

نشریه پژوهش‌های اقلیم‌شناسی
سال سیزدهم | شماره چهل و نهم | بهار ۱۴۰۱
وصول: ۱۳۹۶/۰۲/۲۳ پذیرش: ۱۳۹۹/۰۹/۱۷
صص ۱۷۷-۱۹۴

مدلسازی مکانی سیلاب با استفاده از الگوریتم شبکه عصبی مصنوعی و توابع تحلیلی GIS

محسن بختیاری^{۱*}، زهرا جهانتاب

۱- محسن بختیاری، دانشجوی دکتری سنجش از دور و GIS، دانشگاه تهران

۲- زهرا جهانتاب، کارشناس ارشد سنجش از دور و سامانه اطلاعات جغرافیایی، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات

چکیده

سیلاب از اصلی‌ترین بلایای همه‌گیر و یکی از مسائل مهم جهانی است به طوری که با افزایش شدت و فراوانی رخدادهای سیل، نگرانی‌های جهانی در خصوص افزایش مرگ و میر و ضررهای اقتصادی ناشی از سیل افزایش یافته است. تاکنون روش‌های مختلفی برای تحلیل این مخاطره طبیعی توسعه و پیشنهاد داده شده است. هدف این مطالعه بهره‌مندی از توابع تحلیلی مکانی سیستم اطلاعات جغرافیایی (GIS)، داده‌های ایستگاه‌های هیدرومتری و باران‌سنجی، تصاویر ماهواره‌ای و لایه‌های اطلاعاتی موضوعی در قالب الگوریتم شبکه عصبی مصنوعی، برای پیش‌بینی مقادیر دبی و مدلسازی مکانی سیلاب در محدوده حوضه رودخانه کن واقع در استان تهران می‌باشد. به این منظور مدل شبکه عصبی بهینه با هفت ورودی شامل لایه‌های شیب، انحنای دامنه، جریان تجمعی، پوشش گیاهی، واحدهای زمین‌شناسی، رده‌های خاک و داده‌های بارش به همراه هشت، شانزده و یک نورن به ترتیب برای لایه‌های مخفی اول و دوم و خروجی طراحی و توسعه یافت. خروجی مدل شبکه عصبی مقادیر دبی ایستگاه‌ها بود، آنگاه بر اساس بالاترین دقت ثبت شده و به کارگیری اوزان نورون‌ها در لایه‌های شبکه، نقشه پتانسیل سیل خیزی ایجاد شد. پارامترهای دقت سنجی $RMSE$ ، $R2$ و MAE برای نشان دادن کارایی مدل پیشنهادی به کار رفتند که به ترتیب مقادیر ۰.۸۲، ۰.۱۸ و ۰.۱۳ را شامل می‌شدند. نتایج این پژوهش می‌تواند در برنامه‌ریزی‌های محیطی آبی در مقیاس محلی به عنوان امکانی برای بهبود مدیریت بحران و مخاطرات زیست محیطی به کار رود. این مطالعه نشان داد که کاربرد توابع تحلیلی مکانی GIS و الگوریتم شبکه عصبی کارایی بالایی برای پیش‌بینی پتانسیل وقوع مخاطرات طبیعی چون سیلاب دارد.

کلمات کلیدی: مدلسازی سیلاب، شبکه عصبی مصنوعی، GIS، حوضه کن.

al., 2009, Mukand et al., 2011, Saini & Kaushik, همکاران (2012). قاسمی و همکاران (۱۳۸۹) با استفاده از سامانه اطلاعات جغرافیایی، GIS، سنجش از دور، RS، و شیوه تصمیم گیری فرآیند تحلیل سلسله مراتبی AHP سیل خیزی و عوامل تأثیرگذار بر وقوع آن در حوضه رودخانه بالقیلای چای واقع در استان‌های اردبیل و آذربایجان شرقی را ارزیابی کردند. هاشمیان و همکاران (2003) Hashemyan et al. با تلفیق مدل HEC-HMS و HEC-RAS در GIS گزینه‌های مختلف کنترل سیلاب و انتخاب گزینه برتر را تحلیل نمودند. هودسان و کولدیتز (2003) Hudson & Colditz به کمک تلفیق اطلاعات سنجش از دور با روش ژئومورفولوژیکی، نقشه پهنه‌بندی سیل را تهیه نمودند. این دو محقق نتیجه گرفتند که با تلفیق اطلاعات سنجش از دور می‌توان نقشه‌های با توان تفکیک بالا تهیه کرد که برای پهنه‌بندی سیل در مناطق با وسعت زیاد می‌تواند بسیار مفید باشد. از طرفی برخی از مطالعات پهنه بندی سیلاب بر مبنای روش‌های سنجش از دور راداری در مقیاس جهانی صورت گرفته اند، Hess et al., 1995) Hess et al., 1990, Pradhan & Shafie, 2009, Pirasteh et al; 2010) شیوه‌های آماری هم با توجه به رویکرد هیدرولوژیست‌ها به مسئله سیل همواره محل تحقیق بوده است (Farajzadeh, 2001, Farajzadeh, 2002, Horritt) (2009) Bates, 2002, Pradhan & Lee, &). ارزیابی کمی و نگاشت پتانسیل وقوع سیل به کمک GIS و شبکه عصبی مصنوعی^۱، ANN، به انحاء مختلف در چندین مطالعه موردی پیشنهاد شده است (Islam & Sado, 2002, Islam et al., 2001, Dixon, 2005). بیلا و همکاران (2004) Billa et al. از تلفیق GIS، RS و مدل هیدرودینامیک MIKE11 برای طراحی سیستم هشدار سیل حوضه رودخانه Langat در مالزی استفاده کردند. در مطالعه‌ای دیگر، کافله و همکاران (2006) Kafle et al. با تلفیق سنجش از راه دور و GIS و به کمک مدل شبیه سازی جریان، پهنه بندی خطر سیل در رودخانه Bagmati در نپال را انجام دادند. ویو و همکاران (2009) Wu et al. در مطالعه‌ای شیوه‌های بهبود اجرای مدلسازی شبکه عصبی را در برآورد رواناب‌های روزانه مورد بررسی قرار دادند. هو و

مقدمه

سیل از عمده ترین سوانح طبیعی است که به دلیل تحمیل خسارات سنگین بر جوامع بشری و حیات طبیعی، همیشه مورد توجه مدیران و برنامه ریزان محیطی به منظور کاهش اثرات زیان رسان آن بوده است. از منظر جهانی وقوع سیلاب در سالیان اخیر بالاترین فراوانی را در میان انواع مخاطرات طبیعی نشان می دهد که منجر به وارد آمدن خسارات شدید به جان و مال سیل زدگان شده است (Kia, M et al., 2012). به طوری که سهم زیان اقتصادی ناشی از رخداد سیلاب در حدود ۴۰ درصد از مجموع کل خسارت‌های بلایای طبیعی برآورد شده است (Feng and Lu, 2010, Ezemonye & Emeribe, 2012). با روند فزاینده شدت و فراوانی رخدادهای سیل، نگرانی های جهانی در خصوص افزایش مرگ و میر و ضررهای اقتصادی ناشی از آن افزایش یافته است (Sarhadi et al., 2012). به منظور تخفیف آسیب‌های بالقوه، مراجع تصمیم گیری و نگرش عمومی باید از زمان و مکان وقوع سیلاب آتی و اینکه چه نواحی مورد حمله نیروی طغیان گر و غیر قابل مهار آب قرار می‌گیرد، آگاهی داشته باشند؛ لذا اهمیت توسعه روش‌های دقیق پیش بینی سیل به منظور جلوگیری از بلایای آینده یا کمینه کردن عوارض ناشی از آن بیش از پیش نمایان می‌شود. در اغلب حوضه های آبخیز کشور، وقوع سیل و خسارت های ناشی از آن نیز آهنگ رو به افزایشی دارد، بنابراین تعیین مناطق مولد سیل و اولویت بندی حوضه‌ها از نظر پروژه های کنترل سیل و مدیریت جامع حوضه‌های آبخیز ضرورت دارد (تقفیان و فرارزجو، ۱۳۸۶). به طور کلی مدلسازی سیلاب فرآیندی ترکیبی و پیچیده دربردارنده عوامل کیفی و کمی متعددی است، به همین علت تصمیم گیران برای سهولت در این گونه بررسی‌ها ترجیح می‌دهند نتایج تحلیل‌ها را به صورت مقادیر عددی نشان دهند (Yang, et al., 2013). یکی از راهکارهای کنترل و کاهش آسیب‌ها، تفکیک نواحی سیل خیز و تعیین سهم عوامل موثر در آن می باشد که می تواند در تدوین مدیریت مناسب برای سیاست گذاری‌های میان مدت و کوتاه مدت در بهره برداری پهنه از اراضی، نقش ویژه ای داشته باشد (Pawattana et

¹- Artificial Neural Network (ANN)

در سالیان اخیر با هدف ارتقاء دقت روش‌های مدل‌سازی سیل و غلبه بر محدودیت‌های شیوه‌های پیشین، نیاز به داده‌های دقیق و پرهزینه و عدم امکان تعمیم مدل‌ها به نواحی دیگر، چندین مطالعه هیدرولوژیکی تکنیک‌های نوینی چون ANN، منطق فازی و Neuro-Fuzzy را برای پیش‌بینی سیل توسعه داده‌اند (Dixon, 2005). اگرچه تاکنون روش‌های مختلفی برای تحلیل کمی و پیش‌بینی سیلاب توسعه داده شده است، با این حال در بسیاری از مدل‌سازی‌های جای خالی تحلیل‌های مکانی آشکار بوده است. از طرفی تکیه بر رویکردهای آمار مینا برای پیش‌بینی سیل مورد تأکید بوده است که به دلیل مفروض داشتن نوع خاصی از توزیع داده‌ها یعنی توزیع نرمال، دقت نتایج تحت تأثیر قرار می‌گرفت.

