

پیش‌بینی جریان ورودی به مخزن سد کمال صالح با استفاده از محاسبات نرم

نازنین شاه‌کرمی^۱، هادی ثانی‌خانی^۲، مجتبی‌مرادی^۳

تاریخ دریافت: ۱۳۹۳/۱۲/۰۲

تاریخ پذیرش: ۱۳۹۴/۱۲/۰۱

چکیده

پیش‌بینی جریان ورودی به مخازن سدها به منظور انجام برنامه‌ریزی و بهره‌برداری مناسب منابع آب لازم و ضروری است. در این تحقیق عملکرد دو مدل هوشمند شبکه‌های عصبی مصنوعی و سامانه استنتاج فازی-عصبی تطبیقی مبتنی بر روش دسته‌بندی تفریقی در پیش‌بینی جریان ورودی به سد کمال صالح در استان مرکزی مورد بررسی قرار گرفت. بدین منظور از داده‌های جریان و بارش در یک دوره آماری ۳۱ ساله (۱۳۶۰-۱۳۹۰) استفاده شد و پیش‌بینی جریان در گام‌های زمانی روزانه و ماهانه انجام شد. از مقادیر دبی جریان و بارش در گام‌های زمانی قبلی به عنوان الگوهای ورودی مدل‌ها استفاده شد. عملکرد هر دو مدل در پیش‌بینی‌های روزانه و ماهانه جریان بر اساس مقادیر شاخص‌های خطای R ، $RMSE$ و MAE بسیار مطلوب بود، هرچند عملکرد مدل فازی-عصبی بهتر از مدل شبکه‌های عصبی بود (کمتر از ۳ درصد). استفاده از ضریب فصلی موجب بهبود عملکرد مدل‌ها در پیش‌بینی‌های ماهانه شد. در ادامه، اثرات متغیرهای اقلیمی بزرگ مقیاس شامل شاخص نوسانات آتلانتیک شمالی و شاخص نوسانات جنوبی در پیش‌بینی‌های ماهانه حاصل از الگوی بهینه مدل برتر بخش قبل، مورد بررسی قرار گرفت. نتایج به دست آمده حاکی از آن بود که استفاده از شاخص‌های اقلیمی در ترکیب الگوهای ورودی، می‌تواند موجب بهبود عملکرد مدل در پیش‌بینی‌های جریان ورودی گردد. در این میان شاخص نوسانات جنوبی تاثیر بیشتری بر بهبود پیش‌بینی دبی جریان ماهانه داشت. به طوریکه، مقدار شاخص‌های آماری تحلیل خطای مدل فازی-عصبی شامل R ، $RMSE$ و MAE به ترتیب برابر ۰/۹۱، ۳/۵۶، ۳/۷۳ به دست آمدند که نشان‌دهنده توان افزایش دقت مدل با بهبود شاخص‌های خطا به ترتیب به میزان ۱۱، ۹ و ۱۱ درصد می‌باشد.

واژه‌های کلیدی: پیش‌بینی، دسته‌بندی تفریقی، شاخص‌های اقلیمی، شبکه‌های عصبی، فازی-عصبی تطبیقی.

۱- استادیار، گروه عمران، دانشگاه اراک، اراک، ایران، تلفن تماس: ۰۸۶۳۲۶۲۵۳۲۴، n-shahkarami@araku.ac.ir (مسئول مکاتبه)

۲- استادیار، گروه مهندسی آب، دانشگاه کردستان، سنندج، ایران، تلفن تماس: ۰۹۱۲۵۵۵۰۶۰۰، hsanikhani12@gmail.com

