

## ارزیابی مدل‌های شبکه و الگوریتم حسابداری رطوبت خاک مدل HEC-HMS در شبیه‌سازی پیوسته نیمه توزیعی بارش - رواناب در حوضه آبریز جراحی

نوید آذرپیشه<sup>۱</sup>، علیرضا نیکبخت‌شهبازی<sup>۱\*</sup>، حسین فتحیان<sup>۱</sup>

<sup>۱</sup> گروه مهندسی منابع آب، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران.

\*نویسنده مسئول: ar\_nikbakht@yahoo.com

تاریخ پذیرش: ۱۴۰۰/۰۹/۱۵

تاریخ دریافت: ۱۳۹۹/۰۷/۲۸

### چکیده

برآورد صحیح رواناب در بهره‌برداری منابع آب برای بخش‌های مختلف کشاورزی، شرب، برقایی و زیست محیطی موثر است. در این مقاله به شبیه‌سازی پیوسته بارش - رواناب در حوضه جراحی با دو مدل مختلف شامل مدل مفهومی HEC-HMS و مدل بر مبنای پردازش داده‌ها (شبکه‌های عصبی مصنوعی) پرداخته می‌شود تا توانایی و دقت این دو مدل در برآورد رواناب نیز ارزیابی گردد. جهت شبیه‌سازی پیوسته جریان از مدل تلفات احتساب‌کننده رطوبت خاک (SMA) در زیرحوضه‌ها استفاده گردید. برای واسنجی مدل از آمار روزانه بارش، دبی جریان و تبخیر از سال ۱۳۸۰ تا ۱۳۸۶ و برای صحت‌سنجی مدل از سال ۱۳۸۷ تا ۱۳۹۰ استفاده شد. نتایج نشان داد که مدل HEC-HMS به همراه مدل تلفات SMA از قابلیت خوبی در شبیه‌سازی پیوسته بارش - رواناب در فصول خشک و تر متوالی در حوضه جراحی برخوردار می‌باشد. برای انتخاب متغیرهای ورودی موثر بر دبی جریان در شبکه‌های عصبی مصنوعی شامل شبکه پیشخور تعمیم‌یافته (GFF) و شبکه تابع پایه شعاعی (RBF) از الگوریتم اطلاعات متقابل جزئی (PMI) استفاده شد. نتایج بکارگیری الگوریتم PMI نشان می‌دهد که متغیر ورودی موثر بر دبی جریان در ایستگاه هیدرومتری گرگر، دبی جریان یک روز قبل در این ایستگاه می‌باشد. نتایج نشان می‌دهد که شبکه GFF از راندمان و دقت بیشتری نسبت به مدل مفهومی HEC-HMS و شبکه RBF در شبیه‌سازی پیوسته بارش - رواناب در حوضه جراحی برخوردار است؛ بطوری که ضریب ناش - ساتکلایف برای مدل HEC-HMS و شبکه GFF و RBF به ترتیب ۰/۶، ۰/۶۷۷ و ۰/۶۷۶ است.

کلید واژه‌ها: الگوریتم PMI، ایستگاه گرگر، آزمون همپل، ضریب ناش - ساتکلایف.

## مقدمه

برآورد دقیق رواناب می‌تواند کمک شایانی به بخش‌های مختلف مهندسی آب مانند طراحی سیل‌گیرها برای محافظت مناطق شهری و کشاورزی، بهره‌برداری صحیح از منابع آب برای بخش‌های مختلف کشاورزی، شرب، برقایی و زیست محیطی نماید. به طور کلی دو روش عمده برای مدل‌سازی فرآیند بارش- رواناب وجود دارد. روش اول، مدل‌سازی مبتنی بر دانش و روش دوم مبتنی بر داده می‌باشد. روش‌های دانش محور به عنوان رویکردهای مدل‌سازی مبتنی بر خصوصیات و قوانین فیزیکی حاکم بر حوضه نیز شناخته می‌شوند. مدل فیزیکی در برگزیده تعداد زیادی از پارامترها و متغیرهای مشاهداتی است که می‌بایست یک فرآیند هیدرولوژیکی پیچیده را توصیف نماید. در این روش از یک چهارچوب ریاضی بر اساس خصوصیات حوضه مانند شدت و مدت بارش، اندازه، شکل، شیب و خصوصیات ذخیره‌ای حوضه، توپوگرافی، کاربری اراضی، نوع خاک و گیاه و خصوصیات اقلیمی حوضه برای مدل‌سازی فرآیند بارش- رواناب استفاده می‌شود. علاوه بر خصوصیات فوق، شرایط اولیه متغیرها و شرایط مرزی نیز می‌بایست توسط معادلات دیفرانسیل مشخص شده باشند. در اکثر مناطق و به ویژه در کشورهای در حال توسعه یا چنین اطلاعاتی وجود ندارند یا به دست آوردن آنها بسیار مشکل است. پایه و اساس روش‌های داده محور برای مدل‌سازی فرآیندهای هیدرولوژیکی، استفاده و استخراج اطلاعاتی است که به صورت ضمنی درون داده‌های هیدرولوژیکی وجود دارند بدون اینکه هیچ اطلاعات دقیقی از خصوصیات و قوانین فیزیکی حاکم وجود داشته باشد. توسعه و کاربرد روش‌های داده محور در مدل‌سازی فرآیند بارش- رواناب در چند دهه اخیر گسترش فزاینده‌ای داشته است. اگرچه مدل‌سازی با روش‌های داده محور ممکن است توانایی کافی برای تفسیر فرآیندهای فیزیکی درون حوضه را نداشته باشند اما بطور صحیح و دقیقی می‌توانند رواناب خروجی حوضه را تخمین بزنند (Solomatine and Ostfeld, 2008). گسترش و توسعه روزافزون علوم کامپیوتری (سخت‌افزاری و نرم‌افزاری) و در دسترس بودن داده‌های بیشتر و دقیقتر باعث ارتقاء کمی و کیفی رویکردهای مدل‌سازی داده محور برای شناسایی الگوهای موجود در سری‌های زمانی فرآیندهای هیدرولوژیکی شده است. از اجزای اصلی روش‌های داده محور که در چند دهه اخیر کاربردهای زیادی در مدل‌سازی سیستم‌های غیرخطی داشته است می‌توان به شبکه‌های عصبی مصنوعی اشاره کرد. Araghinejad و Karamouz (۲۰۰۵) با استفاده از مفهوم تولید مجموعه‌ای از پیش‌بینی‌ها (ESP) و تفکیک مدل‌سازی برای متغیرهای اقلیمی و هیدرولوژیکی، از مدل‌های مفهومی برای پیش‌بینی بلندمدت حجم جریان رودخانه زاینده‌رود در محل ورودی به سد زاینده‌رود استفاده کردند. نتایج این مدل با یک مدل پیش‌بینی ماهانه بر مبنای شبکه‌های عصبی که با استفاده از اطلاعات مشاهده شده، جریان ماهانه را پیش‌بینی می‌کند، مقایسه شد. نتایج نشان داد که رویکرد ارائه شده علاوه بر دقت قابل قبول در پیش‌بینی نقطه‌ای و بلند مدت جریان، امکان پیش‌بینی به صورت مجموعه‌ای از جریان‌های ممکن را نیز فراهم می‌آورد. دستورانی و همکاران (۱۳۹۰) کارایی شبکه عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی به منظور برآورد بارش- رواناب در حوضه سد زاینده‌رود را مورد ارزیابی قرار دادند. نتایج نشان

داد که شبکه عصبی مصنوعی و سیستم فازی- عصبی در شرایط مختلف و با ترکیب‌های مختلف پارامترهای ورودی، نتایج متفاوتی از خود نشان می‌دهند، ولی در کل این دو روش به میزان قابل قبولی قادر به تخمین رواناب حاصل از بارش با به‌کارگیری پارامترهای ورودی مناسب و استفاده از ساختارهای مناسب شبکه عصبی مصنوعی و شبکه عصبی- فازی هستند.

