



E-ISSN 3032-601X & P-ISSN 3032-7105

Vol. 3, No. 1, 2026

# MISTER

**Journal of Multidisciplinary Inquiry in Science,  
Technology and Educational Research**

**Jurnal Penelitian Multidisiplin dalam Ilmu  
Pengetahuan, Teknologi dan Pendidikan**

**UNIVERSITAS SERAMBI MEKKAH  
KOTA BANDA ACEH**

[mister@serambimekkah.ac.id](mailto:mister@serambimekkah.ac.id)

Journal of Multidisciplinary Inquiry in Science Technology  
and Educational Research

# Journal of MISTER

Vol. 3, No. 1, 2026

Pages: 850–858

FP-Growth dalam Analisis Rekomendasi Barang Terkait

Nofal Azhar Safriansyah, Hasbi Firmansyah, Wahyu Asriani,  
Eko Budi Raharjo

Universitas Pancasakti Tegal

## Article in Journal of MISTER

Available at : <https://jurnal.serambimekkah.ac.id/index.php/mister/index>

DOI : <https://doi.org/10.32672/mister.v3i1.4012>

## How to Cite this Article

APA : Safriansyah, N. A., Hasbi Firmansyah, Wahyu Asriani, & Eko Budi Raharjo. (2025). FP-Growth dalam Analisis Rekomendasi Barang Terkait. Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research, 3(1), 850 – 858. <https://doi.org/10.32672/mister.v3i1.4012>

Others Visit : <https://jurnal.serambimekkah.ac.id/index.php/mister/index>

**MISTER: *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research*** is a scholarly journal dedicated to the exploration and dissemination of innovative ideas, trends and research on the various topics include, but not limited to functional areas of Science, Technology, Education, Humanities, Economy, Art, Health and Medicine, Environment and Sustainability or Law and Ethics.

**MISTER: *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research*** is an open-access journal, and users are permitted to read, download, copy, search, or link to the full text of articles or use them for other lawful purposes. Articles on Journal of MISTER have been previewed and authenticated by the Authors before sending for publication. The Journal, Chief Editor, and the editorial board are not entitled or liable to either justify or responsible for inaccurate and misleading data if any. It is the sole responsibility of the Author concerned.



ISSN 3032-7105

ISSN 3032-601X



## FP-Growth dalam Analisis Rekomendasi Barang Terkait

Nofal Azhar Safriansyah<sup>1</sup>, Hasbi Firmansyah<sup>2</sup>, Wahyu Asriani<sup>3</sup>, Eko Budi Raharjo<sup>4</sup>

Program Studi Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Pancasakti Tegal, Tegal, Indonesia<sup>1,2,3,4</sup>

\*Email: [novalazhar1910@gmail.com](mailto:novalazhar1910@gmail.com)<sup>1</sup>, [hasbifirmansyah@upstegal.ac.id](mailto:hasbifirmansyah@upstegal.ac.id)<sup>2</sup>, [asriyani1409@gmail.com](mailto:asriyani1409@gmail.com)<sup>3</sup>, [ekobudiraharjo@gmail.com](mailto:ekobudiraharjo@gmail.com)<sup>4</sup>

Diterima: 08-12-2025

| Disetujui: 18-12-2025

| Diterbitkan: 20-12-2025

### ABSTRACT

*Based on the implementation and analysis of the FP-Growth algorithm on retail transaction data, it can be concluded that this method is highly effective and efficient in discovering frequent item combinations within large-scale datasets through the FP-Tree structure, which compresses transaction records and enables pattern mining without generating candidate itemsets as required by the Apriori algorithm. This study involved several stages, including data preparation, preprocessing, FP-Tree construction, frequent itemset extraction, association rule generation, and evaluation. The experimental results show that FP-Growth successfully identified meaningful purchasing patterns, where the main frequent itemsets achieved support values ranging from 5% to 18%, indicating a significant level of occurrence in the transaction data. Furthermore, the generated association rules demonstrated confidence values between 70% and 92%, reflecting a high level of reliability in predicting the presence of related items when a particular item is purchased, while lift values greater than 1 confirmed positive correlations among item combinations. These results indicate that the discovered rules are both relevant and reliable for recommendation purposes. Overall, the findings highlight that FP-Growth is a powerful approach for uncovering hidden consumer purchasing behavior and can effectively support strategic decision-making in retail businesses, including product placement optimization, inventory management, cross-selling and up-selling strategies, promotional bundling, and the development of automated recommendation systems. In addition, this research provides opportunities for future work, such as applying the approach to larger datasets, integrating FP-Growth with machine learning techniques for adaptive recommendations, and implementing the method in real-time retail environments to enhance sales performance and customer satisfaction.*

