

PENERAPAN K-MEANS UNTUK PRIORITAS PENERIMA BANTUAN SOSIAL BERDASARKAN DATA DTKS DI KABUPATEN BANYUASIN

M Wildan Solihan^{1*}, Dien Novita²

Universitas Multi Data Palembang

mwildansolihan@mhs.mdp.ac.id^{1}, dien@mdp.ac.id²*

Abstract

Penelitian ini bertujuan untuk meningkatkan efisiensi dan akurasi dalam penyaluran bantuan sosial di Kabupaten Banyuasin dengan mengelompokkan calon penerima bantuan berdasarkan karakteristik sosial-ekonomi menggunakan algoritma K-Means. Data yang digunakan berasal dari Data Terpadu Kesejahteraan Sosial (DTKS), dengan proses cleansing dan transformasi dilakukan menggunakan RapidMiner, serta proses clustering dilanjutkan melalui aplikasi yang dirancang khusus untuk implementasi algoritma K-Means. Hasil penelitian menunjukkan bahwa algoritma ini mampu membentuk empat cluster prioritas penerima bantuan, yaitu prioritas pertama, kedua, ketiga, dan keempat, sehingga mengurangi ketidaktepatan sasaran pada metode manual sebelumnya. Penelitian ini masih terbatas pada penggunaan data DTKS tahun berjalan dan belum mencakup validasi lapangan secara langsung. Studi ini memberikan kontribusi pada pengembangan sistem pendukung keputusan di bidang kesejahteraan sosial, khususnya dalam segmentasi penerima bantuan sosial berbasis data mining.

Kata Kunci: *K-Means, Data Mining, DTKS, Bantuan Sosial*

1. PENDAHULUAN

Kemiskinan merupakan permasalahan fundamental yang masih menjadi tantangan besar di banyak negara berkembang, termasuk Indonesia. Berdasarkan data Badan Pusat Statistik (BPS), jumlah penduduk miskin di Indonesia pada Maret 2024 mencapai 25,22 juta jiwa atau sekitar 9,03% dari total populasi, mencerminkan bahwa isu ini belum sepenuhnya teratasi (Purwanti, 2024). Berbagai faktor saling berkaitan memicu kondisi ini, mulai dari ketimpangan distribusi kekayaan, rendahnya akses terhadap pendidikan dan layanan kesehatan, hingga kebijakan yang kurang efektif.

Secara geografis, kemiskinan menunjukkan pola yang bervariasi antar daerah. Wilayah timur Indonesia seperti Papua Pegunungan dan Papua Tengah mencatat tingkat kemiskinan tertinggi, sedangkan wilayah seperti DKI Jakarta memiliki angka yang relatif rendah. Di tingkat lokal, Kabupaten Banyuasin di Sumatera Selatan mencatatkan angka kemiskinan sebesar 9,31% pada akhir 2024, mengalami penurunan dibandingkan tahun sebelumnya (BPS Sumsel, 2024). Pemerintah daerah telah berupaya menyalurkan bantuan sosial melalui berbagai program, namun masih menghadapi kendala terkait akurasi data penerima dan efisiensi distribusi. Kompleksitas pengelolaan data kerap menyebabkan ketidaktepatan sasaran dan inefisiensi dalam pelaksanaan program.

Untuk mengatasi permasalahan tersebut, pendekatan berbasis teknologi seperti data mining dinilai mampu memberikan solusi yang lebih objektif dan sistematis. Salah satu metode yang potensial adalah K-Means Clustering, yang memungkinkan pengelompokan data berdasarkan karakteristik

sosial-ekonomi masyarakat. Metode ini dapat membantu dalam pengambilan keputusan yang lebih akurat terkait segmentasi penerima bantuan sosial.

