

THE COMPARISON BETWEEN THE APRIORI ALGORITHM AND THE FP-GROWTH ALGORITHM IN DETERMINING FREQUENT PATTERN

PERBANDINGAN ANTARA ALGORITMA APRIORI DENGAN ALGORITMA FP-GROWTH DALAM MENENTUKAN FREQUENT PATTERN

Farid Syah Zikri¹, Muhammad Ikhsan²,

¹Program Studi Ilmu Komputer, Fakultas Sains Dan Teknologi

²Pusat Teknologi Informasi dan Pangkalan Data

^{1,2} Universitas Islam Negeri Sumatera Utara Medan, Indonesia

Email: faridsyahzikri43@gmail.com¹, mhdikhsan@uinsu.ac.id²

Abstract - This study aims to compare the efficiency and accuracy of the Apriori and FP-Growth algorithms in determining frequent patterns from sales transaction data. In addition to evaluating execution time and the quality of the generated association rules, the study also examines the algorithm's advantages on small to large-scale datasets. The data used were collected from G Coffee's sales transactions during the period from September 1 to November 30, 2024. After undergoing preprocessing stages, both algorithms were tested using three dataset variations to identify common association patterns, such as the relationship between "Mineral 660ml" and "Kopi Susu Aren," along with other product combinations with high confidence and significant lift values. The results show that FP-Growth had a faster execution time (0.3008) compared to Apriori (0.5833), without compromising the accuracy of the results. Although both algorithms generated identical association rules, FP-Growth was superior in computational efficiency due to its ability to avoid explicit candidate itemset generation. These findings offer strategic benefits for companies, particularly in enhancing product promotion through bundling, cross-selling, and product grouping based on consumer purchasing patterns. Results, a hybrid approach is recommended to combine the processing speed of FP growth with Apriori's flexible parameter adjustment, enabling more optimal analysis of purchasing patterns in large and complex datasets.

Keywords - Apriori algorithm, association rule mining, data mining, FP-Growth, frequent pattern.

Abstrak - Penelitian ini bertujuan membandingkan efisiensi dan akurasi dari algoritma Apriori dan FP-Growth, dalam menentukan *frequent pattern* dari data transaksi penjualan. Selain mengevaluasi waktu eksekusi dan kualitas aturan asosiasi yang dihasilkan, penelitian ini juga bertujuan mengkaji kelebihan algoritma pada dataset berskala kecil hingga besar. Data yang digunakan berasal dari transaksi penjualan G Coffee selama periode 1 September 2024 hingga 30 November 2024. Setelah melalui tahapan *preprocessing*, kedua algoritma diuji menggunakan tiga variasi dataset untuk mendapatkan pola-pola asosiasi umum, seperti hubungan antara "Mineral 660ml" dan "Kopi Susu Aren", serta berbagai kombinasi produk lainnya dengan *confidence* tinggi dan *lift* signifikan. Hasil penelitian menunjukkan bahwa FP-Growth memiliki waktu eksekusi lebih cepat (0,3008 detik) dibandingkan Apriori (0,5833 detik), tanpa mengorbankan akurasi hasil. Meskipun kedua algoritma menghasilkan aturan asosiasi yang identik, FP-Growth lebih unggul dalam efisiensi komputasi karena tidak memerlukan pembangkitan kandidat itemset secara eksplisit. Temuan ini memiliki manfaat bagi perusahaan, khususnya dalam meningkatkan efektivitas promosi produk melalui *bundling*, *cross-selling*, dan pengelompokan produk berdasarkan pola pembelian konsumen. Pendekatan *hybrid* antara kedua algoritma direkomendasikan untuk menggabungkan kecepatan proses FP-Growth dengan fleksibilitas penyesuaian parameter dari Apriori, sehingga memberikan analisis yang lebih optimal terhadap pola pembelian dalam skala besar dan kompleks.

Kata Kunci - algoritma *apriori*, *association rule mining*, *data mining*, *FP-Growth*, *frequent pattern*.

I. PENDAHULUAN

Dalam era digital yang semakin berkembang, analisis data transaksi pelanggan menjadi salah satu pilar utama dalam pengambilan keputusan berbasis data. Salah satu teknik analisis yang banyak digunakan dalam bidang *data mining* adalah *Association Rule Mining* (ARM), yakni metode untuk menemukan pola keterkaitan antar produk yang sering muncul secara bersamaan dalam data transaksi. ARM sangat penting diterapkan dalam sektor ritel dan kuliner, termasuk pada bisnis seperti G Coffee, yang tengah menghadapi tantangan dalam memahami perilaku pembelian konsumen sebagai dasar dalam menentukan strategi pemasaran, penyusunan paket produk (*bundling*), serta optimalisasi manajemen persediaan [1].

