

Penerapan Model *Recency, Frequency, Monetary* (RFM) Pada Sistem Segmentasi *Member* Solo Paragon Mall

Muflih Taquiuddin^{1*}, Vihi Atina², Dwi Hartanti³

¹Teknik Informatika, Fakultas Ilmu
Komputer

Universitas Duta Bangsa Surakarta
¹*220103267@mhs.udb.ac.id

²Teknik Informatika, Fakultas Ilmu
Komputer

Universitas Duta Bangsa Surakarta
²vihi_atina@udb.ac.id

³Teknik Informatika, Fakultas Ilmu
Komputer

Universitas Duta Bangsa Surakarta
³dwhartanti@udb.ac.id

Abstrak— Pusat perbelanjaan modern menghadapi tantangan dalam mengelola data member secara efektif untuk mendukung strategi pemasaran yang tepat sasaran. Solo Paragon Mall memiliki 780 data member dan 1.500 data transaksi yang hanya digunakan untuk keperluan administratif. Penelitian ini menerapkan model *Recency, Frequency, Monetary* (RFM) dikombinasikan dengan algoritma K-Means Clustering untuk melakukan segmentasi member. Tahapan penelitian mengikuti proses Knowledge Discovery in Databases (KDD) yang meliputi selection, preprocessing, transformation, data mining, dan interpretation/evaluation. Skor RFM dihitung menggunakan metode kuantil (skala 1–5) dan digunakan sebagai fitur clustering. Jumlah kluster optimal ditentukan dengan Elbow Method, sedangkan kualitas clustering dievaluasi menggunakan Davies-Bouldin Index (DBI). Hasil penelitian menunjukkan terbentuknya 4 kluster segmen member, yaitu Champion, Loyal Customer, At Risk, dan Lost Customer. Segmen Champion yang berjumlah 110 member (29,3% dari total 376 member) berkontribusi terhadap 75,3% total pendapatan, sementara Lost Customer (27,7% member) hanya menyumbang 3,3% pendapatan. Nilai Davies-Bouldin Index pada pendekatan RFM + K-Means sebesar 1,013 dibandingkan dengan 0,525 pada K-Means standar, yang menunjukkan bahwa skoring RFM mampu menyeimbangkan bobot ketiga dimensi sehingga segmentasi yang dihasilkan lebih relevan secara bisnis. Hasil segmentasi divisualisasikan melalui sistem berbasis web agar manajemen dapat mengakses informasi segmen member secara real-time. Penelitian ini menghasilkan segmentasi member yang lebih informatif dan akurat dibandingkan K-Means standar, sehingga manajemen dapat merancang program loyalitas yang lebih tepat sasaran.

Kata Kunci— RFM, K-Means Clustering, Segmentasi Pelanggan, Data Mining, KDD, Pusat Perbelanjaan

Abstract— Modern shopping centers face challenges in effectively managing member data to support targeted marketing strategies. Solo Paragon Mall has 780 member records and 1,500 transaction records that only been used for administrative purposes. This research applies the *Recency, Frequency, Monetary* (RFM) model combined with K-Means Clustering algorithm to perform member segmentation. The research follows the Knowledge Discovery in Databases (KDD) process, which includes data selection, data preprocessing, data transformation, data mining, and evaluation. RFM scores were calculated using the quantile method (scale 1–5) and used as clustering features. The optimal number of clusters was determined using the Elbow Method, while clustering quality was evaluated using the Davies-Bouldin Index (DBI). The results show the formation of 4 members segment cluster, namely Champion, Loyal Customer, At Risk, and Lost Customer. The Champion segment, comprising 110 members (29,3% of the total 376 members) contributed 75,3% of total revenue, while the Lost Customer segment (27,7% of members) contributed only 3,3% of revenue. The Davies-Bouldin Index value for the RFM + K-Means approach was 1,013 compared to 0,525 for standard K-Means, indicating that RFM scoring is able to balance the weight of the three dimensions so that the resulting segmentation is more relevant from a business perspective. Segmentation results were visualized through a web-based system to enable management to access member segment information in real-time. This study produces a more informative and accurate member segmentation compared to standard K-Means, enabling management to design more targeted loyalty programs.

Keywords— RFM, K-Means Clustering, Segmentasi Pelanggan, Data Mining, KDD, Pusat Perbelanjaan

I. PENDAHULUAN

Pusat perbelanjaan (mall) modern di Indonesia menghadapi persaingan yang semakin ketat dalam mempertahankan loyalitas konsumen. Solo Paragon Mall sebagai salah satu pusat perbelanjaan di Kota Surakarta memiliki ratusan *member* terdaftar yang melakukan transaksi secara rutin [1]. Namun, pengelolaan data member yang besar dan beragam menjadi tantangan tersendiri bagi manajemen dalam

merumuskan strategi pemasaran yang tepat sasaran.

Saat ini, data transaksi member yang mencakup 780 data member dan 1.500 data transaksi hanya digunakan untuk keperluan pencatatan administratif dan belum diolah menjadi informasi strategis yang berguna bagi pengambilan keputusan. Permasalahan yang ditemukan di Solo Paragon Mall adalah belum tersedianya sistem segmentasi member yang terkomputerisasi dan berbasis data. Pihak

manajemen kesulitan mengidentifikasi member mana yang paling aktif, paling banyak berbelanja, atau yang mulai menunjukkan penurunan aktivitas.


Akibatnya, program loyalitas yang dijalankan bersifat seragam (*one-size-fits-all*) dan kurang efektif dalam merespons kebutuhan tiap kelompok member secara spesifik. Kondisi ini mendorong perlunya penerapan teknik data *mining* untuk mengolah data transaksi menjadi pengetahuan yang bermanfaat dalam segmentasi member [2].

Model *Recency, Frequency, Monetary* (RFM) merupakan pendekatan yang efektif untuk menganalisis perilaku transaksi pelanggan berdasarkan tiga dimensi, yaitu kebaruan transaksi (*Recency*), frekuensi transaksi (*Frequency*), dan moneter transaksi (*Monetary*) [3]. Untuk mendapatkan pengelompokan yang optimal dari skor RFM, penelitian ini menggunakan algoritma K-Means Clustering yang direkomendasikan untuk *dataset* berukuran sedang.

Tujuan penelitian ini adalah menerapkan model RFM untuk mengolah data transaksi *member* menjadi skor *recency*, *frequency*, dan *monetary* [4]. Selanjutnya, skor tersebut digunakan dalam proses segmentasi menggunakan K-Means Clustering berdasarkan skor RFM. Selain itu, penelitian ini bertujuan membangun sistem berbasis web untuk melakukan *input* data, segmentasi, dan menampilkan hasil dalam bentuk visualisasi. Pada tahap akhir, penelitian ini membandingkan kinerja metode RFM + K-Means dengan K-Means standar menggunakan Davies-Bouldin Index.

