



سنجش از دور & GIS ایران



سنجش از دور و GIS ایران سال ششم، شماره چهارم، زمستان ۱۳۹۳
Iranian Remote Sensing & GIS Vol. 6, No. 4, Winter 2015

۱-۱۵

تخمین میزان رواناب حوضه کن با استفاده از شبکه عصبی مصنوعی

علی اکبر متکان^۱، علیرضا شکیبیا*^۲، امین حسینی اصل^۳، فردین رحیمی دهگلان^۴

۱ و ۲. دانشیار گروه سنجش از دور و GIS، دانشکده علوم زمین، دانشگاه شهید بهشتی

۳. مربی گروه سنجش از دور و GIS، دانشکده علوم زمین، دانشگاه شهید بهشتی

۴. کارشناس ارشد سنجش از دور و GIS، دانشکده علوم زمین، دانشگاه شهید بهشتی

تاریخ پذیرش مقاله: ۱۳۹۲/۹/۹

تاریخ دریافت مقاله: ۱۳۹۰/۱۲/۹

چکیده

رواناب یکی از اجزای ضروری محاسبه فرایندهای منابع آب و مسئله‌ای اصلی در هیدرولوژی است. مدل‌های مفهومی زیادی برای پیش‌بینی میزان رواناب مطرح شده‌اند که عمدتاً نیازمند داده‌های توپوگرافی و هیدرولوژیکی هستند. روش‌های مرسوم گذشته برای نواحی‌ای که داده‌های هیدرولوژیکی کافی ندارند، نامناسب‌اند. تخمین رواناب، فرایندی غیرخطی و از نظر زمانی و مکانی به‌طور کامل تصادفی است و شبیه‌سازی آن با مدل ساده به‌راحتی امکان‌پذیر نیست. امروزه استفاده از شبکه‌های عصبی مصنوعی در مواردی که کمبود داده‌ها محسوس است، روش مناسبی به‌شمار می‌آید. در پژوهش حاضر از داده‌های بارش، دما و دبی ایستگاه‌های حوضه کن در بازه زمانی ۱۳۷۵ تا ۱۳۸۵ و همچنین خصوصیات فیزیوگرافی حوضه مورد مطالعه به‌عنوان ورودی شبکه عصبی برای پیش‌بینی رواناب استفاده شد. بدین منظور به‌صورت تصادفی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد داده‌ها برای تست و اعتبارسنجی شبکه اختصاص داده شدند. به‌منظور انتخاب شبکه بهینه، از دو نوع تابع انتقال، ۱۲ تابع آموزشی، و تعدادی نرون مخفی مختلف بین ۱ تا ۹ نرون استفاده شد. نتایج پژوهش پس از آزمون شبکه با لایه‌های پنهان و با توابع یادگیری مختلف آشکار ساختند که استفاده از داده‌های بارش، دما و دبی، و تابع آموزشی LM و تابع انتقال Tansig و چهار نرون مخفی، بهترین ساختار را برای تخمین رواناب به‌دست می‌دهد. شبکه عصبی با این ساختار می‌تواند رواناب را با دقت $(0.68 \geq R^2 \geq 0.78)$ و $(0.03 \leq RMSE \leq 0.53)$ برآورد کند.

کلیدواژه‌ها: تخمین رواناب، شبکه عصبی مصنوعی، الگوریتم پس‌انتشار خطا، حوضه کن، سامانه اطلاعات جغرافیایی.

* نویسنده مکاتبه‌کننده: دانشگاه شهید بهشتی، گروه سنجش از دور و GIS. تلفن: ۰۹۱۲۳۲۷۴۹۹۱

۱- مقدمه

مذکور این است که چون تعداد زیادی نرون در یک زمان درگیر فعالیت هستند، سهم هر نرون اهمیت چندانی ندارد. بنابراین وجود خطا در یکی از آنها و نتیجه آن تأثیر زیادی بر سایر واحدهای محاسباتی نخواهد داشت (Ibid).

تاکنون مدل‌های مفهومی بسیاری برای پیش‌بینی رواناب مطرح شده‌اند که در اکثر موارد نیازمند داده‌های توپوگرافی و هیدرولوژیکی هستند (نوری و همکاران، ۱۳۸۴). تمامی این مدل‌ها به سه دسته اصلی فیزیکی، تجربی و تحلیلی تقسیم می‌شوند. مدل‌های تجربی برای نشان دادن ارتباط بین تغییرات جوی و رواناب از توابع انتقالی ریاضی بهره می‌گیرند. مدل‌های تحلیلی بر اساس شکل ساده‌شده قوانین فیزیکی حاکم بر سیکل آب‌شناختی طراحی شده‌اند و با عامل‌هایی که بیانگر ویژگی‌های حوضه است نشان داده می‌شوند (Ibid).

از ویژگی‌های مهم شبکه‌های عصبی مصنوعی، توانایی آنها در برقراری ارتباط بین ورودی و خروجی فرایند، بدون در نظر گرفتن فیزیک آن مسئله است (رادمان، ۱۳۸۲). شبکه عصبی مصنوعی، مدلی ریاضی است که توانایی مدل‌سازی و ایجاد روابط غیرخطی برای درون‌یابی را دارد. این مدل با ساختار پرسپترون^۱ چندلایه، به‌طور کلی از سه لایه و هر لایه از تعدادی واحد پردازشگر بنام نرون^۲ (سلول، واحد و گره) تشکیل شده است (شکل ۱). اولین لایه هر شبکه را لایه ورودی گویند که در آن بردار داده‌های ورودی در نظر گرفته می‌شود و هیچ‌گونه پردازشی در آن انجام نخواهد شد. لایه آخر هر شبکه، لایه خروجی است که در آن بردارهای خروجی نگاشت استقرار می‌یابند. همچنین هر پرسپترون از تعدادی لایه میانی با نام لایه‌های پنهان تشکیل شده است. تعداد این لایه‌ها و تعداد نرون‌ها در هر لایه را طراح شبکه و طی فرایند آزمون و خطا به‌دست می‌آورد. به‌طور معمول، نرون‌های هر لایه

ضررهای حاصل از رواناب مازاد بر رودخانه (سیل) از لحاظ خسارت‌های احتمالی، شکست سدهای ذخیره‌ای، تخریب سازه‌های در مسیر رودخانه و سیلاب‌دشت، و ایجاد فرایندهای فرسایش و رسوب‌گذاری در مسیرهای تحت تأثیر سیل از جمله مباحث مطرح در پدیده وقوع سیل به‌شمار می‌آیند. مسئله تخمین و پیش‌بینی زمان و مقدار رواناب، پژوهشگران را بر آن داشته است که با کمک علوم مختلف درصدد رفع این نیاز برآیند.

فرایند بارش-رواناب بیشترین توجه مدل‌سازی مفهومی - از جمله شبکه عصبی- را به خود معطوف کرده است (Hall and Minns, 1998). خاصیت غیرخطی، عدم قطعیت ذاتی پدیده رواناب، و نیاز به اطلاعات تاریخی طولانی و پیچیده بودن مدل‌های فیزیکی از جمله دلایلی بوده که باعث شده است پژوهشگران به مدل‌های دیگری نظیر شبکه عصبی روی آورند، که انتخابی منطقی در این زمینه است (Ibid). دستاوردهای اخیر در کاربرد ابزار هوش مصنوعی و به‌خصوص شبکه‌های مصنوعی در زمینه‌های هواشناسی و هیدرولوژیکی، رویکردهای نو و متعددی را در مدل‌سازی گشوده است. شبکه‌های عصبی مصنوعی که از نوع مدل‌های مشتق‌شده از داده‌اند، به‌طور گسترده‌ای در حل مسائل مختلف از جمله در پیش‌بینی، مطالعه و به‌کار گرفته شده‌اند (صداقت‌کردار و فتاحی، ۱۳۸۷). یکی از خصوصیات این مدل‌ها که آنها را از سایر روش‌ها و الگوریتم‌ها ممتاز می‌سازد، حساسیت کمتر آنها به وجود خطا در ورودی‌هاست، که دلیل آن را می‌توان در پردازش توزیعی اطلاعات جست‌وجو کرد (Jeong and Young-oh, 2005). در این سیستم فعالیت‌های پیچیده با ساختاری موازی شبیه‌سازی می‌شوند و به‌جای آنکه تمام بار فعالیت بر دوش یک واحد محاسباتی سریع قرار گیرد، تعداد زیادی واحدهای محاسباتی ساده به‌صورت مشترک انجام آن را برعهده دارند (Ibid). پیامد مثبت دیگر تقسیم کار

1. Perceptron

2. Neuron


می‌سازد، تولید کند (Krose and Smagt, 1996). در آموزش شبکه مهم این است که شبکه بتواند به‌ازای هر بردار ورودی که با آن آموزش ندیده است، خروجی مرتبط با آن را ارائه کند. برای این منظور، الگوها پیش از آغاز کار با شبکه عصبی به دو دسته الگوی آموزشی^۱ و الگوی آزمونی^۲ تقسیم می‌شوند.

