

Prediksi Kerusakan Bangunan Pasca Gempa Bumi Menggunakan Metode Deep Neural Network

Fakhrurrozi¹, Danny Oka Ratmana², Nurul Anisa Sri Winarsih³, Galuh Wilujeng Saraswati⁴, Muhammad Syaifur Rohman⁵, Filmada Ocky Saputra⁶, Ricardus Anggi Pramunendar⁷, Guruh Fajar Shidik⁸

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro, Semarang
Jl. Imam Bonjol No.207, Pendrikan Kidul, Kec. Semarang Tengah, Kota Semarang, Jawa Tengah
50131,Indonesia

e-mail: ¹rf8540300@gmail.com, ²rdannyoka@dsn.dinus.ac.id, ³nurulanisasw@dsn.dinus.ac.id,
⁴galuhwilujeng@dsn.dinus.ac.id, ⁵syiaifur@dsn.dinus.ac.id, ⁶filmada.os@dsn.dinus.ac.id, ⁷
Ricardus.anggi@dsn.dinus.ac.id, ⁸guruh.fajar@research.dinus.ac.id

Submitted Date: December 25th,2023

Revised Date: January 26th, 2024

Reviewed Date: January 21st, 2024

Accepted Date: January 26th, 2024

Abstract

Addressing the challenge of predicting earthquake-induced building damage, this study proposes the innovative use of Deep Neural Networks (DNN) as a solution. Focusing on optimizing predictive models, the research evaluates the effectiveness of various optimizers - ADAM, SGD, RMSprop, and Adagrad - coupled with adjustments in the learning rate to determine the most efficient configuration. The experiment was conducted to compare the performance of each optimizer in predicting post-earthquake building damage, a critical issue in disaster mitigation. The results demonstrate that ADAM significantly outperforms other optimizers, achieving the highest accuracy of up to 90.50% at a learning rate of 0.001, with RMSprop as its closest competitor. While SGD and Adagrad yielded lower accuracies, SGD showed improvement with higher learning rates. The variance analysis confirmed that the choice of optimizer significantly impacts model performance, with the p-value indicating strong statistical significance for optimizers (1.23E-09), whereas the learning rate had no significant impact (p-value 0.56098964). These findings underline the importance of selecting the appropriate optimizer to enhance the accuracy of DNN models for building damage prediction, a crucial aspect in emergency response planning and earthquake disaster mitigation efforts. This research contributes significantly to the development of more accurate predictive models, which are essential in minimizing the risks of earthquake disasters.

Keywords: Deep Neural Network; Building Damage Prediction; Earthquake; Learning Rate; Optimizer.

Abstrak

Menghadapi tantangan dalam memprediksi kerusakan bangunan akibat gempa bumi, penelitian ini mengusulkan penggunaan Deep Neural Network (DNN) sebagai solusi inovatif. Dengan fokus pada optimisasi model prediktif, penelitian ini mengevaluasi efektivitas berbagai optimizer - ADAM, SGD, RMSprop, dan Adagrad - dengan penyesuaian learning rate untuk menentukan konfigurasi yang paling efektif. Eksperimen dilakukan untuk membandingkan performa setiap optimizer dalam memprediksi tingkat kerusakan bangunan pasca-gempa, yang merupakan masalah kritis dalam mitigasi bencana. Hasilnya menunjukkan bahwa ADAM secara signifikan mengungguli optimizer lain, mencapai akurasi tertinggi hingga 90,50% pada learning rate 0,001, dengan RMSprop sebagai kompetitor terdekat. Meskipun SGD dan Adagrad menghasilkan akurasi yang lebih rendah, SGD menunjukkan peningkatan dengan learning rate yang lebih tinggi. Analisis varians menegaskan bahwa pemilihan optimizer memiliki dampak signifikan terhadap kinerja model, dengan nilai p yang menunjukkan signifikansi statistik yang kuat untuk optimizer (1.23E-09), sementara learning rate tidak berdampak signifikan (p-value 0.56098964). Temuan



ini menggarisbawahi pentingnya memilih optimizer yang tepat dalam meningkatkan akurasi model DNN untuk prediksi kerusakan bangunan, suatu aspek krusial dalam perencanaan respons darurat dan upaya mitigasi bencana gempa bumi. Penelitian ini memberikan kontribusi penting dalam pengembangan model prediktif yang lebih akurat, yang sangat dibutuhkan untuk meminimalkan risiko bencana gempa bumi.

Kata Kunci: Deep Neural Network; Prediksi Kerusakan Bangunan; Gempa Bumi; Learning Rate; Optimizer.

1 Pendahuluan

Gempa bumi merupakan fenomena yang tidak dapat dihindari dan seringkali menimbulkan kerusakan besar pada manusia dan infrastruktur. Indonesia sendiri merupakan negara yang sangat rawan mengalami gempa bumi. Karena letaknya letaknya di pertemuan lempeng tektonik Asia, Pasifik, dan Australia sehingga di mendapat julukan "*Ring of Fire*" (Hu et al., 2018) (Maryani, 2021) (Triastari et al., 2021). Gempa bumi dapat terjadi dengan berbagai kekuatan, mulai dari yang hanya terasa sebagai getaran ringan hingga yang memiliki potensi untuk menyebabkan kerusakan besar pada infrastruktur dan bahkan menimbulkan banyak korban jiwa.

Menurut penelitian pada tahun 2022 oleh Subash Gumire, (Ghimire et al., 2022) kerusakan bangunan akibat gempa bumi sangat bervariasi, tergantung pada faktor-faktor seperti intensitas gempa, jarak dari episentrum, kualitas konstruksi bangunan, umur bangunan dan jenis tanah di lokasi tersebut. Dalam kejadian gempa yang kuat, bangunan mungkin mengalami kerusakan struktural serius, termasuk retakan pada dinding, kerusakan pada fondasi, hingga runtuhnya struktur bangunan. Bangunan yang dirancang tanpa mempertimbangkan ketahanan seismik atau yang dibangun di atas tanah yang tidak stabil lebih rentan mengalami kerusakan parah.