Dalam proses penentuan pola asosiasi, dua algoritma yang paling banyak digunakan adalah Apriori dan FP-Growth. Algoritma Apriori menggunakan pendekatan *generate and test* dengan membentuk kandidat itemset berdasarkan pola sebelumnya dan mengevaluasi frekuensinya dalam dataset. Namun, algoritma ini memiliki kelemahan utama dalam efisiensi, karena memerlukan pemindaian data berulang serta menghasilkan sejumlah besar kombinasi kandidat, yang dapat memperlambat proses analisis pada dataset berskala besar [2][3]. Sebagai solusi dari permasalahan tersebut, algoritma FP-Growth dikembangkan dengan pendekatan yang lebih efisien melalui pembentukan struktur *Frequent Pattern Tree* (FP-Tree). Pendekatan ini memungkinkan identifikasi pola tanpa pembangkitan kandidat secara eksplisit, sehingga mengurangi beban komputasi dan mempercepat proses pemrosesan data [3][4].

Meskipun sejumlah penelitian telah membandingkan performa kedua algoritma ini, sebagian besar masih bersifat umum dan belum memberikan pemahaman yang mendalam dalam konteks penerapan nyata, khususnya di lingkungan usaha mikro, kecil, dan menengah (UMKM). Permasalahan utama yang ingin diangkat dalam penelitian ini adalah perlunya kajian komparatif yang menyeluruh antara algoritma Apriori dan FP-Growth untuk menentukan algoritma yang paling optimal digunakan dalam analisis pola pembelian konsumen pada data transaksi penjualan G Coffee. Kajian ini mencakup evaluasi dari aspek kecepatan eksekusi proses, akurasi hasil asosiasi (berdasarkan nilai *support*, *confidence*, dan *lift*), efisiensi penggunaan sumber daya komputasi, serta kesesuaian algoritma terhadap dataset berskala kecil hingga besar.

Penelitian ini mengacu pada temuan sebelumnya yang menyatakan bahwa pemilihan algoritma sangat berpengaruh terhadap efektivitas sistem pendukung keputusan. Mootha et al.[4] mengungkapkan bahwa efisiensi algoritma sangat penting untuk implementasi sistem real-time seperti dalam e-commerce, sedangkan Sibarani[5] menekankan bahwa pemilihan algoritma yang sesuai dapat meningkatkan kualitas pola penjualan dan berdampak langsung pada peningkatan performa bisnis. Berdasarkan latar belakang tersebut, penelitian ini tidak hanya bertujuan untuk membandingkan dua algoritma tersebut secara umum, tetapi juga menawarkan pendekatan sistematis untuk mengukur performa keduanya dalam konteks bisnis ritel modern. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi nyata bagi pengambilan keputusan berbasis data serta menjadi dasar pengembangan pendekatan *hybrid* yang menggabungkan keunggulan efisiensi dari FP-Growth dengan fleksibilitas parameter dari Apriori.

II. SIGNIFIKASI STUDI

A. Penelitian Terdahulu

Berbagai penelitian sebelumnya telah menjadi fondasi penting dalam pengembangan metode *Association Rule Mining* (ARM), khususnya dalam membandingkan algoritma Apriori dan FP-Growth. Studi yang dilakukan oleh Sepri dan Afdal [15] menunjukkan bahwa kedua algoritma mampu menghasilkan aturan asosiasi yang relevan, namun belum memberikan penekanan pada efisiensi pemrosesan waktu maupun skalabilitas dalam skenario bisnis nyata. Penelitian Musdalifah dan Jananto [16] menggunakan pendekatan CRISP-DM untuk menganalisis pola belanja pelanggan, dan menyimpulkan bahwa FP-Growth lebih unggul dalam hal kekuatan *rule* dan kecepatan pemrosesan. Namun, studi tersebut tidak membahas performa pada berbagai ukuran dataset secara sistematis, serta tidak menyoroti konteks bisnis spesifik seperti sektor UMKM atau industri makanan dan minuman.


