



## مقایسه عملکرد دو تابع سیگموئید و تانژانت هیپربولیک شبکه عصبی مصنوعی در پیش‌بینی ضریب روان‌آب رگبار (مطالعه موردی: حوزه آبخیز بار اریه نیشابور)

مینا جعفری<sup>۱</sup>، مهدی وفاخواه<sup>۲</sup> و هیراد عبقری<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد گروه مهندسی آبخیزداری، دانشگاه تربیت مدرس، آستادیار گروه مهندسی آبخیزداری،

دانشگاه تربیت مدرس، آستادیار گروه مهندسی آبخیزداری، دانشگاه ارومیه

تاریخ دریافت: ۹۰/۱۰/۱۴؛ تاریخ پذیرش: ۹۱/۵/۲

### چکیده

فرآیند بارش- روان‌آب و ایجاد سیلاب از پدیده‌های هیدرولوژیکی هستند که بررسی آن‌ها به سبب تأثیرپذیری از پارامترهای مختلف، دشوار می‌باشد. تاکنون روش‌ها و الگوهای مختلفی برای تحلیل این پدیده‌ها ارائه شده است. از این‌رو هدف این پژوهش ارزیابی شبکه‌های عصبی مصنوعی در پیش‌بینی ضریب روان‌آب رگبار با استفاده از دو تابع انتقال سیگموئید و تانژانت هیپربولیک در لایه مخفی و تابع انتقال خطی در لایه خروجی است. به این منظور حوزه آبخیز بار اریه نیشابور انتخاب داده‌های مربوط به ۳۳ واقعه در بین سال‌های آماری ۱۳۳۱ تا ۱۳۸۵ جمع‌آوری گردید. به‌منظور انتخاب متغیرهای مستقل در برآورد ضریب روان‌آب از تجزیه و تحلیل عاملی استفاده شد، که براساس آن ۴ متغیر مقدار متوسط بارندگی، چارک سوم، اول و چهارم شدت بارندگی و همچنین ۵ متغیر شاخص ( $\phi$ ) و چارک‌های اول تا چهارم شدت بارش به‌عنوان عوامل اصلی برگزیده شدند. شبکه عصبی مصنوعی ابتدا با تابع سیگموئید و سپس با تابع تانژانت هیپربولیک اجرا شد. متغیرهای به‌دست آمده از تجزیه و تحلیل عاملی برای شبکه با تابع انتقال سیگموئید به‌خوبی پاسخ داد ولی این متغیرها برای شبکه با تابع انتقال تانژانت هیپربولیک به‌دلیل عملکرد متفاوت این تابع به پاسخ مناسبی منجر نشد، بنابراین ترکیب سایر متغیرها براساس نقش هیدرولوژیکی آن‌ها، به‌عنوان ورودی شبکه مدنظر قرار گرفت. نتایج نشان داد که شبکه با ورودی چارک‌های اول تا چهارم شدت بارندگی، مدت بارش،

\* مسئول مکاتبات: [vafakhah@modares.ac.ir](mailto:vafakhah@modares.ac.ir)

مقدار کل بارش و شاخص ( $\varphi$ ) و بارش ۵ روز قبل و تابع انتقال تانژانت هیپربولیک می‌تواند ضریب روان‌آب رگبار را با ضریب تبیین آزمایش ۰/۹۸ و ریشه میانگین مربعات خطا ۰/۰۳۳۷ و متوسط قدرمطلق خطا ۰/۰۲۷۵ پیش‌بینی کند.

**واژه‌های کلیدی:** شبکه عصبی مصنوعی، تابع سیگموئید، تابع تانژانت هیپربولیک، ضریب روان‌آب، حوزه آب‌خیز بار اریه نیشابور

### مقدمه

با توجه به بروز سیلاب‌های گوناگون و خطرهایی که از این راه جامعه‌های انسانی و سازه‌های سر راه آن‌ها مورد تهدید قرار می‌گیرند، بررسی فرآیند بارش - روان‌آب و اندازه‌گیری میزان روان‌آب از اهمیت ویژه‌ای برخوردار است. یکی از پارامترهای اساسی در برآورد روان‌آب ضریب روان‌آب است. به سبب دشواری و پیچیدگی مسایل مربوط به این پدیده، از سوی متخصصان روش‌ها و الگوهای مختلفی ارایه شده است. شبکه‌های عصبی مصنوعی (ANN) یکی از دستاوردهایی هستند که با الگوبرداری از شبکه عصبی مغز انسان، قادرند پدیده‌های پیچیده و ناشناخته را به‌خوبی بررسی نمایند (منهاج، ۲۰۰۲؛ میثاقی، ۲۰۰۲). دیدگاه جدید شبکه عصبی با اضافه شدن عمل شرط‌گذاری به‌عنوان قانون آموزش مطرح شد که با پیدایش شبکه پرسپترون تک‌لایه و قانون آموزش با همین نام توسعه یافت. سپس با طرح الگوریتم پس‌انتشار و گسترش ریزپردازنده‌ها تحول شگرفی در دنیای شبکه عصبی مصنوعی پدید آمد (منهاج، ۲۰۰۲). ساختار کلی ANN از ۳ لایه با وظایف مجزا تشکیل شده است، این لایه‌ها عبارتند از: لایه ورودی با نقش توزیع داده‌ها در شبکه، لایه یا لایه‌های میانی (پنهان) که عمل پردازش اطلاعات را بر عهده دارند و لایه خروجی که علاوه بر پردازش به‌ازای بردار ورودی شبکه، خروجی آن را نشان می‌دهد (منهاج، ۲۰۰۲). به باور بیشتر پژوهش‌گران شبکه عصبی مصنوعی به دو دلیل عمده در بررسی مسایل ناشناخته و پیچیده، عملکرد خوبی دارد: اول این‌که با برخوردار از قابلیت تشخیص الگو، رابطه خوبی بین ورودی و خروجی داده‌ها برقرار می‌کند. همچنین در قیاس با دیگر الگوها، حساسیت کم‌تری نسبت به وجود خطا در اطلاعات ورودی نشان می‌دهد (منهاج، ۲۰۰۲؛ کولیالی و همکاران، ۲۰۰۰). علت این امر پردازش

