

Improved K-Means Clustering untuk Analisis Ketimpangan Pembangunan Kabupaten/Kota di Pulau Jawa

Kanessa Jasmine Prisheila Az Zahra Setiyanto¹, Amri Muhaimin²,
Kartika Maulida Hindrayani³

^{1,2,3}Sains Data, Universitas Pembangunan Nasional "Veteran" Jawa Timur

¹22083010016@student.upnjatim.ac.id

²amri.muhamin.stat@upnjatim.ac.id

³kartika.maulida.ds@upnjatim.ac.id

Corresponding author email: 22083010016@student.upnjatim.ac.id

ABSTRAK

Abstrak— Ketimpangan pembangunan antar Kabupaten/Kota di Pulau Jawa masih menjadi tantangan dalam meningkatkan kesejahteraan hidup masyarakat. Kerumitan indikator sosial-ekonomi menyulitkan identifikasi wilayah maju dan wilayah berkembang secara akurat. Penelitian ini mengelompokkan status pembangunan Kabupaten/Kota berdasarkan lima indikator sosial-ekonomi yakni Produk Domestik Regional Bruto (PDRB) per Kapita, Gini Rasio, Indeks Pembangunan Manusia (IPM), Tingkat Pembangunan Terbuka (TPT), dan Kemiskinan (P0) dari Badan Pusat Statistik menggunakan *Improved K-Means Clustering*. Evaluasi performa model menggunakan *Silhouette Score* dan *Davies Bouldin Index* (DBI) pada tahun 2020 – 2024 menunjukkan kualitas pemisahan yang cukup baik, dengan rentang nilai 0.468 - 0.581 untuk *Silhouette Score* dan 0.510 - 1.110 untuk DBI. Hasil menunjukkan pembagian kluster mampu menghasilkan dua kluster utama yang membedakan antara wilayah maju dan berkembang, di mana kluster maju didominasi oleh kota besar dan wilayah industri seperti Jakarta Pusat dan Kediri, sedangkan wilayah lainnya masih berada dalam status berkembang. Temuan ini dapat digunakan sebagai gambaran tentang perbedaan pembangunan yang ada antar Kabupaten/Kota sehingga dapat menjadi dasar dalam menentukan kebijakan dan prioritas pembangunan agar pembangunan dapat berjalan dengan adil dan merata.

Keywords: Status Pembangunan, Pulau Jawa, Ketimpangan Pembangunan, Analisis Kluster, Improved K-Means.

I. PENDAHULUAN

Pembangunan regional di Indonesia merupakan salah satu aspek penting yang dilakukan untuk menciptakan pemerataan kesejahteraan dan peningkatan hidup masyarakat [1]. Namun, Indonesia masih menghadapi ketimpangan pembangunan antardaerah yang tercermin dalam kesenjangan sosial, ekonomi, dan infrastruktur. Dinamika pertumbuhan ekonomi yang berbeda antar wilayah Kabupaten/Kota yang menimbulkan ketimpangan pembangunan, yang menjadi tantangan besar dalam upaya mencapai kesejahteraan secara menyeluruh dan berkelanjutan [2]. Ketimpangan ini tidak hanya berdampak terhadap kualitas hidup masyarakat, tetapi juga menghambat efektivitas pemerataan pembangunan dan pertumbuhan ekonomi di tingkat nasional. Berbagai aspek indikator sosial-ekonomi seperti Produk Domestik Regional Bruto

(PDRB) Kapita, Gini Rasio, Indeks Pembangunan Manusia (IPM), Tingkat Pengangguran Terbuka (TPT), dan Kemiskinan (P0) menunjukkan adanya ketimpangan dan perbedaan kinerja antarwilayah terutama pada wilayah dengan tingkat urbanisasi tinggi seperti Pulau Jawa.

