



Flood Susceptibility Mapping Using Optimized SVM Algorithm

S.M. Mirkazemi¹, N. Jalalkamali², and M. Irandoost³

Abstract

This study describes optimization of Support Vector Machine (SVM) using meta-optimization algorithms including the Particle Swarm Optimization (PSO), Genetic Algorithm (GA) and Ant Colony optimization for flood susceptibility mapping at Zahedan Basin. To determine the best factors among the 19 factors used in previous studies and the relative importance of input variables, two experiments of Information Acquisition Ratio (IGR) and multilinearity of parameters were used soil moisture content factor which is identified as a highly effective factor (IGR=0.767), is used directly in this study for the first time. The flood inventory map was prepared from Sentinel-1 satellite data processing and validated. The generated data set was used to map the flood prone areas using SVM model optimized with the mentioned algorithms. For the first time, in this research, ACO algorithm was used to optimize SVM model. The prediction accuracy of the models was evaluated using statistical criterion. All three algorithms used in this study improved SVM performance by 4% in average, while the PSO-SVM model had the best performance among the others with AUC=0.953, MSE=0.025, RMSE=0.158 and StD=0.405.

Keywords: Spatial Flood Prone Areas, Support Vector Machine, Particle Swarm Optimization, Genetic Algorithm, Ant Colony Optimization.

Received: July 3, 2021

Accepted: December 1, 2021

ناحیه‌بندی مناطق مستعد سیلاب توسط الگوریتم ماشین بردار پشتیبان بهینه‌سازی شده

سیدمیشم میرکاظمی^۱، نوید جلال کمالی^{۲*} و محسن ایراندوست

چکیده

در این مطالعه تولید نقشه‌های مناطق مستعد سیل با بهینه‌سازی مدل ماشین بردار پشتیبان (SVM) با استفاده از الگوریتم‌های بهینه‌سازی فراابتکاری ازدحام ذرات (PSO)، ژنتیک (GA) و کلونی مورچگان (ACO) در حوضه آبریز زاهدان صورت گرفته است. برای تعیین بهترین فاکتورهای تأثیرگذار بر سیل، از بین ۱۹ فاکتور مورداستفاده در مطالعات قبلی و اهمیت نسبی متغیرهای ورودی از دو آزمایش روش نسبت کسب اطلاعات (IGR) و متغیرهای ورودی از دو آزمایش بودن پارامترها استفاده شد. فاکتور میزان محتوای آب در خاک که جزو عوامل مؤثر با ضریب IGR=0.767 است، برای اولین بار در این مطالعه به صورت مستقیم در مدل‌سازی مورداستفاده قرار گرفت. نقشه مشخصه سیل از روی پردازش داده‌های ماهواره Sentinel-1 تهیه و اعتبارسنجی شد. از مجموعه داده‌های تولید شده برای تولید نقشه‌های مناطق مستعد سیل با استفاده از مدل SVM بهینه‌سازی شده با الگوریتم‌های مذکور استفاده شد که برای اولین بار، در این تحقیق از الگوریتم ACO برای بهینه‌سازی مدل SVM در تولید نقشه‌های مناطق مستعد سیل استفاده شد. دقت پیش‌بینی مدل‌ها با استفاده از معیارهای آماری بررسی گردید. هر سه الگوریتم مورداستفاده در این مطالعه، عملکرد SVM را به طور متوسط ۴ درصد بهبود بخشیدند در حالی که مدل PSO-SVM بهترین عملکرد را با StD=0.405، AUC=0.953، RMSE=0.025، MSE=0.158 در میان الگوریتم‌های دیگر به نمایش گذاشت؛ همچنین مشخص شد تقریباً نیمی از منطقه شهری زاهدان در مناطق خطر متوسط تا بسیار زیاد قرار دارند.

کلمات کلیدی: مناطق مستعد سیل، ماشین بردار پشتیبان، الگوریتم بهینه‌سازی ازدحام ذرات، الگوریتم بهینه‌سازی ژنتیک، الگوریتم بهینه‌سازی کلونی مورچگان.

تاریخ دریافت مقاله: ۱۴۰۰/۴/۱۲

تاریخ پذیرش مقاله: ۱۴۰۰/۹/۱۰

1- Ph.D. Candidate of Water Resources Engineering, Department of Water Sciences and Engineering, Islamic Azad University, Kerman Branch, Iran.

2- Assistant Professor, Department of Water Sciences and Engineering, Islamic Azad University, Kerman Branch, Iran. Email: njalalkamali@gmail.com

3- Assistant Professor, Department of Water Sciences and Engineering, Islamic Azad University, Kerman Branch, Iran.

*- Corresponding author

Dor: [20.1001.1.17352347.1400.17.4.2.9](https://doi.org/10.17352/347.1400.17.4.2.9)

۱- دانشجوی دکتری مهندسی منابع آب، گروه علوم و مهندسی آب، دانشگاه آزاد اسلامی واحد کرمان، کرمان، ایران

۲- استادیار گروه علوم و مهندسی آب، دانشگاه آزاد اسلامی واحد کرمان، کرمان، ایران.

۳- استادیار گروه علوم و مهندسی آب، دانشگاه آزاد اسلامی واحد کرمان، کرمان، ایران.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان بهار ۱۴۰۱ امکانپذیر است.



۱- مقدمه

چندمعیاره، که از ارتباطات از پیش تعریف شده بین متغیرها و احتمال وقوع سیل استفاده می‌کند، تکنیک‌های یادگیری ماشینی این ارتباطات را مستقیماً از داده‌های مورد استفاده و به‌دوراز هرگونه فرض اولیه استخراج می‌نمایند (Jaafari et al., 2019; Tien Bui et al., 2019). تکنیک‌های ML هزینه‌های عملیاتی را کاهش و سرعت تجزیه و تحلیل داده‌ها را بهبود می‌بخشند، که این نکته خصوصاً در مجموعه داده‌های بزرگ حائز اهمیت است (Lee et al., 2019). علاوه بر این، مدل‌های ML کاربرپسند بوده و از ساختاری غیرخطی بهره می‌برند و عملکرد خوبی برای پیش‌دید پدیده‌های پیچیده مانند وقوع سیل دارند (Dodangheh et al., 2020) به همین دلیل در این تحقیق از روش یادگیری ماشینی استفاده گردیده است.

ماشین بردار پشتیبان (SVM) یکی از قدرتمندترین الگوریتم‌های یادگیری ماشینی تحت نظارت برای طبقه‌بندی و رگرسیون است که در چارچوب تئوری یادگیری آماری ایجاد شده است. الگوریتم SVM سال ۱۹۹۵ توسط وپنیک و همکاران ایجاد و توسعه یافته است (Vapnik et al., 1995). Alizadeh et al. (2018) در تحقیق خود باهدف پیش‌بینی ماهیانه جریان از الگوریتم بهینه‌سازی ملخ (GOA) برای بهینه‌سازی پارامترهای مدل SVM و Panahi et al. (2021) از الگوریتم‌های ملخ و الگوریتم ازدحام ذرات (PSO) برای بهینه‌سازی مدل SVR استفاده نموده‌اند؛ همچنین در تحقیقی، Syifa et al., (2020) از الگوریتم رقابتی امپریالیستی (ICA) برای بهینه‌سازی مدل SVM استفاده کرده‌اند.

در این تحقیق، از الگوریتم‌های فرا ابتکاری قوی بهینه‌سازی ازدحام ذرات (PSO)، ژنتیک (GA) و کلونی مورچگان (ACO) به منظور بهینه‌سازی پارامترهای مدل SVM استفاده شده است و در نتیجه سه مدل ترکیبی جدید PSO-SVM، GA-SVM و ACO-SVM برای تولید نقشه‌های مکانی مناطق مستعد سیلاب حوضه آبریز زاهدان در شرق ایران تولید شد. لازم به ذکر است برای نخستین بار در این تحقیق، از الگوریتم‌های فرا ابتکاری ACO در بهینه‌سازی مدل SVM استفاده شده است. یک تصویر گرافیکی از مراحل توسعه مدل برای تولید نقشه‌های مناطق مستعد سیل در شکل ۱ ارائه شده است. با توجه به اینکه این نوع مدل‌سازی بر اساس اطلاعات آب‌گرفتگی حوضه، ناشی از رخدادهای واقعی سیل در منطقه و بر اساس داده‌های سنجش‌ازدور استوار است؛ لذا در فقدان اطلاعات مشاهداتی بارش-رواناب، استفاده از این نوع مدل‌سازی در تولید نقشه‌های مناطق مستعد سیلاب ارجح است.

سیل از جمله ویران‌کننده‌ترین بلایای طبیعی است که صدمات جبران‌ناپذیری به محیط‌زیست، زندگی انسان و زیرساخت‌ها مانند جاده‌ها و پل‌ها وارد می‌کند. جاری شدن سیل باعث تلفات و خسارات اقتصادی در مناطق کشاورزی و شهری می‌شود که به این دلیل از اهمیت ویژه‌ای برخوردار است (Panahi et al., 2021; Yalcin et al., 2011; Ahmadlou et al., 2019). پیشگیری از حوادث سیل، همواره عملی نخواهد بود؛ بنابراین استفاده از روش‌های کاهش اثرات سیل، بهترین استراتژی برای مدیریت خطرات سیل در نظر گرفته می‌شود (Khosravi et al., 2019; Tien Bui et al., 2017). هدف استفاده از این روش‌ها، کاهش قابل توجه خسارت سیل با ارزیابی مناطق مستعد تولید سیل و انجام اقدامات محافظتی در مناطقی با حساسیت زیاد و بسیار زیاد به سیلاب در آینده است (Panahi et al., 2021).

