



Penerapan Algoritma K-Means dalam Segmentasi Anggota Koperasi Berdasarkan Pola Simpanan dengan Analisis RFMP untuk Meningkatkan Loyalitas

Abdul Razak Naufal*, Turkhamun Adi Kurniawan, M Al'Amin

Fakultas Sains dan Teknologi, Program Studi Informatika, Institut Teknologi dan Sains Nahdlatul Ulama Pekalongan, Pekalongan, Indonesia

Email: ^{1,*}naufal@itsnupekalongan.ac.id, ²adi@itsnupekalongan.ac.id, ³almuhbatik@gmail.com

Email Penulis Korespondensi: naufal@itsnupekalongan.ac.id

Abstrak—Koperasi sebagai lembaga keuangan berbasis anggota memiliki peran penting dalam mendukung kesejahteraan anggotanya. Namun, keberagaman karakteristik anggota, baik dari sisi lama bergabung maupun jumlah simpanan bulanan, menimbulkan tantangan dalam merumuskan strategi pengelolaan yang efektif. Penelitian ini bertujuan untuk mengelompokkan anggota koperasi berdasarkan pola data transaksi keuangan menggunakan pendekatan data mining. Metode yang digunakan adalah algoritma K-Means Clustering, dengan variabel utama menggunakan analisis RFMP (*Recency, Frequency, Monetary dan Payment*), yaitu lama bergabung (*Recency*), frekuensi simpanan dalam setahun (*Frequency*), jumlah simpanan bulanan (*Monetary*) dan pembayaran pinjaman tepat waktu (*Payment*). Data diproses melalui tahap pra-pemrosesan, data dinormalisasi menggunakan metode *Min-Max Scaling* untuk menyelaraskan perbedaan satuan antarvariabel, Penentuan jumlah cluster optimal dilakukan menggunakan Elbow Method, yang menunjukkan bahwa jumlah cluster terbaik adalah tiga kelompok. Hasil penelitian dengan jumlah data sebanyak 50 data transaksi menghasilkan anggota koperasi terbagi menjadi tiga cluster. Cluster pertama yaitu anggota berisiko sebesar 36%, cluster kedua yaitu anggota potensial sebesar 40%, dan cluster ketiga yaitu anggota loyal atau eksklusif sebesar 24%. Temuan ini memberikan solusi praktis bagi koperasi dalam menyusun strategi pengelolaan anggota. Anggota lama perlu diberikan motivasi peningkatan simpanan, anggota baru perlu pembinaan untuk meningkatkan loyalitas, sementara anggota premium perlu layanan khusus agar tetap terjaga kepuasannya. Dengan demikian, hasil *clustering* dapat menjadi dasar pengambilan keputusan berbasis data dalam pengelolaan koperasi.

Kata Kunci: Koperasi; K-Means Clustering; Data Mining; Metode Elbow; Simpanan Anggota

Abstract—Cooperatives as member-based financial institutions have an important role in supporting the welfare of their members. However, the diversity of member characteristics, both in terms of length of membership and the amount of monthly savings, poses challenges in formulating effective management strategies. This study aims to group cooperative members based on financial transaction data patterns using a data mining approach. The method used is the K-Means Clustering algorithm, with the main variables using RFMP analysis (*Recency, Frequency, Monetary and Payment*), namely length of membership (*Recency*), frequency of savings in a year (*Frequency*), amount of monthly savings (*Monetary*) and timely loan payments (*Payment*). Data is processed through a pre-processing stage, the data is normalized using the *Min-Max Scaling* method to equalize unit differences between variables, Determination of the optimal number of clusters is done using the Elbow Method, which shows that the best number of clusters is three groups. The results of the study with a total of 50 transaction data resulted in cooperative members being divided into three clusters. The first cluster is at-risk members at 36%, the second cluster is potential members at 40%, and the third cluster is loyal or exclusive members at 24%. These findings provide practical solutions for cooperatives in developing member management strategies. Existing members need to be motivated to increase savings, new members need coaching to foster loyalty, and premium members need special services to maintain their satisfaction. Thus, clustering results can form the basis for data-driven decision-making in cooperative management.

Keywords: Cooperative; K-Means Clustering; Data Mining; Elbow Method; Savings

1. PENDAHULUAN

Koperasi sebagai lembaga keuangan yang berasaskan kekeluargaan dan kebersamaan memiliki peranan penting dalam menunjang perekonomian masyarakat, khususnya melalui kegiatan simpan pinjam. Seiring dengan bertambahnya jumlah anggota dan kompleksitas transaksi, pengelolaan data anggota menjadi tantangan tersendiri bagi pengurus koperasi. Informasi mengenai pola simpan dan pinjam dari masing-masing anggota seringkali tersebar dan tidak tergalikan secara optimal untuk mendukung pengambilan keputusan strategis, seperti penentuan kebijakan pinjaman, penawaran program insentif, maupun manajemen risiko kredit. Seiring berkembangnya teknologi dan kebutuhan masyarakat, pengelolaan koperasi diharapkan tidak lagi hanya bersifat manual dan administratif, melainkan mulai mengadopsi pendekatan berbasis data untuk meningkatkan efisiensi dan akurasi pengambilan Keputusan [1].

Salah satu hal yang penting dalam pengelolaan pelanggan adalah bagaimana suatu perusahaan dapat mempertahankan pelanggan yang dimilikinya. Usaha mempertahankan pelanggan ini menjadi hal yang penting bagi Koperasi Simpan Pinjam [2]. Dalam praktiknya, koperasi sering menghadapi permasalahan dalam pengelompokan anggota berdasarkan perilaku simpanan. Hal ini penting karena tidak semua anggota memiliki karakteristik yang sama, ada yang rajin menabung, ada yang sering meminjam namun tidak tepat waktu dalam membayar, serta ada pula yang berisiko tinggi mengalami kredit macet.

Model RFMP (*Recency, Frequency, Monetary dan Payment*) dipakai dalam penelitian ini untuk mengukur perilaku pelanggan melalui *Recency* (Lama bergabung), *Frequency* (Jumlah transaksi simpanan dalam setahun) *Monetary* (total nilai simpanan) dan pembayaran pinjaman tepat waktu (*Payment*). Pendekatan ini unggul dibanding demografi



karena berbasis data transaksi aktual, menghasilkan segmen yang *actionable* untuk strategi bisnis seperti kampanye yang tertarget. Tanpa adanya segmentasi yang akurat, koperasi kesulitan dalam menentukan kebijakan yang sesuai, seperti bunga pinjaman, penilaian risiko, hingga strategi insentif bagi anggota yang produktif [3]. Salah satu metode populer dalam data mining adalah algoritma *K-Means Clustering*, yaitu teknik *unsupervised learning* yang digunakan untuk mengelompokkan data ke dalam sejumlah klaster berdasarkan kesamaan fitur [4]. Hasil segmentasi ini dapat digunakan oleh manajemen koperasi untuk mengidentifikasi loyalitas anggota koperasi serta menerapkan strategi yang lebih personal dan efisien kepada setiap kelompok anggota [5].

