Accredited SINTA 5
72/E/KPT/2024

Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)
Vol. 9 No. 2, April 2026
P-ISSN 2620-8342
E-ISSN 2621-3052

Perbandingan Algoritma FP-Growth dan Apriori untuk Menganalisis Pola Pembelian Konsumen

Noviyanti Patak Lembang[1*], Alter Lasarudin[2], Wahyudin Hasyim[3]
Program Studi Sistem Informasi, Universitas Muhammadiyah Gorontalo
Jl. Prof. Dr. H. Mansoer Pateda, Desa Pentadio Timur, Kec. Telaga Biru, Kab. Gorontalo, Gorontalo 96181, Indonesia
E-mail: noviyantipataklembang16@gmail.com

Submitted Date : 03 April 2026 ***Accepted Date : 06 April 2026***

Abstrak - Pemamfaatan data transaksi penjualan berperan penting dalam mengungkap pola pembelian konsumen yang mendukung pengambilan keputusan usaha, namun pada praktiknya masih belum dimanfaatkan secara optimal oleh Usaha Kecil dan Menengah. Penelitian ini bertujuan untuk menerapkan serta membandingkan algoritma FP-Growth dan Apriori dalam menganalisis pola pembelian konsumen pada UKM Mart Koperasi Wanita Kasih Ibu. Penelitian ini menggunakan pendekatan Kuantitatif dengan teknik *Association Rule Mining* terhadap data transaksi penjualan periode Januari hingga Desember 2024, dengan jumlah data awal sebanyak 9305 transaksi dan setelah proses pembersihan diperoleh 7972 transaksi yang terdiri dari dua atribut. Analisis data dilakukan menggunakan aplikasi RapidMiner. Hasil penelitian menunjukkan bahwa algoritma FP-Growth menghasilkan 55 aturan asosiasi dengan waktu pemrosesan yang 1 detik, sedangkan algoritma Apriori menghasilkan 57 aturan asosiasi dengan waktu pemrosesan 4 detik. Penelitian ini menunjukkan bahwa algoritma FP-Growth lebih efektif digunakan dalam mengidentifikasi pola pembelian konsumen sebagai dasar penyusunan strategi pemasaran dan pengelolaan persediaan.
Kata kunci : Data Mining, Association Rule Mining, FP-Growth, Apriori, Pola Pembelian Konsumen.

Abstract - *Utilization Sales transaction data plays an important role in revealing consumer purchasing patterns that support business decision-making, but in practice it is still not optimally utilized by Small and Medium Enterprise. This study aims to apply and compare the FP-Growth and Apriori algorithms in analyzing consumer purchasing pattern at UKM Mart Koperasi Wanita Kasih Ibu. This study uses a quantitative approach with the technique of Association Rule Mining the analysis used sales transaction data from January to Desember 2024, with an initial data set of 9,305 transactions and after the cleaning process, 7,972 transactions consisting of two attributes were obtained. Data analysis was performed using the RapidMiner application. The results showed that the FP-Growth algorithm generated 55 association rules with a processing time of 1 second, while the Apriori algorithm generated 57 association rules with a processing time of 4 seconds. This study indicates that the FP-Growth algorithm is more effective in identifying consumer purchasing patterns as a basic for developing marketing strategies and inventory management.*
Keywords: Data Mining, Association Rule Mining, FP-Growth, Apriori, Consumer Purchasing Patterns.

1. Pendahuluan

Pelaku usaha termasuk Usaha Kecil dan Menengah (UKM) sangat menghargai data transaksi penjualan di era digital saat ini. Data ini mencerminkan perilaku pelanggan dan dapat digunakan untuk mengidentifikasi pola pembelian yang berulang. Namun, banyak UKM yang belum memanfaatkan data ini secara optimal untuk mendukung pengambilan keputusan. Preferensi konsumen dapat diketahui melalui analisis data transaksi, yang dapat membantu dalam perencanaan stok dan strategi pemasaran.

UKM Mart Kasih Ibu adalah usaha yang dikelola oleh Koperasi Wanita Kasih Ibu yang berlokasi di Kelurahan Dulalowo, Kecamatan Kota Tengah, Provinsi Gorontalo. Usaha ini menyediakan beragam kebutuhan harian, mulai dari perlengkapan rumah tangga, makanan ringan, hingga produk lain yang diperlukan masyarakat. Selain menjadi tempat belanja, UKM Mart Kasih Ibu juga mencerminkan peran Koperasi dalam mendukung pemberdayaan ekonomi perempuan di wilayah tersebut. Selama beberapa tahun terakhir, UKM Mart Koperasi Wanita Kasih Ibu telah mengumpulkan data transaksi penjualan, tetapi belum melakukan analisis mendalam untuk mengidentifikasi pola pembelian konsumen. Dengan menganalisis data ini, UKM Mart Koperasi Wanita Kasih Ibu dapat memahami kecenderungan konsumen dalam membeli beberapa produk sekaligus, yang dapat dimanfaatkan untuk meningkatkan penjualan melalui strategi bundling atau penataan produk.

Cara untuk menemukan informasi baru dalam kumpulan data yang besar disebut data mining. Ini dicapai melalui penggabungan berbagai jenis data ke dalam basis data, termasuk data berorientasi objek, data relasional, serta data transaksi [1]. Data mining dapat digunakan oleh perusahaan untuk mengevaluasi data

Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)

Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)
Vol. 9 No. 2, April 2026
P-ISSN 2620-8342
E-ISSN 2621-3052

transaksi penjualan untuk mengidentifikasi kebiasaan pembelian pelanggan. Salah satu teknik data mining yang sesuai untuk menemukan hubungan atau asosiasi antara item-item dalam dataset ialah Association Rule Mining (ARM). Dalam analisis keranjang belanja, ARM dimanfaatkan untuk mengidentifikasi produk yang sering muncul secara bersama dalam satu transaksi, sebagaimana dijelaskan bahwa analisis keranjang belanja bisa menunjukkan item yang kerap dibeli bersamaan sebagai dasar strategi penjualan [2].

Dalam teknik Association Rule Mining (ARM), ada dua algoritma populer serta banyak dipakai, seperti FP-Growth dan Apriori. Algoritma Apriori bekerja dengan pendekatan iterative yang secara bertahap membentuk dan mengevaluasi kandidat-itemset berdasarkan frekuensi kemunculannya, namun pendekatan ini cenderung menjalankan banyak iterasi sehingga kurang efisien dalam kecepatan eksekusi. Di sisi lain, FP-Growth lebih efisien dalam pemrosesan ketika membangun struktur pohon kompresi yang dikenal sebagai FP-Tree, memungkinkan penemuan pola frekuen tanpa harus menghasilkan kandidat-itemset secara eksplisit berkali-kali [3].