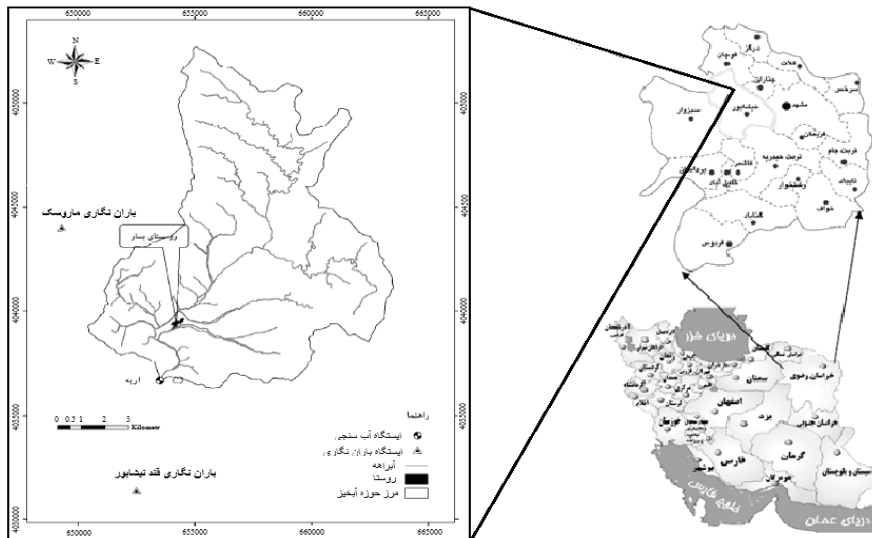
توزیعی اطلاعات در آن است. به طوری که عمل پردازش موازی صورت می‌گیرد و به جای این که تمام بار محاسبه به یک واحد پردازش‌گر تحمیل شود، تعداد زیادی از واحدها هم‌زمان وارد عمل شده و در صورت وجود خطا در یکی از آن‌ها تأثیر منفی بسیاری در عملکرد شبکه و خروجی آن نخواهد داشت (منهاج، ۲۰۰۲).

توکار و جانسون (۱۹۹۹)، به منظور بررسی حساسیت دقت پیش‌بینی مدل شبکه عصبی مصنوعی به حجم داده و طول آموزش، از بارش متأثر از بارش روزانه، دما و ذوب برف استفاده نموده‌اند. همچنین مقایسه‌ای بین نتایج ANN و روش‌های کلاسیک صورت گرفت و نشان داد در شرایط یکسان، شبکه عصبی با کاهش طول داده‌ها و صرف زمان کم‌تر مقادیر واقعی‌تری را پیش‌بینی می‌کند. توکار و مارکوس (۲۰۰۰)، شبکه عصبی مصنوعی و یک مدل مفهومی را برای پیش‌بینی روان‌آب در حوضه‌هایی با ویژگی‌های فیزیکی و اقلیمی متفاوت به کار بستند. از مقایسه نتایج دو روش مشخص شد که در همه موارد شبکه دقت و سرعت بیش‌تر و زمان تمام شده کم‌تری دارد، و در شبیه‌سازی بارش- روان‌آب با بازه‌های زمانی متفاوت توان‌تر از روش مفهومی است. الشورباگی و سیمینویچ (۲۰۰۰)، در پژوهشی ۵ پارامتر شاخص بارندگی پیشین، شاخص ذوب برف، بارندگی زمستانه، بارندگی بهار و زمان را در توسعه هیدروگراف واحد به‌عنوان ورودی‌های شبکه پیش‌خور با الگوریتم پس‌انتشار خطا در رودخانه سرخ ایالات مانتیوای کانادا در نظر گرفتند. نتایج نشان داد که درصد خطا بین مقادیر تخمینی و مشاهده‌ای مربوط به جریان حداکثر و زمان حداکثر به ترتیب ۶ و ۳/۶ درصد است و همبستگی بین این مقادیر به ترتیب ۰/۹۹ و ۰/۸۸ می‌باشد. آنستیل و همکاران (۲۰۰۴)، با مقایسه نتایج ANN و یک مدل مفهومی در پیش‌بینی سیل، شبکه پرسپترون چندلایه را بهتر ارزیابی کردند. ماریا و همکاران (۲۰۰۵)، برای پیش‌بینی بارش در منطقه سائوپائولو در برزیل از شبکه عصبی مصنوعی پیش‌خور با الگوریتم یادگیری resilient و یک مدل رگرسیون خطی استفاده کردند. نتایج به دست آمده نشان داد که پیش‌بینی شبکه عصبی مصنوعی نسبت به آن‌چه که توسط مدل رگرسیون خطی به دست آمده بود برای مجموعه‌های عملیاتی مناسب‌تر است. باجلان و همکاران (۲۰۰۵)، به پیش‌بینی روان‌آب ماهانه با استفاده از ANN از نوع پس‌انتشار با تابع انتقال سیگموئید و الگوریتم لوبنرگ-مارکواریت در حوضه آبریز کسلیان پرداختند و نتایج به دست آمده را با نتایج روش‌های تجربی

جاستین و خوسلا مقایسه کردند. نتایج به‌دست آمده دقت قابل‌قبول شبکه عصبی مصنوعی در پیش‌بینی روان‌آب نسبت به روش‌های تجربی را مورد تأیید قرار می‌دهد. سلیمانی (۲۰۰۹)، برای پیش‌بینی و مدل‌سازی بارش- روان‌آب در حوزه آب‌خیز جراحی واقع در منطقه نیمه‌خشک ایران از شبکه عصبی مصنوعی با پرسپترون چندلایه و کاربرد و مقایسه الگوریتم‌های مختلف استفاده کرد. نتایج به‌دست آمده از مطالعه نشان داد که روش شبکه عصبی مصنوعی برای پیش‌بینی روان‌آب مناسب‌تر و کارتر از روش کلاسیک رگرسیونی است. جهانگیر و همکاران (۲۰۰۸)، شبیه‌سازی فرآیند بارش- روان‌آب را با استفاده از شبکه عصبی مصنوعی از نوع پس‌انتشار با تابع انتقال سیگموئید در حوضه کارده مورد بررسی قرار داده‌اند. نتایج نشان داد شبکه پرسپترون چندلایه دارای یک لایه پنهان، فرآیند روان‌آب را با دقت خوبی شبیه‌سازی می‌کند. در مجموع در زمینه فرآیند بارش- روان‌آب بیش‌تر پژوهش‌گران به برتری شبکه عصبی مصنوعی تأکید داشته‌اند (احمد نور، ۲۰۰۵؛ تائو و همکاران، ۲۰۰۸؛ باجلان و همکاران، ۲۰۰۵؛ رادمان، ۲۰۰۴؛ پریدا و همکاران، ۲۰۰۶؛ رضایی، ۲۰۰۵؛ نورانی و همکاران، ۲۰۱۱؛ وئو و چائو، ۲۰۱۱). هدف این پژوهش مقایسه دو تابع انتقال سیگموئید و تانژانت هیپربولیک شبکه عصبی مصنوعی به‌منظور پیش‌بینی ضریب روان‌آب رگبار در حوزه آب‌خیز بار اریه نیشابور است.

