

Analisis Pola Pinjaman Anggota Koperasi Menggunakan Metode K-Means Clustering

Nisaa' Husnia Yahya¹, Jihan Martha², Resty Wulanningrum³

^{1,2}Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: ¹yahyanisaa461@gmail.com, ²jihannmartha@gmail.com, ³restyw@unpkdr.ac.id

Abstrak

Koperasi Simpan Pinjam (KSP) Sri Hadi Dharma merupakan lembaga keuangan mikro yang melayani pembiayaan anggota dengan karakteristik peminjam yang beragam, sehingga diperlukan mekanisme penilaian risiko kredit yang lebih objektif dan berbasis data. Penelitian ini bertujuan untuk melakukan segmentasi anggota berdasarkan karakteristik pinjaman guna mengidentifikasi kelompok risiko kredit menggunakan algoritma *K-Means Clustering*. Data yang digunakan meliputi besar pinjaman, besar angsuran, tenor, dan status pekerjaan. Tahapan penelitian mencakup preprocessing data (*normalisasi* dan *encoding*), pemilihan jumlah *cluster* optimal menggunakan metode *Elbow* dan *Davies Bouldin Index*, serta analisis karakteristik tiap *cluster*. Hasil penelitian menunjukkan bahwa model dengan tiga *cluster* memberikan pemisahan terbaik, dengan komposisi 55% anggota berada pada kategori Normal, 44,9% Tidak Berisiko, dan 0,1% Berisiko. Analisis karakteristik *cluster* memperlihatkan bahwa besar pinjaman, besar angsuran, serta distribusi pekerjaan menjadi variabel yang paling berpengaruh dalam pembentukan kelompok risiko, sementara tenor tidak memberikan kontribusi signifikan. Temuan ini menunjukkan bahwa pendekatan klasterisasi dapat membantu koperasi dalam memahami pola risiko anggotanya dan memberikan dasar bagi pengembangan sistem pendukung keputusan kredit yang lebih akurat.

Kata Kunci — *Clustering, K-Means, Koperasi, Segmentasi*

1. PENDAHULUAN

Koperasi Simpan Pinjam (KSP) Sri Hadi Dharma merupakan lembaga keuangan mikro yang menyediakan layanan pembiayaan bagi anggotanya. Pengelolaan pinjaman yang efektif memegang peranan penting dalam menjaga stabilitas keuangan koperasi. Beragamnya karakteristik peminjam seperti jumlah pinjaman, jangka waktu angsuran, riwayat pembayaran, serta kemampuan pelunasan membuat proses penilaian kredit menjadi semakin kompleks jika dilakukan secara manual [1]. Hal ini berpotensi untuk meningkatkan risiko kredit macet dan menurunkan efektivitas layanan koperasi apabila tidak didukung oleh analisis data yang memadai [2].

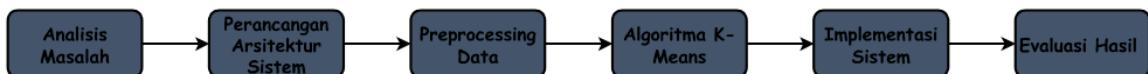
Data pinjaman anggota sebenarnya menyimpan pola-pola penting yang dapat dimanfaatkan untuk memahami kecenderungan perilaku peminjam. Pola tersebut dapat menunjukkan kelompok peminjam yang disiplin, anggota dengan beban pinjaman tinggi, hingga potensi terjadinya keterlambatan pembayaran [3]. Tanpa adanya analisis berbasis data, koperasi sering kali kesulitan mengenali perbedaan karakteristik antar anggota, sehingga kebijakan pembiayaan yang diterapkan tidak selalu tepat sasaran [4]. Penggunaan data sebagai dasar pengambilan keputusan menjadi semakin penting seiring meningkatnya kebutuhan koperasi dalam mengelola risiko kredit secara optimal [5].

