

PERMASALAHAN EFISIENSI ALGORITMA APRIORI DAN EVALUASI *FP-GROWTH* BERDASARKAN STUDI LITERATUR

Oleh:

Khaerunnisa Isnaeni Lestari¹

Suryadi Putra²

Elkin Rilvani³

Universitas Pelita Bangsa

Alamat: JL. Inspeksi Kalimalang No.9, Cibatu, Cikarang Sel., Kabupaten Bekasi, Jawa Barat (17530).

Korespondensi Penulis: khaerunnisa.31221008@mhs.pleitabangsa.ac.id

Abstract. *To find patterns of association between items in transaction data, the Apriori algorithm and FP-Growth are two commonly used association rule mining techniques. The Apriori algorithm relies on a repetitive generate-and-test approach, making it less efficient in terms of time and memory consumption, although its implementation is relatively easy. However, this algorithm has limitations in determining its candidates. As an alternative, the FP-Growth algorithm offers higher efficiency through the FP-Tree structure and a pattern growth mechanism that only requires two data scans. This study uses the literature review method to compare the performance of both algorithms based on processing time, the number of rules generated, rule quality (including support, confidence, and lift), and memory usage. The study results show that although Apriori is still relevant for small datasets and initial exploration, FP-Growth consistently excels in terms of scalability and efficiency in processing large-scale data. Both have their own functions and specifications for each of their respective datasets. This finding can serve as a reference in selecting the appropriate algorithm according to the characteristics of the data and the needs of the developed system.*

Keywords: *Apriori, FP-Growth, Data Mining, Association Comparison Algorithm.*

PERMASALAHAN EFISIENSI ALGORITMA APRIORI DAN EVALUASI *FP-GROWTH* BERDASARKAN STUDI LITERATUR

Abstrak. Untuk menemukan pola keterkaitan antar item dalam data transaksi, algoritma Apriori dan *FP-Growth* merupakan dua teknik *association rule mining* yang populer digunakan. Algoritma Apriori mengandalkan pendekatan *generate-and-test* yang berulang, sehingga cenderung kurang efisien dalam hal waktu dan konsumsi memori, meskipun implementasinya relatif mudah. Akan tetapi, algoritma ini memiliki keterbatasan dalam menentukan kandidatnya. Sebagai alternatif, algoritma *FP-Growth* menawarkan efisiensi yang lebih tinggi melalui struktur *FP-Tree* dan mekanisme pertumbuhan pola yang hanya memerlukan dua kali pemindaian data. Penelitian ini menggunakan metode *literature review* untuk membandingkan kinerja kedua algoritma berdasarkan waktu proses, jumlah aturan yang dihasilkan, kualitas aturan (meliputi *support*, *confidence*, dan *lift*), serta penggunaan memori. Hasil studi menunjukkan bahwa meskipun Apriori masih relevan untuk dataset kecil dan eksplorasi awal, *FP-Growth* secara konsisten unggul dalam hal skalabilitas dan efisiensi pemrosesan data berskala besar. Keduanya mempunyai fungsi dan spesifikasi nya tersendiri di masing-masing datasetnya. Temuan ini dapat menjadi acuan dalam pemilihan algoritma yang tepat sesuai dengan karakteristik data dan kebutuhan sistem yang dikembangkan.

Kata Kunci: Apriori, FP-Growth, Data Mining, Algoritma Komparasi Asosiasi.