۳- رئیس گروه مطالعات آب سطحی، شرکت سهامی آب منطقه ای مرکزی، اراک، ایران، تلفن تماس: ۰۹۱۸۸۶۳۰۸۷۹،

mojtaba.moradi54@gmail.com

مقدمه

جهت برنامه‌ریزی در توسعه منابع آب و بهینه‌سازی مصرف آب لازم است پیش‌بینی‌های جریان ورودی به مخازن سدها در بازه‌های زمانی کوتاه‌مدت و بلندمدت صورت گیرد (Kisi, 2008). اغلب مدل‌های مورد استفاده به منظور پیش‌بینی سری‌های زمانی در زمینه منابع آب، بر مبنای وجود رابطه خطی بین متغیرها توسعه می‌یابند که از آن جمله می‌توان به مدل‌های خود همبسته و خود همبسته میانگین متحرک اشاره کرد (Maier and Dandy, 2000). با توجه به ماهیت پیچیده و غیرخطی جریان رودخانه استفاده از مدل‌های خطی کارایی لازم را نداشته و به کارگیری مدل‌های غیرخطی در این راستا اجتناب‌ناپذیر است (Hsu et al., 1995).

در چند دهه اخیر پیشرفت‌های زیادی در حوزه مدل‌های هوشمند و محاسبات نرم صورت گرفته است.

در سال‌های اخیر استفاده از تکنیک‌های محاسباتی نرم و هوشمند نظیر شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی همواره مورد توجه محققین در زمینه‌های مختلف علوم از جمله هیدرولوژی و منابع آب بوده است. دلیل توسعه مدل‌های ذکر شده، سهولت کاربرد و دقت بالای این مدل‌ها در تقریب معادلات غیرخطی و پیچیده ریاضی می‌باشد. شبکه‌های عصبی مصنوعی از جمله سامانه‌های هوشمندی است که برگرفته از مغز انسان می‌باشد.

Imrie و همکاران در سال ۲۰۰۰ به بررسی قابلیت تعمیم مدل شبکه‌های عصبی مصنوعی در پیش‌بینی دبی جریان رودخانه پرداختند و چنین عنوان نمودند که طول دوره آماری داده‌ها فاکتور موثری بر عملکرد مدل می‌باشد. (Kisi (2005) به مقایسه عملکرد مدل شبکه‌های عصبی و سری زمانی خود همبسته در پیش‌بینی مقادیر دبی جریان رودخانه پرداخت. شاخص‌های آماری ارزیابی عملکرد مدل‌ها حاکی از

برتری عملکرد مدل شبکه‌های عصبی در مقایسه با مدل خود همبسته بود.

(Kisi and Cigizoglu (2007) عملکرد انواع مختلف از شبکه‌های عصبی مصنوعی شامل شبکه‌های پیش‌خور با الگوریتم پس انتشار خطا، شبکه‌های پایه شعاعی و شبکه‌های رگرسیونی تعمیم یافته را در پیش‌بینی جریان دو رودخانه مختلف از ترکیه مورد بررسی قرار دادند. نتایج بدست آمده حاکی از عملکرد بهتر مدل پایه شعاعی در مقایسه با سایر مدل‌ها بود. Wang et al., 2009 به مقایسه عملکرد مدل خود همبسته میانگین متحرک (ARMA)^۱ و چندین مدل هوشمند شامل شبکه‌های عصبی، سیستم استنتاج فازی-عصبی، برنامه‌ریزی ژنتیک (GP)^۲ و ماشین بردار پشتیبان (SVM)^۳ جهت پیش‌بینی سری زمانی دبی جریان در مقیاس ماهانه پرداختند. نتایج آن‌ها نشان داد که به ازای داده‌های مورد استفاده در مرحله آموزش و صحت‌سنجی، بهترین عملکرد با توجه به معیارهای مختلف ارزیابی خطا به مدل‌های فازی-عصبی، برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان اختصاص دارد.

(Sattari et al., (2012) کارایی شبکه‌های عصبی بازگشتی با تاخیر زمانی و شبکه‌های عصبی با الگوریتم پس انتشار خطا را در پیش‌بینی جریان ورودی به مخزن سد علویان را مورد بررسی قرار دادند. نتایج بدست آمده نشان داد که با توجه به شاخص‌های آماری خطا، هر دو مدل توانمندی قابل قبولی در پیش‌بینی مقادیر واقعی جریان دارند.

