JTIS : Journal of Technopreneurship and Information Systems
Vol. 9, No.1, Februari 2026, hal.21~25
E-ISSN: 2614-3054; P-ISSN: 2614-3062, accredited by Kemenristekdikti, Sinta 5
DOI: 10.36085

IMPLEMENTASI METODE ASSOCIATION RULE DAN ALGORITMA FP-GROWTH PADA PENGENDALIAN PERSEDIAAN BARANG

[1]Ramadhan Adesyaputra, [2]Dedy Abdullah, [3]Anisya Sonita
[1,2,3] Universitas Muhammadiyah Bengkulu, Indonesia
[1] ramadhan.adesaputra12@gmail.com ; [2]dedyabdullah.@ac.id.umb; [3]anisasonita@ac.id.umb;

Article Info

Article history:

Received, 2026-01-10
Revised, 2026-02-15
Accepted, 2026-02- 20

Kata Kunci:

Association Rule Mining, FP-Growth, pengendalian persediaan, inventaris TI, *frequent itemset*, aturan asosiasi.

ABSTRAK

Berdasarkan uraian penelitian, penerapan *Association Rule Mining* (ARM) dengan algoritma FP-Growth dapat menjadi pendekatan yang efektif dalam mengoptimalkan pengendalian persediaan di lingkungan Teknologi Informasi. Algoritma FP-Growth mampu mengidentifikasi *frequent itemset* serta menemukan pola keterkaitan antaritem persediaan berdasarkan data transaksi. Melalui analisis *support*, *confidence*, dan *lift ratio*, aturan asosiasi yang dihasilkan dapat dimanfaatkan sebagai dasar dalam memberikan rekomendasi pengadaan, penyediaan, dan pengendalian stok secara lebih tepat. Dibandingkan pendekatan tradisional, FP-Growth memiliki keunggulan dalam mengolah data transaksi dalam jumlah besar secara lebih efisien karena tidak memerlukan pembentukan kandidat itemset secara berulang. Dengan demikian, penerapan metode ini berpotensi meningkatkan efektivitas dan efisiensi pengelolaan inventaris, mengurangi risiko kelebihan maupun kekurangan stok, serta mendukung pengambilan keputusan berbasis data. Penelitian ini diharapkan dapat menjadi dasar pengembangan sistem pengendalian persediaan yang adaptif terhadap kebutuhan organisasi di lingkungan TI.

Keywords:

Association Rule Mining, FP-Growth, inventory control, IT inventory, *frequent itemset*, association rules.

ABSTRACT

Based on the research description, the application of *Association Rule Mining* (ARM) using the FP-Growth algorithm can serve as an effective approach to optimizing inventory control in an Information Technology environment. The FP-Growth algorithm is capable of identifying *frequent itemsets* and discovering patterns of relationships among inventory items based on transaction data. Through the analysis of *support*, *confidence*, and *lift ratio*, the resulting association rules can be utilized as a basis for providing more accurate recommendations for procurement, stock availability, and inventory control. Compared to traditional approaches, FP-Growth offers advantages in processing large volumes of transaction data more efficiently because it does not require repeated candidate itemset generation. Therefore, the application of this method has the potential to improve the effectiveness and efficiency of inventory management, reduce the risks of overstocking and stock shortages, and support data-driven decision-making. This research is expected to serve as a foundation for developing an inventory control system that is adaptive to organizational needs in an IT environment.

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

Penulis Korespondensi:

Ramadhan Ade Saputra,
Program Studi Teknik Infromasi,
Universitas Muhammadiyah Bengkulu,
Email: ramadhan.adesaputra12@gmail.com

1. PENDAHULUAN

Pengendalian persediaan merupakan salah satu komponen penting dalam manajemen rantai pasokan karena berhubungan langsung dengan ketersediaan barang, biaya penyimpanan, dan kualitas pelayanan. Persediaan

JTIS : Journal of Technopreneurship and Information Systems
Vol. 9, No.1, Februari 2026, hal.21~25
E-ISSN: 2614-3054; P-ISSN: 2614-3062, accredited by Kemenristekdikti, Sinta 5
DOI: 10.36085

yang terlalu rendah dapat menyebabkan stockout, sedangkan persediaan yang terlalu tinggi dapat meningkatkan biaya penyimpanan dan risiko penumpukan barang. Dalam lingkungan bisnis yang menghasilkan data transaksi dalam jumlah besar, keputusan pengadaan dan pengendalian stok perlu didukung oleh informasi yang berasal dari data historis, bukan hanya pengalaman pengelola.