Dengan melakukan perbandingan antara FP-Growth dan Apriori pada data penjualan UKM Mart Koperasi Wanita Kasih Ibu, penelitian ini diharapkan mampu memberikan pemahaman mengenai tingkat efektivitas masing-masing algoritma dalam mengidentifikasi pola pembelian konsumen. Temuan dari perbadingan tersebut tidak hanya berfungsi untuk menentukan algoritma yang lebih cepat dan akurat, tetapi juga dapat menjadi landasan bagi UKM Mart dalam menyusun strategi pemasaran, mengatur penempatan produk, serta mengelola persediaan secara lebih optimal.

2. Tinjauan Pustaka

2.1. Analisis

Analisis adalah pendekatan berpikir kritis dan sistematis untuk memecah suatu fenomena menjadi bagian-bagian kecil agar hubungan antar komponennya dapat dipahami. Tujuannya adalah memperoleh pemahaman menyeluruh melalui proses penguraian, pemisahan, dan pengelompokan, sehingga mendukung pengambilan keputusan yang logis dan terstruktur [4].

2.2. Pola Pembelian Konsumen

Pola pembelian konsumen merupakan kecenderungan dan kebiasaan konsumen dalam memilih serta membeli produk, yang dilihat dari kombinasi barang, frekuensi, dan waktu pembelian. Analisis pola ini penting untuk membantu pelaku usaha memahami perilaku konsumen, mengoptimalkan stok, serta mengurangi risiko penumpukan barang, sehingga keputusan bisnis menjadi lebih tepat sasaran [5].

2.3. Data Transaksi Penjualan

Data transaksi penjualan adalah catatan digital yang memuat informasi pembelian pelanggan, seperti jenis produk, jumlah, waktu, dan frekuensi. Seiring meningkatnya volume dan kompleksitas data di era digital, analisis data ini menjadi penting untuk mengungkap pola, asosiasi produk, dan kebiasaan konsumen guna mendukung pengambilan keputusan bisnis [6].

2.4. Data Mining

Data mining adalah proses menemukan pola atau informasi penting dari data dalam jumlah besar yang sebelumnya tidak diketahui, juga dikenal sebagai Knowledge Discovery in Database (KDD). Metode ini membantu bisnis memahami pola pembelian konsumen untuk mendukung pengambilan keputusan yang lebih tepat [7].

2.5. Association Rule Mining

Association rule mining merupakan teknik dalam data mining untuk menemukan hubungan antar item dalam dataset, terutama yang sering muncul bersama dalam transaksi. Informasi ini berguna bagi bisnis, misalnya untuk strategi pemasaran atau penataan produk. Algoritma yang umum digunakan antara lain FP-Growth dan Apriori [8]. Metode untuk melakukan analisis asosiasi terdiri atas dua tahap utama [7]:

1. Analisa Pola Frekuensi Tinggi

Gabungan item yang memenuhi syarat dengan nilai minimum dukungan dalam basis data dicari. *Support*, yakni metrik yang menampilkan seberapa dominan suatu item atau kumpulan item dalam transaksi secara keseluruhan. Metrik ini mengukur frekuensi kemunculan item atau itemset dalam dataset. Nilai *support* untuk satu item dapat dihitung menggunakan rumus:

$$Support\ A = \frac{\sum Transaksi\ Mengandung\ A}{\sum Transaksi}\ x\ 100\% \qquad (1)$$

Untuk mencari nilai pada dua item dapat dihitung menggunakan rumus:

Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)

Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)
Vol. 9 No. 2, April 2026
P-ISSN 2620-8342
E-ISSN 2621-3052

$$Support\ (A,B) = \frac{\sum Transaksi\ Mengandung\ A,B}{\sum Transaksi}\ x\ 100\% \quad (2)$$

Serta mencari nilai pada tiga item menggunakan rumus [9]:

$$Support\ (A,B,C) = \frac{\sum Transaksi\ Mengandung\ A,B,dan\ C}{\sum Transaksi}\ x\ 100\% \quad (3)$$

2. Pembentukan Aturan Asosiatif

Mencari aturan asosiatif yang memenuhi kriteria minimum untuk nilai kepercayaan. Proses ini melibatkan perhitungan kepercayaan untuk aturan asosiatif A∪B. *Confidence* yakni ukuran yang menampilkan seberapa sering itemset B muncul bersama dengan itemset A. Untuk menghitung nilai kepercayaan dari aturan A∪B, dapat digunakan rumus:

$$Confidence\ P(B|A) = \frac{\sum\ Transaksi\ Mengandung\ A,B}{\sum\ Transaksi\ A}\ x\ 100\% \quad (4)$$

2.6. FP-Growth

FP-Growth adalah algoritma yang digunakan untuk menemukan pola keterkaitan item berdasarkan frekuensi kemunculan dengan membangun struktur FP-Tree, sehingga prosesnya lebih cepat tanpa menghasilkan banyak kandidat itemset [10].

2.7. Apriori

Apriori adalah algoritma dalam Market Basket Analysis yang digunakan untuk menemukan frequent itemset dan membentuk aturan asosiasi. Prosesnya dilakukan secara bertahap, mulai dari item tunggal hingga kombinasi item yang memenuhi batas minimum frekuensi [11].

2.8. UKM Mart

UKM Mart yaitu sebuah toko ritel yang berbasis koperasi. Toko ini berfungsi sebagai pendorong bagi gerakan koperasi agar dapat meningkatkan kemampuan manajemennya [12].

2.9. RapidMiner

RapidMiner adalah perangkat lunak open source untuk data mining dan analisis data dengan antarmuka GUI yang memudahkan pengguna tanpa keterampilan pemrograman. Dikembangkan oleh Dr. Markus Hofmann dan Raif Klinkenberg berbasis Java, perangkat ini berlisensi GNU Public License dan dapat berjalan di berbagai sistem operasi [13].

3. Metode Penelitian

3.1. Objek Penelitian

Penelitian ini berfokus pada data transaksi penjualan konsumen di UKM Mart Koperasi Wanita Kasih Ibu, yang mencatat kombinasi produk yang dibeli secara bersamaan. Data tersebut dipilih karena dianggap mampu merepresentasikan perilaku belanja konsumen sekaligus relevan untuk mengungkap pola pembelian berulang. Dengan menggunakan algoritma algoritma FP-Growth dan Apriori, penelitian ini diharapkan dapat menghasilkan aturan asosiasi yang mendukung strategi promosi, penataan produk, serta rekomendasi pembelian.

