

پهنه‌بندی مناطق مستعد دارای جریان‌های واریزه‌ای با استفاده از الگوریتم‌های یادگیری ماشین (مطالعه موردی: حوضه تنگراه استان گلستان)

فریبا پاک‌نژاد: دانشجوی دکتری، دانشکده علوم جغرافیایی، دانشگاه خوارزمی، تهران

علی احمدآبادی*: استادیار ژئومورفولوژی دانشکده علوم جغرافیایی، دانشگاه خوارزمی، تهران

عزت‌اله قنوتی: دانشیار ژئومورفولوژی دانشکده علوم جغرافیایی، دانشگاه خوارزمی، تهران

حسن زحمتکش: دانشجوی دکتری، دانشکده علوم جغرافیایی، دانشگاه خوارزمی، تهران

نوع مقاله: پژوهشی

تاریخ پذیرش: ۱۴۰۱/۳/۲۶

تاریخچه مقاله (تاریخ دریافت: ۱۴۰۰/۱۰/۳)



چکیده

سیلاب، رخدادی طبیعی و نامنتظره است که در دهه‌های اخیر به فراوانی رخ داده و آسیب‌های جبران‌ناپذیری به همراه داشته‌است. ارزیابی جامع خطر جریان‌های واریزه‌ای به علت پیچیدگی و فقدان قطعیت شاخص‌های مختلف مربوطه، بسیار چالش‌برانگیز است. یک ارزیابی منطقی و معقول باید بر اساس داده‌های کافی و رویکردهای واقع‌گرایانه باشد. این مطالعه با استفاده از الگوریتم‌های یادگیری ماشین، رویکرد دقیقی را برای ارزیابی ریسک خطر جریان واریزه‌ای ارائه می‌دهد. در این راستا به منظور ارزیابی آسیب‌پذیری سیلاب‌های رخ داده در منطقه، نقشه پهنه‌بندی ریسک سیلاب از دو مدل RF و ANN در حوضه آبریز تنگراه تهیه شد. بر اساس داده‌های خطر جریان واریزه‌ای، پیمایش‌های گسترده میدانی و داده‌های ژئومورفولوژیکی و محیطی انجام شده، یازده عامل مؤثر برای اجرای این مدل آماده شد که شامل طبقات ارتفاعی، درصد شیب، فاصله از آبراهه، تراکم زهکشی، زمین‌شناسی، میزان بارندگی، کاربری اراضی، جهت شیب، لایه خاک‌شناسی، شاخص قدرت آبراهه (SPI) و شاخص رطوبت توپوگرافیک (TWI) است. با استفاده از نرم‌افزار **Matlab R2020a**، ۶۰۹ منطقه مستعد جریان واریزه‌ای شناسایی شد که از هفتاد درصد آن برای اجرای مدل و از سی درصد آن برای اعتبارسنجی استفاده شد. رویکرد RF بیشترین مقادیر دقت، احتمال تشخیص خطر و AUC (ناحیه زیر منحنی مشخصه عملکرد گیرنده) را ارائه داد. ارزیابی نتایج به دست آمده از مدل الگوریتم جنگل تصادفی نیز با استفاده از ضریب تعیین ۰/۰۸۹ و خطای ۰/۲۴ ایجاد شد که سطح دقت بالای این مدل را نسبت به مدل شبکه عصبی مصنوعی با دقت ۰/۰۷۸ و خطای ۰/۳۵ نشان داد. براساس پهنه‌بندی صورت گرفته، نتایج نشان داد که ۱۷، ۲۲، ۲۶، ۲۲ و ۱۲ درصد از مساحت منطقه به ترتیب پهنه‌های دارای خطر بسیار زیاد با مساحت ۱۰۸/۱۴ کیلومتر مربع، زیاد ۱۳۶/۲، متوسط ۱۶۸/۲۵، کم ۱۴۲/۲ و خیلی کم با ۸۰/۵۶ کیلومتر مربع است. اعتبارسنجی ثانویه توسط معیار ROC و سطح زیر منحنی برای مدل RF، ۰/۹۴ و برای مدل ANN ۰/۰۸۸ است که دقت برآوردی مدل رندم فارست را نشان می‌دهد.

واژگان کلیدی: پهنه‌بندی، جنگل گلستان، جریان واریزه‌ای، روش RF.

۱- مقدمه

در مناطق مختلف جهان، تعاریف متفاوتی از سیلاب و انواع آن بیان شده‌است (Chuboklu, 2017)؛ یکی از این موارد، جریان‌های واریزه‌ای است. این جریان‌ها، پدیده‌های هیدرولوژیکی محلی است که در حوضه‌های آبریز کوچکی به مساحت چند کیلومتر مربع تا چند صد کیلومتر مربع و با زمان پاسخ چند ساعت یا کمتر رخ می‌دهد. بنابراین، این پدیده‌ها یکی از مهم‌ترین خطرهای طبیعی است که تلفات جانی و مالی جدی را در سراسر جهان و به‌ویژه در حوضه‌های کوهستانی به همراه داشته‌است (Villanueva, 2010). علاوه بر شرایط محیط طبیعی، فعالیت‌های انسانی و فقدان برنامه‌ریزی صحیح نیز به ایجاد و افزایش فراوانی و حجم، همچنین خسارت‌های مالی و جانی ناشی از جریان‌های واریزه‌ای منجر می‌شود (Ghanavati, 2013). یکی از راه‌هایی که می‌توان از طریق آن خسارت‌های ناشی از سیلاب را کاهش داد، تعیین مناطق سیلاب‌خیز و اجرای روش‌های مناسب برای کنترل آن است (Ahmadabadi et al, 2020). جریان‌های واریزه‌ای عموماً به شکل جریان‌های گرانشی مخلوط خاک، سنگ و آب و هوا نیز تعریف می‌شود (Yunfun, 2007). جریان رسوب و ترکیب آب به دلیل نیروی جاذبه به جریان مداوم تبدیل می‌شود؛ از این رو، دارای قابلیت حرکت پذیری از فضای خالی بزرگ اشباع شده توسط آب است (Takahashi, 2017). مقایسه ضریب اصطکاک معادل با دیگر جنبش‌های توده‌ای، حرکت‌پذیری قوی جریان واریزه‌ای را نشان می‌دهد؛ هرچند ممکن است این راهکار فاقد معنای فیزیکی باشد، از آن به طور وسیعی در بحث حرکت توده‌های بزرگ استفاده شده‌است (Campell, 1995). این جریان‌ها مربوط به باران‌های سیل‌آسا است و خطری ویرانگر و متداول در نواحی مورد مطالعه محسوب می‌شود. پدیده‌هایی چون لغزش بر روی شیب تند در امتداد کانال پر شیب کوچک و ته‌نشست واریزه‌ها از این دسته‌اند (Jakob and Hanger, 2005). با شروع دهه‌های اخیر، پیشرفت‌های مهمی در درک فرایندها حاصل شد؛ با این وجود، تخصص انسان هنوز هم برای شناسایی خطر کافی نیست؛ زیرا بسیاری از جنبه‌های کل فرایند هنوز درک نشده‌است (Antoni, 2004). سیلاب‌های جریان‌های واریزه‌ای می‌تواند به فجایعی منجر شود که تهدیدی جدی برای جان و مال افراد و توسعه اقتصادی به شمار می‌رود. در ایران به علت آب و هوای متنوع، دما و بارندگی متغیر در بیشتر حوضه‌ها به خصوص در مناطق شمالی کشور، هر ساله سیل‌گیری‌های متعددی دیده می‌شود. در طول دهه‌های گذشته خسارت‌های اقتصادی ایجاد شده به وسیله سیلاب‌ها در ایران، به ۱۷۰۵ هزار دلار افزایش یافته‌است (Tehrani et al, 2006). شهرها و روستاهای فراوانی در ایران از خطر جدی سیلاب رنج می‌برند؛ از جمله این موارد سیلاب جریان واریزه‌ای است که در سال ۱۳۸۴ در کلانه و استان گلستان رخ داد و به کشته شدن ۳۲ نفر، مفقود شدن ۷۰ نفر و تخریب ۲۰۰ واحد مسکونی در ۳۵ نقطه روستایی منجر شد. روستای تنگراه نیز جزء همین روستاها بود و از خسارت‌های ناشی از سیل در امان نماند، تا جایی که آثار آن هنوز هم در منطقه باقی است (شکل ۱). برآورد کلی خسارت‌های ناشی از سیل در این سال، حدود بیست میلیارد تومان بود (Islamic Revolution Housing Foundation, 2006).

مطابق آمار و ارقام منتشر شده توسط سازمان ملل، از میان خطرهای طبیعی، سیلاب بیشترین آسیب و خسارت را به انسان وارد کرده‌است؛ به نحوی که یک سوم خسارت‌های اقتصادی خطرهای طبیعی مربوط به سیلاب است و دو سوم جمعیت کره زمین به طور مستقیم و غیرمستقیم از پیامدهای آن تأثیر می‌پذیرد؛ به عنوان مثال، وقوع سیلاب دارای جریان واریزه‌ای در چین در هشت اگوست ۲۰۱۰، به مرگ ۱۷۰۰ نفر و جریان واریزه‌ای که در سی آوریل ۲۰۱۴ در

افغانستان رخ داد، به مرگ بیش از دو هزار نفر منجر شد (Juo et al, 2014). کشور ایران نیز با توجه به شرایط اقلیمی و یکنواخت نبودن توزیع زمانی و مکانی بارش‌ها، از نظر تعداد وقایع سیلاب در بین مناطق با درجهٔ سیلاب‌خیزی بالا در جهان قرار دارد؛ به طوری که در شصت سال اخیر (۱۳۳۰ - ۱۳۹۰) حدود ۶۱۰۰ واقعهٔ سیلاب در کشور گزارش شده که پنجاه درصد آن در دو دههٔ اخیر روی داده‌است. در این میان، نواحی روستایی از گذشته تا به حال همواره با مسائل و مشکلاتی نظیر کمبود امکانات زیربنایی، کیفیت نامناسب محیط زیست، درآمد پایین، نظام نامناسب استقرار، پراکندگی بیش از حد جمعیت و فعالیت‌ها، کوچک بودن آبادی‌ها و پراکندگی آنها، فقدان امکان سرمایه‌گذاری مطلوب و ضعف سازه‌ها و رویه‌های نامناسب مدیریتی روبرو بود (Hosinnejad, 2019).

از مهم‌ترین عوامل مورفومتریک وقوع جریان واریزه‌ای در مرحلهٔ نخست، شیب حوضه است و از عوامل مهم دیگر، متغیرهای مربوط به دسترس بودن رسوب در حوضه، ساختار زمین‌شناسی، سنگ‌شناسی، وجود لغزش، وجود یخچال‌های طبیعی و پوشش گیاهی است (Sally et al, 2010). با تطبیق نقشهٔ پهنه‌بندی خطر سیل‌گیری با نقشه‌های کاربردی اراضی می‌توان مناطق در خطر شامل شهرها، روستاها، پل‌ها، کارخانه‌ها و غیره را شناسایی کرد تا اقدامات لازم برای حفاظت از این سرمایه‌ها انجام شود. برای پهنه‌بندی خطر سیل ناشی از جریان واریزه‌ای، روش‌های مختلفی وجود دارد که عبارتند از: روش مشاهده‌ای و استفاده از داغاب، استفاده از عکس‌های هوایی و تصاویر ماهواره‌ای و استفاده از مدل ریاضی (Barkhordar and chavoshiyan, 2000). پیشرفت و تکنولوژی سبب شده‌است بشر در جستجوی ابزار جدید و پیشرفته باشد. فرایند تحلیل و سلسله‌مراتبی نیز یکی از فنون معروف تصمیم‌گیری چند معیاره برای وضعیت‌های پیچیده است که سنجنده‌های چندگانه و متضادی دارد. چالش اصلی در ارزیابی خطرپذیری سیلاب، وجود رابطه‌ای غیرخطی میان وقوع سیلاب و متغیرهای پیش‌بینی‌کننده است که در این میان، الگوریتم‌های یادگیری ماشین در رفع این چالش نقش مهمی ایفا می‌کند؛ در عین حال با پیشرفت این الگوریتم‌ها، احتمال بیش‌برازش آنها به الگوهای محلی موجود در داده‌ها نیز افزایش می‌یابد. از الگوریتم‌های یادگیری ماشین در برنامه‌های کاربردی مرتبط با سیل به طور خاص استفاده می‌شود (Salder, 2018) و امکان مدل‌سازی و پیش‌بینی مناطق مستعد سیل را فراهم می‌سازد. از جمله این الگوریتم‌ها می‌توان به مدل شبکه عصبی مصنوعی و رندم فارست اشاره کرد (Kia, 2012).

