

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Sebelumnya

Penelitian yang dilakukan untuk menentukan paket *bundling* dan promo telah banyak dilakukan. Tidak sedikit pula diantaranya mampu memberikan hasil *rules* yang akurat sehingga dapat diterapkan dalam berbagai bidang / aspek kehidupan disekitar kita. Dari banyaknya penelitian yang sudah dilakukan sebelumnya menunjukkan bahwa menentukan paket *bundling* dan promo dapat memberikan manfaat bagi suatu perusahaan dan banyaknya penelitian menggunakan algoritma FP-Growth juga memberikan manfaat berupa keauratan hasil, keefisienan, dan keefektifan. Berikut penelitian terdahulu yang menurut penulis mempunyai keterkaitan dengan penelitian yang akan dilakukan.

Pertama, penelitian yang dilakukan untuk meningkatkan target penjualan dengan strategi paket *bundling* menggunakan algoritma FP-Growth pada data transaksi penjualan dari tanggal 1 Desember sampai tanggal 31 Desember 2020 dengan jumlah data sebanyak 14.846. Penelitian ini menggunakan rapid miner dengan *minimum support* 0,1 dan *confidence* 0,5. Model yang dibangun menghasilkan nilai *lift ratio* terendah 3,304 dan tertinggi 9,686 dengan 12 asosiasi terbentuk. Berdasarkan penelitian tersebut dapat disimpulkan bahwa metode FP-Growth dapat digunakan untuk menganalisa keterhubungan antar produk atau penentuan paket *bundling* sebagai strategi meningkatkan penjualan [13].

Kedua, penelitian yang dilakukan untuk mengatasi penurunan penjualan dan daya tarik konsumen terhadap perubahan tren dan dampak wabah pandemik Covid-19. PT. MSD sebagai objek penelitiannya yang merupakan salah satu distributor alat-alat dapur dan produk *fashion multi brand* dengan data penjualan periode 2019-2020 menghasilkan kluster yang konsisten berhenti pada iterasi ke-4 dengan hasil kluster yang terbentuk sebanyak 58

item pada C1 yang terbukti menghasilkan asosiasi dengan nilai *support* tertinggi 12,76%, nilai *confidence* 97,80% dan nilai *lift ratio* 1,59. Berdasarkan pemahaman lebih dalam penelitian ini sudah baik dalam menentukan asosiasi kombinasi dari itemset namun langkah pada metode *K-Means* dan Apriori yang masih kurang efektif sehingga memerlukan waktu lebih ketika data lebih banyak lagi [14].

Ketiga, penelitian yang dilakukan untuk membuat strategi baru paket *bundling* dan untuk memantau persediaan barang menggunakan algoritma Apriori dan juga FP-Growth. Dikarenakan pada sebuah minimarket di daerah Tangerang belum memanfaatkan data transaksi penjualan sehingga tidak meningkatkan target penjualan dan banyaknya produk tidak terjual atau kekurangan stok persediaan. Data yang digunakan pada penelitian ini merupakan transaksi dari minimarket tersebut pada Bulan Juli tahun 2018. Dimana hasil penelitiannya mendapatkan 152 *rules* dengan 24 *rules* yang memenuhi nilai *support* 60%, 108 *rules* yang memenuhi nilai *confidence* 90% dan nilai *support* tertinggi sebesar 94% yang menunjukkan perlunya peningkatan pada produk tersebut. Berdasarkan penelitian diatas menunjukkan bahwa algoritma Apriori dan FP-Growth dapat membantu pihak manajemen untuk peletakan barang, paket *bundling* dan persediaan stok [15].

Keempat, penelitian yang dilakukan untuk melihat apakah *price bundling* dan *product bundling* yang dimoderasi oleh barang komplementer memiliki pengaruh yang signifikan. Penelitian dilakukan dengan data pelatihan dan pengujian pada 168 responden yang biasa berbelanja di Alfamart melalui kuisioner rentang lima poin skala *likert*. Hasil penelitian menunjukkan *price bundling* dan *product bundling* memiliki pengaruh yang signifikan namun barang komplementer tidak menunjukkan pengaruh terhadap niat beli konsumen [6]. Berdasarkan penelitian ini, maka dapat disimpulkan bahwa paket *bundling* dan promo dapat mempengaruhi keputusan pembelian.