II. METODOLOGI PENELITIAN

A. Tahapan Penelitian



Gambar 1. Tahapan *Knowledge Discovery in Databases* (KDD)

Penelitian ini merupakan penelitian terapan (*applied research*) di bidang rekayasa perangkat lunak dan data *mining*, yang mengikuti tahapan *Knowledge Discovery in Databases* (KDD) [5], seperti ditunjukkan pada Gambar 1 data yang digunakan merupakan data primer dari pihak manajemen Solo Paragon Mall, terdiri atas data *member*, data transaksi, dan data trafik pengunjung harian sebagai data pendukung. Kelima tahapan ini dilakukan secara berurutan, yaitu seleksi data, pra-pemrosesan data, transformasi data, data *mining*, dan evaluasi. Berikut ini penjelasan masing-masing tahapan yang diterapkan pada penelitian ini:

1. Seleksi Data

Tahap ini memilih variabel yang relevan dari data yang telah dikumpulkan, yaitu tanggal belanja untuk *Recency*, jumlah transaksi per *member* untuk *Frequency*, dan total nilai transaksi per *member* untuk *Monetary* [6]. Data trafik harian digunakan sebagai pendukung untuk melakukan validasi kewajaran pola transaksi, namun tidak dijadikan variabel RFM secara langsung.

2. Pra-Pemrosesan Data

Data mentah dibersihkan dengan menghapus transaksi duplikat atau tidak lengkap, menangani nilai kosong, menyeragamkan format tanggal dan mata uang, serta menggabungkan data *member* dengan data transaksi berdasarkan nomor ID yang digunakan untuk memastikan data siap digunakan pada tahap selanjutnya [7]. Transaksi yang tidak memiliki data *member* valid dikeluarkan dari analisis selanjutnya.

3. Transformasi Data

Data yang telah bersih diubah menjadi skor RFM per *member* melalui perhitungan *Recency*, *Frequency*, dan *Monetary*. Ketiga nilai tersebut diberikan skor 1-5 menggunakan metode kuantil, lalu dinormalisasi ke rentang 0-1 dengan *Min.-Max. Normalization* agar setara secara numerik sebagai titik koordinat dalam proses klasterisasi.

4. Data Mining

Jumlah klaster optimal (K) ditentukan menggunakan *Elbow Method* dengan melihat titik siku pada grafik *Within-Cluster Sum of Squares* (WCSS) [8]. Algoritma K-Means kemudian dijalankan pada data RFM yang telah

dinormalisasi, meliputi inisialisasi *centroid*, perhitungan jarak Euclidean, penetapan data ke *centroid* terdekat, dan pembaruan *centroid* hingga ke konvergen [9]. Sebagai pembanding, K-Means juga dijalankan langsung pada data mentah RFM tanpa *skoring kuantil*, disebut pendekatan K-Means standar.

5. Evaluasi

Kualitas hasil klasterisasi dari kedua pendekatan dibandingkan menggunakan Davies-Bouldin Index (DBI), di mana nilai yang lebih kecil menunjukkan klaster yang lebih baik [10]. Setiap klaster kemudian diberi label segmen (*Champion*, *Loyal Customer*, *At Risk*, *Lost Customer*) berdasarkan karakteristik skor RFM rata-ratanya, serta dianalisis kontribusinya terhadap total pendapatan.

B. Perancangan dan Pengembangan Sistem

Hasil dari tahapan *Knowledge Discovery in Databases* (KDD) tersebut diimplementasikan ke dalam sistem berbasis web menggunakan *framework* Laravel agar manajemen Solo Paragon Mall dapat mengakses hasil segmentasi *member* secara interaktif *real-time*. Perancangan sistem diawali dengan *use case diagram* untuk identifikasi kebutuhan fungsional, dilanjutkan *wireframe* dengan prinsip hierarki “*overview ke kontrol ke detail*”. *Wireframe* merupakan desain antarmuka yang digunakan untuk menyusun elemen-elemen pada halaman aplikasi sebelum proses antarmuka dimulai [11]. Rincian ketiganya dijabarkan pada Bagian III-B-1 hingga Bagian III-B-3.

C. Kerangka Pengujian

Untuk memastikan ketepatan implementasi algoritma pada sistem, dilakukan pengujian dengan membandingkan hasil perhitungan manual pada sampel data terhadap keluaran sistem, yang mencakup skor RFM, normalisasi data (*min.-max.*), penentuan klaster melalui jarak Euclidean, hingga nilai Davies-Bouldin Index (DBI), sebagaimana disajikan pada Bagian III-A-3-a hingga Bagian III-A-3-c serta pada Bagian III-A-4-a.

III. HASIL DAN PEMBAHASAN

A. Hasil Analisis Data (Tahapan KDD)

1. Seleksi Data

Tahap seleksi data dilakukan untuk menentukan data yang akan digunakan pada proses penelitian. Data yang digunakan berupa data transaksi *member* Solo Paragon Mall yang diperoleh dalam bentuk berkas dengan format CSV. *Dataset* yang dipilih mencakup transaksi pada periode 2 Januari 2026 hingga 28 Mei 2026 serta berisi informasi yang diperlukan dalam pembentukan model *Recency*, *Frequency*, *Monetary* (RFM) seperti *member*, tanggal transaksi, dan nilai transaksi.

2. Pra-Pemrosesan Data

Setelah tahap seleksi data, dilakukan tahap pra-pemrosesan data untuk memastikan kualitas data sebelum diproses lebih lanjut. Proses ini meliputi penghapusan baris transaksi yang tidak lengkap (*missing values*) serta penyeragaman format tanggal dan nilai mata uang. Hasilnya diperoleh 1.540 transaksi valid dari 376 *member* unik dengan total nilai transaksi sebesar Rp7.254.056.266. Selanjutnya, tanggal 29 Mei 2026 ditetapkan sebagai tanggal referensi, yaitu satu hari setelah transaksi terakhir dalam *dataset* agar seluruh *member* memiliki titik acuan yang sama dalam perhitungan variabel *Recency*. Adapun ringkasan data yang digunakan dalam penelitian ini disajikan pada Tabel 1.

Tabel 1. Ringkasan data penelitian

Keterangan	Nilai
Jumlah <i>Member</i> Unik	376 <i>member</i>
Jumlah Transaksi	1.540 transaksi
Total Nilai Transaksi	Rp7.254.056.266
Periode Data	2 Januari 2026 s.d. 28 Mei 2026
Tanggal Referensi (untuk <i>Recency</i>)	29 Mei 2026 (H+1 dari transaksi terakhir)

3. Transformasi Data

Pada tahap selanjutnya, dilakukan transformasi data dengan menggunakan rumus *Recency*, *Frequency*, *Monetary* (RFM), *skoring kuantil*, serta normalisasi data (*min.-max.*) yang diuji secara manual pada sebuah sampel data. Sampel yang digunakan adalah 10 *member* dengan total nilai belanja (*Monetary*) tertinggi dari seluruh 376 *member*, dengan pertimbangan bahwa kelompok ini merupakan kontributor

pendapatan terbesar sehingga hasil pengelompokannya paling relevan untuk dibuktikan secara manual. Perhitungan manual ini menggunakan data mentah (*Recency*, *Frequency*, *Monetary*) yang diagregasi dari keseluruhan riwayat transaksi tiap member pada dataset, bukan hanya sebagian baris data, sehingga hasilnya dapat dibandingkan secara langsung dan konsisten dengan keluaran sistem pada Bagian III-B-3.

