

Klasterisasi Kabupaten/Kota di Provinsi Jawa Barat Berdasarkan Profil Indikator Kesehatan dan Sosial-Demografi Menggunakan Machine Learning

Belinda Eka Sarah Dewi^{*}, Marisa, HS. Sulistyowati, Nasywa Yumna Huwaida
Teknik Informatika, Universitas Bani Saleh, Indonesia

Abstrak: Kesenjangan derajat kesehatan antarwilayah masih menjadi tantangan utama dalam perencanaan kesehatan publik berbasis data di Indonesia. Penelitian ini bertujuan mengembangkan pendekatan klasterisasi (*clustering*) berbasis *machine learning* untuk mengelompokkan 27 kabupaten/kota di Provinsi Jawa Barat berdasarkan kemiripan profil indikator kesehatan dan sosial-demografi menggunakan data pemerintah terbuka. Metode penelitian mengacu pada kerangka CRISP-DM, mulai dari *business understanding* hingga *deployment*. Sembilan indikator awal menghasilkan delapan fitur akhir setelah transformasi rasio dan seleksi berdasarkan variance threshold serta korelasi Spearman. Lima algoritma *clustering* dibandingkan, yaitu K-Means, K-Medoids (PAM), DBSCAN, Agglomerative Hierarchical Clustering, dan Fuzzy C-Means (FCM), dengan jumlah klaster optimal ditentukan melalui *Elbow Method* dan *Silhouette Analysis*. Hasil eksperimen menunjukkan k=6 sebagai jumlah klaster optimal, dengan K-Means, K-Medoids, dan Agglomerative Hierarchical Clustering menghasilkan kualitas klaster identik dengan kualitas internal terbaik pada dataset dan konfigurasi yang diuji (Silhouette Index 0,289; Davies-Bouldin Index 0,978; Calinski-Harabasz Index 9,52), mengungguli Fuzzy C-Means (0,184), sementara DBSCAN gagal membentuk klaster bermakna akibat distribusi kepadatan data yang relatif homogen. Profil tiap klaster menunjukkan perbedaan deskriptif pada sejumlah indikator, dengan rasio dokter, sanitasi layak, dan sumber air layak menunjukkan sinyal eksploratif yang relatif lebih menonjol sebelum koreksi multiple comparison. Namun, setelah koreksi Benjamini-Hochberg dan Holm-Bonferroni terhadap 120 pengujian Mann-Whitney U, tidak terdapat perbedaan yang tetap signifikan secara statistik. Penelitian ini memberikan kontribusi metodologis sebagai dasar pengembangan sistem pemetaan indikator kesehatan dan sosial-demografi wilayah berbasis data terbuka untuk mendukung kebijakan kesehatan daerah yang lebih tepat sasaran.

Kata Kunci: *machine learning*; klasterisasi; profil indikator kesehatan dan sosial-demografi wilayah; *feature selection*; data pemerintah terbuka

Abstract: Disparities in regional health status remain a major challenge for data-driven public health planning in Indonesia. This study aims to develop a machine learning-based clustering approach to group 27 regencies/cities in West Java Province according to the similarity of their health and socio-demographic indicator profiles using open government data. The research follows the CRISP-DM framework, from business understanding to deployment. Five of nine indicators were converted into population-based and live-birth-based rates to remove the confounding effect of regional size differences, then selected using variance

thresholding and Spearman correlation, resulting in eight final features. Five clustering algorithms were compared: K-Means, K-Medoids (PAM), DBSCAN, Agglomerative Hierarchical Clustering, and Fuzzy C-Means (FCM), with the optimal number of clusters determined through the Elbow Method and Silhouette Analysis. The results indicate $k=6$ as the optimal number of clusters, with K-Means, K-Medoids, and Agglomerative Hierarchical Clustering producing identical and best cluster quality (Silhouette Index 0.289; Davies-Bouldin Index 0.978; Calinski-Harabasz Index 9.52), outperforming Fuzzy C-Means (0.184), while DBSCAN failed to form meaningful clusters due to the relatively homogeneous density distribution of the data. Cluster profiles revealed descriptive differences across several indicators, with doctor ratio, proper sanitation, and access to proper water sources showing relatively stronger exploratory signals before multiple-comparison correction. However, after Benjamini-Hochberg and Holm-Bonferroni corrections across 120 Mann-Whitney U tests, none of the differences remained statistically significant. This study provides a methodological contribution as a foundation for developing an open-data-based regional health and socio-demographic indicator mapping system to support more targeted regional health policy.

Keywords: machine learning; clustering; regional health and socio-demographic profile; feature selection; open government data

1. PENDAHULUAN

Pembangunan kesehatan merupakan salah satu prioritas utama dalam agenda pembangunan nasional dan global, sebagaimana tercantum dalam Tujuan Pembangunan Berkelanjutan (SDGs), khususnya SDGs 3 tentang kehidupan sehat dan sejahtera [1]. Seiring berkembangnya teknologi informasi, pemerintah daerah di Indonesia—termasuk Provinsi Jawa Barat—kini menyediakan portal data terbuka (*open government data*) yang memuat data demografi, fasilitas kesehatan, dan indikator sosial ekonomi hingga tingkat kabupaten/kota [2]. Ketersediaan data ini membuka peluang besar bagi pemanfaatan pendekatan *machine learning*, khususnya *clustering*, untuk menganalisis pola indikator kesehatan dan sosial-demografi berbasis wilayah secara sistematis, sejalan dengan pentingnya kebijakan keterbukaan data dalam mendukung transparansi dan inovasi kebijakan publik berbasis bukti [3]. Fenomena ini menjadikan pendekatan berbasis data sebagai kebutuhan mendesak bagi perencanaan kesehatan publik yang lebih objektif dan tepat sasaran.

Di Indonesia, kesenjangan derajat kesehatan antarkabupaten/kota masih cukup signifikan, yang tercermin dari disparitas Angka Kematian Bayi (AKB), Angka Kematian Ibu (AKI), prevalensi stunting, dan ketersediaan tenaga kesehatan antarwilayah [4]. Sayangnya, standar baku klasterisasi indikator kesehatan dan sosial-demografi wilayah yang dapat digunakan secara konsisten oleh pengambil kebijakan hingga saat ini belum tersedia di Indonesia [5], [6]. Sebagian besar kajian yang ada masih menggunakan analisis statistik deskriptif atau pemetaan spasial konvensional tanpa memanfaatkan kemampuan *machine learning* dalam menangkap pola nonlinier dan hubungan multidimensional antarindikator. Di samping itu, penggunaan seluruh variabel tanpa proses seleksi fitur yang sistematis, serta penggunaan indikator dalam skala absolut tanpa memperhitungkan perbedaan ukuran populasi antarwilayah, berpotensi menurunkan kualitas klaster yang dihasilkan, menyulitkan interpretasi hasil, dan pada akhirnya berisiko menghasilkan rekomendasi alokasi sumber daya kesehatan yang kurang tepat sasaran. Kondisi inilah yang menuntut penelitian lebih lanjut untuk mengembangkan pendekatan clustering yang lebih sistematis dan andal.

