

PERBANDINGAN APRIORI DAN FP-GROWTH DALAM PEMBUATAN ATURAN ASOSIASI PEMBELIAN PRODUK BAKERY BERBASIS CRISP-DM

COMPARING APRIORI AND FP-GROWTH FOR ASSOCIATION RULE MINING OF BAKERY PURCHASES A CRISP-DM BASED APPROACH

Vivian¹, Jong Jek Siang², Halim Budi Santoso³

Universitas Kristen Duta Wacana^{1,2,3}

jjsiang@staff.ukdw.ac.id¹

ABSTRACT

This study compares the performance of Apriori and FP-Growth algorithms in extracting association rules from a bakery sales transaction dataset sourced from Kaggle, consisting of 2,654 transactions and 23 product types. The comparison covers the number of frequent itemsets, number of association rules, average support, confidence, lift, and execution time. All analyses were conducted using Python with the pandas and mlxtend libraries under identical computing conditions to ensure fair comparison. The data were processed using one-hot encoding and analyzed with a minimum support of 5% and a minimum confidence of 50%. The results show that both algorithms produced 43 frequent itemsets and 18 identical association rules, with an average support of 0.1319, average confidence of 0.7454, and average lift of 1.0876. The execution time of Apriori was approximately 0.00379 seconds, while FP-Growth required approximately 0.00397 seconds. These findings indicate that for the analyzed dataset, both algorithms yield equivalent rule quality with only marginal differences in execution time.

Keywords: CRISP-DM, Market Basket Analysis, Apriori, FP-Growth, Association Rules, Bakery

ABSTRAK

Penelitian ini membandingkan performa algoritma Apriori dan FP-Growth dalam mengekstraksi aturan asosiasi dari dataset transaksi penjualan bakery yang bersumber dari Kaggle, terdiri atas 2.654 transaksi dan 23 jenis produk. Perbandingan meliputi jumlah frequent itemset, jumlah aturan asosiasi, nilai rata-rata support, confidence, dan lift, serta waktu eksekusi algoritma. Seluruh proses analisis dilakukan menggunakan perangkat lunak Python dengan pustaka *pandas* dan *mlxtend* pada lingkungan komputasi yang identik untuk memastikan perbandingan yang adil. Data diproses menggunakan *one-hot encoding* dan dianalisis dengan parameter minimum support sebesar 5% dan minimum confidence sebesar 50%. Hasil percobaan menunjukkan bahwa kedua algoritma menghasilkan 43 frequent itemset dan 18 aturan asosiasi yang identik, dengan rata-rata support sebesar 0.1319, rata-rata confidence sebesar 0.7454, dan rata-rata lift sebesar 1.0876. Waktu eksekusi Apriori tercatat sekitar 0.00379 detik, sedangkan FP-Growth sekitar 0.00397 detik. Temuan ini menunjukkan bahwa pada dataset yang dianalisis, kedua algoritma memiliki kinerja yang setara dalam kualitas aturan asosiasi, dengan perbedaan waktu eksekusi yang relatif kecil.

Kata Kunci: CRISP-DM, Market Basket Analysis, Apriori, FP-Growth, Aturan Asosiasi, Bakery

PENDAHULUAN

Pengambilan keputusan berbasis data menjadi aspek penting dalam pengelolaan bisnis ritel modern, termasuk pada sektor bakery yang memiliki karakteristik transaksi harian dengan variasi produk yang relatif beragam. Setiap transaksi penjualan menyimpan informasi mengenai kebiasaan dan preferensi konsumen yang dapat dianalisis untuk memahami pola pembelian produk secara lebih mendalam. Salah satu pendekatan yang banyak digunakan untuk menganalisis data transaksi tersebut adalah Market Basket Analysis (MBA), yaitu

teknik analisis yang bertujuan mengidentifikasi keterkaitan antar produk yang sering dibeli secara bersamaan dalam satu transaksi (Brighton & Hariyanto, 2024; Qoni'ah & Priandika, 2020). Hasil analisis ini dapat dimanfaatkan sebagai dasar pengambilan keputusan terkait penataan produk, promosi, maupun strategi penjualan.