انوری تفتی و همکاران (۱۳۹۰) به بررسی عملکرد شبکه‌های عصبی در پیش‌بینی جریان رودخانه در حوضه کارون پرداختند و اثر شاخص اقلیمی نوسانات جنوبی را بر روی پیش‌بینی‌های ماهانه مورد بررسی قرار دادند. نتایج به دست آمده حاکی از آن بود که متغیرهای دمایی بیشترین تاثیر را بر روی جریان

¹ Auto Regressive Moving Average

² Genetic Programming

³Support Vector Machines

ضریبی استفاده کردند که دقت مدل را افزایش می‌دهد. یافته‌های آن‌ها حاکی از برتری مدل فازی-عصبی در مقایسه با مدل‌های عصبی و خودهمبسته به‌ازای کلیه الگوهای مورد استفاده به عنوان ورودی مدل بود. عبدالله‌پور آزاد و ستاری (۱۳۹۴) به مقایسه عملکرد مدل‌های شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی در پیش‌بینی جریان رودخانه اهرچای پرداختند. نتایج بدست آمده حاکی از برتری روش فازی-عصبی در مدل‌سازی دبی جریان نسبت به شبکه‌های عصبی داشت.

در این تحقیق از مدل‌های هوشمند شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی مبتنی بر روش دسته‌بندی تفریقی به منظور پیش‌بینی جریان ورودی به مخزن سد کمال صالح استفاده شده است. در بخش اول تحقیق مدل‌سازی جریان روزانه و در بخش دوم، مدل‌سازی جریان ورودی ماهانه بررسی شده است. در بخش پایانی نیز به بررسی اثرات متغیرهای اقلیمی بزرگ مقیاس شامل شاخص آتلانتیک شمالی و نوسانات جنوبی بر پیش‌بینی‌های ماهانه پرداخته شده است. در اغلب مطالعات قبلی انجام شده با مدل فازی-عصبی از روش افراز شبکه برای طبقه‌بندی داده‌ها استفاده شده است و کمتر از روش دسته‌بندی تفریقی استفاده شده است. همچنین در مطالعات گذشته جهت پیش‌بینی دبی جریان ورودی به مخازن سدها، اغلب از داده‌های پیشین جریان استفاده شده است و کمتر به اثر متغیرهای اقلیمی بزرگ مقیاس در پیش‌بینی دبی جریان پرداخته شده است.

مواد و روش‌ها

شبکه‌های عصبی مصنوعی^۱

شبکه‌های عصبی مصنوعی مدل‌های ریاضی و انعطاف‌پذیری هستند که می‌توانند در مدل‌سازی سیستم‌های پیچیده به‌کار برده شوند. همچنین این

رودخانه دارند و استفاده از شاخص نوسانات جنوبی موجب بهبود عملکرد مدل شبکه‌های عصبی در پیش‌بینی جریان ماهانه شد.

سامانه استنتاج فازی عصبی-تطبیقی نیز از جمله روش‌هایی است که در تحلیل پدیده‌های غیرخطی و بررسی رابطه بین ورودی و خروجی از جمله مباحث مشابه با این تحقیق به کار برده شده است. (Chang and Chen (2001) از مدل فازی-عصبی به منظور پیش‌بینی جریان رودخانه داچا در مرکز تایلند استفاده نمودند. آن‌ها جهت مدل‌سازی از داده‌های بارش و جریان استفاده کردند. نتایج بدست آمده حاکی از عملکرد بهتر روش فازی-عصبی در مقایسه با مدل‌های سری زمانی بود. (Nayak et al. (2004) عملکرد سیستم استنتاج فازی-عصبی تطبیقی را در مدل‌سازی سری زمانی هیدرولوژیکی مورد بررسی قرار دادند و از آن برای پیش‌بینی جریان آب رودخانه‌ای در هندوستان بهره گرفتند. مقایسه نتایج مدل فازی-عصبی با خروجی شبکه‌های عصبی مصنوعی و مدل‌های مربوط به سری‌های زمانی نشان داد که مدل فازی-عصبی به لحاظ سرعت محاسباتی، خطای پیش‌بینی و قدرت تخمین مقادیر اوج جریان عملکرد بهتری دارد. همچنین نتایج نشان داد که مدل فازی-عصبی، نه تنها از کارایی مشابه با شبکه‌های عصبی مصنوعی برخوردار است بلکه ساخت این مدل آسان‌تر می‌باشد.

