

Analisis Association Rule Menggunakan FP-Growth Pada Data Penjualan Ritel

Jenniva Retno Nuryuansyah^{1*}, Muhammad Noviyanto², Rizal Diaz Reihan Saputra³, Haffiant Resditya Akbar⁴,

¹Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa Surakarta
^{1*}230103064@mhs.udb.ac.id (penulis
korespondensi)

² Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa Surakarta
²230103070@mhs.udb.ac.id

³ Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa Surakarta
³230103076@mhs.udb.ac.id

⁴ Teknik Informatika/Illmu Komputer
Universitas Duta Bangsa Surakarta
⁴230103062@mhs.udb.ac.id

Abstrak— Penelitian ini bertujuan menerapkan algoritma Frequent Pattern Growth (FP-Growth) untuk menganalisis association rule pada data transaksi penjualan ritel guna menemukan pola pembelian produk yang sering terjadi secara bersamaan (market basket analysis). Penelitian menggunakan metodologi Cross-Industry Standard Process for Data Mining (CRISP-DM) yang terdiri dari tahapan Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, dan Deployment. Dataset diproses dengan menghapus data duplikat berdasarkan kombinasi *order_id* dan *product_name*, kemudian diubah ke dalam bentuk transaksi biner menggunakan *TransactionEncoder*. Algoritma FP-Growth diimplementasikan menggunakan Python dan pustaka *mlxtend*, serta dikembangkan dalam sistem Market Basket Analysis System (MBAS) berbasis FastAPI. Hasil penelitian menunjukkan bahwa algoritma FP-Growth berhasil menghasilkan aturan asosiasi yang valid untuk mendukung strategi bisnis ritel. Kombinasi produk Juice–Shirt memiliki nilai lift ratio tertinggi sebesar 1,93, yang menunjukkan adanya hubungan asosiasi yang kuat antara kedua produk. Hasil analisis dapat dimanfaatkan sebagai dasar penyusunan strategi *product bundling*, optimasi tata letak produk, dan promosi silang (*cross-selling*) pada bisnis ritel.

Kata kunci— association rule, FP-Growth, data mining, penjualan ritel, market basket analysis.

Abstract— This study aims to apply the Frequent Pattern Growth (FP-Growth) algorithm to analyze association rules within retail sales transaction data in order to identify product purchasing patterns that frequently occur together (market basket analysis). The research employs the Cross-Industry Standard Process for Data Mining (CRISP-DM) methodology, comprising the stages of Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, and Deployment. The dataset was preprocessed by removing duplicate entries based on the combination of 'order_id' and 'product_name', and subsequently converted into a binary transaction format using 'TransactionEncoder'. The FP-Growth algorithm was implemented using Python and the 'mlxtend' library, and integrated into a Market Basket Analysis System (MBAS) built with FastAPI. The results demonstrate that the FP-Growth algorithm successfully generated valid association rules to support retail business strategies. The "Juice–Shirt" product combination yielded the highest lift ratio of 1.93, indicating a strong association between the two products. These findings can serve as a basis for formulating product bundling strategies, optimizing product layouts, and implementing cross-selling initiatives in retail businesses.

Keywords— association rule, FP-Growth, data mining, retail sales, market basket analysis.

I. PENDAHULUAN

Perkembangan teknologi informasi dan pertumbuhan bisnis ritel telah menghasilkan data transaksi penjualan dalam volume yang sangat besar setiap harinya. Apabila tidak dianalisis dengan tepat, data tersebut hanya menjadi catatan administratif tanpa memberikan nilai tambah bagi pengambilan keputusan bisnis. Padahal, di dalam data transaksi tersebut tersimpan pola perilaku pembelian konsumen yang dapat

dimanfaatkan oleh peritel untuk meningkatkan efisiensi operasional, mengatur tata letak produk, merancang strategi bundling, maupun meningkatkan kepuasan pelanggan [1].

Salah satu pendekatan data mining yang umum digunakan untuk menggali pola keterkaitan antar item dalam data transaksi adalah association rule mining, yang sering diterapkan dalam konteks Market Basket Analysis (MBA). Melalui MBA, dapat diketahui produk-produk apa saja yang

cenderung dibeli secara bersamaan oleh konsumen [2]. Untuk membentuk aturan asosiasi tersebut, dibutuhkan algoritma yang efisien dalam menambang frequent itemset dari kumpulan data transaksi yang besar.