3.2. Metode Penelitian

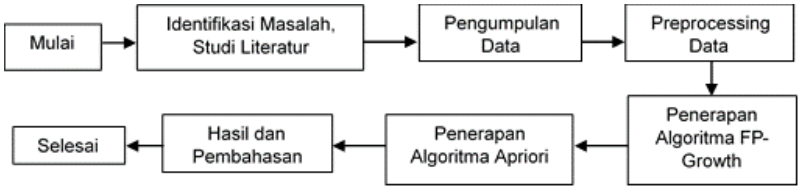
Penelitian ini menerapkan metode kuantitatif dengan mengolah data transaksi penjualan konsumen di UKM Mart Koperasi Wanita Kasih Ibu menggunakan algoritma FP-Growth dan Apriori dalam teknik *association rule mining*. Algoritma FP-Growth memanfaatkan struktur *FP-Tree* untuk mengekstraksi pola dengan lebih cepat dan efisien, sedangkan algoritma Apriori membangun frequent itemset secara bertahap. Pengolahan data dilakukan melalui aplikasi RapidMiner guna membandingkan kinerja kedua algoritma berdasarkan tingkat akurasi pola, kecepatan pemrosesan, serta kompleksitas perhitungan.

3.3. Tahapan Penelitian

Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)

Accredited SINTA 5
72/E/KPT/2024

Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)
Vol. 9 No. 2, April 2026
P-ISSN 2620-8342
E-ISSN 2621-3052



Gambar 1 Tahapan Penelitian

4. Hasil dan Pembahasan

4.1. Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan melalui observasi langsung di UKM Mart Koperasi Wanita Kasih Ibu. Dari hasil observasi tersebut, diperoleh data transaksi penjualan sebanyak 9305 transaksi yang terjadi selama 1 tahun, yaitu Januari hingga Desember 2024. Dataset ini menyajikan informasi tentang jumlah penjualan berbagai produk. Setiap baris pada tabel merepresentasikan satu transaksi yang memuat beragam jenis barang, mulai dari kebutuhan rumah tangga, makanan, hingga produk perawatan diri. Variasi jumlah penjualan pada masing-masing item menggambarkan tingkat permintaan yang berbeda sepanjang periode pancatatan.

4.2. Preprocessing Data

Pada preprocessing data ini terdapat beberapa proses yang dilakukan, yaitu data mentah yang awalnya terdiri dari beberapa atribut, seperti Transaksi, Tanggal, Nama Barang, Satuan, Jumlah, Harga, dan Total, kemudian disederhanakan menjadi dua atribut, yaitu Transaksi, dan Nama Barang. Penyederhanaan ini dilakukan untuk memfokuskan analisis pada informasi yang paling relevan dengan tujuan penelitian, serta mengurangi kompleksitas data. Selanjutnya nama barang dikelompokkan berdasarkan jenisnya dan di sederhanakan menjadi kode barang, yaitu A1 hingga A20. Setelah itu, data transaksi yang hanya mengandung satu item di hapus karena data tersebut tidak memberikan kontribusi signifikan dalam pembentukan aturan asosiasi antar produk. Setelah dilakukan proses pembersihan data, diketahui bahwa dari total 9305 data transaksi awal terdapat 1333 data transaksi yang hanya mencakup satu jenis item pembelian. Dengan demikian, jumlah transaksi yang siap digunakan untuk tahap analisis berikutnya adalah sebanyak 7972 transaksi. Hasilnya dapat dilihat pada tabel berikut.

Tabel 1 Hasil Preprocessing Data

TRANSAKSI	NAMA BARANG
T1	ZINC
	DAIA 65GR PUTIH
T2	FOYU 505GR
	GELAS POPICE
	TAS SEDANG
T3	SHINZUI
	DOWNY FRESH BOUQUET
	EMERON HIJAB
	ATTACK JAZZ 1 SEMERBAK CI
	DOWNY ADORABLE
	CUTTOM BUDS BAYI
	ULTRA MILK 125ML
	SUN KARA 65ML
T4	DAIA 65GR PUTIH
	ROYALE
T5	ROYALE
	SOKLIN LIQUID 30 ML
…	…
…	…
T7971	KOPI KOTA 4000
	KECAP SEDAP BOTOL 135 ML
T7972	MAMA LEMON 130
	MOLTO SB 5 IN 1 BIRU
	KECAP SEDAP 70 ML + 11 ML

Setelah tahap pembersihan data selesai dilakukan, data transaksi kemudian disusun kembali dalam bentuk tabel tabular dengan representasi biner. Pada format ini, setiap item dalam transaksi diberi nilai 1 jika produk tersebut terdapat dalam transaksi (*True*), dan 0 jika tidak muncul (*False*). Penggunaan representasi biner bertujuan untuk mempermudah proses komputasi pada algoritma FP-Growth dan Apriori, karena kedua metode tersebut membutuhkan data *numerik* dalam mendeteksi keterkaitan antaritem. Hasilnya dapat dilihat pada tabel berikut ini.

Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)

Accredited SINTA 5
72/E/KPT/2024

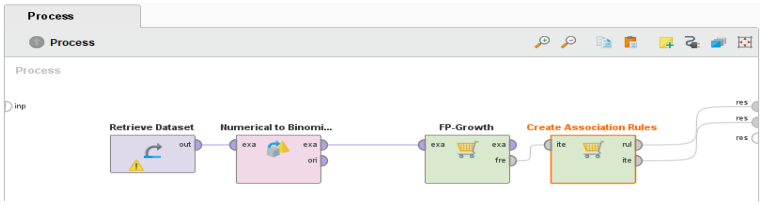
Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)
Vol. 9 No. 2, April 2026
P-ISSN 2620-8342
E-ISSN 2621-3052

Tabel 2 Dataset Transaksi Bentuk Tabular

Transaksi	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17	A18	A19	A20
T1	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0
T2	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
T3	0	0	1	0	0	0	0	1	0	1	0	0	1	1	1	0	0	0	1	0
T4	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0
T5	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0
T6	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0
T7	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
T8	0	0	0	0	1	0	1	0	0	1	0	0	1	0	0	0	0	0	1	1
T9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1
T10	0	1	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	0
…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…
…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…
…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…	…
T7970	0	1	0	0	1	0	1	0	0	0	0	1	0	0	0	0	0	0	1	0
T7971	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
T7972	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	1	0

4.3. Penerapan Algoritma FP-Growth

Langkah selanjutnya adalah menjalankan pengujian algoritma FP-Growth menggunakan software RapidMiner Studio 9.10.



