

ANALISIS POLA PEMBELIAN PRODUK MAKANAN MENGGUNAKAN ALGORITMA FP-GROWTH UNTUK STRATEGI PENJUALAN

Fachrul Prasetyo¹, Humisar Hasugian^{2*}

^{1,2*}Sistem Informasi, Fakultas Teknologi Informasi, Universitas Budi Luhur, Jakarta, Indonesia

Email: ¹fachrulprasetyo98@gmail.com, ^{2*}humisar.hasugian@budiluhur.ac.id

(* : *coressponding author*)

Abstrak- PT Kusno Baso sebuah perusahaan yang bergerak dibidang kuliner yang menjual produk olahan bakso dan otak-otak. Dalam dua tahun terakhir ini yang berfokus pada penjualan tunai pabrik ada sebagian produk mengalami penurunan penjualan. Produksi olahan yang banyak serta jumlah data penjualan yang besar menjadi kendala dalam menganalisis data secara manual. Fenomena ini menyebabkan penumpukan produk setiap hari karena kurang berhasilnya penjualan beberapa *item*. Salah satu penyebabnya adalah kurangnya pengetahuan mengenai produk yang sering dibeli pelanggan dalam satu kali transaksi. *Data mining* adalah proses menemukan hubungan, pola, dan tren yang bermakna dengan memeriksa kumpulan data besar yang disimpan dalam memori menggunakan teknik pengenalan pola seperti teknik statistik dan matematika. *Frequent Pattern Growth (FP-Growth)* merupakan algoritma alternatif yang dapat digunakan untuk menentukan kumpulan data yang sering muncul. Penelitian ini menggunakan metodologi *Cross-Industry Standard Process for Data Mining (CRISP-DM)* untuk mengatasi penurunan penjualan produk. Metode pengumpulan data sekunder dilakukan pada data transaksi tunai pabrik penjualan produk olahan bakso dan otak-otak di PT Kusno Baso Ciledug dari tanggal 11 Mei 2021 sampai dengan tanggal 11 Mei 2023 yang terdiri dari 600 data transaksi dan 21 atribut yang sudah bersih tanpa ada *missing value*. Tujuan dari penelitian ini yaitu untuk mengidentifikasi masalah penjualan dan membantu mengembangkan strategi penjualan dengan menggunakan sistem *cross-selling*. Hasil penelitian ditemukan aturan asosiasi paling tinggi dengan nilai minimum *Support* sebesar 31.3%, minimum *Confidence* 70.9% dan *lift ratio* 14.53% pada aturan "Jika konsumen membeli Bakso Kecil 500g, maka konsumen juga cenderung membeli Bakso Urat 500g".

Kata Kunci: *Association Rule, Cross-Selling, Data Mining, FP-Growth, Pola Pembelian*

Abstract- *PT Kusno Baso is a culinary company that sells processed meatball and otak-otak products. In the last two years, which focused on factory cash sales, some products have decreased sales. Large processed production and large amounts of sales data are obstacles in analyzing data manually. This phenomenon leads to a buildup of products every day due to the lack of successful sales of some items. One of the reasons is the lack of knowledge about products that customers often buy in one transaction. Data mining is the process of finding meaningful relationships, patterns, and trends by examining large data sets stored in memory using pattern recognition techniques such as statistical and mathematical techniques. Frequent Pattern Growth (FP-Growth) is an alternative algorithm that can be used to determine frequently occurring data sets. This research uses Cross-Industry Standard Process for Data Mining (CRISP-DM) methodology to overcome the decline in product sales. The secondary data collection method was carried out on cash transaction data of the factory selling processed meatball products and brains at PT Kusno Baso Ciledug from May 11, 2021 to May 11, 2023 consisting of 600 transaction data and 21 attributes that were clean without any missing value. The purpose of this study is to identify sales problems and help develop sales strategies using a cross-selling system. The results of the study found 9 association rules, one of the highest with a minimum value of Support of 31.3%, minimum Confidence of 70.9% and a lift ratio of 14.53% in the rule "If consumers buy 500g Small Meatballs, then consumers also tend to buy 500g Urat Meatballs".*

Keywords: *Association Rule, Cross-Selling, Data Mining, FP-Growth, Purchasing Patterns*

1. PENDAHULUAN

PT Kusno Baso perusahaan kuliner yang mengkhususkan diri dalam produk olahan bakso dan otak-otak, mengalami penurunan penjualan produk tunai pabrik dalam dua tahun terakhir. Data penjualan dari Mei 2021 hingga Mei 2023 menunjukkan beberapa produk yang hampir tidak terjual. Kendala produksi besar dan volume data yang tinggi mendorong peneliti untuk memanfaatkan *data mining* khususnya algoritma *FP-Growth*, untuk mengidentifikasi pola asosiasi dalam data penjualan. Tujuan utama adalah meningkatkan penjualan dengan pengembangan strategi pemasaran yang lebih efektif serta mengatasi penumpukan produk yang tidak terjual melalui *cross-selling*. Dengan demikian, penelitian ini bertujuan untuk membantu PT Kusno Baso mengoptimalkan penjualannya melalui analisis data dan implementasi strategi penjualan yang lebih baik.

PT Kusno Baso memiliki tujuan yang jelas, yaitu meningkatkan penjualan produk mereka dan menghindari penumpukan stok produk melalui penggunaan strategi pemasaran yang efektif terutama dengan menerapkan teknik *cross-selling*, dimana produk tambahan ditawarkan kepada pelanggan yang telah melakukan pembelian sebelumnya. Untuk mencapai tujuan, penelitian ini menggunakan pemanfaatan *data mining* sebagai pendekatan yang potensial [1]. Pemanfaatan *data mining* merupakan pendekatan potensial untuk mengatasi masalah ini. Metode penelitian yang digunakan dalam penelitian ini adalah metode aturan asosiasi, khususnya memanfaatkan algoritma *FP-Growth*.

