

Journal of Natural Environmental Hazards, Vol.14, Issue 45, September 2025

Evaluation of Random Forest and Support Vector Machine Models in Landslide Risk Mapping (Case study: Tajan Basin, Mazandaran Province)

Sayed Hamid Sadati¹, Seyed Ramzan Mousavi^{2*}, Ghorban Vahabzadeh Kebria³, Sayed Hussein Roshun⁴

1. PhD Student of Watershed Management, Department of Watershed Engineering, Faculty of Natural Resources, Sari Agricultural Sciences and Natural Resources University, Sari, Iran

2. Corresponding Author, Assistant Professor of Watershed Management, Department of Watershed Engineering, Faculty of Natural Resources, Sari Agricultural Sciences and Natural Resources University, Sari, Iran

3. Associate Professor of Watershed Management, Department of Watershed Engineering, Faculty of Natural Resources, Sari Agricultural Sciences and Natural Resources University, Sari, Iran

4. PhD Graduate of Watershed Management, Department of Watershed Engineering, Faculty of Natural Resources, Sari Agricultural Sciences and Natural Resources University, Sari, Iran

Article Info

ABSTRACT

Article type:

Research Article

Article history:

Received: 13 October 2024

Revised: 10 December 2024

Accepted: 12 January 2025

Keywords:

Landslide, Machine Learning Techniques, AUC, Tajan Watershed.

The development of landslide susceptibility maps using machine learning is an effective tool for managing land in vulnerable regions. This study generates a landslide susceptibility map for the Tajan watershed using machine learning techniques. Twenty-one factors influencing landslides were identified and categorized into geological, climatic, environmental, topographical, and hydrological factors. Raster data was prepared using ENVI 5.6, SAGA GIS, and ArcGIS software. Field surveys documented 155 landslide locations, converted to point layers in ArcGIS. This data, along with the training layer, was imported into R software in ASCII format. For model training, Support Vector Machine (SVM) and Random Forest (RF) algorithms were applied, using 70% of the data (109 samples) for training and the remaining 30% (46 samples) for testing. Evaluation of the RF model using the ROC curve showed high predictive accuracy, with scores of 0.972 for training and 0.949 for testing. Analysis of the RF model identified key factors influencing landslides, including aspect, distance from streams and roads, slope, and the Topographic Position Index. The SVM model results indicated a greater proportion of high-susceptibility areas in the watershed than the RF model. AUC values for the SVM model were slightly lower, at 0.906 for training and 0.831 for testing. The SVM model highlighted elevation classes, rainfall, aspect, and distance from streams and roads as significant factors but underperformed compared to the RF model in mapping landslide susceptibility. Risk classification with the RF model showed that 10.19% of the area is very high risk, 4.17% high risk, 10.76% moderate risk, 15.62% low risk, and 59.26% very low risk. Conversely, the SVM model predicted smaller very high-risk areas at 5.51%, high risk at 15.58%, moderate risk at 5.33%, low risk at 4.47%, and very low risk at 69.09%.

Cite this article: Sadati, S. H. , Mousavi, S. R. , Vahabzadeh Kebria, G. and Roshun, S. H. (2025). Evaluation of Random Forest and Support Vector Machine Models in Landslide Risk Mapping (Case study: Tajan Basin, Mazandaran Province). Journal of Natural Environmental Hazards, 14(45), 133-154. DOI: 10.22111/jneh.2025.50031.2071



© Seyed Ramzan Mousavi*

DOI: 10.22111/jneh.2025.50031.2071

Publisher: University of Sistan and Baluchestan

* Corresponding Author Email: srmousavi@sanru.ac.ir

مجله علمی پژوهشی مخاطرات محیط طبیعی، دوره ۱۴، شماره ۴۵، شماره پیاپی ۳، مهر ۱۴۰۴

ارزیابی مدل‌های جنگل تصادفی و ماشین بردار پشتیبان در تهیه نقشه حساسیت زمین‌لغزش (مطالعه موردی: حوضه تجن، استان مازندران)

سید حمید ساداتی^۱، سید رمضان موسوی^{۲*}، قربان وهاب‌زاده کبریا^۳، سید حسین روشان^۴

۱. دانشجوی دکتری آبخیزداری، گروه مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری

۲. استادیار گروه مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری (نویسنده مسئول)

۳. دانشیار گروه مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری

۴. دانشآموخته دکتری علوم و مهندسی آبخیزداری، گروه مهندسی آبخیزداری، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری

اطلاعات مقاله چکیده

نوع مقاله: مقاله پژوهشی	تاریخ دریافت: ۱۴۰۳/۰۷/۲۲	تاریخ ویرایش: ۱۴۰۳/۰۹/۲۰	تاریخ پذیرش: ۱۴۰۳/۱۰/۲۳
تلهیه نقشه حساسیت زمین‌لغزش با استفاده از یادگیری ماشین ایزاری مفید برای مدیریت زمین در مناطق مستعد به این پدیده است. هدف این مطالعه، تهیه نقشه حساسیت زمین‌لغزش در حوضه تجن با یادگیری ماشین است. بدین منظور، عامل مؤثر در وقوع زمین‌لغزش در چهار طبقه عوامل زمین‌شناسی، اقلیمی و محیطی، توپوگرافی و هیدرولوژیکی شناسایی و رستر آنها در نرم‌افزارهای SAGA GIS، ENVI 5.6 و ArcGIS تهیه شد. با بازدهی‌های میدانی، موقعیت ۱۵۵ زمین‌لغزش ثبت و در نقاطهای تبدیل شدند. کلیه عوامل با فرمت ASCII و لایه نقطه‌ای (لایه آموزشی) وارد نرم‌افزار R شدند. برای آموزش مدل‌های ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) درصد از داده‌ها ۱۰۹٪ واقعه و برای آزمون ۳۰ درصد (۴۶٪) واقعه استفاده شد. ارزیابی مدل RF با منحنی ROC نشان داد که نمره‌های ۰/۹۴۹ و ۰/۹۷۲ در مراحل آموزش و آزمون را کسب کرده است. اطلاعات مدل RF نشان داد که می‌دهد که مؤثرترین عوامل شامل جهت شیب، فاصله از آبراهه، فاصله از جاده، درجه شیب و شاخص موقعیت توپوگرافی هستند. نتایج مدل SVM نشان داد که پتانسیل طبقه حساسیت زیاد در حوضه بیشتر از RF است و نمرات AUC به ترتیب ۰/۹۰۶ و ۰/۸۳۱ به دست آمد. نتایج مدل SVM نشان داد که پتانسیل طبقه حساسیت زیاد در حوضه نسبت به پیش‌بینی مدل RF بیشتر شده است. مؤثرترین عوامل در مدل SVM شامل طبقات ارتفاعی، بارندگی، جهت شیب، فاصله از آبراهه و فاصله از جاده می‌باشند. مدل SVM در مقایسه با مدل RF عملکردی ضعیفی در پیش‌بینی نقشه حساسیت زمین‌لغزش دارد. نتایج دسته‌بندی سطح خطر در مدل RF، به ترتیب خیلی زیاد (۰/۱۰/۱۹٪)، زیاد (۰/۱۷٪)، متوسط (۰/۱۷٪)، کم (۰/۱۵/۶۲٪) و خیلی کم (۰/۵۹/۲۶٪) از مساحت حوضه است. در مدل SVM نیز به ترتیب سهم طبقات خیلی زیاد (۰/۵/۵۱٪)، زیاد (۰/۱۵/۵۸٪)، متوسط (۰/۵/۳۳٪)، کم (۰/۴/۴۷٪) و خیلی کم (۰/۶۹/۰/۹٪) محاسبه شده است.	واژه‌های کلیدی: زمین‌لغزش، فن‌های یادگیری ماشین، AUC، حوضه آبخیز تجن.		

استناد: ساداتی، سید حمید، موسوی، سید رمضان، وهاب‌زاده کبریا، قربان و روشان، سید حسین. (۱۴۰۴). ارزیابی مدل‌های جنگل تصادفی و ماشین بردار پشتیبان در تهیه نقشه حساسیت زمین‌لغزش (مطالعه موردی: حوضه تجن، استان مازندران). *مخاطرات محیط طبیعی*, ۴(۴۵).

DOI: 10.22111/jneh.2025.50031.2071. ۱۵۴-۱۳۳



© سید حمید ساداتی، سید رمضان موسوی، قربان وهاب‌زاده کبریا، سید حسین روشان.

ناشر: دانشگاه سیستان و بلوچستان

مقدمه

یکی از رایج‌ترین بلایای طبیعی، لغزش زمین است که در اثر بارش‌های شدید، سیل، زلزله و فرسایش و در اثر فعالیت‌های انسانی ایجاد می‌شود. بسیاری از تلفات گزارش شده پس از طوفان، سیل‌های بزرگ و زمین لرزه‌ها در واقع ناشی از رانش زمین است. مطالعات نشان می‌دهد که کشورهای در حال توسعه بهشت تاثیر زمین لغزش قرار دارند (دارابی شاهماری و صفاری، ۱۳۹۸؛ کاریونمرو^۱ و همکاران، ۲۰۲۱). از مجموع افرادی که در اثر بلایای طبیعی جان خود را از دست داده‌اند، کشورهای بسیار توسعه‌یافته تنها ۵ درصد از تلفات را به خود اختصاص داده‌اند و خسارت‌های مالی ناشی از حساسیت زمین لغزش در کشورهای صنعتی بیشترین میزان را دارد (لاکاس و ندیم^۲، ۲۰۰۹). زمین‌لغزش، زیان‌بارترین مخاطرات طبیعی در مناطق کوهستانی جهان است که باعث تلفات جانی، خسارت مالی و در نتیجه بحران اقتصادی می‌شود (روکاتی^۳، ۲۰۱۹). بیش از ۳۸۷۶ زمین‌لغزش از سال ۱۹۹۵ تا ۲۰۱۴ در سراسر جهان گزارش شده که ۱۱۶۸۹ نفر زخمی و ۱۶۳۶۵۸ نفر فوتی بهمراه داشته است (هاک^۴ و همکاران، ۲۰۱۹). اتخاذ راه‌های مؤثر برای جلوگیری و کاهش تخریب‌های مرتبط با زمین‌لغزش بسیار مهم است. تهیه نقشه حساسیت زمین‌لغزش^۵، یک اقدام متقابل رایج برای کاهش پیامدهای زمین‌لغزش، نشان‌دهنده توزیع مکانی وقوع احتمالی زمین‌لغزش در یک منطقه بر اساس محیط جغرافیایی است (مرغادی^۶ و همکاران، ۲۰۲۰). نقشه‌های حساسیت زمین‌لغزش ابزارهای حیاتی هستند که توسط تصمیم‌گیرندگان برای اتخاذ استراتژی‌های کاهش برای بلایای آینده استفاده می‌شوند (آچو^۷ و همکاران، ۲۰۲۳). زمین‌لغزش بهدلیل افزایش شهرنشینی، جنگل‌زدایی و تغییرات آب‌وهواهای بیشتر رخ می‌دهد؛ از این‌رو تهیه نقشه حساسیت زمین‌لغزش برای حفاظت از جان و اموال بشر حیاتی است (آدو^۸ و همکاران، ۲۰۲۲). روش‌های مختلفی از جمله روش‌های یادگیری ماشین^۹ (ML)، روش‌های آماری و روش‌های مبتنی بر فیزیک برای تهیه نقشه حساسیت زمین‌لغزش در چند دهه اخیر به کار گرفته شده‌اند که هر کدام مزایا و معایب خاصی دارند. در طول دو دهه گذشته، پیشرفت‌های عمدۀ در قدرت محاسباتی، سنجش‌ازدور و سیستم‌های اطلاعات جغرافیایی^{۱۰} (GIS)، تهیه نقشه‌های حساسیت زمین‌لغزش را تسهیل کرده است. این نقشه‌ها می‌توانند توسط سیاست‌گذاران و تصمیم‌گیران برای کاهش خسارت‌های اجتماعی و اقتصادی ناشی از زمین‌لغزش مورد استفاده قرار گیرد (روی^{۱۱} و همکاران، ۲۰۲۲). بهطورکلی، روش‌های تهیه نقشه حساسیت زمین‌لغزش را می‌توان در دو گروه کلی شامل روش‌های اکتشافی و روش‌های احتمالی دسته‌بندی کرد (کوبی^{۱۲} و همکاران، ۲۰۱۷). روش‌های اکتشافی کیفی بوده و به نظر متخصص بستگی دارد که در معرض عدم قطعیت می‌باشند (التووینی و همکاران، ۲۰۱۴). روش‌های احتمالی خود به دو دسته روش‌های آماری و روش‌های داده‌کاوی طبقه‌بندی می‌شوند.

