



"مقاله پژوهشی"

شبیه‌سازی مناطق مستعد سیلاب با استفاده از شبکه عصبی پرسپترون و سیستم اطلاعات جغرافیایی (منطقه مورد مطالعه: حوزه آبخیز زولاچای، شهرستان سلماس)

قورمیک وحید عیسی‌زاده^۱ و بنی زهرا علی‌بیگی^۲

۱- دانشجوی کارشناسی ارشد دانشگاه تهران، (نویسنده مسوول: vahidisazade75@gmail.com)

۲- دانشجوی کارشناسی ارشد دانشگاه تهران

تاریخ ارسال: ۱۳۹۹/۱۰/۴ تاریخ پذیرش: ۱۴۰۰/۲/۱

صفحه: ۹۷ تا ۱۰۸

چکیده مبسوط

مقدمه و هدف: امروزه پدیده سیل یکی از پیچیده‌ترین رخدادهای مخاطره‌آمیز است که بیش از سایر بلایای طبیعی دیگر، همه‌ساله در نقاط مختلف دنیا منجر به ایجاد خسارت‌های جانی و مالی و تخریب اراضی کشاورزی می‌شود.

مواد و روش‌ها: به دلیل سیل‌خیز بودن حوزه آبریز زولاچای، شهرستان سلماس بررسی و شبیه‌سازی خطر وقوع سیل در این منطقه ضروری به نظر می‌رسد. لذا در این پژوهش از تلفیق شبکه عصبی مصنوعی پرسپترون (MLP) و GIS استفاده شده است. ابتدا پارامترهای تأثیرگذار در شبیه‌سازی مناطق سیلابی نظیر: لایه شیب، ارتفاع، جهت جریان، خاک و کاربری اراضی مورد بررسی قرار گرفته و این لایه‌های اطلاعاتی وارد نرم‌افزار ArcGIS5.3 شدند. لایه‌های اطلاعاتی مورد نظر با دستور Fishnet مورد پردازش قرار گرفتند و هرکدام از لایه‌ها به point تبدیل شدند و این داده به همراه داده‌های تعلیمی که از گوگل ارث دریافت شده بود به شبکه عصبی معرفی شد. در شبکه عصبی پرسپترون لایه‌های ورودی شامل ۵ نورون و ۱۶ گره وارد مدل شدند.

یافته‌ها: نتایج نشان داد، ارتفاع دارای کم‌ترین وزن ($R^2=0.713$) و بیشترین وزن مربوط به جهت جریان ($R^2=0.913$) در شبیه‌سازی سیلاب حوزه آبخیز زولاچای، شهرستان سلماس می‌باشد.

نتیجه‌گیری: می‌توان بیان کرد تلفیق GIS و شبکه عصبی مصنوعی می‌تواند برای مدل‌سازی و شبیه‌سازی سیلاب در محیط‌های مکانی مختلف برای جلوگیری و کاهش خسارت‌های محیطی بسیار مفید واقع شود.

واژه‌های کلیدی: حوزه آبخیز زولاچای شهرستان سلماس، سیل، شبکه عصبی مصنوعی پرسپترون، Fishnet

مقدمه

هر جریان سطحی آب، صرف نظر از عامل ایجادکننده آن در صورتی سیلاب تلقی می‌شود که جریان آب در مقطع رودخانه بیش از جریان عادی باشد، تداوم زمانی آن محدود بوده، جریان آب از بستر طبیعی تجاوز کند، اراضی پست و حاشیه رود را فراگیرد و خسارت جانی و مالی به همراه داشته باشد (۲۱).

با این تعریف سیل جریان غیر متعارف آب در بیرون از بستر معمول آن می‌باشد. وقوع این پدیده در نتیجه اندرکنش عوامل جوی و محلی موجب تشدید یا تصیف سیلاب می‌شود نوع، حجم و شدت بارش، پوشش گیاهی، جنس خاک، شیب از عوامل مؤثر بر سیلاب هستند. در نواحی خشک نوسان شدیدی در بارش وجود دارد، بارش‌های این نواحی اغلب اتفاقی، رگباری و بسیار شدید هستند علاوه بر این پوشش گیاهی نامطلوب است. بنابراین وقوع این رگبارهای شدید سبب جاری شدن حجم زیادی از آب شده و بعضاً سیلاب‌های سهمگینی را ایجاد می‌کنند که سبب خسارات مالی، جانی و محیطی می‌شوند. جهت برآورد دبی سیلابی در حوضه‌های فاقد آمار، از مدل‌های تجربی مختلفی از جمله روش تحلیل منطقه‌ای سیلاب، استفاده می‌شود. اما به دلیل آنکه هر حوضه آبریز ویژگی‌های خاص خود را دارا می‌باشد، لازم است روش‌های استفاده شود که بتوان براساس خصوصیات ذاتی هر حوضه، دبی سیلابی آن را شبیه‌سازی نماید. طی دهه‌های اخیر، مدل شبکه‌های عصبی مصنوعیه ابزاری برای شبیه سازی و پیش‌بینی تبدیل شده و نتایج قابل قبولی در زمینه‌های مختلف از خود نشان داده است (۲۳).

شبکه عصبی مصنوعی به‌طور نسبتاً محدودی در پیش‌بینی جریان آبراهه‌ای و جریان سیلابی مورد نقد و بررسی قرار گرفته و نتایج به دست آمده حاکی از عملکرد مناسب آن بوده است (۲۵، ۲۴).

امروزه یکی از ابزارها و روش‌های مطرح در مقابله با پدیده سیل که در برخی از کشورهای جهان رایج گشته، سامانه‌های پیش‌بینی و هشدار سیل می‌باشد که تجارت دهه‌های اخیر در این کشورها، نشان داده که با اجرا و طراحی صحیح این سیستم‌ها، می‌توان خسارات جانی و مالی ناشی از سیل را به میزان چشم‌گیری کاهش داد (۲۱).

شبکه‌های عصبی ابزار محاسباتی قوی و توانمندی هستند که در سازمان دهی و ایجاد رابطه بین اطلاعات گوناگون نیز قابلیت بسیار خوبی داشته‌اند. به‌طور کلی، در برخورد با مسائلی از قبیل شناسایی سیستم تقریب تابع، بهینه‌سازی و پیش‌بینی هدف نتایج موفقیت‌آمیزی داشته‌اند (۲۸).

تاکنون مطالعات زیادی در خصوص موضوع سیل‌خیزی انجام شده است. از جمله در بعد بین‌المللی می‌توان به تحقیقات دووینت و همکاران (۳) از اتو مات سلولی برای ارزیابی تأثیرات مورفولوژیکی بر هیدرولوژی حوضه در خلال تمرکز فوق‌العاده سیلاب‌ها در حوضه پاریس استفاده نمودند و بیان کردند که ترکیب توپوگرافی و مساحت رواناب و شیب می‌تواند توزیع پیچیده تمرکز جریان در زمان و فضا را توضیح دهد.

کای و همکاران (۱) یک مدل ریاضی داتان برای مسیریابی سیلاب بر پایه اتومات سلولی به کار بردند. نتایج نشان داد سیلاب در همه جهات به‌طور منظم گسترش نمی‌یابد. بلکه نخست به سمت مناطق پایین‌دست جریان می‌یابد و مناطق را

نشان داد که مدل شبکه عصبی بر مدل‌های رگرسیون چند متغیره ارجحیت داشته و فاکتورهای ژئومورفولوژیکی اثر قابل توجهی در نتایج مدل دارند.

