

# EVALUATION OF THE EFFECT OF REGULARIZATION ON NEURAL NETWORKS FOR REGRESSION PREDICTION: A CASE STUDY OF MLP, CNN, AND FNN MODELS

## EVALUASI PENGARUH REGULARISASI PADA NEURAL NETWORK UNTUK PREDIKSI REGRESI: STUDI KASUS MODEL MLP, CNN, DAN FNN

Susandri Susandri<sup>\*1</sup>, Ahmad Zamsuri<sup>2</sup>, Nurliana Nasution<sup>3</sup>, Maya Ramadhani<sup>4</sup>

<sup>1234</sup>Pascasarjana Ilmu Komputer, Universitas Lancang Kuning, Pekanbaru, Indonesia  
susandri@unilak.ac.id<sup>1</sup>, ahmadzamsuri@unilak.ac.id<sup>2</sup>, nurliananasution@unilak.ac.id<sup>3</sup>,  
mayaramadhanii13@gmail.com<sup>4</sup>

**Abstract** - Regularization is an important technique for developing deep learning models to improve generalization and reduce overfitting. This study evaluated the effect of regularization on the performance of neural network models in regression prediction tasks using earthquake data. We compare Multilayer Perceptron (MLP), Convolutional Neural Network (CNN), and Feedforward Neural Network (FNN) architectures with L2 and Dropout regularization. The experimental results show that MLP without regularization achieved the best performance (RMSE: 0.500, MAE: 0.380,  $R^2$ : 0.625), although prone to overfitting. CNN performed poorly on tabular data, while FNN showed marginal improvement with deeper layers. The novelty of this study lies in a comparative evaluation of regularization strategies across multiple architectures for earthquake regression prediction, highlighting practical implications for early warning systems.

**Keywords** - Regularization, Neural Network, MLP, CNN, FNN, Earthquake Prediction

**Abstrak** - Regularisasi merupakan teknik penting dalam pengembangan model deep learning untuk meningkatkan generalisasi dan mengurangi overfitting. Studi ini mengevaluasi pengaruh regularisasi terhadap performa model neural network dalam prediksi regresi data gempa bumi. Kami membandingkan arsitektur Multilayer Perceptron (MLP), Convolutional Neural Network (CNN), dan Feedforward Neural Network (FNN) dengan regularisasi L2 dan Dropout. Hasil menunjukkan MLP tanpa regularisasi memberikan performa terbaik (RMSE: 0.500, MAE: 0.380,  $R^2$ : 0.625), namun rentan terhadap overfitting. CNN menunjukkan performa buruk pada data tabular, sedangkan FNN hanya memberikan sedikit peningkatan. Kebaruan studi ini adalah pada evaluasi komparatif regularisasi di berbagai arsitektur untuk prediksi regresi gempa, dengan implikasi praktis untuk sistem peringatan dini.

**Kata Kunci** - Regularisasi, Neural Network, MLP, CNN, FNN, Prediksi Gempa

## I. PENDAHULUAN

Gempa bumi merupakan fenomena geofisika yang kompleks dan sulit diprediksi karena sifatnya yang non-deterministik serta dipengaruhi oleh berbagai faktor seismik. Salah satu tantangan utama dalam bidang geofisika dan kecerdasan buatan adalah pengembangan model yang mampu melakukan prediksi parameter gempa bumi secara akurat, termasuk magnitudo, kedalaman, dan lokasi kejadian [1]. Keakuratan model prediksi sangat bergantung pada kemampuannya dalam menangkap pola tersembunyi dalam data seismik, yang sering kali bersifat non-linear dan memiliki variabilitas tinggi [2]. Neural network telah menjadi pendekatan populer dalam penelitian terbaru karena kemampuannya dalam menangkap hubungan kompleks antar fitur [3][4]. Namun, model ini rentan terhadap *overfitting*, terutama jika jumlah parameter yang digunakan jauh lebih besar dibandingkan jumlah data yang tersedia. *Overfitting* menyebabkan model memiliki performa tinggi pada data pelatihan tetapi gagal melakukan generalisasi terhadap data baru [5][6].

