

مقایسه عملکرد مدل‌های مختلف یادگیری ماشینی در پهنه‌بندی خطر ریزش بهمن در جاده خلخال به شاهرود

مهرداد وهاب زاده زرگری - کارشناسی ارشد ژئومورفولوژی، دانشکده علوم اجتماعی، دانشگاه محقق اردبیلی، اردبیل، ایران.
فریبا اسفندیاری درآباد * - استاد ژئومورفولوژی، دانشکده علوم اجتماعی، دانشگاه محقق اردبیلی، اردبیل، ایران.
مسعود رحیمی - استادیار ژئومورفولوژی، گروه جغرافیا، دانشکده ادبیات و علوم انسانی، دانشگاه فردوسی مشهد، مشهد، ایران.

پذیرش مقاله: ۱۴۰۳/۰۳/۲۲ تأیید نهایی: ۱۴۰۳/۰۹/۲۸

چکیده

ریزش بهمن یکی از پدیده‌هایی است که رخداد آن سبب ایجاد خسارات زیادی به‌ویژه در مناطق کوهستانی می‌شود. بنابراین ارزیابی و شناخت عوامل مؤثر بر رخداد ریزش بهمن در مناطق کوهستانی امری ضروری است. جاده خلخال به شاهرود به خاطر نزدیکی به دریای خزر و همچنین داشتن شرایط کوهستانی، دارای بارش‌های سنگین برف در فصل زمستان است. از این رو در این پژوهش، عملکرد مدل‌های مختلف یادگیری ماشینی در پهنه‌بندی خطر ریزش بهمن در این مسیر مواصلاتی مورد بررسی قرار گرفت. برای شناسایی عوامل مهم در رخداد ریزش بهمن با توجه به مطالعات میدانی ۸ عامل شناسایی شد که شامل: ۱- ارتفاع ۲- پوشش گیاهی ۳- جهت شیب ۴- فاصله از گسل ۵- فاصله از جاده ۶- پهنه برفی ۷- کاربری اراضی ۸- شیب، است. تمامی این عوامل پس از پیش‌پردازش به صورت لایه‌های اولیه وارد نرم‌افزار SPSS MODELER شده و مدل‌سازی با ۸ نورو و ورودی ۸ نورو میانه و ۱ خروجی، طراحی شد. نتایج نشان داد که خروجی وزنی در مدل ماشین بردار پشتیبان بیشترین ارزش وزنی را برای لایه پهنه برفی با مقدار ۰/۲۶ و برای لایه شیب و فاصله از جاده به ترتیب به مقدار ۰/۱۸ و ۰/۱۵، اختصاص داده است. همچنین در مدل پرسپترون چندلایه نیز بیشترین ارزش وزنی برای عامل پهنه برفی با مقدار ۰/۳۰ و بعد از آن نیز برای لایه‌های فاصله از جاده و شیب به مقدار ۰/۱۷ و ۰/۱۳ اختصاص یافته است. در بخش اعتبار سنجی مدل‌ها نیز، نتایج نشان داد که خروجی مدل ماشین بردار نسبت به پرسپترون چندلایه دارای اعتباری بالایی بوده و مقدار AUC مدل ماشین بردار عدد ۰/۹۲۶ در بخش آموزش و عدد ۰/۹۳۶ در بخش تست شبکه می‌باشد. بر این اساس می‌توان گفت عملکرد مدل ماشین بردار پشتیبان در پهنه‌بندی خطر ریزش بهمن در محدوده مورد مطالعه عالی بوده و نتایج آن نسبت به مدل پرسپترون چندلایه دارای دقت بالایی می‌باشد.

واژگان کلیدی: ریزش بهمن، یادگیری ماشینی، ماشین بردار پشتیبان، پرسپترون چندلایه.

مقدمه

فرآیندهای طبیعی مانند فوران‌های آتش‌فشانی، زلزله، سیل و بهمن، زمانی به مخاطرات طبیعی تبدیل می‌شوند که جان و دارایی انسان را تهدید کنند. به عبارت دیگر مخاطرات طبیعی، فرآیندها و رویدادهای طبیعی هستند که تهدیدی بالقوه برای جان و مال انسان‌ها به وجود می‌آورند. مخاطرات طبیعی را بر اساس منشأ می‌توان به مخاطرات زمین‌شناختی، آب‌وهوایی، هیدرولوژیکی، بیولوژیکی و فرازمینی تقسیم‌بندی کرد (کالدرا و همکاران^۱، ۲۰۲۱، ۲). بهمن به عنوان یکی از مخاطرات طبیعی با منشأ هیدرولوژیکی، تهدیدی دائمی برای جان انسان‌ها، اموال و زیرساخت‌ها در مناطق کوهستانی، در سراسر جهان بشمار می‌آید (چیروی و همکاران^۲، ۲۰۲۴، ۱۴). بهمن عبارت است از توده‌های برفی که تحت تأثیر نیروی گرانش به سرعت از شیب تند دامنه‌ها فرود می‌آید (شوآیزر و همکاران^۳، ۲۰۲۱، ۳۹۵). عوامل متعددی می‌توانند در وقوع بهمن نقش داشته باشند. بارش برف سنگین، باد شدید، تغییرات ناگهانی دما و شیب تند کوه‌ها از جمله این عوامل هستند که در ریزش بهمن تأثیر زیادی دارند (مک کلانگ و شایرر^۴، ۲۰۰۶، ۱۰۳). به دلیل عدم آگاهی عمومی و اطلاعات اندک در مورد مناطق مستعد بهمن، این تهدید می‌تواند منجر به مشکلات جدی شود (کومار و همکاران^۵، ۲۰۱۹، ۲۱). وقوع بهمن با توجه به داشتن فشار و سرعت بالا می‌تواند جنگل‌ها، خطوط ارتباطی و شبکه‌های جاده‌ای در مناطق کوهستانی را از بین ببرد (بیاتو و همکاران^۶، ۲۰۱۸، ۳۷۳). بر اساس یک بررسی ۲۰ ساله در مناطق آلپی و آمریکای شمالی، به‌طور میانگین سالانه ۱۳۸ مورد تصادفات مرگبار ناشی از رخداد بهمن اتفاق می‌افتد (چوبین و همکاران^۷، ۲۰۱۹، ۷۱). آمارها نشان می‌دهد که در سال‌های اخیر، تعداد و شدت ریزش بهمن در حال افزایش است، به‌عنوان مثال، در سال ۲۰۱۹، بیش از ۱۰۰ نفر در اثر ریزش بهمن در جاده‌های کوهستانی در سراسر جهان جان خود را از دست دادند (هاگلی و همکاران^۸، ۲۰۲۲، ۱۹). به‌طور مسلم ارزیابی و پهنه‌بندی ریزش بهمن، گام مهمی در شناخت مخاطرات طبیعی است. بنابراین پهنه‌بندی و ارزیابی مناطق مستعد ریزش بهمن یکی از ضرورت‌های برنامه‌ریزی محیطی برای پیشگیری از بحران و کاهش خسارات جانی و مالی در مناطق مختلف است. پیش‌بینی دقیق زمان و مکان ریزش بهمن، کار دشواری است، با این حال روش‌های مختلفی برای پیش‌بینی خطر ریزش بهمن وجود دارد. استفاده از مدل‌های عددی، تصاویر ماهواره‌ای و داده‌های حسگرهای زمینی از جمله این روش‌ها هستند (بارتلت و همکاران^۹، ۲۰۱۲، ۷۹). در سال‌های اخیر، انواع مختلفی از مدل‌های یادگیری ماشینی کارآمد ظاهر شده‌اند و به‌طور فزاینده‌ای در تحقیقات ارزیابی و شناخت نواحی مستعد بهمن مورد استفاده قرار گرفته‌اند (فوون^{۱۰}، ۲۰۲۳، ۱۰). جاده ارتباطی خلخال به بخش شاهرود، به دلیل توسعه شبکه ارتباطی در منطقه و اهمیت اقتصادی، گردشگری و ترانزیتی، توجه ویژه‌ای را به خود جلب کرده است. این مسیر در یک منطقه کوهستانی و با شرایط ژئومورفیک و زمین‌شناسی ویژه‌ای قرار دارد و رخداد ریزش بهمن در این منطقه خسارات زیادی به را دنبال داشته است. همچنین در بسیاری از موارد، نهشته‌های بهمن باعث انسداد جاده شده و به‌طور مستقیم آسیب‌ها و اختلالاتی را در شبکه ارتباطی این

