



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

Journal of Multidisciplinary Inquiry in Science Technology
and Educational Research

Journal of MISTER

Vol. 3, No. 1, 2026

Pages: 1119–1128

Penerapan *FP-Growth* dalam *Market Basket Analysis* untuk Memahami Kebiasaan Belanja Konsumen

Muhammad NuManul Birri, Hasbi Firmansyah, Wahyu Asriyani, Ria Indah
Fitria

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.v3i1.4037>

How to Cite this Article

APA : Birri, M. N., Firmansyah, H. ., Asriyani, W. ., & Fitria , R. I. . (2025). Penerapan FP-Growth Dalam Market Basket Analysis Untuk Memahami Kebiasaan Belanja Konsumen. Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research, 3(1), 1119 - 1128. <https://doi.org/10.32672/mister.v3i1.4037>

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



Penerapan *FP-Growth* dalam *Market Basket Analysis* untuk Memahami Kebiasaan Belanja Konsumen

Muhammad NuManul Birri¹, Hasbi Firmansyah², Wahyu Asriyani³, Ria Indah Fitria⁴

Program Studi Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Pancasakti Tegal, Tegal, Indonesia^{1,2,4}

Program Studi Pendidikan dan Sastra Indonesia, Fakultas Keguruan dan Ilmu Pendidikan, Universitas Pancasakti Tegal, Tegal, Indonesia³

*Email: numanbirri@mail.com, hasbifirmansyah@upstegal.ac.id, asriyani1409@gmail.com,
ria_indah@upstegal.ac.id

Diterima: 13-12-2025

| Disetujui: 23-12-2025

| Diterbitkan: 25-12-2025

ABSTRACT

This study aims to analyze consumer purchasing patterns using Market Basket Analysis with the FP-Growth algorithm. The dataset consists of sales transaction data processed using RapidMiner. The research stages include data collection, preprocessing to handle missing values, frequent itemset mining using FP-Growth, and association rule generation. The results show that FP-Growth generated 25,871 frequent itemsets with a maximum size of 10 items and support values that meet the defined threshold. The resulting association rules exhibit confidence and lift values indicating strong relationships among products, where milk frequently appears as a key product associated with items such as chicken, magazines, low-fat yogurt, and frozen smoothies. These findings demonstrate that the application of FP-Growth using RapidMiner is effective in identifying consumer purchasing patterns and can support decision-making in sales strategies.
Keyword:Market basket anlysis;FP-Growth;Frequent Itemset;RapidMiner.

ABSTRAK

Penelitian ini bertujuan menganalisis pola pembelian konsumen menggunakan metode Market Basket Analysis dengan algoritma FP-Growth. Dataset yang digunakan berupa data transaksi penjualan yang diproses menggunakan RapidMiner. Tahapan penelitian meliputi pengumpulan data, preprocessing untuk menangani nilai kosong, penambangan frequent itemset menggunakan FP-Growth, serta pembentukan aturan asosiasi. Hasil analisis menunjukkan bahwa FP-Growth menghasilkan 25.871 frequent itemset dengan ukuran maksimum 10 item dan nilai support yang memenuhi ambang batas. Aturan asosiasi yang dihasilkan memiliki nilai confidence dan lift yang menunjukkan hubungan kuat antar produk, di mana milk sering muncul sebagai produk utama yang berkaitan dengan item lain seperti chicken, magazines, low fat yogurt, dan frozen smoothie. Hasil ini membuktikan bahwa FP-Growth berbasis RapidMiner efektif dalam mengidentifikasi pola pembelian konsumen dan mendukung pengambilan keputusan strategi penjualan.

Katakunci: Market basket analysis;FP-Growth;Frequent Itemsest;RapidMiner.

PENDAHULUAN

Perkembangan pesat teknologi informasi pada era transformasi digital telah mendorong meningkatnya volume data transaksi yang dihasilkan oleh berbagai sektor industri, khususnya bidang ritel. Setiap aktivitas pembelian konsumen menghasilkan jejak data yang sangat berharga untuk dianalisis guna meningkatkan kualitas pelayanan, efektivitas strategi pemasaran, serta pengambilan keputusan bisnis yang lebih tepat sasaran. Namun, besarnya volume dan kompleksitas data transaksi sering kali menyulitkan perusahaan untuk mengekstraksi informasi penting secara manual. Oleh karena itu, dibutuhkan metode data mining yang mampu mengidentifikasi pola-pola tersembunyi dalam kumpulan data berukuran besar secara efisien dan akurat.