Penelitian ini bertujuan untuk mengevaluasi efektivitas teknik regularisasi dalam meningkatkan generalisasi model *neural network* untuk prediksi regresi parameter gempa bumi. Model yang dibandingkan mencakup *Multilayer Perceptron (MLP)*, *Convolutional Neural Network (CNN)*, dan *Feedforward Neural Network (FNN)*. Performa model dievaluasi menggunakan metrik *Root Mean Square Error (RMSE)*, *Mean Absolute Error (MAE)*, dan koefisien determinasi ( $R^2$ ) untuk menilai tingkat akurasi dan stabilitas prediksi.

Berbagai penelitian telah mengkaji efektivitas *neural network* dalam analisis seismik, menunjukkan bahwa model berbasis jaringan saraf tiruan dapat mengidentifikasi pola kompleks dalam data gempa bumi [7][8]. *MLP* sering digunakan dalam tugas prediksi regresi karena strukturnya yang fleksibel dalam menangani data tabular [9]. *CNN*, yang dirancang untuk pemrosesan data spasial, telah diuji dalam berbagai domain, termasuk analisis seismik berbasis citra [10]. Namun, penerapannya pada data tabular masih menjadi topik yang perlu dieksplorasi lebih lanjut [11]. Sementara itu, *FNN* dengan kedalaman yang lebih tinggi sering digunakan untuk menangkap hubungan *non-linear* yang lebih kompleks, meskipun tidak selalu menjamin peningkatan akurasi [12][13]. Selain itu, teknik regularisasi L2 (*Ridge Regression*) dan *Dropout* telah banyak digunakan dalam berbagai penelitian untuk mengurangi risiko *overfitting* pada model *neural network* [14][15]. Regularisasi L2 bekerja dengan menambahkan penalti terhadap parameter model yang besar, sedangkan *Dropout* secara acak menonaktifkan neuron selama pelatihan guna mencegah ketergantungan berlebihan terhadap fitur tertentu [16]. Meskipun telah terbukti efektif dalam berbagai studi, dampak penerapan regularisasi terhadap performa model *neural network* dalam konteks prediksi regresi gempa bumi masih perlu diteliti lebih lanjut [17][1][18].

## II. SIGNIFIKASI STUDI

Berbeda dari literatur sebelumnya yang fokus pada performa model saja, studi ini secara sistematis membandingkan teknik regularisasi pada arsitektur neural network yang berbeda. Kami juga menyoroti celah penelitian berupa kurangnya studi yang mengevaluasi efek regulasi pada CNN dan FNN dalam konteks data gempa bumi tabular. Studi ini juga menyarankan skenario implementasi praktis dengan mengusulkan integrasi model MLP berbasis Dropout dengan API real-time BMKG sebagai bagian dari sistem peringatan dini berbasis AI. Studi ini membahas kesenjangan penelitian yang spesifik: meskipun pembelajaran mendalam telah diterapkan secara luas untuk prediksi gempa bumi, sangat sedikit penelitian yang mengevaluasi secara sistematis peran regularisasi terutama regularisasi L2 dalam arsitektur CNN-RNN hibrida menggunakan data seismik tabular terstruktur. Studi-studi sebelumnya sebagian besar berfokus pada masukan bentuk gelombang mentah atau metode pembelajaran mesin dangkal, dengan sedikit perhatian diberikan pada kinerja generalisasi dalam konteks geospasial yang beragam.

Lebih lanjut, studi ini menawarkan implikasi praktis. Model CNN yang telah dilatih dapat diintegrasikan dengan API seismik publik, seperti BMKG (<https://data.bmkg.go.id/gempabumi>), untuk mengaktifkan sistem peringatan waktu nyata (real-time). Kemampuan ini memungkinkan pemerintah daerah dan platform peringatan dini untuk mengotomatiskan strategi respons berdasarkan magnitudo dan pola spasial yang diprediksi.


#### A. *Studi Literatur*

Dalam beberapa dekade terakhir, perkembangan metode prediksi gempa bumi telah mengalami transformasi dari pendekatan berbasis statistik menuju model berbasis kecerdasan buatan [13][9]. *Neural network* mulai digunakan secara luas dalam analisis geofisika sejak awal 2000-an dan terus berkembang dengan meningkatnya ketersediaan data seismik dan daya komputasi [19][13]. Studi sebelumnya menunjukkan bahwa kombinasi *machine learning* dan teknik *deep learning* dapat meningkatkan akurasi prediksi parameter gempa dibandingkan metode konvensional [20][21]. Namun, tantangan utama yang masih dihadapi adalah memastikan model tidak hanya akurat dalam pelatihan, tetapi juga memiliki kemampuan generalisasi yang baik pada data baru [22].

