

Pendekatan Wavenet-Inspired Dan LSTM Untuk Prediksi Magnitudo Gempa Sebagai Upaya Transformasi Digital Mitigasi Bencana Di Indonesia

Najmuddin Mubarak MR¹, Susandri², Ahmad Zamsuri³, Maya Ramadhani⁴

^{1,2,3}Program Studi Magister Ilmu Komputer Pascasarjana Universitas Lancang Kuning

^{1,2,3}Jl. Yos Sudarso KM. 8 Rumbai, Pekanbaru, Riau

E-mail: 1mudinnajim85@gmail.com, 2susandri@unilak.ac.id, 3ahmadzamsuri@unilak.ac.id
4maya@unilak.ac.id

Abstrak

Indonesia merupakan salah satu negara dengan aktivitas seismik tertinggi di dunia sehingga pengembangan sistem peringatan dini berbasis teknologi digital menjadi kebutuhan mendesak. Penelitian ini memanfaatkan pendekatan deep learning untuk mendukung transformasi digital dalam prediksi magnitudo gempa. Dua arsitektur dibandingkan, yaitu Long Short-Term Memory (LSTM) dan WaveNet-Inspired, menggunakan data katalog seismik Indonesia. Model LSTM dirancang dengan konfigurasi LSTM(128)–Dropout(0,3)–Dense(64), sedangkan WaveNet-Inspired memanfaatkan dilated causal convolution dan skip connection guna menangkap pola temporal yang kompleks. Kinerja model dievaluasi menggunakan Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan koefisien determinasi (R^2). Hasil eksperimen menunjukkan bahwa WaveNet-Inspired memiliki performa lebih baik dengan RMSE 0,5494; MAE 0,4237; dan R^2 0,5492 dibandingkan LSTM yang mencatat RMSE 0,8701; MAE 0,6888; dan R^2 -0,1369. Temuan ini menegaskan pentingnya transformasi digital melalui integrasi teknologi deep learning untuk meningkatkan akurasi sistem peringatan dini gempa di Indonesia..

Kata Kunci: Prediksi Gempa, WaveNet-Inspired, LSTM, Deep Learning, Transformasi Digital..

Abstract

Indonesia is among the world's most seismically active countries, making the development of technology-driven early-warning systems an urgent need. This study applies a deep-learning approach to support the digital transformation of earthquake magnitude prediction. Two architectures—Long Short-Term Memory (LSTM) and WaveNet-Inspired—were compared using Indonesia's seismic catalog data. The LSTM model follows an LSTM(128)–Dropout(0.3)–Dense(64) configuration, while the WaveNet-Inspired design leverages dilated causal convolution and skip connections to capture complex temporal patterns. Model performance was evaluated using Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and the coefficient of determination (R^2). Experimental results indicate that the WaveNet-Inspired model achieved superior accuracy with RMSE 0.5494, MAE 0.4237, and R^2 0.5492 compared to the LSTM model, which recorded RMSE 0.8701, MAE 0.6888, and R^2 -0.1369. These findings highlight the importance of digital transformation through the integration of deep-learning technology to enhance the accuracy of Indonesia's earthquake early-warning systems.

Keywords: Earthquake Prediction, WaveNet-Inspired, LSTM, Deep Learning, Digital Transformation.

1. PENDAHULUAN

Indonesia merupakan negara kepulauan yang terletak di pertemuan tiga lempeng besar dunia: Indo-Australia, Eurasia, dan Pasifik. Posisi tektonik ini menjadikan Indonesia salah satu wilayah dengan aktivitas gempa paling intens di dunia [1]. Gempa bumi yang terjadi tidak hanya menimbulkan kerugian material yang besar, tetapi juga mengancam keselamatan jiwa dan mengganggu stabilitas sosial ekonomi masyarakat [2]. Oleh karena itu, pengembangan sistem mitigasi bencana yang cepat, akurat, dan berbasis teknologi menjadi kebutuhan mendesak agar risiko dan dampak kerusakan dapat diminimalkan [3].

