

PEMETAAN DAN KLASIFIKASI WILAYAH RAWAN GEMPA DI INDONESIA DENGAN METODE K-MEANS DAN LIGHTGBM

Yudhi Selvina Yulianti^{1*}, Rachmat Adi Purnama², Tommi Alfian Armawan Sandi³

^{1,2,3}Universitas Bina Sarana Informatika; Jl. Kramat Raya No.98, Kwitang, Kec. Senen, Kota Jakarta Pusat, Daerah Khusus Ibukota Jakarta 10450; Telp. (021) 21231170

Keywords:

pemetaan wilayah, K-means clustering, klasifikasi LightGBM

Correspondent Email:

yudhiselvina25@gmail.com

Abstrak. Penelitian ini bertujuan untuk memetakan dan mengklasifikasikan wilayah rawan gempa di Indonesia dengan memanfaatkan algoritma K-Means dan LightGBM. Data historis gempa diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) sebagai dasar analisis. Algoritma K-Means digunakan untuk mengelompokkan wilayah berdasarkan parameter magnitudo dan kedalaman gempa, sedangkan LightGBM diterapkan untuk mengklasifikasikan gempa ke dalam kategori magnitudo tertentu. Hasil pengujian menunjukkan bahwa K-Means mampu mengelompokkan wilayah dengan baik dengan nilai Silhouette Score rata-rata mencapai 1.00, yang menandakan pemisahan cluster yang optimal. Sementara itu, model LightGBM memperoleh akurasi 95% dalam klasifikasi gempa, meskipun ditemukan kendala pada pengenalan gempa dengan magnitudo tinggi. Temuan ini menegaskan bahwa kombinasi metode K-Means dan LightGBM efektif dalam pemetaan serta klasifikasi gempa di Indonesia. Penelitian ini diharapkan dapat memberikan kontribusi bagi penyusunan peta rawan gempa yang lebih akurat, sehingga bermanfaat dalam upaya mitigasi bencana dan pengambilan keputusan kebijakan kebencanaan di masa mendatang.



Copyright © [JITET](http://www.jitet.org) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. This study aims to map and classify earthquake-prone areas in Indonesia by applying K-Means clustering and LightGBM classification. Historical earthquake data obtained from the Meteorology, Climatology, and Geophysics Agency (BMKG) serve as the basis of analysis. The K-Means algorithm is employed to group regions based on earthquake magnitude and depth, while LightGBM is used to classify earthquakes into specific magnitude categories. The results show that K-Means successfully clustered the regions with an average Silhouette Score of 1.00, indicating an optimal separation between clusters. Meanwhile, the LightGBM model achieved an accuracy of 95% in classifying earthquakes, although challenges were found in identifying large-magnitude events. These findings demonstrate that the combination of K-Means and LightGBM is effective for earthquake mapping and classification in Indonesia. This research is expected to contribute to the development of more accurate earthquake-prone area maps, which can be utilized to support disaster mitigation strategies and inform future policy-making in disaster management.

1. PENDAHULUAN

Indonesia merupakan salah satu negara dengan tingkat seismisitas tertinggi di dunia

karena berada pada pertemuan tiga lempeng tektonik utama, yaitu Indo-Australia, Eurasia, dan Pasifik. Setiap tahunnya ribuan gempa

bumi tercatat oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), dengan variasi magnitudo, kedalaman, dan lokasi yang dipicu oleh aktivitas subduksi maupun pergerakan sesar aktif [1]. Kondisi ini menjadikan pemetaan wilayah rawan gempa sebagai kebutuhan penting untuk mendukung strategi mitigasi bencana berbasis data.

Berbagai penelitian sebelumnya telah memanfaatkan metode machine learning dalam analisis seismik. K-Means banyak digunakan dalam pemetaan wilayah berdasarkan magnitudo, kedalaman, maupun lokasi gempa.[2] Namun, sebagian besar penelitian masih terbatas pada pengelompokan (clustering) tanpa dilanjutkan ke tahap klasifikasi kerawanan. Di sisi lain, Light Gradient Boosting Machine (LightGBM) terbukti memiliki kinerja tinggi dalam klasifikasi pada berbagai domain data, termasuk prediksi magnitudo gempa.[3] Meskipun demikian, penerapan kombinasi metode K-Means dan LightGBM dalam konteks pemetaan sekaligus klasifikasi kerawanan gempa di Indonesia masih jarang dilakukan.