مطالعه حاضر قابلیت سنجی تلفیق شبکه عصبی مصنوعی و توابع تحلیل مکانی GIS را در مدل‌سازی مکانی سیلاب مورد توجه قرار داده است. در دهه‌ی حاضر می‌توان شاهد گسترش روش‌های مبتنی بر شبکه‌های عصبی مصنوعی و کاربردهای آن در تحلیل مسائل مختلف مکانی بود. اصلی‌ترین مزیت الگوریتم شبکه عصبی مصنوعی نسبت به بسیاری از الگوهای محاسباتی عدم حساسیت آن به توزیع داده‌های ورودی می‌باشد. دیگر خصایص عمده آن در نوع رفتار با عدم قطعیت‌های موجود در ورودی‌ها و امکان استخراج اطلاعات و الگوهای پنهان از مجموعه داده‌های ناقص و متناقض انعکاس می‌یابد (Ray & Klindworth, 2000). از این رو اهداف عمده این مطالعه عبارت‌اند از: ۱- برآورد میزان دبی اوج سیلاب قابل وقوع در گستره مطالعاتی، ۲- بهینه‌سازی مدل شبکه عصبی مصنوعی ارائه شده با تغییر ضرایب وزنی پارامترهای مؤثر بر پدیده سیلاب (رواناب) به منظور بهینه‌بندی خطر وقوع آن و ۳- مقایسه کارایی و عملکرد شبکه عصبی مصنوعی در مدل‌سازی دبی و دبی اوج. ساختار مطالعه حاضر از چهار بخش اصلی مقدمه، مواد و روش‌ها، بحث و نتایج و نتیجه‌گیری تشکیل شده است، اینک پس از مقدمه، سایر بخش‌ها در ادامه آورده می‌شوند.

همکاران (Huo et al., 2012) در مطالعه‌ی خود از یک مدل‌سازی شبکه عصبی یکپارچه به منظور برآورد جریان رودخانه ای ماهیانه در حوضه‌های خشک شمال چین استفاده کردند. السافی (Elsafi, 2014) شیوه‌های شبکه عصبی مصنوعی در پیش‌بینی سیلاب ایستگاه Dongola در حوضه رودخانه نیل کشور سودان را مرور کردند. وانگ و همکاران (Wang et al., 2015) با به کارگیری شبکه عصبی براساس تجزیه حالت تجربی مجموع EEMD) دقت برآورد رواناب‌های متوسط و بلندمدت را بهبود بخشیدند. در برخی مطالعات از طریق ارزیابی آماری، خطر سیلاب در مقیاس منطقه‌ای را مدل‌سازی کرده‌اند (Stripling et al., 2017) در حالی که کاهش اثرات مخرب سیلاب‌های شدید در بستر سامانه اطلاعات جغرافیایی به عنوان چالشی نوین مورد توجه برخی محققان بوده است (Liu et al., 2017). در مطالعه‌ای از تلفیق شبیه‌سازی هیدرولوژیکی و توابع GIS برای مدل‌سازی سیستم رودخانه‌های در معرض سیلاب استفاده شده است (Pontes et al., 2017)، در حالی که در پژوهشی، مقایسه‌ای میان مدل‌سازی GIS و هیدرودینامیک برای ارزیابی آسیب‌پذیری نسبت به سیلاب انجام شد و نتیجه گرفته شد که مدل‌سازی هیدرودینامیک هر چند با دقت بالاتری همراه است ولی با این حال توابع GIS از عملکرد مناسبی برای مدل‌سازی سیلاب در حوضه‌های وسیع از خود نشان می‌دهند (Seenath et al., 2016). از مطالعات داخلی مدل‌سازی مکانی سیلاب می‌توان به پهنه‌بندی حوضه از نظر تولید سیلاب با استناد به مولفه‌های ژئومورفولوژی (علایی طالقانی و همایونی، ۱۳۹۰)، پهنه‌بندی سیلاب در راستای توسعه شهری (امیراحمدی و همکاران، ۱۳۹۰)، به کارگیری مدل فازی در ارزیابی خطر رخداد سیلاب (قنواتی و همکاران، ۱۳۹۱ و قنواتی، ۱۳۹۲) و پهنه‌بندی خطر وقوع سیلاب با استفاده از فرآیند تحلیل سلسله‌مراتبی (فتوحی و کیانی، ۱۳۹۴) اشاره کرد. همچنین نگارش و همکاران (۱۳۹۲) با به کارگیری شبکه عصبی مصنوعی، شبیه‌سازی و پیش‌بینی مخاطره سیلاب در حوضه رودخانه سرباز را مطالعه کردند.


¹- Ensemble empirical mode decomposition (EEMD)

استان تهران و جنوب شرقی استان البرز جای گرفته است. رودخانه کن با طول ۳۳ کیلومتر از رشته کوه توچال در البرز جنوبی سرچشمه گرفته و در این حوضه سرازیر می شود، می توان ادعا داشت که این رود امروزه پرآب‌ترین رودی است که از استان تهران می‌گذرد (محمودیان، ۱۳۸۴ و جعفری، ۱۳۸۴). مشخصات فیزیوگرافی ایستگاه‌های هیدرومتری حوضه کن در جدول ۱ آمده است.

منطقه مورد مطالعه

معرفی منطقه مورد مطالعه

محدوده مورد مطالعه در این پژوهش حوضه آبریز رودخانه کن می باشد که خود به ترتیب جزئی از حوضه‌های بزرگتر مرکزی و تهران و کرج محسوب می‌گردد (شکل ۱). این حوضه با مساحتی بالغ بر ۷۰۶ کیلومتر مربع در شمال غربی



شکل ۱- موقعیت جغرافیایی محدوده مورد مطالعه
(Landsat 8 تصویر)

جدول ۱- مشخصات فیزیوگرافی ایستگاه‌های هیدرومتری حوضه کن (منبع: شرکت آب منطقه ای تهران)

| نام ایستگاه | طول جغرافیایی | عرض جغرافیایی | ارتفاع (متر) | زیرحوضه | |
|-------------|---------------|---------------|--------------|-----------------|-----------------|
| | | | | شیب آبراهه اصلی | طول آبراهه اصلی |
| جهان آباد | ۵۱° ۱۹' ۲۷" | ۳۵° ۳۱' ۳۴" | ۱۰۱۲ | ۰/۰۷ | ۹/۹۴ |
| رندان | ۵۱° ۱۷' ۰۵" | ۳۵° ۵۱' ۱۲" | ۱۸۷۰ | ۰/۰۸ | ۹/۳۴ |
| سولقان | ۵۱° ۱۶' ۰۰" | ۳۵° ۴۷' ۰۰" | ۱۴۳۰ | ۰/۱۶ | ۶/۹۲ |
| کشار | ۵۱° ۱۹' ۱۲" | ۳۵° ۴۸' ۱۴" | ۱۵۲۰ | ۰/۲۳ | ۳/۲۳ |
| کیگا | ۵۱° ۱۷' ۰۸" | ۳۵° ۵۱' ۱۳" | ۱۸۷۰ | ۰/۱۹ | ۷/۷۶ |

مجموعه داده‌ها

داده به عنوان مهمترین و گاهی پرهزینه ترین عنصر هر تحلیل GIS در طیف گوناگونی از کاربردها و تحلیل‌ها شناخته شده است. (Carrara et al., 1999) در این پژوهش عوامل موثر در وقوع سیلاب در هفت ورودی شامل لایه‌های اطلاعاتی موضوعی شیب، انحنای دامنه، جریان تجمعی، پوشش گیاهی، واحدهای زمین شناسی، رده های خاک و داده های بارش با بهره جستن از توابع تحلیل مکانی و زمین-آمار در محیط GIS برای ورود به الگوریتم شبکه عصبی آماده شدند. این داده ها پس از مطالعه ادبیات پژوهش و تحقیقات پیشین و با لحاظ نمودن شرایط ویژه حوضه کن برای مدلسازی سیلاب برگزیده شدند (شکل ۲)، در این بخش نخست داده‌های برگزیده شده معرفی می‌شوند. سپس بیان می‌شود که از هر داده برای تولید چه اطلاعاتی استفاده می‌شود:

الف. شیب: شیب دامنه به عنوان زاویه میان سطح زمین و یک سطح مبنای افقی تعریف می‌گردد، شیب موجب تأثیر متفاوت گرانش در رواناب حاصل از بارش می‌شود، اگرچه شیب‌های تند جریان‌های سریعی تولید می‌کنند. سیلاب‌ها معمولاً در شیب‌های ملایم رخ می‌دهند (Gomez & ۲۰۰۵) (Kavzoglu, .

