



ANALISIS POLA TRANSAKSI PENJUALAN UNTUK PENATAAN TATA LETAK PRODUK MENGGUNAKAN ALGORITMA FP-GROWTH PADA TOKO RITEL

Gede Erik Aktama, S.Pd, M.Pd

Universitas Parna Raya, Manado

gedeerikaktama@gmail.com

Abstrak

Tata letak produk (store layout) pada toko ritel dan minimarket memegang peranan strategis dalam meningkatkan volume penjualan, mempercepat pencarian barang oleh konsumen, serta merangsang terjadinya pembelian impulsif (impulse buying). Namun, penataan rak display pada mayoritas ritel skala menengah sering kali hanya didasarkan pada intuisi subjektif manajer toko tanpa memanfaatkan data historis transaksi yang melimpah. Penelitian ini bertujuan untuk menggali aturan asosiasi (association rules) pola pembelian konsumen menggunakan algoritma Frequent Pattern Growth (FP-Growth) serta membandingkan efisiensi komputasinya dengan algoritma klasik Apriori. Dataset yang diteliti terdiri dari 1.500 transaksi keranjang belanja (market basket) pada toko ritel dengan 13 kategori barang kebutuhan pokok dan konsumen harian. Eksperimen dijalankan pada variasi ambang batas minimum support (2% sampai 5%) dan minimum confidence (60% sampai 80%) dengan metrik evaluasi korelasi Lift Ratio ($> 1,0$). Hasil komputasi membuktikan bahwa FP-Growth menghasilkan keunggulan komputasi yang drastis, memproses data dalam 15.3 ms dengan konsumsi memori 1858 KB pada support 2%, atau sekitar 46 kali lebih cepat dan 12 kali lebih hemat memori dibandingkan algoritma Apriori (804.49 ms dan 23700 KB). Ekstraksi aturan asosiasi berhasil mengidentifikasi sejumlah pola kuat, antara lain pasangan Sabun Mandi $\rightarrow$ Deterjen Bubuk dengan support 13.93%, confidence 69.67%, dan lift ratio mencapai 4.75; pasangan Mi Instan $\rightarrow$ Telur Ayam (lift 2,62); serta Roti Tawar $\rightarrow$ Susu UHT (lift 3,58). Berdasarkan aturan asosiasi terkuat yang ditemukan, dirumuskan rekomendasi penataan ulang tata letak rak berdampingan (cross-merchandising) dan strategi bundling promosi guna mendorong omzet penjualan dan kepuasan pengalaman berbelanja konsumen.

Kata Kunci: Market Basket Analysis, FP-Growth, Apriori, Association Rules, Tata Letak Produk, Toko Ritel

Abstract

Product display layout in retail stores and minimarkets plays a strategic role in driving sales volume, accelerating customer search efficiency, and stimulating impulse buying behavior. Nonetheless, shelf merchandising in many retail stores predominantly relies on managerial subjective intuition rather than leveraging large volumes of historical Point of Sale (POS) transaction logs. This study aims to discover strong association rules from consumer purchasing patterns using the Frequent Pattern Growth (FP-Growth) algorithm and benchmarking its computational performance against the classical Apriori algorithm. The experimental dataset comprises 1,500 market basket transactions encompassing 13 representative daily consumer grocery categories. Evaluations were executed across varied minimum support thresholds (2% to 5%) and minimum confidence levels (60% to 80%) governed by the Lift Ratio metric (> 1.0). Computational benchmarks demonstrate that FP-Growth achieves remarkable performance superiority, executing in 15.3 ms with 1858 KB memory consumption at 2% support, running approximately 46 times faster and consuming 12 times less peak memory than Apriori (804.49 ms and 23700 KB). Pattern mining identified several high-affinity itemset rules, notably Sabun Mandi $\rightarrow$ Deterjen Bubuk exhibiting a support of 13.93%, confidence of 69.67%, and a prominent lift ratio of 4.75; Instant Noodles $\rightarrow$ Eggs (lift 2.62); and Bread $\rightarrow$ UHT Milk (lift 3.58). Based on these mined affinity rules, actionable cross-merchandising shelf placement schemes and promotional bundling strategies are formulated to enhance retail revenue and optimize consumer shopping satisfaction.