Gambar 2 Proses Algoritma FP-Growth Menggunakan RapidMiner

Berdasarkan proses algoritma FP-Growth di atas, pengelolaan dataset di RapidMiner sebagai berikut:

1. Memasukkan operator '***Retrieve Dataset***', berfungsi memanggil kembali dataset yang telah disimpan melalui operator *Retrieve*.
2. Memasukkan operator '***Numerical to Binominal***', berfungsi mengubah atribut bernilai numerik menjadi format dua kategori, seperti "*true*" dan "*false*".
3. Memasukkan operator '***FP-Growth***', berfungsi mengidentifikasi himpunan item yang muncul secara berulang dalam transaksi dengan memasukkan nilai minimum *support* yang telah ditetapkan.
4. Memasukkan operator '***Create Association Rule***', berfungsi membentuk aturan asosiasi berdasarkan *frequent itemset* tersebut dengan memasukkan minimum *confidence* yang telah ditetapkan.

No.	Premises	Conclusion	Support	Confidence
9	A20, A3, A5, A2	A7	0.021	0.763
10	A5, A6	A7	0.027	0.763
11	A13, A5, A10	A19	0.022	0.767
12	A13, A7, A2	A20	0.033	0.767
13	A13, A5, A15	A19	0.033	0.767
14	A13, A5, A2	A20	0.025	0.768
15	A13, A3, A2	A20	0.027	0.771
16	A19, A20, A3, A5	A7	0.022	0.772
17	A7, A5, A2	A20	0.033	0.774
18	A14	A13	0.124	0.774
19	A3, A2, A4	A20	0.027	0.776
20	A20, A2, A14	A13	0.020	0.776
21	A7, A2, A4	A20	0.030	0.777
22	A7, A5, A14	A13	0.023	0.780
23	A3, A5, A2	A20	0.027	0.782

AssociationRules

```
Association Rules
[A13, A5, A8] --> [A19] (confidence: 0.751)
[A20, A5, A14] --> [A7] (confidence: 0.751)
[A7, A3, A2] --> [A20] (confidence: 0.752)
[A13, A3, A5] --> [A19] (confidence: 0.754)
[A5, A2, A4] --> [A20] (confidence: 0.756)
[A19, A13, A20, A3] --> [A7] (confidence: 0.761)
[A2, A14] --> [A13] (confidence: 0.762)
[A3, A5, A15] --> [A19] (confidence: 0.763)
[A20, A3, A5, A2] --> [A7] (confidence: 0.763)
[A5, A6] --> [A7] (confidence: 0.763)
[A13, A5, A10] --> [A19] (confidence: 0.767)
[A13, A7, A2] --> [A20] (confidence: 0.767)
[A13, A5, A15] --> [A19] (confidence: 0.767)
[A13, A5, A2] --> [A20] (confidence: 0.768)
[A13, A3, A2] --> [A20] (confidence: 0.771)
[A19, A20, A3, A5] --> [A7] (confidence: 0.772)
[A7, A5, A2] --> [A20] (confidence: 0.774)
[A14] --> [A13] (confidence: 0.774)
[A3, A2, A4] --> [A20] (confidence: 0.776)
[A20, A2, A14] --> [A13] (confidence: 0.776)
[A7, A2, A4] --> [A20] (confidence: 0.777)
[A7, A5, A14] --> [A13] (confidence: 0.780)
[A3, A5, A2] --> [A20] (confidence: 0.782)
[A19, A13, A7, A2] --> [A20] (confidence: 0.782)
[A5, A14] --> [A13] (confidence: 0.784)
[A4, A14] --> [A13] (confidence: 0.785)
```

Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)

Accredited SINTA 5
72/E/KPT/2024

Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)
Vol. 9 No. 2, April 2026
P-ISSN 2620-8342
E-ISSN 2621-3052

24	A19, A13, A7, A2	A20	0.021	0.782
25	A5, A14	A13	0.040	0.784
26	A4, A14	A13	0.032	0.785
27	A20, A7, A14	A13	0.026	0.785
28	A5, A15, A2	A20	0.021	0.786
29	A13, A20, A3, A5	A7	0.021	0.786
30	A15, A14	A13	0.045	0.786
31	A3, A6	A7	0.026	0.787
32	A13, A20, A3, A2	A7	0.021	0.788
33	A19, A14	A13	0.052	0.789
34	A19, A7, A14	A13	0.026	0.793
35	A20, A5, A1	A7	0.021	0.798
36	A20, A3, A14	A13	0.022	0.799
37	A14, A10	A13	0.029	0.806
38	A20, A5, A14	A13	0.022	0.806
39	A7, A3, A14	A13	0.024	0.807
40	A19, A7, A3, A2	A20	0.020	0.810
41	A3, A5, A14	A19	0.021	0.810
42	A3, A14	A13	0.037	0.812
43	A14, A11	A13	0.021	0.817
44	A19, A20, A14	A13	0.024	0.819
45	A13, A7, A3, A2	A20	0.021	0.823
46	A7, A5, A1	A20	0.021	0.826
47	A19, A5, A14	A13	0.029	0.827
48	A7, A3, A5, A2	A20	0.021	0.828
49	A3, A5, A14	A13	0.022	0.839
50	A19, A15, A14	A13	0.028	0.840
51	A14, A8	A13	0.031	0.841
52	A19, A3, A14	A13	0.027	0.846
53	A19, A4, A14	A13	0.022	0.852
54	A5, A15, A14	A13	0.021	0.863
55	A7, A2, A1	A20	0.022	0.868

Gambar 3 Hasil Operator *FP-Growth*

```
[A20, A7, A14] --> [A13] (confidence: 0.785)
[A5, A15, A2] --> [A20] (confidence: 0.786)
[A13, A20, A3, A5] --> [A7] (confidence: 0.786)
[A15, A14] --> [A13] (confidence: 0.786)
[A3, A6] --> [A7] (confidence: 0.787)
[A13, A20, A3, A2] --> [A7] (confidence: 0.788)
[A19, A14] --> [A13] (confidence: 0.789)
[A19, A7, A14] --> [A13] (confidence: 0.793)
[A20, A5, A1] --> [A7] (confidence: 0.798)
[A20, A3, A14] --> [A13] (confidence: 0.799)
[A14, A10] --> [A13] (confidence: 0.806)
[A20, A5, A14] --> [A13] (confidence: 0.806)
[A7, A3, A14] --> [A13] (confidence: 0.807)
[A19, A7, A3, A2] --> [A20] (confidence: 0.810)
[A3, A5, A14] --> [A19] (confidence: 0.810)
[A3, A14] --> [A13] (confidence: 0.812)
[A14, A11] --> [A13] (confidence: 0.817)
[A19, A20, A14] --> [A13] (confidence: 0.819)
[A13, A7, A3, A2] --> [A20] (confidence: 0.823)
[A7, A5, A1] --> [A20] (confidence: 0.826)
[A19, A5, A14] --> [A13] (confidence: 0.827)
[A7, A3, A5, A2] --> [A20] (confidence: 0.828)
[A3, A5, A14] --> [A13] (confidence: 0.839)
[A19, A15, A14] --> [A13] (confidence: 0.840)
[A14, A8] --> [A13] (confidence: 0.841)
[A19, A3, A14] --> [A13] (confidence: 0.846)
[A19, A4, A14] --> [A13] (confidence: 0.852)
[A5, A15, A14] --> [A13] (confidence: 0.863)
[A7, A2, A1] --> [A20] (confidence: 0.868)
```

