

Penerapan *Principal Component Analysis (PCA)* dan *K-Medoids Clustering* untuk Pengelompokan Data Inventaris Mesin

Ananda Nabila Azizah^{1*}, Dina Tri Utari¹, Purnama Akbar¹

¹ Jurusan Statistika, Universitas Islam Indonesia, Jl. Kaliurang Km. 14,5. Krawitani, Umbulmartani, Kec. Ngemplak, Kabupaten Sleman, Daerah Istimewa Yogyakarta 55584, Indonesia.

*Corresponding Author: 22611069@students.uii.ac.id



P-ISSN: 2986-4178
E-ISSN: 2988-4004

Riwayat Artikel

Dikirim: 19 Desember 2025

Direvisi: 09 Januari 2026

Diterima: 09 Januari 2026

ABSTRAK

Pengelompokan adalah proses mengklaster sebuah kumpulan data menjadi dua atau lebih kelompok sehingga titik-titik data dalam satu kelompok memiliki kemiripan yang lebih tinggi dibandingkan dengan titik data di kelompok lain. Pengelompokan menjadi proses penting untuk membantu PT. XYZ mengelola *management assets* secara lebih efisien dengan mengklaster data mesin menjadi beberapa kelompok berdasarkan kemiripan karakteristiknya. Dalam pengelompokan data mesin, keberadaan *outlier* dan multikolinieritas menjadi tantangan yang dapat memengaruhi hasil pengelompokan dan interpretasi data. Penelitian ini menggunakan algoritma *K-Medoids Clustering* karena lebih *robust* terhadap *outlier* dibandingkan *K-Means Clustering*. Untuk mengatasi multikolinieritas, diterapkan metode reduksi dimensi *Principal Component Analysis (PCA)*, yaitu teknik statistik multivariat yang mengubah variabel asli menjadi komponen utama yang lebih sedikit namun tetap mewakili informasi data secara optimal. Penentuan jumlah klaster (*k*) dilakukan dengan metode *silhouette* yang menghasilkan skor 0,70, menandakan tiga kelompok sebagai jumlah optimal. Hasil pengelompokan membagi jenis mesin menjadi tiga kelompok, yaitu kelompok 1 berisi 10 jenis mesin, kelompok 2 berisi 43 jenis mesin, dan kelompok 3 berisi 1 jenis mesin. Harapannya penelitian ini dapat menjadi dasar bagi PT. XYZ untuk melakukan evaluasi kembali terkait ketersediaan dan pemanfaatan jenis mesin, sehingga perusahaan dapat mempertimbangkan aspek persediaan dan pemilihan mesin secara lebih optimal guna menekan total biaya persediaan dan total biaya penggunaan mesin.

Kata Kunci: PCA, Mesin, *K-Medoids Clustering*

ABSTRACT

Clustering is the process of grouping a dataset into two or more clusters, where the data points within each cluster are more similar to each other than to data points in other clusters. PT. XYZ can improve its asset management efficiency by clustering machine data into groups based on their shared characteristics. In the process of agglomerating machine data, the presence of outliers and multicollinearity pose challenges that have the potential to affect the outcomes of the agglomeration process as well as the interpretation of the data. This study uses the K-Medoids clustering algorithm because it is more robust to outliers than the K-Means clustering algorithm. To overcome multicollinearity, Principal Component Analysis (PCA), a multivariate statistical technique that transforms original variables into fewer principal components while still representing the data optimally, is applied. The number of clusters (k) is determined using the silhouette method, which produces a score of 0.70. This indicates that three groups are the optimal number. The clustering results divide the types of machines into three groups: group 1 contains ten types of machines; group 2, forty-three types; and group 3, one type. Research findings are expected to provide PT. XYZ with a foundation for re-evaluating the availability and utilization of machine types. This will allow the company to optimize its inventory and machine selection, leading to a reduction in total inventory and machine usage costs.

Keywords: PCA, Machine, K-Medoids Clustering

1. Pendahuluan

Pengelompokan adalah proses mengklaster sebuah kumpulan data menjadi dua atau lebih kelompok sehingga titik-titik data yang termasuk dalam kelompok lebih mirip satu sama lain dibandingkan dengan kelompok yang berbeda [1]. *K-Medoids Clustering* merupakan algoritma yang membentuk kelompok dengan menggunakan titik pusat yang disebut *medoids* sebagai representasi tiap kelompok [2]. *Medoids* didefinisikan sebagai objek dalam kelompok dengan rata-rata ketidaksamaan paling minimal diantara semua objek dalam suatu kelompok [3]. Kelebihan dari algoritma *K-Medoids Clustering* adalah lebih stabil terhadap data *outlier* atau pencilan dibandingkan metode *K-Means Clustering* [4], [5], [6].

