

شناسایی مناطق مستعد به وقوع زمین لغزش با استفاده از سیستم اطلاعات جغرافیایی و ترکیب مدل های یادگیری ماشین و الگوریتم های فراابتکاری

محمد امین دره شوری^{۱*}، مهران یزدی^۲

^۱ کارشناس ارشد سنجش از دور - دانشکده راه، ساختمان و محیط زیست - دانشگاه شیراز
m_a_darehshuri.1361@yahoo.com

^۲ استاد دانشکده برق و کامپیوتر - دانشگاه شیراز
yazdi@shirazu.ac.ir

(تاریخ دریافت آبان ۱۴۰۰، تاریخ تصویب تیر ۱۴۰۱)

چکیده

زمین لغزش یک پدیده زمین شناسی است که در دامنه های ناپایدار مناطق کوهستانی رخ داده و در برخی از موارد خسارات جانی و اقتصادی بسیار شدیدی ایجاد می کند. با استفاده از پهنه بندی مناطق مستعد به وقوع زمین لغزش، می توان از خسارات احتمالی در آینده جلوگیری نمود. بدین منظور، نقشه های حساسیت زمین لغزش با استفاده از دو روش یادگیری ماشین ANFIS و SVR و ترکیب آنها با الگوریتم های فراابتکاری PSO و GWO تولید می شوند. فاکتورهای موثر انتخاب شده شامل چهارده فاکتور ارتفاع، شیب، جهت شیب، انحنای طولی و عرضی شیب، کاربری اراضی، لیتولوژی، بارندگی، فاصله از جاده، فاصله از رودخانه، فاصله از گسل، تراکم جاده، تراکم رودخانه و تراکم گسل می باشد. نقشه های زمین لغزش های رخ داده شامل ۲۵۳ نقطه تهیه شده و از بین نقاط لغزشی ۷۰٪ برای مدل سازی و ۳۰٪ باقی مانده نیز برای صحت سنجی در نظر گرفته می شوند. سپس، نقشه های مربوط به هر پارامتر تهیه شده و پس از آماده سازی پایگاه داده، مدل های ترکیبی ANFIS-GWO، ANFIS-PSO، SVR-GWO و SVR-PSO پیاده سازی می شوند. سپس، شاخص حساسیت زمین لغزش برای هر مدل برآورد می شود که در طی فرآیند مدل سازی با استفاده از شاخص آماری RMSE عملکرد هر روش ارزیابی می گردد. در گام آخر، با استفاده از نرم افزار ArcMap 10.5 نقشه های حساسیت زمین لغزش برای هر مدل تولید شده و سپس با استفاده از منحنی ROC دقت هر نقشه تخمین زده می شود. نتایج حاصل از نمودار ROC برای مدل های ANFIS-GWO، ANFIS-PSO، SVR-PSO و SVR-GWO به ترتیب ۸۹،۴، ۸۵،۷، ۸۸،۱، ۸۸،۷ بدست آمد.

واژگان کلیدی: یادگیری ماشین با نظارت، زمین لغزش، الگوریتم های بهینه سازی، GIS

۱- مقدمه

زمین لغزش^۱ یکی از پرتکرارترین و مخرب ترین پدیده های طبیعی است که هر ساله در سراسر جهان موجب تلفات جانی و خسارات اقتصادی و زیست محیطی می شود که بعد از زلزله و سیل، بیشترین آسیب را به انسان وارد می کنند [۱]، [۴]. بعلاوه، از تاثیرات منفی زیست محیطی آن نمی توان چشم پوشی نمود که شامل جابجایی سالانه میلیاردها تن خاک و سنگ می باشد [۳]. عوامل مختلفی بر وقوع زمین لغزش موثر است که شامل زمین شناسی، هیدرولوژی، هیدروژئولوژی، اقلیم، توپوگرافی و مورفولوژی می باشد. ایران به دلایل مختلف از جمله توپوگرافی عمدتاً کوهستانی، فعالیت های لرزه خیزی، شرایط متنوع زمین شناسی و اقلیمی همواره با وقوع این پدیده ی طبیعی روبرو بوده است. طبق برآوردهای انجام شده تا سپتامبر سال ۲۰۰۷، حدود ۴۹۰۰ زمین لغزش رخ داده است که خسارت مالی ناشی از آن ۱۲۶۸۹۳ میلیون ریال و تلفات جانی نیز ۱۸۷ مورد گزارش شده است [۵].

طی سال های اخیر با توسعه ی سنجش از دور و سیستم های اطلاعات جغرافیایی، تولید نقشه های حساسیت زمین لغزش امکان پذیر شده است. نقشه ی حساسیت زمین لغزش^۲ ابزار بسیار مفیدی است که با توجه به تاثیر پارامترهای مختلف، سطح زمین را به درجات مختلف پایداری شیب طبقه بندی می کند [۲]، [۶]. روش های مختلفی برای ارزیابی حساسیت زمین لغزش بکار رفته است. از جمله مطالعاتی که در این زمینه انجام شده است Pradhan [۱۴] برای تولید نقشه ی حساسیت زمین لغزش حوضه ی Cameron در مالزی سه مدل نسبت فراوانی (FR)، رگرسیون لجستیک چندمتغیره (LR) و منطق فازی (Fuzzy logic) را بکار برده است. ابتدا پایگاه داده شامل ۹ پارامتر موثر بر وقوع زمین لغزش و نقشه ی لغزش های رخ داده ایجاد شد. در گام بعدی، با کمک مدل های بکار رفته ارتباط بین زمین لغزش ها و پارامترها مشخص و پس از وزن دهی کلاس ها نقشه ی حساسیت زمین لغزش تولید شد. در گام آخر، با استفاده از منحنی ROC دقت هر روش برآورد و سپس با یکدیگر مقایسه شدند. نتایج به دست آمده مشخص کرد مدل نسبت فراوانی با دقت ۸۹٪ نسبت به منطق فازی و رگرسیون لجستیک (به ترتیب با دقت های ۸۴٫۵۲٪ و ۸۵٫۷۳٪) عملکرد بهتری دارد.

Mohammady و همکاران [۱۰] از سه روش نسبت فراوانی (FR)، وزن شواهد (WOE) و دمپستر شفر (EBF) جهت تهیه نقشه ی زمین لغزش استفاده نمودند. ابتدا ۳۹۲ زمین لغزش رخ داده شناسایی شد. در مرحله بعد، ۷۰٪ نقاط برای آموزش و ۳۰٪ باقی مانده نیز برای برآورد دقت مدل ها تقسیم بندی شد. با استفاده از مدل های بکار رفته، نقشه های حساسیت زمین لغزش تولید شد. پس از صحت سنجی با استفاده از منحنی ROC، نتایج نشان داد دقت پیش بینی مدل های FR، EBF و WOE به ترتیب ۷۵٪، ۷۳٪ و ۶۹٪ است. براساس نتایج مدل نسبت فراوانی (FR)، در مقایسه با مدل های WOE و EBF برآورد بهتری از منطقه ی مورد مطالعه ارائه می دهد.

Nourani و همکاران [۷] چهار روش متفاوت نسبت فراوانی (FR)، رگرسیون لجستیک (LR)، شبکه ی عصبی مصنوعی (ANN) و الگوریتم ژنتیک (GP) را برای پهنه بندی زمین لغزش منطقه ی Zonouz واقع در شمال ایران بکار گرفتند. برای رسیدن به این مهم، ابتدا پایگاه داده ی شامل ۱۹۰ نقطه ی لغزشی و هفت عامل موثر شیب، جهت شیب، ارتفاع، کاربری اراضی، فاصله از جریانات سطحی و فاصله از جاده را ایجاد نمودند. در گام بعدی، نقشه ی حساسیت زمین لغزش با استفاده از مدل های ارائه شده تولید شد. آن ها مشخص کردند دقت مدل های FR، LR، ANN و GP به ترتیب ۸۷٫۵۷، ۸۹٫۴۲، ۹۲٫۳۷ و ۹۳٫۲۷ درصد می باشد. براساس نتایج، الگوریتم ژنتیک عملکرد بهتری در مقایسه با دیگر مدل ها از خود نشان داد.

