

Penerapan Algoritma Random Forest untuk Prediksi Jumlah Gempa Bulanan di Indonesia

Random Forest for Predicting Earthquakes Monthly in Indonesia

Randi Irwana¹, Risda Nurajizah², Mohammad Shidiq Permana³, Imam Rizki Saputra⁴, Randy Oktaviana Hertland⁵, Mohammad Bayu Anggara⁶

¹Teknik Informatika, Fakultas Teknologi Informasi, Universitas Bale Bandung
Jl. R.A.A Wiranata Kusumah No.7, Baleendah, Kec. Baleendah, Bandung, Jawa Barat
Telp : (3273) 0821-2698-6885

E-mail : randiirwana25@gmail.com¹, risdanurazizah603@gmail.com², shidiqper@gmail.com³,
imamrizkysyahputra123@gmail.com⁴, randyoktaviana2@gmail.com⁵,
mohammadbayuanggara@gmail.com⁶

Abstract

Indonesia's geographic position at the intersection of three active tectonic plates makes it one of the most seismically active countries globally. This high risk emphasizes the importance of developing an effective earthquake forecasting system to aid in disaster risk reduction. This research explores the application of the Random Forest algorithm for predicting the monthly earthquake occurrences across Indonesia. The dataset, sourced from Kaggle, consists of historical seismic records from 2008 to 2022. The methodological approach includes data preprocessing, model training, performance evaluation using Mean Absolute Error (MAE) and Root Mean Square Error (RMSE), and the presentation of results through a web-based application. The prediction model achieved satisfactory accuracy, with a monthly MAE of 187.3 and RMSE of 274.53, while the annual MAE and RMSE reached 1637.9 and 1966.09, respectively. These outcomes suggest that the Random Forest algorithm serves as a promising alternative method for estimating earthquake frequencies in Indonesia.

Keywords: earthquake forecasting, random forest, machine learning, historical data, web application

Abstrak

Letak geografis Indonesia yang berada pada pertemuan tiga lempeng tektonik aktif menjadikannya salah satu negara dengan tingkat aktivitas gempa bumi yang sangat tinggi. Kondisi ini menuntut adanya sistem prediksi yang akurat guna mendukung upaya mitigasi risiko bencana secara efektif. Penelitian ini mengkaji penggunaan algoritma *Random Forest* dalam memprediksi frekuensi gempa bumi bulanan di wilayah Indonesia. Dataset yang digunakan diambil dari platform Kaggle dan mencakup data kejadian gempa dari tahun 2008 hingga 2022. Proses penelitian meliputi tahapan pra-pemrosesan data, pelatihan model, evaluasi performa menggunakan metrik *Mean Absolute Error (MAE)* dan *Root Mean Square Error (RMSE)*, serta penyajian hasil dalam bentuk aplikasi berbasis web. Hasil evaluasi menunjukkan bahwa model memberikan performa yang cukup optimal, dengan nilai MAE bulanan sebesar 187,3 dan RMSE 274,53, serta MAE tahunan 1637,9 dan RMSE 1966,09. Temuan ini menunjukkan bahwa algoritma *Random Forest* dapat menjadi solusi alternatif yang andal untuk memprediksi jumlah gempa bumi di Indonesia.

Kata kunci: prediksi gempa bumi, random forest, pembelajaran mesin, data historis, aplikasi web

1. Pendahuluan

Indonesia berada pada zona pertemuan beberapa lempeng tektonik utama, yang menjadikannya rentan terhadap aktivitas seismik yang cukup tinggi. Gempa bumi merupakan salah satu bencana alam yang berpotensi menimbulkan kerusakan infrastruktur, kerugian ekonomi, serta membahayakan keselamatan jiwa. Intensitas gempa yang diukur menggunakan skala Richter (SR) turut memengaruhi besarnya dampak yang ditimbulkan oleh peristiwa gempa tersebut[1].

Gempa bumi termasuk dalam kategori bencana alam yang berpotensi menimbulkan dampak signifikan terhadap kehidupan manusia serta kerusakan pada infrastruktur. Indonesia memiliki aktivitas seismik yang tinggi akibat letaknya di zona pertemuan tiga lempeng tektonik utama: Indo-Australia, Eurasia, dan Pasifik.

