

ANALISIS POLA PEMBELIAN PRODUK MENGGUNAKAN ALGORITMA APRIORI PADA DATA TRANSAKSI RETAIL

Romadona^{1*}, Dwi Hartanti², Hanifah Permatasari³

^{1,2,3}Universitas Duta Bangsa Surakarta

^{1*}220101036@gmail.com, ²dwihartanti@udb.ac.id, ³hanifah_permatasari@udb.ac.id

DOI: <https://doi.org/10.46880/mtk.v12i2.5730>

ABSTRACT

The growth of transaction data in the retail sector increases the need for analytical methods capable of identifying consumer purchasing patterns efficiently. This study applies the Apriori algorithm within the Cross Industry Standard Process for Data Mining (CRISP-DM) framework to perform market basket analysis on retail transaction data. The dataset consists of 934,974 transaction records, including 407,171 unique transactions and 27,344 unique products collected between July 2021 and September 2025. After the data cleaning process, 189,724 valid transactions were obtained. To improve computational efficiency, the analysis was limited to the 300 best-selling products, resulting in 90,718 transactions for the modeling stage. Frequent itemset generation was performed using a minimum support value of 0.1% and a maximum itemset length of three, producing 570 frequent itemsets consisting of 300 1-itemsets, 213 2-itemsets, and 57 3-itemsets. Association rule generation using a minimum confidence threshold of 70% and a lift ratio greater than 1 produced 52 valid rules. The best rule achieved a lift ratio of 161.32 and a confidence value of 93.88%, indicating a strong purchasing relationship among school supply products. The results demonstrate that the selected support and confidence parameters are effective in identifying meaningful purchasing patterns. Furthermore, the resulting association rules can support practical retail strategies, including product bundling, shelf arrangement optimization, and inventory management.

Keywords: *Apriori Algorithm, Association Rule, Market Basket Analysis, Retail Transaction, Data Mining*

I. PENDAHULUAN

Perkembangan teknologi informasi telah mendorong pertumbuhan volume data transaksi pada sektor retail secara signifikan. Setiap transaksi yang terjadi menyimpan informasi berharga mengenai perilaku pembelian pelanggan yang apabila dianalisis secara tepat dapat menjadi dasar pengambilan keputusan bisnis yang strategis[1]. Permasalahan yang sering dihadapi pelaku usaha retail adalah ketidakmampuan mengolah data transaksi dalam jumlah besar secara efisien sehingga informasi pola pembelian konsumen tidak dapat teridentifikasi dengan baik, yang pada akhirnya berdampak pada inefisiensi manajemen stok, penataan produk, dan strategi pemasaran [2]. Akibatnya, toko mengalami kesulitan dalam menentukan produk yang sebaiknya ditempatkan berdekatan, dipromosikan secara bersamaan, maupun diprioritaskan dalam pengelolaan persediaan.

Data mining merupakan pendekatan yang digunakan untuk menggali informasi dan pengetahuan tersembunyi dari kumpulan data berukuran besar [3]. Salah satu teknik dalam data mining yang relevan untuk menganalisis pola pembelian adalah association rule mining, yaitu metode yang bertujuan menemukan hubungan atau asosiasi antar item yang sering dibeli secara bersamaan dalam satu transaksi [4]. Informasi dari association rule dapat dimanfaatkan untuk menyusun strategi product bundling, rekomendasi produk, serta optimasi tata letak barang di area penjualan [5].

Algoritma Apriori merupakan salah satu algoritma association rule mining yang paling banyak diterapkan karena mampu menghasilkan frequent itemset secara

sistematis berdasarkan nilai minimum support dan minimum confidence yang ditentukan [6]. Beberapa penelitian sebelumnya telah membuktikan efektivitas algoritma ini dalam berbagai konteks retail. Hermawan et al. [7] menerapkan algoritma Apriori pada data penjualan produk supermarket dan berhasil mengidentifikasi kombinasi produk yang paling sering dibeli bersamaan. Penelitian lain oleh Brighton dan Hariyanto [4] pada toko ritel elektronik menunjukkan bahwa penerapan market basket analysis menggunakan Apriori mampu menghasilkan aturan asosiasi yang valid dengan nilai lift ratio lebih dari 1. Ashari et al. [3] juga berhasil menerapkan Apriori untuk analisis pendapatan usaha retail dan membuktikan bahwa hasil association rule dapat digunakan langsung sebagai acuan strategi penjualan.


