

Perbandingan Kinerja *Random Forest* dan *Long Short-Term Memory* dalam Prediksi Kedalaman Hiposentrum Gempa di Maluku dan Laut Banda

Laila Salsabilla Hanifa ¹, Herlawati Herlawati ^{1,*}, Rakhmat Purnomo ¹

* Korespondensi: e-mail: herlawati@ubharajaya.ac.id

¹ Informatika; Fakultas Ilmu Komputer; Universitas Bhayangkara Jakarta Raya, Jl. Perjuangan No.81, Marga Mulya, Bekasi Utara, Bekasi, Jawa Barat, 17143, telp/fax: (021) 88955882; email: 202210715333@mhs.ubharajaya.ac.id, herlawati@ubharajaya.ac.id, rakhmat.purnomo@dsn.ubharajaya.ac.id

Submitted : 8 April 2026
Revised : 22 April 2026
Accepted : 10 Mei 2026
Published : 30 Mei 2026

Abstract

Hypocenter depth is an important parameter in earthquake analysis because it is related to the earthquake source mechanism and its impact on the Earth's surface. The Maluku and Banda Sea regions have high seismic activity caused by interactions among active tectonic plates. This study compares the performance of Random Forest and Long Short-Term Memory (LSTM) algorithms in predicting earthquake hypocenter depth using historical earthquake data from the United States Geological Survey (USGS). Model evaluation used MAE, RMSE, and R² metrics. The results show that Random Forest outperformed LSTM, achieving MAE, RMSE, and R² values of 31.94, 62.83, and 0.73, respectively. Meanwhile, LSTM produced MAE of 69.35, RMSE of 119.31, and R² of -0.11. Therefore, Random Forest was considered more effective for predicting earthquake hypocenter depth in the Maluku and Banda Sea regions.

Keywords: Earthquake, Hypocenter Depth, LSTM, Maluku and Banda Sea, Random Forest

Abstrak

Kedalaman hiposentrum merupakan parameter penting dalam kajian gempa bumi karena berkaitan dengan mekanisme sumber gempa dan besarnya dampak yang dirasakan di permukaan. Kawasan Maluku dan Laut Banda termasuk wilayah dengan tingkat aktivitas seismik tinggi akibat interaksi beberapa lempeng tektonik aktif yang memicu variasi kedalaman gempa yang kompleks. Penelitian ini bertujuan membandingkan kinerja algoritma *Random Forest* dan *Long Short-Term Memory (LSTM)* dalam memprediksi kedalaman hiposentrum gempa bumi pada wilayah Maluku dan Laut Banda. Data yang digunakan berupa data historis gempa bumi yang diperoleh dari United States Geological Survey (USGS). Evaluasi model dilakukan menggunakan metrik MAE, RMSE, dan R². Hasil pengujian menunjukkan bahwa algoritma *Random Forest* memiliki performa yang lebih baik dibandingkan *LSTM*. Model *Random Forest* memperoleh nilai MAE sebesar 31.94, RMSE sebesar 62.83, dan R² sebesar 0.73. Sementara itu, model *LSTM* menghasilkan MAE sebesar 69.35, RMSE sebesar 119.31, dan R² sebesar -0.11. Berdasarkan hasil tersebut, *Random Forest* dinilai lebih efektif dalam memprediksi kedalaman hiposentrum pada data seismik berbentuk tabular di wilayah Maluku dan Laut Banda.

Kata kunci: Gempa Bumi, Kedalaman Hiposentrum, LSTM, Maluku dan Laut Banda, *Random Forest*

1. Pendahuluan

Indonesia merupakan salah satu negara dengan aktivitas seismik tinggi karena berada pada pertemuan tiga lempeng utama dunia, yaitu Eurasia, Indo-Australia, dan Pasifik (Melani et al., 2024). Interaksi antar lempeng tersebut menyebabkan terjadinya pergeseran batuan yang memicu gempa bumi dengan karakteristik yang beragam, baik dari sisi kekuatan maupun kedalamannya. Wilayah Maluku dan Laut Banda termasuk daerah yang memiliki kerawanan seismik tinggi akibat keberadaan sesar aktif dan aktivitas tektonik yang kompleks. Dalam analisis gempa bumi, kedalaman hiposentrum menjadi parameter penting karena menunjukkan lokasi sumber gempa di bawah permukaan bumi (Gaol & Suhardja, 2022).

Kedalaman hiposentrum atau depth memiliki hubungan erat dengan kondisi geodinamika dan interaksi lempeng tektonik pada suatu wilayah. Variasi kedalaman gempa dapat menggambarkan kompleksitas proses tektonik yang terjadi di bawah permukaan bumi (Hutchings & Mooney, 2021). Oleh sebab itu, penentuan kedalaman hiposentrum secara akurat diperlukan untuk mendukung analisis kegempaan serta upaya mitigasi bencana secara lebih optimal (Rachman et al., 2022).

Perkembangan teknologi *Machine Learning* dan *Deep Learning* telah banyak dimanfaatkan dalam pengolahan data gempa bumi karena mampu meningkatkan efisiensi dan kecepatan analisis data. *Random Forest* dipilih karena memiliki kemampuan yang baik dalam mengolah data tabular nonlinear serta lebih tahan terhadap *noise* pada data (Maulita et al., 2024). Sementara itu, *Long Short-Term Memory (LSTM)* digunakan karena mampu mengenali pola temporal dan hubungan berurutan pada data *time series* gempa bumi (Putri et al., 2025).