Algoritma *K-Medoids Clustering* dapat diterapkan dalam berbagai industri misalnya pada industri manufaktur, digunakan untuk mengelompokkan data inventaris mesin [1]. Data inventaris merupakan data yang berisi daftar semua fasilitas atau barang yang ada pada sebuah instansi maupun perusahaan [7]. Dengan demikian data inventaris mesin merupakan daftar catatan mesin pada PT. XYZ. Seringnya data inventaris mesin berbentuk kompleks sehingga terjadi adanya multikolinieritas antar variabel. Oleh karena itu, reduksi dimensi data dibutuhkan sebelum masuk pada tahapan pengelompokan [8]. *Principal Component Analysis* (PCA) menjadi salah satu metode reduksi dimensi data sebelum masuk dalam tahap pengelompokan.

PCA adalah suatu teknik statistik multivariat yang secara *linear* mengubah bentuk sekumpulan variabel asli menjadi komponen variabel yang lebih kecil dan dapat mewakili informasi dari kumpulan variabel asli [9]. Tujuan utamanya adalah untuk menjelaskan sebanyak mungkin variabel data asli dengan sedikit mungkin komponen utama [10]. Selain mereduksi dimensi pada variabel, PCA juga dapat digunakan untuk meningkatkan keakuriasan dalam proses pengelompokan [11].

Penerapan PCA dan algoritma *K-Medoids Clustering* telah dilakukan oleh beberapa peneliti, diantaranya oleh [12] pada tahun 2023 untuk pengelompokan kabupaten/kota di pulau Kalimantan berdasarkan indikator kemiskinan tahun 2021 dengan menggunakan *silhouette coefficient* sebagai ukuran kualitas kekuatan kelompok, oleh [13] pada tahun 2024 dengan judul pengelompokan kecamatan di Daerah Istimewa Yogyakarta berdasarkan jumlah pengguna alat kontrasepsi tahun 2022 dengan *K-Medoids Cluster*. Selain pada penerapan kedua metode tersebut, penelitian terkait pengelompokan data inventaris menggunakan *K-Medoids Clustering* juga telah dilakukan oleh [1] ditahun 2023. Dari sekian banyaknya penelitian terkait penerapan PCA dan algoritma *K-Medoids Clustering*, penerapannya pada sektor industri manufaktur terutama pada data inventaris mesin masih sedikit ditemukan. Hal tersebut merepresentasikan salah satu bentuk inovasi yang dikembangkan oleh peneliti dalam penelitian ini.

Penelitian ini bertujuan untuk mengidentifikasi jenis mesin dalam kategori rendah, sedang, dan tinggi berdasarkan pencatatan inventarisnya, untuk mengurangi risiko death stock yang merugikan PT. XYZ. *Death stock terjadi karena barang menumpuk terlalu lama, kadaluarsa, atau rusak* [16]. Diharapkan, hasil penelitian ini membantu PT. XYZ mengevaluasi ketersediaan dan pemanfaatan mesin secara optimal, guna menekan biaya persediaan dan penggunaan.

2. Metodologi Penelitian

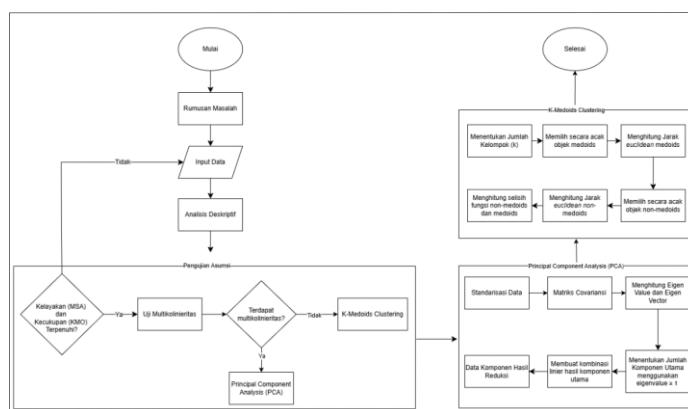
Tahapan metodologi penelitian akan menjelaskan tentang data, tahapan, dan metode yang digunakan pada penelitian ini.

