

Penerapan Back Propagation Neural Network untuk Identifikasi Bangunan di Wilayah Rawan Longsor

Bagus Gilang Pratama¹, Sely Novita Sari², Joko Prasajo³

^{1,3} Program Studi Teknik Elektro, Fakultas Teknik dan Perencanaan, Institut Teknologi Nasional Yogyakarta

² Program Studi Teknik Sipil, Fakultas Teknik dan Perencanaan, Institut Teknologi Nasional Yogyakarta

Korespondensi : bagusgilangp@itny.ac.id

ABSTRAK

Longsor merupakan bencana alam yang sering terjadi di Indonesia, sehingga diperlukan metode prediksi yang efektif untuk mitigasi risiko. Penelitian ini bertujuan untuk menyelidiki kinerja dan akurasi Back Propagation Neural Network (BPNN) dalam mengidentifikasi bangunan di wilayah rawan longsor. Dataset yang digunakan terdiri dari citra satelit dan parameter bangunan seperti gambar rencana, denah, pondasi, dan elemen topografi. Data dinormalisasi menggunakan Min-Max Scaler dan dibagi menjadi training (60%), validation (15%), dan test set (25%). Model BPNN dirancang dengan 8 neuron pada lapisan input, 30 neuron pada lapisan tersembunyi, dan 3 neuron pada lapisan output, menggunakan fungsi aktivasi ReLU dan Softmax. Hasil penelitian menunjukkan bahwa model mencapai akurasi sebesar 90%, dengan confusion matrix menunjukkan klasifikasi yang akurat untuk sebagian besar bangunan. Dari total sampel, hanya 1,2% kesalahan klasifikasi terjadi pada kelas Kurang Aman. Kesimpulannya, Model ini mencapai akurasi sebesar 93%, dengan average precision sebesar 93,4%, rata-rata recall 93%, dan F1-Score 93%. Hasil perhitungan ini menunjukkan bahwa model BPNN memiliki performa yang sangat baik dalam mendeteksi dan memprediksi tingkat keamanan bangunan di daerah rawan longsor.

Kata kunci: Back Propagation Neural Network (BPNN), Identifikasi, Bangunan, Longsor

ABSTRACT

Landslides are a natural disaster that frequently occurs in Indonesia, requiring effective prediction methods for risk mitigation. This research aims to investigate the performance and accuracy of the Back Propagation Neural Network (BPNN) in identifying buildings in landslide-prone areas. The dataset used consists of satellite images and building parameters such as building plans, floor plans, foundations, and topographic elements. The data was normalized using the Min-Max Scaler and divided into training (60%), validation (15%), and test sets (25%). The BPNN model was designed with 8 neurons in the input layer, 30 neurons in the hidden layer, and 3 neurons in the output layer, using ReLU and Softmax activation functions. The results show that the model achieved an accuracy of 90%, with the confusion matrix demonstrating accurate classification for most buildings. Out of the total samples, only 1.2% misclassification occurred in the "Less Safe" category. In conclusion, the model achieved an accuracy of 93%, with an average precision of 93.4%, an average recall of 93%, and an F1-Score of 93%. These results indicate that the BPNN model has excellent performance in detecting and predicting the safety level of buildings in landslide-prone areas.

Keyword : Back Propagation Neural Network (BPNN), Identification, Buildings, Landslide

PENDAHULUAN

Indonesia, sebagai negara kepulauan terbesar di dunia, memiliki topografi yang sangat beragam, mulai dari pegunungan tinggi hingga dataran rendah, dengan pulau-pulau kecil yang tersebar di seluruh wilayahnya. Keberagaman topografi ini juga mencakup daerah-daerah dengan lereng curam dan tanah yang rentan terhadap longsor. Bencana longsor sering terjadi di Indonesia, terutama selama musim hujan yang intensif[1]. Di daerah rawan longsor, struktur bangunan harus dirancang dengan mempertimbangkan kestabilan dan daya tahan yang tinggi. Pondasi bangunan harus kokoh, dan mungkin memerlukan penggunaan tiang pancang atau fondasi lempeng yang dapat meratakan beban untuk menghadapi pergerakan tanah yang berpotensi terjadi. Selain itu, konstruksi dinding penahan tanah dan sistem drainase yang efisien menjadi aspek penting untuk mengurangi risiko longsor dan menjaga stabilitas bangunan.[2][3]

