

Pemetaan Daerah Rawan Bencana di Pulau Sulawesi menggunakan Metode *Density-Based Spatial Clustering of Applications with Noise (DBSCAN)*

Havinka Angel Salsabilla*, Nandini Lova Diani, Abimanyu Arya Ramadhan, M. Al Haris

Program Studi Statistika, Universitas Muhammadiyah Semarang, Semarang, Indonesia

*Corresponding author: havinkaangels@gmail.com

Abstrak

Indonesia terletak pada pertemuan tiga lempeng tektonik aktif sehingga memiliki tingkat kerawanan yang tinggi terhadap bencana alam seperti gempa bumi, banjir, letusan gunung api, dan tanah longsor. Pulau Sulawesi merupakan salah satu wilayah dengan aktivitas seismik dan hidrometeorologi yang tinggi, sehingga identifikasi daerah rawan bencana menjadi penting dalam upaya pengurangan risiko dan perencanaan mitigasi yang efektif. Penelitian ini bertujuan untuk memetakan daerah rawan bencana di Pulau Sulawesi menggunakan algoritma density-based spatial clustering of applications with noise (DBSCAN). DBSCAN merupakan metode klusterisasi berbasis kepadatan yang mampu mengidentifikasi pola spasial tanpa harus menentukan jumlah kluster di awal serta dapat mendeteksi data pencilan (outlier). Data yang digunakan adalah data sekunder dari Badan Nasional Penanggulangan Bencana (BNPB) tahun 2020–2024 yang mencakup kejadian bencana di seluruh kabupaten/kota di Pulau Sulawesi. Variabel yang dianalisis meliputi frekuensi kejadian banjir, tanah longsor, cuaca ekstrem, kekeringan, gempa bumi, letusan gunung api, dan gelombang pasang. Sebelum proses klusterisasi, data dinormalisasi menggunakan metode Min-Max. Hasil terbaik diperoleh pada parameter $\epsilon = 0,28$ dan MinPts = 5, yang menghasilkan dua kluster utama dan satu kelompok noise. Kluster 1 menunjukkan wilayah dengan tingkat kejadian bencana tertinggi, terutama banjir, tanah longsor, dan cuaca ekstrem. Kluster 0 mencakup wilayah dengan intensitas bencana sedang, sedangkan kelompok noise terdiri atas wilayah dengan tingkat kejadian bencana yang rendah atau pola bencana yang tidak jelas. Penerapan algoritma DBSCAN terbukti efektif dalam pemetaan kerawanan bencana karena mampu menangani distribusi spasial yang tidak merata serta mengungkap pola tersembunyi. Hasil penelitian ini diharapkan dapat menjadi dasar dalam pengembangan strategi mitigasi bencana yang lebih terarah. Penelitian selanjutnya disarankan untuk menambahkan indikator kerentanan sosial-ekonomi serta memperluas cakupan data.

Indonesia is located at the confluence of three active tectonic plates, making it highly vulnerable to natural disasters such as earthquakes, floods, volcanic eruptions, and landslides. Sulawesi Island is one of the regions with the highest seismic and hydro-meteorological activity in Indonesia, so identifying its disaster-prone areas is crucial for effective risk reduction and mitigation planning. This study aims to map disaster-prone areas in Sulawesi Island using the density-based spatial clustering of applications with noise (DBSCAN) algorithm. DBSCAN is a density-based clustering method that is able to identify spatial patterns without determining the number of clusters from the start, as well as detect outlier data. The data used is secondary data from National Disaster Management Authority (BNPB) for 2020–2024 covering disaster events in all districts/cities in Sulawesi. The variables analyzed include the frequency of floods, landslides, extreme weather, droughts, earthquakes, volcanic eruptions, and tidal waves. The data was normalized using the Min-Max method before the clustering process. The best results were obtained at parameters $\epsilon = 0.28$ and MinPts = 5, resulting in two main clusters and one noise group. Cluster 1 shows areas with the highest disaster occurrences, especially floods, landslides, and extreme weather. Cluster 0 includes areas with moderate disaster intensity, while the noise group consists of areas with low or unclear disaster patterns. The application of DBSCAN has proven effective for disaster vulnerability because it is able to handle uneven spatial distribution and reveal hidden patterns. These results are expected to be the basis for developing more targeted disaster mitigation strategies. Further research is recommended to add socio-economic vulnerability indicators and expand data coverage.

Kata kunci: DBSCAN; Sulawesi; klusterisasi spasial; pemetaan bencana; mitigasi risiko

Keywords: DBSCAN; Sulawesi; spatial clustering; disaster mapping; risk mitigation

This is an open access article under
the [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/)



How to Cite:

H. A. Salsabilla, N. L. Diani, A. A. Ramadhan, and M. Al Haris. "Pemetaan daerah rawan bencana di Pulau Sulawesi menggunakan metode density-based spatial clustering of applications with noise (DBSCAN)," *Indonesian Journal of Applied Statistics*, vol. 8, no. 2, pp. 137-147, 2025, doi: 10.13057/ijas.v8i2.106040.