Meskipun penelitian-penelitian tersebut menunjukkan hasil yang baik, sebagian besar dilakukan pada dataset dengan konteks produk yang spesifik seperti elektronik, sembako, atau produk fashion. Penelitian pada data transaksi retail umum dengan jumlah transaksi yang besar masih perlu dikaji lebih lanjut untuk mengetahui efektivitas algoritma Apriori dalam menghasilkan pola pembelian yang representatif [8]. Selain itu, penentuan parameter minimum support dan minimum confidence yang tepat sangat mempengaruhi kualitas dan jumlah rule yang dihasilkan sehingga perlu dilakukan analisis yang cermat [9]. Berdasarkan permasalahan tersebut, Penelitian ini bertujuan mengidentifikasi association rule yang memenuhi minimum confidence sebesar 70% dan lift ratio lebih dari 1 untuk menemukan pola pembelian produk yang signifikan pada data transaksi retail. Penelitian dilakukan dengan menentukan nilai minimum support dan



minimum confidence yang optimal sehingga dapat dihasilkan association rule yang relevan dan representatif. Hasil penelitian diharapkan mampu memberikan informasi mengenai keterkaitan antar produk yang sering dibeli secara bersamaan sehingga dapat dimanfaatkan sebagai dasar dalam pengambilan keputusan bisnis, seperti strategi promosi, pengelolaan stok barang, serta penataan produk pada sektor retail..

II. METODOLOGI

Penelitian ini menggunakan kerangka Cross Industry Standard Process for Data Mining (CRISP-DM) sebagai metodologi untuk menganalisis pola pembelian produk pada data transaksi retail menggunakan algoritma Apriori [10]. CRISP-DM dipilih karena menyediakan alur kerja yang sistematis dan terstruktur dalam setiap tahapan proses data mining sehingga dapat dilaksanakan secara terarah dan terukur [11]. Metodologi penelitian terdiri dari lima fase yaitu business understanding, data understanding, data preparation, modeling, dan evaluation sebagaimana ditunjukkan pada Gambar 1. Fase deployment tidak diikutsertakan karena penelitian ini berfokus pada proses analisis dan pemodelan pola pembelian.



Gambar 1. Metodologi Penelitian

Business Understanding

Pada fase ini dilakukan pemahaman terhadap kebutuhan dan tujuan penelitian dari perspektif bisnis retail [12]. Permasalahan utama yang diidentifikasi adalah belum dimanfaatkannya data transaksi penjualan secara optimal untuk mengetahui pola pembelian konsumen. Berdasarkan permasalahan tersebut, tujuan penelitian ditetapkan yaitu menemukan kombinasi produk yang sering dibeli secara bersamaan menggunakan algoritma Apriori sebagai dasar rekomendasi strategi pemasaran dan pengelolaan stok.

Data Understanding

Fase *data understanding* bertujuan untuk memahami karakteristik data yang akan digunakan dalam proses analisis [13]. Data yang digunakan merupakan data penjualan sebuah toko retail. Dataset terdiri dari atribut utama berupa ID transaksi, tanggal transaksi, dan nama produk yang dibeli. Pada fase ini dilakukan eksplorasi awal meliputi pengecekan kelengkapan data, identifikasi nilai kosong (*missing value*), dan pemahaman distribusi frekuensi produk yang terjual.

Data Preparation

Fase data preparation merupakan tahap pembersihan dan transformasi data sebelum diproses menggunakan algoritma Apriori [10]. Data cleaning dilakukan dengan menghapus transaksi yang memiliki nilai produk kosong, menghapus duplikasi produk dalam transaksi yang sama, melakukan trimming spasi pada nama produk, serta menghapus transaksi yang hanya berisi

satu produk karena tidak dapat membentuk hubungan asosiasi. Proses ini terdiri dari tiga langkah sebagai berikut: 1) Data cleaning untuk menghapus record transaksi yang tidak lengkap, mengandung nilai kosong (null), atau merupakan data duplikat; 2) Transformasi data untuk mengubah format data ke dalam bentuk item-transaction matrix dengan nilai 1 jika produk dibeli dan 0 jika tidak; 3) Seleksi atribut untuk memilih atribut yang relevan yaitu ID transaksi dan nama produk.

