

STUDI MODEL ASOSIASI PADA PENJUALAN KOPI BERBASIS ALGORITMA FP-GROWTH

Rina Andriyanti, Nining Rahaningsih, Irfan Ali

Komputerisasi Akuntansi, STMIK IKMI Cirebon

Jl. Perjuangan No.10B, Karyamulya, Kec. Kesambi, Kota Cirebon, Jawa Barat, Indonesia

rinaandriy2@gmail.com

ABSTRAK

Persaingan yang semakin ketat di industri kopi menuntut pemahaman yang lebih mendalam tentang pola pembelian pelanggan untuk mengoptimalkan strategi pemasaran yang tepat sasaran. Salah satu tantangan utama adalah kurangnya pemanfaatan data transaksi yang kompleks, yang sering kali menyebabkan strategi berbasis data seperti bundling produk atau promosi terarah, sering terlewatkan dan tidak diterapkan secara optimal. Padahal kecenderungan pelanggan dalam membeli beberapa produk secara bersamaan membuka peluang besar untuk meningkatkan nilai transaksi, efisiensi promosi, dan loyalitas pelanggan melalui strategi bundling. Penelitian ini menggunakan algoritma FP-Growth pada platform RapidMiner untuk menganalisis 1.900 data transaksi kopi dari Kaggle. Proses analisis meliputi seleksi data, pembersihan (*preprocessing*), transformasi data, dan penerapan algoritma dengan *minimum support* 0.01 dan *confidence* 0.7. Hasil analisis menunjukkan bahwa "Americano with Milk" memiliki frekuensi pembelian tertinggi (*support* 75,5%), dan kombinasi "Cortado" dengan "Hot Chocolate" mencapai *confidence* sebesar 80%. Temuan ini menunjukkan potensi besar untuk menyusun strategi bundling berbasis data, karena kombinasi produk dengan tingkat asosiasi tinggi mencerminkan kebiasaan konsumsi pelanggan yang dapat dimanfaatkan untuk meningkatkan efektivitas penjualan. Penelitian ini membuktikan bahwa algoritma FP-Growth mampu menganalisis data transaksi secara efisien, memberikan wawasan strategis yang relevan, serta mendukung pengambilan keputusan bisnis dalam menciptakan pengalaman pelanggan yang lebih personal dan menguntungkan.

Kata Kunci: Asosiasi, Algoritma FP-Growth, Penjualan, Data Mining, RapidMiner.

1. PENDAHULUAN

Industri *coffee* semakin berkembang pesat seiring dengan meningkatnya gaya hidup masyarakat yang menjadikan *coffee shop* sebagai tempat untuk bersantai, bekerja, atau berkumpul. Setiap kedai kopi selalu berharap produk mereka akan diterima di pasar[1]. Hal ini memicu persaingan yang ketat antara pelaku bisnis *coffee*, yang terus mencari cara untuk meningkatkan strategi pemasaran dan penjualan mereka. Oleh karena itu, menggali pola-pola penjualan yang dapat meningkatkan efisiensi operasional dan daya saing bisnis menjadi semakin penting dengan penggunaan teknologi data mining, khususnya FP-Growth.

Salah satu algoritma dalam *data mining* yang terbukti efektif dalam menemukan pola pembelian pelanggan adalah algoritma *Frequent Pattern Growth* (FP-Growth). FP-Growth mampu mengidentifikasi *frequent itemsets*, yaitu kombinasi item yang sering muncul bersamaan dalam satu transaksi. Dalam konteks industri kopi, algoritma ini dapat dimanfaatkan untuk mengidentifikasi keterkaitan antar produk, seperti item yang sering dibeli bersama, yang berguna untuk strategi promosi, penataan menu, pengelolaan inventaris, hingga bundling produk untuk meningkatkan nilai transaksi.

Penelitian terdahulu yang dilakukan oleh Eva Nurarofah, Ruli Herdiana, dan Nisa Dienwati Nuris dalam jurnal JATI Vol. 7 No. 1, Februari 2023 menunjukkan keberhasilan penggunaan algoritma

FP-Growth dalam menganalisis pola transaksi di sebuah toko roti di Korea. Penelitian tersebut menggunakan data dari platform Kaggle untuk mengidentifikasi hubungan antar produk dalam transaksi, yang selanjutnya digunakan untuk meningkatkan efisiensi serta daya tarik katalog penjualan. Hasilnya memberikan kontribusi nyata dalam penyusunan strategi promosi berbasis data [2].

