

Analisis Spasial Kerentanan Tanah Longsor Melalui Pendekatan Algoritma Machine Learning

Irmayani¹, A. Ika Putriani²

Institut Teknologi Bacharuddin Jusuf Habibie^{1,2}

irmayani2104@ith.ac.id¹, andiikaputriani497@ith.ac.id²

Corresponding Author: Irmayani, E-mail: irmayani2104@ith.ac.id

ABSTRACT

Landslides are among the most frequent natural disasters in Indonesia, posing significant threats to human safety and infrastructure, particularly in regions characterized by steep topography and high rainfall intensity. This study aims to spatially analyze landslide susceptibility using machine learning algorithms and to identify the most influential conditioning factors contributing to landslide occurrences. The research was conducted in Kabupaten Luwu Utara, located in Sulawesi Selatan, utilizing recorded landslide events from 2015–2025. The analysis incorporated biophysical and geospatial variables, including rainfall, humidity, and the Normalized Difference Vegetation Index (NDVI). The study employed a quantitative explanatory approach with predictive modeling based on Random Forest (RF), Support Vector Machine (SVM), and Artificial Neural Network (ANN) algorithms. The dataset was constructed as a balanced binary classification of landslide and non-landslide events. Model performance was evaluated using multiple metrics, including accuracy, precision, recall, F1-score, ROC-AUC, and precision–recall curves to ensure comprehensive assessment. The findings indicate that the Random Forest model achieved the highest overall accuracy, while the Artificial Neural Network demonstrated superior capability in detecting landslide occurrences within the testing dataset. However, the relatively modest AUC and Average Precision values suggest limitations in the models' discriminative performance. Variable importance analysis revealed that rainfall is the most dominant conditioning factor, followed by humidity and NDVI. Overall, the machine learning approach successfully represents landslide susceptibility spatially. Nevertheless, further model optimization and integration of additional relevant variables are required to enhance predictive reliability and to support robust disaster mitigation and early warning systems.

KEYWORDS

Algorithm, Machine Learning, Susceptibility, Spatial, Landslides

ARTICLE DOI:

<https://doi.org/10.53696/venn.v5i1.420>

A. Pendahuluan

Tanah longsor termasuk bencana alam yang memiliki tingkat kejadian sangat tinggi dan menunjukkan kecenderungan peningkatan dari tahun ke tahun, sehingga menimbulkan dampak kerugian yang signifikan, baik secara material maupun non-material ([Taneshab et al, 2023](#)). Peristiwa ini tidak dipicu oleh satu penyebab tunggal, melainkan merupakan hasil interaksi antara berbagai faktor alam dan faktor non-alam ([Alfarizi et al, 2023](#)). Selain itu kondisi Indonesia sebagai negara dengan kerentanan longsor tinggi karena kombinasi topografi pegunungan, curah hujan intens, perubahan tutupan lahan, serta tekanan pembangunan di kawasan lereng. Dampaknya tidak hanya berupa korban jiwa dan kerusakan infrastruktur, tetapi juga gangguan sosial ekonomi yang luas. Data resmi BNPB menunjukkan besarnya dampak bencana secara nasional, termasuk korban meninggal, hilang, luka-luka, serta masyarakat terdampak dan mengungsi pada tahun 2024. Badan Nasional Penanggulangan Bencana (BNPB) mencatat bahwa tahun 2024 hingga Februari 2025 telah terjadi 267 tanah longsor yang menyebabkan 59.293 kerusakan tempat tinggal dan berbagai fasilitas pelayanan umum ([Badan Pusat Statistik, 2025](#)).

Dalam konteks mitigasi, pemetaan kerentanan longsor menjadi instrumen penting untuk mengidentifikasi zona rawan berdasarkan faktor pengontrol misalnya kemiringan lereng, litologi, curah hujan, kelembapan, NDVI, jaringan sungai, dan kedekatan jalan ([Yu et al., 2025](#)).

Perkembangan penelitian menunjukkan adanya pergeseran dari pendekatan statistik konvensional menuju algoritma machine learning yang dinilai lebih mampu menangkap hubungan nonlinier antar variabel dan meningkatkan akurasi prediksi (Merghadi et al., 2020 & [Liu et al., 2024](#)). Berbagai metode telah digunakan secara luas dalam LSM, seperti Logistic Regression, SVM, Random Forest, XGBoost, serta pendekatan ensemble dan optimasi hyperparameter ([Hong et al., 2018](#) & [Achu et al., 2024](#)). Di Indonesia, studi berbasis machine learning juga berkembang, misalnya pada wilayah Bogor dan Papua, menunjukkan urgensi penguatan metodologi LSM yang kontekstual terhadap karakteristik data dan kondisi lokal ([Effendi & Hariyanto, 2016](#)).

