



دوره ۳۵، شماره ۲، شماره‌ی پیاپی ۱۳۵، تابستان ۱۴۰۱، صفحه‌های ۱۰۱-۱۱۸
شناسه‌ی دیجیتال: 10.22092/WMRJ.2021.356462.1439

مقاله‌ی پژوهشی



پژوهش‌های آبخیزداری

شبیه‌سازی حساسیت زمین‌لغزش با مدل‌های داده‌کاوی در منطقه‌ی رأبر، استان کرمان

الهام رفیعی ساردویی

(نویسنده‌ی مسئول)* دانشیار گروه مهندسی طبیعت، دانشکده‌ی منابع طبیعی، دانشگاه جیرفت، کرمان، ایران

*رایانامه‌ی نویسنده‌ی مسئول: ellrafeei@ujiroft.ac.ir

تاریخ دریافت: ۳ آبان ۱۴۰۰ تاریخ پذیرش: ۱۱ آذر ۱۴۰۰

چکیده

زمین‌لغزش یکی از روی‌داده‌های طبیعی مهم است که هر ساله موجب زیان‌های مالی و تخریب اندوخته‌های طبیعی می‌شود. منطقه‌ی رأبر در سرآب آبخیز هلیل‌رود به‌دلیل بودن سازندهای با خاک رُس در آن آمادگی زمین‌لغزش است، و این موجب وارد شدن اندازه‌های زیادی از مواد معلق به سد صفا در منطقه‌ی رأبر شده است. هدف از این پژوهش پهنه‌بندی این روی‌داد زیست‌محیطی با مدل‌های شبکه‌ی عصبی پیچشی، تابع شاهد قطعی، و ماشین بردار پشتیبان در رأبر است. عامل‌های ارتفاع، شیب، فاصله از گسل، زمین‌شناسی، کاربری زمین، نوع خاک، پوشش گیاهی، فاصله از رود، و بارندگی به‌کار برده شد. نقشه‌ی پراکنش زمین‌لغزش‌ها در جایگاه متغیر وابسته با داده‌های سازمان زمین‌شناسی و بازدیدهای میدانی با بهره‌گیری از جی‌پی‌اس تهیه شد. از ۷۰ زمین‌لغزش، ۴۹ زمین‌لغزش (۷۰٪) برای شبیه‌سازی و ۲۱ زمین‌لغزش (۳۰٪) برای اعتبارسنجی مدل به‌کار برده شد. نتیجه‌ی اعتبارسنجی مدل‌ها با منحنی ROC نشان داد که اندازه‌های سطح زیر منحنی برای مدل‌های شبکه‌ی عصبی پیچشی، ماشین بردار پشتیبان، و تابع شاهد قطعی به‌ترتیب ۰/۹۸۷، ۰/۹۵۸ و ۰/۸۹۹ است. به‌طور کلی، نتیجه‌ها هم‌خوانی رضایت‌بخشی میان داده‌های زمین‌لغزش در منطقه و نقشه‌های حساسیت زمین‌لغزش نشان داد، و کارکرد مدل یادگیری عمیق شبکه‌ی عصبی پیچشی بیش‌تر از دو مدل دیگر بود. نقشه‌ی حساسیت زمین‌لغزش در چهار رده با حساسیت کم، متوسط، زیاد و خیلی زیاد رده‌بندی شد. بر پایه‌ی نتیجه‌ی خروجی هر سه مدل بخش‌های مرکزی، جنوب شرقی و جنوب غربی منطقه در خطر زیاد و خیلی زیاد زمین‌لغزش است. انجام طرح‌های مناسب مانند دیوارهای حائل، جلوگیری از نفوذ آب، زه‌کشی مناسب، و کاشت پوشش گیاهی متناسب با محیط در دامنه‌های آمادگی لغزش ممکن است برای جلوگیری از این روی‌داد و مهار آن مناسب باشد.

واژگان کلیدی: تابع شاهد قطعی، سامانه‌ی اطلاعات جغرافیایی، شبکه‌ی عصبی پیچشی، شبیه‌سازی، ماشین بردار پشتیبان

مقدمه

زمین‌لغزش مانند زمین‌لرزه، سیل، و آتشفشان از روی داده‌های طبیعی مهم است که هر ساله در منطقه‌هایی که برای آن آمادگی دارند زیان‌های فراوانی به بار می‌آورد. با افزایش یافتن جمعیت و ساکن شدن در این منطقه‌ها آمارهای جهانی آسیب‌های این پدیده روند افزایشی دارد. از این دیدگاه ایران به دلیل شرایط جغرافیایی، نبود مدیریت جامع محیطی، و رعایت نشدن آستانه‌های محیطی کشوری پرخطر است، به طوری که در میان ۱۰ کشور بلاخیز جهان است، و زمین‌لغزش هر ساله در منطقه‌های کوهستانی و مرتفع کشور زیان‌ها و آسیب‌های فراوانی به بار می‌آورد (سلیمانی و همکاران ۲۰۱۷). از آنجا که تهیه کردن نقشه‌ی حساسیت زمین‌لغزش به طور چشم‌گیری برنامه‌ریزی کاربری را بهبود می‌بخشد، می‌توان از آن همچون روشی کارآمد برای کاهش دادن زیان‌های جانی و مالی زمین‌لغزش‌ها بهره‌گرفت. بنابراین تهیه‌ی نقشه‌ی زمین‌لغزش گامی مهم برای مدیریت کردن خطر آن برای امنیت زندگی انسان‌ها، توسعه‌ی زیرساخت‌ها، و حفاظت از محیط زیست است (تروهورست و نوهاوزر ۲۰۰۷). زمین‌لغزش از خطرناک‌ترین فرآیندهای طبیعی است و آسیب‌های زیادی به بار می‌آورد (روکاتی و همکاران ۲۰۲۱). در کشورهای توسعه‌یافته بیش‌تر از ۰/۵٪ از تولید ناخالص ملی در هر سال به‌علت رانش زمین از دست می‌رود، و ۹۵٪ از زمین‌لغزش در این کشورها ثبت شده‌است (چن و همکاران ۲۰۱۵). یکی از اولین مرحله‌ها برای مدیریت کردن زمین‌لغزش، تهیه‌ی نقشه‌ی حساسیت به زمین‌لغزش است که بر پایه‌ی آن می‌توان روی داد آن را در آینده پیش‌بینی کرد، و منطقه‌های پرخطر را شناخت (تیری و همکاران ۲۰۲۰). به طور کلی نقشه‌ی حساسیت به زمین‌لغزش مرجعی برای مدیریت کردن زمین‌لغزش است (خان و همکاران ۲۰۲۰).

برای تهیه‌ی نقشه‌ی حساسیت به زمین‌لغزش از روش‌های گوناگونی بهره‌گرفته شده‌است، مانند نسبت فراوانی (عرب عامری و همکاران ۲۰۱۷، شهبابی و همکاران ۲۰۱۴)، تابع شاهد قطعی^۱ (هانگ و همکاران ۲۰۱۶، اوه و همکاران ۲۰۱۸، ساردویی و همکاران ۲۰۲۱)، وزن شاهد (یو و همکاران ۲۰۱۶، و خشوری و زراع ۲۰۱۶، لی و وانگ ۲۰۱۹)، تحلیل سلسله‌مراتبی (عمادالدین و باباجانی ۲۰۱۷، رهامانا و همکاران ۲۰۱۴)، جنگل تصادفی (یوسف و همکاران ۲۰۱۶، تالای و همکاران ۲۰۱۸) و ماشین بردار پشتیبان (چن و همکاران ۲۰۱۷، کلاتر و همکاران ۲۰۱۸). پهنه‌بندی خطر زمین‌لغزش در جاده‌ی کوهستانی کامیاران-سنندج در می‌زانیا و شهبابی (۲۰۲۰) با مدل‌های داده‌کاوی تابع شاهد قطعی و وزن شاهد

نشان داد که سطح زیر منحنی در مدل وزن شاهد بیش‌تر از تابع شاهد قطعی است و بهترین مدل برای پیش‌بینی مکانی خطر زمین‌لغزش در این منطقه است. نتیجه‌ی ارزیابی کارایی مدل ماشین بردار پشتیبان در پهنه‌بندی حساسیت زمین‌لغزش در آبخیز اهرچای، شمال غرب ایران، نشان داد که کارایی ماشین بردار پشتیبان در پهنه‌بندی حساسیت زمین‌لغزش خوب است، و ۲۶/۶۱٪ از زمین‌های منطقه، که بیش‌تر در غرب و سرآب حوزه و بخش‌های جنوبی آن است، در رده‌ی با حساسیت زیاد و بسیار زیاد بود (کرمی و همکاران ۲۰۲۰). نتیجه‌ی پهنه‌بندی حساسیت زمین‌لغزش در هیمالیا در پاندی و همکاران (۲۰۲۰) با دو روش پیشینه‌ی آنتروپی و ماشین بردار پشتیبان نشان داد که کارایی هر دو مدل خوب است اما دقت مدل ماشین بردار پشتیبان بیش‌تر است.

نتیجه‌ی ارزیابی کارایی مدل‌های ماشین بردار پشتیبان، وایازی پشتیبان بیزین، و درخت تصمیم تناوبی برای پهنه‌بندی حساسیت زمین‌لغزش در غرب ایران (نهو و همکاران ۲۰۲۰) نشان داد که کارکرد مدل ماشین بردار پشتیبان بهتر بود. نتیجه‌ی محمدی و همکاران (۲۰۱۲) برای تهیه‌ی نقشه‌ی حساسیت زمین‌لغزش در استان گلستان نشان داد که کارایی مدل نسبت فراوانی بهتر از دمپستر شیفر و وزن شاهد است. پهنه‌بندی حساسیت زمین‌لغزش (اوه و همکاران ۲۰۱۸) با مدل‌های تابع شاهد قطعی، ماشین بردار پشتیبان، و وایازی پشتیبان در کره‌ی جنوبی نشان داد که کارکرد مدل وایازی پشتیبان بهتر بود. پهنه‌بندی حساسیت زمین‌لغزش در آبخیز چهل‌چای در استان گلستان (کردی نژاد و پورقاسمی ۲۰۱۹) با دو مدل داده‌کاوی ماشین بردار پشتیبان و درخت وایازی تقویت‌شده نشان داد که کارایی مدل ماشین بردار پشتیبان (مساحت زیر منحنی ۸۲٪) بهتر بود، و درخت وایازی تقویت‌شده (سطح زیر منحنی ۷۷٪) در رتبه‌ی بعدی اهمیت بود. نتیجه‌ی بهشتی و همکاران (۲۰۲۱) در بررسی حساسیت روی داد زمین‌لغزش در بخشی از استان تبریز با مدل‌های تابع شاهد قطعی و شاخص آنتروپی نشان داد که حساسیت به زمین‌لغزش در ۸۹/۸۱٪ از منطقه زیاد است.

