

## ارزیابی رتبه‌ای دو رویکرد مدل‌سازی داده‌مبناء و مفهومی فرآیند بارش - رواناب در مقیاس زمانی ماهانه

فرشته مدرسی<sup>۱</sup>، کیومرث ابراهیمی<sup>۲</sup>، شهاب عراقی نژاد<sup>۳</sup>

تاریخ ارسال: ۱۴۰۰/۰۳/۱۴

تاریخ پذیرش: ۱۴۰۰/۰۶/۰۶

مقاله پژوهشی

### چکیده

مدل‌سازی ماهانه فرآیند بارش- رواناب نقش مهمی در بهره‌برداری از سد‌ها دارد. در مقاله حاضر کارایی سه مدل داده‌مبناء شبکه عصبی مصنوعی (ANN)، شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) و K نزدیک‌ترین همسایگی (KNN) در مقایسه با مدل مفهومی IHACRES در مدل‌سازی ماهانه بارش- رواناب با داده‌های مشابه و ساختار بهینه مورد ارزیابی قرار گرفت. شبیه‌سازی جریان ماهانه ورودی به سد کرخه به عنوان مطالعه موردی انتخاب و از داده‌های مشاهده‌ای ۳۲ ساله (۱۳۶۱-۱۳۹۳) دما و بارش ماهانه و جریان ماهانه ورودی به سد استفاده شد. با توجه به متفاوت بودن الگوهای بارش- رواناب در ماه‌های مختلف، دو نوع ارزیابی کلی و ماهانه از کارایی مدل‌ها با استفاده از روش رتبه‌دهی و بر مبنای سه شاخص ارزیابی نش- ساتکلیف (NSE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) انجام شد. نتایج نشان داد که از هر دو روش ارزیابی مدل‌ها در مرحله صحت‌سنجی، دو مدل ANN و KNN به ترتیب دارای بیشترین و کمترین کارایی در تخمین جریان ماهانه بودند. بر اساس ارزیابی کلی رتبه‌ای مدل‌ها، کارایی دو مدل ANN (NSE=۰/۷۴۹ و R=۰/۸۶۸) و IHACRES (NSE=۰/۶۹۹ و R=۰/۸۴۲) با کسب ۸ امتیاز مشابه بود و دو مدل GRNN (NSE=۰/۶۱۸ و R=۰/۷۹۳) و KNN (NSE=۰/۶۰۱ و R=۰/۷۷۷) با کارایی مشابه (۵ امتیاز) در رتبه دوم قرار گرفتند. در حالیکه بر اساس روش ارزیابی رتبه‌ای ماهانه، دو مدل IHACRES و GRNN با کسب مجموع ۳۸ امتیاز مساوی از سه شاخص ارزیابی خطا دارای کارایی مشابه بوده و کارایی آنها پس از مدل ANN با ۴۸ امتیاز در مقام دوم قرار گرفت.

واژه‌های کلیدی: رتبه‌بندی مدل‌ها، شبکه‌های عصبی، کرخه، مدل KNN، مدل IHACRES.

<sup>۱</sup> استادیار، گروه علوم و مهندسی آب، دانشگاه فردوسی مشهد. پست الکترونیک: FModaresi@ferdowsi.um.ac.ir

<sup>۲</sup> نویسنده مسئول و استاد، گروه مهندسی آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران. [EbrahimiK@ut.ac.ir](mailto:EbrahimiK@ut.ac.ir)

<sup>۳</sup> مهندس کنترل منابع آب در هیئت مدیره کنترل منابع آب ایالتی، ساکرامنتو، کالیفرنیا، امریکا، [Shahab.Araghinejad@stantec.com](mailto:Shahab.Araghinejad@stantec.com)

## مقدمه

از کارایی بهتر مدل IHACRES در مقایسه با مدل GR2M می‌باشد (زندى و همکاران، ۱۳۹۶).

علاوه بر مدل‌های مفهومی، مدل‌های داده‌مبناء نیز برای مدل‌سازی بارش- رواناب در مقیاس‌های زمانی کوتاه‌مدت و بلندمدت بکار می‌روند. این مدل‌ها به علت نداشتن محدودیت بازه زمانی متغیرهای ورودی، در مطالعات بلندمدت بیشتر بکار رفته و می‌توانند بخصوص در مدل‌سازی‌های بلندمدت جایگزین مناسبی برای مدل‌های مفهومی باشند. مطالعات نشان داده است که کارایی شبکه عصبی مصنوعی (ANN) برای مدل‌سازی فرآیند بارش- رواناب در مقیاس ماهانه نسبت به مدل‌های مفهومی Wetbal، SAS، SCRR و HBV مناسب‌تر بوده است (Nilsson et al, 2006; Tokar and Markus, 2000). با این وجود، کارایی مدل‌های داده‌مبناء نیز برای مدل‌سازی فرآیند بارش- رواناب متفاوت است؛ به‌طوریکه در تحقیقی، کارایی سه مدل از سری مدل‌های شبکه عصبی مصنوعی شامل شبکه عصبی انتشار به جلو (FFNN)، شبکه عصبی رگرسیون تعمیم یافته (GRNN) و شبکه عصبی شعاع مبناء (RBF) برای مدل‌سازی بارش- رواناب با کارایی مدل رگرسیون خطی چند متغیره (MLR) مقایسه شده و نتایج نشان‌دهنده برتری کارایی هر سه مدل شبکه عصبی مصنوعی نسبت به رگرسیون خطی و برتری مدل GRNN بر سایر مدل‌ها از نظر عدم تخمین مقدار منفی برای رواناب می‌باشد (Cigizoglu and Alp, 2004).

با توجه به اینکه مدل IHACRES نظیر مدل‌های داده‌مبناء قادر به مدل‌سازی ماهانه فرآیند بارش- رواناب با استفاده از داده‌های ماهانه است، در تعدادی از تحقیقات صورت گرفته، کارایی این مدل با برخی از مدل‌های داده‌مبناء برای مدل‌سازی جریان ماهانه مورد مقایسه و ارزیابی قرار گرفته است؛ از آن جمله، در تحقیقی، کارایی دو مدل استوکستیک ARIMA و DARMA، مدل داده‌مبناء شبکه عصبی مصنوعی (ANN)، مدل فیزیکی SWRRB و مدل مفهومی IHACRES برای مدل‌سازی فرآیند بارش- رواناب به منظور پیش‌بینی جریان ماهانه در حوضه کسلیان مورد ارزیابی قرار گرفته است (Ghanbarpour et al, 2012). نتایج حاصل از این

یکی از فرآیندهای اصلی در چرخه هیدرولوژیکی، فرآیند بارش- رواناب است. مدل‌سازی این فرآیند در مقیاس ماهانه اهمیت ویژه‌ای در تخمین جریان ورودی به سدها و در نتیجه تدوین قوانین و منحنی‌های بهره‌برداری از آنها دارد. مدل‌سازی فرآیند بارش- رواناب با استفاده از مدل‌های مفهومی به علت بکارگیری عوامل اثرگذار بر پیدایش جریان، از دقت مناسبی برخوردار است؛ اما محدودیت اصلی اکثر مدل‌های مفهومی، مقیاس زمانی داده‌های موردنیاز آنها است که حداکثر در مقیاس زمانی روزانه می‌باشد و برای شبیه‌سازی‌های بلندمدت‌تر نظیر ماهانه نیز نیازمند به اطلاعات کوتاه‌مدت ساعتی و روزانه می‌باشند. این در حالی است که تهیه داده با مقیاس‌های زمانی کمتر از ماهانه بسیار مشکل بوده و در صورت وجود، داده‌ها طول دوره زمانی کوتاهی را پوشش می‌دهند. تنها مدل مفهومی که برای مدل‌سازی ماهانه فرآیند بارش- رواناب، از داده‌های ورودی ماهانه استفاده می‌کند، مدل IHACRES می‌باشد. از این‌روی، در مطالعات مربوطه مورد توجه محققین قرار گرفته است (رزاقیان و همکاران، ۱۳۹۵). نتایج مطالعات نشان می‌دهد که با وجود آنکه مدل IHACRES، مدل ساده‌ای است و نسبت به مدل‌های مفهومی دیگر نظیر HEC-HMS، SWAT، SIMHYD و HBV از تعداد پارامترهای کمتری برای واسنجی بهره می‌برد، نتایج آن برای شبیه‌سازی جریان روزانه از مدل‌های HEC-HMS و SYMHYD بهتر بوده و در مقایسه با SWAT و HBV از دقت مناسبی برخوردار است و در شرایط کمبود داده می‌تواند جایگزین مناسبی برای این مدل‌ها باشد (گودرزی و همکاران، ۱۳۹۱؛ یعقوبی و مساح بوانی، ۱۳۹۳). همچنین، نتایج تحقیقات نشان داده است که این مدل برای تخمین جریان ماهانه نیز از دقت مناسب برخوردار است؛ چنانکه در تحقیقی، کارایی مدل‌های مفهومی IHACRES و GR2M برای تخمین جریان ماهانه در حوضه آبریز دره تخت لرستان مورد ارزیابی قرار گرفته و با شرایط کمبود داده، دوره‌های زمانی چهار ساله (۱۳۸۴-۱۳۸۸ و ۱۳۹۲-۱۳۸۸) برای واسنجی و صحت سنجی مدل‌ها استفاده شده است. نتایج این تحقیق حاکی