Zhao و همکاران [۲۰] جهت تولید نقشه ی حساسیت زمین لغزش شهر Shangluo در چین، از دو مدل شاخص آماری (SI) و فاکتور اطمینان (CF) استفاده نمودند. بعد از جمع آوری داده های مربوطه، از ۱۴۵ موقعیت زمین لغزش به دست آمده، ۱۰۱ نقطه برای آموزش مدل ها و نقاط باقی مانده نیز جهت صحت سنجی بکار گرفته شد. بعد از تجزیه و تحلیل ارتباط بین لغزش های رخ داده و پارامترهای موثر، برای هر مدل یک نقشه ی حساسیت زمین لغزش تولید شد. سپس، به منظور مقایسه ی روش ها با یکدیگر و برآورد دقت هریک، از منحنی ROC استفاده نمودند. آن ها نشان دادند مدل CF با سطح زیر منحنی ۶۸٫۸۶٪ با اختلاف بسیار کم دقت بالاتری نسبت به روش SI با سطح زیر منحنی ۶۸٫۶۷٪ دارد.

^۱ Landslide^۲ (LSM) Landslide Susceptibility Mapping

بهتری نسبت به مدل های Bagging (۸۵,۴٪)، LogitBoost (۸۴,۸٪) و AdaBoost (۸۴٪) در شناسایی مناطق مستعد به وقوع زمین لغزش دارد.

Jaafari و همکاران [۱۶] برای ارزیابی دامنه های حساس به وقوع زمین لغزش در منطقه Uttarakhand واقع در شمال هند، از ترکیب مدل ANFIS با دو الگوریتم هوشمند GWO و BBO استفاده کردند. برای این منظور، ابتدا یک پایگاه داده شامل ۳۹۱ نقطه ی لغزشی و شانزده عامل موثر را ایجاد کردند. پس از آماده سازی لایه ها و تقسیم بندی نقاط لغزشی به دو گروه آموزشی و صحت سنجی، ارتباط بین داده ها را با مدل SWARA مشخص کردند. سپس، با استفاده از مدل های ترکیبی ANFIS-GWO و ANFIS-BBO نقشه های حساسیت زمین لغزش منطقه را تولید کردند. همچنین، برای ارزیابی نتایج تحقیق یکبار از منحنی ROC و یکبار نیز از شاخص میانگین مربعات خطا استفاده نمودند. نتایج حاصل نشان داد مدل ANFIS-BBO با سطح زیر منحنی ۰,۹۵٪ و مقدار RMSE^۱ ۰,۳۱۶، نقشه ی دقیق تری نسبت به ANFIS-GWO (با مقدار ROC ۰,۹۴٪ و RMSE ۰,۳۲۲) ارائه می دهد.

هدف از پژوهش حاضر مطالعه ای جامع از طریق ترکیب روش های ماشین بردار پشتیبان (SVR)^۲ و شبکه فازی-عصبی تطبیقی (ANFIS)^۳ با دو الگوریتم هوشمند ازدحام ذرات (PSO)^۴ و گرگ خاکستری (GWO)^۵ است. همچنین، یک مقایسه بین چهار روش ترکیبی جدید انجام خواهد شد تا از بین مدل های بکاررفته، بهترین مدل ترکیبی جهت تولید نقشه ی حساسیت زمین لغزش انتخاب شود. اگرچه روش های کمی و کیفی متفاوتی در مطالعات مختلف بکار رفته است، اما به دلیل اهمیت موضوع، استفاده از روش های جدید به منظور رسیدن به نتایجی با دقت بالاتر ضروری است.

۲- روش تحقیق

۲-۱- منطقه مورد مطالعه

استان اردبیل به عنوان شمالی ترین استان ایران در غرب دریای کاسپین و بین طول جغرافیایی ۴۸° و ۲۰' ۴۷° و ۵۸° و همچنین عرض جغرافیایی ۱۰' ۳۷° و ۴۰' ۳۹° واقع

Chen و همکاران [۱۷] برای شناسایی مناطق مستعد به وقوع زمین لغزش از ترکیب مدل یادگیری ماشین ANFIS با سه الگوریتم هوشمند GA، PSO و DE استفاده کردند. بعد از شناسایی نقاط لغزشی، با استفاده از عکس های هوایی و تصاویر ماهواره ای به تعیین عوامل موثر با استفاده از ویژگی های منطقه ی مورد مطالعه و داده های در دسترس پرداختند. سپس، با استفاده از سه مدل ترکیبی ANFIS-GA، ANFIS-PSO و ANFIS-DE به تجزیه و تحلیل منطقه ی مورد مطالعه پرداختند. ارزیابی نتایج با استفاده از منحنی ROC نشان داد، ترکیب مدل ANFIS با الگوریتم هوشمند DE عملکرد بهتری نسبت به مدل های دیگر دارد.

Aghdam و همکاران [۲۱] به منظور غلبه بر نقاط ضعف مدل های آماری نسبت فراوانی (FR) و وزن شواهد (WOE)، آن ها را با روش یادگیری ماشین ANFIS ترکیب کردند. بنابراین، ابتدا منطقه ی مورد مطالعه که شامل رشته کوه های زاگرس می باشد را انتخاب کردند. سپس، با شناسایی نقاط لغزشی و عوامل موثر (شامل یازده فاکتور) پایگاه داده را ایجاد نمودند. در فاز بعدی، با استفاده از مدل های FR و WOE ارتباط بین توزیع زمین لغزش ها و عوامل موثر را مشخص کردند. به منظور تولید نقشه های حساسیت زمین لغزش، یکبار از نتایج مدل های FR و WOE و بار دیگر نیز از نتایج مدل های ترکیبی ANFIS-FR و ANFIS-WOE استفاده کردند. ارزیابی نتایج نشان داد مدل های ترکیبی بکار رفته خروجی بهتری در مقایسه با روش های آماری FR و WOE دارند. براساس نتایج، مدل های ANFIS-FR و ANFIS-WOE به ترتیب با مقادیر ۸۵٪ و ۸۴٪ عملکرد بهتری در مقابل روش های FR و WOE با مقادیر ۸۲٪ دارد.

Kadavi و همکاران [۲۲] چند مدل ترکیبی یادگیری ماشین شامل AdaBoost، LogitBoost، Multiclass Classifier و Bagging را بکار بردند. برای این منظور، ابتدا نقاط لغزش منطقه ی مورد مطالعه (Sacheon-myeon) واقع در کره جنوبی) را در قالب یک نقشه ی مکانی تهیه کردند. تعداد زمین لغزش های شناسایی شده شامل ۷۶۲ نقطه می باشد. پس از تعیین عوامل موثر بر زمین لغزش و ایجاد پایگاه داده، هریک از مدل ها پیاده سازی و در نهایت نقشه های حساسیت زمین لغزش تولید شد. پس از ارزیابی هر یک از نقشه ها و مقایسه با یکدیگر، مشخص کردند مدل Multiclass Classifier با دقت ۸۵,۹٪ عملکرد

^۱ Root Mean Square Error


^۲ Support Vector Regression (SVR)

^۳ Adaptive neuro-fuzzy inference system

^۴ Particle swarm optimization

^۵ Grey Wolf Optimizer

شده است. این استان دارای مساحتی در حدود ۱۷۹۵۳ کیلومترمربع و ارتفاع متغیر بین ۴ تا ۴۷۸۳ متر است. این استان علاوه بر میانگین بارش ۳۱۶ میلی‌متر در سال، از متوسط دمای ۱۰,۹^۰ نیز بهره می‌برد. شیب منطقه از ۰ تا ۷۵,۶^۰ متغیر است و از نظر ساختار لیتولوژی نیز، واحدهای Eav و Qft2 بیشترین پوشش را دارند. شکل ۱ موقعیت منطقه‌ی مورد مطالعه و همچنین پراکنش نقاط لغزشی را نشان می‌دهد.




