Perbandingan Kinerja Algoritma Apriori dan FP-Growth pada Pola Pembelian Konsumen

Performance Comparison of Apriori and FP-Growth on Purchase Patterns

R.A. Jaffray Marin[1], Agung A. Wiijayanto[2], Nelvan Simangunsong[3] , Miqdad Nur Shidiq[4] .
[1,2,3,4] Teknik Informatika, Fakultas Teknik, Universitas Papua
Jl. Gunung Salju Amban, Manokwari, Papua Barat, Indonesia
E-mail : robertalexanderjaffraymarin@gmail.com[1], nelvan.s2003@gmail.com[2],
agungawiijayantotif@gmail.com[3], nurshidiq1145@gmail.com[4]

Abstract

The development of the retail sector generates a large amount of transaction data that holds potential strategic information about consumer purchasing patterns. This study aims to compare the performance of the Apriori and Frequent Pattern Growth (FP-Growth) algorithms in association rule mining using the secondary dataset "Market Basket Optimization," which includes 7,501 transactions. Testing was conducted with a minimum support parameter of 0.01 and confidence of 0.3 using the Python programming language. The research results showed that both algorithms produced 63 identical association rules, but FP-Growth proved to be 3.7 times faster with an execution time of 0.1547 seconds, while Apriori took 0.5731 seconds. The strongest pattern was identified in the combination of Herb and Pepper as well as Ground Beef with a lift ratio of 3.29. The benefit of this research is to provide recommendations for retail practitioners to accurately improve product placement strategies and cross-selling promotions. It can be concluded that FP-Growth is a superior algorithm for handling large-scale data due to its efficiency in computation time, without sacrificing the accuracy of the obtained pattern results.

Keywords: Data Mining, Market Basket Analysis, Apriori, FP-Growth, Association Rules.

Abstrak

Perkembangan sektor ritel menghasilkan jumlah besar data transaksi yang menyimpan potensi informasi strategis tentang pola pembelian konsumen. Penelitian ini bertujuan untuk membandingkan kinerja algoritma Apriori dan Frequent Pattern Growth (FP-Growth) dalam penambangan aturan asosiasi dengan menggunakan dataset sekunder "Market Basket Optimisation" yang mencakup 7. 501 transaksi. Pengujian dilakukan dengan parameter minimum support 0,01 dan confidence 0,3 menggunakan bahasa pemrograman Python. Hasil penelitian menunjukkan bahwa kedua algoritma menghasilkan 63 aturan asosiasi yang identik, namun FP-Growth terbukti 3,7 kali lebih cepat dengan waktu eksekusi 0,1547 detik, sementara Apriori memerlukan 0,5731 detik. Pola yang paling kuat teridentifikasi pada kombinasi Herb and Pepper serta Ground Beef dengan rasio lift 3,29. Manfaat penelitian ini adalah memberikan saran bagi praktisi ritel untuk meningkatkan strategi penempatan produk dan promosi cross-selling secara akurat. Dapat disimpulkan bahwa FP-Growth merupakan algoritma yang lebih unggul dalam menangani data dalam skala besar karena efisiensinya dalam waktu komputasi, tanpa mengorbankan ketepatan hasil pola yang diperoleh.

Kata kunci: *Data Mining, Market Basket Analysis, Apriori, FP-Growth, Aturan Asosiasi.*

1. Pendahuluan

Perkembangan teknologi informasi yang pesat telah mendorong hampir seluruh sektor kehidupan untuk bertransisi ke dalam ekosistem berbasis data, termasuk industri perdagangan dan bisnis ritel. Setiap aktivitas transaksi harian, baik pada toko fisik maupun platform belanja daring, menghasilkan rekam jejak digital berupa data transaksi ritel yang volumenya terus meningkat secara signifikan. *Market Basket Analysis* (MBA) hadir sebagai salah satu teknik penambangan data (*data mining*) yang paling relevan untuk menelaah peluang di balik data tersebut. MBA bekerja dengan cara menganalisis data keranjang belanja pelanggan guna menemukan pola frekuensi item (*frequent itemset*) serta asosiasi antar produk yang sering dibeli secara bersamaan [1]. Dalam penerapannya, algoritma Apriori dan *Frequent Pattern*

Growth (FP-Growth) adalah dua metode yang paling sering dipakai untuk menerapkan teknik ini. Sebuah studi perbandingan menunjukkan bahwa tingkat akurasi serta aturan asosiasi yang dihasilkan oleh kedua algoritma tersebut ternyata sama, walaupun kedua algoritma memiliki perbedaan signifikan dalam hal waktu pemrosesan dan penggunaan memori [2]. Ini menunjukkan bahwa memilih algoritma yang tepat tidak hanya merupakan masalah teknis, tetapi juga berkaitan dengan efektivitas penggunaan sumber daya yang secara langsung mempengaruhi kemampuan perusahaan dalam mengembangkan strategi bisnis yang didasarkan pada data [3].