ماه‌ها بوده است. این در حالی است که الگوهای بارش-رواناب در ماه‌های مختلف سال، متغیر است و این امر سبب می‌شود که کارایی مدل‌ها در تخمین جریان برای ماه‌های مختلف، متفاوت باشد؛ ولی این مسئله در ارزیابی مدل‌ها در مطالعات پیشین در نظر گرفته نشده است. از سوی دیگر، مطالعات صورت گرفته نشان می‌دهد که مدل شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) در فرآیندهای پیش‌بینی هیدرولوژیکی کارایی مناسب و قابل قبولی را ارائه داده است (Cigizoglu, 2005; Kisi, 2008; Modaresi et al, 2018)؛ ولی کارایی آن برای مدل‌سازی بارش-رواناب فقط در ترکیه و تنها نسبت به مدل ANN سنجیده شده (Cigizoglu and Alp, 2004) و نسبت به مدل‌های KNN و IHACRES مورد ارزیابی قرار نگرفته است. از این‌رو در مطالعه حاضر برآنیم تا کارایی مدل‌های داده مبنای شبکه عصبی مصنوعی (ANN)، شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) و K نزدیک‌ترین همسایگی (KNN) را در مقایسه با یکدیگر و در مقایسه با مدل مفهومی IHACRES در فرآیند مدل‌سازی ماهانه بارش-رواناب از دو جنبه کلی و ماهانه و بر مبنای روش رتبه‌بندی بر اساس سه شاخص ارزیابی نش-ساتکلیف (NSE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) مورد ارزیابی قرار دهیم. از آنجایی که نوع داده‌های ورودی و ساختار بکار گرفته شده برای مدل‌ها بر نتایج آنها اثرگذار است، در تحقیق حاضر، از ورودی‌های یکسان برای تمامی مدل‌ها استفاده شده است و تمامی مدل‌ها با ساختاری بهینه بکار گرفته شدند که این ساختار، حاصل از بکارگیری روش صحت سنجی متقاطع (LOOCV<sup>1</sup>) بر مبنای روش سعی و خطا (با استفاده از کد نویسی) می‌باشد و براساس تمامی مقادیر ممکن هر یک از پارامترهای مدل‌ها صورت گرفته است.

## مواد و روش‌ها

### معرفی منطقه مطالعاتی

در تحقیق حاضر حوضه کرخه به عنوان منطقه مطالعاتی انتخاب شد. سد کرخه، سد اصلی حوضه کرخه

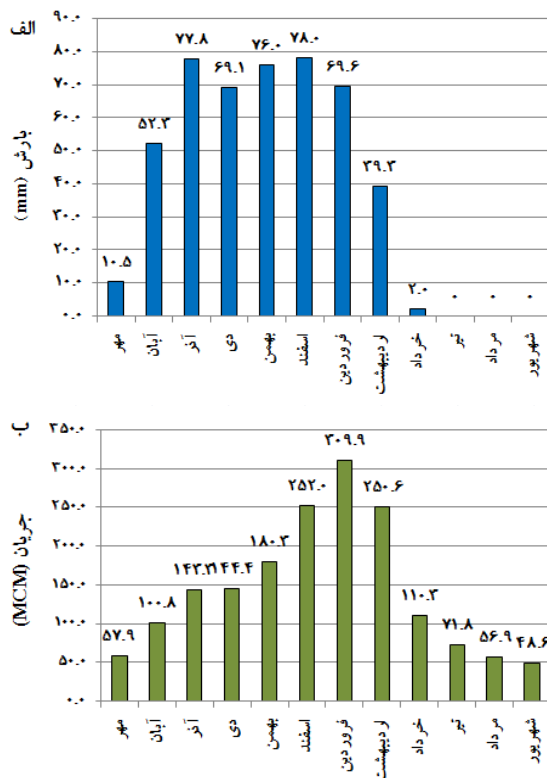
تحقیق نشان داده است که دو مدل شبکه عصبی مصنوعی و IHACRES بهترین کارایی را داشته و حتی کارایی مدل شبکه عصبی از IHACRES نیز بهتر بوده است ولی سایر مدل‌ها کارایی مناسبی را از خود نشان نداده‌اند. همچنین، نتایج بدست آمده از این تحقیق نشان داده است که در شرایط کمبود داده، کارایی مدل مفهومی توده‌ای IHACRES بسیار بهتر از مدل فیزیکی SWRRB است. در تحقیق دیگری، کارایی مدل IHACRES برای شبیه‌سازی و پیش‌بینی جریان ماهانه رودخانه ارازکوسه در استان گلستان با مدل‌های داده‌مبنای K نزدیک‌ترین همسایگی (KNN) و M5 مورد مقایسه و ارزیابی قرار گرفته است. بر اساس نتایج این تحقیق مدل IHACRES از دقت بالایی برخوردار بوده است ولی مدل‌های KNN و M5 نتایجی با دقت بالاتر را ارائه کرده‌اند (قربانی و همکاران، ۱۳۹۵). کارایی مدل‌های مفهومی IHACRES و HEC-HMS برای شبیه‌سازی جریان ماهانه رودخانه ليقوان استان آذربایجان شرقی در مقایسه با مدل‌های شبکه عصبی (ANN)، رگرسیون خطی چند متغیره (MLR) و ساده (SLR) نیز در تحقیق دیگری مورد مقایسه و ارزیابی قرار گرفته است و براساس نتایج تحقیق مذکور، همه مدل‌ها بجز مدل SLR برای تخمین جریان نرمال از کارایی و دقت مناسبی برخوردار بودند؛ در این میان، دو مدل مفهومی دبی پیک را بیش برآورد و مدل MLR دبی پیک را کم برآورد کرده‌اند، در حالیکه شبکه عصبی برای تخمین دبی پیک از دقت مناسب برخوردار بوده است (Sadeghi and Rahimi, 2017).

نکته قابل توجه در تحقیقات مقایسه‌ای صورت گرفته پیشین (که در بالا ارائه شد) مبنی بر مقایسه کارایی مدل‌های داده مبنای IHACRES در این است که در این تحقیقات، ورودی‌های مدل‌های داده مبنای متفاوت از مدل IHACRES در نظر گرفته شده است و با توجه به اهمیت نوع داده‌های ورودی مدل‌ها، این امر سبب می‌گردد که مقایسه درستی میان مدل‌ها صورت نگیرد. همچنین، ارزیابی‌های صورت گرفته از مدل‌ها برای مدل‌سازی ماهانه بارش-رواناب در تمامی تحقیقات به صورت کلی از مجموع

<sup>1</sup> Leave One Out Cross Validation

دما می‌باشد. از این‌رو، در مطالعه حاضر برای مدل‌سازی ماهانه فرآیند بارش- رواناب تنها از متغیر بارش ماهانه برای تخمین جریان ماهانه استفاده شده است.