Data mining merupakan suatu proses yang mencakup pengumpulan dan analisis data historis untuk mengungkapkan pola, korelasi, keteraturan, dan pengetahuan yang tersembunyi dalam kumpulan data besar. Proses ini dikenal juga sebagai *Knowledge Discovery in Database* (KDD) dan memiliki *output* yang sangat berharga dalam pengambilan keputusan dan perbaikan keputusan di masa depan [2]. Salah satu metode yang digunakan dalam data mining adalah metode aturan asosiasi (*association rule*) yang bertujuan untuk mengidentifikasi hubungan antara elemen-elemen dalam data. Ada ukuran kepercayaan (*interestingness measure*) dalam menentukan sebuah hubungan, yaitu nilai minimum *confidence* serta nilai minimum *support* [3]. Langkah awal dalam mengidentifikasi pola asosiasi adalah dengan menghitung nilai *support* untuk setiap transaksi penjualan, yang dapat dilakukan melalui pemanfaatan algoritma *FP-Growth*.

Frequent Pattern Growth (*FP-Growth*) menghadirkan pendekatan alternatif untuk mengidentifikasi *frequent itemset*, sehingga menghilangkan kebutuhan akan pembuatan kandidat [4]. Penggunaan metode algoritma *FP-Growth* dalam kasus strategi penjualan memiliki beberapa kelebihan yang signifikan. Algoritma *FP-Growth* mengatasi salah satu masalah utama dalam analisis asosiasi, yaitu kebutuhan untuk menghasilkan kandidat *itemset* yang sering terjadi seperti yang dilakukan oleh algoritma Apriori. Pembuatan kandidat tidak digunakan dalam algoritma *FP-Growth*, algoritma ini membangun sebuah struktur pohon yang dikenal sebagai *FP-Tree*. *FP-Tree* ini memungkinkan pengguna untuk menemukan *frequent itemset* tanpa perlu melibatkan proses pembuatan *generate candidate* yang memakan waktu dalam algoritma Apriori [5]. Dengan demikian, *FP-Growth* lebih efisien dalam mengidentifikasi pola asosiasi dalam data yang besar, menghemat waktu dan sumber daya komputasi. Keunggulan ini sangat bermanfaat dalam strategi penjualan, dimana pengidentifikasian pola asosiasi yang cepat dan akurat dapat membantu perusahaan seperti PT Kusno Baso dalam meningkatkan penjualan dan mengoptimalkan strategi pemasaran mereka.

Penelitian berjudul "Implementasi *Data Mining* Dalam Menganalisa Pola Penjualan Roti Menggunakan Algoritma *FP-Growth*" [6], melakukan penelitian dengan membuat aplikasi berbasis desktop, aturan asosiasi yang dihasilkan sebanyak 7 aturan asosiasi, dari langkah-langkah telah dilalui sebelum menyelesaikan pola kombinasi 2 *itemset* dengan nilai minimum *support* 20% serta nilai minimum *confidence* 60%.

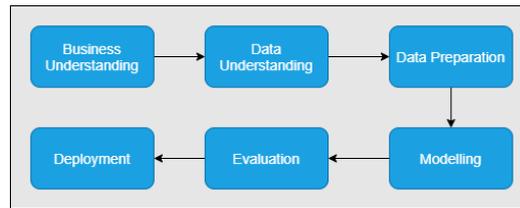
Penelitian berjudul "Penerapan *Data Mining* Dalam Menentukan Pola Penjualan Sepatu Menggunakan Algoritma *FP-Growth*" [7], penelitian dilakukan dengan memanfaatkan perangkat lunak Rapid Miner, dengan pengujian menggunakan nilai minimum *support* 0,2 (20%) dan nilai minimum *confidence* 0,5 (50%), menghasilkan 32 aturan asosiasi yang digunakan sebagai rencana pemasaran periode berikutnya. Pada penelitian yang berjudul "*Data Mining* Untuk Menganalisa Pola Penjualan Pestisida Menggunakan Algoritma *FP-Growth*" [8], melakukan riset dan membangun desain aplikasi berbasis desktop yang akan membantu UD. Dimas Tani dalam memilih distribusi pestisida dengan memahami keterkaitan antar objek memanfaatkan algoritma *FP-Growth*. Penelitian ini menggunakan ambang batas minimum *support* 15% sekaligus minimum *confidence* 50%. Hasilnya, diperoleh 7 aturan dimanfaatkan guna menghasilkan stok tambahan dan merumuskan strategi penjualan UD. Dimas Tani.

Pada penelitian yang berjudul "Implementasi *Data Mining* Pada Penjualan Pakaian dengan Algoritma *FP-Growth*" [9], melakukan penelitian dan pengembangan aplikasi Rapid Miner yang menggunakan algoritma *FP-Growth* untuk menemukan tren pembelian pelanggan. Produk yang paling banyak diminati adalah gamis dan hijab yang memiliki tingkat *support* sebesar 53,3% dan *confidence* 100%. Algoritma *FP-Growth* dapat membantu dalam pembuatan strategi pemasaran dengan memberi tahu penjual tentang produk apa yang harus diperisapkan dan dengan memberikan saran kepada pelanggan tentang produk apa yang harus dibeli.

Penelitian ini memanfaatkan algoritma *FP-Growth* dalam analisis pola penjualan PT Kusno Baso, dengan fokus pada produk makanan olahan bakso dan otak-otak. Perbandingan dengan penelitian sebelumnya yang menggunakan produk berbeda seperti sepatu dan pestisida, penelitian ini menekankan efisiensi dengan menghindari langkah pembuatan *generate candidate* dalam algoritma *FP-Growth*. Selain itu, penelitian ini memungkinkan penyesuaian ambang batas minimum *support* dan *confidence* sesuai dengan kebutuhan bisnis perusahaan. Harapannya, hasil penelitian akan memberikan aturan asosiasi yang dapat digunakan untuk mengembangkan strategi pemasaran yang lebih efektif, meningkatkan penjualan produk, mengurangi penumpukan stok yang tidak terjual, dan meningkatkan kepuasan pelanggan PT Kusno Baso. Dengan demikian, penelitian ini bertujuan untuk mengatasi tantangan penjualan dan penumpukan produk melalui analisis data menggunakan metode *FP-Growth*.

