

## Analisis *Clustering* berdasarkan Faktor-Faktor Kemiskinan di Provinsi Sulawesi Selatan menggunakan Algoritma *K-Medoids*

### *Clustering Analysis of Poverty Indicators in South Sulawesi Province Using the K-Medoids Algorithm*

Saranty<sup>1</sup>, Muhammad Hidayatullah\*<sup>2</sup>, Fardinah<sup>3</sup>

<sup>1,2,3</sup>Program Studi Statistika, Universitas Sulawesi Barat, Sulawesi Barat Indonesia

\*Penulis Korespondensi

Email: muh.hidayatullah@unsulbar.ac.id\*

**Abstrak.** Penelitian ini fokus pada pengelompokan wilayah kabupaten/kota di Provinsi Sulawesi Selatan dengan mempertimbangkan karakteristik kemiskinan menggunakan teknik klusterisasi *K-Medoids*. Urgensi penelitian ini muncul dari kebutuhan untuk memahami pola kemiskinan yang berbeda di wilayah tersebut agar kebijakan pembangunan daerah dapat lebih terarah dan efektif. Sebanyak 24 kabupaten/kota dianalisis menggunakan sembilan indikator kemiskinan, yaitu indeks kedalaman kemiskinan, indeks keparahan kemiskinan, tingkat pengangguran terbuka, harapan hidup, Indeks Pembangunan Manusia (IPM), pengeluaran per kapita, rata-rata lama sekolah, Produk Domestik Regional Bruto (PDRB), dan kepadatan penduduk. Hasil evaluasi menggunakan tiga metrik validitas internal—*Silhouette Coefficient*, *Dunn Index*, dan *Davies-Bouldin Index*—menunjukkan bahwa konfigurasi dua *cluster* ( $k=2$ ) lebih optimal dibandingkan tiga *cluster* ( $k=3$ ). Pada Tahun 2019, dari 24 kabupaten/kota, 23 kabupaten/kota masuk ke dalam *cluster* 1 (wilayah tertinggal) yang ditandai dengan indeks kemiskinan dan keparahan tinggi serta IPM dan pengeluaran per kapita rendah, sedangkan 1 kabupaten/kota berada di *cluster* 2 (wilayah maju) dengan kondisi sebaliknya. Analisis tren dari 2019 sampai 2023 menunjukkan komposisi *cluster* tetap stabil dengan adanya pergeseran positif pada 2 kabupaten/kota dari *cluster* 1 ke *cluster* 2 pada 2023.

**Kata kunci:** Clustering, K-Medoids, Kebijakan Pemerintah, Kemiskinan, Sulawesi Selatan

**Abstract.** This study focuses on grouping the regencies and cities in South Sulawesi Province by considering poverty characteristics using the *K-Medoids* clustering technique. The urgency of this research arises from the need to understand the varying poverty patterns in the region to enable more targeted and effective regional development policies. A total of 24 regencies/cities were analyzed using nine poverty indicators: poverty depth index, poverty severity index, open unemployment rate, life expectancy, Human Development Index (HDI), per capita expenditure, average years of schooling, Gross Regional Domestic Product (GRDP), and population density. Evaluation results using three internal validity metrics—*Silhouette Coefficient*, *Dunn Index*, and *Davies-Bouldin Index*—showed that the configuration of two clusters ( $k=2$ ) is more optimal than three clusters ( $k=3$ ). Of the 24 regencies/cities, 23 fall into cluster 1 (underdeveloped areas), characterized by high poverty and severity indices along with low HDI and per capita expenditure, while 1 regency/city falls into cluster 2 (advanced area) with the opposite conditions. Trend analysis from 2019 to 2023 indicates cluster composition remains stable, with a positive shift of 2 regencies/cities moving from cluster 1 to cluster 2 in 2023.

**Keywords:** Clustering, Development Policy, K-Medoids, Poverty, South Sulawesi

## 1. Pendahuluan

Kemiskinan merupakan permasalahan multidimensional yang menjadi tantangan global, termasuk bagi negara berkembang seperti Indonesia (Hidayat *et al.*, 2023). Meskipun berbagai program bantuan sosial telah diluncurkan, seperti Jaminan Kesehatan Nasional (JKN), Kartu Indonesia Sehat (KIS), dan Kartu Indonesia Pintar (KIP), angka kemiskinan masih menunjukkan tren fluktuatif dalam lima tahun terakhir (Hamdiah, 2024). Berdasarkan data Badan Pusat Statistik (BPS), jumlah penduduk miskin di Indonesia mengalami peningkatan pada tahun 2020 dan 2021 akibat dampak pandemi COVID-19, dan mulai menurun kembali pada tahun 2022 dan 2023. Namun, angka tersebut masih cukup tinggi dan membutuhkan perhatian khusus.

Provinsi Sulawesi Selatan merupakan salah satu daerah dengan jumlah penduduk miskin yang cukup signifikan, berada di peringkat ke-11 dari 34 provinsi di Indonesia pada tahun 2022 dengan jumlah penduduk miskin mencapai 275,44 ribu jiwa (BPS, 2023). Sulawesi Selatan terdiri atas 24 kabupaten/kota yang memiliki karakteristik sosial dan ekonomi yang berbeda-beda. Untuk memahami pola kemiskinan di wilayah ini secara lebih mendalam, diperlukan pendekatan analitik yang mampu mengelompokkan wilayah-wilayah tersebut berdasarkan kesamaan karakteristik faktor-faktor kemiskinan.