در طی پنجاه سال اخیر، مطالعات سیلاب‌های جریان‌های واریزه‌ای به شکل بررسی‌های علمی، آزمایش‌های کنترل شده و تحلیل‌های مکانیکی در آمده‌است. پژوهش‌هایی که در این رابطه انجام شده به شرح زیر است: Ayalew و همکاران (2005) برای ارزیابی توان سیلاب‌های جریان واریزه‌ای، از رگرسیون لجستیک استفاده کردند. Gazatti و همکاران (2005)، رویکردی احتمالی برای ارزیابی ریسک خطر سیلاب‌های جریان واریزه‌ای در مقیاس یک حوضه مطرح کردند. Calo و همکاران (2009) برای ارزیابی ریسک جریان‌های واریزه‌ای، از شبیه‌سازی‌های مونت کارلو استفاده کردند؛ با این حال، روابط غیرخطی بین متغیرهای استفاده شده را نمی‌توان به وسیلهٔ این رویکردها حل کرد. Wan-jie Liang و همکاران (2011) با استفاده از مدل BN^1 و مقایسهٔ آن با مدل‌های SVM^2 و ANN^3 ، به تهیهٔ نقشه‌های خطر جریان واریزه‌ای پرداختند. نتایج به دست آمده از این حکایت داشت که مدل BN ، ریسک و فقدان

¹ Bayesian Network

² Support vector machine

³ Artificial Intelligence Network

قطعیت خطر سیلاب‌های جریان‌واریزه‌ای را بهتر از سایر مدل‌ها (نظیر ANN و SVM) برآورد می‌کند. همچنین می‌تواند برای ارزیابی خطر جریان واریزه‌ای در سطح ملی، به یکپارچه‌سازی معلومات با دقت‌های مختلف از منابع متفاوت و مناسب بپردازد. Takahashi و همکاران (2013) و همین‌طور Rickerman و همکاران (2013)، مدل‌های عددی را برای شبیه‌سازی این جریان‌ها ارائه و شبیه‌سازی‌های قانع‌کننده‌ای از خطر مواد ایجاد کردند. Dowling، اثرات کلی جریان‌های واریزه‌ای را در یک مقیاس جهانی و در طی سال‌های ۱۹۵۰ تا ۲۰۱۱ بررسی کرد (Dowling, 2013). Lee و همکاران (2017) با استفاده از مدل‌های تصادفی جنگل، به پیش‌بینی فضایی حساسیت به سیل پرداختند و به این نتیجه رسیدند که مدل رندم فارست نسبت به دیگر الگوریتم‌های مورد استفاده دقت بیشتری دارد. Juo و همکاران (2014) با استفاده از مدل دو فاز^۱ برای تحلیل جریان‌های واریزه‌ای، مدلی تک بعدی را مطرح کردند که سرعت فازهای جامد و مایع را برآورد می‌کند. آنها به این نتایج رسیدند که روش‌های تئوری می‌توانند سرعت جریان واریزه‌ای را با کسرهای حجم جامد مختلف و قطرهای معادل متفاوت برآورد کنند که این امر، نتایج تئوری را پیگیری و ریسک یک جریان - مواد را پیش‌بینی می‌کند. Band و همکاران (2020) برای ارزیابی پهنه‌های سیل‌گیر، از پنج الگوریتم یادگیری ماشین استفاده کردند و به این نتیجه رسیدند که ۲۸ درصد از منطقه، مستعد سیل‌گیری است و پارامترهای اصلی این امر به ترتیب به ارتفاع شیب بارندگی و ... تعلق دارد. Liu و همکاران (2021) در پژوهشی به ارزیابی پهنه‌های سیل‌گیر در سین کیانگ پرداختند. آنها به این نتیجه رسیدند که مدل رندم فارست نتایج دقیقی را در زمینه پهنه‌های سیل‌گیر ارائه می‌دهد و این امر بیانگر دقت بالای این مدل در پهنه‌بندی است. Andrian و همکاران (2021) با استفاده از مدل ANN، به ارزیابی مناطق مستعد سیلاب در حوضه اجیچای پرداختند. آنها به این نتیجه رسیدند که این مدل در ارزیابی پهنه‌های سیلاب دقت و صحت بالایی دارد و ارتفاع دارای بیشترین تأثیر و خمیدگی دارای کمترین تأثیر است. Maleki nejad و همکاران (۱۳۹۳)، به بررسی کارایی روش HEC-HMS^۲ و روش مصنوعی SCS^۳ در شبیه‌سازی هیدروگراف سیل در حوضه آبریز جنگلی پرداختند و با مقایسه نتایج با هیدروگراف‌های مشاهداتی نشان دادند که این مدل هیدرولوژیک، عملکرد مناسبی در این گونه حوضه‌ها دارد. Khosravi و همکاران (2019) در ارزیابی حساسیت سیل-گیری، به مقایسه مدل‌های آماری دو متغیره وزن واقعه و نسبت فراوانی با تکنیک تصمیم‌گیری چند معیاره پرداختند و به این نتیجه رسیدند که مدل‌های استفاده شده، در تهیه نقشه حساسیت سیل‌گیری دقت قابل قبولی دارد. Dhghani و همکاران (1396) با استفاده از شبکه عصبی موجک، به پیش‌بینی دبی سیلاب پرداختند. آنها به این نتیجه رسیدند که مدل‌های مورد استفاده در تخمین سیلاب قابلیت خوبی دارد. Entezami و همکاران (۱۳۹۸) با استفاده از ارزیابی کارایی روش‌های نسبت فراوانی و وزنی شواهد، به پهنه‌بندی نقشه حساسیت سیل‌گیری پرداختند و نتایج حاصل شده بیانگر دقت ۸۵ درصدی مدل نسبت فراوانی و ۸۳ درصدی مدل وزنی شواهد بود. همچنین نتایج این ارزیابی، دقت بالای مدل را در تهیه نقشه پهنه‌بندی سیل نشان داد. Ahmadabadi و همکاران (2020) با تأکید بر مدل WMS^۴، به تحلیل خطر ناشی از سیلاب در حوضه‌های آبریز شهری در حوضه‌های دربند، گلابدره و سعدآباد کلان شهر تهران پرداختند. نتایج این تحقیق نشان داد که با توجه به تغییرات کاربری اراضی به‌خصوص در حاشیه رودخانه و ساخت و سازهای فراوان

¹ Two-Phase Fluid Model

² Hydrological Modeling System

³ Soil Conservation Service

⁴ Watershed Modeling System

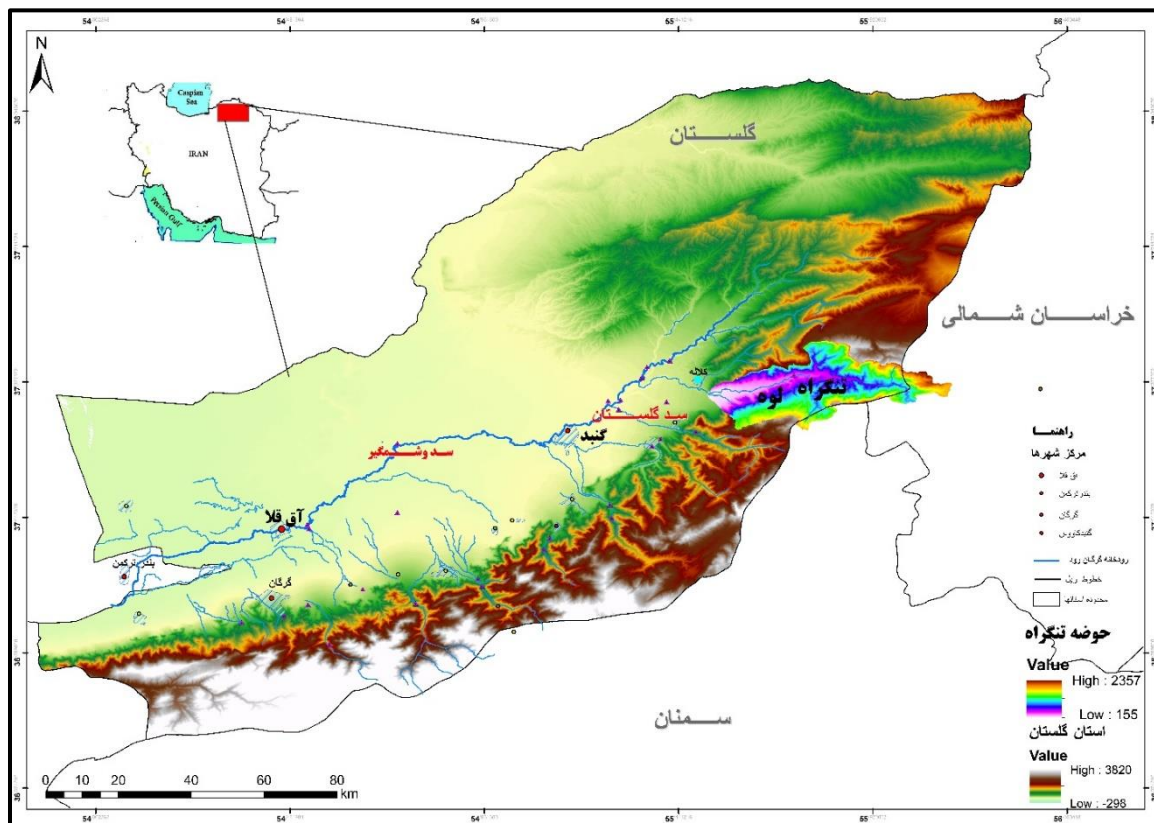
حوضه مورد نظر مطالعه، این حوضه‌ها نمی‌توانند در برابر سیلاب مقاومت کنند. همچنین زیرحوضه‌هایی که به رودخانه‌ها نزدیک‌تر است، بیشتر در معرض خطر سیلاب قرار دارند که این امر به دلیل کاهش شیب و کاهش زمان تمرکز است.



شکل ۱: توده‌های سنگی جریان‌های واریزه‌ای سیلاب‌های گذشته (نگارندگان، ۱۳۹۹)

۲- موقعیت مورد مطالعه

محدوده حوضه آبریز تنگراه با مختصات $37^{\circ}27'45''$ تا $37^{\circ}19'10''$ عرض شمالی و $56^{\circ}01'40''$ تا $55^{\circ}37'16''$ طول شرقی، در شرق استان گلستان قرار دارد. از نظر موقعیت نسبی، این حوضه از شمال به رشته‌کوه‌های هزار مسجد - کپه داغ، از جنوب به رشته‌کوه‌های البرز- بینالود، از شرق به محدوده پارک جنگلی تنگراه و از غرب به اراضی شرق شهرستان کلالة محدود می‌شود (Hosenzaden and Jahadi, 2006). مساحت حوضه آبریز مورد نظر، $633/42$ کیلومتر مربع و محیط آن $160/48$ کیلومتر مربع است. ارتفاع متوسط حوضه نیز 1063 متر است. حوضه مورد نظر به لحاظ سیل-خیزی، آماده وقوع جریان‌واریزه‌ای است. بارش‌های این منطقه نیز بیشتر متأثر از جریان‌های مرطوب خزری است و پوشش گیاهی بسیار متراکمی دارد. از نظر ویژگی‌های اقلیمی، دارای دو بیشینه بارش بهاری و زمستانی است و مجموع بارش فصل زمستان آن بیش از بهار است (Hosenzaden and Jahadi, 2006). در مجموع، ایستگاه تنگراه حدود $34/92$ درصد از بارش سالانه خود را در فصل زمستان دریافت می‌کند و بارش فصل بهار آن در مجموع $25/53$ درصد کل بارش سالانه است. حوضه تنگراه از سنگ‌های آهکی دولومیتی سازند مزدوران، مارن‌های سبز سازند چمن‌بید، کنگلومرای واحد مارنی و نهشته‌های کواترنری تشکیل شده است (شکل ۲).



شکل ۲: نقشه موقعیت منطقه مورد مطالعه (نگارندگان، ۱۴۰۰)

۳- مواد و روش

۱-۳ داده‌های پژوهش

برای بررسی حساسیت و تهیه نقشه پهنه‌بندی سیلاب‌های دارای جریان واریزه‌ای در حوضه مورد نظر، باید اهمیت و ارتباط هر یک از عوامل مؤثر در جریان واریزه‌ای ارزیابی شود. مهم‌ترین عامل برای ایجاد این جریان‌ها، ارتفاعات بالای هزار متر است و شیب‌های بالای ۲۵ درصد اکثر جریان‌های مواد نیز از نواحی منبع گسسته یا توزیع شده‌ای سرچشمه می‌گیرد که در آن شیب‌هایی تندتر از ۲۵ تا ۳۰ درجه وجود دارد و دامنه از خرده‌سنگ‌ها یا خاک‌هایی با چسبندگی کم تشکیل شده‌است (Laverson, 2014). بارش ناگهانی با دبی جریان بسیار زیاد همراه است؛ در سال‌های ۱۳۸۰ تا ۱۳۸۴، جریان واریزه‌ای در منطقه مورد مطالعه با دبی ۱۶۵۰ متر مکعب بر ثانیه (Hosenzadeen and Jahadi, 2006) رخ داد که خسارت‌های زیادی را بر جاده ارتباطی مشهد - گرگان و نقاط روستایی وارد کرد. در این پژوهش با توجه به بررسی‌های میدانی گسترده، یازده عامل مؤثر در ایجاد سیلاب‌های جریان واریزه‌ای شامل طبقات ارتفاعی، درصد شیب، فاصله از آبراهه، تراکم زهکشی، زمین‌شناسی، میزان بارندگی، کاربری اراضی، جهت شیب، لایه خاک-شناسی و لایه خاک‌شناسی از سه لایه موجود در منطقه استفاده شد. لایه‌های مورد نظر به ترتیب زیاد تا کم شامل لایه مالی سول که شامل خاک‌های بلوطی، چرنوزم، بیرونیزم، رندزینا و برخی از خاک‌های قهوه‌ای جنگلی می‌شود، لایه‌های بعدی خاک‌های عمیق تا نیمه عمیق و هوازدگی ملایم است. از شاخص قدرت آبراهه و رطوبت توپوگرافیک نیز استفاده شد. برای تهیه این لایه‌ها، از داده‌های اولیه از جمله نقشه توپوگرافی ۱:۵۰,۰۰۰ و برای تهیه نقشه‌های زمین‌شناسی

و نقشه گسل‌ها، از نقشه‌های زمین‌شناسی با مقیاس ۱:۲۵۰۰۰۰ و ۱:۱۰۰۰۰۰۰ انتشار یافته توسط سازمان زمین‌شناسی و اکتشافات معدنی کشور استفاده شد (شکل ۴). از مدل رقومی ارتفاعی با تفکیک زمینی سی متر نیز برای تهیه شاخص‌هایی چون ارتفاع، شیب، جهت شیب و انحنا استفاده شد. رقومی‌سازی نقشه‌های پایه و توابع، با استفاده از نرم‌افزار ARC GIS 10.5 انجام شد و از فاصله اقلیدسی برای تهیه و آماده‌سازی شاخص‌های لیتولوژی، فاصله از جاده و فاصله از آبراهه استفاده شد. شاخص توان آبراهه بیانگر قدرت جریان آب از نظر فرسایش بود که در محیط نرم‌افزار ARC GIS 10.5 آماده شد. برای تهیه نقشه مجموع بارندگی سالانه، از ایستگاه‌های هیدرومتری تنگراه، گالیکش، تمر و گنبد کابوس استفاده شد؛ بدین صورت که در نرم‌افزار ARC GIS 10.5، با استفاده از توابع ریاضی کریجینگ درون‌یابی شد. شاخص کاربری اراضی با اقتباس از تصاویر ماهواره‌ای لندست ۷ (۲۰۱۴)، آرشیو گوگل‌ارث و لایه اطلاعاتی کاربری اراضی استان گلستان - که از اداره کل منابع طبیعی استان تهیه شد - حاصل شد (شکل ۳). شاخص رطوبت توپوگرافیک (TWI)^۱، یکی از شاخص‌های تأثیرگذار بر وقوع سیل و توان آن در حوضه‌های آبخیز است که در این رابطه، A_S مساحت ویژه هر سلول و β گرادیان شیب بر حسب درجه است (Mirsangari et al, 2019). برای تهیه این شاخص، از نرم‌افزار ARC GIS استفاده و شاخص TWI از رابطه یک حاصل شد (شکل ۴). شاخص قدرت آبراهه (SPI)^۲، نسبت بین مساحت بالادست یک نقطه و شیب زمین در بالا دست، آن را به گونه‌ای نشان می‌دهد که نیرخ طولی آبراهه را منعکس می‌کند. شاخص مذکور از طریق توابع موجود در نرم‌افزار ARC GIS 10.5 و طبق رابطه ۲ در چهار کلاس طبقه‌بندی شد (Babli et al, 2019).