Beberapa studi menunjukkan bahwa algoritma FP-Growth lebih unggul dalam menentukan aturan asosiasi pada dataset besar karena kecepatan dan kemampuannya yang lebih baik dibandingkan dengan Apriori [4]. Meskipun kedua algoritma ini ditujukan untuk mendeteksi pola asosiasi, Apriori dan FP-Growth menggunakan metode komputasi yang berbeda, sehingga hasil kinerjanya tidak selalu sebanding. Algoritma Apriori menerapkan metode pembuatan kandidat item secara berulang, yang merupakan cara yang teratur, tetapi dapat menjadi lambat karena harus memindai basis data berulang kali, khususnya ketika jumlah variasi item semakin rumit [2]. Sebaliknya, FP-Growth menggunakan desain pohon terkompresi yang disebut *FP-Tree*, yang hanya perlu melakukan dua kali pemindaian data, sehingga secara teori jauh lebih efisien [1]. Studi mengenai data transaksi ritel menunjukkan bahwa kedua algoritma dapat menghasilkan aturan asosiasi yang sah sebagai dasar strategi promosi produk, meskipun ada perbedaan dalam jumlah aturan yang dihasilkan [5].

Sejumlah penelitian sebelumnya telah menegaskan betapa krusialnya studi perbandingan kinerja ini. Satu penelitian menemukan bahwa FP-Growth dan Apriori adalah pilihan yang lebih baik dalam menemukan pola frekuensi jika dibandingkan dengan algoritma lainnya, berkat efisiensi waktu komputasinya [2]. Lebih jauh, penerapan metode MBA dengan pendekatan Penemuan *Knowledge Discovery in Databases* (KDD) pada data transaksi ritel berhasil mengidentifikasi kombinasi produk yang dapat segera digunakan sebagai landasan pengaturan produk, strategi pengemasan, dan perencanaan promosi yang lebih terukur [6]. Penelitian yang terdapat dalam jurnal akademik menunjukkan bahwa penerapan ini dapat mendeteksi pola belanja yang tersembunyi yang sebelumnya tidak terlihat, sehingga bisa dimanfaatkan untuk merumuskan rekomendasi strategis dalam rangka meningkatkan efektivitas pemasaran [7].

Namun, ada beberapa celah yang teridentifikasi dalam penelitian sebelumnya. Banyak studi yang masih mengandalkan data transaksi internal perusahaan yang bersifat rahasia, sehingga menyulitkan proses verifikasi atau pengulangan oleh penelitian lain [4]. Selain itu, penilaian kinerja umumnya hanya fokus pada satu dimensi tanpa adanya evaluasi yang menyeluruh yang mencakup tiga metrik utama, yaitu nilai dukungan (*suppor*t), kepercayaan (*confidence*), dan rasio daya angkat (*lift ratio*) secara bersamaan. Penggunaan dataset publik yang standar dalam literatur berbahasa Indonesia juga masih sangat minim, sehingga menghalangi proses perbandingan hasil antar studi [3]. Dataset *Market Basket Optimisation* yang tersedia secara publik di platform Kaggle yang memuat ragam transaksi kebutuhan harian seperti *shrimp, almonds, mineral water,* hingga *vegetables* hadir sebagai peluang untuk menghindarkan penelitian yang transparan dan dapat di replikasi.

Berdasarkan penjelasan di atas, tujuan dari penelitian ini adalah untuk membandingkan efektivitas algoritma Apriori dan FP-Growth secara menyeluruh dengan menggunakan data transaksi ritel sekunder dari Kaggle yang terdiri dari 7501 transaksi produk. Penilaian dilakukan secara menyeluruh dengan membandingkan waktu komputasi pada parameter minimum *support*, *confidence*, dan *life ratio* yang serupa untuk menjamin keadilan dalam pengujian. Dengan pemahaman yang mendalam tentang karakteristik kedua algoritma, para praktisi diharapkan dapat memilih metode analisis yang paling cocok dengan ukuran data yang dimiliki. Secara praktis, hasil penelitian ini diharapkan dapat menjadi panduan bagi pelaku bisnis ritel di Indonesia dalam mengubah data transaksi menjadi wawasan strategis untuk merancang pemasaran berbasis data yang efektif dan tepat sasaran

2. Tinjauan Pustaka

2.1 *Data Mining* dan *Association Rule Mining*

Penggalian data adalah suatu kegiatan untuk menemukan pola yang tidak terlihat dalam kumpulan data yang besar dengan menggunakan metode statistik, matematika, dan komputasi. Di sektor ritel, metode ini digunakan untuk mengambil informasi dari data transaksi dengan tujuan mendukung pembuatan keputusan yang strategis [8]. Salah satu metode yang signifikan adalah penambangan aturan asosiasi, yaitu cara untuk menemukan hubungan antara item dalam data transaksi. Metode ini menggunakan tiga ukuran utama, yaitu *support* untuk mengukur seberapa sering item muncul, *confidence* untuk menilai kekuatan hubungan antara item, dan *lift ratio* untuk mengukur tingkat keterkaitan di atas kemungkinan acak [2]. Ketiga metrik tersebut menjadi dasar dalam menilai kualitas aturan asosiasi yang terbentuk.

2.2 *Market Basket Analysis* (MBA)

Market Basket Analysis (MBA) adalah penerapan penambangan aturan asosiasi yang paling terkenal di industri ritel, baik *online* maupun *offline*. Metode ini

berfungsi dengan menganalisis data transaksi untuk menemukan *Frequent itemset*, yaitu kombinasi produk yang sering dibeli pelanggan dalam periode tertentu, yang kemudian dikonversi menjadi aturan asosiasi [1].