Salah satu metode yang relevan untuk tujuan tersebut adalah metode *clustering*. *Clustering* merupakan metode analisis data yang sering digunakan untuk mengelompokkan data dalam kelompok-kelompok tertentu berdasarkan karakteristik yang ditentukan. Salah satu metode *clustering* yang dapat digunakan yaitu algoritma *K-Medoids*. Metode ini lebih tahan terhadap data ekstrem (*outlier*) dibandingkan *K-Means*, karena menggunakan titik aktual dalam *dataset* sebagai pusat *cluster* (Arbain *et al.*, 2023). Beberapa penelitian terdahulu (Sinatrya & Wardhani, 2018; Safitri *et al.*, 2021; Sari & Ediwijoyo, 2021; Zahra *et al.*, 2024) telah membuktikan keandalan *K-Medoids* dalam pemetaan wilayah miskin, namun beberapa penelitian tersebut tidak menggunakan variabel seperti rata-rata lama sekolah dan kepadatan penduduk yang dapat mempengaruhi tingkat kemiskinan di suatu daerah serta sebagian besar hanya fokus pada hasil pengelompokan tanpa menggali karakteristik masing-masing *cluster* secara mendalam.

Tujuan penelitian ini adalah mengelompokkan wilayah kabupaten/kota di Provinsi Sulawesi Selatan dengan menggunakan sembilan indikator kemiskinan, antara lain kedalaman dan keparahan kemiskinan, pengangguran terbuka, usia harapan hidup, IPM, pengeluaran per kapita, lama sekolah rata-rata, PDRB, dan kepadatan penduduk. Selain itu, penelitian ini juga menganalisis profil masing-masing cluster dan pola perubahannya selama periode 2019 hingga 2023. Diharapkan hasil penelitian ini dapat memberikan wawasan komprehensif bagi pengambil kebijakan dalam merancang strategi penanggulangan kemiskinan yang lebih tepat sasaran.

## 2. Metode

Penelitian ini menggunakan pendekatan kuantitatif dengan metode *K-Medoids Clustering* untuk mengelompokkan kabupaten/kota di Provinsi Sulawesi Selatan berdasarkan berbagai indikator kemiskinan, serta menganalisis karakteristik masing-masing *cluster* yang terbentuk.

## 2.1 Data dan Variabel

Data yang digunakan merupakan data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) melalui situs resmi <https://www.bps.go.id>. Objek penelitian mencakup 24 kabupaten/kota di Provinsi Sulawesi Selatan seperti pada Tabel 1.

Tabel 1. Data Kabupaten/Kota di Sulawesi Selatan

No	Nama Kabupaten/Kota	No	Nama Kabupaten/Kota
1	Kepulauan Selayar	13	Makassar
2	Maros	14	Pare-pare
3	Luwu	15	Palopo
4	Tana Toraja	16	Bulukumba
5	Luwu Utara	17	Jeneponto
6	Bantaeng	18	Takalar
7	Pangkep	19	Gowa
8	Wajo	20	Sinjai
9	Pinrang	21	Bone
10	Enrekang	22	Barru
11	Luwu Timur	23	Soppeng
12	Toraja Utara	24	Sidrap

Penelitian ini menggunakan sembilan variabel sebagai indikator kemiskinan, yaitu:

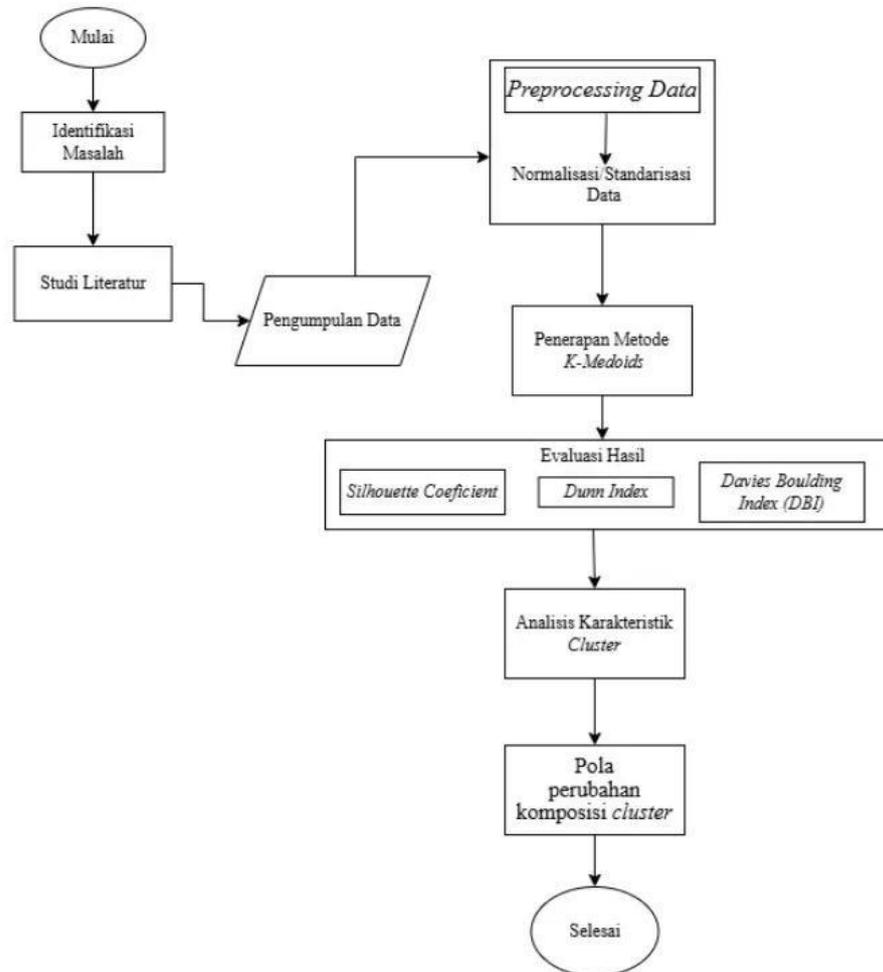
1. Indeks kedalaman kemiskinan
2. Indeks keparahan kemiskinan
3. Tingkat pengangguran terbuka
4. Umur harapan hidup
5. Indeks Pembangunan Manusia (IPM)
6. Pengeluaran per kapita
7. Rata-rata lama sekolah
8. Produk Domestik Regional Bruto (PDRB)
9. Kepadatan penduduk