Pada lingkungan Teknologi Informasi maupun ritel yang mengelola beragam kategori barang, kompleksitas data semakin tinggi. Data transaksi tidak hanya memuat informasi produk, tetapi juga dapat memuat karakteristik pelanggan, metode pembayaran, waktu transaksi, dan atribut lain yang berpotensi menjelaskan pola pembelian. Namun, data tersebut sering hanya digunakan sebagai arsip administrasi sehingga hubungan antaritem yang muncul secara berulang belum dimanfaatkan secara optimal. Penelitian terdahulu yang dirangkum dalam skripsi menunjukkan bahwa pendekatan tradisional dapat mengalami keterbatasan ketika harus mengolah dataset besar dan menemukan korelasi tersembunyi antarproduk.

Association Rule Mining (ARM) merupakan salah satu teknik data mining yang digunakan untuk menemukan hubungan atau pola kemunculan item secara bersamaan dalam basis data transaksi. Konsep aturan asosiasi dapat dinyatakan dalam bentuk $X \rightarrow Y$, dengan kekuatan aturan dinilai melalui support, confidence, dan lift. Pendekatan ini telah banyak digunakan dalam analisis transaksi karena mampu menghasilkan informasi yang dapat diterjemahkan menjadi rekomendasi operasional. Algoritma FP-Growth dikembangkan untuk menemukan frequent itemset secara efisien melalui struktur FP-tree dan menghindari pembangkitan kandidat itemset secara berulang seperti pada pendekatan Apriori [1], [2].

Keunggulan FP-Growth menjadi relevan ketika data transaksi berukuran besar dan pola yang ingin ditemukan cukup beragam. Han, Pei, dan Yin menjelaskan bahwa FP-Growth melakukan kompresi basis data ke dalam FP-tree dan menggunakan pendekatan pattern growth sehingga mengurangi kebutuhan pemindaian basis data secara berulang [1]. Implementasi lain juga menunjukkan bahwa FP-Growth merupakan salah satu pendekatan cepat untuk frequent itemset mining [3]. Penelitian mengenai pengendalian persediaan yang dirangkum dalam skripsi juga menunjukkan pemanfaatan FP-Growth untuk membantu menentukan pola pembelian dan mendukung keputusan stok [4], [5].

Penelitian ini berfokus pada implementasi metode Association Rule dengan algoritma FP-Growth pada data transaksi penjualan supermarket. Tujuannya adalah mengidentifikasi frequent itemset dan association rule, kemudian menafsirkan pola tersebut sebagai informasi pendukung pengendalian persediaan. Kontribusi penelitian terletak pada pemanfaatan atribut kategori produk bersama atribut transaksi lain untuk membentuk pola yang dapat dibaca secara terpadu. Hasil penelitian diharapkan dapat membantu pengelola memprioritaskan perhatian pada kategori produk dengan frekuensi kemunculan relatif tinggi, sekaligus memberikan informasi mengenai karakteristik transaksi yang dapat digunakan untuk mendukung strategi pengadaan dan promosi.

2. METODE PENELITIAN

Penelitian menggunakan pendekatan data mining dengan kerangka Knowledge Discovery in Databases (KDD). Data yang digunakan merupakan data sekunder berupa Supermarket Sales Cleaned Dataset dari Kaggle. Dari dataset tersebut digunakan 1.000 transaksi pertama sebagai objek analisis. Dataset awal memiliki 10 atribut, yaitu Invoice ID, Branch, City, Customer Type, Gender, Product Line, Payment, Quantity, Total, dan Rating. Pemilihan 1.000 transaksi dilakukan untuk memperoleh basis data yang terukur dalam proses penggalian pola transaksi.

Tahap selection dilakukan dengan memilih atribut yang relevan dengan karakteristik item dalam Association Rule. Empat atribut kategorikal yang digunakan adalah Product Line, Payment, Customer Type, dan Gender. Atribut numerik Quantity, Total, dan Rating tidak digunakan secara langsung karena pada penelitian ini FP-Growth diterapkan pada representasi item kategorikal berbentuk biner. Pemilihan atribut tersebut mengikuti rancangan penelitian dalam skripsi yang menempatkan kategori produk sebagai item utama dan atribut transaksi sebagai informasi pendukung.

