

ALGORITMA K-MEANS UNTUK PENINGKATAN MODEL SEGMENTASI DATA ASET TETAP PADA PT. XYZ

Dwi Prayogo, Rudi Kurniawan, Yudhistira Arie Wijaya , Umi Hayati

STMIK IKMI Cirebon Jl. Perjuangan No. 10B Majasem Kota Cirebon

Received: 2 Januari 2025

Accepted: 14 Januari 2025

Published: 20 Januari 2025

Keywords:

algoritma K-Means;
Peningkatan Model;
Segmentasi Data; Data Aset
Tetap; Knowledge Discovery
in Database (KDD).

Correspondent Email:

mail4yogo@gmail.com

Abstrak. Pengelolaan aset tetap merupakan salah satu elemen penting dalam operasional suatu Organisasi ataupun perusahaan, termasuk di PT. XYZ. Namun demikian, metodologi manual sering menimbulkan tantangan seperti inefisiensi, kesalahan klasifikasi, dan kekurangan analitis yang menghambat dalam pengambilan keputusan yang sangat strategis. Penelitian ini berusaha untuk menerapkan algoritma K-Means dalam peningkatan model segmentasi data aset tetap, dengan penekanan terkonsentrasi pada pengoptimalan parameter nilai K, yang bertujuan meningkatkan ketepatan hasil pengelompokan. Berbagai studi sebelumnya, termasuk yang dilakukan oleh Yuan & Yang (2019), Ahmed et al. (2020), dan Ikotun et al. (2023), menunjukkan bahwa algoritma K-Means telah digunakan secara luas, namun, masih ada kekurangan dalam pengoptimalan parameter dan penerapannya pada data aset tetap. Penelitian ini mengadopsi metodologi eksperimental yang memanfaatkan data aset tetap dari PT. XYZ sebagai objek penelitian. Algoritma K-Means diterapkan untuk mengkategorikan data berdasarkan karakteristik tertentu, seperti kategori aset, umur ekonomis, kondisi dan tingkat pemanfaatan. Hasil penelitian menunjukkan bahwa pendekatan ini mampu meningkatkan efisiensi proses pengelolaan aset tetap yang diperoleh nilai Davies Bouldin Index (DBI) = 0,395 melalui pengujian parameter dengan nilai K Optimal = 4. Dengan demikian, penelitian ini memberikan kontribusi teoretis dalam pengembangan algoritma K-Means dan manfaat praktis bagi perusahaan dalam pengelolaan aset tetap mereka.

Abstract. A Fixed asset management is one of the important elements in the operations of an Organization or company, including at PT XYZ. However, manual methodologies often pose challenges such as inefficiency, misclassification, and analytical deficiencies that hinder highly strategic decision-making. This research seeks to apply the K-Means algorithm in improving the fixed asset data segmentation model, with the emphasis concentrated on optimizing the K value parameter, which aims to improve the accuracy of the clustering results. Various previous studies, including those conducted by Yuan & Yang (2019), Ahmed et al. (2020), and Ikotun et al. (2023), show that the K-Means algorithm has been widely used, however, there are still shortcomings in parameter optimization and its application to fixed asset data. This research adopts an experimental methodology that utilizes fixed asset data of PT of XYZ as the research object. K-Means algorithm is applied to categorize the data based on certain characteristics, such as asset category, economic age, condition and utilization rate. The results show that this approach is able to improve the efficiency of the fixed asset management process obtained by the value of Davies Bouldin Index (DBI) = 0.395 through parameter testing with the Optimal K value = 4. Thus,

this research provides theoretical contributions in the development of the K-Means algorithm and practical benefits for companies in the management of their fixed assets.

1. PENDAHULUAN

Segmentasi merupakan teknik analisis data yang sangat penting dalam berbagai konteks, yang berfungsi untuk mengelompokkan data ke dalam kategori yang lebih kecil dan homogen [1], yang pada gilirannya membantu dalam mengidentifikasi pola, mengurangi redundansi, dan meningkatkan efisiensi pengambilan keputusan[2]. Namun, segmentasi yang dilakukan secara manual sering kali memakan waktu, membutuhkan sumber daya yang besar, dan rentan terhadap kesalahan manusia[3].