Algoritma Apriori merupakan salah satu algoritma association rule yang populer, namun memiliki kelemahan berupa proses pembentukan kandidat itemset yang berulang sehingga kurang efisien pada dataset berskala besar [3]. Sebagai alternatif, algoritma Frequent Pattern Growth (FP-Growth) dikembangkan untuk mengatasi kelemahan tersebut dengan memanfaatkan struktur data FP-Tree, sehingga proses pencarian frequent itemset dapat dilakukan tanpa pembentukan kandidat secara eksplisit dan hanya membutuhkan dua kali pemindaian (scan) terhadap basis data [4]. Beberapa penelitian terdahulu telah membuktikan bahwa algoritma FP-Growth mampu menghasilkan aturan asosiasi yang valid pada berbagai jenis data penjualan retail, mulaidari toko sembako, toko retail kesehatan, kafe dan restoran [5], produk elektronik [6], retail produk fashion [7], hingga UMKM roti dan bakery [8].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membangun dan menganalisis penerapan FP-Growth pada data penjualan retail dalam bentuk Market Basket Analysis System (MBAS). Sistem dikembangkan untuk dapat menerima dataset penjualan, melakukan praproses data, menjalankan analisis FP-Growth dengan parameter support dan confidence yang dapat disesuaikan, serta menampilkan aturan asosiasi terbaik yang dapat dimanfaatkan sebagai dasar pengambilan keputusan bisnis retail.

II. METODOLOGI PENELITIAN

A. Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan, yaitu analisis kebutuhan sistem, persiapan dan proses dataset, implementasi algoritma FP-Growth, serta pengembangan sistem. Tahapan-tahapan tersebut dilakukan untuk memperoleh association rules yang mampu menggambarkan pola pembelian konsumen

berdasarkan data transaksi penjualan retail. Metode ini juga diterapkan dalam penelitian analisis transaksi yang menggunakan algoritma FP-Growth pada penelitian [9]. Analisis kebutuhan sistem dilakukan untuk mengidentifikasi fungsi yang diperlukan dalam menganalisis data penjualan ritel. Sistem ini dirancang untuk mendukung langkah-langkah unggah dataset, pemrosesan data, pembentukan itemset yang sering muncul, pembuatan association rules dan visualisasi hasil analisis. Kebutuhan ini disusun berdasarkan proses analisis transaksi yang digunakan dalam penelitian [10].

B. Pengembangan Sistem

Penelitian ini menggunakan metodologi Cross-Industry Standard Process for Data Mining (CRISP-DM) sebagai kerangka kerja dalam proses pengolahan data hingga implementasi sistem. CRISP-DM terdiri atas enam tahapan, yaitu Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, dan Deployment. Setiap tahapan dijelaskan sebagai berikut [10].

1. Business Understanding

Tahap *Business Understanding* bertujuan untuk mengidentifikasi permasalahan bisnis dan tujuan penelitian. Permasalahan yang diangkat adalah belum diketahui pola pembelian produk yang sering terjadi secara bersamaan pada data transaksi penjualan. Oleh karena itu, penelitian ini bertujuan menerapkan algoritma FP-Growth untuk menghasilkan aturan asosiasi (*association rule*) yang dapat dimanfaatkan sebagai dasar penyusunan strategi *cross-selling*, *product bundling*, dan penataan produk pada toko ritel.

2. Data Understanding

Tahap *Data Understanding* dilakukan dengan mengeksplorasi dataset transaksi penjualan untuk mengetahui karakteristik data yang digunakan. Proses ini meliputi identifikasi jumlah transaksi, jumlah produk, tipe data,

serta pemeriksaan kualitas data seperti data kosong, data duplikat, dan distribusi item. Hasil tahap ini menjadi dasar dalam menentukan proses persiapan data sebelum dilakukan pemodelan.

