

PENINGKATAN MODEL ASOSIASI TOKO IKHSAN MENGGUNAKAN ALGORITMA *FP-GROWTH*

M. Salman Hanafi^{1*}, Odi Nurdiawan², Fadhil Muhammad Basysyar³

^{1,2}STIMIK IKMI Cirebon; Jl. Perjuangan No. 10B, Majasem, Cirebon, Indonesia; telp/Fax institusi/afiliasi

²STIMIK IKMI Cirebon; Jl. Perjuangan No. 10B, Majasem, Cirebon, Indonesia; telp/Fax institusi/afiliasi

Received: 18 Desember 2024
Accepted: 14 Januari 2025
Published: 20 Januari 2025

Keywords:

FP-Growth, Data Mining, Purchase Patterns, Marketing Strategies, Retail Store.

Correspondent Email:

salmanhanafi11351@gmail.com

Abstrak. Penelitian ini menganalisis pola pembelian pelanggan di Toko Ikhsan menggunakan algoritma *FP-Growth*, yang efisien dalam mengidentifikasi Frequent Itemset tanpa memerlukan kandidat itemset. Data transaksi dari Juni hingga September 2024 diolah melalui pembersihan, penghapusan duplikasi, dan konversi format. Dengan *Minimum Support* 0,02 dan *Confidence* 0,06, ditemukan 33 aturan asosiasi signifikan, seperti hubungan CHARM dan KECAP (*Confidence* 70,73%) serta BIORE dan LIFEBOUY (*Confidence* 89,92%). Temuan ini membantu toko mengembangkan strategi berbasis data, seperti bundling produk dan penempatan strategis, untuk meningkatkan pengalaman pelanggan dan efisiensi stok. Penelitian ini menunjukkan manfaat data mining untuk usaha kecil, memberikan panduan praktis bagi pengusaha ritel tradisional, dan menjadi acuan studi lanjutan untuk berbagai konteks bisnis.

Abstract. This study analyzes customer purchasing patterns at Ikhsan Store using the *FP-Growth* algorithm, which is efficient in identifying Frequent Itemsets without requiring candidate itemsets. Transaction data from June to September 2024 was processed through cleaning, deduplication, and format conversion. With a *Minimum Support* of 0.02 and *Confidence* of 0.06, 33 significant association rules were found, such as the relationship between CHARM and KECAP (*Confidence* 70.73%) and BIORE and LIFEBOUY (*Confidence* 89.92%). These findings help stores develop data-driven strategies, such as product bundling and strategic placement, to improve customer experience and stock efficiency. This study demonstrates the benefits of data mining for small businesses, provides practical guidance for traditional retail entrepreneurs, and serves as a reference for further studies for various business contexts.

1. PENDAHULUAN

Di era digital, teknologi informasi telah menjadi elemen penting dalam mendukung efisiensi operasional di berbagai sektor, termasuk sektor ritel. *Data mining* muncul sebagai solusi unggul untuk mengekstraksi informasi berharga dari kumpulan data besar yang kompleks [1]. Salah satu algoritma yang banyak digunakan adalah *FP-Growth*, yang dikenal efisien dalam

mengidentifikasi pola asosiasi antar produk tanpa memerlukan proses pembuatan kandidat itemset [2]. Penelitian terdahulu menunjukkan keberhasilan algoritma ini dalam berbagai konteks, seperti analisis pola pembelian di toko online [3], optimalisasi tata letak rak untuk meningkatkan kenyamanan pelanggan [4], dan pengembangan strategi *bundling* produk [5].

Penambangan data melibatkan penyaringan data dalam jumlah besar untuk

mencari pola yang bermakna. Prosedur ini dapat dilakukan secara otomatis atau semi-otomatis, tergantung pada kompleksitas data [6]. Dalam konteks transaksi ritel, aturan asosiasi adalah alat yang berguna untuk mengidentifikasi tren, seperti pola pembelian produk yang sering muncul bersama [7]. Algoritma *FP-Growth* menjadi pendekatan populer dalam menemukan *frequent itemset* karena kecepatannya dibandingkan algoritma *Apriori* [8]. Meskipun algoritma ini telah banyak diterapkan, penelitian yang secara khusus menyoroti sektor ritel kecil, seperti toko sembako, masih terbatas [9].

Sebagian besar penelitian sebelumnya menitikberatkan pada penerapan algoritma *FP-Growth* di sektor ritel besar atau *e-commerce*, seperti toko daring dan toko grosir berskala besar. Hal ini menciptakan kesenjangan dalam literatur, mengingat kebutuhan dan karakteristik toko ritel kecil seperti Toko Ikhsan berbeda dengan bisnis berskala besar. Minimnya penelitian yang relevan dengan konteks ritel kecil menghambat pengembangan strategi berbasis data yang dapat langsung diterapkan oleh usaha kecil. Penelitian ini hadir untuk mengisi kesenjangan tersebut dengan menganalisis data transaksi Toko Ikhsan menggunakan algoritma *FP-Growth*. Fokus penelitian ini pada sektor ritel kecil dan sembako memberikan kebaruan sekaligus kontribusi praktis bagi pengelolaan toko serupa.

Penelitian ini bertujuan untuk menganalisis pola pembelian pelanggan di Toko Ikhsan menggunakan algoritma *FP-Growth*. Dengan menggunakan data transaksi periode Juni hingga September 2024, penelitian ini berupaya mengidentifikasi nilai *support* dan *confidence* untuk menentukan hubungan antar produk yang sering dibeli bersama. Hasil penelitian ini diharapkan dapat memberikan wawasan strategis bagi Toko Ikhsan dalam mengembangkan strategi pemasaran berbasis data, seperti penawaran bundling produk dan pengelolaan stok yang lebih efisien. Secara lebih luas, penelitian ini bertujuan memperkaya literatur tentang penerapan data mining dalam mendukung keberlanjutan usaha kecil di sektor ritel.

2. TINJAUAN PUSTAKA

FP-Growth merupakan metode *data mining* yang sangat efisien dalam menemukan *frequent itemset* tanpa memerlukan pembangkitan kandidat, seperti pada algoritma *Apriori* [10]. Algoritma ini menggunakan struktur data *FP-Tree* untuk merepresentasikan transaksi secara ringkas, sehingga mempercepat proses identifikasi pola [11].

