

## بررسی عملکرد شبکه عصبی مصنوعی در پیش‌بینی جریان رودخانه (مطالعه موردی: حوزه قره‌آغاج استان فارس)

مهدی جلالی<sup>۱</sup>، عبدالله پیرنیا<sup>۲\*</sup>، کریم سلیمانی<sup>۳</sup>، محمود حبیب‌نژاد روشن<sup>۴</sup>

تاریخ دریافت: ۹۳/۱۲/۸

تاریخ پذیرش: ۹۴/۲/۱۳

### چکیده

به منظور پیش‌بینی جریان رودخانه در حوزه‌های آبخیز طی سالیان متمادی، روش‌های مختلفی ابداع شده که کارایی آن‌ها نیز به اثبات رسیده است. یکی از این مدل‌های شبیه‌سازی، شبکه‌های عصبی مصنوعی است که می‌تواند با دقتی درخور توجه، واقعیات موجود را به تصویر بکشد. در این تحقیق، به منظور شبیه‌سازی دبی، به بررسی و تأثیر پارامترهای هواشناسی بر روی جریان رودخانه قره‌آغاج پرداخته شد. برای این منظور از آمار دبی، بارش و دمای ماهانه ایستگاه‌های موجود حوزه با طول دوره آماری ۲۳ سال (۱۳۶۰-۱۳۸۳) استفاده شد. داده‌های موجود پس از نرمال‌سازی، به دو دسته آموزش و تست تقسیم و به ۵ صورت متفاوت و ۹ مدل با استفاده از شبکه عصبی پرسپترون چند لایه با قانون پس انتشار خطا و توابع یادگیری LM و Gdx مورد آزمون قرار گرفتند. بهترین آرایش شبکه با استفاده از تابع یادگیری LM به صورت ۱-۲۱-۹ با مقادیر ضریب همبستگی ۱ و ۱ و برای تابع یادگیری Gdx نیز به صورت ۱-۱۳-۷ با مقادیر ضریب همبستگی ۰/۹۴ و ۰/۹۶ به ترتیب برای داده‌های آموزش و تست حاصل شد. نتایج حاصل بیانگر تأثیر پارامترهای هواشناسی مانند دما و بارش بر روی جریان خروجی حوزه و اختلاف بسیار ناچیز بین داده‌های شبیه‌سازی شده با مقادیر مشاهداتی است. همچنین شبکه عصبی در شبیه‌سازی جریان رودخانه با تابع یادگیری LM کارایی بهتری را نشان داد.

**کلمات کلیدی:** شبیه‌سازی، شبکه عصبی پرسپترون چند لایه (MLP)، الگوریتم یادگیری لونیبرگ - مارکوارت (LM)، جریان رودخانه، قره‌آغاج، استان فارس.

۱. دانش‌آموخته کارشناسی ارشد آبخیزداری دانشگاه مازندران، دانشکده منابع طبیعی ساری، ایران

۲. دانشجوی دکتری آبخیزداری دانشگاه علوم کشاورزی و منابع طبیعی ساری، دانشکده منابع طبیعی، ایران (نویسنده مسئول)

Email: abd.god62@gmail.com

۳. استاد دانشگاه علوم کشاورزی و منابع طبیعی ساری، دانشکده منابع طبیعی، ایران

۴. استاد دانشگاه علوم کشاورزی و منابع طبیعی ساری، دانشکده منابع طبیعی، ایران

## مقدمه

از آنجاکه کشور ایران به دلیل واقع شدن در منطقه خشک و نیمه خشک و محدودیت منابع آبی و با توجه به روند رو به افزایش جمعیت آن در آینده‌ای نه چندان دور، دچار بحران کم آبی خواهد شد، لذا استفاده بهینه از منابع آب لازم و ضروری است (ضیائی، ۲۰۰۱). اکوسیستم بیابانی که بخش وسیعی از کشور ایران را فرا گرفته است، به دلیل کسر رطوبت خاک، شدت تأثیر خورشید، دمای بالا، خشکی زیاد، ضعف هوموس، نمکی بودن آن و توسعه فرسایش آب - بادی و موارد دیگر، آسیب پذیر است. پس با توجه به محدودیت منابع آبی در کشور مخصوصاً اکوسیستم‌های بیابانی، توزیع زمانی و مکانی غیریکنواخت منابع آبی، افزایش آلودگی‌ها، تخریب منابع طبیعی و همچنین افزایش جمعیت، رشد و توسعه جوامع شهری و فعالیت‌های کشاورزی و صنعتی ضرورت برنامه‌ریزی و مدیریت صحیح منابع آبی اجتناب‌ناپذیر است. در هر برنامه مدیریتی برای منابع آب، آگاهی از شرایط آینده به منظور تخصیص بهینه منابع آب به بخش‌های مختلف از قبیل شرب، کشاورزی و... لازم است. در یک سیستم منابع آب اغلب نیاز بخش‌های مختلف از قبیل کشاورزی، شرب و... تغییر چندانی نکرده و به راحتی قابل پیش‌بینی می‌باشد. آنچه در این میان مهم است، پیش‌بینی مقادیر جریان ورودی به سیستم منابع آب در ماه‌های آینده می‌باشد (فتح‌آبادی، ۲۰۰۷).

به منظور پیش‌بینی جریان رودخانه، با توسعه فناوری‌های جدید و علوم کامپیوتری، مدل‌های هیدرولیکی و هیدرولوژیکی مختلفی رایج شده که با آزمایش‌های متعدد کارایی آن‌ها به اثبات رسیده است (توکار و مارکوس، ۲۰۰۰). در این راستا شبکه‌های عصبی از جمله مدل‌های شبیه‌سازی هستند که می‌توانند با دقتی درخور توجه واقعیت‌های موجود را به تصویر بکشند و راهکار مناسبی جهت برآورد و مدل‌سازی باشند. در حال حاضر، شبکه‌های عصبی مصنوعی بیشترین کاربرد را در علوم مهندسی، از جمله مهندسی حوزه‌های آبخیز (به‌ویژه در زمینه هیدرولوژی) دارند (رضایی، ۲۰۰۴) و تحقیقات گسترده‌ای برای به‌کارگیری شبکه‌های