Dalam penelitian ini, kesembilan variabel tersebut dipilih karena merepresentasikan dimensi penting yang berkontribusi terhadap kondisi kemiskinan, baik dari aspek ekonomi, pendidikan, maupun kesehatan. Penggunaan data dalam rentang waktu lima tahun (2019–2023) memberikan gambaran yang lebih komprehensif terkait dinamika kemiskinan yang terjadi di wilayah tersebut, termasuk perubahan atau pergeseran pola yang mungkin timbul akibat kebijakan pemerintah maupun faktor eksternal seperti pandemi.

Dengan pendekatan *K-Medoids Clustering*, setiap kabupaten/kota akan dikelompokkan berdasarkan kemiripan karakteristik terhadap sembilan variabel tersebut. Pendekatan ini dipilih karena lebih tahan terhadap *outlier* dibandingkan metode lain seperti *K-Means*, sehingga hasil cluster yang diperoleh diharapkan lebih stabil dan representatif. Analisis terhadap karakteristik masing-masing *cluster* selanjutnya dapat digunakan sebagai dasar dalam merumuskan strategi penanggulangan kemiskinan yang lebih spesifik dan tepat sasaran sesuai dengan profil wilayah.

## 2.2 Tahapan Penelitian

Berikut tahapan penelitian dapat dilihat pada Gambar 1 dibawah :



Gambar 1. Alur Tahapan Penelitian

1. Identifikasi masalah: Menentukan permasalahan utama terkait tingkat kemiskinan yang belum merata antar wilayah di Provinsi Sulawesi Selatan.
2. Studi literatur: Mengkaji referensi terdahulu mengenai analisis kemiskinan dan metode *clustering*.
3. Pengumpulan data dan Eksplorasi Data: Mengambil data kemiskinan kabupaten/kota di Provinsi Sulawesi Selatan dari BPS dan melakukan eksplorasi data dengan statistik deskriptif.
4. Pra-pemrosesan data: Normalisasi data dilakukan untuk menyamakan skala antar variabel, mengingat metode *K-Medoids* sensitif terhadap skala. Normalisasi merujuk pada standarisasi fitur dengan menghitung rata-rata (*mean*) dan standar deviasi (*std*) untuk setiap fitur (kolom) lalu mengubah nilai menjadi seperti (1):

$$z = \frac{x - \text{mean}}{\text{std}} \quad (1)$$

Tujuannya agar fitur memiliki distribusi dengan nilai mean 0 dan variansi 1.

5. Penerapan metode *K-Medoids* (Andini & Arifin, 2020) :
  - a. Menentukan jumlah *cluster* (*k*) secara acak

b. Menghitung jarak antar objek menggunakan *Euclidean Distance* seperti dalam (2) :

$$d(i, j) = \sum_{k=1}^n (x_{ik} - x_{jk})^2 \quad (2)$$

Keterangan :

- $d(i, j)$  = Jarak *Euclidean* antara titik  $i$  dan  $j$ .  
 $x_{ik}$  dan  $x_{jk}$  = Koordinat ke- $k$  dari masing-masing titik data  
 $n$  = Jumlah dimensi atribut yang digunakan

- c. Menentukan pusat *cluster* awal (medoid)  
 d. Memperbarui medoid berdasarkan evaluasi jarak total  
 e. Iterasi hingga medoid *konvergen*

6. Evaluasi hasil *clustering*:

- a. *Silhouette Coefficient*: Menilai konsistensi internal objek dalam *cluster* seperti dalam (3) (Atira & Sari, 2023).

$$s(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \quad (3)$$

Keterangan :

- $a(i)$  = rata-rata jarak antara  $i$  dengan semua titik lain dalam *cluster* yang sama  
 $b(i)$  = nilai minimum rata-rata jarak  $i$  ke semua titik dalam *cluster* lain

b. *Davies-Bouldin Index (DBI)*: Mengukur tingkat pemisahan antar *cluster* seperti dalam (4).

$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \left( \frac{s_i + s_j}{M_{i,j}} \right) \quad (4)$$

Keterangan :

- $S_i$  = ukuran penyebaran *cluster*  $i$ , biasanya rata-rata jarak titik dalam *cluster*  $i$  ke centrodinya  
 $M_{i,j}$  = Jarak antara centroid *cluster*  $i$  dan  $j$ .

c. *Dunn Index*: Menilai rasio antara jarak minimum antar *cluster* dan jarak maksimum dalam satu *cluster* seperti dalam (5).

$$D = \frac{\min_{i \neq j} \delta(C_i, C_j)}{\max_k \Delta(C_k)} \quad (5)$$

Keterangan :

- $\delta(C_i, C_j)$  = jarak antara *cluster*  $i$  dan  $j$  (misal jarak antara minimum antara titik di dua *cluster*)  
 $\Delta(C_k)$  = diameter *cluster*  $k$

### 3. Hasil dan Pembahasan

#### 3.1 Pengumpulan Data

Proses pengumpulan data dalam penelitian ini bertujuan untuk memperoleh informasi yang relevan mengenai faktor-faktor kemiskinan di Provinsi Sulawesi Selatan. Data diperoleh secara daring dari situs resmi Badan Pusat Statistik (BPS) mulai dari tahun 2019-2023 dengan cakupan 24 kabupaten/kota. Variabel yang dikumpulkan mencerminkan aspek multidimensional kemiskinan, termasuk indikator ekonomi, pendidikan, kesehatan, dan demografi.