Beberapa penelitian terdahulu telah menerapkan *clustering* pada data kesehatan wilayah, baik dalam konteks internasional maupun nasional. Lawson [7] mengembangkan model hierarkis Bayesian untuk analisis spasial penyakit, namun pendekatan tersebut kurang fleksibel untuk data multidimensional agregat seperti yang tersedia dalam data pemerintah terbuka. Bhadra et al. [8] menyoroti pentingnya pendekatan berbasis data yang tidak bias dalam analisis kesehatan populasi, yang dapat difasilitasi oleh pemilihan algoritma clustering yang tepat, seperti K-Means dan K-Medoids yang efisien namun berbeda ketahanannya terhadap outlier [9], DBSCAN yang mampu mendeteksi kluster berbentuk arbitrer [7], serta Fuzzy C-Means yang memungkinkan keanggotaan parsial pada data transisional [10]. Di tingkat nasional, Kudadiri et al. [11] menggunakan K-Medoids untuk mengelompokkan 34 provinsi berdasarkan indikator kesehatan lingkungan; Suraya and Wijayanto [12] membandingkan empat algoritma clustering untuk mengelompokkan provinsi berdasarkan indeks penanganan stunting; Maryani et al. [13] menerapkan K-Means untuk mengklasifikasikan indikator keluarga sehat; dan Septiyani [14] membandingkan K-Means dan K-Medoids untuk mengelompokkan angka kematian bayi neonatal di Provinsi Jawa Barat, wilayah studi yang sama dengan penelitian ini.

Meskipun keempat penelitian nasional tersebut memberikan kontribusi penting, masih terdapat sejumlah keterbatasan yang belum tertangani. Pertama, sebagian besar hanya menggunakan satu hingga dua algoritma clustering tanpa perbandingan komprehensif, sehingga sulit memastikan algoritma yang paling sesuai untuk karakteristik data kesehatan wilayah Indonesia. Kedua, tidak satu pun penelitian tersebut menerapkan tahap *feature selection* sistematis (seperti *variance thresholding* atau analisis korelasi) untuk mengeliminasi indikator yang redundan sebelum proses clustering [15], [16]. Ketiga, indikator kesehatan yang digunakan umumnya masih dalam skala absolut atau indeks komposit tunggal tanpa konversi ke skala rasio per populasi atau per kelahiran hidup, sehingga rentan bias akibat perbedaan ukuran wilayah. Keempat, belum ada penelitian yang memvalidasi signifikansi statistik perbedaan profil antarkluster yang dihasilkan. Kesenjangan-kesenjangan inilah yang menjadi dasar dan motivasi utama penelitian ini.

Untuk mengatasi kesenjangan tersebut, penelitian ini mengusulkan pendekatan clustering yang mengacu pada kerangka kerja CRISP-DM (*Cross Industry Standard Process for Data Mining*), yang mengintegrasikan tiga sumber data pemerintah terbuka Provinsi Jawa Barat—data indikator kesehatan, kependudukan, dan kelahiran hidup—untuk menghasilkan sembilan indikator berskala rasio yang menghilangkan bias ukuran populasi antarwilayah. Pendekatan ini menerapkan tahap *feature selection* sistematis menggunakan *variance threshold* dan korelasi Spearman, kemudian membandingkan lima algoritma clustering sekaligus (K-Means, K-Medoids, DBSCAN, Agglomerative Hierarchical Clustering, dan Fuzzy C-Means) menggunakan tiga metrik evaluasi (Silhouette Index, Davies-Bouldin Index, dan Calinski-Harabasz Index), serta menganalisis secara eksploratif perbedaan distribusi fitur antarkluster menggunakan uji Mann-Whitney U. Kebaruan penelitian ini terletak pada integrasi keempat elemen tersebut secara menyeluruh dalam satu kerangka kerja, yang belum diterapkan secara bersamaan pada penelitian clustering kesehatan wilayah di Indonesia sebelumnya.


Berdasarkan uraian tersebut, penelitian ini bertujuan untuk: (1) membangun model clustering berbasis *machine learning* untuk mengelompokkan 27 kabupaten/kota di Provinsi Jawa Barat berdasarkan profil indikator kesehatan dan sosial-demografi menggunakan data pemerintah terbuka; (2) membandingkan kinerja lima algoritma clustering untuk menentukan algoritma yang menghasilkan kualitas kluster terbaik; dan (3) menganalisis karakteristik profil tiap kluster untuk mengidentifikasi pola indikator dominan sebagai dasar rekomendasi kebijakan berbasis data. Penelitian ini diharapkan memberikan kontribusi teoretis berupa kerangka *feature selection* dan validasi statistik untuk clustering data kesehatan wilayah, kontribusi metodologis berupa perbandingan

komprehensif lima algoritma clustering yang dapat direplikasi pada konteks wilayah lain, serta kontribusi praktis berupa dasar pemetaan indikator kesehatan dan sosial-demografi wilayah yang dapat mendukung pengambil kebijakan daerah dalam prioritas intervensi.

2. METODE PENELITIAN

2.1. Tahapan Penelitian Berbasis CRISP-DM

Penelitian ini menggunakan kerangka CRISP-DM (*Cross Industry Standard Process for Data Mining*) sebagai kerangka tahapan penelitian secara keseluruhan. CRISP-DM dipilih karena bersifat sistematis, iteratif, dan terbukti menjadi model proses *data mining* yang paling banyak diadopsi lintas industri dan domain penelitian [17]. Keenam tahapan CRISP-DM yang digunakan disajikan pada diagram alur Gambar 1 dan diuraikan pada bagian berikut



Gambar 1. Diagram Alur Tahapan Penelitian

Business Understanding. Tujuan penelitian ini adalah menghasilkan pengelompokan kabupaten/kota di Provinsi Jawa Barat berdasarkan kemiripan profil indikator kesehatan dan sosial-demografi yang dapat digunakan sebagai dasar prioritas intervensi kesehatan dan alokasi sumber daya oleh pengambil kebijakan daerah, dengan target teknis kualitas kluster setinggi mungkin yang tetap menghasilkan kluster yang dapat diinterpretasikan secara substantif.

Data Understanding. Unit analisis adalah 27 kabupaten/kota di Provinsi Jawa Barat dengan periode data dirata-ratakan pada tahun 2021–2023, yaitu irisan tahun yang tersedia secara lengkap di tiga sumber data pemerintah terbuka Provinsi Jawa Barat: (1) sembilan indikator kesehatan dan sosial-demografi yang diterbitkan Dinas Kesehatan Provinsi Jawa Barat melalui portal Satu Data Jawa Barat (opendata.jabarprov.go.id); (2) data jumlah penduduk kabupaten/kota; dan (3) data jumlah lahir hidup kabupaten/kota. Data dirata-rata lintas tahun dengan pertimbangan: (1) indikator mortalitas seperti AKB dan AKI bersifat sangat sensitif terhadap fluktuasi tahunan pada wilayah dengan jumlah kejadian kecil; (2) tahun 2020 dikecualikan akibat distorsi sistematis pandemi COVID-19 terhadap pelaporan data kesehatan; dan (3) tujuan penelitian adalah mengidentifikasi profil struktural jangka menengah, bukan *snapshot* tahunan. Kesembilan indikator yang digunakan dirangkum pada Tabel 1.