Ghafari و Vafakhah (۲۰۱۳) با استفاده از شبکه‌های عصبی مصنوعی و فازی عصبی تطبیقی، اقدام به شبیه‌سازی فرآیند بارش- رواناب روزانه، در حوضه آبخیز حاجی قوشان نمودند. در این سیستم‌ها سه ترکیب مختلف ورودی شامل بارندگی همان روز، بارندگی همان روز و روز قبل، بارندگی همان روز و روز قبل و دو روز قبل از آن، مورد استفاده قرار گرفت. بر اساس نتایج ایشان، مدل ANFIS نسبت به مدل ANN فرآیند بارش- رواناب را با دقت بالاتری پیش‌بینی نمود. دهقانی و همکاران (۱۳۸۹) جریان روزانه در حوضه آبخیز کسلیان را با استفاده از شبکه عصبی مصنوعی و شبکه عصبی- فازی تطبیقی شبیه‌سازی نمودند. در این تحقیق از آمار بارش، تبخیر و دما ایستگاه هواشناسی سنگده که ورودی مدل و آمار دبی ایستگاه ولیکین که خروجی مدل محسوب می‌شود طی سال‌های ۱۳۸۲ تا ۱۳۸۸ استفاده شد. تعداد تأخیرهای لازم دو مدل ساختار بارش و تبخیر با یک روز تأخیر برای مدل بهینه انتخاب شد. سپس نتایج با استفاده از نمایه‌های RMSE، برای ورود متغیرهای ورودی به شبکه‌ها با استفاده از نمودار خودهمبستگی جزئی به دست آمد. نتایج نشان داد که شبکه عصبی- فازی تطبیقی با تابع زنگوله‌ای شکل نسبت به مدل شبکه عصبی مصنوعی با همان ساختار با الگوریتم آموزشی در دوره آزمون توانایی بهتری برای مدل‌سازی بارش- رواناب در حوضه آبخیز کسلیان دارد. Miguélez و همکاران (۲۰۰۹) با استفاده از شبکه‌های عصبی مصنوعی در ترکیب با الگوریتم ژنتیک، رواناب شهری را پیش‌بینی نمودند. در این مطالعه از تکنیک هوش مصنوعی برای مدل‌سازی بارش و تولید رواناب سطحی برای یک منطقه شهری استفاده شده است. نتایج کار آنها نشان داد که مدل‌سازی رواناب با استفاده از شبکه‌های عصبی مصنوعی و با مدل پیشخور نتایج رضایت‌بخشی داشته است. حقی‌زاده و همکاران (۱۳۹۴) با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه و مدل فازی عصبی تطبیقی و روش رگرسیون چندمتغیره، فرآیند بارش- رواناب را به صورت روزانه در حوضه آبخیز خرم‌آباد شبیه‌سازی نمودند. برای ورودی‌ها از ترکیب‌های مختلف از ورودی‌های بارندگی همان روز، یک روز قبل و دو روز قبل استفاده شد. نتایج نشان داد که مدل عصبی فازی تطبیقی عملکرد بهتری از شبکه عصبی مصنوعی پرسپترون چندلایه و مدل رگرسیون چندمتغیره دارد. قربانی و همکاران (۱۳۹۴) فرآیند بارش- رواناب روزانه در حوضه آبریز بالیخ‌لوچای با استفاده از ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی، هیبرید موجک- ماشین بردار پشتیبان و هیبرید موجک- شبکه عصبی مورد مطالعه و مقایسه قرار داده‌اند. نتایج حاکی از دقت قابل قبول هر چهار روش می‌باشد. از لحاظ اولویت نیز مدل هیبرید موجک- شبکه عصبی با بیشترین دقت و کمترین خطا در اولویت اول و مدل‌های هیبرید موجک- ماشین بردار پشتیبان، شبکه عصبی مصنوعی و ماشین بردار پشتیبان بترتیب در اولویت‌های بعدی قرار گرفتند. همتی و همکاران (۱۳۹۶) با استفاده از نقشه‌های توپوگرافی، نقشه مدل ارتفاعی رقومی (DEM) با اندازه

سلولی ۳۰ متری در محیط GIS را تهیه نمودند. علاوه بر این نقشه شبکه‌بندی حوضه بر اساس شبکه استاندارد هیدرولوژیکی (SHG) با استفاده از امکانات نرم افزار HEC-GeoHMS برای ورودی به نرم افزار HEC-HMS را تهیه کردند. به منظور انتخاب مقیاس شبکه‌بندی مناسب، از دو شبکه با ابعاد  $1 \times 1$  و  $2 \times 2$  کیلومتر استفاده شد. با اینکه نتایج مدل حاکی از دقت زیاد شبکه  $1 \times 1$  کیلومتری در تفکیک مرزهای مناطق سیل‌خیز از یکدیگر می‌باشد؛ اما تفاوت چشمگیری با نتایج حاصل از شبکه‌بندی  $2 \times 2$  کیلومتری ندارد. نتایج حاصل از این پژوهش، شبکه‌بندی یک کیلومتری را برای تعیین اولویت‌بندی سیل‌خیزی پیشنهاد می‌دهد. با اجرای مکرر مدل مادکلارک در سناریوهای مختلف، شاخص شدت سیل در حوضه به صورت مکانی استخراج گردید. با در نظر گرفتن شاخص شدت سیل، زیرحوضه آلمالوچای، به عنوان مؤثرترین زیرحوضه در دبی اوج هیدروگراف خروجی شناخته شد. پژوهش و همکاران (۱۳۹۷) شبیه‌سازی جریان رواناب و رسوب در حوزه آبخیز بهشت آباد و تعمیم نتایج آن به حوضه‌ی آبخیز آلیج و محاسبه رواناب و رسوب این حوزه را انجام دادند. نتایج شبیه‌سازی نشان داد که تطابق قابل قبولی بین داده‌های شبیه‌سازی شده مدل و مشاهدات رواناب و رسوب وجود دارد. براساس معیار ناش- ساتکلیف، دقت  $57/57$  درصد در شبیه‌سازی رواناب، کارایی قابل قبول مدل را در این حوزه نشان می‌دهد. Anusree و Varghese (۲۰۱۶) با استفاده از شبکه‌ی مصنوعی پرسپترون چند لایه و مدل فازی عصبی تطبیقی و روش رگرسیون چند متغیره، فرایند بارش- رواناب را به صورت روزانه در حوضه آبخیز کاروانور در هند شبیه‌سازی نمودند. نتایج نشان داد مدل ANFIS پیش‌بینی دبی را با دقت بالاتری انجام می‌دهد. Chang و همکاران (۲۰۱۷) برای انتخاب ورودی‌های مدل‌های هوش مصنوعی برای مدل‌سازی بارش- رواناب از دو تکنیک تحلیل همبستگی بین ورودی و خروجی و مدل ترکیبی شاخص اطلاعات متقابل و تحلیل همبستگی استفاده کردند. Lee و همکاران (۲۰۱۰) دو نوع مدل شبکه عصبی مصنوعی برای شبیه‌سازی و پیش‌بینی فرآیند بارش- رواناب در مناطق کوچک استفاده کردند. بر اساس نتایج تحقیقات آنها مدل شبکه عصبی تابع پایه شعاعی، با استفاده از تابع گوسی که روند مشابهی با تابع پایه‌ای دارد، پایداری بهتری نسبت به مدل شبکه عصبی پسانتشار دارد. Tan و همکاران (۲۰۱۸) از روش ترکیبی تجزیه تجربی- گروهی جهت انتخاب ورودی‌های مدل در پیش‌بینی رواناب با استفاده از شبکه‌های عصبی مصنوعی در حوضه رودخانه یانگتسه استفاده کردند. نتایج نشان داد که این روش ترکیبی در فصول سیلابی نتایج بهتری را برای پیش‌بینی سیلاب نسبت به روش‌های دیگر هوش مصنوعی از قبیل ANN، SVM و ANFIS ارائه می‌کند. روش‌های هوشمند در شبیه‌سازی بارش- رواناب مورد استفاده قرار گرفته‌اند و مقایسه بین مدل‌های هوشمند و مفهومی کمتر مورد توجه قرار گرفته است. هدف از این تحقیق ارزیابی دو مدل مختلف شامل مدل مفهومی HEC-HMS و مدل‌های بر مبنای پردازش

داده‌ها (شبکه عصبی مصنوعی) که متغیرهای ورودی موثر در آن با الگوریتم PMI انتخاب شده، در شبیه‌سازی پیوسته بارش-رواناب است.