2.1 Data dan Variabel Penelitian

Pada penelitian ini digunakan data inventaris mesin sebanyak 54 baris, yang bersumber dari PT. XYZ dengan lima variabel, yaitu jenis mesin (kategorik), total penggunaan (unit), total persediaan (unit), total biaya penggunaan (Rp/unit), dan total biaya persediaan (Rp/unit).

2.2 Tahapan Penelitian

Penelitian ini terdiri atas beberapa tahapan yang dijelaskan menggunakan diagram alir pada **Gambar 1**. Berdasarkan diagram alir pada **Gambar 1**, tahapan pada penelitian ini adalah sebagai berikut:



Gambar 1. Diagram Alir Analisis

2.2.1. Rumusan Masalah

Penelitian ini berfokus pada sejauh mana penerapan metode *Principal Component Analysis* (PCA) dan algoritma *K-Medoids Clustering* efektif dalam mereduksi dimensi dan mengelompokkan data inventaris mesin.

2.2.2. Input Data

Data inventaris mesin sebanyak 54 jenis mesin di-inputkan pada *software Rstudio* untuk dilakukan analisis sesuai dengan metode yang digunakan dalam penelitian ini.

2.2.3. Analisis Deskriptif

Statistika deskriptif bertujuan mendeskripsikan data sampel untuk memberikan informasi yang berguna bagi pembacanya [17]. Pada tahap ini, data diolah untuk dibuat dalam visualisasi yang memudahkan peneliti melihat distribusi dari data.

2.2.4. Pengujian Asumsi

Terdapat beberapa pengujian asumsi yang harus dipenuhi pada penelitian ini, diantaranya:

1. Uji kelayakan data, bertujuan untuk memastikan bahwa data memenuhi kriteria validitas dan reliabilitas. Hal ini ditunjukkan dengan nilai MSA (*Measure of Sampling Adequacy*) $> 0,5$.

$$MSA = \frac{\sum_{i=1}^p r_{ij}^2}{\sum_{i=1}^p r_{ij}^2 + \sum_{i=1}^p a_{ij}^2} \quad (1)$$

dengan: r_{ij}^2 : koefisien korelasi variabel i dan j , a_{ij}^2 : koefisien korelasi parsial variabel i dan j , dan p : jumlah variabel dalam model [18].

2. Uji kecukupan data, bertujuan untuk memastikan bahwa data yang diperoleh mewakili populasi dengan baik. Jika nilai KMO (*Kaiser Meyer Olkin Measure of Sampling Adequacy*) $> 0,5$, data dianggap cukup untuk analisis lebih lanjut.

$$KMO = \frac{\sum_{i=1}^p \sum_{j=1}^p r_{ij}^2}{\sum_{i=1}^p \sum_{j=1}^p r_{ij}^2 + \sum_{i=1}^p \sum_{j=1}^p a_{ij}^2} \quad (2)$$

dengan: r_{ij}^2 : koefisien korelasi variabel i dan j , a_{ij}^2 : koefisien korelasi parsial variabel i dan j , dan p : jumlah variabel dalam model [18].

3. Uji multikolinieritas, dilakukan dengan menggunakan *Bartlett's Test of Sphericity* dengan H_0 : tidak terdapat korelasi antar variabel, sedangkan H_1 : terdapat minimal satu korelasi antar variabel.

2.2.5. Principal Component Analysis (PCA)

Dengan sifat PCA yang saling *orthogonal* (saling bebas) diharapkan setiap variabel saling independen dan tidak saling berkorelasi. Adapun, dalam PCA terdapat beberapa langkah analisis, diantaranya:

1. Standarisasi data agar skala data menjadi sama menggunakan *Z-Score*.

$$z = \frac{x_i - \mu}{\sigma} \quad (3)$$

dengan: z : nilai standar *z-score*, x_i : data observasi ke- i , μ : rata-rata setiap variabel, dan σ : standar deviasi setiap variabel [12].

2. Menghitung matriks kovarian dengan tujuan menentukan korelasi setiap variabel.
3. Menghitung *eigenvalue* dan *eigenvector*, untuk mendapatkan informasi terkait struktur data dan variabilitas yang dapat dijelaskan oleh komponen utama.
 - *eigenvalue* [18]

$$|\lambda I - R| = 0 \quad (4)$$

- *eigenvector* [12]

$$\det|\lambda I - R| = 0 \quad (5)$$

dengan: I : matriks identitas dan λ : nilai eigenvalue.