1. PENDAHULUAN

Indonesia merupakan negara kepulauan yang terletak di pertemuan tiga lempeng tektonik utama, yaitu Lempeng Eurasia, Indo-Australia, dan Pasifik [1]. Letak ini menjadikan Indonesia sebagai salah satu negara dengan tingkat kerawanan bencana alam tertinggi di dunia, termasuk gempa bumi, letusan gunung api, tsunami, banjir, dan tanah longsor [2]. Berdasarkan Undang-Undang No. 24 Tahun 2007, bencana alam didefinisikan sebagai peristiwa atau serangkaian peristiwa yang disebabkan oleh alam yang menimbulkan kerugian terhadap kehidupan, harta benda, serta lingkungan. Pulau Sulawesi, sebagai bagian dari wilayah Cincin Api Pasifik, memiliki struktur geologis kompleks dan aktivitas tektonik yang tinggi sehingga tergolong sebagai wilayah dengan potensi bencana yang signifikan [3]. Kondisi ini menegaskan pentingnya pemetaan wilayah rawan bencana sebagai bagian dari upaya mitigasi yang terencana dan berbasis data.

Kawasan rawan bencana merupakan wilayah yang memiliki karakteristik geologis, hidrologis, klimatologis, geografis, maupun sosial-ekonomi yang menyebabkan rendahnya kemampuan untuk mencegah, merespons, atau pulih dari dampak bencana alam. Oleh karena itu, penataan ruang yang adaptif terhadap risiko bencana menjadi kebutuhan penting dalam perencanaan wilayah. Salah satu pendekatan yang diperlukan adalah metode analisis spasial untuk mengidentifikasi pola kerentanan wilayah secara menyeluruh sebagai dasar pengambilan kebijakan mitigasi yang tepat sasaran [4]. Namun dalam praktiknya, masih terdapat perbedaan antara kebutuhan akan pemetaan kerentanan bencana yang akurat (berbasis data spasial dan algoritma modern) menurut pengguna (pemerintah, masyarakat, akademisi) dan persepsi pembuat kebijakan atau peneliti terhadap urgensi pemanfaatan pendekatan tersebut. Banyak pihak belum menyadari pentingnya pendekatan analitis modern dalam menangani kompleksitas risiko bencana. Pulau Sulawesi dipilih sebagai objek penelitian karena termasuk salah satu wilayah dengan tingkat kerawanan bencana tertinggi di Indonesia. Letaknya di pertemuan tiga lempeng tektonik aktif dan dalam kawasan Cincin Api Pasifik membuatnya sangat rentan terhadap gempa bumi, tanah longsor, banjir, dan letusan gunung berapi. Selain itu, keberadaan sesar aktif Palu Koro yang melintasi wilayah ini turut memperbesar potensi terjadinya bencana, khususnya gempa bumi berskala besar [5].

Pemetaan wilayah rawan bencana memerlukan pendekatan spasial yang mampu mengenali pola-pola kerentanan berdasarkan sebaran data di suatu wilayah. Salah satu pendekatan yang dapat digunakan adalah metode klusterisasi berbasis kepadatan data yaitu *density-based spatial clustering of applications with noise* (DBSCAN). Algoritma ini menjadi salah satu pionir dalam metode *clustering* yang menggunakan pendekatan berbasis kepadatan [6]. Berbeda dengan algoritma seperti k-means, DBSCAN tidak memerlukan informasi awal mengenai jumlah *cluster* yang ada dalam data. Hal ini menjadi keunggulan tersendiri, terutama ketika berhadapan dengan data berdimensi tinggi yang sulit dianalisis secara visual. Selain itu, DBSCAN juga memiliki kemampuan yang baik dalam mendeteksi data *noise* atau *outlier* [7]. Dalam konteks pemetaan wilayah rawan bencana, fleksibilitas ini membuat DBSCAN sangat relevan, terutama untuk data yang memiliki sebaran spasial tidak merata dan mengandung banyak variasi intensitas kejadian. DBSCAN menggunakan dua parameter utama, yaitu *epsilon* (ϵ) yang menentukan radius maksimum pencarian tetangga terdekat dan *MinPts* yang merupakan jumlah minimum titik dalam radius tersebut untuk membentuk sebuah kluster. Kombinasi kedua parameter ini memungkinkan DBSCAN mengidentifikasi kluster dengan bentuk yang tidak beraturan serta

membedakan area dengan kepadatan tinggi (klaster) dan kepadatan rendah (*noise*), yang sangat berguna dalam menganalisis distribusi spasial kejadian bencana yang tidak seragam.

Sejumlah penelitian terdahulu telah dilakukan terkait pemetaan daerah rawan bencana di Sulawesi. Penelitian oleh [2] menggunakan metode K-Means untuk memetakan daerah rawan bencana di Provinsi Sulawesi Tengah dan berhasil mengelompokkan wilayah berdasarkan tingkat risiko. Penelitian lain oleh [8] juga menerapkan algoritma K-Means untuk memetakan zona kerawanan gempa di Pulau Sulawesi dengan menggunakan data seismik dari USGS periode 1974–2024 yang menghasilkan pembagian zona berdasarkan kedalaman gempa. Kedua penelitian tersebut menunjukkan efektivitas metode K-Means dalam pengelompokan spasial, namun masih terbatas pada fokus wilayah atau jenis bencana tertentu serta memerlukan jumlah klaster yang harus ditentukan di awal. Sementara itu, [9] menunjukkan bahwa algoritma DBSCAN lebih fleksibel karena mampu mengelompokkan wilayah berdasarkan kepadatan kejadian bencana tanpa menentukan jumlah klaster terlebih dahulu. Berdasarkan hal tersebut, penelitian ini menggunakan pendekatan DBSCAN untuk mengelompokkan seluruh wilayah di Pulau Sulawesi dengan cakupan berbagai jenis bencana dan data terbaru, sehingga dapat memberikan hasil pemetaan yang lebih menyeluruh dan menggambarkan kondisi sebaran bencana secara lebih nyata di lapangan.

