



## Analisis Pola dan Peramalan Aktivitas Gempa di Provinsi Bengkulu Menggunakan *K-Means Clustering* dan Rantai Markov

Yahanna She Dasti<sup>1</sup>, Jose Rizal<sup>2\*</sup>, Siska Yosmar<sup>3</sup>, Mulia Astuti<sup>4</sup>, dan Septri Damayanti<sup>5</sup>

<sup>1,3,4,5</sup>Program Studi Matematika, Universitas Bengkulu

<sup>2</sup>Program Studi Statistika, Universitas Bengkulu

\*Correspondence: [jrizal04@unib.ac.id](mailto:jrizal04@unib.ac.id)

### ABSTRAK

Penelitian ini mengintegrasikan *K-Means Clustering* dengan validasi *Silhouette Coefficient* ke dalam model Rantai Markov untuk memprediksi pola aktivitas gempa di Provinsi Bengkulu, yang belum diterapkan di wilayah ini. Data gempa yang diperoleh dari USGS terdiri atas berbagai skala magnitudo sehingga dikonversi ke skala magnitudo momen (Mw) untuk memperoleh ukuran yang lebih konsisten. Data selanjutnya melalui proses *declustering* untuk memisahkan gempa utama dari gempa pendahuluan dan susulan, kemudian dikelompokkan berdasarkan magnitudo, kedalaman, dan waktu kejadian. Hasil analisis menunjukkan bahwa pola aktivitas gempa di Provinsi Bengkulu didominasi oleh kejadian gempa bermagnitudo sedang, kedalaman dangkal, serta kecenderungan peningkatan aktivitas pada pertengahan tahun. Temuan ini memperjelas karakteristik spasial dan temporal gempa gempa serta mendukung pengambilan Keputusan dalam perencanaan mitigasi risiko bencana berbasis data di Provinsi Bengkulu.

© 2026 Kantor Jurnal dan Publikasi UPI

### INFORMASI ARTIKEL

#### Sejarah Artikel:

Diterima 11 Maret 2026

Direvisi 23 April 2026

Disetujui 13 Mei 2026

Tersedia online 15 Mei 2026

Dipublikasikan 15 Mei 2026

#### Kata Kunci:

Gempa bumi,  
*K-Means Clustering*,  
Pola Seismik,  
Provinsi Bengkulu,  
Rantai Markov.

### ABSTRACT

This study integrates *K-Means Clustering* with *Silhouette Coefficient* validation into a Markov Chain model to predict earthquake activity patterns in Bengkulu Province, which has not been applied in this region. Seismic data obtained from the United States Geological Survey (USGS) consist of various magnitude scales and were therefore converted to the moment magnitude scale (Mw) to obtain more consistent measurements. The data were then processed through *declustering* to separate mainshocks from foreshocks and aftershocks, and subsequently grouped based on magnitude, depth, and time of occurrence. The analysis results indicate that earthquake activity patterns in Bengkulu Province are dominated by moderate-magnitude events, shallow depths, and a tendency for increased activity during mid-year. These findings clarify the spatial and temporal characteristics of earthquakes and support data-driven decision-making in disaster risk mitigation planning in Bengkulu Province.

© 2026 Kantor Jurnal dan Publikasi UPI

#### Keywords:

Bengkulu Province,  
Earthquake,  
*K-Means Clustering*,  
Markov Chain,  
Seismic Pattern.

## 1. PENDAHULUAN

Secara geografis, Indonesia terletak pada pertemuan tiga lempeng tektonik besar dunia yang aktif bergerak, yaitu Lempeng Indo-Australia, Eurasia, dan Pasifik. Kondisi tersebut menyebabkan Indonesia menjadi salah satu wilayah dengan tingkat aktivitas seismik tertinggi di dunia (Putra *et al.*, 2012). Berdasarkan data Kementerian Energi dan Sumber Daya Mineral (ESDM), terdapat 25 wilayah rawan gempa di Indonesia, dan enam diantaranya berada di Pulau Sumatra, yaitu Sumatra Utara, Sumatra Barat, Aceh, Jambi, Lampung dan Bengkulu (Rahmi, Muliawati, & Harbowo, 2024).

Provinsi Bengkulu merupakan salah satu wilayah dengan aktivitas sesismik yang tinggi di antara keenam wilayah tersebut. Secara geografis, Bengkulu terletak di sepanjang pantai barat Sumatra dan berada pada zona subduksi pertemuan antara Lempeng Indo-Australia dan Lempeng Eurasia. Selain itu, wilayah ini juga dilalui oleh jalur Sesar Sumatra sebagai salah satu struktur geologi aktif di Sumatra (Hadi & Brotopuspito, 2016). Kondisi tektonik tersebut menjadikan analisis pola aktivitas seismik di Bengkulu penting dilakukan guna mendukung upaya mitigasi dan perencanaan kebencanaan di masa mendatang.