$$TWI = \ln(A_S / \tan(\beta)) \quad \text{رابطه ۱}$$

$$SPI = A_S / \tan \quad \text{رابطه ۲}$$

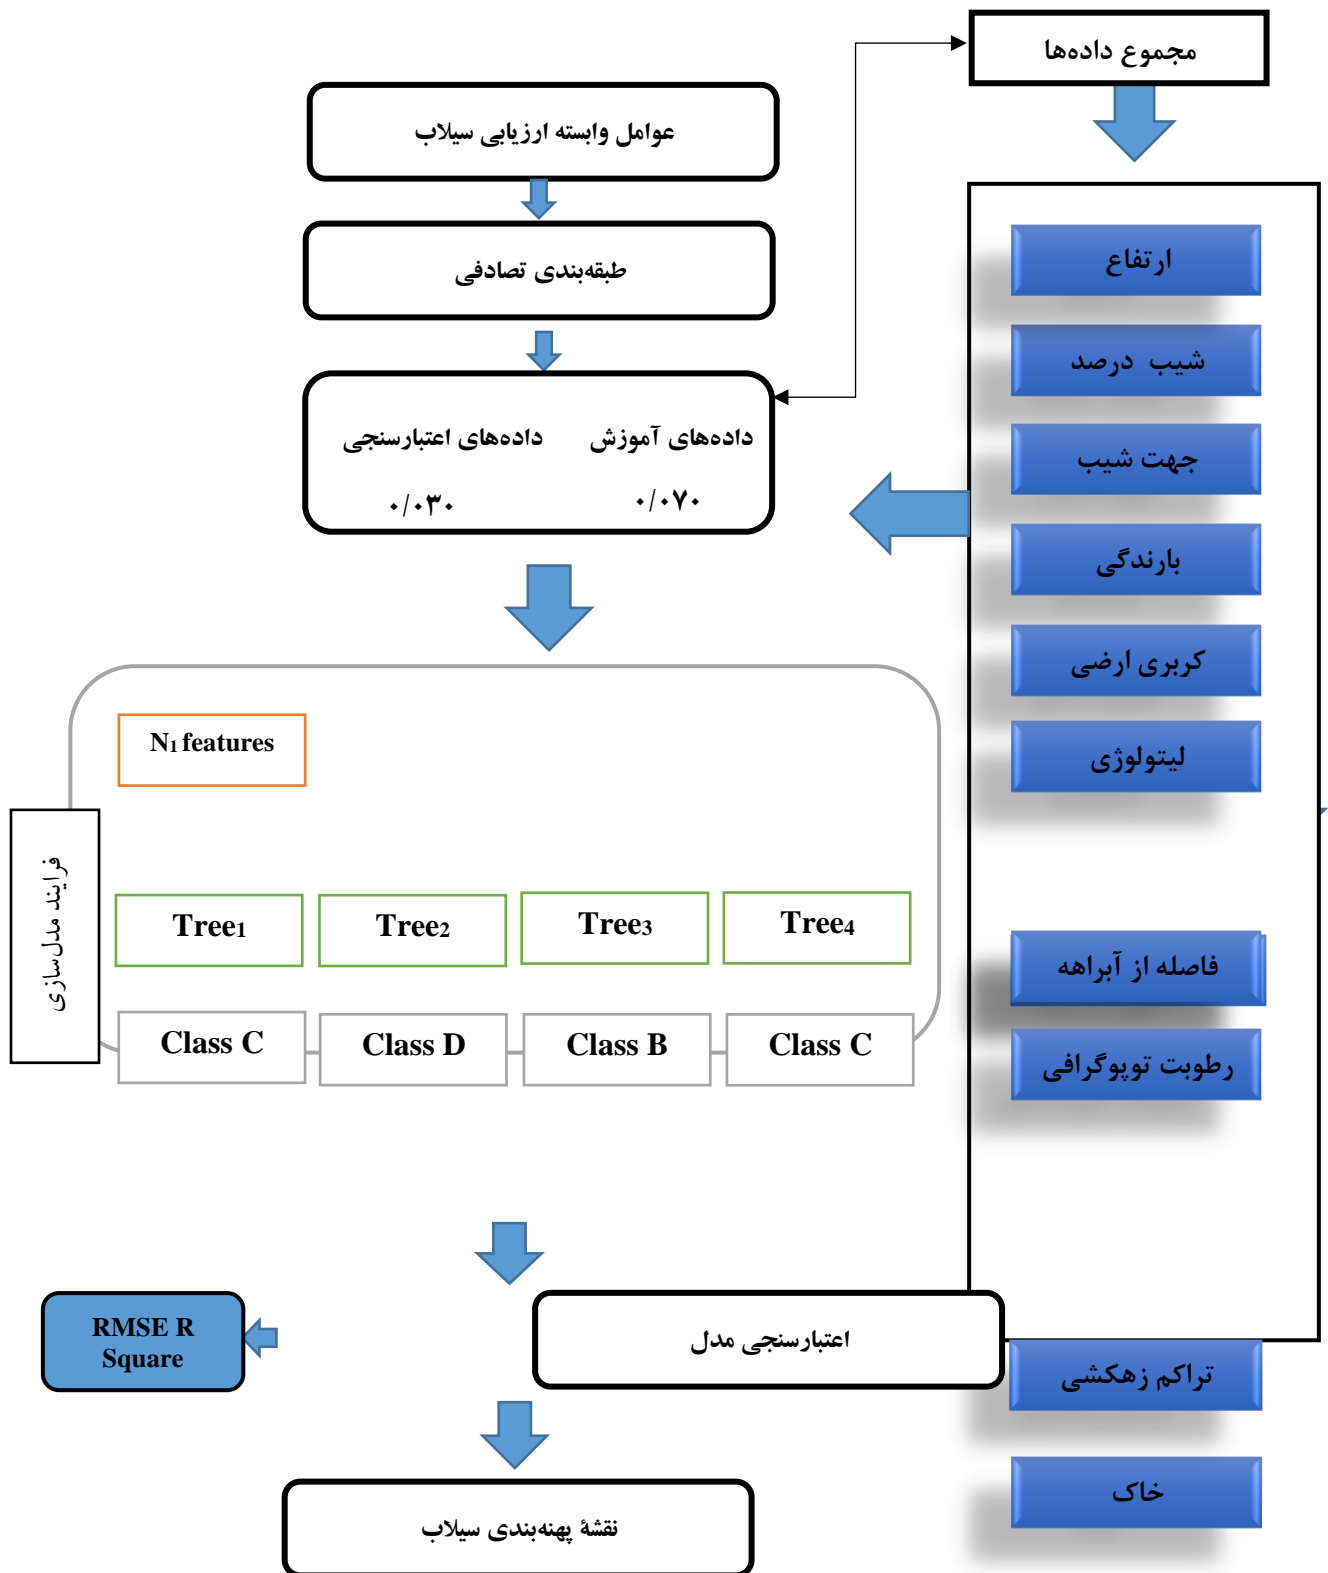
موقعیت سیلابی با ۶۰۵ نقطه، با استفاده از تصاویر ماهواره‌ای و بازدهی‌های میدانی و تطبیق آن با پروژة جایگاه، همچنین با استفاده از نقشه آبراهه و تصاویر ماهواره‌ای IRS-P6-LISS4 با قدرت تفکیک ۵/۵ متر و تصاویر بزرگ مقیاس Quick bird با قدرت تفکیک ۰/۶ متر از سازمان جنگل و مراتع تهیه شد که قسمت اعظم منطقه مورد مطالعه را پوشش داد و در نهایت، از هفتاد درصد این نقاط برای آموزش مدل و از سی درصد باقیمانده آن برای اعتبارسنجی استفاده شد. در پژوهش حاضر برای تهیه نقشه خطر وقوع سیلاب و ارزیابی صحت دقت الگوریتم‌های یادگیری ماشین، از دو روش RF^۳ و ANN^۴ استفاده شد. برای این کار، از ده فاکتور مستقل و پهنه‌های سیلاب استفاده و این داده‌ها در محیط ARC GIS 10.5 آماده‌سازی شد. پس از آن، وزن‌دهی هر یک از شاخص‌ها در نرم‌افزار Matlab R2020a انجام و وزن آنها در محیط ARC GIS 10.5 روی هر یک از لایه‌های رقومی اعمال شد. در نهایت، پهنه‌های خطر وقوع سیلاب در پنج کلاس خیلی کم، کم، متوسط، زیاد و بسیار زیاد تهیه شد.

¹ Topographic Wetness Index

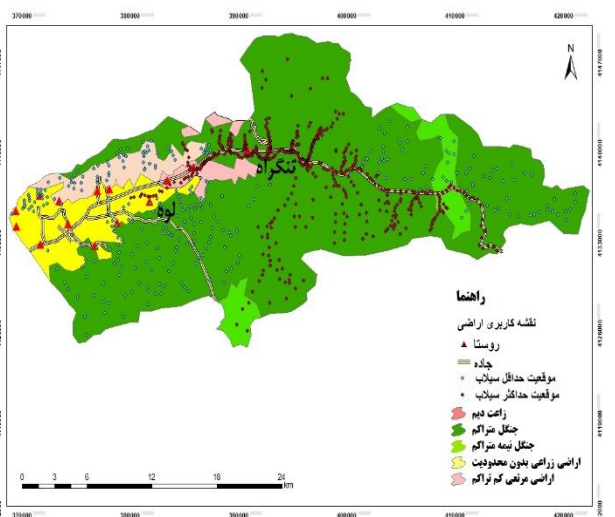
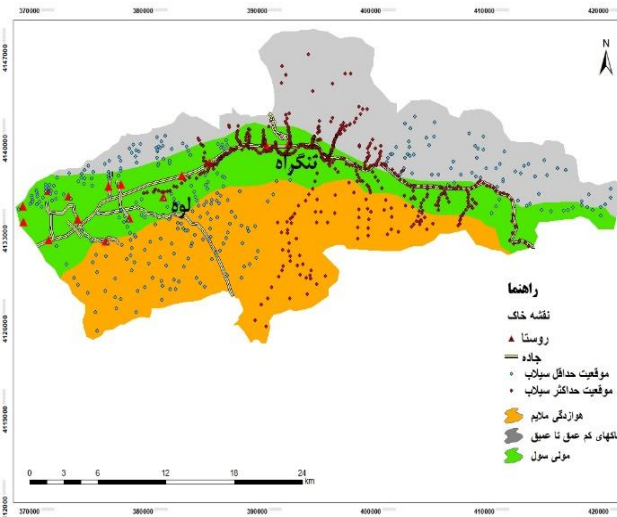
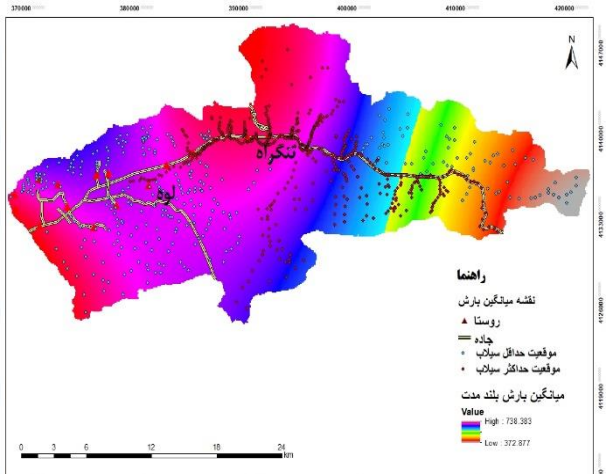
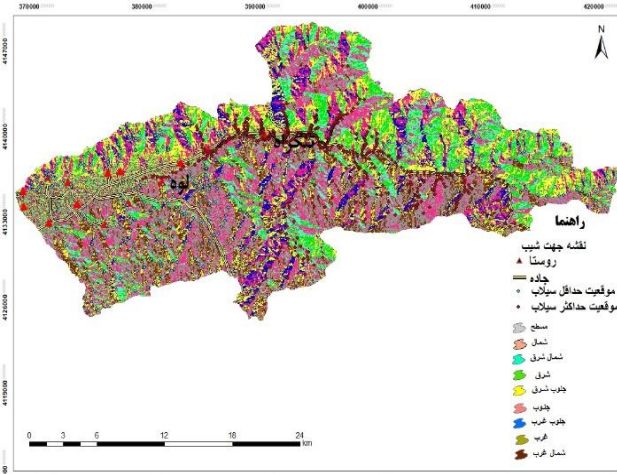
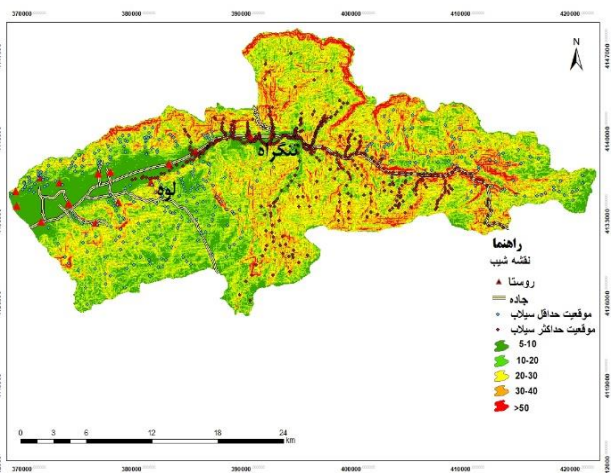
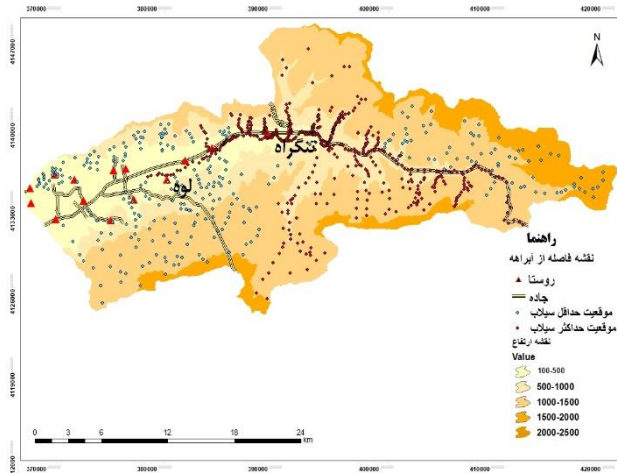
² Length Slope Factor