Interaksi antar lempeng ini menyebabkan frekuensi gempa bumi yang tinggi setiap tahun [2]. Kompleksitas tektonik yang dimiliki Indonesia menyebabkan frekuensi kejadian gempa bumi yang relatif tinggi, dengan variasi intensitas yang cukup beragam [3].

Tingkat kerusakan bangunan akibat gempa sangat bergantung pada intensitas gempa, jarak dari episentrum, kualitas dan usia bangunan, serta karakteristik tanah. Gempa kuat dapat menyebabkan kerusakan struktural serius, terutama pada bangunan tanpa desain tahan gempa atau yang berdiri di atas tanah tidak stabil [4].

Berbagai pendekatan ilmiah telah digunakan untuk memprediksi gempa bumi, mulai dari metode statistik hingga simulasi fisik dan machine learning. Namun, keterbatasan metode statistik dalam menangkap

hubungan non-linear antar variabel menjadikan machine learning sebagai alternatif yang lebih adaptif [5].

Berbagai metode telah dikembangkan dalam rangka memprediksi gempa bumi, mulai dari pendekatan fisika bumi hingga metode berbasis kecerdasan buatan. Salah satu pendekatan yang banyak digunakan dalam dekade terakhir adalah model deep learning seperti Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), dan Bidirectional LSTM (BLSTM), yang terbukti efektif dalam menangani data deret waktu. Namun, metode ini memiliki kelemahan seperti kebutuhan komputasi yang tinggi, kompleksitas arsitektur model, serta rendahnya interpretabilitas model (black box) yang menyulitkan pengguna non-teknis dalam memahami proses prediksi.

Sebagai alternatif, Algoritma Random Forest merupakan salah satu algoritma machine learning yang populer dan efektif untuk menangani data non-linear. Sebagai metode ensemble, algoritma ini membangun sejumlah pohon keputusan dari data acak dan menghasilkan prediksi melalui mekanisme voting atau rata-rata [6]. Random Forest unggul dalam menangani variabel kompleks, mengurangi overfitting, dan menghasilkan akurasi tinggi. Algoritma ini juga efisien untuk data besar dan efektif dalam menangani data yang hilang [7].

Penelitian sebelumnya menunjukkan bahwa Random Forest efektif dalam prediksi seismik. Tantyoko et al. (2023) melaporkan bahwa integrasi Random Forest dengan feature selection menghasilkan F1-score sebesar 92,23% untuk klasifikasi potensi gempa di Indonesia. Sementara itu, Magono et al. (2025) menggunakan pendekatan hybrid Random Forest-MLP dan memperoleh nilai RMSE rendah dalam prediksi magnitudo gempa.

Dengan kemajuan teknologi informasi, sistem prediksi gempa kini terintegrasi dengan visualisasi data dalam aplikasi web. Integrasi ini memudahkan interpretasi hasil prediksi dan mendukung penyampaian informasi secara real-time kepada publik dan otoritas terkait [8].

Penelitian ini menerapkan algoritma Random Forest untuk memprediksi jumlah gempa bulanan di Indonesia menggunakan data Kaggle (2008–2022), melalui tahapan preprocessing, pelatihan, evaluasi, dan visualisasi dalam aplikasi web.

2. Tinjauan Pustaka

2.1 Gempa Bumi

Gempa bumi adalah pelepasan energi secara tiba-tiba akibat pergerakan kerak bumi atau patahan, yang menghasilkan gelombang seismik dan getaran tanah. Getaran ini dicatat oleh seismograf dan diukur menggunakan seismometer. Ribuan gempa kecil terjadi setiap hari tanpa dampak signifikan. Di Indonesia,

frekuensi gempa tinggi disebabkan oleh pertemuan lempeng tektonik dan aktivitas vulkanik. Secara umum, gempa bumi disebabkan oleh pergerakan lempeng, aktivitas manusia, dan letusan gunung berapi [9].

