

Perbandingan Metode *K-Means* dan OPTICS dalam Penggerombolan Kemiskinan Multidimensi di Indonesia

Devi Permata Sari^{1*}, Tasya Anisah Rizqi², Anwar Fitrianto³, Erfiani M.S⁴, L.M. Risman Dwi Jumansyah⁵

^{1,2,3,4,5} Sekolah Sains Data, Matematika, dan Informatika, Statistika dan Sains Data, Institut Pertanian Bogor, Kabupaten Bogor, Indonesia.

^{*)}email: dvprmta@gmail.com

Abstrak

Kemiskinan multidimensi tetap menjadi tantangan serius di Indonesia meskipun telah mengalami penurunan dalam beberapa tahun terakhir. Penelitian ini bertujuan menganalisis dan membandingkan pola kemiskinan multidimensi di 34 provinsi Indonesia menggunakan metode *K-Means* dan *OPTICS Clustering*. Data kemiskinan multidimensi yang digunakan mencakup aspek ekonomi, pendidikan, ketenagakerjaan, dan standar hidup dari Badan Pusat Statistik. Analisis statistik deskriptif mengungkapkan kesenjangan signifikan antar provinsi dalam berbagai dimensi kemiskinan, dengan korelasi tertinggi sebesar 0,4 antara dimensi pendidikan dan status ketenagakerjaan. *K-Means Clustering* mengidentifikasi 5 cluster provinsi dengan karakteristik beragam, menunjukkan adanya trade-off antara akses fasilitas dan tingkat kemiskinan. Sementara itu, *OPTICS Clustering* menghasilkan 2 cluster utama, dengan cluster 1 terdiri dari 24 provinsi yang memiliki kondisi cenderung homogen dan cluster 2 terdiri dari 7 provinsi dengan karakteristik yang berbeda secara signifikan. Perbandingan performa menunjukkan *OPTICS* unggul dengan nilai *Silhouette Index* dan *WCSS* yang lebih baik dibandingkan *K-Means*. Temuan ini memberikan kontribusi penting dalam analisis kemiskinan multidimensi di Indonesia dan dapat dimanfaatkan untuk merancang program pengentasan kemiskinan yang lebih terlokalisasi sesuai karakteristik masing-masing cluster.

Kata kunci: Kemiskinan multidimensi, Clustering, *K-Means*, *OPTICS*, Analisis regional, Pengentasan kemiskinan

Abstract

Multidimensional poverty remains a serious challenge in Indonesia despite its decline in recent years. This study aims to analyze and compare multidimensional poverty patterns across 34 Indonesian provinces using K-Means and OPTICS Clustering methods. The multidimensional poverty data used includes economic, educational, employment, and living standards aspects from the Central Bureau of Statistics. Descriptive statistical analysis reveals significant disparities among provinces across various poverty dimensions, with the highest correlation of 0.4 between education and employment status dimensions. K-Means Clustering identifies 5 clusters of provinces with diverse characteristics, showing a trade-off between facility access and poverty levels. Meanwhile, OPTICS Clustering produces 2 main clusters, with cluster 1 consisting of 24 provinces having relatively homogeneous conditions and cluster 2 comprising 7 provinces with significantly different characteristics. Performance comparison shows that OPTICS is superior with better Silhouette Index and WCSS values

^{*)} Corresponding Author

Diterima: 15-10-2024, Disetujui: 27-11-2024, Diterbitkan: 30-11-2024

compared to K-Means. These findings provide important contributions to the analysis of multidimensional poverty in Indonesia and can be utilized to design more localized poverty alleviation programs according to the characteristics of each cluster.

Keywords: *Multidimensional poverty, Clustering, K-Means, OPTICS, Regional analysis, Poverty alleviation*

Format sitasi: D. P. Sari, T. A. Rizqi, A. Fitrianto, E. M. S, dan L. M. R. D. Jumansyah, "Perbandingan Metode *K-Means* dan OPTICS dalam Penggerombolan Kemiskinan Multidimensi di Indonesia", *KUBIK J. Publ. Ilm. Mat.*, Vol. 9, No. 1, pp. 1-9, 2024.