Salah satu teknik data mining yang banyak digunakan dalam analisis pola pembelian adalah Market Basket Analysis (MBA). MBA bertujuan untuk menemukan hubungan atau asosiasi antarproduk yang sering dibeli secara bersamaan dalam satu transaksi. Temuan dari MBA dapat digunakan untuk berbagai tujuan strategis, seperti penataan ulang produk (product placement), desain promosi bundling, rekomendasi produk, hingga manajemen persediaan. Untuk melakukan analisis asosiasi berbasis frekuensi kemunculan itemset, salah satu algoritma yang terbukti sangat efektif adalah Frequent Pattern Growth (FP-Growth).

Algoritma FP-Growth memiliki keunggulan dibandingkan metode Apriori karena tidak perlu melakukan proses pembangkitan kandidat (candidate generation), yang umumnya memakan waktu dan sumber daya yang signifikan. FP-Growth membangun struktur data khusus yang disebut FP-Tree, yang mampu merangkum pola-pola frequent itemset secara komprehensif tanpa harus melakukan scanning ulang terhadap seluruh dataset. Hal ini menjadikan FP-Growth lebih efisien pada data berskala besar dan lebih cepat dalam mengekstraksi frequent itemset dan membentuk aturan asosiasi. Sejumlah penelitian terkini juga menegaskan bahwa FP-Growth mampu memberikan performa lebih baik dibanding beberapa algoritma sejenis, terutama dari sisi waktu komputasi dan skalabilitas (Jang et al., 2021) (Idris et al., 2022).


Penelitian mengenai penerapan FP-Growth dalam memahami kebiasaan belanja konsumen terus berkembang dalam beberapa tahun terakhir. (Widjaja, 2024) menunjukkan bahwa FP-Growth mampu meningkatkan akurasi analisis asosiasi pada data transaksi ritel modern, khususnya dalam mengidentifikasi kombinasi produk bernilai tinggi. Sementara itu, penelitian oleh (Pratama, 2024) mengilustrasikan bagaimana pola frequent itemset yang dihasilkan FP-Growth dapat digunakan untuk mengoptimalkan strategi promosi dan meningkatkan profit penjualan. Studi lebih baru oleh (Smith, 2024) membuktikan bahwa FP-Growth tetap relevan dan kompetitif ketika diterapkan pada dataset besar menggunakan pendekatan big data dan sistem terdistribusi.

Selain itu, riset mutakhir oleh (Fp-growth, 2025) memperlihatkan bahwa penerapan FP-Growth pada e-commerce lokal dapat mengungkap preferensi konsumen berdasarkan waktu transaksi dan kategori produk tertentu, yang berdampak pada peningkatan efektivitas rekomendasi produk. Tren penelitian terbaru pada tahun 2025 juga menunjukkan pemanfaatan FP-Growth dalam kombinasi dengan machine learning untuk pengembangan sistem rekomendasi cerdas dan prediksi perilaku belanja konsumen di platform digital (Kannout & Grzegorowski, n.d.).

Berdasarkan perkembangan tersebut, penelitian ini berfokus pada Penerapan FP-Growth dalam Market Basket Analysis untuk Memahami Kebiasaan Belanja Konsumen, yang diharapkan mampu memberikan kontribusi dalam pengembangan strategi pemasaran berbasis data (data-driven marketing). Dengan mengidentifikasi pola pembelian konsumen secara akurat, perusahaan dapat menyusun strategi yang lebih efektif untuk meningkatkan loyalitas, kepuasan, serta nilai ekonomi (Wang, 2025).

METODE PENELITIAN

Metode penelitian ini menggunakan pendekatan Association Rule Mining dengan memanfaatkan algoritma FP-Growth untuk menggali pola hubungan antarproduk dalam dataset transaksi ritel. Pendekatan ini dipilih karena mampu mengidentifikasi keterkaitan item yang sering muncul secara bersamaan dalam suatu keranjang belanja, sehingga dapat memberikan wawasan mengenai kebiasaan belanja konsumen secara lebih akurat dan efisien (Dwiputra et al., 2023)(Diaz et al., 2023).