2.2 Prediksi Gempa Bumi

Prediksi gempa bumi memegang peranan penting dalam mitigasi bencana, namun masih menjadi tantangan karena kompleksitas dinamika kerak bumi dan ketidakpastian prekursor seismic [10]. Metode statistik tradisional sering kali gagal menangkap pola non-linear yang kompleks. Sebagai solusi, pendekatan Machine Learning seperti Random Forest, XGBoost, LSTM, dan CNN digunakan untuk mengelola data seismik berskala besar secara lebih akurat [11]. Di Indonesia, penelitian oleh Puspita et al. (2025) menunjukkan bahwa Random Forest mampu memetakan zona risiko gempa dengan akurasi hingga 90,8% [12].

2.3 Random Forest

Algoritma Random Forest diperkenalkan oleh Breiman (2001) sebagai teknik *ensemble learning* yang menggabungkan banyak pohon keputusan (decision trees) untuk menghasilkan prediksi yang lebih akurat dan stabil. RF bekerja dengan membangun banyak pohon dari subset data acak dan melakukan *majority voting* untuk klasifikasi atau rata-rata untuk regresi. Algoritma ini sangat efektif dalam menangani data non-linear dan tidak sensitif terhadap *outliers*.

2.4 Penerapan Random Forest dalam Prediksi Gempa

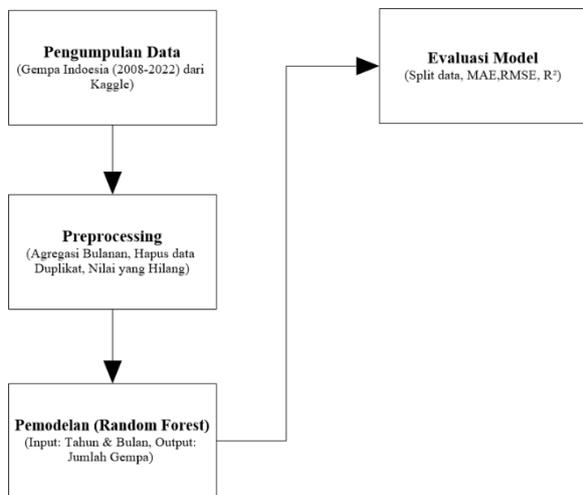
Penelitian oleh Tantyoko et al. (2023) menunjukkan bahwa algoritma Random Forest mampu memberikan akurasi tinggi dalam klasifikasi gempa bumi di Indonesia dengan F1-Score mencapai 92,23%. Handayani et al. (2024) juga mengembangkan sistem prediksi magnitudo gempa menggunakan sinyal P-Wave dan algoritma RF, menghasilkan akurasi prediksi sebesar 94,49%. Penelitian lain oleh Apriyani dan Hidayat (2023) menyatakan bahwa RF juga unggul dalam konteks prediksi kebencanaan lainnya, termasuk banjir dan cuaca ekstrem. Menurut Handayani et al. (2024), model RFmag berbasis data strong-motion BMKG mampu memprediksi magnitudo gempa secara real-time dengan akurasi 94,49% dan deviasi standar 0,36, menunjukkan potensi Random Forest dalam sistem peringatan dini [13].

2.5 Kelebihan dan Keterbatasan Random Forest

Random Forest memiliki keunggulan dalam mencegah overfitting serta mampu menghasilkan prediksi yang akurat meskipun pada data kompleks dengan banyak variabel [14]. Namun, kelemahannya adalah kebutuhan memori yang tinggi jika pohon yang dibentuk terlalu banyak, serta kurang cocok untuk prediksi jangka

panjang berbasis time-series murni dibandingkan model sekuensial seperti LSTM (Bahdanau et al., 2015; Vaswani et al., 2017).

3. Metodologi Penelitian



Gambar 1. Diagram Alur Metode Penelitian

4.1 Pengumpulan Data

Penelitian ini menggunakan dataset gempa bumi Indonesia yang diperoleh dari Kaggle. Dataset ini berisi data kejadian gempa bumi di wilayah Indonesia mulai dari tahun 2008 hingga 2022.