Berbeda dari penelitian-penelitian terdahulu, studi ini secara spesifik berfokus pada data transaksi penjualan dari G Coffee, sebuah bisnis ritel di sektor kuliner dan bertujuan untuk menguji serta membandingkan performa algoritma Apriori dan FP-Growth dari aspek yang lebih terukur, yaitu waktu eksekusi (*execution time*), tingkat akurasi (*support*, *confidence*, dan *lift*), serta efisiensi penggunaan sumber daya pada dataset dengan skala yang bervariasi (300, 400, dan 500 transaksi). Dengan demikian, posisi penelitian ini adalah untuk melengkapi dan sekaligus mengonfirmasi temuan sebelumnya melalui penerapan langsung pada konteks bisnis nyata dengan pendekatan eksperimental yang lebih terstruktur.

Penelitian ini tidak hanya mengadopsi pendekatan CRISP-DM secara metodologis, tetapi juga memperjelas penerapannya pada tahapan *data understanding*, *data preparation*, *modeling*, dan *evaluation* tanpa mengulang penjelasan umum yang telah banyak dibahas. Adapun parameter minimum yang digunakan dalam penelitian ini adalah nilai *support* sebesar 5% dan *confidence* sebesar 70%, dengan pemrosesan data menggunakan bahasa pemrograman Python dan pustaka *mlxtend* untuk penerapan algoritma.

Dengan kontribusi ini, studi diharapkan mampu memberikan rekomendasi konkret bagi pelaku bisnis, khususnya di sektor UMKM, dalam memilih algoritma analisis data transaksi yang paling sesuai untuk meningkatkan strategi pemasaran berbasis pola pembelian pelanggan.

B. Metode Penelitian

Penelitian ini mengikuti serangkaian langkah metodologis yang dirancang untuk memastikan proses analisis data berjalan secara sistematis dan efektif. Langkah pertama dalam penelitian ini adalah identifikasi masalah, yang bertujuan untuk menentukan strategi terbaik dalam mengoptimalkan analisis transaksi menggunakan algoritma Apriori dan FP-Growth. Berikut adalah gambaran singkat sebagai alur penyusunan laporan ini dengan kerangka pemikiran yang dapat dilihat pada gambar 1.



Gambar 1 Kerangka Penelitian

1. Mengidentifikasi Masalah
Masalah yang diidentifikasi dalam penelitian ini untuk mendapatkan strategi daerah untuk promosi yang efektif dan efisien dalam mendapatkan calon mahasiswa baru ditengah ketatnya persaingan antar Perguruan Tinggi.
2. Menganalisis Masalah
Analisis masalah pada penelitian ini dilakukan dengan dua metode yaitu metode deskriptif dan metode komparatif.
 - a. Metode Deskriptif
Pada metode ini data yang ada dikumpulkan, disusun, dikelompokkan dan dianalisis sehingga diperoleh beberapa gambaran yang jelas pada masalah yang akan dibahas.
 - b. Metode Komparatif
Pada metode ini analisis dilakukan dengan cara membandingkan teori dan praktek sehingga diperoleh gambaran yang jelas tentang persamaan dan perbedaan di antara algoritma Apriori dan *FP-Growth*.
3. Menentukan Tujuan
Menentukan tujuan akhir dari penelitian ini.
4. Mempelajari Literatur

5. Literatur

Literatur yang dipakai sebagai bahan referensi dalam penelitian ini adalah dari jurnal-jurnal ilmiah, modul pembelajaran dan buku tentang Data Mining. literatur-literatur ini akan menjadi pedoman untuk melakukan penelitian agar memudahkan proses penelitian.

6. Pengujian Menggunakan Code Python.

Pada tahap ini, rule di tes kembali atau diuji lagi menggunakan sistem data mining yang sudah ada. *Tools* yang digunakan sebagai pengujian sistem adalah Code Python.

7. Pengambilan Kesimpulan

Setelah diuji, hasil analisis antara cara manual dan pengujian memanfaatkan *tools* akan terlihat perbandingannya. Langkah berikutnya adalah mengambil kesimpulan dari analisa penerapan pada algoritma Apriori maupun *FP-Growth* terhadap *knowledge* yang baru didapat yaitu berupa penentuan dalam menentukan strategi dalam mempromosikan pendidikan.