Salah satu pendekatan yang efektif untuk mengelompokkan anggota berdasarkan kemiripan karakteristik pinjaman adalah metode klasterisasi menggunakan algoritma *K-Means*. Algoritma ini mampu memproses data berukuran besar dan membentuk beberapa *cluster* yang mencerminkan pola perilaku peminjam dengan tingkat kemiripan tertentu [6]. Pengelompokan tersebut dapat membantu koperasi memahami kondisi *riil* anggota secara lebih objektif sehingga memudahkan dalam merancang kebijakan kredit yang sesuai dengan profil masing-masing kelompok [7]. Metode ini juga umum digunakan pada lembaga keuangan dalam menganalisis perilaku nasabah, baik dari sisi jumlah kredit, lama kredit, maupun aspek demografi yang relevan [8].

Berdasarkan uraian di atas, penelitian ini bertujuan menerapkan algoritma *K-Means Clustering* pada data "BUKU CICILAN PACET 2025" untuk menghasilkan segmentasi anggota koperasi yang akurat. Hasil klasterisasi diharapkan menjadi dasar dalam menentukan strategi pembiayaan, meningkatkan pengawasan kredit, serta mendukung pengambilan keputusan yang lebih terukur dan efisien. Dengan pendekatan ini, koperasi dapat meningkatkan kualitas layanan, meminimalkan risiko kredit macet, dan memperkuat keberlanjutan operasional Lembaga.

2. METODE PENELITIAN

Metode penelitian ini dirancang untuk menganalisis pola pinjaman anggota KSP Sri Hadi Dharma menggunakan algoritma *K-Means Clustering*. Tahapan penelitian digambarkan pada Gambar 1 dan mengikuti pendekatan data mining yang umum digunakan untuk segmentasi nasabah.



Gambar 1. Metode Penelitian

2.1 Analisis Masalah

1. Analisis Permasalahan

Tahap awal bertujuan mengidentifikasi permasalahan dan kebutuhan penelitian. Saat ini, Koperasi Sri Hadi Dharma belum memiliki sistem segmentasi anggota berdasarkan perilaku pinjaman, sehingga risiko kredit belum dapat diukur secara kuantitatif.

Variabel penelitian yang digunakan adalah:

1. Jumlah Pinjaman : total pinjaman anggota.
2. Angsuran : nilai cicilan per periode.
3. Pekerjaan : status pekerjaan anggota (Dinas ,Umum ,Pensiunan).
4. Tenor : lama cicilan anggota.

Pemilihan variabel ini mengacu pada praktik umum segmentasi risiko kredit pada koperasi dan lembaga keuangan [9].

2.2 Perancangan Arsitektur Sistem

Arsitektur sistem dirancang untuk memetakan alur data dan proses analisis. Sistem terdiri dari tiga lapisan utama:

1. *Input Layer*
Menangkap data variabel: jumlah pinjaman, angsuran, pekerjaan, dan tenor.
2. *Processing Layer*
Melakukan *preprocessing data*: *cleaning*, *normalisasi*, *encoding* kategori.
Menerapkan algoritma *K-Means* untuk mengelompokkan anggota berdasarkan jarak ke *centroid*.
3. *Output Layer*
Menampilkan hasil *cluster* berupa segmentasi anggota koperasi dengan karakteristik pinjaman serupa.

Visualisasi dapat berupa *scatter plot* atau diagram *cluster*.

Arsitektur ini memudahkan implementasi sistem berbasis Python dan memastikan proses analisis berjalan terstruktur [10]. Alur hubungan antar lapisan dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur Sistem

2.3 Preprocessing Data

Sebelum dilakukan *clustering*, data harus diproses agar berkualitas:

1. Pembersihan Data (*Cleaning*)
Menghapus data kosong atau *outlier* yang dapat memengaruhi hasil *cluster*.
2. Transformasi Data (*Normalisasi*)

Data numerik dinormalisasi menggunakan *Min–Max Normalization*:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

3. *Encoding* Variabel Kategori

Variabel pekerjaan dikonversi menjadi angka menggunakan *label encoding*, sehingga dapat diproses *K-Means* [11].