4. Menentukan jumlah *principal component* yang mungkin terbentuk dengan melihat nilai *eigen* yang ≥ 1 .
5. Membentuk variabel baru hasil reduksi *principal component*.

2.2.6. K-Medoids Clustering

K-Medoids Clustering atau *Partitioning Around Medoids* (PAM) merupakan metode berbasis pertisi dalam mengelompokkan objek-objek menjadi sejumlah kelompok. Adapun, dalam *K-Medoids Clustering* terdapat beberapa tahapan analisis, diantaranya:

1. Penentuan banyaknya kelompok (k) menggunakan metode *silhouette*. Metode *silhouette* menggabungkan *cohesion* untuk mengukur kedekatan antar objek dalam kelompok dan *separation* untuk mengukur jarak antar kelompok [18].
 - Menghitung rata-rata jarak objek dengan seluruh objek yang berada di dalam satu kelompok.
 - Menghitung rata-rata jarak objek dengan seluruh objek yang berada dalam kelompok lain dan mengambil nilai paling minimum menggunakan persamaan:
 - Menghitung nilai *silhouette coefficient*. Nilai ini terletak pada rentang -1 sampai 1.
2. Memilih secara acak pada objek sebanyak k sebagai objek representatif *medoids*.
3. Menghitung jarak *euclidean* antara data dengan pusat cluster dengan rumus yang ada pada persamaan 9:

$$d_{ij} = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad (6)$$

dengan: d_{ij} : jarak data dan titik pusat kelompok, x_{ik}, x_{jk} : perhitungan jarak data ke- i dan ke- j , n : jumlah atribut yang digunakan [12].

4. Memilih secara acak objek yang bukan *medoids*.
5. Menghitung jarak objek pada masing-masing kelompok dengan kandidat *non-medoids*.
6. Menghitung selisih dari fungsi objektif. Jika $S < 0$ maka kandidat *medoid* baru diterima sebagai pembaruan *medoid* dan dilakukan pengulangan dari langkah 3.
7. Lakukan langkah 1 sampai 6 hingga *medoids* tidak mengalami perubahan.

3. Hasil dan Pembahasan

Setelah dilakukan adanya tahap analisis, maka didapatkan hasil dan pembahasan. Adapun hasil dan pembahasannya adalah sebagai berikut.

3.1. Analisis Deskriptif

Analisis deskriptif pada tahapan ini bertujuan untuk mengetahui sebaran data secara umum melalui beberapa visualisasi data inventaris mesin pada PT. XYZ.

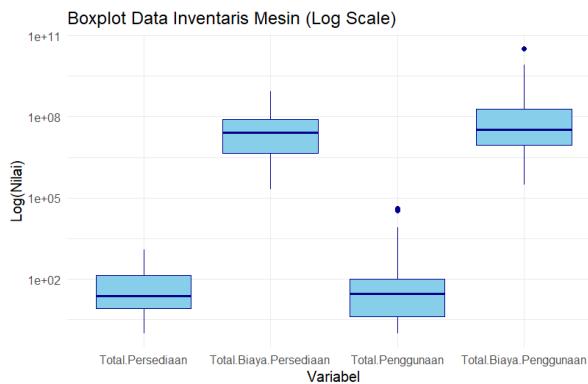


Gambar 2. Barplot Perbandingan Total Penggunaan dan Persediaan

Visualisasi pada **Gambar 2** menunjukkan lima mesin dengan penggunaan tertinggi. Namun, persedianya jauh lebih rendah dibandingkan penggunaannya, yang dapat

memperpanjang *lead time*. Sebelum analisis, standarisasi data perlu dilakukan, dan selain *barplot*, *boxplot* juga berguna untuk melihat sebaran data inventaris mesin.

Pada **Gambar 3**, variabel diubah ke skala logaritma untuk memperkecil perbedaan skala, sehingga mempermudah visualisasi dalam mendekripsi *outlier*. Pengubahan pada skala logaritma hanya digunakan pada proses visualisasi data saja. Terlihat pada boxplot bahwa keempat variabel memiliki distribusi tidak simetris, yang bisa memengaruhi analisis. Oleh karena itu, pengecekan *outlier* penting, dan *K-Medoids Clustering* dipilih karena efektif menangani data dengan *outlier*.



