

Penerapan Market Basket Analysis dengan Algoritma Apriori pada Data Transaksi Pos Retail untuk Mendukung Strategi Penjualan

Dendi Winardi¹, Gilang Ramadhan Pratama², Nandar Brayun Syah Lubis³

^{1,2,3}Program Studi Sistem Informasi, Universitas Pamulang

Email: dendiwinski777@gmail.com

Article Info

Article history:

Received June 1, 2026

Revised June 10, 2026

Accepted June 20, 2026

Keywords:

Apriori Algorithm, Data Mining, Interactive Dashboard, Market Basket Analysis, Retail

ABSTRACT

Increasing competition in the retail industry requires businesses to understand customer purchasing patterns to support more effective decision-making. This study applies Market Basket Analysis (MBA) using the Apriori algorithm to identify product associations and generate data-driven marketing recommendations. The research follows the CRISP-DM methodology, consisting of business understanding, data understanding, data preparation, modeling, evaluation, and deployment stages. The dataset was obtained from the Retail POS Basket Data on Kaggle, comprising 1,991 unique transactions and 68 product categories. The analysis results indicate that a minimum support of 0.2% and a minimum lift of 1.0 produced 2,370 frequent itemsets and 1,974 association rules. The strongest rule identified was {Energy Drink, Fish} → {Potato}, with a confidence value of 66.7% and a lift value of 9.69. Furthermore, the resulting association rules were implemented in an interactive Streamlit-based dashboard. The findings demonstrate that Market Basket Analysis can provide valuable insights to support marketing strategies and improve sales performance in the retail sector.

This is an open access article under the CC BY-SA license.



Article Info

Article history:

Received June 1, 2026

Revised June 10, 2026

Accepted June 20, 2026

Keywords:

Algoritma Apriori, Dashboard Interaktif, Data Mining, Market Basket Analysis, Ritel.

ABSTRAK

Persaingan industri ritel yang semakin ketat menuntut pelaku usaha untuk memahami pola pembelian konsumen guna mendukung pengambilan keputusan yang lebih efektif. Penelitian ini menerapkan metode Market Basket Analysis (MBA) menggunakan algoritma Apriori untuk mengidentifikasi hubungan antarproduk dan menghasilkan rekomendasi strategi pemasaran berbasis data. Metodologi yang digunakan adalah CRISP-DM yang mencakup tahapan *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Dataset penelitian berasal dari Retail POS Basket Data di Kaggle yang terdiri atas 1.991 transaksi unik dan 68 jenis produk. Hasil analisis menunjukkan bahwa parameter minimum support 0,2% dan minimum lift 1,0 menghasilkan 2.370 *frequent itemset* serta 1.974 aturan asosiasi. Aturan terkuat yang ditemukan adalah {Energy Drink, Fish} → {Potato} dengan nilai confidence 66,7% dan lift 9,69. Hasil analisis diimplementasikan ke dalam *dashboard* interaktif berbasis Streamlit yang mendukung eksplorasi aturan asosiasi dan rekomendasi produk secara dinamis. Temuan penelitian menunjukkan bahwa penerapan Market Basket Analysis mampu menghasilkan informasi yang bermanfaat untuk mendukung strategi pemasaran dan peningkatan penjualan pada sektor ritel.

This is an open access article under the CC BY-SA license.



Corresponding Author:

Dendi Winardi

Universitas Pamulang

Email: dendiwinski777@gmail.com

Pendahuluan

Perkembangan teknologi informasi telah mendorong transformasi signifikan pada sektor bisnis ritel. Tingkat persaingan yang semakin kompetitif menuntut pelaku usaha untuk memanfaatkan data sebagai aset strategis dalam mendukung pengambilan keputusan bisnis (Hermawan et al., 2024). Sistem Point of Sale (POS) yang digunakan dalam operasional toko ritel menghasilkan data transaksi dalam jumlah besar setiap harinya. Namun, data tersebut sering kali hanya berfungsi sebagai arsip digital dan belum dimanfaatkan secara optimal untuk menghasilkan informasi yang bernilai bagi perusahaan (Brighton & Hariyanto, 2024). Data transaksi penjualan menyimpan informasi mengenai pola perilaku belanja konsumen yang dapat digunakan untuk mengidentifikasi hubungan antarproduk dalam suatu transaksi. Informasi tersebut penting bagi pengelola bisnis karena dapat digunakan sebagai dasar dalam penyusunan strategi pemasaran, seperti promosi bundling, cross-selling, dan penataan produk pada rak penjualan untuk meningkatkan nilai transaksi pelanggan (Nugraheni & Nugroho, 2023; Purwati & Karnila, 2023).

