

# Penggunaan Metode *Artificial Neural Network* dalam Pembuatan Peta Kerentanan Longsor Wilayah Kabupaten Karanganyar

Atila Salwa<sup>1\*)</sup> Raden Harya Dananjaya<sup>2)</sup> Niken Silmi Surjandari<sup>3)</sup>

<sup>1,2,3)</sup> Fakultas Teknik, Program Studi Teknik Sipil, Universitas Sebelas Maret, Surakarta, Jl. Ir. Sutami, No.36A, Kentingan, Surakarta; Telp. 0271-634524. Email: campus@mail.uns.ac.id

Email:atillasalwa@gmail.com

## Abstrak

Tanah longsor menjadi bencana alam yang marak terjadi di Indonesia. Selama sepuluh tahun terakhir terdapat 2975 kejadian tanah longsor yang terjadi di Jawa Tengah, di mana 101 kejadian tanah longsor berada di Kabupaten Karanganyar. Penelitian ini bertujuan untuk membuat peta kerentanan longsor pada wilayah Kabupaten Karanganyar. Peta kerentanan akan dibagi menjadi lima kelas, yaitu sangat rendah, rendah, sedang, tinggi dan sangat tinggi dengan menggunakan metode *natural breaks* (jenk's). Penelitian ini menggunakan 9 faktor pengondisi longsor yaitu jarak terhadap jalan sekunder, jarak terhadap jalan tersier, *slope*, *topographic wetness index* (TWI), elevasi, tata guna lahan (*landuse*), litologi, *normalized difference vegetation index* (NDVI), dan hujan. Pembuatan peta dilakukan dengan menggunakan *Artificial Neural Network* dengan bantuan modul *scikit learn* dan metode *ten-folds cross validation* digunakan sebagai metode validasi model yang dihasilkan. Nilai *landslide density* dihitung pada penelitian ini untuk evaluasi performa dari hasil klasifikasi kerentanan longsor. Parameter *machine learning* yang digunakan pada penelitian ini adalah *hidden layer sizes*, *activation*, *maximum iteration* dan *random state*. Performa model *Artificial Neural Network* yang dihasilkan menggunakan parameter tersebut menunjukkan hasil yang *excellent*. Nilai AUC yang didapat pada penelitian ini sebesar 0,9140 dengan nilai *ten-folds cross validation* 0,7444.

**Kata kunci:** *Artificial Neural Network* (ANN), Peta Kerentanan Longsor, *Ten-folds cross validation*

## Abstract

*Landslides are a frequent natural disaster in Indonesia. During the last ten years, 2975 landslides occurred in Central Java, of which 101 landslides were in Karanganyar Regency. This study aims to make a landslide vulnerability map in the Karanganyar Regency area. The vulnerability map will be divided into five classes, namely very low, low, medium, high and very high using the natural breaks (jenk's) method. This study used 9 landslide conditioning factors, namely distance to secondary roads, distance to tertiary roads, slope, topographic wetness index (TWI), elevation, landuse, lithology, normalized difference vegetation index (NDVI), and rain. Map making is done using an Artificial Neural Network with the help of the scikit learn module and the ten-folds cross validation method is used as a validation method for the resulting model. The landslide density value was calculated in this study to evaluate the performance of the landslide susceptibility classification results. The machine learning parameters used in this research are hidden layer sizes, activation, maximum iteration and random state. The Artificial Neural Network model performance generated using these parameters showed excellent results. The AUC value obtained in this study was 0,9140 with a ten-fold cross validation value of 0,7444.*

**Keywords:** *Artificial Neural Network* (ANN), *Landslide Vulnerability Map*, *Ten-folds cross validation*



Copyright © 2024 The Author(s)

This is an open access article under the [CC-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.

## 1. PENDAHULUAN

Bencana tanah longsor masih marak terjadi di Kabupaten Karanganyar. Hal ini dikarenakan curah hujan yang tinggi dan juga topografi yang curam. Berdasarkan data yang dimiliki Badan Nasional Penanggulangan Bencana, selama sepuluh tahun terakhir terdapat 2975 kejadian tanah longsor yang terjadi di Jawa Tengah, di mana 101 kejadian tanah longsor berada di

Kabupaten Karanganyar (BNPB, 2023). Pemetaan wilayah kerentanan longsor dapat menjadi salah satu bentuk mitigasi bencana tanah longsor. Upaya mitigasi dengan pemetaan wilayah kerentanan longsor di wilayah Kabupaten Karanganyar telah dilakukan oleh Marzuki (2021) dengan menggunakan metode *machine learning* yaitu *Support Vector Machine* (SVM). Penelitian Marzuki (2021)

hanya menggunakan lima kecamatan yang berada di Kabupaten Karanganyar sebagai objek penelitian.