3. Data Preparation

Tahap *Data Preparation* dilakukan dengan membersihkan data transaksi melalui penghapusan data duplikat berdasarkan kombinasi *order_id* dan *product_name*. Selanjutnya data ditransformasikan ke dalam format transaksi (*basket transaction*) dan diubah menjadi matriks biner menggunakan *TransactionEncoder* sehingga setiap produk direpresentasikan dalam bentuk nilai boolean sesuai kebutuhan algoritma FP-Growth.

4. Modeling

Tahap *Modeling* dilakukan dengan menerapkan algoritma FP-Growth menggunakan pustaka *mlxtend* pada Python untuk memperoleh *frequent itemset*. Selanjutnya dibentuk *association rule* berdasarkan parameter minimum support dan minimum confidence yang telah ditentukan. Setiap aturan kemudian dihitung nilai support, confidence, dan lift ratio untuk mengetahui kekuatan hubungan antarproduk.

5. Evaluation

Tahap *Evaluation* dilakukan dengan mengevaluasi aturan asosiasi yang dihasilkan menggunakan nilai support, confidence, dan lift ratio. Aturan dengan nilai *lift ratio* lebih dari satu menunjukkan adanya hubungan positif antarproduk, sedangkan aturan dengan nilai *lift ratio* tertinggi dipilih sebagai aturan asosiasi yang paling kuat untuk dijadikan rekomendasi strategi penjualan.

6. Deployment

Tahap *Deployment* dilakukan dengan mengimplementasikan hasil analisis ke

dalam Market Basket Analysis System (MBAS) berbasis FastAPI. Sistem memungkinkan pengguna mengunggah data transaksi, menjalankan proses analisis FP-Growth secara otomatis, serta menampilkan *frequent itemset*, *association rule*, dan rekomendasi produk yang dapat dimanfaatkan dalam pengambilan keputusan bisnis.

III. HASIL DAN PEMBAHASAN


Bagian ini menyajikan hasil penerapan algoritma Frequent Pattern Growth (FP-Growth) pada data transaksi penjualan ritel beserta pembahasan mendalam mengenai pola asosiasi yang terbentuk. Pembahasan difokuskan pada interpretasi temuan pola keranjang belanja konsumen dan implikasi strategisnya terhadap operasional bisnis ritel, bukan sekadar pengulangan data mentah. Proses analisis mengikuti kerangka Cross-Industry Standard Process for Data Mining (CRISP-DM) yang terdiri dari enam tahapan utama, yaitu pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan implementasi [11].

G. Implementasi Sistem Market Basket Analysis (MBAS)

Sistem MBAS dikembangkan dengan arsitektur client-server menggunakan backend FastAPI dan frontend ReactJS. Sistem ini dirancang untuk memproses data transaksi secara interaktif dan menghasilkan aturan asosiasi menggunakan algoritma FP-Growth.

1. Flowchart Sistem Analisis Association Rule (FP-Growth)

Tahapan analisis *association rule* menggunakan algoritma FP-Growth pada penelitian ini digambarkan melalui flowchart sistem yang disajikan pada Gambar 1. Flowchart ini merepresentasikan alur proses pengolahan data transaksi penjualan ritel mulai dari input dataset hingga menghasilkan aturan asosiasi dan rekomendasi strategi bisnis.



Gambar 24. Flowchart Sistem Analisis Association Rule (FP-Growth)

Berdasarkan Gambar 1, proses analisis dimulai dengan input dataset penjualan retail yang kemudian melalui tahap preprocessing untuk membersihkan data dan menghapus transaksi duplikat. Setelah data bersih, dilakukan transformasi ke format transaksi biner yang sesuai dengan kebutuhan algoritma FP-Growth. Tahap selanjutnya adalah penentuan parameter minimum support dan minimum confidence yang digunakan sebagai ambang batas dalam pembentukan aturan asosiasi.

Algoritma FP-Growth kemudian membangun struktur FP-Tree untuk mencari frequent itemset tanpa melalui proses pembentukan kandidat berulang seperti pada algoritma Apriori [12]. Frequent itemset yang terbentuk selanjutnya digunakan untuk membentuk aturan asosiasi (association rules) dengan menghitung nilai support, confidence, dan lift ratio. Aturan yang dihasilkan kemudian dievaluasi apakah memenuhi threshold minimum support dan minimum confidence yang telah ditentukan. Apabila tidak memenuhi, maka aturan tersebut ditolak dan

sistem akan mengembalikan proses untuk mencari itemset lainnya. Apabila memenuhi threshold, maka aturan asosiasi yang valid akan ditampilkan dalam bentuk visualisasi dan rekomendasi strategi bisnis [13].

