



دانشگاه آزاد اسلامی واحد اهر
فصلنامه‌ی علمی فضای جغرافیایی

سال بیستم، شماره‌ی ۶۹
بهار ۱۳۹۹، صفحات ۹۷-۱۱۶

* مهدی فیض‌اله پور^۱
مهدی مومی پور^۲

پهنه‌بندی مناطق مستعد زمین لغزش با استفاده از پرسپترون چند لایه از نوع پیش‌خور با الگوریتم پس انتشار (مطالعه موردی: حوضه رودخانه سنگورچای)

تاریخ پذیرش: ۱۳۹۷/۱۱/۰۳

تاریخ دریافت: ۱۳۹۶/۰۷/۱۷

چکیده

زمین‌لغزش‌ها از جمله پدیده‌های مخرب طبیعی به‌شمار می‌آیند که باعث خسارات جانی و مالی می‌گردند. تحلیل شرایط رخداد زمین‌لغزش به‌منظور پهنه‌بندی آن در امر مدیریت و برنامه‌ریزی مخاطرات از اهمیت ویژه‌ای برخوردار است. لذا در این تحقیق به‌منظور برآورد امکان رخداد زمین‌لغزش از نوعی مدل شبکه عصبی مصنوعی که با عنوان مدل پرسپترون چند لایه شناخته می‌شود برای تحلیل زمین‌لغزش‌های رخ داده در حوضه سنگورچای بهره گرفته شد. به این منظور، داده‌های ۱۲۴ زمین‌لغزش شناسایی شده و به سیستم ارائه شد. در کنار آن برای پردازش زمین‌لغزش‌ها در نرم‌افزار MATLAB، ۷ لایه متشکل از لایه‌های شیب، جهت شیب، DEM، لیتولوژی، شبکه هیدروگرافی، لایه NDVI و پراکنش زمین‌لغزش در نرم‌افزار Arc GIS ترسیم گردید. سپس ۸۰ درصد داده‌ها (۶۸۲۴ پیکسل) برای تعلیم و ۲۰ درصد داده‌ها (۱۷۰۶ پیکسل) برای تست انتخاب شده و در ساختار مدل پرسپترون چند لایه مورد پردازش قرار گرفتند. به علت وجود روابط غیرخطی در پدیده زمین‌لغزش از توابع انتقال سیگموئید استفاده گردید. برای این تحقیق تعداد نرون در لایه میانی از ۵ تا ۲۰ تغییر داده شد و با تعداد ۱۸ نرون شبکه به کم‌ترین خطا در مرحله آموزش و آزمایش رسید. ضریب یادگیری که میزان تغییر وزن‌ها را در کنترل دارد، از ۰/۱ تا ۰/۳ مورد بررسی قرار گرفت و با

E-mail: feyzolahpour@znu.ac.ir

* ۱- گروه جغرافیا، دانشگاه زنجان. (نویسنده مسئول).

۲- دانشگاه علوم و فنون دریایی خرمشهر.

مقدار ۰/۳ شبکه به بهترین یادگیری دست یافت. در نهایت با توجه به وزن خروجی، نقشه پهنه‌بندی زمین لغزش ترسیم گردید. نتایج نشان داد که ساختار زمین‌شناسی شکل گرفته از مارن خاکستری و توفهای آتشفشانی در کنار منابع رطوبتی بالا باعث شده که ارتفاعات کوه‌های گنجگاه و اسلام آباد در محدوده جنوب‌غربی حوضه از قابلیت بالایی در رخداد زمین لغزش برخوردار شوند.

کلید واژه‌ها: زمین لغزش، شبکه عصبی مصنوعی، مدل پرسپترون چند لایه، پهنه‌بندی، حوضه رودخانه سنگورچای.

مقدمه

وقوع زمین لغزش نتیجه روابط پیچیده بین فاکتورهای محیطی بوده و این فاکتورها به عوامل اولیه و تشدید کننده تقسیم شده‌اند. عوامل تشدید کننده زمین لغزش شامل زلزله، بارندگی و ذوب برف می‌باشند. فعالیت‌های انسانی از قبیل جاده‌سازی و ساختمان‌سازی بر روی دامنه‌های با شیب تند و پخش آب مخازن و فاضلاب‌ها نیز می‌تواند وقوع زمین لغزش را شدت ببخشد (Cubito et al., 2005: 362). عوامل اولیه از قبیل اشکال زمین‌شناسی و ژئومورفولوژیکی، بیرون‌زدگی سنگ‌ها، نوع سنگ و پوشش گیاهی نیز از اهمیت بالایی برخوردار است (Zeze et al., 1999: 137; Fernandes et al., 2004: 167; Cubito et al., 2005: 366; Moreiras, 2005: 349). علل اولیه وقوع زمین لغزش‌ها می‌تواند شامل محدوده وسیعی از فاکتورها از قبیل سرعت جریان و فاصله تا رودخانه، توپوگرافی، میزان رطوبت خاک و شاخص شدت جریان (Gokceoglu et al., 2005: 69)، کاربری اراضی، حضور زمین لغزش‌های قدیمی و فعالیت انسانی (Zeze et al., 1999: 139) باشد. بررسی روابط دینامیکی بین فاکتورهای موثر در وقوع زمین لغزش از اهمیت بالایی در موفقیت ارزیابی خطر زمین لغزش برخوردار است. برای تعیین روابط بین انواع فاکتورهای محیطی و وقوع زمین لغزش تحقیقات مختلفی صورت گرفته است (Anbalagan, 1992: 273; Lee & Min, 2001: 1105; Iwahashi et al; 2003: 351; Ayalew & Yamagishi, 2005: 26). برخی از این تحقیقات روابط منسجمی را بین توزیع فاکتورهای زمین‌شناسی و ژئومورفولوژیک و زمین لغزش مشاهده نمودند. با این وجود برای تحلیل نتایج این تحقیقات و پیش‌بینی احتمال وقوع زمین لغزش‌ها از ابزارهای محاسبات آماری متداول استفاده شد. در حقیقت، پیش‌بینی احتمال وقوع زمین لغزش نیازمند مدل‌های کمی در ترکیب رخدادهای گذشته بوده و با استفاده از داده‌های میدانی یا آزمایشگاهی اقدام به مدل‌سازی می‌گردد (Melchiorre et al., 2006: 389). با این وجود، روابط غیرخطی بین وقوع زمین لغزش و فاکتورهای مشارکت کننده در آن بسیار پیچیده بوده و نیازمند استفاده از مدل‌ها با درجه صحت پیش‌بینی بالا می‌باشد. اخیراً شبکه عصبی مصنوعی به‌عنوان ابزار تحلیلی در محدوده گسترده‌ای از علوم طبیعی به‌کار برده شده است. یکی از مزایای استفاده از مدل ANN در مدل‌سازی کیفی پدیده‌های طبیعی، توانایی کنترل داده‌ها در هر مقیاس اندازه‌گیری به نسبت خطی، توصیفی و عددی و هر شکل از توزیع داده‌ها می‌باشد (Wang et al., 1995: 775). علاوه بر این، مدل فوق می‌تواند به‌طور گسترده در ادغام داده‌های مکانی با منابع چند متغیره و پیش‌بینی متغیرها به‌کار برده

شود. برخی از محققان اصول اولیه و کاربرد مدل ANN را در شناسایی الگوهای طبیعی تشریح نموده‌اند (Rumelhart et al., 1986; Alexander & Morton, 1990; Guyon & Wang, 1993). مدل ANN، یک روش تحلیل‌گر داده بوده و از توابع غیرخطی تبعیت می‌کند؛ بنابراین این مدل ابزار مدل‌سازی با اهمیتی برای پهنه‌بندی مناطق مستعد لغزش به‌شمار می‌رود (Lee et al., 2003: 1367; Lu & Rosenbaum, 2003: 388; Ermini et al., 2005:322; Gomez & Kavzoglu, 2005:16).