Kesenjangan tersebut menunjukkan bahwa penelitian sebelumnya belum secara optimal mengintegrasikan metode clustering dan classification untuk menghasilkan peta kerawanan yang lebih informatif. Oleh karena itu, penelitian ini bertujuan untuk memetakan wilayah rawan gempa di Indonesia menggunakan algoritma K-Means, mengklasifikasikan tingkat kerawanan gempa berdasarkan magnitudo dengan algoritma LightGBM, serta mengevaluasi kinerja kombinasi kedua metode tersebut dalam menghasilkan informasi spasial yang akurat untuk mendukung strategi mitigasi bencana.

2. TINJAUAN PUSTAKA

2.1. Gempa Bumi

Gempa bumi dapat menyebabkan kerusakan parah pada kehidupan manusia dan infrastruktur. Di Indonesia, gempa bumi adalah salah satu bencana alam yang paling sering terjadi.[4] Gempa bumi terjadi akibat pembebasan atau pelepasan energi yang menumpuk dan terkungkung di dalam kerak bumi ke permukaan. Energi yang dibebaskan itu berubah menjadi gelombang getaran atau

guncangan yang kemudian dirasakan oleh manusia dan direkam oleh alat pencatat gempa bumi yaitu seismograf. [5]

2.2. Pemetaan

Pemetaan adalah proses penting dalam geografi yang mengelompokkan wilayah berdasarkan letak geografis, seperti dataran tinggi, pegunungan, sumber daya alam, dan potensi penduduk yang mempengaruhi aspek sosial dan budaya.[6] Pemetaan wilayah rawan bencana bertujuan untuk mengidentifikasi area yang memiliki tingkat kerentanan berbeda berdasarkan parameter fisik.[7] Klasifikasi dalam data mining digunakan untuk menetapkan suatu data ke dalam kelas tertentu sehingga dapat memberikan informasi prediktif.[8]

2.3. K-Means


K-Means adalah algoritma clustering yang mengelompokkan data berdasarkan kedekatan jarak dengan centroid. Algoritma ini sering digunakan dalam penelitian kebencanaan untuk mengidentifikasi pola distribusi spasial gempa karena kesederhanaan dan efektivitasnya.[9]

2.4. LightGBM

Algoritma LightGBM adalah algoritma yang dirancang oleh Microsoft Research Asia menggunakan kerangka Gradient Boosting Decision Tree (GBDT). Tujuannya untuk meningkatkan efisiensi komputasi, sehingga masalah prediksi dengan big data dapat diselesaikan dengan efisien.[10] LightGBM memiliki beberapa keunggulan dibandingkan dengan metode GBDT lainnya, yaitu kecepatan pelatihan lebih cepat, efisiensi lebih tinggi, penggunaan memori lebih rendah, tingkat akurasi lebih baik, kemampuan dalam menangani data dengan skala yang besar dan dukungan pembelajaran paralel dan GPU.[11]

3. METODE PENELITIAN

Penelitian ini dilakukan untuk mengembangkan model pemetaan dan klasifikasi wilayah rawan gempa di Indonesia dengan menggunakan algoritma K-Means untuk pengelompokan wilayah berdasarkan kedalaman dan megnitudo gempa, serta



Gambar 1 Proses dan Langkah penelitian

LightGBM untuk klasifikasi gempa berdasarkan kategori magnitudo.

3.1. Pengumpulan Dataset

Data yang digunakan dalam penelitian ini adalah data kuantitatif, yang mencakup informasi mengenai kejadian gempa di Indonesia, seperti waktu, Lokasi (lintang dan bujur), kedalaman dan magnitudo. Data ini diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) <https://dataonline.bmkg.go.id/> untuk periode 2023 hingga April 2025. Dataset ini mencakup 16.215 titik data yang menggambarkan berbagai kejadian gempa bumi di wilayah Indonesia.