	date	time	latitude	longetitude	depth	magnitude
1	11/1/2008	0:31:25	-0.6	98.89553	20	2.99
2	11/1/2008	1:34:25	-6.61	129.3872	30.1	5.51
3	11/1/2008	1:38:25	-3.65	127.9907	5	3.54
4	11/1/2008	2:20:05	-4.2	128.097	5	2.42
5	11/1/2008	2:32:18	-4.09	128.2005	10	2.41
87369	9/26/2022	22:00:50	-8.15	121.3515	10	3.41
87370	9/26/2022	22:08:59	0.97	125.6301	12.1	3.29
87371	9/26/2022	22:11:43	-8.27	116.7115	10	3.38
87372	9/26/2022	22:53:16	-8.11	121.3947	10	3.49
87373	9/26/2022	23:17:38	-10.81	113.3663	10	4.9

Gambar 2. Tabel Asli

Setiap entri dalam dataset memuat informasi seperti:

- *date & time*: menunjukkan waktu terjadinya gempa bumi.
- *latitude & longitude*: menyatakan koordinat geografis lokasi pusat gempa.
- *depth*: kedalaman pusat gempa dalam satuan kilometer.
- *magnitude*: menunjukkan kekuatan gempa bumi yang diukur berdasarkan skala Richter.

Data ini kemudian diolah untuk diklasifikasikan menjadi jumlah gempa per bulan berdasarkan tahun dan bulan sebagai indeks waktu

4.2 Preprocessing Data

Tahapan preprocessing dilakukan untuk membersihkan dan menyusun ulang data agar siap digunakan dalam

model machine learning. Langkah-langkah preprocessing meliputi:

1. Penggabungan dan transformasi waktu: Kolom tanggal diubah menjadi format *datetime*, lalu dikelompokkan berdasarkan bulan dan tahun untuk menghasilkan fitur jumlah gempa per bulan.
2. Pembersihan data: Menghapus baris duplikat dan baris dengan nilai yang hilang (*missing values*).
3. Normalisasi dan agregasi: Data dianalisis per bulan, menghasilkan satu nilai jumlah gempa tiap bulan sebagai target (*label*) dan nilai rata-rata magnitudo serta kedalaman sebagai fitur (*feature*).

4.3 Algoritma Random Forest

andom Forest menggabungkan pohon keputusan dari data acak guna meningkatkan akurasi dan kestabilan prediksi secara kolektif [15]. Metode ini efektif dalam menangani data non-linear, data yang hilang, serta ketidakseimbangan variabel, dengan kebutuhan tuning parameter yang minimal.

Model RF akan dilatih untuk memprediksi jumlah gempa bulanan berdasarkan variabel input seperti: Tahun dan Bulan.

Proses training menggunakan skema supervised learning dengan pendekatan regresi.

4.4 Evaluasi Model

Model dievaluasi menggunakan metrik regresi berikut:

- **Mean Absolute Error (MAE)**: Mengukur rata-rata kesalahan absolut antara prediksi dan nilai aktual.
- **Root Mean Square Error (RMSE)**: Mengukur seberapa besar rata-rata kuadrat kesalahan prediksi.
- **R-squared (R²)**: Mengukur seberapa besar variansi target yang dapat dijelaskan oleh fitur input.

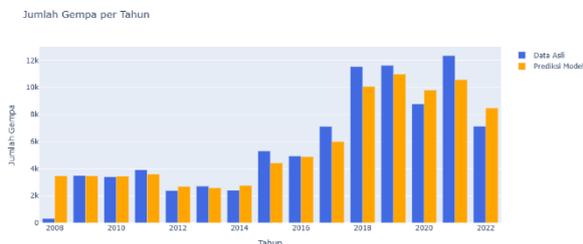
Model diuji dengan membagi data menjadi 80% data pelatihan dan 20% data pengujian (*train-test split*). *Cross-validation* 5-fold juga dilakukan untuk menghindari bias pada pembagian data dan meningkatkan generalisasi model.

4. Hasil dan Pembahasan

4.1 Hasil Prediksi Jumlah Gempa Tahunan

Gambar 1 menampilkan hasil agregasi tahunan antara data aktual dan prediksi model. Prediksi model menunjukkan akurasi yang lebih baik secara tahunan dibanding bulanan, dengan pola tren yang relatif mirip, terutama pada tahun-tahun dengan jumlah gempa tinggi seperti 2017–2019.

