

Analisis Tingkat Kemiskinan di Indonesia Dengan Metode DBSCAN

Maria M. Mitan¹, I Wayan Sudiarsa^{2*}, Andrianus Koda³, Stanisilia D. Wero⁴, Moh M. Azmi⁵

^{1,3,4,5} Bisnis Digital, Institut Bisnis dan Teknologi Indonesia

²Bisnis Digital Teknologi Pariwisata Institut Bisnis dan Teknologi Indonesia

*sudiarsa@instiki.ac.id

Abstrak

Kemiskinan merupakan permasalahan multidimensional yang masih menjadi fokus utama pembangunan di Indonesia. Penelitian ini bertujuan untuk menganalisis tingkat kemiskinan kabupaten/kota di Indonesia menggunakan metode Density-Based Spatial Clustering of Applications with Noise (DBSCAN). Data dianalisis menggunakan Google Colaboratory dengan parameter DBSCAN berupa nilai epsilon (ϵ) sebesar 0,5 dan minimum points (MinPts) sebesar 5. Hasil pengujian menunjukkan bahwa metode DBSCAN menghasilkan 2 kluster utama dan 7 data teridentifikasi sebagai noise (cluster -1). Kluster pertama mencakup 68 kabupaten/kota dengan karakteristik tingkat kemiskinan relatif sedang, sedangkan kluster kedua terdiri dari 34 kabupaten/kota dengan tingkat kemiskinan tinggi. Keberadaan data noise menunjukkan wilayah dengan karakteristik kemiskinan yang bersifat ekstrem dan berbeda dari pola umum. Hasil ini membuktikan bahwa DBSCAN mampu mengelompokkan wilayah berdasarkan kepadatan karakteristik kemiskinan serta mengidentifikasi wilayah outlier yang memerlukan perhatian kebijakan khusus.

Kata kunci: Kemiskinan, DBSCAN, Clustering, Machine Learning, Indonesia.

Abstract

Poverty is a multidimensional problem that remains a major focus of development in Indonesia. This study aims to analyze poverty levels across regencies and cities in Indonesia using the Density-Based Spatial Clustering of Applications with Noise (DBSCAN) method. The data were analyzed using

Google Colaboratory with DBSCAN parameters consisting of an epsilon (ϵ) value of 0.5 and a minimum number of points (MinPts) of 5. The results show that the DBSCAN method produces two main clusters, with seven data points identified as noise (cluster -1). The first cluster consists of 68 regencies/cities characterized by relatively moderate poverty levels, while the second cluster includes 34 regencies/cities with high poverty levels. The presence of noise data indicates regions with extreme poverty characteristics that differ from the general pattern. These findings demonstrate that DBSCAN is effective in grouping regions based on the density of poverty-related characteristics and in identifying outlier regions that require special policy attention.

Keywords: Poverty, DBSCAN, Clustering, Machine Learning, Indonesia

1. PENDAHULUAN

Kemiskinan merupakan permasalahan multidimensional yang masih menjadi tantangan utama dalam pembangunan di Indonesia. Meskipun pemerintah telah melaksanakan berbagai program penanggulangan kemiskinan, ketimpangan tingkat kesejahteraan antar wilayah, khususnya pada level kabupaten/kota, masih relatif tinggi. Kondisi ini menunjukkan bahwa kemiskinan tidak hanya dipengaruhi oleh factor ekonomi, tetapi juga oleh aspek pendidikan, kesehatan dan infrastruktur dasar. Oleh karena itu, diperlukan pendekatan analisis yang mampu menggambarkan karakteristik kemiskinan secara komprehensif dan berbasis data. Pendekatan konvensional dalam analisis kemiskinan umumnya menggunakan metode klasifikasi berbasis ambang batas, seperti presentase penduduk miskin atau garis kemiskinan. Pendekatan tersebut cenderung bersifat satu dimensi dan kurang mampu menangkap kompleksitas hubungan antar indikator sosial-ekonomi serta keberadaan

wilayah dengan kondisi ekstrem. Selain itu, metode tersebut belum optimal dalam mengidentifikasi kelompok wilayah yang memiliki karakteristik serupa namun tidak selalu berada pada kategori administratif yang sama. Permasalahan ini menimbulkan kebutuhan akan metode analisis alternatif yang lebih adaptif dan mampu mengelompokkan wilayah berdasarkan kemiripan karakteristik multidimensi.

