

# Penentuan Barang Terpopuler Menggunakan Algoritma *Frequent Patern Growth (FP-Growth)* Pada Data Transaksi Penjualan Odeliz.ID

Abidah Wafiyah Ramadhaniah Afandi<sup>1</sup>, Miftahur Rahman\*<sup>2</sup>, Wiwik Suharso<sup>3</sup>

<sup>1,2,3</sup>Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Jember

Email: <sup>1</sup>[awra.afandi@gmail.com](mailto:awra.afandi@gmail.com), <sup>2</sup>[miftahurrahman@unmuhjember.ac.id](mailto:miftahurrahman@unmuhjember.ac.id),

<sup>3</sup>[wiwiksuharso@unmuhjember.ac.id](mailto:wiwiksuharso@unmuhjember.ac.id)

*Corresponden Author:* [miftahurrahman@unmuhjember.ac.id](mailto:miftahurrahman@unmuhjember.ac.id)

Diterima Redaksi: 03 Juli 2024 Revisi Akhir: 03 Agustus 2024 Diterbitkan Online: 11 September 2024

**Abstrak** – Odeliz.ID menjadi salah satu *thriftshop* yang ikut bersaing dalam dunia bisnis fashion dan menjual berbagai jenis rok kedalam empat kategori yaitu, *premium*, *basic*, *semibasic*, dan *sale*. Untuk menemukan barang terpopuler yang dibeli konsumen, digunakan algoritma *frequent patern growth* untuk menganalisis barang terpopuler dari data transaksi penjualan Odeliz.Id. Nilai *support* dan *confidence* digunakan sebagai ukuran analisis data. Rok dengan kategori B atau *basic* memiliki nilai *support* tertinggi sebesar 0.52 atau 52%, yang berarti kategori ini menjadi rok yang paling populer dikalangan pembeli. Pembeli yang membeli rok dengan kategori P atau *premium* bersamaan dengan kategori B atau *basic* memiliki nilai *support* dan *confidence* tertinggi sebesar 10.8% dan 21.9%. Rok dengan kategori *premium* dan *basic* paling sering dibeli secara bersamaan karena memiliki nilai *support* dan *confidence* tertinggi sebesar 10.8% dan 21.9%, hal ini bisa menjadi saran untuk promosi produk dengan cara *bundling* harga yang mengandung dua kategori rok ini. Penerapan algoritma *FP-Growth* berhasil dalam mengidentifikasi pola-pola frekuensi tinggi dalam data transaksi penjualan Odeliz.ID. *Frequent itemset* yang didapat atau barang barang yang sering dibeli secara bersamaan adalah barang dengan kategori *premium* dan *basic*, *premium* dan *semibasic*, *basic* dan *semibasic*. Nilai *support* mengindikasikan seberapa sering suatu produk dibeli dan nilai *confidence* mengukur seberapa sering barang yang dibeli secara bersamaan dalam suatu transaksi.

**Kata Kunci** — *FP-Growth*, *Frequent Itemset*, Rok, Populer, *Thriftshop*

**Abstract** – Odeliz.ID has become one of the *thriftshops* competing in the fashion business world, selling various types of skirts categorized into four categories: *premium*, *basic*, *semibasic*, and *sale*. To identify the most purchased items by consumers, the *frequent pattern growth* algorithm is used to analyze popular items from Odeliz.ID sales transaction data. *Support* and *confidence* values are used as measures for data analysis. Skirts categorized as B or *basic* have the highest *support* value of 0.52 or 52%, indicating this category is the most popular among buyers. Buyers purchasing skirts categorized as P or *premium* along with B or *basic* have the highest *support* and *confidence* values of 10.8% and 21.9%, respectively. *Premium* and *basic* category skirts are most frequently purchased together, as indicated by their highest *support* and *confidence* values of 10.8% and 21.9%, suggesting a recommendation for product promotion through *bundled pricing* containing these two skirt categories. The implementation of the *FP-Growth* algorithm successfully identifies high-frequency patterns in Odeliz.ID sales transaction data. The *frequent itemsets* obtained, or items frequently purchased together, include items categorized as *premium* and *basic*, *premium* and *semibasic*, and *basic* and *semibasic*. *Support* values indicate how often a product is purchased, while *confidence* measures how often items are purchased together in a transaction.