از جمله اولین رویکردها، استفاده از روش‌های آماری برای بررسی ارتباط ویژگی‌های سیل با برخی از خصوصیات فیزیکی حوضه‌های آبریز است (Khosravi et al., 2019). اخیراً، مدل‌های مفهومی و فیزیک پایه برای پیش‌بینی مکانی سیل در بسیاری از مناطق جهان استفاده شده است. با این حال، مشکل تولید نقشه‌های سیلاب توسط مدل‌های بارش-رواناب همچنان یک ضعف عمده در این مدل‌ها می‌باشد که فقط میزان تخلیه رودخانه را پیش‌بینی می‌کند (Solomatine et al., 2019).

با توجه به پیچیدگی مباحث سیل، نمی‌توان آن‌ها را با استفاده از مدل‌های ساده، مدل‌سازی نمود. در سال‌های اخیر، مدل‌های مبتنی بر داده، شامل مدل‌های آماری متغیر، تصمیم‌گیری چندمعیاره (MCDM) هوش مصنوعی (AI)، یادگیری ماشینی (ML)، هوش محاسباتی (CI)، محاسبات نرم (SC)، داده‌کاوی (DM)، تجزیه و تحلیل هوشمند داده‌ها (IDA) و غیره در بسیاری از شاخه‌های علوم پیش‌بینی از جمله نقشه مناطق مستعد سیل (FMS) مورد استفاده قرار گرفته است.

یکی از روش‌های پیش‌بینی و تعیین مناطق مستعد سیل که در دهه اخیر مورد توجه قرار گرفته است، استفاده از روش‌های یادگیری ماشینی (ML) می‌باشد که می‌توان برای مدل‌سازی مکانی مناطق مستعد سیل بر اساس روابط غیرخطی بین عوامل مؤثر در تولید سیل و مناطق سیل گرفته استفاده نمود. برخلاف روش‌های آماری مرسوم و تحلیل تصمیم

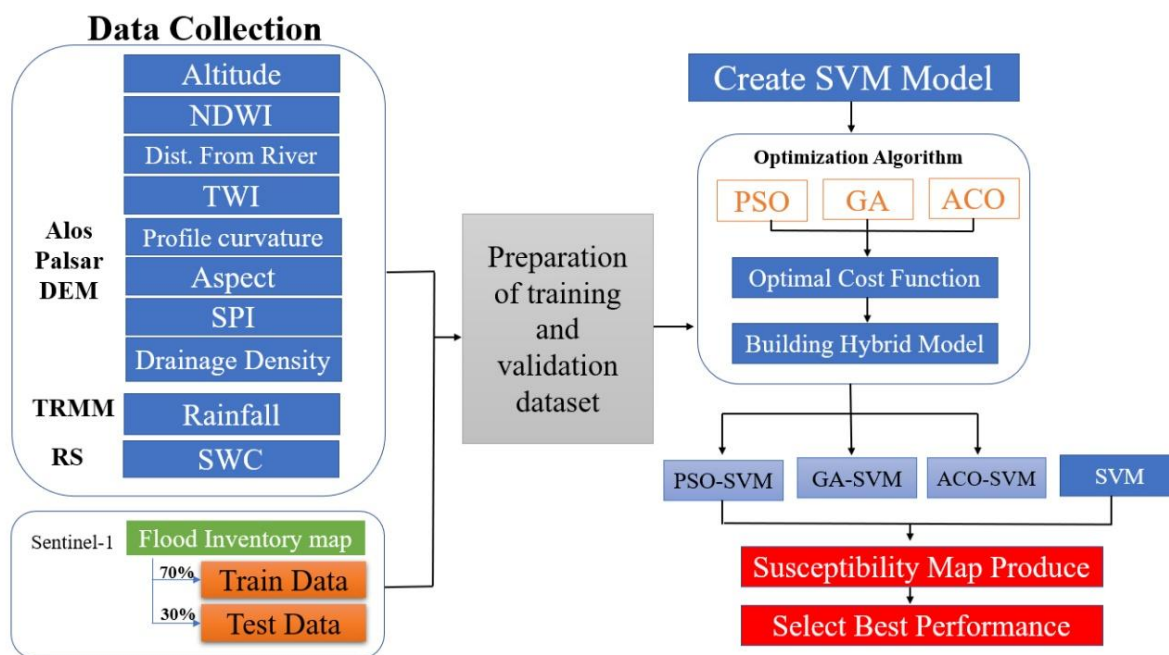


Fig. 1- Flowchart of developing the meta-optimized hybrid models for flood susceptibility mapping
 شکل ۱- روندنمای مدل بهینه‌سازی ترکیبی برای تولید نقشه‌های مناطق مستعد سیل

۲- مواد و روش‌ها

۱-۲- منطقه مورد مطالعه

منطقه مورد مطالعه در استان سیستان و بلوچستان در شرق ایران و در زیر حوضه هامون با مختصات $29^{\circ}08'$ تا $29^{\circ}44'$ عرض شمالی و $60^{\circ}36'$ تا $61^{\circ}00'$ طول شرقی قرار گرفته است (شکل ۲). مساحت این حوضه 1681 کیلومترمربع و دارای ارتفاعی بین 1122 تا 2541 متر از سطح دریاست. میانگین بارندگی سالانه در منطقه مورد مطالعه 69 میلی‌متر می‌باشد. از منظر کاربری اراضی، بخش عمده‌ای از حوضه تحت پوشش مراتع (72%) می‌باشد، 5% آن شامل مناطق شهری، 1% مناطق کشاورزی و مابقی کوه و صخره است. رودخانه فصلی لار در این منطقه، وظیفه زهکشی این حوضه را بر عهده دارد. سیلاب‌های این حوضه عامل آب‌گرفتگی شهر زاهدان در پایین دست حوضه است. این رودخانه از دامنه کوه‌های لار و پدگی از جنوب شرقی تا شمال شرقی شهر زاهدان سرچشمه می‌گیرد و از روستای همت‌آباد گذشته و وارد تنگه لار شده و سپس در ادامه از مرز کشور خارج شده و وارد کشور پاکستان می‌شود.

۲-۲- پیشینه نظری روش‌ها

۱-۲-۲- ماشین بردار پشتیبان

SVM یک تکنیک یادگیری ماشینی تحت نظارت است که بر اساس تئوری یادگیری آماری انجام می‌شود. با کمک یک مجموعه داده آموزشی، SVM داده‌های ورودی را در یک فضای ویژگی با ابعاد بالا ترسیم می‌کند و حداکثر حاشیه تفکیک بین کلاس‌ها را پیدا و یک ابر صفحه طبقه‌بندی را در منطقه مرکزی حداکثر حاشیه ایجاد می‌کند (Pradhan, 2013). بعد از آن، می‌توان از ویژگی‌های داده‌های جدید برای پیش‌بینی گروهی یک رکورد جدید استفاده کرد. جزئیات بیشتری از محاسبات و روابط داخلی SVM را می‌توان در مقالات (Tehrany et al., 2015; Hong et al. 2018; Pham et al., 2018) یافت.

عملگر کرنل 15 در مدل SVM از اهمیت فراوانی برخوردار است. انواع مختلف کرنل‌های مورد استفاده عبارت‌اند از: خطی 16 ، چندجمله‌ای 17 ، عملگر پایه رادیکال 18 و سیگموئید. لازم به ذکر است انتخاب نوع کرنل و دقت در مدل‌سازی تا حد زیادی به مجموعه داده مورد استفاده بستگی خواهد داشت. در این تحقیق، از هسته خطی برای مطالعه SVM استفاده شد.

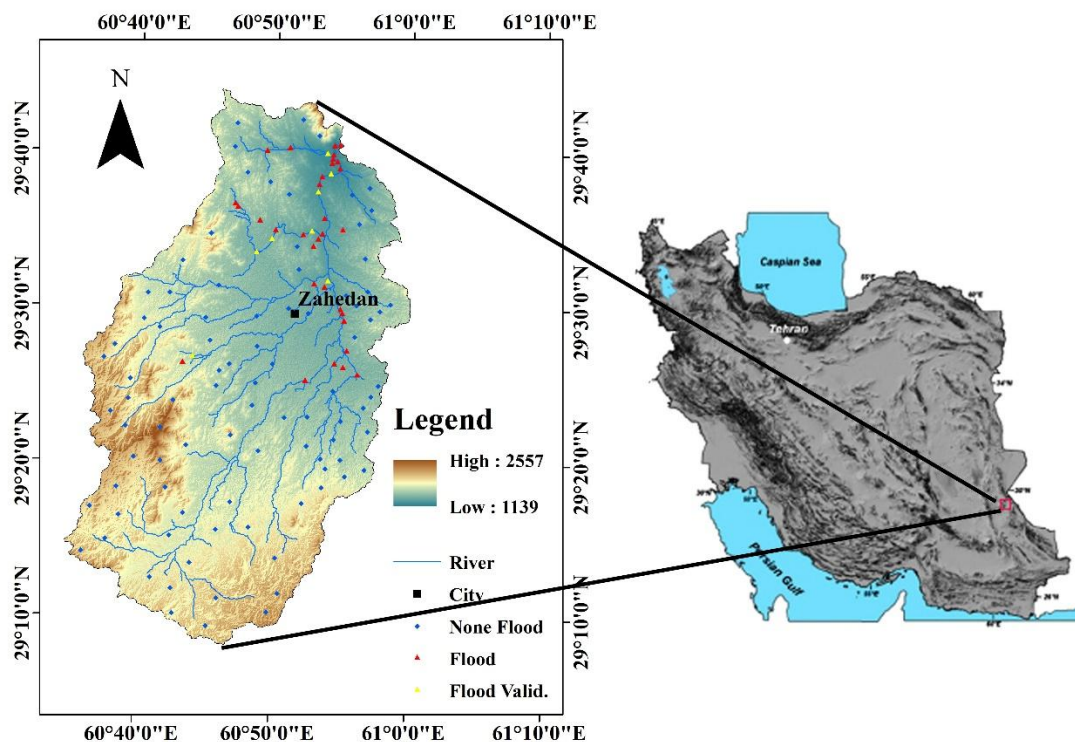


Fig. 2- Location of the study area
شکل ۲- موقعیت منطقه مورد مطالعه

می‌گذارد. نتیجه مدل‌سازی این رفتار اجتماعی فرایند جستجویی است که ذرات به سمت نواحی موفق میل می‌کنند. اساس کار PSO بر این اصل استوار است که در هر لحظه هر ذره مکان خود را در فضای جستجو با توجه به بهترین مکانی که تاکنون در آن قرار گرفته است و بهترین مکانی که در کل همسایگی‌اش وجود دارد، تنظیم می‌کند.

