

Seleksi faktor kondisi kerentanan longsor berbasis *weights of evidence*, *variance inflation factor*, dan *information value* melalui *google earth engine* di wilayah Perbukitan Menoreh, Kulon Progo

Nizar Achmad^{1,*}, Setya Winarno¹, Sri Kusumadewi²

¹Program Doktor Teknik Sipil, FTSP, Universitas Islam Indonesia, Yogyakarta, Indonesia

²Jurusan Informatika, FTI, Universitas Islam Indonesia, Yogyakarta, Indonesia

Article Info

Available online

Keywords:

Tanah longsor

Weights of evidence

Variance inflation factor

Google earth engine

Menoreh hills

Litologi biner

Corresponding Author:

Nizar Achmad

nizar@janabadra.ac.id

Abstract

The Menoreh Hills in Kulon Progo, Yogyakarta Special Region, is one of the highest-frequency landslide areas in Java. This study presents a two-stage conditioning factor selection—(1) iterative Variance Inflation Factor (VIF, threshold < 10) to eliminate multicollinearity, followed by (2) Information Value (IV, threshold ≥ 0.10) to remove weak predictors—before computing Weights of Evidence (WoE) through Google Earth Engine (GEE). The dataset comprises 695 landslide events (2017–2025) after spatial thinning. Of eight candidate factors, NDVI (VIF = 22.89) was eliminated in Stage 1, reflecting a suppression effect in which NDVI captures shared terrain variance in a tropical volcanic setting. In Stage 2, aspect (IV = 0.084) and profile curvature (IV = 0.083) were eliminated as weak predictors. The five final factors are: distance to geological formation boundary (IV = 1.020, very strong), slope (IV = 0.367, strong), distance to river (IV = 0.311, strong), binary lithology Tomk+a1 (IV = 0.258, strong), and TWI-HydroSHEDS (IV = 0.106, moderate). Results confirm the primacy of geological structural control over topographic control in Menoreh Hills landslide susceptibility. The entire pipeline, implemented through GEE and Python, is transparent, reproducible, and adaptable to other volcanic areas in Java.

Copyright © 2026 Universitas Islam Indonesia

All rights reserved

Pendahuluan

Perbukitan Menoreh di Kabupaten Kulon Progo, Daerah Istimewa Yogyakarta (DIY), merupakan kawasan rawan longsor yang ditandai oleh dominasi breksi andesit lapuk Formasi Kaligesing (Tomk) dan Formasi Kebabutak (a1) berumur Oligosen Akhir–Miosen Awal. Karakteristik pedogeomorfik kawasan ini yaitu lereng terjal, tanah residual lempung kaolinit dengan kedalaman zona lapuk yang dalam—menjadikan Menoreh sebagai kawasan dengan frekuensi longsor tertinggi di DIY. Data BPBD Kulon Progo mencatat lebih dari 700 kejadian longsor selama 2017–2025 (BPBD Kabupaten Kulon Progo, 2025); sebanyak 695 kejadian digunakan setelah filter spasial 30×30 m².

Pemodelan *Landslide Susceptibility Index* (LSI) memerlukan identifikasi kuantifikasi faktor-faktor kondisi yang informatif dan tidak *redundan*. Pemilihan faktor yang tidak tepat, baik terlalu sedikit maupun mengandung *multikolinearitas*, akan menghasilkan bobot *Weights of Evidence* (WoE) yang bias dan peta kerentanan yang tidak dapat diandalkan. Sebagian besar studi LSI di kawasan vulkanik Jawa menggunakan set faktor yang ditetapkan secara apriori tanpa pengujian multikolinearitas yang memadai (Pertwi dkk., 2025; Rekinagara dkk., 2021). Demikian juga review komprehensif 565 artikel *landslide susceptibility mapping* (LSM) menemukan sebagian besar studi menggunakan 6–12 faktor tanpa seleksi multikolinearitas (Reichenbach dkk., 2018). Hal ini juga bisa ditemukan dalam penelitian

dampak adanya multikolinearitas pada banyak studi LSM di Indonesia (Nugroho dkk., 2025). Metode Weights of Evidence (WoE) dengan jaringan syaraf tiruan (ANN) telah terbukti efektif untuk pemetaan kerentanan longsor, (Pradhan & Lee, 2010). Studi LSM menggunakan WoE dan Frequency Ratio di pegunungan Menoreh menghasilkan AUC WoE = 0,827 (Erzagian dkk., 2025).

Penelitian memperluas pendekatan standar dengan mengevaluasi delapan faktor kandidat—termasuk tiga faktor yang jarang digunakan bersama-sama di Jawa, aspek lereng, NDVI berbasis Sentinel-2, dan jarak ke sungai berbasis HydroSHEDS (Lehner dkk., 2008) dan menyeleksi secara sistematis menggunakan VIF iteratif (O'Brien, 2007) sebelum kalkulasi WoE.

