

# Optimalisasi Model *Artificial Neural Network* Menggunakan *Certainty Factor* (C-ANN) Untuk Pemetaan Kerawanan Tanah Longsor Skala Semi-Detil di DAS Bendo, Kabupaten Banyuwangi

Syamsul Bachri<sup>1\*</sup>, Kresno Sastro Bangun Utomo, Sumarmi, Mohammad Naufal Fathon, dan Yulius Eka Aldianto

Jurusan Geografi, Fakultas Ilmu Sosial, Universitas Negeri Malang, Indonesia

\*Email koresponden: syamsul.bachri.fis@um.ac.id

Direvisi: 2020-08-12. Diterima: 2021-01-21

©2021 Fakultas Geografi UGM dan Ikatan Geograf Indonesia (IGI)

**Abstrak.** Kerawanan longsor di DAS Bendo termasuk dalam kerawanan kelas sedang hingga tinggi. Sampai dengan saat ini, pemetaan rawan longsor di DAS Bendo baru dilakukan pada skala pemetaan 1:250.000. Penelitian ini bertujuan untuk melakukan pemodelan pemetaan kerawanan longsor di DAS Bendo pada skala semi-detil. Metode yang digunakan dalam penelitian ini adalah optimalisasi model *artificial neural network* menggunakan *certainty factor* (C-ANN). Peta kerawanan dibangun berdasarkan faktor pengontrol tanah longsor yang berkorelasi positif terhadap kejadian longsor menggunakan *Certainty Factor*. Sedangkan pemodelan prediksi kerawanan menggunakan model ANN, khususnya arsitektur BPNN (*back-propagation neural network*). Hasil pemodelan menunjukkan bahwa model C-ANN (7 variabel independen) memiliki nilai AUC (0,916) lebih tinggi daripada model ANN (0,778). Faktor redundansi data, multikolinieritas data, dan proporsi kejadian longsor terhadap cakupan wilayah penelitian mengakibatkan ketidakpastian dalam data variabel independen. Melalui penelitian ini ditemukan hasil bahwa kondisi kerawanan longsor di DAS Bendo masuk kategori tinggi, khususnya pada lereng atas Gunung Ijen, Rante, dan Merapi.

**Kata kunci:** Certainty Factor, Artificial Neural Network, Sistem Informasi Geografi, Penginderaan Jauh, Pemetaan Kerawanan Tanah Longsor

**Abstract.** Landslide disaster in DAS Bendo is categorized as moderate to highly susceptible. Until today, landslide hazard mapping in DAS Bendo has been carried out with a scale 1:250.000. This study aimed to model landslide susceptibility mapping on a semi-detailed scale. The method used in this research was the integration of the Certainty Factor with Artificial Neural Network models (C-ANN). The development of susceptibility mapping based on factors that positively correlate to landslide events using Certainty Factor. While the susceptibility prediction model using the ANN model, specifically the BPNN (back-propagation neural network) architecture. Modelling results show that the C-ANN model (7 independent variables) has an AUC value (0.916) higher than the ANN model (0.778). Data redundancy factors, multicollinearity of data, and the proportion of landslide events to the study area's coverage resulted in uncertainty in the independent variable data. This research found that the Landslide hazard in the Bendo Watershed is in the high category, especially on the upper slopes of Mount Ijen, Rante, and Merapi.

**Keywords:** Certainty Factor, Artificial Neural Network, Geographic Information System, Remote Sensing, Landslide Susceptibility Mapping

## PENDAHULUAN

Tanah longsor adalah pergerakan material tanah, batuan, dan organik akibat pengaruh gravitasi yang menghasilkan bentuklahan baru (Highland & Bobrowsky, 2008). Selain itu, tanah longsor juga didefinisikan sebagai gerakan massa (*mass movement*), yakni gerakan material pembentuk lereng yang bergerak ke arah bawah karena pengaruh gaya gravitasi (Varnes, 1978). Kejadian tanah longsor seringkali meninggalkan bekas pada suatu bentuklahan berupa perubahan morfologi permukaan dengan karakteristik lereng yang tidak stabil. Ketidakstabilan lereng di suatu bentuklahan disebabkan oleh faktor geometri dan material pembentuk lereng (Brunsden, 1993). Morfologi suatu lereng dengan kelerengan curam memiliki peluang terjadinya longsoran yang tinggi (Bachri & Shresta, 2010). Seiring dengan waktu, frekuensi kejadian tanah longsor terus menerus meningkat yang diikuti dengan pertumbuhan populasi manusia (Polykretis & Chalkias, 2018; Qiqing Wang et al., 2019).

Bencana tanah longsor merupakan salah satu bencana alam yang memiliki tingkat ancaman serius di Indonesia.

Bencana tersebut menimbulkan banyak korban jiwa berjatuhan dan kerugian secara material dan non-material (Pradhan & Lee, 2010). Menurut data *Centre for Research on The Epidemiology Disaster* (2018), Negara Indonesia berada di peringkat pertama dunia untuk kategori korban jiwa berjumlah 4.535 jiwa. Selain itu, data kejadian bencana tanah longsor pada tahun 1815 hingga 2019 telah menimbulkan korban meninggal sebanyak 2.491 jiwa, luka-luka 2.789 jiwa, dan mengungsi 236.121 jiwa. Dalam aspek kerugian material, bencana tanah longsor menimbulkan rumah rusak berat sebanyak 10.106 unit, rusak sedang sebanyak 3.376 unit, dan rusak ringan sebanyak 14.556 (BNPB, 2019). Wilayah Provinsi Jawa Timur memiliki potensi yang tinggi untuk terjadinya bencana tanah longsor. Menurut data BNPB (2019), dalam 10 tahun terakhir terjadi bencana tanah longsor sebanyak 619 kali. Sebaran spasial bahaya tanah longsor di Kabupaten Banyuwangi, khususnya sekitar Kompleks Gunungapi Ijen masuk kategori sedang hingga tinggi (BNPB, 2015).

Kejadian tanah longsor seringkali susah diprediksi ‘dimana’ dan ‘kapan’ terjadinya, serta ‘bagaimana’ tingkat kerusakan yang ditimbulkan secara presisi. Akan tetapi, kejadian tanah longsor dapat diprediksi peluang terjadinya dalam wujud peta zonasi kerawanan tanah longsor (Guzzetti et al., 2006). Pemetaan kerawanan tanah longsor dibangun dengan menggunakan data inventarisasi longsoran masa lalu dan zonasi potensi terjadinya tanah longsor di masa depan (Cascini, 2008).