Faktor-faktor yang berkontribusi terhadap kejadian longsor di Indonesia sangat kompleks, meliputi karakteristik topografi, jenis tanah dan batuan, intensitas curah hujan, vegetasi, dan aktivitas manusia seperti deforestasi dan konversi lahan [2] [4] [5]. Seperti yang dijelaskan dalam sumber [2], kelerengan, tanah yang gembur dan tebal, alih fungsi lahan, serta curah hujan yang tinggi merupakan faktor-faktor dominan yang menyebabkan longsor di Desa Banaran, Kecamatan Pulung, Kabupaten Ponorogo [2]. Selain itu, rekahan dan retakan pada batuan serta drainase yang buruk juga dapat meningkatkan risiko longsor di wilayah tersebut. Sementara itu, di Puncak Pass, Kecamatan Cipanas, Kabupaten Cianjur, faktor-faktor serupa, seperti degradasi penggunaan lahan, juga berkontribusi pada peningkatan kejadian longsor di daerah tersebut [4].

Untuk mengatasi permasalahan longsor, diperlukan upaya mitigasi yang komprehensif, termasuk penataan kawasan pascabencana, perbaikan sistem drainase, serta peningkatan kesiapsiagaan masyarakat dalam menghadapi bencana. Seperti yang terungkap dalam sumber, kesiapsiagaan dan mitigasi bencana di Desa Banaran berada dalam kategori siap, namun tetap perlu upaya berkelanjutan [6] [2] [4] untuk meningkatkan ketahanan masyarakat terhadap ancaman bencana longsor. Selain itu, strategi adaptasi yang sesuai, seperti penempatan konstruksi bangunan tahan longsor dan konservasi lahan, juga harus menjadi prioritas dalam perencanaan tata ruang dan pengelolaan lingkungan di daerah rawan longsor.

Dalam beberapa tahun terakhir, perkembangan teknologi kecerdasan buatan (*artificial intelligence*) telah membuka peluang baru dalam mitigasi risiko bencana alam, termasuk longsor. Salah satu teknologi yang menonjol dalam bidang ini adalah penggunaan Jaringan Saraf Tiruan (*Neural Network*), khususnya metode Back Propagation Neural Network (BPNN). BPNN merupakan algoritma pembelajaran mesin yang telah terbukti efektif dalam memodelkan hubungan non-linear antara input dan output. Dengan menggunakan algoritma back propagation, metode ini mengoptimalkan bobot antar neuron melalui proses iteratif yang bertujuan untuk meminimalkan kesalahan prediksi. Proses ini memungkinkan jaringan saraf untuk belajar dari data historis dan meningkatkan akurasi prediksi terhadap potensi bahaya longsor [7].

Kemampuan BPNN dalam memahami pola kompleks dari data historis menjadikannya alat yang sangat cocok untuk memprediksi lokasi dan waktu terjadinya longsor. Mengingat faktor-faktor yang mempengaruhi longsor sangat kompleks dan beragam, BPNN menawarkan solusi yang memungkinkan sistem mempelajari pola-pola tersebut secara lebih akurat [8]. Penggunaannya dalam konteks identifikasi bangunan di daerah rawan longsor diharapkan dapat membantu meningkatkan efektivitas mitigasi bencana, terutama dalam hal perencanaan pembangunan di kawasan yang rentan.