Meski algoritma ini telah banyak digunakan di sektor perbankan dan *e-commerce* untuk segmentasi pelanggan [6], [7], namun penerapannya dalam sektor koperasi masih sangat terbatas. Dengan menerapkan segmentasi berbasis *K-Means*, koperasi tidak hanya dapat mengidentifikasi pola perilaku anggota, tetapi juga dapat mengantisipasi risiko pinjaman bermasalah lebih dini [8]. Penggunaan teknologi data mining, khususnya algoritma *K-Means Clustering*, dapat menjadi solusi untuk mengelompokkan anggota koperasi berdasarkan pola perilaku finansial mereka. Algoritma ini mampu mengidentifikasi kelompok-kelompok anggota dengan karakteristik yang serupa, seperti anggota dengan kecenderungan menabung tinggi, anggota aktif meminjam, atau anggota yang kurang aktif. Informasi ini sangat berharga untuk mendukung pengelolaan koperasi yang lebih efisien, personalisasi layanan, serta meningkatkan kualitas pengambilan keputusan [9] [10]. Beberapa penelitian sebelumnya yang berhubungan dengan penelitian ini sebagai berikut:

Penelitian Fadhillah et al. (2025) menerapkan model RFM pada dengan perbandingan tiga algoritma clustering (*K-Means*, Agglomerative, DBSCAN) pada 118.314 transaksi pada PT SID dari 1.570 pelanggan distributor bahan bangunan B2B (PT SID). *K-Means* unggul dengan Silhouette Score 0.364, Davies-Bouldin Index 0.93, dan Calinski-Harabasz 1303.6, menghasilkan tiga segmen: loyal customer (694 pelanggan), adequate customer (383), dan churn/lost customer (494) untuk strategi pemasaran [11]. Data 2022-2023 diproses melalui *cleaning*, transformasi RFM (*Recency*: hari sejak transaksi terakhir, *Frequency*: jumlah transaksi, *Monetary*: total nilai), dan normalisasi *Standard Scaler*. *K-Means* dipilih terbaik setelah validasi metrik, mengelompokkan pelanggan berdasarkan perilaku transaksi pasca-pandemi dan perdagangan bebas, fokus pada loyalitas B2B. Algoritma *K-Means* sangat cocok untuk segmentasi pelanggan potensial dalam konteks penelitian RFM, karena efektif mengelompokkan data transaksi berdasarkan kesamaan perilaku seperti *Recency*, *Frequency*, dan *Monetary*. Metrik validasi seperti Silhouette Score 0.364 dan Davies-Bouldin Index 0.93 pada studi Fadhillah et al. (2025) membuktikan kualitas klasteringnya unggul dibanding DBSCAN atau Agglomerative untuk data B2B skala besar.

Penelitian Rifqi dan Aldisa (2023) menerapkan algoritma *K-Means* untuk mengelompokkan pelanggan potensial pada koperasi simpan pinjam menggunakan data demografis seperti jenis pekerjaan, penghasilan, dan kepemilikan aset. Hasilnya membagi 15 anggota menjadi dua cluster: Cluster 1 (tidak potensial: 7 anggota) dan Cluster 2 (potensial: 8 anggota) setelah dua iterasi Euclidean distance, mendukung strategi pemasaran tertarget untuk tingkatan loyalitas [2]. Cluster potensial (C2) menonjol dengan rata-rata nilai lebih tinggi pada penghasilan bulanan (3) dan status perkawinan (1.625), memudahkan koperasi identifikasi anggota prioritas untuk promosi dan retensi. Total 15 data sampel berhasil diklasifikasikan stabil, membuktikan *K-Means* efektif untuk data kecil koperasi.

Penelitian Anjainah dan Monalisa (2022) yang berjudul Analisis Produk berdasarkan Segmentasi Pelanggan Berdasarkan Analisis RFM Menggunakan Algoritma *K-Means* Sebagai Dasar Strategi Pemasaran. Penelitian ini bertujuan untuk menentukan produk berdasarkan segmentasi pelanggan menggunakan Algoritma DBSCAN dan FP-Growth. Parameter yang dipertimbangkan yaitu nilai RFM pelanggan, segmen pelanggan, dan produk yang sering dibeli secara bersamaan dalam 1 tahun data transaksi member menggunakan algoritma DBSCAN dan FP-Growth. Dalam segmentasi pelanggan, diperoleh 5 cluster dan 31 data noise dengan nilai Eps 0,060, MinPts 3 dan nilai SI 0,4222. Hasil asosiasi menggunakan minsup 30% dan minconf 70% menghasilkan cluster 1 ada 7 rules, cluster 2 ada 6 rules, cluster 3 ada 10 rules, cluster 4 ada 2 rules, dan cluster 5 ada 6 rules. Rules yang terbentuk dapat digunakan untuk pemasaran langsung dengan merekomendasikan produk-produk kepada pelanggan masing-masing cluster [12].

Penelitian Diotivano, Ruslianto dan Prawira (2023) untuk mencari pelanggan potensial menggunakan algoritma *K-Means* dan Analisis RFM. Sistem Berbasis Web dibuat untuk memudahkan Perusahaan dalam melakukan segmentasi pelanggan dari sisi antarmuka. Metode *clustering* menggunakan algoritma *K-Means clustering* digunakan dalam melakukan segmentasi pelanggan. Analisis RFM digunakan untuk pemilihan variabel yang digunakan dalam melakukan *clustering*. RFM menyimpan informasi tentang waktu pembelian terbaru (*recency*), berapa kali pelanggan melakukan pembelian (*frequency*), dan rata-rata total uang yang dikeluarkan (*monetary*). Hasil dari *clustering* akan ditampilkan dalam bentuk visualisasi yang membantu penyajian data dan informasi sehingga lebih mudah dipahami dalam membaca hasil segmentasi pelanggan. Hasil dari penelitian ini berupa sistem segmentasi pelanggan potensial yang telah dilakukan pengujian fungsional, memperoleh hasil sesuai dengan rancangan fungsional sistem. Sedangkan pengujian *interface* kepada masyarakat umum memperoleh predikat sangat baik dengan persentase 87,59% [13].

Berdasarkan kajian terhadap penelitian-penelitian terdahulu, terlihat bahwa penerapan algoritma *clustering K-Means* telah banyak digunakan dalam proses segmentasi pelanggan, khususnya menggunakan analisis RFM. Dengan mengacu pada hasil-hasil penelitian tersebut, dapat disimpulkan bahwa algoritma *K-Means Clustering* dengan RFM sangat relevan dan efektif digunakan dalam segmentasi anggota koperasi. Dalam konteks penelitian ini yang berfokus pada koperasi simpan pinjam, data yang digunakan berupa lama bergabung (*Recency*) dan jumlah simpanan bulanan (*Frequency*), saldo simpanan (*Monetary*) dan ketepatan waktu pembayaran pinjaman (*Payment*) yang peneliti sebut model RFMP (*Recency, Frequency, Monetary, Payment*) dapat dijadikan dasar pembentukan cluster anggota. Model RFMP



