

Perbandingan Algoritma Apriori dan FP-Growth dalam Analisis Pola Pembelian Konsumen

Sari Agustin ^{✉1}, Admi Salma²

Program Studi Statistika, Universitas Negeri Padang, Indonesia¹

Program Studi Statistika, Universitas Negeri Padang, Indonesia²

email: sariagustin892@gmail.com¹, admisalma1@fmipa.unp.ac.id²

Received 09 Feb 2026, Accepted 31 Maret 2026, Published 31 Maret 2026

Abstrak

Penelitian ini bertujuan untuk menganalisis pola pembelian konsumen serta membandingkan kinerja algoritma Apriori dan FP-Growth dalam penambangan aturan asosiasi pada data transaksi penjualan produk cat Avian di PT. XYZ. Data yang digunakan merupakan data sekunder transaksi penjualan periode Januari hingga Maret 2025. Metode yang diterapkan adalah *association rule mining* dengan tahapan *Knowledge Discovery in Databases* (KDD), meliputi *data cleaning*, *data selection*, *data transformation*, *data mining*, dan *pattern evaluation*. Parameter evaluasi yang digunakan mencakup nilai support, confidence, lift ratio, jumlah aturan asosiasi, serta waktu eksekusi algoritma. Hasil penelitian menunjukkan bahwa kedua algoritma menghasilkan jumlah aturan asosiasi yang sama dengan nilai rata-rata *confidence* sebesar 96,3% dan *lift ratio* sebesar 4,82, yang mengindikasikan hubungan positif antar produk. Namun, dari sisi efisiensi waktu pemrosesan, algoritma FP-Growth memiliki waktu eksekusi yang lebih cepat dibandingkan algoritma Apriori. Temuan ini menunjukkan bahwa FP-Growth lebih efisien dalam pengolahan data, sementara Apriori tetap relevan dari sisi interpretabilitas hasil. Pola pembelian yang dihasilkan dapat dimanfaatkan oleh perusahaan dalam penyusunan strategi pemasaran, *cross-selling*, *bundling* produk, serta pengelolaan persediaan berbasis data.

Kata Kunci: association rule mining; Apriori; FP-Growth; pola pembelian; data transaksi

Abstract

This study aims to analyze consumer purchasing patterns and compare the performance of the Apriori and FP-Growth algorithms in association rule mining using transaction data of Avian paint products at PT. XYZ. The data used in this research are secondary sales transaction data from January to March 2025. The research method applies association rule mining based on the Knowledge Discovery in Databases (KDD) framework, including data cleaning, data selection, data transformation, data mining, and pattern evaluation stages. Evaluation parameters consist of support, confidence, lift ratio, number of association rules, and execution time. The results indicate that both algorithms generate the same number of association rules with an average confidence value of 96.3% and an average lift ratio of 4.82, indicating strong positive correlations among products. However, FP-Growth demonstrates a slightly faster execution time compared to Apriori, suggesting better computational efficiency. These findings imply that FP-Growth is more efficient in processing transaction data, while Apriori remains advantageous in terms of result interpretability. The extracted purchasing patterns can support data-driven marketing strategies, such as cross-selling, product bundling, and inventory management.

Keywords: association rule mining; Apriori; FP-Growth; purchasing patterns; transaction data

✉ Corresponding author

PENDAHULUAN

Perkembangan teknologi informasi dan sistem pencatatan transaksi telah mendorong perusahaan di sektor perdagangan, distribusi, dan ritel untuk mengelola data dalam jumlah yang semakin besar. Data transaksi yang tersimpan secara digital sebenarnya memiliki potensi besar untuk dimanfaatkan sebagai dasar pengambilan keputusan strategis [1]. Namun, dalam praktiknya, banyak perusahaan masih menghadapi permasalahan berupa melimpahnya data tanpa diimbangi dengan pemanfaatan informasi yang optimal. Kondisi ini dikenal sebagai *rich of data but poor of information*, yaitu situasi ketika data tersedia dalam jumlah besar tetapi belum diolah secara sistematis untuk menghasilkan pengetahuan yang bernilai bagi perusahaan [2].