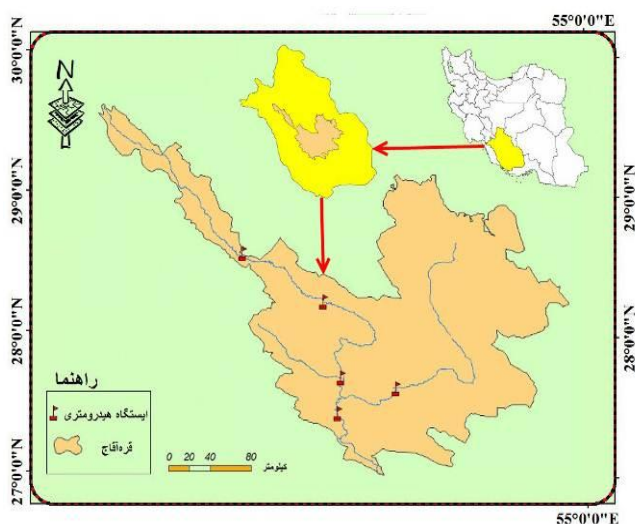
عصبی مصنوعی در حل مسائل هیدرولوژی کاربردی و مهندسی منابع آب صورت گرفته و علاقه‌مندی زیادی بین مهندسان برای به‌کارگیری آن وجود دارد (سالاس و همکاران، ۲۰۰۰).

شمس‌الدین<sup>۳</sup> (۱۹۹۷) برای پیش‌بینی رواناب، عملکرد مدل شبکه عصبی مصنوعی را با روش‌هایی مانند رگرسیون خطی، روش فصلی و نزدیک‌ترین همسایه مقایسه کرد و نتیجه گرفت که روش شبکه عصبی عملکرد بهتری در پیش‌بینی رواناب دارد. سیگیزقلو (۲۰۰۵) برای پیش‌بینی جریان روزانه رودخانه ارجن واقع در ترکیه، از شبکه عصبی پیشرو با روش پس‌انتشار خطا استفاده کرد و در نتایج خود مشاهده کرد که شبکه عصبی نسبت به سری‌های زمانی، نتایج بهتری را ارائه می‌دهد، ولی در برآورد مقادیر کم جریان ناموفق است. شاک<sup>۴</sup> (۲۰۰۷) به تفسیر داده‌ها برای پیش‌بینی جریان رودخانه هاوایی پرداخت و به این نتیجه رسید که مدل‌های (شبکه عصبی مصنوعی باید با داده‌های کافی و دقت زیادی استفاده شوند. در ایران نیز استفاده از شبکه عصبی در سال‌های اخیر افزایش چشمگیری داشته است. یزدانی و چاوشی (۲۰۰۵) با استفاده از شبکه عصبی مصنوعی، پیش‌بینی رفتار رودخانه پلاسجان را مورد ارزیابی قرار دادند. آن‌ها نشان دادند که کارایی این مدل در پیش‌بینی جریان نسبتاً خوب است و همچنین با افزایش تعداد لایه مخفی میزان خطا افزایش می‌یابد. نساجی زواره و همکاران (۲۰۰۷) با استفاده از شبکه عصبی مصنوعی دبی ماهانه حوزه آبخیز رودزرد را برآورد کردند. نتایج به‌دست‌آمده نشان‌دهنده قابلیت مناسب و دقت قابل قبول شبکه‌های عصبی در پیش‌بینی دبی ماهانه بود و همچنین قابلیت شبکه برای برآورد دبی حداکثر مناسب‌تر از دبی حداقل است. برهانی داریان و فاتحی مرچ (۲۰۰۸)، در حوزه آبخیز نازلوچای، کاربرد شبکه عصبی مصنوعی را در پیش‌بینی جریان رودخانه با استفاده از شاخص‌های اقلیمی مورد مطالعه قرار دادند و دریافتند که با به‌کارگیری شبکه عصبی و با استفاده از شاخص‌های اقلیمی یک سال قبل، می‌توان دبی یک سال بعد

2. Salas et al  
3. Shamseldin  
4. Sha

1. Tokar & Markus

قره‌آغاج یکی از دو شاخه مهم رودخانه مند و شاخه سرچشمه اصلی آن است که دارای حوزه آبخیز وسیعی می‌باشد. این رودخانه از مهم‌ترین رودخانه‌های استان فارس است. طول رودخانه تا محل ایستگاه تنگ کارزین ۳۲۳ کیلومتر و حوزه آبخیز آن تا محل سد سلمان فارسی منطقه‌ای به وسعت ۱۳۰۵۰ کیلومترمربع را شامل می‌شود. بستر این رودخانه، پرپیچ‌وخم و متشکل از آبرفت‌های دانه درشت است. آب رودخانه دائمی بوده و در زمستان و بهار پرآب است و به‌طور کلی می‌توان این رودخانه را یک رودخانه سیلابی به حساب آورد. این رودخانه در طول مسیر خود به نام‌های دیگری چون کوار، کارزین و بار نیز نامیده می‌شود (افشین، ۱۹۹۴). شکل (۱) موقعیت کلی حوزه آبخیز رودخانه قره‌آغاج را نشان می‌دهد.



شکل (۱): موقعیت منطقه مورد مطالعه در ایران و استان فارس

### مبانی و ساختار شبکه‌های عصبی

شبکه‌های عصبی مصنوعی تاریخ ۵۰ ساله دارند، اما کاربرد آن‌ها در مسائل علمی به یکی دو دهه گذشته برمی‌گردد و هم‌اکنون به سرعت در حال پیشرفت است. امروزه از این شبکه‌ها برای حل مسائل دشواری که حل آن‌ها با کامپیوترهای معمولی و انسان دشوار است، استفاده می‌کنند (کیا، ۲۰۰۸). شبکه‌های عصبی از عناصر عملیاتی ساده‌ای به‌صورت موازی ساخته می‌شوند. این عناصر از سیستم‌های عصبی زیستی الهام گرفته‌اند. هر شبکه عصبی مصنوعی معمولاً از سه لایه ورودی، میانی

را با دقت مناسبی پیش‌بینی کرد. اصغری‌مقدم و همکاران (۲۰۰۸) در تهیه مدل پیش‌بینی بارش دشت تبریز با استفاده از شبکه عصبی، الگوریتم یادگیری لونیبرگ - مارکوارت (LM) را بهترین الگوریتم معرفی کردند. ولی و همکاران (۲۰۱۱) در مطالعه‌ای کارایی مدل‌های شبکه‌های عصبی مصنوعی و رگرسیون را برای پیش‌بینی بار رسوب جریان در حوزه آبخیز سمنندگان مقایسه کردند و نتیجه گرفتند که شبکه عصبی ژئومورفولوژیکی در مقایسه با شبکه عصبی غیر ژئومورفولوژیکی، میزان رسوب جریان را بهتر پیش‌بینی می‌کند. همچنین نتایج آن‌ها نشان داد که مدل‌های رگرسیونی عملکرد ضعیف‌تری در مقایسه با روش شبکه عصبی مصنوعی دارند.

