

Evaluasi Kinerja Model RNN & LSTM untuk Prediksi Magnitude Gempa di Indonesia

Rara Fazira¹, Dimas Yudistira², Lailan Sofinah Harahap³

^{1,2}Fakultas Sains dan Teknologi, Program Studi Ilmu Komputer, Universitas Islam Negeri Sumatera Utara, Indonesia

³Fakultas Ilmu Komputer dan Teknologi Informasi, Program Studi Teknologi Informasi, Universitas Muhammadiyah Sumatera Utara, Indonesia

Email: rarafazira27@gmail.com¹, yudistira@uinsu.ac.id², lailansofinahharahap@umsu.ac.id³

Alamat: Jl. Lap. Golf No.120, Kp. Tengah, Kec. Pancur Batu, Kabupaten Deli Serdang, Sumatera Utara 20353

Korespondensi penulis: rarafazira27@gmail.com

Abstract. Indonesia is located on the Pacific Ring of Fire which is known to have very high seismic activity with thousands of earthquakes occurring every year. This research aims to analyze the performance of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) in predicting earthquake magnitudes using historical data taken from Kaggle. This data covers the time period from November 2008 to September 2022 which has gone through a normalization process and is separated into training and testing data. Evaluation of model performance is carried out using the Mean Absolute Error (MAE) and Root Mean Square Error (RMSE) metrics. In the first trial, LSTM showed the best performance with MAE values of 0.6226 and RMSE 0.7731 on test data, better than RNN which recorded MAE 0.6271 and RMSE 0.7831. On the other hand, in the second trial, RNN was superior with MAE values of 0.5583 and RMSE 0.7008, while LSTM had MAE 0.5822 and RMSE 0.7132. These results show that LSTM is more suitable for handling complex temporal data patterns, while RNN is more reliable on data sets with simpler patterns. It is hoped that this research can be a stepping stone in developing a prediction system for earthquake disaster risk mitigation in Indonesia.

Keywords: Earthquake, Magnitude Prediction, RNN, LSTM, Model Evaluation.

Abstrak. Indonesia terletak di kawasan Cincin Api Pasifik, yang dikenal memiliki aktivitas seismik yang sangat tinggi dengan ribuan gempa bumi terjadi setiap tahunnya. Penelitian ini bertujuan untuk menganalisis performa Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM) dalam memprediksi magnitudo gempa bumi menggunakan data historis yang diambil dari Kaggle. Data tersebut mencakup rentang waktu dari November 2008 hingga September 2022, yang telah melalui proses normalisasi serta pemisahan menjadi data pelatihan dan pengujian. Evaluasi performa model dilakukan dengan menggunakan metrik Mean Absolute Error (MAE) dan Root Mean Square Error (RMSE). Pada uji coba pertama, LSTM menunjukkan performa terbaik dengan nilai MAE 0.6226 dan RMSE 0.7731 pada data pengujian, lebih baik dibandingkan RNN yang mencatatkan MAE 0.6271 dan RMSE 0.7831. Sebaliknya, pada uji coba kedua, RNN unggul dengan nilai MAE 0.5583 dan RMSE 0.7008, sementara LSTM memiliki MAE 0.5822 dan RMSE 0.7132. Hasil ini mengindikasikan bahwa LSTM lebih cocok untuk menangani pola data temporal yang kompleks, sedangkan RNN lebih andal pada dataset dengan pola yang lebih sederhana. Penelitian ini diharapkan dapat menjadi pijakan dalam pengembangan sistem prediktif untuk mitigasi risiko bencana gempa bumi di Indonesia.

Kata kunci: Gempa Bumi, Prediksi Magnitude, RNN, LSTM, Evaluasi Model.

1. LATAR BELAKANG

Indonesia berada di kawasan Cincin Api Pasifik, yang dianggap memiliki aktivitas seismik tertinggi di dunia. Setiap tahun, pergerakan lempeng tektonik di sekitar Indonesia menyebabkan ribuan gempa bumi, beberapa di antaranya memiliki magnitudo yang besar dan berpotensi menyebabkan kerusakan besar. Sangat penting untuk memprediksi magnitudo gempa bumi untuk meminimalkan efek negatifnya terhadap kehidupan manusia, infrastruktur, dan stabilitas ekonomi. Dengan prediksi yang lebih akurat, masyarakat dan pemerintah dapat

mempersiapkan tindakan mitigasi yang lebih baik, seperti perencanaan evakuasi dini dan pembangunan infrastruktur tahan gempa (Irawan, Hasibuan, and Fauzi 2020).

Prediksi magnitudo gempa bumi adalah masalah yang signifikan yang membutuhkan pendekatan kompleks. Data seismik yang digunakan seringkali non-linear dan stokastik, dan metode konvensional sulit menangkap pola. Model statistik tradisional, seperti regresi linier atau autoregressive, tidak dapat menunjukkan hubungan yang mendalam antara parameter seismik secara temporal dan spasial. Selain itu, proses ekstraksi fitur menjadi lebih sulit karena data seismik sering kali penuh dengan suara. Akibatnya, pendekatan berbasis kecerdasan buatan (AI) memiliki potensi besar untuk mengatasi masalah ini karena memungkinkan analisis data sekuensial yang lebih adaptif dan presisi (Swastikawati et al. 2024).