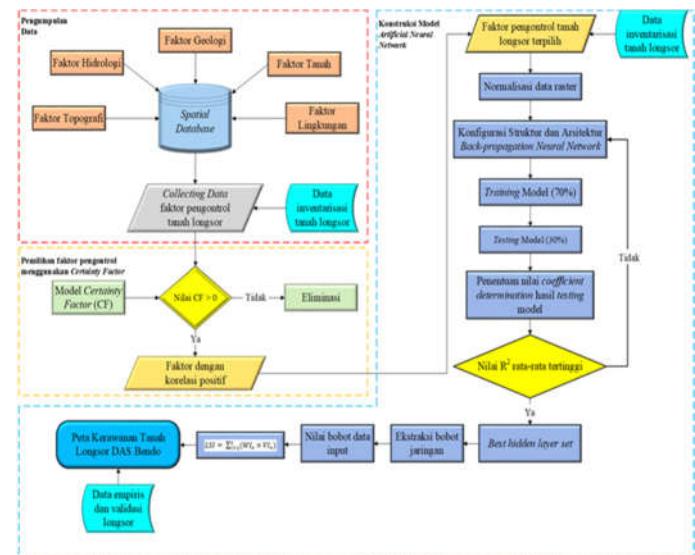
Pemetaan kerawanan tanah longsor telah dilakukan oleh banyak peneliti untuk kebutuhan tertentu pada wilayah kondisi geografis yang beragam. Metode dan teknik analisis untuk pemodelan prediksi kerawanan tanah longsor berkembang terus menerus dari waktu ke waktu. Beberapa metode yang pernah digunakan dalam penelitian sebelumnya untuk memetakan kerawanan tanah longsor seperti *direct* atau *indirect* (Carrara et al., 1999), *qualitative* (Mandaglio et al., 2016), *quantitative* (Liu & Duan, 2018), *certainty factor* (Pourghasemi et al., 2013; Qiqing Wang et al., 2019), dan *artificial neural network* (Dou et al., 2015; Ortiz & Martínez-Graña, 2018; Qiqing Wang et al., 2019).

*Artificial Neural Network* (ANN) merupakan model yang teknik pengolahan informasinya terinspirasi dari cara kerja sistem biologis, khususnya otak manusia untuk memecahkan suatu permasalahan. Model ANN terdiri dari beberapa unit pemrosesan (*neuron*) yang saling terhubung dan bekerja sama untuk memecahkan masalah tertentu (Másson & Wang, 1990). Setiap neuron menerima sinyal dari elemen-elemen (data input) yang diproses secara matematis hingga menghasilkan sebuah sinyal output. Dalam penelitian zonasi rawan longsor, secara umum data input (faktor pengontrol longsor) dalam *neuron* yang dipakai meliputi elevasi, arah hadap lereng, kelerengan, *plan curvature*, *profile curvature*, densitas sungai, dan jarak dari sungai. Pemilihan faktor pengontrol tanah longsor dapat mempengaruhi akurasi *output neuron*. Beberapa penelitian terdahulu telah mengaitkan sejumlah faktor pengontrol tanah longsor dengan kejadian tanah longsor (Devkota et al., 2013; Dou et al., 2015). Namun menurut Ayalew dan Yamagishi (2005) sampai saat ini belum terdapat pedoman secara universal untuk menentukan faktor pengontrol tanah longsor. Alhasil, muncul kesulitan untuk menentukan faktor-faktor yang telah dipilih berkorelasi atau tidak terhadap kejadian tanah longsor di wilayah penelitian.

Mendasarkan pada kondisi diatas, penelitian ini bertujuan memetakan kerawanan tanah longsor di DAS Bendo dengan skala semi-detil (1:50.000) yang diharapkan mampu memberikan informasi secara detil dengan melibatkan faktor pengontrol longsor secara pasti. Penilaian faktor pengontrol pada penelitian ini dilakukan pada faktor-faktor yang berkorelasi untuk zonasi kerawanan tanah longsor dengan menggunakan model *certainty factor* (CF). Nilai CF yang positif diasumsikan berkorelasi dengan kejadian tanah longsor (Dou et al., 2015). Sedangkan pemodelan prediksi kerawanan menggunakan model ANN, khususnya arsitektur BPNN (*back-propagation neural network*).

## METODE PENELITIAN

Integrasi *Geographic Information System* (GIS) dengan model *certainty factor* dan *artificial neural network* ditujukan untuk membangun prediksi zona kerawanan tanah longsor di DAS Bendo. Pemetaan kerawanan tanah longsor pada

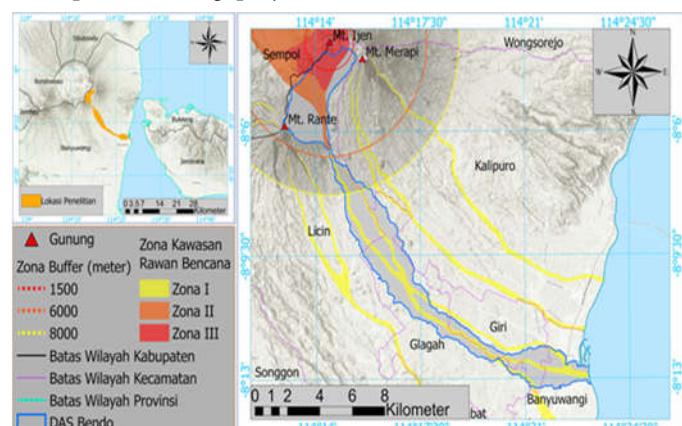


Gambar 1. Alur Penelitian Pemetaan Kerawanan Tanah Longsor di DAS Bendo

penelitian ini meliputi tahapan pengumpulan data dan analisis data. Alur proses penelitian ini dimulai dari pengumpulan data primer maupun sekunder, pemilihan faktor pengontrol tanah longsor, konstruksi model prediksi kerawanan dengan ANN, dan uji akurasi model berdasarkan data aktual longsoran (gambar 1).

