

ارزیابی کارایی دو مدل احتمالاتی شبکه عصبی رگرسیون تعمیم یافته (GRNN) و رگرسیون ناپارامتری K- نزدیک ترین همسایگی (KNN) برای مدل سازی ماهانه فرآیند بارش-رواناب

فرشته مدرسی

استادیار، گروه علوم و مهندسی آب، دانشگاه فردوسی مشهد
Fmodaresi@um.ac.ir



چکیده

یکی از فرآیندهای اصلی در مدل سازی هیدرولوژیکی حوضه های آبریز، فرآیند بارش- رواناب است و مدل سازی ماهانه آن در برنامه ریزی برای بهره برداری بلندمدت از منابع آب از اهمیت ویژه ای برخوردار است. با توجه به تعدد عوامل اثرگذار بر شکل گیری رواناب حاصل از بارش و عدم اندازه گیری دقیق مقادیر آنها در بلندمدت، مدل سازی بلندمدت این فرآیند، پیچیده و غیرخطی می باشد. از این رو، در تحقیق حاضر، کارایی دو مدل احتمالاتی شبکه عصبی رگرسیون تعمیم یافته (GRNN) و رگرسیون K- نزدیک ترین همسایگی که به ترتیب بر مبنای تابع پایه شعاعی و توابع کرنل می باشند، برای مدل سازی ماهانه فرآیند بارش- رواناب در حوضه بالادست سد کرخه مورد ارزیابی قرار گرفته است. به منظور تعیین پارامترهای اثرگذار بر هر یک از مدل ها، از روش صحت سنجی متقاطع LOOCV استفاده شده است. نتایج بدست آمده نشان می دهد که در حالت ارزیابی کلی از تمامی ماه ها، هر دو مدل از کارایی مناسبی برخوردارند و کارایی دو مدل، مشابه است ولی در حالت بررسی ماهانه بر اساس رده بندی شاخص های نش- ساتکلیف، RMSE و ضریب همبستگی، کارایی مدل GRNN بر KNN برتری دارد.

کلید واژه ها: مدل سازی ماهانه، بارش-رواناب، کرخه، صحت سنجی متقاطع، GRNN، KNN



مقدمه

یکی از مسائل اساسی در مدیریت بلندمدت حوضه آبریز، آگاهی از میزان منابع آب سطحی موجود می باشد. فرآیند بارش- رواناب اصلی ترین فرآیند هیدرولوژیکی یک حوضه آبریز است که میزان رواناب حاصل از بارش را تعیین می کند. در شکل گیری رواناب حاصل از بارش، عوامل بسیار گسترده و متنوعی اثر گذارند؛ از جمله این عوامل می توان به شیب زمین، جنس خاک، رطوبت موجود در خاک، میزان نفوذپذیری خاک، تراز آب زیر زمینی، نوع پوشش گیاهی، کاربری اراضی و ... اشاره نمود. تنوع و گستردگی عوامل اثرگذار بر این فرآیند نشان می دهد که فرآیند بارش- رواناب یک فرآیند غیرخطی و پیچیده است. از این رو استفاده از مدل هایی که قادر به مدل سازی شرایط پیچیده و غیر خطی باشند، نظیر انواع مدل های شبکه عصبی مصنوعی، ماشین بردار پشتیبان، K- نزدیک ترین همسایگی برای مدل سازی این فرآیند امری ضروری است. مطالعات صورت گرفته نشان می دهد که مدل های داده مبنا برای مدل سازی کوتاه مدت و بلندمدت جریان در

مقایسه با مدل های مفهومی از دقت مناسب و بالاتری برخوردارند؛ از آن جمله می توان به تحقیقات صورت گرفته زیر اشاره نمود:

