

کاربرد شبکه عصبی مصنوعی در شناسایی مناطق مستعد لغزش به کمک نسبت فراوانی و تحلیل سلسله مراتبی در پادانای علیای سمیرم

علیرضا عرب عامری^{۱*}، خلیل رضایی^۲، محمدحسین رامشت^۳ و کورش شیرانی^۴

^۱ دانشجوی دکتری ژئومورفولوژی، دانشکده علوم انسانی، دانشگاه تربیت مدرس، ^۲ استادیار، دانشکده علوم زمین، دانشگاه خوارزمی، ^۳ استاد، دانشکده علوم انسانی، دانشگاه اصفهان و ^۴ استادیار بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان اصفهان، سازمان تحقیقات، آموزش و ترویج کشاورزی، اصفهان، ایران

تاریخ پذیرش: ۱۳۹۶/۰۳/۱۷

تاریخ دریافت: ۱۳۹۵/۰۸/۱۶

چکیده

تهیه نقشه حساسیت زمین به لغزش و ارزیابی خطر آن از مهمترین مراحل در تهیه نقشه ریسک زمین لغزش می‌باشد. در این پژوهش به تهیه نقشه حساسیت وقوع زمین لغزش در پادانای علیای سمیرم که یک منطقه حساس به زمین لغزش است، با استفاده از روش شبکه عصبی پرداخته شده است. بدین منظور، در اولین گام ۲۳ عامل موثر در لغزش در منطقه شناسایی شده، همچنین، به کمک تفسیر عکس‌های هوایی و پیمایش‌های میدانی موقعیت لغزش‌ها مشخص شد. در گام بعد با کمک نظرات کارشناسی (AHP) به غربالگری پارامترها پرداخته، در نهایت ۱۴ پارامتر برای اجرای مدل انتخاب شد. از ۱۰۳ لغزش شناسایی شده در منطقه ۷۰ درصد (۷۲ زمین لغزش) به صورت تصادفی به منظور آموزش شبکه و ۳۰ درصد (۳۱ زمین لغزش) به منظور اعتبارسنجی مورد استفاده قرار گرفت. از شبکه عصبی پرسپترون چند لایه (multilayer perceptron) با الگوریتم یادگیری پس انتشار خطا استفاده شد و تابع سیگموئید (sigmoid function) به عنوان تابع فعال‌سازی انتخاب شد. به منظور انتخاب بهترین آرایش شبکه از شاخص‌های میانگین مربعات خطا (MSE)، جذر میانگین مجذور خطا (RMSE)، بیشینه خطای مطلق (MAE) و ضریب همبستگی (R2) استفاده کرده، بهترین ساختار شبکه برای پهنه‌بندی حساسیت به زمین لغزش ۱-۴-۱۴ انتخاب شد. قبل از ورود لایه‌های اطلاعاتی به شبکه با استفاده از روش نسبت فراوانی (FR) وزن هر یک از طبقات لایه‌های اطلاعاتی محاسبه شده، بر اساس آن لایه‌ها وزن‌دهی شدند. منحنی ROC و مساحت زیر منحنی (AUC) برای نقشه پهنه‌بندی ترسیم و از AUC برای صحت‌سنجی استفاده شد. نتایج اعتبارسنجی نشان داد که مساحت زیر منحنی برای مدل ۰/۹۳۸ (۹۳/۸ درصد) است که در گروه دقت پیش‌بینی عالی قرار می‌گیرد. طبق نتایج ۲۹/۶۱ کیلومتر مربع (۹۳/۲۵ درصد) از مساحت لغزش‌ها در رده‌های خطر زیاد و خیلی زیاد قرار گرفته است.

واژه‌های کلیدی: پادانای علیای سمیرم، پرسپترون چند لایه، حساسیت زمین به لغزش، رسوب، روش نسبت فراوانی، روش AHP

مقدمه

در سال‌های اخیر، پیش‌بینی رخداد زمین لغزش به‌عنوان یک موضوع مهم و چالش برانگیز در مطالعات کاهش خطر تبدیل شده است (Dou و همکاران، ۲۰۱۴؛ Dou و همکاران، ۲۰۱۵). نقشه‌های حساسیت زمین به لغزش سطح زمین را به مناطقی از درجات مختلفی از خطر بر اساس ارزیابی پارامترهای موثر در بی‌ثباتی منطقه تقسیم می‌کند (Youssef و همکاران، ۲۰۱۵) و نقش بسیار مهمی را در کاهش خطر دارند (Dou و همکاران، ۲۰۱۵). همچنین، ارزیابی حساسیت زمین به لغزش توجه بسیاری از محققین را به خود جلب کرده است و تحقیقات مختلفی در زمینه ارزیابی حساسیت زمین به لغزش در سراسر جهان انجام شده است (Pavel و همکاران، ۲۰۱۱؛ Park و همکاران، ۲۰۱۲؛ Tien Bui و همکاران، ۲۰۱۲؛ Feizizadeh و همکاران، ۲۰۱۴). بیشتر پژوهش‌ها بر اساس ایجاد ارتباط بین عوامل موثر در زمین لغزش و رخداد زمین لغزش بر اساس تحلیل داده‌های مکانی می‌باشد. این روابط می‌تواند به‌صورت رتبه و وزن مشخص شود. روش‌های داده محور به دو گروه کمی و کیفی تقسیم می‌شود (Li و همکاران، ۲۰۱۲). با توجه به پیشرفت‌های صورت گرفته در سامانه‌های کامپیوتری و تکنیک‌های GIS، روش‌های کمی دارای کارایی بالاتری نسبت به روش‌های کیفی هستند، زیرا روش‌های کیفی فقط بر اساس ارزش‌های ذهنی می‌باشد (Sumer و Turker، ۲۰۱۳). روش‌های کمی مانند شبکه عصبی مصنوعی برای حل مسئله مفید هستند و در زمینه‌های متنوع علمی، مهندسی و ارزیابی حساسیت به‌صورت موفقیت‌آمیزی به‌کار گرفته شده است. چنین روش‌هایی نتایج رضایت‌بخش‌تری را نسبت به روش‌های آماری دیگر در زمینه ارزیابی حساسیت زمین به لغزش به‌دست آورده‌اند (Chauhan و همکاران، ۲۰۱۰؛ Li و همکاران، ۲۰۱۲؛ Conforti و همکاران، ۲۰۱۴). شبکه عصبی مصنوعی یک روش آماری غیر خطی پیچیده و انعطاف‌پذیر است و می‌تواند دقت پیش‌بینی بالایی را در طبقه‌بندی مخصوصاً با داده‌های کافی به‌دست بیاورد (Kanungo و همکاران، ۲۰۰۶). از جمله مزایای این روش نسبت به روش‌های دیگر این است که شبکه عصبی از توزیع

آماري داده‌ها مستقل است و به متغیرهای آماری مخصوصی نیاز ندارد (Caniani و همکاران، ۲۰۰۸). شبکه عصبی برای تحلیل صحت داده‌ها به بررسی کمتری نسبت به روش‌های آماری نیاز دارد (Caniani و همکاران، ۲۰۰۸) و به واسطه قابلیت منحصر به فرد شبکه‌های عصبی در تعمیم دادن عمومیت‌های حاکم در پایگاه داده در حین آموزش، از شبکه عصبی می‌توان برای تصمیم‌گیری در موارد جدید که قبلاً در اختیار شبکه قرار نگرفته استفاده کرد (Souri و همکاران، ۲۰۱۱). حوضه رودخانه ماربر در منطقه پادانای سمیرم از سرشاخه‌های کارون نمونه‌ای بارز از رخداد ضررهای مادی جبران‌ناپذیری مانند تخریب جاده‌های ارتباطی روستاها، تخریب مراتع، ایجاد فرسایش و رسوب و هرز رفتن خاک در مسیر رودخانه ماربر و غیره بر اثر زمین لغزش است و نیازمند بررسی دقیق و شناسایی مناطق حساس به زمین لغزش با روش‌های نوین و کارآمد می‌باشد. تاکنون مطالعات زیادی در زمینه کاربرد شبکه عصبی مصنوعی در پهنه‌بندی حساسیت زمین به لغزش در داخل و خارج از کشور انجام شده است. Yilmaz (۲۰۰۹) با استفاده از سه روش شبکه عصبی مصنوعی، نسبت فراوانی و رگرسیون لجستیک به پهنه‌بندی خطر زمین لغزش در منطقه کت ترکیه پرداخت و به این نتیجه رسید که شبکه عصبی دارای کارایی بالاتری نسبت به بقیه روش‌ها می‌باشد. Zare و همکاران (۲۰۱۳) به پهنه‌بندی حساسیت زمین به لغزش با استفاده از شبکه عصبی پرسپترون چند لایه و تابع پایه شعاعی در حوضه واز پرداختند و به این نتیجه رسیدند که شبکه عصبی پرسپترون چند لایه دارای دقت بالاتری می‌باشد. Dou و همکاران (۲۰۱۵) به پهنه‌بندی حساسیت زمین به لغزش در جزیره اسادو با استفاده از شبکه عصبی مصنوعی پرداختند و به این نتیجه رسیدند که شبکه عصبی دارای توانایی بالایی که پیش‌بینی مناطق حساس به لغزش می‌باشد. RÍOS و همکاران (۲۰۱۶) به ترکیب شبکه عصبی مصنوعی و روش زمین آماری در تهیه نقشه حساسیت زمین به لغزش در منطقه سالوادور پرداخته‌اند. Souri و همکاران (۲۰۱۱) به پهنه‌بندی خطر زمین لغزش با استفاده از شبکه عصبی مصنوعی در حوضه کشوری

لغزش با استفاده از فرایند تحلیل شبکه و شبکه عصبی مصنوعی در حوضه آذرشهر چای پرداخته‌اند و به این نتیجه رسیدند که شبکه عصبی مصنوعی با ضریب $0/74$ نسبت به فرایند تحلیل شبکه‌ای با ضریب $0/72$ از دقت بهتری در پیش‌بینی زمین لغزش در حوضه آذرشهر چای برخوردار است. در جدول ۱، بهترین ساختار شبکه عصبی مورد استفاده در پژوهش‌های پیشین نشان داده شده است. هدف از این پژوهش در مرحله نخست شناسایی تعداد پارامترهای مرتبط با تهیه نقشه حساسیت زمین به لغزش می‌باشد. بدین منظور، روش تحلیل سلسله مراتبی برای غربالگری پارامترها و انتخاب پارامترهای مرتبط با زمین لغزش مورد استفاده قرار گرفت. پس از انتخاب پارامترها از روش شبکه عصبی مصنوعی به همراه روش نسبت فراوانی برای پیش‌بینی حساسیت زمین به لغزش و تهیه نقشه حساسیت زمین به لغزش استفاده شد. به‌منظور صحت‌سنجی مدل از روش ROC استفاده شده است.