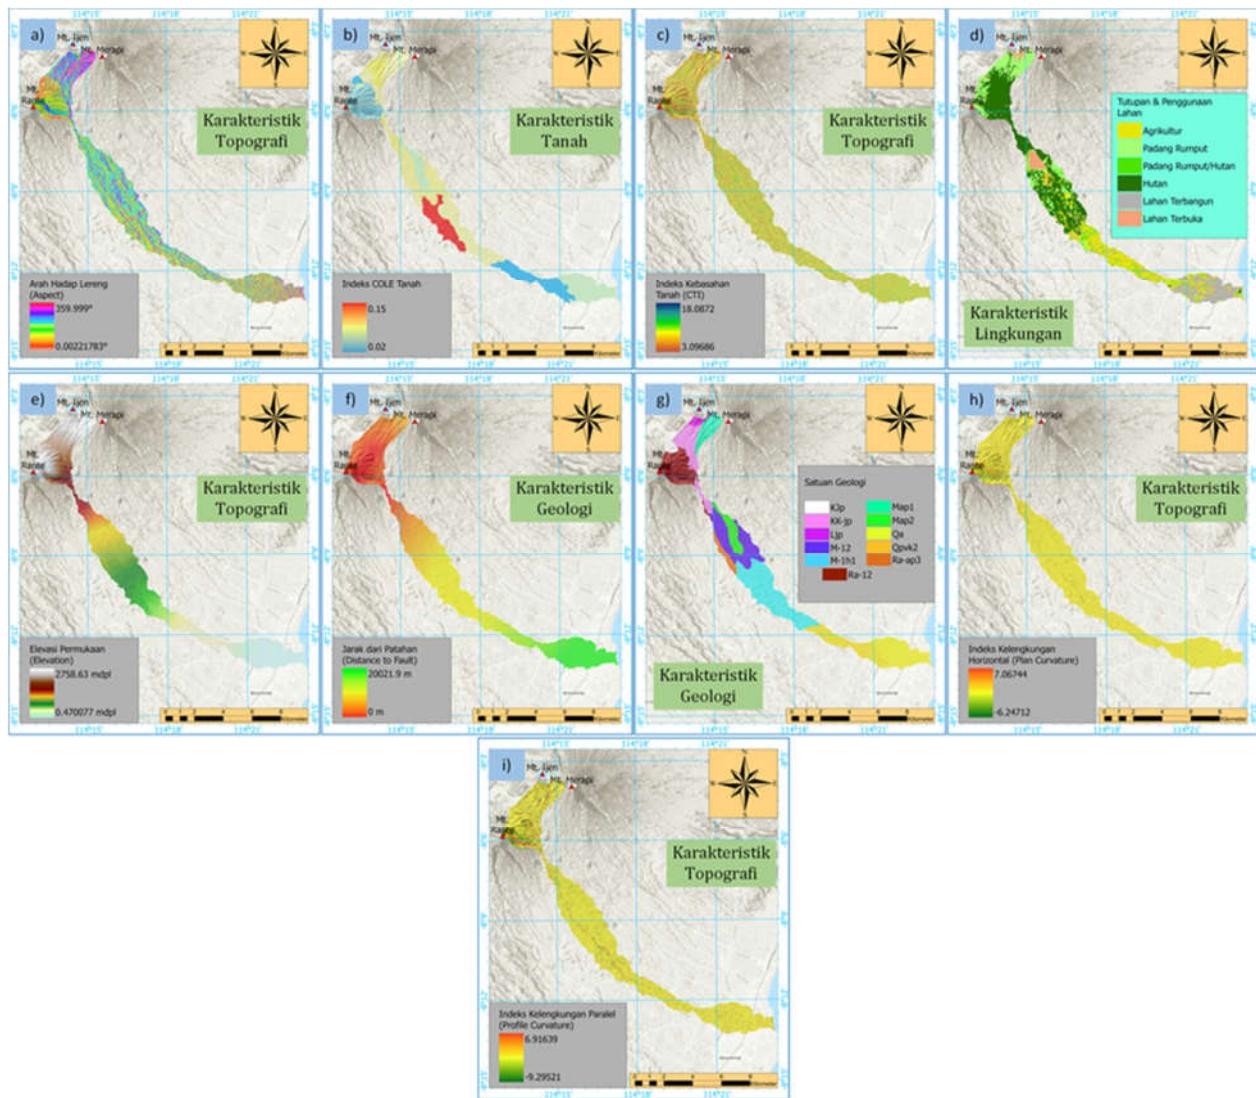
## Wilayah Penelitian

Wilayah penelitian berada di DAS Bendo, Kabupaten Banyuwangi yang memiliki luas sekitar 4012,74 Ha. Secara astronomis terletak antara 114°12'54" BT hingga 114°23'11" BT dan 8°3'35" LS hingga 8°13'19" LS. Ketinggian wilayah penelitian antara 0,47 hingga 2758,63 mdpl. Kondisi morfologinya heterogen dengan relief datar hingga bergunungan dan kemiringan lerengnya berkisar 0° - 60°. Secara geologi, wilayah studi didominasi oleh material batuan vulkanis dari Kompleks Gunungapi Ijen (lihat tabel 1). Kondisi klimatolo-

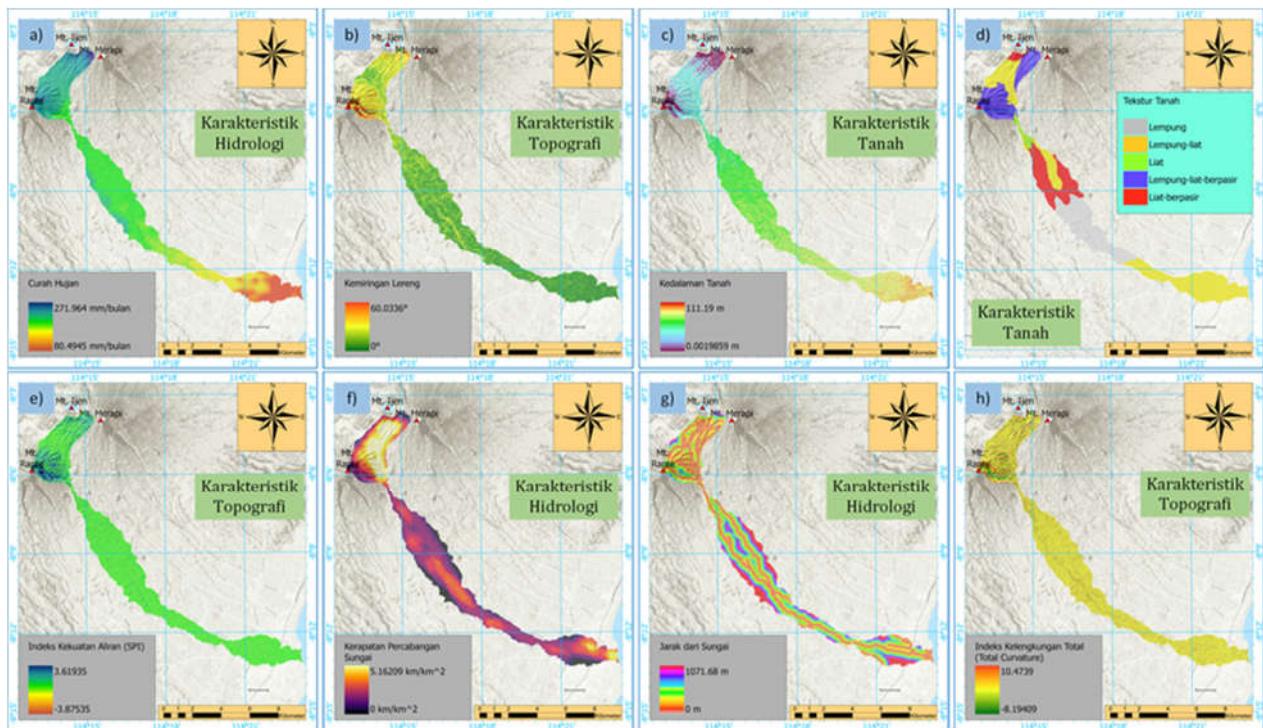


Gambar 2. Peta Lokasi dan Kawasan Rawan Bencana Vulkanik DAS Bendo

gis, khususnya curah hujan rata-rata bulanan selama 10 tahun antara 80,49 mm hingga 271,96 mm yang bersumber dari data 6 penakar hujan di wilayah studi (BMKG, 2019). Peta lokasi penelitian beserta kawasan rawan bencana vulkanik direpresentasikan pada gambar 2.



Gambar 3. Faktor pengontrol tanah longsor, a) *aspect*, b) *COLE*, c) *CTI*, d) *landuse*, e) *elevation*, f) *distance to fault*, g) *geology*, h) *plan curvature*, dan i) *profile curvature*.



Gambar 4. Faktor pengontrol tanah longsor, a) *rainfall*, b) *slope*, c) *soil depth*, d) *soil texture*, e) *SPI*, f) *stream density*, g) *distance to stream*, dan h) *total curvature*.

## Pengumpulan Data

Penelitian ini menggunakan data primer dan sekunder untuk membangun faktor pengontrol tanah longsor. Data primer yang dimaksud ialah data tekstur tanah, indeks COLE (*Coefficient of Linier Extensibility*), dan kedalaman tanah dengan unit *sampling* menggunakan satuan bentuklahan. Informasi satuan bentuklahan membedakan karakteristik tanah, topografi, material batuan, dan kondisi airtanah (Blaszczyński, 1997; Sartohadi et al., 2014). Data sekunder yang dipakai ialah data penginderaan jauh, yakni Sentinel-2 dan DEMNAS (*Digital Elevation Model Nasional*).

