



IMPLEMENTASI *DEEP LEARNING* MENGGUNAKAN *LONG SHORT-TERM MEMORY* UNTUK PREDIKSI STABILITAS PONDASI TAHAN GEMPA

Safitri^{1*}, Fatsyahrina Fitriastuti², Ryan Ari Setyawan³, Teguh Widodo⁴

^{1,2,3}Program Studi Informatika, Universitas Janabadra

⁴Program Studi Teknik Sipil, Universitas Janabadra

email: saafitrii09@gmail.com^{1*}

Abstrak: Pondasi merupakan elemen struktural yang sangat krusial dalam menjamin kestabilan bangunan terhadap beban gempa. Ketidakstabilan pada sistem pondasi dapat memicu keruntuhan total struktur meskipun elemen atas telah dirancang tahan gempa. Penelitian ini bertujuan untuk mengembangkan model prediksi stabilitas pondasi menggunakan pendekatan *deep learning* berbasis *Long Short-Term Memory* (LSTM) dengan memanfaatkan data gaya dan momen sambungan (*joint reactions*) hasil analisis struktur dari perangkat lunak SAP2000. Dataset terdiri atas tiga jenis bangunan berbeda, yakni pondasi utama, gedung *service*, dan gedung klinik teduh, yang masing-masing memuat komponen gaya (F1, F2, F3) dan momen (M1, M2, M3). Data diproses melalui tahapan normalisasi, penyusunan *time series* lima langkah ke belakang, dan pelatihan model menggunakan arsitektur LSTM dua lapis dengan *dropout* 0,2. Evaluasi dilakukan dengan skema validasi silang (*Time Series Split*) dan pengujian data *unseen*. Hasil penelitian menunjukkan bahwa model mampu melakukan prediksi dengan akurasi, presisi, *recall*, dan *F1-score* sebesar 1,0000. Grafik perbandingan *training loss* dan *validation loss* memperlihatkan konvergensi yang stabil tanpa indikasi *overfitting*. Sistem ini juga berhasil mengintegrasikan deteksi *noise* berbasis *threshold error*, memungkinkan klasifikasi anomali struktural secara otomatis. Kesimpulan dari penelitian ini menyatakan bahwa model LSTM sangat efektif dalam memprediksi respons pondasi terhadap gempa serta mendeteksi ketidaknormalan pola gaya dan momen.

Kata Kunci: *LSTM, Prediksi Time-Series, Deep Learning, Joint Reactions, Noise Detection*

PENDAHULUAN

Perubahan paradigma dalam dunia konstruksi modern menuntut pendekatan yang lebih adaptif dan prediktif terhadap potensi bencana alam, khususnya gempa bumi. Bangunan yang dibangun di wilayah rawan gempa memerlukan ketahanan struktural tidak hanya pada elemen atas seperti kolom, balok, dan pelat, tetapi juga pada sistem pondasi yang menjadi tumpuan utama beban vertikal maupun lateral. Pondasi memegang peranan vital dalam meredam gaya yang ditimbulkan oleh aktivitas seismik, di mana kestabilannya sangat mempengaruhi integritas keseluruhan struktur bangunan [1]. Berbagai metode konvensional seperti analisis statik dan dinamik berbasis *software* simulasi telah digunakan secara luas, namun pendekatan ini cenderung bersifat deterministik dan tidak memiliki kemampuan adaptif dalam memahami pola historis dari data struktural secara waktu-ke-waktu.

Gempa bumi merupakan fenomena alam yang menimbulkan beban dinamis pada struktur bangunan, yang bersifat tak terprediksi dan sangat merusak. Beban gempa tidak hanya bekerja secara lateral, tetapi juga dapat menimbulkan efek vertikal dan torsi yang berbahaya bagi kestabilan pondasi. Secara teknis, respons bangunan terhadap gempa dipengaruhi oleh frekuensi dominan struktur, jenis tanah, dan konfigurasi pembebanan, termasuk efek resonansi apabila frekuensi alami struktur mendekati frekuensi getaran tanah [1]. Dalam konteks ini, pondasi menjadi elemen kritis karena mendistribusikan gaya seismik ke tanah. Ketidakstabilan pondasi dapat menyebabkan keruntuhan total meskipun elemen atas bangunan telah didesain tahan gempa (*base shear dissipation failure*).

Untuk menganalisis dan mengantisipasi kerusakan tersebut, dibutuhkan pendekatan prediktif yang mampu memahami pola kompleks dan temporal dari data reaksi struktur. Di sinilah peran teknologi *deep learning*, khususnya *Long Short-Term Memory* (LSTM), menjadi relevan. LSTM merupakan pengembangan dari arsitektur *Recurrent Neural*

Network (RNN) yang dirancang untuk menangani data runtut waktu (*time-series*), seperti gaya dan momen pada sambungan struktur. Mekanisme internal LSTM mencakup *cell state* dan tiga gate utama (*input*, *forget*, dan *output gate*) yang bekerja untuk mempertahankan memori jangka panjang sekaligus menyaring informasi tidak relevan [2]. Kekuatan LSTM terletak pada kemampuannya dalam belajar dari urutan data yang panjang dan dinamis, menjadikannya sangat sesuai untuk permasalahan struktural yang dipengaruhi oleh variabel waktu, seperti respons bangunan terhadap beban gempa.