Pada tahun 2018, baik data aktual maupun hasil prediksi menunjukkan peningkatan tajam, yang menandakan model mampu mengantisipasi tren makro secara tahunan. Namun, pada beberapa tahun seperti 2022, model memprediksi jumlah gempa lebih tinggi dibandingkan data aktual.

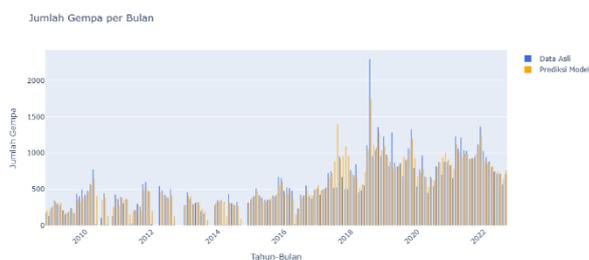


Gambar 3. Grafik Jumlah Gempa per Tahun (2008–2022): Data Aktual vs Prediksi Model Random Forest

4.2 Hasil Prediksi Jumlah Gempa Bulanan

Gambar 2 menunjukkan perbandingan antara jumlah gempa aktual dan hasil prediksi model Random Forest dalam skala bulanan dari tahun 2008 hingga 2022. Model ini dilatih menggunakan fitur-fitur historis seperti magnitudo, kedalaman, lokasi episenter, dan waktu kejadian untuk memprediksi jumlah kejadian gempa pada setiap bulan.

Dari visualisasi, terlihat bahwa tren jumlah gempa per bulan berhasil diikuti dengan cukup baik oleh model, meskipun terdapat beberapa lonjakan (outlier) yang tidak sepenuhnya terprediksi secara akurat—terutama pada periode 2018 yang menunjukkan lonjakan signifikan pada data aktual.



Gambar 4. Grafik Jumlah Gempa per Bulan (2008–2022): Data Aktual vs Prediksi Model Random Forest

4.3 Evaluasi Kinerja Model

Model Random Forest yang dikembangkan dievaluasi menggunakan dua skala: tahunan dan bulanan, dengan metrik utama Mean Absolute Error (MAE) dan Root Mean Square Error (RMSE).

Tabel 1 hasil evaluasi menunjukkan performa sebagai berikut:

Tabel 1. Evaluasi Kinerja Model Berdasarkan Skala Waktu

Skala Evaluasi	MAE	RMSE
Tahunan	1637,9	1966,09
Bulanan	187,3	274,53

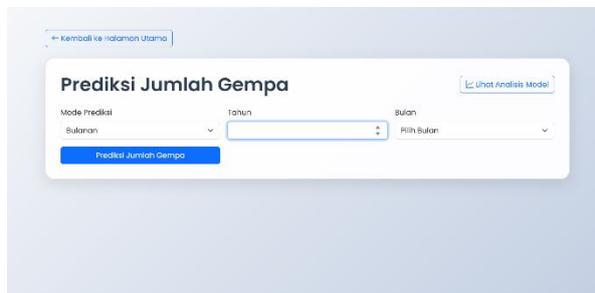
- Pada skala tahunan, RMSE sebesar 1966,09 mengindikasikan bahwa meskipun model cukup akurat dalam mempelajari tren umum, masih terdapat deviasi yang cukup besar di beberapa tahun dengan jumlah gempa ekstrem.
- Pada skala bulanan, nilai MAE sebesar 187,3 menandakan rata-rata kesalahan absolut prediksi sebanyak ±187 kejadian gempa tiap bulan. Nilai ini cukup rendah mengingat variasi bulanan yang tinggi.

Secara keseluruhan, model memiliki kinerja prediktif yang layak untuk tujuan early warning dan estimasi tren.