Citra Sentinel-2 yang dipakai ialah produk Sentinel-2B dengan akuisisi tahun 2018 sekitar wilayah Kabupaten Banyuwangi. Sentinel-2B memiliki jumlah sensor sebanyak 13 kanal multispektral (10 m, 20m, dan 60m) dengan data berlevel-1C (ESA, 2020). Sentinel-2B dimanfaatkan untuk klasifikasi penggunaan lahan dengan skala 1:50.000 sebagai salah satu faktor pengontrol tanah longsor.

Data DEMNAS merupakan hasil transformasi gabungan dari data IFSAR (5m), TERRASAR-X (5m), dan ALOS-PALSAR (11,25m) dengan menambah data *stereo-plotting masspoint* (BIG, 2008). Resolusi spasial data DEMNAS ialah 8 meter. Penelitian ini mengubah resolusi spasial menjadi 10 meter karena mengikuti resolusi spasial Citra Sentinel-2B. Selain itu juga, skala pemetaan 1:50.000 memerlukan data penginderaan jauh dengan resolusi spasial antara 10 meter hingga 20 meter (Li et al., 2019). Data DEM dapat diturunkan informasinya menjadi karakteristik topografi dan hidrologi (Qianqian Wang et al., 2015). Data spasial satuan batuan dan informasi patahan didapatkan dari Peta Geologi Gunungapi Ijen skala 1:50.000 (PVMBG, 2016). Faktor pengontrol tanah longsor yang dipilih (gambar 3 dan 4) dalam penelitian ini berdasarkan pada penelitian sebelumnya yang mungkin berkaitan dengan karakteristik tanah longsor di DAS Bendo (Bachri et al., 2019; Pourghasemi et al., 2013; Soma et al., 2019).

## Inventarisasi Kejadian Longsor Terdahulu

Pemetaan inventarisasi longsor merupakan proses deteksi lokasi, waktu kejadian, dan tipe longsoran yang meninggalkan bekas sehingga morfologi lereng berubah di suatu lanskap (Guzzetti et al., 2012). Teknik survei lapangan untuk inventarisasi longsor memerlukan biaya yang tidak sedikit dan terdapat keterbatasan akses, khususnya wilayah dengan morfologi pegunungan, walaupun hasil pemetaan memiliki keakuratan informasi yang tinggi (Hung et al., 2017). Sebagai alternatif, citra satelit resolusi tinggi dapat digunakan untuk memetakan inventarisasi longsor secara efektif dan efisien dengan keakuratan informasi yang cukup tinggi (Guzzetti et al., 2012; Hung et al., 2017; Ngadisih et al., 2017). Penelitian ini menggunakan produk citra satelit dari *google earth image* secara temporal untuk pemetaan inventarisasi longsor.

## Model *Certainty Factor*

Model *Certainty Factor* (CF) merupakan metode kuantitatif yang bertujuan untuk meminimalisir ketidakpastian variabel independen sebagai data input model *artificial neural network* (Chung & Fabbri, 1993; Devkota et al., 2013; Pourghasemi et al., 2013). Data variabel independen dalam penelitian ini adalah faktor pengontrol tanah longsor. Sedangkan, variabel dependen ialah data kejadian longsor terdahulu. Hasil akhir nantinya berupa nilai CF yang berkorelasi negatif ( $< 0$ ) dan positif ( $> 0$ ) antara variabel inde-

penden dengan kejadian longsor. Variabel independen yang berkorelasi positif dipilih sebagai data input dalam pemodelan kerawanan tanah longsor. Sedangkan, yang berkorelasi negatif dieliminasi dan tidak digunakan sebagai data input.

## Model *Artificial Neural Network*

Model ANN memiliki beberapa arsitektur untuk memecahkan suatu permasalahan, salah satunya adalah *back-propagation neural network* (BPNN). Arsitektur tersebut merupakan gabungan antara proses *feed-forward* dan *backward*. Sistem iterasi dilakukan untuk memprediksi data input terhadap data target (*output*) hingga mendapatkan nilai kesalahan terkecil, tetapi juga menghindari terjadinya *overfitting model*. Algoritma *feed-forward*, *back-propagation*, dan fungsi aktivasi digunakan dalam struktur model ANN (Dou et al., 2015; Rumelhart et al., 1986; Sarkar & Sharma, 2011). Algoritma *levenberg-marquadt* memiliki kemampuan lebih cepat untuk meminimalisir nilai kesalahan dalam jaringan syaraf tiruan, tetapi membutuhkan daya komputasi yang besar (Sarkar & Sharma, 2011; Xiong et al., 2019). Normalisasi data faktor pengontrol juga dilakukan agar komputasi lebih cepat, kesalahan minimal, dan tidak terjadi *overfitting* model. Koefisien determinasi dihitung untuk menemukan *hidden layer* terbaik dengan kondisi semakin mendekati nilai 1 semakin baik performa model dalam memprediksi kerawanan tanah longsor, begitu pula sebaliknya (Dou et al., 2015).

## Ekstraksi Bobot Variabel Independen

Ekstraksi nilai bobot data input bertujuan untuk pembuatan sistem *ranking* yang didasarkan pada nilai absolut bobot jaringan bahwa semakin tinggi nilainya, semakin besar kontribusi variabel independen untuk memprediksi kerawanan tanah longsor (Kanungo et al., 2006; Sarkar & Sharma, 2011). Nilai bobot variabel independen digunakan untuk membangun prediksi kerawanan tanah longsor yang telah dimodelkan melalui jaringan ANN.

## HASIL DAN PEMBAHASAN

Pemetaan prediksi kerawanan tanah longsor di DAS Bendo melalui model *artificial neural network* yang didasarkan pada data latih kejadian longsoran. Faktor pengontrol tanah longsor berperan sebagai data input dalam jaringan untuk memprediksi kerawanan tanah longsor. Metode kuantitatif *certainty factor* digunakan untuk menutupi kelemahan dari sistem ANN karena terdapat unsur ketidakpastian dalam data input.

## Pemetaan Inventarisasi Longsor

Kejadian longsoran yang dapat diinterpretasi melalui citra resolusi tinggi di DAS Bendo sebanyak 183 titik longsor. Data longsor berupa data vektor (area) yang dibagi menjadi 2, yakni untuk *training model* (70%) sebanyak 128 titik dan *testing model* (30%) sebanyak 55 titik (gambar 5). Data kejadian longsoran di DAS Bendo dominan berada di wilayah tubuh Gunung Ijen, Rante, dan Merapi. Minimum luasan longsor yang dideteksi ialah 225 m<sup>2</sup> karena berdasarkan pada resolusi spasial citra (10 meter) dan skala pemetaan yang dipakai (1:50.000).

## Perhitungan Nilai *Certainty Factor*

Nilai CF setiap variabel independen dihitung untuk menentukan nilai yang berkorelasi positif terhadap kejadian longsor. Hasil perhitungan menunjukkan bahwa terdapat 7

variabel independen yang memiliki nilai CF positif ( $>0$ ) meliputi *elevation* (0.91), *profile curvature* (0.76), *soil depth* (0.37), *slope* (0.9993), *stream density* (0.29), *stream power index* (0.992), dan *total curvature* (0.68). Tujuh variabel independen tersebut dipilih sebagai data input untuk jaringan ANN. Perhitungan nilai CF dilakukan secara *parallel-combination* setiap kelas dalam variabel independen. Pemberian sistem *ranking* pada varabel independen yang terpilih dimaksudkan untuk mengetahui tingkatan korelasi terhadap kejadian longsor.