Berbagai penelitian terdahulu telah mengkaji pola aktivitas seismik di Pulau Sumatra diantaranya Rahmi, Muliawati, dan Harbowo (2024) yang menerapkan metode *K-Means Clustering* dan Rantai Markov untuk analisis serta prediksi pola gempa. Namun, penelitian tersebut belum secara spesifik difokuskan pada wilayah Bengkulu dan masih menggunakan metode Elbow dalam penentuan jumlah kluster tanpa mempertimbangkan stabilitas hasil klusterisasi. Selain itu, analisis distribusi keseimbangan (*steady-state distribution*) pada model Rantai Markov, yang berperan penting dalam mengidentifikasi kecenderungan sistem menuju kondisi konvergen jangka panjang, belum dilakukan.

Penelitian ini bertujuan mengisi kesenjangan tersebut dengan menerapkan kombinasi metode *K-Means Clustering* dan Rantai Markov pada data gempa bumi di Provinsi Bengkulu. Penentuan jumlah kluster optimal dilakukan menggunakan validasi *Silhouette Coefficient* untuk memperoleh hasil klusterisasi yang lebih stabil. Hasil klusterisasi selanjutnya digunakan sebagai ruang keadaan (*state space*) dalam model Rantai Markov guna menggambarkan distribusi keseimbangan dan meningkatkan keandalan prediksi probabilistik aktivitas seismik jangka panjang di Provinsi Bengkulu.

## 2. METODE

Penelitian ini terdiri dari lima tahapan penelitian. Tahap pertama adalah pengumpulan data gempa dari situs resmi *United States Geological Survey (USGS)*, yang mencakup magnitudo, kedalaman, dan waktu kejadian pada periode 1 Januari 2018 hingga 31 Desember 2024 sebanyak 71 kejadian gempa.

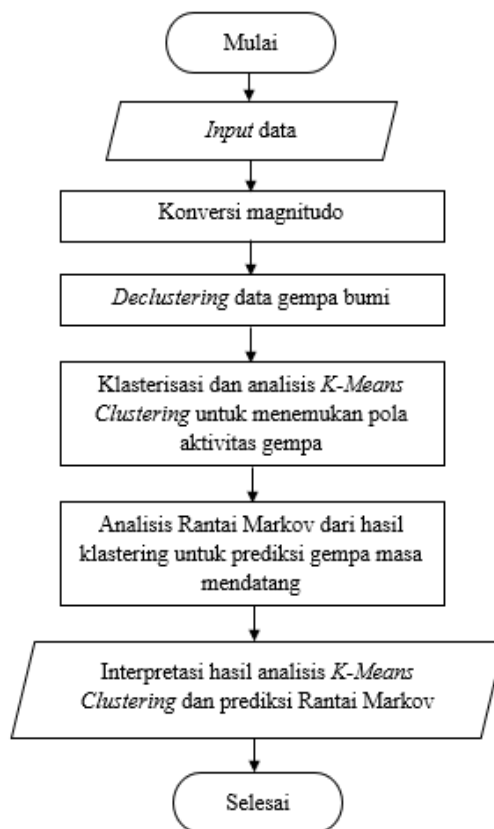
Tahap kedua merupakan praproses data sebelum dianalisis, yang meliputi penyeragaman skala magnitudo serta proses *declustering*. Data magnitudo yang diperoleh dari USGS terdiri atas skala mb (*body-wave magnitude*) dan Mw (*moment magnitude*). Untuk menjaga konsistensi analisis, seluruh magnitudo dikonversi ke skala Mw. Konversi ini dilakukan karena skala mb dihitung berdasarkan amplitudo gelombang badan dan cenderung mengalami saturasi pada gempa besar, sedangkan skala Mw merepresentasikan momen seismik sehingga lebih stabil dan lebih sesuai untuk analisis statistik serta pemodelan probabilistik jangka Panjang. Proses *declustering* dilakukan menggunakan perangkat lunak ZMAP, yaitu *toolbox* analisis statistik kegempaan berbasis MATLAB, untuk

memisahkan *mainshock* dari *foreshock* dan *aftershock* sehingga diperoleh kejadian gempa yang relative independen.

Tahap ketiga adalah pengelompokan data menggunakan *K-Means Clustering* berdasarkan variabel magnitudo, kedalaman dan waktu kejadian. Jumlah kluster optimal ditentukan menggunakan validasi *Silhouette Coefficient*.

Tahap keempat adalah pemodelan menggunakan Rantai Markov, di mana hasil klusterisasi digunakan sebagai ruang keadaan (*state space*) untuk menghitung probabilitas transisi antar keadaan serta menentukan distribusi keseimbangan.

