

Perbandingan Algoritma Apriori dan Fp-Growth dalam Pengaplikasian Market Basket Analysis untuk Strategi Bisnis Retail

Rizky Amelia*, Darmansyah, Ahmad Maulana Rismadin

Jurusan Matematika dan Teknologi Informasi, Informatika, Institut Teknologi Kalimantan, Balikpapan, Indonesia

Email: ^{1,*}rizky.amelia@lecturer.itk.ac.id, ²darmansyah@lecturer.itk.ac.id, ³11201004@student.itk.ac.id

Email Penulis Korespondensi: rizky.amelia@lecturer.itk.ac.id

Submitted: 24/06/2024; Accepted: 28/06/2024; Published: 28/06/2024

Abstrak—Kemajuan teknologi informasi mendorong para pelaku usaha dalam menyusun strategi bisnis agar tetap kompetitif. Bisnis ritel dihadapi dengan tantangan perubahan perilaku konsumen yang mengutamakan kenyamanan dan kecepatan dalam berbelanja. Hal ini berpotensi menurunkan omset jika bisnis tidak mampu beradaptasi dengan cepat. Pendekatan yang efektif dengan menganalisis ulang data transaksi penjualan untuk memperoleh pola pembelian konsumen sehingga memberikan panduan dalam pengambilan keputusan strategis. Teknik asosiasi dalam data mining dengan model *Market Basket Analysis* dapat dikembangkan untuk menganalisis keranjang belanja dan mengidentifikasi korelasi antar *item* dalam keranjang belanja konsumen. Model ini diterapkan dengan algoritma apriori dan *fp-growth* untuk menghasilkan aturan asosiasi tersebut. *Preprocessing* dataset untuk memperoleh *frequent itemset*, lalu diterapkan *association rules* untuk mengidentifikasi korelasi atau pola yang signifikan dari sekumpulan dataset yang digunakan. Algoritma apriori dan *fp-growth* dengan minimum *support* dan minimum *confidence* yang ditetapkan, kemudian tahap interpretasi melibatkan pengujian dan pemeriksaan untuk verifikasi kesesuaian pola yang ditemukan dengan fakta atau hipotesis sebelumnya. Penerapan algoritma apriori dan *fp-growth* menunjukkan adanya pengaruh terhadap jumlah dataset yang digunakan, yakni bahwa nilai minimum *support* dan minimum *confidence* mempengaruhi jumlah aturan asosiasi yang dihasilkan. Percobaan dengan algoritma *Fp-Growth* dan Apriori menunjukkan bahwa penggunaan minimum *support* 0.02 membutuhkan waktu eksekusi lebih lama dibandingkan dengan 0.06. Penggunaan minimum *support* 0.02 dan minimum *confidence* 0.1 menghasilkan aturan yang sama untuk penggunaan data 1200 dan 2364 dalam berbagai pembagian data (30%, 40%, 50%, dan 55%) terhadap 100% data. Persentase akurasi kedua algoritma adalah 100%, menunjukkan keandalan dan validitas dalam menemukan pola signifikan dalam dataset yang sama.

Kata Kunci: Data Mining; Algoritma Apriori; Algoritma Fp-Growth Market Basket Analysis;

Abstract—The advancement of information technology drives businesses to strategize to remain competitive. Retail businesses face challenges from changing consumer behaviors that prioritize convenience and speed in shopping, potentially reducing revenue if businesses fail to adapt quickly. An effective approach involves reanalyzing sales transaction data to identify consumer purchasing patterns, providing guidance for strategic decision-making. One effective technique is data mining using Market Basket Analysis models to analyze shopping baskets and identify correlations between items purchased. This model utilizes algorithms like Apriori and FP-Growth to generate association rules. Preprocessing the dataset to derive frequent itemsets, followed by applying association rules, helps identify significant correlations or patterns within the dataset. The Apriori and FP-Growth algorithms are applied with predefined minimum support and minimum confidence levels. Interpretation involves testing and verifying the discovered patterns against previous facts or hypotheses. The application of these algorithms shows their impact on the dataset size, as the chosen minimum support and confidence levels affect the number of association rules generated. Experiments with FP-Growth and Apriori algorithms indicate that using a minimum support of 0.02 requires longer execution time compared to 0.06. Using a minimum support of 0.02 and minimum confidence of 0.1 yields similar rules across different data divisions (30%, 40%, 50%, and 55% splits) of datasets containing 1200 and 2364 records out of 100% data. Both algorithms achieve 100% accuracy, demonstrating reliability and validity in discovering significant patterns within the same dataset.

Keywords: Data Mining; Apriori Algorithm; Fp-Growth Algorithm; Market Basket Analysis