Gambar 4 Hasil Operator Create Association Rule

Berdasarkan kedua hasil tersebut, proses analisis pola berhasil menghasilkan 55 aturan asosiasi yang memenuhi nilai minimum *support* 2% dan nilai minimum *confidence* 75%, yaitu:

- Jika membeli Deterjen, Mie, dan Shampo, maka akan membeli Bahan Dapur, dengan tingkat kepercayaan 0.751 atau 75.1% dan tingkat dukungan 0.022 atau 2.2%.
- Jika membeli Rokok, Mie, dan Pewangi, maka akan membeli Snack, dengan tingkat kepercayaan 0.751 atau 75.1% dan tingkat dukungan 0.020 atau 2%.
- Jika membeli Snack, Susu, dan Soft Drinks, maka akan membeli Rokok, dengan tingkat kepercayaan 0.752 atau 75.2% dan tingkat dukungan 0.032 atau 3.2%.
- Jika membeli Deterjen, Susu, dan Mie, maka akan membeli Bahan Dapur, dengan tingkat kepercayaan 0.754 atau 75.4% dan tingkat dukungan 0.033 atau 3.3%.
- Jika membeli Mie, Soft Drinks, dan Kopi, maka akan membeli Rokok, dengan tingkat kepercayaan 0.756 atau 75.6% dan tingkat dukungan 0.024 atau 2.4%.
- Jika membeli Bahan Dapur, Deterjen, Rokok, dan Susu, maka akan membeli Snack, dengan tingkat kepercayaan 0.761 atau 76.1% dan tingkat dukungan 0.024 atau 2.4%.
- Jika membeli Soft Drinks dan Pewangi, maka akan membeli Deterjen, dengan tingkat kepercayaan 0.762 atau 76.2% dan tingkat dukungan 0.028 atau 2.8%.
- Jika membeli Susu, Mie, dan Pembersih, maka akan membeli Bahan Dapur, dengan tingkat kepercayaan 0.763 atau 76.3% dan tingkat dukungan 0.027 atau 2.7%.
- Jika membeli Rokok, Susu, Mie, dan Soft Drinks, maka akan membeli Snack, dengan tingkat kepercayaan 0.763 atau 76.3% dan tingkat dukungan 0.021 atau 2.1%.
- Jika membeli Mie dan Permen, maka akan membeli Snack, dengan tingkat kepercayaan 0.763 atau 76.3% dan tingkat dukungan 0.027 atau 2.7%.

...
...

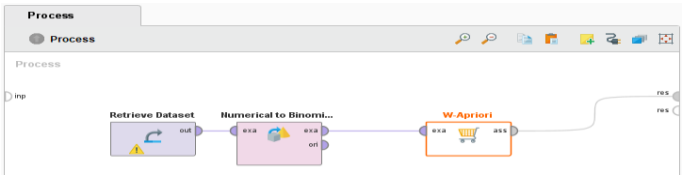
- Jika membeli Bahan Dapur, Kopi, dan Pewangi, maka akan membeli Deterjen, dengan tingkat kepercayaan 0,852 atau 85.2% dan tingkat dukungan 0,022 atau 2.2%.
- Jika membeli Mie, Pembersih, dan Pewangi, maka akan membeli Deterjen, dengan tingkat kepercayaan 0,863 atau 86.3% dan tingkat dukungan 0,021 atau 2.1%.

Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)

❖ Jika membeli Snack, Soft Drinks, dan Air Mineral, maka akan membeli Rokok, dengan tingkat kepercayaan 0,868 atau 86.8% dan tingkat dukungan 0,022 atau 2.2%.

4.4. Penerapan Algoritma Apriori

Setelah dilakukan pengujian algoritma FP-Growth menggunakan RapidMiner, tahap selanjutnya melakukan pengujian algoritma Apriori melalui RapidMiner Studio 9.10, sebagai lanjutan dari rangkaian pengujian pola asosiasi.



Gambar 5 Proses Algoritma Apriori Menggunakan RapidMiner

Berdasarkan proses algoritma FP-Growth di atas, pengelolaan dataset di RapidMiner sebagai berikut:

1. Memasukkan operator '***Retrieve Dataset***', berfungsi memanggil kembali dataset yang telah disimpan melalui operator *Retrieve*.
2. Memasukkan operator '***Numerical to Binominal***', berfungsi mengubah atribut bernilai numerik menjadi format dua kategori, seperti "*true*" dan "*false*".
3. Memasukkan operator '***W-Apriori***', berfungsi mengekstraksi frequent itemset menggunakan minimum *support* dan minimum *confidence* yang telah ditetapkan.