1- Carrión-Mero

2- Lacasse and Nadim

3- Roccati

4- Haque

5- Landslide Susceptibility Mapping

6- Merghadi

7- Achu

8- Ado

9- Machine Learning

10- Geographic Information System

11- Roy

12- Cui

روش‌های آماری مهم شامل نسبت فراوانی (FR) و آنتروپی شانون (باردواج و سرکار^۱، ۲۰۲۴)، حداکثر آنتروپی و وزن شواهد (سوهرمات^۲ و همکاران، ۲۰۲۴)، عامل اطمینان (جولیف^۳ و همکاران، ۲۰۱۹)، رگرسیون لجستیک (هماسینگه^۴ و همکاران، ۲۰۱۸)، خطوط رگرسیون تطبیقی چندگانه (چو^۵ و همکاران، ۲۰۱۹) و روش‌های داده‌کاوی شامل ماشین بردار پشتیبان (هوانگ^۶ و همکاران، ۲۰۲۲)، جنگل تصادفی (کیم^۷ و همکاران، ۲۰۱۸؛ سان^۸ و همکاران، ۲۰۲۰)، درخت تصمیم (هانگ^۹ و همکاران، ۲۰۱۸؛ یون^{۱۰} و همکاران، ۲۰۱۰)، شبکه عصبی مصنوعی (سلامت و همکاران، ۲۰۲۲) و یادگیری عمیق (هابوموگیشا^{۱۱} و همکاران، ۲۰۲۲؛ آذرافزا و همکاران، ۲۰۲۱). کرمی و همکاران (۱۳۹۸) در پژوهش خود به بررسی کارایی الگوریتم ماشین بردار پشتیبان (SVM) برای پنهانبندی حساسیت زمین‌لغزش در حوضه آبریز اهرچای پرداختند. در این پژوهش، حدود ۲۰۰ زمین‌لغزش شناسایی و نقشه پراکنش آن‌ها تهیه شد. برای تهیه نقشه حساسیت زمین‌لغزش از ۱۴ معیار مؤثر استفاده شد و در نهایت، حساسیت به پنج کلاس دسته‌بندی شد. ارزیابی عملکرد با استفاده از منحنی ROC و AUC انجام شد که نشان داد تابع پایه شعاعی (RBF) بهترین عملکرد را دارد. نتایج نشان داد که حدود ۲۶۶۱ درصد از اراضی منطقه در کلاس‌های حساسیت زیاد و بسیار زیاد قرار دارند که بیشتر در بخش‌های غربی و بالادست حوضه واقع شده‌اند. ذاکری نژاد و کهرانی (۱۴۰۲) جهت تهیه نقشه حساسیت زمین‌لغزش در حوضه آبخیز کمۀ استان اصفهان از الگوریتم‌های درختان رگرسیون چندگانه جمع‌شدتی^{۱۲} (TreeNet) و درخت طبقه‌بندی و رگرسیون^{۱۳} (CART) استفاده کردند. بدین منظور ۱۱ فاکتور مؤثر در وقوع زمین‌لغزش امل ارتفاع، شیب، جهت شیب، رطوبت نسبی، بارش، پوشش گیاهی، کاربری اراضی، زمین‌شناسی، فاصله از جاده، فاصله از گسل و فاصله از آبراهه را در نظر گرفتند. نتایج آنها نشان داد که مناطق پر خطر در مناطق غرب و جنوب حوضه واقع هستند. آنها بیان داشتند که دقت مدل CART نسبت به مدل TreeNet بیشتر بوده است. سپهوند و بیرانوند (۱۴۰۳) به ارزیابی حساسیت وقوع زمین‌لغزش در حوزه آبخیز هزار، با استفاده از الگوریتم‌های مختلف یادگیری ماشین از نوع ماشین پشتیبان بردار (SVM) و رگرسیون فرآیند گاووسی (SVM) با دو کرنل (RBF و PUK) و جنگل تصادفی (RF) پرداختند. آنها نه عامل مؤثر از جمله مقدار شیب، جهت شیب، ارتفاع، زمین‌شناسی، کاربری اراضی، فاصله از گسل، فاصله از جاده، فاصله از رودخانه و بارش را به عنوان پارامترهای ورودی در نظر گرفتند و از ۱۴۸ نقطه لغزشی و غیرلغزشی، ۷۰ درصد برای آموزش و ۳۰ درصد برای آزمون مدل‌ها استفاده کردند. نتایج نشان داد که مدل RF در مقایسه با مدل‌های SVM بهترین عملکرد را داشته است. نقشه نهایی توزیع مناطق حساسیت مختلف نیز نشان داد که جهت شیب حساس‌ترین عامل در وقوع

1- Bhardwaj & Sarkar

2- Suhermat

3- Juliev

4- Hemasinghe

5- Chu

6- Huang

7- Kim

8- Sun

9- Hong

10- Yeon

11- Habumugisha

12- Summable Multiple Regression Tree Algorithms (TreeNet)

13- Classification and Regression Trees (CART)

زمین لغزش است. لی^۱ و همکاران (۲۰۲۳) به مقایسه عملکرد شش الگوریتم یادگیری ماشین (ML) در تولید نقشه حساسیت زمین لغزش در شهرستان اینجه، کره جنوبی اقدام کردند. آنها ترکیبی از داده‌های جغرافیایی جمع‌آوری شده از سال ۲۰۰۵ تا ۲۰۱۹ برای آموزش و ارزیابی شش الگوریتم شامل رگرسیون لجستیک (LR)، بیز ساده گاووسی^۲ (GNB)، ماشین بردار پشتیبان (SVM)، نزدیکترین همسایگان^۳ (KNN)، جنگل تصادفی (RF) و تقویت گرادیان شدید^۴ (XGB) استفاده کردند. نتایج آنها نشان داد که مدل‌های RF و XGB با بالاترین مقدار PCC و F1 به ترتیب ۰/۹۴۱ و ۰/۹۴۱ دارای بیشترین عملکرد می‌باشند. توابین^۵ و همکاران (۲۰۲۴) با ترکیب سنجش‌ازدور و سامانه اطلاعات جغرافیایی با روش‌های یادگیری ماشین جنگل تصادفی، ماشین بردار پشتیبان و رگرسیون لجستیک اقدام به تهیه نقشه حساسیت زمین لغزش در استان نهان^۶ ویتنام کردند. آنها از بین عوامل مؤثر در وقوع زمین لغزش ارتفاع، شبی، جهت شبی، تجمع جریان، ژئومورفولوژی، انحنای طولی شاخص موقعیت توپوگرافی (TPI)، تراکم گسل، تراکم جاده، بارش و کاربری اراضی را در نظر گرفتند. نتایج حاکی از آن است که مهم‌ترین عوامل مؤثر در وقوع زمین لغزش منطقه شامل شاخص بارش استادارد شده، ترافیک، شبی زمین و ارتفاع می‌باشد. همچنین در بین الگوریتم‌های به کار گرفته شده، مدل جنگل تصادفی با ضریب همبستگی ($R^2=0.97$) بیشترین دقت را در تهیه نقشه حساسیت زمین لغزش در منطقه نشان داد. هدف این مطالعه، ارزیابی مدل‌های یادگیری ماشین بردار پشتیبان و جنگل تصادفی در تهیه نقشه حساسیت زمین لغزش در شمال ایران می‌باشد. شمال کشور اغلب با تغییرات کاربری از جنگل به اراضی کشاورزی، اراضی مسکونی و باغات مواجه است و در سال‌های اخیر همزمان با افزایش جمعیت این تغییرات کاربری روند افزایش داشته است. از طرفی حساسیت زمین لغزش با افزایش فعالیت‌های انسانی از جمله تغییرات کاربری اراضی، جاده‌سازی و توسعه ساخت‌وساز نیز تشدید می‌شود. وقوع زمین لغزش در برخی از نقاط استان مازندران موجب ایجاد خسارت‌های زیادی به زیربنایها و محیط زیست شده است. در این مطالعه روش‌های نوین یادگیری ماشین در تهیه نقشه حساسیت زمین لغزش در یکی از حوضه‌های مهم استان مازندران ارزیابی می‌گردد.

داده‌ها و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه حوزه آبخیز تجن واقع در شرق استان مازندران با مساحت ۴۲۹۰ کیلومتر مربع می‌باشد. این حوزه آبخیز از شمال به دریای مازندران، از جنوب به استان سمنان، از باختر به شهرستان‌های سوادکوه و قائم‌شهر و از خاور به شهرستان بهشهر محدود شده است. بیش از ۵۱ درصد حوضه از مناطق کوهستانی، حدود ۲۰ درصد آن از اراضی جلگه‌ای و دشت‌های ساحلی و بقیه آن را تراس‌های روDXانه‌ای، اراضی کوهپایه‌ای و تپه ماهورها تشکیل می‌دهند. سرشاخه‌های حوضه، در کوههای مرتفع البرز قرار دارد و بخش ساحلی که مسطح است، اغلب به‌طور ناگهانی آغاز می‌شود و تا دریا ادامه دارد. ارتفاعات این ناحیه از البرز، روند شمال شرقی جنوب غربی دارند. شکل

^۱- Le

^۲- Gaussian Naïve Bayes

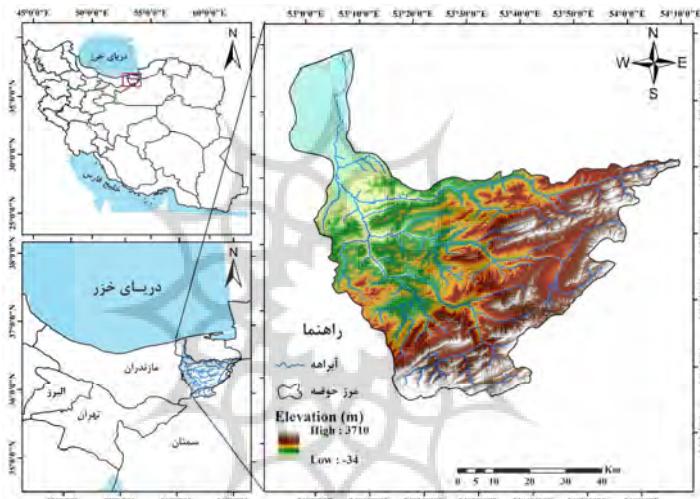
^۳- K-Nearest Neighbors

^۴- Extreme Gradient Boosting

^۵- Tuyen

^۶- Nghe An

حوضه به صورت نامتقارن گسترش یافته است. به تبعیت از گسترش ارتفاعات، بیشتر طول حوضه به سمت شرق گسترش دارد. محیط حوضه بدلیل گستردگی و کشیدگی زیاد نزدیک به ۱۱۱ کیلومتر است. شاخه‌بندی رودخانه تجن نیز ترکیبی از شاخه‌بندی دندربیتی و موازی می‌باشد. منطقه مورد مطالعه را بر اساس خصوصیت‌های دما و بارش و توپوگرافی منطقه می‌توان به دو نوع آب‌وهوای معتدل خزری و آب‌وهوای کوهستانی تقسیم کرد. آب‌وهوای کوهستانی خود دارای دو نوع معتدل کوهستانی و سرد کوهستانی می‌باشد. شکل ۱ موقعیت جغرافیایی حوضه تجن در استان مازندران و کشور را نشان می‌دهد.



شکل ۱: موقعیت جغرافیایی حوضه تجن در استان مازندران و ایران

روش پژوهش

در این پژوهش، ابتدا با مطالعه اسناد علمی شامل انواع مقالات پژوهشی داخلی و خارجی، پایان‌نامه‌ها، گزارش‌ها و بازدیدهای میدانی مهم‌ترین عوامل مؤثر در وقوع حساسیت زمین‌لغزش تعیین شدند. با توجه به اینکه عوامل زیادی دخیل بودند، در این مطالعه مهم‌ترین و مؤثرترین آنها در چهار دسته شامل عوامل زمین‌شناسی^۱، اقلیمی و محیطی^۲، توپوگرافیکی^۳ و هیدرولوژیکی^۴ تقسیم‌بندی شدند که تأثیرگذاری آنها بر زمین‌لغزش و نحوه تهییه لایه آنها در زیر تشریح می‌گردد.

تهییه لایه عوامل مؤثر در وقوع زمین‌لغزش

عوامل زمین‌شناسی

-
- 1- Geological Factors
 - 2- Climate and Environmental Factors
 - 3- Topographical Factors
 - 4- Hydrological Factors

واحدهای سنگشناسی^۱: واحدهای مختلف سنگشناسی دارای خصوصیت‌های متنوع از نظر بافت، نفوذپذیری و استحکام دارند که نقش مهمی در فرآیندهای هیدرولوژیکی و ژئومورفولوژیکی حوضه آبخیز ایفا می‌کنند. عامل زمین-شناسی را می‌توان از مهم‌ترین عوامل مؤثر در موقع زمین‌لغزش و سایر حرکات توده‌ای در یک منطقه دانست. واحدهای سنگشناسی حوضه مورد مطالعه بر اساس نقشه زمین‌شناسی منطقه با مقیاس ۱:۱۰۰۰۰ به دست آمد. بدین ترتیب که ابتدا هر واحد سنگشناسی در حوضه در نرم‌افزار ArcMap 10.8 رقومی شدند و سپس به فرمت رستری تبدیل گردید.

فاصله از گسل و تراکم گسل^۲: گسل خوردگی نقش مهمی در خرد شدن سنگ‌های تشکیل‌دهنده دامنه‌ها، مهیا کردن شرایط جهت عبور آبهای سطحی و زیرزمینی، افزایش میزان هوازدگی و آلتراسیون و کاهش مقاومت سنگ‌های اطراف توده لغزشی و تنش‌های انتقالی ناشی از لرزش آنها نشان می‌دهد. گسل خوردگی به عنوان عامل اساسی و مهم در ناپایداری شیب‌ها و پهنه‌بندی حساسیت زمین‌لغزش در نظر گرفته می‌شود (درویشی و موسوی ندوشن، ۱۴۰۲). برای تهیه نقشه گسل‌ها از نقشه زمین‌شناسی منطقه استفاده شد. بدین ترتیب که ابتدا موقعیت گسل‌ها با استفاده از ابزار Editor رقومی گردید؛ سپس با استفاده از ابزار فاصله اقلیدسی^۳ و تراکم خط^۴ به ترتیب فاصله از گسل‌ها و تراکم آنها در حوضه محاسبه گردید.

عوامل اقلیمی و محیطی

بارندگی^۵: در فرآیند وقوع زمین‌لغزش برقی از عوامل را به عنوان محرك‌های خارجی یا عامل ماشه‌ای که نقش محوری دارند، در نظر می‌گیرند. بارندگی شدید، ذوب سریع برف، تغییرات ناگهانی در سطح آب زیرزمینی، زلزله و فرسایش خاک با سرعت زیاد از مهم‌ترین عوامل ماشه‌ای زمین‌لغزش‌ها به حساب می‌آیند (سایدل و اوکیایی، ۲۰۰۶). متداول‌ترین عامل ماشه‌ای در بین عوامل یادشده بارندگی می‌باشد (طالبی و همکاران، ۱۳۸۸). بارندگی در حوضه مورد مطالعه بر پایه اطلاعات ثبت‌شده در ایستگاه‌های هواشناسی مورد بررسی قرار گرفت. بدین ترتیب، ابتدا آمار ایستگاه‌های هواشناسی از اداره کل هواشناسی استان اخذ گردید و بعد از حذف ایستگاه‌های دارای آمار ناقص، حذف آمار پرت و انجام آزمون همگنی و نرمال بودن داده‌ها با استفاده از آزمون ران تست و آزمون کلوموگروف - اسمایرنوف، در نهایت پایه زمانی مشتکر بین ایستگاه‌ها تشکیل گردید و بارندگی متوسط سالانه هر ایستگاه محاسبه شد. سپس بر اساس روش‌های درون‌یابی در نرم‌افزار ArcMap 10.8 با استفاده از روش معکوس وزن فاصله (IDW) نقشه توزیع مکانی بارش در حوضه مورد مطالعه تهیه گردید.