Sejumlah penelitian terkait penerapan *Machine Learning* dan *Deep Learning* pada data gempa bumi telah dilakukan sebelumnya. Akan tetapi, studi yang secara khusus membandingkan algoritma *Random Forest* dan *Long Short-Term Memory* dalam memprediksi kedalaman hiposentrum di wilayah Maluku dan Laut Banda masih relatif terbatas. Penelitian ini memanfaatkan data historis gempa bumi dari *United States Geological Survey (USGS)* untuk membangun model prediksi kedalaman hiposentrum sekaligus mengevaluasi performa kedua algoritma tersebut. Hasil penelitian diharapkan dapat memberikan kontribusi terhadap pengembangan model prediksi berbasis kecerdasan buatan serta mendukung upaya mitigasi bencana gempa bumi di Indonesia.

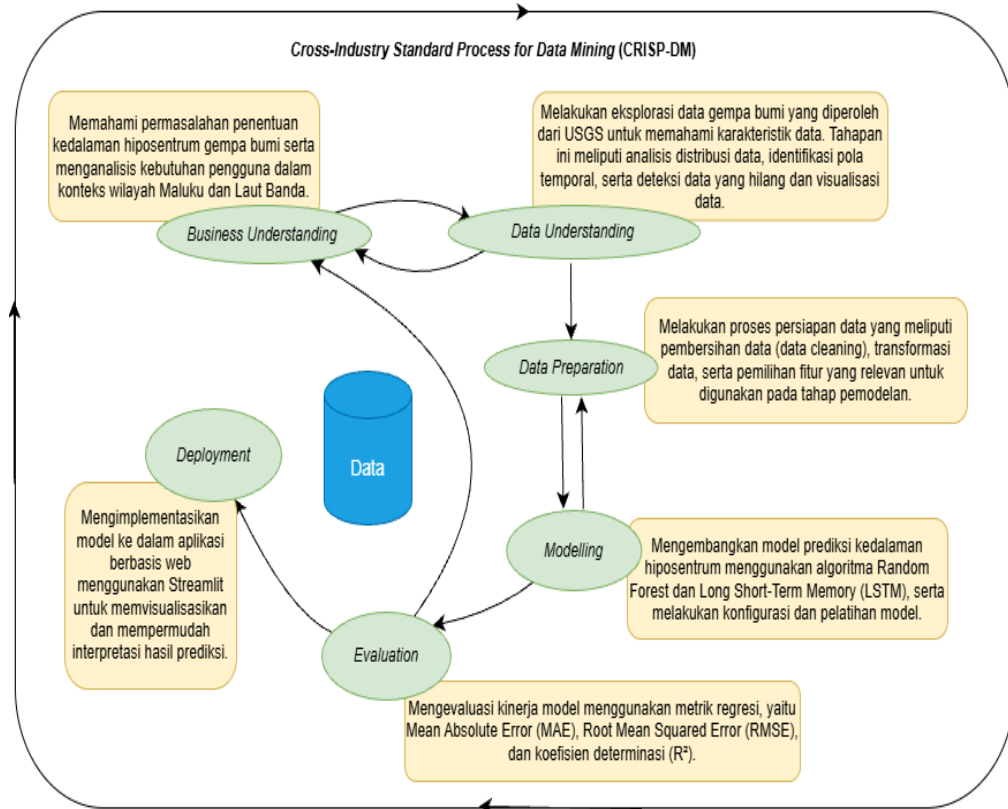
2. Metode Penelitian

Penelitian ini menggunakan metodologi *Cross-Industry Standard Process for Data Mining* (CRISP-DM) sebagai kerangka kerja penelitian dan metode *Random Forest* dan *Long Short-Term Memory* untuk menghasilkan prediksi kedalaman hiposentrum gempa bumi. CRISP-DM digunakan karena memiliki alur kerja yang terstruktur untuk proses pengolahan dan analisis data penelitian.

2.1 Cross-Industry Standard Process for Data Mining (CRISP-DM)

Cross-Industry Standard Process for Data Mining (CRISP-DM) diperkenalkan pada tahun 1999 oleh empat perusahaan besar Daimler-Benz, NCR Corp, OHRA, dan SPSS, Inc. Metode

yang sangat luas digunakan oleh para peneliti dan praktisi dalam proses pemodelan data (Mart et al., 2021),(Rianti et al., 2023) ini bertujuan untuk mengidentifikasi pola-pola yang menarik serta memiliki makna dari data yang dianalisis. Metode ini terdiri dari 6 tahapan utama, *Business Understanding, Data Understanding, Data Preparation, Modelling, Evaluation, dan Deployment* (Saputra et al., 2024). Adapun struktur kerangka penelitian dapat dilihat pada Gambar 1.




Sumber: Hasil Penelitian (2026)

Gambar 1. Tahapan CRISP-DM

2.2. Random Forest

Random Forest merupakan metode *ensemble learning* yang bekerja dengan membentuk sejumlah *decision tree* untuk meningkatkan akurasi prediksi. Algoritma ini menerapkan teknik *bootstrap aggregating (bagging)*, sehingga setiap pohon dibangun dari sampel data yang berbeda. Struktur *Random Forest* dapat dilihat pada Gambar 2.



Sumber: Hasil Penelitian (2026)

Gambar 2. Struktur *Random Forest*

Pada proses prediksi, setiap *decision tree* menghasilkan nilai prediksi yang selanjutnya dikombinasikan untuk memperoleh hasil akhir. Penggunaan banyak *decision tree* membuat *Random Forest* lebih mampu menangani pola data yang kompleks serta membantu mengurangi risiko *overfitting* (Xu et al., 2025). Persamaan matematis *Random Forest* ditunjukkan sebagai berikut:

$$\hat{Y} = \frac{1}{N} \sum_{i=1}^N h_i(x) \quad (1)$$

Keterangan:


\hat{Y} = nilai prediksi akhir,

N = jumlah pohon dalam *Random Forest*,

$h_i(x)$ = prediksi dari pohon ke- i terhadap input x .