ب. انحنای دامنه: لایه‌ی انحنای دامنه یا همان محدب و مقعر بودن دامنه بر اساس تابعی که مشتق دوم سطح ارتفاعی را حساب می‌کند، حاصل می‌گردد که می‌تواند خصوصیات فیزیکی یک حوضه زهکشی را به منظور درک فرآیندهای رواناب و فرسایش توصیف نماید (شکل ۲-ب). به طور کلی، شیب اراضی آهنگ حرکت جریان به پایین دامنه را مشخص

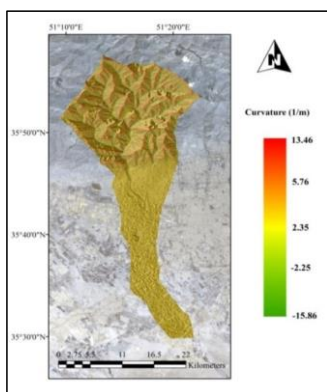
می‌کند، جهت شیب جهت جریان را تعیین می‌کند، در حالی که انحنای نیمرخ بر افزایش یا کاهش سرعت جریان و بنابراین بر فرسایش و رسوب گذاری اثر گذار خواهد بود. ضمن اینکه انحنای صفحه بر واگرا بودن یا همگرا بودن جریان توده‌ای تأثیرگذار می‌باشد (Zevenbergen & Thorne, 1987, Moore et al., 1991)

پ. جریان تجمعی: اگر مسیر جریان شناخته شود، می‌توان تعیین کرد که کدام قسمت از مسیر نسبت به دیگر بخش‌ها دارای آب بیشتری است و این کار با شمارش تعداد سلول‌هایی انجام می‌گیرد که به هر سلول واقع در پای شیب ختم می‌گردند. در واقع در یک جریان تجمعی (شکل ۲-ت) مقداری که برای هر سلول به دست می‌آید بیانگر تعداد کل پیکسل‌هایی است که به داخل یک سلول منحصراً به فرد می‌ریزد (Jenson & Domingue, 1988)


ت. پوشش گیاهی: پوشش گیاهی از طریق دریافت بارش موجب تبخیر نسبی از آن از یک سو و انتقال آهسته سهمی دیگر از آن به سطح زمین می‌گردد و در عین حال با ایجاد مانع در مقابل حرکت آب روی زمین سبب افزایش نفوذ آب به داخل خاک می‌شود. در نتیجه تأثیر قابل ملاحظه‌ای روی رواناب به جای می‌گذارد. تغییر نوع و تراکم پوشش گیاهی موجب کاهش یا افزایش رواناب و بروز سیلاب‌های مخرب می‌شود (همت زاده و همکاران، ۱۳۸۷).

ث. واحدهای زمین شناسی: واحدهای زمین شناسی عمده حوضه کن، بر اساس نقشه زمین شناسی تهیه شده به وسیله سازمان زمین شناسی و اکتشافات معدنی کشور، شامل گدازه های آندزیتی بازالتی (Ea.bv)، شیل تیره توف دار با میان لایه های از توف (Ek)، شیل آهکی و توف (Ek.a)، شیل توفی


آبخیزداری کشور، در مقایسه با واحدهای زمین شناسی کمتر می‌باشد و عمدتاً از رخنمون‌های Inceptisol در شمال و رده Aridisol در نواحی جنوبی منطقه مورد مطالعه تشکیل شده است (سازمان جنگل‌ها، مراتع و آبخیزداری کشور). شکل ۲-ج رده های خاک محدوده مورد نظر را نشان می‌دهد. ج. داده های بارش: ایستگاه‌های هیدرومتری محدوده مورد مطالعه داده های دبی روزانه و ایستگاه‌های باران سنتی مقادیر بارش روزانه را اندازه گیری می کنند، داده های مذکور با مراجعه به سازمان آب و فاضلاب استان قابل دسترسی هستند.




۲-ب- انحنای دامنه محدوده مورد مطالعه



۲-الف- شیب محدوده مورد مطالعه




۲-ت- جریان تجمعی محدوده مورد مطالعه



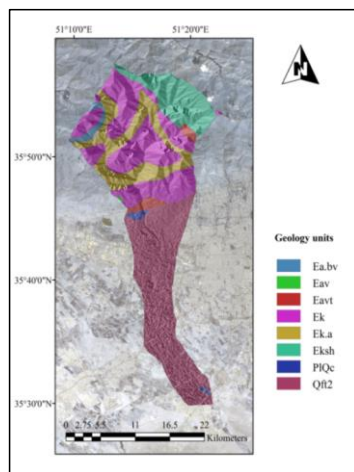
۲-پ- جهت جریان محدوده مورد مطالعه

با میان لایه هایی از توف (Eksh)، کنگلومرای پلی ژنیک سست (PIQc) و ذخایر تراسی و مخروط افکنه های کوهپایه‌ای جدید کم ارتفاع (Qft2) می‌باشد (سازمان زمین شناسی و اکتشافات معدنی کشور). واحدهای Eksh و Ek بخش‌های شمالی و واحد Qft2 نوار جنوبی محدوده مطالعاتی، منطبق بر نواحی شهری و مسکونی را می‌پوشانند (شکل ۲-ث).

ج. رده های خاک: تنوع رده‌های خاک حوضه کن، بر اساس نقشه خاک تهیه شده به وسیله سازمان جنگل‌ها، مراتع و



۲- ج- رده‌های خاک محدوده مورد مطالعه



۲- ث- زمین‌شناسی محدوده مورد مطالعه

شکل ۲- لایه‌های اطلاعاتی آماده شده به عنوان ورودی‌های شبکه عصبی مصنوعی .

زیرنویس تنظیم شود: [k1] Commented

به یک حد معین تولید خروجی می‌کند. این حد معین که همان حد آستانه می‌باشد، در حقیقت عامل فعالیت نورون یا غیرفعال بودن آن است. با توضیحات فوق می‌توان گفت که در مدل‌سازی یک نورون بیولوژیک به طور مصنوعی می‌بایست به سه عامل توجه شود: ۱- نورون یا فعال است یا غیرفعال، ۲- خروجی تنها به ورودی‌های نورون بستگی دارد و ۳- ورودی‌ها باید به حدی برسند تا خروجی ایجاد گردد (منهاج، ۱۳۸۸).

شبکه‌های عصبی پرسپترون

در بسیاری از مسائلی پیچیده ریاضی که به حل معادلات بفرنج غیر خطی منجر می‌شود، یک شبکه‌ی پرسپترون چند لایه^۱ می‌تواند به سادگی با تعریف اوزان و توابع مناسب مورد استفاده قرار گیرد. توابع فعالیت مختلفی به فراخور اسلوب مسئله در نورون‌ها مورد استفاده قرار می‌گیرد. در این نوع شبکه‌ها از یک لایه‌ی ورودی جهت اعمال ورودی‌های مسئله، یک لایه‌ی پنهان و یک لایه‌ی خروجی که نهایتاً پاسخ‌های مسئله را ارائه می‌نمایند، استفاده می‌شود. آموزش این گونه شبکه‌ها معمولاً با روش پس انتشار

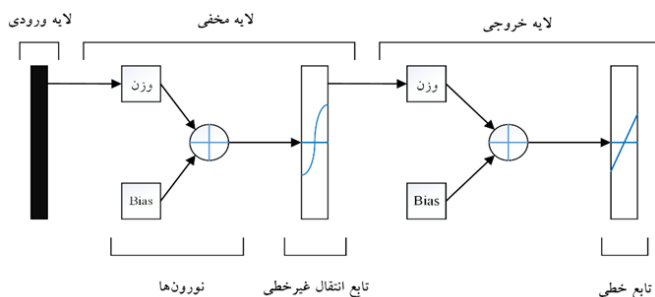
روش تحقیق

شبکه عصبی مصنوعی نامی آشنا و پرکاربرد در علوم مهندسی و پایه است که به طور ابتدایی و آغازین در سال ۱۹۶۲ توسط Frank Rosenblatt و در شکل جدی و تأثیرگذار در سال ۱۹۸۶ توسط Rumelhart و McClelland با ابداع و ارائه مدل پرسپترون بهبود یافته به جهان معرفی شد (منهاج، ۱۳۸۸). این شیوه از ساختاری نورونی و هوشمند با الگوبرداری مناسب از نورون‌های موجود در مغز انسان سعی می‌کند تا از طریق توابع تعریف شده ریاضی رفتار درون سلولی نورون‌های مغز را شبیه‌سازی کند و از طریق وزن‌های محاسباتی موجود در خطوط ارتباطی نورون‌های مصنوعی، عملکرد سیناپسی را در نورون‌های طبیعی به مدل در آورد .

ماهیت و ذات تجربی و منعطف این روش باعث می‌شود تا در مسائلی مانند مقوله پیش‌بینی، که چنین نگرشی در ساختار آن‌ها مشاهده می‌شود و از رفتاری غیرخطی و لجام‌گسیخته برخوردار هستند، به خوبی قابل استفاده باشد. یک نورون بیولوژیک با جمع ورودی‌های خود که از طریق دندریت‌ها با یک وزن سیناپسی خاص به نورون اعمال می‌شوند، با رسیدن

^۱- Multilayer Perceptron

خطا^۱ انجام می‌شود (منهاج، ۱۳۸۸). کارکرد مفهومی شبکه پرسپترون چند لایه در زیر نمایش داده شده است (شکل ۳).



شکل ۳- ساختار پرسپترون چند لایه با نورون‌های پنهان و نورون‌های خروجی با تابع خطی (منهاج، ۱۳۸۸)

سه لایه شبکه‌های پرسپترون چند لایه یا MLP شامل یک لایه‌ی ورودی، لایه‌های مخفی و یک لایه‌ی خروجی است که به ترتیب معادل داده‌های ورودی، پردازش داده‌ها و داده‌های خروجی می‌باشند. هر لایه از چندین گره یا نورون مصنوعی تشکیل شده است، همه‌ی نورون‌ها به جز نورون‌هایی که در یک لایه واقع می‌باشند، به هم متصل هستند. در مسائل پیش‌بینی، که مدلسازی سیلاب نیز می‌تواند از لحاظ هدف مشابه این مسائل فرض شود و در این مطالعه هر گره‌ی لایه‌ی ورودی معادل یکی از هفت عامل تأثیرگذار آماده شده به صورت لایه‌ی اطلاعاتی برای تاریخ‌های مختلف در نظر گرفته می‌شود. لایه‌های مخفی برای طبقه‌بندی و انتقال نتایج به لایه‌ی خروجی به کار می‌رود، لایه‌ی خروجی نیز مقادیر پیش‌بینی شده متغیر مطلوب را نشان می‌دهد، در این پژوهش لایه‌ی خروجی برآوردی از میزان دبی روزانه گزارش شده ایستگاه‌ها را نشان می‌دهد.