کاربری اراضی^۶: کاربری زمین ویژگی‌های سطحی زمین را تحت تأثیر قرار داده و موجب تغییر رفتار آن در مقابل فرآیندهای زمین‌شناسی حاکم بر منطقه از جمله هوازدگی و فرسایش می‌گردد. به طور کلی نقشه کاربری اراضی در حوضه آبخیز توزیع پوشش جنگلی، پهنه‌های آبی و انواع شیوه‌های استفاده از زمین را نشان می‌دهد. در این مطالعه

1- Lithology

2- Distance to Fault and Fault Density

3- Euclidean distance

4- Line Density

5- Rainfall

6- Sidle and Ochiai

7- Land use

نقشه کاربری اراضی از تصاویر ماهواره لندست ۸ (سنجدنده OLI) در سال ۲۰۲۲ با استفاده روش طبقه‌بندی حداکثر همسایگی به دست آمد.

شاخص تفاوت پوشش گیاهی نرمال شده^۱ (NDVI): پوشش گیاهی نقش مهمی در حفظ پایداری طبیعی مواد دامنه دارد و از طریق خروج رطوبت از خاک به صورت تبخیر و تعرق هیدرولوژی دامنه را می‌تواند تغییر دهد. همچنان، ساقه و ریشه گیاهان عامل تقویت مکانیکی برای دامنه محسوب می‌شود (گری و سوتیر^۲، ۱۹۹۶). علاوه بر این، پوشش گیاهی میزان انرژی جنبشی بارندگی و سرعت جریان زمینی را کاهش می‌دهد که باعث کاهش فرسایش خاک و متعاقب آن تثبیت شیب می‌شود. در این مطالعه از NDVI، معیاری برای سلامت پوشش گیاهی، برای تعیین کمیت اثر پوشش گیاهی بر زمین‌لغزش استفاده شده است. نقشه شاخص NDVI با بکارگیری تصاویر ماهواره لندست ۸ (سنجدنده OLI) در سال ۲۰۲۲ با استفاده از رابطه زیر برای حوضه مورد مطالعه تهیه گردید.

$$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}} \quad (1)$$

که در آن RNIR: بازنای از تابش مادون قرمز نزدیک و RRED: بازنای از تابش باند قرمز محدوده مرئی است. فاصله از جاده و تراکم جاده^۳: زمین‌لغزش‌ها به دلیل ساخت جاده بر روی دامنه‌ها ایجاد می‌شوند که اغلب به آن ناپایداری انسانی^۴ می‌گویند (آچو و همکاران، ۲۰۲۳). تعریض جاده و ساخت‌وساز جاده‌های جدید در منطقه مورد مطالعه به عنوان بخشی از توسعه زیرساختی، باعث کاهش پایداری شیب می‌شود. نقشه جاده‌ها از روی نقشه توپوگرافی منطقه در نرم‌افزار ArcMap 10.8 استخراج شد و سپس با استفاده از ابزار فاصله اقلیدسی و تراکم خط به ترتیب فاصله از جاده‌ها و تراکم آنها در حوضه محاسبه گردید.

عوامل توپوگرافیکی

طبقات ارتفاعی^۵: عامل ارتفاع به طور غیرمستقیم بر روی اغلب متغیرهای حوضه آبخیز تأثیر است. این متغیرها شامل بارش سالانه، نوع بارش، تغییرات دمایی، یخ‌بندان و ذوب برف، هوازدگی شیمیایی و فیزیکی و در نتیجه فرسایش خاک می‌باشند. جهت تهیه لایه طبقات ارتفاعی از مدل رقومی ارتفاع^۶ (DEM) استفاده شد. بدین ترتیب که ابتدا مدل رقومی ارتفاع از داده‌های تصاویر ماهواره ALOS POLSAR با اندازه پیکسل ۱۲/۵ متر اخذ و در نرم‌افزار ArcMap 10.8 با استفاده از روش شکست‌های طبیعی^۷ طبقه‌بندی گردید.

مقدار شیب^۸: شیب یکی از بحرانی‌ترین عوامل زمین‌لغزش است. به طور کلی با افزایش شیب، تنفس برشی بالا رفته و در نتیجه حساسیت زمین‌لغزش افزایش می‌یابد (کانوال^۹ و همکاران، ۲۰۱۷). بنابراین، با افزایش شیب دامنه

1- Normalized Differential Vegetation Index

2- Gray and Sotir

3- Distance to Road and Road Density

4- Anthropogenic Instability

5- Elevation

6- Digital Elevation Model

7- Natural Break

8- Slope

9- Kanwal

نایابداری توده خاکی روی دامنه نیز بیشتر می‌شود. نقشه شیب حوضه بر اساس مدل رقومی ارتفاع (DEM) با ابزار آنالیز مکانی^۱ در نرم‌افزار ArcMap 10.8 تهیه شد.

جهت شیب^۲: دامنه‌های شمالی به دلیل زاویه تابش و طول مدت کمتر تابش خورشیدی در نیم‌کره شمالی، دارای مقدار رطوبت خاک بیشتری می‌باشند. در حالی که دامنه‌های جنوبی مدت زمان بیشتری تابش خورشیدی را دریافت کرده و اغلب دارای رطوبت کمتری می‌باشند. این خصوصیت بر روی تراکم پوشش گیاهی و نوع آن و عمق خاک تأثیرگذار خواهد بود. از طرفی، همه این ویژگی‌ها باعث شده که در دامنه‌های شمالی نسبت به دامنه‌های جنوبی شرایط برای وقوع زمین‌لغزش مساعدتر باشد. نقشه جهت شیب با تکیه بر مدل رقومی ارتفاع (DEM) حوضه با ابزار آنالیز مکانی در نرم‌افزار ArcMap 10.8 تولید شد.

انحنای سطح توپوگرافی: انحنای سطح میزان انحراف دامنه از مسطح بودن است که کاربرد زیادی در ژئومورفولوژی و هیدرولوژی دارد (اشمیت^۳ و همکاران، ۲۰۰۳). به عبارتی، میزان همگرایی و واگرایی دامنه بیانگر میزان انحنای توپوگرافی می‌باشد که عامل مهم در کنترل پاسخ هیدرولوژیکی دامنه و حوضه آبخیز است (بوگارت و تروج^۴، ۲۰۰۶). به طور کلی، برای بیان میزان انحنای سطح توپوگرافی از سه ویژگی انحنای عرضی^۵، انحنای طولی^۶ و انحنای کل^۷ استفاده می‌شود. انحنای طولی و عرضی بر روی تمرکز خطوط جریان روی دامنه‌ها اثرگذار هستند. این ویژگی‌ها بر مبنای DEM در نرم‌افزار ArcMap 10.8 تهیه شدند.

شاخص موقعیت توپوگرافی^۸ (TPI): شاخص TPI بازتابی از تفاوت بین ارتفاع سلول کانونی و ارتفاع متوسط تمام سلول‌ها در همسایگی آن است (عبدیین و همکاران، ۲۰۲۰). TPI همراه با سنگشناسی، یک عامل مؤثر برای جریان توده‌ای است. درنظرگرفتن TPI به عنوان یک عامل مؤثر در وقوع زمین‌لغزش و استفاده گسترده از آن در مطالعات تهیه نقشه حساسیت زمین‌لغزش بر این استدلال است که رویدادهای زمین‌لغزش عموماً در دامنه‌ها و یال‌ها رخ می‌دهند (جویی‌اف^۹ و همکاران، ۲۰۱۹). شاخص موقعیت توپوگرافی در شناخت ویژگی‌های توپوگرافی مانند بالای تپه، پایین دره، خط‌الراس آشکار، دشت صاف، شیب بالا یا پایین کاربرد دارد. TPI، مقایسه ارتفاع هر سلول در DEM با میانگین ارتفاع سلول‌های هماییه است که در نهایت ارتفاع میانگین از مقدار ارتفاع سلول مرکزی کم می‌شود. نقشه این شاخص بر پایه مدل رقومی ارتفاع در نرم‌افزار SAGA GIS بر مبنای رابطه زیر تهیه شد.

$$TPI = Z_0 - \frac{\sum_{n=1}^n Z_n}{n} \quad (2)$$

که در آن Z_0 : ارتفاع نقطه مورد نظر ارزیابی، Z_n : ارتفاع از شبکه و n : تعداد کل نقاط اطراف در نظر گرفته در ارزیابی است.

1- Spatial Analyst

2- Aspect

3- Schmidt

4- Bogaart and Troch

5- Plan Curvature

6- Profile Curvature

7- Curvature

8- Topographic Position Index

9- Juliev

شاخص ناهمواری زمین^۱ (TRI): این شاخص در سال ۱۹۹۹ توسط رایلی و همکاران ارائه شده است. این شاخص بر مبنای اختلاف ارتفاع یک پیکسل با هشت پیکسل اطراف آن محاسبه می‌شود. بدین ترتیب که ارتفاع هر پیکسل از پیکسل‌های اطراف خود کم می‌شود؛ سپس از آنها میانگین گرفته شده و ریشه دوم آنها را محاسبه و به پیکسل مورد نظر نسبت می‌دهد. به طور کلی رابطه این شاخص به صورت زیر است:

$$TRI = \sqrt{\sum_{P=1}^8 ZMd} \quad (۳)$$

P: تعداد پیکسل اطراف، ZMd: میانگین تفاضل هشت پیکسل اطراف هر پیکسل می‌باشد.
نقشه شاخص ناهمواری زمین بر مبنای رابطه بالا و با ورودی نقشه DEM در نرم‌افزار SAGA GIS به دست آمد.

عوامل هیدرولوژیکی

فاصله از آبراهه و تراکم آبراهه^۲: شبکه زهکشی حوضه آبخیز نقش مهمی در زمان خارج شدن رواناب‌ها از دامنه‌ها و در نهایت حوضه آبخیز ایفا می‌کند. همچنین، در کنار آبراهه‌ها به دلیل سرعت جریان و انرژی جنبشی جریان فرسایش کناری و کنش پای دامنه‌ها قابل مشاهده است که از این نظر نقش مهمی در ایجاد حرکت‌های توده‌ای دامنه دارند. نقشه آبراهه‌ها و شبکه هیدرولوژیکی حوضه بر مبنای DEM و با استفاده از ابزار هیدرولوژی در نرم‌افزار ArcGIS استخراج شد. سپس با ابزار فاصله اقلیدسی نقشه فاصله از آبراهه و با ابزار تراکم خط نقشه تراکم زهکشی برای حوضه مورد مطالعه تولید گردید.

شاخص حمل رسوب^۳ (STI): یکی از شاخص‌های هیدرولوژیکی مهم در مطالعات زمین‌لغزش شاخص حمل رسوب است. این شاخص در سال ۱۹۸۶ توسط مور و برج ارائه گردید. شاخص STI قدرت فرسایندگی جریان‌ها را روی زمین مشخص می‌کند که بر اساس رابطه زیر قابل محاسبه می‌باشد.

$$STI = (m + 1) \times (A_s / 22.13)^m \times \sin(B / 0.0896)^n \quad (۴)$$

که در آن As: مساحت ویژه (سطح مشارکت کننده بالادست در واحد طول بین خطوط تراز)، B: شیب موضعی (درجه)، m: ثابت عددی برابر با $0/4$ ، n: مقدار عددی برابر با $1/4$ ، برای محاسبه As می‌توان از ابزار تجمع جریان در ArcGIS استفاده کرد. برای تهیه نقشه شاخص STI از مدل رقومی ارتفاع در محیط ArcMap 10.8 بهره گرفته شد. همان‌طور که بیان شد، شاخص STI بر اساس مساحت حوضه و سینوس گرادیان شیب می‌تواند قابلیت حمل رسوب در حوضه را کنترل نمایید. بنابراین، با تغییر شیب و سطح حوضه ممکن است تراکم زهکشی را آشفته کرده و دامنه‌های با گرادیان شیب کم به ایجاد لغزش تمایل پیدا کنند (فصلی اوغلو و همکاران، ۲۰۰۸).

شاخص رطوبت توپوگرافی^۴ (TWI): از آنجایی که توپوگرافی به عنوان یکی از مهم‌ترین عوامل کنترل کننده الگوی مکانی مناطق اشباع رطوبت خاک است، دارای نقش مهمی در فرآیندهای هیدرولوژیکی دامنه و کیفیت آب آبراهه‌ها می‌باشد (گرابز^۵ و همکاران، ۲۰۰۹). تغییرات مکانی رطوبت خاک متأثر از شرایط توپوگرافی دامنه می‌باشند، به-

1- Terrain Ruggedness Index

2- Distance to Stream and Stream Density

3- Sediment Transport Index

4- Topographic Wetness Index

5- Grabs

طوری که میزان رطوبت خاک در نقاط مختلف شبیه‌ها متفاوت است و بر این اساس توصیف شرایط رطوبتی در مقیاس دامنه و حوضه به صورت شاخص TWI بیان گردید. این شاخص اولین بار توسط Beven و Kirkby در سال ۱۹۷۹ در مدل بارش-رواناب TOPMODEL معرفی شد که نقش توپوگرافی بر تولید رواناب را به صورت کمی بیان می‌کند و مناطق اشباع سطحی و توزیع مکانی رطوبت خاک را تخمین می‌زند (بیون و کربی^۱، ۱۹۷۹). به جهت نقش مهم این شاخص بر هیدرولوژی دامنه و اثر بر روی حرکات توده‌ای دامنه به عنوان عامل مهمی در وقوع زمین‌لغزش در نظر گرفته شد. این شاخص بر مبنای DEM در نرم‌افزار ArcMap 10.8 و بر اساس رابطه زیر تهیه گردید.

$$TWI = A_s / \tan\beta \quad (5)$$

که در آن As: سطح ویژه حوضه بر حسب مساحت تجمعی بالادست (مساحت بالادست در واحد طول خط تراز)، β : درجه شبیب است که گرایش آب را به جمع شدن در هر نقطه از حوضه (بر حسب As) و تمایل نیروهای گرانشی را به انتقال آب پایین‌دست (بر حسب $\tan\beta$ به عنوان شبیه هیدرولیکی تقریبی) توصیف می‌کند.

شاخص قدرت جریان^۲ (SPI): شاخص SPI بیانگر قدرت فرسایندگی جریان در آبراهه‌ها می‌باشد و نرخ زمانی مصرف انرژی توسط جریان برای کنش و ایجاد فرسایش را بیان می‌کند. شاخص SPI، ظرفیت انتقال رسوب را به صورت مکانی محاسبه می‌کند و معیار مناسبی برای ارزیابی چشم‌اندازهای فرسایشی است. از این شاخص برای پتانسیل‌یابی وقوع زمین‌لغزش نیز می‌توان استفاده کرد. شاخص SPI با استفاده از رابطه زیر قابل محاسبه است.

$$SPI = A_s \tan\beta \quad (6)$$

که در آن As: سطح ویژه حوضه و β : درجه شبیب است. برای تهیه این شاخص از مدل رقومی ارتفاع (DEM) در نرم‌افزار ArcMap 10.8 استفاده گردید.