Sering berkembangnya bidang artificial intelligence dan machine learning, metode unsupervised learning seperti klusterisasi banyak dimanfaatkan dalam analisis data sosial-ekonomi. Metode klusterisasi memungkinkan pengelompokan data tanpa label awal, sehingga pola tersembunyi dalam data dapat teridentifikasi secara lebih objektif. Salah satu metode klusterisasi yang banyak digunakan adalah K-Means, namun metode ini memiliki keterbatasan dalam menentukan jumlah kluster dan sensitivitas terhadap outlier. Sebagai alternatif, metode Density-Based Spatial Clustering of Applications with Noise (DBSCAN) menawarkan keunggulan dalam mengidentifikasi kluster berbasis kepadatan serta mendeteksi data ekstrem atau noise yang sering kali merepresentasikan kondisi wilayah dengan karakteristik yang sangat berbeda.

Beberapa penelitian terdahulu telah menerapkan metode klusterisasi dalam analisis kemiskinan dan pembangunan wilayah. Penelitian oleh Putra et al. [1] menggunakan metode K-means untuk mengelompokkan tingkat kemiskinan provinsi di Indonesia berdasarkan indikator ekonomi dan sosial. Selanjutnya, Sari dan Nugroho [2] menerapkan Hierarchical Clustering untuk memetakan ketimpangan pembangunan daerah. Penelitian lain oleh Pratama et al. [3] membandingkan metode KMeans dan DBSCAN dalam analisis data sosial-ekonomi, namun belum secara spesifik membahas tingkat kemiskinan pada level kabupaten/kota. Selain itu, penelitian oleh Lestari et al. [4] menggunakan DBSCAN untuk analisis data wilayah, tetapi fokus pada sektor kesehatan. Penelitian terbaru oleh Rahman et al. [5] mengkaji pemetaan kemiskinan menggunakan machine learning, namun masih menggunakan pendekatan klasifikasi terawasi (supervised learning).


Berdasarkan penelitian-penelitian tersebut, dapat diidentifikasi adanya research gap yaitu masih terbatasnya penelitian yang menerapkan metode DBSCAN untuk menganalisis tingkat kemiskinan kabupaten/kota di Indonesia secara multidimensi serta memanfaatkan kemampuan DBSCAN dalam mendeteksi wilayah dengan kondisi kemiskinan ekstrem sebagai noise. Selain itu, sebagian besar penelitian sebelumnya masih berfokus pada tingkat provinsi atau menggunakan metode klusterisasi yang sensitif terhadap bentuk kluster dan outlier.

Oleh karena itu, penelitian ini bertujuan untuk menganalisis tingkat kemiskinan kabupaten/kota di Indonesia menggunakan metode DBSCAN berdasarkan indikator sosial-ekonomi yang bersumber dari Badan Pusat Statistik (BPS). Penelitian ini diharapkan dapat menghasilkan pengelompokan wilayah yang lebih representatif terhadap kondisi kemiskinan actual serta memberikan kontribusi sebagai dasar pertimbangan dalam perumusan kebijakan penanggulangan kemiskinan yang lebih tepat sasaran dan berbasis data.

2. METODE

Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) dan diakses melalui platform Kaggle. Dataset mencakup indikator-indikator kemiskinan dan sosial ekonomi pada tingkat kabupaten/kota di Indonesia, seperti persentase penduduk miskin, jumlah penduduk miskin, pengeluaran per kapita, serta indikator pendukung lainnya. Selain data atribut, digunakan pula data spasial



wilayah administratif kabupaten/kota untuk mendukung analisis berbasis spasial. Penggunaan data resmi bertujuan untuk memastikan validitas dan reliabilitas hasil klasterisasi yang diperoleh.