Pendahuluan

Analisis *clustering* semakin populer dalam studi sosial-ekonomi, memungkinkan identifikasi pola dalam data kompleks. Tinjauan teknik *clustering* menunjukkan berbagai pendekatan untuk memahami dinamika kemiskinan [1]. Selain itu, aplikasi pembelajaran mesin dalam pemetaan kemiskinan menunjukkan potensi teknologi ini dalam menciptakan peta yang lebih akurat [2]. Pada analisis sosial-ekonomi, dua metode *clustering* yang dapat dibandingkan adalah *K-Means* dan OPTICS (*Ordering Points To Identify the Clustering Structure*). Sebuah penelitian komparatif antara *K-Means* dan OPTICS menunjukkan bahwa masing-masing metode memiliki kekuatan dan kelemahan dalam analisis sosial-ekonomi. *K-Means* dikenal efisien dan sederhana, tetapi memiliki keterbatasan dalam menangani *cluster* non-spherical dan kepadatan bervariasi. Sebaliknya, OPTICS unggul dalam mendeteksi *cluster* arbitrer dan dapat mengungkapkan struktur hierarkis dalam data, meskipun lebih kompleks secara komputasi [3][4]. Penelitian lebih lanjut mengeksplorasi perbedaan antara OPTICS dan *K-Means* dalam analisis sosial-ekonomi, menemukan bahwa OPTICS lebih efektif dalam mengidentifikasi kelompok kemiskinan yang memiliki karakteristik spasial yang kompleks [4].

Beberapa penelitian terdahulu telah menerapkan metode *K-Means* untuk menganalisis kemiskinan regional di Indonesia. *Clustering* kemiskinan di kabupaten/kota menghasilkan empat cluster dengan karakteristik berbeda [5]. Perbandingan *K-Means* dengan Average Linkage di Jawa Tengah menunjukkan *Average Linkage* lebih unggul berdasarkan *Silhouette Index* [6] sementara di Bogor, perbandingan dengan metode *Agglomerative* menunjukkan hasil yang setara dengan nilai perbandingan cluster 49,4% [7]. Melalui penerapan *K-Means*, penelitian berhasil mengidentifikasi dan mengelompokkan pantun-pantun yang diperoleh dari twitter atau X 9ke dalam berbagai topik yang berbeda [8]. Meskipun demikian, belum ada penelitian yang membandingkan *K-Means* dengan metode density-based seperti OPTICS untuk kasus kemiskinan regional.

Sementara itu, beberapa penelitian telah mengeksplorasi penggunaan algoritma OPTICS dalam analisis sosial-ekonomi. OPTICS terbukti efektif dalam menangani data dengan densitas bervariasi [9], menghasilkan cluster yang lebih natural pada analisis pola konsumsi air rumah tangga [10], dan menunjukkan akurasi yang baik ketika dikombinasikan dengan GIS untuk analisis pola spasial [11]. Meskipun tidak diterapkan langsung pada data kemiskinan, metodologi ini menunjukkan potensi OPTICS dalam analisis sosial-ekonomi yang kompleks.

Meskipun beberapa penelitian sebelumnya memberikan wawasan penting, namun perbandingan *K-Means* dan OPTICS jarang dilakukan, terutama dalam analisis kemiskinan [12]. Sebuah penelitian menggunakan *K-Means* untuk mengidentifikasi indikator kemiskinan multidimensi pada kelompok 40% terbawah di Malaysia, namun tidak membandingkannya dengan metode lain [1]. *K-Means* cenderung menghasilkan *cluster* berbentuk bola dan kesulitan menangani noise, sementara OPTICS lebih fleksibel untuk *cluster* berbentuk *arbitrary* dan dapat menangani *noise* [12].

Perbandingan ini juga dapat memberikan wawasan baru mengenai pemilihan metode *clustering* yang tepat untuk analisis kebijakan pengentasan kemiskinan di Indonesia.

Kemiskinan masih menjadi masalah serius di Indonesia meskipun ada penurunan. Pada Maret 2024, persentase penduduk miskin turun menjadi 9,03% dengan total 25,22 juta orang. Kesenjangan antara daerah perkotaan (7,09%) dan perdesaan (11,79%) dengan Garis Kemiskinan Rp582.932 per kapita per bulan [13] mencerminkan kompleksitas permasalahan yang dipengaruhi berbagai faktor sosial ekonomi [14]. Dalam konteks ini, metode *clustering* menjadi alat potensial untuk mengidentifikasi pola kemiskinan di Indonesia untuk pengentasan yang lebih tepat sasaran.