پرداخته‌اند. نتایج به‌دست آمده از شبکه عصبی مصنوعی نشان دهنده ساختار نهایی ۱-۱۱-۹ برای پهنه‌بندی خطر زمین لغزش در این حوضه است. بدین صورت که تعداد لایه‌های ورودی به مدل ۱۱ پارامتر موثر در لغزش، تعداد لایه‌های پنهان مدل نه لایه و خروجی مدل که تهیه نقشه حساسیت زمین به لغزش است، شامل یک لایه می‌باشد. بر اساس این پهنه‌بندی، $34/47$ درصد از حوضه در خطر خیلی زیاد قرار گرفته است. Rajabi و Feizollahpour (۲۰۱۴) در تحقیقی به پهنه‌بندی زمین لغزش‌های حوضه رودخانه گیوی چای با استفاده از مدل پرسپترون چند لایه پرداختند و به این نتیجه رسیدند که ساختار زمین‌شناسی شکل گرفته از آهک‌های کرتاسه و آندزیت‌های پرفیری و همچنین، دسترسی به منابع رطوبتی باعث شده است که ارتفاعات شرقی کوه بوغروداغ و آلاداغ در محدوده کوه‌های تالش از قابلیت بالایی در رخداد زمین لغزش برخوردار شوند. Rajabi و همکاران (۲۰۱۶) به ارزیابی و پهنه‌بندی خطر زمین


جدول ۱- بهترین شبکه عصبی مورد استفاده در پژوهش‌های پیشین

نویسندگان	تاریخ	بهترین ساختار شبکه عصبی	منبع
Souri و همکاران	۲۰۱۱	۱۱-۹-۱	Souri و همکاران (۲۰۱۱)
Feizollahpour و Rajabi	۲۰۱۴	۸-۲۰-۱	Feizollahpour و Rajabi (۲۰۱۴)
Rajabi و همکاران	۱۳۹۵	۱۵-۸-۱	Rajabi و همکاران (۲۰۱۶)
Yilmaz	۲۰۰۹	۸-۴-۱	Yilmaz (۲۰۰۹)
Zare و همکاران	۲۰۱۳	۹-۴-۲	Zare و همکاران (۲۰۱۳)
Park و همکاران	۲۰۱۳	۱۳-۲۵-۱	Park و همکاران (۲۰۱۳)
Pascale و همکاران	۲۰۱۳	۷-۱۵-۱	Pascale و همکاران (۲۰۱۳)
Wu و Liu	۲۰۱۶	۱۲-۴-۱	Wu و Liu (۲۰۱۶)
Saro و همکاران	۲۰۱۶	۱۵-۴-۱	Saro و همکاران (۲۰۱۶)
RÍOS و همکاران	۲۰۱۶	۱۹-۴-۱	RÍOS و همکاران (۲۰۱۶)

مواد و روش‌ها

جنوبی‌ترین قسمت استان اصفهان و تقریباً شمال استان فارس قرار می‌گیرد. عمده منطقه مورد پژوهش را کوهستان‌های با دیواره بلند و دره‌های ژرف تشکیل داده است و تنها در قسمت مرکزی حوضه مورفولوژی نسبتاً هموار و تپه‌ماهوری به همراه دشت نسبتاً وسیعی بین روستای دشتبال و کیفته گسترش دارد.

منطقه مورد پژوهش: حوضه رودخانه ماربر در حد فاصل $31^{\circ} 3' 20''$ تا $30^{\circ} 41' 48''$ عرض شمالی و $51^{\circ} 23' 18''$ تا $51^{\circ} 52' 54''$ طول شرقی واقع شده است (شکل ۱). وسعت حوضه ماربر حدود $552/9$ کیلومتر مربع می‌باشد و در 55 کیلومتری جنوب شهر سمیرم قرار دارد. این حوضه در



شکل ۱- منطقه مورد مطالعه

شرکت ملی نفت ایران)، نقشه‌های زمین‌شناسی (۱:۱۰۰۰۰۰ برگ‌های سمیرم، دنا، سی‌سخت، و یاسوج و لایه رقومی زمین‌شناسی کل ایران تهیه شده به‌وسیله پایگاه علوم زمین تهیه شد. نقشه شیب حوضه با استفاده از DEM منطقه در نرم‌افزار Arc GIS 10.1 و با استفاده از ابزار Spatial Analyst به‌دست آمد. نقشه جهت شیب نیز با استفاده از DEM منطقه در نرم‌افزار Arc GIS 10.1 و با استفاده از ابزار Surface Analysis-Aspect، گزینه Spatial Analyst، برای بررسی پارامترهای مربوط به بارندگی از دوره آماری ۳۰ ساله استفاده شد (از سال ۱۳۶۰ تا ۱۳۹۰) و با توجه به رابطه همبستگی بین ایستگاه‌ها به تکمیل و بازسازی آمار در موارد مربوط به نقصان آمار در ایستگاه‌های مورد نظر اقدام شد. با استفاده از ارقام میانگین سالانه بارندگی و ارتفاع ایستگاه‌های منطقه متوسط بارندگی در کل منطقه محاسبه شد، و نقشه هم‌بارش حوضه ماربر در نرم‌افزار Surfer تهیه شد. نقشه کاربری اراضی منطقه ابتدا با استفاده از نقشه‌های توپوگرافی ۱:۵۰۰۰۰ و سپس با انجام مشاهدات میدانی و استفاده از اطلاعات موجود در مرکز تحقیقات و منابع طبیعی اصفهان تهیه و لایه‌های رقومی آن‌ها برای تحلیل‌های بعدی در محیط GIS تهیه شد. نقشه‌های فاصله مناطق لغزشی از جاده

روش پژوهش: نقشه‌های پایه مورد استفاده در این پژوهش عبارتند از نقشه زمین‌شناسی در مقیاس‌های ۱:۱۰۰۰۰۰ و ۱:۲۵۰۰۰۰، نقشه کاربری اراضی از سازمان تحقیقات کشاورزی استان اصفهان در مقیاس ۱:۱۰۰۰۰۰، عکس‌های هوایی در مقیاس ۱:۴۰۰۰۰، نقشه توپوگرافی با مقیاس ۱:۵۰۰۰۰ و تصاویر ماهواره‌ای ETM⁺. در این پژوهش ابتدا بر اساس تفسیر نقشه‌های توپوگرافی، زمین‌شناسی، تصاویر ماهواره‌ای، عکس‌های هوایی و نیز مطالعات کتابخانه‌ای و پیمایشات میدانی، ۲۳ عامل موثر در رخداد زمین لغزش شناسایی شد و با استفاده از نظر کارشناسی (AHP) به غربالگری پارامترها پرداخته شد و در نهایت ۱۴ پارامتر برای استفاده در مدل انتخاب شد (شکل ۲) که شامل پارامترهای ژئومورفولوژیک (ارتفاع، شیب، جهت شیب، انحنای سطح، انحنای مقطع)، پارامترهای هیدرولوژیک (بارندگی، فاصله از آبراهه، SP، TWI)، پارامترهای زمین‌شناسی (لیتولوژی، فاصله از گسل) و پارامترهای محیطی (فاصله از جاده، کاربری اراضی، NDVI) می‌باشد. نقشه زمین‌شناسی و گسل‌های منطقه بر اساس بررسی عکس‌های هوایی ۱:۴۰۰۰۰ سازمان نقشه‌برداری کشور، نقشه‌های زمین‌شناسی ۱:۲۵۰۰۰۰ چهار گوش گچساران-بهبهان و چهارگوش بروجن

درصد از داده‌ها به صورت تصادفی به سه دسته ۶۵ درصدی (آموزش شبکه)، ۱۰ درصدی (سنجش دقت) و ۲۵ درصد (تست شبکه) تقسیم شدند. به منظور دستیابی به اهداف مورد نظر از شبکه‌های عصبی با ساختارهای مختلف سعی شد تا بهترین و کاراترین شبکه با کمترین میزان خطا انتخاب و مورد استفاده قرار گیرد. قبل از وارد کردن داده‌ها به شبکه، داده‌ها استاندارد شد. برای تجزیه و تحلیل داده‌ها از نرم‌افزار SPSS نسخه ۱۶ و نرم‌افزار مطلب استفاده شده است و در نهایت نقشه پهنه‌بندی حساسیت زمین به لغزش با روش شبکه عصبی مصنوعی تهیه شد. مراحل پژوهش در شکل ۳ نشان داده شده است.

روش تحلیل سلسله مراتبی (AHP): یکی از پرکاربردترین و مشهورترین تکنیک‌های تصمیم‌گیری چند شاخصه، روش AHP است که به وسیله ساعتی در سال ۱۹۸۰ ارائه شد و اجزای یک سامانه را به صورت سلسله مراتبی سازماندهی می‌کند. این تکنیک، بر پایه مقایسات زوجی معیارها به وسیله افراد خبره با به کارگیری مقایسات نه‌گانه است، سپس با به کارگیری خروجی این مرحله، یک یا تعداد بیشتری ماتریس مقایسات زوجی تشکیل می‌شود که برای وزن‌دهی و رتبه‌بندی مورد استفاده قرار می‌گیرد. از جمله مزایای این تکنیک قابلیت در نظر گرفتن معیارهای کیفی در فرایند ارزیابی، برخورداری از الگوریتم تعیین وزن معیارها و سادگی نسبی و معیاری از جمله محدودیت امکان استفاده از تعداد معیارهای زیاد، وارونی رتبه، دشواری فرایند مقایسات زوجی و وقوع ناسازگاری بین قضاوت‌ها را برشمرد (Junior و همکاران، ۲۰۱۴؛ Oikonomidis و همکاران، ۲۰۱۵). مراحل فرایند تحلیل سلسله مراتبی به شرح ذیل می‌باشد.