آمده‌سازی لایه جهت ورود به مدل‌سازی

بعد از تهیه لایه‌های مؤثر در وقوع زمین‌لغزش، کلیه عوامل با سه ویژگی مشترک شامل سیستم تصویر و مختصات (UTM_WGS1984_Zone_39)، اندازه سلول (Pixel size = 12.5 m) و ابعاد فیزیکی (Extent) یکسان به فرمت رستری (شبکه سلولی) تنظیم شد و تمامی رستری‌ها به فرمت عددی ASCII تبدیل شدند. سپس به همراه لایه آموزشی (لایه نقطه‌ای شامل ۱۵۵ زمین‌لغزش) که حاصل برداشت‌های میدانی و داده‌های تاریخی زمین‌لغزش‌های رخداده در حوضه می‌باشد، برای مدل‌سازی وارد نرم‌افزار R شدند. سرانجام با استفاده از الگوریتم‌های ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) نقشه حساسیت زمین‌لغزش در حوضه تهیه گردید.

جنگل تصادفی (RF)

RF یک فن یادگیری ترکیبی است که توسط Breiman (۲۰۰۱) توسعه داده شد. این فن بر اساس مجموعه‌ای از درخت‌های تصمیم (DT) است که هر درخت با انتخاب یک دسته تصادفی از متغیرها و مجموعه نمونه‌های آموزشی، آموزش داده می‌شود (وینچنزو^۳ و همکاران، ۲۰۱۱). در واقع RF یک الگوریتم طبقه‌بندی و رگرسیون بر اساس

1- Beven and Kirkby

2- Stream Power Index

3- Vincenzi

روش‌های Bagging و زیر مجموعه‌های تصادفی است (سیح^۱ و همکاران، ۲۰۱۸). که تعداد زیادی DT می‌سازد و از آنها میانگین می‌گیرد (فراکلین، ۲۰۱۰). علت ساخت مجموعه‌ای از درختان جنگل این است که واریانس درخت منفرد که به عنوان یک اثر منفی شناخته می‌شود، توسط فن Bagging کاهش می‌یابد. در فن RF زیر مجموعه تصادفی به عنوان پیش‌بینی کننده‌های کاندید در نظر گرفته می‌شود. این رویکرد، عملکرد درختان را از یکدیگر جدا کرده و کاهش واریانس را بهبود می‌بخشد (الیت و گراهام، ۲۰۰۹). الگوریتم رشد RF با K درخت تصمیم به صورت زیر عمل می‌کند:

$$\text{for } i = 1 \text{ to } k - 1 \quad (7)$$

ترسیم یک زیر مجموعه X در برگیرنده تقریباً (دو سوم) ۳/۲ از عناصر مجموعه اصلی X عناصری که در مجموعه X قرار نمی‌گیرند، عناصر OOB هستند و در ساخت درخت استفاده نمی‌شوند. استفاده از X به منظور رشد یک درخت طبقه‌بندی هرس‌نشده جهت رسیدن به حداکثر رشد عمقی (عرضی)، در هر گره به جای انتخاب بهترین بخش در میان همه متغیرهای پیش‌بینی کننده، m متغیر پیش‌بینی به صورت تصادفی انتخاب شده و بهترین بخش از بین این متغیرها انتخاب می‌شود.

مدل ماشین بردار پشتیبان (SVM)

الگوریتم ماشین بردار پشتیبان، یک روش رگرسیون و طبقه‌بندی است که اولین بار توسط کورتس و واپنیک^۲ (۱۹۹۵) ارائه شد. این روش بر پایه تئوری یادگیری آماری بنا شده است و بر اساس آن می‌توان کران نرخ خطای ماشین یادگیری را برای داده‌های طبقه‌بندی نشده به عنوان نرخ خطای تعیین‌یافته در نظر گرفت. این کرانه‌ها به عنوان تابعی از مجموع نرخ خطاهای آموزشی می‌باشند که میزان پیچیدگی طبقه‌بندی کننده‌ها را نشان می‌دهد. مدل SVM یکی از مدل‌های یادگیری ماشین نظرارت شده است که پس از مشخص کردن داده‌های ورودی مدل (متغیرهای مستقل) و داده‌های هدف (متغیرهای وابسته) می‌تواند پس از تجزیه و تحلیل این داده‌ها آنها را در گروه‌های متمایزی گروه‌بندی کند. در مدل SVM هر نمونه داده را به عنوان یک نقطه در فضای n بعدی روی نمودار پراکندگی داده‌ها ترسیم می‌کند و مقدار هر ویژگی مربوط به داده‌ها، یکی از مؤلفه‌های مختصات نقطه روی نمودار را مشخص می‌کند (سیه‌اگ^۴ و همکاران، ۲۰۱۹). در این پژوهش، برای اجرای مدل‌های ماشین بردار پشتیبان و جنگل تصادفی، از برنامه‌نویسی در نرم‌افزار RStudio استفاده گردید.

صحت‌سنجی نقشه‌های تولید شده با استفاده از منحنی ROC

به این منظور از محاسبه ویژگی‌های عامل نسبی (ROC) در محیط نرم‌افزار R استفاده شد. در روش ROC، مساحت زیر منحنی (AUC) مقادیر بین ۰/۵ تا ۱ داشته و برای ارزیابی دقت مدل به کار می‌رود. هر چقدر مقدار AUC به (۱) نزدیک‌تر شود، دقت مدل بیشتر است (اوپوچوفسکی و بولن^۵، ۲۰۱۸؛ رابین^۶ و همکاران، ۲۰۱۱).

1- Ceh

2- Elith and Graham

3- Cortes and Vapnik

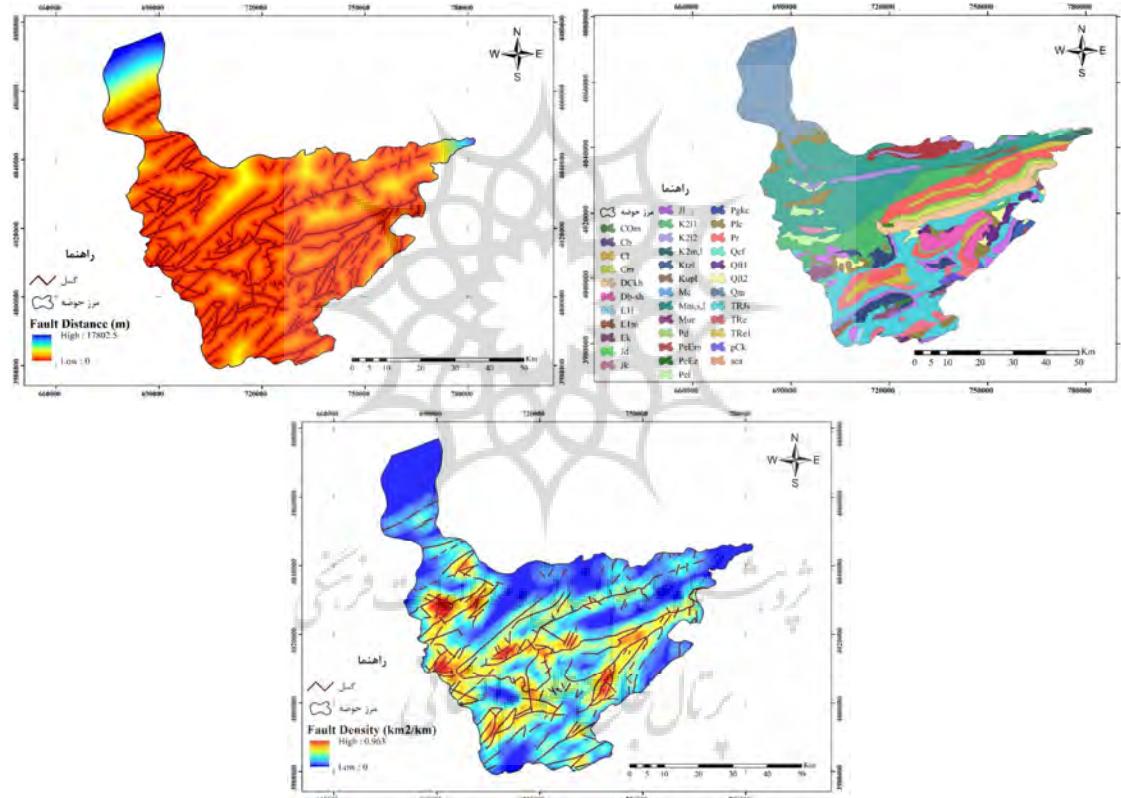
4- Sihag

5- Obuchowski and Bullen

6- Robin

نتایج و بحث عوامل زمین‌شناسی

از مهم‌ترین عوامل مؤثر در وقوع زمین‌لغزش، عوامل زمین‌شناسی می‌باشند. عوامل زمین‌شناسی شامل مقاومت سنگ‌ها در برابر فرآیند هوازدگی و فرسایش، میزان گسل‌ها و خطواره‌ها که جنبه مهمی در کنترل پایداری شیب به شمار می‌روند. نوع واحدهای سنگی و میزان گسترش آنها، فاصله از گسل و تراکم گسل‌ها در حوضه مهم‌ترین عواملی است که در این مطالعه درنظر گرفته شد. نقشه نهایی عوامل زمین‌شناسی که نحوه تهیه آنها قبل اشاره شده است در زیر ارائه شده است (شکل ۲).

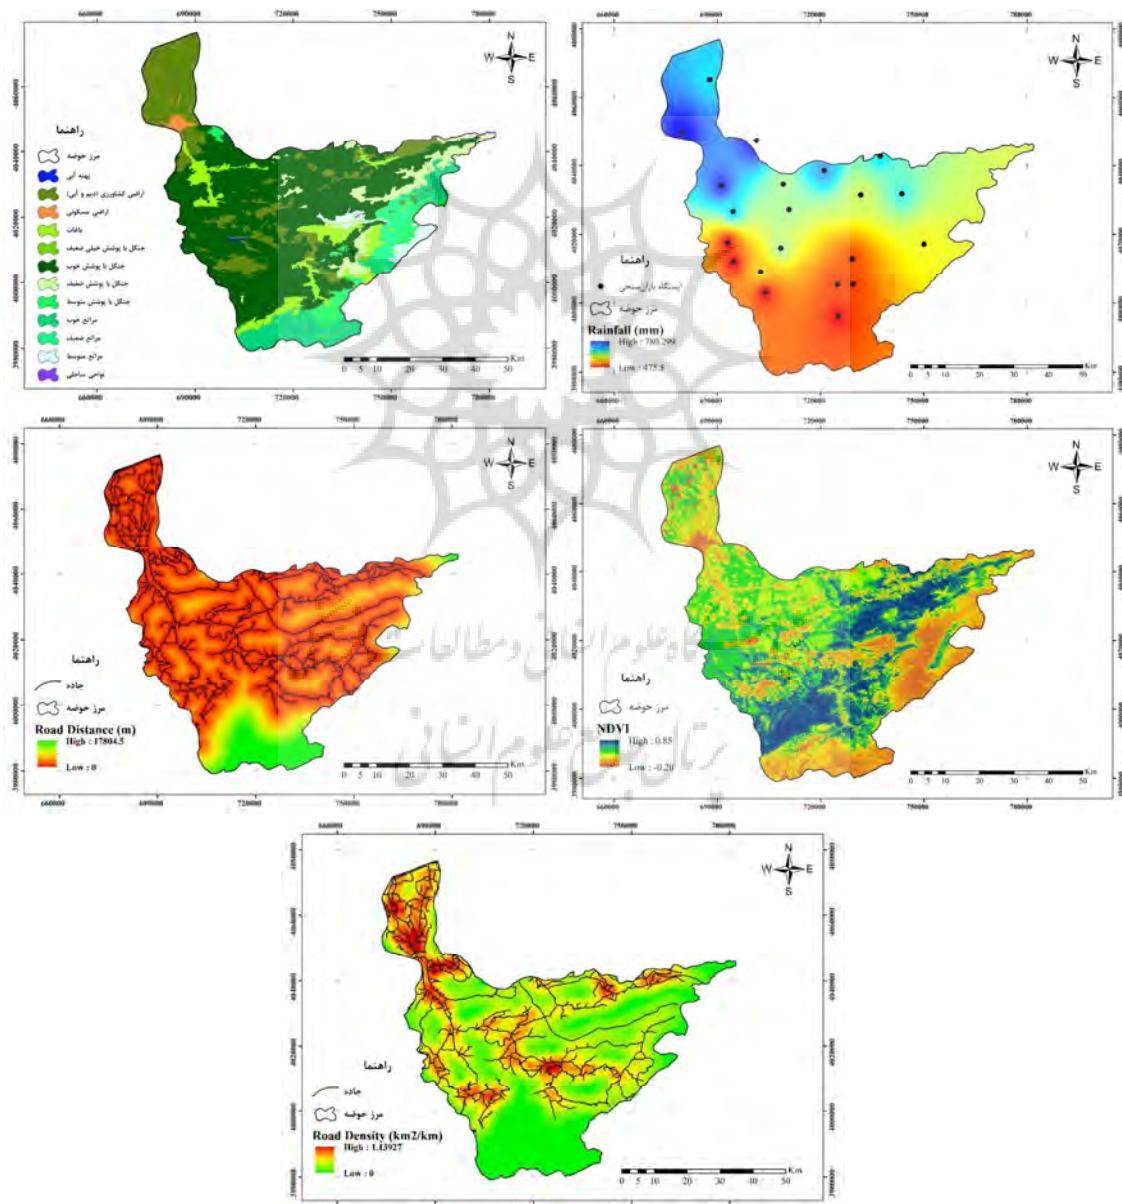


شکل ۲: نقشه مهم‌ترین عوامل زمین‌شناسی مؤثر بر وقوع زمین‌لغزش در حوضه آبخیز تجن

بر اساس نتایج به دست آمده از نقشه واحدهای سنگ‌شناسی سازندهای موجود در حوضه شامل سازند باروت (Ebt)، سازند لالون (El)، سازند مبارک (Cm)، سازند میلا (Em)، سازند دلیچای (Jd)، سازند کشف رود (Jk)، سازند لار (Jl)، سازند تیزکوه (K11)، سازند درود (Pd)، سازند زیارت (Ez) و سازند شمشک (Js) می‌باشد. بیشترین سطح حوضه را سنگ‌های مارنی، ماسه سنگ آهکی، سنگ آهکی شنی و کنگلومراژ جزئی ۹۵۱/۰۶ کیلومتر مربع) و شیل و ماسه سنگ، سیلتستون خاکستری تیره (۵۸۰/۷۷ کیلومتر مربع) به خود اختصاص داده است. حوضه آبخیز تجن در برگیرنده دو گسل فعال شامل گسل خزر و گسل شمال البرز می‌باشد که نقش مهمی در تکتونیک منطقه دارند.