Sebagai negara yang berada di "*Ring of Fire*", secara konsisten menghadapi ancaman gempa bumi yang serius. Memprediksi dan mengklasifikasikan tingkat kerusakan yang mungkin terjadi pada bangunan saat gempa merupakan langkah krusial dalam mempersiapkan dan mengurangi risiko bencana.

Dengan memanfaatkan Deep Neural Networks (DNN) untuk klasifikasi kerusakan, penelitian ini bertujuan untuk mengembangkan sebuah sistem yang berguna dalam mengevaluasi kerentanan bangunan terhadap gempa. Hal ini sangat penting untuk memastikan keselamatan penduduk dan meminimalisir kerugian ekonomi.

Model yang akurat dapat membantu dalam perencanaan kota dan pembangunan infrastruktur yang lebih tangguh, memungkinkan pemerintah dan lembaga terkait untuk mengambil tindakan preventif yang lebih efektif.

Dalam upaya untuk mengklasifikasikan tingkat kerusakan bangunan yang disebabkan oleh gempa bumi, penelitian ini dilakukan menggunakan metode *deep neural network* (DNN) untuk mengetahui tingkat kerusakan bangunan yang sudah dibagi menjadi lima tingkatan. Untuk penelitian tersebut menggunakan empat optimizer dengan parameter berbeda dan dilakukan perbandingan untuk mendapatkan akurasi yang lebih baik. Proses pelatihan model dijalankan menggunakan set data latih dan validasi. Evaluasi model dilakukan pada set data uji untuk menentukan tingkat akurasi, yang memberikan gambaran tentang efektivitas arsitektur dan hiperparameter yang dipilih dalam klasifikasi data uji. Tingkat akurasi yang tinggi mencerminkan kesesuaian model dengan data dan menunjukkan potensi model dalam menyelesaikan tugas klasifikasi yang ditargetkan dalam penelitian ini. Pemilihan optimizer yang tepat, seperti RMSprop, Adam, SGD, atau Adagrad, dapat secara signifikan mempengaruhi hasil pelatihan dan kinerja model, bergantung pada sifat khusus data dan masalah yang ditangani.

2 Penelitian Terkait

Pada penelitian sebelumnya oleh (Ghimire et al., 2022) mengenai penerapan teknik machine learning dalam memproyeksikan kerusakan pada bangunan yang disebabkan oleh gempa. Penelitian ini mengeksplorasi efektivitas algoritma seperti Neural Network dan Random Forest dalam evaluasi kerusakan struktural bangunan setelah terjadinya gempa.

Temuan utama menunjukkan bahwa Random Forest menunjukkan kinerja yang baik dalam memprediksi kerusakan, mencatat skor F1 sebesar 74,32%. Berdasarkan penelitian ini

karakteristik bangunan seperti jumlah lantai, usia bangunan, area lantai, dan ketinggiannya, dapat diaplikasikan dalam manajemen bencana dan perencanaan perkotaan setelah gempa.

Penelitian yang dilakukan Kuldeep Chaurasia pada tahun 2019 (Chaurasia et al., 2019) membangun berbagai skenario kerusakan akibat gempa menggunakan berbagai fitur. Dalam penelitian ini, kerusakan bangunan akibat gempa di Nepal diklasifikasikan dalam berbagai tingkat kerusakan. Penelitian ini menggunakan algoritma Neural Network (NN) dan Random Forest dengan penyetelan parameter untuk menilai kondisi struktur bangunan. Hasil analisis menunjukkan bahwa metode Random Forest lebih unggul daripada pendekatan neural network dalam memprediksi kerusakan bangunan. Skor F1 yang diperoleh menggunakan klasifikasi Random Forest adalah 74,32%. Pendekatan ini dianggap sederhana, nyaman, dan mudah diimplementasikan dalam program komputer. Selain itu, metode ini berkontribusi dalam penilaian kerugian akibat kerusakan gempa secara cepat.


Penelitian yang dilakukan oleh (Isnaeni & Prasetyo, 2022) pada tahun 2022, mengklasifikasi kerusakan lahan akibat bencana tsunami menggunakan metode Machine Learning. Metode yang digunakan adalah Artificial Neural Network (ANN), yang dibandingkan dengan Random Forest dan Support Vector Machine (SVM) untuk menentukan metode terbaik dalam klasifikasi dan prediksi risiko kerusakan lahan. Hasil penelitian menunjukkan bahwa metode ANN merupakan metode paling akurat untuk klasifikasi prediksi, dengan akurasi mencapai 95.45% dan nilai Kappa sebesar 86.08%. Prediksi spasial menggunakan interpolasi Inverse Distance Weighted (IDW) menghasilkan peta distribusi wilayah risiko tinggi dan rendah kerusakan lahan akibat tsunami. Temuan ini menunjukkan keefektifan ANN dalam klasifikasi dan prediksi wilayah berpotensi risiko tinggi kerusakan akibat bencana tsunami, yang dapat digunakan dalam perencanaan mitigasi bencana dan respons darurat.

Deep Neural Network (DNN) juga dikembangkan untuk menilai risiko bencana geologi yang dipicu oleh gempa bumi (Su et al., 2022). Model DNN dilatih menggunakan sembilan faktor kunci yang mempengaruhi bencana geologi, dan kinerjanya dibandingkan dengan model lain seperti Support Vector Machine (SVM), Logistic

Regression (LR), dan Random Forest (RF). Hasilnya menunjukkan bahwa model DNN memiliki akurasi tertinggi di antara semua model, membuatnya sangat cocok untuk membuat peta kerentanan dan bahaya geologi. Hal ini menunjukkan potensi model DNN sebagai alat untuk memprediksi bencana berantai dan menilai bahaya geologi.