2.4 Penerapan Algoritma K-Means

Tahap *clustering* dilakukan dengan langkah berikut:

1. Menentukan jumlah *cluster* *k*.

2. Menentukan *centroid* awal secara acak.
3. Menghitung jarak setiap data ke *centroid* menggunakan ***Euclidean Distance***:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2)$$

4. Mengelompokkan data ke *centroid* terdekat.
5. Menghitung ulang *centroid* dan mengulang proses hingga *konvergen*.

Algoritma ini dipilih karena efektif untuk segmentasi data numerik yang besar, seperti dataset anggota koperasi [12].

2.5 Implementasi Sistem

Implementasi dilakukan menggunakan Python dengan *library*:

- a) *Pandas* – pengolahan data.
- b) *NumPy* – operasi numerik.
- c) *Scikit-learn (Sklearn)* – algoritma *K-Means* dan *preprocessing*.

Tahapan implementasi:

1. Memasukkan dataset pinjaman anggota koperasi.
2. *Preprocessing* data melalui pipeline otomatis.
3. Menjalankan *K-Means* untuk nilai *k* tertentu.
4. Menghasilkan *output cluster* berupa segmentasi anggota.
5. Membuat visualisasi hasil *cluster* untuk interpretasi mudah. [13]

2.6 Evaluasi Hasil

Evaluasi dilakukan menggunakan dua metrik standar [14]:

1. *Sum of Squared Error (SSE)* – untuk metode *Elbow* menentukan jumlah *cluster* optimal [15]:

$$SSE = \sum_{i=1}^k \sum_{x \in C_i} \|x - c_i\|^2 \quad (3)$$

2. *Davies–Bouldin Index (DBI)* – mengukur kualitas pemisahan *cluster* [16]:

$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \frac{S_i + S_j}{d_{ij}} \quad (4)$$

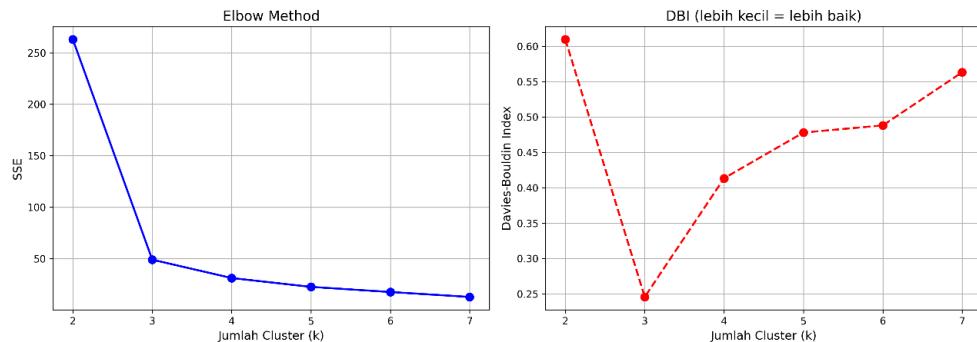
Evaluasi ini memastikan *cluster* yang terbentuk memiliki homogenitas tinggi dan pemisahan antar *cluster* yang baik .

3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil pengolahan data, proses *clustering* menggunakan algoritma *K-Means*, visualisasi hasil, dan analisis pembahasan berdasarkan grafik serta tabel yang dihasilkan. Seluruh hasil diperoleh melalui implementasi kode Python serta aplikasi antarmuka berbasis Streamlit.

3.1 Penentuan Jumlah *Cluster* Optimal

Penentuan jumlah *cluster* dilakukan menggunakan dua metrik, yaitu *Elbow Method* dan *Davies–Bouldin Index (DBI)*. *Elbow* menentukan titik tekuk grafik *Sum of Squared Error (SSE)*, sedangkan *DBI* mengukur kualitas pemisahan *cluster*.