در سال‌های گذشته روش‌های جدیدی مانند روش‌های یادگیری عمیق برای پهنه‌بندی حساسیت روی داده‌های محیطی به‌کار برده شده‌است (وانگ و همکاران ۲۰۲۰، مندال و همکاران ۲۰۲۱، انگو و همکاران ۲۰۲۱). نتیجه‌ی ارزیابی دقت مدل یادگیری عمیق (شبکه‌ی عصبی پیچشی) و مدل‌های یادگیری ماشین (جنگل تصادفی و مدل شبکه‌ی عصبی) برای شبیه‌سازی حساسیت زمین‌لغزش در حوزه‌ی رود روراچو در هند نشان داد که کارکرد مدل شبکه‌ی عصبی پیچشی بهتر است (مندال و

روی داده‌های محیطی در ایران دارد. در این پژوهش کارایی مدل یادگیری عمیق شبکه‌ی عصبی پیچشی در شبیه‌سازی حساسیت زمین‌لغزش بررسی، و کارکرد آن با دو مدل تابع شاهد قطعی و ماشین بردار پشتیبان مقایسه شد. منطقه‌ی رابر در سرآب آبخیز هلیل‌رود، به دلیل بودن سازندهای خاک رُس‌دار در آن، آماده‌ی زمین‌لغزش است، و این مسئله موجب واردشدن اندازه‌های زیادی از مواد معلق به سد صفارود شده است. تا کنون پژوهشی بر پهنه‌بندی زمین‌لغزش با روش‌های داده‌کاوی در این منطقه انجام نشده‌است تا بتوان بر پایه‌ی آن راه‌کارهایی برای کاستن از زیان‌های زمین‌لغزش یافت. از این‌رو، هدف از این پژوهش ارزیابی کردن حساسیت به زمین‌لغزش با مدل‌های شبکه‌ی عصبی پیچشی، تابع شاهد قطعی، و ماشین بردار پشتیبان، و تعیین روش داده‌کاوی مناسب برای پهنه‌بندی حساسیت زمین‌لغزش در این منطقه است.

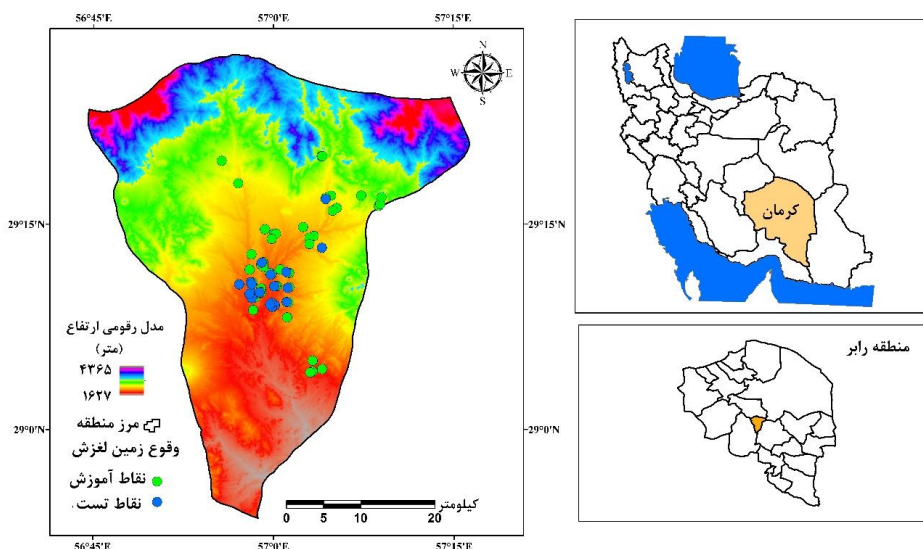
مواد و روش‌ها

منطقه‌ی رابر ($1636/69 \text{ km}^2$) در سرآب آبخیز هلیل‌رود یکی از منطقه‌های کوهستانی استان کرمان در جنوب شرق ایران ($28^{\circ}54'$ تا $29^{\circ}27'$ طول شرقی و $56^{\circ}45'$ عرض شمالی) است (شکل ۱). بارش و دمای سالانه‌ی منطقه $266/7 \text{ mm}$ و 20°C است. بخش‌های مرکزی منطقه به دلیل داشتن سازندهای زمین‌شناسی خاک رُس‌دار آماده‌ی زمین‌لغزش است، و یکی از منطقه‌های بحرانی استان کرمان از دیدگاه زمین‌لغزش است. سازندهای خاک رُس‌دار به دلیل نفوذناپذیری از عامل‌های اصلی حرکت‌های توده‌ی خاک است (صالحی و همکاران ۲۰۱۷، تین بوی و همکاران ۲۰۱۹، مجرد تیتکانلو و همکاران ۲۰۲۰).

همکاران (۲۰۲۱). نتیجه‌ی تین بوی و همکاران (۲۰۲۰) برای پیش‌بینی حساسیت به سیل در ویتنام، با مدل شبکه‌ی عصبی یادگیری عمیق، ماشین بردار پشتیبان، و شبکه‌ی عصبی پرسپترون چندلایه نشان‌دهنده‌ی عمل‌کرد بهتر مدل یادگیری عمیق است.

مدل‌های یادگیری عمیق کم‌تر برای پهنه‌بندی حساسیت زمین‌لغزش به کار برده شده‌است. روش‌های یادگیری عمیق برتری‌های بسیاری بر روش‌های یادگیری ماشین و دیگر مدل‌های داده‌کاوی دارد. یادگیری عمیق به نوبه‌ی خود زیرمجموعه‌ی دیگری از یادگیری ماشین است، اما شیوه‌ی کارکرد آن در تراز بالاتر و پیچیده‌تری است. یادگیری عمیق مجموعه‌ی از شبکه‌های عصبی است که بر پایه‌ی داده‌هایی که به ماشین داده می‌شود فرآیند یادگیری خودکار را انجام می‌دهد. نورون‌های تشکیل‌دهنده‌ی شبکه یاد می‌گیرند که تصمیم بگیرند کدام ویژگی‌ها برای انجام یک کار مشخص، بهتر کار می‌کند، یا داده‌ها را رده‌بندی می‌کنند (انگو و همکاران ۲۰۲۱). با گذشت زمان، یادگیری عمیق احتمال رده‌بندی یا پیش‌بینی دقیق را بعد از تکرارهای فرآیند یادگیری بهبود می‌بخشد. مانند مغز انسان، شبکه‌های عمیق نیز می‌تواند از اشتباه‌های خود درس بگیرد. با یادگیری عمیق بیش از یک لایه در شبکه‌ی عصبی هست. یادگیری عمیق زیرمجموعه‌ی از یادگیری ماشین با پیچیدگی و توانایی بیشتر است (قربان زاده و همکاران ۲۰۱۹).

به طور کلی پژوهش‌های اندکی در کشورهای دیگر کارکرد روش یادگیری عمیق را در شبیه‌سازی حساسیت روی داده‌های محیطی بررسی کرده‌اند، و هیچ یک از پژوهش‌های داخلی به این روش نپرداخته‌اند. از این‌رو، کارایی مدل‌های یادگیری عمیق نیاز به بررسی بیشتر و دقیق‌تری به‌ویژه در پهنه‌بندی



شکل ۱- موقعیت جغرافیایی منطقه‌ی رابر.

درجه‌ی شیب با مدل رقومی ارتفاع استخراج شد (شکل ۲). نقشه‌ی گسل‌های منطقه با مقیاس ۱:۱۰۰۰۰۰ (سازمان زمین‌شناسی کشور، دریافت شخصی) به کار برده شد. نقشه‌ی فاصله از گسل با دستور فاصله‌ی اقلیدسی در آرک جی‌آی‌اس ۱۰٫۷ تهیه، و بر پایه‌ی روش شکست طبیعی به پنج رده رده‌بندی شد (شکل ۳). این روش برای تعیین بهترین آرایش ارزش‌ها به رده‌های گوناگون طراحی شده است، و پس از به‌کمینه رساندن انحراف هر رده از میانگین، و به‌بیشینه رساندن انحراف هر رده از میانگین گروه‌های دیگر انجام می‌شود. این روش رده‌بندی برای کاستن از پراکنش‌ها درون رده‌ها، و بیشینه‌کردن پراکنش میان رده‌ها است (رحیمی و سلیمانی ۲۰۱۷). نقشه‌ی سنگ‌شناسی منطقه با مقیاس ۱:۱۰۰۰۰۰ (سازمان زمین‌شناسی کشور، دریافت شخصی) به کار برده شد (شکل ۴، جدول ۱).

داده‌های زمین‌لغزش (۷۰ زمین‌لغزش در منطقه‌ی رابر) تهیه شد (سازمان زمین‌شناسی و اکتشافات معدنی ایران، مراجعه‌ی شخصی). دقت این داده‌ها با تصویرهای گوگل‌ارت (۲۰۱۹) و بررسی‌های میدانی بررسی شد. پراکنش مکانی زمین‌لغزش‌ها و موقعیت آن‌ها نسبت به آب‌راه‌ها در شکل ۱ نشان داده شده است.

بر پایه‌ی اطلاعات پیشین و داده‌های دسترس منطقه، برای پهنه‌بندی خطر زمین‌لغزش ۹ لایه‌ی ارتفاع، شیب، فاصله از گسل، زمین‌شناسی، کاربری زمین، نوع خاک، شاخص بهنجار شده‌ی تفاوت پوشش، فاصله از رود، و بارندگی به کار برده شد (رها مانا و همکاران ۲۰۱۴، لی و وانگ ۲۰۱۹، سیلاخوری و همکاران ۲۰۲۱). نقشه‌ی مدل رقومی ارتفاع با توان تفکیک ۳۰ m از روی نقشه‌ی پستی‌بلندی ۱:۵۰۰۰۰ (سازمان نقشه‌برداری کشور) تهیه شد (شکل ۲ الف). نقشه‌ی

جدول ۱- سازندهای زمین‌شناسی منطقه‌ی رابر.