شبکه‌های عصبی مصنوعی دارای انواع مختلفی می‌باشند. یکی از معروف‌ترین و پرکاربردترین این مدل‌ها مدل MLP یا همان مدل پرسپترون چند لایه می‌باشد. اجزای این مدل از طریق نرون‌ها به یکدیگر مرتبط شده و هر نرون دارای وزن مخصوص به خود بوده است. مشابه تمام مدل‌های شبکه عصبی مصنوعی، این مدل نیز از لایه‌های ورودی، لایه پنهان و لایه خروجی تشکیل شده است. تعداد لایه‌های پنهان در این مدل از طریق روش آزمون و خطا و تکرار تعیین می‌شود. این آزمون تا زمان رسیدن به کم‌ترین میزان خطا ادامه می‌یابد. کم‌ترین میزان خطا معرف بهترین حالت ممکن بوده و در آن امکان رسیدن به بهترین حالت شبیه‌سازی افزایش می‌یابد.

(Abadinejad et al 2007) در تحقیقی به ارزیابی کارایی عملگرهای منطق فازی در تعیین توانمندی زمین‌لغزش در منطقه شیروود پرداخته‌اند. در ابتدا برخی از مهم‌ترین عوامل موثر در رخداد این پدیده مانند شیب، سنگ‌شناسی، کاربری اراضی، جهت شیب و فاصله از گسل به‌عنوان متغیرهای مستقل در محیط سامانه‌های اطلاعات جغرافیایی تهیه و رقومی شدند. لایه پراکنش زمین‌لغزش‌ها نیز با استفاده از تفسیر عکس‌های هوایی و عملیات میدانی با استفاده از GPS تهیه گردید. نتایج حاصل از این بررسی نشان می‌دهد که عملگر فازی گامای $0/8$ به‌عنوان مناسب‌ترین عملگر در تعیین توانمندی زمین‌لغزش در حوضه آبخیز شیروود می‌باشند.

در تحقیقی (Gomez et al 2005) با استفاده از شبکه عصبی به ارزیابی مناطق مستعد لغزش مصنوعی در حوضه رودخانه جابونوسا (ونزوئلا) پرداخته‌اند. این تحقیق با استفاده از شبکه عصبی مصنوعی ANN مخصوصاً پرسپترون چندلایه و الگوریتم‌های یادگیری به ارزیابی پتانسیل ریسک لغزش می‌پردازد. در این روش از پارامترهای دامنه‌های ناپایدار که از مدل ارتفاعی دیجیتالی (DEM) تهیه شده‌اند بهره گرفته شده است. مدل ANN با صحتی معادل 90% از قابلیت استفاده در پهنه‌بندی مناطق مستعد لغزش برخوردار می‌باشد.

(Ishik Yilmaz 2009) در تحقیقی به بررسی پهنه‌بندی مناطق مستعد لغزش با استفاده از نسبت فراوانی، رگرسیون لجستیک و شبکه عصبی مصنوعی و مقایسه آن‌ها با یکدیگر پرداخته است. هدف از این مطالعه مقایسه روش‌های پهنه‌بندی مناطق مستعد لغزش از قبیل نسبت فراوانی (FR)، رگرسیون لجستیک و شبکه عصبی مصنوعی (ANN) و کاربرد آن‌ها در شهر کات ترکیه می‌باشد. سطوح زیر منحنی (AUC) نشان می‌دهد که پهنه‌بندی به‌دست آمده از طریق شبکه عصبی مصنوعی از بیش‌ترین صحت نسبت به مدل‌های دیگر برخوردار است. نتایج به‌دست آمده در این مطالعه

همچنین نشان می‌دهد که مدل رگرسیون لجستیک و شبکه عصبی مصنوعی نیازمند داده‌هایی در فرمت ASCII و سایر فرمت‌های مشابه می‌باشند و بررسی مقادیر زیاد داده‌ها در بسته‌های آماری بسیار مشکل می‌باشد.

Borgogno Mondino (2009) در تحقیقی به بررسی نحوه استفاده از روش شبکه عصبی در لغزش منطقه سوسا در شمال غرب ایتالیا پرداخته‌اند. این تحقیق بررسی‌های ژئومورفولوژیکی را با تاکید بر اطلاعات حاصل از سنجنده MIVIS (مادون قرمز چندطیفی و تصاویر طیف مرئی) انجام می‌دهد. لذا در ایجاد همبستگی هندسی و طبقه‌بندی از الگوریتم‌های شبکه عصبی استفاده شده است. نتایج حاصله منجر به تشخیص خصوصیات عناصر اصلی فعال در ناپایداری دامنه‌ها و ساختار اصلی و لندفرم‌های لغزش گردیده است.

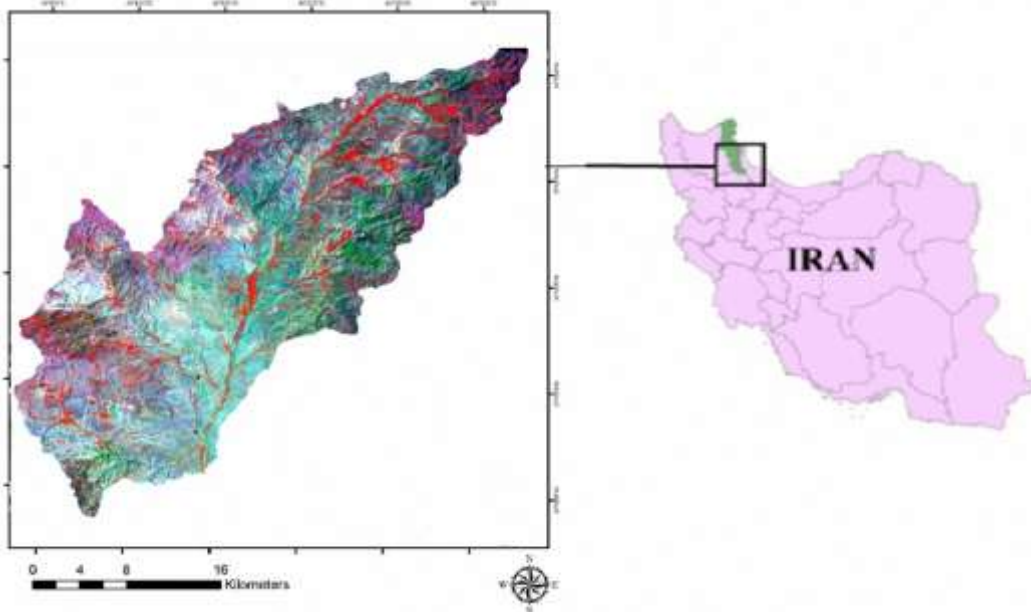
Biswajeet et al (2010) در تحقیقی به استفاده از داده‌های سنجش از دور و GIS در تحلیل مخاطرات لغزش با استفاده از شبکه عصبی مصنوعی پرداخته‌اند. هدف از مطالعه فوق ارزیابی مخاطرات لغزش در منطقه سلانگور در مالزی با استفاده از سنجش از دور و GIS می‌باشد. هر فاکتور توسط شبکه عصبی مصنوعی وزن‌دهی شده سپس شاخص مخاطرات لغزش با استفاده از وزن‌ها محاسبه شده و در نهایت نقشه مخاطرات لغزش با استفاده از GIS ترسیم می‌شود. نتایج حاصله از صحتی معادل ۸۲/۹۲ درصد برخوردار هستند.