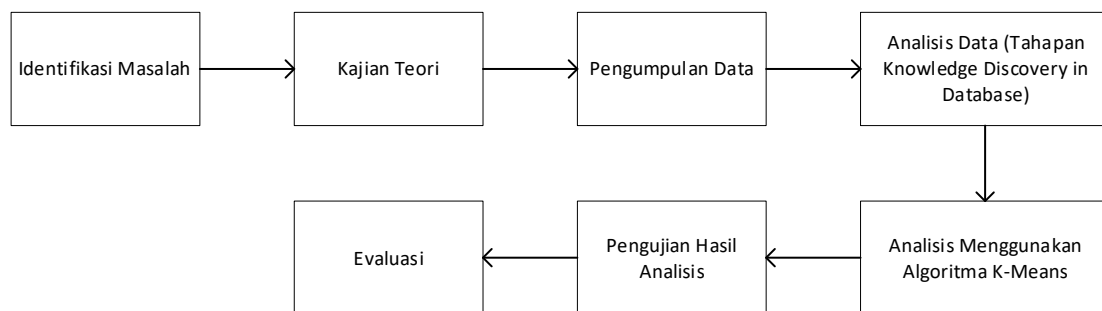
menjadi pembeda dengan penelitian sebelumnya yang tidak menggunakan indikator *payment* sebagai salah satu atribut dalam melakukan klustering. Dengan model analisis RFMP menggunakan algoritma K-Means ini dapat diimplementasikan pada berbagai domain, termasuk dalam mendukung pengambilan keputusan strategis koperasi untuk menjaga keberlanjutan dan meningkatkan kesejahteraan anggota.

Berdasarkan uraian ini, penting untuk mengembangkan sebuah sistem segmentasi anggota koperasi dengan analisis RFMP dan menggunakan algoritma *K-Means Clustering* yang mampu mengolah data transaksi simpanan secara efisien. Hasil pengelompokan tersebut diharapkan dapat membantu koperasi dalam memahami karakteristik anggotanya, meningkatkan kualitas layanan, serta menekan potensi risiko keuangan yang timbul akibat pengambilan keputusan yang tidak berbasis data.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Metode penelitian ini dilakukan melalui beberapa tahap yaitu identifikasi masalah, kajian teori, pengumpulan data, analisis data, pengujian, implementasi, dan evaluasi. Adapun tahapan tersebut ditunjukkan pada Gambar 1. Tahapan yang pertama identifikasi masalah yaitu mendeskripsikan latar belakang masalah, tujuan dan manfaat. Hal ini dilakukan sebagai batasan masalah penelitian yang akan dikembangkan yaitu untuk mengembangkan data mining dalam menentukan segmentasi loyalitas anggota.



Gambar 1 Tahapan Penelitian

Tahapan yang kedua yaitu kajian teori. Pada tahapan ini dilakukan untuk mencari informasi dan sumber yang berkaitan dengan masalah baik dilakukan studi pustaka, jurnal dan internet sebagai dasar pendukung penelitian. Tahapan yang ketiga yaitu pengumpulan data, setelah dilakukan kajian teori maka diperlukan tahapan pengumpulan data. Populasi penelitian ini adalah anggota Koperasi yang beroperasi di Kota Pekalongan. Untuk memastikan sampel yang representatif, ukuran sampel sebanyak 50 data yang diambil dari sistem informasi koperasi atau *core banking system* yang digunakan oleh pihak koperasi untuk mencatat data demografi anggota, data transaksi simpanan, pengambilan, pinjaman dan angsuran. Pada tahapan ini juga dilakukan wawancara dan dokumentasi. Wawancara dilakukan dengan pihak Koperasi Simpan Pinjam untuk memperoleh keterangan mengenai anggota, keakuratan data pada *core banking system*, pendekatan terstruktur ini untuk mengumpulkan data kuantitatif dari ukuran sampel yang besar, yang memungkinkan peneliti untuk menganalisis tren dan pola dalam populasi anggota [14].

2.2 Algoritma K-Means

K-means Clustering adalah algoritma *unsupervised learning* yang digunakan untuk mengelompokkan data berdasarkan kesamaan. Pengelompokan K-means biasanya berfungsi dengan baik dalam praktik dan berskala untuk sekumpulan data yang besar [15]. Algoritma pengelompokan K-means bergantung pada perhitungan jarak antar titik data, sehingga sensitif terhadap skala fitur. Untuk mengatasi hal ini, kami menggunakan penskalaan standar untuk menormalkan fitur, memastikan bahwa setiap fitur berkontribusi secara proporsional terhadap proses pengelompokan.

Teknik *unsupervised learning* ini tidak memerlukan data berlabel dan mengidentifikasi kluster dengan meminimalkan jumlah kuadrat jarak dalam kluster [16]. Menurut [15] [17] clustering ialah pengklasteran dari dataset atau suatu objek ke dalam sebuah kelompok atau yang disebut dengan cluster, jadi dalam setiap cluster yang telah terbentuk berisi suatu data yang serupa dan sangat berbeda dengan data dalam cluster yang lainnya. Pada penelitian ini algoritma K-Means merupakan mekanisme yang tidak memiliki hierarki yang menggunakan beberapa komponen populasi sebagai pusat kluster awal [18].

Dengan metode pengelompokan berdasarkan jarak, teknik K-means yang dianggap sebagai metode pengelompokan klasik. Salah satu fitur utama yang membuat K-means berguna dalam penelitian ini adalah kemungkinan menentukan terlebih dahulu berapa banyak cluster yang sedang dicari. Jumlah ini mengacu pada parameter K. Dari jumlah ini, poin K dipilih dalam cluster random sebagai pusat cluster. Semua variabel ditugaskan ke pusat cluster terdekat mereka sesuai dengan metrik jarak Euclidean. Persamaan 1 berikut ini untuk mengukur jarak *Euclidean Distance* [2]:



$$d = \sqrt{(X_i - X_c)^2 + (Y_i - Y_c)^2} \quad (1)$$

Dimana:

d = Jarak (*Euclidean Distance*)

x = data

y = centroid

Jarak adalah akar kuadrat dari hasil penjumlahan: kuadrat selisih *Recency*, ditambah kuadrat selisih *Frequency*, ditambah kuadrat selisih *Monetary*, dan ditambah kuadrat selisih *Payment*.

Setelah semua data terklastrer, kita akan menghitung centroid baru dengan persamaan 2 berikut ini:

$$\mu_x = \frac{\sum x_i}{n}, \mu_y = \frac{\sum y_i}{n} \quad (2)$$

μ_k = Centroid pada cluster ke k

x_i = Data ke i

y_i = centroid

n = Banyaknya objek/jumlah data yang menjadi anggota klaster ke k

Untuk menghitung centroid baru dalam algoritma K-Means *Clustering*, kita menggunakan rumus rata-rata aritmetika (*mean*) dari seluruh anggota yang tergolong dalam cluster yang sama. Secara matematis, proses ini dilakukan dengan menjumlahkan setiap nilai fitur (seperti R, F, M, dan P) dari semua anggota di dalam cluster tersebut, kemudian membagi total tersebut dengan jumlah anggota yang ada di dalamnya.