### Membangun Model Artificial Neural Network

Pemilihan jumlah *hidden neuron* terbaik dilakukan sistem *trial and error* sebanyak 10 kali untuk menghitung nilai  $R^2$  rata-rata (gambar 6). Jumlah *hidden neuron* sebanyak 4 pada tujuh variabel independen (C-ANN) memiliki nilai  $R^2$  tertinggi, yakni 0,94. Sedangkan, pada 17 variabel independen (ANN) berjumlah 11 *neuron* dengan nilai  $R^2 = 0,89$ . Struktur jaringan yang dipakai dalam arsitektur BPNN ialah 17-11-2 (model ANN) dan 7-4-2 (model C-ANN).

### Pemetaan Prediksi Kerawanan Tanah Longsor

Topologi jaringan yang telah dilatih dan dilakukan *testing model* memiliki nilai bobot jaringan akhir dalam *input-hidden neurons* (I-H) dan *hidden-output neurons* (H-O). Nilai bobot jaringan diekstrak menjadi bobot variabel independen. Penelitian ini, proses ekstraksi dilakukan sebanyak 10 kali dan diambil nilai rata-rata bobotnya. Pernyataan tersebut atas dasar bahwa setiap nilai bobot pada I-H dan O-H

adalah berbeda. Selain itu juga, nilai bobot jaringan berubah secara acak ketika melakukan proses *retrained model*. Hasil pemodelan prediksi kerawanan longsor menggunakan sistem pembobotan dari model ANN memiliki nilai akurasi yang lebih baik daripada tanpa pembobotan (Lee et al., 2004; Pradhan & Lee, 2010; Sarkar & Sharma, 2011).

Kelas indeks kerawanan ditentukan dengan metode *natural breaks*. Metode tersebut digunakan dalam penelitian ini karena cocok untuk *environment modelling*, yakni mengurangi nilai varians dalam kelas dan memaksimalkan varians antar kelas (Dou et al., 2015; Ortiz & Martínez-Graña, 2018; Pourghasemi et al., 2013; Qianqian Wang et al., 2015). Kelas kerawanan dibagi menjadi 5, yakni sangat tinggi, tinggi, sedang, rendah, dan sangat rendah (gambar 7).

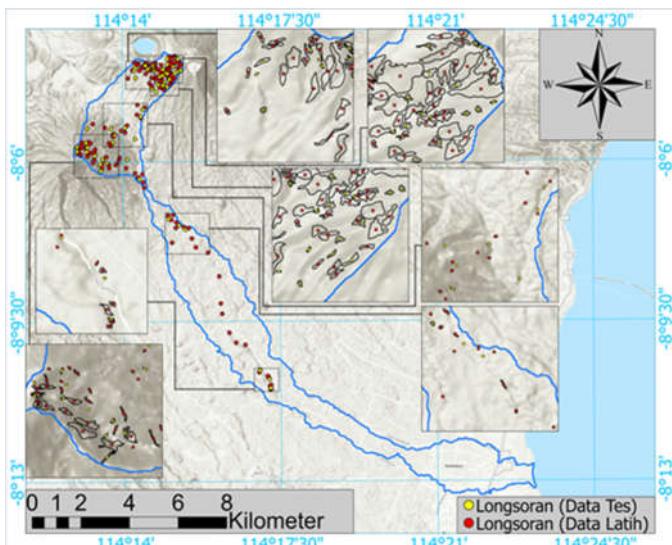
### Uji Akurasi Hasil Prediksi Kerawanan Tanah Longsor

Teknik uji akurasi model prediksi kerawanan dalam penelitian ini menggunakan kurva ROC (*Receiver Operating Curve*) untuk menghitung nilai AUC (*Area Under Curve*). Nilai AUC merepresentasikan kualitas performa prediksi model kerawanan longsor. Penelitian ini menggunakan teknik tersebut karena hasil luaran model ANN bersifat *binary classification*, yakni kelas *landslide prone* dan *landslide not-prone* (Dou et al., 2015; Pourghasemi et al., 2013; Sarkar & Sharma, 2011; QiQing Wang et al., 2019). Nilai AUC berkisar 0 hingga 1, dalam artian bahwa semakin performa model mendekati 1, semakin bagus untuk membedakan antar kelasnya, khususnya *landslide prone* dan *landslide not-prone* (Andrew P., 1997). Uji validasi model prediksi kerawanan longsor menggunakan data validasi longsor hasil survei lapangan dan visual dari citra resolusi tinggi (*google earth*).

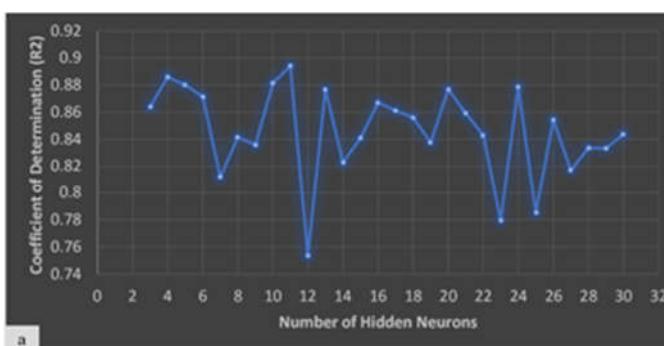
Nilai *True Positive Rate* mengindikasikan bahwa antara hasil prediksi dengan aktual adalah sama-sama kelas 1 (*landslide prone*). Sedangkan, nilai *false positive rate* ialah sama-sama kelas 0 (*landslide not-prone*). Nilai yang dipakai untuk uji validasi model prediksi kerawanan longsor menggunakan nilai AUC. Model ANN (17 variabel independen) menunjukkan nilai AUC sebesar 0,778, sedangkan model C-ANN (7 variabel independen) adalah 0,916. Berdasarkan nilai AUC, model yang paling baik dalam memodelkan kerawanan tanah longsor di DAS Bendo ialah C-ANN karena memiliki nilai paling baik dibandingkan dengan model ANN (gambar 8).

### Analisis Kondisi Faktor-faktor Kerawanan Tanah Longsor

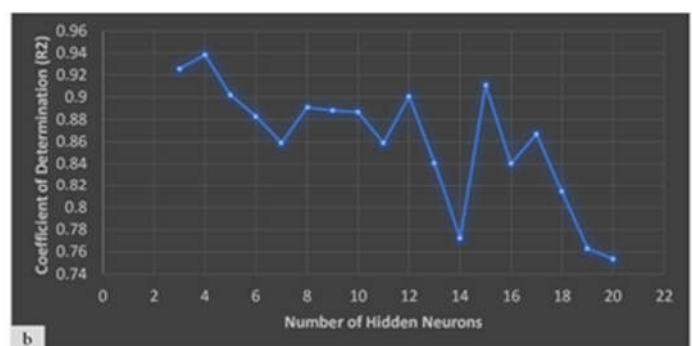
Model *certainty factor* termasuk dalam teknik penilaian ketidakpastian suatu variabel independen. Penilaian ketidakpastian dalam data input pemodelan berguna untuk memetakan kerawanan tanah longsor. Berdasarkan nilai Z, 7