Dalam MBA, *Association Rule Mining* digunakan untuk mengekstraksi pola keterkaitan antar item melalui pembentukan aturan asosiasi. Algoritma Apriori dan FP-Growth merupakan dua

algoritma yang paling umum diterapkan untuk tujuan tersebut. Apriori bekerja dengan prinsip iteratif dalam membentuk kandidat itemset berdasarkan nilai minimum support dan confidence, sehingga mudah dipahami dan diimplementasikan, namun cenderung kurang efisien ketika jumlah transaksi dan kombinasi item meningkat. Sebaliknya, FP-Growth dikembangkan untuk mengatasi keterbatasan tersebut dengan menggunakan struktur FP-Tree sehingga proses pencarian frequent itemset dapat dilakukan tanpa pembentukan kandidat secara eksplisit (Musdalifah & Jananto, 2022; Rahayu et al., 2021).

Penelitian-penelitian terdahulu menunjukkan bahwa perbedaan karakteristik dataset berpengaruh terhadap perilaku komputasi kedua algoritma tersebut. Husain et al. (2023) melaporkan bahwa FP-Growth menunjukkan efisiensi komputasi yang lebih baik pada dataset ritel berskala besar dengan jumlah transaksi yang sangat tinggi, sedangkan Apriori masih banyak digunakan pada studi dengan jumlah transaksi dan item yang lebih terbatas karena kemudahan interpretasi hasil dan implementasinya (Prasetya et al., 2022; Qoni'ah & Priandika, 2020). Rahayu et al. (2021) juga menunjukkan bahwa pada dataset berukuran kecil hingga menengah, kedua algoritma cenderung menghasilkan aturan asosiasi dengan kualitas yang setara, sementara perbedaan waktu komputasi tidak selalu signifikan. Temuan-temuan ini mengindikasikan bahwa hasil perbandingan algoritma perlu dipahami dalam konteks ukuran dan karakteristik data yang digunakan.

Penelitian ini bertujuan untuk membandingkan kinerja algoritma Apriori dan FP-Growth dalam membuat aturan asosiasi pembelian produk bakery, ditinjau dari kualitas aturan asosiasi dan efisiensi komputasi. Analisis dilakukan menggunakan data transaksi sebuah bakery di Korea Selatan yang melayani pembelian langsung dan layanan pengantaran melalui platform Bea Min sejak tahun 2019. Objek

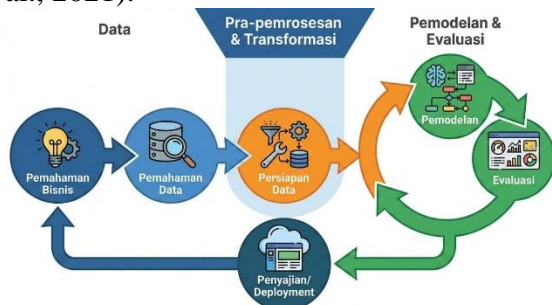
bakery dipilih karena produk bakery merupakan produk konsumsi rutin yang sering dibeli bersamaan sebagai produk pelengkap, sehingga relevan untuk analisis pola asosiasi pembelian. Data yang digunakan merupakan dataset publik transaksi penjualan bakery yang diperoleh dari Kaggle dan merepresentasikan transaksi nyata dengan jumlah transaksi dan variasi item yang relatif terbatas, sehingga dapat dikategorikan sebagai dataset berukuran kecil hingga menengah sebagaimana umum digunakan dalam studi Market Basket Analysis ritel (Husain et al., 2023; Rahayu et al., 2021). Dataset tersebut tersedia pada laman Kaggle: <https://www.kaggle.com/datasets/hosubjeo/ng/bakery-sales>. Penggunaan dataset publik ini memungkinkan evaluasi algoritma dilakukan secara transparan dan reproduksibel.