۱ Caldera

۲ Chiroiu

۳ Schweizer

۴ McClung and Schaerer

۵ Kumar

۶ Beato

۷ Choubin

۸ Haegeli et al

۹ Bartelt et al

۱۰ Phoon

منطقه به وجود آورده است. به همین دلیل، ارزیابی و پهنه‌بندی نواحی مستعد ریزش بهمن در جاده خلخال به بخش شاهرود بسیار حیاتی است. این مطالعات می‌تواند به برنامه‌ریزی و اقداماتی مؤثر برای کاهش خسارات جانی و مالی و حفاظت از محیط‌زیست منطقه منجر شود.

در رابطه با پدیده ریزش بهمن و خطرات ناشی از آن مطالعات زیادی در ایران و خارج از آن صورت گرفته است: سلیمانی مطلق و همکاران (۱۳۹۰)، به امکان پیش‌بینی احتمال وقوع بهمن در محورهای بهمن خیز استان تهران با استفاده از روش نزدیک‌ترین همسایه در محیط نرم‌افزار Arc GIS پرداختند. محققین به این نتیجه رسیدند که احتمال سقوط بهمن در محور دیزین - گاجره و محور کرج - چالوس به ترتیب با داشتن نسبت همسایه‌های مثبت ۰/۷۷ و ۰/۴۴ بالاتر از سایر محورها، پیش‌بینی می‌گردد. اسدماجرای و همکاران (۱۳۹۲)، به ارائه‌ی مدل ارزیابی خطر ریزش بهمن در محورهای کوهستانی کرج-چالوس پرداختند. محققین در این پژوهش از مدل تحلیل سلسله مراتبی (AHP)^۱ استفاده کردند و به این نتایج رسیدند که نقاط واقع در کیلومترهای ۶۵، ۷۳ و ۶۰ از مبدأ کرج خطر بیش‌تری دارند.

اسدماجرای و نهاوندی (۱۳۹۵)، به الگوی اولویت‌بندی جاده‌های کوهستانی از لحاظ ریسک ریزش بهمن با به‌کارگیری احتمال برخورد وسیله نقلیه پرداختند. محققین به این نتیجه رسیدند که نتایج حاصل از اولویت‌بندی نقاط حادثه‌خیز در محور کرج-چالوس و کیلومترهای ۶۲-۶۳ و ۶۳-۶۸ و ۷۰ تا ۷۴ بیشترین ریسک از نظر ریزش بهمن را دارند و باید راهکارهای ایمن‌سازی مناسب برای این نقاط در اولویت قرار گیرد. تاج‌بخش و نیک‌فال (۱۳۹۷)، به پیش‌بینی پتانسیل سقوط بهمن با استفاده از یک مدل پیش‌بینی عددی در منطقه شهرستانک پرداختند. محققین به این نتایج رسیدند که الگوهای پیش‌بینی همدیدی وضع هوا در این مطالعه، با شرایط جوی واقعی هم‌خوانی دارند و آستانه‌های معرفی‌شده برای پتانسیل وقوع بهمن با رخداد واقعی در این مطالعه هم‌خوانی خوبی دارند. نیری و همکاران (۱۳۹۷)، به پهنه‌بندی گذرگاه‌های بهمن خیز حوضه سیروان با تلفیق مدل تحلیل سلسله مراتبی و شبکه‌های عصبی مصنوعی پرداختند. محققین به این نتیجه رسیدند که بیش از ۸۶ درصد از منطقه مورد مطالعه جزء مناطق باقابلیت بهمن خیزی بالا است. احمدی و مرادی (۱۳۹۸)، به پهنه‌بندی وقوع بهمن با استفاده از مدل شبکه عصبی مصنوعی در کوهستان‌های شمالی استان البرز پرداختند. محققین به این نتیجه رسیدند که عامل جهت شیب، شیب و ارتفاع به ترتیب بیشترین تأثیر در دامنه‌های مستعد ریزش بهمن را دارند. نصرتی و همکاران (۱۳۹۸)، به ارزیابی و مدل‌سازی پارامترهای محیطی مؤثر بر وقوع بهمن در محور میگون-شمشک با استفاده از تکنیک‌های آماری چند متغیره پرداختند. محققین به این نتیجه رسیدند که آزمون، ضریب انحنای دره، درصد شیب، ضریب زبری، درصد پوشش گیاهی و سنگی دارای تفاوت معناداری است و مهم‌ترین پارامترهای مؤثر بر وقوع بهمن که از نتایج تحلیل عاملی بدست آمده، آزمون و ضریب زبری است. وارول^۲ (۲۰۲۲)، به نقشه‌برداری حساسیت بهمن با استفاده از نسبت فرکانس، فرآیند تحلیل سلسله مراتبی فازی و کلاسیک برای منطقه اوزون گول، ترکیه پرداخت و نتایج به‌دست‌آمده نشان‌دهنده این است که میزان موفقیت روش‌ها ۸۹/۱۲ درصد برای Fr، ۷۱/۱۵ درصد برای AHP و ۷۳/۲۴ درصد برای FAHP بوده و کارایی روش فازی AHP مورد آزمایش قرار گرفته و با مقایسه نتایج روش‌های مختلف، مشخص شد که روش Fr کارایی بهتری نسبت به سایر مدل‌ها دارد. بین^۳ و همکاران (۲۰۲۲)، به ارزیابی حساسیت بهمن برف بر اساس مدل یادگیری ماشین گروهی در کوه شالولی مرکزی پرداختند. در این تحقیق از مدل‌های پرسپترون چندلایه، رگرسیون لجستیک، همراه با دو مدل یادگیری ماشینی استفاده‌شده است. محققین به این نتایج دست یافتند که ۱۰/۰۱ درصد از منطقه در کلاس خطر خیلی زیاد و ۱۵/۳۳ درصد از منطقه در کلاس خطر زیاد قرار گرفته است. چیرویو^۴

