

BAB II TINJAUAN PUSTAKA

A. Penelitian Terkait

Berikut adalah beberapa penelitian terkait.

Tabel 1. Studi Pustaka

No.	Peneliti	Keterangan Penelitian
1.	Dewi Anisa Istiqomah, Yuli Astuti, Siti Nurjanah (2022)[6]	Judul: Implementasi Algoritma FP-Growth dan Apriori untuk Persediaan Produk Metode: Algoritma Apriori dan FP-Growth Software: RapidMiner versi 9.9 Hasil Penelitian: Algoritma Apriori menghasilkan 2 aturan asosiasi dengan nilai confidence tertinggi 0,83, sedangkan FP-Growth menghasilkan 10 aturan asosiasi dengan nilai confidence tertinggi 1. Aturan asosiasi membantu Toko Emyra Bedding dalam memantau produk yang sering dibeli bersamaan, sehingga dapat mengurangi risiko kehabisan stok. Keduanya mampu memetakan keterkaitan produk secara efektif, namun FP-Growth lebih unggul dalam jumlah aturan yang dihasilkan.
2.	Badrul Anwar, Ambiyar, Fadhilah (2023)[2]	Judul: <i>Application of the Fp-Growth Method to Determine Drug Sales Patterns</i> Metode: Algoritma FP-Growth Hasil Penelitian: Ditemukan pola keterkaitan penjualan obat yang sering dibeli bersamaan, seperti Dexa dengan Paracetamol dan Omz dengan Domperidone , dengan confidence tertinggi mencapai 85,29% . Pola ini dapat membantu penataan obat dan pelayanan yang lebih efisien di Klinik Pratama Sehati Husada.
3.	Jeffri Prayitno Bangkit Saputra, Silvia Anggun Rahayu, Taqwa Hariguna (2023)[7]	Judul: <i>Market Basket Analysis Using Fp-Growth Algorithm to Design Marketing Strategy by Determining Consumer Purchasing Patterns</i> Metode: Algoritma FP-Growth Software: RapidMiner Hasil Penelitian:

No.	Peneliti	Keterangan Penelitian
		Diperoleh 33 pola kebiasaan belanja konsumen dari 10 transaksi dengan minimum support 0,2 dan confidence 0,75. Contohnya, konsumen yang membeli gula, teh, air mineral, dan kopi akan membeli permen. Sistem membantu menyusun rekomendasi produk dan mengelola stok barang secara lebih efektif di Toko Asra.
4.	Luki Hernando (2019)[8]	Judul: Algoritma Apriori dan FP-Growth untuk Analisa Perbandingan Data Penjualan Laptop Berdasarkan Merk yang Diminati Konsumen (Studi Kasus: Indocomputer Payakumbuh) Metode: Algoritma Apriori dan FP-Growth Software: WEKA 3.7.4 Hasil Penelitian: Kedua algoritma menghasilkan aturan asosiasi yang kuat, namun FP-Growth lebih efisien dalam menghasilkan frequent itemset. Merk laptop yang paling banyak diminati adalah Lenovo AMD A8 (K01), Toshiba C840-I3 (K09), HP AMD A8 (K12), dan ASUS X200 MA (K14). Sistem membantu menentukan strategi stok dan promosi berdasarkan pola pembelian konsumen.
5.	Agus Muhamad Andika, Nana Suarna, Raditya Danar Dana (2023)[9]	Judul: Analisa Dataset Asosiasi Penjualan Menggunakan Metode FP-Growth Metode: Algoritma FP-Growth Software: RapidMiner Studio Hasil Penelitian: Ditemukan pola asosiasi antara produk BATIK LONTARA dan JAM LOKESWARA dengan confidence sebesar 0,97 dan support 0,39. Pola ini dapat digunakan untuk menyusun strategi penempatan produk dan promosi yang lebih efektif dalam bisnis ritel.
6.	Saut Parsaoran Tamba, Mario Sitanggang, Bimo Christhoper Situmorang, Gracia Laura Panjaitan,	Judul: <i>Application of Data Mining To Determine The Level Of Fish Sales In Pt. Trans Retail With Fp-Growth Method</i> Metode: Algoritma FP-Growth Software: RapidMiner Studio Hasil Penelitian:

No.	Peneliti	Keterangan Penelitian
	Marlince Nababan (2022)[10]	Ditemukan bahwa ikan Jengka Split paling banyak diminati dengan tingkat support 90%. Kombinasi pembelian menunjukkan jika konsumen membeli ikan Jengka, maka kemungkinan besar juga akan membeli Teri Buntiaw, ikan teri besar, dan ikan peda putih dengan confidence mencapai 100% . Pola ini dapat dijadikan acuan dalam menentukan stok dan strategi penyediaan ikan.
7.	Firmansyah, Agus Yulianto (2021)[11]	Judul: Market Basket Analysis untuk Promosi Penjualan Buku menggunakan Algoritma FP-Growth (Studi Kasus: Gramedia Matraman Jakarta) Metode: Algoritma FP-Growth Software: RapidMiner Hasil Penelitian: Dari 10.987 transaksi penjualan, ditemukan 6 aturan asosiasi. Kombinasi Donat Ring Regular + Glass Cake memiliki support 5,5%, confidence 98,80%, lift 3.075, dan conviction 55.436 menuju produk Roti Regular All Varian. Roti Regular terbukti sebagai produk utama yang sering dibeli konsumen dan direkomendasikan untuk promosi dan bundling.
8.	Ahmad Fitri Boy, Suardi Yakub, Ishak, Zulfian Azmi (2022)[12]	Judul: Implementasi Data Mining pada Pengaturan Distribusi Barang dengan Menggunakan Algoritma FP-Growth Metode: Algoritma FP-Growth Software: Visual Basic 2010 Hasil Penelitian: Sistem berhasil mengidentifikasi 7 aturan asosiasi antara kode pengiriman barang. Contoh: jika pengiriman A010 maka akan dipasangkan dengan A005 (support 23,33%, confidence 77,78%). Sistem ini membantu Lastana Express dalam menganalisis pola distribusi dan pengambilan keputusan logistik secara efisien.
9.	Dwi Hartanti, Vihi Atina (2023)[13]	Judul: <i>Product Stock Supply Analysis System with FP-Growth Algorithm</i> Metode: Algoritma FP-Growth