Penelitian terdahulu, seperti yang dilakukan oleh [12]. Menunjukkan bahwa *FP-Growth* dapat digunakan untuk meningkatkan efektivitas penempatan produk di *e-commerce*. [13]. Mengidentifikasi bahwa algoritma ini unggul dalam menemukan pola asosiasi terbaik untuk analisis penjualan daring. Teori-teori ini menjadi dasar untuk penerapan algoritma *FP-Growth* dalam konteks Toko Ikhsan, yang bertujuan mengidentifikasi hubungan antar produk untuk mendukung strategi pemasaran dan pengelolaan stok yang lebih efisien. Penelitian sebelumnya menunjukkan bahwa algoritma *FP-Growth* mampu mengidentifikasi pola pembelian dengan efisien, seperti yang diterapkan pada analisis pola penjualan obat di Apotek Dr. Rika untuk meningkatkan pengelolaan stok dan kepuasan pelanggan [14].

3. METODE PENELITIAN

Pendekatan penelitian yang diterapkan di studi ini adalah metode kuantitatif, dimana metode kuantitatif adalah pendekatan penelitian yang berfokus pada pengukuran objektif dan analisis numerik data yang dikumpulkan melalui survei, kuesioner, atau pemrosesan data sekunder, data primer, bertujuan untuk menemukan pola dan tren yang dapat digeneralisasi pada populasi tertentu. Saya menggunakan algoritma *FP-Growth* dalam penelitian saya yang berjudul "Algoritma *FP-Growth* untuk meningkatkan model asosiasi pada Toko Ikhsan." Tujuan algoritma ini adalah untuk menemukan pola pembelian yang sering muncul dalam data transaksi. Selanjutnya, hasil ini digunakan untuk membuat strategi pemasaran yang lebih terfokus yang berfokus pada kecenderungan pembelian bersama, data yang digunakan dalam penelitian ini bersumber dari data transaksi penjualan di Toko Ikhsan pada periode Juni hingga September 2024. Penelitian ini merupakan penelitian terapan


yang memanfaatkan kerangka *knowledge discovery in databases* (KDD) untuk mengeksplorasi dan menganalisis pola produk dari data yang tersedia. Dengan kerangka ini, penelitian bertujuan untuk mengungkap pola pembelian yang signifikan, yang nantinya dapat menjadi dasar dalam mengambil keputusan untuk menyusun strategi pemasaran yang lebih efektif.

3.1. Tahapan Review (Review Steps)

Tahapan review dilakukan secara komprehensif untuk memastikan kualitas penelitian. Dimulai dengan penelusuran literatur mendalam terhadap algoritma *FP-Growth*, data mining, dan penerapannya di sektor ritel, khususnya merujuk pada penelitian terbaru seperti [1], [2], dan [3]. Selanjutnya, dataset transaksi Toko Ikhsan dengan 38.809 catatan diperiksa secara cermat untuk memastikan validitas dan kelengkapan data. Algoritma *FP-Growth* dipilih dan parameter *minimum support* 0,02 serta *confidence* 0,06 ditetapkan berdasarkan studi literatur dan karakteristik data. Terakhir, perangkat lunak Ai Studio diuji coba untuk memastikan kinerjanya dalam memproses data yang besar. Melalui tahapan-tahapan ini, penelitian dipastikan dilakukan secara sistematis, menggunakan data yang valid, dan metode yang relevan untuk mencapai tujuan penelitian.

3.1.1. Gambar dan tabel. (Figures and tables)

Pada penelitian ini, analisis data dilakukan dengan menggunakan teknik data mining, yaitu algoritma *FP-Growth*. Algoritma ini dipilih karena efektif dalam mengidentifikasi pola asosiasi pada data transaksi yang berukuran besar. Proses analisis data mengikuti tahapan-tahapan *Knowledge Discovery in Databases* (KDD) seperti yang ditunjukkan pada Gambar 1.



Gambar 1 KDD [15]

a) Selection

Memilih data transaksi penjualan skincare dari Toko Ikhsan dari Juni sampai Septemeber 2024.

b) Preprocessing

Melakukan pembersihan data, seperti menghapus duplikasi dan memperbaiki kesalahan dalam data.

c) Transformation

Menggunakan *FP-Growth* untuk mengubah data transaksi menjadi format yang sesuai untuk proses mining.

d) Data Mining

Algoritma *FP-Growth* digunakan untuk mengidentifikasi pola asosiasi di antara produk yang dijual.

e) Interpretation/Evaluation

Mengevaluasi pola yang ditemukan dan menilai relevansinya dalam konteks pemasaran.

3.1.2. Rumus Matematika.(Math formul a.)

Dalam analisis asosiasi, beberapa metrik penting digunakan untuk mengukur kekuatan hubungan antara item-item dalam suatu transaksi. Metrik-metrik ini meliputi *support*, *confidence*, dan *lift ratio*. Ketiga metrik ini memiliki peran yang krusial dalam mengidentifikasi aturan asosiasi yang kuat dan bermakna.

1. *Support Calculation*: *Support* adalah metrik yang mengukur seberapa sering sebuah item atau kombinasi item muncul dalam seluruh transaksi. Rumus untuk menghitung *support* adalah sebagai berikut:

Support untuk satu item:

$$\text{Support}(a) = \frac{\text{Jumlah transaksi yang mengandung } a}{\text{Total transaksi}}$$

Support untuk dua item:

$$\text{Support}(a \rightarrow b) = \frac{\text{Jumlah transaksi yang mengandung } a \text{ dan } b}{\text{Total transaksi}}$$

Jika nilai *Confidence* mencapai 80%, ini menunjukkan bahwa 80% dari transaksi yang mengandung AAA juga mengandung BBB.

2. *Confidence Calculation*: *Confidence* menunjukkan tingkat hubungan antara dua item berdasarkan kondisi tertentu. *Confidence* untuk asosiasi $A \rightarrow BA$ \rightarrow BA \rightarrow B dihitung sebagai:

$$\text{Confidence (a} \rightarrow b) = \frac{\text{Jumlah transaksi yang mengandung a dan b}}{\text{Jumlah transaksi yang mengandung a}}$$

Jika nilai *Confidence* mencapai 80%, hal ini mengindikasikan bahwa 80% dari transaksi yang mengandung AAA juga mengandung BBB.