Tabel 1. Variabel Penelitian

No	Variabel	Keterangan
1	Persentase Penduduk Miskin Indikator tingkat kemiskinan	
2	IPM	Indeks Pembangunan Manusia
3	Tingkat Pengangguran	Persentase pengangguran terbuka
4	Rata-rata Lama Sekolah	Indikator pendidikan
5	Pengeluaran Per Kapita	Indikator kesejahteraan

Data ini tidak hanya merefleksikan keadaan ekonomi dan sosial masyarakat, tetapi juga dapat digunakan untuk menganalisis efek kebijakan publik dalam memerangi kemiskinan dan meningkatkan kualitas hidup. Oleh karena itu, penggunaan data sekunder dari BPS sangat relevan dan penting dalam konteks penelitian ini.

Prapemrosesan Data

Setelah data terkumpul, langkah selanjutnya dalam analisis tingkat kemiskinan di Indonesia adalah pra-pemrosesan, yang bertujuan untuk memastikan kualitas dan integritas data sebelum dilakukan analisis lebih lanjut. Proses ini terdiri dari beberapa tahapan penting, termasuk pemeriksaan data hilang, pembersihan data tidak valid, serta penyesuaian format data agar sesuai dengan kebutuhan analisis. Penghilangan data yang hilang melalui cara yang tepat, seperti metode imputasi, dapat meningkatkan kekuatan analisis yang dilakukan dan menghasilkan hasil clustering yang lebih akurat. Pembersihan data juga berfungsi untuk mengidentifikasi dan mengeluarkan outliers yang dapat mempengaruhi ketepatan hasil analisis. DBSCAN, sebagai metode clustering yang digunakan dalam penelitian ini, dikenal sangat sensitif terhadap kehadiran outliers. Oleh karena itu, pembersihan data yang efektif menjadi sangat penting agar pengelompokan yang dihasilkan merefleksikan pola kemiskinan sebenarnya.

Normalisasi Data

Normalisasi data merupakan langkah krusial dalam proses pra-pemrosesan sebelum menerapkan algoritma clustering, seperti DBSCAN, terutama dalam konteks analisis tingkat kemiskinan di Indonesia. Proses ini bertujuan untuk menyamakan skala antar variabel sehingga tidak ada variabel yang mendominasi perhitungan jarak antara data satu dengan yang lain. Dalam analisis kemiskinan, variabel yang digunakan bisa sangat bervariasi, mulai dari indikator ekonomi, kesehatan, hingga pendidikan, yang tentunya memiliki rentang nilai yang berbeda-beda. Jika data tidak dinormalisasi, variabel dengan nilai yang lebih besar (misalnya, pendapatan) dapat mendominasi pengaruhnya terhadap jarak, sementara variabel lainnya mungkin tidak terakumulasi dengan benar dalam proses pengelompokan (Rodríguez & Laio, 2014).

DBSCAN, yang merupakan singkatan dari Density-Based Spatial Clustering of Applications with Noise, sangat sensitif terhadap perhitungan jarak antar titik data. Oleh karena itu, normalisasi tidak hanya penting untuk menjaga keakuratan perhitungan tetapi juga diperlukan untuk mendukung identifikasi kluster dengan kepadatan yang berbeda dan mendeteksi outliers (Rodríguez & Laio, 2014). Metode normalisasi yang umum digunakan antara lain Min-Max scaling dan Z-score normalization. Min-Max scaling melakukan transformasi pada nilai-nilai data agar berada dalam rentang Rodríguez & Laio, 2014), sedangkan Z-score normalization mengubah data sehingga memiliki rata-rata 0 dan deviasi standar 1, yang berguna terutama ketika ada kemungkinan ada nilai pencilan

Penentuan Prameter DBSCAN

Pada tahap penentuan parameter dalam algoritma DBSCAN, dua nilai yang ditentukan secara kritis adalah epsilon (ϵ) dan minimum points (MinPts). Parameter epsilon berfungsi untuk menentukan radius lingkungan di sekitar setiap titik data, yang akan mengidentifikasi wilayah di mana titik-titik yang terhubung dapat dikelompokkan ke dalam satu kluster. Semakin kecil nilai epsilon, semakin ketat kriteria untuk mengelompokkan titik-titik data, yang dapat menghasilkan lebih banyak kluster kecil dan meningkatkan kemungkinan terdeteksinya data sebagai noise. Di sisi lain, jika epsilon terlalu besar, titik-titik yang seharusnya terpisah dapat terkluster bersama, yang bisa menyebabkan hilangnya informasi penting mengenai pola data yang ada.