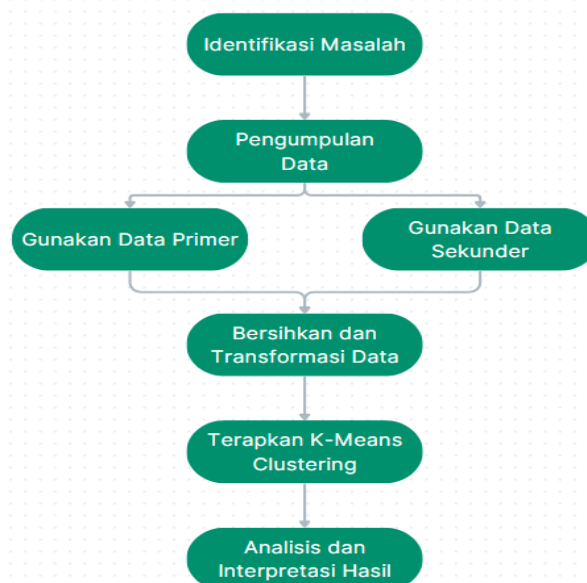
Sejumlah penelitian telah membuktikan efektivitas metode ini dalam mendukung ketepatan penyaluran bantuan. (Amaliyah dkk., 2023) mengelompokkan 1.022 data kepala keluarga di Desa Kuala Dendang, Tanjung Jabung Timur, dan menemukan bahwa 114 keluarga masuk dalam kategori prioritas namun belum tercatat sebagai penerima. Sementara itu, (Sari Ufriani dkk., 2023) mengelompokkan 2.668 data masyarakat di Kelurahan Kampung Singkep dan mengidentifikasi 28 warga yang layak prioritas namun tidak terdaftar, berdasarkan atribut seperti status rumah dan penghasilan.

Penelitian lain oleh (Fitriani dkk., 2024) menerapkan K-Means untuk mengevaluasi penentuan prioritas penerima Program Keluarga Harapan (PKH) di Desa Tambaksari, menghasilkan dua kluster utama (prioritas dan tidak prioritas) dengan nilai DBI sebesar 0,415, menandakan kualitas kluster yang cukup baik. Di bidang pendidikan, (Sompa & Ishak, 2022) mengelompokkan calon penerima KIP Kuliah menjadi lima kelompok prioritas, sedangkan (Bengnga & Ishak, 2023) menggabungkan XGBoost untuk seleksi atribut dengan K-Means dan berhasil mengidentifikasi empat kluster dengan nilai DBI terbaik sebesar 0,819. (Kusnaidi dkk., 2022) juga menunjukkan efektivitas metode ini dalam menentukan penerima bantuan UKT selama masa pandemi melalui proses normalisasi dan klasterisasi data.

Berdasarkan studi-studi tersebut, dapat disimpulkan bahwa K-Means Clustering sangat relevan untuk diterapkan dalam proses seleksi penerima bantuan sosial. Pendekatan ini menawarkan solusi berbasis data yang lebih adil, efisien, dan sistematis dibandingkan metode konvensional. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem penentuan prioritas penerima bantuan sosial di Kabupaten Banyuasin menggunakan algoritma K-Means Clustering sebagai upaya meningkatkan ketepatan sasaran dan efektivitas distribusi bantuan.

2. METODOLOGI PENELITIAN

Penelitian ini merupakan studi eksperimental berbasis data mining yang bertujuan untuk mengembangkan solusi efisien dalam penyaluran bantuan sosial dengan menggunakan algoritma *K-Means Clustering*. Proses penelitian dilakukan secara sistematis melalui beberapa tahapan berikut:



Gambar 1.1 Metode Penelitian

1. Identifikasi Masalah

Pada tahap awal, peneliti melakukan identifikasi terhadap permasalahan dalam proses penyaluran bantuan sosial. Permasalahan utama yang diangkat adalah pengelolaan data yang besar dan kompleks, serta proses seleksi penerima bantuan yang masih bersifat manual. Proses manual ini berpotensi menimbulkan subjektivitas, ketidaktepatan sasaran, dan memerlukan waktu yang lama. Oleh karena itu, peneliti menganalisis sejumlah variabel seperti pekerjaan kepala keluarga, kondisi rumah, dan status sosial ekonomi yang menjadi indikator dalam penentuan penerima bantuan.