^۱ Analytical Hierarchy Process

^۲ Varol

^۳ Bian et al

^۴ Chiroiu et al

و همکاران (۲۰۲۳)، به هم‌زمانی بهمن برفی برگرفته از بازسازی حلقه‌درختی چندمسیره در کوه‌های فاگارش (کارپات‌های جنوبی، رومانی) پرداختند. محققین به این نتیجه رسیدند که میانگین فاصله رخداد رویدادهای گسترده و شدید ۴/۱ سال است. بلاگووچشنسکی^۱ و همکاران (۲۰۲۳)، به کاربرد هوش مصنوعی در ارزیابی و پیش‌بینی خطر بهمن در ارتفاعات ایل‌آلتائو پرداختند. محققین به این نتیجه رسیدند که این مدل به‌درستی سطح فعلی خطر بهمن را در ۹۰ درصد موارد ارزیابی کرد است. یویشیری^۲ و همکاران (۲۰۲۴)، به بررسی بهمن برفی در سایکم هیمالیا از طریق نقشه‌برداری انسجام و جابجایی داده‌های Sentinel-1A SAR پرداختند. محققین به این نتیجه رسیدند که در نیمه دوم مارس ۲۰۲۳ و نیمه اول آوریل ۲۰۲۳ کاهش قابل‌توجهی از انسجام، افزایش و جابجایی عمودی در منطقه مورد مطالعه وجود دارد و این مشاهدات مصادف با آسیب در مقیاس بزرگی است.

تایرل^۳ (۲۰۲۴)، به‌پیش‌بینی بهمن با تجزیه و تحلیل جغرافیایی در جنوب غربی کلرادو با استفاده از مدل رگرسیون لجستیک باینری پرداخت. محقق به این نتیجه رسید که نرخ موفقیت ۶۴ تا ۷۲ درصدی در پیش‌بینی بهمن در مسیرهای کریدور بزرگراه است. مطالعات انجام شده فوق در خصوص مخاطره ریزش بهمن اطلاعات مفیدی را ارائه داده است. به‌صورت کلی می‌توان گفت استفاده از مدل‌های یادگیری ماشینی و هوش مصنوعی در رابطه با شناسایی و ارزیابی مناطق مستعد ریزش بهمن در سال‌های اخیر پیشرفت چشم‌گیری داشته است اما آنچه پژوهش حاضر را از مطالعات فوق متمایز کرده است، به‌کارگیری عوامل مختلف به‌ویژه عامل پهنه برفی است. یکی از مهم‌ترین عامل که در ریزش بهمن اثر دارد پهنه برفی است که در فرآیند مدل‌سازی و پهنه‌بندی خطر ریزش بهمن در منطقه مورد مطالعه استفاده شده است. بهره‌گیری از این داده‌ها دقت مدل را در پهنه‌بندی و شناسایی مناطق مستعد بالا می‌برد و خروجی مدل را قابل‌اطمینان‌تر می‌کند.


منطقه مورد مطالعه

محور ارتباطی خلخال به شاهرود به طول ۶۰ کیلومتر در جنوبی‌ترین نقطه خلخال در محدوده سیاسی استان اردبیل با مختصات جغرافیایی ۳۷ درجه ۳۵ دقیقه ۴۹ ثانیه تا ۳۷ درجه ۱۷ دقیقه ۳۹ ثانیه عرض شمالی و ۴۸ درجه ۳۴ دقیقه ۴۷ ثانیه تا ۴۸ درجه ۳۱ دقیقه ۲۴ ثانیه طول شرقی قرار دارد (شکل ۱). از ارتفاعات منطقه می‌توان به رشته‌کوه‌های تالش (باغرو داغ) در شرق و ارتفاعات غربی (فلات آذربایجان) اشاره کرد که بیشترین ارتفاع منطقه ۲۴۰۰ متر و کم‌ترین ارتفاع ۱۳۲۸ متر بوده و ۷۰ درصد منطقه دارای تیپ کوهستانی است. منطقه به لحاظ تکتونیک بسیار فعال بوده و تحت تأثیر فازهای کوه‌زایی چین‌خوردگی‌های مختلفی در منطقه به‌صورت طاق‌دیس و ناودیس دیده می‌شود. طی این فعالیت تکتونیکی گسل‌ها و شکستگی‌های مختلفی در منطقه ایجاد شده است که از اصلی‌ترین گسل‌ها می‌توان به گسل هروآباد یا امام‌چای اشاره کرد، همچنین به لحاظ اقلیمی به خاطر اینکه محدوده در یک ناحیه کوهستانی قرار دارد و نزدیکی به دریای خزر باعث شده در فصول سرد سال بارش‌های سنگینی در منطقه به‌صورت برف و باران صورت گیرد.

^۱ Blagovechshenskiy et al

^۲ Devishri et al


^۳ Tyrrell



شکل ۱: موقعیت جغرافیایی منطقه مورد مطالعه


مواد و روش

یکی از اساسی‌ترین مراحل انجام هر پژوهش جمع‌آوری داده و اطلاعات است در این پژوهش نیز داده و اطلاعات مختلفی به کار گرفته شده است که شامل: نقشه زمین‌شناسی استان اردبیل با مقیاس ۱/۲۵۰۰۰۰ که اطلاعات مربوط به گسل‌ها از این نقشه استخراج شد، نقشه توپوگرافی خلخال با مقیاس ۱/۲۰۰۰۰ که نقشه جاده‌ها از این نقشه استخراج شده، داده‌های میدانی نقاط ریزش بهمن از طریق بازدید میدانی و دستگاه GPS برداشت شده است و داده و اطلاعات مهم سنجش از دوری شامل، پوشش گیاهی، کاربری اراضی، نقشه ارتفاعی، نقشه شیب، نقشه جهت شیب از تصاویر ماهواره‌های Sentinel 2 و ALOS – PALSAR محاسبه شده است. این پژوهش متکی بر کارهای میدانی، تحلیلی و آماری است. جهت تهیه و آماده‌سازی لایه‌ها و اجرای مدل تحقیق از نرم‌افزارهای Arc GIS، SPSS Modeler و ENVI استفاده شده است (شکل ۲).