لایه شیب (شکل ۲- الف)، بر اساس مدل رقومی ارتفاعی^۲، DEM، ۳۰ متری تهیه شده از تصاویر Aster حاصل شد (<http://glovis.usgs.gov>). برای ساختن لایه‌ی جریان تجمعی ابتدا لایه جهت جریان با استفاده از DEM ساخته شد، این لایه جهت جریان خروجی از هر پیکسل را مشخص می‌کند، به طوری که مقادیر پیکسل‌ها مسیر تخلیه

شبکه‌های عصبی، با قابلیت قابل توجه در استنتاج معانی از داده‌های پیچیده یا مبهم، برای استخراج الگوها و شناسایی روش‌هایی که آگاهی از آن‌ها برای انسان و دیگر تکنیک‌های کامپیوتری بسیار پیچیده و دشوار است به کار گرفته می‌شوند. یک شبکه عصبی تربیت یافته می‌تواند به عنوان یک متخصص در مقوله اطلاعاتی که برای تجزیه و تحلیل به آن وارد شده، به حساب آید. از این متخصص می‌توان برای برآورد وضعیت‌های دلخواه جدید و جواب سؤال‌های چه می‌شد اگر، استفاده کرد. مزیت‌های دیگر آن شامل موارد زیر می‌شود (منهاج، ۱۳۸۸).

مدلسازی سیلاب مبتنی بر شبکه‌های عصبی

پرسپترون سه لایه

به طور کلی شبکه‌های عصبی گروهی متصل از گره‌هایی است که با استفاده از شیوه‌های ریاضی به پردازش اطلاعات می‌پردازند. شبکه‌ی پرسپترون سه لایه یکی از مدل‌های ANN است که به صورت گسترده‌ای مورد استفاده قرار می‌گیرد و علت عمده‌ی آن قابلیت بالای این نوع شبکه‌ها برای حل بسیاری از مسائل شبیه‌سازی، پیش‌بینی و طبقه‌بندی نظارت شده تصاویر و لایه‌ی اطلاعاتی است.

¹- Back Propagation

²- Digital Elevation Model (DEM)

فرآیند یادگیری پرسپترون چند لایه پس انتشار خطا است، این الگوریتم این گونه توصیف می‌شود که ابتدا وزن‌های اولیه به وجود می‌آیند و به هر گره اختصاص می‌یابند، پس از آن نمونه‌های آموزشی وارد مدل می‌گردند؛ آنگاه نتایج تولید می‌شود و با نمونه‌های آزمایشی مقایسه می‌شوند، اگر اختلاف بزرگتر از مقدار آستانه تعیین شده باشد، اوزان تا کمینه شدن تفاوت بین خروجی‌های مطلوب و واقعی، تولید شده توسط شبکه، تغییر می‌یابند. فرآیند تا زمان رسیدن به یک سطح دقت از پیش تعیین شده یا بیشینه تکرار ادامه می‌یابد (Hu & Weng, 2009).

طراحی و توسعه یک مدل ANN کاری چالش برانگیز است. بسیاری از پارامترهای بحرانی باید به صورت دستی وارد شوند؛ مانند: تعداد لایه‌ها و نورون‌های لایه‌ی مخفی، نرخ یادگیری^۱، فاکتور لحظه‌ای^۲ و نواحی آموزشی^۳. پارامترهای مذکور باید به درستی تعیین شوند تا کمینه کلی تابع خطا در عوض کمینه محلی یافت گردد. تعداد نورون‌های لایه‌ی مخفی تأثیر زیادی بر دقت نتایج دارد، تعداد بسیار بالای نورون‌ها باعث بیش برآزش مدل می‌گردد در حالی که تعداد خیلی کم نمی‌تواند ساختار داخلی داده‌ها را شناسایی کند. از طرفی اگر نرخ آموزش خیلی بالا باشد مدل ثبات ندارد و نمی‌تواند همگرا گردد، در صورتی که اگر آن خیلی پایین باشد، مدل ممکن است در دام یک کمینه محلی گیر کند (Kavzoglu & Mather, 2003). الگوی طبقه بندی کننده MLP از رابطه زیر (رابطه ۱) برای محاسبه‌ی ورودی‌هایی که یک گره منفرد J دریافت می‌کند، بهره می‌برد (Hu & Weng, 2009):

$$net_j = \sum_i w_{ij} I_i \quad (1)$$

در رابطه فوق، net_j پارامتر ورودی است که نورون منفرد J دریافت می‌کند، w_{ij} اوزان بین نورون i و نورون J را نشان می‌دهد و I_i خروجی نورون i متعلق به لایه فرستنده، لایه ورودی یا مخفی، می‌باشد. مقدار خروجی از

آب‌های سطحی را نمایش می‌دهد. سپس با استفاده از جهت جریان می‌توان جریان تجمعی را برای هر پیکسل تخمین زد. با توجه به تغییر سریع فنولوژی گیاهان در دوره‌های مختلف، شاخص تفاضلی نرمال شده پوشش گیاهی^۱ با استفاده از باندهای قرمز و مادون قرمز نزدیک تصاویر Landsat 5 و Landsat 8 با در نظر داشتن تاریخ گذر ماهواره از حوضه کن طی سال‌های ۲۰۰۷ تا ۲۰۱۳، با فاصله زمانی حداقل ۱۶ روزه، ایجاد شد. تصاویر Landsat به دلایل ۱- داشتن باندهایی که تطابق بالاتری با محدوده‌های قرمز و مادون قرمز طیف الکترومغناطیسی جهت محاسبه NDVI، ۲- دارا بودن ابعاد پیکسلی ۳۰ متر، این ابعاد پیکسلی با توجه به مقیاس مطالعاتی و قدرت تفکیک سایر لایه‌های اطلاعاتی مناسب به نظر می‌رسد و ۳- برخورداری از پوشش سرتاسری و آرشویی غنی به ویژه برای پایش تغییرات پدیده‌ها و عوارض پویا مانند وضعیت پوشش گیاهی، برای تهیه لایه‌های NDVI به کار رفتند. با در نظر داشتن تفکیک زمانی این تصاویر و بازه زمانی داده‌های ایستگاه‌های باران سنجی و هیدرومتری، به طور متوسط برای هر سال ۱۰ تصویر Landsat دریافت و برای تهیه لایه‌های NDVI به کار رفت، یعنی در مجموع ۶۰ لایه اطلاعاتی NDVI به منظور پوشش مناسب وضعیت پوشش گیاهی در محدوده مطالعاتی آماده شد. برای برآورد بارش روزانه در ایستگاه‌های هیدرومتری از یک مدل رگرسیون میان داده‌های بارش روزانه پنج ایستگاه باران سنجی حوضه کن و DEM محدوده با نمونه گیری تصادفی ساده از داده‌های بارش ۲۰۰۸ روز طی فاصله ۲۰۰۷ تا ۲۰۱۳ استفاده شد، پس از ارزیابی و تأیید دقت آن، با R^2 و RMSE به ترتیب برابر ۰/۸۹ و ۰/۱۱، با استفاده از توابع درون یابی و زمین-آمار برای ایستگاه‌های هیدرومتری مقادیر بارش روزانه در بازه زمانی مد نظر برآورد شد. توابع مذکور برای تبدیل داده‌های نقطه‌ای به سطوح پیوسته به کار گرفته شد تا بتوان با برآوردی از سطوح پیوسته بارش و دبی در محدوده مطالعاتی، مراحل آتی مطالعه را اجرا کرد.

^۳- Momentum term

^۴- Training data

^۱- Normalized Differential Vegetation Index (NDVI)

^۲- Learning rate

سوی دیگر، سعی در مدل نمودن دبی روزانه ایستگاه‌های هیدرومتری به عنوان شاخصی از وقوع سیل بر مبنای داده های بارش برآورد شده از ایستگاه‌های هواشناسی و خصوصیات طبیعی حوضه می باشد. لذا در گام اول لایه‌های اطلاعاتی مربوط به ویژگی‌های فیزیوگرافی حوضه پس از جمع آوری از منابع مختلف، چون مدل رقومی ارتفاعی حاصل از تصاویر ASTER که خود برای تهیه لایه‌های شیب، انحنای دامنه و جریان تجمعی حوضه استفاده شد، لایه های شاخص پوشش گیاهی برآمده از تصاویر سری زمانی NDVI و نقشه‌های زمین شناسی و رده‌های خاک حوضه آبخیز کن، در محیط GIS آماده سازی شدند. با توجه به عدم ثبت داده های بارش توسط ایستگاه های هیدرومتری، از رابطه میان بارش‌های ثبت شده در ایستگاه های باران سنجی و مدل رقومی ارتفاعی محدوده مطالعاتی به منظور تخمین داده های سری زمانی بارش در ایستگاه های هیدرومتری سود برده شد؛ به این ترتیب که برای ایجاد مدل رگرسیونی از بارش های روزانه پنج ایستگاه باران سنجی در بازه زمانی ۲۰۰۷ تا ۲۰۱۳ و به منظور دقت سنجی نتایج حاصل، از داده های بارش به کار نگرفته شده در مدل در همین بازه استفاده شد.