2. Pengumpulan Data

Penelitian ini menggunakan data primer dan data sekunder. Data primer diperoleh melalui studi literatur guna memperkuat landasan teoritis mengenai bantuan sosial dan teknik data mining. Selain itu, peneliti juga melakukan wawancara langsung dengan pihak Dinas Sosial untuk mendapatkan informasi faktual mengenai alur distribusi bantuan, kendala-kendala yang dihadapi, serta struktur data yang digunakan dalam proses seleksi. Sementara itu, data sekunder diperoleh dari Data Terpadu Kesejahteraan Sosial (DTKS) yang dikelola oleh instansi pemerintah terkait. Data ini berisi informasi sosial-ekonomi keluarga yang telah terdokumentasi dan dapat digunakan sebagai dasar analisis.

3. Transformasi Data

Data yang telah dikumpulkan kemudian melalui proses transformasi. Langkah ini mencakup pembersihan data dari nilai yang hilang atau tidak valid, normalisasi untuk menyeragamkan skala antar variabel, serta konversi data ke dalam bentuk numerik yang dapat diproses oleh algoritma *K-Means*.

4. Penerapan K-Means Clustering

Setelah data berhasil dikumpulkan dan melalui tahap transformasi untuk memastikan bahwa data telah dibersihkan dan siap untuk dianalisis, langkah selanjutnya adalah penerapan algoritma *K-Means Clustering* untuk mengelompokkan data.

5. Analisis dan Interpretasi Hasil

Hasil dari *K-Means Clustering* berupa pembentukan beberapa klaster yang masing-masing mewakili kelompok keluarga dengan karakteristik sosial-ekonomi yang serupa. Peneliti kemudian menganalisis tiap klaster untuk mengidentifikasi kelompok yang paling membutuhkan bantuan sosial. Hasil ini dijadikan dasar dalam memberikan rekomendasi penyaluran bantuan yang lebih akurat dan tepat sasaran.