Tahap preprocessing dilakukan untuk memastikan kualitas data. Pemeriksaan missing value dilakukan dengan df.isnull().sum(), sedangkan baris yang tidak lengkap ditangani menggunakan df.dropna(). Data duplikat dihapus menggunakan df.drop_duplicates() agar satu transaksi tidak dihitung lebih dari satu kali. Setelah proses pembersihan, data berada dalam kondisi yang siap ditransformasikan ke format transaksi.

Pada tahap transformation, setiap baris transaksi diubah menjadi daftar item yang terdiri dari Product Line, Payment, Customer Type, dan Gender. Representasi transaksi kemudian dikonversi ke bentuk one-hot encoding menggunakan TransactionEncoder. Nilai True/1 menunjukkan bahwa item terdapat dalam transaksi, sedangkan False/0 menunjukkan bahwa item tidak terdapat dalam transaksi. Bentuk biner ini digunakan sebagai masukan algoritma FP-Growth.

JTIS : Journal of Technopreneurship and Information Systems
Vol. 9, No.1, Februari 2026, hal.21~25
E-ISSN: 2614-3054; P-ISSN: 2614-3062, accredited by Kemenristekdikti, Sinta 5
DOI: 10.36085

Tahap data mining dimulai dengan perhitungan support count. Minimum support ditetapkan sebesar 0,10 atau 10%, sehingga item harus muncul sedikitnya 100 kali dari 1.000 transaksi untuk dipertahankan. Item yang memenuhi ambang tersebut diurutkan berdasarkan frekuensi, kemudian digunakan untuk membentuk FP-tree. Struktur FP-tree memanfaatkan prefix sharing sehingga transaksi dengan awalan item yang sama dapat disimpan pada jalur yang sama. Setelah FP-tree terbentuk, proses dilanjutkan dengan pembentukan conditional pattern base, conditional FP-tree, dan pencarian frequent itemset.

Frequent itemset diperoleh dengan fungsi FP-Growth pada pustaka mlxtend menggunakan parameter min_support=0.1. Setelah frequent itemset diperoleh, association rule dibentuk dengan minimum confidence 0,5 atau 50%. Evaluasi aturan dilakukan menggunakan support, confidence, dan lift ratio. Support mengukur proporsi transaksi yang mengandung kombinasi item, confidence mengukur tingkat kepastian consequent ketika antecedent muncul, sedangkan lift membandingkan kekuatan hubungan tersebut dengan peluang kemunculan secara independen. Lift lebih besar dari 1 menunjukkan hubungan positif.

Tahap terakhir adalah interpretation/evaluation. Aturan yang dihasilkan diurutkan berdasarkan lift dan dianalisis dari sudut pandang pengendalian persediaan. Interpretasi tidak hanya mempertimbangkan nilai support, tetapi juga confidence dan lift secara bersamaan. Hal ini penting karena item dengan frekuensi tinggi belum tentu memiliki hubungan asosiasi yang kuat dengan item lainnya.

Tahap KDD	Proses	Output
Data	Mengambil 1.000 transaksi pertama dari dataset Kaggle	Dataset transaksi
Selection	Memilih Product Line, Payment, Customer Type, Gender	Atribut analisis
Preprocessing	Memeriksa missing value dan menghapus duplikat	Data bersih
Transformation	Membentuk list transaksi dan one-hot encoding	Matriks biner
Data Mining	FP-Growth, frequent itemset, association rule	Pola dan aturan asosiasi
Interpretation/Evaluation	Menganalisis support, confidence, lift	Rekomendasi pendukung keputusan

Tabel 1. Tahapan penelitian berdasarkan kerangka KDD.

3. HASIL DAN ANALISIS

Dataset yang digunakan terdiri atas 1.000 transaksi. Dari 10 atribut awal, empat atribut kategorikal dipilih untuk proses Association Rule, yaitu Product Line, Payment, Customer Type, dan Gender. Setelah preprocessing, data tidak memiliki missing value dan duplikasi yang digunakan dalam analisis. Data kemudian diubah menjadi daftar transaksi dan direpresentasikan dalam bentuk biner menggunakan one-hot encoding.