Untuk memastikan proses analisis dilakukan secara sistematis dan terstruktur, penelitian ini menerapkan metodologi CRISP-DM (*Cross Industry Standard Process for Data Mining*) sebagai kerangka kerja penelitian. CRISP-DM digunakan untuk mengarahkan tahapan penelitian mulai dari pemahaman data, persiapan data, pemodelan menggunakan algoritma Apriori dan FP-Growth, hingga evaluasi hasil perbandingan secara konsisten (Keristina & Ependi, 2025; Rahayu et al., 2021). Dengan pendekatan ini, penelitian difokuskan pada evaluasi komparatif kedua algoritma dalam konteks yang terkendali, sehingga dapat memberikan gambaran yang jelas mengenai karakteristik dan implikasi penggunaan Apriori dan FP-Growth pada analisis Market Basket Analysis di sektor bakery.

METODE

Penelitian ini menggunakan metodologi CRISP-DM (*Cross Industry Standard Process for Data Mining*) sebagai kerangka kerja utama dalam melakukan analisis dan perbandingan algoritma Apriori dan FP-Growth. Pemilihan CRISP-DM didasarkan pada kemampuannya

dalam menyediakan alur kerja yang sistematis dan terstruktur, sehingga setiap tahapan analisis data dapat dilakukan secara konsisten dan dapat direplikasi. Metodologi ini juga banyak digunakan dalam penelitian data mining yang berfokus pada evaluasi performa algoritma, termasuk dalam konteks Market Basket Analysis (Musdalifah & Jananto, 2022; Rahayu et al., 2021).



Gambar 1. flowchart CRISP-DM

Data dan Karakteristik Dataset

Data yang digunakan dalam penelitian ini berasal dari dataset publik transaksi penjualan sebuah toko bakery kecil di Korea Selatan yang tersedia melalui platform Kaggle. Dataset ini merepresentasikan transaksi penjualan bakery yang melayani pembelian langsung dan pengantaran melalui platform Bea Min sejak Juli 2019. Data yang dianalisis merupakan hasil cleaning dan preprocessing yang disimpan dalam file *Bakery_Sales.xlsx* untuk memastikan konsistensi input pada seluruh eksperimen.

Dataset akhir terdiri dari 2.654 transaksi dengan 23 jenis produk bakery yang berbeda. Setiap baris data merepresentasikan satu transaksi. Kolom produk menunjukkan keberadaan item dalam transaksi tersebut. Untuk keperluan Market Basket Analysis, data dikonversi ke dalam bentuk matriks transaksi-item biner, di mana nilai 1 menunjukkan bahwa suatu produk dibeli dalam transaksi tertentu dan nilai 0 menunjukkan sebaliknya. Kolom yang digunakan dalam analisis adalah kolom-kolom produk, sementara kolom lain seperti identitas transaksi dan waktu transaksi hanya digunakan pada tahap

eksplorasi awal dan tidak dilibatkan dalam pemodelan asosiasi.

Produk bakery dipilih sebagai konteks penelitian karena memiliki karakteristik konsumsi harian dan kombinasi pembelian yang relatif stabil, sehingga cocok untuk analisis pola pembelian berulang. Selain itu, jumlah item yang tidak terlalu besar memungkinkan evaluasi yang lebih terkontrol terhadap perbedaan perilaku algoritma Apriori dan FP-Growth.

Pra-pemrosesan dan transformasi Data

Tahap pra-pemrosesan dilakukan untuk memastikan kualitas dan keseragaman data sebelum dilakukan pemodelan. Proses ini mencakup pemeriksaan nilai hilang, penghapusan duplikasi transaksi, serta normalisasi penamaan produk agar tidak terjadi perbedaan representasi untuk item yang sama. Selanjutnya, data transaksi yang awalnya berbentuk daftar item per transaksi ditransformasikan ke dalam format one-hot encoding sehingga dapat digunakan sebagai input bagi algoritma Apriori dan FP-Growth.