Tabel 1. Daftar Variabel/Fitur Dataset (sebelum *feature selection*)

No.	Variabel	Keterangan	Satuan
1	Angka Kematian Bayi (AKB)	Kematian bayi per 1.000 kelahiran hidup	per 1.000 KH
2	Angka Kematian Ibu (AKI)	Kematian ibu per 100.000 kelahiran hidup	per 100.000 KH
3	Rasio Dokter	Jumlah dokter per 1.000 penduduk	per 1.000 pddk
4	Rasio Puskesmas	Jumlah Puskesmas per 100.000 penduduk	per 100.000 pddk
5	Rasio Rumah Sakit	Jumlah RS per 100.000 penduduk	per 100.000 pddk
6	Tingkat Kemiskinan	Persentase penduduk miskin	%
7	Prevalensi Stunting	Persentase balita stunting	%
8	Sanitasi Layak	Persentase RT dengan sanitasi layak	%
9	Sumber Air Layak	Persentase RT dengan akses air layak	%

Data Preparation. Tahap ini meliputi: (1) konversi lima indikator absolut menjadi rasio per kelahiran hidup atau per jumlah penduduk (2) penanganan *missing values* menggunakan imputasi median antar-kabupaten/kota; (3) deteksi dan penanganan *outlier* menggunakan metode IQR dengan Winsorization untuk mempertahankan jumlah observasi; (4) normalisasi fitur menggunakan *Min-Max Scaling* ke rentang [0,1]; dan (5) *feature selection* menggunakan *variance threshold* (menghapus fitur dengan variansi < 0,01) dan analisis korelasi Spearman (menghapus satu dari dua fitur dengan korelasi > 0,85).

Pada tahap konversi pertama, data mentah yang dihimpun dari portal Satu Data Jawa Barat berbentuk angka absolut, yaitu jumlah kematian bayi, jumlah kematian ibu, jumlah dokter, jumlah Puskesmas, dan jumlah Rumah Sakit per kabupaten/kota per tahun. Kelima indikator absolut ini dikonversi menjadi indikator berbasis populasi (*rate*) menggunakan formula berikut, dihitung untuk setiap tahun 2021, 2022 dan 2023 sebelum dirata-ratakan:

$$AKB = \frac{\text{jumlah kematian bayi}}{\text{jumlah lahir hidup}} \times 1.000$$

$$AKI = \frac{\text{jumlah kematian ibu}}{\text{jumlah lahir hidup}} \times 100.000$$

$$\text{Rasio dokter} = \frac{\text{jumlah dokter}}{\text{jumlah penduduk}} \times 1.000$$

$$\text{Rasio puskesmas} = \frac{\text{jumlah puskesmas}}{\text{jumlah penduduk}} \times 100.000$$

$$\text{Rasio rumah sakit} = \frac{\text{jumlah rumah sakit}}{\text{jumlah penduduk}} \times 100.000$$

Rate tahunan yang diperoleh kemudian dirata-ratakan secara aritmetik antartahun 2021–2023 (*average of annual rates*) untuk memperoleh nilai representatif per kabupaten/kota, alih-alih menjumlahkan seluruh numerator dan denominator ketiga tahun sekaligus (*pooled rate*). Pendekatan rata-rata tahunan dipilih karena lebih sederhana secara komputasi dan cukup representatif mengingat denominator (jumlah lahir hidup/penduduk) relatif stabil antartahun pada level kabupaten/kota; namun demikian, pendekatan *pooled*

rate berpotensi memberikan estimasi yang lebih presisi khususnya untuk wilayah dengan jumlah kejadian (numerator) kecil, dan hal ini diakui secara eksplisit sebagai keterbatasan metodologis penelitian.

Modelling. Penentuan jumlah kluster optimal k dilakukan menggunakan *Elbow Method* (memplot $WCSS/inertia$ terhadap $k = 2$ hingga 10) dan *Silhouette Analysis* (memilih k dengan Silhouette Index rata-rata tertinggi), dengan nilai k final dipilih berdasarkan konsensus kedua metode serta interpretabilitas substantif kluster yang dihasilkan. Lima algoritma *clustering* dibandingkan: K-Means dengan inisialisasi K-Means++; K-Medoids (PAM); DBSCAN dengan tuning parameter epsilon menggunakan *k-distance graph* dan $min_samples = 2 \times \text{jumlah fitur}$; Agglomerative Hierarchical Clustering dengan *linkage Ward*; dan Fuzzy C-Means (FCM) dengan nilai *fuzziness* $m = 2$. K-Means dan K-Medoids dijalankan 10 kali dengan *random seed* berbeda dan diambil hasil dengan Silhouette Index tertinggi mengingat sifat stokastik kedua algoritma. Seluruh eksperimen dilakukan menggunakan Python 3.12 dengan *library* scikit-learn, scikit-learn-extra, scikit-fuzzy, dan lingkungan Google Colaboratory.

Evaluation. Evaluasi kualitas kluster menggunakan tiga metrik internal: Silhouette Index (SI), Davies-Bouldin Index (DBI), dan Calinski-Harabasz Index (CHI). Algoritma dengan SI tertinggi, DBI terendah, dan CHI tertinggi dipilih sebagai model terbaik. Hasil *clustering* terbaik selanjutnya dianalisis profilnya menggunakan nilai rata-rata (*mean*) tiap fitur per kluster, serta diuji signifikansi perbedaan antarkluster menggunakan uji Mann-Whitney U (nonparametrik, dua sampel independen) pada tingkat signifikansi $\alpha = 0,05$.

Deployment. Hasil akhir berupa label kluster, profil karakteristik tiap kluster, dan visualisasi pendukung (dendrogram, diagram pencar PCA) disusun menjadi rekomendasi kebijakan berbasis data bagi pengambil kebijakan kesehatan daerah.

2.2. Metode K-Means

K-Means merupakan algoritma *clustering* berbasis partisi yang mengelompokkan data ke dalam k kluster dengan meminimalkan fungsi objektif:

$$J = \sum_{k=1}^K \sum_{x_i \in C_k} \|x_i - \mu_k\|^2$$

yaitu jumlah kuadrat jarak (*within-cluster sum of squares/WCSS*) antara setiap titik data dengan sentroid klasternya. Inisialisasi sentroid menggunakan K-Means++ untuk mempercepat konvergensi dan menghindari solusi lokal yang buruk. Karena bersifat stokastik, algoritma dijalankan 10 kali dengan *random seed* berbeda ($n_init = 10$) dan hasil dengan Silhouette Index tertinggi dipilih sebagai representasi akhir.

2.3. Metode K-Medoids (PAM)

K-Medoids merupakan varian clustering berbasis partisi yang menggunakan objek data aktual (medoid) sebagai representasi pusat kluster, bukan nilai rata-rata seperti pada K-Means, sehingga lebih robust terhadap outlier. Penelitian ini menggunakan algoritma Partitioning Around Medoids (PAM) dengan pendekatan yang sama seperti K-Means: dijalankan 10 kali dengan *random seed* berbeda dan hasil dengan Silhouette Index tertinggi dipilih sebagai representasi akhir. Penelitian ini menggunakan algoritma *Partitioning Around Medoids* (PAM) dengan jarak Euclidean:

$$d(i, j) = \sqrt{\sum_{n=1}^p (x_{in} - x_{jn})^2}$$

2.4. Metode DBSCAN

Density-Based Spatial Clustering of Applications with Noise (DBSCAN) mengelompokkan data berdasarkan kepadatan lokal: suatu titik dianggap bagian dari kluster apabila memiliki minimal min_samples tetangga dalam radius epsilon, dan titik yang tidak memenuhi syarat ini diklasifikasikan sebagai noise. Keunggulan DBSCAN adalah kemampuannya mendeteksi kluster berbentuk arbitrer serta outlier secara otomatis tanpa perlu menentukan jumlah kluster di awal. Parameter epsilon ditentukan dari titik siku pada k-distance graph, sedangkan min_samples ditetapkan sebesar $2 \times \text{jumlah fitur}$ ($2 \times 8 = 16$) mengikuti aturan umum yang direkomendasikan pada literatur.