2. METODE PENELITIAN

Penelitian ini menggunakan metodologi CRISP-DM untuk melaksanakan tahapan penelitian, memastikan pendekatan yang sistematis, jelas, dan efektif dalam melakukan penelitian. *Cross Industry Standard Process for Data Mining* (CRISP-DM) ialah kerangka kerja untuk mengubah tantangan bisnis menjadi tugas penambangan data dan melakukan proyek penambangan data secara *independent*, terlepas dari domain aplikasi spesifik atau alat teknologi yang digunakan. Metodologi CRISP-DM banyak digunakan dalam pengaturan industri untuk tujuan implementasi proses [10]. Pendekatan ini disusun menjadi 6 tahap, seperti terlihat pada Gambar 1.



Gambar 1. Tahapan CRISP-DM

2.1 Pemahaman Data (*Data Understanding*)

Tahap Pemahaman Data (*Data Understanding*), dilakukan pengumpulan data sekunder yang mencakup transaksi penjualan pabrik selama dua tahun terakhir di PT Kusno Baso Ciledug, mulai dari 11 Mei 2021 hingga 11 Mei 2023. Data ini menjadi dasar untuk analisis lebih lanjut.

2.2 Persiapan Data (*Data Preparation*)

Setelah data terkumpul, dilanjutkan dengan Persiapan Data (*Data Preparation*), yang melibatkan serangkaian prosedur untuk memproses data awal tersebut. Ini mencakup pembersihan data, reduksi data, transformasi data, serta pemilihan tabel, *record*, dan atribut yang relevan untuk digunakan dalam pemodelan data lebih lanjut. Tahapan ini penting untuk memastikan data yang digunakan dalam analisis memiliki kualitas yang baik sebelum masuk ke tahap pemodelan.

2.3 Pemodelan (*Modelling*)

Pada tahap pemodelan, peneliti menggunakan teknik *association rule* dengan melakukan percobaan di perangkat lunak Rapid Miner setelah melakukan *preprocessing* terhadap *dataset*. Peneliti menyesuaikan parameter minimum *Support* dan minimum *Confidence* pada setiap percobaan untuk menemukan aturan asosiasi yang relevan. Aturan asosiasi memiliki bentuk "*if...then...*" atau "*jika...maka...*" dan dapat memberikan pengetahuan berharga dari data [11]. Tingginya nilai *Confidence* dan *Support* digunakan sebagai indikator kepercayaan dan dominasi dalam konteks transaksi yang lebih luas. *Support* adalah metrik kuantitatif yang mencerminkan tingkat dominasi suatu *item* atau kumpulan *item* dalam konteks transaksi, sementara *Confidence* adalah metrik kepercayaan yang menggambarkan keterkaitan bersyarat antara dua *item*, bergantung pada kondisi yang ada [12]. Persamaan (1) dapat digunakan guna mencari nilai *support* dari satu *itemset*.

$$Support\ A = \frac{\sum\ \text{Transaksi yang mengandung A}}{\sum\ \text{Transaksi}} \quad (1)$$

Persamaan (1) digunakan dalam analisis data mining, khususnya dalam mencari aturan asosiasi seperti Apriori atau *FP-Growth*. Fungsi persamaan ini adalah mengukur nilai *support itemset* A dalam dataset, menunjukkan seberapa sering *itemset* A muncul dalam transaksi dibandingkan dengan total transaksi dalam dataset. Nilai *support* ini membantu mengidentifikasi *itemset* yang relevan. Sedangkan perhitungan nilai *support 2 itemset* didapatkan dengan persamaan (2).

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

Persamaan (2) juga digunakan dalam analisis *data mining*, menghitung nilai *support* gabungan dua *itemset* A dan B dalam *dataset*. Nilai *support* ($A \cap B$) mengukur seberapa sering keduanya muncul bersamaan. Perhitungan nilai *confidence* dapat diperoleh dengan persamaan (3).

$$Confidence\ P(A|B) = \frac{\sum\ \text{Transaksi mengandung A dan B}}{\sum\ \text{Transaksi mengandung A}} \quad (3)$$

Persamaan (3) mengukur nilai *confidence* dari aturan asosiasi antara dua *itemset* A dan B dalam *dataset*. Nilai *confidence* mengindikasikan peluang *itemset* A terjadi ketika *itemset* B ada, menggambarkan kekuatan hubungan antara keduanya. Dengan persamaan ini, dapat memahami sejauh mana *itemset* A dapat diprediksi ketika *itemset* B

sudah terjadi. Dalam tahap pemodelan, penelitian ini menerapkan algoritma *FP-Growth* yang terdiri dari tiga langkah utama [13] yaitu:

- Tahap pembangkitan *conditional pattern base* yang melibatkan pencarian jalur lintasan *prefix* dan pola akhiran (*suffix*) dalam *subdatabase* yang disebut *conditional pattern base* dengan *FP-Tree* sebagai dasar.
- Tahap pembangkitan *conditional FP-Tree* di mana *support count* untuk setiap *item* dalam *conditional pattern base* dijumlahkan, dan *item* dengan *support count* tinggi akan digunakan untuk membangun *conditional FP-Tree*.
- Tahap pencarian *frequent itemset* di mana *frequent itemset* dibentuk dengan menggabungkan *item* dalam *conditional FP-Tree*.

Selama tahap pemodelan, peneliti melakukan pengujian algoritma *FP-Growth* secara manual dengan sampel *dataset* transaksi penjualan menggunakan beberapa tabel dan menggunakan perangkat lunak Rapid Miner sebagai alat bantu untuk pemodelan data asli.