Kelima, penelitian yang untuk membuat strategi pemasaran dengan penerapan paket *bundling* secara tepat menggunakan AR-MBA dikarenakan persaingan bisnis yang memicu target penjualan tidak tercapai. Hasil

penelitian dibantu dengan *software RapidMiner* dan menghasilkan bahwa departemen 5 dan departemen 2 merupakan departemen yang produknya sering dibeli dari total 5 departemen. Hasil ini ditunjukkan dengan *lift ratio* 1,029, *confidence* 0,852 dan *support* 0,397 [16].

Keenam, penelitian yang dilakukan untuk mendeskripsikan makna dan motif-motif pemanfaatan elektronik tiket dan juga tanggapan layanan yang diberikan CV.Guti Mulia wisata. Hasil penelitian menunjukkan kemudahan dalam pembelian tiket dan ketepatan penyampain informasi setelah penggunaan data mining. Berdasarkan penelitian ini menunjukkan data mining sangat berguna untuk mengetahui hubungan pola frekuensi penjualan tiket [17].

Ketujuh, penelitian yang bertujuan menganalisis informasi transaksi penjualan barang untuk menghasilkan *association rules* dari pola kombinasi itemsets yang sesuai agar membantu pemilik dalam melakukan peletakan dan persediaan barang. Penelitian ini menggunakan data transaksi penjualan barang pakaian dengan nilai *minimum support* 0,2% dan *confidence* 0,8%. Dan dihasilkan 7 aturan asosiasi dengan nilai *support* tertinggi 10% dan nilai *confidence* 88% [18].

Dengan merujuk penelitian – penelitian sebelumnya tersebut, penelitian ini bertujuan melengkapi dan mengeksplorasi aspek baru dalam penentuan paket *bundling* dan promo. Hasil – hasil penelitian sebelumnya tetap menjadi titik tolak yang penting untuk penelitian ini. Penelitian ini menggunakan big data dengan menggunakan pendekatan berbeda dimana penelitian sebelumnya umumnya menggunakan *software* RapidMiner. Penentuan paket *bundling* dan promo pada penelitian ini menggunakan pendekatan pemrograman phyton. Penelitian ini penting sebagai penelitian lanjutan karena tidak hanya memperluas cakupan pengetahuan yang ada, tetapi juga menyediakan wawasan baru yang dapat memperkaya pemahaman kita tentang strategi paket *bundling* dan promo dalam konteks yang berkembang pesat seperti retail *online/e-commerce*.

Tabel 2.1 Penelitian Terdahulu

<i>Referensi</i>	<i>Objective</i>	<i>Contribution</i>	<i>Data</i>	<i>Methodology</i>	<i>Result/Conclusion</i>
[13]	Analisis Keterhubungan antar Produk	<i>Rapidminer</i> sebagai <i>software</i> penguji.	Data transaksi PT Catur Mitra Sejati Sentosa pada 1-31 Desember 2020	Menggunakan FP-Growth dengan minimum <i>support</i> 0,1 dan nilai <i>confidence</i> 0,5	Dari hasil uji <i>Rapidminer</i> didapatkan 12 <i>rules</i> keterhubungan produk dengan <i>lift ratio</i> tertinggi 9,686 dan nilai <i>confidence</i> tertinggi 0,672
[14]	Strategi Produk <i>Bundling</i>	<i>CRISP-DM</i> untuk analisa dan mengolah data, <i>Rapidminer</i> , <i>SPSS</i> , dan <i>Anova</i>	Data sekunder dari PT. MSD periode Januari – Maret 2020	<i>K-Means</i> dan Apriori	Metode <i>K-Means</i> menghasilkan klaster yang konsisten berhenti pada iterasi 4. <i>K-Means</i> dan Apriori mendapat nilai 83,58 yang berarti baik untuk pemilihan produk <i>bundling</i> .