2. Pemahaman Bisnis (Business Understanding)

Tahap ini bertujuan mengidentifikasi kebutuhan bisnis dari implementasi Market Basket Analysis. Permasalahan utama yang ditemukan adalah belum optimalnya pemanfaatan data transaksi penjualan sebagai dasar pengambilan keputusan strategis. Data transaksi hanya tersimpan sebagai arsip administratif tanpa dilakukan analisis mendalam untuk menemukan pola pembelian konsumen. Tujuan bisnis dari penelitian ini adalah: (1) mengidentifikasi pola keterkaitan antar produk yang sering dibeli secara bersamaan, (2) menyusun strategi promosi dan bundling berbasis data aktual, serta (3) mengoptimalkan tata letak produk dan pengelolaan stok barang [13].

3. Pemahaman Data (Data Understanding)

Dataset yang digunakan merupakan data transaksi penjualan ritel dengan total 1.991 transaksi unik, terdiri dari 9.701 baris record, serta 68 jenis produk unik yang terbagi dalam 17 kategori. Struktur data utama mencakup atribut `order_id` dan `product name` yang menjadi fokus analisis. Berdasarkan eksplorasi awal, ditemukan bahwa produk kebutuhan sehari-hari seperti Dishwashing Liquid, Chips, dan Energy Drink memiliki frekuensi kemunculan tertinggi. Hal ini sejalan dengan temuan [12] bahwa produk konsumsi harian cenderung memiliki frekuensi pembelian yang lebih tinggi dibandingkan produk lainnya.


4. Persiapan Data (Data Preparation)

Tahap persiapan data merupakan proses krusial untuk memastikan data berada dalam kondisi bersih dan sesuai dengan format algoritma [11]. Proses ini mencakup:

- a) **Pembersihan Data (Data Cleaning):** Dilakukan dengan menghilangkan data duplikat berdasarkan kombinasi `order_id` dan `product name`. Proses ini penting untuk menghindari bias

dalam pembentukan pola asosiasi [12]. Hasilnya menghasilkan dataset `retail_cleaned.csv` yang siap diproses.


- b) **Pembersihan Data (Data Cleaning):** Dilakukan dengan menghilangkan data duplikat berdasarkan kombinasi `order_id` dan `product_name`. Proses ini penting untuk menghindari bias dalam pembentukan pola asosiasi [12]. Hasilnya menghasilkan dataset `retail_cleaned.csv` yang siap diproses.



Gambar 25. Halaman Preprocessing Data Mentah dan Hasil Format Transaksi

itemset yang representatif tanpa menghasilkan aturan yang terlalu sedikit [15].

Sementara itu, minimum confidence sebesar 5% digunakan agar aturan asosiasi yang dihasilkan memiliki tingkat kepercayaan minimum yang masih layak untuk dianalisis. Nilai tersebut dipilih karena mampu menghasilkan jumlah aturan yang cukup untuk dianalisis lebih lanjut, sedangkan kualitas hubungan antar produk tetap dievaluasi menggunakan nilai lift ratio.



Gambar 26. Tampilan Halaman Pengaturan Parameter Analisis FP-Growth

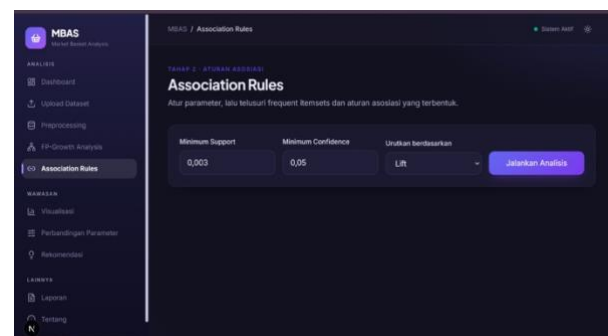
5. Pemodelan (Modeling) dengan FP-Growth

Pemodelan dilakukan menggunakan algoritma FP-Growth yang diimplementasikan dengan bahasa Python dan pustaka `mlxtend`. Pemilihan FP-Growth didasarkan pada keunggulannya dalam efisiensi pemrosesan data transaksi berukuran besar tanpa proses pembentukan kandidat berulang seperti pada Apriori [12]. Penelitian [14] juga membuktikan bahwa FP-Growth lebih cepat dan menggunakan memori lebih sedikit dibandingkan Apriori.