Modeling

Pada fase *modeling* diterapkan algoritma Apriori untuk menemukan pola asosiasi antar produk dalam data transaksi [2]. Algoritma Apriori bekerja melalui dua tahap utama yaitu pembentukan *frequent itemset* dan pembangkitan *association rule* [13].

1. Pembentukan Frequent Itemset

Frequent itemset adalah kumpulan item yang memiliki nilai *support* memenuhi ambang batas *minimum support* yang telah ditentukan. Nilai *support* dihitung menggunakan persamaan berikut [16]:

$$\text{Support}(A) = \frac{\text{Frekuensi}(A)}{N} \times 100\% \quad (1)$$

Keterangan:

Support(A) = Nilai persentase kemunculan item A dari seluruh transaksi

Frekuensi(A) = Jumlah transaksi yang mengandung item A

N = Total seluruh transaksi dalam dataset

$$\text{Support}(A \rightarrow B) = \frac{\text{Frekuensi}(A \cup B)}{N} \times 100\% \quad (2)$$

Keterangan:

Support(A→B) = Nilai persentase kemunculan item A dan item B secara bersamaan dalam satu transaksi

Frekuensi(A∪B) = Jumlah transaksi yang mengandung item A dan item B sekaligus dalam satu transaksi yang sama

N = Total seluruh transaksi dalam dataset

2. Pembentukan Association Rule

$$\text{Confidence}(A \rightarrow B) = \frac{\text{Frekuensi}(A \cup B)}{\text{Frekuensi } A} \times 100\% \quad (3)$$

Keterangan:

Confidence(A→B) = Nilai persentase peluang item B dibeli apabila item A dibeli dalam transaksi yang sama

Frekuensi(A∪B) = Jumlah transaksi yang mengandung item A dan item B secara bersamaan

Frekuensi(A) = Jumlah seluruh transaksi yang mengandung item A

$$\text{Lift}(A \rightarrow B) = \frac{\text{Confidence}(A \rightarrow B)}{\text{Support}(B)} \quad (4)$$

Keterangan:

Lift(A→B) = Nilai yang menunjukkan kekuatan

hubungan asosiasi antara item A dan item B

$\text{Confidence}(A \rightarrow B) = \text{Nilai } confidence \text{ dari aturan asosiasi A terhadap B pada persamaan (3)}$

$\text{Support}(B) = \text{Nilai } support \text{ item B yang dihitung menggunakan persamaan (1)}$

Seluruh proses analisis dilakukan menggunakan Python 3.12 dengan library Pandas 2.2.2 untuk pengolahan data, Mlxtend 0.23.1 untuk implementasi algoritma Apriori dan Association Rule, serta Matplotlib 3.9 untuk visualisasi hasil. Nilai minimum support sebesar 0,1% dipilih karena dataset memiliki jumlah produk yang sangat besar dan distribusi transaksi yang tidak merata. Nilai minimum confidence sebesar 70% digunakan untuk memastikan bahwa rule yang dihasilkan memiliki tingkat kepercayaan yang tinggi dan relevan untuk kebutuhan bisnis retail.

III. HASIL DAN PEMBAHASAN

A. Data Understanding


Dataset yang digunakan dalam penelitian ini merupakan data transaksi penjualan sebuah toko retail yang terdiri dari tiga atribut utama yaitu ID transaksi, tanggal transaksi, dan nama produk yang dibeli. Hasil eksplorasi awal menunjukkan bahwa dataset memiliki total 934.974 record transaksi yang mencakup 407.171 transaksi unik dengan 27.344 jenis produk unik. Periode data mencakup rentang waktu dari tanggal 14 Juli 2021 hingga 17 September 2025. Hasil pengecekan kelengkapan data menunjukkan bahwa tidak ditemukan adanya nilai kosong (missing value) pada dataset sehingga seluruh record dapat diproses lebih lanjut. Distribusi frekuensi produk menunjukkan adanya variasi kemunculan yang signifikan antar produk, dengan produk AP POOL PTH 963 965 (24) 37/43 mendominasi dengan frekuensi tertinggi sebesar 3.703 kemunculan.