Penelitian ini membahas kesulitan dalam mengidentifikasi pola pembelian pelanggan dari data transaksi penjualan kopi yang tersedia. Data untuk penelitian ini diperoleh dari website Kaggle.com[3], mencakup informasi seperti jenis minuman, metode pembayaran, dan nominal pendapatan. Meskipun data mencerminkan pola transaksi beragam, perusahaan sering kali kesulitan menganalisis hubungan antar produk atau preferensi konsumen. Misalnya, produk seperti *Americano with Milk* dan *Latte* sering terjual, tetapi potensi optimalisasi penjualan melalui analisis pola pembelian belum dimanfaatkan. Penelitian ini bertujuan mengungkap pola asosiasi antar produk untuk membantu perusahaan memahami perilaku konsumen dan menyusun strategi pemasaran yang lebih efektif.

Dengan algoritma FP-Growth, analisis ini bertujuan mengidentifikasi pola asosiasi antar produk, seperti kecenderungan konsumen membeli minuman tertentu secara bersamaan. Hasilnya diharapkan membantu perusahaan memahami perilaku konsumen dengan lebih baik, sehingga dapat merancang strategi

pemasaran yang efektif, seperti promosi bundling produk atau menentukan waktu promosi yang optimal.

Dari latar belakang yang telah dijelaskan, penelitian ini merumuskan dua pertanyaan utama. Pertama, bagaimana model asosiasi dapat diterapkan untuk menganalisis pola penjualan kopi menggunakan algoritma FP-Growth. Kedua, bagaimana performa algoritma FP-Growth dievaluasi dalam rangka meningkatkan model asosiasi berdasarkan data penjualan kopi.

Untuk menjaga fokus dan relevansi penelitian terhadap tujuan dan rumusan masalah, terdapat beberapa batasan dalam kajian ini. Penelitian terbatas pada penerapan algoritma FP-Growth untuk mengidentifikasi pola asosiasi antar produk kopi berdasarkan data transaksi yang telah tersedia. Data yang digunakan adalah data historis penjualan kopi, tanpa mempertimbangkan perubahan pola penjualan di masa mendatang. Evaluasi performa algoritma hanya menggunakan metrik *support*, dan *confidence*, tanpa membandingkannya dengan algoritma lain. Selain itu, hasil penelitian hanya mencakup analisis pola asosiasi antar produk kopi tanpa implementasi langsung pada sistem rekomendasi atau strategi pemasaran. Seluruh proses pengolahan data dan analisis dilakukan menggunakan perangkat lunak RapidMiner, dengan asumsi bahwa perangkat lunak tersebut dapat mendukung kebutuhan penelitian.

2. TINJAUAN PUSTAKA

2.1. Asosiasi

Salah satu metode yang bertujuan untuk menemukan pola yang sering muncul di antara banyak transaksi, di mana setiap transaksi terdiri dari beberapa item, adalah aturan asosiasi. Metode ini akan menemukan hubungan antar item.[4].

2.2. Algoritma FP-Growth

Salah satu alternatif algoritma yang dapat digunakan untuk menentukan himpunan data yang paling sering muncul (*frequent itemset*) dalam kumpulan data adalah algoritma FP-Growth. Algoritma ini menggunakan konsep pembangunan pohon, juga dikenal sebagai FP-Tree, dalam pencarian himpunan data yang paling sering muncul, daripada menggunakan *generate candidate* seperti yang dilakukan oleh Algoritma Apriori. Akibatnya, algoritma FP-Growth lebih cepat dari pada algoritma Apriori[5].

2.3. Penjualan

Menurut Assauri, penjualan adalah kegiatan manusia yang bertujuan untuk memenuhi dan memuaskan kebutuhan dan keinginan melalui proses pertukaran. Penjualan juga merupakan kegiatan yang bertujuan untuk mencari pembeli, mempengaruhi dan memberikan petunjuk agar pembeli dapat menyesuaikan kebutuhannya dengan produk yang ditawarkan, dan mengadakan perjanjian mengenai

harga yang menguntungkan bagi kedua belah pihak[6].