**Keywords** — *FP-Growth*, *Frequent Itemset*, Skirt, Popular, *Thriftshop*



## 1. PENDAHULUAN

Pembelian pakaian bekas atau *thrift shopping* menjadi alternatif utama bagi orang yang ingin hemat namun tetap modis. *Thrift shopping* merupakan salah satu metode berbelanja yang memiliki tujuan agar pengeluaran untuk belanja menjadi minimal. Barang-barang yang dijual di *thrift shop* merupakan barang bekas pakai atau barang sortiran dari beberapa brand namun masih layak untuk digunakan [1]. Salah satu *thrift shop* yang ikut bersaing dalam dunia fashion adalah “Odeliz.ID”. Odeliz.ID merupakan *thrift shop* yang menjual berbagai jenis rok *thrift* namun masih layak pakai. Toko ini diawali dengan *thrift* baju anak, *blouse*, celana, dan sekarang ini menjual rok dengan berbagai macam model. Dalam penjualan item rok, dibagi menjadi 4 kategori berdasarkan kualitas dan harga rok, yaitu : premium (P) dengan *range* harga Rp55.000,- sampai Rp100.000,-, *basic* (B) dengan *range* harga Rp35.000,- sampai Rp50.000,-, *semibasic* (SB) dengan *range* harga Rp20.000,- sampai Rp30.000,-, dan *sale* (S) dengan *range* harga Rp10.000,- sampai Rp15.000,-. Pemilik bisnis *thriftshop* ini memiliki kendala dalam menentukan jenis produk yang paling diminati oleh para customer. Harus ditemukan analisis cermat dan efektif untuk memperoleh pola-pola pembelian dari data transaksi yang kompleks dan besar.

Terkait dengan hal tersebut, data mining memiliki peran penting dalam proses pengolahan sebuah data. Data mining umumnya berasal dari banyaknya jumlah data yang tersimpan dalam suatu *database*. Teknik pembelajaran mesin, pengenalan pola, *database*, *statistic*, dan visualisasi digunakan dalam data mining untuk memecahkan masalah menggali data dari repositori *database* yang sangat besar [2][3]. Oleh sebab itu jenis data mining yang sesuai untuk menggali suatu informasi dari pola belanja pada transaksi penjualan yang kerap timbul pada tiap permintaan dimana terdiri dari sebagian item ialah dengan memakai tata cara *association rules* dengan algoritma *fp-growth*. *Association rules* merupakan data mining yang menyediakan catatan transaksi pembelian yang keluar secara bersamaan dalam satu waktu. *Association rules* bertujuan untuk mengetahui pola belanja konsumen dan mengetahui seberapa sering kombinasi item muncul dalam data penjualan tersebut [4][5]. Algoritma *FP-Growth* merupakan salah satu algoritma yang dapat digunakan untuk menentukan himpunan data yang sering muncul (*frequent itemset*) dalam suatu dataset [6][7]. Algoritma ini dapat memperoleh pola-pola pembelian yang signifikan dengan efisien, membantu dalam mengidentifikasi barang-barang yang sering dibeli bersamaan [8]. Dengan demikian, penerapan algoritma *FP-Growth* pada data transaksi *thrift shop* dapat memberikan solusi analitis yang kuat dalam menghadapi kompleksitas data yang ada.


Penelitian yang dilakukan oleh Firmansyah pada 2023 dengan judul “Penerapan Data Mining Menggunakan Algoritma Frequent Pattern-Growth untuk Menentukan pola pembelian produk Chemicals”, menunjukkan bahwa teknik data mining yang dikombinasikan dengan algoritma *FP-Growth* dapat menghasilkan pola pembelian produk kimia yang signifikan, yang dapat meningkatkan efektivitas strategi pemasaran dan penjualan produk kimia. Pola pembelian ini mencakup informasi tentang kombinasi produk kimia yang paling sering dibeli oleh konsumen, urutan pembelian mereka, dan kecenderungan mereka [9].