Hasil akhir dari tahap ini adalah sebuah dataset matriks biner berukuran 2.654×23 yang merepresentasikan seluruh transaksi dan produk secara konsisten. Dataset hasil pra-pemrosesan ini digunakan sebagai input yang sama persis untuk kedua algoritma, sehingga perbandingan kinerja yang dilakukan tidak dipengaruhi oleh perbedaan data atau format input. Dengan demikian, perbedaan hasil yang muncul sepenuhnya berasal dari karakteristik algoritma yang digunakan.

Seluruh tahapan pra-pemrosesan ini selaras dengan fase *Data Understanding* dan *Data Preparation* pada CRISP-DM, di mana tujuan utama adalah menghasilkan data yang siap dianalisis dan sesuai dengan kebutuhan pemodelan association rule mining.

Pemodelan, Parameter, dan Evaluasi

Tahap pemodelan dilakukan dengan menerapkan algoritma Apriori dan FP-Growth pada dataset hasil pra-pemrosesan. Kedua algoritma dijalankan menggunakan parameter yang sama, yaitu minimum support sebesar 0.05 dan minimum confidence sebesar 0.50, dengan panjang maksimum itemset dibatasi hingga tiga item. Pemilihan nilai minimum support 5% didasarkan pada praktik umum dalam analisis ritel untuk menyaring pola yang terlalu jarang dan kurang relevan secara operasional, sementara nilai confidence 50% digunakan sebagai ambang moderat untuk memastikan kekuatan aturan asosiasi yang terbentuk (Musdalifah & Jananto, 2022; Qoni'ah & Priandika, 2020).

Selain eksperimen utama dengan confidence 50%, dilakukan pula percobaan tambahan dengan nilai confidence yang lebih tinggi untuk mengamati perubahan jumlah aturan dan kekuatan asosiasi. Pendekatan ini bertujuan untuk mengevaluasi sensitivitas hasil terhadap perubahan parameter serta memastikan bahwa kesimpulan tidak hanya bergantung pada satu konfigurasi ambang batas.

Implementasi pemodelan dilakukan menggunakan bahasa pemrograman Python dengan bantuan pustaka *mlxtend* untuk fungsi Apriori dan FP-Growth, serta *pandas* untuk pengolahan data. Waktu eksekusi dicatat menggunakan fungsi pengukuran waktu yang sama untuk kedua algoritma dan dijalankan pada dataset serta lingkungan komputasi yang identik, sehingga perbandingan efisiensi dapat dilakukan secara adil.

Evaluasi hasil difokuskan pada dua aspek utama, yaitu kualitas aturan asosiasi dan efisiensi komputasi. Kualitas aturan dievaluasi berdasarkan jumlah frequent itemset, jumlah aturan yang dihasilkan, serta nilai rata-rata support, confidence, dan lift. Efisiensi algoritma diukur berdasarkan waktu eksekusi yang dibutuhkan untuk menghasilkan frequent itemset dan aturan asosiasi. Selain itu, dilakukan pemeriksaan kesetaraan isi aturan untuk memastikan

apakah aturan yang dihasilkan oleh Apriori dan FP-Growth tidak hanya sama secara kuantitas, tetapi juga identik dari sisi antecedent, consequent, dan nilai metriknya.

Tahap ini mencerminkan fase *Modeling* dan *Evaluation* dalam CRISP-DM, di mana hasil dari masing-masing algoritma dibandingkan secara menyeluruh untuk menilai kelebihan dan keterbatasannya. Seluruh proses analisis dan hasil akhirnya kemudian disiapkan untuk disajikan dalam bentuk tabel dan visualisasi pada bagian hasil dan pembahasan sebagai bentuk *Deployment* dari CRISP-DM.

HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penerapan algoritma Apriori dan FP-Growth pada data transaksi bakery serta analisis perbandingan kinerja kedua algoritma. Seluruh pengujian dilakukan menggunakan dataset, parameter, dan lingkungan pemrosesan yang identik, sehingga perbedaan hasil yang diperoleh mencerminkan karakteristik masing-masing algoritma secara adil.

Hasil Aturan Asosiasi Pembelian Produk Bakery

Penerapan algoritma Apriori dan FP-Growth dengan nilai minimum support sebesar 0.05 dan minimum confidence sebesar 0.50 menghasilkan sebanyak 18 aturan asosiasi yang memenuhi kriteria. Pemeriksaan lebih lanjut menunjukkan bahwa tidak hanya jumlah aturan yang dihasilkan oleh kedua algoritma sama, tetapi juga isi aturan tersebut identik, baik dari sisi antecedent, consequent, maupun nilai metrik asosiasi yang menyertainya. Hal ini mengindikasikan bahwa pada dataset dengan ukuran dan karakteristik seperti yang digunakan dalam penelitian ini, kedua algoritma mampu menemukan pola pembelian yang setara.

Tabel 1 menyajikan sepuluh aturan asosiasi dengan nilai confidence tertinggi yang diperoleh dari hasil analisis. Aturan

dengan kekuatan asosiasi paling signifikan adalah pembelian *jam* yang diikuti oleh pembelian *plain bread*, dengan nilai support sebesar 0.072, confidence sebesar 0.873, dan lift sebesar 2.703. Nilai lift yang jauh di atas 1 menunjukkan adanya

hubungan asosiasi yang sangat kuat antara kedua produk tersebut, yang berarti konsumen yang membeli *jam* memiliki kecenderungan yang jauh lebih besar untuk juga membeli *plain bread* dibandingkan pembelian secara acak.

Tabel 1. Aturan Asosiasi Utama dan Nilai Metriknya

No	Aturan Asosiasi	Support	Confidence	Lift	Leverage	Conviction
1	(jam) → (plain bread)	0.072344	0.872727	2.702705	0.045577	5.320002
2	(americano) → (angbutter)	0.122833	0.791262	1.064374	0.007429	1.229263
3	(orange pound) → (angbutter)	0.152977	0.782274	1.052283	0.007601	1.178515
4	(tiramisu croissant) → (angbutter)	0.226451	0.771502	1.037793	0.008247	1.122958
5	(pandoro) → (angbutter)	0.099472	0.769679	1.035342	0.003396	1.114072
6	(cacao deep) → (angbutter)	0.092313	0.758514	1.020322	0.001839	1.062562
7	(plain bread) → (angbutter)	0.244160	0.756126	1.017110	0.004107	1.052157
8	(wiener) → (angbutter)	0.100603	0.752113	1.011712	0.001165	1.035123
9	(gateau chocolat) → (angbutter)	0.055388	0.750000	1.008870	0.000487	1.026375
10	(pain au chocolat) → (angbutter)	0.165787	0.749574	1.008297	0.001364	1.024630

Dominasi produk *angbutter* sebagai consequent pada sebagian besar aturan menunjukkan bahwa produk tersebut berperan sebagai item pelengkap utama dalam transaksi bakery yang dianalisis. Pola ini mencerminkan karakteristik konsumsi bakery di Korea Selatan, di mana produk roti manis atau butter-based sering dibeli bersamaan dengan berbagai jenis roti dan minuman.

Pengaruh Variasi Nilai Confidence

Untuk melihat pengaruh perubahan nilai confidence terhadap aturan asosiasi yang dihasilkan, dilakukan pengujian menggunakan dua ambang confidence, yaitu 50% dan 60%. Variasi nilai ini digunakan untuk mengevaluasi perubahan jumlah aturan serta kekuatan asosiasi yang terbentuk, khususnya berdasarkan nilai lift dan conviction.