1. PENDAHULUAN

Banyak bisnis ritel menghadapi tantangan terhadap perubahan perilaku konsumen yang mengutamakan kenyamanan dan kecepatan dalam berbelanja[1]. Toko Jaya Plastik sebagai salah satu usaha di bidang ritel menghadapi adanya perubahan perilaku konsumen ini, perihal konsumen menjadi lebih nyaman untuk berbelanja di pesaing seperti minimarket khususnya dengan tawaran berbagai bentuk promo. Tentu kondisi ini menyebabkan penurunan omset yang cukup signifikan karena ketidakmampuan untuk beradaptasi dengan cepat atas kondisi ini. Melihat kondisi ini, tentu harus ada upaya peningkatan penjualan yang mengarah kepada pemanfaatan teknologi informasi. Pendekatan yang dapat diambil salah satunya yaitu dengan mengatur tata letak barang yang sering diminta oleh konsumen dengan menganalisis kembali data transaksi penjualan untuk menemukan pola pembelian konsumen sebagai pertimbangan proses pengambilan keputusan strategis[2]. Analisis big data dengan menggunakan pendekatan data mining dalam teknik machine learning telah menarik perhatian para peneliti saat ini. Kendala khususnya bagi pelaku usaha lokal yang bergerak di bidang ritel adalah sulit dalam mengolah data penjualan yang jumlahnya cukup besar. Kendati demikian, pendekatan data mining ini memiliki keunggulan dalam mengolah data dengan ukuran besar dan kompleksitas yang tinggi. Hal ini menjadi tantangan besar dalam menemukan informasi berharga dari data besar dengan kontrol terdistribusi untuk menemukan hubungan (asosiasi) rumit antar data[3]. Analisis asosiasi data menjadi sangat efektif dalam menggali hubungan antara data dan mengekstraksinya menjadi informasi yang berharga[4]. Kemajuan teknologi data mining kini tidak hanya memiliki potensi dalam pengambilan keputusan strategis baik dalam

penelitian ilmiah, bisnis ataupun pengendalian proses, namun juga secara signifikan dapat memajukan kemajuan komprehensif ilmu komputer[5].


Association Rules mining digunakan untuk mengidentifikasi keterkaitan antara item dalam suatu dataset yang telah ditetapkan sebelumnya[6]. Dalam sebuah bisnis, data mining menjadi sangat penting untuk memahami perilaku konsumen dan membuat keputusan bisnis yang cerdas. *Market Basket Analysis* menjadi bagian dari data mining yang mampu mengidentifikasi hubungan antara pola pembelian konsumen dan *association rules mining*[7]. *Market basket analysis* dapat dikatakan sebagai sebuah pendekatan yang berfungsi untuk menganalisis kebiasaan pembelian konsumen dengan mengidentifikasi korelasi antara beberapa item berbeda yang ditempatkan dalam keranjang belanja. Tujuan utamanya adalah untuk mengetahui produk-produk yang cenderung dibeli bersamaan oleh konsumen[8]. Menganalisis pola transaksi atau pembelian konsumen saat ini telah dilakukan dengan beberapa algoritma dalam data mining, yakni algoritma Apriori, Fp-Growth dan juga Eclat [9]. Algoritma Apriori dan FP-Growth adalah algoritma *association rules mining* yang populer, karena memiliki performa yang baik dalam menangani data dalam skala besar dan kompleks serta menghasilkan data yang lebih akurat dan cepat[10]. Algoritma Apriori menggunakan pendekatan metode iteratif untuk membentuk set item, di mana set item (k-item) digunakan sebagai dasar untuk membentuk set item selanjutnya. Sementara, pendekatan dalam algoritma Fp-Growth mengarah pada teknik mencari *frequent itemset* tanpa perlu menghasilkan kandidat secara eksplisit, dikenal sebagai pendekatan berbasis pohon (FP-Tree). Dengan membandingkan keduanya, peneliti dapat memperoleh pemahaman untuk menentukan algoritma mana yang lebih optimal dalam proses data mining. Dengan menerapkan kedua algoritma tersebut dalam proses data mining dapat dilihat optimalisasi yang terjadi apakah menjadi lebih optimal diantara keduanya.

Penelitian oleh Hossain pada tahun 2019 menunjukkan bahwa reduksi dengan produk-produk terlaris mengurangi waktu komputasi yang dibutuhkan oleh kedua algoritma dibandingkan seluruh produk. Setelah menggunakan reduksi produk, aturan yang dihasilkan dan itemset yang sering muncul hampir sama untuk berbagai tingkat dukungan[11]. Penelitian oleh Intania Sihombing pada tahun 2020 menunjukkan bahwa Fp-Growth lebih efisien dalam pembentukan aturan asosiasi daripada Apriori [12]. Penelitian oleh Bekri & Arief pada tahun 2023 dalam konteks rekomendasi penataan display barang menunjukkan bahwa algoritma Fp-Growth menghasilkan 53 aturan asosiasi dengan tingkat asosiasi sebesar 6,2% dan akurasi sebesar 124%, sedangkan algoritma Apriori hanya menghasilkan 12 aturan dengan akurasi 7,8%[13]. Penelitian lain oleh Widyarini pada tahun 2023 dalam analisis pola asosiasi pada data transaksi toko bunga menggunakan algoritma Apriori dan Fp-Growth menunjukkan bahwa algoritma Apriori menghasilkan 14 aturan, sedangkan Fp-Growth menghasilkan 8 aturan dengan nilai minimum support 0.02 untuk kombinasi 2 item. Hasil tersebut menunjukkan pola pembelian yang signifikan antara berbagai jenis produk bunga dan aksesoris[14]. Dalam penelitian ini, akan dilakukan *Market Basket Analysis* dengan pendekatan algoritma Apriori dan Fp-Growth untuk menghasilkan aturan asosiasi. Upaya optimalisasi hasil dari aturan asosiasi yang diperoleh nantinya dalam penelitian di coba untuk mereduksi data sehingga dapat dilihat pola asosiasi yang terjadi. Data dibagi menjadi dua set, yaitu set data keseluruhan dari data penjualan Toko Retail Jaya Plastik sebagai sample dan set data yang direduksi dengan mempertahankan barang-barang yang sering dibeli sebesar 30%, 40%, 50%, dan 55% dari keseluruhan data transaksi. Dengan tujuan melihat hasil perbandingan data yang menghasilkan nilai rule yang sama terhadap set data keseluruhan penjualan. Hasil evaluasi dan interpretasi dari perhitungan aturan (rule) yang dihasilkan nanti akan menjadi bahan pertimbangan bagi Toko Jaya Plastik dalam mengatur tata letak barang di toko sehingga idealnya dapat menarik perhatian konsumen dan dapat meningkatkan penjualan.