PT. XYZ merupakan perusahaan yang bergerak di bidang distribusi dan ritel produk kebutuhan bangunan, khususnya produk cat Avian. Karakteristik transaksi penjualan di perusahaan ini relatif kompleks karena setiap transaksi dapat melibatkan lebih dari satu jenis produk dengan variasi ukuran dan jumlah yang beragam. Selama ini, data transaksi penjualan lebih banyak dimanfaatkan sebagai laporan administratif harian, bulanan, atau tahunan, tanpa dilakukan analisis lanjutan untuk menggali pola pembelian konsumen. Akibatnya, perusahaan berpotensi kehilangan peluang strategis dalam menyusun kebijakan pemasaran, pengelolaan persediaan, serta optimalisasi penjualan [3][4].

Permasalahan tersebut menjadi semakin krusial di tengah kondisi ekonomi yang dinamis dan cenderung mengalami perlambatan dalam beberapa tahun terakhir. Perusahaan dituntut untuk lebih efisien dalam mengelola stok, menghindari penumpukan produk *slow moving*, serta memastikan ketersediaan produk *fast moving*. Tanpa dukungan analisis berbasis data, risiko terjadinya *overstock* maupun *stockout* sulit dihindari dan dapat berdampak langsung terhadap kinerja keuangan perusahaan. Oleh karena itu, diperlukan pendekatan analitis yang mampu mengungkap pola pembelian konsumen secara objektif dan berbasis data transaksi aktual [5].

Salah satu pendekatan yang banyak digunakan untuk menganalisis perilaku pembelian konsumen adalah *association rule mining* atau *market basket analysis*. Teknik ini bertujuan untuk mengidentifikasi hubungan antar produk yang sering dibeli secara bersamaan oleh konsumen [6]. Informasi yang dihasilkan dari analisis ini dapat digunakan sebagai dasar dalam penyusunan strategi *bundling*, *cross-selling*, penataan produk, serta pengelolaan persediaan yang lebih efektif. Dalam konteks *data mining*, algoritma Apriori dan FP-Growth merupakan dua algoritma yang paling populer dan banyak diterapkan dalam penambangan aturan asosiasi [7].

Algoritma Apriori dikenal sebagai metode klasik yang memanfaatkan prinsip antimonotonisitas untuk menghasilkan *frequent itemset* dan aturan asosiasi [8]. Keunggulan utama algoritma ini terletak pada kesederhanaan konsep dan kemudahan interpretasi hasil, sehingga cocok digunakan sebagai dasar pengambilan keputusan oleh pihak manajemen. Namun, Apriori memiliki kelemahan dari sisi efisiensi komputasi karena memerlukan pembangkitan kandidat itemset dalam jumlah besar, terutama ketika diterapkan pada dataset dengan variasi produk yang tinggi [9].

Sebagai alternatif, algoritma FP-Growth dikembangkan untuk mengatasi keterbatasan Apriori dengan menghilangkan proses pembangkitan kandidat itemset.

FP-Growth memanfaatkan struktur data FP-tree yang terkompresi sehingga mampu menambang *frequent itemset* dengan waktu pemrosesan yang lebih efisien[10]. Sejumlah penelitian terdahulu menunjukkan bahwa FP-Growth unggul dari sisi kecepatan pemrosesan, khususnya pada dataset berskala besar dan kompleks, sementara Apriori tetap memiliki keunggulan dari sisi interpretabilitas hasil aturan asosiasi [11].

