

Penerapan Algoritma K-Medoids dan FP-Growth dalam Penentuan Pola Kombinasi Produk Berdasarkan Hasil Segmentasi Pelanggan

Tata Ayunita Pertiwi*, M. Afdal, Rice Novita, Mustakim

Fakultas Sains dan Teknologi, Sistem Informasi, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

Email: 12050327015@students.uin-suska.ac.id, m.afdal@uin-suska.ac.id, rice.Novita@email.com,

mustakim@uin-suska.ac.id

Email Penulis Korespondensi: 12050327015@students.uin-suska.ac.id

Submitted: 03/06/2024; Accepted: 20/06/2024; Published: 09/09/2024

Abstrak—Persaingan dunia bisnis mengalami peningkatan yang mengakibatkan perusahaan harus mengoptimalkan penjualan dan mempertahankan pelanggannya. Pelanggan adalah aset penting perusahaan yang harus dijaga dengan baik. Tujuan dilakukannya segmentasi pelanggan adalah memahami perilaku pembelian pelanggan agar perusahaan dapat menerapkan strategi pemasaran yang tepat. Aurel Mini Mart adalah bisnis ritel yang belum mempertimbangkan *recency*, *frequency*, dan *monetary* belanja pelanggan. Selama ini, promosi yang dilakukan hanya berdasarkan perkiraan saja, tanpa memperhitungkan kembali data dan informasi yang akurat. Penelitian ini menggabungkan model RFM dengan teknik data mining untuk melakukan segmentasi pelanggan. Berdasarkan 5 *cluster* yang terbentuk dari proses *clustering*, *golden customers* berada pada *cluster* 1 yang memiliki loyalitas tinggi dengan nilai *recency* rendah, *frequency* tinggi dan *monetary* tinggi. Ini menunjukkan bahwa pelanggan dalam segmen ini sering melakukan pembelian dengan jumlah uang yang cukup besar. Sedangkan, pelanggan pada *cluster* 2, 3, 4, dan 5 adalah *dormant customers* yang jarang melakukan transaksi dan jumlah uang yang dikeluarkan juga kecil. Setelah proses segmentasi pelanggan selesai, langkah berikutnya menggunakan Algoritma FP-Growth untuk mengasosiasikan produk yang dibeli oleh pelanggan. Hal ini bertujuan untuk memperoleh kombinasi produk yang lebih baik, sehingga strategi penjualan dapat menjadi lebih efektif dan perusahaan dapat meraih keuntungan.

Kata Kunci: RFM; K-Medoids; FP-Growth; Kombinasi Produk; Segmentasi Pelanggan

Abstract—Competition in the business world has increased, resulting in companies having to optimize sales and retain their customers. Customers are an important company asset that must be well looked after. The aim of customer segmentation is to understand customer purchasing behavior so that companies can implement appropriate marketing strategies. Aurel Mini Mart is a retail business that does not yet consider the *recency*, *frequency* and *monetary* value of customer shopping. So far, promotions have been carried out only based on estimates, without taking into account accurate data and information. This research combines the RFM model with data mining techniques to segment customers. Based on the 5 clusters formed from the clustering process, gold customers are in cluster 1 which has high loyalty with low *recency* value, high *frequency* and high *monetary* value. This shows that customers in this segment often make purchases for quite large amounts of money. Meanwhile, customers in clusters 2, 3, 4, and 5 are dormant customers who rarely make transactions and the amount of money spent is also small. After the customer segmentation process is complete, the next step is to use the FP-Growth Algorithm to associate the products purchased by customers. This aims to obtain a better product combination, so that the sales strategy can be more effective and the company can make a profit.

Keywords: RFM; K-Medoids; FP-Growth; Product Combination; Customer Segmentation

1. PENDAHULUAN

Persaingan dunia bisnis mengalami peningkatan yang mengakibatkan perusahaan harus mengoptimalkan penjualan dan mempertahankan pelanggannya. Salah satu strategi meningkatkan penjualan adalah melakukan kombinasi antar produk yang akan dibeli pelanggan. Kombinasi produk adalah strategi promosi yang menggabungkan produk-produk yang memiliki kemungkinan besar akan dibeli oleh pelanggan. Dengan memahami keterkaitan antara produk yang sering dibeli oleh pelanggan, promosi produk menjadi lebih tepat sasaran.

Aurel Mini Mart didirikan pada tahun 2022 yang bergerak dibidang penjualan produk atau barang kebutuhan sehari-hari seperti air mineral, alat mandi, ATK, bahan kue, bahan pokok, beras, biscuit & wafer, dan masih banyak lagi. Aurel Mini Mart menggunakan sistem informasi penjualan yang memungkinkan sebuah *database* menyimpan setiap transaksi pembelian produk dalam bentuk laporan penjualan.

Berdasarkan hasil observasi dan wawancara, laporan penjualan Aurel Mini Mart selama 1 tahun yaitu Januari 2023-Desember 2023 hanya berupa arsip laporan penjualan yang tidak dilakukan analisis lebih lanjut. Penentuan pelanggan potensial selama ini hanya menggunakan perkiraan saja tanpa didukung data maupun informasi yang lebih akurat. Analisis lebih lanjut pada data transaksi penjualan menghasilkan informasi-informasi yang bermanfaat bagi pihak Aurel Mini Mart. Salah satunya dengan memperhitungkan *recency*, *frequency*, dan *monetary* pelanggan berbelanja yang berpengaruh dalam kegiatan pemasaran, salah satunya promosi produk yang dapat dilakukan dengan lebih efektif dan tepat sasaran [1] [2]. Menyikapi permasalahan tersebut, dilakukan analisis terhadap masalah yang ada dengan menggabungkan salah satu dari metode CRM yaitu analisis RFM dengan teknik data mining. Penelitian ini menggunakan algoritma K-Medoids dengan analisis RFM untuk proses *clustering* pelanggan yang dilanjutkan mengasosiasikan produk pada tiap *cluster* menggunakan algoritma FP-Growth untuk meningkatkan efektivitas strategi penjualan dan meningkatkan kepuasan pelanggan [3].

Model RFM (*Recency*, *Frequency*, *Monetary*) merupakan salah satu metode analisis dalam segmentasi pelanggan [4]. Segmentasi pelanggan adalah mengelompokkan pelanggan menjadi kelompok-kelompok terpisah yang

memiliki karakteristik serupa [5]. Klasterisasi dengan analisis RFM dapat mengidentifikasi pelanggan dengan nilai tertentu sehingga yang menjadikan sasaran promosi atau pemasaran produk lebih tepat sasaran [6]. Dalam data mining, teknik untuk melakukan klasterisasi adalah *Clustering* [7].

Clustering memisahkan data menjadi beberapa kelompok yang masing-masing memiliki ciri khas [8]. Proses *clustering* menggunakan algoritma K-Medoids memiliki sejumlah keunggulan diantaranya yaitu dapat mengurangi *noise*, tidak sensitif terhadap *outlier* dan unggul dalam melakukan klasterisasi *dataset heterogen* yang menjadi kelebihan diantara algoritma *clustering* yang lain [9]. *Davies Bouldin Index* (DBI) digunakan untuk melakukan uji validitas *cluster* [10]. Setelah mendapatkan hasil *cluster*, langkah selanjutnya yaitu melakukan tahap *association rules*.