<i>Referensi</i>	<i>Objective</i>	<i>Contribution</i>	<i>Data</i>	<i>Methodology</i>	<i>Result/Conclusion</i>
[15]	Peletakan Barang dan Pemantaun Stok	<i>Rapidminer</i> sebagai <i>software</i> penguji.	Data Transaksi Minimarket Daerah Tanggerang pada Juli 2018	Apriori dan FP-Growth, dengan <i>minimum suport</i> 60% dan nilai <i>confident</i> 90%	Dari sampel diperoleh 152 <i>rules</i> , dengan 24 <i>rules</i> yang memenuhi ambang batas <i>support</i> dan 108 <i>rules</i> yang memenuhi ambang batas <i>confidence</i> .
[6]	Pengaruh <i>Price Bundling</i> , Produk <i>Bundling</i> dimoderasi Barang Komplement er terhadap niat membeli.	<i>SmartPLS3</i> untuk mengkonfirma si hasil penemuan. Moderasi Barang Komplenter.	Data transaksi <i>alfamart</i> pada hari jumat, sabtu, minggu yang membeli paket <i>bundling</i> (168 sampel)	Kuisoner tertutup dan <i>purposive sampling</i> .	<i>Price Bundling</i> dan <i>Product Bundling</i> mempengaruhi niat membeli, namun barang komplement er tidak terlihat memilki pengaruh moderasi.
[16]	Penentuan	<i>Rapidminer</i>	Wawancara	FP-Growth dengan nilai	Model dapat membuat 6 <i>rules</i> namun

<i>Referensi</i>	<i>Objective</i>	<i>Contribution</i>	<i>Data</i>	<i>Methodology</i>	<i>Result/Conclusion</i>
	Strategi Produk <i>Bundling</i>	sebagai <i>software</i> penguji.	langsung dengan pemilik Ritel Z, dan survei langsung ke tempat (58 data transaksi)	<i>minimum support</i> 0,3 dan nilai <i>confidence</i> 0,6	hanya 1 <i>rules</i> yang memenuhi nilai <i>minimum support</i> dan <i>confident</i> .
[17]	Manfaat Data Mining tepatnya untuk mengamati stok	Tanagra	Data Transaksi CV Gutu Mulia Wisata pada Oktober 2018 – Januari 2019	Apriori	Data mining membantu membaca pola frekuensi penjualan tiket.
[18]	Pengendalian Persediaan Barang dan Peletakan	<i>Ms. Excel</i> dan <i>Rapidminer</i>	Data persediaan barang di Bengkulu pada	Apriori, dengan nilai <i>minimum support</i> 0,2 dan nilai <i>confidence</i> 0,8	Metode menghasilkan 7 <i>rules</i> dengan nilai <i>suport</i> tertinggi 10% dan nilai <i>confidence</i> 88%.

<i>Referensi</i>	<i>Objective</i>	<i>Contribution</i>	<i>Data</i>	<i>Methodology</i>	<i>Result/Conclusion</i>
	Barang		Januari – Maret 2020		

2.2 Landasan Teori

2.2.1 Paket *Bundling*

Paket *Bundling* merupakan bentuk pemasaran di mana dua atau lebih produk atau layanan digabungkan menjadi satu, satu paket untuk satu harga [19]. Pada Gambar 2.1 merupakan contoh paket *bundling* yang terdapat pada retail *online* Shopee dengan paket berisi beberapa produk yang digabung menjadi 1. Menurut Streamersch dan Tellis mengatakan paket *bundling* sebagai intergrasi dan penjualan dua produk atau lebih pada harga tertentu. Integrasi ini memberikan nilai tambah kepada pelanggan karena meningkatkan harga reservasi yang *bundle* dibandingkan harga yang dijual terpisah [20]. Strategi paket *bundling* ini juga bisa meningkatkan suatu merek yang juga mengubah persepsi orang terhadap merek tersebut, seperti satu merek melengkapi merek lain dimana merek itu sudah memiliki ketenaran [21].



Gambar 2.1 Contoh Paket Bundling

Indikator Paket *Bundling* :

- a. Ketepatan : Ketepatan baik secara pengelompokan produk, tujuan *bundling*nya ataupun ketepatan waktu promosi paket *bundling*nya.
- b. Harga : Harga produk terpisah dengan *bundling* harus memiliki perbedaan untuk menarik minat beli. Yang pada umumnya

keunggulan paket *bundling* adalah harga produk yang menjadi lebih murah.