در مجموع شش لایه‌ی اطلاعاتی شامل شیب دامنه، انحنای دامنه، تجمع جریان، NDVI، زمین شناسی و رده‌های خاک همراه با داده های سری زمانی بارش روزانه درونبایی شده برای ۵ ایستگاه هیدرومتری به عنوان هفت لایه ورودی برای مدل سازی سیلاب در حوضه کن به کار رفتند. معماری شبکه عصبی عمدتاً بر مبنای سعی و خطا، نتایج و دقت خروجی ها طراحی و بهینه شد و با توجه به ماهیت مسئله یک شبکه عصبی پرسپترون چهار لایه با الگوی آموزش پس انتشار به کار گرفته شد. به طوری که لایه اول شامل هفت نورون ورودی ها و لایه های دوم و سوم به عنوان لایه های مخفی به ترتیب در بردارنده هشت و شانزده نورون با گره پردازشی بودند، در حالی که لایه چهارم به عنوان لایه ی

نورون z_j از رابطه ۲ به ترتیب زیر حاصل می‌شود (Hu & Weng 2009):

$$O_j = f(\text{net}_j) \quad (2)$$

که در آن تابع f معمولاً یک تابع سیگموئیدی یا زنگوله‌ای غیرخطی که پارامترهای آن با توجه به رفتار داده‌ها می‌تولند، تعیین شود. در این پژوهش ورودی‌ها متناظر با لایه‌های اطلاعاتی آماده شده در GIS و خروجی‌ها مقادیر پیش بینی شده دبی روزانه در حوضه آبخیز کن است. اگرچه راه حل مورد توافقی برای تعیین تعداد نورون‌های لایه‌ی مخفی معرفی نشده، با این حال رابطه ۳ را می‌توان به این منظور به کار برد.

$$N_h = INT \sqrt{N_i \times N_o} \quad (3)$$

در رابطه بالا N_h تعداد نورون‌های لایه‌ی مخفی (با اعمال عملگر INT باید عددی صحیح باشد)، N_i تعداد نورون‌های لایه‌ی ورودی و N_o تعداد نورون‌های لایه‌ی خروجی را نشان می‌دهد (Hu & Weng, 2009).

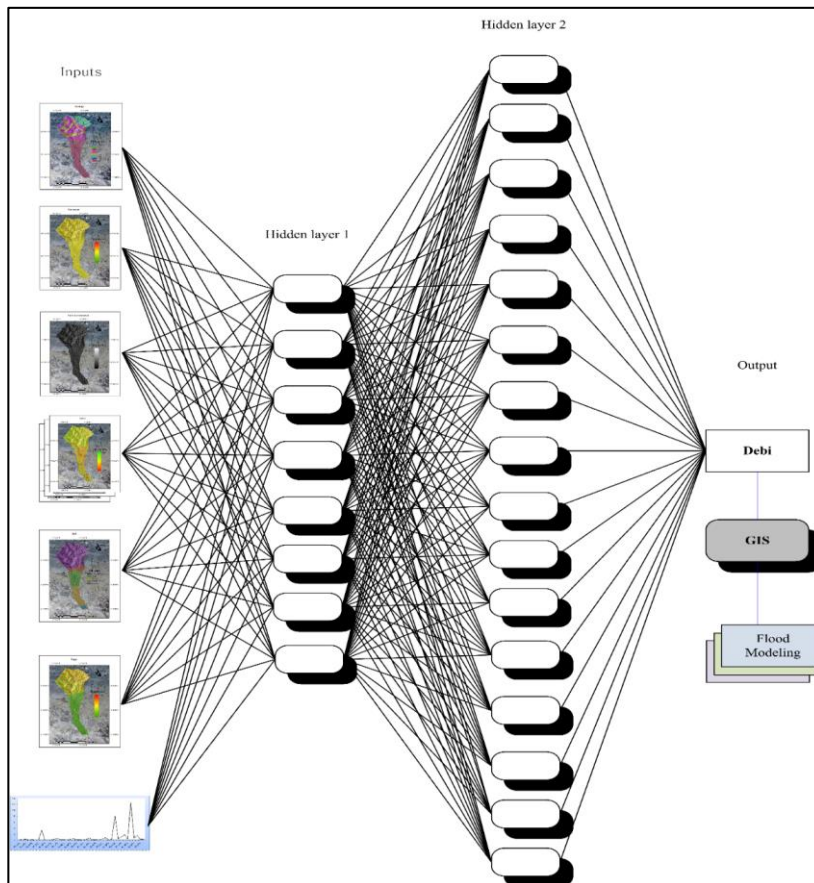
در این مطالعه برای نمونه‌های آموزشی و آزمایشی که به ترتیب به منظور یادگیری و برآورد خطای شبکه‌ی عصبی استفاده می‌شوند، باید از پیکسل‌های نشان دهنده مقادیر دبی روزانه ثبت شده استفاده نمود. در مورد نرخ آموزش و فاکتور لحظه‌ای هم به ترتیب مقادیر ۰/۱ تا ۰/۲ و ۰/۵ تا ۰/۶ پیشنهاد شده است (Kavzoglu & Mather, 2003) که البته با ملاحظه شرایط خاص هر مطالعه این مقادیر برای نیل به نتایج مطلوب می‌توانند دستخوش تغییر شوند. همچنین الگوی Levenberg-Marquardt به عنوان یک الگوی پس انتشار برای آموزش شبکه استفاده شد. در نهایت اجرای الگوریتم MLP با استفاده از جعبه ابزار شبکه های عصبی مصنوعی در برنامه Matlab 2015 صورت گرفته است.

بحث و نتایج

این مطالعه با توجه به همبستگی بالای میان دبی اوج و بارش‌های منجر به سیل به عنوان یک خصوصیت متغیر مرتبط با وقوع سیل از یک طرف و وجود رابطه میان ویژگی‌های فیزیوگرافی حوضه و وقوع سیل در منطقه از

آن به ترتیب نشان دهنده مقادیر ۵۳٪ و ۸۲٪ بود، ضمن اینکه دقت کل نیز ۶۲٪ را نشان می‌داد (شکل‌های ۵ و ۶). البته این مقادیر جدا از دقت سنجی خروجی‌های پیش‌بینی شده با به کارگیری پارامترهای دقت سنجی شناخته شده چون: میانگین جذر مربعات خطا^۱ (RMSE)، خطای متوسط میانگین^۲ (MAE) و ضریب تشخیص یا تعیین (R^2) بوده است که در ادامه این مقادیر آورده شده است.

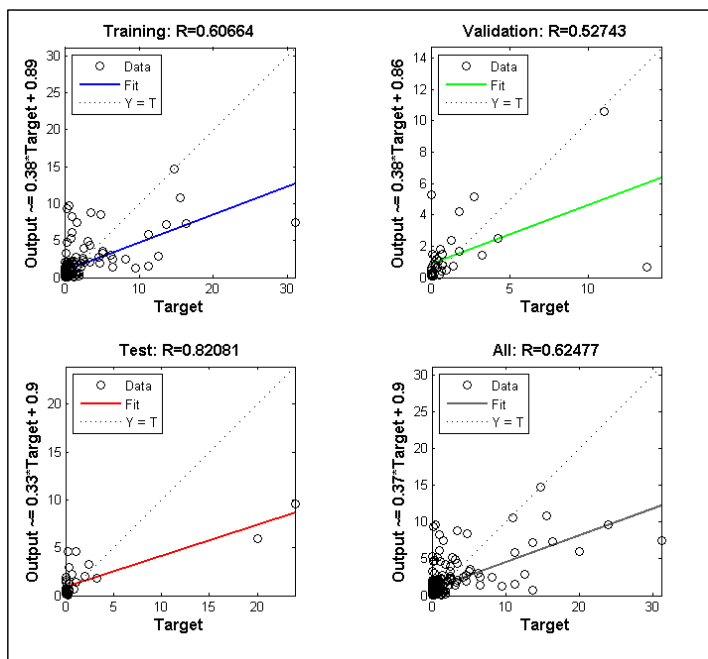
خروجی حاوی دبی‌های پیش‌بینی شده به عنوان نتایج نهایی شبکه بود (شکل ۴). داده‌های به کار رفته برای مدل‌سازی در قالب شبکه عصبی به صورت تصادفی انتخاب شدند؛ به طوری که ۶۵٪ آنها برای آموزش شبکه استفاده شدند در حالی که به منظور اعتبارسنجی و آزمایش شبکه به ترتیب ۲۰٪ و ۱۵٪ درصد داده‌های انتخابی به کار رفتند. ضریب تعیین یا R^2 و به عبارتی دقت آموزش شبکه طراحی شده بیش از ۶۰٪ بود در حالی که دقت‌های معتبرسازی و آزمایش




شکل ۴- معماری ساختار شبکه عصبی پرسپترون چهار لایه پیشنهادی برای مدل‌سازی سیلاب در حوضه کن

^۲- Mean Average Error

^۱- Root Mean Square Error



شکل ۵- همبستگی میان داده‌های هدف و داده‌های پیش‌بینی شده در حین اعتبارسنجی (بالا سمت راست)، آموزش (بالا سمت چپ)، آزمون دقت (پایین سمت چپ) و مجموع اعتبارسنجی، آموزش و آزمون دقت




شکل ۶- عملکرد شبکه عصبی در حین اجرای مدل. هنگامی که خطای مراحل آموزش، اعتبارسنجی و آزمون دقت شبکه عصبی به طور همزمان به پایین‌ترین مقدار برسد، نشان‌دهنده عملکرد مناسب شبکه در آن تکرار می‌باشد.

