


Terbit online pada laman: <http://jurnal.utu.ac.id/JTI>**Jurnal Teknologi Informasi**

|ISSN (Online): 2829-8934|



Analisis Kinerja Algoritma *Long Short-Term Memory* (LSTM) untuk Prediksi Gempa Bumi di Aceh

Miya Amalia Putri¹, Rivansyah Suhendra², Abdurrahman Ridho³

1,2,3 Program Studi Teknologi Informasi, Universitas Teuku Umar, Aceh Barat, Indonesia
 Jl. Alue Peunyareng, Ujong Tanoh Darat, Meurebo, Kabupaten Aceh Barat, Aceh, Indonesia
 Email: ¹miyaamaliaputri@gmail.com, ²rivansyahsuhendra@utu.ac.id, ³abdurrahman.ridho@utu.ac.id

INFORMASI ARTIKEL

Sejarah Artikel:
 Diterima: 17 Juli 2025
 Revisi: 22 Oktober 2025
 Diterbitkan: 30 Oktober 2025

Kata Kunci:
 Long Short-Term Memory (LSTM)
 Prediksi Gempa Bumi
 Time Series
 Aceh
 Hyperparameter Tuning

ABSTRAK

Aceh merupakan wilayah dengan tingkat aktivitas seismik tinggi karena berada di jalur subduksi aktif antara Lempeng Indo-Australia dan Eurasia. Prediksi gempa bumi di wilayah ini menjadi tantangan karena karakteristik data seismik yang kompleks, tidak linier, dan tidak stasioner. Penelitian ini bertujuan untuk mengembangkan model prediksi magnitudo gempa bumi harian menggunakan algoritma Long Short-Term Memory (LSTM). Data historis gempa dari United States Geological Survey (USGS) periode 2000 hingga 2025 diolah melalui tahap resampling harian, normalisasi, dan pembentukan data sekuensial menggunakan pendekatan *sliding window*. Sebanyak 72 kombinasi hyperparameter diuji untuk mengoptimalkan performa model, mencakup variasi *units*, *batch size*, *learning rate*, dan jumlah *epoch*. Evaluasi dilakukan menggunakan metrik RMSE, MAE, dan koefisien korelasi Pearson (*r*). Hasil terbaik diperoleh pada konfigurasi 64 *units*, *batch size* 16, *learning rate* 0.0005, dan 60 *epoch* dengan RMSE sebesar 0.16291, MAE sebesar 0.09046, dan *r* sebesar 0.83116. Hasil ini menunjukkan bahwa LSTM mampu mengenali pola temporal aktivitas seismik secara efektif. Penelitian ini mendukung pemanfaatan LSTM sebagai komponen dalam sistem mitigasi bencana dan peringatan dini berbasis data di wilayah rawan gempa seperti Aceh.

Copyright © 2025 Jurnal Teknologi Informasi UTU
 All rights reserved

1. Pendahuluan


Indonesia merupakan salah satu negara yang berada pada zona tektonik paling aktif di dunia karena pertemuannya dengan tiga lempeng utama, yaitu Indo-Australia, Eurasia, dan Pasifik. Konvergensi ketiga lempeng ini menjadikan wilayah Indonesia, khususnya bagian barat Sumatera, rawan terhadap gempa bumi berkekuatan tinggi dan berulang [1]. Provinsi Aceh, yang terletak di jalur subduksi aktif antara Lempeng Indo-Australia dan Eurasia, menjadi salah satu kawasan dengan tingkat seismisitas tertinggi di Indonesia [2]. Keberadaan patahan-patahan aktif seperti segmen Aceh dan Seulimeum dari Patahan Sumatera, serta zona subduksi di lepas pantai barat, merupakan pemicu utama aktivitas gempa yang sangat intens di wilayah ini. Tingkat seismisitas tinggi inilah yang dibuktikan oleh sejarah bencana gempa dan tsunami Aceh 2004 sebagai salah satu peristiwa paling mematikan dalam sejarah modern, dengan lebih dari 227.000 korban jiwa [3].

