

PEMODELAN ARTIFICIAL NEURAL NETWORK (ANN) UNTUK IDENTIFIKASI BANGUNAN DAERAH RAWAN LONGSOR

Sely Novita Sari ¹⁾, Bagus Gilang Pratama ²⁾, Rizqi Prastowo ³⁾

¹⁾ Program Studi Teknik Sipil, Institut Teknologi Nasional Yogyakarta

²⁾ Program Studi Teknik Elektro, Institut Teknologi Nasional Yogyakarta

³⁾ Program Studi Teknik Pertambangan, Institut Teknologi Nasional Yogyakarta

Email : sely.novita@itny.ac.id ¹⁾, bagusgilangp@itny.ac.id ²⁾, rizqi@itny.ac.id ³⁾

ABSTRAK

Identifikasi bangunan daerah rawan longsor adalah suatu hal yang penting dalam mitigasi bencana alam. Longsor dapat terjadi di mana saja dan kapan saja, dan dapat menyebabkan kerugian yang besar baik dari segi manusia maupun materiil. Oleh karena itu, penting untuk mengidentifikasi bangunan yang berada di daerah rawan longsor agar dapat mengambil tindakan pencegahan yang tepat. Metode yang dapat digunakan untuk identifikasi bangunan di daerah rawan longsor adalah artificial neural network (ANN). ANN adalah suatu model komputasi yang terinspirasi dari sistem saraf biologis yang terdiri dari sejumlah unit pemrosesan sederhana yang disebut neuron. ANN dapat belajar dari data dan menyesuaikan bobot koneksi antar neuron untuk menghasilkan keluaran yang diinginkan. Terdapat 169 data sample yang didapatkan dari hasil survei lapangan, 85 data dilakukan untuk pelatihan, 34 data dilakukan untuk uji validasi dan 50 data set dilakukan untuk pengujian untuk memprediksi hasil. Berdasarkan analisis data klasifikasi dinding sederhana di Kecamatan Kalirejo, Kecamatan Kokap, Kabupaten Kulon Progo, Yogyakarta, menggunakan Artificial Neural Network (ANN), presentase prediksi setiap data dari pemodelan ANN menunjukkan bahwa indikator Bangunan Tidak Aman mencapai 100%, dengan 89% prediksi Bangunan Aman, dan 82,7% prediksi Bangunan Aman berdasarkan History Accuracy. Hasil tersebut diukur dengan merujuk pada kurva model validasi yang semakin meningkat dan stabil, mencapai nilai akurasi rata-rata di atas 80%, yakni sebesar 88%.

Kata Kunci : Identifikasi, Longsor, Prediksi, ANN.

ABSTRACT

Identification of buildings in landslide-prone areas is important in mitigating natural disasters. Landslides can occur anywhere and at any time, and can cause large losses both in terms of humans and material (Fadli et al, 2023). Therefore, it is important to identify buildings that are located in landslide-prone areas so that appropriate preventive measures can be taken. The method that can be used to identify buildings in landslide-prone areas is artificial neural network (ANN). ANN is a computational model inspired by the biological nervous system which consists of a number of simple processing units called neurons. ANNs can learn from data and adjust the connection weights between neurons to produce the desired output. There were 169 data samples obtained from field survey results, 85 data were used for training, 34 data were used for validation tests and 50 data sets were used for testing to predict results. Based on analysis of simple wall classification data in Kalirejo District, Kokap District, Kulon Progo Regency, Yogyakarta, using Artificial Neural Network (ANN), the percentage of predictions for each data from ANN modeling shows that the Unsafe Building indicator reaches 100%, with 89% of Safe Building predictions, and 82.7% Safe Building prediction based on Historical Accuracy. These results are measured by referring to the validation model curve which is increasingly increasing and stable, reaching an average accuracy value above 80%, namely 88%.

Keywords: Identification, Avalanche, Prediction, ANN

1. PENDAHULUAN

Musim hujan di Indonesia telah mengakibatkan bencana-bencana di daerah rawan. Dalam konteks ini, banjir dan tanah longsor menjadi ancaman utama. Salah satu wilayah yang rentan terhadap longsor adalah kecamatan Samigaluh di Yogyakarta, yang merupakan salah satu dari 14 lokasi rawan longsor di Kulon Progo. Tanah longsor bukan hanya merupakan ancaman alam, tetapi juga dapat mengubah lanskap dan menyebabkan kerugian ekonomi yang besar, memerlukan tindakan mitigasi dan pengurangan risiko (Trianda dkk, 2018).

Mitigasi terhadap longsor dapat melibatkan penggunaan metode geofisika untuk memahami struktur bawah permukaan di daerah rawan longsor (Prastowo dkk, 2018). Pentingnya identifikasi bangunan di daerah rawan longsor menjadi jelas dalam upaya mitigasi bencana alam. Longsor dapat terjadi di mana saja dan kapan saja, berpotensi menyebabkan kerugian manusia dan materiil yang signifikan (fadli dkk, 2023). Oleh karena itu, pengidentifikasian bangunan di daerah rawan longsor menjadi langkah penting untuk mengambil tindakan pencegahan yang tepat.

Gempa bumi dipengaruhi oleh dua faktor utama, yaitu faktor pengendali dan faktor pemicu. Faktor pengendali mencakup kondisi yang membuat lereng atau tebing siap bergerak, seperti bentuk lahan, jenis batuan/tanah, struktur geologi, kondisi hidrologi, dan penggunaan lahan (Kristanti, 2021). Sebaliknya, faktor pemicu memicu perubahan dari keadaan rentan menjadi kritis yang berujung pada gempa, seperti curah hujan, getaran seismik, dan kegiatan manusia yang mengubah beban lereng atau tebing.

