

BAB II

TINJAUAN LITERATUR

2.1 Penelitian Terkait

Association Rule Mining adalah landasan penambangan data, yang dirancang untuk mengidentifikasi hubungan antar variabel dalam suatu kumpulan data. Misalnya, aturan asosiasi dapat mengungkapkan bahwa pelanggan yang membeli laptop juga cenderung membeli hard drive eksternal. Wawasan seperti itu dapat sangat berharga untuk pengendalian persediaan, karena memungkinkan organisasi untuk memprediksi permintaan barang-barang terkait dan menyesuaikan tingkat stok mereka sesuai dengan itu.

Algoritma FP-Growth meningkatkan kegunaan ARM dengan menyediakan cara yang lebih efisien untuk mengidentifikasi itemset yang sering muncul. Algoritma FP-Growth menghilangkan kebutuhan akan beberapa pemindaian basis data, sehingga sangat cocok untuk menangani kumpulan data besar. Algoritma ini bekerja dengan membangun FP-tree, struktur data ringkas yang merepresentasikan frekuensi itemset dalam suatu kumpulan data. Pendekatan berbasis pohon ini tidak hanya mempercepat proses penemuan pola tetapi juga mengurangi penggunaan memori, menjadikannya pilihan optimal untuk sistem manajemen inventaris (Khalid and Wade, 2022)

Salah satu keunggulan utama penggunaan ARM dan FP-Growth untuk pengendalian persediaan adalah kemampuannya menghasilkan wawasan berbasis data yang melampaui metrik tradisional seperti tingkat stok dan

tingkat perputaran. Misalnya, Chopvitayakun dkk. (2024) menunjukkan bagaimana teknik ini dapat mengidentifikasi tren musiman dan preferensi pelanggan, memungkinkan bisnis untuk menyelaraskan strategi persediaan mereka dengan permintaan pasar. Demikian pula, Hartanti dan Atina (2023) menyoroti peran FP-Growth dalam menyesuaikan sistem manajemen persediaan untuk memenuhi kebutuhan organisasi tertentu. Dengan memanfaatkan wawasan ini, organisasi dapat mencapai pendekatan yang lebih proaktif terhadap pengendalian persediaan, meminimalkan risiko kelebihan stok dan kekurangan stok.

Kesimpulannya, pendahuluan ini menyiapkan landasan untuk eksplorasi mendetail tentang bagaimana Metode Aturan Asosiasi dan Algoritma FP-Growth dapat merevolusi pengendalian inventaris di lingkungan TI. Dengan mengatasi keterbatasan metode tradisional dan memanfaatkan kekuatan teknik komputasi, laporan ini bertujuan untuk memberikan peta jalan untuk mengimplementasikan solusi manajemen inventaris berbasis data yang efisien dan efektif.

Pengendalian persediaan merupakan komponen penting dalam manajemen rantai pasokan, yang secara langsung memengaruhi efisiensi operasional dan profitabilitas perusahaan. Bisnis modern menghadapi tantangan yang semakin besar dalam mempertahankan tingkat persediaan optimal karena fluktuasi permintaan konsumen, gangguan rantai pasokan global, dan kompleksitas pengelolaan persediaan yang besar. Metode komputasi seperti Association Rule Mining (ARM) dan algoritma seperti *Frequent Pattern Growth* (FP-Growth) telah muncul sebagai solusi inovatif

untuk mengatasi tantangan ini. Tinjauan literatur ini mengeksplorasi penelitian sebelumnya tentang teknik pengendalian persediaan dengan penekanan pada metode komputasi, keterbatasan pendekatan tradisional, dan keunggulan ARM dan FP-Growth untuk optimasi persediaan. Tinjauan ini juga mengkaji studi kasus dan landasan teoritis yang relevan, menyoroti pentingnya ARM dalam manajemen persediaan.