Selama beberapa dekade, metode prediksi gempa tradisional banyak mengandalkan pendekatan statistik dan analisis fisik seismologi [4]. Meskipun metode tersebut memberikan wawasan yang berharga, kompleksitas pola temporal dan karakteristik nonlinier data seismik sering kali membuat prediksi kurang presisi [5]. Di era transformasi digital, kemajuan teknologi komputasi dan ketersediaan data besar (big data) menghadirkan peluang baru untuk mengembangkan model prediksi yang lebih canggih dan andal, khususnya melalui penerapan *machine learning* dan *deep learning* [6].

Long Short-Term Memory (LSTM), sebagai salah satu varian Recurrent Neural Network (RNN), telah terbukti efektif dalam mempelajari ketergantungan jangka panjang pada data deret waktu [7]. Keunggulan LSTM terletak pada kemampuannya menahan informasi penting dalam jangka waktu yang panjang serta mengurangi masalah *vanishing gradient* yang umum terjadi pada RNN konvensional. Berbagai penelitian di bidang cuaca, keuangan, dan seismologi menunjukkan bahwa LSTM mampu menghasilkan prediksi yang kompetitif. Namun, LSTM masih menghadapi tantangan ketika dihadapkan pada data seismik yang sangat kompleks dan sporadis [8].


Di sisi lain, arsitektur WaveNet yang awalnya dikembangkan untuk pemrosesan sinyal audio, menawarkan keunggulan dalam menangkap pola temporal yang rumit melalui *dilated causal convolution* dan *skip connections* [9]. Karakteristik ini memungkinkan model untuk memiliki *receptive field* yang luas tanpa menambah jumlah parameter secara signifikan, sehingga efisien dalam mengenali pola jangka panjang. Adaptasi konsep WaveNet-Inspired pada data gempa diharapkan mampu mengatasi keterbatasan LSTM, terutama dalam memodelkan ketergantungan nonlinier pada data seismik [10].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan membandingkan kinerja model LSTM dan WaveNet-Inspired untuk prediksi magnitudo gempa di Indonesia sebagai bagian dari upaya transformasi digital dalam mitigasi bencana. Evaluasi kinerja dilakukan menggunakan metrik Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan koefisien determinasi (R^2). Hasil yang diperoleh diharapkan dapat memberikan kontribusi nyata dalam meningkatkan akurasi sistem peringatan dini gempa, sekaligus mendukung kebijakan nasional terkait pemanfaatan teknologi digital untuk mengurangi risiko bencana [11].

2. METODE PENELITIAN

Metode penelitian ini dirancang untuk memberikan gambaran menyeluruh mengenai tahapan kerja yang dilakukan dalam memprediksi magnitudo gempa menggunakan pendekatan deep learning. Proses penelitian dimulai dari perancangan dan

pengumpulan data, dilanjutkan dengan pra-pemrosesan untuk memastikan kualitas data yang optimal, kemudian pengembangan serta pelatihan model Long Short-Term Memory (LSTM) dan WaveNet-Inspired. Selanjutnya dilakukan evaluasi kinerja melalui pengukuran metrik statistik dan analisis perbandingan untuk menentukan model dengan performa terbaik. Seluruh tahapan tersebut disajikan secara ringkas dalam diagram alir (flowchart) Gambar 1 yang menggambarkan urutan kegiatan penelitian secara lengkap mulai dari tahap awal hingga tahap akhir.