واحد زمین‌شناسی	توصیف	سن زمین‌شناسی
Ea.bvt	خاکستر آتشفشانی سنگ‌شده‌ی آندزیتی تا بازالتی	ائوسن
Mv	سنگ‌های آتشفشانی	میوسن
Murc	جوش سنگ قرمز و ماسه‌سنگ	میوسن
Mur	خاک رُس قرمز، خاک رُس گچی، ماسه‌سنگ و جوش سنگ (سازند قرمز بالایی)	میوسن
Eat	خاکستر آتشفشانی سنگ‌شده‌ی آندزیتی	ائوسن
E2m	خاک رُس قرمز کم‌رنگ، خاک رُس گچی، و سنگ آهک	ائوسن
tm	آمیزه‌های رنگین کالرد ملانژ (افیولیت)	تریاسیک-پالئوژن

نقشه‌ی نوع و رده‌ی خاک منطقه نیز در مقیاس ۱:۱۰۰۰۰۰ تهیه شد (موسسه‌ی تحقیقات خاک و آب کشور، دریافت شخصی) (شکل ۳). شاخص بهنجار شده‌ی تفاوت پوشش گیاهی (NDVI) بر پایه‌ی تصویرهای لندست ۸ (OLI) در نرم افزار انوی ۵٫۳ با رابطه‌ی ۱ محاسبه و تهیه شد (روز و همکاران ۱۹۷۴).

$$NDVI = \frac{(NIR - R)}{(NIR + R)}$$

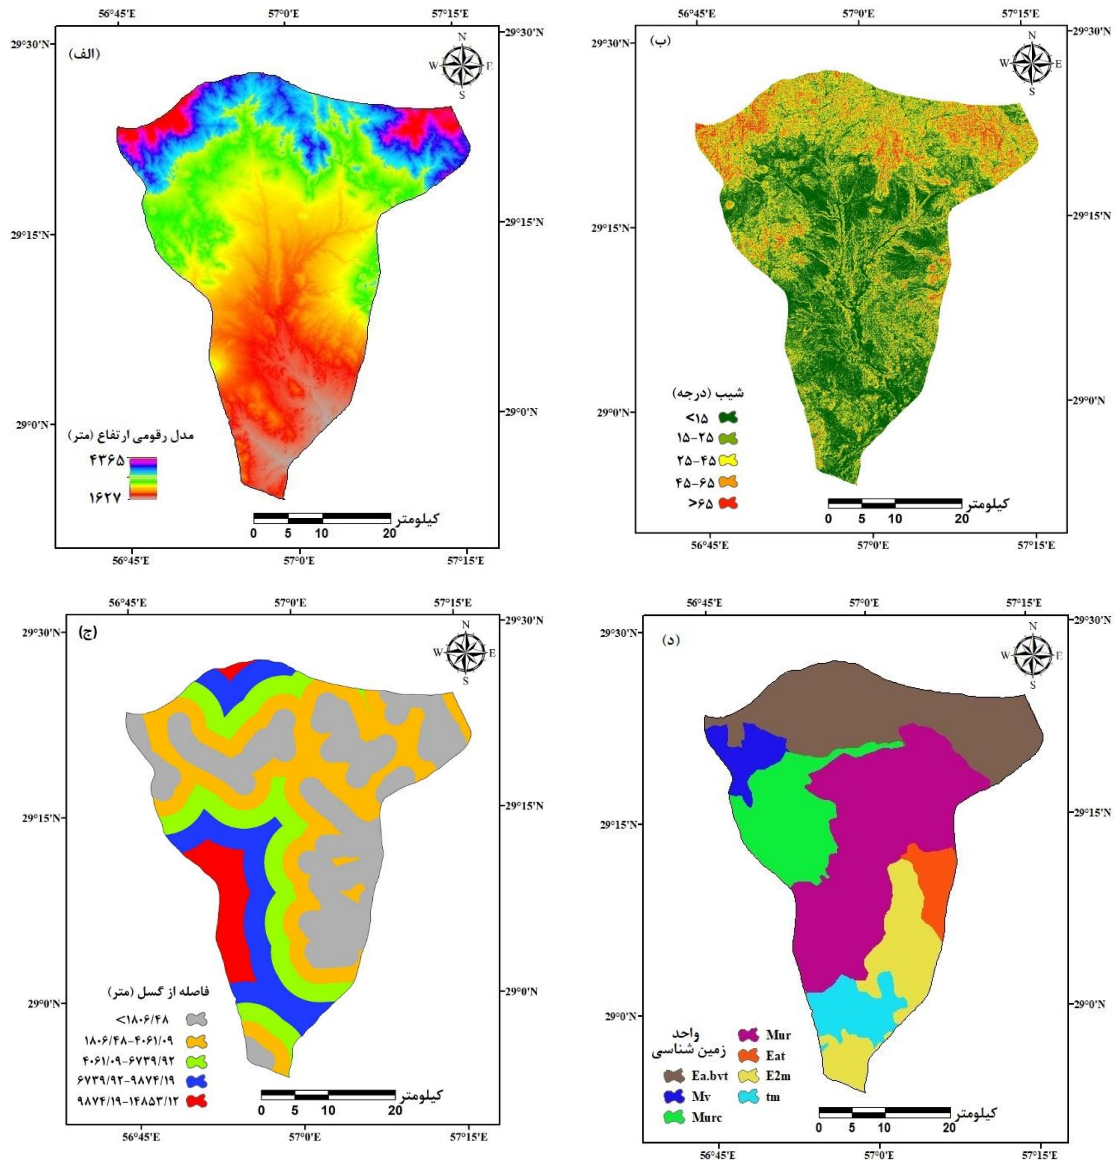
۱

NIR فرسرخ نزدیک، و R نوار سرخ ماهواره‌ی لندست ۸ از دیدگاه نظری، اندازه‌های شاخص تفاوت پوشش گیاهی از ۱- تا ۱+ متغیر است (فانگ و همکاران ۲۰۰۴، امیری و همکاران ۲۰۱۳). این شاخص برای ارزیابی وضعیت پوشش گیاهی به کار برده می‌شود (تنکابل و همکاران ۲۰۰۲، پانندی ۲۰۰۲). اندازه‌ی آن در منطقه‌های با تراکم بسیار کم پوشش گیاهی (پوشش گیاهی تنک) نزدیک به ۱- و در منطقه‌های با تراکم زیاد نزدیک به ۱ است (شکل ۳). نقشه‌ی آب‌راه‌ها با مدل رقومی ارتفاع استخراج شد. نقشه‌ی فاصله‌ی اقلیدسی از

نقشه‌ی کاربری زمین سال ۲۰۲۰ منطقه (لندست ۸) تهیه شد. در ابتدا با نمونه‌برداری میدانی و به‌کمک جی‌پی‌اس، و با تصویرهای ماهواره‌ی بزرگ‌مقیاس (از گوگل‌ارت)، به‌طور کلی هفت رده‌ی زمین کشاورزی، باغی، و بایر، مرتع فقیر، بیشه‌زار، مرتع متوسط، و زمین شهری شناسایی، و نمونه‌ی آموزشی برای ۷ رده‌ی انتظارداشته تهیه شد. نمونه‌های آموزشی به گونه‌ی انتخاب شد که تعداد و پراکنش آن در سراسر حوزه مناسب باشد. در کل منطقه حدود ۱۰۰ جا برای داده‌های آموزشی و داده‌های بررسی انتخاب شد. نقشه‌ی کاربری زمین ۲۰۲۰ بر پایه‌ی نمونه‌های آموزشی و روش رده‌بندی نظارت‌شده‌ی بیشینه‌ی درست‌نمایی در نرم افزار ENVI 5.3 تهیه شد، و به هفت دسته‌ی پیش‌گفته رده‌بندی شد (شکل ۴). برای بررسی دقت نقشه‌ی کاربری زمین تهیه‌شده ضریب کاپا به کار برده شد. هر چه ضریب کاپا به ۱ نزدیک‌تر باشد، نشان‌دهنده‌ی هم‌خوانی بیش‌تر نقشه‌ی تولیدشده با اندازه‌های واقعی است. ضریب کاپای نقشه‌ی کاربری زمین تهیه‌شده نزدیک به ۱ بود (۸۷٪) که نشان‌دهنده‌ی درستی زیاد آن است.

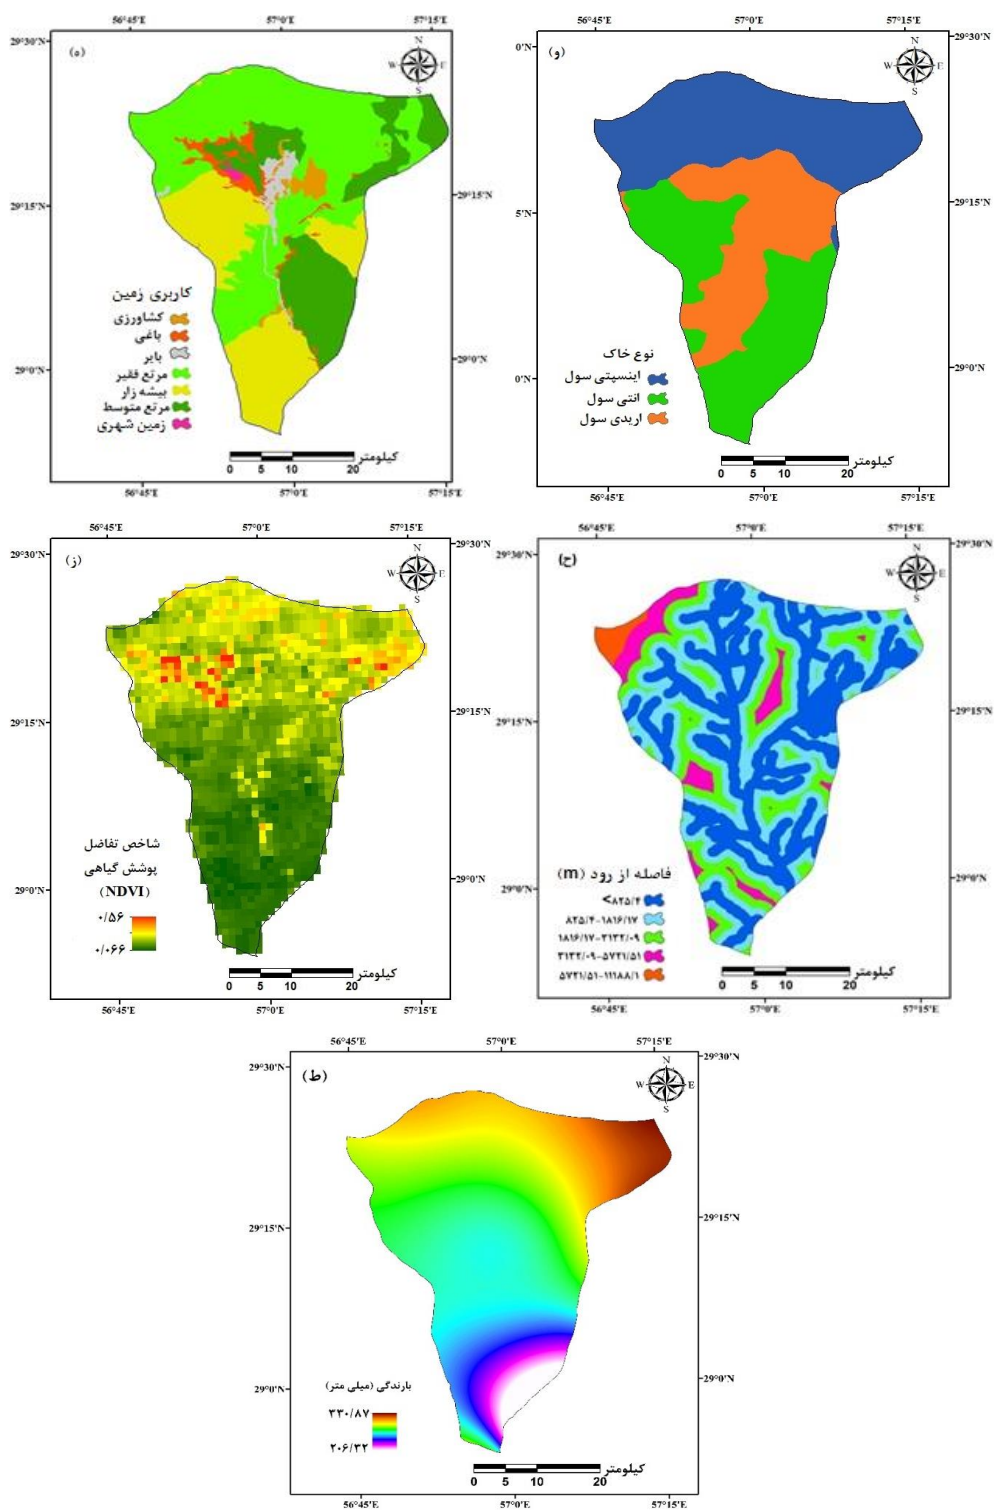
منطقه بر پایه روش درون‌یابی فاصله‌ی معکوس وزنی تهیه شد (شکل ۲ط).