### مواد و روش‌ها

**خصوصیات منطقه مطالعاتی:** حوزه آب‌خیز بار اریه نیشابور به مساحت ۱۱۳۸۸ هکتار در جنوب‌غربی سلسله جبال بینالود قرار گرفته است. این منطقه حد واسط ۳۶ درجه و ۲۷ دقیقه و ۳۸ ثانیه تا ۳۶ درجه و ۳۶ دقیقه و ۳۲ ثانیه عرض شمالی و ۵۸ درجه و ۴۰ دقیقه و ۴۶ ثانیه تا ۵۸ درجه و ۴۹ دقیقه و ۳۱ ثانیه طول شرقی قرار دارد. متوسط ارتفاع حوزه آب‌خیز بار ۲۲۲۶ متر و در محل ایستگاه هیدرومتری ۱۵۶۰ متر می‌باشد (شکل ۱). محیط حوزه آب‌خیز ۵۴ کیلومتر و شیب متوسط آن ۱۱/۹ درصد محاسبه گردیده است. متوسط دبی آن ۰/۶۶ مترمکعب بر ثانیه می‌باشد آب و هوای منطقه نیمه‌خشک و متوسط درجه حرارت آن ۱۲/۸ درجه سانتی‌گراد و میزان متوسط بارندگی سالانه آن ۳۳۰/۴ میلی‌متر است. مدت استقرار برف به‌ترتیب از حداکثر به حداقل در ماه‌های بهمن، دی، اسفند، آذر، آبان، فروردین گزارش شده است (توسلی، ۲۰۰۸).



شکل ۱- موقعیت منطقه مورد مطالعه در ایران و استان خراسان رضوی.

به منظور تکمیل بانک اطلاعاتی همه داده‌های بارش و روان‌آب طی سال‌های ۱۳۳۱ تا ۱۳۸۵ (سال‌های آماری موجود) از سازمان آب منطقه‌ای خراسان رضوی تهیه شد. با توجه به این‌که ایستگاه باران‌سنجی ماروسک در نقاط کوهستانی و ایستگاه باران‌سنجی کارخانه قند در منطقه دشتی و حوزه آب‌خیز بار نیز تقریباً بین این دو ایستگاه واقع گردیده است، بنابراین ثبت وقایع بارشی در هر دو ایستگاه و به منزله سطح مؤثر توده باران‌زا و تأثیر آن بر حوزه آب‌خیز بار، مدنظر قرار گرفت. از این‌رو در انتخاب رگبارها دقت گردید تا وقایع بارشی انتخاب گردند که در هر دو ایستگاه باران‌سنجی ثبت، و سیلاب منفردی تولید کرده باشند. همچنین وقایع بارشی در ماه‌های با احتمال وقوع بالای برف با دقت زیاد کنترل شدند. بنابراین تمامی وقایع بارش برف، باران و برف هم‌زمان و رگبارهایی با فاصله زمانی کم‌تر از ۷۲ ساعت برای کاهش تأثیر روان‌آب به دست آمده از ذوب برف از رگبارهای انتخابی حذف شدند. در نهایت با توجه به در نظر گرفتن همه شرایط حاکم بر رگبارهای موجود و پس از رسم هیدروگراف‌ها و هیتوگراف‌های وقایع اتفاق افتاده، تعداد ۳۳ رگبار انتخاب شد. سپس متغیرهای مدت بارش، شدت متوسط بارش، شاخص  $(\Phi)$ ، بارش ۵ روز قبل، بارش کل، چارک‌های شدت و چارک‌های مقدار بارش از هیتوگراف‌ها و ضریب روان‌آب رگبار از

هیدروگراف‌ها استخراج گردید (جدول ۱). به منظور انتخاب متغیرهای مستقل در برآورد ضریب روان‌آب از روش تجزیه و تحلیل عاملی<sup>۱</sup> با استفاده از نرم‌افزار SPSS استفاده شد. تجزیه عاملی با هدف کشف متغیرهای مستقلی که عامل نامیده می‌شوند، برای یافتن مدل ارتباطی بین مجموعه‌ای از متغیرها که به ظاهر بی‌ارتباط هستند، به کار برده می‌شود. هرچه مقدار همبستگی داخلی بین متغیرها بیش‌تر باشد. تعداد عامل‌های پدید آمده کم‌تر خواهد بود. برای انجام تجزیه و تحلیل عاملی داده‌ها استاندارد شدن سپس ماتریس وزنی عاملی با استفاده از دو روش درست‌نمایی ماکزیمم و تحلیل عامل اصلی در دو حالت با دوران با روش‌های واریماکس، کوارتیماکس و اکواماکس و بدون دوران صورت گرفت. برای انتخاب تعداد عامل‌ها از یک قاعده سرانگشتی که در بیش‌تر نرم‌افزارهای آماری مورد استفاده قرار می‌گیرد استفاده گردید. به این صورت که در مرحله اول تعداد عامل‌ها با توجه به میزان ریشه پنهان ماتریس همبستگی که از یک بزرگ‌ترند انتخاب شد و سپس با استفاده از میزان درصد واریانس آزمون گردید (مانلی، ۲۰۰۵).

جدول ۱- مشخصه‌های آماری متغیرها.

ردیف	نام متغیر	میانگین	انحراف معیار	حداکثر	حداقل
۱	چارک اول شدت بارندگی (میلی متر بر ساعت)	۲/۵۰۷	۲/۵۲۴	۱۲/۱	۰/۳
۲	چارک دوم شدت بارندگی (میلی متر بر ساعت)	۱/۸۹۶	۱/۷۵۰	۸/۲	۰/۴
۳	چارک سوم شدت بارندگی (میلی متر بر ساعت)	۱/۵۸۸	۱/۲۸۰	۵/۰	۰/۰
۴	چارک چهارم شدت بارندگی (میلی متر بر ساعت)	۱/۲۷۴	۱/۱۴۰	۶/۱	۰/۱
۵	شدت متوسط بارندگی کل (میلی متر بر ساعت)	۱/۷۹۰	۱/۱۴۹	۵/۵۵	۰/۱۷
۶	چارک اول مقدار بارندگی (میلی متر)	۳/۳۱۴	۳/۰۶۹	۱۵/۵	۰/۴
۷	چارک دوم مقدار بارندگی (میلی متر)	۲/۵۲۱	۲/۳۲۲	۹/۴	۰/۴
۸	چارک سوم مقدار بارندگی (میلی متر)	۲/۰۹۴	۱/۸۷۸	۹/۵	۰/۰
۹	چارک چهارم مقدار بارندگی (میلی متر)	۱/۶۷۷	۱/۳۵۴	۵/۲	۰/۲
۱۰	مقدار متوسط بارندگی کل (میلی متر)	۹/۶۰۶	۶/۱۷۴	۳۱/۴	۲/۳
۱۱	شاخص $\varphi$ (میلی متر بر ساعت)	۴/۶۹۸	۴/۲۲۲	۱۸/۶	۰/۸
۱۲	بارش ۵ روز قبل (میلی متر)	۱۰/۲۵۱	۱۳/۵۰۳	۶۴/۲	۰/۰
۱۳	ضریب روان‌آب (درصد)	۱۰/۴۷۷	۹/۲۵۱	۴۵/۷۴	۰/۶

