

METODE ANN UNTUK PREDIKSI TANAH LONGSOR BERDASARKAN CURAH HUJAN DI KABUPATEN PURWAKARTA

Cece Supriatna^{1*}, Teguh Nurhadi Suharsono²

^{1,2}Universitas Sangga Buana YPKP Bandung

sharingan2515@gmail.com¹, teguh.nurhadi@usbypkp.ac.id²

Received: 25-10-2024

Revised: 16-11-2023

Approved: 10-12-2024

ABSTRAK

Bencana alam, termasuk tanah longsor, merupakan ancaman signifikan yang dapat mengganggu keberlangsungan hidup dan menyebabkan kerugian besar di Indonesia, terutama di wilayah yang rawan seperti Kabupaten Purwakarta. Dengan latar belakang ini, penelitian ini bertujuan untuk mengembangkan model prediksi potensi tanah longsor berdasarkan data curah hujan menggunakan metode Artificial Neural Network (ANN). Penelitian ini menganalisis karakteristik curah hujan di Kabupaten Purwakarta dan mengimplementasikan ANN sebagai alat prediksi. Metode ANN dipilih karena kemampuannya dalam mengenali pola dan hubungan dalam data kompleks, yang sulit diidentifikasi oleh pendekatan konvensional. Hasil penelitian menunjukkan bahwa curah hujan merupakan faktor signifikan yang mempengaruhi potensi tanah longsor di Kabupaten Purwakarta. Model ANN yang dikembangkan mampu memprediksi potensi tanah longsor dengan akurasi yang tinggi, dimana nilai R^2 sebesar 0.8374 diperoleh pada data testing, menunjukkan bahwa model dapat menjelaskan 83.74% dari variabilitas data baru. Penelitian ini memberikan kontribusi penting dalam upaya mitigasi bencana tanah longsor di Kabupaten Purwakarta dengan menggunakan teknologi kecerdasan buatan.

Kata kunci: *Artificial Neural Network, Prediksi Tanah Longsor, Curah Hujan*

PENDAHULUAN

Bencana adalah rangkaian peristiwa yang dapat mengganggu dan menghambat keberlangsungan hidup makhluk hidup, menyebabkan terjadinya kerugian materi, kerusakan lingkungan hidup, dampak psikologis dan bahkan korban jiwa (BPBD JABAR, n.d.). Bencana dibagi menjadi dua kategori yaitu bencana alam dan bencana non alam. Bencana alam berasal dari peristiwa alam seperti gempa bumi, gunung meletus, tsunami, banjir, kekeringan, dan angin topan. Sementara itu, bencana non alam berasal dari tindakan manusia seperti pandemi, kegagalan teknologi, dan kegagalan modernisasi.

Secara geografis, Indonesia berada di kawasan *Ring of Fire* (lingkaran api) yang merupakan pertemuan tiga lempeng tektonik yaitu lempeng *Indo-Australia*, lempeng *Eurasia*, dan lempeng *Pasifik*. Sehingga intensitas bencana alam di Indonesia sangat tinggi. Indonesia sebagai negara kepulauan dengan topografi yang beragam menghadapi berbagai tantangan terkait bencana alam, salah satunya adalah tanah longsor. Tanah longsor merupakan fenomena geologi yang dapat disebabkan oleh berbagai faktor, termasuk curah hujan yang tinggi dan pergerakan tanah yang tidak stabil. Kabupaten Purwakarta, sebagai salah satu wilayah dengan karakteristik geografis yang rentan terhadap tanah longsor, memerlukan pendekatan ilmiah dan teknologi mutakhir dalam upaya mitigasi risiko bencana ini.

Tanah longsor adalah salah satu jenis gerakan massa tanah atau bebatuan, atau kombinasi keduanya, yang menuruni atau keluar dari lereng akibat terganggunya kestabilan tanah atau batuan yang membentuk lereng tersebut. Saat peneliti menulis laporan ini, ada 1.775 kejadian tanah longsor di Jawa Barat dari tahun 2014 hingga 2023.

Dalam bidang manajemen bencana, teknologi Artificial Neural Networks (ANN) semakin diakui kemampuannya untuk mengelola dan meramalkan situasi darurat. Sebuah tinjauan terhadap 128 artikel menunjukkan bahwa ANN sangat efektif untuk prediksi banjir, terutama melalui arsitektur *Backpropagation Neural Networks* (BPNN). Selain itu, *Convolutional Neural Networks* (CNN) dianggap menjanjikan dalam mengekstraksi data media sosial selama keadaan darurat, yang dapat memberikan informasi cepat untuk respons bencana (Guha et al., 2022). Temuan ini mendukung pemanfaatan ANN dalam studi ini untuk memprediksi potensi tanah longsor.