PSO با جمعیتی از ذرات که هر کدام بیانگر یک راه‌حل هستند آغاز می‌گردد که با موقعیت‌ها و سرعت‌های تصادفی در منطقه جستجو پراکنده می‌شوند (Liu et al., 2019). الگوریتم PSO در مقایسه با سایر الگوریتم‌های بهینه‌سازی فرا ابتکاری، دارای عملیات کمتر، سادگی بیشتر، با محاسبات کمتر و میزان همگرایی بالاتر می‌باشد (Panahi et al., 2021). به دلیل محدودیت تعداد صفحات، جزئیات و اطلاعات بیشتر مربوط به الگوریتم PSO در منابع (Shi and Eberhart, 1998; Al-Musaylh, 2018; Kim et al., 2021) اشاره شده است.

۲-۲-۳- الگوریتم بهینه‌سازی ژنتیک (GA)

الگوریتم ژنتیک توسط Holland (1992) از ایده‌های انتخاب طبیعی و ژنتیک طبیعی گرفته شده است. الگوریتم ژنتیک یک الگوریتم

از آنجاکه مقدار پارامترها می‌تواند بر دقت طبقه‌بندی SVM تأثیر بگذارد، به منظور کارایی بیشتر، لازم است از روش‌های بهینه‌سازی برای به دست آوردن پارامترهای بهینه، استفاده شود، بنابراین با استفاده از الگوریتم‌های فرا ابتکاری نسبت به بهینه‌سازی ضریب ^{۱۹}C اقدام گردید. C نشان‌دهنده دامنه تغییرات در برابر خطا است. هرچه C بالاتر باشد، میزان دامنه تغییرات مورد نیاز مدل کاهش می‌یابد. باین حال، مقدار بیش‌از حد C می‌تواند ظرفیت تعمیم یک SVM را تحت تأثیر قرار دهد (Marjanović et al., 2011).

۲-۲-۲- الگوریتم بهینه‌سازی ازدحام ذرات (PSO)

بهینه‌سازی ازدحام ذرات (PSO) یک روش بهینه‌سازی جمعیتی مبتنی بر هوش ازدحامی است که برای اولین بار توسط Kennedy and Eberhart (1995) با الهام از رفتارهای شکار دسته پرنده‌گان ارائه شد. یک الگوریتم بهینه‌سازی ازدحام ذرات باعث می‌شود که هر ذره در جمعیت با سرعت مشخصی از ذرات برتر فعلی پیروی کرده و به دنبال راه‌حل بهینه در منطقه باشد (Kim et al., 2021). در PSO، ذرات در فضای جستجو جاری می‌شوند. تغییر مکان ذرات در فضای جستجو تحت تأثیر تجربه و دانش خودشان و همسایگان‌شان است؛ بنابراین موقعیت دیگر توده ذرات روی چگونگی جستجوی یک ذره اثر

جستجوگر است که از ایده‌های انتخاب طبیعی و عملگرهای ژنتیکی تقاطع و جهش استفاده می‌کند. در هر نسل، جمعیت جدیدی از راه‌حل‌ها با تبادل و ترکیب اطلاعات به‌دست‌آمده از راه‌حل‌های نسل قبلی، ایجاد می‌شود.

مهم‌ترین تفاوت این است که الگوریتم ژنتیک روی جمعیتی از راه‌حل‌های ممکن کار می‌کند، درحالی‌که سایر روش‌های ابتکاری از یک راه‌حل واحد در تکرارهای خود استفاده می‌کنند. تفاوت دیگر این الگوریتم تصادفی بودن آن است. هر فرد در جمعیت الگوریتم ژنتیک یک راه‌حل ممکن را نشان می‌دهد. برخی از افراد بر اساس ارزش سازگاری انتخاب می‌شوند. سپس، الگوریتم ژنتیک از روند ژنتیکی طبیعت، برای تبادل برخی از این داده‌های ژنتیکی، به‌طور تصادفی برای تولید فرزندان تقلید می‌کند. این فرایندها تا زمانی که بهترین ژن‌ها که از بهترین توانایی برخوردار هستند به دست آید تکرار می‌گردد. هر فرد ممکن است نشان‌دهنده یک یا چند کروموزوم با ارزش سازگاری مرتبط باشد (Yen et al., 2011).

۲-۲-۴- الگوریتم بهینه‌سازی کلونی مورچگان (ACO)

الگوریتم کلونی مورچگان در سال ۱۹۹۲ توسط دوریگو معرفی گردید که رفتارهای مورچه‌های واقعی را در جستجوی کوتاه‌ترین مسیر به منابع غذایی شبیه‌سازی می‌کند (Dorigo, 1992). تعاملات مورچگان از طریق ماده شیمیایی فرمون^{۲۰} که از آن برای نشان‌گذاری مسیر استفاده می‌شود، انجام می‌گیرد. هر چه فرمون‌های بیشتری در مسیر قرار گیرد مابقی مورچه‌ها از این مسیر بیشتر استفاده می‌کنند؛ بنابراین، چنین کمیتی نشان می‌دهد که این مسیر به‌عنوان یکی از بهینه‌ترین و کوتاه‌ترین راه می‌باشد (Gupta and Srivastava, 2020).

رسوب و یا تبخیر فرمون ارتباط مستقیمی با تعداد مورچه‌هایی دارد که در آن مسیر سفر می‌کنند. مورچه‌ها با پیروی از حداکثر رسوب فرمون، مسیر بهینه را پیدا می‌کنند (Talatahari et al., 2013). جزئیات بیشتر این الگوریتم در منبع (Dorigo (1992 قابل دسترسی است.

۲-۳- جمع‌آوری و تهیه اطلاعات

۲-۳-۱- تجزیه و تحلیل انتخاب ویژگی

عوامل مختلفی بر وقوع سیل تأثیر می‌گذارند و نقش آن‌ها در سیلاب در مناطق مختلف متفاوت است (Fernández and Lutz, 2010). با این حال، هیچ راهنمای جهانی در مورد انتخاب عوامل تأثیرگذار برای هر بلایای طبیعی وجود ندارد (Rahmati et al., 2019). شناسایی مؤثرترین عوامل وقوع سیل و متغیرهایی که هیچ تأثیری بر

خصوصیات هیدرو محیطی ندارند برای بهبود مدل مکانی مناطق مستعد سیل بسیار مهم است (Panahi et al., 2021). بر اساس مطالعات و تحقیقات صورت گرفته قبلی (Panahi et al., 2021; Mahato et al., 2021; Pham et al., 2021; Dos et al., 2021; Darabi et al., 2018) ۱۹ فاکتور مختلف هیدرولوژیکی و ژئو مورفولوژیکی که در جدول ۱ نشان داده شده است، برای بررسی در نظر گرفته شد. تعیین عوامل مهم و مؤثر در سیل با استفاده از روش نسبت کسب اطلاعات (IGR^{۲۱}) ارزیابی گردید (Dai and Xu, 2013; Panahi et al., 2021). این روش یک رویکرد قوی برای انتخاب ویژگی است (Pham et al., 2019; Panahi et al., 2021; Pham et al., 2017). مقادیر بزرگ‌تر IGR نشانگر قابلیت پیش‌بینی بیشتر برای آن ویژگی خاص است (Panahi et al., 2021).

تکنیک‌های متعددی برای تشخیص صلاحیت و قابلیت پیش‌بینی متغیرهای اثرگذار بر وقوع یک پدیده وجود دارند؛ از جمله Fuzzy-Information Gain (Dubois & Prade, 1990)، Rough Sets (Hunter et al., 1990)، Information Gain Ratio (Quinlan, 1966).

پایه و اساس IG، تئوری اطلاعات است که با کاهش آنتروپی، صلاحیت اهمیت‌دار بودن عوامل مؤثر را تعیین کرده و به‌عنوان یک تکنیک استاندارد برای اندازه‌گیری توانایی پیش‌بینی عوامل اثرگذار بر وقوع یک پدیده در روش داده‌کاوی بررسی می‌گردد (Thien Bui et al., 2017). (Quinlan (1993 شاخص IGR را به‌این ترتیب پیشنهاد داد که مقادیر IGR بالاتر نشان‌دهنده توانایی پیش‌بینی بالاتر آن عامل مؤثر برای مدل‌سازی است.

اگر S داده‌های آموزشی با n نمونه ورودی و $n(L_i, S)$ تعداد نمونه‌ها در داده‌های آموزشی S متعلق به کلاس L_i (سیل، بدون سیل) باشد، در این صورت خواهیم داشت:

$$\text{Info}(S) = - \sum_{i=1}^2 \frac{n(L_i, S)}{|S|} \log_2 \frac{n(L_i, S)}{|S|} \quad (1)$$

با توجه به عوامل مؤثر بر وقوع زمین‌لغزش، مقدار اطلاعات موردنیاز برای تقسیم S به مجموعه (S_1, S_2, \dots, S_m) از رابطه زیر برآورد می‌گردد:

$$\text{Info}(S, A) = \sum_{j=1}^m \frac{S_j}{|S|} \text{Info}(S) \quad (2)$$

شاخص IGR برای یک عامل مؤثر خاص مثل فاکتور A (به‌عنوان مثال: درجه شیب) از رابطه زیر محاسبه می‌شود:

$$\text{Information Gain Ratio}(S, A) = \frac{\text{Info}(S) - \text{Info}(S, A)}{\text{Split info}(S, A)} \quad (3)$$

که در آن split info نشان‌دهنده اطلاعات تولیدشده توسط تقسیم S داده‌های آموزشی به m زیرمجموعه است که از رابطه زیر محاسبه می‌گردد:

$$\text{Split Info}(S,A) = - \sum_{j=1}^m \frac{S_j}{|S|} \log_2 \frac{|S_j|}{|S|} \quad (4)$$

از بین ۱۹ عامل بررسی‌شده، تعداد ۱۰ عامل که دارای بیشترین مقدار IGR هستند برای استفاده در این تحقیق انتخاب شد (جدول ۱)، پس از انتخاب بهترین عوامل مؤثر از بین عوامل در نظر گرفته‌شده، آزمایش تشخیصی هم‌خطی چندگانه (MCDT^{۲۳})، به منظور بررسی عدم تداخل اثربخشی عوامل مختلف، انجام شد. برای این منظور، از ضریب تورم واریانس (VIF^{۲۴}) و معیارهای تحمل (رواداری) استفاده گردید، که $VIF > 10$ و معیار تحمل کمتر از ۰/۱ نشان‌دهنده حد آستانه برای چندخطی بودن عوامل است (Panahi et al., 2021).