2.4 Evaluasi (*Evaluation*)

Pada tahap evaluasi, validitas aturan asosiasi diuji untuk menentukan apakah produk A dan B benar-benar dibeli bersamaan. Aturan dianggap valid jika menghasilkan nilai *lift ratio* > 1 , yang menunjukkan potensi rekomendasi produk [14]. Evaluasi juga memastikan bahwa model yang dihasilkan oleh algoritma *FP-Growth* sesuai dengan tujuan bisnis yang telah ditentukan sebelumnya. Perhitungan *lift ratio* dapat diperoleh dengan persamaan (4).

$$\textit{lift ratio} = \frac{\textit{Confidence (A,B)}}{\textit{Benchmark Confidence (A,B)}} \quad (4)$$

Perhitungan *lift ratio* persamaan (4) digunakan untuk mengukur hubungan antara dua *itemset* A dan B dalam konteks asosiasi. Perhitungan nilai *benchmark confidence* diperoleh dengan persamaan (5).

$$\textit{Benchmark Confidence (A,B)} = \frac{\textit{Jumlah transaksi yang mengandung B}}{\textit{Total Transaksi}} \quad (5)$$

Nilai *Benchmark Confidence* persamaan (5) digunakan sebagai standar untuk membandingkan dengan nilai *confidence* aktual dalam analisis asosiasi.

2.5 Penerapan (*Deployment*)

Tahap penerapan (*deployment*) yang direncanakan mencakup transformasi hasil keputusan ke dalam sistem operasional dan penyajian dalam bentuk laporan [15]. Hasil pola kombinasi produk dari aturan asosiasi akan digunakan dalam strategi penjualan, terutama *cross-selling* dan akan disajikan dalam bentuk laporan.

3. HASIL DAN PEMBAHASAN

3.1 Pemahaman Data (*Data Understanding*)

Peneliti mengumpulkan data sekunder berupa catatan transaksi penjualan dari tanggal 11 Mei 2021 hingga 11 Mei 2023 mencakup 21 karakteristik dan total 600 *record* data bersih tanpa ada *missing value*. Dengan pemahaman bisnis dan pemahaman data ini, diharapkan perusahaan dapat lebih efektif dalam mengelola persediaan dan menerapkan strategi *cross-selling* yang relevan untuk mengatasi tantangan penurunan penjualan produk. Tabel 1 untuk rincian data lebih lanjut.

Tabel 1. Atribut Data

No.	Nama Atribut	Tipe Atribut	Deskripsi Atribut
1.	Tanggal	Categorical	Tanggal Transaksi
2.	No Fak	Numeric	Nomor Faktur Pembelian
3.	Rupiah	Numeric	Total Uang Transaksi
4.	S1000	Numeric	Bakso Spesial 1000g
5.	B1000	Numeric	Bakso Besar 1000g
6.	K1000	Numeric	Bakso Kecil 1000g
7.	U1000	Numeric	Bakso Urat 1000g
8.	I1000	Numeric	Bakso Ikan 1000g
9.	O1000	Numeric	Otak-Otak Ikan 1000g
10.	S500	Numeric	Bakso Spesial 500g
11.	B500	Numeric	Bakso Besar 500g
12.	K500	Numeric	Bakso Kecil 500g
13.	U500	Numeric	Bakso Urat 500g
14.	I500	Numeric	Bakso Ikan 500g
15.	O500	Numeric	Otak-Otak Ikan 500g
16.	S250	Numeric	Bakso Spesial 250g
17.	B250	Numeric	Bakso Besar 250g
18.	K250	Numeric	Bakso Kecil 250g
19.	U250	Numeric	Bakso Urat 250g
20.	I250	Numeric	Bakso Ikan 250g
21.	O250	Numeric	Otak-Otak Ikan 250g

3.2 Persiapan Data (Data Preparation)

Pada tahap persiapan data, karena data yang dikumpulkan sudah bersih tanpa *missing value*, langkah-langkah *preprocessing* yang dilakukan adalah reduksi data dan transformasi data. Dalam tahap reduksi data, atribut-atribut yang relevan dan informatif dipilih untuk di analisis, sementara atribut yang tidak relevan dihapus. Sebagai contoh, atribut "No Fak" dan "Rupiah" dianggap tidak diperlukan dalam data transaksi. Selanjutnya dalam tahap transformasi data dilakukan pembentukan tabel baru dengan memberikan kode untuk setiap produk dalam rangka penyederhanaan analisis, seperti yang terlihat dalam Tabel 2. Hal ini bertujuan untuk memudahkan proses analisis data selanjutnya.

Tabel 2. Pengkodean Produk

No.	Nama Atribut	Kode Atribut	Deskripsi Atribut
1.	S1000	B1	Bakso Spesial 1000g
2.	B1000	B2	Bakso Besar 1000g
....
18.	O250	B18	Otak-Otak Ikan 250g

Pada Tabel 2 sebelumnya hanya berisi jumlah *quantity* produk yang dibeli oleh konsumen. Dengan demikian, perlu dilakukan perubahan agar dapat menjadi atribut *item* produk terjual dengan tipe data *binomial* yang berisikan 1 dan 0.

Tabel 3. Processing Binomial

Record	Tanggal	B1	B2	B3	B4	B5	B6	B7	B8	B9	B10	B11	...	B18
1	11/05/2021	0	0	0	1	0	0	0	1	0	0	0	...	1
2	20/05/2021	1	1	1	0	0	1	1	1	1	1	1	...	1
3	21/05/2021	1	0	0	0	0	1	1	1	0	0	1	...	1
....
600	11/05/2023	0	1	1	1	0	0	1	1	1	1	1	...	1

Sebagai contoh jika kode produk B1 yaitu Bakso Spesial 1000g berisikan nilai lebih dari 0 maka nilai Bakso Spesial 1000g pada Tabel 2 berisikan nilai 1 jika tidak, maka berisikan nilai 0 begitu seterusnya.