2. METODOLOGI PENELITIAN


2.1 Tahapan Penelitian

Penelitian ini dilakukan dengan mengembangkan *data mining* untuk memperoleh pola asosiasi dengan teknik *market basket analysis*. Tahapan yang digunakan mencakup pengumpulan dataset, *selection*, *preprocessing data*, transformasi, data mining, interpretasi hasil dan evaluasi. Data mining digunakan untuk mengidentifikasi pola atau informasi tertentu dengan menerapkan berbagai teknik atau metode[15].



Gambar 1. Tahapan proses data mining [16]

Teknik dan metode yang digunakan diproses untuk mengungkap pola, yang sering disebut sebagai proses *knowledge discovery*. Metode deskriptif dalam data mining digunakan untuk mengidentifikasi pola yang penting dari data dalam suatu basis data mencakup teknik pengelompokan (*clustering*), asosiasi, dan pencarian urutan (*sequential mining*)[17].



Gambar 2. Diagram Alir Penelitian

Proses pada *data mining* dilakukan secara bertahap yang bersifat interaktif dimana *knowledge base* menjadi perantara dengan pemakai yang terlibat secara langsung[18]. Mengintegrasikan proses data mining dari gambar 1, prosedur penelitian secara urut digambarkan pada diagram alir di gambar 2. Studi literatur yang digunakan sebagai proses awal dalam pengembangan solusi yang ditawarkan dari permasalahan yang terjadi. Tahap selanjutnya yaitu pengumpulan dataset.

2.1.1 Pengumpulan Data Transaksi

Dataset yang dikumpulkan merupakan dataset pada tahun 2022 hingga tahun 2023 yang nantinya data tersebut akan dipilih untuk digunakan dalam proses *preprocessing*.

Tabel 1. Datset tahun 2022 hingga tahun 2023

Nomor Faktur	Tanggal	Nama Barang	QTY	Harga
R43-030122013	2022-01-03	CUP 22 OZ MERAK,NUTRI SARI RTG,CUP MAHKOTA	1,1,1	250.000
R43-030122022	2022-01-03	tusuk sate 500g,AJI NO MOTO 100G,SISRI RTG	6,1,1	25.000
R43-030122104	2022-01-03	KLIP 4X6	1	15.000

Pada tabel 1 merupakan dataset keseluruhan dari Toko retail Jaya Plastik pada tahun 2022 hingga tahun 2023 dengan 5 atribut dan berjumlah 2364 data.

2.1.2 Pemilihan Data

Pada tahap *selection* yaitu pemilihan dataset yang disimpan dalam berkas terpisah untuk dilakukan proses *data mining*. Pemilihan data dilakukan dengan menyeleksi data sesuai dengan atribut yang sudah ditentukan. Atribut sebelum dan sesudah dipilih direpresentasikan dalam tabel 2 dan 3.

Tabel 2. Keseluruhan atribut dataset transaksi

Nomor Faktur	Tanggal	Nama Barang	QTY	Harga
R43-030122013	2022-01-03	CUP 22 OZ MERAK,NUTRI SARI RTG,CUP MAHKOTA	1,1,1	250.000
R43-030122022	2022-01-03	tusuk sate 500g,AJI NO MOTO 100G,SISRI RTG	6,1,1	25.000
R43-030122104	2022-01-03	KLIP 4X6	1	15.000

Pada table 2 merupakan data lengkap dengan 5 atribut yaitu Nomor Faktur, Tanggal, Nama Barang, Qty dan harga. Kemudian dalam proses pemilihan data ini di lakukan proses pemilihan atribut yang dibutuhkan dalam penelitian dengan mengurangi atribut yang tidak digunakan. Dalam hal ini, atribut harga barang tidak digunakan dalam dataset.

Tabel 3. Atribut dataset transaksi yang dipilih

Nomor Faktur	Tanggal	Nama Barang	QTY
R43-030122013	2022-01-03	CUP 22 OZ MERAK,NUTRI SARI RTG,CUP MAHKOTA	1,1,1
R43-030122022	2022-01-03	tusuk sate 500g,AJI NO MOTO 100G,SISRI RTG	6,1,1

Pada table 3 merupakan data yang sudah melauai tahap penyeleksian atribut dengan mengambil 4 atribut yaitu Nomor Faktur, Tanggal, Nama Barang dan Qty. Keempat atribut ini nantinya akan di proses ke tahap *preprocessing data*.