Salah satu teknik data mining yang banyak digunakan untuk menemukan pola hubungan antarproduk adalah Market Basket Analysis (MBA). Market Basket Analysis merupakan metode analisis yang bertujuan mengidentifikasi keterkaitan antar item dalam suatu transaksi sehingga dapat diketahui produk-produk yang sering dibeli secara bersamaan (Ridho et al., 2024; Widodo & Fachrudin, 2022). Teknik ini termasuk ke dalam kategori *association rule mining* yang berfokus pada pencarian pola asosiasi dari kumpulan data transaksi.

Salah satu algoritma yang paling banyak digunakan adalah Apriori. Algoritma Apriori bekerja dengan mencari frequent itemset berdasarkan nilai minimum support, kemudian membentuk aturan asosiasi menggunakan metrik support, confidence, dan lift (Umar et al., 2022; Ramadhani et al., 2020). Prinsip utama algoritma ini menyatakan bahwa jika suatu kombinasi item memenuhi nilai minimum support, maka seluruh subset dari kombinasi tersebut juga harus memenuhi nilai minimum support (Putra et al., 2022). Beberapa penelitian sebelumnya telah menerapkan algoritma Apriori untuk menganalisis pola pembelian konsumen. Hermawan et al. memperoleh aturan asosiasi dengan nilai lift tertinggi sebesar 9,689 pada data transaksi supermarket (Hermawan et al., 2024). Brighton dan Hariyanto menerapkan pendekatan CRISP-DM pada data transaksi toko ritel elektronik menggunakan minimum support 20% dan minimum confidence 60% (Bagaskara & Bangkalang, 2023). Purwati dan Karnila menerapkan Market Basket Analysis pada data penjualan produk frozen food dengan minimum support 30% dan minimum confidence 90% (Purwati & Karnila, 2023). Rizaldi dan Adnan melakukan analisis pola pembelian pada data transaksi 212 Mart Pekanbaru dan menghasilkan aturan asosiasi dengan nilai lift tertinggi sebesar 2,665 (Rizaldi & Adnan, 2021).

Penelitian ini menawarkan beberapa kontribusi, yaitu melakukan eksplorasi parameter minimum support melalui lima skenario pengujian yang berbeda (0,001; 0,002; 0,003; 0,005; dan 0,01), menerapkan filter redundansi untuk menghilangkan aturan asosiasi simetris, serta menyajikan hasil analisis dalam bentuk dashboard interaktif berbasis Streamlit yang memungkinkan pengguna melakukan eksplorasi data secara dinamis. Berdasarkan permasalahan tersebut, penelitian ini bertujuan menerapkan algoritma *Apriori* pada data transaksi ritel publik untuk menemukan pola asosiasi antarproduk, menghasilkan aturan asosiasi berdasarkan nilai *support*, *confidence*, dan *lift*, serta merumuskan rekomendasi

strategi pemasaran melalui pendekatan *bundling* dan *cross-selling*.

Metode

1. Kerangka CRISP-DM

Penelitian ini mengadopsi kerangka *Cross-Industry Standard Process for Data Mining* (CRISP-DM) sebagai panduan metodologis yang bersifat iteratif dan terstruktur. Kerangka ini terdiri dari enam fase yang saling berkaitan, yakni *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Fase *business understanding* diwujudkan dalam perumusan masalah dan penetapan tujuan penelitian. Fase *data understanding* dan *data preparation* mencakup eksplorasi dan *preprocessing dataset*. Fase *modeling* menerapkan algoritma *Apriori*, sedangkan fase *evaluation* dan *deployment* mencakup evaluasi hasil dan implementasi *dashboard* interaktif.

2. Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini adalah Retail POS Dataset for Market Basket Analysis yang bersumber dari platform Kaggle (Mustofa et al., 2025). Dataset merepresentasikan transaksi penjualan ritel yang disimulasikan selama periode satu tahun, yaitu dari 1 Januari hingga 31 Desember 2024. Dataset terdiri atas 10.000 baris data yang mencakup 1.991 transaksi unik dengan 68 jenis produk yang dikelompokkan ke dalam 17 kategori produk. Atribut yang digunakan meliputi *order_id*, *user_id*, *order_date*, *time*, *order_hour_of_day*, *product_name*, *quantity*, *price*, *category*, dan *product_id* (Mustofa et al., 2025).