B. Data Preparation

Tahap data preparation dilakukan untuk memastikan kualitas data sebelum diproses menggunakan algoritma Apriori. Proses pertama adalah data cleaning yang meliputi penghapusan duplikat produk dalam satu transaksi yang sama, pembersihan nilai kosong atau spasi pada nama produk, serta penghapusan transaksi dengan hanya satu item (single-item transaction) karena tidak relevan dalam analisis asosiasi. Setelah proses cleaning, jumlah record berkurang dari 934.974 menjadi 699.449 record dengan 189.724 transaksi valid yang masing-masing memuat minimal dua produk berbeda. Proses kedua adalah transformasi data dari format record per baris menjadi item-transaction matrix menggunakan TransactionEncoder dari library mlxtend.

Untuk efisiensi komputasi, hanya 300 produk terlaris yang diikutsertakan sehingga diperoleh 90.718 transaksi valid dengan matriks berukuran 90.718 baris (transaksi) x 300 kolom (produk), dengan nilai True jika produk dibeli dalam transaksi tersebut dan False jika tidak. Proses seleksi ini tidak menghilangkan informasi yang signifikan karena produk-produk tersebut mencakup frekuensi pembelian tertinggi dalam dataset.

Eksplorasi distribusi frekuensi produk dilakukan untuk



Gambar 2. Distribusi Top 15 Produk Terlaris

memahami pola dominasi item dalam dataset. Gambar 2 menampilkan 15 produk terlaris berdasarkan frekuensi kemunculan dalam transaksi. Hasil eksplorasi menunjukkan adanya beberapa produk yang memiliki frekuensi pembelian jauh lebih tinggi dibandingkan produk lainnya. Produk-produk dengan frekuensi tertinggi ini berpotensi besar untuk muncul dalam frequent itemset maupun association rule yang akan dihasilkan pada tahap modeling

C. Modeling: Pembentukan Frequent Itemset

Proses pembentukan frequent itemset dilakukan menggunakan fungsi apriori dari library mlxtend dengan nilai minimum support yang ditetapkan sebesar 0,1% ($\text{min_support} = 0,001$) dan panjang maksimum itemset sebesar 3 item ($\text{max_len} = 3$). Penetapan nilai minimum support yang relatif kecil bertujuan agar lebih banyak pola pembelian yang dapat teridentifikasi, mengingat dataset transaksi retail umumnya memiliki distribusi yang sangat bervariasi. Pemilihan parameter ini sejalan dengan pendekatan yang digunakan Ashari et al. [3] yang menyebutkan bahwa penyesuaian nilai minimum support perlu disesuaikan dengan karakteristik dan kepadatan data transaksi.

Proses Apriori menghasilkan frequent itemset yang terdistribusi ke dalam tiga kategori panjang itemset. 1-itemset adalah item tunggal yang memenuhi minimum support, 2-itemset adalah pasangan dua item yang sering dibeli bersamaan, dan 3-itemset adalah kombinasi tiga item yang muncul bersama dalam satu transaksi. Distribusi itemset berdasarkan panjangnya disajikan pada Gambar 3.

```
=====
HASIL FREQUENT ITEMSET
=====
Min. Support   : 0.001 (0.1%)
Total itemset  : 570

Distribusi panjang itemset:
1-itemset     : 300
2-itemset     : 213
3-itemset     : 57
=====
```

Gambar 3. Distribusi Frequent Itemset Berdasarkan Panjang Itemset

D. Modeling: Pembangkitan Association Rule

Berdasarkan frequent itemset yang diperoleh, tahap berikutnya adalah pembangkitan association rule menggunakan fungsi association_rules dari library mlxtend. Nilai minimum confidence ditetapkan sebesar 70% ($\text{min_confidence} = 0,7$), artinya hanya rule dengan peluang pembelian consequent minimal 70% apabila

antecedent dibeli yang akan disertakan. Selain itu, dilakukan penyaringan tambahan dengan syarat lift ratio lebih dari 1 untuk memastikan bahwa setiap rule yang dihasilkan mencerminkan hubungan yang benar-benar positif antara produk, bukan sekadar kebetulan statistik. Rule dengan lift > 1 mengindikasikan bahwa kemunculan antecedent dan consequent secara bersamaan lebih tinggi dari yang diharapkan secara acak [14].