Contoh faktor pengendali meliputi topografi, jenis batuan/tanah, struktur geologi, hidrologi, dan penggunaan lahan, seperti lereng curam, jenis batuan rentan, dan struktur geologi tidak stabil. Pembangunan infrastruktur tanpa mempertimbangkan faktor geologi juga dapat meningkatkan risiko gempa. Sementara itu, faktor pemicu melibatkan curah hujan tinggi, getaran seismik, dan aktivitas manusia seperti

penambangan atau Pembangunan Trianda dkk, 2018).

Kedua faktor ini saling terkait dan memainkan peran penting dalam terjadinya gempa bumi. Faktor pengendali menyebabkan kondisi yang rentan terhadap pergerakan tanah, sementara faktor pemicu memulai perubahan yang dapat menghasilkan gempa (Ramadhan, 2021). Kerentanan bangunan secara umum mencakup faktor-faktor yang dapat menyebabkan kerusakan atau kegagalan fungsi selama bencana. Antisipasi kinerja bangunan adalah kemampuan struktur untuk menghindari keruntuhan selama bencana, mendorong upaya mengurangi risiko dengan membangun gedung tahan gempa di daerah rentan gempa (Firdausa, 2019). Konsep bangunan tahan gempa menekankan bahwa pada gempa kecil, bagian non-struktural dan struktural bangunan tidak boleh rusak. Pada gempa sedang, bagian non-struktural dapat merusak, namun bagian struktural harus tetap utuh (Sari, 2020).

Upaya mengurangi risiko gempa termasuk analisis kerentanan bangunan untuk meminimalkan risiko kematian dan kerusakan. Kategori utama penyebab kerentanan, seperti lokasi bangunan, umur dan bentuk bangunan, serta struktur bangunan, memiliki dampak yang signifikan. Faktor-faktor ini mencakup kondisi medan, geologi, daya dukung tanah, pembebanan struktur, keteraturan bangunan, ukuran pori, sistem struktur, prinsip struktural, dan kondisi bangunan, semuanya memainkan peran penting dalam tingkat kerentanan terhadap gempa (Sari, 2020). Keberhasilan dalam mengurangi risiko kematian dan kerusakan akibat gempa bumi membutuhkan perencanaan dan konstruksi bangunan yang mempertimbangkan semua faktor ini. Selain itu, pemeliharaan yang baik dan pemantauan kondisi bangunan sepanjang waktu juga merupakan langkah penting dalam menjaga kinerja struktural dan mengurangi kerentanan terhadap gempa (Firdausa, 2019).

Meskipun identifikasi bangunan biasanya terjadi saat terjadi gempa bumi, penting untuk diingat bahwa bencana di Indonesia tidak hanya terbatas pada gempa bumi. Bencana lain

juga dapat menyebabkan kerusakan pada bangunan dengan dampak signifikan terhadap korban. Bencana tanah longsor khususnya, selain menimbulkan kerusakan bangunan, juga menimbulkan korban jiwa yang signifikan di Indonesia, terutama di wilayah Kulonprogo. Proses identifikasi daerah rawan longsor, meskipun luas, belum sepenuhnya memahami bangunan yang berada di atas tanah longsor (Saedudin, dkk, 2022).

Metode yang dapat digunakan untuk mengidentifikasi bangunan di daerah rawan longsor adalah *Artificial Neural Network* (ANN), sebuah model komputasi terinspirasi dari sistem saraf biologis yang dapat belajar dari data dan menghasilkan keluaran yang diinginkan dengan menyesuaikan bobot koneksi antar neuron (Panjaitan, 2021). ANN mampu mengenali pola, mengklasifikasikan data, dan memprediksi hasil. Penerapan ANN dalam identifikasi bangunan di daerah rawan longsor melibatkan pemrosesan citra satelit atau udara untuk menampilkan daerah rawan longsor dan bangunan di dalamnya. ANN dapat mengenali ciri-ciri bangunan seperti bentuk, ukuran, warna, tekstur, dan lokasi, menghasilkan peta sebaran dan karakteristik bangunan yang berguna untuk analisis dan perencanaan mitigasi bencana.

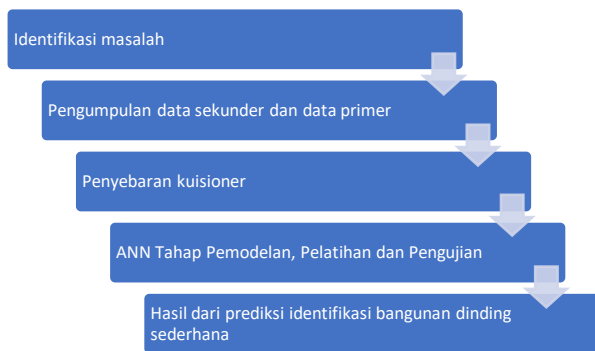
Tiga penelitian dilakukan di berbagai wilayah di Indonesia dengan fokus pada bencana alam dan potensi kerusakan bangunan. Pertama, di Kalirejo, bencana tanah longsor menjadi ancaman utama. Penelitian pertama mencoba menganalisis pengaruh retakan tanah terhadap kondisi bangunan sederhana dengan melakukan survei lapangan. Hasilnya menunjukkan bahwa 54.17% bangunan dianggap aman, 35.42% tidak aman, dan 10.42% harus direlokasi atau diperbaiki sesuai dengan persyaratan minimum bangunan sederhana. Di desa yang sama, penelitian kedua mengevaluasi pemahaman pemilik bangunan tentang perencanaan bangunan tahan gempa menggunakan aplikasi Asesmen Cepat Bangunan (ACEBS) dari InaRISK. Kedua penelitian di Kalirejo menyoroti pentingnya penanganan potensi bencana alam dalam perencanaan dan pemeliharaan bangunan. Sementara itu, penelitian ketiga di