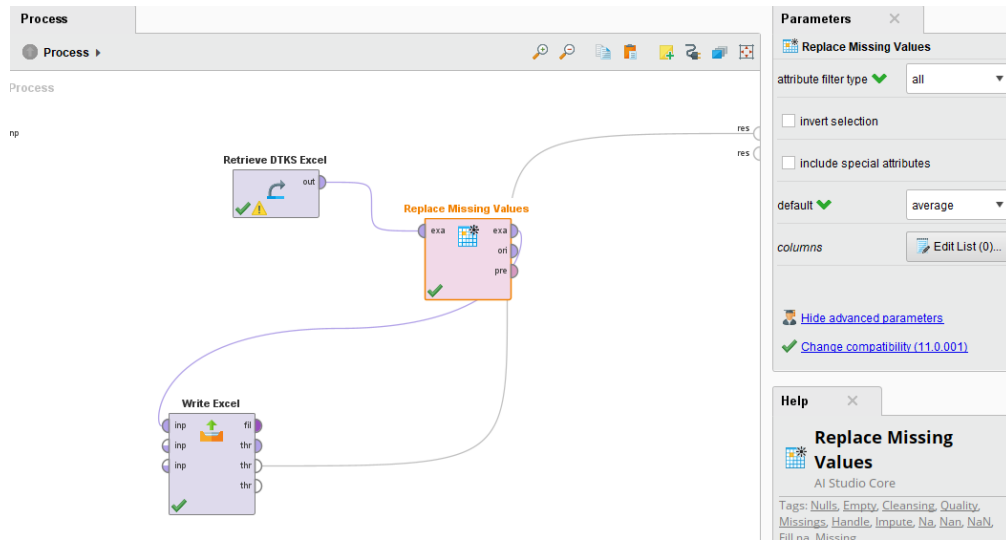
3. HASIL DAN PEMBAHASAN

3.1 Analisis Data Mining Menggunakan Clustering K-Means

Penulis melakukan perhitungan 91705 data Kepala Keluarga pada Kabupaten Banyuasin dengan menggunakan 11 atribut yaitu: Nama Kepala Keluarga, Pekerjaan Kepala Keluarga, Status Kepemilikan Rumah, Jenis Atap, Jenis Dinding, Jenis Lantai, Sumber Penerangan, Daya Listrik Terpasang, Bahan Bakar Memasak, Sumber Air Minum, dan Fasilitas Buang Air Besar. Dengan menggunakan 4 cluster yang setelah analisis cluster yang memiliki total rata-rata terendah akan dilabeli dengan prioritas 1 dan yang tertinggi akan dilabeli dengan prioritas 4.

3.1.1 Pembersihan Data

Sebelum data diproses dengan algoritma k-means, data terlebih dahulu dibersihkan agar hasil proses klusterisasi optimal dan sesuai dengan yang diharapkan. Gambar 3.1 menampilkan proses pembersihan data menggunakan Rapidminer.



Gambar 3. 1 Mengubah nilai Null Menjadi nilai rata-rata

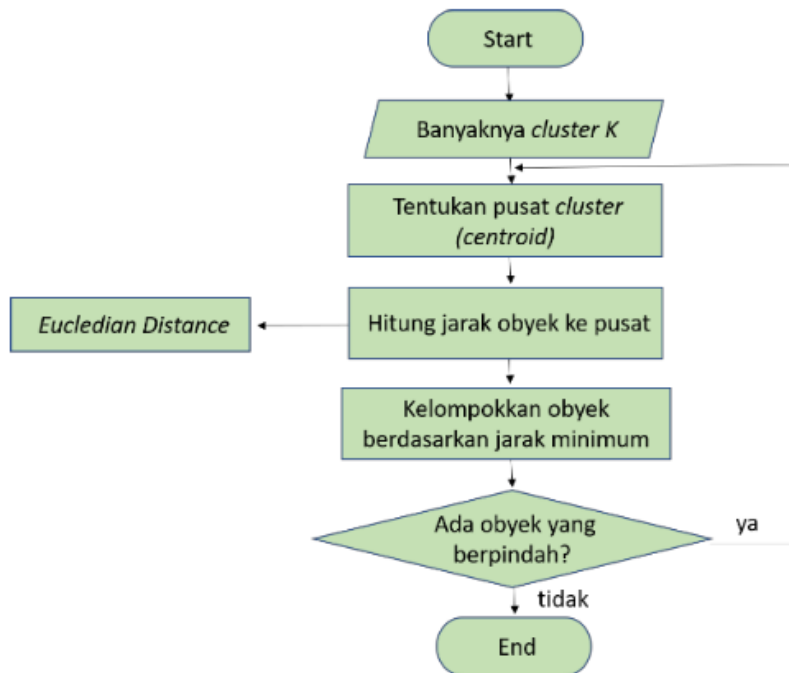
3.1.4 Transformasi Data

Tabel 3. Inisialisasi Nilai Data

A	PEKERJAAN	Inisial
	Belum/Tidak Bekerja	1
	Pekerja Lepas	2
	Petani/Nelayan/Pedagang	3
	Pensiunan/Swasta	4
B	Kepemilikan Rumah	Inisial
	Menumpang/Sewa	1
	Dinas/Milik Sendiri	2
C	Jenis Atap	Inisial
	Jerami/Daun-daunan/Ijuk/Rumbia	1
	Bambu/Kayu/Sirap	2
	Asbes/Seng	3
	Genteng	4
	Beton	5
D	Jenis Dinding	Inisial
	Bambu/Kayu/Sirap	1