عوامل اقلیمی و محیطی

بارندگی، شایع‌ترین علت زمین‌لغزش است. بارندگی باعث تغییراتی در دینامیک آب‌های سطحی و زیرزمینی می‌شود که شرایط پایداری شیب را کاهش داده و باعث لغزش زمین می‌شود. نقش فعالیت‌های انسانی بیشتر بر روی تغییرات کاربری اراضی، پوشش گیاهی و جاده‌سازی در دامنه‌ها مشهود است که این فاکتورها مهم‌ترین عوامل در وقوع زمین‌لغزش در دامنه‌ها می‌باشند (شکل ۳).

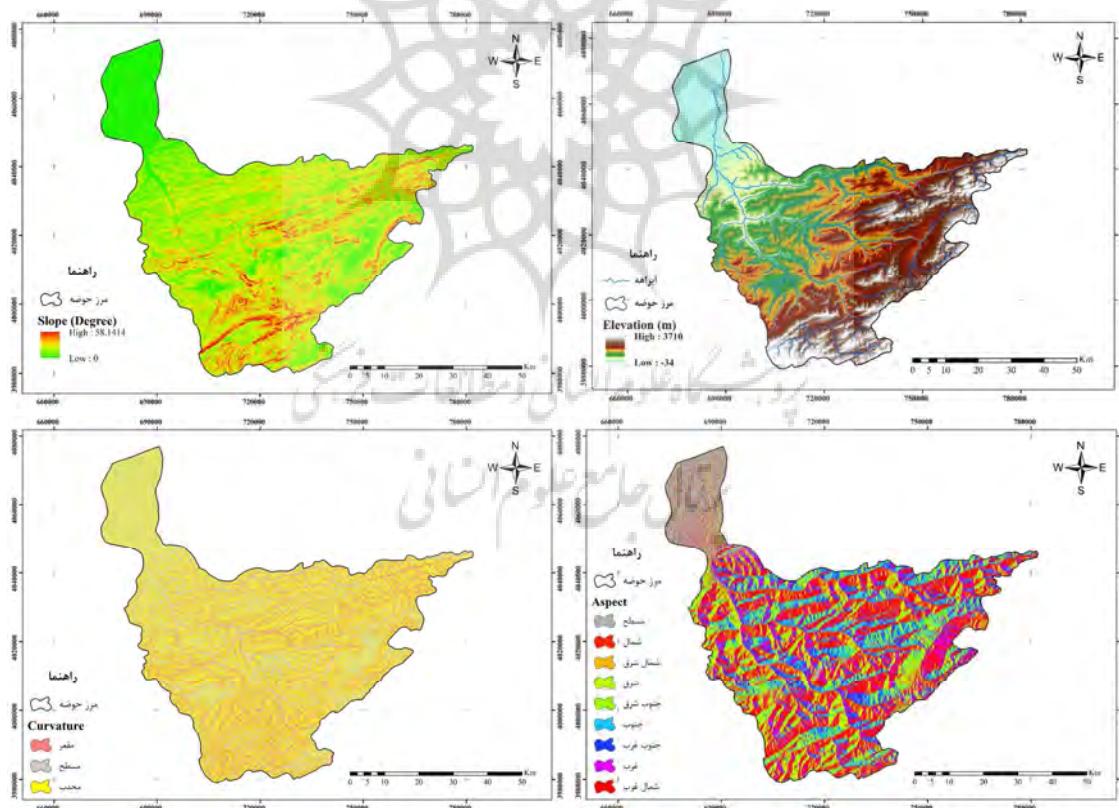


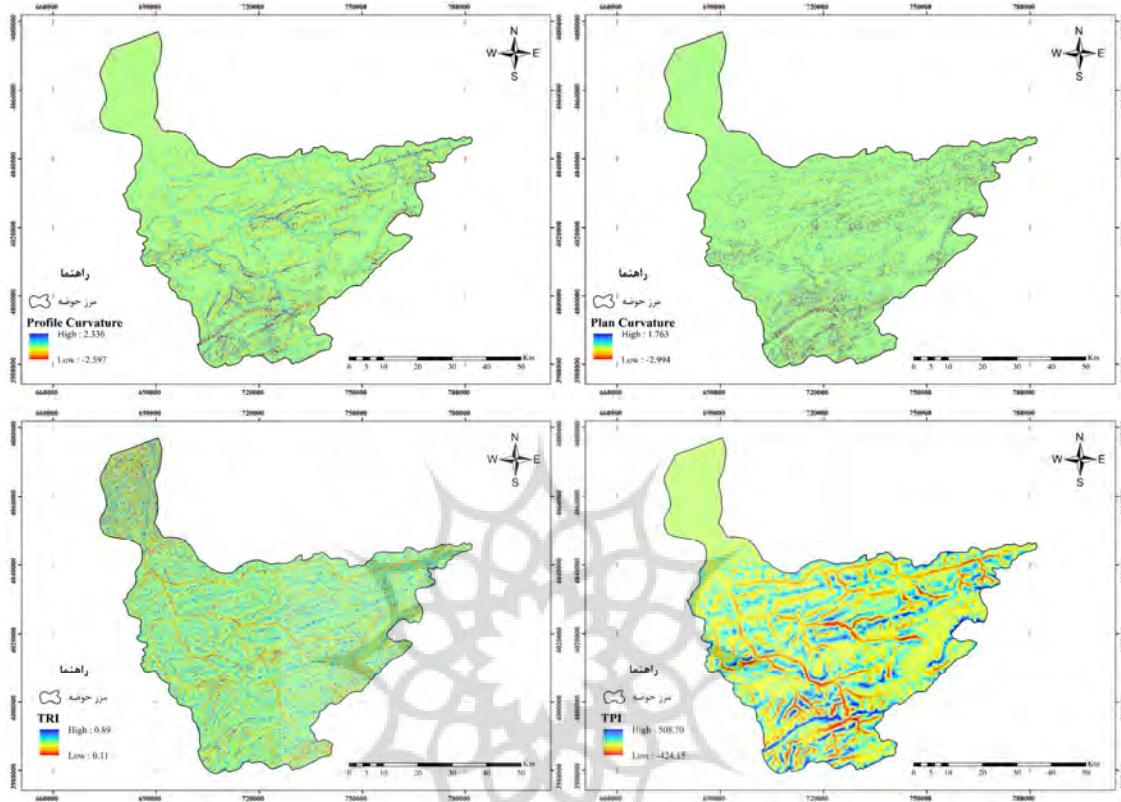
شکل ۳: نقشه مهم‌ترین عوامل اقلیمی و محیطی مؤثر بر وقوع زمین‌لغزش در حوضه آبخیز تجن

بر اساس نتایج به دست آمده، میزان بارندگی متوسط سالانه حوضه سالانه حوضه آبخیز تجن ۵۶۰ میلی‌متر می‌باشد که بیشترین میزان بارش در نواحی شمالی حوضه رخ می‌دهد. بر اساس نقشه کاربری اراضی، بیشترین سطح حوضه را جنگلهای متراکم (۲۱۸۳/۳۸ کیلومتر مربع) و اراضی کشاورزی (۷۹۳/۶۴ کیلومتر مربع) پوشانده است. با افزایش جمعیت و توسعه شهرها و روستاهای جاده‌سازی در حوضه مورد نظر افزایش یافته است که عامل مهمی در برهم‌زدن مواد دامنه‌ای می‌باشد.

عوامل توپوگرافیکی

میزان تخریب در اراضی با وضعیت توپوگرافی پرشیب بهویژه در خط الراس‌ها و قله‌ها به میزان قابل توجهی افزایش می‌باید (اسمیت، ۱۹۹۲). عوامل توپوگرافی زمین روی بسیاری از ویژگی‌ها حوضه از جمله هیدرولوژیکی، ژئومورفولوژیکی، خاک‌شناسی و سازندهای زمین‌شناسی مؤثر می‌باشند. عوامل مختلفی از توپوگرافی زمین بر روی زمین‌لغزش اثرگذار هستند که مهم‌ترین آنها در این مطالعه در نظر گرفته شد. نتایج تهیه نقشه این عوامل در زیر قابل مشاهده است (شکل ۴).



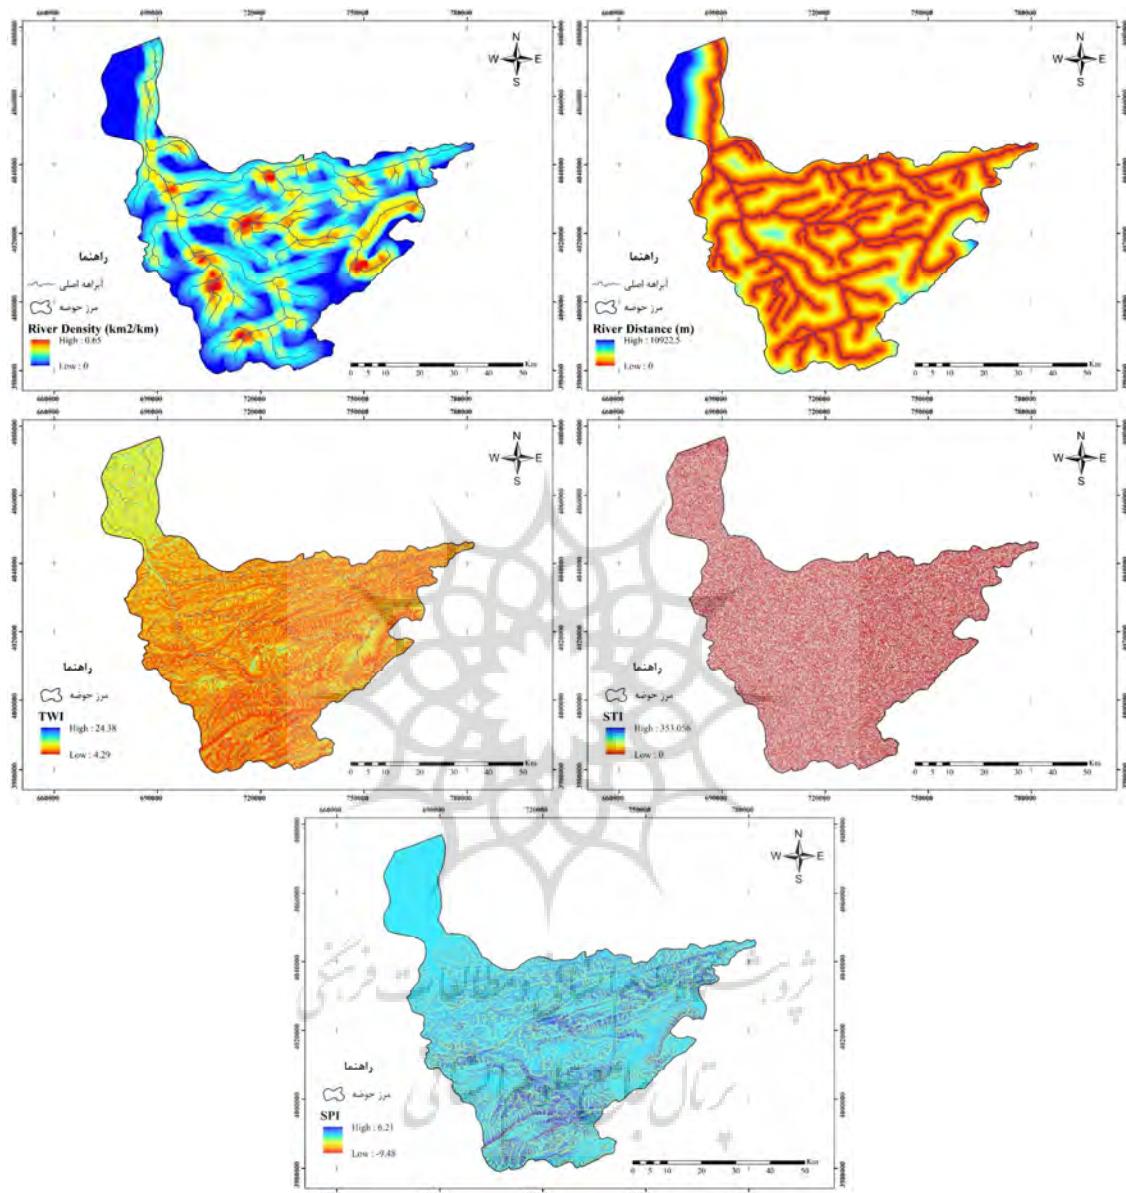


شکل ۴: نقشه مهم‌ترین عوامل توپوگرافی مؤثر بر وقوع زمین‌لغزش در حوضه آبخیز تجن

نتایج این مطالعه نشان داد که محدوده تغییرات ارتفاعی در حوضه بین ۳۴-۳۷۱۰ متر می‌باشد. از نظر توپوگرافی نیز در سطح حوضه اراضی دشتی (دشت ساری) و هموار تا مناطق مرتفع و دارای توپوگرافی شدید وجود دارد. به طوری که میزان شیب بر حسب درجه از صفر درجه و در برخی مناطق تا ۵۸/۱۴ درجه قابل مشاهده است. همچنین، بیشترین سطح حوضه (۲۱/۷۲ درصد) در طبقه شیب ۱۰-۱۵ درجه قرار دارد. جهت‌های شمال و شمال غرب نیز بیشترین درصد سطح حوضه را به خود اختصاص داده‌اند. مقادیر شاخص TPI نیز بیانگر توپوگرافی شدید و اختلاف بالای بین مناطق مرتفع و دره‌ها و اراضی پست را نشان می‌دهد.