wilayah Medan Utara berfokus pada pemetaan zona terancam banjir rob dengan mempertimbangkan faktor-faktor seperti curah hujan, elevasi, dan jarak ke muara. Analisis menggunakan metode GIS, regresi logistik, dan ANN menunjukkan faktor-faktor tertentu yang mempengaruhi kerawanan terhadap banjir rob. Penelitian ini memberikan informasi dasar bagi para pemangku kepentingan dalam upaya penanganan bencana banjir rob di wilayah tersebut.

Secara keseluruhan, penggunaan teknik *Artificial Neural Network* (ANN) meningkatkan efektivitas dan ketepatan identifikasi bangunan di daerah rawan longsor. Dengan memanfaatkan data dan variabel yang relevan, upaya mitigasi bencana longsor dapat dilakukan lebih tepat sasaran, mengurangi risiko dan kerugian yang disebabkan oleh bencana alam tersebut.

2. METODE

Fungsi aktivasi berperan sebagai penentu keluaran neuron dalam *Artificial Neural Network* (ANN). Salah satu metode pelatihan ANN yang umum digunakan adalah pembelajaran terawasi, di mana selama sesi pelatihan, input dan target yang besar digunakan untuk mengajarkan jaringan hingga mencapai bobot yang diinginkan. Dalam proses pelatihan, masukan disampaikan ke jaringan, kemudian jaringan memprosesnya dan mengeluarkan hasil. Kesalahan antara output jaringan dan target dihitung, dan jaringan memodifikasi bobotnya sesuai dengan kesalahan tersebut. Dalam penelitian identifikasi bangunan di daerah rawan longsor menggunakan ANN, tahapannya melibatkan pengumpulan data yang mencakup data sekunder, seperti formulir evaluasi bangunan sederhana dan peta gerakan tanah di daerah Kalirejo, Kulonprogo, serta data primer yang diperoleh melalui identifikasi bangunan sederhana tipikal tembokan, termasuk parameter input seperti gambar rencana, denah, pondasi, sloof, kolom, dinding, ring balk, detail tulangan, sambungan, gunung-gunung, dan kuda-kuda.



Gambar 1. Alur Pelaksanaan Penelitian

Data dan Sample Data

Data yang digunakan dalam penelitian ini berasal dari evaluasi bangunan sederhana, khususnya yang terkait dengan struktur tembokan yang tipikal. Sumber data ini diperoleh melalui proses evaluasi menggunakan metode *Rapid Visual Screening* (RVS), suatu pendekatan penilaian visual yang dilakukan secara cepat untuk mengamati kondisi bangunan, terutama pada aspek struktural. Evaluasi tersebut memfokuskan perhatian pada kondisi fisik dan struktural bangunan sederhana, dengan penekanan khusus pada karakteristik yang lazim ditemui pada tembokan tipikal. Oleh karena itu, data penelitian ini mencakup informasi yang relevan untuk memahami dan mengklasifikasikan bangunan sederhana berdasarkan evaluasi RVS terhadap struktur tembokan yang tipikal.

Dari total 169 bangunan yang dinilai dari tiga dusun, yaitu Dusun Sangon, Dusun Kalibuko, dan Dusun Kalirejo di Kabupaten Kulon Progo. Dataset ini terdiri dari 169 sampel dan dibagi menjadi dua set data utama: set data pelatihan dan set data pengujian. Set data pelatihan mencakup 50% dari total sampel, sedangkan set data validasi terdiri dari 20% dari sampel tersebut. Sisa 30% dari sampel digunakan untuk pengujian setelah model dilatih, dan sampel ini diambil dari penilaian bangunan yang telah dilakukan.

Penting untuk dicatat bahwa set pelatihan dapat disesuaikan dengan menambahkan data baru jika kinerja model tidak mencapai tingkat hasil yang diharapkan. Proses ini melibatkan penambahan data ke dalam set pelatihan dan pengulangan pelatihan jaringan saraf sesuai

kebutuhan, dengan tujuan mencapai hasil yang optimal. Oleh karena itu, fleksibilitas untuk menyesuaikan set pelatihan dapat membantu meningkatkan kemampuan model dalam mengatasi berbagai situasi atau kondisi yang mungkin muncul selama pengujian dan implementasi model (Pradana dkk, 2022).

Artificial Neural Network Architectures dan Proses Pelatihan (*Training Processes*)

Jaringan saraf tiruan, secara umum, terdiri dari tiga bagian utama yang disebut sebagai lapisan. Pertama adalah Lapisan Masukan, yang berfungsi untuk menerima informasi, data, sinyal, atau pengukuran dari lingkungan eksternal. Input ini, biasanya berupa sampel atau pola, dinormalisasi untuk memperoleh presisi numerik yang optimal dalam operasi matematis yang dilakukan oleh jaringan.