Penelitian yang dilakukan oleh [10] pada tahun 2022 dengan judul “Pengaruh Kualitas Produk, Harga, Dan Promosi Terhadap Volume Penjualan Pakaian Thrifting Di Toko Thriftshop Sidoarjo”, didapatkan hasil bahwa variabel kualitas produk, harga dan promosi sangat berpengaruh dalam peningkatan volume penjualan.

Dalam penelitian ini juga dibutuhkan *tools* untuk tempat pengujian data. Penelitian yang dilakukan oleh [11] mengenai prediksi Tingkat ketersediaan stok sembako dengan algoritma *FP-Growth* untuk meningkatkan penjualan, data diimplementasikan dengan menggunakan aplikasi *rapidminer* 9.4 sebagai *tools* untuk pengujian data. *RapidMiner* merupakan salah satu tool yang digunakan dalam mengolah data mining [12]. Pola-pola yang dihasilkan dalam penelitian tersebut digunakan sebagai informasi untuk memprediksi ketersediaan stok sembako pada Toko UD. Smart Aliwansyah. Dengan mengimplementasikan algoritma *FP-Growth* dan menggunakan *Rapidminer* sebagai *tools* pengujian data pada data transaksi penjualan *thrift shop*, dapat diungkap pola-pola pembelian yang mungkin tidak terduga sebelumnya. Ini dapat memberikan informasi berharga mengenai jenis barang yang paling diminati oleh pelanggan.

## 2. METODE PENELITIAN

Tahapan-Tahapan yang dilakukan pada penelitian ini terdiri dari 7 (tujuh) tahapan yang ditunjukkan pada gambar berikut ini:



Gambar 1. Tahapan Penelitian

### 2.1 Identifikasi Masalah

Tahapan yang pertama ini menjelaskan permasalahan-permasalahan yang terjadi yang melatarbelakangi penelitian yang akan dilakukan.

### 2.2 Pengumpulan Data

Mengumpulkan data-data yang berkaitan dengan penelitian ini yaitu berdasarkan buku transaksi harian pada *thrift shop* Odeliz.ID sejak tanggal 1 hingga 10 Maret 2024.


### 2.3 Pengolahan Data

Tahap selanjutnya adalah pengolahan data transaksi penjualan meliputi: *selection*, *cleaning*, dan *transformation*.

### 2.4 Perhitungan Algoritma FP-Growth

#### 2.4.1 Algoritma Frequent Patern Growth

Algoritma *fp-growth* bertujuan untuk menemukan *frequent itemset* pada data yang ingin dianalisis [13]. Algoritma *fp-growth* juga memiliki waktu proses yang lebih cepat, membutuhkan memori yang sedikit [14]. Langkah-langkah algoritma *fp-growth* ada 3 dapat dilihat pada gambar 2:



Gambar 2. Langkah-langkah FP-Growth

#### a. Pembangunan Conditional Patern Base

Langkah ini melibatkan pembentukan pola dari dataset transaksi yang sudah difilter berdasarkan item yang termasuk dalam *frequent itemset* sebelumnya. Dasar pola yang dibentuk adalah himpunan transaksi yang mengandung item-item yang sering muncul bersama dengan item yang sedang dieksplorasi .

#### b. Pembangunan Conditional FP-Tree

Setelah memiliki dasar pola, langkah berikutnya adalah membangun *conditional fp-tree*. *FP-tree* ini dibangun berdasarkan dasar pola yang dihasilkan dari langkah sebelumnya. Dalam pembangunan *fp-tree*, diurutkan berdasarkan alur transaksi yang telah memenuhi minimum *support*.