2.1.3 Preprocessing Data

Preprocessing bertujuan untuk mengolah data sehingga data tersebut siap digunakan, prosesnya yaitu dataset diperiksa dan diperbaiki apabila terdapat kesalahan pada data. Pada data pertama, pendekatan dilakukan dengan membagi jumlah dataset berdasarkan jumlah transaksi yang berbeda, kemudian analisis dilakukan dengan mengambil sebagian dari produk terlaris dalam data sebesar top 30%, 40%, 50%, dan 55%. Tujuan dari proses ini adalah untuk mengoptimalkan proses data mining dengan mereduksi dataset yang tidak cukup laris di Toko Jaya Plastik.

Tabel 4. Atribut dataset transaksi yang dipilih

DATASET	30%	40%	50%	55%
400	28	38	48	52
600	54	73	91	100
800	77	102	128	141
1200	122	163	204	224
2364	192	256	320	352

Pada tabel 4 pembagian data transaksi dengan top 30%, 40%, 50%, dan 55%, pembagian dataset berdasarkan peringkat teratas data yang mengandung produk terlaris untuk selanjutnya diambil berdasarkan top dataset.

2.1.4 Transformation Data

Transformasi dalam hal ini bertujuan untuk menyesuaikan bentuk dan format dataset untuk diproses dalam *data mining*. Pada tahap transformation data, dilakukan *Binary Encoding* yang mengacu pada proses transformasi data menjadi bentuk biner.

Tabel 5. Transformation Data

Nama Barang	Nata Decoco	13 Raja Tawon	28 Beko Hijau
Nomor Transaksi			
R43-030122013	0	0	0
R43-030122012	0	1	0
R43-010222057	0	1	0
R43-010222057	1	1	0

Pada proses ini, nilai-nilai numerik diubah menjadi representasi biner, di mana nilai-nilai tersebut dikonversi menjadi 0 atau 1. Langkah ini bertujuan untuk menghasilkan representasi biner dari keberadaan atau ketidak beradaan suatu elemen yang dipresentasikan pada tabel 5.

2.1.5 Penerapan Proses Data Mining

Inti dari tahapan ini yaitu pengaplikasian algoritma dalam data mining untuk proses penggalian pola dari dataset menggunakan berbagai teknik dan metode. Tahap interpretasi melibatkan pengujian dan pemeriksaan untuk verifikasi kesesuaian pola yang ditemukan dengan fakta atau hipotesis yang telah ada sebelumnya. Melalui proses *market basket analysis* pola pembelian pelanggan dapat diidentifikasi dengan menemukan korelasi antara berbagai item yang terdapat dalam transaksi penjualan[19]. *Market basket analysis* difokuskan pada penemuan pola pembelian bersama dalam ribuan dataset. Aturan asosiasi memegang peran krusial dalam mengidentifikasi itemset yang sering muncul dan hubungan antara pembelian berbagai produk. Dalam deklarasi tipe ini, jika item X dibeli, maka item Y juga dibeli secara eksplisit[20].

Association rules dalam proses data mining ini ditujukan untuk mengidentifikasi korelasi atau pola yang signifikan atau menarik dari sekumpulan dataset yang digunakan. Evaluasi kualitas *association rules* berdasarkan nilai *support* dan *confidence*. Semakin tinggi nilai *support*, semakin sering *itemset* muncul dalam transaksi[21]. Semakin nilai minimal *support* nya rendah maka akan semakin tinggi *rule* yang diperoleh, berlaku sebaliknya. Sementara jika

nilai minimal *confidencenya* tinggi maka rule yang diperoleh akan semakin rendah, begitu pun sebaliknya. Aturan dengan nilai support yang tinggi lebih disukai karena menunjukkan bahwa pola tersebut cenderung berlaku untuk sejumlah besar transaksi di masa depan. Maka perhitungan *support* dapat disesuaikan menggunakan persamaan berikut ini:

a. *Support*, yaitu ukuran atau nilai penunjang dari hubungan antar item

$$\text{Support} = \frac{\text{Total transaksi data mengandung barang A}}{\text{Jumlah transaksi data}} \quad (1)$$

b. *Confidence*, yaitu ukuran kepastiandari hubungan antar item

$$\text{Confidence} = \frac{\text{Total transaksi data mengandung barang A dan B}}{\text{Jumlah transaksi data}} \quad (2)$$

Penerapan algoritma Apriori dan Fp-Growth, dimana Apriori menggunakan *frequent itemsets* untuk mengidentifikasi aturan asosiasi, teknik ini dikenal sebagai pendekatan *level-wise*, di mana himpunan k-item digunakan untuk eksplorasi himpunan (k+1)-item. Prosesnya dimulai dengan menemukan himpunan 1-itemsets yang sering muncul diidentifikasi dengan melakukan pemindaian pada database untuk menghitung frekuensi masing-masing item, serta mengumpulkan item yang memenuhi batasan support minimum. Himpunan ini disebut L1. Berikutnya, L1 digunakan sebagai basis untuk menemukan L2, yang merupakan kumpulan 2-itemsets yang sering muncul, yang selanjutnya digunakan untuk mencari L3, dan seterusnya, sampai tidak ada lagi k-itemsets yang sering muncul yang dapat ditemukan. Setiap kali Lk ditemukan, diperlukan satu pemindaian lengkap dari database. Untuk meningkatkan efisiensi pencarian level-wise pada frequent itemsets, Apriori menggunakan suatu sifat penting yang dikenal sebagai Apriori property untuk mengurangi ruang pencarian.