۱- تشکیل ساختار سلسله مراتبی از مسئله، ۲- تشکیل ماتریس‌های مقایسات زوجی در اندازه $(n \times n)$ برای مسئله به کمک مقیاس‌های سنجش نسبی، ۳- محاسبه وزن نسبی هر یک از پارامترها با استفاده از روش میانگین حسابی و ۴- تعیین سازگاری ماتریس‌ها.

و فاصله از شبکه زه‌کشی با طبقه‌بندی فواصل معین از شبکه جاده و شبکه هیدروگرافی رقومی شده از نقشه توپوگرافی منطقه تهیه شد. پس از تصحیحات لازم و زمین مرجع کردن تصویر TM سال ۲۰۰۶، مقدار NDVI محاسبه شد که به عنوان شاخصی برای وجود گیاهان در آبراه‌ها از آن استفاده شد. برای تهیه نقشه طبقات ارتفاعی از DEM منطقه استفاده شد. شاخص-های انحنا سطح، انحنا مقطع، توان حمل رسوب آبراهه (SPI) و شاخص خیزی توپوگرافی (TWI) با استفاده از مدل رقومی ارتفاعی منطقه با قدرت تفکیک 10×10 متر، از طریق روابط (۱) تا (۴) در محیط نرم‌افزار SAGA.GIS 2.1.1 استخراج شد (Shary و همکاران، ۲۰۰۲).

$$Plan\ Curvature = - \frac{q^2 \times r - 2 \times p \times q \times s + p^2 \times t}{(\sqrt{1 + p^2 + q^2})^3} \quad (1)$$

$$Profile\ Curvature = - \frac{q^2 \times r + 2 \times p \times q \times s + q^2 \times t}{(p^2 + q^2) \times (\sqrt{1 + p^2 + q^2})^3} \quad (2)$$

$$SPI = A_s \times \tan \sigma \quad (3)$$

$$TWI = \ln(A_s / \tan \beta) \quad (4)$$

که در آن، d ، p ، q ، r ، s و t ضرایبی هستند که در نرم‌افزار مورد استفاده قرار می‌گیرند. نحوه محاسبه آن‌ها در قالب روابط (۵) تا (۹) نشان داده شده است.

$$p = \frac{Z_3 + Z_6 + Z_9 - Z_1 - Z_4 - Z_7}{6 \times \Delta_s^2} \quad (5)$$

$$q = \frac{Z_1 + Z_2 + Z_3 - Z_7 - Z_8 - Z_9}{6 \times \Delta_s^2} \quad (6)$$

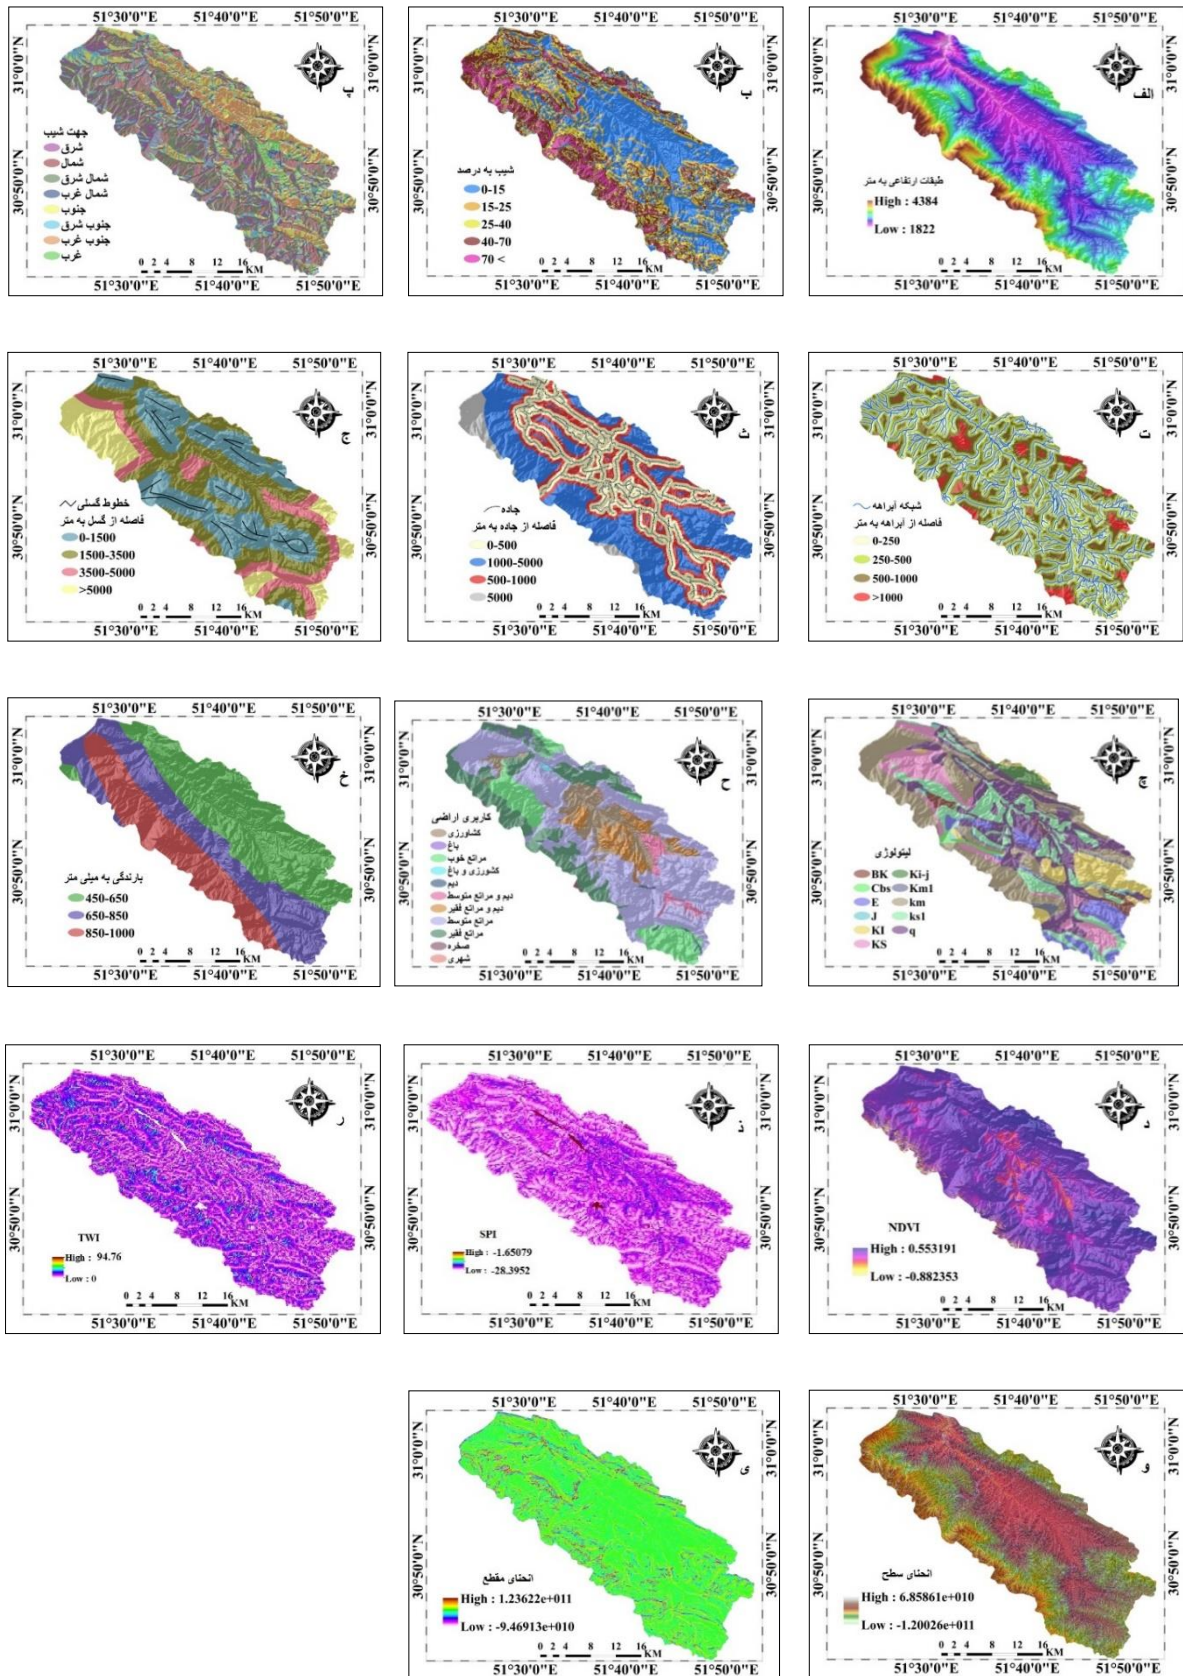
$$r = \frac{Z_1 + Z_3 + Z_4 + Z_6 + Z_7 + Z_9 - 2 \times (Z_2 + Z_5 + Z_8)}{3 \times \Delta_s^2} \quad (7)$$

$$s = \frac{-Z_1 + Z_3 + Z_7 - Z_9}{4 \times \Delta_s^2} \quad (8)$$

$$t = \frac{Z_1 + Z_2 + Z_3 + Z_7 + Z_8 + Z_9 - 2 \times (Z_4 + Z_5 + Z_6)}{3 \times \Delta_s^2} \quad (9)$$

که در آن‌ها، AS مساحت حوزه آبخیز و β گرادیان شیب (درجه) می‌باشد. پارامترهای $Z1$ تا $Z9$ مقادیر ارتفاع در شبکه سلولی 3×3 می‌باشد.