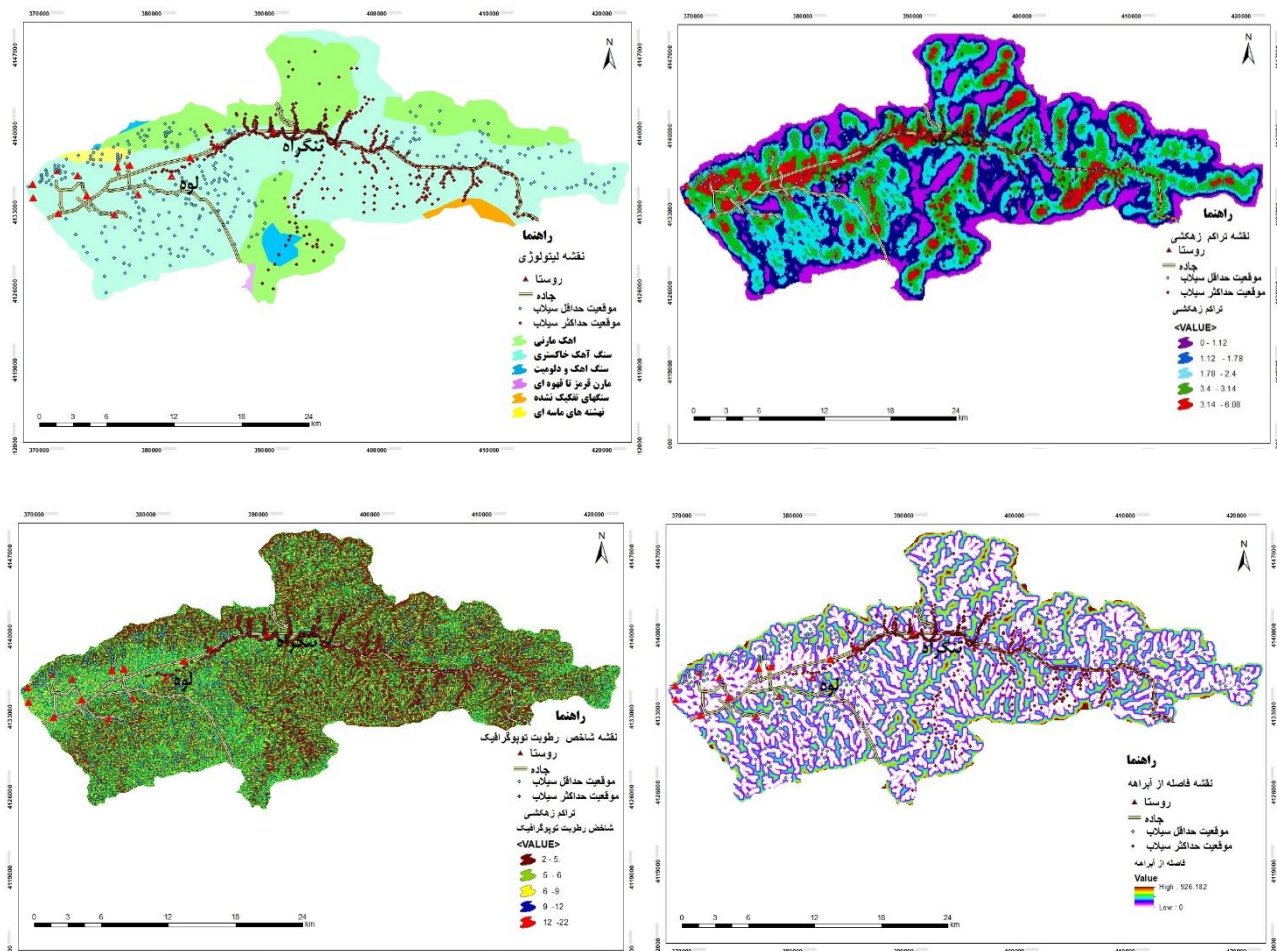
³ Random Forest

⁴ Artificial Neural Network



شکل ۳: فرایند پژوهش مدل‌سازی و تهیه نقشه پهنه‌بندی سیلاب در حوضه تنگراه





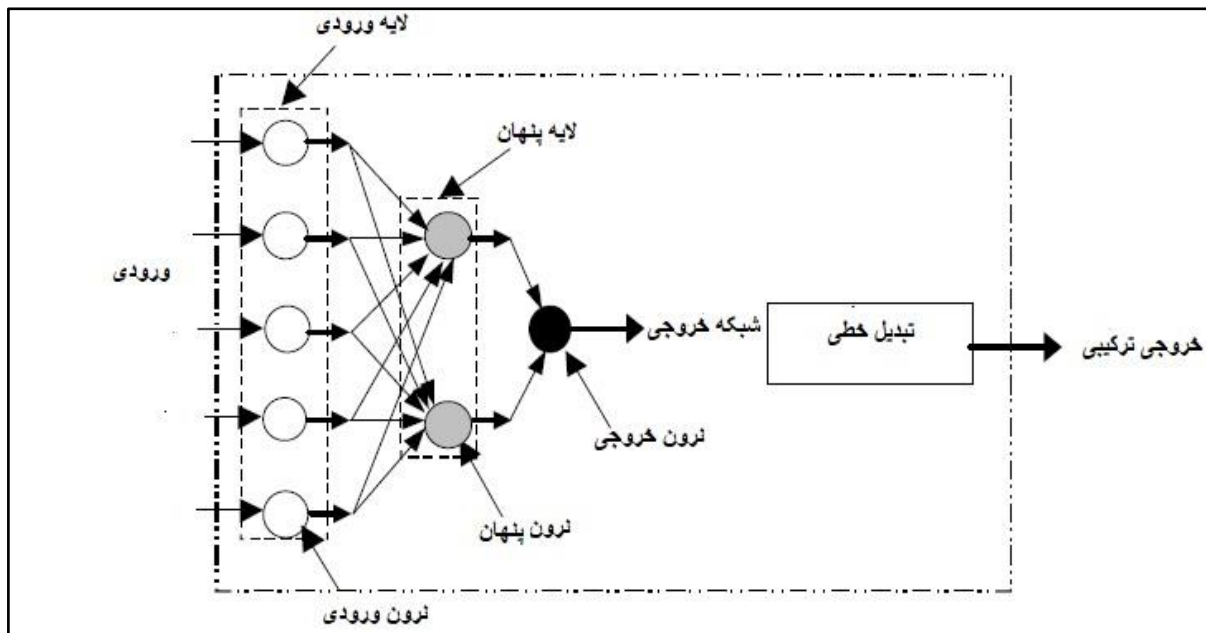
شکل ۴: نقشه عوامل مؤثر برای تهیه نقشه حساسیت به سیلاب‌های جریان واریزه‌ای

۳-۲- مدل شبکه عصبی مصنوعی و ارزیابی مدل

یک روش برای کنترل فقدان قطعیت^۱ در مسائل، بر پایه نظریه احتمالات است (Russell et al., 2003). یک ارزیابی منطقی و معقول باید بر اساس داده‌های کافی و رویکردهای واقع‌گرایانه باشد. شبکه عصبی مصنوعی، طبقه‌ای از مدل‌های غیرخطی انعطاف‌پذیر برای یادگیری توابع گوناگون است (Mishra, 2006) که بر پایه اتصال به هم پیوسته چندین واحد پردازش ساخته می‌شود. این شبکه از تعداد زیادی سلول یا گره و نرون تشکیل شده است که مجموعه ورودی را به خروجی ربط می‌دهد.

نرون کوچک‌ترین واحد پردازشگر اطلاعات است که اساس عملکرد شبکه‌های عصبی است (شکل ۵) و دستگاه‌های محاسباتی ساده‌ای است که ارتباط بین آنها عملکرد شبکه را تعیین می‌کند (Alshorboi, 2006). در پژوهش حاضر برای مدل‌سازی داده‌ها در محیط MatlabR2020a، از روش مدل شبکه عصبی مصنوعی پیشخور استفاده شد که در ادامه به توضیح آن می‌پردازیم.

¹ uncertainty



شکل ۵: نمودار شماتیک برای شبکه عصبی چند لایه Feed-Forward

ساختار یادگیری مدل شبکه عصبی پیشخور

شبکه عصبی پیشخور شامل یک سلسله لایه داده است؛ از جمله لایه ورودی، پنهان و خروجی اما تعداد سلول‌های عصبی در هر لایه متفاوت است (Golamhosini, 2006)؛ ورودی در این شبکه لایه به لایه عبور می‌کند تا به لایه خروجی برسد و چون هیچ گونه پس انتشاری در آن رخ نمی‌دهد، به شبکه پیشخور شناخته شده است. مهم‌ترین مسئله در طراحی شبکه مصنوعی، تعیین تعداد لایه‌های پنهان و تعداد نرون‌ها در آنها است. تعداد نرون‌ها به طور مستقیم بر آموزش و القای شبکه عصبی تأثیر دارد؛ به طوری که اگر تعدادی کمتر انتخاب شود، زمان آموزش نیز کمتر می‌شود؛ اما شبکه آموزش، توانایی کمتری دارد و بالعکس (Varng, 2013). در این روش، از الگوریتم پس انتشار استفاده شد. پس انتشار در شبکه‌های عصبی مصنوعی پیشخور، نوعی روش یادگیری اکتشافی تحت نظارت است که مارتین رایسد میلر و هانیریش براون در سال ۱۹۹۲ آن را به وجود آوردند. یادگیری ماشینی با نظارت^۱، در پی تابعی از میان یک سلسله توابع است که تابع هزینه^۲ داده‌ها را بهینه سازد. یکی از روش‌های متداول حل مسئله بهینه‌سازی در شبکه‌های عصبی، بازگشت به عقب^۳ است. روش بازگشت به عقب گرادیان، تابع هزینه را برای تمام وزن‌های شبکه عصبی محاسبه می‌کند، سپس از روش‌های گرادیان کاهش^۴ برای یافتن مجموعه وزن‌های بهینه استفاده می‌کند. روش‌های گرادیان کاهش می‌کوشد به صورت متناوب در خلاف جهت گرادیان حرکت کند و با این کار، تابع هزینه را به حداقل برساند. یافتن گرادیان لایه آخر، ساده است و با استفاده از مشتق جزئی به دست می‌آید (Haton, 2017). برای به دست آوردن کمینه $Q(W)$ باید از روش گرادیان کاهش استفاده کرد؛ به این معنی که گرادیان تابع را حساب کنیم. روش بازگشت به عقب در واقع روشی برای یافتن گرادیان کمینه است. حال فرض کنیم می‌خواهیم گرادیان

¹ Supervised learning

² loss function

³ Back propagation

⁴ Gradient descent

تابع $Q(W)$ را نسبت به وزن WPC به دست بیاوریم، برای این کار به قاعده زنجیری در مشتق‌گیری نیازمندیم. این قاعده به این شکل کار می‌کند که اگر تابعی به اسم F داشته باشیم که به سه ورودی U, W, V وابسته باشد و هر کدام از این سه ورودی به نوبه خود به T وابسته باشند، مشتق F به T از رابطه سه به دست می‌آید. باید توجه داشت که هر یک از ورودی‌ها به همه نرون‌ها متصل شده‌است. ماتریس W نیز در این حالت، S سطر و R ستون دارد و لایه‌ها شامل ماتریس وزن، جمع‌کننده‌ها، بردار بایاس b و تابع f است. در شبکه تک لایه بردار، ورودی P توسط نرون‌های لایه طبق رابطه پنج به بردار خروجی مرتبط می‌شود.

$$Q(W) = \sum_{i=1}^n l(h_w(x_i, y_i)) \quad \text{رابطه ۳}$$

$$\frac{\partial f(u(t), u(t), w(t))}{\partial t} = \frac{\partial f}{\partial u} \frac{\partial u}{\partial t} + \frac{\partial f}{\partial u} \frac{\partial u}{\partial t} + \frac{\partial f}{\partial w} \frac{\partial w}{\partial t} \quad \text{رابطه ۴}$$

$$a = f(w_p + b) \quad \text{رابطه ۵}$$

هدف هر الگوریتم، آموزش به حداقل رساندن سطح خطای کل است که با یکی از معیارهای زیر سنجیده می‌شود؛ مقدار ریشه میانگین مربعات (RMS) بیانگر میزان انحراف پیش‌بینی از مشاهده واقعی است و MAE خطای متوسط میانگین که در آن مقادیر منفی و مثبت به ترتیب حاکی از بیش برآورد مقادیر توسط مدل است. شرط استفاده از این روش این است که هیچ داده واقعی صفر نباشد؛ چون در مخرج کسر قرار می‌گیرد و حاصل مبهم خواهد شد (Makrid, 1993). R_2 ضریب تعیین نیز میزان انحراف داده‌های خروجی شبکه را از داده‌های هدف نشان می‌دهد که هر چه این ضریب به عدد یک نزدیک‌تر باشد، خطا کمتر است.

$$RMSE = \left(\left(\frac{N}{1} \right) \sum_{i=1}^N |T_i - O_i|^2 \right)^{\frac{1}{2}} \quad \text{رابطه ۶}$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (t_i - O_i)^2}{\sum_{i=1}^N (t_i - t^-)^2}; T^- = \frac{1}{N} \sum_{i=1}^N T_i \quad \text{رابطه ۷}$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |I_i - \hat{I}| \quad \text{رابطه ۸}$$