3 Metode Penelitian

Setidaknya ada tujuh tahapan dalam penelitian ini yaitu input data, eksplorasi data, klasifikasi data menggunakan deep learning, memilih DNN sebagai algoritma yang dipakai, melakukan ujicoba terhadap deep neural network(DNN), menggunakan Optimizer ke DNN, dan yang terakhir evaluasi model.(Gambar 1)



Gambar 1. Tahapan Penelitian

3.1 Hardware and Software

Perangkat keras merupakan faktor kunci dalam keberhasilan penelitian, terutama dalam bidang ilmu komputer di mana peran perangkat keras dan perangkat lunak sangat krusial. Kinerja perangkat lunak yang optimal memerlukan dukungan dari perangkat keras yang berkualitas, dan sebaliknya, perangkat keras canggih membutuhkan perangkat lunak yang sesuai untuk mengoptimalkan fungsinya. Kedua komponen ini saling melengkapi dan sangat vital untuk mendukung kelancaran serta keberhasilan riset. Dalam penelitian ini, kami menggunakan perangkat keras pribadi dengan spesifikasi:

- Processor : Intel Core I5-11400H
- VGA : Nvidia RTX 3050
- SSD : 2 TB
- RAM : 16 GB

Sedangkan perangkat lunak yang digunakan untuk penelitian ini adalah Jupyter Notebook. Aplikasi ini digunakan untuk melakukan penelitian ini karena dapat menjalankan Python yang memiliki perpustakaan yang diperlukan seperti

TensorFlow dan PyTorch (Randles et al., 2017) untuk mendukung pembuatan model Deep Neural Network.

3.2 Input Data

Penelitian ini menggunakan dataset "Earthquake Damage to Buildings in Nepal" (yang dapat diakses melalui tautan <https://eq2015.npc.gov.np/#/>). Dataset ini mencakup data kerusakan bangunan akibat gempa bumi di Nepal dari tahun 2015 hingga saat ini. Tujuan utama dari penggunaan data tersebut adalah untuk mengembangkan model Deep Neural Network (DNN) yang mampu memprediksi tingkat kerusakan bangunan akibat gempa bumi, yang nantinya dilatih dengan dataset tersebut untuk mengidentifikasi dan mempelajari pola-pola signifikan dalam data yang berkaitan dengan kerusakan bangunan. Variabel target dalam dataset tersebut ialah "damage target" yang menentukan tingkatan kerusakan bangunan sebagai "grade 1 sampai 5". Dataset ini memiliki 31 atribut dan 762,106.

3.3 Eksplorasi Data

Exploratory Data Analysis (EDA) merupakan proses fundamental dalam analisis data yang menggunakan statistik deskriptif dan visualisasi untuk memahami karakteristik utama dalam dataset, termasuk distribusi, variabilitas, dan korelasi antar variabel (Matchev et al., 2022). Melaksanakan Eksplorasi Data (EDA) sebelum mengembangkan model pembelajaran mesin menghadirkan berbagai manfaat, seperti mengidentifikasi pola dan tren yang tidak langsung terlihat dengan inspeksi data sekilas, serta menemukan keterkaitan dan struktur dalam dataset yang ada (Da Poian et al., 2023).

3.4 Preprocessing

Preprocessing data merupakan serangkaian langkah yang diambil sebelum analisis data untuk membersihkan dan menyusun data sehingga cocok untuk digunakan dalam pembuatan model. Langkah-langkah ini termasuk normalisasi, penanganan nilai yang hilang, encoding variabel kategorikal, dan pengurangan dimensi. Preprocessing sangat penting karena data mentah sering kali tidak sempurna atau tidak terstruktur dengan baik, yang dapat memengaruhi kinerja model. Dengan memproses data terlebih dahulu,


kita memastikan bahwa algoritma klasifikasi dapat bekerja dengan lebih efektif, menghasilkan model yang lebih akurat dan prediksi yang lebih handal. Preprocessing diperlukan untuk memaksimalkan kinerja algoritma klasifikasi (Sun et al., 2018).

3.5 Klasifikasi Data Menggunakan Deep Learning

Deep Learning adalah subbidang dari machine learning yang berkaitan dengan algoritma yang terinspirasi oleh struktur dan fungsi otak, yang dikenal sebagai jaringan saraf tiruan (neural networks). Istilah "deep" merujuk pada jumlah lapisan dalam jaringan saraf tiruan—dalam deep learning, jaringan ini seringkali terdiri dari banyak lapisan, yang memungkinkan sistem untuk mempelajari tingkatan abstraksi yang tinggi dalam data. Deep Learning merupakan salah satu bagian dalam Machine Learning yang menggunakan algoritma, yang dibuat berdasarkan pada hukum matematik, yang bekerja layaknya otak manusia (Maulana & Rochmawati, 2020).

3.6 Deep Neural Network

Deep Neural Networks (DNN) adalah kelas model pembelajaran mesin penting yang digunakan untuk merepresentasikan hubungan input-output yang kompleks (Das et al., 2020). Deep Neural Networks (DNN) adalah jenis algoritme pembelajaran mesin yang terdiri dari beberapa lapisan node atau neuron yang saling berhubungan, yang dapat mempelajari pola dan representasi kompleks dari data masukan (Retson et al., 2019). Arsitektur DNN biasanya mencakup beberapa lapisan tersembunyi antara lapisan input dan output.



Gambar 2. Arsitektur Deep Neural Network

- Input Layer: Lapisan ini menerima data masukan, bisa berupa gambar, teks, atau jenis data lainnya.

- Hidden layer: Lapisan ini bertanggung jawab untuk ekstraksi dan transformasi fitur. Mereka terdiri dari neuron yang memproses data masukan dan meneruskannya ke lapisan berikutnya. Hidden layer dapat dibagi menjadi beberapa sublapisan, seperti lapisan konvolusional, lapisan penggabungan, dan lapisan terhubung penuh (Retson et al., 2019).
- Output Layer: Lapisan ini menghasilkan keluaran akhir atau prediksi berdasarkan data masukan yang diproses. Ini terdiri dari neuron yang bertanggung jawab untuk membuat keputusan atau prediksi (Firmansyah, Rusmal, Shidiq, 2023).

Dalam pengujian ini, digunakan fungsi aktivasi *softmax* pada *output layer*.