LATAR BELAKANG

Perkembangan teknologi digital saat ini menghasilkan jejak digital yang sangat besar dan kompleks tentang bagaimana manusia berinteraksi, berkolaborasi, dan bertukar informasi dengan berbagai pihak. Perkembangan ini memunculkan tantangan sekaligus peluang dalam pengelolaan dan pemanfaatan data, mengingat volume data yang dihasilkan dari aktivitas manusia semakin meningkat dari waktu ke waktu, baik pada tingkat individu, organisasi, hingga skala global. Dalam menghadapi kondisi tersebut, dibutuhkan metode analisis data yang mampu menggali informasi tersembunyi dari kumpulan data yang besar dan tidak terstruktur. Salah satu pendekatan yang menjadi kunci dalam proses tersebut adalah data mining atau penambangan data. *Data mining* merupakan teknik dalam ilmu komputer yang berfungsi untuk mengekstraksi pola dan pengetahuan penting dari dataset berskala besar, serta digunakan secara luas dalam berbagai bidang, seperti bisnis, teknologi, kesehatan, pendidikan, dan lainnya.

Salah satu teknik penting dalam data mining adalah analisis *asosiasi* (*Association rule mining*), yaitu teknik yang digunakan untuk menemukan hubungan atau keterkaitan antara item dalam data transaksional. Dalam dunia bisnis, analisis asosiasi sering diterapkan untuk memahami perilaku konsumen dan mengoptimalkan strategi penjualan. Contohnya adalah penentuan peletakan produk, penawaran *bundling*, dan pengaturan waktu promosi atau diskon berdasarkan kebiasaan belanja pelanggan. Namun, manfaat analisis asosiasi tidak terbatas pada sektor bisnis saja. Teknik ini juga relevan diterapkan dalam bidang lain seperti sistem rekomendasi, analisis pola penyakit, serta penentuan strategi pembelajaran adaptif dalam pendidikan. Untuk menerapkan analisis asosiasi, beberapa algoritma telah dikembangkan dan digunakan secara luas, antara lain Apriori, dan *FP-Growth*. Masing-masing algoritma memiliki pendekatan dan keunggulan tersendiri dalam proses pencarian frequent itemset, yaitu item yang sering muncul dalam satu transaksi. (Erlina, Irfansyah, Yudi, Ikhsanudin, & Pujha, 2023)

Algoritma Apriori dikenal sebagai algoritma dasar dalam analisis asosiasi. Meskipun mudah diterapkan, algoritma ini kurang efisien saat diterapkan pada dataset berukuran besar karena memerlukan banyak proses pembangkitan kandidat itemset. Algoritma Apriori menggunakan pendekatan "*bottom-up*", di mana itemset ditentukan satu item pada satu waktu, langkah-langkah ini dikenal sebagai generasi kandidat. Algoritma ini menggunakan pencarian *breadth-first* dan struktur pohon *hash* untuk menghitung itemset kandidat dengan efisien. Sekelompok kandidat diuji terhadap data, yang akan dipangkas jika kandidat memiliki sub polanya yang jarang. Proses ini diulang sampai tidak ada perpanjangan yang berhasil ditemukan. Algoritma apriori dianggap sebagai metode *brute-force* karena metode ini mempertimbangkan setiap *k-itemset* sebagai kandidat dari itemset yang sering.

Algoritma *FP-Growth* untuk menambang serangkaian lengkap pola frekuensi melalui pertumbuhan fragmen pola. Algoritma *FP-Growth* menggunakan struktur pohon prefiks yang diperluas untuk menyimpan informasi terkompresi tentang pola frekuensi yang disebut pohon pola frekuensi. Dalam studinya, ia membuktikan bahwa metode ini mengungguli metode lain untuk penambangan pola frekuensi. Algoritma adalah algoritma yang efisien untuk aturan asosiasi. Dalam algoritma ini, menggunakan cara alternatif untuk menemukan himpunan item frekuensi tanpa generasi kandidat yang

PERMASALAHAN EFISIENSI ALGORITMA APRIORI DAN EVALUASI *FP-GROWTH* BERDASARKAN STUDI LITERATUR

memakan banyak memori dan waktu proses, ini membuat kinerja algoritma ini lebih baik daripada Apriori. (Deo Wicaksono, 2019)