Tabel 2. 10 Sampel data *member* dengan nilai belanja (*Monetary*) tertinggi

No	Nama Member	No. Member	Recency (hari)	Frequency (kali)	Monetary (Rp)
1	Ningsih	2023 10 0107	2	58	897.577.259
2	David	2023 10 0097	1	28	771.707.300
3	Dwi	2023 10 0528	5	27	560.129.129
4	Nicholas	2023 10 0587	12	26	545.783.700
5	Wibowo	2023 10 0572	3	12	283.645.800
6	Handoyo	2023 10 0619	98	7	220.564.000
7	Monika	2023 10 0481	1	13	153.395.930
8	Rahayu	2023 10 0673	2	9	151.514.000
9	Susanti	2023 10 0041	5	12	131.305.800
10	Albert	2023 10 0667	98	3	118.675.000

a. Perhitungan *Recency*, *Frequency*, dan *Monetary*

Ketiga nilai dasar RFM dihitung dengan rumus berikut:

$$\text{Recency} = \text{Tanggal Referensi} - \text{Tanggal Transaksi Terakhir Member} \quad (1)$$

$$\text{Frequency} = \text{Jumlah Baris Transaksi Milik Member} \quad (2)$$

$$\text{Monetary} = \Sigma (\text{Nilai Transaksi Member}) \quad (3)$$

Sebagai ilustrasi, pada rumus-rumus berikut diuraikan perhitungan penuh untuk dua sampel yang mewakili dua karakteristik berbeda: Eka Rahayu (frekuensi sedang, transaksi baru) dan Albert Widjaja (frekuensi rendah, transaksi lama, namun nilai besar). Perhitungan pada dua sampel tersebut disajikan sebagai berikut:

1) Contoh Ke-1 — Eka Rahayu (No. *Member* 2023 10 0673)

Seluruh transaksi Eka Rahayu yang tercatat pada *dataset* adalah sebagai berikut:

Tabel 3. Riwayat transaksi Eka Rahayu

No.	Tanggal	Nilai Transaksi (Rp)
1	12 Feb 2026	12.015.000
2	20 Feb 2026	3.999.000
3	28 Feb 2026	18.342.000
4	11 Mar 2026	23.804.000
5	04 Apr 2026	9.549.000
6	02 Mei 2026	9.948.000
7	14 Mei 2026	39.056.000
8	16 Mei 2026	13.068.000
9	27 Mei 2026	21.733.000

Frequency = 9 (jumlah baris transaksi).

Monetary = (12.015.000 + 3.999.000 + 18.342.000 + 23.804.000 + 9.549.000 + 9.948.000 + 39.056.000 + 13.068.000 + 21.733.000) = Rp151.514.000.

Recency = Tanggal Referensi (29 Mei 2026) – Tanggal Transaksi Terakhir (27 Mei 2026) = 2 hari.

2) Contoh 2 — Albert Widjaja (No. *Member* 2023 10 0667)

Seluruh transaksi Albert Widjaja yang tercatat pada *dataset* adalah sebagai berikut:

Tabel 4. Riwayat transaksi Albert Widjaja

No.	Tanggal	Nilai Transaksi (Rp)
1	28 Jan 2026	50.000.000
2	20 Feb 2026	50.000.000
3	20 Feb 2026	18.675.000

Frequency = 3 (jumlah baris transaksi).

Monetary = (50.000.000 + 50.000.000 + 18.675.000) = Rp118.675.000.

Recency = (29 Mei 2026 – 20 Februari 2026) = 98 hari; (8 hari sisa Februari + 31 hari Maret + 30 hari April + 29 hari Mei = 98 hari).

Kedua contoh di atas menunjukkan bahwa nilai akhir yang identik dengan baris ke-8 dan ke-10 pada Tabel 2 yang berarti agregasi *Recency*, *Frequency*, *Monetary* telah dihitung dengan benar. Kedelapan sampel lainnya pada Tabel 2 dihitung dengan metode identik menggunakan seluruh riwayat transaksi masing-masing *member*.

b. Penentuan Skor RFM (*Skoring Kuantil*)

Nilai *Recency*, *Frequency*, *Monetary* yang masih berskala berbeda-beda selanjutnya diubah menjadi skor 1-5 menggunakan metode kuantil berbasis peringkat (*rank-based quantile*), dengan langkah-langkah sebagai berikut: Seluruh 376 *member* diurutkan menaik berdasarkan nilai dimensi yang dihitung. Selanjutnya, setiap *member* diberi persentil = peringkat / (n-1). Kemudian, persentil dipetakan ke salah satu dari 5 kelompok yang berukuran sama (*bucket* = [persentil × 5], skor = *bucket* + 1). Pada langkah terakhir, nilai untuk *Frequency* dan *Monetary* diberikan skor 5 pada nilai tertinggi, sedangkan nilai untuk *Recency* arah dibalik (skor = 6 – skor) karena semakin kecil jumlah hari sejak transaksi terakhir, maka nilai semakin baik.

Perhitungan untuk Eka Rahayu (n = 376, sehingga n-1 = 375):

Tabel 5. Perhitungan skor kuantil Eka Rahayu

Dime nsi	Nilai Mentah	Pering kat	Persentil	Bucket	Skor
<i>Recency</i>	2 hari	16 dari 375	$16/375 = 0,0427$	$[0,0427 \times 5] = 0$	$6 - 0 = 6$
<i>Frequency</i>	9 kali	333 dari 375	$333/375 = 0,8880$	$[0,8880 \times 5] = 4$	$4 + 1 = 5$
<i>Monetary</i>	Rp151.51 4.000	368 dari 375	$368/375 = 0,9813$	$[0,9813 \times 5] = 4$	$4 + 1 = 5$

Perhitungan untuk Albert Widjaja (n = 376, sehingga n-1 = 375):

Tabel 6. Perhitungan skor kuantil Albert Widjaja

Dime nsi	Nilai Mentah	Pering kat	Persentil	Bucket	Skor
<i>Recency</i>	98 hari	320 dari 375	$320/375 = 0,8533$	$[0,8533 \times 5] = 4$	$6 - 4 = 2$
<i>Frequency</i>	3 kali	191 dari 375	$191/375 = 0,5093$	$[0,5093 \times 5] = 2$	$2 + 1 = 3$
<i>Monetary</i>	Rp118.67 5.000	366 dari 375	$366/375 = 0,9760$	$[0,9760 \times 5] = 4$	$4 + 1 = 5$

Menarik untuk dicatat bahwa meskipun Albert Widjaja termasuk 10 penyumbang nilai belanja terbesar (*Monetary* tetap memiliki skor 5), sementara skor *Recency* justru lebih rendah (skor 1) dikarenakan sudah 98 hari tidak melakukan transaksi, dan skor *Frequency* hanya sedang

(skor 3) karena hanya melakukan transaksi 3 kali. Kombinasi ini nantinya akan menempatkan Albert Widjaja pada segmen *Loyal Customer* bukan *Champion*, meskipun nilai belanjanya besar. Hal ini menunjukkan bahwa pendekatan RFM menilai pelanggan secara multidimensi, tidak hanya dari besarnya nilai transaksi semata.