Parameter yang digunakan dalam pemodelan adalah:

- Minimum support: 0,003 (0,3%)
- Minimum confidence: 0,05 (5%)

Nilai minimum support 0,3% dipilih karena dataset transaksi memiliki banyak variasi produk sehingga sebagian besar kombinasi produk muncul dengan frekuensi yang relatif rendah. Penggunaan nilai support yang lebih besar berpotensi menghilangkan pola pembelian yang sebenarnya masih relevan. Oleh karena itu, nilai 0,3% dipilih agar algoritma tetap mampu menemukan *frequent*



Gambar 27. Tampilan Halaman Penelusuran Aturan Asosiasi

6. Evaluasi (Evaluation)

Hasil evaluasi dilakukan terhadap aturan asosiasi yang dihasilkan oleh algoritma FP-Growth menggunakan tiga metrik, yaitu *support*, *confidence*, dan *lift ratio*. Nilai *support* digunakan untuk mengetahui tingkat kemunculan suatu kombinasi produk dalam seluruh transaksi, sedangkan *confidence* menunjukkan peluang suatu produk dibeli ketika produk lain telah dibeli. Selanjutnya, *lift ratio* digunakan untuk mengukur kekuatan hubungan antar produk dibandingkan dengan kondisi apabila kedua produk terjadi secara acak.

Berdasarkan hasil pengujian, diperoleh beberapa aturan asosiasi yang memenuhi nilai minimum *support* sebesar 0,3% dan *minimum confidence* sebesar 5%. Dari seluruh aturan yang dihasilkan, kombinasi produk Juice → Shirt memiliki nilai lift ratio tertinggi sebesar 1,93. Nilai tersebut menunjukkan bahwa pelanggan yang membeli produk Juice memiliki kemungkinan sekitar 1,93 kali lebih besar untuk membeli Shirt dibandingkan apabila kedua produk dibeli secara independen. Karena nilai *lift ratio* lebih besar dari 1, hubungan antara kedua produk termasuk asosiasi positif sehingga kombinasi tersebut layak dijadikan rekomendasi dalam strategi *product bundling*, *cross-selling*, maupun penataan produk pada toko.

1. Produk dengan Frekuensi Tertinggi

Analisis awal dilakukan untuk mengidentifikasi produk-produk dengan frekuensi kemunculan tertinggi. Hasilnya disajikan pada Tabel 3.1 berikut.

Tabel 3.1. Produk dengan Frekuensi Kemunculan Tertinggi


No	Nama Produk	Jumlah Muncul	Presentase(%)
1	Dishwashing Liquid	163	8,19
2	Chips	161	8,09
3	Energy Drink	158	7,94
4	Soda	158	7,94
5	Cake	158	7,94
6	Tissue	157	7,89
7	Prawns	157	7,89
8	Phone Cover	156	7,84
9	Milk	155	7,78
10	Spinach	154	7,73

Berdasarkan Tabel 3.1, produk pembersih rumah tangga (Dishwashing Liquid), makanan ringan (Chips, Cake), serta minuman penyegar (Energy Drink, Soda) menempati posisi lima teratas. Temuan ini mengonfirmasi hasil penelitian Putra dkk. (2024) yang menyatakan bahwa produk kebutuhan harian memiliki tingkat permintaan stabil dan cenderung dibeli secara berulang oleh konsumen.

2. Distribusi Kategori Produk

Analisis distribusi berdasarkan kategori menunjukkan bahwa produk makanan dan minuman mendominasi total transaksi. Hal

ini mengindikasikan bahwa konsumen ritel modern lebih sering membeli produk-produk konsumsi sehari-hari dibandingkan produk non-konsumsi, sehingga kategori ini menjadi prioritas utama dalam pengelolaan stok dan strategi promosi.