Marku و Tokar (۲۰۰۰) نشان دادند که مدل شبکه عصبی مصنوعی (ANN) دارای کارایی بهتری نسبت به سه مدل مفهومی بیلان آب (Watbal)، محاسبه رطوبت خاک (SAS) و بارش - رواناب مفهومی ساده (SCRR) برای مدل سازی بارش - رواناب در مقیاس های روزانه و ماهانه در سه حوضه متفاوت در آمریکا است. تحقیق صورت گرفته توسط Nilsson و همکاران (۲۰۰۶) برای پیش بینی جریان ماهانه رودخانه در دو حوضه در نروژ نیز نشان داد که به علت بکارگیری داده های روزانه توسط مدل HBV، کارایی مدل ANN در مقیاس ماهانه بهتر از مدل HBV است. همچنین، Nor و همکاران (۲۰۰۷) یک مدل RBF را برای مدل سازی رابطه میان بارش و رواناب در دو حوضه در سانجایی بکار بردند. آنها از این روش برای پیش بینی هیدروگراف جریان بر اساس رخدادهای بارش استفاده کردند و برای آموزش مدل RBF، مدل شبکه عصبی رگرسیون تعمیم یافته (GRNN) را بکار بردند. ارزیابی نتایج حاصله از این مدل و مقایسه آن با نتایج بدست آمده از مدل مفهومی HEC-HMS بیانگر کارایی بیشتر و مدل سازی صحیح تر مدل RBF بود. در تحقیق Ghanbarpour و همکاران (۲۰۱۲)، کارایی دو مدل استوکستیک ARIMA و DARMA، مدل داده مبنای شبکه عصبی مصنوعی (ANN)، مدل فیزیکی SWRRB و مدل مفهومی IHACRES برای مدل سازی فرآیند بارش - رواناب به منظور پیش بینی جریان ماهانه در حوضه کسلیان مورد ارزیابی قرار گرفته است. نتایج حاصل از این تحقیق نشان می دهد که کارایی مدل شبکه عصبی از سایر مدل ها بهتر بوده است. نظام خیاوی و قلمی (۱۳۹۰) کارایی روش شبکه عصبی مصنوعی را برای مدل سازی بارش - رواناب حوضه آبریز قره سو در استان اردبیل با روش رگرسیون معمولی مورد مقایسه قرار دادند. نتایج آنها نشان داد که روش شبکه عصبی مصنوعی به علت توانایی در مدل سازی فرآیندهای غیر خطی، نتایج قابل قبول تری نسبت به روش رگرسیون ارائه کرده است. در تحقیق دیگری توسط قربانی و همکاران (۱۳۹۵) کارایی مدل های داده مبنای K نزدیک ترین همسایگی (KNN) و درخت تصمیم M5 با مدل مفهومی IHACRES برای شبیه سازی و پیش بینی جریان ماهانه رودخانه ارازکوسه در استان گلستان مورد مقایسه و ارزیابی قرار گرفته است. نتایج این تحقیق نشان داد که مدل های KNN و M5 نتایجی با دقت بالاتر را ارائه کرده اند.

با توجه به متفاوت بودن ساختار مدل های مبناء، کارایی آنها برای مدل سازی در شرایط مختلف، متفاوت است؛ تحقیقات صورت گرفته توسط Cigizuglu و Kisi (۲۰۰۶)، Kisi و Cigizoglu (۲۰۰۷) و Kisi (۲۰۰۸) نشان می دهد که مدل شبکه عصبی GRNN در مقایسه با دو شبکه عصبی انتشار رو به جلو (FFNN) و شعاع مبنا (RBF) برای پیش بینی جریان متوسط ماهانه و روزانه از دقت بالاتری برخوردار است. Wu و Chau (۲۰۱۰) کارایی سه مدل ARMA، KNN و ANN را برای پیش بینی جریان ماهانه یک ماه بعد در دو رودخانه چین مورد بررسی قرار دادند. نتایج آنها نشان داد که شرایطی که همبستگی میان متغیرهای ورودی و خروجی مدل پایین است، کارایی مدل KNN نسبت به دو مدل دیگر بهتر می باشد. دل ناز و همکاران (۱۳۹۶) کارایی مدل شبکه عصبی GRNN را در مقایسه با مدل های شبکه عصبی ANN و RBF برای تخمین پارامترهای آبخوان محبوس بر اساس داده های آزمایش پمپاژ مورد ارزیابی قرار دادند. نتایج آنها نشان داد که مدل GRNN دارای کارایی بهتر از نظر دقت بالای نتایج و زمان اندک برای انجام محاسبات در مقایسه با دو مدل دیگر است. همچنین،