Meski demikian, terdapat kesenjangan kajian ilmiah yang cukup konsisten dalam literatur LSM berbasis machine learning. Beberapa studi masih menitikberatkan evaluasi pada ROC–AUC saja, metrik ini dapat kurang representatif ketika data kejadian longsor bersifat tidak seimbang dan ketika false positive atau false negative memiliki konsekuensi mitigasi yang berbeda ([Zhao et al., 2023](#), [Abdo & Richi, 2024](#)). Kualitas LSM sangat dipengaruhi oleh strategi sampling non-longsor (misalnya random, buffer, threshold kemiringan, atau zonasi awal), namun aspek ini sering diperlakukan sebagai langkah teknis biasa, padahal terbukti dapat mengubah performa model secara signifikan ([Jia et al., 2025](#)). Konsistensi spasial antar model dan penjelasan kontribusi faktor masih sering kurang ditekankan, padahal penting untuk mengubah alur prediksi menjadi dasar keputusan kebijakan yang dapat dipertanggungjawabkan ([Zhou & Xing, 2025](#)).

Berdasarkan permasalahan tersebut, penelitian berjudul “Analisis Spasial Kerentanan Tanah Longsor Melalui Pendekatan Algoritma Machine Learning” ini berfokus pada pemodelan kerentanan longsor berbasis variabel biofisik dan geospasial, pemilihan data sampel yang tepat, serta evaluasi model yang lebih komprehensif dengan tujuan menganalisis kerentanan tanah longsor secara spasial melalui pendekatan algoritma machine learning serta mengidentifikasi faktor-faktor pengondisi yang paling berpengaruh terhadap kejadian tanah longsor. Penelitian ini menegaskan pentingnya membandingkan beberapa algoritma *machine learning* dan menilai performanya tidak hanya dari ROC–AUC, tetapi juga dari metrik lain yang relevan untuk tujuan mitigasi. Dengan demikian, keluaran penelitian diharapkan menghasilkan model yang akurat dalam memprediksi kerentanan tanah longsor serta mengidentifikasi faktor-faktor yang paling mempengaruhi munculnya kejadian tanah longsor melalui analisis *feature importance* atau parameter model.

Urgensi penelitian ini semakin tinggi karena meningkatnya keterpaparan masyarakat dan infrastruktur di kawasan lereng, serta adanya kecenderungan kejadian hidrometeorologi ekstrem yang dapat memicu longsor. Model yang akurat dalam memprediksi metodologis dibutuhkan agar keputusan mitigasi tidak hanya “akurasi tinggi di atas kertas”, tetapi juga efektif secara operasional mampu menekan pengingat keliru sekaligus tidak mengabaikan zona berisiko tinggi ([Lyu et al., 2024](#)). Oleh karena itu, pendekatan *machine learning* yang diiringi strategi sampling yang tepat, evaluasi multi-metrik, serta interpretasi kontribusi faktor menjadi landasan penting untuk memperkuat kualitas LSM di Indonesia dan menjembatani kebutuhan sains dan kebijakan.

B. Metodologi

Metode Penelitian yang digunakan merupakan metode penelitian kuantitatif eksplanatori dengan tujuan menentukan serta menjelaskan faktor pengondisi senjadian tanah longsor melalui pemodelan AI.

1. Lokasi dan data penelitian

Data yang digunakan merupakan data kejadian tanah longsor di wilayah Luwu Utara provinsi Sulawesi Selatan. Data kejadian sejak tahun 2018 hingga kejadian tahun 2025. Sumber data berupa

data kejadian tanah longsor, data topografi seperti curah hujan, kelembaban, data penggunaan lahan dan vegetasi seperti NDVI

2. Variabel pengondisi dan pra-pemrosesan

Variabel kondisional terdiri dari faktor topografi, faktor hidrologi dan faktor geologi. Faktor hidrologi seperti curah hujan.

Pra-pemrosesan data meliputi

- a. Reproyeksi dan resampling. Semua data raster dan data vektor diseragamkan ke sistem koordinat proyeksi yang sama. Data raster seperti curah hujan, NDVI diseresampling ke resolusi grid yang konsisten.
- b. Clipping dan pembersihan data. Seluruh layer spasial dipotong sesuai batas wilayah yang akan diteliti agar analisis fokus pada wilayah yang relevan. Tahap ini untuk membersihkan data serta memeriksa kualitas peta geologi.
- c. Penanganan nilai hilang dan standarisasi. Nilai hilang pada raster diisi atau dikecualikan dengan prosedur sistematis. Variabel yang memiliki skala yang berbeda dinormalisasi atau distandarisasi.
- d. Pembentukan dataset biner. Wilayah yang diteliti dinyatakan dalam pixel. Untuk tiap pixel dikumpulkan semua nilai variabel pengondisi kemudian diberikan label untuk kelas 1 untuk lokasi yang mengalami kejadian tanah longsor dan 0 untuk lokasi yang tidak mengalami kejadian tanah longsor.