Secara praktis, hasil dari MBA menjadi dasar yang bijak bagi para pelaku usaha untuk meningkatkan penempatan barang, merancang penawaran paket (*bundling*), serta memperbaiki manajemen inventaris [8]. Meskipun berguna dan mudah untuk dipahami, MBA memiliki sifat yang tetap karena pola yang dihasilkan sering kali bersifat umum dan tidak selalu responsif terhadap perubahan cepat dalam perilaku individu. Namun, dengan penyesuaian yang sesuai, MBA tetap menjadi alat analisis yang sangat penting untuk mengubah kumpulan data transaksi menjadi strategi pemasaran yang lebih terukur [1].

2.3 Algoritma Apriori

Algoritma Apriori, yang diperkenalkan oleh Agrawal dan Srikant (1994), merupakan fondasi dalam *association rule mining*. Algoritma ini beroperasi dengan pendekatan *generate-and-test*, di mana kandidat *itemset* dibangun secara iteratif mulai dari 1-*itemset* hingga k-*itemset*. Di setiap tahapan, kandidat yang tidak memenuhi nilai *minimum support* akan dipangkas berdasarkan prinsip apriori *propety* [9]. Keunggulan utamanya terletak pada transparansi proses yang sistematis, sehingga setiap pembentukan aturan sangat mudah ditelusuri dan diverifikasi [8].

Namun, Apriori memiliki kelemahan pada dataset berskala besar karena memerlukan pemindaian basis data berulang kali untuk setiap level *itemset*. Hal ini menyebabkan konsumsi waktu komputasi dan memori yang cukup tinggi [3]. Sebuah studi komparatif menunjukkan bahwa pada dataset yang sama, waktu eksekusi Apriori mencapai 0,5833 detik, lebih lambat dibandingkan FP-Growth yang hanya memerlukan 0,3008 detik [10].

2.4 Algoritma FP-Growth

Algoritma *Frequent Pattern Growth* (FP-Growth) muncul sebagai jawaban untuk meningkatkan efisiensi yang terbatasi oleh Apriori dengan menggunakan struktur pohon yang diolah untuk menghemat ruang yang disebut *FP-Tree*. Tidak seperti metode tradisional, FP-Growth hanya memerlukan dua kali pemeriksaan data tanpa harus secara jelas menyusun kandidat *itemset* [2]. Keunggulan ini memungkinkan FP-Growth untuk menggunakan waktu dan memori dengan lebih efisien, khususnya ketika berhadapan dengan jumlah data yang besar. Pada pengujian yang melibatkan 143. 523 transaksi di minimarket, algoritma ini menunjukkan kecepatan rata-rata 33,33% lebih baik dibandingkan dengan Apriori [11]. Meskipun begitu, dalam dataset dengan ukuran kecil, perbedaan kinerja kedua metode ini biasanya tidak begitu mencolok, bahkan pada beberapa kasus, Apriori bisa menghasilkan nilai *lift ratio* yang lebih baik [12].

2.5 Perbandingan Kinerja Apriori dan FP-Growth

Berbagai studi literatur menunjukkan konsistensi keunggulan performa antara kedua algoritma ini. Dalam transaksi farmasi. FP-Growth terbukti sebagai metode tercepat dibandingkan Apriori dan Eclat meski menghasilkan 156 aturan yang identik [5]. Pada data penjualan pupuk, FP-Growth mampu menghasilkan 156 aturan asosiasi, melampaui Apriori yang hanya mencapai 136 aturan, dengan nilai *support* tertinggi 59% beserta *confidence* 100% pada kedua algoritma [3]. Keunggulan kecepatan FP-Growth juga terkonfirmasi pada *Kaggle Groceris Dataset* dengan catatan waktu 0,004 detik [12]. Meski FP-Growth terlihat unggul dalam efisiensi komputasi, apriori tetap dinilai relevan karena transparansi perhitungannya yang lebih mudah diperiksa. Lebih lanjut, analisis pada data transaksi toko bunga menunjukkan bahwa meskipun jumlah aturan yang dihasilkan berbeda 14 aturan oleh Apriori dan 8 aturan terbaik oleh FP-Growth dari keduanya tetap menghasilkan nilai *lift rasio* yang valid sebagai dasar strategis promosi dan pengembangan bisnis nyata [5].

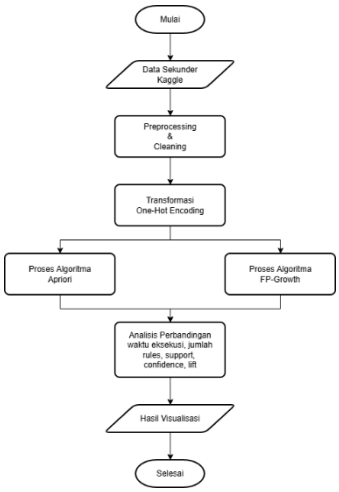
2.6 Penelitian Terkait

Beberapa penelitian sebelumnya telah membuktikan efektivitas algoritma asosiasi dalam menganalisis pola pembelian konsumen:

a. Pola Strategis: Penelitian pada Toko Bali Amenities menggunakan KDD dan Apriori berhasil mencapai nilai *confidence* 82% yang diimplementasikan untuk strategis *bundling* dan penataan produk [6].
b. Komparasi Performa: Studi berbasi CRISP-DM dan pengujian pada dataset INA-CBG's menyimpulkan bahwa Apriori dan FP-Growth menghasilkan aturan yang identik, namun FP-Growth secara konsisten lebih praktis dalam penggunaan memori dan waktu komputasi [13], [2].
c. Skalabilitas Data: Evaluasi pada berbagai ukuran dataset menunjukkan FP-Growth lebih baik karena tidak membangkitkan kandidat secara definitif, sementara analisis pada *Groceries Dataset* Kaggle membuktikan efektivitasnya dalam menggali pola tersembunyi pada data yang memiliki tingkat *sparsity* tinggi [10], [4].
d. Implementasi Ritel: Penggunaan algoritma asosiasi terbukti meningkatkan pengalaman belanja melalui penempatan produk strategis dan optimalisasi tata letak barang [9].