Algoritma Apriori adalah salah satu teknik yang paling populer dan paling awal untuk menggali aturan asosiasi. Ini karena konsep dan implementasinya yang mudah dipahami. Namun, Apriori mengalami beberapa keterbatasan teknis dan kinerja yang signifikan seiring peningkatan kebutuhan akan analisis data yang lebih cepat dan kompleks. Ini terutama berlaku untuk dataset berskala besar atau dengan banyak item transaksi. Beberapa kendala utama algoritma apriori adalah:

1. Pilih kandidat berulang kali
2. Sangat lama untuk data besar
3. Membutuhkan banyak memori
4. Tidak efisien untuk barang langka
5. Konsumsi memori tinggi
6. Tidak efektif untuk item langka

Dalam analisis asosiasi, algoritma Apriori dianggap sebagai algoritma dasar. Meskipun mudah digunakan, algoritma ini kurang efektif untuk dataset berukuran besar karena membutuhkan banyak proses pembangkitan itemset kandidat. Algoritma *FP-Growth* adalah solusi. Ini menghilangkan proses pembangkitan kandidat dan menggunakan struktur pohon *FP-Tree* untuk mempercepat pencarian pola. Penelitian ini akan menganalisis literatur sebelumnya untuk menemukan keterbatasan algoritma apriori dan melihat solusi yang ditawarkan algoritma *FP-Growth* untuk menutupi keterbatasan tersebut. Pada akhirnya, penelitian ini akan membandingkan performa dan karakteristik keduanya dari berbagai studi terdahulu. Dalam analisis asosiasi, algoritma Apriori dianggap sebagai algoritma dasar. Meskipun mudah digunakan, algoritma ini tidak efektif dengan dataset besar karena membutuhkan banyak proses pemrosesan kandidat itemset. Algoritma *FP-Growth* adalah solusi; itu meminimalkan proses pengembangan kandidat dan meningkatkan kecepatan pencarian pola dengan menggunakan struktur pola *FP-Tree*.

KAJIAN TEORITIS

Berbagai penelitian sebelumnya telah menjadi pondasi penting dalam pengembangan metode *Association Rule Mining (ARM)*, khususnya dalam membandingkan algoritma Apriori dan FP Growth.

1. Artikel ilmiah berjudul "*Analisis Perbandingan Algoritma Apriori dan FP-Growth untuk Menentukan Strategi Penjualan pada Maestro Jakarta Cafe & Space*" menunjukkan bahwa perlu ada inovasi untuk meningkatkan penjualan karena penurunan penjualan yang mengakibatkan persaingan dan pengelolaan data transaksi yang tidak optimal. Hasil penelitian ini, yang menggunakan metode Apriori dan *FP-Growth*, menunjukkan bahwa kedua algoritma memiliki kinerja yang lebih baik dari yang pertama, dan bahwa prosesnya sedikit lebih cepat. Hasil analisisnya menunjukkan bahwa algoritma apriori dan pertumbuhan fp menghasilkan 22 aturan asosiasi pada data transaksi penjualan dengan nilai minimum dukungan sebesar 1% dan nilai minimum keyakinan sebesar 100%. dengan satu-satunya perbedaan indeks kemunculannya.
2. Berbeda dari penelitian-penelitian terdahulu, "*PERBANDINGAN ANTARA ALGORITMA APRIORI DENGAN ALGORITMA FP-GROWTH DALAM MENENTUKAN FREQUENT PATTERN*" studi ini secara spesifik berfokus pada data transaksi penjualan dari G Coffee, sebuah bisnis ritel di sektor kuliner dan bertujuan untuk menguji serta membandingkan performa algoritma Apriori dan *FP-Growth* dari aspek yang lebih terukur, yaitu waktu eksekusi (*execution time*), tingkat akurasi (*support, confidence, dan lift*), serta efisiensi penggunaan sumber daya pada dataset dengan skala yang bervariasi (300, 400, dan 500 transaksi) Ini menunjukkan *FP-Growth* sebagai pilihan yang lebih baik untuk pemrosesan data berskala besar atau sistem real-time. Untuk ilustrasi, kombinasi terkenal seperti "*Vanilla Latte*" dan "*Taro*" dengan "*Banana Split*" atau "*Ayam Geprek Ijo + Nasi*" dengan "*Jasmine Tea*" menunjukkan potensi untuk strategi *cross-selling* yang lebih efektif.
3. "*Sistem Saran Pencegahan Dengue Fever Penelitian ini mengembangkan sistem rekomendasi berbasis web untuk pencegahan demam berdarah (DHF)*" dengan data dari 100 rumah tangga di Provinsi Surat Thani, Thailand. Ini menggunakan pembelajaran mesin. Untuk menemukan aturan asosiasi dan membandingkan efektivitasnya, dua algoritma pemrosesan data *FP-Growth* dan Apriori