Penelitian Pascale dkk.(2013) menggunakan metode *Artificial Neural Network* untuk membuat peta kerentanan longsor dengan lima kelas klasifikasi yaitu sangat rendah, rendah, sedang, tinggi dan sangat tinggi. Penelitian Pascale dkk. (2013) menjelaskan bahwa penggunaan metode *Artificial Neural Network* dapat menjadi solusi yang relatif sederhana untuk memecahkan masalah yang kompleks termasuk yang berkaitan dengan estimasi kerentanan tanah longsor. Penelitian W. Chen dkk. (2017) membandingkan penggunaan metode *machine learning Artificial Neural Network* dengan metode SVM dan MaxEnt dalam membuat model kerentanan longsor. Penelitian W. Chen dkk. (2017) menyebutkan bahwa metode ANN mendapatkan nilai AUC tertinggi dibandingkan dengan dua metode lainnya dengan nilai 0.824. Penelitian Ortiz & Martínez-Graña (2018) dengan judul *A neural network model applied to landslide susceptibility analysis* mengambil wilayah studi di Capitanejo, Colombia. Penelitian Ortiz & Martínez-Graña (2018) menggunakan metode *Artificial Neural Network*. Hasil simulasi pada model ANN menunjukkan AUC dari kurva ROC dengan nilai spesifisitas terhadap sensitivitas model sebesar 0,988. Metode *Artificial Neural Network* juga digunakan pada penelitian Selamat dkk. (2022), dimana pada penelitian ini menghasilkan model yang bagus dengan nilai AUC sebesar 0,940.

Tujuan dilakukannya penelitian ini adalah membuat peta kerentanan longsor dengan lima kelas klasifikasi yaitu sangat rendah, rendah, sedang, tinggi, dan sangat tinggi. Metode *machine learning* yang digunakan adalah *Artificial Neural Network* karena relatif sederhana untuk memecahkan masalah yang kompleks (Pascale dkk.,2013). Berdasarkan penelitian W. Chen dkk. (2017), Ortiz & Martínez-Graña (2018), dan Selamat dkk. (2022), metode *Artificial Neural Network* menghasilkan nilai AUC yang baik yaitu berkisar 0,8 hingga 0,9. Pada penelitian kali ini metode validasi model yang digunakan yaitu menggunakan *ten-folds cross validation* yang akan diterapkan pada model ANN terbaik.

### Faktor Pengondisi Penyebab Longsor

Penelitian yang dilakukan He dkk. (2019) menjelaskan mengenai 14 faktor pengondisi yang dinilai berpengaruh pada penyebab kejadian longsor. Penelitian yang dilakukan Fitria (2021) mengeliminasi faktor pengondisi yang telah diteliti sebelumnya menjadi 9 faktor pengondisi. Faktor-faktor tersebut adalah Jarak titik longsor terhadap Jalan Sekunder, Jarak titik longsor terhadap Jalan Tersier, *Slope*, *Topographic Wetness Index (TWI)*, Elevasi, Tata Guna Lahan (*Landuse*), Litologi, *Normalized Difference Vegetation Index (NDVI)*, dan Hujan.

Jarak terhadap jalan menjadi faktor pengondisi yang dinilai dapat menyebabkan longsor. Aktivitas kendaraan yang melewati jalan dapat menyebabkan peningkatan regangan di belakang lereng dan mengakibatkan retakan pada kaki lereng (He dkk.,2019). Semakin dekat jarak suatu lereng terhadap jalan raya, semakin besar angka penyimpangan stabilitas sehingga semakin besar kemungkinan terjadi tanah longsor (Sun dkk., 2022).

*Slope* dinilai menjadi faktor yang berpengaruh terhadap terjadinya longsor. Arah kemiringan lereng mengindikasikan seberapa banyak sisi lereng tersebut mendapatkan sinar matahari, paparan angin, dan turunan air hujan. Pada penelitian yang telah dilakukan sebelumnya, lereng yang mendapatkan paparan sinar matahari yang tinggi cenderung lebih stabil dibandingkan dengan lereng dengan paparan sinar matahari yang rendah (Sharifi Teshnizi dkk., 2022).

*Topographic Wetness Index (TWI)* adalah topografi yang memengaruhi angka kadar air tanah yang mengontrol arah aliran air tanah (Meinhardt dkk., 2015). Nilai TWI yang tinggi mengindikasikan tingginya kandungan air tanah, dimana tanah dengan kandungan air yang tinggi lebih rentan terhadap longsor (Zhou dkk., 2021).

Elevasi adalah salah satu faktor pengondisi yang banyak digunakan dalam pemetaan kerentanan longsor. Daerah perbukitan dan pegunungan memiliki perbedaan nilai elevasi yang cenderung besar, dan di daerah ini pula longsor sering terjadi. Tanah longsor rawan terjadi di daerah yang mengalami perubahan elevasi secara signifikan (Liao dkk., 2022).

Tata guna lahan adalah faktor pengondisi yang menjelaskan hubungan antara potensi kejadian

longsor dengan tipe penggunaan lahan. Perluasan daerah tempat tinggal dan pembangunan infrastruktur menjadi salah satu penyebab longsor karena melibatkan kegiatan pemotongan atau penggalian lereng untuk jalan raya dan bangunan sehingga mengganggu stabilitas lereng (Youssef & Pourghasemi, 2021).