## 1- Factor Analysis

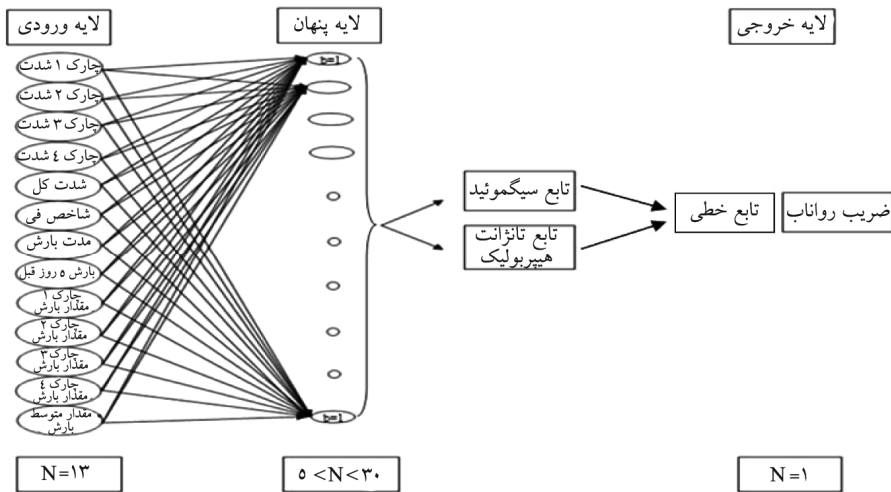
شبکه‌های عصبی مصنوعی: معماری معمول شبکه‌های عصبی مصنوعی متشکل از ۳ لایه است: لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان که داده‌ها را پردازش می‌کند و لایه خروجی که نتایج را به‌ازای ورودی‌های مشخص، استخراج می‌کند. یک شبکه می‌تواند چندین لایه پنهان داشته باشد. ولی پژوهش‌های تئوریک انجام گرفته در این زمینه نشان داده‌اند که یک لایه پنهان برای این‌گونه مدل‌ها می‌تواند هر تابع پیچیده و غیرخطی را تقریب زند (سینکو، ۱۹۸۹؛ هورنیک و همکاران، ۱۹۸۹؛ ژانگ و همکاران، ۱۹۹۸). همچنین نتایج تجربی و عملی نیز این موضوع را تأیید می‌کنند (ژانگ و همکاران، ۱۹۹۸؛ جلیلی‌قازی‌زاده و نوری، ۲۰۰۸؛ نوری و همکاران، ۲۰۰۸). براساس پژوهش‌های انجام شده، ۹۰ درصد شبکه‌های عصبی مصنوعی که در مسایل هیدرولوژی مورد استفاده قرار گرفته‌اند، از نوع الگوریتم پس‌انتشار هستند (کمیته مهندسی عمران آمریکا، ۲۰۰۰؛ برادوک و همکاران، ۱۹۹۸). بنابراین در این پژوهش از شبکه عصبی پرسپترون چندلایه با یک لایه پنهان برای پیش‌بینی ضریب روان‌آب استفاده گردید.

شبکه‌های پرسپترون چندلایه<sup>۱</sup>: مدل عمومی شبکه‌های پرسپترون، شبکه جلورونده<sup>۲</sup> با روال تعلیم انتشار به عقب<sup>۳</sup> است. شبکه‌های جلورونده شبکه‌هایی هستند که ورودی‌های لایه اول نرون‌های آن به لایه‌های بعدی متصل بوده و در هر سطح این مسأله صادق بوده تا به لایه خروجی برسد. روال انتشار به عقب به این معنی است که پس از مشخص شدن خروجی شبکه، ابتدا وزن‌های لایه آخر تصحیح شده و بعد به ترتیب وزن‌های لایه‌های قبلی تصحیح می‌شوند. شکلی از ساختار شبکه مورد استفاده در شکل ۲ آمده است.

طراحی شبکه: شبکه عصبی مصنوعی برای طراحی، نیازمند ۳ دسته داده آموزشی<sup>۴</sup>، صحت‌سنجی<sup>۵</sup> و آزمایش<sup>۶</sup> می‌باشد. در این پژوهش ۷۰ درصد داده‌ها برای آموزش شبکه، ۱۵ درصد برای صحت‌سنجی و ۱۵ درصد دیگر برای اعتبارسنجی در نظر گرفته شد. اولین قدم در معماری یک شبکه، انتخاب قانون یادگیری مناسب می‌باشد که در این پژوهش از قوانین یادگیری لوبنرگ-مارکوآرت<sup>۷</sup> استفاده شده است

- 1- Multi Layer Perceptron
- 2- Feed Forward
- 3- Back Propagation Training
- 4- Training
- 5- Validation
- 6- Test
- 7- Levenberg-Marquardt

(کیسی، ۲۰۰۸). از این‌رو برای شبیه‌سازی ضریب روان‌آب شبکه پرسپترون چندلایه با الگوریتم پس‌انتشار خطا برگزیده شد که در محیط نرم‌افزار Matlab اجرا گردید. تابع غیرخطی سیگموئید و تابع تانژانت هیپربولیک به‌عنوان توابع انتقال شبکه در لایه مخفی و تابع خطی در لایه خروجی مورد استفاده قرار گرفت.



شکل ۲- ساختار شبکه عصبی مصنوعی به کار رفته.

تابع فعال<sup>۱</sup>: در این پژوهش از تابع غیرخطی مشتق‌پذیر سیگموئید<sup>۲</sup> (رابطه ۱) و تابع نامتقارن تانژانت هیپربولیک<sup>۳</sup> (رابطه ۲) در لایه پنهان و تابع خطی در لایه خروجی استفاده شد.

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

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

- 1- Activation Function
- 2- Sigmoid Function
- 3- Hyperbolic Tangent Function



استاندارد کردن<sup>۱</sup>: قبل از ورود داده‌ها به شبکه باید آن‌ها نرمال شوند. زیرا وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. همچنین از آنجایی که هر کدام از پارامترها تقسیم‌بندی‌های مربوط به خودشان را دارند، بنابراین برای یکسان کردن دامنه تغییرات آن‌ها عمل نرمال‌سازی داده‌ها صورت می‌گیرد تا از کوچک شدن بیش از حد وزن‌های شبکه جلوگیری شود (کیسی، ۲۰۰۸). برای انجام این پژوهش از رابطه ۳ برای نرمال‌سازی استفاده شد که داده‌ها را بین ۰/۱-۰/۹ استاندارد می‌کند:

$$N_i = 0.1 \times \left( \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right) + 0.1 \quad (3)$$

که در آن،  $N_i$ : مقادیر استاندارد شده،  $x_i$ : مقادیر واقعی،  $x_{\min}$ : حداقل مقادیر واقعی و  $x_{\max}$ : حداکثر مقادیر واقعی می‌باشد. مبنای تصمیم‌گیری برای انتخاب بهترین شبکه در هر بار اجرای برنامه، ضریب تعیین  $R^2$  (رابطه ۴)، ریشه میانگین مربعات خطا (RMSE)<sup>۲</sup> (رابطه ۵) و متوسط قدرمطلق خطا (MAE)<sup>۳</sup> (رابطه ۶) می‌باشد، که در زیر ارایه شده است:

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{y}_f)^2}{\sum_{i=1}^n y_i^2 - \frac{(\sum_{i=1}^n y_i)^2}{n}} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y}_f)^2}{n}} \quad (5)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - y_f|}{n} \quad (6)$$

که در آن‌ها،  $y_i$  و  $y_f$ : به ترتیب اندازه مشاهده‌ای و برآورد شده پارامتر موردنظر با شبکه و  $n$ : تعداد کل داده‌های استفاده شده است. بهترین عملکرد مدل براساس معیار  $R^2$ ، مقدار ۱ و براساس سایر معیارها مقدار صفر را به همراه دارد که نشان‌دهنده نزدیک‌تر بودن مقادیر مشاهده شده و پیش‌بینی شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است.