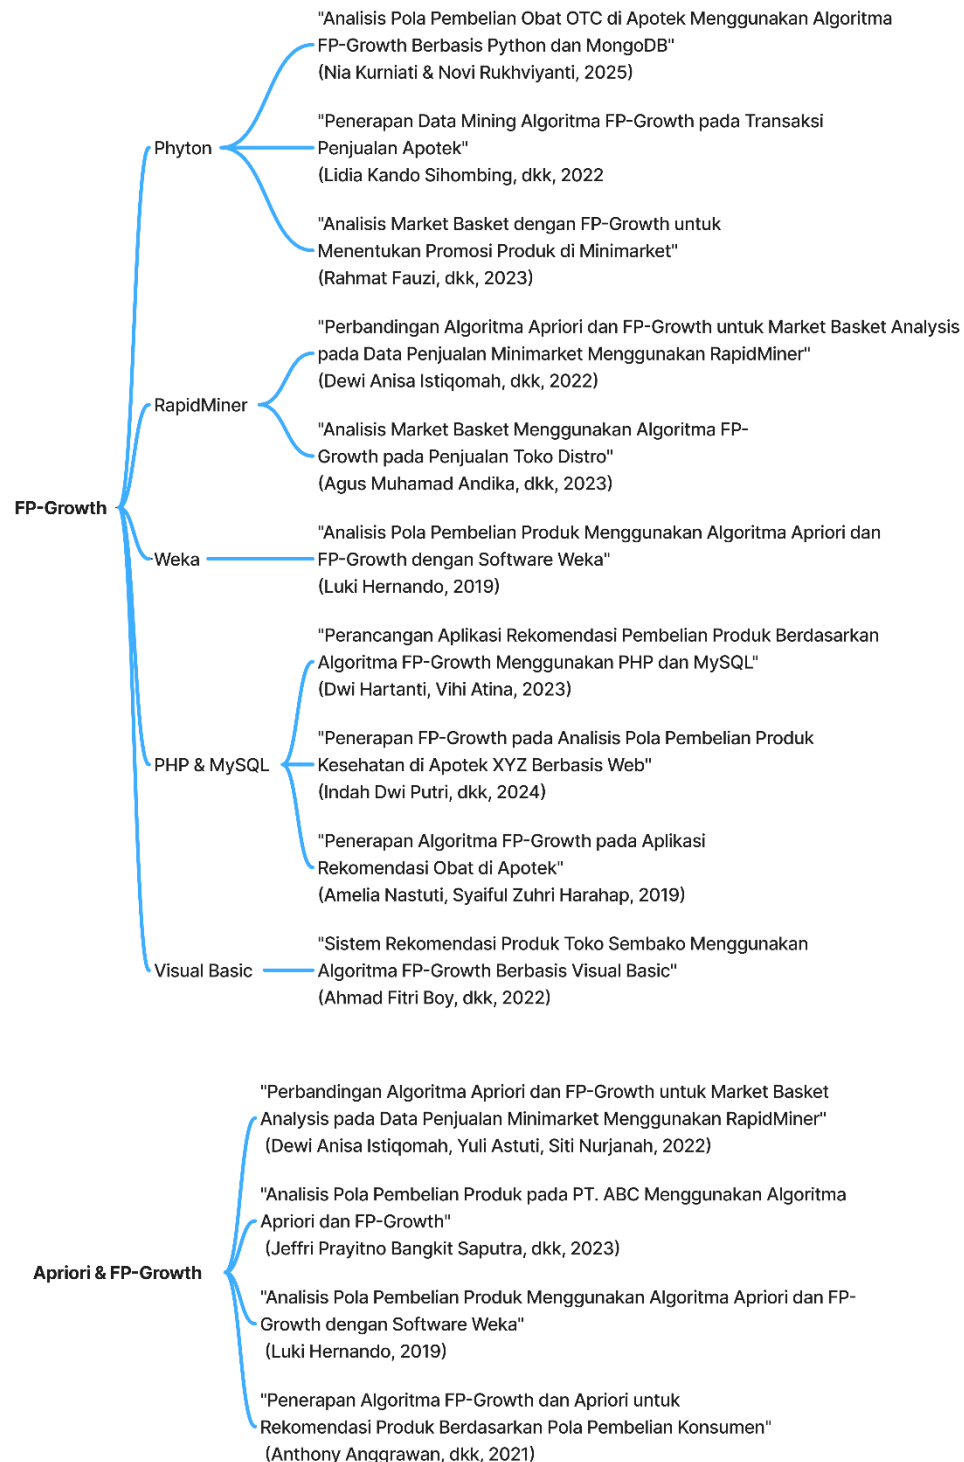
No.	Peneliti	Keterangan Penelitian
		Software: PHP dan MySQL Hasil Penelitian: Ditemukan pola bahwa konsumen yang membeli UREA Fertilizer dan Jaya Seed Chili juga cenderung membeli NPK Mutiara 16-16-16 , dengan confidence 71,4% dan lift 3,67 . Sistem membantu mengelola stok produk secara optimal sesuai pola pembelian konsumen.
10.	Indah Dwi Putri, Yuhandri, Romi Hardianto (2024)[14]	Judul: <i>Application of the Fp-Growth Algorithm in Consumer Purchasing Pattern Analysis</i> Metode: Algoritma FP-Growth Software: PHP dan MySQL Hasil Penelitian: Dari 10 transaksi dengan minimum support 0.2 dan minimum confidence 0.75, diperoleh 33 pola kebiasaan belanja konsumen yang dapat membantu pengambilan keputusan bisnis dalam pengelolaan stok dan penempatan produk.
11.	Satia Suhada, Daniel Ratag, Gunawan, Dede Wintana, Taufik Hidayatulloh (2020)[15]	Judul: Penerapan Algoritma FP-Growth Untuk Menentukan Pola Pembelian Konsumen Pada AHASS Cibadak Metode: Algoritma FP-Growth Software: RapidMiner Hasil Penelitian: Metode FP-Growth berhasil mengidentifikasi pola pembelian sparepart yang sering dibeli bersamaan, seperti OLI MPX2 10W30 SL 0,8L IDE dan BRAKESHOE, yang sangat berguna untuk strategi pemesanan.
12.	Anthony Anggrawan, Mayadi, Christofer Satria (2021)[16]	Judul: Menentukan Akurasi Tata Letak Barang dengan Menggunakan Algoritma Apriori dan FP-Growth Metode: Algoritma Apriori & FP-Growth Hasil Penelitian: Algoritma FP-Growth menghasilkan 6 aturan dengan akurasi 128%, lebih baik daripada algoritma Apriori yang menghasilkan 4 aturan dengan akurasi 78%. Hasil ini menunjukkan bahwa

No.	Peneliti	Keterangan Penelitian
		FP-Growth lebih efektif dalam menentukan tata letak barang.
13.	Fandi Achmad, Odi Nurdiawan, Yudhistira Arie Wijaya (2023)[17]	Judul: Analisa Pola Transaksi Pembelian Konsumen pada Toko Ritel Kesehatan Menggunakan Algoritma FP-Growth Metode: Algoritma FP-Growth Hasil Penelitian: Penelitian menghasilkan 9 aturan asosiasi dengan nilai minimum support 0,005, confidence 0,1, dan lift 1,0. Aturan ini membantu strategi cross-selling dengan memberikan informasi pola pembelian yang detail
14.	Lidia Kando Sihombing, Tugiono, Usti Fatimah Sari Sitorus (2022)[18]	Judul: Implementasi Data Mining Dalam Menganalisa Pola Penjualan Roti Menggunakan Algoritma FP-Growth Metode: Algoritma FP-Growth Hasil Penelitian: Penelitian berhasil menghasilkan pola penjualan roti dengan 9 aturan asosiasi, memperlihatkan keterkaitan produk yang sering dibeli bersama, dan memberikan strategi pemasaran yang lebih efektif.
15.	Rahmat Fauzi, Alvendo Wahyu Aranski, Nopriadi, Ellbert Hutabri (2023)[19]	Judul: Implementasi Data Mining Pada Penjualan Pakaian dengan Algoritma FP-Growth Metode: Algoritma FP-Growth Hasil Penelitian: Penelitian menemukan pola penjualan Gamis dan Jilbab dengan support 53,33% dan confidence 100%. Algoritma FP-Growth membantu dalam strategi pemasaran dan pengaturan stok barang.
16.	Amelia Nastuti, Syaiful Zuhri Harahap (2019)[20]	Judul: Teknik Data Mining untuk Penentuan Paket Hemat Sembako dan Kebutuhan Harian dengan Menggunakan Algoritma FP-Growth (Studi Kasus di Ulfamart Lubuk Alung) Metode: Algoritma FP-Growth Hasil Penelitian: Penelitian menghasilkan 8 aturan asosiasi dengan minimum support 20% dan minimum confidence 80%. Rekomendasi paket hemat dapat meningkatkan strategi pemasaran.