پس از انتخاب و استخراج پارامترها به اجرای مدل شبکه عصبی پرداخته شد (شکل ۳). به منظور طراحی شبکه در این پژوهش از ۱۴ پارامتر موثر در لغزش که با روش AHP انتخاب شد، به عنوان ورودی شبکه استفاده شد. همچنین، از الگوریتم پرسپترون چند لایه استفاده شد. برای آموزش شبکه ابتدا ۷۰



شکل ۲- عوامل موثر در رخداد زمین لغزش، الف) طبقات ارتفاعی، ب) شیب، پ) جهت شیب، ت) فاصله از آبراهه، ث) فاصله از جاده، ج) فاصله از گسل، چ) لیتولوژی، ح) کاربری اراضی، خ) بارندگی، د) NDVI، ذ) SPI، ر) TWI، و) انحنای سطح و ی) انحنای مقطع

جدول ۲- مقادیر شاخص ناسازگاری

اندازه ماتریس	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲
RI	۰/۵۸	۰/۹۰	۱/۱۲	۱/۲۴	۱/۳۲	۱/۴۱	۱/۴۵	۱/۴۹	۱/۵۲	۱/۵۴

در صورتی که مقدار CR از ۰/۱ کمتر باشد، قابل قبول و در صورت بیشتر بودن مقدار آن، ماتریس قضاوت ناسازگار خواهد بود.

روش نسبت فراوانی: نسبت فراوانی ارتباط کمی میان رخداد زمین لغزشها و متغیرهای مختلف تاثیرگذار در آن را مشخص می‌نماید. در تعیین نرخ نسبت فراوانی، نسبت رخداد لغزش در هر طبقه از عوامل تاثیرگذار نسبت به کل لغزشها به دست آمده و نسبت سطح هر طبقه نسبت به کل مساحت منطقه نیز محاسبه می‌شود. در نهایت با تقسیم نرخ رخداد لغزشها در هر طبقه بر نرخ مساحت هر طبقه نسبت به کل منطقه مورد مطالعه، نسبت فراوانی طبقات هر عامل محاسبه می‌شود. مراحل محاسبه نسبت فراوانی برای هر طبقه از عوامل موثر در لغزش در رابطه (۱۳) بیان شده است (Soleimani و همکاران، ۲۰۱۴).

$$FR = \frac{(A/B)}{(C/D)} = \frac{E}{F} \quad (13)$$

که در آن، A تعداد پیکسل‌های لغزش یافته در هر طبقه، B مجموع پیکسل‌های لغزشی کل حوضه، C تعداد پیکسل‌های هر زیر طبقه از عوامل موثر در لغزش، D تعداد کل پیکسل‌های یک منطقه، E درصد رخداد لغزش در هر زیر طبقه از عوامل موثر و F درصد نسبی مساحت هر زیر طبقه از کل مساحت می‌باشد. برای به دست آوردن شاخص حساسیت به رخداد زمین لغزش نتایج عوامل در محیط GIS با یکدیگر جمع می‌شود (رابطه ۱۴) (Pradhan و Lee، ۲۰۰۷).

$$LSI = \sum (FR)_i \quad (i = 1, 2, \dots, n) \quad (14)$$

که در آن، LSI شاخص پتانسیل رخداد زمین لغزش، FR نسبت فراوانی عوامل و n مجموع عوامل ورودی است.

شبکه عصبی پرسپترون چند لایه: شبکه عصبی، سامانه پردازش اطلاعاتی است که از تعداد زیادی از عنصرهای پردازش ساده‌تر که به مثابه عصب‌های مصنوعی شناخته می‌شوند، تشکیل یافته است. هر

شبکه عصبی از تعدادی گره که همان نورون‌ها هستند و وزن‌های ارتباطی که گره‌ها را به هم وصل می‌کنند، تشکیل شده است (Simpson، ۱۹۹۰). داده‌های ورودی در وزن متناظرشان ضرب می‌شوند و مجموع آن‌ها به نورون‌ها وارد می‌شود. هر نورون دارای یک تابع فعال‌سازی است. این مقدار ورودی از تابع فعال‌سازی عبور می‌کند و مقدار خروجی نورون را مشخص می‌سازد. تعداد نورون‌ها و لایه‌های شبکه عصبی متناسب با مسئله مورد نظر و با روش سعی و خطا به دست می‌آید. یکی از ساده‌ترین و در عین حال کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی عصب‌های واقعی مدل پرسپترون چند لایه است که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل یافته است (Haykin، ۱۹۹۴). در این ساختار، همه نورون‌های یک لایه به همه نورون‌های لایه بعد متصل‌اند. این چیدمان در اصطلاح یک شبکه با اتصال‌های کامل را تشکیل می‌دهد. هر نورون در لایه ورودی بر اساس تابع زیر پردازش را بر روی پارامترهای ورودی شبکه عصبی عملی می‌سازد (Leandro، ۲۰۰۷).

$$y_k = \varphi \left[\sum_{k=1}^1 W_k \varphi \left[\sum_{i=1}^m (X_i \times W_{ki}) + b_k \right] + W_0 \right] \quad (15)$$

که در آن، y_k نورون خروجی، φ تابع فعال‌سازی نورون، m تعداد پارامترهای ورودی شبکه، X_i نشان دهنده پارامتر نام ورودی، W_{ki} وزن هر نورون و b_k اریبی پارامترهای ورودی است. تابع فعال‌سازی را می‌توان به صورت تابع سیگموئید تعریف کرد (Leandro، ۲۰۰۷).

$$\varphi(x) = \frac{1}{1 + e^{-x}} \quad (16)$$

مهمترین مسئله در شبکه‌های عصبی مصنوعی چند لایه تعداد نورون‌های لایه‌های مختلف است. در لایه‌های ورودی و خروجی تعداد نورون‌ها بر اساس تعداد پارامترهای ورودی و خروجی و در لایه پنهان بر اساس سعی و خطا و نیز در نظر گرفتن مقدار خطای ایجاد شده در پارامترهای خروجی به دست می‌آید.

پارامترهای میانگین مربعات خطا^۱ (MSE)، جذر میانگین مجذور خطا^۲ (RMSE)، بیشینه خطای مطلق^۳ (MAE) و ضریب همبستگی^۴ (R²) مطابق با روابط زیر است (Cander, ۱۹۹۸).

$$MSE = \frac{1}{N} \sum (P_i - O_i)^2 \quad (۱۷)$$

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \right]^{1/2} \quad (۱۸)$$

$$MAE = \frac{1}{N} \sum |P_i - O_i| \quad (۱۹)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N [O_i - P_i]^2}{\sum_{i=1}^N [O_i - \bar{O}]^2} \quad (۲۰)$$

که در آن، N شمار داده‌ها، O_i داده‌های اصلی، P_i مقادیر پیش‌بینی و \bar{O} میانگین داده‌های اصلی می‌باشد.

نتایج و بحث

اجرای روش تحلیل سلسله مراتبی: در این پژوهش ابتدا با استفاده از نقشه‌های توپوگرافی، زمین‌شناسی، عکس‌های هوایی، تصاویر ماهواره‌ای و ویژگی‌های منطقه مطالعاتی تعداد ۲۳ عامل موثر در زمین لغزش در منطقه مطالعاتی شناسایی شد و سپس با استفاده از روش تحلیل سلسله مراتبی به غربالگری پارامترها پرداخته شد و تعداد ۱۴ پارامتر شامل لایه‌های طبقات ارتفاعی، شیب، جهت شیب، انحنای سطح، انحنای مقطع، لیتولوژی، فاصله از گسل، فاصله از جاده، کاربری اراضی، NDVI، SPI، TWI، بارندگی و فاصله از آبراهه در وقوع زمین لغزش‌های منطقه موثر شناخته شد. به‌منظور رتبه‌بندی پارامترها با استفاده از روش تحلیل سلسله مراتبی در ابتدا پرسشنامه تهیه شد و برای وزن‌دهی در خدمت خبرگان و متخصصان قرار گرفت. بدین منظور از نظر ۱۵ ژئومورفولوژیست استفاده شد. پس از پرسیدن پرسشنامه‌ها به‌وسیله متخصصان، میزان ناسازگاری برای هر یک از پرسشنامه‌ها محاسبه شد و آن‌هایی که میزان ناسازگاری بالاتر از ۰/۱ داشتند دوباره برای وزن‌دهی در خدمت خبرگان قرار گرفت و در نهایت از تلفیق وزن‌های به‌دست آمده از هر یک از پرسشنامه‌ها، وزن نهایی هر یک از عوامل محاسبه شد

الگوریتم پس انتشار خطا: این الگوریتم که در سال ۱۹۸۶ روملهارت و مک کلیلاند پیشنهاد کردند، در شبکه عصبی پیش‌سو مورد استفاده قرار می‌گیرد. پیش‌سو بودن بدین معناست که نورون‌های مصنوعی در لایه‌های متوالی قرار گرفته‌اند و خروجی خود را رو به جلو می‌فرستند. واژه پس انتشار نیز به معنای این است که خطاها به سمت عقب در شبکه تغذیه می‌شوند تا وزن‌ها را اصلاح کنند و پس از آن مجدداً ورودی مسیر پیش‌سوی خود تا خروجی را تکرار می‌کند (Mars و همکاران، ۱۹۹۶). روش پس انتشار خطا از روش‌های باسرپرست است بدین معنا که نمونه‌های ورودی برچسب خورده‌اند و خروجی مورد انتظار هر یک از آن‌ها از پیش مشخص است (Svozil و همکاران، ۱۹۹۷). لذا خروجی شبکه با این خروجی‌های ایده‌آل مقایسه و خطای شبکه محاسبه می‌شود. در این الگوریتم ابتدا فرض بر این است که وزن‌های شبکه تصادفی انتخاب شده‌اند. در هر گام خروجی شبکه محاسبه می‌شود و بر حسب میزان اختلاف آن با خروجی مطلوب، وزن‌ها تصحیح می‌شوند تا در نهایت این خطا کمینه شود. در این الگوریتم پارامترهای شبکه طوری تنظیم می‌شوند که پاسخ واقعی شبکه هر چه بیشتر به سمت پاسخ مطلوب نزدیک‌تر شود. استفاده از خروجی‌های واقعی در این شبکه‌ها سبب شده است تا این شبکه‌ها در گروه آموزش با ناظر قرار گیرند.