Litologi dari suatu daerah mengindikasikan perbedaan propertis fisik dan kimiawi suatu batuan yang dapat memengaruhi stabilitas lereng. Secara umum, daerah dengan permeabilitas suatu massa batuan yang rendah memiliki potensi yang lebih tinggi terhadap longsor (Zhou dkk., 2021).


Nilai NDVI menunjukkan karakteristik pertumbuhan vegetasi dan tutupan vegetasi suatu daerah. Nilai NDVI berkisar antara -1 hingga 1. (Youssef & Pourghasemi, 2021).

Intensitas hujan suatu daerah memengaruhi proses infiltrasi air hujan ke dalam tanah, dimana proses infiltrasi tersebut mengubah tekanan air pori dan melemahkan tegangan tanah. Hal ini menyebabkan penurunan kekuatan geser tanah sehingga menyebabkan terjadinya tanah longsor (Zhao dkk., 2022).

### Artificial Neural Network (ANN)

*Artificial Neural Network* (ANN) didefinisikan sebagai mekanisme komputasi yang dapat memperoleh, merepresentasikan, dan menghitung pemetaan dari satu ruang multivariat informasi ke ruang informasi multivariat lainnya, dengan memberikan sekumpulan data yang mewakili pemetaan tersebut. *Artificial Neural Network* terinspirasi dari jaringan syaraf manusia yang memiliki *neurons* atau *nodes* yang saling terhubung satu sama lain (Merghadi dkk., 2020).

*Multilayered Perceptron* (MLP) adalah salah satu arsitektur ANN yang paling umum digunakan. MLP terdiri dari tiga lapisan yaitu *input layer*, *hidden layer*, dan *output layer*. Setiap lapisan pada MLP memiliki *neurons* yang saling berhubungan satu sama lain. *Input layer* menerima data atau memasukan data, sedangkan *ouput layer* mengeluarkan hasil akhir. *Hidden layer* terdapat diantara *input layer* dan *output layer* yang berfungsi untuk membuat prediksi atau belajar mengenai data (Dastres & Soori, 2021). Gambar 1 menunjukkan bagaimana *Multilayered Perceptron* (MLP) bekerja.



Gambar 1. *Multilayered Perceptron* (MLP), Bre dkk. (2018)

### Receiver Operating Characteristics Curve (ROC Curve) dan Area Under the Curve (AUC)

*Receiver Operating Characteristics Curve* (ROC Curve) merupakan suatu metode untuk memverifikasi peta kerentanan longsor yang menunjukkan sensitivitas pada sumbu vertikal dan 1-spesifisitas pada sumbu horizontal (Akinci, 2022). ROC Curve menghasilkan suatu kurva yang mengindikasikan nilai akurasi suatu model yang disebut area di bawah kurva (*Area Under the Curve/AUC*). Nilai AUC pada data *training* menunjukkan keberhasilan prediksi suatu model pada variabel yang diteliti, sedangkan nilai AUC pada data *testing* menunjukkan kemampuan prediksi suatu model. Nilai AUC berada di antara angka 0 dan 1 sehingga jika nilai AUC mendekati 1 maka prediksi yang dapat dilakukan suatu model semakin baik (Sun dkk., 2022). Kategori klasifikasi nilai AUC terhadap performa model yang merujuk pada Hammad Khaliq dkk (2022) ditunjukkan pada Tabel 1.

Tabel 1. Kategori klasifikasi performa model berdasarkan nilai AUC

Nilai AUC	Kategori Performa Model
0,90 – 1,00	<i>Excellent</i>
0,80 – 0,90	<i>Good</i>
0,70 – 0,80	<i>Fair</i>
0,60 – 0,70	<i>Poor</i>
0,50 – 0,60	<i>Fail</i>

### Natural Breaks (Jenk's)

*Natural Breaks* (Jenk's) merupakan sebuah metode klasifikasi yang dirancang untuk menentukan susunan nilai terbaik ke dalam kelas yang berbeda. *Natural Breaks* berusaha untuk meminimalkan variasi dalam kelompok dan memaksimalkan variasi antar kelompok. Dengan kata lain, metode *Natural Breaks* berusaha untuk mengurangi variasi dalam kelas (J. Chen dkk., 2013).

## 2. METODE

### Pengumpulan Data

Penelitian ini dimulai dengan mengumpulkan data sekunder berupa peta dalam bentuk raster dan *vector*. Data yang digunakan pada penelitian ini bersumber dari *website* dan juga penelitian yang telah dilakukan sebelumnya. Data yang ada nantinya akan diolah menjadi sembilan peta faktor pengondisi longsor dan satu peta *inventory longsor*. Tabel 2 menunjukkan peta – peta yang digunakan beserta sumbernya.