Pulau Jawa merupakan pusat aktivitas ekonomi, industri, dan pemerintahan nasional, sehingga memiliki kontribusi terbesar terhadap Produk Domestik Regional Bruto (PDRB) Indonesia [3]. Namun, tingginya konsentrasi pertumbuhan tersebut tidak selalu diiringi dengan pemerataan pembangunan di seluruh wilayah. Perbedaan capaian Indeks Pembangunan Manusia (IPM), Tingkat Pengangguran Terbuka (TPT), serta tingkat kemiskinan (P0) pada level kabupaten/kota menunjukkan adanya kesenjangan sosial dan ekonomi yang masih cukup tajam. Sebagai contoh, Kabupaten Cianjur di Provinsi Jawa Barat memiliki IPM sebesar 67,24 [4], sedangkan Kota Bandung yang berada di provinsi yang sama memiliki capaian IPM di atas 83 [5]. Kondisi ini menggambarkan bahwa kualitas layanan pendidikan, kesehatan, serta akses terhadap kesempatan ekonomi tidak merata. Ketimpangan tersebut menegaskan pentingnya analisis mendalam berbasis data untuk memahami penyebaran pembangunan dan merumuskan kebijakan pemerataan yang lebih tepat sasaran.

Ketimpangan pembangunan tersebut membutuhkan pendekatan analisis yang lebih akurat dalam melakukan pengelompokan wilayah berdasarkan karakteristik indikator sosial-ekonomi. Pendekatan clustering menjadi salah satu metode yang relevan karena mampu mengidentifikasi pola kemiripan antaratribut pembangunan sehingga menghasilkan pemetaan wilayah yang lebih objektif dan berbasis data. Melalui analisis cluster, pemerintah dapat memperoleh gambaran mengenai prioritas program pembangunan yang lebih spesifik serta terarah sesuai dengan kebutuhan masing-masing wilayah. Selain itu, penggunaan metode clustering dalam penentuan status pembangunan daerah dapat meminimalisir subjektivitas dan bias dalam klasifikasi wilayah maju dan berkembang, karena proses pengelompokan dilakukan secara komputasional berdasarkan kedekatan nilai indikator yang digunakan.

Penelitian terdahulu menerapkan algoritma K-Means untuk mengelompokkan kabupaten/kota di Papua berdasarkan delapan indikator kemiskinan dan menggunakan metode *Elbow* serta *Silhouette* untuk menentukan jumlah cluster optimal. Hasilnya menunjukkan dua klaster utama yang menggambarkan wilayah dengan tingkat kemiskinan tinggi dan rendah, sehingga dapat menjadi dasar bagi pemerintah dalam merancang kebijakan penanggulangan kemiskinan yang lebih terarah [6]. Sementara itu, penelitian lain mengelompokkan kabupaten/kota di Provinsi Maluku berdasarkan indikator IPM tahun 2014 menggunakan metode K-Means dan menghasilkan tiga klaster dengan tingkat pembangunan yang berbeda. Hasilnya menunjukkan bahwa Kota Ambon berada pada klaster dengan pembangunan tertinggi, sementara wilayah lainnya tersebar pada klaster dengan capaian indikator yang lebih rendah [7].

Berbeda dengan penelitian sebelumnya yang menggunakan metode *K-Means Clustering*, penelitian ini menerapkan *Improved K-Means Clustering* yang diharapkan mampu menangkap hubungan non-linear antarindikator seperti PDRB per Kapita, IPM, Gini Rasio, TPT, dan Kemiskinan sehingga menghasilkan klaster yang lebih representatif dan akurat. Selain itu, penelitian ini juga mengatasi keterbatasan penelitian terdahulu yang menggunakan K-Means tradisional yang memiliki kelemahan dalam menginisialisasi centroid awal dan kurang optimal dalam memisahkan wilayah dengan karakteristik pembangunan yang mirip. Penelitian ini berfokus pada analisis kabupaten/kota yang ada di Pulau Jawa dalam rentang tahun 2020 – 2024 yang didapatkan dari Badan Pusat Statistik (BPS). Penelitian ini bertujuan untuk menganalisis pola ketimpangan Pembangunan kabupaten/kota di Pulau Jawa menggunakan *Improved K-Means Clustering* dan menghasilkan pengelompokan wilayah berdasarkan indikator sosial-ekonomi.