Perubahan iklim dan berbagai faktor lain yang memengaruhi ketersediaan air tanah di wilayah Purwakarta menimbulkan kebutuhan mendesak untuk memahami dan memprediksi potensi terjadinya tanah longsor. Oleh karena itu, penelitian ini berfokus pada beberapa masalah utama, yaitu bagaimana curah hujan mempengaruhi potensi tanah longsor di Kabupaten Purwakarta dan seberapa efektif metode *Artificial Neural Network* (ANN) dalam memprediksi tanah longsor berdasarkan data curah hujan. Batasan dalam penelitian ini adalah fokus pada analisis curah hujan sebagai variabel prediktif dan wilayah penelitian yang terbatas pada Kabupaten Purwakarta. Penelitian ini bertujuan untuk menganalisis karakteristik curah hujan di Kabupaten Purwakarta serta mengimplementasikan metode ANN untuk membangun model prediksi tanah longsor. Diharapkan, hasil dari penelitian ini dapat meningkatkan pemahaman terkait faktor pemicu tanah longsor, memberikan informasi yang berguna bagi pihak terkait dalam mitigasi risiko, serta mengembangkan model prediktif sebagai alat bantu dalamantisipasi tanah longsor.

KERANGKA TEORI

Artificial Neural Network

Artificial Neural Network (ANN) adalah teknik kecerdasan buatan atau pemrosesan data yang memiliki karakteristik yang mirip dengan jaringan saraf biologis dalam proses pemrosesan data, terutama sel otak manusia. Metode ini dapat memecahkan masalah yang kompleks dan memiliki kemampuan belajar mandiri, sehingga memungkinkan Anda mencapai hasil yang lebih baik dengan jumlah data yang ada (Fadhilla et al., 2017).

Prediksi

Menurut Kamus Besar Bahasa Indonesia, prediksi adalah hasil dari proses memprediksi, meramal, atau memperkirakan nilai pada masa yang akan datang dengan menggunakan data dari masa lalu (*Prediksi*, 2016). Untuk mengurangi kesalahan, atau perbedaan antara sesuatu yang terjadi dan hasil perkiraan, prediksi dilakukan secara sistematis untuk memperkirakan apa yang paling mungkin terjadi di masa depan dengan menggunakan informasi yang ada. Prediksi tidak selalu memberikan jawaban pasti untuk kejadian yang akan terjadi; sebaliknya, mereka harus berusaha untuk menemukan jawaban sedekat mungkin (Rohmawati et al., 2017).

Tanah Longsor

Tanah longsor adalah perpindahan bahan yang membentuk lereng, seperti batuan, bahan pembangunan tanah, atau campuran, ke bawah atau keluar lereng (Ginanjari

Bayuaji et al., 2016). Longsor, juga dikenal sebagai gerakan tanah, adalah peristiwa geologi yang disebabkan oleh pergerakan masa batuan atau tanah dari berbagai jenis dan jenis, seperti jatuhnya bebatuan atau gumpalan besar tanah. Tanah longsor merupakan pergerakan cepat dan tiba-tiba dari batuan atau lapisan tanah di lereng atau bukit.

Curah Hujan

Jumlah air hujan yang terkumpul pada permukaan datar tanpa menguap, meresap, atau mengalir disebut curah hujan. Di Indonesia, satuan yang digunakan untuk mengukur curah hujan adalah milimeter (mm), meskipun ukuran umum untuk curah hujan adalah milimeter atau inci. Curah hujan 1 mm berarti 1 meter persegi luas tanah pada tahun dapat menampung 1 mm atau 1 liter air pada tahun (Soewarno, 2015). Pengukuran dapat dilakukan secara langsung dengan mengumpulkan akumulasi air hujan. Namun, pengukuran hanya dapat dilakukan pada titik-titik tertentu yang telah ditentukan oleh alat pengukur hujan. (Triatmodjo, 2008).