Selain epsilon, parameter kedua, yaitu MinPts, merujuk pada jumlah minimum titik data yang diperlukan agar satu ruang dalam radius epsilon dapat dianggap sebagai kluster yang valid. Penentuan nilai ini sangat penting karena jika nilainya terlalu rendah, bahkan kumpulan titik yang sangat jarang dapat dianggap sebagai kluster, sementara nilai yang terlalu tinggi bisa membuat kluster yang valid menjadi tidak terdeteksi. Dalam konteks ini, penelitian menunjukkan bahwa keseimbangan yang tepat antara kedua parameter ini berpengaruh signifikan terhadap keberhasilan algoritma dalam menghasilkan kluster yang bermakna dan akurat.

Proses Clustering DBSCAN

Proses clustering dengan menggunakan metode DBSCAN diterapkan pada data yang telah dinormalisasi, biasanya dengan bantuan platform seperti Google Colaboratory. Metode ini dirancang untuk mengelompokkan data berdasarkan kepadatan dengan cara mengidentifikasi daerah berbasis densitas dan memisahkan noise. Algoritma DBSCAN melakukan ini dengan memanfaatkan dua parameter utama: epsilon (ϵ), yang menetapkan radius lingkungan di mana titik-titik data dapat dianggap sebagai bagian dari kluster, dan minimum points (MinPts), yang menentukan jumlah titik minimum yang diperlukan dalam lingkungan tersebut untuk membentuk kluster yang valid. Dengan melakukan clustering pada data kemiskinan di Indonesia, DBSCAN dapat mengidentifikasi berbagai wilayah yang memiliki pola kemiskinan yang berbeda, yang sangat penting untuk perumusan intervensi kebijakan yang lebih tepat dan berbasis data (Cai et al., 2020).

Setelah algoritma DBSCAN dijalankan, hasil pengelompokan dapat memberikan wawasan penting mengenai sebaran tingkat kemiskinan dalam masyarakat. Dalam analisis ini, kluster yang dihasilkan mencerminkan kelompok wilayah dengan karakteristik kemiskinan yang serupa, sementara titik-titik data yang tidak masuk dalam kluster utama akan teridentifikasi sebagai noise atau outliers (cluster -1). Penanganan noise ini penting karena menunjukkan daerah atau populasi yang mungkin berbeda secara signifikan dari kluster mayoritas, sehingga memerlukan perhatian dan strategi intervensi yang lebih terspesialisasi (Yang et al., 2022). Penelitian sebelumnya menunjukkan bahwa DBSCAN dapat secara efektif mengidentifikasi pola kompleks dalam data berdimensi tinggi, termasuk dalam konteks kemiskinan yang terdistribusi tidak merata di seluruh Indonesia, sehingga membantu mengarahkan kebijakan sosial untuk fokus pada entitas yang paling membutuhkan dukungan.

Visualisasi Hasil Kluster

Hasil clustering dari metode DBSCAN kemudian divisualisasikan dalam bentuk grafik atau scatter plot, yang berfungsi untuk mempermudah pemahaman pola kluster yang terbentuk serta persebaran data noise. Proses visualisasi ini sangat penting karena memberikan gambaran yang jelas tentang bagaimana titik-titik data dikelompokkan berdasarkan kelebihan dan kekurangan masing-masing wilayah dalam konteks kemiskinan. Dengan menggunakan scatter plot, setiap kluster dapat diidentifikasi dengan warna yang berbeda, sehingga memudahkan analisis terhadap wilayah dengan karakteristik kemiskinan serupa. Selain itu, titik yang teridentifikasi sebagai noise atau outlier dapat

dengan mudah dikenali, biasanya ditandai dengan warna atau simbol yang berbeda, yang menunjukkan bahwa area tersebut tidak termasuk dalam kluster utama yang dihasilkan oleh algoritma [26][27].