Tabel 2. Peta - peta yang digunakan sebagai bahan penelitian

Nama Peta	Format Peta	Sumber
Peta <i>Landslide Inventory</i>	Vektor	Priyono dkk.(2020)
Peta ASTER GDEM	Raster	NASA (2013)
Peta Data TRMM	Raster	NASA (2020)
Peta Data MODIS	Raster	NASA (2022)
Peta Geologi	Vektor	PT. Indonesia Geospasial Tech (2020)
Peta <i>Landuse</i>	Vektor	Priyono dkk.(2020)
Peta Jalan Indonesia	Vektor	Priyono dkk.(2020)

### Pembuatan dan Validasi Model

Pembuatan model ANN dibantu dengan modul *sci-kit learn* yaitu *MLPClassifier*. Pembuatan model dilatih dengan menggunakan data *training* dengan proporsi data *training* 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, dan 90%. Penelitian ini menggunakan metode *Ten-folds cross validation* sebagai metode validasi model. Metode *Ten-folds cross validation* membagi data *training* menjadi 10 bagian data (*folds*) dan dilakukan *training* pada 9 bagian data pertama dan *testing* dengan 1 bagian data sisanya. Proses tersebut dilakukan secara

bergiliran dengan mengambil 1 bagian data secara bergantian pada setiap skenario *training* dan *testing*.

### Pembuatan Peta Prediksi Kerentanan Longsor

Peta prediksi kerentanan longsor dibuat berdasarkan model ANN yang mendapatkan nilai validasi terbaik yang telah diuji dan disimpan. Pengklasifikasian menggunakan *Natural Breaks* menggunakan pemrograman *python* dengan menghasilkan lima kelas klasifikasi yaitu sangat rendah, rendah, sedang, tinggi, dan sangat tinggi. Hasil dari pengklasifikasian nantinya akan ditampilkan didalam aplikasi QGIS.

### Perhitungan *Landslide Density*

Performa dari hasil klasifikasi kerentanan longsor perlu dievaluasi. Cara untuk mengevaluasinya dengan menghitung nilai *landslide density*. Persamaan *landslide density* ditunjukkan pada Persamaan (1).

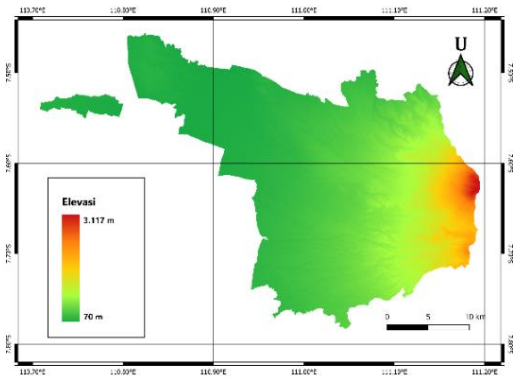
$$LD = \frac{\text{total piksel longsor dalam satu kelas kerentanan}}{\text{total piksel satu kelas kerentanan}} \quad (1)$$

LD adalah nilai *landslide density*. Nilai *landslide density* didapat dari perbandingan antara persentase total piksel longsor dalam satu kelas kerentanan dengan total piksel untuk satu kelas kerentanan. Hasil visualisasi klasifikasi dikatakan bagus jika nilai *landslide density* yang dihasilkan meningkat seiring dengan meningkatnya kelas kerentanan (Pham dkk., 2016).

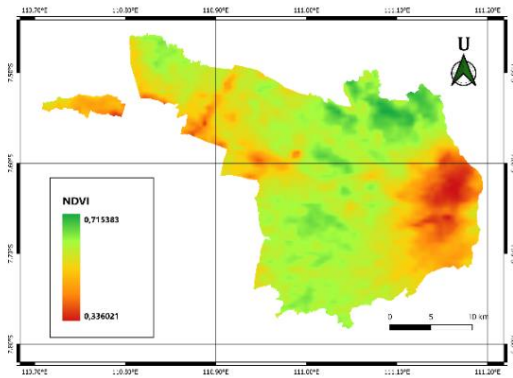
## 3. HASIL DAN PEMBAHASAN

### Pengolahan Data

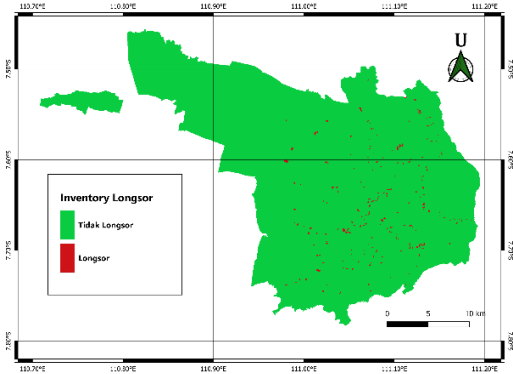
Data yang dikumpulkan pada penelitian ini diolah menggunakan bantuan *script* dan aplikasi GIS seperti GRASS GIS dan juga QGIS. Pengolahan data sekunder menghasilkan sembilan peta faktor pengondisi dan satu peta *inventory longsor*. Gambar 2 hingga Gambar 11 merupakan hasil visualisasi data yang menghasilkan sembilan peta faktor pengondisi dan satu peta *inventory longsor*.



