

Analisis Pola Pembelian Pelanggan Menggunakan Algoritma Apriori Pada Transaksi Belanja Supermarket

Syaelan Raka Pramuja Ananda^{1*}, Latief Prayoga Yudhi Putra², Alberthino Ramadhan Oktaviano³, Andita Titi Sulanjari⁴, Azzah Nur Farida⁵, Aprilisa Arum Sari⁶

¹Teknik Informatika/Illmu komputer
Universitas Duta Bangsa Surakarta
^{1*}220103190@mhs.udb.ac.id

²Teknik Informatika/Illmu komputer
Universitas Duta Bangsa Surakarta
² 220103180@mhs.udb.ac.id

³ Teknik Informatika/Illmu komputer
Universitas Duta Bangsa Surakarta
³ 220103172@mhs.udb.ac.id

⁴ Teknik Informatika/Illmu komputer
Universitas Duta Bangsa Surakarta
⁴220103174@mhs.udb.ac.id

⁵ Teknik Informatika/Illmu komputer
Universitas Duta Bangsa Surakarta
⁵220103004@mhs.udb.ac.id

⁶Ilmu komputer
Universitas Duta Bangsa Surakarta
⁶ aprilisa_arumsari@udb.ac.id

Abstrak— Penelitian ini bertujuan menganalisis pola asosiasi produk pada transaksi supermarket menggunakan algoritma Apriori. Dataset publik dari Kaggle (350 transaksi, 9 item) diolah melalui tahap data cleaning dan transformasi one-hot encoding. Dengan parameter minimum support 0.4 dan minimum confidence 0.5, hasil menunjukkan kombinasi Telur-Minyak-Tepung sebagai frequent itemset dominan (support 48.57%). Aturan asosiasi terkuat teridentifikasi pada relasi {Telur, Minyak} → {Tepung} dengan confidence 84.58% dan lift ratio 1.24, mengindikasikan peningkatan probabilitas pembelian Tepung sebesar 24% ketika Telur dan Minyak dibeli bersamaan. Temuan ini merekomendasikan strategi penempatan produk berdekatan, bundling promosi, dan alokasi stok sinergis. Penelitian membuktikan efektivitas Apriori dalam identifikasi pola pembelian, meski terbatas pada hubungan linear antar item. Implementasi hasil dapat menjadi dasar pengambilan keputusan strategis di sektor ritel berbasis data.

Kata kunci— Market Basket Analysis, Apriori algorithm, association rules, support, confidence, lift ratio.

Abstract— This study aims to analyze product association patterns in supermarket transactions using the Apriori algorithm. A public Kaggle dataset (350 transactions, 9 items) was processed through data cleaning and one-hot encoding transformation. With a minimum support of 0.4 and minimum confidence of 0.5, results identified Eggs-Cooking Oil-Flour as the dominant frequent itemset (support 48.57%). The strongest association rule was {Eggs, Cooking Oil} → {Flour} with 84.58% confidence and 1.24 lift ratio, indicating a 24% increase in Flour purchase probability when Eggs and Cooking Oil are bought together. These findings recommend strategic product placement, promotional bundling, and synergistic stock allocation. The study proves Apriori's effectiveness in identifying purchase patterns, though limited to linear item relationships. Implementation can serve as a data-driven foundation for strategic retail decision-making.

Keywords— Market Basket Analysis, Apriori algorithm, association rules, support, confidence, lift ratio.

I. PENDAHULUAN

Di era persaingan bisnis yang semakin ketat, pemahaman mendalam tentang perilaku konsumen menjadi kunci penting dalam pengambilan keputusan strategis, khususnya di sektor ritel. Market Basket Analysis (MBA) muncul sebagai pendekatan kritis yang memungkinkan pelaku bisnis mengidentifikasi hubungan antar produk yang sering dibeli bersamaan oleh konsumen. Analisis ini tidak hanya membantu dalam penyusunan strategi penempatan produk (product placement) dan bundling, tetapi juga dalam manajemen inventori dan personalisasi promosi. Namun,

kompleksitas pola pembelian yang melibatkan ribuan transaksi dan variasi produk menghadirkan tantangan signifikan jika dianalisis secara konvensional.