	Tembok	2
E	Jenis Lantai	Inisial
	Tanah	1
	Bambu/Kayu/Sirap	2
	Semen	3
	Keramik/Granit/Marmer/Ubin/Tegel/Teraso	4
F	Sumber Penerangan	Inisial
	Non Listrik	1
	Listrik Bukan PLN	2
	Listrik PLN	3
G	Daya Listrik Terpasang	Inisial
	=< 900 watts	1
	> 900 watts	2
H	Bahan Bakar Memasak	Inisial
	Arang/Kayu	1
	Minyak Tanah	2
	Listrik/Gas	3
I	Sumber Air Minum	
	Air Permukaan/Sumur Tidak Terlindung	1
	Air Hujan	2
	Air Kemasan/Isi Ulang/Ledeng/PAM	3
	Sumur Terlindung	4
	Sumur Bor	5
J	Memiliki fasilitas Buang Air Besar	Inisial
	Tidak, Jamban Umum	1
	Ya, Tanpa Septictank	2
	Ya, Dengan Septictank	3

3.1.3 Flowchart Langkah-langkah Clustering K-Means



Gambar 3. 2 Flowchart Clustering K-Means

Sumber:(Amaliyah dkk., 2023)

3.1.4 Nilai Centroid Awal

Pemilihan nilai Centroid awal ini dilakukan secara acak. Berikut pada tabel 3.2 ditampilkan nilai centroid awal.

Tabel 3. 2 Nilai Centroid Awal

Pusat	No.	A	B	C	D	E	F	G	H	I
M1	713	2	1	3	1	2	3	1	3	1
M2	16	2	1	3	1	2	3	1	3	4
M3	12	2	2	3	2	3	3	1	3	3
M4	89	4	2	3	2	3	3	1	3	5

Menghitung jarak masing-masing *centroid*

- a. Perhitungan pada data pertama (x_1)

Cluster C1

$$d(x_1, C_1) = \sqrt{\begin{matrix} (a_1 - C_{1a})^2 + (b_1 - C_{1b})^2 + (c_1 - C_{1c})^2 + (d_1 - C_{1d})^2 \\ + (e_1 - C_{1e})^2 + (f_1 - C_{1f})^2 + (g_1 - C_{1g})^2 \\ + (h_1 - C_{1h})^2 + (i_1 - C_{1i})^2 + (j_1 - C_{1j})^2 \end{matrix}} = \sqrt{\begin{matrix} (2 - 2)^2 + (2 - 1)^2 + (3 - 3)^2 + (1 - 1)^2 \\ + (3 - 2)^2 + (3 - 3)^2 + (1 - 1)^2 + (3 - 3)^2 \\ + (3 - 1)^2 + (3 - 1)^2 \end{matrix}} = 3,162$$

Jarak Euclidean antara data pertama dan centroid cluster C1 adalah sekitar 3,162, yang menunjukkan tingkat kemiripan dengan pusat cluster. Semakin kecil jarak, semakin mirip data dengan karakteristik cluster C1.

Cluster C2

$$d(x_1, C_2) = \sqrt{\begin{matrix} (a_1 - C_{2a})^2 + (b_1 - C_{2b})^2 + (c_1 - C_{2c})^2 + (d_1 - C_{2d})^2 \\ + (e_1 - C_{2e})^2 + (f_1 - C_{2f})^2 + (g_1 - C_{2g})^2 \\ + (h_1 - C_{2h})^2 + (i_1 - C_{2i})^2 + (j_1 - C_{2j})^2 \end{matrix}} = \sqrt{\begin{matrix} (2-2)^2 + (2-1)^2 + (3-3)^2 + (1-1)^2 \\ + (3-2)^2 + (3-3)^2 + (1-1)^2 + (3-3)^2 \\ + (3-4)^2 + (3-3)^2 \end{matrix}} = 1,732$$

Hasil perhitungan menunjukkan bahwa jarak data pertama ke centroid cluster C2 (1,732) lebih kecil dibandingkan ke C1 (3,162), sehingga data tersebut lebih dekat atau lebih mirip dengan karakteristik cluster C2. Cluster C3

$$d(x_1, C_3) = \sqrt{\begin{matrix} (a_1 - C_{3a})^2 + (b_1 - C_{3b})^2 + (c_1 - C_{3c})^2 + (d_1 - C_{3d})^2 \\ + (e_1 - C_{3e})^2 + (f_1 - C_{3f})^2 + (g_1 - C_{3g})^2 \\ + (h_1 - C_{3h})^2 + (i_1 - C_{3i})^2 + (j_1 - C_{3j})^2 \end{matrix}} = \sqrt{\begin{matrix} (2-2)^2 + (2-2)^2 + (3-3)^2 + (1-2)^2 \\ + (3-3)^2 + (3-3)^2 + (1-1)^2 \\ + (3-3)^2 + (3-3)^2 + (3-3)^2 \end{matrix}} = 1$$