Modaresi و همکاران (۲۰۱۸) کارایی مدل های شبکه عصبی ANN و GRNN را با مدل های LS-SVR و KNN برای پیش بینی جریان براساس متغیرهای اقلیمی در شرایط خطی و غیرخطی مقایسه کردند. نتایج آنها نشان داد که کارایی مدل ها در شرایط خطی و غیر خطی متفاوت است و در شرایط خطی کارایی مدل های ANN و GRNN بهتر از KNN است ولی در شرایط غیر خطی کارایی مدل های KNN و LS-SVR بر مدل های ANN و GRNN برتری دارد. Khazaei Poul و همکاران (۲۰۱۹) کارایی چهار مدل ANN، KNN، MLR و ANFIS را برای پیش بینی جریان ماهانه با متغیرهای ورودی متفاوت و نیز در شرایط ترکیب شده با تبدیل موجک و بدون آن مورد ارزیابی قرار دادند. نتایج این تحقیق نشان داد در شرایط عدم استفاده از تبدیل موجک، مدل KNN دارای کارایی بهتری نسبت به سایرین است و با بکارگیری تبدیل موجک، کارایی سایر مدل ها نسبت به مدل KNN ارتقای بیشتری می یابد. Ren و همکاران (۲۰۲۰) اثر بکارگیری هشت روش فیلترکننده انتخاب و ویژگی نظیر ضریب همبستگی خطی پیرسون، همبستگی خطی جزئی پیرسون، اطلاعات متقابل، اطلاعات متقابل شرطی، اطلاعات متقابل جزئی و ... را بر مدل های ANN، KNN، MLR و enELM برای پیش بینی جریان ماهانه در یک ماه بعد در سه مورد مطالعاتی مورد ارزیابی قرار دادند. نتایج آنها نشان داد که برای افزایش کارایی مدل های KNN و enELM هیچ یک از هشت روش فیلتر کننده ویژگی بر دیگری برتری ندارد.

ارزیابی کارایی مدل ها با توجه به تحقیقات فوق نشان دهنده کارایی بالای مدل های شبکه عصبی GRNN و رگرسیون K- نزدیک ترین همسایگی برای مدل سازی فرآیندهایی نظیر پیش بینی جریان روزانه و ماهانه و تخمین پارامترهای آبخوان در مقایسه با مدل هایی نظیر ANN، RBF، ARMA، ANFIS و MLR می باشد. با توجه به تفاوت کارایی مدل ها در شرایط مختلف، هدف از انجام این تحقیق، مقایسه کارایی دو مدل GRNN و KNN برای مدل سازی ماهانه فرآیند بارش- رواناب می باشد. با توجه به کمبود اطلاعات در دسترس از عوامل اثرگذار بر شکل گیری رواناب در یک حوضه آبریز در بلندمدت، مزیت استفاده از مدل های هوشمند و داده مبنای برای مدل سازی فرآیند بارش- رواناب در این است که برای استفاده از این مدل ها نیازی به استفاده از تمامی عوامل نمی باشد؛ در مقابل، هر چه تعداد متغیرهای ورودی کمتر و متغیرها بر خروجی مدل اثرگذارتر باشند، توانایی این مدل ها برای شناسایی الگوی موجود میان متغیرها بهتر می باشد. از این رو در تحقیق حاضر، با توجه به مقیاس زمانی بلندمدت ماهانه و کم شدن اثرگذاری مستقیم سایر عوامل اقلیمی و مورفولوژیکی بر مقدار جریان ماهانه رودخانه، برای ارزیابی کارایی دو مدل مذکور در شناسایی رابطه پیچیده و غیر خطی فرآیند بارش- رواناب ماهانه، تنها از دو متغیر بارش و جریان بدون تأخیر زمانی به عنوان ورودی و خروجی مدل ها استفاده شده است. در این تحقیق، بهترین ساختار برای هر یک از مدل ها بر اساس روش صحت سنجی متقاطع LOOCV تعیین شده و ارزیابی عملکرد این دو مدل به دو صورت کلی و ماهانه بر اساس رده بندی شاخص های نش- ساتکیف، ریشه متوسط مربعات خطا و ضریب همبستگی پیرسون صورت گرفته است.