مطالعات صورت گرفته نشان می‌دهد که متوسط بارش ماهانه این زیرحوضه و متوسط حجم جریان ماهانه ورودی به سد کرخه در طول دوره مطالعاتی به ترتیب برابر با ۵۲/۷ میلی‌متر و ۱۴۳/۹ میلیون مترمکعب بوده است و بارش اصلی این زیرحوضه در ماه‌های آبان تا اردیبهشت رخ می‌دهد (مدرسی و همکاران، ۱۳۹۵). در شکل ۲، توزیع بارش و جریان ماهانه در این بازه زمانی نشان داده شده است.



شکل (۲): نحوه توزیع ماهانه بارش بر حسب میلی‌متر (الف) و جریان بر حسب میلیون متر مکعب (ب) در زیرحوضه کرخه

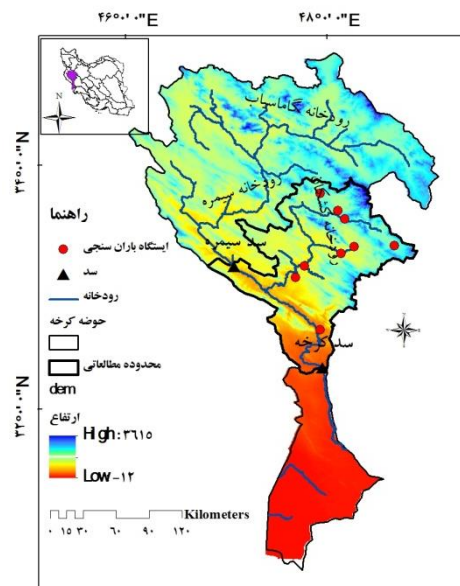
#### مدل‌های بکار رفته در تحقیق

در این بخش، ساختار مدل‌های بکار رفته در تحقیق و پارامترهای بهینه شده آنها به‌طور خلاصه بیان شده است.

#### ۱- مدل شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی یک مدل داده‌مبناست که قادر به نگاشت انواع توابع پیچیده خطی و غیرخطی می‌باشد. در تحقیق حاضر، یک مدل شبکه عصبی سه لایه پیشخور با

و در پایین دست سد سیمره در طول جغرافیایی  $48^{\circ}07'31''$  و عرض جغرافیایی  $32^{\circ}29'22''$  بر روی رودخانه کرخه ساخته شده است. از این‌رو، حوضه کرخه را می‌توان به دو زیرحوضه در بالادست سد سیمره و بالادست سد کرخه تقسیم نمود. با توجه به اهمیت سد کرخه در تأمین آب کشاورزی جلگه خوزستان، در این تحقیق، مدل‌سازی فرآیند بارش- رواناب در زیرحوضه بالادست سد کرخه مورد ارزیابی قرار گرفته است که مساحت آن حدود ۱۴۴۳۰ کیلومتر مربع است (شکل ۱).



شکل (۱): موقعیت زیرحوضه مطالعاتی و ایستگاه‌های هواشناسی آن

به منظور انجام این تحقیق از آمار جریان ماهانه در ایستگاه هیدرومتری سد کرخه واقع در محل ورودی جریان به مخزن سد کرخه و آمار متوسط بارش و دمای ماهانه ۹ ایستگاه باران‌سنجی و سینوپتیک بالادست سد واقع در زیرحوضه مطالعاتی در بازه زمانی ۳۲ ساله (۱۳۶۱-۱۳۹۳) استفاده شد (شکل ۱) که ۲۲ سال آن (۱۳۶۱-۱۳۸۲) برای واسنجی و ۱۰ سال دیگر (۱۳۸۳-۱۳۹۳) برای صحت سنجی مدل‌ها بکار برده شد. ارزیابی ضریب همبستگی میان متغیر دما و جریان رودخانه در منطقه مطالعاتی نشان داد که در سطح اطمینان ۹۵٪ همبستگی معنی‌داری میان دما با تأخیر زمانی یک تا سه ماه و جریان ماهانه وجود ندارد که این امر ناشی از عدم اثرپذیری مستقیم جریان از



### ۳- مدل رگرسیون K نزدیک‌ترین همسایگی (KNN)

مدل رگرسیون KNN یک مدل رگرسیون ناپارامتری است که برای رگرسیون و طبقه‌بندی کاربرد دارد (فدایی و همکاران، ۱۳۹۶). در این مدل بجای تعریف یک رابطه پارامتری از پیش تعیین شده (نظیر مدل رگرسیون خطی) بین متغیرها، از اطلاعات به‌دست آمده از K داده مشاهداتی که مشابه‌ترین داده‌ها به داده واقعی هستند، استفاده می‌شود. برای شناسایی مشابه‌ترین داده‌ها به داده واقعی، در این مدل از تابع فاصله اقلیدسی استفاده می‌شود. در این مدل، انتخاب تعداد همسایه‌های مشابه (K) بر دقت نتایج اثرگذار است که در تحقیق حاضر، مقدار بهینه آن توسط روش LOOCV تعیین شد.

### ۴- مدل مفهومی IHACRES

مدل IHACRES یک مدل مفهومی آماری است که برای شبیه‌سازی فرآیند بارش- رواناب از دو مدول خطی و غیرخطی که به صورت سری به یکدیگر مرتبط شده‌اند، استفاده می‌کند که در مدول غیرخطی بارش مؤثر و در مدول خطی جریان رودخانه محاسبه می‌شود (IHACRES user guide, 2003).

این مدل برای مدل‌سازی فرآیند بارش- رواناب فقط به مساحت حوضه و سری‌های زمانی متغیرهای بارش و جریان رودخانه به عنوان متغیرهای اصلی نیازمند است و متغیر دما نیز در این مدل به عنوان یک متغیر اختیاری برای محاسبه بارش مؤثر کاربرد دارد. از آنجایی که در مدل‌های مفهومی، داده‌ها حداکثر می‌توانند دارای گام‌های زمانی روزانه باشند، امکان استفاده از گام زمانی ماهانه در این مدل یک مزیت ارزشمند می‌باشد که در تحقیق حاضر نیز از داده‌ها در بازه‌های زمانی ماهانه استفاده شد.

برای تنظیم مدل IHACRES و واسنجی آن لازم است که دو پارامتر زمان تأخیر ( $\Omega$ ) و ثابت زمانی خشکی حوضه ( $\tau_w$ ) برای مدل تعیین شود. تعیین مقادیر بهینه این دو پارامتر باید توسط کاربر و به روش سعی و خطا صورت پذیرد. از این‌رو، در این تحقیق از روش صحت‌سنجی متقاطع برای تعیین مقادیر بهینه دو پارامتر

اتصال کامل و انتشار رو به عقب ( $FFBP^1$ ) بکار رفت که تعداد نورون‌های لایه ابتدایی و انتهایی آن به ترتیب برابر با تعداد متغیرهای ورودی (بارش) و خروجی (رواناب) می‌باشد؛ در حالیکه، تعداد نورون‌های لایه میانی آن، قابل تغییر است و باید توسط کاربر تعیین شود. علاوه بر تعداد نورون‌های لایه میانی، مقدار وزن اولیه و بایاس در اتصال نورون‌ها نیز بر دستیابی به نتایج بهینه توسط شبکه عصبی اثر گذار است (Araghinejad, 2014). از این‌رو در تحقیق حاضر، تعداد بهینه نورون‌های لایه میانی و نیز مقدار بهینه وزن‌ها و بایاس‌های اتصال نورون‌ها توسط روش صحت‌سنجی متقاطع (LOOCV) تعیین شد.