II. METODOLOGI PENELITIAN

II.1 Variabel dan Sumber Data

Penelitian ini menggunakan data indikator sosial-ekonomi yang didapatkan dari Badan Pusat Statistik (BPS) tahun 2020 – 2024 yang terdiri dari 125 Kabupaten/Kota di Pulau Jawa meliputi Provinsi DKI Jakarta, Jawa Barat, Banten, Jawa Tengah, DI Yogyakarta, dan Jawa Timur. Variabel yang digunakan dalam penelitian ini terdiri dari Produk Domestik Regional Bruto (PDRB) per Kapita sebagai indikator ekonomi daerah, Indeks Pembangunan Manusia (IPM) sebagai indikator kualitas pendidikan, kesehatan, dan pembangunan masyarakat, Gini Rasio (GR) yang merepresentasikan tingkat ketimpangan, Tingkat Pengangguran Terbuka (TPT) sebagai indikator kondisi tenaga kerja, dan Kemiskinan (PO) yang merepresentasikan proporsi penduduk miskin.

II.2 Standarisasi Data

Sebelum proses klusterisasi dilakukan, dilakukan tahap standarisasi data (*scaling*) agar seluruh variabel memiliki skala yang sama. Pada penelitian ini digunakan metode *StandardScaler* yang merupakan teknik standarisasi dengan mengubah nilai variabel menjadi distribusi dengan rata-rata 0 dan standar deviasi 1. Standarisasi data dilakukan secara terpisah pada setiap tahun pengamatan (2020 – 2024) agar karakteristik data tiap tahun terjaga dan tidak dipengaruhi oleh perbedaan skala antar variabel. Dengan demikian, setiap variabel dapat berkontribusi secara seimbang dalam proses pembentukan kluster tanpa didominasi oleh variabel tertentu. Secara matematis, proses standarisasi dinyatakan dengan menggunakan rumus pada persamaan (1).

$$Z = \frac{X - \mu}{\sigma} \quad (1)$$

II.3 Improved K-Means Clustering

Improved K-Means Clustering merupakan pengembangan dari metode K-Means Clustering tradisional yang bertujuan untuk meningkatkan kualitas kluster dengan memperbaiki cara dalam menentukan centroid awal dengan menetapkan bobot pada setiap fitur [8]. Bobot pada *Improved K-Means Clustering* ditentukan berdasarkan variansi fitur, di mana fitur dengan variansi yang lebih tinggi akan memiliki pengaruh yang lebih besar.

Langkah-langkah Improved K-Means yang digunakan dalam penelitian ini adalah sebagai berikut:

- Hitung bobot tiap fitur data menggunakan standar deviasi untuk memberikan pengaruh yang lebih besar pada fitur dengan variansi tinggi.

$$\mu_j = \frac{1}{n} \sum_{i=1}^n x_{ij} \quad (2)$$

$$\sigma = \frac{1}{\mu_j} \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{ij} - \mu_j)^2} \quad (3)$$

Kemudian bobot fitur dihitung menggunakan:

$$W_j = \frac{\sigma_j}{\sum_{j=1}^m \sigma_j} \quad (4)$$

- Hitung jarak antar data ke centroid terdekat dengan menggunakan jarak *Euclidean* berbobot untuk mendapatkan ukuran kemiripan antar objek.

$$\text{dis}(x_a, x_b) = \sqrt{\sum_{j=1}^m w_j (x_{aj}, x_{bj})^2} \quad (5)$$

- c. Tentukan centroid awal menggunakan *nearest neighbors* dengan menghitung jarak rata-rata antar data sebagai ambang batas pemilihan centroid.