Jenis jaringan saraf tiruan seperti Recurrent Neural Network (RNN) dan Long Short-Term Memory (LSTM) dapat memproses data berurutan, termasuk data seismik. Meskipun RNN memiliki kemampuan untuk mengidentifikasi pola temporal dalam data, masalah vanishing gradient sering muncul saat memproses urutan data yang sangat panjang. Sebaliknya, keterbatasan ini diatasi oleh LSTM melalui mekanisme memori jangka panjang. Ini memungkinkan model untuk mempertahankan informasi penting meskipun data memiliki pola yang kompleks. Tujuan penelitian ini adalah untuk mengevaluasi kinerja RNN dan LSTM dalam memprediksi magnitudo gempa berdasarkan data kejadian per kejadian. Metode ini diharapkan dapat memberikan wawasan baru tentang akurasi dan efisiensi model yang berbeda dalam analisis data gempa di Indonesia (Wang et al. 2023).

Penelitian ini menggunakan data gempa historis yang mencakup magnitudo dan waktu kejadian, yang diambil dari dataset Kaggle. Rata-rata Kesalahan Absolut (MAE) dan Rata-rata Kesalahan Kuadrat (MSE) adalah metrik evaluasi yang digunakan untuk mengevaluasi kinerja RNN dan LSTM. MAE menunjukkan tingkat kesalahan rata-rata dalam satuan data asli, sedangkan MSE memperhitungkan kuadrat kesalahan, memberikan perhatian yang lebih besar pada kesalahan yang lebih signifikan. Sejauh mana model dapat memberikan prediksi yang lebih realistis adalah tujuan analisis ini (Bhandarkar et al. 2019).

Kajian terdahulu tentang penggunaan Recurrent Neural Networks (RNN) dan Long Short-Term Memory (LSTM) untuk memprediksi magnitudo gempa menunjukkan bahwa kedua model ini sangat bermanfaat untuk menganalisis data sekuensial, seperti data gempa. Dalam salah satu studi yang membahas penggunaan LSTM untuk prediksi magnitudo gempa oleh (González, Yu, and Telesca 2019), terbukti bahwa LSTM lebih baik daripada RNN konvensional dalam menangani ketergantungan jangka panjang pada data sekuensial. LSTM juga dapat mengatasi masalah vanishing gradient, yang biasanya terjadi pada RNN, sehingga

LSTM lebih baik dalam mengingat informasi penting dalam jangka waktu panjang. Penelitian ini menggunakan data seismik dari catalog gempa Italia. Dengan hanya dua epoch dan 10% data pelatihan, model LSTM mencapai error prediksi sebesar 0.003.

Dalam penelitian yang dilakukan oleh (Sadhukhan et al. 2023), mengenai Bidirectional LSTM (BiLSTM) untuk prediksi magnitudo gempa, nilai kesalahan prediksi khusus tidak dijelaskan dengan detail numerik pada sumber yang tersedia. Namun, BiLSTM memiliki keunggulan dalam memproses data sekuensial dengan menganalisis data dari dua arah (maju dan mundur), yang memungkinkan model untuk menangkap pola yang lebih kompleks dibandingkan dengan unidirectional RNN atau LSTM.

2. KAJIAN TEORITIS

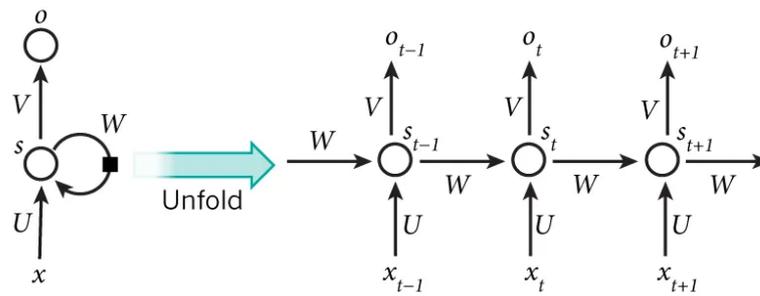
Jaringan Syaraf Tiruan

Salah satu teknik kecerdasan buatan adalah jaringan saraf tiruan (JST), yang meniru cara otak manusia memproses data. JST terdiri dari banyak neuron yang saling berhubungan melalui lapisan input, lapisan tersembunyi, dan lapisan output. Pola non-linear dan hubungan kompleks dalam data dapat ditangkap dengan sangat baik dengan menggunakan teknik ini. Untuk prediksi gempa, JST dapat menganalisis data temporal seperti magnitudo gempa atau waktu kejadian untuk menemukan pola tersembunyi. Karena fleksibilitasnya dalam mengolah data dengan pola dinamis dan noise tinggi, JST lebih unggul daripada metode statistik konvensional (Tambunan, Hartama, and Gunawan 2021).

Recurrent Neural Network (RNN)

Salah satu bagian dari area pembelajaran mesin adalah RNN, yang berfokus pada ekstraksi fitur dari data yang lebih detail. RNN berasal dari Artificial Neural Networks (ANN) dan memiliki desain yang mirip dengan Multi Layer Perception. (MLP). Dengan cara ini, pembelajaran mendalam dapat mengirimkan informasi dari satu neuron ke neuron lainnya. Recurrent Neural Network (RNN) memiliki berbagai jenis seperti Long Short Term Memory. Dengan memasukkan pengulangan dalam arsitekturnya, teknik ini dapat menyimpan data masa lalu. Hal ini memungkinkan untuk mengenali pola data dengan baik dan menggunakannya untuk membuat prediksi (Yunizar, Rismawan, and Midyanti 2023).