Kebaruan penelitian ini terletak pada: (1) konfirmasi kuantitatif peran litologi biner breksi andesit (Tomk dan a1) sebagai faktor kondisi eksplisit; (2) dokumentasi proses eliminasi faktor yang transparan dan dapat direproduksi melalui platform GEE; dan (3) pendalaman implementasi teknis GEE sebagai infrastruktur komputasi awan untuk seleksi faktor kondisi kerentanan longsor di kawasan vulkanik tropis.

Metode

Inventaris longsor BPBD

Fondasi seluruh analisis kerentanan dalam penelitian ini adalah inventaris kejadian longsor yang valid dan representatif. Bagian ini menjelaskan sumber data, proses pembersihan, dan pembagian dataset yang digunakan sebagai *ground truth* pemodelan LSI.

Inventaris longsor BPBD Kulon Progo 2017–2025 digunakan sebagai *ground truth*. Dataset awal (735 kejadian setelah filter

administrasi) melalui dua tahap pembersihan: (1) Filter B — eliminasi 5 titik yang koordinatnya di luar batas cakupan raster GEE (formasi Qa dan Qvu3 di tepi *Area of Interest*), menghasilkan 727 titik; (2) *spatial thinning* per piksel 30 m untuk menghindari *pseudoreplication*, menghasilkan 695 kejadian final. Dataset dibagi secara *stratified* berdasarkan kelas litologi. Sebanyak 524 kejadian (75,4%) berada di zona breksi Tomk+a1 (Grup A) dan 171 (24,6%) di zona non-breksi (Grup B). Dataset juga dibagi 486 (70%) data *training* dan 209 (30%) data *testing* peta LSI.

Pengenalan platform GEE

Platform *Google Earth Engine* (GEE) (Gorelick dkk., 2017) dipilih sebagai lingkungan komputasi utama dalam penelitian ini atas tiga pertimbangan metodologis. Pertama, aksesibilitas data — seluruh dataset satelit yang digunakan (SRTM, HydroSHEDS, ALOS AW3D30, Sentinel-2) tersedia langsung dalam katalog GEE tanpa memerlukan unduh lokal, sehingga menghilangkan ketergantungan pada kapasitas penyimpanan dan kecepatan unduh peneliti. Kedua, konsistensi pemrosesan — seluruh faktor diekstraksi dalam satu *pipeline* dengan proyeksi dan resolusi yang seragam (UTM Zona 49S, 30 m), mengeliminasi potensi kesalahan *co-registration* antar dataset yang umum terjadi pada pengolahan raster lokal. Ketiga, *reproducibility* — seluruh proses ekstraksi faktor dapat direproduksi secara identik melalui *script* yang sama tanpa ketergantungan pada perangkat lunak berlisensi komersial. Ketiga pertimbangan ini relevan khususnya untuk AOI seluas 852,59 km² dengan 947.322 piksel valid yang membutuhkan konsistensi pemrosesan di seluruh wilayah.

Tabel 1. Arsitektur *pipeline* ekstraksi faktor kondisi kerentanan melalui GEE


N o	Faktor	Asset string GEE (data satelit)	Fungsi utama yang digunakan	Resolusi	Output
1	Kemiringan lereng	USGS/SRTMGL1_003	ee.Terrain.slope()	30 m	30 m
2	TWI	WWF/HydroSHEDS/15ACC	log(A/tan β), D8	463 m	30 m
3	Profile curvature	USGS/SRTMGL1_003	Laplacian kernel 3×3	30 m	30 m
4	Jarak ke batas formasi	JAXA/ALOS/AW3D30/V4_1 + aset geologi	cumulativeCost(), maxDistance 15.000 m	30 m	30 m
5	Litologi biner	JAXA/ALOS/AW3D30/V4_1 + peta geologi	paint(), filter Tomk/a1	30 m	30 m
6	Aspek lereng	USGS/SRTMGL1_003	ee.Terrain.aspect()	30 m	30 m
7	NDVI	COPERNICUS/S2_SR_HARMO NIZED	band B8/B4	10 m	30 m
8	Jarak ke sungai	WWF/HydroSHEDS/15ACC	cumulativeCost(), stream > 1.000 px	463 m	30 m

Keterangan: Seluruh hasil diproyeksikan ke UTM Zona 49S (EPSG:32749), resolusi 30 m. Raster diekspor ke Google Drive dalam format GeoTIFF via ee.batch.Export.image.toDrive

Kandidat faktor kondisi kerentanan

Delapan faktor kandidat diperoleh seluruhnya melalui platform *Google Earth Engine* (Gorelick dkk., 2017). Delapan faktor tersebut adalah :


1. Sudut lereng (*Slope* °), dari satelit SRTM 30 m via ee.Terrain.slope(); merupakan faktor Energi gravitasi yaitu faktor utama *Landslide Susceptibility Mapping* (LSM) *global*. Gambar 1 menunjukkan hasil olahan sudut lereng dari data DEM satelit SRTM.



Gambar 1. Sudut lereng data SRTM

2. Indeks kejenuhan topografi (TWI *Topographic Wetness Index*) = data dari


satelit WWF/HydroSHEDS ; merupakan faktor akumulasi aliran algoritma *deterministic eight neighbour* (D8) lalu menjadi Gambar 2.



