

Density-Based Clustering untuk Pemetaan Daerah Rawan Gempa Bumi di Wilayah Sumatera Barat Menggunakan Metode DBSCAN

Reny Medikawati Taufiq¹, Rahmad Firdaus², Fitri Handayani³, Putri Fadhilla Muarif⁴, Riza Rindriani Rizqy⁵

^{1,2,3,4,5}Teknik Informatika, Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

¹renymedikawati@umri.ac.id, ²rahmadfirdaus@umri.ac.id, ³fitrihandayani@umri.ac.id, ⁴pmuarif@umri.ac.id, ⁵200401163@student.umri.ac.id

Abstract

Earthquakes are natural disasters that cannot be prevented or avoided. One of the areas affected is the West Sumatra region, where West Sumatra is one of the regions in Indonesia which is in the Sumatra basin which is vulnerable to earthquakes. Therefore, density-based clustering analysis can be carried out which aims to produce a point map of earthquake-prone areas in the West Sumatra region using the Density Based Spatial Clustering of Application with Noise (DBSCAN) method. In implementing the DBSCAN algorithm, epsilon and minpts parameters are required using the K-Nearest Neighbors method with evaluation of results using the Silhouette Coefficient. The results of DBSCAN clustering using KNN input parameters obtained a total of 3 clusters and 1 noise with a silhouette coefficient value of 0.310 from the 2010-2023 data period. However, from the testing stage without using KNN, we got a high silhouette score, namely 0.890 with 2 clusters and 1 noise. Keywords: abstract keywords.

Abstrak

Gempa bumi merupakan bencana alam yang tidak dapat dicegah maupun dihindari. Salah satu daerah yang terkena dampak itu ialah wilayah Sumatera Barat, dimana Sumatera Barat merupakan salah satu wilayah di Indonesia yang berada di jalur cekungan Sumatera yang rentan terhadap gempa bumi. Maka dari itu dapat dilakukan analisis *clustering* berbasis kepadatan yang bertujuan untuk menghasilkan peta titik daerah rawan gempa bumi di wilayah Sumatera Barat menggunakan *Density Based Spatial Clustering of Application with Noise* (DBSCAN). Dalam penerapan algoritma DBSCAN diperlukan parameter *epsilon* dan *minpts* yang menggunakan metode *K-Nearest Neighbors* dengan evaluasi hasil menggunakan *Silhouette Coefficient*. Hasil *Clustering* DBSCAN yang menggunakan input parameter KNN ini memperoleh jumlah cluster sebanyak 3 cluster dan 1 *noise* dengan nilai *silhouette coefficient* sebesar 0.310 dari periode data 2010-2023. Namun, dari tahapan pengujian tanpa menggunakan KNN mendapatkan hasil *silhouette score* yang tinggi yaitu 0.890 dengan jumlah 2 cluster dan 1 *noise*.

Kata kunci: klasterisasi, gempa bumi, KNN, DBSCAN, *silhouette coefficient*

1. Pendahuluan

Gempa bumi sebuah getaran yang terjadi secara tiba-tiba dipermukaan bumi akibat pelepasan energi dari dalam kerak bumi. Pelepasan energi ini terjadi ketika tekanan diperbatasan antara lempeng tektonik mencapai ambang batas dan mengakibatkan pergeseran secara tiba-tiba. Salah satu daerah yang terdampak oleh peristiwa ini adalah Sumatera Barat[1]. Bencana ini memiliki sifat destruktif, terjadi secara tiba-tiba dan berlangsung dalam durasi relatif singkat [2].

Berdasarkan data dari *United States Geological Survey* (USGS) sebuah lembaga Amerika Serikat yang bertanggung jawab dalam bidang pemetaan, tercatat sebanyak 214 kejadian gempa bumi terjadi di wilayah Sumatera Barat dalam kurun waktu 2010 hingga 2023. Dari data yang dikumpulkan beberapa daerah yang terdampak gempa bumi meliputi Kepulauan Mentawai, Padang, Solok dan Pariaman.

Analisis spasial merupakan suatu pendekatan yang memanfaatkan metode statistik dan teknik analisis untuk mengevaluasi pola distribusi geografis serta mengkaji hubungan spasial dalam data geospasial[3]. Analisis spasial bertujuan untuk mengkaji serta memahami keterkaitan geografis antara objek,

fenomena atau entitas yang terdapat dalam suatu area tertentu [4].

Salah satu langkah untuk memetakan zona rawan gempa bumi dilihat dari sumbernya di wilayah Sumatera Barat secara langsung adalah dengan menerapkan metode clustering atau pengelompokkan data berdasarkan kesamaan atribut. Menurut Narwati (2010) *clustering* adalah metode yang digunakan untuk mengidentifikasi kelompok objek dengan karakteristik serupa serta menganalisis pola distribusi dan keterkaitan dalam himpunan data berukuran besar.


Dalam proses *clustering* ini, data yang dianalisis mencakup lokasi titik gempa dengan atribut seperti koordinat geografis (longitude dan latitude), magnitudo, serta kedalaman gempa. Hasil pemetaan yang diperoleh berperan sebagai salah satu strategi mitigasi untuk meminimalkan dampak negatif bencana alam. Dengan tersedianya informasi mengenai wilayah yang mempunyai tingkah rawan yang signifikan, pihak-pihak terkait dalam penanggulangan bencana dapat mengambil langkah-langkah preventif yang dapat dijadikan dasar dalam perencanaan kawasan pariwisata serta meningkatkan edukasi bagi masyarakat yang bermukim di daerah berisiko tinggi terhadap bencana alam [5].

Algoritma dalam *machine learning* adalah representasi matematis yang digunakan untuk memodelkan suatu sistem atau fenomena serta mendeteksi pola dalam data. Sistem *machine learning* mampu belajar dari data dan pengalaman, memungkinkan peningkatan kinerja seiring waktu. Semakin optimal algoritma yang diterapkan, semakin baik pula kualitas keputusan yang dihasilkan [6]. Secara dasar, *machine learning* dikategorikan menjadi 3 jenis: *Supervised Learning*, *Unsupervised Learning* dan *Reinforcement Learning* [7].

Penelitian ini menerapkan algoritma DBSCAN untuk mengelompokkan data ke dalam beberapa cluster. DBSCAN merupakan metode berbasis kepadatan tinggi diklasifikasikan sebagai bagian dari suatu klaster, sedangkan objek dengan kepadatan rendah dianggap sebagai *noise* atau *outlier*.

2. Metode Penelitian

Metode penelitian merupakan serangkaian tahapan yang dirancang secara sistematis dan logis dalam melakukan penelitian untuk menghasilkan tujuan yang telah ditetapkan. Tahap awal yang dilakukan mencakup perencanaan penelitian, pengumpulan data, preprocessing data, penerapan algoritma DBSCAN untuk klusterisasi, evaluasi klaster menggunakan *Silhouette Coefficient* serta visualisasi hasil klusterisasi. Gambar 1 menunjukkan penelitian yang dilaksanakan.



Gambar 1. Tahapan Penelitian

2.1. Rencana Penelitian

Pada langkah perencanaan, penelitian disusun berdasarkan tahapan yang harus dilalui secara sistematis. Proses perencanaan diawali dengan melakukan studi literatur, yaitu menelusuri jurnal, buku, serta makalah dari penelitian sebelumnya yang relevan guna dijadikan referensi dan kutipan sesuai dengan topik yang dikaji dalam penelitian.

2.2. Pengumpulan Data

Tahap berikut merupakan pengumpulan dataset pada penelitian ini diambil dari pada website <https://www.usgs.gov/> *United States Geological Survey (USGS)* berjumlah 214 kasus data gempa bumi wilayah Sumatera Barat. Adapun variabel data yang digunakan adalah *latitude*, *longitude*, *magnitude*, dan *depth*.

2.3. Tahapan Preprocessing

Preprocessing data merupakan tahap krusial dalam pengembangan model analisis data serta langkah awal untuk menyelaraskan data yang telah diperoleh. Proses ini bertujuan untuk meningkatkan kualitas data, mengeliminasi informasi yang tidak relevan, serta memastikan konsistensi dalam representasi data[8].

2.4. Penentuan Nilai (ϵ) dan MinPts menggunakan metode jarak KNN (*K-Nearest Neighbors*)

Pada saat menetapkan nilai *epsilon* (ϵ) dan *MinPts*, penentuan nilai epsilon yang optimal berperan penting dalam kualitas hasil *clustering*. Nilai epsilon yang sesuai diperoleh dengan menerapkan metode jarak KNN (*K-Nearest Neighbors*) atau k-tetangga terdekat [9].

2.5. DBSCAN Clustering

Algoritma DBSCAN merupakan metode klusterisasi yang dikembangkan berdasarkan kepadatan data (*density-based*). Konsep kepadatan ini mengelompokkan data ke dalam 3 kategori yaitu inti (*core*), batas (*border*) dan *noise* [10] [11]. Algoritma ini melakukan pembentukan cluster dengan cara mengidentifikasi serta memperluas area yang memiliki tingkat kepadatan tinggi. Proses ini bergantung pada dua parameter utama yang harus ditentukan secara presisi, salah satunya adalah radius pencarian yang dilambangkan sebagai input (*Epsilon* (ϵ) atau eps dan jumlah terkecil objek dalam sebuah cluster *MinPts*) yang menjadi batas kepadatan (*density threshold*) untuk menentukan suatu region termasuk padat atau tidak [12].

Clustering merupakan proses mengelompokkan data ke dalam beberapa cluster dimana objek dalam satu cluster memiliki kesamaan karakteristik tetapi berbeda dari objek di cluster lain [13].

Proses *clustering* diterapkan dengan menggunakan algoritma *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN). Algoritma ini memperoleh penghargaan *Test of Time Award* dari ACM (*Association for Computing Machinery*) pada konferensi data mining tahun 2014 [14]. Tahapan-tahapan algoritma DBSCAN secara dasar sebagai berikut :

- Menetapkan titik awal secara acak dari kumpulan data sebagai kandidat titik inti dalam proses *clustering*.
- Menetapkan nilai *Epsilon* dan *MinPts*.
- Apabila titik awal yang dipilih memenuhi kriteria sebagai titik inti berdasarkan parameter *MinPts* dan

ϵ yang telah ditemukan, maka proses *clustering* akan terbentuk suatu cluster yang mencakup objek-objek di sekitarnya yang berada dalam radius yang telah ditetapkan.

d. Apabila objek pada titik awal dikategorikan sebagai *border point* dan tidak tersedia objek lain yang memiliki keterhubungan secara *density-reachable* dengan titik tersebut, maka algoritma DBSCAN akan melanjutkan pemrosesan dengan memilih objek berikutnya dalam basis data sebagai calon titik pusat yang baru.

e. Melanjutkan proses c dan d hingga semua poin telah dikunjungi.

f. Apabila suatu objek atau titik yang dipilih tidak termasuk sebagai titik pusat (*core point*) maupun titik batas (*border point*) dalam cluster yang terbentuk, maka objek tersebut diklasifikasikan sebagai *outlier*. *Outlier* merupakan titik data yang memiliki jarak lebih besar dari nilai ϵ terhadap *core point* serta tidak memenuhi jumlah minimum titik (*minPts*) yang telah ditetapkan dalam dataset.

2.7. Uji Cluster Dengan Silhouette Coefficient

Silhouette Coefficient adalah suatu metode validasi berbasis kriteria internal menilai kualitas *clustering*. Teknik ini mengevaluasi posisi setiap objek dalam *cluster* dengan membandingkan rata-rata jarak antar objek dalam *cluster* yang sama dengan jarak objek tersebut terhadap *cluster* lainnya[15]. *Silhouette Coefficient* digunakan karena kemampuannya dalam menilai jumlah cluster yang dihasilkan dalam proses pengelompokan data[16].

2.6. Hasil


Pada tahap ini, dilakukan peringkasan hasil klasterisasi dalam pemetaan wilayah rawan gempa di Sumatera Barat menggunakan algoritma DBSCAN. Selanjutnya, hasil yang diperoleh akan dievaluasi menggunakan metode *silhouette coefficient* dan divisualisasikan sebagai output akhir.

2.7. Evaluasi Hasil

Menilai kualitas cluster yang terbentuk dilakukan dengan menganalisis nilai *silhouette coefficient*. Metode ini digunakan untuk mengukur kualitas serta kekuatan cluster dengan menilai seberapa baik objek dalam satu cluster dikelompokkan. Teknik ini berkaitan dengan konsep kohesi dan pemisahan (*cohesion and separation*)

2.8. Visualisasi Hasil

Hasil visualisasi *clustering* menggunakan algoritma DBSCAN akan menampilkan representasi peta yang menggambarkan sebaran titik-titik lokasi daerah rawan gempa di Sumatera Barat. Peta tersebut disusun berdasarkan variabel-variabel seperti lokasi geografis serta koordinat titik di wilayah yang dianalisis. Gambar 2 di bawah ini menyajikan ilustrasi visual dari peta yang menunjukkan distribusi daerah rawa gempa.



Gambar 2. Contoh Visualisasi Pemetaan

3. Hasil dan Pembahasan

3.1. Preprocessing

Proses *preprocessing* data dilakukan secara manual dengan menggunakan Microsoft Excel memfilter wilayah yang hanya termasuk dalam cakupan Provinsi Sumatera Barat serta menghapus data dari wilayah di luar provinsi tersebut. Selain itu, tahap ini juga mencakup pembersihan data dengan menghilangkan entri yang kosong atau tidak valid. Gambar 3 adalah dataset yang sudah di *preprocessing*:

id	latitude	longitude	depth/ke/mag/ku/mag/1.net	gap	dmn	rms	net	id	updated	place
2023-09-02	-2.0649	99.9114	40.184	4.4	mb	40	131	4.829	0.69 us	us70000ay 2023-10-2 Kepulauan Mentawai region, Indonesia
2023-09-00	-2.2387	99.9712	35	4.1	mb	19	102	3.801	0.43 us	us70000ay 2023-10-1 48 km ESE of Padang, Indonesia
2023-08-31	-1.0986	100.3617	101.989	4.1	mb	22	130	3.685	0.37 us	us70000ay 2023-10-2 15 km S of Padang, Indonesia
2023-08-00	-0.4807	101.3782	10.012	3.9	ml	5	136	3.318	0.15 us	us70000ay 2023-10-0 53 km ENE of Sijunjung, Indonesia
2023-07-02	-2.0999	99.9804	34.244	4.4	mb	19	138	3.818	0.72 us	us70000ay 2023-09-21 11 km ESE of Padang, Indonesia
2023-04-00	-0.4315	100.4370	9.797	4.2	mb	24	64	3.332	0.97 us	us60000ay 2023-08-1 southern Sumatra, Indonesia
2023-03-00	-5.5855	100.8384	93.325	5	msw	206	28	3.49	0.64 us	us70000ay 2023-05-0 southern Sumatra, Indonesia
2023-01-01	-1.8301	99.6227	35	4.3	mb	21	78	3.709	0.55 us	us60000ay 2023-09-31 Kepulauan Mentawai region, Indonesia
2022-11-02	-1.897	99.930	39.819	4.3	mb	32	142	2.291	0.62 us	us70000ay 2023-09-04 6 km SSE of Padang, Indonesia
2022-10-02	-0.1947	99.7866	10.322	4.3	mb	26	104	2.649	0.77 us	us70000ay 2023-01-01 61 km NW of Pariaman, Indonesia
2022-10-01	-1.5178	99.9911	40	4.2	mb	24	187	3.635	0.63 us	us60000ay 2022-12-1 81 km SW of Padang, Indonesia
2022-10-00	-1.4543	101.651	220.374	4.2	mb	30	150	3.023	0.58 us	us60000ay 2022-12-1 southern Sumatra, Indonesia
2022-09-01	-2.0313	99.6071	19.034	4.8	msw	111	51	2.764	0.71 us	us70000ay 2022-11-01 147 km SW of Padang, Indonesia
2022-09-00	-2.3603	100.6472	50.366	4.6	mb	51	126	2.697	0.49 us	us60000ay 2022-11-19720.13.1402
2022-08-02	-1.5438	100.2556	90.795	4.6	mb	33	132	1.857	0.66 us	us70000ay 2022-11-01 24 km SSW of Padang, Indonesia
2022-08-00	-1.9812	100.2649	35	4.7	mb	36	64	2.421	0.67 us	us60000ay 2022-10-2 114 km S of Padang, Indonesia
2022-08-00	-0.809	99.7163	70.455	4.5	mb	27	139	1.799	0.62 us	us60000ay 2022-10-2 24 km WSW of Pariaman, Indonesia
2022-06-00	-1.8368	100.4097	50.54	5.1	mb	142	51	2.238	0.88 us	us70000ay 2022-08-01 96 km S of Padang, Indonesia
2022-05-02	-0.4777	99.6588	81.85	4.6	mb	49	78	1.395	0.63 us	us60000ay 2022-08-01 53 km WNW of Pariaman, Indonesia
2022-04-00	-0.2221	100.6678	47.55	4.3	mb	78	6.651	1.1	us	us70000ay 2022-06-1 1 km E of Payakumbuh, Indonesia
2022-04-00	-2.2443	100.6988	44.54	4.5	mb	96	2.703	0.65 us	us60000ay 2022-05-2 143 km SSW of Padang, Indonesia	

Gambar 3. Hasil Preprocessing

3.2. Penentuan Nilai (ϵ) dan *MinPts* menggunakan metode jarak KNN (*K-Nearest Neighbors*)

Tahapan ini menetapkan nilai ϵ dan *minpts* yang optimal harus menggunakan metode *K-Nearest Neighbor KNN* dan dengan *tools google collabs* [17].


Salah satu metode perhitungan jarak yang digunakan dalam KNN adalah *Euclidean Distance* yang dinyatakan dalam persamaan berikut:

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

di mana:

x_i : titik x ke I

y_i : titik y ke i




Gambar 4. Hasil Kurva dan KNN Optimal

Pada gambar 4. Diatas menunjukkan bahwa hasil KNN beserta kurva dari hasil yang diperoleh untuk nilai epsilon dan minpts optimal sesuai data sudah di inputkan dan akan menjadi parameter yang akan di inputkan kembali pada proses *clustering* DBSCAN.

3.3. DBSCAN Clustering

Algoritma DBSCAN mengelompokkan titik data ke dalam cluster berdasarkan kedekatan spasialnya. Titik-titik yang berdekatan dan memilih jumlah tetangga yang memenuhi bata minimum (*minPts*) akan diklasifikasikan dalam cluster yang sama. Sementara itu, titik-titik yang tidak memenuhi syarat untuk membentuk klaster dan tidak memiliki cukup tetangga akan dikategorikan sebagai *Noise*.



Gambar 5. Output Jumlah Clustering DBSCAN

Gambar 5. Diatas menunjukkan bahwa clustering menggunakan algoritma DBSCAN dengan inputan epsilon dan minpts sesuai hasil metode KNN dan data yang berjumlah 214 mendapatkan hasil 3 cluster 1 noise.

3.4. Evaluasi Hasil Dengan *Silhouette Coefficient*


Hasil diperoleh *Silhouette score*nya ialah 0.3100 sesuai data dan hasil yang sudah di clustering menggunakan KNN. Interpretasi dari nilai *silhouette score* tersebut adalah bahwa *clustering* dengan algoritma DBSCAN

mampu *mencluster* data dengan baik, meskipun nilai *silhouette score* yang diperoleh tergolong rendah namun visualisasi menunjukkan bahwa DBSCAN mampu mengelompokkan data berdasarkan kerapatan tinggi.

Beberapa hasil *clustering* menggunakan algoritma DBSCAN telah diuji tanpa penerapan metode KNN, menghasilkan nilai *silhouette score* yang tinggi. Dari berbagai pengujian, epsilon 0.1 menunjukkan nilai tertinggi dibandingkan dengan *epsilon* lainnya. Seiring dengan peningkatan nilai *minPts* yang digunakan sebagai parameter *input*. Lima nilai *silhouette score* yang dikategorikan baik, yaitu 0.746, 0.755, 0.763, 0.835, dan 0.890 akan divisualisasikan dalam peta cluster sebagai bagian dari hasil *clustering*.

3.5. Visualisasi Hasil Clustering

Visualisasi hasil dilakukan menggunakan google collabs dengan memasukkan *output clustering* ke dalam kode program. Proses ini memanfaatkan bahasa pemrograman Python, yang dikenal memiliki kemampuan optimal dalam menangani data berukuran besar secara efisien [18] [19].



Gambar 6. Peta Hasil Cluster Menggunakan Epsilon dan MinPts KNN

Dapat dilihat dari gambar 6. Ialah peta cluster daerah Sumatera Barat yang menggunakan inputan epsilon dan minpts dari metode KNN yang menghasilkan 3 cluster daerah rawan gempa dan 1 *cluster* noise yang mana noise nya berjumlah 31. Pada tabel 1. Di sajikan tabel jumlag dari hasil clusternya.


Tabel 1. Jumlah Hasil Cluster

No	Nama Cluster	Jumlah Anggota Cluster
1	Cluster 0	171
2	Cluster 1	8
3	Cluster 2	4


Pada tabel 1 diatas terdapat hasil 3 *cluster* yaitu ada clister 0 yang mana merupakan *cluster* yang tingkat kerapatan paling tinggi dan jumlah anggota cluster nya paling banyak, cluster 1 merupakan tingkat kerapatan menengah dengan jumlah anggota *cluster* nya 8, sedangkan *cluster* 2 merupakan tingkat kerapatan paling rendah dan jumlah anggota *cluster* nya pun paling sedikit.

Dalam konteks ini, peta cluster akan ditampilkan berdasarkan hasil pengujian parameter epsilon dan


minPts yang optimal, sebagaimana dihitung pada Tabel 1. Lima nilai silhouette coefficient tertinggi telah diperoleh dari pengujian dengan epsilon 0.1 serta *minPts* pada rentang 8, 9, 10, 11, dan 12. Hasil tersebut akan divisualisasikan dalam peta cluster berikut.




Gambar 7. Peta Cluster DBSCAN Dari Tahapan Pengujian Silhouette Score Tertinggi (5 Cluster)




Gambar 8. Peta Cluster DBSCAN Dari Tahapan Pengujian Silhouette Score Tertinggi (4 Cluster)



Gambar 9. Peta Cluster DBSCAN Dari Tahapan Pengujian Silhouette Score Tertinggi (3 Cluster)



Gambar 10. Peta Cluster DBSCAN Dari Tahapan Pengujian Silhouette Score Tertinggi (2 Cluster)



Gambar 11. Peta Cluster DBSCAN Dari Tahapan Pengujian Silhouette Score Tertinggi (1 Cluster)

3.6. Analisis Hasil

Berdasarkan hasil analisis *clustering* menggunakan metode DBSCAN, beberapa wilayah di Sumatera Barat khususnya kawasan kepulauan dan pesisir seperti Kepulauan Mentawai dan Tuapejat teridentifikasi sebagai daerah rawan gempa bumi. Kerentanan ini disebabkan oleh kedekatan wilayah tersebut dengan zona pertemuan lempeng tektonik di dasar laut.

Analisis ini mencakup perhitungan dan visualisasi peta cluster yang dapat dijadikan acuan dalam upaya mitigasi risiko bencana. Hasil pengujian menunjukkan bahwa peta cluster dengan nilai silhouette score tinggi yaitu sebesar 0,890 cenderung memiliki jumlah cluster yang sedikit yaitu dua cluster dan satu noise Sementara itu, hasil clustering dengan metode KNN dalam optimasi parameter menghasilkan 3 cluster dan satu noise dengan silhouette score yang lebih rendah yaitu 0.310.

4. Kesimpulan

Penelitian analisis *clustering* dengan metode DBSCAN untuk pemetaan daerah rawan gempa di Sumatera Barat menghasilkan tiga *cluster*, dengan satu cluster sebagai noise. Penggunaan parameter KNN menghasilkan nilai *Silhouette Coefficient* 0.310, sementara tanpa KNN mencapai 0.890 dengan 2 *cluster* dan 1 noise. Meskipun nilai *silhouette DBSCAN* rendah, metode ini tetap efektif dalam mengelompokkan data gempa bumi berdasarkan kerapatan kejadian. Hasil penelitian dijadikan sebagai dasar mitigasi bencana dan perencanaan tata ruang di Sumatera Barat.

Daftar Rujukan

- [1] R. Baihaqi and D. Pujiastuti, "Analisis Risiko Gempa Bumi di Kota Pariaman Provinsi Sumatera Barat," *J. Fis. Unand*, vol. 12, no. 2, pp. 206–212, 2023, doi: 10.25077/jfu.12.2.206-212.2023.
- [2] F. D. Cahyo, F. Ihsan, R. Roulita, N. Wijayanti, and R. Mirwanti, "Kesiapsiagaan Bencana Gempa Bumi Dalam Keperawatan: Tinjauan Penelitian," *JPP (Jurnal Kesehat. Poltekkes Palembang)*, vol. 18, no. 1, pp. 87–94, 2023, doi: 10.36086/jpp.v18i1.1525.
- [3] J. M. Flenniken, S. Stuglik, and B. V. Iannone, "Quantum GIS (QGIS): An introduction to a free alternative to more costly GIS platforms," *Edis*, vol. 2020, no. 2, p. 7, 2020, doi: 10.32473/edis-fr428-2020.
- [4] P. C. Latue, "Analisis Spasial Temporal Perubahan Tutupan

- Lahan di Pulau Ternate Provinsi Maluku Utara Citra Satelit Resolusi Tinggi," *Buana J. Geogr. Ekol. dan Kebencanaan*, vol. 1, no. 1, pp. 31–38, 2023, doi: 10.56211/buana.v1i1.339.
- [5] I. N. Setiawan, D. Krismawati, S. Pramana, and E. Tanur, "Klasterisasi Wilayah Rentan Bencana Alam Berupa Gerakan Tanah Dan Gempa Bumi Di Indonesia," *Semin. Nas. Off. Stat.*, vol. 2022, no. 1, pp. 669–676, 2022, doi: 10.34123/semnasoffstat.v2022i1.1538.
- [6] I. M. Faiza, G. Gunawan, and W. Andriani, "Tinjauan Pustaka Sistematis: Penerapan Metode Machine Learning untuk Deteksi Bencana Banjir," *J. Minfo Polgan*, vol. 11, no. 2, pp. 59–63, 2022, doi: 10.33395/jmp.v11i2.11657.
- [7] G. E. Kamiadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang, and L. Yang, "Physics-informed machine learning," *Nat. Rev. Phys.*, vol. 3, no. 6, pp. 422–440, 2021, doi: 10.1038/s42254-021-00314-5.
- [8] T. A. Alghamdi and N. Javaid, "A Survey of Preprocessing Methods Used for Analysis of Big Data Originated from Smart Grids," *IEEE Access*, vol. 10, pp. 29149–29171, 2022, doi: 10.1109/ACCESS.2022.3157941.
- [9] I. B. F. Arafat, M. A. Hariyadi, I. B. Santoso, and C. Crysdiyan, "Clustering Gempabumi di Wilayah Regional VII Menggunakan Pendekatan DBSCAN," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 4, pp. 823–830, 2023, doi: 10.25126/jtiik.20241046918.
- [10] G. Djati, C. Series, and D. Mining, "Klasterisasi Data Pemain Premier League 2020 dengan Algoritma DBSCAN," *Gunung Djati Conf. Ser.*, vol. 3, p. 8, 2021.
- [11] L. Qadrini, "Metode K-Means dan DBSCAN pada Pengelompokan Data Dasar Kompetensi Laboratorium ITS Tahun 2017," *J. Stat. J. Ilm. Teor. dan Apl. Stat.*, vol. 13, no. 2, pp. 5–11, 2020, doi: 10.36456/jstat.vol13.no2.a2886.
- [12] I. R. C. Pata, Statiswaty, and N. Ransi, "Segmentasi Pemetaan Pelanggan Potensial Menggunakan Algoritma DbSCAN Dengan Rfm Model Berbasis Web," *Animator*, vol. 1, no. 2, pp. 63–71, 2023, [Online]. Available: <http://animator.uho.ac.id/index.php/journal/article/view/25%0Ahttp://animator.uho.ac.id/index.php/journal/article/downlo>
- ad/25/16
- [13] K. Annisa, B. S. Ginting, and M. A. Syar, "Penerapan Data Mining Pengelompokan Data Pengguna Air Bersih Berdasarkan Keluhannya Menggunakan Metode Clustering Pada Pdam Langkat," *J. Sist. Inf. Kaputama*, vol. 6, no. 2, pp. 165–179, 2022, doi: 10.59697/jsik.v6i2.167.
- [14] B. N. Sari and A. Primajaya, "Penerapan Clustering DbSCAN Untuk Pertanian Padi Di Kabupaten Karawang," *J. Inform. dan Komput.*, vol. 4, no. 1, pp. 28–34, 2019, [Online]. Available: www.mapcoordinates.net/en.
- [15] S. 'Aina Salsabila, T. Widiyari, and S. Sudarmo, "METODE K-HARMONIC MEANS CLUSTERING DENGAN VALIDASI SILHOUETTE COEFFICIENT (Studi Kasus : Empat Faktor Utama Penyebab Stunting 34 Provinsi di Indonesia Tahun 2018)," *J. Gaussian*, vol. 11, no. 1, pp. 11–20, 2022, doi: 10.14710/j.gauss.v11i1.34003.
- [16] D. Hartama and M. Anjelita, "Analysis of Silhouette Coefficient Evaluation with Euclidean Distance in the Clustering Method (Case Study: Number of Public Schools in Indonesia)," *J. Mantik*, vol. 6, no. 3, pp. 3667–3677, 2022, [Online]. Available: <https://iocscience.org/ejournal/index.php/mantik/article/view/3318>
- [17] T. S. Gunawan *et al.*, "Development of video-based emotion recognition using deep learning with Google Colab," *Telkomnika (Telecommunication Comput. Electron. Control.*, vol. 18, no. 5, pp. 2463–2471, 2020, doi: 10.12928/TELKOMNIKA.v18i5.16717.
- [18] Y. Galahartlambang, T. Khotiah, and J. Jumain, "Visualisasi Data Dari Dataset COVID-19 Menggunakan Pemrograman Python," *J. Ilm. Intech Inf. Technol. J. UMUS*, vol. 3, no. 01, pp. 58–64, 2021, [Online]. Available: <http://jurnal.umus.ac.id/index.php/intech/article/view/417>
- [19] Angelina M. T. I. Sambi Ua *et al.*, "Penggunaan Bahasa Pemrograman Python Dalam Analisis Faktor Penyebab Kanker Paru-Paru," *J. Publ. Tek. Inform.*, vol. 2, no. 2, pp. 88–99, 2023, doi: 10.55606/jupti.v2i2.1742.