به‌طور کلی، آموزش شبکه‌های عصبی به دو طریق صورت می‌گیرد. در آموزش نظارت‌شده، خروجی معینی به هر ورودی نسبت داده می‌شود و آموزش نظارت‌نشده دارای خروجی از قبل مشخصی نیست (Lange, 1999). در این تحقیق به‌دلیل موجودبودن پارامتر خروجی از آموزش نظارت‌شده استفاده شد.

از مهم‌ترین تحقیقات صورت‌گرفته در زمینه شبکه عصبی و رواناب، مطالعه ایالت مریلند امریکا در حوضه آبخیز رودخانه پاتوننت^۳ است (Johnson and Tokar, 1999). در این تحقیق از داده‌های بارندگی روزانه، درجه حرارت و ذوب برف استفاده شد و نتایج پژوهش نشان دادند که مدل‌سازی بارش-رواناب انجام‌شده با استفاده از شبکه عصبی مصنوعی، نتایج مطلوب‌تری درمقایسه با مدل‌های معادله همبستگی دارد و مفهومی ساده‌تر را نیز ارائه می‌کند.

در سال ۲۰۰۶ با استفاده از شبکه‌های عصبی مصنوعی و الگوریتم پس‌انتشار، پیش‌بینی ضریب رواناب حوضه آبریزی نیمه‌خشک نوتواین تا سال ۲۰۲۰ در بوتسوانای شرقی در دستور کار قرار گرفت. برای این منظور ورودی شبکه را عوامل اقلیمی و کاربری اراضی-پوشش زمین و خروجی شبکه را ضریب رواناب حوضه مورد نظر تعیین کردند (Parida et al., 2006). پژوهشگران در این شبیه‌سازی به این نتیجه رسیدند که هر ساله حدود ۱ درصد ضریب رواناب افزایش می‌یابد، که البته احتمال روند کاهشی نیز وجود دارد. به‌منظور مدل‌سازی بارش-رواناب، از شبکه عصبی

به کلیه نرون‌های لایه مجاور از طریق رابطه‌ای جهت‌دار مرتبط است و اطلاعات بین نرون‌ها از طریق این اتصالات منتقل می‌شوند. هر یک از این اتصالات دارای مشخصه‌ای (وزن) است که در اطلاعات انتقال‌یافته از یک نرون به نرون دیگر ضرب می‌شود (منهاج، ۱۳۸۴).



شکل ۱. نمای کلی شبکه عصبی با ساختار پرسپترون چندلایه
منبع: منهاج، ۱۳۸۴

منظور از آموزش در شبکه‌های عصبی مصنوعی، محاسبه وزن اتصالات مختلف آن است. برای آموزش شبکه، از تعدادی الگوی آموزشی که هر الگو شامل یک بردار ورودی و یک بردار خروجی متناظر با آن است، استفاده می‌شود. تعداد گره‌های لایه‌های ورودی و نرون‌های لایه‌های خروجی به‌ترتیب برابر با تعداد بردارهای ورودی و خروجی است. از آنجاکه رابطه‌ای خاص برای محاسبه تعداد لایه‌های پنهان و نرون‌های مربوط به آنها وجود ندارد، چاره‌ای جز آزمون ساختارهای مختلف نیست. در آموزش شبکه، وزن‌های اتصالات شبکه به‌گونه‌ای محاسبه می‌شوند که با اعمال هر بردار ورودی از الگوی آموزشی، شبکه بتواند خروجی متناظر با آن را با میزان خطایی که طراح مشخص

1. Train
2. Test
3. Patuxent

حرارت و پنج ایستگاه باران‌سنجی به‌عنوان ورودی مدل پرسپترون چندلایه شبکه عصبی مصنوعی استفاده کردند. لایه خروجی جریان عبوری از ایستگاه هیدرومتری اسکندری است که کلیه جریان‌های بالادست از آن عبور می‌کنند. در این تحقیق مناسب‌ترین مدل، مدلی با ساختار ۶، ۴، ۱ نرون ورودی و ۴ نرون در لایه مخفی بود.

در سال ۱۳۸۶ با استفاده از روش‌های نوروفازی و مدل‌های سری زمانی از آمار ۴۲ سال ایستگاه گلینگ (سال ۱۳۳۷ تا سال ۱۳۸۰) در بالادست سد طالقان برای پیش‌بینی دبی ماهانه رودخانه طالقان رود استفاده شد. در این پژوهش برای مدل‌های مختلف، دو ورودی متفاوت شامل مقادیر داده‌های دبی بدون حذف روندهای فصلی، و مقادیر داده‌های دبی پس از حذف روندهای فصلی در نظر گرفته شد. در تحقیق مذکور، عملکرد مدل تلفیقی هوش مصنوعی و سری زمانی درمقایسه با هر کدام از مدل‌های هوش مصنوعی و سری زمانی برای پیش‌بینی دبی بهتر بود (فتح‌آبادی، ۱۳۸۴).

خسروی (۱۳۸۵) از شبکه عصبی مصنوعی پرسپترون برای پیش‌بینی دبی اوج حوضه‌های گنده و گلینگ واقع در حوضه آبخیز طالقان استفاده کرد. وی از ورودی‌های حداکثر دبی متوسط روزانه ماه قبل، بارش متناظر، بارندگی یک روز و پنج روز قبل، مجموع بارندگی پنج روز قبل و دمای میانگین هر ماه برای پیش‌بینی دبی اوج استفاده کرد. در ایستگاه گنده، شبکه‌ای با سه ورودی دبی حداکثر ماه قبل، بارندگی همان روز و پنج روز قبل، پنج نرون در لایه مخفی و تابع فعال‌سازی خطی با مقدار $RMSE^2$ برابر با ۰/۷۱ به‌عنوان بهترین مدل انتخاب شد. در ایستگاه گلینگ، شبکه با دو ورودی دبی حداکثر ماه قبل و بارندگی همان روز، شش نرون در لایه مخفی و تابع فعال‌سازی

مصنوعی در رودخانه مایی تون^۱ در تایلند استفاده شد. نتایج پژوهش نشان دادند که شبکه عصبی مصنوعی با ورودی‌های تصادفی، جواب مناسب‌تری درمقایسه با شبکه عصبی مصنوعی با ورودی‌های رتبه‌بندی شده می‌دهد (Junsawang et al., 2007).

جیان و کومار (۲۰۰۷) برای پیش‌بینی دبی ماهانه رودخانه کلرادو آمریکا از مدل‌های شبکه عصبی و سری‌های زمانی استفاده کردند. نتایج پژوهش آنها نشان دادند که با افزایش تعداد ورودی‌ها برای شبکه عصبی و افزایش مرتبه مدل در مدل‌های AR، کارایی مدل‌ها بهتر می‌شود. در آن پژوهش، کارایی شبکه عصبی بهتر از مدل‌های AR بود.