2.3 Analisis RFMP

RFMP adalah kependekan dari *recency*, *frequency*, *monetary* dan *Payment*. RFMP dapat didefinisikan sebagai alat analisis pemasaran untuk menentukan secara kuantitatif pelanggan mana yang terbaik untuk perusahaan dengan menganalisis dan memeriksa informasi terkait waktu transaksi terakhir (*recency*), berapa kali pelanggan melakukan transaksi (*frequency*), dan berapa total yang dihabiskan pelanggan dalam melakukan pembelian (*monetary*) [13] dan pembayaran pinjaman tepat waktu (*payment*). Transformasi yang dilakukan pada tahap ini yaitu analisis RFMP dan mencari skor RFMP setiap anggota. Dataset akan otomatis ditransformasi oleh sistem saat proses analisis segmentasi pelanggan potensial dilakukan. Data dinormalisasi menggunakan *Min-Max Scaler* untuk menyesuaikan skala nilai fitur-fitur dalam dataset agar berada dalam rentang antara 0 dan 1. Normalisasi ini dilakukan terhadap seluruh dataset untuk memastikan konsistensi skala antar fitur, yang dapat meningkatkan kinerja algoritma K-Means *Clustering*. Untuk pengelompokan data anggota koperasi simpan pinjam diperlukan beberapa atribut RFMP yang menjadi acuan dalam implementasi data mining dengan menggunakan metode K-Means. Tabel 1 berikut ini adalah data nilai atribut pada data mining untuk pengelompokan data anggota koperasi menggunakan analisis RFMP.

Tabel 1. Data Atribut RFM

No	Kode	Atribut	RFM
1	A1	Lama Bergabung	<i>Recency</i>
2	A2	Frekuensi Transaksi Simpanan	<i>Frequency</i>
3	A3	Simpanan Bulanan	<i>Monetary</i>
4	A4	Pembayaran Tepat Waktu	<i>Payment Behavior</i>

2.4 Metode Elbow

Dalam penelitian ini juga digunakan metode Elbow merupakan sebuah metode yang diterapkan pada k-means *clustering* untuk menentukan jumlah optimal dari cluster yang akan dibentuk. Metode Elbow membantu dalam menentukan jumlah cluster yang tepat untuk data tertentu [19] [6]. Cara untuk menentukan jumlah cluster terbaik dengan metode elbow yaitu dengan mengamati hasil perbandingan grafik antara setiap jumlah cluster k yang akan membentuk perbedaan paling mencolok yaitu membentuk sudut siku atau elbow pada suatu titik [13] [6]. Setiap jumlah cluster k yang dihasilkan dengan menggunakan metode K-means diuji dengan menggunakan persamaan SSE (*Sum of Square Error*) yaitu merupakan persamaan yang mengukur perbedaan atau selisih SSE tiap jumlah cluster k yang diperoleh dengan metode K-means [20] sebelumnya. Persamaan 3 berikut ini adalah persamaan yang digunakan untuk menghitung SSE:

$$SSE = \sum_{k=1}^k \sum_{x_i} |X_i - C_k|^2 \quad (3)$$

Dimana:

k = cluster k-c

X_i = jarak data objek ke-i

C_k = pusat cluster ke-i

Berikut ini adalah langkah analisis metode Elbow:

- Melakukan pengelompokan dengan metode k-means pada berbagai variasi nilai k yang berbeda. Contohnya, jumlah nilai k dari 1 hingga 3 cluster.
- Pada setiap cluster k, tentukan nilai *sum of square error* (SSE).



- c. Plot kurva SSE sesuai dengan jumlah cluster k.
d. Titik sudut yang membentuk siku pada plot umumnya ditentukan sebagai indikator jumlah cluster terbaik.

3. HASIL DAN PEMBAHASAN

3.1. Implementasi K-Means

Implementasi data mining untuk pengelompokan data anggota koperasi simpan pinjam Koperasi LKMS Kasuwari menggunakan metode K-Means membutuhkan beberapa fasilitas pendukung. Berikut ini merupakan data transaksi anggota koperasi yang diperoleh dari *core banking system* dan hasil observasi di koperasi simpan pinjam LKMS Kasuwari pada awal tahun 2025. Tabel 2 merupakan data anggota koperasi yang diambil sebanyak 50 sampel.

Tabel 2 Data Anggota Koperasi

No	CIF	Nama Anggota	Lama Bergabung (Recency)	Transaksi Simpanan Setahun (Frequency)	Simpanan (Monetary)	Pembayaran Pinjaman Tepat Waktu (Payment)
1	CIF001	DEWI PANGESTUTI	23	7	49,713	1
2	CIF002	MUSTOFA	19	12	10,000	1
3	CIF003	SODIKIN	23	11	95,837	1
4	CIF004	SUHARDI	9	4	39,336	1
5	CIF005	WASDIYANTO	12	5	100,000	1
6	CIF006	NANIK SURYANI	23	8	197,250	0
7	CIF007	RINA WATI	21	3	146,660	0
8	CIF008	NILUH PUTU SUWANDEWI	23	5	134,936	0
9	CIF009	SUTEJO SULAKSONO	23	4	54,098	1
10	CIF010	HANIP SUGI HARTO	23	11	6,000	1
11	CIF011	SLAMET MUJIONO	23	12	5,905	1
12	CIF012	RIYANTO (Mulyorejo)	23	4	16,880	0
13	CIF013	ARUM SASI	20	6	100,000	0
14	CIF014	FRANSISCA ANDINA SUCI W.	23	5	13,547	1
15	CIF015	AGUS WIRAWAN YUNIENTYO	23	9	28,500	0
16	CIF016	DESY TRIA AMIRA FASA	18	10	2,850,492	0
17	CIF017	SRI NINGSIH	23	7	35,491	0
18	CIF018	NURUL MIFTA	23	5	36,489	0
19	CIF019	AKHMAD SYAIKHU	23	9	26,990	0
...
50	CIF050	TIA KOMALASARI	23	8	5,660	1

Data pada Tabel 2 ini merupakan data RFMP anggota yang ada pada koperasi LKMS Kasuwari. Atribut pembayaran tepat waktu merupakan atribut yang menjelaskan tentang tepat waktunya anggota dalam membayarkan simpanan. Dalam teknik penilaian untuk nilai atribut pembayaran pinjaman tepat waktu menggunakan skala guttman. Skala guttman adalah skala yang digunakan untuk mendapatkan jawaban tegas dari responden, yaitu hanya terdapat dua interval seperti Ya atau Tidak, Benar atau Salah, dan lain- lain yang memiliki nilai skala 0 (tidak lancar) atau 1 (lancar).