Salah satu pendekatan yang banyak digunakan adalah segmentasi data, yang bertujuan untuk mengelompokkan data ke dalam kategori tertentu berdasarkan karakteristiknya[4]. Penelitian ini bertujuan untuk meningkatkan model segmentasi data aset tetap pada PT. XYZ dengan menggunakan algoritma K-Means untuk menghasilkan pengelompokan yang lebih terstruktur. Salah satu tujuan utama adalah memberikan panduan bagi manajemen perusahaan dalam pengambilan keputusan strategis berdasarkan hasil segmentasi yang lebih informatif dan mengidentifikasi pola-pola signifikan dalam data aset tetap, yang dapat mendukung efisiensi operasional perusahaan[5]. Penelitian ini diharapkan memberikan kontribusi penting pada pengelolaan aset tetap melalui penerapan algoritma K-Means, yang dapat meningkatkan akurasi dan efisiensi segmentasi data dan dapat digunakan oleh praktisi untuk memperbaiki proses pengelolaan aset tetap di perusahaan, sehingga mendukung pengambilan keputusan yang lebih strategis serta memberikan wawasan baru bagi peneliti tentang bagaimana algoritma K-Means dapat diadaptasi untuk aplikasi spesifik dalam manajemen aset tetap, yang masih kurang dieksplorasi dalam penelitian sebelumnya.

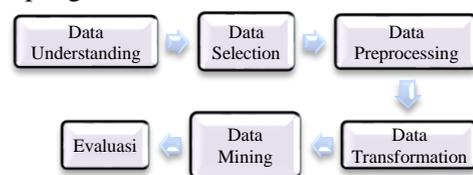
2. TINJAUAN PUSTAKA

Data yang tidak terstruktur sering kali menghambat proses analisis, sehingga sulit untuk mengidentifikasi pola-pola yang relevan dalam pengambilan keputusan strategis [6]. Penelitian sebelumnya menunjukkan bahwa

algoritma K-Means dapat digunakan untuk pengelompokan data yang efektif, seperti pada pengelompokan pembeli biji alpukat [6] dan segmentasi pembuluh darah retina [7]. Muslih (2022) menerapkan metode ini untuk segmentasi pembuluh darah retina dan menunjukkan akurasi yang tinggi. Aziz dan Rifai (2022) menggunakan K-Means untuk mengelompokkan data ekspor kopi berdasarkan negara tujuan, yang memberikan hasil clustering yang terarah. Pamungkas (2023) menerapkan metode serupa pada segmentasi citra daun bawang, menghasilkan klasifikasi yang akurat untuk analisis lanjutan. Namun, penerapan algoritma ini dalam pengelolaan aset tetap masih minim dieksplorasi [8], [9].

3. METODE PENELITIAN

Penelitian ini menggunakan metode *Knowledge Discovery in Database* (KDD) dengan tipe kuantitatif yang memanfaatkan teknik eksperimental dari dataset yang data aset tetap PT. XYZ melalui penerapan algoritma K-Means, nilai Davies Bouldin Indeks (DBI) terbaik yang dihasilkan melalui pengujian parameter nilai K dengan rentang 2 (dua) sampai dengan 10 (sepuluh) dan mengidentifikasi atribut apa saja yang mempengaruhi nilai DBI terbaik.



Gambar 3.1 Tahapan Metode Penelitian

- a. Data Understanding : Data Analisis diperoleh dari database PT. XYZ melalui Proses Ijin Observasi, yang mencakup informasi tentang Aset Perusahaan selama periode Januari 2020 hingga Juni 2024. Data yang dikumpulkan merupakan data

