

Predicting flood-prone areas using generalized linear and maximum entropy machine learning models

Abdulaziz Hanifinia¹, Hiran Abghari^{2*} 

1. PH.D. Student of Watershed Management, Urmia University, Iran

2. *Corresponding Author*, Associate Professor, Department of Range and Watershed Management, Urmia University, Iran

Article Info

Article type:

Research Article

Article history:

Received: 14 January 2024

Revised: 13 May 2024

Accepted: 08 June 2024

Keywords:

flood, Geographic Information System, SAGA-GIS, ROC curve, Lake Urmia.

ABSTRACT

The purpose of this study is to identify the effective factors, prepare flood risk prediction maps using machine learning models, and finally evaluate the efficiency of these models in the Zive watershed of Urmia. For this purpose, environmental and human factors including morphometric indices; Waterway Power Index (SPI), Slope Length Index (LS), Topographic Wetness Index (TWI), Topographic Position Index (TPI), Land Roughness Index (TRI), Mass Balance Index (MBI), Profile Curvature Index and The surface curvature index (Plan Curvature), rainfall, basin height, slope degree, slope direction, lithology, land use, normalized difference index of vegetation cover (NDVI), distance from waterway, distance from village and distance from fault were used. For this purpose, 96 flood spots were identified in the basin by using field visits and Google Earth images and sources received from the offices. Layers related to morphometric indices from the digital height model (12.5 x 12.5) meters and in the SAGA_GIS environment; And maps of environmental and human factors were prepared and digitized in the ArcGIS geographic information system. The evaluation results of two models using the ROC curve for machine learning (ML) models showed that the maximum entropy model with AUC=0.916 and the generalized linear model with AUC=0.902 have excellent performance in the field. The results of the Kappa index for the superior model showed that environmental factors including geology, distance from waterways, height and slope have the greatest impact and the least impact related to profile curvature index factors. , land use, and mass balance index. Identifying high-risk areas and determining factors affecting the occurrence of floods in this basin can be very efficient in reducing possible damages.

Cite this article: Hanifinia, A., & Abghari, H. (2025). Predicting flood prone areas using generalized linear and maximum entropy machine learning models. *Journal of Natural Environmental Hazards*, 14(43), 19-34. DOI: 10.22111/jneh.2024.47730.2021



© Hiran Abghari

Publisher: University of Sistan and Baluchestan

DOI: 10.22111/jneh.2024.47730.2021

* Corresponding Author Email: h.abghari@urmia.ac.ir

مجله علمی پژوهشی مخاطرات محیط طبیعی، دوره ۱۴، شماره ۴۳، پیاپی ۱، بهار ۱۴۰۴

پیش‌بینی مناطق مستعد سیل با استفاده از مدل‌های یادگیری ماشین خطی

تعمیم‌یافته و بیشینه آنتروپی

عبدالعزیز حنیفی‌نیا^۱، هیراد عبقری^{۲*} 

۱. دانشجوی دکترای مدیریت حوزه‌های آبخیز، دانشگاه ارومیه

۲. دانشیار، گروه مرتع و آبخیزداری، دانشگاه ارومیه (نویسنده مسئول)

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	هدف این مطالعه، شناسایی عوامل موثر، تهیه نقشه‌های پیش‌بینی خطرات سیل با استفاده از مدل‌های یادگیری ماشین و در انتها ارزیابی کارایی این مدل‌ها در حوزه آبخیز زیوه ارومیه می‌باشد. برای این منظور از عوامل محیطی و انسانی شامل شاخص‌های مورفومتری، شاخص توان آبراهه (SPI)، شاخص طول شیب (LS)، شاخص خیزی توپوگرافی (TWI)، شاخص موقعیت توپوگرافی (TPI)، شاخص ناهمواری زمین (TRI)، شاخص تعادل جرم (MBI)، شاخص انحنا ی پروفیل (Profile Curvature) و شاخص انحنا ی سطح (Plan Curvature)، بارندگی، ارتفاع حوضه، درجه شیب، جهت شیب، لیتولوژی، کاربری اراضی، شاخص تفاضل نرمال شده پوشش گیاهی (NDVI)، فاصله از آبراهه، فاصله از روستا و فاصله از گسل استفاده شد. برای این منظور با استفاده از بازدهی‌های میدانی و تصاویر گوگل ارث و منابع دریافتی از ادارات، تعداد ۹۶ نقطه سیل در حوضه شناسایی شدند. لایه‌های مربوط به شاخص‌های مورفومتری از مدل رقومی ارتفاعی (۱۲/۵×۱۲/۵) متر و در محیط SAGA_GIS و نقشه‌های عوامل محیطی و انسانی در سامانه اطلاعات جغرافیایی ArcGIS تهیه و رقومی شدند. نتایج ارزیابی دو مدل با استفاده از منحنی ROC برای مدل‌های یادگیری ماشین (ML) نشان داد که مدل بیشینه آنتروپی با $AUC = 0.916$ و مدل خطی تعمیم‌یافته با $AUC = 0.902$ دارای عملکرد عالی در پهنه‌بندی حساسیت محدوده مطالعاتی به سیلاب بوده‌اند. همچنین نتایج حاصل از شاخص کاپا برای مدل برتر نشان داد که عوامل محیطی شامل زمین‌شناسی، فاصله از آبراهه، ارتفاع و شیب بیشترین تاثیر و کمترین تاثیر مربوط به عامل‌های شاخص انحنا ی پروفیل، کاربری اراضی و شاخص تعادل جرم بوده است. شناسایی مناطق پر خطر و تعیین عوامل موثر بر رخداد سیلاب‌ها در این حوضه در امر کاهش خسارت‌های احتمالی می‌تواند بسیار کارآمد باشد.

استناد: حنیفی‌نیا، عبدالعزیز، عبقری، هیراد. (۱۴۰۴). پیش‌بینی مناطق مستعد سیل با استفاده از مدل‌های یادگیری ماشین خطی تعمیم‌یافته و

بیشینه آنتروپی. مخاطرات محیط طبیعی، ۱۴(۴۳)، ۱۹-۳۴. DOI: 10.22111/jneh.2024.47730.2021



© عبدالعزیز حنیفی‌نیا، هیراد عبقری*

ناشر: دانشگاه سیستان و بلوچستان

مقدمه

سیل به عنوان یکی از پدیده‌های مهم به لحاظ ایجاد مخاطرات طبیعی در سراسر جهان شناخته می‌شود. یک سیل ناگهانی ناشی از یک بارندگی سریع و بیش از توان و ظرفیت محل عبور آن است که به سرعت ارتفاع آب افزایش می‌یابد و ممکن است به بستر یا کناره‌های مسیر حرکت خود آسیب برساند.

در حالت کلی، دو عامل اصلی و مهم وجود دارد که می‌تواند شدت و حجم سیلاب را تحت تاثیر خود قرار دهد. فعالیت‌های انسانی (تغییر در پوشش تراکم و نوع پوشش زمین (جایگزین شدن گیاهان یکساله)، تغییرات کاربری اراضی و الگوی کشت) از طریق تاثیر بر الگوی بارش می‌تواند شدت و حجم سیلاب را افزایش دهد (اسماعیلی و طاهری، ۱۴۰۱ و هیرابایاشی^۱ و همکاران، ۲۰۱۳). علاوه بر آن عامل تغییرات آب و هوایی است نیز یک عامل بسیار مهم است که تغییرات آن با افزایش رخداد سیلاب‌های آبی و در نتیجه روند صعودی شدت بارندگی و فرکانس سیلاب همراه می‌شود (عابدینی و همکاران، ۱۳۹۸ و تبری^۲، ۲۰۲۰).

سیلاب هر ساله خسارت‌های مالی بسیار زیادی را به منابع موجود در یک کشور می‌رساند. پیش‌بینی‌ها نشان داده‌اند که وقوع و شدت سیل احتمالاً باعث خسارت‌های مالی تا حدود یک تریلیون دلار آمریکا در سال تا سال ۲۰۵۰ خواهد شد (هانگ^۳ و همکاران، ۲۰۱۹). خسارت‌های جانی سیلاب در سال‌های اخیر در دنیا به بیش از ۵۰۰۰ کشته در سال می‌رسد (ال-راوی^۴ و همکاران، ۲۰۲۳). در بین سال‌های ۲۰۰۰-۲۰۱۹ تعداد ۷۳۴۸ واقعه از بلایای طبیعی در سراسر جهان اتفاق افتاد که زندگی ۹/۳ میلیارد نفر را تحت تاثیر و در طی آن ۲۳/۱ میلیون نفر جان خود را از دست دادند. از این تعداد اغلب مرگ و میر حدود ۷۰ درصد آن مربوط به مناطقی از سطح جهان می‌شود که دارای مورفولوژی کوهستانی هستند (UNDRR, 2020) که یکی از شایع‌ترین خطرات طبیعی در مناطق کوهستانی همین پدیده سیلاب است. علت بالا بودن خطر وقوع سیل و به طبع آن تعداد بالای وقوع این پدیده در مناطق کوهستانی، فراهم بودن شرایط مستعدکننده از جمله ویژگی‌هایی مانند سنگ‌شناسی، ارتفاع، شیب، آب و هوا و خصوصیت‌های فیزیوگرافی متفاوت می‌باشد (بینگ^۵ و همکاران، ۲۰۲۱). از آنجایی که در طی ۲۰ سال گذشته جمعیت جهان در مناطق کوهستانی به ۱۷۰ میلیون نفر رسیده است (ارلیخ^۶ و همکاران، ۲۰۲۱)، بنابراین ضرورت توجه به بلایای طبیعی که مربوط به مناطق کوهستانی مانند سیل می‌شوند، بیشتر خود را نمایان می‌کند.