2.4. Data Mining

Data mining adalah proses penambangan data yang menggunakan sejumlah besar data melalui berbagai langkah untuk menghasilkan berbagai informasi berguna[7].

2.5. RapidMiner

RapidMiner adalah perangkat lunak yang dikembangkan oleh Dr. Markus Hofmann dan Ralf Klinkenberg dari Institut Teknologi Blanchardstown. Perangkat lunak ini mendukung pemrograman berbasis antarmuka grafis (*Graphical User Interface/GUI*) dan bersifat *open source*. Ditulis menggunakan bahasa pemrograman Java, RapidMiner kompatibel dengan berbagai sistem operasi. Salah satu keunggulannya adalah pengguna tidak memerlukan keahlian pemrograman khusus, karena semua model telah tersedia secara langsung di dalamnya. RapidMiner digunakan untuk aktivitas data mining dan menawarkan berbagai model analisis data yang cukup lengkap, seperti model Bayesian, pemodelan, *tree induction*, *neural networks*, dan lainnya. Selain itu, RapidMiner juga mendukung berbagai metode analisis data, termasuk klasifikasi, pengelompokan, dan asosiasi. Sebagai platform analisis data yang populer, RapidMiner memberikan kemudahan dalam membangun alur kerja analisis data melalui antarmuka grafis yang intuitif[8].

3. METODE PENELITIAN


3.1. Metode pengumpulan data

Data yang bernama *Coffee Sales* ini diambil dari situs web Kaggle, yang merupakan komunitas online yang mengumpulkan para ilmuwan data. Data yang berjumlah 1900 transaksi ini diambil pada hari Sabtu, 7 Desember 2024. Dataset ini mencakup penjualan kopi dari bulan Maret sampai November 2024.

Metode pengumpulan data untuk penelitian ini menggunakan studi dokumentasi dan merupakan data sekunder karena diperoleh dari *platform* Kaggle. Dataset tersebut mencakup informasi transaksi penjualan kopi, seperti tanggal, waktu transaksi, metode pembayaran, kartu, nominal uang, dan nama minuman yang terjual. Sebagai data yang telah terstruktur dan tersedia secara publik, dataset ini siap dianalisis menggunakan algoritma FP-Growth di RapidMiner. Pemanfaatan data sekunder memungkinkan penelitian dilakukan secara lebih efisien dalam hal waktu dan biaya tanpa perlu mengumpulkan data primer secara langsung.

3.2. Tahapan penelitian

Karena fokus penelitian adalah analisis data dan kecerdasan buatan, maka kerangka *Knowledge Discovery in Databases(KDD)* digunakan. KDD adalah proses sistematis untuk mengekstrak informasi bermanfaat dari data besar. Berikut adalah proses yang diikuti :



Gambar 1. Tahapan proses KDD

a. *Data Selection*

Proses ini memilih himpunan data, membuat himpunan data target, atau memfokuskan pada sampel data yang akan digunakan untuk penemuan. Seleksi hasil disimpan dalam berkas yang berbeda dari basis data operasional.

b. *Pre-Processing dan Cleaning Data*

Data *preprocessing* adalah tahap penting dalam proses *Knowledge Data Discovery* (KDD) yang berfokus pada pembersihan data yang telah dikumpulkan. Tahap ini bertujuan untuk menghilangkan noise dari data mentah sehingga informasi yang relevan dapat diekstraksi. Proses ini dianggap sebagai langkah utama dan krusial dalam analisis data. Data *preprocessing* mencakup beberapa langkah, seperti ekstraksi fitur (*feature extraction*), pembersihan data (*data cleaning*), pemilihan fitur (*feature selection*), dan transformasi data (*data transformation*) [9].

c. *Transformation*

Transformasi merupakan sekumpulan instruksi untuk mengubah input menjadi output yang diinginkan (input-proses-output) [10].

d. *Data Mining*

Data mining adalah proses menemukan pola atau informasi yang menarik dalam data tertentu dengan menggunakan teknik, metode, atau algoritma tertentu yang sesuai dengan tujuan umum dari proses data mining.

e. *Interpretation/ Evaluasi*

Data mining adalah proses menemukan pola atau informasi yang menarik dalam data tertentu dengan menggunakan teknik, metode, atau algoritma tertentu yang sesuai dengan tujuan umum dari proses *data mining* [11].