Tabel 7. Skor RFM (1-5) untuk 10 sampel data

No.	Nama Member	R	F	M
1	Ningsih	5	5	5
2	David	5	5	5
3	Dwi	5	5	5
4	Nicholas	4	5	5
5	Wibowo	5	5	5
6	Handoyo	1	5	5
7	Monika	5	5	5
8	Rahayu	5	5	5
9	Susanti	5	5	5
10	Albert	1	3	5

c. Normalisasi Data (*Min.-Max.*)

Skor R, F, M (rentang 1-5) selanjutnya dinormalisasi ke rentang (0-1) agar setara secara numerik sebagai koordinat titik dalam proses klusterisasi, dengan menggunakan rumus berikut:

$$x' = (x - \min. (x)) / (\max. (x) - \min. (x)) \quad (4)$$

Karena metode *skoring kuantil* pada (Bagian A-3b) selalu menghasilkan rentang skor 1-5 untuk populasi 376 *member*, maka *min. (x)* = 1 dan *max. (x)* = 5 berlaku untuk R, F, maupun M. Rumus di atas dapat disederhanakan menjadi $x' = (\text{skor}-1) / 4$. Hasil normalisasi untuk 10 sampel data disajikan pada Tabel 8.

Tabel 8. Hasil normalisasi data (*min.-max.*) skor RFM untuk 10 sampel data

No	Nama Member	R'	F'	M'
1	Ningsih	1,00	1,00	1,00
2	David	1,00	1,00	1,00
3	Dwi	1,00	1,00	1,00
4	Nicholas	0,75	1,00	1,00
5	Wibowo	1,00	1,00	1,00
6	Handoyo	0,00	1,00	1,00
7	Monika	1,00	1,00	1,00
8	Rahayu	1,00	1,00	1,00
9	Susanti	1,00	1,00	1,00
10	Albert	0,00	0,50	1,00

4. Data Mining (K-Means Clustering)

a. Penentuan Klaster dengan Perhitungan Jarak Euclidean

Pada tahapan data *mining*, K-Means digunakan untuk menetapkan setiap titik data ke klaster dengan *centroid* terdekat (langkah *assignment*), dihitung dengan rumus jarak Euclidean tiga dimensi sebagai berikut:

$$d(x, c) = \sqrt{[(x_1 - c_1)^2 + (x_2 - c_2)^2 + (x_3 - c_3)^2]} \quad (5)$$

Karena proses pelatihan (iterasi *assignment*, *update centroid*, hingga konvergen) dilakukan sistem terhadap keseluruhan 376 titik data, replikasi seluruh iterasi tersebut secara manual tidak praktis dilakukan dengan tangan. Namun demikian, langkah *assignment* yang merupakan inti perhitungan K-Means dapat dibuktikan secara manual dengan cara mengambil *centroid* akhir (final) yang dihasilkan sistem pada $K = 4$, kemudian menghitung ulang secara manual jarak Euclidean dari tiap sampel ke keempat *centroid* tersebut, dan memastikan klaster terdekat (jarak *minimum*) sesuai dengan label segmen yang ditampilkan sistem. Keempat *centroid* akhir tersebut adalah:

Tabel 9. *Centroid* akhir hasil K-Means ($K = 4$)

Klaster / Segmen	R'	F'	M'	Jumlah Anggota
<i>Champion</i>	0,8455	0,8886	0,8295	110
<i>Loyal Customer</i>	0,3219	0,6062	0,6969	80
<i>At Risk</i>	0,7134	0,3750	0,2439	82
<i>Lost Customer</i>	0,0986	0,1106	0,2067	104

Contoh perhitungan untuk Eka Rahayu, titik ternormalisasi (1,00; 1,00; 1,00):

$$\begin{aligned} d(\text{Eka}, \text{Champion}) &= \sqrt{[(1-0,8455)^2 + (1-0,8886)^2 + (1-0,8295)^2]} \\ &= \sqrt{0,0654} = 0,2556 \end{aligned}$$

$$\begin{aligned} d(\text{Eka}, \text{Loyal}) &= \sqrt{[(1-0,3219)^2 + (1-0,6062)^2 + (1-0,6969)^2]} \\ &= \sqrt{0,7068} = 0,8407 \end{aligned}$$

$$\begin{aligned} d(\text{Eka}, \text{At Risk}) &= \sqrt{[(1-0,7134)^2 + (1-0,3750)^2 + (1-0,2439)^2]} \\ &= \sqrt{1,0445} = 1,0220 \end{aligned}$$

$$\begin{aligned} d(\text{Eka}, \text{Lost}) &= \sqrt{[(1-0,0986)^2 + (1-0,1106)^2 + (1-0,2067)^2]} \\ &= \sqrt{2,2329} = 1,4943 \end{aligned}$$

Jarak terkecil adalah ke *centroid Champion* (0,2556), sehingga Eka Rahayu ditetapkan

sebagai anggota klaster *Champion* sesuai dengan label yang tampil pada sistem (dapat diverifikasi pada Gambar 11 di Bagian III-E-6).

Contoh perhitungan untuk Albert Widjaja, titik ternormalisasi (0,00; 0,50; 1,00):

$$\begin{aligned} d(\text{Albert}, \text{Champion}) &= \sqrt{[(0-0,8455)^2 + (0,5-0,8886)^2 + (1-0,8295)^2]} \\ &= \sqrt{0,8944} = 0,9460 \end{aligned}$$

$$\begin{aligned} d(\text{Albert}, \text{Loyal}) &= \sqrt{[(0-0,3219)^2 + (0,5-0,6062)^2 + (1-0,6969)^2]} \\ &= \sqrt{0,2068} = 0,4547 \end{aligned}$$

$$\begin{aligned} d(\text{Albert}, \text{At Risk}) &= \sqrt{[(0-0,7134)^2 + (0,5-0,3750)^2 + (1-0,2439)^2]} \\ &= \sqrt{1,0961} = 1,0470 \end{aligned}$$

$$\begin{aligned} d(\text{Albert}, \text{Lost}) &= \sqrt{[(0-0,0986)^2 + (0,5-0,1106)^2 + (1-0,2067)^2]} \\ &= \sqrt{0,7907} = 0,8892 \end{aligned}$$

Jarak terkecil adalah ke *centroid Loyal Customer* (0,4547), sehingga Albert Widjaja ditetapkan sebagai anggota klaster *Loyal Customer* bukan *Champion* yang membuktikan secara kuantitatif alasan yang telah didiskusikan pada Bagian III-A-3-b.