3.2. Pembersihan Data

Setelah data di unduh selanjutnya Adalah proses pembersihan data (*Data Cleaning*). Proses ini mencakup pengecekan data yang hilang, duplikat, dan kesalahan format. Data yang hilang akan diatasi dengan penghapusan baris yang relevan atau pengisian dengan nilai rata-rata atau interpolasi, tergantung pada karakteristik data.

3.3. Transformasi Data

Pada tahap transformasi data kolom tanggal akan dikonversi ke format yang sesuai, dan variabel lainnya akan dipersiapkan dalam bentuk yang dapat digunakan oleh algoritma K-Means dan LightGBM.

3.4. Normalisasi Data

Beberapa fitur seperti kedalaman dan magnitudo akan dinormalisasi untuk memastikan bahwa data tersebut memiliki skala yang seragam, yang penting untuk efektivitas algoritma K-Means dalam clustering. Normalisasi menggunakan metode *Min-Max Scaling*, yang memastikan bahwa nilai-nilai data berada dalam rentang 0 hingga 1.

3.5. Pemetaan Dengan K-Means

K-Means digunakan untuk mengelompokkan wilayah rawan gempa berdasarkan dua fitur utama yaitu kedalaman dan magnitudo gempa.[12] Algoritma K-Means akan mengelompokkan data ke dalam beberapa cluster, yang masing-masing menunjukkan wilayah dengan karakteristik kedalaman dan magnitudo yang serupa.[13] Langkah-langkah dalam pengelompokan menggunakan K-Means adalah sebagai berikut:

1. Menentukan jumlah cluster yang optimal menggunakan *Elbow Method*. Elbow

Method digunakan untuk menentukan jumlah cluster terbaik dalam algoritma K-Means. Metode ini mengukur jumlah error kuadrat dalam setiap cluster dan memilih jumlah cluster yang meminimalkan error.[14]

$$WCSS = \sum_{i=1}^k \sum_{x_j} ||x_j - \mu_i||^2 \quad (1)$$

2. Menjalankan algoritma K-Means dengan jumlah cluster yang telah ditentukan.
3. Memetakan hasil clustering ke dalam peta untuk memvisualisasikan distribusi wilayah rawan gempa.

3.6. Klasifikasi dengan LightGBM

LightGBM digunakan untuk mengklasifikasi gempa berdasarkan magnitudo, dengan klasifikasi sebagai gempa kecil, sedang, atau besar. Data yang digunakan untuk pelatihan model ini meliputi kedalaman, Lokasi geografis (lintang dan bujur), serta magnitudo gempa. Langkah-langkah dalam klasifikasi menggunakan LightGBM adalah sebagai berikut:

1. Memisahkan dataset menjadi data pelatihan dan data uji.
2. Melatih model LightGBM dengan data pelatihan.
3. Mengukur akurasi model menggunakan data uji dengan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

3.7. Evaluasi Model

Evaluasi dilakukan untuk mengukur kinerja model K-Means dan LightGBM. Untuk K-Means, evaluasi dilakukan menggunakan *Silhouette Score* untuk mengevaluasi kualitas pengelompokan yang dihasilkan oleh K-Means. Nilai yang lebih tinggi menunjukkan bahwa cluster yang terbentuk lebih terpisah dan lebih padat.

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

Untuk LightGBM, model dievaluasi menggunakan *confusion matrix*, *classification report*, dan *ROC curve* untuk mengukur sejauh mana model dapat mengklasifikasikan gempa dengan akurat.[15]

4. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk memetakan wilayah rawan gempa di Indonesia menggunakan algoritma K-Means dan mengklasifikasi gempa berdasarkan magnitudo menggunakan LightGBM. Pada bagian ini,

hasil pelaksanaan metode penelitian akan disajikan secara terstruktur, dengan data yang relevan untuk menjawab pertanyaan penelitian dan menguji hipotesis yang telah diajukan.

4.1. Dataset yang Digunakan

Dataset yang digunakan dalam penelitian ini adalah data gempa bumi yang diperoleh dari BMKG untuk periode tahun 2023 hingga April 2025. Dataset ini berisi informasi mengenai waktu kejadian gempa, Lokasi geografis (lintang dan bujur), kedalaman gempa, dan magnitudo gempa.