۲-۳-۲- پایگاه داده‌های مکانی عوامل سیل

عوامل نهایی استخراج‌شده به ترتیب عبارت‌اند از: بارش سالانه، تراکم زهکشی، ارتفاع، شاخص نرمال تفاوت رطوبت (NDWI^{۲۵})، فاصله از رودخانه، شاخص رطوبت توپوگرافی (TWI^{۲۶})، محتوای آب در خاک (SWC^{۲۷})، انحنای نیمرخ، وجه شیب و شاخص توان آبراهه (SPI^{۲۸})، کلیه عوامل توپوگرافی مورد استفاده در این تحقیق، از یک مدل رقومی ارتفاع (DEM^{۲۹}) که از سازمان فضایی ایالات متحده (NASA) با رزولوشن $12/5 \times 12/5$ متر، تهیه گردیده، محاسبه شده است. در این تحقیق، داده‌های بارندگی سالانه از داده‌های موجود در پایگاه اطلاعات اندازه‌گیری بارش باران مناطق گرمسیری (TRMM^{۳۰}) و بخش

تحقیقات زمین سازمان هوایی ایالات متحده، به صورت تجمعی برای مدت‌زمان ۲۳ سال (۱۹۹۸ تا ۲۰۲۰) با وضوح مکانی ۰/۲۵ درجه، به دست آمده که در شکل ۳-الف نشان داده شده است. تراکم زهکشی یکی از ویژگی‌های اساسی سیستم رودخانه است که در صورت بروز بارندگی در حوضه آبریز، دارای تأثیر زیادی در دبی پیک جریان می‌باشد (Lee et al., 2019). تراکم زهکشی به نسبت طول کل رودخانه به سطح حوضه اشاره دارد. همچنین، این شاخص یک عامل مهم هیدروژئومورفولوژی در تعیین چگونگی فرآیندهای رواناب سطحی، شدت سیلاب و میزان فرسایش خاک می‌باشد. تراکم زهکشی منطقه مورد مطالعه در شکل ۳-ب نشان داده شده است. ارتفاع (شکل ۳-ج) یک عامل تأثیرگذار اصلی است که می‌تواند به صورت مستقیم در ایجاد سیل مؤثر باشد. (Khosravi et al., 2019) در تحقیقات خود اشاره کرده‌اند که ارتفاع از سطح زمین تأثیر زیادی در خطر سیلاب ناگهانی دارد. این مناطق می‌تواند تحت تأثیر بارندگی و آورد سیلاب از مناطق و حوضه‌های بالادست خود باشند. همچنین، در تحقیقات (Panahi et al., 2021) اشاره شده است که مناطق کم ارتفاع، جریان آب را از مناطق اطراف با ارتفاعات بالاتر با میزان بارندگی بیشتر دریافت می‌کنند. شاخص تفاوت رطوبت نرمال شده است که یک شاخص ماهواره‌ای مشتق شده از کانال‌های نزدیک مادون قرمز (NIR) و موج کوتاه مادون قرمز (SWIR) است. این شاخص در تشخیص مناطق دارای پوشش گیاهی بسیار مفید و مؤثر می‌باشد؛ در مناطقی که دارای پوشش گیاهی بیشتری می‌باشد، مقدار این شاخص بالاتر از مناطق دارای پوشش گیاهی کمتر خواهد بود و یا به عبارت دیگر مقدار این شاخص ارتباط مستقیم با پوشش گیاهی دارد.

Table 1- IGR analysis and MCDT for selected flood factors
جدول ۱- IGR و آزمون تشخیص چندخطی برای عوامل مؤثر

Variable Name	IGR	Collinearity statistics		Variable Name	IGR	Collinearity statistics	
		Tolerance	VIF			Tolerance	VIF
Rainfall	0.8905	0.65	1.54	Plan Curvature	0.4333	-	-
Drainage Density	0.8905	0.586	1.707	Slope	0.4131	-	-
Altitude	0.8751	0.368	2.718	STI	0.3449	-	-
NDWI	0.8374	0.834	1.199	TRI	0.2389	-	-
Dist. from River	0.8327	0.689	1.452	CN	0.1305	-	-
TWI	0.7886	0.849	1.178	Geology	0.1252	-	-
Soil water content	0.7674	0.634	1.577	Curvature	0.1182	-	-
Profile Curvature	0.5048	0.920	1.087	TPI	0.0816	-	-
Aspect	0.498	0.920	1.087	LULC	0.0121	-	-
SPI	0.4499	0.898	1.113				

(al., 2021). در مطالعه حاضر، یک نقشه مشخصه سیل با استفاده از داده‌های ماهواره سنتینل ۱ تهیه و توسط نقاط کنترل زمینی صحت‌سنجی گردید. به این منظور، از دو تصویر ماهواره Sentinel-1 (GRD, IW) در تاریخ‌های ۱۳ ژانویه ۲۰۲۰ (زمان وقوع بارندگی که بیش از نیمی از استان سیستان و بلوچستان در شرق ایران از جمله منطقه مورد مطالعه را درگیر سیل نمود) و ۱۸ ژانویه ۲۰۱۹، برای شناسایی مکان‌های سیل‌زده در منطقه مورد مطالعه استفاده گردید. با استفاده از نرم‌افزارهای SNAP 8.0 و ArcGIS 10.6، داده‌ها به ترتیب پیش‌پردازش و پردازش شدند. اطلاعات کامل در خصوص مراحل پیش‌پردازش و پردازش در منبع (Mohammadi et al., 2020) قابل‌دسترسی می‌باشد. با استفاده از این مدل می‌توان مناطق سیل‌زده را به راحتی شناسایی و ثبت نمود. نقشه تولید شده در این مرحله در شکل ۴ نشان داده شده است. مناطق سیل‌زده در این نقشه، به رنگ قرمز قابل مشاهده می‌باشد. تعداد ۴۰ نقطه به صورت تصادفی در نقاط سیل‌زده به عنوان نقشه مشخصه سیلاب انتخاب و به منظور بررسی صحت نقشه به دست آمده، از ۸ نقطه (۲۰ درصد نقاط) با کمک دستگاه GPS، بازدید گردید که در این نقاط آثار سیل به وضوح مشخص بود.

۲-۴- توسعه مدل

از نقشه تولید شده در مرحله قبل، ۹۰ نقطه نیز از مکان‌هایی که در آن‌ها مشخصه آب‌گرفتگی وجود نداشت، به عنوان مکان‌های غیر سیلابی انتخاب گردید و با نقاط قبلی به صورت یک مجموعه داده ترکیب شد. با توجه به سیستم باینری مدل، به همه مکان‌های سیل‌زده و غیر سیلابی (۱۳۰ نقطه به دست آمده)، به ترتیب کد ۱ و صفر اختصاص داده شد. سپس، با استفاده از روش انتخاب تصادفی، داده‌های موجود به دو مجموعه ۹۰ نقطه‌ای (۷۰ درصد داده‌ها) برای استفاده در آموزش و ۴۰ نقطه‌ای (۳۰ درصد داده‌ها) برای آزمایش مدل، تقسیم گردید (نقش پراکندگی نقاط در شکل ۱ نشان داده شده است).

از این مجموعه نقاط که شامل ویژگی‌های انتخاب شده مؤثر بر سیل است، برای بهینه‌سازی مدل SVM و همچنین تولید مدل مناطق مستعد سیل استفاده گردید. در ابتدا مجموعه داده به صورت یک ماتریس که شامل نقاط سیل‌زده و غیر سیلابی است، در نرم‌افزار MATLAB فراخوانی گردید. مقدار ثابت C در مدل SVM با استفاده از الگوریتم‌های PSO، GA و ACO که در محیط برنامه کد نویسی شده بود، با به حداقل رساندن تابع هزینه به عنوان تابع هدف، بهینه‌سازی گردید.