کشور ایران یکی از بلاخیزترین کشورهای آسیایی به دلیل دارا بودن توپوگرافی کوهستانی، فعالیت دوره‌های زمین‌ساختی و توان لرزه‌خیزی بالا، تنوع اقلیمی، افزایش جمعیت و فعالیت‌های انسانی می‌باشد. به طوری که ۷/۳۱ درصد از کل مساحت کشور ایران دارای مناطق پرخطر برای بلایای طبیعی است (حسن زاده و همکاران، ۱۴۰۰). علاوه بر آن حدود ۷۰ درصد جمعیت کشور در مناطق با توپوگرافی کوهستانی ساکن هستند. بین سال‌های ۱۹۸۵-۲۰۱۵، گروه مدیریت بلایای طبیعی سازمان ملل متحد (UNDM^۷) برای کشور ایران ۱۴۶ واقعه سیل را گزارش کرده است که در اثر آن بیش از ۷۰ هزار نفر جان خود را از دست دادند. بر اساس گزارش وزارت بهداشت کشور ایران، به-

1 Hirabayashi

2 Tabari

3 Huang

4 El-Rawy

5 Baig

6 Ehrlich

7 United Nations Natural Disaster Management

طور متوسط در دهه‌های اخیر رخداد بلایای طبیعی بلاخص سیلاب سبب مرگ حدود ۲۹۰۰ نفر و زندگی یک میلیون و ۵۰۰ هزار ایرانی را تحت تاثیر قرار داده است (وزارت بهداشت، آموزش و درمان پزشکی، ۱۴۰۱). شناخت عوامل موثر بر رخداد سیلاب و مدل‌سازی فضایی سیل در مقیاس حوزه آبخیز، یک ابزار مهم برای درک و مدیریت سیل است که می‌تواند در به حداقل رساندن آسیب سیل و اجرای اقدامات مناسب کمک کند (تین بوی^۱ و همکاران، ۲۰۱۹). در سراسر جهان هیچ استاندارد برای تعیین تعداد عوامل انتخاب عوامل دخیل در مخاطرات طبیعی وجود ندارد و این خطرات در هر حوضه‌ای به شرایطی که بر آن حوضه حاکم است بستگی دارد؛ اما در حالت کلی به سه دسته عوامل انسانی، عوامل طبیعی و شاخص‌های مورفومتری تقسیم‌بندی می‌کنند. در این پژوهش از هر سه نوع این عوامل در نظر گرفته شده است.

به‌طور کلی مدل‌های مورد استفاده در مباحث مربوط به مخاطرات طبیعی (سیلاب، لغزش و غیره) را به چهار دسته مدل‌های نظری (مبتنی بر نظر کارشناسی)، مدل‌های آماری، مدل‌های داده‌کاوی، مدل‌های یادگیری ماشینی و مدل‌های ترکیبی تقسیم بندی می‌کنند. مدل‌های مبتنی بر نظرات کارشناسی، مدل‌های آماری سنتی و روش‌های تصمیم‌گیری چندمعیاره به‌دلیل متکی بودن بر فرضیات آماری و مدل‌سازی خطی پدیده‌ها و همچنین داشتن ماهیت غیرخطی در پهنه‌بندی حوادث طبیعی مانند سیل به چالش کشیده شده‌اند (حنیفی‌نیا و همکاران، ۱۳۹۹). در مقابل، الگوریتم‌های مبتنی بر GIS و یادگیری ماشین (ML^۲) در حال حاضر جایگزین خوبی برای تولید نقشه‌های خطر سیلاب استفاده می‌شود (پناهی و همکاران، ۲۰۲۱). ماهیت غیرخطی بودن رویدادهای طبیعی مانند سیل توسط این الگوریتم‌ها می‌تواند در کل یک حوزه آبخیز به خوبی پوشش داده می‌شود. با توجه به ابعاد بالای داده‌ها و تعداد زیادی نمونه مورد نیاز برای آموزش بهینه ML، پیچیدگی پردازش داده‌ها به‌طور چشمگیری افزایش می‌یابد، منتهی از سوی دیگر به بهبود دقت و صحت نتایج کمک شایانی می‌کند. علاوه بر آن توانایی استخراج موثر رویدادهای گذشته بدون نیاز به درک مباحث فیزیکی از دیگر مزایای این مدل‌ها می‌باشد (حنیفی‌نیا و نظرنژاد، ۱۴۰۰). از محبوب‌ترین مدل‌های ماشینی در پژوهش‌های مربوط به مخاطرات طبیعی می‌توان به مدل خطی تعمیم‌یافته (سها^۳ و همکاران، ۲۰۲۲؛ موسوی^۴ و همکاران، ۲۰۲۲ و یوسف^۵ و همکاران، ۲۰۲۲)، مدل الگوریتم ماشین پشتیبان بردار (تیموری و همکاران، ۱۴۰۲ و یوسف و همکاران، ۲۰۲۳)، مدل شبکه عصبی مصنوعی (بختیاری و جهان‌تاب، ۱۴۰۱؛ خو^۶ و همکاران، ۲۰۲۳ و اسلام^۷ و همکاران، ۲۰۲۳)، مدل بیشینه آنتروپی (دسترنج و سنگچینی، ۱۴۰۲ و بوصوف^۸ و همکاران، ۲۰۲۳) و بسیاری دیگر از مدل‌های از نوع اشاره کرد. انعطاف پذیری بالا، بهره‌گیری کامل از داده‌های موجود و مدل‌سازی بهتر داده‌های پیچیده و غیرخطی در مدل بیشینه آنتروپی و برای مدل خطی تعمیم‌یافته نیز مزایایی چون تعمیم‌پذیری، تفسیرپذیری و سرعت بالای داده‌های آموزشی و اعتبارسنجی منجر شد که از این مدل‌ها به منظور تهیه نقشه خطر سیلاب در حوزه آبخیز زیوه استفاده بشود.

1 Tien Bui

2 Machine Learning

3 Saha

4 Mosavi

5 Youssef

6 Xu

7 Islam


8 Boussouf

وجود عوامل مستعدکننده وقوع سیل در حوزه آبخیز زیوه مانند خصوصیت‌های هیدرولوژیک (مسئله تراکم بالای آبراهه‌ها)، تکتونیک (وجود گسل‌های فراوان)، توپوگرافی (داشتن آب و هوای نیمه‌مرطوب سرد به همراه شیب تند، وجود ناهمواری‌های زیاد)، زمین‌شناسی (آسیب‌پذیری بخش بزرگی از سازندهای زمین‌شناسی منطقه) آمیزه‌های افیولیتی و آهک‌های پلاژیک و عوامل انسانی نظیر تغییر کاربری اراضی و چرای بی‌رویه و زودرس (کاهش تراکم پوشش گیاهی) سبب سیر صعودی رخداد و افزایش خسارت‌های محسوس و غیرمحسوس در این محدوده شده است. در حال حاضر وقوع سیلاب به‌عنوان یکی از چالش‌های اصلی و اساسی در این حوضه مطرح می‌باشد. با رخداد‌های مکرر سالانه این پدیده در مراتع، مزارع کشاورزی و حتی باغات هزینه‌های بسیار زیادی را برای ترمیم مناطق آسیب دیده (جاده‌ها، لایه‌روبی مناطق مملو شده از رسوبات، جمع‌آوری سنگ و سنگریزه در مناطق کشاورزی اطراف رودخانه‌های اصلی و بازسازی مجدد خانه‌ها و دامداری‌های آسیب دیده) و خسارت‌های بسیار زیادی را متحمل می‌شوند. به‌علت کوهستانی بودن حوضه انتظار می‌رود که عوامل شیب، ارتفاع، آبراهه و ویژگی‌های مربوط به زمین جزء عامل‌های موثر در رخداد سیلاب‌ها باشند. هرساله این حوضه در بهار و پاییز شاهد رخداد سیلاب‌های کوچک و بزرگی هست که اگر همراه با رخداد سایر پدیده‌ها مانند لغزش‌های کنار رودخانه‌ای و فرسایش خندقی باشد، قدرت تخریب چندین برابر افزایش می‌یابد. بنابراین، شناخت عوامل موثر و توسعه نقشه‌های مناطق حساس به وقوع در امر پیش‌بینی و مدیریت این پدیده جهت انجام اقدامات اصلاحی و پیشگیرانه ضرورت پیدا می‌کند. هدف اصلی در این پژوهش تهیه نقشه پهنه‌بندی مناطق پر خطر ناشی از سیل و وقوع سیلاب و اهداف فرعی آن شامل شناسایی موثرترین عوامل دخیل در این پدیده با استفاده از الگوریتم قدرتمند یادگیری ماشین با بررسی شاخص کاپا و در انتها ارزیابی میزان دقت و صحت این مدل‌ها مدنظر می‌باشد.