عوامل هیدرولوژیکی

بررسی ویژگی‌های شبکه هیدرولوژیکی در تهیه نقشه حساسیت وقوع زمین‌لغزش بسیار حائز اهمیت می‌باشد. ایجاد فرسایش و تولید رسوب، کنش دیواره کانال‌ها و آبراهه‌ها، کنش و فرسایش در بستر آبراهه‌ها از مهم‌ترین اثرات شبکه هیدرولوژیکی می‌باشد. وجود جریان و خصوصیت آن در این شبکه نیز می‌تواند بر روی ویژگی‌های هیدرولوژیکی و ریخت‌شناسی آبراهه‌ها مؤثر باشد که خود عاملی مهم در وقوع زمین‌لغزش است. نتایج مهم‌ترین عوامل هیدرولوژیکی در وقوع حساسیت زمین‌لغزش در زیر نشان داده شده است (شکل ۵).

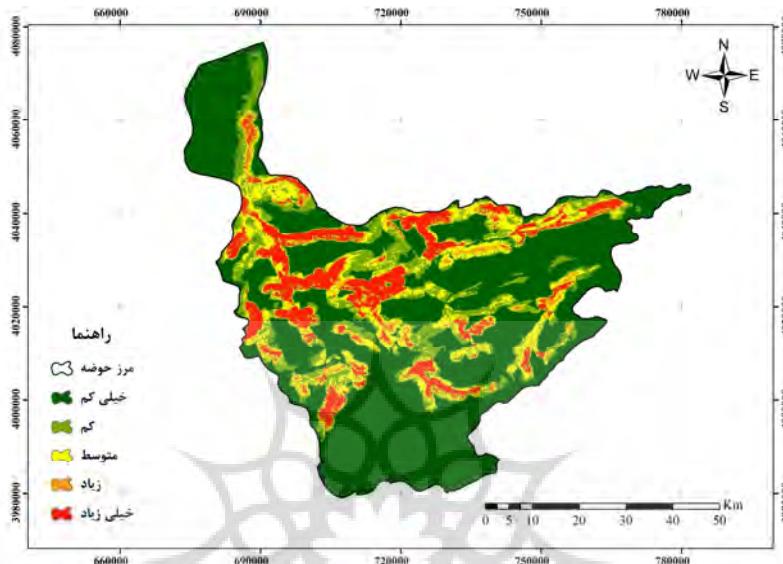


شکل ۵: نقشه مهم‌ترین عوامل هیدرولوژیکی مؤثر بر وقوع زمین‌لغزش در حوضه آبخیز تجن

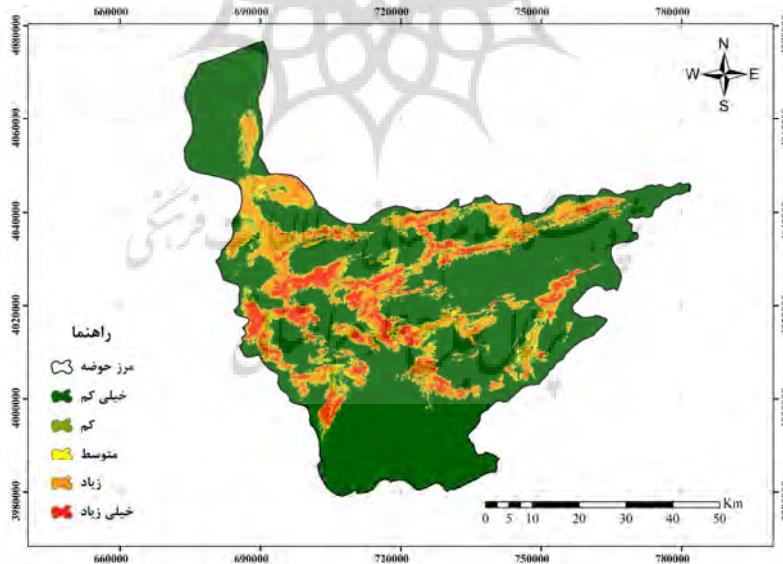
نتایج نقشه حساسیت زمین‌لغزش با الگوریتم‌های یادگیری ماشین

تهییه نقشه عوامل مؤثر در وقوع زمین‌لغزش در نرم‌افزار ArcGIS نهایی شد. سپس برای انتقال به نرم‌افزار R کلیه عوامل به فرمت ASCII تبدیل شدند. برای اجرای مدل‌های یادگیری ماشین از لایه آموزشی نقطه‌ای شامل ۱۵۵ واقعه زمین‌لغزش استفاده گردید. بدین منظور از ۷۰ درصد (۱۰۹ واقعه زمین‌لغزش) آنها برای آموزش مدل‌ها و ۳۰ درصد (۴۶ واقعه زمین‌لغزش) جهت آزمون مدل‌ها بهره گرفته شد. در نهایت مدل‌های ماشین بردار پشتیبان (SVM)

و جنگل تصادفی (RF) در نرم‌افزار R اجرا گردید که نتایج نقشه حساسیت وقوع زمین‌لغزش به ترتیب زیر به دست آمد (شکل ۶ و ۷).



شکل ۶: نقشه حساسیت به وقوع زمین‌لغزش با مدل جنگل تصادفی (RF) حوزه آبخیز تجن



شکل ۷: نقشه حساسیت به وقوع زمین‌لغزش با مدل ماشین بردار پشتیبان (SVM) حوزه آبخیز تجن

ارزیابی نتایج مدل‌ها

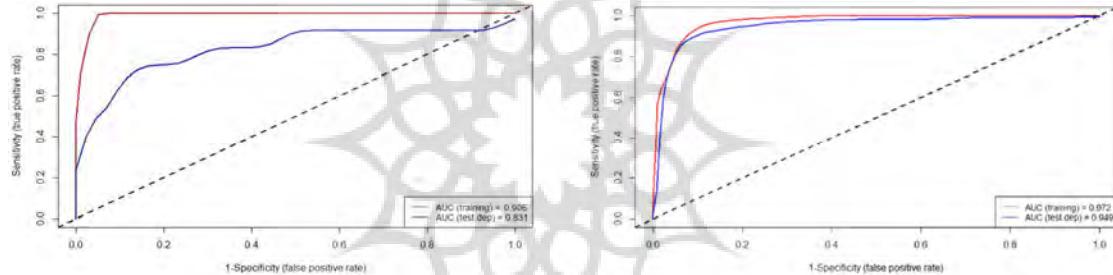
جهت ارزیابی نتایج مدل‌ها از منحنی مشخصه عملکرد و سطح زیر آن در نرم‌افزار R استفاده شد. در منحنی ROC سطح زیر منحنی بیانگر دقیقت مدل مورد نظر است که میزان تغییرات آن بین ۵/۰ تا ۱ می‌باشد. اگر میزان سطح زیر

منحنی (AUC) بین ۰/۹-۱/۰ باشد عملکرد عالی و بین ۰/۸-۰/۹ عملکرد خیلی خوب، ۰/۷-۰/۸ عملکرد خوب، ۰/۶-۰/۵ عملکرد ضعیفی را برای مدل نشان می‌دهد. نتایج ارزیابی مدل‌ها بر مبنای منحنی در جدول زیر ارائه شده است (جدول ۱).

جدول ۱: نتایج اعتبارسنجی مدل‌های مورد استفاده در پیش‌بینی نقشه حساسیت زمین‌لغزش حوضه آبخیز تجن

ROC-AUC		مدل
Testing	Training	
۰/۹۴۹	۰/۹۷۲	جنگل تصادفی (RF)
۰/۸۳۱	۰/۹۰۶	ماشین بردار پشتیبان (SVM)

منحنی‌های ROC مدل‌های SVM و RF نیز به صورت زیر به دست آمد (شکل ۸ و ۹).

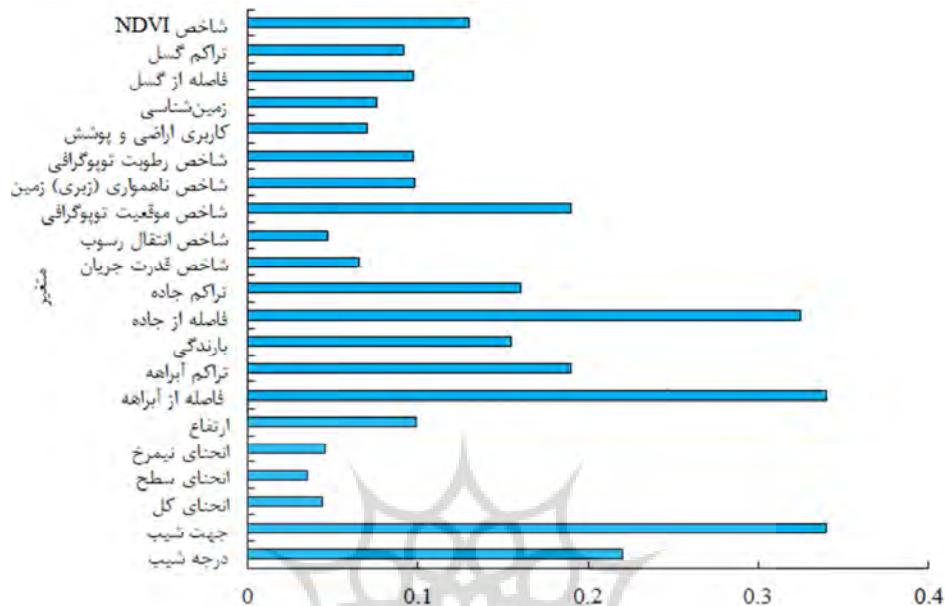


شکل ۹: منحنی ROC مدل SVM در پیش‌بینی نقشه حساسیت زمین‌لغزش حوضه آبخیز تجن

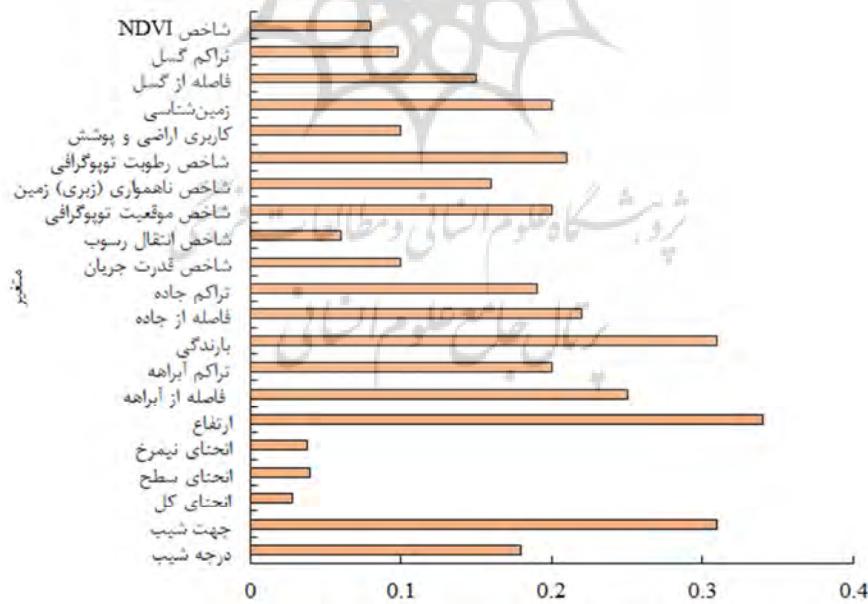
شکل ۸: منحنی ROC مدل RF در پیش‌بینی نقشه حساسیت زمین‌لغزش حوضه آبخیز تجن

نتایج اهمیت فاکتورهای مختلف در وقوع زمین‌لغزش

جهت تعیین اهمیت فاکتورهای مختلف در وقوع زمین‌لغزش و انتخاب مؤثرترین آنها از برنامه‌نویسی در نرم‌افزار R استفاده گردید. با تعیین این عوامل می‌توان در جهت مدیریت و کاهش خطر وقوع گام برداشت. اهمیت نسبی عوامل مؤثر در وقوع زمین‌لغزش برای دو مدل SVM و RF به ترتیب زیر می‌باشد (شکل ۱۰ و ۱۱).



شکل ۱۰: اهمیت نسبی عوامل مؤثر در وقوع زمین‌لغزش با مدل RF در حوضه آبخیز تجن



شکل ۱۰: اهمیت نسبی عوامل مؤثر در وقوع زمین‌لغزش با مدل SVM در حوضه آبخیز تجن

نتیجه‌گیری

به منظور دستیابی به اهداف پژوهش، ابتدا با استفاده از مطالعات کتابخانه‌ای شامل بررسی منابع دانشگاهی، کتب، مقالات داخلی و خارجی و گزارش‌های مهندسی عوامل مؤثر در وقوع زمین‌لغزش بر مبنای اصول علمی و مهندسی

انتخاب شدند. سپس نقشه توزیع مکانی و پراکنش زمین‌لغزش‌های رخداده در منطقه از اداره کل منابع طبیعی استان مازندران - ساری اخذ و با انجام بازدیدهای میدانی از دقت و صحت آنها اطمینان حاصل شد. همچنین، در بازدیدهای میدانی موقعیت جغرافیایی تعدادی زمین‌لغزش که اخیراً رخداده بودند جانمایی و با دستگاه موقعیت‌یاب جهانی (GPS) برداشت شدند. عوامل مؤثر در وقوع زمین‌لغزش در این مطالعه در چهار طبقه عوامل زمین‌شناسی، اقلیمی و محیطی، توپوگرافی و هیدرولوژیکی دسته‌بندی شدند. نقشه تمامی عوامل در نرم‌افزارهای ArcGIS 10.8، EVNI 5.6 و SAGA GIS با اندازه پیکسل یکسان (۱۲/۵ متر) تولید و سپس به فرمت ASCII برای تهیه نقشه حساسیت زمین‌لغزش به نرم‌افزار R وارد شدند. با توجه به نیاز الگوریتم‌های یادگیری ماشین به نمونه‌های آموزشی (Training Samples) برای انجام فرآیند یادگیری، از لایه وکتوری موقعیت زمین‌لغزش‌ها (۱۵۵ نمونه) برای آموزش این الگوریتم‌ها بهره گرفته شد. نقشه‌های نهایی حساسیت به وقوع زمین‌لغزش با مدل جنگل تصادفی بررسی نشان می‌دهد که مناطق میانی حوضه دارای بیشترین حساسیت به وقوع زمین‌لغزش هستند و نقشه جاده‌ها و آبراهه‌ها در حساسیت زیاد غیرقابل اجتناب است. بر اساس نتایج حاصل از مدل RF، طبقات خیلی‌زیاد، زیاد، متوسط، کم و خیلی کم در معرض خطر به ترتیب ۱۰/۱۹٪ (معادل ۴۳۷/۲۲ کیلومتر مربع)، ۱۷/۰۹٪ (۱۷۹/۰۹ کیلومتر مربع)، ۱۰/۷۶٪ (۴۶۱/۶۱ کیلومتر مربع)، ۱۵/۶۲٪ (۶۷۰/۰۲ کیلومتر مربع) و ۵۹/۲۶٪ (۲۵۴۲/۰۶ کیلومتر مربع) از سطح حوضه را تشکیل می‌دهند. نتایج اعتبارسنجی الگوریتم جنگل تصادفی (RF) نشان می‌دهد که عملکرد مدل در مرحله آموزش و آزمون به ترتیب ۹۷۲/۰ و ۹۴۹/۰ بوده که نشان‌دهنده عملکرد عالی آن است. همچنین، عوامل مؤثر در تهیه نقشه حساسیت وقوع زمین‌لغزش شامل جهت شیب، فاصله از آبراهه، فاصله از جاده، درجه شیب و شاخص موقعیت توپوگرافی از اهمیت بالایی برخوردارند.