2.3. Long Short-Term Memory

Long Short-Term Memory (LSTM) merupakan pengembangan dari *Recurrent Neural Network (RNN)* yang dirancang untuk mempelajari pola pada data berurutan atau *sequential data* (Larasati & Primandari, 2021). Model ini memiliki kemampuan menyimpan informasi dari data sebelumnya sehingga dapat mengenali hubungan temporal pada data *time series*. Struktur arsitektur *Long Short-Term Memory* ditunjukkan pada Gambar 3.



Sumber: Sianturi et al (2023)

Gambar 3. Arsitektur LSTM

Secara umum, arsitektur *LSTM* terdiri dari *cell state* (C_t), *hidden state* (h_t), serta tiga komponen gerbang utama, yaitu forget gate, input gate, dan output gate yang berfungsi untuk mengatur aliran informasi pada jaringan (Yudistira et al., 2025). Adapun persamaan matematis pada model *LSTM* ditunjukkan sebagai berikut:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (2)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (4)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (5)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (6)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (7)$$

Keterangan:

σ = Fungsi aktivitas Sigmoid.

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*)

$b_{f,i,c,o}$ = Vektor *Bias* untuk masing-masing *gate*.

\tanh = Fungsi aktivitas Tangen Hiperbolik.

3. Hasil dan Pembahasan

Penelitian ini menerapkan metode *Cross-Industry Standard Process for Data Mining* (CRISP-DM) dalam pengembangan model prediksi kedalaman hiposentrum gempa bumi menggunakan algoritma *Random Forest* dan *Long Short-Term Memory (LSTM)*. Data yang digunakan berasal dari *United States Geological Survey (USGS)* dengan total 5.264 data kejadian gempa bumi.

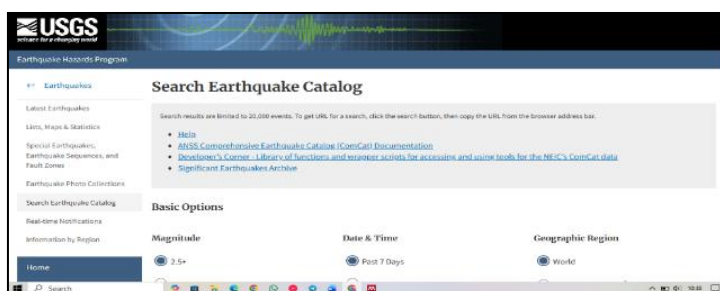
Tahap pemodelan dilakukan dengan membagi dataset menjadi data latih dan data uji pada kedua algoritma. Evaluasi performa model dilakukan menggunakan metrik *Mean Absolute Error (MAE)*, *Root Mean Squared Error (RMSE)*, dan koefisien determinasi (R^2) untuk mengukur tingkat akurasi prediksi. Hasil pengujian menunjukkan bahwa *Random Forest* memiliki performa yang lebih baik dibandingkan model *LSTM*. Selanjutnya, model diimplementasikan ke dalam aplikasi berbasis *web* menggunakan *Streamlit* untuk menampilkan hasil prediksi secara interaktif.

3.1. Business Understanding

Tahap *business understanding* difokuskan pada permasalahan penentuan kedalaman hiposentrum (*depth*) gempa bumi di wilayah Maluku dan Laut Banda yang memiliki tingkat aktivitas seismik tinggi akibat interaksi beberapa lempeng tektonik aktif. Kondisi tersebut menyebabkan variasi kedalaman gempa yang beragam sehingga proses analisis secara manual menjadi lebih kompleks. Selain itu, jumlah data gempa yang terus meningkat juga membuat proses pengolahan data secara manual kurang efektif. Oleh karena itu, penelitian ini memanfaatkan algoritma *Random Forest* dan *Long Short-Term Memory (LSTM)* untuk memprediksi kedalaman hiposentrum gempa bumi sekaligus membandingkan kinerja kedua metode tersebut.

3.2. Data Understanding

Tahap *data understanding* dilakukan untuk memahami karakteristik serta struktur dataset yang digunakan dalam penelitian.



Sumber: Hasil Penelitian (2026)

Gambar 4. Data Sekunder USGS

Data yang digunakan berupa data historis kejadian gempa bumi di wilayah Maluku dan Laut Banda yang diperoleh melalui situs resmi <https://earthquake.usgs.gov/earthquakes/search/> sebagaimana ditunjukkan pada Gambar 4. *Dataset* penelitian diperoleh dari *United States Geological Survey (USGS)* dengan rentang waktu Januari 2020 sampai Januari 2026 yang terdiri dari 5.264 data gempa bumi di wilayah Maluku dan Laut Banda. Pada tahap ini dilakukan eksplorasi data untuk mengetahui distribusi kedalaman hiposentrum (*depth*), hubungan antarvariabel, serta mendeteksi adanya *missing value* dan *outlier* yang berpotensi memengaruhi kinerja model.

3.3. Data Preparation

Tahap *data preparation* dilakukan untuk mengubah data mentah menjadi *dataset* yang lebih bersih, terstruktur, dan siap digunakan dalam proses pemodelan. Adapun tahapan *data preparation* pada penelitian ini meliputi:

a. Data Cleaning

Proses data cleaning dilakukan dengan menghapus data yang memiliki nilai kosong (*missing value*) pada fitur dan variabel target menggunakan pemrograman Python.

```
Jumlah data sebelum cleaning: 5264
Missing value sebelum cleaning:
latitude      0
longitude     0
mag           0
depth         0
dtype: int64

Jumlah data sesudah cleaning: 5264
Missing value sesudah cleaning:
latitude      0
longitude     0
mag           0
depth         0
dtype: int64
```

Sumber: Hasil Penelitian (2026)