TOP 10 ASSOCIATION RULES (diurutkan berdasarkan Lift Ratio):


	Antecedent (Jika)	Consequent (Maka)	Support (%)	Confidence (%)	Lift Ratio
1	SAMPUL COKLAT POLOS ISI 20 (10 LBR)	SAMPUL PLASTIK OPP KC HGS ISI 50 (10 LBR)	0.2910	80.7339	161.3221
2	KK TWIKI 17-18 TH (10), KOLONG HIJAU (200)	KK TWIKI 17-18 HITAM (10)	0.1014	83.6364	158.7306
3	KOLONG HIJAU (200), KK TWIKI 17-18 HITAM (10)	KK TWIKI 17-18 TH (10)	0.1014	85.1852	130.3175
4	KK TWIKI 17-18 HITAM (10)	KK TWIKI 17-18 TH (10)	0.4079	77.4059	118.4166
5	KK TWIKI 19-20 HITAM (10)	KK TWIKI 19-20 TH (10)	0.3020	74.2547	117.7665
6	KK PRIMA SMP HITAM, KK PRIMA SD TH	KK PRIMA SD HITAM	0.1080	78.4000	101.8953
7	KK PRIMA SMA TH, KK PRIMA SMP HITAM	KK PRIMA SMA HITAM	0.1102	80.6452	94.6438
8	HASDUK L SD, KK TWIKI 17-18 HITAM (10)	KOLONG HIJAU (200)	0.1058	88.8889	89.7976
9	KK PRIMA SMP TH, KK PRIMA SD HITAM	KK PRIMA SMP HITAM	0.1102	81.9672	87.1735
10	KK TWIKI 17-18 TH (10), HASDUK L SD	KOLONG HIJAU (200)	0.1102	84.7458	85.6121

Gambar 4. Top 10 Association Rule Terbaik Berdasarkan Lift Ratio

Gambar 4 menyajikan 10 association rule terbaik yang diurutkan berdasarkan nilai lift ratio tertinggi. Hasil menunjukkan bahwa seluruh rule memiliki confidence di atas 70% dan lift ratio lebih dari 1, yang berarti setiap rule mencerminkan hubungan asosiasi yang kuat dan signifikan secara statistik antara produk-produk yang terlibat.

E. Evaluation

Evaluasi terhadap association rule yang dihasilkan dilakukan berdasarkan tiga metrik utama yaitu support, confidence, dan lift ratio. Dari total 570 frequent itemset yang dihasilkan, proses pembangkitan rule menghasilkan 52 association rule valid yang memenuhi syarat minimum confidence 70% dan lift ratio lebih dari 1. Seluruh rule yang lolos filter memiliki lift ratio di atas 1, yang menandakan bahwa hubungan antar produk bersifat positif dan tidak terjadi secara kebetulan. Nilai confidence tertinggi yang diperoleh mencapai 93,88%, nilai lift ratio tertinggi sebesar 161,32, dan nilai support tertinggi sebesar 0,7430%. Pola sebaran pada scatter plot (Gambar 5) menunjukkan bahwa rule dengan confidence tinggi cenderung memiliki support yang lebih rendah, yang merupakan trade-off umum dalam analisis market basket.



Gambar 5. Scatter Plot Support vs Confidence (warna = Lift Ratio)

Visualisasi scatter plot pada Gambar 5 menampilkan sebaran nilai support dan confidence dari seluruh rule yang dihasilkan, dengan warna titik merepresentasikan nilai lift ratio. Pola sebaran menunjukkan bahwa rule

dengan confidence tinggi cenderung memiliki support yang lebih rendah, hal ini merupakan trade-off yang umum dalam analisis market basket dan konsisten dengan temuan penelitian-penelitian sebelumnya [7], [15]. Rule dengan nilai lift ratio tertinggi menunjukkan bahwa produk-produk perlengkapan sekolah memiliki kecenderungan kuat untuk dibeli secara bersamaan. Temuan ini dapat diterapkan melalui strategi product bundling, penempatan produk dalam rak yang berdekatan, maupun penyediaan stok yang lebih terencana untuk menghindari kekosongan barang pada periode permintaan tinggi.