Data RFMP khususnya data lama bergabung, data simpanan, frekuensi simpanan dan pembayaran tepat waktu akan dilakukan normalisasi *Min-Max* mengubah nilai ke rentang 0 – 1 tanpa mengubah pola data menggunakan persamaan 4 berikut ini:

$$X_{nomr} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (4)$$

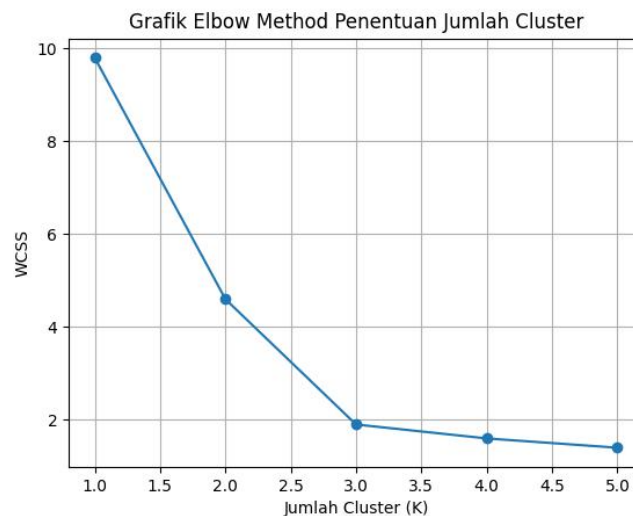
Data Lama bergabung (*Recency*) min = 3 dan max = 23, data simpanan (*Monetary*) min = Rp. 3.000 dan max = Rp. 5.641.367, frekuensi simpanan per tahun (*Frequency* min = 3 dan max = 14) dan Pembayaran tepat waktu (*payment*) min = 0 dan max = 1. sehingga hasil dari perhitungan normalisasi ini menghasilkan data pada Tabel 3 berikut ini.

Tabel 3 Hasil Normalisasi Data

CIF	Nama Anggota	R norm	F norm	M Log norm	P norm
CIF001	DEWI PANGESTUTI	1.000	0.364	0.372	1.000
CIF002	MUSTOFA	0.800	0.818	0.161	1.000
CIF003	SODIKIN	1.000	0.727	0.461	1.000
CIF004	SUHARDI	0.300	0.091	0.342	1.000
CIF005	WASDIYANTO	0.450	0.182	0.467	1.000
CIF006	NANIK SURYANI	1.000	0.455	0.556	0.000

CIF	Nama Anggota	R norm	F norm	M Log norm	P norm
CIF016	DESY TRIA AMIRA	0.750	0.636	0.910	0.000
CIF024	SATRIO DAKSA P.	1.000	1.000	1.000	1.000
CIF034	NAUVAL NADZIF	0.900	0.455	0.000	1.000
CIF045	TIA AGUSTINA	0.150	0.273	0.211	0.000
...
CIF050	TIA KOMALASARI	1.000	0.455	0.086	1.000

Langkah selanjutnya adalah menghitung data RFMP ini menggunakan metode Elbow yang berfungsi untuk menentukan jumlah *cluster* optimal (K). Berdasarkan hasil metode Elbow, jumlah cluster optimal ditetapkan sebanyak tiga cluster (K = 3). Selanjutnya, centroid awal ditentukan dengan memilih data anggota yang merepresentasikan karakteristik rendah, sedang, dan tinggi berdasarkan variabel RFMP yang telah dinormalisasi. Pendekatan ini bertujuan untuk mempercepat konvergensi dan menghasilkan pengelompokan yang lebih *representative* [21].



Gambar 2 Hasil Metode Elbow

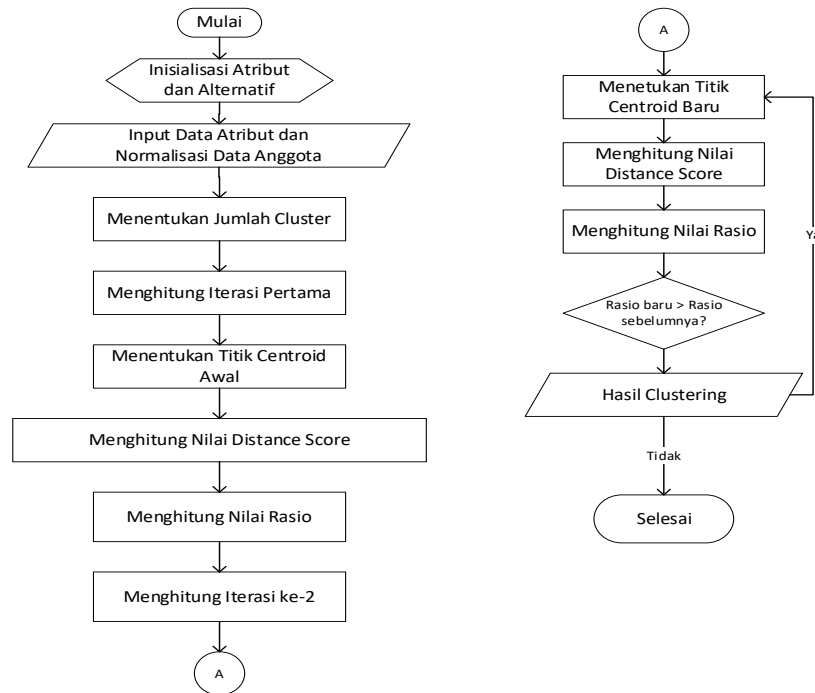
Gambar 3 merupakan grafik hasil Elbow yang menggambarkan hubungan antara jumlah cluster (K) pada sumbu horizontal dengan nilai *Within Cluster Sum of Squares* (WCSS) pada sumbu vertikal. Nilai WCSS menunjukkan tingkat kedekatan data dengan centroid dalam satu cluster; semakin kecil nilai WCSS, maka semakin homogen data dalam cluster tersebut. Pada grafik Elbow, terlihat bahwa ketika jumlah cluster meningkat dari K = 1 ke K = 2, terjadi penurunan nilai WCSS yang cukup signifikan. Penurunan yang tajam ini menunjukkan bahwa pembentukan cluster tambahan mampu meningkatkan kualitas pengelompokan data secara nyata. Selanjutnya, penurunan nilai WCSS masih cukup besar hingga K = 3. Namun, setelah K = 3, penurunan nilai WCSS mulai melandai dan tidak lagi signifikan meskipun jumlah cluster terus ditambah. Kondisi ini membentuk sudut menyerupai siku (Elbow), yang menandakan bahwa penambahan cluster setelah titik tersebut tidak memberikan peningkatan kualitas clustering yang berarti.

Berdasarkan pola tersebut, titik siku (Elbow) pada grafik berada di K = 3, sehingga jumlah cluster optimal dalam penelitian ini ditetapkan sebanyak tiga cluster. Pemilihan tiga *cluster* dinilai paling representatif dalam menggambarkan karakteristik anggota koperasi, sekaligus menjaga keseimbangan antara tingkat akurasi pengelompokan dan kesederhanaan model. Dengan K = 3, cluster dapat diinterpretasikan pada Tabel 3.

Tabel 4 Hasil Kluster dengan Metode Elbow

Jumlah Cluster	Keterangan	Karakteristik
Cluster 1	Anggota beresiko atau tidak loyal	Bergabung cukup lama, frekuensi transaksi sedang (4-7x), nominal simpanan menengah.
Cluster 2	Anggota potensial	Baru bergabung atau jarang bertransaksi (frekuensi < 4x), simpanan kecil
Cluster 3	Anggota eksklusif atau loyal	Anggota lama, frekuensi transaksi sangat tinggi (> 10x), simpanan stabil/besar

Pada tahapan selanjutnya algoritma pengklasteran K-Means digunakan untuk mengklasterkan data anggota koperasi dan data simpanan. Pada tahapan ini diolah dan dianalisis data hasil dari sistem informasi koperasi yang telah peneliti kembangkan pada penelitian sebelumnya dan sudah diimplementasikan pada mitra peneliti [22], sehingga data tersebut dapat dikategorikan sesuai dengan variabel yang sudah ditentukan. Proses penyelesaian segmentasi anggota koperasi menggunakan Algoritma *K-Means Clustering* seperti yang ditunjukkan pada Gambar 3.