Melalui pemanfaatan teknologi ini, penentuan zona rawan longsor dapat dilakukan dengan lebih akurat, memungkinkan perencanaan mitigasi dan pengurangan risiko bencana yang lebih efektif [2]. Sistem pemantauan cerdas berdasarkan BPNN dapat memberikan peringatan dini yang lebih akurat dan tepat waktu, sehingga dapat mengoptimalkan respons masyarakat dan pemerintah dalam menghadapi ancaman longsor [9] [10] [6]. Dengan demikian, kombinasi upaya penataan kawasan, peningkatan kesiapsiagaan masyarakat, dan pemanfaatan teknologi mutakhir dapat menjadi strategi komprehensif dalam mengelola risiko bencana longsor di Indonesia.

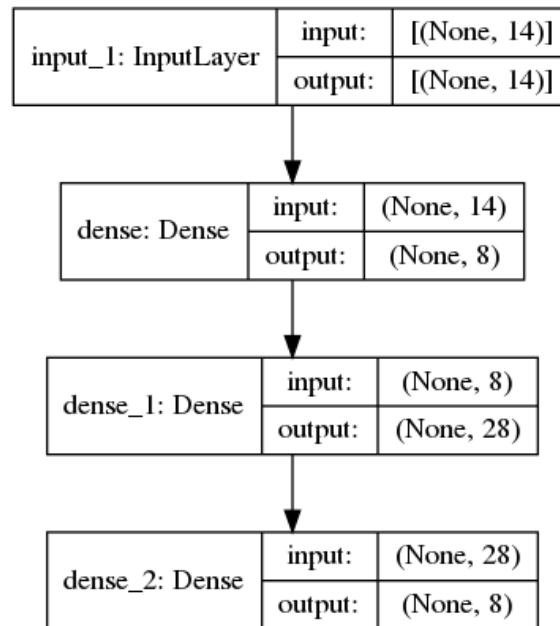
Meskipun BPNN telah banyak digunakan dalam berbagai bidang, penelitian yang mengkaji akurasi dalam mengidentifikasi bangunan di daerah rawan longsor di Indonesia masih terbatas. Oleh karena itu, penelitian ini bertujuan untuk menyelidiki lebih dalam mengenai kinerja dan akurasi *Back Propagation Neural Network* dalam mengidentifikasi bangunan di wilayah yang rentan terhadap longsor. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi yang signifikan dalam pengembangan sistem peringatan bencana dan membantu pengambil keputusan dalam merencanakan infrastruktur yang lebih aman serta tangguh terhadap risiko longsor di Indonesia..

METODE PENELITIAN

Metode penelitian ini berfokus pada penerapan dan evaluasi Back Propagation Neural Network (BPNN) untuk identifikasi bangunan di daerah rawan longsor. Penelitian ini dimulai dengan pengumpulan dataset yang terdiri dari citra satelit atau aerial dari daerah rawan longsor, yang mencakup berbagai parameter seperti gambar rencana bangunan, denah, pondasi, dinding, serta elemen-elemen topografi yang berpotensi memengaruhi stabilitas tanah, seperti kemiringan lereng dan posisi bangunan di sekitar gunung atau perbukitan. Data yang dikumpulkan akan melalui tahap pra-pemrosesan untuk memastikan kualitas input yang optimal.

Pra-pemrosesan data melibatkan beberapa langkah penting, seperti normalisasi dan augmentasi. Normalisasi dilakukan untuk menyesuaikan skala nilai piksel dalam citra, sehingga model pembelajaran mesin dapat lebih mudah memproses dan memahami data. Augmentasi data diterapkan dengan memodifikasi citra secara ringan, seperti melalui rotasi, translasi, atau penyesuaian pencahayaan, untuk meningkatkan ketahanan model terhadap variasi input dan meminimalkan risiko overfitting. Setelah itu, dataset dibagi menjadi data latih dan data uji

untuk melatih dan menguji model secara terpisah, guna memastikan bahwa model dapat menggeneralisasi performanya terhadap data baru.