Gambar 2. *Topographic wetness index*


3. Kelengkungan profil lereng; *Profile curvature* dari data SRTM dan *Laplacian kernel 3×3*; Morfologi permukaan; cembung positif berasosiasi dengan longsor.
4. Jarak ke batas formasi (*distance lineament to geological formation boundary*); dari data ALOS AW3D30 dan geologi (*cumulative Cost*); Kontrol struktural geologi; kedekatan batas formasi meningkatkan kerentanan.

5. Litologi biner yaitu pengelompokan antara breksi andesit lapuk dan non breksi andesit lapuk; menggunakan data ALOS + peta geologi (simbol litologi Tomk dan a1); merupakan faktor baru yaitu breksi andesit lapuk sebagai faktor kondisi rentan eksplisit, lokasi longsor dan pengelompokan litologi biner lihat Gambar 3.



Gambar 3. litologi biner dan distribusi spasial inventaris longsor

6. Aspek arah lereng ($^{\circ}$); data SRTM via `ee.Terrain.aspect()`; Orientasi arah lereng terhadap pola hujan dan radiasi matahari. Hasil olahan dapat dilihat di Gambar 4.




Gambar 4. Aspek arah lereng (SRTM)

7. Indeks vegetasi terkoreksi (NDVI *Normalized Difference Vegetation*

Index); ukuran indeks kerapatan dan kesehatan *vegetasi* dari data satelit Sentinel-2 L2A pada median Juni–September 2022–2024; Tutupan vegetasi sebagai proxy kohesi tanah permukaan dapat dilihat pada Gambar 5.

8. Jarak ke sungai; data satelit WWF/HydroSHEDS/15ACC (stream > 1000 px); Erosi lateral dan penjuhan tanah dari arah bawah (sungai) = *maxDistance cumulativeCost*.



Gambar 5. Indeks Vegetasi terkoreksi NDVI

Dari 8 faktor ini akan dilakukan seleksi tiga tahapan, yaitu tahap awal berdasarkan nilai r pearson jika $|r| > 0,8$; eliminasi pertama jika *Variance Inflation Factor* $VIF > 10$, dan eliminasi kedua berdasarkan kategori *Information Value* $IV < 0,10$ (lemah). Dua kendala teknis ditemui selama implementasi GEE beserta solusinya.

Ada bias skala akumulasi aliran HydroSHEDS.

Koleksi WWF/HydroSHEDS/15ACC memiliki resolusi asli 15 *arc-second*; pada lintang Perbukitan Menoreh ($-7,7^{\circ}$), satu piksel setara dengan ≈ 463 m. Kalkulasi luas *upslope catchment* dengan mengalikan jumlah piksel akumulasi dengan 30 m menghasilkan *underestimate* sebesar faktor 15,4 $\times$, dengan implikasi *bias aditif* konstan sebesar +2,74 unit pada seluruh nilai TWI ($\ln(463/30) = 2,74$; Beven & Kirkby, 1979). Namun, karena bias ini bersifat konstan dan

seragam di seluruh AOI, urutan relatif nilai TWI antar piksel tidak berubah. Pengelompokan kelas *equal-frequency* yang digunakan dalam kalkulasi IV menghasilkan partisi yang identik dengan dan tanpa koreksi bias — sehingga nilai IV TWI yang dilaporkan tetap valid secara metodologis.

Ada pembatasan *server-side request* GEE. Pengambilan sampel nilai faktor pada seluruh titik inventaris longsor melalui *sampleRegions()* menghasilkan *timeout* jika diproses sekaligus. Solusi yang diterapkan adalah pembagian *batch* 200 titik per permintaan secara iteratif dengan verifikasi jumlah sampel pada setiap iterasi, menghasilkan *sampling* yang lengkap dan terverifikasi untuk seluruh 695 titik inventaris.

Seleksi faktor: *r* pearson, VIF dan IV

Sebelum kalkulasi WoE dilakukan, delapan faktor kandidat diseleksi melalui tiga tahap berurutan untuk memastikan setiap faktor yang masuk ke model bebas dari multikolinearitas dan memiliki relevansi prediktif yang terukur terhadap distribusi kejadian longsor.

Tahap pertama adalah pre-screening menggunakan matriks korelasi *Pearson*: pasangan faktor dengan $|r| > 0,8$ diidentifikasi sebagai kandidat multikolinear. Korelasi *Pearson* (*pre-screening*) dihitung dengan Persamaan (1).