Association rules adalah metode data mining yang mengidentifikasi pola yang sering muncul disekitar transaksi [11] [12]. *Market Basket Analysis* (MBA) adalah *association rules* yang paling terkenal [13]. Salah satu algoritma *association rules* adalah FP-Growth yang terbentuk dari hasil *ekspansi* algoritma *apriori* [16]. Algoritma FP-Growth memiliki keunggulan yaitu tidak menghasilkan himpunan kandidat dan hanya melintasi himpunan data dua kali, sehingga meningkatkan efisiensi dalam penambangan *itemset* yang sering muncul [17]. *Association rules* menghasilkan pola kombinasi *itemset* dari data produk untuk memberikan informasi berupa kombinasi produk guna meningkatkan pembelian produk dan menaikkan omzet penjualan [14]. Kombinasi produk dapat meningkatkan strategi pemasaran dan menarik banyak pelanggan [15].

Pada penelitian yang dilakukan Siagian, Sirait & Halim (2022) menyatakan bahwa algoritma K-Medoids jauh lebih efektif dalam segmentasi pelanggan daripada algoritma K-Means [19]. Penelitian Fahrudin dan Rindiyan (2024) menyatakan bahwa K-Medoids mampu memetakan berbagai jenis pelanggan dengan baik dengan data *outlier* yang lebih terintegrasi [18]. Terkait segmentasi pelanggan dengan model analisis RFM telah dilakukan penelitian oleh Madani, Rahmah, Nurunnisa & Elia (2022) menggunakan algoritma K-Medoids menghasilkan 2 kategori pelanggan [20]. Pada penelitian Sechuti, Via & Maulana (2024) diketahui bahwa FP-Growth yang memiliki nilai minimum *support* 10% dan minimum *confidence* 60% lebih efisien dalam segi alokasi memori dan menghasilkan *rules* yang lebih banyak dibandingkan Apriori. Selanjutnya, penelitian yang dilakukan Octavia, Mustakim, Permana & Monalisa (2023) membandingkan dua algoritma *association rules* yakni FP-Growth dan Apriori yang terlebih dahulu dilakukan proses *clustering*. Didapatkan hasil bahwa FP-Growth lebih banyak menghasilkan *rules* dan memiliki tingkat akurasi paling besar [3].

Berdasarkan uraian permasalahan diatas maka penelitian ini menggunakan algoritma K-Medoids dan algoritma FP-Growth dengan analisis RFM untuk menentukan segmentasi pelanggan dan pola aturan asosiasi produk yang dijual. Hasil akhir dari penelitian ini diharapkan dapat membantu pihak Aurel Mini Mart dalam membuat kombinasi produk yang dapat dijual pada setiap segmentasi pelanggan yang berbeda-beda untuk meningkatkan penjualan produk.

2. METODOLOGI PENELITIAN

Penelitian yang dilakukan memiliki 5 tahapan sistematis untuk mencapai tujuan yang diinginkan. Adapun tahap penelitian ini ada pada Gambar 1.



Gambar 1. Metodologi Penelitian

Penelitian ini dimulai dari tahap pengumpulan data transaksi penjualan Aurel Mini Mart yang diambil dari bulan Januari 2023 hingga Desember 2023. Selanjutnya, dilakukan tahap sejumlah tahap *preprocessing* data menggunakan analisis RFM yaitu pembersihan data, transformasi data, dan normalisasi data. Kemudian, dilakukan proses *clustering* pelanggan menggunakan algoritma K-Medoids. Langkah selanjutnya, dilakukan asosiasi menggunakan algoritma FP-Growth terhadap masing-masing *cluster*. Tahap akhir penelitian ini adalah menganalisis hasil segmentasi pelanggan dan *rules* yang muncul.

2.1 Customer Relationship Management (CRM)

Customer Relationship Management (CRM) adalah pendekatan bisnis untuk mempertahankan pelanggan, meningkatkan loyalitas pelanggan, kepuasan pelanggan dan mengelola hubungan jangka panjang antara perusahaan dengan pelanggannya [21] [22]. *Customer Relationship Management* (CRM) juga bertujuan untuk menarik pelanggan baru, mengurangi biaya pemasaran dan layanan pelanggan [23].

2.2 Segmentasi pelanggan

Segmentasi pelanggan merupakan pengelompokan untuk mengetahui nilai masing-masing pelanggan dan mengidentifikasi pola perilaku pelanggan berdasarkan berbagai faktor seperti profil pelanggan, riwayat transaksi, minat, dan kepuasan pelanggan [24]. Segmentasi pelanggan dilakukan untuk mengidentifikasi pelanggan yang menguntungkan bagi perusahaan [25].

2.3 Model RFM

Analisis Model RFM diusulkan pada tahun 1994 oleh A.M. Huges untuk melakukan segmentasi pelanggan dan mengamati perilaku pelanggan [4] [26]. Nilai RFM didefinisikan sebagai berikut [5]:

- a. R (*Recency*) adalah jangka waktu pembelian terakhir dengan waktu saat ini. Nilai rendah menunjukkan kemungkinan tinggi pelanggan akan melakukan transaksi kembali.
- b. F (*Frequency*) adalah jumlah pembelian yang terjadi pada jangka waktu tertentu. Nilai frekuensi tinggi menunjukkan tingkat loyalitas pelanggan yang semakin tinggi pula.
- c. M (*Monetary*) adalah total uang pelanggan berbelanja dalam jangka waktu tertentu.

Matriks loyalitas pelanggan digunakan untuk mengetahui tipe pelanggan. Matriks mengkategorikan perilaku pelanggan berdasarkan segmen. Apabila nilai rata-rata suatu *cluster* berada di atas nilai rata-rata keseluruhan *cluster* dinyatakan dengan simbol (↑), sedangkan apabila nilai rata-rata suatu *cluster* lebih rendah dibandingkan nilai rata-rata keseluruhan *cluster* dinyatakan dengan simbol (↓) [20]. Adapun enam karakteristik pelanggan berdasarkan nilai RFM [5] ada pada Tabel 1.