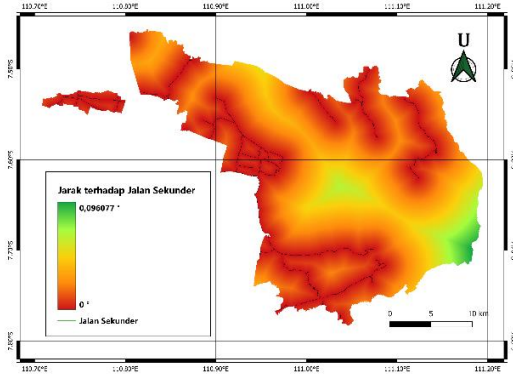
Gambar 2. Peta elevasi



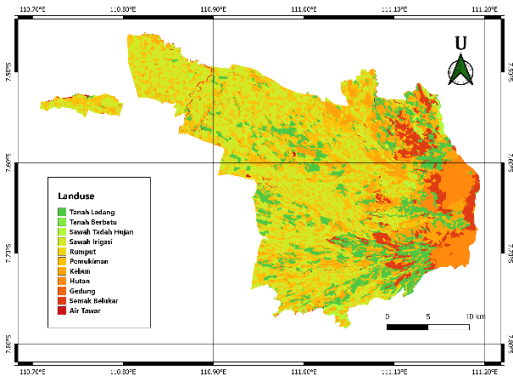
Gambar 6. Peta NDVI



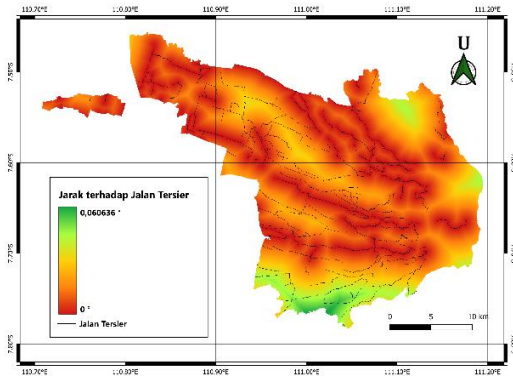
Gambar 3. Peta *inventory* longsor



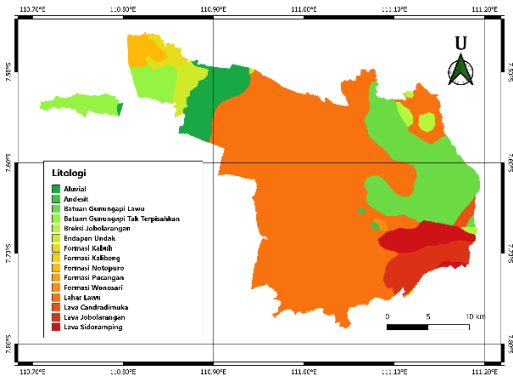
Gambar 7. Peta jarak terhadap jalan sekunder



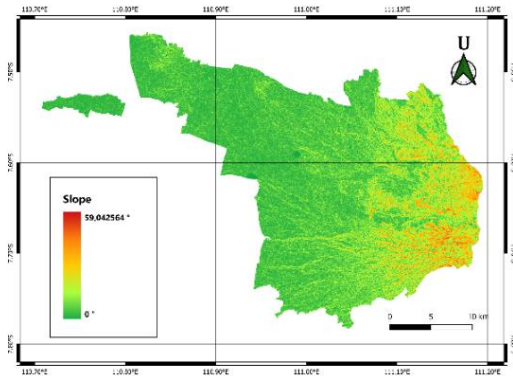
Gambar 4. Peta *landuse*



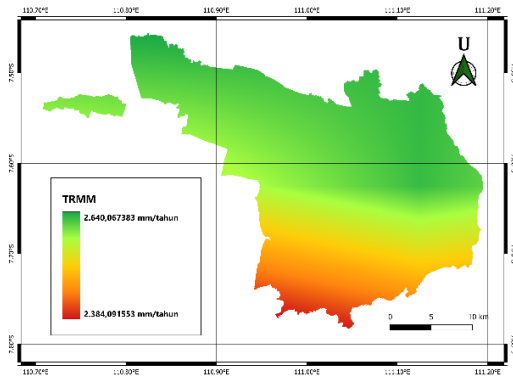
Gambar 8. Peta jarak terhadap jalan tersier



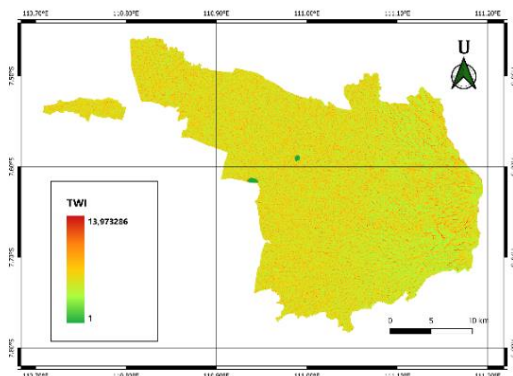
Gambar 5. Peta litologi



Gambar 9. Peta *slope*



Gambar 10. Peta TRMM



Gambar 11. Peta TWI

### Kombinasi Parameter

Penelitian ini menggunakan pendekatan *trial and error* dalam penentuan parameter yang akan digunakan. Parameter yang digunakan pada penelitian ini adalah *hidden layer sizes* diatur dengan satu *hidden layer* dengan 200 *nodes*, *activation* yang digunakan adalah *tanh* dan *maximum iteration* yang digunakan adalah 2000. Penelitian ini menggunakan perbandingan komposisi data *training* dan data *testing* adalah 80 : 20. Komposisi data longsor dan tidak longsor yang digunakan pada penelitian ini adalah 5557:8891 yaitu 5557 data longsor dan 8891 data tidak longsor.