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \cdot \sum(y_i - \bar{y})^2}} \quad (1)$$

Kedua, *Variance Inflation Factor* mengukur seberapa besar sebuah faktor bisa "dijelaskan" oleh faktor-faktor lain. VIF iteratif diterapkan dengan *threshold* 10 (O'Brien, 2007) untuk setiap iterasi, faktor VIF, rumus dasarnya adalah Persamaan (2).

$$VIF_j = \frac{1}{1 - R_j^2} \quad (2)$$

di mana R_j^2 adalah koefisien determinasi yang diperoleh dari meregresikan faktor ke-*j* terhadap seluruh faktor lainnya. Semakin tinggi korelasi faktor *j* dengan faktor-faktor

lain, semakin besar R_j^2 , semakin besar pula VIF-nya. Secara iteratif VIF tertinggi dieliminasi satu per satu hingga semua faktor tersisa memenuhi $VIF < 10$. *Threshold* 10 merupakan *rule of thumb* yang umum digunakan (Hair dkk., 2010) dan lebih konservatif dibanding *threshold* < 5 namun lebih longgar dari $< 7,5$ (O'Brien, 2007). Seluruh *multikolinearitas* berat dieliminasi di tahap VIF. Berikutnya eliminasi menggunakan *Information Value* IV yaitu kekuatan asosiasi antara suatu kelas faktor kondisi dengan distribusi kejadian longsor.

Seleksi IV diterapkan dengan *threshold* $IV \geq 0,10$ (Siddiqi, 2006): faktor yang lolos VIF namun memiliki nilai $IV < 0,10$ (kategori "Lemah") dieliminasi. Urutan eliminasi bertahap ini memisahkan secara eksplisit dua masalah yang berbeda yaitu *redundansi* informasi (ditangani VIF) dan relevansi prediktif (ditangani IV). Interpretasi $IV > 0,5$ sangat kuat; 0,25 - 0,5 kuat; 0,1 - 0,25 sedang; 0,02 - 0,1 lemah; $< 0,02$ tidak berguna.

Pemilihan kedua ambang batas tersebut mengacu pada rujukan baku (Hair dkk., 2010; Siddiqi, 2006), namun juga dipertimbangkan terhadap karakteristik data penelitian ini. Ambang $VIF > 10$ tergolong moderat dibandingkan ambang yang lebih ketat (mis. $VIF > 5$) yang kerap diterapkan pada penelitian dengan ukuran sampel terbatas; pemilihan ambang moderat ini didukung oleh ukuran sampel yang relatif besar dalam penelitian ini (695 kejadian longsor dan 2.430 titik latar hasil *sampling* WoE), yang secara umum memberikan derajat kebebasan yang memadai untuk menoleransi multikolinearitas sedang tanpa menyebabkan estimasi bobot WoE yang tidak stabil. Nilai VIF NDVI yang ekstrem (22,89) juga konsisten dengan karakteristik fisik kawasan penelitian: keseragaman relatif tutupan vegetasi di Perbukitan Menoreh yang dikontrol ketat oleh kondisi *terrain* menjadikan eliminasinya beralasan secara fisik, bukan sekadar artefak statistik. Adapun ambang $IV \geq 0,10$ pada tahap kedua

tergolong lebih ketat dibandingkan batas minimum kategori “tidak berguna” ($IV < 0,02$) yang lazim digunakan pada beberapa studi *credit scoring* (Siddiqi, 2006). Pemilihan ambang yang lebih konservatif ini dimaksudkan agar faktor yang dipertahankan dalam model WoE final memiliki kekuatan prediktif sekurang-kurangnya pada kategori “sedang”, sehingga mengurangi risiko mempertahankan faktor dengan kontribusi marginal yang dapat menambah kompleksitas model tanpa peningkatan kemampuan diskriminasi yang berarti. Perlu ditegaskan bahwa penjelasan di atas merupakan argumentasi penalaran penulis berdasarkan karakteristik data dan kondisi lapangan, bukan hasil pengujian sensitivitas ambang batas secara statistik formal; pengujian sensitivitas ambang batas secara sistematis direkomendasikan sebagai agenda penelitian lanjutan.

Kalkulasi WoE dan IV

Weights of Evidence untuk faktor kondisi kerentanan kelas k dan faktor f dihitung menggunakan Persamaan (3):

$$WoE_{f,k} = \ln \left(\frac{D_k}{N_k} \right) \dots (3)$$

D_k = proporsi piksel longsor yang jatuh di kelas k : $D_k = N_{longsor,k} / N_{longsor}$; N_k = proporsi piksel area di kelas k : $N_k = N_{pixel,k} / N_{total}$.

Sampling WoE menggunakan 2.430 titik latar (486 titik *training* $\times$ 5 rasio) sekitar titik kejadian longsor yaitu satu lokasi longsor akan diambil lima piksel sekitarnya dengan *eksklusi buffer* 100 m dari titik longsor via cKDTTree. Setiap faktor dibagi menjadi 10 kelas *equal-frequency* (≈ 246 piksel/kelas) untuk faktor kontinu, atau 2 kelas (biner) untuk litologi. Jika $WoE > 0$ rentan longsor, $WoE = 0$ netral, $WoE < 0$ “menolak longsor”.