- sekunder yang relevan dengan penelitian.
- b. Data Selection mencakup Data Aset yang sudah diperoleh kemudian di pilih berdasarkan attribut yang paling relevan dengan analisis Penelitian seperti No, On Site, FATagNo, FA Category, FA Description Department dan Condition Asset
 - c. Data Preprocessing ini di dalamnya dilakukan pembersihan untuk menghilangkan duplikasi dan menangani data yang hilang. Sebagai contoh, aset dengan informasi yang tidak lengkap atau inkonsistensi dicatat dan diperbaiki untuk menjaga kualitas data
 - d. Data Transformation merupakan tahapan yang lakukan pengolahan dan standarisasi data menjadi format agar sesuai dengan input yang dibutuhkan bila kita menggunakan algoritma K-Means.
 - e. Data Mining : Data yang sudah format selanjutnya lakukan eksperimen menggunakan algoritma K-Means untuk memperoleh Nilai Davies Index Bouldin (DBI) terbaik berdasarkan Jumlah Cluster (nilai K) optimal.
 - f. Tahap evaluasi dilakukan untuk mengukur tingkat Optimal model Segmentasi menggunakan Algoritma K-Means, mengidentifikasi atribut yang paling berpengaruh, serta menganalisis hasil eksperimen untuk meningkatkan Efektifitas dan Efisiensi dalam pengelolaan Aset Tetap Perusahaan.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Penelitian

Pada bagian ini memaparkan hasil penelitian yang dilakukan dengan menerapkan algoritma K-Means untuk segmentasi data aset tetap pada PT. XYZ. Data aset tetap yang digunakan mencakup informasi tentang No, On Site, FATagNo, FA Category, FA Description

Department dan Condition Asset. Penelitian ini menggunakan pendekatan Knowledge Discovery in Databases (KDD) yang terdiri dari lima tahapan yaitu Memahami data, seleksi data, praproses data, transformasi data, penambahan data, dan evaluasi hasil. Proses analisis dilakukan menggunakan perangkat lunak RapidMiner.

4.1.1 Data Understanding Seleksi Data

Dataset yang digunakan sebagai bahan eksperimen merupakan data aset tetap dikumpulkan dari database internal PT. XYZ selama periode Januari 2021 hingga Juni 2024. Data tersebut mencakup informasi Aset yang memiliki atribut seperti No, On Site, FATagNo, FA Category, FA Description Department dan Condition Asset yang relevan untuk proses analisis. Tahap ini memastikan data yang digunakan sesuai dengan tujuan segmentasi.

4.1.2 Seleksi data

Data yang diperoleh merupakan file dataset asli yang masih dalam format file xlsx dari microsoft excel terdapat sejumlah 3923 record. Operator Read Excel digunakan untuk membaca file xlsx seperti pada gambar 4.1.2.1, dengan parameternya di tabel 4.1.2.1

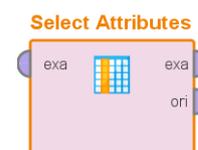


Gambar 4.1.2.1 Operator Read Excel

Tabel 4.1.2.1 Parameter Operator Read Excel

Parameter	Uraian
Excel file	..\Desktop\Dataset_Fix_Aset.xlsx
Sheet number	1
Import cell	A1

Operator Select Attributes digunakan untuk memilih atribut yang relevan dalam eksperimen seperti pada gambar 4.1.2.2, parameternya ada di tabel 4.1.2.2.



Gambar 4.1.2.2 Operator Select Attributes

Tabel 4.1.2.2 Parameter Select Attributes

Parameter	Uraian
Type	Include attributes

Attribute Filter	A subset
Selected attributes	No, Condition Asset, Department, FACategory, FADescription, FATagNo, On site,

Operator Set Role digunakan untuk penentu suatu atribut sebagai ID, seperti pada gambar 4.1.2.3, dengan parameter seperti pada tabel 4.1.2.3.



Gambar 4.1.2.3 Operator Set Role

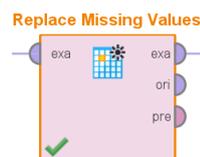
Tabel 4.1.2.3 Parameter Operator Set Role

Attribut name	Target Role
No	Id

4.1.3 Praproses Data

Praproses Data yaitu proses pembersihan untuk menghilangkan duplikasi dan menangani data yang hilang. misalnya aset dengan informasi yang tidak lengkap atau inkonsistensi dicatat dan diperbaiki untuk menjaga kualitas data.