نقشه مربوط به این عامل که با استفاده از تصاویر ماهواره لندست ۸ تهیه شد در شکل ۳-۵ نشان داده شده است. عامل مهم دیگر که به طور قابل توجهی در سیل تأثیر می‌گذارد فاصله تا رودخانه (مجاورت با رودخانه) است (Panahi et al., 2021). خطر سیل در مناطقی با فاصله نزدیک به رودخانه بیشتر خواهد بود. نقشه فاصله تا رودخانه بر اساس شبکه رودخانه حوضه که با مدل رقومی ارتفاع به دست آمده، ترسیم شده است (شکل ۳-۵). عامل دیگری که در این تحقیق استفاده شده است، شاخص رطوبت توپوگرافی (TWI) پارامتری از وضعیت رطوبت خاک است که در بسیاری از تحقیقات بکار برده شده است (Rahmati et al., 2019; Balogun et al., 2021). نقشه شاخص TWI منطقه مورد مطالعه به وسیله مدل رقومی ارتفاع تولید گردید که در شکل ۳-۶ و نشان داده شده است. از آنجائی که رطوبت خاک یکی از عوامل مهم و مؤثر در میزان رواناب است، لذا خاک‌های خشک دارای پتانسیل کمتری برای تولید رواناب نسبت به خاک‌های مرطوب را دارند (Grillakis et al., 2016). رطوبت خاک در اعماق مختلف آن متغیر می‌باشد، ولی عمق مؤثر رطوبت در اکثر فرایندهای مرتبط، مربوط به ۱۰ سانتی‌متری بالای خاک می‌باشد. در این مطالعه با استفاده از داده‌های موجود در سایت سازمان هواپی ایالات متحده^{۳۱} نسبت به تهیه نقشه میانگین ۱۱ ساله (۲۰۱۰ تا ۲۰۲۰) محتوای آب در خاک در عمق ۰ تا ۱۰ سانتی‌متری بالای خاک اقدام گردید که در شکل ۳-۷ نشان داده شده است. لازم به ذکر است از این شاخص برای تولید نقشه‌های سیل‌خیزی، برای نخستین بار، در این تحقیق استفاده گردیده است. انحنای نیمرخ (شکل ۳-۸) نیز از عوامل مهم تأثیرگذار در سیل است که مناطق شتاب جریان را نشان می‌دهد (Panahi et al., 2021). وجه شیب یکی از اصلی‌ترین عواملی است که به صورت غیرمستقیم از طریق تأثیر بر محتوای رطوبت خاک و پوشش گیاهی در وقوع سیل مؤثر می‌باشد (Panahi et al., 2021). نقشه وجه شیب منطقه مورد مطالعه که از مدل رقومی ارتفاع تهیه گردیده، در شکل ۳-۹ ارائه شده است. شاخص توان آبراهه (SPI) یک ویژگی توپوگرافی است که برای توصیف و فرآیندهای مرتبط با آبراهه‌ها، استفاده می‌شود. این شاخص با درجه شیب و مساحت حوضه آبریز، رابطه مستقیم دارد (Balogun et al. 2021)؛ بنابراین وقتی سرعت جریان سطحی افزایش پیدا می‌کند، شاخص توان آبراهه و ریسک فرسایش افزایش می‌یابد. مقادیر SPI محاسبه شده از مدل ارتفاع رقومی، در شکل ۳-۱۰ نشان داده شده است.

۲-۳-۳- نقشه مشخصه سیل (FIM^{۳۲})

نقشه مشخصه سیل که مکان سیل‌های تاریخی را نشان می‌دهد، پیش‌شرط مدل‌سازی مکانی مناطق مستعد سیل است (Panahi et

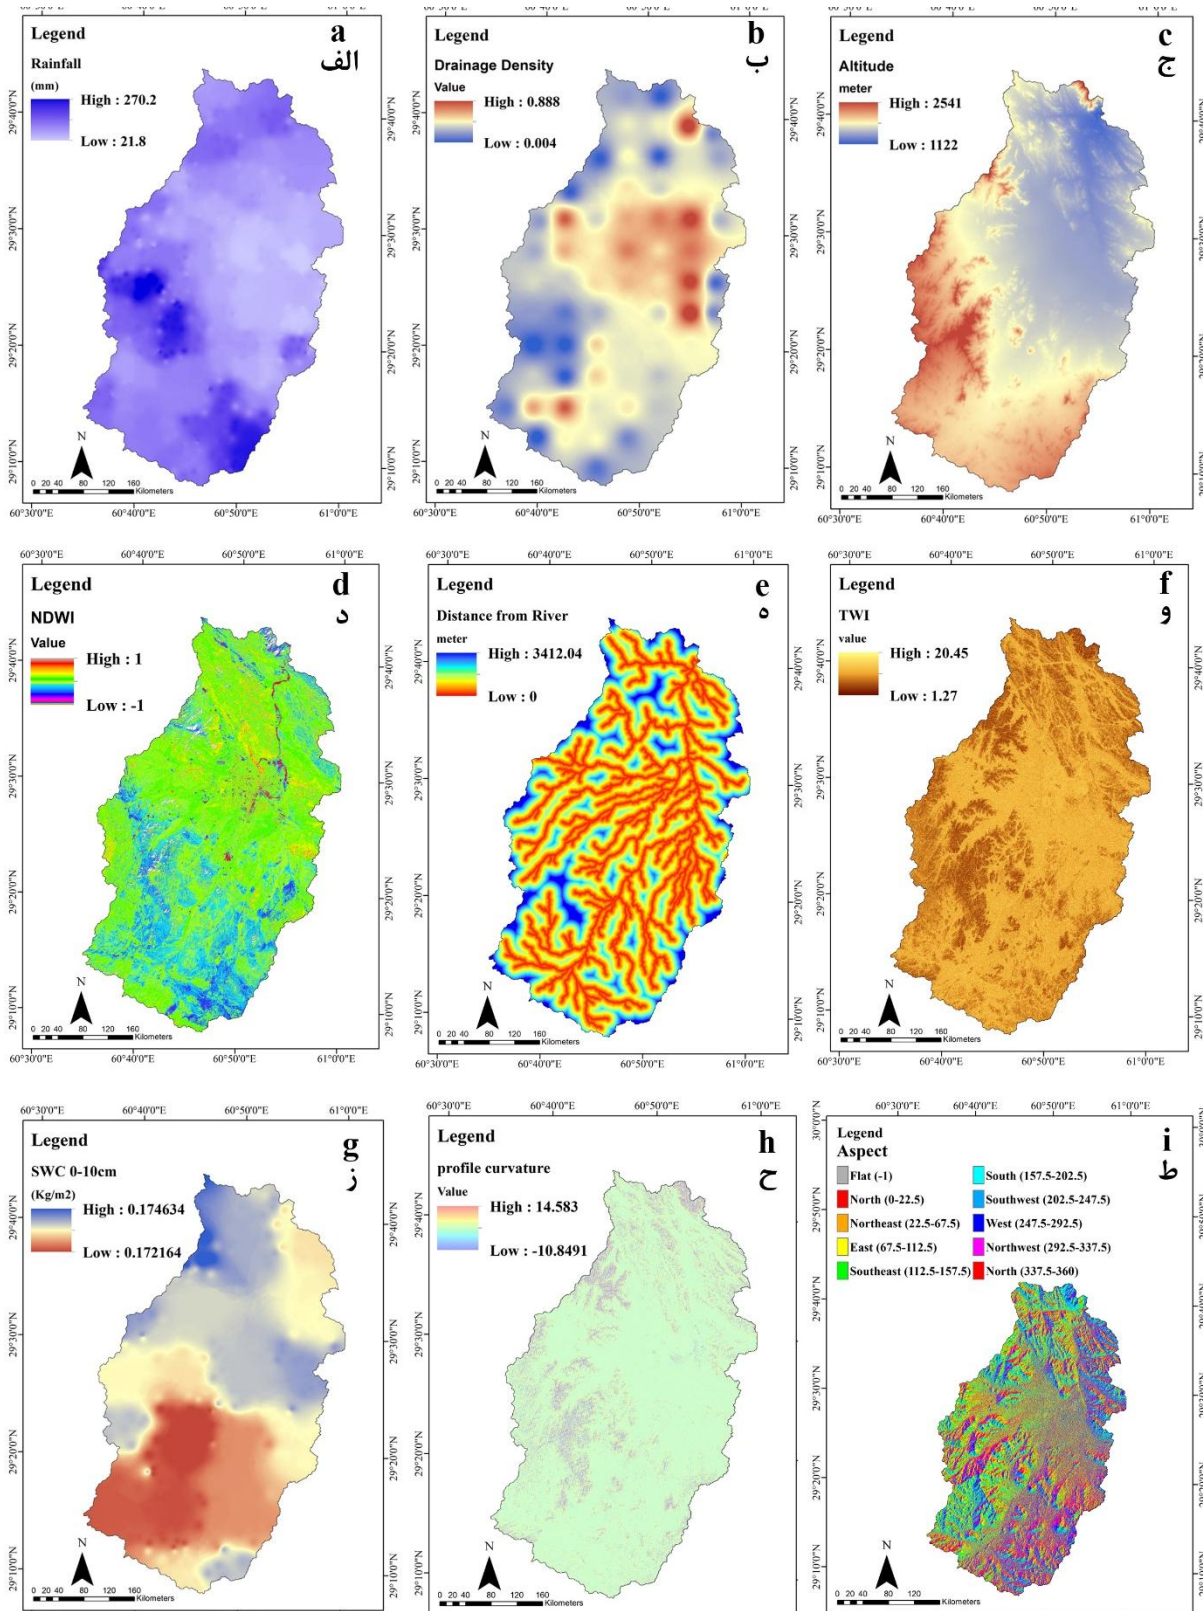


Fig. 3- Flood conditioning factors influencing the flood occurrence in the study area