**Keywords:** Association Rule, Data Mining, FP-Growth, Frequent Itemset, Product Recommendation.

### ABSTRAK

Berdasarkan implementasi dan analisis algoritma FP-Growth pada data transaksi retail, dapat disimpulkan bahwa metode ini efektif dan efisien dalam menemukan kombinasi item yang sering muncul secara bersamaan pada dataset berukuran besar melalui struktur FP-Tree yang mampu memampatkan data transaksi serta melakukan penambangan pola tanpa pembangkitan candidate itemsets seperti pada metode Apriori. Penelitian ini melalui tahapan persiapan data, preprocessing, konstruksi FP-Tree, ekstraksi frequent itemset, pembentukan association rule, serta evaluasi aturan. Hasil implementasi menunjukkan bahwa FP-Growth berhasil menghasilkan sejumlah pola pembelian yang bermakna, dimana frequent itemset utama memiliki nilai support antara 5% hingga 18%, menunjukkan tingkat

kemunculan yang signifikan dalam transaksi. Aturan asosiasi yang dihasilkan memiliki nilai confidence berkisar antara 70% hingga 92%, yang mengindikasikan tingkat keandalan yang tinggi dalam memprediksi kemunculan item lain ketika suatu item dibeli, serta nilai lift  $> 1$ , yang menandakan adanya hubungan positif antar item. Dengan demikian, aturan yang dihasilkan dinilai relevan dan andal untuk digunakan sebagai dasar rekomendasi produk. Temuan ini membuktikan bahwa algoritma FP-Growth mampu mengungkap pola perilaku pembelian konsumen yang tersembunyi dan berpotensi mendukung pengambilan keputusan strategis pada bisnis retail, seperti penempatan produk, manajemen inventori, strategi cross-selling, up-selling, dan bundling promosi, serta pengembangan sistem rekomendasi otomatis. Selain itu, penelitian ini juga membuka peluang pengembangan lebih lanjut, seperti penerapan pada dataset berskala lebih besar, integrasi dengan metode pembelajaran mesin untuk rekomendasi adaptif, serta implementasi secara real-time guna meningkatkan kinerja penjualan dan kepuasan pelanggan.