Arsitektur RNN dapat dilihat pada Gambar 1 di bawah ini :



Gambar 1. Arsitektur RNN

Arsitektur RNN

$$S_t = \phi (UX_t + WS_{t-1} + b_1), \quad (1)$$

$$o_t = \phi (VS_t + b_2), \quad (2)$$

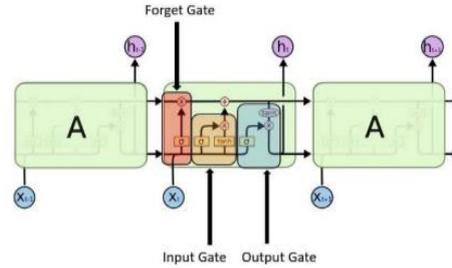
$$\hat{y}_t = \phi (o_t) \quad (3)$$

Dimana, X_t , S_t dan o_t masing-masing menampilkan unit input, unit tersembunyi, dan unit output pada t . V , W , dan U menunjukkan bobot koneksi jaringan; b dan \hat{y} menunjukkan bias dan nilai output yang diprediksi, dan ϕ menunjukkan fungsi aktivasi. Dengan bertambahnya jumlah dan dimensi data, RNN harus mengingat banyak informasi sebelum waktu t , yang mengarah pada masalah vanishing gradient. Vanishing gradient problem adalah permasalahan saat gradien mengecil menyusut seiring dengan proses back propagation melalui waktu. Inilah kenapa metode LSTM dibutuhkan untuk mengatasi masalah ini (Mulyawan 2024).

Long Short-Term Memory (LSTM)

Arsitektur Recurrent Neural Network (RNN) yang dikemukakan oleh Sepp Hochreiter dan Jurgen Schmidhuber pada tahun 1997 dikembangkan menjadi Long Short-Term Memory (LSTM). LSTM direkomendasikan untuk mengatasi masalah hilangnya pembentukan gradien di RNN saat memproses data sekuensial panjang. Karena kapasitas memori selnya meningkat, arsitektur LSTM dapat menangani penyimpanan memori dalam jangka waktu yang lebih lama. Artinya selama pemrosesan data sekuensial yang panjang, LSTM dapat mengatasi pembentukan vanishing gradien di RNN (Pontoh et al. 2022).

Berikut adalah arsitektur model LSTM dapat dilihat pada gambar 2, dan persamaan yang digunakan di proses LSTM dapat dilihat di bawah gambar arsitektur LSTM.



Gambar 2. Arsitektur Perulangan Model Unit LSTM

$$f_t = \sigma(W_{fh}[h_{t-1}], W_{fx}[X_t], b_f), \quad (4)$$

$$i_t = \sigma(W_{ih}[h_{t-1}], W_{ix}[X_t], b_i), \quad (5)$$

$$\bar{C}_t = \tanh(W_c[h_{t-1}, X_t] + b_c), \quad (6)$$

$$C_t = i_t * C_{t-1} + i_t * \bar{C}_t, \quad (7)$$

$$o_t = \sigma(W_o[h_{t-1}, X_t] + b_o), \quad (8)$$

$$h_t = o_t * \tanh(C_t), \quad (9)$$

Pada arsitektur LSTM terdapat tiga gates yaitu forget gate (f_t), input gate (i_t), dan output gate (O_t). Forget gate (f_t) berfungsi untuk menghapus informasi dari cell state. Input gate (i_t) berfungsi dalam memutuskan informasi baru yang masuk kedalam cell state, sedangkan Output gate (O_t) berfungsi dalam memilah informasi yang berguna dari arus cell state dan menampilkannya sebagai output. Dengan x_t adalah nilai input, W merupakan bobot, b merupakan bias, h_{t-1} merupakan output dari waktu $t-1$, C_{t-1} merupakan memory cell state pada cell sebelumnya, dan h_t adalah output akhir (Puteri 2023).

Data Magnitudo Gempa dan Tantangan dalam Prediksi

Salah satu parameter penting dalam analisis seismik adalah data magnitudo gempa, yang mencerminkan jumlah energi yang dilepaskan selama kejadian gempa. Karena sifatnya yang non-linear dan seringkali dipengaruhi oleh faktor geologi yang sulit dihitung, prediksi magnitudo gempa menghadirkan tantangan khusus. Selain itu, gempa bermagnitudo besar sangat jarang terjadi, dan gempa-gempa bermagnitudo kecil biasanya memiliki frekuensi tinggi, karena distribusi gempa tidak merata. Sifat-sifat ini membuat mempelajari pola distribusi magnitudo sulit. Oleh karena itu, untuk menangkap pola temporal tersembunyi dalam data magnitudo gempa, pendekatan berbasis kecerdasan buatan seperti RNN dan LSTM diperlukan. Untuk menguji keandalan model dalam membuat prediksi yang akurat, penelitian ini menggunakan data magnitudo gempa dari dataset Kaggle (Rosca and Stancu 2024).