Fungsi Aktivasi *Softmax* :

$$f(x)_i = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$$

3.7 Matrix Evaluasi

Tabel 1. *Confusion Matrix*

		Prediksi	
		0	1
Actual	0	True Negative	False Positive
	1	False Negative	True Positive

Untuk prediksi dalam data kategorikal melibatkan penghitungan indikator kinerja model klasifikasi. *Confusion Matrix* adalah matriks berukuran 2x2 yang mewakili performa model pada kumpulan data tertentu, dengan baris mewakili kelas aktual dari instance dan kolom mewakili kelas prediksinya. Ini berisi nilai-nilai berikut: *true positives* (TP), *true negatives* (TN), *false positives* (FP), and *false negatives* (FN) (Caelen, 2017) yang bisa dilihat pada Tabel 1.

- "True Negative" (TN) merujuk pada jumlah prediksi yang benar bahwa sebuah instansi adalah negatif,
- "False Positive" (FP) adalah jumlah prediksi yang salah bahwa sebuah instansi adalah positif,
- "False Negative" (FN) mewakili jumlah prediksi yang salah di mana sebuah instansi adalah negatif,

- "True Positive" (TP) adalah jumlah prediksi yang benar bahwa sebuah instansi adalah positif.

Untuk mengukur kinerja dan validasi model prediksi yang diusulkan, penelitian ini menggunakan akurasi dan kerugian menggunakan *cross-entropy loss* sebagai matriks evaluasi. Akurasi adalah matriks yang mengukur persentase prediksi benar yang dibuat oleh model dibandingkan dengan label sebenarnya. Rumus akurasi sebagai berikut :

$$accuracy = \frac{TP + TN}{TP + FP + FN + TN}$$

Cross-entropy loss mengukur seberapa akurat model memprediksi kelas sebenarnya dari setiap sampel. Semakin rendah nilai kerugian *cross-entropy*, semakin baik model dalam memprediksi kelas yang tepat, berikut adalah rumusnya:

Cross-entropy loss

$$L(y, y^{\wedge}) = -(y \log(y^{\wedge}) + (1 - y) \log(1 - y^{\wedge}))$$

Di mana:

- y adalah label kelas sebenarnya (0 atau 1)
- p adalah probabilitas model memprediksi sampel berada di kelas 1.

4 Hasil dan Pembahasan

Dalam penelitian ini penulis menggunakan metode pengumpulan dan pengolahan data kuantitatif dan metode Deep neural Network. Metode ini dipilih karena Deep Neural Network (DNN) memiliki kemampuan untuk menangkap kompleksitas dan hubungan non-linear yang ada dalam data besar. DNN mampu memodelkan interaksi yang rumit antara fitur-fitur dengan menggunakan banyak lapisan pemrosesan, yang masing-masing dapat belajar representasi data pada tingkat abstraksi yang berbeda. Ini sangat cocok untuk menangani volume besar data kuantitatif, yang sering ditemui dalam penelitian yang mengandalkan pengolahan data numerik untuk mendapatkan insight dan pola tersembunyi. Selain itu, DNN telah terbukti sukses dalam berbagai aplikasi, seperti pengolahan gambar (Ghenescu et al., 2018), pemrosesan bahasa alami (Mittal, 2020), dan analisis prediktif (Shah & Campbell, 2018), yang menambah kepercayaan bahwa metode ini dapat memberikan hasil yang akurat dan berdampak dalam konteks penelitian yang



dilakukan. Penelitian ini terdiri dari beberapa tahapan utama yaitu, (1) Input data, (2) Data Eksplorasi, (3) Pre-processing, (4) Klasifikasi menggunakan deep neural network, (5) Evaluasi model.

4.1 Input Data

Dalam penelitian yang menggunakan metode Deep Neural Network untuk menilai kerusakan bangunan, pengumpulan data menjadi langkah awal yang sangat krusial. Variabel target yang ditentukan dalam dataset adalah "damage grade", yang mengklasifikasikan tingkat kerusakan pada bangunan dari grade 1 yang menunjukkan

kerusakan paling ringan, hingga grade 5 untuk kerusakan paling parah. Dataset yang bersangkutan terdiri dari 31 atribut yang mendeskripsikan berbagai aspek struktural dan geografis dari 762,106 bangunan yang bisa dilihat pada Tabel 1. Data detailnya diperoleh dari National Planning Commission (NPC) Nepal melalui portal mereka <https://eq2015.npc.gov.np/#/>. ini membutuhkan penataan data secara menyeluruh dan teliti ke dalam suatu bentuk yang sesuai untuk diproses oleh model Deep Neural Network., dengan penekanan khusus pada keakuratan dan kelengkapan data untuk memastikan hasil analisis yang dapat diandalkan.

Tabel 2. Dataset "Earthquake Damage to Buildings in Nepal"

No	Atribut	Tipe Data	Deskripsi
1	building_id	int64	ID setiap bangunan
2	district_id	int64	ID distrik bangunan
3	vdcmun_id	int64	ID municipal
4	ward_id	int64	ID ward
5	count_floors_pre_eq	int64	Jumlah lantai sebelum gempa
6	count_floors_post_eq	int64	Jumlah lantai setelah gempa
7	age_building	int64	Usia bangunan
8	plinth_area_sq_ft	int64	Luas bangunan
9	height_ft_pre_eq	int64	Tinggi bangunan sebelum gempa
10	height_ft_post_eq	int64	Tinggi bangunan setelah gempa
11	land_surface_condition	object	Kondisi permukaan tanah
12	foundation_type	object	Tipe pondasi
13	roof_type	object	Tipe atap
14	ground_floor_type	object	Tipe lantai dasar
15	other_floor_type	object	Tipe lantai lainnya
16	position	object	Posisi bangunan
17	plan_configuration	object	Konfigurasi rencana
18	has_superstructure_adobe_mud	int64	Tipe Bahan Bangunan
19	has_superstructure_mud_mortar_stone	int64	Tipe Bahan Bangunan
20	has_superstructure_stone_flag	int64	Tipe Bahan Bangunan
21	has_superstructure_cement_mortar_stone	int64	Tipe Bahan Bangunan
22	has_superstructure_mud_mortar_brick	int64	Tipe Bahan Bangunan
23	has_superstructure_cement_mortar_brick	int64	Tipe Bahan Bangunan
24	has_superstructure_timber	int64	Tipe Bahan Bangunan
25	has_superstructure_bamboo	int64	Tipe Bahan Bangunan
26	has_superstructure_rc_non_engineered	int64	Tipe Bahan Bangunan
27	has_superstructure_rc_engineered	int64	Tipe Bahan Bangunan
28	has_superstructure_other	int64	Tipe Bahan Bangunan
29	condition_post_eq	object	Kondisi setelah gempa
30	damage_grade	object	Tingkat kerusakan
31	technical_solution_proposed	object	Solusi