Information Value (IV) mengukur kekuatan asosiasi antara suatu kelas faktor kondisi dengan distribusi kejadian longsor. IV dihitung pada faktor kondisi kerentanan kelas k dan faktor f menggunakan Persamaan (4).


$$IV_f = \sum_{k=1}^K (D_k - N_k) \cdot WoE_{f,k} \\ = \sum_{k=1}^K (D_k - N_k) \cdot \ln \left(\frac{D_k}{N_k} \right) \dots (4)$$

Hasil dan Pembahasan

Tahap 1 : eliminasi r pearson, VIF Iteratif

Metode. Tahap pertama mencakup pre-screening korelasi Pearson dan eliminasi VIF iteratif terhadap delapan faktor kandidat.

Eliminasi awal nilai r Pearson $> |0,8|$ tidak menghasilkan pasangan kandidat tereliminasi seperti pada Gambar 6 yaitu maksimal $r = 0.51$ sehingga semua $< |0,8|$.



Gambar 6. Matriks Korelasi Pearson pada 8 faktor kerentanan

Eliminasi Tahap 1 (VIF (*threshold* > 10) oleh korelasi berpasangan: pada iterasi pertama, NDVI memiliki VIF = 22,89 jauh melampaui *threshold* 10 sedangkan tujuh faktor lainnya memiliki VIF < 2 (Tabel 2). VIF NDVI yang ekstrem mengindikasikan bahwa pola distribusi spasial NDVI di Menoreh hampir sepenuhnya dapat diprediksi dari kombinasi linear ketujuh faktor *terrain* lainnya ($R^2 = 0,956$). Kondisi ini secara fisik masuk akal, di kawasan vulkanik tropis seperti Menoreh, distribusi vegetasi dikontrol erat oleh topografi (kemiringan, aspek), hidrologi (TWI, jarak sungai), dan litologi, sehingga NDVI tidak

membawa informasi independen yang signifikan.

Fenomena yang perlu dicatat adalah efek *suppression*: setelah NDVI dieliminasi pada iterasi pertama, VIF faktor-faktor yang tersisa melonjak secara substansial (Tabel 2). Sebagai contoh, VIF jarak ke batas formasi naik dari 1,036 menjadi 7,283, dan TWI dari 1,352 menjadi 6,760. Fenomena ini terjadi karena NDVI sebagai faktor yang berkorelasi tinggi dengan kombinasi faktor *terrain* sehingga saat NDVI diangkat, korelasi antar faktor *terrain* yang tersembunyi tersebut menjadi terlihat.

Tabel 2. Hasil VIF iteratif proses seleksi faktor kerentanan

No	Faktor	VIF 8 faktor	VIF 7 faktor
1	Jarak ke batas formasi (<i>dist. lineament</i>)	7,49	7,03
2	Indeks kejenuhan topografi TWI (HydroSHEDS)	9,29	6,76
3	Kemiringan lereng <i>Slope</i>	6,69	5,14
4	Litologi biner	5,41	5,31
5	<i>Profile curvature</i>	1,01	1,01
6	Aspek arah lereng	3,95	3,73
7	Indeks <i>vegetasi</i> NDVI	X 22,89	*
8	Jarak ke sungai	6,47	5,91

Keterangan: tanda X menandai faktor yang dieliminasi pada tahap ini karena nilai VIF melebihi ambang batas (VIF > 10,0).

Tahap 2: eliminasi IV (*threshold* $\geq 0,10$)

Tujuh faktor yang lolos tahap VIF selanjutnya dievaluasi kekuatan prediktifnya menggunakan Information Value (IV). Tahap ini bertujuan mengeliminasi faktor yang secara statistik bebas dari multikolinearitas namun tidak memiliki asosiasi yang bermakna dengan distribusi kejadian longsor.

Dari tujuh faktor yang lolos VIF, kalkulasi WoE menggunakan 2.430 titik latar (rasio

1:5, *buffer* 100 m) menghasilkan nilai IV untuk masing-masing faktor pada Tabel 3.

Tabel 3. diagnostik IV per faktor

No	Faktor	IV	Kekuatan prediktif
1	Jarak ke batas formasi	1,0201	Sangat kuat
2	Kemiringan lereng <i>slope</i>	0,3667	Kuat
3	Jarak ke sungai	0,3114	Kuat
4	Litologi biner	0,2580	Kuat
5	Indeks kejenuhan topografi TWI	0,1063	sedang
6	Aspek arah lereng	X 0,0843	Lemah
7	<i>Profile curvature</i>	X 0,0834	Lemah

IV = *Information Value* sebagai ukuran kekuatan prediktif. *Threshold* eliminasi: IV < 0,10. Keterangan: tanda X menandai faktor yang dieliminasi pada tahap ini karena nilai IV berada di bawah ambang batas (IV < 0,10, kategori "Lemah").

Dua faktor memiliki IV di bawah *threshold* 0,10 (kategori "Lemah" menurut (Siddiqi, 2006):

(1) Aspek lereng (IV = 0,0843): rendahnya nilai prediktif aspek di Menoreh mengindikasikan bahwa orientasi lereng tidak menjadi faktor dominan dalam membedakan area longsor dan non-longsor—berbeda dari kawasan dengan paparan angin laut yang kuat dan hujan orografis terarah. (2) *Profile curvature* (IV = 0,0834): meskipun *profile curvature* secara teoritis berkaitan dengan akselerasi aliran permukaan, resolusi DEM 30 m tidak cukup untuk merekam variasi morfologi lokal yang bermakna di Menoreh. Kedua faktor ini dieliminasi pada tahap 2, menghasilkan sisa 5 faktor yang digunakan untuk kalkulasi WoE raster dan konstruksi peta LSI.