Fp-Growth (*frequent-pattern growth*) dapat menghasilkan *frequent itemset* tanpa perlu membuat *candidate generation* secara lengkap. Prosesnya yaitu dengan mengubah *database* menjadi sebuah FP-tree. Langkah awalnya adalah mengubah database menjadi sebuah FP-tree, yang pada dasarnya adalah sebuah pohon yang memiliki sifatsifat sebagai berikut. Ada satu akar yang diberi label "null". Sejumlah item awal membentuk cabang-cabang dari akar tersebut dan merupakan tabel header item yang sering muncul. Setiap node dalam subtree item awal memiliki tiga komponen: label item, jumlah, dan node-link. Label item yang terdaftar ditampilkan pada node item, jumlah dari transaksi menunjukkan total dari masing-masing elemen yang mencapai node ini, dan node-link menghubungkan node berikutnya pada FP-tree yang memiliki label item yang sama, ditunjukkan dengan panah putus-putus. Setiap entri dalam frequent-item-header pada tabel terdiri dari dua komponen: nama item dan kepala dari node-link (suatu titik pada simpul awal FP-tree yang menyimpan nama item).

2.1.6 Evaluasi

Dalam mengevaluasi hasil, kita menggunakan dua faktor pengukuran, yaitu generalitas (*generality*) dan reliabilitas (*reliability*) dari *association rules* yang dihasilkan. Ukuran generalitas memberikan informasi tentang seberapa sering setiap item muncul dalam aturan asosiasi dibandingkan dengan total transaksi keseluruhan. Beberapa metrik yang digunakan dalam pengukuran ini meliputi, *support* dan *coverage*. Reliabilitas digunakan untuk menilai seberapa dapat diandalkan aturan asosiasi yang dihasilkan dalam proses *association rules* dengan parameter *Confidence*, *Added Value*, *Correlation*.


3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengembangan Data Mining dengan Market Basket Analysis

Data mining dengan pengembangan teknik *market basket analysis* ini telah diterapkan dua buah algoritma yaitu *apriori* dan FP-Growth. Pertama, nilai *minimum support* dan *confidence* ditetapkan pada algoritma yang dikembangkan untuk selanjutnya dilakukan perhitungan pola dari itemset yang sering muncul (*frequent itemset*)

3.1.1 Hasil Percobaan minimum support dan minimum confidence

Dilakukan percobaan dengan minimum *support* untuk setiap data transaksi yang sudah dibagi, dengan rentang minimum *support* dari 0.05 hingga 0.09.




Gambar 2. Percobaan Minimum Support dan Minimum Confidence

Hasilnya, untuk data transaksi dengan 30%, 40%, 50%, dan 55% dari keseluruhan data, didapatkan *Frequent Itemset* untuk semua percobaan. Sementara itu, untuk penggunaan 100% data, hanya pada minimum support 0.01 dan 0.02 yang menghasilkan *frequent itemset*. Berdasarkan hasil tersebut, diputuskan untuk menggunakan dua nilai minimum support dalam percobaan lebih lanjut, yaitu 0.06 dan 0.02. Nilai-nilai ini dipilih karena menghasilkan jumlah aturan yang cukup untuk dianalisis. Jumlah aturan ini tidak terlalu banyak sehingga menjadi berlebihan dan sulit dikelola, tetapi juga tidak terlalu sedikit sehingga kurang informatif.

3.1.2 Perhitungan Apriori Percobaan Pertama dan Kedua


Pada gambar 2 merupakan perhitungan pertama menggunakan algoritma *Apriori* dengan minimum support 0.06 dan minimum support 0.02 dengan minimum support 0.1 didapatkan variasi nilai *frequent itemset* dan *rule* dari pembagian data 30%, 40% 50% dan 55% sedangkan untuk penggunaan 100% data pada hasil perhitungan tidak mendapatkan *rule* sama sekali. Hal ini dikarenakan pengaruh penerapan *minimum support* dan *minimum confidence* terhadap jumlah data yang dihitung. Selanjutnya dilakukan perhitungan kedua dengan nilai *minimum support* 0,02 dan *minimum confidence* 0,1 pada penggunaan 100% yang di presentasikan pada gambar 3.



Gambar 3. Grafik Perhitungan Perbandingan antara *Frequent Itemset* Percobaan Pertama Algoritma *Apriori*


Pada gambar 3 yaitu perhitungan kedua menggunakan algoritma *Apriori* dengan *minimum support* 0.02 dan *minimum confidence* 0,1 untuk 100% data. Dari perhitungan dapat dilihat bahwa untuk 100% data *rule* mulai terbentuk hal ini terjadi karena adanya perbedaan nilai *minimum support* dan *minimum confidence* pada pembagian 30%, 40%, 50% dan 55%. Dari perhitungan jika di lihat pada penggunaan dataset dari 1200 hingga 2364 di dapatkan nilai *rule* yang sama untuk semua pembagian data terhadap 100% data. Sehingga di simpulkan adanya pengaruh penggunaan jumlah data dengan penetapan nilai *minimum support* dan *minimum confidence* pada nilai *rule* yang dihasilkan.

Selanjutnya dihitung presentasi waktu dan penggunaan memori yang dilakukan pada percobaan minimum support 0.06 dan minimum support 0.02 yang dipresentasikan pada gambar 4 berikut.