4.2 Data Eksplorasi

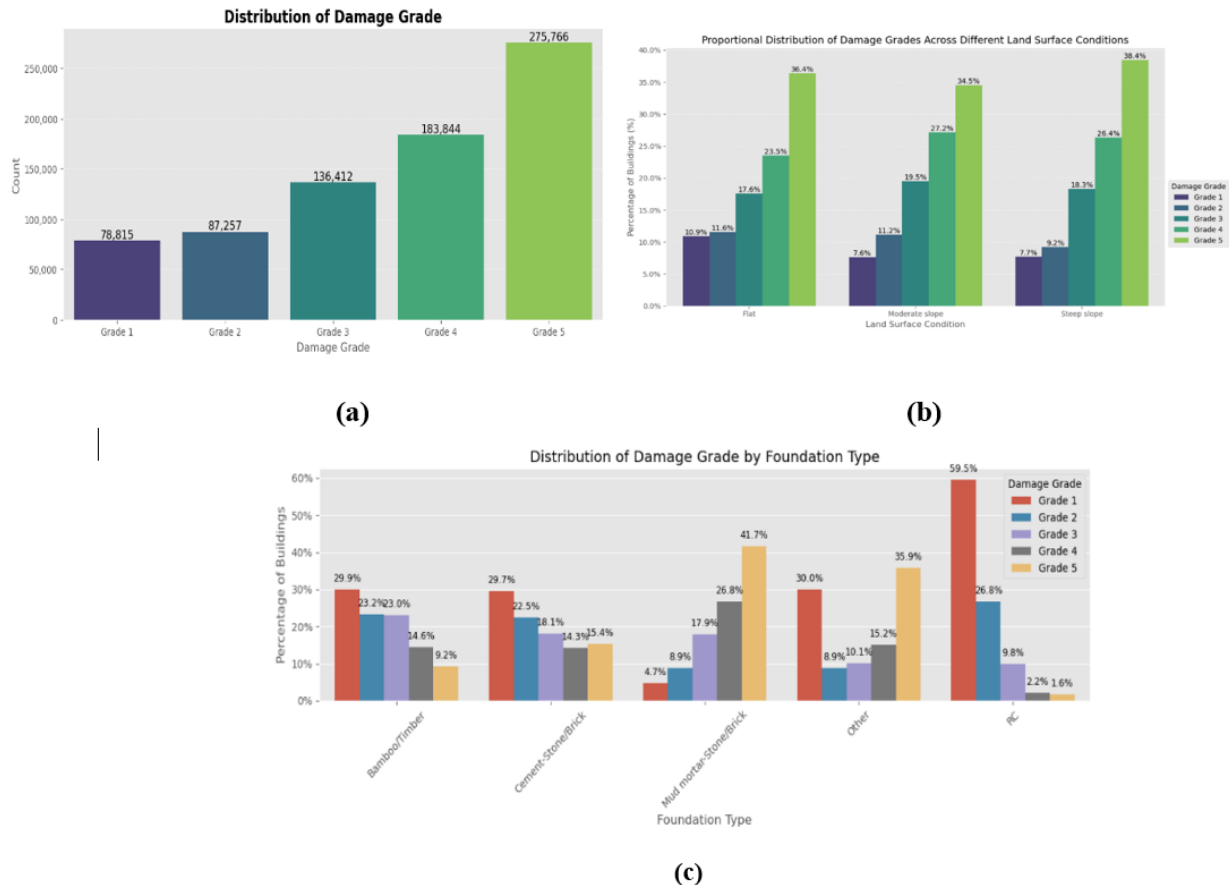
Dalam fase Eksplorasi Data Analys (EDA) penelitian ini, kami melakukan analisis mendalam terhadap data yang diperoleh dari portal National Planning Commission (NPC) Nepal. Proses EDA

melibatkan pemeriksaan statistik deskriptif untuk memahami distribusi dan rentang dari 31 atribut yang mencakup data struktural dan geografis dari 762,106 bangunan. Kami juga mengeksplorasi hubungan antara variabel-variabel tersebut dengan



variabel target, yaitu "damage grade", yang mengklasifikasikan tingkat kerusakan bangunan. Visualisasi data seperti histogram, box plots, dan scatter plots digunakan untuk mendeteksi pola, tren, dan anomali yang tidak akan langsung terlihat hanya dengan mengamati angka-angka mentah, membantu kami memperoleh wawasan awal yang akan mengarahkan pemodelan DNN yang lebih

lanjut. Maka dari itu, EDA merupakan langkah penting dalam proses analisis data yang mempersiapkan landasan bagi pembangunan model pembelajaran mesin dan deep learning. Berikut beberapa Exploratory Data Analysis (EDA) yang dilakukan pada kumpulan data kerusakan bangunan.



Gambar 3. Exploratory Data Analysis (a) Distribusi "damage grade"; (b) Analisis presentase tingkat kerusakan bangunan berdasarkan permukaan tanah; (c) Analisis kerusakan bangunan berdasarkan tipe pondasi

- Pada Gambar 3(a) peneliti menganalisis distribusi dari variabel target, kami mengamati bahwa frekuensi munculnya setiap kategori kerusakan bertambah seiring dengan tingkatan klasifikasinya. Dengan kata lain, kategori kerusakan Grade 5 adalah yang paling sering terjadi dalam dataset dengan jumlah 275.766 kerusakan, sementara Grade 1 merupakan yang paling sedikit dengan jumlah 78.815. Mengingat ini adalah permasalahan
- klasifikasi, kami mengidentifikasi adanya ketidakseimbangan dalam data.
- Grafik pada Gambar 3(b) menggambarkan bahwa kerusakan bangunan paling berat (Grade 5) merupakan yang paling dominan di setiap kondisi permukaan tanah, dengan prevalensi tertinggi di tanah berlereng curam (38.4%). Sebaliknya, kerusakan teringan (Grade 1) adalah yang paling jarang, terutama di lereng curam (7.7%). Data ini menyarankan adanya hubungan

antara kecuraman lereng dengan tingkat kerusakan yang lebih parah akibat gempa.