گیسیوانتاین و همکاران (۱۰) کارایی شبکه عصبی موجک را جهت پیش‌بینی دبی سیلابی رودخانه آبرتا در کانادا مورد بررسی قرار دادند که نتایج حاصله نشان داد مدل شبکه عصبی موجک خطایی ناچیز در تخمین دبی داشته و نیز نسبت به روش شبکه عصبی مصنوعی در تخمین اکثر مقادیر دقت بالایی دارد. الساقی (۵) در پژوهش جهت پیش‌بینی سیل در ایستگاه دانگ لا سودان از شبکه عصبی مصنوعی استفاده نمودند نتایج نشان داد که شبکه عصبی مصنوعی مدلی مناسب و قابل اعتماد جهت پیش‌بینی دبی سیل است.

دلال اوغلی و همکاران (۴) به ارزیابی و تهیه پهنه‌های سیل‌خیز در حوضه رودخانه آجر لوجای با استفاده از رویکرد نوین سیستم‌های تصمیم‌گیری چند شاخصه و مدل فازی اقدام کردند. در این مطالعه از ۸ پارامتر طبیعی و انسانی استفاده کردند. نتایج آن‌ها نشان داد که پهنه‌های با خطر بسیار زیاد در بالادست حوضه قرار دارند.

قلی‌زاده و همکاران (۷) به ارزیابی و پهنه‌بندی خطر سیل در حوضه زنگمار در شهرستان ماکو با استفاده از مدل فازی پرداختند. آن‌ها به این منظور از لایه‌های اطلاعاتی مربوط به شیب، ارتفاع، انحنای پلانی متریک، انحنای پروفیل، کاربری اراضی و شاخص NDVI استفاده کردند. نتایج نشان داد که در نقشه نهایی پهنه‌بندی خطر سیل‌خیزی، نواحی با خطر بسیار بالا در بالادست و شمال حوضه قرار دارند.

قنوتی و همکاران (۲۲) به ارزیابی و پهنه‌بندی خطر رخداد سیلاب در حوضه فرحزاد تهران با استفاده از منطق فازی پرداختند که در این زمینه اقدام به تهیه لایه‌های اطلاعاتی هم چون شیب، انحناء پروفیل، پلانی متریک، ارتفاع، تراکم زهکشی و فاصله از آبراهه، لند فرم‌ها و کاربری اراضی کردند. نتایج نشان داد نواحی با خطر سیل بسیار بالا در پایین‌دست حوضه و منطبق بر دره‌اصلی فرحزاد هستند.

رضایی و همکاران (۳۰) با استفاده از خصوصیات فیزیوگرافی حوضه آبریز سفیدرود و بارندگی‌های یک و پنج روز ماقبل سیل نظیر، اقدام مدل‌سازی منطقه‌ای دبی اوج نمودند. در تحقیق مذکور، شبکه مطلوب از نوع پیش‌خور و با دولایه پنهان بود. همچنین این نتایج بیانگر ارجحیت کامل مدل شبکه عصبی مصنوعی بر روش‌های سنتی بوده است.

یمانی و عنایتی (۲۹) پهنه‌بندی خطر سیل در حوضه‌های فشنند و بهجت آباد (واقع در استان‌های تهران و قزوین) را با استفاده از خصوصیات ژئو مورفولوژیک حوضه‌ها و بکارگیری روش وزن‌دهی در محیط سامانه اطلاعات جغرافیایی (GIS) دادند. نتایج حاصله بیانگر آن است که حوضه گراولیوس کمتر، ضریب سیل‌خیزی بیشتری دارا هستند.

نگارش و همکاران (۱۶) در پژوهشی جهت پیش‌بینی سیلاب رودخانه سرباز از شبکه عصبی مصنوعی و داده‌های روزانه اقلیمی و هیدرولوژیکی سه ایستگاه سرباز، ابرانشهر و پیر دان طی یک دوره ۲۸ ساله بهره گرفتند. برای این منظور از سه لایه شبکه پرسپترون چند لایه، پس انتشار و RadialBasis

به سرعت می‌پوشاند. تجزیه و تحلیل آن‌ها نشان داد مدل ارائه شده می‌تواند ابزاری ارزشمند برای مسیریابی سیل باشد. لیانگ و همکاران (۱۴) با استفاده از سیستم اطلاعات جغرافیایی، در منطقه ماها نادی واقع در اوراسیای هندوستان، اقدام به پهنه‌بندی سیل کردند. آن‌ها مدیریت سیلاب‌ها را بر اساس پهنه‌بندی به‌منزله یک روش غیرسازه‌ای کنترل سیلاب معرفی و آن را بهینه کردند.

کوریا و همکاران (۱۲) با استفاده از سیستم اطلاعات جغرافیایی و مدل‌های هیدرولوژیکی و هیدرولیکی، در دشت‌های سیلابی که با توسعه شهر همراه است و در معرض خطر سیل قرار دارند، تأثیر کنترل کاربری اراضی در کاهش خطر سیل را ارزیابی و در ادامه اقدام به پهنه‌بندی و آنالیز سیل کردند.

هانگ و همکاران (۹) با استفاده از روش وزن شواهد و سایر تکنیک‌های داده کاوی اقدام به تهیه نقشه حساسیت سیل در شهرستان پویانگ در کشور چین کردند. به این منظور لایه مربوط به سنگ‌شناسی، خاک، ارتفاع، درجه شیب، جهت، شاخص رطوبت توپوگرافی، شاخص قدرت جریان، انحنای دامنه و فاصله از شبکه آبراهه در محیط نرم‌افزار ARCGIS تهیه شد و سپس با استفاده از روش فازی وزن شواهد و تکنیک‌های داده کاوی مثل رگرسیون لجستیک، جنگل تصادفی و ماشین بردار پشتیبان نقشه حساسیت سیل به دست آمد. نتایج نشان داد که مدل فازی وزن شواهد- ماشین بردار پشتیبان بالاترین توانایی در تهیه نقشه حساسیت سیل داشته است.

ژائو و همکاران (۲۷) به‌منظور تهیه نقشه حساسیت سیل در مناطق کوهستانی کشور چین از داده‌های سیلاب‌های تاریخی دوره زمانی ۱۹۴۹ تا ۲۰۰۰ و مدل جنگل تصادفی استفاده کردند. نتایج پژوهش آن‌ها نشان داد که مدل جنگل تصادفی در شناسایی مناطق مستعد سیل عملکرد مؤثری دارد. ساهو و همکاران (۲۰) در تحقیقی با استفاده از شبکه عصبی مصنوعی در رودخانه‌های کوهستانی حوضه مشخصه منطقه اوهایو آمریکا به پیش‌بینی پارامترهای کیفیت آب (دما، کدورت، اکسیژن محلول و PH) و نیز سیلاب ناگهانی منطقه پرداختند. نتایج مربوطه، نشان‌دهنده توان بالای شبکه عصبی مصنوعی در پیش‌بینی پارامترهای مذکور بود.

کرج و لی (۱۱) در کشور تایوان در حوضه رودخانه کویپنگ با بکارگیری شبکه عصبی مصنوعی، برآورد دبی سیلابی را در پایین دست حوضه مزبور برآورد نمودند. نتایج آن‌ها نشان‌دهنده تأثیر قابل توجه خصوصیات فیزیوگرافی بالادست در دقت پیش‌بینی دبی سیلابی بوده و این روش را جهت پیش‌بینی دبی سیلابی و ارائه نظرات مهندسی در حوضه‌های فاقد آمار پیشنهاد نمودند.