Dalam konteks inilah teknik data mining, khususnya Association Rule Mining (ARM), menawarkan solusi sistematis melalui kemampuan menyaring pola tersembunyi dari dataset besar. Algoritma Apriori, sebagai salah satu metode ARM paling populer, memungkinkan ekstraksi aturan asosiasi berdasarkan frekuensi kemunculan item (support), probabilitas keterkaitan (confidence), dan kekuatan hubungan (lift

ratio). Implementasinya telah terbukti efektif dalam berbagai studi, seperti identifikasi pola pembelian produk alat tulis kantor [1] hingga analisis gejala penyakit [2].

II. METODOLOGI PENELITIAN



Gambar 1. Tahap penelitian

berdasarkan gambar diatas kami menggunakan metode waterfall, metode waterfall adalah model pengembangan proyek yang bersifat berurutan, di mana kemajuan dilihat secara bertahap melewati serangkaian fase [3]. Dalam konteks analisis atau penelitian, pendekatan ini mengharuskan setiap tahapan diselesaikan terlebih dahulu sebelum memulai tahapan selanjutnya. Proses diawali dengan fase perumusan masalah yang harus didefinisikan secara jelas. Barulah dapat melanjutkan ke tahap persiapan data yang meliputi pencarian sumber data, kemudian persiapan data yang meliputi data cleaning, normalisasi data, dan transformasi data. Ketika data telah siap, proses berlanjut ke pengolahan data. Temuan dari pengolahan tersebut kemudian dianalisis dalam tahap hasil & pembahasan, dan pada tahap terakhir adalah penarikan kesimpulan sebagai tahap akhir.

A. Sumber data

Pengambilan data dalam penelitian ini dilakukan dengan menggunakan dataset publik yang diakses melalui platform Kaggle

(www.kaggle.com/datasets/alanhevnoraak/dataset-dummy-transaksi-belanja-supermarket)

Dataset yang digunakan terdiri dari 350 record transaksi belanja supermarket dengan struktur 3 field utama. Dataset ini merepresentasikan perilaku pembelian konsumen dalam periode tertentu, menyediakan basis data untuk analisis pola asosiasi antar produk. Proses akuisisi data mengikuti protokol etika penelitian data sekunder, menjamin anonymitas melalui penghilangan informasi identitas pribadi, Mematuhi kebijakan penggunaan data sumber (*Kaggle Dataset Usage Policy*)

B. Persiapan Data

Sebelum diproses lebih lanjut dilakukan persiapan data, persiapan data dilakukan melalui tiga tahap untuk memastikan kesiapan dataset terhadap analisis asosiasi, yaitu Data cleaning, Normalisasi data, dan transformasi format

1. Data cleaning adalah tahap persiapan data di mana sebuah kumpulan data dibersihkan. Proses ini mencakup identifikasi dan penanganan data yang tidak lengkap (nilai yang hilang), tidak akurat (kesalahan ketik), tidak konsisten (format yang berbeda), dan duplikat [4]. Tujuan utamanya adalah untuk mengubah data mentah yang berantakan menjadi dataset yang bersih dan berkualitas, sehingga siap digunakan untuk analisis, pemodelan, atau visualisasi data yang akurat.
2. Transformasi data adalah proses penting dalam Data Mining untuk mengubah atau menggabungkan data ke format yang kompatibel [5]. Hal ini diperlukan karena metode standar seperti analisis asosiasi dan clustering membutuhkan input berupa data kategorikal, sehingga data numerik harus dikelompokkan ke dalam interval.

C. Asosiasi menggunakan algoritma apriori

Algoritma apriori termasuk salah satu algoritma yang dapat diterapkan dalam analisis

pemasaran, dengan tujuan menemukan setiap aturan asosiasi yang telah memenuhi batas minimum support dan confidence. Setiap aturan yang terbentuk diperoleh melalui penggunaan parameter tertentu, sehingga aturan yang dihasilkan mampu memberikan nilai prediksi yang lebih akurat [6]. Algoritma Apriori termasuk dalam kategori teknik association rule dalam ilmu data mining. Teknik ini digunakan untuk mengidentifikasi hubungan atau keterkaitan antar atribut dalam suatu data, yang sering disebut dengan market basket analysis. Association rule mining sendiri merupakan metode dalam data mining yang bertujuan untuk menemukan pola atau aturan dari kombinasi item atau juga bisa disebut *frequent itemsets* yang sering muncul secara bersamaan [1].