Metode pengendalian persediaan tradisional, seperti *Economic Order Quantity* (EOQ), *Just-in-Time* (JIT), dan analisis ABC, telah lama digunakan oleh bisnis untuk mengelola tingkat persediaan. Meskipun metode ini efektif dalam skenario tertentu, metode ini seringkali kurang memadai dalam lingkungan dinamis di mana perilaku konsumen tidak dapat diprediksi, dan tren pasar berubah dengan cepat. Menurut Riadi dkk. (2023), teknik konvensional sangat bergantung pada data historis dan ambang batas yang telah ditentukan sebelumnya, yang mungkin tidak memperhitungkan hubungan rumit antar produk atau dampak faktor eksternal. Keterbatasan ini menciptakan inefisiensi dalam pengisian kembali persediaan, yang menyebabkan kelebihan persediaan atau kekurangan persediaan.

Selain itu, pendekatan tradisional kurang memiliki daya komputasi untuk memproses kumpulan data besar dan mengungkap pola tersembunyi dalam transaksi inventaris. Dwiputra dkk. (2023) mengamati bahwa sistem manual atau semi-otomatis seringkali gagal mengidentifikasi korelasi antar produk, seperti barang mana yang sering dibeli bersamaan. Kelalaian ini dapat menghambat pengembangan strategi pemasaran dan kebijakan inventaris yang efektif. Metode tradisional untuk saat ini sudah tidak dapat beradaptasi dengan

skenario inventaris yang kompleks dan terus berkembang menggarisbawahi kebutuhan akan teknik komputasi canggih seperti ARM dan FP-Growth.

Association Rule Mining (ARM), sebuah teknik penambangan data, mengidentifikasi hubungan atau pola antar item dalam kumpulan data besar. Teknik ini sangat berguna untuk manajemen persediaan karena memungkinkan bisnis untuk mengungkap pola pembelian dan memprediksi permintaan di masa mendatang. Algoritma FP-Growth, sebuah perluasan dari ARM, meningkatkan proses ini dengan secara efisien mengidentifikasi himpunan item yang sering muncul tanpa menghasilkan himpunan kandidat, seperti yang terlihat pada algoritma sebelumnya seperti Apriori. Efisiensi ini membuat FP-Growth sangat cocok untuk menganalisis data persediaan skala besar (Sari and Khoiriah, 2022).

Salah satu keunggulan signifikan FP-Growth adalah kemampuannya untuk menangani kumpulan data besar dengan sumber daya komputasi minimal. (Rahmawati and Merlina, 2018) menunjukkan bahwa strategi bagidantaklukkan algoritma secara signifikan mengurangi waktu yang dibutuhkan untuk memproses data, sehingga memungkinkan pengambilan keputusan secara real-time. Selain itu, FP-Growth memfasilitasi pembuatan wawasan yang dapat ditindaklanjuti, seperti mengidentifikasi produk yang sering dibeli bersamaan atau pola permintaan musiman, yang dapat memberikan informasi untuk strategi pengadaan persediaan dan pemasaran.

Keunggulan lainnya terletak pada skalabilitas algoritma bahwa FP-Growth dapat beradaptasi dengan berbagai jenis data inventaris, sehingga dapat diterapkan di berbagai industri, dari ritel hingga manufaktur.

Kemampuannya untuk bekerja dengan dataset multidimensi memungkinkan bisnis untuk mengintegrasikan manajemen inventaris dengan fungsi lain, seperti peramalan penjualan dan manajemen hubungan pelanggan. Integrasi ini meningkatkan efisiensi operasional secara keseluruhan dan kepuasan pelanggan.

Beberapa studi telah menyoroti keberhasilan implementasi FP-Growth dalam pengendalian persediaan. Misalnya, Riadi dkk. (2023) menerapkan algoritma tersebut untuk menganalisis transaksi pembelian gas LPG 3 kg, mengungkap aturan asosiasi yang membantu pemilik toko mengoptimalkan tingkat stok mereka. Studi tersebut mengungkapkan bahwa FP-Growth tidak hanya meningkatkan akurasi persediaan tetapi juga mengurangi biaya penyimpanan dengan mengidentifikasi barang-barang yang pergerakannya lambat.

Demikian pula, (Rahman and Riana, 2025) menggunakan ARM dan FP-Growth untuk menganalisis data ritel, menunjukkan bagaimana wawasan yang diperoleh dari aturan asosiasi dapat dimanfaatkan untuk pemasaran strategis dan manajemen persediaan. Studi tersebut menemukan bahwa pengelompokan produk berdasarkan pola pembelian memungkinkan pengecer untuk merancang promosi yang ditargetkan dan meningkatkan tingkat perputaran stok. Pendekatan ini terbukti sangat efektif dalam mencegah kekurangan stok barang-barang yang permintaannya tinggi dan meminimalkan kelebihan persediaan.