Penelitian ini dilakukan untuk menganalisis dan mengelompokkan wilayah rawan bencana di seluruh Pulau Sulawesi berdasarkan pola kepadatan kejadian bencana selama periode 2020 hingga 2024. Berbeda dari penelitian sebelumnya yang berfokus pada satu provinsi dengan metode berbasis jarak, penelitian ini menggunakan algoritma DBSCAN untuk mengidentifikasi pola spasial secara lebih adaptif terhadap variasi distribusi data di seluruh wilayah Sulawesi. Pendekatan ini diharapkan dapat memberikan gambaran klaster kerawanan bencana yang lebih representatif, sekaligus menjadi dasar perumusan strategi mitigasi dan pencegahan bencana yang lebih terarah bagi pemerintah pusat maupun daerah sesuai karakteristik risiko di tiap wilayah.

2. METODE PENELITIAN

2.1. Sumber Data

Penelitian ini menggunakan data sekunder yang bersumber dari situs resmi *Data dan Informasi Bencana Indonesia* (DIBI) (<https://dibi.bnpb.go.id/superset/dashboard/>) milik Badan Nasional Penanggulangan Bencana (BNPB). Data yang digunakan mencakup informasi mengenai kejadian bencana alam yang terjadi di 80 kabupaten/kota di wilayah Pulau Sulawesi dalam kurun waktu tahun 2020 hingga 2024. Data ini mencatat jumlah kejadian dari berbagai jenis bencana, seperti banjir, tanah longsor, cuaca ekstrem, kekeringan, gempa bumi, erupsi gunung api, serta gelombang pasang/abrasi. Setiap observasi merepresentasikan total kejadian seluruh jenis bencana pada masing-masing kabupaten/kota selama rentang waktu tersebut. Struktur data penelitian ditunjukkan pada Tabel 1 sebagai berikut:

Tabel 1. Struktur data

Kabupaten/Kota	Banjir	Tanah Longsor	...	Gelombang Pasang dan Abrasi
Bolaang Mongondow	n_{11}	n_{21}	...	n_{71}
Minahasa	n_{12}	n_{22}	...	n_{72}
⋮	⋮	⋮	⋮	⋮
Pasangkayu	n_{179}	n_{279}	...	n_{779}
Mamuju Tengah	n_{180}	n_{280}	...	n_{780}

Pemilihan data ini dilatarbelakangi oleh cakupan wilayah yang luas, kelengkapan jenis bencana yang tercatat, serta periode pengamatan yang memadai untuk meninjau dinamika pola kejadian bencana dari waktu ke waktu. Selain itu, data ini bersifat terbuka dan dapat diakses publik, sehingga mendukung prinsip transparansi serta memudahkan proses replikasi maupun validasi hasil penelitian.

2.2. Variabel Penelitian

Variabel dalam penelitian ini merupakan jumlah kejadian bencana alam yang terjadi di tingkat kabupaten/kota di wilayah Pulau Sulawesi. Setiap variabel mewakili jenis bencana alam tertentu dan bersifat kuantitatif, yang akan dianalisis untuk mengidentifikasi pola kerawanan wilayah. Rincian jenis variabel yang digunakan disajikan pada Tabel 2 sebagai berikut [10]:

Tabel 2. Variabel penelitian

Nama Variabel	Keterangan
Banjir (X_1)	Jumlah kejadian banjir
Tanah Longsor (X_2)	Jumlah kejadian tanah longsor
Cuaca Ekstrem (X_3)	Jumlah kejadian cuaca ekstrem
Kekeringan (X_4)	Jumlah kejadian kekeringan
Gempa Bumi (X_5)	Jumlah kejadian gempa bumi
Erupsi Gunung Merapi (X_6)	Jumlah kejadian erupsi gunung berapi
Gelombang Pasang dan Abrasi (X_7)	Jumlah kejadian gelombang pasang dan abrasi pantai

2.3. Langkah-langkah Penelitian

Berikut adalah langkah atau alur penelitian:

1. Melakukan pengumpulan data terkait frekuensi atau jumlah kejadian bencana di tiap kabupaten/kota yang berada di Pulau Sulawesi pada tahun 2020–2024.
2. Menganalisis data secara deskriptif untuk mengetahui pola awal persebaran bencana alam di Pulau Sulawesi.
3. Melakukan normalisasi data menggunakan metode atau konsep *Min-Max Normalization*. *Min-Max normalization* merupakan teknik normalisasi yang mengubah data asli secara linier ke dalam rentang tertentu (normalisasi ke rentang [0,1]) sehingga mempertahankan proporsi nilai antar data sebelum dan sesudah transformasi [11]. Metode ini dapat dirumuskan sebagai berikut [12]:

$$s' = \frac{s - \min(s_k)}{(s_k) - \min(s_k)} \quad (1)$$

dimana,

$$k = 1, 2, \dots, n.$$

Keterangan:

- s' : Nilai hasil normalisasi (rentang 0 hingga 1)
 s : Nilai asli sebelum dinormalisasi
 $\min(s_k)$: Nilai minimum dalam satu kolom data ke- k
 $\max(s_k)$: Nilai maksimum dalam satu kolom data ke- k

4. Penerapan metode *density-based spatial clustering of applications with noise* (DBSCAN). Metode ini merupakan algoritma pengelompokan yang didasarkan pada kepadatan data [13]. Algoritma ini mengelompokkan data berdasarkan jumlah titik di sekitar suatu radius tertentu (ϵ) [14]. Jika dalam radius tersebut terdapat jumlah titik yang memenuhi ambang minimal (*MinPts*), maka titik tersebut disebut sebagai *core point* atau titik inti. Titik-titik yang berada dalam jangkauan radius dari *core point*, tetapi tidak memenuhi syarat *MinPts*, disebut *border point*. Sementara itu, titik yang tidak memiliki cukup tetangga dalam radius ϵ dan tidak terhubung dengan *core point* akan dikategorikan sebagai *noise* atau data luar (*outlier*). Langkah kerja algoritma DBSCAN adalah sebagai berikut [15]:

- a. Memilih sebuah titik secara acak.
 - b. Hitung jumlah titik di sekitarnya dalam jarak ϵ .
 - c. Jika jumlah titik tetangga $\geq \text{MinPts}$, maka titik tersebut menjadi *core point*, dan klaster baru terbentuk.
 - d. Semua titik yang berada dalam radius ϵ dari *core point* dimasukkan ke dalam klaster.
 - e. Proses ini berulang hingga semua titik telah dianalisis.
 - f. Titik-titik yang tidak tergabung dalam klaster mana pun dikategorikan sebagai *noise*.
5. Mengevaluasi *cluster* menggunakan *silhouette coefficient*. Validasi *silhouette coefficient* digunakan untuk mengevaluasi hasil pengelompokan yang telah dilakukan. Evaluasi ini bertujuan untuk mengukur seberapa baik kualitas hasil *clustering*, yaitu dengan melihat sejauh mana objek-objek dalam satu *cluster* memiliki kemiripan dan seberapa jelas perbedaan antar *cluster* [16]. berikut adalah tahapan perhitungan *silhouette coefficient* [17]:

- a. Menghitung jarak rata-rata antar objek dalam *cluster* yang sama.

Nilai ini dinotasikan sebagai $\alpha(i)$, dengan rumus:

$$\alpha(i) = \frac{1}{|A|-1} \sum_{j \in A, j \neq i} d_{i,j} \quad (2)$$

dimana, $|A|$ adalah jumlah objek dalam *cluster* A dan $d_{i,j}$ adalah jarak antara objek i dan objek j .

- b. Menghitung jarak rata-rata ke *cluster* lain yang berbeda.

Jarak ini dirumuskan sebagai berikut:

$$d_{i,A'} = \frac{1}{|A'|} \sum_{j \in A'} d_{i,j} \quad (3)$$

dimana, A' adalah *cluster* lain yang tidak mengandung objek i .

- c. Menentukan jarak minimum ke *cluster* lain.

Dari semua rata-rata jarak ke *cluster* lain, diambil nilai terkecil sebagai $b(i)$, yaitu:

$$b(i) = d_{i,A'} \quad (4)$$

- d. Menghitung nilai *silhouette* untuk setiap objek.

Nilai *Silhouette* untuk objek i dihitung dengan:

$$s(i) = \frac{b(i) - a(i)}{(a(i), b(i))} \quad (5)$$

- e. Menghitung nilai rata - rata *silhouette coefficient* untuk seluruh objek.

silhouette coefficient keseluruhan dihitung dengan rata-rata dari semua nilai $s(i)$:

$$SC = \frac{1}{n} \sum_{i=1}^n s(i) \quad (6)$$

Kriteria *silhouette coefficient* disajikan dalam Tabel 3 sebagai berikut [17]:

Tabel 3. Kriteria *silhouette coefficient*

Nilai Silhouette Coefficient	Kriteria
0,71 – 1,00	Struktur Kuat
0,51 – 0,70	Struktur Baik
0,26 – 0,50	Struktur Lemah
$\leq 0,25$	Struktur Buruk

3. HASIL DAN PEMBAHASAN

Sebelum melakukan analisis lebih lanjut, dilakukan analisis deskriptif untuk melihat gambaran umum dataset yang dianalisis. Dataset penelitian berisi data kejadian bencana dengan total 80 observasi (kota/kabupaten) untuk setiap jenis bencana. Statistika deskriptif dari masing-masing jenis bencana dapat dilihat pada Tabel 4 sebagai berikut:

Tabel 4. Statistika deskriptif

Nama Variabel	<i>Min</i>	<i>Max</i>	<i>Mean</i>	<i>Std</i>
Banjir (X_1)	0	59	12,56	12,74
Tanah Longsor (X_2)	0	31	2,3	4,43
Cuaca Ekstrem (X_3)	0	36	6,12	6,96
Kekeringan (X_4)	0	14	2,21	3,29
Gempa Bumi (X_5)	0	3	0,21	0,60
Erupsi Gunung Merapi (X_6)	0	2	0,025	0,22
Gelombang Pasang dan Abrasi (X_7)	0	1	0,012	0,11

Secara umum, bencana banjir memiliki jumlah kejadian tertinggi yaitu sekitar 59 kejadian dengan kejadian tertinggi tercatat di Kabupaten Luwu Utara. Bencana cuaca ekstrem menempati urutan kedua dengan 36 kejadian dan kejadian tertinggi terjadi di Kabupaten Wajo. Selanjutnya, bencana tanah longsor tercatat sebanyak 31 kejadian dengan frekuensi tertinggi di Kabupaten Tana Toraja. Untuk jenis bencana lainnya, kejadian kekeringan tertinggi ditemukan di Kabupaten Takalar, gempa bumi tertinggi di Kepulauan Talaud, erupsi gunung berapi tertinggi di Kepulauan Siau Tagulandang Biaro, serta gelombang pasang dan abrasi tertinggi di Kabupaten Minahasa. Secara umum, beberapa jenis bencana seperti erupsi gunung berapi dan gelombang pasang/abrasi hanya tercatat masing-masing sebanyak 2 dan 1 kejadian dalam satu observasi.

Selanjutnya, dilakukan normalisasi data menggunakan metode *Min-Max Normalization*. Metode *Min-Max Normalization* digunakan untuk menormalisasi data dengan mengubah data asli secara linier ke dalam rentang 0 hingga 1. Normalisasi dilakukan agar setiap variabel memiliki skala yang sebanding dan tidak ada variabel dengan nilai besar yang mendominasi hasil analisis. Pada perhitungan Google Colab digunakan fitur *MinMaxScaler* dan didapatkan hasil pada Tabel 5 sebagai berikut:

Tabel 5. Hasil normalisasi data

Kabupaten/Kota	X_1	X_2	...	X_7
Bolaang Mongondow	0,254	0,032	...	0,0
Minahasa	0,101	0,032	...	1,0
Kepulauan Sangihe	0,067	0,000	...	0,0
⋮	⋮	⋮	⋮	⋮
Mamuju	0,254	0,096	...	0,0
Pasangkayu	0,135	0,064	...	0,0
Mamuju Tengah	0,338	0,032	...	0,0

Tahap berikutnya adalah penentuan parameter utama DBSCAN, yaitu nilai *Epsilon* (ϵ) dan *minimum points* (*MinPts*). Penentuan nilai *Epsilon* (*Eps*) dan *Minimal Points* (*MinPts*) dilakukan melalui beberapa percobaan untuk memperoleh hasil pengelompokan yang paling optimal. Kombinasi nilai *MinPts* dan *Eps* dicoba secara *trial and error* dengan mempertimbangkan nilai *silhouette coefficient* sebagai acuan. Penentuan nilai *Eps* dan *MinPts* dilakukan secara sistematis menggunakan pendekatan *grid search* sederhana di Google Colab. Proses ini dilakukan dengan menjalankan iterasi berbagai kombinasi nilai *Eps* dan *MinPts* melalui pemrograman Python menggunakan pustaka *scikit-learn*. Nilai *Eps* diuji pada rentang 0,1 hingga 1,0 dengan interval 0,01, sedangkan *MinPts* divariasikan dari 3 hingga 6. Untuk setiap kombinasi parameter, dilakukan pelatihan model DBSCAN dan perhitungan *silhouette score* sebagai


metrik evaluasi guna menilai kualitas hasil pengelompokan. Hasil kombinasi parameter dapat dilihat pada Tabel 6 sebagai berikut:

Tabel 6. Kombinasi parameter DBSCAN

Eps	MinPts	Jumlah Cluster	Silhouette Score
0,28	5	2	0,359291
0,24	3	5	0,306829
0,25	3	5	0,306829
0,23	3	5	0,297502
0,24	4	5	0,297502
0,25	4	5	0,297502
0,26	4	5	0,291775
0,30	5	3	0,287612
0,22	3	5	0,268538

Dari hasil perhitungan didapatkan nilai *Epsilon (Eps)* sebesar 0,28 dan *Minimal Points (MinPts)* sebesar 5 sebagai parameter terbaik dengan hasil *Silhouette Score* sebesar 0,359291. Dengan parameter ini akan didapatkan 2 cluster yang terbentuk. Peningkatan nilai *MinPts* dapat memperbaiki kualitas cluster hingga titik tertentu, tetapi jika terlalu besar, justru menurunkan kualitasnya. Nilai *MinPts* yang lebih tinggi memperkecil peluang pembentukan cluster karena membutuhkan lebih banyak objek dalam satu wilayah, sedangkan nilai *MinPts* yang lebih rendah memudahkan terbentuknya cluster.

Setelah parameter ditetapkan, dilakukan penerapan DBSCAN pada data yang telah dinormalisasi. Pada penelitian ini, penambahan parameter terbaik pada penerapan metode DBSCAN membentuk dua kelompok cluster dan satu kelompok *noise* atau kelompok data yang tidak masuk pada cluster manapun.



Gambar 1. Visualisasi cluster

Hasil dari proses ini divisualisasikan dalam bentuk sebaran klaster seperti pada Gambar 1, di mana setiap warna menggambarkan kelompok wilayah yang memiliki karakteristik serupa berdasarkan variabel analisis. Dari hasil visualisasi tersebut, dapat diidentifikasi wilayah (kota/kabupaten) yang termasuk dalam masing-masing klaster serta kelompok data yang terdeteksi sebagai *noise* atau tidak tergolong ke dalam klaster manapun. Kelompok cluster dapat dilihat pada Tabel 7 sebagai berikut:

Tabel 7. Kelompok *cluster*

<i>Cluster</i>	Kabupaten/Kota
-1 (Noise)	Minahasa, Kepulauan Talaud, Kepulauan Siau Tagulandang Biaro, Banggai, Morowali, Tojo Una-una, Sigi, Kepulauan Selayar, Bulukumba, Jeneponto, Takalar, Maros, Pangkajene Kepulauan, Barru, Bone, Wajo, Sidenreng Rappang, Pinrang, Tana Toraja, Kota Pare-pare, Konawe, Gorontalo, Majene, Polewali Mandar, Mamasa, Mamuju, Mamuju Tengah.
0	Bolaang Mongondow, Kepulauan Sangihe, Minahasa Selatan, Minahasa Utara, Bolaang Mongondow Utara, Minahasa Tenggara, Bolaang Mongondow Selatan, Bolaang Mongondow Timur, Kota Manado, Kota Bitung, Kota Tomohon, Kota Kotamobagu, Banggai Kepulauan, Donggala, Toli-toli, Buol, Banggai Laut, Morowali Utara, Kota Palu, Bantaeng, Gowa, Sinjai, Soppeng, Enrekang, Luwu Timur, Toraja Utara, Kota Makassar, Kota Palopo, Buton, Muna, Kolaka, Konawe Selatan, Bombana, Wakatobi, Kolaka Utara, Buton Utara, Konawe Utara, Kolaka Timur, Muna Barat, Buton Tengah, Buton Selatan, Kota Kendari, Kota Baubau, Boalemo, Pohuwato, Bone Bolango, Gorontalo Utara, Kota Gorontalo, Pasangkayu.
1	Poso, Parigi Moutong, Luwu, Luwu Utara

Dari hasil tersebut didapatkan jumlah kabupaten/kota pada *cluster* 0 adalah yang tertinggi dengan jumlah sebesar 49 kabupaten/kota sedangkan pada *cluster* 1 hanya terdapat 4 kabupaten/kota. Sisanya sekitar 27 kabupaten/kota termasuk dalam *cluster* -1 atau *noise*.

Tahap akhir adalah analisis karakteristik setiap klaster berdasarkan nilai rata-rata dari variabel – variabel yang digunakan. Analisis ini memberikan interpretasi lebih lanjut mengenai perbedaan ciri antar klaster. Hasil rata-rata pada setiap klaster ditampilkan pada Tabel 8 berikut:

Tabel 8. Hasil rata-rata setiap *cluster*

Cluster	Banjir	Tanah Longsor	Cuaca Ekstrem	Kekeringan	Gempa Bumi	Erupsi Gunung Merapi	Gelombang Pasang dan Abrasi
-1	13,11	3,33	11,22	4,96	0,62	0,07	0,03
0	9,44	1,69	2,83	0,75	0,00	0,00	0,00
1	47,00	2,75	12,00	1,50	0,00	0,00	0,00

Berdasarkan hasil tersebut, *cluster* 1 menunjukkan tingkat kerawanan bencana tertinggi, ditandai dengan rata-rata kejadian banjir yang sangat tinggi, serta frekuensi tanah longsor dan cuaca ekstrem yang juga cukup signifikan. Wilayah-wilayah yang masuk dalam klaster ini cenderung memiliki karakteristik kerawanan tinggi terhadap bencana *hidrometeorologis* dan perlu mendapat perhatian khusus dalam upaya mitigasi bencana. Sementara itu, *cluster* 0 memiliki karakteristik kerawanan yang sedang, ditunjukkan oleh kejadian banjir, cuaca ekstrem dan tanah longsor yang cukup sering terjadi, namun masih berada di bawah intensitas *cluster* 1. Berbeda dengan dua klaster tersebut, *cluster* -1 merupakan kelompok data yang berstatus *noise* dalam metode DBSCAN, artinya data pada wilayah-wilayah ini tidak dapat dikelompokkan ke dalam klaster yang padat. Meskipun menunjukkan bahwa nilai rerata kejadian bencana pada *cluster* -1 cukup tinggi, DBSCAN tidak mengelompokkannya karena sebarannya terisolasi secara spasial atau tidak memenuhi syarat minimum tetangga dalam radius tertentu. Dengan demikian, status “*noise*” tidak berarti wilayah tersebut bebas risiko, melainkan mencerminkan ketidakaturan pola kepadatan spasial kejadian. Oleh sebab itu, daerah dengan status ini tetap penting untuk diperhatikan, terlebih jika frekuensi kejadiannya tinggi namun tidak tersebar merata di sekitarnya.

Hasil penelitian ini menunjukkan bahwa metode DBSCAN berhasil mengelompokkan wilayah di Pulau Sulawesi berdasarkan tingkat kerawanan bencana, dengan terbentuknya dua klaster utama dan

beberapa wilayah yang teridentifikasi sebagai *noise*. Klaster dengan tingkat kepadatan tinggi menggambarkan daerah yang sering mengalami bencana, sedangkan wilayah dengan sebaran kejadian yang tidak merata cenderung masuk ke dalam kategori *noise*. Temuan ini sejalan dengan penelitian [18] yang menggunakan algoritma DBSCAN untuk memetakan kerawanan bencana di Pulau Sumatra, di mana metode tersebut juga mengidentifikasi wilayah dengan tingkat risiko berbeda berdasarkan kepadatan kejadian bencana. Namun, berbeda dengan Sumatra yang menunjukkan pola klaster yang lebih jelas dan terpisah antar tingkat kerawanan, hasil pada Pulau Sulawesi memperlihatkan variasi persebaran yang lebih kompleks. Beberapa wilayah menunjukkan frekuensi bencana tinggi tetapi tidak membentuk klaster padat sehingga teridentifikasi sebagai *noise*. Kondisi ini mengindikasikan bahwa pola spasial bencana di Sulawesi cenderung lebih beragam dan tidak homogen. Hal ini memperlihatkan bahwa penerapan DBSCAN pada wilayah dengan kondisi geografis berbeda dapat memberikan gambaran yang lebih rinci mengenai pola spasial kerawanan bencana dan membantu dalam penentuan prioritas wilayah untuk mitigasi.

4. SIMPULAN

Penelitian ini berhasil memberikan gambaran wilayah rawan bencana di Pulau Sulawesi melalui pendekatan metode DBSCAN. Penggunaan metode ini terbukti efektif dalam mengidentifikasi pola spasial daerah rawan bencana tanpa perlu menentukan jumlah cluster sejak awal, serta mampu mengenali data *outlier* atau *noise*. Dari hasil analisis, diperoleh parameter optimal berupa nilai *Eps* sebesar 0,28 dan *MinPts* sebesar 5, yang menghasilkan dua *cluster* utama dan satu kategori *noise*, dengan nilai *silhouette score* sebesar 0,359. Diperoleh tiga kategori hasil pengelompokan, yaitu *cluster* 1 sebagai wilayah dengan tingkat kerawanan bencana tinggi, *cluster* 0 dengan tingkat kerawanan sedang, dan *cluster* -1 sebagai wilayah dengan status *noise* atau sebaran kejadian yang tidak membentuk klaster padat. Hasil pengelompokan menunjukkan bahwa sebaran kejadian bencana di wilayah ini tidak merata, serta terdapat daerah-daerah tertentu yang memiliki tingkat kerawanan lebih tinggi. Selain itu, wilayah yang tidak membentuk pola sebaran padat juga dapat teridentifikasi, sehingga dapat menjadi perhatian khusus dalam perencanaan penanganan bencana. Temuan ini diharapkan dapat menjadi bahan pertimbangan dalam merancang strategi mitigasi yang lebih tepat sasaran dan berbasis data.

Nilai *silhouette score* pada penelitian ini termasuk kategori lemah. Untuk meningkatkan nilai *silhouette coefficient* dan memperbaiki kualitas pengelompokan dapat dilakukan perluasan rentang pencarian parameter *Eps* dan *MinPts*, misalnya dengan menerapkan pendekatan *grid search* yang lebih halus atau metode optimasi otomatis seperti *Bayesian optimization*. Penambahan variabel yang relevan dan penyesuaian teknik normalisasi juga dapat dipertimbangkan untuk meningkatkan separabilitas antar *cluster*.

DAFTAR PUSTAKA

- [1] F. D. Cahyo, F. Ihsan, Roulita, N. Wijayanti, and R. Mirwanti, "Kesiapsiagaan bencana gempa bumi dalam keperawatan: tinjauan penelitian," *Jurnal Kesehatan Poltekkes Palembang*, vol. 18, no. 1, pp. 87-97, 2023, <https://doi.org/10.36086/jpp.v18i1.1525>.
- [2] R. B. Sippan and N. Setiyawati, "Pemetaan dan klasterisasi daerah rawan bencana alam di Provinsi Sulawesi Tengah menggunakan k-means," *Jurnal Ilmiah Penelitian dan Pembelajaran Informatika*, vol. 10, no. 2, pp. 1031-1045, 2025, doi: <https://doi.org/10.29100/jipi.v10i2.6161>.
- [3] O. O. Wijaya and Rushendra, "Analysis of Sulawesi earthquake data from 2019 to 2023 using DBSCAN clustering," *Jurnal Rekayasa Sistem dan Teknologi Informasi*, vol. 8, no. 4, pp. 454-465, 2024, doi: <https://doi.org/10.29207/resti.v8i4.5819>.