شکل ۳- عوامل مؤثر در وقوع سیل در منطقه مورد مطالعه

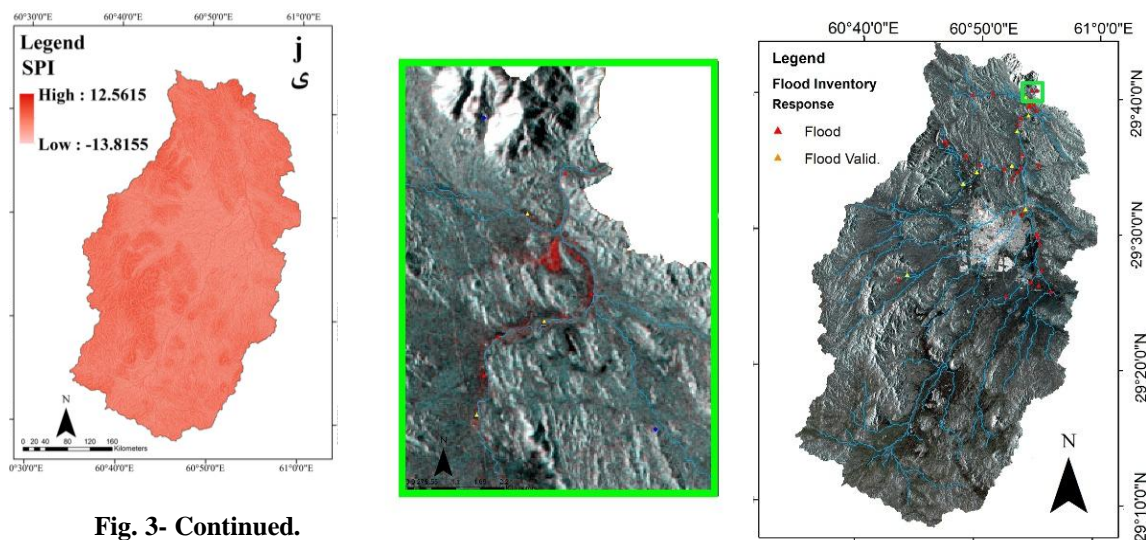


Fig. 3- Continued.
شکل ۳- ادامه

و نرخ مثبت کاذب (۱- ویژگی) در محور عمودی است. از مساحت زیر منحنی (AUC) ROC برای ارزیابی کمی مدل‌های ترکیبی استفاده می‌شود. مقادیر AUC بین ۰ (مدل کاملاً غیرمفید) و ۱ (مدل کاملاً کارآمد) متغیر می‌باشد (Evans et al., 2005). مقادیر بالای AUC، مدل‌های بهتری را نشان می‌دهد. مقدار AUC کمتر از ۰/۶ نشانگر عملکرد ضعیف، ۰/۶ تا ۰/۷ نشانگر عملکرد متوسط، ۰/۷ تا ۰/۸ نشانگر عملکرد خوب و بزرگ‌تر از ۰/۸ عملکرد بسیار خوب است.

۳- نتایج و بحث

۳-۱- شناسایی مؤثرترین عوامل سیل

همپوشانی نقشه مناطق مستعد سیل با محتوای آب در خاک نشان می‌دهد که مناطق دارای بیشترین میزان رطوبت در خاک، دارای استعداد بیشتری برای سیل می‌باشد. اگرچه بر اساس نتایج IGR، سیلاب به شدت به پارامتر بارندگی بستگی دارد، اما نتایج نقشه‌های تولیدشده نشان می‌دهد که اکثر مناطق مستعد سیل در مناطقی است که دارای بارندگی متوسط تا کم می‌باشد؛ این مسئله می‌تواند ناشی از شرایط مورفولوژیکی حوضه نیز باشد، همان‌گونه که در مطالعات (Tehrany et al., 2015) اشاره شده است که مناطق کم ارتفاع، جریان آب را از مناطق اطراف با ارتفاعات بالاتر با میزان بارندگی بیشتر دریافت می‌کنند. همچنین به صورت مشابه، همپوشانی نقشه مناطق مستعد سیل با نقشه تراکم زهکشی منطقه، نشان می‌دهد که مناطق دارای بیشترین تراکم زهکشی، دارای استعداد بیشتری برای آب‌گرفتگی می‌باشد.

۲-۵- تولید نقشه

بعد از بهینه‌سازی مدل SVM، نسبت به تولید ۳ مدل بهینه‌سازی شده اقدام گردید و با استفاده از این مدل‌ها، نقشه‌های طبقه‌بندی مکانی مناطق مستعد سیل برای منطقه مورد مطالعه تولید گردید. در این مطالعه، از روش طبقه‌بندی شکست طبیعی^{۳۳} برای طبقه‌بندی مقادیر، به گروه‌هایی با حداقل واریانس درون کلاس استفاده شد. این الگوریتم طبقه‌بندی، با به حداقل رساندن اختلافات درون کلاس‌ها و به حداکثر رساندن اختلافات بین کلاس‌ها، شکاف‌های کلاس را مشخص می‌کند (Choubin et al., 2019). این روش معمولاً در نقشه‌های موضوعی به کار می‌رود تا تجسم معنادارتری از داده‌های جغرافیایی را بر اساس شکاف‌های طبیعی داده‌ها فراهم کند (Panahi et al., 2021).

۲-۶- ارزیابی و مقایسه مدل‌ها

عملکرد مدل‌های توسعه‌یافته، با استفاده از معیارهای آماری برازش مناسب، مانند خطای میانگین مربعات (RMSE^{۳۴}) و میانگین خطای مطلق (MAE^{۳۵}) ارزیابی گردید. معیارهای آماری فوق‌الذکر به تنهایی برای ارزیابی مدل‌ها کافی نیست، زیرا RMSE و MAE بر اساس ارزیابی خطا صورت می‌گیرد (Panahi et al., 2021). بنابراین، از روش مشخصه عملکرد گیرنده (ROC^{۳۶}) برای ارزیابی مدل بهینه‌سازی شده SVM استفاده شد. منحنی ROC اغلب در ارزیابی نقشه مناطق مستعد سیل استفاده شده است (Panahi et al., 2021; Khosravi et al., 2016; Choubin et al., 2019). منحنی ROC یک منحنی دوبعدی است که دارای نرخ‌های مثبت بر روی محور افقی

۳-۲- پیش‌بینی مناطق مستعد سیل

نقشه‌های پیش‌بینی مکانی مناطق مستعد سیل با استفاده از مدل SVM و مدل‌های ترکیبی فرا ابتکاری بهینه‌شده PSO-SVM، GA-SVM و ACO-SVM، در شکل ۵ ارائه شده است.

در آزمایش بررسی هم‌خطی چندگانه عوامل، تمام فاکتورهای سیل دارای مقادیر VIF کمتر از ۱۰ و مقادیر تحمل بیشتر از ۰/۱ بودند که نشان‌دهنده عدم همپوشانی این عوامل بر هم است (جدول ۱). ارتفاع دارای بالاترین مقدار VIF (۲/۷۱۸) و کمترین میزان رواداری (۰/۳۶۸) بود؛ که به دلیل ماهیت این پارامتر و تفاوت آن با عوامل دیگر است (Panahi et al., 2021). نتایج مشابهی توسط Panahi et al. (2018) و (2021) به دست آمده است.

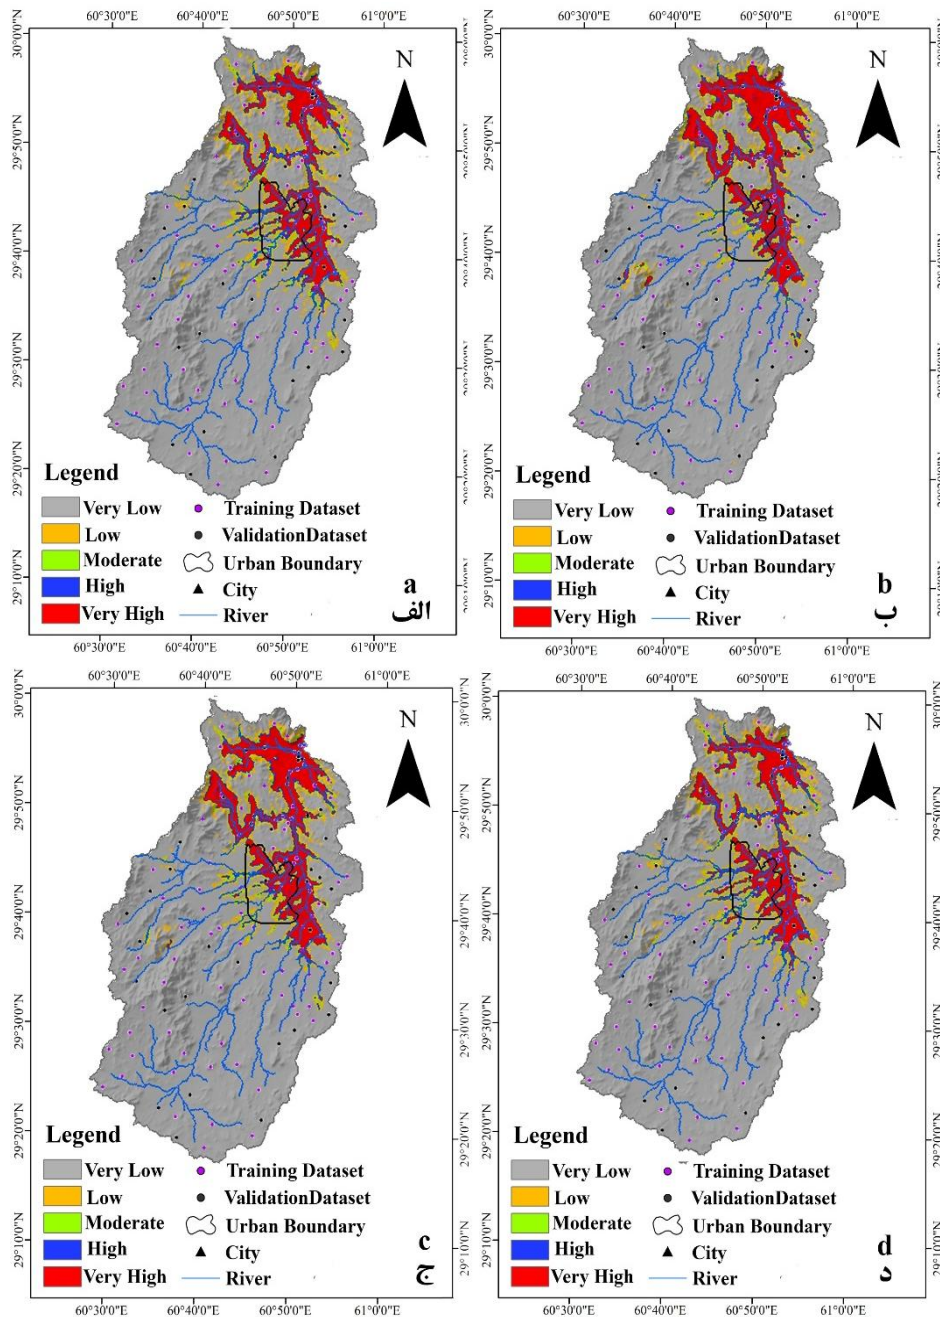


Fig. 5- Flood susceptibility maps using (a) SVM model (b) PSO-SVM (c) GA-SVM (d) ACO-SVM models
 شکل ۵- نقشه پیش‌بینی مکانی مناطق مستعد سیل الف- مدل SVM، ب- PSO-SVM، ج- GA-SVM و د- ACO-SVM

موجود می‌باشد (بالاترین مقدار AUC و کمترین مقادیر RMSE, MSE و Std). به‌طور کلی، نتایج نشان داد که هر سه مدل ترکیبی مورد استفاده، عملکرد SVM بر اساس شاخص AUC به‌طور متوسط حدود ۴٪ بهبود بخشیده است که بیشترین مقدار، مربوط به مدل PSO-SVM با ۶ درصد بهبود عملکرد می‌باشد.