Pada penelitian ini mengembangkan kajian dengan melakukan pengujian performa yang lebih mendalam antara Apriori dan FP-Growth. Fokus utama tim kami adalah menyediakan analisis perbandingan yang objektif menggunakan dataset *Market Basket Optimisation* untuk membedah efisiensi algoritma pada volume data riil, guna memberikan rekomendasi teknis yang aplikatif bagi pengembangan strategis bisnis ritel berbasis data.

3. Metodologi Penelitian



Gambar 1 Diagram Alur Tahapan Penelitian

Penelitian eksperimental kuantitatif ini menggunakan data sekunder dari *Market Basket Optimisation* (7.501), yang diterbitkan di *Kaggle*, pada tahun 2020 dan diakses kembali pada tahun 2026 [14]. Data transaksi yang tersedia kemudian diubah menjadi matriks biner melalui tahap pra-pemrosesan untuk mendukung penambangan *frequent itemset mining* yang lebih efektif. Algoritma Apriori dan FP-Growth diterapkan dengan parameter *support* serta *confidence* yang sama agar dapat membandingkan efisiensi waktu eksekusi dan jumlah aturan asosiasi yang ditemukan. Evaluasi menyeluruh dilakukan melalui visualisasi grafis untuk membandingkan kemajuan kecepatan pemrosesan dan sebaran kualitas pola (*support*, *confidence*, dan *lift*) pada berbagai level. Kesimpulan dari studi ini akan digunakan untuk memilih algoritma yang paling efektif demi mendukung strategi pengaturan produk dan *cross-selling* ritel [15]. Berikut adalah komponen-komponen dari penelitian ini:

3.1 *Data Collection*

Dalam penelitian ini, informasi yang relevan didapatkan dengan memanfaatkan data sekunder dari Kaggle, sebuah *repository* data. Langkah ini diambil untuk memastikan kepercayaan dan transparansi dari sumber data yang digunakan [6]. Data set yang kami pilih adalah *Market Basket Optimisation*, disajikan dalam format nilai terpisah koma (CSV), yang mencakup total 7.501 transaksi. Data ini kemudian disusun dan diolah menggunakan pemrograman *Python* untuk mengidentifikasi pola pembelian secara terstruktur. Pendekatan ini digunakan agar data yang dikumpulkan memiliki akurasi dan keandalan yang tinggi, sehingga analisis yang di hasilkan dapa menjadi dasar dalam menilai kinerja algoritma dan merumuskan rekomendasi strategi bisnis yang lebih tepat bagi sektor ritel [16].

3.2 Spesifikasi Perangkat Keras dan Lunak

Studi ini dibangun dengan menggunakan bahasa pemrograman *Python* dan didukung oleh beberapa pustaka untuk membantu dalam analisis data serta pembuatan grafik. Situasi ini memungkinkan penilaian performa yang konsistensi dan adil [8].Spesifikasi lengkap perangkat yang digunakan disajikan pada Tabel 1.

Tabel 1. Spesifikasi Perangkat Keras dan Lunak

Komponen	Keterangan
IDE	Visual Studi Code
Bahasa Pemrograman	Python 3.11.5 (Anaconda)
Library	Mlxtend (v0.24.0), Pandas, Matplotlib
Sistem Operasi	Windows (64-bit)
Memori (RAM)	16 GB
Presesor	Intel Core i7 vPro 8th Gen

3.3 *Data Preprocessing*

Tahap pengolahan data awal dilakukan untuk menjamin bahwa kumpulan data dalam keadaan bersih, konsisten, dan siap untuk diproses oleh algoritma, Proses ini sangat penting karena mutu dari aturan asosiasi yang dihasilkan sangat dipengaruhi oleh kualitas data yang digunakan. Tahap ini terdiri dari dua langkah utama:

3.3.1 *Data Cleaning*

Tujuan pembersihan data dilakukan untuk menghilangkan inkonsistensi yang dapat memengaruhi kualitas aturan asosiasi yang dihasilkan [4]. Langkah-langkah yang dilakukan mencakup penghapusan spasi ekstra di awal dan akhir nilai teks (*trimming*), menormalisasi karakter menjadi huruf kecil (*lowercase*) untuk menstandarkan penulisan nama produk, dan menghapus catatan transaksi yang mengandung nilai (*null*). Proses ini menghasilkan dataset yang bersih dan bebas dari duplikasi semantik yang disebabkan oleh variasi penamaan item yang merujuk pada produk yang sama [15].