#### c. Pencarian Frequent Itemset

*Frequent itemset* yang ditemukan merupakan kombinasi item-item yang sering muncul bersama dalam dataset transaksi, dengan mempertimbangkan *threshold support* yang telah ditentukan sebelumnya .

#### 2.4.2 Assosiation Rule Mining

*Association rule* adalah metode atau teknik data mining untuk mencari suatu hubungan atau menemukan aturan asosiatif antara suatu kombinasi item. Salah satu tahap analisis asosiasi untuk menghasilkan algoritma yang efisien adalah dengan mengetahui variable nilai *support* dan *confidence* yang dapat diketahui dengan mengukur variable sebagai berikut [15] :

$$Support A = \frac{Jumlah\ transaksi\ yang\ mengandung\ item\ A}{total\ transaksi} \quad (1)$$

Setelah itu, nilai *support* dari dua item yang dibeli bersamaan didapatkan dengan menjumlah transaksi yang mengandung item A dan B dan dibagi dengan total transaksi seperti pada rumus berikut :

$$Support (A, B) = P(A \cap B) = \frac{Jumlah\ transaksi\ yang\ mengandung\ item\ A\ dan\ B}{total\ transaksi} \quad (2)$$

Keterangan :  $P(A \cap B)$  = *Support* gabungan transaksi yang mengandung *item* A dan B

Setelah memperoleh semua item yang sering muncul () dan himpunan item besar (*large item set*), dapat mencari nilai kepercayaan minimum (*mincof*) dengan menjumlahkan transaksi yang mengandung *item* A dan B dan dibagi dengan total transaksi yang mengandung *item* A, dapat dilihat pada rumus berikut:

$$Confidence (A \rightarrow B) = P(A|B) = \frac{Jumlah\ transaksi\ yang\ mengandung\ item\ A\ dan\ B}{umlah\ transaksi\ yang\ mengandung\ item\ A} \quad (3)$$

Keterangan :  $P(A|B)$  = Transaksi yang mengandung item A dan B

### 3. HASIL DAN PEMBAHASAN

Data transaksi penjualan odeliz.id yang akan digunakan pada penelitian ini adalah data pada tanggal 01 sampai 10 Maret 2024 sebagai berikut :

Tabel 1. Data penjualan Odeliz.id 1-10 Maret 2024

No	Username	Shopee	Tiktokshop	TF	K	Kategori Rok			
						P	B	SB	S
1	Mess	50,000					1		1
2	Keranjang	30,000						1	
3	Aku		85,000			1			1
4	Wellania	85,000				1		1	
5	Aku	55,000						1	2
6	Novi		30.000				1		
7	Ines		70.000			1			
.....	.....	.....	.....	.....	.....	.....	.....	.....	.....
735	Karin	30,000						1	
736	Ida	40,000					1		
737	Miwa		75,000			1			
738	Rain		145,000				4		

Pada tabel 1, dapat dilihat transaksi nomor 1, pembeli dengan *username* Mess membeli barang dengan kategori B sebanyak 1pcs dan S sebanyak 1pcs melalui *shopee* dan begitu juga seterusnya hingga transaksi nomor 738. Data tersebut selanjutnya diolah kedalam tahap-tahap *selection*, *cleaning*, dan *transformation* yang nantinya akan digunakan sebagai dataset penelitian. Maka diperoleh dataset penelitian sebagai berikut :