Bila terdapat data yang masih Missing Value, maka diperlukan Operator Replace Missing Value seperti Gambar 4.1.3.1 dengan parameternya bisa di lihat pada tabel 4.1.3.1,



Gambar 4.1.3.1 Operator Replace Missing Value

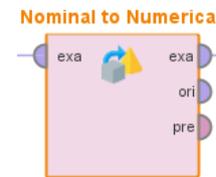
Tabel 4.1.3.1 Parameter Operator Replace Missing Value

Parameter	Uraian
Attribute Filter Type	Subset
default	Average
Selected attributes	Department

4.1.4 Transformasi Data

Transformasi data dilakukan untuk pengolahan dan standarisasi data menjadi format yang sesuai dengan input yang dibutuhkan bila kita menggunakan algoritma K-Means. Tahapan ini memungkinkan kita untuk melakukan berbagai analisis statistik dan perhitungan matematis yang hanya bisa dilakukan pada data numerik. Salah satu

operator yang digunakan yaitu operator “Nominal To Numerical” seperti pada gambar 4.1.4.1. operator ini memiliki fungsi mengkonversi data bertipe kategorikal menjadi bertipe numerik. Untuk paramernya bisa dilihat pada tabel 4.1.4.1,



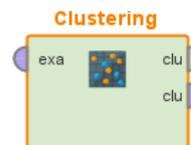
Gambar 4.1.4.1 Operator Nominal to Numerical

Tabel 4.1.4.1 Parameter Nominal to Numerical

Parameter	uraian
Attribute Filter Type	subset
Coding Type	Unique Integer
Selected attributes	Condition Asset, Department, FACategory, FADescription, FATagNo, On site

4.1.5 Penambangan Data (Data Mining)

Algoritma K-Means diterapkan dengan menentukan jumlah cluster yang ditentukan dengan menggunakan operator K-Means Clustering seperti pada gambar 4.1.5.1, yang mana dilakukan eksperimen dengan menguji satu per satu dengan rentang nilai K = 2 hingga K = 10 dan nilai Max Run = 10. Untuk parameter operator Clustering (K-Means) bisa di lihat pada tabel 4.1.5.1.



Gambar 4.1.5.1. Operator Clustering (K-Means)

Tabel 4.1.5.1 Parameter Operator Clustering (K-Means)

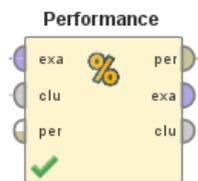
Parameter	Uraian
Add Cluster Attribute	Check
Add as Label	Uncheck
Remove unlabeled	Uncheck
K	2 sampai dengan 10
Max runs	10
Measure types	Mix Measure
Mix Measure	MixEuclideanDistance
Max optimize steps	10
Use local random seed	uncheck

Operator Cluster Distance Performance pada gambar 4.1.5.2 berfungsi menampilkan hasil proses ke dalam nilai Davies Bouldien Index (DBI). Yang mana Nilai Davies Bouldien

Index (DBI) dikatakan paling baik apabila nilainya mendekati 0 (nol), seperti pada tabel 4.1.5.2.

Tabel 4.1.5.2 Parameter Operator Cluster Distance Performance

Parameter	Uraian
Main Criterion	Davies Bouldien
Main Criterion Only	check
Normalize	Uncheck
Maximize	check
Max runs	10



Gambar 4.1.5.2 Operator Cluster Distance Performance

Tabel 4.1.5.2 merupakan Tabel informasi Matriks Pengujian penggunaan Atribut. Yang mana cell atribut yang berisi angka 1 memiliki arti bahwa atribut tersebut digunakan dalam proses eksperimen, sedangkan cell atribut yang berwarna merah muda merupakan Atribut yang tidak diikuti dalam eksperimen. Tindakan ini dilakukan untuk mendapatkan informasi tentang atribut apa saja yang memiliki pengaruh terhadap nilai Davies Bouldien Index (DBI) terbaik melalui pengujian operator Clustering K-Means dengan rentang nilai Parameter K = 2 hingga K = 10.