3.3.2 Transformasi Data

Dengan menggunakan kelas *TransactionEncoder* dari pustaka *mlxtend*, data transaksi yang semula berbentuk teks dikonversi menjadi matriks biner menggunakan *One-Hot Encoding*. Setiap kolom dalam matriks sesuai

dengan satu nama produk; nilai 1 (*True*) menunjukkan adanya produk dalam suatu transaksi, sedangkan nilai 0 (*False*) menandakan ketidakhadirannya [12]. Format matriks biner ini merupakan representasi standar yang diperlukan untuk pemrosesan langsung data oleh algoritma Apriori dan FP-Growth.

Tabel 2. Dataset Transaksi Biner

No	Almonds	Antioxydant Juice	Asparagus	...	Zucchini
1	1	1	0	...	0
2	0	0	0	...	0
3	0	0	0	...	0
…	...	...	...	...	…
7.502	0	0	0	…	0

3.4 Implementasi Algoritma

Kedua algoritma diimplementasikan menggunakan fungsi yang tersedia dalam modul *frequent_patterns* dari pustaka *mlxtend*. Penggunaan pustaka yang sama untuk kedua algoritma memastikan tidak ada perbedaan implementasi yang dapat memengaruhi hasil perbandingan kinerja.

3.4.1 Algoritma Apriori

Algoritma Apriori bekerja dengan cara memindai basis data beberapa kali untuk mengidentifikasi kumpulan item yang sering muncul berdasarkan nilai *minimum support* yang telah ditentukan sebelumnya. Prinsip dasarnya dikenal sebagai Apriori *property*: jika suatu *itemset* jarang muncul, semua superset-nya juga akan jarang muncul, sehingga memungkinkan pemangkasan dini untuk menghemat sumber daya komputasi [9]. Algoritma ini menghasilkan kandidat *itemset* iteratif dari tingkat *1-itemset* hingga *k-itemset*, menjadikannya mudah dipahami dan prosesnya mudah ditelusuri secara sistematis [8]. Dalam penelitian ini, implementasinya menggunakan parameter *min_suppor*t = 0,01 dan min_threshold confidence = 0,3 sebagai berikut:

Proses Algoritma Apriori

frequent_apriori = apriori(df_final, min_support=0.01, use_colnames=True)

rules_apriori = association_rules(frequent_apriori, metric="confidence", min_threshold=0.3)

3.4.2 Algoritma FP-Growth

Berbeda dengan metode Apriori, algoritma *Frequent Pattern Growth* (FP-Growth) tidak memerlukan proses pembuatan kandidat secara langsung. Algoritma ini menyimpan semua data mengenai frekuensi item dalam sebuah struktur pohon terkompresi yang dikenal sebagai *FP-Tree*, yang hanya membutuhkan dua kali pemindaian data, menjadikannya jauh lebih efisiensi bagi dari segi waktu maupun memori [2]. Pola *frequent itemset* selanjutnya diambil dengan cara membangun conditional *fp-Tree* secara berulang [17]. Penelitian ini menerapkan parameter yang sama dengan yang digunakan dalam Apriori agar perbandingan kinerjanya adil.

Listing Program 2. Implementasi Algoritma FP-Growth

Proses Algoritma FP-Growth

frequent_fp = fpgrowth(df_final, min_support=0.01, use_colnames=True)

rules_fp = association_rules(frequent_fp, metric="confidence", min_threshold=0.3)

3.5 Pengukuran Kinerja

Kinerja kedua algoritma diukur dan dibandingkan berdasarkan beberapa parameter penting. Pengukuran pertama dilakukan berdasarkan waktu eksekusi, yang mengukur durasi proses komputasi mulai dari algoritma dijalankan hingga munculnya aturan asosiasi, diukur dalam satuan detik [1][8]. Selain itu, dilakukan juga perhitungan terhadap jumlah aturan (*rules*) yang dihasilkan untuk mengetahui banyaknya pola hubungan yang terbentuk dari data transaksi pada berbagai ambang batas parameter [3]. Evaluasi kualitas aturan dilakukan menggunakan tiga metrik utama, yaitu nilai dukungan (*support*), nilai keyakinan (*confidence*), dan nilai daya angkat (lift). Ketiga metrik ini merupakan standar untuk validasi dalam *association rule mining* agar memastikan pola yang ditemukan memiliki nilai strategis [3][18]. Nilai *support* digunakan untuk mengukur seberapa sering suatu himpunan item muncul dalam keseluruhan dataset [5]. Secara matematis, *Support* dirumuskan sebagai:

$$Support(A) = \frac{Jumlah\ Transaki\ Mengandung\ A}{Total\ Seluruh\ Tran} \quad (1)$$

Selanjutnya, nilai *confidence* digunakan untuk menilai seberapa sering aturan asosiasi tersebut terbukti akurat, dan memiliki keterkaitan yang kuat antar-produk [10][18]. Rumus yang digunakan adalah:

$$Confidence(A \rightarrow B) = \frac{Support\ (A\ \cup B)}{Support\ (A)} \quad (2)$$

Terakhir, nilai *lift* berfungsi untuk menilai sejauh mana hubungan antara satu item dengan item lainnya, yang memperlihatkan seberapa besar peluang konsumen untuk membeli item B setelah membeli item A, dibandingkan dengan probabilitas pembelian item B secara independen [2][18]. Formula untuk menghitung nilai *lift* adalah:

$$Lift(A \rightarrow B) = \frac{Confidence(A \rightarrow B)}{Support} \quad (3)$$

4. Hasil dan Pembahasan

Bagian ini menyajikan hasil dari pengujian perbandingan antara algoritma Apriori dan FP-Growth, yang meliputi efisiensi waktu eksekusi, kuantitas aturan asosiasi, serta analisis pola pembelian yang dihasilkan. Semua pengujian dilakukan dengan menggunakan parameter yang sama, yaitu *minimum support* sebesar 0,01 dan *minimum confidence* sebesar 0,3.