3. Persiapan dan Preprocessing Data

Tahap persiapan data bertujuan untuk memastikan data berada dalam kondisi yang memenuhi persyaratan teknis algoritma *Apriori*. Proses ini mencakup tiga langkah utama: (1) Pembersihan data melalui pemeriksaan seluruh atribut untuk mengidentifikasi *missing value* maupun data tidak valid; (2) Penanganan duplikasi pada kombinasi atribut *order_id* dan *product_name* dengan proses agregasi menggunakan fungsi *groupby* dan penjumlahan nilai *quantity*; (3) Transformasi data ke dalam format basket transaction menggunakan teknik *one-hot encoding*, menghasilkan matriks biner yang siap digunakan dalam proses pembentukan *frequent itemset* menggunakan algoritma *Apriori* (Purwati & Karnila, 2023).

4. Penerapan Algoritma Apriori

Algoritma *Apriori* bekerja secara iteratif untuk menemukan *frequent itemset* dan membangkitkan aturan asosiasi (Putra et al., 2022; Fadillah et al., 2023). Pada setiap iterasi, kandidat *itemset* dibentuk dari kombinasi yang lebih kecil menuju yang lebih besar, dan *itemset* yang tidak memenuhi nilai *minimum support* dieliminasi melalui mekanisme *pruning*. Dalam penelitian ini dilakukan eksplorasi terhadap beberapa kandidat nilai *minimum support*, yaitu 0,001 (0,1%), 0,002 (0,2%), 0,003 (0,3%), 0,005 (0,5%), dan 0,01 (1%). Penelitian ini juga menerapkan *minimum confidence* sebesar 30% dan *minimum lift* sebesar 1,0 sebagai kriteria pembentukan aturan asosiasi.

5. Filter Redundansi dan Perancangan *Dashboard*

Setelah aturan asosiasi berhasil dibangkitkan, diterapkan prosedur filter redundansi guna mengeliminasi aturan-aturan simetris. Untuk setiap pasangan item, hanya satu aturan unik yang dipertahankan berdasarkan nilai confidence tertinggi. Selanjutnya, seluruh hasil pemodelan diimplementasikan ke dalam dashboard interaktif berbasis Streamlit. Dashboard yang dikembangkan dilengkapi dengan panel filter dinamis untuk pengaturan parameter support, confidence, dan lift secara real-time, fitur pencarian rekomendasi produk berdasarkan antecedent, serta visualisasi aturan asosiasi dalam bentuk bar chart, scatter plot, dan heatmap (Umar et al., 2022).

Hasil dan Pembahasan

Statistik Deskriptif *Dataset*

Berdasarkan hasil eksplorasi data, diperoleh ringkasan statistik *dataset* yang disajikan pada Tabel 1. *Dataset* yang digunakan terdiri dari 10.000 baris data transaksi yang merepresentasikan 1.991 transaksi unik dengan 68 produk yang terdistribusi ke dalam 17 kategori produk. Periode transaksi mencakup rentang waktu satu tahun penuh, yaitu dari 1 Januari 2024 hingga 31 Desember 2024.

Tabel 1. Ringkasan Statistik *Dataset*

Metrik	Nilai
Total Transaksi	1.991
Total Produk Unik	68
Total Kategori Produk	17
Rentang Tanggal	2024-01-01 s/d 2024-12-31
Minimum Item per Transaksi	2
Rata-rata Item per Transaksi	5,02
Maksimum Item per Transaksi	7

Berdasarkan Tabel 1, rata-rata jumlah item per transaksi adalah 5,02 item dengan rentang antara 2 hingga 7 item per transaksi. Kondisi ini mengindikasikan bahwa *dataset* memiliki karakteristik *sparse* (tersebar), di mana kombinasi item yang sama cenderung jarang muncul secara berulang. Kondisi ini umum ditemukan pada *dataset* ritel yang memiliki variasi produk cukup tinggi. Produk dengan frekuensi pembelian tertinggi adalah Dishwashing Liquid (8,19%), diikuti oleh Chips (8,09%), Cake, Energy Drink, dan Soda masing-masing 7,94%. Distribusi waktu transaksi menunjukkan puncak aktivitas pada pukul 15.00-16.00, sementara hari Sabtu mencatatkan jumlah transaksi tertinggi (328 transaksi).