3. Algoritma machine learning

a. Pemilihan algoritma machine learning

- 1) Random Forest (RF) mampu menangani hubungan nonlinear, relatif kebal terhadap outlier, dapat bekerja dengan banyak variabel serta menyediakan nilai future importance.
- 2) Support Vektor Machine (SVM) dipertimbangkan untuk pola pemisahan kelas relatif kompleks.
- 3) Artificial Neural Network (ANN) untuk menangkap hubungan yang sangat kompleks dan interaksi antar variabel yang tidak mudah dimodelkan oleh metode klasik.
- 4) algoritma utama untuk membandingkan beberapa algoritma.

b. Konfigurasi model

- 1) Random forest memiliki parameter kunci yang dapat diatur antara lain jumlah pohon (n_estimator), kedalaman maksimum pohon (max_depth), jumlah minimal sampel untuk memisahkan node (min_samples_split), dan jumlah fitur yang dipertimbangkan pada tiap pemisahan (max_feature).
- 2) SVM mengonfigurasi jenis kernel (linear, polynomial, RBF), parameter regulasi C (mengendalikan trade-off antara margin lebar dan kesalahan klasifikasi) serta gamma (khusus kernel RBF atau polynomial) yang mengatur pengaruh setiap sampel pelatihan.
- 3) ANN memiliki parameter yang disesuaikan mencakup jumlah lapisan tersembunyi dan neuron per lapisan, fungsi aktivasi. Learning rate, ukuran batch, dan jumlah epoch pelatihan.

c. Turning hyperparameter

Strategi pencarian parameter seperti menguji seluruh kombinasi parameter dalam rentang tertentu atau mengambil kombinasi acak dalam ruang parameter. Proses akan digabungkan dengan skema *k-fold-cross-validation*. Di mana data pelatihan

dibagimenjadi k lipatan, odel dilatih pada k-1 lipatan dan validasi pada lipatan yang tersisa secara bergantian.

d. Skema pelatihan, validasi dan evaluasi (Sokolova & Lapalme, 2009)

1) Performa model dinilai menggunakan metrik kalrifiksi standar yang terdiri dari

- Akurasi: proporsi prediksi benar terhada total sampel.
- Presisi: proporsi predisi longsor yang benar di antara seluruh prediksi longsor (mengurani false positive)

$$Precision = \frac{n_{TP}}{n_{TP}+n_{FP}} \quad (1)$$

Dimana n_{TP} merupakan jumlah sampel longsor yang dinyatakan benar dan n_{FP} merupakan jumlah sampel longsor yang dinyatakan salah.

- Recall: proporsi kejadian longsor yang berhasil terdeteksi di antara seluruh kejadian longsor aktual (mengurangi false negative)

$$Recall = \frac{n_{TP}}{n_{TP}+n_{FN}} \quad (2)$$

Dimana n_{TP} merupakan jumlah sampel longsor yang dinyatakan benar dan n_{FN} merupakan jumlah sampel non-longsor yang dinyatakan salah.

- F1-score: rata-rata harmonis presisi dan recall berguna ketika kelas tidak seimbang.

$$F1 = \frac{2Precision*Recall}{Precision+Recall} \quad (3)$$

2) AUC-ROC digunakan sebagai metrik utama yang digunaka untuk mengukur kemampuan model membedakan anantara kelas longsor dan tidak longsor pada berbagai ambang batas. Nilai AUC lebih dekat ke 1 menunjukkan model yang sangat baik.

3) Matrik spaial sperti landslide density per kelas kerenatanan, rumusnya dapat dijelaskan seperti

$$landslide\ density = \frac{jumlah\ kejadian\ longsor\ dalam\ kelas}{luar\ kelas} \quad (4)$$

4. Keterkaitan dengan teori Faktor Keamanan

Secara geotonik


$$SF = \frac{c' + (\sigma - \mu) \tan \varphi'}{\tau} \quad (5)$$

Dimana c' merupakan kohesi efektif tanah, σ merupakan tegangan normal total, μ adalah tekanan air pori, φ' merupakan sudut geser dalam efektif dan τ adalah tegangan geser akibat gaya gravitasi. (Misriani et al., 2025)

Dengan tegangan geser

$$\tau = \gamma . z . \sin \theta \quad (6)$$


Dimana γ merupakan berat volume tanah, z adalah kedalaman tanah, dan θ adalah sudut kemiringan lereng. (Raia et al., 2018)



Gambar 1 . Alur penelitian


C. Hasil Penelitian dan Pembahasan

1. Data Penelitian




Gambar 2 . Grafik Intensitas Curah Hujan dan Kejadian Tanah Longsor

Intensitas curah hujan dari tahun 2015 hingga 2025 yang disertai dengan titik kejadian tanah longsor. Secara umum, pola curah hujan bersifat fluktuatif dengan beberapa puncak intensitas yang cukup tinggi, terutama pada periode sekitar 2016, 2020, 2022, dan 2024. Titik kejadian longsor (ditandai dengan simbol lingkaran merah) cenderung muncul pada periode dengan intensitas curah hujan menengah hingga tinggi, yaitu pada kisaran sekitar 10 mm –25 mm, yang mengindikasikan adanya hubungan erat antara peningkatan curah hujan dan terjadinya longsor. Meskipun demikian, grafik juga menunjukkan bahwa kejadian longsor tidak selalu terjadi pada saat curah hujan mencapai nilai maksimum.