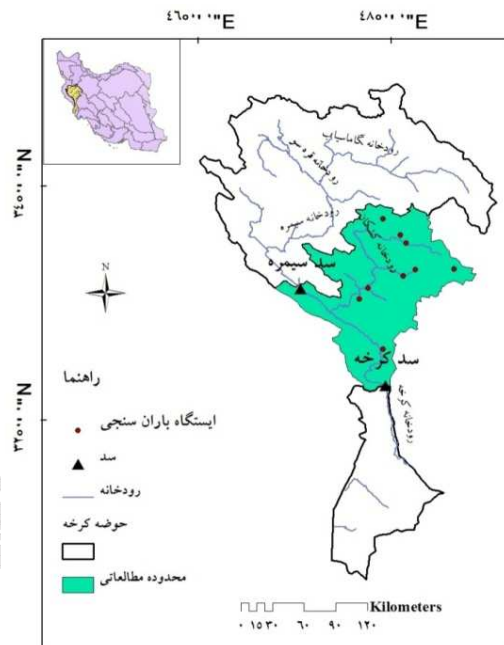
مواد و روش ها

معرفی منطقه مطالعاتی

در تحقیق حاضر حوضه کرخه به عنوان منطقه مطالعاتی انتخاب شده است. سد کرخه، سد اصلی حوضه کرخه و در پایین دست سد سیمره در طول جغرافیایی $48^{\circ}07'31''$ و عرض جغرافیایی $32^{\circ}29'22''$ بر روی

رودخانه کرخه قرار دارد. از این رو، حوضه کرخه را می توان 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، مدل سازی فرآیند بارش - رواناب در زیرحوضه بالادست سد کرخه مورد ارزیابی قرار گرفته است که مساحت آن حدود ۱۴۴۳۰ کیلومتر مربع می باشد (شکل ۱).

به منظور انجام این تحقیق از آمار جریان ماهانه در ایستگاه هیدرومتری ورودی به سد کرخه و آمار متوسط بارش ماهانه ۹ ایستگاه باران سنجی و سینوپتیک بالادست سد واقع در زیرحوضه مطالعاتی در بازه زمانی ۳۲ ساله (۱۳۶۱-۱۳۹۳) استفاده شد که ۲۲ سال آن (۱۳۶۱-۱۳۸۲) برای واسنجی و ۱۰ سال دیگر (۱۳۸۳-۱۳۹۳) برای صحت سنجی مدل ها بکار برده شد. آمارهای بدست آمده از ایستگاه ها نشان می دهد که متوسط بارش ماهانه این زیرحوضه در طول دوره مطالعاتی برابر با ۵۲/۷ میلی متر بوده و بارش اصلی این زیرحوضه در ماه های آبان تا اردیبهشت رخ می دهد. همچنین، متوسط حجم جریان ماهانه ورودی به سد کرخه در طول دوره مطالعاتی برابر با ۱۴۳/۹ میلیون مترمکعب می باشد. در جدول ۱ نام ایستگاه ها و در شکل ۱ موقعیت ایستگاه های هواشناسی مورد استفاده نشان داده شده است.



شکل ۱- موقعیت زیرحوضه مطالعاتی و ایستگاه های هواشناسی آن

مدل های بکار رفته در تحقیق

شبکه عصبی مصنوعی رگرسیون تعمیم یافته (GRNN)

مدل شبکه عصبی رگرسیون تعمیم یافته (GRNN) یکی از انواع شبکه های عصبی تابع پایه شعاعی (Radial Basis Function) است که برای حل مسائل رگرسیون کاربرد دارد. این مدل که توسط Specht در سال ۱۹۹۱ ارائه شد، یک تقریب گر همه منظوره برای توابع هموار (Smooth Functions) است و توانایی حل هر نوع از مسائل تقریب تابع هموار با داده های کافی را دارد. این مدل همانند مدل شبکه عصبی مصنوعی، یک روش هوش مصنوعی است که برای یادگیری روابط میان متغیرهای مستقل و وابسته از روش آموزش باناظر

بهره می گیرد. مزیت این مدل نسبت به سایر شبکه های عصبی در داشتن ساختار احتمالاتی است که سبب می شود این مدل در فرآیند مدل سازی با مشکل مینیمم های محلی که سایر شبکه های عصبی با آن درگیرند، مواجه نشود (Cigizoglu, 2006).

جدول ۱- مشخصات ایستگاه های باران سنجی زیر حوضه کرخه

سازمان مربوطه	عرض جغرافیایی		طول جغرافیایی		نام ایستگاه	ردیف
	دقیقه	درجه	دقیقه	درجه		
وزارت نیرو	۱۳	۳۳	۴۹	۴۷	پل دختر	۱
وزارت نیرو	۵۵	۳۳	۱	۴۸	نظر آباد	۲
وزارت نیرو	۴۸	۲۲	۵	۴۸	پل زال	۳
وزارت نیرو	۱۹	۳۳	۵۴	۴۷	آفرینه	۴
وزارت نیرو	۲۶	۳۳	۱۵	۴۸	چم انجیر	۵
وزارت نیرو	۳۱	۳۳	۴۶	۴۸	دهنو	۶
وزارت نیرو	۴۳	۳۳	۱۶	۴۸	کاکارضا	۷
وزارت نیرو	۴۵	۳۳	۴۱	۴۶	سراب سید علی	۸
سازمان هواشناسی	۲۹	۳۳	۲۲	۴۸	خرم آباد	۹