Gambar 3. Boxplot Data Inventaris Mesin

3.2. Uji Asumsi

Uji asumsi harus terpenuhi sebelum dilakukan adanya pengelompokan diantaranya:

3.2.1 Uji Kelayakan dan Kecukupan Data

Telah didapatkan hasil uji kecukupan data dengan metode *Kaiser-Meyer-Olkin* (KMO) dan uji kelayakan model dengan menggunakan kriteria *Measure of Sampling Adequacy* (MSA).

Tabel 1. Uji Kelayakan dan Kecukupan Data

Variabel	KMO	MSA
Total Persediaan		0.52
Biaya Total Persediaan		0.59
Total Penggunaan	0.53	0.53
Biaya Total Penggunaan		0.52

Berdasarkan **Tabel 1** dapat dilihat bahwa nilai $KMO > 0.5$ dan $MSA > 0.5$ maka data yang ada mencukupi dan layak untuk dianalisis.

3.2.2 Uji Multikolinieritas

Pengujian korelasi antar variabel menggunakan metode *bartlett's test of sphericity* sebagai berikut:

(i). Hipotesis

$H_0: \rho_1 = \rho_2 = \rho_3 = \rho_4$ (Tidak terdapat korelasi dari semua variabel)

$H_1: \exists \rho_i \neq \rho_p ; i,p=1,2,3,4$ (Paling sedikit terdapat satu korelasi antar variabel)

(ii). Tingkat Signifikansi

$\alpha = 5\%$

(iii). Daerah Kritis

Tolak H_0 jika $pvalue < 0.05$ atau $\chi^2 = - \left| (N - 1) - \frac{(2p+5)}{6} |R| \right| > \chi^2_{tabel(p-1,\alpha)}$

(iv). Statistik Uji dan Keputusan

Tabel 2. Uji Multikolinieritas

Statistik Uji	Hasil	Keterangan	Pembanding	Keputusan
pvalue	$2.22e^{-16}$	<	0.05	Tolak H_0
χ^2	97.408	>	7.815	Tolak H_0

(v). Kesimpulan

Dengan menggunakan tingkat kepercayaan 95% data yang ada mendukung untuk tolak H_0 . Artinya, paling sedikit terdapat satu korelasi antar variabel. Untuk dilakukan analisis *K-Medoids Clustering* diperlukan reduksi dimensi PCA agar tidak terjadi adanya multikolinieritas antar variabel.

3.3 Principal Component Analysis (PCA)

PCA bertujuan untuk mempertahankan sebanyak mungkin variasi dalam data asli. Adapun beberapa tahapan PCA adalah sebagai berikut:

3.3.1 Standarisasi Data

Data inventaris mesin yang digunakan memiliki skala yang berbeda. Oleh karena itu, dilakukan standarisasi untuk menyamakan skala variabel dengan menggunakan nilai Z-Score.

Tabel 3. Data Standarisasi

Jenis Mesin	Total Persediaan	Total Biaya Persediaan	Total Penggunaan	Total Biaya Penggunaan
Line Boring Type 1	4.291117	1.56139151	-0.197032650	-0.100712115
Angle Grinder Type 3	3.86435	-0.02239180	-0.165495333	-190777126
:	:	:	:	:
Engine	$-5.484309e^{-1}$	-0.54263284	-0.252066903	-0.212694508

3.3.2 Pembentukan Komponen Utama

Menggunakan nilai *eigenvector* dan *eigenvalue*, didapatkan hasil pembentukan komponen utama *Principal Component Analysis* (PCA) pada **Tabel 4**. Nilai *eigen* yang > 1 terdapat pada komponen 1 dan 2. Sehingga banyaknya komponen yang terbentuk sebanyak 2. Komponen 2 memiliki *eigenvalue* sebesar 1.3305261 dengan kumulatif varians sebesar 86.05297%, yang artinya komponen 2 mampu menjelaskan variabel sebesar 86.05297%.