برای پهنه‌بندی خطر سیلاب در منطقه مورد مطالعه با استفاده از شبکه مصنوعی، کد نویسی در محیط Mat LAB R2020a انجام شد. در این برنامه برای تعیین همگرایی شبکه، مقادیر مربوط به نرون‌های ورودی با استفاده از رابطه ۹ نرمالیزه شد؛ زیرا وارد کردن داده‌ها به صورت خام به کاهش سرعت و دقت شبکه منجر می‌شود (Go et al, 2017). در این رابطه، Z_i وزن پیکسل مورد نظر، $Z_i(\min)$ کمترین وزن شاخص مورد نظر، $Z_i(\max)$ بیشترین وزن شاخص مورد نظر و X_i وزن نرمال شده شاخص مورد نظر است. برای آموزش ۰/۰۷۰ و اعتبارسنجی ۰/۰۳۰ از داده‌ها در شبکه استفاده شد. الگوی آزمایش باید تا حد امکان کل فضای داده‌ها را پوشش و قابلیت تعمیم شبکه را افزایش دهد تا بتواند در برابر هر ورودی، خروجی متناظری را ارائه کند (Fattahi, 2017). نرون‌ها می‌توانند برای تولید خروجی از توابع متحرک متفاوتی استفاده کنند که در این تحقیق با توجه به محدوده مد نظر صفر تا یک تابع غیر سیگموئید، از رابطه ۹ به دلیل مشتق بودن و سادگی استفاده شد.

$$X_i = \frac{Z_i - Z_i(\min)}{Z_i(\max) - Z_i(\min)} \quad \text{رابطه ۹}$$

$$F(X) = \frac{1}{1 - e^{-x}} \quad \text{رابطه ۱۰}$$

۳-۳- الگوریتم جنگل تصادفی و روش ارزیابی مدل

جنگل تصادفی RF، نوع مدرنی از درخت پایه است که اولین بار توسط برمن در سال ۲۰۰۱ ایجاد و توسعه داده شد. این الگوریتم، انبوهی از درخت‌های کلاس‌بندی و رگرسیون را در برمی‌گیرد (Berman, 2001). الگوریتم جنگل تصادفی مبتنی بر دسته‌ای از درختان تصمیم و اینک یکی از بهترین الگوریتم‌های یادگیری است. مدل پیش‌بینی کننده RF، بر میانگین گرفتن از نتایج حاصل از تمامی درخت‌های تصمیم مربوطه مبتنی است و طبقه‌بندی با صحت بالا را برای بسیاری از مجموعه داده‌ها انجام می‌دهد (Lee, 2017). مهم‌ترین ویژگی جنگل تصادفی، عملکرد بالای آن در اندازه‌گیری اهمیت متغیر است که مشخص می‌کند هر متغیر چه نقشی در پیش‌بینی پاسخ دارد. جنگل تصادفی شامل سه پارامتر تعریف شده توسط کاربر است که عبارتند از: تعداد متغیرهای مورد استفاده در ساخت هر درخت که قدرت هر درخت مستقل را بیان می‌کند، تعداد درختان در جنگل تصادفی و حداقل تعداد گره‌های انتهایی (Petros et al, 2008). قدرت پیش‌بینی جنگل تصادفی با افزایش قدرت درختان مستقل و کاهش همبستگی بین آنها افزایش می‌یابد (Lieb et al, 2012). از جمله علت‌های بالاتر بودن دقت این الگوریتم، بهره‌گیری از روش Bagging است که علاوه بر افزایش قابلیت پیش‌بینی مدل، از بیش برآزش آن جلوگیری می‌کند. الگوریتم جنگل تصادفی از بین تمام داده‌های موجود برای رویاندن درخت، فقط از ۶۶ درصد این داده‌ها استفاده می‌کند که به آن نمونه Bootstrap می‌گویند. این الگوریتم برای تکمیل ایده‌های جنگل تصادفی و افزایش تنوع و پراکندگی در آن طراحی شده است. از ۳۳ درصد داده‌های باقیمانده نیز برای ارزیابی درخت برآزش شده استفاده می‌شود. این فرایند چندین بار تکرار می‌شود و از میانگین تمام مقادیر پیش‌بینی شده به عنوان پیش‌بینی نهایی الگوریتم استفاده می‌شود (Simpson et al, 2012). برای تعیین تعداد بهینه درختان، ابتدا از تعدادی درخت اولیه برای تولید گراف تغییرات میانگین مربعات خطا (MSE) در مقابل تعداد خاص درختان نمونه آموزشی و ارزیابی، استفاده شد. این یک ابزار تحلیلی بسیار قدرتمند برای جستجوی اطلاعات و اصلاح تعداد بهینه

درختان در مدل جنگل تصادفی است. تعداد درختان بهینه به گونه‌ای انتخاب می‌شود که نخست، کمترین خطای آموزش در مدل‌سازی به دست آید و دوم، تعداد درختان نباید آن قدر زیاد شود که تجزیه و تحلیل متغیرها به زمان و محاسبات کامپیوتری زیادی نیاز داشته باشد. یکی از پارامترهای اصلی در جریان مدل جنگل تصادفی، پیش‌بینی‌کننده K (متغیر مستقل) در هر گره برای پیش‌بینی وابسته (پاسخ) است. مجموعه داده‌ها با D نمایش داده می‌شود، $D = (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ و B درخت تصادفی با ایجاد B داده جدید از D ایجاد می‌شود. مدل نهایی با میانگین گرفتن یا رأی‌گیری بین درختان کار می‌کند. جزئیات این الگوریتم عبارت است از:

برای B تا $B = 1$:

N نمونه را با جایگزینی از داده D انتخاب می‌کند و این نمونه‌ها را در مجموعه داده D_b قرار می‌دهد. از آنجا که نمونه‌گیری با جایگزینی صورت می‌گیرد، یک نمونه ممکن است چند بار انتخاب شود. یک درخت تصادفی به اسم T_b با D_b به روش پایین به دست بیاید: هر دفعه برای یافتن بهترین متغیر، ابتدا تعداد مشخصی از متغیرها را کاملاً به صورت تصادفی انتخاب (مثلاً m تا، m از قبل به مسئله داده شده است و معمولاً با جذر تعداد متغیرها برابر است) و بهترین متغیر را از میان آنها برمی‌گزینند. در مسئله رگرسیون مدل نهایی، میانگین تمامی درخت‌ها از رابطه یازده به دست می‌آید (Wikipedia). برای به دست آوردن خروجی نهایی متوسط، همه پیش‌بینی‌های درخت‌ها محاسبه می‌شود و خطای پیش‌بینی نیز بر اساس نمونه‌های خارج از کیسه طبق رابطه به دست می‌آید. در این رابطه، $\hat{y}(x)_i$ نتایج محاسباتی، y_i نتایج مشاهداتی، N تعداد کل مشاهدات است و MSE میزان خطای بین مقادیر مشاهداتی و محاسباتی را نشان می‌دهد. روش جنگل تصادفی برای طبقه‌بندی و اولویت‌بندی به طور خلاصه بدین صورت است که در ابتدا T نمونه خودراه‌انداز، از داده‌های آموزش استخراج می‌شود و از هر نمونه خود راه‌انداز β ، یک درخت طبقه‌بندی و رگرسیون هرس نشده ایجاد می‌شود که برای انشعاب در هم گروه رگرسیون، تنها یکی از M ویژگی انتخاب شده به صورت تصادفی استفاده می‌شود. در نهایت، خروجی طبقه‌بندی براساس یک نتیجه میانگین از پیش‌بینی‌های تمام درخت‌های آموزش دیده به دست می‌آید (Chen, 2018).

$$f(x) = \frac{1}{b} \sum_{B=1}^B T_B(x) \quad \text{رابطه ۱۱}$$


$$MSE^{OOB} = N^{-1} \sum_{i=1}^N [Y - (Y_1) - Y_1]^2 \quad \text{رابطه ۱۲}$$

۴- یافته‌های پژوهش


۴-۱- یافته‌های مدل شبکه عصبی مصنوعی

برای آموزش و آزمایش در مدل شبکه عصبی مصنوعی، از اطلاعات ۶۰۵ نقطه سیل‌گیر و سیصد نقطه فاقد سیل-گیری استفاده شد که از این تعداد، ۰/۰۷۰ برای آموزش مدل و ۰/۰۳۰ برای اعتبارسنجی به کار گرفته شد. تعداد تکرار نیز بین هزار تا ده هزار تغییر یافت و با انتخاب هزار، میزان کمترین خطا محاسبه شد. معمولاً الگوریتم پس انتشار خطا با نسبت یادگیری پایین، بهترین پاسخگو است (Kia, 2010). شکل ۶ با در نظر گرفتن اینکه نسبت کمیت برای الگوریتم پس انتشار خطا معمولاً ۰/۹ در نظر گرفته می‌شود، نسبت یادگیری از ۰/۱ تا ۰/۷ تغییر داده شد که با نسبت ۰/۱

بهترین جواب به دست آمد. تعداد نرون‌های لایه پنهان بین ده تا بیست تغییر یافت که با انتخاب پانزده نرون در لایه پنهان، کمترین مقدار خطا حاصل شد. ساختار نهایی شبکه با ده نرون در لایه ورودی، پانزده نرون در لایه پنهان و یک نرون در لایه خروجی مناسب تشخیص داده شد (شکل ۷) و پهنه‌بندی نهایی بر اساس این ساختار صورت گرفت. پس از مشخص کردن ساختار اصلی شبکه عصبی مصنوعی و فراهم کردن اطلاعات مورد نیاز برای آموزش این شبکه، طراحی شد. با رسیدن به خطای قابل قبول در مرحله آزمایش مشخص شد که شبکه عصبی ایجاد شده می‌تواند با دقت بالای ۰/۰۸۸، به وزن‌دهی پیکسل‌های ورودی پردازد (شکل ۸). با استفاده از وزن‌های مرحله پایانی مربوط به آموزش شبکه، کل منطقه - که شامل ۶۳۴۹۵ پیکسل و هر پیکسل دارای ده ویژگی مربوط به ده عامل تأثیرگذار در سیلاب‌های جریان واریزه‌ای بود - در ساختار شبکه قرار گرفت. پس از تحلیل این داده‌ها توسط شبکه عصبی، براساس هر کدام از پیکسل‌ها مقادیری بین صفر تا یک به دست آمد. در نهایت، نقشه پهنه‌بندی خطر با انتقال وزن پیکسل‌های نهایی در محیط ARC GIS در پنج کلاس خطر بسیار کم، کم، متوسط، زیاد و بسیار زیاد تهیه شد (شکل ۹).



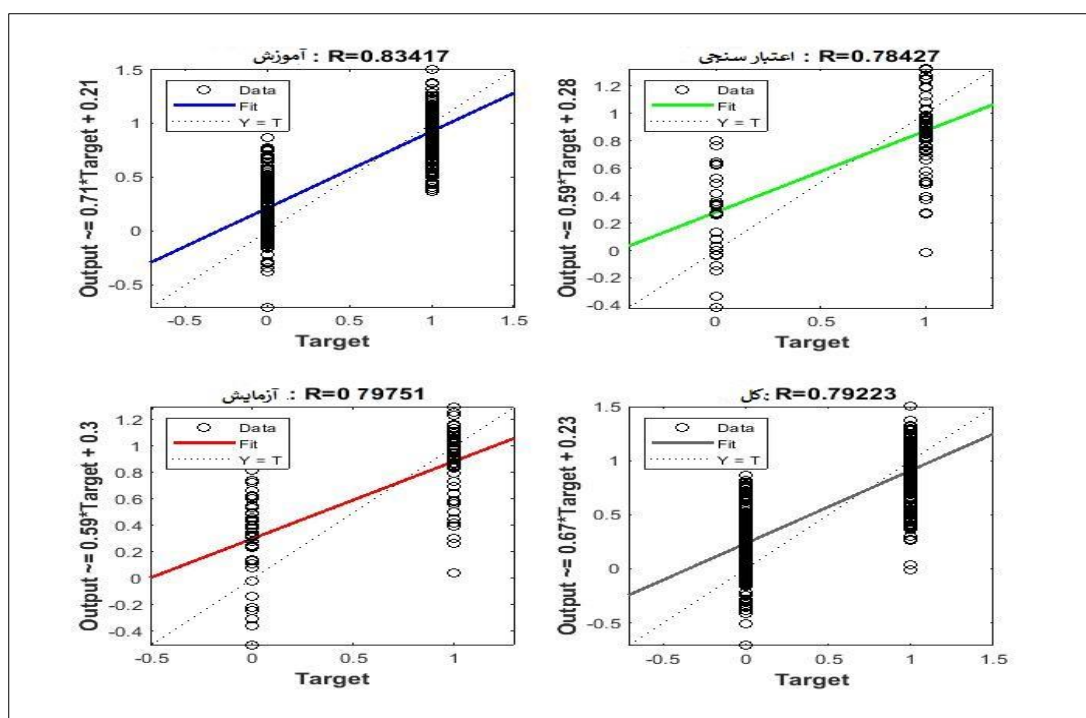
شکل ۶: عملکرد شبکه عصبی با پانزده نرون در لایه میانی



شکل ۷: ساختار شبکه عصبی مصنوعی برای پهنه‌بندی مناطق خطر سیلاب‌های جریان واریزه‌ای (Ibrahim, 2013)

۲-۴. یافته‌های مدل رندم فارست (RF)

در اجرای مدل جنگل تصادفی، تعیین درخت‌ها در آموزش و اعتبارسنجی خطای OOB¹ اهمیت بسیار زیادی دارد. برای تعیین تعداد مناسب درخت‌ها، ابتدا با استفاده از معیار میانگین مربعات خطا (MSE) چند مقدار اولیه برای تعداد درخت‌ها تعیین و مدل اجرا شد. با بررسی میزان میانگین مربعات خطا و معیار ضریب تعیین برای آموزش مدل بهینه با کمترین میزان خطا طراحی شد. مدل به دست آمده، با مقدار ضریب تعیین ۰/۹۴ و مجذور میانگین مربعات خطا ۰/۲۴ برای مرحله آموزش به دست آمد (شکل ۹). در نهایت پس از آموزش مدل و اعتبارسنجی آن، اعداد خطرپذیری سیلاب برای تمامی منطقه در بازه عددی صفر تا یک به دست آمد، سپس نتایج این مدل به محیط GIS ARC منتقل و نقشه نهایی به دست آمده در پنج کلاس آسیب‌پذیری با فواصل ۰/۲ تقسیم‌بندی شد. همچنین نتایج وزن رده‌های مربوط به هر طبقه نیز در شکل ۱۱ ارائه شد. با توجه به نقشه خطرپذیری سیلاب‌های جریان‌های واریزه‌ای، بیش از هفده درصد منطقه در کلاس بسیار زیاد قرار گرفت؛ به طوری که ۲۱ درصد از منطقه در کلاس خطر زیاد، ۲۶ درصد در کلاس متوسط، ۲۲ درصد در کلاس کم و ۱۲ درصد در کلاس خیلی کم قرار گرفت (شکل ۱۱).