Hingga saat ini, aktivitas gempa di wilayah tersebut masih berlangsung, seperti yang tercatat pada Januari 2025 dengan magnitudo 5,9. Fakta ini menunjukkan bahwa Aceh merupakan wilayah dengan risiko gempa tinggi yang memerlukan pendekatan mitigasi bencana yang adaptif dan berbasis teknologi.

Namun demikian, prediksi gempa bumi tetap menjadi tantangan besar karena sifat data seismik yang kompleks, bersifat non-linier, tidak stasioner, dan sering kali mengandung noise tinggi [4]. Data

gempa juga bersifat tidak beraturan secara waktu dan amplitudo, dengan keterkaitan spasio-temporal yang kuat namun tidak eksplisit. Metode konvensional, baik berbasis statistik maupun pendekatan probabilistik, masih terbatas dalam mengenali pola laten dalam data seismik yang berfluktuasi [5]. Oleh karena itu, pendekatan baru berbasis *machine learning* dan *deep learning* mulai digunakan secara luas dalam kajian prediksi gempa bumi.

Salah satu pendekatan *deep learning* yang menjanjikan adalah algoritma *Long Short-Term Memory* (LSTM), yang merupakan varian dari *Recurrent Neural Network* (RNN) dan dirancang khusus untuk mempelajari hubungan jangka panjang dalam data sekuensial. LSTM mampu menyimpan informasi relevan dalam memori jangka panjang dan mengabaikan informasi yang tidak penting melalui mekanisme *gate* [6]. Kemampuan ini menjadikan LSTM sangat efektif dalam menangani data deret waktu seperti data seismik, yang memiliki pola temporal yang sulit dikenali secara manual.



Gambar 1. Struktur *Long Short-Term Memory* (LSTM)

(Sumber:[11])

$$f_t = \sigma(W_f \cdot |h_{t-1}, x_t| + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot |h_{t-1}, x_t| + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot |h_{t-1}, x_t| + b_c) \quad (3)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (4)$$

$$o_t = \sigma(W_o \cdot |h_{t-1}, x_t| + b_o) \quad (5)$$

$$h_t = o_t \odot \tanh C_t \quad (6)$$

Keterangan :

- x_t : Vektor input pada *time step* t .
- h_t : Vektor *hidden state* (output) pada *time step* t .
- c_t : Vektor *cell state* (memori jangka panjang) pada *time step* t .
- $w_{f,i,c,o}$: Matriks bobot (*Weight Matrices*) untuk *Forget Gate*, *Input Gate*, *Cell State Kandidat*, dan *Output Gate*.
- $b_{f,i,c,o}$: Vektor *Bias* untuk masing-masing *gate*.
- σ : Fungsi aktivasi Sigmoid.
- $\tanh$: Fungsi aktivasi Tangen Hiperbolik.
- $\odot$: Perkalian *element-wise*.

Persamaan di atas merepresentasikan operasi matematika pada unit *Long Short-Term Memory* (LSTM), yang dirancang khusus untuk mempelajari ketergantungan jangka panjang dalam data deret waktu. Persamaan ini mengatur mekanisme tiga *gate* utama (*Forget*, *Input*, dan *Output*) yang mengontrol aliran informasi ke dalam dan keluar dari sel memori (*Cell State*). Tujuan persamaan di atas adalah sebagai berikut:

Tabel 1. Tujuan Operasi Persamaan LSTM

Persamaan	Gate/Proses	Tujuan
1	Forget Gate (f_t)	Menentukan seberapa banyak informasi dari <i>cell state</i> sebelumnya (c_{t-1}) yang harus dibuang (dilupakan).
2	Input Gate (i_t)	Menentukan nilai-nilai baru yang akan diperbarui ke dalam <i>cell state</i> .
3	Vektor Kandidat ($\tilde{c}_t$)	Menciptakan vektor nilai kandidat yang akan ditambahkan ke <i>cell state</i> .
4	Update Cell State (c_t)	Memperbarui <i>cell state</i> dengan menggabungkan informasi yang dipertahankan dan informasi baru.
5	Output Gate (o_t)	Menentukan bagian mana dari <i>cell state</i> yang akan diungkap sebagai <i>hidden state</i> (output).
6	Hidden State (h_t)	Menghasilkan <i>hidden state</i> yang merupakan output unit LSTM saat ini.