Tabel 1. Karakteristik Pelanggan

Segmentasi Pelanggan	Karakteristik
<i>Superstar</i>	<ol style="list-style-type: none"> a. Nilai <i>monetary</i> tinggi b. <i>Frequency</i> tinggi c. <i>Recency</i> tinggi
<i>Golden Customer</i>	<ol style="list-style-type: none"> a. Nilai <i>frequency</i> tinggi b. Memiliki nilai <i>monetary</i> rata-rata dari seluruh pelanggan
<i>Typical Customer</i>	<ol style="list-style-type: none"> a. Memiliki nilai <i>monetary</i> rata-rata dari seluruh pelanggan b. <i>Frequency</i> sedang
<i>Occasional Customer</i>	<ol style="list-style-type: none"> a. Nilai <i>frequency</i> terendah kedua setelah <i>dormant customer</i> b. Nilai <i>recency</i> rendah
<i>Everyday Shopper</i>	<ol style="list-style-type: none"> a. Nilai <i>frequency</i> lebih tinggi dibandingkan <i>dormant customer</i> b. Nilai <i>monetary</i> sedang hingga rendah
<i>Dormant Customer</i>	<ol style="list-style-type: none"> a. <i>Frequency</i> dan <i>monetary</i> terendah b. Nilai <i>recency</i> terendah

2.4 Data Mining

Data Mining juga dikenal dengan nama *Knowledge Discovery in Database* (KDD) [27], merupakan serangkaian aktivitas mengumpulkan dan memanfaatkan data historis untuk mengetahui pola atau hubungan dalam suatu kumpulan data yang besar. [28]. Selain itu, data mining juga melakukan sejumlah proses penambangan maupun analisis data yang bertujuan untuk menemukan informasi atau pola yang ada dalam suatu data [29] [30].

2.5 Algoritma K-Medoids

Algoritma K-Medoids dikenal sebagai Algoritma *Partition Around Medoids* (PAM) adalah algoritma yang diperbaharui pada tahun 1987 oleh peneliti yang bernama Leonard Kaufman dan Peter J. Rousseeuw. Algoritma K-Medoids mengelompokkan (n) objek dalam satu *cluster* [31]. K-Medoids menggunakan waktu komputasi yang lebih sedikit daripada K-Means. Selain itu, K-Medoids lebih unggul mengurangi sensitivitas terhadap *noise* maupun *outlier*, dan jumlah yang tidak sesuai dengan distribusi data. Pendistribusian data ke *cluster* terdekat berdasarkan nilai *Euclidean Distance* dengan rumus (1) [25]:

$$d(x_j, c_j) = \sqrt{\sum_{j=1}^n (X_j - C_j)^2} \tag{1}$$

2.6 Davies Bouldin Index (DBI)

Davies Bouldin Index (DBI) merupakan salah satu metode uji validitas *cluster* untuk mengevaluasi kualitas *cluster*. DBI menghitung nilai rata-rata setiap titik pada suatu kumpulan data yang diolah. Nilai DBI yang paling kecil atau mendekati nol (*non-negatif* ≥ 0) adalah menunjukkan hasil *cluster* yang paling optimal. Rumus menghitung nilai DBI ada pada rumus (2) [19]:

$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{i \neq j} (R_{i,j}) \tag{2}$$

2.3 Association Rules

Association Rules adalah metode mengidentifikasi pola-pola dan hubungan dalam data [17]. *Association Rules* bertujuan menemukan pola yang sering terjadi di antara banyak transaksi yang memiliki beberapa *item*. Oleh karena itu, *association rules* dapat membuat kombinasi *item* dengan mencari pola antara *item* dalam transaksi yang terjadi [32] [11]. *Association Rules* memiliki beberapa perhitungan yaitu *Support*, *Confidence*, dan *Lift Ratio*.

Support adalah kemungkinan pelanggan akan membeli kembali beberapa produk secara bersamaan dari total seluruh transaksi. Adapun nilai *support* diperoleh dengan rumus (3) dan (4) [11]:



$$Support(A) = \frac{jumlah\ transaksi\ A}{total\ transaksi} \tag{3}$$

$$Support(A, B) = P(A \cap B) = \frac{jumlah\ transaksi\ A\ dan\ B}{total\ transaksi} \tag{4}$$

Langkah selanjutnya adalah membuat aturan asosiasi yang memenuhi nilai minimum *confidence* "jika A maka B". *Confidence* adalah kemungkinan terjadinya pembelian beberapa produk secara bersamaan. *Confidence* mengukur bahwa seberapa sering item B akan muncul ketika A juga muncul. Nilai *confidence* diperoleh dengan rumus (5) [11]:

$$Confidence(A \rightarrow B) = \frac{jumlah\ transaksi\ A\ dan\ B}{total\ transaksi\ A} \tag{5}$$

Langkah untuk mengetahui kuatnya aturan asosiasi adalah membandingkannya dengan nilai *Confidence Benchmark*. Hal ini mengasumsikan *consequents* item pada suatu transaksi tidak bergantung pada *antecedent* aturan asosiasi. Atau, dengan kata lain, jika item *antecedent* dan item *consequents* adalah *independent*. Rumus *Confidence Benchmark* dapat dilihat pada rumus (6) [11]:

$$Confidence\ Benchmark = \frac{transaksi\ consequent}{total\ transaksi} \tag{6}$$

Setelah mengetahui nilai *support* dan *confidence* kombinasi produk, dilakukan *validasi* menggunakan *lift ratio* bertujuan untuk menentukan aturan asosiasi yang dibentuk kuat atau tidak [33]. Rumus *Lift ratio* dapat dilihat pada rumus (7) [34].

$$Lift = \frac{Confidence(A,B)}{Confidence\ Benchmark(A,B)} \tag{7}$$

2.7 Algoritma FP-Growth

Algoritma FP-Growth adalah hasil pengembangan algoritma Apriori [35]. Keunggulan algoritma FP-growth yaitu kinerjanya yang jauh lebih cepat. Hal ini dikarenakan FP-Growth bisa menghilangkan suatu *candidate generation* yang ada di algoritma Apriori. Selain itu, algoritma FP-Growth lebih efektif mengidentifikasi suatu pola dan juga *frequent itemset* dibandingkan algoritma Apriori [14]. Algoritma FP-Growth dapat memberikan informasi mengenai pola pembelian yang digunakan untuk meningkatkan strategi promosi dan penjualan [36].

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Data penelitian ini adalah data transaksi penjualan Aurel Mini Mart mulai dari bulan Januari 2023 hingga Desember 2023 dengan total 104347 baris data.

3.2 Preprocessing Data dengan Analisis RFM

3.2.1 Pembersihan data

Tahap pembersihan data bertujuan menghilangkan *noise* sebelum data diolah untuk menjaga data tetap *valid* dan tepat. Untuk mempermudah langkah berikutnya pada tahap ini juga mengkategorikan data. Terdapat 45 kategori produk yaitu air mineral, alat mandi, ATK, bahan kue, bahan pokok, beras, biskuit & wafer, bumbu dapur, *deodorant*, *detergent*, es krim, *frozen food*, *hair care*, *hand & body lotion*, jajanan UMKM, kecap, kopi, kosmetik, madu, makanan kucing, *mie instant*, minuman kemasan, minyak goreng, obat, obat nyamuk, *pampers*, parfum, pasta gigi, pembalut, pembersih lantai, pengharum, perlengkapan bayi, permen, pewangi pakaian, roti, rumah tangga, sabun mandi, saus, selai, sereal, sirup, *skincare*, snack, susu, teh, telur, tepung, tisu. Hasil dari tahap pembersihan data ada pada Tabel 2.