3.3 Pemodelan (Modelling)

3.3.1 Penerapan Algoritma *Frequent Pattern Growth* (FP-Growth)

Dalam tahap pemodelan, algoritma *FP-Growth* diaplikasikan pada sampel *dataset* transaksi penjualan PT Kusno Baso Ciledug pada bulan Januari 2023. Sampel ini terdiri dari 13 transaksi yang melibatkan 6 produk terpilih, yakni Bakso Spesial 1000g (B1), Bakso Besar 1000g (B2), Otak-Otak Ikan 1000g (B6), Bakso Kecil 500g (B9), Bakso Urat 500g (B10), dan Bakso Ikan 500g (B11). Penggunaan sampel *dataset* ini bertujuan untuk memberikan pemahaman yang lebih baik tentang proses yang dilakukan oleh algoritma *FP-Growth*. Rincian sampel *dataset* transaksi penjualan dapat dilihat pada Tabel 4.

Tabel 4. Sampel *Dataset* Transaksi Penjualan

Record	Tanggal Transaksi	Itemset
497	02/01/23	B1, B9
498	03/01/23	B6, B9, B10
499	04/01/23	B2, B6, B10, B11
500	05/01/23	B2, B6, B10
501	06/01/23	B1, B9
503	09/01/23	B1, B6
504	10/01/23	B1, B6, B11
505	11/01/23	B9, B10
509	16/01/23	B1, B2, B6, B11
511	18/01/23	B1, B2
514	21/01/23	B1, B2, B6, B9
517	25/01/23	B6, B9, B10
519	27/01/23	B2, B6, B9

Berdasarkan Tabel 4 diatas dapat disimpulkan bahwa nilai parameter minimum *support* dimanfaatkan dalam penelitian ini 0.2 (20%) serta nilai minimum *confidence* 0.7 (70%).

a. Tahap *Frequent 1 Itemset*

Pada tahap ini adalah langkah awal dalam proses analisis menggunakan algoritma *FP-Growth*. Pada tahap ini, dilakukan penentuan frekuensi kemunculan setiap *itemset* dari sampel *dataset* transaksi penjualan yang telah dijelaskan sebelumnya. Parameter minimum *support* yang telah ditentukan adalah 0.2. Perhitungan nilai *support* untuk setiap *itemset* menggunakan rumus persamaan (1). Hasil perhitungan ini dapat dilihat dalam Tabel 5 yang menampilkan frekuensi kemunculan dari setiap *itemset* dalam dataset.

Tabel 5. Frekuensi Kemunculan

Itemset	Frekuensi	Support
B6	9	9/13 = 0.692
B1	7	7/13 = 0.538
B9	7	7/13 = 0.538
B2	6	6/13 = 0.461
B10	5	5/13 = 0.384
B11	3	3/13 = 0.230

Pada Tabel 5 sudah diurutkan berdasarkan priority atau frekuensi tertinggi dan semua itemset telah memenuhi syarat minimum Support 0.2, maka dapat melakukan ke tahapan selanjutnya yaitu pembuatan FP-Tree.

b. Tahap *Ordered Itemset*

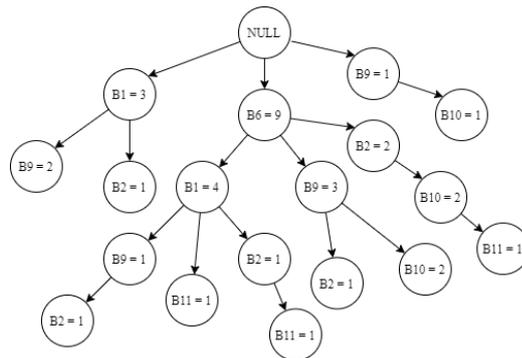
Tahap *Ordered Itemset* adalah langkah berikutnya dalam analisis dengan algoritma *FP-Growth*. Pada tahap ini, hasil pencarian *itemset* yang sering muncul diurutkan secara *descending* (dari frekuensi tertinggi ke terendah) dari setiap *itemset* dalam sampel *dataset* transaksi penjualan. Hasil pengurutan ini yang didasarkan pada frekuensi kemunculan itemset, disajikan dalam Tabel 6.

Tabel 6. Dataset Diurutkan Secara *Descending* Berdasarkan *Priority*

Record	Tanggal Transaksi	Itemset
497	02/01/23	B1, B9
498	03/01/23	B6, B9, B10
499	04/01/23	B6, B2, B10, B11
500	05/01/23	B6, B2, B10
501	06/01/23	B1, B9
503	09/01/23	B6, B1
504	10/01/23	B6, B1, B11
505	11/01/23	B9, B10
509	16/01/23	B6, B1, B2, B11
511	18/01/23	B1, B2
514	21/01/23	B6, B1, B9, B2
517	25/01/23	B6, B9, B10
519	27/01/23	B6, B9, B2

c. Pembentukan *FP-Tree*

Tahap Pembentukan *FP-Tree* adalah langkah berikutnya dalam analisis menggunakan algoritma *FP-Growth*. *FP-Tree* dibentuk berdasarkan urutan *itemset* yang telah diurutkan seperti yang tercantum dalam Tabel 6. Setiap transaksi dalam dataset berkontribusi dengan menambahkan nilai *support count* ke simpul yang sesuai dalam *FP-Tree*. Jika simpul belum ada, maka simpul baru akan dibuat. Selama proses ini, setiap simpul yang dilewati akan mengakumulasi nilai *support count*. Hasil dari pembentukan *FP-Tree* ini dapat dilihat dalam Gambar 2.