شکل ۱- منطقه‌ی مورد مطالعه

۲-۲- روش شناسی

در این بخش، عوامل موثر بر وقوع زمین‌لغزش استان اردبیل شناسایی شده و درجه‌ی حساسیت مناطق مختلف آن ارزیابی می‌شود. پایگاه داده شامل نقشه‌ی پراکنش لغزش‌های رخ داده از سازمان مراتع، جنگل‌ها و آبخیزداری تهیه شده و جهت ارزیابی و تایید زمین‌لغزش‌های رخ داده، از تصاویر گوگل‌ارث استفاده شده است. در ادامه، با استفاده از داده‌های در دسترس و بررسی مطالعات گذشته، عوامل موثر و محرک وقوع زمین‌لغزش شناسایی شده و سپس با استفاده از نرم‌افزار ArcGIS 10.5 لایه‌های رقومی هر پارامتر تهیه شده است. پس از شناسایی وابستگی بین زمین لغزش‌ها و عوامل موثر با استفاده از مدل SWARA، ابتدا روش یادگیری ماشین ANFIS با دو الگوریتم هوشمند PSO و GWO در محیط MATLAB پیاده‌سازی شده است. سپس با استفاده از نقاط لغزش‌های در نظر گرفته شده برای آموزش مدل‌ها که شامل ۷۰٪ نقاط می‌باشد، دو مدل ترکیبی ANFIS-PSO و ANFIS-GWO آموزش داده می‌شوند. در مرحله بعد، با استفاده از شبکه‌ی ایجاد شده مقادیر نهایی هر پیکسل مشخص می‌گردد. همین روند برای ترکیب روش یادگیری ماشین SVR با دو الگوریتم PSO و GWO تکرار می‌گردد. پس از پیاده‌سازی مدل‌ها، نقشه‌های حساسیت زمین‌لغزش با

استفاده از مقادیر نهایی پیکسل‌ها و انتقال آن به نرم‌افزار ArcMap تولید می‌شوند. فاز آخر نیز در اصل ارزیابی نتایج حاصل از فاز اول می‌باشد. برای رسیدن به این هدف، ۲ روش کمی جهت برآورد نتایج حاصل بکار گرفته شده‌اند. ابتدا در محیط MATLAB با استفاده از شاخص آماری RMSE عملکرد هر مدل ارزیابی می‌شود. سپس با استفاده از منحنی ROC دقت نقشه‌های حساسیت زمین‌لغزش، برآورد خواهد شد. صحت‌سنجی مدل‌ها و نقشه‌ها با استفاده از نقاط صحت‌سنجی انجام گرفته است. با استفاده از این دو روش می‌توان یک ارزیابی دقیق از نتایج مدل‌سازی ارائه کرد. نهایتاً نتایج مدل‌های ترکیبی بکار رفته به منظور انتخاب بهترین مدل مقایسه می‌شوند. شکل ۲ مراحل مختلف مطالعه را به صورت شماتیک نشان می‌دهد.



شکل ۲- فلوچارت مراحل انجام شده

۲-۳- روش تحلیل نسبت ارزیابی وزن‌دهی تدریجی (SWARA)


این روش که در سال ۲۰۱۱ به وسیله Keršulienė و Turskis معرفی شد به عنوان یک روش قدرتمند در مطالعات مختلفی بکار رفته است. هدف این مدل رتبه‌بندی و محاسبه وزن معیارها و زیرمعیارها می‌باشد. از ویژگی‌های این روش که آن را نسبت به دیگر روش‌ها متمایز می‌کند، این است که نظرات کارشناسی، معیارها را بر اساس اهمیت نسبی آن‌ها رتبه‌بندی می‌کند (Keršulienė and Turskis, 2011). مهمترین معیار در رده‌ی نخست قرار می‌گیرد و به آن امتیاز یک اختصاص داده می‌شود. جزئیات مربوط به این روش بصورت زیر است:

۴-۲- نقشه‌ی زمین لغزش‌های رخ داده

تهیه‌ی نقشه‌ی زمین لغزش‌های رخ داده اولین گام و یکی از مهم‌ترین داده‌های مورد نیاز جهت تولید نقشه‌ی حساسیت زمین لغزش است. در این مقاله، موقعیت و توزیع مکانی زمین لغزش‌ها از سازمان مراتع، جنگل‌ها و آبخیزداری تهیه شده است. در گام بعدی، از سامانه‌ی گوگل ارث به منظور اعتبار سنجی داده‌ها استفاده شده است. براساس داده‌های موجود، تعداد ۲۵۳ نقطه‌ی لغزشی برای استان اردبیل در نظر گرفته شده و با استفاده از نرم افزار ArcMap نقاط لغزشی به دو دسته‌ی آموزش و آزمایش تقسیم‌بندی می‌شود.

۴-۲-۱- ارتفاع

ارتفاع یکی از عوامل مهم و تاثیرگذار بر وقوع زمین لغزش به حساب می‌آید. این عامل به صورت معناداری بر ویژگی خاک موثر است [۱۲]. در این مقاله، نقشه‌ی DEM منطقه‌ی مورد مطالعه که با استفاده از تصاویر ماهواره ASTER تهیه شده و مدل رقومی ارتفاع به ۵ کلاس مختلف تقسیم بندی شده است. شکل ۳ لایه‌ی مورد نظر را نشان می‌دهد.



شکل ۳- نقشه‌ی ارتفاع منطقه‌ی مورد مطالعه

۴-۲-۲- شیب

شیب به عنوان یک پارامتر بسیار مهم در رانش زمین همواره مورد توجه بوده است و از عوامل اصلی ایجاد زمین لغزش در مناطق مختلف به حساب می‌آید. به طور پیش فرض، در شیب‌های کمتر از ۵ درجه لغزش اتفاق نمی‌افتد [۱۲]. شکل ۴ جزئیات لایه‌ی تولید شده را نشان می‌دهد.

۱- کارشناسان بر مبنای دانش و تجربه خود، معیارها را بر اساس درجه‌ی اهمیتی که دارند رتبه‌بندی می‌کنند. مهمترین معیار در رده نخست قرار می‌گیرد و بدترین معیار نیز در جایگاه آخر قرار می‌گیرد.

۲- اهمیت نسبی هر معیار نسبت به معیار قبلی برآورد می‌شود، بر اساس رابطه (۱) که در آن n تعداد خبرگان و A_i نیز رتبه‌های پیشنهادی است.

$$S_j = \sum_i^n A_i / n \quad (1)$$

۳- ضریب K_j تابعی از مقدار اهمیت نسبی هر معیار بوده و بصورت رابطه (۲) برآورد می‌شود.

$$K_j = S_j + 1 \quad (2)$$


۴- در این مرحله، وزن اولیه‌ی هر معیار براساس رابطه (۳) محاسبه می‌شود. معیار نخست که مهمترین می باشد وزنی معادل ۱ دارد.

$$Q_j = Q_{j-1} / K_j \quad (3)$$

۵- در گام آخر نیز وزن نرمال نهایی محاسبه می‌شود. هرچقدر این مقدار بیشتر باشد، نشان‌دهنده‌ی وابستگی بیشتر بین کلاس مربوطه با وقوع زمین لغزش است.

