

REKOMENDASI STRATEGI PENJUALAN BUNDLING DI CAFE SZ POINT MENGGUNAKAN ALGORITMA FREQUENT PATTERN GROWTH

Muhammad Faiz Harby^{1*}, Eka Dyar Wahyuni², Nur Cahyo Wibowo³

1,2,3Fakultas Ilmu Komputer, Universitas Pembangunan Nasional Veteran Jawa Timur; Jl.Raya Rungkut Madya, Gunung Anyar, Surabaya, Jawa Timur 60294; Telp. +62 (031) 870 6369 / Fax. +62 (031) 870 6372

Received: 11 Juli 2024

Accepted: 31 Juli 2024

Published: 7 Agustus 2024

Keywords:

FP-Growth;

Strategi Penjualan Bundling;

CRISP-DM;

Data Mining.

Correspondent Email:

20082010013@student.upnja
tim.ac.id

Abstrak. Penelitian ini bertujuan untuk menghasilkan rekomendasi strategi penjualan bundling yang efektif untuk Cafe SZ Point, sebuah UKM yang berlokasi di Jalan Sambikerep No.25, Sambikerep, Kec. Sambikerep, Surabaya, Jawa Timur. Cafe SZ Point baru memulai usahanya pada 11 Maret 2023. Sebelumnya, kafe ini pernah melakukan promosi bundling yang kurang efektif sehingga mengakibatkan kerugian dan penurunan pendapatan. Hal ini terjadi karena kafe tersebut belum memaksimalkan penggunaan data penjualan dari lunapos untuk mengidentifikasi tren konsumen, pola pembelian, dan preferensi pelanggan. Tanpa pemanfaatan data penjualan yang optimal, strategi pemasaran yang tepat sasaran sulit dirancang.

Penelitian ini menggunakan algoritma Frequent Pattern Growth (FP-Growth) melalui pendekatan metode CRISP-DM (Cross-Industry Standard Process for Data Mining) untuk menganalisis data transaksi dari Cafe SZ Point dan menemukan pola pembelian pelanggan yang sering muncul. Hasil analisis menunjukkan dapat diterapkan untuk menentukan pola pembelian menu dengan membentuk aturan asosiasi yang dapat digunakan untuk strategi penjualan. Rekomendasi strategi bundling yang dihasilkan dari penelitian ini diharapkan dapat membantu Cafe SZ Point dalam meningkatkan performa penjualannya.

Abstract. *This research aims to produce recommendations for an effective bundling sales strategy for Cafe SZ Point, an SME located on Jalan Sambikerep No.25, Sambikerep, Kec. Sambikerep, Surabaya, East Java. Cafe SZ Point just started its business on March 11 2023. Previously, this cafe had carried out bundling promotions that were less effective, resulting in losses and a decrease in income. This happens because the cafe has not maximized the use of sales data from LUNAPOS to identify consumer trends, purchasing patterns and customer preferences. Without optimal use of sales data, targeted marketing strategies are difficult to design.*

This research uses the Frequent Pattern Growth (FP-Growth) algorithm using the CRISP-DM (Cross-Industry Standard Process for Data Mining) method approach to analyze transaction data from Cafe SZ Point and find customer purchasing patterns that frequently appear. The analysis results show that it can be applied to determine menu purchasing patterns by forming association rules that can be used for sales strategies. It is hoped that the bundling strategy recommendations resulting from this research will help Cafe SZ Point improve its sales performance..