Kehadiran teknologi *artificial intelligence*, khususnya *deep learning*, telah membuka cakrawala baru dalam melakukan prediksi dan deteksi dini terhadap potensi kerusakan atau ketidakstabilan pada bangunan [2]. *Long Short-Term Memory* (LSTM), sebagai bagian dari *Recurrent Neural Network* (RNN), dirancang untuk mengatasi keterbatasan model jaringan saraf tradisional dalam menangani data runtut waktu (*time series*) yang panjang [3]. LSTM memiliki mekanisme "*memory gate*" yang memungkinkan model untuk mengingat pola historis yang relevan dan mengabaikan informasi yang tidak signifikan dalam proses prediksi [4]. Teknologi ini telah diterapkan secara luas pada berbagai bidang seperti keuangan [5], prediksi lalu lintas [6], deteksi kerusakan jembatan [7], dan bahkan sistem peringatan dini bencana



[8]. Namun, dalam bidang teknik sipil, khususnya untuk memprediksi respons pondasi terhadap gempa bumi berdasarkan *output* gaya dan momen sambungan struktur dari software SAP2000, penelitian masih terbatas dan belum menjadi praktik umum [3].

SAP2000 sebagai perangkat lunak analisis struktural telah lama menjadi standar dalam perencanaan bangunan sipil, memberikan data *output* penting seperti gaya aksial (F3), gaya horizontal (F1 dan F2), serta momen pada tiga sumbu (M1, M2, dan M3) [9]. Data-data ini, apabila disusun dalam bentuk *time series* dari berbagai kombinasi beban dapat dianalisis lebih lanjut menggunakan *deep learning* untuk memprediksi stabilitas sistem pondasi. Sayangnya, mayoritas praktisi dan peneliti masih terpaku pada pendekatan numerik klasik dan belum mengintegrasikan metode kecerdasan buatan dalam mengevaluasi performa struktur terhadap gempa [10]. *Gap* ini menunjukkan adanya peluang besar untuk mengembangkan sistem evaluasi struktural yang berbasis *machine learning*, khususnya dengan LSTM, yang memiliki keunggulan dalam mengenali pola dinamis jangka panjang.

Beberapa penelitian sebelumnya telah mencoba mengintegrasikan pembelajaran mesin dalam dunia konstruksi. Misalnya, Saputra et al. (2022) menggunakan *deep neural network* untuk identifikasi kerusakan struktural berdasarkan data modal [11], sementara Yang et al. (2023) menerapkan *deep learning* untuk memprediksi deformasi struktural berbasis data sensor [12]. Jia dan Li. (2023) juga menunjukkan keberhasilan metode *unsupervised learning* untuk mendeteksi anomali pada infrastruktur sipil [13]. Namun, belum ada penelitian komprehensif yang mengkaji efektivitas LSTM dalam mendeteksi kestabilan pondasi berdasarkan data nyata dari SAP2000 dan membandingkan performanya pada tiga jenis bangunan berbeda.

Selain itu, pendekatan ini juga mencakup deteksi *noise* atau anomali dalam data prediksi. Beberapa studi terdahulu, seperti Hameed et al. (2021), telah menggunakan metode *unsupervised learning* untuk mendeteksi anomali struktural, namun belum dikombinasikan langsung dengan model LSTM dan konteks prediksi stabilitas pondasi [6], [14]. Dalam penelitian ini, *noise* didefinisikan berdasarkan ambang batas kesalahan prediksi (*threshold error*) yang dihitung dari distribusi error maksimum setiap *time-step*. Pendekatan ini memungkinkan sistem tidak hanya memprediksi nilai gaya dan momen, tetapi juga mengklasifikasi potensi ketidakstabilan secara otomatis.

Penelitian ini bertujuan untuk mengembangkan dan menguji model *deep learning* berbasis *Long Short-Term Memory* (LSTM) untuk memprediksi stabilitas pondasi tahan gempa dengan menggunakan data *output* sambungan struktur dari perangkat lunak SAP2000. Model ini tidak hanya difokuskan pada prediksi nilai numerik gaya dan momen, tetapi juga dirancang untuk mendeteksi keberadaan *noise* atau anomali berdasarkan ambang batas kesalahan prediksi. Data yang digunakan berasal dari tiga jenis bangunan berbeda, yaitu pondasi utama, gedung *service*, dan gedung klinik teduh, sehingga memungkinkan adanya perbandingan performa prediksi antar skenario bangunan. Hasil evaluasi model menunjukkan bahwa akurasi, presisi, *recall*, dan *F1-score* mencapai nilai sempurna (1,0000), serta grafik *training loss* dan *validation loss* menunjukkan tidak adanya indikasi *overfitting*, sehingga model dianggap stabil dan dapat diandalkan. Penelitian ini diharapkan dapat menjadi rujukan dalam pengembangan sistem evaluasi dan mitigasi kegagalan pondasi berbasis teknologi kecerdasan buatan, khususnya dalam konteks kebencanaan di bidang teknik sipil.

TINJAUAN PUSTAKA

Gempa bumi menyebabkan gaya inersia yang bekerja pada struktur bangunan dalam arah horizontal dan vertikal. Gaya-gaya ini bersifat dinamis dan berubah-ubah dalam waktu yang sangat singkat. Konsep dasar analisis gempa dalam rekayasa sipil biasanya mengacu pada teori *base shear*, spektrum respons, serta rasio redaman struktural yang menentukan intensitas deformasi. Chopra (2017) menjelaskan bahwa pada struktur bertingkat, beban gempa tidak hanya meningkatkan gaya lateral tetapi juga memperbesar momen dasar (*base moment*) dan dapat memperlemah integritas pondasi apabila tumpuan tidak dirancang dengan sistem disipasi energi yang memadai [4]. Oleh karena itu, pondasi harus mampu merespons beban seismik yang berulang secara fleksibel namun tetap stabil.