Visualisasi yang efektif tidak hanya memberikan pemahaman intuitif mengenai data yang dikelompokkan, tetapi juga memungkinkan para pembuat kebijakan untuk dengan cepat menganalisis dan merespons pola yang ada. Misalnya, dengan melihat visualisasi kluster pada peta distribusi, para pembuat kebijakan dan pemerintah daerah dapat lebih mudah menangkap area yang membutuhkan perhatian lebih, seperti wilayah dengan konsentrasi tinggi kemiskinan atau daerah yang memiliki kebutuhan khusus yang tidak terjangkau oleh program pengentasan kemiskinan yang ada saat ini. Penelitian menunjukkan bahwa pendekatan visualisasi ini sangat meningkatkan pemahaman data, membantu para pemangku kepentingan dalam merumuskan kebijakan dan program yang lebih efektif [28][29].

Analisis dan Interpretasi Kluster

Setiap kluster yang dihasilkan dari proses clustering dianalisis berdasarkan karakteristik indikator kemiskinan yang digunakan dalam studi ini. Kluster utama yang terbentuk mencerminkan pola kemiskinan yang dominan di berbagai wilayah, dengan setiap kluster mewakili kelompok wilayah dengan kesamaan tertentu dalam hal indikator sosial dan ekonomi. Misalnya, dalam menganalisis tingkat pendidikan, akses kepada layanan kesehatan, dan pendapatan penduduk, setiap kluster dapat menunjukkan tingkat kemiskinan yang berbeda, di mana kluster dengan indikator yang lebih rendah akan menunjukkan wilayah yang lebih parah dalam hal kemiskinan. Hasil analisis ini memberikan wawasan yang penting bagi para pengambil kebijakan untuk merumuskan strategis intervensi yang lebih efektif yang difokuskan pada kebutuhan spesifik dalam masing-masing kluster.

Di sisi lain, terdapat pula data yang teridentifikasi sebagai noise, yang menunjukkan wilayah dengan karakteristik ekstrem yang memerlukan perhatian khusus. Nilai noise ini umumnya mencakup area yang tidak dapat tergolong dalam kluster mana pun, seringkali disebabkan oleh ketidakcukupan data atau fitur unik yang tidak sesuai dengan pola umum lainnya. Noise sering kali menunjukkan masalah sosial atau ekonomi yang sangat spesifik, seperti wilayah terpencil yang tertinggal atau kumpulan populasi yang mengalami kesulitan yang signifikan dalam mengakses sumber daya dasar. Identifikasi noise dalam data menjadi kunci dalam analisis, karena memberikan indikasi akan kebutuhan daerah-daerah tersebut yang sering kali terabaikan dalam kebijakan umum. Dengan memahami baik kluster utama maupun noise, pemerintah dan organisasi non-pemerintah dapat memperbaiki strategi dan program intervensi yang difokuskan agar lebih tepat sasaran, dan lebih responsif terhadap kondisi nyata masyarakat, yang pada gilirannya dapat membantu mengatasi kemiskinan secara lebih efektif di Indonesia.

3. HASIL DAN PEMBAHASAN

Hasil Clustering DBSCAN

Hasil clustering menggunakan algoritma DBSCAN menunjukkan terbentuknya satu cluster utama yang mewakili karakteristik kemiskinan yang umum dan satu kelompok data pencilan atau noise. Hasil ini menggambarkan kompleksitas dan keragaman kondisi sosial ekonomi yang ada di Indonesia, serta ketidakmerataan yang dapat ditemukan di dalam data.

Tabel 2. Hasil Clustering DBSCAN

Cluster	Jumlah Wilayah	Karakteristik
Cluster 0		Mayoritas wilayah Pola kemiskinan umum
Cluster -1		Beberapa wilayah Karakteristik ekstrem (outlier)

Cluster 0 merepresentasikan wilayah dengan karakteristik kemiskinan yang relatif homogen dan mencerminkan kondisi umum kabupaten/kota di Indonesia. Di dalam cluster ini, mayoritas wilayah

mengalami tantangan serupa dalam hal kemiskinan, memungkinkan peneliti untuk memahami berbagai faktor penyebab dan hubungan antar variabel yang memengaruhi kemiskinan secara lebih mendalam (Fahmi & Tsani, 2025). Pemahaman ini penting untuk memberikan kebijakan yang lebih terfokus dan efektif dalam penanggulangan kemiskinan.