## مواد و روش‌ها

### معرفی منطقه مورد مطالعه

حوضه آبریز جراحی با مساحت ۲۵۳۴۹ کیلومتر مربع از سمت غرب و شمال به حوضه آبریز رودخانه کارون محدود بوده و از سمت شرق حوضه آبریز رودخانه زهره آن را محدود می‌نماید. این حوضه در دامنه‌های جنوبی زاگرس میانی واقع شده و بین مختصات جغرافیایی  $48^{\circ}18'$  تا  $52^{\circ}19'$  طول شرقی و  $30^{\circ}00'$  تا  $31^{\circ}42'$  عرض شمالی قرار دارد.

### معرفی الگوریتم PMI

الگوریتم PMI توسط Sharma (۲۰۰۰) جهت شناسایی متغیرهای ورودی موثر در مدل‌های هیدرولوژیکی توسعه داده شد. تنها الگوریتم غیرخطی انتخاب متغیرهای ورودی جهت تعیین متغیرهای ورودی موثر در مدل‌های بر مبنای پردازش داده‌ها، الگوریتم PMI می‌باشد. الگوریتم PMI هر تکرار را با در نظر گرفتن یک ورودی (C) و یک خروجی (Y) و با پیدا کردن Cs (Cs متفاوت از C است) که مقدار PMI را با توجه به متغیر خروجی ماکزیمم می‌کند (با توجه به ورودی‌هایی که از قبل انتخاب شده‌اند)، انجام می‌دهد. مفهوم آماری که PMI برای Cs برآورد می‌کند بر مبنای محدوده‌های اطمینان است که از توزیع تشکیل شده توسط یک حلقه‌ی خودراه‌انداز، تعیین شده است. اگر ورودی معنی‌دار باشد، Cs به S (مجموعه متغیرهای ورودی انتخاب‌شده) اضافه شده و انتخاب کردن ادامه می‌یابد، تا جایی که هیچ ورودی معنی‌داری باقی نماند، سپس متعاقباً الگوریتم متوقف می‌شود.

### برآورد اطلاعات متقابل جزئی (PMI)

با توجه به یک متغیر خروجی تصادفی Y، مقداری عدم قطعیت در مورد یک مشاهده y که عضوی از Y می‌باشد، وجود دارد که می‌توان آن را با توجه به آنتروپی شانون H، (Shannon, 1948) تعریف کرد. ولی با فرض یک متغیر ورودی تصادفی X که Y وابسته به آن است، مشاهدات متقابل (x, y) این عدم قطعیت را کاهش می‌دهد، زیرا اطلاع از x، اجازه می‌دهد تا مقدار Y استنتاج شود و برعکس. بنا به تعریف اطلاعات متقابل  $I(X;Y)$ ، کاهش در عدم قطعیت متغیر Y به دلیل مشاهده X است (Cover and Thomas, 1991). این مسئله بصورت یک قسمت مشترک بین دو دایره در شکل (۱) نمایش داده شده است.


قسمت مشترک جایی است که عدم قطعیت کاهش یافته حول  $X$  و  $Y$  به ترتیب توسط آنتروپی شرطی  $H(Y|X)$  و  $H(X|Y)$  مشخص شده است. اطلاعات متقابل (MI) را می‌توان با فرمول زیر بصورت مستقیم محاسبه کرد (May et al., 2008):

$$I(X; Y) = \iint p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy \quad (1)$$

$p(x)$  و  $p(y)$  به ترتیب توابع چگالی احتمال حاشیه‌ای  $X$  (pdfs) و  $Y$  هستند و  $p(x, y)$  تابع چگالی احتمال توام است. به هر حال بصورت عملی، فرم صحیح توابع چگالی احتمال در رابطه (۱) مجهول است. از این رو، از برآورد چگالی‌های احتمال بجای آن استفاده می‌شود. با جایگذاری برآوردهای چگالی احتمال با تقریب عددی انتگرال در رابطه (۱) خواهیم داشت (May et al., 2008):

$$I(X; Y) \approx \frac{1}{n} \sum_{i=1}^n \log \left[ \frac{f(x_i, y_i)}{f(x_i)f(y_i)} \right] \quad (2)$$

که در آن:  $f$  نمایانگر چگالی برآورد شده بر مبنای نمونه‌ای از  $n$  مشاهده از  $(x, y)$  است. با فرض رابطه (۲) می‌توان گفت که برآورد دقیق و موثر MI (اطلاعات متقابل) بستگی زیادی به روش بکارگرفته شده در برآورد توابع چگالی احتمال حاشیه‌ای و توام دارد. در مجموع سه معیار توقف الگوریتم PMI وجود دارد که عبارتند از: ۱- مقادیر بحرانی جدول‌بندی شده، ۲- معیار بر مبنای اطلاعات اکائیکه (AIC) (Akaike, 1974)، ۳- معیار آزمون همپیل. با توجه به اینکه در این تحقیق از معیار آزمون همپیل جهت تعیین متغیرهای موثر استفاده شده، بنابراین این معیار در ادامه توضیح داده می‌شود.



شکل ۱: دیاگرام وین، نشان‌دهنده رابطه بین اطلاعات متقابل (MI) و آنتروپی برای خروجی  $Y$  و متغیر ورودی منفرد  $X$  (May et al., 2008)

### معیار آزمون همپیل (Z)

روش‌های تعیین داده پرت، به‌عنوان یک روش آماری قوی برای تعیین این که آیا یک مقدار  $x$  مورد نظر، به‌طور قابل توجهی متفاوت از مقادیر دیگر در مجموعه‌ای از مقادیر  $X$  است. این آزمون انحراف یک مشاهده منفرد را نسبت به میانگین تمامی

مشاهدات مقایسه می‌کند. یک مقدار مشاهده‌ای با داشتن امتیاز  $Z$  بزرگتر از ۳ بر اساس قانون  $3\sigma$  برای توزیع نرمال معمولاً به‌عنوان داده پرت در نظر گرفته می‌شود (داده‌های پرت دارای مقداری بیشتر از ۳ برابر انحراف معیار از میانگین مجموعه داده‌ها دارند). در فرمول‌بندی کردن یک ضابطه متوقف‌کننده برپایه تشخیص داده‌های پرت برای الگوریتم PMIS، فرض اساسی بر این است که مجموعه داده‌ها ابتدا دارای برخی متغیرهای اضافی و غیر وابسته بوده و متغیرهای مهم شناسایی خواهند شد. فاصله همپل (Davies and Gather, 1993) بر پایه میانه مجموعه ورودی‌ها بنا نهاده شده است. نقطه از کارافتادگی آزمون همپل  $n/2$  است و بعنوان یکی از توانمندترین آزمون‌های تشخیص داده پرت با وجود چندین داده پرت شناخته می‌شود (Davies and Gather, 1993; Pearson, 2002). آزمون همپل با محاسبه انحراف مطلق از میانه PMI برای همه ورودی‌ها بصورت زیر شروع می‌شود (May et al., 2008):

$$d_j = |I_{C_j Y.S} - I_{C_j Y.S}^{(50)}| \quad (3)$$

که در این رابطه  $d_j$  نمایانگر انحراف مطلق،  $I_{C_j Y.S}$  برابر با مقدار PMI برای متغیر  $x$  و  $I_{C_j Y.S}^{(50)}$  نشان‌دهنده میانه PMI برای مجموعه ورودی‌های  $C$  می‌باشد. سپس فاصله همپل را می‌توان بصورت زیر تعیین کرد (May et al., 2008):