شکل ۸: برازش خط رگرسیون برای داده‌های آموزشی شبکه

به منظور دستیابی به مدل منطقی و مناسب برای حوضه آبریز تنگراه، از منحنی ROC استفاده شد (شکل ۱۱). منحنی ROC از کامل‌ترین روش‌ها برای ارائه خصوصیت تعیین، شناسایی احتمالی و پیش‌بینی سیستم‌ها است که میزان دقت مدل را به صورت کمی برآورد می‌کند. در ارزیابی با روش منحنی راک، هر چه سطح این منحنی بیشتر باشد دقت مدل نیز بیشتر می‌شود و میزان آن بین ۰/۵ تا ۱ در تغییر است. به طور کلی در این روش، تقسیم‌بندی ۰/۹-۱ عالی، ۰/۹-۰/۹

¹ Out of bag error

۰/۸ خیلی خوب، ۰/۸ - ۰/۷ خوب، ۰/۷ - ۰/۶ متوسط و ۰/۶ تا ۰/۵ ضعیف است. برای رسم منحنی ROC در الگوریتم جنگل تصادفی، قبل از کلاس‌بندی نقشه وزن نهایی، نقاط لغزشی که برای ارزیابی در نظر گرفته شده‌است روی نقشه قرار گرفت، سپس وزنی که در هر نقطه به دست آمد (منظور کدهای ۱ و ۰) نیز به نرم‌افزار Mat lab R2020a انتقال یافت و دقت مدل با استفاده از کد دستوری سطح زیر منحنی حاصل شد. براساس نتایج منحنی راک، مقدار سطح منحنی منطقه مورد نظر با استفاده از الگوریتم جنگل تصادفی ۰/۹۴ برآورد شد (شکل ۹).

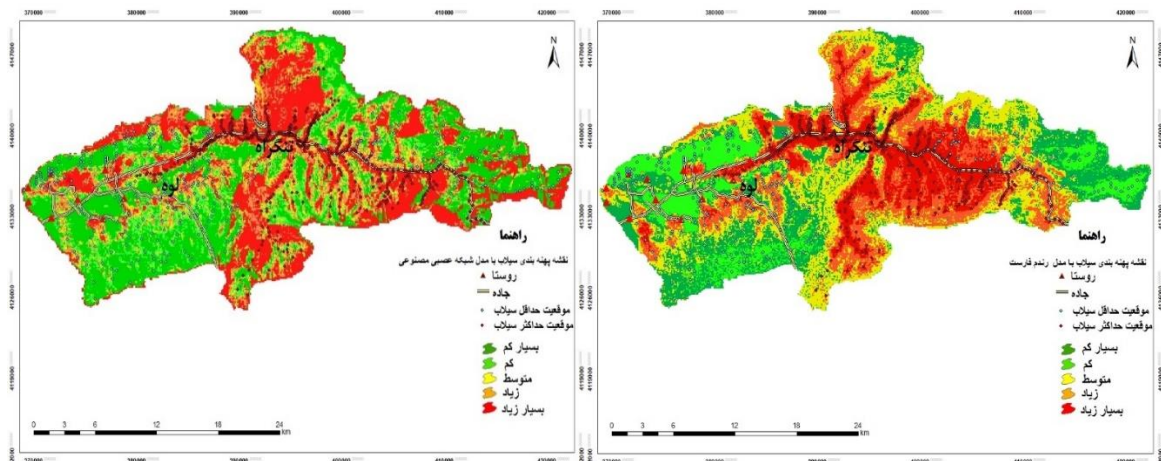


شکل ۹: ضریب تعیین رگرسیون (راست) و نمودار کاهش خطایی آموزش در ازای درختان (چپ)


۳-۴- ارزیابی دو مدل ANN و RF

نتایج به دست آمده از مدل جنگل تصادفی و شبکه عصبی مصنوعی، به صورت وزن و اهمیت متغیرها در وقوع حرکات واریزه‌ای در جدول ۱ آورده شده‌است. نتایج نشان داد که بیشترین وزن با رتبه معیار ۲۰۶ در رویکرد رندم فارست و مقدار ۲۰۴ در رویکرد شبکه عصبی مصنوعی، مربوط به میزان بارندگی است که این صحت ارزیابی دو مدل را در برآورد پهنه‌های سیلاب‌های جریان واریزه‌ای نشان می‌دهد. دومین عامل در ایجاد این حرکات، متغیر ارتفاع با وزن ۱۶۸ است. از آن جایی که قسمت شمال و جنوب شرقی مرتفع‌ترین نقاط منطقه است، این عامل به همراه شاخص بارندگی - که در رده اول قرار داشت - عامل فعال‌سازی نیروی ثقل و جابه‌جایی توده‌های واریزه‌ای و رواناب در سطوح دامنه‌ها است. پس از مشخص کردن ساختار اصلی در مدل RF و ANN، فراهم آوردن اطلاعات مورد نظر برای آموزش رویکردها و رسیدن به خطای قابل قبول، شبکه آماده شد تا تحلیل مناطقی را که با آن مواجه نشده‌است، انجام دهد. به این منظور، وزن‌های مرحله پایانی مربوط به آموزش شبکه عصبی مصنوعی با ضریب ۰/۲ همراه با پانزده نرون در لایه پنهان کل منطقه - که شامل پیکسل بود - در اختیار مدل ANN و RF قرار گرفت و بعد از این مرحله، مدل‌ها مقدار درجه خطرپذیری صفر تا یک را برای هر پیکسل تعیین کردند. با دسته‌بندی مقادیر به دست آمده و انتقال آن به نرم‌افزار ARC GIS، نقشه نهایی به دست آمده در پنج کلاس آسیب‌پذیری با فواصل ۰/۲ تقسیم‌بندی شد (شکل ۱۰). ذکر این امر لازم است که این نتیجه در تعداد مختلف نرون در لایه پنهان در شبکه ANN، کمترین خطا (RMSE) را دارد. با توجه به نقشه پهنه‌بندی سیلاب در منطقه مورد نظر با مدل RF، ۰/۱۷ درصد منطقه در کلاس خطر خیلی زیاد،

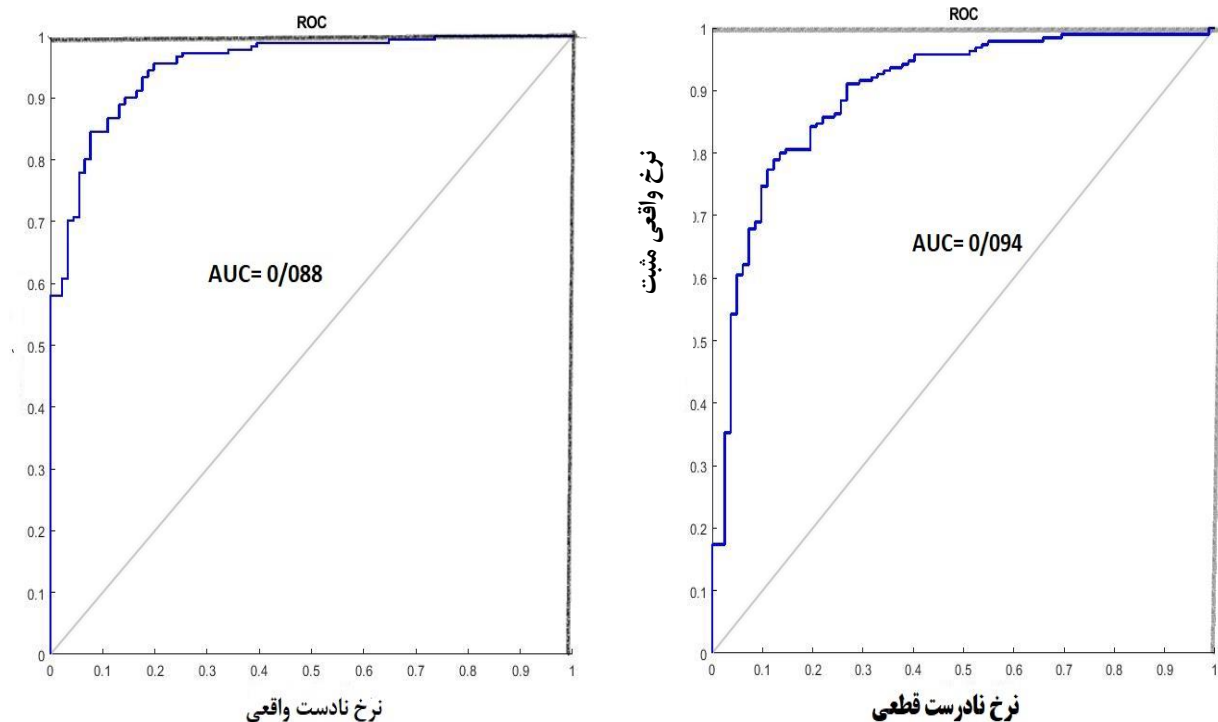
۰/۲۱ درصد خطر زیاد، ۰/۲۶ درصد خطر متوسط، ۰/۲۲ درصد خطر کم و ۰/۱۲ درصد خطر خیلی کم قرار دارد. این رویکرد در مدل شبکه عصبی مصنوعی نیز پهنه‌بندی بیشتری را برای خطر بسیار زیاد ارزیابی کرده‌است که این مقدار شامل ۰/۳۱ درصد از منطقه با خطر بسیار زیاد، ۰/۱۲ درصد خطر زیاد، ۰/۱۰ درصد خطر متوسط، ۰/۱۲ درصد خطر خیلی کم و ۰/۳۲ درصد خطر خیلی کم قرار دارد (شکل ۱۱). به منظور دستیابی به مدل منطقی و مناسب برای حوضه تنگراه، از منحنی ROC استفاده شد (شکل ۱۲). منحنی ROC، کامل‌ترین روش‌ها در ارائه خصوصیت تعیین، شناسایی احتمالی و پیش‌بینی سیستم‌ها است که میزان دقت مدل را به صورت کمی برآورد می‌کند. در ارزیابی با روش منحنی راک، هر چه سطح منحنی بیشتر باشد دقت مدل نیز بیشتر و میزان آن بین ۰/۵ تا ۱ در تغییر است. به طور کلی در این روش، تقسیم‌بندی ۰/۹-۱ عالی، ۰/۸-۰/۹ خیلی خوب، ۰/۷-۰/۸ خوب، ۰/۶-۰/۷ متوسط و ۰/۵ تا ۰/۶ ضعیف است. برای رسم این منحنی در الگوریتم جنگل تصادفی، قبل از کلاس‌بندی نقشه وزن نهایی، نقاط لغزشی که برای ارزیابی در نظر گرفته شده‌است روی نقشه قرار گرفت. سپس وزنی که در هر نقطه به دست آمد (منظور کدهای ۱ و ۰) نیز به نرم‌افزار Mat lab R2020a انتقال یافت و دقت مدل با استفاده از کد دستوری سطح زیر منحنی حاصل شد. براساس نتایج منحنی راک، مقدار سطح منحنی منطقه مورد نظر با استفاده از الگوریتم جنگل تصادفی، ۰/۹۴ و با استفاده از مدل شبکه عصبی مصنوعی، ۰/۸۸ برآورد شد (شکل ۱۲) که بیانگر دقت بالای مدل RF در پهنه‌بندی خطرات سیلاب در منطقه بود.



شکل ۱۰: نقشه پهنه‌بندی خطر جریان واریزه‌ای با استفاده از الگوریتم جنگل تصادفی و شبکه عصبی مصنوعی در حوضه آبریز تنگراه



شکل ۱۱: مساحت کلاس‌های نقشه خطر جریان واریزه‌ای با استفاده از الگوریتم جنگلی



شکل ۱۲: نمودار منحنی عملکردی راک و مقدار عددی سطح زیر نمودار راست مدل RF چپ مدل ANN

۵- بحث و نتیجه‌گیری

حوضه تنگراه به علت کوهستانی بودن همواره مستعد سیلاب‌های جریان واریزه‌ای است. سیلابی که در سال‌های ۱۳۸۱ و ۱۳۸۴ در منطقه رخ داد، خسارت‌های جانی و مالی جبران‌ناپذیری را در منطقه به همراه داشت. همین مسأله، مطالعه در خصوص عوامل مؤثر بر بروز سیلاب و تعیین پهنه‌های سیلابی را ضروری می‌سازد. برای این منظور، در این پژوهش از دو مدل RF و ANN استفاده شد. بر مبنای ارزیابی دو مدل، میزان بارندگی مهم‌ترین عامل است؛ زیرا بارش در همه زیرحوضه‌های منطقه با تداوم بالا رخ داده است. بارش، عامل اصلی شکل‌گیری چنین سیلاب‌ها و شروع حرکات واریزه‌ای است، همچنین اثر نفوذ بارش در شیب می‌تواند به تغییر مکش خاک و فشار مثبت منافذ منجر شود. بارش همچنین عامل اصلی به حرکت درآوردن واریزه‌های دامنه‌ای است که در مناطق پایین‌دست حوضه، خسارت‌های جبران‌ناپذیری را بر جای می‌گذارد. عامل بعدی شکل‌گیری این جریان‌ها در هر دو مدل، عامل ارتفاع است. بیشتر بخش‌های منطقه در ارتفاع بالای ۱۵۰۰ قرار دارد و برخی از عوامل از قبیل بارندگی، درجه حرارت، تبخیر و نوع ریزش‌های جوی نیز با ارتفاع حوضه در ارتباط است؛ بدین صورت که با افزایش ارتفاع، غالباً میزان بارندگی افزایش می‌یابد و از باران به برف تبدیل می‌شود. درجه حرارت نیز کاهش می‌یابد و میزان تبخیر را کاهش می‌دهد. بنابراین در شرایط بارندگی یکسان، میزان تولید رسوب در حوضه‌هایی که ارتفاع بیشتری دارند، بیش از حوضه‌های پست‌تر خواهد بود. همچنین چون هوازدگی سنگ‌ها در ارتفاع‌های بالا بیشتر اتفاق می‌افتد و پدیده ذوب و انجماد غالب است؛ به همین