### ۲- مدل شبکه عصبی مصنوعی رگرسیون تعمیم یافته (GRNN)

شبکه عصبی رگرسیون تعمیم‌یافته یک شبکه عصبی سه لایه احتمالاتی است و در زمره شبکه‌های عصبی تابع پایه شعاعی (RBF) قرار دارد (Araghinejad, 2014). ساختار احتمالاتی این مدل سبب می‌شود که با مشکل مینیمم‌های محلی که اغلب شبکه‌های عصبی با آن مواجه هستند، روبرو نشود (Cigizoglu, 2005). در این شبکه، تعداد نورون‌های لایه ابتدایی و انتهایی نظیر سایر شبکه‌های عصبی برابر با تعداد متغیرهای ورودی و خروجی می‌باشد ولی تعداد نورون‌های لایه میانی آن بر خلاف شبکه‌عصبی ANN ثابت و مشخص بوده و برابر با تعداد داده‌های مشاهداتی (داده‌هایی که برای آموزش مدل بکار می‌روند) است. این مدل دارای پارامتری با نام پارامتر انتشار (Spread) است که تابع RBF را تنظیم می‌نماید و مقدار آن باید توسط کاربر تعیین شود. تعیین مقدار بهینه برای این پارامتر بر دستیابی به نتایج بهتر و با دقت بالاتر اثرگذار است؛ از این‌رو در تحقیق حاضر، مقدار بهینه این پارامتر توسط روش LOOCV تعیین شد.

<sup>1</sup> Feed Forward Back Propagation (FFBP)



می‌شود. در نهایت پس از انجام  $n$  بار صحت سنجی برای  $n$  داده‌های مشاهده‌ای، متوسط خطای مدل برای  $n$  بار صحت سنجی به عنوان خطای مدل برای آن مقدار مشخص از آن پارامتر در نظر گرفته می‌شود (Sammut and Webb, 2017). در تحقیق حاضر، این فرآیند برای هر مقدار ممکن از هر پارامتر بهینه شده متعلق به هر یک از مدل‌ها، با استفاده از کدنویسی در محیط نرم‌افزار MATLAB 2017 به صورت حلقه‌های تودرتو انجام شد و در نهایت، مقدار پارامتری که منجر به کمترین خطا در این فرآیند گردید، به عنوان بهترین مقدار برای آن پارامتر در نظر گرفته شد. در جدول ۱ پارامترهای بهینه شده هر مدل توسط روش LOOCV ارائه شده است.

زمان تأخیر و ثابت زمانی خشکی حوضه استفاده شد و بهترین حالت که مقدار پارامترها منجر به بروز کمترین خطا گردید، به عنوان بهترین ساختار برای مدل برگزیده شد.

### روش صحت‌سنجی متقاطع LOOCV در تعیین ساختار بهینه مدل‌ها

روش صحت‌سنجی متقاطع LOOCV یک روش صحت‌سنجی  $n$  لایه برای  $n$  داده‌های مشاهده‌ای است که در آن، مدل  $n$  بار بوسیله یک مقدار مشخص برای یک پارامتر مورد صحت‌سنجی قرار می‌گیرد و در هر بار صحت‌سنجی، مدل توسط تمامی داده‌ها بجز یکی از آنها آموزش دیده و سپس توسط آن یک داده کنار گذاشته شده، صحت سنجی

جدول (۱) پارامترهای بهینه شده مدل‌ها در تحقیق حاضر

پارامترهای بهینه شده	نام مدل
وزن‌ها ( $w$ ) و بایاس‌های ( $b$ ) اولیه و تعداد نورون‌های لایه میانی ( $M$ )	ANN
پارامتر تنظیم مدل ( $\text{Spread}$ )	GRNN
تعداد همسایگی‌ها ( $K$ )	KNN
زمان تأخیر ( $\underline{\Omega}$ ) و ثابت زمانی خشکی حوضه ( $\tau_w$ )	IHACRES

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (Q_t - \hat{Q}_t)^2}{n}} \quad (2)$$

$$R = \frac{\sum_{t=1}^N (Q_t - \bar{Q})(\hat{Q}_t - \bar{\hat{Q}})}{\sqrt{\sum_{t=1}^N (Q_t - \bar{Q})^2} \cdot \sqrt{\sum_{t=1}^N (\hat{Q}_t - \bar{\hat{Q}})^2}} \quad (3)$$

در روابط ۱، ۲ و ۳  $Q_t$  و  $\hat{Q}_t$  به ترتیب دبی‌های مشاهده‌ای و دبی تخمین زده شده در زمان  $t$ ،  $\bar{Q}$  و  $\bar{\hat{Q}}$  به ترتیب میانگین دبی‌های مشاهده‌ای و تخمین زده شده و  $N$  تعداد داده‌ها می‌باشد. دامنه تغییرات شاخص‌نش-ساتکلیف از منفی بی‌نهایت تا یک می‌باشد. هر چه مقدار این شاخص به یک نزدیک‌تر باشد، خطای مدل کمتر است. شاخص RMSE از صفر تا بی‌نهایت تغییر می‌کند. هر چه مقدار این شاخص به صفر نزدیک‌تر باشد، نشان‌دهنده خطای کمتر و کارایی بهتر مدل می‌باشد.

### شاخص‌های ارزیابی خطا

برای ارزیابی و مقایسه کارایی مدل‌های بکار رفته در این تحقیق از سه شاخص ارزیابی نش-ساتکلیف (NSE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) استفاده شد که به ترتیب در روابط ۱، ۲ و ۳ ارائه شده‌اند (Moriasi et al., 2017).

$$NSE = 1 - \frac{\sum_{t=1}^N (Q_t - \hat{Q}_t)^2}{\sum_{t=1}^N (Q_t - \bar{Q})^2} \quad (1)$$



ندارند. بنابراین، هر چه مقدار این شاخص به یک نزدیک‌تر باشد، کارایی مدل بهتر است و تغییرات مقادیر مشاهداتی و تخمین زده شده همسو می‌باشد. براساس شاخص‌های فوق، کارایی مدل‌ها را می‌توان به صورت جدول ۲ طبقه‌بندی نمود (Diaz-Ramirez et al., 2011; Moriasi et al., 2007).

مقدار شاخص ضریب همبستگی در دامنه منفی یک تا یک تغییر می‌کند. مقدار یک و منفی یک به ترتیب نشان دهنده همبستگی کامل و معکوس مقادیر مشاهداتی و شبیه‌سازی شده می‌باشد. همچنین، مقدار صفر این شاخص نشان می‌دهد که مقادیر مشاهداتی و شبیه‌سازی شده هیچ‌گونه همبستگی خطی معنی‌داری

جدول (۲): طبقه‌بندی کارایی مدل‌ها بر اساس شاخص‌های ارزیابی (Diaz-Ramirez et al., 2011; Moriasi et al., 2007)

شاخص‌های ارزیابی مدل‌ها	طبقه کارایی مدل‌ها		
R	RMSE	NSE	
$0.93 < R < 1.0$	$\leq RMSE \leq 0.5 SD^*$	$0.75 < NSE \leq 1$	بسیار خوب
$0.88 < R < 0.92$	$0.5 SD < RMSE \leq 0.6 SD$	$0.65 < NSE \leq 0.75$	خوب
$0.81 < R < 0.87$	$0.6 SD < RMSE \leq 0.7 SD$	$0.5 < NSE \leq 0.65$	مناسب
$R < 0.8$	$RMSE > 0.7 SD$	$NSE \leq 0.5$	نامناسب

\*SD= انحراف معیار

با توجه به جدول ۳ مشاهده می‌شود که براساس طبقه‌بندی ارائه شده برای کارایی مدل‌ها (جدول ۲)، کارایی هر چهار مدل در مرحله واسنجی بر اساس دو شاخص NSE و RMSE در مرتبه خوب و بر اساس شاخص R، کارایی مدل KNN در مرتبه خوب (R=0.929) و کارایی سایر مدل‌ها در مرتبه مناسب قرار دارد. همچنین، کارایی مدل IHACRES در مرحله واسنجی بر اساس هر سه شاخص ارزیابی بهتر از مدل‌های GRNN و ANN است.

## نتایج و بحث

در تحقیق حاضر، میزان همبستگی بارش ماهانه با تأخیر صفر تا سه ماه با جریان ماهانه برای تعیین بهترین متغیر ورودی به مدل‌های داده‌مبناء مورد ارزیابی قرار گرفت. نتایج نشان داد که بارش هر ماه دارای بیشترین همبستگی با جریان همان ماه است. همچنین، ارزیابی مقدار پارامتر زمان تأخیر ( $\Omega$ ) در مدل IHACRES نیز نشان داد که مقدار این پارامتر در ساختار بهینه مدل برابر با صفر است که نشان دهنده اثرگذاری بارش هر ماه بر مقدار جریان در همان ماه است. از این رو برای تخمین جریان ماهانه، از مقدار بارش در همان ماه استفاده شد تا مدل‌ها با شرایط ورودی مشابه و ساختار بهینه حاصل از روش صحت‌سنجی متقاطع مورد مقایسه و ارزیابی قرار گیرند.