Kedua, terdapat Lapisan Tersembunyi, Intermediet, atau Tak Terlihat, yang terdiri dari neuron yang bertugas mengekstrak pola terkait dengan proses atau sistem yang dianalisis. Lapisan ini melibatkan sebagian besar pemrosesan internal jaringan. Terakhir, ada Lapisan Keluaran yang juga terdiri dari neuron dan bertanggung jawab untuk menghasilkan output akhir jaringan, hasil dari pemrosesan yang telah dilakukan oleh neuron di lapisan sebelumnya.

Dalam arsitektur utama jaringan saraf tiruan, ada berbagai struktur yang memperhitungkan disposisi neuron, koneksi antar neuron, dan pembentukan lapisan-lapisan. Struktur ini dapat dibagi menjadi empat kategori utama, yaitu: (i) jaringan feedforward satu lapis, (ii) jaringan feedforward banyak lapis, (iii) jaringan rekuren, dan (iv) jaringan mesh. Setiap kategori memiliki karakteristik dan kegunaannya sendiri dalam konteks penggunaan jaringan saraf tiruan.

Proses Pelatihan dan Sifat Pembelajaran

Jaringan saraf tiruan (ANN) memiliki kemampuan untuk belajar dari penyajian sampel, mencerminkan perilaku sistem, dan menghasilkan solusi umum setelah memahami hubungan antara masukan dan keluaran. Proses pelatihan ANN melibatkan pengaturan bobot sinapsis dan ambang batas neuron untuk

mencapai solusi umum dari keluaran. Data perilaku sistem dibagi menjadi subset pelatihan dan subset uji, yang digunakan untuk melatih dan menguji model ANN. Epoch pelatihan merujuk pada satu iterasi penuh melatih jaringan dengan seluruh subset pelatihan.

Dalam model Artificial Neural Network (ANN), sinyal masukan (x_1, x_2, \dots, x_n) mencerminkan nilai-nilai dari lingkungan eksternal dan sering dinormalisasi untuk meningkatkan efisiensi komputasional. Bobot sinapsis (w_1, w_2, \dots, w_n) memberikan nilai bobot pada setiap variabel masukan untuk mengukur relevansinya terhadap fungsi neuron. Agregator linear (R) mengumpulkan sinyal masukan yang diberi bobot oleh sinapsis-sinapsis untuk menghasilkan tegangan aktivasi. Ambang aktivasi atau bias (h) digunakan untuk menentukan ambang agar hasil dari agregator linear menghasilkan nilai pemicu ke arah keluaran neuron. Potensi aktivasi (u) dihitung sebagai selisih antara agregator linear dan ambang aktivasi, dengan nilai positif menghasilkan potensi eksitatori, dan sebaliknya. Fungsi aktivasi (g) membatasi keluaran neuron dalam rentang nilai yang wajar. Sinyal keluaran (y) adalah nilai akhir yang dihasilkan oleh neuron, dapat menjadi masukan untuk neuron berikutnya dalam rangkaian.

$$u = \sum_{i=1}^n W_i \cdot X_i - \theta \dots (2.1)$$

$$y = g(u) \dots (2.2)$$

Langkah-langkah pra-pemrosesan data, seperti pembersihan, normalisasi, dan pemilihan fitur, diperlukan sebelum desain arsitektur ANN. Pelatihan model ANN melibatkan pembagian data, inisialisasi parameter, penggunaan algoritma pembelajaran, dan iterasi pelatihan hingga konvergensi. Setelah pelatihan, evaluasi dan validasi model dilakukan menggunakan metrik yang relevan dan subset uji terpisah.

Implementasi dan prediksi model ANN melibatkan penggunaan model yang telah dilatih untuk memprediksi identifikasi bangunan di daerah rawan longsor. Hasil prediksi dibandingkan dengan data observasi atau penilaian manual untuk mengevaluasi

akurasi dan kehandalan model. Analisis dan interpretasi hasil kemudian dilakukan untuk memahami faktor-faktor yang mempengaruhi kecenderungan longsor pada bangunan di wilayah tersebut.

Tahap akhir mencakup diskusi implikasi praktis hasil penelitian, termasuk interpretasi temuan dan diskusi tentang bagaimana hasil analisis dapat diterjemahkan ke dalam tindakan konkret untuk mengurangi risiko longsor pada bangunan di daerah tersebut. Dengan demikian, penelitian ini memberikan wawasan mendalam tentang faktor-faktor yang terlibat dalam kecenderungan longsor dan membantu dalam pengembangan strategi mitigasi risiko yang lebih efektif.

3. HASIL DAN PEMBAHASAN

Penelitian ini menerapkan suatu metode yang melibatkan evaluasi bangunan sederhana, terutama tembokan, di dusun Papak, desa Kalirejo, Kecamatan Kokap, Kabupaten Kulon Progo, Yogyakarta. Evaluasi dilakukan menggunakan Formulir Evaluasi Bangunan Sederhana (Tipikal Tembokan), yang kemudian menghasilkan klasifikasi bangunan sebagai aman, kurang aman, atau tidak aman. Untuk melakukan analisis tersebut, penelitian menggunakan Metode Artificial Neural Network (ANN) dengan tujuan mengklasifikasikan Bangunan Sederhana (Tipikal Tembokan) berdasarkan evaluasi bangunan melalui Rapid Visual Screening (RVS) menggunakan Formulir Evaluasi Bangunan Sederhana (Tipikal Tembokan). Penerapan Metode Artificial Neural Network (ANN) dalam penelitian ini bertujuan untuk memprediksi klasifikasi bangunan dengan tingkat akurasi yang optimal.