(Sanikhani and Kisi (2012) از دو روش مختلف فازی-عصبی شامل افراز شبکه و دسته‌بندی تفریقی جهت پیش‌بینی میزان جریان رودخانه در دو ایستگاه هیدرومتری واقع در کشور ترکیه استفاده نمودند. آن‌ها از مقادیر جریان‌های پیشین جهت مدل‌سازی استفاده کردند و نتایج بدست آمده حاکی از دقت قابل قبول هر دو روش در پیش‌بینی میزان جریان بود. (Lohani et al. (2012) به مقایسه عملکرد مدل‌های فازی-عصبی و خود همبسته در پیش‌بینی جریان ماهانه ورودی به مخزنی در هندوستان پرداختند. آن‌ها با توجه به پریودیک بودن داده‌ها در مقیاس ماهانه، از

^۱Artificial neural network

حقیقی در دامنه‌ای محدود می‌باشد که به ازای هر درجه‌ای از صحت قابل استفاده است.

با فرض یک سامانه استنتاج فازی شامل دو ورودی X و Y و یک خروجی Z ، مدل فازی مرتبه اول سوگنو با دو قانون فاز اگر-آنگاه به صورت زیر بیان می‌شود:
قانون ۱ - اگر x برابر A_1 و y برابر B_1 باشد
آنگاه:

$$Z_1 = p_1x + q_1y + r_1$$

قانون ۲ - اگر x برابر A_2 و y برابر B_2 باشد
آنگاه:

$$Z_2 = p_2x + q_2y + r_2$$

در شکل ۱ تصویری شماتیک از مدل فازی مرتبه اول نوع سوگنو با دو ورودی $(X$ و $Y)$ ، یک خروجی f به همراه دو قانون فازی و همچنین مدل ANFIS معادل آن نشان داده شده است.

سامانه استنتاجی فازی-عصبی برای طبقه‌بندی داده‌ها از روش‌های مختلفی استفاده می‌کند که مرسوم‌ترین آن‌ها روش افراز شبکه و روش دسته‌بندی تفریقی می‌باشد. عملکرد هر دو روش در پیش‌بینی‌های انجام شده توسط محققین مختلف تقریباً مشابه می‌باشد (Vernieuwe et al., 2005).

این مدل ترکیبی از دسته‌بندی تفریقی و سامانه استنتاج فازی-عصبی می‌باشد. در این روش نقاط مربوط به داده‌ها با تعیین پتانسیل هر نقطه در فضای مورد نظر دسته‌بندی می‌گردند. تعداد دسته‌ها و مرکز هر دسته با استفاده از روش دسته‌بندی نقاط مرتفع تعیین می‌گردند. در این روش هر نقطه در فضا تعیین کننده مرکز دسته با توجه به چگالی و تراکم نقاط موجود در اطراف آن می‌باشد. نقطه با بیشترین پتانسیل به عنوان مرکز اولین دسته انتخاب می‌گردد.

جهت مشخص نمودن تعداد دسته‌ها تعیین شعاع موثر لازم است. انتخاب مقداری کوچک برای آن، موجب کوچک شدن بیش از حد دسته‌ها در فضای داده‌ها و به تبع آن موجب افزایش قوانین می‌گردد. بنابراین

شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها یک نگاهت غیرخطی بین ورودی‌ها و خروجی‌ها ارائه دهند. پردازش در شبکه عصبی مصنوعی براساس بسیاری از واحدهای پردازش که نرون نام دارند، انجام می‌شود. هر نرون در هر لایه به همه عناصر لایه قبل و بعد با یک‌سری وزن‌هایی متصل شده است. توانایی کلی شبکه عصبی مصنوعی یادگیری ارتباط غیرخطی بین داده‌ها و تعمیم نتایج برای داده‌های دیگر است (Karayiannis and Venetsanopoulos, 1993). در این تحقیق از شبکه‌های پیش‌خور سه لایه با تابع انتقال سیگموئید در لایه پنهان و تابع انتقال خطی در لایه خروجی استفاده شد. مرسوم‌ترین روش‌های آموزش شبکه‌های پیش‌خور استفاده از الگوریتم‌های پس انتشار خطا می‌باشد که در آن‌ها اطلاعات در راستای مستقیم از لایه ورودی به لایه پنهان (میانی) و سپس به لایه خروجی انتقال می‌یابند. در پیش‌بینی‌های انجام شده با مدل شبکه‌های عصبی، الگوریتم‌های آموزشی مختلف شامل لوبرگ-مارکوات^۱، گرادیان کاهشی^۲، گرادیان کاهشی با نرخ یادگیری تطبیقی^۳، گرادیان کاهشی با نرخ یادگیری تطبیقی و مونتوم^۴ مورد بررسی قرار گرفتند. همچنین جهت تعیین تعداد نرون میانی از روش آزمون و خطا استفاده شد. جزئیات بیشتر در خصوص مدل شبکه‌های عصبی در مطالعات Haykin (1999) آورده شده است.

سیستم استنتاج فازی - عصبی تطبیقی^۵

سامانه استنتاج فازی-عصبی تطبیقی (ANFIS) برای اولین بار توسط Jang (1993) معرفی شد. این سامانه ابزاری جهانی جهت تخمین توابع پیوسته

¹Levenberg-Marquardt backpropagation

²Gradient descent back-propagation

³Gradient descent with adaptive learning rate backpropagation

⁴Gradient descent with momentum and adaptive learning rate back-propagation



⁵Adaptive neuron-fuzzy inference system

$$R = \frac{\sum_{i=1}^N (Q_t - \bar{Q}_t)(Q_t^{pred} - \bar{Q}_t^{pred})}{\sqrt{\sum_{i=1}^N (Q_t - \bar{Q}_t)^2 \sum_{i=1}^N (Q_t^{pred} - \bar{Q}_t^{pred})^2}} \quad (۱)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Q_t - Q_t^{pred})^2}{N}} \quad (۲)$$

$$MAE = \frac{\sum_{i=1}^N |Q_t - Q_t^{pred}|}{N} \quad (۳)$$

که در این روابط Q_t دبی مشاهداتی در گام زمانی t ، Q_t^{pred} دبی پیش‌بینی شده توسط مدل در گام زمانی t ، میانگین مقادیر دبی مشاهداتی \bar{Q}_t^{pred} میانگین مقادیر دبی پیش‌بینی شده توسط مدل و N تعداد مشاهدات است.



شکل (۱): مدل فازی مرتبه اول سوگنو با دو قانون فازی و مدل ANFIS متناظر آن

داده‌های مورد استفاده از سازمان آب منطقه‌ای استان مرکزی و اداره کل هواشناسی استان مرکزی تهیه شدند. در این تحقیق از داده‌های جریان ورودی به مخزن سد در یک دوره آماری ۳۱ ساله (۱۳۹۰-۱۳۶۰) استفاده شد. ۷۰ درصد از کل داده‌ها (۱۳۸۱-۱۳۶۰) جهت واسنجی مدل‌ها و ۳۰ درصد باقی‌مانده (۱۳۹۰-۱۳۸۲) جهت آزمون مدل‌های مورد بررسی استفاده شدند. پارامترهای آماری ماهانه داده‌های مورد استفاده در جدول (۱) نمایش داده شده است.

با توجه به جدول (۱)، می‌توان دید که ضریب چولگی مقادیر بارش نسبت به مقادیر جریان کمتر می‌باشد که معرف عدم برآزش مناسب داده‌های دبی

انتخاب صحیح شعاع موثر جهت دسته‌بندی داده‌ها ضروری است. پس از تعیین شعاع موثر، باید قوانین فازی و توابع عضویت تعیین گردند (Chiu, 1994).