Pada tahap support count dengan minimum support 10%, terdapat 13 item tunggal yang memenuhi ambang batas. Item Member dan Female menempati urutan tertinggi dengan support masing-masing 0,501 atau 50,1%. Item Normal dan Male memiliki support 0,499 atau 49,9%. Metode pembayaran Ewallet memiliki support 34,5%, Cash 34,4%, dan Credit card 31,1%. Untuk kategori produk, Fashion accessories memiliki support 17,8%, Food and beverages 17,4%, Electronic accessories 17,0%, Sports and travel 16,6%, Home and lifestyle 16,0%, serta Health and beauty 15,2%. Distribusi kategori produk yang relatif merata menunjukkan bahwa tidak terdapat satu kategori yang mendominasi secara ekstrem.

Item	Support Count	Support
Member	501	50,1%
Female	501	50,1%
Normal	499	49,9%
Male	499	49,9%
Ewallet	345	34,5%
Cash	344	34,4%
Credit card	311	31,1%
Fashion accessories	178	17,8%
Food and beverages	174	17,4%
Electronic accessories	170	17,0%
Sports and travel	166	16,6%
Home and lifestyle	160	16,0%
Health and beauty	152	15,2%

Tabel 2. Item tunggal yang memenuhi minimum support 10%.

JTIS : Journal of Technopreneurship and Information Systems
Vol. 9, No.1, Februari 2026, hal.21~25
E-ISSN: 2614-3054; P-ISSN: 2614-3062, accredited by Kemenristekdikti, Sinta 5
DOI: 10.36085

Frequent itemset yang dihasilkan menunjukkan bahwa kombinasi Female–Member memiliki support 26,1%, sedangkan Normal–Male mencapai 25,9%. Kombinasi Female–Normal dan Male–Member masing-masing memiliki support 24,0%. Pada kombinasi yang melibatkan metode pembayaran, Ewallet–Male memiliki support 18,5%, Normal–Ewallet 18,4%, Cash–Female 17,8%, Cash–Normal 17,6%, Credit card–Member 17,2%, Cash–Member 16,8%, Female–Credit card 16,3%, Ewallet–Member 16,1%, dan Female–Ewallet 16,0%. Kombinasi tiga item Normal–Ewallet–Male memiliki support 10,5% dan menjadi salah satu pola yang memenuhi ambang minimum.

Temuan tersebut memperlihatkan bahwa frequent itemset yang dihasilkan tidak hanya menggambarkan kategori produk, tetapi juga karakteristik transaksi. Dalam konteks pengendalian persediaan, kategori produk dengan support relatif tinggi dapat digunakan sebagai indikator awal untuk menetapkan prioritas pemantauan stok. Fashion accessories dan Food and beverages menjadi dua kategori dengan support produk tertinggi dalam dataset, sehingga keduanya dapat memperoleh perhatian lebih besar dalam penyediaan dan perputaran stok. Namun, support bukan satu-satunya dasar keputusan karena frekuensi kemunculan tidak secara otomatis menunjukkan kekuatan hubungan antaritem.

Setelah frequent itemset diperoleh, association rule dibentuk dengan minimum confidence 50%. Dari aturan yang terbentuk, aturan {Normal, Ewallet} → {Male} memiliki lift tertinggi, yaitu 1,143592, dengan support 0,105 dan confidence 0,570652. Artinya, 10,5% transaksi memuat kombinasi antecedent dan consequent tersebut, sementara ketika transaksi memiliki karakteristik Normal dan Ewallet, consequent Male muncul dengan tingkat confidence sekitar 57,06%. Nilai lift di atas 1 menunjukkan adanya hubungan positif dibandingkan peluang kemunculan secara independen.

Aturan berikutnya adalah {Male, Ewallet} → {Normal} dengan support 0,105, confidence 0,567568, dan lift 1,137410. Aturan {Credit card} → {Member} memiliki support 0,172, confidence 0,553055, dan lift 1,103902. Selanjutnya {Ewallet} → {Male} memiliki support 0,185, confidence 0,536232, dan lift 1,074613, sedangkan {Ewallet} → {Normal} memiliki support 0,184, confidence 0,533333, dan lift 1,068804. Nilai-nilai tersebut menunjukkan adanya korelasi positif, tetapi kekuatan asosiasinya tidak tinggi.