با توجه به مطالعاتی که تاکنون انجام شده است، مشاهده می‌شود که شبکه‌های عصبی مصنوعی می‌توانند یکی از موفق‌ترین سیستم‌های هوشمند محاسباتی باشند که توانایی کشف روابط پیچیده غیرخطی در پیش‌بینی جریان رودخانه را دارند. از این‌رو در این تحقیق سعی بر این است تا کارایی شبکه‌های عصبی در پیش‌بینی و شبیه‌سازی جریان رودخانه در حوزه آبخیز قره‌آغاج که جز اکوسیستم‌های بیابانی کشور است و همچنین توانایی الگوریتم یادگیری لونیبرگ - مارکوارت (LM) در آموزش شبکه‌های عصبی مورد بررسی و تأکید قرار گیرد.

### مواد و روش‌ها

#### منطقه مورد مطالعه


موقعیت منطقه مورد مطالعه در دامنه‌های شرقی سلسله جبال زاگرس و بین طول‌های ۴۷' - ۵۱° و ۱۴' - ۵۴° شمالی و عرض ۲۲' - ۲۸° تا ۵۴' - ۲۹° شرقی واقع شده است. وسعت حوزه آبخیز آن ۱۳۰۵۰ کیلومترمربع است و از شمال به حوزه آبخیز رودخانه کر و حوزه آبخیز دریاچه بختگان و مهارلو و از شرق به حوزه آبخیز رودخانه کل، از جنوب به حوزه آبخیز مند و از غرب به حوزه آبخیز شاپور و دالکی محدود می‌شود. ریزش‌های جوی در منطقه به جز در قسمت‌هایی از ارتفاعات غربی که به‌صورت برف می‌باشد، به‌صورت باران‌های با شدت زیاد نازل می‌شود (مهندسین مشاور پارساب، ۱۹۹۶). رودخانه

لایه‌های مخفی به روش آزمون و خطا و مقایسه عملکرد خطای آن‌ها انتخاب شده‌اند (ولی و همکاران، ۲۰۱۱).

### روش انجام تحقیق

برای مطالعه و بررسی و شبیه‌سازی جریان رودخانه با استفاده از شبکه عصبی مصنوعی حوزه آبریز قره‌آغاج در استان فارس که دارای ایستگاه‌های متعدد و آمار کافی است، انتخاب شد. آمار موجود از سازمان تماب، سازمان آب منطقه‌ای، سازمان هواشناسی و سازمان جهاد کشاورزی فارس اخذ شد و برای انتخاب دوره مشترک آماری با طول دوره مناسب، ۵ ایستگاه با دوره آماری ۲۳ ساله (۱۳۸۳-۱۳۶۰) شامل ایستگاه‌های بندبهن، علی‌آباد خفر، بابا عرب، براک و تنگ‌کارزین انتخاب شدند. سپس صحت و همگن بودن آمار مورد بررسی قرار گرفت و ایستگاه‌هایی که در یک یا چند سال دارای نواقص آماری بودند با استفاده از روش تفاضل‌ها و نسبت‌ها بازسازی شدند. جهت ساخت و اجرای مدل شبکه عصبی و شبیه‌سازی جریان رودخانه با توجه به پژوهش‌های انجام شده در ایران و جهان اقدام به نرمال‌سازی داده‌ها شد که به آن، پیش‌پردازش اطلاق می‌شود. پیش‌پردازش را می‌توان به‌عنوان هرگونه عملیات بر روی داده‌های خام که باعث افزایش کارایی شبکه در مدل‌سازی داده‌های ورودی و خروجی می‌شود، تفسیر کرد. در صورتی که داده‌ها به‌صورت خام وارد شبکه شوند، به‌علت تغییرات زیاد، داده‌ها تأثیر متفاوتی روی شبکه می‌گذارند و از سرعت و دقت آن می‌کاهد (اسفندیاری درآباد و همکاران، ۲۰۱۰). لذا در ابتدا لازم است که داده‌ها نرمال شوند، یعنی بین یک دامنه عددی که معمولاً (۰ و ۱) یا (۱- و ۱) می‌باشد، قرار گیرند. در این مطالعه با استفاده از رابطه پیشنهاد شده توسط ساجی‌کومار و همکاران (۱۹۹۹) داده‌ها در محدوده ۰/۱ تا ۰/۹ نرمال‌سازی شدند.

و خروجی تشکیل می‌شود (هملت و لتنمایر<sup>۱</sup>، ۱۹۹۹). لایه اول یا لایه ورودی شامل اندازه‌گیری‌ها یا بردار ورودی است و لایه آخر یا لایه خروجی مقادیری است که شبکه محاسبه می‌کند. در هر لایه، تعدادی گره یا سلول عصبی (نرون) وجود دارد. نرون مهم‌ترین عنصر پردازش در سیستم‌های زیستی است. در شبکه عصبی مصنوعی هر نرون زمانی فعال می‌شود که مجموع سیگنال‌های رسیده به بدنه آن از حد آستانه مشخصی تجاوز نماید. این گره‌ها از طریق وزن‌ها به گره‌های بعدی متصل می‌شوند. هر گره دو قسمت دارد که در قسمت اول آن مجموع حاصل ضرب مقادیر و وزن‌ها و در قسمت دوم تابع تحریک قرار دارد که این مقادیر از آن عبور و به لایه بعدی می‌روند. شکل (۲) تصویر کلی از یک شبکه عصبی مصنوعی چند لایه را نشان می‌دهد.