انتخاب بهترین آرایش شبکه: اساس آموزش شبکه‌های عصبی بر اساس آزمون و خطا می‌باشد تا بهترین آرایش شبکه با تغییر تعداد لایه‌های پنهان و نرون‌های آن‌ها، تابع فعالیت، الگوریتم آموزش و تعداد تکرار در مرحله آموزش برای برآورد پارامتر خروجی مورد نظر ارائه شود. در شبکه‌های عصبی به‌منظور به‌دست آوردن ساختار بهینه شبکه داده‌های ورودی را به سه دسته تقسیم می‌کنند که شامل مجموعه آموزش، مجموعه آزمون و مجموعه ارزیابی می‌باشد. مجموعه آموزش صرفاً به‌منظور آموزش شبکه و تعیین وزن نورون‌ها به کار می‌رود. مبنای تصمیم‌گیری برای انتخاب بهترین شبکه در هر بار اجرای برنامه،

¹ Mean Squared Error (MSE)


² Root Mean Square Error (RMSE)

³ Mean Absolute Error (MAE)

⁴ random error

(شکل ۴). نتایج نشان داد که پارامترهای کاربری اراضی، زمین‌شناسی، فاصله از جاده و جهت شیب به ترتیب با کسب امتیازات (۰/۱۴۶، ۰/۱۱۴، ۰/۱۰۷، ۰/۰۹۹) بیشترین تاثیر را در وقوع زمین لغزش در منطقه مطالعاتی داشته‌اند که با نتایج Ercanoglu و Candan (۲۰۰۴) و Ayalew و همکاران (۲۰۰۵) که کاربری اراضی را یک عامل مهم در وقوع زمین لغزش می‌دانند و با نتایج Yamagishi و Ayalew (۲۰۰۶)، Kamp و همکاران (۲۰۰۸) و Tilahun و Tarun

Kumar (۲۰۱۶) که عامل فاصله از جاده را در وقوع زمین لغزش موثر می‌دانند و همچنین، با نتایج Gokceoglu و همکاران (۲۰۰۵)، Lee و Pradhan (۲۰۰۷)، Akgun (۲۰۰۸)، Nefeslioglu و همکاران (۲۰۱۰)، Constantin و همکاران (۲۰۱۱) و Chenkual و همکاران (۲۰۱۶) که عوامل لیتولوژی و جهت شیب را در وقوع زمین لغزش موثر می‌دانند، مطابقت دارد.



شکل ۴- رتبه‌بندی پارامترها با روش AHP

های ورودی تعیین می‌کند. در رابطه با نورون‌های لایه میانی مبنای خاصی وجود ندارد و معمولاً با سعی و خطا به نحوی انتخاب می‌شود که شبکه جواب معقولی در اختیار بگذارد. خروجی شبکه نیز شامل یک نورون می‌باشد. به منظور انتخاب بهترین ساختار شبکه عصبی، شبکه‌های عصبی متعدد ایجاد شد که در تعداد تکرار، تعداد نرون‌های موجود در لایه ورودی و ضریب یادگیری متفاوت بودند. در شبیه‌سازی‌های صورت گرفته از شاخص‌های میانگین مربعات خطا (MSE)، جذر میانگین مجذور خطا (RMSE)، حداکثر

اجرای شبکه عصبی مصنوعی: به منظور شبیه‌سازی یک مسئله با استفاده از شبکه‌های عصبی اولین قدم انتخاب نوع و ابعاد شبکه است. در این پژوهش از شبکه عصبی مصنوعی با ساختار پرسپترون چند لایه به دلیل کارایی بالاتر نسبت به دیگر انواع شبکه‌های عصبی مصنوعی استفاده شد. در این ساختار انتخاب تعداد لایه‌ها محدود به سه لایه می‌شود که شامل لایه ورودی، لایه پنهان و لایه خروجی می‌باشد. در لایه ورودی باید به تعداد بعدهای هر لایه ورودی نورون قرار داده شود، بنابراین اندازه لایه ورودی را بعد لایه-

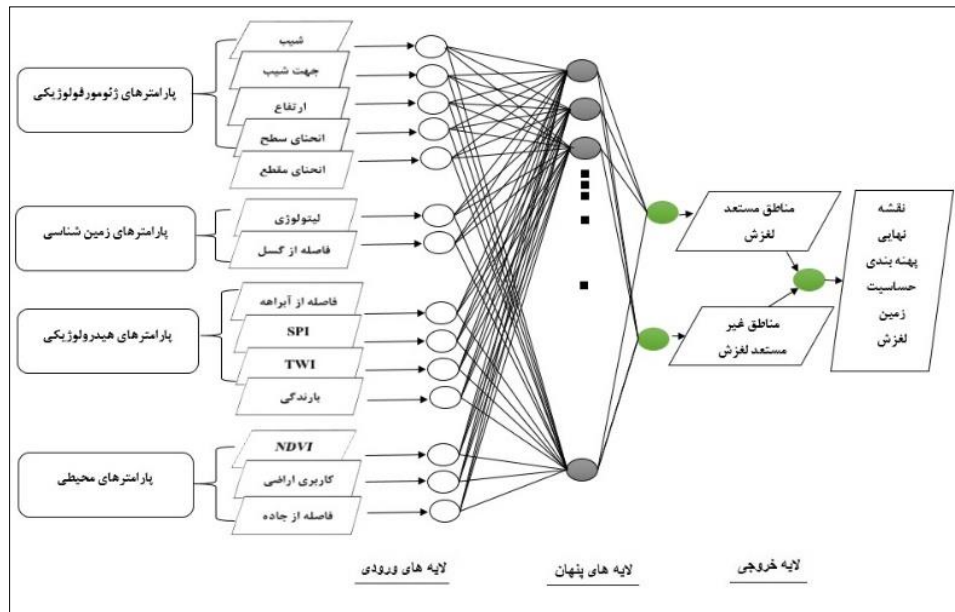
به زیاد کدبندی شدند. وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود، برای اجتناب از چنین شرایطی و همچنین، یکسان نمودن ارزش داده‌ها، قبل از انجام تجزیه و تحلیل، داده‌های ورودی به آن بایستی استاندارد شوند. این کار مانع از کوچک شدن بیش از حد وزن‌ها می‌شود (Sajikumara و Thandaveswra، ۱۹۹۹) برای نرمال-سازی داده‌ها از رابطه زیر استفاده شد.

$$X_i = \frac{Z_i - Z_i(\min)}{Z_i(\max) - Z_i(\min)} \quad (21)$$

که در آن، Z_i وزن هر پیکسل، $Z_i(\max)$ برابر با کمترین وزن عامل مورد نظر، $Z_i(\max)$ برابر با بیشترین وزن عامل مورد نظر و X_i برابر با وزن نرمال شده می‌باشد. پس از ورود داده‌ها به شبکه عصبی مصنوعی به منظور آموزش بهتر و سریعتر، همه وزن‌ها به صورت تصادفی بین -0.7 تا 0.7 وزن‌دهی شدند و سپس در مرحله آموزش هر عامل دارای وزن جدیدی می‌شود که این وزن‌ها برای پیش‌بینی میزان خطر در دیگر پیکسل‌ها استفاده می‌شود. در این پژوهش برای آموزش و آزمایش شبکه از اطلاعات ۱۴۴ پیکسل لغزشی و غیر لغزشی (۷۰ درصد زمین لغزش‌ها) استفاده شد که از این تعداد ۹۳ پیکسل (۶۵ درصد) برای آموزش، ۳۶ پیکسل (۲۵ درصد) برای آزمایش شبکه و ۱۵ پیکسل برای سنجش دقت به کار گرفته شد. مطلبی که در کار با شبکه عصبی از اهمیت بالایی برخوردار است، جلوگیری از یادگیری بیش از حد شبکه است، زیرا در این حالت شبکه به جای یادگیری و درک روابط بین پارامترها شروع به از برکردن اطلاعات می‌کند که در اختیار آن گذاشته می‌شود (Gomez و همکاران، ۲۰۰۲). برای جلوگیری از این خطا بایستی در تکرارهای مشخصی شبکه را با اطلاعات دیگری مورد آزمایش قرار داد. در اینجا بایستی با کاهش میزان خطا در مرحله آموزش، میزان خطا در مرحله آزمایش نیز کاهش یابد. بعد از انتخاب داده‌های آموزشی و آزمایشی برای قرار دادن خروجی هر نرون در دامنه صفر تا یک از تابع فعال‌ساز استفاده شده است.

خطای مطلق (MAE) و ضریب همبستگی (R^2) به عنوان راهنما استفاده شد. تعداد لایه‌ها برای آزمایش شبکه از دست کم سه لایه ورودی شروع شده، مشاهده شد که با افزایش تعداد لایه‌های ورودی تا ۱۴ لایه مقادیر پارامترهای کنترلی بهینه شدند و از لایه ۱۵ به بعد مقادیر خطا افزایش یافت. تعداد لایه‌های میانی نیز بر اساس سعی و خطا و بر اساس شاخص R^2 تعیین شد (شکل ۸). در نهایت ساختار ۱-۴-۱۴ مناسب تشخیص داده شد و پهنه‌بندی حساسیت زمین به لغزش بر اساس این ساختار انجام پذیرفت (جدول ۳). ساختار شبکه عصبی مورد استفاده در این پژوهش در شکل ۵ نشان داده شده است.