- 
- 1- Normalization
  - 2- Root Mean Squared Error
  - 3- Mean Absolute Error

نتایج و بحث

به‌منظور تعیین ساختار بهینه، شبکه مورد استفاده به‌ازای تعداد نرون‌های متفاوت در لایه میانی مورد ارزیابی قرار گرفت. تعداد نرون‌های لایه پنهان برای هر دو تابع از ۳۰-۵ نرون تغییر داده شد که مشخص گردید شبکه با تابع سیگموئید با تعداد ۲۵ نرون در لایه میانی (پنهان) از کم‌ترین مقدار میانگین مربعات خطا (۰/۰۰۶۰۹) برخوردار است و شبکه با تابع تانژانت هیپربولیک با تعداد ۱۵ نرون در لایه میانی از کم‌ترین مقدار میانگین مربعات خطا (۰/۰۰۸۰۸) برخوردار است. البته این مرحله به‌ازای لایه‌های دوم و سوم میانی نیز به اجرا درآمد که بهبودی چشم‌گیری در عملکرد شبکه مشاهده نگردید. برای تعیین اثر تعداد تکرارهای آموزش در عملکرد شبکه، تعداد تکرار از ۱۰۰-۱۰۰۰ برای هر دو تابع در نظر گرفته شد و اجرای شبکه‌هایی با تکرارهای متفاوت نشان داد که هم برای تابع سیگموئید و هم تابع تانژانت هیپربولیک، شبکه با ۲۰۰ تکرار مناسب‌ترین پیش‌بینی را ارائه می‌دهد. با استفاده از روش تجزیه و تحلیل عاملی، ۱۳ متغیر مورد بررسی، به ۴ متغیر مستقل کاهش پیدا کرد (جدول ۲).

جدول ۲- ماتریس وزنی عاملی دوران‌یافته برای داده‌های استاندارد شده.

ردیف	متغیر	عامل ۱	عامل ۲	عامل ۳	عامل ۴
۱	چارک چهارم شدت بارندگی	-۰/۲۳۲	۰/۱۲۳	۰/۱۲۴	۰/۹۱۱*
۲	چارک سوم شدت بارندگی	۰/۰۴۸	۰/۸۸۲*	-۰/۱۴۹	۰/۱۳۳
۳	چارک دوم شدت بارندگی	۰/۱۴۳	۰/۸۴۹*	۰/۲۱۳	-۰/۰۴۴
۴	چارک اول شدت بارندگی	-۰/۰۸۰	۰/۲۲۲	۰/۸۹۸*	۰/۰۹۸
۵	چارک چهارم مقدار بارندگی	۰/۴۸۷	-۰/۲۵۴	-۰/۱۳۶	۰/۷۴۳*
۶	چارک سوم مقدار بارندگی	۰/۷۳۵*	۰/۳۳۳	-۰/۳۳۷	۰/۱۴۵
۷	چارک دوم مقدار بارندگی	۰/۸۴۵*	۰/۳۲۰	۰/۱۱۸	-۰/۰۹۲
۸	چارک اول مقدار بارندگی	۰/۶۰۶	-۰/۲۲۷	۰/۶۸۷	-۰/۰۸۴
۹	بارش ۵ روزقبل	۰/۰۶۷	۰/۱۵۲	۰/۱۳۱	۰/۵۵۲
۱۰	شاخص فی	۰/۰۴۴	۰/۰۴۳	۰/۸۹۶*	۰/۱۲۵
۱۱	شدت متوسط بارندگی	-۰/۰۳۶	۰/۷۳۵*	۰/۵۷۳	۰/۳۲۵
۱۲	مدت بارندگی	۰/۷۹۸*	-۰/۴۹۷	-۰/۱۲۴	-۰/۰۳۵
۱۳	مقدار متوسط بارندگی	۰/۹۴۹*	۰/۰۵۳	۰/۲۵۳	۰/۱۳۱

با توجه به نتایج مقادیر ویژه<sup>۱</sup> ریشه پنهان ماتریس همبستگی ۴ عامل اول انتخاب شده در جدول ۲ می‌توانند حدود ۸۳ درصد واریانس را توضیح دهند. در عامل اول، از آنجایی که عامل مقدار متوسط بارندگی می‌تواند بقیه عوامل را توضیح دهد این عامل انتخاب گردید. به همین ترتیب عوامل چارک سوم، اول و چهارم شدت بارندگی به ترتیب در عوامل دوم تا چهارم انتخاب گردیدند (استراتژی اول). از طرف دیگر با توجه به این که محاسبه‌های تحلیل عاملی به تنهایی نمی‌تواند نتایج روشن فراهم آورد و برای انتخاب صحیح متغیرها باید درک کافی از داده‌ها وجود داشته باشد، به تجزیه و تحلیل هر یک از متغیرهای انتخاب شده پرداخته شد. همان‌طور که از نتایج برمی‌آید به جز عامل اول، وزن سایر عوامل روی چارک‌های شدت بارش اعمال شده و این با توجه به ماهیت داده‌های شدت بارش که دربرگیرنده مقدار و مدت بارندگی است کاملاً قابل توجیه است. در عامل اول بیش‌ترین وزن روی متغیر مقادیر بارندگی اعمال شده ولی با تاکید بر این که مقدار و مدت بارندگی در مقیاس‌های کوچک‌تر و دقیق‌تر چارک‌های شدت بارندگی مستتر است بنابراین از انتخاب این متغیر صرف‌نظر شده و با افزودن چارک دوم شدت بارندگی به ۳ چارک دیگر که در عوامل دوم، سوم و چهارم انتخاب شده بودند، گزینش متغیرها تکمیل می‌شود. در عامل سوم، دو متغیر شاخص فی و چارک اول شدت بارندگی دارای وزن ماتریسی تقریباً برابر هستند در این حالت با توجه به تأثیر هر یک از این متغیرها روی ضریب روان‌آب و اهمیت و نقش هیدرولوژیکی آن‌ها هر دو متغیر انتخاب می‌شود. بنابراین در مجموع ۵ متغیر چارک‌های اول تا چهارم شدت بارندگی و شاخص فی به‌عنوان متغیرهای مستقل برای اجرای شبکه انتخاب شدند (استراتژی دوم).