در جدول ۳ نتایج ارزیابی کلی مدل‌ها در مراحل واسنجی و صحت‌سنجی بر اساس هر سه شاخص ارزیابی و نیز مقادیر بهینه پارامترهای مدل‌ها و در شکل ۳ (الف، ب، ج، د) مقادیر جریان مشاهداتی و شبیه‌سازی شده در مراحل واسنجی (۱۳۶۱-۱۳۸۲) و صحت‌سنجی (۱۳۸۳-۱۳۹۳) به ترتیب توسط مدل‌های ANN، GRNN، KNN و IHACRES ارائه شده است.

جدول (۳): نتایج ارزیابی مدل‌ها در مراحل واسنجی و صحت سنجی بر اساس شاخص‌های ارزیابی و مقادیر بهینه پارامترها

مقادیر بهینه پارامترها	صحت سنجی			آموزش (واسنجی)			نام مدل
	R	RMSE (MCM)	NSE	R	RMSE (MCM)	NSE	
$w=0.7, b=0.51, M=6$	0.868	67.312	0.749	0.817	74.723	0.658	ANN
Spread=0.67	0.793	83.163	0.618	0.830	71.690	0.685	GRNN
K=3	0.777	84.977	0.601	0.929	47.389	0.862	KNN
$\tau_w = 7, \Omega = 0^*$	0.842	73.793	0.699	0.845	69.719	0.702	IHACRES

\* مقدار صفر برای زمان تأخیر نشان می‌دهد که مدل از داده‌های همراه برای تخمین جریان در همان ماه استفاده کرده است.

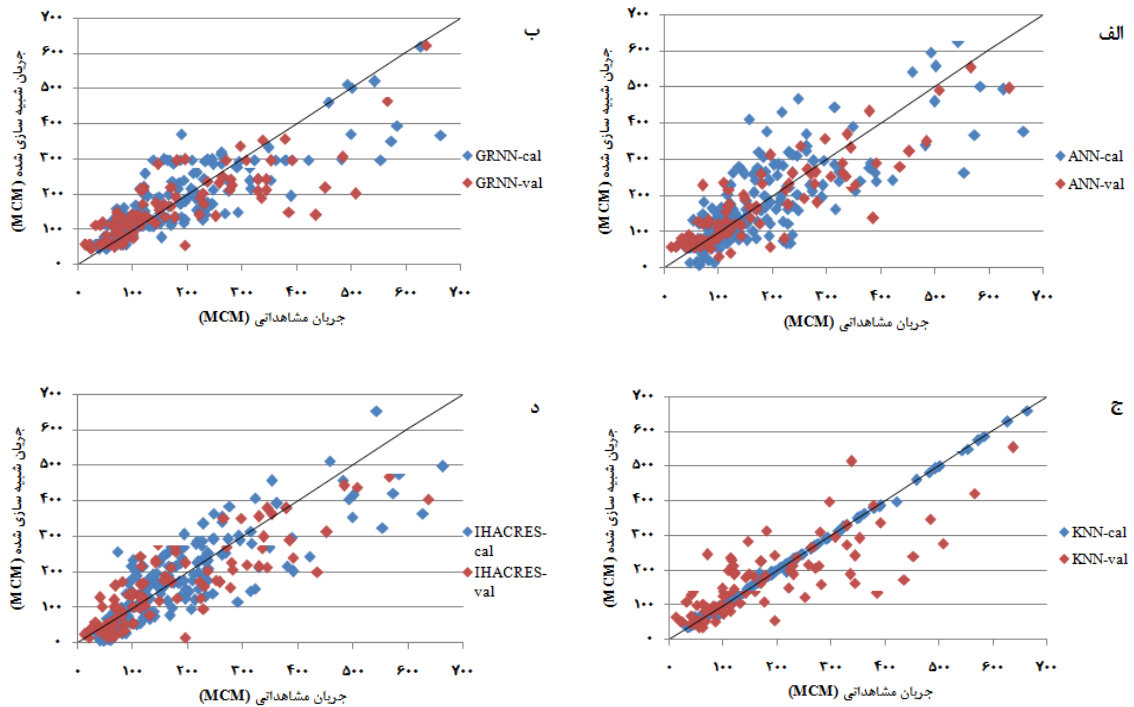
RMSE، NSE و R دارای کارایی مشابه می‌باشند؛ همچنین، کارایی دو مدل GRNN و KNN با کسب ۵ امتیاز (۲، ۲، ۱) نیز مشابه است.

با توجه به شکل ۳ مشاهده می‌شود که در هر دو مرحله واسنجی و صحت سنجی، تمامی مدل‌ها برآورد مناسبی از مقادیر کمینه و متوسط (از صفر تا حدود حجم MCM ۳۰۰) داشته‌اند و پراکندگی نقاط حول خط یک به یک است. با این وجود، در مقادیر بیشینه، مدل GRNN به طور مشخص در هر دو مرحله واسنجی و صحت سنجی و مدل KNN در مرحله صحت سنجی کم برآورد بوده است؛ ولی دو مدل IHACRES و ANN در هر دو مرحله واسنجی و صحت سنجی در برخی موارد بیش برآورد و در برخی موارد کم برآورد بوده‌اند که مقدار کم برآوردی در مدل IHACRES بیشتر از بیش برآوردی است.


با توجه به اینکه الگوی رابطه میان بارش و جریان رودخانه در ماه‌های مختلف متفاوت است و هدف از مدل‌سازی، ایجاد بهترین نتایج در مرحله صحت سنجی است، کارایی مدل‌ها در ماه‌های آبان تا اردیبهشت (ماه‌های اصلی بارش در حوضه کرخه) به‌طور جداگانه بر اساس سه شاخص NSE، RMSE و R در شکل ۴ (الف، ب و ج) در مرحله صحت‌سنجی مورد ارزیابی قرار گرفت.

برخلاف مرحله واسنجی، کارایی مدل ANN در مرحله صحت سنجی بر اساس هر سه شاخص ارزیابی بهتر از سایر مدل‌ها می‌باشد؛ پس از آن، مدل IHACRES با اندکی اختلاف از مدل ANN، دارای بهترین کارایی است. کارایی مدل‌های GRNN و KNN در مرحله صحت سنجی، با اندکی اختلاف با یکدیگر به ترتیب در مراتب سوم و چهارم قرار دارد. همچنین، بر اساس طبقه‌بندی ارائه شده برای کارایی مدل‌ها بر اساس شاخص‌های ارزیابی NSE و RMSE (جدول ۲)، کارایی دو مدل ANN ( $NSE=0.749$ ) و ( $RMSE=0.851$ ) IHACRES و ( $NSE=0.699$ ) و ( $RMSE=1.074$ ) در مرحله صحت سنجی در مرتبه خوب و دو مدل GRNN ( $NSE=0.618$ ) و ( $RMSE=1.001$ ) و KNN ( $NSE=0.601$ ) در مرتبه مناسب قرار دارد؛ ولی بر اساس شاخص R، کارایی دو مدل ANN ( $R=0.868$ ) و IHACRES ( $R=0.842$ ) در مرتبه مناسب و دو مدل GRNN ( $R=0.777$ ) و KNN ( $R=0.793$ ) نامناسب قرار دارد. بنابراین، با در نظر گرفتن امتیازهای ۴، ۳، ۲ و ۱ به ترتیب برای کلاس‌های کیفی کارایی بسیار خوب، خوب، مناسب و نامناسب بر اساس شاخص‌های ارزیابی، دو مدل ANN و IHACRES با کسب ۸ امتیاز (۳، ۳، ۲) به ترتیب از سه شاخص ارزیابی





شکل (۳): مقادیر جریان مشاهداتی و شبیه سازی شده توسط مدل های ANN (الف)، GRNN (ب)، KNN (ج) و IHACRES (د) در مراحل واسنجی (cal) و صحت سنجی (val)



شکل (۴): مقایسه ماهانه کارایی مدل ها بر اساس شاخص های نش-ساتکلیف (NSE) (الف)، RMSE (ب) و ضریب همبستگی (R) (ج)

نماید. با وجود آنکه کارایی این مدل در مجموع کل ماهها (نتایج جدول ۳) مشابه به مدل GRNN است، ولی بررسی ماهانه کارایی این مدل نشان می‌دهد که تنها در ماه بهمن کارایی این مدل از مدل GRNN بهتر بوده و در سایر ماهها کارایی آن کمتر از مدل GRNN بوده است.