نتایج این تحقیق نشان می‌دهد که الگوریتم‌های PSO, ACO و GA به ترتیب، بهترین عملکرد را در منطقه مورد مطالعه داشته‌اند. همچنین الگوریتم فرا ابتکاری کلونی مورچگان (ACO) که برای اولین بار برای بهینه‌سازی مدل SVM در این تحقیق استفاده شده است، موجب بهبود عملکرد مدل SVM شده است.

در جدول ۳، درصد مناطق کلاس‌های مختلف خطر (خیلی کم، کم، متوسط، زیاد و خیلی زیاد) در نقشه‌های مناطق مستعد سیل تولید شده، نشان داده شده است. مدل ACO-SVM درصد کمتری از پیکسل‌ها را به‌عنوان حساسیت بسیار زیاد (۹/۲٪) در مقایسه با مدل‌های PSO-SVM (۱۱/۵٪) و GA-SVM (۱۰/۹٪) طبقه‌بندی کرده است (جدول ۳).

یکی از اهداف تولید نقشه مناطق مستعد سیل، استفاده در برنامه‌ریزی مخاطرات به‌صورت ویژه در مناطق شهری می‌باشد، و از طرفی با توجه به اینکه شهرستان زاهدان، یکی از کلان‌شهرهای ایران در منطقه مورد مطالعه قرار دارد، بر اساس بهترین مدل تولید شده (PSO-SVM)، تقریباً ۴۸ درصد ناحیه شهری در مناطق خطر متوسط تا خطر بسیار زیاد قرار دارد که باید در برنامه‌ریزی‌های پیشگیری از وقوع سیل، در اولویت قرار گیرد (شکل ۵).

بر اساس پیش‌بینی‌های مدل، مناطق مرکزی و شمالی حوضه، حساسیت بیشتری به سیل دارد. از طرفی بیشتر این مناطق در نواحی کم ارتفاع منطقه مورد مطالعه قرار گرفته است. Tehrany et al. (2015) و Khosravi et al. (2018) در تحقیقات خود اشاره کرده‌اند که ارتفاع از سطح زمین تأثیر زیادی در خطر سیلاب ناگهانی دارد. این مناطق می‌تواند تحت تأثیر بارندگی و آورد سیلاب از مناطق و حوضه‌های بالادست خود باشند.

۳-۳- اعتبارسنجی و مقایسه مدل‌ها

نقاط مشخصه سیلاب، در کلاس‌های حساسیت زیاد و بسیار زیاد قرار دارند که قدرت پیش‌بینی خوبی از مدل‌ها را نشان می‌دهند. نتایج به‌دست‌آمده از ۴ مدل استفاده‌شده در جدول ۲ نشان داده شده است. نتایج نشان می‌دهد که هر ۳ مدل ترکیبی مورد استفاده، عملکرد بهتری نسبت به مدل SVM داشته است.

مدل ترکیبی GA-SVM در مرحله آموزش، عملکرد بهتری را در مقایسه با ۲ مدل ترکیبی دیگر (ACO-SVM, PSO-SVM) نشان داد. در حالی که، مدل PSO-SVM در مرحله اعتبارسنجی، عملکرد بهتری نسبت به مدل‌های دیگر ترکیبی داشت (جدول ۲).

از آنجائی که عملکرد و انطباق خوب یک مدل، بر اساس مجموعه داده آزمایش تعیین می‌شود (Panahi et al., 2021; Ahmadi et al., 2019; Lee et al., 2019). بنابراین، نتایج نشان می‌دهد که مدل ترکیبی PSO-SVM با توجه به نتایج معیارهای سنجش خوبی برآزش به‌دست‌آمده در این مطالعه، بهترین عملکرد را برای مدل‌سازی مناطق مستعد سیل دارد و نتایج به‌دست‌آمده منطبق بر رخدادهای مشاهداتی

Table 2- Accuracy assessment of the hybrid models

جدول ۲- نتایج ارزیابی دقیق مدل‌های ترکیبی

Step	Model	AUC	RMSE	MSE	Std ³⁸
Training	SVM	0.887	0.258	0.077	0.474
	PSO-SVM	0.967	0.258	0.066	0.481
	GA-SVM	0.990	0.236	0.055	0.456
	AC-SVM	0.954	0.279	0.066	0.470
Validation	SVM	0.890	0.418	0.175	0.439
	PSO-SVM	0.953	0.158	0.025	0.405
	GA-SVM	0.909	0.316	0.100	0.483
	AC-SVM	0.932	0.274	0.075	0.456

Table 3- Area percentage reproduced for each flood susceptibility class

جدول ۳- درصد مناطق هر کلاس در نقشه‌های مناطق مستعد سیل

Model	Very Low	Low	Moderate	High	Very High
SVM	78.203	6.630	3.107	2.725	9.334
PSO-SVM	79.609	4.613	2.271	1.994	11.514
GA-SVM	79.116	5.179	2.568	2.240	10.896
AC-SVM	78.325	6.668	3.043	2.688	9.276

۴- جمع‌بندی و نتیجه‌گیری

پی‌نوشت‌ها

- 1- Multi-Criteria Decision Making
- 2- Artificial Intelligence
- 3- Machine Learning
- 4- Computational Intelligence
- 5- Soft Calculations
- 6- Data Mining
- 7- Intelligent Data Analysis
- 8- Flood Susceptibility Mapping
- 9- Support Vector Machine
- 10- Grasshopper Optimization Algorithm
- 11- Particle Swarm Optimization
- 12- Imperial Competitive Algorithm
- 13- Genetic Algorithm
- 14- Ant Colony Optimization
- 15- Kernel
- 16- Linear
- 17- Polynomials
- 18- Radical Base Function (RBF)
- 19- Box Constraint
- 20- Pheromone
- 21- Information Gain Ratio
- 22- Multi Collinearity Diagnostic Test
- 23- Variance Inflation Factor
- 24- Tolerance
- 25- Normalized Difference Water Index
- 26- Topographic Wetness Index
- 27- Soil Water Content
- 28- Stream Power Index
- 29- Digital Elevation Model
- 30- Tropical Rainfall Measuring Mission
- 31- <https://giovanni.gsfc.nasa.gov/giovanni>
- 32- Flood Inventory Map
- 33- Natural Break Classification Method
- 34- Root Mean Square Error
- 35- Mean Absolute Error
- 36- Receiver Operating Characteristic
- 37- Area Under Curve
- 38- Standard Deviation

انتخاب فاکتورهای مؤثر بر سیل، نقش مهمی در دقت و کارایی مدل‌های تولیدشده دارد. بر اساس نتایج IGR، تمامی فاکتورهای مورد استفاده در این مدل‌سازی، به خوبی انتخاب گردیده است، همچنین فاکتور محتوای آب در خاک که برای نخستین بار در این مطالعه مورد استفاده قرار گرفته است، نقش مؤثری را در بین فاکتورهای انتخابی دارد. لازم به ذکر است در تحقیقات گذشته، به طور غیرمستقیم اثر رطوبت خاک از طریق فاکتورهای مختلف لحاظ می‌گردیده است؛ اما در این تحقیق، این عامل مهم را برای اولین بار و به صورت صریح در مطالعه گنجانده شده است که منجر به بهبود نتایج گردیده. مدل‌سازی مکانی مناطق مستعد سیل و شناسایی مناطق حساس در برابر سیل، کاربرد مهمی در کاهش اثرات سیل دارد. در این تحقیق، برای به دست آوردن پیش‌بینی‌های دقیق‌تر، از ترکیب یک مدل قوی یادگیری ماشینی (SVM) با الگوریتم‌های بهینه‌سازی PSO، GA و ACO استفاده گردید که مدل ترکیبی ACO-SVM برای نخستین بار در این مطالعه مورد استفاده قرار گرفته است.

تمامی مدل‌های استفاده‌شده، عملکرد بهتری را نسبت به مدل SVM نشان داد. مدل GA-SVM در مرحله آموزش، عملکرد بهتری نسبت به سایر مدل‌ها داشت در صورتی که مدل PSO-SVM در مرحله آزمایش و صحت‌سنجی عملکرد بهتری از خود نشان داد. به صورت کلی، تمامی مدل‌های ترکیبی استفاده‌شده باعث بهبود عملکرد مدل SVM شده است. نتایج این مطالعه کارایی مدل‌های پیشنهادی برای پیش‌بینی مکانی مناطق مستعد سیل را تأیید می‌کند. از آنجایی که تقریباً نیمی از منطقه شهری زاهدان در مناطق خطر متوسط تا بسیار زیاد قرار دارند، لذا باید توجه ویژه‌ای به این منطقه به منظور جلوگیری از وقوع سیل، نمود.