شکل (۲): ساختار کلی یک شبکه عصبی چند لایه

در شبکه‌های از نوع انتشار برگشتی، قاعده مشخصی برای انتخاب لایه‌های پنهان و همچنین تعداد نرون‌ها در لایه پنهان وجود ندارد. در حقیقت انتخاب تعداد نرون‌ها در لایه پنهان و همچنین تعداد لایه‌های پنهان با توجه به نوع مسئله تغییر می‌کند. در حل مسائل هیدرولوژی، با توجه به تغییر شدید داده‌ها، اغتشاش حاکم بر داده‌ها استفاده از شبکه‌های از نوع پس‌انتشار خطا به دلیل قابلیت انعطاف‌پذیری بالا با معماری منطبق بر تجربه و آزمون و خطا استفاده می‌شود. با توجه به عدم وجود ثبات در ایجاد و توسعه شبکه عصبی مصنوعی تجربیات موفق قبلی می‌تواند مفید واقع شود. تعداد لایه‌های مخفی و تعداد نرون‌های

$$x_n = \frac{0.8(x - x_{\min})}{(x_{\max} - x_{\min})} + 0.1 \quad (1)$$

در این رابطه،  $x$ : داده مشاهده‌ای،  $x_{\min}$  و  $x_{\max}$  به ترتیب کوچک‌ترین و بزرگ‌ترین داده موجود در سری و  $x_n$  داده نرمال‌شده (معیارسازی شده) است.

این دامنه عددی بستگی به نوع تابع محرک انتخابی برای شبکه خصوصاً مشتق‌پذیر بودن آن‌ها دارد که معمولاً از توابع سیگموئید می‌باشند. پس از بررسی پارامترهای موجود داده‌ها به دو دسته آموزش (۹۰ درصد) و تست (۱۰ درصد) تقسیم شدند. برای آموزش و تست داده‌ها از شبکه پرسپترون چند لایه یا به عبارتی شبکه‌های پیش‌خور (MLP) استفاده شد که از سه بخش لایه ورودی، لایه پنهان و یک لایه خروجی تشکیل شده است. یک لایه، گروهی از نرون‌ها (واحد پردازشگر) است که ارتباط بین ورودی و خروجی است. در این شبکه‌ها تعداد نرون‌های لایه ورودی برابر با تعداد عناصر بردار ورودی و تعداد نرون‌های لایه خروجی برابر با تعداد عناصر بردار خروجی است. تعیین تعداد نرون‌های لایه پنهان بسیار پیچیده است و عمدتاً به‌طور تجربی به دست می‌آید. در این شبکه‌ها ورودی مؤثر هر نرون، حاصل ضرب خروجی نرون‌های لایه قبل در وزن‌های میان آن نرون‌ها است. نرون‌های لایه اول اطلاعات را گرفته و از طریق اتصالات مربوطه به نرون‌های لایه مخفی منتقل می‌کنند. در لایه مخفی پس از محاسبه ورودی مؤثر هر نرون، این ورودی از یک تابع محرک گذرانده می‌شود. برای این کار توابع مختلفی ارائه شده که گرایش بیشتر محققان به استفاده از توابع محرک کران‌دار است که مشهورترین آن‌ها تابع سیگموئید می‌باشد. برای هماهنگی بین برد تابع محرک و خروجی شبکه، نیاز به نرمال‌سازی داده‌هاست که در بالا توضیح داده شد.

در این نوع از شبکه‌ها عموماً از قانون آموزش دلتا (روش پس‌انتشار خطا) استفاده می‌شود. به عبارتی، توپولوژی شبکه‌های پرسپترون چند لایه با قانون پس‌انتشار خطا تکمیل می‌شود (برهانی داریان و فاتحی مرج، ۲۰۰۸). از آنجا که در روش پس‌انتشار خطا نیاز به توابع محرک مشتق‌پذیر است، در

این شبکه بیشتر از توابع مشتق‌پذیری مانند تابع سیگموئید استفاده می‌شود (منه‌اج، ۲۰۰۵). ساختار شبکه که می‌توان آن را تحت عنوان معماری شبکه مطرح کرد، براساس انتخاب نوع شبکه، توابع آموزش و تعداد لایه‌ها همراه با تعداد نرون‌ها (گره‌ها) مشخص می‌شود. در واقع این معماری شبکه است که نحوه جریان داده‌های ورودی را برای رسیدن به خروجی مطلوب تعیین می‌کند. همچنین برای آموزش و تست داده‌ها از تکنیک‌های آموزش LM و GDx استفاده شد که داده‌های ایستگاه‌های مورد آزمون به ۵ صورت متفاوت و به صورت ۹ مدل به شرح زیر مورد بررسی قرار گرفت:

۱. پیش‌بینی دبی خروجی در ایستگاه تنگ کارزین با استفاده از داده‌های بارش و دما ایستگاه‌های بالادست و خروجی (مدل ۱ و ۲).
۲. پیش‌بینی دبی خروجی با استفاده از داده‌های بارش و دما ایستگاه‌های بالادست و خروجی و دبی خروجی با یک گام زمانی تأخیر (مدل ۳ و ۴).
۳. پیش‌بینی دبی خروجی با استفاده از داده‌های دبی ایستگاه خروجی تا دو گام زمانی تأخیر (مدل ۵ و ۶).
۴. پیش‌بینی دبی خروجی با استفاده از داده‌های بارش و دما ایستگاه بالادست و خروجی و دبی خروجی با یک و دو گام زمانی تأخیر (مدل ۷ و ۸).
۵. پیش‌بینی دبی خروجی با استفاده از داده‌های بارش تا یک گام زمانی تأخیر، دما و همچنین دبی خروجی با یک و دو گام زمانی تأخیر (مدل ۹).

### معیارهای ارزیابی

در این تحقیق در هر مرحله برای تعیین بهترین ساختار مدل و مقایسه مدل‌های مختلف از معیارهای معمول زیر استفاده شد.

الف. معیار ضریب همبستگی  $r$ : بدیهی است که هر چه مقدار آن به یک نزدیک‌تر باشد، نشان‌دهنده نزدیکی بیشتر مقادیر پیش‌بینی شده به مقادیر واقعی است (خلیلی و همکاران، ۲۰۰۶).