Gambar 28. Halaman Visualisasi Produk Terlaris dan Sepuluh Aturan dengan Lift Tertinggi

H. Analisis Frequent Itemset dengan FP-Growth

1. Pembentukan FP-Tree dan Ekstraksi Pola Frekuensi Tinggi

Algoritma FP-Growth membangun FP-Tree dengan mengurutkan item berdasarkan frekuensi tertinggi. Hasil pembentukan menunjukkan bahwa item seperti Dishwashing Liquid, Chips, dan Energy Drink menjadi node utama, mengindikasikan bahwa produk-produk tersebut sering menjadi item dasar yang dibeli bersama produk lain dalam satu transaksi [12].

Proses ekstraksi pola frekuensi tinggi menghasilkan beberapa kombinasi produk dengan nilai support signifikan, seperti disajikan pada Tabel 3.2.

Tabel 3.2. Hasil Frequent Itemset dengan FP-Growth

No	Itemset	Support	Jumlah Transaksi
1	Juice, Shirt	0,0075	15
2	Educational Book, Croissant	0,0080	16
3	Earphones, Detergent	0,0095	19
4	Juice, Shirt, Detergent	0,0060	12
5	Educational Book, Croissant, Coffee	0,0055	11

Kombinasi produk seperti Juice-Shirt dan Educational Book-Croissant menunjukkan adanya hubungan keterkaitan antar produk yang tidak terlihat secara kasat mata. Temuan ini sejalan dengan penelitian [12] yang menyatakan bahwa FP-Growth efektif mengungkap pola tersembunyi dalam dataset retail online.

I. Ekstraksi Aturan Asosiasi


1. Aturan Asosiasi dengan Nilai Lift Tertinggi

Dari hasil ekstraksi dengan minimum support 0,003 dan minimum confidence 0,05, diperoleh lima aturan asosiasi dengan nilai lift ratio tertinggi (Tabel 3.3).

Tabel 3.2. Hasil *Frequent Itemset* dengan FP-Growth

No	Itemset	Support	Jumlah Transaksi
1	Juice, Shirt	0,0075	15
2	Educational Book, Croissant	0,0080	16
3	Earphones, Detergent	0,0095	19
4	Juice, Shirt, Detergent	0,0060	12
5	Educational Book, Croissant, Coffee	0,0055	11

Kombinasi Juice dan Shirt memiliki nilai lift ratio tertinggi sebesar 1,93, yang berarti hubungan antara kedua produk tersebut sangat kuat dan tidak terjadi secara kebetulan. Nilai lift > 1 mengindikasikan adanya korelasi positif yang signifikan antara antecedent dan consequent [13]. Pola keterkaitan antara produk fashion (Shirt) dan produk konsumsi (Juice) ini mengonfirmasi temuan [15] bahwa konsumen cenderung membeli produk dari kategori berbeda dalam satu transaksi.



Gambar 29. Grafik Scatter Plot Distribusi Aturan Asosiasi (Support vs Confidence)

2. Perbandingan dengan Penelitian Sebelumnya

Hasil penelitian ini menunjukkan kemiripan dengan temuan penelitian sebelumnya :

- a) pada CanNgopi menemukan bahwa kombinasi produk snack, signature, dan non-coffee memiliki

nilai support 0,319 dan confidence 0,968, menunjukkan hubungan yang sangat kuat untuk strategi bundling paket pasta. [15]

- b) pada Warung Sidorukun menemukan tiga aturan asosiasi signifikan, yaitu Sampoerna → Sunlight (Support 38,71%, Confidence 75%), Gula Pasir → Mancis (Support 32,26%, Confidence 83,33%), dan Rinso → Bodrek (Support 19,35%, Confidence 75%). Aturan-aturan ini digunakan untuk menyusun produk pada rak tertentu. [13]
- c) membandingkan akurasi Apriori dan FP-Growth pada data penjualan seragam sekolah. Mereka menemukan bahwa Apriori memiliki akurasi lebih tinggi (63,19%) dibandingkan FP-Growth (2,92%) untuk dataset kecil (365 transaksi), namun FP-Growth unggul dalam efisiensi pemrosesan. [11]
- d) pada Maestro Jakarta Cafe & Space membuktikan bahwa FP-Growth lebih efisien dalam penggunaan memori (0,379 MB vs 13,783 MB pada Apriori) dan kecepatan pemrosesan (0,0317s vs 0,0589s) pada minimum support 1%, serta menghasilkan aturan identik dengan perbedaan hanya pada indeks kemunculan. [14]