4. HASIL DAN PEMBAHASAN

Tabel 1. Jenis *Coffee_Name*

<i>Coffee_Name</i>
Americano
Americano with Milk
Cappuccino
Cocoa
Cortado
Espresso
Hot Chocolate
Latte


Prosedur yang digunakan untuk menerapkan algoritma FP-Growth pada data transaksi penjualan adalah menggunakan aplikasi RapidMiner.

4.1. Data Selection



Gambar 2. Proses Read Excel

Langkah pertama yaitu menambahkan atribut *Read Excel* pada lembar kerja RapidMiner. *Read Excel* merupakan operator atau fungsi yang digunakan untuk mengimpor data dari file Excel ke dalam lingkungan analisis. Fungsi ini memungkinkan pembacaan data dari *spreadsheet* Excel sehingga dapat digunakan dalam proses analisis data di RapidMiner [12].



Gambar 3. Import data


Dataset yang digunakan bernama *dataset coffee*, pemilihan ini dilakukan karena pentingnya analisis data dan relevansinya dengan tujuan penelitian.

Row No.	date	datetime	cash_type	card	money	coffee_name
1	Mar 1, 2024	Mar 1, 2024, 10:15:1	cash	ANON-0000-0000-1	1.588	Americano with Milk
2	Mar 1, 2024	Mar 1, 2024, 12:19:23	cash	ANON-0000-0000-1	1.588	Cappuccino
3	Mar 1, 2024	Mar 1, 2024, 1:46:35	cash	ANON-0000-0000-1	1.173	Cortado
4	Mar 1, 2024	Mar 1, 2024, 1:46:15	cash	ANON-0000-0000-1	1.588	Hot Chocolate
5	Mar 1, 2024	Mar 1, 2024, 3:38:48	cash	ANON-0000-0000-1	1.581	Americano with Milk
6	Mar 1, 2024	Mar 1, 2024, 4:19:03	cash	ANON-0000-0000-2	1.588	Cappuccino
7	Mar 1, 2024	Mar 1, 2024, 6:38:04	cash	ANON-0000-0000-2	1.581	Cortado
8	Mar 1, 2024	Mar 1, 2024, 10:15:1	cash	ANON-0000-0000-2	1.588	Hot Chocolate
9	Mar 1, 2024	Mar 1, 2024, 12:19:23	cash	ANON-0000-0000-2	1.581	Americano with Milk
10	Mar 1, 2024	Mar 1, 2024, 1:46:35	cash	ANON-0000-0000-3	1.581	Cappuccino
11	Mar 1, 2024	Mar 1, 2024, 1:46:15	cash	ANON-0000-0000-3	1.173	Cortado
12	Mar 2, 2024	Mar 2, 2024, 3:38:48	cash	ANON-0000-0000-4	1.173	Hot Chocolate
13	Mar 2, 2024	Mar 2, 2024, 4:19:03	cash	ANON-0000-0000-4	1.581	Americano with Milk

Gambar 4. Output Read Excel

Gambar 4 diatas menunjukan sebanyak 1900 baris data transaksi yang siap untuk diproses dan dianalisis lebih lanjut.

4.2. Preprocessing Data




Gambar 5. Proses dari Aggregate

Proses ini merupakan langkah penting dalam pengolahan data, tujuannya adalah untuk menyederhanakan data dari kumpulan data yang besar dan kompleks. Proses ini dilakukan untuk menggabungkan, menghitung, atau menganalisis kelompok data tertentu berdasarkan karakteristik tertentu. Dengan cara ini, data yang awalnya tersebar dapat diubah menjadi format yang lebih terstruktur.