PERMASALAHAN EFISIENSI ALGORITMA APRIORI DAN EVALUASI *FP-GROWTH* BERDASARKAN STUDI LITERATUR

digunakan; *FP-Growth* menghasilkan lebih banyak aturan asosiasi (19 aturan).membandingkan apriori dengan delapan aturan. Nilai keyakinan *FP-Pertumbuhan* adalah 0,91–1,00, dan nilai lift *FP-Pertumbuhan* adalah 1,32–1,66. Karena prosesnya yang lebih cepat, *FP-Growth* dianggap lebih cocok.

4. “*Data Mining FP-Growth dan Metode Apriori Dibandingkan Untuk mengetahui pola penjualan*”. penelitian ini melihat bahwa data penjualan dari toko parfum corner hanya terkumpul di dalam *database*. Namun, toko tersebut menghadapi masalah dengan data penjualan produk terlaris dan berusaha untuk meningkatkan jumlah penjualan produk parfum berikutnya. Antara lain, *orange*, *tanagara*, dan *rapidminer* adalah beberapa alat yang membantu penelitian ini menghasilkan banyak varian dan memiliki nilai pendukung dan keyakinan. Dua kombinasi (*Jo Malone dan Zarra*) dan tiga kombinasi (*Jo Malone dan Zarra, Baccarte*) mendapat aturan asosiasi berdasarkan nilai dukungan 20% dan kepercayaan minimal 80%. *Relative lift ratio* dari set yang terbentuk dari dua dan tiga itemset berstatus valid dan kuat, yang ditunjukkan dengan nilai *lift* lebih dari 1. Algoritma *FP-Growth* memiliki nilai dukungan tertinggi dan keyakinan tertinggi ketika digunakan dengan alat pemrosesan cepat.

METODE PENELITIAN

Penelitian ini menggunakan metode *SLR (System Literature Review)*, yang dapat dilakukan dengan meninjau dan mengidentifikasi jurnal secara sistematis di setiap langkah proses. Hasil identifikasi penelitian ini diharapkan akan menambah literatur tentang penggunaan metode *SLR* dalam identifikasi jurnal. Dalam proses penerusan dan pengolahan sumber ilmiah, *SLR* dimaksudkan untuk menjadi metode yang terorganisir, terstruktur, dan transparan. Dengan menggunakan metode ini, tujuan utama adalah untuk merangkum dan menyajikan kembali temuan penelitian sebelumnya secara sistematis sehingga peneliti dapat memperoleh pemahaman yang lebih baik tentang bagaimana topik tertentu berkembang. Selain itu, *SLR* membantu menentukan kesenjangan (*gap*) dalam penelitian saat ini dan berfungsi sebagai dasar untuk menentukan tujuan penelitian berikutnya.