Dalam bidang kecerdasan buatan, *Long Short-Term Memory* (LSTM) merupakan arsitektur jaringan saraf berulang (*Recurrent Neural Network*) yang secara khusus dirancang untuk mengatasi keterbatasan RNN konvensional dalam mengingat ketergantungan jangka panjang pada data *time-series*. Hochreiter dan Schmidhuber (1997) mengembangkan LSTM dengan menyusun struktur sel memori internal yang dilengkapi *forget gate*, *input gate*, dan *output gate*, sehingga memungkinkan informasi penting dipertahankan dan informasi tidak relevan dihilangkan dari proses prediksi [6].

Dalam konteks teknik sipil, LSTM telah terbukti cocok digunakan untuk memodelkan fenomena struktural berbasis urutan waktu, seperti respons struktur terhadap pembebanan dinamis atau kondisi seismik. LSTM memiliki kemampuan unggul dalam mengenali pola dalam data sekuensial tanpa kehilangan konteks jangka panjang, menjadikannya alat prediktif yang sangat relevan dalam menganalisis gaya dan momen pada elemen struktur bangunan selama siklus pembebanan gempa [1], [6].


SAP2000 merupakan perangkat lunak berbasis metode elemen hingga (FEM) yang banyak digunakan dalam analisis struktur teknik sipil. Aplikasi ini menyediakan output data yang sangat rinci berupa gaya internal (F1, F2, F3) dan momen (M1, M2, M3) pada titik sambungan struktur (*joint reactions*). Data ini umumnya digunakan dalam evaluasi struktural konvensional untuk mengecek kapasitas tumpuan dan efisiensi distribusi gaya [3]. Namun, potensi data ini untuk digunakan dalam sistem prediksi berbasis kecerdasan buatan masih jarang dieksplorasi [2].



Penelitian ini mengambil pendekatan inovatif dengan memanfaatkan langsung output SAP2000 dari tiga jenis bangunan yang berbeda dan menggunakannya sebagai dataset input model LSTM. Langkah ini memungkinkan evaluasi kestabilan pondasi dilakukan berdasarkan pola gaya dan momen yang nyata dan kompleks, bukan sekadar pendekatan teoritis. Dengan pemrosesan data time-series dan pelatihan model LSTM, sistem mampu belajar pola distribusi gaya struktural dan mendeteksi perubahan yang signifikan.

METODE

Penelitian ini menerapkan pendekatan eksperimen berbasis deep learning dengan menggunakan model *Long Short-Term Memory* (LSTM) untuk memprediksi stabilitas pondasi bangunan terhadap beban gempa. LSTM merupakan arsitektur jaringan saraf berulang (*Recurrent Neural Network/RNN*) yang diperkenalkan oleh Hochreiter dan Schmidhuber, dikenal efektif dalam mempelajari pola data runtun waktu karena memiliki mekanisme penyimpanan memori jangka panjang yang menghindari masalah *vanishing gradient* [15]. Pendekatan ini dipilih karena data gaya dan momen pada pondasi bangunan yang diperoleh dari perangkat lunak SAP2000 bersifat sekuensial dan memiliki ketergantungan temporal yang kuat.



Gambar 1. Flowchart Penelitian

Gambar Flowchart di atas menggambarkan tahapan alur kerja sistem prediksi stabilitas pondasi tahan gempa berbasis *Long Short-Term Memory* (LSTM) yang diterapkan dalam penelitian ini. Diagram dimulai dari node “Mulai”, kemudian dilanjutkan ke proses ekstraksi data dari perangkat lunak SAP2000. Data yang diambil berupa reaksi sambungan struktur (*joint reactions*), yang mencakup gaya (F_1 , F_2 , F_3) dan momen (M_1 , M_2 , M_3), dari tiga jenis bangunan berbeda. Tahap selanjutnya adalah *pre-processing data*, yang mencakup normalisasi skala fitur numerik, *encoding variabel* kategorikal, serta penyusunan data ke dalam bentuk *time-series* agar sesuai dengan kebutuhan *input model* LSTM. Setelah data diproses, sistem melanjutkan ke proses membangun model LSTM, yang terdiri dari dua layer LSTM dan satu layer *output dense*. Kemudian dilakukan proses *training dataset*, yaitu pelatihan model menggunakan data yang telah disiapkan. Setelah pelatihan selesai, model dievaluasi dengan menghitung metrik performa, meliputi akurasi, presisi, *recall*, dan *F1-score*. Jika hasil metrik belum optimal atau menunjukkan indikasi *overfitting*, maka proses kembali ke tahap *training* untuk dilakukan penyempurnaan. Sebaliknya, jika hasil evaluasi sudah optimal, sistem dilanjutkan ke tahap analisis *training loss* dan *validation loss*. Tahapan ini bertujuan untuk memastikan kestabilan dan kemampuan generalisasi model berdasarkan grafik *loss*. Jika analisis *loss* menunjukkan konvergensi yang baik (*validation loss* lebih rendah dari *training loss* secara konsisten), maka proses dilanjutkan ke tahap interpretasi hasil, yang mencakup analisis prediksi numerik, deteksi *noise*, dan perbandingan antar *dataset*. Akhir dari Flowchart ditandai dengan node “Selesai”, yang mengindikasikan bahwa seluruh proses penelitian telah rampung dan hasil siap untuk dianalisis secara mendalam. Flowchart ini menggambarkan proses berulang (*iteratif*) yang bersifat adaptif, di mana evaluasi metrik dan validasi *loss* menjadi titik krusial dalam menentukan keberlanjutan atau penghentian proses pelatihan. Hal ini memastikan bahwa model yang dihasilkan benar-benar optimal dan dapat direproduksi secara metodologis [4].

Data input dalam penelitian ini diperoleh dari hasil simulasi struktur tiga jenis bangunan berbeda menggunakan SAP2000, yaitu pondasi utama, gedung pelayanan, dan gedung klinik. Output yang digunakan adalah gaya aksial dan lateral (F_1 , F_2 , F_3) serta momen (M_1 , M_2 , M_3) pada titik sambungan struktur (*joint reactions*), yang kemudian diekspor ke dalam format Excel [9]. Data ini selanjutnya diproses melalui tahapan pra-pemrosesan, yang mencakup pemilihan fitur numerik relevan, pengisian nilai kosong, *encoding variabel* kategorikal, serta normalisasi menggunakan *MinMaxScaler* ke dalam rentang $[0, 1]$. Agar dapat digunakan dalam model LSTM, data dikonversi menjadi bentuk tiga dimensi dengan struktur [*samples*, *time steps*, *features*], dengan mengambil lima langkah waktu sebelumnya ($n_{past} = 5$) sebagai input prediksi langkah berikutnya [4].

Model LSTM dibangun menggunakan TensorFlow-Keras dengan dua layer LSTM masing-masing terdiri dari 50 unit dan *dropout* sebesar 0,2 untuk mengurangi risiko *overfitting*. Setelah layer LSTM, digunakan satu layer *Dense* sebagai output dengan jumlah neuron yang sesuai dengan banyaknya fitur. Model dikompilasi menggunakan *optimizer* Adam dan fungsi *loss* Mean Squared Error (MSE). Proses pelatihan dilakukan selama lima *epoch* dengan batch size 64,



dan validasi dilakukan melalui *skema cross-validation* dengan *Time Series Split* sebanyak lima lipatan. *Early Stopping* juga diterapkan untuk menghentikan pelatihan secara otomatis ketika model tidak mengalami peningkatan akurasi validasi selama tiga *epoch* berturut-turut [2].

Kinerja model dievaluasi melalui beberapa metrik klasifikasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Seluruh nilai metrik menunjukkan hasil sempurna (1,0000), mengindikasikan bahwa model berhasil mengidentifikasi pola dan *noise* dengan akurasi tinggi. Selain itu, dihitung pula *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) untuk mengetahui rata-rata deviasi antara hasil prediksi dan data aktual. Grafik perbandingan antara *training loss* dan *validation loss* menunjukkan bahwa *validation loss* cenderung lebih rendah dari *training loss*, menandakan bahwa model tidak mengalami *overfitting* dan mampu melakukan generalisasi dengan baik [6].

Untuk mendeteksi anomali atau *noise*, model menghitung *error absolut* antara data prediksi dan aktual. Nilai ambang batas (*threshold*) ditentukan berdasarkan persentil ke-95 dari *error* maksimum setiap data uji. Data dengan *error* melebihi ambang tersebut diklasifikasikan sebagai *noise*. Teknik ini memungkinkan model tidak hanya memprediksi *output* numerik, tetapi juga mengidentifikasi data anomali yang berpotensi menunjukkan ketidakstabilan pondasi [11]. Proses ini divalidasi dengan menguji model terhadap 10% data yang sebelumnya tidak digunakan dalam pelatihan. Berikut rumus yang digunakan untuk menghitung kinerja model dalam mendeteksi *noise* atau anomali *structural*:

1. Akurasi (*Accuracy*)

Mengukur proporsi prediksi yang benar terhadap seluruh data.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN}$$

2. Presisi (*Precision*)

Mengukur seberapa banyak prediksi positif yang benar-benar benar.

$$\text{Presisi} = \frac{TP}{TP + FP}$$

3. Recall (*Sensitivity*)

Mengukur seberapa banyak data positif yang berhasil dikenali.

$$\text{Recall} = \frac{TP}{TP + FN}$$

4. F1-Score

Rata-rata harmonis antara presisi dan recall.

$$F1 - \text{Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}}$$

Keterangan:

TP = *True Positive* (anomali terdeteksi dan memang benar anomali)


TN = *True Negative* (data normal terdeteksi dengan benar)

FP = *False Positive* (data normal tetapi dikira anomali)

FN = *False Negative* (anomali tapi tidak terdeteksi)

HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk mengimplementasikan model *deep learning* berbasis *Long Short-Term Memory* (LSTM) dalam memprediksi stabilitas pondasi bangunan terhadap beban gempa dengan mengandalkan data *time-series* reaksi sambungan (*joint reactions*) dari perangkat lunak SAP2000. Data yang dianalisis berasal dari tiga jenis bangunan yang merepresentasikan variasi massa dan kerumitan struktur, yaitu pondasi utama, gedung *service*, dan gedung klinik teduh. Setiap data mengandung komponen gaya (F1, F2, F3) dan momen (M1, M2, M3) pada sambungan. F3 mewakili gaya vertikal, sedangkan F1 dan F2 mencerminkan gaya lateral. Sementara M1, M2, dan M3 menggambarkan besaran momen pada masing-masing sumbu rotasi.



Gambar 2. Flowchart Kerja Sistem

Sistem yang dikembangkan diimplementasikan dalam beberapa tahapan terstruktur untuk memastikan proses pelatihan dan evaluasi model berjalan optimal. Tahap pertama dimulai dengan mempersiapkan *dataset*, di mana file data



yang akan digunakan harus tersedia dalam format yang didukung, seperti file berformat *.csv*. Selanjutnya, pengguna membuka platform *Google Colab* dan memuat *notebook (.ipynb)* yang telah berisi *script* pemrograman model LSTM. Pada tahap berikutnya, pengguna melakukan proses unggah *dataset*, kemudian memilih file dari perangkat lokal. Setelah *dataset* berhasil diunggah, program dijalankan dengan mengeksekusi sel yang telah disiapkan untuk memulai pelatihan model LSTM. Sistem secara otomatis menampilkan perkembangan proses pelatihan, termasuk informasi mengenai jumlah *epoch*, nilai *loss*, dan tingkat akurasi. Setelah seluruh proses pelatihan selesai, sistem akan melakukan evaluasi model dengan menghitung beberapa metrik kinerja, seperti akurasi, presisi, *recall*, *F1-score*, serta *error metrics* yaitu *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE). Untuk melengkapi analisis performa, sistem juga menghasilkan visualisasi berupa grafik perbandingan *Training Loss* dan *Validation Loss*, yang berfungsi untuk mengidentifikasi potensi *overfitting* pada model yang dibangun.