$$Z_j = \frac{d_j}{1.4826d_j^{(50)}} \quad (4)$$

که  $Z_j$  نشان دهنده فاصله همپل برای مجموعه ورودی  $C_j$  و  $d_j^{(50)}$  نشان‌دهنده میانه انحراف مطلق (MAD)،  $d_j$  می‌باشد. ضریب  $1/4826$  فاصله را به نحوی تغییر داده تا قانون  $Z > 3$  را بتوان اعمال کرد، همانطوری که در مورد  $Z$ -test متعارف بکار برده شده است (Pearson, 2002). با استفاده از این معیار متوقف‌کننده، الگوریتم PMI بر پایه انتخاب ورودی، دیگر حاوی حلقه خودراه‌انداز نیست، و نیز PMI با هیچ مقدار بحرانی از  $I$  مقایسه نمی‌شود. در عوض، مقدار  $Z_s$  برای برگزیدن  $C_s$  تعیین می‌شود و اگر  $Z_s > 3$  باشد، ورودی انتخاب شده و به  $S$  اضافه می‌شود، در غیراینصورت ادامه عملیات الگوریتم انتخاب متغیرهای ورودی متوقف می‌شود.

### شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی جزء سیستم‌های دینامیکی هوشمند مدل-آزاد بوده که مبتنی بر داده‌های تجربی بوده و با پردازش روی این داده‌ها دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. این سامانه‌ها از دو ویژگی اساسی یادگیری یا نگاشت‌پذیری بر اساس آرایه‌ی داده‌های تجربی و ساختارپذیری موازی برخوردارند که ضمن اجرای فرایند آموزش، اطلاعات مربوط به داده‌ها درون وزن‌های شبکه ذخیره می‌شوند. در این تحقیق از شبکه‌های مختلف عصبی شامل شبکه پیشخور تعمیم یافته (GFF) و شبکه تابع پایه شعاعی (RBF) در شبیه‌سازی پیوسته بارش- رواناب در حوضه جراحی استفاده

شده است. برای شبیه‌سازی پیوسته فرایند بارش- رواناب در حوضه جراحی با شبکه‌های عصبی مصنوعی، متوسط بارش و تبخیر روزانه ایستگاه‌های باران‌سنجی و تبخیرسنجی در داخل و اطراف حوضه و دبی جریان روزانه ایستگاه هیدرومتری گرگر استفاده گردید. جهت تهیه مجموعه پتانسیل متغیرهای ورودی، هر یک از متغیرهای ورودی شامل متوسط بارش و تبخیر روزانه در سطح حوضه نیز تا یک هفته قبل در نظر گرفته شد. همچنین با توجه به اینکه مقدار دبی در یک ایستگاه هیدرومتری وابسته به مقدار دبی در روزهای قبل می‌باشد، تاخیر زمانی یک هفته‌ای برای مقدار دبی در ایستگاه هیدرومتری گرگر در نظر گرفته شد تا مجموعه پتانسیل متغیرهای ورودی در شبکه عصبی مصنوعی بدست آید. سپس متغیرهای ورودی موثر بر متغیر خروجی (دبی) در زمان حال در ایستگاه هیدرومتری گرگر) با استفاده از الگوریتم PMI بدست آمد. جدول (۱) مشخصات آماری متغیرهای مورد استفاده در شبکه‌های عصبی مصنوعی را نشان می‌دهد.

### معرفی مدل هیدرولوژیکی HEC-HMS

مدل HEC-HMS یکی از پرکاربردترین مدل‌های بارش- رواناب در ایالت متحده آمریکا می‌باشد. این مدل یک مدل مفهومی نیمه‌توزیعی بوده که دارای قابلیت شبیه‌سازی تلفات و نفوذ، ذوب برف، روندیابی زیرحوضه‌ها، روندیابی شبکه رودخانه‌ها، فرسایش و انتقال رسوب در زیرحوضه‌ها، شبیه‌سازی کیفیت آب زیرحوضه‌ها و پیش‌بینی جریان می‌باشد. بر اساس نقشه‌های پایه توپوگرافی، شبکه رودخانه‌ها و موقعیت ایستگاه‌های هیدرومتری، مرز حوضه جراحی تا محل ایستگاه آبرسانی گرگر بسته شد و به تعدادی زیرحوضه تقسیم‌بندی شد. شکل (۲) نقشه زیرحوضه‌بندی حوضه جراحی در محل ایستگاه هیدرومتری گرگر و موقعیت ایستگاه‌ها را نشان می‌دهد. جهت شبیه‌سازی فرایند بارش- رواناب با مدل HEC-HMS، برای مدل تلفات روش محاسبه رطوبت خاک (SMA) استفاده شد. مدل SMA<sup>۲</sup> تنها مدل پیوسته در این نرم‌افزار بوده و علاوه بر جدید بودن آن، توانایی مدل‌سازی سیستم‌های هیدرولوژیکی را برای دوره‌های طولانی مدت به صورت پیوسته دارا می‌باشد. همچنین از بین مدل‌های مختلف تبدیل بارش به رواناب، مدل هیدروگراف واحد کلارک به دلیل استفاده عمومی‌تر در حوضه‌های بزرگ و عملکرد قابل قبول آن استفاده گردید (Iran Power and Water Resources Development Company, 2006). همچنین بنابر توصیه‌های صورت‌گرفته به همراه مدل SMA از مدل جریان پایه مخزن خطی برای برآورد جریان پایه بهره گرفته شد (HEC, 2000). برای روندیابی هیدروگراف در طی بازه‌ها رودخانه نیز روش روندیابی ماسکینگام انتخاب شد.

### واسنجی و صحت‌سنجی مدل HEC-HMS

به منظور واسنجی مدل HEC-HMS در شبیه‌سازی درازمدت جریان از داده‌های دبی روزانه از ۱۳۸۰/۷/۱ تا ۱۳۸۶/۶/۳۱ و برای صحت، سنجی مدل از داده‌های ۱۳۸۶/۷/۱ تا ۱۳۹۰/۶/۳۱ در ایستگاه‌های هیدرومتری گرگر استفاده شد. پارامترهای

<sup>۲</sup>Soil Moisture Accounting



واسنجی برای هر زیرحوضه شامل ۱۴ پارامتر مربوط به مدل تلفات SMA، ۶ پارامتر مربوط به مدل مخزن خطی و ۲ پارامتر مربوط به مدل تبدیل بارش به رواناب کلارک می‌باشد. پارامترهای واسنجی برای هر آبراهه شامل ۲ پارامتر مربوط به ضرایب X و K ماسکینگام می‌باشد.

### شاخص‌های ارزیابی

برای مقایسه هیدروگراف مشاهداتی با هیدروگراف شبیه‌سازی شده در مراحل واسنجی و صحت‌سنجی مدل، شاخص‌های نیکویی برازش مختلفی رامی‌توان استفاده نمود. از شاخص‌های آماری سنجش خطا می‌توان به ضریب ناش- ساتکلایف، ریشه میانگین مربعات خطا، ضریب همبستگی و درصد خطای حجمی کل اشاره کرد که به ترتیب در روابط (۷) تا (۱۰) آمده است.