3. *Lift Ratio Calculation*: *Lift ratio* digunakan untuk menilai efektivitas asosiasi. Nilai lift dihitung sebagai:

$$\text{Lift Ratio} = \frac{\text{Confidence (a} \rightarrow b)}{\text{Support (b)}}$$

Jika nilai *Lift Ratio* lebih dari 1, maka aturan asosiasi tersebut terpenuhi. Semakin tinggi nilai *Lift Ratio*, semakin kuat asosiasi antar produk tersebut.

4. HASIL DAN PEMBAHASAN

4.1 Data Selection

Agar kumpulan data berada di repositori Ai Studio perlu untuk mengimport data. Dataset penjualan_Penjualan_Ikhsan.xlsx ketika sudah di upload di *repository*, langsung masukan data nya ke oprator *Retrive* seperti pada gambar 2.



Gambar 2 Oprator *Retrive*


Hasil dari oprator *Retrive* ditunjukkan pada tabel 1.

Tabel 1 Hasil Oprator *Retrive*

Tanggal	Jam	ID	Nama pembeli	Nama barang	Jenis	Quantity	Jumlah
---------	-----	----	--------------	-------------	-------	----------	--------

01/06/2024	10:18	#2	Pa k Santi	PO CI CE LUP	VA NIL A	25' S	20
01/06/2024	10:18	#2	Pa k Santi	LU X	OR AN GE	70 GR A M	8
01/06/2024	10:23	#2	Pa k Kartika	DO VE	INT EN SE	9 ML	5
01/06/2024	10:29	#2	BP Santi	DJ AR UM	SU PE R FIL TE R	12	19
01/06/2024	10:29	#2	BP Santi	SE DA AP	KA RI AY AM	80 GR A M	16
....							
30/09/2024	20:56	#3	BP Yaya	LU X	KU NIN G	70 GR A M	18

Dilanjutkan dengan menggunakan Operat or *Pivot*. Tujuannya untuk menentukan Atribut apa saja yang akan dipakai dalam penelitian. Berikut adalah Gambar 3 dari operator *Pivot*:



Gambar 3 Oprator *Pivot*

Gambar 3 menunjukkan visualisasi operator *Pivot* di lingkungan AI Studio yang berfungsi untuk mengubah dan menyusun ulang data. Operator ini memiliki beberapa input dan output yang merepresentasikan aliran data yang sedang diproses. Berikut isi Parameters

pada oprator *Pivot* yang digunakan disajikan di tabel 2.

Tabel 2 Parameter Oprator *Pivot*

No	Parameters	isi
1	<i>Group by attribute</i>	ID
2	<i>Column grouping attribute</i>	Nama Barang
3	<i>Aggregation attribute</i>	Nama Barang
4	<i>Aggregation function</i>	Count


Tabel 2 memberikan rincian konfigurasi parameter *Pivot* yang divisualisasikan pada Gambar 3. Tabel ini secara khusus menjelaskan nilai-nilai yang ditetapkan untuk parameter-parameter penting dalam parameter tersebut, seperti atribut *Group by* yang diisi dengan "ID", atribut *Column grouping* yang diisi dengan "Nama Barang", atribut *Aggregation* yang juga diisi dengan "Nama Barang", dan fungsi *Aggregation* yang ditetapkan ke "Count". Berikut hasil yang diperoleh dari oprator *Pivot* disajikan di tabel 3.

Tabel 3 Hasil Data Oprator *Pivot*

N o	ID	Count (Nama Barang)_A BC	Coun t(Na ma Bara ng)_ ACI	Count (Nama Barang)_A DA	...	Count (Nama Barang)_Z NC
1	#2 05 58	?	?	?	...	?
2	#2 05 80	?	?	?	...	?
3	#2 05	?	?	?	...	?

	97					
4	#2 05 90	?	?	?	...	?
...					...	
15 45 4	#3 59 07	?	?	?	...	?

Tabel hasil transformasi menggunakan operator *Pivot* mengelompokkan data berdasarkan ID dan menghitung jumlah item berdasarkan kategori. Nilai "?" menunjukkan tidak adanya data untuk kategori tertentu pada ID tersebut. Setelah pivot, kolom ID diubah menjadi tipe data Role untuk mencegah data mining menggunakan nilai nol. Dan selanjutnya akan digunakan oprator *Set Role* yang akan ditampilkan di gambar 4.

Gambar 4 Oprator *Set Role*

Gambar 4 menunjukkan operator *Set Role* yang digunakan dalam proses pemodelan data menggunakan Ai Studio. Operator ini berfungsi untuk mengatur atribut tertentu dalam data dengan peran tertentu yang dibutuhkan dalam analisis. Parameters pada oprator *Set Role* yang digunakan tampak pada tabel 4.

Tabel 4 Isi Parameter *Set Role*

No	Parameters	Isi
1	<i>Attribute name</i>	ID
2	<i>Target role</i>	ID

Pada tabel 4. Dalam tabel tersebut, dijelaskan bahwa Attribute name diatur

menjadi "ID", dan Target role juga diatur menjadi "ID". Hal ini menunjukkan bahwa atribut "ID" pada dataset difungsikan sebagai identifikasi utama dalam proses analisis. Berikut hasil yang diperoleh operator Set Role ditunjukkan pada tabel 5.


Tabel 5 Hasil Oprator *Set Role*

N o	ID	Count (Nama Barang)_ABC	Count (Nama Barang)_ACI	Count (Nama Barang)_AIDA	...	Count (Nama Barang)_ZINC
1	#2 05 58	?	?	?	...	?
2	#2 05 80	?	?	?	...	?
3	#2 05 97	?	?	?	...	?
4	#2 05 90	?	?	?	...	?
...					...	
15 45 4	#3 59 07	?	?	?	...	?

Tabel 5 menunjukkan output dari operator *Set Role* yang telah diterapkan pada kumpulan data. Hasil ini menunjukkan bahwa atribut ID telah diidentifikasi sebagai peran utama dalam pengelompokan data transaksi.

4.2 Data Preprocessing

Langkah *preprocessing* adalah proses pembersihan data, seperti menangani nilai kosong atau inkonsisten. Sebelum memulai langkah ini dilakukan evaluasi untuk memastikan bahwa atribut-atribut yang dipilih dalam dataset bebas dalam nilai kosong atau data yang tidak konsisten. Berdasarkan data analisis statistik yang ditampilkan pada gambar dibawah, diketahui bahwa semua atribut tidak mengandung nilai yang hilang. Untuk memastikan dataset benar-benar konsisten, dilakukan pengecekan langsung terhadap setiap catatan, dan hasilnya menunjukkan bahwa dataset memiliki tingkat konsistensi yang tinggi. Dikarenakan hasil dari operator *Set Role* pada tabel 5 terdapat nilai *Missing* pada nama barang, maka dari itu diperlukan operator *Replace Missing Value* untuk menangani nilai *Missing* tersebut.