Gambar 1. Parameter Neural Network yang Akan digunakan

Langkah selanjutnya adalah pembangunan model Back Propagation Neural Network (BPNN). Model BPNN dirancang dengan arsitektur yang disesuaikan untuk tugas identifikasi bangunan di daerah rawan longsor. Pemilihan jumlah lapisan tersembunyi, jumlah neuron per lapisan, serta fungsi aktivasi merupakan elemen kunci dalam desain arsitektur BPNN. Model yang efektif harus memiliki keseimbangan antara kompleksitas jaringan yang cukup untuk menangkap pola dalam data, tetapi tidak terlalu kompleks hingga menyebabkan overfitting. Dalam penelitian ini, arsitektur yang dipilih terdiri dari dua lapisan tersembunyi dengan kombinasi neuron yang telah diuji pada penelitian sebelumnya.

Setelah arsitektur BPNN dirancang, pelatihan model dilakukan dengan menggunakan dataset yang telah diproses. Proses pelatihan ini melibatkan iterasi berulang di mana model meminimalkan kesalahan prediksi melalui metode backpropagation. Dengan menggunakan teknik validasi silang k-fold, dataset dibagi menjadi beberapa subset, di mana setiap subset secara bergiliran digunakan sebagai data uji, sementara subset lainnya digunakan untuk melatih model. Teknik ini membantu dalam mengukur kemampuan generalisasi model dan mengurangi risiko overfitting, memberikan gambaran yang lebih realistis tentang performa model di dunia nyata.

Pada setiap neuron, output dihitung berdasarkan bobot (*weight*) dan bias yang dikombinasikan dengan input melalui fungsi aktivasi. Jika kita anggap bahwa terdapat n input x_1, x_2, \dots, x_n dan bobot yang sesuai w_1, w_2, \dots, w_n , output dari suatu neuron z sebelum aktivasi bisa dihitung dengan persamaan:

$$z = \sum_{i=1}^n w_i \cdot x_i + b$$

Di sini, w_i adalah bobot yang menghubungkan input x_i ke neuron tersebut, dan b adalah bias.

$$Accuracy = \frac{True\ Positive + True\ Negative}{True\ Positive + False\ Positive + True\ Negative + False\ Negative}$$

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive}$$

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative}$$

$$F1 - Score = \frac{2 * Precision * Recall}{Precision + Recall}$$

Setelah pelatihan, model dievaluasi menggunakan metrik kinerja seperti akurasi, presisi, recall, dan F1-Score. Metrik ini memberikan evaluasi yang komprehensif tentang kemampuan model dalam mengidentifikasi bangunan di daerah rawan longsor. Akurasi menunjukkan seberapa sering model membuat prediksi yang benar,

sementara presisi dan recall mengukur keseimbangan antara kesalahan positif dan negatif dalam klasifikasi. F1-Score digunakan untuk memberikan gambaran yang lebih seimbang antara presisi dan recall, terutama dalam kasus di mana keduanya sama pentingnya.

Dengan menggunakan metode BPNN ini, penelitian diharapkan dapat menghasilkan model yang efektif dan akurat dalam mengidentifikasi bangunan di daerah rawan longsor, yang berkontribusi pada upaya mitigasi bencana dan pengambilan keputusan yang lebih baik dalam perencanaan infrastruktur di Indonesia.