Gambar 4. Grafik Perhitungan Perbandingan antara *Frequent Itemset* Percobaan Kedua Algoritma Apriori


Pada gambar 4 merupakan perhitungan kedua menggunakan algoritma apriori dengan minimum support 0.02 dan minimum confidence 0,1 untuk 100%data. Dari perhitungan dapat dilihat bahwa untuk 100% data rule mulai terbentuk hal ini terjadi karena adanya perbedaan nilai minimum support dan minimum confidence pada pembagian 30%, 40%, 50% dan 55% . Dari perhitungan jika di lihat pada penggunaan dataset dari 1200 hingga 2364 di dapatkan nilai rule yang Gambar 4. 47 Perhitungan percobaan kedua Apriori79sama untuk semua pembagian data terhadap 100% data. Sehingga di simpulkan adanya pengaruh penggunaan jumlah data dengan penetapan nilai minimum support dan minimum confidence pada nilai rule yang dihasilkan.



Gambar 5. Grafik Perbandingan Perhitungan Antara Waktu dan Memori pada Percobaan Apriori


Pada gambar 5 merupakan perhitungan perbandingan waktu dan penggunaan memori dari percobaan pada algoritma *Apriori* dengan *minimum support* 0.06 dengan *minimum support* 0.02. didapatkan bahwa penggunaan *minimum support* 0.02 membutuhkan waktu eksekusi lebih lama daripada penggunaan *minimum support* 0.06 sehingga di simpulkan adanya pengaruh terhadap penetapan *minimum support* yang digunakan terhadap eksekusi waktu. Kemudian pada penggunaan memori tidak ada perbedaan untuk semua percobaan, hal ini dikarenakan data yang digunakan relatif kecil sehingga pada perhitungan kedua algoritma sama-sama menghasilkan penggunaan memori yang sama.

3.1.3 Perhitungan *Fp-Growth* percobaan pertama dan kedua




Gambar 5. Grafik Perhitungan Perbandingan antara *Frequent Itemset* Percobaan Pertama Algoritma *Fp-Growth*

Pada gambar 5 merupakan hasil perhitungan pertama algoritma *fp-growth* dengan *minimum support* 0.06 dan *minimum confidence* 0,1 didapatkan variasi nilai *frequent itemset* dan *rule* dari pembagian data 30%, 40% 50% dan 55% sedangkan untuk penggunaan 100% data pada hasil perhitungan tidak mendapatkan *rule* sama sekali. Hal ini di karenakan pengaruh penerapan *minimum support* dan *minimum confidence* terhadap jumlah data yang dihitung. Selanjutnya dilakukan perhitungan kedua dengan nilai *minimum support* 0,02 dan *minimum confidence* 0,1 pada penggunaan 100% data yang di presentasikan pada gambar 6.



Gambar 6. Grafik Perhitungan Perbandingan antara *Frequent Itemset* Percobaan Kedua Algoritma *Fp-Growth*

Pada gambar 6 merupakan perhitungan kedua menggunakan algoritma *fp-growth* dengan *minimum support* 0.02 dan *minimum confidence* 0,1 untuk 100%. Dari perhitungan dapat dilihat bahwa untuk 100% data rule mulai terbentuk hal ini terjadi karena adanya perbedaan nilai *minimum support* dan *minimum confidence* pada pembagian 30%, 40%, 50% dan 55%. Dari perhitungan jika di lihat pada penggunaan *dataset* dari 1200 hingga 2364 di dapatkan nilai *rule* yang sama untuk semua pembagian data terhadap 100% data. Sehingga di simpulkan adanya pengaruh penggunaan jumlah data dengan penetapan nilai *minimum support* dan *minimum confidence* pada nilai *rule* yang dihasilkan. Selanjutnya dihitung presentasi waktu dan penggunaan memori yang dilakukan pada percobaan *minimum support* 0.06 dan *minimum support* 0.02 yang di representasikan pada gambar berikut. Kemudian dihitung presentasi waktu dan penggunaan memori yang dilakukan pada percobaan *minimum support* 0.06 dan *minimum support* 0.02 yang di representasikan pada gambar 7 berikut.



Gambar 7. Perhitungan waktu dan memori pada percobaan Fp-Growth

Pada gambar 7 merupakan perhitungan perbandingan waktu dan penggunaan memori dari percobaan pada algoritma Fp-Growth dengan minimum *support* 0.06 dengan minimum *support* 0.02. didapatkan bahwa penggunaan minimum *support* 0.02 membutuhkan waktu eksekusi lebih lama daripada penggunaan minimum *support* 0.06 sehingga di simpulkan adanya pengaruh terhadap penetapan minimum *support* yang digunakan terhadap eksekusi waktu. Kemudian pada penggunaan memori tidak ada perbedaan untuk semua percobaan, hal ini dikarenakan data yang digunakan relatif kecil sehingga pada perhitungan kedua algoritma sama-sama menghasilkan penggunaan memori yang sama.

3.4.3 Evaluasi dan Analisa

Tingkat kekuatan dari aturan asosiasi ditentukan oleh nilai *support* yang mewakili aspek *generality* dan nilai *confidence* yang mewakili aspek *reliability* yang dipresentasikan dalam gambar 8 berikut.