Perbedaan nilai support dan confidence antar penelitian menunjukkan bahwa karakteristik data dan jenis produk mempengaruhi hasil aturan asosiasi. Namun secara umum, semua penelitian membuktikan bahwa FP-Growth mampu menghasilkan aturan asosiasi yang valid dan bermanfaat untuk strategi bisnis.

J. Implikasi Hasil Penelitian terhadap Strategi Bisnis

Temuan analisis memiliki beberapa implikasi strategis yang dapat diterapkan dalam pengelolaan bisnis ritel:

1. Strategi Bundling Produk: Berdasarkan aturan asosiasi Juice-Shirt (lift 1,93) dan Educational Book-Croissant (lift 1,89), pihak ritel dapat merancang paket bundling menarik. Produk dengan hubungan asosiasi kuat dapat dikemas dalam satu paket harga khusus untuk mendorong peningkatan volume penjualan [13].
2. Optimasi Tata Letak Produk: Pengetahuan tentang pola pembelian memungkinkan ritel menempatkan produk yang sering dibeli bersama pada lokasi berdekatan. Hal ini memudahkan konsumen dan mendorong pembelian impulsif [15].
3. Strategi Promosi Silang (Cross-Selling): Informasi pola asosiasi dapat dimanfaatkan untuk strategi cross-selling, di mana petugas penjualan atau sistem rekomendasi menawarkan produk pendamping yang memiliki hubungan kuat dengan produk yang sedang dibeli konsumen.
4. Pengelolaan Stok Barang: Dengan mengetahui kombinasi produk yang sering dibeli bersama, manajer gudang dapat membuat perencanaan stok lebih akurat dan menghindari kekurangan maupun kelebihan stok [11].
5. Efisiensi Operasional: [14] membuktikan bahwa FP-Growth lebih efisien dalam penggunaan memori dan kecepatan pemrosesan, sehingga sistem MBAS yang dikembangkan dapat diandalkan untuk analisis data transaksi berskala besar secara real-time.

IV. KESIMPULAN

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa penerapan algoritma FP-Growth pada data transaksi penjualan ritel berhasil mengidentifikasi pola asosiasi produk yang valid dan informatif. Kombinasi produk Juice-Shirt memiliki nilai lift ratio tertinggi sebesar 1,93, mengindikasikan hubungan keterkaitan yang kuat dan tidak terjadi secara kebetulan. Pola-pola asosiasi yang ditemukan dapat dimanfaatkan

sebagai dasar penyusunan strategi bisnis ritel, seperti perancangan paket penjualan (product bundling), optimasi tata letak produk (product placement), serta penerapan strategi promosi silang (cross-selling).

Sistem Market Basket Analysis System (MBAS) yang dikembangkan telah berhasil mengimplementasikan seluruh fungsionalitas yang diperlukan dalam analisis association rule dengan antarmuka yang intuitif dan informatif, sehingga memudahkan pengguna dalam melakukan eksplorasi data dan interpretasi hasil analisis. Dari sisi performa, algoritma FP-Growth terbukti efisien dalam memproses data transaksi berukuran besar karena mampu menemukan frequent itemset tanpa proses pembangkitan kandidat secara berulang, sehingga penggunaan memori dan waktu komputasi menjadi lebih optimal.

Temuan penelitian ini sejalan dengan berbagai penelitian sebelumnya yang menyatakan bahwa algoritma FP-Growth efektif digunakan dalam analisis association rule untuk mendukung pengambilan keputusan bisnis di sektor ritel [14], [13], [11], [15].