Tabel 10. Rekapitulasi jarak Euclidean dan klaster terpilih untuk 10 sampel data

Nama Member	d.Champion	d.Loyal	d.At Risk	d.Lost	Klaster Terpilih (manual)	Segmen Sistem
Ningsih	0,2556	0,8407	1,0220	1,4943	<i>Champion</i>	<i>Champion</i>
David	0,2556	0,8407	1,0220	1,4943	<i>Champion</i>	<i>Champion</i>
Dwi	0,2556	0,8407	1,0220	1,4943	<i>Champion</i>	<i>Champion</i>
Nicholas	0,2249	0,6559	0,9817	1,3582	<i>Champion</i>	<i>Champion</i>
Wibowo	0,2556	0,8407	1,0220	1,4943	<i>Champion</i>	<i>Champion</i>
Handoyo	0,8697	0,5921	1,2130	1,1959	<i>Loyal Customer</i>	<i>Loyal Customer</i>
Monika	0,2556	0,8407	1,0220	1,4943	<i>Champion</i>	<i>Champion</i>
Rahayu	0,2556	0,8407	1,0220	1,4943	<i>Champion</i>	<i>Champion</i>
Susanti	0,2556	0,8407	1,0220	1,4943	<i>Champion</i>	<i>Champion</i>
Albert	0,9460	0,4547	1,0470	0,8892	<i>Loyal Customer</i>	<i>Loyal Customer</i>

Pada Tabel 10 menunjukkan bahwa hasil perhitungan manual (kolom “Klaster Terpilih”) sama persis dengan label segmen yang dihasilkan

sistem (kolom “Segmen Sistem”) untuk seluruh 10 sampel data (kecocokan 10 dari 10, atau 100%). Hasil ini membuktikan bahwa rumus perhitungan RFM, *skoring kuantil*, normalisasi data (*min.-max.*), dan langkah *assignment* K-Means telah diimplementasikan dengan benar pada sistem.

5. Evaluasi

a. Perhitungan Davies-Bouldin Index

Kualitas hasil klusterisasi dievaluasi dengan Davies-Bouldin Index (DBI), dihitung melalui tiga rumus berikut:

$$S_i = \text{Rata-rata jarak anggota klaster-}i \text{ ke } \textit{centroid-nya sendiri} \quad (6)$$

$$R_{ij} = (S_i + S_j) / d(\textit{centroid}_i, \textit{centroid}_j) \quad (7)$$

$$DBI = (1/k) \sum \max_{j \neq i} (R_{ij}) \quad (8)$$

Berdasarkan seluruh 376 data pada $K = 4$, sistem menghitung nilai S_i (kepadatan klaster) sebagai berikut:

Tabel 11. Nilai S_i (kepadatan klaster)

Klaster	S_i (rata-rata jarak ke <i>centroid</i>)
<i>Champion</i>	0,2906
<i>Loyal Customer</i>	0,3445
<i>At Risk</i>	0,3189
<i>Lost Customer</i>	0,3076

Serta, adapun jarak antar *centroid* disajikan pada tabel sebagai berikut:

Tabel 12. Jarak antar *centroid*

Pasangan Klaster	Jarak <i>Centroid</i>
<i>At Risk – Champion</i>	0,7901
<i>At Risk – Loyal Customer</i>	0,6418
<i>At Risk – Lost Customer</i>	0,6703
<i>Champion – Loyal Customer</i>	0,6095
<i>Champion – Lost Customer</i>	1,2454
<i>Loyal Customer – Lost Customer</i>	0,7320

Dari kedua tabel di atas, dihitung R_{ij} untuk tiap pasangan, kemudian diambil nilai maksimum (D_i) untuk tiap klaster:

Tabel 13. Nilai R_{ij} dan D_i maksimum

Klaster (i)	R thd <i>Champion</i>	R thd <i>Loyal</i>	R thd <i>At Risk</i>	R thd <i>Lost</i>	D_i (max.)
<i>Champion</i>	—	1,0420	0,7714	0,4803	1,0420
<i>Loyal Customer</i>	1,0420	—	1,0337	0,8909	1,0420
<i>At Risk</i>	0,7714	1,0337	—	0,9347	1,0337
<i>Lost Customer</i>	0,4803	0,8909	0,9347	—	0,9347

$$DBI = (1,0420 + 1,0420 + 1,0337 + 0,9347) / 4 \\ = 4,0524 / 4 = 1,0131$$

Nilai DBI hasil perhitungan manual (1,0131) sama dengan nilai yang ditampilkan sistem pada Gambar 9 (1,013; selisih pada digit ketiga desimal disebabkan pembulatan), yang sekali lagi membuktikan kebenaran implementasi rumus. Sebagai pembanding, sistem juga menghitung DBI untuk pendekatan K-Means standar (klusterisasi langsung pada data mentah R, F, M yang dinormalisasi tanpa melalui *skoring kuantil* RFM), yaitu 0,525 yang di mana lebih kecil (lebih baik secara geometris) dibandingkan pendekatan RFM + K-Means. Hal ini terjadi karena nilai *Monetary* mentah sangat timpang (rentang Rp300.000 hingga Rp897.577.259), yang secara alami membentuk klaster yang sangat renggang dan mudah terpisah pada K-Means standar. Namun demikian, DBI hanya mengukur kekompakan geometris klaster, bukan kebermaknaan bisnisnya. Oleh karena itu, penggunaan *skoring kuantil* RFM justru diperlukan agar ketiga dimensi (R, F, M) memiliki bobot yang setara dan segmen yang terbentuk (*Champion*, *Loyal Customer*, *At Risk*, *Lost Customer*) dapat diinterpretasikan secara konsisten untuk kebutuhan strategi pemasaran, sebagaimana dibahas lebih lanjut pada Bagian III-C.

B. Perancangan dan Implementasi Sistem

1. Perancangan *Use Case Diagram*


Perancangan sistem dimulai dengan identifikasi kebutuhan fungsional melalui *use case diagram*, sebagai acuan pengembangan antarmuka dan logika pemrosesan pada bagian berikutnya.

a. Identifikasi Aktor

Sistem ini tidak memiliki mekanisme *login* atau otentikasi, sehingga hanya terdapat satu aktor yang berinteraksi langsung dengan seluruh *use case*, yaitu pengguna sistem (Tim CRM/Marketing Mall) serta pihak internal pengelola mall yang memanfaatkan sistem untuk memantau dan menganalisis segmentasi *member*.

b. Use Case Diagram

Diagram use case sistem digambarkan pada Gambar 2, use case “Menjalankan Klasterisasi RFM + K-Means” merupakan use case inti yang di-include oleh empat use case penyajian hasil, karena keempatnya menyajikan hasil dari satu proses klasterisasi yang sama.