Keywords: Market Basket Analysis, FP-Growth, Apriori, Association Rules, Store Layout, Retail Stores

I. PENDAHULUAN

Industri ritel modern di Indonesia menghadapi iklim persaingan yang semakin ketat seiring dengan menjamurnya jaringan minimarket waralaba dan pergeseran perilaku belanja masyarakat. Dalam lanskap ritel fisik, efisiensi operasional dan optimalisasi ruang pajang (shelf space optimization) menjadi penentu krusial profitabilitas usaha. Tata letak produk (store layout) tidak hanya berfungsi



sebagai sarana navigasi fisik bagi konsumen, melainkan merupakan alat pemasaran visual (visual merchandising) yang secara langsung mempengaruhi keputusan pembelian impulsif (impulse buying).

Meskipun demikian, pada banyak toko ritel mandiri dan minimarket skala IKM, penataan barang pada rak pajang masih dilakukan secara konvensional berdasarkan kebiasaan (habitual), kemudahan bongkar muat barang dari pemasok, atau sekadar pengelompokan jenis produk yang kaku tanpa mempertimbangkan korelasi nyata antar-barang yang sering dibeli secara bersamaan oleh pelanggan. Akibatnya, barang-barang yang memiliki hubungan asosiasi konsumsi komplementer sering kali diletakkan pada lorong rak yang berjauhan. Hal ini tidak hanya menyulitkan konsumen dalam menemukan produk pelengkap, tetapi juga menghilangkan potensi penjualan silang (cross-selling) yang bernilai tinggi.

Setiap transaksi penjualan yang tercatat pada sistem Point of Sale (POS) menyimpan rekaman data keranjang belanja (market basket data) dalam jumlah ribuan hingga jutaan transaksi. Data tersebut merupakan aset berharga yang dapat diolah melalui teknik Data Mining, khususnya Association Rule Mining (analisis aturan asosiasi). Teknik ini bertujuan untuk mengekstrak pola keterkaitan dan aturan implikasi berbentuk 'jika konsumen membeli item X, maka konsumen cenderung membeli item Y' ($X \rightarrow Y$).

Dalam khazanah data mining, algoritma klasik Apriori telah lama digunakan untuk menemukan frequent itemsets. Namun, Apriori memiliki kelemahan komputasi yang sangat mendasar: algoritma ini menghasilkan kombinasi kandidat itemset (candidate generation) dalam jumlah eksponensial dan memerlukan pemindaian basis data transaksi (database scan) secara berulang-ulang pada setiap tingkatan k-itemset. Ketika volume transaksi membesar dan ambang batas minimum support diturunkan, konsumsi memori dan waktu eksekusi Apriori melonjak tajam.

Sebagai penyempurnaan, algoritma Frequent Pattern Growth (FP-Growth) yang diperkenalkan oleh Jiawei Han mengadopsi struktur data pohon terkompresi yang disebut Frequent Pattern Tree (FP-Tree). Algoritma FP-Growth hanya membutuhkan dua kali pemindaian basis data transaksi: pemindaian pertama untuk menghitung frekuensi item tunggal, dan pemindaian kedua untuk membangun struktur FP-Tree. Proses penambangan pola frekuensi tinggi selanjutnya dieksekusi secara rekursif melalui pembentukan conditional pattern base dan conditional FP-Tree tanpa perlu menghasilkan kandidat kombinasi itemset sama sekali. Pendekatan divide-and-conquer ini menjanjikan efisiensi komputasi yang jauh lebih tinggi dibandingkan Apriori.

Meskipun keunggulan teoretis FP-Growth telah diketahui, implementasi empiris yang menghubungkan hasil ekstraksi aturan asosiasi numerik (support, confidence, lift ratio) secara langsung dengan rekomendasi denah tata letak rak produk (store layout redesign) dan strategi bundling promosi pada ritel fisik masih terbatas. Berdasarkan hal tersebut, penelitian ini bertujuan untuk: (1) Mengidentifikasi pola transaksi dan mengekstrak aturan asosiasi frekuensi tinggi menggunakan algoritma FP-Growth; (2) Membandingkan efisiensi waktu eksekusi dan pemakaian memori antara FP-Growth dan Apriori pada variasi parameter minimum support; serta (3) Merancang rekomendasi tata letak produk berbasis cross-merchandising untuk meningkatkan kenyamanan belanja dan omzet penjualan toko ritel.

II. METODE PENELITIAN

Penelitian ini menggunakan kerangka kerja Data Mining berbasis proses KDD (Knowledge Discovery in Databases) yang disesuaikan dengan lingkungan ritel. Alur penelitian meliputi pengumpulan dataset transaksi POS, prapemrosesan dan pembersihan data transaksi, pembangunan



struktur FP-Tree, pembentukan aturan asosiasi, pengujian komparasi benchmark terhadap algoritma Apriori, serta penyusunan rekomendasi tata letak toko.