Tahap kelima adalah interpretasi hasil analisis pola seismik untuk mengidentifikasi kecenderungan aktivitas gempa jangka panjang di Provinsi Bengkulu. Diagram alir keseluruhan proses ditampilkan pada Gambar 1 untuk memperjelas hubungan antar kelima tahapan, mulai dari praproses data, klusterisasi, hingga pemodelan probabilistik menggunakan Rantai Markov.



Gambar 1. Diagram Alir Penelitian

## 2.1 Validasi *Silhouette Coefficient*

*Silhouette Coefficient* merupakan metode yang digunakan untuk mengevaluasi hasil pengelompokan dengan mengukur seberapa baik kelompok-kelompok (kluster) yang terbentuk (Wulandari, Irmayansyah, & Ningrum, 2025). Validasi *Silhouette Coefficient* bertujuan untuk memperoleh partisi kluster yang paling sesuai dengan karakteristik data, yaitu dengan mencari nilai maksimum dari nilai *Silhouette Index* pada variasi jumlah kluster mulai dari  $k = 2$  hingga  $k = n - 1$  (Nahdliyah, Widiharih, & Prahutama, 2019).

Nilai rata-rata *Silhouette Coefficient* dihitung menggunakan persamaan (1):

$$SC = \frac{1}{n} \sum_{i=1}^n S(i), \quad (1)$$

dengan  $SC$  adalah nilai rata-rata *Silhouette Coefficient* dari seluruh data, dan  $S(i)$  adalah nilai *Silhouette* untuk data ke- $i$  (Dewi & Pramita, 2019).

Nilai  $S(i)$  dihitung menggunakan Persamaan (2):

$$S(i) = \frac{b_i - a_i}{\max\{a_i, b_i\}}, \quad (2)$$

nilai  $S(i)$  dari sebuah data ke- $i$  diperoleh dengan melibatkan 2 komponen yaitu  $a_i$  dan  $b_i$ , di mana nilai  $a_i$  adalah rata-rata jarak ke- $i$  terhadap semua data lainnya dalam satu kluster, sedangkan  $b_i$  didapatkan dengan menghitung rata-rata jarak data ke- $i$  terhadap semua data dari kluster lainnya yang tidak satu kluster dengan data ke- $i$ , lalu diambil yang terkecil. Nilai  $a_i$  dihitung menggunakan Persamaan (3):

$$a_i = \frac{1}{m_j - 1} \sum_{r=1, r \neq i}^{m_j} d(x_i, x_r), \quad (3)$$

dengan  $m_j$  adalah jumlah data dalam kluster ke- $j$ ,  $k$  adalah jumlah total kluster,  $j$  yang menyatakan indeks kluster ( $j = 1, 2, 3, \dots, k$ ) yang memuat data ke- $i$ , dan  $d(x_i, x_r)$  adalah jarak data ke- $i$  dan data ke- $r$  dalam kluster yang sama. Selanjutnya nilai  $b_i$  dihitung menggunakan Persamaan (4):

$$b_i = \min_{n=1, n \neq j}^k \left\{ \frac{1}{m_n} \sum_{r=1}^{m_n} d(x_i, x_r) \right\}, \quad (4)$$

dengan  $m_n$  adalah jumlah data dalam kluster ke- $n$ . *Silhouette Coefficient* memiliki rentang nilai antara -1 hingga 1. Kualitas kluster dianggap semakin baik apabila nilai dari rata-rata *Silhouette Coefficient* mendekati 1, sedangkan kluster yang buruk ditunjukkan oleh nilai rata-rata yang mendekati -1 (Fransiska, Anggraeni, & Enri, 2023). Kriteria penilaian *Silhouette coefficient* dapat dilihat pada Tabel 1.

**Tabel 1.** Kriteria Pengukuran *Silhouette Coefficient*

Nilai <i>Silhouette Coefficient</i>	Kriteria
$0.7 < Silhouette \leq 1.0$	Struktur kuat
$0.5 < Silhouette \leq 0.7$	Struktur baik
$0.25 < Silhouette \leq 0.5$	Struktur lemah
$Silhouette \leq 0.25$	Struktur buruk

## 2.2 K-Means Clustering

Metode *K-Means Clustering* merupakan salah satu teknik pengelompokan data yang paling banyak digunakan dalam analisis data (Hendrastuty, 2024). Algoritma ini bekerja dengan membagi data ke dalam  $k$  kluster yang telah ditentukan sebelumnya, di mana setiap titik data diklasifikasikan berdasarkan kedekatannya dengan titik pusat kelompok

(*centroid*). Proses pengelompokkan menggunakan algoritma *K-Means Clustering* dilakukan melalui tahapan berikut (Kurniadi et al., 2023).