Evaluasi Metriks

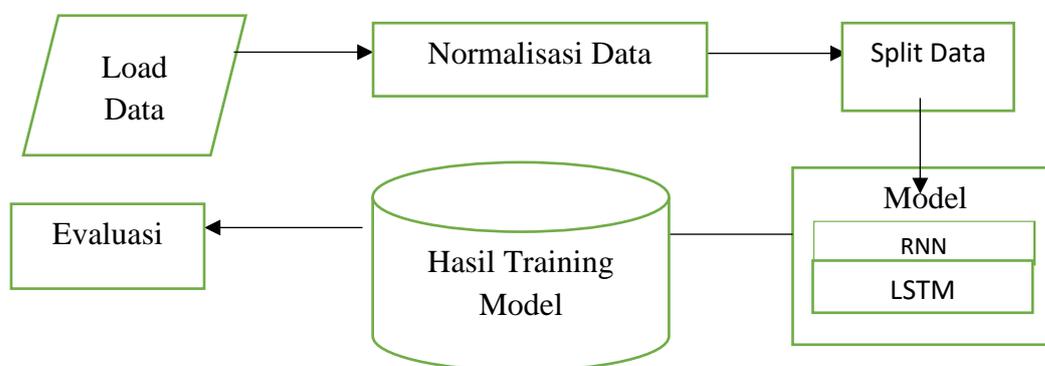
Dalam penelitian ini, dua jenis metrik evaluasi digunakan: Mean Absolut Error (MAE) dan Root Mean Square Error (RMSE). MAE digunakan untuk mengevaluasi keakuratan hasil prediksi menggunakan metode megkalkulasi rata-rata dari selisih absolut antara nilai sebenarnya dan nilai prediksi (Khoirunnisa Hamidah and Voutama 2023). sementara RMSE (Root Untuk menghitung besarnya kesalahan dalam prediksi, penggunaan "kesalahan persegi sederhana" RMSE menghitung perbedaan antara nilai sebenarnya dan nilai yang diharapkan dalam data, membagi jumlah operasi perkiraan dengan nilai total yang diperoleh dan mengambil akar quadrat (Tita Lattifia, Putu Wira Buana, and NI Kadek Dwi Rusjyanthi 2022). Rumus berikut untuk masing-masing dari kedua ukuran penilaian:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

$$RMSE = \sqrt{\frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (11)$$

Dengan n sebagai banyaknya data, \hat{y} sebagai hasil prediksi, dan y_i sebagai nilai data yang sebenarnya.

3. METODE PENELITIAN



Gambar 3. Metode Penelitian

Berikut adalah penjelasan untuk tahapan penelitian yang ditampilkan pada gambar 3, diantaranya:

1. Load Data

Penelitian ini menggunakan platform open-source data Kaggle untuk memuat data yang akan digunakan untuk analisis. Selanjutnya, data ini akan diproses dan dianalisis untuk memprediksi frekuensi gempa bulanan di Indonesia.

2. Normalisasi Data

Normalisasi dilakukan setelah data di-resample. Merubah skala data ke rentang tertentu (seperti [0, 1] atau [-1, 1]) adalah tujuan normalisasi. Ini sangat penting untuk model belajar pola seperti RNN dan LSTM, yang sensitif terhadap skala data, dapat melakukannya dengan lebih baik. Contoh metode normalisasi adalah skala min-max dan skala z (Nilsen 2022). Rumus untuk teknik normalisasi ini adalah sebagai berikut:

$$X' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (12)$$

3. Visualisasi Data

Untuk memastikan bahwa data benar, tren magnitudo gempa digambarkan dari waktu ke waktu setelah data diproses. Grafik tren tahunan ini memberikan gambaran tentang pola, fluktuasi, atau anomali magnitudo gempa. Visualisasi ini penting untuk mengetahui apakah data menunjukkan pola musiman, tren naik/turun, atau apakah ada aktivitas gempa yang signifikan pada tahun-tahun tertentu.

4. Split Data

Setelah semua tahap preprocessing selesai dan distribusi data sudah dapat dipahami dengan baik, langkah selanjutnya yang diperlukan adalah mengelompokkan data menjadi data pelatihan dan pengujian. Dalam penelitian ini, data training saya pakai data sebelum 2021 dan untuk data testing saya memakai 4 tahun terakhir dari dataset saya.

5. Model Algoritma

Setelah data dibagi, selanjutnya adalah membuat kedua model yang RNN dan LSTM untuk dibandingkan performanya menggunakan data training.

6. Evaluasi

Nilai error yang didapat pada setiap model kemudian akan digunakan sebagai evaluasi. Untuk nilai error yang digunakan sebagai evaluasi pada penelitian adalah RMSE dan MAE.