- c. Kemerarikan : Pemilihan produk yang beragam menjadi kemerarikan tersendiri yang membantu meningkatkan dorongan konsumen untuk membelinya.
- d. Cara penggabungan produk : Penggabungan produk utama dan pendukung secara seimbang dan sesuai kebutuhan konsumen haruslah maksimal [20].

2.2.2 Harga

Harga menjadi faktor penentu dalam pembelian dikebanyakan orang dan harga juga menjadi unsur penting dalam penentuan bagian pasar dan tingkat keuntungan. Harga merupakan unsur bauran yang fleksibel atau bisa diubah dengan cepat.

Proses penetapan harga :

- a. Menentukan tujuan penetapan harga.
- b. Memperkiraan tingkat permintaan barang.
- c. Antisipasi reaksi dalam persaingan.
- d. Penentuan pangsa pasar.
- e. Pemilihan strategi harga untuk mencapai pemasaran perusahaan.
- f. Pertimbangan kebijakan pemasaran.
- g. Metode perhitungan harga [22].

2.2.3 Promo

Promo atau diskon merupakan potongan harga dari penjual kepada pembeli atas penghargaan aktivitas jual beli yang menyenangkan penjual.

Terdapat empat bentuk diskon :

- a. Diskon Kuantitas : Potongan harga yang mendorong pembeli untuk melakukan pembelian dengan jumlah atau volume yang lebih banyak.

- b. Diskon Musiman : Potongan harga yang diberikan di masa masa tertentu seperti Shopee 12.12, Promo Gajian, Promo Akhir Tahun, dan lainnya.
- c. Diskon Langsung : Potongan dari penjual karena sebab tertentu, seperti adanya kecacatan produk atau gangguan jasa.
- d. Diskon Penjual : Potongan harga yang hanya diberikan kepada para penyalur atau distributor produk [23].

2.2.4 Behavior Costumer

Behavior Costumer merupakan perilaku konsumen baik individu atau kelompok dalam menyeleksi, membeli, menggunakan, atau menghentikan pemakaian produk, jasa, ataupun ide. Pemahaman *costumer behavior* memiliki manfaat penting dalam strategi penjualan seperti membantu menejer pemasaran dalam pengambilan keputusan, dan lainnya [24].

2.2.5 Preprocessing

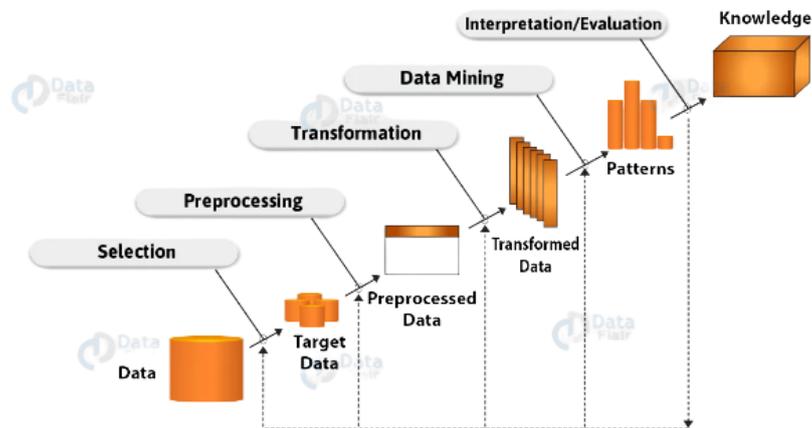
Data atau database sekarang ini kebanyakan merupakan data kotor, seperti terdapat *missing value* atau hilang data, *noise*, dan lainnya. Data kotor ini akan mempengaruhi hasil penelitian. Saat menggunakan data dalam jumlah yang besar pasti akan memakan waktu yang lama sehingga ini sangat tidak praktis dan efisien. *Missing value* atau hilang data sangat tidak diinginkan oleh peneliti. Ada beberapa cara untuk menangani *missing value* seperti *Listwise deletion*, *Pairwise deletion* dan Imputasi. *Listwise deletion* yaitu menangani *missing value* dengan cara menghapus kasus/objek yang mengandung *missing value*. Pendekatan ini membuang semua data yang hilang sehingga data yang dianalisis hanya data yang lengkap. Ini memudahkan perhitungan statistika karena data lengkap, namun ini dapat mengurangi keakuratan karena data sampel yang berkurang. Selain itu dapat menyebabkan bias dalam hasil jika *missing value* data tidak acak.