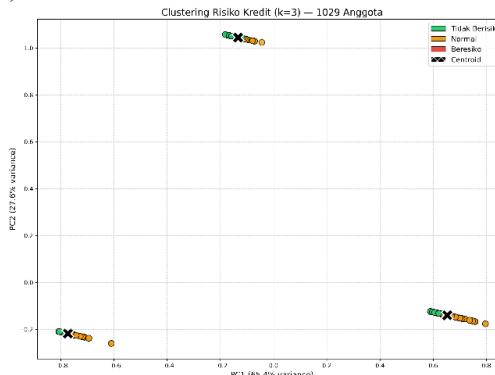
Gambar 3. Grafik Elbow dan DBI Penentuan Jumlah *Cluster* Optimal

Gambar 3 menunjukkan hasil analisis penentuan jumlah *cluster* optimal menggunakan metode *Elbow* dan *Davies–Bouldin Index (DBI)*. Pada grafik *Elbow*, nilai *SSE* mengalami penurunan tajam dari *k* = 2 ke *k* = 3,

kemudian mulai melandai pada $k > 3$, sehingga titik siku (*elbow*) terlihat jelas pada $k = 3$. Kondisi ini mengindikasikan bahwa penambahan jumlah *cluster* setelah $k = 3$ tidak lagi memberikan pengurangan kesalahan yang signifikan, sehingga $k = 3$ dianggap sebagai titik paling efisien. Temuan ini diperkuat oleh grafik *DBI*, di mana nilai indeks terendah yang menunjukkan kualitas *cluster* paling baik juga terjadi pada $k = 3$ dengan nilai sekitar 0,24. Sebaliknya, nilai *DBI* meningkat pada $k = 4$ hingga $k = 7$, yang menandakan menurunnya kualitas pemisahan *cluster*. Konsistensi hasil dari kedua metode tersebut menunjukkan bahwa struktur data paling optimal direpresentasikan oleh tiga *cluster*, sehingga $k = 3$ dipilih sebagai jumlah *cluster* terbaik dalam penelitian ini.

3.2 Visualisasi *Clustering* dengan PCA

Untuk memudahkan interpretasi data berdimensi tinggi, dilakukan reduksi dimensi menggunakan *Principal Component Analysis* (PCA).