4. HASIL DAN PEMBAHASAN

1. Deskripsi Data

Data yang digunakan untuk penelitian ini berasal dari catatan gempa bumi yang terjadi di Indonesia dari November 2008 hingga September 2022. Data ini berasal dari sumber data Kaggle : <https://www.kaggle.com/datasets/greegtitan/indonesiearthquake-data>. Jumlah datanya adalah 87372 baris yang terdiri dari 6 kolom atau variabel. Berikut datanya saya tampilkan pada gambar 4.

```

      date      time  latitude  longitude  depth  magnitude
0    2008-11-01  00:31:25   -0.60   98.89553   20.0     2.99
1    2008-11-01  01:34:29   -6.61  129.38722   30.1     5.51
2    2008-11-01  01:38:14   -3.65  127.99068    5.0     3.54
3    2008-11-01  02:20:05   -4.20  128.09700    5.0     2.42
4    2008-11-01  02:32:18   -4.09  128.20047   10.0     2.41
...      ...      ...      ...      ...      ...
87367 2022-09-26  22:00:50   -8.15  121.35150   10.0     3.41
87368 2022-09-26  22:08:59    0.97  125.63014   12.1     3.29
87369 2022-09-26  22:11:43   -8.27  116.71154   10.0     3.38
87370 2022-09-26  22:53:16   -8.11  121.39471   10.0     3.49
87371 2022-09-26  23:17:38  -10.81  113.36631   10.0     4.90

[87372 rows x 6 columns]

```

Gambar 4. Data Asli Gempa

2. Pembahasan

a. Uji Coba 1

```

                                magnitude
date_time
2020-01-01 00:02:21                3.29
2020-01-01 04:27:36                2.25
2020-01-01 04:38:04                4.11
2020-01-01 05:31:55                3.52
2020-01-01 06:01:13                5.02
...
2021-01-01 08:57:43                2.77
2021-01-01 11:13:23                4.21
2021-01-01 11:32:18                3.77
2021-01-01 20:35:22                2.55
2021-01-01 23:24:25                3.06

[8802 rows x 1 columns]

```

Gambar 5. Data Magnitude (2020-2021) Untuk Uji Coba 1

Gambar ini menunjukkan data praproses dari kumpulan gempa. Kolom `date_time` menunjukkan tanggal dan waktu kejadian gempa, dan kolom `magnitude` menunjukkan skala gempa saat itu. Total 8802 baris dimasukkan ke dalam data, yang mencakup tanggal 1 Januari 2020 hingga 1 Januari 2021.

```

                                normalized_magnitude
date_time
2020-01-01 00:02:21                0.367720
2020-01-01 04:27:36                0.194676
2020-01-01 04:38:04                0.504160
2020-01-01 05:31:55                0.405990
2020-01-01 06:01:13                0.655574
...
2021-01-01 08:57:43                0.281198
2021-01-01 11:13:23                0.520799
2021-01-01 11:32:18                0.447587
2021-01-01 20:35:22                0.244592
2021-01-01 23:24:25                0.329451

[8802 rows x 1 columns]

```

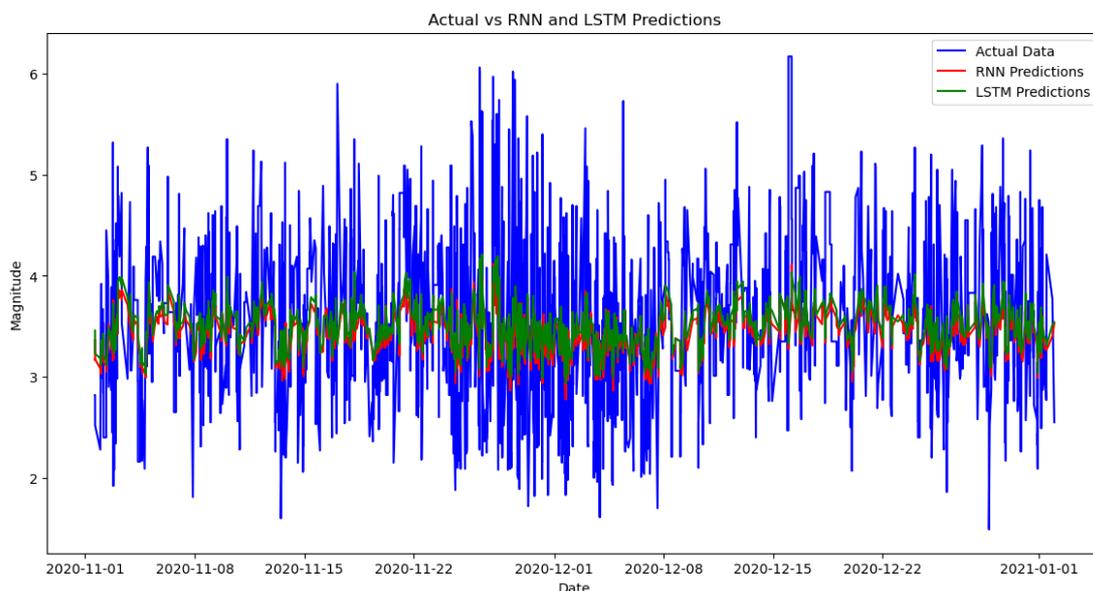
Gambar 6. Data Magnitudo Gempa yang Telah Dinormalisasi

Dataset dengan 8802 baris data dari 1 Januari 2020 hingga 1 Januari 2021, seperti yang ditunjukkan pada gambar. Selain itu, ada dua kolom dalam dataset ini: `date_time` dan `normalized_magnitude`. Nilai gempa bumi telah dinormalisasi dalam rentang 0-1, seperti yang ditunjukkan oleh nilai 0.367720 di awal data dan 0.329451 di akhir data. Data waktu diberikan dalam format "tahun-bulan-tanggal jam:menit:detik" dengan jumlah baris yang lebih sedikit (8802 baris) dibandingkan dengan kumpulan data sebelumnya (11571 baris), yang menunjukkan adanya perbedaan frekuensi kejadian gempa yang tercatat selama periode ini.