Pairwise deletion yaitu menangani *missing value* dengan cara menghapus *missing value*nya, sehingga yang dianalisis hanya *value* yang tersedia. Cara ini memaksimalkan data yang tersedia tanpa mengurangi ukuran sampel, sehingga akan lebih banyak informasi yang dapat diambil dari data. Namun, jika *missing value* terjadi secara sistematis atau tidak acak maka akan menghasilkan bias.

Imputasi yaitu menangani *missing value* dengan cara mengisi *missing value* dengan nilai atau dari informasi yang tersedia dari data. Dengan cara ini kita dapat menghindari penghapusan data/ kasus *missing value* secara keseluruhan. Beberapa teknik imputasi yang sering digunakan, seperti imputasi berbasis statistik, imputasi menggunakan nilai tengah atau rerata, imputasi berbasis model, dan imputasi menggunakan teknik seperti K-Nearest Neighbors (KNN) atau regresi. Dengan menggunakan salah satu atau kombinasi dari teknik-teknik ini, imputasi dapat membantu mempertahankan integritas dan kompleksitas data serta mencegah kehilangan informasi yang berharga [25].

2.2.6 Data Mining

Data Mining merupakan proses penemuan pola atau proses ekstraksi data dan explorasi dari analisis data yang tersimpan dalam jumlah besar. Sejarah data mining bermula dari statistika dan kecerdasan buatan di tahun 1960-an dan dapat dilihat kembali ke akhir tahun 1980-an pada saat istilah tersebut mulai digunakan, paling tidak dalam kalangan komunitas, yang kemudian berkembang dengan pesat karena meningkatnya volume data dan kemampuan komputasi, serta kebutuhan bisnis untuk menganalisis data dalam jumlah besar [26]. Data mining memiliki beberapa sebutan seperti *Knowledge Discovery in Databases (KDD)*, ekstraksi pengetahuan (*knowledge extraction*), analisa data dan pola, dan lainnya.



Gambar 2.2 Diagram Alir Data Mining

Faktor pendukung perlunya data mining :

1. Jumlah data sangat besar.
2. Telah dilakukan proses data *warehaousing*(pengumpulan, pengolahan, pengintegrasian, dan penyimpanan data dari berbagai sumber yang berbeda).
3. Kemampuan komputasi yang terjangkau.
4. Ketatnya persaingan bisnis.

Data mining dikelompokkan dalam beberapa metode menurut tugasnya [27] :

1. Estimasi, berfokus untuk memprediksi nilai numerik variabel target berdasarkan data yang tersedia.
Algoritma : *Linear Regression, Neural Network, Support Vector Machine*, dan lainnya.
2. Prediksi, berfokus memprediksi nilai variable target di masa mendatang berdasarkan data *history*.
Algoritma : *Linear Regression, Neural Network, Support Vector Machine*, dan lainnya.
3. Klasifikasi, berfokus mengelompokkan data ke kategori tertentu berdasarkan atribut tertentu untuk memprediksi kategori data baru.

Algoritma : *Naïve Bayes*, *K-Nearest Neighbor*, *C4.5*, *ID3*, *CART*, *Logistic Regression*, dan lainnya.

4. Pengklusteran, berfokus mengelompokkan data menjadi cluster-cluster berdasarkan kesamaan fitur tanpa adanya kategori sebelumnya.

Algoritma : *K-Means*, *K-Medoids*, *Fuzzy C-Means*, dan lainnya.

5. Asosiasi, berfokus menemukan pola hubungan antar item dalam data.

Algoritma : *Apriori*, *FP-Growth*, *Chi Square*, *Eclat*, dan lainnya [28].