Gambar 5. Hasil Pembersihan Data

Berdasarkan Gambar 5, hasil pemeriksaan menunjukkan bahwa dataset tidak memiliki *missing value* pada seluruh variabel yang digunakan sehingga seluruh 5.264 data dapat diproses pada tahap berikutnya. Setelah dilakukan proses transformasi dan *filtering* data, jumlah dataset yang digunakan menjadi 3.145 data gempa bumi.

b. Transformasi Data

Transformasi data dilakukan untuk menyesuaikan struktur dan atribut data agar dapat digunakan pada tahap pemodelan. Tahap ini mencakup ekstraksi fitur waktu, penyaringan wilayah penelitian, serta filtering kedalaman gempa bumi.

```
Jumlah data setelah filter: 3145
```

Sumber: Hasil Penelitian (2026)

Gambar 6. Hasil Transformasi Data

Berdasarkan Gambar 6, atribut *time* diekstraksi menjadi beberapa fitur baru, yaitu *hour*, *day*, dan *month*. Selain itu, dilakukan proses filtering wilayah menggunakan koordinat *latitude* dan *longitude* serta penyaringan nilai *depth* pada rentang 0–700 km agar dataset yang digunakan


lebih relevan. Setelah seluruh proses dilakukan, diperoleh 3.145 data gempa bumi yang digunakan pada tahap prediksi kedalaman hiposentrum.

c. *Feature Selection*

Pada tahap *feature selection*, variabel target yang digunakan adalah *depth* sebagai representasi kedalaman hiposentrum gempa bumi. Adapun variabel input (*feature*) yang digunakan terdiri dari *latitude*, *longitude*, *mag*, *gap*, *dmin*, *rms*, serta fitur waktu berupa *hour*, *day*, dan *month* yang diperoleh dari proses ekstraksi waktu kejadian gempa bumi.

d. *Pembagian Data*

Tahap data splitting dilakukan pada model *Random Forest* dan *Long Short-Term Memory (LSTM)*. Pada algoritma *Random Forest*, data dibagi secara acak menggunakan metode *train-test split* dengan rasio 80% data latih dan 20% data uji. Sementara itu, pada model *LSTM* pembagian data dilakukan berdasarkan urutan waktu (*time series split*) tanpa proses pengacakan sehingga pola temporal pada data gempa bumi tetap terjaga.



Sumber: Hasil Penelitian (2026)

Gambar 7. (a) Pembagian Data *Random Forest*, (b) Pembagian Data *LSTM*


Berdasarkan Gambar 7, hasil pembagian data pada kedua algoritma menunjukkan bahwa data training terdiri dari 2.516 data, sedangkan data *testing* sebanyak 629 data dengan total 9 fitur penelitian. Perbedaan metode pembagian data dilakukan agar setiap algoritma dapat mempelajari karakteristik data secara lebih optimal sesuai pendekatan yang digunakan.

e. *Normalisasi Data*

Proses normalisasi data dilakukan menggunakan metode *MinMaxScaler* untuk mengubah rentang nilai fitur ke skala 0 hingga 1 sehingga perbedaan nilai antar fitur tidak mempengaruhi proses pelatihan model.

f. *Reshaping*

Pada tahap *reshaping*, data diubah ke dalam bentuk *sequence* agar dapat diproses oleh model *Long Short-Term Memory (LSTM)*. Model menggunakan 10 data sebelumnya untuk memprediksi data selanjutnya sehingga data disusun dalam bentuk tiga dimensi (3D) sesuai kebutuhan arsitektur *LSTM*.



Sumber: Hasil Penelitian (2026)

Gambar 8. Hasil *Reshaping* Data

Berdasarkan Gambar 8, hasil pembentukan *sequence* menunjukkan bahwa data training memiliki dimensi (2506, 10, 9), sedangkan data testing memiliki dimensi (619, 10, 9).

Sementara itu, data target masing-masing berukuran (2506, 1) dan (619, 1). Jumlah data pada proses *reshaping* berkurang karena pembentukan *sequence* menggunakan *window* sebanyak 10 *timestep* pada model *LSTM*.

3.4. Modelling

Tahap *modelling* dilakukan untuk membangun model prediksi kedalaman hiposentrum gempa bumi menggunakan algoritma *Random Forest* dan *Long Short-Term Memory (LSTM)* pada wilayah Maluku dan Laut Banda. Model dikembangkan menggunakan data gempa bumi dari *United States Geological Survey (USGS)* yang telah melalui tahap *data preparation*. Adapun tahapan *modelling* dalam penelitian meliputi beberapa proses:

a. Import *Library* Pemodelan

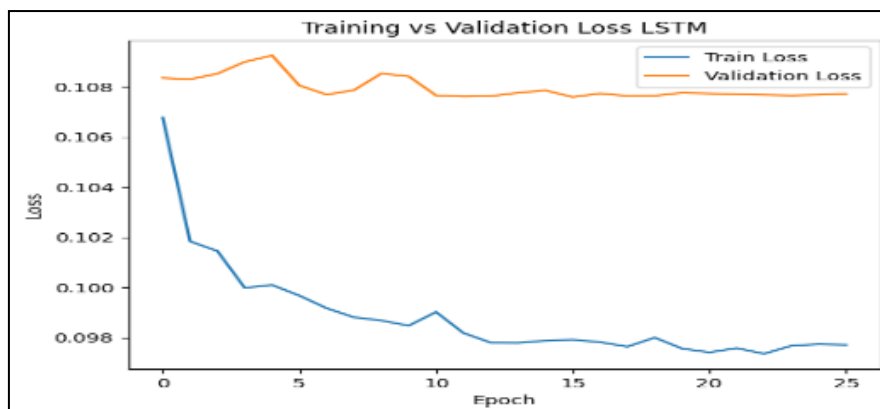
Tahap ini dilakukan untuk mengimpor *library* yang digunakan dalam proses pembangunan model *Random Forest* dan *Long Short-Term Memory (LSTM)*. Pada model *Random Forest* digunakan *RandomForestRegressor* dari *Scikit-learn*, sedangkan model *LSTM* memanfaatkan *library TensorFlow Keras* seperti *Sequential*, *LSTM*, *Dense*, dan *EarlyStopping* untuk membangun serta melatih model prediksi kedalaman hiposentrum gempa bumi.