2.5. Metode Agglomerative Hierarchical Clustering

Algoritma ini membangun hierarki kluster secara *bottom-up*: setiap titik data mula-mula dianggap sebagai kluster tersendiri, kemudian secara iteratif digabungkan dengan kluster terdekat hingga membentuk satu kluster besar. Penelitian ini menggunakan metode *linkage Ward*, yang menggabungkan dua kluster dengan kenaikan variansi intra-kluster paling kecil pada setiap iterasi, sehingga cenderung menghasilkan kluster yang kompak dan seimbang ukurannya. Proses penggabungan divisualisasikan dalam bentuk dendrogram.

2.6. Metode Fuzzy C-Means

Fuzzy C-Means (FCM) merupakan algoritma soft clustering yang memungkinkan setiap titik data memiliki derajat keanggotaan pada lebih dari satu kluster sekaligus, alih-alih partisi tegas (hard clustering) seperti pada K-Means. Pendekatan ini cocok untuk data wilayah yang memiliki profil transisional atau tidak sepenuhnya homogen. Parameter fuzziness (m) ditetapkan sebesar 2, nilai yang umum digunakan dalam literatur, dan setiap titik data akhirnya ditetapkan ke kluster dengan derajat keanggotaan tertinggi untuk keperluan perbandingan dengan algoritma partisi tegas lainnya.

2.7. Metode Elbow dan Silhouette Analysis

Jumlah kluster optimal (k) ditentukan menggunakan dua metode: *Elbow Method*, yang memplot nilai WCSS terhadap $k = 2$ hingga 10 dan mengidentifikasi titik siku di mana penurunan WCSS mulai melandai; dan *Silhouette Analysis*, yang menghitung rata-rata Silhouette Index untuk setiap nilai k dan memilih k dengan nilai tertinggi. Nilai k final dipilih berdasarkan konsensus kedua metode serta interpretabilitas substantif kluster yang dihasilkan.

2.8. Metode Evaluasi

Kualitas kluster dievaluasi menggunakan tiga metrik internal. Silhouette Index untuk objek i :

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

dengan $a(i)$ rata-rata jarak objek i terhadap objek lain dalam klusternya sendiri dan $b(i)$ rata-rata jarak terkecil objek i terhadap objek pada kluster tetangga terdekat; rentang nilai $[-1, 1]$, semakin mendekati 1 semakin baik. Davies-Bouldin Index:

$$DBI = \frac{1}{K} \sum_{i=1}^K \max_{j \neq i} \frac{S_i + S_j}{M_{ij}}$$

dengan S_i dispersi rata-rata dalam kluster i dan M_{ij} jarak antar-sentroid kluster i dan j ; nilai yang lebih kecil menunjukkan kluster yang lebih kompak dan terpisah dengan baik. Calinski-Harabasz Index:

$$CH = \frac{Tr(B_k)/(k-1)}{Tr(W_k)/(n-k)}$$

dengan $Tr(B_k)$ jejak matriks dispersi antar-kluster dan $Tr(W_k)$ matriks dispersi intra-kluster; nilai yang lebih besar menunjukkan kualitas kluster yang lebih baik. Algoritma dengan SI tertinggi, DBI terendah, dan CHI tertinggi dipilih sebagai model terbaik.

2.9. Uji Mann-Whitney U

Untuk mengidentifikasi indikator yang menunjukkan perbedaan distribusi antarpasangan kluster, dilakukan uji Mann-Whitney U — uji nonparametrik dua sampel independen yang tidak mengasumsikan distribusi normal, sesuai dengan ukuran sampel penelitian yang relatif kecil ($n = 27$). Statistik U dihitung sebagai:

$$U = R_1 - n_1(n_1 + 1)/2$$

dengan R_1 jumlah peringkat (*rank sum*) kelompok pertama dan n_1 ukuran kelompok pertama; nilai p diperoleh dari distribusi U di bawah hipotesis nol bahwa kedua kelompok berasal dari populasi yang sama. Pengujian dilakukan pada seluruh 15 pasangan kluster untuk masing-masing dari delapan fitur (120 pengujian). Karena kluster dibentuk menggunakan kedelapan fitur yang sama, hasil uji ini diposisikan sebagai *analisis eksploratif* untuk mengidentifikasi indikator dengan sinyal indikator terkuat antarkluster, bukan sebagai validasi independen terhadap kualitas *clustering* itu sendiri. Mengingat 120 pengujian dilakukan secara simultan pada sampel yang sama, koreksi *multiple comparison* (Benjamini-Hochberg dan Holm-Bonferroni, keduanya pada tingkat kesalahan 5%) diterapkan untuk mengendalikan inflasi *false positive*.

3. HASIL DAN PEMBAHASAN


3.1. Hasil Penelitian

Dataset akhir yang digunakan terdiri dari 27 kabupaten/kota di Provinsi Jawa Barat dengan sembilan fitur numerik hasil konversi rasio, tanpa *missing values* setelah proses *merge data*. Tahap Winsorization IQR mengoreksi nilai ekstrem pada beberapa fitur: AKB_rate (1 nilai), rasio dokter (2 nilai), rasio Puskesmas (2 nilai), prevalensi stunting (2 nilai), dan sumber air layak (1 nilai). *Variance threshold* tidak mengeliminasi fitur apa pun (seluruh sembilan fitur memiliki variansi $\geq 0,01$ setelah normalisasi), sementara analisis korelasi Spearman mengeliminasi satu fitur, yaitu rasio Rumah Sakit, yang berkorelasi tinggi dengan rasio dokter ($r = 0,88$). Dataset akhir yang digunakan untuk *clustering* terdiri dari delapan fitur: AKB, AKI, rasio dokter, rasio Puskesmas, tingkat kemiskinan, prevalensi stunting, sanitasi layak, dan sumber air layak. Statistik deskriptif kedelapan fitur akhir disajikan pada Tabel 2, dan matriks korelasi Spearman antarindikator ditampilkan pada Gambar 2.

Tabel 2. Statistik Deskriptif Fitur Akhir ($n = 27$ kabupaten/kota)


Fitur	Mean	Std	Min	Median	Max
AKB (per 1.000 KH)	5,84	2,67	0,93	5,22	12,37
AKI (per 100.000 KH)	134,35	56,63	39,51	128,50	282,12
Rasio dokter (per 1.000 pddk)	0,24	0,18	0,06	0,16	0,66
Rasio Puskesmas (per 100rb pddk)	2,58	0,87	1,42	2,41	4,64
Tingkat kemiskinan (%)	8,60	2,80	2,50	8,66	12,66
Prevalensi stunting (%)	21,67	4,30	10,03	21,73	28,43

Sanitasi layak (%)	73,74	15,35	43,40	77,47	96,90
Sumber air layak (%)	93,73	5,86	78,88	95,68	99,51




Gambar 2. Matriks Korelasi Spearman Antarindikator

Berdasarkan Metode Elbow (Gambar 3), nilai WCSS menurun dari 8,87 pada $k = 2$ menjadi 4,39 pada $k = 5$, kemudian melandai secara bertahap hingga 2,09 pada $k = 10$ tanpa titik siku baru yang terlihat jelas setelah $k = 6$. Berdasarkan Gambar 4 (Silhouette Analysis), nilai Silhouette Index tertinggi secara global di antara $k = 2-10$ diperoleh pada $k = 6$ ($SI = 0,2888$) — lebih tinggi dibanding seluruh nilai k lain yang diuji, termasuk $k = 2$ ($SI = 0,2315$). Nilai $k = 6$ dipilih sebagai jumlah kluster final karena merupakan optimum global Silhouette Index yang didukung pola Elbow Method yang mulai melandai pada rentang k yang sama, serta menghasilkan kluster yang secara substantif dapat diinterpretasikan (lihat subbab 3.3). Nilai $k = 6$ ini kemudian diterapkan sebagai jumlah kluster yang sama (common k) pada K-Medoids, Agglomerative Hierarchical Clustering, dan Fuzzy C-Means untuk keperluan pembandingan antaralgoritma,