از آنجایی که پارامترهای مختلفی بر وقوع زمین لغزش موثر است، انتخاب و آماده‌سازی درست پارامترهای موثر همواره از اهمیت زیادی برخوردار بوده است. در این مقاله، با بررسی مطالعات گذشته و همچنین داده‌های در دسترس، ۱۴ عامل مهم و تاثیرگذار شامل ارتفاع، شیب، جهت شیب، انحنای طولی و عرضی شیب، کاربری اراضی، لیتولوژی، بارندگی، فاصله از جاده، تراکم جاده، فاصله از رودخانه، تراکم رودخانه، فاصله از گسل و تراکم گسل انتخاب گردید. داده‌های مورد نیاز تهیه و سپس با استفاده از پلت فرم ArcGIS 10.5 رقومی و ذخیره‌سازی شده‌اند. در گام بعدی، نقشه‌ی لغزش‌های رخ داده با لایه‌های رقومی تولید شده همپوشانی شد تا درصد زمین لغزش در هر کلاس مشخص گردد. سپس، با استفاده از درصد زمین لغزش‌های رخ داده و درصد پیکسل‌های هر کلاس، مدل تصمیم‌گیری SWARA برای وزن‌دهی به کلاس‌های هر پارامتر اجرا شده است.


لایه مدل رقومی ارتفاع وارد نرم افزار ArcMap شد. شکل ۶ جزئیات مربوط به این لایه را نشان می دهد.



شکل ۶- نقشه‌ی انحنای سطح منطقه‌ی مورد مطالعه

۲-۴-۵- انحنای پروفایل^۲

انحنای طولی شیب نقش مهمی در واگرایی و همگرایی جریان آب در سراسیابی ایفا می کند. بنابراین در نظر گرفتن آن به عنوان یک پارامتر تاثیرگذار بر زمین لغزش همواره مورد توجه بوده است. برای تولید این لایه، مدل رقومی ارتفاع استفاده شد. شکل ۷ کلاس‌های این لایه را نشان می دهد.




شکل ۷- نقشه‌ی انحنای پروفایل منطقه‌ی مورد مطالعه

۲-۴-۶- کاربری اراضی

افزایش فعالیت‌های انسانی طی دهه‌های اخیر و تغییر کاربری اراضی موجب تشدید وقوع زمین لغزش شده است، به طوری که بر بزرگی، تعداد تکرارها و حتی نوع آن تاثیرگذار


^۲ Profile curvature



شکل ۴- نقشه‌ی شیب منطقه‌ی مورد مطالعه

۲-۴-۳- جهت شیب

جهت مختلف شیب تاثیر متفاوتی بر وقوع زمین لغزش دارد. مثلاً، جهت شمال به دلیل تبخیر کمتر و رطوبت بیشتر، نسبت به جهت جنوب که در معرض نور آفتاب است با احتمال وقوع زمین لغزش بیشتری روبرو است. در این مقاله به منظور نشان دادن ارتباط بین جهت شیب و زمین لغزش‌های رخ داده، این پارامتر انتخاب گردید. برای تولید لایه‌ی جهت شیب از مدل رقومی ارتفاع استفاده شد و لایه‌ی تولیدشده به ۹ کلاس طبقه‌بندی شده است. شکل ۵ جزئیات مربوط به این لایه را نشان می دهد.




شکل ۵- نقشه‌ی جهت شیب منطقه‌ی مورد مطالعه

۲-۴-۴- انحنای سطح^۱

انحنای سطح، نقش مهمی در واگرایی و همگرایی جریان آب در سراسیابی ایفا می کند. این پارامتر نشان دهنده انحنای خط منحنی میزان است که از تقاطع سطح زمین با یک سطح افقی تشکیل شده است. برای تولید این

^۱ Plan curvature


بارندگی همواره به عنوان یک عامل محرک بر وقوع زمین لغزش شناخته شده است [۱۵]، [۲۰]. بارندگی موجب نفوذ آب به مواد دامنه و افزایش درجهی اشباع می شود. با افزایش درجهی اشباع، مقاومت برشی شیب ها کاهش یافته و لذا احتمال وقوع زمین لغزش افزایش می یابد. میزان تاثیر بارندگی بستگی به شرایط اقلیمی منطقه، توپوگرافی و نفوذپذیری مواد سازندهی دامنه دارد. با استفاده از اطلاعات سازمان هواشناسی، میانگین بارش سالانهی هر ایستگاه مشخص شد. شکل ۱۰، لایه های این پارامتر را نشان می دهد.



شکل ۱۰- نقشه ی میانگین بارش منطقه ی مورد مطالعه


۲-۴-۹- فاصله از جاده و تراکم جاده

ساخت جاده همواره به عنوان یک عامل انسانی مخرب موجب تشدید وقوع زمین لغزش شده است. راه سازی در نزدیکی شیب ها موجب بر هم زدن تعادل طبیعی آن ها و در نتیجه ریزش دامنه می شود.



شکل ۱۱- نقشه ی فاصله از جاده و تراکم جاده ی منطقه ی مورد مطالعه


است [۱۸]. یکی از این فعالیت های مخرب، از بین بردن پوشش های گیاهی دامنه ها و در نتیجه کاهش مقاومت برشی خاک است. در این مقاله، نقشه ی کاربری اراضی از سازمان جغرافیایی تهیه شده و به فرمت رستر تبدیل شده است. شکل ۸ لایه های این پارامتر را نشان می دهد.



شکل ۸- نقشه ی کاربری اراضی منطقه ی مورد مطالعه


۲-۴-۷- لیتولوژی

یکی از عوامل اصلی در وقوع لغزش در بسیاری از زمین لغزش ها نوع مصالح درگیر است و هر نوع ساختار سنگ شناسی از مقاومت خاصی در برابر تنش برشی خاک برخوردار است [۱۹]. نقشه ی سنگ شناسی با مقیاس 1:100000 از سازمان زمین شناسی تهیه و سپس رقومی سازی شد. شکل ۹ نقشه ی لیتولوژی منطقه ی مورد مطالعه و واحدهای تشکیل دهنده ی هر منطقه را نشان می دهد.



شکل ۹- نقشه ی لیتولوژی منطقه ی مورد مطالعه

۲-۴-۸- بارندگی



شکل ۱۳- نقشه‌ی فاصله از گسل و تراکم گسل منطقه‌ی مورد مطالعه

۲-۴-۵- ترکیب روش‌های یادگیری ماشین ANFIS و SVR با الگوریتم‌های PSO و GWO

به منظور تولید نقشه‌های حساسیت زمین‌لغزش از چهار مدل ترکیبی مختلف ANFIS-GWO، ANFIS-PSO، SVR-GWO و SVR-PSO استفاده می‌شود. برای رسیدن به این هدف، ابتدا با استفاده از روش SWARA وزن هر کلاس مشخص شده و در گام بعدی داده‌های ورودی به الگوریتم‌ها با استفاده از نقاط آموزشی و صحت‌سنجی و همپوشانی آن‌ها با لایه‌های رقومی آماده می‌گردد. سپس با استفاده از نرم‌افزار MATLAB و داده‌های ورودی، هر الگوریتم به صورت جداگانه آموزش داده خواهد شد. پس از آموزش و آزمایش، مقادیر نهایی پیکسل‌ها وارد مدل‌ها شده تا شاخص حساسیت زمین لغزش برآورد گردد. همچنین، به منظور تخمین دقت عملکرد هر مدل در مرحله‌ی آموزش و آزمایش از شاخص‌های کمی مانند MSE و R^2 و MAE و RMSE استفاده می‌شود.