**.Katakunci:** Association Rule, Data Mining, FP-Growth, Frequent Itemset, Rekomendasi Produk

## PENDAHULUAN

Perkembangan teknologi informasi telah mendorong banyak organisasi menerapkan sistem analisis data untuk mendukung proses pengambilan keputusan terutama pada sektor retail [1]. Data transaksi penjualan yang terus meningkat menjadi tantangan karena sebagian besar data tersebut tersimpan tanpa dianalisis secara optimal [2]. Pemanfaatan teknik data mining menjadi solusi untuk menggali pola berharga dari data sehingga dapat menghasilkan informasi baru yang mendukung peningkatan strategi bisnis [3]. Salah satu teknik populer dalam data mining untuk menemukan pola keterkaitan antar item adalah Association Rule Mining [4], yang banyak digunakan dalam pengembangan sistem rekomendasi. Algoritma FP-Growth menjadi alternatif dari Apriori karena mampu menemukan frequent itemset tanpa proses pembangkitan kandidat sehingga lebih efisien dalam pemrosesan dataset besar [5]. FP-Growth memampatkan data transaksi menjadi struktur FP-Tree yang memungkinkan proses pencarian pola lebih cepat dan minim penggunaan memori [6]. Penelitian-penelitian sebelumnya menunjukkan bahwa FP-Growth efektif dalam menghasilkan rekomendasi produk berdasarkan asosiasi kebiasaan belanja pelanggan [7]. Penerapan metode ini terbukti dapat meningkatkan akurasi rekomendasi barang terkait dan mendukung strategi pemasaran seperti cross-selling maupun up-selling [8]. Namun, beberapa penelitian masih menyoroti tantangan pada optimasi performa ketika dataset sangat besar atau memiliki keragaman produk yang tinggi [9]. Oleh karena itu, penelitian ini berfokus pada implementasi dan analisis algoritma FP-Growth untuk rekomendasi barang terkait pada konteks transaksi retail sehingga mampu memberikan pemahaman mengenai efektivitas algoritma dalam mendukung keputusan bisnis berbasis data [10]. Harapannya penelitian ini dapat memberikan kontribusi dalam pengembangan sistem rekomendasi pada domain e-commerce dan minimarket dengan kualitas rekomendasi yang lebih relevan. Berkontribusi dalam klasifikasi tumor otak dan bagaimana struktur keputusan dibentuk oleh algoritma Decision Tree (Hidayatullah, 2024).

Rumusan masalah dalam penelitian ini adalah bagaimana algoritma Decision Tree yang diimplementasikan menggunakan RapidMiner dapat mengklasifikasikan citra tumor otak dengan memanfaatkan fitur statistik dan tekstur pada dataset Brain Tumor, serta fitur mana yang memiliki pengaruh terbesar dalam proses klasifikasi. Tujuan dari penelitian ini yaitu membangun model klasifikasi tumor otak menggunakan Decision Tree, mengevaluasi performa model tersebut, dan menganalisis kontribusi fitur-fitur yang digunakan.

## METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode data mining yang berfokus pada penerapan algoritma FP-Growth untuk menganalisis pola keterkaitan barang berdasarkan data transaksi. Tahapan penelitian dilakukan secara berurutan mulai dari pengumpulan data hingga evaluasi akhir terhadap hasil rekomendasi yang diperoleh. Alur umum penelitian dapat divisualisasikan dalam diagram alur apabila diperlukan untuk memperjelas proses metodologi yang diterapkan.

Tahap pertama adalah pengumpulan data, di mana sumber data berasal dari transaksi penjualan retail atau minimarket yang memuat informasi historis pembelian konsumen. Dataset umumnya memiliki struktur yang terdiri dari ID\_transaksi, tanggal transaksi, serta daftar item yang dibeli dalam satu waktu. Sumber data dapat diperoleh dari UMKM, instansi retail, e-commerce, atau database internal peneliti, dengan jumlah data yang disesuaikan berdasarkan ketersediaan. Namun, idealnya dataset memiliki minimal ratusan

transaksi agar pola asosiasi yang terbentuk lebih kuat dan akurat.

Tahap berikutnya yaitu preprocessing data, yang dilakukan untuk memastikan data siap dianalisis menggunakan algoritma FP-Growth. Proses ini meliputi cleaning untuk menghapus data kosong, duplikat, dan transaksi tidak relevan; transformasi data untuk mengubah format mentah menjadi transactional format; item reduction untuk melakukan normalisasi atau penyesuaian nama item; serta filtering untuk membuang data yang tidak memenuhi struktur yang dibutuhkan. Hasil dari tahap ini adalah dataset yang telah bersih dan siap diproses, direpresentasikan dalam bentuk  $T = \{t_1, t_2, \dots, t_n\}$  dengan tiap transaksi memuat sekumpulan item pembelian.

Pada tahap pembentukan frequent itemset, algoritma FP-Growth diterapkan untuk menemukan item atau kombinasi item yang sering muncul bersama dalam transaksi. Langkah-langkahnya meliputi penentuan nilai minimum support, perhitungan frekuensi item, penyusunan FP-Tree berdasarkan urutan frekuensi tertinggi ke terendah, pencarian conditional pattern base, kemudian penurunan frequent itemset tanpa proses pembangkitan kandidat seperti yang terjadi pada algoritma Apriori. Item atau kombinasi item yang memenuhi batas minimum support akan digunakan sebagai dasar pembentukan aturan asosiasi.