Gambar 2. Use case diagram sistem segmentasi member Solo Paragon

c. Deskripsi Use Case

Kesembilan use case di atas dijabarkan pada Tabel 14 Skenario rinci tiap use case (aktor, prakondisi, alur utama, alur alternatif, dan postkondisi) disajikan pada tabel berikut ini:

Tabel 14. Daftar use case sistem

ID	Nama Use Case	Deskripsi Singkat
UC-01	Melihat Ringkasan Data Transaksi	Menampilkan jumlah member, transaksi, total nilai, dan periode data saat dashboard dibuka.
UC-02	Mengatur Jumlah Klaster (K)	Menentukan K (2–8) melalui slider untuk menjalankan ulang klasterisasi.
UC-03	Menjalankan Klasterisasi RFM + K-Means	Use case inti: preprocessing, RFM, scoring kuantil, Elbow Method, K-Means++, evaluasi DBI.
UC-04	Melihat Grafik Elbow Method	Menampilkan grafik WCSS terhadap K untuk menilai titik K optimal.
UC-05	Melihat Peta Sebaran Member	Menampilkan scatter plot Frekuensi vs Monetary, diwarnai per segmen.
UC-06	Melihat Kartu Segmen Member	Menampilkan ringkasan tiap segmen: jumlah member, rata-rata R/F/M, kontribusi revenue, dan aksi yang disarankan.
UC-07	Melihat Evaluasi Davies-Bouldin Index	Menampilkan perbandingan kualitas klaster RFM+K-Means vs K-Means standar.
UC-08	Mencari dan Melakukan Filter Data Member	Mencari member berdasarkan nama/ID, melakukan filter segmen, mengurutkan, dan menavigasi tabel.

UC-09

Mengunggah atau Mengganti Dataset


Mengunggah file CSV baru untuk menggantikan dataset aktif di storage.

2. Perancangan Antarmuka Sistem (UI/UX)

Sebelum diimplementasikan menjadi antarmuka akhir, setiap bagian halaman dirancang terlebih dahulu dalam bentuk wireframe (rancangan antarmuka low-fidelity) untuk menentukan hierarki informasi dan urutan interaksi pengguna. Prinsip perancangan yang diterapkan adalah pola “overview → kontrol → detail”: pengguna terlebih dahulu disuguhkan ringkasan data secara sekilas, kemudian diberi kendali untuk mengubah parameter analisis, dan pada bagian akhir disediakan rincian data per member. Alur rancangan wireframe mengikuti urutan pengguliran (scroll) halaman dari atas ke bawah, sebagaimana dijabarkan pada Bagian III-B-2-a sampai Bagian III-B-2-d.

a. Wireframe Bagian Ringkasan Data dan Tahapan KDD


Bagian teratas halaman dirancang untuk menjawab pertanyaan “data apa yang sedang diproses?” secara sekilas melalui kotak “Penjelasan Singkat” dan empat kotak statistik (Member Aktif, Transaksi, Total Nilai, Periode Data). Di bawahnya diletakkan kotak “Penjelasan Tahapan KDD yang diterapkan” sebagai bentuk transparansi metodologi kepada pengguna, sebelum masuk ke bagian interaktif.



Gambar 3. Wireframe bagian ringkasan data dan tahapan KDD

b. Wireframe Bagian Kontrol Klaster dan Elbow Method

Kotak “Toggle update Jumlah Klaster (K)” merepresentasikan kontrol interaktif (slider) yang menjadi satu-satunya input utama pengguna terhadap hasil analisis, diletakkan tepat di atas grafik “Elbow Method Chart” agar pengguna dapat langsung melihat dampak perubahan K terhadap grafik di bawahnya.



Gambar 4. Wireframe bagian kontrol klaster dan elbow method

c. Wireframe Bagian Sebaran Member dan Kartu Segmen

Setelah pengguna memahami jumlah klaster yang dipakai, bagian berikutnya menampilkan wireframe “Peta Sebaran Member” (visualisasi posisi tiap member) yang kemudian diringkas secara kuantitatif pada wireframe “Kartu Segmen” di bawahnya yang di mana urutan ini mengikuti pola dari data mentah (visual) menuju kesimpulan (ringkasan per segmen).



Gambar 5. Wireframe bagian sebaran member dan kartu segmen

d. Wireframe Bagian Evaluasi dan Tabel Member

Bagian akhir halaman dirancang untuk kebutuhan validasi (“Davies-Bouldin Index”, sebagai bukti kualitas klaster secara kuantitatif) dan kebutuhan operasional sehari-hari (“Daftar Member per Segmen”, untuk mencari member tertentu). Kedua kebutuhan ini diletakkan paling akhir karena bersifat pelengkap/pendukung, bukan informasi utama yang pertama kali dicari pengguna.



Gambar 6. Wireframe bagian evaluasi dan tabel member


Berdasarkan keempat wireframe tersebut, antarmuka akhir diimplementasikan dengan tema warna keemasan (*gold*) di atas latar ungu tua (*deep plum*) yang merepresentasikan kesan eksklusif atau loyalitas sebuah mall, dengan elemen dekoratif garis putus-putus pada kartu segmen yang meniru bentuk sobekan tiket atau struk belanja sesuai dengan konteks bisnis ritel yang diangkat pada penelitian ini. Detail hasil akhir implementasi dijabarkan pada Bagian III-B-3.

3. Implementasi Antarmuka Sistem

Bagian ini menjabarkan hasil implementasi akhir sistem berbasis web (Laravel), mengikuti urutan tampilan sebagaimana dilihat pengguna dari atas ke bawah halaman, sesuai dengan rancangan wireframe pada Bagian III-B-2.

a. Halaman Ringkasan Data dan Tahapan KDD

Gambar 7 menampilkan hasil implementasi UC-01 (Melihat Ringkasan Data Transaksi). Angka yang ditampilkan (terdapat 376 member aktif, 1.540 transaksi, total Rp7.254.056.266, periode 2 Jan–28 Mei 2026) sama dengan Tabel 1 pada Bagian III-A-2, karena keduanya dihitung dari dataset yang identik. Di bawah ringkasan tersebut ditampilkan lima tahapan KDD sesuai rancangan wireframe pada Gambar 3.




Gambar 7. Implementasi halaman ringkasan data dan tahapan KDD

b. Pengaturan Jumlah Klaster dan Grafik Elbow Method

Gambar 8 menampilkan implementasi UC-02 (Mengatur Jumlah Klaster) dan UC-04 (Melihat Grafik Elbow Method). Slider K diatur pada rentang 2–8, dengan nilai K = 4 digunakan sebagai nilai bawaan (*default*) karena pada grafik terlihat titik siku (*elbow*) terjadi di sekitar K = 4, yaitu titik di mana penurunan nilai WCSS mulai melandai (dari 70,53 pada K=2 menjadi 41,39 pada K=4, kemudian melandai menjadi 35,91 pada K=5 dan seterusnya). Tombol “Jalankan


Ulang” memicu ulang seluruh proses klasterisasi (UC-03) dengan inisialisasi K-Means++ yang baru, sedangkan tombol “Ganti Data” membuka form unggah (UC-09).



Gambar 8. Implementasi pengaturan kluster dan grafik *elbow method*

c. Peta Sebaran *Member*

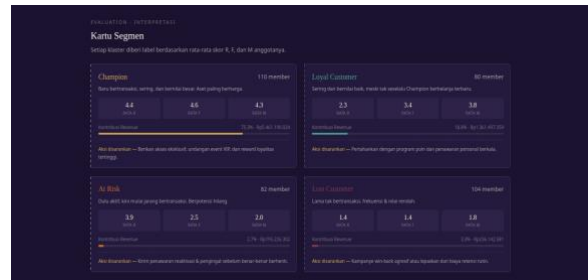
Gambar 9 menampilkan implementasi UC-05 (Melihat Peta Sebaran *Member*). Sumbu X merepresentasikan frekuensi transaksi dan sumbu Y merepresentasikan total nilai belanja (*Monetary*), dengan tiap titik diwarnai menurut segmen hasil klasterisasi. Terlihat *member* dengan frekuensi dan nilai belanja tertinggi (misalnya Swatiningsih, S.H. pada Tabel 2, dengan frekuensi 58 kali dan nilai hampir Rp900 juta) berada pada titik paling kanan-atas grafik, konsisten dengan status *Champion* yang telah dibuktikan secara manual pada Bagian III-A-4-a.



