

Tinjauan Sistematis: Pemetaan Kerentanan Tanah Longsor berbasis *Machine Learning*

Mohammad Alvi Aldi Bani¹, Prananda Navitas^{✉ 2}, Ary Mazharuddin Shiddiqi³

¹Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia

² Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia

³ Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia

Diunggah: 15/06/2025 | Direview: 04/07/2025 | Diterima: 09/07/2025

✉ p.navitas@its.ac.id

Abstrak: Masalah longsor merupakan salah satu jenis bencana yang merusak kerugian jiwa ekonomi dan manusia. Masalah ini membutuhkan kesadaran dan pemetaan daerah rentan untuk mencegah efeknya. Penelitian ini meninjau 28 penelitian yang berlokasi di Cina, Iran, Pakistan, Korea Selatan, Slovakia, Yunani, Brazil, Rwanda dan Rumania. Negara-negara ini menghadapi masalah longsor karena topografinya lebih banyak jenis medan berbukit. *Random Forest* menjadi metode yang paling populer digunakan dalam pemetaan kerentanan tanah longsor. Akurasi yang didapat dalam penelitian tersebut menghasilkan akurasi antara 70% dan 98,3% dan nilai AUC dari sekitar 0,8 hingga 0,997. Beberapa makalah menunjukkan bahwa ensemble dan pendekatan pembelajaran mendalam (termasuk jaringan saraf konvolusi dan berulang) berkinerja secara kompetitif tetapi membutuhkan sumber daya komputasi yang lebih besar. Faktor topografi (kemiringan, ketinggian, aspek, kelengkungan) menjadi faktor yang paling sering digunakan dalam topik ini. Tinjauan artikel ini mencakup publikasi dalam kurun waktu lima tahun terakhir, yaitu dari tahun 2020 hingga Mei 2025. Penelitian ini lebih difokuskan pada model *machine learning* untuk memetakan masalah longsor di daerah terpilih ini. Penelitian ini dapat membantu peneliti masa depan yang akan memanfaatkan metode *machine learning* untuk memetakan kerentanan daerah terhadap tanah.

Kata Kunci: Pemetaan Bencana; Tanah Longsor; *Machine Learning*; Tinjauan Sistematis

A Systematic Review: Machine Learning-based Landslide Vulnerability Mapping

Abstract: Landslide problem is one type of disaster that damages economic and human lives. This problem requires awareness and mapping of vulnerable areas to prevent its effects. This study reviewed 28 studies located in China, Iran, Pakistan, South Korea, Slovakia, Greece, Brazil, Rwanda and Romania. These countries face landslide problems due to their topography of more hilly terrain types. Random Forest is the most popular method used in landslide susceptibility mapping. The accuracy obtained in these studies resulted in accuracy between 70% and 98.3% and AUC values from about 0.8 to 0.997. Several papers have shown that ensemble and deep learning approaches (including convolutional and recurrent neural networks) perform competitively but require greater computational resources. Topography factors (slope, elevation, aspect, curvature) are the most frequently used factors in this topic. This article review covers publications within the last five years, from 2020 to May 2025. This research is more focused on machine learning models to map landslide problems in these selected areas. This research can help future researchers who will utilise machine learning methods to map regional vulnerability to landslides.

Keywords: Disaster Mapping; Landslides; Machine Learning; Systematic Review.

1. Latar Belakang

Tanah longsor merupakan salah satu ancaman geologis global yang paling merusak, mengakibatkan hilangnya nyawa, kerugian ekonomi yang besar, dan kerusakan lingkungan yang parah (Shafapourtehrany et al., 2025). Dampak destruktif ini menegaskan betapa mendesaknya strategi mitigasi dan manajemen risiko yang efektif. Dalam kerangka ini, Pemetaan Kerentanan Longsor menjadi instrumen analisis yang sangat penting (Azarafza et al., 2021a). Dalam pemetaan kerentanan longsor, *Machine Learning* (ML) menunjukkan keunggulan yang signifikan dibandingkan metode statistik tradisional, terutama karena kemampuannya memodelkan hubungan non-linear yang kompleks dalam data besar dan di area dengan data geoteknik yang minim (Ado et al., 2022; Kavzoglu et al., 2018; Tehrani et al., 2022). Algoritma seperti *Random Forest* (RF), *Support Vector Machines* (SVM), dan *Artificial Neural Network* (ANN) telah menjadi standar aplikasi yang berhasil (Marjanović et al., 2017; Merghadi et al., 2020). Inovasi lebih lanjut melalui model ensemble dan deep learning bahkan menawarkan peningkatan performa yang lebih tinggi (Ado et al., 2022; Bandara et al., 2020). Namun, implementasinya masih menghadapi kendala, terutama terkait kebutuhan persiapan data yang teliti dan seleksi faktor pengondisi yang akurat (Lun et al., n.d.; Mwakapesa et al., n.d.). Meskipun begitu, kontribusi pembelajaran mesin untuk menghasilkan peta kerentanan longsor yang lebih akurat dan andal tetap sangat menjanjikan (Tehrani et al., 2022). Seiring berjalannya waktu, model yang lebih canggih seperti pendekatan gabungan dan *deep learning* (DL) seperti *Convolutional Neural Networks* (CNN) mulai menunjukkan kinerja yang kompetitif. Namun, model-model ini memiliki tantangan, terutama kebutuhan sumber daya komputasi yang lebih besar dan waktu pelatihan yang lebih lama dibandingkan dengan model ML tradisional. Oleh karena itu, tantangan implementasi tetap ada, tidak hanya dalam hal komputasi tetapi juga dalam persiapan data yang teliti dan pemilihan faktor yang paling relevan untuk konteks geomorfologi lokal yang spesifik. Mengingat variasi dalam pilihan model, faktor prediktif, dan kinerja yang dilaporkan, serta pesatnya perkembangan jumlah publikasi, kajian sistematis yang komprehensif sangat diperlukan. Penelitian ini bertujuan untuk mensintesis temuan-temuan yang ada, mengidentifikasi tren, kesenjangan riset, dan memberikan rekomendasi metodologis untuk penelitian selanjutnya.