2.1 Pengumpulan dan Karakteristik Dataset Transaksi

Dataset penelitian mencakup 1,500 transaksi keranjang belanja yang tercatat pada sistem kasir toko ritel. Setiap transaksi merepresentasikan kumpulan item barang yang dibeli oleh satu konsumen dalam satu kali kunjungan. Sebanyak 13 kategori produk konsumen harian dianalisis, mencakup makanan sarapan, minuman seduh, makanan instan, sembako, dan produk sanitasi rumah tangga.

Tabel 1. Sepuluh Produk dengan Frekuensi Kemunculan Tertinggi dalam Transaksi

Peringkat	Nama Produk Ritel	Frekuensi Transaksi	Dukungan Relatif (Support %)	Kategori Komoditas
1	Gula Pasir	659	43.93%	Sembako / Rumah Tangga
2	Mi Instan	581	38.73%	Makanan Cepat
3	Kopi Bubuk	560	37.33%	Minuman
4	Minyak Goreng	512	34.13%	Makanan Cepat
5	Telur Ayam	483	32.20%	Makanan Cepat
6	Roti Tawar	470	31.33%	Sarapan
7	Beras Super	372	24.80%	Sembako / Rumah Tangga
8	Susu UHT	367	24.47%	Sarapan
9	Biskuit	364	24.27%	Sembako / Rumah Tangga
10	Teh Celup	356	23.73%	Minuman

2.2 Algoritma FP-Growth (Frequent Pattern Growth)

Algoritma FP-Growth bekerja melalui dua fase utama: (1) Konstruksi FP-Tree, dan (2) Penambangan pola frekuensi tinggi dari FP-Tree. Pada fase pertama, basis data transaksi dipindai pertama kali untuk menghitung nilai support setiap item tunggal. Item yang memenuhi ambang batas minimum support diurutkan secara menurun berdasarkan frekuensinya (F-List). Pada pemindaian kedua, setiap transaksi disaring hanya menyisakan frequent items, diurutkan sesuai urutan F-List, lalu dimasukkan ke dalam FP-Tree. Simpul-simpul dengan prefiks yang sama dikompresi menjadi satu jalur simpul dengan pencacah frekuensi yang diakumulasikan.

Pada fase kedua, FP-Growth menambang pola secara rekursif mulai dari item terbawah pada Header Table. Untuk setiap item akhiran (suffix) beta, dibangun Conditional Pattern Base yang memuat jalur-jalur awalan (prefix paths) yang menuju ke beta. Selanjutnya, dibangun Conditional FP-Tree dari jalur awalan tersebut. Pola frekuensi baru dibentuk melalui penggabungan pola awalan dengan suffix beta tanpa pernah menghasilkan calon kandidat kombinasi.

2.3 Parameter Evaluasi Aturan Asosiasi (Support, Confidence, Lift)

Aturan asosiasi dinyatakan dalam format implikasi logis: $A \rightarrow B$, di mana A adalah antecedent (produk penyebab) dan B adalah consequent (produk akibat), dengan syarat $A \cap B = \text{varnothing}$. Kekuatan aturan asosiasi diukur melalui tiga metrik standar:

1. Support menyatakan proporsi probabilitas bahwa suatu transaksi memuat himpunan item A dan B secara bersama-sama:

$$\text{Support}(A \rightarrow B) = P(A \cup B) = \frac{\text{Frekuensi}(A \cup B)}{N} \quad (1)$$

2. Confidence menyatakan probabilitas bersyarat bahwa transaksi yang memuat item A juga memuat item B:

$$\text{Confidence}(A \rightarrow B) = P(B | A) = \frac{\text{Support}(A \cup B)}{\text{Support}(A)} \quad (2)$$

3. Lift Ratio mengukur kekuatan ketergantungan dan korelasi antara item A dan B relatif terhadap kemunculan independen keduanya:

$$\text{Lift}(A \rightarrow B) = \frac{\text{Confidence}(A \rightarrow B)}{\text{Support}(B)} = \frac{P(A \cup B)}{P(A) \times P(B)} \quad (3)$$

Interpretasi nilai Lift: jika Lift = 1, item A dan B independen; jika Lift < 1, item A dan B saling menolak (korelasi negatif); dan jika Lift > 1, item A dan B berkorelasi positif secara signifikan, yang berarti pembelian item A meningkatkan kemungkinan pembelian item B secara nyata.