Tabel 4.1.5.3 Matriks Pengujian Atribut

No	Conditon asset	Department	Atribut			
			FA Category	FA Description	FA Tag No	On Site
1	1	1	1	1	1	1
2	1	1	1	1	1	1
3	1	1	1	1	1	1
4	1	1	1	1	1	1
5	1	1	1	1	1	1
6	1	1	1	1	1	1
7	1	1	1	1	1	1
8	1	1	1	1	1	1
9	1	1	1	1	1	1
10	1	1	1	1	1	1
11	1	1	1	1	1	1
12	1	1	1	1	1	1
13	1	1	1	1	1	1
14	1	1	1	1	1	1
15	1	1	1	1	1	1
16	1	1	1	1	1	1
17	1	1	1	1	1	1
18	1	1	1	1	1	1
19	1	1	1	1	1	1
20	1	1	1	1	1	1
21	1	1	1	1	1	1

No	Conditon asset	Department	Atribut			
			FA Category	FA Description	FA Tag No	On Site
22	1	1	1	1	1	1

Sedangkan Tabel 4.1.5.4 merupakan Tabel informasi hasil eksperimen berdasarkan Nilai Davies Bouldien Index (DBI) yang diperoleh dari pengujian rentang nilai K= 2 hingga k = 10 serta korelasi penggunaan Atribut yang berpengaruh berdasarkan pada tabel 4.1.5.3.

Tabel 4.1.5.4 Matriks Hasil Eksperimen

No	Davies Bouldien Index (DBI)								
	K=2	K=3	K=4	K=5	K=6	K=7	K=8	K=9	K=10
1	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
2	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
3	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
4	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
5	0,499	0,499	0,499	0,499	0,500	0,500	0,501	0,502	0,506
6	0,642	0,455	0,396	0,419	0,492	0,491	0,492	0,497	0,480
7	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
8	0,642	0,455	0,396	0,419	0,492	0,491	0,492	0,497	0,479
9	0,980	0,737	0,726	0,849	0,738	0,697	0,641	0,668	0,634
10	0,499	0,499	0,499	0,499	0,500	0,500	0,501	0,502	0,506
11	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,558
12	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
13	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
14	0,499	0,499	0,499	0,499	0,500	0,500	0,501	0,502	0,506
15	0,642	0,455	0,396	0,419	0,492	0,491	0,492	0,496	0,479
16	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
17	0,499	0,499	0,499	0,499	0,500	0,500	0,501	0,502	0,506
18	0,641	0,454	0,395	0,416	0,489	0,487	0,486	0,471	0,473
19	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
20	0,642	0,454	0,395	0,414	0,487	0,486	0,496	0,472	0,474
21	0,503	0,507	0,513	0,517	0,523	0,527	0,534	0,553	0,559
22	0,499	0,499	0,499	0,499	0,500	0,500	0,501	0,502	0,506

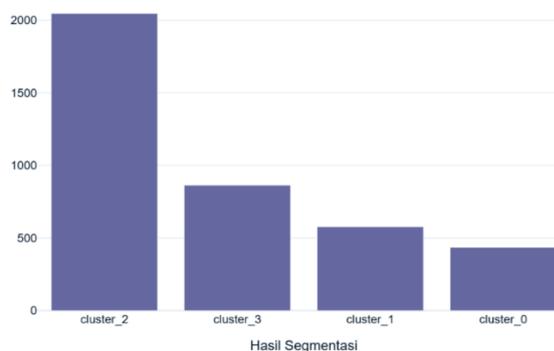
4.1.6 Evaluasi

Evaluasi hasil analisis dilakukan untuk menentukan atribut yang memberikan pengaruh paling signifikan terhadap perolehan nilai Davies Bouldien Index (DBI). Pendekatan yang digunakan adalah dengan tidak mengikutsertakan paling banyak 2 (dua) atribut dalam dataset secara bertahap, kemudian mencatat perubahan pada nilai Davies Bouldien Index (DBI). Hasil analisis menunjukkan bahwa atribut "FACategory dan FATagNo" ketika tidak diikuti pada eksperimen memiliki kontribusi paling signifikan dalam peningkatan model. Evaluasi ini menegaskan pentingnya penggunaan atribut yang relevan dan berpengaruh dalam proses pembelajaran mesin untuk memastikan model dapat menghasilkan segmentasi yang optimal.