Gambar 3. Kurva Elbow Method (WCSS terhadap Jumlah Kluster k)

**Gambar 4.** Kurva Silhouette Analysis (k = 2 sampai 10)


Model K-Means dengan k = 6 menghasilkan distribusi anggota kluster sebagai berikut: Kluster 0 (9 wilayah): Kabupaten Bandung, Tasikmalaya, Sukabumi, Pangandaran, Garut, Purwakarta, Bandung Barat, Cianjur, dan Bogor. Kluster 1 (8 wilayah): Kabupaten Cirebon, Subang, Sumedang, Kuningan, Karawang, Indramayu, Ciamis, dan Majalengka. Kluster 2 (3 wilayah): Kota Bandung, Kota Bogor, dan Kota Cimahi. Kluster 3 (3 wilayah): Kabupaten Bekasi, Kota Bekasi, dan Kota Depok. Kluster 4 (2 wilayah): Kota Sukabumi dan Kota Tasikmalaya. Kluster 5 (2 wilayah): Kota Banjar dan Kota Cirebon. Tabel 3 menyajikan profil rata-rata sembilan indikator per kluster (termasuk rasio Rumah Sakit yang tereliminasi pada tahap *clustering* namun tetap disajikan sebagai data pendukung).

Tabel 3. Profil Rata-Rata Indikator per Kluster (K-Means, k = 6)


Indikator	Kluster 0	Kluster 1	Kluster 2	Kluster 3	Kluster 4	Kluster 5	Jabar
AKB (per 1.000 KH)	5,23	6,52	5,11	2,04	8,21	10,29	5,84
AKI (per 100rb KH)	118,6	148,5	98,9	62,6	214,9	228,9	134,4
Rasio dokter (/1000)	0,12	0,14	0,55	0,34	0,34	0,48	0,24
Rasio Puskesmas (/100rb)	2,14	2,64	2,57	1,66	3,61	4,64	2,58
Kemiskinan (%)	9,15	10,62	5,41	3,99	10,19	8,17	8,60
Stunting (%)	24,96	20,13	19,63	15,97	23,93	22,38	21,67
Sanitasi layak (%)	64,32	81,85	67,18	93,35	48,62	89,31	73,74
Air layak (%)	87,24	96,08	98,42	98,04	97,00	97,86	93,73
Jumlah kab/kota	9	8	3	3	2	2	27

Gambar 5 menyajikan dendrogram hasil Agglomerative Hierarchical Clustering dengan metode *linkage* Ward, memperlihatkan proses penggabungan wilayah secara hierarkis berdasarkan kemiripan karakteristik pada delapan fitur hasil *feature selection*. Gambar 6 menyajikan visualisasi distribusi 27 kabupaten/kota pada ruang dua dimensi hasil *Principal*

Component Analysis (PCA) yang menjelaskan 41,9% (PC1) dan 27,2% (PC2) variansi data, dengan pewarnaan berdasarkan hasil klasterisasi K-Means.



Gambar 5. Dendrogram Agglomerative Hierarchical Clustering (Linkage Ward)



Gambar 6. Visualisasi Klaster pada Proyeksi PCA 2 Dimensi

3.2. Hasil Pengujian

Pengujian dilakukan untuk membandingkan kinerja lima algoritma *clustering* (K-Means, K-Medoids, DBSCAN, Agglomerative Hierarchical Clustering, dan Fuzzy C-Means) pada kondisi data yang identik, yaitu 27 kabupaten/kota, delapan fitur hasil *feature selection*, dan jumlah klaster $k = 6$ (kecuali DBSCAN yang menentukan jumlah klaster secara otomatis berdasarkan kepadatan data). Parameter evaluasi yang digunakan adalah Silhouette Index (SI), Davies-Bouldin Index (DBI), dan Calinski-Harabasz Index (CHI). Hasil pengujian kelima algoritma disajikan pada Tabel 4.

Tabel 4. Perbandingan Kualitas Klaster Lima Algoritma ($k = 6$)

Algoritma	Silhouette Index	DBI	Calinski-Harabasz	k Aktual
K-Means	0,2888	0,9780	9,52	6
K-Medoids (PAM)	0,2888	0,9780	9,52	6

Agglomerative (Ward)	0,2888	0,9780	9,52	6
Fuzzy C-Means	0,1841	1,2827	7,49	6
DBSCAN	–	–	–	1 (gagal)

Hasil pengujian pada Tabel 4 menunjukkan K-Means, K-Medoids, dan Agglomerative Hierarchical Clustering menghasilkan nilai SI, DBI, dan CHI yang identik (SI = 0,2888; DBI = 0,978; CHI = 9,52). Fuzzy C-Means menghasilkan SI = 0,1841, DBI = 1,2827, dan CHI = 7,49. Pengujian DBSCAN dilakukan pada dua nilai *epsilon*: pada *epsilon* = 1,1 (ditentukan dari titik siku k-distance graph) dengan min_samples = 16 (2 × delapan fitur), seluruh 27 observasi terklasifikasi ke dalam satu kluster dominan tanpa titik *noise*; pada pengujian lanjutan dengan *epsilon* = 0,72, DBSCAN tetap menghasilkan satu kluster dominan dengan 8 titik dianggap *noise*, tanpa membentuk kluster tambahan.

Untuk memverifikasi klaim bahwa K-Means, K-Medoids, dan Agglomerative menghasilkan partisi yang identik, dilakukan perbandingan langsung label kluster menggunakan Adjusted Rand Index (ARI) dan Normalized Mutual Information (NMI). Ketiga pasangan algoritma yaitu Agglomerative vs K-Means, K-Medoids vs K-Means, dan K-Medoids vs Agglomerative seluruhnya menghasilkan ARI = 1,0 dan NMI = 1,0 (Tabel 5). Hal ini membuktikan ketiga partisi identik secara persis. Tabel 6 menyajikan *label correspondence matrix* antara K-Means dan K-Medoids sebagai bukti langsung bahwa setiap kluster K-Means berpadanan tepat satu ke satu dengan satu kluster K-Medoids tanpa tumpang tindih keanggotaan wilayah, dengan pola yang identik juga berlaku untuk Agglomerative.

Tabel 5. Kesepakatan Partisi Antaralgoritma ARI dan NMI

Pasangan Algoritma	ARI	NMI	Keterangan
Agglomerative vs K-Means	1,00	1,00	Diverifikasi langsung dari label kluster
K-Medoids vs K-Means	1,00	1,00	Diverifikasi langsung dari label kluster
Agglomerative vs K-Medoids	1,00	1,00	Diverifikasi langsung dari label kluster

Tabel 6 menunjukkan pola diagonal-permutasi sempurna, yaitu setiap baris dan kolom hanya memiliki tepat satu sel bernilai bukan nol, tanpa ada wilayah yang terbagi ke lebih dari satu kluster yang berbeda antara kedua algoritma. Pola yang identik juga berlaku pada perbandingan Agglomerative terhadap K-Means maupun K-Medoids. Bukti langsung ini mengonfirmasi bahwa kesamaan nilai Silhouette Index, DBI, dan CHI pada Tabel 4 benar-benar mencerminkan partisi kluster yang identik, bukan kebetulan numerik.