با در نظر گرفتن امتیازهای ۴، ۳، ۲ و ۱ به ترتیب برای کلاس‌های کیفی کارایی بسیار خوب، خوب، مناسب و نامناسب بر اساس شاخص‌های ارزیابی (جدول ۲)، کارایی ماهانه مدل‌ها در مرحله صحت‌سنجی در جدول ۴ امتیازدهی شده است. بر مبنای مجموع امتیازاتی که هر مدل بر اساس هر سه شاخص ارزیابی در کل ماهها کسب کرده است می‌توان گفت که مدل ANN با مجموع ۴۸ امتیاز دارای بهترین کارایی و مدل KNN با مجموع ۳۵ امتیاز دارای کمترین کارایی در مدل‌سازی ماهانه فرآیند بارش- رواناب می‌باشد. همچنین، دو مدل GRNN و IHACRES با کسب مجموع ۳۸ امتیاز، دارای کارایی مشابه می‌باشند و کارایی آنها در رده دوم پس از مدل ANN قرار دارد.

با توجه به شکل ۴ (الف، ب و ج) مشاهده می‌شود که کارایی مدل IHACRES در شبیه‌سازی فرآیند بارش- رواناب در اسفند ماه به‌طور قابل ملاحظه‌ای بهتر از سایر مدل‌ها می‌باشد ( $NSE=0/554$ ،  $RMSE=0/554$  و  $R=0/793$ ). در دو ماه دی و بهمن نیز کارایی این مدل مشابه به مدل ANN و بسیار بهتر از دو مدل GRNN و KNN می‌باشد (در بهمن اندکی بهتر از ANN است) و به‌طور کلی، کارایی این مدل تنها در دو ماه آبان و اردیبهشت از سایر مدل‌ها کمتر بوده است. مدل ANN در ماه‌های آذر، دی، فروردین و اردیبهشت بهترین کارایی را داشته است. ارزیابی مدل GRNN نیز نشان می‌دهد که کارایی این مدل در شبیه‌سازی جریان ماه‌های دی، بهمن و اسفند مناسب نبوده است، ولی این مدل در ماه آبان، بهترین کارایی ( $NSE=0/726$ ،  $RMSE=0/586$  و  $R=0/853$ )، در ماه‌های آذر و فروردین کارایی مشابه با مدل IHACRES و در ماه اردیبهشت، کارایی مشابه با مدل ANN داشته است. ارزیابی کارایی مدل KNN نیز در مقایسه با سایر مدل‌ها نشان می‌دهد که این مدل در هیچ‌یک از ماه‌ها نتوانسته است بهترین نتایج را ایجاد

جدول (۴): نتایج امتیازبندی کارایی ماهانه مدل‌ها بر اساس کلاس‌های کیفی شاخص‌های ارزیابی

ماه	IHACRES			KNN			GRNN			ANN		
	R	RMSE	NSE	R	RMSE	NSE	R	RMSE	NSE	R	RMSE	NSE
آبان	۱	۱	۱	۲	۳	۳	۲	۳	۳	۲	۳	۳
آذر	۱	۲	۲	۲	۲	۲	۲	۲	۲	۲	۳	۳
دی	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱
بهمن	۳	۴	۴	۲	۱	۱	۲	۱	۱	۳	۳	۳
اسفند	۱	۲	۲	۱	۱	۱	۱	۱	۱	۱	۱	۱
فروردین	۱	۲	۲	۱	۱	۱	۱	۱	۱	۱	۲	۲
اردیبهشت	۲	۲	۲	۲	۳	۳	۳	۴	۴	۴	۴	۴
امتیاز کل	۳۸			۳۵			۳۸			۴۸		

حالت ارزیابی، مدل ANN و KNN به ترتیب دارای بیشترین و کمترین کارایی در مدل‌سازی بارش- رواناب در مرحله صحت‌سنجی می‌باشند؛ ولی نتایج ارزیابی

با مقایسه امتیازهای حاصل از ارزیابی کارایی مدل‌ها در حالت کلی و ماهانه مشاهده می‌شود که در هر دو



کمترین کارایی در مدل‌سازی فرآیند بارش- رواناب در مقیاس ماهانه بر اساس امتیازهای حاصل از هر سه شاخص ارزیابی می‌باشند. نتایج ارزیابی کارایی مدل‌ها در مجموع کل ماه‌ها با نتایج کارایی آنها به صورت جداگانه در هر ماه متفاوت بود؛ به طوری که ارزیابی رتبه‌ای کلی مدل‌ها گویای تشابه کارایی دو مدل GRNN و KNN (۵ امتیاز) و نیز تشابه کارایی مدل‌های ANN و IHACRES (۸ امتیاز) در مرحله صحت‌سنجی بود و کارایی مدل‌های GRNN و KNN در مقام دوم پس از دو مدل دیگر قرار گرفت ولی بر اساس ارزیابی ماهانه مدل‌ها، کارایی دو مدل IHACRES و GRNN با ۳۸ امتیاز بر اساس هر سه شاخص ارزیابی، مشابه و در مقاوم دوم پس از مدل ANN با ۴۸ امتیاز قرار گرفت. ارزیابی نتایج حاصل از تحقیق حاضر در مقایسه با تحقیق‌های پیشین نشان می‌دهد که نتایج تحقیق حاضر تأیید کننده نتایج پیشین مبنی بر کارایی مناسب مدل‌های IHACRES و ANN برای مدل‌سازی فرآیند بارش- رواناب می‌باشد (Ghanbarpour et al., 2012; Sadeghi and Rahimi, 2017). در مقابل، نتایج حاصل از این تحقیق به هر دو صورت کلی و ماهانه گویای کارایی کمتر مدل KNN در مقایسه با مدل IHACRES است و برخلاف نتایج پیشین (قربانی و همکاران، ۱۳۹۵) می‌باشد که ناشی از در نظر گرفتن متغیرهای ورودی متفاوت برای مدل‌ها در تحقیق مذکور است. همچنین نتایج به دست آمده از تحقیق حاضر تأیید کننده نتایج تحقیق انجام شده توسط Cigizoglu and Alp (2004) مبتنی بر عدم ایجاد جواب‌های منفی توسط مدل GRNN است ولی از نظر برتری کارایی ANN نسبت به GRNN، نتایج این تحقیق را تأیید نمی‌نماید.

از آنجایی که ارزیابی ماهانه مدل‌ها بر اساس کارایی آنها در تک تک ماه‌ها صورت گرفت، این نتایج قابلیت اطمینان بیشتری دارد. همچنین، با توجه به تفاوت کارایی مدل‌ها در ماه‌های مختلف، توصیه می‌شود که در ارزیابی مدل‌ها برای مدل‌سازی ماهانه، بجای ارزیابی کلی آنها، کارایی مدل‌ها به‌طور ماهانه مورد ارزیابی قرار

ماهانه نشان می‌دهد که کارایی مدل GRNN مشابه مدل IHACRES است در حالی که نتایج ارزیابی کلی گویای شباهت کارایی مدل GRNN به مدل KNN می‌باشد و از این منظر، نتایج این دو نوع ارزیابی با یکدیگر اختلاف دارند. از آنجایی که در ارزیابی ماهانه، کارایی مدل‌ها به صورت ماه به ماه ارزیابی شده است، این ارزیابی قابل اعتمادتر می‌باشد و در نتیجه کارایی مدل GRNN در مدل‌سازی فرآیند بارش- رواناب مشابه مدل IHACRES و در رتبه دوم پس از مدل ANN قرار دارد.