Hasil observasi awal menunjukkan perbedaan signifikan dalam magnitudo gaya dan momen antar ketiga *dataset*. Data pondasi utama menunjukkan nilai F3 yang sangat besar, yaitu rata-rata 7788,79 KN, diikuti oleh Gedung *Service* sebesar 775,45 KN, dan Gedung Klinik Teduh sebesar 207,26 KN. Nilai momen M1–M3 juga mengikuti pola serupa, mencerminkan bahwa pondasi utama dirancang untuk beban struktural lebih berat. Tabel berikut menyajikan ringkasan statistik gaya dan momen dari masing-masing *dataset*:


Tabel 1. Statistik Gaya Dan Momen Dari Pondasi Utama, Gedung *Service* Dan Gedung Klinik Teduh

Dataset	Rata-rata F3 (KN)	Rata-rata M1 (KN-m)	Rata-rata M2 (KN-m)	Rata-rata M3 (KN-m)
Pondasi Utama	7788,79	548,27	802,23	9,58
Gedung <i>Service</i>	775,45	261,3	290,5	5,4
Gedung Klinik Teduh	207,26	111,56	106,9	1,42

Tabel perbandingan diatas menunjukkan adanya perbedaan yang mencolok antara ketiga bangunan yang menjadi objek penelitian, yaitu Pondasi Utama, Gedung *Service*, dan Gedung Klinik Teduh. Pondasi Utama mencatatkan nilai tertinggi pada seluruh parameter, dengan gaya vertikal F3 mencapai 7788,79 kiloNewton (KN), serta momen M1 dan M2 masing-masing sebesar 548,27 dan 802,23 kiloNewton-meter (KN-m). Hal ini mengindikasikan bahwa pondasi tersebut dirancang untuk menopang struktur dengan massa besar dan kompleksitas tinggi, seperti bangunan bertingkat atau fasilitas utama. Momen M3 yang relatif kecil sebesar 9,58 KN-m menunjukkan bahwa torsi terhadap sumbu *vertikal* masih terjadi, meskipun tidak sekuat pada sumbu *horizontal*. Sementara itu, Gedung *Service* menunjukkan nilai sedang untuk semua parameter. Gaya vertikal F3 sebesar 775,45 KN menandakan bahwa struktur ini berfungsi untuk menanggung beban menengah, kemungkinan berupa bangunan pelayanan dua atau tiga lantai. Nilai momen M1 dan M2 masing-masing sebesar 261,23 dan 290,50 KN-m, serta M3 sebesar 5,44 KN-m, menunjukkan bahwa gedung ini masih mengalami pengaruh rotasi akibat beban lateral, namun dalam skala yang jauh lebih kecil dibanding Pondasi Utama. Gedung Klinik Teduh memiliki nilai terendah untuk semua parameter, dengan F3 sebesar 207,26 KN, M1 sebesar 111,56 KN-m, M2 sebesar 106,90 KN-m, dan M3 hanya 1,42 KN-m. Nilai-nilai ini mencerminkan bahwa struktur klinik merupakan bangunan ringan, kemungkinan satu lantai, dengan sistem pondasi yang relatif stabil dan minim tekanan rotasional. Rendahnya momen pada ketiga sumbu mengindikasikan bahwa distribusi beban pada struktur ini cukup merata dan tidak menimbulkan *eksentrisitas* atau *torsi* yang signifikan. Perbedaan nilai gaya dan momen pada ketiga bangunan ini menjadi dasar kuat untuk menguji kemampuan model LSTM dalam mengenali pola dan perbedaan karakteristik struktural. Variasi yang kontras antara bangunan berat, sedang, dan ringan memungkinkan model diuji pada berbagai skenario kompleksitas beban, sekaligus menilai sensitivitasnya dalam mendeteksi potensi *instabilitas* pondasi berdasarkan *respons* gaya dan momen.

Perbedaan tersebut secara teoritis dapat dijelaskan melalui prinsip analisis struktur terhadap beban dinamis, dimana struktur dengan massa dan kekakuan tinggi cenderung mengalami *respons* yang lebih besar terhadap gaya *seismik* [16]. Selain itu, letak pusat massa dan tumpuan pondasi akan menentukan distribusi gaya dan momen yang dihasilkan oleh kombinasi pembebanan.

Setelah data diproses melalui tahapan normalisasi dan penyusunan *time-series*, dilakukan pelatihan model LSTM dengan struktur dua layer masing-masing 50 unit *neuron* serta *dropout* sebesar 0,2. Model kemudian diuji menggunakan skema validasi silang *Time Series Split (5 fold)*. Seluruh proses pelatihan memperlihatkan *konvergensi* yang stabil, dengan grafik *training loss* dan *validation loss* menunjukkan tren penurunan seiring bertambahnya *epoch*. Visualisasi tersebut ditunjukkan pada Gambar 3 berikut:



Gambar 3. Grafik Training Loss vs Validation Loss

Gambar diatas menunjukkan grafik perbandingan nilai *training loss* dan *validation loss* selama proses pelatihan model *Long Short-Term Memory* (LSTM) selama 25 *epoch*. Sumbu horizontal (x-axis) merepresentasikan jumlah *epoch*, sedangkan sumbu vertikal (y-axis) menunjukkan nilai *loss* atau kesalahan prediksi model. Kurva berwarna biru dengan penanda lingkaran merepresentasikan *training loss*, sementara kurva berwarna merah dengan penanda bintang menggambarkan *validation loss*. Grafik menunjukkan pola penurunan *loss* yang cukup stabil pada kedua kurva. Meskipun terdapat fluktuasi tajam pada beberapa titik *epoch* khususnya pada kurva *training* tren utamanya tetap menurun secara konsisten. Pada *epoch* pertama, *training loss* berada pada kisaran 0,29 dan *validation loss* pada 0,17, menandakan bahwa model pada tahap awal belum mampu mengenali pola data dengan baik. Namun, seiring bertambahnya *epoch*, kedua nilai *loss* mengalami penurunan dan mulai konvergen di bawah angka 0,07 pada akhir pelatihan. Kurva *validation loss* cenderung lebih rendah dibandingkan *training loss* hampir di seluruh tahapan. Hal ini mengindikasikan bahwa model tidak mengalami *overfitting* yaitu kondisi di mana model terlalu menghafal data latih sehingga performanya buruk saat diuji pada data baru. Sebaliknya, perbedaan kecil antara kedua kurva dan kecenderungan *validation loss* yang lebih rendah menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data uji yang belum pernah dilihat sebelumnya. Fluktuasi periodik pada *training loss* dapat disebabkan oleh dinamika dalam pembaruan bobot jaringan selama iterasi pelatihan, atau akibat pengaruh struktur data *time-series* yang bersifat *non-linier* dan kompleks. Namun, penurunan secara bertahap pada akhir *epoch* menunjukkan bahwa model berhasil mencapai *stabilitas konvergensi*. Hasil ini memperkuat evaluasi metrik yang menunjukkan akurasi, presisi, *recall*, dan *F1-score* sempurna (1,0000), sekaligus menegaskan bahwa proses pembelajaran berlangsung efektif.

Validation loss berada sedikit di bawah *training loss*, yang menandakan bahwa model tidak mengalami *overfitting*. Secara teoritis, *overfitting* merupakan kondisi ketika model terlalu menghafal data latih dan gagal mengenali pola baru pada data uji, biasanya ditandai dengan selisih besar antara nilai *loss training* dan validasi [6]. Fenomena ini tidak ditemukan dalam penelitian ini.

Sebagai pelengkap visualisasi *loss*, performa model LSTM juga dievaluasi menggunakan metrik klasifikasi dan regresi, yaitu akurasi, presisi, *recall*, *F1-score*, MAE, dan RMSE. Evaluasi dilakukan pada masing-masing dataset bangunan yang digunakan dalam penelitian. Hasil evaluasi disajikan pada Tabel 2 berikut.

Tabel 2. Evaluasi Kinerja Model LSTM

Dataset	Akurasi	Presisi	Recall	F1-Score	MAE	RMSE
Pondasi Utama	1	1	1	1	0,0082	0,0124
Gedung Service	1	1	1	1	0,0079	0,0117
Gedung Klinik Teduh	1	1	1	1	0,0085	0,0128

Tabel di atas menyajikan hasil evaluasi model *Long Short-Term Memory* (LSTM) dalam memprediksi *stabilitas* pondasi bangunan berdasarkan tiga dataset yang digunakan, yaitu Pondasi Utama, Gedung Service, dan Gedung Klinik Teduh. Metrik yang ditampilkan mencakup metrik klasifikasi (*Akurasi*, *Presisi*, *Recall*, dan *F1-Score*) serta metrik regresi (MAE dan RMSE) sebagai indikator *deviasi prediksi numerik*. Seluruh nilai akurasi, *presisi*, *recall*, dan *F1-score* menunjukkan angka sempurna, yaitu 1,0000, baik pada data pelatihan maupun pengujian. Hasil ini menunjukkan bahwa model mampu mengklasifikasikan seluruh data dengan benar, tanpa adanya kesalahan dalam mendeteksi anomali (*noise*) maupun dalam memetakan pola-pola data normal. Nilai *F1-score* yang sempurna juga menandakan bahwa tidak ada *trade-off* antara *presisi* dan *recall*, sehingga model seimbang dalam mendeteksi data positif dan negatif. Untuk metrik regresi, *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) menunjukkan nilai yang sangat kecil pada



semua *dataset* berada pada kisaran 0,0079 hingga 0,0128. MAE mengukur rata-rata perbedaan absolut antara nilai aktual dan prediksi, sedangkan RMSE memberikan penalti lebih besar terhadap *error* yang besar. Nilai-nilai yang rendah tersebut mengindikasikan bahwa *prediksi numerik* gaya dan momen oleh model sangat dekat dengan data sebenarnya, dengan deviasi rata-rata kurang dari 1.3%.

Perbedaan kecil antara *dataset* juga menunjukkan *konsistensi* performa model. Misalnya, meskipun Gedung Klinik Teduh memiliki karakteristik beban dan struktur yang lebih ringan dibanding Pondasi Utama, model tetap mempertahankan tingkat akurasi yang identik. Hal ini menegaskan kemampuan *generalisasi* LSTM terhadap variasi *struktural* dan *kompleksitas* beban antar bangunan. Dengan kata lain, tabel ini mengukuhkan bahwa model LSTM yang dibangun tidak hanya unggul dalam klasifikasi, tetapi juga sangat presisi dalam estimasi nilai numerik. Hal ini menjadikan pendekatan ini sangat relevan untuk diaplikasikan dalam sistem *monitoring* dan evaluasi struktur tahan gempa secara *real-time*.