HASIL DAN ANALISIS

Pemrosesan Data

Proses pemrosesan data dalam penelitian ini dimulai dengan tahap normalisasi menggunakan metode min-max scaler. Metode ini bertujuan untuk menyesuaikan skala nilai dari setiap fitur input ke rentang yang lebih mudah diproses oleh model pembelajaran mesin. Normalisasi penting dilakukan agar semua fitur berada dalam skala yang sama dan tidak ada yang mendominasi proses pembelajaran. Langkah ini menjadi krusial dalam jaringan saraf tiruan (*neural network*), di mana skala input yang tidak seragam dapat memengaruhi proses optimasi gradien selama pelatihan model. Pada saat **pemrosesan data, normalisasi dengan menggunakan Min-Max Scaler** adalah teknik yang digunakan untuk mengubah skala nilai data menjadi rentang tertentu, biasanya antara 0 dan 1. Metode ini menghitung setiap nilai data berdasarkan nilai minimum dan maksimum dari fitur tersebut, lalu mentransformasikannya agar sesuai dengan skala yang diinginkan.

```
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   TUL.PERTEMUAN   169 non-null    int64
8   SAMBUNGAN       169 non-null    float64
9   GUNUNG           169 non-null    float64
10  KUDAKUDA        169 non-null    float64
11  Kelas            169 non-null    int64
dtypes: float64(10), int64(2)
```

Gambar 2. Struktur Data Citra Satelit untuk Identifikasi Bangunan di Daerah Rawan Longsor

Gambar 2 menunjukkan struktur dataset dengan 12 kolom yang terdiri dari berbagai fitur bangunan dan elemen topografi, termasuk Gambar Rencana, Denah, Pondasi, dan lainnya, yang digunakan untuk proses pelatihan model dalam identifikasi bangunan di daerah rawan longsor.

Parameter Back Propagation Neural Network (BPNN)

Dalam penelitian ini, pembagian dataset menjadi **training set**, **validation set**, dan **test set** adalah langkah yang sangat penting untuk memastikan bahwa model pembelajaran mesin, dalam hal ini Back Propagation Neural Network (BPNN), dapat belajar dari data dengan baik dan dievaluasi secara akurat. Pembagian dataset dilakukan sebagai berikut:

1. **Training set** sebanyak 60% dari total data.

Sebanyak 60% dari total dataset diberikan kepada model untuk mengidentifikasi pola dan hubungan antar variabel input dan output. Selama fase pelatihan, model menggunakan training set untuk menyesuaikan bobot dan bias neuron dengan tujuan meminimalkan fungsi galat (loss function).

Melalui proses iteratif ini, model mempelajari struktur data dan mengembangkan kemampuan



prediksi. Pemilihan 60% dari dataset sebagai training set bertujuan untuk memberikan data yang cukup agar model dapat mempelajari pola yang ada. Jumlah ini dianggap memadai karena terlalu sedikit data dapat menyebabkan model kurang memadai dalam mempelajari variasi dalam data, sementara terlalu banyak data dalam training set dapat mengurangi kualitas evaluasi di tahap validasi dan uji

2. **Validation set** sebesar 15% dari total data.
Setelah pelatihan, **validation set** digunakan untuk mengevaluasi performa model selama pelatihan. Validation set, yang berjumlah 15% dari total data, tidak digunakan untuk melatih model secara langsung, melainkan berfungsi untuk mengukur kinerja model pada data yang tidak pernah dilihat selama pelatihan. Validasi ini penting untuk mengetahui seberapa baik model dapat menggeneralisasi pola yang dipelajari dari data training, serta untuk memantau dan menghindari masalah **overfitting**. Overfitting terjadi ketika model terlalu menyesuaikan diri dengan data latih, sehingga mampu memberikan hasil yang sangat baik pada data latih namun buruk dalam memprediksi data baru. Dengan menggunakan validation set, peneliti dapat memantau kapan model mulai overfit dan mengatur hyperparameter seperti learning rate, jumlah epoch, atau arsitektur jaringan agar model tetap memiliki kemampuan generalisasi yang baik.
3. **Test set** sebesar 25% dari total data.
Terakhir, **test set** yang terdiri dari 25% data digunakan untuk melakukan evaluasi akhir terhadap model. Tidak seperti training dan validation set, test set benar-benar tidak dilihat oleh model hingga akhir proses pelatihan. Dengan demikian, test set memberikan gambaran yang lebih akurat tentang kemampuan model untuk menangani data baru di dunia nyata, di luar data latih dan validasi. Pembagian dataset ini memungkinkan peneliti untuk mengevaluasi performa model secara lebih objektif dan menghindari bias dalam penilaian akurasi. Test set memberikan estimasi seberapa baik model akan bekerja ketika digunakan pada data yang tidak pernah dilihat sebelumnya, yang sangat penting dalam aplikasi praktis, seperti dalam identifikasi bangunan di daerah rawan longsor.