مجموعه دربردارنده نمونه‌های تصادفی مقادیر پیش‌بینی شده و مقادیر ثبت شده برای ایستگاه‌ها در شکل ۷ نشان داده شده است. در شکل ۸ مقایسه میان دبی روزهای سیلابی و


همان‌طور که در قبل اشاره شد، خروجی شبکه عصبی طراحی شده در این مطالعه مقادیر دبی ایستگاه‌های هیدرومتری در محدوده مورد مطالعه بود. مقایسه میان

و از آنجایی که دبی بیشینه می‌تواند برای پیش‌بینی سیل استفاده گردد، این تقریب می‌تواند کارایی نتایج حاصل را نشان دهد.

متوسط دبی بیشینه سیل آورده شده است. با دقت در خروجی‌های فوق مشخص می‌شود که در دبی‌های بالاتر اختلاف میان مقادیر پیش‌بینی شده و ثبت شده کمتر می‌شود.



شکل ۷- مقایسه میان مقادیر دبی پیش‌بینی شده برای ایستگاه‌ها و دبی روزانه ثبت شده. خط سمت سفید مقادیر پیش‌بینی شده دبی و خط نقطه چین سیاه مقادیر مشاهده شده دبی را نشان می‌دهد.



شکل ۸- دبی بیشینه سیلابی و متوسط دبی بیشینه منجر به سیل در ایستگاه‌های هیدرومتری. خط سیاه مقادیر بیشینه دبی و خط سفید متوسط مقادیر بیشینه دبی را نشان می‌دهد.

$$R^2 = \frac{\sum_{i=1}^N (\hat{I}_i - \bar{I})^2}{\sum_{i=1}^N (I_i - \bar{I})^2} \quad (۶)$$

در روابط بالا، \hat{I}_i دبی برآورد شده برای نمونه i ، I_i مقدار دبی از داده‌های مرجع، \bar{I} میانگین مقادیر دبی نمونه‌ها و N تعداد نمونه‌ها می‌باشد. تعیین مقادیر پارامترهای دقت سنجی فوق با استفاده از نمونه برداری تصادفی ساده داده‌های برآورد شده و مرجع صورت گرفت. مقادیر RMSE

برای ارزیابی دقت مقادیر دبی پیش‌بینی شده از سه پارامتر RMSE، MAE و R^2 استفاده می‌شود (Powell et al., 2007):

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{I}_i - I_i)^2}{N}} \quad (۴)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |I_i - \hat{I}_i| \quad (۵)$$

MAE و R^2 برای مدلسازی و پیش‌بینی مقادیر دبی و دبی اوج در جدول ۲ آورده شده است.

جدول ۲- دقت برآورد شده برای مقادیر پیش‌بینی شده دبی و دبی اوج با شیوه شبکه عصبی مصنوعی

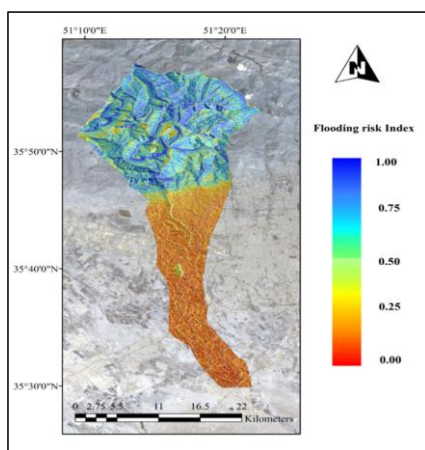
| مقادیر شاخص‌های دقت سنجی | | | شیوه اجرا شده | پارامتر برآورد شده |
|--------------------------|------|------|------------------|--------------------|
| R ² | MAE | RMSE | | |
| ۰/۸۲ | ۰/۱۳ | ۰/۱۸ | شبکه عصبی مصنوعی | دبی |
| ۰/۸۴ | ۰/۱۲ | ۰/۱۶ | شبکه عصبی مصنوعی | دبی اوج |
| ۰/۷۱ | ۰/۱۷ | ۰/۲۱ | SCS | دبی اوج |

اجرای الگوریتم شبکه عصبی مصنوعی میان لایه‌های ورودی و نورون‌های لایه مخفی اول پیداست که متوسط ارجحیت‌های ورودی‌های بارش و پس از آن پوشش گیاهی از بالاترین مقادیر برخوردار هستند، به دلیل این است که دو ورودی فوق در مقایسه با دیگر ورودی‌ها چون زمین‌شناسی، شیب و ... نسبت به زمان متغیرتر می‌باشند،

نقشه پهنه بندی مناطق در خطر سیل بر اساس متوسط اوزان میان لایه‌های شبکه عصبی به کار رفته (جدول ۳)، ایجاد شد (Kia et al., 2012) که می‌تواند در فرآیند برنامه ریزی فضایی و شناسایی نواحی مستعد وقوع سیلاب به خصوص در صورت مشاهده دبی‌های نزدیک به دبی اوج سیلاب، در مقیاس‌های زیرحوضه‌ای قابلیت‌های قابل‌اعتنایی را از خود نشان دهد (شکل ۹). با دقت در اوزان به دست آمده از

جدول ۳- اوزان میان ورودی‌ها و نورون‌های لایه مخفی اول

| اوزان لایه‌های ورودی | | | | | | | | |
|----------------------|--------|-----------|--------------|-------------|------------|------------|-------------|---------|
| لایه ورودی | بارش | شیب دامنه | انحنای دامنه | جریان تجمعی | پوشش گیاهی | زمین‌شناسی | رده‌های خاک | |
| شماره نورون | ۱ | -۰/۱۱۲۲ | ۰/۲۸۳۴ | -۰/۹۶۷۳ | ۰/۶۰۶۹ | ۰/۰۰۲۳ | -۰/۴۳۷۱ | ۰/۰۳۱۷ |
| | ۲ | -۳/۱۳۴۸ | -۰/۳۳۶۰ | -۶/۳۳۱۷ | -۲/۹۰۸۹ | -۳/۳۲۱۳ | ۰/۰۰۵۴۳ | -۳/۸۷۱۲ |
| | ۳ | ۵/۶۵۸۴ | -۸/۴۱۷۵ | -۲/۱۳۲۲ | ۰/۵۴۲۷ | ۴/۴۵۸۱ | -۷/۵۴۱۰ | ۰/۰۶۵۴ |
| | ۴ | ۳/۱۰۸۳ | -۰/۸۵۱۰ | -۰/۲۱۳۴ | -۱/۶۱۳۴ | ۶/۶۷۱۲ | ۰/۰۹۱۵ | -۲/۶۷۱۳ |
| | ۵ | ۲/۶۹۱۲ | ۲/۳۵۲۶ | ۴/۰۶۵۹ | -۴/۰۲۰۳ | -۳/۷۸۴۳ | -۴/۸۳۲۱ | ۰/۰۰۵۴۱ |
| | ۶ | ۲/۶۱۶۲ | ۱/۷۵۰۴ | -۳/۶۶۲۰ | ۲/۷۸۱۱ | -۰/۷۰۰۱ | ۰/۲۱۴۵۸ | ۳/۷۸۳۱ |
| | ۷ | ۲/۰۰۳۵ | ۱/۰۴۶۲ | ۰/۲۰۱۶ | ۴/۰۴۴۶ | -۰/۰۴۱۸ | ۷/۹۲۱۳ | -۲/۹۳۱۸ |
| | ۸ | -۰/۰۸۸۴ | -۱/۶۱۱۹ | -۱/۵۹۳۳ | ۰/۱۳۱۶ | ۳/۹۵۱۷ | -۰/۰۰۵۴ | ۵/۸۳۲۱ |
| وزن متوسط | ۱/۵۹۲۷ | ۰/۷۹۲۹ | -۱/۳۲۹۰ | -۰/۰۵۴۴ | ۰/۹۰۴۴ | ۰/۰۵۶۶۷ | ۰/۰۳۶۵ | |



شکل ۹- نقشه پهنه بندی خطر وقوع سیلاب در حوضه کن بر اساس اوزان حاصل از شبکه عصبی

ویژگی‌های خاص خود را دارا می‌باشند، مدل‌های تجربی نمی‌توانند به نواحی با خصوصیات متفاوت تعمیم یابند و لازم است روش‌هایی استفاده شود که بتوان بر اساس خصوصیات ذاتی هر حوضه، دبی سیلابی آن را شبیه‌سازی نمود. این مطالعه با بهره‌گیری از قابلیت برآورد و شبیه‌سازی شبکه عصبی و بهره‌گیری از توابع تحلیل مکانی GIS، ضمن پیش‌بینی پارامترهایی چون دبی و دبی اوج سیلاب با دقت مناسب که ارتباط مستقیم و محکمی با وقوع سیلاب و بارش‌های سیل‌آسا دارند، با استخراج اوزان یا اهمیت‌های نسبی برای لایه‌های اطلاعاتی ورودی مؤثر در وقوع رخداد سیلاب، توانسته ویژگی‌های خاص هر حوضه را در مدلسازی سیلاب مد نظر قرار بدهد به طوری که هر دو جنبه پیش‌بینی دبی و دبی اوج سیلاب و پهنه بندی خطر وقوع سیلاب در گستره مطالعاتی با به کارگیری نتایج حاصل از اجرای الگوریتم شبکه‌های عصبی مصنوعی پرسپترون چندلایه میسر شده است. چالش عمده در این فرآیند عدم دسترسی به داده‌های سطحی متغیرها و پارامترهای تأثیرگذار در سیلاب بود که با کمک توابع درون‌یابی، برآورد اطلاعات مذکور از داده‌های نقطه‌ای امکان‌پذیر شد.