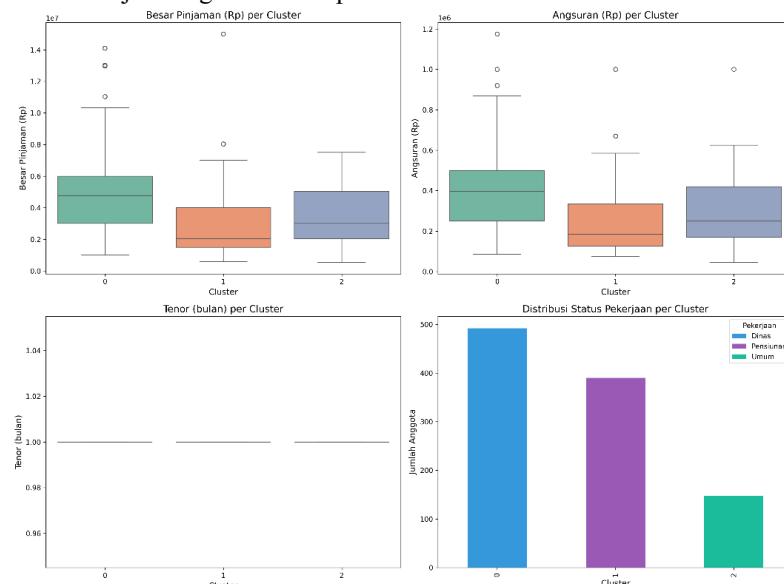


Gambar 4. Visualisasi PCA Hasil *Clustering* K-Means

Gambar 4 menampilkan visualisasi hasil *clustering* risiko kredit menggunakan algoritma *K-Means* dengan jumlah *cluster* optimal $k = 3$, yang direduksi ke dalam ruang dua dimensi menggunakan *Principal Component Analysis* (PCA). Plot tersebut menggambarkan distribusi 1.029 anggota koperasi berdasarkan karakteristik pinjaman yang telah diproses melalui model, di mana setiap warna merepresentasikan kategori risiko berbeda: “Tidak Berisiko”, “Normal”, dan “Berasiko”. Ketiga kelompok tampak terpisah dengan jelas, menunjukkan bahwa model berhasil memetakan pola data yang memiliki perbedaan signifikan antar *cluster*. Posisi *centroid* yang ditandai dengan simbol ‘X’ memperlihatkan pusat massa masing-masing *cluster*, yang menjadi representasi profil risiko dominan pada setiap kelompok. Sebaran data yang kompak di sekitar *centroid* menandakan homogenitas yang baik dalam *cluster*, sementara jarak antar *cluster* yang cukup lebar menunjukkan bahwa model mampu membedakan tingkat risiko kredit dengan efektif. Secara keseluruhan, visualisasi ini mengonfirmasi bahwa struktur data kredit anggota secara alami terbagi ke dalam tiga kelompok risiko yang berbeda dan terdefinisi dengan baik.

3.3 Analisis Hasil Cluster

Setiap *cluster* dianalisis berdasarkan distribusi nilai variabel: jumlah pinjaman, angsuran, pekerjaan, dan tenor. Untuk visualisasi lebih jelas digunakan boxplot.

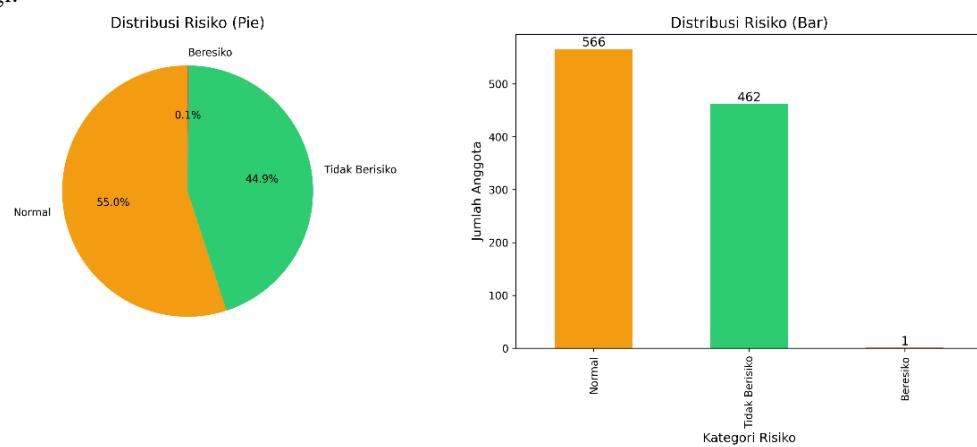


Gambar 5. Boxplot Variabel Berdasarkan Cluster

Gambar 5 menyajikan analisis karakteristik tiap *cluster* berdasarkan empat variabel utama, yaitu besar pinjaman, besar angsuran, tenor pinjaman, dan status pekerjaan anggota. Pada panel pertama (atas kiri), boxplot menunjukkan perbedaan pola distribusi besar pinjaman antar *cluster*, di mana *Cluster 0* cenderung memiliki nilai pinjaman lebih tinggi dengan rentang variasi yang lebih besar, sedangkan *Cluster 1* memiliki pinjaman yang relatif lebih rendah dan stabil. Panel kedua (atas kanan) memperlihatkan pola serupa pada variabel angsuran, di mana *Cluster 0* kembali menunjukkan nilai angsuran yang lebih besar, menandakan bahwa kelompok ini terdiri dari peminjam dengan beban kredit lebih tinggi. Panel ketiga (bawah kiri) menunjukkan bahwa tenor pinjaman relatif seragam di seluruh *cluster*, sehingga variabel ini tidak berkontribusi signifikan dalam proses pembentukan *cluster*. Pada panel keempat (bawah kanan), distribusi status pekerjaan antar *cluster* tampak berbeda: *Cluster 0* didominasi oleh anggota dengan pekerjaan Dinas, *Cluster 1* lebih banyak terdiri dari pekerja Umum, sedangkan *Cluster 2* menunjukkan proporsi terbesar pada kelompok Pensiunan. Temuan ini menunjukkan bahwa variabel besar pinjaman, angsuran, serta status pekerjaan menjadi faktor utama yang membedakan karakteristik antar *cluster*, sementara tenor memiliki pengaruh minimal terhadap segmentasi risiko.