عصبی از شبکه MLP سه لایه با قانون پس انتشار خطا و تکنیک‌های یادگیری LM و Gdx، تعداد تکرار بین ۵۰۰ - ۲۵ و تعداد نرون ۲ تا ۳۰ پیش‌بینی جریان خروجی حوزه به ۵ صورت متفاوت مورد بررسی قرار گرفت. برای انتخاب بهترین معماری شبکه از بین ۹ مدل مورد آزمون با توجه به نتایج حاصل از معماری بهینه هریک از مدل‌ها که در جداول (۱) و (۲) ذکر شده است و همچنین با بررسی و تجزیه و تحلیل آن‌ها، مدلی که از ضریب همبستگی (R) بالاتر و مقادیر MSE، RMSE و MAE کمتری برخوردار بود، به‌عنوان برترین معماری شبکه جهت شبیه‌سازی جریان رودخانه برگزیده شد. در حالت استفاده از تابع LM برترین معماری شبکه به صورت ۱-۲۱-۹ با ۹ ورودی و ۲۱ نرون در لایه میانی (مدل ۴) انتخاب شد که مقادیر ضریب همبستگی، MSE، RMSE و MAE آن به ترتیب برای داده‌های آموزش مقادیر ۱، ۰/۷۳، ۰/۸۵ و ۰/۰۶۱ و برای داده‌های تست مقادیر ۱، ۰/۵۷، ۰/۷۶ و ۰/۰۰۳ است. در حالت استفاده از تابع Gdx نیز برترین معماری شبکه به صورت ۱-۱۳-۷ با ۷ ورودی و ۱۳ نرون در لایه میانی (مدل ۷) انتخاب شد که مقادیر ضریب همبستگی، MSE، RMSE و MAE آن به ترتیب برای داده‌های آموزش مقادیر ۰/۹۴، ۰/۴۱، ۰/۶۲، ۰/۲۱ و ۰/۹۰ و برای داده‌های تست مقادیر ۰/۹۶، ۰/۶۹، ۰/۴۵ و ۰/۰۷۶ است. دیاگرام پراکنش و هیدروگراف داده‌های آموزش و تست مدل نهایی برای تابع LM و Gdx در اشکال (۳) تا (۶) نشان داده شده است.

$$r = \frac{\sum_{i=1}^n (p_i - \bar{p})(o_i - \bar{o})}{\sum_{i=1}^n (p_i - \bar{p}) \sum_{i=1}^n (o_i - \bar{o})} \quad (2)$$

ب. معیار خطای RMSE: جذر میانگین مربعات خطاست و هر مدل که کمترین مقدار RMSE را داشته باشد، به‌عنوان بهترین مدل انتخاب می‌شود.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (o_i - p_i)^2}{n}} \quad (3)$$

ج. معیار خطای MAE

$$MAE = \frac{1}{n} \sum_{i=1}^n |o_i - p_i| \quad (4)$$

د. معیار ارزیابی MSE

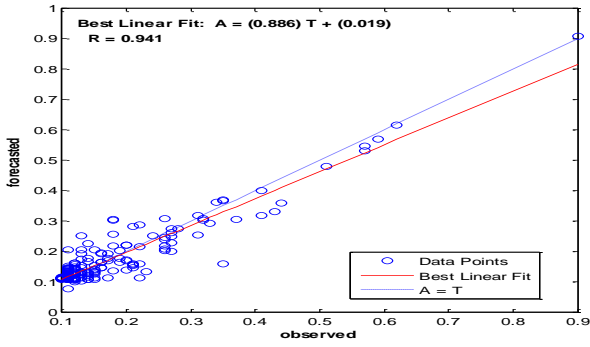
$$MSE = \frac{\sum_{i=1}^n (o_i - p_i)^2}{n} \quad (5)$$

در روابط فوق،  $\bar{o}$  میانگین جریان مشاهده‌ای و  $\bar{p}$  میانگین جریان محاسبه‌شده توسط شبکه،  $o_i$  مقادیر جریان مشاهده‌ای و  $p_i$  مقادیر جریان محاسبه‌شده و  $n$  برابر با تعداد داده‌هاست.


## نتایج

در شبکه‌های عصبی ساختار شبکه شامل تعداد لایه‌های مخفی، تعداد نرون‌های هریک از لایه‌های مخفی، نوع تابع فعال‌سازی و ورودی مدل‌های مورد بررسی که بر روی خروجی مدل تأثیرگذار هستند، باید تعیین گردند و معماری بهینه شبکه با روش سعی و خطا و انجام آزمون‌های مختلف و مقایسه نتایج با استفاده از معیارهای ارزیابی انتخاب می‌شود و شبکه‌ای که کمترین میزان خطا و بیشترین ضریب همبستگی را در بین مدل‌های مورد بررسی دارد، به‌عنوان معماری بهینه انتخاب می‌شود.

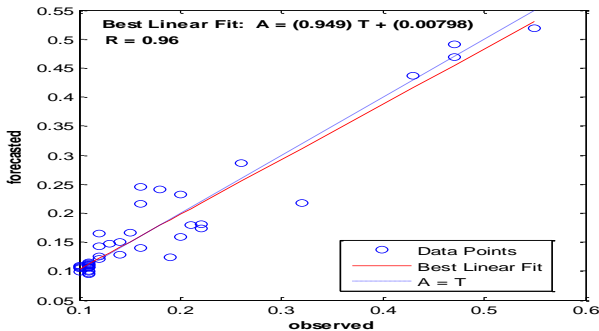
در این مطالعه، به‌منظور بررسی تأثیر پارامترهای هواشناسی بر روی دبی جریان و شبیه‌سازی جریان رودخانه توسط شبکه



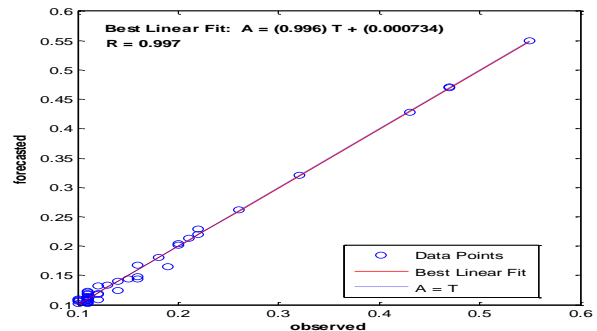
(الف)



(الف)






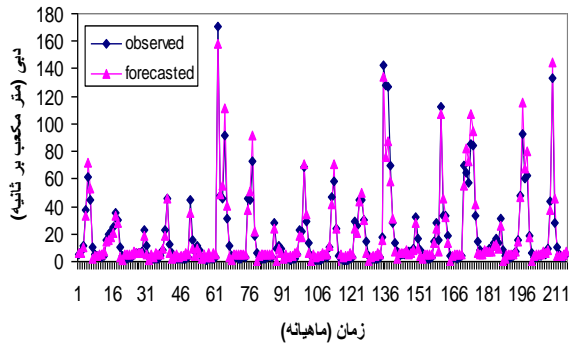
(ب)



(ب)

شکل (۵): دیاگرام‌های پراکنش مربوط به پیش بینی شبکه در مدل بهینه به ترتیب برای داده‌های آموزش و تست با تابع یادگیری Gdx. (الف) و (ب)

شکل (۳): دیاگرام‌های پراکنش مربوط به پیش بینی شبکه در مدل بهینه به ترتیب برای داده‌های آموزش و تست با تابع یادگیری LM. (الف) و (ب)