Gambar 9. Implementasi peta sebaran *member* (scatter plot)

d. Kartu Segmen *Member*

Gambar 10 menampilkan implementasi UC-06 (Melihat Kartu Segmen *Member*) untuk keempat segmen pada $K = 4$. Nilai rata-rata R, F, M serta jumlah anggota tiap kartu sama dengan hasil perhitungan pada Tabel 9 (110 *Champion*, 80 *Loyal Customer*, 82 *At Risk*, 104 *Lost Customer*). Kartu *Champion* menyumbang 75,3% dari total pendapatan (Rp5.461.190.024) meskipun hanya berjumlah 110 dari 376 *member* (29,3%). Kondisi ini menunjukkan pola yang sejalan dengan “prinsip Pareto” dalam ritel, yang dibahas lebih lanjut pada Bagian III-C.



Gambar 10. Implementasi kartu segmen *member*

e. Evaluasi Davies-Bouldin Index

Gambar 11 menampilkan implementasi UC-07 (Melihat Evaluasi Davies-Bouldin Index), dengan nilai RFM + K-Means sebesar 1,013 dan K-Means Standar sebesar 0,525 yang identik dengan hasil perhitungan manual pada Bagian III-A-5-a (selisih pembulatan pada digit ketiga desimal). Sistem juga menampilkan kesimpulan naratif otomatis mengenai pendekatan mana yang menghasilkan kluster lebih kompak pada konfigurasi-K yang sedang dipilih.



Gambar 11. Implementasi evaluasi Davies-Bouldin Index

f. Pencarian dan Daftar *Member* per segmen

Gambar 12 menampilkan implementasi UC-08 (mencari dan melakukan filter data *member*), yaitu tabel *member* yang dapat dicari berdasarkan nama atau ID dan difilter berdasarkan segmen. Pada contoh tangkapan layar, filter “*Lost Customer*” menampilkan 104 *member* sama dengan jumlah pada Tabel 9 dan kartu segmen Gambar 10 *Member* Albert Widjaja dan Eka Rahayu yang telah dihitung manual pada Bagian III-A-3 juga dapat ditemukan pada tabel ini dengan segmen yang identik dengan hasil perhitungan manual (*Loyal Customer* dan *Champion*).

ID	Nama	Segment	Status
121	PAULUS ANDRIAN PRIMA	1	Active
76	LEVI KRETIANTO BANA SANTOSO	1	Active
77	WENDY LEE WANDYANDI, SH	1	Active
117	BUDIMAN SETIYANINGRAT	1	Active
132	REO ADE PUGNAT	1	Active
142	UTAMA PUGNAT	1	Active
84	UTAMA BUDIMAN SANTOSO	1	Active
145	UTAMA PUGNAT	1	Active
147	UTAMA PUGNAT	1	Active
84	UTAMA PUGNAT	1	Active
148	UTAMA PUGNAT	1	Active

Gambar 12. Implementasi pencarian dan daftar *member* per segmen

C. Analisis Hasil Penelitian

Hasil perhitungan manual pada Bagian III-A-3 dan hasil implementasi sistem pada Bagian III-B-3 menunjukkan kecocokan penuh (10 dari 10 sampel data, atau 100%) baik pada tahap perhitungan RFM, *skoring kuantil*, normalisasi data (*min.-max.*), penentuan klaster, maupun evaluasi Davies-Bouldin Index. Hal ini membuktikan bahwa rumus yang diimplementasikan pada kelas RFM K-Means *Service* telah berjalan sesuai dengan rancangan metodologi penelitian.

Dari sisi bisnis, hasil segmentasi pada $K = 4$ menunjukkan pola yang sejalan dengan prinsip Pareto: segmen *Champion* yang hanya berjumlah 110 *member* (29,3% dari total 376 *member*) berkontribusi terhadap 75,3% dari total pendapatan (Rp5.461.190.024 dari Rp7.254.056.266). Sebaliknya, segmen *Lost Customer* yang berjumlah 104 *member* (27,7%) hanya berkontribusi 3,3% pendapatan. Temuan ini memberikan dasar kuantitatif bagi manajemen mall untuk memprioritaskan program loyalitas pada kelompok *Champion*, sekaligus mempertimbangkan strategi reaktivasi maupun efisiensi biaya retensi pada kelompok *Lost Customer*, sebagaimana telah tercantum pada rekomendasi aksi di tiap kartu segmen Gambar 10.

Pada studi kasus, Erlina Handoyo dan Albert Widjaja (keduanya termasuk 10 penyumbang nilai belanja terbesar, namun dikategorikan *Loyal Customer*, bukan *Champion*) menegaskan kelebihan pendekatan RFM dibandingkan analisis nilai transaksi (*Monetary*) semata. Kedua *member* tersebut sudah lebih dari 90 hari tidak melakukan transaksi, sehingga berisiko berpindah ke kompetitor apabila tidak segera diberikan penawaran reaktivasi, meskipun secara historis nilai belanjanya besar.

Perbandingan Davies-Bouldin Index antara pendekatan RFM + K-Means (1,013) dengan K-Means standar (0,525) menunjukkan bahwa secara geometris klaster K-Means standar sedikit lebih kompak. Namun demikian, hal ini bukan berarti pendekatan RFM tidak tepat untuk digunakan. DBI mengukur kekompakan dan keterpisahan klaster secara matematis pada ruang fitur yang dipakai, sedangkan *skoring kuantil* RFM sengaja dirancang untuk menyetarakan bobot ketiga dimensi (*Recency*, *Frequency*, *Monetary*) agar segmen yang terbentuk dapat diinterpretasikan secara konsisten dari sisi bisnis tanpa *skoring*, dimensi *Monetary* yang memiliki rentang sangat lebar yaitu (Rp300.000 hingga Rp897.577.259) akan mendominasi hasil klasterisasi dan mengabaikan sinyal penting dari *Recency* dan *Frequency*, sebagaimana yang ditunjukkan oleh kasus Erlina Handoyo dan Albert Widjaja di atas.

Secara keseluruhan, hasil pada bagian ini menunjukkan bahwa sistem yang dibangun telah berhasil mengimplementasikan metodologi RFM dan K-Means Clustering sesuai dengan rancangan pada Bagian II, disertai dengan bukti kuantitatif berupa kecocokan penuh antara perhitungan manual dan keluaran sistem, serta memberikan wawasan bisnis yang dapat langsung ditindaklanjuti oleh manajemen Solo Paragon Mall.