$$\text{dis}_{Avg} = \frac{1}{A_n^2} \sum \text{dis}(x_a, x_b) \quad (6)$$

Data yang memiliki jumlah nearest neighbors tertinggi (dis_{Avg}) dipilih sebagai centroid awal untuk mengurangi ketidakstabilan pemilihan centroid acak seperti yang dilakukan pada *K-Means Clustering* tradisional, sehingga menghasilkan kluster yang lebih optimal. Centroid berikutnya dipilih secara berurutan berdasarkan jumlah *nearest neighbors* terbanyak, dan apabila suatu data merupakan *nearest neighbor* dari centroid yang sudah terpilih, maka data tersebut dilewati. Proses ini diulang hingga jumlah centroid awal sesuai dengan banyaknya kluster, sehingga penyebaran centroid menjadi lebih optimal dan stabil.

II.4 Evaluasi Hasil Clustering

Setelah melakukan proses klusterisasi, dilakukan tahap evaluasi untuk menilai kualitas kluster yang dihasilkan [9]. Proses evaluasi ini merupakan salah satu tahapan penting untuk memastikan pengelompokan yang terbentuk benar-benar mencerminkan kemiripan karakteristik sosial-ekonomi antar wilayah, serta memiliki pemisahan yang jelas antara kluster satu dengan lainnya. Dalam penelitian ini, digunakan dua metrik evaluasi yang umum dan banyak direkomendasikan dalam analisis kluster, yaitu *Silhouette Score* dan *Davies-Bouldin Index (DBI)*. Kedua ukuran ini berperan dalam memberikan penilaian secara kuantitatif mengenai tingkat kekompakan serta pemisahan kluster, sehingga hasil klusterisasi yang diperoleh dapat dinilai keandalannya sebelum digunakan dalam interpretasi lebih lanjut.

Silhouette Score digunakan untuk menilai seberapa baik suatu objek berada dalam kluster tempatnya berada [10]. Matriks ini bekerja dengan meninjau kedekatannya dengan anggota kluster saat ini dan membandingkannya dengan kluster lain yang paling mirip [11]. Pada silhouette score nilai yang mendekati angka 1 mengindikasikan bahwa struktur kluster kuat, sedangkan nilai yang mendekati angka -1 mengindikasikan kemungkinan salah penempatan. Dalam penelitian ini, selain digunakan untuk menilai dan mengevaluasi hasil klusterisasi, silhouette score juga digunakan untuk menentukan kluster terbaik sebelum dilakukan klusterisasi menggunakan *Improved K-Means Clustering*. Perhitungan rumus *Silhouette score* adalah sebagai berikut:

$$s = \frac{b - a}{\max(a, b)} \quad (7)$$

Davies-Bouldin Index digunakan untuk mengukur tingkat kemiripan antara kluster dengan melihat pemisahan kluster (*separation*) dan kekompakan kluster (*compactness*) [12]. Secara konsep, DBI menghitung rasio antarjarak rata-rata antar kluster dengan deviasi rata-rata yang ada dalam kluster. Proses evaluasi dilakukan dengan menghitung nilai DBI untuk setiap hasil klusterisasi pertahun. Semakin rendah nilai DBI mengindikasikan bahwa kualitas pemisahan dan kekompakan kluster semakin baik. Rumus DBI adalah sebagai berikut:

$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{i \neq j} \left(\frac{S_i + S_j}{M_{ij}} \right) \quad (8)$$