Penelitian ini memberikan kontribusi dengan: Mengevaluasi dampak regularisasi L2 dan *Dropout* terhadap performa model *neural network* dalam prediksi regresi gempa bumi. Membandingkan performa arsitektur *MLP*, *CNN*, dan *FNN* dalam menangani data tabular parameter gempa. Menyediakan wawasan mengenai pemilihan strategi regularisasi optimal untuk meningkatkan generalisasi model tanpa mengorbankan akurasi secara signifikan. Meskipun banyak studi telah meneliti penggunaan *neural network* dalam analisis seismik, terdapat kesenjangan dalam pemahaman mengenai efektivitas teknik regularisasi dalam meningkatkan stabilitas dan akurasi prediksi parameter gempa bumi [23][24]. Selain itu, belum ada kajian komprehensif yang membandingkan performa regularisasi pada arsitektur *neural network* yang berbeda dalam konteks prediksi regresi gempa [25]. Penelitian ini dirancang khusus untuk menutup celah pengetahuan tersebut dengan menyelidiki secara mendalam dampak metode regularisasi terhadap akurasi prediksi, sekaligus mengeksplorasi konfigurasi terbaik guna memaksimalkan generalisasi model dalam konteks peramalan gempa.

#### B. *Dataset*

Penelitian ini memanfaatkan dataset gempa bumi historis yang mencakup ribuan entri data seismik. Setiap entri berisi informasi mengenai magnitudo, kedalaman, lokasi episentrum (lintang dan bujur), serta waktu kejadian. Setelah melalui proses pembersihan dan normalisasi, jumlah data yang digunakan mencapai lebih dari 10.000 entri. Distribusi temporal data menunjukkan frekuensi kejadian gempa per tahun dalam rentang waktu tertentu. Berdasarkan analisis, jumlah gempa bumi per tahun bervariasi antara 2.000 hingga 5.000 kejadian, dengan tren yang fluktuatif namun cenderung meningkat pada tahun-tahun terakhir. Hal ini dapat mencerminkan peningkatan aktivitas seismik global atau peningkatan kemampuan deteksi instrumen seismologi seperti yang ditampilkan pada Gambar 1.a. Distribusi magnitudo gempa dalam dataset ini mengikuti pola yang umumnya diamati dalam studi seismik, di mana gempa dengan magnitudo kecil lebih sering terjadi dibandingkan gempa besar. Sebagian besar gempa dalam dataset memiliki magnitudo 4.0 hingga 5.5, dengan frekuensi mencapai 1.750 kejadian untuk magnitudo 4.0. Frekuensi ini menurun secara eksponensial seiring peningkatan magnitudo, dengan gempa magnitudo  $\geq 7.0$  terjadi kurang dari 250 kali lihat Gambar 1.b. Distribusi ini konsisten dengan hukum *Gutenberg-Richter*, yang menyatakan hubungan logaritmik antara frekuensi dan magnitudo gempa [13]. Dataset ini dibagi menjadi tiga bagian, yaitu data pelatihan sebesar 80%, data validasi sebesar 10%, dan data pengujian sebesar 10%, guna memastikan evaluasi model yang adil dan representatif terhadap data yang tidak terlihat sebelumnya. Data yang digunakan berasal dari sumber terbuka dan resmi dari Kaggle dan BMKG (Badan Meteorologi, Klimatologi, dan Geofisika Indonesia), yang menjamin kredibilitas dan akurasi informasi seismik yang digunakan dalam penelitian ini.




Gambar 1. (a) Tren Temporal Kejadian Gempa Bumi per Tahun (b) Distribusi Frekuensi Gempa Bumi Berdasarkan Magnitudo

### C. Metode Penelitian dan Evaluasi

Instrumen utama yang digunakan adalah arsitektur jaringan *neural network* dan teknik regularisasi. Tiga jenis arsitektur utama yang diterapkan meliputi *Multilayer Perceptron*, *Convolutional Neural Network*, dan *Feedforward Neural Network* dengan struktur yang lebih dalam. *MLP* diuji dalam tiga konfigurasi, yaitu tanpa regularisasi (baseline), dengan regularisasi L2 menggunakan nilai  $\lambda = 0.01$ , dan dengan penerapan dropout sebesar  $p = 0.3$ . *CNN* digunakan dengan penerapan L2 regularization pada lapisan fully connected, sementara model *FNN* dirancang dengan kedalaman lebih dari lima lapisan tersembunyi untuk mengevaluasi performa model yang lebih kompleks dalam menangkap hubungan non-linear.