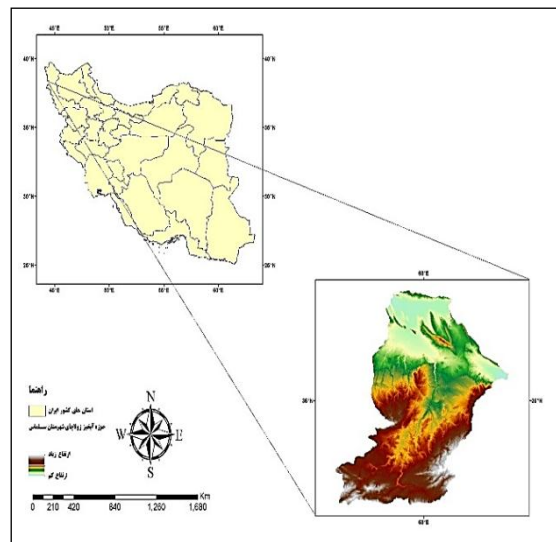
توسط داوسون و همکاران (۲) در یکی از حوضه آبریز کشور ایرلند انجام گرفته با استفاده از شبکه عصبی مصنوعی و خصوصیات ژئومورفولوژیکی زیر حوضه‌ها اقدام برآورد دبی سیلاب برای دوره‌های بازگشت ۱۰، ۲۰ و ۳۰ ساله و همچنین سیلاب شاخص گردید. نتایج مدل شبکه عصبی با روش‌های تجربی برآورد سیلاب‌ها مقایسه شد. نتایج تحقیق

مواد و روش‌ها

منطقه مورد مطالعه

حوزه آبخیز زولاچای شهرستان سلماس (چهریق علیا) به عنوان بخشی از حوضه آبخیز دریاچه ارومیه، در جنوب غربی شهرستان سلماس در استان آذربایجان غربی در منطقه مرزی ایران و ترکیه واقع شده است. این حوضه با مساحت ۸۲۳ کیلومترمربع در محدوده ۳۸° تا ۱۱' و ۵۱" شمالی و ۴۴° تا ۴۶' و ۱۶" شمال شرقی واقع شده است. مرتفع‌ترین نقاط حوزه در امتداد مرز بین ایران و ترکیه در دامنه کوه هراول داغ و کوه قراداش به ارتفاع ۳۰۰۰ متر و کم ارتفاع‌ترین نقطه حوزه دارای ارتفاع ۱۴۵۰ متر از سطح دریا در محل خروجی زولاچای شهرستان سلماس (چهریق علیا) است (۱۹). موقعیت جغرافیایی منطقه مورد مطالعه در شکل (۱) نشان داده شده است.

جهت پیش‌بینی سیلاب رودخانه سرباز استفاده کردند با بررسی همبستگی بین این داده‌ها و دبی رودخانه سرباز پارامترهای مؤثر بر سیلاب انتخاب و پس از نرمالیزه کردن داده‌ها، مدل‌های مختلف ایجاد نمودند و نشان دادند مدل شبکه عصبی پیش‌بینی بهتری نسبت به روش رگرسیونی از سیلاب رودخانه سرباز ارائه می‌دهد. از آن جا که نقش عوامل طبیعی و انسانی در وقوع سیل مؤثر می‌باشد و تفاوت در میزان سیل‌خیزی حوضه‌ها هم‌جوار توسط دخالت انسان‌ها و تفاوت‌های ویژگی‌های طبیعی آن‌ها قابل توجیه می‌باشد. با توجه به پیشینه تحقیق استفاده از سیستم اطلاعات جغرافیایی و شبکه عصبی از استقبال بالایی برخوردار بوده است. هدف از پژوهش حاضر به کارگیری شبکه عصبی مصنوعی پرسپترون و سیستم اطلاعات جغرافیایی برای شبیه‌سازی مناطقی که در حوزه آبخیز زولاچای شهرستان سلماس سیلاب هستند. تا با استفاده از این شبیه‌سازی بتوان مدیریت درستی را برای مناطق سیل‌خیز در منطقه مورد مطالعه اتخاذ کرد.



شکل ۱- موقعیت کشوری حوزه آبخیز زولاچای شهرستان سلماس (منبع: نگارندگان، ۱۳۹۸)
Figure 1. Country location of Zolachai watershed in Salmas city

۳۰ متری، نقشه خاک، نقشه کاربری اراضی، جهت جریان و نقشه شیب منطقه مورد مطالعه در نرم‌افزار ARCGIS5.3 تولید شدند و همچنین داده‌های تعلیمی که در گوگل ارث از منطقه مورد نظر برداشت شد. نقشه‌های تولیدشده در نرم‌افزار ARCGIS5.3 نقشه‌های رستر تبدیل شدند و این نقشه‌های رستری با دستور Fishnet مورد پردازش قرار گرفته و این دستور به ازای هر پیکسل یک عدد را در جدول توصیفات نشان داد. در ادامه نقشه Fishnet شده از نقشه‌های رستری را با دستور Extract by Mask برش داده شد و داده‌های Fishnet شده را در جدول توصیفات به همراه داده‌های تعلیمی به صورت ماتریس ایجاد و وارد شبکه عصبی پرسپترون شدند و نتایج حاصل از شبکه عصبی پرسپترون به صورت اعداد نشان داده شد و در نتیجه این اعداد روی منطقه مورد مطالعه در نرم افزار ذکر شده مورد پهنه‌بندی قرار گرفت و در نهایت مناطق مستعد سیلاب استخراج شد.

به‌منظور توسعه مدل سیلاب، درک و تعیین عوامل ایجادکننده سیلاب برای منطقه مورد مطالعه بسیار مهم در نظر گرفته شده است. این عوامل بر اساس دانش به‌دست آمده انتخاب می‌شوند. یک بررسی از تحقیقات پیشین مانند برنامه محیط‌زیست سازمان ملل متحد و مطالعات میدانی برای شبیه‌سازی و مدل‌سازی سیلاب می‌باشد (۲۶).

اما در همه شرایط محیطی امکان‌پذیر نیست. برای کاهش و جلوگیری از تلفات، مسئولان و مدیران باید بدانند و آگاه باشند که سیل بعدی کجا اتفاق خواهد افتاد برای پیش‌گیری از موارد ذکر شده یک روش دقیق برای پیش‌بینی لازم است. در سال‌های اخیر مطالعات زیادی در مورد حساسیت به سیلاب و نقشه‌برداری از خطر با استفاده از داده‌های سنجش از دور و ابزارهای GIS انجام شده است. از داده‌های سنجش از دور رادار برای نظارت بر سیل در سراسر جهان استفاده گسترده‌ای شده است. ابتدا در پژوهش حاضر نقشه مدل رقومی ارتفاعی

شبیه‌سازی سیل

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی به‌عنوان مدل‌های ریاضی از درک انسان هستند. که می‌توانند بر اساس داده‌های تجربی موجود برای انجام یک کار خاص آموزش ببینند. وقتی روابط بین داده‌ها ناشناخته باشد، می‌توانند ابزاری قدرتمند برای مدل‌سازی در نظر گرفته شوند (۱۳) و اساس ریاضی ANNها توسط بسیاری از محققان با جزئیات توضیح داده شده است (۸).