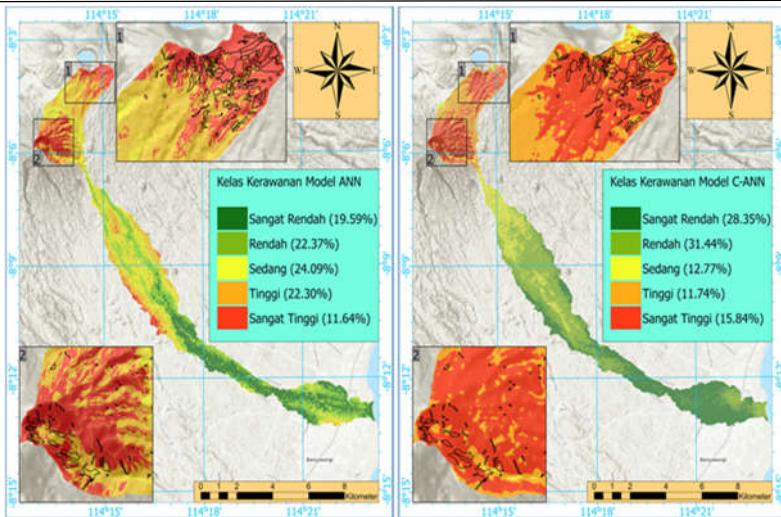


Gambar 5. Peta Distribusi Kejadian Longsor di DAS Bendo

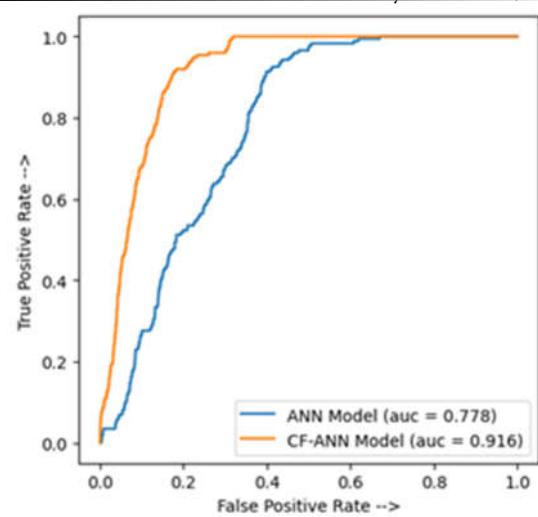


Gambar 6. Jumlah *Hidden Neurons* dalam Arsitektur BPNN, (a) 17 variabel independen (model ANN), (b) 7 variabel independen (model C-ANN)

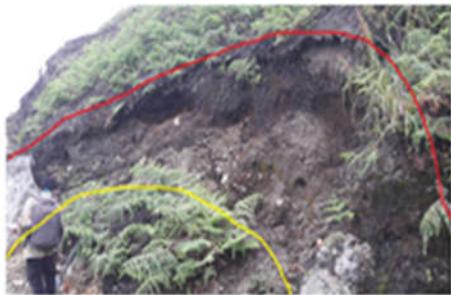




Gambar 7. Peta Rawan Longsor DAS Bendo, (a) Model ANN dengan 17 Variabel Independen, (b) Model C-ANN dengan 7 Variabel Independen



Gambar 8. Uji Validasi Model Menggunakan ROC dan AUC



Gambar 9. Kejadian Longsor Aktual di DAS Bendo

sub-kriteria telah ditentukan, meliputi *elevation* (0.91), *profile curvature* (0.76), *soil depth* (0.37), *slope* (0.9993), *stream density* (0.29), *stream power index* (0.992), dan *total curvature* (0.68). Hasil tersebut mengindikasikan bahwa 7 sub-kriteria tersebut memiliki korelasi yang pasti dengan kejadian tanah longsor.

Salah satu variabel independen yakni kemiringan lereng merupakan faktor penting yang berpengaruh terhadap kestabilan lereng. Kelas kemiringan lereng  $0 - 20^\circ$  memiliki nilai kepastian negatif. Sedangkan, kelas kemiringan lereng  $> 20^\circ$  berkorelasi kuat terhadap kejadian longsor. Peningkatan kemiringan lereng, daya tegangan geser dalam tanah atau material tak terkonsolidasi secara umum meningkat pula (Pourghasemi et al., 2013). Dalam artian bahwa morfologi dengan kelerengan yang curam hingga sangat curam memiliki potensi kejadian longsoran yang besar (Bachri et al., 2019; Bachri & Shresta, 2010). *Gentle slopes* di DAS Bendo memiliki frekuensi kejadian longsor yang sedikit karena memiliki daya tegangan geser lemah pada tanah.

Variabel independen elevasi memiliki korelasi yang sangat tinggi terhadap kejadian tanah longsor. Frekuensi kejadian longsor yang tinggi berada pada elevasi  $> 2000$  meter, tepatnya di bagian lereng atas dan tengah Kompleks Gunungapi Ijen. Elevasi dapat sebagai ukuran pengganti penggunaan lahan yang berkaitan dengan zona vegetasi. Dalam artian, elevasi kemungkinan menjadi *best estimator* yang dimana terjadi pemotongan lereng oleh jalan, dan devegetasi yang dapat menimbulkan longsoran (Lineback Gritzner et al., 2001).

Atribut *curvature* seperti *profile curvature* dan *total curvature* memiliki korelasi yang cukup kuat terhadap kejadian tanah longsor. *Curvature* merepresentasikan bentuk morfologi pada topografi. Nilai positif dalam atribut *curvature* mengindikasikan bentuk lereng cembung. Sedangkan, nilai negatif memiliki bentuk lereng cekung. Area lereng cekung memiliki nilai kepastian lebih tinggi daripada lereng cembung. Hal ini dikarenakan air hujan mudah terakumulasi pada lereng cekung yang mengakibatkan tanah menjadi lebih lunak sehingga berpotensi terjadinya longsoran (He et al., 2019). Morfologi bentuk lereng yang cekung dominan berada di lembah-lembah pada bagian tubuh Gunung Ijen, Merapi, dan Rante.

Kondisi hidrologis direpresentasikan dengan atribut *stream power index* dan *stream density*. Nilai kepastian pada atribut SPI adalah paling besar pada karakteristik hidrologi. SPI menjelaskan kondisi tingkat laju erosi karena berkaitan kuat dengan kelerengan. Intensitas erosi di DAS Bendo melalui nilai indeks SPI mengindikasikan proses gerak massa memiliki tingkat aktivitas yang tinggi sehingga berpengaruh terhadap kondisi yang memicu tanah longsor (Hong et al., 2017). Densitas sungai merupakan tingkat kerapatan sungai dalam satuan  $\text{km}^2$ . Nilai kepastian faktor densitas sungai adalah yang paling rendah diantara semua variabel independen yang terpilih. Akan tetapi, longsoran terjadi pada kelas kerapatan sungai yang tinggi karena adanya proses erosi pada kaki lereng dan menjenuhkan material pada dasar lereng (Dehnavi et al., 2015).

Variabel independen kedalaman tanah memiliki pengaruh terhadap kejadian longsor, walaupun dengan nilai kepastian sedang. Menurut hasil perhitungan nilai CF, bahwa longsoran terjadi dengan kondisi ketebalan tanah yang tipis, dan sebaliknya. Hal tersebut dikarenakan tanah yang tipis tidak cukup kuat untuk menopang kekuatan akar dapat menyebabkan meningkatnya daya geser tanah (Dietrich et al., 2007).