### Validasi Model

Seluruh kombinasi parameter yang ada dilatih dengan menggunakan data *training* dengan proporsi yang ditentukan. Model yang dihasilkan akan diuji menggunakan data *testing*. Setelah proses pembelajaran selesai akan dilakukan validasi model menggunakan *ten-folds cross validation*. Model yang dihasilkan menggunakan parameter yang ditentukan menghasilkan nilai AUC 0.9140 dan *nilai ten-folds cross validation* 0.7444 yang nantinya akan digunakan pada pembuatan peta kerentanan wilayah longsor.

### Batas Kelas Kerentanan

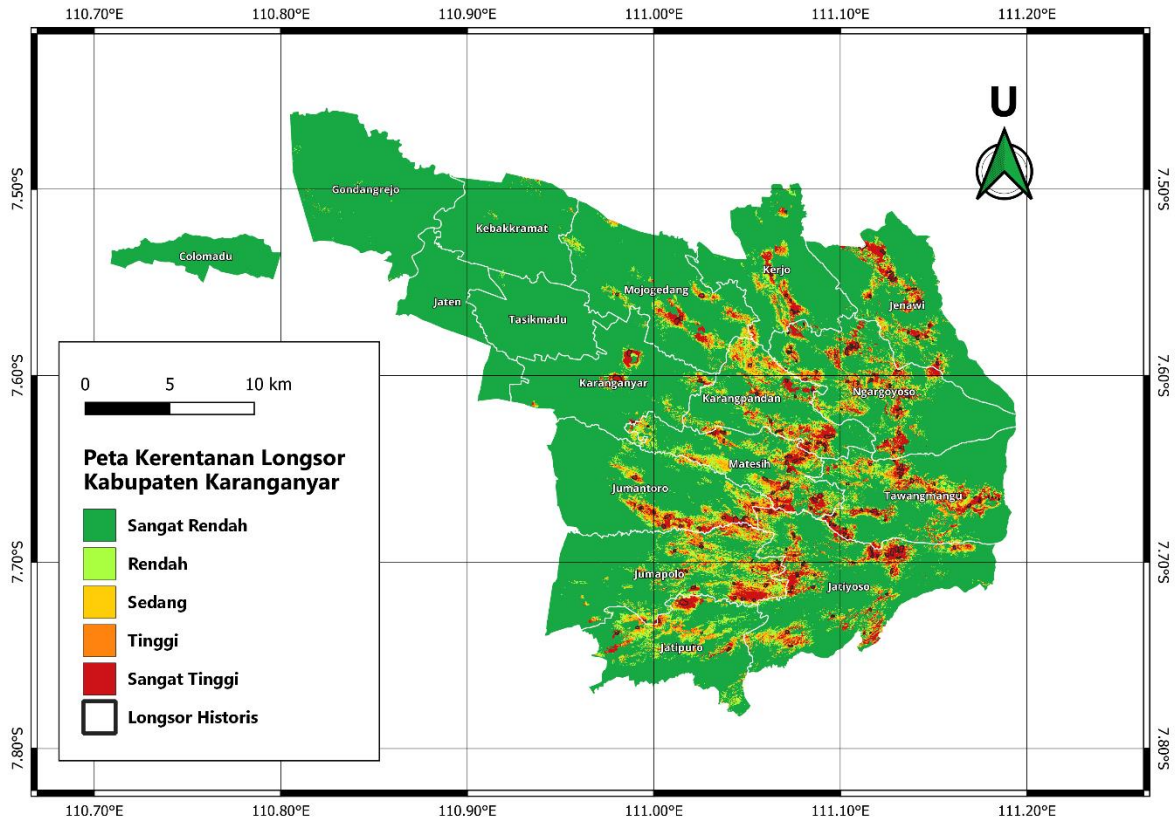
Penelitian ini mengklasifikasikan wilayah kerentanan menjadi lima kelas yaitu sangat rendah, rendah, sedang, tinggi dan sangat tinggi. Pembagian kelas ini menggunakan bantuan metode *natural breaks* (jenk's). Hasil batas kelas kerentanan dapat dilihat pada Tabel 3.

Tabel 3. Hasil batas kelas kerentanan

Klasifikasi longsor	Nilai Kelas
Sangat rendah	0,0000 - 0,0859
Rendah	0,0859 - 0,2826
Sedang	0,2826 - 0,5325
Tinggi	0,5325 - 0,7938
Sangat Tinggi	0,7938 - 1,0000

### Hasil Peta Prediksi Wilayah Kerentanan Longsor

Model yang dihasilkan menggunakan metode *Artificial Neural Network* akan olah menjadi peta kerentanan longsor pada wilayah Kabupaten Karanganyar. Pembuatan peta menggunakan bantuan aplikasi QGIS dan menghasilkan peta seperti yang ditunjukkan pada Gambar 12.