2. Metode

2.1. Pengumpulan Data

2.1.1. Database dan Kata Kunci

Penelitian ini menggunakan pendekatan data sekunder yang bersumber dari artikel jurnal dan prosiding konferensi yang telah dipublikasikan sebelumnya. Seluruh data primer dikumpulkan melalui database Scopus, yang diakses dari situs resminya (www.scopus.com). Scopus dipilih karena merupakan basis data kutipan dan abstrak terbesar dan paling komprehensif, sehingga ideal untuk tahap pengumpulan data awal sebelum dilakukan ekstraksi lebih lanjut (Alsharif et al., 2021; Wang et al., 2015). Proses pencarian literatur difokuskan pada artikel yang diterbitkan pada tahun 2020 hingga bulan Mei 2025, dengan topik utama pemetaan kerentanan bencana tanah longsor dengan machine learning (ML). Untuk memastikan relevansi, kata kunci pencarian secara spesifik menggunakan istilah dalam bahasa Inggris seperti. Hasil penelusuran awal ini berhasil mengidentifikasi sebanyak 1657 publikasi yang relevan dari rentang waktu 5 tahun. Selanjutnya, artikel tersebut direduksi berdasarkan tipe dokumen, bahasa, aksesibilitas, dan jumlah disitasi. Dokumen yang diambil hanya berupa artikel dengan bahasa Inggris yang dapat diakses dan memiliki lebih dari 40 sitasi.


2.1.2. Kriteria Inklusi dan Eksklusi

Untuk memastikan relevansi dan kualitas, kami menyaring jurnal penelitian menggunakan kriteria inklusi dan eksklusi yang ketat. Artikel yang terpilih harus lengkap dan artikel tersebut harus didasarkan pada pemetaan kerentanan longsor menggunakan teori dan/atau konsep *machine learning*. Mengenai kriteria terakhir ini, tidak cukup hanya sebuah artikel yang menyebutkan konsep atau teori pemetaan kerentanan tanah longsor untuk dipilih, tetapi teori dan/atau konsep tersebut perlu menjadi pusat penelitian (Aslam et al., 2022). Alasan utamanya adalah karena ulasan literatur hanya merangkum temuan orang lain dan tidak menyajikan data primer, serta berisiko tinggi terhadap bias penulisnya, sehingga tidak cocok untuk analisis sistematis. Berdasarkan kata kunci dan kriteria-kriteria tersebut maka formulasi pencarian yang digunakan adalah (TITLE-

ABS-KEY ("landslide susceptibility" OR "landslide susceptibility mapping")) AND (TITLE-ABS-KEY ("machine learning" OR "artificial intelligence" OR "deep learning" OR "support vector machine" OR "random forest" OR "logistic regression" OR "neural network" OR "gradient boosting" OR "XGBoost"))

2.2. Metode Analisis

Penelitian ini dilaksanakan sebagai sebuah Tinjauan Literatur Sistematis (*Systematic Literature Review - SLR*), yaitu sebuah metode untuk mengulas literatur secara terstruktur dan dapat diverifikasi (Rahayu & Syafril, 2018). Pendekatan ini dipilih karena kemampuannya untuk memberikan gambaran yang jelas mengenai lanskap riset terkini, sekaligus mengidentifikasi area yang memerlukan eksplorasi lebih lanjut (Feak & Swales, 2009). Seluruh prosedur penelitian, mulai dari pencarian hingga pelaporan, mengacu pada kerangka kerja *Preferred Reporting Items for Systematic Reviews and Meta-Analysis* (PRISMA) untuk menjaga kualitas dan transparansi (Moher et al., 2009). Sebagai panduan praktis, kami menerapkan alur kerja empat langkah yang diuraikan oleh Ramdhani (2014). Proses dimulai dengan pemilihan topik yang spesifik. Selanjutnya, kami melakukan pencarian dan seleksi literatur secara cermat melalui database akademik dengan menerapkan kriteria yang ketat. Artikel yang lolos seleksi kemudian dianalisis dan disintesis untuk mengekstrak temuan kunci dan merangkainya menjadi sebuah argumen utuh. Terakhir, seluruh hasil disusun dalam sebuah laporan yang terstruktur agar mudah dipahami.



Gambar 1. Diagram Prisma
Sumber: Penulis, 2025

3. Hasil dan Pembahasan

Proses seleksi literatur dalam penelitian ini dilakukan secara sistematis dan bertahap. Pencarian awal dengan kata kunci '*Landslide Susceptibility Mapping*' dan '*Machine Learning*' untuk periode 2020 hingga Mei 2025 mengidentifikasi sebanyak 1.657 publikasi. Langkah pertama adalah penghapusan duplikasi, di mana 43 artikel yang identik berhasil disingkirkan. Selanjutnya, pada tahap identifikasi, sebanyak 1.494 dokumen dieksklusi karena tidak memenuhi kriteria kelayakan yang telah ditetapkan, seperti bukan merupakan artikel, tidak berbahasa Inggris, tidak dapat diakses, atau memiliki jumlah sitasi di bawah 40. Pada tahap penyaringan (*screening*), 41 artikel lainnya dikeluarkan karena tidak dapat diunduh. Terakhir, melalui peninjauan teks lengkap untuk memeriksa kelayakan, 51 studi disingkirkan karena isinya tidak relevan dengan fokus aplikasi


pemetaan yang diteliti. Dengan demikian, setelah melalui seluruh proses seleksi yang ketat ini, total akhir sebanyak 28 artikel yang paling sesuai dipilih untuk dianalisis.