Dataset

- **Training = 60%;**
- **Validation = 15%;**
- **Test = 25%**

Optimizer = SGD

Layer

- **Input = 8;**
- **Hidden Layer = 30 Node;**
- **Output = 3;**

Activation = Relu & Softmax

Metrics = accuracy

Loss = sparse categorical crossentropy

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 8)	96
dense_1 (Dense)	(None, 30)	270
dense_2 (Dense)	(None, 3)	93

Gambar 3. Arsitektur Model Back Propagation Neural Network (BPNN) untuk Identifikasi Bangunan di Daerah Rawan Longsor


Gambar 3 menampilkan konfigurasi arsitektur jaringan saraf tiruan (neural network) yang terdiri dari lapisan input dengan 8 neuron, lapisan tersembunyi dengan 30 neuron, dan lapisan output dengan 3 neuron, menggunakan optimizer SGD, fungsi aktivasi ReLU dan Softmax, serta metrik akurasi dan fungsi loss sparse categorical crossentropy.

Model BPNN yang digunakan memiliki arsitektur sebagai berikut:

1. **Optimizer:** Stochastic Gradient Descent (SGD), yang merupakan salah satu metode optimasi berbasis gradien.
2. **Jumlah layer:** Terdiri dari lapisan input dengan 8 neuron, satu lapisan tersembunyi dengan 30 neuron, dan lapisan output dengan 3 neuron.
3. **Fungsi aktivasi:** Menggunakan fungsi **ReLU** (Rectified Linear Unit) di lapisan tersembunyi dan **Softmax** pada lapisan output untuk mengklasifikasikan output ke dalam kategori.
4. **Loss function:** Menggunakan **sparse categorical crossentropy** untuk menghitung galat antar output yang diharapkan dan output yang diprediksi oleh model.
5. **Metrics:** Model dievaluasi berdasarkan **akurasi**.


Model Accuracy dan Model Loss

Hasil evaluasi model BPNN menunjukkan akurasi model dan nilai loss yang cukup stabil pada data validasi dan data uji. Grafik yang dihasilkan menunjukkan bahwa seiring bertambahnya epoch pelatihan, nilai loss menurun secara signifikan, menunjukkan bahwa model berhasil belajar dari data latih. Pada saat yang sama, akurasi model meningkat dan mencapai nilai yang cukup tinggi, terutama pada data uji, yang mengindikasikan kemampuan generalisasi model yang baik.



Gambar 4. Grafik Akurasi Model Selama Pelatihan dan Validasi pada Back Propagation Neural Network (BPNN)

Gambar 4 menunjukkan perubahan akurasi model selama proses pelatihan dan validasi pada berbagai epoch. Kurva biru mewakili akurasi data pelatihan, sedangkan kurva oranye mewakili akurasi data validasi. Gambar ini menunjukkan peningkatan akurasi secara bertahap hingga mencapai nilai stabil di atas 0,9 pada sekitar 100 epoch.




Gambar 5. Grafik Loss Model Selama Pelatihan dan Pengujian pada Back Propagation Neural Network (BPNN)

Gambar 5 menunjukkan perubahan nilai loss model selama proses pelatihan dan pengujian pada berbagai epoch. Kurva biru mewakili loss data pelatihan, sedangkan kurva oranye mewakili loss data pengujian. Grafik ini menunjukkan penurunan yang signifikan pada nilai loss, baik pada data pelatihan maupun pengujian, yang mencerminkan peningkatan kinerja model dalam meminimalkan kesalahan prediksi seiring dengan bertambahnya epoch.