(Nash and Sutcliffe, 1970; Abrahart et al., 2004).

$$NS = 1 - \left[ \frac{\sum_i^n (S_i - O_i)^2}{\sum_i^n (O_i - \bar{O})^2} \right] \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_i - O_i)^2} \quad (8)$$

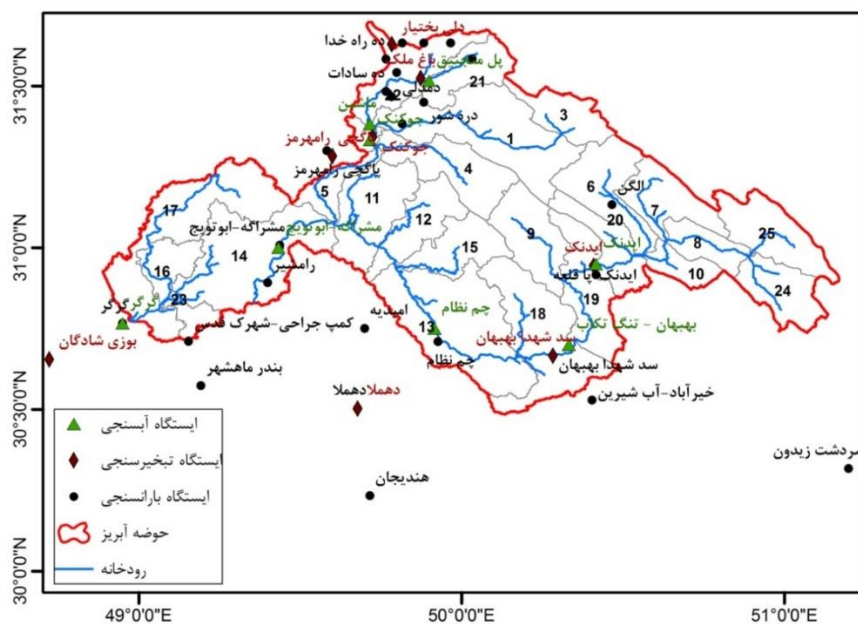
$$R = Cov(O_i, S_i) / \sqrt{Cov(O_i, O_i) \cdot Cov(S_i, S_i)} \quad (9)$$

$$PTVE = \frac{\sum_i^n S_i - \sum_i^n O_i}{\sum_i^n O_i} * 100 \quad (10)$$

در روابط (۷) تا (۱۰)، n برابر با تعداد داده‌های جریان،  $O_i$  و  $S_i$  داده‌های جریان مشاهداتی و شبیه‌سازی شده در گام زمانی i ام،  $\bar{O}$  دبی میانگین مشاهده‌ای و Cov کوواریانس داده‌ها می‌باشد.

جدول ۱: مشخصات آماری متغیرهای مورد استفاده در شبکه‌های عصبی مصنوعی


شاخص آماری	بارش متوسط روزانه (میلیمتر)	تبخیر متوسط روزانه (میلیمتر)	دبی جریان در ایستگاه گرگر
حداکثر	۶۳/۵۶	۱۸/۷۷	۴۰۶
حداقل	۰	۰	۰
انحراف استاندارد	۴/۲۳	۴/۸۱	۵۳/۲۶
میانگین	۱/۲۹	۸/۷۷	۳۸/۹۶
ضریب تغییرات	۳/۲۸	۰/۵۵	۱/۳۷
دامنه تغییرات	۶۳/۵۶	۱۸/۷۷	۴۰۶




شکل ۲: نقشه زیرحوضه‌بندی حوضه جراحی در محل ایستگاه هیدرومتری گرگر و موقعیت ایستگاه‌ها نتایج و بحث

### نتایج واسنجی و صحت‌سنجی مدل HEC-HMS

شکل (۳) مقایسه هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل HEC-HMS در مرحله واسنجی مدل HEC-HMS در ایستگاه هیدرومتری گرگر را نشان می‌دهد. با توجه به شکل (۳) می‌توان دریافت که مدل HEC-HMS در برآورد دبی جریان با مقادیر کم و پایه بیش برآورد می‌باشد. به منظور صحت‌سنجی مدل کالیبره شده HEC-HMS شبیه‌سازی بارش-رواناب برای دوره زمانی صحت‌سنجی توسط مدل با مقادیر پارامترهای نهایی حاصل از کالیبراسیون انجام شد. شکل (۴) مقایسه هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل HEC-HMS به ترتیب در ایستگاه هیدرومتری گرگر برای دوره زمانی صحت‌سنجی مدل را نشان می‌دهد. مقایسه بین هیدروگراف جریان در شکل (۴) نشان می‌دهد که مدل HEC-HMS از لحاظ شبیه‌سازی بارش-رواناب بخوبی واسنجی شده است. جدول (۲) معیارهای آماری نیکوئی برآزش برای دوره واسنجی و صحت‌سنجی مدل HEC-HMS در شبیه‌سازی جریان در ایستگاه هیدرومتری گرگر را نشان می‌دهد. با توجه به جدول (۲)، درصد خطای حجمی کل بین رواناب مشاهده‌ای و شبیه‌سازی شده در مرحله واسنجی و صحت‌سنجی مدل برای ایستگاه گرگر به ترتیب برابر با ۲۱/۷ درصد و ۲۰ درصد بود؛ که نشان‌دهنده عملکرد نسبتاً مناسب مدل در برآورد حجم کل رواناب می‌باشد. علاوه بر این با توجه به جدول (۲)، مقادیر ریشه میانگین مربعات خطا بین دبی مشاهداتی و شبیه‌سازی شده در ایستگاه گرگر برای واسنجی و صحت‌سنجی مدل به ترتیب برابر با ۴۰/۶ و ۱۶/۳ مترمکعب در ثانیه می‌باشد. همچنین مقدار ضریب ناش-ساکلایف برای مرحله واسنجی و صحت‌سنجی مدل برای ایستگاه گرگر به ترتیب برابر با ۰/۵۶ و ۰/۶۰ بود؛ که بیانگر راندمان و دقت قابل قبول مدل از لحاظ شبیه‌سازی هیدروگراف جریان می‌باشد.



شکل ۳: مقایسه هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل HEC-HMS در مرحله واسنجی مدل در ایستگاه هیدرومتری گرگر



شکل ۴: مقایسه هیدروگراف جریان مشاهداتی و شبیه‌سازی شده با مدل HEC-HMS در مرحله صحت‌سنجی در ایستگاه هیدرومتری گرگر

جدول ۲: معیارهای آماری نیکوتی برازش برای دور هواسنجی و صحت‌سنجی مدل HEC-HMS

ایستگاه	RMSE (cms)	PTVE %	NS	R
واسنجی	۴۰/۶	۲۱/۷	۰/۵۶	۰/۸۳۷
صحت‌سنجی	۱۶/۳	۲۰/۰	۰/۶۰	۰/۸۴۳

### تعیین متغیرهای موثر ورودی در شبکه‌های عصبی مصنوعی با الگوریتم PMI

جدول (۳) نتایج الگوریتم PMI برای ۵ متغیر موثر به ترتیب اولویت نشان می‌دهد. در جدول (۳)، Iteration تعداد تکرار

الگوریتم PMI، Variable نام متغیر،  $I(x; y)$  مقدار اطلاعات متقابل جزئی (PMI) برای هر متغیر،  $MC-I^*(95)$  محدوده ۹۵

درصد مقدار بحرانی اطلاعات متقابل (MI)، (99) MC-I\* محدود به ۹۹ درصد مقدار بحرانی MI و Hampel مقدار فاصله همپل برای هر متغیر است. همچنین در جدول (۳)،  $Q(t-1)$ ،  $Q(t-2)$ ،  $Q(t-7)$ ،  $Q(t-3)$  و  $Q(t-6)$  دبی جریان در ایستگاه گرگر به ترتیب برای یک روز قبل، دو روز قبل، هفت روز قبل، سه روز قبل و شش روز قبل است. برای تعیین متغیرهای ورودی موثر با توجه به مقادیر ضابطه همپل، تا متغیرهایی موثر هستند که مقدار فاصله همپل آنها بزرگتر از ۳ باشند. بنابراین با توجه به جدول (۳) و با در نظر گرفتن ضابطه همپل، متغیرهای ورودی موثر بر دبی جریان در ایستگاه گرگر، دبی جریان یک روز قبل در این ایستگاه می‌باشد.