Teknik regularisasi yang digunakan terdiri dari *L2 Regularization*, yaitu teknik penalti terhadap bobot jaringan untuk mengurangi kompleksitas model dan mencegah *overfitting* [7], serta *Dropout*, yang menonaktifkan secara acak sejumlah neuron selama pelatihan guna mencegah ketergantungan berlebihan terhadap fitur tertentu [6]. Tugas utama dari seluruh model adalah melakukan prediksi regresi terhadap parameter gempa bumi, khususnya magnitudo dan kedalaman, berdasarkan fitur input seismik. Alur proses eksperimen dan desain model divisualisasikan dalam Gambar 2.



Gambar 2. Alur Kerja Adaptif dalam Pemodelan Deep Learning untuk Prediksi Gempa Bumi

Prosedur eksperimen dimulai dengan tahap preprocessing dan *feature engineering*. Pada tahap ini, dilakukan penghapusan data duplikat, penanganan *missing values*, serta normalisasi seluruh fitur numerik menggunakan teknik *Min-Max Scaling*. Selanjutnya, dilakukan perancangan fitur tambahan, estimasi jarak antara episentrum dan pusat populasi terdekat untuk memperkaya representasi data. Setelah *preprocessing* selesai, model dilatih menggunakan algoritma optimasi Adam dengan *learning rate* sebesar 0.001 dan jumlah *epoch* sebanyak 50. Pelatihan dilakukan pada *training set*, sedangkan model dievaluasi pada *validation set* untuk memantau performa selama proses pelatihan. Untuk memastikan kemampuan generalisasi model, diterapkan teknik validasi silang menggunakan skema *5-fold cross-validation*. Setiap eksperimen diulang sebanyak tiga kali dengan *seed* acak yang berbeda untuk memastikan kestabilan dan reproduktibilitas hasil.

Tabel I  
Arsitektur Model

| Model                    | Arsitektur & Regularisasi                                                          | Hyperparameter                                      |
|--------------------------|------------------------------------------------------------------------------------|-----------------------------------------------------|
| MLP Sederhana            | - 3 Dense Layer (128-64-32)<br>- L2 ( $\lambda=0.001$ )<br>- Dropout (20%)         | LR=0.001<br>Batch=32<br>EarlyStopping (patience=10) |
| MLP (L2 Intensified)     | - Sama seperti No.1<br>- L2 ( $\lambda=0.01$ )                                     | Identik dengan No.1                                 |
| CNN dengan Regularisasi  | - 2x Conv1D + MaxPooling<br>- BatchNorm<br>- Dropout (30%) + L2 ( $\lambda=0.01$ ) | LR=0.001<br>Batch=32                                |
| FNN Dasar                | - 3 Dense Layer (128-64-32)<br>- BatchNorm<br>- Dropout (30%)                      | LR=0.001<br>Batch=32                                |
| FNN Deep + L2 Aggressive | - 4 Dense Layer (256-128-64-32)<br>- L2 ( $\lambda=0.01$ )<br>- Dropout (40%)      | LR=0.0005<br>Batch=64<br>EarlyStopping              |

Selain evaluasi kuantitatif, dilakukan pula analisis visual untuk mendukung interpretasi hasil. Kurva *loss* dibandingkan antara *training* dan *validation loss* guna mendeteksi potensi *overfitting* atau *underfitting*, sedangkan *scatter plot* antara nilai prediksi dan nilai aktual digunakan untuk mengevaluasi distribusi kesalahan prediksi dengan Kurva *Loss* dan *Scatter Plot Prediksi vs. Aktual*