1	DATE	LINTANG	BUJUR	KEDALAMAN	MAGNITUDO
2	1/1/2023 0:42	-0.67	124.4425	10	2.82
3	1/1/2023 0:45	-0.04	123.6601	86.7	2.58
4	1/1/2023 0:50	-2.71	128.5374	10	3.82
5	1/1/2023 2:44	-3.63	121.5448	10	2.51
6	1/1/2023 2:47	-1.42	100.4661	54.1	3.2
7	1/1/2023 2:51	-3.5	121.5174	10	2.75
8	1/1/2023 2:52	-3.7	121.5213	10	2.57
9	1/1/2023 2:58	-3.64	121.4925	10	2.49
10	1/1/2023 4:09	-4.93	102.7892	19.6	3.99
11	1/1/2023 4:20	-1.52	99.87775	24.3	3.86
12	1/1/2023 7:28	-0.27	122.9628	14.1	2.43
13	1/1/2023 9:24	-5.28	103.1562	24.4	3.05
14	1/1/2023 10:17	2.13	128.2999	10	3.67
15	1/1/2023 10:38	0.14	124.117	76.1	3.11
16	1/1/2023 10:52	-6.79	107.0899	10	2.97
17	1/1/2023 11:42	-6.8	107.0814	12.1	1.89
18	1/1/2023 13:03	2.06	98.89861	10	2.86
19	1/1/2023 13:13	2.04	98.87454	10	2.65
20	1/1/2023 13:37	-2.97	128.3561	13	3.79
21	1/1/2023 14:06	-7.23	106.8026	114.1	3