Maka pada akhirnya digunakan 5 faktor kerentanan longsor yang menjadi lapisan data kerentanan dalam peta indeks kerentanan longsor (*Landslide Susceptibility Indeks*). Indeks kerentanan longsor ini dihitung dengan Persamaan (5).

Bobot WoE dan hierarki prediktif 5 faktor final

Kalkulasi WoE terhadap lima faktor final menghasilkan bobot per kelas yang mencerminkan kekuatan asosiasi spasial masing-masing faktor dengan kejadian longsor. Berikut ini dibahas hierarki prediktif kelima faktor tersebut dari yang terkuat hingga yang paling moderat, beserta implikasi fisik dari pola WoE yang diperoleh.

Jarak ke batas formasi geologi merupakan prediktor terkuat ($IV = 1,0201$), mengkonfirmasi dominasi kontrol struktural

geologi dalam kerentanan longsor Menoreh. Kedekatan batas antar formasi (Kaligesing–Kebabutak) mengindikasikan zona transisi litologi dengan intensitas pelapukan tidak merata dan konduktivitas hidrolik lebih tinggi, kondisi yang secara mekanis melemahkan kuat geser tanah (Rekinagara dkk., 2021).

Nilai WoE tertinggi pada kelas jarak sangat dekat ($WoE = +0,901$) dan terendah pada kelas jarak sangat jauh ($WoE = -3,886$) menunjukkan gradien kontribusi yang tajam (Tabel 4).

Tabel 4. IV diagnostik dan bobot WoE per faktor final

#	Faktor	WoE maks. (kelas)	WoE min. (kelas)
1	Jarak ke batas formasi	0,901 (jarak sangat dekat)	-3,886 (jarak sangat jauh)
2	Kemiringan lereng Slope (°)	0,461 (14,0°–20,1°)	-1,485 (< 5°)
3	Jarak ke sungai (m)	0,814 (< 250 m)	-1,580 (> 3.000 m)
4	Litologi biner (Tomk+a1)	0,385 (kelas breksi = 1)	-0,685 (kelas non-breksi = 0)
5	TWI (HydroSHEDS)	0,408 (TWI 6,25–6,68)	-0,628 (TWI sangat rendah)

Keterangan: WoE maks./min. = batas kelas dengan WoE tertinggi/terendah.

Kemiringan lereng slope ($IV = 0,3667$) menempati posisi kedua—konsisten dengan literatur LSM global (Pourghasemi dkk., 2012; Yalcin dkk., 2011). Kelas WoE tertinggi berada pada rentang 14,0°–20,1°, bukan pada lereng paling terjal, mengindikasikan bahwa longsor Menoreh lebih sering terjadi pada lereng sedang-terjal di mana zona lapuk dalam dan kandungan air tanah lebih tinggi, bukan pada batuan segar di lereng ekstrem.

Jarak ke sungai ($IV = 0,3114$) muncul sebagai prediktor kuat ketiga. Nilai WoE tertinggi pada kelas jarak < 250 m ($WoE = +0,814$) mengkonfirmasi peran erosi lateral dan penjenjutan tanah dari arah bawah lereng sebagai mekanisme pemicu penting di DAS Menoreh, konsisten dengan pola kejadian longsor yang terkonsentrasi di lereng dekat lembah.

Litologi biner Tomk+a1 ($IV = 0,2580$) mengkonfirmasi secara kuantitatif bahwa breksi andesit lapuk merupakan faktor kondisi bermakna—justifikasi untuk penggunaan diferensiasi litologi eksplisit dalam analisis kerentanan longsor Menoreh. TWI berbasis HydroSHEDS ($IV = 0,1063$) memberikan kontribusi sedang; nilai VIF-nya (6,760) yang lebih rendah dari implementasi proxy sum-elevasi sebelumnya ($VIF = 10,1$) mengkonfirmasi keberhasilan perbaikan implementasi hidrologi.

Implikasi dan perbandingan dengan studi terkait

Pipeline dua tahap VIF–IV dalam penelitian ini menghasilkan set faktor yang lebih *parsimonious* dibanding pendekatan satu tahap. Dengan hanya menggunakan *threshold* $VIF < 7,5$, aspek lereng dan profile

curvature akan dipertahankan meskipun kontribusi prediktifnya lemah (IV masing-masing 0,084 dan 0,083). Penambahan tahap seleksi IV memastikan bahwa setiap faktor yang dimasukkan ke dalam model memiliki relevansi yang terukur terhadap distribusi longsor, bukan hanya bebas dari *redundansi*. Konsekuensi metodologis ini terkonfirmasi secara empiris melalui hierarki IV yang konsisten, menunjukkan bahwa kelima faktor final memiliki relevansi prediktif yang terukur terhadap distribusi kejadian longsor di Perbukitan Menoreh.