Gambar 1. Flowchart Metode Penelitian

Adapan tahapan yang dilakukan berdasarkan gambar 1 diatas adalah sebagai berikut;

2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental untuk membandingkan dua arsitektur *deep learning*—Long Short-Term Memory (LSTM) dan WaveNet-Inspired—dalam memprediksi magnitudo gempa di Indonesia. Desain eksperimen dipilih untuk memungkinkan pengukuran kinerja model secara objektif melalui metrik statistik, sekaligus mendukung pemanfaatan teknologi *deep learning* sebagai bagian dari transformasi digital mitigasi bencana. Seluruh proses perancangan dan analisis dilakukan dengan bahasa pemrograman Python serta pustaka *TensorFlow* dan *Keras*, sehingga hasilnya dapat direplikasi oleh peneliti lain.

2.2 Pengumpulan Data

Data penelitian diperoleh dari katalog gempa Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) periode 2010–2025. Katalog ini memuat informasi waktu kejadian, magnitudo, kedalaman, serta koordinat lintang dan bujur yang merepresentasikan aktivitas seismik di seluruh wilayah Indonesia. Data dipilih karena cakupannya luas dan memiliki tingkat keandalan tinggi untuk menggambarkan pola gempa secara nasional. Seluruh data diunduh melalui portal resmi BMKG dalam format digital yang memungkinkan pengolahan lanjutan.

2.3 Pra-Pemrosesan Data

Proses pra-pemrosesan dilakukan secara berlapis untuk memastikan data siap digunakan dalam pelatihan model. Tahap pertama adalah pembersihan data dengan menghapus duplikasi, memperbaiki format tanggal dan waktu, serta menangani data hilang atau anomali. Selanjutnya, semua variabel numerik dinormalisasi ke rentang $[0,1]$ menggunakan metode *Min-Max Scaling* agar proses pembelajaran model menjadi lebih stabil dan cepat. Data kemudian diubah menjadi bentuk deret waktu dengan *window* 30 hari, sehingga setiap jendela data berisi 30 titik observasi yang digunakan untuk memprediksi magnitudo pada hari berikutnya. Pembagian data dilakukan dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian dengan mempertahankan urutan kronologis agar pola temporal tidak terganggu.

2.4 Pengembangan dan Pelatihan Model

Tahap pengembangan model melibatkan dua arsitektur yang berbeda. Model LSTM dirancang dengan lapisan *LSTM(128)* yang mampu mempelajari ketergantungan jangka panjang, diikuti *Dropout(0,3)* untuk mengurangi *overfitting*, kemudian lapisan *Dense(64)* dengan aktivasi ReLU, dan lapisan keluaran linear. Model WaveNet-Inspired memanfaatkan tumpukan *dilated causal Conv1D* dengan tingkat dilasi 2^1 hingga 2^5 , aktivasi *gated tanh-sigmoid*, serta *skip connections* yang memperluas *receptive field* tanpa menambah parameter secara signifikan. Bagian akhir model terdiri atas lapisan ReLU, Flatten, Dense(64), Dropout(0,2), dan lapisan output linear. Kedua model dilatih menggunakan *optimizer* Adam dengan *learning rate* 0,001 dan fungsi kerugian Mean Squared Error (MSE). Proses pelatihan dilakukan selama 100 *epoch* dengan *batch size* 32, serta dilengkapi *early stopping* berdasarkan nilai *validation loss* untuk mencegah *overfitting*.

2.5 Evaluasi Kinerja dan Analisis Perbandingan

Evaluasi kinerja dilakukan menggunakan metode *5-fold cross-validation* untuk menjamin reliabilitas hasil. Tiga metrik utama digunakan: Root Mean Square Error (RMSE) untuk mengukur besarnya kesalahan prediksi secara keseluruhan, Mean Absolute Error (MAE) untuk menghitung rata-rata selisih absolut antara nilai aktual dan prediksi, dan koefisien determinasi (R^2) untuk menilai proporsi variasi data yang dapat dijelaskan oleh model. Setelah evaluasi selesai, hasil dari kedua model dianalisis dan dibandingkan untuk mengidentifikasi arsitektur yang memberikan kinerja terbaik. Analisis juga menyoroti keunggulan mekanisme *dilated convolution* pada WaveNet dibandingkan kemampuan memori jangka panjang LSTM. Hasil ini diharapkan memberikan kontribusi signifikan dalam peningkatan akurasi sistem peringatan dini gempa serta memperkuat langkah transformasi digital di bidang mitigasi bencana..