- Dalam analisis Gambar 3(c), ditemukan distribusi tingkat kerusakan bangunan berdasarkan jenis pondasi. Dari lima kategori yang ditampilkan, pondasi jenis Mortar-Stone/Brick merupakan yang paling umum, dengan proporsi kerusakan terendah yang paling tinggi (29.7% untuk Grade 1) dan menurun seiring meningkatnya tingkat kerusakan. Pondasi Bamboo/Timber mengikuti tren yang serupa, dengan kerusakan Grade 1 yang tinggi (29.9%) dan menurun untuk kerusakan yang lebih parah. Sebaliknya, pondasi Mud Mortar/Stone mengalami tingkat kerusakan paling berat (Grade 5) dengan proporsi yang tinggi (41.7%). Jenis pondasi lainnya dan RC menunjukkan variasi yang lebih kecil dalam distribusi kerusakan, kemungkinan karena jumlah sampel yang lebih kecil. Secara keseluruhan, jenis pondasi tampaknya merupakan indikator yang kuat dari tingkat kerusakan yang dialami bangunan, dengan pondasi Mortar-Stone/Brick dan Bamboo/Timber cenderung mengalami kerusakan lebih ringan, sedangkan Mud Mortar/Stone lebih sering mengalami kerusakan berat.

4.3 Preprocessing

Dalam penelitian ini, kami menerapkan serangkaian langkah preprocessing data yang detail dan sistematis untuk memahami distribusi kerusakan pada bangunan pasca gempa berdasarkan jenis fondasi yang digunakan. Proses ini diawali dengan pengelompokan data menggunakan metode "groupby" berdasarkan dua atribut utama: 'foundation_type' dan 'damage_grade'. Langkah ini bertujuan untuk mengidentifikasi pola distribusi kerusakan terhadap berbagai jenis fondasi bangunan. Selanjutnya, kami menghitung jumlah bangunan dalam setiap kelompok kombinasi menggunakan fungsi size(), memberikagambaran numerik yang jelas mengenai frekuensi distribusi kerusakan pada setiap tipe fondasi. Dalam penelitian ini, data awalnya dibagi menjadi dua bagian: 80% untuk pelatihan dan 20% untuk pengujian, dengan distribusi kelas yang seimbang di kedua bagian

untuk mempertahankan proporsi variabel target. Set pelatihan selanjutnya dipisahkan menjadi set pelatihan dan validasi dengan rasio 9:1 untuk memperhalus tuning model. Untuk memenuhi prasyarat model Deep Neural Network, kolom numerik distandarisasi menggunakan StandardScaler, yang menghasilkan skor z dengan rata-rata nol dan varians satu, sementara kolom kategorikal diubah menjadi bentuk numerik melalui proses OneHotEncoding. Transformasi ini memastikan bahwa setiap atribut berkontribusi secara setara terhadap kemampuan prediksi model tanpa didominasi oleh skala asli variabel.

4.4 Klasifikasi Menggunakan Deep Neural Network

Dalam penelitian ini, kami mengembangkan sebuah model Deep Neural Network (DNN) menggunakan Keras, dirancang dengan tiga lapisan padat (Dense layers) untuk klasifikasi data. Model ini dibangun secara linear menggunakan kelas Sequential. Dimulai dengan lapisan padat pertama yang berisi 64 unit dengan aktivasi ReLU dan 72,448 parameter, menentukan bentuk input sesuai dengan fitur data yang telah ditransformasi. Lapisan kedua memiliki 64 unit dan 4,160 parameter. Lapisan ketiga dan terakhir adalah lapisan output dengan 5 unit menggunakan aktivasi softmax untuk klasifikasi multikelas, dan memiliki 325 parameter. Totalnya, model ini memiliki 76,933 parameter yang semuanya dapat dilatih, menunjukkan arsitektur yang dirancang secara efisien untuk tugas klasifikasi. Fungsi "summary()" dapat digunakan untuk menjelaskan secara detail struktur dari model ini, menyediakan informasi lengkap tentang total parameter serta arsitektur model, seperti yang ditampilkan pada Gambar 4

```
Model: "sequential"
-----
```

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 64)	72448
dense_1 (Dense)	(None, 64)	4160
dense_2 (Dense)	(None, 5)	325

```
-----
Total params: 76933 (300.52 KB)
Trainable params: 76933 (300.52 KB)
Non-trainable params: 0 (0.00 Byte)
```

Gambar 4. Aksitektur Model dan Parameter



Model ini di-*compile* dengan loss function 'categorical_crossentropy', dengan 'accuracy' sebagai metrik utama. Model dilatih sebanyak 20 *epoch* dengan *batch size* 32, menggunakan set data latih dan validasi yang telah ditransformasi dan di-encode. Optimizer yang digunakan meliputi 'RMSprop', 'Adam', 'SGD' (*Stochastic Gradient Descent*), dan 'Adagrad'. Kami juga menggunakan berbagai learning rate untuk setiap optimizer untuk mengamati bagaimana perubahan ini mempengaruhi proses pelatihan dan akurasi model. Learning rate yang digunakan ialah 0.001, 0.01, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9. Dengan menguji kombinasi optimizer dan learning rate yang berbeda, kami dapat menilai kinerja model kami dalam kondisi yang bervariasi dan menentukan konfigurasi yang optimal untuk tugas klasifikasi yang ditentukan. Setelah pelatihan,

model dievaluasi pada set data uji untuk mengukur akurasi dan loss.