3.4 Distribusi Kategori Risiko Berdasarkan *Cluster*

Cluster hasil *K-Means* dikelompokkan kembali untuk memetakan kategori risiko: risiko rendah, sedang, dan tinggi.



Gambar 6. Distribusi Kategori Risiko Anggota

Gambar 6 menampilkan distribusi kategori risiko kredit anggota koperasi dalam bentuk diagram *pie* dan diagram batang. Berdasarkan visualisasi tersebut, sebagian besar anggota berada pada kategori “Normal” dengan total 566 orang atau sekitar 55% dari populasi. Kategori “Tidak Berisiko” menempati proporsi terbesar kedua dengan 462 anggota atau 44,9%, menunjukkan bahwa hampir separuh anggota memiliki profil kredit yang aman. Sementara itu, kategori “Berisiko” hanya mencakup satu anggota atau sekitar 0,1%, yang mengindikasikan bahwa kasus kredit bermasalah pada koperasi sangat rendah. Konsistensi antara visualisasi *pie* dan *bar chart* memperjelas perbandingan proporsi antar kategori, sekaligus menunjukkan bahwa distribusi risiko kredit cenderung terkonsentrasi pada dua kelompok utama, yakni Normal dan Tidak Berisiko. Secara keseluruhan, hasil ini menggambarkan bahwa profil kredit anggota koperasi berada pada kondisi yang relatif stabil dan aman, dengan tingkat risiko tinggi yang sangat minimal.

3.5 Implementasi Sistem Berbasis Streamlit

Untuk mempermudah pengguna dalam melihat hasil analisis *K-Means* secara interaktif, dikembangkan aplikasi berbasis Streamlit yang dijalankan secara lokal selama proses penelitian.

Fitur utama aplikasi meliputi:

1. *Upload* dataset "Buku Cicilan Pacet 2025"
2. Melakukan *preprocessing* otomatis
3. Menentukan jumlah *cluster*
4. Menyajikan visualisasi *Elbow & DBI*
5. Menampilkan *PCA Clustering*
6. Menyediakan boxplot dan distribusi risiko
7. Menampilkan interpretasi hasil secara otomatis

Aplikasi ini membantu koperasi dalam melakukan segmentasi anggota secara lebih cepat, informatif, dan akurat selama tahap analisis penelitian

3.6 Pembahasan

Berdasarkan seluruh hasil analisis dan visualisasi:

1. Tiga *cluster* merupakan jumlah optimal yang menggambarkan kelompok peminjam.

2. Visualisasi PCA memperlihatkan pemisahan cukup baik, memperkuat validitas hasil *clustering*.
3. Boxplot memperjelas perbedaan variabel antar *cluster* sehingga memudahkan pemahaman karakteristik tiap kelompok.
4. Distribusi risiko membantu koperasi dalam memahami proporsi anggota yang berpotensi mengalami keterlambatan pembayaran.
5. Aplikasi Streamlit yang dibangun meningkatkan efektivitas analisis karena dapat dijalankan berulang oleh pengguna tanpa perlu membuka kode Python.

Dengan demikian, metode *K-Means* efektif digunakan untuk segmentasi anggota KSP Sri Hadi Dharma dan mendukung pengambilan keputusan kredit secara lebih objektif dan terukur.

3.7 Integrasi Sistem Streamlit

Sistem klasterisasi risiko kredit juga telah diimplementasikan dalam bentuk aplikasi *dashboard* berbasis Streamlit yang dijalankan secara lokal selama proses penelitian.