F. Pembahasan

Hasil penelitian menunjukkan bahwa algoritma Apriori mampu mengidentifikasi 570 frequent itemset dan 52 association rule valid dari 90.718 transaksi yang dianalisis. Nilai minimum support sebesar 0,1% dan minimum confidence sebesar 70% menghasilkan rule yang memiliki lift ratio lebih dari 1, sehingga hubungan antar produk yang ditemukan dapat dianggap memiliki asosiasi positif dan bukan terjadi secara acak.

Rule dengan nilai lift ratio tertinggi menunjukkan adanya keterkaitan yang kuat antar produk perlengkapan sekolah, seperti kelompok produk KK. TWIKI, KK. PRIMA, dan KOLONG HIJAU. Pola ini menunjukkan bahwa pelanggan cenderung membeli produk-produk tersebut secara bersamaan dalam satu transaksi. Dari sisi bisnis, informasi ini dapat dimanfaatkan untuk menyusun strategi product bundling, penempatan produk pada rak yang berdekatan, serta perencanaan persediaan yang lebih efektif agar produk yang sering dibeli bersamaan selalu tersedia.

Hasil penelitian ini sejalan dengan penelitian Ashari *et al.* [3] dan Brighton & Hariyanto [4] yang menunjukkan bahwa algoritma Apriori mampu menghasilkan association rule yang valid untuk mendukung pengambilan keputusan pada sektor retail. Perbedaannya, penelitian ini menggunakan data transaksi retail umum dengan jumlah transaksi yang relatif besar sehingga mampu memberikan gambaran pola pembelian yang lebih luas.

Penelitian ini memiliki keterbatasan karena hanya menggunakan 300 produk terlaris dari keseluruhan 27.344 produk yang tersedia. Pembatasan tersebut dilakukan untuk meningkatkan efisiensi komputasi, namun berpotensi menyebabkan pola asosiasi pada produk dengan frekuensi penjualan rendah tidak teridentifikasi. Oleh karena itu, penelitian selanjutnya dapat mempertimbangkan penggunaan lebih banyak produk atau melakukan analisis khusus terhadap kelompok produk dengan frekuensi rendah.

IV. KESIMPULAN

Adapun kesimpulan dari penelitian ini adalah proses pembersihan dan seleksi data mengurangi 934.974 record menjadi 189.724 transaksi valid untuk efisiensi hanya 300 produk terlaris dipakai sehingga dimodelkan 90.718 transaksi, Algoritma Apriori (min_support = 0,1%, max_len = 3, min_confidence = 70%) menghasilkan 570 frequent itemset dan 52 aturan asosiasi dengan aturan terbaik menunjukkan lift = 161,32

ini menandakan asosiasi sangat kuat terutama antar produk alat tulis/sekolah kemudian hasil analisis memberikan pola pembelian yang bermakna dan bisa dijadikan dasar keputusan komersial (bundling produk, tata letak rak, pengelolaan stok), meskipun pembatasan pada 300 produk terlaris berisiko mengabaikan pola long-tail.