Gambar 2. Tampilan Dataset Gempa

4.2. Pre-Processing Data

1. Pembersihan Data (Data Cleaning)

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 16214 entries, 0 to 16213
Data columns (total 5 columns):
#   Column      Non-Null Count  Dtype
---  ---
0    DATE        16213 non-null  object
1    LINTANG      16213 non-null  float64
2    BUJUR        16213 non-null  float64
3    KEDALAMAN    16213 non-null  float64
4    MAGNITUDO    16213 non-null  float64
dtypes: float64(4), object(1)
memory usage: 633.5+ KB
DATE      0
LINTANG    0
BUJUR      0
KEDALAMAN 0
MAGNITUDO 0
dtype: int64
```

Gambar 3. Hasil Pembersihan Data

Setelah pengumpulan data, dilakukan proses pembersihan data (data cleaning) dan transformasi data untuk memastikan dataset siap untuk dianalisis.

Pada gambar 3 merupakan hasil pembersihan data yang menunjukkan jumlah nilai kosong (missing value) per kolom setelah pembersihan. Semua kolom memiliki 0 (nilai kosong), yang artinya semua data sudah bersih.

2. Transformasi Data

Pada tahap transformasi data berfungsi untuk mengubah kolom tanggal menjadi format datetime dan menambahkan kolom-kolom baru dari kolom tanggal.

	DATE	Bulan	Hari	Jam	Tahun
0	2023-01-01 00:42:00	1.0	1.0	0.0	2023.0
1	2023-01-01 00:45:00	1.0	1.0	0.0	2023.0
2	2023-01-01 00:50:00	1.0	1.0	0.0	2023.0
3	2023-01-01 02:44:00	1.0	1.0	2.0	2023.0
4	2023-01-01 02:47:00	1.0	1.0	2.0	2023.0

Gambar 4. Hasil Transformasi Data

Gambar 4 merupakan hasil dari proses transformasi data pada kolom tanggal dan waktu. Kolom "DATE" telah dipecah menjadi komponen "Bulan", "Hari", "Jam", dan "Tahun" untuk memudahkan tahapan analisis selanjutnya.


3. Normalisasi Data

Pada tahap normalisasi data Adalah untuk mengubah skala fitur data sehingga rata-rata 0 atau 1 dan mengatur skala data agar atribut dengan skala yang lebih besar tidak mendominasi hasil analisis.

4.3. Pemetaan Wilayah Rawan Gempa dengan K-Means

Proses pemetaan wilayah rawan gempa dilakukan dengan menggunakan algoritma K-Means. Dalam tahap ini, wilayah rawan gempa dikelompokkan berdasarkan fitur utama yaitu kedalaman dan magnitudo. Sebelum menjalankan K-Means, dilakukan analisis untuk menentukan jumlah cluster optimal menggunakan *Elbow Method*.

Berdasarkan Grafik Elbow menunjukkan hubungan antara jumlah cluster (1–9) pada sumbu X dan nilai *Within-Cluster Sum of*




Gambar 5. Hasil Elbow Method

Squares (WCSS) pada sumbu Y. Terlihat penurunan WCSS seiring bertambahnya jumlah cluster, dengan titik siku berada di antara cluster ke-3 dan ke-4, sehingga jumlah cluster optimal berada pada $k = 3$ atau 4.


Melanjutkan tahap menentukan cluster optimal, dilakukan proses clustering wilayah rawan gempa berdasarkan frekuensi kejadian pada titik koordinat tertentu. Data yang telah dibersihkan dikelompokkan menurut lintang dan bujur, kemudian dihitung jumlah kejadian gempa pada setiap lokasi sehingga terbentuk kolom FREKUENSI. Clustering dilakukan dengan metode K-Means menggunakan $k=3$, yang membagi wilayah menjadi tiga kategori frekuensi gempa: rendah, sedang, dan tinggi. Hasilnya disimpan dalam kolom Cluster pada dataset.

Hasil visualisasi clustering frekuensi gempa pada Gambar 6 menggunakan algoritma K-Means menghasilkan tiga cluster:

1. Cluster 0 (biru) mencakup sebagian besar wilayah Indonesia dengan frekuensi gempa rendah-menengah.
2. Cluster 1 (oranye) terkonsentrasi di jalur subduksi aktif seperti pantai barat Sumatra, selatan Jawa, Maluku, dan Papua dengan frekuensi menengah.



Gambar 6. Hasil Pemetaan dengan K-Means




3. Cluster 2 (hijau) berjumlah sedikit namun berada pada zona tumbukan lempeng dan sesar aktif di timur Indonesia dengan frekuensi tinggi.

4.4. Klasifikasi Gempa dengan LightGBM

Setelah wilayah rawan gempa dipetakan dengan K-Means, tahapan selanjutnya adalah melakukan klasifikasi gempa berdasarkan magnitudo dan kedalaman menggunakan LightGBM. Data yang digunakan untuk pelatihan model LightGBM mencakup kedalaman gempa, lokasi geografis, serta magnitudo gempa. Sebelum menjalankan klasifikasi gempa penulis melakukan pengelompokan data gempa bumi menjadi 3 kategori.