Gambar 3 . Grafik Kelembaban dan Kejadian Tanah Longsor

Fluktuasi tingkat kelembaban udara pada periode 2016–2025 yang disertai dengan titik kejadian tanah longsor. Secara umum, nilai kelembaban berada pada kisaran relatif tinggi, yaitu sekitar 75 % –87%, dengan beberapa periode penurunan tajam yang bersifat sementara. Titik kejadian longsor sebagian besar muncul pada kondisi kelembaban menengah hingga tinggi, khususnya pada kisaran 80 % – 86%, yang mengindikasikan adanya keterkaitan yang kuat antara tingginya tingkat kelembaban dan terjadinya longsor. Meskipun demikian, grafik juga memperlihatkan bahwa kejadian longsor tidak selalu bertepatan dengan nilai kelembaban maksimum. Beberapa kejadian terjadi pada kondisi kelembaban yang lebih rendah, yang menunjukkan bahwa kelembaban bukan satu-satunya faktor pemicu langsung, melainkan berperan sebagai faktor pengkondisi bersifat sementara.



Gambar 4 . Grafik NDVI dan Kejadian Tanah Longsor

Nilai NDVI (Normalized Difference Vegetation Index) pada periode tahun 2015–2025 yang disertai dengan sebaran titik kejadian tanah longsor. Secara umum, nilai NDVI berada pada kisaran 0,60–0,67 yang mencerminkan kondisi tutupan vegetasi sedang hingga relatif baik. Namun, terdapat beberapa periode dengan tajam, bahkan hingga mendekati 0,33 – 0,45 yang mengindikasikan degradasi vegetasi atau perubahan tutupan lahan yang signifikan pada waktu-waktu tertentu. Sebaran titik kejadian longsor cenderung muncul pada periode ketika nilai NDVI relatif lebih rendah atau sedang, serta pada fase transisi ketika NDVI mengalami penurunan. Hal ini menunjukkan bahwa berkurangnya kerapatan vegetasi berasosiasi dengan meningkatnya kerentanan lereng terhadap longsor, karena berkurangnya peran vegetasi dalam memperkuat struktur tanah melalui sistem perakaran dan dalam mengurangi limpasan permukaan.

2. Pengembangan Model

Model *machine learning* yang diuji RF, SVM, dan ANN memberikan hasil kinerja yang tidak sama walaupun datanya identik (Yu et Al., 2025)(Yu et al., 2025). Perbedaan ini menunjukkan bahwa tiap algoritma memiliki ketajaman yang berbeda dalam mendeteksi hubungan kompleks pada data longsor (Bhattacharjee et al., 2025). Nilai probabilitas keluaran model selanjutnya digunakan sebagai Indeks Kerentanan Longsor (LSI) untuk membangun peta kerentanan secara spasial (Ado et al., 2022). Distribusi LSI menunjukkan bahwa area dengan nilai kerentanan tinggi umumnya berasosiasi dengan kondisi curah hujan tinggi, kelembaban tanah yang besar, serta tutupan vegetasi yang rendah. Konsistensi kerja model menunjukkan bahwa model mampu merepresentasikan proses fisik utama yang memicu longsor, meskipun ketidakpastian prediksi masih terlihat pada beberapa lokasi.

3. Evaluasi Model

Tabel 1. Evaluasi *training* model *machine learning*

Model	Akurasi	Presisi	Recall	F1-Score	AUC-ROC
RF	0.69	0.76	0.81	0.78	0.6028
SVM	0.55	0.72	0.58	0.65	0.525
ANN	0.63	0.77	0.67	0.72	0.6


Tabel 1 menunjukkan hasil evaluasi kinerja tiga model *machine learning* pada data pelatihan, yaitu Random Forest (RF), Support Vector Machine (SVM), dan Artificial Neural Network (ANN), berdasarkan metrik akurasi, presisi, recall, F1-score, dan AUC-ROC. Secara umum, Random Forest menunjukkan performa terbaik dengan akurasi tertinggi dengan nilai sebesar 0,69 dan nilai AUC-ROC sebesar 0,6028 yang menandakan kemampuan paling baik dalam membedakan kelas longsor dan non-longsor. Nilai *recall* yang tinggi 0,81 juga mengindikasikan bahwa RF efektif dalam

mendeteksi kejadian longsor. Sementara nilai ANN menunjukkan performa yang relatif seimbang, dengan presisi tertinggi sebesar 0,77 dan F1-score sebesar 0,72 mencerminkan keseimbangan yang baik antara presisi dan *recall*. Sebaliknya, SVM memiliki kinerja terendah, ditunjukkan oleh akurasi sebesar 0,55 dan AUC-ROC sebesar 0,525 yang mendekati klasifikasi acak, meskipun nilai *recall*-nya cukup tinggi. Secara keseluruhan, hasil ini menegaskan bahwa RF paling unggul pada tahap pelatihan, kemudian model ANN, sedangkan SVM masih memerlukan optimasi lebih lanjut.