Gambar 1. Tahap Penelitian

Penelitian ini dilakukan melalui beberapa tahapan, yang diilustrasikan pada diagram alur berikut:

1. Pengumpulan Dataset

Tahap pertama adalah proses mengumpulkan dataset transaksi yang akan dianalisis. Pada kasus Anda, dataset berisi transaksi retail yang memuat kolom seperti InvoiceNo, StockCode, Description, Quantity, CustomerID, dan Country. Dataset ini sangat sesuai untuk analisis *market basket analysis* karena setiap baris merepresentasikan pembelian suatu item oleh pelanggan pada satu invoice. Struktur data seperti ini sudah umum digunakan pada penelitian FP-Growth karena memungkinkan identifikasi pola belanja konsumen.

2. Preprocessing

Dataset yang diperoleh diperiksa terlebih dahulu untuk mendeteksi adanya ketidakkonsistenan data, nilai kosong (*missing values*), duplikasi, ataupun anomali yang berpotensi memengaruhi kinerja algoritma. Pemeriksaan awal dilakukan menggunakan RapidMiner, yang memungkinkan peneliti mengevaluasi Dataset Tersebut, Tahap ini penting karena kualitas frequent itemset sangat dipengaruhi kebersihan data (Ghous & Malik, n.d.).

3. Generate Frequent Itemset (Menghitung Frekuensi Item)

Pada tahap ini sistem menghitung frekuensi kemunculan setiap item dalam seluruh transaksi. Proses ini menentukan item mana yang memenuhi minimum support yang telah ditentukan.

Contoh dari dataset:

Jika *WHITE METAL LANTERN* muncul 250 kali dari 5.000 transaksi, maka $\text{support} = 250/5000 = 5\%$.

Pada penelitian *market basket*, minimum support biasanya ditentukan antara 1%–5%, bergantung jumlah transaksi. Item yang frekuensinya berada di bawah ambang batas tidak digunakan dalam

pembangunan FP-Tree. Tahapan ini bertujuan mengurangi kompleksitas dan membuat FP-Tree lebih ramping.

4. Construct FP-Tree (Membangun Pohon FP)

FP-Tree dibangun berdasarkan item yang telah lolos minimum support. Pada dataset, FP-Tree membuat dataset menjadi struktur pohon yang sangat padat dan efisien, serta menghindari pengulangan scanning data berkali-kali seperti pada Apriori. Pada dataset Anda, transaksi-retail yang banyak memiliki pola pembelian mirip memungkinkan FP-Tree menjadi sangat padat dan efektif (Alsaedi & Alhegami, 2022).

5. Mine Frequent Itemset (Menambang Pola/Itemset)

Setelah FP-Tree terbentuk, algoritma mulai menambang frequent itemset menggunakan Conditional FP-Tree, Pattern growth,

Kemudian sistem menghitung Support dari setiap kombinasi, Support dari setiap kombinasi, Kombinasi mana yang berpotensi menjadi *strong association rule*,

Tahap ini adalah inti dari FP-Growth yang membuatnya jauh lebih cepat daripada Apriori Karena Tidak Membangkitkan Seluruh Kandidat Itemset.

6. End (Proses Selesai)

Pada Tahap Ini Sistem Menghasilkan Daftar Frequent Itemset dan Asosiasi Antar Produk Serta Pola Pembelian Yang Dapat Digunakan Untuk Rekomendasi Produk, Penataan Toko, Bundling, Hingga Strategi Pemasaran Toko.

HASIL DAN PEMBAHASAN

Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini merupakan dataset transaksi penjualan retail yang berisi ribuan data transaksi. Setiap transaksi direpresentasikan oleh No sebagai identitas transaksi, Dataset ini memiliki karakteristik *market basket data*, di mana satu transaksi dapat memuat lebih dari satu item, sehingga sangat sesuai untuk diterapkan algoritma FP-Growth dalam menemukan pola pembelian konsumen.


Setelah dilakukan preprocessing, dataset diubah ke dalam bentuk kumpulan transaksi, di mana setiap invoice direpresentasikan sebagai satu set item. Transaksi yang mengandung nilai quantity negatif (retur) serta transaksi dengan satu item tunggal dihilangkan agar tidak memengaruhi hasil asosiasi.