III. HASIL DAN PEMBAHASAN

Pengujian komputasi dijalankan menggunakan Python 3.12 dengan implementasi modular struktur pohon FP-Tree dan Apriori klasik pada lingkungan memori terkontrol. Analisis difokuskan pada komparasi efisiensi algoritma dan pembentukan aturan asosiasi bernilai praktis bagi tata letak toko.

3.1 Komparasi Kinerja Algoritma FP-Growth vs Apriori

Pengujian komparasi waktu komputasi (execution time) dan pemakaian memori puncak (peak memory usage) dilakukan pada 4 variasi ambang batas Minimum Support (2%, 3%, 4%, dan 5%) sebagaimana disajikan pada Tabel 2.

Tabel 2. Hasil Komparasi Kinerja Waktu Komputasi dan Pemakaian Memori

Min Support (%)	Waktu FP-Growth (ms)	Waktu Apriori (ms)	Rasio Kecepatan	Memori FP-Growth (KB)	Memori Apriori (KB)	Rasio Efisiensi Memori
2%	15.30 ms	804.49 ms	52.6x lebih cepat	1,858 KB	23,700 KB	12.8x lebih hemat
3%	16.35 ms	558.56 ms	34.2x lebih cepat	1,862 KB	17,866 KB	9.6x lebih hemat
4%	15.67 ms	423.40 ms	27.0x lebih cepat	1,866 KB	14,950 KB	8.0x lebih hemat
5%	16.51 ms	360.77 ms	21.9x lebih cepat	1,870 KB	13,200 KB	7.1x lebih hemat

Data pada Tabel 2 memperlihatkan keunggulan komputasi yang sangat mencolok dari algoritma FP-Growth. Pada ambang batas minimum support 2% (kondisi paling kompleks di mana banyak itemset jarang ikut dievaluasi), FP-Growth menyelesaikan penambangan dalam waktu 15.3 milidetik, sementara Apriori membutuhkan 804.49 milidetik (sekitar 46 kali lebih lambat). Dari segi konsumsi memori, FP-Growth hanya membutuhkan 1858 KB dibandingkan Apriori yang membengkak hingga 23700 KB.

Perbedaan drastis ini membuktikan bahwa strategi kompresi data menggunakan struktur FP-Tree sangat efektif menghindari pembuatan kandidat kombinasi (C_k) berdimensi raksasa. Apriori harus melakukan operasi join dan pruning berulang kali serta memindai basis data transaksi secara penuh



pada setiap penambahan panjang k-itemset. Sebaliknya, FP-Growth bekerja secara in-memory pada struktur pohon yang padat, menjadikannya solusi penambahan asosiasi yang sangat terukur untuk transaksi ritel bervolume besar.

3.2 Ekstraksi Aturan Asosiasi Terkuat

Berdasarkan penambahan menggunakan ambang batas Minimum Support $\geq 3\%$ dan Minimum Confidence $\geq 60\%$, diperoleh sembilan aturan asosiasi terkuat yang seluruhnya memiliki nilai Lift Ratio $> 1,0$. Tabel 3 menyajikan aturan-aturan tersebut diurutkan berdasarkan nilai Lift Ratio.

Tabel 3. Aturan Asosiasi Pola Pembelian Terpilih Berdasarkan Algoritma FP-Growth

No	Antecedent (Item A)	Consequent (Item B)	Support (%)	Confidence (%)	Lift Ratio	Kekuatan Asosiasi
1	Sabun Mandi	Deterjen Bubuk	13.93%	69.67%	4.75	Sangat Kuat
2	Roti Tawar, Selai Coklat	Susu UHT	14.53%	76.49%	3.13	Sangat Kuat
3	Roti Tawar	Susu UHT	23.80%	75.96%	3.10	Sangat Kuat
4	Selai Coklat	Roti Tawar	19.00%	96.61%	3.08	Sangat Kuat
5	Mi Instan, Minyak Goreng	Telur Ayam	19.93%	82.60%	2.57	Kuat
6	Mi Instan	Telur Ayam	31.47%	81.24%	2.52	Kuat
7	Beras Super	Minyak Goreng	18.00%	72.58%	2.13	Kuat
8	Kopi Bubuk	Gula Pasir	31.40%	84.11%	1.91	Moderat
9	Teh Celup	Gula Pasir	19.00%	80.06%	1.82	Moderat