Tabel 2. Evaluasi *training model machine learning*

Model	Akurasi	Presisi	Recall	F1-Score	AUC-ROC
RF	0.69	0.76	0.81	0.78	0.56
SVM	0.55	0.72	0.58	0.65	0.57
ANN	0.63	0.77	0.67	0.72	0.64


Hasil evaluasi pada data pengujian (*testing*) menunjukkan perbedaan kinerja antara ketiga model. Random Forest memperoleh akurasi tertinggi sebesar 0,69 dengan kemampuan yang baik dalam mengklasifikasikan kelas non-longsor ditunjukkan oleh nilai presisi 0,76, *recall* 0,81, dan F1-score 0,78. Namun, performanya dalam mendeteksi kejadian longsor masih relatif rendah, dengan *recall* 0,40, yang mengindikasikan bahwa sebagian kejadian longsor belum berhasil teridentifikasi. Nilai ROC-AUC sebesar 0,5620 menunjukkan kemampuan diskriminasi model yang masih tergolong moderat. Sementara model SVM menunjukkan performa terendah dengan akurasi 0,55 dan F1-score kelas longsor hanya 0,38, meskipun *recall* kejadian tanah longsor mencapai 0,47. Hal ini menandakan bahwa SVM masih kurang konsisten dalam membedakan kedua kejadian. ANN memberikan kinerja yang lebih seimbang dengan akurasi 0,63 dan nilai ROC-AUC tertinggi sebesar 0,6407 menunjukkan kemampuan terbaik dalam membedakan kejadian secara keseluruhan. ANN juga memiliki *recall* kelas longsor tertinggi sebesar 0,53, sehingga relatif lebih efektif dalam mendeteksi kejadian longsor dibandingkan RF dan SVM. Secara keseluruhan, hasil ini menunjukkan bahwa ANN lebih unggul pada data pengujian, khususnya dari sisi kemampuan diskriminasi dan deteksi kejadian longsor, sementara RF unggul pada akurasi global dan SVM memerlukan optimasi lanjutan.



Gambar 5. Metrik ROC untuk model *training*

Grafik ROC memperlihatkan kemampuan model dalam membedakan kelas positif dan negatif melalui hubungan antara True Positive Rate dan False Positive Rate (FPR). Semakin tinggi TPR berarti semakin banyak kasus positif yang berhasil ditangkap, namun semakin tinggi FPR berarti semakin banyak kasus negatif yang keliru dianggap positif (*false alarm*). Garis diagonal putus-putus merupakan acuan prediksi acak dengan nilai AUC = 0.5. Pada grafik kurva setiap model cenderung dekat dengan diagonal, artinya saat model mencoba menaikkan *recall*, dengan meningkatnya *false positive*. Berdasarkan nilai AUC, performa terbaik ditunjukkan oleh Logistic Regression dengan nilai AUC = 0.58, disusul Random Forest dengan nilai AUC = 0.56 dan SVM dengan nilai AUC = 0.56.

yang relatif setara, sedangkan ANN dengan nilai AUC = 0.53 paling rendah dan hampir mendekati random. Namun selisih AUC antar model sangat kecil, sehingga perbedaannya kinerja model tidak cukup signifikan secara statistik untuk menyatakan satu model unggul secara signifikan dibandingkan model lain.



Gambar 6 . Metrik AUC-PR untuk model *training*

Grafik Precision–Recall Curve di atas menunjukkan bagaimana performa model Random Forest (RF) dalam menyeimbangkan precision (ketepatan prediksi positif) dan recall (kemampuan menangkap seluruh kasus positif). Kurva relevan jika dataset tidak seimbang (imbalanced), karena PR Curve menggambarkan kualitas prediksi kelas minoritas. Pada grafik, terlihat bahwa ketika nilai recall masih rendah 0.1–0.4, precision naik hingga kisaran 0.45–0.46, artinya ketika model dibuat lebih selektif, prediksi positif yang dihasilkan relatif lebih banyak yang benar. Namun begitu model berusaha menangkap lebih banyak kasus positif (recall meningkat), kurva turun dan cenderung stabil pada precision rendah, yang mengindikasikan kualitas prediksi positif mulai menurun karena semakin banyak false positive. Nilai grafik yang ditunjukkan oleh Average Precision merupakan indikator kinerja keseluruhan pada kurva precision- Recall. Semakin mendekati 1 maka model semakin baik. Nilai 0.35 tergolong rendah, yang berarti model Random Forest belum mampu mempertahankan precision yang baik ketika recall ditingkatkan.