Dashboard ini menyediakan fitur:

1. Pencarian anggota berdasarkan nama
2. Informasi total anggota yang diproses
3. Jumlah *cluster* yang terbentuk
4. Distribusi anggota per *cluster*
5. Tabel data anggota lengkap beserta status risiko
6. Visualisasi (*scatter plot*, *PCA*, distribusi risiko, dan lainnya)

Tampilan *Dashboard* Streamlit

Berikut contoh tampilan sistem yang dihasilkan berupa dashboard klasterisasi risiko kredit. Tampilan tersebut dapat dilihat pada Gambar 7.



Gambar 7. Tampilan Dashboard Klasterisasi Risiko Kredit

Contoh data anggota yang ditampilkan pada dashboard disajikan dalam bentuk tabel. Data tersebut dapat dilihat pada Tabel 1.

Tabel 1. Contoh Data Anggota pada Dashboard Streamlit

Nama Anggota	Status Pekerjaan	Besar Pinjaman	Angsuran	Tenor	Cluster	Risiko
Fitri Martasuli	Umum	Rp3.020.000	Rp335.000	1	2	Normal
Seniman/Sutjipto	Dinas	Rp2.400.000	Rp200.000	1	0	Tidak Berisiko
Misiyem	Pensiunan	Rp1.500.000	Rp125.000	1	1	Tidak Berisiko
Anis Sarnista	Dinas	Rp5.040.000	Rp420.000	1	0	Normal
Garry Painun	Dinas	Rp3.500.000	Rp375.000	1	0	Normal

4. SIMPULAN

Berdasarkan hasil analisis yang dilakukan, algoritma *K-Means Clustering* terbukti mampu mengelompokkan anggota KSP Sri Hadi Dharma ke dalam tiga *cluster* yang optimal. Penentuan jumlah *cluster* menggunakan metode *Elbow* dan *Davies–Bouldin Index* menunjukkan bahwa nilai $k = 3$ memberikan struktur pengelompokan yang paling stabil dan terpisah dengan baik. Setiap *cluster* yang terbentuk memiliki karakteristik berbeda pada variabel jumlah pinjaman, angsuran, pekerjaan, dan tenor, sehingga menghasilkan segmentasi anggota yang lebih objektif. Visualisasi berupa PCA, boxplot, dan distribusi risiko mengonfirmasi bahwa hasil klasterisasi mencerminkan pola pinjaman yang nyata di lapangan. Selain itu, implementasi sistem analisis berbasis Streamlit membuat seluruh proses evaluasi risiko lebih interaktif dan mudah digunakan, karena pengguna dapat melakukan pencarian anggota, melihat distribusi *cluster*, serta memahami status risiko tanpa mengeksekusi kode secara manual. Secara keseluruhan, penelitian ini menunjukkan bahwa *K-Means Clustering* efektif sebagai alat bantu pengambilan keputusan untuk penilaian risiko kredit pada koperasi.

5. SARAN

Penelitian ini masih memiliki ruang untuk pengembangan lebih lanjut. Variabel yang digunakan dapat diperluas, misalnya menambahkan informasi pendapatan anggota, riwayat keterlambatan pembayaran, atau frekuensi pengajuan pinjaman agar hasil klasterisasi lebih akurat. Penelitian selanjutnya juga dapat membandingkan *K-Means* dengan algoritma klasterisasi lainnya, seperti *DBSCAN* atau *Hierarchical Clustering*, guna menemukan metode yang paling cocok untuk karakteristik data koperasi. Selain itu, hasil *cluster* dapat diintegrasikan dalam model *supervised learning* sebagai fitur tambahan untuk meningkatkan akurasi prediksi risiko menggunakan algoritma seperti *Random Forest* atau *XGBoost*. Aplikasi Streamlit yang dibangun juga dapat dikembangkan lebih jauh menjadi sistem operasional koperasi dengan integrasi database *real-time*, autentifikasi pengguna, dan *dashboard* manajemen risiko. Terakhir, diperlukan evaluasi pengguna (*user evaluation*) bersama pihak koperasi untuk memastikan bahwa sistem ini benar-benar memenuhi kebutuhan operasional dan mampu mendukung proses pengambilan keputusan secara efektif.