## KESIMPULAN

Metode kuantitatif *certainty factor* memiliki kemampuan untuk menutupi kelemahan dari model *artificial neural network* dalam hal keterkaitan antara variabel independen dengan data target (kejadian longsor terdahulu). Hasil pemodelan menunjukkan bahwa terdapat tujuh faktor pengontrol tanah longsor yang terpilih dari total 17 faktor. Model C-ANN (AUC=0,916) memiliki kualitas performa lebih baik daripada model ANN (0,778) dengan 17 faktor. Hasil performa model menunjukkan bahwa dengan memilih faktor pengontrol tanah yang lebih banyak tidak selalu menghasilkan model prediksi kerawanan longsor lebih akurat. Hal tersebut karena faktor redundansi data, multikolinieritas data, kualitas data citra, dan karakteristik kejadian longsor terdahulu terhadap cakupan wilayah penelitian. Sehingga tujuh faktor ini tidak dapat dijadikan pedoman absolut untuk wilayah kajian berbeda. Kondisi kerawanan tanah longsor di DAS Bendo secara spasial memiliki kerawanan yang tinggi berdasarkan nilai indeks kerawanan, khususnya pada bagian lereng atas tubuh Gunung Ijen, Rante, dan Merapi.

Pemetaan kerawanan tanah longsor dapat memberikan informasi untuk analisis lebih lanjut, khususnya memetakan bahaya bencana longsor hingga risiko bencana longsor. Maka dari itu, peta kerawanan longsor dapat memberikan kontribusi untuk mencegah dan mengendalikan kerusakan infrastruktur, khususnya kepariwisataan di DAS Bendo.

## UCAPAN TERIMA KASIH

Terimakasih diucapkan kepada 1) Universitas Negeri Malang yang telah mendanai riset ini melalui skema Hibah Penelitian dana PNBP UM tahun 2019, 2) Tim Peneliti *Ijen Mountain Research Group* (Naufal, Kresno, Yulius, Mufti dan Sismi) yang telah bekerja keras dalam pengumpulan data di lapangan.

## KONTRIBUSI PENULIS

Syamsul Bachri : Ketua peneliti dan penulis artikel, Kresno Sastro Bangun Utomo: *RS and GIS* analisis dan penulis artikel. Sumarmi : Anggota peneliti dan editor artikel, Mohamad Naufal Fathoni : *RS and GIS* analisis, coordinator pengumpulan data lapangan, Yulius Eka Aldianto : Pengambilan data lapangan dan *layouter* artikel

## DAFTAR PUSTAKA

- Andrew P., B. (1997). The Use of the Area Under the ROC Curve in the Evaluation of Machine Learning Algorithms. *Pattern Recognition*, 30(7), 1145–1159. [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2)
- Ayalew, L., & Yamagishi, H. (2005). The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko Mountains, Central Japan. *Geomorphology*, 65(1-2), 15–31. <https://doi.org/10.1016/j.geomorph.2004.06.010>
- Bachri, S., & Shresta, R. P. (2010). Landslide hazard assessment using analytic hierarchy processing ( AHP ) and geographic information system in Kaligesing mountain area of Central Java Province Indonesia. *Annual International Workshop & Expo on Sumatra Tsunami*, 108–112.
- Bachri, S., Sumarmi, Yudha Irawan, L., Utaya, S., Dwitri Nurdiansyah, F., Erfika Nurjanah, A., Wahyu Ning Tyas, L., Amri Adillah, A., & Setia Purnama, D. (2019). Landslide Susceptibility Mapping (LSM) in Kelud Volcano Using Spatial Multi-Criteria Evaluation. *IOP Conference Series: Earth and Environmental Science*, 273(1). <https://doi.org/10.1088/1755-1315/273/1/012014>
- BIG. (2008). DEMNAS. <http://tides.big.go.id/DEMNAS/>
- Binaghi, E., Luzi, L., Madella, P., Pergalani, F., & Rampini, A. (1998). Slope instability zonation: a comparison between certainty factor and fuzzy Dempster-Shafer approaches. *Natural Hazards*, 17(1), 77–97. <https://doi.org/10.1023/A:1008001724538>
- Blaszcynski, J. S. (1997). Landform characterization with geographic information systems. *Photogrammetric Engineering and Remote Sensing*, 63(2), 183–191.
- BMKG. (2019). BMKG | Badan Meteorologi, Klimatologi, dan Geofisika. <https://www.bmkg.go.id/>
- BNPB. (2015). *Kajian Risiko Bencana Jawa Timur 2016 - 2020*. BNPB.
- BNPB. (2019). *Data Informasi Bencana Indonesia (DIBI)*. <http://bnpb.cloud/dibi/tabel1a>
- Brunsden, D. (1993). Mass movement; the research frontier and beyond: a geomorphological approach. *Geomorphology*, 7, 85–128.
- Carrara, A., Guzzetti, F., Cardinali, M., & Reichenbach, P. (1999). Use of GIS technology in the prediction and monitoring of landslide hazard. *Natural Hazards*, 20(2–3), 117–135. <https://doi.org/10.1023/A:1008097111310>
- Cascini, L. (2008). Applicability of landslide susceptibility and hazard zoning at different scales. *Engineering Geology*, 102(3–4), 164–177. <https://doi.org/10.1016/j.enggeo.2008.03.016>
- Chung, C. J. F., & Fabbri, A. G. (1993). The representation of geoscience information for data integration. *Nonrenewable Resources*, 2(2), 122–139. <https://doi.org/10.1007/BF02272809>
- CRED. (2018). *2018 REVIEW OF DISASTER EVENTS*.
- Dehnavi, A., Aghdam, I. N., Pradhan, B., & Morshed Varzandeh, M. H. (2015). A new hybrid model using step-wise weight assessment ratio analysis (SWARA) technique and adaptive neuro-fuzzy inference system (ANFIS) for regional landslide hazard assessment in Iran. *Catena*, 135, 122–148. <https://doi.org/10.1016/j.catena.2015.07.020>
- Devkota, K. C., Regmi, A. D., Pourghasemi, H. R., Yoshida, K., Pradhan, B., Ryu, I. C., Dhital, M. R., & Althuwaynee, O. F. (2013). Landslide susceptibility mapping using certainty factor, index of entropy and logistic regression models in GIS and their comparison at Mugling-Narayanghat road section in Nepal Himalaya. *Natural Hazards*, 65(1), 135–165. <https://doi.org/10.1007/s11069-012-0347-6>
- Dietrich, W. E., McKean, J., Bellugi, D., & Perron, T. (2007). The prediction of shallow landslide location and size using a multidimensional landslide analysis in a digital terrain model. *International Conference on Debris-Flow Hazards Mitigation: Mechanics, Prediction, and Assessment, Proceedings*, 319–329.
- Dou, J., Yamagishi, H., Pourghasemi, H. R., Yunus, A. P., Song, X., Xu, Y., & Zhu, Z. (2015). An integrated artificial neural network model for the landslide susceptibility assessment of Osado Island, Japan. *Natural Hazards*, 78(3), 1749–1776. <https://doi.org/10.1007/s11069-015-1799-2>
- ESA. (2020). *Sentinel-2 MSI Introduction*.
- Guzzetti, F., Cesare, A., Cardinali, M., Fiorucci, F., Santangelo, M., & Chang, K. (2012). Landslide inventory maps: New tools for an old problem. *Earth Science Reviews*, 112(1–2), 42–66. <https://doi.org/10.1016/j.earscirev.2012.02.001>
- Guzzetti, F., Reichenbach, P., Ardizzone, F., Cardinali, M., & Galli, M. (2006). Estimating the quality of landslide susceptibility