4.4 Implementasi dalam Aplikasi Web

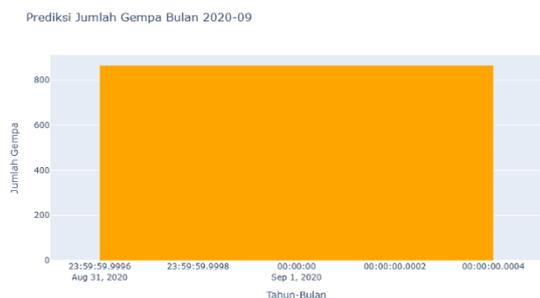
Sebagai bagian dari kontribusi praktis, hasil model diimplementasikan dalam bentuk aplikasi web berbasis antarmuka pengguna (UI) sederhana. Aplikasi ini menyediakan pilihan untuk melakukan prediksi jumlah gempa berdasarkan:

- Mode prediksi: Bulanan
- Input pengguna: Tahun dan bulan
- Output: Jumlah gempa yang diprediksi untuk periode tersebut



Gambar 5. Tampilan Aplikasi Prediksi Jumlah Gempa

Sebagai contoh, ketika pengguna memilih bulan September tahun 2020, sistem memprediksi akan terjadi sebanyak 865 kejadian gempa bumi. Nilai prediksi ini ditampilkan secara real-time pada halaman aplikasi, disertai dengan grafik batang sebagai visualisasi tambahan. Gambar 4 berikut menunjukkan tampilan grafik prediksi untuk bulan tersebut.



Gambar 6. Grafik Prediksi Jumlah Gempa Bulan September 2020

Untuk memudahkan akses, aplikasi web ini dapat digunakan melalui tautan berikut:

<https://web-prediksi-gempa-production.up.railway.app/>

5. Kesimpulan dan Saran

5.1 Kesimpulan

Penelitian ini bertujuan untuk membangun model prediksi jumlah gempa bumi bulanan di Indonesia dengan memanfaatkan algoritma Random Forest. Berdasarkan hasil evaluasi dan analisis, dapat disimpulkan bahwa:

1. Algoritma Random Forest mampu memodelkan pola historis jumlah gempa bumi secara efektif, baik dalam skala bulanan maupun tahunan.
2. Model memberikan hasil evaluasi dengan nilai MAE bulanan sebesar 187,3 dan RMSE bulanan sebesar 274,53, menunjukkan bahwa model cukup akurat untuk digunakan sebagai alat bantu dalam sistem peringatan dini gempa bumi.
3. Implementasi model dalam bentuk aplikasi web interaktif menjadikan prediksi lebih mudah diakses dan digunakan oleh pengguna non-teknis.
4. Dibandingkan dengan metode deep learning seperti LSTM, pendekatan Random Forest memberikan keunggulan dari sisi interpretabilitas, efisiensi, dan ketahanan terhadap overfitting, terutama saat jumlah data terbatas.

5.2 Saran

Berdasarkan hasil penelitian ini, beberapa saran yang dapat diberikan untuk pengembangan lebih lanjut adalah:

1. Pengembangan lebih lanjut dapat mencakup integrasi data spasial (koordinat, kedalaman, lokasi lempeng tektonik) untuk meningkatkan akurasi dan cakupan prediksi.
2. Model dapat ditingkatkan dengan menerapkan teknik ensemble lainnya atau metode hybrid seperti RF+MLP atau RF+SVR.
3. Perlu dilakukan pengujian sistem prediksi secara real-time menggunakan data terbaru dari BMKG

agar dapat diintegrasikan dengan sistem mitigasi bencana nasional.

4. Sumber data dapat diperluas mencakup sensor gempa lokal dan satelit untuk memperkaya fitur input model.
5. Disarankan untuk melakukan penelitian lanjutan menggunakan metodologi explainable AI (XAI) agar hasil prediksi lebih transparan dan dapat dijelaskan secara logis kepada pembuat kebijakan.