III. HASIL DAN PEMBAHASAN

1. Deskripsi Umum Dataset

Data yang digunakan dalam penelitian ini merupakan transaksi penjualan dari G Coffee selama periode 1 September hingga 30 November 2024. Dataset mencakup informasi seperti nomor transaksi dan item yang dibeli oleh pelanggan. Data tersebut telah diproses melalui tahap *preprocessing* satu kali di awal penelitian, meliputi seleksi kolom yang relevan, penghapusan data kosong (*null*), serta transformasi ke format transaksi menggunakan teknik *transaction grouping* dan *one-hot encoding*. Selanjutnya, data dianalisis menggunakan dua pendekatan: perhitungan manual untuk memahami proses logika dasar, dan implementasi algoritma menggunakan bahasa Python. Data yang digunakan berasal dari laporan penjualan “G Coffee” dari tanggal 1 September 2024 hingga 30 November 2024. Tabel dari dataset dapat dilihat pada gambar 2.

Nomor	Tanggal	Tipe Penj	Metode P	Masuk ke	Pelanggan	Item	Notes	Kategori	Varian	Pilihan Ek	Qty	Harga Sat	Sub Total	Total	Dibuat Ol	Diubah Ol
						bakso udon		bakso			4	35000	140000			
						Caffe Latte		Espresso Based			1	25000	25000			
						PAKET 2		PAKET			1	49000	49000			
						Diskon Final : diskon member 10%							-21400			
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera -		Pembulatan					1	-100	-100	192500	angel 08 S	
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera -		ice cream		frappe			1	15000	15000	15000	angel 08 S	
						Kopi Susu Aren		Signature			2	25000	50000			
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera -		Biaya jasa aplikasi					1	1000	1000	51000	angel 08 S	
						odading coklat		Snack			2	20000	40000			
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera -		otak otak		Snack			2	22000	44000	84000	angel 08 S	
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera -		Caffe Latte		Espresso Based			1	25000	25000	25000	angel 08 S	
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera -		Kopi Susu Hazelnut		Signature		minuman	1	37000	37000	37000	angel 08 S	
						chocolate		frappe			1	26500	26500			
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera -		Kopi Susu Hazelnut		Signature			1	27000	27000	53500	angel 08 S	
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera Ani/Lanta		nasi putih		makanan			1	5000	5000	5000	angel 08 S	angel 08 S
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera Sofa 1		ayam geprek ijo+nas		makanan			1	30000	30000	30000	angel 08 S	angel 08 S
						jasminetee		Tea			1	21000	21000			
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera Wely,Lt 2		mie rebus Gcoffee		noodles			1	23000	23000	44000	angel 08 S	
						Cappucino		Espresso Based			1	25000	25000			
						chiken katsu+nasi		makanan			4	33000	132000			
						lemontea		Tea			3	25000	75000			
S/240908/	08 Septem	Makan di	Tunai	Kasir Pera Zaskia,Cw		Vanilla Latte		Espresso Based			1	25000	25000	257000	angel 08 S	

Gambar 2 Dataset Penjualan G Coffee

2. Proses Perhitungan Algoritma Apriori

a. Menghitung Support

Support adalah ukuran yang menunjukkan seberapa sering sebuah itemset muncul dalam seluruh transaksi. Untuk menghitung support, kita cukup menghitung jumlah transaksi yang mengandung itemset tertentu dan membaginya dengan total jumlah transaksi dalam dataset.

$$\text{Support (A)} = \frac{\text{Jumlah Transaksi Mengandung Item A}}{\text{Total Transaksi}} \quad (1)$$

Sebagai contoh, untuk itemset “mineral 660ml”, support dihitung dengan cara menghitung jumlah transaksi yang mengandung item tersebut, kemudian membaginya dengan total jumlah transaksi.

$$\text{mineral 660ml} = \frac{\text{Jumlah Transaksi Mengandung mineral 660ml}}{\text{Total Transaksi}} \quad (2)$$

$$\text{mineral 660ml} = \frac{1225}{3261} = 0.3756516406010426$$

b. Menghitung Confidence

Confidence mengukur kekuatan aturan asosiasi, yaitu probabilitas bahwa item B akan muncul di transaksi yang sudah mengandung item A. Untuk menghitung confidence, kita membagi jumlah transaksi yang mengandung kedua item (A dan B) dengan jumlah transaksi yang mengandung item A. Rumus untuk menghitung confidence adalah sebagai berikut :

$$\text{Confidence (A} \rightarrow \text{B)} = \frac{\text{Jumlah Transaksi Mengandung Item A dan B}}{\text{Jumlah Transaksi Mengandung Item A}} \quad (3)$$