Tabel 2 menyajikan sebagian contoh data yang diperoleh, yang terdiri dari sembilan variabel utama seperti Indeks Kedalaman Kemiskinan, Indeks Keparahan Kemiskinan, Tingkat Pengangguran Terbuka, dan lainnya. Data ini menjadi dasar untuk tahapan analisis deskriptif dan proses *clustering* dengan metode *K-Medoids*.

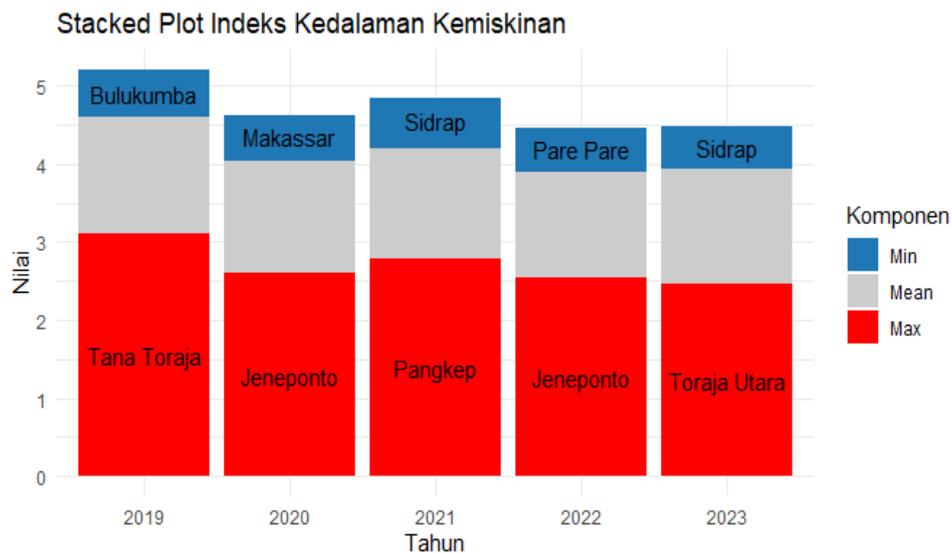
Tabel 2. Data Faktor-faktor Kemiskinan di Provinsi Sulawesi Selatan

No	Nama Kabupaten/Kota	Indeks Kedalamam Kemiskinan	Indeks Keparahan Kemiskinan	Tingkat Pengangguran Terbuka	...
1.	Kepulauan Selayar	0,25	0,6	2,44	...
2.	Bukumba	0,72	0,14	3,42	...
3.	Bantaeng	0,97	0,18	4,27	...
4.	Jeneponto	2,6	0,68	2,31	...
5.	Takalar	1,09	0,21	4,16	...
...	...	...	...	...	...

#### 3.2 Statistik Deskriptif

Statistik deskriptif digunakan untuk menggambarkan karakteristik umum dari masing-masing variabel yang dianalisis. Analisis ini penting untuk memahami distribusi nilai, serta pola-pola awal yang mungkin muncul sebelum data diolah lebih lanjut. Secara visual, distribusi variabel dianalisis dengan stacked plot dan grafik lainnya yang menunjukkan perubahan nilai tiap indikator selama periode 2019–2023.

Sebagai contoh pada Gambar 2, Indeks Kedalaman Kemiskinan tertinggi di tahun 2019 tercatat di Kabupaten Tana Toraja, sedangkan yang terendah di Bulukumba. Fenomena serupa terjadi pada variabel lainnya seperti pengangguran terbuka, IPM, dan pengeluaran per kapita, yang memperlihatkan kesenjangan antarwilayah. Kota Makassar secara konsisten menempati posisi tertinggi dalam indikator pembangunan dan ekonomi, sedangkan Jeneponto dan kabupaten lainnya cenderung berada pada posisi terendah dalam beberapa aspek.



Gambar 2. Indeks Kedalaman Kemiskinan

Visualisasi data dari masing-masing indikator ini sangat penting untuk menegaskan adanya ketimpangan spasial antar kabupaten/kota di Sulawesi Selatan, serta memberikan dasar yang kuat dalam pembentukan *cluster* di tahap analisis selanjutnya.

### 3.3 Preprocessing Data

Proses preprocessing adalah tahap penting dalam analisis data yang bertujuan untuk memastikan data yang digunakan memiliki kualitas dan konsistensi yang baik. Dalam penelitian ini, proses *preprocessing* dilakukan dengan pendekatan normalisasi atau standarisasi data. Hal ini disebabkan oleh perbedaan skala pengukuran antar variabel, seperti dalam bentuk indeks, persentase, dan satuan rupiah.

Normalisasi dilakukan dengan tujuan agar setiap variabel memiliki pengaruh yang seimbang dalam proses analisis *clustering*. Metode yang digunakan adalah *z-score standardization*, yang mengubah distribusi data sehingga memiliki rata-rata nol (0) dan simpangan baku satu (1). Proses ini membantu dalam menghilangkan dominasi variabel dengan nilai skala yang lebih besar dan meningkatkan akurasi proses pengelompokan. Berikut contoh hasil normalisasi data Tabel 3 :

Tabel 3. Hasil Normalisasi Data

Kabupaten	var1_2019	var1_2020	var1_2021	var1_2022	....
K.Selayar	2,87	2,25	2,09	2,15	....
Bulukumba	0,6	0,71	1	0,99	....
Bantaeng	1,35	0,97	1,23	1,32	...
Jeneponto	2,02	2,6	1,64	2,54	...
Takalar	1,08	1,09	1,03	0,88	...
....	....	....	...	...	...