گام بعدی در شبیه‌سازی، انتخاب نوع تابع خروجی نورون است. در این پژوهش که شبکه چند لایه با الگوریتم پس‌انتشار خطا استفاده شده است، از تابع سیگموئید استفاده شده است. علت این امر مشتق-گیری ساده و ارتباط مستقیم مشتق تابع با خود تابع است. در شبکه عصبی به منظور استفاده از عوامل موثر در زمین لغزش باید خصوصیات آن‌ها مشخص شود. بدین منظور باید هر نقشه عامل موثر به پیکسل‌هایی به اندازه‌های مشخص تقسیم شود. در این پژوهش اندازه هر پیکسل 100×100 متر تعیین شد و منطقه مطالعاتی به ۸۰ هزار پیکسل تقسیم شد که در ۱۰۳ پیکسل آن لغزش رخ داده است. هر پیکسل از هر نقشه حاوی ۱۴ لایه اطلاعاتی است که این اطلاعات در پهنه‌بندی حساسیت زمین به لغزش مورد استفاده قرار گرفته است. بعد از انتخاب عوامل و تهیه نقشه‌های رقومی شده آن‌ها نقشه پراکنش زمین لغزش‌ها و نقشه مناطق غیر لغزشی که احتمال خطر لغزش در آن خیلی کم در نظر گرفته می‌شود، برای تحلیل در شبکه عصبی به کار گرفته شد. برای تعیین شاخص حساسیت زمین به لغزش هر یک از طبقات از مدل احتمالاتی نسبت فراوانی استفاده شد. بدین منظور ابتدا نسبت فراوانی محاسبه و در نهایت شاخص حساسیت به زمین لغزش محاسبه شد و سپس داده‌ها بر اساس نسبت فراوانی در نرم‌افزار MATLAB از کم




شکل ۵- ساختار شبکه عصبی

جدول ۳- مقادیر برازش خط رگرسیون و عملکرد شبکه با لایه های مختلف

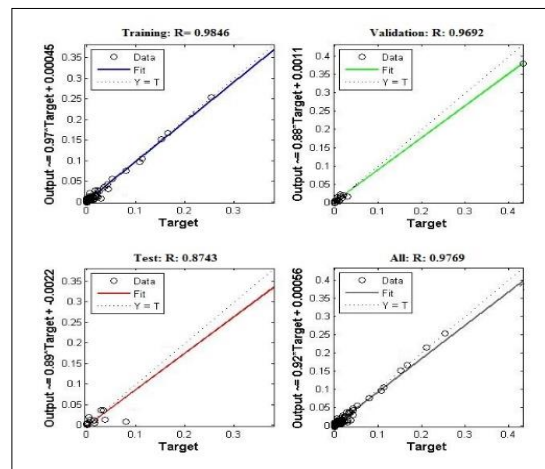
شماره شبکه	ساختار شبکه	مقادیر برازش خط رگرسیون					عملکرد شبکه			
		آموزشی	اعتبار سنجی	آزمایشی	R ²	RMSE	MAE	MSE	شماره بهترین تکرار	شماره توقف تکرار
ANN1	۴-۳-۱	۰/۸۳۱	۰/۸۴۵	۰/۷۶۵	۰/۸۵۱	۰/۷۶۱	۰/۵۴۳	۰/۱۲۳۶	۳	۳
ANN2	۴-۴-۱	۰/۸۴۵	۰/۸۶۰	۰/۸۷۷۱	۰/۸۷۹	۰/۷۸۲	۰/۳۲۵	۰/۱۲۱۱	۳	۴
ANN3	۴-۵-۱	۰/۸۷۱	۰/۸۶۲	۰/۷۳۶	۰/۸۵۲	۰/۷۶۱	۰/۸۷۲	۰/۱۱۵۶	۵	۵
ANN4	۴-۶-۱	۰/۹۱۲	۰/۹۱۰	۰/۷۴۶	۰/۹۳۷	۰/۸۱۱	۱/۱۲	۰/۰۹۷۱	۴	۵
ANN5	۴-۷-۱	۰/۹۲۰	۰/۹۱۳	۰/۷۷۱	۰/۹۶۴	۰/۸۷۱	۲/۴۲	۰/۰۸۳۴	۵	۶
ANN6	۴-۸-۱	۰/۹۳۵	۰/۹۲۲	۰/۷۸۶	۰/۹۷۱	۰/۸۹۳	۰/۹۸۱	۰/۰۸۸۹	۷	۷
ANN7	۴-۹-۱	۰/۹۳۸	۰/۹۳۳	۰/۷۸۲	۰/۹۷۷	۰/۸۸۰	۰/۷۶۱	۰/۰۶۲۱	۷	۹
ANN8	۴-۱۰-۱	۰/۹۴۲	۰/۹۳۸	۰/۷۹۳	۰/۹۸۱	۰/۸۸۴	۱/۶۳	۰/۰۴۵۴	۹	۹
ANN9	۴-۱۱-۱	۰/۹۴۸	۰/۹۴۳	۰/۸۰۸	۰/۹۸۳	۰/۸۸۷	۰/۶۳۲	۰/۰۴۱۱	۵	۱۰
ANN10	۴-۱۲-۱	۰/۹۵۳	۰/۹۵۶	۰/۸۲۱	۰/۹۸۷	۰/۸۸۱	۰/۸۷۱	۰/۰۴۳۲	۶	۹
ANN11	۴-۱۳-۱	۰/۹۵۸	۰/۹۶۳	۰/۸۴۳	۰/۹۸۲	۰/۹۲۱	۰/۸۲۱	۰/۰۲۱۸	۷	۱۰
ANN12	۴-۱۴-۱	۰/۹۸۴	۰/۹۶۹	۰/۸۷۴	۰/۹۸۶	۰/۹۴۸	۰/۴۱۲	۰/۰۰۶۱	۸	۱۲
ANN13	۴-۱۵-۱	۰/۹۴۶	۰/۹۳۰	۰/۷۵۱	۰/۸۴۲	۰/۸۶۱	۰/۹۲۳	۰/۱۱۱۵	۱۰	۱۴
ANN14	۴-۱۶-۱	۰/۹۳۰	۰/۹۲۳	۰/۷۲۱	۰/۸۳۳	۰/۷۵۲	۰/۷۳۴	۰/۰۹۲۱	۸	۱۱
ANN15	۴-۱۷-۱	۰/۹۱۲	۰/۸۹۹	۰/۶۹۱	۰/۸۰۱	۰/۷۱۳	۱/۴۲	۰/۰۸۱۸	۱۲	۱۵
ANN16	۴-۱۸-۱	۰/۹۲۶	۰/۸۴۱	۰/۶۶۳	۰/۸۶۱	۰/۷۴۷	۳/۷۲	۰/۰۶۳۶	۱۱	۱۴
ANN17	۴-۱۹-۱	۰/۹۰۲	۰/۸۱۸	۰/۶۳۲	۰/۸۴۷	۰/۷۵۹	۵/۷۵	۰/۰۳۲۱	۱۳	۱۷
ANN18	۴-۲۰-۱	۰/۹۱۰	۰/۸۷۸	۰/۷۸۵	۰/۸۸۱	۰/۷۷۲	۲/۹۸	۰/۰۳۱۰	۱۵	۱۹
ANN19	۴-۲۱-۱	۰/۸۹۰	۰/۸۵۶	۰/۷۵۱	۰/۸۶۶	۰/۷۵۲	۳/۷۴	۰/۰۴۸۱	۷	۲۰



شکل ۶- عملکرد شبکه‌های عصبی مصنوعی با لایه‌های درونی متفاوت با شاخص MSE



شکل ۸- عملکرد شبکه با لایه‌های درونی متفاوت با شاخص R^2



شکل ۷- برازش خط رگرسیون برای داده‌ها

روش همپوشانی نقشه‌های عامل استفاده می‌کنند که به دو روش رستری و وکتوری صورت می‌گیرد (Constantin و همکاران، ۲۰۱۱). در این پژوهش نیز وزن معیارها و طبقه‌های حاصل از روش‌های شبکه عصبی مصنوعی و نسبت فراوانی، در محیط MATLAB تلفیق و نقشه نهایی حاصل شد.


به منظور ارزیابی صحت مدل با استفاده از منحنی ویژگی عملکرد نسبی (ROC) صحت روش‌ها و با استفاده از نسبت فراوانی^۱ (FR) و شاخص سطح سلول هسته^۲ (SCAI) دقت تفکیک بین طبقات مورد بررسی و تأیید قرار گرفت. با توجه به این‌که برای ارزیابی مدل نمی‌توان از همان لغزش‌هایی استفاده نمود که در پهنه‌بندی استفاده شده‌اند، از بین نقاط لغزشی، ۷۰ درصد برای اجرای مدل و ۳۰ درصد برای ارزیابی مدل مورد استفاده قرار گرفت (Constantin و

بعد از مشخص کردن ساختار اصلی شبکه عصبی و فراهم نمودن اطلاعات مورد نیاز برای آموزش شبکه عصبی و همچنین، رسیدن به خطای قابل قبول، شبکه آماده است تا تحلیلی منطقی را که قبلاً با آن مواجه نشده است را انجام دهد. بدین منظور با در دست داشتن وزن‌های مرحله پایانی، کل منطقه که مشتمل بر ۸۰۰۰۰ پیکسل می‌باشد در اختیار شبکه قرار گرفت. خروجی که از این شبکه به دست می‌آید بین صفر و یک قرار دارد. این بازده به پنج طبقه با اختلاف ۰/۲۰ تقسیم شد. نتیجه این تقسیم مشخص شدن پنج طبقه با خطرات خیلی کم تا خیلی زیاد است. به گونه‌ای که طبقه ۰-۰/۲۰ خطر خیلی کم، ۰/۲-۰/۴ خطر کم، ۰/۴-۰/۶ خطر متوسط، ۰/۶-۰/۸ خطر زیاد و طبقه ۰/۸-۱ خطر خیلی زیاد است (شکل ۹). با توجه به این‌که شیوه تجزیه و تحلیل داده‌ها در دقت نقشه پهنه‌بندی خطر زمین لغزش تأثیرگذار است، بیشتر پژوهشگران به منظور تهیه نقشه پهنه‌بندی از

¹ Frequency Ratio

² Seed Cell Area Index

همکاران، ۲۰۱۱). نحوه محاسبه منحنی ROC در جدول ۴ نشان داده شده است.