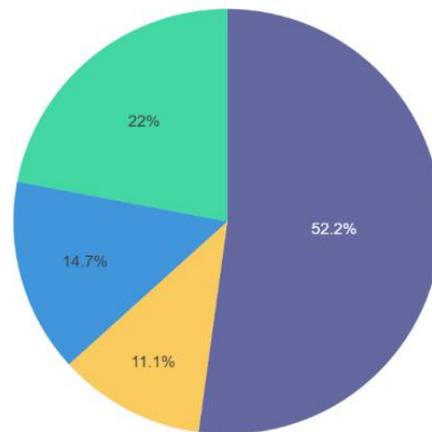
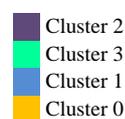
4.2. Pembahasan

Dari tabel 4.5.1.4, dapat dilihat terdapat nilai Davies Bouldin Index (DBI) terkecil yaitu di angka 0,395. Yang mana nilai tersebut diperoleh dari pengujian pada parameter operator Clustering K-Means dengan nilai K = 4 yang bermakna pengelompokan aset tetap terdapat 4 Cluster (empat klaster), dan juga melalui pengujian atribut yang berkorelasi dengan tabel 4.1.5.3 dengan matriks eksperimen pada nomor 20 (dua puluh). Yang artinya pada pengujian tersebut terdapat 5 (lima) atribut yang digunakan yaitu atribut No sebagai Id, Conditon aset, Department, FA, Description dan OnSite serta terdapat 2 (dua) atribut yang tidak diikutsertakan pengujian yaitu atribut FACategory dan FATagNo.

Penelitian ini berhasil menerapkan algoritma K-Means untuk melakukan segmentasi aset tetap berdasarkan pengujian parameter yang ditentukan. Hasil Segmentasi menunjukkan pembagian aset ke dalam empat kelompok dengan distribusi yang berbeda yaitu Cluster 0 (klaster nol) terdapat sejumlah 436 (empat ratus tiga puluh enam) aset atau 11,1% dari jumlah total aset, Cluster 1 (klaster satu) sejumlah 578 (lima ratus tujuh puluh delapan) aset atau 14,7% dari jumlah total aset, Cluster 2 (klaster dua) sejumlah 2046 (dua ribu empat puluh enam) aset atau 52,2% dari jumlah total aset dan Cluster 3 (klaster tiga) sejumlah 863 (delapan ratus enam puluh tiga) aset atau 22% dari jumlah total aset. Hasil visualisasi bisa dilihat pada gambar 4.2.1. dan prosentasi dari masing – masing klaster dapat dilihat pada gambar 4.2.2.



Gambar 4.2.1 Distribusi hasil Segmentasi



Gambar 4.2.2 Prosentasi Distribusi Hasil Segmentasi

Distribusi ini menunjukkan heterogenitas data aset tetap, dengan kecenderungan untuk mengelompokkan berdasarkan jenis serta fungsi aset tetap. Secara khusus, kategori "Plant and Machinery" mendominasi Cluster 2 (klaster dua) dengan 956 (sembilan ratus lima puluh enam) aset, sedangkan "Computer Hardware" merupakan kategori terbanyak di Cluster 1 (klaster satu) dengan 222 (dua ratus dua puluh dua) aset.

Selanjutnya, analisis distribusi kategori mengungkapkan bahwa setiap klaster memiliki karakteristik yang berbeda. Cluster 0 (klaster nol), walaupun kecil, sebagian besar terdiri dari kategori aset " Plant and Machinery " terdapat sejumlah 272 (dua ratus tujuh puluh dua) aset dan kategori "Computer Hardware" terdapat sejumlah 102 (seratus dua) aset. Cluster 3 (klaster tiga) didominasi oleh kategori "Equipment Factory" terdapat sejumlah 454 (empat ratus lima puluh empat) aset.