شکل ۲: فلوچارت مراحل کار

با توجه به مطالعات میدانی و بررسی تصاویر ماهواره‌ای برای شناسایی عوامل مؤثر بر ریزش بهمن در جاده خلخال به شاهرود، ۸ لایه به ترتیب: ۱- ارتفاع ۲- پوشش گیاهی ۳- جهت شیب ۴- فاصله از گسل ۵- فاصله از جاده ۶- پهنه برقی ۷- کاربری اراضی ۸- شیب، با استاندارد فرمت رستری مورد استفاده قرار گرفت (شکل ۴ تا ۱۱) و در ادامه تمام لایه‌ها بعد از تولید به صورت مشترک باهم جمع شده و یک تصویر رستری واحد ایجاد شده است. تصویر رستری واحد شامل تمام مقادیر عددی ۸ لایه‌های بالا می‌باشد. سپس برای فهم مدل از ورودی داده‌ها، تمام مقادیر پیکسل‌ها که به صورت باینری تبدیل شده‌اند به صورت استاندارد طبقه‌بندی شدند. لذا مرحله اول آماده‌سازی لایه‌ها در محیط نرم‌افزار Arc GIS صورت گرفت است. این طبقه‌بندی کمک می‌کند تا مدل در پردازش دچار خطا نشود چراکه ورودی مدل دارای مقادیر زیاد عدد می‌باشد و این طبقه‌بندی باعث انسجام بین مقادیر می‌شود. بعد از اتمام فرایند طبقه‌بندی، مدل‌سازی در نرم‌افزار SPSS Modeler با ۸ نورون ورودی با ۸ نورون میانه و ۱ خروجی انجام شد و ۷۰ درصد داده‌ها برای آموزش مدل و ۳۰ درصد داده‌ها برای تست مدل اختصاص داده شدند. نوع الگوریتم مدل SVM و MLP از نوع پس از انتشار خطا می‌باشد. این الگوریتم در عین سادگی بسیار کارآمد بوده و باعث یادگیری هرچه بهتر مدل می‌شود و اتمام فرایند مدل زمانی است که به کم‌ترین میزان خطا رسیده باشد (شکل ۳).






شکل ۳: مدل طراحی شده برای پهنه‌بندی ریزش بهمن



شکل ۵: نقشه پوشش گیاهی

شکل ۴: نقشه ارتفاع





شکل ۱۱: نقشه شیب

شکل ۱۰: نقشه کاربری اراضی

ماشین بردار پشتیبان (SVM)^۱


یک مدل یادگیری ماشینی است که برای کارهای طبقه‌بندی و رگرسیون استفاده می‌شود (شکل ۱۲). اما به‌طور کلی در مسائل طبقه‌بندی، بهترین عملکرد را ارائه می‌دهند مدل SVM یک الگوریتم نظارت‌شده قدرتمند است که به‌خوبی برای مجموعه داده‌های کوچک‌تر، اما در مواجهه با مجموعه‌های پیچیده عملکرد بهتری دارد (یواکیمز^۲، ۱۹۹۸، ۴۳). این مدل با یافتن بهترین خط یا مرز تصمیم، نقاط داده و کلاس‌های مختلف را از هم جدا می‌کند و باهدف به حداکثر رساندن حاشیه که فاصله بین ابر صفحه و نزدیک‌ترین نقاط داده هر دسته است، عمل می‌کنند. همچنین این مدل برای مسائل طبقه‌بندی باینری بسیار مؤثر می‌باشد و می‌تواند داده‌های قابل جداسازی خطی و غیرخطی را مدیریت کند (پادلی^۳ و همکاران، ۲۰۲۳، ۱۰۵). مدل SVM نیازمند مرحله آموزش با استفاده از داده‌های آموزشی است. در این مرحله، پارامترهای مدل به‌گونه‌ای تنظیم می‌شوند که خطای پیش‌بینی بر روی داده‌های آموزش کمینه شده و همچنین مرز بین دسته‌ها بهینه شود، سپس در مرحله آزمون، مدل با استفاده از داده‌های تست ارزیابی می‌شود (یوم^۴، ۲۰۰۴، ۶۲).

^۱ Support vector machine

^۲ Joachims

^۳ Padeli et al

^۴ Yom



شکل ۱۲: نمایی از مدل ماشین بردار پشتیبان (SVM) (منبع: پادلی و همکاران، ۲۰۲۳)

پرسپترون چندلایه (MLP)^۱

پرسپترون چندلایه یک سازوکار محاسباتی است که قادر است با گرفتن اطلاعات و محاسبه کردن آن‌ها، یک سری اطلاعات جدید را ارائه دهد در پرسپترون چندلایه سعی بر آن است که ساختاری مشابه ساختار بیولوژیکی مغز انسان و شبکه اعصاب بدن ساخته شود تا همانند مغز قدرت یادگیری، تعمیم دهی و تصمیم‌گیری داشته باشد و یک پهنه‌بندی از یک فضای چند متغیره با اطلاعات دریافتی را به وجود آورد (لی^۲ و همکاران، ۲۰۰۶، ۲۱۵). مدل پرسپترون چندلایه شامل یک یا چندلایه میانی هستند که نورون‌های این لایه به‌عنوان نورون‌های مخفی شناخته می‌شوند همچنین افزودن چندین لایه میانی باعث افزایش توانایی شبکه در تحلیل‌های با پیچیدگی بالاتر می‌شود (هاگان^۳ و همکاران، ۲۰۱۴، ۱۰). مدل پرسپترون اطلاعات را از لایه‌های ورودی دریافت می‌کند و با وزن‌های مختلف به هم متصل می‌کند. اطلاعات وارد شده از لایه ورودی به لایه میانی منتقل می‌شوند، جایی که گره‌ها عملیات پردازش را انجام می‌دهند و لایه میانی عملیات پیچیده‌تری را انجام می‌دهد تا گره‌ها، اطلاعات را از لایه‌های ورودی دریافت کنند و با استفاده از وزن‌های خود، پردازش‌های مختلفی را اجرا کرده و نتیجه این پردازش به‌صورت لایه خروجی از شبکه خارج می‌شود (مائو^۴ و همکاران، ۲۰۲۳، ۴۵۵۴).

نتایج و یافته‌ها


در پهنه‌بندی مناطق مستعد ریزش بهمن مهم‌ترین بخش کار تهیه نقاط واقعی ریزش بهمن منطقه می‌باشد. میزان دقت و ارزیابی درست پهنه‌بندی تا حد زیادی مربوط به این بخش از کار می‌باشد. لذا جهت ارزیابی دقیق و صحت پهنه‌بندی و همچنین برای آموزش مدل، گردآوری نقاط واقعی امری ضروری است. بدین منظور، با استفاده دستگاه GPS به‌صورت میدانی، مناطق مستعد ریزش بهمن با توجه به پیشینه رخداد آن به تعداد ۱۷ پهنه به‌صورت پلیگون برداشت شد است. با توجه به گسترده بودن منطقه و پیچیدگی عوامل تأثیرگذار در رخداد ریزش بهمن، مطالعات میدانی یکی از اقدامات مهم در روند این پژوهش می‌باشد و همچنین بدون مطالعات میدانی نمی‌توان به داده‌های دقیق در رابطه با رخداد ریزش بهمن دست یافت (شکل ۱۳).