III. HASIL DAN ANALISIS

III.1 Statistika Deskriptif

Pada tahap awal analisis, dilakukan proses perhitungan statistika deskriptif untuk melihat karakteristik data seperti nilai rata-rata, maksimum, minimum, dan variasi antar indikator yang digunakan. Analisis ini bertujuan untuk memberikan gambaran umum mengenai kondisi pembangunan sosial-ekonomi setiap provinsi sebelum dilakukan proses klusterisasi, sehingga pola awal ketimpangan atau perbedaan antar wilayah dapat teridentifikasi sejak awal. Pada Tabel 1 disajikan hasil statistika deskriptif untuk variabel penelitian yang meliputi PDRB per kapita, Indeks Pembangunan Manusia (IPM), laju pertumbuhan ekonomi (GR), Tingkat Pengangguran Terbuka (TPT), serta persentase penduduk miskin (P0) sebagai indikator utama dalam menggambarkan tingkat perkembangan wilayah..


Tabel 1. Statistika Deskriptif

Variabel	Mean	Standar Deviasi	Minimum	Maksimum
PDRB	69973	94807	17596	883715
IPM	73.85	5.32	62.70	88.77
GR	0.35	0.05	0.21	0.54
TPT	6.20	2.48	1.36	14.29
P0	9.61	3.90	2.29	23.76

Berdasarkan Tabel 1, dapat dilihat bahwa PDRB per kapita memiliki rata-rata tertinggi sebesar RP. 69.973 dengan standar deviasi sebesar RP. 94.807 yang menandakan adanya kesenjangan ekonomi antarwilayah di Pulau Jawa. Nilai IPM maksimum sebesar 88.77 dengan nilai minimum sebesar 62.70 mengindikasikan adanya tingkat pembangunan manusia yang belum merata. Dengan pertumbuhan GR yang relatif stabil dengan rata-rata 0.35, serta nilai TPT dan P0 yang menunjukkan variasi cukup tinggi, menandakan adanya ketimpangan pembangunan antar kabupaten/kota di Pulau Jawa.

III.2 Klusterisasi Menggunakan *Improved K-Means Clustering*

Pada penelitian ini dilakukan penentuan jumlah kluster yang paling optimal (k) dengan menggunakan *Silhouette Score* berbasis *K-Means* Tradisional. Data diuji menggunakan berbagai nilai k (k=2 hingga k=6), kemudian dihitung *Silhouette Score* untuk masing-masing nilai k dimana nilai k yang memiliki nilai *Silhouette Score* tertinggi akan dipilih sebagai jumlah kluster terbaik. Jumlah kluster optimal dari analisis ini dapat dilihat dari plot *Silhouette Score* yang ada dalam Gambar. 1.



Gambar 1. Silhouette Score Plot

III.3 Evaluasi Hasil Klusterisasi

Setelah dilakukan proses klusterisasi menggunakan Improved K-Means Clustering, tahap selanjutnya adalah melakukan evaluasi kualitas hasil klusterisasi menggunakan dua metrik evaluasi internal, yaitu *Silhouette Score* dan *Davies-Bouldin Index (DBI)*. Evaluasi ini bertujuan untuk menilai seberapa baik struktur klaster yang terbentuk dalam merepresentasikan kesamaan karakteristik antarwilayah di dalam klaster yang sama dan perbedaannya dengan klaster lain. Hasil evaluasi menggunakan *Silhouette Score* dan DBI untuk masing-masing pendekatan disajikan pada tabel berikut:

Metrik Evaluasi	Tahun Pengamatan				
	2020	2021	2022	2023	2024
<i>Silhouette Score</i>	0.581	0.575	0.468	0.577	0.576
<i>Davies-Bouldin Index (DBI)</i>	0.560	0.510	1.110	0.570	0.569

Tabel 2 menunjukkan bahwa nilai *Silhouette Score* berada pada kisaran 0,46–0,58 yang mengindikasikan bahwa secara umum pemisahan antar klaster sudah cukup baik dan objek di dalam klaster memiliki kedekatan yang relevan satu sama lain. Nilai tertinggi terdapat pada tahun 2020 (0,581), menunjukkan bahwa di tahun tersebut pembentukan dua klaster memiliki struktur yang paling jelas dan konsisten dalam mengelompokkan wilayah berdasarkan indikator pembangunan. Sementara pada tahun 2022, nilai *Silhouette Score* mengalami penurunan signifikan menjadi 0,468, yang menandakan tingkat ketidakpastian yang lebih tinggi dalam penempatan wilayah ke dalam klaster yang tepat.