- [4] T. W. Wibowo, E. A. W. Putri, and H. Y. Loekman, "Evaluasi multi-kriteria keruangan untuk pemetaan kerentanan terhadap bahaya tsunami di pesisir Kabupaten Bantul," in *Prosiding Seminar Nasional Geografi UMS 2015*, 2015, doi: <https://doi.org/10.13140/RG.2.1.5152.2723>.
- [5] H. Saputra, M. Arsyad, and Sulistiawaty, "Studi analisis parameter gempa dan pola sebarannya berdasarkan data multi-station (studi kasus kejadian gempa Pulau Sulawesi tahun 2000 - 2014)," *Jurnal Sains dan Pendidikan Fisika*, vol. 12, no. 1, pp. 83–87, 2016, [Online], Available: <https://ojs.unm.ac.id/JSdPF/article/view/2036/1002>.
- [6] D. Safitri, T. Wuryandari, and R. Rahmawati, "Metode DBSCAN untuk pengelompokan kabupaten/kota di Provinsi Jawa Tengah berdasarkan produksi padi sawah dan padi ladang," *Jurnal Statistika Universitas Muhammadiyah Semarang*, vol. 5, no. 1, pp. 8–13, 2017, [Online], Available: <https://jurnal.unimus.ac.id/index.php/statistik/article/view/2710>.
- [7] R. Anggara and A. Rahman, "Implementasi algoritma DBSCAN dalam mengelompokan data pasien terdiagnosa penyakit ginjal kronis (PGK)," *Algoritme Jurnal Mahasiswa Teknik Informatika*, vol. 3, no. 1, pp. 114–123, 2022, doi: <https://doi.org/10.35957/algoritme.v3i1.3593>.
- [8] A. N. Lumowa, "Zonasi wilayah rawan gempa di Sulawesi menggunakan metode k-means clustering terhadap data historis USGS (1974-2024)," *Technologica*, vol. 4, no. 2, pp. 119–131, 2025, [Online], Available: <https://journals.gesociety.org/index.php/technologica/article/view/311>.
- [9] I. N. Setiawan, D. Krismawati, S. Pramana, and E. Tanur, "Klasterisasi wilayah rentan bencana alam berupa gerakan tanah dan gempa bumi di Indonesia," in *Seminar Nasional Official Statistics*, pp. 669–676, 2022, doi: <https://doi.org/10.34123/semnasoffstat.v2022i1.1538>.
- [10] Badan Nasional Penanggulangan Bencana, "Statistik kejadian bencana menurut wilayah."
- [11] D. A. Nasution, H. H. Khotimah, and N. Chamidah, "Perbandingan normalisasi data untuk klasifikasi wine menggunakan algoritma K-NN," *Journal of Computer Engineering System and Science*, vol. 4, no. 1, pp. 78–82, 2019, doi: <https://doi.org/10.24114/cess.v4i1.11458>.
- [12] R. Adha, N. Nurhaliza, U. Soleha, and Mustakim, "Perbandingan algoritma DBSCAN dan k-means clustering untuk pengelompokan kasus covid-19 di dunia," *Jurnal Sains, Teknologi dan Industri*, vol. 18, no. 2, pp. 206–211, 2021, [Online], Available: <https://ejournal.uin-suska.ac.id/index.php/sitekin/article/view/12469>.
- [13] F. W. Saputri and D. B. Arianto, "Perbandingan performa algoritma k-means, k-medoids, dan DBSCAN dalam penggerombolan provinsi di Indonesia berdasarkan indikator kesejahteraan masyarakat," *Jurnal Teknologi Informasi*, vol. 17, no. 2, pp. 138–151, 2023, doi: <https://doi.org/10.47111/jti.v7i2.9558>.
- [14] Z. Falahiazar, A. Bagheri, and M. Reshadi, "Determining the parameters of DBSCAN automatically using the multi-objective genetic algorithm," *Journal of Information Science and Engineering*, vol. 37, no. 1, pp. 157–183, 2021, doi: [https://doi.org/10.6688/JISE.202101_37\(1\).0011](https://doi.org/10.6688/JISE.202101_37(1).0011).
- [15] M. A. Idris, Rahmawati, and Apriyanto, "Pemetaan produksi perikanan tangkap di Indonesia dengan menggunakan metode DBSCAN," *Journal of Mathematics: Theory and Applications*, vol. 5, no. 2, pp. 80–86, 2023, doi: <https://doi.org/10.31605/jomta.v5i2.2930>.
- [16] H. S. Ramadan, H. A. Maghawry, M. El-Eleamy, and K. El-Bahnasy, "A heuristic novel approach for determination of optimal epsilon for DBSCAN clustering algorithm," *J Theor Appl Inf Technol*, vol. 15, no. 7, 2022, Accessed: May 05, 2025, [Online]. Available: <https://www.jatit.org/volumes/Vol100No7/22Vol100No7>.
- [17] T. Rahmawati, Y. Wilandari, and P. Kartikasari, "Analisis perbandingan silhouette coefficient dan metode elbow pada pengelompokan provinsi di Indonesia berdasarkan indikator IPM dengan k-

medoids,” *Jurnal Gaussian*, vol. 13, no. 1, pp. 13–24, 2024, doi: <https://doi.org/10.14710/j.gauss.13.1.13-24>.

- [18] A. F. Boer, M. Al Haris, and R. Wasono, “Pengelompokan daerah rawan bencana di Pulau Sumatera dengan metode density based spatial clustering of applications with noise (DBSCAN),” 2023. Accessed: May 28, 2025. [Online]. Available: <https://prosiding.unimus.ac.id/index.php/semnas/article/download/1481/1485>.