3.1. Tahun Publikasi

Publikasi artikel mengenai pemetaan kerentanan tanah longsor berbasis *machine learning* mengalami fluktuasi dalam lima tahun terakhir. Tahun 2020 mencatat jumlah publikasi terbanyak yang masuk dalam proses penyaringan awal (data screening), sekaligus menjadi tahun dengan jumlah artikel terbanyak yang lolos seleksi dan diikutkan dalam analisis akhir (data included). Hal ini mencerminkan meningkatnya perhatian peneliti terhadap penerapan metode *machine learning* dalam studi kerentanan tanah longsor pada awal dekade ini.

Pada tahun 2021 dan 2022, jumlah artikel yang disaring masih tinggi, namun hanya sebagian kecil di antaranya yang memenuhi kriteria inklusi. Hal ini dapat menunjukkan meningkatnya variasi pendekatan, cakupan studi yang lebih luas, atau kualitas laporan ilmiah yang belum sepenuhnya relevan dengan fokus kajian sistematis ini. Sementara itu, tahun 2023 dan 2024 menunjukkan tren penurunan baik dalam jumlah artikel yang disaring maupun yang dimasukkan. Penurunan ini dapat disebabkan oleh waktu proses publikasi ilmiah yang memerlukan jeda, serta kemungkinan bahwa topik pemetaan kerentanan tanah longsor dengan ML mulai mencapai titik jenuh dalam beberapa pendekatan utama.

Secara keseluruhan, pola distribusi ini mencerminkan bahwa pemanfaatan machine learning untuk studi kerentanan longsor berkembang pesat pada awal 2020-an, dengan puncaknya pada tahun 2020. Meskipun demikian, penyaringan ketat berdasarkan kualitas metodologi dan kesesuaian topik membuat hanya sebagian kecil artikel yang akhirnya dapat dimasukkan dalam analisis sistematis.




Gambar 2. Tahun Publish Artikel
Sumber: Scopus (Diolah), 2025

3.2. Lokasi Penelitian

Kondisi geografis dan geologis tempat studi sangat menentukan efektivitas model machine learning dalam mendeteksi area rawan longsor. sebagian besar penelitian mengenai pemetaan kerentanan tanah longsor dengan pendekatan *machine learning* dilakukan di kawasan Asia. Negara yang paling dominan adalah China, dengan total 13 studi, disusul oleh Iran sebanyak 6 studi, serta Pakistan dan Korea Selatan masing-masing sebanyak 2 studi. Negara-negara lain seperti Slovakia, Yunani, Brasil, Rwanda, dan Rumania hanya menyumbangkan masing-masing satu studi. Fakta ini menunjukkan bahwa konsentrasi penelitian masih sangat terpusat pada negara-negara yang secara geografis rawan longsor, memiliki wilayah topografi kompleks, serta memiliki ketersediaan data spasial yang baik. Studi-studi tersebut umumnya memilih daerah dengan topografi kompleks, hujan tinggi, struktur tanah yang labil, serta tekanan antropogenik (pembangunan dan deforestasi).

Pemilihan lokasi dengan kondisi ekstrem tersebut memungkinkan model untuk belajar dari pola yang kuat, namun juga mengandung risiko *overfitting* apabila tidak divalidasi pada wilayah berbeda. Beberapa studi, seperti oleh (R. Yuan & Chen, 2022) dan (Shahzad et al., 2022), menyertakan data penggunaan lahan, elevasi, kelerengan, jarak ke sungai, dan curah hujan sebagai variabel input. Hal ini menunjukkan bahwa penggabungan data geospasial yang relevan secara lokal dapat meningkatkan presisi pemetaan.

Jika dilihat dengan tren kejadian bencana dari (*EM-DAT - The International Disaster Database*, n.d.) Terdapat korelasi yang erat antara frekuensi kejadian longsor di suatu benua dengan intensitas penelitian yang dilakukan di wilayah tersebut. Wilayah Asia yang mencatatkan angka kejadian tertinggi juga menjadi fokus utama dalam kajian ilmiah, terbukti dari dominasi negara-negara Asia sebagai lokasi penelitian. Dengan kata lain, semakin tinggi risiko atau frekuensi kejadian longsor di suatu wilayah, semakin besar pula perhatian yang diberikan oleh kalangan akademik untuk mengembangkan dan menerapkan metode prediktif berbasis *machine learning*. Hal ini juga mencerminkan ketersediaan data, dukungan pemerintah terhadap riset bencana, dan urgensi mitigasi sebagai pendorong utama aktivitas penelitian. Namun, masih terdapat kesenjangan di beberapa wilayah seperti Afrika dan Amerika Selatan, di mana kejadian longsor juga cukup tinggi namun belum diimbangi dengan jumlah studi yang sebanding. Hal ini menunjukkan adanya peluang bagi penelitian lebih lanjut di kawasan-kawasan tersebut.