مطالعه حاضر قابلیت‌های استفاده از داده‌های متغیر و پویای بارش و پوشش گیاهی با در نظر گرفتن گذر زمان، به همراه خصوصیات نسبتاً ثابت فیزیوگرافی و ذاتی حوضه آبریز شامل: شیب، انحنا، دامنه، جریان تجمعی، واحدهای زمین

از این روست که دامنه آن‌ها نیز نسبتاً بالا می‌باشند؛ این اهمیت‌ها به عنوان شاخصی برای پهنه بندی خطر وقوع سیلاب در محدوده مطالعاتی به کار رفتند که با عنوان نقشه خطر سیلاب در شکل ۹ آورده شده است؛ به طوری که مجموع اوزان حاصل برای هر ورودی به منظور همپوشانی لایه‌های اطلاعاتی در محیط GIS به کار رفت و نقشه پهنه بندی خطر وقوع سیلاب ایجاد شد. به عبارتی همپوشانی لایه‌های اطلاعاتی با استفاده از مجموع حاصلضرب متوسط اوزان استخراج شده از ANN، در مقادیر نرمال شده پیکسل‌های هر رستر، به منظور پهنه بندی خطر وقوع سیلاب در محدوده مطالعاتی به دست آمد. از مشاهده نقشه فوق مشخص می‌شود که نواحی شمالی به طور اعم و خط القعر زهکش‌های رودخانه کن به طور خاص از بالاترین پتانسیل سیل‌خیزی به هنگام بارش‌های منجر به دبی بیشینه سیل برخوردارند.

نتیجه‌گیری

به دلیل دامنه آسیب‌های بالقوه و بالفعل مخاطره سیلاب پژوهشگران به دنبال توسعه روش‌های دقیق و بهینه برای مدلسازی آن با هدف کمینه کردن اثرات مخرب آن هستند. جهت برآورد دبی منجر به سیلاب در حوضه‌های فاقد آمار، از مدل‌های تجربی مختلفی از جمله روش تحلیل منطقه‌ای سیلاب، استفاده می‌شود. اما به دلیل آنکه هر حوضه آبریز

وقوع سیلاب در حوضه مطالعاتی به کار گرفته شد. این پهنه بندی معلوم ساخت که نواحی شمالی و خط القعرهای حوضه کن پتانسیل سیل خیزی بالاتری را نشان می‌دهند.

نتایج و یافته‌های این پژوهش می‌تواند در برنامه ریزی‌های محیطی آبی در مقیاس محلی به عنوان امکان و قابلیت برای بهبود مدیریت بحران و مخاطرات زیست محیطی با تأکید بر مخاطره سیل به کار رود. به طور کلی این مطالعه نشان داد که کاربرد توأم توابع تحلیل مکانی GIS و الگوریتم شبکه عصبی مصنوعی، به عنوان یکی از الگوریتم‌های هوش مصنوعی و تکاملی، کارایی و کارکرد بالایی برای مدلسازی مکانی و پیش بینی پتانسیل وقوع مخاطرات طبیعی چون سیلاب به خصوص در گستره‌ها و حوضه‌های دربردارنده رودخانه‌هایی با تغییرات قابل توجه در توپوگرافی محدوده تحت اثر دارد. پیشنهاد می‌شود در مطالعات آبی کارایی دیگر الگوریتم‌های محاسباتی تکاملی در مدلسازی سیلاب و مؤلفه‌ها و پارامترهای مرتبط با آن مورد کنکاش و مقایسه قرار گیرد.

شناختی و رده‌های خاک را در قالب هشت لایه اطلاعاتی در پیش بینی و تخمین دبی به عنوان شاخصی از وقوع سیلاب بر مبنای شبکه عصبی مصنوعی به خوبی نشان داده است. استفاده از لایه اطلاعاتی انحنای دامنه که تععر و تحدب توپوگرافی گستره مطالعاتی را نشان می‌دهد، از پتانسیل بالایی برای مدلسازی مخاطراتی چون سیلاب برخوردار است که در این مطالعه مورد ملاحظه قرار گرفته است. شبکه عصبی بهینه برای این مطالعه از یک لایه ورودی با ۸ نورون شامل داده‌های ورودی، دو لایه مخفی به ترتیب شامل ۸ و ۱۶ نورون و لایه خروجی نشان دهنده دبی پیش بینی شده در ایستگاه‌ها تشکیل شده است. به طور کلی مسیر مطالعه از محیط GIS آغاز و با به کارگیری خروجی‌ها و اوزان حاصل از اجرای بهینه شبکه عصبی به منظور همپوشانی لایه‌های اطلاعاتی ورودی دوباره به GIS ختم می‌گردد. تحلیل داده‌های ایستگاه‌های هیدرومتری و باران سنجی بر اساس درجات اهمیتی که در اتصال با لایه‌های ورودی به خود اختصاص می‌دهند، به عنوان معیاری برای پهنه بندی خطر

منابع

1. امیراحمدی، ابوالقاسم و کرامتی، صغری و احمدی، طیبیه. (۱۳۹۱). ریز پهنه بندی خطر سیلاب در محدوده شهر نیشابور در راستای توسعه شهری. مجله پژوهش و برنامه ریزی شهری، شماره ۷، صص ۹۱ تا ۱۱۰.
2. جعفری، عباس. (۱۳۸۴). گیتاشناسی ایران، رودها و رودنامه ایران، تهران، انتشارات موسسه جغرافیایی و کارتوگرافی گیتاشناسی، تهران.
3. علایی طالقانی، محمود و همایونی، صدیقه. (۱۳۹۰). پهنه بندی حوضه ی دینور از نظر تولید سیلاب با استناد به مؤلفه های ژئومورفولوژی. پژوهش نامه ی جغرافیایی، شماره ۱، صص ۳۷ تا ۴۹.
4. قاسمی، علی و سلاجقه، علی و ملکیان، آرش و اسمعیلی عوری، ابانر. (۱۳۹۳). بررسی سیل خیزی و تعیین عوامل مؤثر در آن در حوضه رودخانه بالفیچای با استفاده از تکنیک GIS،RS و محیط شناسی، شماره ۲، صص AHP و ۳۸۹ تا ۴۰۰.
5. نگارش، حسین و ازدری مقدم، مهدی و آرمش، محسن. (۱۳۹۲). کاربرد شبکه‌ی عصبی مصنوعی در شبیه‌سازی و پیش بینی سیلاب در حوضه ی ابریز سرپاز. جغرافیا و توسعه، شماره ۳۱، صص ۱۵ تا ۲۸.
6. Billa, L., Mansor, Sh, Mahmud, A.R and Ghazali, A.H, (2004), Integration of RS, GIS and MIKE 11 Hydrodynamic Modeling for Flood Early Warning: A case study of the Langat river basin Malaysia.
7. Carrara, A., Guzzetti, F., Cardinali, M., & Reichenbach, P. (1999). Use of GIS technology in the prediction and monitoring of landslide hazard. *Natural hazards*, 20(2-3), 117-135.
8. Dang, N. M., Babel, M. S., & Luong, H. T. (2011). Evaluation of food risk parameters in the day river flood diversion area, Red River delta, Vietnam. *Natural hazards*, 56(1), 169-194.
9. Dawson, C. W., Abrahart, R. J., Shamseldin, A. Y., & Wilby, R. L. (2006). Flood estimation at ungauged sites using artificial neural networks. *Journal of Hydrology*, 319(1), 391-409.
10. Dixon, B. (2005). Applicability of neuro-fuzzy techniques in predicting groundwater vulnerability: a GIS-based sensitivity analysis. *Journal of hydrology*, 309(1), 17-38.
11. Elsafi, S. H. (2014), Artificial Neural Networks (ANNs) for flood forecasting at Dongola Station in the River Nile, Sudan. *Alexandria Engineering Journal*, 53, 655-662.
12. Ezemonye, M. N., & Emeribe, C. N. (2011). Flood characteristics and management adaptations in parts of the Imo

