \rightarrow \{M\}$ berdasarkan rumus (4) adalah sebagai berikut.

$Confidence(\{T\} \rightarrow \{M\}) = 0,52$; $Support(\{M\}) = 0,23$;

$$Conv(\{T\} \rightarrow \{M\}) = \frac{1 - Support(\{M\})}{1 - Confidence(\{T\} \rightarrow \{M\})} = \frac{1 - 0,23}{1 - 0,52} = \frac{0,77}{0,48} = 1,60$$

Hasil perhitungan *conviction* seluruh aturan asosiasi diperlihatkan pada tabel berikut.

Tabel 13. Nilai *Conviction* Aturan Asosiasi

Aturan Asosiasi	Conviction	Korelasi
$\{LT\} \rightarrow \{T\}$	3,36	Sangat kuat
$\{T\} \rightarrow \{M\}$	1,60	Sangat kuat
$\{M\} \rightarrow \{T\}$	3,20	Sangat kuat
$\{K\} \rightarrow \{T\}$	1,18	Sangat kuat
$\{K\} \rightarrow \{G\}$	1,12	Sangat kuat
$\{T\} \rightarrow \{G\}$	1,12	Sangat kuat
$\{G\} \rightarrow \{T\}$	1,12	Sangat kuat

4.19. Implementasi Data pada Rapidminer

Item	Support	Item 1	Item 2	Item 3	Item 4
1	0.180	J			
2	0.350	T			
3	0.094	G			
4	0.275	K			
5	0.220	M			
6	0.192	L			
7	0.164	LT			
8	0.100	PG			
9	0.131	G			
10	0.110	TP			
11	0.110	DS			
12	0.110	CS			
13	0.110	DB			
14	0.110	HL			
15	0.080	C			

Gambar 3. Hasil *fp-growth* berdasarkan *minimum support*

No.	Item	Confidence	Support	Lift	Gain	P-R	LR	Conviction
37	J, G, T	0.140	0.420	0.800	-0.009	0.901	1.174	1.507
38	J, T	0.140	0.420	0.800	-0.003	0.923	1.162	1.160
39	L, T	0.084	0.409	0.900	-0.008	0.914	1.260	1.160
40	K, T	0.117	0.420	0.870	-0.004	0.919	1.161	1.160
41	T, G	0.104	0.420	0.800	-0.002	0.907	1.214	1.160
42	PG, T	0.084	0.420	0.920	-0.002	0.911	1.201	1.160
43	T, M, L, LT	0.080	0.420	0.800	-0.001	0.903	1.207	1.509
44	CS, G, K	0.040	0.420	0.940	-0.176	0.920	2.019	1.364
45	G, T	0.104	0.420	0.800	-0.004	0.907	1.214	1.160
46	J, M	0.084	0.420	0.900	-0.004	0.916	1.224	1.160
47	J, PG, LT	0.030	0.420	0.940	-0.176	0.923	2.007	1.510
48	T, G, M	0.080	0.440	0.940	-0.163	0.940	2.174	1.000
49	T, L, G	0.087	0.440	0.920	-0.003	0.914	1.324	1.160
50	HL, LT	0.040	0.440	0.940	-0.172	0.922	2.023	1.524
51	HL, J, M	0.040	0.440	0.940	-0.172	0.920	2.070	1.411

Gambar 4. Pengolahan *dataset* menggunakan operator *fp-growth* dan *association rules mining*

5. KESIMPULAN DAN SARAN

Analisis terhadap penerapan algoritma *FP-Growth* pada data transaksi persewaan Bayti Adventure periode 2024 menghasilkan beberapa temuan krusial. Implementasi metode ini terbukti efektif dalam memetakan pola frekuensi tinggi yang muncul dari riwayat penyewaan pelanggan. Proses penyaringan menggunakan standar *minimum confidence* 40% berhasil merumuskan tujuh aturan asosiasi yang signifikan, meliputi korelasi antarpaket $\{LT\} \rightarrow \{T\}$, $\{T\} \rightarrow \{M\}$, $\{M\} \rightarrow \{T\}$, $\{K\} \rightarrow \{T\}$, $\{K\} \rightarrow \{G\}$, $\{T\} \rightarrow \{G\}$, serta $\{G\} \rightarrow \{T\}$. Akurasi dari aturan-aturan tersebut semakin diperkuat dengan

integrasi metrik *Lift Ratio* dan *Conviction* dalam tahap pengujian, sehingga informasi yang dihasilkan menjadi lebih presisi dan valid.

Beberapa rekomendasi dapat dipertimbangkan untuk pengembangan studi di masa mendatang berdasarkan hasil penelitian yang telah dicapai. Peneliti selanjutnya dapat mengeksplorasi penggunaan algoritma alternatif seperti ECLAT, AIS, atau SETM dengan tetap mempertahankan parameter *Lift Ratio* dan *Conviction* sebagai pembanding efektivitas. Pemanfaatan temuan ini juga berpotensi besar jika diimplementasikan ke dalam sistem aplikasi penataan letak barang otomatis. Integrasi pola keterkaitan antar-item ke dalam manajemen operasional diharapkan mampu menciptakan rekomendasi penempatan inventaris yang lebih strategis guna meningkatkan efisiensi layanan. Penelitian ini menyajikan data yang diperoleh dari tahap pengolahan dataset menggunakan algoritma *FP-Growth*. Pembahasan difokuskan pada hasil aturan asosiasi dengan diperkuat menggunakan metrik pengitungan *lift ratio* dan *conviction*.