Kemiskinan di Indonesia tidak hanya dapat diukur dari segi pendapatan, tetapi juga perlu dilihat dari berbagai dimensi lain yang mencerminkan kualitas hidup masyarakat. Lembaga Riset dan Advokasi Kebijakan Publik The PRAKARSA telah meluncurkan laporan Indeks Kemiskinan Multidimensi (IKM) di Indonesia yang mengukur kemiskinan dari aspek pendidikan, kesehatan, dan standar hidup. Hasil pengukuran IKM menunjukkan adanya penurunan jumlah penduduk miskin multidimensi dari 120,1 juta jiwa pada tahun 2012 menjadi 38,95 juta jiwa pada tahun 2021. Pendekatan multidimensi ini dianggap dapat memberikan gambaran yang lebih komprehensif tentang kondisi kemiskinan di Indonesia dan membantu pemerintah dalam menentukan intervensi kebijakan yang lebih efektif [15]. Pemahaman tentang kemiskinan multidimensi ini juga sejalan dengan upaya Credit Union seperti CU Pancur Kasih dalam memberikan pendidikan keuangan dan pemberdayaan ekonomi kepada anggotanya untuk mengatasi berbagai aspek kemiskinan [16].

Variabel-variabel kemiskinan multidimensi yang digunakan dalam penelitian ini mencakup empat dimensi utama: ekonomi, pendidikan, ketenagakerjaan, dan standar hidup. Pemilihan variabel ini didasarkan pada penelitian [17], yang menekankan pentingnya pendekatan multidimensi dalam mengukur kemiskinan, serta mempertimbangkan konteks spesifik Indonesia yang mencakup aspek perkotaan dan perdesaan. Penelitian ini bertujuan untuk menganalisis dan membandingkan efektivitas metode *clustering K-Means* dan OPTICS dalam mengidentifikasi pola kemiskinan multidimensi di Indonesia. Kebaruan penelitian ini terletak pada pengembangan framework analisis komparatif yang sistematis untuk mengevaluasi kinerja kedua metode *clustering*, serta memberikan rekomendasi kebijakan pengentasan kemiskinan yang lebih tepat sasaran berdasarkan karakteristik masing-masing klaster yang teridentifikasi.

Metode

Data

Penelitian ini menggunakan data kemiskinan multidimensi dari BPS untuk 34 provinsi di Indonesia tahun 2023, mencakup empat dimensi utama yaitu ekonomi, pendidikan, ketenagakerjaan dan standar hidup berdasarkan penelitian [17] dan [18] Rincian variabel untuk setiap dimensi disajikan pada Tabel 1.

Tabel 1. Variabel kemiskinan multidimensi

Dimensi	Variabel	Notasi
Ekonomi	Garis Kemiskinan atau Tingkat minimum pendapatan (Rupiah per kapita per bulan)	X_1
	Persentase penduduk tamat SD/SMP	X_2
Pendidikan	Persentase penduduk > SMA	X_3
	Tingkat pengangguran terbuka (%)	X_4
Ketenagakerjaan	Persentase rumah tangga dengan jamban sendiri/bersama	X_5
	Persentase rumah tangga dengan akses air layak	X_6
Standar Hidup		

Tahapan Penelitian

Tahapan penelitian ini diadopsi dari metodologi [9] dengan penyesuaian konteks analisis kemiskinan multidimensi di Indonesia. Tahapan penelitian tersusun sebagai berikut.

1. Pengumpulan Data

Data kemiskinan multidimensi dikumpulkan dari BPS untuk 34 provinsi, dengan variabel:

- Ekonomi: X1 (Garis Kemiskinan)
- Pendidikan: X2 (Persentase penduduk tamat SD/SMP), X3 (Persentase penduduk > SMA)
- Ketenagakerjaan: X4 (Tingkat pengangguran terbuka)
- Standar Hidup: X5 (Persentase rumah tangga dengan jamban), X6 (Persentase rumah tangga dengan akses air layak)

2. Pra-pemrosesan Data

Data melalui tahap normalisasi menggunakan Min-Max Scaling untuk menyeragamkan skala dari berbagai variabel menggunakan persamaan 1:

$$X'_{ij} = \frac{X_{ij} - \min(X_j)}{\max(X_j) - \min(X_j)} \quad (1)$$

Definition 1. Dimana x adalah nilai asli, x_{\min} adalah nilai minimum, dan x_{\max} adalah nilai maksimum dari setiap variabel.

3. Implementasi Metode *Clustering*

Dua metode *clustering* digunakan dalam penelitian ini:

a. *K-Means*

- Penentuan jumlah *cluster* optimal dengan metode *elbow* berdasarkan *plotting* WCSS menggunakan persamaan 2.

$$WCSS = \sum_{i=1}^k \sum_{x_i \in C_i} ||x_i - \mu_i||^2 \quad (2)$$

Definition 2. Dimana x_i adalah data *point* dan μ_i adalah *centroid* pada *cluster* C_i .