Tabel 6. *label correspondence matrix* antara K-Means dan K-Medoids

K-Means / K-Medoids	0	1	2	3	4	5
0	0	0	0	9	0	0
1	8	0	0	0	0	0
2	0	3	0	0	0	0
3	0	0	3	0	0	0
4	0	0	0	0	0	2

5 0 0 0 0 2 0

Sebagai analisis eksploratif, uji Mann-Whitney U dilakukan untuk mengidentifikasi fitur yang menunjukkan perbedaan distribusi antar-klaster. Karena fitur yang diuji juga digunakan dalam pembentukan klaster, hasil pengujian tidak dimaksudkan sebagai validasi independen terhadap struktur klaster. Oleh karena itu, interpretasi difokuskan pada besarnya perbedaan antar-klaster melalui ukuran efek rank-biserial correlation (r), disertai koreksi Benjamini-Hochberg untuk multiple comparisons.

Pengujian signifikansi statistik dilakukan menggunakan uji Mann-Whitney U pada seluruh 15 pasangan klaster untuk masing-masing dari delapan fitur (120 pengujian) pada tingkat signifikansi $\alpha = 0,05$. Sebelum koreksi, 35 dari 120 pengujian (29,2%) menunjukkan $p < 0,05$, dengan proporsi tertinggi pada rasio dokter (53,3%; 8 dari 15 pasangan), sanitasi layak (40,0%), dan sumber air layak (33,3%). Namun, karena 120 pengujian dilakukan secara simultan pada sampel yang sama, koreksi *multiple comparison* diterapkan: setelah koreksi Benjamini-Hochberg (mengendalikan *false discovery rate* pada 5%) maupun koreksi Holm-Bonferroni (lebih konservatif), tidak ada satu pun dari 120 pengujian yang tetap signifikan (0 dari 120, 0%).


Tabel 7. Ringkasan Effect Size (Rank-Biserial r) dan Proporsi Signifikansi per Fitur (120 Uji Mann-Whitney U, $k=6$)

Fitur	Mean $ r $	Max $ r $	$ r \geq 0.5$ (besar)	$ r \geq 0.3$ (sedang)	Sig. sebelum koreksi (dari 15)	Sig. setelah koreksi BH
AKB	0,761	1,0	12	1	3/15	0
AKI	0,742	1,0	12	1	2/15	0
Rasio Dokter	0,763	1,0	11	2	8/15	0
Rasio Puskesmas	0,838	1,0	14	0	4/15	0
Kemiskinan	0,700	1,0	10	4	4/15	0
Stunting	0,637	1,0	10	3	3/15	0
Sanitasi Layak	0,845	1,0	14	0	6/15	0
Sumber Air Layak	0,600	1,0	10	3	5/15	0

Keterangan: $|r|$ = nilai absolut rank-biserial correlation (effect size); $|r| < 0.1$ = sangat kecil; $0.1-0.3$ = kecil; $0.3-0.5$ = sedang; > 0.5 = besar. Sig. BH = signifikan setelah koreksi Benjamini-Hochberg pada $\alpha = 0.05$.

Selain p -value, ukuran efek dihitung untuk menggambarkan magnitude perbedaan antar pasangan klaster pada Tabel 7. Dari 120 pengujian Mann-Whitney U, sebanyak 93 pengujian (77,5%) menunjukkan effect size besar, 14 (11,7%) sedang, 6 (5,0%) kecil, dan 7 (5,8%) sangat kecil. Nilai absolut effect size memiliki rata-rata 0,736 dan median 0,882. Meskipun sebagian besar perbandingan menunjukkan magnitude perbedaan yang relatif besar, hasil tersebut tidak dapat diinterpretasikan sebagai perbedaan yang signifikan secara statistik karena setelah koreksi Benjamini-Hochberg dan Holm-Bonferroni tidak terdapat pengujian yang tetap signifikan. Dengan demikian, effect size digunakan sebagai informasi deskriptif mengenai magnitude perbedaan dan bukan sebagai bukti inferensial independen terhadap struktur klaster.

Mengingat nilai Silhouette Index yang diperoleh (0,289) berada di bawah ambang batas yang umum dianggap sebagai indikasi struktur kluster yang kuat ($> 0,50$), dilakukan bootstrap stability analysis untuk menilai konsistensi partisi kluster secara empiris. Hasil stability analysis disajikan pada Gambar 7. Analisis stabilitas dilakukan melalui 200 pengulangan bootstrap dengan rasio resampling sebesar 90% (24 dari 27 kabupaten/kota) pada setiap pengulangan. Konsistensi partisi terhadap hasil baseline dievaluasi menggunakan Adjusted Rand Index (ARI). Hasil menunjukkan nilai ARI rata-rata sebesar $0,856 \pm 0,1301$ dengan median 0,8435 dan rentang 0,4612–1,0000. Sebanyak 98,5% pengulangan menghasilkan $ARI \geq 0,6$, sedangkan seluruh pengulangan menghasilkan $ARI \geq 0,4$. Hasil tersebut menunjukkan bahwa struktur partisi yang diperoleh relatif stabil terhadap perubahan sampel, meskipun terdapat variasi tertentu pada sebagian kecil pengulangan.



Gambar 7. Distribusi nilai Adjusted Rand Index (ARI)

3.3. Analisis Perbandingan

Dibandingkan dengan penelitian terdahulu yang diuraikan pada bagian Pendahuluan, penelitian ini menunjukkan sejumlah kelebihan metodologis. Septiyani [14] hanya membandingkan dua algoritma (K-Means dan K-Medoids) pada satu indikator tunggal (AKB neonatal) di wilayah studi yang sama; penelitian ini membandingkan lima algoritma pada delapan indikator hasil *feature selection* sistematis, sehingga memberikan gambaran yang lebih komprehensif mengenai algoritma mana yang paling sesuai untuk data kesehatan wilayah Jawa Barat. Suraya and Wijayanto [12] membandingkan empat algoritma namun hanya pada satu indeks komposit stunting tanpa validasi statistik; penelitian ini melengkapi perbandingan algoritma dengan analisis eksploratif Mann-Whitney U beserta koreksi *multiple comparison*, menghasilkan kesimpulan yang lebih berhati-hati mengenai signifikansi perbedaan antarkluster (lihat pembahasan di bawah). Kudadiri et al. [11] dan Maryani et al. [13] masing-masing hanya menerapkan satu algoritma (*single-method*) tanpa perbandingan, sehingga tidak dapat memastikan apakah algoritma yang dipilih benar-benar optimal untuk karakteristik data yang digunakan.

Kesamaan hasil evaluasi yang identik antara K-Means, K-Medoids, dan Agglomerative Hierarchical Clustering pada Tabel 4 dikonfirmasi secara langsung melalui perbandingan label kluster: ketiga pasangan algoritma (Agglomerative vs K-Means, K-Medoids vs K-

Means, dan K-Medoids vs Agglomerative) seluruhnya menghasilkan Adjusted Rand Index dan Normalized Mutual Information sebesar 1,0 (Tabel 5), membuktikan ketiga partisi identik secara persis, bukan sekadar kebetulan angka metrik yang berdekatan, sebagaimana ditunjukkan pula secara visual oleh pola diagonal-permutasi sempurna pada *label correspondence matrix* (Tabel 6). Kesamaan ini kemungkinan besar disebabkan oleh struktur data yang relatif kompak dan terpisah dengan baik pada ruang fitur berdimensi rendah (delapan fitur) dengan jumlah observasi yang kecil ($n = 27$), sehingga ketiga pendekatan yang berbeda secara algoritmik konvergen pada solusi optimal yang sama. Fuzzy C-Means menghasilkan kualitas klaster yang lebih rendah pada metrik partisi tegas (Silhouette Index 0,1841), yang wajar mengingat FCM mengoptimalkan keanggotaan parsial (*soft clustering*) alih-alih partisi tegas; metrik khusus *soft clustering* (FPC = 0,3503; PE = 1,34) mengonfirmasi derajat keanggotaan *fuzzy* yang tidak terlalu tegas pada dataset ini.