4.5 Model Evaluasi

Model Evaluasi merupakan langkah penting dalam penelitian untuk mengukur keakuratan prediksi model pada data uji. Setelah pelatihan selesai, evaluasi dilakukan dengan menggunakan data uji (x_{test} dan y_{test}), menggabungkan metrik kerugian (loss) dan akurasi. Dengan memperhatikan x_{test} sebagai input dan y_{test} sebagai label, evaluasi ini memberikan gambaran komprehensif tentang kinerja model dalam konteks penelitian. Hasil evaluasi membantu menilai sejauh mana model dapat digunakan untuk klasifikasi, prediksi, atau pengambilan keputusan, menjadi dasar untuk peningkatan model.


Tabel 3. Hasil Pelatihan Model DNN

ADAM			RMSprop		
Learning Rate	Loss	Accuracy	Learning Rate	Loss	Accuracy
0,001	25,75%	90,50%	0,001	41,50%	87,80%
0,01	26,01%	90,47%	0,01	38,04%	88,76%
0,1	26,07%	90,45%	0,1	38,31%	89,03%
0,2	25,78%	90,47%	0,2	38,02%	89,01%
0,3	25,61%	90,52%	0,3	46,02%	85,17%
0,4	26,15%	90,38%	0,4	39,14%	89,00%
0,5	25,99%	90,46%	0,5	38,91%	88,92%
0,6	25,64%	90,50%	0,6	38,59%	88,83%
0,7	25,55%	90,50%	0,7	38,23%	88,75%
0,8	25,53%	90,53%	0,8	39,55%	88,51%
0,9	25,67%	90,50%	0,9	39,41%	88,83%
SGD			Adagrad		
Learning Rate	Loss	Accuracy	Learning Rate	Loss	Accuracy
0,001	26,41%	90,15%	0,001	31,39%	88,64%
0,01	26,60%	90,08%	0,01	31,24%	88,62%
0,1	26,22%	90,23%	0,1	31,53%	89%
0,2	27,71%	89,43%	0,2	31,47%	88,58%
0,3	26,56%	90,07%	0,3	31,24%	88,65%
0,4	26,36%	90,11%	0,4	31,29%	88,64%
0,5	26,42%	90,12%	0,5	31,36%	88,60%
0,6	26,36%	90,16%	0,6	31,35%	88,67%
0,7	26,93%	89,84%	0,7	31,23%	88,65%
0,8	26,59%	89,99%	0,8	31,36%	88,69%
0,9	26,48%	90,05%	0,9	31,12%	88,67%





Gambar 5. Visualisasi Perbandingan Hasil Nilai Akurasi Antara Adam, SGD, RMSprop, Adagrad



Gambar 6. Visualisasi Perbandingan Hasil Nilai Loss Antara Adam, SGD, RMSprop, Adagrad

Pada Tabel 3 yang divisualisasikan pada Gambar 5 dan Gambar 6, optimizer ADAM unggul dengan mencapai akurasi puncak sekitar 90,50% pada learning rate terendah 0,001. Optimizer RMSprop juga menunjukkan hasil yang kompetitif dengan akurasi tertinggi mendekati 90,47% pada learning rate yang sama. Sementara itu, optimizer SGD dan Adagrad menampilkan akurasi lebih rendah dengan kisaran terbaik mereka sekitar 89,03% dan 88,78% secara berturut-turut pada berbagai learning rate. Ini menunjukkan bahwa ADAM secara konsisten memberikan performa

terbaik dalam hal akurasi dibandingkan dengan optimizer lain dalam set penelitian ini.

Pada Gambar 6 menunjukkan optimizer ADAM memberikan nilai loss paling kecil, turun hingga 25,76% pada learning rate 0,001. Hal ini menunjukkan nilai efisiensinya dalam meminimalkan kesalahan prediksi. Sedangkan optimizer RMSprop mendekati nilai loss yang serupa, sedikit di atas ADAM pada learning rate yang sama. Di lain percobaan, SGD memiliki loss yang relatif lebih tinggi, dengan titik terendahnya sekitar 26,56%, sementara Adagrad menunjukkan

kinerja yang stabil di berbagai tingkat learning rate, dengan nilai *loss* terbaiknya sekitar 26,22 model dengan nilai *loss* paling rendah.

Dari Tabel 3 terungkap bahwa faktor optimizer memiliki dampak yang signifikan terhadap performa model, sebagaimana ditunjukkan oleh nilai Sum of Squares (SS) yang relatif tinggi sebesar 0.00340645 dan nilai F yang sangat melebihi nilai kritis pada tingkat kepercayaan yang diinginkan, dengan p-value mencapai 1.23E-09, yang jauh lebih rendah dari ambang batas signifikansi umum 0.05. Ini menandakan bahwa perbedaan dalam penggunaan optimizer berkontribusi pada variabilitas yang signifikan dalam performa model. faktor learning rate tidak menunjukkan pengaruh yang signifikan, dengan nilai p yang sebesar 0.56098964, mengindikasikan bahwa perubahan learning rate tidak menyebabkan perbedaan performa model yang signifikan secara statistik.

5 Kesimpulan

Berdasarkan evaluasi terhadap hasil pengujian yang dilakukan dalam penelitian ini, kita dapat menyimpulkan bahwa:

- Penelitian berhasil mengembangkan model DNN yang menargetkan variabel "damage grade" dengan lima tingkat kerusakan menggunakan dataset yang melibatkan 762,106 bangunan dengan 31 atribut beragam. Model ini mencapai akurasi tertinggi sebesar 90,50% dengan menggunakan optimizer ADAM dan learning rate 0,001, menunjukkan bahwa pemilihan optimizer yang tepat sangat krusial dalam mencapai efisiensi dan efektivitas model dalam mengklasifikasi tingkat kerusakan
- Salah satu tantangan utama dalam penelitian ini adalah waktu pelatihan yang lama untuk model DNN. Dengan 76,933 parameter, model memerlukan waktu yang signifikan untuk melatih dan mengoptimalkan dataset. Hal ini menjadi kendala khusus dalam lingkungan dengan sumber daya komputasi terbatas.
- Penelitian ini mengidentifikasi kebutuhan untuk mengoptimalkan model guna meningkatkan efisiensi pelatihan. Meskipun model berhasil menunjukkan akurasi yang tinggi, tetapi diperlukan upaya lebih lanjut

untuk mengurangi waktu pelatihan dan sumber daya komputasi yang dibutuhkan tanpa mengurangi akurasi prediksi, sehingga memungkinkan penerapan yang lebih luas dan efektif, terutama dalam situasi dengan keterbatasan hardware.