- Inisialisasi *centroid* acak dan perhitungan jarak *Euclidean* menggunakan Persamaan 3:

$$d(p, q) = \sqrt{(X_{1p} - X_{1q})^2 + (X_{2p} - X_{2q})^2 + \dots + (X_{np} - X_{nq})^2} \quad (3)$$

Definition 3. Jarak *Euclidean* antara data *point* (p) dan *centroid* (q)

- Pengelompokan data ke cluster terdekat dan pembaruan *centroid* dengan rata-rata titik dalam cluster
- Pengulangan langkah 2-3 hingga konvergen (posisi *centroid* tidak berubah signifikan)

b. OPTICS

- Parameter ϵ (*epsilon*) dan *MinPts* ditentukan berdasarkan karakteristik dataset [19], dimana ϵ dipilih dengan *k-distance graph* untuk konektivitas antar cluster [37,38] dan *MinPts* dipilih $2 \times$ dimensi data untuk mereduksi *noise* [39]
- Algoritma mulai dari titik acak dan mengekstraksi tetangga dalam radius ϵ , bersifat *invariant* terhadap urutan pemrosesan
- Core Distance (CD)* dan *Reachability Distance (RD)* dihitung menggunakan persamaan 4 dan 5:

$$core - dist(p) = \min \{dist ||N_{\epsilon}(p)| \geq MinPts\} \quad (4)$$

Definition 4. Dimana $N_\varepsilon(p)$ adalah tetangga dalam radius ε dan MinPts adalah jumlah minimum tetangga

$$react - dist(p, o) = \max \{core - dist(o), d(o, p)\} \quad (5)$$

Definition 5. Dimana $d(o, p)$ adalah jarak antara titik o dan p , sedangkan $core - dist(o)$ adalah jarak inti dari titik o

- 4) Pembentukan cluster melalui pengurutan RD dalam *priority queue*, visualisasi dengan plot RD dimana *valley* menunjukkan cluster dengan densitas tinggi, dan penentuan *threshold* berdasarkan *hierarchical clustering structure*
- c. Evaluasi dan Analisis
Hasil clustering dievaluasi menggunakan *Silhouette Index* untuk mengukur kesesuaian objek dalam *cluster* dan *Within-Cluster Sum of Squares* (WCSS) untuk mengukur kompaktilitas *cluster*. Hasil evaluasi dianalisis untuk interpretasi karakteristik setiap *cluster*, pola kemiskinan multidimensi, dan perbandingan kedua metode yang divisualisasikan dalam bentuk peta atau grafik.


Hasil dan Diskusi

Analisis deskriptif dilakukan terhadap 7 variabel kemiskinan multidimensi untuk 34 provinsi di Indonesia. Ringkasan statistik deskriptif dari masing-masing variabel disajikan pada Tabel 2.

Tabel 2. Hasil Statistik Deskriptif

Variabel	Minimum	Median	Rata-rata	Maksimum
Garis Kemiskinan (Rp)	433.131	584.603	597.448	874.204
Penduduk tamat SD/SMP (%)	35,7	53,4	53,45	66,67
Penduduk > SMA (%)	16,17	26,46	26,63	44,32
Penduduk tidak bekerja/sektor formal (%)	27,22	43,98	43,44	54,38
Kepemilikan jamban sendiri/bersama (%)	54,69	85,66	83,35	98,22
Akses air layak (%)	57,86	82,19	81,65	98,21


Rentang yang lebar pada garis kemiskinan mengindikasikan adanya perbedaan substansial dalam standar hidup minimum antar provinsi. Provinsi dengan garis kemiskinan tinggi mencerminkan biaya hidup yang lebih tinggi, namun juga bisa menunjukkan standar hidup yang lebih baik [20]. Setengah populasi di beberapa provinsi memiliki pendidikan rendah sehingga menghambat upaya pengentasan kemiskinan. Kesenjangan pada populasi berpendidikan tinggi mencerminkan distribusi sumber daya manusia yang tidak merata sehingga berdampak pada perkembangan ekonomi dan sosial [21]. Variasi yang signifikan pada tingkat penduduk yang tidak bekerja atau pengangguran mengindikasikan bahwa hampir setengah dari populasi di banyak provinsi tidak bekerja yang mengakibatkan ketidakstabilan ekonomi dan kerentanan terhadap kemiskinan [22]. Meskipun beberapa provinsi hampir mencapai akses universal, namun hampir setengah populasi masih ada daerah yang tidak memiliki akses fasilitas sanitasi dan air bersih yang layak sehingga berdampak serius pada kesehatan dan kualitas hidup [23].