رهنما و موسوی (۱۳۸۲)، پیش‌بینی سیلاب حوضه آبریز قره‌آقاج را با استفاده از شبکه عصبی مصنوعی و به‌وسیله نرم‌افزار NETS بررسی کردند. معماری شبکه‌های عصبی با یک، دو و سه لایه پنهان با ترکیب‌های مختلف از نرون‌ها در هر لایه آزمون شده و بهترین ساختمان شبکه برای پیش‌بینی دبی با گام زمانی یک‌ساعته شامل یک گره در لایه ورودی، چهار نرون در لایه پنهان و یک نرون خروجی بوده است.

رادمان (۱۳۸۲)، از مدل‌های کلاسیک و شبکه عصبی با الگوریتم پس‌انتشار خطا برای پیش‌بینی جریان ماهانه رودخانه کرج استفاده کرد. وی از آمار جریان، بارش، آب معادل برف و دمای مربوط به ۳۱ سال آبی در محل سد کرج برای مدل‌سازی استفاده کرد. در این تحقیق، کارایی شبکه عصبی برای پیش‌بینی جریان رودخانه از مدل‌های کلاسیک بالاتر است.

حسامی و همکاران (۱۳۸۳)، دبی ماکزیمم سیلاب حوضه آبخیز کرخه را با فازی-عصبی تطبیقی و معادله همبستگی پیش‌بینی کردند. آنها نتیجه گرفتند که فازی-عصبی تطبیقی در مقایسه با معادله همبستگی کمترین خطای ممکن را تولید می‌کند.

یزدانی و چاوشی (۱۳۸۴) به‌منظور پیش‌بینی رفتار رودخانه پلاسجان، از یک ایستگاه اندازه‌گیری درجه

1. Mae Tun
2. Root-mean Squared Error

تخمین میزان رواناب حوضه کن با استفاده از شبکه عصبی مصنوعی

عرض جغرافیایی $35^{\circ}46'$ تا $35^{\circ}57'$ و طول جغرافیایی $51^{\circ}10'$ تا $51^{\circ}22'$ در البرز مرکزی واقع شده است (شکل ۱). این حوضه از شمال به حوضه شهرستانک، از جنوب به حوضه واریش و وردیج، از غرب به سیجان و واریش و وردیج، و از شرق به حصارک و فرحزاد منتهی است. تاکنون سیلاب‌های متعددی با شدت‌های مختلف در این حوضه رخ داده که دبی ماکزیمم برخی از بزرگ‌ترین آنها به این شرح است:

- سیلاب ۱۳۷۹/۹/۱۱ با دبی پیک ۷ مترمکعب/ثانیه؛
- سیلاب ۱۳۷۹/۹/۲۱ و ۱۳۷۹/۹/۲۲ با دبی پیک ۵/۵ مترمکعب/ثانیه؛ و
- سیلاب ۱۳۸۰/۸/۲۷ و ۱۳۸۰/۸/۲۸ با دبی پیک ۴/۵ مترمکعب/ثانیه (اوسطی، ۱۳۸۷).

خطی با مقدار RMSE معادل ۲۰/۴۶ بهترین مدل شناخته شد.

شبکه‌های عصبی از ابزارهای جدیدی هستند که در سیستم‌های غیرخطی و نامعین که روابط بین اجزا و پارامترهای سیستم به خوبی شناخته شده و توصیف‌پذیر نیستند، توان تحلیل و شبیه‌سازی را دارند. پدیده رواناب و پیش‌بینی آن از جمله این سیستم‌هاست.

با توجه به پیشینه مطالعات ذکر شده در اینجا، شبکه عصبی به عنوان روشی جدید در بیشتر موارد شبکه عصبی مصنوعی در مقایسه با روش‌های مرسوم گذشته کارایی بالاتری در تخمین رواناب دارد. چگونگی استفاده از این روش در حوضه کن هدف پژوهش حاضر است.

۲- مواد و روش‌ها

۲-۱- موقعیت حوضه مطالعه شده

حوضه کن با مساحت تقریبی ۲۰۰ کیلومترمربع در



شکل ۱. موقعیت حوضه کن و ایستگاه‌های محدوده مطالعه شده در ایران و تهران

جدول ۱. داده‌های استفاده‌شده در حوضه کن از سال ۱۳۷۵ تا سال ۱۳۸۵ (خروجی نرم‌افزار Arc GIS)

نام پارامتر در زیر حوضه	ایستگاه کشار	ایستگاه کیگا	ایستگاه رندان	واحد
میانگین دمای ماهانه	۱۴/۷	۱۲/۶	۱۲/۸	درجه سانتی‌گراد
میانگین بارش ماهانه	۶۴۰	۷۱۰	۶۲۰	میلی‌متر
میانگین دبی ماهانه	۰/۳۵	۰/۳۶	۰/۳۹	لیتر بر ثانیه
محیط	۳۳/۴	۲۴	۲۹/۷	کیلومتر
مساحت	۲۹	۱۹/۵	۳۰	کیلومتر مربع
طول زیر حوضه	۳۵۶۰	۴۲۲۰	۴۷۸۰	متر
ضریب شکل	۲/۳	۱/۱	۱/۳	-
ضریب فشردگی	۱/۸	۱/۵	۱/۵	متر
نسبت دایره	۰/۳۳	۰/۴۳	۰/۴۳	-
نسبت کشیدگی	۱/۷	۱/۲	۱/۳	-
ارتفاع متوسط	۲۴۴۰	۲۴۹۰	۲۰۴۰	متر
میانگین شیب	۳۹	۳۶	۳۱	درصد
طول شبکه آبراهه	۳۶	۲۰	۳۴	کیلومتر
زمان تمرکز	۱۲/۳	۱۴/۸	۱۸/۴	دقیقه

۲-۲- داده‌های استفاده‌شده

داده‌های استفاده‌شده در پژوهش حاضر شامل داده‌های باران، دما و دبی ایستگاه‌های باران‌سنجی، دماسنجی و هیدرومتری واقع در حوضه مطالعه‌شده (ایستگاه‌های کیگا، رندان و کشار از سال ۱۳۷۵ تا ۱۳۸۵) و نقشه توپوگرافی با مقیاس ۱/۲۵۰۰۰ به‌منظور تهیه نقشه DEM^۱ و خصوصیات فیزیوگرافی حوضه مورد مطالعه است. به‌منظور استخراج خصوصیات فیزیوگرافی حوضه کن، از اکستنشن Arc Hydro در محیط نرم‌افزار Arc GIS استفاده شد. داده‌های فیزیوگرافی استخراج‌شده در این نرم‌افزار در جدول ۱ آمده است.

رواناب تولیدشده از هر حوضه تابع مستقیم مساحت و بارش حوضه است. بارش در هر حوضه تابع ارتفاع متوسط آن است و هرچه ارتفاع حوضه بالاتر باشد بارش در آنجا - جز در موارد خاص - بالاتر است. بالطبع هرچه مساحت و بارش در حوضه بیشتر باشد، رواناب تشکیل‌شده بیشتر خواهد بود. در جدول ۱ مشاهده می‌شود که ارتفاع متوسط حوضه کیگا بالاتر از دو

حوضه دیگر و میانگین بارش ماهانه آن از دو ایستگاه دیگر بالاتر است. مساحت دو حوضه کشار و رندان از حوضه کیگا بیشتر است و به‌همین دلیل رواناب بیشتری تولید می‌کنند.

۳- روش تحقیق

شبکه عصبی استفاده‌شده در این پژوهش از نوع پس‌خور یا الگوریتم پس‌انتشار خطاست، که بیشترین کاربرد را در مسائل آب‌شناختی دارد (Jankowski, 2001). در پژوهش حاضر برای تخمین رواناب، از داده‌های هیدرومتری، هواشناسی و فیزیوگرافی در شبکه عصبی پرسپترون چندلایه و به‌منظور دستیابی به ساختار بهینه، از الگوریتم‌های مختلف شبکه عصبی پرسپترون استفاده شد.