DAFTAR PUSTAKA

- [1] N. H. F. Hartanto and B. Aribowo, "Perancangan Tata Letak Toko Ritel Berdasarkan Pola Belanja Konsumen Dengan Market Basket Analysis (Studi Kasus: Indomaret Sukatani)," *Jurnal Al-Azhar Indonesia Seri Sains Dan Teknologi*, vol. 8, no. 2, p. 119, May 2023, doi: 10.36722/sst.v8i2.1375.
- [2] D. Kurniawan, M. Sahata Sipayung, R. Ismayanti, M. Rivani Ibrahim, Y. Bintan, and S. Aulia Miranda, "Optimalisasi Strategi Pemenuhan Persediaan Stok Barang Menggunakan Algoritma Frequent Pattern Growth," *Metik Jurnal*, vol. 6, no. 2, pp. 104–114, Dec. 2022, doi: 10.47002/metik.v6i2.387.
- [3] K. Truna Wijaya and I. Pratama, "Penerapan Algoritma FP-Growth Untuk Analisis Data Transaksi Penjualan Di Internet Learning Cafe Kaliurang," *Jurnal Nasional Komputasi dan Teknologi Informasi*, vol. 5, no. 4, pp. 642–651, 2022, doi: <https://doi.org/10.32672/jnkti.v5i4.4585>.
- [4] I. Musdalifah and A. Jananto, "Analisis Perbandingan Algoritma Apriori Dan FP-Growth Dalam Pembentukan Pola Asosiasi Keranjang Belanja Pelanggan," *Jurnal Ilmiah Komputer*, 2022, doi: 10.35889/progresif.v18i2.878.
- [5] R. Saputra, S. Wasiyanti, and R. Nugraha, "Penerapan Algoritma Apriori Untuk Analisa Pola Penempatan Barang Berdasarkan Data Transaksi Penjualan," *SWABUMI*, vol. 8, no. 2, pp. 160–170, 2020, doi: 10.31294/swabumi.v8i2.9031.
- [6] T. Martiwansyah, D. Alita, A. R. Isnain, and N. Nuroji, "Penerapan Algoritma Apriori untuk Menentukan Tata Letak Barang (Studi Kasus: Swalayan S&M Mart)," *Jurnal Informatika dan Rekayasa Perangkat Lunak*, vol. 4, no. 2, pp.

- 167–175, Jun. 2023, doi: 10.33365/jatika.v4i2.2594.
- [7] H. Catrio Wicaksono, D. Witarsyah, and F. Hamami, “Analisis Penempatan Produk Retail dengan Metode Asosiasi Menggunakan Algoritma FP-Growth,” *e-Proceeding of Engineering*, vol. 10, no. 3, pp. 3128–3137, 2023, Accessed: Apr. 07, 2026. [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/20568>
- [8] Andy Hermawan, Bayu Wicaksono, Tigfhar Ahmadjayadi, Bagas Surya Prakasa, and Jasico Dacomoro Aruan, “Implementasi Algoritma Apriori pada Market Basket Analysis terhadap Data Penjualan Produk Supermarket,” *Algoritma: Jurnal Matematika, Ilmu pengetahuan Alam, Kebumian dan Angkasa*, vol. 2, no. 5, pp. 95–105, Jun. 2024, doi: 10.62383/algoritma.v2i5.137.
- [9] Z. K. Putri, I. Iskandar, and A. Nazir, “Implementasi Algoritma FP-Growth untuk Menemukan Pola Keterkaitan Antara Matakuliah Pemrograman dan Matakuliah Matematika,” *Jurnal CoreIT: Jurnal Hasil Penelitian Ilmu Komputer dan Teknologi Informasi*, vol. 7, no. 2, p. 51, Dec. 2021, doi: 10.24014/coreit.v7i2.15351.
- [10] E. Munanda and S. Monalisa, “Penerapan Algoritma Fp-Growth Pada Data Transaksi Penjualan Untuk Penentuan Tataletak Barang,” *Jurnal Ilmiah Rekayasa dan Manajemen Sistem Informasi*, vol. 7, no. 2, pp. 173–184, 2021, doi: <http://dx.doi.org/10.24014/rmsi.v7i2.13253>.
- [11] B. S. Bakti, “Antologi pendekatan machine learning: Aturan asosiasi (Konsep, teori, dan algoritma FP-Growth) [Makalah tidak diterbitkan].,” Jember, 2025.
- [12] A. Shihab and Z. Fatah, “Implementasi Algoritma Fp-Growth Pada Dataset Sintetis Untuk Penentuan Pola Pembelian Sembako Dan Kebutuhan Harian,” *Jurnal TIMES*, vol. 13, no. 2, pp. 221–235, 2024, doi: <https://doi.org/10.51351/jtimes>.
- [13] L. Holpiani, F. Putrawansyah, S. Muntari, J. Masik Siagim No, and S. Mbacang Kec Dempo Tengah Kota Pagar Alam, “Implementasi Algoritma Fp-Growth Untuk Menganalisa Pola Penjualan Kue Pada Toko Dapur Bunda,” 2024. doi: <https://doi.org/10.36595/jire.v7i1.1136>