Gambar 5 Oprator *Replace Missing Value*

Gambar 5 menunjukkan operator *Replace Missing Value* di AI Studio, digunakan untuk menangani data yang memiliki nilai kosong (*missing value*) dengan menggantinya sesuai dengan parameter yang telah ditentukan. Berikut isi Parameters pada operator *Replace Missing Value* disajikan pada tabel 6.

Tabel 6 Isi Parameter Oprator *Replace Missing Value*

N o	Parameter s	Isi
1	<i>Attribute filter type</i>	<i>subset</i>
2	<i>attributes</i>	<i>Select Attribute :</i>
		Count(Nama Barang)_ABC
		Count(Nama

		Barang)_ACI
		Count(Nama Barang)_AIDA
		Count(Nama Barang)_AJINOMOT O
		
		Count(Nama Barang)_ZINC
3	Default	Zero

Tabel 6 memberikan rincian mengenai parameter-parameter yang dapat disesuaikan pada operator tersebut, termasuk jenis filter atribut yang diatur menjadi "subset", pemilihan atribut-atribut tertentu seperti *Count(Nama Barang)_ABC*, serta pengaturan default untuk menggantikan nilai kosong dengan "Zero". Pengaturan ini memungkinkan pengguna untuk menyesuaikan metode pengisian nilai kosong sesuai dengan kebutuhan analisis data. Berikut hasil data yang diperoleh dari oprator *Replace Missing Value* disajikan di tabel 7.

Tabel 7 Hasil Data Oprartor *Replace Missing Value*

N o	I D	Cou nt(N ama Bara ng)_ AB C	Cou nt(N ama Bara ng)_ ACI	Coun t(Na ma Bara ng)_ AID A	..	Cou nt(N ama Bara ng)_ ZIN C
1	#2 05 58	0	0	0	..	0
2	#2 05	0	0	0	..	0


	80					
3	#2 05 97	0	0	0	..	0
4	#2 05 90	0	0	0	..	0
...	...				..	
1	#3 5 4 5 4	1	0	0	..	0

Hasil data dari operator *Replace Missing Value* menunjukkan bahwa nilai-nilai yang hilang pada atribut-atribut seperti *Count(Nama Item)_ABC* telah berhasil diganti sesuai dengan pengaturan yang telah ditetapkan. Sebagian besar nilai pada atribut-atribut tersebut terisi dengan angka nol (0), yang mencerminkan pengaturan default yang digunakan dalam mengganti nilai-nilai yang kosong. Namun, ada beberapa baris data, seperti pada baris ke-6 dengan ID #20505 dan baris ke-15454 dengan ID #35907, di mana nilai atribut tertentu terisi dengan angka satu (1), yang menunjukkan adanya variasi atau penggantian data tertentu. Proses ini membantu dalam memastikan integritas data sehingga dapat digunakan untuk analisis selanjutnya tanpa adanya gangguan dari nilai-nilai yang kosong.

4.3 Data Transformation

Untuk mengganti nama atribut yang panjang contohnya: *count(NAMA BARANG)_ABC*. Dapat menggunakan oprator *Rename* seperti gambar 6.

Gambar 6 Oprator *Rename*



Gambar 6 menunjukkan operator *Rename* di AI Studio, yang digunakan untuk mengganti nama atribut dalam kumpulan data agar lebih sederhana, lebih terstruktur, atau lebih sesuai dengan kebutuhan analisis. Berikut isi Parameters pada oprator *Rename* disajikan pada tabel 8.

Tabel 8 Isi Parameter *Rename*

N o	Param eter	Isi	
1	<i>Renam e Atrtrib utes</i>	<i>Edit List</i>	
		<i>Old Name</i>	<i>New Name</i>
		Count(NAMA BARANG)_ABC	ABC
		Count(NAMA BARANG)_ACI	ACI
		Count(NAMA BARANG)_AID A	AIDA
		Count(NAMA BARANG)_AJI NOMOTO	AJINOM OTO
			
		Count(NAMA BARANG)_ZIN C	ZINC


Tabel 8 menjelaskan detail parameter dalam operator ini, khususnya daftar atribut yang telah diubah namanya. Di kolom "Old Name", nama atribut asli Count(NAMA BARANG)_ABC, yang kemudian diubah menjadi nama baru seperti ABC di kolom "New Name". Proses ini bertujuan untuk meningkatkan keterbacaan data dan memudahkan analisis lebih lanjut. Berikut hasil dari penggunaan oprator *Rename* disajikan di tabel 9.

Tabel 9 Hasil Data Oprator *Rename*

No	ID	AB C	A CI	AID A	...	ZIN C
1	#205 58	0	0	0	0	0
2	#205 80	0	0	0	0	0
3	#205 97	0	0	0	0	0
4	#205 90	0	0	0	0	0
....					...	
154 54	#359 07	1	0	0	0	0

Hasil data dari operator *Rename* menunjukkan bahwa nama atribut dalam dataset telah berhasil diubah sesuai dengan pengaturan pada operator. Sebelumnya, atribut seperti Count(NAMA BARANG)_ABC telah diubah menjadi nama yang lebih ringkas, yaitu ABC.

Karena algoritma *FP-Growth* menggunakan tipe data biner, dataset memerlukan proses transformasi, untuk mengubah nilai data yang tadinya numerik menjadi binominal. Hal ini dapat dicapai dengan menggunakan oprator *Numerical to Binominal*, seperti yang ditunjukkan pada gambar 7.

Gambar 7 Oprator *Numerical To Binominal*

Gambar 7 menunjukkan operator *Numerical to Binominal* di AI Studio, yang digunakan untuk mengubah atribut numerik menjadi atribut biner (bernilai dua). Operator ini memiliki input dan output berlabel “exa” dan “ori,” yang kemungkinan mewakili data yang diekstrak dan data asli. Berikut isi Parameters pada oprator *Numerical to Binominal* disajikan pada tabel 10.