Gambar 3. a. Tren longsor tiap benua b. Lokasi Penelitian
 Sumber: a. [EM-DAT](#)(diolah), 2025 b. *Scopus* (Diolah), 2025

3.3. Penerbit dan jumlah sitasi

Berdasarkan analisis terhadap distribusi penerbit, diketahui bahwa mayoritas artikel dalam kajian sistematis ini diterbitkan oleh MDPI AG sebanyak 14 publikasi, disusul oleh MDPI sebanyak 8 publikasi. Sementara itu, Taylor and Francis Ltd. menerbitkan 4 artikel dan Nature Research hanya menerbitkan 2 artikel. Hal ini menunjukkan dominasi penerbit akses terbuka, khususnya MDPI, dalam mempublikasikan kajian terkait pemetaan kerentanan tanah longsor berbasis *machine learning*. Didominasinya MDPI bisa jadi dipengaruhi oleh kemudahan proses publikasi dan akses terbuka yang memperluas jangkauan pembaca serta peluang sitasi yang lebih besar.

Sementara itu, berdasarkan jumlah sitasi, artikel (Azarafza et al., 2021a) menjadi yang paling berpengaruh dengan total 267 sitasi, diikuti oleh (Chang et al., 2020) dengan 234 sitasi, dan (Fang et al., 2021) dengan 192 sitasi. Sebagian besar artikel yang menempati urutan teratas dalam jumlah sitasi diterbitkan pada rentang tahun 2020–2022, menandakan bahwa topik ini mengalami peningkatan minat dan relevansi dalam lima tahun terakhir. Selain itu, banyak artikel dengan jumlah sitasi tinggi juga berasal dari jurnal-jurnal yang diterbitkan oleh MDPI, mengindikasikan bahwa meskipun ada pandangan skeptis terhadap jurnal akses terbuka, artikel-artikel dari penerbit ini tetap memiliki dampak ilmiah yang signifikan. Keterkaitan antara jumlah publikasi dan sitasi menunjukkan bahwa jurnal-jurnal dari penerbit terbuka tidak hanya mendominasi secara kuantitatif, namun juga mampu bersaing dalam hal kualitas dan pengaruh. Artikel-artikel dengan sitasi tinggi umumnya menyajikan

pendekatan baru, pemanfaatan teknologi terkini seperti machine learning dan GIS, serta studi kasus pada wilayah yang rawan longsor, menjadikannya rujukan penting bagi peneliti selanjutnya.



Gambar 4. a. Publikasi berdasarkan Publisher b. Jumlah Sitasi Artikel
Sumber: Scopus (Diolah), 2025


3.4. Faktor yang mempengaruhi longsor

Berdasarkan hasil sintesis dari kajian sistematis, terdapat beberapa faktor utama yang sering digunakan dalam model pemetaan kerentanan tanah longsor berbasis machine learning. Faktor-faktor ini dipilih karena keterkaitannya secara ilmiah dan empiris terhadap proses terjadinya longsor. Hasil analisis menunjukkan bahwa:

1. *Topographic Factors* merupakan faktor paling dominan, digunakan dalam 28 studi. Faktor ini meliputi elevasi, kemiringan lereng (*slope*), aspek lereng (*aspect*), serta bentuk lahan (*curvature*). Topografi sangat memengaruhi kestabilan lereng, sehingga menjadi prediktor utama dalam hampir semua model pemetaan.
2. *Proximity Variables* digunakan dalam 20 studi, termasuk jarak terhadap sungai, jalan, dan pemukiman. Variabel ini berkaitan dengan tekanan manusia terhadap lingkungan dan pengaruh eksternal terhadap stabilitas lereng.
3. *Geologic Factors* dan *Hydrologic Factors* masing-masing digunakan dalam 17 studi. Faktor geologi mencakup jenis batuan dan struktur geologi yang memengaruhi kekuatan material, sedangkan faktor hidrologi mencakup curah hujan, kedalaman air tanah, dan drainase, yang berperan besar dalam memicu longsor akibat kejenuhan air.
4. *Soil Factors* dan *Climate Factors* digunakan dalam 10 studi. Jenis tanah, tekstur, dan kadar air tanah sangat menentukan daya dukung lereng. Sementara itu, iklim (terutama curah hujan dan suhu) memiliki pengaruh jangka panjang terhadap proses pelapukan dan kelembaban tanah.
5. *Land Use/Cover* digunakan dalam 9 studi, mengacu pada penggunaan lahan seperti hutan, permukiman, atau lahan terbuka. Perubahan tutupan lahan secara langsung dapat meningkatkan kerentanan terhadap longsor.
6. *Vegetation*, *Human Activity*, dan *Remote Sensing Indices* masing-masing muncul dalam 6 studi. Keberadaan vegetasi dapat meningkatkan stabilitas lereng melalui sistem perakaran, sedangkan aktivitas manusia seperti pembangunan dan deforestasi dapat memperburuk kondisi lereng. Indeks penginderaan jauh seperti NDVI (*Normalized Difference Vegetation Index*) digunakan untuk mendeteksi kondisi tutupan lahan dan kesehatan vegetasi.

Faktor topografi menempati posisi sentral dalam hampir semua studi, disusul oleh variabel kedekatan dan karakteristik geologi serta hidrologi. Komposisi ini menunjukkan bahwa model machine learning dalam LSM sangat bergantung pada integrasi antara faktor fisik lereng dan tekanan eksternal seperti aktivitas manusia.

Oleh karena itu, pemilihan variabel input yang tepat sangat menentukan akurasi dan generalisasi model pemetaan.



Gambar 5. Faktor Paling Populer
Sumber: Penulis, 2025


3.5. Model yang digunakan

Dalam dua dekade terakhir, pemanfaatan algoritma *machine learning* (ML) dalam studi *Landslide Susceptibility Mapping* (LSM) mengalami pertumbuhan yang signifikan. Studi-studi yang direview menunjukkan keberagaman metode yang digunakan, baik dari kategori *single learner* hingga *ensemble methods*. Beberapa metode populer yang sering digunakan antara lain:

- Single learners: seperti Support Vector Machine (SVM), Logistic Regression (LR), Decision Tree (DT), dan Naïve Bayes (NB).
- Ensemble methods: seperti Random Forest (RF), Gradient Boosting Machine (GBM), Extreme Gradient Boosting (XGBoost), Bagging, AdaBoost, dan Blending.