Penelitian sebelumnya telah menunjukkan efektivitas LSTM dalam berbagai aplikasi prediksi gempa. Fazira dkk, menunjukkan bahwa LSTM memberikan galat yang lebih rendah dibanding RNN standar dalam memprediksi gempa bumi di Indonesia [7]. Bahkan menambahkan *attention mechanism* pada LSTM dilakukan untuk meningkatkan kemampuan model dalam mengenali anomali dan pola minor, yang sangat krusial dalam konteks prediksi bencana [8]. Studi lain yang menggunakan varian BiLSTM dan Transformer juga menunjukkan peningkatan akurasi dalam mengenali korelasi temporal yang kompleks [9], [10].


Namun, kebanyakan studi dilakukan di luar konteks wilayah Aceh secara spesifik, atau hanya terbatas pada model tanpa eksplorasi mendalam terhadap *hyperparameter tuning* yang dapat meningkatkan performa model. Belum banyak penelitian yang memfokuskan pada pengembangan dan evaluasi model LSTM secara sistematis untuk wilayah Aceh dengan data historis jangka panjang.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model LSTM dalam memprediksi magnitudo gempa bumi di Aceh menggunakan data historis dari tahun 2000 hingga 2025. Penelitian ini juga mengeksplorasi kombinasi *hyperparameter* yang optimal (jumlah *unit*, *batch size*, *learning rate*, dan *epoch*) untuk memperoleh akurasi tertinggi. Evaluasi dilakukan menggunakan metrik RMSE, MAE, dan koefisien korelasi Pearson (r) untuk mengukur akurasi dan kemampuan generalisasi model.

Dengan pendekatan ini, diharapkan hasil penelitian dapat memberikan kontribusi nyata terhadap pengembangan sistem peringatan dini berbasis data di wilayah rawan gempa seperti Aceh, serta menjadi referensi penting dalam pemanfaatan LSTM untuk permasalahan prediksi geofisika di Indonesia.

2. Metodologi Penelitian

Penelitian ini dilakukan dengan beberapa tahapan utama yang dirancang secara sistematis, mulai dari akuisisi data seismik historis hingga evaluasi kinerja model akhir. Keseluruhan rangkaian proses penelitian, termasuk tahapan pra-pemrosesan data, perancangan arsitektur LSTM, dan evaluasi model, diilustrasikan secara komprehensif pada Gambar 2.



Gambar 2. Alur Penelitian

Gambar 2. menyajikan alur lengkap metodologi penelitian yang digunakan dalam studi ini, mulai dari akuisisi data hingga tahap visualisasi hasil. Proses ini dibagi menjadi lima tahap utama yang dijelaskan lebih lanjut sebagai berikut:

2.1 Pra-pemrosesan Data

2.1.1 Load Data


Penelitian ini dimulai dengan pengumpulan data gempa bumi di wilayah Aceh dari *United States Geological Survey* (USGS) untuk periode 1 Januari 2000 hingga 1 Januari 2025. Dataset awal difilter untuk menghapus entri dengan lokasi tidak spesifik, menghasilkan 4.039 catatan yang merepresentasikan kejadian gempa aktual secara individual. Data mencakup waktu kejadian, magnitudo, kedalaman, serta koordinat geografis. Berdasarkan eksplorasi data, sebelum proses resampling, data bersifat tidak teratur secara temporal karena bergantung pada frekuensi kejadian gempa. Setelah dilakukan resampling harian dengan metode rata-rata (*daily mean*), jumlah entri meningkat menjadi 9.121, membentuk deret waktu yang seragam.