Tabel 2. Hasil pembersihan data

No Transaksi	Pelanggan	Departemen	Nama Stock	Tanggal	Qty	Jumlah (Rp.)
1182203380	SUMEDI	BISKUIT & WAFER	RM SANDWICH PEANUT 189GR	28/11/2023	1	7500
1182203380	SUMEDI	ES KRIM	PADDLE POP TRICO NEW BLY 60ML_	28/11/2023	1	2000
1182203380	SUMEDI	PERLENGKAPAN BAYI	C.BUDS DODO 132 50S_XXX	28/11/2023	1	5000
1182203380	SUMEDI	BISKUIT & WAFER	NISSIN COCONUT BUTTER BISC 200	28/11/2023	1	10000
1182203380	SUMEDI	BISKUIT & WAFER	RM SANDWICH PEANUT 189GR	28/11/2023	1	7500

No Transaksi	Pelanggan	Departemen	Nama Stock	Tanggal	Qty	Jumlah (Rp.)
7904303800	LEONI MAHARA NI DEWI	SNACK	TOYAKI RASA JAGUNG BAKAR 22GR	07/02/2023	1	1000

3.2.2 Transformasi Data

Selanjutnya dilakukan transformasi pada atribut yang ada menjadi bentuk nilai kriteria RFM. Hasil transformasi data RFM dapat dilihat pada Tabel 3.

Tabel 3. Hasil transformasi data

No	Nama Member	Recency	Frequency	Monetary
1	SUMEDI	182	15	678870
2	RIKO FEBRIANTO	198	1	45242
3	JUM'AH FAJRI	182	6	271548
4	SYARIF HIDAYATULOH	182	4	181032
5	THOHIRIN	198	3	135627
1157	TUGINO	154	8	361067

3.2.3 Normalisasi Data RFM


Normalisasi dilakukan untuk mengecilkan perbedaan skala nilai antara atribut RF dengan M, sehingga tidak ada perbedaan yang terlalu besar. Rentang yang digunakan yaitu 0-1 menggunakan rumus *min-max normalization*. Hasil transformasi data memperoleh nilai *min* R=148, F=1, dan M=45242 dan nilai *max* R=512, F= 961, dan M=43.354.742. Tabel 3 adalah hasil perhitungan normalisasi RFM.

Tabel 4. Hasil Normalisasi RFM

No	Nama Member	Normalisasi Recency	Normalisasi Frequency	Normalisasi Monetary
1	SUMEDI	0,9093	0,0146	0,0146
2	RIKO FEBRIANTO	0,8654	0,0000	0,0000
3	JUM'AH FAJRI	0,9093	0,0052	0,0052
4	SYARIF HIDAYATULOH	0,9093	0,0031	0,0031
5	THOHIRIN	0,8654	0,0021	0,0021
1157	TUGINO	0,9863	0,0073	0,0073

3.3 Clustering Menggunakan Algoritma K-Medoids

Penelitian ini menggunakan algoritma K-Medoids untuk mengelompokkan data yang telah diproses sebelumnya. Tujuannya adalah untuk mengurangi ukuran *dataset* pada tahap asosiasi menggunakan algoritma FP-Growth. Dilakukan sejumlah percobaan dari *cluster* 2 hingga *cluster* 10 untuk memperoleh nilai DBI terbaik dan optimal. Nilai DBI pada setiap percobaan yang dilakukan terdapat Gambar 2.



Gambar 2. Grafik nilai DBI tiap cluster



Pada Gambar 2 diketahui bahwa nilai DBI paling rendah terdapat pada *cluster* 5 sebesar 0,754. Sehingga, data dikelompokkan menjadi 5 *cluster*, yaitu *cluster* 1 berjumlah 198 pelanggan, *cluster* 2 berjumlah 274 pelanggan, *cluster* 3 berjumlah 185 pelanggan, *cluster* 4 berjumlah 90 pelanggan, dan *cluster* 5 berjumlah 410 pelanggan. Kemudian dilakukan perhitungan nilai rata-rata RFM terhadap 5 *cluster* yang terbentuk sehingga mendapatkan hasil R=179,888, F=32,3803, dan M=1.460.994. Setelah memperoleh nilai rata-rata RFM dari seluruh *cluster*, langkah berikutnya menghitung nilai rata-rata RFM untuk setiap *cluster* guna menentukan simbol *rank* dari masing-masing *cluster*. Simbol (↑) untuk nilai rata-rata yang lebih tinggi dan simbol (↓) untuk nilai rata-rata yang lebih rendah. Tabel 5 menunjukkan nilai rata-rata RFM tiap *cluster*.

Tabel 5. Nilai rata-rata RFM tiap *cluster*

Cluster	Anggota Cluster	R	F	M	Simbol Rank RFM
1	198	158,136	83,682	3.775.741	R↓F↑M↑
2	274	178,722	21,059	950.212	R↓F↓M↓
3	185	208,400	16,276	734.107	R↑F↓M↓
4	90	302,978	10,144	457.156	R↑F↓M↓
5	410	156,890	27,456	1.239.012	R↓F↓M↓

Dari Tabel 5 diatas dapat diambil kesimpulan analisis pola RFM tiap *cluster* berdasarkan variable RFM untuk menentukan kategori pelanggan :

- Cluster 1 terdiri dari pelanggan yang sering bertransaksi dan memiliki nilai *monetary* (M) yang tinggi, artinya rata-rata jumlah uang yang dibelanjakan lebih besar dibandingkan *cluster* lainnya.
- Cluster 2 dan 5 terdiri dari pelanggan yang jarang bertransaksi dan memiliki nilai *monetary* (M) yang rendah, artinya jumlah uang yang dibelanjakan relatif kecil.
- Cluster 3 dan 4 terdiri dari pelanggan dengan nilai *recency* (R) yang tinggi, artinya pelanggan dalam segmen ini sudah lama tidak bertransaksi dan jumlah uang yang dibelanjakan juga kecil.

3.4 Asosiasi dengan Algoritma FP-Growth

Sebelum dilakukan tahap asosiasi menggunakan algoritma FP-Growth, terlebih dahulu dilakukan *pre-processing* data pada tiap *cluster* yang hanya memiliki 1 *itemset*, karena salah satu syarat penentuan pola *association rules* setidaknya memiliki 2 *itemset* dalam satu transaksi. Hasil dari *pre-processing* data asosiasi pada tiap *cluster* terdapat pada Tabel 6.

Tabel 6. *Pre-processing* data masing-masing *cluster*

Cluster	No Transaksi	Departemen
1	1909003220	Air Mineral, Kosmetik, Roti
	1928503220	Snack, Minuman Kemasan

2	7904303800	Mie Instant, Susu, Susu
	1182203380	Biskuit & Wafer, Es Krim, Perlengkapan Bayi, Biskuit & Wafer, Bahan Kue, Biskuit & Wafer, Snack, Es Krim, Es Krim
	1196803380	Hand & Body Lotion, Bahan Kue, Kosmetik

	7904003520	Snack, Minuman Kemasan
3	1240503220	Bumbu Dapur Perlengkapan Bayi, Air Mineral, Beras
	1636002230	Biskuit & Wafer, Minuman Kemasan, Susu

4	7904105500	Mie Instant, Snack
	2402602660	Minuman Kemasan, Permen, Snack
	2405202150	Biskuit & Wafer, Deodorant, Susu
5
	7898402530	Saus, Permen, Minuman Kemasan
	1675503220	Beras, Detergent, Hair Care, Minyak Goreng, Pampers, Pasta Gigi, Pembersih Lantai, Perlengkapan Bayi, Pewangi Pakaian, Sabun Mandi,
	1678803380	Bahan Kue, Mie Instant
...
	7904101040	Mie Instant, Air Mineral

Setelah dilakukan pengelompokan data tiap *cluster*, langkah selanjutnya dilakukan transformasi data kedalam bentuk *boolean*. Proses ini melibatkan melibatkan pengisian atribut-atribut baru dengan nilai 1 jika item atau produk sesuai dengan atribut tersebut ada dalam data dan mengisi nilai 0 jika tidak ada. Transformasi data *cluster* 1-5 dapat dilihat pada Tabel 7, Tabel 8, Tabel 9, Tabel 10, dan Tabel 11.