شکل ۹- نقشه پهنه‌بندی حساسیت زمین به لغزش با روش ANN

جدول ۴- نحوه محاسبه نرخ ROC (اصلاح شده به وسیله Swets، ۱۹۸۸)

	زمین لغزش‌ها	مناطق عاری از زمین لغزش
رخداد زمین لغزش بر اساس تابع محاسبه	مثبت حقیقی (TP)	مثبت کاذب (FP)
مناطق امن بر اساس تابع محاسبه	منفی کاذب (FN)	منفی حقیقی (TN)

استفاده شد. نسبت فراوانی (FR) و شاخص SCAI دو شاخصی هستند که دقت طبقه‌بندی مدل را می‌توانند تعیین کنند (Kayastha و همکاران، ۲۰۱۲). در حقیقت نسبت فراوانی (FR) نسبت مساحت سطح لغزشی در هر طبقه به مساحت سطح آن طبقه می‌باشد و شاخص SCAI نسبت درصد مساحت هر یک از طبقات پهنه‌بندی خطر وقوع زمین لغزش به درصد لغزش‌های اتفاق افتاده در هر طبقه است (Akgun، ۲۰۱۲). نتایج حاصل از مقادیر SCAI (شکل ۱۱) و FR (شکل ۱۲) نشان داد که نقشه تولید شده دقیق می‌باشد زیرا طبقات حساسیت زیاد و خیلی زیاد دارای مقادیر خیلی کم SCAI و مقادیر بالای FR هستند و طبقات حساسیت کم و خیلی کم دارای مقادیر بالای SCAI و مقادیر خیلی کم FR هستند. این نتایج با نتایج حاصل از تحقیقات Akgun و Turk (۲۰۱۰)، Akgun (۲۰۱۲) و Pourghasemi و همکاران (۲۰۱۴) که بیان داشتند مقادیر SCAI باید از طبقه حساسیت


رابطه کمی-کیفی بین AUC و دقت پیش‌بینی که دامنه بین صفر تا یک را شامل می‌شود به شرح ذیل است. ۰/۹-۱ دقت عالی، ۰/۸-۰/۹ خیلی خوب، ۰/۸-۰/۷ خوب، ۰/۷-۰/۶ متوسط و ۰/۶-۰/۵ دقت ضعیف (Yesilnacar، ۲۰۰۵). در این پژوهش با استفاده از ۳۰ درصد زمین لغزش‌ها (۳۱ زمین لغزش) منحنی ROC محاسبه شد. نتایج حاصل از منحنی ROC در شکل ۱۲ نشان داده شده است. نتایج نشان داد که دقت پیش‌بینی مدل شبکه عصبی مصنوعی عالی می‌باشد. نتایج ارزیابی منحنی ROC نشان داد که میزان AUC مدل ۰/۹۳۸ و دقت پیش‌بینی آن ۹۳/۸ درصد است. به منظور ارزیابی قابلیت اطمینان نقشه پهنه‌بندی حساسیت زمین به لغزش از شاخص‌های نسبت فراوانی (FR)^۱ و شاخص سطح سلول هسته (SCAI)^۲

¹ Frequency Ratio


² Seed Cell Area Index

نتایج حاصل از شبکه عصبی نشان داد که اگر تعداد تکرار زیاد باشد، قابلیت از بر کردن شبکه افزایش پیدا کرده و تعمیم دادن یادگیری در اطلاعات آزمایشی کاهش می‌یابد و اگر تکرار کم باشد شبکه قادر به یادگیری نخواهد بود. در رابطه با اندازه مجموعه آموزشی نیز اگر زیاد باشد توانایی شبکه در تعمیم دادن یادگیری خوب فهمیده می‌شود و اگر کم باشد میزان یادگیری و جواب شبکه مشخص نمی‌شود. نرخ یادگیری نیز اگر زیاد باشد شبکه ناپایدار و اگر کم باشد مدت زمان آموزش زیاد می‌شود. مقدار یادگیری از ۰/۱ تا ۰/۵ تغییر داده شد که مقدار ۰/۱ با منتم ۰/۸ کمترین مقدار خطا را نشان داد. برای تعداد لایه ورودی نیز از سه تا ۲۱ نرون استفاده شد و کمترین مقدار خطا برای ۱۴ نرون به دست آمد. تعداد نرون در لایه پنهان نیز با روش سعی و خطا چهار نرون با کمترین خطا و بالاترین مقدار R^2 به دست آمد. در نهایت بهترین ساختار شبکه ۱-۴-۱۴ تشخیص داده شد. پس از اجرای روش شبکه عصبی نقشه نهایی پهنه‌بندی در پنج طبقه تهیه شد. به منظور اعتبارسنجی از منحنی ROC استفاده شد. نتایج حاصل از اعتبارسنجی نشان داد که مدل شبکه عصبی مصنوعی دارای دقت پیش‌بینی بالایی (۹۳/۸ درصد) برای شناسایی مناطق حساس به زمین لغزش در منطقه مورد مطالعه می‌باشد. نتایج حاصل از پهنه‌بندی حساسیت زمین به لغزش نشان داد که از کل مساحت مناطق لغزشی در منطقه مطالعاتی به وسعت (۳۱/۷۶ کیلومتر مربع)، ۱/۰۵ درصد (۰/۳۳ کیلومتر مربع) در رده خطر خیلی کم، ۱/۵ درصد از منطقه (۰/۴۷ کیلومتر مربع) در رده خطر کم، ۴/۲ درصد (۱/۳۳ کیلومتر مربع) در رده خطر متوسط، ۱۶/۸ درصد (۵/۳۳ کیلومتر مربع) در رده خطر زیاد و ۷۶/۴۵ درصد (۲۴/۲۸ کیلومتر مربع) در رده خطر خیلی زیاد قرار گرفته است. با توجه به دقت بالایی که نقشه حساسیت زمین به لغزش ایجاد شده از منطقه مطالعاتی با استفاده از روش شبکه عصبی مصنوعی دارد، این نقشه می‌تواند به منظور مدیریت بهینه به وسیله تصمیم‌گیران و برنامه‌ریزان کاربری اراضی و


خیلی کم تا زیاد کاهش یابد و مقادیر FR باید از طبقه حساسیت خیلی کم تا زیاد افزایش یابد، هم‌خوانی دارد.



شکل ۱۰- روند شاخص FR



شکل ۱۱- روند شاخص SCAI



شکل ۱۲ - منحنی ROC

همچنین، اجتناب از مناطق حساس مورد استفاده قرار گیرد. همچنین، با توجه به دقت بالای شبکه عصبی مصنوعی در شناسایی مناطق حساس به زمین لغزش

پیشنهاد می‌شود که در زمینه تهیه نقشه حساسیت زمین به لغزش در مناطق دیگر نیز این روش مورد استفاده قرار گیرد.

جدول ۵- نسبت فراوانی (FR) و شاخص SCAI پهنه‌بندی خطر وقوع زمین لغزش

محل	رده های خطر لغزش	مساحت فاقد لغزش (هکتار)	مساحت لغزش (هکتار)	درصد مساحت لغزش	مساحت هر رده خطر (هکتار)	درصد مساحت رده	درصد نسبت فراوانی	Seed درصد	SCAI
	خیلی کم	۱۳۷۵۸/۶۵	۳۳/۳۵	۱/۰۵	۱۳۷۹۲	۱۷/۲۴	۰/۰۲	۹/۴۵	۲/۷۹
	کم	۲۶۷۲/۳۶	۴۷/۶۴	۱/۵	۲۷۲۰	۳/۴	۰/۰۴	۱۸/۱	۱/۵۲
ANN	متوسط	۱۶۹۱۴/۶	۱۳۳/۴	۴/۲	۱۷۰۴۸	۲۱/۳۱	۰/۰۵	۲۱/۱۶	۰/۸۳
	زیاد	۱۵۰۹۸/۳۷	۵۳۳/۶۳	۱۶/۸	۱۵۶۳۲	۱۹/۵۴	۰/۰۵	۲۳/۱۱	۰/۷۱
	خیلی زیاد	۲۸۳۷۹/۹۵	۲۴۲۸/۰۵	۷۶/۴۵	۳۰۸۰۸	۳۸/۵۱	۰/۰۶	۲۸/۰۱	۰/۳۳

منابع مورد استفاده

- Akgun, A., E.A. Sezer, H.A. Nefeslioglu, C. Gokceoglu and B. Pradhan. 2012. An easy-to-use MATLAB program (MamLand) for the assessment of landslide susceptibility using a Mamdani fuzzy algorithm. *Computational Geosciences*, 38(1): 23–34.
- Akgun, A. and N. Turk. 2010. Landslide susceptibility mapping for Ayvalik (Western Turkey) and its vicinity by multi criteria decision analysis. *Environmental Earth Sciences*, 61: 595–611.
- Akgun, A., S. Dag and F. Bulut. 2008. Landslide susceptibility mapping for a landslide-prone area (Findikli, NE of Turkey) by likelihood frequency ratio and weighted linear combination models. *Environmental Geology*, 54(6): 1127–1143.
- Ayalew, L. and H. Yamagishi. 2006. The application of GIS-based logistic regression for landslide susceptibility mapping in the kakuda-yahiko mountains-Central Japan. *Geomorphology*, 65: 31–45.
- Ayalew, L., H. Yamagishi, H. Marui and T. Kanno. 2005. Landslides in Sado Island of Japan: Part II. GIS-based susceptibility mapping with comparisons of results from two methods and verifications. *Environmental Geology*, 81: 432–445.
- Constantin, M., M. Bednarik, M.C. Jurchescu and M. Vlaicu. 2011. Landslide susceptibility assessment using the bivariate statistical analysis and the index of entropy in the Sibiciu Basin (Romania). *Environmental Earth Sciences*, 63: 397–406.
- Conforti, M., S. Pascale, G. Robustelli and F. Sdao. 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.
- Chauhan, S., M. Sharma, M.K. Arora and N.K. Gupta. 2010. Landslide susceptibility zonation through ratings derived from artificial neural network. *International Journal of Applied Earth Observation and Geoinformation*, 12: 340–350.
- Chenkual, L., Z.D. Laltanpuia and F. Lalbiakmawia. 2016. Landslide Hazard Zonation (LHz) of lawngtlai district, Mizoram, India using remote sensing and GIS. *International Journal of Innovative Research in Science, Engineering and Technology*, 5(7): 13455-13460.
- Caniani, D., S. Pascale, F. Sdao and A. Sole. 2008. Neural networks and landslide susceptibility, case study: urban area of Potenza. *Natural Hazards*, 45: 55–72.
- Dou, J., T. Oguchi and Y.S. Hayakawa. 2014. Susceptibility mapping using a certainty factor model and its validation in the Chuetsu area, Central Japan. *Landslide Science for a Safer Geoenvironment*, 2: 483–489.
- Dou, J., X. Li and A.P. Yunus. 2015. Automatic detection of sinkhole collapses at finer resolutions using a multi-component remote sensing approach. *Natural Hazards*, 26: 1–24.
- Ercanoglu, M. and G.P. Candan. 2004. Use of fuzzy relation to produce landslide susceptibility map of a landslide prone area (West Black Sea Region, Turkey). *Engineering Geology*, 75: 229–250.
- Feizizadeh, B., P. Jankowski and T. Blaschke. 2014. A GIS based spatially-explicit sensitivity and uncertainty analysis approach for multi-criteria decision analysis. *Computers and Geosciences*, 64: 81–95.