Dalam praktiknya, *SLR* tidak hanya mengumpulkan data dari berbagai sumber, tetapi juga menggabungkannya menjadi laporan yang adil dan terintegrasi. Metode

PRISMA, pedoman pelaporan sistematik yang diakui secara internasional, digunakan untuk melaksanakan proses ini. Pendekatan *PRISMA* menyusun dan transparan sepenuhnya proses pelaksanaan evaluasi, mulai dari seleksi hingga pelaporan hasil. Kajian literatur sistematis dilakukan dalam lima tahapan utama yang mendalam dan berurutan, yaitu

1. Determinasi kriteria kelayakan penelitian yang akan ditinjau
2. Menentukan sumber data yang relevan.
3. Memilih literatur yang sesuai
4. Mengumpulkan dan mengevaluasi data dari studi terpilih
5. Menentukan elemen data yang penting untuk analisis tambahan

Melalui pendekatan yang sistematik seperti ini, *SLR* tidak hanya meningkatkan validitas dan replikasi studi, tetapi juga memberikan kontribusi nyata terhadap pengembangan ilmu pengetahuan dengan menyajikan informasi yang lebih lengkap, terarah, dan berimbang. (Farid Syah Zikri, 2025).

HASIL DAN PEMBAHASAN

Algoritma Apriori

Dengan menggunakan pendekatan *generate and test*, Algoritma Apriori membuat kumpulan itemset potensial berdasarkan pola sebelumnya dan kemudian mengukur frekuensinya dalam dataset. Namun, kelemahan utama algoritma ini adalah bahwa ia memerlukan pemindaian data berulang dan menghasilkan banyak kombinasi potensial, yang dapat memperlambat proses analisis pada dataset berskala besar. Studi ini menjelaskan mengapa algoritma apriori tidak efisien dalam mengelola data berskala besar karena, seperti yang disebutkan sebelumnya.

1. Keterbatasan Algoritma Apriori

Ada beberapa keterbatasan utama algoritma apriori:

- a) Berulang kali menghasilkan kandidat, apriori menggunakan pendekatan *generate and test*, di mana algoritma secara eksplisit menghasilkan semua kombinasi itemset terlebih dahulu, lalu menguji satu per satu apakah itemset memenuhi ambang batas (*support* dan keyakinan). Proses ini memakan banyak waktu dan sumber daya, terutama dengan banyak item.

PERMASALAHAN EFISIENSI ALGORITMA APRIORI DAN EVALUASI *FP-GROWTH* BERDASARKAN STUDI LITERATUR

- b) Semakin besar dataset (baik dari segi jumlah transaksi maupun item dalam transaksi) algoritma ini menjadi lebih lambat dan tidak efisien. Karena setiap iterasi memerlukan pindai ulang keseluruhan dataset, waktu eksekusi semakin lama.
- c) Karena banyaknya kombinasi item yang perlu disimpan dan diuji, penggunaan memori meningkat seiring dengan ukuran data set yang lebih besar dan kurangnya dukungan.

2. Efektivitas Algoritma Apriori

Meskipun algoritma apriori memiliki keterbatasan dalam penerapannya, apriori juga memiliki sisi efektivitas pada data yang diolahnya :

- a) Efektif dalam data set kecil hingga sedang, yaitu ia mampu mengolah dataset yang berskala kecil hingga menengah saja. Layaknya dataset *e-commerce*, *market basket*, serta data *diagnostic*.
- b) Mudah dipahami dan diterapkan bagi pemula dalam analisis data.

Algoritma *FP-Growth*

Algoritma *FP-Growth* adalah metode yang efisien yang dapat digunakan untuk meningkatkan panjang frekuensi pola sehubungan dengan pertumbuhan fragmen pola. Han mengembangkan algoritma *FP-Growth* pada tahun 2000. Ini menggunakan struktur prefiks yang diperlukan untuk mengompresi informasi tentang frekuensi frekuensi, yang juga dikenal sebagai frekuensi frekuensi frekuensi. *FP-Growth* dirancang untuk mengatasi masalah apriori, terutama dalam hal efisiensi dan skala. *FP-Growth* tidak menggunakan metode *generate-and-test*, sebaliknya, ia menganalisis himpunan item yang sering muncul dengan cara yang langsung menggunakan struktur data yang dikenal sebagai *FP-Tree (Frequent Pattern Tree)*. (Muhammad Raihan, 2024)