داده‌ها و روش‌ها

منطقه مورد مطالعه

حوضه آبخیز زیوه واقع در استان آذربایجان غربی با مساحتی بالغ بر ۲۱۶۸۶ هکتار در جنوب غربی شهرستان ارومیه و در بخش مرگور سیلوانه قرار دارد. حوضه آبخیز زیوه یکی از حوضه‌های مرزی است که ارتفاعات کوه دالانیر و بز سینا را در بین دو کشور ترکیه و عراق به خود اختصاص داده است. رودخانه خروجی از این حوضه با نام رودخانه هاشم آباد شناخته می‌شود. این رودخانه پس از اتصال با رودخانه بزرگ باراندوزچای که یکی از سرشاخه‌های اصلی حوضه مطالعه است، به دریاچه ارومیه می‌ریزد. بنابراین، حوضه آبخیز زیوه نقش مهمی در تغذیه آب دریاچه ارومیه دارد. ارتفاع میانی حوضه زیوه حدود ۲۲۶۵ متر است و حداقل ارتفاع آن ۱۵۰۰ متر و حداکثر ارتفاع آن ۳۴۷۹ متر است. شیب متوسط حوضه زیوه حدود ۱۶/۵ درجه است. بر اساس آمار ایستگاه‌های مجاور حوضه، بارش سالیانه متوسط در این منطقه حدود ۳۹۵ میلی‌متر تخمین زده شده است. با توجه به وجود کوهستان‌ها در حوضه زیوه، بخش عمده این منطقه مراتع است و بخش‌های شمالی حوضه که نزدیک به روستاها و دارای زمین‌های مسطح و هموارتر هستند، به کشاورزی اختصاص یافته‌اند. در تقسیم‌بندی زون‌های زمین‌شناسی، حوضه آبخیز زیوه در زون سنندج - سیرجان قرار دارد (حنیفی‌نیا و عبقری، ۱۴۰۱).




شکل ۱: موقعیت جغرافیایی حوزه آبخیز زیوه در تقسیمات کشوری. منبع: نگارندگان

گردآوری نقاط سیلاب و تهیه لایه‌های عوامل موثر بر خطر سیلاب

با استفاده از جی پی اس (GPS)، از طریق پیمایش میدانی و مشاهده مستقیم مناطق سیل‌زده بر اساس شواهد موجود و آمار سیلاب اداره منابع طبیعی شهرستان ارومیه، محل وقوع تعداد ۹۶ نقطه سیلابی ثبت گردید. در نهایت لایه پراکنش نقاط لغزشی در ArcGIS تهیه گردید. در یک بررسی اجمالی از منابع اثرگذار بر رخداد سیل در منابع و پژوهش‌های گذشته مشخص شد که عوامل مختلفی از جمله زمین‌شناسی، تکتونیک توپوگرافی و ژئومورفولوژی، هواشناسی، هیدرولوژی، پوشش گیاهی و تأثیرات انسانی تأثیر می‌گذارند. با بازدیدهای صورت‌گرفته از محدوده مطالعاتی، مهم‌ترین عوامل موثر بر رخداد سیل‌ها (عوامل محیطی و انسانی) شناسایی و لایه‌های اطلاعاتی آنان استخراج شد. نقشه مدل رقومی ارتفاعی با قدرت تفکیک ۱۲/۵ متر از سایت دانشگاه آلاسکا دانلود و لایه‌های اطلاعاتی ارتفاع، درجه شیب، جهت شیب و فاصله از آبراهه در سیستم اطلاعات جغرافیایی تنظیم گردید. همچنین از مدل رقومی ارتفاعی برای تهیه لایه‌های مربوط به شاخص‌های مورفومتری استفاده گردید. لایه بارندگی به‌علت نبود ایستگاه باران‌سنجی از ۱۳ ایستگاه اطراف حوزه از طریق درون‌یابی با روش کریجینگ ساده استخراج شد. لایه کاربری اراضی با استفاده از تصاویر بروز شده سال ۲۰۲۲ تهیه گردید. به منظور تهیه لایه لیتولوژی و فاصله از گسل‌ها از نقشه توپوگرافی ۱:۱۰۰۰۰۰ برگه سیلوانه استفاده شد. لایه فاصله از روستا از مدل رقومی ارتفاعی و لایه روستاهای منطقه به وسیله نرم‌افزار Google Earth آماده گردید. لایه شاخص تفاوت نرمال‌شده پوشش گیاهی (NDVI) از

تصاویر Sentinel_2 خرداد ماه استخراج گردید. نقشه لایه‌هایی که در این پژوهش مورد استفاده قرار می‌گیرند در شکل (۲) تنظیم شده‌اند.



شکل ۲: نقشه‌های عوامل موثر بر رخداد سیلاب در حوزه آبخیز زیوه ارومیه. منبع: نگارندگان

لایه شاخص‌های مورفومتری مورد استفاده در این مطالعه به منظور پهنه‌بندی مخاطره سیل عبارتند از: شاخص طول شیب (LS)، این فاکتور بر روی لایه‌های خاک و فاکتورهای توپوگرافی مانند درصد و زاویه شیب تاثیر می‌گذارد که در نتیجه آن میزان فرسایش خاک افزایش می‌یابد. شاخص تعادل جرم (MBI)، بیان‌کننده تعادل رسوب (شاخص‌های منفی) و رهاسازی توده یا حجم خاک (شاخص‌های مثبت) در دامنه‌ها است. بنابراین، افزایش یا کاهش این فاکتور می‌تواند بر میزان جابه‌جایی خاک تاثیر مستقیم داشته باشد (عرب‌عامری و همکاران، ۱۳۹۷). اگر مقادیر نزدیک صفر باشد، تعادل بین رسوب و توده خاک برقرار است و در این حالت میزان فرسایش توده به حداقل خود می‌رسد (مولر^۱ و همکاران، ۲۰۰۸)، شاخص خیسی (TWI^۲)، این شاخص بیان‌کننده مقدار آب موجود در توده خاک است که افزایش این آب سبب کاهش درصد نفوذ و در نتیجه افزایش حجم آب جاری‌شده از سطح دامنه می‌شود (حنیفی‌نیا و عبقری، ۱۴۰۱). شاخص ناهمواری زمین زبری سطح (TRI^۳)، از طریق در نظر گرفتن یک سلول مرکزی و محاسبه ارتفاع هشت سلول اطراف، مقادیر را کمی می‌کند و از این طریق به میزان فرسایش و رسوب در این سلول‌ها پی برده می‌شود (آناند^۴ و همکاران، ۲۰۲۳). شاخص موقعیت توپوگرافی (TPI^۵)، الگوریتمی است که به‌طور فزاینده‌ای برای اندازه‌گیری موقعیت‌های شیب توپوگرافی استفاده می‌شود. این شاخص ارتفاع هر سلول را نسبت به ارتفاع میانگین سلول‌های مجاور در یک پهنه مشخص مقایسه می‌نماید (دریو^۶ و همکاران، ۲۰۱۳). انحنای پلان (Plan_Cu) به‌عنوان انحنای یک خط که از تقاطع یک صفحه افقی با سطح تشکیل شده، تعریف می‌شود. این عامل فرآیندهای تخریب زمین، همگرایی یا واگرایی آب در جریان را تحت تاثیر قرار می‌دهد (خسروی^۷ و همکاران، ۲۰۲۰). انحنای پروفیل (Profile_Cu) شتاب یا افت جریان را کنترل و بر حرکت رسوبات اثر می‌گذارد. فرسایش در مقادیر منفی و رسوب‌گذاری در مقادیر مثبت انجام این شاخص صورت می‌گیرد (حنیفی‌نیا و نظرزاد، ۱۴۰۰). شاخص توان آبراهه (SPI^۸)، منعکس‌کننده نیم‌رخ عرضی و نیم‌رخ طولی آبراهه با نشان دادن نسبت بین مساحت یک نقطه و شیب زمین در بالادست است. می‌تواند بیانگر نقاط تجمع و رسوب‌گذاری در حوضه آبخیز باشد (شهابی^۹ و همکاران، ۲۰۱۴). نقشه شاخص‌های مورفومتری از روی لایه مدل رقومی ارتفاعی (۱۲/۵*۱۲/۵) در نرم‌افزار SAGA-GIS تهیه گردید. تمامی فاکتورهای در نظر گرفته‌شده به‌صورت یک لایه ASCII برای اجرای مدل‌ها وارد نرم‌افزار ModEco شدند.