1. PENDAHULUAN

Perkembangan teknologi informasi yang pesat telah memberikan dampak signifikan dalam berbagai aspek kehidupan, termasuk dalam pengolahan dan analisis data. Teknologi ini mempermudah manusia untuk memperoleh informasi yang relevan, cepat, jelas, dan akurat [1]. Dalam dunia bisnis, teknologi informasi memungkinkan perusahaan untuk mengoptimalkan strategi penjualannya melalui teknik analisis data seperti data mining, yang membantu dalam pengambilan keputusan yang lebih tepat dan efektif. SZ Point adalah sebuah UKM dalam bentuk kafe yang berlokasi di Surabaya dan baru memulai operasinya pada tahun 2023. Kafe ini menggunakan aplikasi kasir Lunapos untuk mencatat transaksi penjualannya. Namun, kafe ini belum memanfaatkan data penjualan secara optimal untuk mengidentifikasi tren konsumen, pola pembelian, dan preferensi pelanggan. Hal ini menyebabkan kurang tepatnya strategi promosi bundling yang diterapkan, sehingga berdampak negatif pada pendapatan kafe.

Untuk mengatasi masalah ini, metode data mining dengan teknik aturan asosiasi menggunakan algoritma FP-Growth dapat diterapkan. FP-Growth adalah algoritma yang efektif untuk menemukan pola dari data yang banyak dan membantu dalam menentukan strategi pemasaran yang tepat [2]. Penelitian sebelumnya menunjukkan bahwa algoritma ini dapat menghasilkan strategi promosi yang meningkatkan penjualan [3]. Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menghadirkan rekomendasi paket menu promosi yang menarik di kafe SZ Point dengan menggunakan algoritma FP-Growth. Penelitian ini diharapkan dapat membantu kafe SZ Point dalam menghadapi persaingan penjualan, meningkatkan efisiensi operasional, dan pada akhirnya meningkatkan omzet serta kepuasan pelanggan.

Rumusan masalah dalam penelitian ini adalah: Apa saja rekomendasi menu yang dihasilkan oleh algoritma FP-Growth untuk pembuatan paket menu makanan di Cafe SZ Point? Batasan masalah dalam penelitian ini mencakup: (1) Proses pemodelan menggunakan pendekatan data mining dengan algoritma FP-Growth; (2) Data yang dianalisis adalah data transaksi penjualan pelanggan dari periode 9

Maret 2023 hingga 29 Februari 2024 di kafe SZ Point; (3) Proses pengolahan data menggunakan bahasa pemrograman Python; (4) Hasil visualisasi akan ditampilkan dalam bentuk dashboard di aplikasi web. Tujuan penelitian ini adalah mengimplementasikan algoritma FP-Growth pada data penjualan kafe SZ Point untuk meningkatkan strategi penjualan dengan memaksimalkan keuntungan dan mengurangi kerugian.

2. TINJAUAN PUSTAKA

A. *Crisp-Dm*

Metode data mining yang dapat diterapkan pada tahap penelitian ini adalah *Crisp-dm*. *Crisp-dm* (Cross Industry Standard Process for Data Mining) adalah suatu standarisasi pemrosesan data mining yang dirancang agar data yang ada melewati setiap langkah terstruktur dan terdefinisi dengan baik dan efisien [4]. *Crisp-dm* memiliki alur penelitian yang terbagi dalam enam fase, *Business Understanding phase, Data Understanding Phase, Data Preparation Phase, Modeling Phase, Evaluasi Phase, Deployment Phase*.

B. *Python*

Bahasa pemrograman *Python* pertama kali dirancang dan dikembangkan oleh Guido van Rossum pada tahun 1991. *Python* sendiri memiliki *syntax* yang mudah dipahami bahkan memiliki kemiripan dengan bahasa Inggris [5]. Flask merupakan kerangka web yang digunakan oleh Python. Framework Flask diklasifikasikan sebagai micro framework karena tidak memerlukan alat atau library khusus dan memiliki data bawaan [6]. Pemrograman *Python* cocok digunakan dalam bidang data mining.