Gambar 12. Peta hasil prediksi kerentanan longsor Kabupaten Karanganyar dengan metode ANN

### Hasil Perhitungan *Landslide Density*

Hasil perhitungan *landslide density* ditunjukkan pada Tabel 4 dengan menggunakan persamaan (1).

Tabel 4. Hasil perhitungan *landslide density*

Klasifikasi longsor	<i>Landslide density</i>
Sangat rendah	0,0000
Rendah	0,0009
Sedang	0,0057
Tinggi	0,0251
Sangat Tinggi	0,1006

Dari hasil perhitungan *landslide density*, dapat dilihat bahwa hasil visualisasi kelas kerentanan longsor menunjukkan hasil yang baik. Hal ini ditandai dengan semakin tinggi kelas kerentanan longsor maka semakin tinggi pula nilai *landslide density*.

## 4. SIMPULAN

Pada penelitian ini dapat diambil kesimpulan sebagai berikut :

1. Performa model yang dihasilkan dengan menggunakan metode *Artificial Neural*

*Network* pada penelitian ini menunjukkan hasil yang *excellent* yaitu nilai AUC berkisar antara 0.9 hingga 1. Nilai AUC yang didapatkan dari parameter yang digunakan adalah 0.9140 dengan Nilai *ten-folds cross validation* 0.7444.

2. Hasil visualisasi peta yang dihasilkan pada penelitian ini dianggap baik dikarenakan nilai *landslide density* yang dihasilkan meningkat seiring dengan meningkatnya kelas kerentanan.

## 5. UCAPAN TERIMA KASIH

Terima kasih penulis ucapkan untuk orang tua dan keluarga karena selalu mendoakan dan memberikan semangat kepada penulis. Terima kasih penulis ucapkan untuk kelompok penelitian yang sangat membantu penulis hingga akhir. Ucapan terima kasih penulis sampaikan juga kepada seluruh pihak yang telah membantu penulis sehingga penelitian ini dapat berjalan dengan baik.

## 6. DAFTAR PUSTAKA

- Akinci, H. (2022). Assessment of rainfall-induced landslide susceptibility in Artvin, Turkey using machine learning techniques. *Journal of African Earth Sciences*, 191(April), 104535. <https://doi.org/10.1016/j.jafrearsci.2022.104535>
- BNPB. (2023). *Geoportal Data Bencana Indonesia*. <https://gis.bnpb.go.id/>
- Bre, F., Gimenez, J. M., & Fachinotti, V. D. (2018). Prediction of wind pressure coefficients on building surfaces using artificial neural networks. *Energy and Buildings*, 158, 1429–1441. <https://doi.org/10.1016/j.enbuild.2017.11.045>
- Chen, J., Yang, S., Li, H., Zhang, B., & Lv, J. (2013). Research on geographical environment unit division based on the method of natural breaks (Jenks). *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 40(4W3), 47–50. <https://doi.org/10.5194/isprsarchives-XL-4-W3-47-2013>
- Chen, W., Pourghasemi, H. R., Kornejady, A., & Zhang, N. (2017). Landslide spatial modeling: Introducing new ensembles of ANN, MaxEnt, and SVM machine learning techniques. *Geoderma*, 305, 314–327. <https://doi.org/10.1016/J.GEODERMA.2017.06.020>
- Dastres, R., & Soori, M. (2021). Artificial Neural Network Systems. *International Journal of Imaging and Robotics*, 21(2). [https://www.researchgate.net/publication/350486076\\_Artificial\\_Neural\\_Network\\_Systems](https://www.researchgate.net/publication/350486076_Artificial_Neural_Network_Systems)
- Fitria, I. (2021). *Eliminasi Faktor pada Model Pemetaan Risiko Kerentanan Longsor Berbasis Sistem Kecerdasan Buatan*. Universitas Sebelas Maret.
- Hammad Khaliq, A., Basharat, M., Talha Riaz, M., Tayyib Riaz, M., Wani, S., Al-Ansari, N., Ba Le, L., & Thi Thuy Linh, N. (2022). Spatio-temporal landslide susceptibility mapping using machine learning models: A case study from district Hattian Bala, NW Himalaya, Pakistan. *Ain Shams Engineering Journal*, xxx, 101907. <https://doi.org/10.1016/j.asej.2022.101907>
- He, Q., Shahabi, H., Shirzadi, A., Li, S., Chen, W., Wang, N., Chai, H., Bian, H., Ma, J., Chen, Y., Wang, X., Chapi, K., & Ahmad, B. Bin. (2019). Landslide spatial modelling using novel bivariate statistical based Naïve Bayes, RBF Classifier, and RBF Network machine learning algorithms. *Science of the Total Environment*, 663, 1–15. <https://doi.org/10.1016/j.scitotenv.2019.01.329>
- Liao, M., Wen, H., & Yang, L. (2022). Identifying the essential conditioning factors of landslide susceptibility models under different grid resolutions using hybrid machine learning: A case of Wushan and Wuxi counties, China. *Catena*, 217(October 2021), 106428. <https://doi.org/10.1016/j.catena.2022.106428>
- Marzuki, T. (2021). *Pembuatan Script Pemetaan Wilayah Resiko Kerentanan Longsor Berbasis Sistem Kecerdasan Buatan*. Universitas Sebelas Maret.
- Meinhardt, M., Fink, M., & Tünschel, H. (2015). Landslide susceptibility analysis in central Vietnam based on an incomplete landslide inventory: Comparison of a new method to calculate weighting factors by means of bivariate statistics. *Geomorphology*, 234, 80–97. <https://doi.org/10.1016/j.geomorph.2014.12.042>
- Merghadi, A., Yunus, A. P., Dou, J., Whiteley, J., ThaiPham, B., Bui, D. T., Avtar, R., & Abderrahmane, B. (2020). Machine learning methods for landslide susceptibility studies: A comparative overview of algorithm performance. *Earth-Science Reviews*, 207(September 2019), 103225. <https://doi.org/10.1016/j.earsci-rev.2020.103225>
- NASA. (2013). *Earthdata Search | Earthdata Search*. <https://search.earthdata.nasa.gov/search>
- NASA. (2020). *GES DISC*. <https://disc.gsfc.nasa.gov/>
- NASA. (2022). *MODIS Web*. <https://modis.gsfc.nasa.gov/>
- Ortiz, J. A. V., & Martínez-Graña, A. M. (2018). A neural network model applied to landslide susceptibility analysis (Capitanejo, Colombia). *Geomatics, Natural Hazards and Risk*, 9(1), 1106–1128. <https://doi.org/10.1080/19475705.2018.1513083>
- Pascale, S., Parisi, S., Mancini, A., Schiattarella, M., Conforti, M., Sole, A., Murgante, B., & Sdao, F. (2013). Landslide susceptibility mapping using artificial neural network in the urban area of Senise and San Costantino Albanese (Basilicata, Southern Italy). *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7974 LNCS(PART 4), 473–488. [https://doi.org/10.1007/978-3-642-39649-6\\_34](https://doi.org/10.1007/978-3-642-39649-6_34)
- Pham, B. T., Pradhan, B., Tien Bui, D., Prakash, I., & Dholakia, M. B. (2016). A comparative study of different machine learning methods for landslide susceptibility assessment: A case study of Uttarakhand area (India). *Environmental Modelling and Software*, 84, 240–250. <https://doi.org/10.1016/j.envsoft.2016.07.005>