Misalnya, studi oleh (X. Yuan et al., 2022) membandingkan kinerja tiga model tunggal dan tiga model ensemble, di mana model ensemble (khususnya Bagging dan Boosting) menunjukkan performa prediksi yang lebih tinggi dan stabil. Sementara (Fang et al., 2021) memperkenalkan pendekatan *heterogeneous ensemble learning* yang menggabungkan kelebihan dari berbagai algoritma melalui teknik *blending*, yang mampu mencapai nilai AUC hingga 0.96. Di sisi lain, (Pham et al., 2021) dan (Shahzad et al., 2022) menyoroti pentingnya membandingkan performa antar metode ML klasik dalam berbagai kondisi spasial dan atribut data. Penggunaan banyak model dalam satu studi menunjukkan pentingnya eksplorasi performa sebelum implementasi operasional, serta semakin menguatkan posisi ensemble learning sebagai pendekatan unggulan dalam LSM.

Dari total 28 studi yang dianalisis, model Random Forest (RF) merupakan algoritma yang paling sering digunakan dalam pemetaan kerentanan tanah longsor, ditemukan dalam 14 studi. Ini diikuti oleh Support Vector Machine (SVM) (12 studi), dan Logistic Regression (11 studi). Sementara itu, pendekatan berbasis Deep Learning seperti Convolutional Neural Networks (CNN) dan Deep Neural Networks (DNN) mulai mendapat perhatian, meskipun baru digunakan dalam 5 studi. Kombinasi model atau metode ensemble juga cukup populer, digunakan dalam 7 studi.




Gambar 2. Model yang digunakan
Sumber: Penulis, 2025

3.6. Performa Model

Hasil performa model merupakan elemen penting dalam studi pemetaan kerentanan tanah longsor berbasis *machine learning*, terutama untuk mengukur kemampuan generalisasi model terhadap data baru. Hampir seluruh studi yang direview menggunakan *Area Under the Receiver Operating Characteristic Curve* (AUC-ROC) sebagai metrik utama. Nilai AUC yang tinggi (misalnya di atas 0.90) menjadi indikator bahwa model mampu memisahkan antara area rawan dan tidak rawan longsor dengan baik. Hasil evaluasi menunjukkan bahwa akurasi model bervariasi antara 49.9% hingga 98.3%, dengan nilai *Area Under Curve* (AUC) antara 0.568 hingga 0.997. Model RF dan SVM sering menjadi yang terbaik, tetapi dalam beberapa kasus, model lain seperti *Extreme Gradient Boosting* (XGBoost), *Deep Learning* (DL), dan *Weighted Frequency Ratio* (WFR) juga unggul, tergantung pada kondisi data dan konteks geografis penelitian. Sebagai contoh:

- RF menghasilkan akurasi hingga 98.3% (Pham et al., 2021), 96,2% (Shahzad et al., 2022)
- CNN-DNN mencapai AUC 0.909 dengan akurasi 84.8% (Azarafa et al., 2021b)
- XGBoost mencetak AUC tertinggi sebesar 0.997 (Kulsoom et al., 2023)
- SVM menghasilkan nilai AUC = 0.969 (SVM)

Selain AUC, beberapa studi juga melaporkan metrik tambahan seperti *Accuracy*, *Sensitivity/Recall*, *Specificity*, *Kappa coefficient* dan *RMSE*. Namun demikian, terdapat variasi signifikan dalam metode validasi yang digunakan. Sebagian studi menerapkan validasi silang (*cross-validation*), sementara lainnya hanya menggunakan pembagian data training-test split yang sederhana. Minimnya laporan mengenai teknik validasi silang yang sistematis menjadi catatan penting, karena validasi yang lemah bisa menyebabkan kesalahan dalam interpretasi akurasi model. Lebih jauh lagi, sebagian besar studi belum menerapkan *spatial cross-validation*, padahal hal ini penting dalam konteks pemetaan geospasial karena dapat menguji kemampuan model memprediksi area yang belum pernah terlihat sebelumnya (*spatial transferability*).



Gambar 2. Performa model terbaik
Sumber: Penulis, 2025

4. Kesimpulan

Pemetaan kerentanan tanah longsor merupakan bagian penting dalam strategi mitigasi bencana, khususnya di wilayah dengan karakteristik topografi kompleks. Berdasarkan kajian terhadap 28 studi yang menggunakan pendekatan *machine learning*, dapat disimpulkan bahwa algoritma seperti *Random Forest* (RF) dan *Support Vector Machine* (SVM) mendominasi penggunaan karena menunjukkan kinerja klasifikasi yang sangat baik, dengan tingkat akurasi mencapai 98.3% dan nilai *Area Under Curve* (AUC) hingga 0.997. Model *deep learning* seperti *Convolutional Neural Network* (CNN) dan pendekatan gabungan seperti *blending* atau *stacking* juga menunjukkan hasil yang kompetitif, meskipun memerlukan sumber daya komputasi yang lebih besar. Faktor-faktor prediktif yang paling signifikan dalam model-model tersebut hampir selalu berkaitan dengan variabel topografi seperti kemiringan lereng, elevasi, aspek, dan kurvatur. Di samping itu, faktor-faktor seperti jarak ke jalan, sungai, sesar, serta parameter geologi dan hidrologi juga berperan penting dalam menentukan kerentanan. Meskipun demikian, sebagian besar studi hanya terbatas pada wilayah geografis tertentu—terutama di Asia—dan belum banyak melakukan validasi model lintas wilayah. Ini menunjukkan bahwa meskipun pendekatan *machine learning* telah terbukti menjanjikan, tantangan terkait generalisasi, ketersediaan data, dan interpretabilitas hasil masih menjadi perhatian utama.