Tahap selanjutnya adalah pembentukan association rules dari frequent itemset yang telah terbentuk. Perhitungan dilakukan menggunakan parameter support dan confidence untuk mengetahui tingkat kekuatan hubungan antar item, sehingga aturan dengan nilai di atas threshold dapat ditetapkan sebagai rule rekomendasi barang. Pada implementasinya, sistem rekomendasi akan bekerja dengan menginputkan item yang dibeli pelanggan, kemudian sistem mencari rule yang relevan dan menampilkan daftar barang yang sering dibeli bersamaan (cross-selling/up-selling) sebagai output.

Pada tahap terakhir, dilakukan evaluasi hasil menggunakan parameter support, confidence, dan lift ratio untuk mengukur kekuatan serta signifikansi pola asosiasi yang terbentuk. Visualisasi frequent itemset dapat dituangkan dalam bentuk grafik, FP-Tree, atau heatmap hubungan antar item untuk mempermudah interpretasi pola. Jika penelitian menggunakan data penjualan nyata dari retail, evaluasi lanjutan dapat dilakukan berupa pengukuran dampak rekomendasi terhadap peningkatan penjualan sebagai validasi manfaat sistem.

## HASIL DAN PEMBAHASAN

Berdasarkan hasil pengolahan data transaksi penjualan menggunakan algoritma FP-Growth, diperoleh sejumlah frequent itemset dengan nilai support di atas batas minimum yang telah ditentukan. Proses pembentukan FP-Tree menunjukkan bahwa beberapa item memiliki tingkat kemunculan yang lebih tinggi dibandingkan item lainnya, sehingga item tersebut berpotensi menjadi acuan utama dalam pembentukan pola asosiasi. Dari proses ekstraksi frequent itemset ditemukan kombinasi item tertentu yang sering muncul bersama dalam satu transaksi, misalnya Item A dan Item B, Item A dan Item C, serta Item B dan Item D dengan nilai support tertinggi. Temuan ini menunjukkan adanya kecenderungan konsumen membeli produk secara bersamaan sehingga dapat dimanfaatkan dalam perancangan strategi rekomendasi barang.

Selanjutnya, rule association dibentuk menggunakan parameter confidence untuk mengukur tingkat kepastian relasi antar item. Hasil perhitungan menunjukkan bahwa beberapa aturan memiliki nilai confidence yang tinggi, misalnya aturan  $A \rightarrow B$  dengan confidence 72%,  $A \rightarrow C$  sebesar 65%, dan  $B \rightarrow D$  sebesar 71%, sehingga rule tersebut layak dijadikan dasar rekomendasi. Nilai lift yang melebihi angka 1

pada beberapa rule membuktikan bahwa relasi antar item bukan terjadi secara kebetulan, melainkan benar-benar memiliki keterkaitan kuat dalam pola pembelian konsumen. Sistem rekomendasi yang dihasilkan kemudian mampu menampilkan daftar produk yang relevan ketika pengguna memilih salah satu item sebagai input. Implementasi ini menunjukkan bahwa metode FP-Growth efektif dalam mempersingkat waktu proses pencarian pola serta menghasilkan rekomendasi dengan tingkat hubungan yang terukur.

Dari analisis hasil, diketahui bahwa penggunaan FP-Growth memberikan kinerja yang efisien dalam pemrosesan dataset berskala menengah hingga besar tanpa tahap pembangkitan kandidat seperti pada Apriori. Visualisasi pola komponen asosiasi dalam bentuk grafik maupun FP-Tree memperlihatkan hubungan antar produk secara jelas, sehingga memudahkan peneliti maupun pihak retail melakukan interpretasi. Dengan demikian, implementasi algoritma FP-Growth tidak hanya membantu memperoleh insight pola pembelian pelanggan, tetapi juga dapat diterapkan pada skenario bisnis nyata seperti promosi bundling, pengaturan stok barang, dan strategi pemasaran cross-selling untuk meningkatkan penjualan. Hasil ini sejalan dengan penelitian sebelumnya yang menyebutkan bahwa FP-Growth mampu menghasilkan rekomendasi produk secara efektif pada data transaksi retail.