دلیل، نقش ارتفاع در وقوع حرکات واریزه‌ای اهمیت بسیاری دارد. عامل سوم در هر دو مدل، تراکم زهکشی است که به میزان قابل توجهی بیانگر وضعیت فرسایش در بخش‌های مختلف حوضه است. در حوضه‌هایی که تراکم زهکشی بیشتر است، واکنش حوضه در برابر بارندگی نیز سریع‌تر و جریان‌های سطحی با سرعت بیشتری تشکیل می‌شود؛ بنابراین، سیلاب بیشتری را در پی خواهد داشت. نوع رواناب و تغییرات محیطی نیز به تنوع در تراکم زهکشی منجر می‌شود. عامل چهارم در مدل رندم فارست، کاربری اراضی است. در زمینه کاربری اراضی ذکر این امر لازم است که عوامل انسانی به تغییر کاربری و تبدیل جنگل به مراتع و مناطق مسکونی منجر می‌شود که این تغییر، خود از عوامل اصلی تشدید سیلاب‌های جریان واریزه‌ای در منطقه است. عامل بعدی، شاخص زمین‌شناسی است. حوضه تنگراه، بیشتر از سنگ‌های آهکی دولومیتی سازند مزدوران و مارن‌های سبز سازند چمن‌بید تشکیل شده است. از عوامل مهم، کنترل تراکم زهکشی نوع سنگ است. سنگ‌های سخت و مقاوم مانند گرانیت‌های نفوذی، گنیس، سنگ ماسه و کوارتز، تراکم زهکشی پایینی را ایجاد می‌کنند؛ زیرا این سنگ‌ها مقاومت بیشتری دارند و تنها کانال‌های اصلی می‌توانند آنها را فرسایش دهند. در سنگ‌های سست مانند شیل و رس که در حوضه مورد نظر در واحد مارنی PLq وجود دارد، مقدار کم آب جاری در یک حوضه آبریز کوچک می‌تواند برای فرسایش کافی باشد. عامل بعدی، شیب است که موارد مختلفی همچون سرعت جریان آب‌های سطحی، مقاومت توده خاک در مقابل لغزش، مقدار نفوذ آب در خاک و غیره به آن وابسته است. با افزایش شیب، سرعت جریان آب و در نتیجه قدرت تخریب و حمل آن افزایش می‌یابد و از میزان نفوذ آن در خاک کاسته می‌شود (Alizade, 2010). به دلیل سرعت و قدرت بالای آب در مناطق پرشیب، این مناطق استعداد فرسایشی بیشتر و توان تولید رسوب بالاتری خواهند داشت (wiser et al, 2004)، زیرا زمین‌های هموارتر برای ایجاد جریان‌های واریزه‌ای پتانسیل کمی دارند. عامل بعدی فاصله از آبراهه است. در یک بستر آبراهه شیب‌دار ممکن است هیچ جریان آبی در زمان‌های عادی وجود نداشته باشد، اما با ریزش سنگ‌ها و زمین‌لغزش‌ها، رسوبات به علت عرضه از دیواره‌های جانبی به تدریج انباشته می‌شود. از آنجا که یک آبراهه مسیر عبور آب غلیظ است، در هنگام بارش شدید، بستر آن به وسیله جریان آب عظیمی شسته می‌شود که گاه به دلیل اثرات افزایش محتوای آب و آبگونه‌ها در حین حرکت در شیب، زمین‌لغزشی کوچک رخ می‌دهد. همچنین در مناطقی که قدرت رودخانه بیشتر است، تأثیر آن بر وقوع زمین‌لغزش نیز بیشتر می‌باشد؛ زیرا آبراهه به کاهش مقاومت دامنه و فرسایش کناره جریان رودخانه منجر می‌شود؛ با این حال، فاصله از آبراهه در حوضه تنگراه در ایجاد سیلاب‌های دارای جریان واریزه-ای تأثیر چشمگیری دارد و بستر مناسبی برای انتقال این جریان‌ها در هنگام رخدادهای ناگهانی است. عامل آخر، شاخص رطوبت توپوگرافیک است که در پهنه‌های سیلاب در این منطقه تأثیر بسیار ناچیزی دارد. با توجه به قرارگیری نقاط روستایی در پهنه‌های خطر بسیار زیاد، این امر روستاها را از آسیب‌های این نوع از سیلاب‌ها مصون نمی‌سازد؛ زیرا پانزده روستا در کنار خروجی آبراهه‌های اصلی زیرحوضه‌های منطقه مورد نظر قرار دارد که محل تجمع آوردهای واریزه‌ای در هنگام بارش‌های ناگهانی است (شکل ۱۰)؛ با این حال، برای حفظ امنیت روستاها از این ناپایداری‌ها، لازم است تمهیدات لازم در اکثر روستاها اجرا شود تا از خسارت‌های پیش آمده در امان باشند.

در تحقیق حاضر با هدف ارزیابی آسیب‌پذیری، به شناسایی پهنه‌های مستعد سیلاب‌های جریان‌های واریزه‌ای در حوضه آبریز تنگراه پرداخته شد. غالب این جریان‌ها بر زندگی مردم و اقتصاد منطقه تأثیرات منفی داشت؛ به طوری که

آورد‌های واریزه‌ای توسط رخدادهای ناگهانی بر مناطق مسکونی تأثیر عمده‌ای گذاشت. در این مطالعه از روش نوین جنگل تصادفی - که یکی از انواع پیش‌بینی کننده‌های درخت و شبکه عصبی مصنوعی است - استفاده شد. نتایج بیانگر دقت بالای این روش نسبت به مدل شبکه عصبی مصنوعی در تعیین ارتباط بین متغیرهای محیطی است. پس از تهیه نقشه نهایی توسط مدل ایجاد شده، برای اعتبارسنجی نتایج از معیار منحنی عملکردی مدل ROC و مقدار زیر منحنی AUC استفاده شد. مقدار سطح زیر منحنی، برای مدل رندم فارست ۰/۹۴ و برای مدل شبکه عصبی مصنوعی ۰/۰۸۸ است که دقت و توانایی بالای مدل را در پهنه‌بندی خطر سیلاب‌ها در حوضه آبریز تنگراه نشان می‌دهد. نتایج حاصل از تحقیق حاضر می‌تواند در برنامه‌ریزی‌های آتی قابل توجه قرار گیرد تا رفتار طبیعی زمین به تلفات و خسارت‌های جانی و مالی منجر نشود.

با توجه به دقت بالای مدل الگوریتم جنگل تصادفی در پهنه‌بندی سیلاب، می‌توان پیشنهاد‌های قطعی را درباره مکان‌های خطر مشخص شده بیان کرد؛ از جمله این راهکارها، پیشنهادی در مورد نواحی مسکونی روستاهای تنگراه است. این نواحی در خروجی حوضه و بر روی قسمت‌هایی از مخروط‌ها شکل گرفته‌است که خطر وقوع جریان مواد بر آن وجود دارد. پس باید از خروجی آبراهه‌های حوضه دور شوند و در نواحی مرتفع‌تر و پادگانه‌های بسیار قدیمی رودخانه استقرار یابند. به علت مقاوم نبودن پل‌ها و سازه‌های ساخته شده در این منطقه، بیشتر نواحی در برابر خطر خسارت‌های احتمالی این جریان‌ها قرار دارند و بسیاری از سازه‌ها در زمان سیلاب سال ۱۳۸۰ و ۱۳۸۱ تخریب شد و از بین رفت؛ بنابراین، باید ساخت و ساز این گونه سازه‌ها اصولی باشد و بر اساس برآورد حداکثر دبی لحظه‌ای و تخمین حمل مواد حاصل از این جریان‌ها از جمله سنگ، چوب و رسوبات حاصل از این جریان‌ها صورت گیرد. طبق مشاهدات انجام شده برای جلوگیری از جریان واریزه‌ای و کم کردن سرعت آن در روستای تنگراه، سیل‌بندی ساخته شد؛ اما سازه‌های این سیل‌بند نمی‌تواند چنین جریان‌هایی را تحمل کند و باید کاملاً اصولی ساخته شود. برای جلوگیری از طولانی شدن مسیرهای جریان واریزه‌ای نیز بایستی سیل‌بندها در نواحی بالا دست ایجاد شود. راهکار دیگر، آگاه‌سازی مردم عامه با جریان مواد است؛ اغلب مردم در مورد چنین جریان‌هایی اطلاعات کافی ندارند و همین فقدان اطلاعات، میزان خسارت‌ها را افزایش می‌دهد. در این رابطه برای فهم بیشتر این امر پیشنهاد می‌شود فیلم‌هایی سه بعدی - که برای اکثر مردم قابل فهم و درک باشد - در این زمینه تهیه و نمایش داده شود. نتایج به دست آمده از تحقیق حاضر با نتایج پژوهشگرانی Avand and Moradi (2020) در استان مازندران، و Janizadeh و همکاران (2019) در استان مرکزی از لحاظ دقت بیشتر مدل رندم فارست در تهیه نقشه حساسیت سیل با پژوهش مورد نظر همخوانی و مطابقت دارد. پژوهشگران نامبرده پیشنهاد داده‌اند برای نقشه‌برداری از حساسیت سیل از روش‌های یادگیری ماشین استفاده شود.

منابع

1. Ahmadabadi, A., & A. Saffari., (2020). Flood risk analysis based on wms model in urban catchment case: Darband Basin, Golabdereh, Saad Abad, Tehran. *Journal of Applied Research in Geographical Sciences*. 57, 318-334.
2. Agha Nabati, A., 2006. *Geology of Iran*, Geological Survey of Iran: Tehran.
3. Alaei Taleghani, M., & et al., (2011). Zoning of slope susceptibility to instability (slip) in Javanrood watershed using a two-dimensional statistical model of surface density. *Geography and Development*. 22, 72-57.

4. Alizadeh, A., (2010). Principles of Applied Hydrology, Astan Quds Razavi Publications.
5. Avand, M., & H. Moradi., (2020). Preparation of flood sensitivity map using Bayesian generalized random and linear forest machine learning models. *Environment and Water Engineering*. 6, 1.
6. Ayalew, L., Yamagishi, H., The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko Mountains, Central Japan, / *Geomorphology* 65 (2005) 15–31.
7. Baba Ali, H., & R. Dehghan., (2017). Prediction of flood discharge using wavelet neural network. *Hydro geomorphology*. 11, 149-168.
8. Babylon, M, Shirani.H., (2018). Evaluation of landslide sensitivity zonation map using a combination of reliability factor and logistic regression using geomorphic indices, *Quantitative Geomorphological Research*, 3, 91-116.
9. Band, S.H.; Janizadeh, S.; Chandra Pal, S.; & A. Saha, 2020. Flash Flood Susceptibility Modeling Using New Approaches of Hybrid and Ensemble Tree-Based Machine Learning Algorithms, *Remote Sens*, 12, 3568. doi:10.3390/rs12213568.
10. Barkhorda, M., & A. Chavoshian., Flood zoning, Technical workshop on non-structural methods of flood management.
11. Breiman, L., 2001. Random forests, *Machine learning*, 45(1), 5-32.
12. Costache, R., 2019. Flood Susceptibility Assessment by Using Bivariate Statistics and Machine Learning Models - A Useful Tool for Flood Risk Management, *Water Resources Management*, 33, 3239-3256.
13. Dehgani, R., (2017) Prediction of flood discharge using wavelet neural network, *Hydrogeomorphology*, P 149-168.
14. Darvishzadeh, A., 2006. Geology of Iran, Amir Kabir Publishing Institute: Tehran.
15. Dai, F. C., & C. F. Lee., (2002). Landslide characteristics and slope instability modeling using GIS, Lantau Island, Hong Kong. *Geomorphology*. 42, 213-228.
16. Datto, f., & M. Chiarle., (2014). 3D Video Simulation of a Debris Flow. *Hydrological Protection (CNR IRPI)*.
17. Demir, V., & O. Kisi., (2016). Flood Hazard Mapping by Using Geographic Information System and Hydraulic Model: Mert River, Samsun, Turkey. *Advances in Meteorology* Volume 2016, Article ID 4891015, 9 pages.
18. Dowling, A., & P. M. Santi., (2014). Debris Flow and their toll on Human life: a Global Analysis of Debris-Flow fatalities from 1950 to 2011. *hat Hazards*. 71, 203-227.
19. Entezari M., Jaliliyan. T. (۲۰۱۹), Flooding susceptibility zoning using the evaluation between frequency ratio method and control weight of a case study: Kermanshah province, *Natural environment hazards.*, P19-40.
20. Farrokh Payam, R., & Z. Jahani., (2014). Intelligent Prediction of Particleboard Properties Using Artificial Neural Network. *Iranian Journal of Wood and Paper Research*. 29, 2, 253-242.
21. Fattahi, M.; Toosi, S.; & M. Kh. Tabar Ahmadi, 2007. Estimation of Neka river sediment load by an artificial neural network. *7th International on River Engineering*, Shahid Chamran University, Ahwaz, Iran, P 253-261.
22. Geographical Organization of the Armed Forces, 2003. IRS satellite images of the study area.
23. Geological Survey of Iran, Dozen geological maps, with a scale of 1: 100000.
24. Gholamhosseini, h., 2006. The comparison of different feed forward neural network architectures for ECG signal diagnosis, *Medical Engineering & Physics*, 28, 372-378.
25. Haddadi, F., & S. Kanchi., (2006), Intrusion Detection and Attack Classification Using Feed-Forward Neural Network, *Second International Conference on Computer and Network Technology*.