Davies-Bouldin Index (DBI) juga memperlihatkan pola yang sama. Nilai DBI terbaik, yaitu 0,510, terjadi pada tahun 2021 yang menunjukkan bahwa klaster pada tahun tersebut memiliki tingkat kekompakan antarwilayah yang lebih baik serta pemisahan yang lebih kuat dengan klaster lain. Sebaliknya, nilai DBI mencapai angka terburuk pada tahun 2022 (1,110), yang mengindikasikan adanya kedekatan yang lebih tinggi antar klaster dan semakin melemahnya batas pemisahan antara wilayah maju dan berkembang. Kondisi ini mengarah pada kemungkinan meningkatnya kedekatan karakteristik pembangunan wilayah antar klaster, sehingga beberapa wilayah cenderung berada lebih dekat pada batas klaster atau mengalami potensi *misclassification*.

Dalam perbandingan setiap tahunnya, dapat disimpulkan bahwa kualitas pemisahan dan kekompakan klaster paling optimal terjadi pada awal periode (2020–2021), kemudian menurun pada 2022, sebelum kembali meningkat dan stabil pada 2023–2024. Hal ini mengindikasikan bahwa struktur pengelompokan wilayah berdasarkan indikator sosial-ekonomi masih cukup konsisten, namun terdapat tahun tertentu di mana dinamika pembangunan antar wilayah mengakibatkan batas klaster menjadi kurang tegas. Dengan demikian, hasil evaluasi ini menunjukkan bahwa secara keseluruhan pendekatan Improved K-Means Clustering mampu menghasilkan struktur klaster yang baik, meskipun masih perlu perhatian khusus terhadap tahun-tahun dengan penurunan kualitas evaluasi.

III.4 Interpretasi Klaster

Berdasarkan hasil klusterisasi menggunakan *Improved K-Means Clustering*, terbentuk dua klaster utama yang merepresentasikan kondisi pembangunan di Pulau Jawa, yaitu Klaster 1 (Wilayah Maju) dengan karakteristik IPM dan PDRB tinggi serta GR, TPT, dan P0 rendah, dan Klaster 0 (Wilayah Berkembang) yang memiliki IPM dan PDRB lebih rendah serta GR, TPT, dan P0 lebih tinggi, yang dapat dilihat pada Tabel 1.

Tabel 3. Profil Rata-Rata Indikator per Tahun dan Klaster

Tahun	Cluster	PDRB	IPM	GR	TPT	P0
2020	0	52463.30	72.59	0.34	7.38	9.99
	1	563922.00	79.81	0.37	8.59	6.10
2021	0	55509.32	72.91	0.52	6.85	10.40
	1	588890.50	80.08	0.85	7.06	6.34
2022	0	51735.25	73.42	0.35	6.09	9.74
	1	426876.16	79.07	0.36	6.50	6.77
2023	0	64665.75	74.23	0.35	5.55	9.44
	1	680245.50	81.48	0.37	5.24	5.91
2024	0	68584.53	74.82	0.35	5.02	9.13
	1	724778.00	82.18	0.34	5.16	5.57

Berdasarkan Tabel 1, klaster 1 secara konsisten menunjukkan profil wilayah maju dengan IPM tinggi dan kemiskinan rendah. Namun, pada tahun 2022 terjadi penurunan rata-rata profil cluster, pergeseran ini tidak disebabkan oleh peningkatan IPM atau PDRB, melainkan karena terjadi penurunan ketimpangan antarwilayah yang membuat batas antar klaster lebih longgar pada tahun tersebut. Hal ini dapat dilihat dari penurunan nilai *Silhouette Score* (0,468) dan kenaikan DBI (1,110) pada tahun 2022, yang mengindikasikan menurunnya kualitas pemisahan antar klaster. Setelah 2022, komposisi klaster kembali stabil seperti tahun-tahun sebelumnya.