3. HASIL DAN PEMBAHASAN

Penelitian ini membandingkan kinerja dua arsitektur *deep learning*, yakni Long Short-Term Memory (LSTM) dan WaveNet-Inspired, dalam memprediksi magnitudo gempa di Indonesia. Model dilatih dan diuji menggunakan data katalog gempa BMKG periode 2010–2025 dengan pembagian 80% data pelatihan dan 20% data pengujian. Evaluasi dilakukan melalui *5-fold cross-validation* menggunakan metrik Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan koefisien determinasi (R^2).


3.1 Hasil Pelatihan Model

Gambar 2 dan Gambar 3 menampilkan kurva *loss* dan sebaran nilai aktual vs prediksi untuk model WaveNet-Inspired. Kurva menunjukkan penurunan *train loss* dan *validation loss* yang stabil hingga akhir pelatihan, menandakan proses pembelajaran yang baik dan

minim *overfitting*. Sebaran prediksi terhadap nilai aktual membentuk pola diagonal yang rapat, mengindikasikan akurasi prediksi yang tinggi.



Gambar 2. WaveNet-Inspired – Scatter Plot Nilai Aktual vs Prediksi




Gambar 3. WaveNet-Inspired – Kurva *Train Loss* dan *Validation Loss*


Pada gambar 2 WaveNet-Inspired – Scatter Plot Nilai Aktual vs Prediksi, menunjukkan hubungan antara nilai aktual dan nilai prediksi yang dihasilkan oleh model WaveNet-Inspired dalam bentuk scatter plot. Sumbu horizontal merepresentasikan nilai aktual, sedangkan sumbu vertikal menunjukkan nilai prediksi. Titik-titik data membentuk pola cenderung linear naik, yang menandakan bahwa model mampu mengikuti tren nilai aktual dengan cukup baik. Namun, masih terlihat adanya sebaran titik yang cukup lebar, terutama pada nilai aktual yang lebih tinggi, yang mengindikasikan adanya error prediksi dan variasi performa model pada rentang nilai tertentu.

Sedangkan WaveNet-Inspire Kurva Train Loss dan Validation Loss, yang divisualisasikan pada gambar 3 memperlihatkan kurva penurunan nilai loss selama proses pelatihan model. Kurva train loss dan validation loss sama-sama mengalami penurunan seiring bertambahnya epoch, yang menunjukkan bahwa model berhasil melakukan proses pembelajaran. Selisih antara train loss dan validation loss relatif kecil dan stabil, menandakan tidak terjadinya *overfitting* yang signifikan. Pada epoch akhir, kedua kurva cenderung konvergen, yang menunjukkan bahwa model telah mencapai kondisi pelatihan yang cukup optimal.

Gambar 4 dan Gambar 5 menunjukkan hasil untuk model LSTM. Kurva *loss* memperlihatkan divergensi antara *train loss* dan *validation loss* pada epoch sekitar 20, yang mengindikasikan terjadinya *overfitting*. Scatter plot aktual vs prediksi juga menampilkan sebaran yang lebih menyebar dibandingkan WaveNet-Inspired, sehingga ketepatan prediksi model LSTM relatif lebih rendah.



Gambar 4. LSTM – Scatter Plot Nilai Aktual vs Prediksi



Gambar 5. LSTM – Kurva *Train Loss* dan *Validation Loss*

3.2 Perbandingan Kinerja

Ringkasan perbandingan performa kedua model ditampilkan pada Tabel 1.