Tabel 10 Isi Parameter *Numerical To Binomunal*

No	Parameter	Isi
1	<i>Attribut filter type</i>	<i>All</i>
2	<i>Invert Selection</i>	
3	<i>Include Special Attributes</i>	
4	<i>Min</i>	0
5	<i>Max</i>	0

Tabel 10 menyajikan rincian parameter yang digunakan dalam operator *Numerical to binominal*. *Attribut filter type* diatur ke “All”, yang berarti bahwa operator akan memproses semua atribut numerik dalam kumpulan data. Parameter *Invert Selection* dan *Include Special Attributes* dibiarkan kosong, yang menunjukkan bahwa fitur *inverse selection* dan penggunaan atribut khusus tidak diaktifkan. Parameter *Min* dan *Max*, yang menentukan batas bawah dan atas untuk konversi ke biner, keduanya ditetapkan ke 0. Berikut hasil penggunaan oprator *Numerical to Binominal* ditampilkan di tabel 11.

Tabel 11 Hasil Data Oprator *Numerical To Binominal*

No	ID	AB C	AC I	AID A	...	ZIN C
1	#205	fals	fal	fals	fal	fals

	58	e	se	e	se	e
2	#205	fals	fal	fals	fal	fals
	80	e	se	e	se	e
3	#205	fals	fal	fals	fal	fals
	97	e	se	e	se	e
4	#205	fals	fal	fals	fal	fals
	90	e	se	e	se	e
...	...	...	...	...	...	...
154	#359	fals	fal	fals	fal	fals
54	07	e	se	e	se	e

Pada Tabel 11 terlihat hasil data setelah dilakukan penerapan operator *Numerical to Binominal*, dimana sebagian besar nilai pada kolom ABC, ACI, AIDA, dan ZINC bernilai *false*, hal ini terjadi karena operator tersebut mengubah nilai 0 menjadi *false*, dan mengubah nilai yang lebih dari 0 menjadi *true*.

4.4 Data Mining

Pada tahap data mining, analisis dilakukan dengan memanfaatkan oprator *FP-Growth* seperti yang ditampilkan pada gambar 8. Oprator ini berfungsi untuk mengidentifikasi secara efektif semua kombinasi item yang sering muncul didalam *ExampleSet*. Algoritma *FP-Growth* dikenal sebagai metode yang sangat efisien untuk menemukan pola pembelian produk yang sering terjadi secara bersamaan dalam database transaksi. Melalui pendekatan ini, pola pembelian dapat diidentifikasi dengan lebih optimal, sehingga mendukung pengambilan keputusan strategis dalam pemasaran.

Gambar 8 Oprator *FP-Growth*

Operator *FP-Growth* adalah alat yang digunakan dalam data mining untuk menemukan pola-pola menarik dalam data

yang besar. Misalnya, jika kita punya data transaksi, operator ini bisa membantu kita menemukan kombinasi barang yang sering dibeli bersama-sama, sehingga kita bisa mengatur tata letak toko yang lebih efektif. Berikut isi parameter pada oprator *FP-Growth* ditampilkan pada tabel 12.

Tabel 12 Isi Parameter Oprator *FP-Growth*

No	Parameter	Isi
1	<i>Input Format</i>	<i>Items in dummy-coded columns</i>
2	<i>Positive Value</i>	
3	<i>Min Requirement</i>	<i>Support</i>
4	<i>Min Frequency</i>	0.01; 0.02; 0.03; 0.04;
5	<i>Min items per itemset</i>	1
6	<i>Max items per itemset</i>	0

Pada isi parameter nilai *support*. Saya menguji empat nilai *support* yang berbeda (0.01, 0.02, 0.03, dan 0.04) untuk melihat bagaimana perubahan nilai *support* ini mempengaruhi hasil akhir, khususnya dalam hal jumlah aturan asosiasi yang ditemukan dan tingkat kepercayaan aturan tersebut. Dengan mengubah nilai *support*, kita dapat mengontrol seberapa sering suatu pola harus muncul dalam data agar dianggap sebagai pola yang menarik.

Untuk menghasilkan aturan asosiasi, harus menggunakan oprator *Create Association Rules* seperti yang ditampilkan pada gambar 9, oprator ini berfungsi untuk mengekstrasi aturan asosiasi berdasarkan item yang sering muncul, sehingga memberikan wawasan yang dapat digunakan untuk mendukung strategi pemasaran.

Gambar 9 Oprator *Create Association Rules*

Gambar ini menunjukkan proses menemukan pola-pola menarik dalam data, seperti “jika seseorang membeli sabun, maka kemungkinan besar dia juga akan membeli shampo”. Proses ini disebut pembuatan aturan asosiasi. Aturan-aturan ini sangat berguna untuk memahami perilaku konsumen dan membuat rekomendasi produk yang lebih baik. Berikut isi Parameters pada *Create Association Rules* bisa dilihat di tabel 13.

Tabel 13 Isi Parameter Oprator *Create Association Rules*

No	Parameter	Isi
1	<i>Criterion</i>	<i>Confidence</i>
2	<i>Min Confidence</i>	0.07; 0.06; 0.05; 0.04;
3	<i>Gain Tetha</i>	2.0
4	<i>Laplace K</i>	1.0

Dalam eksperimen ini, saya menggunakan algoritma *create association rules* untuk menemukan pola-pola hubungan antar item dalam data. Saya menguji empat nilai *minimum confidence* yang berbeda (0.07, 0.06, 0.05, dan 0.04) untuk melihat bagaimana perubahan nilai *confidence* ini mempengaruhi hasil akhir, khususnya dalam hal jumlah aturan asosiasi yang ditemukan dan tingkat keyakinan aturan tersebut. Dengan mengubah nilai *confidence*, kita dapat mengontrol seberapa kuat hubungan antara dua item harus agar dianggap sebagai aturan asosiasi yang valid. Seperti yang di tunjukan pada tabel 14.

No	Parameter	Isi
1	<i>Minimum Support</i>	0.01; 0.02; 0.03; 0.04;

2	Minimum <i>Confidence</i>	0.07;0.06; 0.05; 0.04;
---	------------------------------	---------------------------

Analisis dilakukan menggunakan oprator FP-Growth dan Create Association Rules di Ai Studio selama tahap data mining. Untuk memastikan hasil analisis yang akurat dan sesuai, parameter seperti nilai minimum dukungan dan kepercayaan digunakan. Tabel 14 menunjukkan nilai-nilai parameter yang digunakan.