Tabel 4. Pembentukan Komponen Utama

Komponen	Eigenvalues		
	Total	Varians(%)	Kumulatif(%)
1	2.1115925	0.5278981	0.5278981
2	1.3305261	0.3326315	0.8605297
3	0.4384051	0.1096013	0.9701309
4	0.1194763	0.0298690	1.0000000

Sementara nilai kombinasi *linear* yang terbentuk pada komponen 1 dan 2 adalah sebagai berikut:

$$\text{Comp. 1} = 0.3185Z_1 + 0.425Z_2 + 0.6026Z_3 + 0.596Z_4 \quad (7)$$

$$\text{Comp. 2} = 0.663Z_1 + 0.539Z_2 - 0.359Z_3 - 0.376Z_4 \quad (8)$$

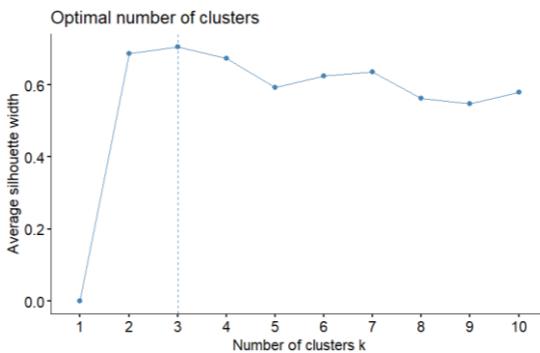
Data hasil reduksi selanjutnya bisa digunakan untuk pengelompokan menggunakan algoritma *K-Medoids Clustering*.

3.4 K-Medoids Clustering

Setelah uji asumsi terpenuhi langkah berikutnya adalah melakukan analisis pengelompokan dengan metode *K-Medoids*. Hasil analisisnya adalah sebagai berikut:

3.4.1 Penentuan Banyaknya Kelompok

Pada tahapan ini digunakan metode *silhouette* untuk menentukan banyaknya kelompok.



Gambar 4. Penentuan Jumlah k

Gambar 4, menunjukkan nilai *average silhouette width* untuk berbagai jumlah kelompok (*k*) pada proses pemilihan jumlah kelompok optimal. Terlihat bahwa nilai *silhouette* mencapai puncaknya pada *k*=3 dengan nilai sekitar 0.7.

3.4.2 Penerapan Pengelompokan K-Medoids

Pembagian jumlah kelompok dilakukan dengan membagi jumlah kelompok sebanyak 3 sesuai dengan hasil penentuan jumlah kelompok. Hasil dari pembagian 54 jenis mesin berdasarkan reduksi dimensi PCA terdapat **Tabel 5**.

Tabel 5. Anggota Kelompok

Kelompok	Anggota
1	Line Boring Type 1, Angle Grinder Type 3, Angle Grinder Type 1, Line Boring Type 2, Angle Grinder Type 2, Sand Blasting, Crane Type 1, Air Compressor Type 2, Heat Treatment, Metal Spray Type 1
2	Huckbolt, Welding Machine Type 4, Angle Grinder Type 4, Welding Parts Type 4, Gouging Torch, Genset, Epoxy Linner, Airless Painter, Cutting Torch, Electrical Parts Type 2, Crane, Magnetic Drill Type 3, Air Dryer, Crane Parts Type 2, Painter, Electrical Parts Type 1, Crane Parts Type 1, Press Brake Type 1, Welding Parts Type 3, Welding Parts Type 2, Timer Controller, Electrical Parts Type 3, Welding Parts Type 1, Plasma Cutting Type 1, Magnetic Drill Type 2, Engine Type Type 2, Kobe, Welding Parts Type 5, Air Compressor Type 1, Electrical Socket, Diesel Welder, Metal Spray Type 2, Hydraulic Jack Type 1, Air Hose, Honing Machine, Air Conditioner Type 2, Magnetic Drill Type 1, Measurement Tool, Crane Type 3, Crane Type 2, Air Conditioner Type 1, Custom, Engine
3	Welding Machine Type 1

Setelah diketahui anggota dari masing-masing kelompok, dilakukan profilisasi dari masing-masing kelompok untuk diketahui karakteristik dari kelompoknya. Untuk memudahkan dalam mengetahui karakteristik dari masing-masing kelompok, peneliti menyajikan hasil profilisasinya dalam bentuk *fishbone diagram* seperti pada Gambar 5.