Dalam studi lain, (Rachmawati *et al.*, 2024) membandingkan FP-Growth dengan algoritma Apriori dalam hal efisiensi dan akurasi. Temuan

mereka menunjukkan bahwa FP-Growth mengungguli Apriori dalam memproses dataset besar, menjadikannya pilihan yang lebih disukai untuk aplikasi pengendalian persediaan. Studi ini juga menyoroti peran algoritma dalam mengoptimalkan organisasi produk, tata letak persediaan, dan strategi pemasaran.

Mengeksplorasi penggunaan FP-Growth dalam teknik pemasaran, menekankan kemudahan implementasinya dan kemampuannya untuk menghasilkan wawasan yang dapat ditindaklanjuti. Para peneliti menerapkan algoritma tersebut pada dataset ritel, mengidentifikasi itemset yang sering muncul yang memberikan informasi untuk kampanye promosi dan keputusan inventaris. Temuan mereka menunjukkan bagaimana FP-Growth dapat meningkatkan efisiensi operasional dan kepuasan pelanggan.

Dasar teoritis dari Association Rule Mining terletak pada identifikasi hubungan antar item dalam basis data transaksional. Aturan asosiasi biasanya dinyatakan dalam bentuk "Jika A, maka B," di mana A dan B adalah himpunan item. Kekuatan aturan ini diukur menggunakan metrik seperti support, confidence, dan lift. Support menunjukkan proporsi transaksi yang mengandung himpunan item tertentu, sedangkan confidence mengukur kemungkinan terjadinya B dengan asumsi A ada. Lift mengevaluasi kekuatan asosiasi relatif terhadap peluang.

FP-Growth dibangun berdasarkan prinsip-prinsip ini dengan menggunakan struktur data berbasis pohon yang disebut FP-tree. Struktur ini mengompresi data masukan, hanya merepresentasikan himpunan item yang sering muncul dan jumlahnya. Algoritma kemudian secara rekursif mempartisi

dataset, membangun FP-tree bersyarat untuk mengidentifikasi pola yang sering muncul. Pendekatan ini menghilangkan kebutuhan untuk menghasilkan kandidat, sebuah proses yang memakan waktu dalam metode ARM tradisional seperti Apriori.

Relevansi ARM terhadap optimasi persediaan terletak pada kemampuannya untuk memberikan wawasan berbasis data yang menginformasikan pengambilan keputusan. Dengan mengidentifikasi hubungan antar produk, bisnis dapat memperkirakan permintaan, mengoptimalkan tingkat stok, dan merancang strategi pemasaran yang efektif. Penggunaan ARM di supermarket, di mana teknik ini menguntungkan pemilik toko dan pelanggan dengan meningkatkan ketersediaan produk dan meningkatkan pengalaman berbelanja. Tinjauan literatur di bagian ini menggarisbawahi potensi transformatif dari Association Rule Mining dan FP-Growth dalam manajemen persediaan. Metode tradisional, meskipun andal dalam lingkungan statis, kurang memiliki kemampuan adaptasi dan daya komputasi yang dibutuhkan untuk mengatasi tantangan persediaan modern. Sebaliknya, ARM dan FP-Growth menawarkan pendekatan berbasis data yang mengungkap pola tersembunyi, memungkinkan bisnis untuk membuat keputusan yang tepat.

Studi kasus yang diteliti menunjukkan manfaat praktis FP-Growth, mulai dari mengurangi biaya penyimpanan hingga meningkatkan tingkat perputaran stok. Efisiensi, skalabilitas, dan kemampuan algoritma untuk menangani kumpulan data besar menjadikannya alat yang sangat berharga bagi bisnis yang ingin mengoptimalkan proses inventaris mereka. Selain itu,

landasan teoritis ARM memberikan kerangka kerja yang kuat untuk memahami dan menerapkan teknik-teknik ini dalam berbagai konteks.