Gambar 1. Korelasi Antar Variabel

Berdasarkan matriks korelasi pada Gambar 1, terlihat bahwa dimensi pendidikan memiliki korelasi tertinggi dengan status ketenagakerjaan tidak bekerja secara formal sebesar 0.4. Meskipun terdapat beberapa korelasi yang cukup signifikan, secara umum tidak ada korelasi yang sangat tinggi antar variabel (korelasi > 0.7 atau < -0.7) [24], sehingga analisis *cluster* masih dapat dilakukan untuk mengidentifikasi kelompok-kelompok yang memiliki karakteristik serupa.

Langkah pertama implementasi *K-Means clustering* adalah menentukan jumlah *cluster* optimal menggunakan metode *elbow* dan analisis *Silhouette Score*. Hasil analisis disajikan pada Gambar 2.



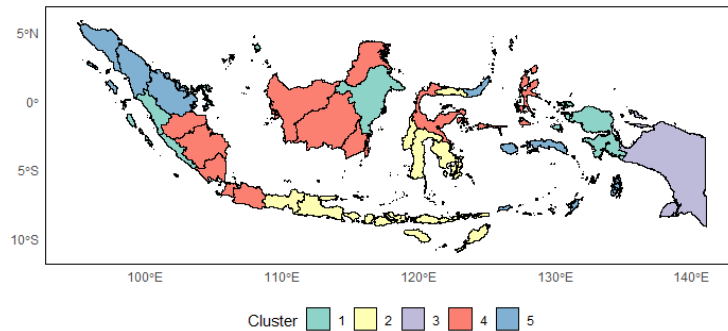
Gambar 2. Average *Silhouette Score* terhadap jumlah *cluster* (k) pada *K-Means*

Hasil analisis pada Gambar 2 menunjukkan bahwa nilai *Silhouette Score* meningkat secara signifikan saat $k = 5$. Titik $k = 5$ ini diidentifikasi sebagai '*elbow point*', yang menandakan jumlah *cluster* optimal. Berdasarkan analisis ini, jumlah *cluster* optimal yang dipilih adalah 5. Setelah menentukan jumlah *cluster*, algoritma *K-Means* membagi 34 provinsi ke dalam 5 kelompok berdasarkan karakteristik kemiskinan multidimensi, seperti yang dirangkum pada Tabel 3.

Tabel 3. Ringkasan Hasil *K-Means Clustering*

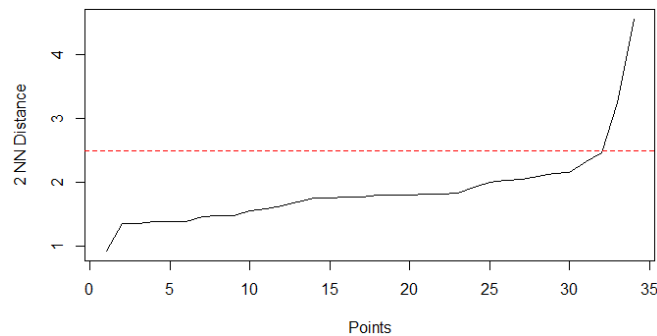
Cluster	Jumlah Provinsi	Karakteristik Utama
1	6	Garis kemiskinan tinggi, pendidikan dasar tinggi
2	10	Garis kemiskinan rendah, pendidikan dasar tinggi
3	1	Garis kemiskinan tinggi, akses fasilitas rendah
4	11	Garis kemiskinan sedang, pendidikan dasar tinggi
5	6	Garis kemiskinan sedang, akses fasilitas tinggi

K-Means clustering menghasilkan 5 *cluster* dengan karakteristik yang bervariasi berdasarkan multidimensi kemiskinan. Pola yang terbentuk mengindikasikan adanya trade-off di mana provinsi dengan akses fasilitas rendah memiliki tingkat kemiskinan tinggi pada *Cluster* 3. Sebaliknya, *Cluster* 5 menunjukkan provinsi dengan akses fasilitas tinggi memiliki tingkat kemiskinan sedang. Visualisasi hasil *K-Means clustering* yang menunjukkan pola geografis disajikan pada Gambar 3.



Gambar 3. Visualisasi Hasil *K-Means clustering* pada Peta Indonesia

Setelah menerapkan *K-Means clustering*, langkah selanjutnya adalah mengimplementasikan algoritma OPTICS (*Ordering Points To Identify the Clustering Structure*). Langkah pertama implementasi OPTICS clustering adalah menentukan nilai *eps* menggunakan metode *elbow*.