- Priyono, K. D., Jumadi, Saputra, A., & Fikriyah, V. N. (2020). Risk analysis of landslide impacts on settlements in Karanganyar, Central Java, Indonesia. *International Journal of GEOMATE*, 19(73), 100–107. <https://doi.org/10.21660/2020.73.34128>
- PT. Indonesia Geospasial Tech. (2020). [√ Download Shapefile Geologi Seluruh Indonesia - INDONESIA GEOSPASIAL](https://www.indonesia-geospasial.com/2020/03/download-data-shapefile-shp-geologi-se.html). <https://www.indonesia-geospasial.com/2020/03/download-data-shapefile-shp-geologi-se.html>
- Selamat, S. N., Majid, N. A., Taha, M. R., & Osman, A. (2022). Landslide Susceptibility Model Using Artificial Neural Network (ANN) Approach in Langat River Basin, Selangor, Malaysia. *Land*, 11(6). <https://doi.org/10.3390/land11060833>
- Sharifi Teshnizi, E., Golian, M., Sadeghi, S., & Rastegarnia, A. (2022). Application of analytical hierarchy process (AHP) in landslide susceptibility mapping for Qazvin province, N Iran. *Computers in Earth and Environmental Sciences*, 55–95. <https://doi.org/10.1016/B978-0-323-89861-4.00041-5>
- Sun, D., Gu, Q., Wen, H., Xu, J., Zhang, Y., Shi, S., Xue, M., & Zhou, X. (2022). Assessment of landslide susceptibility along mountain highways based on different machine learning algorithms and mapping units by hybrid factors screening and sample optimization. *Gondwana Research*, xxx. <https://doi.org/10.1016/j.gr.2022.07.013>
- Youssef, A. M., & Pourghasemi, H. R. (2021). Landslide susceptibility mapping using machine learning algorithms and comparison of their performance at Abha Basin, Asir Region, Saudi Arabia. *Geoscience Frontiers*, 12(2), 639–655. <https://doi.org/10.1016/j.gsf.2020.05.010>
- Zhao, L., Liu, M., Song, Z., Wang, S., Zhao, Z., & Zuo, S. (2022). Regional-scale modeling of rainfall-induced landslides under random rainfall patterns. *Environmental Modelling and Software*, 155(February), 105454. <https://doi.org/10.1016/j.envsoft.2022.105454>
- Zhou, X., Wen, H., Zhang, Y., Xu, J., & Zhang, W. (2021). Landslide susceptibility mapping using hybrid random forest with GeoDetector and RFE for factor optimization. *Geoscience Frontiers*, 12(5), 101211. <https://doi.org/10.1016/j.gsf.2021.101211>