شاخص‌های ارزیابی مدل‌ها

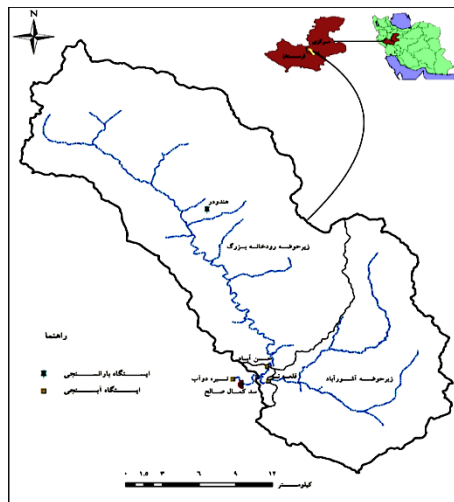
به منظور ارزیابی عملکرد مدل‌های استفاده شده در این تحقیق، از تعدادی از شاخص‌های ارزیابی خطا شامل ضریب همبستگی (R)، ریشه میانگین مربعات خطا ($RMSE$) و متوسط قدرمطلق خطا (MAE) مطابق روابط زیر استفاده شد:

نقشه منطقه و حوضه مورد مطالعه

حوضه سدکمال صالح با وسعت ۶۵۴ کیلومتر مربع، در جنوب غرب استان مرکزی و شمال شرق استان لرستان قرار دارد و یکی از زیرحوضه‌های مهم رودخانه تیره استان لرستان به حساب می‌آید (شکل ۲). اقلیم منطقه نیز در طبقه نیمه خشک سرد تا نیمه مرطوب سرد قرار دارد. سد کمال صالح با ظرفیت ۱۱۰ میلیون مترمکعب برای تأمین آب شرب شهرهای اراک، شازند و صنایع وابسته، با قابلیت تنظیم آب ۶۵ میلیون مترمکعب، بر روی رودخانه تیره دوآب احداث شده است. میانگین جریان ورودی سالانه سد معادل ۱۰۰/۹۵ میلیون مترمکعب است.

آموزش (۳۲/۶۹) می‌باشد که این مسأله می‌تواند کارایی روش‌های مورد استفاده جهت برون‌یابی داده‌های دوره آزمون را بهتر مورد ارزیابی قرار دهد (Kisi, 2007).

با توزیع نرمال می‌باشد که جهت بررسی دقیق این موضوع باید از آزمون‌های نکوئی برازش استفاده شود. همچنین مقدار حداکثر دبی جریان در بخش داده‌های آزمون (۳۶/۰۴) بیشتر از مقدار دبی حداکثر در بخش




شکل (۲): حوضه سد کمال صالح

جدول (۱): مقادیر پارامترهای آماری داده‌های ماهانه جریان رودخانه


نوع داده	متغیر	میانگین	حداقل	حداکثر	انحراف معیار	ضریب تغییرات	ضریب چولگی
آموزش	دبی جریان (m^3/s)	۳/۳۳	۰/۰۱	۳۲/۶۹	۵/۷۳	۱/۷۲	۲/۹۳
	بارش (mm)	۴۲/۱۸	۰/۰۰	۲۳۶/۵	۵۰/۹۹	۱/۶۰	۱/۲۱
آزمون	دبی جریان (m^3/s)	۲/۹۳	۰/۰۰	۳۶/۰۴	۶/۶۳	۲/۱۷	۴/۰۳
	بارش (mm)	۲۹/۹۳	۰/۰۰	۱۶۶/۵۰	۳۵/۱۵	۱/۱۷	۱/۴۶

خودهمبستگی جزئی سری‌های زمانی جریان و همبستگی بین بارش و جریان استفاده شد. نمودار ضرایب خودهمبستگی جزئی برای مقادیر دبی جریان ماهانه و ضرایب همبستگی بارش و جریان ماهانه در شکل ۴ (۳) نشان داده شده است.