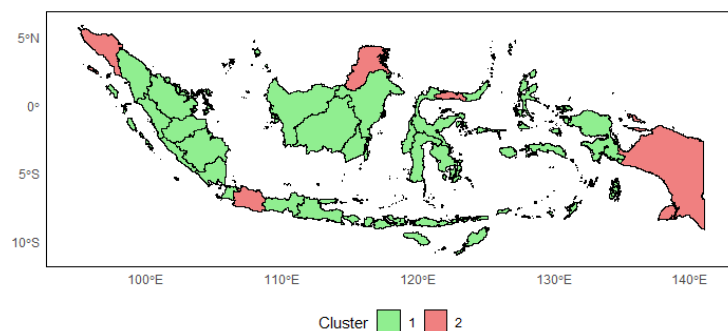
Gambar 4. Kombinasi Parameter Terbaik untuk OPTICS

Hasil analisis pada Gambar 4 menunjukkan bahwa nilai *eps* meningkat dengan tajam saat *eps* = 2.5. Nilai *eps* yang lebih besar menganggap lebih banyak titik sebagai tetangga. *MinPts* adalah jumlah minimum titik dalam radius *eps* untuk menganggap suatu titik sebagai core point. *MinPts* diperoleh dari 2 kalinya banyak variabel. *Eps_cl* adalah nilai epsilon yang digunakan untuk mengekstraksi *cluster* dari urutan titik yang dihasilkan oleh OPTICS. Kombinasi parameter yang dipilih adalah *eps* = 2.5, *MinPts* = 12, dan *eps_cl* = 2.5 dengan nilai *Silhouette Score* tertinggi sebesar 0.1665646.

Hasil *clustering* menunjukkan bahwa OPTICS membagi 34 provinsi di Indonesia menjadi 2 *cluster* utama:

- Cluster* 1: terdiri dari 24 provinsi.
- Cluster* 2: terdiri dari 7 provinsi.


Visualisasi hasil OPTICS clustering yang menunjukkan pola geografis disajikan pada Gambar 5.



Gambar 5. Visualisasi Hasil OPTICS clustering pada Peta Indonesia

OPTICS *clustering* menghasilkan 2 *cluster* dengan karakteristik yang berbeda antar *cluster* berdasarkan multidimensi kemiskinan. *Cluster* 1 umumnya memiliki kondisi ekonomi, pendidikan, ketenagakerjaan, dan akses fasilitas yang cenderung homogen. Sebaliknya, *Cluster* 2 memiliki karakteristik yang berbeda secara signifikan yang menunjukkan pola unik.

Penentuan metode *clustering* dalam menganalisis pola kemiskinan multidimensi di Indonesia dilakukan perbandingan nilai *Silhouette Index* dan *Within-Cluster Sum of Squares* (WCSS). Penelitian [12] menyimpulkan bahwa meskipun *K-Means* dan OPTICS metode yang populer, perbandingan antara keduanya masih jarang dilakukan khususnya dalam kemiskinan.



Gambar 6. (a) Perbandingan *K-Means* dan OPTICS berdasarkan *Silhouette Index*
(b) Perbandingan *K-Means* dan OPTICS berdasarkan *WCSS Index*

Berdasarkan Gambar 6, diperoleh *Silhouette Index* OPTICS menghasilkan nilai yang lebih tinggi dibandingkan *K-Means* di mana OPTICS menunjukkan struktur *cluster* yang lebih baik dan nilai WCSS (*Within-Cluster Sum of Squares*) OPTICS menghasilkan nilai lebih rendah dibandingkan *K-Means* yang menandakan bahwa *cluster* yang dihasilkan OPTICS lebih kohesif dan kompak. Hasil perbandingan ini menunjukkan bahwa dalam konteks analisis pola kemiskinan multidimensi di Indonesia, OPTICS merupakan metode *clustering* yang lebih unggul dibandingkan *K-Means*. OPTICS mampu menangkap struktur *cluster* yang lebih alami meskipun jumlah *cluster* yang dihasilkan lebih sedikit [7,8,11].

Penelitian ini memberikan kontribusi penting dengan membandingkan langsung metode *K-Means* dan OPTICS dalam analisis kemiskinan multidimensi di Indonesia, berbeda dari penelitian sebelumnya yang hanya fokus pada satu metode atau membandingkan dengan pendekatan berbeda [5,9,10]. Temuan ini memiliki implikasi signifikan bagi kebijakan pengentasan kemiskinan. Ini sejalan dengan pandangan [16], yang menekankan pentingnya teknologi berbasis data dalam mendukung pencapaian SDGs, termasuk pengentasan kemiskinan.