No.	Peneliti	Keterangan Penelitian
17.	Anggun Pastika Sandi, Vina Widya Ningsih (2023)[21]	Judul: Implementasi Data Mining Sebagai Penentu Persediaan Produk dengan Algoritma FP-Growth pada Data Penjualan Sinarmart Metode: Algoritma FP-Growth Hasil Penelitian: Penelitian menunjukkan bahwa algoritma FP-Growth dapat mengidentifikasi produk yang paling banyak terjual, seperti minuman dan susu, dengan support 96,77% dan confidence 100%. Ini membantu dalam pengadaan stok yang efisien.
18.	M. Hafizh, Triana Novita, Dodi Guswandi, Hadi Syahputra, Liga Mayola (2023)[22]	Judul: Implementasi Data Mining Menggunakan Algoritma FP-Growth untuk Menganalisa Transaksi Penjualan Ekspor Online Metode: Algoritma FP-Growth Hasil Penelitian: Ditemukan 9 rule dari 51 transaksi penjualan ekspor. Penjualan tertinggi terjadi di Filipina dengan produk Fender 1, sementara Malaysia memiliki variasi penjualan paling rendah, dan Singapura memiliki distribusi produk paling seimbang.
19.	Nia Kurniati & Novi Rukhviyanti (2025)[23]	Judul: Minimarket Sales Optimization: Implementation of FP-Growth Algorithm and MongoDB with Python Metode: Algoritma FP-Growth Software: MongoDB, Python (mlxtend), Flask Hasil Penelitian: Menggunakan 150.000 data transaksi, penelitian ini berhasil mengidentifikasi pola pembelian pelanggan, meningkatkan efisiensi operasional hingga 15%, meningkatkan volume penjualan sebesar 12,3%, dan mengurangi stok mati sebesar 8,7%. Produk Beras MCS 5KG menjadi yang paling menguntungkan.

No.	Peneliti	Keterangan Penelitian
20.	Soni Erpian, Rini Astuti, Willy Prihartono, Ryan Hamonangan (2025)[24]	Judul: Implementasi Algoritma FP-Growth untuk Meningkatkan Pemasaran Produk Minuman Boba Berbasis Python (Studi Kasus: Kedai Ngenyod's Desa Bogor Indramayu) Metode: Algoritma FP-Growth Hasil Penelitian: Menggunakan 508 data transaksi, ditemukan pola pembelian kuat seperti Milo Ori dan Boba Milk. FP-Growth mampu meningkatkan efisiensi pemasaran dan manajemen stok, serta memberikan rekomendasi strategi bundling produk untuk meningkatkan penjualan di UMKM.

Diagram *mind map* dicontohkan pada gambar berikut ini



Gambar 1. *Mind Map* Penelitian

Beragam penelitian sebelumnya telah menerapkan algoritma FP-Growth untuk menganalisis pola pembelian konsumen di berbagai sektor, seperti ritel, makanan, pakaian, dan kesehatan. Sebagian besar fokus pada identifikasi produk yang sering dibeli bersamaan untuk mendukung strategi promosi, pengelolaan stok, atau tata letak barang. Banyak di antaranya menggunakan software seperti RapidMiner, WEKA, PHP, atau Visual Basic, dengan skala data yang relatif kecil hingga menengah. Beberapa penelitian juga membandingkan FP-Growth dengan algoritma Apriori, dan menyimpulkan bahwa FP-Growth lebih efisien dalam menghasilkan aturan asosiasi.

Penelitian ini berbeda karena secara khusus menerapkan FP-Growth pada data transaksi obat bebas (OTC), terutama kategori analgesik dan antipiretik, dengan dukungan analisis berbasis Python. Selain menghasilkan pola asosiasi, pendekatan ini mengintegrasikan visualisasi interaktif untuk mendukung interpretasi hasil dan pengambilan keputusan di apotek. Dengan demikian, penelitian ini tidak hanya memperluas konteks penerapan FP-Growth ke bidang farmasi, tetapi juga menghadirkan solusi berbasis data yang lebih relevan dan aplikatif bagi pengelolaan operasional apotek.