- river system. *Ethiopian Journal of Environmental studies and management*, 4(3), 56-64.
13. Farajzadeh, M. (2001, August). The flood modeling using multiple regression analysis in Zohre & Khyrabad Basins. In 5th International Conference of Geomorphology.
 14. Farajzadeh, M. (2002, September). Flood susceptibility zonation of drainage basins using remote sensing and GIS, case study area: Gaveh rod Iran. In *Proceeding of international symposium on geographic information systems*, Istanbul, Turkey (pp. 23-26).
 15. Feng LH, Lu J (2010) The practical research on flood forecasting based on artificial neural networks. *Expert Syst Appl* 37:2974-2977.
 16. Fotouhi, S., & Kiani, S. (2015). Micro-zonation of the Urban Flood Risk Model Using AHP (Case Study: Nahavand city).
 17. Geological Survey & Mineral Explorations of Iran (GSI).
 18. Ghanavati, E., Karam, A., & Aghaalkhani, M. (2013). Flood risk zonation in the farahzad basin (Tehran) using Fuzzy model. *Geography and Environmental Planning*, 23(4), 121-138.
 19. Ghanavati, E. (2014). Flood Risk Zonation for Karaj City Using Fuzzy Logic. *Journal of Geography and Environmental Hazards*, 2(4), 113-132. doi: 10.22067/geo.v0i0.27924
 20. Gomez H, Kavzoglu T (2005) Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin. *Venezuela. Eng Geol* 78(1-2):11-27
 21. Hashemyan, F., M. R. Khaleghi, and M. Kamyar. (2015). Combination of HEC-HMS and HEC-RAS models in GIS in order to Simulate Flood (Case study: Khoshke Rudan river in Fars province, Iran). *Research Journal of Recent Sciences*, 4 (8), 122- 127.
 22. Hematzadeh, Y., Barani, H., & Kabir, A. (2009). The role of vegetation management on surface runoff (Case study: Kechik catchment in north-east of Golestan Province).
 23. Hess, L. L., Melack, J. M., & Simonett, D. S. (1990). Radar detection of flooding beneath the forest canopy: a review. *International Journal of Remote Sensing*, 11(7), 1313-1325.
 24. Hess, L. L., Melack, J. M., Filoso, S., & Wang, Y. (1995). Delineation of inundated area and vegetation along the Amazon floodplain with the SIR-C synthetic aperture radar. *IEEE Transactions on Geoscience and Remote Sensing*, 33(4), 896-904.
 25. Horritt, M. S., & Bates, P. D. (2002). Evaluation of 1D and 2D numerical models for predicting river flood inundation. *Journal of hydrology*, 268(1), 87-99.
 26. Hu, X., & Weng, Q. (2009). Estimating impervious surfaces from medium spatial resolution imagery using the self-organizing map and multi-layer perceptron neural networks. *Remote Sensing of Environment*, 113(10), 2089-2102.
 27. Huo, Z., Feng, S., Kang, S., Huang, G., & Wang, F. (2012). Integrated neural networks for monthly river flow estimation in arid inland basin of Northwest China. *Journal of Hydrology*, 159-170.
 28. Hudson, P. F., & Colditz, R. R. (2003). Flood delineation in a large and complex alluvial valley, lower Panuco basin, Mexico. *Journal of Hydrology*, 280(1), 229-245.
 29. Islam, M. M., Sado, K. I. M. I. T. E. R. U., Owe, M., Brubaker, K., Ritchie, J., & Rango, A. (2001). Flood damage and management modelling using satellite remote sensing data with GIS: case study of Bangladesh. *IAHS PUBLICATION*, 455-457.
 30. Islam, M. M., & Sado, K. (2002). Development priority map for flood countermeasures by remote sensing data with geographic information system. *Journal of Hydrologic Engineering*, 7(5), 346-355.
 31. Jenson, S. K., & Domingue, J. O. (1988). Extracting topographic structure from digital elevation data for geographic information system analysis. *Photogrammetric engineering and remote sensing*, 54(11), 1593-1600.
 32. Kafle, T. P., Hazarika, M. K., Shrestha, K. G., Prathumchai, K., & Samarakoon, L. (2006). Integration of remote sensing and GIS with flood simulation model for flood hazard mapping in the Bagmati River, Nepal. *Thailand: New Technologies for Urban Safety of Mega Cities in Asia*, 257-268.
 33. Kalteh, A. M. (2008). Rainfall-runoff modelling using artificial neural networks (ANNs): modelling and understanding. *Caspian Journal of Environmental Sciences*, 6(1), 53-58.

34. Kavzoglu, T., & Mather, P. M. (2003). The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, 24(23), 4907-4938
35. Kentel, E. (2009). Estimation of river flow by artificial neural networks and identification of input vectors susceptible to producing unreliable flow estimates. *Journal of hydrology*, 375(3), 481-488.
36. Kerh, T., & Lee, C. S. (2006). Neural networks forecasting of flood discharge at an unmeasured station using river upstream information. *Advances in Engineering Software*, 37(8), 533-543.
37. Kia, M. B., Pirasteh, S., Pradhan, B., Mahmud, A. R., Sulaiman, W. N. A., & Moradi, A. (2012). An artificial neural network model for flood simulation using GIS: Johor River Basin, Malaysia. *Environmental Earth Sciences*, 67(1), 251-264.
38. Kim, M., & Gilley, J. E. (2008). Artificial Neural Network estimation of soil erosion and nutrient concentrations in runoff from land application areas. *Computers and electronics in agriculture*, 64(2), 268-275.
39. Kia, M. B., Pirasteh, S., Pradhan, B., Mahmud, A. R., Sulaiman, W. N. A., & Moradi, A. (2012). An artificial neural network model for flood simulation using GIS: Johor River Basin, Malaysia. *Environmental Earth Sciences*, 67(1), 251-264.
40. Liu, C., Li, Y., & Li, J. (2017). Geographic information system-based assessment of mitigating flash-flood disaster from green roof systems. *Computers, Environment and Urban Systems*, 64, 321-331.
41. Liu, H., & Chandrasekar, V. (2000). Classification of hydrometeors based on polarimetric radar measurements: Development of fuzzy logic and neuro-fuzzy systems, and in situ verification. *Journal of Atmospheric and Oceanic Technology*, 17(2), 140-164.
42. Mahmudian, Ali Akbar. Ghasemi, Houshang. Houshmand fini, Gholam Reza. Artidar, Reza. (2006). A glance at Tehran from the beginning up till now. Tehran: GITASHENASI Geographical & Cartographic Institute.
43. Maier, H. R., & Dandy, G. C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental modelling & software*, 15(1), 101-124.
44. Menhaj, M. B. (1998). Fundamentals of neural networks. *Computational intelligence*, 1(1).
45. Moore, I. D., Grayson, R. B., & Ladson, A. R. (1991). Digital terrain modelling: a review of hydrological, geomorphological, and biological applications. *Hydrological processes*, 5(1), 3-30.
46. Mukand, N.M.D., Huynh, S.B. and T. Luong. (2011). Evaluation of food risk parameters in the Day River Flood Diversion Area, Red River Delta, Vietnam. *Nat Hazards*, 56:169-194.
47. Natural Resources and Watershed Management Organization
48. Pawattana, C., Tripathi, N. K., & Htwe, S. L. (2009). Development of Potential Floodwater Retention Zones using AHP and GIS: A Case Study in the Chi River Basin, Thailand. *International Journal of Geoinformatics*, 5(4).
49. Pirasteh, S., Rizvi, S. M. A., Ayazi, M. H., & Mahmoodzadeh, A. (2010). Using microwave remote sensing for flood study in Bhuj Taluk, Kuchch District Gujarat, India. *Int Geoinformatics Res Dev J*, 1(1), 13-24.
50. Pontes, P. R. M., Fan, F. M., Fleischmann, A. S., de Paiva, R. C. D., Buarque, D. C., Siqueira, V. A., ... & Collischonn, W. (2017). MGB-IPH model for hydrological and hydraulic simulation of large floodplain river systems coupled with open source GIS. *Environmental Modelling & Software*, 94, 1-20.
51. Powell, R. L., Roberts, D. A., Dennison, P. E., & Hess, L. L. (2007). Sub-pixel mapping of urban land cover using multiple endmember spectral mixture analysis: Manaus, Brazil. *Remote Sensing of Environment*, 106(2), 253-267.
52. Pradhan, B., & Lee, S. (2009). Landslide risk analysis using artificial neural network model focussing on different training sites. *International Journal of Physical Sciences*, 4(1), 1-15.
53. Oh, H. J., & Pradhan, B. (2011). Application of a neuro-fuzzy model to landslide-susceptibility mapping for shallow landslides in a tropical hilly area. *Computers & Geosciences*, 37(9), 1264-1276.
54. Ray, C., & Klindworth, K. K. (2000). Neural networks for agrichemical vulnerability assessment of rural private

- wells. *Journal of Hydrologic Engineering*, 5(2), 162-171.
55. Saini, S. S., & Kaushik, S. P. (2012). Risk and vulnerability assessment of flood hazard in part of Ghaggar Basin: A case study of Guhla block, Kaithal, Haryana, India. *International Journal of Geomatics and Geosciences*, 3(1), 42-54.
56. Saghafian, B. and H. Farazjoo. 2007. Determination of flood source areas and flooding prioritization of hydrologic units in Golestam dam watershed, Iranian journal of watershed management science and engineering 1: 1-11.
57. Sarhadi, A., Soltani, S., & Modarres, R. (2012). Probabilistic flood inundation mapping of ungauged rivers: Linking GIS techniques and frequency analysis. *Journal of Hydrology*, 458, 68-86.
58. See, L., & Openshaw, S. (2000). A hybrid multi-model approach to river level forecasting. *Hydrological Sciences Journal*, 45(4), 523-536.
59. Seenath, A., Wilson, M., & Miller, K. (2016). Hydrodynamic versus GIS modelling for coastal flood vulnerability assessment: Which is better for guiding coastal management?. *Ocean & Coastal Management*, 120, 99-109.
60. Stefanidis, S., & Stathis, D. (2013). Assessment of flood hazard based on natural and anthropogenic factors using analytic hierarchy process (AHP). *Natural hazards*, 68(2), 569-585.
61. Stripling, S., Panzeri, M., Blanco, B., Rossington, K., Sayers, P., & Borthwick, A. (2017). Regional-scale probabilistic shoreline evolution modelling for flood-risk assessment. *Coastal Engineering*, 121, 129-144
62. Wang, W., Chau, W., Qiu, L., & Chen, Y. (2015). Improving forecasting accuracy of medium and long-term runoff using artificial neural network based on EEMD decomposition. *Environmental Research*.
63. Wu, C. L., Chau, K. W., & Li, Y. S. (2009). Methods to improve neural network performance in daily flows prediction. *Journal of Hydrology*, 80-93.
64. Yang, X. L., Ding, J. H., & Hou, H. (2013). Application of a triangular fuzzy AHP approach for flood risk evaluation and response measures analysis. *Natural hazards*, 68(2), 657-674.
65. Zevenbergen, L. W., & Thorne, C. R. (1987). Quantitative analysis of land surface topography. *Earth surface processes and landforms*, 12(1), 47-56.