رودها در آرک‌جی‌آی‌اس ۱۰٫۷ تهیه و بر پایه روش شکست طبیعی به پنج رده، رده‌بندی شد (شکل ۲ح). نقشه‌ی بارش با داده‌های بارش ۱۱ ایستگاه باران‌سنجی درون و پیرامون



شکل ۲- لایه‌های به‌کار برده‌شده برای پهنه‌بندی خطر زمین‌لغزش: مدل رقومی ارتفاع (الف)، شیب (ب)، فاصله از گسل (ج)، و زمین‌شناسی (د).

شبیه‌سازی حساسیت زمین لغزش با مدل‌های داده‌کاوی...



شکل ۲، ادامه - لایه‌های به کار برده شده برای پهنه‌بندی خطر زمین لغزش: کاربری زمین (ه)، نوع خاک (و)، شاخص تفاوت پوشش گیاهی (ز)، فاصله از رود (ح)، بارندگی (ط).

هم جمع کرده‌شد، و نقشه‌ی نهایی حساسیت زمین‌لغزش بر پایه‌ی روش تابع شاهد قطعی در نرم افزار آرک جی‌آی‌اس به‌دست‌آمد.

مدل ماشین‌بردار پشتیبان یکی از روش‌های یادگیری ماشین با نظارت است که برای گروه‌بندی و برآورد کردن تابع برازش داده‌ها به کار برده می‌شود، به طوری که کم‌ترین خطا در گروه‌بندی داده‌ها یا تابع برازش رخ دهد. این روش بر پایه‌ی نظریه‌ی یادگیری آماری است، و از اصل کمینه‌سازی خطای ساختاری بهره می‌گیرد تا پاسخی بهینه و کلی به‌دست آورده شود (وپنیک ۱۹۹۹). این مدل ممکن است به شکل خطی به داده‌ها برازیده شود، و اگر چیدمان داده‌ها در فضای اصلی ناخطی باشد آن‌ها را به فضای بالاتری می‌برد تا شیوه‌ی جاگرفتن آن‌ها خطی شود. از طرفی، به دلیل این که یافتن تابع ویژگی برای کارهای گوناگون بسیار دشوار است، می‌توان از تابع‌های کرنل بهره‌گرفت (هافمن و همکاران ۲۰۰۸). مدل SVM با تابع کرنل RBF به دلیل کارکرد بهتر، توانایی عمومی‌سازی خوب و ساختار ساده، برای پیش‌بینی کردن حساسیت زمین‌لغزش مناسب است (وخشوری و همکاران ۲۰۱۹). در این پژوهش مدل SVM با نرم افزار R ۳.۵.۳ اجرا شد (نعیمی و آراجو ۲۰۱۶).

شبکه‌ی عصبی پیچشی (CNN) یکی از مهم‌ترین مدل‌های یادگیری عمیق است (لی چون و همکاران ۲۰۱۵). ویژگی مهم آن پردازش سریع داده‌ها است، زیرا با همه‌ی داده‌های واردشده مانند تصویر رفتار می‌کند (سمین و همکاران ۲۰۲۰). ساختار شبکه‌ی عصبی پیچشی شامل لایه‌های درهم پیچش، لایه‌های ادغام، و لایه‌های متصل کامل است (فام و همکاران ۲۰۲۰، سمین و همکاران ۲۰۲۰) (شکل ۳). دلیل اصلی کارکرد بهتر این مدل بیش‌تر کارکرد لایه‌های پیچشی و ادغام است، زیرا لایه‌های درهم پیچش، ارتباط میان عامل‌ها را در داده‌های واردشده شناسایی می‌کند. لایه‌ی ادغام اندازه‌ی نقشه‌های ویژگی را کاهش می‌دهد، که این خود تعداد ویژگی‌های یادگیری و اندازه‌ی محاسبه‌های شبکه را کاهش می‌دهد. از طرف دیگر این لایه ویژگی‌های هر ناحیه از نقشه‌ی ویژگی را که لایه‌ی پیچشی تولید کرده باشد خلاصه می‌کند؛ در واقع مهم‌ترین آن‌ها را انتخاب و به مرحله‌ی بعد منتقل می‌کند. این باعث می‌شود مدل در برابر تغییر موقعیت ویژگی‌های موجود در تصویر واردشده مقاومت بیش‌تری داشته باشد (فام و همکاران ۲۰۲۰، سمین و همکاران ۲۰۲۰). تابع یکسوساز خطی (ReLU) برای لایه‌های کاملاً متصل برای کاهش خطی بودن شبکه، و دادن رفتار نا خطی به

مدل EBF شامل Bel یا درجه‌ی اطمینان، Dis درجه‌ی نبود اطمینان، Unc درجه‌ی بی قطعیتی و Pls درجه‌ی معقولیت در محدوده‌ی ۰ تا ۱ است (کارانزا و هیل ۲۰۰۳، آلتووینی و همکاران ۲۰۱۲، پرادهان و همکاران ۲۰۱۴). بخش اصلی این نظریه با درجه‌ی اطمینان و درجه‌ی معقولیت نشان داده می‌شود، به همین دلیل درجه‌ی معقولیت بزرگ‌تر از یا مساوی با درجه‌ی اطمینان است. داده‌ی استخراج شده از EBFs نه تنها همبستگی مکانی میان عامل‌های موثر و خطر زمین‌لغزش را، که همبستگی مکانی میان رده‌های هر عامل موثر را برآورد می‌کند (رابطه‌ی ۲ تا ۶) (جور و همکاران ۲۰۱۴).

$$Belief (Bel) = \frac{Bel_1 + Bel_2 + \dots + Bel_n}{\beta} \quad ۲$$

$$Disbelief (Dis) = \frac{Dis_1 + Dis_2 + \dots + Dis_n}{\beta} \quad ۳$$

$$Uncertainty (Unc) = \quad ۴$$

$$\frac{\sum_{i=2}^n (Unc_{i-1}Unc_i + Bel_{i-1}Unc_i + Bel_iUnc_{i-1} + Dis_{i-1}Unc_i + Dis_iUnc_{i-1})}{\beta}$$

$$Plausibility = Bel + Unc \quad ۵$$

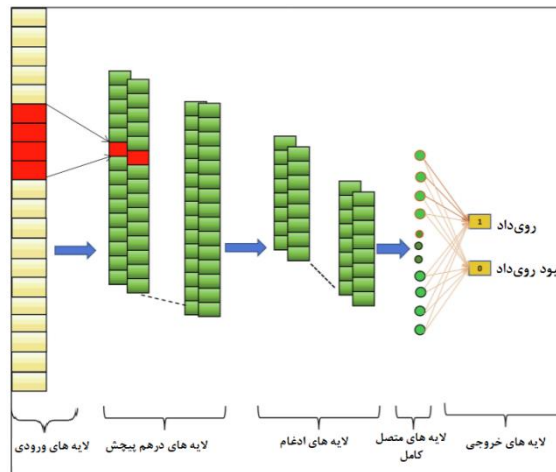
$$\beta = 1 - \sum_{i=2}^n (Bel_{i-1}Dis_i - Dis_{i-1}Bel_i) \quad ۶$$

Beln درجه‌ی کم‌تر از اعتماد برای هر عامل یا محدوده، Disn درجه‌ی بی اعتمادی برای هر عامل یا محدوده، Uncn درجه‌ی بی قطعیتی هر عامل یا محدوده، و n تعداد عامل‌ها است. یکی از ویژگی‌های مدل EBF این است که، Dis و Bel و Unc در محدوده‌ی ۰ و ۱ است و مجموع آن‌ها ۱ است. بنابراین، اگر اندازه‌ی Unc یک باشد، Bel و Dis صفر می‌شود، و اگر مجموع Bel و Dis یک شود، درجه‌ی Unc صفر است.

پس از تعیین کردن وزن ۸ عامل موثر در روی داد زمین‌لغزش (Bel) و ضرب کردن آن در رده‌های عامل، نقشه‌های وزنی با

می‌کند. شبکه‌ی MLP ساختار داده‌های وارد شده را عوض می‌کند، و ماتریس دوبعدی 100×100 را تبدیل به برداری با اندازه‌های 10000 می‌کند. شبکه‌ی عصبی پیچشی ساختار ورودی را عوض نمی‌کند (تبدیل به بردار نمی‌کند)، همان ورودی اصلی را به شبکه می‌دهد و به ارتباط میان نقطه‌های تصویر (پیکسل‌های) همسایه اهمیت می‌دهد (پناهی و همکاران ۲۰۲۰، وانگ و همکاران ۲۰۲۰). این مدل در نرم افزار پایتون اجرا شد.

شبکه به کار برده می‌شود. به دلیل کارکرد خوب مدل بر پایه‌ی پژوهش‌های پیشین، در این پژوهش مدل شبکه‌ی عصبی پیچشی به کار برده شد (قربان‌زاده و همکاران ۲۰۱۹، مندل و همکاران ۲۰۲۱). یکی از ویژگی‌هایی که باعث افزایش یافتن دقت شبکه‌ی عصبی پیچشی در مقایسه با شبکه‌ی عصبی پرسپترون چندلایه شد این است که شبکه‌ی عصبی پیچشی به‌گونه‌ی طراحی شده است که برای ورودی‌های با ساختار چهارچوبی (ماتریسی: دوبعدی و سه‌بعدی) به‌خوبی کار



شکل ۳- ساختار مدل شبکه‌ی عصبی پیچشی.

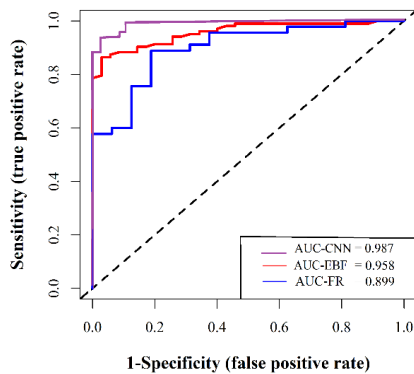
باشد بیانگر بهترین دقت از نقشه‌ی پهنه‌بندی تهیه‌شده است. همبستگی کیفی-کمی سطح زیر منحنی و ارزیابی تخمین به شیوه‌ی ترتیبی است (۱- ۰/۹-۰/۹، عالی، ۰/۸-۰/۸، خیلی خوب، ۰/۷-۰/۸، خوب، ۰/۶-۰/۷، میانه، و ۰/۵-۰/۶، ضعیف) (غلامی و همکاران ۲۰۱۷، و خشوری و زراع ۲۰۱۸). ۷۰٪ از جاهای زمین‌لغزش برای شبیه‌سازی (۴۹ جا) و ۳۰٪ از آن (۲۱ جا) برای ارزیابی مدل‌ها به کار برده شد. با منحنی ROC، درستی نقشه‌های تولیدشده با مدل‌های شبکه‌ی عصبی پیچشی، تابع شاهد قطعی، و ماشین بردار پشتیبان بررسی، و نقشه‌ی دقت آن بیش‌ترین بود نقشه‌ی نهایی خطر زمین‌لغزش برای منطقه پیشنهاد شد.