Feyzolahpour (2017) در تحقیقی با استفاده از مدل شبکه عصبی مصنوعی به تخمین بار معلق رسوبی در رودخانه سنگورچای پرداخته است. نتایج نشان داد که مدل RBF در تخمین بار معلق رسوبی به نتایج بهتری دست یافته است. Jafari et al (2019) در تحقیقی با استفاده از روش تحلیل شبکه‌ای به پهنه‌بندی زمین لغزش در حوضه آبریز بدرانلو پرداختند. نتایج نشان داد که عوامل شیب دامنه، ویژگی‌های لیتولوژی، فاصله از آبراهه و بارندگی سالانه بیش‌ترین تاثیر را در وقوع زمین لغزش داشته‌اند.

با توجه به مواردی که عنوان گردید در این تحقیق از شبکه عصبی مصنوعی از نوع پرسپترون چند لایه پیش‌خور با الگوریتم پس انتشار برای پهنه‌بندی زمین لغزش در حوضه رودخانه سنگورچای بهره گرفته شد.

محدوده مورد مطالعه

حوضه رودخانه سنگورچای با مجموع مساحت ۸۵۳ کیلومتر مربع یکی از زیرحوضه‌های آبریز سفیدرود می‌باشد که در مختصات ۴۸ درجه و ۴ دقیقه و ۲۰ ثانیه تا ۴۸ درجه و ۳۳ دقیقه و ۲۴ ثانیه طول شرقی و ۳۷ درجه و ۳۴ دقیقه و ۳۲ ثانیه تا ۳۷ درجه و ۵۶ دقیقه و ۱۷ ثانیه عرض شمالی واقع شده است (شکل ۱). این حوضه در استان اردبیل و مابین شهرهای گیوی و خلخال واقع شده و یکی از رودهایی است که در زمان ورود رودخانه قزل‌اوزن به این منطقه به آن می‌پیوندد. به واسطه نزدیکی این حوضه به دریای خزر میزان بارندگی در آن نسبت به مناطق مجاورش در حد مطلوبی بوده است. میانگین بارندگی در این حوضه ۴۲۷ میلی‌متر بوده و مشابه سایر نقاط آذربایجان، بیشینه بارش در فروردین و اردیبهشت ماه رخ می‌دهد. به طوری که حدود ۸۳ تا ۹۲ درصد از مجموع بارندگی در این ماه‌ها مشاهده شده است. با توجه به شرایط فوق میزان زمین لغزش در این منطقه می‌تواند قابل توجه باشد.



شکل ۱: موقعیت جغرافیایی حوضه رودخانه سنگورچای در استان اردبیل
Figure 1: Geographic location of Songurchay river basin in Ardebil province

مواد و روش‌ها

با توجه به هدف تحقیق که پهنه‌بندی زمین لغزش می‌باشد لازم است تا به منظور آزمون نتایج حاصله از مدل، وضعیت زمین لغزش در این حوضه مورد ارزیابی و شناسایی قرار گیرد. با مطالعات صورت گرفته، ۱۲۴ زمین لغزش و پهنه لغزشی تشخیص داده شد که از اطلاعات مربوط به این مناطق در آموزش و آزمایش شبکه استفاده می‌گردد. مرحله بعدی شامل تهیه پایگاه اطلاعاتی از عوامل موثر در زمین لغزش می‌باشد. در این مرحله ۷ عامل لیتولوژی، شیب و جهت شیب، نقشه DEM، شبکه هیدروگرافی، NDVI و نقشه پراکنش زمین لغزش‌ها مورد بررسی قرار گرفت. نقشه این عوامل توسط نرم‌افزار ArcGIS تهیه و برای آموزش شبکه عصبی مصنوعی مورد استفاده قرار گرفته و در نهایت نقشه پهنه‌بندی زمین لغزش ترسیم گردید. در زیر ساختار مدل شبکه عصبی مصنوعی از نوع پیش خور پس انتشار شرح داده می‌شود.

مدل پیش خور پس انتشار^۳

شبکه‌های عصبی مصنوعی با فرایند پردازش داده‌ها مدل‌های جدیدی را ارائه می‌دهند که با ورود داده‌ها قادر به پیش‌بینی خروجی‌ها باشند (Atkinson & Tatnall, 1997:703). یکی از مهم‌ترین مدل‌های محاسبات عصبی، شبکه عصبی پس انتشار خطا (EBPNN) می‌باشد. در این مدل، نرون‌ها به‌عنوان لایه‌های متوالی، سازمان داده شده و هر لایه متشکل از یک یا چندین نرون بوده و لایه‌های ورودی، لایه‌های میانی و لایه خروجی را تشکیل می‌دهد. سپس

شبکه پیش‌خور با ارائه وزن به هر داده، روابط بین نرون‌ها را برقرار می‌سازد. وزن‌ها می‌توانند داده‌های مثبت و منفی را در بر گرفته و در بین ساختار مدل ANN توزیع شده و رفتار فرآیندهای اطلاعاتی را تعیین نمایند. در پردازش اطلاعات، مجموعه‌ای از الگوها، ساختار لایه ورودی را طراحی نموده و دارای یک لایه ورودی و چندین لایه پنهان و یک لایه خروجی می‌باشد. نتایج لایه‌های ورودی به وسیله لایه پنهان پردازش شده و در آنجا برای هر نرون چندین لایه در نظر گرفته شده است لیکن در نهایت مدل دارای یک لایه خروجی خواهد بود. استفاده از مدل ANN در دو مرحله صورت می‌گیرد. در مرحله تعلیم، وزن بین نرون‌ها تنظیم شده و سپس در مرحله طبقه‌بندی، داده‌های تعلیم داده شده در پیش‌بینی لایه خروجی مورد استفاده قرار می‌گیرند.

تعلیم شبکه عصبی پیش‌خور شامل اختصاص وزن بین نرون‌ها بوده و در هر بار وزن‌دهی، مجموعه‌ای از ورودی‌ها و خروجی‌های مطلوب به عنوان نمونه به خدمت گرفته می‌شوند. الگوهای احتمالاتی با یکدیگر برابر در نظر گرفته می‌شوند به این معنی که هیچ الگویی نسبت به سایر الگوها از اهمیت بیش‌تری برخوردار نیست. در ابتدا، وزن بین نرون‌ها به صورت تصادفی تعیین می‌گردد. سپس الگوی ارائه شده به شبکه با نتایج مطلوب مقایسه می‌شود. مسلماً خروجی‌های اولیه به نتایج مطلوب شبیه نبوده و دارای خطای نسبی نسبت به فاصله اقلیدسی بین خروجی محاسبه شده و نتایج مطلوب می‌باشد. از بین کم‌ترین میانگین خطا، وزن‌ها مطابق با میزان خطا، اصلاح شده و میزان آن‌ها کاهش می‌یابد. با چندین مرحله تکرار، خروجی شبکه به سمت خروجی مطلوب متمایل خواهد شد. در نهایت مدل EBPNN تعلیم داده می‌شود. به نسبت اندازه مدل و پیچیدگی الگوهای تعلیم دهنده، فرآیند همگرایی نتایج ممکن است نیازمند چندین هزار بار تکرار باشند.