4.5 Evaluation

Pengujian dimulai dengan menggunakan oprator FP-Growth untuk membuat set data transaksi frekuensi satu dan dua dengan nilai minimum dukungan 0.01, 0.02, 0.03, dan 0.04. Hasil pengujian operator ditunjukkan dalam tabel 15.

Tabel 15 Hasil Uji Nilai *Support*

Minimum support value	1-itemset	2-itemset
0.01	100	23
0.02	106	28
0.03	98	23
0.04	75	9

Selanjutnya, dilakukan pengujian dengan mengombinasikan nilai *Min Support* dan *Min Confidence*. Hasil uji tersebut bisa dilihat pada tabel 16.

Tabel 16 Hasil Uji Nilai *Support* Dan *Confidence*

Min. Support Value	Min. Confidence Value	ΣAssociation Rule
0.01	0.04	43
0.01	0.05	34
0.01	0.06	28
0.01	0.07	26

0.02	0.04	51
0.02	0.05	39
0.02	0.06	33
0.02	0.07	31
0.03	0.04	43
0.03	0.05	34
0.03	0.06	28
0.03	0.07	26
0.04	0.04	13
0.04	0.05	13
0.04	0.06	13
0.04	0.07	12

Pola asosiasi dalam penelitian ini dibentuk menggunakan kombinasi nilai *Minimum Support* dan *Confidence*. Hal ini dipilih karena merupakan metrik yang umum digunakan dalam analisis asosiasi pada data mining. Keduanya sudah cukup untuk memberikan gambaran tentang hubungan antar item dan dataset. Dengan menggunakan nilai *Support* sebesar 0.02 dan *Confidence* sebesar 0.06, yang menghasilkan 33 aturan asosiasi. Aturan-aturan ini menggunakan kombinasi produk yang sering di beli bersamaan dalam dataset, sehingga dapat dimanfaatkan dalam membuat efektifnya strategi pemasaran. Rincian hasil aturan bisa dilihat pada tabel 17.

N O	Pr em ise s	Co ncl usi on	S u p p or t	Co nfi de nc e	L a Pl ac e	G A I N	P - S	L if t	Co nfi cti on
3	L U X	C H A R	0. 0 0 6	0.0 77	0. 9 2 9	- 0 .1	- 0 .0	0 .7 7	0. 97 5

		M				6	0	1	
						0	2		
4	S	C	0.	0.0	0.	-	-	0	0.
	K	H	0	78	9	0	0	.	97
	M	A	0		3	.	.	7	6
		R	6		7	1	0	8	
		M				4	0	1	
						1	2		
...	...	...	...	...	...	...	...	...	...
3	G	BI	0.	0.1	0.	-	-	0	0.
3	U	O	0	27	9	0	0	.	98
	D	RE	0		5	.	.	9	8
	A		7		6	0	0	2	
	N					9	0	5	
	G					9	1		
	G								
	A								
	R								
	A								
	M								

Tabel 4.18 menampilkan analisis hubungan antara merek-merek tertentu (*Premises*) dengan merek lainnya (*Conclusion*) berdasarkan berbagai metrik, seperti *Support*, *Confidence*, *LaPlace*, *Gain*, *P-S*, *Lift*, dan *Confiction*. Data menunjukkan bahwa hubungan antara merek seperti LUX, CHARM, dan LIFEBOUY memiliki tingkat dukungan (*Support*) yang rendah, tetapi *Confidence* yang cukup tinggi, menunjukkan kecenderungan kuat meskipun jarang terjadi. Misalnya, hubungan antara LUX dan CHARM memiliki *Confidence* sebesar 0.929 dengan *Lift* 0.975, sementara hubungan antara GUDANG GARAM dan BIORE memiliki *Confidence* yang lebih tinggi sebesar 0.956 dengan *Lift* 0.988, menunjukkan peningkatan probabilitas keterkaitan di antara merek-merek tersebut. Analisis ini memberikan wawasan penting

untuk mengidentifikasi pola hubungan antar merek dalam konteks pasar.

4.6 Pembahasan

Penelitian ini menganalisis 38.809 transaksi penjualan Toko Ikhsan dari Juni hingga September 2024, yang setelah transformasi data menjadi 15.454 baris dengan 100 atribut reguler dan 1 atribut khusus. Proses melibatkan berbagai tahap, seperti *pivot* data, penanganan nilai hilang, pengubahan tipe data, dan penggunaan algoritma *FP-Growth* untuk menemukan pola asosiasi antar produk. Dengan parameter *Support* 0,02 dan *Confidence* 0,06, dihasilkan 33 aturan asosiasi, seperti Charm → Kecap (*Confidence* 91,57%) dan Lifebuoy → Kecap (*Confidence* 89,95%). Temuan ini dapat mendukung strategi pemasaran seperti promosi bundling atau pengaturan produk strategis. Hasil ini konsisten dengan penelitian sebelumnya yang menunjukkan efisiensi algoritma *FP-Growth* dalam menambang pola itemset pada dataset besar untuk mendukung pengambilan keputusan berbasis data. Selama proses asosiasi, parameter yang digunakan adalah nilai *Support* dan *Confidence*, dengan kombinasi *Support* = 0,2 dan *Confidence* = 0,6. interpretasi dari hasil aturan asosiasi pada tabel diatas akan dijelaskan dibawah ini:

Rule 1: Transaksi antara CHARM dan KECAP tercatat sebanyak 0.71% dari seluruh transaksi. Pelanggan yang membeli CHARM memiliki peluang 70.73% untuk membeli KECAP, dengan peningkatan peluang sebesar 84.28%.

Rule 2: Produk LIFEBOUY dan KECAP muncul bersama dalam 0.87% transaksi. Pelanggan yang membeli LIFEBOUY memiliki peluang 71.47% lebih cenderung membeli KECAP, dengan tingkat keberhasilan mencapai 85.15%.

Rule 3: Kombinasi LUX dan CHARM terjadi pada 0.64% dari keseluruhan transaksi. Pembelian LUX meningkatkan kemungkinan pembelian CHARM hingga 76.92%, dengan penguatan hubungan sebesar 77.14%.