2.2.7 Asosiasi

Asosiasi merupakan salah satu metode data mining yang berfokus pada penemuan pola hubungan antar item dalam data. Asosiasi digunakan untuk membuat aturan asosiatif yang memenuhi nilai *minimum support* dan *confidence* pada sebuah data. Algoritma asosiasi awal seperti *Apriori* diperkenalkan oleh Rakesh Agrawal dan Ramakrishnan Srikant pada tahun 1994 [29]. Kemudian *FP-Growth*, yang diperkenalkan oleh Han et al. pada tahun 2000, membawa inovasi signifikan dengan menggunakan struktur data *FP-Tree* untuk menghindari pemindaian berulang pada database, sehingga lebih efisien dalam hal waktu dan memori [30]. Asosiasi sendiri memiliki dua langkah penyelesaian, yaitu mencari *frequent itemset* dan mendefinisikan *conditional* dan *result*.

- a. *Support*, merupakan seberapa sering item tertentu muncul dalam dataset atau ukuran yang menunjukkan dominasi suatu item layak untuk dicari *confidence*-nya. Nilai *minimum support* dapat ditentukan dalam rentang 0 hingga 1. Perhitungan *support* item menggunakan rumus persamaan (1) dan persamaan (2).

$$Support(A) = \frac{\sum Transaksi Mengandung A}{\sum Semua Transaksi} \quad (1)$$

$$Support A \cap B = \frac{\sum Transaksi Mengandung A dan B}{\sum Semua Transaksi} \quad (2)$$

- b. *Confidence*, merupakan seberapa sering aturan asosiasi tertentu ditemui dalam data atau suatu ukuran yang menunjukkan seberapa sering item B muncul dalam transaksi yang juga mengandung item A. Nilai *confidence* dapat ditentukan dalam rentang 0 hingga 1, dengan pertimbangan nilai *confidence* semakin mendekati 1 menunjukkan pengaruh kuat *antecedent* terhadap *consequent*. Perhitungan *confidence* menggunakan rumus persamaan (3).

$$Confidence(A \rightarrow B) = \frac{\sum Transaksi Mengandung A dan B}{\sum Transaksi Mengandung A} \quad (3)$$

- c. *Lift Ratio*, merupakan seberapa banyak kemunculan item B dipengarungi oleh kemunculan item A. Jika nilai *lift ratio* lebih dari 1 menunjukkan item A dan item B memenuhi keterkaitan yang lebih besar. Perhitungan *lift ratio* menggunakan rumus persamaan (4).

$$Lift Ratio (A \rightarrow B) = \frac{Confidence (A \rightarrow B)}{Support(B)} \quad (4) \quad [5].$$

Langkah – Langkah Proses Asosiasi :

1. Pindai data, sistem akan memindai data untuk mendapatkan kandidat 1-itemset. Sistem akan memindai dan membaca data secara keseluruhan dan mencatat setiap item yang ada di dalamnya. Setiap item ini akan menjadi kandidat 1-itemset. Jadi, jika ada n transaksi maka kita mendapatkan kumpulan i-itemset, masing – masing item dalam himpunan terpisah.
2. Hitung nilai *support*, setelah mendapat kandidat 1-itemset, sistem akan menghitung nilai *support* dan dibandingkan dengan nilai *minimum support* yang telah ditentukan. Nilai *minimum*

support adalah nilai ambang batas dari *support*/seberapa sering item muncul dalam data. Jika nilai *support* kandidat 1-itemset lebih kecil dari nilai *minimum support*, maka item akan dieleminasi dan tidak diikuti pada iterasi selanjutnya. Jika nilai *support* item lebih besar dari nilai *minimum support*, maka item akan dianggap sebagai *large itemset*. Kemudian iterasi akan dilanjutkan sampai dengan item terakhir dengan sistem akan menggabungkan setiap iterasi dan menghapus item yang tidak termasuk *large itemset*.

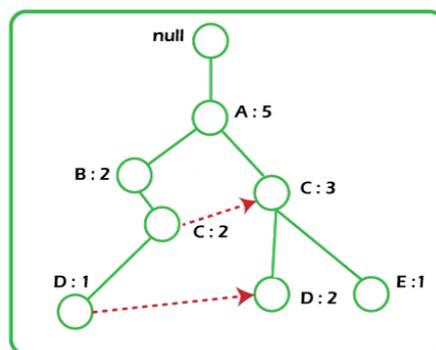
3. Setelah penggabungan maka pasangan item baru dari hasil penggabungan itu akan dihitung nilai *support*nya.
4. Setelah itu, dari hasil *frequent itemset* akan dibentuk *rules* yang sesuai dengan nilai *support* dan *confidence* yang telah ditentukan [31].