نقطه ضعف شبکه‌های عصبی، نبود قانونی تأییدشده برای معماری شبکه آنهاست (رضایی و

1. Digital Elevation Model

شبکه را قادر می‌سازد تا علاوه بر تغییرات شیب به تغییرات سطح خطا نیز واکنش نشان دهد و باعث می‌شود خطاهای ناچیز نادیده گرفته شوند؛ الگوریتم کاهش شیب با سرعت آموزش متغیر^۵ (GDA) که در آن سرعت آموزش متغیر است و اندازه سرعت آموزش طوری تنظیم می‌شود که به سطح خطای محلی واکنش نشان دهد؛ الگوریتم کاهش شیب با مومنتوم با سرعت آموزش متغیر^۶ (GDX) که در آن در صورتی که خطای جدید در قیاس با خطای قدیمی از مقدار افزایش تعیین شده - که معمولاً ۱/۰۴ است- تجاوز کند، وزن و بایاس‌های جدید نادیده گرفته می‌شوند؛ الگوریتم پس‌انتشار ارتجاعی^۷ (RP) که هدف آن از بین بردن تأثیرات مضر روی اندازه مشتقات جزئی است (کیا، ۱۳۸۷). در تمامی الگوریتم‌های شیب توأم که شامل^۸ CGP،^۹ CGP،^{۱۰} CGB و^{۱۱} SCG است، اصلاح وزن‌ها توأم در چند جهت چک می‌شود. برخی از این توابع جست‌وجو برای تابع آموزش خاص مناسب‌ترند و کارایی‌شان بالاتر است. الگوریتم‌های شیب توأم بسیار سریع و برای شبکه‌هایی با تعداد وزن‌های زیاد و حجم بالا مناسب‌اند (همان). الگوریتم شبه‌نیوتن^{۱۲} BFGS در مقایسه با روش‌های شیب توأم به محاسبات و فضای بیشتری نیاز دارد، اما سریع‌تر و در تعداد تکرار کمتری همگرا می‌شود. کارایی این الگوریتم برای شبکه‌های کوچک بهتر از روش‌های دیگر است (همان). الگوریتم شبه‌نیوتن^{۱۳} OSS در مقایسه با BFGS به فضا و

همکاران، ۱۳۸۶)؛ به طوری که معیار مناسبی برای تعیین تعداد لایه و تعداد نرون در لایه پنهان، نوع تابع فعال‌سازی برای لایه پنهان و لایه خروجی وجود ندارد و تنها راه‌حل برای رفع این مشکل استفاده از روش آزمون و خطاست.

در شبکه‌های عصبی، توابع انتقال مختلف معرفی می‌شوند. توانایی محاسبه مشتقات تابع انتقالی در الگوی آموزشی پس‌انتشار خطا اهمیت دارد. توابع^۱ Logsig و^۲ Tansig معمول‌ترین توابع انتقالی در آموزش پس‌انتشار هستند که معمولاً در شبکه‌های چندلایه کاربرد دارند (کیا، ۱۳۸۷). تابع Logsig خروجی‌های بین ۰ و ۱ در محدوده مقادیر مثبت و منفی ایجاد می‌کند. در شرایطی که در داده‌های ورودی، مقدار صفر وجود داشته باشد به‌منظور بهبود کارایی می‌توان از تابع Tansig نیز استفاده کرد (همان). از آنجاکه دو تابع مذکور به‌دلیل پیوسته‌بودن و مشتق‌پذیر بودن بیشترین کاربرد را در الگوریتم پس‌انتشار خطا دارند (همان)، در پژوهش حاضر کلیه محاسبات یک‌بار با تابع Logsig و یک‌بار با تابع Tansig انجام شدند.

افزایش تعداد واحدها در لایه میانی همواره باعث کمتر شدن خطای آموزشی می‌شود ولی ممکن است خطای تست را بالا ببرد، که به آن تطبیق بیش از حد گفته می‌شود؛ بدین معنی که نمونه‌های آموزشی به‌خوبی آموزش دیده‌اند ولی شبکه تابع مورد نظر را به‌خوبی آموزش نداده است. این امر به‌ویژه زمانی که نویز در میان نمونه‌های آموزشی وجود داشته باشد بیشتر رخ می‌دهد (منهاج، ۱۳۸۴).

یکی از مراحل انجام محاسبه با استفاده از شبکه عصبی مصنوعی، انتخاب تابعی است که به‌منظور آموزش شبکه از آن استفاده می‌شود. این توابع عبارت‌اند از: الگوریتم کاهش شیب با سرعت آموزش ثابت^۳ (GD) که در آن وزن‌ها و بایاس‌ها در جهت عکس تابع کارایی به‌روز می‌شوند؛ و الگوریتم کاهش شیب با مومنتوم با سرعت ثابت^۴ (GDM) که مومنتوم

1. Log-Sigmoid
2. Tan-Sigmoid
3. Gradient Descent Backpropagation
4. Gradient Descent with Momentum Backpropagation
5. Gradient Descent with Adaptive Lr Backpropagation
6. Gradient Descent with Momentum & Adaptive Lr Backpropagation
7. Resilient Backpropagation (Rprop)
8. Fletcher-Powell Conjugate Gradient Backpropagation
9. Polak-Ribiere Conjugate Gradient Backpropagation
10. Powell-Beale Conjugate Gradient Backpropagation
11. Scaled Conjugate Gradient Backpropagation
12. BFGS Quasi-Newton Backpropagation
13. One Step Secant Backpropagation

شد و با محاسبه ضریب تعیین و میزان خطا، تأثیر هر کدام از این عوامل در میزان بهبود عملکرد شبکه سنجیده شد. به همین ترتیب، پارامترهای مربوط به فیزیوگرافی حوضه نیز به عنوان ورودی به شبکه عصبی تشکیل شده اضافه گردید و نتایج به دست آمده و میزان تأثیر هر کدام از پارامترها در محاسبه میزان رواناب بررسی شد. به صورت تصادفی از ۸۰ درصد داده‌ها برای آموزش شبکه عصبی و از ۲۰ درصد باقی مانده داده‌ها به عنوان داده‌های تست برای ارزیابی و اعتبارسنجی شبکه عصبی استفاده شد.

۴- نتایج

انتخاب معماری در شبکه‌های عصبی با روش سعی و خطا صورت می‌گیرد که طی آن با استفاده از ارقام مختلف لایه‌های پنهان و نرون‌های مربوط و همچنین افزایش ورودی‌ها به شبکه به صورت گام به گام، می‌توان شبکه‌ای بهینه را ایجاد کرد. هر چه تعداد لایه‌ها و نرون‌ها و ورودی‌ها بیشتر باشد، عملکرد شبکه برای آموزش بهبود می‌یابد.

از آنجاکه در تحقیق حاضر از ورودی‌های مختلفی استفاده شد و تعداد نرون‌های مخفی نیز مرتباً تغییر یافت تا ساختار بهینه حاصل شود، تعداد زیادی ساختار شبکه عصبی به دست آمد. با توجه به اینکه آوردن همه ساختارهای شبکه عصبی به دست آمده امکان پذیر نیست، بهترین نتایج از ساختارهای مختلف شبکه‌های عصبی ارائه می‌شود. نرون‌های مخفی و تعداد تکرارها برای توابع آموزشی مختلف با دو تابع انتقال Tansig و Logsig تا جایی افزایش می‌یابند که شیب مقدار خطا به حداقل برسد و ساختار بهینه به دست آید.

محاسبات کمتری در هر تکرار نیاز دارد، اما محاسبات مورد نیاز آن در هر تکرار اندکی بیش از الگوریتم‌های شبه نیوتن و شیب توأم است (همان). الگوریتم LM¹ سریع‌ترین روش پیاده‌سازی در MATLAB است و برای شبکه‌های متوسط (با چند صد پارامتر مؤثر) کارایی بسیار زیادی دارد (همان). تعیین اینکه کدام الگوریتم برای هر مسئله مشخص سریع‌تر عمل می‌کند بسیار دشوار است، زیرا به مؤلفه‌های زیادی از جمله پیچیدگی مسئله، تعداد داده‌های مجموعه آموزشی، تعداد وزن‌ها و بایاس‌ها بستگی دارد (همان).