ANN شامل تعدادی نورون یا گره است که به‌طور موازی کار می‌کنند تا داده‌های ورودی را به دسته‌های خروجی تبدیل کنند. به‌طور معمول، ANN از سه لایه یعنی ورودی، لایه‌های پنهان و خروجی تشکیل شده است. هر لایه بسته به کاربرد خاص در یک شبکه، دارای برخی از سلول‌های عصبی است. هر نورون در لایه متوالی بعدی با پیوندهای مستقیم به سلول‌های عصبی دیگر متصل می‌شود. این پیوندها دارای وزنی هستند که قدرت سیگنال خروجی را نشان می‌دهد. تعداد سلول‌های عصبی موجود در لایه‌های خروجی توسط برنامه ثابت‌شده و توسط کلاس در حال پردازش نشان داده می‌شود. هر نورون پنهان به ورودی‌های وزنی که از سلول‌های عصبی

متصل شده از لایه ورودی قبلی دریافت می‌کند. پاسخ می‌دهد پس از تعیین اثر ترکیبی در هر نورون پنهان، فعال شدن در این نورون از طریق یک تابع انتقال مشخص می‌شود. بسیاری از کارکردهای غیرخطی متمایز به‌عنوان یک تابع انتقال در دسترس هستند.

نتایج و بحث

نقشه خاک

منطقه مورد مطالعه با چهار نوع مختلف از خاک مشخص شد غالب‌ترین سری خاک منطقه مورد مطالعه خاک (Torrifluvents) است. این خاک حدود ۶۵ درصد از منطقه مورد مطالعه را اشغال کرده است. اراضی شیب‌دار حدود ۶/۵ درصد از منطقه مورد نظر را در بر گرفته که این مناطق در قسمت‌های شمال و شمال غربی حوضه آبخیز یافت می‌شوند. و خاک (Haplocambids) حدود ۱۰/۲ درصد را در بر گرفته و عمدتاً این مناطق در دره‌های یافت می‌شوند. می‌توان بیان کرد که مرکز حوضه آبخیز بیشتر در قسمت‌های شمالی منطقه مورد مطالعه قرار گرفته بنابراین توزیع مکانی انواع خاک‌ها در شکل (۲) نشان داده شده است.




شکل ۲- نقشه خاک حوزه آبخیز زولاچای شهرستان سلماس (منبع: نگارندگان، ۱۳۹۸)

Figure 2. Soil map of Zolachai watershed in Salmas city

عالی برای عوامل استخراج توپوگرافی سیل در یک منطقه است. از آن جا که نتایج حاصل از مدل طغیان باید برای تعیین مناطق مستعد از سیل روی DEM نشان دهد DEM باید از دقت مناسب برخوردار باشد (۱۷). بنابراین نقشه رقومی ارتفاعی از شمارگرهای ۱: ۲۵۰۰۰ تشکیل شده است که در شکل (۳) نشان داده شده است.

نقشه مدل رقومی ارتفاعی

توپوگرافی به‌عنوان یک عامل تشدیدکننده، نقش مهمی در شدت سیل و برای تعیین منطقه سیلاب ایفای می‌کند. از یک طرف، عوامل توپوگرافی تأثیر مستقیمی بر اندازه جریان و سرعت رواناب دارند. از طرف دیگر، مناطق مستعد سیلاب رودخانه اکثراً دارای ارتفاع کم و همچنین شیب توپوگرافی کمی هستند. مدل‌های رقومی ارتفاعی (DEM) یک منبع

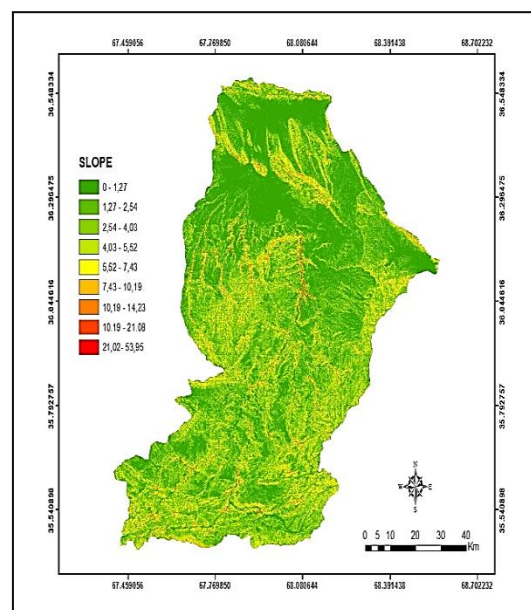


شکل ۳- نقشه مدل رقومی ارتفاعی حوزه آبخیز زولاچای شهرستان سلماس (منبع: نگارندگان، ۱۳۹۸)
Figure 3. Digital elevation model map of Zolachai watershed in Salmas city

جریان‌های سریع‌تری تولید می‌کنند، اما در دامنه‌های ملایم سیل رخ می‌دهد. برآورد زاویه شیب برای حوضه نقشه‌های مدل رقومی ارتفاعی گرفته شده و به چهار کلاس تقسیم شده است که در شکل (۴) نشان داده شده است.

نقشه شیب

شیب توپوگرافی به‌عنوان زاویه بین سطح و یک داده افقی تعریف می‌شود. این بدان معنی است که جاذبه در القای رواناب و سرعت آن تأثیر دارد. بنابراین این عامل در هیدرولوژی بسیار مهم است (۶). اگرچه دامنه‌های تندتر



شکل ۴- نقشه شیب حوزه آبخیز شهرستان سلماس (منبع: نگارندگان، ۱۳۹۸)
Figure 4. Slope map of Salmas city watershedcity


پرشده DEM تهیه شده است که یکی از کلیدهای استخراج ویژگی‌های هیدرولوژیکی یک سطح است. این عملکرد جریان هر سلول را هدایت می‌کند. مقادیر موجود در پیکسل‌های حاصل از شبکه جهت جریان، جهت حرکت شدیدترین سیل را

نقشه جهت جریان

بسیاری از سیل‌ها در زهکشی با چگالی بالا به دلیل تجمع مقدار زیادی آب رخ می‌دهد. برای ساخت این لایه یک لایه داده زهکشی از DEM با جهت جریان برای هر سلول

شبیه‌سازی مناطق مستعد سیلاب با استفاده از شبکه عصبی پرسپترون و سیستم اطلاعات جغرافیایی ۱۰۲

نشان می‌دهد. بعداً تجمع جریان با استفاده از تعداد انباشته پیکسل‌ها در بالا دست محاسبه شد. از نتایج تجمع جریان می‌توان برای ایجاد یک شبکه جریان با طبقه‌بندی مقادیر پیکسل استفاده کرد که در شکل (۵) نشان داده شده است.

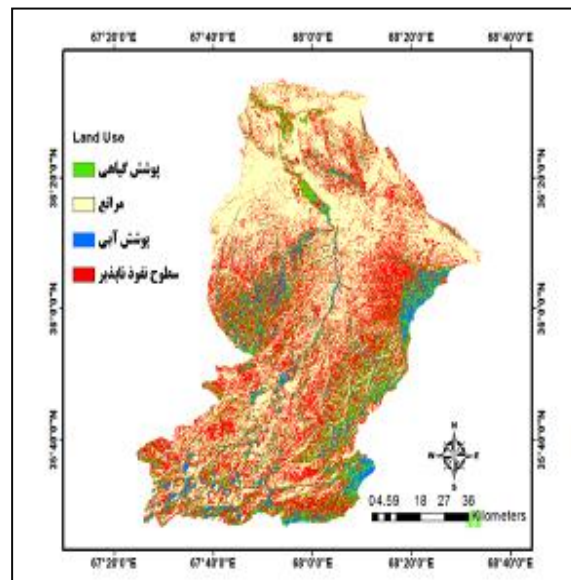


شکل ۵- نقشه جهت جریان حوزه آبخیز زولاچای شهرستان سلماس (منبع: نگارندگان، ۱۳۹۸)
Figure 5. Map for the flow of Zolachai watershed in Salmas city

با مناطق مشابه، میزان رواناب بیشتری را به همراه دارد. که توسط چمنزار یا جنگل پوشیده شده است. برای تعریف این فاکتور، این لایه تهیه شده و چهار کلاس تحت پوشش اراضی غالب از جمله پوشش گیاهی، مراتع، پوشش آبی و سطوح نفوذناپذیر در نظر گرفته شده است. می‌توان کلاس‌های کاربری اراضی در شکل (۶) نشان داده شده است.