Tabel 7. Transformasi Data Transaksi *Cluster 1*

No Transaksi	Air Mineral	Alat Mandi	Bahan Kue	Bahan Pokok	Beras	...	Tisu
1909003220	1	0	0	0	0	...	0
1928503220	1	0	0	0	0	...	0
1930103380	0	0	0	0	0	...	0
2014002230	1	0	1	0	0	...	0
2027503220	0	0	0	0	0	...	0
...
7904303800	0	0	0	0	0	...	0

Tabel 8. Transformasi Data Transaksi *Cluster 2*

No Transaksi	Air Mineral	Alat Mandi	Bahan Kue	Bahan Pokok	Beras	...	Tisu
1182203380	0	0	1	0	0	...	0
1196803380	0	0	1	0	0	...	0
1228703380	0	0	0	0	0	...	0
1354203380	0	0	0	0	0	...	0
1396503380	0	0	0	0	0	...	0
...
7904003520	1	0	0	0	0	...	0

Tabel 9. Transformasi Data Transaksi *Cluster 3*

No Transaksi	Air Mineral	Alat Mandi	Bahan Kue	Bahan Pokok	Beras	...	Tisu
1240503220	0	0	0	0	0	...	0
1636002230	0	0	0	0	0	...	0
2334202300	0	0	0	0	0	...	0
2335501330	0	0	0	0	0	...	0
2338603080	0	0	0	0	1	...	0
...
7904105500	0	0	0	0	0	...	0

Tabel 10. Transformasi Data Transaksi *Cluster 4*

No Transaksi	Air Mineral	Alat Mandi	Bahan Kue	Bahan Pokok	Beras	...	Tisu
2402602660	0	0	0	0	0	...	0
2405202150	0	0	0	0	0	...	0
2405206900	0	0	0	0	0	...	0
2405402020	0	0	0	0	0	...	0
2419302340	0	0	0	0	0	...	0
...
7898402530	0	0	0	0	0	...	0

Tabel 11. Transformasi Data Transaksi *Cluster 5*

No Transaksi	Air Mineral	Alat Mandi	Bahan Kue	Bahan Pokok	Beras	...	Tisu
1675503220	0	0	0	0	1	...	0
1678803380	0	0	1	0	0	...	0
1681103220	0	0	0	0	0	...	0
1719803220	0	0	0	1	1	...	0
1725403220	0	0	0	0	0	...	0
...
7904101040	0	0	0	0	0	...	0

Langkah terakhir dilakukan asosiasi data menggunakan algoritma FP-Growth untuk mengetahui *rules* yang dihasilkan dengan *support* 10% dan *confidence* 60%. Adapun *rules* yang terbentuk dari masing-masing *cluster* ada pada Tabel 12, Tabel 13, dan Tabel 14.

Tabel 12. Hasil asosiasi *Cluster 1*



No	Premises	Conclusion	Support	Confidence	Lift Ratio
1	Snack	Minuman Kemasan	0,132	0,943	3,171
2	Snack	Biskuit & Wafer	0,116	0,830	6,778
3	Biskuit & Wafer	Snack	0,116	0,952	6,778
4	Biskuit & Wafer	Minuman Kemasan	0,116	0,952	3,201
5	Snack, Biskuit & Wafer	Minuman Kemasan	0,111	0,954	3,209
6	Snack, Minuman Kemasan	Biskuit & Wafer	0,111	0,840	6,973
7	Biskuit & Wafer, Minuman Kemasan	Snack	0,111	0,954	6,793
8	Snack	Biskuit & Wafer, Minuman Kemasan	0,111	0,792	6,858
9	Biskuit & Wafer	Snack, Minuman Kemasan	0,106	0,909	5,530
10	Pewangi Pakaian	Detergent	0,106	0,797	5,530

Berdasarkan Tabel 12. Dapat diketahui bahwa 10 *rules* yang terbentuk pada *cluster* 1 memenuhi nilai lift rasio > 1. Adapun penjelasan tabel sebagai berikut:

- a. Jika pelanggan *cluster* 1 membeli snack maka pelanggan juga membeli minuman kemasan berdasarkan tingkat kepercayaan 0,132, nilai dukungan 0,943 dan *lift ratio* 3,171. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.
- b. Jika pelanggan pada *cluster* 1 membeli snack maka pelanggan juga membeli biskuit & wafer berdasarkan tingkat kepercayaan 0,116, nilai dukungan 0,830 dan *lift ratio* 6,778. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.
- c. Jika pelanggan pada *cluster* 1 membeli biskuit & wafer maka pelanggan juga membeli snack berdasarkan tingkat kepercayaan 0,116, nilai dukungan 0,952 dan *lift ratio* 6,778. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.
- d. Jika pelanggan pada *cluster* 1 membeli biskuit & wafer maka pelanggan juga membeli minuman kemasan berdasarkan tingkat kepercayaan 0,116, nilai dukungan 0,952 dan *lift ratio* 3,201. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.
- e. Jika pelanggan pada *cluster* 1 membeli snack, biskuit & wafer maka pelanggan juga membeli minuman kemasan berdasarkan tingkat kepercayaan 0,111, nilai dukungan 0,954 dan *lift ratio* 3,209. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.
- f. Jika pelanggan pada *cluster* 1 membeli snack, minuman kemasan maka pelanggan juga membeli biskuit & wafer berdasarkan tingkat kepercayaan 0,111, nilai dukungan 0,840 dan *lift ratio* 9,973. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.
- g. Jika pelanggan pada *cluster* 1 membeli biskuit & wafer, minuman kemasan maka pelanggan juga membeli snack berdasarkan tingkat kepercayaan 0,111, nilai dukungan 0,954 dan *lift ratio* 9,973. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.
- h. Jika pelanggan pada *cluster* 1 membeli snack maka pelanggan juga membeli biskuit & wafer, minuman kemasan berdasarkan tingkat kepercayaan 0,111, nilai dukungan 0,792 dan *lift ratio* 6,858. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.
- i. Jika pelanggan pada *cluster* 1 membeli biskuit & wafer maka pelanggan juga membeli snack, minuman kemasan berdasarkan tingkat kepercayaan 0,106, nilai dukungan 0,909 dan *lift ratio* 5,530. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.
- j. Jika pelanggan pada *cluster* 1 membeli pewangi pakaian maka pelanggan juga membeli *detergent* berdasarkan tingkat kepercayaan 0,106, nilai dukungan 0,797 dan *lift ratio* 5,530. Ini menunjukkan sebuah *rules* yang bermanfaat dengan tingkat asosiasi tinggi.