3.1 Indikator Penilaian Pada Komponen Struktur Bangunan

Dalam penelitian ini, parameter penilaian untuk komponen struktur bangunan menggunakan indikator yang berasal dari formulir evaluasi (Sari, 2020). Formulir tersebut ditujukan untuk mengevaluasi bangunan sederhana dengan tipe tembokan yang umum, dan mencakup sebelas indikator penilaian, seperti Gambar Rencana, Denah,

Pondasi, Sloof, Kolom, Dinding, Ring Balk, Tulangan Pertemuan Balok dan Kolom, Sambungan, Gunung-Gunung (Dari Beton), dan Kuda-Kuda.

Indikator-indikator ini berperan sebagai panduan dalam menilai kondisi dan kualitas struktur bangunan. Melalui proses evaluasi menggunakan Formulir Evaluasi Bangunan Sederhana (Tipikal Tembokan), klasifikasi bangunan dapat diperoleh berdasarkan tingkat keamanannya, yaitu aman, kurang aman, atau tidak aman. Data penilaian, yang merupakan bagian dari penelitian ini, disajikan dalam Tabel 1.

Tabel 1 Contoh Indikator Penilaian Pada Komponen Struktur Bangunan

PENILAIAN PADA KOMPONEN STRUKTUR BANGUNAN											Prosentase Kondisi Bangunan (%)	Kondisi Bangunan
A	B	C	D	E	F	G	H	I	J	K		
GAMBAR RENCANA	DENAH	PONDASI	SLOOF	KOLOM	DINDING	RING BALK	TULANGAN PERTEMUAN BALOK & KOLOM	SAMBUNGAN	GUNUNG (dari beton)	KUDA-KUDA		
0	0,5	0,7	1	1	1	0,9	1	0	0,833	0	72,5	Aman
1	1	0,7	0,75	0,7	0,833	0,7	1	0	0,583	0	62,5	Kurang Aman
0,5	0,5	0,7	1	1	0,667	1	1	0	0,75	0	72,5	Aman
0	0,5	1	1	0,9	1	1	1	1	0,667	0	73,75	Aman
0	1	0,6	0,833	0,5	0,167	0,5	1	0	0	0	41,5	Kurang Aman
1	0,5	0,7	0,833	0,8	0,5	0,8	1	0	0	0,4	58,75	Kurang Aman
0	0	0	0	0	0	0	0	0	0	0,5	5	Tidak Aman
0	1	0,6	0,833	0,8	0,833	0,8	1	0	0,667	0	77,5	Aman
1	1	0,8	0,833	0,7	0,833	0,8	1	0	0,833	0	77,5	Aman

Dengan merujuk pada indikator-indikator penilaian tersebut, penelitian ini dapat memberikan analisis yang komprehensif terhadap kondisi struktur bangunan sederhana. Hal ini memungkinkan pengklasifikasian bangunan berdasarkan kriteria keamanan yang telah ditetapkan. Rincian data yang terdapat dalam Tabel 1 dan Gambar 1 menjadi dasar untuk evaluasi dan pengembangan model klasifikasi menggunakan metode Artificial Neural Network (ANN).

3.2 Tahap Permodelan Metode Artificial Neural Network (ANN)

Langkah-langkah dalam proses pemodelan ini melibatkan perancangan arsitektur Artificial Neural Network (ANN), suatu tugas yang bersifat kompleks dan

dinamis. Tahap awal memerlukan penentuan identifikasi bangunan daerah rawan longsor yang relevan. Dalam proses ini, desain model ANN disesuaikan dengan jenis data yang tersedia dan tanggapan yang diinginkan oleh aplikasi ANN dalam konteks mitigasi bencana.


```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 169 entries, 0 to 168
Data columns (total 12 columns):
#   Column                Non-Null Count  Dtype
---  ---                ---
0   GambarRencana         169 non-null    float64
1   Denah                  169 non-null    float64
2   Pondasi                169 non-null    float64
3   Sloof                  169 non-null    float64
4   Kolom                  169 non-null    float64
5   Dinding                169 non-null    float64
6   RingBalk               169 non-null    float64
7   Pertemuan              169 non-null    float64
8   Sambungan              169 non-null    float64
9   Gunung                 169 non-null    float64
10  Kuda                   169 non-null    float64
11  KondisiBangunan       169 non-null    int64
dtypes: float64(11), int64(1)
memory usage: 16.0 KB
```

Gambar 2. Struktur Data Identifikasi Bangunan Daerah Rawan Longsor

Model Artificial Neural Network (ANN) yang dikembangkan telah dirancang dengan merinci komponen-komponen utamanya. Input layer terdiri dari lima elemen pemrosesan (neuron) yang sesuai dengan lima parameter input yang digunakan, sedangkan output layer terdiri dari satu elemen pemrosesan (neuron) sebagai tujuan utama. Setelah melalui beberapa eksperimen selama tahap pengujian, dipilih satu hidden layer dengan lima elemen proses untuk memperkaya kapabilitas model. Subfitur dari pola input kemudian diolah untuk meramalkan hasil jaringan atau nilai lapisan output yang terdiri dari delapan elemen.