Antecedent	Consequent	Support	Confidence	Lift
Normal, Ewallet	Male	0,105	0,570652	1,143592
Male, Ewallet	Normal	0,105	0,567568	1,137410
Credit card	Member	0,172	0,553055	1,103902
Ewallet	Male	0,185	0,536232	1,074613
Ewallet	Normal	0,184	0,533333	1,068804
Credit card	Female	0,163	0,524116	1,046139
Male	Normal	0,259	0,519038	1,040156
Normal	Male	0,259	0,519038	1,040156
Female	Member	0,261	0,520958	1,039836
Member	Female	0,261	0,520958	1,039836
Cash	Female	0,178	0,517442	1,032818
Cash	Normal	0,176	0,511628	1,025306

Tabel 3. Aturan asosiasi utama berdasarkan nilai lift.

Analisis terhadap seluruh aturan utama menunjukkan bahwa nilai lift berada pada kisaran 1,02–1,14. Dengan demikian, semua aturan utama memiliki hubungan positif, tetapi tingkat keeratan hubungan masih rendah hingga sedang. Kondisi ini berarti aturan asosiasi sebaiknya digunakan sebagai informasi pendukung, bukan sebagai satu-satunya parameter dalam keputusan pengadaan. Keputusan stok tetap perlu mempertimbangkan data stok aktual, jumlah barang masuk dan keluar, tren permintaan, serta faktor operasional lain.

Dari sisi pengendalian persediaan, hasil FP-Growth dapat digunakan untuk memetakan kategori yang perlu mendapatkan perhatian lebih tinggi. Produk dengan support relatif lebih besar dapat menjadi kandidat untuk pemantauan stok dan penjadwalan pengadaan yang lebih konsisten. Informasi karakteristik pelanggan dan metode pembayaran juga dapat dimanfaatkan untuk mendukung strategi promosi dan penempatan produk. Dengan demikian, hasil association rule memiliki fungsi sebagai jembatan antara data transaksi dan keputusan operasional.

Hasil penelitian juga memperlihatkan keterbatasan yang perlu diperhatikan. Dataset yang digunakan merupakan dataset transaksi supermarket dari Kaggle dan tidak secara langsung memuat atribut stok awal, stok masuk, stok keluar, atau stok akhir. Oleh karena itu, istilah pengendalian persediaan dalam penelitian ini lebih tepat dipahami sebagai pemanfaatan pola transaksi untuk mendukung keputusan persediaan, bukan sebagai sistem perhitungan persediaan secara langsung. Penelitian berikutnya dapat memperluas dataset dengan atribut persediaan aktual agar rekomendasi yang dihasilkan lebih dekat dengan kondisi operasional gudang.

Secara metodologis, hasil penelitian konsisten dengan karakteristik FP-Growth yang menggunakan FP-tree untuk memampatkan data dan menambang frequent pattern tanpa pembangkitan kandidat itemset secara berulang [1], [3]. Temuan penelitian sebelumnya yang dicantumkan dalam skripsi juga menunjukkan bahwa ARM dan FP-Growth dapat digunakan untuk mengidentifikasi pola transaksi serta mendukung strategi pengendalian persediaan [4]–[8]. Oleh karena itu, penerapan FP-Growth dalam penelitian ini menunjukkan bahwa data transaksi dapat diubah menjadi informasi pola yang lebih mudah digunakan untuk mendukung pengambilan keputusan.