Hasil perhitungan menunjukkan bahwa jarak antara data pertama dan centroid cluster C3 adalah 1. Nilai ini lebih kecil dibandingkan dengan jarak ke cluster C1 ataupun C2, yang berarti untuk saat ini data pertama lebih dekat ke cluster C3

Cluster C4

$$d(x_1, C_4) = \sqrt{\begin{matrix} (a_1 - C_{4a})^2 + (b_1 - C_{4b})^2 + (c_1 - C_{4c})^2 \\ + (d_1 - C_{4d})^2 + (e_1 - C_{4e})^2 + (f_1 - C_{4f})^2 + (g_1 - C_{4g})^2 \\ + (h_1 - C_{4h})^2 + (i_1 - C_{4i})^2 + (j_1 - C_{4j})^2 \end{matrix}} = \sqrt{\begin{matrix} (2-4)^2 + (2-2)^2 + (3-3)^2 + (1-2)^2 \\ + (3-3)^2 + (3-3)^2 + (1-1)^2 \\ + (3-3)^2 + (3-5)^2 + (3-3)^2 \end{matrix}} = 3$$

Dari hasil perhitungan diketahui data pertama memiliki jarak terdekat ke centroid cluster C3, sehingga sebaiknya dimasukkan ke dalam cluster tersebut. Setelah pengelompokan berdasarkan jarak terdekat, proses iterasi dilakukan untuk menghitung ulang hingga centroid mencapai nilai optimal. Pada tabel 3.3 ditampilkan hasil pengelompokan berdasarkan jarak terdekat.

Tabel 3. 3 Pengelompokan Berdasarkan Jarak Terdekat

Nama	A	B	C	D	E	F	G	H	I	J	C1	C2	C3	C4	Cluster
NANO	2	2	3	1	3	3	1	3	3	3	3,162277 66	1,7320 51	1	3	Cluster 3
MUHAMMAD YASER MALIK	2	1	3	1	3	3	2	3	3	3	3,162277 66	1,7320 51	1,7320 51	3,3166 25	Cluster 2
ABDUL RACHMAN	4	2	3	1	3	3	1	3	5	3	5,099019 514	2,6457 51	3	1	Cluster 4
SISWANTO	3	2	3	2	3	3	1	3	3	3	3,464101 615	2,2360 68	1	2,2360 68	Cluster 3
JANAWI	2	1	3	1	3	3	1	3	3	3	3	1,4142 14	1,4142 14	3,1622 78	Cluster 2
...
TAWANDUK	3	2	3	2	4	3	1	3	2	3	3,464101 615	3,3166 25	1,7320 51	3,3166 25	Cluster 3
NURIL HUDA	3	2	4	1	3	3	1	3	2	3	3	2,8284 27	2	3,4641 02	Cluster 3
WARSITO	3	2	3	2	4	3	1	3	2	3	3,464101 615	3,3166 25	1,7320 51	3,3166 25	Cluster 3
SUYANTO	3	2	3	2	4	3	1	3	2	3	3,464101 615	3,3166 25	1,7320 51	3,3166 25	Cluster 3

Nama	A	B	C	D	E	F	G	H	I	J	C1	C2	C3	C4	Cluster
SALIKUN	3	2	3	2	4	3	1	3	2	3	3,464101 615	3,3166 25	1,7320 51	3,3166 25	Cluster 3

3.1.5 Nilai Centroid Final

Setelah dilakukan iterasi, berikut pada tabel 3.4 adalah hasil centroid final.