Selanjutnya, dilakukan evaluasi performa model menggunakan *metrik klasifikasi*. Hasil evaluasi menunjukkan bahwa model LSTM mampu melakukan prediksi dengan nilai akurasi, *presisi*, *recall*, dan *F1-score* sebesar 1,0000 di seluruh skenario pengujian. Hasil ini tidak hanya mengindikasikan bahwa model mengenali pola *time-series* secara sempurna, tetapi juga mampu membedakan secara akurat antara data normal dan data yang tergolong *noise*. *Noise* didefinisikan sebagai data dengan error prediksi melebihi *threshold* yang ditentukan, yaitu persentil ke-95 dari *error* maksimum.

Selain *metrik klasifikasi*, juga dihitung nilai *Mean Absolute Error* (MAE) dan *Root Mean Squared Error* (RMSE) sebagai ukuran deviasi numerik antara data aktual dan hasil prediksi. Nilai MAE dan RMSE yang sangat kecil (< 0.01 pada skala ternormalisasi) menegaskan keakuratan prediksi numerik dari model. Model juga diuji terhadap 10% data yang sebelumnya tidak digunakan dalam pelatihan (*unseen* data) dan hasilnya tetap konsisten, mengindikasikan bahwa *generalisasi* model terhadap data baru sangat baik. Nilai MAE digunakan untuk mengukur rata-rata absolut dari perbedaan antara hasil prediksi dan nilai sebenarnya dengan rumus:

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

Sedangkan RMSE digunakan untuk mengukur akar dari rata-rata kuadrat error, memberi penalti lebih besar pada error besar dengan rumus:

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

Misalkan y_i dan $\hat{y}_i$ adalah nilai aktual dan adalah nilai hasil prediksi, dengan total data n .

Dalam aspek deteksi anomali, model mampu mengenali pola-pola deviasi *ekstrem* yang secara struktural dapat diinterpretasikan sebagai *respons abnormal* akibat kombinasi pembebanan ekstrem atau ketidakstabilan elemen pondasi. Mekanisme ini sangat bermanfaat dalam sistem pemantauan struktur (*structural health monitoring*) karena mampu mendeteksi potensi keruntuhan sejak dini.

Jika dibandingkan dengan penelitian terdahulu, pendekatan ini menawarkan kontribusi baru Choi et al. (2024) mengusulkan deteksi anomali berbasis *autoencoder* tanpa melakukan prediksi eksplisit terhadap gaya dan momen [7]. Sementara Zhhexevay (2025) hanya memodelkan respons global struktur terhadap gempa tanpa fokus pada pondasi [17]. Penelitian ini menyempurnakan kedua pendekatan tersebut dengan menggabungkan prediksi *time-series*, deteksi *noise* berbasis ambang *error*, serta membandingkan antar struktur bangunan yang berbeda, menjadikannya lebih komprehensif dalam konteks rekayasa gempa.

Sistem prediksi berbasis LSTM yang dikembangkan dalam penelitian ini memiliki sejumlah keunggulan signifikan. Pertama, model menunjukkan kemampuan *generalisasi* yang sangat tinggi terhadap variasi data bangunan, baik dari segi massa, kompleksitas struktur, maupun karakteristik beban gempa. Hal ini terlihat dari *konsistensi* performa model pada ketiga jenis bangunan yang digunakan [15]. Kedua, pendekatan ini mengintegrasikan prediksi numerik dan klasifikasi *noise* secara bersamaan, sehingga selain memproyeksikan nilai gaya dan momen secara akurat, model juga mampu mengidentifikasi potensi anomali atau ketidakstabilan struktural. Ketiga, efisiensi pemrosesan LSTM dalam menangani *dataset multi-variabel* struktural membuat metode ini cocok untuk diterapkan pada data teknik sipil yang bersifat kompleks dan saling bergantung antar variabel. Keempat, validasi model dilakukan dengan pendekatan *cross-validation* serta pengujian terhadap data *unseen*, yang secara metodologis memperkuat reliabilitas dan kestabilan model.

Sistem ini juga memiliki beberapa keterbatasan yang perlu dicermati. Pertama, skala data yang digunakan masih terbatas pada tiga jenis bangunan, sehingga *generalisasi* model ke skenario dunia nyata yang lebih beragam masih perlu dibuktikan melalui uji lebih lanjut. Kedua, metode deteksi *noise* dalam model ini masih menggunakan *threshold* berbasis statistik statis, sehingga belum adaptif terhadap perubahan distribusi data yang *dinamis* atau *ekstrem*. Ketiga, performa model sangat bergantung pada kualitas dan kelengkapan data hasil *ekstraksi* dari SAP2000. Jika terjadi *inkonsistensi* dalam *input* data, maka akurasi prediksi dan deteksi anomali juga dapat berdampak secara signifikan [8]. Oleh karena itu, pengembangan lebih lanjut disarankan untuk mencakup integrasi metode *threshold* dinamis serta pengujian pada data yang lebih luas dan *heterogen*.



Pendekatan LSTM sangat potensial diterapkan dalam sistem *monitoring* dan evaluasi struktur tahan gempa, khususnya pada aspek pondasi. Penelitian ini sekaligus menegaskan pentingnya integrasi antara simulasi struktur konvensional dengan metode kecerdasan buatan dalam pengambilan keputusan berbasis data.

KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan dan menerapkan model *deep learning* berbasis *Long Short-Term Memory* (LSTM) untuk memprediksi stabilitas pondasi bangunan terhadap beban gempa dengan menggunakan data reaksi sambungan struktur dari SAP2000. Sistem diimplementasikan secara terstruktur, dimulai dari tahap persiapan *dataset*, pelatihan model, hingga evaluasi performa menggunakan *Google Colab*. Model diuji pada tiga jenis bangunan berbeda, yaitu pondasi utama, gedung *service*, dan gedung klinik teduh, yang merepresentasikan variasi beban dan kompleksitas *structural*. Model menunjukkan performa sangat tinggi dengan akurasi, presisi, *recall*, dan *F1-score* sebesar 1,0000, baik pada proses validasi silang maupun pada data *unseen*, yang menunjukkan kemampuan generalisasi yang kuat. Grafik *training loss* dan *validation loss* yang stabil serta rendah mengindikasikan bahwa model tidak mengalami *overfitting*. Integrasi antara prediksi numerik dan deteksi *noise* berbasis ambang *error* menjadikan sistem ini unggul sebagai alat prediktif sekaligus diagnostik. Namun demikian, penelitian ini memiliki keterbatasan pada skala data yang masih terbatas pada tiga bangunan serta penggunaan *threshold noise* yang masih bersifat statis.

Berdasarkan pembahasan di atas, disarankan agar penelitian selanjutnya menguji model ini pada jenis bangunan yang lebih beragam dan kompleks, serta mengintegrasikan metode *threshold* adaptif yang dinamis sesuai perubahan distribusi data. Selain itu, perlu dilakukan eksplorasi pemanfaatan data dari berbagai perangkat lunak analisis struktur lainnya untuk meningkatkan *fleksibilitas sistem*. Pengembangan *visualisasi prediktif* dan integrasi ke dalam sistem *monitoring real-time* juga menjadi arah potensial untuk penelitian lanjutan yang lebih aplikatif.

DAFTAR PUSTAKA

- [1] A. S. B. Karno, "Analisis Data Time Series Menggunakan LSTM (Long Short Term Memory) dan ARIMA (Autocorrelation Integrated Moving Average) dalam Bahasa Python," vol. XI, no. 1, pp. 1–7, 2020.
- [2] Misdi and A. Hamzah, "TIME HISTORY ANALYSIS PADA STRUKTUR BANGUNAN YANG MENGGUNAKAN BASE ISOLATOR," *J. Al Ulum LPPM Univ. Al Washliyah Medan*, vol. 13, no. 1, 2025.
- [3] A. Shabani, "A review of graphical user interfaces of OpenSees software framework," *FRONTLINER*, vol. 1998, no. July, pp. 1–7, 2023, doi: 10.3389/fbuil.2023.1233116.
- [4] I. Cholissodin dan A. A. Soebroto, "AI , MACHINE LEARNING & DEEP LEARNING (Teori & Implementasi)," no. December, 2021.
- [5] B. Lindemann, T. Müller, H. Vietz, N. Jazdi, dan M. Weyrich, "ScienceDirect A survey on long short-term memory networks for time series prediction," *Procedia CIRP*, vol. 99, no. July 2020, pp. 650–655, 2023, doi: 10.1016/j.procir.2021.03.088.
- [6] I. U. Khan, S. Jeong, dan S. H. Sim, "Investigation of Issues in Data Anomaly Detection Using Deep-Learning- and Rule-Based Classifications for Long-Term Vibration Measurements," *Appl. Sci.*, 2024.
- [7] I. Choi, H. Yong, dan B. Kwan, "Convolutional neural network-based seismic response prediction method using spectral acceleration of earthquakes and conditional vector of structural property," *Soil Dyn. Earthq. Eng.*, vol. 187, no. September, p. 109021, 2024, doi: 10.1016/j.soildyn.2024.109021.
- [8] R. L. Abduljabbar, H. Dia, P. W. Tsai, dan S. Liyanage, "Short-Term Traffic Forecasting: An LSTM Network for Spatial-Temporal Speed Prediction," *Futur. Transp.*, pp. 21–37, 2021.
- [9] S. Documentation, "SAP2000 v23.0.0 Release Notes," pp. 2–7, 2021.
- [10] A. Moghar dan M. Hamiche, "Stock Market Prediction Using LSTM Recurrent Neural Network," *Procedia Comput. Sci.*, vol. 170, pp. 1168–1173, 2020, doi: 10.1016/j.procs.2020.03.049.
- [11] A. W. Saputra, A. P. Wibawa, U. Pujianto, A. B. P. Utama, dan A. Nafalski, "LSTM-based Multivariate Time-Series Analysis: A Case of Journal Visitors Forecasting," vol. 14, no. 1, pp. 57–62, 2022.
- [12] C. Yang, L. Yang, W. Guo, dan P. Xu, "Deep learning based structural damage identification for the strain field of a subway bolster," *Alexandria Eng. J.*, vol. 81, no. September, pp. 264–28, 2023, doi: 10.1016/j.aej.2023.09.031.
- [13] J. Jia dan Y. Li, "Deep Learning for Structural Health Monitoring: Data, Algorithms, Applications, Challenges, and Trends," *Sensors*, 2023.
- [14] J. Han, H. Yang, Y. Liu, Z. Lu, K. Zeng, dan R. Jiao, "A Deep Learning Application for Deformation Prediction from Ground-Based InSAR," *Remote Sens.*, 2022.
- [15] B. Etim, A. Al-Ghosoun, J. Renno, M. Seaid, dan M. S. Mohamed, "Machine Learning-Based Modeling for Structural Engineering: A Comprehensive Survey and Applications Overview," pp. 1–36, 2024.
- [16] E. Naf'an, F. Islami, dan G. Gushelmi, *DASAR-DASAR DEEP LEARNING dan Contoh Aplikasinya*. 2022.
- [17] D. Zhexebay *et al.*, "applied sciences Deep Learning for Early Earthquake Detection: Application of Convolutional Neural Networks for P-Wave Detection," pp. 1–16, 2025.