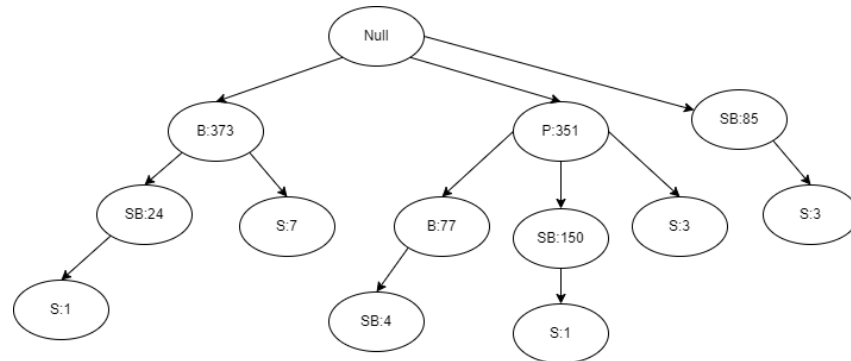
Tabel 2. Dataset penelitian

No	Username	Kategori Rok			
		P	B	SB	S
1	A1	0	1	1	0
2	A2	0	1	0	0
3	A3	1	0	0	1
4	A4	1	0	1	0
5	A5	0	0	1	1
6	A6	0	1	0	0
7	A7	1	0	0	0
8	A8	0	1	0	0
.....	.....	.....	.....	.....	.....
709	A709	0	0	1	0
710	A710	0	1	0	0
711	A711	1	0	0	0
712	A712	0	1	0	0

Pada dataset penelitian, data diseleksi dan di transformasi sesuai dengan kebutuhan penelitian. Pada transaksi nomor 1, *username* pembeli diganti menjadi A1 dan tabel *shopee*, *tiktokshop*, *tf*, dan *k* dihapus, begitu juga dengan transaksi seterusnya hingga transaksi nomor 712.

#### 3.1 Pembentukan FP-Tree

Pembangunan *FP-tree* didasarkan pada dataset penelitian yang berjumlah 712 data. Untuk hasil akhir dari pembangunan *FP-tree* dapat dilihat pada gambar 3.

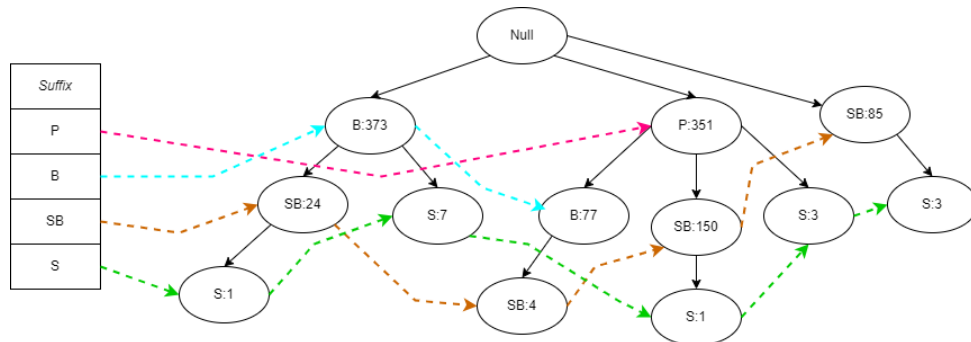


Gambar 3. Hasil pembentukan fp-tree

3.2 Implementasi Algoritma FP-Growth

3.2.1 Pembangunan Conditional Patern Base


Pembangunan *conditional patern base* berdasarkan hasil akhir dari FP-tree dapat dilihat pada gambar 4, dimana garis berwarna merah muda menandakan alur *suffix* P, garis berwarna biru menandakan alur *suffix* B, garis berwarna orange menandakan alur *suffix* SB, dan garis berwarna hijau menandakan alur *suffix* S.



Gambar 4. Pembangunan conditional patern base

3.2.2 Pembangunan Conditional FP-Tree

Untuk pembangunan *conditional FP-tree* dilakukan penghapusan *suffix* S karena tidak memenuhi nilai *support* dan *confidence*. Hasil dari *conditional FP-tree* dapat dilihat pada gambar 5.