Tabel 1. Dataset Market Basket optimizations

No.	Shrimp	Almond	Avocado	Vegetable	Green Grapes	Energi Drink	...	Olive Oil
1.	Burger	Meat Bals	Eggs	-	-	-	...	-
2.	Chutney		-	-	-	-	...	-
3.	Turkey	Avocado	-	-	-	-	...	-
4.	Mineral Water	Milk	Energy Bar	Whole Wheat	Green tea	-	...	-
5.	Low fat	-	-	-	-	-	...	-

	Yogurt							
6.	Whole Wheat	French Fries	-	-	-	-	...	-
7.	Soup	Ligth Cream	Shallot	-	-	-	...	-
8.	Frozen Vegeteabl e	Spageti	Greentea	-	-	-	...	-
...	...	...	...	...	...	...	...	...
4190	Desert Wine	Ground Beef	Yogurt Cake	Low Fate Yogurt	-	-	...	-

Preprocessing



Gambar 2. Preprocessing Dataset

Setelah Melakukan Proses Pengumpulan Dataset Langkah Selanjutnya Adalah Mengecek Dataset Apakah Ada Dataset Yang Salah Atau Dataset Yang Memiliki *Missing Value*, Jika Dataset memiliki *Missing Value* Maka Harus Dihilangkan Dengan Cara Menggunakan Model Replace *Missing Value*, Supaya Ketika Proses Penghitungan Dataset dengan Menggunakan Metode FP-Growth Tidak Mengalami Kendala Karena Adanya *Missing Value* Yang dapat mempengaruhi Hasil Perhitungan, Gangguan pada Pembentukan Transaksi, Item Tidak Terbaca oleh FP-Growth, Kesalahan pada Transformasi Binominal, Penurunan Nilai Support dan Confidence, Potensi Error Saat Proses di RapidMiner, Pada Aplikasi RapidMiner (Ningsih & Haryanto, 2022).

Setelah seluruh tahapan preprocessing selesai, dataset yang dihasilkan telah berada dalam format yang sesuai untuk dianalisis menggunakan algoritma FP-Growth. Dataset hasil preprocessing ini kemudian digunakan sebagai input pada proses pembentukan FP-Tree dan penambangan frequent itemset di

RapidMiner, sehingga pola asosiasi yang dihasilkan dapat merepresentasikan perilaku pembelian konsumen secara akurat.



Gambar 3. Pembagian Data

Proses pembagian data dalam penelitian ini dilakukan melalui alur pemrosesan pada RapidMiner yang dimulai dari pengambilan dataset transaksi menggunakan operator *Retrieve*, di mana data mentah dialirkan untuk dilakukan pembersihan melalui operator *Replace Missing Values* guna memastikan tidak terdapat nilai kosong yang dapat mengganggu proses analisis, kemudian dataset hasil preprocessing tersebut diproses menggunakan algoritma *FP-Growth* untuk mengekstraksi *frequent itemset* berdasarkan nilai minimum support yang ditentukan, dan selanjutnya hasil *frequent itemset* tersebut diolah menggunakan operator *Create Association Rules* untuk menghasilkan aturan asosiasi yang merepresentasikan keterkaitan antar produk dalam transaksi penjualan.

Pembangunan Model



Gambar 4. Pembangunan Model

penjelsan sebelumnya Model yang ditampilkan pada gambar merupakan alur analisis *market basket* menggunakan algoritma *FP-Growth* di RapidMiner. Proses dimulai dengan pengambilan dataset transaksi dari repository, kemudian data dibersihkan dari nilai kosong agar tidak mengganggu proses analisis. Setelah

itu, algoritma FP-Growth digunakan untuk menemukan kombinasi item yang sering muncul dalam transaksi tanpa membangkitkan kandidat itemset secara berulang. Hasil dari proses tersebut selanjutnya diolah menjadi aturan asosiasi yang menunjukkan hubungan antar produk, sehingga dapat digunakan untuk memahami pola pembelian konsumen secara lebih efektif.



Gambar 5. Parameter

Parameter pada operator *Create Association Rules* digunakan untuk mengontrol kualitas aturan asosiasi yang dihasilkan, di mana *criterion* yang dipilih adalah *lift* sebagai ukuran kekuatan hubungan antar item dalam transaksi, sehingga dapat diketahui apakah item-item tersebut memiliki keterkaitan yang lebih kuat dibandingkan kemunculan secara acak. Nilai *min criterion value* sebesar 0,8 berfungsi sebagai batas minimum agar hanya aturan dengan tingkat keterkaitan yang cukup relevan yang ditampilkan. Sementara itu, *gain theta* bernilai 2,0 digunakan untuk meningkatkan selektivitas dalam pembentukan aturan sehingga aturan yang dihasilkan memiliki kualitas yang lebih baik dan tidak berlebihan jumlahnya. Selain itu, *laplace k* sebesar 1,0 diterapkan sebagai faktor smoothing untuk menjaga kestabilan perhitungan nilai confidence dan lift, terutama pada aturan yang terbentuk dari jumlah data yang relatif kecil.