W-Apriori

```
Apriori
=======

Minimum support: 0.02 (159 instances)
Minimum metric <confidence>: 0.75
Number of cycles performed: 20

Generated sets of large itemsets:

Size of set of large itemsets L(1): 19

Size of set of large itemsets L(2): 137

Size of set of large itemsets L(3): 225

Size of set of large itemsets L(4): 120

Size of set of large itemsets L(5): 9

Best rules found:

  1. A1=true A2=true A7=true 204 ==> A20=true 177    conf:(0.87)
  2. A5=true A14=true A15=true 190 ==> A13=true 164    conf:(0.86)
  3. A4=true A14=true A19=true 203 ==> A13=true 173    conf:(0.85)
  4. A2=true A7=true A14=true 187 ==> A20=true 159    conf:(0.85)
  5. A3=true A14=true A19=true 253 ==> A13=true 214    conf:(0.85)
  6. A8=true A14=true 296 ==> A13=true 249    conf:(0.84)
  7. A14=true A15=true A19=true 268 ==> A13=true 225    conf:(0.84)
  8. A3=true A5=true A14=true 211 ==> A13=true 177    conf:(0.84)
  9. A2=true A3=true A5=true A7=true 198 ==> A20=true 164    conf:(0.83)
 10. A5=true A14=true A19=true 284 ==> A13=true 235    conf:(0.83)
 11. A1=true A5=true A7=true 201 ==> A20=true 166    conf:(0.83)
 12. A2=true A3=true A7=true A13=true 203 ==> A20=true 167    conf:(0.82)
 13. A14=true A19=true A20=true 237 ==> A13=true 194    conf:(0.82)
 14. A11=true A14=true 208 ==> A13=true 170    conf:(0.82)
 15. A3=true A14=true 361 ==> A13=true 293    conf:(0.81)
 16. A3=true A5=true A14=true 211 ==> A19=true 171    conf:(0.81)
 17. A2=true A3=true A7=true A19=true 200 ==> A20=true 162    conf:(0.81)
 18. A3=true A7=true A14=true 233 ==> A13=true 188    conf:(0.81)
 19. A5=true A14=true A20=true 217 ==> A13=true 175    conf:(0.81)
 20. A10=true A14=true 284 ==> A13=true 229    conf:(0.81)
 21. A3=true A14=true A20=true 219 ==> A13=true 175    conf:(0.8)
 22. A1=true A5=true A20=true 208 ==> A7=true 166    conf:(0.8)
 23. A7=true A14=true A19=true 266 ==> A13=true 211    conf:(0.79)
 24. A14=true A19=true 525 ==> A13=true 414    conf:(0.79)
 25. A2=true A3=true A13=true A20=true 212 ==> A7=true 167    conf:(0.79)
 26. A3=true A6=true 268 ==> A7=true 211    conf:(0.79)
 27. A14=true A15=true 454 ==> A13=true 357    conf:(0.79)
 28. A2=true A5=true A15=true 210 ==> A20=true 165    conf:(0.79)
 29. A3=true A5=true A13=true A20=true 210 ==> A7=true 165    conf:(0.79)
 30. A7=true A14=true A20=true 261 ==> A13=true 205    conf:(0.79)
 31. A4=true A14=true 321 ==> A13=true 252    conf:(0.79)
 32. A5=true A14=true 408 ==> A13=true 320    conf:(0.78)
 33. A2=true A7=true A13=true A19=true 216 ==> A20=true 169    conf:(0.78)
 34. A2=true A3=true A5=true 275 ==> A20=true 215    conf:(0.78)
 35. A5=true A7=true A14=true 236 ==> A13=true 184    conf:(0.78)
 36. A2=true A4=true A7=true 305 ==> A20=true 237    conf:(0.78)
 37. A2=true A14=true A20=true 210 ==> A13=true 163    conf:(0.78)
 38. A2=true A3=true A4=true 281 ==> A20=true 218    conf:(0.78)
```

Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)

```
39. A14=true 1277 ==> A13=true 989    conf:(0.77)
40. A2=true A5=true A7=true 340 ==> A20=true 263    conf:(0.77)
41. A3=true A5=true A19=true A20=true 224 ==> A7=true 173    conf:(0.77)
42. A2=true A3=true A13=true 275 ==> A20=true 212    conf:(0.77)
43. A2=true A5=true A13=true 263 ==> A20=true 202    conf:(0.77)
44. A5=true A13=true A15=true 348 ==> A19=true 267    conf:(0.77)
45. A2=true A7=true A13=true 339 ==> A20=true 260    conf:(0.77)
46. A5=true A10=true A13=true 227 ==> A19=true 174    conf:(0.77)
47. A5=true A6=true 279 ==> A7=true 213    conf:(0.76)
48. A2=true A3=true A5=true A20=true 215 ==> A7=true 164    conf:(0.76)
49. A3=true A5=true A15=true 278 ==> A19=true 212    conf:(0.76)
50. A2=true A14=true 290 ==> A13=true 221    conf:(0.76)
51. A3=true A13=true A19=true A20=true 247 ==> A7=true 188    conf:(0.76)
52. A2=true A14=true A20=true 210 ==> A7=true 159    conf:(0.76)
53. A2=true A4=true A5=true 258 ==> A20=true 195    conf:(0.76)
54. A3=true A5=true A13=true 353 ==> A19=true 266    conf:(0.75)
55. A2=true A3=true A7=true 339 ==> A20=true 255    conf:(0.75)
56. A5=true A14=true A20=true 217 ==> A7=true 163    conf:(0.75)
57. A5=true A8=true A13=true 233 ==> A19=true 175    conf:(0.75)
```

Gambar 6 Hasil Operator *W-Apriori*

Berdasarkan output pada gambar di atas yang menunjukkan hasil pengolahan data menggunakan algoritma Apriori di RapidMiner, diperoleh 57 aturan asosiasi yang memenuhi nilai minimum *support* 2% dan nilai minimum *confidence* 75%, yaitu:

- Jika membeli Air Mineral, Soft Drinks, dan Snack, maka akan membeli Rokok, dengan tingkat kepercayaan 0.87 atau 87%.
- Jika membeli Mie, Pewangi, dan Pembersih, maka akan membeli Deterjen, dengan tingkat kepercayaan 0.86 atau 86%.
- Jika membeli Kopi, Pewangi, dan Bahan Dapur, maka akan membeli Deterjen, dengan tingkat kepercayaan 0.85 atau 85%.
- Jika membeli Soft Drinks, Snack, dan Pewangi, maka akan membeli Rokok, dengan tingkat kepercayaan 0.85 atau 85%.
- Jika membeli Susu, Pewangi, dan Bahan Dapur, maka akan membeli Deterjen, dengan tingkat kepercayaan 0.85 atau 85%.
- Jika membeli Shampo dan Pewangi, maka akan membeli Deterjen, dengan tingkat kepercayaan 0.84 atau 84%.
- Jika membeli Pewangi, Pembersih, dan Bahan Dapur, maka akan membeli Deterjen, dengan tingkat kepercayaan 0.84 atau 84%.
- Jika membeli Susu, Mie, dan Pewangi, maka akan membeli Deterjen, dengan tingkat kepercayaan 0.84 atau 84%.
- Jika membeli Soft Drinks, Susu, Mie, dan Snack, maka akan membeli Rokok, dengan tingkat kepercayaan 0.83 atau 83%.
- Jika membeli Mie, Pewangi, dan Bahan Dapur, maka akan membeli Deterjen, dengan tingkat kepercayaan 0.83 atau 83%.

...
...