b. Konfigurasi Parameter

Pada tahap ini dilakukan pengaturan parameter pada model *Random Forest* dan *LSTM* sebelum proses pelatihan dimulai. Model *Random Forest* menggunakan 100 decision tree untuk menghasilkan prediksi yang lebih stabil. Sementara itu, model *LSTM* memanfaatkan *layer LSTM*, *dropout*, dan *dense* untuk mempelajari pola temporal pada data gempa bumi. Selain itu, digunakan *optimizer Adam*, *fungsi loss MAE*, serta *EarlyStopping* untuk membantu mengoptimalkan proses pelatihan model.

c. Pelatihan Model

Proses pelatihan model dilakukan menggunakan data *training* yang telah melalui tahap normalisasi sebelumnya. Model *Random Forest* digunakan untuk mempelajari hubungan antara fitur input dengan target kedalaman hiposentrum (*depth*), sedangkan model *LSTM* dilatih untuk mengenali pola temporal pada data gempa bumi.



Sumber: Hasil Penelitian (2026)

Gambar 9. Training vs Validation Loss

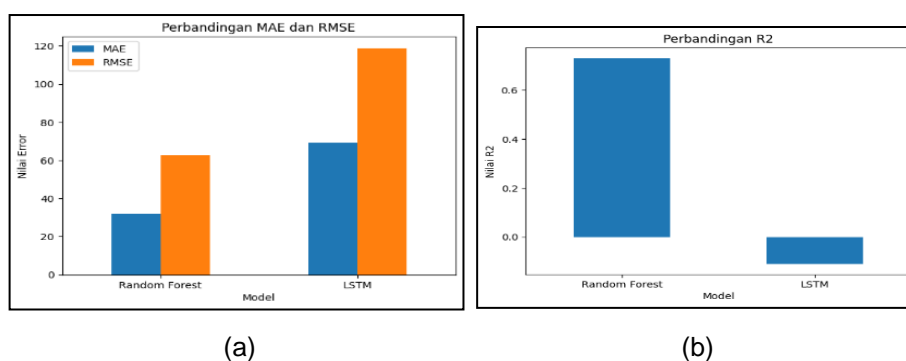
Berdasarkan Gambar 9, nilai training loss mengalami penurunan pada beberapa epoch awal, sedangkan validation loss cenderung stabil sehingga peningkatan performa model pada data validasi belum terlalu signifikan.

Tabel 1. Pelatihan Model

Epoch	Loss	Val Loss
1	0.1126	0.1084
22	0.0972	0.1080
45	0.976	0.1079

Sumber: Hasil Penelitian (2026)

Berdasarkan Tabel 1, nilai loss mengalami penurunan dari 0.1126 menjadi 0.0976, sedangkan nilai *validation loss* relatif stabil pada rentang 0.1079–0.1084. Hasil tersebut menunjukkan bahwa model mulai mampu mempelajari pola data, meskipun peningkatan performa pada data validasi masih belum terlalu optimal.



Sumber: Hasil Penelitian (2026)

Gambar 10. (a) Perbandingan Nilai MAE dan RMSE, (b) Perbandingan Nilai R²

Berdasarkan Gambar 10, hasil evaluasi menunjukkan bahwa *Random Forest* memiliki performa lebih baik dibandingkan *LSTM* dalam memprediksi kedalaman hiposentrum gempa bumi. *Random Forest* menghasilkan nilai MAE sebesar 31,94, RMSE sebesar 62,83, dan R² sebesar 0,73, yang menunjukkan bahwa model memiliki tingkat kesalahan lebih rendah dan mampu memprediksi data dengan baik. Sementara itu, *LSTM* menghasilkan nilai MAE sebesar 69,35, RMSE sebesar 119,31, dan R² sebesar -0,11, sehingga performanya masih kurang baik. Oleh karena itu, *Random Forest* dinilai lebih akurat dibandingkan *LSTM* pada penelitian ini.

3.5. Evaluation

Tahap *evaluation* dilakukan untuk mengukur performa model *Random Forest* dan *Long Short-Term Memory (LSTM)* dalam memprediksi kedalaman hiposentrum (*depth*) gempa bumi. Evaluasi dilakukan menggunakan metrik MAE, RMSE dan R². Ketiga metrik utama tersebut dapat didefinisikan berikut:

- Mean Absolute Error (MAE)* digunakan untuk menghitung rata-rata perbedaan *absolut* antara nilai aktual dan nilai prediksi model. MAE dapat dihitung menggunakan persamaan berikut:

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

- b. *Root Mean Squared Error* (RMSE) digunakan untuk mengetahui besar kesalahan prediksi dengan memberikan penalti lebih tinggi terhadap *error* besar. RMSE dapat dihitung menggunakan persamaan berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

- c. Koefisien determinasi (R^2) digunakan untuk mengetahui kemampuan model dalam menjelaskan variasi data aktual. R^2 dapat dihitung menggunakan persamaan berikut:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (10)$$

Keterangan:

- y_i = nilai aktual
- \hat{y}_i = nilai prediksi
- \bar{y} = rata-rata nilai aktual
- n = jumlah data

Adapun hasil evaluasi model *Random Forest* dan *Long Short-Term Memory* ditunjukkan pada Tabel 2.