Gambar 2. Hasil Pembentukan *FP-Tree*

d. *Conditional Pattern Base* dan *Conditional FP-Tree*

Langkah *Conditional Pattern Base* dan *Conditional FP-Tree* adalah bagian penting dalam analisis menggunakan algoritma *FP-Growth*. Proses pembentukan *Conditional Pattern Base* dimulai dengan mengurutkan *itemset* pola akhiran (*suffix*) berdasarkan *support count* dari yang terendah hingga yang tertinggi. Selanjutnya, *Conditional FP-Tree* dibentuk dengan cara menghitung total *support count* untuk setiap *item* dalam *conditional pattern base*. *Item* yang memiliki *support count* lebih tinggi atau sama dengan minimum *support count* yang ditentukan kemudian digunakan untuk membentuk *conditional FP-Tree*. Hasil dari langkah ini dapat dilihat dalam Tabel 7.

Tabel 7. Hasil *Conditional Pattern Base* dan *Conditional FP-Tree*

Suffix	Conditional Pattern Base	Conditional FP-Tree
B11	{B6, B1=1}, {B6, B1,B2=1}, {B6,B2,B10=1}	{B6=3, B1=2}
B10	{B6, B9=2}, {B6,B2=2}, {B9=1}	{B6=4, B9=2}, {B2=2}
B2	{B1=1}, {B6, B1,B9=1}, {B6,B1=1}, {B6,B9=1}, {B6=2}	{B6=5, B1=2}
B9	{B1=2}, {B6,B1=1}, {B6=3}	{B1=2}, {B6=4}
B1	{B6=4}	{B6=4}

e. Pencarian *Frequent Itemset*

Pada tahap pencarian *Frequent Itemset* adalah langkah penting dalam analisis menggunakan algoritma *FP-Growth*. Di tahap ini, peneliti menggabungkan *itemset* yang ada dalam *Conditional FP-Tree* untuk menemukan *itemset* yang muncul dengan frekuensi yang memenuhi syarat minimum *support* yang telah ditentukan

sebelumnya. Hasil dari pencarian ini ditampilkan dalam Tabel 8 yang berisi daftar *itemset* yang memenuhi kriteria sebagai *frequent itemset*.

Tabel 8. Hasil *Frequent Itemset*

<i>Suffix</i>	<i>Frequent Itemset</i>
B11	{B11,B6=3},{B11,B1=2}
B10	{B10,B6=4},{B10,B9=2},{B10,B2=2}
B2	{B2,B6=5},{B2,B1=2}
B9	{B9,B1=2},{B9,B6=4}
B1	{B1,B6=4}

f. Tahapan Aturan Asosiasi

Tahapan ini melibatkan pembentukan 10 aturan asosiasi berdasarkan hasil *frequent itemset* yang telah ditemukan sebelumnya. Proses selanjutnya adalah perhitungan nilai *support* untuk dua *itemset* menggunakan rumus persamaan (2) dan perhitungan minimum *confidence* menggunakan rumus persamaan (3) dengan nilai minimum *support* 0.2 dan minimum *confidence* 0.7, seperti yang terlihat dalam Tabel 9.

Tabel 9. Hasil Aturan Asosiasi

No.	<i>Rule</i>	<i>Support</i>	<i>Confidence</i>
1.	B11 => B6	3/13 = 0.230	3/3 = 1.0
2.	B11 => B1	2/13 = 0.153	2/3 = 0.666
3.	B10 => B6	4/13 = 0.307	4/5 = 0.8
4.	B10 => B9	2/13 = 0.153	2/5 = 0.4
5.	B10 => B2	2/13 = 0.153	2/5 = 0.4
6.	B2 => B6	5/13 = 0.384	5/6 = 0.833
7.	B2 => B1	2/13 = 0.153	2/6 = 0.333
8.	B9 => B1	2/13 = 0.153	2/7 = 0.285
9.	B9 => B6	4/13 = 0.307	4/7 = 0.571
10.	B1 => B6	4/13 = 0.307	4/7 = 0.571

Dari tahapan-tahapan yang telah dilakukan, maka dapat disimpulkan aturan yang memenuhi syarat nilai *support* dan *confidence* yaitu:

1. Jika konsumen membeli Bakso Ikan 500g, maka konsumen juga dipastikan membeli Otak-Otak Ikan 1000g, dengan nilai *Support* = 23% dan nilai *Confidence* = 100%.
2. Jika konsumen membeli Bakso Urat 500g, maka konsumen juga cenderung membeli Otak-Otak Ikan 1000g, dengan nilai *Support* = 30.7% dan nilai *Confidence* = 80%.
3. Jika konsumen membeli Bakso Besar 1000g, maka konsumen juga cenderung membeli Otak-Otak Ikan 1000g, dengan nilai *Support* = 38.4% dan nilai *Confidence* = 83.3%.

3.3.2 Pengujian Lift Ratio

Pada tahap pengujian *Lift Ratio*, dilakukan perhitungan *Benchmark Confidence* menggunakan rumus persamaan (5) dan *lift ratio* menggunakan rumus persamaan (4). Hasil perhitungan dapat dilihat dalam Tabel 10.

Tabel 10. Pengujian *Lift Ratio*

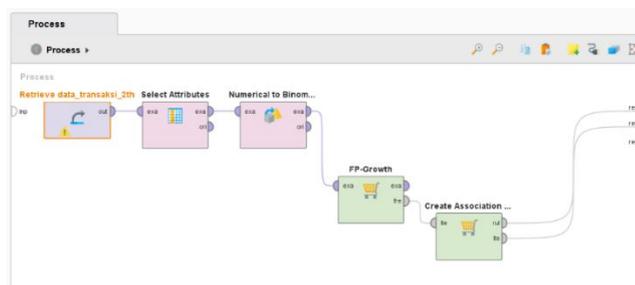
No.	<i>Rule</i>	<i>Support</i>	<i>Confidence</i>	<i>Benchmark Confidence</i>	<i>Lift Ratio</i>
1.	B11 => B6	0.230	1.0	9/13 = 0.692	1.0/0.692 = 1.445
2.	B10 => B6	0.307	0.8	9/13 = 0.692	0.8/0.692 = 1.156
3.	B2 => B6	0.384	0.833	9/13 = 0.692	0.833/0.692 = 1.203

Dari hasil pengujian *lift ratio*, maka dapat disimpulkan bahwa aturan asosiasi terbukti kuat atau valid yang berkorelasi positif antara suatu *item* dengan *item* pasangannya, artinya produk tersebut lebih sering muncul bersamaan.