C. *Association Rules*

Association rules mining adalah sebuah metode yang digunakan untuk menemukan hubungan antar *item* suatu *dataset* yang telah ditentukan. *Association rules mining* mencari dan menemukan hubungan antar kumpulan dataset. Peraturan *asosiasi* adalah teknik data mining menemukan aturan *asosiasi* antar kombinasi item [7]. Proses perhitungan aturan asosiasi dikelompokkan sesuai dengan masing-masing penjualan produk. Hasil aturan asosiasi dari setiap penjualan dapat dibandingkan untuk

melihat kombinasi item-item mana saja yang memiliki penjualan yang sering laku dan tidak laku, sehingga dapat dijadikan sebagai bahan acuan dalam penerapan strategi pemasaran produk sesuai target penjualan yang dicapai [8]. Menurut [9], *Association Rule* memiliki aturan *asosiasi* dengan dua parameter yaitu :

1. Support :

Pada *association rule*, support adalah presentasi gabungan item dalam database. di dalamnya terdapat item A dan B, maka support adalah proporsi dari transaksi dalam database yang mengandung A dan B.

$$Support(A) = \frac{Jumlah\ Transaksi\ mengandung\ A}{Total\ Transaksi}$$

Sedangkan nilai *support* dari 2 item diperoleh dari rumus berikut:

$$Support(A \cap B) = \frac{Jumlah\ Transaksi\ mengandung\ A\ dan\ B}{Total\ Transaksi}$$

2. Confidence :

Confidence mengukur seberapa kuat hubungan antara dua *item* atau *itemset* dalam aturan *asosiasi*. Setelah semua pola frekuensi tinggi ditemukan, barulah dicari aturan *asosiasi* yang memenuhi syarat minimum untuk *confidence* dengan menghitung *confidence* aturan *asosiasi*

$A \rightarrow B$ (Wijaya *et al.*, 2022). Nilai *confidence* dari aturan $A \rightarrow B$ diperoleh dengan rumus berikut:

$$Confidence(A,B) = \frac{Jumlah\ Transaksi\ Mengandung\ A\ dan\ B}{Total\ Transaksi\ Mengandung\ A}$$

D. Lift Ratio

Lift ratio merupakan ukuran untuk mengetahui kekuatan aturan *asosiasi* yang telah dibentuk (*association rule*). Nilai *lift ratio* biasanya digunakan sebagai faktor dalam menentukan valid atau tidak valid [10]. Rule dikatakan kuat jika memiliki nilai *lift ratio* lebih dari 1[11]. Untuk menghitung *lift ratio* digunakan rumus berikut:

$$Lift\ Ratio = \frac{Confidence(A,B)}{Semua\ Transaksi}$$

E. Algoritma FP-Growth

Algoritma *FP-Growth* merupakan pengembangan lebih lanjut dari algoritma *Apriori*. Dengan demikian kekurangan pada algoritma *Apriori* diperbaiki oleh algoritma *FP-Growth*. *Frequent Pattern Growth (FP-Growth)* adalah algoritma alternatif yang dapat digunakan untuk menentukan kumpulan data yang paling sering muncul (*frequent itemset*) dalam kumpulan data. Namun pada algoritma *FP-Growth*, *generate candidate* tidak dilakukan karena *FP-Growth* menggunakan konsep *note tree* dalam pencarian *frequent itemsets* [12]. Bahkan pertumbuhan algoritma *FP-Growth* menjadi lebih cepat dibandingkan algoritma *Apriori* [13]. Menurut [14], algoritma *FP-Growth* dibagi menjadi tiga langkah utama, yaitu :

1. Tahap pembangkitan *Conditional Pattern Base*
2. Tahap pembangkitan *Conditional FP-Tree*
3. Tahap pencarian *frequent itemset*

3. METODE PENELITIAN

Pada bab ini akan berisi penjelasan mengenai alur metode penelitian. Dimana menggunakan CRISP-DM dan untuk keseluruhan rangkaian proses penelitian dapat digambarkan dengan diagram alur berikut ini :



Gambar 1. Diagram Alur Metodologi Penelitian

A. Studi Literatur

Tahapan selanjutnya yaitu studi literatur untuk mendapatkan fakta dari penelitian terdahulu atau literatur terkait permasalahan yang ada. Dan juga mempelajari temuan dari penelitian terdahulu agar dapat dijadikan dasar dan pedoman pada penelitian ini.