شکل (۶): هیدروگراف‌های پیش بینی شبکه به ترتیب برای داده‌های آموزش و تست در مدل بهینه با تابع یادگیری Gdx

شکل (۴): هیدروگراف‌های پیش بینی شبکه به ترتیب برای داده‌های آموزش و تست در مدل بهینه با تابع یادگیری LM



جدول (۱): برترین شبکه آموزش دیده هریک از مدل‌های مورد آزمون با تابع یادگیری (LM)

| تعداد نرون هر لایه |       |       |       | معیار MSE |       | معیار RMSE |      | معیار MAE |       | ضریب همبستگی R |      |
|--------------------|-------|-------|-------|-----------|-------|------------|------|-----------|-------|----------------|------|
| مدل                | ورودی | میانی | خروجی | معیار MSE |       | معیار RMSE |      | معیار MAE |       | ضریب همبستگی R |      |
|                    |       |       |       | آموزش     | تست   | آموزش      | تست  | آموزش     | تست   | آموزش          | تست  |
| اول                | ۵     | ۲۳    | ۱     | ۱۶/۷۴     | ۱۳/۸۸ | ۴/۱۰۹      | ۳/۷۳ | ۰/۰۵      | ۰/۰۰۲ | ۰/۹۸           | ۰/۹۸ |
| دوم                | ۸     | ۱۱    | ۱     | ۱۱/۵۳     | ۰/۵۸  | ۳/۴        | ۰/۷۶ | ۰/۰۶      | ۰/۰۰۴ | ۰/۹۸           | ۰/۹۷ |
| سوم                | ۶     | ۵     | ۱     | ۳۴/۷۶     | ۱/۸۸  | ۵/۹        | ۱/۳۷ | ۰/۰۲      | ۰/۰۰۵ | ۰/۹۶           | ۱    |
| چهارم              | ۹     | ۲۱    | ۱     | ۰/۷۳      | ۰/۵۷  | ۰/۸۵       | ۰/۷۶ | ۰/۰۶۱     | ۰/۰۰۳ | ۱              | ۱    |
| پنجم               | ۲     | ۲     | ۱     | ۰/۷۱      | ۰/۶۷  | ۰/۸۴       | ۰/۸۲ | ۰/۱       | ۰/۰۰۴ | ۰/۹۹           | ۰/۹۹ |
| ششم                | ۳     | ۲     | ۱     | ۰/۷۱      | ۰/۶۹  | ۰/۸۴       | ۰/۸۳ | ۰/۰۶      | ۰/۰۰۴ | ۰/۹۹           | ۰/۹۹ |
| هفتم               | ۷     | ۲۵    | ۱     | ۱۳/۴۵     | ۰/۷۵  | ۳/۶۷       | ۰/۸۷ | ۰/۰۳۲     | ۰/۰۴۶ | ۰/۹۸           | ۱    |
| هشتم               | ۱۰    | ۱۷    | ۱     | ۱۸/۰۴     | ۰/۶۷  | ۴/۲۵       | ۰/۸۲ | ۰/۱۴۳     | ۰/۰۷  | ۰/۹۸           | ۱    |
| نهم                | ۱۵    | ۲۷    | ۱     | ۰/۸۴      | ۰/۸۵  | ۰/۹۲       | ۰/۹۲ | ۰/۱۶۸     | ۰/۰۶۶ | ۱              | ۱    |

جدول (۲): برترین شبکه آموزش دیده هریک از مدل‌های مورد آزمون با تابع یادگیری (Gdx)

| تعداد نرون هر لایه |       |       |       | معیار MSE |        | معیار RMSE |       | معیار MAE |       | ضریب همبستگی R |      |
|--------------------|-------|-------|-------|-----------|--------|------------|-------|-----------|-------|----------------|------|
| مدل                | ورودی | میانی | خروجی | معیار MSE |        | معیار RMSE |       | معیار MAE |       | ضریب همبستگی R |      |
|                    |       |       |       | آموزش     | تست    | آموزش      | تست   | آموزش     | تست   | آموزش          | تست  |
| اول                | ۵     | ۱۶    | ۱     | ۲۵۷/۴۶    | ۷۵/۷   | ۱۶/۰۵      | ۸/۷   | ۰/۰۲۳     | ۰/۰۰۹ | ۰/۷۰           | ۰/۹۱ |
| دوم                | ۸     | ۱۱    | ۱     | ۳۰۱/۳۴    | ۱۱۳/۸۶ | ۱۷/۳۶      | ۱۰/۶۷ | ۰/۴۶      | ۰/۰۱۹ | ۰/۶۴           | ۰/۸۶ |
| سوم                | ۶     | ۹     | ۱     | ۱۴۲/۰۶    | ۴۴/۶۷  | ۱۱/۹۲      | ۶/۶۸  | ۰/۱۴۲     | ۰/۰۴۱ | ۰/۸۳           | ۰/۹۵ |
| چهارم              | ۹     | ۱۳    | ۱     | ۲۳۳/۴     | ۴۰/۱۲  | ۱۵/۲۸      | ۶/۳۳  | ۰/۰۲۲     | ۰/۰۴۴ | ۰/۷۳           | ۰/۹۵ |
| پنجم               | ۲     | ۳     | ۱     | ۶۷/۸۵     | ۳۱/۳۳  | ۸/۲۴       | ۵/۶   | ۰/۱۱      | ۰/۴۴  | ۰/۹۲           | ۰/۹۶ |
| ششم                | ۳     | ۱۹    | ۱     | ۸۱/۵۲     | ۴۰/۱۲  | ۹/۰۳       | ۶/۳۳  | ۰/۰۷      | ۰/۲۶  | ۰/۹۱           | ۰/۹۵ |
| هفتم               | ۷     | ۱۳    | ۱     | ۶۲/۴۱     | ۲۹/۶۹  | ۷/۹۰       | ۵/۴۵  | ۰/۰۲۱     | ۰/۰۷۶ | ۰/۹۴           | ۰/۹۶ |
| هشتم               | ۱۰    | ۱۵    | ۱     | ۱۶۶/۲۴    | ۳۱/۳   | ۱۲/۸۹      | ۵/۶   | ۰/۰۵      | ۱/۰۷  | ۰/۸۱           | ۰/۹۶ |
| نهم                | ۱۵    | ۵     | ۱     | ۱۸۸/۵     | ۴۱/۶۳  | ۱۳/۷۳      | ۶/۴۵  | ۰/۰۶      | ۰/۰۵۷ | ۰/۷۸           | ۰/۹۵ |



## بحث و نتیجه‌گیری

در این تحقیق تأثیر پارامترهای هواشناسی مانند دما و بارش بر روی جریان رودخانه در حوزه آبخیز قره‌آغاج مورد بررسی قرار گرفت. به منظور بررسی عملکرد و توانایی شبکه‌های عصبی در مدل کردن سیستم‌های پیچیده غیرخطی، اقدام به شبیه‌سازی جریان رودخانه گردید و سعی شد با انتخاب مدل‌های مختلف و تعداد پارامترهای ورودی متغیر، تعداد لایه، توابع محرک، و توابع یادگیری، مدلی مناسب انتخاب شود.