Gambar 5. Pembangunan conditional fp-tree

3.2.3 Pencarian Frequent Itemset

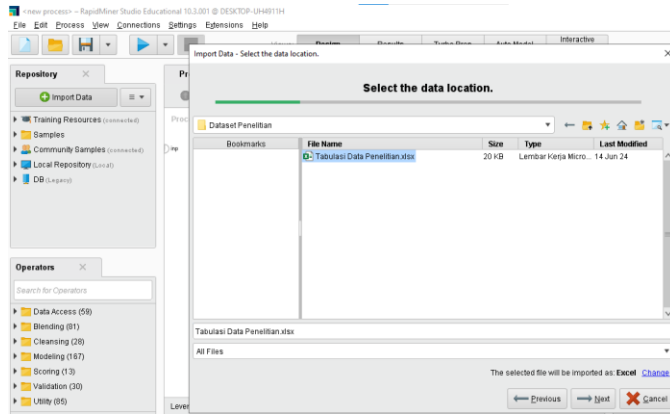
*Frequent itemset* yang didapat setelah disaring dengan minimal *support* 10% dan minimal *confidence* 0.1% dapat dilihat pada tabel 3.

Tabel 3. Frequent itemset

No	Suffix	Frequent Itemset
1	P	{P,B} {P,SB}
2	B	{B,SB}

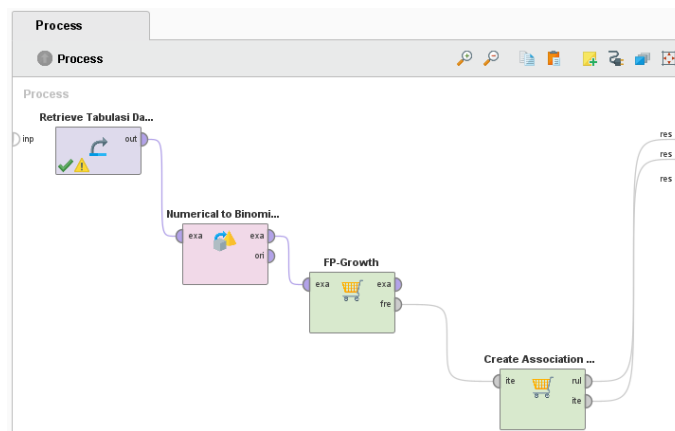
3.3 Pengujian Rapidminer

Untuk melakukan pengujian dalam *rapidminer*, langkah pertama adalah memasukkan data yang telah diubah menjadi tabel *boolean*, dapat dilihat pada gambar 6.



Gambar 6. Import data dalam Rapidminer

Desain proses yang akan dilakukan dengan memsuaikan dataset penelitian, mengubah angka menjadi binominal, memasukan algoritma fp-growth, dan langkah terakhir membuat *association rule mining*.



Gambar 7. Desain proses

Jalankan desain proses yang telah dibuat, untuk hasil implementasi algoritma fp-growth dan nilai *support* dapat dilihat pada gambar 8. Hasil dari *association rule mining*, nilai *support* dan *confidence* dapat dilihat pada gambar 9.

FrequentItemSets (FP-Growth)		AssociationRules (Create Association Rules)		
No. of Sets: 7	Size	Support	Item 1	Item 2
Total Max. Size: 2	1	0.524	B	
Min. Size: 1	1	0.493	P	
Max. Size: 2	1	0.117	SB	
Contains Item:	1	0.049	S	
<input type="text"/>	2	0.108	B	P
<input type="text"/>	2	0.034	B	SB
<input type="text"/>	2	0.021	P	SB

Gambar 8. Hasil FP-Growth

FrequentItemSets (FP-Growth)		AssociationRules (Create Association Rules)		
Association Rules				
Association Rules				
[P] --> [SB] (confidence: 0.043)				
[B] --> [SB] (confidence: 0.064)				
[SB] --> [P] (confidence: 0.181)				
[B] --> [P] (confidence: 0.206)				
[P] --> [B] (confidence: 0.219)				
[SB] --> [B] (confidence: 0.289)				

Gambar 9. Hasil *association rule mining*

### 3.4 Assosiation Rule Mining

Dengan menggunakan batas nilai minimal *support* 10% dan minimal *confidence* 0.1% didapatkan 3 *rule* yang kuat termasuk dalam *assosiation rule mining*, dan dapat dilihat pada tabel 4 dan 5.