Rule 4: SKM dan CHARM ditemukan dalam 0.57% transaksi. Peluang pelanggan

- membeli CHARM setelah membeli SKM adalah 77.88%, dengan kenaikan keberhasilan sebesar 78.10%.
- Rule 5: Produk LIFEBUOY dan CHARM sering muncul bersama di 0.98% transaksi, di mana pembelian LIFEBUOY meningkatkan kemungkinan pembelian CHARM sebesar 81.07%, dengan peningkatan peluang sebesar 81.29%.
- Rule 6: Kombinasi MOLTO dan CHARM muncul pada 0.59% transaksi. Pembelian MOLTO meningkatkan peluang pembelian CHARM hingga 81.69%, dengan tingkat hubungan sebesar 81.92%.
- Rule 7: KECAP dan CHARM sering dibeli bersama pada 0.71% transaksi. Peluang pembelian CHARM setelah membeli KECAP meningkat sebesar 84.04%, dengan penguatan hubungan sebesar 84.28%.
- Rule 8: ABC dan CHARM hadir dalam 0.65% transaksi. Pelanggan yang membeli ABC memiliki peluang 84.73% sangat memungkinkan untuk membeli CHARM, dengan tingkat keberhasilan sebesar 84.97%.
- Rule 9: Transaksi antara LUX dan LIFEBUOY terjadi sebanyak 0.74% dari total transaksi. Pembelian LUX meningkatkan peluang pembelian LIFEBUOY hingga 88.58%, dengan penguatan hubungan sebesar 73.01%.
- Rule 10: BIORE dan CHARM hadir dalam 1.23% transaksi. Pembelian BIORE meningkatkan peluang pembelian CHARM hingga 89.92%, dengan penguatan hubungan sebesar 90.18%.
- Rule 11: ABC dan LIFEBUOY terjadi bersama dalam 0.70% transaksi. Pelanggan yang membeli ABC berpeluang 90.60% lebih tinggi untuk membeli LIFEBUOY, dengan tingkat keberhasilan mencapai 74.67%.
- Rule 12: INDOMIE dan LIFEBUOY muncul di 0.71% transaksi. Pembelian INDOMIE meningkatkan peluang pembelian LIFEBUOY hingga 91.37%, dengan penguatan hubungan sebesar 75.31%.
- Rule 13: Kombinasi MOLTO dan LIFEBUOY terjadi dalam 0.67% transaksi. Pelanggan yang membeli MOLTO berpeluang 93.36% lebih tinggi untuk membeli LIFEBUOY, dengan tingkat keberhasilan sebesar 76.94%.
- Rule 14: DANCOW dan LIFEBUOY ditemukan di 0.69% transaksi. Peluang pembelian LIFEBUOY setelah DANCOW meningkat sebesar 94.73%, dengan penguatan hubungan sebesar 78.08%.
- Rule 15: INDOFOOD dan BIORE terjadi pada 0.58% transaksi. Pelanggan yang membeli INDOFOOD memiliki peluang 96.36% lebih tinggi untuk membeli BIORE, dengan tingkat keberhasilan sebesar 70.11%.
- Rule 16: BIORE dan LIFEBUOY terjadi di 1.34% transaksi. Pembelian BIORE meningkatkan peluang pembelian LIFEBUOY hingga 97.45%, dengan penguatan hubungan sebesar 80.32%.
- Rule 17: CHARM dan LIFEBUOY ditemukan dalam 0.98% transaksi. Pelanggan yang membeli CHARM memiliki peluang 98.63% lebih tinggi untuk membeli LIFEBUOY, dengan tingkat keberhasilan sebesar 81.29%.
- Rule 18: SKM dan LIFEBUOY sering dibeli bersama pada 0.72% transaksi. Pembelian SKM meningkatkan peluang pembelian LIFEBUOY hingga 99.12%, dengan penguatan hubungan sebesar 81.69%.
- Rule 19: KECAP dan LIFEBUOY hadir dalam 0.87% transaksi. Pelanggan yang membeli KECAP berpeluang 103.31% lebih tinggi untuk membeli LIFEBUOY, dengan tingkat keberhasilan sebesar 85.15%.
- Rule 20: MOLTO dan BIORE ditemukan bersama pada 0.76% transaksi. Pelanggan yang membeli MOLTO memiliki peluang 105.92% lebih tinggi untuk membeli BIORE, dengan tingkat keberhasilan sebesar 77.07%.
- Rule 21: SEDAAP dan LIFEBUOY terjadi sebanyak 0.57% dari total transaksi. Pembelian SEDAAP meningkatkan peluang pembelian LIFEBUOY hingga 109.59%, dengan penguatan hubungan sebesar 90.32%.
- Rule 22: KECAP dan BIORE ditemukan dalam 0.93% transaksi. Pelanggan

yang membeli KECAP memiliki peluang 110.25% lebih tinggi untuk membeli BIORE, dengan tingkat keberhasilan sebesar 80.22%.

Rule 23: INDOFOOD dan LIFEBOUY sering dibeli bersama dalam 0.67% transaksi. Pelanggan yang membeli INDOFOOD berpeluang 110.27% lebih tinggi untuk membeli LIFEBOUY, dengan penguatan hubungan sebesar 90.89%.

Rule 24: LIFEBOUY dan BIORE terjadi dalam 1.34% transaksi. Pembelian LIFEBOUY meningkatkan peluang pembelian BIORE hingga 110.40%, dengan tingkat keberhasilan sebesar 80.32%

Rule 25: LUX dan BIORE ditemukan dalam 0.93% transaksi. Pelanggan yang membeli LUX memiliki peluang 111.11% lebih tinggi untuk membeli BIORE, dengan penguatan hubungan sebesar 80.84%.

Rule 26: ABC dan BIORE ditemukan dalam 0.86% transaksi. Pelanggan yang membeli ABC berpeluang 111.57% lebih tinggi untuk membeli BIORE, dengan tingkat keberhasilan sebesar 81.18%.

Rule 27: SKM dan BIORE terjadi sebanyak 0.82% transaksi. Pelanggan yang membeli SKM memiliki peluang 112.39% lebih tinggi untuk membeli BIORE, dengan penguatan hubungan sebesar 81.77%.

Rule 28: INDOMIE dan BIORE ditemukan pada 0.90% transaksi. Pelanggan yang membeli INDOMIE berpeluang 116.51% lebih tinggi untuk membeli BIORE, dengan tingkat keberhasilan sebesar 84.77%.