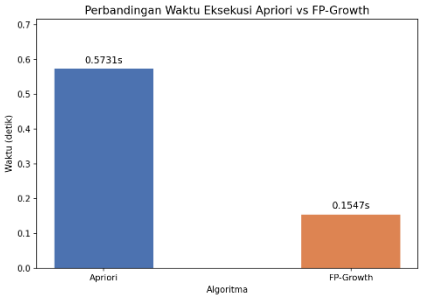
4.1 Analisis Waktu Eksekusi

Berdasarkan eksperimen yang dilakukan, diperoleh data mengenai perbandingan durasi komputasi yang signifikan antara algoritma Apriori dan FP-Growth. Perbandingan detailnya tersaji pada Tabel 3.

Tabel 3. Perbandingan Waktu Eksekusi

Algoritma	Waktu Eksekusi (Detik)
Apriori	0,5731
FP-Growth	0,1547

Data yang terlihat pada Tabel 3 menampilkan bahwa algoritma FP-Growth memiliki kecepatan pemrosesan yang cukup jauh lebih tinggi dibandingkan dengan algoritma Apriori. FP-Growth dapat menyelesaikan proses dalam waktu 0,1547 detik, sedangkan Apriori membutuhkan waktu 0,5731 detik. Keunggulan dari FP-Growth ini disebabkan oleh mekanisme yang tidak memerlukan pembuatan kandidat secara berulang maupun pemindaian basis data secara langsung. Visualisasi perbandingan waktu eksekusi dapat dilihat pada Gambar 2.



Gambar 2. Grafik Perbandingan Waktu Eksekusi

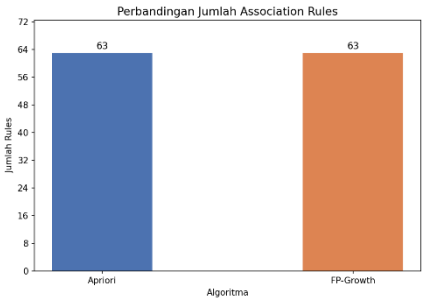
4.2 Hasil Pengujian Aturan Asosiasi

Selain aspek kecepatan, penelitian ini juga mengevaluasi jumlah aturan asosiasi (*rules*) yang dihasilkan oleh kedua algoritma. Hasil perbandingan jumlah aturan disajikan dalam Tabel 4.

Tabel 4. Perbandingan Jumlah Aturan

Algoritma	Jumlah Aturan (*Rules*)
Apriori	63
FP-Growth	63

Penelitian menunjukkan bahwa kedua algoritma tersebut menciptakan jumlah aturan identik, dengan total 63 aturan. Penemuan ini menegaskan bahwa metode komputasinya berbeda, validitas dan kualitas pola yang dihasilkan tetap konsisten. Perbandingan jumlah aturan tersebut divisualisasikan pada Gambar 3.



Gambar 3. Grafik Perbandingan Jumlah Aturan Asosiasi

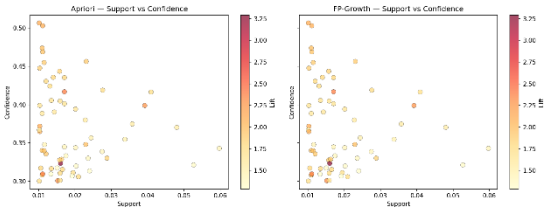
4.3 Analisis Pola Asosiasi Terkkuat

Fase ini bertujuan mengidentifikasi aturan asosiasi yang memiliki nilai *lift rasio* tertinggi untuk menentukan hubungan produk yang paling signifikan. Berikut adalah lima pola pembelian paling kuat berhasil teridentifikasi.

Tabel 5. Top Lima Association Rules Terkuat

Antecedents	*Consequents*	*Support*	*Confidence*	*Lift*
Herb & Pepper	Ground Beef	0.0160	0.3235	3.2920
Mineral Water, Olive Oil	Spaghetti	0.0103	0.3720	2.1365
Red Wine	Spaghetti	0.0103	0.3649	2.0960
Olive Oil	Spaghetti	0.0229	0.3482	1.9998
Soup	Milk	0.0152	0.3008	2.3212

Berdasarkan Tabel 5, kombinasi *Herb* dan *Paper* dengan *Ground Beefi* menunjukkan hubungan paling signifikan dengan nilai *lifti* mencapai 3,29. Ini berarti bahwa konsumen yang membeli bumbu tersebut cenderung 3,29 kali lebih tinggi untuk membeli daging cincang dibandingkan pembelian secara acak. Di samping itu, produk *Spaghetti* menunjukkan hubungan kuat dengan *Olive Oil* dan *Red Wine*, yang mencerminkan pola konsumsi yang teratur pada segmen makanan tertentu.