B. Landasan Teori

1. Data Mining

Data Mining adalah proses untuk menemukan pola atau informasi penting dari kumpulan data yang besar. Menurut Larose (dalam Athanasia [25]), *Data Mining* dibagi menjadi beberapa kelompok berdasarkan tugas yang dapat dilakukan, yaitu deskripsi, estimasi, prediksi, klasifikasi, pengklusteran, dan asosiasi.

a. Deskripsi

Deskripsi digunakan untuk pengelolaan *Data Mining* dengan cara menggambarkan pola kecenderungan dalam suatu data. Deskripsi dalam *Data Mining* ini lebih menjelaskan kepada pola-pola yang terbentuk akibat adanya penambahan data.

b. Estimasi

Estimasi pada Data Mining hampir sama dengan klasifikasi akan tetapi target dari estimasi ini lebih ke hasil yang sifatnya numerik, bukan kategori. Beberapa teknik yang digunakan dalam klasifikasi dan estimasi dapat pula digunakan (untuk keadaan yang tepat) untuk prediksi.

c. Prediksi

Prediksi memiliki beberapa kesamaan dengan klasifikasi dan estimasi, hasil yang didapat pada prediksi ini akan ada pada kejadian yang akan datang.

d. Klasifikasi

Klasifikasi pada Data Mining digunakan untuk mengelompokkan sesuatu berdasarkan kategori. Kategori di sini berarti sesuatu yang sudah digolongkan, misal gaji rendah, sedang, dan tinggi, curah hujan rendah, sedang, dan tinggi, dan sebagainya.

e. Pengklusteran

Pengklusteran berbeda dengan klasifikasi, pengklusteran lebih kepada pengelompokan data berdasarkan kemiripan. Pengklusteran mencoba untuk melakukan pembagian terhadap keseluruhan data menjadi kelompok-kelompok yang memiliki kemiripan (homogen), dimana kemiripan dengan record dalam kelompok lain akan bernilai minimal.

f. Asosiasi

Asosiasi dalam Data Mining adalah menemukan atribut yang muncul dalam suatu waktu. Dalam dunia bisnis lebih umum disebut analisis keranjang belanja (*Market Basket Analysis*). Contoh asosiasi dalam bisnis adalah mencari barang dalam supermarket yang dibeli secara bersamaan dalam suatu waktu. Penting tidaknya suatu aturan asosiatif dapat diketahui dengan dua parameter, *support* (nilai penunjang) yaitu persentase kombinasi *item* tersebut dalam database dan *confidence* (nilai kepastian) yaitu kuatnya hubungan antar *item* dalam aturan asosiatif.

Dalam penelitian ini, *Data Mining* digunakan untuk menganalisis data transaksi pembelian obat bebas (OTC) guna menemukan hubungan atau pola pembelian antar produk. Proses ini melibatkan teknik-teknik analisis seperti asosiasi dan algoritma FP-Growth untuk menghasilkan aturan yang relevan.

2. Association Rule Mining

Association rule mining adalah suatu prosedur untuk mencari hubungan antar item dalam suatu data set yang ditentukan[26][26][26]. Terdapat dua tahap dalam melakukan analisis asosiatif, yaitu *frequent itemset candidate generation* dan *rule generation*. Tahap *frequent itemset candidate generation*, merupakan tahap untuk mencari *frequent itemset* dengan menggunakan algoritma FP-Growth dan struktur FP-Tree. Tahap *rule generation* adalah tahap mengeneralisasi *rule* dengan *Confidence* yang tinggi dari setiap *frequent itemset*[27]. Untuk menilai validitas aturan ini, digunakan tiga metrik utama: support, confidence, dan lift.

a. *Support* (Nilai Penunjang)

Support adalah ukuran statistik yang menunjukkan seberapa sering kombinasi item X dan Y muncul bersama dalam dataset. Metrik ini menggambarkan popularitas suatu aturan dalam keseluruhan transaksi. Nilai *support* dihitung dengan rumus sebagai berikut:

$$\begin{aligned} & \text{Support } (X \rightarrow Y) \\ &= \frac{\text{Jumlah Transaksi yang Mengandung } X \cup Y}{\text{Jumlah total Transaksi}} \end{aligned} \quad (1)$$

Aturan dengan nilai support yang rendah biasanya diabaikan karena dianggap tidak signifikan secara statistik.

b. *Confidence* (Nilai Kepastian)