- Jika membeli Soft Drinks, Susu, dan Snack, maka akan membeli Rokok, dengan tingkat kepercayaan 0.75 atau 75%.
- Jika membeli Mie, Pewangi, dan Rokok, maka akan membeli Snack, dengan tingkat kepercayaan 0.75 atau 75%.
- Jika membeli Mie, Shampo, dan Deterjen, maka akan membeli Bahan Dapur, dengan tingkat kepercayaan 0.75 atau 75%.

4.5. Perbandingan Algoritma FP-Growth dan Apriori

Bagian ini menyajikan analisis perbandingan kinerja kedua algoritma berdasarkan hasil pengujian yang dilakukan menggunakan RapidMiner Studio 9.10. Perbandingan tersebut mencakup beberapa aspek utama yang menjadi dasar evaluasi performa masing-masing algoritma.

4.5.1. Perbandingan Jumlah Aturan Asosiasi

Proses pengujian terhadap dataset transaksi menghasilkan jumlah aturan yang tidak sama pada kedua algoritma. Hasil tersebut dapat dilihat pada tabel berikut.

Tabel 3 Jumlah Aturan Asosiasi

Algoritma	Jumlah Aturan	Minimum *Support*	Minimum *Confidence*
FP-Growth	55 Aturan	0.02	0.75
Apriori	57 Aturan	0.02	0.75

Perbedaan jumlah aturan menunjukkan bahwa algoritma Apriori menghasilkan aturan sedikit lebih banyak dibandingkan algoritma FP-Growth. Kondisi ini berkaitan dengan cara kerja algoritma Apriori yang

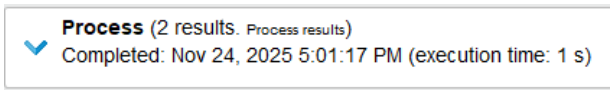
Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)

Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)
Vol. 9 No. 2, April 2026
P-ISSN 2620-8342
E-ISSN 2621-3052

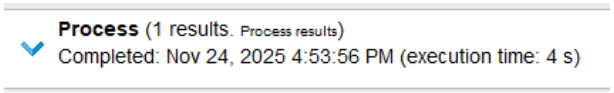
menilai kandidat *itemset* secara bertahap pada setiap tingkat, sehingga peluang kombinasi yang diterima sebagai *frequent itemsets* menjadi lebih besar. Di sisi lain, algoritma FP-Growth memamfaatkan struktur *Frequent Pattern Tree* (*FP-Tree*) untuk melakukan kompresi data, sehingga pola yang terbentuk umumnya merupakan itemset yang lebih kuat dan stabil. Walaupun perbedaannya relatif kecil, temuan ini mengindikasikan bahwa algoritma Apriori cenderung menghasilkan pencarian pola yang lebih luas, sedangkan algoritma FP-Growth lebih selektif dan efisien dalam membangun *frequent itemsets*.

4.5.2. Perbandingan Waktu Eksekusi

Waktu komputasi menjadi salah satu indikator utama untuk menilai tingkat efisiensi kedua algoritma. Durasi pemrosesan masing-masing metode diperoleh secara langsung dari eksekusi pada RapidMiner Studio 9.10. Hasilnya ditampilkan pada Gambar 7 dan Gambar 8 berikut.



Gambar 7 Waktu Eksekusi Data pada Algoritma FP-Growth



Gambar 8 Waktu Eksekusi Data pada Algoritma Apriori

Perbedaan waktu pemrosesan tersebut sejalan dengan karakteristik kerja masing-masing algoritma. Algoritma FP-Growth tidak melakukan pembangkitan kandidat itemset secara berulang, sehingga proses perhitungannya lebih ringan dan cepat. Sebaliknya, algoritma Apriori harus membentuk serta memverifikasi kandidat itemset pada setiap tahap iterasi, yang membuat waktu eksekusinya lebih panjang. Temuan ini menunjukkan bahwa algoritma FP-Growth memiliki keunggulan dari sisi efisien waktu ketika diterapkan pada dataset transaksi UKM Mart Koperasi Wanita Kasih Ibu.

4.5.3. Perbandingan Efektivitas Temuan Pola

Efektivitas kedua algoritma dievaluasi berdasarkan kemampuannya dalam menemukan pola pembelian yang relevan dan konsisten. Hasil penelitian menunjukkan bahwa algoritma FP-Growth dan Apriori mampu mengidentifikasi pola yang hampir sama, seperti keterkaitan antara produk Pewangi dan Deterjen, kombinasi Snack dan Soft Drinks yang berhubungan dengan rokok, maupun hubungan antara Susu dan Mie dengan Bahan Dapur. Rentang nilai *confidence* yang dihasilkan oleh kedua algoritma tidak menunjukkan perbedaan yang signifikan, yaitu 75%-87%. Algoritma FP-Growth menghasilkan nilai *confidence* tertinggi sebesar 86,8%, sedangkan algoritma Apriori menghasilkan nilai *confidence* tertinggi sebesar 87%. Pola-pola dominan yang muncul menunjukkan konsistensi pada kelompok produk rumah tangga, makanan ringan, dan minuman.

Perbedaan efektivitas terlihat pada cara masing-masing algoritma membentuk aturan, dimana algoritma Apriori menghasilkan lebih banyak aturan sehingga cakupan polanya lebih luas, sedangkan algoritma FP-Growth menghasilkan aturan yang lebih ringkas dan relevan tanpa adanya duplikasi. Secara keseluruhan, kedua algoritma sama-sama efektif, namun memiliki pendekatan yang berbeda dalam menggali pola pembelian.

5. Kesimpulan

Berdasarkan hasil analisis dan pengujian yang dilakukan terhadap kedua algoritma, dapat dirumuskan beberapa kesimpulan sebagai berikut.

Penerapan algoritma FP-Growth dan Apriori dalam menganalisis pola pembelian konsumen pada data transaksi penjualan di UKM Mart Koperasi Wanita Kasih Ibu menunjukkan bahwa kedua metode mampu mengidentifikasi hubungan antarproduk yang sering dibeli secara bersamaan. Algoritma FP-Growth menghasilkan 55 aturan asosiasi, sementara algoritma Apriori menghasilkan 57 aturan asosiasi dengan parameter minimum support 0,02 dan minimum confidence 0,75. Pola-pola yang muncul dari kedua algoritma menunjukkan konsistensi, seperti hubungan antara Pewangi dan Deterjen, Snack dan Rokok, serta Mie dan Bahan Dapur. Hasil ini membuktikan bahwa kedua algoritma bekerja dengan baik dalam menemukan pola pembelian yang relevan dan dapat digunakan sebagai dasar pengambilan keputusan terkait pengelolaan stok dan strategi penataan produk.