نتایج


اهمیت نسبی عامل‌ها برای پیش‌بینی حساسیت زمین‌لغزش بر پایه‌ی آزمون جک‌نایف (آماره‌ی سطح زیر منحنی) به‌دست‌آمده از خروجی مدل SVM بررسی شد. عامل‌های زمین‌شناسی و نوع خاک، و سپس ارتفاع و شیب از مهم‌ترین عامل‌های موثر بر روی داد زمین‌لغزش در منطقه بود (شکل ۴). بارندگی تاثیر ناچیزی در پهنه‌بندی حساسیت زمین‌لغزش داشت.

منحنی ROC مشخصه‌ی کارکرد نسبی هر مدل است، و روشی مفید برای نشان‌دادن کیفیت تشخیص‌های احتمالی و قطعی، و سامانه‌های پیش‌بینی است (Pradhan, 2010). نموداری است که در آن نسبت نقطه‌های تصویر مدل که روی داد یا نبود روی داد زمین‌لغزش در آن‌ها به درستی پیش‌بینی شده‌است روی محور افقی (مثبت درست یا ۱-Specificity)، در برابر اندازه‌ی مکمل آن یعنی نسبت نقطه‌هایی که نادرست پیش‌بینی شده‌است (مثبت غلط یا Sensitivity) روی محور عمودی ترسیم می‌شود. این منحنی در نرم‌افزار R 3.5.3 محاسبه و رسم شد.

کارکرد نسبی مدلی که اندازه‌ی مساحت زیر این منحنی آن (سطح زیر منحنی) بیش‌ترین باشد، بهتر است. سطح زیر منحنی بیان‌گر اندازه‌ی پیش‌بینی سامانه از راه توصیف توانایی آن در تخمین‌زدن درست روی داد (زمین‌لغزش) و نبود روی داد است (پرادهان ۲۰۱۰). دل‌خواه‌ترین مدل بیش‌ترین سطح زیر منحنی دارد، و اندازه‌های سطح زیر منحنی از ۰/۵ تا ۱ متغیر است. اگر مدلی نتواند روی داد لغزشی را بهتر از دیدگاه احتمالی (تصادفی) تخمین بزند، اندازه‌ی سطح زیر منحنی آن ۰/۵ است و اگر سطح زیر منحنی برای منحنی تجمعی ۱



شکل ۵- منحنی ROC برای مدل‌های شبکه‌ی عصبی پیچشی، تابع شاهد قطعی، و ماشین بردار پشتیبان در فرآیند شبیه‌سازی حساسیت زمین لغزش منطقه‌ی راتر.



شکل ۴- اهمیت نسبی متغیرهای موثر بر روی داد زمین لغزش.

نظر گسل خوردگی در رده‌های کم‌تر از $18.06/48$ m بود، که به ترتیب 0.44 امتیاز در روش تابع شاهد قطعی گرفت، و بیش‌ترین تاثیر بر روی داد زمین لغزش داشت. بیش‌ترین احتمال روی داد زمین لغزش در منطقه‌های با پوشش گیاهی پراکنده (شاخص کم‌تر از 0.163) و کم‌ترین آن در منطقه‌های با پوشش گیاهی متراکم بود. در زمین‌های مرتعی فقیر و سپس مرتع‌های میانی بیش‌ترین درصد لغزش رخ داده دیده شد. در زمین‌های شهری، بیشه‌زار، بایر و کشاورزی هیچ لغزشی رخ نداد. سازند Mur و E2m بیش‌ترین امتیاز در روش تابع شاهد قطعی (به ترتیب 0.75 و 0.75) گرفت. خاک این سازندها بیش‌تر رُس قرمز و خاک رُس گچی است، و حساسیت‌پذیری آن‌ها در برابر خطر زمین لغزش زیاد بود. بیش‌ترین درصد زمین لغزش در خاک‌های آریدی-سول و سپس اینسپتی-سول بود. وزن رده‌ی بارش $270/54 - 289/03$ بیش‌ترین بود ($Bel=0.56$)، و حساسیت زمین لغزش در بارش‌های کم‌تر و بیش‌تر از آن کاهش یافت. بارندگی اهمیت کم‌تری در روی داد زمین لغزش داشت، و نقش زمین‌شناسی از دیگر عامل‌ها پررنگ‌تر بود. منطقه‌های با بارندگی بیش‌تر در سازندهای زمین‌شناسی سخت بود، که امکان روی داد زمین لغزش در آن‌ها کم‌تر است.

نتیجه‌ی ارزیابی دقت رده‌بندی بر مبنای مدل‌های شبکه‌ی عصبی پیچشی، ماشین بردار پشتیبان و تابع شاهد قطعی با سطح زیر منحنی ROC در شکل ۵ نشان داده شده است. اندازه‌های سطح زیر منحنی برای مدل شبکه‌ی عصبی پیچشی، مدل ماشین بردار پشتیبان، و مدل تابع شاهد قطعی به ترتیب 0.987 ، 0.958 و 0.899 به دست آمد. کارکرد مدل شبکه‌ی عصبی پیچشی در شبیه‌سازی حساسیت زمین لغزش بهتر بود.

نتیجه‌ی بررسی ارتباط میان زمین لغزش و عامل‌های موثر در زمین لغزش، و اندازه‌ی اثر آن‌ها با مدل تابع شاهد قطعی در جدول ۲ آورده شده است. روش EBF چهار عامل درجه‌ی بی اطمینانی (Dis)، اطمینان (Bel)، بی قطعیتی (Unc)، و مقبولیت (Pls) دارد. به طور کلی اندازه‌های زیاد درجه‌ی اطمینان نشان‌دهنده‌ی بیش‌تر بودن خطر لغزش در این منطقه‌ها، و اندازه‌های کم نشان‌دهنده‌ی کم بودن آن است (نمپاک و همکاران ۲۰۱۴). مقایسه‌ی اندازه‌های درجه‌ی اطمینان با بی اطمینانی برای لایه‌های گوناگون نشان داد که درجه‌ی اطمینان برای رده‌هایی که در آن‌ها بی اطمینانی بیش‌تر است، کم‌تر است، و به عکس (جدول ۲). بنابراین بیش‌ترین خطر زمین لغزش در منطقه‌هایی است که در آن درجه‌ی اطمینان زیاد، و بی اطمینانی کم است. بی قطعیتی زیاد در منطقه‌هایی است که در آن درجه‌ی اطمینان کم است (موندال و ماندال ۲۰۲۰). در منطقه‌هایی که درجه‌ی مقبولیت زیاد است درجه‌ی اطمینان زیاد، و بی قطعیتی کم است.

بیش‌ترین وزن ($Bel=0.43$) در بلندی‌های کم‌تر از 2000 m دیده شد، و با افزایش ارتفاع اندازه‌ی حساسیت به خطر زمین لغزش کاهش یافت. شیب 15° تا 25° درجه برای روی داد زمین لغزش بیش‌ترین امتیاز را گرفت (0.4) در روش تابع شاهد قطعی). با فاصله از آبراه‌ها اندازه‌ی تاثیر آن در روی داد زمین لغزش کاهش می‌یافت، به طوری که رده‌ی کم‌تر از $825/4$ m در روش تابع شاهد قطعی 0.37 امتیاز گرفت، و بیش‌ترین تاثیر را در روی داد زمین لغزش داشت (جدول ۲). بر پایه‌ی درجه‌ی اطمینان (Bel)، این رده بیش‌ترین ارتباط را با نقطه‌های روی داد زمین لغزش داشت. فاصله از گسل (شکستگی و خردشدگی بر اثر گسل) نقش موثری در افزودن بر احتمال ناپایداری دامنه‌ها داشت. بیش‌ترین ناپایداری از

شبیه‌سازی حساسیت زمین لغزش با مدل‌های داده‌کاوی...

جدول ۲- ارتباط میان عامل‌های موثر و نقطه‌های لغزشی با مدل تابع شاهد قطعی.

متغیر	فاصله رده‌ها	درصد زمین لغزش	Bel	Dis	Unc	Pls
ارتفاع (m)	<2000	50	0/43	0/14	0/43	0/86
	2000-2500	32/14	0/3	0/18	0/52	0/82
	2500-2800	14/29	0/14	0/23	0/63	0/77
	2800-3300	3/57	0/14	0/21	0/66	0/79
	>3300	0	0	0/24	0/76	0/76
فاصله از رود (m)	825-0/4	46/43	0/37	0/18	0/45	0/82
	1816/17-825/4	39/29	0/32	0/19	0/5	0/81
	3132/09-1816/17	10/71	0/17	0/22	0/61	0/78
	5721/51-3132/09	3/57	0/14	0/21	0/65	0/79
	11188/1-5721/51	0	0	0/21	0/79	0/79
کاربری زمین	زمین‌های کشاورزی	0	0	0/15	0/85	0/85
	زمین‌های باغی	3/57	0/25	0/14	0/61	0/86
	زمین‌های بایر	0	0	0/15	0/85	0/85
	مرتع فقیر	50	0/25	0/13	0/62	0/87
	بیشه‌زار	0	0	0/19	0/81	0/81
پوشش گیاهی	مرتع متوسط	46/43	0/5	0/1	0/4	0/9
	زمین‌های شهری	0	0	0/14	0/86	0/86
	0/163-0/066	64/29	0/58	0/22	0/2	0/78
	0/258-0/163	32/14	0/29	0/42	0/3	0/58
	0/56-0/258	3/57	0/13	0/37	0/5	0/63
شیب (°)	15>	25	0/27	0/2	0/54	0/8
	25-15	46/43	0/4	0/15	0/45	0/85
	45-25	21/43	0/18	0/23	0/59	0/77
	65-45	7/14	0/15	0/21	0/64	0/79
	>65	0	0	0/21	0/79	0/79
نوع خاک	اینسیتی‌سول	28/57	0/22	0/38	0/4	0/62
	انثی‌سول	3/57	0/03	0/47	0/5	0/53
	آریدی‌سول	67/86	0/75	0/14	0/11	0/86
فاصله از گسل (m)	1806/48-0	46/43	0/44	0/15	0/41	0/85
	4061/09-1806/48	35/71	0/3	0/2	0/51	0/8
	6739/92-4061/09	17/86	0/26	0/2	0/53	0/8
	9874/19-6739/92	0	0	0/23	0/77	0/77
	14853/12-9874/19	0	0	0/22	0/78	0/78
زمین شناسی	Ea.bvt	0	0	0/2	0/8	0/8
	Mv	0	0	0/15	0/85	0/85
	Murc	0	0	0/17	0/83	0/83
	Mur	89/3	0/75	0/02	0/23	0/98
	Eat	0	0	0/15	0/85	0/85
	E2m	10/7	0/25	0/15	0/6	0/85
	tm	0	0	0/16	0/84	0/84
بارندگی (mm)	206/31-246/7	0	0	0/21	0/79	0/79
	246/7-270/54	7/5	0/2	0/21	0/59	0/79
	270/54-289/03	71/7	0/56	0/09	0/35	0/91
	289/03-306/54	15/1	0/15	0/24	0/6	0/76
306/54-330/87	5/7	0/09	0/24	0/68	0/76	

نتیجه‌ی خروجی همه‌ی مدل‌ها نشان داد که خطر زمین لغزش در بخش‌های مرکزی، جنوب شرقی و جنوب غربی منطقه زیاد و خیلی زیاد است. به دلیل وجود سازندهای خاک رُس‌دار، این منطقه‌ها آماده‌ی زمین لغزش است. نتیجه‌ی مدل ماشین بردار پشتیبان نشان داد که ۱۵/۱٪ از منطقه (۲۴۳/۸ Km²)

نقشه‌ی نهایی خطر زمین لغزش بر پایه‌ی سه مدل شبکه‌ی عصبی پیچشی، ماشین بردار پشتیبان، و تابع شاهد قطعی در شکل ۶ نشان داده شده است. این نقشه بر پایه‌ی روش رده‌بندی فاصله‌ی یکسان به چهار رده‌ی کم، میانه، زیاد، و خیلی زیاد رده‌بندی شد (ساردویی و همکاران ۲۰۲۱ الف).