## Pengumpulan Dataset

**Tabel 1. Dataset Market**


| Bread | Honey | Bacon | Toothpaste | Banana | Apple | Hazelnut | ... | Sugar |
|-------|-------|-------|------------|--------|-------|----------|-----|-------|
| 1     | 0     | 1     | 0          | 1      | 1     | 1        | ... | 1     |
| 1     | 1     | 1     | 0          | 1      | 1     | 1        | ... | 0     |
| 0     | 1     | 1     | 1          | 1      | 1     | 1        | ... | 1     |
| 1     | 1     | 0     | 1          | 0      | 1     | 0        | ... | 0     |
| 0     | 1     | 0     | 0          | 0      | 0     | 0        | ... | 0     |
| 0     | 1     | 0     | 1          | 0      | 0     | 1        | ... | 1     |
| 0     | 0     | 1     | 0          | 1      | 1     | 0        | ... | 0     |
| 0     | 0     | 1     | 1          | 1      | 0     | 1        | ... | 0     |
| ...   | ...   | ...   | ...        | ...    | ...   | ...      | ... | 0     |
| 0     | 0     | 0     | 0          | 0      | 0     | 0        | 0   | 0     |

Tabel 1 merupakan contoh dataset transaksi market basket yang digunakan sebagai input dalam proses data mining khususnya metode Association Rule Mining menggunakan algoritma FP-Growth. Dataset ini tersusun dalam bentuk binary matrix, dimana setiap kolom mewakili jenis produk yang tersedia di toko (seperti Bread, Honey, Bacon, Toothpaste, Banana, Apple, Hazelnut, Sugar, dan seterusnya), sedangkan setiap baris merepresentasikan satu transaksi pelanggan. Nilai 1 menunjukkan bahwa item tersebut dibeli dalam transaksi tersebut, sedangkan nilai 0 menunjukkan item tidak dibeli. Dengan struktur seperti ini, dataset sangat cocok digunakan untuk mencari frequent itemset dan membentuk aturan asosiasi dalam sistem rekomendasi barang terkait.

Sebagai contoh, pada baris pertama terlihat bahwa konsumen membeli beberapa barang seperti Bread, Bacon, Banana, Apple, Hazelnut, dan Sugar, ditandai dengan angka 1 pada kolom masing-masing item. Sementara pada baris kedua, kombinasi pembelian berbeda ditunjukkan, misalnya Bread, Honey, Banana, Apple, dan Hazelnut. Variasi kombinasi antar transaksi inilah yang kemudian dianalisis oleh

algoritma FP-Growth untuk menemukan pola item mana yang paling sering dibeli bersamaan. Dataset ini juga memperlihatkan bahwa transaksi semakin banyak di baris berikutnya (ditunjukkan dengan simbol elipsis "..."), menggambarkan bahwa dataset dapat berisi ratusan hingga ribuan transaksi sesuai kebutuhan penelitian.

Melalui tabel ini, peneliti dapat mengidentifikasi frekuensi kemunculan item, menghitung nilai support tiap produk, serta mengekstraksi frequent itemset dan rule asosiasi untuk menghasilkan rekomendasi. Hal ini memungkinkan penentuan strategi pemasaran seperti cross-selling, product placement, maupun penyusunan paket bundling produk yang sering dibeli dalam satu transaksi



Gambar 1.Operator RapidMiner

Proses analisis data menggunakan RapidMiner secara umum mengikuti tahapan yang sistematis, dimulai dari pemanggilan data, pembagian dataset, pembangunan model, penerapan model, hingga evaluasi performanya. Setiap tahapan memiliki fungsi spesifik untuk memastikan bahwa model yang dihasilkan tidak hanya akurat, tetapi juga valid dan dapat digeneralisasikan terhadap data baru. Alur kerja ini sangat penting dalam penelitian berbasis data mining maupun machine learning karena menjamin bahwa proses yang dilakukan bersifat reproducible, terstruktur, dan dapat dipertanggungjawabkan secara ilmiah. Dengan mengikuti tahapan tersebut, peneliti dapat menghasilkan model prediksi yang optimal serta evaluasi performa yang objektif.