شبکه عصبی رگرسیون تعمیم یافته یک شبکه عصبی سه لایه است که در آن تعداد نورون های موجود در لایه اول و آخر مانند سایر شبکه های عصبی به ترتیب برابر با ابعاد بردارهای ورودی و خروجی است؛ ولی در این شبکه برخلاف سایر شبکه های عصبی، تعداد نورون های لایه میانی (مخفی) برابر با تعداد داده های مشاهداتی است. در این شبکه یک تابع احتمالاتی نرمال (گوسی) در هر یک از نورون های لایه مخفی وجود دارد که به صورت زیر می باشد:

$$f(X_r, t) = e^{-\left(\|X_r - X_t\| \times 0.8326 / s\right)^2} \quad (1)$$

در رابطه (۱)، X_r : بردار ورودی به شبکه با خروجی نامشخص، X_t : مقادیر ورودی مشاهداتی در زمان t و s : پارامتر spread است که با تغییر آن، میزان جمع و بازشدگی تابع تغییر می نماید به نحوی که تابع، بهترین برازش را بر داده ها بیابد. پس از محاسبه این تابع احتمالاتی در هر یک از نورون های لایه مخفی، خروجی شبکه به ازای ورودی X_r از رابطه (۲) قابل محاسبه است (Araghinejad, 2014):

$$Y_r = \frac{1}{\sum_{t=1}^n f(X_r, t)} \sum_{t=1}^n [f(X_r, t) \times T_t] \quad (2)$$

در این رابطه، T_t : مقدار خروجی مشاهداتی متناظر با بردار ورودی t امین داده و n : تعداد داده های مشاهداتی است. از آنجایی که مقدار خروجی شبکه عصبی GRNN به پارامتر s وابسته است و این پارامتر برای تنظیم تابع در جهت انجام تخمین های دقیق تر بکار می رود، باید مقدار بهینه آن تعیین شود. به همین دلیل، در تحقیق حاضر با استفاده از کدنویسی در نرم افزار MATLAB، از روش صحت سنجی متقاطع (Leave One Out Cross Validation) برای تعیین بهترین مقدار پارامتر s برای مدل GRNN استفاده شده است.

رگرسیون K- نزدیک ترین همسایگی (KNN)

رگرسیون K نزدیک ترین همسایگی نوعی رگرسیون ناپارامتری می باشد که اولین بار توسط Karlsson و Yakowitz در سال ۱۹۸۷ برای پیش بینی و تخمین متغیرهای هیدرولوژیکی استفاده شد. در این روش، رابطه پارامتری از پیش تعیین شده ای میان متغیرهای ورودی و خروجی برقرار نمی شود بلکه در این روش، برای مدل سازی یک فرآیند نظیر مدل سازی فرآیند بارش- رواناب، از اطلاعات حاصل از داده های مشاهداتی بر اساس شباهت میان متغیرهای زمان واقعی مورد نظر و متغیرهای دوره مشاهداتی استفاده می شود.

منطق مورد استفاده در این روش، محاسبه احتمال رخداد یک واقعه بر اساس وقایع مشابه تاریخی آن (وقایع مشاهداتی) است. در این روش، برای تعیین میزان مشابهت شرایط کنونی به شرایط تاریخی از تابع احتمالاتی کرنل $f(D_{ri})$ به صورت زیر استفاده می شود:

$$f(D_{ri}) = \frac{1/D_{ri}}{\sum_{i=1}^K 1/D_{ri}} \quad (3)$$

که در آن، D_{ri} : فاصله اقلیدسی بردار شرایط کنونی (X_r) از بردار مشاهداتی تاریخی (X_i) و K: تعداد نزدیک ترین همسایگی ها به شرایط کنونی است. خروجی حاصل از این مدل رگرسیون (Y_r) به ازای بردار ورودی X_r بر اساس رابطه کرنل فوق و مقادیر Y_i متناظر با هر D_{ri} از رابطه زیر محاسبه می شود:

$$Y_r = \sum_{i=1}^K f(D_{ri}) \times Y_i \quad (4)$$

در مدل KNN، انتخاب تعداد نزدیک ترین همسایگی (K) بر دقت نتایج اثرگذار است؛ به طوری که اگر تعداد همسایه ها زیاد باشد، نتایج به میانگین گیری از داده های مشاهداتی نزدیک می شود و اگر بسیار کم باشد، امکان زیاد شدن خطا افزایش می یابد. بنابراین، تعیین تعداد بهینه این پارامتر در این مدل برای دستیابی به کمترین خطا ضروری است. از این رو، در تحقیق حاضر، تعداد بهینه این پارامتر با استفاده از روش صحت سنجی متقاطع LOOCV تعیین شده است.