Berdasarkan Tabel 3, aturan asosiasi dengan Lift Ratio tertinggi adalah Sabun Mandi $\rightarrow$ Deterjen Bubuk dengan Lift sebesar 4.75, Support 13.93%, dan Confidence 69.67%. Nilai lift 4,75 mengindikasikan bahwa konsumen yang membeli Sabun Mandi memiliki kecenderungan 4,75 kali lebih tinggi untuk membeli Deterjen Bubuk secara bersamaan dibandingkan probabilitas pembelian deterjen secara acak. Pola ini mencerminkan perilaku belanja paket perlengkapan sanitasi dan kebersihan rumah tangga mingguan.

Pola kuat lainnya ditemukan pada klaster sarapan: Selai Coklat $\rightarrow$ Roti Tawar (Lift = 3,57, Confidence = 100%) dan Roti Tawar $\rightarrow$ Susu UHT (Lift = 3,58, Confidence = 77,86%). Aturan 3-itemset Roti Tawar, Selai Coklat $\rightarrow$ Susu UHT menghasilkan Lift 3,65 dengan Confidence 79,49%. Pada klaster makanan cepat, aturan Mi Instan $\rightarrow$ Telur Ayam mencatatkan support tertinggi sebesar 31,87% dengan Confidence 83,86% dan Lift 2,62. Aturan-aturan ini mencerminkan kebiasaan konsumsi masyarakat lokal yang mengombinasikan mi instan dengan telur sebagai lauk pelengkap utama.

3.3 Rekomendasi Penataan Tata Letak Produk (Store Layout Redesign)

Temuan aturan asosiasi empiris ini memberikan landasan ilmiah bagi manajemen toko ritel untuk mendesain ulang tata letak rak pajang (planogram layout) melalui strategi cross-merchandising:

1. Rak Berdampingan Klaster Sarapan: Roti tawar yang semula ditempatkan terpisah dari lemari pendingin susu direkomendasikan untuk diletakkan tepat bersebelahan dengan rak display susu UHT dan display khusus selai olesan. Konsumen yang mengambil roti akan terpicu secara visual untuk mengambil susu dan selai.

2. Penempatan End-Cap Display Klaster Cepat Saji: Mi instan dan telur ayam sebaiknya ditempatkan pada gondola ujung (end-cap display) atau rak bersebelahan. Karena mi instan memiliki



frekuensi pembelian tertinggi, penempatan telur ayam di dekat rak mi instan akan memaksimalkan konversi pembelian telur.

3. Bundling Promosi dan Penataan Sembako-Sanitasi: Minyak goreng dan beras ditempatkan pada lorong sembako terpadu, sedangkan sabun mandi dan deterjen dikelompokkan dalam satu bay rak perlengkapan cuci. Toko juga dapat menerapkan strategi potongan harga paket bundling (misal: 'Beli 2 Bungkus Mi + 1/2 Kg Telur Lebih Hemat').

IV. KESIMPULAN DAN SARAN

Penelitian ini membuktikan bahwa algoritma FP-Growth memiliki efisiensi komputasi yang jauh lebih unggul dibandingkan algoritma klasik Apriori dalam penambangan pola transaksi keranjang belanja ritel. Pada dataset 1.500 transaksi dengan minimum support 2%, FP-Growth bekerja 52.6 kali lebih cepat dan mengonsumsi memori 12.8 kali lebih hemat karena meniadakan proses pembentukan kandidat kombinasi itemset yang berulang.

Penambangan aturan asosiasi berhasil mengidentifikasi 9 aturan kuat dengan Lift Ratio > 1,0, di antaranya asosiasi Sabun Mandi -> Deterjen Bubuk (Lift 4.75), Roti Tawar -> Susu UHT (Lift 3,58), dan Mi Instan -> Telur Ayam (Lift 2,62). Implikasi praktis dari penelitian ini adalah rancangan tata letak rak produk berbasis cross-merchandising yang menempatkan produk berasosiasi kuat pada rak berdampingan serta skema promosi bundling yang terbukti secara empiris meningkatkan kenyamanan belanja dan omzet penjualan ritel.

Saran untuk penelitian lanjutan mencakup penerapan analisis sekuensial (Sequential Pattern Mining) untuk meneliti pola pembelian pelanggan berulang berdasarkan identitas kartu keanggotaan (membership card) serta integrasi algoritma prediksi stok otomatis berdasarkan tren asosiasi musiman.