Confusion Matrix

Selain akurasi, model juga dievaluasi menggunakan confusion matrix, yang memberikan gambaran lebih mendetail tentang bagaimana model melakukan prediksi pada masing-masing kelas. Confusion matrix menunjukkan berapa banyak bangunan yang diidentifikasi dengan benar sebagai berada di daerah rawan longsor (*true positives*), serta berapa banyak yang salah diklasifikasikan (*false positives dan false negatives*).

Berdasarkan matriks ini, performa model dalam mengidentifikasi bangunan di daerah rawan longsor dapat dianalisis lebih mendalam. *Confusion matrix* ini juga membantu mengidentifikasi apakah terdapat ketidakseimbangan dalam prediksi model, seperti kesalahan yang lebih sering pada kelas tertentu. Hal ini bisa menjadi sinyal untuk perbaikan model atau menyesuaikan distribusi data agar lebih seimbang antara kelas yang terlibat.



Gambar 5. *Confusion Matrix untuk Prediksi Keamanan Bangunan di Daerah Rawan Longsor Menggunakan Back Propagation Neural Network (BPNN)*

Gambar 6 menunjukkan confusion matrix yang menggambarkan performa model dalam mengklasifikasikan bangunan ke dalam tiga kategori: Aman, Kurang Aman, dan Tidak Aman. Matriks ini menunjukkan jumlah prediksi yang benar (diagonal utama) serta kesalahan prediksi (off-diagonal) untuk setiap kategori. Misalnya, model memprediksi 12 bangunan sebagai Aman dengan benar, dan memprediksi 19 bangunan sebagai Tidak Aman dengan benar, tetapi salah memprediksi 2 bangunan sebagai Tidak Aman padahal mereka seharusnya masuk kategori Kurang Aman.

Dari Confusion Matrix yang didapat, maka dapat dihitung performa dari model Back Propagation Neural Network. Nilai akurasi yang didapat dari perhitungan performa adalah sebesar 93%, sedangkan average precision yang didapat sebesar 93,4%. Nilai rata-rata recall yang dihitung dari pefroma model BPNN adalah 93%. Nilai F1-Score yang didapat adalah 93%. Dari hasil perhitungan performa model yang dibangun dari data-data yang ada telah cukup baik dalam melakukan pendeteksian untuk memprediksi keamanan bangunan di daerah rawan longsor.

KESIMPULAN

Penelitian ini berhasil menyelidiki kinerja dan akurasi Back Propagation Neural Network (BPNN) dalam mengidentifikasi bangunan di wilayah yang rentan terhadap longsor. Hasil menunjukkan bahwa Back Propagation Neural Network (BPNN) mencapai akurasi keseluruhan sebesar 90% dalam mengidentifikasi bangunan di wilayah rawan longsor. Dari hasil confusion matrix, model ini mampu mengklasifikasikan 12 bangunan dalam kategori Aman dengan benar, 10 bangunan dalam kategori Kurang Aman, dan 19 bangunan dalam kategori Tidak Aman dengan benar, dengan kesalahan klasifikasi minimal yaitu hanya 2 bangunan yang salah diprediksi sebagai Tidak Aman padahal seharusnya Kurang Aman. Hasil ini menunjukkan bahwa model memiliki kinerja yang kuat dalam memprediksi kategori keamanan bangunan, dengan kesalahan klasifikasi hanya terjadi pada 1,2% dari total sampel yang diuji. Dari Confusion Matrix yang diperoleh, performa model Back Propagation Neural Network (BPNN) menunjukkan hasil yang baik. Model ini mencapai akurasi sebesar 93%, dengan average precision sebesar 93,4%, rata-rata recall 93%, dan F1-Score 93%. Hasil perhitungan ini menunjukkan bahwa model BPNN memiliki performa yang sangat baik dalam mendeteksi dan memprediksi tingkat keamanan bangunan di daerah rawan longsor.