26. Hosseinzadeh, R., & A. Bidkhori., (2010). GIS (Fundamentals and Training of ArcGIS Software), Mashhad Jihad University Press.
27. Hosseinzadeh, S. R., & M. Jihadi Torghi., (2006). Geomorphic analysis of catastrophic floods of Madersu River (Golestan forest). *Journal of Geography and Regional Development*. 7, 109.
28. Housing Foundation of the Islamic Revolution, 2006. Report on the destructive flood in Golestan and the performance of the foundation, Office of Reconstruction and Renovation of Deprived Areas of the Housing Foundation of Golestan Province.
29. Hung-Yuan, Ch.; Che-Chang, H.; & H. Chih-Hsiang(2007). Support vector machines using Bayesian-based approach in the issue of unbalanced classifications, *Expert Systems with Applications*, 38(9) , 11447-11462.
30. Jakob, M., & O. Hunger.,(2005). Debris- flow Hazards and Related Phenomena.
31. James, G.; Witten, D.; Hastie, T.; & R. Tibshirani, 2013. An introduction to statistical learning (Vol. 112): Springer.
32. Janizadeh. S., & M. Avand., (2016). Prediction Success of Machine Learning Methods for Flash Flood Susceptibility Mapping in the Tafresh Watershed, Iran. *Sustainability*. 11, 5426; doi:10.3390/su11195426.
33. JICA CTI Engineering International Co. Ltd., 2006. The study on flood and Debris flow in the coastal area focusing on the flood-hit Region Golestan Province.
34. Jieling, W.; Fan Zhuang, D.; & D. Jiang, 2012. Assessment of Debris Flow Hazards using a Bayesian network, *Geomorphology*, 171-172, 94-100.
35. Khosravi, Kh.; Shahabi, H.; Thai Pham, B.; Adamowski, J.; & A. Shirzadi, 2019. Comparative Assessment of Flood Susceptibility Modeling Using Multi-Criteria Decision-Making Analysis and Machine Learning Methods, *Journal of Hydrology*.
36. Kia, M. B.; Pirasteh, S.; Pradhan, B.; Mahmud, A. R.; Sulaiman, W. N. A.; & A. Moradi, 2012. An artificial neural network model for flood simulation using GIS: Johor River Basin, Malaysia, *Environmental Earth Sciences*, 67(1), 251-264.
37. Kia, M., 2010. *Neural Network in MATLAB*, Kian Rayaneh Sabz Publications, 229.
38. Kissi, O., 2005. Suspended sediment estimation using neuro-fuzzy and neural network approaches, *Hydro Sci Journal*1, 50, 683- 696.
39. Lee Sunmin Kim J. C.; Jung, H. S.; Lee, M. J.; & S. Lee, 2017. Spatial prediction of flood susceptibility using random-forest and boosted-tree models in Korea's Seoul Metropol. *German, Nat. Hazard. Risk*, 8, 1185-1203.
40. Lee, I.; Kim, J.; & H. Jung, 2017. Spatial prediction of flood susceptibility using random-forest and boosted-tree models in Seoul metropolitan city, Korea, *GEOMATICS, NATURAL HAZARDS, AND RISK*, 8, 2, 1185-1203.
41. Lieb, M.; Glaser, B.; & B. Huwe, 2012. Uncertainty in the spatial prediction of soil texture: comparison of regression tree and Random Forest models, *Geoderma*, 170, 70-79.
42. Lieue, X., 1995. Size a Debris flow Debostition Model Experiment Approach, *Environ Geo*, 170, 70-80.
43. Liu, Yan.; Lu, X.; Yao, Y.; & N. Wang, 2020. Mapping the risk zoning of storm flood disaster based on heterogeneous data and a machine learning algorithm in Xinjiang, China, *Flood Risk Management*, 2021;14:e12671.
44. Luu, C., & J. V. Meding., (2018). A flood risk assessment of Quang Nam, Vietnam. *Water*. 10(4), 461.
45. Lverson, R. M.; Reid, M.; & R. G. Lhusen, 1997. Debris-flow mobilization from Landslides *Earth Planet*, 25, 85-138.
46. Mahmoudi, F., 2007. *Dynamic Geomorphology*, Payamnoor University Press: Tehran.

47. Moradi nejad., Karimi,M.,(2011), Evaluation of different flood hydrograph simulation methods using HEC-HMS software package (case study: Chel Gezi watershed). Iranian water research.P29-38.
48. Mir Sanjari, Mehrdad. Idem, A. R., 2018. Landslide zoning using LNRF model (study area: Qamroud-Aligudarz catchment), Journal of Environmental Hazards, 7, 18.
49. Mishra, A., & A. Desai., (2006). Drought forecasting using feed-forward recursive neural network. ecological modeling. 198, 127-138.
50. New Zealand, and implications for debris-flow hazard assessment.
51. Nicodemus, K. K., 2011. Letter to the Editor: On the stability and ranking of predictors from random forest variable importance measures, Briefings in Bioinformatics, 12, 369-373.
52. Peters, J.; Verhoest, N.; Samson, R.; Boeckx, P.; & B. De Baets, 2008. Wetland vegetation distribution modeling for the identification of constraining environmental variables, Landscape Ecology, 23, 1049- 1065.
53. Pourghasami. H.; & N. kerle.; (2016). Random forests and evidential belief function-based landslide susceptibility assessment in Western Mazandaran Province, Iran February 2016. Environmental Earth Sciences. 75(3).
54. Qanavati, E., 2013. Flood Danger Zoning in Karaj Using Fuzzy Logic, Geography and Environmental Hazards, 8.
55. Rahimifar, I., & A. Behrmand., (2011). Introduction and preparation of topographic moisture index (TWI) map, Fifth National Conference on Watershed Management and Soil and Water Management.
56. Sadler, J.; Goodall, J.; Morsy, M.; & K. Spencer, 2018. Modeling urban coastal flood severity from crowd-sourced flood reports using Poisson regression and Random Forest, Journal of Hydrology, 559, 43-55.
57. Samuels, P., & B. Gouldby., (2005). Language of Risk: Integrated Flood Risk Analysis and Management Methodologies, HR Wallingford, Report No. T32-04-01, March 2005.
58. Scally, F., & I. Owens., (2010). Controls on fan depositional processes in the schist ranges of the Southern Alps. Geomorphology. 122, 99-116.
59. Şen, Z., 2018. Flood Modeling, Prediction, and Mitigation, Istanbul Medipol UniversityBeykoz, Istanbul Turkey, ISBN 978-3-319-52355-2.
60. Shahabi, H.; Shirzadi, A.; Ghaderi, K.; & E. Omidvar, 2019. Flood Detection and Susceptibility Mapping Using Sentinel-1 Remote Sensing Data and a Machine Learning Approach: Hybrid Intelligence of Bagging Ensemble Based on K-Nearest Neighbor Classifier, Remote Sens. 2020, 12, 266; doi:10.3390/rs12020266.
61. Simpson, G. L., & H. J. B. Birks., (2012). Tracking environmental change using lake sediments. Springer Publication. 5, 673.
62. Spatial prediction of flood susceptibility using random-forest and boosted-tree models in Seoul metropolitan city, Korea, 2017. GEOMATICS, NATURAL HAZARDS AND RISK, 8, 2, 1185-1203.
63. Stumpf, A., 2011. Object-oriented mapping of landslides using Random Forests, Remote Sensing of Environment, 115(10), 2564-2577.
64. Takahashi, T., 2007. Debris-flow: Mechanics, Prediction and Countermeasures, Proceedings and Monographs in Engineering Water and Earth sciences.
65. Tehrany, M. S.; Pradhan, B.; & M. N. Jebur, 2014. Flood susceptibility mapping using a novel ensemble weights-of-evidence and support vector machine models in GIS, J Hydrol, 512, 332-343.
66. Trigila, A.; Catani, F.; Casagli, N.; Crosta, G.; Esposito, C.; Frattini, P.; Iadanza, C.; Lagomarsino, D.; Lari, S.; ScarasciaMugnozza, G.; Segoni, S.; Spizzichino, D.; & V.

- Tofani, 2012. The landslide susceptibility map of Italy at 1:1 Million scale, Geophysical Research Abstracts, 14, EGU2012-7655, 2012.
67. Villanueva, V. R., & A. D. Herrero., (2010). dendrogeomorphic analysis of flash floods in a small ungauged mountain catchment (central Spain). Geomorphology. 118, 383-392.
68. Wan-jie Liang, Zhuang,H., Assessment of debris flow hazards using a Bayesian Network, Geomorphology 171-172 (2012) 94-100
69. Yuan, CH., 2005. Rainfall Duration and Debris flow Initiated Studies for Real-time Monitoring, Environ Geol, 47, 715-724.
70. Yuenglingng, J., & M. Deyang., (2011). Risk Assessment of debris flow in Songne Stream Taiwan. Engineering Geology. 123, 100-12.
71. Yun fan, T., 2007. A Debris -flow Simulation Model for the Evaluation of Protection Structures, Journal of Mountain Science, 3, 193-202.

Zoning of Susceptible Areas with Debris Flows Using Machine Learning Algorithms (Case study of Tangarah Basin -Golestan Province)

Fariba Paknejad :Ph.D. Candidate, Faculty of Geomorphology, Kharazmi University, Tehran.

Ali Ahmadabadi* : Assistant Professor of Geomorphology, Faculty of Geographic Sciences, Kharazmi University, Tehran.

Ezatollah Qanavati :Associate Professor of Geomorphology, Faculty of Geographical Sciences, Kharazmi University, Tehran

Hasan zahmatkesh :Ph.D. Candidate, Faculty of Geomorphology, Kharazmi University, Tehran.

Article History (Received: 2021/12/24

Accepted: 2022/04/16)



1- Introduction

Since the beginning of human civilization, human life has always been threatened by natural disasters. Floods are one of the most severe and dangerous natural events that cause a lot of human and financial losses. Although humans today have realized how they are originated, they are still not able to fully control such natural events (Qanavati et al., 2009). Different definitions of flood and their types have been used in different parts of the world (Chuboklu, 2016; 1). One of these cases is sedimentary currents, which are local hydrological phenomena that occur in small catchments with an area of several square kilometers to several hundred square kilometers with a response time of several hours or less. Therefore, these phenomena are one of the most important natural hazards that have serious casualties and financial losses around the world, especially in mountainous basins (Vilanova et al., 2010) in addition to natural environmental conditions, human activities, and lack of planning. also causes the increase and increase of frequency and volume, as well as financial and human losses caused by deposit flows (Qanavati, 2013). One of the ways that can reduce the damage caused by floods is to determine the areas that produce floods and apply appropriate methods to control them (Ahmadabadi, 1399; 318). These currents are related to torrential rains and are a destructive and common hazard in the study areas. Phenomena such as slipping on a steep slope along a small sloping canal and sediment deposition are of this category (Jacob, Hanger, 2005: 9). Floods of deposit streams can lead to catastrophes that pose a serious threat to the lives and property of individuals and economic development. This doubles the need to assess the vulnerability of areas prone to these currents in the area.

2- Methodology

To perform sensitivity analysis and prepare a zoning map of floods with debris flow in the basin, the importance and relationship of each of the factors affecting the debris flow should be evaluated. The most important factors for creating debris flows are the height, slope, and sudden precipitation with a very high flow rate. In this study, according to extensive field studies, 10 effective factors in creating debris flow floods were identified and used, including elevation, slope percentage, distance from the stream, drainage density, geology, rainfall, land use, slope direction, soil layer, waterway strength index, and topographic moisture index. To prepare these layers from basic data, 1: 50000 topographic maps and to prepare geological maps and fault maps from 1: 250000 and 1: 100000 scale geological maps published by the Geological Survey of Iran were used. The digital elevation model with a ground separation of 30 meters has been used to prepare factors such as height, slope, slope direction, and slope curvature. Digitization of base maps and functions has been done using

ARC GIS 10.5 software and Euclidean distance has been used to prepare lithological factors, distance from the road, and distance from the waterway. The flow rate index indicates the strength of water flow in terms of erosion, which was prepared in the GIS software environment. To prepare the map of total annual rainfall, the hydrometric stations of Strait, Galikesh, Tamar, and Dome of the Nightmare have been used, so that it has been interpolated in ARC GIS 10.5 software using mathematical functions. Land use invoice based on Landsat 7 (2014) satellite images and Google Earth archive, as well as the land use information layer of Golestan province, which had been prepared by the General Department of Natural Resources, had been used. Topographic Humidity Index (TWI) is one of the indicators affecting the occurrence and potential of floods in watersheds (Wooger 2019). To prepare this index, ARC GIS software was used and the TWI index was obtained from Equation One.

3-Results

For training and experimentation in the artificial neural network model, the data of 605 flood points and 300 non-flood points were used. 0.070 has been used for model training and 0.030 for validation. Usually, the error propagation algorithm with a low learning ratio gives the best answer (Kia, 2010; 229). The number of neurons in the hidden layer was changed between 10 and 20, and by selecting 15 neurons in the hidden layer, the least amount of error was obtained. The final network structure was identified with 10 neurons in the input layer, 15 neurons in the latent layer, and 1 neuron in the output layer, And based on this structure, the final zoning was done. Using the final stage weights related to network training, the whole area, which included 63495 pixels, and each of the pixels had 10 characteristics related to 10 factors influencing the debris flow floods, was included in the network structure. After analyzing this data by the neural network, values between zero and one were obtained based on each of the pixels. Finally, the hazard zoning map was prepared by transferring the weight of the final pixels in the ARC GIS environment into 5 hazard classes: low, very low, medium, high, and very high. In the implementation of the stochastic forest model, the identification of trees is very important in OOB error training and validation. To determine the appropriate number of trees, using the mean square error (MSE) criterion, first, some initial values for the number of trees were determined, and then the model was implemented. By examining the mean square error and the coefficient of determination, the optimal model with the lowest error was designed. The resulting model was obtained with a coefficient of determination of 0.94 and a mean squared error of 0.24 for the training stage. Based on the results of the rocking curve, the area of the curve in the area using the random forest algorithm is estimated to be 0.94.

4- Discussion & Conclusion

The results showed that the highest weight with a criterion rank of 2.06 in the random Forest approach and a value of 2.04 in the artificial neural network approach is related to rainfall, which shows the accuracy of the evaluation of the two models in estimating debris flow flood zones. The second factor in creating these movements is the height variable with a weight of 1.68. Since the northern and southeastern parts have the highest points of the region, this factor, along with the rainfall factor, which was in the first category, has been the factor often causing the city to activate the force of gravity and to move the sediment and runoff masses on the slope surfaces. After identifying the core structure in the RF and ANN models and providing the information needed to teach the approaches as well as achieving the promised error, the network prepared to analyze the areas it did not encounter. For this purpose, holding the weights of the final stage related to artificial neural network training with a coefficient of 0.2 along with 15 neurons in the hidden layer of the whole region, which included pixels, was provided to ANN and RF models in order to determine

the degree of risk from 0 to 1 for each pixel. By classifying the obtained values and transferring these values to ARC GIS software, the final map obtained was divided into 5 vulnerability classes with intervals of 0.2. Among the proposed solutions, the residential areas of Tangarah villages are formed on parts of cones that are exposed to the flow of materials. These dwellings are formed at the outlet of the basin and should be developed away from the outlet of the basin waterways and should be located in higher areas and very old barracks of the river. Due to the non-resistance capacity of bridges and structures built in this area, most areas are at risk of possible damage.

Keywords: Zoning, Golestan forest, Debris flow, RF method.