Data Preparation

Tahap *Data Preparation* dilakukan untuk memastikan kualitas data sebelum diterapkan pada proses pembentukan *frequent itemset*. Hasil pemeriksaan duplikasi menunjukkan adanya 299 entri duplikat yang ditangani melalui proses agregasi nilai quantity. Pemeriksaan kelengkapan data menunjukkan bahwa seluruh atribut utama telah terisi dengan baik sehingga tidak diperlukan proses imputasi. Selanjutnya data ditransformasikan ke dalam bentuk *transaction basket* dan dilakukan *one-hot encoding* untuk mengubah data transaksi menjadi matriks biner yang dapat diproses oleh algoritma Apriori.

Parameter Tuning

Sebelum menerapkan algoritma Apriori, dilakukan eksplorasi parameter untuk menentukan nilai minimum support yang optimal. Lima nilai *minimum support* diuji dan hasilnya disajikan pada Tabel 2.

Tabel 2. Hasil Eksplorasi Parameter *Minimum Support*

min support	frequent itemsets	association rules
0,001 (0,1%)	7.166	32.202
0,002 (0,2%)	2.370	1.974
0,003 (0,3%)	2.113	1.542
0,005 (0,5%)	1.034	1.454
0,010 (1,0%)	68	0

Berdasarkan Tabel 2, pada nilai minimum support 0,01 (1%) tidak dihasilkan aturan asosiasi sama sekali akibat karakteristik *dataset* yang *sparse*. Nilai *minimum support* 0,002 (0,2%) dipilih karena menghasilkan jumlah aturan asosiasi yang cukup (1.974 aturan) tanpa menghasilkan terlalu banyak *noise* seperti pada nilai 0,001 yang menghasilkan 32.202 aturan. Pemilihan ini sejalan dengan penelitian (Fatahillah & Wibowo, 2023) yang menggunakan nilai support rendah (0,1%-0,2%) pada *dataset* ritel dengan keragaman produk tinggi.

Frequent Itemset

Penerapan algoritma Apriori dengan nilai *minimum support* 0,002 menghasilkan 2.370 *frequent itemset* yang terdiri dari 68 1-itemset, 2.230 2-itemset, dan 72 3-itemset. Tabel 3 menyajikan 10 frequent 1-itemset dengan nilai *support* tertinggi.

Tabel 3. Top 10 Frequent 1-Itemset (min_support = 0,002)

No	Produk	Support
1	Dishwashing Liquid	8,19%
2	Chips	8,09%
3	Cake	7,94%
4	Energy Drink	7,94%
5	Soda	7,94%
6	Prawns	7,89%
7	Tissue	7,89%
8	Phone Cover	7,84%
9	Milk	7,79%
10	Salt	7,73%

Tabel 4 menyajikan 10 kombinasi 2 produk (2-itemset) dengan nilai support tertinggi. Kombinasi Detergent + Earphones dan Butter + Milk memiliki nilai support tertinggi sebesar 0,95%. Tabel 5 menyajikan 10 kombinasi 3 produk (3-itemset) dengan nilai support tertinggi, di mana kombinasi Baby Food + Spices + Tissue, Chicken Breast + Coffee + Shirt, dan Carrot + Phone Cover + Soap memiliki nilai support tertinggi sebesar 0,251%.

Tabel 4. Top 10 Frequent 2-Itemset (min_support = 0,002)

No	Kombinasi Produk	Support
1	Detergent + Earphones	0,95%
2	Butter + Milk	0,95%
3	Shoes + Spices	0,90%
4	Energy Drink + Sugar	0,90%

5	Cooking Oil + Saree	0,90%
6	Energy Drink + Tomato	0,90%
7	Baby Food + Milk	0,90%
8	Bread + Pastry	0,90%
9	Cheese + Chips	0,90%
10	Energy Drink + Potato	0,85%

Tabel 5. Top 10 Frequent 3-Itemset ($\text{min_support} = 0,002$)

No	Kombinasi Produk	Support
1	Baby Food + Spices + Tissue	0,251%
2	Chicken Breast + Coffee + Shirt	0,251%
3	Carrot + Phone Cover + Soap	0,251%
4	Apple + Cheese + Chips	0,201%
5	Beef + Energy Drink + Potato	0,201%
6	Belt + Fish + Lentils	0,201%
7	Apple + Cheese + Salt	0,201%
8	Banana + Chips + Spinach	0,201%
9	Biscuits + Chicken Breast + Face Wash	0,201%
10	Belt + Fish + Tea	0,201%