نقشه کاربری اراضی

کاربری اراضی و نوع پوشش اراضی نیز عوامل مهمی در بروز سیلاب هستند. وقوع سیل رابطه معکوس با تراکم پوشش گیاهی دارد. باران در دامنه‌های بی‌ثمر در مقایسه با منطقه جنگلی با سرعت زیاد روی سطح زمین می‌بارد. در نتیجه، برخی از مناطق کاربری اراضی (به‌عنوان مثال درصد بالایی از اراضی زراعی یا کاربری اراضی شهری) در مقایسه



شکل ۶- نقشه کاربری اراضی حوزه آبخیز زولاچای شهرستان سلماس (منبع: نگارندگان، ۱۳۹۸)
Figure 6. Land use map of Zolachai watershed in Salmas city

را قادر می‌سازد تا هر فرآیند غیرخطی را نقشه‌برداری کند. یک نورون مصنوعی معمولی و مدل‌سازی یک شبکه عصبی

بسیاری از کارکردهای غیرخطی متمایز به‌عنوان یک تابع انتقال در دسترس هستند. از آنجاکه عملکرد sigmoid شبکه

استفاده از حداقل خطای میانگین مربع تغییر یافتند. مقادیر نورون‌ها در لایه‌های اول و دوم به ترتیب از ۵ تا ۲۱ و ۴ تا ۱۲ بررسی شد. برای هر پیکربندی ANN، روند تمرین با شروع از شرایط اولیه مستقل و در نهایت اطمینان از انتخاب بهترین عملکرد شبکه تکرار شد. از روند کاهش حداقل خطای مربع در مجموعه‌های آموزش و اعتبار سنجی برای تصمیم بهینه استفاده شد. با رسیدن به حداقل خطای میانگین مربع، این تمرین متوقف شد. این کار با اضافه کردن یک روش توقف اولیه در نرم‌افزار MATLAB انجام شد. این نشانه‌ای از آموزش بیش‌ازحد شبکه است. به عنوان یک ANN در مرحله آموزش بسیار خوب عمل می‌کند اما در صورت استفاده از مجموعه داده‌های دیگر، قادر به حفظ آن سطح عملکرد نیست.

برای جلوگیری از هرگونه خطا داده به سه بخش تقسیم می‌شوند. آموزش، اعتبار سنجی و آزمایش از قسمت آموزشی برای آموزش و بروز رسانی پارامترهای شبکه عصبی مصنوعی استفاده می‌شود. در مرحله اول خطای اعتبار سنجی آموزش کاهش می‌یابد. هنگامی که خطای اعتبار سنجی برای تعداد معینی از تکرارها بروز می‌شود، برنامه چندلایه (MLP) Perceptron در نرم‌افزار متلب مورد استفاده قرار گرفت. بخش‌های ورودی برنامه برای محاسبه آسان در نرم ARC GIS 5.3 اصلاح شد و از الگوریتم مارکوات برای مقیاس‌گذاری (نرمال‌سازی) داده و آموزش شبکه و انجام پردازش مورد نیاز برای دستیابی به خروجی مدل استفاده شده است. شش گره ورودی هر یک نمایانگر پارامترهای ایجادکننده سیل از جمله شیب، ارتفاع مدل رقومی، خاک، تجمع جریان، جهت جریان و کاربری اراضی در طول مدل‌سازی شبکه عصبی مصنوعی بودند این پارامترها به ترتیب I1, I2, I3, I4, I5, I6 مشخص شده‌اند (جدول ۱) تغییرات اتصال وزن بین لایه‌های پنهان و ورودی را نشان می‌دهد. در (جدول ۲) می‌توان مشاهده کرد که در وزن حداکثر و حداقل اتصال بین گره‌های لایه‌های ورودی و پنهان به جز پارامتر شیب (I1) تغییرات کمی وجود دارد. برای پارامتر شیب (I1)، تغییر بین حداکثر و حداقل وزن اتصال از سایر عوامل بزرگ‌تر است.

آزمون شبکه

پس از پایان مراحل آموزش ANN، از مجموعه داده‌های مختلف (داده‌های آزمایش) برای گسترش و تعیین صحت مدل استفاده شد. با استفاده از داده‌های جدید، عملکرد شبکه ارزیابی شد. این داده‌ها دارای مشخصات مشابه داده‌های آموزش بودند اما در طول آموزش مدل مورد استفاده قرار نگرفتند. نتیجه مهم در آزمایش این داده‌ها این بود که ANN توانست مقادیر مشابه مرحله آموزش را شناسایی کند. این نتیجه مقدار R^2 از ۱ را به دست می‌دهد که نتیجه قابل قبول است و سطح بالایی از پیش‌بینی را نشان می‌دهد. جریان رودخانه شبیه‌سازی شده و ANN پیش‌بینی شده و نقشه رگرسیون نشان داده شده است.

چند لایه در شکل ۷ نشان داده شده است، جریان سیگنال از ورودی‌های x_1, \dots, x_n است. در نظر گرفته می‌شود و همان‌طور که جریان سیگنال خروجی نورون (O) است. سیگنال خروجی نورون O از طریق رابطه (۱-۲) محاسبه می‌شود.

(رابطه ۱)

$$O = f(\text{net}) = f(\sum_{i=1}^n w_{ji}x_i)$$

که در آن w_{ji} بردار وزن است و تابع $f(\text{net})$ به عنوان یک تابع فعال‌سازی (انتقال) گفته می‌شود. شبکه متغیر به عنوان یک محصول مقیاس سنج بردارهای وزن و ورودی تعریف می‌شود. (رابطه ۲)

$$\text{Net} = wx = (w1x1) + (w2x2) + (wnxn)$$

معماری‌های ANN

معماری ANN به تعداد لایه‌ها و وزن اتصال اشاره دارد. همچنین جریان اطلاعات در شبکه ANN را تعریف می‌کند. طراحی یک ساختار مناسب مهم‌ترین و همچنین دشوارترین بخش در فرآیند مدل‌سازی ANN است (۱۵).

در این پژوهش یک معماری ANN با سه اتصال متشکل از یک لایه ورودی، دو لایه پنهان، یک لایه خروجی استفاده شده است. لایه ورودی شامل شش تا نورون است (هر یک برای ارتفاعات، شیب، جریان دقیق، کاربری اراضی، خاک و داده‌های بارندگی) که هر یک از این عوامل در حوضه مورد نظر در بروز سیلاب نقش دارند. لایه خروجی شامل یک جریان واحد است که جریان رودخانه را نشان می‌دهد. لایه پنهان و تعداد نورون‌ها برای تعریف رابطه پیچیده بین متغیرهای ورودی و خروجی استفاده می‌شود. از این‌رو، تعداد نورون‌های موجود در لایه ورودی به تعداد منابع داده ورودی بستگی دارد. داده‌ها به طور فعال در لایه‌های پنهان و خروجی پردازش می‌شوند. تعداد لایه‌های پنهان و نورون‌های آن‌ها اغلب با آزمایش و خطا تعریف می‌شوند.