### 3.4 Penerapan Algoritma *K-Medoids*

Penerapan algoritma *K-Medoids* dilakukan dengan Python untuk melihat pola klasterisasi suatu wilayah di Sulawesi Selatan berdasarkan faktor-faktor yang mempengaruhi tingkat kemiskinan. Berikut langkah-langkah yang dilakukan dalam penerapan algoritma *K-Medoids*:

#### a. Penentuan Pusat *Cluster* Awal

Algoritma *K-Medoids* diawali dengan penentuan *medoid* awal sebanyak  $k = 3$ , sesuai jumlah *cluster* yang ditetapkan. Selanjutnya memilih *medoids* secara acak. Objek yang dipilih sebagai *medoid* awal adalah Maros (*Cluster* 1), Pinrang (*Cluster* 2), dan Soppeng (*Cluster* 3) seperti pada Tabel 4.

Tabel 4. Pusat Cluster Awal

Kabupaten	Var1_2019	Var2_2019	...	Var9_2023	Medoid
Maros	1.28480453	1.85603598	...	-0.25030644	1
Pinrang	0.04311425	0.09009883	...	-0.26475554	2
Soppeng	-1.05629903	-0.91900811	...	-0.27862667	3

#### b. Perhitungan Jarak terhadap *Medoid*

Setelah *medoid* awal ditentukan, langkah selanjutnya adalah menghitung jarak antara masing-masing data (kabupaten/kota) terhadap setiap *medoid* menggunakan rumus *Euclidean distance*. Semakin rendah nilai jarak antar suatu data, maka karakteristik suatu data tersebut mirip. Berikut adalah contoh perhitungan jarak antara Kabupaten Kepulauan Selayar terhadap ketiga *medoid* awal:

Jarak ke Medoid 1 (Maros):  $d(1,9) = 2.069$

Jarak ke Medoid 2 (Pinrang):  $d(1,15) = 3.208$

Jarak ke Medoid 3 (Soppeng):  $d(1,12) = 4.164$

Proses ini dilakukan untuk seluruh kabupaten dan hasilnya ditampilkan dalam Tabel 5 sebagai berikut :

Tabel 5. Hasil Perhitungan Jarak terhadap *Medoid*

Kabupaten/Kota	Jarak ke medoid 1	Jarak ke medoid 2	Jarak ke medoid 3	Cluster
Kep.Selayar	2.069788	3.207561	4.1644158	1
Bulukumba	3.9213789	2.124682	1.0563746	3
Bantaeng	2.943655	1.590402	1.886337	2
Jeneponto	3.155278	3.031331	3.022022	3
Takalar	3.3780629	2.0916780	1.5619653	3
Gowa	3.491778	1.899198	0.9319681	3
Sinjai	3.481118	2.137079	1.4278219	3
Maros	0.000000	2.375067	3.7849192	1
Pangkep	2.632910	1.966622	2.5460891	2
Barru	3.166616	1.612938	1.5220577	3
Bone	3.247021	2.482207	1.9956779	3
Soppeng	3.784919	2.035797	0.0000000	3

Wajo	3.266545	1.717588	2.1267318	2
Sidrap	3.766453	1.715058	1.5341109	3
Pinrang	2.375067	0.000000	2.0357971	2
Enrekang	2.933709	1.395658	2.4163513	2
Luwu	1.186266	2.255444	3.5256328	1
Tana Toraja	3.177558	4.459326	5.2366692	1
Luwu Utara	1.402638	1.672644	3.2310732	1
Luwu Timur	3.372075	1.330320	2.2983765	2
Toraja Utara	3.217493	2.807171	2.9451271	2
Makassar	9.730485	9.026563	9.6204528	2
Pare Pare	5.113847	3.632023	4.1380306	2
Palopo	5.250110	4.491510	5.0312895	2

Berdasarkan Tabel 5 diatas, data dikelompokkan sementara ke dalam tiga *cluster* seperti pada Tabel 6 berikut :

Tabel 6. Hasil *Cluster* Sementara

Kabupaten/Kota	Cluster
Kepulauan Selayar, Maros, Luwu, Tana Toraja, Luwu Utara	1
Bantaeng, Pangkep, Wajo, Pinrang, Enrekang, Luwu Timur, Toraja Utara, Makassar, Pare-pare, Palopo	2
Bulukumba, Jeneponto, Takalar, Gowa, Sinjai, Barru, Bone, Soppeng, Sidrap	3

#### c. Pemilihan *Medoid* Baru

Pemilihan *medoid* baru dilakukan agar pengelompokan data/wilayah dapat terpisah dengan baik. Pemilihan *medoid* baru dalam setiap *cluster* dilakukan berdasarkan total jarak terpendek dari semua anggota *cluster*. *Medoid* baru yang terpilih setelah iterasi pertama adalah:

*Cluster* 1 → Luwu (Total jarak: 7.668)

*Cluster* 2 → Luwu Timur (Total jarak: 27.952)

*Cluster* 3 → Takalar (Total jarak: 12.503)

Proses iterasi dilanjutkan hingga tidak ada lagi perubahan *medoid*.

#### d. Hasil Akhir Clustering

Setelah pemilihan *medoid* baru tidak berubah / *konvergen*, maka proses pengukuran jarak dihentikan. Berikut hasil akhir clustering dengan  $k = 3$  dapat dilihat pada Tabel 7.