در پژوهش حاضر از تمامی توابع آموزشی صرف‌نظر از معایب‌شان استفاده شد. در این تحقیق علاوه بر آمار هیدرومتری و هواشناسی، پارامترهای فیزیوگرافی حوضه نیز به عنوان ورودی شبکه عصبی به کار گرفته شدند. با توجه به اینکه آمار ایستگاه‌های کیگا، رندان و کشار از ایستگاه‌های دیگر بالاتر بود، پس از استخراج زیرحوضه‌های محدوده مطالعه شده از DEM منطقه، از آمار هواشناسی و هیدرومتری این ایستگاه‌ها به همراه پارامترهای فیزیوگرافی این سه زیرحوضه به عنوان داده‌های مؤثر در رواناب استفاده شد. داده‌های فیزیوگرافی استفاده شده در این تحقیق عبارت‌اند از: متوسط شیب، محیط زیرحوضه، مساحت زیرحوضه، طول زیرحوضه، ضریب شکل، ضریب فشردگی، نسبت دایره، نسبت کشیدگی، ارتفاع متوسط زیرحوضه‌ها، طول شبکه آبراهه‌ها و زمان تمرکز.

یکی از مهم‌ترین گام‌ها در پیشبرد رضایت‌بخش مدل پیش‌بینی شبکه عصبی، انتخاب ورودی مناسب است. برای این منظور به ارزیابی عملکرد شبکه‌های عصبی با ورودی‌های مختلف نیاز است و کوشش می‌شود که شبکه‌ای با کمترین خطا و بالاترین همبستگی معرفی شود (Aksoy and Dahamsheh, 2009).

در مدل شبکه عصبی مصنوعی تشکیل شده ابتدا فقط از داده‌های بارش ماه جاری برای آموزش و تست شبکه عصبی استفاده شد. در مراحل بعد، داده‌های دمای ماه جاری و دبی ماه گذشته نیز به شبکه اضافه

1. Levenberg-Marquardt Backpropagation

تخمین میزان رواناب حوضه کن با استفاده از شبکه عصبی مصنوعی

جدول ۲. بهترین نتایج شبکه عصبی با داده‌های تست بارش

تابع انتقال	ردیف	تکرار	تابع یادگیری	ساختار	R ²	RMSE	Mae
Tansig	۱	۵۰۰	CGB	۱-۶-۱	۰/۳۰	۰/۰۵۲	۰/۰۳۵
	۲	۵۰	RP	۱-۹-۱	۰/۳۵	۰/۰۵۱	۰/۰۳۴
	۳	۵۰	CGP	۱-۶-۱	۰/۳۰	۰/۰۵۲	۰/۰۳۴
	۴	۵۰	CGB	۱-۶-۱	۰/۳۰	۰/۰۵۲	۰/۰۳۴
	۵	۱۰۰	SCG	۱-۷-۱	۰/۳۱	۰/۰۵۲	۰/۰۳۴
	۶	۵۰	OSS	۱-۶-۱	۰/۳۰	۰/۰۵۲	۰/۰۳۴
	۷	۳۰۰	LM	۱-۸-۱	۰/۴۵	۰/۰۴۷	۰/۰۲۷
Logsig	۸	۳۰۰	LM	۱-۵-۱	۰/۴۹	۰/۰۴۸	۰/۰۲۷
	۹	۲۰۰	CGP	۱-۵-۱	۰/۳۸	۰/۰۵۲	۰/۰۳۴
	۱۰	۲۰۰	OSS	۱-۶-۱	۰/۳۹	۰/۰۵۲	۰/۰۳۴
	۱۱	۱۰۰	SCG	۱-۶-۱	۰/۳۹	۰/۰۵۲	۰/۰۳۴

جدول ۳. بهترین نتایج شبکه عصبی با داده‌های تست بارش و دما

تابع انتقال	ردیف	تکرار	تابع یادگیری	ساختار	R ²	RMSE	Mae
Tansig	۱	۲۰۰	RP	۲-۹-۱	۰/۷۰	۰/۰۳۸	۰/۰۲۱
	۲	۲۰۰	CGF	۲-۸-۱	۰/۶۹	۰/۰۳۸	۰/۰۱۸
	۳	۲۰۰	CGP	۲-۸-۱	۰/۷۰	۰/۰۳۷	۰/۰۱۷
	۴	۳۰۰	CGB	۲-۵-۱	۰/۶۸	۰/۰۳۹	۰/۰۱۹
	۵	۲۰۰	SCG	۲-۷-۱	۰/۶۶	۰/۰۳۹	۰/۰۲۱
	۶	۲۰۰	BFG	۲-۴-۱	۰/۶۹	۰/۰۳۸	۰/۰۱۹
	۷	۳۰۰	OSS	۲-۸-۱	۰/۶۸	۰/۰۳۸	۰/۰۱۸
	۸	۲۰۰	LM	۲-۳-۱	۰/۶۸	۰/۰۳۸	۰/۰۱۸
Logsig	۹	۲۰۰	CGP	۲-۸-۱	۰/۷۴	۰/۰۳۵	۰/۰۱۹
	۱۰	۲۰۰	CGB	۲-۸-۱	۰/۶۹	۰/۰۳۷	۰/۰۱۹
	۱۱	۳۰۰	SCG	۲-۹-۱	۰/۷۰	۰/۰۳۷	۰/۰۱۹
	۱۲	۳۰۰	RP	۲-۳-۱	۰/۷۴	۰/۰۳۶	۰/۰۱۹
	۱۳	۵۰۰	BFG	۲-۲-۱	۰/۷۲	۰/۰۳۶	۰/۰۱۸
	۱۴	۱۰۰	LM	۲-۳-۱	۰/۷۲	۰/۰۳۷	۰/۰۱۸

نتایج جدول ۳ نشان می‌دهند که با ورودی‌های بارش و دما، بهترین نتیجه با استفاده از تابع آموزشی RP و ۳ نرون مخفی به دست می‌آید (ردیف ۱۲). در این حالت برای داده‌های تست، ضریب تعیین ۰/۷۴، میانگین مربعات خطا ۰/۰۳۶، و میانگین خطای مطلق ۰/۰۱۹ است. با استفاده از تابع آموزشی CGP نیز نتیجه مشابهی حاصل می‌شود ولی با توجه به اینکه

همان‌طور که نتایج جدول ۲ نشان می‌دهند، در صورتی که فقط از ورودی بارش برای مدل‌سازی شبکه عصبی استفاده شود، بهترین نتیجه وقتی حاصل می‌گردد که شبکه با استفاده از تابع یادگیری LM و ۵ نرون مخفی آموزش داده شود (ردیف ۸). در این حالت ضریب تعیین برای داده‌های تست ۰/۴۹ و میانگین مربعات خطا ۰/۰۴۸ و میانگین خطای مطلق ۰/۰۲۷ است.

داده‌های تست، به ضریب تعیین ۰/۵۴ و میانگین مربعات خطای ۰/۰۴۴ و میانگین خطای مطلق ۰/۰۲۶ می‌رسد. با افزایش بیشتر نرون‌های میانی و تعداد تکرار برای آموزش شبکه عصبی، آموزش مدل شبکه عصبی متوقف می‌شود و این افزایش فقط باعث پیچیدگی مدل و افزایش محاسبات برای رسیدن به پاسخ بهینه می‌گردد.

تعداد نرون مخفی به کاررفته برای مدل‌سازی ۸ عدد است، مدل شبکه عصبی پیچیده‌تر می‌شود و بهتر است از مدلی استفاده شود که با پیچیدگی کمتر به پاسخ بهینه برسد.