TABEL 1. Perbandingan Kinerja Model Prediksi Magnitudo Gempa

Model	RMSE	MAE	R ²
LSTM	0,8701	0,6888	-0,1369
WaveNet-Inspired	0,5494	0,4237	0,5492

Tabel di atas menunjukkan bahwa WaveNet-Inspired unggul pada semua metrik evaluasi. Nilai RMSE dan MAE yang lebih rendah menandakan kesalahan prediksi yang lebih kecil, sedangkan R^2 yang positif dan cukup tinggi menandakan model mampu menjelaskan variasi data dengan baik. Sebaliknya, nilai R^2 negatif pada LSTM menunjukkan bahwa model tersebut tidak dapat menangkap pola data secara optimal.

3.3 Pembahasan

Keunggulan WaveNet-Inspired dapat dijelaskan melalui arsitektur *dilated causal convolution* yang memperluas *receptive field* secara efisien tanpa menambah parameter, memungkinkan model menangkap pola temporal jangka panjang dan kompleks. Mekanisme *skip connections* membantu menjaga aliran gradien sehingga mengurangi risiko *vanishing gradient* yang umum pada RNN, termasuk LSTM. LSTM tetap memiliki kemampuan mengingat informasi jangka panjang, namun pola seismik Indonesia yang sangat bervariasi dan nonlinier membuat model ini kesulitan mempertahankan akurasi tinggi.

Hasil penelitian ini menegaskan bahwa integrasi arsitektur WaveNet-Inspired ke dalam sistem peringatan dini gempa dapat meningkatkan akurasi prediksi dan mendukung transformasi digital mitigasi bencana di Indonesia. Temuan ini memberikan dasar ilmiah bagi pengembangan lebih lanjut, misalnya integrasi data geodesik atau penerapan *transfer learning* untuk memperluas cakupan prediksi.

4. KESIMPULAN

Penelitian ini membandingkan kinerja dua arsitektur deep learning, yaitu Long Short-Term Memory (LSTM) dan WaveNet-Inspired, dalam memprediksi magnitudo gempa bumi di Indonesia. Berdasarkan hasil pengujian menggunakan metode 5-fold cross-validation dengan metrik RMSE, MAE, dan koefisien determinasi (R^2), model WaveNet-Inspired menunjukkan kinerja yang jauh lebih baik dengan RMSE 0,5494, MAE 0,4237, dan R^2 0,5492. Sementara itu, model LSTM hanya mencapai RMSE 0,8701, MAE 0,6888, dan R^2 -0,1369.

Keunggulan WaveNet-Inspired dipengaruhi oleh kemampuan *dilated causal convolution* dan *skip connections* dalam menangkap pola temporal kompleks tanpa menambah parameter secara signifikan, sehingga model mampu mempelajari karakteristik data seismik yang bersifat nonlinier dan sporadis. Temuan ini menegaskan bahwa integrasi arsitektur WaveNet-Inspired ke dalam sistem peringatan dini gempa dapat meningkatkan akurasi prediksi sekaligus mendukung transformasi digital dalam mitigasi bencana di Indonesia.

Untuk pengembangan selanjutnya, disarankan melakukan integrasi data geodesik seperti slip-rate GPS dan menerapkan transfer learning guna memperluas cakupan prediksi dan meningkatkan generalisasi model. Dengan demikian, hasil penelitian ini dapat menjadi dasar penting bagi pemanfaatan teknologi deep learning dalam membangun sistem peringatan dini gempa yang lebih andal, cepat, dan efisien.

UCAPAN TERIMA KASIH

Puji syukur penulis panjatkan ke hadirat Allah SWT atas rahmat dan karunia-Nya sehingga penelitian ini dapat diselesaikan. Penulis mengucapkan terima kasih kepada Yayasan Syirkah Ta'awuniyah Pekanbaru (YSTP) atas dukungan dan kerja sama yang diberikan, serta kepada semua pihak yang telah membantu dan memberikan kontribusi dalam

penyusunan penelitian ini. Semoga hasil penelitian ini bermanfaat bagi yayasan dan pengembangan ilmu pengetahuan di bidang teknologi informasi.