با در نظر گرفتن یک شبکه با گره‌های N_i ، N_j و N_k به عنوان داده‌های لایه‌های ورودی، پنهان و خروجی، برای ارائه یک جفت داده تعلیم داده شده، خروجی (O_{pj}) گره N_j در لایه پنهان به وسیله تابع سیگموئید تعیین می‌گردد.

$$O_{pj} = \frac{1}{1 + e^{-A_{pj}}} \quad \text{رابطه (۱)}$$

در این معادله A_{pj} داده‌های گره N_j بوده و از طریق معادله زیر محاسبه می‌گردد:

$$A_{pj} = \sum (i(O_{pi} \cdot w_{ji})) + u_j \quad \text{رابطه (۲)}$$

در این معادله O_{pj} داده‌های ورودی تعلیم داده شده‌ای است که وارد گره ورودی شده و به وسیله w_{ij} که نشان دهنده وزن بین گره‌های N_i و N_j هستند تعلیم داده می‌شوند. همچنین u_j نشان دهنده داده‌های آستانه گره N_j می‌باشند. در نهایت در تعیین خروجی شبکه، داده‌های N_k که خروجی شبکه را نشان می‌دهند از طریق معادله زیر محاسبه می‌شوند.

$$O_{pk} = \frac{1}{1 + e^{-A_{pk}}} \quad \text{رابطه (۳)}$$

در این معادله داده‌های گره N_k که به صورت A_{pk} نشان داده شده‌اند از طریق معادله زیر محاسبه می‌گردند.

$$A_{pk} = \sum (j) O_{pj} w_{kj} + u_k \quad \text{رابطه (۴)}$$

در این معادله w_{kj} وزن بین گره‌های j و k در لایه پنهان و خروجی بوده و u_k داده‌های آستانه گره N_k یا خروجی می‌باشد. به بیان ساده می‌توان چنین عنوان کرد که وزن بین گره‌های دو لایه مجاور و داده‌های آستانه در لایه‌های پنهان و خروجی به صورت تصادفی تعیین می‌گردد. به عنوان نمونه، مجموعه‌ای از الگوی ورودی تعلیم داده شده در شبکه وارد شده و نتایج خروجی O_{pk} با نتایج مطلوب خروجی T_{pk} مقایسه شدند. همان‌طور که انتظار می‌رفت خروجی‌های اولیه محاسبه شده مشابه نتایج مطلوب نمی‌باشند. در نتیجه خطای حاصل از تفاضل O_{pk} و T_{pk} محاسبه گردید. سپس با استفاده از شبکه پس انتشار، وزن‌ها مطابق با میزان خطا اصلاح شده و در مراحل بعدی به حداقل ممکن کاهش می‌یابند. در این مرحله، الگوریتم ارائه شده به وسیله Rumelhart (1986) برای تغییر وزن شبکه مورد استفاده قرار گرفت. برای ارائه یک جفت خروجی تعلیم داده شده، بایستی وزن متغیرها (w_{kj}) به منظور ایجاد خطای یکسان pk (δ) تغییر یافته و محاسبه شوند. برای تغییر وزن بین لایه‌های پنهان و خروجی، معادله زیر ارائه شده است:

$$\Delta p w_{kj} = \beta \delta_{pk} O_{pj} \quad \text{رابطه (۵)}$$

در این معادله، B ضریبی است که میزان یادگیری را در طی فرآیند تعلیم تعیین می‌کند. تغییر وزن بین لایه‌های ورودی و پنهان نیز به شکل زیر انجام می‌پذیرد:

$$\Delta p w_{ji} = B \partial_{pj} O_{pi} (\Delta p w_{kj} + w_{kj}) \quad \text{رابطه (۶)}$$

در این معادله ∂_{pj} خطای گره i در لایه پنهان می‌باشد. در محاسبه شبکه پس انتشار، خطا و وزن لایه خروجی ابتدا محاسبه شده و سپس برای برآورد تغییر وزن لایه‌های اولیه مورد استفاده قرار می‌گیرد. خطای لایه‌های پنهان و خروجی به ترتیب زیر به وسیله معادله Rumelhart (1986) محاسبه می‌گردد:

$$\partial_{pk} = (T_{pk} - O_{pk}) f_k(A_{pk}) \quad \text{رابطه (۷)}$$

$$\partial_{pj} = \left(\sum (k) \partial_{pk} \right) f_j \quad \text{رابطه (۸)}$$

نسبت $(T_{pk} - O_{pk})$ نشان دهنده تناسب خطا بین خروجی واقعی (O_{pk}) و خروجی هدف (T_{pk}) می‌باشد. نسبت $f_k(A_{pk})$ نیز میزان تغییرات O_{pk} را به نسبت $f_k(A_{pk})$ نشان می‌دهد. همان‌طور که Rumelhart (1986) نشان دادند

میزان $f_k(A_{pk})$ بایستی به تبعیت از پارامتر A_{pk} به آرامی افزایش یابد. همچنین مقادیر $f_j(A_{pk})$ از طریق معادله زیر برآورد می‌شود:

$$f_j(A_{pk}) = O_{pj}(1 - O_{pk}) \quad \text{رابطه (۹)}$$

شکل ساده شده خطاهای هر گره در لایه خروجی (معادله ۷) و لایه پنهان (معادله ۸) به ترتیب به صورت زیر می‌باشد:


$$\partial_{pk} = (T_{pk} - O_{pk})O_{pk}(1 - O_{pk}) \quad \text{رابطه (۱۰)}$$

$$\partial_{pj} = \left(\sum (k) \partial_{pk} w_{kj} \right) O_{pj}(1 - O_{pj}) \quad \text{رابطه (۱۱)}$$

با بهره‌گیری از این معادله مقادیر تغییر وزن برای تمام وزن‌های شبکه بعد از هر تکرار تعیین می‌شود. در این تحقیق از مدل پرسپترون چند لایه پیش‌خور پس انتشار در پهنه‌بندی زمین‌لغزش حوضه رودخانه سنگورچای استفاده شده است. مدل شبکه عصبی مصنوعی که در این تحقیق استفاده شده دارای یک لایه پنهان با ۱۸ گره می‌باشد. تعداد گره‌ها در لایه ورودی معادل ۷ گره یا تعداد فاکتورهای استفاده شده در پهنه‌بندی زمین‌لغزش بوده است. همچنین تعداد گره‌های لایه خروجی نیز یک در نظر گرفته شده که نشان دهنده احتمال وقوع یا عدم وقوع زمین‌لغزش می‌باشد.