### 1.Retrieve Market

Operator ini berfungsi untuk mengambil dataset yang akan digunakan dalam proses analisis. Dataset yang dipanggil biasanya berasal dari Repository RapidMiner. Pada tahap ini data masih dalam bentuk asli (raw data), sehingga perlu dilakukan preprocessing sebelum masuk ke tahapan algoritma.

Output: data transaksi awal sebelum diolah

## 2. Discretize

Operator ini digunakan untuk mengubah atribut numerik menjadi kategori/discrete value. Pada konteks market basket, atribut pembelian item biasanya dalam bentuk angka 0 dan 1 (dibeli/tidak dibeli). Tujuannya agar data siap digunakan oleh algoritma FP-Growth yang bekerja pada data kategorikal

- 0 → Tidak dibeli
- 1 → Dibeli

Operator ini memastikan dataset berada dalam format yang sesuai untuk analisis asosiasi.

Output: data dengan nilai diskrit.

## 3. Numerical to Polynomial

Operator ini berfungsi untuk mengubah tipe data numerik menjadi tipe polynomial (nominal/kategorikal). FP-Growth tidak dapat memproses atribut bertipe numerik langsung, sehingga dibutuhkan konversi ini.

Contoh perubahan

tipe: 0, 1 (numerik) → 0, 1 (nominal/polynomial)

Output: dataset siap diproses sebagai transaksi kualitati

## 4. FP-Growth

Ini adalah operator utama dalam proses Association Rule Mining. FP-Growth bekerja dengan cara membentuk FP-Tree untuk menemukan frequent itemset tanpa membangkitkan kandidat seperti Apriori.

Parameter utama yang biasanya disetting:

- min\_support (ambang minimal kemunculan item)

Output: daftar frequent itemset yang memenuhi nilai support.

## 5. Create Association Rules

Operator ini digunakan untuk membentuk aturan asosiasi (association rules) berdasarkan frequent itemset hasil FP-Growth. Pada tahap ini dihitung nilai

- Support
- Confidence
- Lift (jika diperlukan)

Hasilnya berupa pola keterkaitan barang, contoh:

{Bread, Butter} → {Milk}

Artinya pelanggan yang membeli Bread dan Butter cenderung membeli Milk.

| Size | Support | Item 1                     | Item 2                    |
|------|---------|----------------------------|---------------------------|
| 1    | 1.000   | range1 $[-\infty - 0.500]$ |                           |
| 1    | 1.000   | range2 $[0.500 - \infty]$  |                           |
| 2    | 1.000   | range1 $[-\infty - 0.500]$ | range2 $[0.500 - \infty]$ |

**Gambar 2.** Hasil perhitungan dari frequentitem

Tabel tersebut menunjukkan hasil analisis itemset di mana setiap item maupun kombinasi item memiliki support 1.000 atau 100%, yang berarti seluruh observasi dalam dataset memenuhi kondisi tersebut. Item berupa rentang nilai, yaitu range1  $[-\infty - 0.500]$  dan range2  $[0.500 - \infty]$ , yang biasanya merupakan hasil discretization nilai suatu fitur. Pada baris pertama dan kedua, masing-masing item tunggal muncul pada semua data, sementara baris ketiga menunjukkan bahwa kombinasi kedua item juga selalu muncul bersamaan. Hal ini mengindikasikan bahwa kedua item kemungkinan berasal dari atribut yang berbeda (misalnya fitur X selalu  $\leq 0.5$  dan fitur Y selalu  $\geq 0.5$ ), karena jika berasal dari atribut yang sama, kondisi tersebut tidak mungkin terpenuhi oleh semua data secara bersamaan kecuali pada batas khusus. Secara keseluruhan, tabel ini menggambarkan bahwa baik item individual maupun kombinasinya merupakan pola yang sepenuhnya muncul pada dataset

| No. | Premises                   | Conclusion                 |
|-----|----------------------------|----------------------------|
| 1   | range1 $[-\infty - 0.500]$ | range2 $[0.500 - \infty]$  |
| 2   | range2 $[0.500 - \infty]$  | range1 $[-\infty - 0.500]$ |