Tabel 2. Perbandingan Model Evaluasi Metrik

Model	MAE	RMSE	R^2
<i>Random Forest</i>	31.94	62.83	0.73
<i>LSTM</i>	69.35	119.31	-0.11

Sumber: Hasil Penelitian (2026)

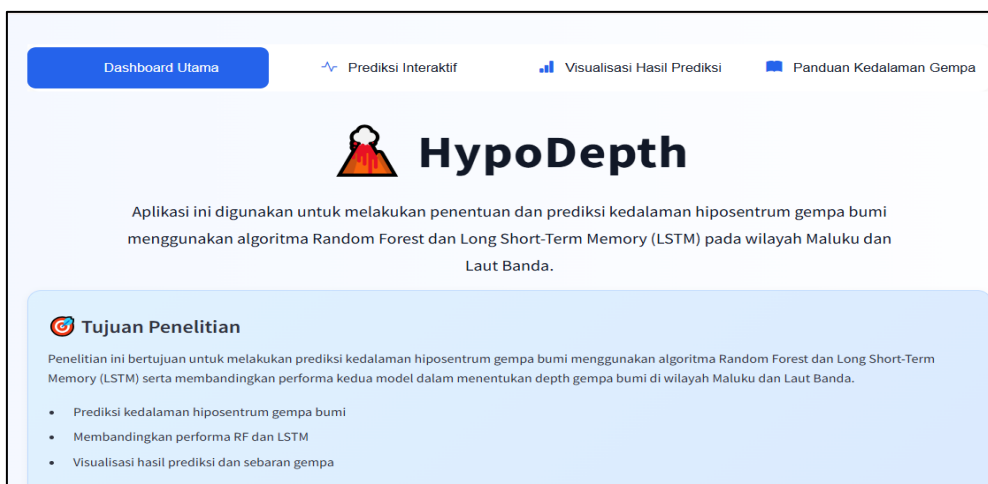
Hasil evaluasi pada Tabel 2 menunjukkan bahwa *Random Forest* memiliki tingkat *error* yang lebih rendah dibandingkan model *LSTM*. Selain itu, nilai R^2 sebesar 0.73 pada model *Random Forest* menunjukkan kemampuan yang cukup baik dalam menjelaskan variasi data kedalaman gempa bumi, sedangkan model *LSTM* dengan nilai R^2 sebesar -0.11 masih menunjukkan performa yang rendah.

3.6. Deployment

Pada tahap deployment, model prediksi yang telah dibangun kemudian diterapkan pada aplikasi *web* interaktif menggunakan *Streamlit* dan *Hugging Face Spaces*. Aplikasi menggunakan model *Random Forest* dan *Long Short-Term Memory (LSTM)* yang telah disimpan dalam format *.pkl* dan *.keras* untuk melakukan proses prediksi. Aplikasi dilengkapi menu dashboard, prediksi interaktif, visualisasi hasil, dan panduan kedalaman gempa untuk memudahkan pengguna dalam melakukan analisis.

Pada Gambar 11, halaman *dashboard* utama menampilkan informasi umum mengenai sistem prediksi kedalaman hiposentrum (*depth*) gempa bumi, tujuan penelitian, jumlah data historis gempa, algoritma yang digunakan, serta visualisasi peta sebaran gempa bumi di wilayah Maluku dan Laut Banda. Halaman ini dirancang untuk membantu pengguna memahami fungsi sistem dan informasi dasar sebelum melakukan proses prediksi. Selain itu, halaman *dashboard* utama juga berfungsi sebagai titik awal navigasi pengguna untuk mengakses berbagai fitur yang tersedia dalam sistem, seperti prediksi interaktif, visualisasi hasil prediksi, dan panduan

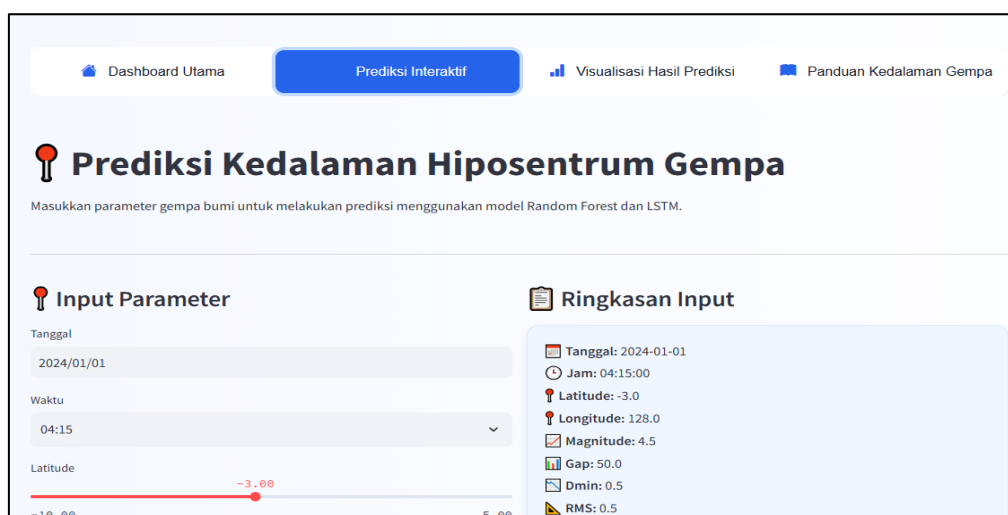
interpretasi kedalaman hiposentrum gempa. Dengan tampilan yang informatif dan terstruktur, pengguna dapat memperoleh gambaran umum mengenai tujuan dan cara kerja sistem sebelum melakukan analisis lebih lanjut.