Selanjutnya, hasil asosiasi pada *cluster* 3 membentuk 9 *rules* yang terdiri dari produk snack, minuman kemasan, biskuit & wafer, pewangi pakaian, *detergent*, dan *mie instant* terdapat pada Tabel 13.

Tabel 13. Hasil asosiasi *Cluster* 3

No	Premises	Conclusion	Support	Confidence	Lift Ratio
1	Snack	Minuman Kemasan	0,412	0,600	1,024
2	Minuman Kemasan	Snack	0,412	0,704	1,024
3	Biskuit & Wafer	Minuman Kemasan	0,275	0,572	0,977
4	Biskuit & Wafer	Snack	0,331	0,689	1,002
5	Snack, Biskuit & Wafer	Minuman Kemasan	0,178	0,538	0,919

No	Premises	Conclusion	Support	Confidence	Lift Ratio
6	Biskuit & Wafer, Minuman Kemasan	Snack	0,178	0,648	0,942
7	Pewangi Pakaian	Detergent	0,137	0,609	2,544
8	Detergent	Pewangi Pakaian	0,137	0,574	2,544
9	Mie Instant	Snack	0,149	0,586	0,853

Berdasarkan Tabel 13. Dapat diketahui bahwa hanya 5 rules yang memenuhi nilai lift ratio > 1. Penjelasan dari tabel sebagai berikut:

- Jika pelanggan pada cluster 3 membeli snack maka pelanggan juga membeli minuman kemasan berdasarkan tingkat kepercayaan 0,412, nilai dukungan 0,600 dan lift ratio 1,024. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi tinggi.
- Jika pelanggan pada cluster 3 membeli minuman kemasan maka pelanggan juga membeli snack berdasarkan tingkat kepercayaan 0,412, nilai dukungan 0,704 dan lift ratio 1,024. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi tinggi.
- Jika pelanggan pada cluster 3 membeli biskuit & wafer maka pelanggan juga membeli minuman kemasan berdasarkan tingkat kepercayaan 0,275, nilai dukungan 0,572 dan lift ratio 0,977. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi rendah.
- Jika pelanggan pada cluster 2 membeli biskuit & wafer maka pelanggan juga membeli snack berdasarkan tingkat kepercayaan 0,331, nilai dukungan 0,689 dan lift ratio 1,002. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi tinggi.
- Jika pelanggan pada cluster 3 membeli snack, biskuit & wafer maka pelanggan juga membeli minuman kemasan berdasarkan tingkat kepercayaan 0,178, nilai dukungan 0,538 dan lift ratio 0,919. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi rendah.
- Jika pelanggan pada cluster 3 membeli biskuit & wafer, minuman kemasan maka pelanggan juga membeli snack berdasarkan tingkat kepercayaan 0,178, nilai dukungan 0,648 dan lift ratio 0,942. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi rendah.
- Jika pelanggan pada cluster 3 membeli pewangi pakaian maka pelanggan juga membeli detergent berdasarkan tingkat kepercayaan 0,137, nilai dukungan 0,609 dan lift ratio 2,544. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi tinggi.
- Jika pelanggan pada cluster 3 membeli pewangi pakaian maka pelanggan juga membeli detergent berdasarkan tingkat kepercayaan 0,137, nilai dukungan 0,574 dan lift ratio 2,544. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi tinggi.
- Jika pelanggan pada cluster 3 membeli mie instant maka pelanggan juga membeli snack berdasarkan tingkat kepercayaan 0,149, nilai dukungan 0,586 dan lift ratio 0,853. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi rendah.

Selanjutnya, hasil asosiasi pada cluster 4 membentuk 3 rules yang terdiri dari minuman kemasan, biskuit & wafer, susu dan snack terdapat pada Tabel 14.

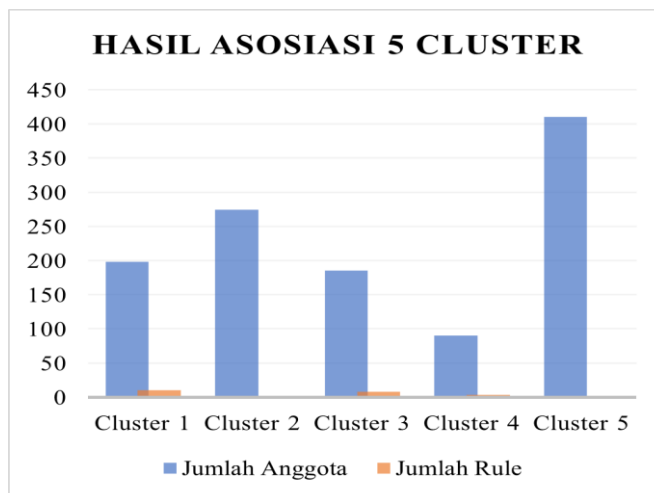
Tabel 14. Hasil asosiasi Cluster 4

No	Premises	Conclusion	Support	Confidence	Lift Ratio
1	Minuman Kemasan	Snack	0,139	0,551	1,370
2	Susu	Snack	0,108	0,552	1,305
3	Biskuit & Wafer	Snack	0,103	0,500	1,243

Berdasarkan Tabel 14. Dapat diketahui bahwa 3 rules yang terbentuk pada cluster 4 memenuhi nilai lift ratio > 1. Penjelasan dari tabel sebagai berikut:

- Jika pelanggan pada cluster 4 membeli minuman kemasan maka pelanggan juga membeli snack berdasarkan tingkat kepercayaan 0,139, nilai dukungan 0,551 dan lift ratio 1,370. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi rendah.
- Jika pelanggan pada cluster 4 membeli susu maka pelanggan juga membeli snack berdasarkan tingkat kepercayaan 0,108, nilai dukungan 0,552 dan lift ratio 1,305. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi rendah.
- Jika pelanggan pada cluster 4 membeli biskuit & wafer maka pelanggan juga membeli snack berdasarkan tingkat kepercayaan 0,103, nilai dukungan 0,500 dan lift ratio 1,243. Ini menunjukkan sebuah rules yang bermanfaat dengan tingkat asosiasi rendah.

Aturan asosiasi/pola yang ditemukan pada setiap cluster yang terbentuk menggunakan algoritma FP-Growth dengan nilai minimal support 10% dan nilai minimal confidence 60% menghasilkan jumlah rules yang berbeda. Adapun perbandingan jumlah pelanggan tiap cluster dan rules yang ditemukan terdapat pada Gambar 3.



Gambar 3. Grafik perbandingan rules tiap cluster

Berdasarkan uraian diatas dapat diketahui 10 rules pada cluster 1, 5 rules pada cluster 3, 3 rules pada cluster 4 sedangkan pada cluster 2 dan 5 tidak ditemukan rules.