1. Menentukan jumlah  $k$  kluster dengan validasi *Silhouette Coefficient* menggunakan Persamaan (1).
2. Menentukan *centroid* awal secara acak.
3. Setiap data dikelompokkan ke dalam  $k$  kluster yang memiliki *centroid* yang memiliki jarak minimum terhadap data tersebut. Jarak antar data dan *centroid* dihitung menggunakan jarak *Euclidean* sebagaimana dirumuskan pada Persamaan (5)

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad (5)$$

dengan  $d(x, y)$  merupakan jarak antara data  $x$  dan *centroid*  $y$ ,  $x$  merupakan data,  $y$  merupakan *centroid*, dan  $n$  merupakan jumlah variabel.

4. Hitung ulang *centroid* setiap kluster dengan mengambil rata-rata dari data yang menjadi anggota pada kluster tersebut, menggunakan Persamaan (6)

$$y_k = \frac{1}{n_k} \sum_{t=1}^{n_k} x_t, \quad (6)$$

dengan  $y_k$  merupakan *centroid* dari kluster ke- $k$ ,  $n_k$  merupakan jumlah data dalam kluster ke- $k$ , dan  $x_t$  merupakan data ke- $t$  dalam kluster ke- $k$ .

5. Lakukan kembali langkah 3-4 hingga tidak ada lagi data yang berpindah ke kluster yang lain.
6. Proses dihentikan apabila tidak terjadi perubahan posisi *centroid* atau ketika jumlah iterasi maksimum telah tercapai.

### 2.3 Rantai Markov

Proses Markov adalah sifat “memori pendek”, di mana probabilitas transisi ke keadaan berikutnya hanya bergantung pada keadaan saat ini, bukan pada urutan kejadian sebelumnya. Langkah awal dalam membangun model adalah dengan menentukan himpunan semua keadaan yang mungkin terjadi dalam sistem. Proses stokastik waktu diskrit disebut Rantai Markov, apabila peluang perpindahan dari keadaan  $i$  ke keadaan  $j$  ( $P_{ij}$ ) memenuhi Persamaan (7) (Mustakim et al., 2018)

$$P\{X_{t+1} = j | X_0 = i_0, X_1 = i_1, \dots, X_t = i\} = P\{X_{t+1} = j | X_t = i\} = P_{ij}. \quad (7)$$

Sifat Markovian menyatakan bahwa peluang bersyarat dari kejadian masa depan ( $X_{t+1}$ ) bersifat independen terhadap kejadian-kejadian di masa lalu dan hanya bergantung pada keadaan saat ini ( $X_t$ ) (Rahmi, Muliawati, & Harbowo, 2024). Notasi  $P_{ij}$  digunakan untuk menyatakan probabilitas transisi. Nilai probabilitas transisi diperoleh dengan membagi frekuensi transisi ( $n_{ij}$ ) perpindahan dari keadaan  $i$  ke keadaan  $j$  dengan total seluruh perpindahan dari keadaan  $i$  (Nurhamiddin & Sulisa, 2019). Perhitungan probabilitas transisi dapat dilihat pada Persamaan (8)

$$P_{ij} = \frac{n_{ij}}{\sum_{j=1}^m n_{ij}}. \quad (8)$$

Ruang keadaan, diagram transisi, dan matriks probabilitas transisi merupakan konsep penting dalam model Rantai Markov. Matriks probabilitas transisi  $P$  berbentuk persegi berukuran  $(m \times m)$ , di mana  $m$  merupakan jumlah total keadaan atau kluster hasil dari proses *K-Means Clustering*. Matriks probabilitas transisi dapat ditulis sebagai berikut:

$$P = \begin{bmatrix} P_{00} & P_{01} & \cdots & P_{0j} & P_{10} & P_{11} & \cdots & P_{1j} & \vdots & P_{i0} & \vdots & P_{i1} & \ddots & \cdots & \vdots & P_{ij} \end{bmatrix}$$

dengan  $P_{ij}$  menyatakan probabilitas transisi dari keadaan ke- $i$  menuju keadaan ke- $j$  (Rahmi, Muliawati, & Harbowo, 2024).

Probabilitas transisi yang telah diperoleh sebelumnya digunakan untuk perhitungan distribusi keseimbangan yaitu kondisi jangka panjang di mana probabilitas dari keadaan-keadaan sistem tidak berubah lagi bila dilanjutkan proses transisinya (Norris, 1997). Perhitungan distribusi keseimbangan dapat menggunakan Persamaan (9) di mana  $\pi_0$  adalah distribusi awal,  $P^n$  adalah matriks probabilitas transisi berpangkat  $n$  dan  $\pi_n$  adalah distribusi setelah  $n$  langkah

$$\pi_n = \pi_0 P^n. \quad (9)$$

Dengan demikian matriks transisi digunakan untuk memperkirakan kemungkinan transisi ke suatu keadaan dalam beberapa langkah ke depan, dengan elemen-elemen matriks yang menggambarkan probabilitas perpindahan yang menjadi dasar peramalan probabilistik aktivitas gempa berdasarkan data historis (Tabar et al., 2005).