الف) بهینه‌سازی رگرسیون بردار پشتیبان (SVR) توسط الگوریتم ازدحام ذرات (PSO)

رگرسیون بردار پشتیبان SVR یک الگوریتم یادگیری ماشین است که توسط Vapnik در سال ۱۹۹۹ بر اساس تئوری یادگیری آماری تهیه شده است (Vapnik, 1995). در هر مدل‌سازی SVR، پارامترهایی وجود دارد که باید توسط کاربر با دقت بسیار زیادی تنظیم شوند. ورود نادرست پارامترهای فوق توسط کاربر می‌تواند منجر به نتایج نادرست و حتی فریبنده شود. برای این منظور، در این تحقیق از الگوریتم بهینه‌سازی فراابتکاری برای جستجو مقدار بهینه‌ی

این مسئله بخصوص زمانی تشدید می‌شود که این گونه ساختوسازهای غیراصولی و بدون در نظر گرفتن مقاوم‌سازی‌های لازم انجام شوند. بنابراین، در این مقاله دو عامل فاصله از جاده و تراکم جاده‌های استان اردبیل به عنوان پارامترهای تاثیرگذار در نظر گرفته شده است. شکل ۱۱ لایه‌های این پارامتر را نمایش می‌دهد.

۲-۴-۱۰- فاصله از رودخانه و تراکم رودخانه

جریان‌ات سطحی به وسیله‌ی اشباع مواد و همچنین شستن و حمل مواد پنجه شیب‌ها موجب ناپایداری شیب‌ها می‌شود [۲۰]. این شستشو به وسیله امواج رودخانه‌ها در طول مسیر حرکتشان رخ می‌دهد. اگر رودخانه طغیان کند، احتمال وقوع زمین‌لغزش افزایش می‌یابد. شکل ۱۲ لایه‌های این پارامتر را نشان می‌دهد.



شکل ۱۲- نقشه‌ی فاصله از رودخانه و تراکم رودخانه‌ی منطقه‌ی مورد مطالعه

۲-۴-۱۱- فاصله از گسل و تراکم گسل

حرکت صفحات تکتونیکی زمین همواره تعادل طبیعی شیب‌ها را بر هم زده و به عنوان یک عامل موثر در نظر گرفته شده است [۲۱]. در مناطقی که گسل‌های فعال وجود دارد، معمولاً شاهد وقوع بیشتر زمین‌لغزش هستیم. این احتمال با فاصله از گسل رابطه‌ی مستقیم دارد. هرچقدر فاصله از گسل بیشتر باشد تاثیرپذیری دامنه‌های ناپایدار از حرکت صفحات تکتونیکی کمتر می‌شود. در تحقیق حاضر، داده‌های مربوط به گسل‌های فعال با مقیاس ۱:۵۰۰۰۰۰ از سازمان زمین‌شناسی تهیه شده و سپس به لایه‌های رقومی تبدیل شده است. شکل ۱۳ نقشه‌ی های مربوط به عوامل فاصله از گسل و تراکم گسل را نشان می‌دهد.

$$\begin{cases} \vec{D} = \left| \vec{C} \cdot \vec{X}_P(t) - \vec{X}(t) \right| \\ \vec{X}(t+1) = \left| \vec{X}_P(t) - \vec{A} \cdot \vec{D} \right| \end{cases} \quad (۶)$$

که در این روابط، t بیانگر دور اجرای جاری، $\vec{A}$ و $\vec{C}$ (رابطه‌ی ۷) بردارهای ضریب برای فاصله و طعمه، $\vec{X}_P$ بردار موقعیت طعمه و $\vec{X}$ بردار نشان‌دهنده‌ی موقعیت گرگ خاکستری است.

$$\begin{cases} \vec{A} = 2 \cdot \vec{a} \cdot \vec{r}_1 - \vec{a} \\ \vec{C} = 2 \cdot \vec{r}_2 \end{cases} \quad (۷)$$

همچنین، r_1 و r_2 بردارهای تصادفی بین $[0,1]$ هستند. اعضای بردار α به صورت خطی از ۲ به صفر در مدت دورهای اجرا کاهش می‌یابند. اعضای این بردار اعداد اعشاری بین ۰ تا ۲ هستند که در اولین دور اجرا مقدار ۲ دارد. این بردار باعث می‌شود در دورهای اول از اجرای الگوریتم، الگوریتم به صورت واگرا عمل کرده و گرگ‌ها بیشتر سعی در پوشش فضای حالت مسئله داشته باشند تا بتوانند تمام طعمه‌های داخل فضای جستجو را پوشش دهند. به مرور و با رسیدن به دورهای آخر اجرای الگوریتم، با کاهش این ضریب، گرگ‌ها همگرا شده و سعی می‌کنند به بهترین تخمین از طعمه نزدیک شوند تا عمل شکار صورت پذیرد.

ج) بهینه‌سازی سیستم عصبی فازی تطبیقی (ANFIS) توسط الگوریتم ازدحام ذرات (PSO)

منطق فازی برای مدل‌سازی فرآیندهای مهندسی و حل ویژگی‌های مبهم آن‌ها پیشنهاد شده‌است. با وجود این، مشکل اصلی منطق فازی این است که روند سینماتیکی برای طراحی یک کنترل‌کننده‌ی فازی وجود ندارد. به عبارت دیگر، یک شبکه‌ی عصبی این توانایی را دارد که از محیط آموزش ببیند (جفت‌های ورودی-خروجی)، ساختارش را خود مرتب کند و با شیوه‌ای، تعامل خود را تطبیق دهد. بدین منظور، پروفیسور Jang در سال ۱۹۹۳ الگوریتم ANFIS را ارائه کرد که قابلیت ترکیب توانایی دو روش مذکور را داشت (Jang, 1993). در هر مدل‌سازی با ANFIS، پارامترهای مربوط به توابع عضویت و همچنین پارامترهای متعاقب برای متغیرهای ورودی و متغیرهای خروجی وجود دارد که در حین فرآیند

این پارامترها استفاده شد. پارامترهای C ، ε و σ سه پارامتر اصلی SVR هستند که باید در مرحله‌ی آموزش بهینه شوند و برای یافتن بهترین مقدار این پارامترها در الگوریتم SVR از الگوریتم PSO استفاده می‌شود. روابط (۴) مربوط به SVR به شرح زیر است:

$$\begin{aligned} f(x) &= \langle w, x \rangle + b \\ \text{Minimize } \phi(w, \zeta^*, \zeta) &= \frac{\|w\|^2}{2} + C(\sum \zeta_i^* + \sum \zeta_i) \\ \text{Subject to } y_i - ((w \cdot x_i + b)) &\leq \varepsilon + \zeta_i \\ ((w \cdot x_i + b)) - y_i &\leq \varepsilon + \zeta_i^* \\ \zeta_i, \zeta_i^* &\geq 0 \\ i &= 1, 2, \dots, l \end{aligned} \quad (۴)$$

در این رابطه، ε خطای مورد قبول در تابع تلفات، $\|w\|^2$ اندازه‌ی بردار وزن (مقدار آن $\sum_{i=1}^n w_i^2$ می‌باشد) و همچنین، ζ_i و ζ_i^* متغیرهای slack هستند. همچنین، برای مدل PSO از روابط (۵) مطابق زیر استفاده می‌شود:

$$\begin{aligned} \max f(x), \quad X^{(l)} &\leq X \leq X^{(u)} \\ V_j(i) &= V_j(i-1) + c_1 r_1 [P_{best,j} - X_j(i-1)] + c_2 r_2 [G_{best} - X_j(i-1)] \quad (۵) \\ X_j(i) &= X_j(i-1) + V_j(i); \quad j = 1, 2, \dots, N \end{aligned}$$

که بردار موقعیت و سرعت ذره z ام در تکرار l ام به ترتیب با $V_j(i)$ و $X_j(i)$ نمایش داده شده‌است. و همچنین C_1 و C_2 به ترتیب ضرایب یادگیری شناختی (یا فردی) و اجتماعی (یا گروهی) و r_1 و r_2 دو عدد تصادفی با توزیع یکنواخت در بازه $[0,1]$ هستند. $P_{best,j}$ و G_{best} به ترتیب بهترین مقدار تابع هدف برای ذره z ام در طول کل تکرارها و بهترین مقدار تابع هدف برای همه‌ی ذرات در تمامی تکرارها است.