Beberapa penelitian sebelumnya telah membandingkan kinerja algoritma Apriori dan FP-Growth dalam berbagai konteks industri, seperti ritel pakaian, apotek, dan penjualan produk elektronik. Hasil penelitian tersebut umumnya menunjukkan bahwa tidak ada satu algoritma yang selalu unggul dalam semua kondisi. Kinerja algoritma sangat bergantung pada karakteristik data, tujuan analisis, serta kebutuhan pengguna terhadap kualitas aturan atau efisiensi komputasi [12][13][14]. Meskipun demikian, kajian perbandingan algoritma Apriori dan FP-Growth pada sektor distribusi dan ritel bahan bangunan, khususnya produk cat, masih relatif terbatas.

Meskipun demikian, terdapat beberapa keterbatasan yang menunjukkan adanya *research gap*. Pertama, sebagian besar penelitian belum mengkaji penerapan algoritma Apriori dan FP-Growth pada sektor distribusi bahan bangunan, khususnya produk cat, yang memiliki karakteristik data lebih kompleks dan heterogen. Kedua, penelitian sebelumnya cenderung hanya berfokus pada satu aspek evaluasi, seperti waktu pemrosesan atau jumlah aturan asosiasi, sehingga belum memberikan evaluasi yang komprehensif berdasarkan kombinasi indikator seperti *support*, *confidence*, dan *lift ratio* [13][14]. Ketiga, masih terbatas penelitian yang menggunakan data transaksi riil dari perusahaan distributor regional di Indonesia, sehingga hasil penelitian sebelumnya belum sepenuhnya merepresentasikan kondisi nyata di lapangan.

Berdasarkan kesenjangan tersebut, penelitian ini dilakukan untuk mengisi kekosongan kajian dengan menerapkan dan membandingkan algoritma Apriori dan FP-Growth pada data transaksi penjualan PT. XYZ. Penelitian ini tidak hanya mengevaluasi kinerja algoritma dari sisi efisiensi waktu pemrosesan, tetapi juga dari sisi kualitas aturan asosiasi yang dihasilkan melalui nilai *support*, *confidence*, dan *lift ratio*.

Tujuan dari penelitian ini adalah untuk mengidentifikasi pola pembelian konsumen berdasarkan data transaksi penjualan produk cat Avian di PT. XYZ serta menentukan algoritma yang paling sesuai dengan karakteristik data perusahaan. Hasil penelitian diharapkan dapat memberikan manfaat praktis dalam mendukung penyusunan strategi pemasaran dan pengelolaan persediaan berbasis data, serta memberikan kontribusi akademis dalam memperkaya literatur terkait penerapan association rule mining pada sektor distribusi dan ritel di Indonesia.

METODOLOGI

Penelitian ini merupakan penelitian terapan yang bertujuan untuk menerapkan teknik *data mining* secara langsung pada data transaksi penjualan guna menghasilkan informasi yang dapat dimanfaatkan dalam pengambilan keputusan bisnis. Pendekatan yang digunakan adalah *association rule mining* dengan membandingkan dua algoritma utama, yaitu Apriori dan FP-Growth, dalam menganalisis pola pembelian konsumen.

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari sistem pencatatan transaksi penjualan sebuah perusahaan distribusi dan ritel

bahan bangunan yang dalam artikel ini disamakan sebagai PT. XYZ. Data yang dianalisis merupakan data transaksi penjualan produk cat merek Avian pada periode Januari hingga Maret 2025. Setiap transaksi memuat informasi nomor faktur, jenis barang, dan jumlah (*quantity*) pembelian. Data transaksi tersebut digunakan sebagai bahan utama dalam proses analisis tanpa melibatkan data primer atau survei langsung kepada konsumen. Adapun langkah analisis menggunakan *Knowledge Discovery in Databases* (KDD) sebagai berikut:

Data Cleaning dan Data Integration

Tahap awal penelitian dimulai dengan proses pembersihan data untuk memastikan kualitas data yang digunakan. Pada tahap ini dilakukan penghapusan data duplikat, transaksi yang tidak lengkap, serta data yang tidak konsisten, seperti penulisan nama produk yang berbeda untuk item yang sama. Selanjutnya, menggabungkan data transaksi yang berasal dari sumber data yang berbeda ke dalam satu basis data terintegrasi agar dapat dianalisis secara menyeluruh.