Row No.	card	concat(coffee_name)
1	AMON-0000-0000-01	Americano with Milk/Cappuccino/Cortado/Hot Chocolate/Americano with Milk
2	AMON-0000-0000-02	Cortado/Hot Chocolate/Americano with Milk
3	AMON-0000-0000-03	Cortado/Hot Chocolate/Americano with Milk/Cappuccino/Cortado
4	AMON-0000-0000-04	Hot Chocolate/Americano with Milk/Cappuccino/Cortado
5	AMON-0000-0000-05	Hot Chocolate/Americano with Milk
6	AMON-0000-0000-06	Cappuccino/Cortado
7	AMON-0000-0000-07	Hot Chocolate/Americano with Milk
8	AMON-0000-0000-08	Cappuccino/Hot Chocolate/Americano with Milk/Cappuccino
9	AMON-0000-0000-09	Cortado/Hot Chocolate/Americano with Milk/Cappuccino
10	AMON-0000-0000-10	Cortado
11	AMON-0000-0000-11	Hot Chocolate/Americano with Milk/Cappuccino
12	AMON-0000-0000-12	Cortado/Hot Chocolate/Americano with Milk
13	AMON-0000-0000-13	Cappuccino/Cortado/Hot Chocolate/Americano with Milk

Gambar 6. Output Aggregate

Gambar diatas menunjukkan hasil dari proses penggabungan yang bertujuan untuk menyatukan jenis *Coffee_Name* berdasarkan *card*, dalam hal ini, *card* adalah faktor.



Gambar 7. Proses Rename

Operator *Rename* digunakan untuk mengganti nama atribut (kolom) dalam dataset tanpa mengubah tipe atau peran atribut tersebut. Misalnya, atribut bernama "alpha" dengan tipe integer dan peran reguler dapat diubah namanya menjadi "beta," sementara tipe dan perannya tetap sama. Proses ini berguna untuk membuat nama kolom lebih deskriptif atau sesuai dengan kebutuhan penelitian.


old name	new name
concat(coffee_name)	Menu

Gambar 8. Rename attributes

Agar dataset ini lebih mudah untuk dipahami, jadi saya mengganti nama atribut. Sebelumnya

bernama "concat(coffee_name)", diubah menjadi "Menu".

4.3. Transformasi Data



Gambar 9. Proses SetRole


Operator ini digunakan untuk menentukan atau mengubah peran (*role*) atribut tertentu dalam dataset. Dalam proses ini, atribut **Card** ditetapkan sebagai ID, sehingga dianggap identitas unik untuk setiap baris data dan tidak digunakan untuk prediksi atau analisis.

Row No.	card	Menu
1	AMON-0000-0000-01	Americano with Milk/Cappuccino/Cortado/Hot Chocolate/Americano with Milk
2	AMON-0000-0000-02	Cortado/Hot Chocolate/Americano with Milk
3	AMON-0000-0000-03	Cortado/Hot Chocolate/Americano with Milk/Cappuccino/Cortado
4	AMON-0000-0000-04	Hot Chocolate/Americano with Milk
5	AMON-0000-0000-05	Cappuccino/Cortado
6	AMON-0000-0000-06	Hot Chocolate/Americano with Milk
7	AMON-0000-0000-07	Cappuccino/Hot Chocolate/Americano with Milk/Cappuccino
8	AMON-0000-0000-08	Cortado/Hot Chocolate/Americano with Milk/Cappuccino
9	AMON-0000-0000-09	Cortado
10	AMON-0000-0000-10	Hot Chocolate/Americano with Milk/Cappuccino
11	AMON-0000-0000-11	Cortado/Hot Chocolate/Americano with Milk
12	AMON-0000-0000-12	Cappuccino/Cortado/Hot Chocolate/Americano with Milk
13	AMON-0000-0000-13	Cappuccino/Cortado/Hot Chocolate/Americano with Milk

Gambar 10. Output Set Role

Warna biru pada *card* menandakan bahwa telah ditetapkannya Id pada dataset ini.

4.4. Data Mining




Gambar 11. Flowchart Proses Algoritma FP-Growth

Pada tahap ini, proses data mining dilakukan menggunakan algoritma FP-Growth untuk menemukan pola asosiasi dari data transaksi penjualan kopi. FP-Growth dipilih karena kemampuannya dalam mengekstraksi pola *frequent itemsets* secara efisien tanpa harus membangkitkan kandidat itemsets seperti pada algoritma Apriori.

Tahapan kerja algoritma FP-Growth secara umum dimulai dengan menghitung support untuk setiap item, membentuk struktur FP-Tree untuk menyimpan transaksi secara efisien, menelusuri pohon guna menemukan *frequent itemsets*, lalu membentuk aturan asosiasi berdasarkan nilai *confidence*.