در این نوع شبکه‌های عصبی از تابع محرک تانژانت سیگموئید در لایه میانی و تابع خطی در لایه خروجی استفاده شد که بهترین معماری شبکه برای هر دو نوع تابع در شکل (۷) نشان داده شده است.

نرمال‌سازی داده‌های ورودی و خروجی نقش مؤثری در افزایش دقت پیش‌بینی مدل داشته است. همچنین با افزایش تعداد ورودی‌ها در مدل‌های مورد بررسی برای دستیابی به مدل بهینه، نیاز به تعداد نرون‌های بیشتری در لایه میانی می‌باشد و در مدل‌هایی که فقط از مقادیر دبی برای ورودی استفاده شد، شبکه با تعداد نرون کمتری در لایه میانی به پاسخ مطلوب دست یافت.

نتایج حاصل از مدل بهینه بیانگر تأثیر پارامترهای هواشناسی مانند دما و بارش بر روی جریان رودخانه‌ای است، به طوری که اکثر بارش‌ها در فصل زمستان و پاییز که دمای ماهانه کمتر است، اتفاق می‌افتند تا در فصل تابستان که دمای ماهانه افزایش می‌یابد. عملکرد شبکه در حالتی که از پارامترهای هواشناسی و هیدرومتری با تأخیر زمانی استفاده شد، بهتر گردید که با نتایج درواری (۲۰۰۷)، فتح‌آبادی (۲۰۰۷)، اسکندری‌نیا (۲۰۰۶)، طارقیان و همکاران (۲۰۰۶) و سیگیزوگلو و آلپ (۲۰۰۶) همخوانی دارد.

شبکه عصبی با ساختار ۱-۲۱-۹ و تابع یادگیری LM و شبکه عصبی با ساختار ۱-۱۳-۷ با تابع یادگیری Gdx بهترین آرایش را به خود اختصاص داده و به عنوان مدل بهینه معرفی شدند. در این تحقیق، استفاده از تابع یادگیری LM کارایی بهتری را نشان داد، به طوری که دبی‌های شبیه‌سازی شده ایستگاه خروجی با روش‌های شبکه عصبی خصوصاً تابع یادگیری LM با داده‌های مشاهداتی ثبت شده دارای اختلاف بسیار ناچیزی بوده که مقادیر MSE، RMSE و ضریب همبستگی حاصل بین دبی‌های شبیه‌سازی شده و مشاهداتی بیانگر مطلب فوق است که با نتایج درواری (۲۰۰۷)، فتح‌آبادی (۲۰۰۷)، کاظمی‌کیا (۲۰۰۶)، احمد و سیمونوویک (۲۰۰۰)، الشوبای و همکاران (۲۰۰۰)، دیبیک و سولوماتین (۲۰۰۱) و سیگیزوگلو (۲۰۰۵) همخوانی دارد. مقادیر ضریب همبستگی و MSE در حالت استفاده از تابع Gdx حتی با افزایش تعداد نرون‌ها و تعداد تکرارها تغییر چندانی نکرده‌اند، درحالی‌که با استفاده از تابع LM بسیار خوب بهبود یافته‌اند. در رابطه با اهمیت الگوریتم LM در آموزش شبکه عصبی، باید اضافه شود که این الگوریتم از سال ۱۹۹۳ تا به امروز به‌عنوان سریع‌ترین روش آموزش شبکه‌های عصبی شناخته شده است (اصلاح، ۲۰۰۴) و احتمالاً مؤثرترین روش از مجموعه روش‌های مبتنی بر شیب می‌باشد (Adamowski and Karapataki, 2010). در مطالعه‌ای که به مقایسه این الگوریتم یادگیری مبتنی بر شیب با ۸ روش از مجموعه روش‌های EC (Evolutionary Computation) انجام شد، برتری کامل روش LM بر آن‌ها اثبات شده است (Adam and Jaroslaw, 2011). در نتایج این تحقیق نیز می‌توان همانند مطالعات فوق‌الذکر، کارایی مطلوب این روش را مشاهده کرد.

با توجه به نتایج این تحقیق و تجارب قبلی به نظر می‌رسد که انجام شبیه‌سازی جریان به‌صورت روزانه، ماهانه،

مدل هاست. همچنین استفاده از روش شبکه عصبی مصنوعی پرسپترون چندلایه به عنوان روشی غیرخطی در پیش‌بینی جریان رودخانه با توجه به تعیین خطای آموزشی می‌تواند به عنوان گزینه‌ای سودمند مورد توجه و بررسی قرار گیرد که طبیعتاً با گذشت زمان در سال‌های آتی و افزایش اطلاعات در دسترس، دقت این روش نیز افزایش یافته و برای پیش‌بینی‌های فصلی، سالانه و بلندمدت نیز کاربرد خواهد داشت که از نتایج آن می‌توان در بهره‌برداری از منابع آب، مطالعات زیست‌محیطی، تغییر اقلیم، خشکسالی و... استفاده کرد.