^۱ Multilayer perceptron

^۲ Lee et al

^۳ Hagan et al

^۴ Mao et al



جدول ۱: مقادیر خروجی مدل‌های SVM و MLP


ردیف	عوامل ورودی	وزن خروجی (SVM)	ردیف	عوامل ورودی	وزن خروجی (MLP)
۱	ارتفاع	۰/۱۰۸۱	۱	ارتفاع	۰/۱۰۳۱
۲	پوشش گیاهی	۰/۰۳۵۸	۲	پوشش گیاهی	۰/۰۲۶۲
۳	فاصله از گسل	۰/۰۵۵۸	۳	فاصله از گسل	۰/۰۹۴۴
۴	جهت شیب	۰/۱۳۳۸	۴	جهت شیب	۰/۰۸۱۸
۵	پهنه برفی	۰/۲۶۶۱	۵	پهنه برفی	۰/۲۰۹۱
۶	فاصله از جاده	۰/۱۵۵۹	۶	فاصله از جاده	۰/۱۷۶۲
۷	کاربری اراضی	۰/۰۵۲۱	۷	کاربری اراضی	۰/۱۲۸۵
۸	شیب	۰/۱۸۲۹	۸	شیب	۰/۱۳۷۷

وزن معیارهای مؤثر در خطر ریزش بهمن در نرم‌افزار Arc GIS بعد از نرمالیزه کردن تبدیل به نقشه شده و مساحت مناطق خطرناک در چهار رتبه به صورت: کم، متوسط، زیاد و خیلی زیاد به روش جنکس طبقه‌بندی شد. طبق (جدول ۲). مساحت مناطق خطرناک در چهار رتبه به صورت: کم، متوسط، زیاد و خیلی زیاد طبقه‌بندی شده است. الگوریتم جنکس به عنوان یک روش مؤثر برای ترتیب دهی مقادیر در کلاس‌های مختلف ارائه شده است. این الگوریتم از یک روند تکراری برای گروه‌بندی داده‌ها استفاده می‌کند تا میانگین انحراف هر طبقه از میانگین کل را به حداقل برساند و به همراه آن، واریانس بین طبقه‌ها را به حداکثر افزایش دهد (جهاندار و همکاران، ۱۳۹۸، ۳۷۴). طبق (جدول ۲) نیز مساحت طبقات خطرپذیری نشان‌دهنده این است که در مدل ماشین بردار پشتیبان بیشترین طبقه به لحاظ خطرپذیری دارای مقدار ۳۶/۳۴ کیلومترمربع و در مدل پرسپترون چندلایه ۴۵/۸۳ کیلومترمربع است که نشان‌دهنده این بوده که مدل پرسپترون چندلایه نسبت به مدل ماشین بردار حجم زیادی از منطقه را در طبقه خطرپذیری زیاد قرار داده است.

همچنین در مدل ماشین بردار پشتیبان برای طبقه خطرپذیری زیاد مقدار ۶۱/۵۷ کیلومترمربع و برای مدل پرسپترون چندلایه ۴۹/۳۲ کیلومترمربع طبقه‌بندی شده که در این بخش تفاوت زیادی بین مقادیر مساحت مدل‌ها وجود دارد که نشان می‌دهد مدل ماشین بردار پشتیبان عملکرد واقع‌بینانه‌ای داشته و توانسته مناطقی که در آن ریزش بهمن و خطرات ناشی از آن وجود داشته به درستی شناسایی کند. درحالی‌که مدل پرسپترون چندلایه در بخش خطرپذیری زیاد عملکرد خوبی نداشته است. در بخش خطرپذیری متوسط نیز نتایج مقادیر مساحت نشان‌دهنده این است که مدل ماشین بردار پشتیبان با مساحت ۲۳/۹۳ و مدل پرسپترون چندلایه با مقدار ۲۵/۸۳ کیلومترمربع طبقه‌بندی شده‌اند و تفاوت زیادی بین مقادیر مساحت‌ها وجود ندارد، اما در طبقه خطرپذیری کم، مدل پرسپترون چندلایه با مساحت ۱۵/۷۳ کیلومترمربع نسبت به مساحت مدل ماشین بردار پشتیبان با مساحت ۱۴/۸۷ دارای تفاوت کمی می‌باشد.

جدول ۲: طبقات ارزیابی شده به لحاظ مساحت


ردیف	طبقات ارزیابی شده (SVM)	مساحت (KM2)	ردیف	طبقات ارزیابی شده (MLP)	مساحت (KM2)
۱	خطرپذیری کم	۱۴/۷۸	۱	خطرپذیری کم	۱۵/۷۳
۲	خطرپذیری متوسط	۲۳/۹۳	۲	خطرپذیری متوسط	۲۵/۸۲
۳	خطرپذیری زیاد	۶۱/۵۷	۳	خطرپذیری زیاد	۴۹/۳۲
۴	خطرپذیری خیلی زیاد	۳۶/۳۴	۴	خطرپذیری خیلی زیاد	۴۵/۸۳




شکل ۱۴: نقشه پهنه‌بندی ریزش بهمن مدل ماشین بردار پشتیبان - شکل ۱۵: نقشه پهنه‌بندی ریزش بهمن مدل پرسپترون چندلایه



شکل ۱۶: تصویر سمت راست: ارتفاع برف دامنه جاده اسکستان، تصویر سمت چپ: پاک‌سازی بهمن توسط اداره راهداری در جاده کلور به شال



شکل ۱۷: تصویر سمت راست: ارتفاع برف دامنه جاده اسکستان، تصویر سمت چپ: بهمن اتفاق افتاده در جاده اسکستان