METODE PENELITIAN

Sistem yang diusulkan untuk memprediksi potensi kejadian tanah longsor berdasarkan curah hujan dengan menggunakan algoritma *Artificial Neural Network* (ANN), dengan menunjukkan pengaruh curah hujan terhadap kejadian tanah longsor. Alur perancangan sistem yang diusulkan adalah sebagai berikut :



Gambar 1 Flowchart Metode Penelitian

Pengumpulan Data

Pengumpulan data curah hujan historis dan data kejadian tanah longsor di masa lampau. Data ini dapat diperoleh dari berbagai sumber, seperti stasiun meteorologi, Badan Penanggulangan Bencana Daerah (BPBD), dan penelitian ilmiah.

Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari data curah hujan Provinsi Jawa Barat dan data kejadian tanah longsor Kabupaten Purwakarta yang dikumpulkan dari BPBD Kabupaten Purwakarta, dan Badan Meteorologi Bandung melalui website Badan Pusat Statistika. Data curah hujan dan tanah longsor dapat dilihat pada tabel 1 dan tabel 2 :

Tabel 1 Data Curah Hujan Jawa Barat

Tahun	Bulan											
	1	2	3	4	5	6	7	8	9	10	11	12
2022	60	117	239	336	147	151	99	30	182	366	307	278
2023	67	111	200	276	269	90	24	30	18	62	239	365
2024	450	390	355	265	105	165						

Tabel 2 Data Historis Tanah Longsor Kabupate Purwakarta

Tahun	Bulan											
	1	2	3	4	5	6	7	8	9	10	11	12
2022	6	2	4	14	11	8	1	1	4	22	5	8
2023	10	6	9	9	10	4	2	1	5	6	8	10
2024	38	41	13	5	6	1						

Preprocessing

Data perlu dibersihkan dan dipersiapkan sebelum digunakan untuk melatih ANN. Hal ini termasuk menangani nilai yang hilang, normalisasi data, dan transformasi data.

Preprocessing data perlu dilakukan agar value setiap data bisa seimbang. Teknik preprocessing data yang dilakukan mencakup 2 langkah yaitu :

a. Data Cleaning

Data Cleaning merupakan proses perbaikan data yang tidak konsisten atau menghapus kesalahan pada sekumpulan data sekunder yang telah dikumpulkan dari sumber data.

b. Normalisasi Data

Normalisasi data merupakan proses penskalaan nilai atribut dari data agar data memiliki *range* tertentu. Tujuan dari normalisasi data adalah mendapatkan *range* tertentu agar *value* setiap variabel menjadi seimbang. Salah satu metode normalisasi data adalah *Min-Max Normalization*.

1. Membangun Model ANN

Model dan struktur *Artificial Neural Network* (ANN) dirancang agar sesuai dengan bentuk dan pola data yang digunakan dalam penelitian ini. Dalam melakukan perancangan model ANN dilakukan *try and error* untuk mendapatkan parameter yang akan digunakan.

a. *Hidden Layer*

Dimulai dari 1 *hidden layer* dan ditingkatkan secara bertahap. Eksperimen dilakukan dengan 1 hingga 3 *hidden layer*.

b. Jumlah *Neuron* dalam *Hidden Layer*:

Dimulai dari 3 *neuron* dan ditingkatkan hingga 16 *neuron*. Eksperimen dilakukan dengan berbagai kombinasi jumlah *neuron*.

c. *Learning Rate*:

Learning rate menentukan seberapa besar langkah yang diambil model dalam mengupdate bobotnya selama pelatihan. Nilai yang umum digunakan berkisar antara 0.001 hingga 0.1. Eksperimen dilakukan dengan berbagai nilai *learning rate* untuk menemukan yang optimal.

d. *Batch Size*:

Batch size menentukan jumlah sampel yang diproses sebelum model memperbarui bobotnya. Nilai *batch size* yang umum adalah 16, 32, 64, dan 128. Eksperimen dilakukan untuk menemukan *batch size* yang memberikan performa terbaik.

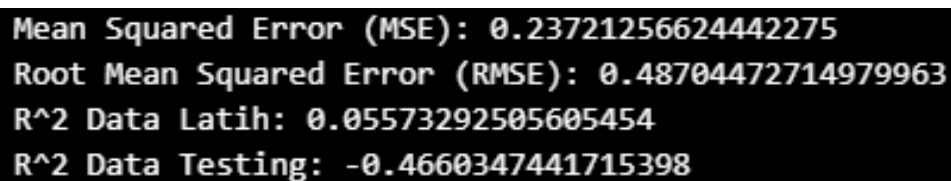
e. Jumlah *Epoch*:

Epoch menentukan berapa kali seluruh *dataset* digunakan untuk melatih model. Eksperimen dilakukan dengan berbagai jumlah *epoch*, misalnya 50, 100, dan 200 *epoch*.