مدل‌های یادگیری ماشین

مدل‌های یادگیری ماشین، الگوریتم‌ها و مدل‌های محاسباتی هستند که براساس داده‌های ورودی آموزشی، قادر به یادگیری الگوها و انجام پیش‌بینی‌ها و تصمیم‌گیری‌های هوشمندانه هستند (فام^{۱۰} و همکاران، ۲۰۲۱). این مدل‌ها به‌صورت خودکار و بدون نیاز به برنامه‌نویسی صریح، از داده‌ها الگوها و قوانینی برای انجام وظایفی مانند تشخیص

1 Möller

2 Topographic Wetness Index

3 Terrain Ruggedness Index

4 Anand

5 Topographic Position Index

6 De Reu

7 Khosravi

8 Stream Power Index

9 Shahabi

10 Pham

الگو، تصمیم‌گیری، تصویربرداری و پیش‌بینی استخراج می‌کنند (یوسف و همکاران، ۲۰۲۲؛ ها^۱ و همکاران، ۲۰۲۱؛ ریاضی^۲ و همکاران، ۲۰۲۳). با هدف انجام این پژوهش، از دو مدل بیشینه آنتروپی و مدل خطی تصمیم‌یافته استفاده خواهد شد. برای این منظور بعد از آماده‌سازی لایه‌های اطلاعاتی و جمع‌آوری نقاط رخداد سیلاب، لایه نقاط حضور و عدم حضور سیلاب در نرم‌افزار ArcGIG تهیه گردید. تجزیه و تحلیل داده‌ها، تهیه نقشه‌های سیلاب و بررسی میزان تاثیر هر عامل با استفاده از نرم‌افزار ModEco انجام شد.

مدل خطی تصمیم‌یافته

مدل خطی تصمیم‌یافته توسط نلدر و و دربرن به‌عنوان راهی برای یکسان‌سازی مدل‌های آماری از جمله رگرسیون خطی، رگرسیون لجستیک و رگرسیون پواسون استفاده گردید (موسوی و همکاران، ۲۰۱۳). مدل خطی تصمیم‌یافته به دنبال ایجاد یک رگرسیون خطی ساده بین مکان‌های وقوع یک پدیده و متغیرهای موثر از طریق یک تابع پیوند است (آوند^۳ و همکاران، ۲۰۲۲). مدل خطی تصمیم‌یافته یک روش پارامتری با مفروضات محدود و قابل بحث است که برای پیش‌بینی‌کننده‌های غیرخطی مناسب است و بیشتر برای داده‌هایی که توزیع نرمال ندارند، مورد استفاده قرار می‌گیرد. از آنجایی که وقوع سیلاب‌ها به صورت کاملاً تصادفی و در مکان‌هایی با شرایط خاص رخ می‌دهد، بنابراین نرمال بودن داده‌ها در این پدیده قریب به وقوع می‌باشد. بنابراین این مدل می‌تواند در مباحث مربوط به بلایای طبیعی نتایج قابل قبولی را ارائه کند. جزئیات بیشتر این مدل در مقاله (ویلیس^۴ و همکاران، ۲۰۱۴) ارائه شده است. مدل خطی تصمیم‌یافته شامل سه مرحله می‌باشد.

الف) مولفه‌های تصادفی که توزیعی برای متغیر پاسخ y است و معمولاً از خانواده توابع نمایی است و با بیش پراکندگی $d(\tau)$ انتخاب می‌گردد.

ب) مولفه سیستماتیک

همان پیشگویی‌کننده خطی $x \beta = \eta$ است که β یک بردار $p \times 1$ از پارامترهای نامعلوم و x یک ماتریس $n \times p$ متشکل از متغیرهای مستقل است.

ج) تابع پیوند

تابعی است که یکنوای صعودی و حداقل دو بار مشتق‌پذیر که قسمت سیستماتیک مدل را به امید ریاضی مؤلفه تصادفی $E(Y) = \mu$ مربوط می‌کند و آن را با تابع h به صورت $\eta = h(\mu)$ نمایش می‌دهند.

فرمول نهایی مدل GLM به صورت زیر می‌باشد.

تابع y متعلق به نوعی از خانواده نمایی با چگالی زیر است:

$$f_Y(Y|\theta, \tau) = h(y, \tau) \exp\left(\frac{b(\theta)^T T(y) - A(\theta)}{d(\tau)}\right) \quad (1)$$

¹ Ha

² Riazi

³ Avand

⁴ Willis

θ مربوط به پارامتر پراکندگی، A و b توابعی معلوم، متناظر با نوع چگالی مربوط به خانواده نمایی و $d(\tau)$ بیش پراکندگی مربوط به تابع است.

مدل بیشینه آنتروپی

مدل بیشینه آنتروپی، یک مدل یادگیری ماشین مولد نقاط حضوری است که بر اساس تئوری اطلاعات بیان شده است (شیونگ^۱ و همکاران، ۲۰۱۸). شانون برای اولین بار اصطلاح آنتروپی را برای بیان محتوای اطلاعاتی ذخیره شده در داده‌ها و به دست آوردن درجه‌ای از یک پدیده که می‌تواند تا حدودی غیرقابل پیش‌بینی باشد، ابداع کرد. در این تئوری درجه بالاتری از غیرقابل پیش‌بینی بودن نسبی می‌تواند متقابلاً محتوای اطلاعاتی بالاتری را ارائه دهد (شانون^۲، ۱۹۸۴). بیشینه آنتروپی می‌تواند محتوای اطلاعات را افزایش دهد و مدل را قادر می‌سازد تا الگوی علاقه را بهتر تشخیص دهد. یکی از مزیت‌های مدل آنتروپی بیشینه این است که این مدل بر خلاف مدل‌های آماری به تعریف فرضیه وابسته نیست (سیاه کمری^۳ و همکاران، ۲۰۱۸). دلیل انتخاب این مدل برای این پژوهش، توانایی بالای این مدل در شناخت مناطق قطعیت به وقوع در مناطق سیل‌خیز است. این مدل بر خلاف خیلی از مدل‌ها قادر است از طریق فقط نقاط حضور مدل‌سازی و تجزیه و تحلیل‌ها را انجام دهد. جزئیات بیشتر این مدل در مقاله (بالدوین^۴، ۲۰۱۴) ارائه شده است.

آنتروپی این توزیع‌ها بر اساس رابطه (۲) به دست می‌آید.

$$H(\hat{\pi}) = -\sum_{x \in X} \hat{\pi}(x) \ln \hat{\pi}(x) \quad (2)$$

$H(\hat{\pi})$ مقدار آنتروپی توزیع احتمالاتی، $\ln$ لگاریتم طبیعی، x مقدار ارزش هر سلول و X مجموعه‌ای از داده‌های یک لایه رستری.

توزیع احتمالاتی Gibbs برای هر یک از متغیرهای مستقل با استفاده از رابطه (۳) به دست می‌آید.

$$q_{\lambda}(x) = \frac{e^{\lambda f(x)}}{Z_{\lambda}} \quad (3)$$

$q_{\lambda}(x)$ تابع توزیع Gibbs، λ وزن متغیر مورد نظر، Z_{λ} ثابت نرمال‌کننده تابع توزیع Gibbs است.

اعتبارسنجی مدل‌ها

پس از تهیه نقشه‌های حساسیت سیل با استفاده از مدل‌های یادگیری ماشینی اتخاذ شده، از مجموعه داده‌های اعتبارسنجی ۳۰ درصد از تعداد کل نقاط سیلابی برای آزمون اعتبارسنجی نتایج مدل‌ها با استفاده از منحنی ROC و سطح زیر منحنی (AUROC) استفاده شد. در این منحنی نقاط مثبت کاذب (نقاط دارای پیش‌بینی نادرست مکان‌های غیر سیل به عنوان سیلابی) را در محور x در برابر مثبت‌های واقعی یعنی پیش‌بینی صحیح مکان‌های

¹ Xiong

² Shannon


³ Siahkamari

⁴ Baldwin

سیلابی که در طبیعت مشاهده می‌شود، ترسیم می‌کند (هانگ و همکاران، ۲۰۱۹). AUC نماینده عملکرد مدل است که در آن مقدار یک برای مدل با عملکرد عالی، مقادیر مساوی یا نزدیک به ۰/۵ نشان‌دهنده یک مدل خنثی است که نتایج آن از شانس تصادفی خالص مشتق شده است و همچنین مقادیر کمتر از ۰/۵ نشان‌دهنده عدم قطعیت مدل است (داودی^۱ و همکاران، ۲۰۱۹). در این پژوهش منحنی ROC از طریق ۳۰ درصد داده‌های اعتبارسنجی در داخل نرم‌افزار ModEco اجرا و داده‌ها به منظور تهیه منحنی‌های دارای کیفیت مناسب با استفاده از نرم‌افزار اکسل رسم شدند.