Untuk memberikan gambaran yang lebih jelas mengenai alur kerja algoritma FP-Growth, berikut flowchart prosesnya:



Gambar 12. Pemodelan Data Mining

Analisis data adalah proses yang dimaksudkan untuk mengolah data hingga menghasilkan aturan asosiasi. Hasil analisis ini adalah aturan asosiasi yang dapat digunakan untuk analisis lebih lanjut, seperti membuat keputusan berdasarkan pola data atau memberikan rekomendasi tentang produk.

Parameters

FP-Growth

- min requirement: support
- min support: 0.01
- min items per itemset: 1
- max items per itemset: 0
- max number of itemsets: 1000000
- [Hide advanced parameters](#)
- [Change compatibility \(9.8.001\)](#)

Parameters

Create Association Rules

- criterion: confidence
- min confidence: 0.7
- gain theta: 2.0
- laplace k: 1.0
- [Hide advanced parameters](#)

Gambar 13. Menyertakan Minimum Support dan Minimum Confidence

Minimum support sebesar 0.01 yang berarti itemset harus muncul dalam 1% dari total transaksi untuk dianggap sering. *Minimum confidence* dengan nilai 0.7 yang berarti aturan akan dihasilkan jika *confidence* nya itu minimal 70%.

4.5. Interpretation / Evaluasi

No.	Itemset	Support	Item 1	Item 2	Item 3	Item 4
1	Americano with Milk	0.755				
2	Cappuccino	0.747				
3	Cortado	0.744				
4	Hot Chocolate	0.738				
5	Americano with Milk, Cappuccino	0.607				
6	Americano with Milk, Cortado	0.591				
7	Americano with Milk, Hot Chocolate	0.589				
8	Cappuccino, Cortado	0.587				
9	Cappuccino, Hot Chocolate	0.533				
10	Cortado, Hot Chocolate	0.588				
11	Americano with Milk, Cappuccino, Cortado	0.479				
12	Americano with Milk, Cappuccino, Hot Chocolate	0.464				
13	Americano with Milk, Cortado, Hot Chocolate	0.476				
14	Cappuccino, Cortado, Hot Chocolate	0.472				
15	Americano with Milk, Cappuccino, Cortado, Hot Chocolate	0.403				

Gambar 14. Output frequent itemsets (FP-Growth)

Gambar ini memberikan informasi tentang frekuensi kemunculan item individu atau kombinasi item dalam transaksi:


- Americano with Milk** memiliki *support* tertinggi sebesar 0,755, menunjukkan bahwa item ini muncul dalam 75,5% dari total transaksi, menjadikannya yang paling sering dibeli.
- Kombinasi dua item, yaitu **Americano with Milk** dan **Cappuccino**, memiliki *support* sebesar 0,607, yang berarti kedua item ini muncul bersama dalam 60,7% transaksi.
- Kombinasi tiga item, yakni **Americano with Milk**, **Cappuccino**, dan **Cortado**, menunjukkan *support* sebesar 0,479, mencerminkan kemunculannya dalam 47,9% transaksi.
- Kombinasi empat item, yaitu **Americano with Milk**, **Cappuccino**, **Cortado**, dan **Hot Chocolate**, memiliki *support* sebesar 0,403, yang berarti muncul bersama dalam 40,3% transaksi.

No.	Premise	Conclusion	Support	Confidence	Lift
1	Cappuccino	Hot Chocolate	0.533	0.713	0.977
2	Hot Chocolate	Cappuccino	0.533	0.721	0.982
3	Americano with Milk	Cortado	0.591	0.738	0.884
4	Americano with Milk, Cortado	Cappuccino, Hot Chocolate	0.403	0.731	0.904
5	Cortado	Americano with Milk	0.591	0.741	0.890
6	Cappuccino, Hot Chocolate	Americano with Milk, Cortado	0.403	0.738	0.915
7	Americano with Milk, Cappuccino	Hot Chocolate	0.464	0.764	0.911
8	Americano with Milk	Hot Chocolate	0.589	0.779	0.905
9	Americano with Milk, Hot Chocolate	Cappuccino	0.464	0.788	0.921
10	Americano with Milk, Cappuccino	Cortado	0.479	0.788	0.905
11	Cappuccino, Cortado	Hot Chocolate	0.472	0.791	0.922
12	Cortado, Hot Chocolate	Cappuccino	0.472	0.793	0.923
13	Hot Chocolate	Americano with Milk	0.589	0.797	0.914
14	Cortado, Hot Chocolate	Americano with Milk	0.476	0.798	0.925