2.2.8 FP-Growth

FP-Growth merupakan salah satu algoritma data mining dari metode asosiasi. FP-Growth juga merupakan pengembangan dari algoritma Apriori, sehingga kekurangan pada algoritma Apriori diperbaiki pada algoritma FP-Growth ini. Perbaikan ini berupa keunggulan dari FP-Growth itu sendiri, penggunaan *FP-Tree* pada FP-Growth membantu pencarian *frequent itemset* dengan cepat karena penjelajahan data seperti *tree* atau pohon dari akar atau bawah menuju atas atau bisa dikatakan tidak menggunakan *generate candidate* seperti Apriori [32]. Keunggulan FP-Growth dibandingkan dengan model lainnya :

1. FP-Growth lebih efisien secara komputasi daripada metode Apriori dan Eclat karena FP-Growth membangun struktur data *FP-Tree*.

2. FP-Growth lebih baik dalam mengatasi masalah *sparsity*, yaitu ketika terdapat banyak item yang jarang muncul dalam transaksi.
3. FP-Growth cenderung lebih skalabel daripada Apriori dalam menangani dataset yang besar.
4. FP-Growth mampu menemukan pola asosiasi yang lebih kompleks daripada metode Apriori [5].



Gambar 2.3 Contoh FP-Tree

FP-Growth berfokus pada pencarian *frequent itemset* yaitu kumpulan item yang muncul secara bersamaan.

Langkah – Langkah Penyelesaian :

1. Pembentukan *FP-Tree*, dimana dataset dihitung frekuensi setiap item dari keseluruhan transaksi yang kemudian dipilah sesuai batas nilai *minimum support*.
 - a. Pemindaian dataset. Yaitu langkah menghitung frekuensi kemunculan item pada dataset. Frekuensi kemunculan ini disebut dengan *support*.

Tabel 2. 2 Tabel Perhitungan Support Item

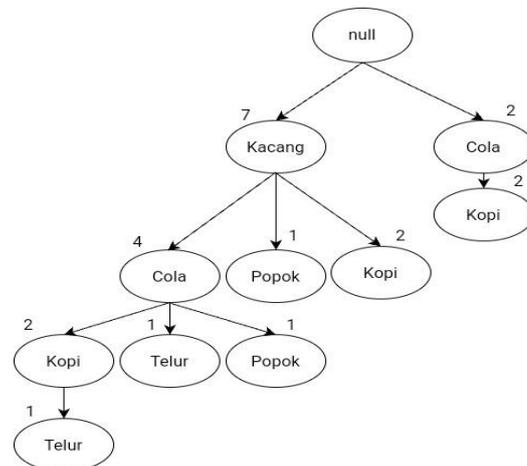
Item	Support	Urutan Suppor Tertinggi ke-
Cola	6	2
Kacang	7	1
Telur	2	4
Popok	2	5
Kopi	6	3

- b. Melakukan eliminasi item berdasarkan nilai *minimum support*. Contoh nilai minimum support adalah 2, maka *support* yang mendapatkan nilai lebih kecil dari 2 akan dieleminasi.

Tabel 2. 3 Tabel Eliminasi Item

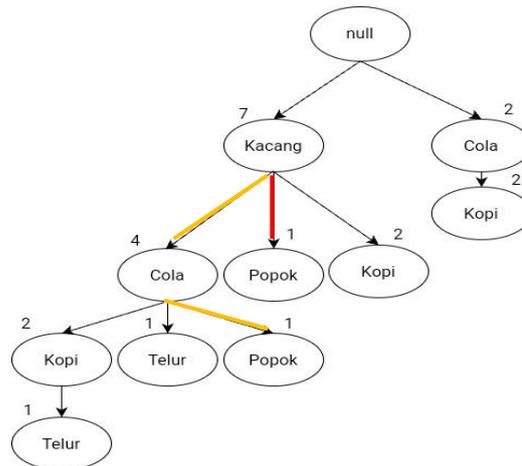
Item	Support	Eliminasi
Kacang	7	X
Cola	6	X
Kopi	6	X
Telur	2	X
Popok	2	X

- c. Pemindaian data, dimana transaksi unik akan membentuk jalur baru dengan hitungan mulai 1. Jika transaksi sudah ada maka jalur akan ditumpuk dan hitungan ditingkatkan sebesar 1.