Peta Cluster Kabupaten/Kota Pulau Jawa



Gambar 3. Peta Persebaran Wilayah Klaster

Gambar 3 menampilkan persebaran wilayah klaster pada periode 2020–2024 dalam satu peta gabungan. Warna biru menunjukkan klaster 1 (wilayah maju) dan warna merah menunjukkan klaster 0 (wilayah berkembang). Secara spasial, wilayah yang konsisten berada pada klaster 1 adalah Kota Jakarta Pusat dan Kota Kediri. Sementara itu, pada tahun 2022 terlihat beberapa wilayah seperti Kepulauan Seribu, Kota Cilegon, Jakarta Selatan, dan Jakarta Utara yang sempat masuk ke klaster 1. Pola ini sesuai dengan temuan sebelumnya, di mana batas klaster pada tahun 2022 menjadi lebih longgar akibat menurunnya kualitas pemisahan klaster. Setelah 2022, persebaran klaster kembali mengerucut dan stabil, sesuai pola tahun-tahun lainnya.

III. KESIMPULAN

Hasil klusterisasi menggunakan *Improved K-Means Clustering* menunjukkan terbentuknya dua klaster utama yang merepresentasikan kondisi pembangunan di Pulau Jawa, yakni Klaster 1 (wilayah maju) dengan IPM dan PDRB tinggi serta P0, TPT, dan GR rendah, dan Klaster 0 (wilayah berkembang) dengan karakteristik sebaliknya. Kualitas pemisahan klaster relatif stabil selama 2020–2024, meskipun pada tahun 2022

terjadi penurunan akibat tumpang tindih antarwilayah, di mana beberapa daerah seperti Kepulauan Seribu, Kota Cilegon, Jakarta Selatan, dan Jakarta Utara sempat berpindah ke kluster maju yang bukan disebabkan oleh peningkatan indikator, melainkan akibat fluktuasi nilai indikator yang memperkecil jarak antarwilayah. Secara keseluruhan, hasil ini menunjukkan pola konvergensi pembangunan yang stabil, dengan Kota Jakarta Pusat dan Kota Kediri tetap menjadi pusat pertumbuhan, sementara daerah lain mulai menunjukkan perbaikan meski kesenjangan masih terlihat.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih sebesar-besarnya kepada dosen pembimbing dan seluruh pihak yang telah memberikan dukungan dalam pelaksanaan penelitian ini baik dalam bentuk arahan, bimbingan, serta masukan akademik selama proses penelitian dan penyusunan naskah ini. Ucapan terimakasih juga penulis ucapkan kepada pihak penyedia data serta instansi terkait yang telah mendukung dalam ketersediaan informasi yang diperlukan. Selain itu, penghargaan khusus disampaikan kepada Tim DISCOVER selaku penyelenggara dan penyusun template prosiding yang memfasilitasi publikasi penelitian, sehingga proses penulisan dan publikasi dapat berjalan secara lebih terstruktur dan efisien.