ب) بهینه‌سازی رگرسیون بردار پشتیبان (SVR) توسط الگوریتم گرگ خاکستری (GWO)

علاوه بر آنچه در قسمت (الف) بیان شد، می‌توان الگوریتم SVR را برای مدل‌سازی و پیش‌بینی، توسط الگوریتم فراابتکاری GWO بهینه‌سازی نمود و مقادیر مناسب پارامترهای آن را بدست آورد. روابط (۶) و (۷) مورد استفاده در مدل GWO به صورت زیر است:

آموزش مقادیر آن‌ها تعیین می‌شود. با توجه به توانایی الگوریتم‌های بهینه‌سازی در یافتن مقادیر بهینه‌ی پارامترها، می‌توان از الگوریتم‌های بهینه‌سازی فراابتکاری برای جستجوی مقادیر مناسب این پارامترها استفاده کرد. از این‌رو، می‌توان مدل ANFIS را برای مدل‌سازی و پیش‌بینی، توسط الگوریتم فراابتکاری ازدحام ذرات PSO بهینه‌سازی نموده و مقادیر مناسب پارامترهای تطبیقی و متعاقب آن را توسط PSO بدست آورد. روابط (۸)، (۹)، (۱۰) و (۱۱) به ترتیب مربوط به لایه‌های اول تا پنجم ANFIS به شرح زیر است:

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x) \quad i=1,2 \\ O_{2,i} &= \mu_{B_i}(y) \quad i=3,4 \end{aligned} \quad (8)$$

که x و y ورودیهای غیرفازی به گره i و A_i و B_i برچسبهای زبانی هستند که به ترتیب با توابع عضویت مناسب μ_{B_i} و μ_{A_i} مشخص می‌شوند.

$$O_{2,k} = \mu_{A_i}(x) \cdot \mu_{B_i}(y) \quad (9)$$

$$O_{3,i} = \bar{W}_i = \frac{W_i}{\sum_{k=1}^4 W_k} \quad (10)$$

$$O_{4,i} = \bar{W}_i f_i = \bar{W}_i (p_i x + q_i y + r_i) \quad (11)$$

که $\bar{W}_i$ خروجی نامین گره از لایه قبلی است، p_i ، q_i و r_i ضرایب این ترکیب خطی هستند که پارامترهای متعاقب نامیده شده‌است.

$$O_{5,i} = \bar{W}_i f_i = \frac{\sum_{i=1}^4 W_i f_i}{\sum_{i=1}^4 W_i} \quad (12)$$

د) بهینه‌سازی سیستم عصبی فازی تطبیقی (ANFIS) توسط الگوریتم گرگ خاکستری (GWO)

علاوه بر آنچه در قسمت (ج) بیان شد، می‌توان الگوریتم ANFIS را برای مدل‌سازی و پیش‌بینی، توسط الگوریتم فراابتکاری GWO بهینه‌سازی نمود و مقادیر مناسب پارامترهای آن را بدست آورد.

۳- یافته‌ها


۳-۱- نتایج مدل SWARA

برای همپوشانی نقاط لغزشی با لایه‌های رقومی تولید شده از نرم‌افزار ArcMap10.5 استفاده شده‌است تا ارتباط


عوامل تاثیرگذار بر وقوع زمین‌لغزش در منطقه‌ی مورد مطالعه مشخص شود. بررسی نتایج نشان می‌دهد که برای عامل ارتفاع، کلاس ۲۰۳۴-۲۷۸۰ متر با وزن ۰,۳۰۷ بالاترین حساسیت را نسبت به وقوع زمین‌لغزش دارد. شیب ۳۵-۵۰ درجه با مقدار ۰,۴۲۴، بیشترین و شیب ۰-۵ درجه نیز با وزن ۰,۰۷۱، کمترین وابستگی را دارد. دلیل این روند کاهش نیروی ثقل در شیب‌های پایین است که احتمال ریزش دامنه را کم می‌کند. نتایج حاصل از جهت شیب نشان می‌دهد، جهات شمال شرق و جنوب به ترتیب با اوزان ۰,۴۴۶ و ۰,۲۲۹، بیشترین ارتباط را با وقوع زمین لغزش دارند. بررسی پراکندگی نقاط لغزشی برای عوامل انحنای سطح و انحنای پروفایل نشان می‌دهد کلاس مقعر برای هر دو عامل، نه تنها دارای بیشترین تعداد زمین‌لغزش است، بلکه با اوزان ۰,۴۷۷ و ۰,۴۴۴، بیشترین تاثیرپذیری را دارد. این اتفاق می‌تواند ناشی از همگرایی رواناب‌ها در شیب‌های مقعر و در نتیجه افزایش احتمال وقوع زمین لغزش باشد. نتایج کاربری اراضی منطقه‌ی مورد مطالعه نشان می‌دهد اگرچه بیشترین تعداد نقاط لغزشی در کلاس مرتع ضعیف رخ داده‌است، اما کلاس باغ با مقدار ۰,۲۲۳، بیشترین تاثیر را بر ناپایداری شیب دارد که نشان دهنده‌ی نقش انسان در تخریب اکوسیستم‌های طبیعی مانند شیب‌های ناپایدار می‌باشد. براساس نتایج حاصل از واحدهای مختلف سنگ‌شناسی، PIQC با وزن ۰,۳۰۱، بیشترین حساسیت را نسبت به خطر زمین‌لغزش دارد. نتایج به دست آمده از پهنه‌بندی میانگین بارش سالانه نیز بیانگر این است که کلاس ۲۰۹-۲۷۶ میلی‌متر با مقدار ۰,۳۰۵، بالاترین احتمال را دارد. برای عامل فاصله از جاده، فاصله ۰-۱۰۰ متر بیشترین حساسیت را دارد که با افزایش فاصله کاهش می‌یابد. ساخت‌وساز جاده در دامنه شیب‌ها موجب برهم‌زدن تعادل طبیعی شیب‌ها شده و لذا احتمال زمین‌لغزش افزایش می‌یابد. همچنین، برای تراکم جاده، کلاس ۰,۱۶۵-۰,۰۹۹، بیشترین ارتباط را با زمین لغزش‌ها دارد. نتایج فاصله از رودخانه بیانگر این است که کلاس ۱۰۰-۲۰۰ متر با وزن ۰,۴۵۲، بیشترین احتمال وقوع زمین‌لغزش را دارد. همچنین، برای تراکم رودخانه در کلاس ۰,۲۸۳-۰,۱۴۹، با مقدار ۰,۴۱۲، بیشترین تعداد زمین‌لغزش رخ داده‌است. بررسی عامل فاصله از غسل نیز مشخص می‌کند که بیشترین حساسیت زمین‌لغزش در محدوده‌ی ۶۰۰-۱۲۰۰ متر است. در همین راستا، برای