شاخص های ارزیابی مدل ها

برای ارزیابی و مقایسه کارایی مدل های بکار رفته در این تحقیق از سه شاخص ارزیابی نش- ساتکلیف (NSE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی پیرسون (R) استفاده شده است. رده بندی کارایی مدل ها بر اساس این سه شاخص در جدول ۲ آورده شده است: (Moriasi et al., 2007).

جدول ۲- طبقه بندی کارایی مدل ها بر اساس شاخص های ارزیابی


شاخص های ارزیابی مدل ها			طبقه کارایی مدل ها
R	RMSE	NSE	
$0.93 < R < 1.0$	$RMSE \leq 0.5 SD^*$	$0.75 < NSE \leq 1$	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



نتایج و بحث

برای انجام فرآیند مدل سازی، ابتدا رابطه میان بارش متوسط ماهانه زیر حوضه بالادست سد و جریان ماهانه ورودی به سد کرخه بررسی شد که در شکل ۲ نشان داده شده است.



شکل ۲- رابطه میان بارش متوسط ماهانه و حجم جریان ماهانه در زیر حوضه کرخه

همان طور که در شکل ۲ مشاهده می شود، رابطه میان این دو متغیر غیرخطی است؛ به طوری که از میان توابع خطی، نمایی، لگاریتمی، توانی و چندجمله ای با درجه های ۲ تا ۶، بهترین تابع برازش یافته براساس ضریب تبیین، تابع چندجمله ای درجه ۶ می باشد که ضریب تبیین آن ۰/۳۱۶ است و نشان دهنده شرایط پیچیده غیرخطی می باشد. از این رو، بکارگیری توابع احتمالاتی برای مدل سازی این رابطه ضروری است. با بکارگیری دو مدل داده مبناء و احتمالاتی GRNN و KNN برای مدل سازی فرآیند بارش - رواناب در زیر حوضه مطالعاتی و تعیین مقادیر بهینه پارامترهای مدل ها به روش صحت سنجی متقاطع LOOCV، نتایج کلی زیر برای تمامی ماه ها در مراحل واسنجی و صحت سنجی حاصل شد:


جدول ۳- نتایج ارزیابی مدل ها در مراحل واسنجی و صحت سنجی بر اساس شاخص های ارزیابی و مقادیر بهینه پارامترها

مقادیر بهینه پارامترها	صحت سنجی			آموزش (واسنجی)			نام مدل
	R	RMSE (MCM)	NSE	R	RMSE (MCM)	NSE	
Spread= ۰/۶۷	۰/۷۹۳	۸۳/۱۶۳	۰/۶۱۸	۰/۸۲۰	۷۱/۶۹۰	۰/۶۸۵	GRNN
K= ۳	۰/۷۷۷	۸۴/۹۷۷	۰/۶۰۱	۰/۹۳۹	۴۷/۳۸۹	۰/۸۶۲	KNN

با توجه به جدول ۳ و براساس طبقه بندی شاخص های ارزیابی (جدول ۲) مشاهده می شود که هر دو مدل در مرحله صحت سنجی از کارایی مناسبی بر اساس دو شاخص NSE و RMSE برخوردار هستند؛ ولی بر اساس معیار ضریب همبستگی، دقت نتایج آنها مناسب نیست. در شکل ۳ نتایج حاصل از مدل ها در مقایسه با مقادیر مشاهداتی نشان داده شده است.

با توجه به شکل ۳ مشاهده می شود که هر دو مدل برای مدل سازی مقادیر متوسط از کارایی بالایی برخوردارند و مقادیر مدل سازی شده و مشاهداتی بر هم منطبق می باشند ولی در برخی از نقاط اکسترمم (جریان های حداکثر و حداقل)، از دقت مناسبی برخوردار نبوده اند؛ با این وجود، در مقادیر شبیه سازی شده

توسط این دو مدل، مقادیر غیر منطقی نظیر مقدار منفی برای جریان و یا اعداد خیلی بزرگ و غیر واقعی وجود ندارد و این یک مزیت مهم برای آنها می باشد.