Gambar 5. Fishbone Diagram

Berdasarkan gambar *fishbone diagram* tersebut, terlihat bahwa kelompok 3 menunjukkan mesin yang sangat sering digunakan sehingga menimbulkan biaya tinggi, meskipun persediaannya tidak terlalu banyak, sehingga perlu perhatian khusus dalam hal efisiensi biaya dan ketersediaan supaya tidak mempengaruhi lamanya *lead time* perusahaan. Kelompok 1 memiliki jumlah anggota lebih sedikit, yaitu sebanyak 10 anggota yang mengindikasikan adanya mesin dengan karakteristik tertentu yang berbeda dari kelompok mayoritas, namun masih memiliki kemiripan satu sama lain. Kelompok 2 merupakan kelompok terbesar, yang menunjukkan bahwa sebagian besar mesin memiliki karakteristik yang relatif homogen. Kelompok ini dapat dianggap sebagai kelompok mesin standar atau dominan. Di sisi lain, kelompok 3 dapat dianggap sebagai *outlier cluster*. Kelompok 3 yang hanya terdiri dari satu anggota memiliki karakteristik yang berbeda secara signifikan dibandingkan mesin lainnya. Perbedaan ini menyebabkan algoritma pengelompokan menempatkannya pada kluster tersendiri.

4. Kesimpulan

Penelitian ini memiliki salah satu tahapan pengujian asumsi yang tidak terpenuhi sebelum masuk pada tahap pengelompokan, yaitu asumsi multikolinieritas. Untuk itu perlu dilakukannya tahapan reduksi dimensi menggunakan metode PCA yang menghasilkan terbentuknya 2 komponen utama. Sementara itu, dihasilkan jumlah kelompok (k) sebanyak 3 berdasarkan metode *silhouette* yang mendapatkan nilai *silhouette coefficient* sebesar 0.70 sehingga menghasilkan kelompok 1 yang beranggotakan 10, dimana kelompok 1 merepresentasikan jenis mesin dengan persediaan tinggi namun tingkat penggunaan dan biaya yang sedang, kelompok 2 beranggotakan 43 dengan mesin yang memiliki nilai rendah pada semua variabel, sementara kelompok 3 hanya memiliki 1 anggota mesin yang sangat sering digunakan sehingga menimbulkan biaya tinggi.

5. Daftar Pustaka

- [1] H. A. Mubarak, “Penerapan Algoritma K-Means dan K-Medoids dalam Pengelompokan Data Inventaris Rig: Application Of K-Means And K-Medoid Algorithm In Rig Inventory Data Grouping,” *Indones. J. Inform. Res. Softw. Eng. IJIRSE*, vol. 3, no. 2, Art. no. 2, Sept. 2023, doi: 10.57152/ijirse.v3i2.965.
- [2] S. Nadilla, W. Syahrifa, F. Razi, R. Maulana, and M. Ula, “Analisis Perbandingan Kinerja Algoritma K-Means Dan Kmedoids Untuk Klasterisasi Produksi Padi Di Pulau Sumatera,” *SENASTIKA Univ. Malikussaleh*.
- [3] S. Maryani and S. Darwis, “Klasterisasi Kerusakan Bearing Menggunakan Metode K-Medoids,” *Bdg. Conf. Ser. Stat.*, vol. 5, no. 1, Art. no. 1, Feb. 2025, doi: 10.29313/bcss.v5i1.17827.
- [4] A. Meiriza, E. Ali, Rahmiati, and Agustin, “Perbandingan Algoritma K-Means dan K-Medoids untuk Pengelompokan Program BPJS Ketenagakerjaan,” *Indones. J. Comput. Sci.*, vol. 12, no. 2, Art. no. 2, Apr. 2023, doi: 10.33022/ijcs.v12i2.3184.
- [5] S. Sugiono, N. A. Wahyuni, and L. J. Hendriani, “Pengelompokan Perusahaan Berdasarkan Statistik Penelitian dan Pengembangan Melalui Metode K-Medoids,” *JOINS J. Inf. Syst.*, vol. 7, no. 1, pp. 41–52, May 2022, doi: 10.33633/joins.v7i1.5935.
- [6] J. Heidari, N. Daneshpour, and A. Zangeneh, “A novel K-means and K-medoids algorithms for clustering non-spherical-shape clusters non-sensitive to outliers,” *Pattern Recognit.*, vol. 155, p. 110639, Nov. 2024, doi: 10.1016/j.patcog.2024.110639.
- [7] A. A. Aqham, E. Siswanto, and D. Kurniawan, “Metode Enterprise Architecture Planning Dalam Sistem Informasi Pengelolaan Data Inventaris,” *J. Teknol. Inf. DAN Komun.*, vol. 14, no. 1, pp. 201–208, Mar. 2023, doi: 10.51903/jtikp.v14i1.555.
- [8] R. Afifa, M. I. Mazdadi, T. H. Saragih, F. Indriani, and M. Muliadi, “Implementasi Principal Component Analysis (PCA) dan Gap Statistic untuk Clustering Kanker Payudara pada