Kesimpulannya, adopsi ARM dan FP-Growth merupakan kemajuan signifikan dalam manajemen persediaan. Seiring bisnis terus bergulat dengan kompleksitas rantai pasokan global, metode komputasi ini menawarkan solusi yang menjanjikan untuk mencapai efisiensi, akurasi, dan kepuasan pelanggan. Penelitian selanjutnya harus mengeksplorasi integrasi FP-Growth dengan teknologi baru, seperti kecerdasan buatan dan pembelajaran mesin, untuk lebih meningkatkan kemampuan dan aplikasinya.

2.2 Data Mining

Data mining merupakan proses menemukan pola, hubungan, atau informasi yang bermanfaat dan sebelumnya tidak diketahui dari sekumpulan data berukuran besar. Proses ini melibatkan penggunaan metode-metode dari bidang statistik, machine learning, dan basis data untuk menggali pengetahuan (*knowledge discovery*) yang dapat digunakan sebagai dasar pengambilan keputusan. Salah satu teknik yang umum digunakan dalam data mining adalah association rule mining, yaitu teknik untuk menemukan aturan asosiasi atau pola kombinasi item yang sering muncul bersamaan dalam suatu kumpulan data transaksi.

2.3 Association Rule Mining

Association rule mining bertujuan untuk menemukan aturan-aturan asosiasi antar itemset di dalam suatu basis data transaksi. Aturan asosiasi umumnya dinyatakan dalam bentuk implikasi $X \rightarrow Y$, yang berarti bahwa kemunculan itemset X dalam suatu transaksi cenderung diikuti oleh

kemunculan itemset Y. Contoh penerapannya adalah analisis keranjang belanja (market basket analysis), yang digunakan untuk mengetahui kombinasi produk yang sering dibeli secara bersamaan oleh konsumen.

Dua ukuran utama yang digunakan untuk menilai kekuatan suatu aturan asosiasi adalah support dan confidence.

$\text{Support}(X) = (\text{Jumlah transaksi yang mengandung } X) / (\text{Total jumlah transaksi}) \times 100\%$

$\text{Confidence}(X \rightarrow Y) = (\text{Jumlah transaksi yang mengandung } X \text{ dan } Y) / (\text{Jumlah transaksi yang mengandung } X) \times 100\%$

Nilai support menunjukkan seberapa sering suatu itemset muncul di dalam keseluruhan data transaksi, sedangkan nilai confidence menunjukkan seberapa kuat hubungan antara itemset X dan itemset Y. Suatu itemset dikatakan frequent itemset apabila nilai support-nya lebih besar atau sama dengan nilai minimum support (minsup) yang telah ditentukan sebelumnya.

2.4 Algoritma FP-Growth (Frequent Pattern Growth)

2.1.1 Pengertian FP-Growth

FP-Growth (Frequent Pattern Growth) merupakan salah satu algoritma dalam data mining yang digunakan untuk menemukan himpunan item yang sering muncul (frequent itemset) di dalam suatu kumpulan data tanpa melakukan proses pembangkitan kandidat (candidate generation) sebagaimana yang dilakukan pada algoritma Apriori. Algoritma ini pertama kali diperkenalkan oleh Han, Pei, dan Yin pada tahun 2000 sebagai solusi atas permasalahan efisiensi pada algoritma Apriori, terutama ketika digunakan

pada basis data berskala besar dengan jumlah kandidat itemset yang sangat banyak.

Ide dasar dari algoritma FP-Growth adalah memampatkan basis data yang merepresentasikan frequent itemset ke dalam sebuah struktur data yang disebut FP-Tree (Frequent Pattern Tree), kemudian membagi basis data yang telah dipampatkan tersebut menjadi sekumpulan basis data bersyarat (conditional pattern base), yang masing-masing berasosiasi dengan satu frequent itemset, dan menambang setiap basis data tersebut secara terpisah. Dengan pendekatan ini, algoritma FP-Growth hanya perlu melakukan pemindaian (scanning) basis data sebanyak dua kali, berbeda dengan algoritma Apriori yang harus memindai basis data berulang kali sesuai dengan panjang kandidat itemset yang diuji.