(جدول ۳). مدل شبکه‌ی عصبی پیچشی نیز نشان داد که ۱۰/۷٪ از منطقه ($172/7 \text{ Km}^2$) در رده‌ی کم، ۴۷/۵٪ ($747/1 \text{ Km}^2$) در رده‌ی متوسط، ۲۸/۷٪ ($426/6 \text{ Km}^2$) در رده‌ی زیاد، و ۱۳/۱٪ ($211/4 \text{ Km}^2$) در رده‌ی خیلی زیاد است (جدول ۳).

در رده‌ی کم، ۴۶/۱٪ ($744/5 \text{ Km}^2$) در رده‌ی میانه، ۲۸/۳٪ ($456/4 \text{ Km}^2$) در رده‌ی زیاد، و ۱۰/۵٪ ($172/7 \text{ Km}^2$) در رده‌ی خیلی زیاد، و در روش تابع شاهد قطعی ۱۶۹٪ از منطقه ($215/6 \text{ Km}^2$) در رده‌ی کم، ۴۶/۱٪ ($743/3 \text{ Km}^2$) در رده‌ی میانی، ۲۶/۹٪ ($434/1 \text{ Km}^2$) در رده‌ی زیاد، و ۱۳/۷٪ ($220/8 \text{ Km}^2$) در رده‌ی خیلی زیاد است.

جدول ۳- مساحت و درصد رده‌های حساسیت در نقشه‌های پهنه‌بندی خطر زمین‌لغزش.

خطر زمین‌لغزش	ماشین بردار پشتیبان		تابع شاهد قطعی		شبکه‌ی عصبی پیچشی	
	مساحت (Km^2)	مساحت (%)	مساحت (Km^2)	مساحت (%)	مساحت (Km^2)	مساحت (%)
کم	۲۴۳/۸	۱۵/۱	۲۱۵/۶	۱۳/۴	۱۷۲/۷	۱۰/۷
متوسط	۷۴۴/۵	۴۶/۱	۷۴۳/۳	۴۶/۱	۷۶۷/۱	۴۷/۵
زیاد	۴۵۶/۴	۲۸/۳	۴۳۴/۱	۲۶/۹	۴۲۶/۶	۲۸/۷
خیلی زیاد	۱۶۹	۱۰/۵	۲۲۰/۸	۱۳/۷	۲۱۱/۴	۱۳/۱
مساحت کل	۱۶۱۳/۸	۱۰۰	۱۶۱۳/۸	۱۰۰	۱۶۱۳/۸	۱۰۰

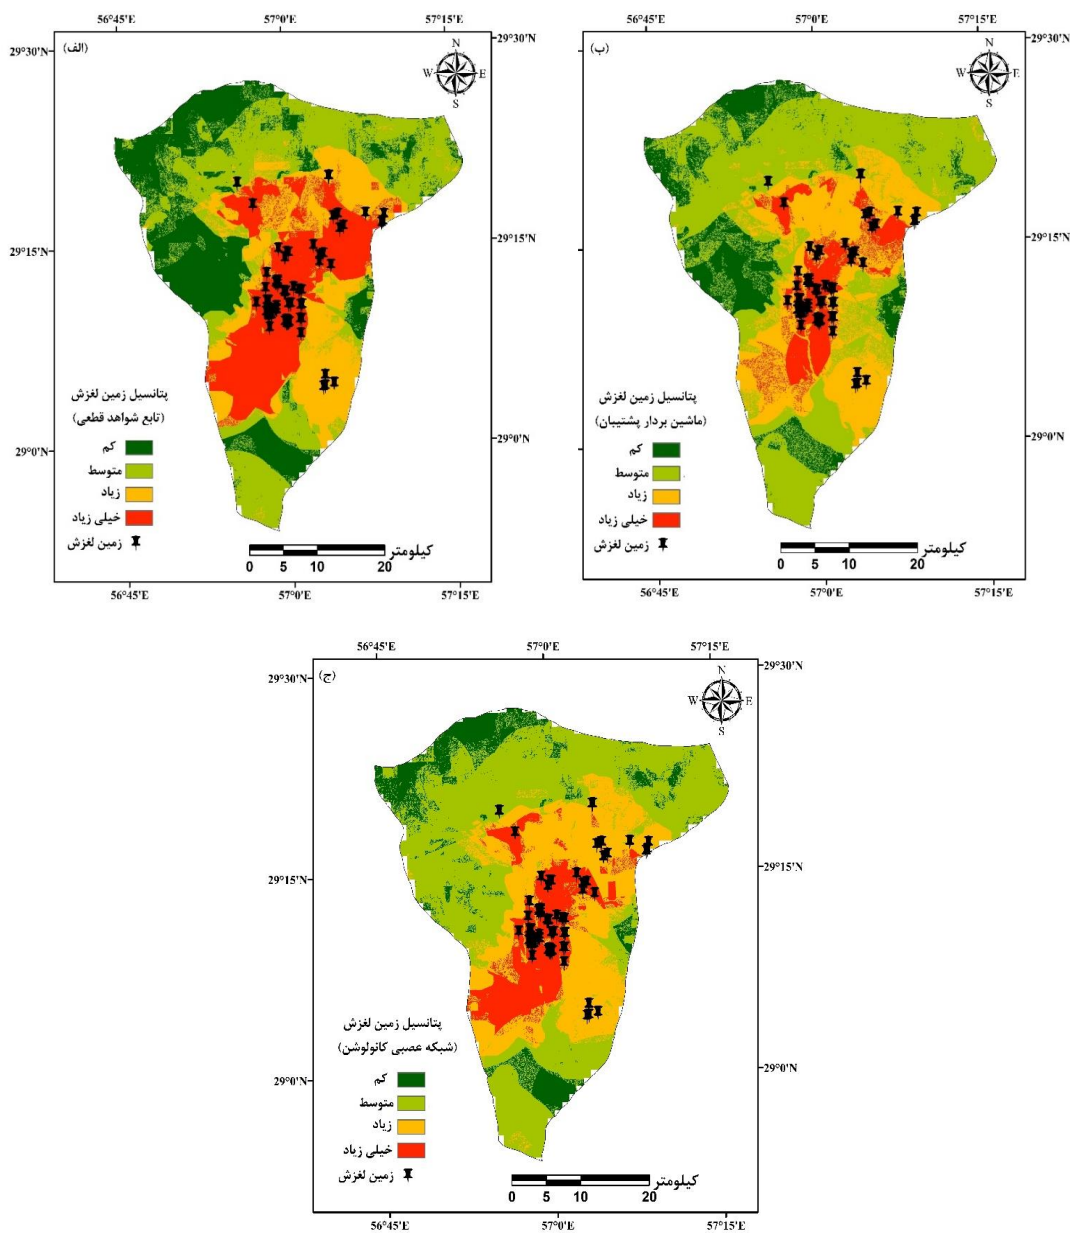
خطر زمین‌لغزش کاهش یافت، که این موضوع نشان‌دهنده‌ی سنگ‌شناسی مقاوم منطقه در بلندی‌های زیاد و دست‌کاری‌های انسانی در بلندی‌های کم‌تر است. بررسی شیب منطقه نشان داد که امتیاز شیب 15° تا 25° برای روی‌داد زمین‌لغزش بیش‌ترین است. در شیب‌های کم‌تر و بیش‌تر از این روی‌داد زمین‌لغزش کاهش می‌یابد. در شیب کم برآیند نیروها به شیوه‌ی است که نیروهای مقاوم بیش‌تر از نیروی محرکه است، و شرایط روی‌داد زمین‌لغزش را در منطقه فراهم نکرده است. در برابر، در شیب‌های خیلی زیاد نیز فرآیندهای فرسایشی دیگر چیرگی دارد و خاک کافی برای روی‌داد زمین‌لغزش فراهم نمی‌شود.

با فاصله از آب‌راه‌ها اندازه‌ی تاثیر آن در روی‌داد زمین‌لغزش کاهش یافت. شبکه‌های زه‌کشی به‌علت بارش و مساعده‌بودن شیب از جریان تند آب تاثیر می‌گیرد، و جریان آب و نفوذ آن باعث ناپایداری شدن سازندهای سست و حساس در برابر نفوذ می‌شود. از طرفی، بودن جریان آب و نفوذ کردن آن به منطقه‌های خردشده و پهنه‌های برشی امکان لغزش را افزایش می‌دهد. از این رو با فاصله‌گرفتن از رود اندازه‌ی نفوذ آب کم‌تر می‌شود و در نتیجه اندازه‌ی لغزش کاهش می‌یابد. این یافته با نتیجه‌های محمدنیا و فلاح (۲۰۱۸) هم‌خوانی دارد. بررسی نقشه‌ی بارش نشان داد که بیش‌ترین روی‌داد زمین‌لغزش در رده‌ی $289/03 - 270/54$ بود، و در بارش‌های کم‌تر و بیش‌تر از آن حساسیت زمین‌لغزش کاهش یافت. فاصله از گسل (شکستگی و خردشدگی بر اثر گسل) نقش موثری در افزایش ناپایداری دامنه‌ها دارد. بیش‌ترین تاثیر در روی‌داد زمین‌لغزش در منطقه‌های با فاصله‌ی کم‌تر از آن بود.