Tabel 2. Sampel Data Gempa Bumi Wilayah Aceh

Time	Place	Magnitude	Longitude	Latitude	Depth
2000-01-06 00:56:17.590	41 km SE of Singkil, Indonesia	5.1	98.041	2.01	33.0
2000-03-03 01:21:06.670	15 km SE of Sigli, Indonesia	4.6	96.067	5.295	189.0
2000-03-04 18:13:21.490	42 km SE of Meulaboh, Indonesia	3.8	96.431	3.905	33.0

2000-03-07 18:49:17.590	59 km S of Meulaboh, Indonesia	4.8	96.101	3.605	76.7
2000-03-10 21:32:12.670	61 km SSW of Reuleuet, Indonesia	5.5	96.007	4.738	33.0

Struktur data awal yang mencakup fitur-fitur utama yang dikumpulkan dari USGS, seperti waktu kejadian, magnitudo, dan koordinat geografis, diilustrasikan pada Tabel 2.



Gambar 3. Perbandingan Magnitudo Sebelum Dan Sesudah *Resampling*

Gambar 3 secara visual mengonfirmasi bahwa proses *resampling* berhasil mengubah data gempa yang tidak teratur (*sparse*) menjadi deret waktu harian yang seragam dan berkelanjutan. Meskipun metode rata-rata harian (*daily mean*) menghasilkan sedikit penyesuaian pada magnitudo puncak, pola tren aktivitas seismik jangka panjang tetap dipertahankan dengan baik. Data yang telah di-resampling ini selanjutnya siap untuk diproses pada tahap penanganan nilai nol untuk menjaga kontinuitas temporal.

2.1.2 Penanganan Dominasi Nol

Magnitudo bernilai 0 dianggap sebagai tidak ada gempa atau data kosong, sehingga diubah menjadi NaN dan diisi ulang dengan metode *forward fill* untuk menjaga kontinuitas temporal. Sementara itu, nilai kosong pada *depth*, *latitude*, dan *longitude* diisi dengan 0 sebagai pendekatan sederhana, karena hanya berfungsi sebagai fitur tambahan, bukan target prediksi.

2.1.3 Normalisasi

Seluruh fitur dinormalisasi ke rentang [0, 1] menggunakan metode *MinMaxScaler* dari *Scikit-learn*. Proses ini penting untuk memastikan kestabilan dan konvergensi model LSTM, karena skala data yang bervariasi dapat mempengaruhi efektivitas pelatihan. Objek *scaler* disimpan menggunakan *joblib* untuk keperluan transformasi data uji di masa mendatang.

2.1.4 Pembentukan Data Sekuensial

Data yang telah dinormalisasi dikonversi menjadi format input-output sekuensial menggunakan pendekatan *sliding window* sepanjang 30 hari. Artinya, setiap baris input (x) terdiri dari 30 hari berturut-turut data (*mag*, *depth*, *latitude*, *longitude*), dan target output (y) adalah nilai magnitudo hari ke-31. Secara formal, pasangan input-output dibentuk sebagai:

$$X_t = [x_t, x_{t+1}, \dots, x_{t+29}], \quad y_t = \text{mag}_{t+30}$$

di mana x_t adalah vektor fitur harian pada waktu t . Fungsi `make_sequence()` diimplementasikan untuk mengekstrak pasangan data dari dataframe menjadi array *NumPy* yang dapat langsung digunakan sebagai input model LSTM. Hasilnya, diperoleh tensor

berdimensi tiga $(n, 30, 4)$ untuk input, dan vektor target berdimensi $(n,)$ untuk prediksi magnitudo.