Tabel 1. Hasil Evaluasi Prediksi Magnitude RNN & LSTM Uji Coba 1

Metode	Training				Testing	
	Loss	Val Loss	MAE	RMSE	MAE	RMSE
RNN	0.0163	0.0170	0.6060	0.7542	0.6271	0.7831
LSTM	0.0155	0.0166	0.6083	0.7529	0.6226	0.7731

Model LSTM memprediksi magnitude dengan lebih baik daripada RNN, seperti yang ditunjukkan oleh nilai hilang, MAE, dan RMSE yang lebih rendah pada data uji dan latih. Ini menunjukkan bahwa model LSTM lebih akurat dan mampu melakukan generalisasi dengan lebih baik.



Gambar 7. Grafik Perbandingan Model pada Uji Coba 1

Dalam grafik ini, kita dapat melihat perbandingan antara prediksi yang dibuat menggunakan model RNN (merah) dan LSTM (hijau) pada rentang waktu tertentu. Terlihat bahwa prediksi LSTM lebih mirip dengan data aktual daripada prediksi RNN, terutama dalam hal mengikuti pola fluktuasi magnitude. Ini menunjukkan bahwa, dibandingkan dengan RNN, prediksi LSTM lebih baik dalam menangkap pola temporal data.

b. Uji Coba 2

```

                                magnitude
date_time
2018-01-01 00:52:32      5.11
2018-01-01 02:47:53      2.35
2018-01-01 03:03:26      2.39
2018-01-01 03:07:09      1.90
2018-01-01 03:24:53      4.27
...
2019-01-01 21:53:58      3.92
2019-01-01 22:07:32      4.53
2019-01-01 22:11:18      4.45
2019-01-01 22:12:30      2.42
2019-01-01 22:25:57      2.47

[11571 rows x 1 columns]

```

Gambar 8. Data Magnitude (2018-2019) Untuk Uji Coba 2

Gambar ini menunjukkan data praproses dari kumpulan gempa. Kolom `date_time` menunjukkan tanggal dan waktu kejadian gempa, dan kolom `magnitude` menunjukkan skala gempa saat itu. Total 11.571 baris dimasukkan ke dalam data, yang mencakup tanggal 1 Januari 2018 hingga 1 Januari 2019.

```

                                normalized_magnitude
date_time
2018-01-01 00:52:32      0.669477
2018-01-01 02:47:53      0.204047
2018-01-01 03:03:26      0.210793
2018-01-01 03:07:09      0.128162
2018-01-01 03:24:53      0.527825
...
2019-01-01 21:53:58      0.468803
2019-01-01 22:07:32      0.571669
...
2019-01-01 22:12:30      0.215852
2019-01-01 22:25:57      0.224283

[11571 rows x 1 columns]

```

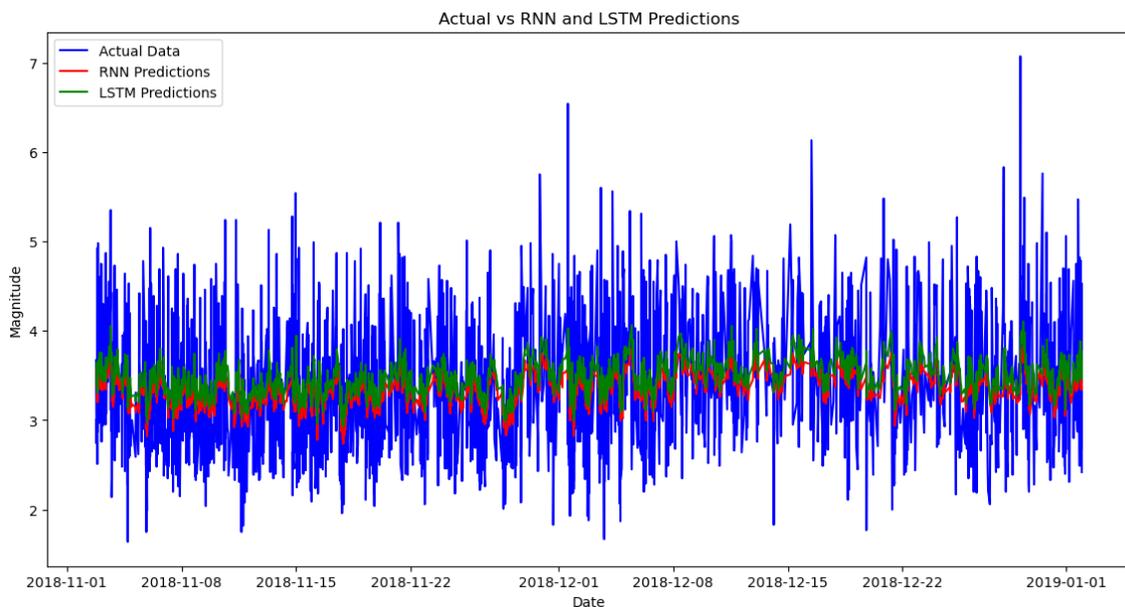
Gambar 9. Data Magnitudo Gempa yang Telah Dinormalisasi