نتایج


این پژوهش با هدف پهنه‌بندی حساسیت سیلاب با استفاده از مدل‌های یادگیری ماشین بیشینه آنتروپی (Max Ent) و مدل خطی تعمیم‌یافته (GLM) در حوزه آبخیز زیوه ارومیه انجام شد. پس از تهیه نقشه پراکنش سیلاب‌های رخ داده و شناسایی عوامل مؤثر بر وقوع، نقشه حساسیت‌پذیری منطقه به رخداد سیلاب‌ها با دو روش بالا تهیه گردید. نتایج حاصل از ارزیابی مدل‌ها با استفاده از منحنی ROC برای روش بالا نشان می‌دهد که نتایج هر دو مدل دارای عملکرد عالی ($AUC > 0.9$) در پیش‌بینی مناطق حساس به رخداد سیلاب می‌باشد.



شکل ۳: نقشه‌های حساسیت‌پذیری و نتایج منحنی ROC برای مدل‌های MaxEnt و GLM در آبخیز زیوه

¹ Davoudi

همچنین نتایج حاصل از بررسی شاخص کاپا^۱ در مدل برتر (بیشینه آنتروپی) در نرم‌افزار ModEco برای تعیین عوامل موثر بر رخداد سیلاب در منطقه مورد نظر نشان می‌دهد که به ترتیب زمین‌شناسی، فاصله از آبراهه، ارتفاع و شیب و شاخص زبری سطح بیشترین تاثیر و شاخص انحنای پروفیل، کاربری اراضی و شاخص تعادل کمترین تاثیر مربوط به شاخص زبری سطح زمین می‌باشد.



شکل ۴: نمودار شاخص Kapa برای مدل برتر (مدل بیشینه آنتروپی)

بحث

بر اساس نتایج حاصل از شاخص کاپا، سازندهای زمین‌شناسی در آبخیز زیوه کوهستانی بودن حوضه، ارتفاع، شیب زیاد و وجود آبراهه‌های فراوان جزء عوامل کلیدی و اصلی در وقوع سیلاب‌ها هستند. بر اساس نتایج مدل‌ها، اغلب سیلاب‌ها در ارتفاعات میانی حوزه اتفاق افتاده‌اند. وجود شیب زیاد در ارتفاعات بالا بر میزان نفوذ در لایه‌های خاک تاثیر گذاشته و در نتیجه آن زمان تمرکز کاهش پیدا می‌کند. با کاهش زمان تمرکز بر میزان دبی پیک افزوده می‌گردد. همچنین سازندهای زمین‌شناسی در این بازه اغلب انواع آهک‌ها را شامل می‌شود که فرسایش این سازندها قدرت رخداد سیلاب را چندین برابر می‌کند. وجود آبراهه‌های فراوان نیز یکی از دلایل اصلی افزایش میزان رخداد سیلاب می‌باشد؛ زیرا با رسیدن آب بارندگی به آبراهه‌ها، جریان متمرکز شده و در نتیجه قدرت جذب آب به دلیل افزایش سرعت حرکت کاهش می‌یابد. بارندگی و پوشش گیاهی که در اغلب مطالعات (خدمت‌زاده و حسنی نظام‌آباد، ۱۳۹۹) جز عوامل کلیدی و اصلی شاهد بر رخداد سیلاب‌ها می‌باشد، درحالی‌که در این حوضه از تاثیری کمتری برخوردار هستند. میانگین بارندگی در این حوضه بر اساس مدل زمین آمار کریجینگ ساده برابر ۳۹۵ میلی‌متر در سال می‌باشد. اگر چه میزان بارندگی در سطح حوضه به خوبی شرایط را برای وقوع سیلاب‌های مخرب مهیا کرده است؛ اما پراکنش مناسب این حجم از بارندگی در ماه‌های مختلف سال و نبود اختلاف زیاد بارندگی در مناطق پایین

¹ Kappa

دست نسبت به بالا دست (۴۰ میلی‌متر) دو عامل مهم در کاهش تاثیر این عامل می‌باشد. اوج تراکم تاج پوشش در این حوضه مربوط به اواخر خرداد و اوایل تیرماه می‌باشد که در این زمان از سال میزان بارندگی کمتر می‌شود. بنابراین افزایش تراکم تاج پوشش مانع رخداد سیلاب‌های مخرب می‌شود. اغلب سیلاب‌ها در این حوضه در ماه‌های آبان، آذر، فروردین و تا اواسط اردیبهشت با میزان پوشش گیاهی کم بر روی زمین اتفاق می‌افتند. به دلیل وجود بارندگی زیاد در حوضه روز به روز بر میزان تغییرات کاربری حوضه افزوده می‌گردد و مراتع بیشتری تبدیل به دیم-زارهای کم بازدهی می‌گردند که بعد از سه تا چهار سال کاشت، به حال خودشان رها می‌گردند. در نتیجه تغییر در لایه سطحی خاک و کاهش تراکم پوشش گیاهی در طولانی مدت منجر به ایجاد خسارت‌های محسوس و نامحسوس در این حوضه می‌گردد. وجود خصوصیت‌های ذاتی مانند سازندهای زمین‌شناسی با فراوانی آمیزه‌های افیولیتی و آهک‌های پلازیک، آب و هوای نیمه‌سرد مرطوب، میانگین شیب و ارتفاع بالا، وجود خصوصیت‌های ژئومورفولوژی و خصوصیت‌های فیزیوگرافی، عوامل انسانی نظیر تغییر کاربری اراضی و چرای بی‌رویه و زودرس (کاهش تراکم پوشش گیاهی) بر وقوع سیلاب‌های حوضه تأثیرگذار بوده‌اند. یک گام مهم در بحث پهنه‌بندی حساسیت سیل و ارزیابی خطرات آن، انتخاب یک مدلی است که قادر باشد رابطه فی‌مابین تمامی این عوامل را به‌خوبی مدل کند. از مهم‌ترین دلایل انتخاب مدل خطی تعمیم‌یافته و بیشینه آنتروپی برای این پژوهش، داشتن وجه‌های مشترک زیاد مانند انعطاف‌پذیری و قدرت پیش‌بینی مکانی بالا برای داده‌های غیرخطی، بهره‌گیری کامل از داده‌های موجود همراه با در نظر گرفتن پیچیدگی‌های موجود بین اجزاء، دارای توزیع آماری داده‌های مستقل بودن، مبتنی بر روش‌های طبقه‌بندی بودن می‌باشند (داودی و همکاران، ۲۰۱۹). نتایج ارزیابی کارایی مدل‌های یادگیری ماشین بیشینه آنتروپی و مدل خطی تعمیم‌یافته در منطقه مورد مطالعه مشخص شد که این آبخیز به رخداد سیلاب‌ها بسیار حساس و در شرایط بحرانی قرار دارد. با هدف کاهش رخداد این بلیه طبیعی و جلوگیری از تهدید جان و مال مردم ضروری است که خطر وقوع سیلاب‌های مخرب در این حوضه برای سال‌های آینده مورد توجه قرار گیرد. نتایج منحنی ROC و مقدار سطح زیر منحنی (AUC) نشان داد که هر دوی این مدل‌ها مناطق حساس را به خوبی پیش‌بینی کرده‌اند. اگرچه مدل MaxEnt نسبت به مدل GLM دارای نتایج قابل قبول‌تر بوده است؛ اما در حالت کلی هر دو مدل هم از لحاظ تفکیک رده‌های خطر (بالای ۶۰ درصد در کلاس‌های دارای حساسیت زیاد و خیلی زیاد) و هم از لحاظ ارزیابی مدل‌ها در سطح عملکرد بالای ۰/۹ بوده‌اند. با توجه به حساسیت بالای این حوضه به رخداد انواع بلایای طبیعی مانند زمین‌لغزش (حنیفی‌نیا و عبقری، ۱۴۰۱) و سیلاب بر اساس نتایج این پژوهش، اگر تمهیدات لازم در جهت مقابله با این رخدادها صورت نگیرد، در دراز مدت ممکن است به مهاجرت‌های اجباری به درون کلان شهرها نیز منجر بشود. مدیران و مسئولان برنامه‌ریز کشوری با توجه کافی و اتخاذ تصمیمات درست و قابل اجرا در کوتاه مدت با توجه به ذاتی بودن عوامل تاثیرگذار بر رخداد این مخاطرات، می‌توانند تا حدود زیادی از خطرات احتمالی پیش رو جلوگیری کنند.