Berdasarkan profil pada Tabel 3, dapat diidentifikasi enam profil wilayah yang berbeda secara deskriptif. Klaster 3 (Kabupaten Bekasi, Kota Bekasi, Kota Depok) menunjukkan profil indikator kesehatan dan sosial-demografi paling baik, dengan AKB dan AKI terendah (2,04 per 1.000 KH dan 62,6 per 100.000 KH), kemiskinan terendah (3,99%), dan sanitasi layak tertinggi (93,35%), konsisten dengan karakteristik wilayah aglomerasi metropolitan Jabodetabek yang memiliki infrastruktur kesehatan dan sosial ekonomi relatif mapan. Klaster 2 (Kota Bandung, Kota Bogor, Kota Cimahi) menunjukkan rasio dokter tertinggi (0,55 per 1.000 penduduk) serta kemiskinan rendah (5,41%), merepresentasikan kota besar dengan konsentrasi tenaga medis tinggi.

Sebaliknya, Klaster 0 dan Klaster 1 yang didominasi wilayah kabupaten dengan cakupan geografis luas menunjukkan prevalensi stunting tertinggi (24,96% dan 20,13%) dan sanitasi layak yang relatif rendah (64,32% dan 81,85%), disertai tingkat kemiskinan yang juga lebih tinggi dari rata-rata provinsi, khususnya pada Klaster 1 (10,62%). Pola yang menarik ditunjukkan oleh Klaster 4 dan Klaster 5 (Kota Sukabumi, Kota Tasikmalaya, Kota Banjar, dan Kota Cirebon): keempat kota kecil ini justru menunjukkan AKB dan AKI tertinggi di antara seluruh klaster (AKB 8,21–10,29 per 1.000 KH; AKI 214,9–228,9 per 100.000 KH), meskipun rasio Puskesmas dan Rumah Sakitnya termasuk yang tertinggi (khususnya Klaster 5 dengan rasio Puskesmas 4,64 per 100.000 penduduk). Pola deskriptif ini mengindikasikan kemungkinan bahwa tingginya AKB/AKI pada kelompok kota kecil ini tidak semata-mata disebabkan oleh kurangnya infrastruktur fisik, melainkan berpotensi dipengaruhi oleh faktor lain seperti kualitas dan utilisasi layanan, akses terhadap tenaga spesialis, atau karakteristik rujukan pasien dari wilayah kabupaten sekitarnya menuju fasilitas kesehatan di kota tersebut. Sebuah hipotesis yang memerlukan investigasi lebih lanjut dengan data dan desain penelitian yang lebih memadai, mengingat ukuran klaster yang sangat kecil ($n = 2$) membatasi generalisasi temuan ini.

Hasil uji Mann-Whitney U memerlukan interpretasi yang berhati-hati. Sebelum koreksi *multiple comparison*, rasio dokter, sanitasi layak, dan sumber air layak menunjukkan proporsi $p < 0,05$ tertinggi, yang secara eksploratif mengindikasikan ketiga indikator tersebut sebagai indikator dengan sinyal relatif terkuat antarklaster. Namun, setelah koreksi Benjamini-Hochberg maupun Holm-Bonferroni diterapkan pada 120 pengujian, tidak ada satu pun pasangan klaster-fitur yang tetap signifikan secara statistik. Hasil ini konsisten dengan keterbatasan daya uji (*statistical power*) akibat ukuran sampel yang kecil ($n = 27$) dan empat dari enam klaster yang hanya beranggotakan dua hingga tiga wilayah, bukan berarti tidak ada perbedaan substantif antarklaster, melainkan bahwa perbedaan deskriptif yang teramati pada Tabel 3 belum dapat dikonfirmasi signifikan secara statistik pada tingkat kepercayaan yang ketat setelah koreksi *multiple comparison*. Oleh karena itu, profil klaster pada penelitian ini sebaiknya dipahami sebagai pengelompokan deskriptif-

eksploratif berbasis kemiripan multidimensional, bukan sebagai klaster yang telah tervalidasi berbeda secara statistik.

Dengan mempertimbangkan keterbatasan statistik tersebut, hasil klasterisasi ini tetap memiliki nilai praktis sebagai dasar diskusi kebijakan kesehatan, meskipun rekomendasi berikut sebaiknya diperlakukan sebagai hipotesis awal yang memerlukan validasi lebih lanjut, bukan kesimpulan definitif. Klaster 4 dan 5 (kota-kota kecil dengan AKB/AKI tertinggi meski infrastruktur relatif memadai) berpotensi memerlukan perhatian pada kualitas dan utilisasi layanan kesehatan ibu dan anak. Klaster 0 dan 1 (wilayah kabupaten dengan stunting dan kemiskinan tinggi, sanitasi rendah) menunjukkan pola yang sejalan dengan kebutuhan penguatan program sanitasi berbasis masyarakat dan pengentasan kemiskinan yang terintegrasi dengan program kesehatan. Klaster 3 (Bekasi–Depok) dapat menjadi acuan awal (*benchmark*) praktik pengelolaan layanan kesehatan wilayah metropolitan bagi wilayah lain dengan karakteristik urban serupa, sejalan dengan tujuan SDGs 3 dalam mengurangi kesenjangan derajat kesehatan antardaerah [1], [4].

Pada penelitian ini ada beberapa catatan metodologis dan keterbatasan perlu disampaikan. Pertama, nilai Silhouette Index terbaik yang diperoleh (0,289) menunjukkan struktur pemisahan antarklaster yang relatif lemah. Meskipun bootstrap stability analysis menghasilkan ARI rata-rata $0,856 \pm 0,130$ yang mengindikasikan relative stabil, nilai SI yang rendah ini kemungkinan besar disebabkan oleh ukuran sampel kecil ($n=27$) dan homogenitas geografis provinsi tunggal. Oleh karena itu, temuan ini perlu diperlakukan sebagai pengelompokan deskriptif-eksploratif dengan validasi empiris terbatas. Kedua, setelah koreksi *multiple comparison*, tidak ada perbedaan antarklaster yang tetap signifikan secara statistik pada uji Mann-Whitney U, sehingga profil klaster yang dihasilkan bersifat deskriptif-eksploratif dan belum tervalidasi secara inferensial. Ketiga, konversi indikator AKB dan AKI menggunakan pendekatan rata-rata *rate* tahunan (*average of annual rates*), bukan *pooled rate* berbasis total numerator dan denominator tiga tahun; pendekatan *pooled rate* berpotensi memberikan estimasi yang lebih presisi dan menjadi arah perbaikan pada penelitian lanjutan. Keempat, nilai $k = 6$ diterapkan secara seragam pada empat algoritma partisi/hierarki untuk keperluan perbandingan yang adil, bukan hasil optimasi k independen untuk masing-masing algoritma; pencarian k optimal per algoritma merupakan arah penelitian lanjutan yang lebih komprehensif. Kelima, empat dari enam klaster hanya beranggotakan dua hingga tiga wilayah, yang membatasi generalisasi profil klaster dan daya uji statistik. Keenam, penelitian ini terbatas pada cakupan Provinsi Jawa Barat karena ketersediaan data terintegrasi lintas-sumber; perluasan cakupan ke provinsi lain memerlukan verifikasi ketersediaan dan konsistensi definisi operasional data pada masing-masing provinsi.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan pendekatan klasterisasi berbasis machine learning untuk mengelompokkan 27 kabupaten/kota di Provinsi Jawa Barat berdasarkan profil indikator kesehatan dan sosial-demografi menggunakan data pemerintah terbuka. Beberapa temuan utama: (1) algoritma K-Means, K-Medoids, dan Agglomerative Hierarchical Clustering menghasilkan kualitas klaster identik dengan kualitas internal terbaik pada dataset dan konfigurasi yang diuji dengan Silhouette Index 0,289 dan Davies-Bouldin Index 0,978, mengungguli Fuzzy C-Means (Silhouette Index 0,184), sementara DBSCAN gagal membentuk klaster bermakna akibat distribusi kepadatan data yang homogen; (2) jumlah klaster optimal $k = 6$ menghasilkan pengelompokan yang dapat diinterpretasikan secara substantif; (3) *feature selection* berbasis *variance threshold* dan korelasi Spearman berhasil mereduksi dimensi dari sembilan menjadi delapan fitur setelah mengeliminasi rasio Rumah Sakit yang redundan dengan rasio dokter; dan (4) profil tiap klaster menunjukkan pola perbedaan deskriptif antarwilayah, dengan rasio dokter, sanitasi