Tabel 7. Hasil Akhir *Clustering* ( $K=3$ )

Kabupaten/Kota	Cluster
Kepulauan Selayar, Maros, Luwu, Tana Toraja, Luwu Utara, Toraja Utara	1

Gowa, Barru, Sidrap, Pinrang, Enrekang, Luwu Timur, Makassar, Pare-pare, Palopo	2
Bulukumba , Bantaeng, Jeneponto, Takalar, Sinjai, Pangkep, Bone, Soppeng, Wajo	3

e. Evaluasi Hasil

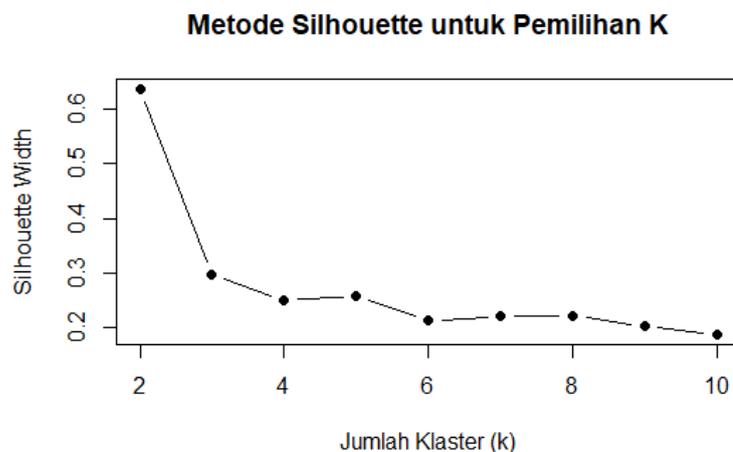
Evaluasi hasil *clustering* pada penelitian ini menggunakan tiga metrik validitas internal, yaitu *Silhouette Coefficient*, *Dunn Index*, dan *Davies-Bouldin Index*. Hasil evaluasi untuk jumlah *cluster*  $k = 3$  disajikan pada Tabel 8 berikut :

Tabel 8. Hasil Evaluasi untuk Jumlah *Cluster*  $k=3$

Metrik Evaluasi	Nilai
<i>Silhouette Coefficient</i>	0.2199
<i>Dunn Index</i>	0.1019
<i>Davies-Bouldin Index</i>	1.7103

Berdasarkan Tabel 8, nilai *Silhouette Coefficient* sebesar 0.2199 menunjukkan bahwa struktur *cluster* yang terbentuk belum optimal. Nilai tersebut mendekati nol, yang mengindikasikan bahwa beberapa objek berada diantara dua *cluster* atau bahkan salah penempatan. Selanjutnya, nilai *Dunn Index* sebesar 0.1019 juga tergolong rendah. Hal ini menandakan bahwa jarak antar *cluster* relatif kecil dibandingkan dengan ukuran dalam *cluster*, yang berarti adanya tumpang tindih antar *cluster*. Selain itu, nilai *Davies-Bouldin Index (DBI)* sebesar 1.7103 termasuk tinggi, yang mengindikasikan bahwa *cluster* yang terbentuk kurang kompak dan tidak saling terpisah dengan baik. Secara keseluruhan, ketiga metrik menunjukkan bahwa hasil *clustering* dengan  $k = 3$  belum menghasilkan pemisahan *cluster* yang baik.

Oleh karena itu, dilakukan pemilihan jumlah *cluster* yang optimal ( $k$  optimal) dengan menguji nilai  $k$  dari  $k=2$  hingga  $k=10$  secara iteratif. Hasil evaluasi  $k$  optimal ditampilkan pada Gambar 3.



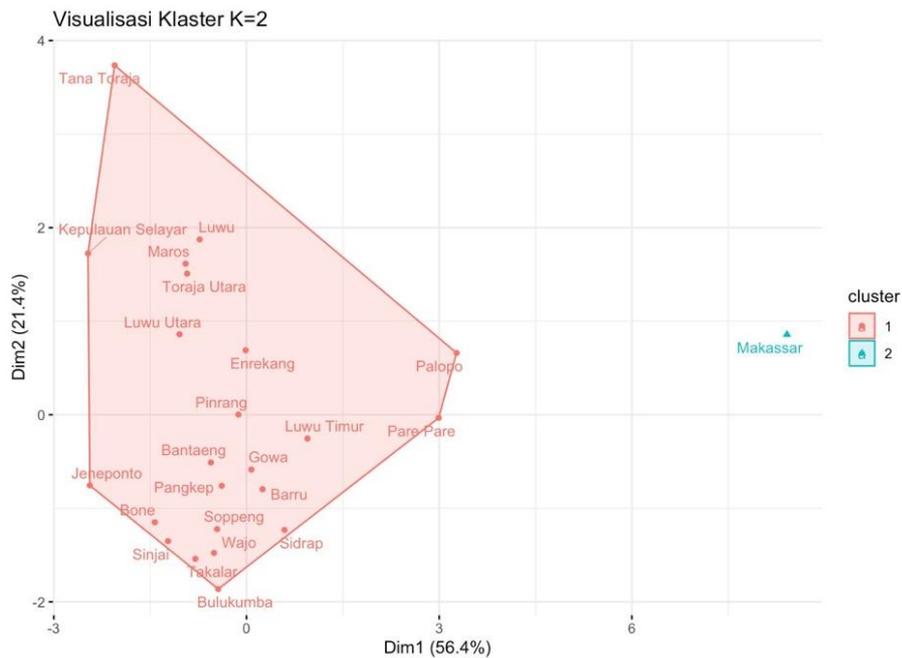
Gambar 2. Pemilihan K-Optimal

Berdasarkan Gambar 3, terlihat bahwa  $k=2$  memberikan hasil yang paling optimal dengan nilai *Silhouette Width* = 0.6369. Oleh karena itu, dilakukan evaluasi ulang menggunakan metrik yang sama untuk jumlah *cluster*  $k = 2$ . Hasil evaluasi disajikan pada Tabel 9 berikut:

Metrik Evaluasi	Nilai
<i>Silhouette Coefficient</i>	0.6369
<i>Dunn Index</i>	0.875
<i>Davies-Bouldin Index</i>	0.254

Hasil evaluasi pada Tabel 9 menunjukkan peningkatan kualitas *clustering* yang signifikan dibandingkan dengan  $k=3$ . Nilai *Silhouette Coefficient* sebesar 0.6369 menunjukkan bahwa sebagian besar objek berada dalam *cluster* yang tepat, dan bahwa pemisahan antar *cluster* cukup jelas. Nilai *Dunn Index* sebesar 0.875 tergolong tinggi, yang menunjukkan bahwa jarak antar *cluster* cukup besar dibandingkan dengan ukuran masing-masing *cluster*. Hal ini berarti bahwa *cluster* yang terbentuk bersifat kompak dan terpisah dengan baik. Sementara itu, *Davies-Bouldin Index* sebesar 0.254, yang tergolong rendah, menunjukkan bahwa rata-rata kemiripan antar *cluster* rendah, sehingga struktur *cluster* yang terbentuk bersifat kuat dan terisolasi satu sama lain.

Dengan demikian, hasil evaluasi ketiga metrik menunjukkan bahwa pemilihan jumlah *cluster*  $k = 2$  memberikan *clustering* yang paling optimal. Hasil akhir pengelompokan wilayah berdasarkan *medoid* akhir untuk  $k = 2$  ditampilkan pada Gambar 4.



Gambar 3. Hasil Clustering dengan  $k=2$

Berdasarkan Gambar 4, diperoleh bahwa semua kabupaten/kota kecuali Kota Makassar masuk pada *Cluster 1* sedangkan hanya Kota Makassar yang masuk pada *Cluster 2*.

#### f. Analisis Karakteristik *Cluster*

Berdasarkan hasil klasterisasi dengan algoritma *K-Medoids*, terbentuk dua *cluster* utama yang mengelompokkan 24 Kabupaten/kota di Sulawesi Selatan menurut sembilan variabel

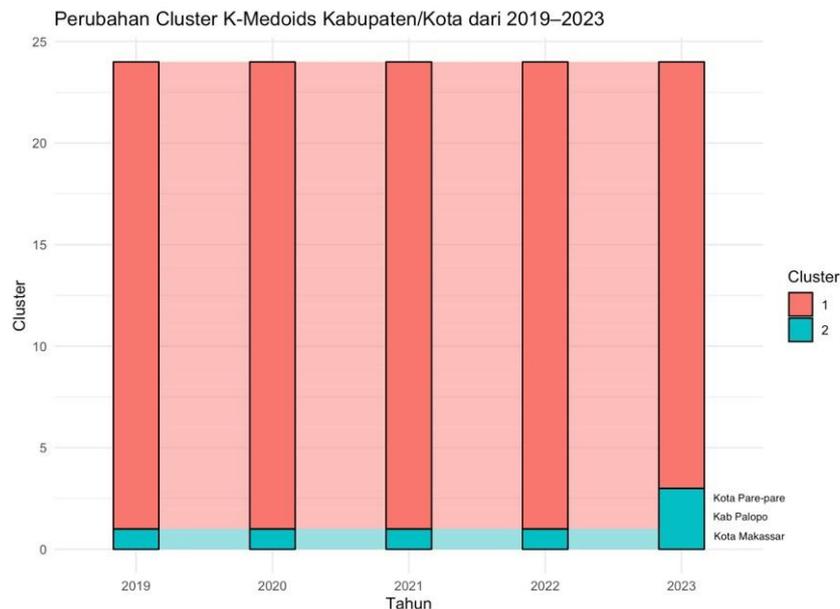
kemiskinan, yaitu *cluster 1* (Kabupaten/Kota Tertinggal) dan *cluster 2* (Kabupaten/Kota Maju). Analisis profil masing-masing *cluster* menunjukkan perbedaan signifikan antara kedua kelompok. *Cluster 1* memiliki indeks kedalaman dan keparahan kemiskinan yang tinggi, IPM (Indeks Pembangunan Manusia) rendah, pengeluaran per kapita dan PDRB yang kecil, serta rata-rata lama sekolah yang lebih rendah. Kepadatan penduduk di *cluster* ini juga relatif rendah, mencerminkan wilayah yang lebih rural.

Sebaliknya, *cluster 2* menunjukkan nilai IPM yang jauh lebih tinggi, harapan hidup lebih panjang, pengeluaran dan PDRB per kapita yang sangat besar, rata-rata lama sekolah yang mencapai tingkat SMA, serta kepadatan penduduk sangat tinggi yang kemungkinan didominasi oleh kawasan perkotaan besar seperti Makassar. Uniknya, tingkat pengangguran terbuka lebih tinggi di *cluster 2*, yang dapat dijelaskan oleh pasar kerja yang lebih besar dan kompleks di wilayah maju tersebut.