Hasil model dievaluasi secara kuantitatif menggunakan tiga metrik utama, yaitu *Root Mean Squared Error (RMSE)* untuk menilai ketepatan prediksi model secara umum, *Mean Absolute Error (MAE)* untuk mengukur rata-rata kesalahan absolut, dan *R<sup>2</sup> Score* (koefisien determinasi) untuk mengevaluasi sejauh mana model dapat menjelaskan variabilitas target data. Selain itu, dilakukan analisis perbandingan performa antar model dengan dan tanpa regularisasi, serta penilaian terhadap dampak kedalaman arsitektur terhadap performa prediksi regresi. Hasil evaluasi penelitian ini juga memberikan rekomendasi mengenai strategi regularisasi yang paling efektif untuk prediksi regresi gempa bumi. Selain itu, dibahas pula potensi pemanfaatan model neural network dalam sistem peringatan dini bencana alam.

### III. HASIL DAN PEMBAHASAN

Model FNN dengan regularisasi agresif menunjukkan peningkatan  $R^2$  yang kecil namun stabil. Analisis ini menunjukkan bahwa FNN dapat menangani non-linearitas, namun tidak unggul signifikan dibanding MLP. CNN gagal karena tidak mampu menangkap struktur lokal dari input numerik. Gambar 3 menunjukkan tren *overfitting* jelas terjadi pada CNN, ditandai dengan gap besar antara *training* dan *validation loss*. Sedangkan *scatter plot* pada Gambar 4 memperlihatkan distribusi prediksi MLP mendekati garis diagonal ( $y = x$ ), menandakan akurasi tinggi. Perbedaan performa model didorong oleh jumlah parameter, kedalaman layer, dan sensitivitas terhadap regularisasi. Dropout terlalu agresif menurunkan MAE namun meningkatkan RMSE, menunjukkan trade-off antara error rata-rata dan error maksimum.


Hasil eksperimen menunjukkan perbandingan performa lima model jaringan *Neural Network* pada tugas prediksi regresi parameter gempa bumi, yaitu magnitudo dan kedalaman. Model-model tersebut diuji dengan berbagai teknik regularisasi untuk mengevaluasi akurasi dan kemampuan generalisasi. Evaluasi dilakukan menggunakan metrik *RMSE*, *MAE*, dan  $R^2$ , yang hasil lengkapnya ditampilkan pada Tabel 1 berikut:

Tabel II.  
Performa Model dengan Teknik Regularisasi


| Model                       | RMSE  | MAE   | $R^2$ |
|-----------------------------|-------|-------|-------|
| MLP (Baseline)              | 0.500 | 0.380 | 0.625 |
| MLP + L2 ( $\lambda=0.01$ ) | 0.551 | 0.424 | 0.545 |
| CNN + L2                    | 0.618 | 0.473 | 0.429 |
| FNN(Baseline)               | 0.534 | 0.402 | 0.572 |
| FNN (Deep) + L2             | 0.489 | 0.373 | 0.641 |

Model *MLP baseline* menunjukkan performa terbaik dengan nilai *RMSE* sebesar 0.500 dan  $R^2$  sebesar 0.625. Namun, stabilitas model ini selama pelatihan tergolong rendah karena tidak menggunakan teknik regularisasi, sehingga berisiko overfitting. Penambahan regularisasi L2 pada *MLP* sedikit menurunkan performa (*RMSE* naik menjadi 0.551), tetapi meningkatkan kestabilan pelatihan. *Dropout* pada *MLP* memberikan *RMSE* sebesar 0.570, mengindikasikan adanya trade-off antara akurasi dan ketahanan terhadap overfitting. Model *CNN* menunjukkan performa terendah, sementara model *FNN* dengan kedalaman tambahan sedikit unggul dalam  $R^2$  (0.641), namun dengan peningkatan kebutuhan komputasi.

Visualisasi pelatihan dan prediksi model ditunjukkan pada Gambar 3 dan Gambar 4, yang masing-masing menunjukkan kurva *loss* dan scatter plot antara nilai prediksi dengan nilai aktual.