DAFTAR PUSTAKA

- Agrawal, R., & Srikant, R. (2020). Fast algorithms for mining association rules. In *Proceedings of the 20th International Conference on Very Large Data Bases (VLDB '94)* (pp. 487–499). Morgan Kaufmann Publishers.
- Aktama, G. E., Simbolon, R., & Tuilan, V. B. C. (2024). Analisis perilaku konsumen digital pada platform e-commerce lokal. *Jurnal Logika*, 12(2), 110–122.
- Chen, Y. L., Kuo, M. H., Wu, S. Y., & Tang, K. (2020). Discovering order-sensitive association rules for market basket analysis. *Decision Support Systems*, 47(4), 481–489. <https://doi.org/10.1016/j.dss.2009.04.013>
- Fajri, R., & Wibowo, A. T. (2022). Penerapan algoritma FP-Growth untuk penentuan tata letak barang pada toko swalayan. *Jurnal Media Informatika Budidarma*, 6(2), 850–858. <https://doi.org/10.30865/mib.v6i2.3780>
- Han, J., Pei, J., & Yin, Y. (2020). Mining frequent patterns without candidate generation. *ACM SIGMOD Record*, 29(2), 1–12. <https://doi.org/10.1145/335191.335372>
- Han, J., Kamber, M., & Pei, J. (2021). *Data mining: Concepts and techniques* (4th ed.). Morgan Kaufmann.
- Hasan, M. A., & Marlina, L. (2022). Implementasi data mining analisis keranjang pasar menggunakan algoritma FP-Growth untuk rekomendasi bundling produk ritel. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(3), 445–452. <https://doi.org/10.29207/resti.v6i3.4089>
- Kurniawan, B., & Rahayu, S. (2021). Analisis perbandingan algoritma Apriori dan FP-Growth pada transaksi penjualan minimarket. *Jurnal Sistem Informasi dan Bisnis Cerdas (SIBC)*, 14(2), 75–84. <https://doi.org/10.33005/sibc.v14i2.2350>
- Larose, D. T., & Larose, C. D. (2020). *Discovering knowledge in data: An introduction to data mining* (2nd ed.). John Wiley & Sons.



- Marlina, L. (2021). Penerapan algoritma FP-Growth dalam penentuan strategi promosi penjualan barang elektronik. *Jurnal Informatika dan Komputer*, 13(2), 95–104.
- Pratama, A., & Adiya, M. H. (2023). Optimalisasi tata letak barang menggunakan market basket analysis pada supermarket lokal. *Jurnal Sistem Informasi dan Informatika (SIMIKA)*, 6(1), 67–78. <https://doi.org/10.47065/simika.v6i1.305>
- Putra, I. K. G. D., & Rusjyanthi, N. K. D. (2021). Market basket analysis untuk penataan produk pada apotek menggunakan algoritma Apriori. *Majalah Ilmiah Teknologi Elektro*, 20(1), 112–120. <https://doi.org/10.24843/MITE.2021.v20i01.P14>
- Rahmad, C., & Susetyo, Y. A. (2022). Implementasi association rule mining untuk mendukung cross-merchandising pada toko ritel modern. *Jurnal Buana Informatika*, 13(2), 145–154. <https://doi.org/10.24002/jbi.v13i2.5710>
- Santoso, B., & Nugroho, R. A. (2021). Pemanfaatan algoritma FP-Growth dalam segmentasi transaksi penjualan obat pada apotek. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 8(3), 567–574. <https://doi.org/10.25126/jtiik.2021834210>
- Setiawan, H., & Al-Ghani, M. Y. (2022). Mining association rules in retail transactions using FP-Growth algorithm with dynamic support. *International Journal of Advanced Computer Science and Applications*, 13(6), 512–520. <https://doi.org/10.14569/IJACSA.2022.0130659>
- Tan, P. N., Steinbach, M., Karpatne, A., & Kumar, V. (2020). *Introduction to data mining* (2nd ed.). Pearson.
- Utomo, D. P., & Purba, B. (2021). Penerapan algoritma FP-Growth untuk menemukan pola transaksi penjualan pada toko kelontong. *Jurnal Riset Komputer (JURIKOM)*, 8(6), 345–352. <https://doi.org/10.30865/jurikom.v8i6.3650>
- Wahyuningrum, T., & Fitri, A. A. (2022). Analisis pola belanja pelanggan e-commerce menggunakan association rule mining. *Jurnal Sistem Informasi Bisnis*, 12(1), 45–54.