Sebagai contoh, untuk aturan asosiasi “mineral 660ml” → “Kopi Susu Aren”, confidence dihitung dengan cara membagi jumlah transaksi yang mengandung kedua itemset tersebut dengan jumlah transaksi yang mengandung “mineral 660ml”.

$$\text{Confidence ("mineral 660ml"} \rightarrow \text{"Kopi Susu Aren"}) = \frac{\text{Jumlah Transaksi Mengandung Item "mineral 660ml"} \rightarrow \text{"Kopi Susu Aren"}}{\text{Jumlah Transaksi Mengandung Item "mineral 660ml"}} \quad (4)$$

$$\text{Confidence ("mineral 660ml"} \rightarrow \text{"Kopi Susu Aren"}) = \frac{325}{3261} = 0.09966268015946028$$

c. Menghitung Lift

Lift adalah ukuran yang menunjukkan seberapa kuat asosiasi antara dua itemset jika dibandingkan dengan probabilitas independen mereka. Lift dihitung dengan membagi confidence dengan support dari itemset B.

$$\text{Lift (A} \rightarrow \text{B)} = \frac{\text{Confidence (A} \rightarrow \text{B)}}{\text{Support (B)}} \quad (5)$$

Lift yang lebih tinggi menunjukkan hubungan yang lebih kuat antara kedua itemset tersebut. Sebagai contoh, untuk aturan asosiasi “mineral 660ml” → “Kopi Susu Aren”, lift dihitung dengan membagi confidence dengan support dari itemset “Kopi Susu Aren”.

$$Lift ("mineral 660ml" \rightarrow "Kopi Susu Aren") = \frac{Confidence ("mineral 660ml" \rightarrow "Kopi Susu Aren")}{Support ("Kopi Susu Aren")}$$

$$Lift ("mineral 660ml" \rightarrow "Kopi Susu Aren") = \frac{0.2653061224489796}{0.23091076356945722} 1.1489551996097245 \quad (6)$$

3. Proses Perhitungan Algoritma FP-Growth

a. Menghitung Frekuensi Setiap Item

Proses perhitungan frekuensi setiap item dimulai dengan mengonversi data transaksi ke dalam format one-hot encoding. Setiap kolom merepresentasikan sebuah item, dan setiap baris merepresentasikan transaksi. Frekuensi dihitung dengan menjumlahkan nilai dalam setiap kolom, yang merepresentasikan jumlah transaksi di mana item tersebut muncul. Selanjutnya, nilai support diperoleh dengan membagi frekuensi setiap item dengan total jumlah transaksi.


b. Urutkan Item Berdasarkan Frekuensi

Setelah menghitung frekuensi setiap item, langkah berikutnya adalah mengurutkan item secara menurun berdasarkan frekuensinya. Pengurutan ini bertujuan untuk memprioritaskan item yang paling sering muncul, yang kemudian digunakan dalam proses pembuatan FP-Tree untuk menyusun struktur pohon yang efisien. Urutan item berdasarkan nilai frekuensi adalah sebagai berikut :

['mineral 660ml', 'Kopi Susu Aren', 'kentang goreng', 'nugget', 'ayam geprek+nasi', 'tempe mendoan', 'lemontea', 'matcha', 'kwetiaw seafood', 'Vanilla Latte', 'chocolate', 'chiken katsu+nasi', 'lycheetea', 'Americano', 'Caffe Latte', 'bakso udon', 'nasgor telur', 'mie goreng Gcoffee', 'nasgor ayam', 'nasgor kampung', 'ice cream', 'Kopi Susu Vanilla', 'Cappucino', 'dimsum udang', 'odading coklat', 'mango yakult', 'red velvet', 'es teh', 'greentea', 'tahu bakso', 'taro', 'greentea milk', 'avocado choco', 'Caramel Machiato', 'ayam geprek ijo+nasi', 'dimsum ayam', 'Kopi Susu Butterscoth', 'creamy strawberry', 'pisang kipas', 'otak otak', 'nasgor nugget', 'cireng', 'Kopi Susu Caramel', 'mie rebus Gcoffee', 'Rainbow mojito', 'dimsum rumput laut', 'odading mozzarella', 'roti bakar', 'oreo n cream', 'mie bakso', 'sampoerna (L)', 'dimsum kepiting', 'banana split', 'Kopi Susu Hazelnut', 'lychee yakult', 'Avocado Coffee', 'sisis', 'lumpia kulit tahu', 'snack bucket', 'espresso', 'bakso kosong', 'mix', 'nasi putih', 'Mochalatte', 'strawberry punch', 'lychee sparkling', 'Blue Margarita', 'soju', 'rum regal', 'Matcha Coffee', 'burger+french fries', 'jasminetea', 'blackcurrant', 'Affogato', 'malboro merah', '+telur mata sapi 1/2 matang', 'ginger tea', 'Kosu Botol 250ml', 'strawberrytea']