Association Rules

Setelah *frequent itemset* ditemukan, algoritma Apriori menghasilkan 1.974 aturan asosiasi. Setelah diterapkan filter redundansi yang mengeliminasi aturan-aturan simetris, diperoleh 138 aturan asosiasi unik dengan nilai *confidence* $\geq 30\%$. Tabel 6 menyajikan 15 aturan asosiasi dengan nilai *lift* tertinggi. Aturan terkuat yang ditemukan adalah Energy Drink + Fish \rightarrow Potato dengan nilai support 0,201%, confidence 66,7%, dan lift 9,6886. Nilai *lift* sebesar 9,6886 menunjukkan bahwa peluang ketiga produk dibeli bersamaan adalah 9,7 kali lebih besar dibandingkan dengan pembelian secara acak.

Tabel 6. 15 Association Rules dengan Nilai Lift Tertinggi

No	Antecedent	Consequent	Support	Confidence	Lift
1	Energy Drink, Fish	Potato	0,201%	66,7%	9,6886
2	Croissant, Shirt	Educational Book	0,201%	50,0%	8,5085
3	Cheese, Toilet Paper	Tea	0,201%	57,1%	8,1850
4	Pain Reliever, Toothpaste	Eggs	0,201%	57,1%	8,1850
5	Chips, Electric Kettle	Earphones	0,201%	57,1%	7,9008
6	Milk, Tomato	Pastry	0,201%	57,1%	7,7396
7	Coffee, Shirt	Chicken Breast	0,251%	55,6%	7,7350
8	Chicken Breast, Coffee	Shirt	0,251%	45,5%	7,6050
9	Earphones, Toothpaste	Potato	0,201%	50,0%	7,2664
10	Electric Kettle, Popcorn	Eggs	0,201%	50,0%	7,1619
11	Baby Food, Spices	Tissue	0,251%	55,6%	7,0453
12	Baby Food, Tissue	Spices	0,251%	50,0%	7,0106
13	Energy Drink, Tea	Spices	0,201%	50,0%	7,0106
14	Onion, Soap	Notebook	0,201%	50,0%	7,0106
15	Educational Book, Shirt	Croissant	0,201%	50,0%	6,9132

Berdasarkan hasil evaluasi, aturan asosiasi yang dihasilkan memiliki nilai *confidence* antara 30% hingga 66,7% dengan nilai *lift* seluruh aturan terpilih lebih besar dari 1. Kondisi ini menunjukkan bahwa hubungan antarproduk yang ditemukan merupakan asosiasi positif dan tidak terjadi secara kebetulan. Beberapa aturan dengan nilai lift tinggi memiliki nilai

support yang relatif rendah sehingga interpretasi hasil perlu mempertimbangkan ketiga metrik secara bersamaan agar rekomendasi yang dihasilkan tetap relevan secara bisnis. Visualisasi aturan asosiasi disajikan dalam bentuk bar *chart*, *scatter plot*, dan *heatmap* pada *dashboard* interaktif yang dikembangkan.

Implementasi *Dashboard*

Hasil analisis *Market Basket Analysis* diimplementasikan ke dalam *dashboard* interaktif berbasis Streamlit sebagai tahap *Deployment* dalam *framework* CRISP-DM. *Dashboard* dilengkapi panel filter yang memungkinkan pengguna menyesuaikan parameter *minimum support*, *confidence*, dan *lift* secara dinamis. Fitur utama *dashboard* meliputi: (1) filter parameter *real-time* yang langsung mempengaruhi tabel aturan asosiasi; (2) fitur pencarian rekomendasi produk berdasarkan *antecedent*; (3) visualisasi interaktif dalam bentuk bar *chart*, *scatter plot*, dan *heatmap*; serta (4) ringkasan proyek dan kesimpulan. Dengan adanya *dashboard* ini, pemilik toko dapat mengeksplorasi pola pembelian konsumen secara mandiri tanpa harus memahami kode pemrograman.

Rekomendasi Bisnis

Berdasarkan aturan asosiasi yang ditemukan, khususnya aturan terkuat Energy Drink + Fish -> Potato dengan nilai *lift* 9,6886 dan *confidence* 66,7%, disusun rekomendasi strategis untuk mendukung peningkatan penjualan. Tabel 7 menyajikan *action plan* rekomendasi bisnis yang dapat diimplementasikan oleh pengelola toko.