B. Business Understanding

Dalam tahap ini, akan mulai belajar mengenai detail dari Kafe SZ Point. Detail terkait bisnis yang berjalan serta tata pengelolaan usaha.

C. Data Understanding

Tahap selanjutnya adalah data understanding. Tahap ini melibatkan eksplorasi bentuk data yang di analisis. Pemahaman mendalam tentang data akan membantu untuk mengidentifikasi perubahan atau ketidaknormalan yang mungkin memengaruhi performa analisis data, sehingga dapat mengetahui seperti apa bentuk data serta anomaly sehingga dapat mengatasi anomaly pada data agar tidak menurunkan kinerja machine learning.

D. Data Preparation

Tahap ini mencakup proses pra-pemrosesan data, seperti pembersihan data, penggabungan data, dan transformasi data agar dapat digunakan pada proses data mining. Secara garis besar, data preparation di kalangan data mining digunakan untuk memperbaiki masalah dalam data, kemudian membuat variabel turunan. Langkah ini menjadi dasar penting untuk meningkatkan kualitas data sebelum diterapkan pada proses data mining. Tahap data preparation membutuhkan pemikiran matang dan usaha tinggi untuk memastikan data sesuai dengan algoritma yang digunakan. Proses ini merupakan data treatment menuju model berkualitas yang berguna. Tahap data preparation bertujuan agar data teks menjadi seragam dan memudahkan pembacaan dalam proses selanjutnya, sehingga lebih mudah diolah dengan menggunakan FP-Growth. Proses ini melibatkan beberapa langkah, yaitu data cleaning, di mana dilakukan pembersihan data dari kesalahan pengisian dan tabel yang tidak diisi; data integration, yang menggabungkan, menyamakan, dan menambah isi data untuk eksplorasi dan pemodelan; exploratory data analysis, untuk mengetahui

nilai pada data dan mendapatkan insight; serta data transformation, yang memanipulasi nilai data sesuai kebutuhan penelitian tanpa mengurangi informasi.

E. Modelling

Tahap ini mencakup pemilihan dan penerapan Teknik data mining untuk menciptakan model atau pola dari data yang telah dipersiapkan sebelumnya. Dengan menggunakan FP-Growth dilakukan tahap ini, algoritma ini sudah di dukung oleh FP-Tree sehingga algoritma ini bisa cepat dan efektif.

F. Evaluasi dan Analisa

Tahap ini melibatkan evaluasi kualitas pola aturan yang telah dihasilkan, serta menentukan apakah aturan tersebut memenuhi nilai batas lift ratio yang telah ditentukan sebelumnya. Setelah didapatkan sebuah atau beberapa aturan. Aturan ini akan diwujudkan dalam bentuk bundling makanan.

4. HASIL DAN PEMBAHASAN

A. Business Understanding

Business understanding dilakukan melalui observasi dan wawancara, dengan hasil wawancara terlampir di Lampiran 1 yang menggambarkan kondisi Cafe SZ Point. Observasi menunjukkan bahwa cafe belum memaksimalkan data penjualan dengan baik. Saat ini, menu yang ada hanya tersedia secara satuan, dan promosi bundling yang pernah dilakukan tidak tepat sasaran sehingga menyebabkan penurunan pendapatan. Cafe SZ Point belum memanfaatkan data penjualan dari Lunapos secara optimal dan kesulitan mengidentifikasi tren konsumen, pola pembelian, serta preferensi pelanggan. Dengan memanfaatkan algoritma Frequent Pattern Growth (FP-Growth), diharapkan dapat ditemukan pola pembelian dan preferensi pelanggan yang memungkinkan perancangan strategi bundling yang lebih efektif. Strategi bundling yang tepat berdasarkan analisis data diharapkan dapat meningkatkan penjualan dan pendapatan, mengurangi produk terbuang, serta meningkatkan kepuasan pelanggan dengan menawarkan kombinasi menu yang lebih sesuai dengan preferensi mereka.