آموزش شبکه

هدف از فرآیند آموزش کاهش دادن خطا بین خروجی بین شبکه عصبی و داده‌های واقعی با تغییر مقادیر وزنی بر اساس یک الگوریتم معین است (۱۷).

به طور معمول، الگوریتم‌های انتشار مجدد توسط شبکه‌های عصبی مصنوعی در این مرحله استفاده می‌شود. یک مدل شبکه عصبی مصنوعی موفق می‌تواند داده‌های هدف را از یک مجموعه داده ورودی پیش‌بینی کند. پس از دستیابی به حداقل خطا و اتمام آموزش ساختار منبع ذخیره به جلو توسط شبکه عصبی مصنوعی استفاده می‌شود تا طبقه‌بندی کل مجموعه داده‌ها را ایجاد کند. برای آموزش ANN، از یک فرمت N-N-1-5 در این مطالعه استفاده شد، جایی که N گره‌های لایه پنهان را نشان می‌دهد. با تغییر تعداد نورون‌ها در هر دو لایه پنهان، شبکه‌های عصبی چندین بار اجرا شدند تا مناسب‌ترین معماری شبکه عصبی را بر اساس آموزش و آزمایش دقیق تشخیص دهند. بنابراین، سلول‌های عصبی در لایه‌های پنهان با تکرار فرایند تمرین ۱۶ بار و سپس با

جدول ۱- لایه‌های ورودی (I)، لایه‌های پنهان (AH) ارتباطات وزن‌ها (منبع: نگارندگان، ۱۳۹۸)

Table 1. Input layers (I), hidden layers (AH) Weights communication

گره	شیب (I1)	مدل رقومی ارتفاعی (I2)	خاک (I3)	جهت جریان (I4)	کاربری اراضی (I5)
AH 1	۲۲/۵۴۳۲	۱/۳ - ۰.۷	۱/۵ - ۰.۸	۲/۲ - ۰.۲	- ۰/۹ - ۳/۲
AH2	- ۰/۴۵۶۳	- ۳/۹ - ۰	- ۲/۴ - ۰.۲	۱/۶ - ۰.۴	۵/۱ - ۰.۳
AH3	- ۱/۲۱ - ۳۴	۱/۰ - ۰.۲	۳/۷ - ۰.۷	۱/۲ - ۰.۵	۷/۹ - ۰.۲
AH4	- ۹/۶۵۸۱	۱/۸ - ۰.۳	۲/۹ - ۰.۲	۱/۳ - ۰.۳	۵/۳ - ۰.۵
AH5	۲/۵۶۴۲	۹/۱ - ۰.۸	۷/۱ - ۰.۴	۴۴/ - ۰.۳	۱/۸ - ۰.۲
AH6	۳/۸۷۳۱	- ۳/۱ - ۰.۵	- ۵/۹ - ۰.۷	۳/۸ - ۰.۵	۱/۷ - ۰.۲
AH7	۴/۸۷۴۱	- ۳/۱ - ۰.۹	- ۲/۹ - ۰.۴	۳/۸ - ۰.۸	۶/۷ - ۰.۳
AH8	- ۰/۱۳۳۱	۱/۲ - ۰.۵	۲/۸ - ۰.۸	۵/۹ - ۰.۲	۱/۱ - ۰.۵
AH9	- ۲/۲۳۴۱	- ۱ - ۰.۶	۳/۵ - ۰.۲	۹/۷ - ۰.۲	۶/۵ - ۰.۸
AH10	- ۲۳/۷۶۲۱	- ۰/۶۵۳	- ۹/۴ - ۰.۳	۳/۳ - ۰.۵	- ۱/۷ - ۰.۱
AH11	- ۰/۶۵۴۱	۱/۱ - ۰.۱	۵/۶ - ۰.۳	- ۲/۲ - ۰.۵	۲/۲ - ۰.۴
AH12	- ۰/۴۱۷۴	۱/۱ - ۰.۱	۵/۶ - ۰.۳	- ۲/۲ - ۰.۵	۲/۲ - ۰.۴
AH13	- ۰/۱۲۷۶	۲/۱ - ۰.۱	۱/۵ - ۰.۱	۱/۲ - ۰.۶	- ۱/۱ - ۰.۱
AH14	۹/۶۵۳۲	۲/۵ - ۰.۵	- ۵/۳ - ۰.۴	- ۸/۶ - ۰.۳	۱/۴ - ۰.۴
AH15	- ۰/۶۵۴۱	۳/۸ - ۰.۱	۹/۳ - ۰.۲	۱/۱ - ۰.۶	- ۴/۸ - ۰.۲
AH16	۶/۱ - ۰.۶	۶/۱ - ۰.۶	۵/۲ - ۰.۱	۲/۸	- ۴/۹ - ۰.۶

ارزیابی عملکرد مدل

لایه (MLP) برای پیش‌بینی حوادث سیل استفاده شد و بر اساس داده‌های آموزش و آزمایش مورد محاسبه قرار گرفت (جدول ۲). نتایج پیش‌بینی مدل MLP با داده‌های واقعی با ضریب تعیین (R^2) نتایج خوبی را ایجاد می‌کند. (شکل ۷) در حالی که نتایج نشان داد که مدل شبکه عصبی، SSE، MSE، RMSE به‌طور کلی دارای خطای ناچیزی بودند (جدول ۳).

ارزیابی دقت مدل از نظر خطای پیش‌بینی یا تغییر بین مقادیر مشاهده شده و پیش‌بینی و توصیف شده است. در پژوهش حاضر، متداول‌ترین روش‌ها شامل ضریب تعیین (R^2)، خطای جمع مربعات (SSE)، میانگین خطای مربعات (MSE) و خطای میانگین مربعات (RMSE) استفاده شده است. برای بررسی و ارزیابی عملکرد مدل، از شبکه عصبی پرسپترون چند

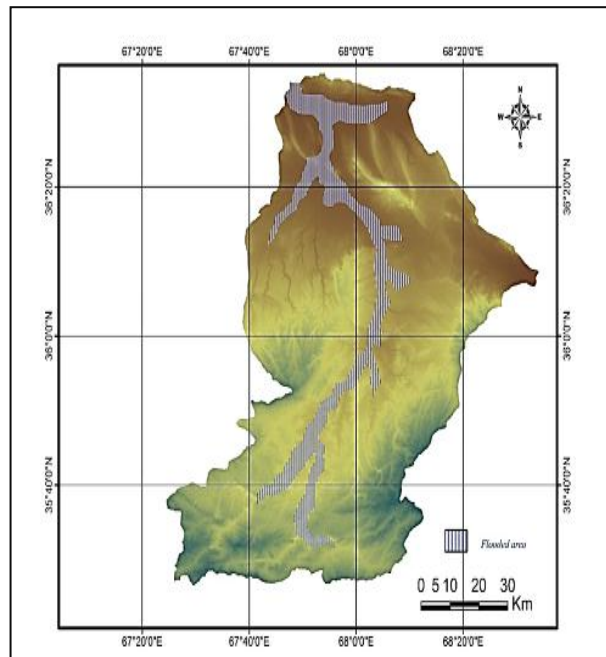
جدول ۲- مقایسه و ارزیابی عملکرد مدل برای شبکه عصبی پرسپترون در حین آموزش شبکه و آزمون شبکه (منبع: نگارندگان، ۱۳۹۸)
Table 2. Comparison and evaluation of model performance for perceptron neural network during network training and network testing