تعیین ترکیب‌های مختلفی از ورودی‌ها برای ساخت شبکه: با اعمال نظر کارشناسی ترکیب‌های مختلفی از ورودی‌ها تعیین شده و براساس آن ساختارهای مختلف تعریف و شبکه‌ها اجرا شد. ترکیب‌های مختلف ورودی‌ها در جدول‌های ۳ و ۴ قابل مشاهده است (استراتژی سوم).

جدول ۳- ترکیب ورودی‌های مختلف برای شبکه، حالت اول.

شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه
۱	شدت	۵	چارک‌های	۹	مقدار	۱۳	چارک‌های
	متوسط بارش		شدت بارش		متوسط بارش		مقدار بارش
۲	شدت	۶	چارک‌های	۱۰	مقدار	۱۴	چارک‌های
	متوسط بارش		شدت بارش		متوسط بارش		مقدار بارش
	شاخص فی		شاخص فی		شاخص فی		شاخص فی
۳	شدت	۷	چارک‌های	۱۱	مقدار	۱۵	چارک‌های
	متوسط بارش		شدت بارش		متوسط بارش		مقدار بارش
	شاخص فی		شاخص فی		شاخص فی		شاخص فی
	بارش ۵ روز قبل		بارش ۵ روز قبل		بارش ۵ روز قبل		بارش ۵ روز قبل
۴	شدت	۸	چارک‌های	۱۲	مقدار	۱۶	چارک‌های
	متوسط بارش		شدت بارش		متوسط بارش		مقدار بارش
	بارش ۵ روز قبل		بارش ۵ روز قبل		بارش ۵ روز قبل		بارش ۵ روز قبل

جدول ۴- ترکیب ورودی‌های مختلف برای شبکه حالت دوم.

شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه	شماره شبکه	ورودی شبکه
۱۷	چارک‌های	۱۹	چارک‌های	۲۱	چارک‌های	۲۳	چارک‌های
	شدت بارش		شدت بارش		مقدار بارش		مقدار بارش
	شاخص فی		مدت بارش		شدت		شدت
	مقدار		شاخص فی		متوسط بارش		متوسط بارش
	متوسط بارش		مقدار		بارش ۵ روز قبل		بارش ۵ روز قبل
	چارک‌های		متوسط بارش		شاخص فی		شاخص فی
	مقدار بارش		مدت بارش		بارش ۵ روز قبل		بارش ۵ روز قبل
۱۸	بارش ۵ روز قبل	۲۰	چارک‌های	۲۲	چارک‌های	۲۴	چارک‌های
	شاخص فی		شدت بارش		شدت بارش		شدت بارش
	شدت		مقدار		مدت بارش		مدت بارش
	متوسط بارش		متوسط بارش		شاخص فی		شاخص فی
	مدت بارش		بارش ۵ روز قبل		مقدار		مقدار
			بارش ۵ روز قبل		متوسط بارش		متوسط بارش
			بارش ۵ روز قبل		بارش ۵ روز قبل		بارش ۵ روز قبل


مطابق با معیارهای ارزیابی موردنظر همانطورکه در جدول ۵ مشاهده می‌شود نتایج تحلیل عاملی ۲ و ترکیب‌های مختلف ورودی‌ها با اعمال نظر کارشناسی با تابع سیگموئید نتایج یکسانی داشتند. شبکه با ورودی‌های چارک‌های اول تا چهارم شدت بارندگی، مدت بارش، مقدار متوسط بارش، شاخص فی و بارش ۵ روز قبل و تابع انتقال تانژانت هیپربولیک می‌تواند ضریب روان‌آب رگبار را نسبت به تابع سیگموئید با ورودی‌های شاخص فی و چارک‌های اول تا چهارم شدت بارندگی، با دقت بیش‌تری پیش‌بینی کند.

جدول ۵- نتایج مرحله آزمایش، صحت‌سنجی و آموزش شبکه عصبی مصنوعی برای دو تابع مختلف.

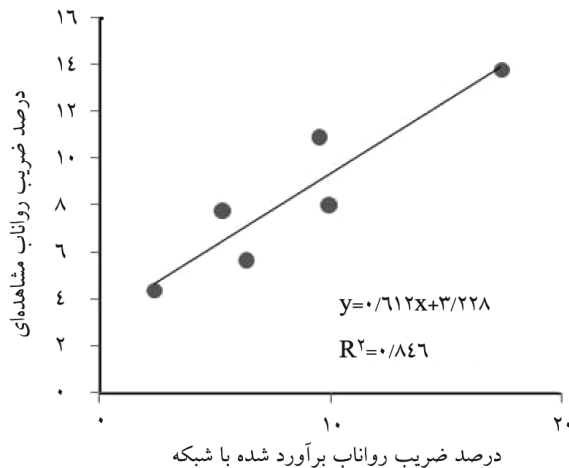
آزمایش		صحت‌سنجی		آموزش		تابع انتقال	معماری شبکه	متغیر ورودی
MAE	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE			
۰/۱۱۸۰	۰/۱۷۲۳	۰/۵۹	۰/۰۳۹۹	۰/۹۸	۰/۰۰۹۰۶	۰/۹۹	۴-۱۵-۱	تحلیل عاملی ۱
۰/۱۵۵۴	۰/۱۸۰۶	۰/۳۲	۰/۰۶۰۴	۰/۷۱	۰/۰۲۸۲	۰/۹۵	۴-۲۵-۱	تحلیل عاملی ۱
۰/۲۴۶۲	۰/۳۳۵۶	۰/۴۶	۰/۰۰۹۲۵	۰/۹۰	۰/۰۰۳۳۶	۰/۹۹	۵-۲۵-۱	تحلیل عاملی ۲
۰/۰۳۵۷	۰/۰۳۹۲	۰/۸۴	۰/۰۰۱۰	۰/۹۴	۰/۰۰۸۱۰	۰/۹۹	۵-۲۵-۱	تحلیل عاملی ۲
۰/۰۲۷۵	۰/۰۳۳۷	۰/۹۸	۰/۰۰۲۳۶	۰/۹۹	۰/۰۰۸۲۸	۰/۹۹	۸-۱۵-۱	شبکه شماره ۲
۰/۰۳۵۷	۰/۰۳۹۲	۰/۸۴	۰/۰۰۱۰	۰/۹۴	۰/۰۰۸۱۰	۰/۹۹	۵-۲۵-۱	شبکه شماره ۶

ارزیابی عملکرد شبکه‌ها بر مبنای مقایسه ضریب روان‌آب پیش‌بینی شده با شبکه و مقادیر مشاهده‌ای در نظر گرفته شد که تفاوت کم‌تر بین آن‌ها مناسب‌تر تشخیص داده شد. در شکل ۳ مشاهده می‌شود که شبکه با تابع تانژانت هیپربولیک ضریب روان‌آب را با ضریب تبیین مرحله آزمایش ۰/۹۸ به‌خوبی شبیه‌سازی کرده و پیش‌بینی‌های شبکه بسیار نزدیک به داده‌های مشاهده‌ای است. شبیه‌سازی شبکه با تابع سیگموئید (شکل ۴) اگرچه به داده‌های مشاهده‌ای بسیار نزدیک است (ضریب تبیین ۰/۸۴)، ولی از دقت کم‌تری نسبت به تابع تانژانت هیپربولیک برخوردار است. همچنین برآزش


داده‌های مشاهده‌ای و برآورد شده، عملکرد بهتر شبکه با تابع تانژانت هیپربولیک (شکل ۵) را نسبت به شبکه با تابع سیگموئید (شکل ۶) را نشان می‌دهد. به این ترتیب شبکه عصبی مصنوعی با تابع تانژانت هیپربولیک در تخمین این پارامتر پیچیده عملکرد مناسبی داشته است.