Sumber: Hasil Penelitian (2026)

Gambar 11. Tampilan Menu *Dashboard Utama*

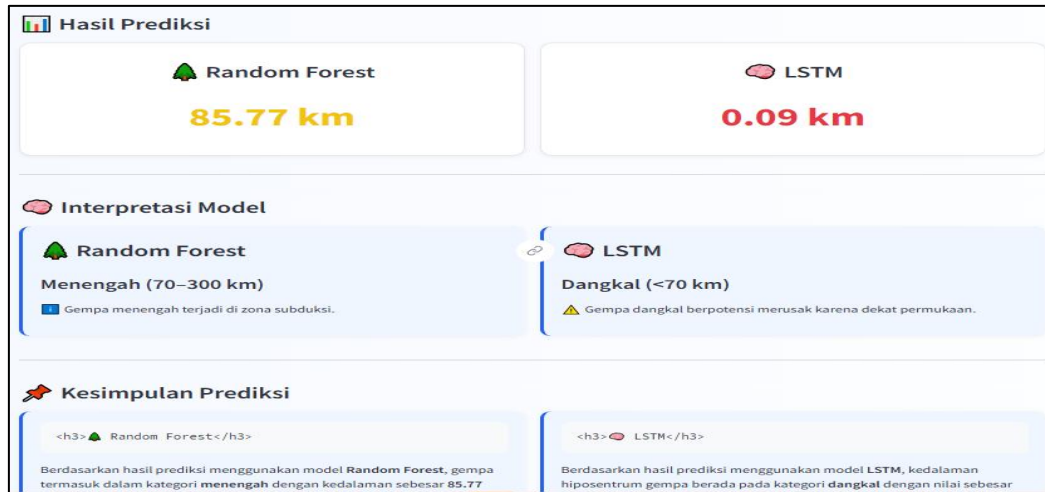
Pada Gambar 12 merupakan antarmuka halaman Prediksi untuk memudahkan pengguna dalam memasukkan parameter gempa bumi yang diperlukan oleh model prediksi. Parameter meliputi tanggal kejadian, waktu, koordinat geografis (latitude dan longitude), magnitudo, nilai gap, Dmin, dan RMS. Setelah data dimasukkan, sistem akan menampilkan ringkasan parameter pada panel sebelah kanan sebagai bentuk validasi sebelum proses prediksi dilakukan. Selanjutnya, model yang telah dibangun menggunakan algoritma *Random Forest* dan *Long Short-Term Memory (LSTM)* akan mengolah parameter tersebut untuk menghasilkan estimasi kedalaman hiposentrum gempa bumi.



Sumber: Hasil Penelitian (2026)

Gambar 12. Tampilan Menu Input Parameter

Berdasarkan Gambar 12, pengguna memasukkan parameter gempa untuk melakukan prediksi kedalaman hiposentrum (*depth*) gempa bumi.

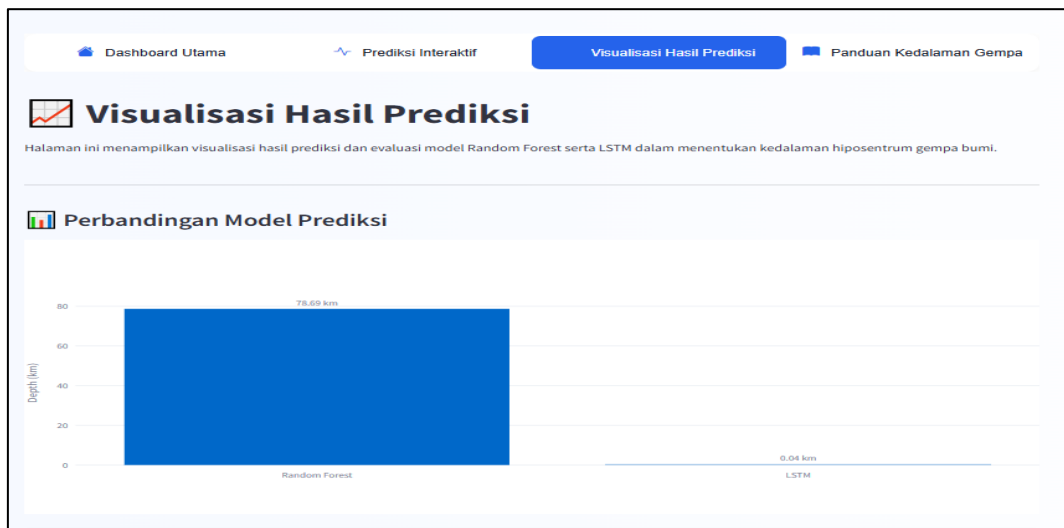


Sumber: Hasil Penelitian (2026)

Gambar 13. Tampilan Hasil Input Parameter

Berdasarkan Gambar 13, Setelah proses penginputan data dilakukan, sistem akan menampilkan hasil prediksi dari model *Random Forest* dan *LSTM* secara informatif. Hasil tersebut disertai dengan interpretasi kategori kedalaman gempa serta kesimpulan prediksi untuk memudahkan pengguna dalam memahami hasil yang diperoleh.

Berdasarkan Gambar 14, sistem menampilkan visualisasi hasil prediksi dan evaluasi model dalam bentuk grafik perbandingan hasil prediksi, *Actual vs Predicted*, perbandingan nilai MAE, RMSE, dan R^2 , serta grafik *training loss* dan *validation loss* model *LSTM*. Visualisasi hasil digunakan untuk mempermudah interpretasi performa model secara interaktif.



Sumber: Hasil Penelitian (2026)

Gambar 14. Tampilan Menu Visualisasi

Sistem menyediakan halaman panduan yang berisi informasi mengenai kategori kedalaman gempa bumi, parameter input prediksi, serta penjelasan wilayah penelitian Maluku dan Laut Banda. Halaman ini bertujuan membantu pengguna memahami hasil prediksi dan karakteristik kedalaman hiposentrum gempa bumi secara lebih mudah.