Proses pelatihan model ANN dilakukan melalui 300 epoch, di mana setiap epoch mewakili satu iterasi melalui seluruh dataset yang tersedia. Evaluasi kinerja model menggunakan metrik akurasi, yang mengukur kemampuan model dalam memprediksi dengan benar pada seluruh dataset. Sebanyak 50% dari total dataset digunakan untuk melatih model, sementara 20% digunakan untuk validasi guna mengevaluasi kinerja dan mencegah overfitting. Sementara itu, 30%

dataset tersisa digunakan untuk pengujian setelah model dilatih. Algoritma optimizer yang diterapkan adalah Adam, algoritma yang umum digunakan dalam pembelajaran mesin. Tingkat pembelajaran (*learning rate*) sebesar 0.001 diterapkan untuk memastikan langkah pembelajaran yang relatif kecil, memperkuat konvergensi model secara stabil, meskipun mungkin memerlukan lebih banyak epoch untuk mencapai hasil optimal. Seluruh proses ini bertujuan untuk menghasilkan model ANN yang efisien dan andal dalam meramalkan hasil terkait mitigasi bencana dengan memanfaatkan faktor-faktor kunci yang telah ditetapkan.



Gambar 3. Arsitektur dan Parameter ANN

3.3 Evaluasi Data dan Pengenalan Faktor Desain Metode Artificial Neural Network (ANN)

Model ini disusun dengan menyesuaikan parameter guna mencapai hasil waktu komputasi, kesalahan model, dan kesalahan prediksi yang minimal (Isnaeni dkk, 2022). Parameter-parameter tersebut dianggap sebagai faktor kunci yang sangat penting dalam menentukan Identifikasi Bangunan Daerah Rawan Longsor yang diperlukan untuk menilai kondisi bangunan.

Walaupun variabel-variabel yang telah dipertimbangkan di atas memiliki peran penting, terdapat beberapa variabel krusial lain yang belum dimasukkan dalam pemodelan Artificial Neural Network (ANN) ini. Keputusan mengenai variabel input memiliki dampak signifikan terhadap akurasi prediksi jaringan saraf. Oleh karena itu, hasil prediksi dapat berbeda atau bahkan lebih optimal jika variabel input penting lainnya juga dipertimbangkan. Variabel-variabel yang diusulkan untuk penilaian melibatkan indikator Gambar Rencana, Denah, Pondasi, Sloof, Kolom, Dinding, Ring Balk, Tulangan

Pertemuan Balok dan Kolom, Sambungan, Gunung-Gunung (Dari Beton), dan Kuda-Kuda, yang menghasilkan penilaian aman, kurang aman, atau tidak aman.

Pada tahap pelatihan, perhatian difokuskan pada durasi iterasi, toleransi kesalahan yang berhasil dicapai, dan dampak jumlah neuron di lapisan tersembunyi terhadap tingkat akurasi. Data status kredit dari set pelatihan menjadi target yang dibandingkan dengan output di lapisan output, hasilnya dihasilkan melalui perhitungan feedforward neural network. Output ini memberikan nilai *Mean Squared Error* (MSE) secara keseluruhan, yang digunakan sebagai parameter oleh jaringan untuk menentukan apakah pembelajaran akan dilanjutkan atau dihentikan setelah mencapai jumlah iterasi yang telah ditetapkan. Rincian konfigurasi jaringan eksperimental dapat ditemukan pada Tabel 2 dalam penelitian ini.

Tabel 1. Ragam Pengaturan Jaringan


Percobaan	Epoch	Input	Output	Learning Rate
1	200	5	5	0,001
2	200	5	8	0,001
3	200	8	28	0,001
4	200	28	8	0,001

3.4 Tahap Pelatihan Metode Artificial Neural Network (ANN)

Menerapkan jaringan saraf tiruan dalam penelitian ini menantang, terutama dalam menentukan dan menerapkan prosedur pelatihan yang sesuai (Isnaeni dkk, 2022). Algoritma backpropagation dianggap paling sesuai untuk aplikasi penelitian ini, menjadi teknik yang umum digunakan untuk masalah serupa. Proses pelatihan bukan hanya mencapai nilai epoch maksimum, tetapi juga memperhatikan kriteria lain, khususnya ketika nilai *Mean Squared Error* (MSE) mencapai atau lebih rendah dari toleransi kesalahan yang ditetapkan. Jika pelatihan mencapai toleransi kesalahan, bobot otomatis disimpan untuk digunakan pada tahap pengujian. Tabel model loss pada *Artificial Neural Network* (ANN)

memberikan informasi tentang perubahan nilai fungsi kehilangan selama pelatihan model.

Fungsi kehilangan mengukur sejauh mana prediksi model cocok dengan nilai sebenarnya dari data pelatihan. Tabel tersebut mencakup kolom seperti nomor epoch, nilai kehilangan pelatihan, kehilangan validasi, dan kehilangan pengujian. Tujuannya adalah memantau perubahan nilai kehilangan selama pelatihan dan mengidentifikasi overfitting. Kenaikan nilai kehilangan validasi sementara kehilangan pelatihan terus menurun dapat menjadi indikasi kinerja yang buruk pada data baru. Grafik History Loss terkait dengan nilai error antara prediksi data latih dan data latih asli menunjukkan kurva train yang semakin menurun dan konvergen setiap Epoch, menandakan bahwa model semakin membaik. Pemodelan Loss dapat dilihat pada gambar 3.