### تعیین بهترین ساختار شبکه عصبی GFF

دوره زمانی جهت آموزش و تست شبکه‌های عصبی مصنوعی دقیقاً مشابه دوره زمانی مراحل واسنجی و صحت‌سنجی مدل HEC-HMS در نظر گرفته شد. به منظور تعیین بهترین ساختار مدل بارش- رواناب شبکه پیشخور تعمیم‌یافته (GFF)، ساختارهای مختلف شبکه GFF از لحاظ تعداد لایه‌های میانی، نوع الگوریتم آموزش شبکه، نوع تابع انتقال، تعداد نرون‌های لایه میانی و تعداد تکرارهای (Epoch) آموزش در نظر گرفته شد. سپس اقدام به آموزش و آزمون هر یک آنها گردید و به ازای هر شبکه شاخص‌های آماری شامل مقدار ضریب ناش- ساتکلایف، ضریب رگرسیون و ریشه میانگین مربعات خطا بین دبی جریان مشاهداتی و محاسباتی نیز تعیین شد. با مقایسه مقدار شاخص‌های آماری برای ساختارهای مختلف شبکه GFF، بهترین ساختار شبکه از لحاظ دقت و عملکرد در شبیه‌سازی پیوسته فرایند بارش رواناب بدست آمد.

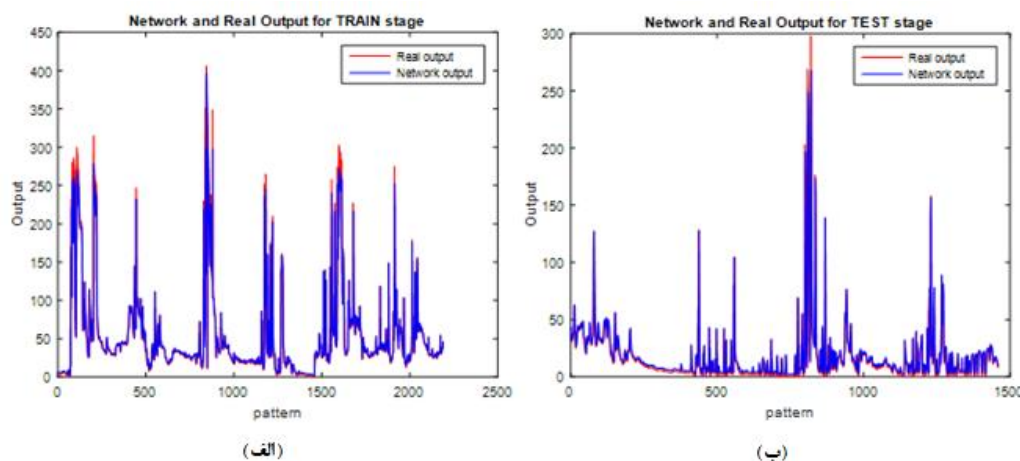
جدول (۴) نتایج حاصل از بهترین ساختار شبکه GFF در شبیه‌سازی بارش- رواناب را نشان می‌دهد. با توجه به جدول (۴) می‌توان دریافت که شبکه GFF با ساختار ۱-۲-۱ (یعنی ۱ نرون ورودی، ۲ نرون در لایه میانی و ۱ نرون برای لایه خروجی) با ۱۰۰۰ تکرار آموزش به ازای تابع انتقال Tansig (تانزانت سیگموئید) در لایه میانی و تابع انتقال purelin (خطی) در لایه خروجی و الگوریتم آموزش Trainlm (لونبرگ مارکوارت) دارای بیشترین ضریب ناش- ساتکلایف و کمترین ریشه میانگین مربعات خطا بین دبی جریان مشاهداتی در ایستگاه گرگر و محاسباتی با شبکه GFF می‌باشد. بنابراین شبکه GFF با این مشخصات، بهترین شبکه می‌باشد. شکل (۵) مقایسه هیدروگراف جریان روزانه مشاهداتی ایستگاه گرگر و محاسباتی با بهترین شبکه GFF به ازای مرحله آموزش و تست شبکه را نشان می‌دهد. با توجه به شکل (۵) می‌توان دریافت که تغییرات هیدروگراف جریان مشاهداتی مشابه تغییرات هیدروگراف جریان محاسباتی با بهترین مدل GFF می‌باشد. البته مدل GFF مقادیر دبی‌های پائین را نسبت به دبی‌های اوج بهتر و دقیق‌تر شبیه‌سازی کرده است.

جدول ۳: نتایج الگوریتم PMI برای تعیین متغیرهای موثر ورودی در شبکه عصبی مصنوعی

متغیر	I(x;y)	MC-I*(95)	MC-I*(99)	Hampel	تکرار
logQgargr(t-1)	۱/۶۴۴۹۷	۰/۰۲۴۳۲۴۱	۰/۰۲۶۱۹۰۷	۳/۹۸۶۷۲	۰
logQgargr(t-2)	۰/۱۴۲۲۹۲	۰/۰۲۴۳۲۴۱	۰/۰۲۶۱۹۰۷	۰/۹۰۲۶۲۲	۱
logQgargr(t-7)	۰/۰۹۸۵۰۳۶	۰/۰۲۴۳۲۴۱	۰/۰۲۶۱۹۰۷	۰/۷۵۵۲۵۸	۲
logQgargr(t-3)	۰/۱۰۳۷۷۳	۰/۰۲۴۳۲۴۱	۰/۰۲۶۱۹۰۷	۱/۱۱۷۱۲	۳
logQgargr(t-6)	۰/۰۸۵۸۸۱۳	۰/۰۲۴۳۲۴۱	۰/۰۲۶۱۹۰۷	۰/۸۸۳۳۵۷	۴

جدول ۴: نتایج حاصل از بهترین ساختار شبکه GFF برای شبیه‌سازی پیوسته بارش- رواناب

ساختار	تابع انتقال در لایه میانی	تابع انتقال در لایه خروجی	الگوریتم آموزش	RMSE (cms)		NS		R	
				آموزش	آزمون	آموزش	آزمون	آموزش	آزمون
۱-۲-۱	tansig	purelin	Trainlm	۲۲/۸۰	۱۴/۵۸	۰/۸۶۰	۰/۶۷۷	۰/۹۲۷	۰/۸۳۲



شکل ۵: مقایسه هیدروگراف جریان مشاهداتی و محاسباتی با بهترین شبکه GFF در ایستگاه هیدرومتری گرگر برای

(الف) مرحله آموزش شبکه و (ب) مرحله تست شبکه

### تعیین بهترین ساختار شبکه عصبی RBF

به منظور تعیین بهترین ساختار شبکه RBF برای شبیه‌سازی پیوسته بارش- رواناب در حوضه جراحی، شبکه RBF با ساختارهای مختلف از لحاظ تعداد نرون‌های لایه میانی، مقدار پراکنش و تعداد تکرارهای آموزش در نظر گرفته شد. سپس اقدام به آموزش و آزمون هر یک از شبکه‌ها گردید. دامنه تغییرات مقدار پراکنش یا Spread بین صفر تا ۱ است. جدول (۵) نتایج حاصل از شبیه‌سازی بارش- رواناب با بهترین ساختار شبکه RBF را نشان می‌دهد. با توجه به جدول (۵) می‌توان دریافت که شبکه RBF با ساختار ۱-۳۷-۱ (یعنی ۱ نرون در لایه ورودی، ۳۷ نرون در لایه میانی و ۱ نرون در لایه خروجی) با ۱۰۰۰