c. Membuat FP-Tree

Setelah menghitung frekuensi setiap item, langkah berikutnya adalah mengurutkan item secara menurun berdasarkan frekuensinya. Pengurutan ini bertujuan untuk memprioritaskan item yang paling sering muncul, yang kemudian digunakan dalam proses pembuatan FP-Tree untuk menyusun struktur pohon yang efisien. FP-Tree yang dihasilkan dapat dilihat pada gambar 3.



Gambar 3 FP-Tree

Gambar 3 menunjukkan FP-Tree yang terbentuk setelah mengurutkan item berdasarkan frekuensinya, di mana struktur pohon ini dimulai dari sebuah akar kosong dan setiap simpul mewakili item yang muncul dalam transaksi; dengan mengurutkan item dari yang paling sering muncul hingga yang kurang sering, FP-Tree memungkinkan pembagian jalur transaksi yang sama (prefix paths) sehingga struktur pohon menjadi lebih ringkas dan efisien, serta garis penghubung antar simpul menggambarkan keterkaitan antar item yang sering muncul bersama, yang kemudian dapat digunakan oleh algoritma FP-Growth untuk mengekstrak pola frequent itemset serta aturan asosiatif dari dataset.

d. Menghitung Support Confidence dan Lift

Rumus yang digunakan dalam menghitung nilai Support, Confidence dan Lift pada algoritma FP-Growth sama dengan yang digunakan pada perhitungan algoritma Apriori.

4. Implementasi Menggunakan Python

Penerapan algoritma Apriori dan FP-Growth dilakukan menggunakan pustaka *mlxtend.frequent_patterns* di Python. Parameter yang digunakan seragam pada kedua algoritma, yaitu minimum support 0.05 dan minimum confidence 0.7. Penelitian ini menggunakan tiga variasi dataset berukuran 300, 400, dan 500 transaksi untuk menguji konsistensi hasil dan skalabilitas algoritma.

Hasil yang diperoleh dari kedua algoritma sebagian besar identik dalam hal aturan asosiasi yang ditemukan. Contoh beberapa asosiasi yang konsisten muncul di semua dataset antara lain :

- “Vanilla Latte” dan “Taro” → “Banana Split” (Lift: 9.69, Confidence: 83.33%)
- “Ayam Geprek Ijo + Nasi” dan “Strawberry Tea” → “Jasmine Tea” (Lift: 7.93, Confidence: 83.33%)

Namun, terdapat perbedaan signifikan dalam waktu eksekusi.

5. Perbandingan Kuantitatif Algoritma

Hasil perbandingan kuantitatif dari masing-masing algoritma dapat dilihat pada tabel 1 sebagai berikut :

Tabel 1 Perbandingan Kuantitatif Algoritma

Dataset	Jumlah Transaksi	Algoritma	Jumlah Aturan	Waktu Eksekusi (detik)
1	300	Apriori	13	0.5833
		FP-Growth	13	0.3008
2	400	Apriori	15	0.6402
		FP-Growth	15	0.3121
3	500	Apriori	17	0.691
		FP-Growth	17	0.3189

Dari tabel di atas, terlihat bahwa FP-Growth secara konsisten membutuhkan waktu eksekusi hampir setengah dari waktu yang dibutuhkan oleh Apriori, meskipun aturan yang dihasilkan sama. Hal ini mendukung literatur yang menyebutkan keunggulan FP-Growth dalam efisiensi pemrosesan, terutama pada dataset yang terus bertambah skalanya.