Kesimpulan

Penelitian ini mengidentifikasi pola kemiskinan multidimensi di Indonesia dengan membandingkan metode *K-Means* dan OPTICS yang menunjukkan bahwa OPTICS lebih unggul dalam menangkap struktur *cluster* yang alami dan lebih kohesif. Kesenjangan multidimensi antar provinsi menunjukkan pentingnya pendekatan kebijakan yang terlokalisasi. Kontribusi utama penelitian ini adalah penerapan dua metode *clustering* secara langsung yang memberikan wawasan baru dalam analisis kemiskinan di Indonesia. Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi data yang lebih mendalam dan melibatkan lebih banyak dimensi seperti data ketimpangan sosial dan ekonomi, serta mempertimbangkan pendekatan alternatif untuk meningkatkan akurasi *clustering*.

Keterbatasan studi ini adalah penggunaan dua metode *clustering*, yang bisa diperluas dengan metode lain untuk memperkaya analisis seperti *Hierarchical Clustering*.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Badan Pusat Statistik (BPS) atas penyediaan data kemiskinan multidimensi yang digunakan dalam penelitian ini. Ucapan terima kasih juga disampaikan kepada para peneliti terdahulu yang karyanya menjadi referensi penting dalam pengembangan metodologi dan analisis penelitian ini. Penulis berterima kasih kepada rekan-rekan yang telah memberikan masukan dan dukungan selama proses penelitian.

Referensi

- [1] M. A. Rahman, N. S. Sani, R. Hamdan, Z. A. Othman, and A. A. Bakar, "A clustering approach to identify multidimensional poverty indicators for the bottom 40 percent group," *PLoS One*, vol. 16, no. 8 August, pp. 1–25, 2021, doi: 10.1371/journal.pone.0255312.
- [2] O. Hall, F. Dompae, I. Wahab, and F. M. Dzanku, "A review of machine learning and satellite imagery for poverty prediction: Implications for development research and applications," *J. Int. Dev.*, vol. 35, no. 7, pp. 1753–1768, 2023, doi: 10.1002/jid.3751.
- [3] M. A. Ahmed, H. Baharin, and P. N. E. Nohuddin, "Analysis of K-means, DBSCAN and OPTICS Cluster algorithms on Al-Quran verses," *Int. J. Adv. Comput. Sci. Appl.*, vol. 11, no. 8, pp. 248–254, 2020, doi: 10.14569/IJACSA.2020.0110832.
- [4] E. Cesario, P. Lindia, and A. Vinci, "Detecting Multi-Density Urban Hotspots in a Smart City: Approaches, Challenges and Applications," *Big Data Cogn. Comput.*, vol. 7, no. 1, 2023, doi: 10.3390/bdcc7010029.
- [5] S. Annas, B. Poerwanto, S. Sapriani, and M. F. S., "Implementation of K-Means Clustering on Poverty Indicators in Indonesia," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 21, no. 2, pp. 257–266, 2022, doi: 10.30812/matrik.v21i2.1289.
- [6] D. Widyadhana, R. B. Hastuti, I. Kharisudin, and F. Fauzi, "Perbandingan Analisis Kluster K-Means dan Average Linkage untuk Pengklasteran Kemiskinan di Provinsi Jawa Tengah," *Prism. Pros. Semin. Nas. Mat.*, vol. 4, no. 2, pp. 584–594, 2021.
- [7] B. N. Ruchjana, H. Khoirunnisa, I. Irianingsih, and B. Suhandi, "Perbandingan Penerapan Metode Agglomerative dengan Metode K-Means pada Data Curah Hujan di Wilayah Bogor," *Kubik J. Publ. Ilm. Mat.*, vol. 5, no. 2, pp. 71–82, 2020, doi: 10.15575/kubik.v5i2.7581.
- [8] N. Ulinuha and J. G. Indriyani, "Ekstraksi Topik Pantun di Twitter Menggunakan K-Means Clustering," *KUBIK J. Publ. Ilm. Mat.*, vol. 8, no. 1, pp. 24–34, 2023, doi: 10.15575/kubik.v8i1.29191.
- [9] M. Mollaian, G. D. "o, and A. Palazoglu, "Performing Multi-Objective Optimization Alongside," *Processes*, vol. 10, no. 893, pp. 1–22, 2022.
- [10] D. Arsene, A. Predescu, C. O. Truică, E. S. Apostol, and M. Mocanu, "Decision Support Strategies for Household Water Consumption Behaviors Based on Advanced Recommender Systems," *Water (Switzerland)*, vol. 15, no. 14, 2023, doi: 10.3390/w15142550.
- [11] C. Willmes *et al.*, "State of the art in paleoenvironment mapping for modeling applications in archeology—summary, conclusions, and future directions from the paleomaps workshop," *Quaternary*, vol. 3, no. 2, 2020, doi: 10.3390/quat3020013.
- [12] A. Ghosal, A. Nandy, A. K. Das, S. Goswami, and M. Panday, *A Short Review on Different Clustering Techniques and Their Applications*, vol. 937. Springer Singapore, 2020. doi: 10.1007/978-981-13-7403-6_9.
- [13] BPS, "Persentase Penduduk Miskin Maret 2024 turun menjadi 9,03 persen," Badan Pusat Statistik.[Online].Available:<https://www.bps.go.id/id/pressrelease/2024/07/01/2370/persentase-penduduk-miskin-maret-2024-turun-menjadi-9-03-persen-.html>
- [14] A. Sarjito, "Efektivitas Kebijakan Sosial dalam Mengurangi Ketimpangan Pendapatan dan