REFERENSI

- [1] F. Achmad, O. Nurdian, and Y. A. Wijaya, "ANALISA POLA TRANSAKSI PEMBELIAN KONSUMEN PADA TOKO RITEL KESEHATAN MENGGUNAKAN ALGORITMA FP-GROWTH," vol. 7, no. 1, pp. 168–175, 2023.
- [2] Y. S. Putra, R. Kurniawan, Y. A. Wijaya, T. Informatika, S. Informatika, and D. Mining, "PENERAPAN DATA MINING MENGGUNAKAN ALGORITMA FP-GROWTH PADA DATA PENJUALAN SEMBAKO," vol. 8, no. 1, pp. 561–567, 2024.
- [3] R. Dio, J. Hidayati, R. Arifin, D. A. Putera, and A. Agung, "Analisis Data Mining Pembelian dengan Association Rule Market Basket Analysis menggunakan algoritma FP-Growth," vol. XVII, no. 2, pp. 187–198, 2023.
- [4] M. N. Assidiq, A. Bahaiddin, C. D. Octaviani, N. Ummi, and A. S. Mariawati, "Journal of Systems Engineering and Management Market Basket Analysis dengan Metode Association Rule Menggunakan Algoritma FP- Growth untuk Mendukung Strategi Promosi Ritel Modern," vol. 5, no. 1, pp. 37–48, 2026.
- [5] I. D. Ayu, I. Saraswati, I. M. Agus, O. Gunawan, I. M. Agus, and W. Putra, "Analisis Keranjang Belanja pada Data Ritel Non- Toko menggunakan Algoritma FP-Growth," pp. 1692–1704, 2027.
- [6] R. Hamonangan, R. Narasati, and P. P. Marta, "ANALISIS POLA PEMBELIAN PARFUM MENGGUNAKAN METODE DATA MAINING ALGORITMA FP-GROWTH," vol. 3, no. 03, pp. 1–6, 2026.
- [7] J. T. Suryani, N. Rahaningsih, and R. D. Dana, "PENERAPAN ASOSIASI UNTUK MENGANALISA PENJUALAN BARANG MENGGUNAKAN ALGORITMA FP-GROWTH,"

- vol. 8, no. 1, pp. 3435–3440, 2024.
- [8] D. Pratama and E. Tohidi, “MARKET BASKET ANALYSIS PADA DATA PENJUALAN UMKM MENGGUNAKAN ALGORITMA FP-GROWTH,” vol. 8, no. 4, pp. 8197–8206, 2024.
- [9] M. Fathur, R. Junaedi, and U. Hayati, “ANALISIS POLA TRANSAKSI PEMBELIAN MAKANAN DAN MINUMAN,” vol. 8, no. 1, pp. 360–367, 2024.
- [10] M. Informatika and S. I. Cirebon, “PENERAPAN ALGORITMA FP-GROWTH DALAM ANALISIS POLA TRANSAKSI APPLICATION OF FP-GROWTH ALGORITHM IN TRANSACTION PATTERN ANALYSIS FOR OPTIMIZING TRANSACTION DATA MANAGEMENT IN LIA ’ S,” vol. 3, no. 1, 2024.
- [11] 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, 2025, doi: 10.33364/algoritma/v.22-1.2303.
- [12] Y. Ramdhani, “Analisis Algoritma Fp-Growth Dan Apriori Untuk Menemukan,” vol. 3, no. January, pp. 21–36, 2025.
- [13] B. Kesuma, I. Zufria, and I. Rusydi, “Implementasi Algoritma Apriori dan FP-Growth untuk Rekomendasi Produk Guna Meningkatkan Penjualan pada Toko (Studi Kasus : Warung Sidorukun),” 2025.
- [14] M. Raihan, “Analisis Perbandingan Algoritma Apriori dan FP-Growth untuk Menentukan Strategi Penjualan Pada Maestro Jakarta Cafe & Space Abstrak,” vol. 5, no. 3, pp. 3147–3157, 2024.
- [15] S. Valencia and W. T. Atmojo, “Analisis Pola Pembelian Konsumen Pada Data Penjualan Menggunakan Algoritma Apriori,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 5, pp. 10029–10034, 2024, doi: 10.36040/jati.v8i5.10953.