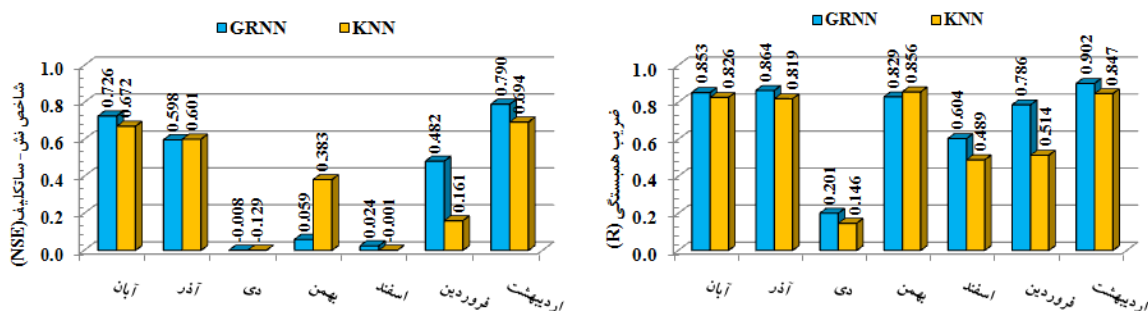


شکل ۳- مقادیر جریان مشاهداتی و شبیه سازی شده توسط مدل های GRNN و KNN

نظر به اینکه الگوهای بارش - رواناب در ماه های مختلف متفاوت است، ارزیابی ماهانه از کارایی مدل ها نیز صورت گرفت. نتایج این ارزیابی براساس دو شاخص نش - ساتکلیف و ضریب همبستگی در مرحله صحت سنجی در شکل ۴ آورده شده است.

با توجه به شکل ۴ مشاهده می شود که بر اساس هر دو شاخص کارایی نش - ساتکلیف و ضریب همبستگی، دقت نتایج مدل GRNN در تمامی ماه ها بجز بهمن ماه از مدل KNN بیشتر است. بر اساس رده بندی شاخص نش - ساتکلیف، نتایج مدل GRNN در ماه اردیبهشت در رده بسیار خوب، در آبان در رده خوب و در ماه آذر در رده مناسب قرار دارد. همچنین بر اساس شاخص ضریب همبستگی، نتایج مدل GRNN در ماه های آبان، آذر و بهمن در رده مناسب و در ماه اردیبهشت در رده خوب قرار دارد. این در حالی است که نتایج مدل KNN بر اساس شاخص نش - ساتکلیف در دو ماه آبان و اردیبهشت در رده خوب و در ماه آذر در رده مناسب قرار دارد و در ماه های آبان، آذر، بهمن و اردیبهشت بر اساس رده بندی شاخص ضریب همبستگی، کارایی این مدل در رده مناسب قرار دارد. با این وجود، بر اساس شاخص نش - ساتکلیف دقت نتایج حاصل از هر دو مدل در ماه های دی تا فروردین در رده نامناسب قرار دارد که علت آن رخداد بارش های حدی در این ماه ها می باشد. همچنین، بررسی ضریب همبستگی ماهانه نشان می دهد که با وجود قرارگیری ضریب

همبستگی کلی نتایج دو مدل در رده نامناسب، ضریب همبستگی نتایج دو مدل تنها در ماه های دی، اسفند و فروردین در رده نامناسب قرار دارد و در سایر ماه ها در رده مناسب به بالا قرار گرفته است.