DAFTAR PUSTAKA

- [1] I. O. Arissinta, I. D. Sulistiyawati, D. Kurnianto, and I. Kharisudin, "Pemodelan Time Series untuk Peramalan Web Traffic Menggunakan Algoritma Arima," *Prism. Pros. Semin. Nas. Mat.*, vol. 5, pp. 693–700, 2022, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [2] S. Susandri, S. Defit, and M. Tajuddin, "Enhancing Text Sentiment Classification with Hybrid CNN-BiLSTM Model on WhatsApp Group," *J. Adv. Inf. Technol.*, vol. 15, no. 3, pp. 355–363, 2024, doi: 10.12720/jait.15.3.355-363.
- [3] C. Zoremsanga and J. Hussain, "Particle Swarm Optimized Deep Learning Models for Rainfall Prediction: A Case Study in Aizawl, Mizoram," *IEEE Access*, vol. 12, no. April, pp. 57172–57184, 2024, doi: 10.1109/ACCESS.2024.3390781.
- [4] P. Ayuningtyas, S. Khomsah, and S. Sudianto, "Pelabelan Sentimen Berbasis Semi-Supervised Learning menggunakan Algoritma LSTM dan GRU," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 9, no. 3, pp. 217–229, 2024, doi: 10.14421/jiska.2024.9.3.217-229.
- [5] M. I. K. Asmae Berhich, Fatima-Zahra Belouadha, "LSTM-based Models for Earthquake Prediction," *NISS '20 Proc. 3rd Int. Conf. Networking, Inf. Syst. Secur. Artic.*, p. Pages 1-7, 2020, [Online]. Available: https://dl.acm.org/doi/10.1145/3386723.3387865?utm_source=chatgpt.com
- [6] D. A. Hanan, A. Y. Husodo, and R. P. Rassy, "Sentiment Study of ChatGPT on Twitter Data with Hybrid K-Means and LSTM," vol. 24, no. 2, pp. 273–284, 2025, doi: 10.30812/matrik.v24i2.4791.
- [7] Roni Merdiansah, Khofifah Wulandari, Mentari Hasibuan, and Yuyun Umaidah, "Perbandingan Kinerja Model RNN, LSTM, dan BLSTM dalam Memprediksi Jumlah Gempa Bulanan di Indonesia," *J. Penelit. Rumpun Ilmu Tek.*, vol. 3, no. 1, pp. 262–277, 2024, doi: 10.55606/juprit.v3i1.3466.
- [8] M. Rizki, S. Basuki, and Y. Azhar, "Implementasi Deep Learning Menggunakan Arsitektur Long Short Term Memory(LSTM) Untuk Prediksi Curah Hujan Kota Malang," *J. Repos.*, vol. 2, no. 3, pp. 331–338, 2020, doi: 10.22219/repositor.v2i3.470.
- [9] H. Tantyoko, D. K. Sari, and A. R. Wijaya, "Prediksi Potensial Gempa Bumi Indonesia Menggunakan Metode Random Forest Dan Feature Selection," *IDEALIS Indones. J. Inf. Syst.*, vol. 6, no. 2, pp. 83–89, 2023, doi: 10.36080/idealis.v6i2.3036.
- [10] O. Somantri, J. Teknik Informatika, and P. Negeri Cilacap, "Seminar Nasional Informatika Bela Negara (SANTIKA) Prediksi Kekuatan Gempa Bumi Indonesia Berdasarkan Nilai Magnitudo Menggunakan Neural Network," vol. 2, pp. 203–207, 2021.
- [11] N. Mubarak MR, F. N. Salisah, M. Megawati, and F. Muttakin, "Perancangan Arsitektur Sistem Informasi Enterprise Menggunakan Togaf Pada Ma'Had Al Husna Indragiri," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 10, no. 1, pp. 381–395, 2025, doi: 10.29100/jipi.v10i1.5828.