### 3. HASIL DAN PEMBAHASAN

Untuk menganalisis dan memprediksi pola aktivitas gempa bumi di Provinsi Bengkulu, 3 variabel data akan dikonversi ke magnitudo Mw terlebih dahulu, kemudian dilakukan *declustering* data gempa utama (*mainshock*) untuk memisahkan pengaruh gempa dependen yaitu gempa pendahuluan (*aftershock*) dan gempa susulan (*foreshock*). Data yang telah dikonversi dan melalui proses *declustering* akan digunakan untuk analisis pengelompokan *K-Means Clustering*. Hasil pengelompokan ini akan digunakan dalam pemodelan Rantai Markov.

#### 3.1 Menentukan Kluster Optimal dengan Validasi *Silhouette Coefficient*

Dalam penelitian ini, penentuan kluster optimal ( $k$ ) menggunakan validasi *Silhouette Coefficient* dengan menampilkan nilai rata-rata *Silhouette* untuk setiap kluster, yang membantu menentukan jumlah kluster optimal. Kluster optimal yang ditentukan untuk masing-masing variabel gempa dapat dilihat pada Tabel 2.

**Tabel 2.** Hasil Uji Kluster Optimal *Silhouette Coefficient*

Variabel	<i>Silhouette Coefficient</i>	Jumlah Kluster
Magnitudo	0.6806741	2

Kedalaman	0.5936595	2
Waktu Kejadian Gempa	0.6212030	3

Berdasarkan Tabel 2, hasil validasi *Silhouette Coefficient* menunjukkan bahwa kluster optimal untuk variabel magnitudo dan kedalaman memiliki jumlah kluster ( $k$ ) yang sama yaitu sebanyak 2 kluster. Sementara itu, variabel waktu kejadian memiliki jumlah kluster ( $k$ ) sebanyak 3 kluster sebagai jumlah optimal. Jumlah kluster tersebut selanjutnya digunakan sebagai acuan dalam proses pengelompokan menggunakan metode *K-Means Clustering*.

### 3.2 Pengelompokan Data dengan *K-Means Clustering*

Berdasarkan hasil validasi *Silhouette Coefficient* pada proses sebelumnya, secara keseluruhan telah diperoleh banyaknya kluster optimal pada masing-masing variabel. Selanjutnya dilakukan proses pengelompokan dengan *K-Means Clustering*, ringkasan jumlah hasil kluster untuk masing-masing variabel data gempa dapat dilihat pada Tabel 3.

**Tabel 3.** Hasil Akhir *Clustering* pada masing-masing Variabel Gempa Provinsi Bengkulu

Variabel	Rentang Kluster	Kluster
Magnitudo	$5.6 \leq x_1 \leq 6.9$	1
	$4.43 \leq x_1 \leq 5.5$	2
Kedalaman	$10 \leq x_2 \leq 42.9$	1
	$45.258 \leq x_2 \leq 163.21$	2
	$1 \leq x_3 \leq 125$	1
Waktu Kejadian Gempa	$243 \leq x_3 \leq 366$	2
	$126 \leq x_3 \leq 242$	3

Hasil perhitungan *K-Means Clustering* yang telah terbentuk untuk variabel magnitudo dalam kluster 1 merupakan gempa sedang, kluster 2 merupakan gempa kecil. Variabel kedalaman dalam kluster 1 merupakan gempa dangkal, kluster 2 merupakan gempa menengah. Variabel waktu kejadian dalam kluster 1 merupakan gempa awal tahun, kluster 2 merupakan gempa akhir tahun dan kluster 3 merupakan gempa pertengahan tahun. Jumlah kluster yang diperoleh dari proses *K-Means Clustering* selanjutnya digunakan sebagai ruang keadaan (*state space*) pada proses prediksi model Rantai Markov.

### 3.3 Analisis Pola Aktivitas Gempa dengan Metode Rantai Markov

Dalam proses Rantai Markov penentuan *state* atau ruang keadaan merupakan tahap yang sangat penting karena memungkinkan identifikasi langkah selanjutnya serta perhitungan nilai probabilitas transisi. Pada penelitian ini, *state* diperoleh dari hasil kluster *K-Means Clustering* untuk setiap variabel. Informasi mengenai *state* dapat dilihat pada Tabel 3 di mana kolom "kluster" menunjukkan *state* yang bersesuaian. Sebagai contoh, data dalam kluster 1 dianggap sebagai *state* 1 dalam proses Rantai Markov. Penentuan keterangan untuk setiap variabel pada setiap *state* mengacu pada klasifikasi yang telah ditetapkan berdasarkan literatur terkait dapat dilihat pada Tabel 4 berikut.