Oleh karena itu, untuk meningkatkan efektivitas dan relevansi penelitian pemetaan kerentanan tanah longsor di masa depan, disarankan agar studi dilakukan di wilayah yang lebih beragam secara geografis dan geomorfologis, termasuk kawasan rawan longsor di Asia Tenggara, Afrika, dan Amerika Selatan yang saat ini masih minim perhatian. Selain itu, integrasi data dari berbagai sumber seperti citra satelit, data LiDAR, serta informasi temporal seperti curah hujan atau perubahan tutupan lahan, akan memperkuat kualitas model dan memungkinkan prediksi yang lebih dinamis dan adaptif terhadap perubahan lingkungan. Pengembangan model juga perlu mengarah pada keseimbangan antara akurasi dan interpretabilitas. Model-model *hybrid* yang menggabungkan kekuatan *deep learning* dengan transparansi algoritma seperti *random forest* atau *logistic regression* sangat layak untuk dieksplorasi lebih lanjut. Teknik interpretasi model seperti SHAP (*Shapley Additive Explanations*) juga dapat membantu menjelaskan kontribusi masing-masing variabel secara intuitif, sehingga hasil pemodelan dapat digunakan secara efektif oleh pengambil kebijakan dan pemangku kepentingan non-teknis.

Dalam konteks kebijakan, hasil pemetaan kerentanan longsor berbasis *machine learning* harus diterjemahkan ke dalam aksi nyata. Pemerintah, baik di tingkat lokal maupun nasional, perlu memperkuat infrastruktur pengumpulan data geospasial, termasuk sistem informasi geografis (GIS) dan platform data terbuka. Data ini

penting untuk mendukung proses perencanaan tata ruang, pembangunan infrastruktur, dan penentuan zona rawan bencana secara ilmiah dan terukur.

Selain itu, peningkatan kapasitas teknis sumber daya manusia di tingkat daerah sangat diperlukan agar teknologi *machine learning* benar-benar dapat diadopsi dan dimanfaatkan secara optimal. Pelatihan, pendampingan, dan pelibatan komunitas dalam proses pemodelan dan interpretasi hasil akan mendorong terciptanya sistem mitigasi yang lebih partisipatif dan berkelanjutan. Lebih jauh lagi, pemerintah perlu menyusun pedoman atau standar nasional terkait pemodelan kerentanan tanah longsor berbasis AI, agar metode yang digunakan konsisten, valid, dan akuntabel. Kolaborasi antar sektor, baik antara peneliti, lembaga pemerintah, sektor swasta, maupun komunitas lokal, menjadi fondasi penting dalam mendorong penerapan teknologi ini secara luas dan berkelanjutan. Dengan pendekatan yang terpadu antara sains, kebijakan, dan masyarakat, pemetaan kerentanan longsor berbasis machine learning berpotensi menjadi alat strategis dalam menyelamatkan nyawa, mengurangi kerugian ekonomi, dan membangun ketahanan lingkungan di masa depan.