جدول ۵- زمان اجرای مدل‌ها برای محاسبه‌ی شاخص حساسیت

مدل	زمان لغزش		
	زمان آموزش (دقیقه)	زمان ارزیابی (دقیقه)	زمان اجرا (دقیقه)
SVR-PSO	۷۰	۲۰	۳۰۰
SVR-GWO	۸۲	۲۰	۳۵۰
ANFIS-PSO	۱۱۰	۳۵	۴۲۰
ANFIS-GWO	۱۲۰	۴۰	۴۸۰



شکل ۱۴- نقشه‌ی حساسیت زمین لغزش مدل SVR-PSO



شکل ۱۵- نقشه‌ی حساسیت زمین لغزش مدل SVR-GWO

تراکم گسل نیز کلاس ۰,۱۷۶-۰,۱۰ کیلومتر مربع با مقدار ۰,۳۰۹ بیشترین تاثیر را بر وقوع زمین لغزش دارد.

۲-۳- نتایج بهینه‌سازی روش‌های یادگیری ماشین ANFIS و SVR با الگوریتم‌های PSO و GWO

نتایج پیش‌بینی متغیر هدف (متغیر زمین لغزش) توسط روش‌های ترکیبی مختلف SVR+PSO، SVR+GWO، ANFIS+PSO و ANFIS+GWO در هر دو مرحله‌ی آموزش و آزمایش در جداول ۱ تا ۴ مشاهده می‌گردد.

۳-۳- تولید نقشه‌های حساسیت زمین لغزش منطقه‌ی مورد مطالعه

با توجه به نتایج آموزش و اعتبارسنجی همه پیکسل‌های منطقه وارد مدل‌ها شده و پس از محاسبه‌ی شاخص حساسیت زمین لغزش، مقادیر محاسبه‌شده از نرم افزار MATLAB وارد ArcMap شده‌است. زمان اجرای مدل‌ها برای محاسبه‌ی شاخص حساسیت زمین لغزش در جدول ۵ آورده شده‌است. سپس، نقشه‌های حساسیت زمین لغزش برای هر مدل تولید شده و با استفاده از روش quantile به ۵ کلاس با حساسیت خیلی کم، کم، متوسط، زیاد و خیلی زیاد تقسیم‌بندی شده‌اند. شکل‌های ۱۴ تا ۱۷ نقشه‌های حساسیت زمین لغزش تولیدشده و کلاس‌های حساسیت را نشان می‌دهند.

جدول ۱- نتایج بهینه‌سازی مدل SVR توسط الگوریتم PSO

مرحله	R ²	RMSE	MSE	MAE
آموزش	۰,۶۸۱	۰,۲۸۲	۰,۱۱۳	۰,۲۶۵
آزمایش	۰,۶۴۴	۰,۲۹۹	۰,۱۱۵	۰,۲۸۸

جدول ۲- نتایج بهینه‌سازی مدل SVR توسط الگوریتم GWO


مرحله	R ²	RMSE	MSE	MAE
آموزش	۰,۷۰۴	۰,۲۷۲	۰,۰۹۶	۰,۲۳۷
آزمایش	۰,۶۹۲	۰,۲۷۹	۰,۱۰۶	۰,۲۴۱

جدول ۳- نتایج بهینه‌سازی مدل ANFIS توسط الگوریتم PSO


مرحله	R ²	RMSE	MSE	MAE
آموزش	۰,۷۳۳	۰,۲۵۸	۰,۰۹۵	۰,۲۴۷
آزمایش	۰,۷۵۴	۰,۲۴۹	۰,۰۸۸	۰,۲۳۴

جدول ۴- نتایج بهینه‌سازی مدل ANFIS توسط الگوریتم GWO

مرحله	R ²	RMSE	MSE	MAE
آموزش	۰,۶۴۵	۰,۲۹۸	۰,۱۳۱	۰,۳۱۷
آزمایش	۰,۶۱۱	۰,۳۱۳	۰,۱۴۴	۰,۳۳۳



شکل ۱۶- نقشه‌ی حساسیت زمین لغزش مدل ANFIS-PSO




شکل ۱۷- نقشه‌ی حساسیت زمین لغزش مدل ANFIS-GWO

۳-۴- ارزیابی نقشه‌های حساسیت زمین لغزش با استفاده از نمودار ROC

منحنی ROC یک ابزار کمی بسیار مفید برای شناسایی احتمالی و پیش‌بینی سیستم‌ها است [۵]. این نمودار از دو محور x (نرخ مثبت اشتباه) و y (نرخ مثبت درست) تشکیل شده‌است. در این روش، دقت روش بکار رفته به سطح زیر منحنی (AUC) بستگی دارد که مقادیر سطح زیر منحنی از ۰٫۵ تا ۱ متغیر می‌باشد. هرچه قدر سطح زیر منحنی بزرگتر

باشد مقدار بدست‌آمده به ۱ نزدیک‌تر بوده و لذا دقت پیش‌بینی روش بکار رفته نیز بیشتر است. به بیان دیگر ایده‌آل‌ترین مدل بیشترین سطح زیر منحنی را دارد و مقدار ۱ بیانگر بهترین دقت می‌باشد. مقادیر ۰٫۶-۰٫۷، ۰٫۵-۰٫۶، ۰٫۸-۰٫۹، ۰٫۷-۰٫۸، ۰٫۸-۰٫۹ و ۱-۰٫۹ به ترتیب نشان‌دهنده‌ی عملکرد ضعیف، متوسط، خوب، خیلی خوب و عالی است. در این پژوهش، به منظور برآورد مقدار سطح زیر منحنی (AUC) از ۳۰٪ نقاط لغزشی و غیر-لغزشی استفاده شده است که پس از همپوشانی با نقشه‌های حساسیت زمین لغزش، وارد نرم‌افزار SPSS شد تا دقت پیش‌بینی هر نقشه مشخص شود. در شکل ۱۸ نمودار ROC برای چهار مدل بکار رفته نشان داده شده‌است. همانطور که در این شکل مشاهده می‌گردد، مقادیر سطح زیر منحنی برای مدل‌های ANFIS-GWO، ANFIS-PSO، SVR-GWO و SVR-PSO به ترتیب ۸۵٫۷، ۸۹٫۴، ۸۸٫۷ و ۸۸٫۱ درصد به دست آمده‌است. نتایج حاصل نشان می‌دهد که مدل ترکیبی ANFIS-PSO با دقت پیش‌بینی ۸۹٫۴٪ بهترین عملکرد را در مقایسه با دیگر روش‌ها دارد. بعد از آن SVR-GWO با دقت ۸۸٫۷٪ دقت بسیار خوبی در ارزیابی حساسیت دارد. روش‌های ANFIS-GWO و SVR-PSO نیز در جایگاه بعدی از این لحاظ قرار دارند.