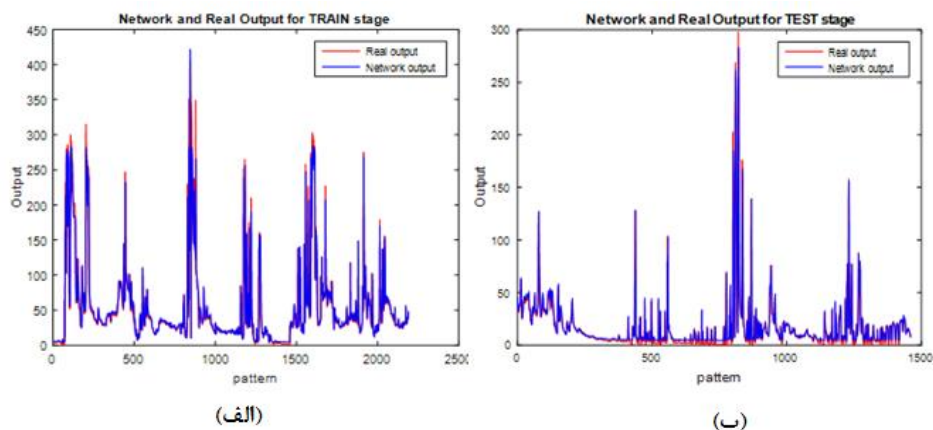
تکرار آموزش به ازای مقدار ضریب پراکنش برابر با ۰/۹ دارای بیشترین ضریب ناش- ساتکلایف و کمترین ریشه میانگین مربعات خطا بین دبی جریان مشاهداتی در ایستگاه گرگر و محاسباتی با شبکه RBF به ازای داده‌های مرحله تست شبکه می‌باشد. بنابراین شبکه با این مشخصات، بهترین شبکه RBF می‌باشد. شکل (۶) مقایسه هیدروگراف جریان روزانه مشاهداتی ایستگاه گرگر و محاسباتی با بهترین شبکه RBF به ازای مرحله آموزش و تست شبکه را نشان می‌دهد. با توجه به شکل (۶) می‌توان دریافت که شکل تغییرات هیدروگراف جریان محاسباتی نسبتاً مشابه شکل تغییرات هیدروگراف جریان مشاهداتی می‌باشد.

### مقایسه مدل HEC-HMS و شبکه عصبی مصنوعی برای شبیه‌سازی پیوسته بارش- رواناب


به منظور مقایسه و ارزیابی مدل مفهومی HEC-HMS و شبکه عصبی مصنوعی جهت شبیه‌سازی پیوسته بارش- رواناب در حوضه جراحی، ابتدا بهترین شبکه عصبی مصنوعی تعیین می‌شود. با توجه به جداول (۴) و (۵)، ضریب ناش- ساتکلایف در مرحله تست بهترین شبکه GFF و RBF به ترتیب ۰/۶۷۷ و ۰/۶۷۶ است. همچنین ریشه میانگین مربعات خطا بین مقادیر دبی هیدروگراف مشاهداتی و محاسباتی در ایستگاه هیدرومتری گرگر برای مرحله تست بهترین شبکه GFF و RBF به ترتیب برابر با ۱۴/۵۸ و ۱۴/۶۰ مترمکعب در ثانیه است. بنابراین با مقایسه مقادیر ضریب ناش- ساتکلایف و ریشه میانگین مربعات خطا، شبکه GFF از دقت بیشتری در شبیه‌سازی پیوسته بارش- رواناب نسبت به شبکه RBF برخوردار است. شکل (۷) مقایسه هیدروگراف جریان شبیه‌سازی شده با مدل HEC-HMS و شبکه GFF برای دوره زمانی صحت‌سنجی نسبت به هیدروگراف مشاهداتی در ایستگاه گرگر را نشان می‌دهد. با توجه به شکل (۷) می‌توان دریافت که تغییرات هیدروگراف جریان شبیه‌سازی شده با شبکه GFF نزدیکتر به هیدروگراف مشاهداتی در مقایسه با هیدروگراف جریان شبیه‌سازی شده با مدل HEC-HMS می‌باشد. جدول (۶) مقایسه شاخص‌های آماری بین هیدروگراف مشاهداتی و هیدروگراف جریان شبیه‌سازی شده با مدل HEC-HMS و شبکه GFF برای دوره زمانی صحت‌سنجی در ایستگاه گرگر را نشان می‌دهد. با توجه به جدول (۶) می‌توان دریافت که ضریب ناش- ساتکلایف برای مدل HEC-HMS و شبکه GFF به ترتیب ۰/۶ و ۰/۶۷۷ است. بنابراین شبکه GFF از راندمان و دقت بیشتری نسبت به مدل HEC-HMS در شبیه‌سازی پیوسته بارش- رواناب در حوضه جراحی برخوردار است.

جدول ۵: نتایج حاصل از بهترین ساختار شبکه RBF برای شبیه‌سازی پیوسته بارش- رواناب

ساختار	spread	epoch	RMSE (cms)		NS		R	
			آموزش	آزمون	آموزش	آزمون	آموزش	آزمون
			۱-۳۷-۱	۰/۹	۱۰۰۰	۲۲/۵۶	۱۴/۶۰	۰/۸۶۳



شکل ۶: مقایسه هیدروگراف جریان مشاهداتی و محاسباتی با بهترین شبکه RBF در ایستگاه هیدرومتری گرگر برای (الف) مرحله آموزش شبکه و (ب) مرحله تست شبکه



شکل ۷: مقایسه هیدروگراف جریان شبیه‌سازی شده با مدل HEC-HMS و شبکه GFF برای دوره زمانی صحت‌سنجی نسبت به هیدروگراف مشاهداتی در ایستگاه گرگر

جدول ۶: مقایسه شاخص‌های آماری بین هیدروگراف مشاهداتی و هیدروگراف جریان شبیه‌سازی شده با مدل HEC-HMS و شبکه GFF برای دوره زمانی صحت‌سنجی در ایستگاه گرگر

مدل	RMSE (cms)	NS	R
HEC-HMS model	۱۶/۳۰	۰/۶۰۰	۰/۸۴۳
GFF network	۱۴/۵۸	۰/۶۷۷	۰/۸۳۲

### نتیجه‌گیری

نتایج این تحقیق نشان می‌دهد که بکارگیری الگوریتم PMI جهت تعیین متغیرهای ورودی موثر در شبکه‌های عصبی مصنوعی موجب افزایش دقت شبکه‌ها در شبیه‌سازی پیوسته بارش- رواناب می‌گردد. علاوه بر این استفاده از الگوریتم PMI موجب کاهش قابل توجه در زمان مورد نیاز برای تعیین متغیرهای ورودی موثر و در نتیجه توسعه مدل می‌گردد. May و

همکاران (۲۰۰۸) با مقایسه نتایج مدل ANN توسعه یافته با الگوریتم PMI با نتایج مدل ANN بدون بکارگیری الگوریتم PMI، دریافتند که مدل توسعه یافته با الگوریتم PMI از دقت پیش بینی بیشتری همراه با صرفه جویی قابل توجه در توسعه مدل برخوردار است. نتایج حاصل از بکارگیری الگوریتم PMI جهت تعیین متغیرهای ورودی موثر بر دبی جریان در مدل سازی بارش- رواناب با استفاده از شبکه های عصبی مصنوعی نشان می دهد که فقط مقدار دبی جریان یک روز قبل در ایستگاه هیدرومتری، متغیر ورودی موثر می باشد. علت آن این است که تعداد روزهای بارانی در هر سال خیلی کمتر از تعداد روزهای غیربارانی بوده، بنابراین متغیرهای موثر بر دبی جریان در ایستگاه هیدرومتری فقط شامل دبی جریان یک روز قبل خواهد بود. نتایج نشان می دهد که شبکه GFF از دقت بیشتری در شبیه سازی پیوسته بارش- رواناب در حوضه جراحی نسبت به شبکه RBF برخوردار می باشد. همچنین نتایج نشان می دهد که شبکه GFF از راندمان و دقت بیشتری نسبت به مدل مفهومی HEC-HMS در شبیه سازی پیوسته بارش- رواناب در حوضه جراحی برخوردار است. همچنین تغییرات هیدروگراف جریان شبیه سازی شده با شبکه GFF نزدیکتر به هیدروگراف مشاهداتی در مقایسه با هیدروگراف جریان شبیه سازی شده با مدل HEC-HMS می باشد.