4. KESIMPULAN

Implementasi metode *clustering* menggunakan algoritma K-Medoids dalam segmentasi pelanggan dengan model RFM menghasilkan dua kategori pelanggan. Kategori pertama adalah *Golden customers* ($R\downarrow F\uparrow M\uparrow$) yang terdapat pada cluster 1 adalah pelanggan dengan loyalitas tinggi. Hal ini diketahui dari nilai *recency* rendah, *frequency* tinggi dan *monetary* tinggi. Ini menandakan pelanggan sering melakukan pembelian dengan jumlah uang yang besar. pelanggan ini merupakan pelanggan potensial bagi perusahaan dan perlu dipertahankan dengan memberikan layanan terbaik agar pelanggan tidak beralih ke pesaing. Kategori kedua adalah *Dormant customers* ($R\downarrow F\downarrow M\downarrow$ dan $R\uparrow F\downarrow M\downarrow$) yang terdapat pada cluster 2, 3, 4, dan 5 merupakan pelanggan yang jarang bertransaksi dan memiliki nilai uang yang dikeluarkan rendah. Pelanggan pada segmen ini dapat menjadi pelanggan potensial bagi perusahaan. Strategi pemasaran seperti promosi kombinasi produk dapat digunakan untuk menarik pelanggan agar kembali bertransaksi, sehingga meningkatkan nilai *recency*, *frequency*, dan *monetary*. Selanjutnya, implementasi algoritma FP-Growth dengan nilai minimum *support* 10 % dan nilai minimum *confidence* 60% pada masing-masing cluster menghasilkan 10 rules pada cluster 1, 9 rules pada cluster 3, 3 rules pada cluster 4 sedangkan pada cluster 2 dan 5 tidak ditemukan rules. Rules ini dapat menjadi panduan untuk aktivitas promosi, termasuk strategi kombinasi produk yang ditargetkan untuk setiap cluster pelanggan. Secara keseluruhan, penggabungan model RFM dengan teknik data mining dapat meningkatkan efektivitas penjualan dan pemasaran produk, dan memastikan produk yang dijual lebih tepat sasaran dalam memenuhi kebutuhan dan preferensi pelanggan.

REFERENCES

- [1] S. M. Monalisa and D. A. Anjainah, "Analisis Rekomendasi Produk Berdasarkan Segmentasi Pelanggan Menggunakan Algoritma DBSCAN dan FP-Growth," *Techno. Com*, vol. 21, no. 4, pp. 948–956, 2022.
- [2] A. R. Riszky and M. Sadikin, "Data Mining Menggunakan Algoritma Apriori untuk Rekomendasi Produk bagi Pelanggan," *Jurnal Teknologi dan Sistem Komputer*, vol. 7, no. 3, pp. 103–108, 2019.
- [3] S. F. Octavia, M. Mustakim, I. Permana, and S. Monalisa, "Penerapan Algoritma Association Rules Dalam Penentuan Pola Pembelian Berdasarkan Hasil Clustering," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 7, no. 3, pp. 956–965, 2023.
- [4] V. Dawane, P. Waghodekar, and J. Pagare, "Rfm analysis using k-means clustering to improve revenue and customer retention," in *Proceedings of the International Conference on Smart Data Intelligence (ICSMDI 2021)*, 2021.
- [5] D. R. Ramadhan and N. Rokhman, "Segmentation-Based Sequential Rules For Product Promotion Recommendations As Sales Strategy (Case Study: Dayra Store)," *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, vol. 14, no. 3, pp. 243–252, 2020.
- [6] A. Wibowo and A. R. Handoko, "Segmentasi Pelanggan Ritel Produk Farmasi Obat Menggunakan Metode Data Mining Klasterisasi Dengan Analisis Recency Frequency Monetary (RFM) Termodifikasi," *J. Teknol. Inf. dan Ilmu Komput*, vol. 7, no. 3, 2020.
- [7] I. Kamila, U. Khairunnisa, and M. Mustakim, "Perbandingan Algoritma K-Means dan K-Medoids untuk Pengelompokan Data Transaksi Bongkar Muat di Provinsi Riau," *Jurnal Ilmiah Rekayasa dan Manajemen Sistem Informasi*, vol. 5, no. 1, pp. 119–125, 2019.
- [8] B. E. Adiana, I. Soesanti, and A. E. Permasasari, "Analisis segmentasi pelanggan menggunakan kombinasi RFM model dan teknik clustering," *Jurnal Terapan Teknologi Informasi*, vol. 2, no. 1, pp. 23–32, 2018.
- [9] A. A. D. Sulistyawati and M. Sadikin, "Penerapan Algoritma K-Medoids Untuk Menentukan Segmentasi Pelanggan," *SISTEMASI: Jurnal Sistem Informasi*, vol. 10, no. 3, pp. 516–526, 2021.