**Tabel 4.** Klasifikasi Gempa Bumi masing-masing Variabel

Variabel	Kategori	Rentang Kategori
----------	----------	------------------

	Sangat Besar	$> 8$
	Besar	$7 - 8$
Magnitudo	Sedang	$5 - 7$
	Kecil	$3 - 5$
	Mikro	$1 - 3$
	Dangkal	$< 50$
Kedalaman	Menengah	$50 - 300$
	Dalam	$> 300$
Waktu	Awal Tahun	$1 \leq x \leq 125$
	Pertengahan Tahun	$125 \leq x \leq 242$
	Akhir Tahun	$242 \leq x \leq 366$

Berdasarkan pengklasifikasian data gempa bumi menurut Linda, Ihsan, dan Palloan (2019), Ubaidillah dan Fatah (2024), serta Rahmi, Muliawati, dan Harbowo (2024), sebagaimana ditampilkan pada Tabel 4 sebelumnya, berikut disajikan Tabel 5 yang merupakan hasil klasifikasi data gempa bumi untuk setiap *state* pada masing-masing variabel penelitian.

**Tabel 5.** Keterangan masing-masing *State* pada Data Gempa Provinsi Bengkulu

Variabel	Kategori	Rentang Kategori	State
Magnitudo (Mw)	Sedang	$5.6 \leq x_1 \leq 6.9$	1
	Kecil	$4.43 \leq x_1 \leq 5.5$	2
Kedalaman (km)	Dangkal	$10 \leq x_2 \leq 42.9$	1
	Menengah	$45.258 \leq x_2 \leq 163.21$	2
	Awal Tahun	$1 \leq x_3 \leq 125$	1
Waktu (hari)	Akhir Tahun	$243 \leq x_3 \leq 366$	2
	Pertengahan Tahun	$126 \leq x_3 \leq 242$	3

Setelah *state* untuk masing-masing variabel ditentukan, selanjutnya menyusun matriks peluang transisi. Penyusunan matriks ini dilakukan dengan mengidentifikasi peralihan *state* pada setiap variabel data penelitian. Proses tersebut menghasilkan matriks frekuensi, yang kemudian digunakan untuk menghitung matriks peluang transisi melalui estimasi probabilitas pada setiap elemen dalam matriks frekuensi. Dengan demikian, dapat dianalisis pola perubahan *state* serta diprediksi dinamika kejadian gempa bumi di Provinsi Bengkulu. Hasil perhitungan matriks peluang transisi untuk setiap variabel ditunjukkan pada Tabel 6 berikut.

**Tabel 6.** Matriks Peluang Transisi Variabel Magnitudo

Matriks Peluang Transisi (%)		
State	State 1 (Sedang)	State 2 (Kecil)
State 1 (Sedang)	0.595	0.405
State 2 (Kecil)	0.607	0.393

Nilai peluang tertinggi data magnitudo terjadi pada saat *state* 2 beralih ke *state* 1 atau pada kondisi magnitudo dengan kekuatan gempa “kecil” ke kekuatan gempa “sedang” yaitu sebesar 60.7%, dapat dilihat pada Tabel 6, serta hasil analisis dijelaskan sebagai berikut.

- a. ketika terjadi gempa dengan magnitudo “Sedang”, maka pada kejadian berikutnya terdapat peluang 59,5% bahwa gempa berikutnya juga akan memiliki magnitudo sedang dan 40.5% kemungkinan mengalami penurunan menjadi magnitudo “Kecil”.
- b. Ketika terjadi gempa dengan magnitudo “Kecil”, gempa berpeluang 60.7% mencapai magnitudo “Sedang” dan 39.3% gempa tetap berada pada magnitudo “Kecil”.

Secara keseluruhan, hasil transisi tersebut memperlihatkan bahwa aktivitas gempa di Provinsi Bengkulu didominasi oleh interaksi antara gempa kecil dan sedang, dengan probabilitas tinggi untuk berpindah di antara kedua kategori tersebut. Kemudian peluang tertinggi data kedalaman terjadi pada saat *state* 1 tetap berada di *state* 1 atau pada kondisi magnitudo dengan kekuatan gempa “Dangkal” tetap di kekuatan gempa “Dangkal” yaitu sebesar 73.5%, seperti yang ditunjukkan dalam Tabel 7.

**Tabel 7.** Matriks Peluang Transisi Variabel Kedalaman

Matriks Peluang Transisi (%)		
State	State 1 (Dangkal)	State 2 (Menengah)
State 1 (Dangkal)	0.735	0.265
State 2 (Menengah)	0.619	0.381

Hasil analisis untuk peluang pola aktivitas gempa dari data kedalaman pada gempa bumi di Provinsi Bengkulu dijelaskan sebagai berikut.

- a. Ketika kedalaman gempa “Dangkal”, maka terdapat peluang sebesar 73.5% bahwa gempa berikutnya juga akan terjadi pada kedalaman “Dangkal” dan 26.5% kemungkinan berpindah ke kedalaman “Menengah”.
- b. Ketika Kedalaman gempa “Menengah”, maka terdapat peluang 61.9% bahwa gempa berikutnya terjadi pada kedalaman “Dangkal” dan 38.1% kemungkinan gempa tetap berada pada kedalaman “Menengah”.