Gambar 4. Grafik Hubungan Support dan Confidence

Berdasarkan Gambar 4, distribusi titik data antara algoritma Apriori dan FP-Growth menunjukkan pola

yang serupa. Hal ini memperkuat kesimpulan bahwa kedua metode memberikan *output* yang sama valid, namun berbeda secara fundamental dalam efisiensi waktu pemrosesan.

4.4 Pembahasan

Berdasarkan hasil eksperimen yang telah dipaparkan, terdapat beberapa poin penting yang memerlukan analisis lebih lanjut. Keunggulan kecepatan FP-Growth, yang 3,7 kali lebih cepat daripada Apriori, menunjukkan bahwa efisiensi struktur data *FP-Treei* sangat signifikan dalam mereduksi beban kerja prosesor. Hal ini sejalan dengan teori bahwa menghilangkah tahap *candidate generation* pada FP-Growth dapat secara signifikan memangkas waktu komputasi, terutama pada dataset dengan tingkat *sparsity* yang tinggi seperti *Market Basket Optimisation*. Selain itu, temuan bahwa kedua algoritma menghasilkan 63 aturan yang identik menegaskan bahwa perbedaan dalam prosedur teknis tidak mengubah esensi temuan asosiasi. Konsistensi ini memberikan fleksibilitas bagi pengembang sistem untuk memilih FP-Growth demi efisiensi sambil tetap mempertahankan akurasi pola. Secara strategis, asosiasi antara *Herb* dan *Papper* dengan *Ground Beef*, memiliki nilai *lift* sebesar 3,29 mempresentasikan perilaku pola belanja konsumen yang nyata. Manajer ritel dapat menerapkan strategi *cross-selling* dengan menempatkan produk-produk ini berdampingan atau merancang promosi paket untuk secara efektif meningkatkan volume penjualan.

5. Kesimpulan

5.1 Simpulan

Berdasarkan pengujian dan analisis perbandingan kinerja yang telah dilasksanakan, dapat disimpulkan bahwa algoritma FP-Growth jauh lebih efisien dalam hal komputasi dibandingkan dengan algoritma Apriori. Kelebihan ini terlihat dari waktu eksekusi FP-Growth yang hanya memerlukan 0,1547 detik, yang berarti sekitar 3,7 kali lebih cepat dibandingkan Apriori yang membutuhkan 0,5731 detik untuk memproses dataset yang sama. Perbedaan signifikan ini terjadi karena FP-Growth menggunakan struktur data *FP-Tree* yang memampatkan informasi tanpa perlu membangkitkan kandidat *itemset* secara berulang. Meskipun terdapat perbedaan besar dalam kecepatan, kedua algoritma ini menghasilkan *output* yang konsisten dengan jumlah aturan asosiasi yang identik, yaitu sebanyak 63 aturan. Hal ini menunjukkan bahwa kualitas dan keakuratan pola pembelian yang ditemukan, seperti hubungan kuat antara *Herb and Pepper* dengan *Ground Beef*, tetap akurat pada kedua metode tersebut. Dengan demikian, FP-Growth menjadi pilihan yang lebih direkomendasikan untuk analisis Market Basket Analysis pada data dalam skala besar guna mengoptimalkan penggunaan sumber daya komputasi.

5.2 Saran

Untuk pengembangan penelitian di masa mendatang, ada beberapa aspek yang dapat dieksplorasi lebih lanjut guna memperkaya literatur di bidang *data mining*. Disarankan agar pengujian selanjutnya dilakukan pada *dataset* yang jauh lebih besar guna mengevaluasi batas penggunaan memori dan waktu eksekusi secara lebih mendalam pada kondisi beban kerja yang ekstrem. Selain itu, penelitian berikutnya dapat melakukan variasi parameter *minimum support* dan *minumum confidence* secara lebih dinamis untuk memetakan bagaimana perubahan ambang batas tersebut memengaruhi kompleksitas komputasi masing-masing algoritma. Studi ini juga dapat diperluas dengan menyertakan perbandingan dengan algoritma lain seperti *Eclat* atau *Princer-Search* untuk mendapatkan gambaran yang lebih menyeluruh mengenai metode penambangan aturan asosiasi yang paling efektif untuk sektor ritel. Terakhir, mengintegrasikan hasil pola asosiasi ke dalam sistem rekomendasi berbasis *web* atau aplikasi *mobile* dapat menjadi langkah praktis untuk menguji efektivitas strategi *cross-selling* secara langsung di lingkungan operasional binis.

Daftar Rujukan

[1] V. Dixit, D. Hebri, and M. Wagh, “Market Basket Analysis for Product Recommendation: Trends, Techniques, And Applications,” *IJRTTE Int. J. Recent Trends Technol. Eng.*, vol. 4, no. 3, pp. 1–7, 2025, [Online]. Available: https://ijrtte.com/

[2] E. W. Pujiharto, K. Kusrini, and A. Nasiri, “Analisis Perbandingan Kinerja Algoritma Apriori, FP-Growth dan Eclat dalam menemukan Pola Frekuensi pada Dataset INA-CBG’S,” *CogITo Smart J.*, vol. 9, no. 2, pp. 340–354, Dec. 2023, doi: 10.31154/cogito.v9i2.547.340-354.