IV. KESIMPULAN

Penelitian ini menggunakan data transaksi *member* Solo Paragon Mall pada periode 2 Januari 2026 hingga 28 Mei 2026, yang setelah proses pembersihan menghasilkan 1.540 transaksi valid dari 376 *member* unik dengan total nilai Rp7.254.056.266. Untuk memastikan keakuratan algoritma di dalam sistem, dilakukan pengujian manual pada sampel 10 *member* dengan nilai belanja tertinggi. Pengujian ini mencakup perhitungan agregasi *Recency*, *Frequency*, *Monetary* (RFM), *skoring kuantil*, normalisasi data (*min.-max.*), hingga perhitungan jarak Euclidean untuk penentuan klaster K-Means. Hasil validasi menunjukkan tingkat kecocokan 100% antara perhitungan manual dengan keluaran sistem, yang membuktikan

bahwa seluruh rumusan matematis telah diimplementasikan dengan tepat.

Dalam mengevaluasi kualitas klaster, pengukuran dengan Davies-Bouldin Index (DBI) menghasilkan nilai sebesar 1,013 untuk metode RFM + K-Means dan 0,525 untuk K-Means standar. Meskipun K-Means standar lebih ringkas secara matematis, metode RFM + K-Means tetap diterapkan karena *skoring kuantil* tersebut secara efektif menyetarakan bobot ketiga dimensi, sehingga mencegah dominasi nilai transaksi dan menghasilkan segmen yang lebih relevan untuk bisnis. Model ini kemudian diwadahi dalam sistem berbasis web menggunakan kerangka kerja Laravel yang dikelola oleh satu aktor utama (Tim CRM atau *Marketing*) melalui 9 *use case*. Antarmuka sistemnya dirancang interaktif dengan prinsip hierarki informasi mulai dari ringkasan data umum, kontrol parameter jumlah klaster, hingga rincian data individu per member.

Dari sisi wawasan bisnis, konfigurasi klaster optimal pada $K=4$ (berdasarkan *Elbow Method*) membagi pelanggan ke dalam segmen *Champion*, *Loyal Customer*, *At Risk*, dan *Lost Customer*. Hasil analisis memperlihatkan pola distribusi pendapatan yang sesuai dengan prinsip Pareto, di mana segmen *Champion* yang hanya mewakili 29,3% dari total member mampu menyumbang 75,3% pendapatan mall. Pendekatan RFM ini juga terbukti krusial untuk mendeteksi member dengan nilai belanja besar yang berisiko berpindah kompetitor karena sudah lama tidak bertransaksi, sehingga manajemen dapat langsung memanfaatkan wawasan dan rekomendasi aksi dari sistem untuk menyusun strategi loyalitas dan reaktivasi yang tepat sasaran.

UCAPAN TERIMA KASIH

Puji syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa atas rahmat dan karunia-Nya, sehingga penelitian ini dapat diselesaikan dengan baik. Penulis juga menyampaikan terima kasih kepada semua pihak yang telah memberikan bantuan dan dukungan baik secara langsung maupun tidak langsung selama proses penyusunan penelitian ini.

REFERENSI

- [1] R. O. Harmono and D. Mutiari, "Hubungan Pola Sirkulasi terhadap Tingkat Keramaian Pengunjung pada Groundfloor Solo Paragon Mall," in *Prosiding (SLAR) Seminar Ilmiah Arsitektur*, 2023, pp. 9–19.
- [2] A. P. Sanevil and S. S. Hidayah, "Penerapan Teknik Data Mining Clustering Pengunjung Mall dengan Algoritma K-Means," *Jurnal Teknologi Sistem Informasi*, vol. 6, no. 1, pp. 11–20, Apr. 2025, doi: 10.35957/jtsi.v6i1.10128.
- [3] R. M. Fauzan and G. Alfian, "Segmentasi Pelanggan E-Commerce Menggunakan Fitur Recency, Frequency, Monetary (RFM) dan Algoritma Klasterisasi K-Means," *JISKA (Jurnal Informatika Sunan Kalijaga)*, vol. 9, no. 3, pp. 170–177, Sep. 2024, doi: 10.14421/jiska.2024.9.3.170-177.
- [4] F. Hendra, Yati Rohayati, and Budi Sulistyono, "Segmentasi Customer Value Pengunjung Kedai Kopi Generasi Z Berdasarkan Pendekatan Recency, Frequency, Monetary (RFM)," *Jurnal Manajemen dan Pemasaran Digital*, vol. 4, no. 3, pp. 323–334, Jul. 2026, doi: 10.38035/jmpd.v4i3.679.
- [5] A. Sitanggang, Y. Umaidah, Y. Umaidah, R. I. Adam, and R. I. Adam, "ANALISIS SENTIMEN MASYARAKAT TERHADAP PROGRAM MAKAN SIANG GRATIS PADA MEDIA SOSIAL X MENGGUNAKAN ALGORITMA NAÏVE BAYES," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, Aug. 2024, doi: 10.23960/jitet.v12i3.4902.
- [6] A. Y. N. Rumapea, D. Pratiwi, and S. Sari, "Analisis segmentasi pelanggan ritel online menggunakan K-Means clustering berdasarkan model Recency, Frequency, Monetary (RFM)," *Jurnal Sains dan Teknologi*, vol. 6, no. 3, pp. 292–299, 2024.
- [7] M. D. Salman *et al.*, "Perbandingan Kinerja Algoritma Clustering K-Means dan K-Medoids dalam Pengelompokan Sekolah di Provinsi Riau Berdasarkan Ketersediaan Sarana dan Prasarana," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. 3, pp. 797–806, Jun. 2025, doi: 10.57152/malcom.v5i3.1950.
- [8] A. Rajsya, P. Purnawansyah, and A. R. Manga, "Rancang Bangun Penerapan Metode Elbow Pada K-Means Untuk Clustering Data Persediaan Barang," *LINIER: Literatur Informatika dan Komputer*, vol. 1, no. 4, pp. 395–403, 2024.
- [9] N. Hendrastuty, "Penerapan Data Mining Menggunakan Algoritma K-Means Clustering Dalam Evaluasi Hasil Pembelajaran Siswa," *Jurnal Ilmiah Informatika dan Ilmu Komputer (JIMA-ILKOM)*, vol. 3, no. 1, pp. 46–56, Mar. 2024, doi: 10.58602/jima-ilkom.v3i1.26.
- [10] E. T. Ena Tasia and M. Afdal, "Perbandingan Algoritma K-Means Dan K-Medoids Untuk Clustering Daerah Rawan Banjir Di Kabupaten Rokan Hilir," *Indonesian Journal of Informatic Research and Software Engineering (IJIRSE)*, vol. 3, no. 1, pp. 65–73, Mar. 2023, doi: 10.57152/ijirse.v3i1.523.
- [11] A. R. Yusri, I. F. Hanif, M. D. Al-farel, M. N. Zaandami, and M. Yasin, "Perancangan Desain UI/UX Berbasis Scan Barcode Dengan Metode Design Thinking Untuk Pemesanan Makanan," *Bulletin of Information Technology (BIT)*, vol. 5, no. 2, pp. 102–113, 2024.