Dalam gambar tersebut, dataset terdiri dari dua kolom: `date_time`, yang menunjukkan waktu dan tanggal, dan `normalized_magnitude`, yang menunjukkan kekuatan gempa yang telah dinormalisasi. Data ini memiliki 11571 baris data, yang mencakup periode dari 1 Januari 2018 hingga 1 Januari 2019. Nilai `normalized_magnitude` yang ditampilkan telah dinormalisasi sehingga berada dalam rentang 0-1. Misalnya, nilai `normalized_magnitude` untuk data pertama adalah 0,669477, dan nilai `normalized_magnitude` untuk data terakhir adalah 0,224283. Semua detik dalam format waktu ditampilkan dengan detail, seperti "2018-01-01 00:52:32". Metode RNN dan LSTM yang telah dibahas sebelumnya dapat digunakan sebagai data input untuk model prediksi magnitudo gempa.

Tabel 2. Hasil Evaluasi Prediksi Magnitude RNN & LSTM Uji Coba 2

Metode	Training				Testing	
	Loss	Val Loss	MAE	RMSE	MAE	RMSE
RNN	0.0147	0.0140	0.5748	0.7246	0.5583	0.7008
LSTM	0.0150	0.0145	0.5890	0.7286	0.5822	0.7132

Pada uji coba kedua, tabel tersebut menunjukkan perbandingan hasil evaluasi prediksi magnitude gempa menggunakan dua metode pembelajaran mesin, RNN (Recurrent Neural Network) dan LSTM (Long Short-Term Memory). Dalam pengujiannya, kedua model memiliki performa yang relatif mirip, di mana RNN menunjukkan nilai loss training 0.0147 dan val loss 0.0140, sementara LSTM memiliki loss training 0.0150 dan val loss 0.0145. Untuk metrik evaluasi MAE dan RMSE, RNN menghasilkan nilai yang sedikit lebih baik dibandingkan LSTM baik pada fase training maupun testing meskipun perbedaannya tidak terlalu signifikan.

**Gambar 10. Grafik Perbandingan Model pada Uji Coba 2**

Grafik menunjukkan perbandingan magnitude gempa aktual (biru) dengan prediksi model RNN (merah) dan LSTM (hijau) dari November 2018 hingga Januari 2019. Data aktual berfluktuasi antara magnitude 2-7, sementara kedua model memberikan prediksi yang lebih stabil di sekitar magnitude 3-4. Meski kedua model menunjukkan pola prediksi yang mirip, keduanya tampak kurang optimal dalam memprediksi kejadian gempa dengan magnitude ekstrem.

5. KESIMPULAN DAN SARAN

Dalam dataset dengan pola temporal yang kompleks, seperti pada uji coba pertama, LSTM berhasil lebih baik daripada RNN dengan MAE 0.6226 dan RMSE 0.7731. Ini menunjukkan bahwa LSTM lebih baik dalam memahami pola data yang lebih kompleks. Dalam dataset uji coba kedua, yang relatif sederhana, RNN menghasilkan MAE 0.5583 dan RMSE 0.7008 lebih baik daripada LSTM. Ini menunjukkan bahwa ketika dataset memiliki pola temporal yang lebih mudah dikenali, RNN lebih stabil. Proses normalisasi dan pemisahan data menjadi pelatihan dan pengujian menghasilkan hasil prediksi yang lebih stabil dan akurat. Namun, dengan menambah data gempa bermagnitudo besar untuk meningkatkan representasi pola, kedua model dapat lebih baik.

Sangat disarankan untuk melihat model canggih seperti Bidirectional LSTM (BiLSTM) atau Gated Recurrent Unit (GRU) yang memiliki kapasitas yang lebih besar untuk menangkap pola temporal data gempa. Untuk meningkatkan keakuratan prediksi, terutama dalam menangkap pola ekstrem, data set harus diperluas dengan data dari gempa bermagnitudo besar dan kejadian langka lainnya. Model yang dibuat dapat diterapkan pada sistem prediksi gempa berbasis real-time yang berfungsi untuk meminimalkan risiko gempa. Sistem ini akan membantu pemerintah dan masyarakat mengambil tindakan mitigasi yang lebih efektif. Untuk menguji generalisasi model terhadap berbagai pola gempa, disarankan untuk melakukan validasi tambahan dengan teknik cross-validation pada dataset yang lebih beragam.

DAFTAR REFERENSI

- Agwil, Winalia. 2020. "Penerapan Jaringan Saraf Tiruan Pada Data Gempa Bumi Di Provinsi Bengkulu." *Jurnal Statistika Universitas Muhammadiyah Semarang* 8(2):152. doi: 10.26714/jsunimus.8.2.2020.152-158.
- Berhich, Asmae, Fatima Zahra Belouadha, and Mohammed Issam Kabbaj. 2020. "LSTM-Based Models for Earthquake Prediction." *ACM International Conference Proceeding Series* (August). doi: 10.1145/3386723.3387865.
- Bhandarkar, Tanvi, Vardaan K, Nikhil Satish, S. Sridhar, R. Sivakumar, and Snehasish Ghosh. 2019. "Earthquake Trend Prediction Using Long Short-Term Memory RNN." *International Journal of Electrical and Computer Engineering (IJECE)* 9(2):1304. doi: 10.11591/ijece.v9i2.pp1304-1312.
- Bilal, Muhammad Atif, Yongzhi Wang, Yanju Ji, Muhammad Pervez Akhter, and Hengxi Liu. 2023. "Earthquake Detection Using Stacked Normalized Recurrent Neural Network (SNRNN)." *Applied Sciences (Switzerland)* 13(14). doi: 10.3390/app13148121.
- Ercan, Doç Emre, and Nuh Muhammed Pişkin. 2019. "Earthquake Estimation with Lstm Network Model."