Gambar 15. Output AssociationRules


Gambar ini mengilustrasikan aturan asosiasi antara produk berdasarkan pola pembelian pelanggan. Sebagai contoh, aturan $\{Cappuccino\} \rightarrow \{Hot Chocolate\}$ memiliki nilai *support* sebesar 0,533, yang menunjukkan bahwa 53,3% dari total transaksi melibatkan pembelian *Cappuccino* dan *Hot Chocolate* secara bersamaan. Dengan *confidence* sebesar 0,713, ini berarti 71,3% dari transaksi yang mencakup *Cappuccino* juga melibatkan pembelian *Hot Chocolate*.

Informasi ini dapat membantu bisnis memahami keterkaitan antar produk, sehingga dapat digunakan untuk menyusun strategi pemasaran yang lebih efektif, seperti promosi bundling atau rekomendasi produk kepada pelanggan.



Gambar 16. Grafik AssociationRules

Grafik ini menyajikan visualisasi aturan asosiasi yang menggambarkan pola pembelian atau hubungan antar item dalam dataset. Data dari grafik ini dapat dimanfaatkan untuk mendukung pengambilan keputusan dalam merancang strategi pemasaran, seperti mengatur penempatan produk atau merancang promosi berdasarkan item yang kerap dibeli bersamaan.



Gambar 17. Aturan AssociationRules dalam bentuk deskripsi

Gambar tersebut merupakan hasil aturan asosiasi (*Association Rules*) yang dihasilkan menggunakan algoritma FP-Growth dalam RapidMiner. Aturan ini dirancang untuk mengidentifikasi keterkaitan antar produk yang sering dibeli bersamaan dalam dataset transaksi. Setiap aturan ditulis dalam format *Premises* → *Conclusion*, di mana *Premises* mewakili kombinasi produk sebagai dasar aturan, sedangkan *Conclusion* menunjukkan produk yang kemungkinan besar akan dibeli berdasarkan *Premises*. Nilai *confidence* merepresentasikan peluang (dalam persentase) bahwa produk pada *Conclusion* akan dibeli jika produk pada *Premises* ada dalam transaksi.

Sebagai contoh, aturan [*Cappuccino*] → [*Hot Chocolate*] dengan *confidence* 71,3% menunjukkan bahwa jika seseorang membeli *Cappuccino*, terdapat kemungkinan 71,3% mereka juga akan membeli *Hot Chocolate*. Analisis ini bermanfaat untuk mengidentifikasi pola pembelian konsumen yang

dapat diterapkan dalam strategi bisnis, seperti memberikan rekomendasi produk, mengoptimalkan tata letak produk di toko, atau merancang penawaran bundling. Selain itu, aturan ini juga dapat mendukung strategi pemasaran berbasis data, misalnya dengan memberikan diskon pada produk yang sering dibeli bersamaan dengan *confidence* tinggi. Dengan demikian, analisis asosiasi ini memberikan wawasan penting untuk memahami pola perilaku pelanggan dan membantu pengambilan keputusan bisnis yang lebih strategis.

5. KESIMPULAN

Berdasarkan hasil analisis penjualan kopi menggunakan algoritma FP-Growth, penelitian ini menunjukkan keberhasilan algoritma dalam menemukan pola pembelian konsumen dari dataset berisi 1.900 transaksi. Dengan *minimum support* 0.01 dan *confidence* 0.7, analisis ini menghasilkan aturan asosiasi yang mendukung strategi seperti bundling dan promosi. Produk seperti *Americano with Milk* muncul dalam 75,5% transaksi, sementara kombinasi seperti *Cortado* dan *Hot Chocolate* memiliki *confidence* 80%, menunjukkan potensi besar untuk strategi pemasaran berbasis data. Evaluasi performa algoritma FP-Growth mengonfirmasi kemampuannya dalam mengidentifikasi pola pembelian yang relevan, efisien, dan bernilai strategis, membantu optimalisasi penempatan produk, rekomendasi pembelian, serta peningkatan penjualan secara efektif. Studi lanjutan disarankan menggunakan dataset lebih besar, variasi parameter, serta integrasi data eksternal untuk analisis yang lebih mendalam dan penerapan dalam sistem rekomendasi.