تهیه نقشه حساسیت زمین‌لغزش با مدل SVM نشان داد که سطح طبقات خطر به ترتیب شامل ۵/۵۱ درصد سطح حوضه (۲۳۶/۳۹ کیلومتر مربع) در طبقه خطر خیلی‌زیاد، ۱۵/۵۸ درصد (۶۶۸/۷۸ کیلومتر مربع) در طبقه زیاد، ۵/۳۳ درصد (۲۲۸/۷۳ کیلومتر مربع) در طبقه متوسط، ۴/۴۷ درصد (۱۹۲/۱۱ کیلومتر مربع) در طبقه کم و ۶۹/۰۹ درصد (۲۹۶۴/۰۰ کیلومتر مربع) در طبقه خطر خیلی کم قرار دارند. نتایج نشان می‌دهد که در مدل SVM طبقه خطر خیلی زیاد کاهش یافته و پتانسیل طبقه خطر زیاد افزایش یافته است. ارزیابی این مدل نشان می‌دهد که مقدار AUC در مرحله آموزش ۰/۹۰۶ و در مرحله آزمون ۰/۸۳۱ است که نشان‌دهنده عملکرد عالی در مرحله آموزش و خیلی خوب در مرحله آزمون است. با این حال، مدل SVM در مقایسه با مدل جنگل تصادفی (RF) عملکرد ضعیفتری در پیش‌بینی نقشه حساسیت زمین‌لغزش دارد. همچنین، عوامل مؤثر در این مدل شامل طبقات ارتفاعی، بارندگی، جهت شیب، فاصله از آبراهه و فاصله از جاده شناسایی شده‌اند.

تقدیر و تشکر

نویسنده‌گان از اداره کل منابع طبیعی استان مازندران - ساری به جهت در اختیار قرار دادن موقعیت زمین‌لغزش‌های تاریخی حوضه تجن و هماهنگی برای بازدید مراتب تقدیر و سپاسگزاری را به عمل می‌آورند.

منابع

- دارابی شاهماری، سحر؛ صفاری، امیر. (۱۳۹۸). برآورد حساسیت زمین‌لغزش با استفاده از مدل رگرسیون لجستیک و شاخص آنتربویی مطالعه موردی: ارتفاعات شهرستان دالاهو. *تحلیل فضایی مخاطرات طبیعی*, ۲(۶)، ۱۶۰-۱۸۵. <http://dx.doi.org/10.29252/jsaeh.6.2.165>
- درویشی، یوسف؛ موسوی‌ندوشن، سید معین. (۱۴۰۲). تحلیل فضایی حساسیت وقوع زمین‌لغزش در محدوده‌های روستایی و شهری (مطالعه موردی: حیریم مناطق تابع شهرستان گرگان در حوضه آبخیز زرین‌گل). *مهندسی جغرافیایی سرزمین*, ۷(۲)، ۳۳۳-۳۵۰. <https://www.doi.org/10.22034/jget.2023.147993>
- ذاکری نژاد، رضا؛ کهرانی، عباس. (۱۴۰۲). ارزیابی و مقایسه مدل‌های TreeNet و CART جهت تهیه نقشه‌های حساسیت زمین‌لغزش با استفاده نرم‌افزار SPM و سامانه اطلاعات جغرافیایی (GIS). *(مطالعه موردی حوضه آبخیز کمه، استان اصفهان)*. *مخاطرات محیط طبیعی*, ۱۲(۳۷)، ۱۷-۳۸. <https://doi.org/10.22111/jneh.2023.42304.1904>
- طالبی، علی؛ نفرزادگان، علیرضا؛ ملکی‌نژاد، حسین. (۱۳۸۸). مروری بر مدل‌سازی تجربی و فیزیکی زمین‌لغزش‌های ناشی از بارندگی. *پژوهش‌های جغرافیای طبیعی*, ۴۱(۷۰)، ۴۵-۶۴.
- Abedin, J., Rabby, Y. W., Hasan, I., Akter, H. (2020). An investigation of the characteristics, causes, and consequences of June 13, 2017, landslides in Rangamati District Bangladesh. *Geoenvironmental Disasters*, 7, 1-19. <https://doi.org/10.1186/s40677-020-00161-z>
- Achu, A. L., Aju, C. D., Di Napoli, M., Prakash, P., Gopinath, G., Shaji, E., Chandra, V. (2023). Machine-learning-based landslide susceptibility modeling with emphasis on uncertainty analysis. *Geoscience Frontiers*, 14(6), 101657. <https://doi.org/10.1016/j.gsf.2023.101657>
- 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>
- Althuwaynee, O. F., Pradhan, B., Park, H. J., Lee, J. H. (2014). A novel ensemble bivariate statistical evidential belief function with knowledge-based analytical hierarchy process and multivariate statistical logistic regression for landslide susceptibility mapping. *Catena*, 114, 21-36. <https://doi.org/10.1016/j.catena.2013.10.011>
- Azrafza, M., Azrafza, M., Akgün, H., Atkinson, P. M., Derakhshani, R. (2021). Deep learning-based landslide susceptibility mapping. *Scientific reports*, 11(1), 24112. <https://doi.org/10.1038/s41598-021-03585-1>
- Beven, K. J., Kirkby, M. J. (1979). A physically based, variable contributing area model of basin hydrology/Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. *Hydrological Sciences Journal*, 24(1), 43-69. <https://doi.org/10.1080/02626667909491834>
- Bhardwaj, D., Sarkar, R. (2024). Landslide susceptibility mapping using probabilistic frequency ratio and Shannon entropy for Chamoli, Uttarakhand Himalayas. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 48(1), 377-395. <https://doi.org/10.1007/s40996-024-01509-3>
- Bogaart, P. W., Troch, P. A. (2006). Curvature distribution within hillslopes and catchments and its effect on the hydrological response. *Hydrology and Earth System Sciences*, 10(6), 925-936. <https://doi.org/10.5194/hess-10-925-2006>
- Carrión-Mero, P., Montalván-Burbano, N., Morante-Carballo, F., Quesada-Román, A., Apolo-Masache, B. (2021). Worldwide research trends in landslide science. *International journal of environmental research and public health*, 18(18), 9445. <https://doi.org/10.3390/ijerph18189445>
- Chu, L., Wang, L. J., Jiang, J., Liu, X., Sawada, K., & Zhang, J. (2019). Comparison of landslide susceptibility maps using random forest and multivariate adaptive regression spline models in combination with catchment map units. *Geosciences Journal*, 23, 341-355. <https://doi.org/10.1007/s12303-018-0038-8>
- Cortes, C., Vapnik, V. (1995). Support vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Cui, K., Lu, D., Li, W. (2017). Comparison of landslide susceptibility mapping based on statistical index, certainty factors, weights of evidence, and evidential belief function models. *Geocarto International*, 32(9), 935-955. <https://doi.org/10.1080/10106049.2016.1195886>
- Grabs, T., Seibert, J., Bishop, K., Laudon, H. (2009). Modeling spatial patterns of saturated areas: A comparison of the topographic wetness index and a dynamic distributed model. *Journal of Hydrology*, 373(1-2), 15-23. <https://doi.org/10.1016/j.jhydrol.2009.03.031>
- Gray, D. H., Sotir, R. B. (1996). Biotechnical and soil bioengineering slope stabilization: a practical guide for erosion control. John Wiley & Sons. 400 pages.
- Habumugisha, J. M., Chen, N., Rahman, M., Islam, M. M., Ahmad, H., Elbeltagi, A., Sharma, G., Liza, S.N. and Dewan, A. (2022). Landslide susceptibility mapping with deep learning algorithms. *Sustainability*, 14(3), 1734. <https://doi.org/10.3390/su14031734>

- Haque, U., Da Silva, P.F., Devoli, G., Pilz, J., Zhao, B., Khaloua, A., Wilopo, W., Andersen, P., Lu, P., Lee, J. and Yamamoto, T. (2019). The human cost of global warming: Deadly landslides and their triggers (1995–2014). *Science of the Total Environment*, 682, 673-684. <https://doi.org/10.1016/j.scitotenv.2019.03.415>
- Hemasinghe, H., Rangali, R.S.S., Deshpriya, N. L., Samarakoon, L. (2018). Landslide susceptibility mapping using logistic regression model (a case study in Badulla District, Sri Lanka). *Procedia Engineering*, 212, 1046-1053. <https://doi.org/10.1016/j.proeng.2018.01.135>
- Hong, H., Liu, J., Bui, D.T., Pradhan, B., Acharya, T.D., Pham, B.T., Zhu, A.X., Chen, W. and Ahmad, B.B. (2018). Landslide susceptibility mapping using J48 Decision Tree with AdaBoost, Bagging, and Rotation Forest ensembles in the Guangchang area (China). *Catena*, 163, 399-413. <https://doi.org/10.1016/j.catena.2018.01.005>
- Huang, W., Ding, M., Li, Z., Zhuang, J., Yang, J., Li, X., Meng, L.E., Zhang, H., Dong, Y. (2022). An efficient user-friendly integration tool for landslide susceptibility mapping based on support vector machines: SVM-LSM toolbox. *Remote Sensing*, 14(14), 3408. <https://doi.org/10.3390/rs14143408>
- Juliev, M., Mergili, M., Mondal, I., Nurtaev, B., Pulatov, A., Hübl, J. (2019). Comparative analysis of statistical methods for landslide susceptibility mapping in the Bostanlik District, Uzbekistan. *Science of the total environment*, 653, 801-814. <https://doi.org/10.1016/j.scitotenv.2018.10.431>
- Kanwal, S., Atif, S., Shafiq, M. (2017). GIS-based landslide susceptibility mapping of northern areas of Pakistan, a case study of Shigar and Shyok Basins. *Geomatics, Natural Hazards and Risk*, 8(2), 348-366. <https://doi.org/10.1080/19475705.2016.1220023>
- Kavzoglu, T., Colkesen, I., Sahin, E. K. (2019). Machine learning techniques in landslide susceptibility mapping: a survey and a case study. *Landslides: Theory, practice and modeling*, 283-301. https://doi.org/10.1007/978-3-319-77377-3_13
- Kim, J. C., Lee, S., Jung, H. S., Lee, S. (2018). Landslide susceptibility mapping using random forest and boosted tree models in Pyeong-Chang, Korea. *Geocarto international*, 33(9), 1000-1015. <https://doi.org/10.1080/10106049.2017.1323964>
- Lacasse, S., Nadim, F. (2009). Landslide risk assessment and mitigation strategy. *Landslides–disaster risk reduction*, 31-61. https://doi.org/10.1007/978-3-540-69970-5_3
- Merghadi, A., Yunus, A.P., Dou, J., Whiteley, J., ThaiPham, B., Bui, D.T., Avtar, R. and 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>
- Moore, I. D., Burch, G. J. (1986). Sediment transport capacity of sheet and rill flow: application of unit stream power theory. *Water resources research*, 22(8), 1350-1360. https://ui.adsabs.harvard.edu/link_gateway/1986WRR....22.1350M/doi:10.1029/WR022i008p01350
- Nefeslioglu, H. A., Duman, T. Y., Durmaz, S. (2008). Landslide susceptibility mapping for a part of tectonic Kelkit Valley (Eastern Black Sea region of Turkey). *Geomorphology*, 94(3-4), 401-418. <https://doi.org/10.1016/j.geomorph.2006.10.036>
- Obuchowski, N.A., Bullen, J.A. (2018). Receiver operating characteristic (ROC) curves: review of methods with applications in diagnostic medicine. *Physics in Medicine & Biology*, 63(7), 07TR01. <https://doi.org/10.1088/1361-6560/aa84b>
- Reilly Shawn, J., DeGloria Stephen, D., Elliot Robert, A. (1999). Terrain Ruggedness Index That Quantifies Topographic Heterogeneity. *intermountain Journal of Science*, 5(1-4), 23-27.
- Robin, X., Turck, N., Hainard, A., Tiberti, N., Lisacek, F., Sanchez, J. C., Müller, M. (2011). pROC: an open-source package for R and S+ to analyze and compare ROC curves. *BMC Bioinformatics*, 12, 1-8. <https://doi.org/10.1186/1471-2105-12-77>
- Roccati, A., Faccini, F., Luino, F., Ciampalini, A., Turconi, L. (2019). Heavy rainfall triggering shallow landslides: A susceptibility assessment by a GIS-approach in a Ligurian Apennine Catchment (Italy). *Water*, 11(3), 605. <https://doi.org/10.3390/w11030605>
- Roy, P., Ghosal, K., Paul, P. K. (2022). Landslide susceptibility mapping of Kalimpong in Eastern Himalayan Region using a Rprop ANN approach. *Journal of Earth System Science*, 131(2), 130. <https://doi.org/10.1007/s12040-022-01877-2>
- Schmidt, J., Evans, I. S., Brinkmann, J. (2003). Comparison of polynomial models for land surface curvature calculation. *International Journal of Geographical Information Science*, 17(8), 797-814. <https://doi.org/10.1080/13658810310001596058>
- Selamat, S. N., Majid, N. A., Taha, M. R., Osman, A. (2022). Landslide susceptibility model using artificial neural network (ANN) approach in Langat river basin, Selangor, Malaysia. *Land*, 11(6), 833. <https://doi.org/10.3390/land11060833>
- Sihag, P., Singh, V. P., Angelaki, A., Kumar, V., Sepahvand, A., Golia, E. (2019). Modeling of infiltration using artificial intelligence techniques in semi-arid Iran. *Hydrological Sciences Journal*, 64(13), 1647-1658. <https://doi.org/10.1080/02626667.2019.1659965>
- Suhermat, M., Sugianti, K., Yunarto, Y., Kumoro, Y., Nur, W. H., Sukristiyanti, S., Lestiana, H. (2024). Effectiveness of Landslide Susceptibility Mapping Using the Maximum Entropy Model and Weights of Evidence Modelling in the Kuningan Regency, West Java, Indonesia. *Rudarsko-geološko-naftni zbornik*, 39(3), 27-42. <https://doi.org/10.17794/rgn.2024.3.3>
- Sun, D., Xu, J., Wen, H., Wang, Y. (2020). An optimized random forest model and its generalization ability in landslide susceptibility mapping: application in two areas of Three Gorges Reservoir, China. *Journal of Earth Science*, 31, 1068-1086. <https://doi.org/10.1007/s12583-020-1072-9>
- Weiss, A.D. (2001). Topographic Positions and Landforms Analysis, ESRI International User Conference, San Diego, CA, 3, 9-13.
- Yeon, Y.K., Han, J.G., Ryu, K.H. (2010). Landslide susceptibility mapping in Injae, Korea, using a decision tree. *Engineering Geology*, 116(3-4), 274-283. <https://doi.org/10.1016/j.enggeo.2010.09.009>.