Confidence mengukur kekuatan aturan asosiasi dengan menghitung probabilitas bahwa transaksi yang mengandung item X juga mengandung item Y. Semakin tinggi nilai *confidence*, semakin besar kepercayaan terhadap aturan tersebut. Rumusnya adalah:

$$Confidence(X \rightarrow Y) = \frac{Support(X \cup Y)}{Support(X)} \quad (2)$$

Confidence digunakan untuk mengevaluasi keandalan atau reliabilitas dari suatu aturan yang dihasilkan.

c. *Lift*

Lift adalah metrik yang digunakan untuk menilai kekuatan hubungan antara X dan Y dengan membandingkan *confidence* terhadap *support* Y. *Lift* menunjukkan apakah Y lebih mungkin muncul ketika X muncul dibandingkan dengan kemungkinan munculnya Y secara umum. Rumusnya sebagai berikut:

$$Lift(X \rightarrow Y) = \frac{Confidence(X \rightarrow Y)}{Support(Y)} \quad (3)$$

Interpretasi nilai *lift*:

- *Lift* > 1: Korelasi positif, X dan Y lebih sering muncul bersama dari yang diharapkan.
- *Lift* = 1: Tidak ada korelasi antara X dan Y (independen).
- *Lift* < 1: Korelasi negatif, kehadiran X justru mengurangi kemungkinan Y.

3. Algoritma Apriori

Algoritma Apriori merupakan salah satu teknik dasar dalam association rule mining yang pertama kali diperkenalkan oleh Agrawal dan Srikant pada tahun 1994. Algoritma ini dirancang untuk menentukan frequent itemset (kumpulan item yang sering muncul) dalam suatu dataset transaksi dan selanjutnya membentuk aturan asosiasi (association rules) berdasarkan metrik statistika seperti support dan confidence. Prinsip utama dari Apriori adalah “apabila suatu itemset sering muncul, maka seluruh subset-nya juga harus sering muncul”, sehingga proses pencarian aturan dapat dipersempit dan lebih efisien dibandingkan memeriksa semua kemungkinan kombinasi item secara langsung [28].

Dalam konteks *market basket analysis* atau analisis keranjang belanja, algoritma Apriori mengidentifikasi hubungan antara produk-produk yang sering dibeli bersama oleh konsumen. Setiap aturan asosiasi yang dihasilkan biasanya berbentuk:

“Jika *antecedent* (X), maka *consequent* (Y)”, yang disertai nilai *support* dan *confidence* untuk menunjukkan seberapa sering dan seberapa kuat hubungan tersebut terjadi dalam data transaksi. Nilai *support* mengukur persentase transaksi yang mencakup kombinasi item tertentu, sedangkan *confidence* menunjukkan seberapa sering *consequent* muncul dalam transaksi yang mengandung *antecedent*.

Apriori bekerja dengan menguji itemset berukuran kecil secara berurutan ke ukuran yang lebih besar (candidate itemset generation) dan memfilter item yang tidak memenuhi minimum support yang telah ditentukan. Itemset yang lolos kemudian digunakan untuk membentuk

aturan asosiasi yang memenuhi nilai minimum support dan confidence, yang selanjutnya dievaluasi untuk menentukan kekuatan dan relevansinya.

Meskipun algoritma ini banyak digunakan dalam berbagai aplikasi seperti perencanaan inventaris, pemasaran dan penataan produk, Apriori memiliki keterbatasan terutama pada dataset yang sangat besar karena memerlukan beberapa kali pemindaian database dan bisa menghasilkan sejumlah besar candidate itemset. Untuk mengatasi hal ini, algoritma alternatif seperti Frequent Pattern Growth (FP-Growth) sering dipilih karena struktur pemrosesannya yang lebih efisien.

4. Algoritma *Frequent Pattern Growth* (FP-Growth)

Algoritma FP-Growth (*Frequent Pattern Growth*) merupakan salah satu metode dalam Data Mining yang digunakan untuk menemukan pola *itemset* yang sering muncul dalam suatu kumpulan data transaksi. FP-Growth termasuk dalam kategori algoritma *association rule mining* dan dikembangkan sebagai alternatif dari algoritma Apriori. Perbedaan utamanya terletak pada efisiensi kinerja, di mana FP-Growth tidak perlu membangkitkan kandidat itemset terlebih dahulu seperti yang dilakukan oleh Apriori, sehingga proses pencarian pola menjadi lebih cepat dan tidak memerlukan banyak pembacaan ulang data[29]. FP-Growth memiliki kecepatan dan efisiensi pemrosesan yang lebih unggul dalam analisis data besar meskipun menggunakan struktur data FP-Tree yang lebih kompleks[30].