Gambar 3. Kurva Training dan Validation Loss: (a). MLP (Baseline) (b) MLP + L2 ( $\lambda=0.01$ ) (c) CNN + L2 (d) FNN(Baseline) (e) FNN (Deep) + L2



Gambar 4: Scatter Plot Prediksi vs. Nilai Aktual

Hasil utama menunjukkan bahwa model *MLP* tanpa regularisasi memberikan akurasi tertinggi, tetapi berisiko tinggi mengalami *overfitting*. Sebaliknya, penerapan *L2 regularization* dan *dropout* memberikan manfaat dalam meningkatkan kemampuan generalisasi meskipun dengan sedikit pengorbanan pada akurasi. Regularisasi *L2* terbukti menstabilkan proses pelatihan dan menurunkan fluktuasi *loss*, meskipun terjadi penurunan  $R^2$  sekitar 2,4%. Ini menunjukkan bahwa *L2* merupakan pilihan efektif untuk mengurangi *overfitting* tanpa kehilangan performa secara drastis. Sementara itu, *dropout* memberikan pengurangan *MAE*, namun meningkatkan *RMSE*, mengindikasikan bahwa *dropout* efektif untuk mencegah *overfitting* tetapi memerlukan pemilihan nilai parameter yang optimal. *Dropout* dengan  $p$  yang terlalu tinggi (misalnya  $> 0.5$ ) justru menyebabkan *underfitting*, sesuai dengan temuan pada eksperimen tambahan. Perbandingan antar arsitektur mengonfirmasi bahwa *CNN* tidak cocok untuk data tabular seperti gempa bumi.  $R^2$  yang jauh lebih rendah (0.429) menunjukkan bahwa *CNN* gagal mengekstraksi pola yang relevan dari data numerik, meskipun efektif untuk data spasial seperti peta atau citra. *FNN* dengan lebih dari lima lapisan menghasilkan  $R^2$  sedikit lebih tinggi dari *MLP*, namun peningkatan ini tidak cukup signifikan untuk membenarkan kebutuhan sumber daya komputasi yang lebih besar.

#### IV. KESIMPULAN

Kesimpulan ini menegaskan kontribusi utama bahwa *MLP* dengan *Dropout* ( $p=0.3$ ) adalah konfigurasi paling optimal untuk prediksi regresi gempa pada data tabular. Studi ini menyoroti bahwa model kompleks seperti *FNN* tidak selalu lebih baik dan bahwa regularisasi memegang peranan penting dalam stabilitas pelatihan. Batasan studi mencakup (1) belum digunakannya data spasial seismogram atau peta geologi, (2) model hanya diuji pada data Indonesia, sehingga belum diketahui generalisasi globalnya, (3) nilai  $\lambda$  dan  $p$  regularisasi dipilih secara empiris, tanpa pencarian grid yang sistematis. Penelitian mendatang dapat menguji transfer learning antar kawasan seismik, eksplorasi regularisasi adaptif, serta penggabungan data spasial-temporal untuk memperkaya konteks prediktif.

Penelitian ini mengevaluasi efektivitas teknik regularisasi pada berbagai arsitektur *Neural Network* untuk prediksi regresi data gempa bumi. Hasil eksperimen menunjukkan bahwa model *MLP* baseline tanpa regularisasi mencapai performa optimal (*RMSE*: 0.500, *MAE*: 0.380,  $R^2$ : 0.625), namun penerapan *Dropout* ( $p=0.3$ ) berhasil menyeimbangkan akurasi dan generalisasi dengan mengurangi *overfitting*. Sementara itu, *L2 Regularization* ( $\lambda=0.01$ ) meningkatkan stabilitas model meskipun dengan sedikit penurunan akurasi. Arsitektur *CNN* terbukti kurang cocok untuk data tabular ( $R^2$ : 0.429) karena ketiadaan pola spasial, sedangkan *FNN* dengan kedalaman lebih tinggi hanya memberikan peningkatan marginal, menunjukkan bahwa kompleksitas tidak selalu sebanding dengan akurasi.

Temuan utama mengarah pada rekomendasi *MLP* dengan *Dropout* sebagai pilihan optimal untuk prediksi gempa bumi berbasis data tabular. Namun, keterbatasan studi mencakup penggunaan data non-temporal/spasial, parameter regularisasi empiris, dan belum adanya eksplorasi model sekuensial *LSTM* atau *Transformer*. Untuk penelitian lanjutan, eksplorasi model berbasis waktu, integrasi data spasial (seismogram/peta), atau augmentasi data dapat menjadi solusi untuk meningkatkan prediksi gempa berkekuatan tinggi. Implementasi sistem real-time dengan sumber data dinamis menggunakan *API* BMKG perlu dipertimbangkan guna membangun sistem prediksi yang lebih adaptif. Secara keseluruhan, studi ini menegaskan pentingnya pemilihan arsitektur dan strategi regularisasi yang sesuai dengan karakteristik data, di mana kesederhanaan model *MLP* dapat lebih efektif daripada kompleksitas yang tidak terjustifikasi.