Tabel 2 menunjukkan bahwa peningkatan nilai minimum confidence dari 50% menjadi 60% tidak menyebabkan perubahan pada jumlah aturan asosiasi yang dihasilkan maupun pada nilai rata-rata lift dan conviction. Hal ini menunjukkan bahwa seluruh aturan yang terbentuk pada ambang confidence 50% telah memenuhi kriteria confidence yang lebih tinggi, sehingga peningkatan threshold tidak menyaring aturan tambahan. Temuan ini mengindikasikan bahwa pola pembelian

yang teridentifikasi bersifat kuat dan konsisten pada dataset bakery yang digunakan, serta relatif stabil terhadap perubahan nilai confidence dalam rentang pengujian.

Tabel 2. Perbandingan Hasil Association Rule Mining pada Variasi Nilai Confidence

Confidence	Jumlah Aturan	Rata-rata Lift	Rata-rata Conviction
50%	18	1.088	1.235
60%	18	1.088	1.235

Perbandingan Kinerja Algoritma Apriori dan FP-Growth

Perbandingan kinerja algoritma difokuskan pada efisiensi komputasi dan kualitas hasil. Dari sisi kualitas, kedua algoritma menghasilkan jumlah frequent itemset yang sama, yaitu 43 itemset, serta jumlah aturan asosiasi yang identik. Pemeriksaan manual terhadap aturan yang dihasilkan menunjukkan bahwa seluruh aturan dari Apriori memiliki pasangan yang sama persis pada hasil FP-Growth, baik dari sisi kombinasi item maupun nilai support, confidence, dan lift. Dengan demikian, tidak terdapat perbedaan kualitas hasil antara kedua algoritma pada kasus ini.

Perbedaan waktu eksekusi antara algoritma Apriori dan FP-Growth pada penelitian ini tidak menunjukkan selisih yang signifikan. Berdasarkan hasil pengukuran pada tabel 3, algoritma Apriori

membutuhkan waktu sekitar 0.0038 detik, sedangkan FP-Growth membutuhkan waktu sekitar 0.0040 detik. Kondisi ini terjadi karena ukuran dataset yang relatif kecil, yaitu 2.654 transaksi dengan 23 item, sehingga kompleksitas pencarian pola belum cukup besar untuk menonjolkan keunggulan FP-Growth dalam efisiensi komputasi. Meskipun demikian, kedua algoritma tetap menghasilkan jumlah frequent itemset dan aturan asosiasi yang identik, sehingga perbandingan difokuskan pada karakteristik algoritma dan konsistensi hasil, bukan pada keunggulan waktu komputasi semata.

Meskipun secara teoritis FP-Growth dikenal lebih efisien pada dataset besar, hasil penelitian ini menunjukkan bahwa pada dataset berukuran relatif kecil hingga menengah dengan jumlah item yang terbatas, overhead pembangunan struktur FP-Tree justru menyebabkan waktu eksekusi yang lebih lama dibandingkan Apriori. Kondisi ini menunjukkan bahwa keunggulan FP-Growth baru terasa signifikan ketika skala data jauh lebih besar dan jumlah kombinasi item meningkat secara eksponensial.

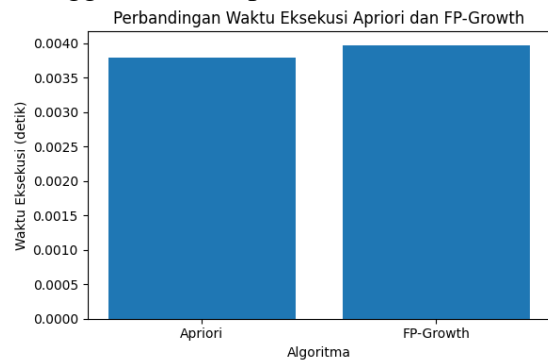
Tabel 3. Perbandingan Kinerja Apriori dan FP-Growth