طبق نتایج جدول ۴ با استفاده از ورودی‌های بارش و دبی، شبکه عصبی زمانی به حالت بهینه می‌رسد که از تابع آموزشی SCG و ۷ نرون مخفی استفاده کند (ردیف ۴). با استفاده از این ساختار، شبکه عصبی برای

جدول ۴. بهترین نتایج شبکه عصبی با داده‌های تست بارش و دبی

تابع انتقال	ردیف	تکرار	تابع یادگیری	ساختار	R ²	RMSE	Mae
Tansig	۱	۵۰۰	GDX	۲-۹-۱	۰/۴۱	۰/۰۵۲	۰/۰۳۴
	۲	۳۰۰	CGF	۲-۸-۱	۰/۴۵	۰/۰۵۲	۰/۰۳۲
	۳	۳۰۰	CGB	۲-۵-۱	۰/۴۳	۰/۰۵۲	۰/۰۳۳
	۴	۵۰۰	SCG	۲-۷-۱	۰/۵۴	۰/۰۴۴	۰/۰۲۶
	۵	۳۰۰	BFG	۲-۴-۱	۰/۵۱	۰/۰۴۵	۰/۰۲۸
	۶	۳۰۰	OSS	۲-۸-۱	۰/۵۱	۰/۰۴۵	۰/۰۲۷
Logsig	۷	۵۰	CGF	۲-۷-۱	۰/۴۲	۰/۰۵۱	۰/۰۳۴
	۸	۵۰	CGB	۲-۹-۱	۰/۴۴	۰/۰۵۱	۰/۰۴۴
	۹	۳۰۰	SCG	۲-۹-۱	۰/۵۱	۰/۰۵۰	۰/۰۳۲
	۱۰	۲۰۰	OSS	۲-۶-۱	۰/۴۸	۰/۰۵۰	۰/۰۳۲
	۱۱	۵۰	LM	۲-۴-۱	۰/۴۳	۰/۰۵۲	۰/۰۳۳

جدول ۵. بهترین نتایج شبکه عصبی با داده‌های تست بارش، دما و دبی

تابع انتقال	ردیف	تکرار	تابع یادگیری	ساختار	R ²	RMSE	Mae
Tansig	۱	۳۰۰	GDX	۳-۵-۱	۰/۶۸	۰/۰۳۱	۰/۰۲۱
	۲	۳۰۰	RP	۳-۲-۱	۰/۷۶	۰/۰۳۹	۰/۰۷۴
	۳	۳۰۰	CGF	۳-۸-۱	۰/۷۳	۰/۰۳۸	۰/۰۱۹
	۴	۳۰۰	CGP	۳-۸-۱	۰/۷۲	۰/۰۳۹	۰/۰۲۱
	۵	۳۰۰	CGB	۳-۸-۱	۰/۷۲	۰/۰۴۰	۰/۰۲۱
	۶	۲۰۰	SCG	۳-۲-۱	۰/۷۲	۰/۰۴۱	۰/۰۲۰
	۷	۵۰۰	BFG	۳-۷-۱	۰/۷۵	۰/۰۳۷	۰/۰۱۷
	۸	۲۰۰	OSS	۳-۸-۱	۰/۷۰	۰/۰۴۰	۰/۰۱۹
	۹	۲۰۰	LM	۳-۴-۱	۰/۷۸	۰/۰۳۰	۰/۰۱۷
Logsig	۱۰	۲۰۰	CGB	۳-۵-۱	۰/۷۶	۰/۰۳۰	۰/۰۲۰
	۱۱	۳۰۰	RP	۳-۴-۱	۰/۷۳	۰/۰۴۳	۰/۰۶۴
	۱۲	۱۰۰	SCG	۳-۳-۱	۰/۶۹	۰/۰۵۳	۰/۰۲۵
	۱۳	۲۰۰	OSS	۳-۵-۱	۰/۶۷	۰/۰۴۲	۰/۰۲۶
	۱۴	۳۰۰	CGP	۳-۴-۱	۰/۷۰	۰/۰۴۳	۰/۰۲۰
	۱۵	۱۰۰	CGF	۳-۹-۱	۰/۷۵	۰/۰۴۳	۰/۰۱۳

تخمین میزان رواناب حوضه کن با استفاده از شبکه عصبی مصنوعی

به دست آمده نشان از تأثیر زیاد این پارامترها در برآورد رواناب دارد. با آزمون t مشاهده شد که بین مقادیر پیش‌بینی شده در این مدل و مقدار واقعی رواناب اختلاف معناداری وجود ندارد ($P.Value > 0.05$).

با مشاهده جدول‌های ۴، ۵، ۶ و ۷ می‌توان دریافت که الگوریتم‌های شبکه‌های عصبی غالباً به تغییر تعداد ورودی‌ها واکنش نشان می‌دهند و ضریب R^2 تغییر می‌کند. دلیل واکنش مذکور این است که با افزایش تعداد داده‌های آموزشی، شبکه عصبی با داده بیشتری در مقایسه با حالت اول آموزش می‌بیند و این امر باعث افزایش ضریب R^2 در داده‌های آموزشی می‌شود. از طرفی با هر بار اجرای یک شبکه، نتایج به دست آمده به دلیل اختصاص دادن وزن‌های تصادفی در شبکه به ورودی‌ها تغییر می‌کند و این تغییر می‌تواند عاملی برای تغییر ضرایب R^2 و RMSE در حالت دوم باشد. نتایج این مرحله نیز بالا رفتن دقت را با افزایش تعداد ورودی‌ها نشان می‌دهد.

طبق جدول ۵، مدل‌سازی شبکه عصبی با داده‌های ورودی بارش، دما و دبی زمانی بهینه می‌شود که از ۴ نرون مخفی و تابع یادگیری LM استفاده شود (ردیف ۹). شبکه عصبی پس از ۲۰۰ بار آموزش برای داده‌های تست، به ضریب تعیین 0.78 و میانگین مربعات خطای 0.03 و میانگین خطای مطلق 0.017 خواهد رسید. برای تعداد نرون مخفی بیشتر و تعداد تکرار بیشتر، افزایش ضریب تعیین و کاهش خطا متوقف شده است. با توجه به جدول ۶، افزایش پارامترهای فیزیوگرافی به داده‌های ورودی قبلی بهبود چندانی در نتایج ضریب تعیین و میانگین مربعات خطا و میانگین خطای مطلق حاصل از نتایج قبلی ایجاد نکرد.

همان‌طور که در جدول ۵ مشاهده می‌شود، شبکه عصبی بهترین مدل را بین داده‌های بارش و دمای ماه جاری و دبی ماه گذشته برازش داده است. با استفاده از این ورودی‌ها، خروجی شبکه عصبی دارای بالاترین میزان R^2 و کمترین میزان RMSE است. نتایج

جدول ۶. بهترین نتایج شبکه عصبی با داده‌های تست بارش، دما، دبی و داده‌های فیزیوگرافی

تابع انتقال	ردیف	تکرار	تابع یادگیری	ساختار	R^2	RMSE	Mae
Tansig	۱	۳۰۰	RP	۱۴-۳-۱	۰/۷۱	۰/۰۴۰	۰/۰۲۰
	۲	۵۰۰	CGF	۱۴-۶-۱	۰/۶۸	۰/۰۳۹	۰/۰۲۱
	۳	۳۰۰	CGP	۱۴-۶-۱	۰/۶۷	۰/۰۴۰	۰/۰۲۴
	۴	۳۰۰	CGP	۱۴-۶-۱	۰/۷۳	۰/۰۴۶	۰/۰۲۷
	۵	۳۰۰	CGF	۱۴-۷-۱	۰/۷۴	۰/۰۳۷	۰/۰۱۸
	۶	۳۰۰	CGF	۱۴-۴-۱	۰/۷۳	۰/۰۳۸	۰/۰۱۹
	۷	۲۰۰	CGF	۱۴-۳-۱	۰/۷۱	۰/۰۳۷	۰/۰۱۹
Logsig	۸	۱۰۰	RP	۳-۷-۱	۰/۷۱	۰/۰۳۹	۰/۰۲۰
	۹	۲۰۰	BFG	۳-۵-۱	۰/۷۲	۰/۰۳۷	۰/۰۲۰
	۱۰	۱۰۰	LM	۳-۲-۱	۰/۷۲	۰/۰۳۷	۰/۰۱۸
	۱۱	۵۰۰	SCG	۳-۷-۱	۰/۶۸	۰/۰۳۸	۰/۰۲۱

۵- بحث و نتیجه گیری

در وقوع پدیده رواناب عوامل بسیار زیادی اثرگذارند، به طوری که تشخیص دادن و وارد کردن همه آنها در محاسبه‌ها و مدل سازی امکان پذیر نیست. وارد کردن عامل‌های بیشتر نیز ممکن است باعث افزایش پیچیدگی مدل و به احتمال زیاد مانع رسیدن به هدف نهایی شود. نکته مهم این است که با انتخاب ورودی‌های در دسترس و با اثرگذاری زیاد بتوان به پیش بینی نسبتاً دقیقی از بزرگی پدیده مورد نظر دست یافت. از این رو انتخاب ورودی‌های مناسب در ساخت مدل‌های پیش بینی بسیار مهم است (Faraway and Kaastra and Body, 1995 ; Chatfield, 1998).