Eliminasi NDVI pada tahap VIF mengandung implikasi metodologis yang penting. Secara intuitif, NDVI sering dimasukkan dalam analisis LSM sebagai proxy kohesi tanah permukaan dan intersepsi hujan. Namun, di kawasan vulkanik tropis seperti Menoreh, distribusi vegetasi merupakan fungsi dari kondisi *terrain* (*slope*, aspek, hidrologi, litologi)—bukan variabel independen. Memasukkan NDVI bersama faktor-faktor *terrain* yang mengendalikannya setara dengan memasukkan variabel dependen sebagai prediktor, yang menghasilkan multikolinearitas struktural ($VIF = 22,89$, $R^2 = 0,956$). Eliminasi NDVI melalui VIF mengkonfirmasi validitas pengujian multikolinearitas multivariat—bukan hanya bivariat, sebelum kalkulasi WoE.

Munculnya jarak ke sungai sebagai prediktor kuat ketiga ($IV = 0,3114$) merupakan temuan yang membedakan penelitian ini dari studi LSM Menoreh sebelumnya. Fakta bahwa 62,3% kejadian longsor dalam dataset terjadi dalam radius 1.500 m dari sungai mengkonfirmasi peran hidrologis erosi lateral sebagai mekanisme destabilisasi yang penting, yang relevan untuk desain sistem peringatan dini berbasis curah hujan di kawasan tersebut. Temuan ini diperkuat oleh dominasi bobot WoE tertinggi pada kelas jarak ke sungai < 250 m ($WoE = +0,814$).

Kesimpulan

Penelitian ini mendemonstrasikan *pipeline* seleksi faktor kondisi kerentanan dua tahap (VIF iteratif dan seleksi IV) untuk analisis kerentanan longsor berbasis WoE di Perbukitan Menoreh. Dari 695 kejadian longsor (2017–2025), delapan faktor kandidat dievaluasi menghasilkan lima faktor final melalui proses eliminasi bertahap yang transparan dan dapat direproduksi.

Pada tahap VIF ($threshold > 10$; (Hair dkk., 2010)), NDVI dieliminasi karena VIF ekstrem (22,89) yang mencerminkan efek *suppression*—NDVI menangkap variansi bersama faktor *terrain* di kawasan vulkanik tropis sehingga tidak membawa informasi *independen* yang signifikan. Pada tahap IV ($threshold \geq 0,10$; (Siddiqi, 2006)), aspek lereng ($IV = 0,0843$) dan *profile curvature* ($IV = 0,0834$) dieliminasi sebagai prediktor lemah.

Lima faktor final terdiri dari: jarak ke batas formasi ($IV = 1,0201$, sangat kuat), kemiringan lereng ($IV = 0,3667$, kuat), jarak ke sungai ($IV = 0,3114$, kuat), litologi biner Tomk+al ($IV = 0,2580$, kuat), dan TWI-HydroSHEDS ($IV = 0,1063$, sedang). Hierarki ini mengkonfirmasi dominasi kontrol struktural geologi atas kontrol topografi di Menoreh, serta menegaskan peran hidrologis jarak ke sungai—yang jarang digunakan secara eksplisit dalam studi LSM Menoreh sebelumnya—sebagai faktor kondisi yang signifikan.

Penelitian ini memiliki keterbatasan yang perlu dicatat: peningkatan kemampuan prediktif model akibat proses seleksi faktor dua tahap (VIF dan IV) belum dikonfirmasi melalui evaluasi kinerja model secara kuantitatif, misalnya nilai *Area Under Curve* pada kurva *Receiver Operating Characteristic* (AUC-ROC), *success rate*, atau *prediction rate* pada 209 titik data uji (*testing*) yang telah dipisahkan pada tahap pembagian dataset. Tanpa validasi tersebut, klaim bahwa lima faktor final menghasilkan model yang lebih baik masih bersifat

indikatif berdasarkan konsistensi hierarki IV, dan belum merupakan bukti kuantitatif peningkatan akurasi prediksi dibandingkan model delapan faktor awal. Evaluasi kinerja model tersebut direkomendasikan sebagai agenda penelitian lanjutan yang akan memperkuat validitas eksternal *pipeline* seleksi faktor yang diusulkan.