f. Jenis Fungsi Aktivasi:

Fungsi aktivasi yang umum digunakan adalah *ReLU*, *sigmoid*, dan *tanh*. Eksperimen dilakukan untuk menemukan fungsi aktivasi yang paling cocok untuk *dataset* yang digunakan. Pada penelitian ini menggunakan fungsi aktivasi *ReLU*. Berikut adalah model model yang di uji coba :

Model 2 *hidden layer* hasilnya adalah MSE sebesar 0.2372 menunjukkan bahwa model memiliki kesalahan rata-rata kuadrat yang relatif kecil. Koefisien determinasi R^2 sebesar -0.4660 menunjukkan performa buruk, di mana model tidak mampu melakukan generalisasi dan bahkan lebih buruk daripada prediksi sederhana berdasarkan rata-rata. Secara keseluruhan, performa model kurang optimal, terutama dalam memprediksi data baru. Berikut adalah hasil eksperimen pertama :



```
Mean Squared Error (MSE): 0.23721256624442275
Root Mean Squared Error (RMSE): 0.48704472714979963
R^2 Data Latih: 0.05573292505605454
R^2 Data Testing: -0.4660347441715398
```

Gambar 2 Hasil Model 1

Model 3 *neuron* 1 *Hidden layer*, Model ini memiliki *Mean Squared Error* (MSE) sebesar 0.214 dan *Root Mean Squared Error* (RMSE) sebesar 0.463, yang mengindikasikan rata-rata kesalahan prediksi pada data testing cukup rendah. Namun, nilai R^2 pada data latih sebesar 0.255 menunjukkan model hanya mampu menjelaskan sekitar 25.5% variasi dalam data latih, sementara nilai R^2 negatif (-0.325) pada *data testing* menunjukkan model memiliki performa yang sangat buruk di luar data latih, kemungkinan disebabkan oleh *overfitting*. Hal ini berarti model lebih buruk daripada prediksi rata-rata sederhana dalam memprediksi hasil pada *data testing*. Berikut adalah hasil eksperimen kedua :

```
Mean Squared Error (MSE): 0.21437380061466904
Root Mean Squared Error (RMSE): 0.46300518422007875
R^2 Data Latih: 0.2548523293531385
R^2 Data Testing: -0.32488529135246114
```

Gambar 3 Hasil Model 2

Model dengan 0,1 *Learning rate*, Hasil evaluasi model ini menunjukkan angka yang sangat besar untuk *Mean Squared Error* (MSE) ($1.02e+59$) dan *Root Mean Squared Error* (RMSE) ($3.20e+29$), yang menandakan adanya kesalahan prediksi yang sangat ekstrem. Selain itu, nilai R^2 negatif yang sangat besar pada data latih ($-7.51e+60$) dan *data testing* ($-6.33e+59$) menunjukkan bahwa model gagal total dalam memprediksi dengan benar. Kesalahan ini kemungkinan besar disebabkan oleh masalah numerik dalam perhitungan atau penggunaan parameter yang tidak tepat selama pelatihan, yang menyebabkan model tidak konvergen. Berikut adalah hasil eksperimen ketiga:

```
Mean Squared Error (MSE): 1.0239142209331813e+59
Root Mean Squared Error (RMSE): 3.1998659674011054e+29
R^2 Data Latih: -7.505880894145878e+60
R^2 Data Testing: -6.328053554265156e+59
```

Gambar 4 Hasil Model 3

2. Training dan Testing

Artificial Neural Network (ANN) akan dilatih dengan menggunakan data curah hujan dan data kejadian tanah longsor. *Artificial Neural Network* (ANN) akan mempelajari pola dalam data dan membangun model untuk memprediksi potensi terjadinya tanah longsor di masa depan.

Proses pelatihan melibatkan dua langkah utama, yaitu *forward propagation* dan *backward propagation*. Pada *forward propagation*, *input data* melewati lapisan tersembunyi dan *output* untuk menghasilkan prediksi. Fungsi aktivasi *ReLU* digunakan pada lapisan tersembunyi, sedangkan fungsi aktivasi linear digunakan pada lapisan output.