یافته‌ها و بحث


قبل از انجام مراحل تحقیق و مدل‌سازی، لازم است تا شناختی از وضعیت موجود و عوامل موثر در رخداد زمین‌لغزش حاصل گردد. به این منظور هر یک از ۷ موردی که از آن‌ها در امر پهنه‌بندی استفاده شد مورد واکاوی و بررسی قرار گرفتند. در زیر هر یک از این لایه‌ها و میزان تأثیرگذاری آن‌ها بررسی گردیده و از آن در ترسیم نقشه پهنه‌بندی استفاده شد. در سطح حوضه سنگورچای حدود ۸ سازند با منشا رخساره‌های رسوبی شناسایی شده که حدود ۳۲/۷ درصد از حوضه را به خود اختصاص داده‌اند. با توجه به زمین‌لغزش‌های انتخابی، سازند مارن خاکستری و قرمز با ماسه‌سنگ خاکستری (Ngms)، از حدود ۷۲ زمین‌لغزش برخوردار بوده و سطحی معادل ۲۳۵/۴ کیلومتر مربع یا ۲۷/۶ درصد حوضه را به خود اختصاص داده است. به غیر از سازندهای فوق، ۷ سازند دیگر نیز در گروه رخساره‌های رسوبی قرار می‌گیرند. در کنار رخساره‌های رسوبی، سنگ‌های آتشفشانی و مواد آذر آواری واقع در حوضه سنگورچای حدود ۵۷۴/۰۶ کیلومتر مربع یا ۶۷/۳ درصد از سطح حوضه را به خود اختصاص داده‌اند. در بین سازندهای این بخش تنها سازند آندزیت پرفیری (Ev) توانسته حدود ۱۹۶/۱ کیلومتر مربع یا ۲۳ درصد کل حوضه را در برگیرد. توفها نیز از پراکنش قابل توجهی برخوردارند به طوری که حدود ۱۵۳/۵ کیلومتر مربع یا ۱۸ درصد از کل حوضه را پوشانیده‌اند. در این تحقیق از بین ۱۲۴ زمین‌لغزش انتخابی ۵۲ لغزش در سنگ‌های آتشفشانی و توفها رخ داده است. به غیر از سازندهای فوق ۱۲ سازند دیگر نیز با ماهیتی آتشفشانی در حوضه وجود دارد که ۲۲۴/۳ کیلومتر مربع یا ۲۶/۳ درصد سطح حوضه را پوشانیده و فاقد زمین‌لغزش‌های چشمگیری هستند.



شکل ۵: نقشه DEM برای حوضه رودخانه سنگورچای

Figure 5: DEM map in Songurchay river basin

همچنین در این مطالعه برای پهنه‌بندی به‌وسیله مدل پرسپترون چند لایه تغییرات شیب با اختلاف $2/8$ درجه در نظر گرفته شد. با افزایش شیب، احتمال لغزش افزایش می‌یابد تا به حدود $52/2$ درجه برسد از این شیب به بعد کاهش شدیدی در زمین‌لغزش‌ها دیده می‌شود.




شکل ۶: نقشه هیدرولوژی حوضه رودخانه سنگورچای

Figure 6: Hydrology map in Songurchay river basin

رودخانه‌ها نیز با توجه به ویژگی‌های آن‌ها که متأثر از شرایط اقلیمی و ساختار زمین‌شناسی و لیتولوژیک است به کاوش و تغییر شکل سطح زمین می‌پردازند. حوضه رودخانه سنگورچای با عبور از سازندهای مختلف اقدام به فرسایش زمین کرده و باعث تشدید رخداد زمین لغزش در این منطقه گردیده است. در شکل (۶)، شبکه‌های هیدروگرافی حوضه رودخانه سنگورچای نشان داده شده است. در برآورد مقادیر پوشش گیاهی نیز از شاخص NDVI استفاده شد. این شاخص از معروف‌ترین، ساده‌ترین و کاربردی‌ترین شاخص‌هایی است که در زمینه مطالعات پوشش گیاهی شناخته شده است. فرآیند محاسباتی در این روش ساده بوده و در مقایسه با دیگر شاخص‌ها دارای بهترین توان دینامیک می‌باشد. این شاخص بیش‌ترین حساسیت را به تغییرات پوشش گیاهی داشته و در مقابل اثرات جوی و زمینه خاک به جز مواردی که پوشش گیاهی کم باشد حساسیت کم‌تری دارد. شاخص NDVI از رابطه زیر محاسبه می‌شود.

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}} \quad \text{رابطه (۱۲)}$$


در این معادله NIR، بازتاب در باند فرورسرخ نزدیک و RED، انعکاس در باند سرخ است. از دیدگاه نظری مقدار این شاخص در محدوده -۱ و +۱ می‌باشد. مقادیر این شاخص برای پوشش گیاهی تراکم به‌سوی عدد یک میل می‌کند ولی ابرها، برف و آب با مقادیر منفی مشخص می‌شوند. سنگ‌ها و خاک بایر که واکنش طیفی مشابه در دو باند مورد استفاده دارند با مقادیر نزدیک به صفر دیده می‌شوند. در این شاخص خاک معمولی، معادل یک منظور می‌شود. هر قدر فاصله شاخص یک پیکسل بالاتر از اندازه خاک باشد نشان‌دهنده تراکم پوشش گیاهی است. بررسی‌ها نشان می‌دهد که بیش‌ترین تراکم پوشش گیاهی در محدوده اسلام‌آباد در غرب و آق باش در شمال‌شرق واقع شده است. در شکل (۷) نقشه NDVI برای محدوده حوضه سنگورچای نشان داده شده است.



شکل ۷: شاخص NDVI برای حوضه رودخانه سنگورچای

Figure 7: NDVI index in Songurchay river basin

بررسی زمین‌لغزش‌های موجود (شکل ۸) نشان می‌دهد که در این منطقه اکثر دامنه‌ها تمایل به زمین‌لغزش را در انواع و ابعاد مختلف از خود نشان می‌دهند. برخی از زمین‌لغزش‌ها فعال بوده و برخی دیگر به صورت دوره‌ای عمل می‌کنند. به این منظور در ترسیم نقشه کامل زمین‌لغزش‌های موجود در منطقه مورد مطالعه از منابع مختلفی استفاده شده است. برای اندازه‌گیری زمین‌لغزش‌های قدیمی از عکس‌های هوایی و تصاویر ماهواره‌ای Spot5 بهره گرفته شد. این تصاویر دوره زمانی ۱۹۸۵ تا ۲۰۱۲ را در بر گرفته و از سازمان نقشه‌برداری کشوری و منابع طبیعی اردبیل گردآوری شده است. به واسطه این تصاویر امکان شناسایی دقیق و ترسیم نقشه زمین‌لغزش‌های موجود میسر گردید. نقشه زمین‌لغزش‌های موجود در فهم فاکتورهای موثر در انواع حرکات توده‌ای نقش مهمی را ایفا می‌کند. در مجموع ۱۲۴ زمین‌لغزش شناسایی و ثبت گردید. در زیر موقعیت زمین‌لغزش‌های رخ داده در حوضه رودخانه سنگورچای نشان داده شده است.



شکل ۸: موقعیت زمین‌لغزش‌ها در حوضه رودخانه سنگورچای

Figure 8: Location of landslide in Songurchay river basin

شبکه‌بندی حوضه سنگورچای به منظور وزن دهی به هر یک از لایه‌ها در این تحقیق از روش شبکه‌بندی منظم چهارگوش برای وزن‌دهی لایه‌ها استفاده گردید و کل نقشه‌ها با این نوع شبکه‌بندی، تقسیم‌بندی گردیدند. اندازه شبکه‌ها از خیلی کوچک تا خیلی بزرگ متغیر در نظر گرفته شد. هر چه شبکه‌بندی منطقه با ابعاد کوچک صورت گیرد اطلاعات موجود در پایگاه داده‌ها از دقت فراوانی برخوردار می‌شود.