6. Pembahasan Strategis Hasil

Hasil analisis FP-Growth memberikan gambaran strategis yang mendalam bagi G Coffee, dengan aturan asosiasi yang dapat dimanfaatkan untuk mengembangkan berbagai inisiatif bisnis. Aturan tersebut memungkinkan perusahaan menyusun strategi bundling produk yang efektif, di mana paket produk dibentuk berdasarkan pola pembelian pelanggan, sehingga kombinasi produk yang sering muncul bersama dapat ditawarkan sebagai satu paket yang menarik bagi konsumen. Selain itu, penerapan promosi terarah juga dapat dilakukan dengan menawarkan produk pelengkap secara otomatis saat item utama dipilih, meningkatkan nilai tambah yang dirasakan pelanggan dan mendorong peningkatan penjualan. Dari sisi operasional, optimalisasi stok menjadi lebih tepat sasaran karena inventory dapat diatur berdasarkan pola produk yang kerap dibeli bersama, sehingga membantu dalam pengelolaan persediaan agar tidak terjadi kelebihan atau kekurangan barang. Lebih jauh, keunggulan FP-Growth dalam melakukan analisis secara cepat dan efisien membuatnya sangat cocok untuk diterapkan dalam sistem real-time seperti point-of-sale atau sistem rekomendasi harian, sehingga G Coffee dapat dengan segera merespons dinamika pasar dan kebutuhan pelanggan yang berubah dengan cepat.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa baik algoritma Apriori maupun FP-Growth mampu mengidentifikasi pola asosiasi yang relevan dari data transaksi penjualan, dengan hasil aturan asosiasi yang serupa. Namun, terdapat perbedaan signifikan dari segi efisiensi: algoritma FP-Growth secara konsisten menunjukkan waktu eksekusi yang lebih cepat dibandingkan Apriori, khususnya pada dataset yang lebih besar. Hal ini menjadikan FP-Growth lebih unggul dalam konteks pemrosesan data berskala besar atau sistem real-time. Penerapan hasil temuan ini memiliki manfaat praktis yang nyata bagi perusahaan, terutama dalam merancang strategi promosi berbasis bundling, menyusun rekomendasi produk otomatis di sistem kasir (point-of-sale), serta mengoptimalkan manajemen stok berdasarkan pola pembelian konsumen. Sebagai contoh, beberapa aturan yang ditemukan seperti kombinasi “Vanilla Latte” dan “Taro” → “Banana Split” atau “Ayam Geprek Ijo + Nasi” → “Jasmine Tea” menunjukkan potensi besar untuk strategi cross-selling yang lebih efektif.

Secara keseluruhan, dari berbagai ukuran dataset yang diuji, ditemukan cukup banyak aturan asosiasi yang menarik dan berpotensi diterapkan, bukan hanya satu atau dua kombinasi saja. Hal ini memperkuat validitas hasil serta memperluas cakupan manfaatnya bagi pengambilan keputusan bisnis.

Namun, penelitian ini memiliki keterbatasan, antara lain penggunaan data transaksi dari satu perusahaan dalam periode waktu terbatas (tiga bulan), serta parameter tetap (support dan confidence) yang belum divariasikan untuk melihat sensitivitas hasil. Oleh karena itu, penelitian lanjutan disarankan untuk mengeksplorasi berbagai sektor bisnis lainnya, menggunakan rentang waktu yang lebih panjang, serta menerapkan optimasi parameter untuk meningkatkan fleksibilitas dan akurasi dalam menemukan pola asosiasi.

