

Zonasi Wilayah Rawan Gempa di Sulawesi Menggunakan Metode K-Means Clustering terhadap Data Historis USGS (1974-2024)

Zoning of Earthquake-Prone Areas in Sulawesi Using the K-Means Clustering Method on USGS Historical Data (1974-2024)

Adrian Nicholas Lumowa

Program Studi Teknik Informatika, Fakultas Sains Dan Teknologi (Saintek)
Universitas Prisma Manado, Indonesia

*Penulis Korespondensi

E-mail : adriannicholaslumowa@gmail.com

Abstrak. Penelitian ini bertujuan untuk melakukan pemetaan wilayah rawan gempa di Pulau Sulawesi dengan memanfaatkan algoritma *K-Means* terhadap data historis gempa bumi yang dikumpulkan oleh *United States Geological Survey* (USGS) selama periode 1974 hingga 2024. Data yang digunakan dalam analisis mencakup informasi lokasi geografis, magnitudo, serta kedalaman gempa. Proses klusterisasi menghasilkan tiga zona utama berdasarkan kedalaman gempa: dangkal, menengah, dan dalam. Di antara ketiganya, gempa dangkal dengan magnitudo tinggi merupakan kejadian yang paling dominan dan memiliki potensi besar dalam menyebabkan kerusakan infrastruktur. *K-Means* terbukti efektif dalam menyegmentasi data gempa dan mengungkap pola seismik di kawasan Sulawesi. Hasil zonasi ini dapat dimanfaatkan untuk mendukung kebijakan mitigasi bencana serta perencanaan tata ruang yang lebih responsif terhadap risiko gempa. Informasi yang dihasilkan juga berperan penting dalam meningkatkan kesiapsiagaan masyarakat serta upaya pengurangan dampak bencana di wilayah tersebut.

Kata kunci: pemetaan gempa, Sulawesi, *K-Means*, data seismik historis USGS, pengurangan risiko bencana

Abstract. This study aims to map earthquake-prone zones in Sulawesi by applying the *K-Means Clustering algorithm* to historical earthquake data from the *United States Geological Survey* (USGS) spanning the period from 1974 to 2024. The analysis was conducted using variables including geographic location, magnitude, and depth of earthquakes. The clustering results identified three primary seismic zones: shallow, intermediate, and deep. Among these, shallow earthquakes with high magnitudes were found to occur most frequently and pose significant risks to infrastructure. The *K-Means* method proved to be an effective tool in categorizing earthquake data and revealing seismic patterns in the Sulawesi region. This zonation offers valuable insights to support disaster mitigation strategies and spatial planning, contributing to better preparedness and risk reduction efforts across the region.

Keywords: earthquake zoning, Sulawesi, *K-Means*, USGS historical data, disaster mitigation

1. Pendahuluan

Indonesia merupakan salah satu negara dengan tingkat aktivitas seismik tertinggi di dunia. Hal ini disebabkan oleh posisinya yang berada di pertemuan tiga lempeng tektonik utama: Lempeng Pasifik, Indo-Australia, dan Eurasia. Kompleksitas struktur geologi Indonesia menyebabkan terbentuknya berbagai sesar aktif, termasuk *Patahan Palu-Koro* yang melintasi wilayah Sulawesi Tengah. Pulau Sulawesi dikenal sebagai salah satu wilayah yang paling rawan terhadap gempa bumi, sebagaimana tercermin dari peristiwa seismik besar yang pernah terjadi di wilayah tersebut. Salah satunya adalah gempa Palu tahun 2018 yang memicu *likuifaksi* dan *tsunami*, serta gempa Toli-Toli dan Palu pada tahun 1996 yang mengakibatkan kerusakan infrastruktur dan korban jiwa dalam jumlah besar (Nurul, Rachman, Matira, & Fadjryani, 2018).

Risiko seismik yang tinggi di Sulawesi menuntut adanya strategi mitigasi bencana yang lebih komprehensif dan berbasis data. Salah satu langkah penting dalam perencanaan pengurangan risiko bencana adalah pengembangan peta zonasi bahaya seismik. Peta zonasi ini dapat mendukung berbagai kebijakan pembangunan, seperti penerapan standar bangunan tahan gempa, perencanaan tata ruang yang adaptif, serta sistem tanggap darurat yang berbasis pada risiko spasial aktual (Bangun, Darnius, & Sutarman, 2022). Dengan zonasi yang akurat, pengambil kebijakan dapat menyusun strategi mitigasi dan adaptasi yang lebih tepat sasaran.

Dalam beberapa tahun terakhir, pendekatan berbasis data dan teknologi seperti *machine learning* menjadi sangat relevan dalam kajian kebencanaan geologi. Salah satu metode yang paling umum digunakan untuk pengelompokan data seismik adalah algoritma *K-Means Clustering*. Metode ini mampu mengidentifikasi pola spasial dalam data numerik seperti kedalaman, magnitudo, dan lokasi gempa bumi (Dwitiyanti, Kumala, & Handayani, 2024; Kusmiran *et al.*, 2022). Penelitian terdahulu menunjukkan bahwa *K-Means* cukup efektif dalam membedakan zona-zona aktivitas gempa, baik yang bersifat dalam dan berpotensi menyebabkan *tsunami*, maupun gempa dangkal dengan magnitudo tinggi yang mengancam permukiman (Nurul *et al.*, 2018). Dibandingkan algoritma lainnya seperti *K-Medoids*, *DBSCAN*, dan *Fuzzy C-Means*, *K-Means* dinilai unggul dari segi kecepatan komputasi dan kesederhanaan implementasi (Dwitiyanti *et al.*, 2024; Al Banna, Taher, Kaiser, & Mahmud, 2020).

Ketersediaan dataset historis dari *United States Geological Survey* (USGS), yang mencakup data gempa dari tahun 1974 hingga 2024, memberikan fondasi yang kuat untuk analisis spasial kejadian gempa. Dataset ini memungkinkan penerapan algoritma *K-Means* untuk mengidentifikasi pola distribusi aktivitas seismik sebagai dasar bagi zonasi bahaya gempa (Malik *et al.*, 2024). Penelitian sebelumnya juga menunjukkan keberhasilan metode ini dalam memetakan zona rawan gempa di Indonesia, termasuk di Sulawesi (Prasetyo, Effendi, & Dwi, 2023). Hal tersebut menegaskan bahwa pengolahan data spasial geofisika menggunakan pendekatan *unsupervised learning* seperti *K-Means* dapat menjadi alat bantu yang penting dalam perencanaan mitigasi bencana geologi.

Meski demikian, sejumlah studi terbaru juga mengevaluasi metode alternatif untuk klasifikasi data spasial yang memiliki variabel campuran, seperti algoritma *K-Prototypes* dan *K-Medoids*. Studi oleh Annas, Irwan, Safei, dan Rais (2022) membandingkan performa beberapa algoritma *clustering* pada dataset gempa di Sulawesi tahun 2017 hingga 2020, dan menunjukkan bahwa pemilihan metode harus disesuaikan dengan jenis data yang digunakan. Meskipun begitu,

K-Means tetap menjadi pilihan populer dalam pengolahan data geografis numerik karena efisiensinya serta kemampuannya dalam menangani volume data besar (Sharma & Nanda, 2022).

Penelitian ini memanfaatkan data historis USGS dan algoritma *K-Means Clustering* untuk mengidentifikasi daerah rawan gempa bumi di Pulau Sulawesi. Tujuan utama dari penelitian ini adalah: (1) memetakan klaster-klaster seismik sebagai dasar pembuatan peta zonasi bahaya gempa; (2) menentukan jumlah klaster yang optimal berdasarkan pola distribusi spasial gempa bumi; dan (3) menganalisis karakteristik seismik dari setiap klaster yang terbentuk. Penelitian difokuskan pada atribut geografis dan seismik, meliputi lintang, bujur, kedalaman, dan magnitudo. Hasil akhir berupa peta zonasi awal diharapkan dapat digunakan sebagai referensi oleh para peneliti, pengambil kebijakan, serta pihak terkait dalam merancang strategi mitigasi risiko gempa bumi di Sulawesi secara lebih efektif dan tepat sasaran.

2. Metode

2.1 Desain Penelitian

Penelitian ini dirancang sebagai studi kuantitatif berbasis analisis spasial dengan pendekatan *unsupervised machine learning*, yang bertujuan untuk mengidentifikasi zonasi wilayah rawan gempa di Pulau Sulawesi. Algoritma utama yang digunakan adalah *K-Means Clustering*, yaitu teknik pembelajaran tanpa pengawasan yang efektif dalam pengelompokan data numerik ke dalam beberapa klaster berdasarkan kesamaan fitur (Jain, 2010). Fokus dari studi ini adalah pada karakteristik spasial dan seismik dari kejadian gempa bumi, khususnya dengan mempertimbangkan atribut-atribut utama yaitu lokasi episentrum (*latitude* dan *longitude*), kedalaman hiposenter (*depth*), dan magnitudo (*mag*).

Pendekatan ini sangat relevan untuk wilayah seperti Sulawesi, yang berada pada zona pertemuan tiga lempeng tektonik aktif — *Eurasia*, *Indo-Australia*, dan *Pasifik* — dan memiliki kompleksitas geologi serta kepadatan sesar aktif yang tinggi (Kusmiran *et al*, 2022). Zonasi yang dihasilkan diharapkan dapat memberikan gambaran objektif mengenai wilayah dengan tingkat kerentanan seismik tinggi, yang berguna dalam perencanaan pembangunan dan mitigasi bencana.

2.2 Data dan Preprocessing: Teknik Pengumpulan dan Pengolahan Data

Dataset yang digunakan dalam penelitian ini bersumber dari katalog gempa resmi milik *United States Geological Survey* (USGS) dengan cakupan data dari tahun 1974 hingga 2024. File diunduh dalam format *.csv* dan terdiri atas atribut-atribut utama yang meliputi: *latitude* (lintang), *longitude* (bujur), *depth* (kedalaman gempa dalam km), *mag* (magnitudo), dan *time* (waktu kejadian). Data ini dipilih karena memiliki validitas tinggi, cakupan jangka panjang, serta kualitas spasial yang baik untuk dianalisis secara kuantitatif (Malik *et al*, 2024).

Langkah *preprocessing* dilakukan menggunakan pustaka *pandas* dalam lingkungan Python di Google Colab. Proses *preprocessing* meliputi:

Konversi kolom waktu (*time*) ke dalam format *datetime*

- a. Penurunan informasi tahun (*year*) dan bulan (*month*) dari objek waktu
- b. Seleksi kolom yang relevan dan penghapusan baris dengan data hilang (*null*)
- c. Penyaringan hanya untuk wilayah geografis Pulau Sulawesi

2.3 Visualisasi Eksploratif

Sebelum melakukan proses klasterisasi, dilakukan eksplorasi data visual (*Exploratory Data Analysis/EDA*) untuk mengidentifikasi pola dasar dari distribusi kejadian gempa. Tahap awal

analisis dilakukan dengan pra-pemrosesan data menggunakan bahasa pemrograman Python, seperti membaca data dari file CSV, melakukan konversi format waktu, serta mengekstrak atribut spasial dan seismik (lintang, bujur, kedalaman, dan magnitudo). Gambar 1 menampilkan potongan kode Python yang digunakan dalam proses awal ini.

```
import pandas as pd

# Ubah path sesuai dengan lokasi file Anda
file_path = '/content/drive/MyDrive/sulawesi_earthquake.csv'

# Baca file
df = pd.read_csv(file_path)
df['time'] = pd.to_datetime(df['time'], errors='coerce')
df = df[['latitude', 'longitude', 'depth', 'mag', 'time']].dropna()
df['year'] = df['time'].dt.year
df['month'] = df['time'].dt.month_name()
```

Gambar 1. Python Code - Data dan Preprocessing

Selanjutnya, visualisasi dilakukan untuk menggambarkan pola temporal dan magnitudo dari kejadian gempa. Visualisasi dilakukan terhadap:

- Jumlah kejadian gempa per tahun (*histogram*)
- Rata-rata magnitudo per tahun (*line chart*)
- Frekuensi gempa per bulan (*bar chart* musiman)
- Presentase kejadian gempa dengan magnitudo > 5.0 (*pie chart*)

Visualisasi dilakukan dengan menggunakan pustaka *matplotlib* dan *seaborn*, yang memungkinkan pembuatan grafik ilmiah yang presisi dan interaktif. Tujuan dari analisis ini adalah untuk mendeteksi tren temporal serta menganalisis kecenderungan tahunan atau musiman dari kejadian gempa, yang dapat memperkuat interpretasi zonasi spasial yang akan dibentuk.

2.4 Visualisasi Spasial

Untuk memahami distribusi spasial dari kejadian gempa di wilayah Sulawesi, digunakan teknik *heatmap* berbasis pustaka *folium*, yang merupakan alat pemetaan interaktif berbasis Leaflet dalam Python. Teknik ini berguna untuk merepresentasikan intensitas seismik secara geografis berdasarkan koordinat lintang dan bujur dari setiap titik gempa. Gambar 2 memperlihatkan potongan kode Python yang digunakan untuk membangun *heatmap* menggunakan atribut spasial dalam dataset.

```

!pip install folium

import folium
from folium.plugins import HeatMap

# Peta Interaktif
m = folium.Map(location=[-1.5, 121], zoom_start=6, tiles='CartoDB positron')
heat_data = df[['latitude', 'longitude']].values.tolist()
HeatMap(heat_data, radius=8).add_to(m)
m # Peta ditampilkan interaktif

```

Gambar 2. Code Python - Visualisasi Spasial

Visualisasi ini memungkinkan identifikasi wilayah dengan konsentrasi aktivitas seismik tinggi secara intuitif dan *real-time*, serta menjadi dasar awal dalam analisis zona bahaya. *HeatMap* ini telah digunakan luas dalam studi pemetaan seismik oleh Zhang *et al.* (2024) untuk mengidentifikasi zona aktif tektonik di wilayah rawan gempa di Asia.

2.5 Klasterisasi K-Means

Tahap utama dari penelitian ini adalah penerapan algoritma *K-Means Clustering* untuk mengelompokkan kejadian gempa ke dalam zona risiko *seismic* yang homogen. Algoritma ini bekerja dengan menginisialisasi k buah *centroid*, lalu secara iteratif menyesuaikan posisi *centroid* dan mengelompokkan setiap titik ke dalam kluster terdekat berdasarkan jarak *Euclidean* minimal. Gambar 3 memperlihatkan kode Python yang digunakan untuk mengimplementasikan proses klasterisasi menggunakan algoritma *K-Means*, mulai dari seleksi fitur hingga visualisasi hasil kluster.

```

from sklearn.cluster import KMeans

# Fitur untuk klasterisasi
X = df[['latitude', 'longitude', 'depth', 'mag']]

# Inisialisasi dan pelatihan model
kmeans = KMeans(n_clusters=4, random_state=42)
df['cluster'] = kmeans.fit_predict(X)

# Visualisasi hasil kluster
plt.figure(figsize=(10, 7))
sns.scatterplot(data=df, x='longitude', y='latitude', hue='cluster', palette='Set1')
plt.title("Hasil Klasterisasi K-Means (Zona Seismik)")
plt.xlabel("Bujur")
plt.ylabel("Lintang")
plt.legend(title='Klaster')
plt.show()

```

Gambar 3. Code Python - Klasterisasi K-Means

Fitur input yang digunakan meliputi: latitude, longitude, depth, dan mag. Nilai k ditentukan menggunakan *Elbow Method* untuk mengoptimalkan jumlah kluster berdasarkan infleksi kurva *inertia*. Dalam kasus ini, $k = 4$ dipilih karena memberikan keseimbangan antara kompleksitas dan kejelasan pemisahan kluster.

Keunggulan dari *K-Means* adalah kesederhanaannya, efisiensinya untuk dataset besar, dan kemampuannya dalam menangkap pola spasial dasar. Algoritma ini telah terbukti lebih unggul dibandingkan *K-Medoids* atau *Fuzzy C-Means* dalam beberapa studi zonasi seismik di Indonesia (Annas et al., 2022; Dwitiyanti et al., 2024).

3. Hasil dan Pembahasan

Hasil penelitian ini menunjukkan bahwa penerapan metode *unsupervised learning* berupa algoritma *K-Means Clustering* terhadap data historis gempa dari USGS berhasil mengidentifikasi pola spasial dan temporal aktivitas seismik di wilayah Sulawesi secara signifikan. Analisis ini tidak hanya mengelompokkan karakteristik gempa berdasarkan kedalaman dan magnitudo, tetapi juga mengungkapkan kecenderungan waktu dan wilayah yang paling rentan terhadap aktivitas seismik.

Visualisasi dalam bentuk grafik dan peta telah digunakan untuk merepresentasikan dinamika gempa secara komprehensif. Secara temporal, data dianalisis berdasarkan tahun dan musim untuk melihat kecenderungan frekuensi dan kekuatan gempa dari waktu ke waktu. Secara spasial, persebaran gempa divisualisasikan menggunakan *heatmap* dan pemetaan kluster untuk mengidentifikasi zona bahaya dengan resolusi yang lebih tinggi. Hasil visual ini memperkuat pentingnya pemetaan risiko berbasis data historis dalam upaya mitigasi bencana dan perencanaan tata ruang yang adaptif terhadap bahaya seismik di Sulawesi.

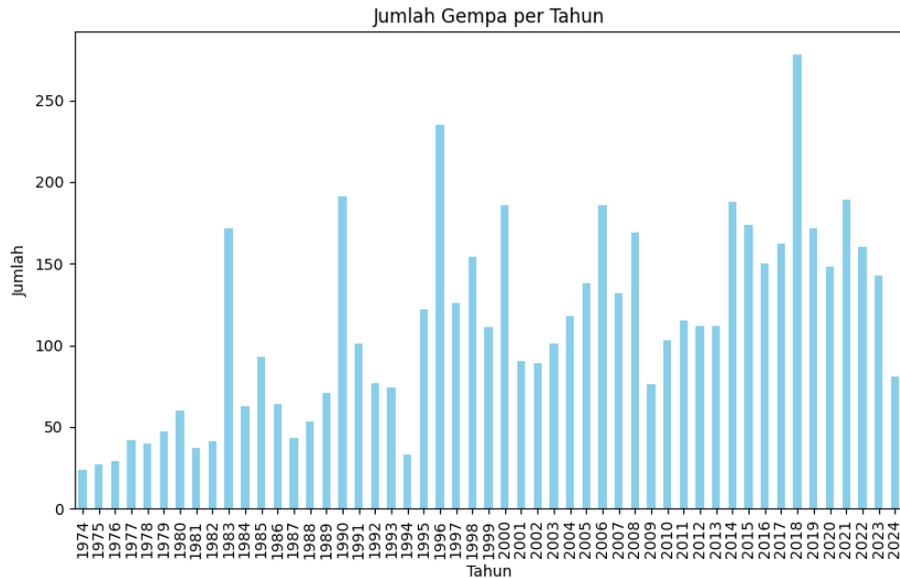
3.1 Visualisasi TEM (Temporal Earthquake Metrics)

Visualisasi *Temporal Earthquake Metrics* (TEM) memberikan wawasan penting mengenai karakteristik temporal kejadian gempa bumi di wilayah Sulawesi selama 50 tahun terakhir (1974–2024). Empat visualisasi berikut disusun untuk menganalisis dimensi waktu tahunan dan musiman serta distribusi magnitudo gempa. Gambar 4 hingga Gambar 7 menyajikan hasil visualisasi yang digunakan untuk mendukung proses analisis.

a. Jumlah Gempa per Tahun

Visualisasi pertama dalam bentuk *bar chart* menggambarkan jumlah kejadian gempa per tahun selama lima dekade. Gambar 4 menunjukkan tren yang fluktuatif, dengan beberapa lonjakan signifikan, terutama pada tahun 1994 dan 2018. Peningkatan frekuensi kejadian sejak awal tahun 2000-an diduga berkorelasi dengan kemajuan sistem monitoring global

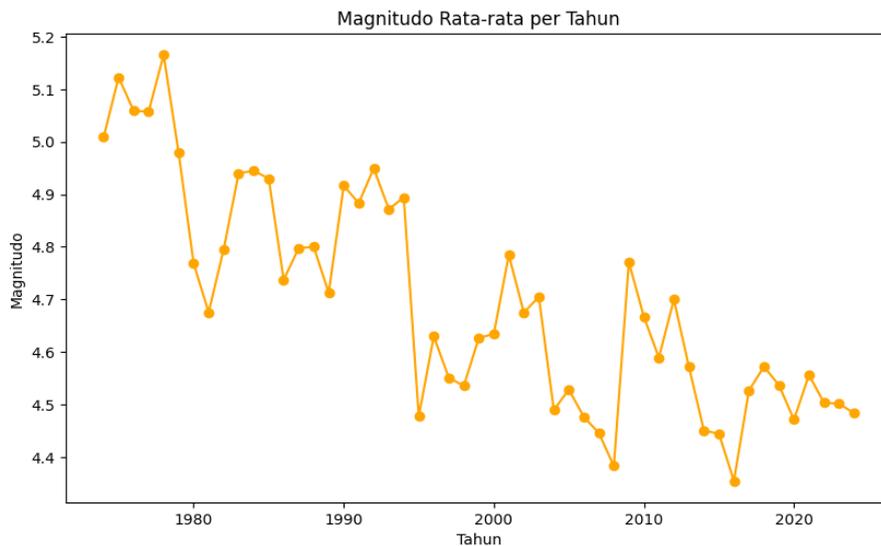
seperti milik USGS, yang meningkatkan sensitivitas dan deteksi gempa berskala kecil hingga menengah (Malik *et al*, 2024).



Gambar 4. Bar Chart - Jumlah Gempa per Tahun

b. Magnitudo Rata-rata per Tahun

Selanjutnya, Gambar 5 menampilkan *line chart* yang menggambarkan tren perubahan magnitudo rata-rata tahunan. Data menunjukkan bahwa rata-rata magnitudo mengalami penurunan dari kisaran 5.0–5.2 pada 1980-an menjadi sekitar 4.4–4.6 pada dekade 2020-an. Penurunan ini diperkirakan berkaitan dengan meningkatnya jumlah gempa kecil akibat pelepasan energi tektonik skala mikro yang dikenal sebagai fenomena *microseismic swarm* (Zhang *et al*, 2024).

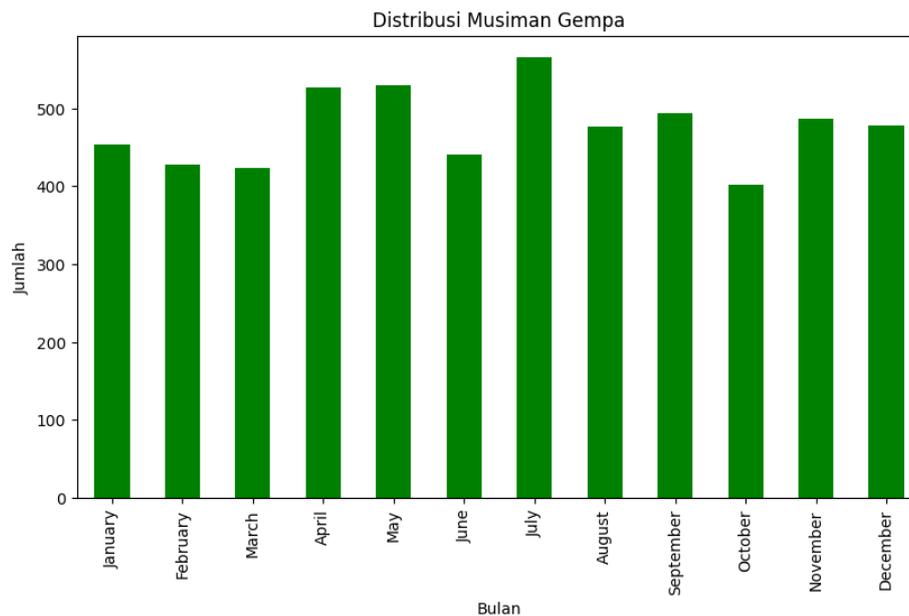


Gambar 5. Line Chart - Magnitudo Rata-rata per Tahun

c. Distribusi Musiman

Visualisasi musiman pada Gambar 6 memperlihatkan *bar chart* berdasarkan total kejadian gempa per bulan. Bulan Juli, Mei, dan April tercatat sebagai bulan dengan jumlah kejadian gempa tertinggi. Temuan ini membuka kemungkinan adanya hubungan antara aktivitas

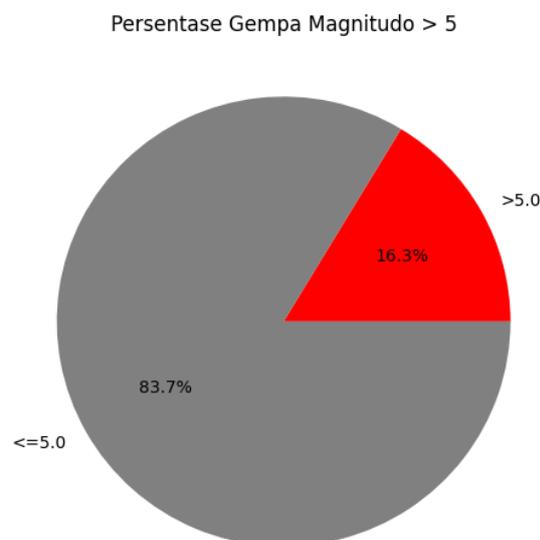
tektonik dan pola musiman, yang mungkin dipengaruhi oleh faktor eksternal seperti fluktuasi tekanan air pori akibat kekeringan atau curah hujan musiman (Putri, 2024).



Gambar 6. Bar Chart - Distribusi Musiman Gempa

d. Presentasi Gempa Magnitudo > 5.0

Analisis terakhir menyajikan proporsi kejadian gempa dengan magnitudo lebih dari 5.0 SR. Berdasarkan data, sekitar 16,3% dari total gempa yang tercatat berada dalam kategori ini. Walaupun proporsinya kecil dibandingkan gempa skala ringan, gempa dengan magnitudo sedang hingga besar ini cenderung memiliki dampak signifikan, khususnya jika terjadi di kedalaman dangkal dan dekat kawasan padat penduduk. Gambar 7 menyajikan *pie chart* yang memvisualisasikan distribusi ini secara proporsional. Persentase tersebut konsisten dengan karakteristik wilayah seismik aktif seperti Sulawesi (Anggarajati, Yatini, & Raharjo, 2024).



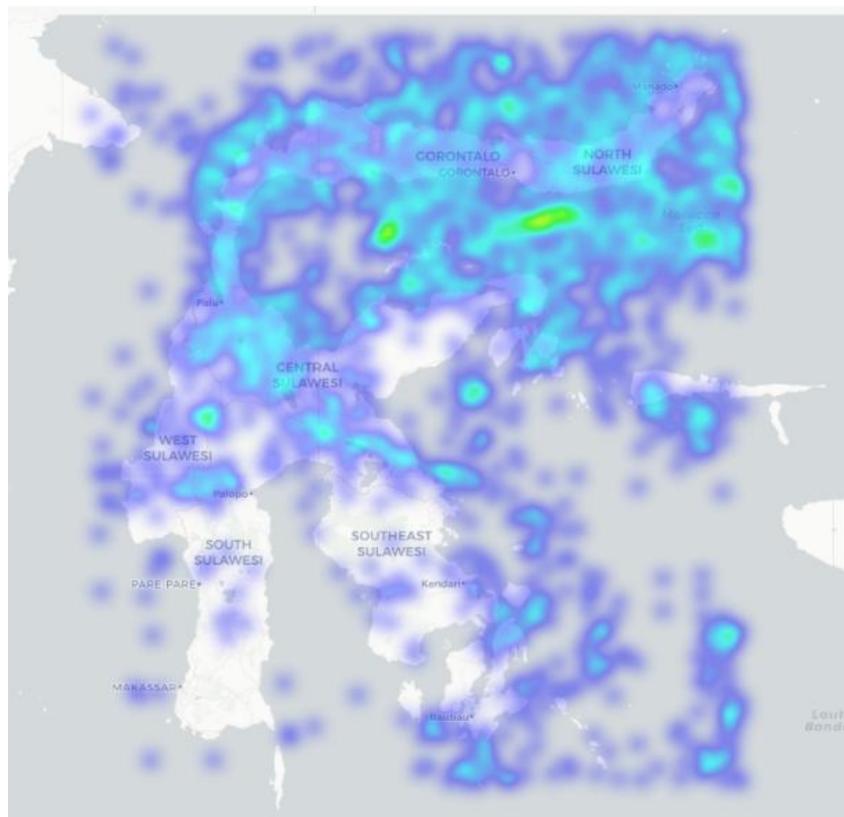
Gambar 7. Pie Chart - Presentasi Gempa Magnitudo > 5.0

3.2 Analisis Heatmap Intensitas Seismik Regional – Sulawesi

Visualisasi *heatmap* pada Gambar 8 memperlihatkan persebaran spasial intensitas seismik di wilayah Sulawesi berdasarkan kejadian gempa selama periode 1974–2024. Hasil visualisasi ini menunjukkan bahwa zona dengan intensitas seismik tinggi teridentifikasi di wilayah barat laut Manado yang berasosiasi dengan zona subduksi Laut Maluku, di bagian utara Teluk Tomini yang kemungkinan besar berkaitan dengan struktur sesar lepas pantai, serta di sepanjang wilayah Palu yang dilintasi oleh *Sesar Palu-Koro*. Ketiga wilayah ini memperlihatkan konsentrasi energi seismik yang tinggi, sehingga perlu menjadi perhatian utama dalam strategi mitigasi bencana.

Sementara itu, wilayah dengan intensitas seismik sedang tersebar cukup merata di sebagian besar wilayah Sulawesi Barat dan Sulawesi Tenggara. Persebaran ini menunjukkan karakter seismik menengah yang konsisten dalam jumlah, tetapi cenderung lebih terdistribusi secara luas tanpa dominasi episentrum tertentu.

Adapun zona dengan intensitas rendah sebagian besar terletak di wilayah selatan dan pesisir, termasuk daerah seperti Makassar, Pare-Pare, dan Pulau Buton. Meskipun zona ini menunjukkan



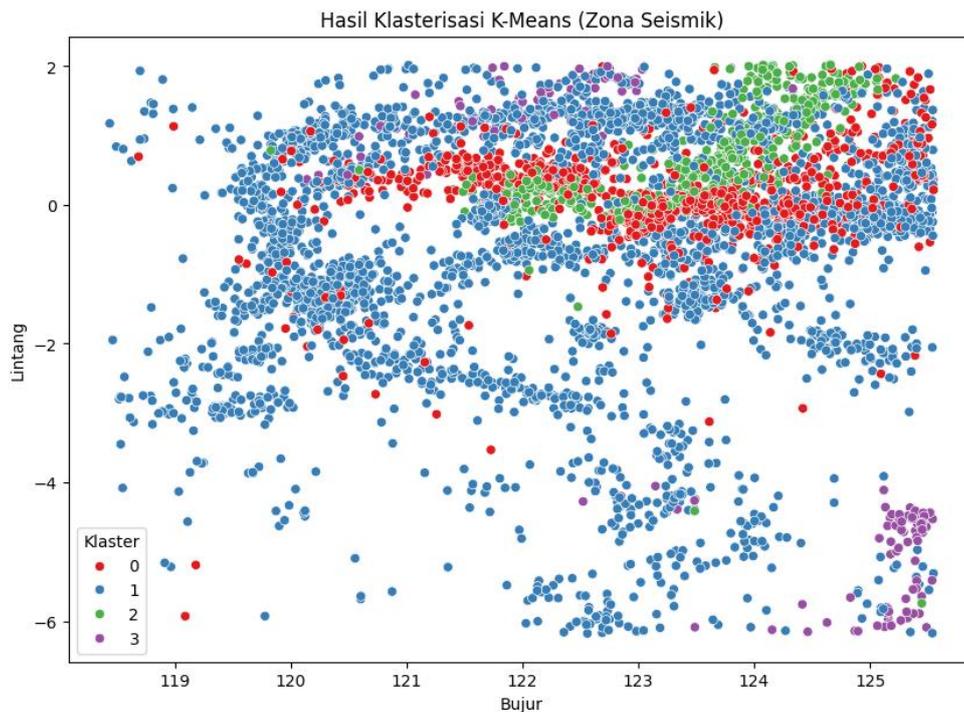
Gambar 8. Heatmap Sulawesi

kepadatan gempa yang lebih rendah, daerah-daerah tersebut tetap memiliki kerentanan terhadap gempa berkekuatan sedang hingga besar, terutama jika berada di dekat garis pantai atau zona batas administratif yang padat penduduk.

Informasi yang dihasilkan dari *heatmap* ini memiliki nilai strategis dalam pengembangan rencana mitigasi bencana, terutama dalam menyusun kebijakan tata ruang yang memperhitungkan zona-zona seismik aktif di pesisir maupun batas wilayah administratif. Data ini dapat menjadi acuan awal dalam penentuan prioritas penguatan infrastruktur dan sistem peringatan dini di Sulawesi.

3.3 Analisis Klasterisasi K-Means: Segmentasi Zona Seismik

Proses klasterisasi menggunakan algoritma *K-Means* menghasilkan segmentasi zona gempa berdasarkan atribut kedalaman dan magnitudo. Gambar 9 menyajikan visualisasi spasial dari hasil klasterisasi yang membagi data menjadi empat kelompok berbeda. Setiap warna dalam visualisasi tersebut merepresentasikan satu klaster yang memiliki pola sebaran dan karakteristik seismik yang khas. Untuk memperjelas perbedaan antar klaster, Tabel 1 merangkum nilai rata-rata kedalaman, magnitudo, dan deskripsi umum dari masing-masing kelompok yang terbentuk.



Gambar 9. Visualisasi Spasial Hasil Klasterisasi K-Means terhadap Data Gempa di Sulawesi

Table 1. Ringkasan Statistik K-Means

Klaster	Rata-rata Kedalaman (km)	Rata-rata Magnitudo	Deskripsi
0	125.63	4.62	Gempa dalam, magnitudo moderat
1	36.56	4.65	Gempa dangkal, kejadian terbanyak (3631 kejadian)
2	230.51	4.51	Gempa sangat dalam, lebih tersebar dan jarang
3	501.68	4.58	Gempa ultra-dalam, jumlah sangat sedikit (153 kejadian)

Hasil klasterisasi menunjukkan bahwa Klaster 1 (ditandai dengan warna biru) merupakan kelompok gempa bumi yang paling sering terjadi. Gempa pada klaster ini didominasi oleh kejadian dengan kedalaman dangkal dan magnitudo sedang, serta terkonsentrasi di wilayah-wilayah padat penduduk seperti Kota Gorontalo dan Palu. Kepadatan tinggi pada klaster ini mengindikasikan tingginya potensi dampak terhadap infrastruktur dan masyarakat.

Sementara itu, Klaster 0 (warna merah) mencakup kejadian gempa dengan kedalaman menengah. Sebaran gempa pada klaster ini umumnya terjadi di sekitar sesar aktif, khususnya di sepanjang Sesar Palu-Koro yang merupakan salah satu sesar paling aktif di Sulawesi. Klaster ini menunjukkan pola linear yang konsisten dengan arah sesar utama.

Untuk Klaster 2 dan Klaster 3, yang divisualisasikan dengan warna hijau dan ungu, pola seismik yang terbentuk menunjukkan gempa-gempa dengan kedalaman sangat dalam. Gempa pada klaster ini berlokasi lebih jauh dari daratan utama dan mayoritas terjadi di zona subduksi laut dalam. Kedua klaster ini jarang terjadi namun berpotensi besar menghasilkan gempa berkekuatan tinggi jika aktivitasnya berpindah ke kedalaman lebih dangkal.

Secara keseluruhan, segmentasi klaster yang dihasilkan mampu merepresentasikan karakteristik spasial dan kedalaman gempa secara lebih objektif. Integrasi antara hasil klasterisasi dan zonasi intensitas spasial akan sangat bermanfaat dalam mendukung penyusunan kebijakan mitigasi bencana dan perencanaan tata ruang berbasis risiko di wilayah Sulawesi.

4. Kesimpulan

Penelitian ini menunjukkan bahwa algoritma *K-Means Clustering* efektif dalam memetakan zona rawan gempa bumi di Sulawesi berdasarkan data historis dari USGS yang mencakup periode 1974-2024. Dengan menganalisis parameter spasial dan seismik—termasuk lintang, bujur, kedalaman, dan magnitudo—empat kelompok gempa bumi yang berbeda berhasil diidentifikasi. Gempa bumi dangkal dengan magnitudo tinggi ditemukan mendominasi wilayah tengah Sulawesi, khususnya di sekitar Sesar Palu-Koro, sebuah zona seismik aktif dengan potensi kerusakan yang signifikan.

Temuan ini menegaskan bahwa pendekatan pembelajaran tanpa pengawasan dapat menghasilkan peta risiko seismik yang objektif dan berbasis data, yang sangat berguna untuk perencanaan pembangunan, manajemen penggunaan lahan, serta kebijakan mitigasi bencana di tingkat lokal dan regional. Walaupun model saat ini belum memasukkan faktor geologi dan sosio-ekonomi secara menyeluruh, studi ini tetap memberikan fondasi kuat untuk pengembangan sistem pemetaan risiko seismik yang lebih komprehensif di masa depan.

Daftar Pustaka

- Annas, S., Irwan, I., Safei, R., & Rais, Z. (2022). K-Prototypes algorithm for clustering the tectonic earthquake in Sulawesi Island. *Jurnal Varian*, 6(2), 123–130. <https://doi.org/10.30812/varian.v5i2.1908>
- Anggarajati, B., Yatini, Y., & Raharjo, W. (2024). Application of *K*-means clustering and *B*-value algorithms for analysis of earthquake-dangerous zones in Java Island. *International Journal of Advances in Applied Sciences*, 12(4), 300–310. <https://doi.org/10.11591/ijaas.v13.i4.pp907-915>
- Bangun, M. N., Darnius, O., & Sutarman, S. (2022). Optimization model in clustering the hazard zone after an earthquake disaster. *Sinkron*, 7(2), 1–8. <https://doi.org/10.33395/sinkron.v7i3.11598>
- Dwitiyanti, N., Kumala, S. A., & Handayani, S. D. (2024). Comparative study of earthquake clustering in Indonesia using K-Medoids, K-Means, DBSCAN, Fuzzy C-Means and K-AP

- algorithms. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 8(4), 1–10. <https://doi.org/10.29207/resti.v8i6.5514>
- Jihad Nurul, Rachman, R., Matira, Y., & Fadryani, J. (2018). Web application of classification of potential earthquake region in Central Sulawesi. In *Proceedings of the 3rd International Conference on Information Technology, Information System and Electrical Engineering (ICITISEE)*. https://doi.org/10.2991/978-94-6463-228-6_35
- Kusmiran, A., Minarti, M., Massinai, M. F. I., Zarkasi, A., Maharani, A., & Desiani, R. (2022). Klasifikasi kedalaman kejadian gempa menggunakan algoritma K-Means clustering: Studi kasus kejadian gempa di Sulawesi. *JFT: Jurnal Fisika dan Terapannya*, 8(2), 45–54. <https://doi.org/10.24252/jft.v9i2.29198>
- Malik, D., Made, I., Agastya, A., Yustiantoro, A., Anjaya, A., & Hartantyo, S. (2024). Earthquake distribution mapping in Indonesia using K-Means clustering algorithm. In *Proceedings of the 8th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*. <https://doi.org/10.1109/ICITISEE63424.2024.10730706>
- Prasetio, A., Effendi, M., & Dwi M, M. (2023). Analisis gempa bumi di Indonesia dengan metode clustering. *Bulletin of Information Technology (BIT)*, 7(3), 200–210. <https://doi.org/10.47065/bit.v4i3.820>
- Putri, S. A. (2024). Pengelompokan daerah rawan bencana di Indonesia menggunakan metode clustering K-Means. *Jupiter: Publikasi Ilmu Keteknikan Industri, Teknik Elektro dan Informatika*, 6(2), 100–110. <https://doi.org/10.61132/jupiter.v3i1.644>
- Ramadhani Senduk, F. (2019). Clustering of earthquake prone areas in Indonesia using K-Medoids algorithm. *INDOJC: Indonesian Journal of Computing*, 4(3), 359–366. <https://doi.org/10.34818/INDOJC.2019.4.3.359>
- Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651–666. <https://doi.org/10.1016/j.patrec.2009.09.011>
- Jena, R., Pradhan, B., Beydoun, G., & Alamri, A. M. (2020). Earthquake hazard and risk assessment using machine learning approaches at Palu, Indonesia. *Science of the Total Environment*, 730, 139068. <https://doi.org/10.1016/j.scitotenv.2020.139068>
- Pwavodi, J., Ibrahim, A. U., & Pwavodi, P. C. (2024). The role of artificial intelligence and IoT in prediction of earthquakes. *Artificial Intelligence in Geosciences*, 5, 100046. <https://www.sciencedirect.com/science/article/pii/S2666544124000169>
- Sharma, A., & Nanda, S. J. (2022). A multi-objective chimp optimization algorithm for seismicity de-clustering. *Applied Soft Computing*, 122, 108881. <https://www.sciencedirect.com/science/article/pii/S1568494622001855>
- Choi, E., & Song, J. (2022). Clustering-based disaster resilience assessment of South Korea communities building portfolios using open GIS and census data. *International Journal of Disaster Risk Reduction*, 73, 102899. <https://doi.org/10.1016/j.ijdr.2022.102899>
- Ridzwan, N. S. M., & Yusoff, S. H. M. (2023). Machine learning for earthquake prediction: A review (2017–2021). *Earth Science Informatics*, 16, 225–243. <https://doi.org/10.1007/s12145-023-00991-z>
- Al Banna, M. H., Taher, K. A., Kaiser, M. S., & Mahmud, M. (2020). Application of artificial intelligence in predicting earthquakes: state-of-the-art and future challenges. *IEEE Access*, 8, 129406–129420. <https://ieeexplore.ieee.org/document/9218936>

Zhang, L., Qu, W., Huang, R., Ye, Z., & Tong, X. (2024). A rational delineation method for active land blocks on the southeastern margin of the Tibetan Plateau based on high-precision GNSS horizontal velocity data. *International Journal of Applied Earth Observation and Geoinformation*, 130, 103487. <https://doi.org/10.1016/j.jag.2024.104024>