در حالت کلی براساس اصول هیدرولوژیکی، یکی از پارامترهایی که ارتباط تنگاتنگی با رواناب حاصل دارد و معمولاً بیشترین همبستگی را نشان می‌دهد، میزان بارندگی تولیدکننده آن رواناب است؛ چراکه بارش پس از تلفات مختلف (نفوذ، تبخیر، تعرق، برگاب و مانند اینها) به رواناب تبدیل می‌شود. بنابراین، بارندگی مهم‌ترین ورودی چرخه هیدرولوژیکی است.

نتایج جدول ۲ نشان می‌دهند که صرفاً با استفاده از ورودی بارش می‌توان به ضریب رگرسیون ۰/۴۹ رسید، که نشان از اهمیت زیاد این عامل در تخمین رواناب دارد. نتایج پژوهش حاضر نشان می‌دهند که با افزایش داده‌های دما به داده‌های بارش به عنوان ورودی شبکه عصبی، ضریب تعیین افزایش می‌یابد. با ورود نرون دمایی یک معیار تفکیک بین داده‌های برف و بارش به شبکه القا می‌شود و کارایی شبکه در مقایسه با حالت قبلی افزایش می‌یابد، درحالی که به دلیل تفکیک نشدن برف و بارش در اطلاعات بارندگی، خطایی در داده‌های ورودی وجود دارد. باید توجه کرد که بارندگی حاصل مجموع باران و برف است و واژه باران، بارش برف را در برنمی‌گیرد.

به طور کلی دما سه نقش اساسی در تولید رواناب دارد: ذوب برف، اثر بر یخبندان و نفوذپذیری خاک، و اثر بر تراکم ابرها و ایجاد بارش (علیزاده، ۱۳۸۴). با

توجه به اینکه نتایج به دست آمده ارتباط زیاد پارامترهای دما و رواناب را نشان می‌دهند، بسیار مهم است که تأثیر برف در میزان تولید رواناب سنجیده شود. در صورتی که میزان برف اثر زیادی در تولید رواناب داشته باشد، می‌توان به همبستگی زیاد داده‌های برف و دما در تولید رواناب اشاره کرد که در صورت بالارفتن دما، ذوب برف افزایش می‌یابد. در صورتی که باران در تولید رواناب اثر بیشتری داشته باشد می‌توان اثر دما در تولید رواناب را چنین بیان کرد که به دلیل کوهستانی بودن حوضه و اختلاف ارتفاعی که در محدوده مورد نظر وجود دارد، دما می‌تواند نقش مؤثری در پدیده یخبندان داشته باشد. این امر نفوذپذیری خاک را کم می‌کند و به تبع آن میزان رواناب افزایش می‌یابد. کوهستانی بودن حوضه می‌تواند منجر به تشکیل ابرهای باران‌زا شود و میزان بارندگی را در منطقه مورد مطالعه افزایش دهد.

رادمان (۱۳۸۲) از مدل‌های کلاسیک و شبکه عصبی با الگوریتم پس انتشار خطا برای پیش بینی جریان ماهانه رودخانه کرج استفاده کرد و دما را به عنوان پارامتری مؤثری برای پیش بینی جریان در نظر گرفت.

یزدانی و چاوشی (۱۳۸۴) از مدل پرسپترون چندلایه شبکه عصبی مصنوعی برای پیش بینی رفتار رودخانه پلاسجان استفاده کردند و پارامتر دما را به عنوان متغیری ثابت در تمامی ساختارهای شبکه عصبی در نظر گرفتند. نتایج پژوهش ایشان نشان داد که بهترین ساختار شبکه عصبی دارای پارامتر دما بود.

فتح‌آبادی (۱۳۸۴) از روش‌های نوروفازی و مدل‌های سری زمانی برای پیش بینی دبی ماهانه رودخانه طالقان رود استفاده کرد و به این نتیجه رسید که با اضافه کردن پارامتر دما به ورودی شبکه عصبی، عملکرد شبکه عصبی بهتر می‌شود.

خسروی (۱۳۸۵) از شبکه عصبی مصنوعی پرسپترون برای پیش بینی دبی اوج حوضه‌های گنده و گلینک واقع در حوضه آبخیز طالقان استفاده کرد و

دست یافت (جدول ۵) و افزایش پارامترهای فیزیوگرافی تأثیر چندانی در بهبود عملکرد مدل شبکه عصبی ندارد (جدول ۶).

مقایسه نتایج پژوهش حاضر و تحقیقاتی که از شبکه عصبی مصنوعی استفاده کرده‌اند نشان می‌دهد که شبکه عصبی مصنوعی قابلیت بالایی در تخمین رواناب دارد. شبکه عصبی پرسپترون مقادیر محاسبه‌شده را با مقادیر واقعی مقایسه می‌کند و با تغییر وزن‌های اختصاص یافته به هر ورودی، سعی در کاهش خطا و افزایش دقت می‌کند و تا زمانی که به حداقل خطای ممکن نرسد آموزش شبکه ادامه می‌یابد و در نهایت دقت کافی به دست می‌آید. از طرفی، در شبکه‌های عصبی می‌توان با وارد کردن ورودی‌های تأثیرگذار، از میزان خطای نهایی تخمین رواناب کاست. با توجه به جداول نتایج تحقیق، با تغییر پارامترهای مربوط به هر شبکه می‌توان با استفاده از تمامی توابع آموزشی به نتایج مناسبی دست یافت زیرا طراحی این توابع به گونه‌ای است که با معرفی دقت مدنظر به شبکه، به سمت کاهش خطا پیش می‌روند. ممکن است برخی از این توابع در تکرارهای پایین و برخی در تعداد تکرارهای بالا به آن دقت برسند.

نتایج مقایسه میزان خطا در روش‌های شبکه عصبی با روش رگرسیونی نشان می‌دهند که شبکه‌های عصبی مصنوعی به دلیل قدرت مدل‌سازی روابط غیرخطی پیچیده و نیازنداشتن به پارامترهای زیاد، کاربرد فراوانی در تخمین میزان رواناب دارند. شبکه عصبی مصنوعی مدل‌شده در تحقیق نشان داد که با استفاده از پارامترهای دما، بارش و دبی می‌توان به دقت بالایی در تخمین میزان رواناب دست یافت.

۶- منابع

اوسطی خ، ۱۳۸۷، استخراج هیدروگراف واحد از رگبارهای مرکب (مطالعه موردی: البرز مرکزی)، پایان‌نامه کارشناسی ارشد، دانشکده منابع طبیعی، دانشگاه تهران.

نتایج نشان دادند که در ایستگاه‌های مهران، علیزان و جویستان با افزودن پارامتر دما به ورودی مدل نتیجه بهتری به دست می‌آید.

نتایج حاصل از مدل‌سازی در پژوهش حاضر نشان می‌دهند که اضافه کردن عامل دما به ساختار شبکه عصبی افزایش جدی در ضریب رگرسیون و کاهش خطا ایجاد می‌کند (جدول ۳). با مقایسه نتایج به دست آمده در این تحقیق و نتایج مطالعات قبلی می‌توان گفت که دما نقش اساسی در پیش‌بینی رواناب دارد. نتایج نشان دادند که دبی ماه قبل بر جریان پایه ماه‌های بعد مؤثر است. رواناب شامل دو بخش است: یک بخش دبی پایه رودخانه و بخش دیگر حاصل جریان‌های سطحی ناشی از بارندگی. در بررسی هیدروگراف‌های ماهانه، دبی پایه بخشی مهمی از رواناب را تشکیل می‌دهد. نتایج جدول ۵ نشان از بهبود عملکرد مدل شبکه عصبی با افزایش دبی ماه قبل به ساختار شبکه عصبی دارند.