Sebaliknya, Cluster -1 menunjukkan wilayah dengan karakteristik yang menyimpang, di mana terdapat indikator ekonomi yang tinggi namun tingkat kemiskinan masih signifikan. Hal ini menunjukkan bahwa walaupun wilayah tersebut memiliki potensi ekonomi yang baik, faktor-faktor lain seperti distribusi pendapatan yang tidak merata dan akses terbatas ke pendidikan serta layanan kesehatan dapat menghambat pengentasan kemiskinan di daerah tersebut (Pratama, 2023). Penemuan ini menegaskan perlunya pendekatan kebijakan yang lebih inklusif dan mempertimbangkan berbagai permasalahan kompleks yang mungkin tidak terlihat pada analisis agregat.

Analisis dan Interpretasi

Keberadaan cluster noise (Cluster -1) menunjukkan bahwa tidak semua wilayah dapat dikelompokkan secara umum, dan terdapat wilayah yang memerlukan perhatian khusus berdasarkan karakteristik lokal mereka. Hasil ini juga menegaskan bahwa DBSCAN dapat menangkap pola tersembunyi dalam data kemiskinan, yang bisa jadi diabaikan oleh algoritma clustering lain seperti K-Means yang lebih cenderung mengabaikan outliers (Hidayati et al., 2022).

Cluster noise menggambarkan pentingnya kebijakan yang lebih spesifik dan berbasis data. Kebijakan yang diambil untuk mengatasi kemiskinan mungkin tidak cukup jika hanya didasarkan pada pola umum yang ada dalam data. Oleh karena itu, penting bagi pembuat kebijakan untuk memahami keragaman di dalam masyarakat dan bagaimana kondisi unik di setiap wilayah dapat mempengaruhi efektivitas kebijakan tersebut (Finuliyah et al., 2023).

Hasil analisis ini juga membuka peluang untuk penelitian lebih lanjut tentang faktor-faktor yang menyebabkan kemiskinan di wilayah-wilayah yang termasuk dalam cluster noise. Dengan menggali lebih dalam karakteristik spesifik dari area tersebut, peneliti dan pemangku kepentingan dapat merumuskan strategi intervensi yang lebih baik dan lebih sesuai dengan kebutuhan lokal. Terlebih lagi, wawasan tentang wilayah-wilayah yang menunjukkan karakteristik luar biasa ini dapat memberikan informasi berharga untuk program-program pengentasan kemiskinan yang lebih terarah (Ramadhan et al., 2024).

Dari sudut pandang metodologis, penggunaan DBSCAN dalam penelitian ini menunjukkan efisiensi dan efektivitas dalam menangani data yang memiliki distribusi tidak merata. Dengan meningkatkan pemahaman kita tentang kompleksitas kemiskinan di Indonesia, hasil ini berpotensi mendorong pengembangan kebijakan yang lebih responsif dan berbasis data. Ini sangat penting mengingat kemiskinan adalah tantangan berkelanjutan yang memerlukan solusi yang adaptif dan inovatif.

4. KESIMPULAN

Hasil penelitian ini menunjukkan bahwa metode DBSCAN mampu mengelompokkan wilayah berdasarkan tingkat kemiskinan secara efektif. Dengan kemampuan untuk mengidentifikasi pola kemiskinan yang tersembunyi dan wilayah pencilan yang memiliki karakteristik unik, DBSCAN mengungkapkan kompleksitas kemiskinan di Indonesia dengan jelas. Cluster yang terbentuk memberikan gambaran yang lebih mendalam tentang kondisi yang berbeda di berbagai daerah, yang penting untuk pengambilan keputusan dan perumusan kebijakan. Penemuan ini menunjukkan bagaimana analisis berbasis data dapat membantu identifikasi dan intervensi yang lebih tepat sasaran dalam upaya pengentasan kemiskinan Birant & Kut (2007).