شکل ۱۸- منحنی‌های ROC مربوط به نقشه‌های حساسیت تولیدشده

۴- بحث و نتیجه‌گیری

ریزش دامنه‌های ناپایدار یکی از حوادث طبیعی است که هر ساله خسارات مالی و تلفات جانی بر کشور تحمیل می‌کند، در این مقاله، پهنه‌بندی استان اردبیل برای مشخص کردن مناطق حساس به وقوع زمین‌لغزش انجام

مدل‌ها بهترین عملکرد را دارد؛ بعد از آن مدل-SVR-GWO دقت بیشتری از خود نشان داد، همچنین، مدل‌های ترکیبی SVR-PSO و ANFIS-GWO به ترتیب در جایگاه سوم و چهارم قرار گرفت، همچنین نتایج بدست‌آمده همسو با مطالعات انجام شده‌است که در آن مدل تصمیم‌گیری چند معیاره SWARA دقت بالایی در نشان دادن وابستگی بین زمین‌لغزش‌های رخ داده و عوامل موثر دارد. به طور کلی، با توجه به دقت روش‌های بکار رفته در این پژوهش، می‌توان آن‌ها را در دیگر مناطق حساس به وقوع زمین‌لغزش بکار برد.

شد؛ بدین منظور، در گام اول، زمین‌لغزش‌های رخ داده با عوامل موثر بر وقوع زمین‌لغزش همپوشانی شد تا ارتباط بین هر کلاس با ناپایداری دامنه‌ای برآورد شود. در گام بعدی، با استفاده از داده‌های تولید شده مدل‌های ترکیبی ANFIS-GWO، ANFIS-PSO، SVR-GWO، و SVR-PSO ایجاد شد. در مرحله آخر، نقشه‌ی حساسیت زمین‌لغزش هر مدل تولید و با استفاده از منحنی ROC ارزیابی شد. نتایج حاصل مشخص کرد هرچند همه مدل‌های بکار رفته با دقت بیش از ۸۰٪ عملکرد بسیار خوبی در پهنه‌بندی دارد، ANFIS-PSO نسبت به دیگر

مراجع

- [1] Chen, W., Panahi, M., & Pourghasemi, H. R. (2017). Performance evaluation of GIS-based new ensemble data mining techniques of adaptive neuro-fuzzy inference system (ANFIS) with genetic algorithm (GA), differential evolution (DE), and particle swarm optimization (PSO) for landslide spatial modelling. *Catena*, 157, 310-324.
- [2] Mohammadnia, M., Amirahmadi, A., & Bahrami, S. (2016). Weight of Evidence (WOE) Model Based on GIS to Evaluate Landslides Susceptibility (Case study: Jaghargh Watershed). *Geographical Researches*, 31(2), 137-151.
- [3] Saffari, A., and Raiti Shavazi, M., and Jan Ahmadi, M., and Shirzadmalairi, L. (2015). Landslide hazard zoning using the frequency model and fuzzy logic (Case study: Central part of Jam city). *Natural Geography*, 8 (30), 15-30.
- [4] Tsangaratos, P., & Ilia, I. (2016). Landslide susceptibility mapping using a modified decision tree classifier in the Xanthi Perfection, Greece. *Landslides*, 13(2), 305-320.
- [5] Pourghasemi, H. R., Pradhan, B., Gokceoglu, C., Mohammadi, M., & Moradi, H. R. (2013). Application of weights-of-evidence and certainty factor models and their comparison in landslide susceptibility mapping at Haraz watershed, Iran. *Arabian Journal of Geosciences*, 6(7), 2351-2365.
- [6] Youssef, A. M., Pradhan, B., Pourghasemi, H. R., & Abdullahi, S. (2015). Landslide susceptibility assessment at Wadi Jawrah Basin, Jizan region, Saudi Arabia using two bivariate models in GIS. *Geosciences Journal*, 19(3), 449-469.
- [7] Nourani, V., Pradhan, B., Ghaffari, H., & Sharifi, S. S. (2014). Landslide susceptibility mapping at Zonouz Plain, Iran using genetic programming and comparison with frequency ratio, logistic regression, and artificial neural network models. *Natural hazards*, 71(1), 523-547.
- [8] Regmi, A. D., Devkota, K. C., Yoshida, K., Pradhan, B., Pourghasemi, H. R., Kumamoto, T., & Akgun, A. (2014). Application of frequency ratio, statistical index, and weights-of-evidence models and their comparison in landslide susceptibility mapping in Central Nepal Himalaya. *Arabian Journal of Geosciences*, 7(2), 725-742.
- [9] Xie, Z., Chen, G., Meng, X., Zhang, Y., Qiao, L., & Tan, L. (2017). A comparative study of landslide susceptibility mapping using weight of evidence, logistic regression and support vector machine and evaluated by SBAS-InSAR monitoring: Zhouqu to Wudu segment in Bailong River Basin, China. *Environmental Earth Sciences*, 76(8), 1-19.
- [10] Mohammady, M., Pourghasemi, H. R., & 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.
- [11] Youssef, A. M., & Pourghasemi, H. R. (2021). Landslide susceptibility mapping using machine learning algorithms and comparison of their performance at Abha Basin, Asir Region, Saudi Arabia. *Geoscience Frontiers*, 12(2), 639-655.
- [12] Gomez, H., & Kavzoglu, T. (2005). Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela. *Engineering Geology*, 78(1-2), 11-27.
- [13] Pourghasemi, H. R., Jirandeh, A. G., Pradhan, B., Xu, C., & Gokceoglu, C. (2013). Landslide susceptibility mapping using support vector machine and GIS at the Golestan Province, Iran. *Journal of Earth System Science*, 122(2), 349-369.

- [14] Pradhan, B., Sezer, E. A., Gokceoglu, C., & Buchroithner, M. F. (2010). Landslide susceptibility mapping by neuro-fuzzy approach in a landslide-prone area (Cameron Highlands, Malaysia). *IEEE Transactions on Geoscience and Remote Sensing*, 48(12), 4164-4177.
- [15] Dehnavi, A., Aghdam, I. N., Pradhan, B., & Varzandeh, M. H. M. (2015). A new hybrid model using step-wise weight assessment ratio analysis (SWARA) technique and adaptive neuro-fuzzy inference system (ANFIS) for regional landslide hazard assessment in Iran. *Catena*, 135, 122-148.
- [16] Jaafari, A., Panahi, M., Pham, B. T., Shahabi, H., Bui, D. T., Rezaie, F., & Lee, S. (2019). Meta optimization of an adaptive neuro-fuzzy inference system with grey wolf optimizer and biogeography-based optimization algorithms for spatial prediction of landslide susceptibility. *Catena*, 175, 430-445.
- [17] Moayedi, H., Mehrabi, M., Mosallanezhad, M., Rashid, A. S. A., & Pradhan, B. (2019). Modification of landslide susceptibility mapping using optimized PSO-ANN technique. *Engineering with Computers*, 35(3), 967-984.
- [18] Sidle, R. C., & Ochiai, H. (2007). Landslides processes, prediction, and land use water resources monograph 18. In *Natural resources forum* (Vol. 31, pp. 322-326).
- [19] Sangchini, E. K., Emami, S. N., Tahmasebipour, N., Pourghasemi, H. R., Naghibi, S. A., Arami, S. A., & Pradhan, B. (2016). Assessment and comparison of combined bivariate and AHP models with logistic regression for landslide susceptibility mapping in the Chaharmahal-e-Bakhtiari Province, Iran. *Arabian Journal of Geosciences*, 9(3), 1-15.
- [20] Conforti, M., Pascale, S., Robustelli, G., & Sdao, F. (2014). Evaluation of prediction capability of the artificial neural networks for mapping landslide susceptibility in the Turbolo River catchment (northern Calabria, Italy). *Catena*, 113, 236-250.
- [21] Aghdam, I. N., Pradhan, B., & Panahi, M. (2017). Landslide susceptibility assessment using a novel hybrid model of statistical bivariate methods (FR and WOE) and adaptive neuro-fuzzy inference system (ANFIS) at southern Zagros Mountains in Iran. *Environmental Earth Sciences*, 76(6), 1-22.