Gambar 4. Model Loss Faktor Optimalisasi Desain Hunian Sementara

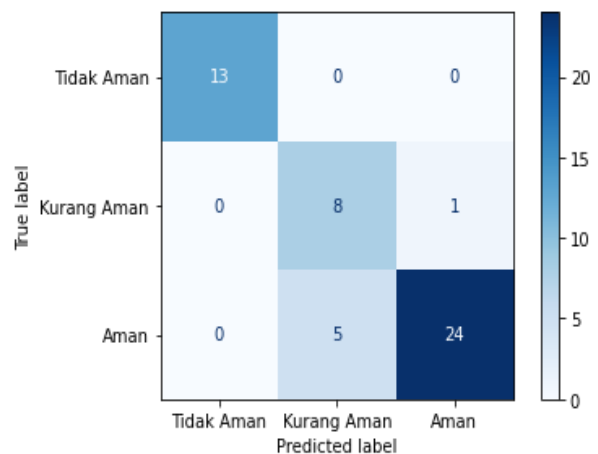
3.5 Tahap Pengujian Metode Artificial Neural Network (ANN)

Pencapaian kinerja model Artificial Neural Network (ANN) dinilai melalui formula persentase error biaya (CPE), memungkinkan rincian dampak setiap input jaringan terhadap outputnya. Analisis sensitivitas digunakan untuk mengeksplorasi korelasi sebab-akibat antara variabel input dan output, memungkinkan pengurangan dimensi dan kompleksitas model selama pelatihan. Analisis ini dilakukan setelah pelatihan selesai, tanpa mengubah bobot jaringan. Proses evaluasi menggunakan data penilaian 169 bangunan.

Akurasi model terlihat dalam kolom model, termasuk nomor epoch/iterasi, akurasi pelatihan, akurasi validasi, dan akurasi pengujian. Nomor epoch mencerminkan iterasi pelatihan, akurasi pelatihan menggambarkan pemahaman model terhadap pola data latihan, sementara akurasi validasi dan pengujian mengevaluasi generalisasi model dan deteksi overfitting. Pemodelan History Accuracy menunjukkan kurva model validasi yang stabil dengan nilai di atas 80%. Confusion matrix menyajikan evaluasi kinerja model klasifikasi, menunjukkan bahwa dari 45 prediksi aman, 8 prediksi kurang aman, dan 13 prediksi tidak aman. Gambar 5 mencerminkan hasil prediksi ini.



Gambar 5. Model Akurasi Identifikasi Bangunan Daerah Rawan Longsor



Gambar 6. Confusion Matriks Identifikasi Bangunan Daerah Rawan Longsor

3.6 Pembahasan

Berdasarkan evaluasi data klasifikasi dinding sederhana yang umum di Kecamatan Kalirejo, Kecamatan Kokap, Kabupaten Kulon Progo, Yogyakarta, menggunakan Artificial

Neural Network (ANN), terdapat presentase prediksi untuk setiap data dari pemodelan ANN dengan indikator Bangunan Tidak Aman mencapai 100%, prediksi Bangunan Aman sebesar 89%, dan prediksi Bangunan Aman dengan pemodelan History Accuracy sebagai acuan mencapai 82,7%, menunjukkan peningkatan dan kestabilan kurva model validasi. Nilai akurasi secara keseluruhan mencapai 88%, dihitung berdasarkan jumlah data yang salah prediksi dibandingkan dengan seluruh data lapangan penilaian bangunan, yaitu 6 dari total 51 model data penilaian.

Selanjutnya, hasil pemodelan menghasilkan presentase prediksi untuk setiap data dari pemodelan ANN dengan indikator Bangunan Tidak Aman sebesar 25,49%, sementara prediksi Bangunan Aman mencapai 15,69%, dan prediksi Bangunan Aman mencapai 47,06%.

3.7 Ucapan Terima Kasih

Terima kasih kepada Lembaga Penelitian Pengabdian Masyarakat dan Inovasi ITNY atas Hibah Penelitian Dasar yang diberikan kepada peneliti.

4. PENUTUP

4.1. Kesimpulan

Berdasarkan analisis data klasifikasi dinding sederhana yang khas di Kecamatan Kalirejo, Kecamatan Kokap, Kabupaten Kulon Progo, Yogyakarta, menggunakan Artificial Neural Network (ANN) adalah presentase untuk prediksi setiap data dari pemodelan Artificial Neural Network (ANN) dengan indikator Bangunan Tidak Aman adalah 100%, 89% prediksi Bangunan Aman, dan 82,7% memiliki prediksi Bangunan Aman dengan pemodelan History Accuracy yang menjadi rujukan, terutama kurva model validasi yang semakin meningkat dan stabil, menunjukkan nilai akurasi rata-rata di atas 80% yaitu 88%.

Berdasarkan analisis data klasifikasi dinding sederhana yang khas di Kecamatan Kalirejo, Kecamatan Kokap, Kabupaten Kulon Progo, Yogyakarta, menggunakan Artificial Neural Network (ANN) adalah presentase untuk prediksi setiap data dari pemodelan

Artificial Neural Network (ANN) dengan indikator Bangunan Tidak Aman adalah 25,49%, 15,69% prediksi Bangunan Aman, dan 47,06% memiliki prediksi Bangunan Aman dengan pemodelan History Accuracy yang menjadi rujukan, terutama kurva model validasi yang semakin meningkat dan stabil, menunjukkan nilai akurasi di atas 80% yaitu 88%.

4.2. Saran

Berdasarkan analisis dan kesimpulan yang disampaikan, terdapat sejumlah saran untuk meningkatkan Identifikasi Bangunan Daerah Rawan Longsor menggunakan Artificial Neural Network (ANN). Pertama, disarankan untuk mengumpulkan data yang lebih komprehensif mengenai kondisi bangunan, termasuk informasi geoteknik, struktural, dan lingkungan sekitar, dengan harapan data yang lebih lengkap dapat meningkatkan kinerja model ANN. Selanjutnya, perlu dilakukan evaluasi dan identifikasi variabel input yang mungkin berkontribusi signifikan terhadap identifikasi bangunan di daerah rawan longsor, serta penambahan variabel tersebut untuk meningkatkan keakuratan model. Eksperimen juga disarankan untuk mengoptimalkan arsitektur jaringan ANN, termasuk jumlah lapisan tersembunyi, jumlah neuron, dan fungsi aktivasi, dengan harapan pemilihan arsitektur yang tepat dapat meningkatkan kemampuan model dalam mengekstraksi fitur. Terakhir, untuk mengatasi ketidakseimbangan kelas dalam distribusi kelas, seperti jumlah bangunan yang aman lebih banyak daripada yang tidak aman, disarankan untuk mempertimbangkan teknik penanganan ketidakseimbangan kelas guna meningkatkan performa model pada kelas minor.

5. DAFTAR PUSTAKA

Fadli, D. I., Hadi, A. I., Allifya, Z., Anggriani, S., Ramdani, R., Idris, B. S., & Refrizon, R. (2023). Identifikasi Daerah Rawan Longsor secara Mikrozonasi di Jalan Alternatif Provinsi menggunakan Metode Simple Additive Weighting (SAW).

INDONESIAN JOURNAL OF APPLIED
PHYSICS, 13(1), 37-52.

- Firdausa, F. (2019). Prediksi dan Analisis Data Gempa Bumi di Provinsi Bengkulu dengan Metode Artificial Neural Network. *Cantilever: Jurnal Penelitian dan Kajian Bidang Teknik Sipil*, 8(2), 45-49.
- 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.
- Jelita Regita Putri, F. (2022). Evaluasi Daya Dukung Lahan Permukiman di Kawasan Rawan Bencana Gempabumi Kalurahan Panjangrejo, Kapanewon Pundong, Kabupaten Bantul, Daerah Istimewa Yogyakarta (Doctoral dissertation, UPN" Veteran" Yogyakarta).
- Kristanti, F. Y. (2021). Implementasi intelligence decision support system dynamic untuk menentukan tingkat kerusakan sektor pasca bencana alam menggunakan modified-topsis dan neural network (Doctoral dissertation, Universitas Islam Negeri Maulana Malik Ibrahim).
- Panjaitan, M., Mulia, A. P., & Nasution, Z. P. (2021). Pemetaan Banjir Rob Medan Utara Menggunakan Artificial Neural Network dan Gis untuk Langkah Mitigasi. *Jurnal Syntax Admiration*, 2(8), 1512-1526.
- Pradana, D., Alghifari, M. L., Juna, M. F., & Palaguna, D. (2022). Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network. *Indonesian Journal of Data and Science*, 3(2), 55-60.
- Prastowo, R., Trianda, O., & Novitasari, S. (2018). Identifikasi Kerentanan Gerakan Tanah Berdasarkan Data Geologi Daerah Kalirejo, Kecamatan Kokap, Kabupaten Kulonprogo, Yogyakarta. *Kurvatek*, 3(2), 31-40.
- Pyanto, F. (2023). Pencitraan Banjir Rob Zona Medan Utara Menggunakan Regresi Logistik dan Artificial Neural Network Serta Global Information System. *Jurnal Ilmiah Ecosystem*, 23(1), 60-74.
- Ramadhan, M. (2021). Analisis Tingkat Kerawanan Tanah Longsor Dengan Menggunakan Kombinasi Metode Frequency Ratio dan Fuzzy Logic di Sub Das Malino Das Jeneberang (Doctoral dissertation, Universitas Hasanuddin).
- Saedudin, R., Yanto, I. T. R., Budiono, A., Sari, S. N., Deris, M. M., & Senan, N. (2022). Data Clustering for Identification of Building Conditions Using Hybrid Multivariate Multinomial Distribution Soft Set (MMDS) Method. *JOIV: International Journal on Informatics Visualization*, 6(2), 284-289.
- Sari, S. N., Prastowo, R., Junaidi, R., & Machmud, A. (2020). Rapid visual screening of building for potential ground movement in Kalirejo, Kulonprogo, Yogyakarta. *Jurnal Ilmiah Pendidikan Fisika Al-Biruni*, 9(1), 51-59.
- Sari, S. N., Prastowo, R., Yanto, I. T. R., Cengiz, K., Ozyurt, B., & Topac, T. (2022). Fast Building Identification Using Fuzzy Soft Set Based on Rapid Visual Building (RVS). *International Journal of Hydrological and Environmental for Sustainability*, 1(2), 70-78.
- Trianda, O., Prastowo, R., & Novitasari, S. (2018). Identifikasi Ketebalan Lapisan Lapuk di Daerah Kalirejo, Kulonprogo Berdasarkan Pengukuran Mikrotremor dalam Upaya Mitigasi Tanah Longsor. *Prosiding Nasional Rekayasa Teknologi Industri dan Informasi XIII*, 246-253.