Tabel 4. Hasil nilai *support*

No	Kategori Rok	Frekuensi	Support	Support %
1	P	351	$\frac{351}{712} = 0.49$	49%
2	B	373	$\frac{373}{712} = 0.52$	52%
3	SB	83	$\frac{83}{712} = 0.11$	11%
4	S	35	$\frac{35}{712} = 0.04$	4%

Tabel 5. Hasil *support* dan *confidence*

No	Frequent Itemset	Support	Support %	Confidence	Confidence %
1	P -> B	$\frac{77}{712} = 0.108$	10,8%	$\frac{77}{351} = 0.219$	21,9%
2	P -> SB	$\frac{150}{712} = 0.021$	1,4%	$\frac{150}{351} = 0.043$	4,3%
3	B -> SB	$\frac{24}{712} = 0.034$	2,2%	$\frac{24}{373} = 0.064$	6,4%

Dari hasil *assosiation rule mining* pada tabel 4 dan 5, dapat dilihat bahwa rok dengan kategori B atau *basic* memiliki nilai *support* tertinggi sebesar 0.52 atau 52%, yang berarti kategori ini menjadi rok yang paling populer dikalangan pembeli. Pembeli yang membeli rok dengan kategori P atau *premium* bersamaan dengan kategori B atau *basic* memiliki nilai *support* dan *confidence* tertinggi sebesar 10.8% dan 21.9%. Rok dengan kategori *premium* dan *basic* paling sering dibeli secara bersamaan karena memiliki nilai *support* dan *confidence* tertinggi sebesar 10.8% dan 21.9%, hal ini bisa menjadi saran untuk promosi produk dengan cara *membundling* harga yang mengandung dua kategori rok ini.

## 4. SIMPULAN

Berdasarkan hasil pembahasan mengenai implementasi algoritma *fp-growth* pada data transaksi penjualan Odeliz.ID tanggal 01 sampai 10 Maret 2024, beberapa kesimpulan dapat diambil. Pertama, algoritma *fp-growth* berhasil mengidentifikasi pola-pola frekuensi tinggi dalam data transaksi penjualan Odeliz.id. Kedua, *frequent itemset* yang sering dibeli bersama adalah barang dengan *support* kategori *premium* dan *basic*, *premium* dan *semibasic*, serta *basic* dan *semibasic*. Ketiga, nilai *support* menunjukkan seberapa sering suatu produk dibeli, di mana rok kategori *basic* memiliki tertinggi sebesar 52%, menjadi barang paling populer di antara pembeli dengan harga berkisar Rp25.000,- sampai Rp35.000,-. Sementara itu, untuk nilai *confidence* tertinggi adalah pada kombinasi rok *premium* dan *basic*, dengan *support* dan *confidence* mencapai 10.8% dan 21.9%.

## 5. SARAN

Disarankan penelitian selanjutnya untuk mengevaluasi efisiensi dan akurasi algoritma *Fp-Growth* dalam mengidentifikasi barang terpopuler pada data transaksi penjualan dan Membuat prediksi tren penjualan berdasarkan pola-pola yang ditemukan dengan mempertimbangkan faktor-faktor eksternal seperti *event*, promo penjualan atau peristiwa khusus lainnya yang dapat mempengaruhi penjualan.

## DAFTAR PUSTAKA

- [1] S. Y. Park, H., Kwon, T. A., Zaman, M. M., & Song, "Thrift shopping for clothes: To treat self or others?," *J. Glob. Fash. Mark.*, vol. 11(1), pp. 56–70, 2020.