REFERENSI

- [1] A. Rizkina Sari Siregar, N. Hamni Lubis, and F. Isfa, "Pentingnya Pemerataan Pembangunan Ekonomi dalam Meningkatkan Kesejahteraan Masyarakat Indonesia," *Cemerlang: Jurnal Manajemen dan Ekonomi Bisnis*, vol. 5, pp. 51–64, Dec. 2024, doi: 10.55606/cemerlang.v4i4.3424.
- [2] Cholly Fatun Nisa, Arivina Ratih Yulihar Taher, Prayudha Ananta, and I Wayan Suparta, "Analisis Ketimpangan Pembangunan Daerah di 34 Provinsi Indonesia," *E-journal Field of Economics, Business, and Entrepreneurship(EFEBE)*, vol. 3, 2025.
- [3] M. R. Yudistira and G. P. D. Sohibien, "ANALISIS KONVERGENSI EKONOMI DI PULAU JAWA MENGGUNAKAN DATA PANEL DINAMIS SPASIAL TAHUN 2013-2017," in *Seminar Nasional Official Statistics 2019: Pengembangan Official Statistics dalam mendukung Implementasi SDG's*, Jakarta: Polteknik Statistika STIS, 2019.
- [4] "[Metode Baru] Indeks Pembangunan Manusia (IPM) Kabupaten Cianjur, 2024," Badan Pusat Statistik Kabupaten Cianjur. Accessed: Nov. 12, 2025. [Online]. Available: <https://cianjurkab.bps.go.id/id/statistics-table/2/MjI5IzI=-metode-baru--indeks-pembangunan-manusia--ipm--kabupaten-cianjur.html>
- [5] "[Metode Baru] Indeks Pembangunan Manusia, 2024," Badan Pusat Statistik. Accessed: Nov. 12, 2025. [Online]. Available:

<https://www.bps.go.id/id/statistics-table/2/NDEzIzI=/-metode-baru--indeks-pembangunan-manusia.html>

- [6] Y. C. Fadilah, A. Sani, and A. Andrianingsih, "Applying K-Means Clustering for Grouping Papua's Districts Based on Poverty Indicators Analysis," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 10, no. 3, pp. 543–553, Feb. 2025, doi: 10.33480/jitk.v10i3.5865.
- [7] M.W. Talakua, Z.A. Leleury, and A.W. Talluta, "ANALISIS CLUSTER DENGAN MENGGUNAKAN METODE K-MEANS UNTUK PENGELOMPOKAN KABUPATEN/KOTA DI PROVINSI MALUKU BERDASARKAN INDIKATOR INDEKS PEMBANGUNAN MANUSIA TAHUN 2014," *Jurnal Ilmu Matematika dan Terapan*, vol. 11, no. 2, pp. 119–128, Dec. 2017.
- [8] Wang Juntao and Su Xiaolong, "An improved K-Means clustering algorithm," in *3rd International Conference on Communication Software and Networks*, Xi'an, China: IEEE, 2011, pp. 44–46. doi: 10.1109/ICCSN.2011.6014384.
- [9] A. L. Musaffak, K. M. Hindrayani, and M. Idhom, "PENERAPAN METODE MEAN SHIFT CLUSTERING UNTUK MENGELOMPOKAN WILAYAH BERDASARKAN PENGELOLAAN SAMPAH," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 3, pp. 4790–4797, 2025, doi: <https://doi.org/10.36040/jati.v9i3.13777>.
- [10] S. Renaldi. S, D. A. Prasetya, and A. Muhaimin, "Analisis Klaster Partitioning Around Medoids dengan Gower Distance untuk Rekomendasi Indekos (Studi Kasus: Indekos di Sekitar Kampus UPNVJT)," *G-Tech: Jurnal Teknologi Terapan*, vol. 8, no. 3, pp. 2060–2069, Jul. 2024, doi: 10.33379/gtech.v8i3.4898.
- [11] Y. Hasan, "Pengukuran Silhouette Score dan Davies-Bouldin Index pada Hasil Cluster K-Means dan Dbscan," *KAKIFIKOM (Kumpulan Artikel Karya Ilmiah Fakultas Ilmu Komputer)*, vol. 06, no. 01, Apr. 2024.
- [12] A. Vij and P. Khandnor, "Validity of Internal Cluster Indices," in *International Conference on Computational Systems and Information Systems for Sustainable Solution*, Bengaluru, India: IEEE, Oct. 2016.