اختلاف کارایی یک مدل در ماه‌های متفاوت، به علت وجود الگوهای مختلف میان بارش و جریان رودخانه در ماه‌های مختلف است که ناشی از عواملی نظیر نوع بارش (باران یا برف)، میزان رطوبت خاک، مقدار و الگوی جریان پایه رودخانه می‌باشد که در مدل‌های داده‌مبنا و مدل IHACRES برای مدل‌سازی فرآیند بارش- رواناب این عوامل به‌طور جداگانه مورد مدل‌سازی قرار نمی‌گیرند. از این‌رو، با توجه به متفاوت بودن کارایی مدل‌ها در ماه‌های مختلف، ارزیابی ماهانه مدل‌ها به محققین در انتخاب مدل‌ها برای انجام فرآیند مدل‌سازی کمک می‌نماید؛ زیرا همان‌طور که در نتایج ماهانه مدل‌های مقاله حاضر مشاهده شد، در ماه‌هایی نظیر بهمن و اسفند که سه مدل داده‌مبنا قادر به مدل‌سازی مناسب جریان نمی‌باشند، مدل IHACRES توانسته است با دقت خوبی جریان را مدل‌سازی نماید.

### نتیجه‌گیری

در این مقاله، کارایی سه مدل داده‌مبنای ANN، GRNN و KNN در مقایسه با مدل مفهومی IHACRES برای مدل‌سازی فرآیند بارش- رواناب در حوضه کرخه در مقیاس زمانی ماهانه با داده‌های مشابه به دو صورت کلی (کل ماه‌ها) و ماهانه بر اساس روش ارزیابی رتبه‌ای مورد بررسی قرار گرفت. نتایج این تحقیق نشان داد که بر اساس هر دو نوع ارزیابی، مدل‌های ANN و KNN به ترتیب دارای بیشترین و

گیرد تا انتخاب صحیح‌تری در بکارگیری مدل‌ها انجام شود.

## تقدیر و تشکر

بدینوسیله از دانشگاه فردوسی مشهد، دانشگاه تهران و شرکت مدیریت منابع آب ایران به دلیل تأمین امکانات و داده‌های لازم جهت انجام این تحقیق و تهیه مقالات مربوطه تشکر و قدردانی می‌شود.

## منابع

- رزاقیان، ه.، شاهدی، ک. و حبیب نژاد روشن، م. ۱۳۹۵. ارزیابی اثر تغییر اقلیم بر رواناب حوضه آبریز بابلرود با استفاده از مدل IHACRES. مهندسی آبیاری و آب ایران، ۷ (۲): ۱۷۲-۱۵۹.
- زندى دره غریبی، ف.، خورسندی کوهانستانی، ز.، مزین، م. و آرمان، ن. ۱۳۹۶. مقایسه عملکرد دو مدل IHACRES و GR2M در شبیه‌سازی جریان ماهانه حوضه آبریز دره تخت. علوم و مهندسی آبیاری، ۴۰ (۲): ۱۵۸-۱۴۷.
- فدایی کرمانی، ا.، بارانی، غ.ع.، قائینی حصاروئی، م. ۱۳۹۶. کاربرد الگوریتم نزدیک‌ترین همسایگی در پیش‌بینی میزان آسیب‌پذیری سرریز سدها در اثر پدیده کاویتاسیون. مهندسی آبیاری و آب ایران، ۷ (۴): ۲۵-۱۵.
- قربانی، خ.، سهرابی، ا. و سالاری‌جزی، م. ۱۳۹۵. ارزیابی روش‌های هیدرولوژیکی و داده‌کاوی در شبیه‌سازی و پیش‌بینی دبی جریان ماهانه (مطالعه موردی: ایستگاه هیدرومتری آرازکوسه). پژوهش‌های حفاظت آب و خاک، ۲۳ (۱): ۲۱۷-۲۰۳.
- گودرزی، م.ر.، ذهبیون، ب.، مساح بوانی، ع.ر. و کمال، ع.ر. ۱۳۹۱. مقایسه عملکرد سه مدل هیدرولوژیکی SWAT، IHACRES و SIMHYD در شبیه‌سازی رواناب حوضه قره‌سو. مدیریت آب و آبیاری، ۲ (۱): ۴۰-۲۵.
- مدرسی، ف.، عراقی‌نژاد، ش. و ابراهیمی، ک. ۱۳۹۵. توسعه سامانه پیش‌بینی بلندمدت هیدرولوژیکی بر اساس ترکیب مدل‌های داده‌مبنا. دانشگاه تهران. تهران. رساله دکتری.
- یعقوبی، م. و مساح بوانی، ع. ۱۳۹۳. تحلیل حساسیت و مقایسه عملکرد سه مدل مفهومی IHACRES، HBV و HEC-HMS در شبیه‌سازی بارش- رواناب پیوسته در حوضه‌های نیمه خشک (بررسی موردی: حوضه اعظم هرات-یزد). فیزیک زمین و فضا، ۴۰ (۲): ۱۵۳-۱۷۲.
- Araghinejad, S. 2014. Data-Driven Modeling: Using MATLAB in Water Resources and Environmental Engineering. 1st Ed. Water Science and Technology Library, Springer, Volume (67), 265p.
- Cigizoglu, H. K. and M. Alp. 2004. Rainfall-runoff modeling using three neural network methods. Artificial Intelligence and Soft Computing, 3070: 166-171.
- Cigizoglu, H. K. 2005. Generalized regression neural network in monthly flow forecasting. Civil Engineering and Environmental Systems, 22(2): 71-81.
- Diaz-Ramirez, J. N., W. H. McAnally, J. L. Martin. 2011. Analysis of hydrological processes applying the HSPF model in selected watersheds in Alabama, Mississippi, and Puerto Rico. Applied Engineering in Agriculture, 27 (6): 937-954.
- Ghanbarpour, M. R., M. Amiri, M. Zarei and Z. Darvari. 2012. Comparison of streamflow predicted in a forest watershed using different modeling procedures: ARMA, ANN, SWRRB, and IHACRES models. River Basin Management, 10 (3): 281-292.
- IHACRES user guide, Version 1.02, September 2003.
- Kişi, Ö. 2008. River flow forecasting and estimation using different artificial neural network techniques. Hydrology Research, 39(1): 27-40.



Modaresi, F., S. Araghinejad and K. Ebrahimi. 2018. A comparative assessment of Artificial Neural Network, Generalized Regression Neural Network, Least-Square Support Vector Regression, and K- Nearest Neighbor Regression for monthly streamflow forecasting in linear and nonlinear conditions. *Water Resources Management*, 32(1):243-258.

Moriasi, D. N., J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel, T. L. Veith. 2007. Model evaluation guidelines for systemic quantification of accuracy in watershed simulations. *Transactions of ASABE*, 50(3): 885-900.

Nilsson, P., C. B. Uvo, R. Berndtsson. 2006. Monthly runoff simulation: comparing and combining conceptual and neural network models. *Hydrology*, 321: 344-363.

Sadeghi Loyeh, N. and M. Rahimi Jamnani. 2017. Comparison of different rainfall-runoff models performance: A case study of Liqvan catchment, Iran. *European Water*, 57: 315-322.

Sammut, C. and G. I. Webb. 2017. *Encyclopedia of machine learning and data mining*. Springer. doi: 10.1007/978-1-4899-7687-1. 1744p.

Tokar, A. S. and M. Markus. 2000. Precipitation-runoff modeling using artificial neural networks and conceptual models. *Hydrologic Engineering*, 5 (2): 156-161.