Gambar 3 Diagram Alir Metode yang Di Usulkan Menggunakan Algoritma K-Means Clustering

Langkah-langkah penyelesaian pada metode K-Means adalah sebagai berikut:

- Tentukan berapa banyak cluster k dari dataset yang akan dibagi.
- Tetapkan secara *random* data k menjadi pusat awal lokasi klaster. Dalam penelitian ini, titik pusat awal ditentukan secara manual oleh pemakai.
- Hitung pusat *cluster* (*centroid*) menggunakan mean untuk masing-masing kelompok. Oleh karena itu, telah terbentuk cluster k : C_1, C_2, C_3
- Alokasikan masing-masing data ke centroid terdekat.
- Ulangi langkah hingga data-data pada tiap *cluster* menjadi terpusat dan konvergen.

Berikut ini adalah penyelesaian masalah dengan metode K-Means dengan menggunakan sample pada Tabel 5.

- Data Awal

Sebagai data awal kita akan mengambil variable utama untuk clustering, yaitu:

- Lama Bergabung
- Simpanan
- Pembayaran Pinjaman
- Frekuensi transaksi simpanan dalam setahun

Jadi setiap anggota punya titik koordinat $(X, Y) = (\text{Lama bergabung, Simpanan bulanan dan Frekuensi transaksi})$.

- Normalisasi Data

Karena skala berbeda (Bulan hanya 3 – 23, simpanan sampai jutaan), perlu normalisasi *Min – Max* agar tidak timpang datanya melalui persamaan 5 berikut ini:

$$X^1 = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

Sehingga didapatkan hasil:

- Lama bergabung: $\min = 3, \max = 23$,
- Simpanan: $\min = 3.000, \max = 5.641.367$
- Frekuensi simpanan: $\min = 3$ dan $\max = 14$
- Pembayaran tepat waktu: $\min = 0$ dan $\max = 1$

Hasil dari perhitungan normalisasi seperti pada Tabel 5 berikut ini:

Tabel 5 Hasil Data Awal yang Sudah di Normalisasi

CIF	Nama Anggota	R norm	F norm	M Log norm	P norm
CIF001	DEWI PANGESTUTI	1.000	0.364	0.372	1.000
CIF002	MUSTOFA	0.800	0.818	0.161	1.000
CIF003	SODIKIN	1.000	0.727	0.461	1.000
CIF004	SUHARDI	0.300	0.091	0.342	1.000



CIF	Nama Anggota	R norm	F norm	M Log norm	P norm
CIF005	WASDIYANTO	0.450	0.182	0.467	1.000
CIF006	NANIK SURYANI	1.000	0.455	0.556	0.000
CIF016	DESY TRIA AMIRA	0.750	0.636	0.910	0.000
CIF024	SATRIO DAKSA P.	1.000	1.000	1.000	1.000
CIF034	NAUVAL NADZIF	0.900	0.455	0.000	1.000
CIF045	TIA AGUSTINA	0.150	0.273	0.211	0.000
...
CIF050	TIA KOMALASARI	1.000	0.455	0.086	1.000

c. Tahap 1 Inisialisasi *Centroid* (Titik Pusat Awal)

Misalkan $k = 3$ cluster umumnya untuk segmentasi beresiko, potensial, eksklusif. Kita tentukan 3 titik pusat awal ($k=3$) secara acak dari data normalisasi yang ada sebagai perwakilan tiap cluster, Tabel 6 merupakan hasil inisialisasi centroid awal:

Tabel 6 Inisialisasi Centroid Awal (Skala Normalisasi 0-1)

Centroid	Nama Cluster	Recency (R)	Frequency (F)	Monetary (M)	Payment (P)	Profil Karakteristik
C1	Berisiko / Pasif	0.30	0.09	0.34	0.00	Anggota baru, jarang transaksi, pembayaran tidak lancar.
C2	Potensial / Sehat	0.90	0.45	0.37	1.00	Anggota lama, transaksi sedang, pembayaran sangat disiplin.
C3	Eksklusif / Loyal	1.00	1.00	1.00	1.00	Anggota paling setia, transaksi paling aktif, saldo besar, lancar.

d. Tahap 2 – Hitung Jarak *Euclidean* (Iterasi 1)

Formula untuk menghitung jarak *Euclidean* dengan data sudah dinormalisasi adalah menggunakan persamaan 6 sebagai berikut ini:

$$D = \sqrt{(R_x - R_c)^2 + (F_x - F_c)^2 + (M_x - M_c)^2 + (P_x - P_c)^2} \quad (6)$$

Kita ambil satu sampel anggota, yaitu CIF002 atas nama Mustofa. Data Normalisasi Mustofa (X):

$R = 0.80$, $F = 0.82$, $M = 0.16$, $P = 0.00$

1. Jarak Mustofa ke C_1 :

$$D_1 = \sqrt{(0.80 - 0.30)^2 + (0.82 - 0.09)^2 + (0.16 - 0.34)^2 + (0.00 - 0.00)^2}$$

$$D_1 = \sqrt{0.5^2 + 0.73^2 + (-0.18)^2 + 0} = \sqrt{0.25 + 0.5329 + 0.0324} = \sqrt{0.8153} = \mathbf{0.903}$$

2. Jarak Mustofa ke C_2 :

$$D_2 = \sqrt{(0.80 - 0.90)^2 + (0.82 - 0.45)^2 + (0.16 - 0.37)^2 + (0.00 - 1.00)^2}$$

$$D_2 = \sqrt{(-0.1)^2 + 0.37^2 + (-0.21)^2 + (-1)^2} = \sqrt{0.01 + 0.1369 + 0.0441 + 1} = \sqrt{1.191} = \mathbf{1.091}$$

3. Jarak Mustofa ke C_3 :

$$D_3 = \sqrt{(0.80 - 1.00)^2 + (0.82 - 1.00)^2 + (0.16 - 1.00)^2 + (0.00 - 1.00)^2}$$

$$D_3 = \sqrt{(-0.2)^2 + 0.18^2 + (-0.84)^2 + (-1)^2} = \sqrt{0.04 + 0.324 + 0.7056 + 1} = \sqrt{1.778} = \mathbf{1.333}$$

Hasil pengelompokan anggota atas nama Mustofa masuk ke Cluster 1 karena D_1 adalah jarak terpendek.

e. Tahap 3 penentuan Nilai Centroid

Setelah semua 50 anggota dihitung jaraknya ke data kluster C1, C2, dan C3, selanjutnya kita akan menghitung centroid baru dengan persamaan 2.