4. KESIMPULAN

Penelitian ini berhasil menerapkan metode Association Rule menggunakan algoritma FP-Growth pada 1.000 transaksi Supermarket Sales Cleaned Dataset melalui tahapan KDD yang meliputi selection, preprocessing, transformation, data mining, dan interpretation/evaluation. Dengan minimum support 10%, algoritma menghasilkan frequent itemset yang menggambarkan pola kemunculan atribut pelanggan, metode pembayaran, dan kategori produk. Item Member dan Female menjadi item tunggal dengan support tertinggi sebesar 50,1%, sedangkan pada kategori produk Fashion accessories memiliki support tertinggi sebesar 17,8%. Dengan minimum confidence 50%, aturan terkuat adalah {Normal, Ewallet} → {Male}, dengan support 10,5%, confidence 57,06%, dan lift 1,143592. Seluruh aturan utama memiliki lift di atas 1, tetapi berada pada kisaran 1,02–1,14 sehingga kekuatan asosiasi tergolong rendah hingga sedang. Hasil tersebut menunjukkan bahwa FP-Growth efektif untuk menemukan pola tersembunyi dalam data transaksi dan dapat dimanfaatkan sebagai informasi pendukung pengendalian persediaan, khususnya untuk menentukan prioritas pemantauan kategori produk dan mendukung strategi promosi. Untuk penelitian selanjutnya, disarankan menggunakan dataset yang lebih lengkap dengan atribut stok awal, stok masuk, stok keluar, stok akhir, serta menguji beberapa kombinasi minimum support dan minimum confidence. Perbandingan dengan Apriori atau Eclat juga dapat dilakukan untuk mengevaluasi efisiensi dan kualitas aturan yang dihasilkan.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada Universitas Muhammadiyah Bengkulu, Fakultas Teknik, Program Studi Teknik Informatika, serta dosen pembimbing yang telah memberikan arahan dalam penyelesaian penelitian ini.

REFERENSI

[1] J. Han, J. Pei, and Y. Yin, “Mining frequent patterns without candidate generation,” SIGMOD Record, vol. 29, no. 2, pp. 1–12, 2000, doi: 10.1145/335191.335372.
[2] R. Agrawal and R. Srikant, “Fast algorithms for mining association rules in large databases,” in Proc. 20th Int. Conf. Very Large Data Bases (VLDB), 1994, pp. 487–499.
[3] C. Borgelt, “An implementation of the FP-growth algorithm,” in Proc. 1st Int. Workshop Open Source Data Mining: Frequent Pattern Mining Implementations, 2005.
[4] I. Riadi, F. Herman, M. Fitriah, A. Muis, et al., “Implementation of association rule using apriori algorithm and frequent pattern growth for inventory control,” vol. 15, no. 4, pp. 369–378, 2023, doi: 10.20895/infotel.v15i4.980.
[5] I. Riadi, F. Herman, M. Fitriah, and Suprihatin, “Optimizing inventory with frequent pattern growth algorithm for small and medium enterprises,” MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer, vol. 23, no. 1, pp. 169–182, 2023, doi: 10.30812/matrik.v23i1.3363.
[6] D. Rachmawati et al., “Perbandingan algoritma Apriori dan algoritma FP-Growth dalam menentukan pola penjualan pupuk,” vol. 3, no. 1, pp. 21–31, 2024.
[7] I. F. Rahman and D. Riana, “Market basket analysis untuk penjualan retail: Perbandingan akurasi,” pp. 468–479, 2025, doi: 10.33364/algoritma/v.22-1.2303.
[8] S. Komariyah, S. Anwar, and B. Nurhakim, “Implementasi data mining FP-Growth untuk analisis pola pembelian pada transaksi penjualan,” vol. 1, no. 2, 2023.
[9] H. Chen, M. Yang, and X. Tang, “Association rule mining of aircraft event causes based on the Apriori algorithm,” Scientific Reports, pp. 1–18, 2024, doi: 10.1038/s41598-024-64360-6.
[10] H. Khalid and V. Wade, “Comparative analysis of existing and a novel approach to topic detection on conversational dialogue data,” vol. 11, no. 4, pp. 1–18, 2022.
[11] H. Sahara, S. D. Saragih, and A. P. Windarto, “Teknik asosiasi datamining dalam menentukan pola penjualan dengan metode Apriori,” vol. 2, no. 12, pp. 684–689, 2022, doi: 10.47065/tin.v2i12.1577.
[12] N. D. Sari and S. Khoiriah, “Penerapan metode asosiasi pada Toko Afifa dengan algoritma Apriori,” vol. 1, no. 1, pp. 8–17, 2022.
[13] H. Anderson et al., “Penerapan data mining asosiasi genre game untuk market research,” 2022.
[14] H. Ilmiah and J. Pendidikan, “Penerapan data mining pada pengelolaan data,” vol. 10, no. 16, pp. 655–661, 2024.
[15] F. Rahmawati and N. Merlina, “Metode data mining terhadap data penjualan sparepart mesin fotocopy menggunakan algoritma Apriori,” PIKSEL: Penelitian Ilmu Komputer Sistem Embedded and Logic, vol. 6, no. 1, pp. 9–20, 2018, doi: 10.33558/piksel.v6i1.1390.