1. Solusi yang Ditawarkan *FP-Growth*

FP-Tree adalah struktur terkompresi yang merangkum informasi frekuensi dari item-item yang sering muncul dalam transaksi. Puisi ini didasarkan pada frekuensi kemunculan item, jadi hanya item yang muncul secara frekuen (dengan dukungan minimal) yang dimasukkan. Beberapa manfaat dari algoritma *FP-Growth* termasuk:

Awalnya, menggunakan proses *generate and test* untuk menentukan kandidat

- a) Lebih cepat, tidak perlu membangkitkan kandidat itemset secara eksplisit seperti pada apriori, dan iterasi lebih sedikit karena dataset hanya discan dua kali.
- b) Efektivitas Mempertimbangkan bahwa struktur *fp-tree* menyimpan item yang sama dalam jalur yang sama, yang menghasilkan data yang lebih terkompresi.
- c) Tidak menghasilkan kandidat, *fp-growth* tidak menggunakan metode *generate and test*, dan pola item set langsung diperoleh melalui teknik pertumbuhan pola rekursif.

Tabel Ringkasan Komparasi

Tabel 1. Ringkasan Komparasi

Aspek	<i>FP-Growth</i>	Apriori	S1	S2	S3	S4
Waktu Eksekusi	0,5833 s – 0,6910 s (rata-rata lebih lambat)	0,3008 s – 0,3189 s (rata-rata lebih cepat, hanya 2 scan)	X	✓	✓	X
Jumlah Rule	Sama (22 rules, tergantung min_sup & min_conf)	Sama (hasil rule identik, hanya beda indeks urutan)	✓	X	✓	X
Penggunaan Memori	Lebih besar, generate banyak	Lebih hemat, kompresi dengan	X	X	✓	X

PERMASALAHAN EFISIENSI ALGORITMA APRIORI DAN EVALUASI *FP-GROWTH* BERDASARKAN STUDI LITERATUR

	kandidat, scan berulang	struktur FP- Tree				
<i>Support</i>	1%–20% (tergantung setting)	Sama (identik hasil)	✓	✓	X	X
<i>Confidence</i>	80% – 100% (misal Jo Malone → Zarra = 98%)	Sama (nilai confidence identik untuk rule yang sama)	✓	X	X	X
<i>Lift</i>	>1, valid (contoh Jo Malone– Zarra– Baccarte = 1,2 – 1,5)	Sama (nilai lift sama)	✓	X	X	X
Efisiensi Struktur	Struktur sederhana tapi iteratif (generate- and-test)	Struktur pohon efisien, sekali bangun lalu ditelusuri	X	✓	X	X
Skalabilitas	Kurang efisien untuk data	Sangat cocok untuk data besar	X	✓	X	✓

	besar (>500 transaksi)					
Keunggulan	Mudah dipahami, cocok untuk data kecil	Cepat, scalable, efisien memori	✓	✓	✓	✓
Kelemahan	Proses lambat, kandidat besar, butuh banyak scan	Susah implementasi manual, struktur kompleks	✓	✓	✓	✓
Rekomendasi	Cocok untuk data kecil dan edukasi	Cocok untuk e-commerce, POS, rekomendasi produk	X	✓	✓	✓

1. Keterangan Tabel

Keterangan tanda

✓ = memberikan keterangan positif atau menyetujui pernyataan aspek tersebut.

✗ = memberikan keterangan negatif atau kurang menyetujui pernyataan aspek tersebut.