آزمون شبکه	آموزش شبکه	نمایه آمار
\backslash	\backslash	R^2
۵/۲ - ۰.۳	۵/۱ - ۰.۷	ESS
۳/۵ - ۰.۸	۳/۵ - ۰.۸	MSE
۲/۶ - ۱.۷	۲/۵ - ۱.۷	RMSE

جدول ۳- نتایج تجزیه و تحلیل آنالیز حساسیت برای پارامترهای ورودی (منبع: نگارندگان، ۱۳۹۸)

Table 3. Results of sensitivity analysis for input parameters

نمایه آمار	ESS	MSE	RMSE	R^2
شیب	۲/۵۴	- ۰/۰۰۰۳۲	- ۰/۱۳۵۲	- ۰/۸۷۱
مدل رقومی ارتفاعی	۳/۴۳	- ۰/۰۰۰۳۱	- ۰/۱۵۲۱	- ۰/۷۱۳
خاک	۱/۸۷	- ۰/۰۰۰۱۷	- ۰/۱۸۶۱	- ۰/۹۱۳
جهت جریان	۵/۳۲	- ۰/۰۰۰۳۵	- ۰/۳۳۲۱	- ۰/۸۴۵
کاربری اراضی	۳/۱۲	- ۰/۰۰۰۱۷	- ۰/۲۱۲۳	- ۰/۸۹۱



شکل ۷- منطقه شبیه‌سازی شده مستعد سیلاب درحوزه آبخیز زولاچای شهرستان سلماس (منبع: نگارندگان، ۱۳۹۸)
Figure 7. Simulated flood prone area in Zolachai watershed of Salmas city

پیش‌گیری از سیلاب در محیط‌های مکانی مختلف کمک شایانی کرده است. نتایج نشان داده مهم‌ترین عامل برای ایجاد سیل در محیط‌های مکانی عامل ارتفاع می‌باشد که در این پژوهش داری کمترین وزن ($R^2=0.713$)، بیشترین پارامتر مربوط به جهت جریان ($R^2=0.913$) می‌باشد. می‌توان گفت که شبکه عصبی مصنوعی MLP این قابلیت را دارد با نبودن داده‌های مکانی کافی و با اطلاعات اندک از منطقه مورد مطالعه مانند ویژگی‌های فیزیوگرافی حوضه مناطق مستعد سیلاب را شبیه‌سازی و مدل‌سازی کند. می‌توان با تلفیق مدل شبکه عصبی MLP و سیستم اطلاعات جغرافیایی به شناسایی نقاط که احتمال وقوع سیل در آن‌ها وجود دارد. مناطق بالا دست محدوده مورد مطالعه از لحاظ شرایط محیطی، ژئومورفولوژی و جغرافیایی خاص و ویژه‌ای داشته است به همین دلیل سال‌های اخیر پدیده سیل اثرات منفی فراوانی در ابعاد مختلف بر این منطقه گذاشته است و با اعمال روش‌های صحیح مدیریتی می‌توان شرایط مناسبی را برای برقراری توازن و تعادل اکولوژیکی حوضه فراهم نمود و از مخاطرات محیطی و بخصوص مخاطره سیل در مناطق سیل‌خیز جلوگیری کرد. از این رو توسعه سامانه کاربردی WEBGIS با شبکه‌های هوش مصنوعی برای مدل‌سازی و تهیه نقشه‌های خطر سیل به صورت آنی و در زمان واقعی جهت پیش‌بینی، مدیریت و کاهش خطرات برای مطالعات آینده پیشنهاد داده می‌شود. همچنین تاکید می‌شود که به سبب اهمیت در مطالعات آینده کل حوزه آبخیز زولاچای شهرستان سلماس از نظر خطرپذیری سیل مورد بررسی قرار گیرد. متأسفانه در این پژوهش به دلیل محدودیت در داده‌های در دسترس این امر میسر نشده و با بکارگیری سیستم اطلاعات جغرافیایی و شبکه عصبی پرسپترون تنها نقشه شبیه‌سازی خطر سیل از حوزه آبخیز تهیه شده است.

نفوذ آبخیز، ژئومورفولوژی و غیره رابطه بسیار پیچیده‌ای بین این عوامل وجود دارد و اینها تأثیر قابل توجهی بر یکدیگر و رواناب دارند. تعامل و انطباق این پارامترها برای مدل‌سازی هیدرولوژیکی حوضه ضروری می‌باشد. این پژوهش بیان‌کننده شبیه‌سازی سیلاب در حوضه آبریز زولاچای شهرستان سلماس با شبکه عصبی را نشان می‌دهد. بنابراین تجزیه و تحلیل‌های موجود نشان داد، عامل ارتفاع به عنوان مهم‌ترین عامل برای سیل در نظر گرفته شده است. میانگین مقدار نرمال بیان‌کننده آن بود، ارتفاع دارای کمترین مقادیر وزن می‌باشد ($R^2=0.713$)، جریان دقیق ($R^2=0.845$)، شیب ($R^2=0.871$). بنابراین می‌توان گفت آنالیز حساسیت برای تعیین وزن دهی به پارامترهای ورودی ضروری است. این نتایج می‌تواند به عنوان داده‌های اساسی برای کمک به مدیریت شیب و برنامه‌ریزی اراضی استفاده شود و روش‌های به کار رفته در این پژوهش می‌تواند برای اهداف و برنامه‌ریزی کلی استفاده شود. اگر بتوان این مدل شبکه عصبی مصنوعی را با یک سیستم هشدار یا سنسور هشدار تلفیق کرد می‌توان تا حدودی از خطر سیلاب‌ها در منطقه مورد مطالعه کاست.

نتیجه‌گیری کلی

مدل‌سازی و شبیه‌سازی خطر سیل در بحث مدیریت سیلاب و مهندسی رودخانه نقش به سزایی را ایفا می‌کند. در پژوهش حاضر عملکرد شبکه عصبی مصنوعی پرسپترون و جی‌آی‌اس جهت شبیه‌سازی مناطق مستعد سیلاب در حوضه آبریز زولاچای شهرستان سلماس با استفاده از پارامترهای شیب، ارتفاع، جهت جریان، خاک و کاربری اراضی مورد بررسی و ارزیابی قرار گرفت. نتایج حاصل از پژوهش نشان داد که ادغام تکنیک شبکه عصبی مصنوعی با سیستم اطلاعات جغرافیایی در زمینه‌های شبیه‌سازی و مدل‌سازی سیلاب به