B. Data Understanding

Data understanding dilakukan dengan mengumpulkan data penjualan dari Cafe SZ Point yang terdiri dari 3000 data dengan 15 kolom. Data ini mencakup informasi seperti tanggal transaksi, nomor transaksi, lokasi kafe, nomor referensi, identitas pelanggan, produk yang dibeli, kuantitas, subtotal, pajak, biaya layanan, total, jumlah dibayarkan, tanggal pembayaran terakhir, sisa tagihan, dan status pembayaran.

C. Data Preparation

Data preparation melibatkan serangkaian langkah untuk menyesuaikan data dengan kebutuhan pemodelan, mengatasi ketidaksesuaian antara data yang ada dan proses pemodelan. Langkah-langkah ini mencakup data cleaning, yang memastikan kecocokan data dengan mengecek tipe data setiap kolom dan memastikan tidak ada data yang kosong. Data integration dilakukan dengan menggabungkan, menyamakan, dan menambah isi data untuk eksplorasi dan pemodelan. Exploratory data analysis dilakukan untuk mengetahui nilai pada data dan mendapatkan insight. Data transformation dilakukan sebagai proses pra-modeling untuk mengatur data sesuai kebutuhan penelitian, menggunakan teknik one-hot encoding untuk mengubah data menjadi bentuk boolean.

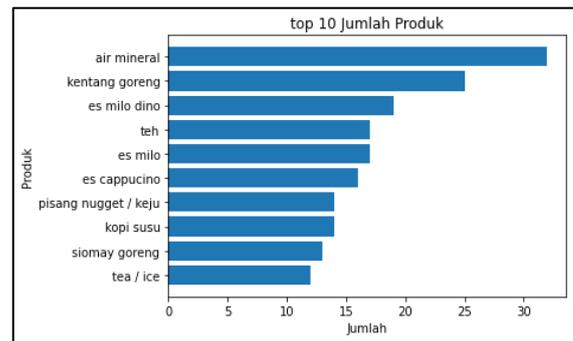
```
data.info()

<class 'pandas.core.frame.DataFrame'>
Int64Index: 3000 entries, 0 to 2999
Data columns (total 15 columns):
#   Column                Non-Null Count  Dtype
---  ---                ---
0   Tanggal                3000 non-null   object
1   No Transaksi           3000 non-null   float64
2   Outlet                 3000 non-null   object
3   Nomor Ref              3000 non-null   object
4   Pelanggan              3000 non-null   object
5   Produk                 3000 non-null   object
6   Qty                    3000 non-null   int64
7   Subtotal               3000 non-null   float64
8   Pajak                  3000 non-null   float64
9   Service Charge         3000 non-null   float64
10  Total                  3000 non-null   int64
11  Dibayar                 3000 non-null   int64
12  Tgl Terakhir dibayar   3000 non-null   object
13  Sisa Tagihan            3000 non-null   int64
14  Status                  3000 non-null   object
dtypes: float64(4), int64(4), object(7)
memory usage: 375.0+ KB
```

Gambar 2. Data Penjualan cafe SZ Point

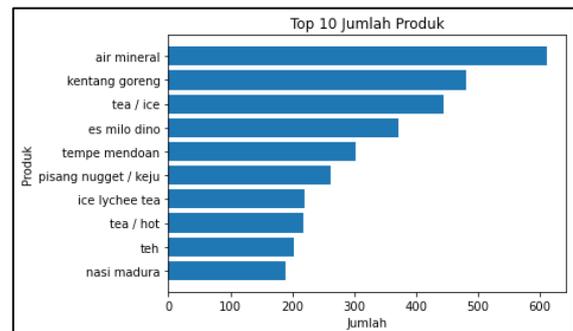
D. Data Exploratory

Selama tahap eksplorasi data, insight diperoleh dan ditampilkan dalam bentuk visualisasi teks maupun grafik.