[3] D. Rachmawati, Y. Cahyana, E. E. Awal, and S. Faisal, “Perbandingan Algoritma Apriori dan Algoritma FP-Growth dalam Menentukan Pola Penjualan Pupuk,” *J. Resist. (Rekayasa Sist. Komputer)*, vol. 7, no. 1, pp. 21–31, Apr. 2024, doi: 10.31598/jurnalresistor.v7i1.1527.

[4] Stanley, “Penerapan Data Mining Menggunakan Algoritma FP-Growth Pada Data Penjualan PT CML BATAMINDO,” *J. Ilm. Bin. STMIK Bina Nusant. Jaya Lubuklinggau*, vol. 7, no. 2, pp. 142–148, Nov. 2025, doi: 10.52303/jb.v7i2.165.

[5] R. Dian Widyarini, A. Suharso, and A. Solehudin, “ASSOCIATION RULE PENGOLAHAN DATA TRANSAKSI TOKO BUNGA MENGGUNAKAN ALGORITMA APRIORI DAN FP-GROWTH UNTUK

MENENTUKAN PROMOSI PAKET BUNGA," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 3, pp. 1461–1466, Oct. 2023, doi: 10.36040/jati.v7i3.7037.

[6] N. M. Meyzia Sabrina Yunika Putri, I. N. Yudi Anggara Wijaya, and M. Irma Dwiputranti, "ANALISIS POLA PEMBELIAN PELANGGAN DENGAN TEKNIK MARKET BASKET ANALYSIS (MBA) BERBASIS KNOWLEDGE DISCOVERY PADA DATA TRANSAKSI PENJUALAN TOKO BALI AMENITIES," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 10, no. 2, pp. 2917–2924, Mar. 2026, doi: 10.36040/jati.v10i2.17834.

[7] S. Wijayanti, M. Yosep, and T. Sulistyono, "ASSOCIATION RULE MINING PADA POLA PEMBELIAN FURNITURE ONLINE STUDI KASUS DATASET SPARSE TAHUN 2025," vol. 11, no. 1, pp. 1934–1946, 2026.

[8] C. Tri and M. Ilham, "Perbandingan Kinerja Algoritma Apriori dan FP- Growth dalam Analisis Pola Pembelian Produk pada Timmy Store," vol. 10, no. 2, pp. 134–138, 2025.

[9] A. Anggrawan, M. Mayadi, and C. Satria, "Menentukan Akurasi Tata Letak Barang dengan Menggunakan Algoritma Apriori dan Algoritma FP-Growth," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 21, no. 1, pp. 125–138, Nov. 2021, doi: 10.30812/matrik.v21i1.1260.

[10] F. Syah Zikri and M. Ikhsan, "The Comparison Between The Apriori Algorithm And The FP-Growth Algorithm In Determining Frequent Pattern," *INOVTEK Polbeng - Seri Inform.*, vol. 10, no. 2, pp. 615–625, Apr. 2025, doi: 10.35314/s1yanj03.

[11] M. Arifin, F. Helmi, and Iddrus, "Analisis Perbandingan Algoritma Asosiasi Data Mining Pada Minimarket Adi Poday Dengan Google Collab," *J. Algoritm.*, vol. 22, no. 1, pp. 103–114, May 2025, doi: 10.33364/algoritma/v.22-1.2177.

[12] Mitha Rosadi and Muhammad Siddik Hasibuan, "Comparison of Apriori and FP-Growth Algorithms in Analyzing Association Rules," *PIKSEL Penelit. Ilmu Komput. Sist. Embed. Log.*, vol. 12, no. 2, pp. 399–408, Sep. 2024, doi: 10.33558/piksel.v12i2.9965.

[13] I. F. Rahman and D. Riana, "Market Basket Analysis untuk Penjualan Retail: Perbandingan Akurasi Algoritma Apriori dan FP-Growth Berbasis CRISP-DM," *J. Algoritm.*, vol. 22, no. 1, pp. 468–479, May 2025, doi: 10.33364/algoritma/v.22-1.2303.

[14] kaggle, "Market_Basket_Optimisation." Accessed: Apr. 02, 2026. [Online]. Available: https://www.kaggle.com/datasets/rupakroy/market-basket-optimization/data?select=Market_Basket_Optimisation.csv

[15] K. M. H. Muhimmatul Arofah, Mohammad Idhom, "Analisis perbandingan algoritma apriori dan fp- growth dalam menentukan pola pembelian konsumen toko bangunan," vol. 9, no. 1, pp. 90–101, 2026.

[16] A. Nur Rahmi and Yosaphat Ananda 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, May 2021, doi: 10.24076/infosjournal.2021v4i1.561.

[17] Yusuf Husain, Enny Dwi Oktaviyani, and Sherly Christina, "Analisis Perbandingan Algoritma Apriori, FP-Growth, Dan Eclat dalam Menemukan Pola Pembelian Konsumen," *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, vol. 3, no. 2, pp. 231–243, Dec. 2023, doi: 10.24002/konstelasi.v3i2.7007.

[18] A. P. Ritonga, S. Z. Harahap, and M. Masrizal, "Comparative Analysis of Incoming Goods Patterns Using FP-Growth and Apriori Algorithms: A Case Study in Retail," *J. Comput. Networks, Archit. High Perform. Comput.*, vol. 7, no. 3, pp. 1007–1020, Aug. 2025, doi: 10.47709/cnahpc.v7i3.6776.