شکل ۱۸: تصویر سمت راست: جاده بهمن گیر کلور به شال، سمت چپ: جاده بهمن گیر اسکستان

اعتبار سنجی خروجی مدل‌ها

برای اعتبار سنجی داده‌ها و نقشه پهنه‌بندی خطر زمین‌لغزش از منحنی ROC در رابطه با خروجی داده‌ها استفاده شده است. منحنی یادشده هم برای داده‌های آموزشی و هم برای داده‌های تست شبکه اجرا شده است، برای اعتبار سنجی یک مدل در وهله اول باید مرحله آموزش اعتبار سنجی شود تا میزان ارزش بخش آموزشی معلوم گردد. مدلی که در بخش آموزش دارای اعتبار پایینی باشد عموماً در مرحله نهایی نیز داده‌هایش دارای دقت کم‌تری خواهد بود. همچنین اعتبار سنجی بخش تست شبکه نیز به‌عنوان بخش نهایی در اعتبار سنجی شناخته می‌شود. برحسب نوع و میزان آموزش کیفیت داده‌های خروجی نیز متغیر است. در بخش تست شبکه نمی‌توان از مقادیر سلولی مناطق خطر ریزش بهمن استفاده کرد بنابراین در بخش طراحی مدل، داده‌ها به ۷۰ درصد آموزش و ۳۰ درصد تست شبکه تقسیم شده‌اند. به بیانی ساده‌تر نرم‌افزار در مرحله مدل‌سازی ۳۰ درصد مقادیر سلولی مناطق ریزش بهمن را نگهداشت و آن را با داده‌های آموزشی ترکیب نمی‌کند و در آخر برای تست شبکه از همین داده‌ها (۳۰ درصد) استفاده می‌کند. نرم‌افزار به‌صورت خودکار با عمل مقایسه داده‌های خروجی و داده‌های ۳۰ درصد باقیمانده، از طریق نمودار اعتبار سنجی نتیجه خروجی را نمایش می‌دهد. با توجه به (جدول ۳) که میزان موفقیت مدل ماشین بردار پشتیبان در شناخت مناطق فعال به لحاظ خطر ریزش بهمن را نمایش می‌دهد، می‌توان دریافت که مدل طراحی شده با مقدار ۹۷/۲۲ درصد در بخش آموزش توانسته مناطق خطرناک را شناسایی کند و تنها ۲/۷۸ درصد دارای خطا بوده است و مناطق خطرناک به لحاظ خطر ریزش بهمن را نتوانسته مشخص کند. در بخش آموزش جمعاً ۷۰ درصد از داده‌های کل استفاده شده است که دارای مقدار ۵۳۶۳ عدد می‌باشد. که از این تعداد ۵۲۱۴ عدد در زون خطرناک شناسایی شده و ۱۴۹ عدد دارای خطا بوده است. همچنین در بخش مهم تست شبکه نیز خروجی مدل نمایان‌گر این است دقت مدل برای شناسایی مناطق خطرناک ۹۷/۱۲ درصد بوده و تنها مقدار ۲/۸۸ درصد در شناخت مناطق خطرناک دچار خطا بوده است. از داده‌های مورد استفاده در بخش تست شبکه جمعاً ۳۰ درصد به مقدار ۲۳۶۰ عدد استفاده شده که از این مقدار ۲۲۹۲ عدد در زون خطرناک و تنها ۶۸ عدد به اشتباه شناسایی شده است. به‌صورت کلی مدل طراحی شده دارای خطای کمی بوده و خروجی مدل دارای اعتبار لازم می‌باشد، اما جدول مربوط به مدل پرسپترون چندلایه (جدول ۴) نمایان‌گر این است که مدل طراحی شده با مقدار ۹۵/۷۳ درصد در بخش آموزش توانسته مناطق خطرناک را شناسایی کند و تنها ۴/۲۷ درصد دارای خطا بوده و مناطق خطرناک به لحاظ خطر ریزش بهمن را نتوانسته مشخص کند. در بخش آموزش جمعاً ۷۰ درصد داده‌های کل استفاده شده است که دارای مقدار ۵۳۶۳ عدد می‌باشد، که از این تعداد ۵۱۳۴ عدد در زون خطرناک شناسایی شده و ۲۲۹ عدد دارای خطا بوده است. همچنین در بخش مهم تست شبکه نیز خروجی مدل نمایان‌گر این است که دقت مدل برای شناسایی مناطق خطرناک ۹۵/۳ درصد بوده و تنها مقدار ۴/۷ درصد در شناخت مناطق خطرناک دچار خطا بوده است. از داده‌های مورد استفاده در بخش تست شبکه جمعاً ۳۰ درصد به مقدار ۲۳۶۰ عدد

استفاده شده که از این مقدار ۲۲۴۹ عدد در زون خطرناک و تنها ۱۱۱ عدد به‌اشتباه شناسایی شده است. کلاً مدل طراحی شده دارای خطای کمی بوده و نشان‌دهنده این است که مدل دارای دقت خوبی است اما نسبت به مدل ماشین بردار پشتیبان میزان دقت مدل پرسپترون چندلایه اندکی متفاوت بوده است و مدل ماشین بردار پشتیبان عملکردی خوبی در شناسایی مناطق مستعد ریزش بهمن داشته است.


جدول ۳: مقادیر عددی پیکسل‌ها در فرایند مدل‌سازی ماشین بردار پشتیبان

'Partition'	1_Training		2_Testing	
Correct	5,214	97.22%	2,292	97.12%
Wrong	149	2.78%	68	2.88%
Total	5,363		2,360	

جدول ۴: مقادیر عددی پیکسل‌ها در فرایند مدل‌سازی شبکه عصبی پرسپترون چندلایه

'Partition'	1_Training		2_Testing	
Correct	5,134	95.73%	2,249	95.3%
Wrong	229	4.27%	111	4.7%
Total	5,363		2,360	

با توجه به (شکل ۱۹) در بخش اول مربوط به قسمت آموزش مدل ماشین بردار پشتیبان، میزان اعتبار نشان‌دهنده این است که مدل به‌خوبی آموزش‌دیده و توانسته بخش زیادی از مناطق خطرناک به لحاظ ریزش بهمن شناسایی کند. معیار این منحنی به‌گونه‌ای است که خطوط رسم شده هرچه دارای فاصله بیشتری از منحنی قرمز اصلی باشد، دارای اعتبار بالایی است. همچنین در نمودار پایین (شکل ۱۹) منحنی آبی به سمت چپ مایل شده و به سمت بالا روانه شده که این حالت هم نمایان‌گر اعتبار بالای مدل در بخش آموزش را نشان می‌دهد. بنابراین آموزش صحیح مدل سبب شده که نتایج خروجی در بخش تست نیز روند اعتبار بالا را نشان دهند. در بخش تست شبکه در بخش ۸/۰ و ۱ نمودار یک خیز به سمت بالا داشته و سپس به سمت راست کشیده شده است که نشان می‌دهد مدل در بخش تست دارای اعتبار خوبی است و نسبت به بخش آموزش دارای تفاوت اندکی است. مقدار AUC عدد ۰/۹۲۶ در بخش آموزش و ۰/۹۳۶ در بخش تست شبکه را نمایش می‌دهد که گویای این است که مدل هم در بخش آموزش و هم در بخش تست، دارای اعتبار خوبی بوده و در رتبه عالی قرار گرفته و نتایج خروجی آن قابل‌اعتماد است. خطوط منحنی نسبت به منحنی مدل پرسپترون چندلایه تفاوت زیادی دارد. این تفاوت ابتدا در فاصله خط آبی از حجم زیرخط قرمز است که این عامل بیانگر این است که مدل شعاعی در بخش آموزش دارای نقص کوچکی بوده و نسبت به مدل ماشین بردار پشتیبان آموزش بهتری نداشته است. همچنین در بخش آموزش و تست شبکه نیز خط آبی منحنی به سمت چپ تمایل کمی داشته و در خط قرمز روند صعودی بوده که نشان می‌دهد عملکرد بهتری نسبت به مدل ماشین بردار پشتیبان نداشته است. اما در بازه ۸/۰ و ۱ روند صعودی سبب شده که نتایج اعتبار سنجی به سمت عدد ۱ تمایل داشته باشد و کیفیت اعتبار سنجی افزایش بیابد. بنابراین مقدار AUC عدد ۰/۷۹۵ در بخش آموزش و ۰/۸۴۶ در بخش تست شبکه را نمایش می‌دهد که گویای این است که مدل هم در بخش آموزش و هم در بخش تست اعتبار لازم را دارد و در رتبه خوب قرار گرفته و نتایج خروجی آن قابل‌اعتماد است. همچنین هم‌پوشانی مناطق شناسایی شده در هر دو مدل با نقاط واقعی ریزش بهمن بالا بوده که نشان از دقت هر دو مدل دارد، اما با توجه به میزان دقت و هم‌پوشانی با نقاط واقعی، مدل ماشین بردار پشتیبان عملکردی بهتری نسبت به مدل پرسپترون چندلایه دارد و توانسته مناطق را به‌صورت واقع‌بینانه شناسایی کند.