2.1.2 Struktur FP-Tree

FP-Tree adalah struktur data berbentuk pohon yang digunakan untuk menyimpan informasi tentang itemset yang sering muncul secara ringkas dan padat, tanpa kehilangan informasi yang dibutuhkan untuk proses penambangan pola frequent itemset. Struktur FP-Tree terdiri atas tiga komponen utama, yaitu:

1. Root node, yaitu node akar yang diberi label "null" dan menjadi titik awal pembentukan pohon.
2. Prefix path sub-tree, yaitu cabang-cabang pohon yang terbentuk dari item-item pada setiap transaksi yang telah diurutkan berdasarkan frekuensi kemunculannya.

3. Node-link, yaitu penghubung antar node yang memiliki label item yang sama, yang membentuk sebuah header table sehingga memudahkan proses penelusuran seluruh kemunculan suatu item di dalam pohon.

Setiap node pada FP-Tree menyimpan tiga informasi, yaitu nama item, jumlah cacah (count) yang menunjukkan banyaknya transaksi yang direpresentasikan oleh lintasan dari root hingga node tersebut, dan node-link yang menunjuk ke node berikutnya yang memiliki label item sama di dalam pohon.

2.1.3 Tahapan Algoritma FP-Growth

Secara umum, proses pembentukan frequent itemset menggunakan algoritma FP-Growth dilakukan melalui tiga tahapan utama, yaitu pembentukan FP-Tree, ekstraksi frequent itemset melalui conditional FP-Tree, dan pencarian frequent itemset. Berikut penjelasan dari masing-masing tahapan tersebut.

1) Tahap Pembangkitan FP-Tree (FP-Tree Construction)

- a. Melakukan pemindaian basis data transaksi yang pertama untuk memperoleh daftar seluruh item beserta frekuensi kemunculannya (support count).
- b. Membuang item-item yang frekuensi kemunculannya berada di bawah nilai minimum support yang ditentukan.
- c. Mengurutkan item-item yang tersisa pada setiap transaksi secara menurun (descending) berdasarkan frekuensinya.
- d. Melakukan pemindaian basis data yang kedua, kemudian membangun FP-Tree dengan cara memasukkan setiap transaksi yang telah

diurutkan ke dalam pohon; apabila terdapat prefix path yang sama, maka node yang bersesuaian akan digabung dan nilai count-nya ditambahkan.

2) Tahap Pembentukan Conditional Pattern Base

Conditional pattern base merupakan kumpulan prefix path (lintasan awalan) dari FP-Tree yang berasosiasi dengan suatu item, yang diperoleh dengan menelusuri node-link pada header table untuk setiap item, dimulai dari item dengan frekuensi terendah.

3) Tahap Pembentukan Conditional FP-Tree

Dari setiap conditional pattern base yang telah diperoleh, dibentuk conditional FP-Tree dengan cara menjumlahkan nilai support dari setiap item pada conditional pattern base tersebut, kemudian item yang nilai support-nya memenuhi minimum support akan digunakan untuk membentuk conditional FP-Tree.

4) Tahap Pencarian Frequent Itemset (Mining)

Apabila conditional FP-Tree yang terbentuk hanya berisi satu lintasan tunggal (single path), maka frequent itemset diperoleh melalui kombinasi dari setiap item pada lintasan tersebut. Namun, apabila conditional FP-Tree memiliki lebih dari satu lintasan, maka algoritma FP-Growth akan dijalankan kembali secara rekursif terhadap conditional FP-Tree tersebut hingga diperoleh seluruh frequent itemset.

2.5 Kaggle

Kaggle adalah platform komunitas data science dan machine learning yang menyediakan kumpulan dataset, kompetisi analisis data, lingkungan pemrograman berbasis cloud, serta ruang kolaborasi bagi peneliti, mahasiswa, dan praktisi untuk mengembangkan serta menguji model analitik. Kaggle didirikan pada tahun 2010 dan diakuisisi oleh Google pada tahun 2017. Melalui Kaggle, pengguna dapat mengakses ribuan dataset dari berbagai bidang seperti kesehatan, keuangan, pendidikan, bisnis, dan media sosial, sekaligus memanfaatkan notebook berbasis Python atau R tanpa perlu melakukan instalasi perangkat lunak di komputer lokal.