2. Hasil Pembahasan

Hasil komparasi dari empat jurnal menunjukkan bahwa algoritma *FP-Growth* secara keseluruhan menunjukkan kinerja yang lebih baik dibandingkan Apriori; ini terutama berlaku untuk aspek-aspek berikut :

PERMASALAHAN EFISIENSI ALGORITMA APRIORI DAN EVALUASI *FP-GROWTH* BERDASARKAN STUDI LITERATUR

a) Waktu Eksekusi

Karena *FP-Growth* tidak menggunakan metode *generate-and-test* dan hanya memerlukan dua kali pemindaian data, prosesnya lebih cepat. Karena harus membangkitkan itemset kandidat berulang kali, apriori cenderung lambat. Dari empat jurnal yang diteliti, tiga menyatakan *FP-Growth* unggul dalam waktu proses.

b) Jumlah Peraturan

Keduanya menghasilkan jumlah aturan yang sama untuk parameter dukungan dan kepercayaan. Namun, karena struktur datanya yang lebih fleksibel, *FP-Growth* dapat menghasilkan lebih banyak aturan daripada jurnal lain, seperti studi *dengue*.

c) Metode Penggunaan Memori

Karena *FP-Tree*, yang menyimpan data secara terkompresi, *FP-Growth* menghemat lebih banyak memori. Karena Apriori menyimpan semua kandidat itemset, ia membutuhkan lebih banyak memori.

d) *Lift, Confidence, dan Support*

Jika parameter inputnya sama, nilai dukungan dan keyakinan yang dihasilkan kedua algoritma biasanya sama. *FP-Growth*, di sisi lain, cenderung memberikan nilai lift yang lebih tinggi pada struktur data tertentu karena kemampuan untuk menggabungkan item dengan kemunculan tersembunyi secara lebih efisien.

e) Efisiensi Struktur *FP-Growth*

Penggunaan pohon *FP-Tree*, yang memungkinkan *traversal* langsung terhadap pattern sering, memungkinkan struktur data yang lebih efisien. Sebagai hasil dari struktur iteratifnya yang menghasilkan banyak kandidat, Apriori tidak efisien pada data besar.

f) Skalabilitas

Karena efisiensi dari sisi waktu dan memori, skalabilitas *FP-Growth* ideal untuk data transaksi berskala besar atau *real-time*. Apriori tidak efektif untuk dataset besar, terutama dalam fase eksplorasi awal atau edukatif.

g) Keunggulan dan Kelemahan

- Keunggulan Apriori: mudah digunakan, ideal untuk eksplorasi dan pembelajaran, dan mudah digunakan.

Kekurangan Apriori: adalah lambatnya dan banyaknya proses *generate-test* yang tidak efisien pada skala besar.

- Keunggulan *FP-Growth*: cepat, *scalable*, efisien memori, dan kompatibel dengan sistem produksi.
- Kekurangan *FP-Growth*: adalah strukturnya yang lebih kompleks dan sulit diterapkan secara manual.

3. Data Perbandingan Apriori dan *FP-Growth*

Tabel 2. Data Perbandingan

Aspek	Apriori	<i>FP-Growth</i>
Waktu Proses (detik)	0.58	0.30
Jumlah <i>Rule</i>	15	15
<i>Lift</i> Tertinggi	1.2	12
Penggunaan Memori	80 MB	30 MB

4. Penggunaan Algoritma

Dengan adanya kedua algoritma ini pentingnya kita untuk mengetahui penggunaan dari masing-masing algoritma, untuk efisiensi dan efektivitas dalam pengolahan data tersebut. Keduanya mempunyai spesifikasi dan kelebihan dari setiap algoritma untuk menunjang pengumpulan dan perhitungan evaluasi dari suatu dataset.