Perlu ditegaskan pula bahwa evaluasi kinerja model pada penelitian lanjutan tersebut belum tentu menunjukkan peningkatan akibat proses seleksi faktor dua tahap ini; hasilnya perlu diinterpretasikan sesuai skenario yang diperoleh. Apabila nilai AUC-ROC yang dihasilkan masih rendah, kondisi ini dapat mengindikasikan bahwa terdapat faktor kondisi dominan lain yang relevan secara lokal di Menoreh namun belum dimasukkan sebagai kandidat dalam penelitian ini. Apabila nilai AUC-ROC relatif tetap dibandingkan model delapan faktor awal, hal ini justru menegaskan bahwa kelima faktor terpilih telah merepresentasikan pengaruh utama secara efisien, sehingga pengelolaan faktor kondisi kerentanan dapat dilakukan secara lebih sederhana dan lebih murah secara komputasi tanpa mengorbankan kinerja prediktif. Apabila nilai AUC-ROC meningkat, hal ini akan menjadi konfirmasi kuantitatif yang diharapkan bahwa seleksi faktor dua tahap benar-benar meningkatkan kemampuan prediksi model. Dengan demikian, evaluasi kinerja model pada penelitian lanjutan tidak semata berfungsi sebagai validasi, tetapi juga sebagai alat diagnostik untuk menilai kelengkapan faktor kondisi yang digunakan. Interpretasi ketiga skenario ini bersifat kerangka penalaran a priori dan belum merupakan hasil pengujian empiris.

Pipeline seleksi faktor yang sepenuhnya diimplementasikan melalui Google Earth Engine dan Python bersifat transparan, dapat direproduksi, dan dapat diadaptasi untuk kawasan vulkanik Jawa lainnya. Implementasi GEE memungkinkan ekstraksi delapan faktor dari sumber data satelit heterogen—SRTM, HydroSHEDS, ALOS AW3D30, Sentinel-2—dalam satu

pipeline komputasi yang konsisten tanpa infrastruktur lokal. Penggunaan DEM resolusi lebih tinggi (ALOS AW3D30 12,5 m) dan integrasi faktor curah hujan berbasis GPM-IMERG direkomendasikan untuk penelitian lanjutan.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada BPBD Kulon Progo atas data inventaris longsor, Universitas Islam Indonesia dan Universitas Janabadra atas dukungan penelitian. Data Satelit yang diperoleh melalui platform Google Earth Engine, dan diolah dengan platform pemrograman python google colaboratory.

Daftar Pustaka

- BPBD Kabupaten Kulon Progo. (2025). *Rekapitulasi Kejadian Longsor Kabupaten Kulon Progo 2017-2025*. Badan Penanggulangan Bencana Daerah Kabupaten Kulon Progo.
- Erzagian, E., Fathani, T. F., & Wilopo, W. (2025). Statistical landslide susceptibility zonation: Kulon Progo Mountains, Indonesia. *Environmental Earth Sciences*, 84(21), 601–601. <https://doi.org/10.1007/S12665-025-12519-3>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate Data Analysis* (7 ed.). Pearson Prentice Hall.
- Lehner, B., Verdin, K., & Jarvis, A. (2008). New global hydrography derived from spaceborne elevation data. *Eos*, 89(10). <https://doi.org/10.1029/2008EO100001>
- Nugroho, H., Sari, D. K., Safitri, S., & Azmi, N. (2025). Assessing the impact of training samples overlap and density in random forest for landslide susceptibility mapping: Implications for degraded land management in Bandung Regency, Indonesia. *Journal of Degraded and Mining Lands Management*, 12(5), 8933–8956. <https://doi.org/10.15243/JDMLM.2025.125.8933>
- O'Brien, R. M. (2007). A caution regarding rules of thumb for variance inflation factors. *Quality & Quantity*, 41(5), 673–690. <https://doi.org/10.1007/s11135-006-9018-6>

- Pertiwi, R., Sartohadi, J., Setiawan, M. A., & Maulana, E. (2025). Landslide susceptibility analysis on road sections in Kaligesing District, Indonesia, using Frequency Ratio (FR) approaches. *Journal of Degraded and Mining Lands Management*, 12(4), 7913–7922.
<https://doi.org/10.15243/jdmlm.2025.124.7913>
- Pourghasemi, H. R., Mohammady, M., & Pradhan, B. (2012). Landslide susceptibility mapping using index of entropy and conditional probability models in GIS: Safarood Basin, Iran. *Catena*, 97.
<https://doi.org/10.1016/j.catena.2012.05.005>
- 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 & Software*, 25(6), 747–759.
<https://doi.org/10.1016/J.ENVSOFT.2009.10.016>
- 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.
<https://doi.org/10.1016/J.EARSCIREV.2018.03.001>
- Rekinagara, I. H., Kusumayudha, S. B., Setiawan, J., Lusantono, O. W., & Dwinagara, B. (2021). Correlation between geological structures and kinematic analysis to identify the vulnerability zone of slope failures on Samigaluh and Borobudur District. *AIP Conference Proceedings*, 2363(1).
<https://doi.org/10.1063/5.0061488>
- Siddiqi, N. (2006). *Credit Risk Scorecards: Developing and Implementing Intelligent Credit Scoring*. John Wiley & Sons.
<https://doi.org/10.1002/9781119201731>
- Yalcin, A., Reis, S., Aydinoglu, A. C., & Yomralioglu, T. (2011). A GIS-based comparative study of frequency ratio, analytical hierarchy process, bivariate statistics and logistics regression methods for landslide susceptibility mapping in Trabzon, NE Turkey. *Catena*, 85(3).
<https://doi.org/10.1016/j.catena.2011.01.014>