Studi serupa pada sektor farmasi menunjukkan bahwa FP-Growth lebih cocok diterapkan untuk data penjualan berukuran besar karena mengurangi waktu proses dibandingkan Apriori[31]. FP-Growth juga sangat relevan untuk strategi bisnis ritel karena kemampuannya menemukan pola pembelian produk yang sering muncul secara efisien[32]. Di sisi lain, Rachmawati et al. menunjukkan bahwa dalam konteks penjualan pupuk, FP-Growth mampu menyusun pola itemset dengan waktu proses yang jauh lebih cepat daripada algoritma Apriori[33].

Algoritma FP-Growth (*Frequent Pattern Growth*) merupakan salah satu teknik dalam *Data Mining* yang digunakan untuk menemukan pola hubungan atau kombinasi item yang sering muncul dalam kumpulan data transaksi. Berbeda dengan algoritma Apriori yang mengandalkan pembangkitan kandidat itemset dan evaluasi berulang terhadap database, FP-Growth justru menawarkan pendekatan yang lebih efisien. Algoritma ini menggunakan struktur data khusus bernama FP-Tree (*Frequent Pattern Tree*), yang berfungsi untuk menyimpan informasi transaksi dalam bentuk yang terkompresi, sehingga tidak perlu menyimpan atau memproses semua data mentah secara berulang[29].

Proses kerja FP-Growth diawali dengan penghitungan frekuensi setiap item dalam dataset. Selanjutnya, item disusun berdasarkan frekuensi tertinggi, dan setiap transaksi direpresentasikan ulang sesuai urutan tersebut sebelum dimasukkan ke dalam FP-Tree. Setelah FP-Tree terbentuk, algoritma melanjutkan dengan eksplorasi pola menggunakan pendekatan

rekursif melalui *conditional pattern base* dan *conditional FP-Tree*, untuk akhirnya membentuk *frequent itemsets* yang valid. Ini memungkinkan FP-Growth mengekstraksi pola tanpa harus membangkitkan seluruh kandidat itemset, yang sangat menghemat sumber daya komputasi terutama pada dataset berskala besar[29].

Dalam penerapannya, algoritma FP-Growth menggunakan dua parameter utama, yaitu *support* dan *confidence*. *Support* mengukur seberapa sering kombinasi item muncul dalam keseluruhan transaksi, sedangkan *confidence* menggambarkan tingkat kepastian bahwa suatu item akan muncul apabila item lainnya sudah dibeli terlebih dahulu. Hanya kombinasi item yang memenuhi ambang batas minimum *support* dan *confidence* yang akan dianggap sebagai aturan asosiasi yang sah. Keunggulan utama dari FP-Growth terletak pada efisiensi proses dan skalabilitasnya dalam menangani data besar. Akan tetapi, kelemahannya adalah struktur FP-Tree yang bisa menjadi kompleks dan sulit dikendalikan apabila data transaksi mengandung banyak item unik atau bervariasi secara ekstrem[29].

Dalam konteks penelitian ini, algoritma FP-Growth diterapkan untuk menganalisis data transaksi penjualan obat bebas (OTC) di Apotek KMG Kesugihan. Tujuan dari penerapan ini adalah untuk menemukan pola pembelian obat yang sering terjadi secara bersamaan dalam satu transaksi. Pola tersebut nantinya dapat dimanfaatkan untuk menyusun strategi penataan stok, pembuatan paket bundling produk, hingga merancang promosi yang lebih tepat sasaran sesuai dengan kebiasaan pembelian konsumen. Hal ini sejalan dengan penelitian Amelia et al.[29] yang menunjukkan bahwa penggunaan algoritma FP-Growth dapat meningkatkan efektivitas strategi pemasaran dan perencanaan logistik pada sektor ritel dan kesehatan.

Algoritma FP-Growth merupakan salah satu metode dalam teknik Data Mining untuk asosiasi, yang digunakan dalam proses pencarian pola hubungan antar item. Algoritma ini bertujuan untuk mengidentifikasi *frequent itemsets*, yaitu himpunan item yang sering muncul bersama dalam suatu kumpulan data transaksi. Proses kerja algoritma FP-Growth terdiri atas tiga tahapan utama, yakni: pembentukan *conditional pattern base*, konstruksi *conditional FP-Tree*, dan ekstraksi *frequent itemsets*[5]. Namun, sebelum memasuki tahapan inti tersebut, terdapat beberapa proses awal yang harus dilakukan yaitu:

- a. Penyiapan dataset
- b. Pencarian frequent itemset
- c. Mengurutkan berdasarkan priority
- d. Dataset (item dalam setiap transaksi) diurutkan berdasarkan priority
- e. Membentuk FP-Tree

Setelah FP-Tree terbentuk, barulah melakukan tiga tahapan utama dalam algoritma FP-Growth berikut:

- a. Tahap Pembangkitan *Conditional Pattern Base*

Conditional pattern base merupakan hasil dari lintasan *FP-Tree* yang terbentuk dengan mempertimbangkan item dengan *support count* terkecil atau anak root terakhir.

b. Tahap Pembangkitan *Conditional FP-Tree*

Hal pertama yang dilakukan pada tahap ini ialah menentukan minimum *support*. Selanjutnya, menjumlahkan *support count* setiap item pada conditional pattern base. Hasil penjumlahan yang memenuhi minimum *support* akan dibangkitkan kembali dengan conditional *FP-Tree*.

c. Tahap Pembangkitan *Frequent Itemset*

Frequent Itemset dibentuk berdasarkan kombinasi setiap item dalam *FP-Tree* berupa rule. Apabila dalam *FP-Tree* terdapat item yang sama pilih *support count* dengan nilai terkecil.