V. REFERENSI

- [1] H. D. Oktory and T. Y. Hadiwandura, "Penerapan Algoritma Apriori untuk Penentuan Pola Pembelian Kacamata pada Optik Indah Optikal," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1275–1281, Jul. 2024, doi: 10.57152/malcom.v4i4.1353.
- [2] I. Fajri, A. Faqih, and S. E. Permana, "Pemanfaatan Algoritma Apriori Dalam Mengungkap Pola Transaksi Untuk Desain Tata Letak Produk," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 2, Apr. 2025, doi: 10.23960/jitet.v13i2.6181.
- [3] I. A. Ashari, A. Wirasto, D. Nugroho Triwibowo, and P. Purwono, "Implementasi Market Basket Analysis dengan Algoritma Apriori untuk Analisis Pendapatan Usaha Retail," *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 21, no. 3, pp. 701–709, Jul. 2022, doi: 10.30812/matrik.v21i3.1439.
- [4] K. Brighton and S. Hariyanto, "Penerapan Metode Market Basket Analisis Dengan Algoritma Apriori Pada Toko Ritel Elektronik," *bit-Tech*, vol. 7, no. 1, pp. 37–46, Aug. 2024, doi: 10.32877/bt.v7i1.1417.
- [5] A. Nur Rahmi and Yosaphat Ananda Mikola, "IMPLEMENTASI ALGORITMA APRIORI UNTUK MENENTUKAN POLA PEMBELIAN PADA CUSTOMER (STUDI KASUS : TOKO BAKOEL SEMBAKO)," *Information System Journal*, vol. 4, no. 1, pp. 14–19, May 2021, doi: 10.24076/infosjournal.2021v4i1.561.
- [6] I. T. Utami and R. Dapa, "Aplikasi Metode Market Basket Analysis dengan Algoritma Apriori untuk Mengetahui Pola Belanja Konsumen pada Online Shop Amerta Fashion," *Indonesian Journal of Applied Statistics*, vol. 6, no. 1, p. 96, Jan. 2024, doi: 10.13057/ijas.v6i1.79963.
- [7] Andy Hermawan, Bayu Wicaksono, Tigfhar Ahmadjayadi, Bagas Surya Prakasa, and Jasico Dacomoro Aruan, "Implementasi Algoritma Apriori pada Market Basket Analysis terhadap Data Penjualan Produk Supermarket," *Algoritma : Jurnal Matematika, Ilmu pengetahuan Alam, Kebumihan dan Angkasa*, vol. 2, no. 5, pp. 95–105, Jun. 2024, doi: 10.62383/algoritma.v2i5.137.
- [8] F. R. Pare, O. Wati, L. P. Taran, and L. M. Arsai, "Penerapan Data Mining Pada Transaksi Penjualan Barang Menggunakan Metode Apriori (Studi Kasus:Toko BE-MART)," *G-Tech: Jurnal Teknologi Terapan*, vol. 7, no. 1, pp. 255–261, Jan. 2023, doi: 10.33379/gtech.v7i1.1951.
- [9] K. Nisa, "Penerapan Data Mining Terhadap Data Transaksi Sebagai Pendukung Informasi Strategi Penjualan Menggunakan Algoritma Apriori," *Jurnal Teknik Informatika UNIKA Santo Thomas*, pp. 306–315, Dec. 2021, doi: 10.54367/jtiust.v6i2.1454.
- [10] S. S. Hartinah and Sugiyono, "Pemodelan Data Mining Transaksi Penjualan Menggunakan Algoritma Apriori (Studi Kasus: Kedai Ngodeng & Smoothies)," *Jurnal Indonesia : Manajemen Informatika dan Komunikasi*, vol. 5, no. 3, pp. 3080–3098, Sep. 2024, doi: 10.35870/jimik.v5i3.992.
- [11] M. G. Saparudin and S. Sholihin, "Penggunaan Data Mining untuk Analisis Pola Pembelian Pelanggan Menggunakan Metode Association Rule Algoritma Apriori (Studi Kasus di Toko Waspada)," *Jurnal Teknologi Sistem Informasi dan Aplikasi*, vol. 6, no. 1, pp. 27–33, Jan. 2023, doi: 10.32493/jtsi.v6i1.26927.
- [12] Andi Diah Kuswanto, Achmad Rizqullah Blessar, Abdul Goni, Arya Nibras Nayottama Sidiki, Oke Rizki Abdullah Haryu, and Hafid Anhar Hamiki, "Penerapan Algoritma Apriori Dalam Analisis Keranjang Belanja Retail Di Wilayah Jawa Barat," *Saturnus : Jurnal Teknologi dan Sistem Informasi*, vol. 2, no. 3, pp. 139–150, Jul. 2024, doi: 10.61132/saturnus.v2i3.208.
- [13] M. Wijaya, I. Pradesan, and A. Yulianto, "Implementasi Pola Pembelian Konsumen Menggunakan Metode Association Rule Mining," *Jurnal Teknologi Sistem Informasi*, vol. 6, no. 2, pp. 348–358, Sep. 2025, doi: 10.35957/jtsi.v6i2.13405.
- [14] K. D. Fernanda, A. P. Widodo, and J. Lemantara, "Analysis and Implementation of the Apriori Algorithm for Strategies to Increase Sales at Sakinah Mart," *JUITA : Jurnal Informatika*, vol. 11, no. 2, p. 203, Nov. 2023, doi: 10.30595/juita.v11i2.17341.
- [15] A. N. Fuadi, M. H. Bhakti, and A. Premana, "Analisis Pola Pembelian Konsumen Di Toko Ritel Dmart Menggunakan Algoritma Apriori Berbasis Website," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, Aug. 2024, doi: 10.23960/jitet.v12i3.4963.