شکل ۳- ضریب تبیین مرحله آزمایش شبکه با تابع تانژانت هیپربولیک.



شکل ۴- ضریب تبیین مرحله آزمایش شبکه با تابع سیگموئید.



شکل ۵- برازش داده‌های مشاهده‌ای و برآوردی شبکه با تابع تانژانت هیپربولیک در مرحله آموزش، صحت‌سنجی و آزمایش.



شکل ۶- برازش داده‌های مشاهده‌ای و برآوردی شبکه با تابع سیگموئید در مرحله آموزش، صحت‌سنجی و آزمایش.

نتایج به‌دست آمده بیانگر این نکته است که از میان ۱۳ متغیر هیدرولوژیکی مورد بررسی در این پژوهش، مقادیر چارک‌های شدت بارش و شاخص فی در مقیاس رگبار با استفاده از شبکه عصبی مصنوعی با تابع سیگموئید بیش‌ترین تأثیر را در برآورد ضریب روان‌آب دارند. این قضیه را از نظر هیدرولوژی می‌توان این گونه توضیح داد که متغیر شدت بارش با اعمال دو متغیر مقدار و مدت بارش ارتباط بیش‌تری را با مقادیر ضریب روان‌آب برقرار می‌کند که با مطالعه پریدا و همکاران (۲۰۰۶) و توسلی (۲۰۰۸) نیز مطابقت دارد. همچنین شاخص فی که یکی از پارامترهای مهم در ارتباط با بارش

مازاد یا به عبارت دیگر مقدار بارشی است که به روان آب تبدیل می‌شود، تأثیر محسوسی در برآورد ضریب روان آب دارد. نتایج به دست آمده از اجرای شبکه با تابع تانژانت هیپربولیک نشان داد که این تابع با ورودی‌های بیش‌تر و جزئی‌تر برای تخمین ضریب روان آب، منجر به پاسخ بهتری خواهد شد. همان‌طور که از نتایج برمی‌آید متغیرهایی که در هر دو نوع شبکه برتر وجود داشته‌اند چارک‌های شدت بارش و شاخص فی بوده‌اند که اهمیت آن‌ها در بالا شرح داده شد. با این تفاوت که شبکه با تابع تانژانت هیپربولیک با متغیرهای بیش‌تری شامل بارش کل، بارش ۵ روز قبل و مدت بارش، ضریب روان آب را پیش‌بینی می‌کند. این مطلب علاوه بر تاکید اهمیت و نقش این متغیرها در پیش‌بینی ضریب روان آب رگبار، عملکرد مناسب شبکه پرسپترون چندلایه در مسایل هیدرولوژیکی را مطابق با مطالعات سایر پژوهش‌گران (توکار و جانسون، ۱۹۹۹؛ جهانگیر و همکاران، ۲۰۰۸؛ باجلان و همکاران، ۲۰۰۵؛ رضایی، ۲۰۰۶؛ رادمان و همکاران، ۲۰۰۴؛ نورانی و همکاران، ۲۰۱۱؛ سلیمانی، ۲۰۰۹؛ تائو و همکاران، ۲۰۰۸؛ ماریا و همکاران، ۲۰۰۵؛ احمد نور، ۲۰۰۵؛ آنستیل و همکاران، ۲۰۰۴؛ الشورباگی و سیمینویچ، ۲۰۰۰؛ توکار و مارکوس، ۲۰۰۰؛ وئو و چائو، ۲۰۱۱) مورد تأیید قرار می‌دهد.

### نتیجه‌گیری

در این مقاله با استفاده از ۱۳ متغیر، به مقایسه عملکرد دو تابع شبکه عصبی مصنوعی در تخمین ضریب روان آب پرداخته شد. نتایج به دست آمده از اجرای شبکه‌ها با دو تابع فعال‌سازی تانژانت هیپربولیک و سیگموئید و با ورودی‌های مختلف نشان داد که تابع تانژانت هیپربولیک با تعداد ورودی‌های بیش‌تر، قادر است ضریب روان آب رگبار را با RMSE برابر ۳/۳ درصد و  $R^2$  برابر ۹۸ درصد پیش‌بینی کند. همچنین با توجه به نتایج به دست آمده از میان ۱۳ متغیر هیدرولوژیکی به کار رفته به عنوان ورودی شبکه برای پیش‌بینی ضریب روان آب، چارک‌های اول تا چهارم شدت بارندگی و شاخص فی را به عنوان مهم‌ترین متغیرهای تأثیرگذار روی بهبود عملکرد شبکه برای پیش‌بینی ضریب روان آب، معرفی می‌کند. افزون بر ویژگی‌های بارش، عوامل دیگری نیز در فرآیند تبدیل بارش به روان آب نقش دارند که بیش‌تر مربوط به حوضه هستند. در این بررسی به سبب نبود این اطلاعات در آمار سال‌های گزینش شده، به جز شاخص فی سایر ویژگی‌ها مورد استفاده قرار نگرفت. با توجه به تأثیر چشم‌گیری که ویژگی‌های فیزیکی و وضعیت رطوبتی حوضه قبل از بارش بر اندازه ضریب روان آب دارند پیشنهاد می‌شود که اطلاعات مربوط به این ویژگی‌ها را در بردار ورودی شبکه در نظر گرفت و تأثیر آن‌ها بررسی شوند.