Hasil segmentasi menunjukkan bahwa aset dengan karakteristik serupa (misalnya, jenis perangkat keras atau mesin) dikelompokkan dalam klaster yang sama. Cluster 2 (klaster dua) memiliki aset dengan distribusi kategori paling luas, yang menunjukkan diversifikasi tinggi dalam jenis aset. Penelitian ini sejalan dengan penelitian sebelumnya yang telah dilakukan seperti Hu et al. (2023) dan Ikotun et al. (2023) menekankan efektivitas K-Means dalam mengelompokkan data besar ke dalam klaster berdasarkan kesamaan fitur[10]. Segmentasi yang dihasilkan dari dataset ini mencerminkan kemampuan metode untuk mengelompokkan aset tetap berdasarkan kategori seperti Computer Hardware, mesin, dan peralatan

pabrik. Klaster besar seperti Cluster 2 (klaster dua) menunjukkan pola sentralisasi data yang umum terjadi pada K-Means saat menangani distribusi kategori aset yang luas[11], sebagaimana dijelaskan dalam **Yang & Sinaga (2019)**. Selaras dengan penelitian **Harahap et al. (2022)** mengenai segmentasi pelanggan bisnis, sama seperti pelanggan yang dikelompokkan berdasarkan atribut perilaku, aset dikelompokkan berdasarkan karakteristik fungsional atau fisik[12]. Penelitian ini relevan dengan penelitian sebelumnya oleh **Fitri et al. (2023)** tentang klasterisasi data penjualan menunjukkan bahwa K-Means cocok untuk mengidentifikasi pola tersembunyi[13], seperti perbedaan kategori aset di sini. Misalnya, klasterisasi dapat digunakan untuk mengoptimalkan distribusi aset di berbagai lokasi.

Hasil ini menunjukkan bahwa algoritma K-Means dengan efektif dapat meningkatkan model Segmentasi berdasarkan kesamaan atribut tertentu yang dapat memberikan definisi berharga tentang struktur data.

Secara keseluruhan, penelitian ini menunjukkan keterkaitan algoritma K-Means dalam pengelolaan aset tetap dan pengambilan keputusan strategis. Dengan adanya identifikasi yang jelas, manajemen aset tetap pada suatu perusahaan dapat lebih berkonsentrasi dalam merancang strategi pemeliharaan dan distribusi sumber daya. Hasil ini juga dapat dimanfaatkan untuk mendukung penilaian aset berdasarkan prioritas operasional, dengan demikian meningkatkan efisiensi dan keberlanjutan dalam pengelolaan sumber daya Perusahaan.

5. KESIMPULAN

Penelitian ini bertujuan untuk mengatasi permasalahan dalam pengelolaan aset tetap di PT. XYZ melalui penerapan algoritma K-Means dalam segmentasi data. Dari analisis yang dilakukan, dapat ditarik beberapa kesimpulan :

a. Nilai Davies Bouldin Index (DBI) terbaik yang di peroleh pada angka 0,395 merupakan hasil pengujian parameter operator Clustering K-Means dengan nilai $K=4$. Ini merupakan nilai K Optimal dari rentang $K=2$ hingga $K=10$.

- b. Selain itu, nilai Davies Bouldin Index (DBI) terbaik diperoleh dari eksperimen menggunakan atribut berjumlah 7 (tujuh) atribut yang dilakukan pada pengujian tersebut terdapat 5 (lima) atribut yang digunakan yaitu atribut No sebagai Id, Conditon asset, Department, FA, Description dan OnSite serta terdapat 2 (dua) atribut yang tidak diikutsertakan pengujian yaitu atribut FACategory dan FATagNo.
- c. Dari hasil model Segmentasi data Aset tetap menggunakan algoritma K-Means diperoleh sejumlah 4 (empat) Klaster yang masing – masing memiliki dominasi diantaranya :
1. Cluster 0 (klaster nol) didominasi kategori " Plant and Machinery " dengan jumlah 272 (dua ratus tujuh puluh dua) aset dan kategori "Computer Hardware" dengan jumlah 102 (seratus dua) aset.
 2. Cluster 1 (klaster satu) didominasi Kategori "Computer Hardware" dengan jumlah 222 (dua ratus dua puluh dua) aset.
 3. Cluster 2 (klaster dua) didominasi kategori "Plant and Machinery" dengan jumlah 956 (sembilan ratus lima puluh enam) aset.
 4. Cluster 3 (klaster tiga) didominasi oleh kategori "Equipment Factory" dengan jumlah 454 (empat ratus lima puluh empat) aset.