## منابع

- دستورانی، م. ت.، شریفی دارانی، ح.، طالبی، ع. و مقدم نیا، ع. (۱۳۹۰). کارایی شبکه های عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی در مدل سازی بارش- رواناب در حوضه آبخیز سد زاینده رود. مجله آب و فاضلاب، دوره ۲۲، شماره ۴، ص ۱۱۴-۱۲۵.
- دهقانی، م.، مرید، س. و نوروزی، ع. ا. (۱۳۸۹). ارزیابی شبیه سازی رواناب حوزه های برفی با مدل شبیه سازی (SRM) و شبکه عصبی برای برآورد انرژی برقی در مواجهه با کمبود آمار. نشریه تحقیقات منابع آب ایران، دوره ۶، شماره ۳، ص ۱۲-۲۴.
- اکبری، م.، رعنائی، ا.، میرزاخان، ح.، درگاهی، ع. و جرگه، م. ر. (۱۳۹۵). پیش بینی رواناب ناشی از ذوب برف با استفاده از مدل SRM و مقایسه با مدل های شبکه عصبی ANN و ANFIS مطالعه موردی: حوضه آبریز سد کارده. نشریه آب و خاک دانشگاه فردوسی مشهد، دوره ۳۰، شماره ۶، ص ۱۸۰۷-۱۷۹۴.
- قربانی، م. ع.، ازانی، ع. و محمودی وانعلیا، س. (۱۳۹۴). مدل سازی بارش رواناب با استفاده از مدل های هوشمند هیبریدی. تحقیقات منابع آب ایران، دوره ۱۱، شماره ۲، ص ۱۵۰-۱۴۶.
- حقی زاده، ع.، محمدلو، م. و نوری، ف. (۱۳۹۴). شبیه سازی فرایند بارش- رواناب با استفاده از شبکه عصبی- مصنوعی و سیستم فازی عصبی تطبیقی و رگرسیون چندمتغیره (مطالعه موردی: حوضه آبخیز خرم آباد). مجله اکوهیدرولوژی، دوره ۲، شماره ۲، ص ۲۳۳-۲۲۴.
- همت، م.، شهنازی، م.، احمدی، ح. و سالار جزی، م. (۱۳۹۶). تعیین مناطق سیل خیز حوضه آبریز قرقو با استفاده از مدل هیدرولوژیکی مادکلارک و GIS. نشریه علمی پژوهشی مهندسی آبیاری و آب ایران، دوره ۷، شماره ۴، ص ۸۰-۶۵.
- پژوهش، م.، طهماسبی، ط. و عبدالمهی، خ. (۱۳۹۷). شبیه سازی رواناب و رسوب با استفاده از مدل WetSpa. نشریه علمی پژوهشی مهندسی آبیاری و آب ایران، دوره ۸، شماره ۴، ص ۳۰-۴۶.



**Abrahart, R., Kneale, P.E. and See, L.M. (2004).** Neural networks for hydrological modeling. CRC Press. 320 pages.

**Akaike, H. (1974).** A new look at the statistical model identification. IEEE Transactions on Automatic Control, 19, pp: 716–723.

**Anusree, K. and Varghese, K. O. (2016).** Streamflow prediction of Karuvannur river basin using ANFIS, ANN and MNLN models. Procedia Technology, 24, pp: 101-108.

**Araghinejad, S. and Karamouz, M. (2005).** Long-lead streamflow forecasting using artificial neural networks and fuzzy inference system. Iran Water Resources Research, 1(2), pp: 29-41.

**Chang, T.K., Talei, A., Alaghmand, S. and Ooi, M.P.L. (2017).** Choice of rainfall inputs for event-based rainfall-runoff modeling in a catchment with multiple rainfall stations using data-driven techniques. Journal of Hydrology, 545, pp:100–108.

**Cover, T.M. and Thomas, J.A. (1991).** Elements of information theory. John Wiley & Sons, Inc., New York. 400 pages.

**Davies, L. and Gather, U. (1993).** The identification of multiple outliers. Journal of the American Statistical Association, 88(423), pp:782–792.

**Hydrologic Engineering Center (HEC), (2000).** HEC-HMS Technical Reference Manual. US Army Corps of Engineers Institute for Water Resources (USACE), Davis, Calif. <http://www.hec.usace.army.mil/>.

**Iran Power and Water Resources Development Company (2006).** Review Report of Probable Maximum Flood (PMF) Studies, Bakhtiari Dam and Power Plant Design, Iranian Water and Power Resources Development Company, 110 p.

**Lee, S.C., Lin, H.T. and Yang, T.Y. (2010).** Artificial neural network analysis for reliability prediction of regional runoff utilization. Environmental Monitoring and Assessment, 161(1–4), pp: 315–326.

**May, R.J., Dandy, G.C., Maier, H.R. and Nixon, J.B. (2008).** Application of partial mutual information variable selection to ANN forecasting of water quality in water distribution systems. Environmental Modelling and Software, 23(10–11), pp:1289–1299.

**May, R.J., Maier, H.R., Dandy, G.C. and Fernando, T.M.K.G. (2008).** Non-linear variable selection for artificial neural networks using partial mutual information. Environ. Environmental Modelling & Software, 23(10), pp:1312-1326.

**Miguélez, M., Puertas, J. and Rabuñal, J.R. (2009).** Artificial neural networks in urban runoff forecast. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). 5517 LNCS (PART 1), pp:1192–1199.

**Nash, J.E. and Sutcliffe, J.V. (1970).** River flow forecasting through conceptual models; part I: A discussion of principles. Journal of Hydrology, 10, pp: 282-290.

**Pearson, R.K. (2002).** Outliers in process modeling and identification. IEEE Transactions on Control Systems Technology, 10(1), pp: 55–63.

**Shannon C.E. (1948).** A mathematical theory of communication. Bell System Technical Journal, 27, pp: 379–423.

**Sharma, A. (2000).** Seasonal to inter annual rainfall probabilistic forecasts for improved water supply management: part 1: A strategy for system predictor identification. Journal of Hydrology, 239, pp: 232–239.

**Solomatine, D. P. and Ostfeld, A. (2008).** Data-driven modelling: some past experiences and new approaches. Journal of Hydroinformatics, 10 (1), pp: 3-22.

**Tan, Q. F., Lei, X. H., Wang, X., Wang, H., Wen, X., Ji, Y. and Kang, A. Q. (2018).** An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach. *Journal of Hydrology*, 567, pp: 767-780.

## **Evaluation of GFF and RBF Neural Network Models and Soil Moisture Accounting Algorithm for HEC-HMS Model in Continuous Semi-Distributed Rainfall-Runoff Simulation in Jarahi Basin**

Navid Azarpisheh<sup>1</sup>, Alireza Nikbakht Shahbazi<sup>\*1</sup>, Hossein Fathian<sup>1</sup>

1) Department of Water Resources Engineering, Ahvaz Branch, Islamic Azad University, Ahvaz, Iran.

\*Correspondence Author: ar\_nikbakht@yahoo.com

Received Date: 2020. 10. 19

Accepted Date: 2021. 12. 06

### **Abstract**

Runoff estimation is effective way in utilization and allocation of water resources for various agricultural, drinking, hydraulic and environmental sectors. In this paper, continuous simulation of rainfall-runoff in the basin with two different models including HEC-HMS conceptual model and data-processing model (artificial neural networks) are considered to evaluate the ability and accuracy of these two models in estimating runoff. The continuous flow simulation was used to calculate soil moisture losses (SMA) in sub-basins. For calibration of the model, daily precipitation, flow, evapotranspiration data from 2001 to 2007 were used and for model accuracy period of 2008 to 2011 were used. The results showed that the HEC-HMS model, along with the SMA model, has a good ability to continuously simulations in dry and continuous periods in the basin. In order to select the input variables that affect the flow rate in artificial neural networks, a generalized feeder grid (GFF) and a radial base function grid (RBF), partial interpolation algorithm (PMI) was used. The results of using the PMI algorithm showed that the input variable influences the flow velocity at the Gargar hydrometric station, the current day flow rate at this station. The results showed that the GFF network has more efficiency and accuracy than the conceptual model of HEC-HMS and RBF network in continuous run-run run simulation in the basin. The Nash coefficient for HEC-HMS and GFF and RBF networks is 0.6, 0.6677 and 0.6676 respectively.

**Keywords:** PMI algorithm, Gargar station, Hampel test, Nash coefficient.