References

- Caelen, O. (2017). *A Bayesian interpretation of the confusion matrix*. September, 429–450. <https://doi.org/10.1007/s10472-017-9564-8>
- Chaurasia, K., Kanse, S., Yewale, A., Singh, V. K., Sharma, B., & Dattu, B. R. (2019). Predicting Damage to Buildings Caused by Earthquakes Using Machine Learning Techniques. *Proceedings of the 2019 IEEE 9th International Conference on Advanced Computing, IACC 2019*, December, 81–86. <https://doi.org/10.1109/IACC48062.2019.8971453>
- Da Poian, V., Theiling, B., Clough, L., McKinney, B., Major, J., Chen, J., & Hörst, S. (2023). Exploratory data analysis (EDA) machine learning approaches for ocean world analog mass spectrometry. *Frontiers in Astronomy and Space Sciences*, 10(May), 1–17. <https://doi.org/10.3389/fspas.2023.1134141>
- Das, L., Sivaram, A., & Venkatasubramanian, V. (2020). Hidden Representations in Deep Neural Networks: Part 2 . Regression Problems. *Computers and Chemical Engineering*, 106895. <https://doi.org/10.1016/j.compchemeng.2020.106895>
- Firmansyah, Rusmal, Shidiq, G. F. (2023). *Peningkatan Deep Neural Network pada Kasus Prediksi Diabetes Menggunakan PSO*. 22(4), 882–892.
- Ghenescu, V., Barnoviciu, E., Carata, S. V., Ghenescu, M., Mihaescu, R., & Chindea, M. (2018). Object recognition on long range thermal image using state of the art dnn. *11th ROLCG Conference on Grid, Cloud and High-Performance Computing in Science - Proceedings*, 1–4. <https://doi.org/10.1109/ROLCG.2018.8572026>
- Ghimire, S., Guéguen, P., Giffard-Roisin, S., & Schorlemmer, D. (2022). Testing machine learning models for seismic damage prediction at a regional scale using building-damage dataset compiled after the 2015 Gorkha Nepal earthquake. *Earthquake Spectra*, 38(4), 2970–2993. <https://doi.org/10.1177/87552930221106495>
- Hu, H., Lei, T., Hu, J., Zhang, S., & Kavan, P. (2018). Disaster-mitigating and general innovative responses to climate disasters: Evidence from modern and historical China. *International Journal of Disaster Risk Reduction*, 28(August



- 2017), 664–673. <https://doi.org/10.1016/j.ijdr.2018.01.022>
- Isnaeni, A. Y., & Prasetyo, S. Y. J. (2022). Klasifikasi Wilayah Potensi Risiko Kerusakan Lahan Akibat Bencana Tsunami Menggunakan Machine Learning. *Jurnal Teknik Informatika Dan Sistem Informasi*, 8(1), 33–42. <https://doi.org/10.28932/jutisi.v8i1.4056>
- Maryani, E. (2021). The role of education and geography on disaster preparedness. *IOP Conference Series: Earth and Environmental Science*, 683(1). <https://doi.org/10.1088/1755-1315/683/1/012043>
- Matchev, K. T., Matcheva, K., & Roman, A. (2022). Unsupervised Machine Learning for Exploratory Data Analysis of Exoplanet Transmission Spectra. *Planetary Science Journal*, 3(9), 205. <https://doi.org/10.3847/PSJ/ac880b>
- Maulana, F. F., & Rochmawati, N. (2020). Klasifikasi Citra Buah Menggunakan Convolutional Neural Network. *Journal of Informatics and Computer Science (JINACS)*, 1(02), 104–108. <https://doi.org/10.26740/jinacs.v1n02.p104-108>
- Mittal, V. (2020). *Exploring The Dimension of DNN Techniques For Text Categorization Using NLP*.
- Randles, B. M., Pasquetto, I. V., Golshan, M. S., & Borgman, C. L. (2017). Using the Jupyter Notebook as a Tool for Open Science: An Empirical Study. *Proceedings of the ACM/IEEE Joint Conference on Digital Libraries*, 17–18. <https://doi.org/10.1109/JCDL.2017.7991618>
- Retson, T. A., Besser, A. H., Sall, S., Golden, D., & Hsiao, A. (2019). *Machine Learning and Deep Neural Networks in Thoracic and Cardiovascular Imaging*. 34(3), 192–201. <https://doi.org/10.1097/RTI.0000000000000385>
- Shah, D., & Campbell, W. (2018). A Comparative Study of LSTM and DNN for Stock Market Forecasting. *2018 IEEE International Conference on Big Data (Big Data)*, 4148–4155. <https://doi.org/10.1109/BigData.2018.8622462>
- Su, Y., Rong, G., Ma, Y., Chi, J., & Liu, X. (2022). *Hazard Assessment of Earthquake Disaster Chains Based on Deep Learning — A Case Study of Mao County, Sichuan Province*. 9(May), 1–10. <https://doi.org/10.3389/feart.2021.683903>
- Sun, W., Cai, Z., Li, Y., Liu, F., Fang, S., & Wang, G. (2018). *Review Article Data Processing and Text Mining Technologies on Electronic Medical Records : A Review. 2018*.
- Triastari, I., Dwiningrum, S. I. A., & Rahmia, S. H. (2021). Developing Disaster Mitigation Education with Local Wisdom: Exemplified in Indonesia Schools. *IOP Conference Series: Earth and Environmental Science*, 884(1). <https://doi.org/10.1088/1755-1315/884/1/012004>