- Angka Kemiskinan," *J. Ilmu Sos. Polit. dan Hum.*, vol. 6, no. 2, pp. 1–12, 2024, doi: 10.36624/jisora.v6i2.90.
- [15] T. Prakarsa, "Laporan Indeks Kemiskinan Multidimensi PRAKARSA Mendapat Apresiasi Para Pihak," The Prakarsa. Accessed: Sep. 19, 2024. [Online]. Available: <https://theprakarsa.org/laporan-indeks-kemiskinan-multidimensi-prakarsa-mendapat-apresiasi-para-pihak/>
 - [16] C. P. Kasih, "Kemiskinan Struktural: Membongkar Akar Masalah dan Pilihan Solusi," CUPK. Accessed: Sep. 09, 2024. [Online]. Available: <https://cupk.org/kemiskinan-struktural-membongkar-akar-masalah-dan-pilihan-solusi/>
 - [17] A. Wahab and Sudirman, "Persoalan Kemiskinan Perkotaan," *J. Pendidik. Sej. dan Ris. Sos. Hum.*, vol. 6, no. 1, pp. 230–238, 2023.
 - [18] B. Sumargo and N. M. M. Simanjuntak, "Deprivasi Utama Kemiskinan Multidimensi Antarprovinsi di Indonesia," *J. Ekon. dan Pembang. Indones.*, vol. 19, no. 2, pp. 160–172, 2019, doi: 10.21002/jepi.2019.10.
 - [19] K. Gomonov, S. Ratner, I. Lazanyuk, and S. Revinova, "Clustering of EU countries by the level of circular economy: An object-oriented approach," *Sustain.*, vol. 13, no. 13, pp. 1–20, 2021, doi: 10.3390/su13137158.
 - [20] N. L. Made Ariasih and N. N. Yuliarmi, "Pengaruh Tingkat Pendidikan, Tingkat Kesehatan dan Pengangguran Terbuka Terhadap Tingkat Kemiskinan di Provinsi Bali," *Cerdika J. Ilm. Indones.*, vol. 1, no. 7, pp. 821–839, 2021, doi: 10.59141/cerdika.v1i7.131.
 - [21] A. Wardhana, B. Kharisma, and D. S. Sulandari, "Belanja Pemerintah dan Peningkatan Sumber Daya Manusia di Indonesia," *J. Ecodemica J. Ekon. Manaj. dan Bisnis*, vol. 5, no. 2, pp. 139–151, 2021, doi: 10.31294/eco.v5i2.10168.
 - [22] Deris Desmawan, R. N. Ramdani, Y. A. Muralifta, S. Wirantara, and N. E. Handayani, "Pengaruh Kemiskinan Terhadap Pertumbuhan Ekonomi di Provinsi Banten," *INFORMATIKA*, vol. 12, no. 2, pp. 208–215, 2024.
 - [23] R. Firdausi, M. Albar, and M. K. Huda, "Peningkatan Kualitas Hidup Masyarakat Desa Sukoraharjo Melalui Edukasi Kesehatan Dan Sanitasi," *Elit. J. Edukasi Literasi Masy.*, vol. 1, no. 1, pp. 39–43, 2024.
 - [24] M. Yunus, A. Saefuddin, and A. M. Soleh, "Pemodelan Statistical Downscaling Dengan Lasso Dan Group Lasso Untuk Pendugaan Curah Hujan," *Indones. J. Stat. Its Appl.*, vol. 4, no. 4, pp. 649–660, 2020, doi: 10.29244/ijsa.v4i4.724.