- models. *Geomorphology*, 81(1–2), 166–184. <https://doi.org/10.1016/j.geomorph.2006.04.007>
- He, H., Hu, D., Sun, Q., Zhu, L., & Liu, Y. (2019). A landslide susceptibility assessment method based on GIS technology and an AHP-weighted information content method: A case study of southern Anhui, China. *ISPRS International Journal of Geo-Information*, 8(6). <https://doi.org/10.3390/ijgi8060266>
- Highland, L. M., & Bobrowsky, P. (2008). *The Landslide Handbook — A Guide to Understanding Landslides*.
- Hong, H., Pradhan, B., Sameen, M. I., Chen, W., & Xu, C. (2017). Spatial prediction of rotational landslide using geographically weighted regression, logistic regression, and support vector machine models in Xing Guo area (China). *Geomatics, Natural Hazards and Risk*, 8(2), 1997–2022. <https://doi.org/10.1080/19475705.2017.1403974>
- Hung, L. Q., Van, N. T. H., Son, P. Van, Ninh, N. H., Tam, N., & Huyen, N. T. (2017). Landslide Inventory Mapping in the Fourteen Northern Provinces of Vietnam: Achievements and Difficulties. *Advancing Culture of Living with Landslides*, 501–510. <https://doi.org/10.1007/978-3-319-59469-9>
- Kanungo, D. P., Arora, M. K., Sarkar, S., & Gupta, R. P. (2006). A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling Himalayas. *Engineering Geology*, 85(3–4), 347–366. <https://doi.org/10.1016/j.enggeo.2006.03.004>
- Lee, S., Ryu, J. H., Won, J. S., & Park, H. J. (2004). Determination and application of the weights for landslide susceptibility mapping using an artificial neural network. *Engineering Geology*, 71(3–4), 289–302. [https://doi.org/10.1016/S0013-7952\(03\)00142-X](https://doi.org/10.1016/S0013-7952(03)00142-X)
- Li, L., Qiang, Y., Zheng, Z., & Zhang, J. (2019). Research on the Relationship between the Spatial Resolution and the Map Scale in the Satellite Remote Sensing Cartographies. *Advances in Intelligent System Research*, 168(Masta), 194–199. <https://doi.org/10.2991/masta-19.2019.33>
- Lineback Gritzner, M., Marcus, W. A., Aspinall, R., & Custer, S. G. (2001). Assessing landslide potential using GIS, soil wetness modeling and topographic attributes, Payette River, Idaho. *Geomorphology*, 37(1–2), 149–165. [https://doi.org/10.1016/S0169-555X\(00\)00068-4](https://doi.org/10.1016/S0169-555X(00)00068-4)
- Liu, J., & Duan, Z. (2018). Quantitative assessment of landslide susceptibility comparing statistical index, index of entropy, and weights of evidence in the Shangnan Area, China. *Entropy*, 20(11), 9–11. <https://doi.org/10.3390/e20110868>
- Mandaglio, M. C., Gioffrè, D., Pitasi, A., & Moraci, N. (2016). Qualitative Landslide Susceptibility Assessment in Small Areas. *Procedia Engineering*, 158, 440–445. <https://doi.org/10.1016/j.proeng.2016.08.469>
- Másson, E., & Wang, Y. J. (1990). Introduction to computation and learning in artificial neural networks. *European Journal of Operational Research*, 47(1), 1–28. [https://doi.org/10.1016/0377-2217\(90\)90085-P](https://doi.org/10.1016/0377-2217(90)90085-P)
- Ngadisih, Samodra, G., Bhandary, N. P., & Yatabe, R. (2017). Landslide Inventory: Challenge for Landslide Hazard Assessment in Indonesia. In *In GIS Landslide*. Springer. <https://doi.org/10.1007/978-4-431-54391-6>
- 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>
- Polykretis, C., & Chalkias, C. (2018). Comparison and evaluation of landslide susceptibility maps obtained from weight of evidence, logistic regression, and artificial neural network models. *Natural Hazards*, 93(1), 249–274. <https://doi.org/10.1007/s11069-018-3299-7>
- Pourghasemi, H. R., Pradhan, B., Gokceoglu, C., Mohammadi, M., & Moradi, H. R. (2013). Application of weights-of-evidence and certainty factor models and their comparison in landslide susceptibility mapping at Haraz watershed, Iran. *Arabian Journal of Geosciences*, 6(7), 2351–2365. <https://doi.org/10.1007/s12517-012-0532-7>
- Pradhan, B., & Lee, S. (2010). Landslide susceptibility assessment and factor effect analysis: backpropagation artificial neural networks and their comparison with frequency ratio and bivariate logistic regression modelling. *Environmental Modelling and Software*, 25(6), 747–759. <https://doi.org/10.1016/j.envsoft.2009.10.016>
- PVMBG. (2016). *Peta Geologi G. Kawah Ijen | Galeri Pusat Vulkanologi dan Mitigasi Bencana Geologi*. <https://vsi.esdm.go.id/gallery/picture.php?/73>
- Rumelhart, D. E., Hinton, G. E., & Willam, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323 (6088), 533–536.
- Sarkar, D. P. K. S., & Sharma, S. (2011). Combining neural network with fuzzy, certainty factor and likelihood ratio concepts for spatial prediction of landslides. 59, 1491–1512. <https://doi.org/10.1007/s11069-011-9847-z>
- Sartohadi, J., Sianturi, R. S., Rahmadana, A. D. W., Maritim, F., Munawaroh, D. W., Suryani, T., & Pratiwi, E. S. (2014). *Bentang Sumberdaya Lahan Kawasan Gunungapi Ijen dan Sekitarnya* (M. A. Setiawan (ed.); 1st ed.). Penerbit Pustaka Pelakar.
- Soma, A. S., Kubota, T., & Mizuno, H. (2019). Optimization of causative factors using logistic regression and artificial neural network models for landslide susceptibility assessment in Ujung Loe Watershed, South Sulawesi Indonesia. *Journal of Mountain Science*, 16(2), 383–401. <https://doi.org/10.1007/s11629-018-4884-7>
- Varnes, D. J. (1978). *Slope Movement Types and Processes* (Vol. 176).
- Wang, Qianqian, Wang, D., Huang, Y., Wang, Z., Zhang, L., Guo, Q., Chen, W., Chen, W., & Sang, M. (2015). Landslide susceptibility mapping based on selected optimal combination of landslide predisposing factors in a large catchment. *Sustainability (Switzerland)*, 7(12), 16653–16669. <https://doi.org/10.3390/su71215839>
- Wang, Qiqing, Guo, Y., Li, W., He, J., & Wu, Z. (2019). Predictive modeling of landslide hazards in Wen County, northwestern China based on information value, weights-of-evidence, and certainty factor. *Geomatics, Natural Hazards and Risk*, 10(1), 820–835. <https://doi.org/10.1080/19475705.2018.1549111>
- Xiong, J., Sun, M., Zhang, H., Cheng, W., Yang, Y., Sun, M., Cao, Y., & Wang, J. (2019). Application of the Levenburg–Marquardt back propagation neural network approach for landslide risk assessments. *Natural Hazards and Earth System Sciences*, 19(3), 629–653. <https://doi.org/10.5194/nhess-19-629-2019>