Rule 29: DANCOW dan BIORE muncul di 0.85% transaksi. Pelanggan yang membeli DANCOW memiliki peluang 117.06% lebih tinggi untuk membeli BIORE, dengan penguatan hubungan sebesar 85.18%.

Rule 30: PANTENE dan BIORE hadir dalam 0.59% transaksi. Pelanggan yang membeli PANTENE memiliki peluang 122.81% lebih tinggi untuk membeli BIORE, dengan tingkat keberhasilan sebesar 89.35%.

Rule 31: CHARM dan BIORE terjadi dalam 1.23% transaksi. Pelanggan yang membeli CHARM memiliki peluang 123.94% lebih tinggi untuk membeli BIORE, dengan penguatan hubungan sebesar 90.18%.

Rule 32: KISPRAY dan BIORE ditemukan dalam 0.65% transaksi. Pelanggan yang membeli KISPRAY berpeluang 125% lebih tinggi untuk membeli BIORE, dengan tingkat keberhasilan sebesar 90.95%.

Rule 33: GUDANG GARAM dan BIORE terjadi dalam 0.67% transaksi. Pelanggan yang membeli GUDANG GARAM memiliki peluang 127.13% lebih tinggi untuk membeli BIORE, dengan penguatan hubungan sebesar 92.50%.

5. KESIMPULAN

Penelitian ini berhasil mengidentifikasi 33 aturan asosiasi signifikan menggunakan algoritma *FP-Growth* pada data transaksi Toko Ikhsan, dengan pola seperti Charm → Kecap (*Confidence* 91,57%) dan Lifebuoy → Kecap (*Confidence* 89,95%), yang menunjukkan relevansi dalam mendukung strategi pemasaran berbasis data. Algoritma *FP-Growth* terbukti efisien dalam menganalisis dataset besar tanpa memerlukan proses kandidat itemset, memberikan wawasan strategis untuk promosi bundling produk dan penempatan produk yang lebih efektif, meskipun memerlukan praproses data yang cermat untuk memastikan kualitas data yang dianalisis.

Ke depan, hasil penelitian dapat dikembangkan dengan mengintegrasikan analisis asosiasi ke dalam sistem rekomendasi berbasis data real-time untuk mendukung penjualan langsung atau membandingkan kinerja *FP-Growth* dengan algoritma lain seperti *Apriori* dan *Eclat* untuk menemukan pola yang mungkin terlewatkan. Selain itu, pengembangan aplikasi visualisasi data dapat mempermudah interpretasi hasil analisis dan implementasi strategi pemasaran berbasis data.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak Toko Ikhsan yang telah memberikan akses data transaksi penjualan

sebagai dasar penelitian ini. Ucapan terima kasih juga ditujukan kepada STIMIK IKMI Cirebon atas dukungan fasilitas dan bimbingan selama proses penelitian. Tak lupa, apresiasi setinggi-tingginya disampaikan kepada rekan-rekan peneliti serta pihak-pihak lain yang telah berkontribusi dalam memberikan masukan berharga sehingga penelitian ini dapat diselesaikan dengan baik.

DAFTAR PUSTAKA

- [1] A. Abdullah, "Rekomendasi Paket Produk Guna Meningkatkan Penjualan Dengan Metode FP-Growth," *Khazanah Inform. J. Ilmu Komput. dan Inform.*, vol. 4, no. 1, pp. 21–26, 2018, doi: 10.23917/khif.v4i1.5794.
- [2] 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, doi: 10.36040/jati.v7i1.6210.
- [3] S. Dewi and N. Suarna, "Penerapan Data Mining Dalam Algoritma Fp Growth Untuk Menentukan Pola Pembelian Pelanggan Online Shop Cirebon Laku," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 1180–1186, 2024, doi: 10.36040/jati.v8i1.8944.
- [4] Y. Syach Putra, R. Kurniawan, and Y. Arie Wijaya, "Penerapan Data Mining Menggunakan Algoritma Fp-Growth Pada Data Penjualan Sembako," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 561–567, 2024, doi: 10.36040/jati.v8i1.8391.
- [5] 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.
- [6] 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/infeb.v2i3.44.
- [7] A. Ardianto and D. Fitriana, "Penerapan Algoritma FP-Growth Rekomendasi Trend Penjualan ATK Pada CV. Fajar Sukses Abadi," *J. Telekomun. dan Komput.*, vol. 9, no. 1, p. 49, 2019, doi: 10.22441/incomtech.v9i1.3263.
- [8] 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, [Online]. Available: <http://ejournal.uin-suska.ac.id/index.php/RMSI/article/view/13253>
- [9] 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.
- [10] D. A. Istiqomah, Yuli Astuti, and Siti Nurjanah, "Implementasi Algoritma Fp-Growth Dan Apriori Untuk Persediaan Produk," *J. Inform. Polinema*, vol. 8, no. 2, pp. 37–42, 2022, doi: 10.33795/jip.v8i2.845.
- [11] D. Indahsari, "Penerapan Metode Asosiasi Dengan Algoritma FP-Growth Pada Data Transaksi PT John Tampi Group," *Comput. Based Inf. Syst. J.*, vol. 9, no. 2, pp. 1–9, 2021, doi: 10.33884/cbis.v9i2.3835.
- [12] Inda Anggraini, "Penerapan Metode Asosiasi Data Mining Pada E-Commerce Toko Nadhira," *JTIK (Jurnal Tek. Inform. Kaputama)*, vol. 7, no. 2, pp. 304–311, 2023, doi: 10.59697/jtik.v7i2.105.
- [13] M. L. Rahimsyah and Y. Ramdhani, "Analisis Algoritma FP-Growth dan Apriori Untuk Menemukan Model Asosiasi Terbaik pada Dataset Online Retail," *J. Multidisiplin Saintek*, vol. 3, no. 1, pp. 1–23, 2024.
- [14] S. Muntari, "DATA MINING MENGGUNAKAN ALGORITMA FP-GROWTH UNTUK MENGANALISA," vol. 12, no. 3, 2024.
- [15] R. Amelia, D. Darmansyah, and A. M. Rismadin, "Perbandingan Algoritma Apriori dan Fp-Growth dalam Pengaplikasian Market Basket Analysis untuk Strategi Bisnis Retail," *Build. Informatics, Technol. Sci.*, vol. 6, no. 1, pp. 279–288, 2024, doi: 10.47065/bits.v6i1.5388.