Tabel 3. 4 Nilai Centroid Final

A	B	C	D	E	F	G	H	I	Pusat
1,89	3,25	1,05	1,88	2,97	1,12	2,96	2,88	2,92	0
1,88	3,64	1,9	3,49	2,99	1,19	2,99	3,58	2,86	1
1,85	3,09	1,1	2,06	2,94	1,06	2,85	2,16	1,21	2
1,94	3,33	1,62	3,25	2,98	1,07	2,94	1,79	2,82	3

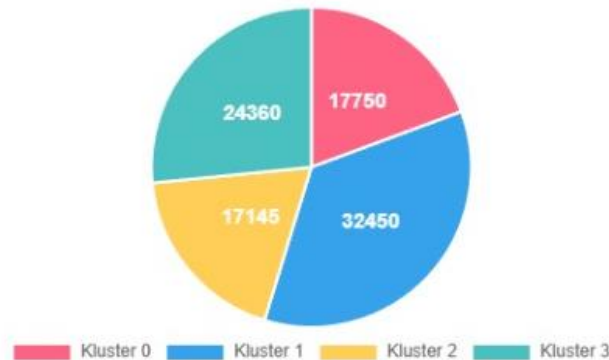
3.1.6 Hasil Pengelompokkan Akhir

Dari *centroid* final yang sudah didapatkan, maka hasil pengelompokkan akhir berdasarkan centroid final dapat dilihat pada tabel 3.5 berikut:

Tabel 3. 5 Hasil Pengelompokkan Akhir

Nama	No	A	B	C	D	E	F	G	H	I	Kluster
NANO	1	2	2	3	1	3	3	1	3	3	Kluster 0
MUHAMMAD YASER MALIK	2	2	2	3	1	3	3	2	3	3	Kluster 0
ABDUL RACHMAN	3	2	2	2	1	3	3	1	3	3	Kluster 1
SISWANTO	4	2	2	2	1	3	3	1	3	3	Kluster 1
JANAWI	5	2	2	3	1	3	3	1	3	3	Kluster 0
...
TAWANDUK	6	3	2	3	2	4	3	1	3	2	Kluster 3
NURIL HUDA	7	3	2	4	1	3	3	1	3	2	Kluster 3
WARSITO	8	3	2	3	2	4	3	1	3	2	Kluster 3
SUYANTO	9	3	2	3	2	4	3	1	3	2	Kluster 3
SALIKUN	10	3	2	3	2	4	3	1	3	2	Kluster 3

Pada gambar 3.3 menampilkan proporsi data per kluster.



Gambar 3. 3 Proporsi Data per Kluster

Penentuan urutan cluster prioritas berdasarkan total rata-rata nilai atribut. kluster dengan urutan prioritas pertama ditempati oleh kluster 2, diikuti kluster 0, kluster 3 dan terakhir kluster 1.

4. KESIMPULAN

Penelitian menunjukkan bahwa algoritma K-Means efektif dalam mengelompokkan penerima bantuan sosial berdasarkan data DTKS di Dinas Sosial Kabupaten Banyuasin. Clustering menghasilkan segmentasi prioritas pertama, kedua, ketiga dan keempat sehingga alokasi bantuan menjadi lebih tepat sasaran dan efisien. Sistem yang dikembangkan juga terbukti berhasil dalam praktik, membantu evaluasi dan distribusi bantuan secara lebih cepat dan akurat.

KETERBATASAN DAN ARAH PENELITIAN SELANJUTNYA

Penelitian ini masih memiliki beberapa keterbatasan yang perlu diperhatikan. Salah satunya adalah terbatasnya jumlah variabel yang digunakan dalam proses clustering. Untuk meningkatkan akurasi segmentasi, disarankan agar Dinas Sosial Kabupaten Banyuasin melibatkan variabel tambahan seperti penghasilan keluarga, tingkat pendidikan, dan akses terhadap layanan kesehatan, sehingga hasil segmentasi lebih mencerminkan kondisi riil masyarakat.