- Nurhopipah, Ade, and Cindy Magnolia. 2023. "Perbandingan Metode Resampling Pada Imbalanced Dataset Untuk Klasifikasi Komentar Program Mbkm." *Jurnal Publikasi Ilmu Komputer Dan Multimedia* 2(1):9–22. doi: 10.55606/jupikom.v2i1.862.
- Somantri, Oman. 2021. "Prediksi Kekuatan Gempa Bumi Indonesia Berdasarkan Nilai Magnitudo Menggunakan Neural Network." *Prosiding Seminar Nasional Informatika Bela Negara* 2(November 2021):203–7. doi: 10.33005/santika.v2i0.124.
- González, Jesús, Wen Yu, and Luciano Telesca. 2019. "Earthquake Magnitude Prediction Using Recurrent Neural Networks." 22. doi: 10.3390/iecg2019-06213.
- Irawan, Lukman, Liyando Hermawan Hasibuan, and Fauzi Fauzi. 2020. "Analisa Prediksi Efek Kerusakan Gempa Dari Magnitudo (Skala Richter) Dengan Metode Algoritma Id3 Menggunakan Aplikasi Data Mining Orange." *Jurnal Teknologi Informasi: Jurnal Keilmuan Dan Aplikasi Bidang Teknik Informatika* 14(2):189–201. doi: 10.47111/jti.v14i2.1079.
- Khoirunnisa Hamidah, and Apriade Voutama. 2023. "Analisis Faktor Tingkat Kebahagiaan Negara Menggunakan Data World Happiness Report Dengan Metode Regresi Linier." *Explore IT: Jurnal Keilmuan Dan Aplikasi Teknik Informatika* 15(1):1–7. doi: 10.35891/explorit.v15i1.3874.
- Mulyawan, Rifqi. 2024. "Vanishing Gradient Problem."
- Nilsen, Andrew. 2022. "Perbandingan Model RNN, Model LSTM, Dan Model GRU Dalam Memprediksi Harga Saham-Saham LQ45." *Jurnal Statistika Dan Aplikasinya* 6(1):137–47. doi: 10.21009/jsa.06113.
- Pontoh, Resa Septiani, Toni Toharudin, Budi Nurani Ruchjana, Farhat Gumelar, Fariza Alamanda Putri, Muhammad Naufal Agisya, and Rezzy Eko Caraka. 2022. "Jakarta Pandemic to Endemic Transition: Forecasting COVID-19 Using NNAR and LSTM." *Applied Sciences (Switzerland)* 12(12). doi: 10.3390/app12125771.
- Puteri, Dian Islamiaty. 2023. "Implementasi Long Short Term Memory (LSTM) Dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah." 11(1):35–43.
- Rosca, Cosmina-mihaela, and Adrian Stancu. 2024. "Earthquake Prediction and Alert System Using IoT Infrastructure and Cloud-Based Environmental Data Analysis."
- Sadhukhan, Bikash, Shayak Chakraborty, Somenath Mukherjee, and Raj Kumar Samanta. 2023. "Climatic and Seismic Data-Driven Deep Learning Model for Earthquake Magnitude Prediction." *Frontiers in Earth Science* 11(February):1–24. doi: 10.3389/feart.2023.1082832.
- Swastikawati, Claudia, Muhamad Agoeng Pamoengkas, Alfian Cahyo Wahyudi, and Kusri. 2024. "Penerapan Data Sains Untuk Klasifikasi Wilayah Yang Terdampak." 7(2):390–402.
- Tambunan, Holpan Torang B., Dedy Hartama, and Indra Gunawan. 2021. "Implementasi Jaringan Syaraf Tiruan (JST) Untuk Memprediksi Jumlah Penjualan Gas 3Kg

Menggunakan Metode Backpropagation.” *Tin: Terapan Informatika Nusantara* 1(9):479–88.

Tita Lattifia, Putu Wira Buana, and NI Kadek Dwi Rusjyanthi. 2022. “Model Prediksi Cuaca Menggunakan Metode LSTM.” *JITTER-Jurnal Ilmiah Teknologi Dan Komputer* 3(1).

Wang, Xi, Zeyuan Zhong, Yuechen Yao, Zexu Li, Shiyong Zhou, Changsheng Jiang, and Ke Jia. 2023. “Applied Sciences Small Earthquakes Can Help Predict Large Earthquakes :”

Yunizar, Ahmad, Tedy Rismawan, and Dwi Marisa Midyanti. 2023. “Penerapan Metode Recurrent Neural Network Model Gated Recurrent Unit Untuk Prediksi Harga Cryptocurrency.” *Coding Jurnal Komputer Dan Aplikasi* 11(1):32. doi: 10.26418/coding.v11i1.58073.