نتیجه‌گیری

شناسایی عوامل موثر و تهیه نقشه‌های حساسیت‌پذیری سیلاب از روش‌هایی هستند که به‌وسیله‌ی آنان تا حدودی می‌توان مناطق پرخطر و بحرانی را مشخص کرد و از این نقشه‌های تولیدشده در برنامه‌ریزی‌های توسعه پایدار استفاده کرد. در این مطالعه، هدف اصلی شناسایی عوامل و مناطق حساس به رخداد سیلاب از طریق مدل‌های

پیشرفته یادگیری ماشین بوده است. نتایج بررسی و مدل‌سازی نشان داد که به‌طور میانگین بالای ۶۰ درصد حوضه در مناطق پر خطر و بحرانی قرار دارد. اگرچه در این مطالعه ارزیابی نتایج مدل بیشینه آنتروپی (۰/۹۱۶) نسبت به مدل خطی تعمیم‌یافته (۰/۹۰۲) بهتر بود؛ اما این تفاوت بسیار اندک و فقط در حد ۰/۱ بوده است. سطح زیر منحنی برای هر دو مدل عملکرد عالی نقشه‌های ایجادشده از این مدل‌ها را نشان می‌دهد. در حالت کلی، مدیریت و کنترل سیلاب‌های به وقوع پیوسته و مناطق مستعد برای سیلاب که عامل اصلی وقوع آنان فعالیت‌های انسانی باشد، بسیار سخت‌تر از حالتی است که عوامل محیطی یا طبیعی به تنهایی اثر گذاشته باشد. در تمام مناطق کوهستانی سیلاب‌هایی که به‌صورت طبیعی و ذاتی رخ می‌دهند، یک حالت خود تنظیمی داشته و طبیعت به خودی خود این سیلاب‌ها را در اغلب موارد کنترل و مدیریت می‌کند. کنترل سیلاب‌های ناشی از دخالت انسان در طبیعت اغلب امکان‌پذیر نیستند و در صورت انجام بسیار پرهزینه خواهند بود. بر اساس نتایج حاصل از شاخص کاپا مشخص شد که عواملی مانند زمین‌شناسی، فاصله از آبراهه، ارتفاع و شیب بیشترین تأثیر را بر رخداد سیلاب داشته‌اند. بنابراین در این منطقه تأثیر عوامل طبیعی نسبت به عوامل انسانی بیشتر می‌باشد، منتهی کوچک‌ترین دخالت توسط انسان می‌تواند باعث ایجاد وضعیت بحرانی در این منطقه بشود. با توجه به دقت خیلی خوب هر دو مدل با درصد خطای کم در ارزیابی و تهیه نقشه خطر سیلاب‌های حوضه، می‌توان پیشنهاد کرد که در تصمیم‌گیری‌های آتی، مدیریت دامنه‌های ناپایدار و آمایش سرزمین این نقشه‌ها می‌توانند بسیار کارآمد باشند.

منابع

- اسماعیلی، رضا؛ طاهری، محمد. (۱۴۰۱). ارزیابی مناطق مستعد خطر سیلاب با نگرش فازی (مطالعه موردی: پایین دست حوضه آبریز نکا، استان مازندران)، مخاطرات محیط طبیعی، دوره ۱۱، شماره ۳۴، صص: ۱۴۵-۱۵۸.
- بختیاری، محسن؛ جهانتاب، زهرا. (۱۴۰۱). مدل‌سازی مکانی سیلاب با استفاده از الگوریتم شبکه عصبی مصنوعی و توابع تحلیلی GIS، پژوهش‌های اقلیم‌شناسی، شماره ۴۹، صص: ۱۷۷-۱۹۴.
- تیموری، مهدی؛ فرزانه وکیلی؛ تجربه مزین، ملیحه؛ رضانی، مرضیه. (۱۴۰۱). مقایسه مدل‌های یادگیری ماشینی در پهنه‌بندی حساسیت سیل‌خیزی حوزه آبخیز سد کرج، مجله علوم و مهندسی آبخیزداری ایران، دوره ۶۱، شماره ۱۷، صص: ۳۰-۴۰.
- حسن‌زاده، رضا؛ هنرمند، مهدی؛ حسینجانی‌زاده، مهدیه؛ محمدی، صدیقه. (۱۴۰۰). پهنه‌بندی سیلاب در نواحی شهری با استفاده از مدل هیدرولوژیکی و اطلاعات میدانی (مطالعه موردی: سیل بردسیر، استان کرمان)، اکوهیدرولوژی، ۸(۲)، صص: ۳۳۱-۳۴۴.
- حنیفی‌نیا، عبدالعزیز؛ عبقری، هیراد. (۱۴۰۱). بررسی ارتباط عوامل مؤثر بر وقوع زمین‌لغزش در مدل آنتروپی شانون با دو ریکرد WOE و LNRF به منظور پهنه‌بندی حساسیت زمین‌لغزش در حوضه آبخیز زیوه ارومیه، پژوهش‌های ژئومورفولوژی کمی، دوره ۱۱، شماره ۲، صص: ۱۰۸-۱۲۷.
- حنیفی‌نیا، عبدالعزیز؛ نظرنژاد، حبیب. (۱۴۰۰). اثر شاخص‌های مورفومتری در بهبود کارایی مدل‌های داده‌کاوی به‌منظور پهنه‌بندی حساسیت زمین‌لغزش حوضه آبخیز چریک‌آباد ارومیه، جغرافیا و مخاطرات محیطی، دوره ۱۱، شماره ۴، صص: ۴۷-۶۸.
- حنیفی‌نیا، عبدالعزیز؛ نظرنژاد، حبیب؛ نجفی، سعید؛ کرنژادی، آیدینگ. (۱۳۹۹). اولویت‌بندی عامل‌های مؤثر بر وقوع زمین‌لغزش و پهنه‌بندی حساسیت آن در آبخیز چریک‌آباد ارومیه با استفاده از مدل آنتروپی شانون، پژوهش‌های آبخیزداری، دوره ۳۳، شماره ۴، صص: ۳۲-۴۸.
- خدمت‌زاده، علی؛ حسنی نظام‌آباد، مهدی. (۱۳۹۹). پهنه‌بندی سیلاب حوضه آبریز شهر چایی ارومیه. مهندسی جغرافیایی سرزمین، دوره ۴، شماره ۱، صص: ۷۰-۸۳.

دسترنج، علی؛ کریمی سنگچینی، ابراهیم. (۱۴۰۱)؛ پیش‌بینی حساسیت وقوع زمین‌لغزش با الگوریتم یادگیری ماشین بیشینه آنتروپی حوزه آبخیز بار نیشابور، پژوهش‌های دانش زمین، ۱۳، دوره ۱۳، شماره ۳، صص: ۷۶-۹۶.

عابدینی، موسی؛ فعال‌نذیری، مهدی؛ پیروزی، الناز. (۱۴۰۲). ارزیابی و پهنه‌بندی خطر سیلاب با استفاده از تکنیک چندمعیاره آراس و هیدروگراف واحد (مطالعه‌ی موردی: حوضه بالادست ایستگاه هیدرومتری پل سلطان مشکین‌شهر)، مخاطرات محیط طبیعی، دوره ۱۲، شماره ۳۵، صص: ۱۱۵-۱۳۸.

عرب‌عامری، علیرضا؛ رضایی، خلیل؛ سهرابی، مسعود؛ شیرانی، کورش. (۱۳۹۷)؛ ارزیابی کارایی پارامترهای کمی ژئومورفومتریک در افزایش صحت نقشه‌های پهنه‌بندی حساسیت زمین‌لغزش (مطالعه موردی: حوضه فریدون شهر، استان اصفهان)، پژوهشنامه مدیریت حوزه آبخیز، پیاپی ۱۸، شماره ۹، صص: ۲۲۰-۲۳۲.