Daftar Pustaka

- 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>
- Alsharif, A. H., Salleh, N. Z. M., Baharun, R., Hashem E, A. R., Mansor, A. A., Ali, J., & Abbas, A. F. (2021). Neuroimaging Techniques in Advertising Research: Main Applications, Development, and Brain Regions and Processes. *Sustainability*, 13(11), 6488. <https://doi.org/10.3390/su13116488>
- Arabameri, A., Karimi-Sangchini, E., Pal, S. C., Saha, A., Chowdhuri, I., Lee, S., & Bui, D. T. (2020). Novel credal decision tree-based ensemble approaches for predicting the landslide susceptibility. *Remote Sensing*, 12(20), 1–27. <https://doi.org/10.3390/rs12203389>
- Aslam, B., Maqsoom, A., Khalil, U., Ghorbanzadeh, O., Blaschke, T., Farooq, D., Tufail, R. F., Suhail, S. A., & Ghamisi, P. (2022). Evaluation of Different Landslide Susceptibility Models for a Local Scale in the Chitral District, Northern Pakistan. *Sensors*, 22(9). <https://doi.org/10.3390/s22093107>
- Azarafza, M., Azarafza, M., Akgün, H., Atkinson, P. M., & Derakhshani, R. (2021a). Deep learning-based landslide susceptibility mapping. *Scientific Reports*, 11(1), 24112.
- Bandara, A., Hettiarachchi, Y., Hettiarachchi, K., Munasinghe, S., Wijesinghe, I., & Thayasivam, U. (2020). A Generalized Ensemble Machine Learning Approach for Landslide Susceptibility Modeling. In N. Sharma, A. Chakrabarti, & V. E. Balas (Eds.), *Advances in Intelligent Systems and Computing* (Vol. 1016, pp. 71–93). Springer. https://doi.org/10.1007/978-981-13-9364-8_6
- Brock, J., Schratz, P., Petschko, H., Muenchow, J., Micu, M., & Brenning, A. (2020). The performance of landslide susceptibility models critically depends on the quality of digital elevations models. *Geomatics, Natural Hazards and Risk*, 11(1), 1075–1092. <https://doi.org/10.1080/19475705.2020.1776403>
- Canavesi, V., Segoni, S., Rosi, A., Ting, X., Nery, T., Catani, F., & Casagli, N. (2020). Different approaches to use morphometric attributes in landslide susceptibility mapping based on meso-scale spatial units: A case study in Rio de Janeiro (Brazil). *Remote Sensing*, 12(11). <https://doi.org/10.3390/rs12111826>
- Chang, Z., Du, Z., Zhang, F., Huang, F., Chen, J., Li, W., & Guo, Z. (2020). Landslide susceptibility prediction based on remote sensing images and GIS: Comparisons of supervised and unsupervised machine learning models. *Remote Sensing*, 12(3). <https://doi.org/10.3390/rs12030502>
- Chen, W., Chen, Y., Tsangaratos, P., Ilia, I., & Wang, X. (2020). Combining evolutionary algorithms and machine learning models in landslide susceptibility assessments. *Remote Sensing*, 12(23), 1–26. <https://doi.org/10.3390/rs12233854>
- Deng, H., Wu, X., Zhang, W., Liu, Y., Li, W., Li, X., Zhou, P., & Zhuo, W. (2022). Slope-Unit Scale Landslide Susceptibility Mapping Based on the Random Forest Model in Deep Valley Areas. *Remote Sensing*, 14(17). <https://doi.org/10.3390/rs14174245>
- EM-DAT - The international disaster database. (n.d.). Retrieved June 14, 2025, from <https://www.emdat.be/>
- Fang, Z., Wang, Y., Peng, L., & Hong, H. (2021). A comparative study of heterogeneous ensemble-learning techniques for landslide susceptibility mapping. *International Journal of Geographical Information Science*, 35(2), 321–347. <https://doi.org/10.1080/13658816.2020.1808897>
- Feak, C., & Swales, J. (2009). *Telling a Research Story: Writing a Literature Review*. University of Michigan Press/ELT. <https://doi.org/10.3998/mpub.309338>
- Ghasemian, B., Shahabi, H., Shirzadi, A., Al-Ansari, N., Jaafari, A., Kress, V. R., Geertsema, M., Renoud, S., & Ahmad, A. (2022). A Robust Deep-Learning Model for Landslide Susceptibility Mapping: A Case Study of Kurdistan Province, Iran. *Sensors*, 22(4). <https://doi.org/10.3390/s22041573>

- Kavzoglu, T., Colkesen, I., & Sahin, E. K. (2018). Machine Learning Techniques in Landslide Susceptibility Mapping: A Survey and a Case Study. In *Advances in Natural and Technological Hazards Research* (pp. 283–301). Springer International Publishing. https://doi.org/10.1007/978-3-319-77377-3_13
- Kulsoom, I., Hua, W., Hussain, S., Chen, Q., Khan, G., & Shihao, D. (2023). SBAS-InSAR based validated landslide susceptibility mapping along the Karakoram Highway: a case study of Gilgit-Baltistan, Pakistan. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-30009-z>
- Lee, D.-H., Kim, Y.-T., & Lee, S.-R. (2020). Shallow landslide susceptibility models based on artificial neural networks considering the factor selection method and various non-linear activation functions. *Remote Sensing*, 12(7). <https://doi.org/10.3390/rs12071194>
- Lei, X., Chen, W., & Pham, B. T. (2020). Performance evaluation of GIS-based artificial intelligence approaches for landslide susceptibility modeling and spatial patterns analysis. *ISPRS International Journal of Geo-Information*, 9(7). <https://doi.org/10.3390/ijgi9070443>
- Li, Y., & Chen, W. (2020). Landslide susceptibility evaluation using hybrid integration of evidential belief function and machine learning techniques. *Water (Switzerland)*, 12(1). <https://doi.org/10.3390/w12010113>
- Lun, N. K., Liew, M. S., Matori, A. N., & Zawawi, N. A. W. A. (n.d.). *Recent developments in machine learning applications in landslide susceptibility mapping*. 1905, 040022. <https://doi.org/10.1063/1.5012210>
- Marjanović, M., Bajat, B., Abolmasov, B., & Kovačević, M. (2017). Machine Learning and Landslide Assessment in a GIS Environment. In *Advances in Geographic Information Science* (pp. 191–213). Springer International Publishing. https://doi.org/10.1007/978-3-319-59511-5_11
- Mehrabi, M., Pradhan, B., Moayedi, H., & Alamri, A. (2020). Optimizing an adaptive neuro-fuzzy inference system for spatial prediction of landslide susceptibility using four state-of-the-art metaheuristic techniques. *Sensors (Switzerland)*, 20(6). <https://doi.org/10.3390/s20061723>
- 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, 103225. <https://doi.org/10.1016/j.earscirev.2020.103225>
- Moher, D., Liberati, A., Tetzlaff, J., & Altman, D. G. (2009). Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. *PLoS Medicine*, 6(7), e1000097. <https://doi.org/10.1371/journal.pmed.1000097>
- Mwakapesa, D. S., Li, Y., Xiangtai, W., Binbin, G., & Yimin, M. (n.d.). *Review on the Application of Machine Learning Methods in Landslide Susceptibility Mapping*. 69–72. <https://doi.org/10.5220/0010790400003167>
- Nikoobakht, S., Azarafza, M., Akgün, H., & Derakhshani, R. (2022). Landslide Susceptibility Assessment by Using Convolutional Neural Network. *Applied Sciences (Switzerland)*, 12(12). <https://doi.org/10.3390/app12125992>
- Nsengiyumva, J. B., & Valentino, R. (2020). Predicting landslide susceptibility and risks using GIS-based machine learning simulations, case of upper Nyabarongo catchment. *Geomatics, Natural Hazards and Risk*, 11(1), 1250–1277. <https://doi.org/10.1080/19475705.2020.1785555>
- Pham, Q. B., Achour, Y., Ali, S. A., Parvin, F., Vojtek, M., Vojteková, J., Al-Ansari, N., Achu, A. L., Costache, R., Khedher, K. M., & Anh, D. T. (2021). A comparison among fuzzy multi-criteria decision making, bivariate, multivariate and machine learning models in landslide susceptibility mapping. *Geomatics, Natural Hazards and Risk*, 12(1), 1741–1777. <https://doi.org/10.1080/19475705.2021.1944330>
- Pradhan, A. M. S., & Kim, Y.-T. (2020). Rainfall-induced shallow landslide susceptibility mapping at two adjacent catchments using advanced machine learning algorithms. *ISPRS International Journal of Geo-Information*, 9(10). <https://doi.org/10.3390/ijgi9100569>
- Rahayu, T., & Syafril, S. (2018). *Cara Mensintesis Literature Review Dalam Penelitian*. <https://doi.org/10.31227/osf.io/4kqa2>
- Ramdhani, A., Ramdhani, M., & Amin, A. (2014). Writing a Literature Review Research Paper: A step-by-step approach. *International Journal of Basic and Applied Science*, 3, 47–56.
- Rong, G., Alu, S., Li, K., Su, Y., Zhang, J., Zhang, Y., & Li, T. (2020). Rainfall induced landslide susceptibility mapping based on bayesian optimized random forest and gradient boosting decision tree models—a case study of shuicheng county, china. *Water (Switzerland)*, 12(11), 1–22. <https://doi.org/10.3390/w12113066>
- Shafapourtehrany, M., Panahi, M., Rezaie, F., Khosravi, K., Kalantari, Z., Bateni, S. M., & Lee, J. A. (2025). Beyond boundaries: AI-optimized global landslide susceptibility mapping. *Geomatics, Natural Hazards and Risk*, 16(1).
- Shahzad, N., Ding, X., & Abbas, S. (2022). A Comparative Assessment of Machine Learning Models for Landslide Susceptibility Mapping in the Rugged Terrain of Northern Pakistan. *Applied Sciences (Switzerland)*, 12(5). <https://doi.org/10.3390/app12052280>
- Shu, H., Guo, Z., Qi, S., Song, D., Pourghasemi, H. R., & Ma, J. (2021). Integrating landslide typology with weighted frequency ratio model for landslide susceptibility mapping: A case study from lanzhou city of northwestern china. *Remote Sensing*, 13(18). <https://doi.org/10.3390/rs13183623>
- Tehrani, F. S., Calvellido, M., Liu, Z., Zhang, L., & Lacasse, S. (2022). Machine learning and landslide studies: recent advances and applications. *Natural Hazards*, 114(2), 1197–1245. <https://doi.org/10.1007/s11069-022-05423-7>
- Wang, J., Zheng, T., Wang, Q., Xu, B., & Wang, L. (2015). A bibliometric review of research trends on bioelectrochemical systems. *Current Science*, 109(12), 2204–2211. <http://www.jstor.org/stable/24906653>