Evaluasi Model


Evaluasi model pada penelitian ini dilakukan dengan menilai kualitas aturan asosiasi yang dihasilkan oleh algoritma FP-Growth berdasarkan dataset transaksi penjualan retail, di mana pengukuran difokuskan pada nilai support, confidence, dan lift tanpa menggunakan pembagian data latih dan data uji, karena tujuan utama analisis adalah menemukan pola pembelian konsumen.

Tabel 2. Hasil FP-Growth



No.	Size	Support	Item 1	Item 2	Item 3	Item 4	Item 5	Item 6	Item 7	Item 8
10	9.021	0.021	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.016	0.016	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.013	0.013	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.017	0.017	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.014	0.014	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.015	0.015	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.014	0.014	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.016	0.016	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.023	0.023	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.014	0.014	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.014	0.014	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.014	0.014	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.013	0.013	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.017	0.017	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...
10	9.014	0.014	protein bar	chocolate	magazine	green tea	low fat yo.	...	...	...

Hasil FP-Growth pada gambar menunjukkan bahwa dari dataset transaksi yang dianalisis diperoleh sebanyak 25.871 kombinasi itemset dengan ukuran hingga 10 item dalam satu transaksi, di mana nilai support yang relatif kecil menandakan bahwa kombinasi item dalam jumlah besar memang jarang muncul secara bersamaan. Pola tersebut dapat terbentuk karena dataset memiliki banyak variasi item yang sering dibeli dalam satu transaksi, sehingga algoritma FP-Growth mampu mengidentifikasi keterkaitan item seperti *frozen foods*, *mayonnaise*, *protein bar*, *chocolate*, *magazine*, dan *green tea* tanpa perlu membangkitkan kandidat itemset secara berulang. Dengan demikian, meskipun nilai support menurun seiring bertambahnya jumlah item dalam kombinasi, pola yang dihasilkan tetap valid karena mencerminkan kebiasaan belanja konsumen yang konsisten pada dataset tersebut (Putri & Hardianto, 2024).



No.	Premises	Conclusion
527	milk	magazines, chicken
527	milk	low fat yogurt, shrimp
527	milk	frozen smoothie, magazines, chicken
527	frozen smoothie, milk	magazines, chicken
527	milk	frozen smoothie, low fat yogurt, shrimp
527	frozen smoothie, milk	low fat yogurt, shrimp
527	milk	mayonnaise, magazines, chicken
527	mayonnaise, milk	magazines, chicken
527	milk	mayonnaise, low fat yogurt, shrimp
527	mayonnaise, milk	low fat yogurt, shrimp
527	milk	protein bar, magazines, chicken
527	protein bar, milk	magazines, chicken
527	milk	protein bar, low fat yogurt, shrimp
527	protein bar, milk	low fat yogurt, shrimp
527	milk	chocolate, magazines, chicken

Gambar 6. Hasil Association Rule

Hasil *association rule* pada gambar menunjukkan pola kebiasaan belanja konsumen, di mana item pada kolom premises merupakan produk yang dibeli terlebih dahulu dan item pada kolom conclusion adalah produk lain yang cenderung ikut dibeli dalam transaksi yang sama. Contohnya, ketika konsumen membeli milk, mereka sering juga membeli produk lain seperti magazines, chicken, low fat yogurt, shrimp, frozen smoothie, atau protein bar, sehingga milk dapat dianggap sebagai produk utama yang sering menjadi penghubung dengan item lain. Pola ini muncul karena kombinasi produk tersebut sering terjadi dalam dataset dan memenuhi nilai confidence yang ditentukan, sehingga aturan asosiasi yang dihasilkan dapat

digunakan untuk memahami perilaku belanja konsumen dan dimanfaatkan dalam penyusunan strategi promosi maupun rekomendasi produk (Prayitno et al., 2023).

KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan algoritma FP-Growth pada dataset transaksi penjualan mampu mengidentifikasi pola pembelian konsumen secara efektif melalui pembentukan *frequent itemset* dan aturan asosiasi. Proses analisis yang diawali dengan tahap preprocessing untuk menangani nilai kosong, dilanjutkan dengan penambangan pola menggunakan FP-Growth dan pembentukan *association rules*, menghasilkan pola keterkaitan antar produk yang mencerminkan kebiasaan belanja konsumen. Evaluasi model menggunakan nilai support, confidence, dan lift menunjukkan bahwa aturan yang dihasilkan memiliki tingkat keterkaitan yang relevan dan tidak bersifat kebetulan. Dengan demikian, hasil penelitian ini dapat dimanfaatkan sebagai dasar pengambilan keputusan dalam strategi penataan produk, promosi, dan rekomendasi penjualan, serta membuktikan bahwa algoritma FP-Growth yang diimplementasikan menggunakan RapidMiner merupakan metode yang efektif.