نتایج نشان داد در مقادیر بزرگ برای واحدها دقت مشخصات عوامل خیلی کم و در مقادیر خیلی کوچک نیز میزان اطلاعات در پایگاه داده‌ها فوق‌العاده زیاد و پردازش آن‌ها مشکل و وقت‌گیر می‌گردد. در این تحقیق اندازه پیکسل‌ها چندین بار تغییر کرد. هر چند با کاهش اندازه پیکسل‌ها دقت افزایش می‌یابد ولی با کاهش اندازه آن‌ها حجم اطلاعات زیاد و تحلیل و کار با آن‌ها بسیار مشکل می‌شود. برای استفاده از این شبکه‌ها بایستی خصوصیات آن‌ها تعیین گردد همچنین خصوصیات شبکه‌هایی که در آن‌ها زمین‌لغزش اتفاق افتاده یا احتمال اتفاق لغزش خیلی کم است نیز بایستی تعیین شود. هر پیکسل از هر نقشه یک سری اطلاعات دریافت می‌کند و بدین ترتیب هر پیکسل حاوی ۷ مشخصه و لایه اطلاعاتی است. این حجم اطلاعات به وسیله منوهای خروج اطلاعات از نرم‌افزار ArcGIS خارج و در محیط MATLAB مورد تحلیل قرار گرفت. در این تحقیق مقدار ۱۰۰ متر مناسب تشخیص داده شد. لذا برای تغذیه این اطلاعات به سیستم پرسپترون چند لایه، منطقه مورد مطالعه با واحدهای مربع شکل با اضلاع ۱۰۰ متر در ۱۰۰ متری شبکه‌بندی گردید. بدین ترتیب کل منطقه به ۸۵۳۰ واحد تقسیم شد. اطلاعات موجود در هر واحد نشانگر مشخصات عوامل موثر در آن‌ها می‌باشد و شامل ۷ لایه اطلاعاتی است.

شبکه عصبی مورد استفاده در پهنه‌بندی زمین‌لغزش

در این مرحله از تحقیق به بررسی موقعیت زمین‌لغزش‌های رخ داده در این حوضه پرداخته شده و وضعیت هر یک از عوامل مورد بررسی که ۷ لایه ورودی به مدل را تشکیل می‌دادند در رخداد زمین‌لغزش مورد پردازش قرار گرفت. یکی از ۷ لایه فوق لایه مربوط به زمین‌لغزش‌های رخ داده هست که از آن در امر صحت سنجی مدل استفاده می‌شود. در بررسی وضعیت این عامل می‌توان به تناسب امکانات موجود از ابزارهای دقیق‌تری چون تصاویر ماهواره‌ای با توان تفکیک بالا بهره گرفت. با مطالعه این نقشه می‌توان مشاهده کرد که نواحی خاصی در حوضه فاقد رخداد زمین‌لغزش قابل توجهی است. این مناطق عمدتاً در شیب‌های کم‌تر از ۵ درجه واقع شده‌اند (Gomez, 2005: 276). تمام اطلاعات فوق در امر تعلیم یا آموزش شبکه به کار برده می‌شوند. بر این اساس تمام حوضه فوق به پیکسل‌هایی تبدیل شده و هر پیکسل به تناسب نقش آن‌ها در زمین‌لغزش نرمالیزه شده و در محدوده بین صفر و یک قرار می‌گیرند. فرایند فوق در نرون‌های ورودی لایه اول که با عنوان لایه ورودی شناخته می‌شود اجرا می‌گردد. برای نرمالیزه کردن داده‌ها از معادله زیر استفاده شد:

$$x_i = \frac{Z_i - Z_i(\min.)}{Z_i(\max.) - Z_i(\min.)} \quad \text{رابطه (۱۳)}$$

در این معادله، Z_i برابر با پیکسل و نمونه مورد نظر، $Z_i(\min.)$ کم‌ترین مقدار در ستون مورد نظر، $Z_i(\max.)$ بیش‌ترین مقدار در ستون مورد نظر و x_i هم اندازه نمونه نرمالیزه شده است. برای مرحله آموزش شبکه از تعداد ۶۸۲۴ نمونه که حدود ۸۰ درصد از اطلاعات را شامل می‌شد استفاده گردید و ۱۷۰۶ نمونه باقی برای مرحله آزمایش شبکه مورد

استفاده قرار گرفت. با به‌کارگیری لایه‌های بیش‌تر، مقدار دقت و توانایی مدل در امر پهنه‌بندی افزایش می‌یابد به نحوی که با افزایش تعداد این عوامل از ۵ عامل به ۷ عامل نقشه پراکنش زمین‌لغزش‌ها، شبکه هیدروگرافی، لیتولوژی، شیب، جهت شیب، NDVI و DEM، میزان خطای شبکه به نحو چشمگیری کاهش یافت؛ بنابراین در این تحقیق لایه‌های ورودی شامل ۷ نرون می‌باشد که بیانگر تعداد عوامل موثر می‌باشد و لایه میانی شامل ۱۸ نرون می‌باشد که تعداد آن توسط آزمون سعی و خطا مشخص گردید و لایه خروجی شامل ۱ نرون می‌باشد که خروجی بین صفر و یک تولید می‌کند.

مقادیر وزنی ماتریس‌های ورودی لایه اول و دوم در بین ۰/۲۵ تا ۰/۲۵ - قرار گرفته و برای پردازش آن‌ها از تابع سیگموئید استفاده شد. در لایه پنهان برای دستیابی به بهترین حالت در ساختار شبکه از انواع مختلف لایه‌های پنهان استفاده شده و ضریب یادگیری در هر کدام متفاوت از دیگری تعیین شده و به تناسب آن‌ها مقادیر خطا برآورد شده و لایه‌های برخوردار از تعداد خطاهای بالاتر حذف گردیدند. در مراحل آزمون و خطا برای ارزیابی مقادیر بهینه ضریب یادگیری از شاخص MSE یا شاخص متوسط مجذور خطا^۴ استفاده شد. قانون یادگیری مطلوب در این تحقیق از نوع قانون یادگیری پس انتشار خطا^۵ می‌باشد. در این نوع از یادگیری بین نرون‌های خروجی و نرون‌های لایه بعدی ارتباط برقرار می‌گردد. زمانی که مقادیر معلوم در مسئله (xi) به لایه‌های ورودی ارائه می‌شود، در وزن اتصال‌های بین لایه ورودی و لایه بعد (wij) ضرب شده و به نرون‌های لایه بعدی منتقل می‌شود. در لایه بعدی تمام ورودی‌های هر نرون با هم جمع شده و پس از اضافه شدن ضریب ثابت بایاس (wo) به آن، نرون خروجی به‌دست می‌آید. معادله لازم برای فرآیند فوق به‌صورت زیر می‌باشد:

$$f(\text{net}_j) = f\left(\sum_{i=1}^n w_{ij}x_i + w_o\right) \quad \text{رابطه (۱۴)}$$


در این تحقیق تعداد نرون‌های لایه پنهان در محدوده بین ۵ تا ۲۰ نرون تعیین شده و هر کدام مورد آزمون قرار گرفته و در تعداد ۱۸ نرون در لایه میانی میزان خطا به شکل چشم‌گیری کاهش یافت. برای هر یک از این لایه‌ها در مرحله آزمون ضریب یادگیری در حدود ۰/۱ تا ۰/۳ تعیین شده و در ضریب ۰/۳ میزان یادگیری در حد مطلوب برآورد شد. در مدل‌های شبکه عصبی بایستی از یادگیری بیش از حد جلوگیری نمود زیرا این امر با افزایش تعداد داده‌های ذخیره شده، کیفیت مدل را در امر شبیه‌سازی کاهش می‌دهد. بر اساس اطلاعات ارائه شده در جدول (۱) مشاهده می‌شود که در مرحله آزمایش تا حدود ۵۸۳۶ دور در یادگیری میزان خطا کاهش یافته و پس از آن دوباره شروع به افزایش می‌کند؛ بنابراین می‌توان چنین استدلال نمود که این حد از یادگیری در مرحله آزمایش نشان دهنده سطح مطلوب در مدل می‌باشد (شکل ۹). با بررسی پاسخ‌های خروجی شبکه عصبی مصنوعی در مرحله آزمایش مشخص گردید که شبکه عصبی ایجاد شده قادر است از میان ۱۸۵ مورد پیکسل لغزشی، ۱۵۹ مورد را به درستی گزارش دهد که نشان دهنده حساسیت تشخیص معادل ۸۳ درصد می‌باشد.