REFERENSI

- [1] I. M. A. M. Dinata, Gunadi. I Gede Aris, and I. M. G. Sunarya, "Analisis Hyperparameter Pada Klasifikasi Jenis Daging Menggunakan Algoritma Convolutional Neural Network," *J. Sains Komput. Inform.*, vol. 8, no. 1, pp. 25–34, 2024.
- [2] T. Kurniana, A. Lestari, and E. D. Oktaviyani, "Penerapan Algoritma Apriori untuk Mencari Pola Transaksi Penjualan Berbasis Web pada Cafe Sakuyan Side," *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, vol. 3, no. 1, pp. 13–23, 2023, doi: 10.24002/konstelasi.v3i1.7005.
- [3] R. R. Rerung, "Penerapan Data Mining dengan Memanfaatkan Metode Association Rule untuk Promosi Produk," *J. Teknol. Rekayasa*, vol. 3, no. 1, p. 89, 2018, doi: 10.31544/jtera.v3.i1.2018.89-98.
- [4] S. Mootha, S. Sridhar, and M. S. K. Devi, "A Stacking Ensemble of Multi Layer Perceptrons to Predict Online Shoppers' Purchasing Intention," in *2020 3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, IEEE, Dec. 2020, pp. 721–726. doi: 10.1109/ISRITI51436.2020.9315447.
- [5] A. J. P. Sibarani, "Implementasi Data Mining Menggunakan Algoritma Apriori Untuk Meningkatkan Pola Penjualan Obat," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 7, no. 2, pp. 262–276, 2020, doi: 10.35957/jatisi.v7i2.195.
- [6] F. Elfaladonna and A. Rahmadani, "Analisa Metode Classification-Decission Tree Dan Algoritma C.45 Untuk Memprediksi Penyakit Diabetes Dengan Menggunakan Aplikasi Rapid Miner," *SINTECH (Science Inf. Technol. J.)*, vol. 2, no. 1, pp. 10–17, 2019, doi: 10.31598/sintechjournal.v2i1.293.
- [7] A. N. Rahmi and Y. A. Mikola, "Implementasi Algoritma Apriori Untuk Menentukan Pola Pembelian Pada Customer (Studi Kasus : Toko Bakoel Sembako)," *Inf. Syst. J.*, vol. 4, no. 1, pp. 14–19, 2021, [Online]. Available: <https://jurnal.amikom.ac.id/index.php/infos/article/view/561>
- [8] R. Takdirillah, "Penerapan Data Mining Menggunakan Algoritma Apriori Terhadap Data Transaksi Sebagai Pendukung Informasi Strategi Penjualan," *Edumatic J. Pendidik. Inform.*, vol. 4, no. 1, pp. 37–46, 2020, doi: 10.29408/edumatic.v4i1.2081.
- [9] I. S. Syahputra, H. -, and A. R. Dewi, "Implementasi Data Mining Dalam Menentukan Pola Elemen Film Favorit Menggunakan Algoritma Apriori," *Syntax J. Softw. Eng. Comput. Sci. Inf. Technol.*, vol. 4, no. 1, pp. 289–294, 2023, doi: 10.46576/syntax.v4i1.2888.

- [10] E. D. Sikumbang, "Penerapan Data Mining Penjualan Sepatu Menggunakan Metode Algoritma Apriori," *J. Tek. Komput. AMIK BSI*, vol. Vol 4, No., no. September, pp. 1–4, 2018.
- [11] D. Fitriana, "Implementasi Data Mining Pada Penjualan Tiket Pesawat Menggunakan Algoritma Apriori (Studi Kasus : PT. Pesona Ceria Travel)," *Pelita Inform. Budi Darma*, vol. 2, no. 2, pp. 31–39, 2017.
- [12] F. A. Sianturi, "Penerapan Algoritma Apriori Untuk Penentuan Tingkat Pesanan," *Mantik Penusa*, vol. 2, no. 1, pp. 50–57, 2018, [Online]. Available: <http://ejurnal.pelitanusantara.ac.id/index.php/mantik/article/view/330>
- [13] N. Giarsyani, "Komparasi Algoritma Machine Learning dan Deep Learning untuk Named Entity Recognition : Studi Kasus Data Kebencanaan," *Indones. J. Appl. Informatics*, vol. 4, no. 2, p. 138, 2020, doi: 10.20961/ijai.v4i2.41317.
- [14] A. F. Lestari and M. Hafiz, "Penerapan Algoritma Apriori Pada Data Penjualan Barbar Warehouse," *INOVTEK Polbeng - Seri Inform.*, vol. 5, no. 1, p. 96, 2020, doi: 10.35314/isi.v5i1.1317.
- [15] D. Sepri, M. Afdal. 2017. "Analisa Dan Perbandingan Metode Algoritma Apriori Dan *FP-Growth* Untuk Mencari Pola Daerah Strategis Pengenalan Kampus Studi Kasus Di Stkip Adzkie Padang". *Jurnal Sistem Informasi Kaputama (JSIK)*, Vol 1 No :1
- [16] Musdalifah, I., Jananto, A. 2022. "Analisis Perbandingan Algoritma Apriori Dan *FP-Growth* Dalam Pembentukan Pola Asosiasi Keranjang Belanja Pelanggan". *Jurnal Ilmiah Komputer*, Vol. 18, No. 2