Parameter	Apriori	FP-Growth
Waktu Eksekusi	0.003792	0.003970
Jumlah Frequent	43	43
Jumlah Aturan	18	18
Rata-rata	0.131911	0.131911
Rata-rata	0.745359	0.745359
Rata-rata Lift	1.087558	1.087558

Temuan ini menunjukkan bahwa pada dataset dengan ukuran dan karakteristik seperti pada penelitian ini, algoritma Apriori menunjukkan waktu eksekusi yang sedikit lebih rendah dan implementasi yang lebih sederhana, tanpa perbedaan kualitas aturan asosiasi dibandingkan FP-Growth.


Gambar 2 memperlihatkan perbandingan waktu eksekusi antara Apriori dan FP-Growth yang diperoleh dari pengukuran eksperimen. Perbedaan waktu eksekusi sangat kecil (Apriori = 0.00379 s;

FP-Growth = 0.00397 s), yang menunjukkan bahwa pada dataset berukuran relatif kecil (2.654 transaksi \times 23 item) kedua implementasi memiliki performa komputasi yang hampir setara. Oleh karena itu diskusi fokus pada kualitas aturan dan karakteristik algoritma daripada keunggulan waktu pada kasus ini.



Gambar 2. Perbandingan waktu eksekusi Apriori vs FP-Growth

Gambar 3 menyajikan visualisasi nilai lift dari aturan asosiasi utama. Visualisasi ini menunjukkan bahwa hanya satu aturan yang memiliki lift jauh di atas nilai lainnya, yaitu asosiasi antara *jam* dan *plain bread*, yang menandakan pola pembelian yang sangat kuat dan konsisten.



Gambar 3. Nilai lift untuk 10 aturan teratas

Visualisasi nilai lift pada Gambar 3 dibangun berdasarkan sepuluh aturan asosiasi dengan nilai lift tertinggi yang sama seperti yang disajikan pada Tabel 1. Pemilihan aturan didasarkan pada pengurutan nilai lift secara menurun, karena lift merepresentasikan kekuatan keterkaitan antar produk yang paling relevan secara bisnis. Hasil visualisasi menunjukkan bahwa hanya satu aturan, yaitu asosiasi antara produk *jam* dan *plain bread*, yang memiliki nilai lift jauh lebih tinggi dibandingkan aturan lainnya. Hal ini mengindikasikan adanya pola pembelian yang sangat kuat dan konsisten, sementara

sebagian besar aturan lainnya memiliki lift mendekati satu, yang menandakan hubungan yang relatif lemah meskipun memenuhi kriteria support dan confidence.

Visualisasi ini membantu memperkuat interpretasi bahwa meskipun banyak aturan yang terbentuk, hanya sebagian kecil yang memiliki kekuatan asosiasi yang sangat tinggi dan berpotensi memberikan wawasan signifikan mengenai perilaku konsumen.

SIMPULAN

Penerapan algoritma Apriori dan FP-Growth dalam kerangka CRISP-DM pada data transaksi bakery menghasilkan temuan bahwa kedua algoritma membentuk jumlah frequent itemset yang sama sebanyak 43 itemset serta menghasilkan 18 aturan asosiasi dengan isi dan struktur aturan yang identik. Nilai rata-rata metrik asosiasi yang diperoleh juga sama, yaitu support sebesar 0,1319, confidence sebesar 0,7454, dan lift sebesar 1,0876, yang menunjukkan bahwa kualitas aturan asosiasi yang dihasilkan oleh kedua algoritma berada pada tingkat yang setara. Aturan dengan kekuatan asosiasi tertinggi adalah (jam) → (plain bread) dengan nilai support 0,0723, confidence 0,8727, lift 2,7027, dan conviction 5,3200, yang mengindikasikan pola pembelian yang kuat dan konsisten pada transaksi bakery. Pada aspek efisiensi komputasi, kedua algoritma menunjukkan waktu eksekusi yang sangat berdekatan. Algoritma Apriori memiliki waktu eksekusi sekitar 0,00379 detik, sedangkan FP-Growth sekitar 0,00397 detik pada lingkungan dan parameter pemrosesan yang identik. Selisih waktu tersebut relatif kecil dan tidak menunjukkan perbedaan kinerja komputasi yang signifikan. Kondisi ini menunjukkan bahwa pada dataset berukuran kecil hingga menengah dengan jumlah item yang terbatas, kedua algoritma memiliki efisiensi komputasi yang setara. Secara keseluruhan, hasil penelitian ini menegaskan bahwa pemilihan algoritma association rule mining perlu mempertimbangkan karakteristik data dan