Daftar Rujukan

- [1] Roni Merdiansah, Khofifah Wulandari, Mentari Hasibuan, and Yuyun Umaidah, "Perbandingan Kinerja Model RNN, LSTM, dan BLSTM dalam Memprediksi Jumlah Gempa Bulanan di Indonesia," *Jurnal Penelitian Rumpun Ilmu Teknik*, vol. 3, no. 1, pp. 262–277, Feb. 2024, doi: 10.55606/juprit.v3i1.3466.
- [2] M. A. Kurniawan, S. K. Wijaya, and N. R. Hanifa, "Convolutional Neural Network for Earthquake Ground Motion Prediction Model in Earthquake Early Warning System in West Java," *Jurnal Penelitian Pendidikan IPA*, vol. 9, no. 11, pp. 1004–1010, Nov. 2023, doi: 10.29303/jppipa.v9i11.3514.
- [3] 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](http://jom.fti.budiluhur.ac.id/index.php/IDEALIS/index)
- [4] F. Fakhrrurrozi *et al.*, "Prediksi Kerusakan Bangunan Pasca Gempa Bumi Menggunakan Metode Deep Neural Network," *Jurnal Teknologi Sistem Informasi dan Aplikasi*, vol. 7, no. 1, pp. 131–142, Jan. 2024, doi: 10.32493/jtsi.v7i1.37181.
- [5] A. Novianty, A. L. Prasasti, and R. E. Saputra, "Early Estimation of Earthquake Magnitude Using Machine Learning," *IJAIT (International Journal of Applied Information Technology)*, vol. 07, no. 02, 2023, doi: 10.25124/ijait.v7i02.5994.
- [6] I. M. Murwantara, P. Yugopuspito, and R. Hermawan, "Comparison of machine learning performance for earthquake prediction in Indonesia using 30 years historical data," *Telkonnika (Telecommunication Computing Electronics and Control)*, vol. 18, no. 3, pp. 1331–1342, 2020, doi: 10.12928/TELKOMNIKA.v18i3.14756.
- [7] A. Fauzan and D. Ahmad, "ANALISIS HASIL PREDIKSI MAGNITUDO GEMPA DI WILAYAH KOTA PADANG MENGGUNAKAN TEKNIK RANDOM FOREST," *Jurnal Lebesgue: Jurnal Ilmiah Pendidikan Matematika, Matematika dan Statistika*, vol. 4, no. 3, pp. 1569–1576, Dec. 2023, doi: 10.46306/lb.v4i3.450.

- [8] H. Kubo, M. Naoi, and M. Kano, "Recent advances in earthquake seismology using machine learning," *Earth, Planets and Space*, vol. 76, no. 1, Dec. 2024, doi: 10.1186/s40623-024-01982-0.
- [9] R. Maharani, A. Hutagaol, V. Tesalonika Lana, Z. A. Dzunnurain, and R. Kurniawan, "Penerapan Machine Learning dalam Prediksi Klasifikasi Big Data Kedalaman Gempa Bumi di Indonesia Tahun 2015-2024," *Seminar Nasional Sains Data*, vol. 2024.
- [10] A. Mignan and M. Broccardo, "Meta-Analytic Insight on their Limitations."
- [11] S. M. Mousavi and G. C. Beroza, "Machine Learning in Earthquake Seismology," vol. 28, p. 15, 2025, doi: 10.1146/annurev-earth-071822.
- [12] D. D. Puspita, S. Steffi, G. Hoendarto, and J. Tjen, "Random Forest Analysis for Predicting the Probability of Earthquake in Indonesia," *Social Science and Humanities Journal*, vol. 9, no. 01, pp. 6295–6304, Jan. 2025, doi: 10.18535/sshj.v9i01.1574.
- [13] T. Handayani, Wijayanto, A. Wijaya, L. Himantara, A. H. Saputro, and D. Djuhana, "Machine Learning Implementation for Estimation of Earthquake Magnitude Using Strong-Motion Data," in *2024 4th International Conference on Robotics, Automation and Artificial Intelligence (RAAI)*, IEEE, Dec. 2024, pp. 351–355. doi: 10.1109/RAAI64504.2024.10949525.
- [14] T. P. M. Wardhani, Z. Tahir, E. Warni, A. Bustamin, M. A. F. Imran Oemar, and M. A. Kayyum, "Deep learning approach in seismology: Enhancing earthquake forecasting using K-means clustering and LSTM networks," *Journal of Information and Communication Technology*, vol. 24, no. 1, pp. 29–51, 2025, doi: 10.32890/jict.
- [15] H. A. Salman, A. Kalakech, and A. Steiti, "Random Forest Algorithm Overview," *Babylonian Journal of Machine Learning*, vol. 2024, pp. 69–79, Jun. 2024, doi: 10.58496/bjml/2024/007.
- [16] Titan, G. (2023). Indonesia Earthquake Data (2008–2022). Kaggle. <https://www.kaggle.com/datasets/greetitan/indonesia-earthquake-data>