## REFERENSI

- [1] S. K C, A. Bhusal, D. Gautam, and R. Rupakhety, "Earthquake damage and rehabilitation intervention prediction using machine learning," *Eng. Fail. Anal.*, vol. 144, p. 106949, 2023, doi: <https://doi.org/10.1016/j.engfailanal.2022.106949>.
- [2] C. Zhu, F. Cotton, H. Kawase, and K. Nakano, "How well can we predict earthquake site response so far? Machine learning vs physics-based modeling," *Earthq. Spectra*, vol. 39, no. 1, pp. 478–504, 2023, doi: 10.1177/87552930221116399.
- [3] Q. Yin, C. Han, A. Li, X. Liu, and Y. Liu, "A Review of Research on Building Energy Consumption Prediction Models Based on Artificial Neural Networks recently, this literature review aims to provide a thorough analysis of types, and temporal characteristics in energy consumption poses guidelines for," *sustainability*, vol. 16, pp. 1–30, 2024.
- [4] Z. Zhang, Y. Song, T. Chen, and J. He, "A regularized orthogonal activated inverse-learning neural network for regression and classification with outliers," *Neural Networks*, vol. 173, p. 106208, 2024, doi: <https://doi.org/10.1016/j.neunet.2024.106208>.
- [5] S. Beltozar-Clemente, O. Iparraguirre-Villanueva, F. Pucuhuayla-Revatta, J. Zapata-Paulini, and M. Cabanillas-Carbonell, "Predicting customer abandonment in recurrent neural networks using short-term memory," *J. Open Innov. Technol. Mark. Complex.*, vol. 10, no. 1, p. 100237, 2024, doi: <https://doi.org/10.1016/j.joitmc.2024.100237>.
- [6] S. Susandri, A. Zamsuri, N. Nasution, Y. Efendi, and H. B. Alwan, "Mitigating Overfitting in Sentiment Analysis Insights from CNN-LSTM Hybrid Models," *Matrik J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 24, no. 2, pp. 297–308, 2025, doi: 10.30812/matrik.v24i1.4742.
- [7] D. Muhammad, I. Ahmad, M. I. Khalil, W. Khalil, and M. O. Ahmad, "A Generalized Deep Learning Approach to Seismic Activity Prediction," *Appl. Sci.*, vol. 13, no. 3, pp. 1–13, 2023, doi: 10.3390/app13031598.
- [8] M. A. Rusho, R. Azizova, D. Mykhalevskiy, M. Karyonov, and H. Hasanova, "Advanced Earthquake Prediction: Unifying Networks, Algorithms, and Attention-Driven Lstm Modelling," *Int. J. GEOMATE*, vol. 27, no. 119, pp. 135–142, 2024, doi: 10.21660/2024.119.m2415.
- [9] J. Jia and W. Ye, "Deep Learning for Earthquake Disaster Assessment: Objects, Data, Models, Stages, Challenges, and Opportunities," *Remote Sens.*, vol. 15, no. 16, pp. 1–41, 2023, doi: 10.3390/rs15164098.
- [10] "LSTM, WaveNet, and 2D CNN for nonlinear time history prediction of seismic responses," *Engineering Structures*. 2023. doi: 10.1016/j.engstruct.2023.116083.
- [11] S. Goyal, A. Raghunathan, M. Jain, H. V. Simhadri, and P. Jain, "{DROCC}: Deep Robust One-Class Classification," in *Proceedings of the 37th International Conference on Machine Learning*, H. D. III and A. Singh, Eds., in *Proceedings of Machine Learning Research*, vol. 119. PMLR, 2020, pp. 3711–3721. [Online]. Available: <https://proceedings.mlr.press/v119/goyal20c.html>
- [12] D. Joshi, B. Singh, S. Kalonia, A. K. Kaushik, N. Goyal, and S. Maggu, "Predictive Modeling of Cardiovascular Disease Using Feedforward Neural Networks," in *Proceedings of International Conference on Paradigms of Communication, Computing and Data Analytics*, H. Mittal, S. J. Nanda, and M.-H. Lim, Eds., Singapore: Springer Nature Singapore, 2025, pp. 195–206.
- [13] V. Convertito, F. Giampaolo, O. Amoroso, and F. Piccialli, "Deep learning forecasting of large induced earthquakes via precursory signals," *Sci. Rep.*, vol. 14, no. 1, pp. 1–17, 2024, doi: 10.1038/s41598-024-