بحث و نتیجه‌گیری

نتیجه‌ی به‌دست‌آمده از بررسی اهمیت نسبی متغیرها بر پایه‌ی آزمون جک نایف در منطقه نشان داد که بارندگی اهمیت کم‌تری از دیگر عامل‌ها در روی‌داد زمین‌لغزش دارد، و نقش زمین‌شناسی چیره‌تر از دیگر عامل‌ها است. سازندهای زمین‌شناسی در منطقه‌های با بارندگی بیش‌تر سخت است، و امکان روی‌داد زمین‌لغزش در آن‌ها کم‌تر است، که با نتیجه‌ی ساردویی و همکاران (۲۰۲۱ الف) هم‌خوانی دارد. بارش نسبت به دیگر عامل‌ها تاثیر کمی در شبیه‌سازی حساسیت زمین‌لغزش داشت. اهمیت متغیرهای واردشده به‌دلیل نتیجه‌ی فرآیند شبیه‌سازی و آزمون جک نایف است. ما در تعیین اهمیت متغیرها دخالتی نداشتیم و این کار با آزمون جک نایف خودکارانه انجام شد. بررسی اهمیت متغیرها، نتیجه‌ی فرآیند تحلیل حساسیت متغیرهای واردشده بود که بر پایه‌ی ارتباط موقعیت نقطه‌های زمین‌لغزش (متغیر وابسته) و متغیرهای محیطی (مستقل) مشخص شد. درست است که بارش برانگیراننده‌ی حرکت‌های توده‌ی است، ولی در همه جا ممکن است متغیر مهمی در شبیه‌سازی زمین‌لغزش نباشد. شاید دیگر ویژگی‌های گیتاشناسی و زمین‌شناسی در منطقه اثرگذارتر باشد. در پژوهش مرادی و همکاران (۲۰۱۰) در تحلیل خطر زمین‌لغزش در جاده‌ی هراز نیز اهمیت بارش در برآورد خطر زمین‌لغزش کم بود.

ارتباط میان زمین‌لغزش و عامل‌های موثر بر آن با روش‌های تابع شاهد قطعی بررسی شد. نتیجه‌ی به‌دست‌آمده از بررسی ارتفاع نشان داد که وزن بلندی‌های کم‌تر از 2000 m در این روش بیش‌ترین بود، و با افزایش ارتفاع اندازه‌ی حساسیت به



شکل ۶- نقشه‌ی پهنه‌بندی خطر زمین‌لغزش بر پایه‌ی مدل تابع شاهد قطعی (الف)، مدل ماشین بردار پشتیبان (ب)، و شبکه‌ی عصبی پیچشی (ج).

جنوب شرقی و جنوب غربی منطقه زیاد و خیلی زیاد است. منحنی ROC یکی از معتبرترین معیارهای ارزیابی کارکرد مدل‌ها است و می‌تواند اعتبار کلی نتیجه را تخمین بزند (وخشوری و زارع ۲۰۱۸). نتیجه‌ی ارزیابی روش‌ها با روش ROC در این پژوهش نشان داد که درستی و توانایی همه‌ی مدل‌ها در پهنه‌بندی حساسیت زمین لغزش در منطقه بسیار خوب بود، که با نتیجه‌ی وخشوری و زارع در آبخیز قائمشهر، استان مازندران (۲۰۱۸) هم‌خوانی دارد. کارایی

منطقه‌های با پوشش گیاهی تنک و پراکنده بیش‌ترین احتمال روی‌داد زمین‌لغزش را داشت که با یافته‌های عرب عامری و شیرانی (۲۰۱۵) هم‌خوانی دارد. نتیجه‌ی زمین‌های مرتعی نشان داد که بیش‌ترین درصد زمین‌لغزش در سازندهای با خاک رُس قرمز و خاک‌های آریدی-سول و اینسپتی-سول بود. نقشه‌های پهنه‌بندی زمین‌لغزش برپایه‌ی خروجی مدل‌های شبکه‌ی عصبی پیچشی، تابع شاهد قطعی، و ماشین بردار پشتیبان نشان داد که خطر زمین‌لغزش در بخش‌های مرکزی،

مدل یادگیری عمیق پیش‌رفته‌ی شبکه‌ی عصبی پیچشی در مقایسه با دیگر مدل‌های داده‌کاوی است. برای افزایش دادن دقت پیش‌بینی‌ها در پژوهش‌های آینده ترکیب مدل شبکه‌ی عصبی پیچشی با دیگر روش‌های داده‌کاوی برای شبیه‌سازی آینده‌ی حساسیت زمین‌لغزش پیشنهاد می‌شود. نقشه‌های پهنه‌بندی خطر زمین‌لغزش در منطقه ممکن است نقش شایانی در تصمیم‌گیری‌های آینده، مدیریت دامنه‌های خطرناک و آمایش سرزمین در منطقه داشته‌باشد. انجام‌دادن طرح‌های مناسب مانند ساختن دیوارهای حائل، جلوگیری از نفوذ آب، زه‌کشی مناسب، کاشت پوشش گیاهی متناسب با محیط در دامنه‌های آماده‌ی لغزش ممکن است در جلوگیری از این روی داد و مهار کردن آن مناسب باشد.

مدل یادگیری عمیق شبکه‌ی عصبی پیچشی (با سطح زیر منحنی ۰/۹۸۷) برای ارزیابی زمین‌لغزش‌ها بهتر از دو مدل دیگر بود، که با نتیجه‌ی مندال و همکاران (۲۰۲۱) در آبخیز رود روراچو سیکیم هند هم‌خوانی دارد. نتیجه‌ی فانگ و همکاران (۲۰۲۰) در منطقه‌ی یانگچین در چین نیز نشان‌دهنده‌ی توانایی زیاد مدل شبکه‌ی عصبی پیچشی از دیگر مدل‌های یادگیری ماشینی در پهنه‌بندی حساسیت زمین‌لغزش بود. نتیجه‌ی فام و همکاران (۲۰۲۰) نیز در شبیه‌سازی حساسیت زمین‌لغزش در ویتنام نشان داد که مدل شبکه‌ی عصبی پیچشی از دیگر مدل‌های یادگیری ماشینی مانند ANN، RF و مانند آن‌ها بهتر عمل کرد. به طور کلی نتیجه‌ی این تحقیق نشان‌دهنده‌ی اهمیت زیاد

فهرست منابع

- Althuwaynee OF, Pradhan B, Lee S. 2012. Application of an evidential belief function model in landslide susceptibility mapping. *Computers & Geosciences*. 44: 120–135.
- Amiri M, Solaimani K, Tamartash R, Miryaghoubzadeh M. 2013. Identification of invasive species using remote sensing and vegetation indices (Case study: Vazroud Rangelands, Iran). *Journal of Rangeland Science*. 3(1): 59–70.
- Arabameri A, Shirani K, Rezaeei Kh. 2017. A comparative assessment between weights-of-evidence and frequency ratio models for landslide hazard zonation in Vanak Basin. *Journal of Watershed Management Research*. 8(15): 147–160. (In Persian)
- Beheshti Z, Gharagozlou A, Monavari M, Zarkesh MK. 2021. Landslides behavior spatial modeling by using evidential belief function model, Promethean II model, and index of entropy in Tabriz, Iran. *Arabian Journal of Geosciences*. 14(17): 1–22.
- Bui DT, Hoang ND, Martínez-Álvarez F, Ngo PTT, Hoa PV, Pham TD, ..., Coštache R. 2020. A novel deep learning neural network approach for predicting flash flood susceptibility: A case study at a high frequency tropical storm area. *Science of The Total Environment*. 701: 1–38.
- Carranza EJM, Hale M. 2003. Evidential belief functions for data-driven geologically constrained mapping of gold potential, Baguio district, Philippines. *Ore Geology Reviews*. 22(1–2): 117–132.
- Chen W, Pourghasemi HR, Kornejady A, Zhang N. 2017. Landslide spatial modeling: Introducing new ensembles of ANN, MaxEnt, and SVM machine learning techniques. *Geoderma*. 305: 314–327.
- Chen YC, Chang KT, Lee HY, Chiang SH. 2015. Average landslide erosion rate at the watershed scale in southern Taiwan estimated from magnitude and frequency of rainfall. *Geomorphology*. 228: 756–764.
- Emad al-Din S, Babajani H. 2017. Landslide hazard mapping using hierarchical analysis (AHP) in Babolrood catchment, the 1st National Conference on New Ideas and Technologies in Geographical Sciences, University of Zanjan, Zanjan, Iran, 10 p. (In Persian).
- Fang J, Piao S, He J, Ma W. 2004. Increasing terrestrial vegetation activity in China, 1982–1999. *Science in China Series C: Life Sciences*. 47(3): 229–240.
- Gholami M, Soleymani K, Nekoe E. 2017. Landslide susceptibility mapping by use of Weight

- of Evidence (WofE) and Frequency Ratio (FR) and Dempster-Shafer (DSH) models: A case study of Sari-Kiasar region, Northern Iran. *Journal of Rangeland and Watershed Management*. 70(3): 735–750. (In Persian).
- Ghorbanzadeh O, Blaschke T, Gholamnia K, Meena SR, Tiede D, Aryal J. 2019. Evaluation of different machine learning methods and deep-learning convolutional neural networks for landslide detection. *Remote Sensing*. 11(2): 196.
- Hofmann T, Schölkopf B, Smola AJ. 2008. Kernel methods in machine learning. *The Annals of Statistics*. 36 (3): 1171–1220.
- Hong H, Naghibi SA, Pourghasemi HR, Pradhan B. 2016. GIS-based landslide spatial modeling in Ganzhou City, China. *Arabian Journal of Geosciences*. 9(2): 1–26.
- Jebur MN, Pradhan B, Tehrany MS. 2014. Manifestation of LiDAR-derived parameters in the spatial prediction of landslides using novel ensemble evidential belief functions and support vector machine models in GIS. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 8(2): 674–690.
- Kalantar B, Pradhan B, Naghibi SA, Motevalli A, Mansor S. 2018. Assessment of the effects of training data selection on the landslide susceptibility mapping: A comparison between support vector machine (SVM), logistic regression (LR) and artificial neural networks (ANN). *Geomatics, Natural Hazards and Risk*. 9(1): 49–69.
- Karami F, Bayati Khatibi M, Kheirizadeh M, Mokhtari Asl A. 2019. Evaluation of performance of support vector machine algorithm in landslide susceptibility zoning in Ahar-chai Basin. *Journal of Geographic and Environmental Hazards*. 8(4): 1–17.
- Khan A, Gupta S, Gupta SK. 2020. Multihazard disaster studies: monitoring, detection, recovery, and management, based on emerging technologies and optimal techniques. *International Journal of Disaster Risk Reduction*. 47: 1–34.
- Kornejady A, Pourghasemi HR. 2019. Landslide susceptibility assessment using data mining models, A case study: Chehel-Chai Basin. *Watershed Engineering and Management*. 11(1): 28–42.
- LeCun Y, Bengio Y, Hinton G. 2015. Deep learning. *Nature*. 521 (7553): 436–444.
- Li R, Wang N. 2019. Landslide susceptibility mapping for the Muchuan County (China): A comparison between bivariate statistical models (woe, ebf, and ioe) and their ensembles with logistic regression. *Symmetry*. 11(6): 1–24.
- Mandal K, Saha S, Mandal S. 2021. Applying deep learning and benchmark machine learning algorithms for landslide susceptibility modeling in Rorachu river basin of Sikkim Himalaya, India. *Geoscience Frontiers*. 12(5): 1–17.
- Mirzania S, Shahabi H. 2020. Evaluation and spatial prediction of landslide hazard in mountainous road of Sanandaj-Kamyaran using advanced data mining algorithms. *Environmental Hazards Management*. 6(4): 317–340. (In Persian).
- Mohammadnia M, Fallah G. 2018. Landslide susceptibility mapping using fuzzy logic and AHP. *Researches in Geographical Sciences*. 18 (48): 115–130. (In Persian).
- Mohammady M, Pourghasemi HR, Pradhan B. 2012. Landslide susceptibility mapping at Golestan Province, Iran: A comparison between frequency ratio, Dempster-Shafer and weights-of-evidence models. *Journal of Asian Earth Sciences*. 61: 221–236.
- Mojarad Z, Jamalabadi J, Shafiei N, Zanganeh Asadi M, Parak K. 2020. The zoning of the risk of mass movements using information valuation methods and surface density in the Ghouchan- Shirvan watershed. *Journal of Spatial Analysis Environmental Hazards*. 7 (3): 147–162. (In Persian).
- Mondal S, Mandal S. 2020. Data-driven evidential