Secara keseluruhan, hasil ini mengindikasikan bahwa gempa di Provinsi Bengkulu memiliki dominasi aktivitas pada zona dangkal. Selanjutnya peluang tertinggi data waktu kejadian gempa pada saat *state* 3 tetap berada di *state* 3 atau pada kondisi waktu kejadian dengan kategori gempa “Pertengahan Tahun” tetap di kekuatan gempa “Pertengahan Tahun” yaitu sebesar 75.9%, seperti yang ditunjukkan dalam Tabel 8.

**Tabel 8.** Matriks Peluang Transisi Variabel Waktu

Matriks Peluang Transisi (%)			
State	State 1 (Awal Tahun)	State 2 (Akhir Tahun)	State 3 (Pertengahn Tahun)
State 1 (Awal Tahun)	0.727	0.000	0.273

State 2 (Akhir Tahun)	0.263	0.684	0.053
State 3 (Pertengahan Tahun)	0.000	0.241	0.759

Hasil analisis untuk peluang pola aktivitas gempa dari data waktu kejadian gempa di Provinsi Bengkulu dijelaskan sebagai berikut.

- Apabila gempa terjadi pada "Awal Tahun", maka terdapat peluang sebesar 72.7% bahwa gempa berikutnya juga akan terjadi pada "Awal Tahun" dan 27.3% kemungkinan berpindah ke "Pertengahan Tahun".
- Sebaliknya, ketika gempa terjadi pada "Akhir Tahun", kemungkinan berpindah ke "Awal Tahun" sebesar 26.3%, berpeluang untuk kembali terjadi pada "Akhir Tahun" sebesar 68.4%, dan sebesar 5.3% kemungkinan pindah ke "Pertengahan Tahun".
- Sementara itu, jika gempa terjadi pada "Pertengahan Tahun", maka 24.1% kemungkinan terjadi di "Akhir Tahun", berpeluang 75.9% tetap berada pada periode "Pertengahan Tahun".

Probabilitas transisi yang telah diperoleh sebelumnya digunakan untuk perhitungan distribusi keseimbangan atau prediksi jangka panjang yang menunjukkan konvergensi sistem menuju distribusi keseimbangan untuk setiap variabel. Hasil distribusi keseimbangan untuk setiap variabel dapat dilihat pada Tabel 9, Tabel 10, dan Tabel 11.

**Tabel 9.** Distribusi Keseimbangan Variabel Magnitudo

Distribusi Keseimbangan (%)	
State 1 (Sedang)	State 2 (Kecil)
0.6	0.4

**Tabel 10.** Distribusi Keseimbangan Variabel Kedalaman

Distribusi Keseimbangan (%)	
State 1 (Dangkal)	State 2 (Menengah)
0.7	0.3

**Tabel 11.** Distribusi Keseimbangan Variabel Waktu

Distribusi Keseimbangan (%)		
State 1 (Awal Tahun)	State 2 (Akhir Tahun)	State 3 (Pertengahan Tahun)
0.295	0.305	0.4

Hasil distribusi keseimbangan menunjukkan bahwa dalam jangka panjang, apabila rantai transisi berlangsung secara terus-menerus tanpa batas waktu, maka sistem akan mencapai kondisi stabil. Pola aktivitas seismic di Provinsi Bengkulu didominasi oleh gempa bermagnitudo sedang (60%) dengan kedalaman dangkal (70%). Dari sisi temporal, kejadian gempa paling banyak terjadi pada pertengahan tahun (40%). Pola ini memperlihatkan kecenderungan seismic yang stabil dan berulang, menandakan dinamika tektonik aktif di

zona subduksi barat Sumatra. Temuan ini memperkuat studi Rahmi, Muliawati, dan Harbowo (2024), namun memberikan detail probabilistik yang lebih tinggi melalui integrasi metode *K-Means Clustering* dan Rantai Markov.

#### 4. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi gempa di Provinsi Bengkulu dengan mengintegrasikan *K-Means Clustering* dan Rantai Markov. Hasil menunjukkan bahwa dominasi gempa magnitudo sedang dan kedalaman dangkal, terutama pada pertengahan tahun, serta pola seismic yang berulang secara probabilistik. Kebaruan dari penelitian ini terletak pada penggunaan kombinasi *K-Means Clustering* dan Rantai Markov untuk memodelkan pola temporal dan spasial gempa secara simultan, memungkinkan identifikasi kluster seismic lebih akurat dan wawasan probabilistik yang lebih mendalam. Temuan ini berpotensi menjadi dasar pengembangan sistem mitigasi risiko bencana berbasis data, dengan penelitian lanjutan disarankan untuk memasukkan variabel Lokasi hiposentrum/episentrum dan data *real-time* untuk memperkuat prediksi jangka panjang.