Keberadaan wilayah pencilan atau cluster noise menunjukkan bahwa sejumlah wilayah tidak dapat dikelompokkan ke dalam karakteristik umum klaster utama. Berdasarkan hasil penelitian, sebanyak 7

kabupaten/kota teridentifikasi sebagai noise (cluster -1) dari total 109 wilayah yang dianalisis, atau sekitar 6,42% dari keseluruhan data. Hal ini mengindikasikan perlunya pendekatan kebijakan yang lebih spesifik dan berbasis pada konteks lokal. Dalam konteks ini, hasil penelitian memberikan wawasan berharga bagi pembuat kebijakan agar dapat merancang kebijakan yang lebih adaptif terhadap kebutuhan spesifik setiap daerah (Andrist et al., 2019; Denny et al., 2016). Misalnya, wilayah yang termasuk dalam cluster noise memiliki indikator ekonomi relatif tinggi namun masih menunjukkan tingkat kemiskinan yang signifikan, sehingga memerlukan intervensi kebijakan yang lebih terfokus, seperti program redistribusi pendapatan, peningkatan akses pendidikan, serta perluasan layanan kesehatan dasar.

5. DAFTAR PUSTAKA

- [1] E. K. Cromley, "GIS and disease," *Annual Review of Public Health*, vol. 24, no. 1, pp. 80–87, 2003, doi: 10.1146/annurev.publhealth.24.120502.101015.
- [2] S. Park and S. Nam, "Multidimensional poverty status of householders with disabilities in South Korea," *International Journal of Social Welfare*, vol. 28, no. 3, pp. 226–234, 2019, doi: 10.1111/1468-2397.12281.
- [3] H. Lin et al., "Remote sensing of urban poverty and gentrification," *Remote Sensing*, vol. 13, no. 15, Art. no. 3000, 2021, doi: 10.3390/rs13153000.
- [4] Y. Hui et al., "A novel DBSCAN clustering algorithm via edge computing-based deep neural network model for targeted poverty alleviation big data," *Wireless Communications and Mobile Computing*, vol. 2021, Art. no. 9963837, 2021, doi: 10.1155/2021/9963837.
- [5] X.-P. Zhang et al., "Study on the spatial distribution characteristics and poverty inducements of poverty-stricken villages in Henan Province," *Land*, vol. 12, no. 4, Art. no. 950, 2023, doi: 10.3390/land12040950.
- [6] A. Mahar et al., "Utilizing remote sensing and geographic information systems for mapping poverty," *Jurnal Pendidikan Geografi*, vol. 13, no. 1, pp. 57–70, 2022, doi: 10.29210/2331234494.
- [7] M. Ahmad et al., "A bibliometric study of the top 100 most-cited randomized controlled trials, systematic reviews and meta-analyses published in endodontic journals," *International Endodontic Journal*, 2019, doi: 10.1111/iej.13073.
- [8] M. Ahmad et al., "The top 50 most-cited articles published in the International Endodontic Journal," *International Endodontic Journal*, 2019, doi: 10.1111/iej.13074.
- [9] H. Small, "Co-citation in the scientific literature: A new measure of the relationship between two documents," *Journal of the American Society for Information Science*, 1973, doi: 10.1002/asi.4630240303.
- [10] M. Ahmad et al., "Applications of bone morphogenetic proteins in dentistry: A bibliometric analysis," *Biomedical Research International*, 2020, doi: 10.1155/2020/5488414.
- [11] R. Martínez et al., "H-Classics: Characterizing the concept of citation classics through H-index," *Scientometrics*, 2013, doi: 10.1007/s11192-013-1006-6.
- [12] T. Boongoen et al., "Fuzzy qualitative link analysis for academic performance evaluation," *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 2011, doi: 10.1142/S0218488511002977.
- [13] A. Anzah and D. Butler, "Revisiting an early classic on gopher bioturbation and geomorphology," *Progress in Physical Geography: Earth and Environment*, 2017, doi: 10.1177/0309133317713965.
- [14] M. Kessler, "Bibliographic coupling between scientific papers," *American Documentation*, 1963, doi: 10.1002/asi.1963.1.1.00.