1. Risiko tinggi : magnitudo $> 5,5$ dan kedalaman ≤ 60 km. kategori ini menggambarkan gempa besar dan dangkal yang berpotensi menimbulkan kerusakan signifikan.
2. Risiko Sedang : magnitudo antara 3,6 hingga 5,5 dan kedalaman ≤ 60 km, atau magnitudo $> 5,5$ dan kedalaman antara 60-300 km. Kategori ini mencakup gempa sedang yang dangkal atau gempa besar dengan kedalaman menengah.
3. Risiko Rendah : gempa yang tidak memenuhi kedua kriteria di atas, umumnya gempa kecil atau sangat dalam yang memiliki potensi kerusakan rendah.




Gambar 7. Hasil Visualisasi LightGBM

Gambar 7 menunjukkan sebaran titik lokasi gempa bumi di wilayah Indonesia yang telah diklasifikasikan ke dalam tiga kategori risiko berdasarkan magnitudo dan kedalaman menggunakan algoritma LightGBM. Setiap titik pada peta mewakili satu kejadian gempa, dengan warna yang merepresentasikan tingkat risiko merah (risiko rendah), biru (risiko sedang), hijau (risiko tinggi).

4.5. Evaluasi Kualitas Clustering dan Klasifikasi

1. Evaluasi kualitas clustering (Silhouette Score)

Pada tahap ini, clustering dilakukan menggunakan K-Means dengan berbagai jumlah cluster. Untuk mengevaluasi kualitas clustering, digunakan Silhouette Score yang memberikan Gambaran tentang seberapa baik data dikelompokkan ke dalam cluster yang tepat.




Gambar 8. Visualisasi Silhouette Score

Berdasarkan hasil visualisasi *Silhouette Score* pada gambar, dapat dilihat bahwa proses pengelompokan dengan 3 cluster menghasilkan nilai rata-rata *silhouette coefficient* sebesar 1.00 (ditunjukkan oleh garis merah vertikal). Nilai ini yang berarti kualitas pemisahan antar cluster tergolong sangat baik. Semakin jelas batas antar cluster dan semakin homogen anggota cluster di dalamnya.

2. Evaluasi kualitas klasifikasi (*Confusion Matrix*)

Setelah tahap clustering selesai, dilakukan klasifikasi menggunakan model LightGBM untuk memprediksi kategori gempa berdasarkan data yang telah dikelompokkan ke dalam cluster. Evaluasi kualitas klasifikasi dilakukan dengan menggunakan *Confusion Matrix*.



Gambar 9. Visualisasi *Confusion Matrix*

Gambar 9 menampilkan *confusion matrix* hasil klasifikasi gempa ke dalam tiga kategori: Rendah, Sedang, dan Tinggi. Model mengklasifikasikan 2405 data kategori Rendah dan 10 data kategori Tinggi dengan benar tanpa kesalahan, serta 827 data kategori Sedang dengan hanya satu kesalahan prediksi, menunjukkan akurasi model yang sangat tinggi pada seluruh kategori.

5. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa:

1. Algoritma K-Means berhasil mengelompokkan wilayah rawan gempa menjadi tiga cluster berdasarkan frekuensi kejadian. Cluster dengan frekuensi tinggi teridentifikasi berada di jalur subduksi dan sesar aktif, seperti Sumatera bagian barat, Selatan Jawa, Nusa Tenggara, serta Maluku hingga Papua. Pada nilai silhouette score menunjukkan kualitas pemisahan cluster cukup baik, sehingga hasil pengelompokan dapat dijadikan dasar pemetaan tingkat aktivitas seismik.
2. LightGBM mampu mengklasifikasikan gempa bumi berdasarkan magnitudo dan kedalaman menjadi tiga kategori: rendah, sedang, tinggi. Serta hasil pengujian menunjukkan akurasi yang cukup tinggi dengan nilai precision, recall, dan f1-score yang baik pada sebagian besar kelas.
3. Kedua model, K-Means dan LightGBM, secara keseluruhan memberikan hasil yang signifikan dan memenuhi tujuan penelitian, yaitu memetakan wilayah

rawan gempa dan mengklasifikasikan gempa berdasarkan megnitudo dengan akurasi yang tinggi. Hasil pengujian mendukung hipotesis bahwa penggunaan kedua algoritma ini dapat meningkatkan pemahaman tentang resiko gempa di Indonesia.

UCAPAN TERIMA KASIH

Pada penelitian ini saya mengucapkan terima kasih kepada:

1. Allah SWT atas karunia dan kemudahan yang diberikan dalam menyelesaikan penelitian ini. Orang tua saya yang senantiasa mendoakan dan memotivasi dalam menuntut ilmu.
2. untuk diriku sendiri yang telah kuat melewati ini semua dan bertahan hingga saat ini.
3. Dosen pembimbing yang telah sabar membimbing dan memberi arahan
4. teman-teman se perjuangan yang telah mendukung satu sama lain

DAFTAR PUSTAKA

- [1] I. Cnn, "Ri Diguncang 8.000 Gempa Setahun, Megathrust Dan Sesar Aktif Mengancam," Cnn Indonesia. Accessed: Aug. 16, 2025. [Online]. Available: <https://www.cnnindonesia.com/teknologi/20241002150410-199-1150813/Ri-Diguncang-8000-Gempa-Setahun-Megathrust-Dan-Sesar-Aktif-Mengancam>
- [2] A. Prasetyo, M. Makmun, And M. N. Dwi, "Analisis Gempa Bumi Di Indonesia Dengan Metode Clustering," *Bulletin Of Information Technology (Bit)*, Vol. 4, No. 2, Pp. 338–343, 2023, Doi: 10.47065/Bit.V3i1.
- [3] I. Maulita And A. M. Wahid, "Prediksi Magnitudo Gempa Menggunakan Random Forest, Support Vector Regression, Xgboost, Lightgbm, Dan Multi-Layer Perceptron Berdasarkan Data Kedalaman Dan Geolokasi," *Jurnal Pendidikan Dan Teknologi Indonesia*, Vol. 4, No. 5, Pp. 221–232, Dec. 2024, Doi: 10.52436/1.Jpti.470.
- [4] H. Tantyoko, D. Kartika Sari, And A. R. Wijaya, "Prediksi Potensial Gempa Bumi Indonesia Menggunakan Metode Random Forest Dan Feature Selection," 2023. [Online]. Available: <http://jom.fti.budiluhur.ac.id/index.php/idealis/indexhenritantyoko> [<http://jom.fti.budiluhur.ac.id/index.php/idealis/index>]
- [5] Ferdy And Wahyuddin, "Aplikasi Game Edukasi Mitigasi Bencana Alam (Gempa Bumi Dan Tsunami) Menggunakan Metode Waterfall Berbasis Android," *Jsilog: Jurnal Sintaks Logika*, Vol. 4, No. 1, 2024, [Online]. Available: <https://jurnal.umpar.ac.id/index.php/sylog>
- [6] B. K. Fajar, "Rancang Bangun Aplikasi Pemetaan Kejadian Bencana Kekeringan Di Kabupaten Banyumas Berbasis Android Menggunakan Metode Scrum," *Jurnal Informatika Dan Teknik Elektro Terapan*, Vol. 12, No. 3, Aug. 2024, Doi: 10.23960/Jitet.V12i3.4478.
- [7] N. Yolanda Paramitha *Et Al.*, "Klasifikasi Penyakit Stroke Menggunakan Metode Naïve Bayes," 2023. [Online]. Available: <https://www.kaggle.com/datasets/zsettrk/alphakbal/full-filled>
- [8] A. Pebdika, R. Herdiana, And D. Solihudin, "Klasifikasi Menggunakan Metode Naive Bayes Untuk Menentukan Calon Penerima Pip," 2023.
- [9] S. Setyaningtyas, B. Nugroho, And Z. Arif, "Tinjauan Pustaka Sistematis: Penerapan Data Mining Teknik Clustering Algoritma K-Means," *Jurnal Teknoif Teknik Informatika Institut Teknologi Padang*, Vol. 10, No. 2, Pp. 52–61, Oct. 2022, Doi: 10.21063/Jtif.2022.V10.2.52-61.
- [10] P. S. Rizky, R. H. Hirzi, And Hidayaturrohmah. Umam, "Perbandingan Metode Lightgbm Dan Xgboost Dalam Menangani Data Dengan Kelas Tidak Seimbang," 2022. [Online]. Available: www.unipasby.ac.id
- [11] D. D. Rufo, T. G. Debelee, A. Ibenthal, And W. G. Negera, "Diagnosis Of Diabetes Mellitus Using Gradient Boosting Machine (Lightgbm)," *Diagnostics*, Vol. 11, No. 9, Sep. 2021, Doi: 10.3390/Diagnostics11091714.
- [12] I. B. F. Arafat, "Clustering Gempabumi Di Wilayah Regional Vii Menggunakan Metode DbSCAN Dan K-Means," Universitas Islam Negeri Maulana Malik Ibrahim, Malang, 2023.
- [13] Y. Y. Marawali, C. Ramadhani, L. A. Syamsul, And I. Akbar, "Pengelompokan Gempa Bumi Di Pulau Lombok Tahun 2018 Menggunakan Algoritma K-Means Clustering Earthquakes In Lombok Island In 2018 Using The K-Means Algorithm," 2022. [Online]. Available: http://repogempa_bmkg.go.id/
- [14] I. N. Abrar, A. Abdullah, And S. Sucipto, "Liver Disease Classification Using The Elbow Method To Determine Optimal K In The K-Nearest Neighbor (K-Nn)

- Algorithm,” *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, Vol. 12, No. 2, Pp. 218–228, Jul. 2023, Doi: 10.32736/Sisfokom.V12i2.1643.
- [15] D. Normawati And S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” 2021.