- [10] S. I. Murpratiwi, I. G. A. Indrawan, and A. Aranta, “Analisis Pemilihan Cluster Optimal Dalam Segmentasi Pelanggan Toko Retail,” *Jurnal Pendidikan Teknologi dan Kejuruan*, vol. 18, no. 2, pp. 152–163, 2021.
- [11] R. A. Suharjo and A. Wibowo, “Customer relationship management in retail using double association rule,” *International Journal*, vol. 8, no. 5, 2020.
- [12] A. R. Mulyawan, W. Gata, and S. Alfarizi, “MARKETING MAPS PADA LEMBAGA AMIL ZAKAT MENGGUNAKAN ALGORITMA CLUSTERING DAN ASSOCIATION RULES,” *Sistemasi: Jurnal Sistem Informasi*, vol. 9, no. 1, pp. 36–50, 2020.
- [13] I. D. Sudirman, R. S. Bahri, I. D. Utama, and C. I. Ratnapuri, “Using Association Rule to Analyze Hypermarket Customer Purchase Patterns,” *Proceedings of the Second Asia Pacific International Conference on Industrial Engineering and Operations Management*, 2021.
- [14] A. T. Suseno, A. R. Naufal, and M. Al Amin, “MARKET BASED ANALYSIS SEBAGAI PENINGKATAN PENJUALAN PRODUK MENGGUNAKAN ALGORITMA K-MEDOIDS DAN FP-GROWTH,” *Jurnal Teknkom (Teknik Informasi dan Komputer)*, vol. 5, no. 2, pp. 301–308, 2022.
- [15] S. G. Setyorini, E. K. Sari, L. R. Elita, and S. A. Putri, “Analisis Keranjang Pasar Menggunakan Algoritma K-Means dan FP-Growth pada PT. Citra Mustika Pandawa: Market Basket Analysis with K-Means and FP-Growth Algorithm as Citra Mustika Pandawa Company,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 1, no. 1, pp. 41–46, 2021.
- [16] G. J. Pabutungan and H. D. Purnomo, “Analisa Market Basket Analysis untuk Melihat Pola Transaksi Customer Menggunakan Algoritma Apriori dan FP-Growth,” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 7, no. 3, pp. 966–974, 2023.
- [17] L. A. Triana, N. I. Khoerida, N. T. Widiawati, and I. Tahyudin, “Implementation of the FP-Growth Algorithm in Sales Transactions for Menu Package Recommendations at Warung Oemah Tani,” *Internet of Things and Artificial Intelligence Journal*, vol. 2, no. 2, pp. 111–121, 2022.
- [18] N. F. Fahrudin and R. Rindiyani, “Comparison of K-Medoids and K-Means Algorithms in Segmenting Customers based on RFM Criteria,” in *E3S Web of Conferences*, EDP Sciences, 2024, p. 02008.
- [19] R. Siagian, P. Sirait, and A. Halim, “The Implementation of K-Means dan K-Medoids Algorithm for Customer Segmentation on E-commerce Data Transactions,” *Sistemasi: Jurnal Sistem Informasi*, vol. 11, no. 2, pp. 260–270, 2022.
- [20] A. Madani, A. R. A. Rahmah, F. N. F. Nurunnisa, and A. E. A. Elia, “Segmentasi Pelanggan pada BC HNI 2 Pekanbaru dengan Menerapkan Algoritma K-Medoids dan Model RFM (Recency, Frequency, Monetary): Customer Segmentation at BC HNI 2 Pekanbaru by Applying the K-Medoids Algorithm and Recency, Frequency, Monetary (RFM) Model,” in *SENTIMAS: Seminar Nasional Penelitian dan Pengabdian Masyarakat*, 2022, pp. 179–186.
- [21] S. M. S. Hosseini, A. Maleki, and M. R. Gholamian, “Cluster analysis using data mining approach to develop CRM methodology to assess the customer loyalty,” *Expert Syst Appl*, vol. 37, no. 7, pp. 5259–5264, 2010.
- [22] R. U. Khan, Y. Salamzadeh, Q. Iqbal, and S. Yang, “The impact of customer relationship management and company reputation on customer loyalty: The mediating role of customer satisfaction,” *Journal of Relationship Marketing*, vol. 21, no. 1, pp. 1–26, 2022.
- [23] S. Lamrhari, H. El Ghazi, M. Oubrich, and A. El Faker, “A social CRM analytic framework for improving customer retention, acquisition, and conversion,” *Technol Forecast Soc Change*, vol. 174, p. 121275, 2022.
- [24] A. Z. Putri, M. Afdal, S. Monalisa, and I. Permana, “Penerapan Algoritma Fuzzy C-Means Pada Segmentasi Pelanggan B2B dengan Model LRFM,” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 7, no. 3, pp. 1423–1432, 2023.
- [25] R. W. Sembiring Brahmana, F. A. Mohammed, and K. Chairuang, “Customer Segmentation Based on RFM Model Using K-Means, K-Medoids, and DBSCAN Methods,” *Lontar Komputer: Jurnal Ilmiah Teknologi Informasi*, vol. 11, no. 1, p. 32, Apr. 2020, doi: 10.24843/lkjiti.2020.v11.i01.p04.
- [26] N. Mirantika, T. S. Syamfithriani, and R. Trisudarmo, “Implementasi Algoritma K-Medoids Clustering Untuk Menentukan Segmentasi Pelanggan,” *NUANSA INFORMATIKA*, vol. 17, no. 1, pp. 196–204, 2023.
- [27] A. N. Shabrina, M. Afdal, and S. Monalisa, “Comparison Of K-Means, K-Medoids, and Fuzzy C-Means Algorithms for Clustering Drug User’s Addiction Levels,” *Jurnal Sistem Cerdas*, vol. 6, no. 2, pp. 113–122, 2023.
- [28] Y. Syahra, Y. Yusnidah, and B. Andika, “Penerapan Algoritma Fuzzy C-Means Dipadukan Dengan Model Fuzzy Recency Frequency Monetary (RFM) Untuk Customer Relationship Management (CRM)(Studi Kasus Di TokoSweet Amirah Medan),” *Jurnal SAINTIKOM (Jurnal Sains Manajemen Informatika dan Komputer)*, vol. 15, no. 1, pp. 7–16, 2019.
- [29] R. M. D. B. Akbar, P. Palupiningsih, and B. Prayitno, “IMPLEMENTASI ALGORITMA FP-GROWTH UNTUK PENENTUAN REKOMENDASI PRODUK UMKM BERDASARKAN FREKUENSI PEMBELIAN,” *Jurnal Teknoinfo*, vol. 17, no. 2, pp. 493–501, 2023.
- [30] Z. C. Dwyne, D. N. Aini, T. A. Pertiwi, S. Suryani, and D. Pramana, “Cluster Tingkat Kecanduan Game Online Pada Mahasiswa Fakultas Sains Dan Teknologi Dan Korelasinya Terhadap Minat Belajar: Cluster Level of Online Game Addiction in Students of the Faculty of Science and Technology and its Correlation with Learning Interest,” in *SENTIMAS: Seminar Nasional Penelitian dan Pengabdian Masyarakat*, 2023, pp. 126–132.
- [31] F. Hardiyanti, H. S. Tambunan, and I. S. Saragih, “PENERAPAN METODE K-MEDOIDS CLUSTERING PADA PENANGANAN KASUS DIARE DI INDONESIA,” *KOMIK (Konferensi Nasional Teknologi Informasi dan Komputer)*, vol. 3, no. 1, Dec. 2019, doi: 10.30865/komik.v3i1.1666.
- [32] T. Marzuqah, I. Permana, and M. Afdal, “Penerapan Algoritma FP-Growth Dalam Pencarian Hubungan Antara Waktu Pembelian Dan Barang yang Dibeli Untuk Strategi Promosi Penjualan,” *JURIKOM (Jurnal Riset Komputer)*, vol. 10, no. 3, pp. 697–703, 2023.
- [33] I. Ismarmiaty and R. Rismayati, “Product Sales Promotion Recommendation Strategy with Purchase Pattern Analysis FP-Growth Algorithm,” *Sinkron: jurnal dan penelitian teknik informatika*, vol. 8, no. 1, pp. 202–211, 2023.
- [34] N. P. Dharshinni, E. Bangun, S. Karunia, R. Damayanti, G. Rophe, and R. Pandapotan, “Menu Package Recommendation using Combination of K-Means and FP-Growth Algorithms at Bakery Stores: Menu Package Recommendation using Combination of K-Means and FP-Growth Algorithms at Bakery Stores,” *Jurnal Mantik*, vol. 4, no. 2, pp. 1272–1277, 2020.



- [35] S. Z. Harahap and A. Nastuti, “Teknik Data Mining Untuk Penentuan Paket Hemat Sembako Dan Kebutuhan Harian Dengan Menggunakan Algoritma Fp-Growth (Studi Kasus Di Ulfamart Lubuk Alung),” *Informatika*, vol. 7, no. 3, pp. 111–119, 2019.
- [36] A. Wilrose, M. Afdal, S. Monalisa, and M. Munzir, “Penerapan Algoritma FP-Growth untuk Menentukan Strategi Promosi Berdasarkan Waktu dan Pembelian Produk,” *Building of Informatics, Technology and Science (BITS)*, vol. 5, no. 1, Jun. 2023, doi: 10.47065/bits.v5i1.3577.