- [2] S. P. Dewi, N. Nurwati, and E. Rahayu, "Penerapan Data Mining Untuk Prediksi Penjualan Produk Terlaris Menggunakan Metode K-Nearest Neighbor," *Build. Informatics, Technol. Sci.*, vol. 3, no. 4, pp. 639–648, 2022, doi: 10.47065/bits.v3i4.1408.
- [3] Daryanto, R. Wahyuningsih, and M. Rahman, "Penerapan Model Algoritma C4.5 dengan Tool WEKA untuk Memprediksi Kelulusan Mahasiswa," *J. Sist. dan Teknol. Inf.*, vol. 7, no. 2, pp. 87–93, 2022, doi: 10.32528/justindo.v7i2.8334.
- [4] L. Oktaviani, Tri Anelia, Hegarmanah Muhabatin, Yudhistira Arie Wijaya, and Dian Ade Kurnia, "Penerapan Algoritma Fp-Growth Untuk Menganalisis Pola Belanja," *KOPERTIP J. Ilm. Manaj. Inform. dan Komput.*, vol. 5, no. 1, pp. 29–35, 2021, doi: 10.32485/kopertip.v5i1.153.
- [5] A. Saputra, H. L. Sari, and D. Sartika, "Implementasi Metode Association Rule Mining Pada Penjualan Barang Di Toko Bangunan Ada Mas Menggunakan Algoritma Apriori," *J. Multidisiplin Dehasen*, vol. 2, no. 4, pp. 709–718, 2023, doi: 10.37676/mude.v2i4.4805.
- [6] I. Astrina, M. Z. Arifin, and U. Pujiyanto, "Penerapan Algoritma FP-Growth dalam Penentuan Pola Pembelian Konsumen pada Kain Tenun Medali Mas," *Matrix J. Manaj. Teknol. dan Inform.*, vol. 9, no. 1, p. 32, 2019, doi: 10.31940/matrix.v9i1.1036.
- [7] Ramadhanti and Fatmasari, "Penerapan Algoritma FP-Growth Untuk Menentukan Pola Pengambilan Treatment," *J. Jupiter*, vol. 14, no. 2, pp. 582–588, 2022.
- [8] 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.
- [9] F. Firmansyah and O. Nurdiawan, "Penerapan Data Mining Menggunakan Algoritma Frequent Pattern - Growth Untuk Menentukan Pola Pembelian Produk Chemicals," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 1, pp. 547–551, 2023, doi: 10.36040/jati.v7i1.6371.
- [10] I. Farah Fu, M. Aswad, J. Ekonomi Syariah, F. Ekonomi dan Bisnis Islam, and U. Sayyid Ali Rahmatullah Tulungagung, "Pengaruh Kualitas Produk, Harga, Dan Promosi Terhadap Volume Penjualan Pakaian Thrifting Di Toko Thriftshop Sidoarjo," *J. Cendekia Ilm.*, vol. 1, no. 3, pp. 169–177, 2022.
- [11] R. Aditiya, S. Defit, and G. W. Nurcahyo, "Prediksi Tingkat Ketersediaan Stock Sembako Menggunakan Algoritma FP-Growth dalam Meningkatkan Penjualan," *J. Inform. Ekon. Bisnis*, vol. 2, pp. 67–73, 2020, doi: 10.37034/infob.v2i3.44.
- [12] R. Maulid, "RapidMiner: Tools Data Science Andalan Data Experts," *DQLab*, 2023. <https://dqlab.id/rapidminer--tools-data-science-andalan-data-experts> (accessed Sep. 04, 2024).
- [13] E. Nofianti, W. A. Triyanto, and N. Latifah, "Penentuan Strategi Pemasaran Menggunakan Frequent Pattern Growth (Fp-Growth) Pada Toko Komputer," *Indones. J. Technol. Informatics Sci.*, vol. 1, no. 2, pp. 59–62, 2020, doi: 10.24176/ijtis.v1i2.4941.
- [14] R. Wahyusari, "Penerapan Algoritma FP-Growth Untuk Menemukan Pola Peminjaman Alat Pada Workshop Teknik Mesin," *Log. J. Ilmu Komput. dan Pendidik.*, vol. 1, no. 3, pp. 406–411, 2023.
- [15] B. S. Pranata and D. P. Utomo, "Penerapan Data Mining Algoritma FP-Growth Untuk Persediaan Sparepart Pada Bengkel Motor (Study Kasus Bengkel Sinar Service)," *Bull. Inf. Technol.*, vol. 1, no. 2, pp. 83–91, 2020.