- Algoritma K-Means,” *Sist. J. Sist. Inf.*, vol. 13, no. 5, Art. no. 5, Sept. 2024, doi: 10.32520/stmsi.v13i5.4015.
- [9] F. I. Muttaqin, Z. R. Ramadani, R. Yotenga, and Suparna, “Implementasi Algoritma K-Means dalam Analisis Cluster Usaha Pertanian Perorangan di Provinsi D. I Yogyakarta Tahun 2023: Implementasi Algoritma K-Means dalam Analisis Cluster Usaha Pertanian Perorangan di Provinsi D. I Yogyakarta Tahun 2023,” *Emerg. Stat. Data Sci. J.*, vol. 3, no. 1, Art. no. 1, Jan. 2025.
- [10] “Analisis Reduksi Dimensi Produktivitas Jagung di Provinsi-Provinsi Indonesia Menggunakan PCA | Interdisciplinary Explorations in Research Journal.” Accessed: Apr. 17, 2025. [Online]. Available: <https://shariajournal.com/index.php/IERJ/article/view/778>
- [11] S. Soesmono, R. Pertiwi, B. Saputri, N. Putri, and E. Widodo, “Pengelompokan Provinsi di Indonesia Berdasarkan Tingkat Pengangguran Tahun 2023 Menggunakan K-Medoids : Pengelompokan Provinsi di Indonesia Berdasarkan Tingkat Pengangguran Tahun 2023 Menggunakan K-Medoids,” *Emerg. Stat. Data Sci. J.*, vol. 3, no. 1, Art. no. 1, Jan. 2025.
- [12] M. Yafi, R. Goejantoro, and A. T. R. Dani, “Pengelompokan Algoritma K-Medoids Dengan Principal Component Analysis (PCA) (Studi Kasus : Kabupaten/Kota di Pulau Kalimantan Berdasarkan Indikator Kemiskinan Tahun 2021),” *Pros. Semin. Nas. Mat. Dan Stat.*, vol. 3, no. 01, Art. no. 01, Aug. 2023.
- [13] S. Maharani and R. Yotenga, “Pengelompokan Kecamatan di Daerah Istimewa Yogyakarta berdasarkan Jumlah Pengguna Alat Kontrasepsi Tahun 2022 dengan K-Medoids Cluster: Pengelompokan Kecamatan di Daerah Istimewa Yogyakarta berdasarkan Jumlah Pengguna Alat Kontrasepsi Tahun 2022 dengan K-Medoids Cluster,” *Emerg. Stat. Data Sci. J.*, vol. 2, no. 2, Art. no. 2, June 2024, doi: 10.20885/esds.vol2.iss.2.art16.
- [14] “Penerapan Biplot Pca Dan K-Medoids Cluster Pada Segmentasi Wilayah Berdasarkan Potensi Kelapa Sawit.” Accessed: Apr. 22, 2025. [Online]. Available: <https://bpsjambi.id/median/index.php/median/article/view/74/73>
- [15] G. R. Suraya and A. W. Wijayanto, “Comparison of Hierarchical Clustering, K-Means, K-Medoids, and Fuzzy C-Means Methods in Grouping Provinces in Indonesia according to the Special Index for Handling Stunting: Perbandingan Metode Hierarchical Clustering, K-Means, K-Medoids, dan Fuzzy C-Means dalam Pengelompokan Provinsi di Indonesia Menurut Indeks Khusus Penanganan Stunting,” *Indones. J. Stat. Its Appl.*, vol. 6, no. 2, pp. 180–201, Aug. 2022, doi: 10.29244/ijsa.v6i2p180-201.
- [16] “Analisis Management Inventory Untuk Menghindari Death Stock Product Di Tb. Sinar Baru.” Accessed: Apr. 17, 2025. [Online]. Available: <https://journal.utnd.ac.id/index.php/value/article/view/631/359>
- [17] T. A. Nengsih, B. Arisha, and Y. Safitri, *Statistika Deskriptif dengan Program R*. PT. Sonpedia Publishing Indonesia.
- [18] I. A. Rosyada and D. T. Utari, “Penerapan Principal Component Analysis untuk Reduksi Variabel pada Algoritma K-Means Clustering,” *Jambura J. Probab. Stat.*, vol. 5, no. 1, Art. no. 1, June 2024, doi: 10.37905/jjps.v5i1.18733.