شکل ۱۸: منحنی اعتبار سنجی ROC

جدول ۵: عملکرد AUC

SVM. Partition	training	testing
model	aus	aus
avalanch	0.926	0.936
MLP. Partition	training	testing
model	aus	aus
avalanch	0.795	0.846

نتیجه‌گیری

توزیع مکانی ریزش بهمن در جاده خلخال به شاهرود و نتایج مدل ماشین بردار پشتیبان نشان می‌دهد که بیشترین ارزش وزنی به ترتیب برای لایه پهنه برفی، لایه شیب، فاصله از جاده و برای مدل شبکه عصبی پرسپترون چندلایه نیز بیشترین ارزش وزنی به ترتیب برای عامل پهنه برفی، فاصله از جاده و شیب تعلق گرفته است. هر دو مدل در شناخت عوامل مؤثر بر ریزش بهمن در منطقه به صورت یکسان عمل کردند اما میزان تخصیص وزنی برای معیارها باهم متفاوت بوده است. با توجه به نتایج دو مدل در خصوص پهنه‌بندی خطر ریزش بهمن در محور خلخال به شاهرود هم‌چنین با توجه به مکانیسم ریزش بهمن و خطرات ناشی از آن که توسط مطالعات میدانی معلوم شده که مورفولوژی دامنه‌های مشرف به جاده، دامنه‌های بخش مرکزی در محدوده روستای اسکستان به خاطر زاویه شیب ۲۰ تا ۳۵ درصدی و نزدیکی پیش از حد به حریم جاده‌ای با بارش برف و انباشت آن در طول فصول زمستان با کوچک‌ترین تحرک، سبب وقوع بهمن در این منطقه می‌شود. وقوع ریزش بهمن در منطقه به صورت اسلایدی و انبوه است و حالت پودری ندارد چرا که طول دامنه و هم‌چنین عامل جاده در رخداد این مدل بهمن تأثیر زیادی گذاشته است. وقوع بهمن عاملی است که یک بخش آن به ویژگی‌های هندسی دامنه و

یک بخش آن مربوط به ویژگی‌های اقلیمی و طبیعی است. منطقه موردنظر به خاطر نزدیکی به دریای خزر و همچنین شرایط کوهستانی بودن دارای بارش‌های سنگین برف در فصل زمستان است. فرسایش بر روی دامنه سبب شده که در برخی از دامنه‌های منطقه مورد مطالعه حالت چاله مانند به وجود آید که با بارش برف، این بخش از برف پر شده و در فصول سه‌ماهه زمستان تا فصل اول بهار باقی‌مانده و تداوم ذوب و یخ بستن توده‌های برفی سبب شده که لایه برف جدید به آن نچسبد و در اثر زاویه شیب و نیروی ثقل با کم‌ترین تحریک که در منطقه موردنظر نزدیکی به حریم جاده مهم‌ترین عامل برای این تحریک شناخته می‌شود، ریزش بهمن به وقوع بپیوندد. نتایج مدل ماشین بردار پشتیبان با اخلاف نسبتاً کم از مدل پرسپترون چندلایه دارای اعتبار بالایی است و توانسته مناطق خطرناک را به‌خوبی شناسایی کند هر دو مدل در بخش تخصیص وزن دارای شباهت‌های زیادی به هم بوده و در بخش آموزش شبکه ماشین بردار پشتیبان عملکرد خوبی داشته است. همچنین هم‌پوشانی مناطق شناسایی‌شده با نقاط واقعی نیز در هر دو مدل بالا است اما نتایج مربوط به شناسایی مناطق مستعد ریزش بهمن در مدل ماشین بردار پشتیبان نسبت به پرسپترون چندلایه دارای عملکرد بهتری بوده و توانسته مناطق را به‌صورت واقع‌بینانه و جزنگر شناسایی کند. بنابراین می‌توان هر دو این مدل‌ها را در شناسایی مناطق مستعد ریزش بهمن مورد استفاده قرار داد. در نهایت پیشنهاد می‌گردد در مطالعات آتی برای بررسی و ارزیابی ریزش بهمن و حرکات دامنه‌ای از سایر مدل‌های یادگیری ماشینی و هوش مصنوعی استفاده شود. همچنین با توجه به خصوصیات ژئومورفولوژیکی و زمین‌شناسی و سایر عوامل، راهکارهای مدیریتی را می‌توان اتخاذ کرد که از رخداد مخاطرات دامنه‌ای در این محور جلوگیری کرده و درصد خسارات را کاهش داد. از جمله این راهکارها می‌توان به موارد زیر اشاره کرد:

- ۱_ اصلاح زاویه و شیب دامنه‌های حساس به رخداد ریزش بهمن.
- ۲_ تقویت و کشت پوشش گیاهی در سطح دامنه‌های مستعد.
- ۳_ نصب تابلو و علائم هشداردهنده در مناطق حساس و مستعد.