4. Analisis Distribusi Model

Tabel 3. Prediksi model *machine learning*

Data_Aktual	Prediksi_SVM	Prob_SVM	Prediksi_RF	Prob_RF	Prediksi_ANN	Prob_ANN
0	0	0,406934	0	0,13	0	0,374583
0	1	0,611937	1	0,83	1	0,716511
0	0	0,423386	0	0,1	0	0,440248
0	0	0,477694	1	0,68	0	0,441295
0	0	0,338126	0	0,03	0	0,237221
0	0	0,476882	1	0,71	0	0,438327
0	1	0,547297	0	0,36	1	0,553827
0	1	0,508738	0	0,35	0	0,43223
0	0	0,388504	0	0,26	0	0,425973
0	0	0,39737	0	0,04	0	0,188598

Data hasil prediksi menunjukkan bahwa seluruh Data Aktual bernilai 0, yang mengindikasikan tidak adanya kejadian tanah longsor pada seluruh observasi yang dianalisis. Meskipun demikian, ketiga model *machine learning*. Support Vector Machine (SVM), Random Forest (RF), dan Artificial


Neural Network (ANN) menunjukkan respons yang berbeda dalam mendeteksi potensi longsor. SVM dan RF pada beberapa observasi memprediksi terjadinya longsor yang mengindikasikan adanya false positive, yaitu kondisi ketika model mengidentifikasi risiko longsor meskipun kejadian tersebut tidak terjadi secara aktual. Hal ini mencerminkan upaya model dalam menangkap sinyal awal risiko berdasarkan pola data masukan. Ditinjau dari nilai probabilitas, Random Forest menunjukkan keyakinan prediksi yang relatif tinggi ketika memprediksi kejadian longsor, dengan beberapa nilai probabilitas di atas 0,7. Hal ini mengindikasikan bahwa RF bersifat lebih selektif dan konservatif, sehingga ketika model memprediksi longsor, keputusan tersebut didukung oleh tingkat kepercayaan yang kuat. Sebaliknya, SVM menghasilkan probabilitas yang cenderung berada pada kisaran menengah yaitu antara 0,4–0,6, yang menunjukkan karakter model yang lebih sensitif terhadap perubahan pola, namun berpotensi menghasilkan peringatan dini yang berlebihan. ANN memperlihatkan probabilitas yang lebih bervariasi, mencerminkan fleksibilitas model dalam menangkap hubungan nonlinier, tetapi juga menunjukkan adanya ketidakstabilan prediksi pada sebagian observasi.

Secara keseluruhan, hasil ini menegaskan bahwa setiap model memiliki karakteristik dan peran yang berbeda dalam konteks mitigasi bencana tanah longsor. SVM lebih sesuai digunakan sebagai sistem peringatan dini yang mengutamakan sensitivitas, Random Forest lebih tepat untuk pengambilan keputusan operasional karena tingkat keyakinan prediksinya lebih tinggi, sedangkan ANN berpotensi dikembangkan lebih lanjut melalui optimasi arsitektur dan parameter. Oleh karena itu, pendekatan kombinasi model atau penyesuaian ambang batas probabilitas (threshold) sangat disarankan untuk meningkatkan akurasi dan keandalan sistem prediksi tanah longsor.

5. Analisis Korelasi Faktor

Tabel 3. Hasil Perbandingan Model

Aspek	SVM	Random Forest	ANN
Sensitivitas	Tinggi	Sedang	Sedang
False Positive	Relatif banyak	Lebih sedikit	Sedang
Probabilitas	Sedang (0,4-0,6)	Tinggi (>).7)	Variatif
Karakter Model	Early warning	Keputusan selektif	Pola nonlinear



Gambar 7 . Grafik perbandingan pengaruh Variabel terhadap Kejadian Tanah Longsor

Grafik pada gambar 7 menunjukkan bahwa curah hujan merupakan faktor paling dominan dalam memengaruhi kejadian tanah longsor dengan kontribusi sekitar 37%, diikuti oleh kelembaban tanah sebesar 33%. Dominasi kedua variabel ini menegaskan peran faktor hidrometeorologi dalam memicu ketidakstabilan lereng. Curah hujan yang tinggi meningkatkan infiltrasi air ke dalam tanah, yang pada gilirannya menaikkan tekanan pori dan menurunkan kuat geser tanah. Kondisi ini semakin diperparah ketika kelembaban tanah sudah tinggi, karena tanah berada pada kondisi mendekati jenuh sehingga tambahan curah hujan dalam jumlah kecil sekalipun dapat memicu terjadinya longsor.

NDVI memberikan kontribusi sebesar 30%, menunjukkan bahwa kondisi tutupan vegetasi juga berperan penting dalam memodulasi kerentanan longsor.