Nilai I (tingkat kekuatan) untuk Apriori: 0.09602368866328255
 Nilai I (tingkat kekuatan) untuk FP-Growth: 0.09602368866328255
 Persentase akurasi algoritma Apriori terhadap FP-Growth: 100.0
 Persentase akurasi algoritma FP-Growth terhadap Apriori: 100.0

Gambar 8. Hasil analisa dari algoritma Apriori dan Fp-Growth

Dalam gambar 8 analisis hasil dari kedua algoritma dapat disimpulkan berdasarkan perhitungan evaluasi di dapatkan untuk algoritma Apriori sebesar 0.096, sementara untuk Fp-Growth sebesar 0.096. Presentasi akurasi algoritma Apriori terhadap Fp-Growth sebesar 100% dan untuk Persentase akurasi algoritma Fp-Growth terhadap Apriori sebesar 100% sehingga dengan hasil ini, disimpulkan bahwa kedua algoritma sama-sama memberikan akurasi yang sangat baik.

4. KESIMPULAN

Hasil perbandingan algoritma Apriori dan Fp-Growth menunjukkan adanya pengaruh terhadap jumlah data dengan penetapan nilai minimum *support* dan minimum *confidence* pada rule yang dihasilkan. Pada penggunaan 100%, tidak ada rule yang terbentuk. Setelah mencoba dengan nilai minimum *support* 0.02 dan minimum *confidence* 0.1, untuk 100% data, nilai *rule* yang dihasilkan tetap sama untuk pembagian data 30%, 40%, 50%, dan 55%. Percobaan dengan algoritma Fp-Growth dan Apriori menunjukkan bahwa penggunaan minimum *support* 0.02 membutuhkan waktu eksekusi lebih lama dibandingkan dengan 0.06. Ini menunjukkan bahwa semakin besar nilai minimum *support* dan minimum *confidence*, semakin singkat waktu pemrosesan algoritma. Penggunaan memori relatif kecil karena data yang digunakan tidak besar, sehingga kedua algoritma menghasilkan penggunaan memori yang serupa. Dari analisis algoritma Apriori dan FP-Growth, diperoleh hasil persentase akurasi algoritma Apriori terhadap Fp-Growth sebesar 100%, dan sebaliknya. Hasil ini menunjukkan bahwa kedua algoritma memberikan akurasi yang sangat baik, menunjukkan keandalan dalam menemukan pola signifikan dalam dataset yang sama.

REFERENCES

- [1] J. Elektronika and D. Komputer, "INDONESIA Pola Asosiasi Untuk Rekomendasi Penataan Display Barang Menggunakan Algoritma Apriori dan FP-Growth (Study Kasus Gamefantasia Ada Swalayan Pati)," *Elkom : Jurnal Elektronika dan Komputer*, vol. 16, no. 1, pp. 109–20, Jul. 2023, doi: 10.51903/ELKOM.V16I1.999.
- [2] N. Nurlalah and M. Ryansyah, "IMPLEMENTASI DATA MINING ANALISIS TERHADAP DATA PENJUALAN PRODUK HERBAL DENGAN METODE ALGORITMA APRIORI DAN FP-GROWTH," *JIKO (Jurnal Informatika dan Komputer)*, vol. 5, no. 3, pp. 249–253, Dec. 2022, doi: 10.33387/JIKO.V5I3.5438.