Gambar 2.4 Jalur FP-Tree

2. Pembangkitan *Conditional Pattern Base*. Merupakan langkah yang digunakan untuk pembangkitan *conditional FP-Tree*. Dimana langkah ini akan menemukan jalur yang mengarah ke item target yang kita tentukan. Untuk setiap jalur yang ditemukan maka item target akan dihapus dan dihitung frekuensi jalur yang tersisa. Kemudian simpan jalur jalur tersebut dan frekuensinya akan digunakan sebagai *Conditional Pattern Base*.



Gambar 2.5 Conditional Pattern Base

Popok = {Kacang, Cola : 1 (jalur kuning)} {Kacang(jalur merah)}

Telur = {Kacang, Cola, Kopi : 1} {Kacang, Cola : 1}

Kopi = {Kacang, Cola : 2} {Kacang : 2} {Cola : 2}

Cola = {Kacang : 4}

3. Pembangkitan *Conditional FP-Tree*. Langkah ini adalah langkah yang akan digunakan untuk pencarian frequent itemset. Dimana jalur yang disimpan atau *conditional pattern basenya* diurutkan dari frekuensi terbesar ke terkecil. Frekuensi jalur yang dibawah nilai minimum support yaitu 2 maka akan dihapus, sedangkan yang sesuai akan dibuatkan *FP-Tree*.

Popok = {Kacang : 2}

Telur = {Kacang : 2} {Cola : 2}

Kopi = {Kacang : 4, Cola : 2} {Cola : 2}

Cola = {Kacang : 4}

4. Pencarian *Frequent Itemset*. Jika *FP-Tree* merupakan jalur tunggal, maka didapatkan *frequent itemsetnya*. Namun jika jalur tidak tunggal maka akan dilakukannya pembangkitan *FP-Tree* secara rekursif (memanggil dirinya sendiri). Dimana berarti dapat dilakukan pencarian *rules* atau aturan [33].

Popok = Kacang, Popok : 2

Telur = Kacang, Telur : 2, Cola Telur : 2, Kacang, Cola, Telur : 2

Kopi = Kacang, Kopi : 4, Cola, Kopi : 4, Kacang, Cola, Kopi : 2

Cola = Kacang, Cola : 4

2.2.9 *Dinamic Pricing*

Dynamic pricing merupakan salah satu cara penentuan harga. Penentuan harga menggunakan *dynamic pricing* akan memungkinkan mendapatkan harga yang dinamis, fleksibel, dan *real time*. *Dynamic pricing* mengoptimalkan data *history* transaksi yang tersedia, seperti jumlah permintaan, jumlah persediaan, harga, harga atas, dan variabel lainnya untuk dijadikan pembelajaran penentuan harga. Macam cara penentuan harga menggunakan *dynamic pricing* secara teori ada 3 jenis penerapan yaitu *Peak Pricing* yaitu penerapan berdasarkan lonjakan permintaan produk atau layanan, *Segemented Pricing* yaitu menetapkan dua harga atau lebih yang berbeda untuk satu produk, dan *Time Pricing* yaitu penetapan berdasarkan basis waktu saat terjadi kenaikan atau penurunan penjualan [34].

Langkah – Langkah melakukan *dynamic pricing* :

1. Data *Gethring*, atau pengumpulan data seperti data transaksi.
2. *Feature Engineering*, yaitu pemilihan ataupun pembuatan fitur baru berdasarkan fitur yang tersedia di data.
3. *Machine Learning*, algoritma *machine learning* akan membantu memprediksi harga optimal. Algoritma pada metode prediksi bisa menggunakan *Regresi Linear*, *Random Forest*, *Neural Network*, dan lainnya. *Machine learning* akan mempelajari data yang tersedia dan akan diujikan untuk penentuan harga [35].