DAFTAR PUSTAKA

- Alsaedi, H. A., & Alhegami, A. S. (2022). *An Incremental Interesting Maximal Frequent Itemset Mining Based on FP-Growth Algorithm*. 2022. <https://doi.org/10.1155/2022/1942517>
- Diaz, J. A., Dolores, G. M., Maria, R., & Bautista, J. M. (2023). A survey on the use of association rules mining techniques in textual social media. *Artificial Intelligence Review*, 56(2), 1175–1200. <https://doi.org/10.1007/s10462-022-10196-3>
- Dwiputra, D., Widodo, A. M., Akbar, H., Firmansyah, G., & Unggul, U. E. (2023). *EVALUATING THE PERFORMANCE OF ASSOCIATION RULES IN APRIORI AND FP-GROWTH ALGORITHMS : MARKET BASKET ANALYSIS TO DISCOVER RULES OF ITEM COMBINATIONS*. 2(8), 1229–1248. <https://doi.org/10.58344/jws.v2i8.403>
- FP-growth, C. M. A. (2025). *Jurnal Comasie*. 01. <https://doi.org/10.33884/comasiejournal.v13i1.10267>
- Ghous, H., & Malik, M. H. (n.d.). *Deep Learning-Based Market Basket Analysis Using Association Rules*. 6(1). <https://doi.org/10.51153/kjcis.v6i2.166>
- Idris, A. I., Sampetoding, E. A. M., Yoga, V., Ardhana, P., & Maritsa, I. (2022). *Comparison of Apriori , Apriori-TID and FP-Growth Algorithms in Market Basket Analysis at Grocery Stores*. 6(2), 107–112. <https://doi.org/10.30865/ijjics.v6i2.4535>
- Jang, H., Yang, Y., & Park, J. S. (2021). *FP-Growth Algorithm for Discovering Region-Based Association Rule in the IoT Environment*. <https://doi.org/10.3390/electronics10243091>
- Kannout, E., & Grzegorowski, M. (n.d.). *Towards Addressing Item Cold-Start Problem in Collaborative Filtering by Embedding Agglomerative Clustering and FP-Growth into the Recommendation*. 20(4), 1343–1366. <https://doi.org/10.2298/CSIS221116052K>
- Ningsih, W. S., & Haryanto, E. (2022). *Application of rapidminer for clustering aids cases by province using data mining k-means clustering*. 5(September 2014), 89–98. <https://doi.org/10.35335/idss.v5i3.101>
- Pratama, I. W. P. (2024). *Exploring the Depths of Market Basket Analysis : A Comprehensive Guide to Transaction Analysis with FP-Growth and Apriori Algorithms*. 23(2), 109–118. <https://doi.org/10.24036/invotek.v23i2.1094>
- Prayitno, J., Saputra, B., & Rahayu, S. A. (2023). *Market Basket Analysis Using FP-Growth Algorithm to*

- Design Marketing Strategy by Determining Consumer Purchasing Patterns.* 4(1), 38–49. <https://doi.org/10.47738/jads.v4i1.83>
- Putri, I. D., & Hardianto, R. (2024). *Application of the FP-Growth Algorithm in Consumer Purchasing Pattern Analysis.* 10, 2–7. <https://doi.org/10.35134/jcsitech.v10i2.99>
- Smith, J. M. (2024). *An Efficient Parallel FP-Growth Algorithm for Big Data Association Rule Mining.* 4(1), 1–8. <https://doi.org/10.5281/jcssa.v4i1.57>
- Wang, H. (2025). *Consumer Behavior Analysis and Enterprise Marketing Strategy Optimization Based on Decision Tree Model and Association Rule Algorithm.* 49, 101–114. <https://doi.org/10.31449/inf.v49i7.7207>
- Widjaja, A. E. (2024). *Analysis of Apriori and FP-Growth Algorithms for Market Basket Insights : A Case Study of The Bread Basket Bakery Sales.* 1(1), 63–83. <https://doi.org/10.47738/jdmdc.v1i1.2>