- belief function (EBF) model in exploring landslide susceptibility zones for the Darjeeling Himalaya, India. -Geocarto International. -35(8): 818-856.
- Moradi HR, Mohammadi M, Pourghasemi HR, Feiznia S. 2010. Landslide risk analysis and estimation using hierarchical analysis process method in a part of Haraz road. The Journal of Spatial Planning. 14(2): 234-247. (In Persian).
- Naimi B, Araujo MB. 2016. sdm: A reproducible and extensible R platform for species distribution modelling. Ecography. 39(4): 368-375.
- Nampak H, Pradhan B, Manap MA. 2014. Application of GIS based data driven evidential belief function model to predict groundwater potential zonation. Journal of Hydrology. 513: 283-300.
- Neuhäuser B, Terhorst B. 2007. Landslide susceptibility assessment using "weights-of-evidence" applied to a study area at the Jurassic escarpment (SW-Germany). -Geomorphology. -86(1-2): 12-24.
- Ngo PTT, Panahi M, Khosravi K, Ghorbanzadeh O, Kariminejad N, Cerda A, Lee S. 2021. Evaluation of deep learning algorithms for national scale landslide susceptibility mapping of Iran. -Geoscience Frontiers. -12(2): 505-519.
- Nhu VH, Zandi D, Shahabi H, Chapi K, Shirzadi A, Al-Ansari N, ..., Nguyen H. 2020. Comparison of support vector machine, Bayesian logistic regression, and alternating decision tree algorithms for shallow landslide susceptibility mapping along a mountainous road in the west of Iran. -Applied Sciences. -10(15): 1-27.
- Oh HJ, Kadavi PR, Lee CW, Lee S. 2018. Evaluation of landslide susceptibility mapping by evidential belief function, logistic regression and support vector machine models. -Geomatics, Natural Hazards and Risk. -9(1): 1053-1070.
- Panahi M, Sadhasivam N, Pourghasemi HR, Rezaie F, Lee S. 2020. Spatial prediction of groundwater potential mapping based on convolutional neural network (CNN) and support vector regression (SVR). Journal of Hydrology. 588: 1-12.
- Pandey R. 2002. Analysis of water resources parameters for model development through application of satellite remote sensing and geographic information system in semi-arid environment. Ph.D. Dissertation. Department of Civil and Building Engineering. Loughborough University. 485 p.
- Pandey VK, Pourghasemi HR, Sharma MC. (2020). Landslide susceptibility mapping using maximum entropy and support vector machine models along the Highway Corridor, Garhwal Himalaya. -Geocarto International. 35(2): 168-187.
- Pham BT, Prakash I, Dou J, Singh SK, Trinh PT, Tran HT, Le TM, Van Phong T, Khoi DK, Shirzadi A, Bui DT. 2020a. A novel hybrid approach of landslide susceptibility modelling using rotation forest ensemble and different base classifiers. Geocarto International. 35 (12): 1267-1292.
- Pradhan B, Hagemann U, Tehrany MS, Prechtel N. 2014. An easy-to-use ArcMap based texture analysis program for extraction of flooded areas from TerraSAR-X satellite image. -Computers & geosciences. -63: 34-43.
- Pradhan B. 2010. Landslide susceptibility mapping of a catchment area using frequency ratio, fuzzy logic and multivariate logistic regression approaches. -Journal of the Indian Society of Remote Sensing. -38(2): 301-320.
- Rahamana SA, Aruchamy S, Jegankumar R. 2014. Geospatial approach on landslide hazard zonation mapping using multicriteria decision analysis: A study on Coonoor and Ooty, part of Kallar watershed, The Nilgiris, Tamil Nadu. -The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences. -40(8): 1417-1422.
- Rahimi M, Solaimani K. 2017. Remote sens-

- ing and GIS based assessment groundwater potential zones mapping using multi-criteria decision-making technique. *Iran-Watershed Management Science & Engineering*. 10(35): 27–38. (In Persian).
- Roccati A, Paliaga G, Luino F, Faccini F, Turconi L. 2021. GIS-based landslide susceptibility mapping for land use planning and risk assessment. *Land*. 10(2): 1–28.
- Rouse JW, Haas RH, Schell JA, Deering DW, Harlan JC. 1974. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. *NASA/GSFC Type III Final Report, Greenbelt, Md*, 371 p.
- Salehi M, Safamehr M, Nasri M, Boor H. 2017. Effects of landslides on the safety of roads and rural settlements in Iran and stabilization methods (Case study of Naghan-Karoon 4 road landslides), *Housing and Rural Environment*. 36(158): 77–88.
- Sameen MI, Pradhan B, Lee S. 2020. Application of convolutional neural networks featuring Bayesian optimization for landslide susceptibility assessment. *Catena*. 186: 1–13
- Sardooi ER, Azareh A, Mesbahzadeh T, Sardooi FS, Parteli EJ, Pradhan B. 2021a. A hybrid model using data mining and multi-criteria decision-making methods for landslide risk mapping at Golestan Province, Iran. *Environmental Earth Sciences*. 80(15): 1–25.
- Sardooi ER, Pourghasemi HR, Azareh A, Sardooi FS, Clague, JJ. 2021b. Comparison of statistical and machine learning approaches in land subsidence modelling. *Geocarto International*. (just-accepted), pp. 1–41.
- Shahabi H, Khezri S, Ahmad BB, Hashim M. 2014. Landslide susceptibility mapping at central Zab basin, Iran: A comparison between analytical hierarchy process, frequency ratio and logistic regression models. *Catena*. 115(4): 55–70.
- Shirani K, Arabameri A. 2015. Landslide hazard zonation using logistic regression method (Case study: Dez-e-Oulia Basin), *Journal of Water and Soil Science, Isfahan University of Technology*. 19(72): 321–334. (In Persian).
- Silakhori Z, Vahabzadekebriya G, Poorghasemi H. 2021. Landslide hazard assessment using Dempster-Shafer model (Case study: Part of Talar Watershed). *Environmental Erosion Research*. 11(3): 82–98. (In Persian).
- Soleimani A, Farrokhnia A, Motamedi H. 2017. Landslide susceptibility zoning in the area of drilling site of well A using Analytic Hierarchy Process (AHP). *Journal of Exploration & Production Oil & Gas*. 1396(148): 64–70. (In Persian).
- Taalab K, Cheng T, Zhang Y. 2018. Mapping landslide susceptibility and types using Random Forest. *Big Earth Data*. 2(2): 159–178.
- Thenkabail PS, Gamage MSDN, Samakhtin VU. 2002. Evaluation of narrowband and Broadband Vegetation Indices for determining optimal hyperspectral wavebands for agricultural crop characterization, *Photogrammetric engineering and remote sensing*. 68(6): 607–621.
- Thiery Y, Terrier M, Colas B, Fressard M, Maquaire O., Grandjean G, Gourdiere S. 2020. Improvement of landslide hazard assessments for regulatory zoning in France: STATE-OF-THE-ART perspectives and considerations. *International Journal of Disaster Risk Reduction*. 47: 1–25.
- Tien Bui D, Shahabi H, Omidvar E, Shirzadi A, Geertsema M, Clague JJ, ... , Lee S. 2019. Shallow landslide prediction using a novel hybrid functional machine learning algorithm. *Remote Sensing*. 11(8): 1–22.
- Vakhshoori V, Pourghasemi HR, Zare M, Blaschke T. 2019. Landslide susceptibility mapping using GIS-based data mining algorithms. *Water*. 11(11): 1–30.
- Vakhshoori V, Zare M. 2016. Landslide susceptibility mapping by comparing weight of evi-

- dence, fuzzy logic, and frequency ratio methods. *Geomatics, Natural Hazards and Risk*. 7(5): 1731–1752.
- Vakhshoori V, Zare M. 2018. Is the ROC curve a reliable tool to compare the validity of landslide susceptibility maps?—*Geomatics, Natural Hazards and Risk*.—9(1): 249–266.
- Vapnik VN. 1999. *The nature of statistical learning theory*. Second Edition, Springer Verlag, New York, 314 p.
- Wang Y, Fang Z, Hong H, Peng L. 2020. Flood susceptibility mapping using convolutional neural network frameworks. *Journal of Hydrology*. 582: 1–48
- Yoo Y, Baek T, Kim J, Park S. 2016. A comparative study of the frequency ratio and evidential belief function models for Landslide susceptibility mapping.—*Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*.—34(6): 597–607.
- Youssef AM, Pourghasemi HR, Pourtaghi ZS, Al-Katheeri MM. 2016. Landslide susceptibility mapping using random forest, boosted regression tree, classification and regression tree, and general linear models and comparison of their performance at Wadi Tayyah Basin, Asir Region, Saudi Arabia.—*Landslides*.—13(5): 839–856.



Landslide Susceptibility Simulation Using Data Mining Models in Rabor Area

Elham Rafiei Sardooi

(Corresponding Author)* Associate Professor, Department of Ecological Engineering, Faculty of Natural Resources, University of Jiroft

Corresponding Author Email: ellrafiei@ujiroft.ac.ir

Received: 25 October 2021

Accepted: 02 December 2021

Abstract

Landslide, as one of the most important natural hazards, causes financial losses and destruction of natural resources, every year. Rabor area, located upstream of Halilrood watershed, is prone to landslides due to the presence of marl formations and hence, a high amount of sediment has entered the Safa reservoir in Rabor city. Therefore, the purpose of this study is to zone this environmental hazard using convolutional neural network (CNN), support vector machine (SVM) and evidential belief function (EBF) models in Rabor region. To achieve this purpose, the parameters of altitude, slope, and distance from the fault, geology, land use, soil type, Normalized Difference Vegetation Index, and distance from the river were used. Then, using the data of the Geological Survey of Iran and field observations using GPS, a landslide distribution map was prepared as a dependent variable. There were 70 landslides, 49 (70%) of which were used for simulating and 21 (30%) for model validation. The results obtained from the validation of the models using the ROC showed that the AUC values for CNN, SVM and EBF models were 0.987, 0.958 and 0.899, respectively. Overall, the results showed a satisfactory correlation between the landslide data available in the area and the landslide susceptibility maps and the deep learning model of the convolutional neural network had a higher performance compared with the other two models. Finally, the landslide susceptibility map was classified into four classes: low, medium, high, and very high susceptibility. According to the results of all models; the central, southeastern, and southwestern parts of the study area have a high and very high landslide risk. Carrying out appropriate designs such as retaining walls, preventing water infiltration, appropriate drainage, planting vegetation suitable for the environment, and landslide-prone slopes and etc can be appropriate in preventing and controlling this hazard.

Keywords: Convolutional neural network, evidence belief function, geographic information system, simulation, support vector machine.