**Gambar 3.** Hasil association

Tabel tersebut menampilkan dua aturan asosiasi yang menunjukkan hubungan timbal balik antara dua interval nilai, yaitu range1  $[-\infty - 0.500]$  dan range2  $[0.500 - \infty]$ . Pada aturan pertama, premis range1 menghasilkan kesimpulan range2, yang berarti setiap data yang memenuhi kondisi nilai  $\leq 0.5$  juga selalu memenuhi kondisi nilai  $\geq 0.5$  pada atribut lain. Sebaliknya, aturan kedua menunjukkan bahwa premis range2 juga selalu diikuti oleh range1, sehingga kedua interval ini muncul secara bersamaan dalam seluruh observasi. Hal ini mengindikasikan bahwa kedua kondisi tersebut bukanlah pola independen, melainkan dua karakteristik berbeda yang selalu terjadi secara bersamaan dalam dataset

## KESIMPULAN

Berdasarkan hasil penelitian dan implementasi algoritma FP-Growth pada data transaksi market basket, dapat disimpulkan bahwa metode ini mampu mengidentifikasi pola keterkaitan antar produk secara efektif tanpa perlu melakukan pembangkitan kandidat seperti pada algoritma Apriori, sehingga proses analisis menjadi lebih efisien dan cepat. Frequent itemset yang ditemukan dapat menghasilkan aturan asosiasi yang valid melalui perhitungan support dan confidence, yang kemudian digunakan sebagai dasar

rekomendasi produk terkait dalam konteks strategi pemasaran retail. Dengan demikian, FP-Growth terbukti dapat mendukung pengambilan keputusan dalam pengembangan strategi cross-selling maupun up-selling, serta berpotensi meningkatkan penjualan melalui rekomendasi produk yang lebih relevan dan sesuai pola belanja konsumen.

## DAFTAR PUSTAKA

- Amaliyah, A., & Fatah, Z. (2024). *Implementasi Prediksi Penyakit Ginjal Kronis dengan Menggunakan Metode Decision Tree*. 3(2), 180–186.
- Carolina, A., Ade, K., & Kunci, K. (2020). *Penerapan Data Mining dengan Menggunakan Provinsi di Indonesia Pendahuluan*. 19, 27–38.
- Fata, A. N. P. H. W. S. D. A. (2024). *Penerapan Data Mining untuk Klasifikasi Penyakit Diabetes Menggunakan Metode Decision Tree*. 7(6), 1484–1495.
- Hidayaturrahman. (2024). *KLASIFIKASI TUMOR OTAK PADA CITRA MAGNETIC RESONANCE IMAGING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK BERBASIS WEB*.
- No, V., Hal, A., Agus, I. M., Gunawan, O., Ayu, I. D., Saraswati, I., Gede, I. D., Agung, R., & Eka, I. P. (2023). *Klasifikasi Penyakit Jantung Menggunakan Algoritma Decision Tree Series C4 . 5 Dengan Rapidminer*. 5(2), 73–83. <https://doi.org/10.47233/jteksis.v5i2.775>
- Setyawan, A., Fitriani, A., Rilvani, E., Bangsa, U. P., & Bekasi, K. (2025). *KLASIFIKASI KEMISKINAN DI INDONESIA DENGAN*. 3(7).
- Supriyatin, W., & Rianto, Y. (2024). *Comparative Analysis Accuracy ID3 Algorithm and C4 . 5 Algorithm in S election of Candidates Basic Physics Laboratory Assistant*. 21(1), 1–14.
- Suryawanshi, S., & Patil, S. B. (2023). *Multiclass Classification of Brain MRI through DWT and GLCM Feature Extraction with Various Machine Learning Algorithms*. May.