فصلی و سالانه و مقایسه نتایج آن‌ها با استفاده از روش‌های غیرپارامتری مانند نزدیک‌ترین همسایه (KNN) و برآورد هسته چگال و روش‌های هوش مصنوعی یکدیگر می‌تواند مدل بهتر را ارائه کند. در نهایت با توجه به نتایج تحقیق و ارزیابی مدل می‌توان اظهار داشت که مدل شبکه عصبی مصنوعی، مدل قدرتمندی با توانمندی بالاست که می‌توان با دیدگاهی مثبت در پیش‌بینی مسائل هیدرولوژیکی به آن توجه کرد. به خصوص آنجا که این شبکه قادر است قانون حاکم بر داده‌های مغشوش را استخراج کند و این خصوصیت، برجسته‌ترین ویژگی این مدل در مقایسه با سایر

## منابع

- Adamowski, J., Karapataki, C., 2010. Comparison of multivariate regression and artificial neural networks for peak urban water-demand forecasting: evaluation of different ANN learning algorithms. *Journal of Hydrologic Engineering* 15 (10), 729–743.
- Adam, P. P. and Jaroslaw, J. N. 2011. Optimizing neural networks for river flow forecasting- Evolutionary Computation methods versus the Levenberg-Marquardt approach. *Journal of Hydrology*, 407: 12-27pp.
- Afshin, Y. 1994. Rivers of Iran, Ministry of Energy, engineering Advisory Company of JAMAB. 383p.
- Ahmad, S. and Simonovic, S. P. 2000. Developing runoff hydrograph using artificial neural networks. University of western Ontario Canada. 17 pp.
- Asghari Moghadam, A., Noorani, V., Nadiri, A. 2008. Modeling rainfall in Tabriz plain using neural network, *Journal of Agricultural of Tabriz University*. 18 (1), 1-15pp.
- Borhani Darian, A., Fatehi Marj, A. 2008. Application of artificial neural network to predict river flow using climate indicators, Case Study: Nazlouchay Basin, 35 (3), 9-20 pp.
- Cigizoglu, H. K. 2005. Application of the Generalized regression neural network to Intermittent Flow forecasting and estimation. *Journal of Hydrologic engng. ASCE* 10(4): 336-341 pp.
- Cigizoglu, H. K., and Alp, M. 2006. Generalized regression neural network in modeling river sediment yield. *Journal of Advances in engineering software*. 37: 63-68 pp.
- Darvari, S. Z. 2007. Simulation of river flow using neural network (case study: Kasilian Basin), Master's thesis, University of Mazandaran, faculty of Natural Resources and agricultural sciences, 142 p.
- Dibike, Y. B. and Solomatine, D. P. 2001. River flow forecasting using artificial neural networks. *Physics and Chemistry of the Earth*. 26(1): 1-7 pp.
- Elshobagy, A., Simonovic, S. P. and Paun, U. S. 2000. Performance Evaluation of artificial networks for Runoff Prediction. *Journal of Hydroligy engineering*. Vol 5. No 4. 131-134 pp.
- Engineering Advisory company of PARSAB, 1996. Studies to identify watershed

- management in Salman Farsi Dam Basin (Ghir), Vol 3, Hydrology and Flood, Ministry of Jihad – Assistance of Watershed management, 91 p.
13. Esfandiari dor abad, F., Hoseyni, S. A., Azadi Mobaraki, M., Hajazi Zadeh, Z. 2010. Forecasting mean monthly temperature in Sanandaj synoptic station using MLP neural network model, *Journal of Geographical Society of Iran*, 8 (27), 45-65pp.
  14. Eskandarinia, A. 2006. Simulation of rainfall-runoff process using artificial neural networks and Comparison with nearest neighbor model, Master's thesis, University of Mazandaran, faculty of Natural Resources and agricultural sciences, 118p.
  15. Eslah, P. 2004. Analysis of return in SASW test using neural Network, Master's thesis of Civil Engineering, Faculty of Technical, Orumieh University.
  16. Fath Abadi, A. 2007. Prediction river flow using Neuro-fuzzy and time series methods (case study: River of Tehran Province), Master's thesis, College of Natural Resources of Tehran University, 127 p.
  17. Hamlet, A. F. and P. L. Lettenmaier, 1999. Columbia River Streamflow Forecasting Based on ENSO and PDO Climate Signals. *ASCE, J. Water Reso. Plan. Manag.* 125(6):333-341
  18. Kazemikia, S. 2006. Prediction of river flow using neural network (case study: Barandoozchay basin), Master's thesis, Mazandaran University, College of Natural Resources of Sari, 120p.
  19. Khalili, N., Khodashenas, S., Davari, K. 2006. Prediction of rainfall using neural network, The Second conference on water resources management.
  20. Kia, M. 2008. Neural network in MATLAB, Publishing of green computer Kian, 229 p.
  21. Menhaj, M. P. 2005. Principles of neural networks, Press of Amirkabir University, 502 p.
  22. Nassaji Zavvareh, M., Safi Samgh Abadi, A. 2007. Prediction of monthly runoff using neural networks, Third Congress of Civil Engineering, University of Tabriz.
  23. Rezaei, A. 2004. Regional modeling of peak flow in sub-watershed of Sefidrood Dam Basin using neural network, PhD thesis of Watershed management, College of Natural Resources of Tehran University, 141p.
  24. Sajikumar N and Thandaveswara BS, 1999. A non linear rainfall- runoff modeling using an artificial network. *J Hydrology* 36:32-35
  25. Salas, G. D. Markus, M. and Tokar, A. S. 2000. Stream flow forecasting based on artificial neural network. *Artificial neural network in Hydrology*. R.S. Govindaraju, A. Ramachandra raoeds. Published by Kluwer Academic: 23-52 pp.
  26. Shamseldin, A. Y. 1997. Application of neural network technique to rainfall-Runoff modeling. *Journal of Hydrology*. 199(10): 272-294 pp.
  27. Sha, W. 2007. Comment on "Flow forecasting for a Hawaii stream using rating curves and neural networks" by G.B. Sahoo and C. Ray. *Journal of Hydrology*. 340: 119-121 pp.
  28. Tareghian, R., Kashefipour, S. M., Taheri, M. 2006. Prediction of river flow using neural network (case study: Karoon River, Pol Shaloo), The first regional conference of optimum utilization of water resources of the basin of Karoon and Zayandehrud, University of Shahrekord, 944-952 pp.
  29. Tokar, A.S. and Markus, M. 2000. Precipitation runoff modelling using artificial neural network. *Journal of Hydrologic engrg.* 5 (2): 156-161 pp.
  30. Vali, A. A., Ramesht, M. H., Seyf. A., Ghazavi, R. 2011. Comparison of efficiency of neural networks models and regression method to predict flow sediment (case study: Samandagan Basin), *Journal of Geography and Planning of Environmental*, 22 (4), 19-34 pp.
  31. Yazdani, M. R., Chavoshi, S. 2005. Prediction of river flow using neural network, Fifth hydraulic Conference, University of

Shahid Bahonar of Kerman, 911-918 pp.

32. Ziaei, H. 2001. Principles of Watershed Management Engineering - Press of Astan Qods Razavi, Emam Reza in Mashad, 542p.