۶- مراجع

- Ahmadlou M, Karimi M, Alizadeh S, Shirzadi A, Parvinnejhad D, Shahabi H, and Panahi M (2019) Flood susceptibility assessment using integration of Adaptive Network-Based Fuzzy Inference System (ANFIS) and Biogeography-Based Optimization (BBO) and BAT Algorithms (BA). *Geocarto International* 34(11):1252-1272
- Alizadeh Z, Yazdi J, Kim JH, and Al-Shamiri AK (2018) Assessment of machine learning techniques for monthly flow prediction. *Water* 10(11)
- Al-Musaylh MS, Deo RC, Li Y, and Adamowski JF (2018) Two-phase particle swarm optimized-support vector regression hybrid model integrated with improved empirical mode decomposition with adaptive noise for multiple-horizon electricity demand forecasting. *Applied Energy* 217:422-439
- Balogun, AL, Rezaie F, Pham QB, Gigović L, Drobnjak S, Aina YA, Lee S (2021) Spatial prediction of landslide susceptibility in western Serbia using hybrid Support Vector Regression (SVR) with GWO, BAT and COA algorithms. *Geoscience Frontiers* 12(3):101104
- Choubin B, Moradi E, Golshan M, Adamowski J, Sajedi-Hosseini F, and Mosavi A (2019) An ensemble prediction of flood susceptibility using multivariate discriminant analysis, classification and regression trees, and support vector machines. *Science of The Total Environment* 651:2087-2096
- Dai J and Xu Q (2013) Attribute selection based on information gain ratio in fuzzy rough set theory with application to tumor classification. *Applied Soft Computing* 13(1):211-221
- Darabi H, Choubin B, Rahmati O, Torabi Haghighi A, Pradhan B, and Kløve B (2019) Urban flood risk mapping using the GARP and QUEST models: A comparative study of machine learning techniques. *Journal of Hydrology* 569:142-154
- Das S and Gupta A (2021) Multi-criteria decision based geospatial mapping of flood susceptibility and temporal hydro-geomorphic changes in the Subarnarekha basin, India. *Geoscience Frontiers* 12(5):101206
- Dodangeh E, Panahi M, Rezaie F, Lee S, Bui DT, Lee CW, and Pradhan B (2020) Novel hybrid intelligence models for flood-susceptibility prediction: Meta optimization of the GMDH and SVR models with the genetic algorithm and harmony search. *Journal of Hydrology* 590:125423
- Dorigo M (1992) Optimization, learning and natural algorithms. Ph. D. Thesis Politecnico di Milano
- Evans R, Horstman C, and Conzemius M (2005) Accuracy and optimization of force platform gait analysis in labradors with cranial cruciate disease evaluated at a walking gait. *Veterinary Surgery* 34(5):445-449
- Fernández DS and Lutz MA (2010) Urban flood hazard zoning in Tucumán Province, Argentina, using GIS and multicriteria decision analysis. *Engineering Geology* 111(1):90-98
- Grillakis MG, Koutroulis AG, Komma J, Tsanis IK, Wagner W, and Blöschl G (2016) Initial soil moisture effects on flash flood generation- A comparison between basins of contrasting hydro-climatic conditions. *Journal of Hydrology* 541:206-217
- Gupta A and Srivastava S (2020) Comparative analysis of ant colony and particle swarm optimization algorithms for distance optimization. *Procedia Computer Science* 173:245-253
- Holland JH (1992) Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence. MIT Press
- Hong H, Panahi M, Shirzadi A, Ma T, Liu J, Zhu AX, Kazakis N (2018) Flood susceptibility assessment in Hengfeng area coupling adaptive neuro-fuzzy inference system with genetic algorithm and differential evolution. *Science of The Total Environment* 621:1124-1141
- Jaafari A, Panahi M, Pham BT, Shahabi H, Bui DT, Rezaie F, Lee S (2019) Meta optimization of an adaptive neuro-fuzzy inference system with grey wolf optimizer and biogeography-based optimization algorithms for spatial prediction of landslide susceptibility. *CATENA* 175:430-445
- Khosravi K, Nohani E, Maroufinia E, and Pourghasemi HR (2016) A GIS-based flood susceptibility assessment and its mapping in Iran: a comparison between frequency ratio and weights-of-evidence bivariate statistical models with multi-criteria decision-making technique. *Natural Hazards* 83(2):947-987
- Khosravi K, Pham BT, Chapi K, Shirzadi A, Shahabi H, Revhaug I, Tien Bui D (2018) A comparative assessment of decision trees algorithms for flash flood susceptibility modeling at Haraz watershed, northern Iran. *Science of the Total Environment* 627:744-755
- Khosravi K, Shahabi H, Pham BT, Adamowski J, Shirzadi A, Pradhan B, Prakash I (2019) A comparative assessment of flood susceptibility modeling using multi-criteria decision-making

- analysis and machine learning methods. *Journal of Hydrology* 573:311-323
- Kim YG, Sun BQ, Kim P, Jo MB, Ri TH, and Pak GH (2021) A study on optimal operation of gate-controlled reservoir system for flood control based on PSO algorithm combined with rearrangement method of partial solution groups. *Journal of Hydrology* 593:125783
- Lee S, Panahi M, Pourghasemi HR, Shahabi H, Alizadeh M, Shirzadi A, Bin Ahmad B (2019) SEVUCAS: A novel GIS-based machine learning software for seismic vulnerability assessment. *Applied Sciences* 9(17) doi:10.3390/app9173495
- Liu G, Chen W, Chen H, Xie J (2019) A quantum particle swarm optimization algorithm with teamwork evolutionary strategy. *Mathematical Problems in Engineering Geology* 2019:1805198
- Mahato S, Pal S, Talukdar S, Saha TK, and Mandal P (2021) Field based Index of Flood Vulnerability (IFV): A new validation technique for flood susceptible models. *Geoscience Frontiers* 12(5):101175
- Marjanović M, Kovačević M, Bajat B, and Voženilek V (2011) Landslide susceptibility assessment using SVM machine learning algorithm. *Engineering Geology* 123(3):225-234
- Mohammadi A, Kamran KV, Karimzadeh S, Shahabi H, and Al-Ansari N (2020) Flood detection and susceptibility mapping using Sentinel-1 timeseries, Alternating Decision Trees, and Bag-ADTree Models. *Complexity* 2020:4271376
- Panahi M, Dodangeh E, Rezaie F, Khosravi K, Van Le H, Lee MJ, Thai Pham B (2021) Flood spatial prediction modeling using a hybrid of meta-optimization and support vector regression modeling. *CATENA* 199:105114
- Pham BT, Luu C, Phong TV, Nguyen HD, Le HV, Tran TQ, Prakash I (2021) Flood risk assessment using hybrid artificial intelligence models integrated with multi-criteria decision analysis in Quang Nam Province, Vietnam. *Journal of Hydrology* 592:125815
- Pham BT, Tien Bui D, Pourghasemi HR, Indra P, and Dholakia MB (2017) Landslide susceptibility assessment in the Uttarakhand area (India) using GIS: a comparison study of prediction capability of naïve bayes, multilayer perceptron neural networks, and functional trees methods. *Theoretical and Applied Climatology* 128(1):255-273
- Pham BT, Tien Bui D, and Prakash I (2018) Bagging based support vector machines for spatial prediction of landslides. *Environmental Earth Sciences* 77(4):146
- Pradhan B (2013) A comparative study on the predictive ability of the decision tree, support vector machine and neuro-fuzzy models in landslide susceptibility mapping using GIS. *Computers & Geosciences* 51:350-365
- Rahmati O, Yousefi S, Kalantari Z, Uuemaa E, Teimurian T, Keesstra S, Tien Bui D (2019) Multi-hazard exposure mapping using machine learning techniques: A case study from Iran. *Remote Sensing* 11(16) doi:10.3390/rs11161943
- Shi Y and Eberhart RC (1998) Parameter selection in particle swarm optimization. Paper Presented at the Evolutionary Programming VII Berlin Heidelberg
- Solomatine D, See LM, and Abraham RJ (2008) Data-driven modelling: Concepts, approaches and experiences. In R. J. Abraham, L. M. See, & D. P. Solomatine (Eds.), *Practical Hydroinformatics: Computational Intelligence and Technological Developments in Water Applications* (pp. 17-30) Berlin Heidelberg Springer Berlin Heidelberg
- Syifa M, Panahi M, and Lee CW (2020) Mapping of post-wildfire burned area using a hybrid algorithm and satellite data: The case of the camp fire wildfire in California, USA. *Remote Sensing* 12(4) doi:10.3390/rs12040623
- Talatahari S, Singh VP, and Hassanzadeh Y (2013) Ant colony optimization for estimating parameters of flood frequency distributions. In X.-S. Yang, A. H. Gandomi, S. Talatahari, & A. H. Alavi (Eds.), *Metaheuristics in Water, Geotechnical and Transport Engineering* (pp. 121-146) Oxford Elsevier
- Tehrany MS, Pradhan B, and Jebur MN (2015) Flood susceptibility analysis and its verification using a novel ensemble support vector machine and frequency ratio method. *Stochastic Environmental Research and Risk Assessment* 29(4):1149-1165
- Tien Bui D, Bui QT, Nguyen QP, Pradhan B, Nampak H, and Trinh PT (2017) A hybrid artificial intelligence approach using GIS-based neural-fuzzy inference system and particle swarm optimization for forest fire susceptibility modeling at a tropical area. *Agricultural and Forest Meteorology* 233:32-44
- Tien Bui D, Shirzadi A, Shahabi H, Chapi K, Omidavri E, Pham BT, Lee S (2019) A novel ensemble artificial intelligence approach for gully erosion mapping in a semi-arid watershed (Iran). *Sensors* 19(11) doi:10.3390/s19112444
- Vapnik V, Guyon I, and Hastie T (1995) Support vector machines. *Machin Learning* 20(3):273-297
- Yalcin A, Reis S, Aydinoglu AC, and Yomralioglu T (2011) A GIS-based comparative study of frequency ratio, analytical hierarchy process, bivariate statistics and logistics regression methods for landslide

susceptibility mapping in Trabzon, NE Turkey.
CATENA 85(3):274-287

Yen YS, Chao HC, Chang RS, and Vasilakos A (2011)
Flooding-limited and multi-constrained QoS

multicast routing based on the genetic algorithm for
MANETs. Mathematical and Computer Modelling
53(11):2238-2250