Tabel 7. *Action Plan* Rekomendasi Bisnis

No	Strategi	Implementasi	Dasar Rule	Target KPI
1	Bundling Produk (Cross-Selling)	Buat paket bundling: Energy Drink + Fish + Potato dengan diskon 10-15%	Energy Drink+Fish->Potato (Lift=9,69, Conf=66,7%)	Kenaikan nilai transaksi 10-20%
2	Tata Letak Toko (Cross-Merchandising)	Letakkan rak Energy Drink berdekatan dengan display Fish & Potato	Energy Drink+Fish->Potato (Lift=9,69)	Kenaikan penjualan Potato 15-25%
3	Promosi Otomatis via POS	Program sistem kasir agar menawarkan Potato saat pelanggan membeli Energy Drink dan Fish	Energy Drink+Fish->Potato (Conf=66,7%)	Konversi upsell 30-40%
4	Targeted Recommendation	Gunakan aturan asosiasi sebagai mesin rekomendasi di aplikasi belanja	Seluruh 1.974 aturan asosiasi	Peningkatan item per transaksi

Selain aturan dengan nilai *lift* tertinggi, pengelola toko juga dapat memanfaatkan aturan asosiasi lain yang memiliki nilai *support* dan *confidence* yang memadai untuk mendukung strategi *cross-selling*, bundling produk, maupun penataan tata letak toko. Dengan demikian, keputusan bisnis tidak hanya bergantung pada satu pola pembelian, tetapi mempertimbangkan keseluruhan pola asosiasi yang ditemukan selama proses analisis.

Kesimpulan

Penelitian ini berhasil menerapkan metode *Market Basket Analysis* menggunakan algoritma Apriori pada 1.991 data transaksi ritel untuk menemukan pola pembelian konsumen dan menghasilkan aturan asosiasi antarproduk. Hasil pengujian menunjukkan bahwa nilai *minimum support* sebesar 0,2% merupakan parameter yang paling optimal untuk karakteristik

data yang bersifat *sparse*. Setelah dilakukan evaluasi dan penyaringan aturan redundan, diperoleh aturan asosiasi terkuat yaitu Energy Drink dan Fish -> Potato dengan nilai *confidence* 66,7% dan *lift* 9,69. Penelitian ini juga berhasil mengimplementasikan hasil analisis ke dalam *dashboard* interaktif berbasis Streamlit yang dapat menampilkan informasi aturan asosiasi dan rekomendasi produk secara dinamis. Untuk penelitian selanjutnya, analisis dapat dikembangkan dengan membandingkan kinerja algoritma Apriori dengan algoritma *frequent pattern* lainnya seperti FP-Growth dan ECLAT, menggunakan dataset dengan periode transaksi yang lebih panjang, serta menambahkan fitur analisis yang lebih komprehensif.