layak, dan sumber air layak memperlihatkan sinyal eksploratif yang relatif lebih menonjol sebelum koreksi multiple comparison. Namun, hasil uji Mann-Whitney U setelah koreksi Benjamini-Hochberg dan Holm-Bonferroni tidak menunjukkan perbedaan yang tetap signifikan secara statistik. Oleh karena itu, karakteristik kluster dalam penelitian ini perlu dipahami sebagai pola deskriptif-eksploratif berdasarkan kemiripan multidimensional, bukan sebagai perbedaan antarkluster yang telah tervalidasi secara inferensial.

Keterbatasan penelitian ini meliputi ukuran sampel yang kecil dan cakupan geografis tunggal provinsi yang membatasi kualitas pemisahan kluster secara statistik, serta tidak adanya validasi lapangan terhadap profil kluster yang dihasilkan. Penelitian lanjutan disarankan untuk memperluas cakupan wilayah ke provinsi lain di Indonesia guna meningkatkan keragaman dan kualitas kluster, mengintegrasikan analisis spasial (*geographic clustering*) untuk mengonfirmasi pola kedekatan geografis antarkluster, menginvestigasi lebih lanjut penyebab tingginya AKB/AKI pada kluster kota kecil melalui data kualitas dan utilisasi layanan kesehatan, serta melakukan validasi profil kluster bersama pemangku kepentingan kesehatan daerah.

PERNYATAAN KONTRIBUSI PENULIS (CREDIT)

Belinda Eka Sarah Dewi: Konseptualisasi, metodologi, analisis data, validasi hasil, penulisan naskah, korespondensi. **Marisa:** Kurasi data, peninjauan naskah, penyuntingan. **HS. Sulistyowati:** Validasi metodologi, peninjauan naskah. **Nasya Yumna H:** Pengumpulan data.

PERNYATAAN KONFLIK KEPENTINGAN

Para penulis menyatakan bahwa tidak terdapat kepentingan finansial atau hubungan pribadi yang diketahui yang dapat memengaruhi hasil penelitian yang dilaporkan dalam artikel ini.

PERNYATAAN PENDANAAN

Penelitian ini didukung oleh Universitas Bani Saleh [nomor hibah 018/PN/LPPM-UBS/IV/2026].

PERNYATAAN PENGGUNAAN AI GENERATIF DAN TEKNOLOGI BERBANTUAN AI DALAM PROSES PENULISAN

Para penulis menggunakan Generative AI untuk meningkatkan kejelasan penulisan artikel ini. Seluruh konten yang dibantu oleh AI telah ditinjau dan disunting oleh penulis, dan para penulis bertanggung jawab sepenuhnya atas isi akhir yang dipublikasikan.

REFERENCES

- [1] World Health Organization, *Global Health Estimates 2019: Disease Burden by Cause, Age, Sex, by Country and by Region*. Geneva, Switzerland: WHO, 2020.
- [2] A. Zuiderwijk and M. Janssen, "Open data policies, their implementation and impact: A framework for comparison," *Government Information Quarterly*, vol. 31, no. 1, pp. 17-29, 2014.
- [3] World Bank, *Open Data for Sustainable Development*. Washington, DC, USA: World Bank, 2019.
- [4] Kementerian Perencanaan Pembangunan Nasional (Bappenas), *Roadmap of SDGs Indonesia: A Highlight*. Jakarta, Indonesia: Bappenas, 2020.

- [5] R. Miotto, F. Wang, S. Wang, X. Jiang, and J. T. Dudley, "Deep learning for healthcare: review, opportunities and challenges," *Briefings in Bioinformatics*, vol. 19, no. 6, pp. 1236–1246, 2018.
- [6] B. Shickel, P. J. Tighe, A. Bihorac, and P. Rashidi, "Deep EHR: A survey of recent advances in deep learning techniques for electronic health record analysis," *IEEE Journal of Biomedical and Health Informatics*, vol. 22, no. 5, pp. 1589–1604, 2018.
- [7] A. B. Lawson, *Bayesian Disease Mapping: Hierarchical Modeling in Spatial Epidemiology*, 3rd ed. Boca Raton, FL, USA: CRC Press, 2018.
- [8] A. Bhadra, J. He, and S. Parthasarathy, "Reducing bias in machine learning-based health risk prediction," *Patterns*, vol. 2, no. 9, art. no. 100313, 2021.
- [9] S. Lessmann, B. Baesens, H. V. Seow, and L. C. Thomas, "Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research," *European Journal of Operational Research*, vol. 247, no. 1, pp. 124–136, 2015.
- [10] H. Liu and H. Motoda, *Feature Selection for Knowledge Discovery and Data Mining*. Boston, MA, USA: Springer, 2012.
- [11] M. S. Kudadiri, P. Silvianti, and F. M. Afendi, "Pengelompokan provinsi berdasarkan capaian indikator kesehatan lingkungan di Indonesia tahun 2020," *Xplore: Journal of Statistics*, vol. 11, no. 3, pp. 191–202, 2022.
- [12] G. R. Suraya and A. W. Wijayanto, "Comparison of hierarchical clustering, K-Means, K-Medoids, and Fuzzy C-Means methods in grouping provinces in Indonesia according to the special index for handling stunting," *Indonesian Journal of Statistics and Its Applications*, vol. 6, no. 2, pp. 180–201, 2022.
- [13] H. Maryani, A. Rizkianti, and N. Izza, "Classification of healthy family indicators in Indonesia based on a K-means cluster analysis," *Journal of Preventive Medicine and Public Health*, vol. 57, no. 3, pp. 234–241, 2024.
- [14] I. P. Septiyani, "Comparative analysis of K-Means clustering and K-Medoids clustering methods in clustering neonatal infant mortality rates in West Java Province," *Journal of Artificial Intelligence and Engineering Applications*, vol. 5, no. 3, pp. 4001–4010, 2026.
- [15] I. Guyon and A. Elisseeff, "An introduction to variable and feature selection," *Journal of Machine Learning Research*, vol. 3, pp. 1157–1182, 2003.
- [16] G. Chandrashekar and F. Sahin, "A survey on feature selection methods," *Computers & Electrical Engineering*, vol. 40, no. 1, pp. 16–28, 2014.
- [17] C. Schröer, F. Kruse, and J. M. Gómez, "A systematic literature review on applying CRISP-DM process model," *Procedia Computer Science*, vol. 181, pp. 526–534, 2021.