Hasil analisis kontribusi variabel menunjukkan bahwa curah hujan merupakan faktor paling dominan yang mempengaruhi kejadian tanah longsor dengan kontribusi 37%. Air hujan yang jatuh pada permukaan tanah dan masuk ke pori-pori tanah (μ), peningkatan tekanan air pori menyebabkan berkurangnya tegangan efektif tanah secara matematis yang dinyatakan sebagai $(\sigma - \mu)$. Pada saat yang sama infiltrasi air meningkatkan berat volume karena bertambahnya kadar air yang memperbesar gaya penggerak pada lereng. Perpaduan antara meningkatnya gaya pendorong dan menurunnya kuat geser tanah menyebabkan faktor keamanan lereng (SF) persamaan (5) mengalami penurunan dan jika kondisi berlangsung terus menerus hingga nilai SF lebih kecil dari satu maka lereng akan mencapai kondisi tidak stabil dan berpotensi munculnya kejadian tanah longsor. Hasil ini menunjukkan bahwa kejadian tanah longsor pada wilayah penelitian lebih dipengaruhi oleh faktor hidrologi dibandingkan faktor penutup lahan. Meskipun ketiga faktor saling berinteraksi faktor hidrologi lebih berperan penting dalam menentukan kestabilan lereng. Dominasi curah hujan sebagai variabel utama menunjukkan bahwa longsor di daerah penelitian tergolong sebagai longsor yang dipicu oleh hujan, yaitu tanah longsor yang terjadi akibat infiltrasi hujan.

Vegetasi yang baik dapat meningkatkan stabilitas lereng melalui sistem perakaran dan pengurangan limpasan permukaan, berdasarkan pendekatan mekanika tanah persamaan (6) menunjukkan semakin besar sudut lereng semakin besar tegangan geser τ (gaya pendorong) yang mengakibatkan gaya penahan yang berasal dari kohesi tanah dan sudut geser pada persamaan (5). tidak mengalami peningkatan signifikan sehingga perbandingan antara gaya pendorong dan penahan yang dinyatakan dalam faktor keamanan lereng (SF) pada persamaan (5) semakin kecil. Selain meningkatkan gaya pendorong, kemiringan lereng juga mempercepat proses infiltrasi air hujan ke dalam tanah yang menyebabkan tekanan air pori (u). Dengan demikian kemiringan lereng berperan sebagai pengontrol utama kestabilan lereng.

NDVI yang rendah mencerminkan degradasi vegetasi yang meningkatkan risiko longsor. Berdasarkan persamaan (5) nilai faktor keamanan lereng (SF) bahwa tutupan vegetasi yang rendah atau terbuka tidak menambah kohesi (c_s) dari akar dan proses evapotranspirasi menjadi sangat kecil. Kondisi menyebabkan tanah lebih cepat jebuh pada saat hujan, tekanan air pori (μ) meningkat dan kuat geser tanah menurun sehingga nilai faktor keamanan berkurang secara signifikan. Dengan demikian tutupan lahan bervegetasi berfungsi sebagai faktor pengontrol kestabilan lereng dua mekanisme utama yaitu meningkatkan kohesi tanah secara mekanis oleh sistem akar dan pengurangan tekanan pori melalui rezim hidrologi tanah. Secara keseluruhan, hasil ini mengindikasikan bahwa kejadian tanah longsor dipengaruhi oleh interaksi antara faktor pemicu utama berupa curah hujan, kondisi awal tanah yang direpresentasikan oleh kelembaban, serta faktor penahan alami berupa tutupan vegetasi, sehingga pendekatan multivariat menjadi krusial dalam pemodelan dan sistem peringatan dini tanah longsor.

Hasil dari pemodelan dan analisis Kerentanan Tanah Longsor dapat dijadikan acuan untuk pembuatan peta kerentanan tanah longsor dalam upaya identifikasi wilayah dengan tingkat kerentanan tinggi sebagai prioritas dalam upaya pengurangan risiko, sebagai salah satu layer utama dalam penyusunan rencana tata ruang wilayah pada rekomendasi kawasan pemukiman dan pembangunan infrastruktur serta pengembangan kawasan budidaya dan penentuan zona rawan longsor yang dapat digunakan dalam klasifikasi tingkat bahaya longsor secara spasial.

D. Kesimpulan

Kinerja model menunjukkan pola yang konsisten. Random Forest RF unggul pada akurasi global, sedangkan ANN lebih menjanjikan untuk deteksi kejadian longsor pada data uji. Pada data training, RF menjadi yang terbaik dengan akurasi 0,69, precision 0,76, recall 0,81, F1-score 0,78, dan AUC-ROC 0,6028, disusul ANN dengan nilai akurasi 0,63 dan AUC 0,60, sementara SVM terendah dengan nilai akurasi 0,55 dan nilai AUC 0,525. Pada data testing, RF tetap terlihat kuat untuk akurasi keseluruhan dengan nilai akurasi 0,69 dan nilai F1= 0,78, tetapi kemampuan mendeteksi kelas longsor masih terbatas. Sebaliknya, ANN pada data uji menunjukkan keseimbangan yang lebih baik untuk deteksi longsor karena cenderung lebih mampu memprediksi kejadian longsor tetapi dengan risiko false alarm lebih tinggi. Faktor dominan pemicu longsor dalam analisis variabel adalah komponen hidrometeorologi, terutama curah hujan. Grafik kontribusi variabel menunjukkan urutan pengaruh kejadian tanah longsor berupa curah hujan, kelembaban dan NDVI. Variabel menyiratkan bahwa kejadian longsor paling kuat dipengaruhi kondisi hujan dan kejenuhan tanah, sementara vegetasi tetap berperan penting sebagai faktor protektif kerentanan, tetapi kontribusinya sedikit dibanding kedua faktor hidrologis tersebut.