- [3] C. R. Artsitella, A. R. Apriliani, and S. Ashari, “Penerapan Association Rules - Market Basket Analysis untuk Mencari Frequent Itemset dengan Algoritma FP-Growth,” *JURNAL AI-AZHAR INDONESIA SERI SAINS DAN TEKNOLOGI*, vol. 6, no. 2, pp. 61–69, Sep. 2021, doi: 10.36722/SST.V6I2.661.
- [4] A. Untuk et al., “ANALISIS UNTUK MEMREDIKSI STOK ASET DI PT. XYZ MENGGUNAKAN ALGORITMA APRIORI,” *JURNAL ILMIAH INFORMATIKA*, vol. 11, no. 02, pp. 106–112, Sep. 2023, doi: 10.33884/JIF.V11I02.7354.
- [5] I. Rosmayati, W. Wahyuningsih, E. F. Harahap, and H. S. Hanifah, “Implementasi Data Mining pada Penjualan Kopi Menggunakan Algoritma Apriori,” *Jurnal Algoritma*, vol. 20, no. 1, pp. 99–107, May 2023, doi: 10.33364/ALGORITMA/V.20-1.1259.
- [6] J. Dongga, A. Sarungallo, N. Koru, G. Lante, and R. Artikel, “Implementasi Data Mining Menggunakan Algoritma Apriori Dalam Menentukan Persediaan Barang (Studi Kasus: Toko Swapen Jaya Manokwari),” *G-Tech: Jurnal Teknologi Terapan*, vol. 7, no. 1, pp. 119–126, Jan. 2023, doi: 10.33379/GTECH.V7I1.1938.
- [7] T. Kurniana, A. Lestari, and E. D. Oktaviyani, “Penerapan Algoritma Apriori untuk Mencari Pola Transaksi Penjualan Berbasis Web pada Cafe Sakuyan Side,” *KONSTELASI: Konvergensi Teknologi dan Sistem Informasi*, vol. 3, no. 1, pp. 13–23, Jun. 2023, doi: 10.24002/KONSTELASI.V3I1.7005.
- [8] R. Kurniawan, R. Yusuf, and D. Wacana, “PENERAPAN METODE ASOSIASI DENGAN ALGORITMA APRIORI UNTUK MENDUKUNG STRATEGI PROMOSI,” *EDUSAINTEK: Jurnal Pendidikan, Sains dan Teknologi*, vol. 10, no. 2, pp. 514–528, Feb. 2023, doi: 10.47668/EDUSAINTEK.V10I2.786.
- [9] A. Penelitian Penerapan Algoritma Apriori Pada Transaksi Penjualan Untuk Rekomendasi Menu Makanan Dan Minuman Nanda Nurisya Merliani, N. Isnaeni Khoerida, N. Tri Widiawati, L. Adi Triana, and P. Subarkah, “Penerapan Algoritma Apriori Pada Transaksi Penjualan Untuk Rekomendasi Menu Makanan Dan Minuman,” *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 1, pp. 9–16, May 2022, doi: 10.25077/TEKNOSI.V8I1.2022.9-16.
- [10] G. Soepriyono, “Penerapan Market Basket Analysis Data Mining Pada Penjualan Batik dengan Menerapkan Algoritma Apriori,” *Journal of Computer System and Informatics (JoSYC)*, vol. 5, no. 3, pp. 516–525, May 2024, doi: 10.47065/JOSYC.V5I3.5198.
- [11] M. Hossain, A. H. M. S. Sattar, and M. K. Paul, “Market basket analysis using apriori and FP growth algorithm,” 2019 22nd International Conference on Computer and Information Technology, ICCIT 2019, Dec. 2019, doi: 10.1109/ICCIT48885.2019.9038197.
- [12] E. I. Sihombing, M. Yetri, and R. I. Ginting, “Penerapan Market Basket Analysis Terhadap Data Penjualan Produk Pupuk Cair Dengan Menggunakan Metode Algoritma Apriori Dan Frequent pattern growth (Fp Growth) Di Ud. Anugerah Tani Saribudolok,” *Jurnal Cyber Tech*, vol. 3, no. 2, Feb. 2020, doi: 10.53513/JCT.V3I2.3130.
- [13] Bekri Murdianto and Arief Jananto, “INDONESIA Pola Asosiasi Untuk Rekomendasi Penataan Display Barang Menggunakan Algoritma Apriori dan FP-Growth (Study Kasus Gamefantasia Ada Swalayan Pati),” *Elkom : Jurnal Elektronika dan Komputer*, vol. 16, no. 1, pp. 109–20, Jul. 2023, doi: 10.51903/ELKOM.V16I1.999.
- [14] R. D. Widyarani, A. Suharso, A. Solehudin, J. H. S. Ronggowaluyo, and T. T. Karawang, “ASSOCIATION RULE PENGOLAHAN DATA TRANSAKSI TOKO BUNGA MENGGUNAKAN ALGORITMA APRIORI DAN FP-GROWTH UNTUK MENENTUKAN PROMOSI PAKET BUNGA:,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 3, pp. 1461–1466, Oct. 2023, doi: 10.36040/JATI.V7I3.7037.
- [15] N. Ramadhani, A. W. Syahroni, A. Supikar, and W. Zumam, “Penerapan Market Basket Analysis Menggunakan Metode Multilevel Association Rules dan Algoritma ML_T2L1 Pada Data Order PT. Unirama,” *InfoTekJar : Jurnal Nasional Informatika dan Teknologi Jaringan*, vol. 4, no. 2, pp. 261–274, Mar. 2020, doi: 10.30743/INFOTEKJAR.V4I2.2405.
- [16] H. Wu, “Data association rules mining method based on improved apriori algorithm,” *ACM International Conference Proceeding Series*, pp. 12–17, Nov. 2020, doi: 10.1145/3445945.3445948.
- [17] M. Soleh, N. Hidayati, F. Dwi Muji Krisdian, P. Studi Teknik Industri, S. Tinggi Teknik Wiworotomo, and J. Semingkir No, “PENERAPAN METODE ASSOCIATION RULE - MARKET BASKET ANALYSIS UNTUK MENINGKATKAN DAYA SAING TOKO SWALAYAN KECIL,” *Jurnal Aplikasi Ilmu Teknik Industri (JAPTI)*, vol. 2, no. 1, pp. 1–9, Jul. 2021, doi: 10.32585/JAPTI.V2I1.1469.
- [18] M. Hossain, A. H. M. S. Sattar, and M. K. Paul, “Market basket analysis using apriori and FP growth algorithm,” 2019 22nd International Conference on Computer and Information Technology, ICCIT 2019, Dec. 2019, doi: 10.1109/ICCIT48885.2019.9038197.
- [19] D. Alcan, K. Ozdemir, B. Ozkan, A. Y. Mucan, and T. Ozcan, “A Comparative Analysis of Apriori and FP-Growth Algorithms for Market Basket Analysis Using Multi-level Association Rule Mining,” pp. 128–137, 2023, doi: 10.1007/978-3-031-25847-3_13.
- [20] M. N. H. S. Anjar Wanto, N. L. W. S. R. G. Dedy Hartama, E. S. N. Darmawan Napitupulu, and C. P. Sarini Vita Dewi, “Data Mining : Algoritma dan Implementasi,” 2020.
- [21] B. Almahenzar and A. W. Wijayanto, “Analisis Intensitas Hujan Provinsi Jawa Barat Tahun 2020 Menggunakan Association Rule Apriori dan FP-Growth,” *Journal of System and Computer Engineering (JSCE)*, vol. 3, no. 2, pp. 258–271, Jul. 2022, doi: 10.47650/JSCE.V3I2.397.