4- Main square error
5- Back error propagation

جدول ۱- مقادیر مربوط به به‌دست آوردن بهینه تکرار در فاکتورهای استخراج شده از حوضه سنگ‌تر چای

Table 1- Values related to obtaining optimal repetition in factors extracted from Songurchay river basin

Epoches	MSE (Training)	SSE (Testing)	MSE (Testing)
۳۵۶	۰/۰۶	۳۵/۳۴	۰/۰۷۳۵۱
۶۹۸	۰/۰۴۳۹۲	۳۴/۸۵۲	۰/۰۶۸۳
۱۲۳۷	۰/۰۴۲۵	۲۹/۷۱۵	۰/۰۵۹۹
۳۸۷۸	۰/۰۳۸۳	۲۹/۴۳۵	۰/۰۵۴۸
۴۷۵۹	۰/۰۳۳۱۵	۲۸/۴۱۲	۰/۰۵۴۵
۵۲۴۸	۰/۰۳۲۵۲	۲۸/۲۵۷	۰/۰۵۳
۵۸۳۶	۰/۰۲۹۹	۲۷/۲۴۳	۰/۰۵۲۱
۶۲۴۸	۰/۰۲۹۶	۲۷/۲۳۱	۰/۰۵۲۳
۶۴۶۶	۰/۰۲۹۳	۲۷/۳۴۲	۰/۰۵۲۸
۶۵۴۹	۰/۰۲۷	۲۷/۷۱۲	۰/۰۵۲۹۶
۶۹۸۲	۰/۰۲۶	۲۸/۱۱۵	۰/۰۵۳۷۵
۷۳۶۶	۰/۰۲۵	۲۸/۳۲۸	۰/۰۵۴۲
۷۸۳۵	۰/۰۲۴	۲۸/۲۲۱	۰/۰۵۴۷
۸۳۴۴	۰/۰۲۳	۲۸/۴۲۶	۰/۰۵۴۸
۸۹۲۶	۰/۰۲۲	۲۸/۳۲	۰/۰۵۴۹
۹۵۳۵	۰/۰۲	۲۸/۲۵۶	۰/۰۵۵۶
۱۴۳۶۵	۰/۰۱۹۲۶	۲۸/۷۱۵	۰/۰۵۶۷۸
۳۸۰۰۰	۰/۰۱۹۱۱	۲۹/۶۲۶	۰/۰۵۷۴۲
۷۹۰۰۰	۰/۰۱۸۵	۳۵/۲۸۹	۰/۰۶۳۱۸



شکل ۹: منحنی‌های مربوط به بهینه تکرار در حوضه سنگور چای

Figure 9: Curves for optimal repetition in the Songurchay River basin

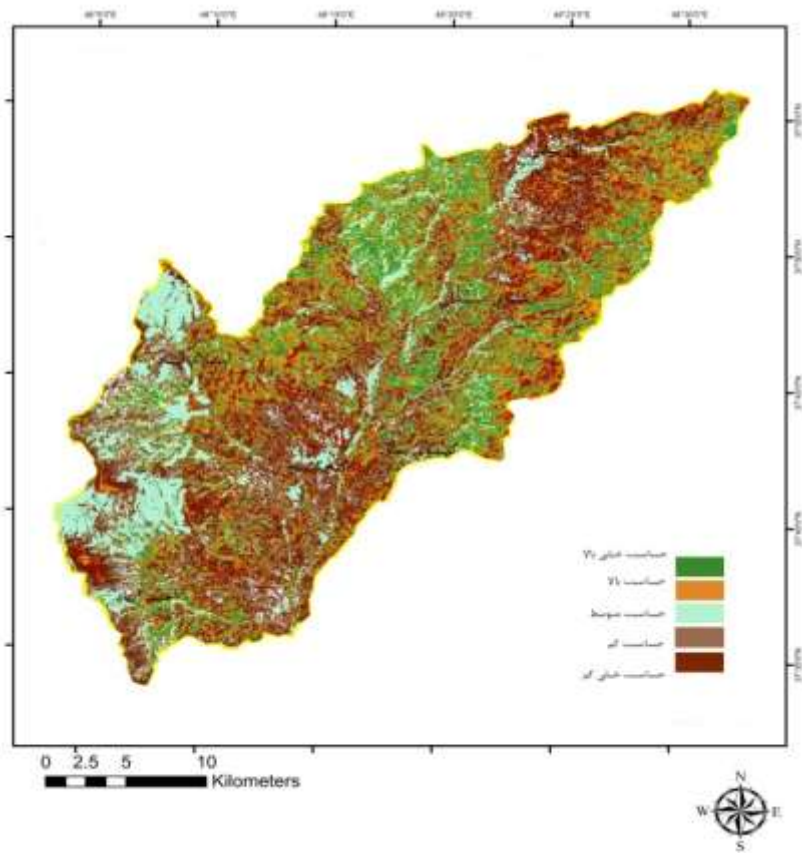
جدول ۲- بهترین مقادیر نرون میانی در هر سطح یادگیری برای حوضه رودخانه سنگور چای

Table 2- The best values of the middle neuron at each level of learning for the Songurchay River basin

تعداد بهترین نرون	خطای SSE	خطای MSE	ضریب یادگیری
۷	۱۵/۶۴۹	۰/۰۳۶۸	۰/۱
۱۱	۱۵/۴۱۸	۰/۰۳۴۷	۰/۲
۱۸	۱۵/۲۴۳	۰/۰۳۲۵	۰/۳

نقشه نهایی پهنه‌بندی خطر زمین‌لغزش

پس از این که با بهره‌گیری از اطلاعات حاصل از ۷ لایه استفاده شده ساختار اصلی لایه ورودی به مدل پرسپترون چند لایه تعیین شد با بهره‌گیری از روش آزمون و خطا مقدار خطای بهینه مشخص شده و بر اساس آن سیستم شبکه عصبی مصنوعی تعلیم داده شد. سپس با در دست داشتن وزن‌های مرحله پایانی مربوط به تعلیم شبکه، کل منطقه که مشتمل بر ۸۵۳۰ پیکسل بود در اختیار شبکه قرار گرفت. هر پیکسل از مقدار نرمالیزه شده‌ای که بین صفر تا یک است برخوردار بوده و بر اساس این مقادیر مشخص می‌گردد که هر منطقه از نظر لغزش خیزی در چه سطحی قرار دارد. در نهایت نقشه نهایی پهنه‌بندی زمین‌لغزش برای حوضه رودخانه سنگور چای با بهره‌گیری از برنامه نوشته شده در محیط MATLAB تهیه گردید. نقشه فوق در زیر نمایش داده شده است.