منابع

- احمدی، و.، مرادی، م.، ۱۳۹۸. پهنه‌بندی وقوع بهمن با استفاده از مدل شبکه عصبی مصنوعی (MLP) (مطالعه موردی: کوهستان‌های شمالی استان البرز)، نشریه علمی مهندسی نقشه‌برداری و اطلاعات مکانی، دوره ۱۰، شماره ۳، صص ۱-۱۴.
- سلیمانی مطلق، م.، طالبی، ع.، اکرامی، م.، ۱۳۹۹. امکان پیش‌بینی احتمال وقوع بهمن با استفاده از روش نزدیک‌ترین همسایه در محیط نرم‌افزار GIS (مطالعه موردی: محورهای بهمن خیز استان تهران)، مجله علوم و مهندسی آب‌خیزداری ایران، دوره ۵، شماره ۱۶، صص ۳۳-۳۸.
- اسدمرجی، م.، نهایندی، ن.، ۱۳۹۵. الگوی اولویت‌بندی قطعات جاده‌های کوهستانی از لحاظ ریسک ریزش بهمن با به‌کارگیری احتمال برخورد وسیله نقلیه. پژوهشنامه حمل‌ونقل، دوره ۱۳، شماره ۴، صص ۱۸۰-۱۹۲.
- اسدمرجی، م.، صفارزاده، م.، حسن‌پور، ش.، رسولی، ن.، ۱۳۹۲. ارائه‌ی مدل ارزیابی خطر ریزش بهمن در محورهای کوهستانی (مطالعه موردی: محور کرج-چالوس)، مهندسی عمران مدرس، دوره ۱۳، شماره ۵، صص ۱۵-۲۸.
- تاج بخش، س.، نیکفال، ا.، ۱۳۹۷. پیش‌بینی پتانسیل سقوط بهمن با استفاده از یک مدل پیش‌بینی عددی (مطالعه موردی: منطقه شهرستانک، ۲۶-۲۸ دسامبر ۲۰۱۶)، مجله فیزیک زمین و فضا، دوره ۴۴، شماره ۳، صص ۶۴۱-۶۵۸.
- جهاندار، ش.، آقاگل زاده، ع.، کاظمی تبار، ج.، ۱۳۹۸. بازشناسی کور کدهای بلوکی در حضور نویز بالا با استفاده از روش‌های آماری. علوم و فناوری پدافند نوین (علوم و فناوری‌های پدافند غیر عامل، دوره ۱۰، شماره ۴، صص ۳۷۳-۳۸۱).

- نصرتی، ک.، کیشمشکی، س.، حسین زاده، م. م.، ۱۳۹۸. ارزیابی و مدل سازی پارامتر های محیطی مؤثر بر وقوع بهمن در محور میگون-شمشک با استفاده از تکنیک های آماری چندمتغیره، اکوهیدرولوژی، دوره ۶، شماره ۱، صص ۸۹-۹۸.
- نیری، ه.، کرمی، م. ر.، چاره خواه، ب.، ۱۳۹۷. پهنه بندی گذرگاه های بهمن خیز حوضه سیروان با تلفیق مدل تحلیل سلسله مراتبی و شبکه های عصبی مصنوعی، فضای جغرافیایی، دوره ۱۸، شماره ۶۱، صص، ۲۰۳-۲۱۹.
- Bartelt, P., Bühler, Y., Christen, M., & Schweizer, J. (2012). Snow avalanche.
- Beato Bergua, S., Poblete Piedrabuena, M. Á., & Marino Alfonso, J. L. (2018). Snow avalanche susceptibility in the eastern hillside of the aramo range (Asturian central massif, cantabrian mountains, nw spain). *Journal of Maps*, 14(2), 373-381.
- Bian, Rui, et al. "Snow avalanche susceptibility assessment based on ensemble machine learning model in the central Shaluli Mountain." *Frontiers in Earth Science* 10 (2022): 880711.
- Blagovechshenskiy, V., Medeu, A., Gulyayeva, T., Zhdanov, V., Ranova, S., Kamalbekova, A., & Aldabergen, U. (2023). Application of Artificial Intelligence in the Assessment and Forecast.
- Caldera, H. J., & Wirasinghe, S. C. (2022). A universal severity classification for natural disasters. *Natural hazards*, 111(2), 1533-1573.
- Chiroiu, P., Onaca, A. L., Favillier, A., Voiculescu, M., Corona, C., Urdea, P., & Stoffel, M. (2024). Snow avalanche synchronicity derived from a multi-path tree-ring reconstruction in the Făgăraș Mountains (Southern Carpathians, Romania). *Quaternary Geochronology*, 79, 101474.
- Chiroiu, P., Onaca, A. L., Favillier, A., Voiculescu, M., Corona, C., Urdea, P., & Stoffel, M. (2024). Snow avalanche synchronicity derived from a multi-path tree-ring reconstruction in the Făgăraș Mountains (Southern Carpathians, Romania). *Quaternary Geochronology*, 79, 101474.
- Choubin, B., Borji, M., Mosavi, A., Sajedi-Hosseini, F., Singh, V. P., & Shamshirband, S. (2019). Snow avalanche hazard prediction using machine learning methods. *Journal of Hydrology*, 577, 123929.
- Choubin, B.; Borji, M.; Hosseini, F.S.; Mosavi, A.; Dineva, A.A. Mass wasting susceptibility assessment of snow avalanches using machine learning models. *Sci. Rep.* 2020, 10, 18363.
- Christen, M., Bühler, Y., Bartelt, P., Leine, R., Glover, J., Schweizer, A., ... & Volkwein, A. (2012, April). Integral hazard management using a unified software environment. In 12th Congress Interpraevent (pp. 77-86).
- Devishri, K., Thombson, C., Rajkumar, K. S., Maisnam, M., & Pallipad, J. (2024). Investigating snow avalanche in the Sikkim Himalaya through coherence and displacement mapping of Sentinel-1A SAR data.
- Föhn, P. M. B. (1988, October). Snow cover stability tests and the areal variability of snow strength. In *Proceedings International Snow Science Workshop, Whistler, British Columbia, Canada* pp. 12-15.
- Haegeli, P., McClung, D. M., & Schaerer, P. (2020). The avalanche handbook. The Mountaineers Books.
- Hagan, M. T., Demuth, H. B., Beale, M. H., and Jesús, O. D., 2014- Neural Network Design, Martin Hagan (2 edition), 1012 pp. ISBN-13:A, Volume 113, Number 6.
- Joachims, T. (1998). Making large scale SVM learning practical. Technical reports.
- Kumar, S., Srivastava, P. K., & Bhatiya, S. (2019). Geospatial probabilistic modelling for release area mapping of snow avalanches. *Cold Regions Science and Technology*, 165, 102813.

- Lee S, Ryu J-H, Lee M-J, Won J-S. 2006. *The application of artificial neural networks to landslide susceptibility mapping at Janghung, Korea. Mathematical Geology*, 38(2): 199,220.
- Mao, K., Zhu, J., Su, L., Cai, G., Li, Y., & Dong, Z. (2023, June). *FinalMLP: an enhanced two-stream MLP model for CTR prediction. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 37, No. 4, pp. 4552-4560).*
- McClung, D. M., & Schaerer, P. (2006). *The avalanche handbook. The Mountaineers Books.*
- Padeli, P., Martono, A., & Sudaryono, S. (2023). *Application of Naive Bayes Model, SVM and Deep Learning Predicting. CICES.*
- Phoon, K.K.; Zhang, W. (2023). *Future of machine learning in geotechnics. Georisk-Assess. Manag. Risk Eng. Syst. Geohazards* 2023, 17, 7–22.
- Tyrrell, E. (2024). *Avalanche Forecasting with Geospatial Analysis in Southwestern Colorado.*
- Varol, N. (2022). *Avalanche susceptibility mapping with the use of frequency ratio, fuzzy and classical analytical hierarchy process for Uzungol area, Turkey. Cold Regions Science and Technology*, 194, 103439.
- Yom, E. (2004). *DR AF T A parallel training algorithm for large scale support vector machines.*