## Ranking Evaluation of Data-driven and Conceptual Modelling of Rainfall-Runoff Process in Monthly Time Scale

Fereshteh Modaresi<sup>1</sup>, Kumars Ebrahimi<sup>2\*</sup> and Shahab Araghinejad<sup>3</sup>

### Abstract

Rainfall-runoff monthly modelling process plays an important role in dams' operation. Herein the performances of three data-based models including Artificial Neural Network (ANN), Generalized Regression Neural Network (GRNN) and K-Nearest Neighbor (KNN) are compared in tandem with IHACRES conceptual model, while they were applied with similar data, and optimal structures. Simulation of monthly inflow to Karkheh reservoir, Iran, was considered as the case study, and 32-year data (1982-2014) of monthly temperature and precipitation belong to the upper sub-basin of the dam, and monthly inflow to the reservoir were used. With respect to the different rainfall-runoff patterns in different months, the models assessed in a general and monthly manners using a rating method based on performance criteria including: Nash-Sutcliffe Efficiency (NSE), Root Mean Square Error (RMSE) and Correlation Coefficient (R). Results showed that both model evaluation procedure in validation phase, ANN and KNN models have the highest and lowest efficiency in monthly streamflow forecasting, respectively. Based on the rating general evaluation the performance of ANN (NSE= 0.749, R= 0.868) and IHACRES (NSE= 0.699, R= 0.842) are similar with a score of 8 while the GRNN (NSE= 0.618, R= 0.793) and KNN (NSE= 0.601, R= 0.777) models with similar performance (score 5) were ranked in the second order. However, in accordance with rating monthly assessment of the models, the performance of GRNN was similar to IHACRES with the total score of 38 based on three criteria while they were ranked in the second order after ANN model with score 48.

**Key Words:** Neural Networks, IHACRES, Karkheh, KNN, Ranking Method.

---

<sup>1</sup> Assistant Professor, Ferdowsi University of Mashhad, Iran, Email: [FModaresi@ferdowsi.um.ac.ir](mailto:FModaresi@ferdowsi.um.ac.ir)

<sup>2</sup> Professor, University of Tehran, Iran. Email: [EbrahimiK@ut.ac.ir](mailto:EbrahimiK@ut.ac.ir) (Corresponding Author)\*

<sup>3</sup> Water Resource Control Engineer at State Water Resources Control Board, Sacramento, California, USA,

[Shahab.Araghinejad@stantec.com](mailto:Shahab.Araghinejad@stantec.com)

## Research Paper

**Ranking Evaluation of Data-driven and Conceptual Modelling of Rainfall-Runoff Process in Monthly Time Scale**Fereshteh Modaresi<sup>1</sup>,Kumars Ebrahimi<sup>2\*</sup>,Shahab Araghinejad<sup>3</sup>

<sup>1</sup> Assistant Professor, Department of Water Science and Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad, [FModaresi@ferdowsi.um.ac.ir](mailto:FModaresi@ferdowsi.um.ac.ir)

<sup>2</sup> Professor, Department of Irrigation and Reclamation Engineering, Faculty of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. [EbrahimiK@ut.ac.ir](mailto:EbrahimiK@ut.ac.ir)

<sup>3</sup> Water Resource Control Engineer at State Water Resources Control Board, Sacramento, California, USA, [Shahab.Araghinejad@stantec.com](mailto:Shahab.Araghinejad@stantec.com)



10.22125/IWE.2020.168536.1054

Received:

**June.14.2021**

Accepted:

**July.28.2021**

Available online:

**June.01.2022**

Keywords:

**Neural networks, IHACRES, Karkheh, KNN, ranking method****Abstract**

Rainfall-runoff monthly modelling process plays an important role in dams' operation. Herein the performances of three data-based models including Artificial Neural Network (ANN), Generalized Regression Neural Network (GRNN) and K-Nearest Neighbor (KNN) are compared with IHACRES conceptual model, while they were applied with similar data, and optimal structures. Simulation of monthly inflow to Karkheh reservoir, Iran, was considered as the case study, and 32-year data (1982-2014) of monthly temperature and precipitation belong to the upper sub-basin of the dam, and monthly inflow to the reservoir were used. With respect to the different rainfall-runoff patterns in different months, the models assessed in a general and monthly manners using a rating method based on performance criteria including: Nash-Sutcliff Efficiency (NSE), Root Mean Square Error (RMSE) and Correlation Coefficient(R). Results showed that in both model evaluation procedures in validation phase, ANN and KNN models have the highest and lowest efficiency in monthly streamflow forecasting, respectively. Based on the rating general evaluation the performance of ANN (NSE= 0.749, R= 0.868) and IHACRES (NSE= 0.699, R= 0.842) are similar with a score of 8 while the GRNN (NSE= 0.618, R= 0.793) and KNN (NSE= 0.601, R= 0.777) models with similar performance (score 5) were ranked in the second order. However, in accordance with rating monthly assessment of the models, the performance of GRNN was similar to IHACRES with the total score of 38 based on three criteria while they were ranked in the second order after ANN model with score 48.

\* **Corresponding Author:** Kumars Ebrahimi

**Address:** Department of Irrigation and Reclamation Engineering, University of Tehran, Iran

**Email:** [EbrahimiK@ut.ac.ir](mailto:EbrahimiK@ut.ac.ir)

**Tel:** +98 26 32226181

## 1. Introduction

Rainfall-runoff modeling in monthly scale is of importance in estimation of inflow to the reservoir of dams and development of operation rule curves for dams. Conceptual modeling of rainfall-runoff process enjoy proper accuracy because of applying all of the effective factors. However, the main limitation of this modeling is time scale of input data which can be maximum in daily scale while long-time modeling using this type of models even requires short-time data, the preparation of which is very difficult. IHACRES is the only conceptual model that uses monthly data to model monthly runoff. So, data-driven models are good alternatives for monthly rainfall-runoff modeling. In this study, the performance of three data driven models are compared with each other and with IHACRES conceptual model for rainfall-runoff modeling while they are assessed monthly and totally (based of all months) on the basis of ranking method.

## 2. Materials and Methods

In current research, Karkheh basin was selected as case study and the inflow to Karkheh dam was forecasted. For this purpose, 32-year monthly rainfall and runoff data in the period of 1982-2014 were used. In this study, the performance of Artificial Neural Network (ANN), Generalized Regression Neural Network (GRNN) and K- Nearest Neighbor model (KNN) was compared to IHACRES conceptual model for rainfall-runoff modeling. In order to set the parameters of all models, the n-fold cross validation method was applied, and the performance of models was evaluated based on three assessment criteria including Nash-Sutcliff Efficiency (NSE), Root Mean Square Error (RMSE), and Pearson Correlation Coefficient (R).

## 3. Results

Results show that in general assessment the efficiency of all models in calibration phase are good while the accuracy of ANN results (NSE= 0.749, R= 0.868) in validation phase is better than other models. The accuracy of IHACRES (NSE= 0.699, R= 0.842) results are placed in the second rank whereas GRNN (NSE= 0.618, R= 0.793) and KNN (NSE= 0.601, R= 0.777) are in third and fourth ranks. Based on ranking models according to assessment criteria, the efficiency of IHACRES model is similar to ANN model whilst that of GRNN and KNN are similar. However, monthly assessment of the model results indicates that ANN and KNN models are the best and worst models, respectively while the performance of GRNN and IHACRES are similar.

## 4. Discussion and Conclusion

With respect to the results of this study, it can be concluded that monthly assessment of models reveals the performance of the models in a better way and the obtained results is more confident as compared to the condition that all of the model result in all months are evaluated in general.

## 5. Six important references

1. Araghinejad, S. 2014. Data-Driven Modeling: Using MATLAB in Water Resources and Environmental Engineering, 1<sup>st</sup> Ed. Water Science and Technology Library, Springer, Volume (67), 265p.
2. Cigizoglu, H. K. and M. Alp. 2004. Rainfall-runoff modeling using three neural network methods. *Artificial Intelligence and Soft Computing*, 3070: 166-171.
3. Kişi, Ö. 2008. River flow forecasting and estimation using different artificial neural network techniques. *Hydrology Research*, 39(1): 27–40.
4. Modaresi, F., S. Araghinejad and K. Ebrahimi. 2018. A comparative assessment of Artificial Neural Network, Generalized Regression Neural Network, Least-Square Support Vector Regression, and K- Nearest Neighbor Regression for monthly streamflow forecasting in linear and nonlinear conditions. *Water Resources Management*, 32(1):243-258.
5. Moriasi, D. N., J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel, T. L. Veith. 2007. Model evaluation guidelines for systemic quantification of accuracy in watershed simulations. *Transactions of ASABE*, 50(3): 885-900.
6. Nilsson, P., C. B. Uvo, R. Berndtsson. 2006. Monthly runoff simulation: comparing and combining conceptual and neural network models. *Hydrology*, 321: 344–363.

## Conflict of Interest

Authors declared no conflict of interest.