2.2 Perancangan Arsitektur Model LSTM

Model prediksi dirancang menggunakan *arsitektur Long Short-Term Memory* (LSTM), yang cocok untuk menangani data deret waktu dengan ketergantungan jangka panjang. Arsitektur terdiri atas lapisan input, satu atau lebih LSTM *layer* yang menangkap informasi temporal, *dropout layer* untuk mencegah *overfitting*, *dense layer* sebagai output, dan fungsi aktivasi non-linear (seperti ReLU atau sigmoid).

2.3 Pelatihan dan Validasi Model

Data sekuensial yang telah dibentuk dibagi menjadi dua bagian: 80% untuk pelatihan dan 20% untuk pengujian. Model dilatih menggunakan fungsi kerugian *Mean Squared Error* (MSE) dan dioptimalkan menggunakan algoritma Adam. Validasi dilakukan selama pelatihan dengan validation split sebesar 20% dari data pelatihan. Seluruh eksperimen dijalankan dalam lingkungan *Google Colab* menggunakan pustaka *TensorFlow* dan *Keras*.

2.4 Evaluasi Model

Setelah pelatihan selesai, model dievaluasi menggunakan tiga metrik evaluasi regresi: Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), dan koefisien korelasi Pearson (r). Metrik ini digunakan untuk mengukur tingkat kesalahan dan korelasi antara nilai prediksi dan nilai aktual. Persamaan formal untuk metrik-metrik tersebut adalah sebagai berikut:

1. Root Mean Squared Error (RMSE)

Metrik ini mengukur akar kuadrat dari rata-rata selisih kuadrat antara nilai aktual dan nilai prediksi. RMSE memberikan bobot yang lebih besar pada galat yang besar (*outliers*).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

2. Mean Absolute Error (MAE)

Metrik ini mengukur rata-rata nilai absolut dari selisih antara nilai aktual dan nilai prediksi. MAE memberikan representasi langsung dari rata-rata besar galat (error) model.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

3. Koefisien Korelasi Pearson (r)

Metrik ini mengukur kekuatan dan arah hubungan linier antara nilai aktual (y) dan nilai prediksi ($\hat{y}$). Nilai r berada pada rentang $[-1, 1]$, di mana nilai mendekati 1 menunjukkan korelasi positif yang kuat.

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \cdot \sum (y_i - \bar{y})^2}} \quad (9)$$

Keterangan :

x_i : nilai aktual

y_i : nilai prediksi

$\bar{x}$: rata-rata nilai aktual

$\bar{y}$: rata-rata nilai prediksi

2.5 Visualisasi dan Interpretasi Hasil

Untuk memahami performa model secara visual, dilakukan visualisasi hasil dalam bentuk grafik. Visualisasi yang dihasilkan mencakup grafik prediksi vs aktual, analisis residual, serta distribusi error. Grafik ini membantu mengidentifikasi apakah model mampu menangkap tren data, serta apakah terdapat bias atau pola error tertentu dalam prediksi magnitudo gempa harian.

3. Hasil dan Pembahasan

3.1 Evaluasi Model

Penelitian ini secara sistematis melakukan eksplorasi terhadap kombinasi hyperparameter model LSTM untuk memaksimalkan akurasi prediksi magnitudo gempa bumi harian. Empat parameter utama yang dituning adalah sebagai berikut:

Tabel 3. Kombinasi *Hyperparameter*

Parameter	Nilai yang Diuji
<i>Hidden units</i>	16, 32, 64
<i>Batch size</i>	16, 32
<i>Learning rate</i>	0.001, 0.0005
<i>Epoch</i>	50, 60, 70, 80, 90, 100

Tabel 3. merupakan daftar hyperparameter utama dari model *Long Short-Term Memory* (LSTM) yang dieksplorasi dan diuji dalam penelitian untuk mencari konfigurasi yang memberikan akurasi prediksi tertinggi. Proses pengujian ini dikenal sebagai *Hyperparameter Tuning*. Dengan menguji semua variasi nilai yang tercantum, penelitian ini secara total menguji 72 kombinasi model.