Berdasarkan hasil perbandingan, algoritma FP-Growth menunjukkan efisiensi yang lebih tinggi dibandingkan algoritma Apriori, khususnya pada aspek waktu eksekusi. Algoritma FP-Growth mampu memproses data dalam waktu 1 detik, sedangkan algoritma Apriori membutuhkan waktu sekitar 4 detik. Meskipun algoritma Apriori menghasilkan jumlah aturan asosiasi yang sedikit lebih banyak, hasil yang diperoleh cenderung lebih redundan. Sebaliknya, FP-Growth menghasilkan pola yang lebih ringkas dan padat

Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)

Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)
Vol. 9 No. 2, April 2026
P-ISSN 2620-8342
E-ISSN 2621-3052

karena tidak melakukan pembangkitan kandidat itemset secara berulang, melainkan memanfaatkan struktur Frequent Pattern Tree (FP-Tree). Oleh karena itu, FP-Growth lebih unggul dari sisi efisiensi dan kecepatan pemrosesan, sedangkan Apriori tetap bermanfaat untuk eksplorasi pola yang lebih luas. Ditinjau dari perhitungan manual, kedua algoritma memiliki kelebihan dan kekurangan yang dipengaruhi oleh ukuran data. Pada data berukuran besar, algoritma FP-Growth relatif sulit diterapkan secara manual karena proses pembentukan FP-Tree yang kompleks, memerlukan waktu lama, serta membutuhkan ruang yang besar, sedangkan algoritma Apriori lebih mudah dipahami tahapannya meskipun prosesnya lambat akibat banyaknya kombinasi itemset yang dihasilkan. Namun, pada data berukuran kecil, kedua algoritma dapat dihitung secara manual dengan relatif cepat karena kompleksitas proses masih dapat dikendalikan. Dengan demikian, FP-Growth lebih direkomendasikan untuk pengolahan data skala besar berbasis sistem, sementara Apriori sesuai digunakan untuk analisis data berskala kecil dan pemahaman konseptual.

Daftar Pustaka

[1] Y. Andini *et al.*, “Penerapan Data Mining Terhadap Tata Letak Buku di Perpustakaan Sintong Bingei Pematangsiantar Menggunakan Metode Apriori,” *J. Technol. Informatics Comput. Syst.*, vol. XI, no. 1, pp. 9–15, 2022.

[2] A. N. Ridho, A. P. A. Masa, and P. P. Widagdo, “IMPLEMENTASI MARKET BASKET ANALYSIS PADA DATA PENJUALAN CV . XYZ MENGGUNAKAN ALGORITMA FP-GROWTH,” vol. 12, no. 3, 2024.

[3] G. B. Atmaja and R. Rachman, “PERBANDINGAN ALGORITMA APRIORI DAN FP-GROWTH PADA ANALISIS PERILAKU KONSUMEN TERHADAP PEMBELIAN DATA ELEKTRONIK,” *J. Inform. Teknol. dan Sains*, vol. 7, no. 1, pp. 298–307, 2025, [Online]. Available: http://www.jurnal.uts.ac.id/index.php/JINTEKS/article/view/4850

[4] S. Syahidin and A. Adnan, “Analisis Pengaruh Harga Dan Lokasi Terhadap Kepuasan Pelanggan Pada Bengkel Andika Teknik Kemili Bebesen Takengon,” *Gajah Putih J. Econ. Rev.*, vol. 4, no. 1, pp. 20–32, 2022, doi: 10.55542/gpjer.v4i1.209.

[5] S. K. Sianturi, D. S. Fansuri, and W. N. Aini, “Algoritma Apriori untuk Mengetahui Pola Beli Konsumen Pada Sistem Informasi Market Basket Analysis Berbasis Andriod,” *J. Insa. Unggul*, vol. 11, no. 1, pp. 35–58, 2023, doi: 10.47926/jiu.2023.11.1.35-58.

[6] Y. Hendra, P. Sakinah, and M. Thoriq, “Evaluasi Kinerja Algoritma Apriori Dalam Pengelompokan Data Transaksi Penjualan Untuk Analisis Pola Pembelian,” *J. Student Dev. Inf. Syst.*, vol. 3, no. 2, pp. 114–122, 2023.

[7] N. Oktaviani, “Implementasi Algoritma Apriori Untuk Analisis Pola Pembelian Konsumen Pada Toko Serba,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 3, pp. 3706–3711, 2024, doi: 10.35889/jutisi.v13i1.1778.

[8] M. G. Saparudin and S. Sholihin, “Penggunaan Data Mining untuk Analisis Pola Pembelian Pelanggan Menggunakan Metode Association Rule Algoritma Apriori (Studi Kasus di Toko Waspada),” *J. Teknol. Sist. Inf. dan Apl.*, vol. 6, no. 1, pp. 27–33, 2023, doi: 10.32493/jtsi.v6i1.26927.

[9] C. I. Wiryawan, D. Nugroho, and Y. R. W. Utami, “Algoritma Apriori Untuk Penentuan Assosiasi Penjualan Barang,” *J. Teknol. Inf. dan Komun.*, vol. 9, no. 1, pp. 7–16, 2021, doi: 10.30646/tikomsin.v9i1.538.

[10] F. Ointu, A. Lasarudin, and W. Hasyim, “Optimasi Data Rekam Medis Pasien Rawat Inap BPJS RSUD Tombulilato Dengan Algoritma K-Means Dan FP-Growth,” pp. 1–8, 2025.

[11] A. R. Kawengian, I. H. Lahay, and J. D. Giu, “Redesain Tata Letak Produk Berdasarkan Market Basket Analysis,” *JISI J. Integr. Sist. Ind.*, vol. 12, no. 1, pp. 49–58, 2025, doi: 10.24853/jisi.12.1.49-58.

[12] E. Hidayat, “Strategi Koperasi Unit Desa Mulya Usaha Kelurahan Talang Benih Dalam Upaya Menarik Minat Masyarakat Menggunakan Produk Koperasi,” *Dr. Diss. Inst. Agama Islam Negeri Curup*, pp. 1–72, 2023.

[13] D. B. Srisulistiowati, M. Khaerudin, and S. Rejeki, “Sistem Informasi Prediksi Penjualan Alat Tulis Kantor Dengan Metode Fp-Growth (Studi Kasus Toko Koperasi Sekolah Bina Mulia),” *JSI (Jurnal Sist. Informasi) Univ. Suryadarma*, vol. 8, no. 2, pp. 243–256, 2021, doi: 10.35968/jsi.v8i2.739.

Copyright © Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)