6. DAFTAR PUSTAKA

- [1] F. F. ,. R. Nuril Ahsina, "CUSTOMER SEGMENTATION ANALYSIS BASED ON CREDIT USING K-MEANS CLUSTERING," *JITTER*, vol. 8, 2022.
- [2] H. H. M. Rahmat Hasibuan Budiansyah, "Penerapan Data Mining Clustering Dengan Menggunakan Algoritma K-Means Pada Data Nasabah Kredit Bermasalah PT. BPR Milala," *J-SISKO TECH EDISI JANUARI*, vol. 5, 2022.
- [3] P. A. Rizki Hesananda, "Customer Segmentation of Cash Management System Using K-Means Clustering," *Journal of Applied Research In Computer Science and Information Systems (JARCIS)*, vol. 2, 2024.
- [4] M. R. A. K. ,. A. N. ,. R. Hafid Ramadhan, "Comparison of Hierarchical, K-Means and DBSCAN Clustering Methods for Credit Card Customer Segmentation Analysis Based on Expenditure Level," *JAIC*, vol. 07, 2023.
- [5] G. W. ,. T. W. Dudi Irawan, "Penerapan Algoritma K-Means Clustering untuk Segmentasi Nasabah Bank.," *BIOS : Jurnal Teknologi Informasi Dan Rekayasa Komputer*, vol. 06, 2025.
- [6] M. S. R. Muhamarram Alfarisi, "IMPLEMENTASI K-MEANS CLUSTERING UNTUK MENGIDENTIFIKASI CALON NASABAH POTENSIAL PADA LEMBAGA KEUANGAN KECIL DAN MENENGAH," *Journal of Science and Social Research*, 2025.
- [7] F. S. I. S. Wilsen Grivin Mokodaser, "Unveiling Banking Customer Pattern Through K-Means and DBSCAN Cluster Evaluation," *CogITo Smart Journal*, vol. 11, 2025.
- [8] N. Widyaningrum, *SEGMENTASI NASABAH BANK MENGGUNAKAN ALGORITMA K-MEANS CLUSTERING DAN VISUALISASI DINAMIS DENGAN STREAMLIT*, Universitas PGRI Semarang, 2024.
- [9] V. I. ,. K. Adelita Syaharani, "ANALISIS CLUSTERING SEGMENTASI PELANGGAN PADA CV PRIMA JAYA UTAMA MENGGUNAKAN METODE K-MEANS," *JATI*, vol. 9, 2025.
- [10] M. S. H. Putri Khairani Ritonga, "Analisis Perbandingan Silhouette dengan Elbow pada Algoritma K-Means dan DBSCAN," *METIK Jurnal*, vol. 9, 2025.
- [11] S. F. F. ,. S. Satria Ardi Perdana, "ANALISIS SEGMENTASI PELANGGAN MENGGUNAKAN K-MEANS CLUSTERING STUDI KASUS APLIKASI ALFAGIFT," vol. 26, 2022.
- [12] F. E. N. S. Rifal Bayu Ardi, "ALGORITMA K-MEANS CLUSTERING UNTUK SEGMENTASI PELANGGAN," *INFOTECH Jurnal*, vol. 9, 2023.
- [13] G. G. Dodi Alexander Manalu, "IMPLEMENTASI METODE DATA MINING K-MEANS CLUSTERING TERHADAP," *INFOTECH:TECH: JOURNAL OF TECHNOLOGY INFORMATION*, 2022.

-
- [14] M. R. ,. A. Maulana Rumi Irwan Balo, "Customer Segmentation Using the K-Means Algorithm for Marketing Strategy Design: Case Study at the Icon Yasika Makassar," *International Journal of Innovative Science and Research Technology* , vol. 10, 2025.
 - [15] I. I. K. D. T. A. Y. Nurlatifa, "IMPLEMENTASI METODE ELBOW UNTUK MENENTUKAN JUMLAH CLUSTER OPTIMAL PADA ALGORITMA K-MEANS," 2024.
 - [16] G. W. ,. T. W. Dudi Irawan, "Penerapan Algoritma K-Means Clustering untuk Segmentasi Nasabah Bank," vol. 6, 2025.