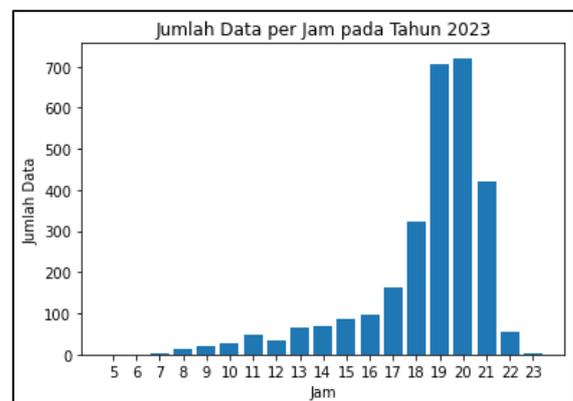
Gambar 3. Grafik menampilkan menu yang paling laku di waktu 3 bulan

Grafik menampilkan menu yang paling laku selama tiga bulan menunjukkan bahwa air mineral adalah menu minuman yang paling banyak dipesan.



Gambar 4. Grafik menu yang paling laku di semua transaksi

sedangkan kentang goreng adalah menu makanan yang sering dipesan di semua transaksi.



Gambar 5. Grafik jam pengunjung

Pola kunjungan per jam di tahun 2023 dan 2024 menunjukkan peningkatan jumlah pengunjung pada jam-jam tertentu, yang membantu pengelola mengidentifikasi waktu-

waktu sibuk untuk menyesuaikan strategi operasional.

E. Data Transformation

Pada tahap *data transformation*, data diubah menggunakan kelas Transaction Encoder dengan teknik one-hot encoding untuk mengubah data menjadi bentuk boolean, di mana nilai true menunjukkan item atau menu terdapat pada transaksi, sedangkan nilai false menunjukkan sebaliknya. Hasil transformasi data ditampilkan dalam tabel dengan mayoritas hasilnya bernilai false karena variasi pembelian yang sedikit.

Gambar 6. Contoh hasil transformasi data

F. Modeling

Tahap *modeling* melibatkan pencarian frequent itemsets pada data yang telah mengalami transformasi. Proses ini menggunakan minimal support sebesar 0.01 untuk menyaring menu yang sering dibeli. Hasil dari frequent itemsets menunjukkan 103 data yang memenuhi kriteria tersebut.

Tabel 1. Hasil Frequent Itemsets

	Support	itemsets
52	0.197667	(air mineral)
4	0.158333	(kentang goreng)
26	0.137000	(tea / ice)
2	0.122000	(es milo dino)
15	0.099000	(tempe mendoan)

G. Evaluation Dan analisa

Pada tahap *evaluation*, metode association rules digunakan untuk membentuk aturan asosiasi dari frequent itemsets yang sudah didapatkan. Nilai threshold minimal diterapkan untuk membatasi hasil analisis

berdasarkan parameter seperti support, confidence, dan lift. Hasil pembentukan aturan asosiasi terdiri dari antecedents, yang merupakan menu pemicu, dan consequents, yang merupakan menu yang mungkin muncul bersama antecedents. Tiga metrik utama yang digunakan adalah support, confidence, dan lift ratio. Nilai support mengindikasikan seberapa sering kombinasi menu muncul, sementara confidence menunjukkan seberapa besar consequents muncul bersamaan dengan antecedents.