Data Seletion

Selanjutnya dilakukan *data selection* dengan memilih atribut yang relevan dengan tujuan analisis, yaitu nomor faktur sebagai penanda transaksi dan jenis barang sebagai item yang dianalisis dalam *market basket analysis*. Atribut ukuran dan jumlah pembelian digunakan sebagai informasi pendukung, namun dalam proses penambangan pola asosiasi data difokuskan pada keberadaan item dalam suatu transaksi.

Data Transformation

Setelah data yang relevan diperoleh, dilakukan *data transformation* untuk mengubah data transaksi ke dalam format yang sesuai dengan kebutuhan *association rule mining*. Data ditransformasikan dengan cara mengelompokkan item berdasarkan nomor faktur sehingga setiap baris data merepresentasikan satu transaksi yang berisi sekumpulan item. Selanjutnya, data kuantitas dikonversi ke dalam bentuk biner, yaitu menunjukkan ada atau tidaknya suatu item dalam transaksi, tanpa mempertimbangkan jumlah pembelian. Transformasi ini dilakukan untuk menyesuaikan data dengan prinsip dasar *market basket analysis* yang berfokus pada kemunculan item secara bersamaan.

Data Mining

Data mining merupakan pendekatan ilmiah yang digunakan untuk menggali pola, hubungan, atau struktur tersembunyi dari kumpulan data berukuran besar guna menghasilkan pengetahuan yang bernilai dan mudah diinterpretasikan. Pendekatan ini berfokus pada eksplorasi data untuk menemukan informasi baru yang dapat dimanfaatkan dalam pengambilan keputusan [8]. Melalui *data mining*, data mentah diolah menjadi wawasan yang berguna, seperti pola keterkaitan, deteksi anomali, serta dukungan terhadap proses prediksi dan klasifikasi. Secara konseptual, data mining memiliki keterkaitan erat dengan berbagai disiplin ilmu, antara lain statistika, kecerdasan buatan, pembelajaran mesin, dan pengenalan pola, yang bersama-sama berperan dalam meningkatkan efektivitas pengambilan keputusan berbasis data [15].

Pada penelitian ini algoritma *data mining* yang digunakan adalah Apriori dan Fp-Growth dengan ketentuan nilai minimum *support* 2% dan minimum *confidence* 60%. Nilai *support* dapat dihitung menggunakan Persamaan 1.

$$\text{support}(A \Rightarrow B) = P(A \cup B) \quad (1)$$

Sedangkan nilai *confidence* dapat dihitung menggunakan Persamaan 2.

$$\text{confidence}(A \Rightarrow B) = P(B|A) = \frac{\text{support}(A \cup B)}{\text{support}(A)} \quad (2)$$

Selanjutnya, untuk menilai kekuatan hubungan antara dua item dalam suatu aturan asosiasi digunakan *lift ratio*. Nilai *lift* menunjukkan seberapa besar kemungkinan item B dibeli ketika item A muncul, dibandingkan dengan kemunculan item B secara acak. Nilai *lift ratio* lebih besar dari 1 menunjukkan adanya korelasi positif antar item, nilai sama dengan 1 menunjukkan hubungan independen, sedangkan nilai kurang dari 1 mengindikasikan korelasi negatif. Secara matematis, *lift ratio* dapat dihitung dengan Persamaan 3.

$$\text{Lift ratio} = \frac{\text{support}(A \cup B)}{\text{support } A \times \text{support } B} \quad (3)$$

1. Algoritma Apriori

Langkah kerja algoritma apriori pertama, mencari *frequent itemset* dari basis data transaksi, kedua menghilangkan itemset frekuensi yang rendah berdasarkan level *minimum support* yang telah ditentukan sebelumnya. Selanjutnya membangun aturan asosiasi dari itemset yang memenuhi nilai *minimum confidence* dalam basis data. Untuk membentuk kandidat itemset ada dua proses utama yang dilakukan saat mengerjakan algoritma apriori yaitu penggabungan dan pemangkasan. Pada tahap penggabungan, setiap item dikombinasikan dengan item lainnya hingga tidak terbentuk kombinasi lagi. Sedangkan pada tahap pemangkasan, hasil dari item yang dikombinasikan tadi kemudian dipangkas dengan menggunakan *minimum support* yang telah ditentukan.