شکل ۱۰: نقشه پهنه‌بندی زمین‌لغزش حوضه رودخانه سنگورچای با استفاده از مدل پرسپترون چند لایه از نوع پیش‌خور پس انتشار
 Figure 10: landslide susceptability zoning map by of using multilayer perceptron type forward-back propagation in Songurchay river basin



شکل ۱۲: نمایی از یک لغزش در حوضه رودخانه سنگورچای
 Figure 12: View of landslide in Songurchay river basin



شکل ۱۱: نمایی از زمین‌لغزش‌های در حوضه رودخانه سنگورچای
 Figure 11: View of landslide in Songurchay river basin

نتیجه‌گیری

در این تحقیق مناطق مستعد زمین‌لغزش در قالب مراحل شناسایی زمین‌لغزش‌های رخ داده، انتخاب ورودی‌های مورد استفاده در پهنه‌بندی زمین‌لغزش، پردازش داده‌های ورودی در محیط MATLAB و ترسیم نقشه پهنه‌بندی زمین‌لغزش مورد بررسی قرار گرفت. منطقه سنگورچای به علت جنگل‌زدایی، ارتفاع زیاد و رطوبت بالا با مشکل زمین‌لغزش مواجه است. به علت مشارکت چندین فاکتور ورودی در مدل پرسپترون چند لایه این مدل نقش مهمی را در پهنه‌بندی زمین‌لغزش ایفا می‌کند. بررسی‌ها نشان داد که فاکتورهای شیب، جهت شیب، DEM، لیتولوژی، شبکه هیدروگرافی، لایه NDVI و پراکنش زمین‌لغزش می‌تواند اطلاعات مفیدی جهت پهنه‌بندی نمودن منطقه از نظر استعداد لغزش فراهم نماید. بدین صورت که با افزایش تعداد عوامل از ۵ عامل به ۷ عامل، میزان خطای شبکه به نحو چشمگیری کاهش می‌یابد. میزان خطا در صورتی که لایه میانی از ۱۸ نرون تشکیل یابد به کم‌ترین میزان خود می‌رسد. همچنین مقادیر خطای Mse در میزان یادگیری ۰/۳ به حدود ۰/۰۳۲۵ می‌رسد که در مقایسه با ضرایب دیگر در حد بسیار پایینی قرار داشته است. نقشه نهایی پهنه‌بندی نشان می‌دهد که بیش‌تر مناطق با خطر خیلی زیاد در مناطق شرقی منطقه قرار می‌گیرد که با توجه به شرایط زمین‌شناسی و اقلیمی حاکم بر این منطقه این موضوع قابل تایید است. در کل، نتایج نهایی نشان می‌دهد که مدل پرسپترون چند لایه ابزار قدرتمندی برای ارزیابی مناطق مستعد زمین‌لغزش می‌باشد.

References

- Abadinejad, S. A., Yamani, M., Maghsoudi, M., Shadfar, S., (2007), "Evaluation of fuzzy logic operators in landslide analysis case study: shirood watershed", *Jwmseir*, 1: 39-44. [In Persian].
- Alexander, I., Morton, H., (1990), "*An introduction to neural computing*", Chapman and Hall: London.
- Anbalagan, R., (1992), "Landslide susceptibility evaluation and zonation mapping in mountainous terrain", *Eng. Geol.*, 32: 269-277.
- Atkinson, P., Tatnall, A., (1997), "Neural networks in remote sensing", *International Journal of Remote Sensing*, 18: 699-709.
- Ayalew, L., Yamagishi, H., (2005), "The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko mountains, central Japan", *Geomorphology*, 65: 15-31.
- Biswajeet, P., (2010), "Remote sensing and GIS based landslide hazard analysis and cross validation using multivariate logistic regression model on three test area in Malaysia", *Advances in Space Research*, 12: 14-27.
- Borgogno Mondino, M., Giardino, L., Perotti, K., (2009), "A neural network method for analysis of hyperspectral", *Geomorphology*, imagery with application to the Cassas landslide (susa valley, NW Italy), 110: 20-27.
- Cubito, A., Ferrara, V., Pappalardo, G., (2005), "Landslide hazard in the Nebrodi Mountains (Northeastern Sicily)" *Geomorphology*, 66: 359-372.
- Ermini, L., Catani, F., Casagli, N., (2005), "Artificial neural networks applied to landslide susceptibility assessment", *Geomorphology*, 66: 327-343.
- Fernandes, N., Guimaraes, R., Gomes, R., Vieira, B., Montgomery, D., Greenberg, H., (2004), "Topographic controls of landslides in Rio de Janeiro: Field evidence and modeling", *Catena*, 55: 163-181.
- feyzolahpour, M., (2017), "Suspended sediment load estimation by using feed forward backpropagation (FFBP) and radial basis function (RBF) (Songurchay river)", *Journal of Geographical Space*, 56: 115-131. [In Persian].
- Gokceoglu, C., Sonmez, H., Nefeslioglu, H., Duman, T., Can, T., (2005), "The 17 March 2005 Kuzulu landslide (Sivas, Turkey) and landslide susceptibility map of its near vicinity", *Engineering Geology*, 81: 65-83.
- Gomez, H., Kavzoglu, T., (2005), "Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa river basin, Venezuela", *Eng. Geol.*, 78: 11-27.
- Guyon, I., Wang, P., (1993), "Advances in pattern recognition systems using neural network technologies", *World Scientific*, pub: New Jersey.
- Ishik, Y., (2009), "Landslide susceptibility mapping using frequency ratio, logistic regression, artificial neural networks and their comparison: A case study from Kat landslides (Tokat-Turkey)", *Computers & Geoscience*, 35: 1125-1138.
- Iwahashi, J., Watanabe, S., Furuya, T., (2003), "Mean slope–angle frequency distribution and size frequency distribution of landslide masses in Higashikubiki area, Japan", *Geomorphology*, 50: 349-364.

- Jafari, T., Gholi mokhtari, L., Naemi Tabar, M., (2019), "Zoning the risk of landslide in badranlou basin using the analytic network process", *Journal of geographical space*, 66: 1-17. [In Persian].
- Lee, S., Min, K., (2001), "Statistical analysis of landslide susceptibility at Yongin, Korea", *Environmental Geology*, 40: 1095-1113.
- Lee, S., Ryu, J., Min, K., Won, J., (2003), "Landslide susceptibility analysis using GIS and artificial neural networks", *Earth Surface Processes and Landforms*, 28: 1361-1376.
- Lu, P., Rosenbaum, M. S., (2003), "Artificial neural network and grey system for the prediction of slope stability", *Natural Hazards*, 30: 383-398.
- Melchiorre, C., Matteucci, M., Azzoni, A., Zanchi, A., (2006), "Artificial neural networks and cluster analysis in landslide susceptibility zonation", *Geomorphology*, 94: 379-400.
- Moreiras, S. M., (2005), "Landslide susceptibility zonation in the Rio Mendoza Valley, Argentina", *Geomorphology*, 66: 345-357.
- Rumelhart, D., Hinton, G., Williams, R., (1986), "Learning internal representations by error propagation", In: Rumelhart, D. E., McLelland, J. L., (Eds.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, *In MIT Press, Cambridge*, pp 318-362.
- Wang, D., Pu, R., Gong, P., Yang, R., (1995), "Predicting forest yield with an artificial neural network and multiple regression", *Chinese University of Hong Kong*: Hong Kong.
- Zezere, J., Ferreira, A., Rodrigues, M., (1999), "The role of conditioning and triggering factors in the occurrence of landslides: A case study in the area north of Lisbon (Portugal)", *Geomorphology*, 30: 133-146.