Selain itu, penelitian selanjutnya dapat dilakukan untuk membandingkan algoritma K-Means dengan metode clustering lain seperti DBSCAN atau Hierarchical Clustering, guna mengevaluasi apakah terdapat pendekatan yang lebih optimal dalam segmentasi penerima bantuan sosial.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Dinas Sosial Kabupaten Banyuasin yang telah menyediakan data dan informasi yang diperlukan dalam penelitian ini. Ucapan terima kasih juga disampaikan kepada dosen pembimbing yang telah memberikan arahan dan masukan selama proses penyusunan penelitian. Selain itu, penulis menghargai segala bentuk dukungan non-finansial dari keluarga dan rekan-rekan yang telah memberikan semangat dan motivasi.

REFERENCES

Amaliyah, S., Jasmir, & Rianti, S. (2023). Penerapan Data Mining Untuk Menentukan Kelompok Prioritas Penerima Bantuan PKH Menggunakan Metode Clustering K-Means Pada Desa Kuala Dandang. *Jurnal Informatika Dan Rekayasa Komputer(JAKAKOM)*, 3(1), 453–458.

<https://doi.org/10.33998/jakakom.2023.3.1.802>

Bengnga, A., & Ishak, R. (2023). Penerapan XGBoost untuk Seleksi Atribut pada K-Means dalam Clustering Penerima KIP Kuliah. *Jambura Journal of Electrical and Electronics Engineering*, 5(2), 192–196. <https://doi.org/10.37905/jjee.v5i2.20253>

BPS Sumsel. (2024). Persentase Penduduk Miskin menurut Kabupaten/Kota (Persen), 2022-2024. *Badan Pusat Statistik Provinsi Sumatera Selatan, VIII(I)*, 1.

Fitriani, F., Kurniawan, R., & Suprapti, T. (2024). Penerapan Algoritma K-Means Clustering Untuk Identifikasi Kelayakan Penerima Bantuan Program Keluarga Harapan (Pkh) Di Desa Tambaksari Ciamis. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(6), 3363–3369. <https://doi.org/10.36040/jati.v7i6.8197>

Kusnaldi, M. R., Gulo, T., & Aripin, S. (2022). Penerapan Normalisasi Data Dalam Mengelompokkan Data Mahasiswa Dengan Menggunakan Metode K-Means Untuk Menentukan Prioritas Bantuan Uang Kuliah Tunggal. *Journal of Computer System and Informatics (JoSYC)*, 3(4), 330–338. <https://doi.org/10.47065/josyc.v3i4.2112>

Purwanti, E. (2024). *Analisis Deskriptif Profil Kemiskinan Indonesia Berdasarkan Data BPS Tahun 2023*. 4(1), 1–10.

Sari Ufriani, Jasmir, & Arvita, Y. (2023). Penerapan Algoritma Clustering K-means untuk Menentukan Prioritas Penerima Bantuan Dana Sosial PKH di Kelurahan Kampung Singkep. *Jurnal Informatika Dan Rekayasa Komputer (JAKAKOM)*, 3(1), 342–350. <https://doi.org/10.33998/jakakom.2023.3.1.726>

Sompa, M., & Ishak, R. (2022). Clustering Tingkat Ekonomi Mahasiswa Calon Penerima Kartu Indonesia Pintar (KIP) Kuliah Metode K-Means. *Jurnal Ilmiah Ilmu Komputer Banthayo Lo Komputer*, 1(2), 65–71. <https://doi.org/10.37195/balok.v1i2.175>

Eg. Li, S., & Seale, C. (2017). Learning to do qualitative data analysis: An observational study of doctoral work. *Qualitative Health Research*, 17(10), 1442-1452. <https://doi.org/10.1177/1049732307306924>

For more detail guidelines for Referencing, visit <https://aut.ac.nz.libguides.com/APA6th/referencelist>

Additions and Suggestions:

- Use free or paid model of <https://grammarly.com> to improve English correctness of the manuscript.
- Use good quality image and give caption below image Figure 1:
- Caption for a table should be above the table. Like Table 1: