

ANALISIS SEGMENTASI PELANGGAN BERBASIS *RECENCY FREQUENCY MONETARY* (RFM) MENGGUNAKAN ALGORITMA *K-MEANS*

Panji Indra Pangestu, Teguh Iman Hermanto, Dede Irmayanti

Program Studi Teknik Informatika S1, Fakultas Teknik Informatika

STT Wastukencana, Jalan Cikopak No.53 Mulyamekar, Purwakarta, Jawa Barat 41151, Indonesia

panjiindra85@wastukencana.ac.id

ABSTRAK

Perkembangan bisnis saat ini berkembang dengan sangat pesat, Dengan kemajuan teknologi internet yang dapat membantu segala aktivitas bisnis. Meningkatnya perkembangan bisnis berdampak menghadirkan pesaing-pesaing bisnis baru, Maka perusahaan perlu strategi yang mampu menjaga kualitas pelanggan. Penelitian ini bertujuan untuk melakukan segmentasi pelanggan dari data transaksi penjualan perusahaan, Dengan jumlah transaksi yang banyak maka diperlukan teknologi untuk mengelompokkan suatu data sehingga metode yang digunakan pada penelitian ini adalah metode data *mining* dan menggunakan algoritma *K-Means*. Dengan Algoritma *K-Means* dapat membantu dalam pengelompokan pelanggan agar memudahkan perusahaan dalam melakukan strategi terhadap tiap-tiap kelompok pelanggan. Pengelompokan pelanggan ini menggunakan model awal *Recency*, *Frequency* dan *Monetary* (RFM) untuk membantu penghitungan kelompok pelanggan. Evaluasi data *mining* dilakukan menggunakan *Silhouette Coefficient* dengan hasil pengujian menggunakan *software Visual Studio Code* bahasa pemrograman python, Hasil penelitian ini terpilihnya 3 cluster yang terdiri dari *Low Loyalty* berjumlah 137 pelanggan, *Medium Loyalty* berjumlah 1636 pelanggan dan *Highest Loyalty* berjumlah 2395 pelanggan.

Kata kunci: RFM, Segmentasi Pelanggan, K-Means, Silhouette Coefficient

1. PENDAHULUAN

Dunia bisnis berkembang dengan sangat pesat saat ini. Hal ini sejalan dengan kemajuan teknologi internet yang dapat membantu semua aktivitas perusahaan. Internet telah berkembang untuk berbelanja di pasar baru yang dikenal sebagai e-commerce. E-commerce adalah sebuah platform atau wadah untuk melakukan pembelian dan penjualan produk dan jasa secara online.[1]

Dengan meningkatnya transaksi jual beli secara online berdampak menghadirkan saingan pada bisnis, Maka perusahaan perlu menerapkan suatu strategi yang tepat, Perlunya strategi yang mampu menjaga kualitas pelanggan sebagai cara untuk meningkatkan pendapatan perusahaan.[2]

Pelanggan memiliki kualitas, kebiasaan, dan tuntutan yang bervariasi, sehingga perlu untuk mengenali setiap pelanggan satu per satu bagi perusahaan agar tidak menjadi masalah, sehingga diperlukan strategi untuk memudahkan dalam mengidentifikasinya.[3]

Teknik *Recency*, *Frequency*, and *Monetary* (RFM) mengkaji karakteristik pelanggan berdasarkan data transaksi untuk menghasilkan tiga faktor utama, yaitu *recency*, *frequency*, dan *monetary*, dalam rangka mempelajari data historis peningkatan transaksi pelanggan. *Recency* merupakan jarak pelanggan terakhir melakukan transaksi dengan menghitung hari, bulan dan tahun, Dengan rentang waktu *recency* kecil pelanggan memiliki point lebih tinggi. *Frequency* merupakan seringnya pelanggan bertransaksi dalam skala waktu pengambilan data.[4] *Monetary* merupakan seberapa banyak jumlah uang pelanggan yang telah dikeluarkan dalam transaksi.

Algoritma yang digunakan untuk pengelompokan pelanggan adalah Algoritma *K-Means*, Metode *K-Means* adalah metode yang dikategorikan ke dalam metode klusterisasi partisi, Karena algoritma ini memiliki kesederhanaan dan kemudahan dalam menggunakannya dan pengguna bisa menentukan sendiri jumlah klusternya.[5]

Dengan pemanfaatan algoritma k-means dapat membagi semua pelanggan ke dalam kelompok *cluster* yang sesuai, setiap *cluster* dapat menentukan dan mempertahankan pelanggan yang menguntungkan dan loyal, Kemudian akan mengembangkan strategi penjualan untuk setiap *cluster* pelanggan.

Menurut penelitian yang dilakukan oleh Bayu Rizki, Nava Gia Ginasta, Muh Akbar Tamrin dan Ali Rahman dengan judul “*Customer Loyalty Segmentation on Point of Sale System Using Recency-Frequency-Monetary (RFM) and K-Means*”. Berdasarkan penelitian yang dilakukan metode RFM merupakan model awal yang digunakan *recency*, *frequency* dan *monetary* dapat membantu perusahaan dalam mengetahui loyalitas pelanggan. Hasil implementasi pengelompokan menggunakan algoritma *k-means* pada *point of sale* terbagi menjadi tiga *centroid* (loyalitas tinggi, sedang dan rendah) dan pengelompokannya berdasarkan jarak terkecil.

Sementara itu, Maulidah Fithryah, Muhammad Ainul Yaqin dan Syahiduz Zaman dengan judul “*K-Means Clustering Untuk Segmentasi Produk Berdasarkan Analisis Recency, Recency, Recency (RFM) pada Data Transaksi Penjualan*”. Pada

Penelitian ini menghasilkan sejumlah *cluster*, yang kemudian dianalisis dengan menggunakan pendekatan *Silhouette Coefficient* untuk menentukan

jumlah *cluster* yang ideal untuk mengelompokkan data yang ada. Nilai *silhouette* terbesar yang diperoleh pada temuan evaluasi adalah 0.4314 pada pengelompokan kedua dengan tiga *cluster*. [6]

2. LANDASAN TEORI

2.1. Data Mining

Data mining merupakan teknik penggalian data untuk menemukan pola yang bisa diklasifikasikan ke dalam pengetahuan yang berguna.[7]

Data mining adalah aktivitas yang menggambarkan sebuah proses analisis yang terjadi secara iteratif pada database yang besar.[8]

Istilah data mining disebut juga sebagai *knowledge discovery in database* (KDD) sering digunakan untuk menggambarkan proses penggalian informasi tersembunyi dari database besar. Oleh karena itu data mining digunakan untuk mengklasifikasikan data pelanggan dalam menentukan strategi penjualan.

2.2. Algoritma K-Means

K-Means merupakan metode *clustering* yang paling sederhana dan umum. *K-Means* memiliki kemampuan mengelompokkan data dalam jumlah cukup besar dalam waktu yang cepat.

Pada *K-Means* objek harus dalam kluster tertentu akan tetapi dalam tahapan berikutnya objek akan berpindah ke kluster lain.[9] Tahapan algoritma *K-Means* dijelaskan pada tahap berikut:[10]

1. Menentukan *K* sebagai jumlah kluster
2. Menentukan secara *random* nilai *k* untuk *centroid* awal
3. Menghitung jarak setiap data input dengan rumus *Euclidean Distance* sehingga dapat ditemukan jarak paling dekat dari setiap data dengan *centroid*. Berikut persamaan *Euclidean Distance* yang ditunjukkan pada persamaan (1):

$$d(x_i, \mu_j) = \sqrt{\sum (x_i - \mu_j)^2} \quad (1)$$

Dimana :

x_i :Data kriteria

μ_j :*Centroid* pada *cluster* ke-*j*

d :Klasifikasi data berdasarkan kedekatan *centroid*

4. Memperbaharui nilai *centroid*. Nilai *centroid* baru didapatkan dari rata-rata *cluster* yang bersangkutan dengan rumus (2):

$$\mu_j(t+1) = \frac{1}{N_{sj}} \sum_{j \in s_j} x_j \quad (2)$$

Dimana:

$\mu_j(t+1)$:*Centroid* baru pada iterasi

ke $(t+1)N_{sj}$:Banyak data pada *cluster* *Sj*

5. Ulangi dari langkah 4 hingga nilai tiap *cluster* tidak ada yang berubah.

Jika langkah 5 terpenuhi, maka nilai (μ_j) iterasi terakhir digunakan sebagai parameter.

2.3. Model RFM

Recency Frequency dan *Monetary* adalah teknik terenal yang digunakan dalam mengevaluasi pelanggan berdasarkan karakteristik pembelian. RFM digunakan untuk mengelompokkan pelanggan yang melibatkan sejumlah besar pelanggan pembelian online dan ritel.[11] Metode ini mengelompokkan pelanggan berdasarkan tiga dimensi sebagai berikut:

a. Recency

Recency untuk mengukur nilai dengan melihat waktu (tanggal, bulan, tahun) transaksi terakhir pelanggan, Dengan rentang waktu *recency* kecil mendapatkan nilai yang semakin tinggi.[12]

b. Frequency

Frequency untuk mengukur nilai dengan melihat seringnya pelanggan melakukan transaksi dalam satu periode. Dengan seringnya bertransaksi mendapatkan nilai semakin tinggi.[13]

c. Monetary

Monetary untuk mengukur nilai pelanggan dengan melihat jumlah uang yang dikeluarkan dalam satu periode. Semakin banyak jumlah uang yang dikeluarkan maka nilai *monetary* semakin tinggi.[14]

2.4. Silhouette Coefficient

Metode ini adalah pendekatan evaluasi kluster yang menggabungkan metode kohesi (yang mengukur kedekatan hubungan antara objek kluster) dan spasial (yang menghitung jarak pemisah antara objek kluster). Pendekatan ini menghasilkan visualisasi singkat, yang dianggap terbentuk dengan baik jika nilai indeks mendekati 1 dan kondisi kebalikannya jika nilainya mendekati -1. Persamaannya dapat ditemukan dalam persamaan (3):

$$s_i = \frac{b_{(i)} - a_{(i)}}{\max(a_{(i)}, b_{(i)})} \quad (3)$$

Dimana:

$b_{(i)}$: Jarak rata-rata di dalam *cluster*

$a_{(i)}$: Jarak rata-rata terdekat dengan *cluster* lain

$s_{(i)}$: [-1,1] -1 = buruk, 0 = *overlapping*, 1 = baik

3. METODE

Penelitian ini menerapkan *Knowledge Discovery in Database* (KDD) meliputi *dataset selection*, selanjutnya dilakukan *preprocessing*, lalu data setelah *preprocessing* dilakukan *transformation*, setelah melewati tahap *transformation* dilakukan *clustering k-means*, lalu dilakukan evaluasi untuk mengetahui tingkat akurasi paling optimal menggunakan *silhouette coefficient*, dan tahap terakhir segmentasi pelanggan. Dalam segmentasi pelanggan proses KDD dapat digunakan untuk mengidentifikasi pola atau karakteristik pelanggan yang berbeda berdasarkan atribut RFM

3.1. Dataset Selection

Pada tahap ini, data yang dipilih merupakan data transaksi penjualan *e-commerce shopee*. Dataset yang diambil yaitu data transaksi penjualan pada 01 Januari 2022 hingga 31 Desember 2022. Jumlah data transaksi sebanyak 255.000 data.

3.2. Preprocessing

Tahap *preprocessing* dilakukan menjadi 2 tahap yaitu, tahap *cleaning* dan tahap *reduction*. Tahap *cleaning* dilakukan pembersihan data dan nilai-nilai transaksi yang hilang, tidak valid atau duplikat. Tahap *reduction* dilakukan menghapus kolom atribut yang tidak diperlukan agar sesuai dengan kebutuhan.

3.3. Transformasi

Tahap *transformation* dilakukan dengan atribut yang terpilih dilakukan transformasi kedalam bentuk yang sesuai dengan algoritma dan teknik data mining yang digunakan pada penelitian ini. Setelah mendapatkan nilai transformasi maka dilakukan normalisasi data agar tidak ada selisih nilai yang jauh.

3.4. Data Mining

Pada tahap ini, teknik data mining dilakukan untuk pencarian pola dan mengeksplorasi data terpilih dengan menggunakan teknik dan metode tertentu. Metode yang digunakan dalam proses ini berupa *clustering*, klasifikasi, regresi, asosiasi dan lain-lain.

3.5. Evaluasi

Setelah dilakukan proses data mining selesai, hasil yang didapatkan akan dievaluasi agar mendapatkan hasil *cluster* optimal. Hasil yang didapatkan akan digunakan untuk membuat strategi atau keputusan yang relevan.

4. HASIL DAN PEMBAHASAN

4.1. Dataset Selection

Dataset *e-commerce* terdapat 47 atribut dengan jumlah transaksi selama 1 tahun pada bulan 01 Januari 2022 sampai 31 Desember 2022 sebanyak 255.000 record data.

Tabel 1. Sample Data Awal

Status Pesanan	Alasan Pembatalan	...	City
Selesai	-	-	KAB. BOGOR
Selesai	-	-	KAB. CILACAP
Selesai	-	-	KAB. CILACAP
...	...	...	...
Selesai	-	-	KAB. KARAWANG

4.2. Preprocessing

Tahapan *preprocessing* dilakukan beberapa tahapan berikut.

a. Data Cleaning

Lima atribut terpilih berupa data utuh yang dilakukan pembersihan data yang kosong, catatan transaksi nilai 0 dan data ganda dapat dilihat pada

Tabel 2 dan data yang sudah dibersihkan dapat dilihat Tabel 3.

Tabel 2. Sample Data Sebelum Cleaning

Status Pesanan	Alasan Pembatalan	...	City
Selesai			KAB. BOGOR
Batal	Dibatalkan secara otomatis oleh sistem. Alasan: Pesanan belum dibayar		KAB. SUKABUMI
Selesai			KAB. CILACAP
...	...	...	...
Batal	Dibatalkan oleh Pembeli. Alasan: Need to change delivery address		KOTA PEKANBARU

Tabel 3. Sample Data Sesudah Cleaning

Status Pesanan	Alasan Pembatalan	...	City
Selesai			KAB. BOGOR
Selesai			KAB. CILACAP
Selesai			KAB. CIANJUR
...	...	...	...
Selesai			KAB. TEGAL

Dengan data sebelum *cleaning* 255.000 data, setelah melakukan *cleaning* data berjumlah 199.999 data.

b. Data Reduction

Setelah melakukan *cleaning* data, catatan dan kolom atribut yang tidak perlu dihapus. Dari data awal; 47 atribut, terpilih 5 atribut yang sesuai model RFM yaitu *CustomerID*, *Quantity*, *UnitPrice*, *InvoiceNo* dan *InvoiceDate* dapat dilihat pada Tabel 4.

Tabel 4. Data Reduction

CustomerID	Quantity	UnitPrice	InvoiceNo	InvoiceDate
12434	8	59500	3242022 INV	3/24/2022 13:05
12423	10	59500	3212022 INV	3/21/2022 11:46
12372	12	12500	2162022 INV	2/16/2022 12:46
...	...	...	...	...
14911	6	29500	4112022 INV	4/11/2022 12:20

Data *reduction* didapatkan dari data awal yang diambil lalu dilakukan *cleaning* untuk pembersihan data, setelah data di bersihkan lalu atribut yang terpilih didapatkan dari proses *reduction* agar bisa dilakukan kedalam tahap selanjutnya yaitu tahap *transformation*.

4.3. Transformation

Data *transformation* dilakukan berdasarkan model RFM (*Recency*, *Frequency* dan *Monetary*) dapat dilihat pada Tabel 5.

Tabel 5. Data Transformation

Monetary	Frequency	Recency
6852800	9	74
11635800	44	18
1487000	7	309
...	...	...
6933600	36	231

Atribut *Monetary* adalah total transaksi yang dikeluarkan pelanggan antara 1 Januari 2022 sampai 31 Desember 2022. Atribut *monetary* diperoleh dari *Quantity* dikalikan dengan *UnitPrice*.

Atribut *Frequency* didefinisikan sebagai seberapa sering pelanggan bertransaksi dalam skala waktu dari 1 Januari 2022 hingga 31 Desember 2022. Atribut *frequency* berasal dari *InvoiceNo*.

Atribut *Recency* sesuai dengan jumlah hari pelanggan terakhir melakukan transaksi pada akhir periode pada tanggal 31 Desember 2022. Atribut *recency* berasal dari *InvoiceDate*.

Setelah melakukan *transformation* selanjutnya dilakukan normalisasi, Dikarenakan besarnya selisih nilai antara atribut *Monetary*, *Frequency* dan *Recency* untuk keakuratan hasil pengujian. Dapat dilihat pada Tabel 6.

Tabel 6. Data Normalisasi

Monetary	Frequency	Recency
0.004	0.002	0.218
0.007	0.011	0.053
0.001	0.001	0.912
...	...	...
0.004	0.009	0.681

4.4. Data Mining

Teknik data mining menyimpan data untuk menghasilkan informasi yang berguna. Pada tahap ini dilakukan *clustering* menggunakan algoritma *k-means* menggunakan 199.999 data transaksi. Dalam penentuan *cluster* awal dilakukan dengan pemilihan secara acak. Berikut adalah penentuan *cluster* awal dilihat pada Tabel 7.

Tabel 7. Cluster Awal

C	R	F	M
C0	256	2	356400
C1	232	1	150000
C2	222	2	77300

Dari tabel 7 berisi titik *centroid* awal yang diambil secara acak dari data transaksi, pengujian ini menggunakan algoritma *k-means* yang melakukan sebanyak 3 kali iterasi untuk menemukan hasil yang sama menggunakan rumus *euclidean distance*. Berikut ini merupakan sample perhitungan jarak *centroid* masing-masing *cluster*.

C0

$$\sqrt{(256 - 256)^2 + (2 - 2)^2 + (356400 - 356400)^2} = 0$$

C1


$$\sqrt{(256 - 232)^2 + (2 - 1)^2 + (356400 - 150000)^2} = 206400$$

C2

$$\sqrt{(256 - 222)^2 + (2 - 2)^2 + (356400 - 77300)^2} = 279100$$

Setelah mendapat *cluster* kemudian dilakukan *distribution* dari atribut *Recency* *Frequency* dan *Monetary* untuk melihat penyebaran dari tiap-tiap *cluster* yang sudah ditentukan, Dapat dilihat pada Gambar dibawah ini :

a. Recency Frequency (RF)




Gambar 1. Plot Recency dan Frequency

Pada Gambar 1 penyebaran *cluster0* dengan warna merah memiliki nilai *recency* dan *frequency* yang rendah, *cluster1* dengan warna biru memiliki nilai *recency* yang rendah dan nilai *frequency* yang tinggi, *cluster2* dengan warna hijau memiliki nilai *recency* yang tinggi dan nilai *frequency* yang rendah.


b. Monetary Recency (MR)

Pada Gambar 2 penyebaran *cluster0* dengan warna merah memiliki nilai *monetary* dan *recency* yang rendah, *cluster1* dengan warna biru memiliki nilai *monetary* yang tinggi dan *recency* yang rendah, *cluster2* dengan warna hijau memiliki nilai *monetary* yang rendah dan nilai *recency* yang tinggi.



Gambar 2. Plot Monetary dan Recency

c. Frequency Monetary (FM)




Gambar 3. Plot Frequency dan Monetary

Pada Gambar 3 penyebaran *cluster0* dengan warna merah memiliki nilai *frequency* dan *monetary* yang rendah, *cluster1* dengan warna biru memiliki nilai *frequency* dan *monetary* yang tinggi, *cluster2* dengan warna hijau memiliki nilai *frequency* dan *monetary* yang rendah.

4.5. Evaluasi

Pada tahap evaluasi data dilakukan dengan menggunakan *Silhouette Coefficient* dalam evaluasi data ini memiliki plot *silhouette* yang dapat dilihat pada Gambar 4.



Gambar 4. Plot Silhouette

Hasil *silhouette* pada gambar 4 menunjukkan cluster 3 adalah *cluster* yang paling mendekati angka 1, maka penulis menggunakan 3 *cluster* untuk pengelompokan pelanggan *e-commerce*. 3 *cluster* terdiri dari *Low Loyalty*, *Medium Loyalty* dan *Highest Loyalty*.