3.3.3 Pemodelan Algoritma FP-Growth Menggunakan Rapid Miner

Pemodelan Algoritma *FP-Growth* Menggunakan Rapid Miner adalah tahap selanjutnya dalam penelitian ini. Pada tahap ini, dilakukan pemodelan dengan metode *association rule* menggunakan algoritma *FP-Growth* pada data transaksi penjualan dari tanggal 11 Mei 2021 sampai 11 Mei 2023, setelah melalui tahap *preprocessing*. Percobaan

pemodelan ini melibatkan pengaturan parameter seperti minimum *support* dan *confidence* yang berbeda pada setiap percobaan. Gambar 3 menunjukkan desain pemodelan yang digunakan dalam Rapid Miner.



Gambar 3. Desain Pemodelan Menggunakan Rapid Miner

Berdasarkan hasil beberapa percobaan menggunakan aplikasi rapid miner pada Gambar 3, percobaan terbaik adalah dengan *setting* parameter minimum *Support* 20%, minimum *Confidence* 70%, dan *lift ratio* > 1 yang menghasilkan 9 aturan asosiasi produk yang dibeli konsumen secara bersamaan dalam satu kali transaksi.

3.4 Evaluasi (*Evaluation*)

Pada tahap Evaluasi, penelitian ini menggunakan data transaksi penjualan PT Kusno Baso Ciledug selama dua tahun (11 Mei 2021 hingga 11 Mei 2023), yang terdiri dari 600 *record* transaksi. Pengujian model dilakukan dengan memanfaatkan perangkat lunak Rapid Miner dan metode *association rule* menggunakan algoritma *FP-Growth*. Hasil pengujian menghasilkan 9 aturan asosiasi dengan parameter terbaik, yaitu minimum *Support* sebesar 0.2 (20%) dan minimum *Confidence* sebesar 0.7 (70%). Aturan-aturan ini didasarkan pada perhitungan *lift ratio* yang menunjukkan korelasi positif antara produk yang dipilih secara bersamaan. Hasil lengkapnya dapat dilihat pada Tabel 11.

Tabel 11. Hasil Aturan Asosiasi Pemodelan Rapid Miner *Dataset* Transaksi Penjualan Dalam Dua Tahun

No.	Rule	Support 0.2	Confidence 0.7	Lift Ratio
1.	Jika konsumen membeli Bakso Besar 1000g dan Bakso Kecil 1000g, maka konsumen juga cenderung membeli Bakso Spesial 1000g	23.3%	70.4%	1.117
2.	Jika konsumen membeli Otak-Otak Ikan 1000g dan Otak-Otak Ikan 500g, maka konsumen juga cenderung membeli Bakso Spesial 1000g	20.2%	70.8%	1.123
3.	Jika konsumen membeli Otak-Otak Ikan 1000g dan Bakso Kecil 1000g, maka konsumen juga cenderung membeli Bakso Spesial 1000g	22.7%	70.8%	1.124
4.	Jika konsumen membeli Bakso Kecil 500g, maka konsumen juga cenderung membeli Bakso Urat 500g	31.3%	70.9%	1.453
5.	Jika konsumen membeli Otak-Otak Ikan 1000g dan Bakso Spesial 250g, maka konsumen juga cenderung membeli Bakso Spesial 1000g	21.7%	72.2%	1.146
6.	Jika konsumen membeli Bakso Spesial 1000g dan Bakso Kecil 500g, maka konsumen juga cenderung membeli Bakso Urat 500g	20.8%	72.3%	1.480
7.	Jika konsumen membeli Bakso Kecil 1000g dan Bakso Urat 1000g, maka konsumen juga cenderung membeli Bakso Spesial 1000g	22.2%	73.1%	1.160
8.	Jika konsumen membeli Bakso Besar 500g dan Bakso Urat 500g, maka konsumen juga cenderung membeli Bakso Kecil 500g	20.7%	76.5%	1.733
9.	Jika konsumen membeli Bakso Ikan 500g dan Bakso Kecil 500g, maka konsumen juga cenderung membeli Bakso Urat 500g	20.2%	79.1%	1.619

Penerapan disajikan dalam bentuk laporan pada Tabel 11 yang sudah dijelaskan dengan pengetahuan agar manajemen pabrik bisa membaca data dengan lebih mudah.

Pembahasan penelitian ini menunjukkan penelitian menggunakan metodologi CRISP-DM membagi penelitian ini menjadi enam tahap, yaitu Pemahaman Bisnis, Pemahaman Data, Persiapan Data, Pemodelan, Evaluasi, dan Penerapan. Peneliti mengolah data menggunakan Microsoft Excel serta Rapid Miner sebagai perangkat lunak untuk penerapan pemodelan *data mining*. Dalam pemodelan ini menggunakan *setting* parameter minimum *Support* dan minimum *Confidence* disesuaikan dalam percobaan untuk menemukan aturan asosiasi yang relevan. Aturan asosiasi membantu mengidentifikasi pola pembelian konsumen yang dapat digunakan dalam strategi penjualan. Hasil lain termasuk laporan yang disajikan kepada manajemen perusahaan, yang mencakup rekomendasi produk yang diminati atau laku terjual dengan baik. Ini dapat membantu perusahaan dalam mengoptimalkan strategi penjualan produk.