Association rules mining merupakan metode yang digunakan untuk mengidentifikasi hubungan antar item dalam suatu dataset yang telah ditentukan sebelumnya. Teknik ini bertujuan untuk mencari dan menemukan keterkaitan antar item yang terdapat dalam data. Penerapan data mining dengan pendekatan aturan asosiasi dimaksudkan untuk menggali informasi mengenai item-item yang memiliki keterhubungan, yang kemudian dinyatakan dalam bentuk aturan atau rules. Aturan asosiasi sendiri merupakan salah satu teknik dalam data mining yang digunakan untuk menemukan keterkaitan antar kombinasi item dalam dataset [7]. Dalam association rule, dikenal istilah antecedent dan consequent, di mana antecedent merujuk pada item A, sedangkan consequent mengacu pada item B [8]. Sebagai contoh penerapan aturan asosiasi dalam analisis perilaku belanja konsumen di sebuah supermarket, apabila seseorang membeli roti, maka ada kemungkinan besar orang tersebut juga akan membeli susu. evaluasi terhadap kualitas aturan asosiasi dilakukan melalui perhitungan nilai support, confidence, dan lift ratio. Bagian berikut akan menjabarkan rumus dari ketiga parameter yang menjadi tolak ukur

dalam Association Rule Market Basket Analysis (AR MBA) ini."

1. Support

Support menunjukkan seberapa sering suatu kombinasi item (A dan B) muncul secara bersamaan dalam seluruh dataset transaksi. Nilai support digunakan untuk mengidentifikasi pola-pola yang memiliki signifikansi statistik dalam data [9]. Rumusnya adalah sebagai berikut:

$$support = P(X \cap Y) = \frac{\sum \text{Transaksi yang mengandung } X \text{ dan } Y}{\text{Jumlah transaksi}}$$

Semakin tinggi nilai support, maka semakin sering kombinasi item tersebut terjadi, sehingga dianggap lebih relevan dan potensial untuk dianalisis lebih lanjut.

2. Confidence

Confidence mengukur tingkat kepercayaan atau kekuatan dari aturan asosiasi. Confidence merepresentasikan seberapa besar kemungkinan item B muncul dalam transaksi yang sudah mengandung item A [10]. Rumusnya adalah:

$$Confidence = P(Y/X) = \frac{P(X \cap Y)}{\sum \text{Transaksi yang mengandung } X}$$

confidence menggambarkan probabilitas kemunculan item B, dengan syarat item A telah terjadi sebelumnya. Semakin tinggi nilai confidence, maka aturan asosiasi tersebut dianggap semakin dapat diandalkan.

3. Lift Ratio

Lift Ratio merupakan metrik yang digunakan untuk menilai kekuatan hubungan antara dua item dengan mempertimbangkan kemungkinan kemunculan item B secara independen. Lift mengukur sejauh mana kemunculan item B dipengaruhi oleh adanya item A dalam satu transaksi [2]. Rumusnya adalah:

$$\text{Lift Ratio} = \frac{\text{Support}(X \cap Y)}{\text{Support}(X) \cdot \text{Support}(Y)}$$

Interpretasi nilai lift adalah sebagai berikut:

- Lift = 1 → Tidak ada hubungan antara A dan B (independen)
- Lift > 1 → Hubungan positif antara A dan B (A meningkatkan kemungkinan B)
- Lift < 1 → Hubungan negatif antara A dan B (A menurunkan kemungkinan B)

Nilai lift yang tinggi menunjukkan bahwa kehadiran item A secara signifikan meningkatkan kemungkinan munculnya item B, sehingga aturan tersebut layak untuk dijadikan rekomendasi atau strategi pemasaran.

Association Rule Mining mengeksplorasi dan memahami hubungan antar item dalam data transaksi. Dengan menggunakan metrik support, confidence, dan lift ide, peneliti data dapat menyaring aturan-aturan yang benar-benar signifikan dan bermanfaat dalam konteks bisnis atau sistem rekomendasi. Pemahaman yang baik terhadap konsep ini menjadi landasan penting dalam pengembangan sistem berbasis data yang mampu memberikan nilai tambah secara strategis.