2. Algoritma FP-Growth

Proses penambangan *frequent itemset* dengan algoritma FP-Growth diawali dengan pembentukan struktur FP-tree sebagai representasi terkompresi dari data transaksi. Selanjutnya, FP-Growth bekerja melalui pembentukan *conditional pattern base* yang diperoleh dari lintasan prefiks pada FP-tree untuk setiap item sebagai pola akhiran. Berdasarkan *conditional pattern base* tersebut, dibangun *conditional FP-tree* dengan mempertahankan item yang memenuhi ambang batas *minimum support*. Tahap akhir dilakukan dengan mengekstraksi *frequent itemset*, baik melalui penggabungan item pada lintasan tunggal (*single path*) maupun melalui proses pencarian secara rekursif apabila struktur pohon yang terbentuk tidak berupa lintasan tunggal.

Pattern Evaluation

Hasil dari kedua algoritma berupa sekumpulan *frequent itemset* dan aturan asosiasi dievaluasi menggunakan ukuran *support*, *confidence*, dan *lift ratio*. Selain itu, waktu pemrosesan masing-masing algoritma juga dicatat sebagai indikator efisiensi komputasi. Analisis perbandingan dilakukan dengan meninjau jumlah aturan asosiasi yang dihasilkan, nilai statistik asosiasi, serta efisiensi waktu pemrosesan untuk menentukan algoritma yang paling sesuai dengan karakteristik data transaksi yang dianalisis.

HASIL DAN PEMBAHASAN

Berikut pada Tabel 1 ditampilkan distribusi produk untuk memberikan representasi kuantitatif dari frekuensi kemunculan setiap item.

Tabel 1. Distribusi Frekuensi Item

No	Nama Produk	Frekuensi	Persentase (%)
1	Avitex Emulsion	37	35,24
2	Aian Syntetic	19	18,1
3	No Drop	17	16,19
4	Boyo	13	12,38
5	Aries Gold	9	8,57
6	Yoko Synthetic	9	8,57
7	Suzuka	1	0,95

Dengan ketentuan nilai *minimum support* 2% dan *minimum confidence* 60% diperoleh aturan asosiasi dengan menggunakan algoritma Apriori yang disajikan pada Tabel 2.

Tabel 2. Hasil Algoritma Apriori

No	Aturan Asosiasi	Support (%)	Confidence (%)	Lift Ratio
1	Suzuka → Boyo	3,85	100	3,71
2	Suzuka → No Drop	3,85	100	2,88
3	Avian Synthetic, Aries Gold → Avitex Emulsion	3,85	100	2
4	Boyo, Avian Synthetic → Aries Gold	3,85	100	5,2
5	Avian Synthetic, Aries Gold → Boyo	3,85	100	3,71
6	Boyo, Yoko Synthetic → Aries Gold	3,85	100	5,2
7	Yoko Synthetic, Aries Gold → Boyo	3,85	100	3,71
8	Boyo, Avian Synthetic → Avitex Emulsion	3,85	100	2
9	Avitex Emulsion, No Drop → Avian Synthetic	7,7	66,7	1,93
10	No Drop, Avian Synthetic → Avitex Emulsion	7,7	66,7	1,33
11	No Drop, Suzuka → Boyo	3,85	100	3,71
12	Boyo, Suzuka → No Drop	3,85	100	2,88
13	Suzuka → No Drop, Boyo	3,85	100	8,67