4. KESIMPULAN

Berdasarkan hasil pengujian serta analisis kesimpulannya aturan asosiasi dibentuk dengan memanfaatkan algoritma *FP-Growth* selama dua tahun dari tanggal 11 Mei 2021 sampai dengan 11 Mei 2023 yang berjumlah 600 *record* data dengan nilai minimum *Support* 20% dan nilai minimum *Confidence* 70% menghasilkan 9 aturan asosiasi yang dapat digunakan untuk mengembangkan strategi penjualan yaitu *cross-selling* dengan tujuan meningkatkan penjualan produk. Manajemen PT Kusno Baso Ciledug dapat memanfaatkan aturan asosiasi yang ditemukan untuk merancang strategi penjualan yang lebih efektif. Dengan memahami hubungan antara produk yang sering dibeli bersamaan oleh konsumen, perusahaan dapat mengoptimalkan stok produk dan mengatur promosi yang lebih cermat untuk meningkatkan penjualan. Untuk penelitian masa depan, disarankan untuk memperluas cakupan data, mempertimbangkan faktor-faktor eksternal, dan mengujinya dalam berbagai situasi bisnis. Hal ini akan meningkatkan validitas hasil dan membantu dalam pengambilan keputusan yang lebih baik dalam strategi penjualan produk. Penelitian ini memberikan wawasan berharga tentang pola pembelian konsumen dan memberikan dasar untuk pengambilan keputusan yang lebih baik dalam strategi penjualan produk.

DAFTAR PUSTAKA

- [1] C.-S. Y. Chiang, Lan-Lung Luke, "Does Country-of-origin Brand Personality Generate Retail Customer Lifetime Value? A Big Data Analytics Approach," *Technol. Forecast. Soc. Change*, vol. 130, pp. 177–187, 2018.
- [2] V. K. G. SuryaNarayana, G., Kamakshiah Kolli, Mohd Dilshad Ansari, "A Traditional Analysis For Efficient Data Mining With Integrated Association Mining Into Regression Techniques," *ICCCE 2020 Proc. 3rd Int. Conf. Commun. Cyber Phys. Eng.*, pp. 1393–1404, 2021.
- [3] R. S. P. Zahrotun, Lisna, Dewi Soyusiawaty, "The Implementation Of Data Mining For Association Patterns Determination Using Temporal Association Methods In Medicine Data," *2018 Int. Semin. Res. Inf. Technol. Intell. Syst.*, pp. 668–673, 2018.
- [4] I. D. Shabtay, Lior, Philippe Fournier-Viger, Rami Yaari, "A Guided FP-Growth Algorithm For Mining Multitude-Targeted Item-Sets And Class Association Rules In Imbalanced Data," *Inf. Sci. (Ny)*, vol. 553, pp. 353–375, 2021.
- [5] W. Y. Chee, Chin-Hoong, Jafreezal Jaafar, Izzatdin Abdul Aziz, Mohd Hilmi Hasan, "Algorithms For Frequent Itemset Mining: A Literature Review," *Artif. Intell. Rev.*, vol. 52, pp. 2603–2621, 2019.
- [6] P. L. Kando Sihombing, U. Fatimah Sari Sitorus Pane, "Studi Sistem Informasi, and S. Triguna Dharma, "Implementasi Data Mining Dalam Menganalisa Pola Penjualan Roti Menggunakan Algoritma Fp-Growth," *J. Sist. Inf. TGD*, vol. 1, no. 3, pp. 228–238, 2022.
- [7] S. Syahriani, "Penerapan Data Mining Dalam Menentukan Pola Penjualan Sepatu Menggunakan Algoritma FP-Growth," *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 6, p. 1920, 2022, doi: 10.30865/jurikom.v9i6.5148.
- [8] M. A. L. M. Hutasuhut, M. Gilang Suryanata, S. Kusnasari, "Data Mining Untuk Menganalisa Pola Penjualan Pestisida dengan Menggunakan Algoritma FP-Growth," *J. Ris. Komput.*, vol. 9, no. 6, pp. 1963–1973, 2022, doi: 10.30865/jurikom.v9i6.5200.
- [9] E. H. R. Fauzi, A. W. Aranski, N. Nopriadi, "Implementasi Data Mining Pada Penjualan Pakaian dengan Algoritma FP-Growth," *JURIKOM (Jurnal Ris. Komputer)*, vol. 10, no. 2, p. 436, 2023, doi: 10.30865/jurikom.v10i2.5795.
- [10] J. vom B. Schneider, Johannes, Stefan Seidel, Marcus Basalla, "Reuse, Reduce, Support: Design Principles for Green Data Mining," *Bus. Inf. Syst. Eng.*, vol. 65, no. 1, pp. 65–83, 2023.
- [11] A. S. Telikani, Akbar, Amir H. Gandomi, "A Survey Of Evolutionary Computation For Association Rule Mining," *Inf. Sci. (Ny)*, vol. 524, pp. 318–352, 2023.
- [12] B. P. Woratschek, Herbert, Chris Horbel, "Determining Customer Satisfaction And Loyalty From A Value Co-Creation Perspective," *Serv. Ind. J.*, vol. 40, no. 11–12, pp. 777–799, 2020.
- [13] H. A. A. Ismail, Walaa N., Mohammad Mehedi Hassan, "Context-Enriched Regular Human Behavioral Pattern Detection From Body Sensors Data," *IEEE Access*, vol. 7, pp. 33834–33850, 2019.
- [14] M. B. Van Atteveldt, Wouter, Mariken ACG Van der Velden, "The Validity Of Sentiment Analysis: Comparing Manual Annotation, Crowd-Coding, Dictionary Approaches, And Machine Learning Algorithms," *Commun. Methods Meas.*, vol. 15, no. 2, pp. 121–140, 2021.
- [15] T. A. B. Wang, Yichuan, LeeAnn Kung, "Big Data Analytics: Understanding Its Capabilities And Potential Benefits For Healthcare Organizations," *Technol. Forecast. Soc. Change*, vol. 126, pp. 3–13, 2018.