Backward propagation digunakan untuk menghitung error antara prediksi model dan nilai sebenarnya, yang kemudian digunakan untuk memperbarui bobot dan bias melalui optimasi gradien. Pada setiap epoch, loss atau kesalahan dihitung dan dicatat. Model dengan performa terbaik disimpan selama proses pelatihan

3. Prediksi Kejadian

Proses peramalan dilakukan dengan data yang telah dilatih, kemudian sistem akan memproses data dan memberikan hasil peramalan tanah longsor.

4. Hasil dan Evaluasi

Performa model *Artificial Neural Network* ANN perlu dievaluasi dengan menggunakan data yang belum pernah digunakan untuk melatih model. Evaluasi ini akan membantu menentukan akurasi dan keandalan model.

HASIL SKENARIO PENELITIAN

1. Data dibagi menjadi 80% data training dan 20% data testing pada skenario pertama hasil yang didapatkan adalah Model prediktif yang dikembangkan telah dievaluasi menggunakan beberapa metrik kinerja, termasuk Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan R-squared (R^2). Hasil evaluasi menunjukkan

bahwa model memiliki MSE sebesar 0.0263 dan RMSE sebesar 0.1622, yang mengindikasikan kesalahan prediksi yang relatif kecil, serta akurasi yang baik dalam memprediksi kejadian tanah longsor. Nilai R^2 sebesar 0.6339 pada data latih menunjukkan bahwa model dapat menjelaskan sekitar 63.39% dari variabilitas dalam data tanah longsor yang digunakan untuk pelatihan, sementara nilai R^2 sebesar 0.8374 pada data testing menunjukkan bahwa model mampu menjelaskan 83.74% dari variabilitas pada data baru. Perbedaan antara R^2 pada data latih dan testing menunjukkan bahwa model memiliki kemampuan generalisasi yang baik, meskipun masih ada potensi untuk meningkatkan keseimbangan antara performa pelatihan dan generalisasi.

2. Data dibagi menjadi 70% data Training dan 30% data testing, pada skenario kedua hasil yang didapat adalah Evaluasi model prediktif berdasarkan beberapa metrik kinerja menunjukkan bahwa model memiliki Mean Squared Error (MSE) sebesar 0.0875 dan Root Mean Squared Error (RMSE) sebesar 0.2958. MSE yang lebih tinggi dan RMSE yang lebih besar dibandingkan dengan hasil sebelumnya menunjukkan bahwa model mengalami kesalahan prediksi yang lebih signifikan, dan akurasi prediksinya lebih rendah. Nilai R-squared (R^2) sebesar 0.541 pada data latih menunjukkan bahwa model hanya mampu menjelaskan sekitar 54.1% dari variabilitas dalam data tanah longsor yang digunakan untuk pelatihan, sementara nilai R^2 yang lebih rendah sebesar 0.274 pada data testing menunjukkan bahwa model hanya dapat menjelaskan 27.4% dari variabilitas pada data baru yang belum pernah dilihat sebelumnya. Rendahnya nilai R^2 pada data testing, jauh lebih rendah dari nilai pada data latih, menunjukkan bahwa model mungkin mengalami *overfitting*, di mana model terlalu cocok dengan data latih namun gagal untuk menggeneralisasi dengan baik pada data baru. Ini mengindikasikan bahwa model memerlukan penyesuaian lebih lanjut untuk meningkatkan kemampuan prediksinya dan mengurangi kesalahan prediksi, terutama dalam menghadapi data yang belum pernah dilihat sebelumnya.
3. Data dibagi menjadi 90% data training dan 10% data testing, pada skenario ini hasil yang didapatkan adalah Hasil evaluasi model prediktif menunjukkan bahwa model memiliki Mean Squared Error (MSE) sebesar 0.0025 dan Root Mean Squared Error (RMSE) sebesar 0.0497, yang menunjukkan bahwa kesalahan prediksi model relatif kecil dalam hal satuan asli data. Nilai R-squared (R^2) sebesar 0.7603 pada data latih menunjukkan bahwa model dapat menjelaskan sekitar 76.03% dari variabilitas dalam data latih, menandakan bahwa model cukup baik dalam menangkap pola yang ada dalam data yang digunakan untuk pelatihan. Namun, nilai R^2 sebesar 0.1539 pada data testing menunjukkan bahwa model hanya mampu menjelaskan 15.39% dari variabilitas dalam data baru yang belum pernah dilihat sebelumnya. Rendahnya R^2 pada data testing dibandingkan dengan data latih menunjukkan bahwa model mungkin mengalami *overfitting*, dimana model terlalu baik dalam menyesuaikan data latih namun kurang mampu melakukan generalisasi pada data baru. Ini menunjukkan perlunya penyesuaian lebih lanjut pada model, seperti dengan mengurangi kompleksitas model atau menambahkan teknik regularisasi, untuk meningkatkan kemampuannya dalam memprediksi data yang tidak terlihat sebelumnya.