References

References (in Persian)

- Darabi Shahmari, S., Saffari, A. (2019). Landslide susceptibility mapping of Dalahoo Mountains using index of Entropy and Logistic Regression model. *Journal of Spatial Analysis Environmental Hazards*, 6(2), 165-180. <http://jsah.knu.ac.ir/article-1-2401-fa.html>. [In Persian].
- Darvishi, Y., Moosavi nadoshan, S.M. (2023). Spatial analysis of landslide susceptibility in rural and urban areas using climatic and topographic indicators (Case study: boundaries of Gorgan city in Zarrin Gol watershed). *Geographical Engineering of Territory*, 7(2), 333-350. <https://doi.org/10.22034/jget.2023.147993>. [In Persian].
- Karami, F., Bayati Khatibi M., Kheirizadeh, M., Mokhtari Asl, A. (2020). Evaluation of Performance of Support Vector Machine Algorithm in Landslide Susceptibility Zoning in Ahar-chai Basin. *Journal of Geography and Environmental Hazards*, 8(4), 1-17. <https://doi.org/10.22067/geo.v8i4.83263> [In Persian].
- Sepahvand, A., Beiranvand, N. (2024). Landslide susceptibility mapping using various soft computing techniques (Case study: A part of Haraz Watershed). *Water and Soil Management and Modelling*, 4(2), 261-278. <https://doi.org/10.22098/mmws.2023.12678.1263> [In Persian].
- Tablebi, A., Nafarzadegan, A., Malekinezhad, H. (2010). A Review on Empirical and Physically Based Modelling of Rainfall Triggered Landslides. *Physical Geography Research*, 41(70), 45-64. https://jphgr.ut.ac.ir/article_21521.html?lang=fa. [In Persian].
- Zakerinejad, R., Kahrani, A. (2023). Assessment and Comparison of CART and TreeNet models to Landslide Susceptibility Mapping using SPM Software and Geographic Information System (GIS), (Case study: Kameh Watershed, Southern of Isfahan Province). *Journal of Natural Environmental Hazards*, 12(37), 17-38. <https://doi.org/10.22111/jneh.2023.42304.1904>. [In Persian]

References (in English)

- Abedin, J., Rabby, Y. W., Hasan, I., Akter, H. (2020). An investigation of the characteristics, causes, and consequences of June 13, 2017, landslides in Rangamati District Bangladesh. *Geoenvironmental Disasters*, 7, 1-19. <https://doi.org/10.1186/s40677-020-00161-z>
- Achu, A. L., Aju, C. D., Di Napoli, M., Prakash, P., Gopinath, G., Shaji, E., Chandra, V. (2023). Machine-learning-based landslide susceptibility modeling with emphasis on uncertainty analysis. *Geoscience Frontiers*, 14(6), 101657. <https://doi.org/10.1016/j.gsf.2023.101657>
- Ado, M., Amitab, K., Maji, A. K., Jasinska, E., Gono, R., Leonowicz, Z., Jasinski, M. (2022). Landslide susceptibility mapping using machine learning: A literature survey. *Remote Sensing*, 14(13), 3029. <https://doi.org/10.3390/rs14133029>
- Althuwaynee, O. F., Pradhan, B., Park, H. J., Lee, J. H. (2014). A novel ensemble bivariate statistical evidential belief function with knowledge-based analytical hierarchy process and multivariate statistical logistic regression for landslide susceptibility mapping. *Catena*, 114, 21-36. <https://doi.org/10.1016/j.catena.2013.10.011>
- Azrafza, M., Azrafza, M., Akgün, H., Atkinson, P. M., Derakhshani, R. (2021). Deep learning-based landslide susceptibility mapping. *Scientific reports*, 11(1), 24112. <https://doi.org/10.1038/s41598-021-03585-1>
- Beven, K. J., Kirkby, M. J. (1979). A physically based, variable contributing area model of basin hydrology/Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. *Hydrological Sciences Journal*, 24(1), 43-69. <https://doi.org/10.1080/02626667909491834>
- Bhardwaj, D., Sarkar, R. (2024). Landslide susceptibility mapping using probabilistic frequency ratio and Shannon entropy for Chamoli, Uttarakhand Himalayas. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 48(1), 377-395. <https://doi.org/10.1007/s40996-024-01509-3>
- Bogaart, P. W., Troch, P. A. (2006). Curvature distribution within hillslopes and catchments and its effect on the hydrological response. *Hydrology and Earth System Sciences*, 10(6), 925-936. <https://doi.org/10.5194/hess-10-925-2006>
- Carrión-Mero, P., Montalván-Burbano, N., Morante-Carballo, F., Quesada-Román, A., Apolo-Masache, B. (2021). Worldwide research trends in landslide science. *International journal of environmental research and public health*, 18(18), 9445. <https://doi.org/10.3390/ijerph18189445>
- Chu, L., Wang, L. J., Jiang, J., Liu, X., Sawada, K., & Zhang, J. (2019). Comparison of landslide susceptibility maps using random forest and multivariate adaptive regression spline models in combination with catchment map units. *Geosciences Journal*, 23, 341-355. <https://doi.org/10.1007/s12303-018-0038-8>
- Cortes, C., Vapnik, V. (1995). Support vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Cui, K., Lu, D., Li, W. (2017). Comparison of landslide susceptibility mapping based on statistical index, certainty factors, weights of evidence, and evidential belief function models. *Geocarto International*, 32(9), 935-955. <https://doi.org/10.1080/10106049.2016.1195886>
- Grabs, T., Seibert, J., Bishop, K., Laudon, H. (2009). Modeling spatial patterns of saturated areas: A comparison of the topographic wetness index and a dynamic distributed model. *Journal of Hydrology*, 373(1-2), 15-23. <https://doi.org/10.1016/j.jhydrol.2009.03.031>

- Gray, D. H., Sotir, R. B. (1996). Biotechnical and soil bioengineering slope stabilization: a practical guide for erosion control. John Wiley & Sons. 400 pages.
- Habumugisha, J. M., Chen, N., Rahman, M., Islam, M. M., Ahmad, H., Elbeltagi, A., Sharma, G., Liza, S.N. and Dewan, A. (2022). Landslide susceptibility mapping with deep learning algorithms. *Sustainability*, 14(3), 1734. <https://doi.org/10.3390/su14031734>
- Haque, U., Da Silva, P.F., Devoli, G., Pilz, J., Zhao, B., Khaloua, A., Wilopo, W., Andersen, P., Lu, P., Lee, J. and Yamamoto, T. (2019). The human cost of global warming: Deadly landslides and their triggers (1995–2014). *Science of the Total Environment*, 682, 673-684. <https://doi.org/10.1016/j.scitotenv.2019.03.415>
- Hemasinghe, H., Rangali, R.S.S., Deshapriya, N. L., Samarakoon, L. (2018). Landslide susceptibility mapping using logistic regression model (a case study in Badulla District, Sri Lanka). *Procedia Engineering*, 212, 1046-1053. <https://doi.org/10.1016/j.proeng.2018.01.135>
- Hong, H., Liu, J., Bui, D.T., Pradhan, B., Acharya, T.D., Pham, B.T., Zhu, A.X., Chen, W. and Ahmad, B.B. (2018). Landslide susceptibility mapping using J48 Decision Tree with AdaBoost, Bagging, and Rotation Forest ensembles in the Guangchang area (China). *Catena*, 163, 399-413. <https://doi.org/10.1016/j.catena.2018.01.005>
- Huang, W., Ding, M., Li, Z., Zhuang, J., Yang, J., Li, X., Meng, L.E., Zhang, H., Dong, Y. (2022). An efficient user-friendly integration tool for landslide susceptibility mapping based on support vector machines: SVM-LSM toolbox. *Remote Sensing*, 14(14), 3408. <https://doi.org/10.3390/rs14143408>
- Juliev, M., Mergili, M., Mondal, I., Nurtaev, B., Pulatov, A., Hübl, J. (2019). Comparative analysis of statistical methods for landslide susceptibility mapping in the Bostanlik District, Uzbekistan. *Science of the total environment*, 653, 801-814. <https://doi.org/10.1016/j.scitotenv.2018.10.431>
- Kanwal, S., Atif, S., Shafiq, M. (2017). GIS-based landslide susceptibility mapping of northern areas of Pakistan, a case study of Shigar and Shyok Basins. *Geomatics, Natural Hazards and Risk*, 8(2), 348-366. <https://doi.org/10.1080/19475705.2016.1220023>
- Kavzoglu, T., Colkesen, I., Sahin, E. K. (2019). Machine learning techniques in landslide susceptibility mapping: a survey and a case study. *Landslides: Theory, practice and modeling*, 283-301. https://doi.org/10.1007/978-3-319-77377-3_13
- Kim, J. C., Lee, S., Jung, H. S., Lee, S. (2018). Landslide susceptibility mapping using random forest and boosted tree models in Pyeong-Chang, Korea. *Geocarto international*, 33(9), 1000-1015. <https://doi.org/10.1080/10106049.2017.1323964>
- Lacasse, S., Nadim, F. (2009). Landslide risk assessment and mitigation strategy. *Landslides–disaster risk reduction*, 31-61. https://doi.org/10.1007/978-3-540-69970-5_3
- Merghadi, A., Yunus, A.P., Dou, J., Whiteley, J., ThaiPham, B., Bui, D.T., Avtar, R. and 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>
- Moore, I. D., Burch, G. J. (1986). Sediment transport capacity of sheet and rill flow: application of unit stream power theory. *Water resources research*, 22(8), 1350-1360. https://ui.adsabs.harvard.edu/link_gateway/1986WRR....22.1350M/doi:10.1029/WR022i008p01350
- Nefeslioglu, H. A., Duman, T. Y., Durmaz, S. (2008). Landslide susceptibility mapping for a part of tectonic Kelkit Valley (Eastern Black Sea region of Turkey). *Geomorphology*, 94(3-4), 401-418. <https://doi.org/10.1016/j.geomorph.2006.10.036>
- Obuchowski, N.A., Bullen, J.A. (2018). Receiver operating characteristic (ROC) curves: review of methods with applications in diagnostic medicine. *Physics in Medicine & Biology*, 63(7), 07TR01. <https://doi.org/10.1088/1361-6560/aab4b>
- Reily Shawn, J., DeGloria Stephen, D., Elliot Robert, A. (1999). Terrain Ruggedness Index That Quantifies Topographic Heterogeneity. *intermountain Journal of Science*, 5(1-4), 23-27.
- Robin, X., Turck, N., Hainard, A., Tiberti, N., Lisacek, F., Sanchez, J. C., Müller, M. (2011). pROC: an open-source package for R and S+ to analyze and compare ROC curves. *BMC Bioinformatics*, 12, 1-8. <https://doi.org/10.1186/1471-2105-12-77>
- Roccati, A., Faccini, F., Luino, F., Ciampalini, A., Turconi, L. (2019). Heavy rainfall triggering shallow landslides: A susceptibility assessment by a GIS-approach in a Ligurian Apennine Catchment (Italy). *Water*, 11(3), 605. <https://doi.org/10.3390/w11030605>
- Roy, P., Ghosal, K., Paul, P. K. (2022). Landslide susceptibility mapping of Kalimpong in Eastern Himalayan Region using a Rprop ANN approach. *Journal of Earth System Science*, 131(2), 130. <https://doi.org/10.1007/s12040-022-01877-2>
- Schmidt, J., Evans, I. S., Brinkmann, J. (2003). Comparison of polynomial models for land surface curvature calculation. *International Journal of Geographical Information Science*, 17(8), 797-814. <https://doi.org/10.1080/13658810310001596058>
- Selamat, S. N., Majid, N. A., Taha, M. R., Osman, A. (2022). Landslide susceptibility model using artificial neural network (ANN) approach in Langat river basin, Selangor, Malaysia. *Land*, 11(6), 833. <https://doi.org/10.3390/land11060833>
- Sihag, P., Singh, V. P., Angelaki, A., Kumar, V., Sepahvand, A., Golia, E. (2019). Modeling of infiltration using artificial intelligence techniques in semi-arid Iran. *Hydrological Sciences Journal*, 64(13), 1647-1658. <https://doi.org/10.1080/02626667.2019.1659965>
- Suhermat, M., Sugianti, K., Yunarto, Y., Kumoro, Y., Nur, W. H., Sukristiyanti, S., Lestiana, H. (2024). Effectiveness of Landslide Susceptibility Mapping Using the Maximum Entropy Model and Weights of Evidence Modelling in the Kuningan Regency, West Java, Indonesia. *Rudarsko-geološko-naftni zbornik*, 39(3), 27-42. <https://doi.org/10.17794/rgn.2024.3.3>
- Sun, D., Xu, J., Wen, H., Wang, Y. (2020). An optimized random forest model and its generalization ability in landslide susceptibility mapping: application in two areas of Three Gorges Reservoir, China. *Journal of Earth Science*, 31, 1068-1086. <https://doi.org/10.1007/s12583-020-1072-9>
- Weiss, A.D. (2001). Topographic Positions and Landforms Analysis, ESRI International User Conference, San Diego, CA, 3, 9-13.

Yeon, Y.K., Han, J.G., Ryu, K.H. (2010). Landslide susceptibility mapping in Injae, Korea, using a decision tree. Engineering Geology, 116(3-4), 274-283. <https://doi.org/10.1016/j.enggeo.2010.09.009>.