No	Aturan Asosiasi	Support (%)	Confidence (%)	Lift Ratio
1	Suzuka → Boyo	3,85	100	3,71
14	Avitex Emulsion, Boyo, Avian Synthetic → Aries Gold	3,85	100	5,2
15	Avitex Emulsion, Boyo, Aries Gold → Boyo	3,85	100	2,88
16	Avitex Emulsion, Avian Synthetic, Aries Gold → No Drop	3,85	100	3,71
17	Boyo, Avian Synthetic, Aries Gold → Boyo	3,85	100	2
18	Boyo, Avian Synthetic → No Drop	3,85	100	13
19	Avian Synthetic, Aries Gold → No Drop, Boyo	3,85	100	13

Hasil analisis menggunakan algoritma Apriori dengan *minimum support* 2% dan *minimum confidence* 60% menghasilkan sejumlah aturan asosiasi dengan nilai *confidence* yang didominasi 100%, yang menunjukkan hubungan keterkaitan yang sangat kuat antar produk. Nilai *support* berada pada kisaran 3,85%-7,7%, menandakan bahwa meskipun kombinasi produk tidak muncul pada seluruh transaksi, pola yang terbentuk tetap signifikan. Seluruh aturan memiliki nilai lift ratio lebih besar dari 1, sehingga mengindikasikan adanya korelasi positif antar produk. Beberapa aturan dengan nilai *lift* tinggi menunjukkan potensi kuat untuk penerapan strategi *cross-selling* dan *bundling* dalam meningkatkan efektivitas penjualan.

Berikut hasil Algoritma FP-Growth yang disajikan pada Tabel 3.

Tabel 3. Hasil Algoritma FP-Growth

No	Aturan Asosiasi	Support (%)	Confidence (%)	Lift Ratio
1	Avian Synthetic, Aries Gold → Avitex Emulsion	3,85	100	2
2	Boyo, Avian Synthetic → Aries Gold	3,85	100	5,2
3	Avian Synthetic, Aries Gold → Boyo	3,85	100	3,71
4	Avitex Emulsion, Boyo, Avian Synthetic → Aries Gold	3,85	100	5,2
5	Avitex Emulsion, Boyo, Aries Gold → Avian Synthetic	3,85	100	2,88
6	Avitex Emulsion, Avian Synthetic, Aries Gold → Boyo	3,85	100	3,71

No	Aturan Asosiasi	Support (%)	Confidence (%)	Lift Ratio
1	Avian Synthetic, Aries Gold → Avitex Emulsion	3,85	100	2
7	Boyo, Avian Synthetic, Aries Gold → Avitex Emulsion	3,85	100	2
8	Boyo, Avian Synthetic → Avitex Emulsion, Aries Gold	3,85	100	13
9	Avian Synthetic, Aries Gold → Avitex Emulsion, Boyo	3,85	100	13
10	Avitex Emulsion, No Drop → Avian Synthetic	7,7	66,7	1,93
11	No Drop, Avian Synthetic → Avitex Emulsion	7,7	66,7	1,33
12	Boyo, Yoko Synthetic → Aries Gold	3,85	100	5,2
13	Yoko Synthetic, Aries Gold → Boyo	3,85	100	3,71
14	Boyo, Avian Synthetic → Avitex Emulsion	3,85	100	2
15	Suzuka → Boyo	3,85	100	3,71
16	Suzuka → No Drop	3,85	100	2,88
17	No Drop, Suzuka → Boyo	3,85	100	3,71
18	Boyo, Suzuka → No Drop	3,85	100	2,88
19	Suzuka → No Drop, Boyo	3,85	100	8,67

