

CLUSTERING GEMPABUMI DI WILAYAH REGIONAL VII MENGGUNAKAN PENDEKATAN DBSCAN

Ihsan Bagus Fahad Arafat^{*1}, Mokhamad Amin Hariyadi², Irwan Budi Santoso³, Cahyo Crysdiann⁴

^{1,2,3}Universitas Islam Negeri Maulana Malik Ibrahim, Malang

Email: ¹210605220013@student.uin-malang.ac.id, ²adyt2002@uin-malang.ac.id, ³irwan@ti.uin-malang.ac.id,

⁴cahyo@ti.uin-malang.ac.id

*Penulis Korespondensi

(Naskah masuk: 09 Januari 2023, diterima untuk diterbitkan: 26 Juli 2023)

Abstrak

Wilayah Regional VII meliputi Jawa Tengah, Yogyakarta, dan Jawa Timur merupakan wilayah tektonik yang aktif karena terletak di wilayah zona subduksi lempeng Indo-Australia dan Eurasia serta terdapat beberapa patahan aktif di daratan. Oleh karena itu, perlu dilakukan klasifikasi gempabumi untuk memetakan zona rawan gempabumi berdasarkan sumbernya di wilayah Regional VII berdasarkan kesamaan atribut salah satunya adalah berdasarkan karakteristik gempabumi dari sumber yang sama. Pada penelitian ini digunakan pendekatan algoritma *Unsupervised Learning Clustering* berbasis kepadatan yaitu, *Density Based Spatial Clustering of Application with Noise* atau DBSCAN, algoritma ini membutuhkan parameter input epsilon (ϵ) dan MinPts. Data yang digunakan pada penelitian ini adalah data gempabumi wilayah Regional VII tahun 2017 hingga 2021 yang diperoleh dari BMKG. Selanjutnya, proses clustering dilakukan dengan membagi data gempabumi berdasarkan periode yaitu periode tahunan dan periode lima tahun dengan tujuan untuk mengetahui pola cluster berdasarkan periode waktu. Hasil yang terbentuk selanjutnya dievaluasi menggunakan *Silhouette Coefficient* serta dibandingkan dengan peta Seismisitas Jawa yang telah ada dari katalog PuSGeN 2017. Hasil clustering menggunakan DBSCAN diperoleh jumlah cluster sebanyak 2 hingga 6 cluster dengan nilai *Silhouette Coefficient* terendah sebesar 0.270 untuk periode $T_{5_2017-2021}$ dan tertinggi sebesar 0.499 untuk periode T_{1_2020} .

Kata kunci: unsupervised learning, clustering, gempabumi, DBSCAN, silhouette coefficient

EARTHQUAKE CLUSTERING IN REGIONAL VII USING DBSCAN APPROACH

Abstract

Regional VII area covering Central Java, Yogyakarta and East Java is an active tectonic region because it is located in the subduction zone of the Indo-Australian and Eurasian plates and there are several active faults on land. Therefore, it is necessary to classify earthquakes to map earthquake-prone zones based on their sources in Regional VII area based on the similarity of attributes, based on the characteristics of earthquakes from the same source. In this study, a density-based Unsupervised Learning Clustering algorithm approach was used namely, Density Based Spatial Clustering of Application with Noise or DBSCAN, this algorithm requires the input parameters epsilon (ϵ) and MinPts. The data used in this study are earthquake data for Regional VII from 2017 to 2021 obtained from the BMKG. Then, the clustering process is carried out by dividing earthquake data based on the period, namely the annual period and the five-year period with the aim of knowing the pattern of cluster based on the time period. The results are then evaluated using the Sillhouette Coefficient and compared with the existing Java Seismicity map from the 2017 PuSGeN catalog. Clustering results using DBSCAN obtained a number of clusters of 2 to 6 clusters with the lowest Silhouette Coefficient value is 0.270 for the $T_{5_2017-2021}$ period and the highest is 0.499 for the T_{1_2020} period.

Keywords: unsupervised learning, clustering, earthquake, DBSCAN, silhouette coefficient

1. LATAR BELAKANG

Wilayah Regional VII meliputi Jawa Tengah, Yogyakarta, dan Jawa Timur merupakan wilayah tektonik yang aktif karena terletak di wilayah zona

subduksi lempeng Indo-Australia dan Eurasia serta terdapat beberapa patahan aktif di daratan seperti Opak Fault di Yogyakarta, Lasem Fault di Jawa Tengah, Kendeng Fault memanjang dari Jawa Tengah

hingga Jawa Timur, Montong Fault di Jawa Timur, dan Wongsorejo Fault di Jawa Timur (Gunawan & Widiantoro, 2019). Ketiga wilayah tersebut termasuk daerah padat penduduk di Indonesia, sehingga kajian analisis seismik diperlukan dan sangat penting bagi masyarakat (Aprilia Puspita et al., 2015).

Salah satu upaya untuk memetakan zona rawan gempabumi berdasarkan sumbernya di wilayah Regional VII secara otomatis berdasarkan kesamaan atribut perlu dilakukan clustering (Cesca, 2020) atau pengelompokan data. Sehingga perencanaan pembangunan daerah dengan potensi gempabumi tinggi di wilayah Regional VII dapat diperkuat.

Unsuervised Learning merupakan algoritma machine learning berupa sebuah fungsi untuk mendefinisikan struktur tersembunyi data yang tidak berlabel (Dike et al., 2019). Dalam algoritma ini, sejumlah besar data dan karakteristik setiap observasi dilengkapi dengan masukan tetapi tidak dengan keluaran yang diinginkan. *Clustering* merupakan salah satu teknik dalam *data mining* untuk mengelompokkan kejadian yang memiliki kemiripan dari yang rendah hingga tinggi. Salah satu metode *clustering* yang popular digunakan adalah *Density Based Spatial Clustering of Application with Noise* atau DBSCAN (Schubert et al., 2017). Metode ini pertama kali dikenalkan oleh Ester et al., 1996 yang menerapkan nilai minimum parameter input dan untuk mengelompokkan *database* spasial yang besar (Daszykowski & Walczak, 2009). Metode ini merupakan metode pengelompokan berdasarkan kepadatan dan cocok diterapkan pada data yang besar (Kazemi-Beydokhti et al., 2017). Algoritma DBSCAN dapat digunakan untuk mendeteksi data *outlier* atau *noise* dan tidak perlu menentukan jumlah cluster terlebih dahulu (Algorithm, 2021). Algoritma ini membutuhkan parameter input Epsilon (ϵ) (radius maksimum antara satu titik ke titik lain) dan MinPts (titik minimum dalam sebuah cluster yang terbentuk).

Pada penelitian ini mencoba melakukan clustering menggunakan metode DBSCAN dan untuk menentukan nilai Epsilon (ϵ) dan MinPts menggunakan metode *k-Nearest Neighbors* (KNN) dengan perhitungan jarak menggunakan pendekatan *Euclidean Distance*. KNN adalah salah satu algoritma paling populer dalam teknologi klasifikasi data mining (Gao & Li, 2020). KNN menggunakan prinsip jumlah tetangga terdekat, di mana jika suatu objek memiliki kesamaan dengan *k*-tetangga terdekat yang sebelumnya telah ditentukan, maka objek tersebut termasuk ke dalam kelompoknya.

2. PENELITIAN TERKAIT

Pada penelitian yang dilakukan oleh (Karmenova et al., 2022) memperkenalkan sebuah pendekatan efektif untuk mendeteksi wilayah dengan peningkatan kerapatan spasial dari peristiwa seismik dan pengelompokan data seismik di wilayah Republik Kazakhstan dengan algoritma DBSCAN.

Hasilnya menunjukkan kemiripan dengan peta zona seismik Republik Kazakhstan. Pengelompokan gempabumi di wilayah Indonesia menggunakan algoritma K-Means dan DBSCAN dengan tujuan untuk mengembangkan klasifikasi sebaran gempabumi di Indonesia tahun 2019 berdasarkan magnitudo, kedalaman dan lokasi gempabumi telah dilakukan oleh (Jufriansah et al., 2021). Hasilnya diperoleh nilai Silhouette Index 0.837 untuk K-Means Clustering dan 0.730 untuk DBSCAB Clustering. Hal serupa juga telah dilakukan oleh (Algorithm, 2021) yaitu melakukan klasifikasi data gempabumi di wilayah Indonesia periode tahun 2018 hingga 2020 yang diperoleh dari BMKG menggunakan algoritma DBSCAN dengan tujuan untuk mengelompokkan data gempabumi berdasarkan koordinat, frekuensi kejadian, kedalaman dan kekuatan gempa.

Clustering gempabumi menggunakan metode DBSCAN juga dilakukan oleh (Harini et al., 2020) untuk memetakan zona potensi gempabumi di wilayah Regional III (Bali dan Nusa Tenggara). Mereka melakukan modifikasi parameter epsilon menggunakan magnitudo karena dianggap dapat mewakili dampak dari kejadian gemoabumi sehingga nilai epsilon berbeda untuk setiap titik. Identifikasi zona rawan gempa berdasarkan aktivitas seismik juga dilakukan oleh (Karri et al., 2019) dengan melakukan pengelompokan data gempabumi menggunakan DBSCAN pada data gempabumi di India. Hasil cluster menunjukkan bahwa kualitas cluster yang diperoleh mewakili berbagai zona seismik sesuai dengan peta seismik India Bureau of India Standards IS 1892:2022. Algoritma DBSCAN banyak digunakan untuk clustering gempabumi secara spasial seperti yang dilakukan oleh (Kazemi-Beydokhti et al., 2017) pada penelitiannya yaitu, melakukan pengelompokan gempabumi di Iran menggunakan algoritma DBSCAN dengan tujuan untuk mengembangkan model kegempaan secara spatio-temporal di Iran berdasarkan kemiripan perilaku seismik dalam bentuk cluster terpisah. Hasil clustering menunjukkan kemiripan dengan penelitian sebelumnya yang dilakukan oleh (Mojarab et al., 2014) dan (Ansari et al., 2009) pada daerah yang disajikan di dalam model.

3. METODE PENELITIAN

3.1. Data

Data yang digunakan pada penelitian ini adalah data gempabumi wilayah Regional VII yaitu, Jawa Tengah, Yogyakarta dan Jawa Timur dengan batas koordinat 6° - 14° LS dan 108° - 114° BT tahun 2017-2021 dengan magnitudo ≥ 3 yang diperoleh dari website BMKG repogempa.bmkg.go.id/repo_new/ yang terdiri dari empat kategori yaitu Lintang, Bujur, Magnitudo, dan Kedalaman sebanyak 1.827 data kejadian gempabumi. Adapun data yang digunakan ditampilkan dalam Tabel 1 berikut:

Tabel 1. Data Gempabumi Regional VII

No	Latitude	Longitude	Magnitude	Depth
1	-8.96	110.00	4.0	10
2	-11.73	113.26	4.9	34
3	-8.18	108.28	4.3	31
4	-8.73	110.61	3.3	35
5	-8.50	108.89	3.9	11
...
1821	-9.16	110.85	3.4	10
1822	-9.10	113.17	3.1	21
1823	-9.12	112.06	3.6	10

Selanjutnya data dibagi menjadi 2 periode yaitu, periode tahunan (T_{1_2017} , T_{1_2018} , T_{1_2019} , T_{1_2020} dan T_{1_2021}) dan periode 5 tahunan ($T_{1_2017-2021}$). Hal ini bertujuan untuk mengetahui pola cluster gempabumi tahunan dan 5 tahunan.

3.2. Algoritma DBSCAN

Penelitian ini menggunakan metode *clustering* DBSCAN untuk *clustering* gempabumi kemudian hasilnya dibandingkan dengan metode *clustering* K-Means. DBSCAN adalah algoritma pengelompokan berbasis kepadatan, yang banyak digunakan untuk analisis pengelompokan data karena karakteristiknya yang sederhana dan efisien (Deng, 2020). Tujuannya adalah untuk menentukan *cluster* dengan bentuk tidak beraturan. Dalam pendekatan ini kepadatan untuk suatu titik tertentu dalam kumpulan data direpresentasikan dengan menghitung jumlah titik yang ada dalam radius tertentu (ϵ) dari titik tersebut (Rahman & Wijayanto, 2021). Algoritma ini memandang *cluster* sebagai area dengan kepadatan tinggi yang dipisahkan oleh area dengan kepadatan rendah. Daerah dengan kepadatan titik yang tinggi menggambarkan adanya *cluster* sedangkan daerah dengan kepadatan titik yang rendah menunjukkan adanya *cluster noise* atau *cluster outlier* (Omran et al., 2007). Algoritma ini sangat cocok untuk mengelompokkan data yang besar, dengan *noise*, dan mampu mengidentifikasi *cluster* dengan ukuran dan bentuk yang berbeda. Komponen utama DBSCAN adalah konsep sampel ini, yaitu sampel yang berada di daerah dengan kepadatan tinggi. Oleh karena itu, *cluster* merupakan sekumpulan sampel ini, masing-masing berdekatan satu sama lain (diukur dengan beberapa ukuran jarak) dan satu set sampel non-inti yang dekat dengan sampel inti (tetapi bukan sampel inti itu sendiri). Algoritma ini sangat populer karena sederhana untuk diterapkan dan hanya membutuhkan dua parameter input (Epsilon (ϵ) atau eps dan jumlah minimum objek dalam sebuah cluster MinPts). MinPts adalah titik minimum dalam sebuah cluster yang terbentuk sedangkan Epsilon adalah radius maksimum antara satu titik ke titik lain.

Konsep clustering menggunakan DBSCAN diilustrasikan dalam Gambar 1. Parameter MinPts adalah 4, dan radius maksimum antar titik (ϵ) atau Epsilon ditunjukkan oleh lingkaran. N adalah *noise point*, A adalah *core point*, dan B dan C adalah *border point*.

Adapun langkah-langkah Algoritma DBSCAN secara umum adalah sebagai berikut:

- Menentukan nilai epsilon (ϵ) dan MinPts. Nilai epsilon yang optimal sangat penting karena mempengaruhi hasil *cluster* yang baik. Penentuan nilai epsilon optimal menggunakan metode jarak KNN (*k-nearest neighbors*) atau *k*-tetangga terdekat (Karmenova et al., 2022). Hal utama dalam perhitungan nilai epsilon optimal dengan metode KNN adalah dengan menghitung jarak dalam matriks titik ke KNN. Jarak rata-rata dari setiap titik KNN dihitung. Nilai *k* diatur sesuai dengan nilai MinPts dan jarak *k* ditampilkan dalam kurva naik di mana nilai yang sesuai dengan threshold di mana ada perubahan tajam dalam kurva merupakan jarak *k* yang optimal. Terdapat beberapa persamaan perhitungan jarak pada KNN salah satunya adalah *Euclidean Distance* dengan persamaan sebagai berikut:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

di mana:

x_i : titik x ke i

y_i : titik y ke i

- Melakukan *clustering* dengan menggunakan epsilon (ϵ) dan MinPts sebagai parameter input.
- Melakukan uji *cluster* dengan *Silhouette Coefficient* dengan persamaan sebagai berikut:

$$si = \frac{b(i)-a(i)}{\max\{a(i), b(i)\}} \quad (2)$$

di mana:

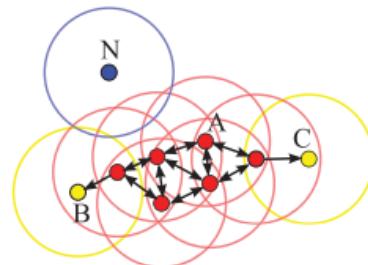
si : nilai *Silhouette Coefficient*

$a(i)$: rata-rata jarak antara titik I dengan seluruh

titik dalam A (cluster di mana titik I berada)

$b(i)$: rata-rata jarak antara titik I ke seluruh titik dalam cluster selain A.

- Melakukan visualisasi cluster yang diperoleh.

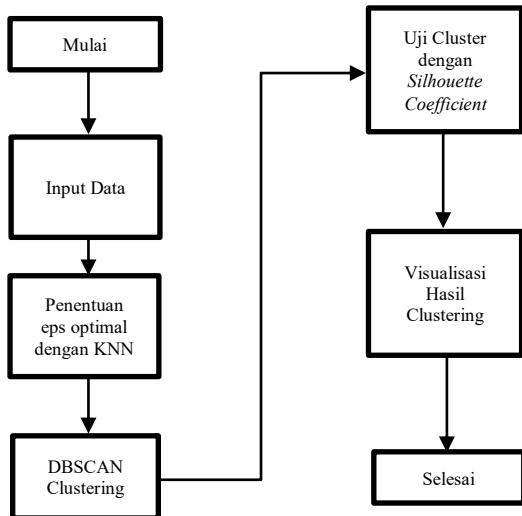


Gambar 1. Ilustrasi Model Cluster DBSCAN
(Schubert et al., 2017)

3.3. Desain Sistem

Proses penentuan jumlah cluster pada model DBSCAN tidak dilakukan di awal melainkan jumlah cluster diperoleh setelah mengetahui nilai Epsilon (ϵ) dan *threshold* MinPts. Penentuan nilai dua parameter tersebut perlu diperhatikan karena kedua parameter tersebut sangat mempengaruhi kualitas jumlah

cluster yang akan terbentuk. Adapun sistem kerja algoritma DBSCAN disajikan dalam Gambar 2.

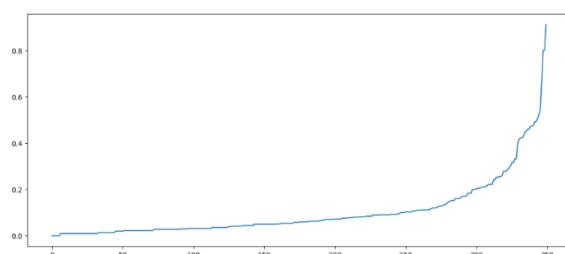


Gambar 2. Alur Algoritma DBSCAN

4. HASIL DAN PEMBAHASAN

4.1. Clustering Menggunakan DBSCAN

Pada penelitian ini untuk menentukan nilai epsilon (ϵ) optimal menggunakan metode KNN dengan menghitung jarak dalam matriks titik ke KNN. Nilai k ditampilkan dalam kurva naik di mana ada perubahan tajam dalam kurva merupakan jarak k yang optimal sebagaimana ditampilkan pada Gambar 3.

Gambar 3. Kurva KNN Penentuan nilai ϵ optimal

Setelah diperoleh nilai epsilon (ϵ) optimal dan MinPts dengan nilai $\epsilon = 0.20$ dan MinPts = 15 berdasarkan nilai *Silhouette Coefficient* tertinggi kemudian dilakukan proses *clustering* dengan dua parameter tersebut sebagai input. Adapun hasil *clustering* ditampilkan dalam Tabel 2.

Tabel 2. di atas menunjukkan *cluster* yang terbentuk dari proses *clustering* menggunakan algoritma DBSCAN dengan data yang digunakan adalah tahun 2017-2021, ditandai dengan nomor *cluster* di kolom paling kanan dari tabel tersebut. Adapun *cluster* yang terbentuk adalah 6 *cluster* dan 1 *outlier* atau *noise* yang ditandai dengan angka -1.

Tabel 2. Hasil Clustering Menggunakan DBSCAN

No.	Latitude	Longitude	Mag	Depth	Cluster
1	-8.96	110.00	4.0	10	0
2	-11.73	113.26	4.9	34	-1
3	-8.18	108.28	4.3	31	1
4	-8.73	110.61	3.3	35	0
5	-8.50	108.89	3.9	11	1
...
1821	-9.16	110.85	3.4	10	0
1822	-9.10	113.17	3.1	21	2
1823	-9.12	112.06	3.6	10	2

4.2. Uji Cluster

Evaluasi hasil clustering dilakukan untuk mengetahui kualitas output yang diperoleh. Pada penelitian untuk validasi cluster menggunakan metode *Silhouette Coefficient*. Untuk clustering menggunakan algoritma DBSCAN diperoleh nilai seperti yang disajikan pada Tabel 4.

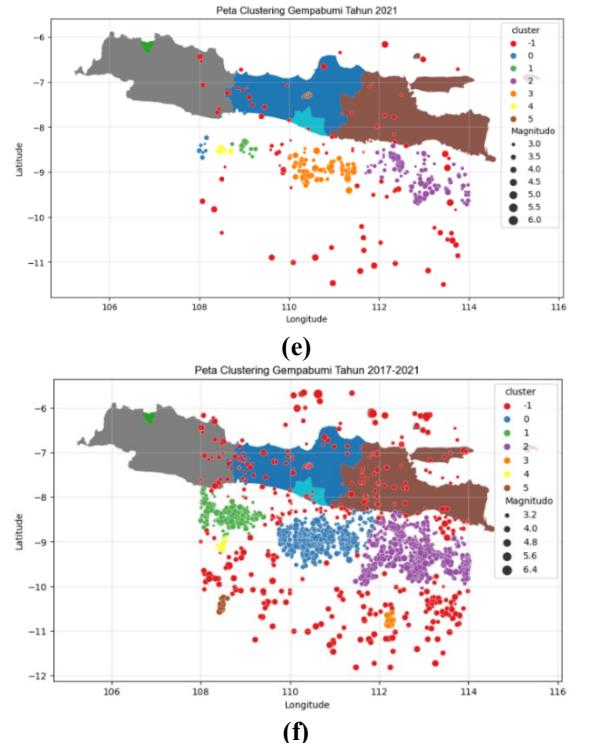
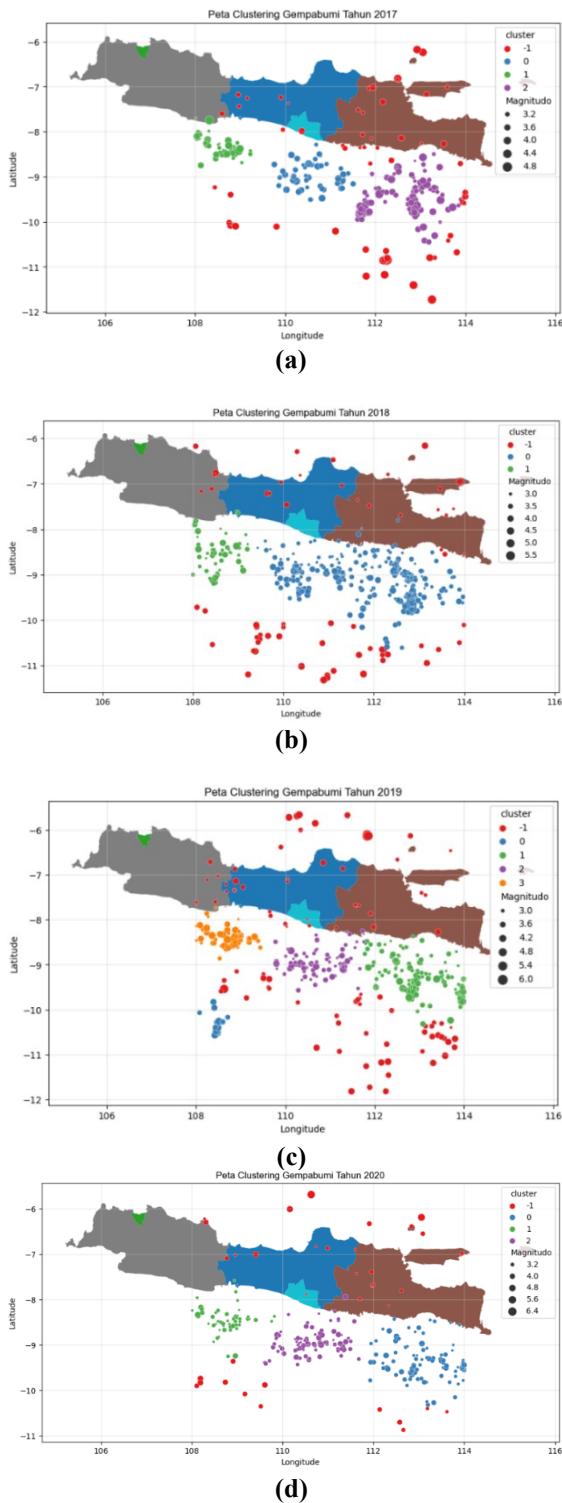
Tabel 4. Hasil Clustering Algoritma DBSCAN

Periode	Eps Optimal	MinPts Optimal	Jumlah Cluster	Silhouette Coefficient
T _{1_2017}	0.45	16	3 cluster dan 1 noise	0.404
T _{1_2018}	0.56	19	2 cluster dan 1 noise	0.367
T _{1_2019}	0.45	19	4 cluster dan 1 noise	0.390
T _{1_2020}	0.56	17	3 cluster dan 1 noise	0.499
T _{1_2021}	0.23	6	6 cluster dan 1 noise	0.319
T _{5_2017-2021}	0.20	15	6 cluster dan 1 noise	0.270

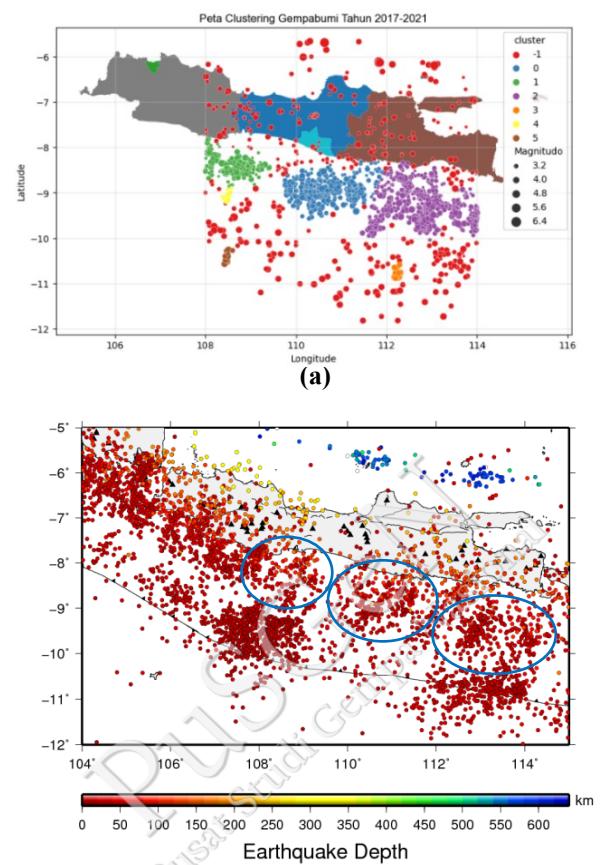
Berdasarkan Tabel 4. di atas diperoleh nilai *Silhouette Coefficient* tertinggi sebesar 0.499 pada data periode T_{1_2020} dengan jumlah 3 cluster dan 1 noise. Selain dilihat dari nilai *Sillhouette Coefficient* hasil visualisasi clustering perlu untuk mengetahui cluster gempabumi yang terbentuk. Adapun visualisasi hasil clustering dengan algoritma DBSCAN dapat dilihat pada Gambar 5.

Gambar 5. di atas menunjukkan hasil clustering gempabumi dengan algortima DBSCAN menurut periode waktu (1 tahun dan 5 tahun). Hasilnya untuk periode T_{1_2017} dan T_{1_2020} diperoleh cluster yang sama yaitu sebanyak 3 cluster dengan 1 noise. Hasil clustering T_{1_2018} sebanyak 2 cluster dengan 1 noise, T_{1_2019} sebanyak 4 cluster dengan 1 noise, dan untuk T_{1_2021} dan T_{5_2017-2021} diperoleh hasil clustering sebanyak 6 cluster dengan 1 noise.

Hasil clustering dengan algoritma DBSCAN secara visual memiliki kemiripan dengan hasil relokasi gempabumi oleh Pusat Studi Gempa Nasional tahun 2017 yang dituliskan pada buku Peta Sumber dan Bahaya Gempa Indonesia Tahun 2017 dengan menggunakan telemoDD (Pustlitbang PUPR, 2017) seperti pada Gambar 7.



Gambar 5. Peta Clustering Gempabumi Regional VII dengan Algoritma DBSCAN. (a) Tahun 2017, (b) Tahun 2018, (c) Tahun 2019, (d) Tahun 2020, (e) Tahun 2021, dan (f) Tahun 2017-2021.



Gambar 7. (a) hasil clustering dengan algoritma DBSCAN untuk $T_5_{2017-2021}$ dan (b) Seismisitas dari katalog PuSGeN tahun 2017 di Jawa hasil relokasi.

Lingkaran biru pada Gambar 7 (b) menunjukkan hasil relokasi gempabumi dengan menggunakan telemoDD oleh PuSGeN tahun 2017. Hasil tersebut memiliki kemiripan dengan hasil clustering menggunakan algoritma DBSCAN seperti pada Gambar 7 (a) meskipun jumlah clusternya berbeda yang disebabkan karena jumlah data yang digunakan berbeda pula.

5. KESIMPULAN

DBSCAN merupakan metode *clustering* berbasis kepadatan. Algoritma ini memandang *cluster* sebagai area dengan kepadatan tinggi yang dipisahkan oleh area dengan kepadatan rendah. Algoritma ini sangat populer karena sederhana untuk diterapkan dan hanya membutuhkan dua parameter input (*Epsilon* (ϵ) atau *eps* dan jumlah minimum objek dalam sebuah cluster *MinPts*). Algoritma ini cocok digunakan untuk pengelompokan data gempabumi karena mampu mengelompokkan data gempabumi berdasarkan pola sebarannya. Algoritma ini bagus digunakan untuk pengelompokan data dalam jumlah besar karena proses clusteringnya yang cepat.

Berdasarkan hasil clustering gempabumi menggunakan DBSCAN di atas diperoleh kesimpulan sebagai berikut:

- 1) Algoritma DBSCAN menghasilkan jumlah cluster 2 hingga 6 cluster.
- 2) Algoritma DBSCAN mampu memisahkan data noise atau outlier dari cluster yang terbentuk.
- 3) Meskipun nilai *Silhouette Coefficient* DBSCAN rendah namun visualisasi menunjukkan bahwa DBSCAN mampu mengelompokkan data dengan baik, yaitu mengelompokkan data berdasarkan kerapatan yang tinggi.
- 4) Hasil clustering algoritma DBSCAN memiliki kecocokan dengan hasil relokasi gempabumi Jawa tahun 2017 yang dirilis oleh Pusat Studi Gempa Nasional (PuSGeN) dalam buku Peta Sumber dan Bahaya Gempa Indonesia tahun 2017.

Clustering gempabumi penting dilakukan untuk memetakan zona rawan gempabumi berdasarkan sumbernya, sehingga dapat diketahui potensi gempabumi suatu wilayah dilihat dari sebaran gempabumi pada sumber gempabumi yang ada.

Penelitian ini masih bisa dikembangkan pada tahap berikutnya dengan menambah jumlah data yang digunakan dengan harapan dapat menghasilkan clustering yang lebih baik.

DAFTAR PUSTAKA

- ALGORITHM, D., 2021. Journal of Physics and Its Applications Clustering of Seismicity in the Indonesian Region for the 2018-2020 Period using the. 4(1), 1–6.
- ANSARI, A., NOORZAD, A., & ZAFARANI, H., 2009. Clustering analysis of the seismic catalog of Iran. Computers and Geosciences, 35(3), 475–486. <https://doi.org/10.1016/j.cageo.2008.01.010>
- APRILIA PUSPITA, C., NUGRAHA, A. D., & PUSPITO, N. T., 2015. Earthquake hypocenter relocation using double difference method in East Java and surrounding areas. AIP Conference Proceedings, 1658, 2013–2016. <https://doi.org/10.1063/1.4915029>
- CESCA, S., 2020. Seiscloud, a tool for density-based seismicity clustering and visualization. Journal of Seismology, 24(3), 443–457. <https://doi.org/10.1007/s10950-020-09921-8>
- DASZYKOWSKI, M., & WALCZAK, B., 2009. Density-Based Clustering Methods. Comprehensive Chemometrics, 2, 635–654. <https://doi.org/10.1016/B978-044452701-1.00067-3>
- DENG, D., 2020. DBSCAN Clustering Algorithm Based on Density. Proceedings - 2020 7th International Forum on Electrical Engineering and Automation, IFEEA 2020, 949–953. <https://doi.org/10.1109/IFEEA51475.2020.00199>
- DIKE, H. U., ZHOU, Y., DEVEERASETTY, K. K., & WU, Q., 2019. Unsupervised Learning Based On Artificial Neural Network: A Review. 2018 IEEE International Conference on Cyborg and Bionic Systems, CBS 2018, 322–327. <https://doi.org/10.1109/CBS.2018.8612259>
- GAO, X., & LI, G., 2020. A KNN Model Based on Manhattan Distance to Identify the SNARE Proteins. IEEE Access, 8, 112922–112931. <https://doi.org/10.1109/ACCESS.2020.3003086>
- GUNAWAN, E., & WIDYANTORO, S., 2019. Active tectonic deformation in Java, Indonesia inferred from a GPS-derived strain rate. Journal of Geodynamics, 123(January), 49–54. <https://doi.org/10.1016/j.jog.2019.01.004>
- HARINI, S., FAHMI, H., MULYANTO, A. D., & KHUDZAIFAH, M., 2020. The earthquake events and impacts mapping in Bali and Nusa Tenggara using a clustering method. IOP Conference Series: Earth and Environmental Science, 456(1). <https://doi.org/10.1088/1755-1315/456/1/012087>
- JUFRIANSAH, A., PRAMUDYA, Y., KHUSNANI, A., & SAPUTRA, S., 2021. Analysis of Earthquake Activity in Indonesia by Clustering Method. Journal of Physics: Theories and Applications, 5(2), 92. <https://doi.org/10.20961/jphystheor-appl.v5i2.59133>
- KARMENOVA, M., TLEBALDINOVA, A., KRAK,

- I., DENISSOVA, N., POPOVA, G., ZHANTASSOVA, Z., PONKINA, E., & GYÖRÖK, G., 2022. An Approach for Clustering of Seismic Events using Unsupervised Machine Learning. *Acta Polytechnica Hungarica*, 19(5), 7–22. <https://doi.org/10.12700/APH.19.5.2022.5.1>
- KARRI, N. A., YOUSUF ANSARI, M., & PATHAK, A., 2019. Identification of seismic zones of India using DBSCAN. 2018 International Conference on Computing, Power and Communication Technologies, GUCON 2018, 65–69. <https://doi.org/10.1109/GUCON.2018.8674964>
- KAZEMI-BEYDOKHTI, M., ALI ABBASPOUR, R., & MOJARAB, M., 2017. Spatio-Temporal Modeling of Seismic Provinces of Iran Using DBSCAN Algorithm. *Pure and Applied Geophysics*, 174(5), 1937–1952. <https://doi.org/10.1007/s00024-017-1507-0>
- MOJARAB, M., MEMARIAN, H., ZARE, M., HOSSEIN MORSHEDY, A., & HOSSEIN PISHAHANG, M., 2014. Modeling of the seismotectonic provinces of Iran using the self-organizing map algorithm. *Computers and Geosciences*, 67, 150–162. <https://doi.org/10.1016/j.cageo.2013.12.007>
- OMRAN, M. G. H., ENGELBRECHT, A. P., & SALMAN, A., 2007. An overview of clustering methods. *Intelligent Data Analysis*, 11(6), 583–605. <https://doi.org/10.3233/ida-2007-11602>
- PUSTLITBANG PUPR., 2017. Buku Peta Gempa 2017.
- RAHMAN, R. R. A., & WIJAYANTO, A. W., 2021. Pengelompokan Data Gempa Bumi Menggunakan Algoritma Dbscan. *Jurnal Meteorologi Dan Geofisika*, 22(1), 31. <https://doi.org/10.31172/jmg.v22i1.738>
- SCHUBERT, E., SANDER, J., ESTER, M., KRIEGEL, H. P., & XU, X., 2017. DBSCAN Revisited, Revisited. *ACM Transactions on Database Systems*, 42(3), 1–21. <https://doi.org/10.1145/3068335>

Halaman ini sengaja dikosongkan