tujuan analisis, di mana Apriori tetap relevan dan efektif untuk analisis pola pembelian pada konteks bakery berskala terbatas, sementara FP-Growth lebih potensial digunakan pada dataset dengan skala dan kompleksitas yang lebih besar.

UCAPAN TERIMA KASIH

Terima kasih pada Fakultas Teknologi Informasi UKDW yang telah memberi bantuan dana publikasi.

DAFTAR PUSTAKA

- Brighton, K., & Hariyanto, S. (2024). Penerapan Metode Market Basket Analisis Dengan Algoritma Apriori Pada Toko Ritel Elektronik. *Bit-Tech*, 7(1), 37–46. <https://doi.org/10.32877/bt.v7i1.1417>
- Husain, Y., Oktaviyani, E. D., & Christina, S. (2023). Analisis Perbandingan Algoritma Apriori, FP-Growth, dan Eclat dalam Menemukan Pola Pembelian Konsumen. *Jurnal Konstelasi*, 3(2), 231–243. <https://doi.org/https://doi.org/10.24002/konstelasi.v3i2.7007>
- Keristina, I., & Ependi, U. (2025). ANALISIS POLA JENIS TINDAK KEJAHATAN MENGGUNAKAN ALGORITMA APRIORI ANALYSIS OF CRIME TYPE PATTERNS USING THE APRIORI ALGORITHM. *Journal of Information Technology and Computer Science (INTECOMS)*, 8(5), 1773–1741. <https://doi.org/https://doi.org/10.31539/08djcf35>
- Musdalifah, I., & Jananto, A. (2022). Analisis Perbandingan Algoritma Apriori Dan FP-Growth Dalam Pembentukan Pola Asosiasi Keranjang Belanja Pelanggan. *Progresif: Jurnal Ilmiah Komputer*, 18, 175–184. <https://doi.org/http://dx.doi.org/10.35889/progresif.v18i2.878>

- Prasetya, T., Eka Yanti, J., Irma Purnamasari, A., Rinaldi Dikananda, A., & Anwar, S. (2022). Analisis Data Transaksi Terhadap Pola Pembelian Konsumen Menggunakan Metode Algoritma Apriori. *INFORMATICS FOR EDUCATORS AND PROFESSIONALS*, 6(1), 43–52.
<https://doi.org/https://doi.org/10.51211/itbi.v6i1.1688>
- Qoni'ah, I., & Priandika, A. T. (2020). Analisis Market Basket Untuk Menentukan Asosiasi Rule Dengan Algoritma Apriori (Studi Kasus: Tb. Menara). *Jurnal Teknologi dan Sistem Informasi*, 1(2), 26–33.
<https://doi.org/https://doi.org/10.33365/jtsi.v1i2.368>
- Rahayu, V., Soedijo, B., & Amikom Yogyakarta, U. (2021). Analisis Algoritma Apriori dan FP-Growth Dalam Menemukan Pola Frequent Item Data Association Rule Pada Supermarket. *Jurnal Explore*, 11, 20–23.
<https://doi.org/https://doi.org/10.35200/ex.v11i2.46>