Daftar Pustaka

- Abdo, H. G., & Richi, S. M. (2024). Journal of King Saud University - Science Application of machine learning in the assessment of landslide susceptibility : A case study of mountainous eastern Mediterranean region , Syria. *Journal of King Saud University - Science*, 36(5), 103174. <https://doi.org/10.1016/j.jksus.2024.103174>
- Achu, A. L., Thomas, J., Aju, C. D., Vijith, H., & Gopinath, G. (2024). Geomorphology Redefining landslide susceptibility under extreme rainfall events using deep learning. *Geomorphology*, 448(December 2022), 109033. <https://doi.org/10.1016/j.geomorph.2023.109033>
- Ado, M., Amitab, K., Maji, A. K., Jasińska, E., Gono, R., Leonowicz, Z., & Jasiński, M. (2022). Landslide Susceptibility Mapping Using Machine Learning: A Literature Survey. *Remote Sensing*, 14(13), 3029. <https://doi.org/10.3390/rs14133029>
- Alfarizi, R., Honesti, L., Driptufany, D. M., & Fikri, S. (2023). Mapping of the landslide area of Tanjung Gadang District, Sijunjung Regency. *Journal of Science*, 5(1), 123–135.
- Badan Nasional Penanggulangan Bencana. (2025). *Data bencana tanah longsor*. <https://gis.bnpb.go.id/databencana/tabel/pencarian.php>
- Bhattacharjee, S., Kumar, S., Shankar, U., & Mishra, O. P. (2025). Geoscience Frontiers An insight into seismotectonic scenario of the southwestern part of Delhi-NCR and delineation of new faults : Implications to seismic hazard potential. *Geoscience Frontiers*, 16(2), 101991. <https://doi.org/10.1016/j.gsf.2024.101991>
- Effendi, A. Y., & Hariyanto, T. (2016). Pembuatan Peta Daerah Rawan Bencana Tanah Longsor dengan Menggunakan Metode Fuzzy logic. *Jurnal Teknik ITS*, 5(2), A714–A722.

- Hong, H., Pourghasemi, H. R., & Pourtaghi, Z. S. (2018). Review on landslide susceptibility mapping using support vector machines. *Computers & Geosciences*. <https://doi.org/10.1016/j.catena.2018.03.003>
- Jia, Z., Cheng, Z., Chang, Z., Li, Q., Huang, F., & Peng, Y. (2025). Journal Pre-proof. *Journal of Rock Mechanics and Geotechnical Engineering*. <https://doi.org/10.1016/j.jrmge.2025.12.011>
- Liu, X., Shao, S., & Shao, S. (2024). ScienceDirect Landslide susceptibility prediction and mapping in Loess Plateau based on different machine learning algorithms by hybrid factors screening : Case study of Xunyi County , Shaanxi Province , China. *Advances in Space Research*, 74(1), 192–210. <https://doi.org/10.1016/j.asr.2024.03.074>
- Lyu, H., Yin, Z., Hicher, P., & Laouafa, F. (2024). Geoscience Frontiers Incorporating mitigation strategies in machine learning for landslide susceptibility prediction. *Geoscience Frontiers*, 15(5), 101869. <https://doi.org/10.1016/j.gsf.2024.101869>
- Reichenbach, P., Rossi, M., Malamud, B. D., Mihir, M., & Guzzetti, F. (2018). A review of statistically-based landslide susceptibility models. *Earth-Science Reviews*, 180, 60–91.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437.
- Tanesab, F. I., Dethan, J. J. S., & Selan, W. (2023). Pemetaan daerah rawan longsor di wilayah Kota Kupang berbasis geographic information system (GIS). *Journal of Computer Science and Technology*, 1(1), 35–40.
- Yu, L., Pradhan, B., & Wang, Y. (2025). Geoscience Frontiers A comparative study of various combination strategies for landslide susceptibility mapping considering landslide types. *Geoscience Frontiers*, 16(2), 101999. <https://doi.org/10.1016/j.gsf.2024.101999>
- Zhao, L., et al. (2023). Evaluating Landslide Susceptibility Using Sampling Methodology and Machine Learning. *ISPRS International Journal of Geo-Information*, 12(5), 197.