منابع

1. Cai, X., Y. Li, X. Guo and W. Wu. 2014. Mathematical model for flood routing based on cellular automaton. *Water Science and Engineering*, 7(2): 133-142.
2. Dawson, C.W., R.J. Abrahart, A.Y. Shamseldin and R.L. Wilby. 2006. Flood Estimation at ungauged sites using artificial neural networks. *Journal of Hydrology*, (319): 391-409.
3. Douvinet, J., D. Delahaye and P. Langlois. 2007. Use of cellular automata in physical geography, 15th European Colloquium of Theoretical and Quantitative Geography, Montreux, Switzerland.
4. Dalal, U., M. Fathi and K. Khoshdel. 2017. Application of new multi-criteria decision-making methods for the estimation of flooding potential with emphasis on geomorphic factors (Case Study: Ajorlu Basin), *Geographic Space*, 17(59): 67-82 (In Persian).
5. Elsafi, H. 2014. Artificial Neural Networks (ANNs) for floodforecasting at Dongola Station in the River Nile, Sudan, *Alexandria Engineering Journal*, 53(3): 655-662.
6. Gomez, H. and T. Kavzoglu. 2005. Assessment of shallow landslidesusceptibility using artificial neural networks in Jabonosa RiverBasin. *Venezuela. Eng Geol*, 78(1-2): 11-27.
7. Gholizadeh, A., E. Ghanavati. H. Afsharmanesh and H. Amanullahpour. 2018. Fuzzy Model Efficiency on Flooding Potential in the Basin of Zangmar, *Geographic Space*, 17(60): 227-245 (In Persian).
8. Haykin, S. 1999. *Neural networks: a comprehensive foundation*, 2ndend. Prentice Hall, New Jersey.
9. Hong, H., P. Tsangaratos, I. Ilia, J. Liu, A. Zhu and W. Chen. 2018. Application of fuzzy weight of evidence and data mining techniques in construction of flood susceptibility map of Poyang County, China, *Science of the Total Environment*, (625): 575-588.
10. Kasiviswanathana, K.S., H. Jianxun, K.P. Sudheerb and T. Joo-Hwa. 2016. Potential application of wavelet neural network ensembleto forecast stream flow for flood management, *Journal of Hydrology*, 536(4): 161-173.
11. Kerh, T. and C.S. Lee. 2006. Neural networks forecasting of flood discharge atan unmeasured station using river upstream information. *Journal of Advances in Engineering Software*, (37): 533-543.
12. Kholghi, M. 2002. The Use of MDCM Method in Prioritizing Sub-Watersheds structural Flood Control. *Iranian Journal of Natural Resources*, (55): 479-490 (In Persian).
13. Lek, S., M. Delacoste, P. Baran, I. Demopoulos, J. Lauga and S. Aulanier. 1996. Application of neural networks to modelling non-linearrelationships in ecology. *Ecol Model*, (90): 39-52.
14. Liang, S. and C.R.C. Mohanty. 1997. Optimization of GIS-Based Flood Hazard Zoning a Case Study at the Mahanady Command Area in Cuttack District, Orrisa, India. *Journal of Chinese Soil and Water Conservation*, (28): 11-20.
15. Maier, H.R. and G.C. Dandy. 1996. The use of artificial neural networks forthe prediction of water quality parameters. *Water Resour Res*, (4): 1013-1022.
16. Reza, M.P. and S. Touraj. 2007. Flood zoning using GIS system (study plan: part of Qara Aghaj river in Fars province), the first urban GIS conference (In Persian).
17. Alireza, M. and M. Habibnejad Roshan. 2006. Study of flood prediction systems in Iran and their role in the protection of lands and residential areas along the canals, the first national conference on canal engineering, (In Pensian).
18. Hussein, N., M.A. Moghadam and M. Aramesh. 2013. Application of artificial neural network in simulation and flood prediction in Sarbaz catchment, *Quarterly Journal of Geography and Development*, 11(31): 15-28.
19. Nabizadeh, M., A. Masaedi. Hesam and A. Dehghani. 2012. Comparison of the performance of models based on fuzzy logic in predicting the daily discharge of Liqan River. *Soil and Water Conservation Research*, (19): 117-134 (In Persian).
20. Pradhan, B. 2009. Groundwater potential zonation for basalticwatersheds using satellite remote sensing data and GIS techniques. *Central Eur Journal Geosci*, 1(1): 120-129
21. Pereira, F.A.J. and S. Dos. 2006. Modeling a densely urbanized watershed with an artificial neural network, weather radar and telemetric data. *Journal of Hydrology*, (317): 31-48.
22. Qanavati, E., O. Karam and M. Alikhani. 2012. Flood Risk Assessment and Zoning in Farahzad Basin (Tehran) Using Fuzzy Model, *Journal of Geography and Environmental Planning*, 23rd Consecutive Year, (48): 38 -121 (In Persian).
23. Sahoo, G.B., C. Ray and D. Carlo. 2006. Use of neural network topredict flash flood and attendant water qualities of a mountainous stream onOahu, Hawaii. *Journal of Hydrology*, (327): 525-538.
24. Tokar, A.S. and P.A. Johnson. 1999. Rainfall-runoff modeling using Artificial Neural Network. *Journal of Hydrology Engineering*, (4): 232-239.
25. Thirumalaiah, K. and M.C. Deo. 2000. Hydrological forecasting using neural network. *Journal of Hydrology Engineering*, (5): 180-189.
26. United Nations Environment Program. 2002. Early warning, forecasting. And operational flood risk monitoring in Asia (Bangladesh, China and India). <http://www.unep.org/geo/geo3.asp>. Accessed 21 Aug 2010.

27. Xiao, Y., Sh. Yi and T. Zh. 2017. Integrated flood hazard assessment based on spatial ordered weighted averaging method considering spatial heterogeneity of risk preference, *Science of the Total Environment*, (600): 1034-1046.
28. Vali, A., M. Ramesht, A. Seif and R. Ghazavi. 2010. Comparing efficiency neural networks and regression models for prediction of watershed sediment load flow forecasting by artificial neural network and conventional model. *Alexandria Engineering Journal*, (50): 345-350.
29. Yamani, M. and M. Enayati. 2006. The analyses of flood data in relation to the geomorphologic specification of Fas hand and Behjatabad basins. 2005. *Journal of Geography Research*, (54): 47-57 (In Persian).
30. Rezai, A., M. Mahdavi, K. Lox, S. Feyznaya and M.H. Mehdian. 2007. Regional peak flows modelling of Sefid Rood Dam's sub basins using artificial neural network. *Journal of Science and Technology of Agriculture and Natural Resources*, (11): 25-39 (In Persian).

Simulation of Flood Prone Areas using Perceptron Neural Network and GIS (Study Area: Zolachai watershed, Salmas City)

Gormic Vahid Isazade¹ and Bny Zahra Aliegigy²

1- M.Sc. Student University of Tehran, (Corresponding Author: vahidisazade75@gmail.com)

2- M.Sc. Student University of Tehran

Received: 24 December, 2020

Accepted: 21 April, 2021

Extended Abstract

Introduction and Objective: Today, the flood phenomenon is one of the most complex and dangerous events that, more than other natural disasters, leads to human and financial losses and destruction of agricultural lands in different parts of the world every year.

Material and Methods: Due to the flooding of Zolachai Watershed, Salmas County, it seems necessary to study and simulate the risk of floods in this area. Therefore, in this study, a combination of artificial perceptron neural network (MLP) and GIS has been used. First, the effective parameters in simulating flood areas such as: slope layer, height, flow direction, soil and land use were examined and these information layers were entered into GIS software. The information layers were processed with the Fishnet command. And each layer became a point. This data, along with the educational data received from Google Earth, was introduced to the perceptron neural network.

Results: In the perceptron neural network, the input layers including 5 neurons and 16 nodes entered the model and the results showed that the height has the lowest weight ($R^2=0.713$) and the highest weight related to the flow direction ($R^2=0.913$) in simulating the Zolachai Watershed flood. Is the city of Salmas.

Conclusion: It can be said that the combination of GIS and artificial neural network can be very useful for modeling and simulating floods in different spatial environments to prevent and reduce environmental hazards.

Keywords: Flood, Fishnet, Perceptron Artificial Neural Network, Salmas County, Zolachai Watershed