1. Highest Loyalty

Berisi pelanggan yang menghasilkan *monetary* dan *frequency* yang paling tinggi.

2. Medium Loyalty

Berisi pelanggan yang menghasilkan *frequency* sedang dan *monetary* sedang.

3. Low Loyalty

Berisi pelanggan yang menghasilkan *monetary* dan *recency* yang rendah, besar karena ini adalah pelanggan satu kali beli.

4.6. Segmentasi Pelanggan

Dari hasil kelompok pelanggan tersebut berjumlah 4168 pelanggan yang terbagi menjadi 3 kelompok dapat dilihat pada Gambar 6 merupakan jumlah tiap-tiap kelompok pelanggan.



Gambar 5. Customer Distribution

Kelompok pelanggan *Highest Loyalty* berjumlah 2395 pelanggan, Kelompok pelanggan *Medium Loyalty* berjumlah 1636 pelanggan dan kelompok pelanggan *Low Loyalty* berjumlah 137 pelanggan. Dari hasil 3 kelompok tersebut maka penulis melakukan

strategi penjualan sesuai dengan kelompoknya masing-masing sebagai berikut :

1. *Highest Loyalty*

Pada kelompok pelanggan *Highest Loyalty* strategi yang dilakukan dengan memberikan penghargaan kepada pelanggan tersebut, memberikan diskon sebesar 10% dan gratis ongkir. Dengan begitu kelompok pelanggan *Highest Loyalty* akan tetap bertahan tidak berpaling kepada saingan yang lainnya.

2. *Medium Loyalty*

Pada kelompok *Medium Loyalty* ini strategi yang dilakukan dengan memberikan rekomendasi produk berdasarkan pembelian sebelumnya dan diskon sebesar 10%. Dengan begitu kelompok pelanggan menjanjikan akan mempertahankan pembelian dan dapat meningkat menjadi kelompok *Highest Loyalty*.

3. *Low Loyalty*

Pada kelompok pelanggan *low loyalty* ini akan sering pergi dengan berbagai alasan, karena itu penulis menggunakan strategi penawaran harga, memberikan diskon sebesar 5%. Dengan begitu kelompok pelanggan ini dapat bertahan dan bisa menjadi kelompok *Medium Loyalty*.

5. KESIMPULAN

Analisis pengelompokan dari data transaksi pelanggan *e-commerce* menghasilkan 3 *cluster* dari 4168 pelanggan yaitu, *Low Loyalty* dengan 137 pelanggan, *Medium Loyalty* dengan 1636 pelanggan dan *Highest Loyalty* dengan 2395 pelanggan. Pada data yang telah dihasilkan maka pelanggan terbanyak merupakan *Highest Loyalty* dengan jumlah 2395 pelanggan. Berdasarkan hasil penelitian yang dilakukan algoritma K-Means dapat menjadi solusi dalam penelitian ini yakni menentukan kelompok pelanggan berdasarkan data transaksi penjualan. *Silhouette Coefficient* dapat membantu menemukan *cluster* paling optimal. Maka dari itu kelebihan pada penelitian ini penggunaan *k-means* dalam penentuan *cluster* dan dibantu menggunakan *silhouette coefficient* dalam menentukan *cluster* paling optimal. Dengan begitu memudahkan perusahaan dalam mengetahui karakteristik pelanggan berdasarkan kelompoknya dan membantu melakukan strategi yang tepat kepada pelanggan. Namun, Terdapat kekurangan pada penelitian ini, yaitu memerlukan data pelanggan terbaru agar proses pengelompokan pelanggan mendapatkan hasil terbaru.