Tabel 2. Hasil Aturan Asosiasi

No	antecedents	Consequents	support	confidence	lift
1	(es milo dino, tempe mendoan)	(kentang goreng)	0.011333	0.507463	3.205027
2	(ayam geprek)	(tea / ice)	0.012667	0.447059	3.263203
3	(ice cream / vanilla)	(chocolate waffle / cheesy biscuit (oreo/regal))	0.010000	0.428571	15.126050
4	(tempe mendoan, kentang goreng)	(es milo dino)	0.011333	0.409639	3.357693
5	(ayam kremes)	(tea / ice)	0.014667	0.403670	2.946494

Untuk mengukur seberapa besar hubungan antar produk ((antecedents dan cosequents) digunakan metrik lift. Dimana nilai lift lebih besar dari 3 maka hubungan antar produk tersebut dianggap kuat atau cenderung lebih sering muncul.

Terdapat 6 aturan asosiasi yang memiliki nilai lift lebih dari 3 dan nilai confidence lebih dari 0.3 lebih dari satu yang artinya keterkaitan antar produk tersebut kuat diantara yang lain. Hal ini juga dapat diartikan bahwa konsumen lebih sering membeli kombinasi produk seperti yang ada pada Tabel 4.2. Aturan yang Paling kuat dengan nilai lift 15.126050 adalah ice cream/vanila sebagai antecedents dan (chocolate waffle / cheesy biscuit (oreo/regal) sebagai consequents.

Gambar 7. Hasil Aturan Asosiasi (lift >3)

No	antecedents	Consequents	support	confidence	lift
1	(ice cream / vanilla)	(chocolate waffle / cheesy biscuit (oreo/regal))	0.010000	0.428571	15.126050
2	(chocolate waffle / cheesy biscuit (oreo/regal))	(ice cream / vanilla)	0.010000	0.352941	15.126050
3	(tempe mendoan, kentang goreng)	(es milo dino)	0.011333	0.409639	3.357693
4	(ayam geprek)	(tea / ice)	0.012667	0.447059	3.263203
5	(es milo dino, tempe mendoan)	(kentang goreng)	0.011333	0.507463	3.205027
6	(es milo dino, kentang goreng)	(tempe mendoan)	0.011333	0.314815	3.179948

5. KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan yang ada, maka dapat ditarik kesimpulan bahwa pengguna algoritma fp-growth dapat diterapkan untuk menentukan pola pembelian menu dengan membentuk aturan asosiasi yang dapat digunakan untuk strategi penjualan. Pada proses pencarian frequent itemsets ditemukan 126 item yang memenuhi minimal support sebesar 0.01 dengan nilai support paling tinggi sebesar 0.197 pada menu air mineral, 0.158 pada menu kentang goreng, 0.137 pada menu tea/ice, 0.122 pada menu es milo dino, dan seterusnya. Pada proses pembentukan aturan asosiasi terdapat 104 rules atau aturan yang berisi antecedents, consequents, support, confidence dan lift. Parameter antecedent sebagai pemicu menu lain muncul, consequent sebagai menu yang muncul secara bersamaan dengan antecedents, support menunjukkan nilai seberapa sering aturan tersebut muncul, confidence menunjukkan nilai seberapa sering consequent muncul secara bersamaan dengan antecedents dan lift menunjukkan nilai seberapa kuat aturan tersebut.

Dari aturan asosiasi akhir dapat dijadikan sebagai strategi penjualan berupa rekomendasi menu contohnya apabila konsumen ingin membeli menu minuman Es Milo Dino dapat diberikan saran memilih menu makanan kentang Goreng karna menu tersebut yang paling banyak di beli. Contoh kedua, apabila konsumen ingin membeli menu makanan Ayam Kremes dapat diberikan saran memilih menu minuman ringan Tea / Ice.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

[1] L. Yana Siregar, M. Irwan Padli Nasution Prodi Manajemen, and U. Negeri Islam Sumatera Utara, "HIRARKI Jurnal Ilmiah Manajemen dan Bisnis Development Of Information Technology On Increasing Business Online,"

Vol. 2, No. 1, Pp. 71–75, 2020, Doi: 10.30606/Hjimb.

- [2] R. Amelia And D. P. Utomo, "Analisa Pola Pemesanan Produk Modern Trade Independent Dengan Menerepakan Algoritma Fp. Growth (Studi Kasus: Pt. Adam Dani Lestari)," *Komik (Konferensi Nasional Teknologi Informasi Dan Komputer)*, Vol. 3, No. 1, Nov. 2019, Doi: 10.30865/Komik.V3i1.1622.
- [3] A. T. Suseno, A. R. Naufal, And M. Al Amin, "Market Based Analysis Sebagai Peningkatan Penjualan Produk Menggunakan Algoritma K-Medoids Dan Fp-Growth," *Jurnal Teknik Informasi Dan Komputer (Teknikom)*, Vol. 5, No. 2, P. 301, Dec. 2022, Doi: 10.37600/Teknikom.V5i2.646.
- [4] M. A. Hasanah, S. Soim, And A. S. Handayani, "Implementasi Crisp-Dm Model Menggunakan Metode Decision Tree Dengan Algoritma Cart Untuk Prediksi Curah Hujan Berpotensi Banjir," 2021. [Online]. Available: [Http://jurnal.Polibatam.Ac.Id/Index.Php/Jaic](http://jurnal.polibatam.ac.id/index.php/jaic)
- [5] V. Rama Vyshnavi And A. Malik, "Efficient Way Of Web Development Using Python And Flask," 2019.
- [6] P. Banerjee, B. Kumar, A. Singh, R. Kumar, And R. Kumar, "Implementation Of Database Using Python Flask Framework," *International Journal Of Engineering And Computer Science*, Vol. 8, No. 12, Pp. 24890–24893, Dec. 2019, Doi: 10.18535/Ijecs/V8i12.4399.
- [7] N. Rohman Ardani And N. Fitriana, "Seminar Nasional Teknologi Informasi Dan Multimedia 2016," 2016.
- [8] U. Baetulloh And A. I. Gufroni, "Penerapan Metode Association Rule Mining Pada Data Transaksi Penjualan Produk Kartu Perdana Kuota Internet Menggunakan Algoritma Apriori," *Jurnal Simetris*, Vol. 10, No. 1, 2019.
- [9] S. Parsaoran Tamba, "Penerapan Data Mining Algoritma Apriori Dalam Menentukan Stok Bahan Baku Pada Restoran Nelayan Menggunakan Metode Association Rule," 2022.
- [10] M. Fauzy, K. W. Rahmat Saleh, I. Asror, J. Telekomunikasi No, And T. Buah Batu Bandung, "Penerapan Metode Association Rule Menggunakan Algoritma Apriori Pada Simulasi Prediksi Hujan Wilayah Kota Bandung," 2016.
- [11] P. S. Strategi, P. Barang, D. Promo, V. N. Latifah, M. T. Furqon, And N. Santoso, "Implementasi Algoritme Modified-Apriori Untuk Menentukan Pola," 2018. [Online]. Available: [Http://J-Ptiik.Ub.Ac.Id](http://j-ptiik.ub.ac.id)
- [12] N. Harahap, "Teknik Data Mining Untuk Penentuan Paket Hemat Sembako Dan Kebutuhan Harian Dengan Menggunakan

Algoritma Fp-Growth (Studi Kasus Di Ulfamart Lubuk Alung),” 2019.

- [13] A. Ardianto And D. Fitriyah, “Penerapan Algoritma Fp-Growth Rekomendasi Trend Penjualan Atk Pada Cv. Fajar Sukses Abadi,” *Jurnal Telekomunikasi Dan Komputer*, Vol. 9, No. 1, P. 49, Apr. 2019, Doi: 10.22441/Incomtech.V9i1.3263.
- [14] Henando, “Jurnal J-Click Algoritma Apriori Dan Fp-Growth Untuk Analisa Perbandingan Data Penjualan Leptop Berdasarkan Merk Yang Diminati Konsumen (Studi Kasus : Indocomputer Payakumbuh),” 2019.