HASIL PENELITIAN

Berdasarkan hasil skenario, dapat disimpulkan bahwa peningkatan proporsi data pelatihan umumnya meningkatkan kinerja model. Pada penelitian ini skenario pertama yaitu 80% data *training* dan 20% data *testing* yang akan digunakan sebagai pelatihan. Parameter yang digunakan yaitu 2 *neuron input layer*, 1 *hidden layer* dengan 16 *neuron*, *learning rate* 0,01, *epoch* 2000 dan *dropout rate* 0,5.

Hasil prediksi potensi tanah longsor untuk 5 bulan kedepan adalah sebagai berikut :

Tabel 3 Hasil Prediksi Potensi Tanah Longsor

No	Bulan	Jumlah Potensi Tanah Longsor
	Agustus 2024	3
	September 2024	4
	Oktober 2024	4
	November 2024	5
	Desember 2024	6

Penelitian ini telah berhasil menganalisis dan memprediksi potensi tanah longsor di Kabupaten Purwakarta menggunakan metode Artificial Neural Network (ANN). Berdasarkan hasil penelitian, dapat disimpulkan beberapa poin penting sebagai berikut:

Curah hujan terbukti menjadi faktor signifikan yang mempengaruhi potensi tanah longsor di Kabupaten Purwakarta. Analisis data menunjukkan bahwa curah hujan yang tinggi dapat meningkatkan risiko terjadinya tanah longsor, terutama ketika curah hujan melebihi ambang batas tertentu yang dapat mengganggu kestabilan tanah.

Metode *Artificial Neural Network* (ANN) mampu digunakan dengan baik dalam memprediksi potensi tanah longsor berdasarkan data curah hujan. Berdasarkan dari 3 skenario pembagian data yang digunakan pada penelitian ini didapatkan R^2 sebesar 0.8374 pada data testing menunjukkan bahwa model mampu menjelaskan 83.74% dari variabilitas pada data baru dengan pembagian data 80% data training dan 20 % data testing.

Secara keseluruhan, hasil penelitian ini mendukung penggunaan ANN sebagai metode yang efektif dalam peramalan bencana tanah longsor dan menekankan pentingnya pemantauan curah hujan dalam mitigasi risiko bencana. Penelitian ini juga membuka peluang untuk penelitian lebih lanjut yang dapat memperluas aplikasi metode ANN pada bencana alam lainnya dan di wilayah lain yang memiliki karakteristik geologis serupa.

DAFTAR PUSTAKA

- BPBD JABAR. (n.d.). Retrieved November 18, 2023, from <https://bpbd.jabarprov.go.id/s=%3Evisi-dan-misi>
- Fadhilla, M., Saf, M. R. A., & Sahid, D. S. S. (2017). Pengenalan kepribadian seseorang berdasarkan pola tulisan tangan menggunakan jaringan saraf tiruan. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 6(3), 365–373.
- Ginanjari Bayuaji, D., Laila Nugraha, A., & Sukmono, A. (2016). ANALISIS PENENTUAN ZONASI RISIKO BENCANA TANAH LONGSOR BERBASIS SISTEM INFORMASI GEOGRAFIS (Studi Kasus : Kabupaten Banjarnegara). In *Jurnal Geodesi Undip Januari* (Vol. 5, Issue 1).

Guha, S., Jana, R. K., & Sanyal, M. K. (2022). Artificial neural network approaches for disaster management: A literature review. *International Journal of Disaster Risk Reduction*, 81, 103276.

Prediksi. (2016). <https://kbbi.kemdikbud.go.id/entri/prediksi>.

Rohmawati, F., Rohman, M. G., & Mujilawati, S. (2017). Sistem Prediksi Jumlah Pengunjung Wisata Wego Kec. Sugio Kab. Lamongan Menggunakan Metode Fuzzy Time Series. *Joutica: Journal of Informatic Unisla*, 2(2).

Soewarno, K. (2015). Pengukuran dan Pengolahan Data Curah Hujan, Contoh Aplikasi Hidrologi Dalam Pengelolaan Sumber Daya Air. *Yogyakarta: Graha Ilmu*.

Triatmodjo, B. (2008). *Hidrologi Terapan (Yogyakarta: Beta Offset)*.