DAFTAR PUSTAKA

- [1] F. Y. Y. Choi, "Segmentation," in *Routledge Encyclopedia of Translation Technology*, London: Routledge, 2023, pp. 713–725. doi: 10.4324/9781003168348-44.
- [2] Z. A. Sofyan *et al.*, "Optimasi Parameter Algoritma K-Means Pada Data Rekam Medis," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 6, pp. 3667–3672, 2023.
- [3] A. V. Mukti and V. T. Noerwasito, "Penggunaan Metode Segmentasi dan Narasi dalam Redesain Gertak di Pesisir Sungai Kapuas," *Jurnal Sains dan Seni ITS*, vol. 11, no. 5, Apr. 2023, doi: 10.12962/j23373520.v11i5.97824.
- [4] F. Febriansyah, "PENERAPAN ALGORITMA K-MEANS CLUSTERING DATA GIZI BALITA PADA UPTD PUSKESMAS BUMI AGUNG," *Jurnal Informatika dan Teknik*

- Elektro Terapan*, vol. 12, no. 3, Aug. 2024, doi: 10.23960/jitet.v12i3.4923.
- [5] K. A. Lubis, M. Rusdi, and S. Sugianto, "Proses Segmentasi Citra Satelit Untuk Pemetaan Tutupan Lahan," *Jurnal Ilmiah Mahasiswa Pertanian*, vol. 6, no. 4, pp. 691–698, Nov. 2021, doi: 10.17969/jimfp.v6i4.18414.
- [6] E. E. K. Putri Lestari, D. Swanjaya, and R. A. Ramadhani, "Segmentation of Avocado Seed Buyers Using K-Means Clustering," *JTECS: Jurnal Sistem Telekomunikasi Elektronika Sistem Kontrol Power Sistem dan Komputer*, vol. 3, no. 2, p. 151, Jul. 2023, doi: 10.32503/jtecs.v3i2.3886.
- [7] Muslih Muslih, "SEGMENTASI PEMBULUH DARAH PADA CITRA RETINA MATA MENGGUNAKAN METODE REGION GROWING," *Jurnal Informatika Polinema*, vol. 8, no. 4, pp. 25–30, Aug. 2022, doi: 10.33795/jip.v8i4.960.
- [8] D. P. Pamungkas and F. M. Wijaya, "Analisis Hasil Segmentasi Citra Daun Bawang Dengan Metode Adaptive Thesholding dan K-Means Clustering," *JOINTECS (Journal of Information Technology and Computer Science)*, vol. 8, no. 3, p. 95, Sep. 2023, doi: 10.31328/jointecs.v8i3.4791.
- [9] A. D. A. Lusinta, T. Titin, and L. N. Azizah, "ANALISIS SEGMENTING, TARGETING DAN POSITIONING UNTUK MERUMUSKAN STRATEGI PEMASARAN GLOBAL PADA UKM KACANG MEDE 'BAWANG MAS' SURABAYA," *JURNAL MANAJEMEN*, vol. 4, no. 2, p. 907, Jun. 2019, doi: 10.30736/jpim.v4i2.249.
- [10] A. M. Ikotun, A. E. Ezugwu, L. Abualigah, B. Abuhaija, and ..., "K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data," *Information ...*, 2023, [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0020025522014633>
- [11] M.-S. Yang and K. P. Sinaga, "A Feature-Reduction Multi-View k-Means Clustering Algorithm," *IEEE Access*, vol. 7, pp. 114472–114486, 2019, doi: 10.1109/ACCESS.2019.2934179.
- [12] M. Harahap, Y. Lubis, and Z. Situmorang, "Analisis Pemasaran Bisnis dengan Data Science: Segmentasi Kepribadian Pelanggan berdasarkan Algoritma K-Means Clustering," *Data Sciences Indonesia (DSI)*, vol. 1, no. 2, pp. 76–88, Jan. 2022, doi: 10.47709/dsi.v1i2.1348.
- [13] E. M. Fitri, R. R. Suryono, and A. Wantoro, "Klasterisasi Data Penjualan Berdasarkan Wilayah Menggunakan Metode K-Means Pada Pt Xyz," *Jurnal Komputasi*, 2023, [Online]. Available: <https://komputasi.fmipa.unila.ac.id/index.php/komputasi/article/view/226>