Hasil penerapan algoritma FP-Growth dengan *minimum support* 2% dan *minimum confidence* 60% menghasilkan sejumlah aturan asosiasi yang didominasi oleh nilai *confidence* sebesar 100%, yang menunjukkan tingkat keterkaitan yang sangat kuat antar produk dalam transaksi. Nilai *support* yang diperoleh berada pada kisaran 3,85% hingga 7,7%, menandakan bahwa kombinasi produk tertentu relatif sering muncul secara bersamaan meskipun tidak mendominasi seluruh transaksi. Seluruh aturan asosiasi memiliki nilai *lift ratio* lebih besar dari 1, yang mengindikasikan adanya korelasi positif antar produk. Beberapa aturan dengan nilai *lift* yang tinggi, khususnya yang melibatkan kombinasi Avian Synthetic, Aries Gold, Avitex Emulsion, dan Boyo, menunjukkan potensi besar untuk penerapan strategi *cross-selling* dan *bundling* dalam meningkatkan kinerja penjualan.

Perbandingan kedua algoritma dilakukan untuk mengukur efesiensi dan efektivitas kedua algoritma dalam menghasilkan aturan asosiasi. Beberapa parameter yang digunakan adalah waktu eksekusi, jumlah aturan yang dihasilkan, *average confident* dan *average lift ratio*.

Tabel 3. Perbandingan Apriori dan FP-Growth

Parameter Perbandingan	Apriori	FP-Growth
Waktu Eksekusi	0,49 detik	0,44 detik
Jumlah Aturan	18	18
<i>Average Confident</i>	96,3	96,3
<i>Average Lift Ratio</i>	4,82	4,82

Berdasarkan Tabel 3, algoritma Apriori dan FP-Growth menghasilkan jumlah aturan asosiasi yang sama, yaitu sebanyak 18 aturan, dengan nilai *average confidence* dan *average lift ratio* yang identik, masing-masing sebesar 96,3% dan 4,82. Hal ini menunjukkan bahwa kedua algoritma mampu mengekstraksi pola asosiasi dengan tingkat kekuatan dan keterandalan yang setara. Namun, dari aspek efisiensi waktu komputasi, FP-Growth memiliki waktu eksekusi yang sedikit lebih cepat dibandingkan Apriori, yaitu 0,44 detik berbanding 0,49 detik. Perbedaan ini mengindikasikan bahwa FP-Growth lebih efisien dalam pemrosesan data, meskipun pada dataset yang digunakan keunggulan kinerjanya belum terlihat secara signifikan.

SIMPULAN

Berdasarkan hasil analisis dan pembahasan, dapat disimpulkan bahwa algoritma Apriori dan FP-Growth sama-sama mampu mengidentifikasi pola pembelian konsumen secara efektif pada data transaksi penjualan produk cat Avian di PT. XYZ. Kedua algoritma menghasilkan jumlah aturan asosiasi yang sama dengan tingkat *confidence* dan *lift ratio* yang identik, sehingga menunjukkan kualitas aturan yang setara. Namun, dari sisi efisiensi komputasi, algoritma FP-Growth memiliki waktu eksekusi yang lebih cepat dibandingkan Apriori, meskipun perbedaannya tidak terlalu signifikan pada dataset yang digunakan. Pola asosiasi yang diperoleh menunjukkan adanya keterkaitan yang kuat antar produk, yang dapat dimanfaatkan perusahaan dalam menyusun strategi pemasaran, *cross-selling*, *bundling* produk, serta pengelolaan persediaan yang lebih optimal dan berbasis data.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada PT. XYZ yang telah memberikan akses data transaksi penjualan sehingga penelitian ini dapat dilaksanakan dengan baik. Penulis juga menyampaikan apresiasi kepada Program Studi Statistika Universitas Negeri Padang atas dukungan akademik yang diberikan selama proses penelitian dan penulisan artikel ini.