Tabel 4. Hasil Tuning Terbaik Berdasarkan RMSE

Units	Batch	LR	Epoch	RMSE	MAE	r
64	16	0.0005	60	0.16291	0.09046	0.83116
32	16	0.0005	100	0.16208	0.08650	0.83062
64	16	0.001	100	0.16210	0.08539	0.83060
64	16	0.001	60	0.16212	0.08690	0.83058
32	32	0.001	100	0.16243	0.08758	0.83035

Hasil dari seluruh batch dibandingkan untuk menemukan model dengan performa terbaik. Ditemukan bahwa kombinasi LSTM dengan 64 *unit*, *batch size* 16, *learning rate* 0.0005, dan 60 *epoch* menghasilkan performa paling optimal, dengan nilai RMSE: 0.16291, MAE: 0.09046, dan r: 0.83 pada data uji.


3.2 Visualisasi Hasil Prediksi Model LSTM Terbaik

Setelah diperoleh model terbaik dari hasil tuning 72 kombinasi, dilakukan visualisasi untuk menilai performa model secara lebih menyeluruh dari segi akurasi, kestabilan, dan karakteristik galat prediksi.




Gambar 4. Kurva Pembelajaran Model LSTM Terbaik: *Loss* (MSE) terhadap *Epoch*.

Gambar 4. Menunjukkan bahwa nilai *loss* pada data pelatihan menurun tajam pada *epoch* awal dan kemudian melandai, menunjukkan konvergensi yang baik. Sementara itu, *loss* pada data validasi cenderung stabil dan tidak menunjukkan kenaikan signifikan, menandakan model tidak mengalami *overfitting*.




Gambar 5. Grafik Perbandingan Prediksi vs Aktual Magnitudo Gempa

Dari gambar 5, secara visual model mampu mengikuti pola aktual dengan cukup baik, meskipun terdapat beberapa deviasi pada lonjakan magnitudo tinggi. Mayoritas prediksi bergerak dalam rentang magnitudo 4.0–5.5, yang konsisten dengan distribusi data sebenarnya. Hal ini menunjukkan bahwa model LSTM cukup efektif dalam menangkap tren umum aktivitas seismik harian di wilayah Aceh. Meskipun demikian, prediksi pada nilai ekstrem masih perlu ditingkatkan melalui pendekatan lanjutan seperti optimasi arsitektur atau penambahan fitur eksternal. Secara keseluruhan, hasil ini memberikan indikasi bahwa model memiliki potensi untuk diterapkan dalam sistem peringatan dini berbasis data historis.




Gambar 6. Distribusi Residual (Aktual – Prediksi) pada Data Uji

Gambar 6. memperlihatkan histogram residual, yakni selisih antara nilai aktual dan prediksi. Galat terbesar cenderung berada di sekitar nol, menunjukkan distribusi yang relatif simetris. Namun, terdapat sedikit skew ke kanan (positif), mengindikasikan kecenderungan model untuk sedikit mengunderestimate magnitudo.



Gambar 7. Plot Residual terhadap Waktu (Aktual – Prediksi).

Gambar 7. menunjukkan plot residual terhadap waktu. Titik-titik residual umumnya tersebar dekat garis nol dengan variasi naik turun yang wajar, tanpa pola berulang yang mengindikasikan autocorrelation. Namun, beberapa outlier besar muncul secara sporadis, terutama pada rentang waktu gempa besar yang jarang terjadi.



Gambar 8. Rata-Rata Nilai RMSE, MAE, dan R pada Evaluasi Kinerja Model LSTM

Terakhir, Gambar 8 menyajikan ringkasan performa model dalam bentuk grafik batang. Model terbaik mencatat nilai RMSE sebesar 0.164, MAE sebesar 0.090, dan koefisien korelasi Pearson (r) sebesar 0.829. Angka ini menunjukkan bahwa model memiliki kemampuan prediktif yang cukup baik dalam menangkap pola magnitudo harian.