Daftar Pustaka

- Bagaskara, S. R., & Bangkalang, D. H. (2023). Analisis dan implementasi Market Basket Analysis (MBA) menggunakan algoritma Apriori dengan dukungan visualisasi data. *Jurnal Sistem Komputer dan Informatika (JSON)*, 4(4), 612–620.
- Brighton, K., & Hariyanto, S. (2024). Penerapan metode Market Basket Analysis dengan algoritma Apriori pada toko ritel elektronik. *bit-Tech*, 7(1), 37–46.
- Fadillah, R., Qadriah, L., & Rizal, M. (2023). Market Basket Analysis data mining untuk mengetahui pola penjualan pada Cerry Mart Beureunueun menggunakan algoritma Apriori. *Jurnal Ilmiah Teknologi Informasi dan Komunikasi*, 1(1), 1–6.
- Fatahillah, R., & Wibowo, A. (2023). Analisis data transaksi (Market Basket Analysis) penjualan vape menggunakan algoritma Apriori berbasis website. *Prosiding Seminar Nasional Mahasiswa Fakultas Teknologi Informasi (SENAFTI)*, 2(2), 901–908.
- Hermawan, A., Wicaksono, B., Ahmadjayadi, T., Prakasa, B. S., & Aruan, J. D. (2024). Implementasi algoritma Apriori pada Market Basket Analysis terhadap data penjualan produk supermarket. *ALGORITMA: Jurnal Matematika, Ilmu Pengetahuan Alam, Kebumihan dan Angkasa*, 2(5), 95–105.
- Ismasari, Ramadhan, M., & Hadikristanto, W. (2020). Analisis tingkat pembelian konsumen dengan algoritma Apriori. *Jurnal Teknologi Informasi dan Komunikasi*, 8(1), 75–84.
- Lewis, A., Zarlis, M., & Situmorang, Z. (2021). Penerapan data mining menggunakan task Market Basket Analysis pada transaksi penjualan barang di AB Mart dengan algoritma Apriori. *Jurnal Media Informatika Budidarma*, 5(2), 676–681.
- Mustofa, N. M., Alfarisi, A. M., & Tholib, A. (2025). Penerapan algoritma Apriori untuk menentukan pola pembelian konsumen. *JSITIK: Jurnal Sistem Informasi dan Teknologi Informasi Komputer*, 4(1), 11–30.
- Nugraheni, W., & Nugroho, A. (2023). Penerapan metode Market Basket Analysis (MBA) dengan algoritma Apriori untuk menganalisis pembelian jajanan khas lebaran pada warung sembako di Toko Win. *Jurnal JTIK (Jurnal Teknologi Informasi dan Komunikasi)*, 7(4), 636–643.
- Purwati, N., & Karnila, S. (2023). Strategi peningkatan penjualan produk menggunakan Market Basket Analysis. *Jurnal Sistem Informasi Bisnis*, 13(2), 96–103.
- Putra, E. D., Rifqo, M. H., & Hardianto, D. (2022). Implementasi algoritma Apriori pada Market Basket Analysis (MBA) aksesoris telepon seluler. *Jurnal Komputer, Informasi dan Teknologi (J-KOMITEK)*, 2(2).
- Ramadhani, N., Syahroni, A. W., Supikar, A., & Zumann, W. (2020). Penerapan Market Basket Analysis menggunakan metode Multilevel Association Rules dan algoritma

- ML_T2L1 pada data order PT. Unirama. *InfoTekJar: Jurnal Nasional Informatika dan Teknologi Jaringan*, 4(2), 261–274.
- Ridho, A. N., Masa, A. P. A., & Widagdo, P. P. (2024). Implementasi Market Basket Analysis pada data penjualan CV. XYZ menggunakan algoritma FP-Growth. *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, 12(3), 1985–1994.
- Rizaldi, D., & Adnan, A. (2021). Market Basket Analysis menggunakan algoritma Apriori: Kasus transaksi 212 Mart Soebrantas Pekanbaru. *Jurnal Statistika dan Aplikasinya*, 5(1), 31–40.
- Safitry, D. L., Rosianti, N., Divyaning, E., Zidan, H., Arnecia, Z. J., Paryudi, I., Veritawati, I., & Nursari, S. R. C. (2025). Analisis pola pembelian konsumen menggunakan algoritma Apriori untuk menentukan strategi pemasaran produk di toko retail X. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(1), 505–511.
- Setyorini, S. G., Sari, E. K., Elita, L. R., & Putri, S. A. (2021). Market basket analysis with K-Means and FP-Growth algorithm as Citra Mustika Pandawa Company. *Journal of Applied Informatics and Computing*, 5(1), 1–8.
- Simanjuntak, A. C., Sitanggang, M. E., Cahyani, M. I., & Syahputri, N. (2024). Penerapan metode data mining Market Basket Analysis terhadap data penjualan produk pada Toko Iblite Luxury menggunakan algoritma Apriori. *BRIDGE: Jurnal Ilmiah Teknik*, 2(3), 62–74.
- Thariq, A. (2023). Implementasi Market Basket Analysis menggunakan algoritma Apriori pada data penjualan buku. *Jurnal Kolaboratif Sains (JKS)*, 6(3), 154–163.
- Umar, E., Manongga, D., & Iriani, A. (2022). Market Basket Analysis menggunakan association rule dan algoritma Apriori pada produk penjualan Mitra Swalayan Salatiga. *Jurnal Media Informatika Budidarma*, 6(3), 1367–1377.
- Widodo, A. A., & Fachrudin, I. A. (2022). Prediksi itemset promosi penjualan menggunakan metode Market Basket Analysis. *KONVERGENSI*, 18(1), 18–24.
- Workspace, A. N. K. S. (2025). Retail POS dataset for Market Basket Analysis. Kaggle. <https://www.kaggle.com/datasets/arunworkspace/retail-pos-dataset-for-market-basket-analysis>