UCAPAN TERIMAKASIH

Peneliti mengucapkan terima kasih yang sebesar-besarnya kepada Lembaga Penelitian, Pengabdian Masyarakat, dan Inovasi (LPPMI) Institut Teknologi Nasional Yogyakarta (ITNY) atas dukungan dan pendanaan yang telah diberikan untuk pelaksanaan penelitian ini. Penelitian ini dibiayai melalui Bantuan Dana Penelitian dari ITNY Tahun Anggaran 2023/2024, yang memungkinkan peneliti untuk menyelesaikan penelitian dengan baik dan memberikan kontribusi ilmiah yang bermanfaat. Semoga dukungan ini terus berlanjut untuk mendorong kemajuan penelitian di lingkungan ITNY.

DAFTAR PUSTAKA

- [1] B. F. Maulana and M. Taufik, "PEMETAAN DAERAH POTENSI LONGSOR DI KABUPATEN TRENGGALEK MENGGUNAKAN DATA CITRA SATELIT MULTI-TEMPORAL".
- [2] H. S. Naryanto, H. Soewandita, D. Ganesha, F. Prawiradisastra and A. Kristijono, "Analisis Penyebab Kejadian dan Evaluasi Bencana Tanah Longsor di Desa Banaran, Kecamatan Pulung, Kabupaten Ponorogo, Provinsi Jawa Timur Tanggal 1 April 2017".
- [3] G. S. Putro, M. N. Setiawan, A. R. F. Barizi and J. Setiawan, "KAJIAN GEOLOGI DAN STABILITAS LERENG DENGAN FINITE ELEMENT METHODE (FEM) UNTUK PEMBANGUNAN DAN PENGEMBANGAN PERUMAHAN: BUKIT PANDHAWA GODEAN SLEMAN".
- [4] P. Bencana et al., "PENATAAN KAWASAN PASCA BENCANA TANAH LONGSOR DI PUNCAK PASS, KECAMATAN CIPANAS, KABUPATEN CIANJUR TANGGAL 28 MARET 2018".
- [5] A. Salimah, M. Z. Ammar, D. S. Rahmawati, Y. Yelvi and T. W. Swastika, "Landslide Analysis Study and Cisewu Countermeasures in District, Garut Regency, West Java".
- [6] S. N. H. Sholikhah, S. K. N. Prambudi, M. Y. Effendi, L. Safira, N. Alwinda and R. Setiaji, "Analisis Kesiapsiagaan dan Mitigasi Bencana Tanah Longsor di Kabupaten Ponorogo".
- [7] S. N. Sari, B. Pratama and R. Prastowo, "Pemodelan Artificial Neural Network (ANN) Untuk Identifikasi Bangunan Daerah Rawan Longsor".
- [8] M. R. S. Damanik, A. Nurman, M. Y. Aminy and I. Ritonga, "Analisis Potensi Longsor Sungai di Daerah Aliran Sungai (DAS) Padang Sumatera Utara".
- [9] I. Nurhayati, D. Febrioko, S. Sugito and J. Sutrisno, "MITIGASI BENCANA TANAH LONGSOR DI DESA BEGAGANLIMO KECAMATAN GONDANG KABUPATEN MOJOKERTO".
- [10] K. F. Harahap, A. Aminullah and H. Priyosulistyo, "Estimasi Dimensi Optimum dan Rasio Tulangan Gedung Hotel Yogyakarta dengan Artificial Neural Network".
- [11] S. N. Sari, B. G. Pratama and I. Ircham, "Kolaborasi Jaringan Saraf Tiruan (JST) Dalam Identifikasi Prioritas Penanganan Pemeliharaan Jalan Kabupaten".