Misalnya, setelah perhitungan, Cluster 3 (Eksklusif) ternyata hanya diisi oleh 2 orang:

1. Mustofa (jika jarak berubah di iterasi berikutnya): [0.80, 0.82, 0.16, 0.00]

2. Sodikin: [1.00, 0.73, 0.46, 0.00]

Maka, Centroid baru untuk Cluster 3 adalah rata-rata dari anggotanya:



1. $R = (0.80 + 1.00) / 2 = 0,90$
 2. $F = (0.82 + 0.73) / 2 = 0,77$
 3. $M = (0.16 + 0.46) / 2 = 0,31$
 4. $P = (0.00 + 0.00) / 2 = 0.00$
- f. Tahap 4 Iterasi berulang (Hitung ulang jarak dan *assign*)
- Ulangi Langkah menghitung jarak, *update centroid* dan *assign* ulang. Ketika sudah berhenti dan centroid stabil atau tidak berubah (Konvergen). Langkah 2 dan 3 diulang terus-menerus menggunakan Centroid baru.
1. Iterasi 2: Hitung lagi jarak setiap anggota ke Centroid baru. Ada kemungkinan anggota berpindah cluster karena pusatnya sudah bergeser.
 2. Iterasi 3: Update lagi Centroidnya.
 3. Selesai: Algoritma berhenti ketika tidak ada lagi anggota yang berpindah *cluster* (konvergen).

3.2 Hasil Akhir Cluster

Dalam kasus ini, variabel *Payment* (P) memiliki pengaruh sangat kuat karena nilai selisihnya ekstrem (0 atau 1). Jika seorang anggota memiliki $P=0$ (tidak lancar), ia akan memiliki "beban" jarak sebesar $1^2 = 1$ terhadap centroid yang memiliki $P=1$. Variabel inilah yang memastikan *cluster* berisiko dan potensial terpisah dengan tegas. Hasil akhir perhitungan clustering menggunakan algoritma k-means sebagaimana pada Tabel 7.


Tabel 7 Hasil Akhir Perhitungan *Clustering K-Means*

No	CIF	Nama Anggota	C1 (Berisiko)	C2 (Potensial)	C3 (Eksklusif)	Cluster Terpilih
1	CIF001	DEWI PANGESTUTI	0.932	0.174	0.612	Cluster 2
2	CIF002	MUSTOFA	0.748	1.052	0.315	Cluster 3
3	CIF003	SODIKIN	0.895	1.021	0.198	Cluster 3
4	CIF004	SUHARDI	0.192	1.154	0.985	Cluster 1
5	CIF005	WASDIYANTO	0.312	1.025	0.842	Cluster 1
6	CIF006	NANIK SURYANI	0.672	0.999	0.675	Cluster 1
7	CIF010	HANIP SUGI HARTO	0.812	0.985	0.244	Cluster 3
8	CIF011	SLAMET MUJIONO	0.885	1.112	0.185	Cluster 3
9	CIF016	DESY TRIA AMIRA	0.985	1.182	0.421	Cluster 3
10	CIF023	KISWATI	0.415	1.321	0.954	Cluster 1
11	CIF024	SATRIO DAKSA P.	1.254	0.685	0.252	Cluster 3
12	CIF025	FADLILIANA M.	0.245	1.185	1.024	Cluster 1
13	CIF029	WIDODO	0.954	0.182	0.654	Cluster 2
14	CIF030	KRIS HERJANTO	0.842	0.211	0.742	Cluster 2
15	CIF035	RISQI ROMADHON	0.912	1.045	0.201	Cluster 3
16	CIF040	ROZANAH	0.875	1.095	0.212	Cluster 3
17	CIF045	TIA AGUSTINA	0.321	1.285	1.102	Cluster 1
18	CIF047	IDA KHULAIFAH	0.285	1.154	0.985	Cluster 1
19	CIF049	M. MASRURON	0.542	1.024	0.785	Cluster 1
...
50	CIF050	TIA KOMALASARI	1.054	0.215	0.785	Cluster 2

Hasil akhir yang ditunjukkan pada Tabel 8 menunjukkan *Cluster* 1 sebanyak 18 anggota disegmen Berisiko. Cluster 2 sebanyak 20 anggota disegmen potensial. Cluster 3 sebanyak 12 anggota berada disegmen Eksklusif atau loyal.

Tabel 8 Hasil Akhir Pengelompokan Anggota Koperasi

Cluster	Nama Segmen	Jumlah Anggota	Persentase (%)
Cluster 1	Berisiko / Pasif	18	36%
Cluster 2	Potensial / Sehat	20	40%
Cluster 3	Eksklusif / Loyal	12	24%
Total		50	100%



Gambar 4 Scatter Plot Sebaran Cluster Anggota



Pada Gambar 4 memetakan 50 anggota koperasi Anda ke dalam ruang dua dimensi berdasarkan dua variabel paling krusial:

- a. Sumbu X (Horizontal): *Frequency* (Keaktifan) — Menunjukkan seberapa sering anggota melakukan transaksi simpanan dalam setahun.
- b. Sumbu Y (Vertikal): *Payment* (Kepatuhan) — Menunjukkan tingkat ketepatan waktu pembayaran pinjaman (Skala 0 hingga 1).

Cluster 1 (Kuning - Berisiko): Terletak di pojok kiri bawah. Kelompok ini memiliki skor kepatuhan pembayaran yang rendah dan jarang melakukan transaksi simpanan. Anggota di zona ini memerlukan pengawasan ketat dan penagihan aktif. Cluster 2 (Hijau - Potensial): Terletak di bagian atas sebelah kiri. Mereka adalah anggota yang sangat patuh (pembayaran lancar), namun frekuensi transaksinya masih rendah hingga sedang. Mereka adalah aset yang stabil namun perlu didorong untuk lebih aktif menabung. Cluster 3 (Biru - Eksklusif): Terletak di sisi kanan grafik. Kelompok ini adalah "bintang" koperasi. Mereka memiliki frekuensi transaksi yang sangat tinggi. Meskipun beberapa memiliki skor pembayaran yang bervariasi, kontribusi mereka terhadap aktivitas keuangan koperasi adalah yang terbesar.

4. KESIMPULAN

Berdasarkan hasil clustering menggunakan algoritma K-Means dengan analisis data *Recency*, *Frequency*, *Monetary* dan *Payment* (RFMP), dapat disimpulkan bahwa cukup banyak anggota koperasi (36%) berada pada kategori berisiko, sementara 40% tergolong anggota potensial, serta 24% merupakan anggota loyal atau eksklusif. Penentuan jumlah cluster optimal $k=3$ divalidasi melalui metode Elbow, yang menunjukkan penurunan tajam seperti siku (elbow) hingga $k=3$ sebelum membentuk grafik yang datar, yang menandakan pemisahan cluster dengan baik. Hasil ini membuktikan efektivitas K-Means dalam segmentasi anggota koperasi berbasis RFMP, dengan metode Elbow sebagai pertimbangan ilmiah yang kuat untuk pemilihan k secara optimal. Segmentasi anggota koperasi ini menjadi dasar keputusan strategis koperasi dalam pengelolaan risiko, peningkatan loyalitas, dan optimalisasi simpanan-pembiayaan, sehingga memperkuat kesehatan finansial jangka panjang.