DAFTAR PUSTAKA

- [1] R. Rusnandi, S. Suparni, and A. B. Pohan, "Penerapan Data Mining Untuk Analisis Market Basket Dengan Algoritma Fp-Growth Pada Pd Pasar Tohaga," *J. Nas. Pendidik. Tek. Inform.*, vol. 9, no. 1, p. 119, 2020, doi: 10.23887/janapati.v9i1.19349.
- [2] D. A. Istiqomah, Y. Astuti, and S. Nurjanah, "Implementasi algoritma fp-growth dan apriori untuk persediaan produk," *JIP (Jurnal Inform. Polinema)*, vol. 8, no. 2, pp. 37–42, 2022.
- [3] N. T. S. Saptadi, P. Chyan, and J. M. Leda, "Analysis of Supermarket Product Purchase Transactions With the Association Data Mining Method," vol. 7, no. 3, pp. 618–627, 2023, doi: <https://doi.org/10.29207/resti.v7i3.4844>.
- [4] F. Bao, L. Mao, Y. Zhu, C. Xiao, and C. Xu, "An Improved Evaluation Methodology for

- Mining Association Rules," *Axioms*, vol. 11, no. 1, pp. 11–17, 2021, [Online]. Available: <https://doi.org/10.3390/axioms11010017>
- [5] M. Hudori and N. T. B. Tarigan, "Pengelompokan Persediaan Barang dengan Metode FSN Analysis (Fast, Slow and Non-moving) Berdasarkan Turn Over Ratio (TOR)," vol. XI, no. 2, pp. 205–215, 2019.
 - [6] D. Rachmawati, Y. Cahyana, E. E. Awal, and S. Faisal, "Perbandingan Algoritma Apriori dan Algoritma FP-Growth dalam Menentukan Pola Penjualan Pupuk," *J. Resist.*, vol. 3, no. 1, pp. 21–31, 2024.
 - [7] F. Syah Zikri and M. Ikhsan, "The Comparison Between The Apriori Algorithm And The FP-Growth Algorithm In Determining Frequent Pattern," *INOVTEK Polbeng - Seri Inform.*, vol. 10, no. 2, pp. 615–625, 2025, doi: 10.35314/s1yanj03.
 - [8] B. Makhabel, *Learning Data Mining with R*, vol. 32, no. 3. Packt Publishing Ltd, 2015.
 - [9] 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, doi: <https://doi.org/10.51401/jinteks.v7i1.4850>.
 - [10] K. I. Lestari, S. Putra, and E. Rilvani, "Permasalahan Efisiensi Algoritma Apriori dan Evaluasi Fp-Growth Berdasarkan Studi Literatur," *J. Media Akad.*, vol. 3, no. 7, pp. 1–15, 2025, doi: <https://doi.org/10.62281/v3i7.2538>.
 - [11] I. F. Rahman and D. Riana, "Market Basket Analysis untuk Penjualan Retail : Perbandingan Akurasi Algoritma Apriori dan FP-Growth Berbasis CRISP-DM," *J. Algoritma.*, vol. 22, no. 1, pp. 468–479, 2025, doi: 10.33364/algoritma/v.22-1.2303.
 - [12] Fajrawati, W. Firgiawan, and N. Nur, "Perbandingan Kinerja Algoritma Apriori dan Frequent Pattern Growth dalam Menemukan Pola Asosiasi," *J. Tekno Kompak*, vol. 19, no. 2, pp. 168–182, 2025, doi: 10.33365/jtk.v19i2.128.
 - [13] Y. Husain, E. D. Oktaviyani, and S. Christina, "Analisis Perbandingan Algoritma Apriori , FP-Growth , dan Eclat dalam Menemukan Pola Pembelian Konsumen," vol. 3, no. 2, pp. 231–243, 2023, doi: <https://doi.org/10.24002/konstelasi.v3i2.7007>.
 - [14] M. Arifin, F. Helmi, and Iddrus, "Analisis Perbandingan Algoritma Asosiasi Data Mining Pada Minimarket Adi Poday Dengan Google Collab," *Junal Algoritma.*, vol. 22, no. 1, pp. 103–114, 2025, doi: 10.33364/algoritma/v.22-1.2177.
 - [15] J. Han, M. Kamber, and J. Pei, *Data Mining Concepts and Techniques Third Edition*. Elsevier, 2012.