Tabel 2. Penggunaan Algoritma

Algoritma	Sebaiknya Digunakan Saat
Apriori	Dataset kecil-menengah, eksperimen yang dilakukan secara manual, proses pembelajaran, atau studi eksploratif awal
<i>FP-Growth</i>	Sistem <i>FP-Growth</i> yang besar, sistem rekomendasi <i>real-time</i> , sistem <i>e-commerce</i> , retail, dan <i>POS</i>

KESIMPULAN DAN SARAN

PERMASALAHAN EFISIENSI ALGORITMA APRIORI DAN EVALUASI *FP-GROWTH* BERDASARKAN STUDI LITERATUR

Dengan demikian, dapat disimpulkan bahwa algoritma *FP-Growth* secara konsisten memiliki keunggulan yang signifikan dibandingkan Apriori. Ini terutama berlaku untuk efisiensi waktu proses, penggunaan memori, dan skalabilitas terhadap dataset yang lebih besar. Kesimpulan ini didasarkan pada hasil tinjauan dari empat penelitian yang dilakukan. *FP-Growth* lebih cocok untuk sistem rekomendasi *real-time*, *e-commerce*, dan *POS* karena hanya membutuhkan dua kali pemindaian data.

Karena strukturnya yang lebih mudah dipahami dan implementasinya yang lebih mudah, algoritma Apriori masih relevan untuk studi eksploratif, dataset kecil, atau kebutuhan pendidikan. Meskipun kedua algoritma menghasilkan aturan asosiasi yang sama dengan parameter yang sama, perbedaan utamanya terletak pada efisiensi struktur data dan kecepatan pemrosesan.

Menurut hasil penelitian ini, pemilihan algoritma harus didasarkan pada sifat data dan kebutuhan sistem. *FP-Growth* lebih cocok untuk penggunaan berskala besar yang membutuhkan kecepatan tinggi. Apriori masih sangat layak digunakan untuk analisis eksploratif dan sederhana.

Selanjutnya, penelitian eksperimental lebih lanjut dapat dilakukan untuk membandingkan kedua algoritma ini dengan teknik modern seperti *ECLAT* atau untuk penerapan mereka dalam berbagai jenis data, seperti smart retail, pendidikan, dan kesehatan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh responden yang telah meluangkan waktu untuk berpartisipasi dalam penelitian ini, serta sumber dan artikel ilmiah pendukung sehingga data yang diperlukan dapat terkumpul dengan baik..

DAFTAR REFERENSI

- Deo Wicaksono, M. I. (2019). The Comparison of Apriori Algorithm with Preprocessing and FP-Growth Algorithm for Finding Frequent Data Pattern in Association Rule. *Sriwijaya International Conference on Information Technology and Its Applications (SICONIAN)*.
- Dimas Irfansyah, D. E. (2023). Literatur Sistematis Perbandingan Kinerja . <https://doi.org/10.70656/ijese.v2i01.323>.

- Erlina, D., Irfansyah, D., Yudi, S., Ikhsanudin, P., & Pujha, S. (2023). Literatur Sistematis Perbandingan Kinerja . <https://doi.org/10.79656/ijese.v2i01.323>.
- Farid Syah Zikri, M. I. (2025). PERBANDINGAN ANTARA ALGORITMA APRIORI DENGAN . *Journal Inovtek Polbeng - Seri Informatika*.
- Muhammad Raihan, S. (2024). Analisis Perbandingan Algoritma Apriori dan FP-Growth untuk Menentukan Strategi Penjualan pada Maestro Jakarta Cafe & Space. *Jurnal Indonesia : Manajemen Informatika dan Komunikasi*.
- Neni Purwati, Y. P. (2023). Komparasi Metode Apriori dan FP-Growth Data Mining . *Jurnal Informatika : Jurnal Pengembangan IT (JPIT)*.
- Ritu Garg, P. G. (2017). Comparative Study of Frequent Itemset Mining . *International Journal of Computer Application*.
- Siriwan Kajornkasirat, B. H. (2025). Recommender system for dengue prevention using machine . *IAES International Journal of Artificial Intelligence (IJ-AI)*.