#### 5. DAFTAR PUSTAKA

- Dewi, D. A. I. C., dan Pramita, D. A. K. (2019). Analisis Perbandingan Metode Elbow dan Silhouette pada Algoritma Clustering K-Medoids dalam Pengelompokan Produksi Kerajinan Bali. *Jurnal Matrix*, 9(3), 102-109.
- Fransiska, N. N., Anggraeni, D. S., dan Enri, U. (2023). Pengelompokan Data Kemiskinan Provinsi Jawa Barat Menggunakan Algoritma K-Means dengan Silhouette Coefficient. *Jurnal Teknologi Informasi Komunikasi (e-Journal)*, 9(1), 29-35.
- Hadi, A. I. dan Brotopuspito, K. S. (2016). Estimasi Kedalaman Bidang Batas Sesar Dari Data Gravitasi di Daerah Rawan Gerakan Tanah (Studi Kasus: Sesar Sumatra Segmen Musi Bengkulu). *Jurnal Ilmu Fisika Indonesia*, 2(2), 37-42.
- Hendrastuty, N. (2024). Penerapan Data Mining Menggunakan Algoritma K-Means Clustering Dalam Evaluasi Hasil Pembelajaran Siswa. *Jurnal Ilmiah Informatika dan Ilmu Komputer*, 3(1), 46-56.
- Kurniadi, D., Agustin, Y. H., Akbar, H. I. N., dan Farida, I. (2023). Penerapan Algoritma K-Means Clustering untuk Pengelompokan Pembangunan Jalan Pada Dinas Pekerjaan Umum dan Penataan Ruang. *Jurnal Teknologi Informasi*, 20(1), 64-77.
- Linda, Ihsan, N., dan Palloan, P. (2019). Analisis Distribusi Spasial dan Temporal Seismotektonik Berdasarkan Nilai B-Value dengan Menggunakan metode Likelihood di Pulau Jawa. *Jurnal Sains dan Pendidikan Fisika (JSPF)*, 15(1), 16-31.
- Mustakim, Kamila, I., Ramadhan, A., dan Irwandi, E. (2018). Implementasi Algoritma Markov Chains untuk Prediksi Kejadian Bencana Alam di Provinsi Riau. *Seminar Nasional Teknologi Informasi, Komunikasi dan Industri (SNTIKI-10)*, 151-157.
- Nahdliyah, M. A., Widiharih, T., dan Prahutama, A. (2019). Metode K-Medoids Clustering dengan Validasi Silhouette Index dan C-Index (Studi Kasus Jumlah Kriminalitas Kabupaten/Kota di Jawa Tengah Tahun 2018). *Jurnal Gaussian*, 8(2), 161-170.
- Norris, J. R. (1997). *Markov Chains*. Cambridge: Cambridge University Press.

- Nurhamiddin, F dan Sulisa, F. M. (2019). Peramalan Cuaca Menggunakan Metode Rantai Markov (Studi Kasus : Rekaman Cuaca Harian di Kantor BMKG Kota Ternate). *Jurnal Biosainstek*, 2(1), 16–22.
- Putra, R. R., Kiyono, J., Ono, Y., dan Parajuli, H. R. (2012) Seismic Hazard Analysis for Indonesia. *Journal of Natural Disaster Science*, 33(2), 59–70.
- Rahmi, P. A., Muliawati, T., dan Harbowo, D. G. (2024) Analisis Pola Aktivitas Gempa Bumi di Pulau Sumatra dengan Metode K-Means Clustering dan Rantai Markov. *Jurnal Seminar Nasional Sains Data (Senada)*, 592–601.
- Tabar, M. R. R., Sahimi, M., Kaviani, K., Allamehzadeh, M., Peinke, J., Mokhtari, M., Vesaghi, M., Niry, M. D., Ghasemi, F., Bahraminasab, A., Tabatabai, S., dan Fayazbakhsh, F. (2005). *Dynamics of the Markov Time Scale of Seismic Activity May Provide a Short-Term Alert for Earthquakes*. asXiv. <https://arxiv.org/abs/physics/0510043>.
- Ubaidillah, M. dan Fatah, Z. (2024). Implementasi Rapiminder Pada Klasterisasi Gempa Bumi di Indonesia Berdasarkan Kedalaman Menggunakan K-Means. *Jurnal Ilmiah Multidisiplin Ilmu*, 1(6), 84-91.
- Wulandari, A., Irmayansyah, Ningrum, L. T. (2025). Penerapan Metode K-Means Clustering untuk Pemetaan Perbaikan Jalan di Kota Bogor. *Jurnal Informatika Teknologi dan Sains (JINTEKS)*, 7(1), 107-116.