- Anand, A. K., & Pradhan, S. P. (2023). Evaluation of bivariate statistical and hybrid models for the preparation of flood hazard susceptibility maps in the Brahmani River Basin, India. *Environmental Earth Sciences*, 82(16), 389.
- Avand, M., Kuriqi, A., Khazaei, M., & Ghorbanzadeh, O. (2022). DEM resolution effects on machine learning performance for flood probability mapping. *Journal of Hydro-Environment Research*, 40, 1-16.
- Baig, S. U., Rehman, M. U., & Janjua, N. N. (2021). District-level disaster risk and vulnerability in the Northern mountains of Pakistan. *Geomatics, Natural Hazards and Risk*, 12(1), 2002-2022.
- Baldwin, R. A. (2009). Use of maximum entropy modeling in wildlife research. *Entropy*, 11(4), 854-866.
- Boussouf, S., Fernández, T., & Hart, A. B. (2023). Landslide susceptibility mapping using maximum entropy (MaxEnt) and geographically weighted logistic regression (GWLRL) models in the Río Aguas catchment (Almería, SE Spain). *Natural Hazards*, 117(1), 207-235.
- Bui, D. T., Tsangaratos, P., Ngo, P. T. T., Pham, T. D., & Pham, B. T. (2019). Flash flood susceptibility modeling using an optimized fuzzy rule-based feature selection technique and tree-based ensemble methods. *Science of the total environment*, 668, 1038-1054.
- Davoudi Moghaddam, D., Pourghasemi, H. R., & Rahmati, O. (2019). Assessment of the contribution of geo-environmental factors to flood inundation in a semi-arid region of SW Iran: Comparison of different advanced modeling approaches. *Natural hazards GIS-based spatial modeling using data mining techniques*, 59-78.
- El-Rawy, M., Elsadek, W. M., & De Smedt, F. (2023). Flood hazard assessment and mitigation using a multi-criteria approach in the Sinai Peninsula, Egypt. *Natural Hazards*, 115(1), 215-236.
- Ha, H., Luu, C., Bui, Q. D., Pham, D. H., Hoang, T., Nguyen, V. P., ... & Pham, B. T. (2021). Flash flood susceptibility prediction mapping for a road network using hybrid machine learning models. *Natural hazards*, 109(1), 1247-1270.
- Hirabayashi, Yukiko, Roobavannan Mahendran, Sujana Koirala, Lisako Konoshima, Dai Yamazaki, Satoshi Watanabe, Hyungjun Kim, and Shinjiro Kanae. "Global flood risk under climate change." *Nature Climate Change* 3, no. 9 (2013): 816-821.
- Huang, K., Li, X., Liu, X., & Seto, K. C. (2019). Projecting global urban land expansion and heat island intensification through 2050. *Environmental Research Letters*, 14(11), 114037.
- Islam, A. R. M. T., Bappi, M. M. R., Alqadhi, S., Bindajam, A. A., Mallick, J., & Talukdar, S. (2023). Improvement of flood susceptibility mapping by introducing hybrid ensemble learning algorithms and high-resolution satellite imageries. *Natural Hazards*, 119(1), 1-37.
- Khosravi, K., Panahi, M., Golkarian, A., Keesstra, S. D., Saco, P. M., Bui, D. T., & Lee, S. (2020). Convolutional neural network approach for spatial prediction of flood hazard at national scale of Iran. *Journal of Hydrology*, 591, 125552.
- Möller M, Volk M, Friedrich K, Lymburner L. (2008). Placing soil-genesis and transport processes into a landscape context: A multiscale terrain-analysis approach, *Journal of Plant Nutrition and Soil Science* 171 (3): 419-430.
- Mosavi, A., Golshan, M., Janizadeh, S., Choubin, B., Melesse, A. M., & Dineva, A. A. (2022). Ensemble models of GLM, FDA, MARS, and RF for flood and erosion susceptibility mapping: a priority assessment of sub-basins. *Geocarto International*, 37(9), 2541-2560.
- Panahi, M., Jaafari, A., Shirzadi, A., Shahabi, H., Rahmati, O., Omidvar, E., ... & Bui, D. T. (2021). Deep learning neural networks for spatially explicit prediction of flash flood probability. *Geoscience Frontiers*, 12(3), 101076.
- Pham, B. T., Luu, C., Van Phong, T., Trinh, P. T., Shirzadi, A., Renoud, S., ... & Clague, J. J. (2021). Can deep learning algorithms outperform benchmark machine learning algorithms in flood susceptibility modeling? *Journal of Hydrology*, 592, 125615.
- Riazi, M., Khosravi, K., Shahedi, K., Ahmad, S., Jun, C., Bateni, S. M., & Kazakis, N. (2023). Enhancing flood susceptibility modeling using multi-temporal SAR images, CHIRPS data, and hybrid machine learning algorithms. *Science of The Total Environment*, 871, 162066.
- Saha, S., Saha, A., Hembram, T. K., Mandal, K., Sarkar, R., & Bhardwaj, D. (2022). Prediction of spatial landslide susceptibility applying the novel ensembles of CNN, GLM, and random forest in the Indian Himalayan region. *Stochastic Environmental Research and Risk Assessment*, 36(10), 3597-3616.

- Samantaray, S., Agnihotri, A., & Sahoo, A. (2023). Flood Replication Using ANN Model Concerning Various Catchment Characteristics: Narmada River Basin. *Journal of The Institution of Engineers (India): Series A*, 104(2), 381-396.
- Shahabi H, Khezri S, Ahmad BB, Hashim M. (2014). Landslide susceptibility mapping at central Zab basin, Iran: A comparison between analytical hierarchy process, frequency ratio, and logistic regression models, *Catena* 115: 55-70.
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3), 379-423.
- Siahkamari, S., Haghizadeh, A., Zeinivand, H., Tahmasebipour, N., & Rahmati, O. (2018). Spatial prediction of flood-susceptible areas using frequency ratio and maximum entropy models. *Geocarto international*, 33(9), 927-941.
- Sofia, G., Roder, G., Dalla Fontana, G., & Tarolli, P. (2017). Flood dynamics in urbanized landscapes: 100 years of climate and humans' interaction. *Scientific reports*, 7(1), 40527.
- Tabari, H. (2020). Climate change's impact on floods and extreme precipitation increases with water availability. *Scientific reports*, 10(1), 13768.
- UN Office for Disaster Risk Reduction. *The Human Cost of Disasters: An Overview of the Last 20 Years (2000–2019)*; UN Office for Disaster Risk Reduction Geneva: Geneva, Switzerland, 2020.
- Willis, G. M., Ward, T., & Levenson, J. S. (2014). The Good Lives model (GLM) is an evaluation of GLM operationalization in North American treatment programs. *Sexual Abuse*, 26(1), 58-81.
- Xiong, F., Guo, S., Chen, L., Chang, F. J., Zhong, Y., & Liu, P. (2018). Identification of flood seasonality using an entropy-based method. *Stochastic Environmental Research and Risk Assessment*, 32, 3021-3035.
- Xu, A., Chang, H., Xu, Y., Li, R., Li, X., & Zhao, Y. (2021). Applying artificial neural networks (ANNs) to solve solid waste-related issues: A critical review. *Waste Management*, 124, 385-402.
- Youssef, A. M., Pourghasemi, H. R., & El-Haddad, B. A. (2022). Advanced machine learning algorithms for flood susceptibility modeling—Performance comparison: Red Sea, Egypt. *Environmental Science and Pollution Research*, 29(44), 66768-66792.
- Youssef, A. M., Pourghasemi, H. R., Mahdi, A. M., & Matar, S. S. (2023). Flood vulnerability mapping and urban sprawl suitability using FR, LR, and SVM models. *Environmental Science and Pollution Research*, 30(6), 16081-16105.

References

References (in Persian)

- Abedini, Mussa., Faal Naziri, Mehdi., & Pirouzi, Alnaz. (2023). Flood risk assessment and zoning using multi-criteria Ara's technique and single hydrograph (Case Study: Upstream Basin of Soltan Meshkinshahr Bridge Hydrometric Station). *Journal of Natural Environmental Hazards*, 12(35), 115-138. [10.22111/JNEH.2022.40684.1863](https://doi.org/10.22111/JNEH.2022.40684.1863). [In Persian]
- Bakhtiari, Mohsen., & Jahantab, Zahra. (2022). Spatial modeling of floods using Artificial Neural Network (ANN) and analyst functions of GIS. *Journal of Climate Research*, (49), 177-194. [In Persian]
- Dastranj, Ali., & Karimi, Ebrahim. (2022). Landslide susceptibility prediction using the maximum entropy machine learning algorithm (Bar catchment of Nishapur). *Researches in Earth Sciences*, 13(3), 76-96. <https://doi.org/10.48308/esri.2022.102965>. [In Persian]
- Esmaili, Reza., & Taheri, Mohammad. (2022). Evaluation of flood hazard areas with fuzzy approach, Case study: Downstream of Neka catchment, Mazandaran province. *Journal of Natural Environmental Hazards*, 11(34), 145-158. [10.22111/JNEH.2022.39817.1842](https://doi.org/10.22111/JNEH.2022.39817.1842). [In Persian]
- Hanifinia, Abdulaziz., & Abghari, Hirad. (2022). Investigation of affecting factors landslide occurrence in Shannon entropy model with two WOE and LNRF approaches to zoning sensitivity landslide in Ziveh watershed of Urmia. *Quantitative Geomorphological Research*, 11(2), 108-127. [10.22034/gmpj.2022.340292.1348](https://doi.org/10.22034/gmpj.2022.340292.1348). [In Persian]
- Hanifinia, Abdulaziz., & Nazarnejad, Habib. (2022). The Effect of Morphometry Indices on Improving the Performance of Data Mining Models for Landslide Sensitivity Zoning in Cherikabad Watershed, Urmia. *Journal of Geography and Environmental Hazards*, 10(4), 47-68. [10.22067/GEOEH.2021.69707.1041](https://doi.org/10.22067/GEOEH.2021.69707.1041). [In Persian]
- Hanifinia, Abdulaziz., Nazarnejad, Habib., Najafi, Saeed., & Kornejady, Aiding. (2020). Prioritization of Effective Factors on Landslide Occurrence and Mapping of its Sensitivity in CherikAbad Watershed, Urmia Using Shannon Entropy Model. *Watershed Management Research Journal*, 33(4), 30-46. [10.22092/WMEJ.2020.128407.1280](https://doi.org/10.22092/WMEJ.2020.128407.1280). [In Persian]
- Hassanzadeh, Reza., Honarmand, Mahdi., Hossinjanizadeh, Mahdieh., & Mohammadi, Sedighe. (2021). Flood zoning in urban areas using hydrological modeling and survey data: A case study of Bardsir city, Kerman Province. *Iranian Journal of Ecohydrology*, 8(2), 331-344. [10.22059/IJE.2021.314075.1423](https://doi.org/10.22059/IJE.2021.314075.1423). [In Persian]
- Teimoori, Mehdi., Vakili tajareh, Farzaneh., Mozayyan, Malihe., Ramezani, Marziyeh (2023). Comparison of Machine Learning Models in Flood Susceptibility Zoning in Karaj Dam Basin. *jwmseir*; 17 (61) :30-40 . [20.1001.1.20089554.1402.17.61.4.8](https://doi.org/10.1001.1.20089554.1402.17.61.4.8) [In Persian]