شکل ۴- ارزیابی ماهانه کارایی مدل های GRNN و KNN برای مدل سازی بارش-رواناب

* * *

نتیجه گیری

در این پژوهش، کارایی دو مدل شبکه عصبی رگرسیون تعمیم یافته (GRNN) و رگرسیون K- نزدیک ترین همسایگی (KNN) که هر دو از نوع داده مبنا و احتمالاتی با ساختارهای متفاوت می باشند برای مدل سازی ماهانه فرآیند بارش رواناب مورد ارزیابی قرار گرفت. این ارزیابی بر اساس مدل سازی ماهانه بارش-رواناب در زیرحوضه بالادست سد کرخه صورت پذیرفت و در آن از داده های ۳۲ ساله بارش متوسط ماهانه زیرحوضه موردنظر و جریان ماهانه ورودی به سد کرخه استفاده شد. نتایج نشان داد که این دو متغیر دارای رابطه پیچیده و غیرخطی از درجه ۶ به بالا می باشند. ساختار بهینه مدل ها با استفاده از روش صحت سنجی متقاطع LOOCV تعیین شد و نتایج مدل ها بر اساس تمامی ماه ها نشان داد که کارایی هر دو مدل در مرحله صحت سنجی مشابه و در رده مناسب بر اساس دو شاخص NSE و RMSE قرار دارد. هر دو مدل برای مدل سازی مقادیر حدی اندکی ضعیف هستند ولی در نتایج هیچ یک از آنها، مقادیر منفی و غیرقابل قبول وجود ندارد. با این حال، ارزیابی ماهانه نتایج مدل ها نشان می دهد که با وجود تشابه کلی کارایی دو مدل، دقت نتایج مدل GRNN در تمامی ماه ها بجز بهمن ماه از مدل KNN بیشتر می باشد و از این جهت، با توجه به بررسی ماهانه، کارایی مدل GRNN بر KNN برتری دارد.

* * *

منابع فارسی

- دل ناز، ع.، رخشنده رو، غ.، نیکو، م.ر. (۱۳۹۶)، کارایی مدل GRNN در قیاس با مدل های ANN و RBF در تخمین پارامترهای آبخوان محبوس، هیدروژئولوژی، ۲(۱)، ۱۰۲-۱۱۷.
- قربانی، خ.، سهرابیان، ا. و سالاری جزی، م. (۱۳۹۵)، ارزیابی روش های هیدرولوژیکی و داده کاوی در شبیه سازی و پیش بینی دبی جریان ماهانه (مطالعه موردی: ایستگاه هیدرومتری ارازکوسه). پژوهش های حفاظت آب و خاک. ۲۳ (۱)، ۲۰۳-۲۱۷.
- نظام خیای، خ. و قلمی، و.، ۱۳۹۰، استفاده از شبکه عصبی مصنوعی در مدل سازی بارش-رواناب. مطالعه موردی: حوضه آبریز قرهسو واقع در استان اردبیل. سومین همایش ملی عمران شهری، چهارم آبان ماه، سنندج.



References

- 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.
- Cigizuglu, H.K. (2006), Generalized regression neural network in monthly flow forecasting, Civil Engineering and Environmental Systems, 22(2), 71-81.
- 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), pp 281-292.
- Karlsson, M., and Yakowitz, S. (1987), Nearest-neighbor methods for nonparametric rainfall-runoff forecasting, Water Resources Research, 23(7), pp 1300-1308.
- Khazaee Poul, A., Shourian, M. and Ebrahimi, H. (2019), A Comparative Study of MLR, KNN, ANN and ANFIS Models with Wavelet Transform in Monthly Stream Flow Prediction, Water Resources Management, 33, pp 2907-2923.
- Kisi, O. and Cigizoglu, H.K. (2007), Comparison of different ANN techniques in river flow prediction, Civil Engineering and Environmental Systems, 24(3), pp 211-231.
- Kişi, Ö. (2008), River flow forecasting and estimation using different artificial neural network techniques, Hydrology Research, 39(1), pp 27-40.
- Modaresi, F., Araghinejad, S. and Ebrahimi, K. (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), pp 243-258.
- Moriassi, 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), pp 885-900.
- Nilsson, P., Uvo, C. B. and Berndtsson, R. (2006), Monthly runoff simulation: comparing and combining conceptual and neural network models, Journal of Hydrology, 321, pp 344-363.
- Nor, N. I. A., Harun, S., and Kassim, A. H. M. (2007), Radial Basis Function modeling of hourly streamflow hydrograph, Journal of Hydrologic Engineering, 12(1), pp 113-123.
- Ren, K., Fang, W., Qu, J., Zhang, X. and Shi, X. (2020), monthly streamflow forecasting – Three case studies on CAMELS data sets, Journal of hydrology, 586, <https://doi.org/10.1016/j.jhydrol.2020.124897>
- Specht, D.F. (1991), A General Regression Neural Network, Transactions on Neural Network, 2(6), pp 578-576.
- Tokar, A. S. and Markus, M. (2000), Precipitation-runoff modeling using artificial neural networks and conceptual models, Journal of Hydrologic Engineering, 5 (2), pp 156-161.
- Wu, C.L., and Chau, K.W. (2010), Data-driven models for monthly streamflow time series prediction, Engineering Application of Artificial Intelligence, 23(8), pp 1350-1367.