4. Kesimpulan

Algoritma *Random Forest* memberikan hasil yang lebih akurat dibandingkan *Long Short-Term Memory (LSTM)* dalam menentukan kedalaman hiposentrum (*depth*) gempa di wilayah Maluku dan Laut Banda. Model *Random Forest* berhasil menangani karakteristik data seismik yang bersifat nonlinear dengan menghasilkan nilai Mean Absolute Error (MAE) sebesar 31.94, Root Mean Squared Error (RMSE) sebesar 62.83, dan koefisien determinasi (R^2) sebesar 0.73, yang menunjukkan bahwa model mampu menjelaskan sekitar 73% variasi data kedalaman gempa bumi. Sementara itu, model *LSTM* menghasilkan nilai MAE sebesar 69.35, RMSE sebesar 119.31, dan R^2 sebesar -0.11 sehingga performanya masih belum optimal dalam memprediksi kedalaman hiposentrum pada dataset penelitian ini. Berdasarkan hasil evaluasi tersebut, model *Random Forest* dinilai lebih efektif dan lebih sesuai digunakan untuk memprediksi kedalaman hiposentrum gempa bumi karena mampu menghasilkan prediksi yang lebih stabil dan mendekati nilai aktual dibandingkan model *LSTM*.

Ucapan Terima Kasih

Peneliti menyampaikan terima kasih kepada seluruh reviewer atas masukan, kritik, dan saran yang diberikan sehingga artikel ini dapat disusun dengan lebih baik. Ucapan terima kasih juga disampaikan kepada Universitas Bhayangkara Jakarta Raya atas dukungan, fasilitas, serta bimbingan yang diberikan selama proses penelitian berlangsung. Seluruh dukungan tersebut sangat membantu dalam kelancaran dan penyelesaian penelitian.

Daftar Pustaka

- Gaol, Y. H. L., & Suhardja, S. K. (2022). Hasil Awal Penentuan Waktu Tiba Gelombang-P Gempa Menggunakan Machine Learning. *Jurnal Geofisika*, 20(02), 76–80. <https://doi.org/10.36435/jgf.v20i2.538>
- Hutchings, S. J., & Mooney, W. D. (2021). The Seismicity of Indonesia and Tectonic Implications. *Geochemistry, Geophysics, Geosystems*, 22(9), 1–42. <https://doi.org/10.1029/2021GC009812>
- Larasati, K. D., & Primandari, A. H. (2021). Forecasting Bitcoin Price Based on Blockchain Information Using Long-Short Term Method. *Parameter: Journal of Statistics*, 1(1), 1–6. <https://doi.org/10.22487/27765660.2021.v1.i1.15389>
- Mart, F., Contreras-ochando, L., & Lachiche, N. (2021). *CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories*. 33, 3048–3061.
- Maulita, I., Mu, A., Fisika, J., Mipa, F., Soedirman, U. J., Komputer, M. I., Komputer, F. I., & Purwokerto, U. A. (2024). 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 (JPTI)*, 4(5), 221–232. <https://doi.org/10.52436/1.ipti.470>

- Melani, P., Realita, A., & Prastowo, T. (2024). Analisis Seismisitas Maluku Dan Barat Papua Berdasarkan Distribusi Frekuensi-Magnitudo Gempa. *Jurnal Inovasi Fisika Indonesia (IFI)*, 13, 25–36. <https://doi.org/10.26740/ifi.v13n2.p25-36>
- Putri, M. A., Suhendra, R., & Ridho, A. (2025). Jurnal Teknologi Informasi Analisis Kinerja Algoritma *Long Short-Term Memory (LSTM)* untuk Prediksi Gempa Bumi di Aceh. *Jurnal Teknik Informasi*, 4(2), 8–18. <https://doi.org/10.35308/jti.v4i2.12921>
- Rachman, G., Santosa, B. J., Nugraha, A. D., Rohadi, S., Rosalia, S., Zulfakriza, Z., Sungkono, S., Sahara, D. P., Muttaqy, F., Supendi, P., Ramdhan, M., Ardianto, A., & Afif, H. (2022). Seismic Structure Beneath the Molucca Sea Collision Zone from Travel Time Tomography Based on Local and Regional BMKG Networks. *Applied Sciences (Switzerland)*, 12(20). <https://doi.org/10.3390/app122010520>
- Rianti, A., Wachid, N., Majid, A., & Fauzi, A. (2023). *CRISP-DM: Metodologi Proyek Data Science*. 107–114.
- Saputra, D. B., Atina, V., & Nastiti, F. E. (2024). Penerapan Model Crisp-Dm Pada Prediksi Nasabah Kredit Menggunakan Algoritma *Random Forest*. *IDEALIS: InDonEsiA Journal Information System*, 7(2), 240–247. <https://doi.org/10.36080/idealism.v7i2.3244>
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3). <https://doi.org/10.1007/s42979-021-00592-x>
- Sianturi, T. B., Cholissodin, I., & Yudistira, N. (2023). Penerapan Algoritma *Long Short-Term Memory (LSTM)* berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 7(3), 1101–1107. <http://j-ptiik.ub.ac.id>
- Xu, M., Zhao, L., Liu, M., & Geng, J. (2025). Machine Learning-Based Seismic Subsurface Characterization: The State of the Art and Future Perspectives. *Journal of Geophysical Research: Machine Learning and Computation*, 2(4), 1–37. <https://doi.org/10.1029/2025jh000846>
- Yudistira, N., Alfiansih, M. D., Andriyani, N. I., Essayem, W., Maghfiroh, N. A., & Nurdian, I. W. (2025). *Prediksi Deret Waktu Menggunakan Deep Learning* (Vol. 6, Issue 0).