#### g. Pola Perubahan Komposisi *Cluster*

Analisis pola perubahan komposisi cluster Kabupaten/Kota di Provinsi Sulawesi Selatan berdasarkan faktor-faktor kemiskinan dilakukan dengan menerapkan algoritma *K-Medoids Clustering* secara tahunan untuk periode 2019 hingga 2023. Proses pengelompokan dilakukan terhadap sembilan variabel indikator kemiskinan untuk setiap tahun secara independen. Hasil dari proses tersebut digunakan untuk memantau dinamika perubahan karakteristik wilayah selama lima tahun terakhir.

Visualisasi hasil perubahan komposisi *cluster* dari tahun 2019 hingga 2023 disajikan pada Gambar 5 berikut :



Gambar 4. Visualisasi Perubahan Komposisi Cluster Kabupaten/Kota Tahun 2019-2023

Berdasarkan Gambar 5, dapat diamati metode bahwa periode tahun 2019 hingga 2022, komposisi *cluster* kabupaten/kota di Provinsi Sulawesi Selatan menunjukkan pola yang relatif stabil. Mayoritas wilayah cenderung tetap berada di dalam *cluster* yang sama dari tahun ke tahun,

yang mengindikasikan bahwa kondisi sosial ekonomi pada wilayah-wilayah tersebut tidak mengalami perubahan yang signifikan selama periode tersebut.

Namun demikian, pada tahun 2023, terjadi perubahan komposisi *cluster* yang cukup signifikan, yang ditandai dengan berpindahnya dua wilayah, yaitu Kota Pare-pare dan Kota Palopo, dari *cluster* 1 ke *cluster* 2. Perpindahan ini mencerminkan adanya peningkatan kinerja wilayah dalam aspek-aspek indikator kemiskinan yang dianalisis.

#### 4. Kesimpulan

Berdasarkan hasil analisis menggunakan metode *K-Medoids Clustering* terhadap sembilan indikator kemiskinan, Kabupaten/Kota di Provinsi Sulawesi Selatan berhasil dikelompokkan ke dalam dua *cluster* utama. Evaluasi dengan tiga metrik validitas internal (*Silhouette Coefficient*, *Dunn Index*, dan *Davies-Bouldin Index*) menunjukkan bahwa konfigurasi dua *cluster* merupakan yang paling optimal.

Selama periode 2019 hingga 2022, komposisi *cluster* cenderung stabil, menunjukkan stagnasi dalam kondisi sosial ekonomi sebagian besar wilayah. Namun, pada tahun 2023 terjadi perubahan signifikan, ditandai dengan perpindahan Kota Parepare dan Kota Palopo dari *cluster* 1 ke *cluster* 2. Hal ini mengindikasikan adanya perbaikan pada aspek-aspek pembangunan sosial ekonomi di wilayah tersebut. Secara keseluruhan, hasil penelitian ini memberikan gambaran pemetaan spasial kemiskinan yang dapat digunakan sebagai dasar perumusan kebijakan pembangunan daerah yang lebih tepat sasaran dan berkeadilan.

#### Daftar Pustaka

- Andini, A.D., & Arifin, T. (2020). Implementasi Algoritma K-Medoids untuk Klasterisasi Data Penyakit Pasien di RSUD Kota Bandung. *Jurnal Responsif: Riset Sains dan Informatika*, 2(2), 128-138.
- Arbain, D., Sriyanto, S., & Triloka, J. (2023). Perbandingan Kinerja Algoritma K-Medoids Dan K-Means Untuk Klasifikasi Penyakit Kanker Serviks. In *Prosiding Seminar Nasional Darmajaya* (Vol. 1, pp. 118-131).
- Atira, A., & Sari, B. N. (2023). Penerapan Silhouette Coefficient, Elbow Method dan Gap Statistics untuk Penentuan Cluster Optimum dalam Pengelompokan Provinsi di Indonesia Berdasarkan Indeks Kebahagiaan. *Jurnal Ilmiah Wahana Pendidikan*, 9(17), 76-86.
- BPS. (2023). Data Kemiskinan Indonesia. Retrived from <https://sulsel.bps.go.id/id>
- Hamdiah, V. (2024). Peran Kebijakan Fiskal dalam Mengevaluasi Zakat sebagai Upaya Menyikapi Kemiskinan di Indonesia. *Jurnal Ilmiah Ekonomi Islam*, 10(1), 333-339.
- Hidayat, F. P., Putra, R. P., Alfitriah, M. D., & Widodo, E. (2023). Implementasi Clustering K-Medoids dalam Pengelompokan Kabupaten di Provinsi Aceh Berdasarkan Faktor yang Mempengaruhi Kemiskinan. *Indonesian Journal of Applied Statistics*, 5(2), 121-130.
- Safitri, P. N., Aristawidya, R., & Faradilla, S. B. (2021). Klasterisasi Faktor-Faktor Kemiskinan Di Provinsi Jawa Barat Menggunakan K-Medoids Clustering. *Journal of Mathematics Education and Science*, 4(2), 75–80. <https://doi.org/10.32665/james.v4i2.242>
- Sari, F. D. R., & Ediwijoyo, S. P. (2021). Pemetaan Tingkat Kemiskinan Di Provinsi Jawa Tengah Berdasarkan Kabupaten/Kota Dengan Metode K-Medoids, *J. Media Inform. Budidarma*, 5(4), 1528.

- Sinatrya, N. S., & Wardhani, L. K. (2018, August). Analysis of K-Means and K-Medoids's Performance Using Big Data Technology. In *2018 6th International Conference on Cyber and IT Service Management (CITSM)* (pp. 1-5). IEEE.
- Zahra, F., Khalif, A., Sari, B. N., Karawang, U. S., Timur, T., & Barat, J. (2024). *Provinsi Indonesia Menggunakan Algoritma K-Medoids*. 12(2).