III. HASIL DAN PEMBAHASAN

A. Dataset

Data yang digunakan berasal dari sumber publik yang diunduh melalui platform kaggle. Jumlah total data mencapai sekitar 1.784 entri, yang terdiri dari 4 kolom yaitu Customer_id, Ide_transaksi, tanggal, dan item. Sementara itu, jumlah item yang tercatat sebanyak 9 jenis, yaitu Telur, Deterjen, Minyak, Kecap, Susu, Snack, Permen, Tepung, dan Sabun. Seluruh data tersebut mencakup sebanyak 350 transaksi.

Tabel 1. Dataset

Ide urut	Customer ID	Ide Transaksi	Tanggal	Items
----------	-------------	---------------	---------	-------

1	10253	548252	14-06-17	Telur, Minyak, Permen, Tepung
2	10104	548253	25-12-17	Deterjen, Kecap, Susu, Sabun
3	10271	548530	10-12-17	Telur, Minyak, Kecap, Snack, Permen, Tepung
4	10257	548436	21-05-18	Deterjen, Kecap, Sabun
.....
.....
.....
348	10186	548367	11-05-18	Telur, Kecap, Sabun, Snack, Permen
349	10242	548218	05-08-17	Telur, Minyak, Tepung
350	10167	548469	21-11-18	Telur, Minyak, Sabun, Snack, Tepung

B. Data cleaning

Data kemudian melalui tahap pembersihan (data cleaning), tahapan ini mencakup identifikasi dan penanganan terhadap berbagai permasalahan data seperti nilai yang hilang (missing values), kesalahan penulisan atau data yang tidak akurat (typos), ketidakkonsistenan format atau isi antar data, serta data duplikat yang dapat mempengaruhi keakuratan analisis. Selain itu, kolom atau field yang dianggap tidak relevan atau tidak diperlukan untuk analisis juga dihapus. Berikut adalah data yang sudah melewati pembersihan data.

Tabel 2. Hasil data cleaning

Items
['Telur', 'Minyak', 'Permen', 'Tepung']
['Deterjen', 'Kecap', 'Susu', 'Sabun']
['Telur', 'Minyak', 'Kecap', 'Snack', 'Permen', 'Tepung']
['Deterjen', 'Kecap', 'Sabun']
['Telur', 'Minyak', 'Kecap', 'Snack', 'Permen', 'Tepung']
['Telur', 'Deterjen', 'Minyak', 'Sabun', 'Snack', 'Permen', 'Tepung']
['Telur', 'Deterjen', 'Minyak', 'Snack', 'Permen', 'Tepung']
['Telur', 'Kecap', 'Sabun', 'Snack', 'Permen']
['Telur', 'Minyak', 'Kecap', 'Susu', 'Snack', 'Permen', 'Tepung']
['Telur', 'Deterjen', 'Minyak', 'Kecap', 'Susu', 'Tepung']

['Deterjen', 'Kecap', 'Susu', 'Sabun', 'Snack']
['Deterjen', 'Minyak', 'Susu', 'Permen']
['Telur', 'Minyak', 'Kecap', 'Susu', 'Snack', 'Tepung']
['Telur', 'Minyak', 'Sabun', 'Snack', 'Permen']
['Telur', 'Minyak', 'Kecap']
['Telur', 'Deterjen', 'Minyak', 'Kecap', 'Susu', 'Sabun', 'Snack', 'Permen', 'Tepung']
['Telur', 'Minyak', 'Kecap', 'Susu', 'Sabun', 'Permen', 'Tepung']
['Deterjen', 'Snack', 'Tepung']
['Telur', 'Minyak', 'Susu', 'Sabun', 'Permen', 'Tepung']
.....
.....

1	1	0	0	1	0	0	0	0
0	1	1	1	0	1	0	1	1
1	0	1	1	1	1	0	1	1
1	0	1	1	0	1	0	1	1
0	1	0	1	1	1	0	1	0
0	1	1	1	0	1	1	1	1
1	1	1	0	0	0	1	1	1
1	1	0	0	1	1	1	0	0
1	0	1	1	0	0	1	0	0
0	1	1	0	0	1	1	1	1
0	0	1	1	1	1	0	1	0
0	0	1	0	1	1	0	1	1
0	1	1	0	0	0	0	1	0
1	1	1	1	1	1	1	1	1
0	1	1	1	1	0	1	1	1
1	0	0	0	0	1	0	0	1
.....

Tabel ini mempresentasikan data transaksi yang telah melalui proses pembersihan (data cleaning). Setiap baris direpresentasikan sebagai *array* yang berisi daftar item dalam satu transaksi, dan format ini menghilangkan informasi yang tidak penting misal Customer IDE, nomor transaksi, dan tanggal, sehingga memfokuskan analisis hanya pada pola kombinasi produk yang dibeli bersamaan. Proses data cleaning telah menstandarisasi penulisan nama produk, menghapus transaksi duplikat, dan mengatasi missing values. Hasilnya adalah kumpulan data yang seragam di mana setiap item memiliki representasi identik di seluruh transaksi.

C. Transformasi data

Transformasi format kami menggunakan metode *One-Hot-Encoding*, *One-Hot-Encoding* adalah salah satu teknik transformasi format yang paling umum digunakan dalam persiapan data untuk *machine learning*. Tujuannya adalah untuk mengubah variabel kategorikal (data yang berupa label atau nama, bukan angka) menjadi bentuk numerik [11]. Hal ini penting karena sebagian besar algoritma *machine learning* tidak dapat bekerja langsung dengan data teks, melainkan membutuhkan masukan berupa angka. Dengan *One-Hot-Encoding*, setiap nilai unik dalam satu kolom kategori diubah menjadi kolom baru yang hanya berisi angka 0 atau 1. Berikut adalah data yang sudah di transformasi menjadi angka biner.

Tabel 3. Hasil data transformasi

Deterje n	Keca p	Min yak	Perm en	Sab un	Snac k	Sus u	Tel ur	Tep ung
0	0	1	1	0	0	0	1	1
1	1	0	0	1	0	1	0	0
0	1	1	1	0	1	0	1	1

Tabel ini memperlihatkan data transaksi yang telah melalui proses *One-Hot Encoding*, sebuah teknik transformasi data kategorikal menjadi format numerik biner. Setiap kolom pada tabel mewakili satu jenis produk (seperti Deterjen, Kecap, Minyak, dll.), sedangkan setiap baris menggambarkan satu transaksi pembelian. Aturan pengkodean: angka 1 menandakan produk dibeli sedangkan angka 0 mengindikasikan produk tidak dibeli. Contoh pada baris pertama nilai 1 untuk Minyak, Permen, Telur, dan Tepung berarti keempat produk tersebut dibeli oleh pelanggan sementara 0 pada kolom lain seperti Deterjen, Kecap, susu menunjukkan produk tersebut tidak dibeli oleh pelanggan.

D. Menerapkan algoritma Apriori

Pada tahap ini, dilakukan proses pencarian *frequent itemsets* atau kombinasi item yang sering muncul bersama dalam transaksi. Parameter minimum support ditentukan sebesar 0.4 atau 40%, yang berarti hanya kombinasi item yang muncul setidaknya dalam 40% dari total transaksi yang akan dianggap sebagai *frequent itemsets*. Nilai support menggambarkan seberapa sering suatu kombinasi item muncul di keseluruhan data transaksi. Dengan kata lain, langkah ini bertujuan untuk menyaring item atau kombinasi item yang memiliki tingkat kemunculan yang signifikan dan layak dianalisis lebih lanjut. Berikut hasil dari penerapan algoritma apriori.

Tabel 4. Hasil penerapan algoritma apriori

Frequent Itemsets Support	(Item yang sering muncul bersama) Itemsets
0.468571	Deterjen
0.520000	Kecap
0.662857	Minyak
0.502857	Permen
0.494286	Sabun
0.508571	Snack
0.462857	Susu
0.728571	Telur
0.680000	Tepung
0.574286	Telur, Minyak
0.525714	Minyak, Tepung
0.565714	Telur, Tepung
0.485714	Telur, Minyak, Tepung

Tabel ini menampilkan hasil penerapan algoritma Apriori berupa *frequent itemsets* atau kombinasi item yang sering muncul bersama beserta nilai support-nya. Nilai support yaitu merepresentasikan persentase kemunculan suatu itemset dalam seluruh transaksi. Dari analisis, ditemukan bahwa Itemset tunggal dominan adalah Telur dengan support 72.86% dan Tepung dengan support sebesar 68.00%, Itemset ganda terkuat adalah {Telur, Minyak} dengan support 57.43%, Itemset triplet teratas adalah {Telur, Minyak, Tepung} dengan support 48.57%. Rata-rata nilai support frequent itemsets dalam tabel ini adalah 55.22%, yang mengindikasikan signifikansi pola pembelian berulang.

E. Pembentukan Aturan Asosiasi (Association Rules)

Langkah selanjutnya adalah membentuk aturan asosiasi berdasarkan kombinasi item tersebut. Dalam penelitian ini, digunakan ambang batas minimum confidence sebesar 0.5 (50%), yang berarti aturan yang dihasilkan harus memiliki kepercayaan minimal 50% atau dengan kata lain, jika suatu item (antecedent) dibeli, maka ada kemungkinan minimal 50% bahwa item lain (consequent) juga akan dibeli. Selain confidence, juga diperhitungkan nilai lift yang mengukur kekuatan hubungan antar item. Aturan dengan nilai lift lebih besar dari 1 menunjukkan adanya korelasi positif antara antecedent dan consequent. Hasil dari langkah ini berupa sekumpulan aturan asosiasi yang menggambarkan pola hubungan antar item

dalam transaksi pelanggan, dan sangat bermanfaat sebagai dasar pengambilan keputusan dalam strategi pemasaran atau pengelolaan persediaan barang. Berikut adalah hasil aturan yang didapat.

Tabel 5. Hasil aturan (*Association Rules*)

Antecedents	Consequents	Support	Confidence	Lift
Telur	Minyak	0.574286	0.788235	1.189148
Minyak	Telur	0.574286	0.866379	1.189148
Minyak	Tepung	0.525714	0.793103	1.166329
Tepung	Minyak	0.525714	0.773109	1.166329
Telur	Tepung	0.565714	0.776471	1.141869
Telur, Minyak	Tepung	0.485714	0.845771	1.243781
Telur, Tepung	Minyak	0.485714	0.858586	1.295280
Minyak, Tepung	Telur	0.485714	0.923913	1.268116
Telur	Minyak, Tepung	0.485714	0.666667	1.268116
Minyak	Telur, Tepung	0.485714	0.732759	1.295280
Tepung	Telur, Minyak	0.485714	0.714286	1.243781

Tabel ini menampilkan hasil pembentukan aturan asosiasi (Association Rules) yang menggambarkan pola hubungan antar produk. *Antecedents* merepresentasikan Item yang dibeli terlebih dahulu (kondisi), *consequents* merepresentasikan Item yang diprediksi akan dibeli bersamaan (hasil), support adalah Persentase kemunculan kombinasi antecedents + consequents dalam transaksi, confidence merupakan probabilitas pembelian consequents jika antecedents sudah dibeli, dan lift adalah Penguatan hubungan jika lift >1 maka korelasi positif. Sebagai contoh pada tabel baris pertama telur sebagai *antecedents* dan minyak sebagai *consequents*, Support 57.43% yang berarti kombinasi Telur & Minyak muncul di 57.43% transaksi, Confidence 78.82% berarti Jika pembeli membeli Telur kemungkinan 78.82% akan membeli Minyak juga, Lift 1.19 berarti pembelian telur meningkatkan kemungkinan beli Minyak sebesar 19%.

IV. KESIMPULAN

Penelitian ini berhasil mengidentifikasi pola asosiasi strategis antar produk. Temuan kunci menunjukkan bahwa kombinasi Telur-Minyak-Tepung merupakan frequent itemset paling signifikan (support 48.57%), dengan aturan asosiasi terkuat pada relasi {Telur, Minyak} \rightarrow {Tepung} (confidence 84.58% dan lift ratio 1.24). Hal ini mengindikasikan bahwa pembelian Telur dan Minyak secara bersamaan meningkatkan probabilitas pembelian Tepung sebesar 24% dibandingkan kemunculan independen. Temuan ini memberikan dasar empiris untuk strategi penempatan produk (product placement), rekomendasi bundling promosi, dan alokasi stok inventori yang lebih efisien. Meskipun algoritma Apriori terbukti efektif mengidentifikasi hubungan linear antar item, penelitian ini memiliki keterbatasan dalam menangani kompleksitas dependensi multi-item akibat ukuran dataset yang relatif kecil (350 transaksi). Untuk pengembangan selanjutnya, disarankan ekspansi dataset, integrasi variabel demografi pelanggan, serta uji komparatif dengan algoritma FP-Growth guna mengeksplorasi pola tersembunyi yang lebih kompleks. Secara holistik, pendekatan ini tidak hanya memenuhi tujuan identifikasi pola pembelian konsumen, tetapi juga menyediakan kerangka kerja berbasis data yang dapat diimplementasikan untuk pengambilan keputusan strategis di sektor ritel.

REFERENSI

- [1] Tiara Antesia, Sri Eniyati., "Aturan asosiasi data alat tulis kantor menggunakan algoritma apriori"., Proceeding SENDIU 2020.
- [2] Salsabilla C Nurzanah, Syariful Alam, Teguh I Hermanto., "Analisis association rule untuk identifikasi pola gejala penyakit hipertensi menggunakan algoritma apriori (studi kasus: klinik rafina medical center)"., JIKO (Jurnal Informatika dan Komputer) Vol. 5, No. 2, Agustus 2022.
- [3] Aceng Abdul Wahid., "Analisis Metode Waterfall Untuk Pengembangan Sistem Informasi," Jurnal Ilmu-ilmu Informatika dan Manajemen STMIK, Oktober (2020).
- [4] Ni Putu Ayu Widiari, I Made Agus Dwi Suarjaya, Dwi Putra Githa., "Teknik Data Cleaning Menggunakan Snowflake untuk Studi Kasus Objek Pariwisata di Bali"., jurnal ilmiah merpati vol. 8, no. 2 august 2020.
- [5] Irma Agustina, Gifthera Dwilestari, Ade Rizki Rinaldi., "Implementasi data mining pada proses seleksi beasiswa menggunakan naive bayes dan backward elimination"., Jurnal Informasi Interaktif Vol. 10No. 1 Januari 2025.
- [6] Prasetyo, Numan Musyaffa, Ricki Sastra "Implementasi data mining untuk analisis data penjualan dengan menggunakan algoritma apriori (studi kasus dapoerin's)"., JURNAL

- KHATULISTIWA INFORMATIKA, VOL. VIII, NO. 2
DESEMBER 2020.
- [7] Shiddiq Ahmad Fadhilah., "Analisis perilaku pembelian konsumen menggunakan metode association rule - market basket analysis dan clustering analysis"., Teknik Industri Fakultas Teknologi Industri Universitas Islam Indonesia Yogyakarta 2022.
 - [8] Pradini Nurul Safitri., "Analisis Strategi Penjualan Produk Menggunakan Association Rule dengan Algoritma Apriori"., Program Studi Statistika Fakultas Matematika Dan Ilmu Pengetahuan Alam Universitas Islam Indonesia Yogyakarta 2022.
 - [9] Arya Wijaya, Ahmad Faqih, Dodi Solihudin, Cep Lukman Rohmat, Sandy Eka Permana., "Penerapan association rules menggunakan algoritma apriori untuk identifikasi pola pembelian"., JATI (Jurnal Mahasiswa Teknik Informatika) Vol. 7 No. 6, Desember 2023.
 - [10] Nola Ritha, Eka Suswaini, Wisnu Pebriadi., "Penerapan Association Rule Menggunakan Algoritma Apriori Pada Poliklinik Penyakit Dalam"., Jurnal Sains dan Informatika Volume 7, Nomor 2, November 2021.
 - [11] Cevi Herdian, Ahya Kamila, I Gusti Agung Musa Budidarma., "Studi Kasus Feature Engineering Untuk Data Teks: Perbandingan Label Encoding dan One-Hot Encoding Pada Metode Linear Regresi"., Technologia : Jurnal Ilmiah Vol. 15 No. 1 Januari 2024.