15. Gomez, H., T. Kavzoglu and P. Mather. 2002. Artificial neural network application in landslide hazard zonation in the Venezuelan Andes. Abstracts of 15th International Conference on Geomorphology, Tokyo, Japan, 23–28 August 2001, 22(4): C–76.
16. Gokceoglu, C., H. Sonmez, H.A. Nefeslioglu, T.Y. Duman and T. Can. 2005. The 17 March 2005 Kuzulu landslide (Sivas, Turkey) and landslide-susceptibility map of its near vicinity. *Engineering Geology*, 81: 65–83.
17. Haykin, S. 1994. *Neural networks, a comprehensive foundation*, Macmillan College Publishing Company, New York.
18. Junior, R.V., S. Varandas, L.S. Fernandes and F. Pacheco. 2014. Environmental land use conflicts: A threat to soil conservation. *Land Use Policy*, 41: 172–185.
19. Kayastha, P., M.R. Dhital and F.D. Smedt. 2012. Landslide susceptibility mapping using the weight of evidence method in the Tinau watershed, case study: Nepal. *Natural Hazards*, 63:479-498.
20. Kanungo, D.P., M.K. Arora, S. Sarkar and R.P. Gupta. 2006. A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling Himalayas. *Engineering Geology*, 85: 347–366.
21. Kamp, U., B.J. Growley, G. Khattak and L.A. Owen. 2008. GIS-based landslide susceptibility mapping for the 2005 Kashmir earthquake region. *Geomorphology*, 101: 631-642.
22. Lee, S. and B. Pradhan. 2007. Landslide hazard mapping at Selangor, Malaysia using frequency ratio and logistic regression models. *Landslides*, 4: 33–41.
23. Leandro, R. F. and M. C. Santos. 2007. A neural network approach for regional vertical total electron content modelling. *Studia Geophysica et Geodaetica*, 51(2): 279-292.
24. Li, Y., G. Chen and C. Tang. 2012. Rainfall and earthquake-induced landslide susceptibility assessment using GIS and artificial neural network. *Natural Hazards and Earth System Sciences*, 12: 2719–2729.
25. Liu, S. and Y. Wu. 2016. Landslide susceptibility mapping in the gangu county, China Using Artificial Neural Network and GIS. *Electronic Journal of Geotechnical Engineering*, 21: 7613-7628.
26. Mars, P., J.R. Chen and R. Nambiar. 1996. *Learning algorithms: theory and applications in signal processing, control and communications*. CRC Press, Boca Raton, Florida.
27. Oikonomidis, D., S. Dimogianni, N. Kazakis and K.A. Voudouris. 2015. GIS/remote sensing-based methodology for groundwater potentiality assessment in Tirnavos area Greece. *Journal of Hydrology*, 525: 197–208.
28. Park, S., C. Choi, B. Kim and J. Kim. 2012. Landslide susceptibility mapping using frequency ratio, analytic hierarchy process, logistic regression and artificial neural network methods at the Inje area, Korea. *Environmental Earth Sciences*, 68: 1443–1464.
29. Pavel, M., J.D. Nelson and R. Jonathan Fannin. 2011. An analysis of landslide susceptibility zonation using a subjective geomorphic mapping and existing landslides. *Computers and Geosciences*, 37: 554–566.
30. Pascale, S., S. Parisi, A. Mancini, M. Schiattarella, M. Conforti, A. Sole, B. Murgante and F. Sdao. 2013. Landslide susceptibility mapping using artificial neural network in the urban area of senise and san costantino albanese (Basilicata, Southern Italy). *Springer*, 7974: 473-488.
31. Pourghasemi, H.H., H.R. Moradi, S.M. Fatemi Aghda, C. Gokceoglu and B. Pradhan. 2014. GIS-based landslide susceptibility mapping with probabilistic likelihood ratio and spatial multi-criteria evaluation models (North of Tehran, Iran). *Arabian Journal of Geosciences*, 7: 1857–1878.
32. Rajabi, M., K. Valizadeh and H. Abedi Gheshlaghi. 2016. Assessment of landslide hazard zonation using AHP and ANN, case study: Azarshahr chay, basin. *Journal of Quantitative Geomorphological Researches*, 5(1): 60-74 (in Persian).
33. Rajabi, M. and M. Feizollahpour. 2014. Landslide hazard zonation using multilayer perceptron model in Givi Chayi river basin. *Development and Geography Journal*, 36: 12-25 (in Persian).
34. Ríos, R., A. Ribó, R. Mejía and G. Molina. 2016. Combining neural networks and geostatistics for landslide hazard assessment of San Salvador, Metropolitan Area. *Revista DE Matematica: Teoria Y Applications*, 23(1): 155–172.
35. Sajikumara, N. and B.S. Thandaveswra. 1999. A non linear rainfall- runoff model using an artificial neural network. *Journal of Hydrology*, 216: 32-55.
36. Shary, P., L. Sharaya and A. Mitusov. 2002. Fundamental quantitative methods of landsurface analysis. *Geoderma*, 107: 1-32.
37. Saro, L., J. Seong Woo, O. Kwan-Young and L. Mounj-Jin. 2016. The spatial prediction of landslide susceptibility applying artificial neural network and logistic regression models, case study of Inje, Korea. *Open Geosciences*, 8: 117–132.
38. Swets, J.A. 1988. Measuring the accuracy of diagnostic systems. *Science*, 240: 1285–1293.

39. Sumer, E. and M. Turker. 2013. An adaptive fuzzy-genetic algorithm approach for building detection using high resolution satellite images. *Computers, Environment and Urban Systems*, 39: 48-62.
40. Svozil, D., V. KvasniEka and J. Pospichal. 1997. Introduction to multi-layer feed-forward neural networks. *Chemometrics and Intelligent Laboratory Systems*, 39: 43-62.
41. Souri, S., Gh.R. Lashgaripour and M. Ghafouri. 2011. Landslide hazard zonation using artificial neural network, case study: Keshvari basin. *Engineering Geology*, 5(2): 1269-1286 (in Persian).
42. Soleimani, K., J. Zandi and M. Habibnejad Roshan. 2014. Performance assessment of frequency ratio and bivariate methods (Wi, Wf) for landslide susceptibility zonation mapping, case study: Mazandaran's Vazrood Basin. *Journal of Geoscience*, 94: 41-50 (in Persian).
43. Tilahun, H. and R. Tarun Kumar. 2016. GIS based landslide hazard evaluation and zonation, A case from Jeldu District, Central Ethiopia. *Journal of King Saud University, Science*, accepted 24 May 2016: 1-15.
44. Tien Bui, D., B. Pradhan and O. Lofman. 2012. Landslide susceptibility assessment in the Hoa Binh province of Vietnam: a comparison of the Levenberg-Marquardt and Bayesian regularized neural networks. *Geomorphology*, 171: 12-29.
45. Yesilnacar, E. and T. Topal. 2005. Landslide susceptibility mapping: a comparison of logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey). *Engineering Geology*, 79: 251-266.
46. Youssef, A.M., B. Pradhan, H.R. Pourghasemi and S. Abdullahi. 2015. Landslide susceptibility assessment at Wadi Jawrah Basin, Jizan region, Saudi Arabia using two bivariate models in GIS. *Journal of Geosciences*, doi:10.1007/s12303-014-0065-z.
47. Yilmaz, I. 2009. Landslide susceptibility mapping using frequency ratio, logistic regression, artificial neural networks and their comparison: A case study from kat landslides (Tokat-Turkey). *Computers and Geosciences*, 35: 1125-1138.
48. Zare, M., H.R. Pourghasemi, M. Vafakhah and B. Pradhan. 2013. Landslide susceptibility mapping at Vaz Watershed (Iran) using an artificial neural network model: a comparison between multilayer perceptron (MLP) and radial basic function (RBF) algorithms. *Arabian Journal of Geosciences*, 6: 2873-2888.

The application of artificial neural network on landslide susceptibility mapping developed by frequency ratio and AHP in Oliya's Padena in Semirom

Alireza Arabameri^{*1}, Kalil Rezaee², Mohammadhossein Ramsheh³ and Kouros Shirani⁴

¹ PhD, Faculty of Humanities, Tarbiat Modares University, Iran, ² Assistant Professor, Faculty of Earth Sciences Kharazmi University, Tehran, Iran, ³ Professor, Faculty of Humanities, Isfahan University, Iran and ⁴ Assistant Professor, Soil Conservation and Watershed Management Research Department, Isfahan Agricultural and Natural Resources, Research and Education Center, AREEO, Isfahan, Iran

Received: 06 November 2016

Accepted: 07 June 2017

Abstract

Landslide susceptibility and its risk assessment is the main part of landslide risk mapping. In this study, landslide susceptibility of Oliya's Padena in Semirom is mapped using artificial neural network. A total of 23 factors in relation to landslide in the region were initially characterized. The spatial location of landslide events was then determined by field study as well as aerial photo analysis. AHP analysis tends to 14 out of 23 parameters as the important factors for further steps. A total of 72 (70%) and 31 (30%) out of 103 detected landslide events in the study area were selected as training and validation data for neural network analysis, respectively. A multilayer perceptron back propagation algorithm with sigmoid as activation function was developed. The best topology was determined by using conventional criteria including mean square error, root mean square error, maximum absolute error and correlation coefficient. Results show that a 14-4-1 array is the optimum topology for landslide susceptibility zoning in the region. The weight of each input layer was estimated by frequency ratio. In order to map landslide, ROC graph and area under curve indices were used and the accuracy of output map was computed. Results from validation shows that area under curve for the obtained model is about 0.938 (93.8%) that is considered as high resolution prediction group. According to this study, a total of 29.61 square kilometers (93.25%) of the landslide areas is categorized in very high and high susceptible groups.

Key words: AHP Method, Frequency ratio method, Landslide susceptibility, Multilayer perceptron, Oliya's Padena in Semirom, Sediment

* Corresponding author: alireza.ameri91@yahoo.com