DAFTAR PUSTAKA

- [1] N. Iman, A. M. Muhar, and A. I. Sari, "Analisis Daya Saing Industri Coffee Shop di Kota Medan," *JAMEK)Jurnal Akunt. Manaj. dan kewirausahaan*, vol. 02, no. 3, pp. 54–64, 2022.
- [2] E. Nurarofah, R. Herdiana, and N. Dienwati Nuris, "Penerapan Asosiasi Menggunakan Algoritma Fp-Growth Pada Pola Transaksi Penjualan Di Toko Roti," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 1, pp. 353–359, 2023, doi: 10.36040/jati.v7i1.6299.
- [3] N. Nafi'iyah and N. F. Maulidi, "LINEAR REGRESSION FOR DISCOUNTING PRESENTATION RECOMMENDATIONS (Kaggle Dataset)," *J. Teknol. Inf. Dan Komun.*, vol. 13, no. 2, pp. 67–73, 2022, doi: 10.51903/jtikp.v13i2.326.
- [4] M. Arif Saifudin, H. Endah Wahanani, and A. Junaidi, "Implementasi Algoritma Asosiasi Fp-Growth Dan Klasifikasi K-Means Terhadap Pola Pembelian Konsumen Di Marketplace Shopee," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 764–771, 2024, doi: 10.36040/jati.v8i1.8848.
- [5] E. Munanda and S. Monalisa, "Penerapan Algoritma Fp-Growth Pada Data Transaksi Penjualan Untuk Penentuan Tataletak," *J. Ilm.*

- Rekayasa dan Manaj. Sist. Inf.*, vol. 7, no. 2, pp. 173–184, 2021, [Online]. Available: <http://ejournal.uin-suska.ac.id/index.php/RMSI/article/view/13253>
- [6] E. P. Yugo Susanto, Sri Bangun Lestari, “Главную | База 1 | База 2 | База 3,” *Int. J. Environ. Res. Public Health*, vol. 1, no. 2, pp. 1–10, 2020.
- [7] B. A. Pangestu, N. A. Kristiawan, and N. Sulistiyowati, “Clustering Obat Untuk Menentukan Pola Pemasaran Efektif di Apotek Amarta Sehat,” *J. Ilm. Wahana Pendidik.*, vol. 8, no. 16, pp. 115–126, 2022, [Online]. Available: <https://doi.org/10.5281/zenodo.7058995>
- [8] E. C. Vidiya and G. Testiana, “Analisis Pola Pembelian di Lathansa Cafe & Ramen dengan Menggunakan Algoritma FP-Growth Berbantuan RapidMiner,” *G-Tech J. Teknol. Terap.*, vol. 7, no. 3, pp. 1118–1126, 2023, doi: 10.33379/gtech.v7i3.2739.
- [9] M. R. A. Prasetya, A. M. Priyatno, and Nurhaeni, “Penanganan Imputasi Missing Values pada Data Time Series dengan Menggunakan Metode Data Mining,” *J. Inf. dan Teknol.*, vol. 5, no. 2, pp. 52–62, 2023, doi: 10.37034/jidt.v5i2.324.
- [10] S. Widaningsih, “Penerapan Data Mining untuk Memprediksi Siswa Berprestasi dengan Menggunakan Algoritma K Nearest Neighbor,” *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 9, no. 3, pp. 2598–2611, 2022, doi: 10.35957/jatisi.v9i3.859.
- [11] K. Erwansyah, B. Andika, and R. Gunawan, “Implementasi Data Mining Menggunakan Asosiasi Dengan Algoritma Apriori Untuk Mendapatkan Pola Rekomendasi Belanja Produk Pada Toko Avis Mobile,” *J-SISKO TECH (Jurnal Teknol. Sist. Inf. dan Sist. Komput. TGD)*, vol. 4, no. 1, p. 148, 2021, doi: 10.53513/jsk.v4i1.2628.
- [12] G. Gunadi, “Infotech: journal of technology information,” vol. 9, no. 1, pp. 67–76, 2023.