طبق نتایج جدول ۸، افزایش پارامترهای فیزیوگرافی تأثیری در بهبود عملکرد شبکه عصبی نداشت. علت این امر را می‌توان در وابستگی میزان خطا در طول آموزش شبکه به تعداد مثال‌های به کاررفته برای آموزش شبکه برشمرد. اگر تعداد الگوها کم باشد، شبکه نمی‌تواند ارتباط بین ورودی‌ها و خروجی‌ها را به درستی فراگیرد (دزفولیان و اکبرپور شیرازی، ۱۳۹۰). با توجه به تعداد اندک زیرحوضه‌ها به عنوان ورودی و دسترسی نداشتن به داده‌های مختلف فیزیوگرافی، شبکه عصبی نمی‌تواند از این داده‌ها برای آموزش شبکه استفاده کند و به ساختار بهینه دست یابد.

با توجه به اینکه داده‌های فیزیوگرافی می‌توانند در تولید رواناب مؤثر باشند، در صورتی که حوضه مورد مطالعه بزرگ باشد و داده‌های فیزیوگرافی تنوع بیشتری داشته باشند، بهتر است این پارامترها نیز اعمال شوند تا مدل بهینه‌تری به دست آید. به طور کلی نتایج پژوهش حاضر نشان دادند که با استفاده از داده‌های بارش، دما و دبی به عنوان ورودی مدل شبکه عصبی و ۴ نرون مخفی می‌توان به بالاترین دقت ممکن

- حسامی ر، ع. افشار، س.ج. موسوی، ۱۳۸۳، مدل پیش‌بینی سیلاب با استفاده از سیستم استنباط فازی عصبی تطبیقی و مقایسه آن با روش رگرسیون (مطالعه موردی: حوضه کرخه)، اولین کنفرانس مدیریت منابع آب، صص. ۱۲-۱.
- خسروی م، ۱۳۸۵، پیش‌بینی سیل با استفاده از روش شبکه عصبی مصنوعی و روش‌های تجربی (مطالعه موردی: حوضه آبخیز طالقان)، پایان‌نامه کارشناسی ارشد، دانشکده منابع طبیعی، دانشگاه تهران.
- دزفولیان م.ا، م. اکبریور شیرازی، ۱۳۹۰، مدل‌سازی سنگ‌شناسی در میدان گازی پارس جنوبی با استفاده از شبکه عصبی مصنوعی، پژوهش نفت، دوره ۲۱، شماره ۶۶، صص. ۲۲-۱۲.
- رادمان ر، ۱۳۸۲، پیش‌بینی جریان رودخانه به کمک مدل شبکه عصبی، پایان‌نامه کارشناسی ارشد، دانشکده فنی و مهندسی، دانشگاه علم و صنعت.
- رضایی ع، م. مهدوی، ک. لوکس، س. فیض‌نیا، م.ج. مهدیان، ۱۳۸۶، مدل‌سازی منطقه‌ای دبی‌های اوج در زیرحوضه‌های آبخیز سد سفیدرود با استفاده از شبکه عصبی مصنوعی، علوم آب و خاک (علوم و فنون کشاورزی و منابع طبیعی، دوره ۱۱، شماره ۱(الف)، صص. ۳۹-۲۵.
- رهنما م.ب، ج. موسوی، ۱۳۸۲، پیش‌بینی سیلاب حوضه آبریز قره‌آقاج با استفاده از شبکه عصبی مصنوعی، سمینار سراسری آبیاری و کاهش تبخیر، شماره ۸.
- صداقت کردار ع، ا. فتاحی، ۱۳۸۷، شاخص‌های پیش‌آگاهی خشکسالی در ایران، فصلنامه جغرافیا و توسعه، دوره ۶، شماره ۱۱، صص. ۷۶-۵۹.
- علیزاده ا، ۱۳۸۴، اصول هیدرولوژی کاربردی، انتشارات قدس رضوی، مشهد.
- فتح‌آبادی ا، ۱۳۸۴، پیش‌بینی سیل با استفاده از روش نوروفازی و تحلیل سری‌های زمانی، پایان‌نامه کارشناسی ارشد، دانشکده منابع طبیعی، دانشگاه تهران.
- کیا س.م، ۱۳۸۷، شبکه عصبی در Matlab، انتشارات رایان سبز کیان.
- منه‌اج م.ب، ۱۳۸۴، اصول شبکه عصبی مصنوعی، انتشارات دانشگاه امیرکبیر، تهران.
- نوری م، م.ب. رهنما، ع. پیره، ۱۳۸۴، مقایسه مدل جدید N.W.N و مدل A.N.N در فرایند شبیه‌سازی جریان رودخانه‌های غازان‌چای، پنجمین کنفرانس هیدرولیک ایرانیان، دانشگاه شهید باهنر، کرمان.
- یزدانی م.ر، س. چاوشی، ۱۳۸۴، پیش‌بینی جریان رودخانه با استفاده از مدل شبکه عصبی مصنوعی، پنجمین کنفرانس هیدرولیک ایران، صص. ۸-۱.
- Aksoy, H. and Dahamsheh, A., 2009, **Artificial Neural Network Models for Forecasting Monthly Precipitation in Jordan**, Stochastic Environmental Research and Risk Assessment, 23, PP. 917-931.
- Faraway, J. and Chatfield, C., 1998, **Time Series Forecasting with Neural Networks: A Comparative Study Using the Airline Data**, Applied Statistics, 47(2), PP. 231-250.
- Hall, M.J. and Minns, A.W., 1998, **Regional Flood Frequency Analysis Using Artificial Neural Networks**, The 3rd International Conference on Hydroinformatics, 98(2), PP. 759-763.
- Jain, A. and Kumar, A.M., 2007, **Hybrid Neural Network Models for Hydrologic Time Series**, Applied Soft Computing, 7(2), PP. 585-592.

- Jankowski, N. and Duch. W., 2001, **Optimal Transfer Function Neural Networks**, European Symposium on Artificial Neural Networks Proceedings, Bruges (Belgium), ISBN 2-930307-01-3, PP. 101-106.
- Jeong, D. and Young-oh K., 2005, **Rainfall-Runoff Models Using Artificial Neural Networks for Ensemble Stream Flow Prediction**, Hydrological Process, 19, PP. 3819-3835.
- Junsawang, P., Asavanant, J. and Lursinsap, C., 2007, **Artificial Neural Network Model for Rainfall-Runoff Relationship**, Proceeding of the 2nd Asian Simulation and Modeling (ASSIMOD2007), Chaing Mai, Thailand, PP. 267-274.
- Kaastra, I. and Boyd, M.S., 1995, **Forecasting Futures Trading Volume Using Neural Networks**, The Journal of Futures Markets, 15(8), PP. 935-970.
- Krose, B. and Smagt, P., 1996, **An Introduction to Neural Networks**, The University of Amsterdam, Netherland.
- Lange, N.T., 1999, **New Mathematical Approaches in Hydrological Modeling: An Application of Artificial Neural Networks**, Physics and Chemistry of the Earth, 24(1-2), PP. 31-35.
- Parida, B.P., Moalafhi, D.B. and Kenabatho, P.K., 2006, **Forecasting Runoff Coefficients Using ANN for Water Resources Management: The Case of Notwane Catchment in Eastern Botswana**, Physics and Chemistry of the Earth, 31, PP. 928-934.
- Tokar, A.S. and Johnson, P.A., 1999, **Rainfall-Runoff Modeling Using Artificial Neural Networks**, Journal of Hydrologic Engineering, 4(3), PP. 232-239.
- Yazdani, M. and Chavoshi, S., 2005, **Prediction of Flood Using Neural Networks**, The 5th Conference of Iran's Hydraulic, Faculty of Engineering, Shahid Bahonar University, 2, PP. 911-918.