- 52935-2.
- [14] R. Chhaya, A. Dasgupta, and S. Shit, "On Coresets for Regularized Regression," in *Proceedings of the 37th International Conference on Machine Learning*, H. D. III and A. Singh, Eds., in Proceedings of Machine Learning Research, vol. 119. PMLR, 2020, pp. 1866–1876. [Online]. Available: <https://proceedings.mlr.press/v119/chhaya20b.html>
  - [15] Y. Sheng and E. Dobriban, "One-shot Distributed Ridge Regression in High Dimensions," in *Proceedings of the 37th International Conference on Machine Learning*, H. D. III and A. Singh, Eds., in Proceedings of Machine Learning Research, vol. 119. PMLR, 2020, pp. 8763–8772. [Online]. Available: <https://proceedings.mlr.press/v119/sheng20a.html>
  - [16] A. Shevchenko and M. Mondelli, "Landscape Connectivity and Dropout Stability of {SGD} Solutions for Over-parameterized Neural Networks," in *Proceedings of the 37th International Conference on Machine Learning*, H. D. III and A. Singh, Eds., in Proceedings of Machine Learning Research, vol. 119. PMLR, 2020, pp. 8773–8784. [Online]. Available: <https://proceedings.mlr.press/v119/shevchenko20a.html>
  - [17] A. Joshi, B. Raman, C. K. Mohan, and L. R. Cenkeramaddi, "Application of a new machine learning model to improve earthquake ground motion predictions," *Nat. Hazards*, vol. 120, no. 1, pp. 729–753, 2024, doi: 10.1007/s11069-023-06230-4.
  - [18] E. Abebe, H. Kebede, M. Kevin, and Z. Demissie, "Earthquakes magnitude prediction using deep learning for the Horn of Africa," *Soil Dyn. Earthq. Eng.*, vol. 170, p. 107913, 2023, doi: <https://doi.org/10.1016/j.soildyn.2023.107913>.
  - [19] P. Chittora *et al.*, "Experimental analysis of earthquake prediction using machine learning classifiers, curve fitting, and neural modeling," *PREPRINT*, vol. 2, pp. 1–26, 2022, [Online]. Available: <https://doi.org/10.21203/rs.3.rs-1896823/v2>
  - [20] 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.
  - [21] 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. March, pp. 57172–57184, 2024, doi: 10.1109/ACCESS.2024.3390781.
  - [22] S. M. Mousavi and G. C. Beroza, "Machine Learning in Earthquake Seismology," *Annu. Rev. Earth Planet. Sci.*, vol. 51, pp. 105–129, 2023, doi: 10.1146/annurev-earth-071822-100323.
  - [23] N. Zhang *et al.*, "Dose My Opinion Count? A CNN-LSTM Approach for Sentiment Analysis of Indian General Elections," *J. Theory Pract. Eng. Sci.*, vol. 4, no. 05, pp. 40–50, 2024, doi: 10.53469/jtpes.2024.04(05).06.
  - [24] B. Hong, "Regularization in Network Optimization via Trimmed Stochastic Gradient Descent With Noisy Label," *IEEE Access*, vol. 10, pp. 34706–34715, 2022, doi: 10.1109/ACCESS.2022.3171910.
  - [25] M. Dahiru, S. Osanga, and E. Samuel, "Sciences Regularization effects in deep learning architecture," *J. Niger. Soc. Phys. Sci.*, vol. 6, pp. 1–11, 2024.

### UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada BMKG Indonesia dan Kaggle atas data seismik, Universitas Lancang Kuning atas dukungan teknis, serta Sekolah Pascasarjana Unilak atas pendanaan (Hibah PNT20251097) dan masukan akademik. Ucapan terima kasih juga disampaikan kepada para peninjau anonim atas saran yang meningkatkan kualitas naskah.