Secara keseluruhan, kelima visualisasi ini mendukung hasil kuantitatif dan menunjukkan bahwa model LSTM yang dibangun cukup akurat dalam mempelajari pola aktivitas seismik di wilayah Aceh, meskipun masih ada ruang untuk perbaikan pada prediksi ekstrem.

4. Kesimpulan

Penelitian ini membuktikan bahwa algoritma *Long Short-Term Memory* (LSTM) efektif dalam memprediksi magnitudo gempa bumi harian di Aceh berdasarkan data historis. Model terbaik diperoleh dari hasil tuning 72 kombinasi hyperparameter, dengan konfigurasi 64 *units*, *batch size* 16, *learning rate* 0.0005, dan 60 *epoch*. Evaluasi pada data uji menghasilkan nilai RMSE sebesar 0.16291, MAE sebesar 0.09046, dan korelasi (r) sebesar 0.83116. Hasil ini menunjukkan bahwa LSTM mampu mengenali pola seismik dengan akurasi tinggi, tanpa indikasi *overfitting*, serta memiliki distribusi galat yang stabil. Temuan ini mendukung potensi LSTM sebagai model prediktif dalam sistem mitigasi bencana dan peringatan dini gempa di wilayah rawan seperti Aceh.

Daftar Pustaka

- [1] S. J. Hutchings and W. D. Mooney, "The Seismicity of Indonesia and Tectonic Implications," *Geochemistry, Geophysics, Geosystems*, vol. 22, no. 9, Sep. 2021, doi: 10.1029/2021GC009812.
- [2] R. Tauladani, N. Ismail, and D. Sugianto, "Kajian Seismisitas Dan Periode Ulang Gempa Bumi Di Aceh," *Pascasarjana Universitas Syiah Kuala*, vol. 7, no. 1, pp. 44–50, 2015.
- [3] I. Rusydy *dkk.*, "Shallow crustal earthquake models, damage, and loss predictions in Banda Aceh, Indonesia," *Geoenvironmental Disasters*, vol. 7, no. 1, Dec. 2020, doi: 10.1186/s40677-020-0145-5.
- [4] S. Bloemheugel, J. van den Hoogen, D. Jozinović, A. Michelini, and M. Atzmueller, "Graph neural networks for multivariate time series regression with application to seismic data," *Int J Data Sci Anal*, vol. 16, no. 3, pp. 317–332, Sep. 2023, doi: 10.1007/s41060-022-00349-6.
- [5] C. Wang, C. Li, S. Yong, X. Wang, and C. Yang, "Time Series and Non-Time Series Models of Earthquake Prediction Based on AETA Data: 16-Week Real Case Study," *Applied Sciences (Switzerland)*, vol. 12, no. 17, Sep. 2022, doi: 10.3390/app12178536.
- [6] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," 1997.
- [7] R. Fazira, D. Yudistira, and L. Sofinah Harahap, "Evaluasi Kinerja Model RNN & LSTM untuk Prediksi Magnitude Gempa di Indonesia," *Mars : Jurnal Teknik Mesin, Industri, Elektro Dan Ilmu Komputer*, vol. 2, no. 6, pp. 62–75, Nov. 2024, doi: 10.61132/mars.v2i6.498.
- [8] M. A. Rusho, R. Azizova, D. Mykhalevskiy, M. Karyonov, and H. Hasanova, "Advanced Earthquake Prediction: Unifying Networks, Algorithms, And Attention-Driven Lstm Modelling," *International Journal of GEOMATE*, vol. 27, no. 119, pp. 135–142, Jul. 2024, doi: 10.21660/2024.119.m2415.
- [9] 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.

- [10] B. Sadhukhan, S. Chakraborty, S. Mukherjee, and R. K. Samanta, "Climatic and seismic data-driven deep learning model for earthquake magnitude prediction," *Front Earth Sci (Lausanne)*, vol. 11, 2023, doi: 10.3389/feart.2023.1082832.
- [11] C. Olah, "Understanding LSTM Networks," *colah's blog*, Aug. 27, 2015. [Online]. Available: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>