REFERENCES

- [1] A. R. Naufal and A. T. Suseno, "Penerapan Fitur Seleksi dan Particle Swarm Optimization pada Algoritma Support Vector Machine untuk Analisis Credit Scoring," *J. Comput. Syst. Informatics*, vol. 5, no. 1, pp. 184–195, 2023, doi: 10.47065/josyc.v5i1.4409.
- [2] A. Rifqi and R. T. Aldisa, "Penerapan Data Mining dalam Implementasi Algoritma K-Means Clustering untuk Pelanggan Potensial pada Koperasi Simpan Pinjam," *Build. Informatics, Technol. Sci.*, vol. 5, no. 2, 2023, doi: 10.47065/bits.v5i2.4278.
- [3] N. Teguh Santoso and Y. Suhari, "SPK Pemberian Pinjaman Menggunakan Metode AHP Dan SAW (Studi Kasus KSP Bhina Raharja Purbalingga)," *JATISI (Jurnal Tek. Inform. dan Sist. Inf.)*, vol. 10, no. 1, pp. 2407–4322, 2023, doi: <https://doi.org/10.35957/jatisi.v10i1.2695>.
- [4] D. T. Larose, *Data Mining Methods and Models*. Canada: John Wiley & Sons, Inc, 2007.
- [5] E. Omol, D. Onyangor, L. Mburu, and P. Abuonji, "Application Of K-Means Clustering For Customer Segmentation In Grocery Stores In Kenya," *Int. J. Sci. Technol. Manag.*, vol. 5, no. 1, pp. 192–200, 2024, doi: 10.46729/ijstm.v5i1.1024.
- [6] 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*, vol. 11, no. 2, p. 260, 2022, doi: 10.32520/stmsi.v11i2.1337.
- [7] R. B. Ardi, F. Ely Nastiti, and S. Sumarlinda, "Algoritma K-Means Clustering Untuk Segmentasi Pelanggan (Studi Kasus : Fashion Viral Solo)," *INFOTECH J.*, vol. 9, no. 1, pp. 124–131, 2023, doi: 10.31949/infotech.v9i1.5214.
- [8] A. T. Suseno, A. R. Naufal, and M. Al Amin, "Market Based Analysis Sebagai Peningkatan Penjualan Produk Menggunakan Algoritma K-Medoids Dan Fp-Growth," *J. Tek. Inf. dan Komput.*, vol. 5, no. 2, p. 301, 2022, doi: 10.37600/tekinkom.v5i2.646.
- [9] Florensia Angela Renya Seran, Yosep PK Kelen, and Darsono Nababan, "Sistem Pendukung Keputusan Penentuan Jurusan Menggunakan Metode Weighted Product," *J. Tekno Kompak*, vol. 17, no. 1, pp. 147–159, 2020.
- [10] R. Raswini, C. Ramdani, and Y. D. Prasetyo, "Sistem Pendukung Keputusan Pemilihan Jurusan Menggunakan Metode Analytical Hierarchy Process," *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 4, p. 810, 2022, doi: 10.30865/jurikom.v9i4.4449.
- [11] M. F. Fadhillah, A. Lovely, A. Suyoso, and I. Puspitasari, "Segmentasi Pelanggan dengan Algoritma Clustering Berdasarkan Atribut Recency, Frequency dan Monetary (RFM)," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. January, pp. 48–56, 2025, doi: <https://doi.org/10.57152/malcom.v5i1.1491>.
- [12] 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, doi: 10.33633/tc.v21i4.6697.
- [13] D. Diotivano, D. Ruslianto, Ikhwan, Prawira, "Sistem Segementasi Pelanggan Potensial Menggunakan Metode K-Means dan Analisis RFM," *J. Komput. dan Apl.*, vol. 11, no. 03, pp. 325–337, 2023, doi: <https://doi.org/10.26418/coding.v11i03.53238>.
- [14] J. Chitra and J. Heikal, "Customer segmentation using the K-Means Clustering algorithm in Foreign Banks in Indonesia," *Indones. Account. Res. J.*, vol. 11, no. 4, pp. 230–241, 2024, doi: <https://doi.org/10.80701/IARN.v9i1.7931>.
- [15] S. Sharma, R. Satsangi, P. Manani, P. Sharma, and J. Gupta, "Strategic Insights into Customer Diversity: Unraveling Purchase Patterns, Income Disparities, and Relationship Dynamics through K-means Clustering for Enhanced Engagement and Loyalty," *Procedia Comput. Sci.*, vol. 259, pp. 1–10, 2025, doi: 10.1016/j.procs.2025.03.301.
- [16] F. O. Dayera, Musa Bundaris Palungan, "AI-Driven Customers Segmentation Using K-Means Clustering," *G-Tech J. Teknol. Terap.*, vol. 8, no. 1, pp. 186–195, 2024, doi: <https://doi.org/10.70609/gtech.v9i1.6202>.
- [17] V. Alvianatinova, I. Ali, N. Rahaningsih, and A. Bahtiar, "Penerapan Algoritma K-Means Clustering Dalam Pengelompokan Data Penjualan Supermarket Berdasarkan Cabang (Branch)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 2, pp. 1529–1535, 2024, doi: 10.36040/jati.v8i2.8993.



- [18] Baiq Nikum Yulisasih, H. Herman, and S. Sunardi, "K-Means Clustering Method For Customer Segmentation Based On Potential Purchases," *J. ELTIKOM*, vol. 8, no. 1, pp. 83–90, 2024, doi: 10.31961/eltikom.v8i1.1137.
- [19] N. A. Maori, "Metode Elbow Dalam Optimasi Jumlah Cluster Pada K-Means Clustering," *SIMETRIS (Jurnal Tek. Ind. Mesin, Elektro dan Ilmu Komputer)*, vol. 14, no. 2, pp. 277–287, 2023, doi: <https://doi.org/10.24176/simet.v14i2.9630>.
- [20] P. Vania and B. N. Sari, "Perbandingan Metode Elbow dan Silhouette untuk Penentuan Jumlah Klaster yang Optimal pada Clustering Produksi Padi menggunakan Algoritma K-Means," *Ilmiah, J. Pendidikan, Wahana Pendidikan, Wahana*, vol. 9, no. November, pp. 547–558, 2023, doi: <https://doi.org/10.5281/zenodo.10081332>.
- [21] S. L. Achmad, A. Fauzi, Rahmat, and J. Indra, "Segmentasi pelanggan menggunakan k-means clustering di toko retail," vol. 7, pp. 736–747, 2024, doi: 10.37600/tekinkom.v7i2.1226.
- [22] A. R. Naufal, R. Ngizudin, and D. Rachdantia, "Penerapan Digitalisasi Koperasi dan Pemasaran serta Pendampingan untuk Peningkatan Value Produk UMKM Anggota Koperasi LKMS Kasuwari di Pekalongan Barat," *J. ABDINUS J. Pengabd. Nasant.*, vol. 9, no. 1, pp. 140–150, 2025, doi: <https://doi.org/10.29407/ja.v9i1.23670>.