5. Obat Bebas (*Over The Counter-OTC*)

Obat bebas atau yang dikenal dengan istilah *Over The Counter* (OTC) adalah jenis obat yang dapat dibeli secara langsung di apotek atau toko obat tanpa memerlukan resep dari dokter[34]. Obat ini digunakan untuk menangani keluhan kesehatan ringan yang umum dialami masyarakat, seperti demam, batuk, pilek, sakit kepala, nyeri otot, dan gangguan pencernaan. Berdasarkan peraturan dari Badan Pengawas Obat dan Makanan (BPOM), obat bebas dibagi menjadi dua jenis, yaitu obat bebas biasa yang ditandai dengan lingkaran hijau dan obat bebas terbatas yang ditandai dengan lingkaran biru[34].

Karena sifatnya yang bebas dijual dan mudah diakses oleh masyarakat, obat OTC memiliki perputaran penjualan yang tinggi dan beragam pola pembelian yang sangat potensial untuk dianalisis. Kategori obat ini mencakup berbagai bentuk sediaan seperti tablet, kapsul, sirup, salep, dan lainnya. Beberapa contoh umum dari obat bebas yang sering dijual di apotek antara lain paracetamol (penurun panas), antasida (untuk lambung), obat batuk dan flu, vitamin, serta antiseptik ringan[34].

Pemahaman terhadap pola pembelian obat OTC menjadi penting dalam konteks pengelolaan apotek. Dengan mengetahui produk mana yang sering dibeli bersamaan oleh pelanggan, pihak apotek dapat menyusun strategi pengadaan dan penyusunan stok secara lebih efektif. Selain itu, analisis ini juga dapat mendukung promosi silang (*cross-selling*) dan peningkatan pelayanan berbasis kebutuhan pelanggan yang sebenarnya. Oleh karena itu, obat OTC sangat relevan untuk dijadikan objek kajian dalam penelitian analisis pola pembelian menggunakan metode *Data Mining*.

6. Google Colaboratory

Google Colaboratory, atau yang lebih dikenal sebagai Google Colab, merupakan layanan berbasis cloud yang disediakan oleh Google untuk menjalankan dan berbagi notebook Jupyter. Platform ini memungkinkan pengguna untuk menulis dan mengeksekusi kode Python langsung melalui browser tanpa perlu melakukan instalasi perangkat lunak tambahan. Salah satu keunggulan utama dari Google Colab adalah tersedianya akses gratis ke sumber daya komputasi seperti GPU dan TPU, yang sangat berguna dalam proses komputasi intensif seperti pelatihan

model machine learning dan analisis data skala besar. Selain itu, integrasi dengan Google Drive memudahkan pengguna dalam menyimpan dan berbagi proyek mereka secara kolaboratif.

Dalam konteks *Data Mining*, Google Colab menyediakan lingkungan yang ideal untuk mengimplementasikan algoritma seperti FP-Growth. Dengan dukungan pustaka Python seperti `mlxtend` dan `Pandas`, pengguna dapat dengan mudah melakukan analisis asosiasi untuk menemukan pola pembelian yang sering terjadi dalam data transaksi. Kemampuan visualisasi yang disediakan oleh pustaka seperti `matplotlib` dan `seaborn` juga memungkinkan pengguna untuk menyajikan hasil analisis dalam bentuk grafik yang informatif. Selain itu, karena Google Colab berbasis cloud, pengguna dapat mengakses dan menjalankan notebook mereka dari berbagai perangkat tanpa khawatir kehilangan data atau konfigurasi lingkungan kerja.

Penggunaan Google Colab dalam penelitian ini akan memfasilitasi proses analisis data transaksi penjualan obat bebas di Apotek KMG Kesugihan. Dengan memanfaatkan algoritma FP-Growth, diharapkan dapat diidentifikasi pola pembelian obat yang sering terjadi, sehingga apotek dapat mengoptimalkan strategi pengadaan dan penataan produk. Selain itu, hasil analisis ini dapat digunakan untuk merancang promosi silang (*cross-selling*) yang lebih efektif, berdasarkan pola pembelian yang telah teridentifikasi.