منابع

1. Ahmat Nor, N.I.B. 2005. Rainfall-runoff modelling using Artificial Neural Networks method, Ph.D. dissertation, Faculty of Civil Engineering, Malaysia Technology University, 120p.
2. Anctil, F., Perrin, C.H., and Andreassian, V. 2004. Impact of the length of observed records on the performance of ANN and conceptual parsimonious rainfall-runoff forecasting models. *Environmental Modeling and Software*, 19: 357-368.
3. ASCE Task Committee. 2000. Artificial neural networks in hydrology, II: Hydrology application. *J. Hydrol. Engine.* 5: 124-137.
4. Bajelan, A., Mahmoodian Shoshtari, M., and Avalipoor, M. 2005. Prediction monthly runoff with artificial neural network (ANN) and compared with results of experimental methods in the Kasilyan basin, P 9. In: CD Proceedings of the fifth Iranian hydraulic conference, Kerman. (In Persian)
5. Braddock, R.D., Kremmer, M.L., and Sanzogni, L. 1998. Feedforward artificial neural network model for forecasting rainfall-runoff. *Environ. Sci.* 9: 419-432.
6. Coulibaly, P., Anctil, F., and Bobee, B. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *J. Hydrol.* 230: 244-257.
7. Cybenko, G. 1989. Approximation by superposition of a sigmoid function. *Math. Contr. Sign. Syst.* 2: 303-314.
8. Elshorbagy, A., and Simonovic, S.P. 2000. Performance evaluation of artificial neural networks for runoff prediction. *J. Hydrol. Engine. ASCE*, 3: 3. 203-209.
9. Hornik, K., Stinchcombe, M., and White, H. 1989. Multilayer feed forward networks are universal approximators. *Neur. Net.* 2: 5. 359-366.
10. Jahangeer, A.E., Raeini-Sarjaz, M., and Ziatabar-Ahmadi, M.Kh. 2008. Comparison of artificial neural networks (ANN) simulation of rainfall-runoff process with HEC-HMS model in Kardeh watershed, *J. Agric. Soil Water Sci. Technol.* 22: 2. 72-84. (In Persian)
11. Jalili-Ghazizade, M., and Noori, R. 2008. Prediction of municipal solid waste generation by use of artificial neural network: a case study of Mashhad. *Int. J. Environ. Res.* 2: 1. 13-22.
12. Kisi, O. 2008. River flow forecasting and estimation using different artificial neural network techniques, *Hydrol. Res.* 39: 1. 27-40.
13. Manly, B.F.J. 2005. *Multivariate statistical methods*, Chapman and Hall/CRC Press, 214p.
14. Maria, C.V.R., Haroldo, F.C.V., and Nelson, J.F. 2005. Artificial neural network technique for rainfall forecasting applied to the São Paulo region, *J. Hydrol.* 301: 1-4. 146-162.
15. Menhaj, M.B. 2002. *Foundations of Neural Networks*, Amirkabir Univ. Press, 715p. (In Persian)

16. Misaghi, F. 2002. Simulation of rainfall-runoff for river routing using artificial neural networks, P 46. In: Proceeding Abstract of sixth international conference on river engineering, Ahvaz. (In Persian)
17. Noori, R., Ashrafi, Kh., and Ajdarpour, A. 2008. Application of artificial neural network methods and multivariate linear regression based on principal component analysis to predict the daily average concentration of carbon monoxide: a case study in Tehran, J. Ear. Space Physics, 34: 152-135. (In Persian)
18. Nourani, V., Kisi, O., and Komasi, M. 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process, J. Hydrol. 402: 41-59.
19. 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, Phys. Chem. Ear. 31: 928-934.
20. Radman, R., Alimohammadi, S., and Jabbari, A. 2004. Comparison of classical models and artificial neural networks in streamflow forecasting, P 1-13. In: Proceedings of the Annual Conference of Iran Water Resources, Water Resources Engineering, Iran Science and Society, Faculty of Tehran University. (In Persian)
21. Rezaei, E. 2005. Peak flow modeling using artificial neural networks, P 343-353. In: Proceedings of the Second National Conference on Watershed and Soil and Water Resources Management, Shahid Bahonar University of Kerman. (In Persian)
22. Solaimani, K. 2009. Rainfall-runoff prediction based on artificial neural network (a case study: Jarahi watershed). American-Eurasian J. Agric. Environ. Sci. 5: 6. 856-865.
23. Tao, W., Kailin, Y., and Yongxin, G. 2008. Application of artificial neural networks to forecasting ice conditions of the Yellow River in the Inner Mongolia reach. J. Hydrol. 13: 9. 811-816.
24. Tavasoli, A. 2008. Dynamics of runoff coefficient in storm basis for Neishabour Bar Watershed, Iran, M.Sc. Thesis, Faculty of Natural Resources, Tarbiat Modares University, 85p. (In Persian)
25. Tokar, A.S., and Johnson, P.A. 1999. Rainfall-runoff modeling using artificial neural networks, J. Hydrol. Engine. ASCE, 4: 3. 232-240.
26. Tokar, A.S., and Markus, M. 2000. Precipitation-runoff modeling using artificial neural networks and conceptual models. J. Hydrol. Engine. ASCE, 45: 156-161.
27. Wu, C.L., and Chau, K.W. 2011. Rainfall-runoff modeling using artificial neural network coupled with singular spectrum analysis, J. Hydrol. 399: 3-4. 394-409.
28. Zhang, G., Patuwo, B.E., and Hu, M.Y. 1998. Forecasting with artificial neural networks: the state of the art. Int. J. Forecast. 14: 1. 35-62.



Gorgan University of Agricultural  
Sciences and Natural Resources

*J. of Water and Soil Conservation, Vol. 20(2), 2013*  
<http://jwsc.gau.ac.ir>

**Performance comparison of two activation functions namely  
Sigmoid and Hyperbolic Tangent in Artificial Neural  
Networks for storm runoff coefficient forecasting  
(Case Study: Barariyeh Watershed, Neishabour)**

**M. Jafari<sup>1</sup>, \*M. Vafakhah<sup>2</sup> and H. Abghari<sup>3</sup>**

<sup>1</sup>M.Sc. Student, Dept. of Watershed Management Engineering, Tarbiat Modares University,

<sup>2</sup>Assistant Prof., Dept. of Watershed Management Engineering, Tarbiat Modares University,

<sup>3</sup>Assistant Prof., Dept. of Watershed Management Engineering, Urmia University

Received: 01/04/2012; Accepted: 07/23/2012

**Abstract**

The rainfall-runoff process and flooding are hydrologic phenomena that are difficult to study due to the influence of different parameters. So far, different methods and models are provided to analyze these phenomena. Therefore, the purpose of this study is evaluation of artificial neural networks (ANNs) for storm runoff coefficient forecasting using two transfer functions, hyperbolic tangent and sigmoid, in hidden layer and linear in output layer. For this reason, Barariyeh watershed was chosen in Neishabour and the data of 33 events were collected during 1952 to 2006. The factor analysis (FA) were used for determination of independent variables in storm runoff coefficient forecasting in which four variables were selected as independent variables, including average rainfall amount, third, first and fourth quartiles rainfall intensity and also five variables including  $\phi$  index and first to fourth quartiles rainfall intensity. ANN was performed using sigmoid and hyperbolic tangent functions. The result of variables through factor analysis was acceptable for ANN using sigmoid transfer function but wasn't acceptable for ANN using hyperbolic tangent transfer function due to different performance of this activation function. So, other variables combined based on their hydrological role, were considered as ANN inputs. The results revealed that ANN using first to fourth quartile rainfall intensity, rainfall duration, average rainfall amount and total rainfall of five days ago inputs and hyperbolic tangent transfer function can predict storm runoff coefficient with  $R^2=0.98$  and  $RMSE=0.0337$  and  $MAE=0.0275$ .

**Keywords:** ANN, Sigmoid function, hyperbolic tangent function, Runoff coefficient, Barariyeh Neishabour Watershed

---

\* Corresponding Author; Email: [vafakhah@modares.ac.ir](mailto:vafakhah@modares.ac.ir)