DAFTAR PUSTAKA

- [1] M. Jordy, A. Triayudi, and I. D. Sholihati, "Analisis Segmentasi Recency dan Customer Value Pada AVANA Indonesia Dengan Algoritma K-Means dan Model RFM (Recency , Frequency and Monetary)," vol. 4, no. 2, pp. 579–589, 2023, doi: 10.47065/josh.v4i2.2950.
- [2] B. Rizki, N. G. Ginasta, M. A. Tamrin, and A. Rahman, "Customer Loyalty Segmentation on Point of Sale System Using Recency-Frequency-Monetary (RFM) and K-Means," *J. Online Inform.*, vol. 5, no. 2, p. 130, 2020, doi: 10.15575/join.v5i2.511.
- [3] R. Siagian, P. Sirait, and A. Halim, "E-Commerce Customer Segmentation Using K-Means Algorithm And LRFM Model," *JITE (Journal Informatics Telecommun. Eng.)*, vol. 5, no. 1, pp. 21–30, 2021, [Online]. Available: <http://ojs.uma.ac.id/index.php/jite>
- [4] B. Basri, W. Gata, and R. Risnandar, "Analisis Loyalitas Pelanggan Berbasis Model Recency, Frequency, dan Monetary (RFM) dan Decision Tree pada PT. Solo," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 5, p. 943, 2020, doi: 10.25126/jtiik.2020752284.
- [5] A. Febriani and S. A. Putri, "Segmentasi Konsumen Berdasarkan Model Recency, Frequency, Monetary dengan Metode K-Means," *Jiems (Journal Ind. Eng. Manag. Syst.)*, vol. 13, no. 2, pp. 52–57, 2020, doi: 10.30813/jiems.v13i2.2274.
- [6] M. Fithriyah, M. A. Yaqin, and S. Zaman, "K-Means Clustering Untuk Segmentasi Produk Berdasarkan Analisis Recency, Frequency, Monetary (RFM) Pada Data Transaksi Penjualan," *Ilk. J. Comput. Sci. Appl. Informatics*, vol. 3, no. 2, pp. 151–164, 2021, doi: 10.28926/ilkomnika.v3i2.284.
- [7] F. Firmansyah and A. Yulianto, "Market Basket Analysis for Books Sales Promotion using FP Growth Algorithm, Case Study: Gramedia Matraman Jakarta," *J. Informatics Telecommun. Eng.*, vol. 4, no. 2, pp. 383–392, 2021, doi: 10.31289/jite.v4i2.4539.
- [8] T. S. Syamfithriani, N. Mirantika, and R. Trisudarmo, "Perbandingan Algoritma K-Means dan K-Medoids Untuk Pemetaan Daerah Penanganan Diare Pada Balita di Kabupaten Kuningan," pp. 132–139, 2023, doi: 10.21456/vol12iss2pp132-139.
- [9] N. W. Wardani and E. Hartono, "Identifikasi Karakter Pelanggan Retail Berpotensi Churn Dengan Metoda Recency, Frequency Dan Monetary," *J. Teknol. Inf. dan ...*, pp. 268–277, 2020, [Online]. Available: <https://www.jurnal.undhirabali.ac.id/index.php/jutik/article/view/1155>
- [10] I. Rahma, P. Prima Arhandi, and A. Tufika Firdausi, "Penerapan Metode Hierarchical Clustering Dan K-Means Clustering Untuk Mengelompokkan Potensi Lokasi Penjualan Linkaja," *J. Inform. Polinema*, vol. 6, no. 1, pp. 15–22, 2020, doi: 10.33795/jip.v6i1.287.
- [11] A. J. Christy, A. Umamakeswari, L. Priyatharsini, and A. Neyaa, "RFM ranking – An effective approach to customer segmentation," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 33, no. 10, pp. 1251–1257, 2021, doi: 10.1016/j.jksuci.2018.09.004.
- [12] A. T. Wiratama, "Analisis Segmentasi Pelanggan

- Dengan RFM Model Pada Pt . Arthamas Citra Mandiri Menggunakan Metode Fuzzy C-Means Clustering,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 2, pp. 1986–1993, 2019.
- [13] R. Y. Firmansah, J. Dedy Irawan, and N. Vendyansyah, “Analisis Rfm (Recency, Frequency and Monetary) Produk Menggunakan Metode K-Means,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 5, no. 1, pp. 334–341, 2021, doi: 10.36040/jati.v5i1.3282.
- [14] A. P. Pramudiansyah, “Segmentasi Pelanggan Menggunakan Algoritma K-Means Berdasarkan Model Recency Frequency Monetary,” *J. Ilm. Ilmu Komput.*, vol. 7, no. 2, pp. 06–19, 2021, doi: 10.35329/jiik.v7i2.201.