- Wang, Y., Sun, D., Wen, H., Zhang, H., & Zhang, F. (2020). Comparison of random forest model and frequency ratio model for landslide susceptibility mapping (LSM) in Yunyang county (Chongqing, China). *International Journal of Environmental Research and Public Health*, 17(12), 1–39. <https://doi.org/10.3390/ijerph17124206>
- Wang, Z., Liu, Q., & Liu, Y. (2020). Mapping landslide susceptibility using machine learning algorithms and GIS: A case study in Shexian county, Anhui province, China. *Symmetry*, 12(12), 1–18. <https://doi.org/10.3390/sym12121954>
- Yu, C., & Chen, J. (2020). Landslide susceptibility mapping using the slope unit for southeastern Helong city, Jilin province, China: A comparison of ANN and SVM. *Symmetry*, 12(6), 1–23. <https://doi.org/10.3390/sym12061047>
- Yuan, R., & Chen, J. (2022). A hybrid deep learning method for landslide susceptibility analysis with the application of InSAR data. *Natural Hazards*, 114(2), 1393–1426. <https://doi.org/10.1007/s11069-022-05430-8>
- Yuan, X., Liu, C., Nie, R., Yang, Z., Li, W., Dai, X., Cheng, J., Zhang, J., Ma, L., Fu, X., Tang, M., Xu, Y., & Lu, H. (2022). A Comparative Analysis of Certainty Factor-Based Machine Learning Methods for Collapse and Landslide Susceptibility Mapping in Wenchuan County, China. *Remote Sensing*, 14(14). <https://doi.org/10.3390/rs14143259>
- Zhao, P., Masoumi, Z., Kalantari, M., Aflaki, M., & Mansourian, A. (2022). A GIS-Based Landslide Susceptibility Mapping and Variable Importance Analysis Using Artificial Intelligent Training-Based Methods. *Remote Sensing*, 14(1). <https://doi.org/10.3390/rs14010211>
- Zhao, X., & Chen, W. (2020). Optimization of computational intelligence models for landslide susceptibility evaluation. *Remote Sensing*, 12(14). <https://doi.org/10.3390/rs12142180>
- Zhu, L., Huang, L., Fan, L., Huang, J., Huang, F., Chen, J., Zhang, Z., & Wang, Y. (2020). Landslide susceptibility prediction modeling based on remote sensing and a novel deep learning algorithm of a cascade-parallel recurrent neural network. *Sensors (Switzerland)*, 20(6). <https://doi.org/10.3390/s20061576>