References (in English)

- Anand, A. K., & Pradhan, S. P. (2023). Evaluation of bivariate statistical and hybrid models for the preparation of flood hazard susceptibility maps in the Brahmani River Basin, India. *Environmental Earth Sciences*, 82(16), 389.
- Avand, M., Kuriqi, A., Khazaei, M., & Ghorbanzadeh, O. (2022). DEM resolution effects on machine learning performance for flood probability mapping. *Journal of Hydro-Environment Research*, 40, 1-16.
- Baig, S. U., Rehman, M. U., & Janjua, N. N. (2021). District-level disaster risk and vulnerability in the Northern mountains of Pakistan. *Geomatics, Natural Hazards and Risk*, 12(1), 2002-2022.
- Baldwin, R. A. (2009). Use of maximum entropy modeling in wildlife research. *Entropy*, 11(4), 854-866.
- Boussouf, S., Fernández, T., & Hart, A. B. (2023). Landslide susceptibility mapping using maximum entropy (MaxEnt) and geographically weighted logistic regression (GWLR) models in the Río Aguas catchment (Almería, SE Spain). *Natural Hazards*, 117(1), 207-235.
- Bui, D. T., Tsangaratos, P., Ngo, P. T. T., Pham, T. D., & Pham, B. T. (2019). Flash flood susceptibility modeling using an optimized fuzzy rule-based feature selection technique and tree-based ensemble methods. *Science of the total environment*, 668, 1038-1054.
- Davoudi Moghaddam, D., Pourghasemi, H. R., & Rahmati, O. (2019). Assessment of the contribution of geo-environmental factors to flood inundation in a semi-arid region of SW Iran: Comparison of different advanced modeling approaches. *Natural hazards GIS-based spatial modeling using data mining techniques*, 59-78.
- El-Rawy, M., Elsadek, W. M., & De Smedt, F. (2023). Flood hazard assessment and mitigation using a multi-criteria approach in the Sinai Peninsula, Egypt. *Natural Hazards*, 115(1), 215-236.
- Ha, H., Luu, C., Bui, Q. D., Pham, D. H., Hoang, T., Nguyen, V. P., ... & Pham, B. T. (2021). Flash flood susceptibility prediction mapping for a road network using hybrid machine learning models. *Natural hazards*, 109(1), 1247-1270.
- Hirabayashi, Yukiko, Roobavannan Mahendran, Sujun Koirala, Lisako Konoshima, Dai Yamazaki, Satoshi Watanabe, Hyungjun Kim, and Shinjiro Kanae. "Global flood risk under climate change." *Nature Climate Change* 3, no. 9 (2013): 816-821.
- Huang, K., Li, X., Liu, X., & Seto, K. C. (2019). Projecting global urban land expansion and heat island intensification through 2050. *Environmental Research Letters*, 14(11), 114037.
- Islam, A. R. M. T., Bappi, M. M. R., Alqadhi, S., Bindajam, A. A., Mallick, J., & Talukdar, S. (2023). Improvement of flood susceptibility mapping by introducing hybrid ensemble learning algorithms and high-resolution satellite imageries. *Natural Hazards*, 119(1), 1-37.

- Khosravi, K., Panahi, M., Golkarian, A., Keesstra, S. D., Saco, P. M., Bui, D. T., & Lee, S. (2020). Convolutional neural network approach for spatial prediction of flood hazard at national scale of Iran. *Journal of Hydrology*, 591, 125552.
- Möller M, Volk M, Friedrich K, Lymburner L. (2008). Placing soil-genesis and transport processes into a landscape context: A multiscale terrain-analysis approach, *Journal of Plant Nutrition and Soil Science* 171 (3): 419-430.
- Mosavi, A., Golshan, M., Janizadeh, S., Choubin, B., Melesse, A. M., & Dineva, A. A. (2022). Ensemble models of GLM, FDA, MARS, and RF for flood and erosion susceptibility mapping: a priority assessment of sub-basins. *Geocarto International*, 37(9), 2541-2560.
- Panahi, M., Jaafari, A., Shirzadi, A., Shahabi, H., Rahmati, O., Omidvar, E., ... & Bui, D. T. (2021). Deep learning neural networks for spatially explicit prediction of flash flood probability. *Geoscience Frontiers*, 12(3), 101076.
- Pham, B. T., Luu, C., Van Phong, T., Trinh, P. T., Shirzadi, A., Renoud, S., ... & Clague, J. J. (2021). Can deep learning algorithms outperform benchmark machine learning algorithms in flood susceptibility modeling? *Journal of Hydrology*, 592, 125615.
- Riazi, M., Khosravi, K., Shahedi, K., Ahmad, S., Jun, C., Bateni, S. M., & Kazakis, N. (2023). Enhancing flood susceptibility modeling using multi-temporal SAR images, CHIRPS data, and hybrid machine learning algorithms. *Science of The Total Environment*, 871, 162066.
- Saha, S., Saha, A., Hembram, T. K., Mandal, K., Sarkar, R., & Bhardwaj, D. (2022). Prediction of spatial landslide susceptibility applying the novel ensembles of CNN, GLM, and random forest in the Indian Himalayan region. *Stochastic Environmental Research and Risk Assessment*, 36(10), 3597-3616.
- Samantaray, S., Agnihotri, A., & Sahoo, A. (2023). Flood Replication Using ANN Model Concerning Various Catchment Characteristics: Narmada River Basin. *Journal of The Institution of Engineers (India): Series A*, 104(2), 381-396.
- Shahabi H, Khezri S, Ahmad BB, Hashim M. (2014). Landslide susceptibility mapping at central Zab basin, Iran: A comparison between analytical hierarchy process, frequency ratio, and logistic regression models, *Catena* 115: 55-70.
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3), 379-423.
- Siahkamari, S., Haghizadeh, A., Zeinivand, H., Tahmasebipour, N., & Rahmati, O. (2018). Spatial prediction of flood-susceptible areas using frequency ratio and maximum entropy models. *Geocarto international*, 33(9), 927-941.
- Sofia, G., Roder, G., Dalla Fontana, G., & Tarolli, P. (2017). Flood dynamics in urbanized landscapes: 100 years of climate and humans' interaction. *Scientific reports*, 7(1), 40527.
- Tabari, H. (2020). Climate change's impact on floods and extreme precipitation increases with water availability. *Scientific reports*, 10(1), 13768.
- UN Office for Disaster Risk Reduction. *The Human Cost of Disasters: An Overview of the Last 20 Years (2000–2019)*; UN Office for Disaster Risk Reduction Geneva: Geneva, Switzerland, 2020.
- Willis, G. M., Ward, T., & Levenson, J. S. (2014). The Good Lives model (GLM) is an evaluation of GLM operationalization in North American treatment programs. *Sexual Abuse*, 26(1), 58-81.
- Xiong, F., Guo, S., Chen, L., Chang, F. J., Zhong, Y., & Liu, P. (2018). Identification of flood seasonality using an entropy-based method. *Stochastic Environmental Research and Risk Assessment*, 32, 3021-3035.
- Xu, A., Chang, H., Xu, Y., Li, R., Li, X., & Zhao, Y. (2021). Applying artificial neural networks (ANNs) to solve solid waste-related issues: A critical review. *Waste Management*, 124, 385-402.
- Youssef, A. M., Pourghasemi, H. R., & El-Haddad, B. A. (2022). Advanced machine learning algorithms for flood susceptibility modeling—Performance comparison: Red Sea, Egypt. *Environmental Science and Pollution Research*, 29(44), 66768-66792.
- Youssef, A. M., Pourghasemi, H. R., Mahdi, A. M., & Matar, S. S. (2023). Flood vulnerability mapping and urban sprawl suitability using FR, LR, and SVM models. *Environmental Science and Pollution Research*, 30(6), 16081-16105.