جهت پیش‌بینی جریان در زمان جاری از داده‌های جریان و بارش در گام زمانی قبل به عنوان ورودی مدل‌های هوشمند استفاده گردید. جهت تعیین ترکیبات ورودی‌های مختلف در مدل‌های هوشمند، از آزمون‌های آماری رگرسیون و تعیین ضرایب



(ب)



(الف)

شکل (۳): مقادیر ضرایب (الف) خود همبستگی جزئی دبی جریان ماهانه (ب) همبستگی دبی جریان و بارش ماهانه

ورودی مقادیر شاخص‌های خطا شامل $RMSE$ ، R و MAE به ترتیب برابر $۰/۹۱$ ، $۳/۷۸$ و $۳/۶۵$ بدست آمد. در شکل (۴) سری زمانی و پراکندگی مقادیر مشاهداتی و شبیه‌سازی شده با مدل شبکه‌های عصبی برای یک دوره ۳۶۵ روزه (۱ مهر ۸۶ تا ۳۱ شهریور ۸۷) نشان داده شده است. با توجه شکل می‌توان که عملکرد مدل بسیار مناسب بوده است و داده‌های شبیه‌سازی شده همخوانی قابل قبولی با مقادیر مشاهداتی دارند. نتایج بدست آمده در این بخش با نتایج عبدالله‌پور آزاد و ستاری (۱۳۹۴) در تطابق کامل می‌باشد.

در مدل فازی-عصبی از نوع دسته‌بندی تفریقی نیز بهترین الگوی ورودی مشابه مدل شبکه‌های عصبی شامل مقادیر دبی جریان با ۴ گام تاخیر و مقادیر بارش همان روز بود. پارامتر اصلی مدل فازی-عصبی شعاع طبقه‌بندی می‌باشد که مقدار آن در محدوده ۰ تا ۱ است و مقدار آن برای بهترین الگوی ورودی برابر $۰/۴۸$ به دست آمد. در مدل فازی-عصبی برای بهترین الگوی ورودی، مقادیر شاخص‌های خطا شامل $RMSE$ ، R و MAE به ترتیب برابر $۰/۹۳$ ، $۳/۶۸$ (m^3/s) و $۳/۵۲$ (m^3/s) بدست آمد. در شکل ۵ سری زمانی و پراکندگی مقادیر مشاهداتی و شبیه‌سازی شده با مدل فازی-عصبی برای یک دوره ۳۶۵ روزه (مشابه روش شبکه‌های عصبی) نشان داده شده است. عملکرد مدل فازی-عصبی نیز در پیش‌بینی‌های روزانه مناسب و قابل قبول بوده است.

با توجه به شکل (۳) مشاهده می‌شود که مقادیر جریان در ماه جاری به مقادیر پیشین جریان وابستگی داشته و این وابستگی به ازای تاخیر برابر دو ماه وجود دارد. همچنین همبستگی بین بارش و جریان ماهانه به ازای تاخیرهای مختلف روند نوسانی از خود نشان می‌دهد. در پیش‌بینی‌های انجام شده روزانه و ماهانه، ترکیبی از مقادیر دبی جریان در گام‌های زمانی پیشین و مقادیر بارش در همان گام و گام‌های پیشین به عنوان الگوهای ورودی مدل‌ها استفاده شد. همچنین با توجه به رفتار پرریودیک و فصلی جریان ماهانه از ضریب فصلی α نیز در الگوهای ورودی تعریف شده، استفاده گردید. ضریب α معرف رفتار فصلی جریان ماهانه بوده و مقدار آن برای ماه اول سال یعنی فروردین برابر ۱ و برای ماه اسفند برابر ۱۲ می‌باشد.

نتایج و بحث


پیش‌بینی دبی جریان روزانه

برای مدل شبکه‌های عصبی بهترین پیش‌بینی به ازای الگوی ورودی شامل مقادیر دبی تا ۴ گام زمانی قبل و مقدار بارش در همان روز $Q(t-1)$ ، $Q(t-2)$ ، $Q(t-3)$ ، $Q(t-4)$ ، $P(t)$ صورت گرفت.


در مدل شبکه‌های عصبی مصنوعی، بهترین پیش‌بینی‌های با الگوریتم لونیبرگ-مارکوات به دست آمد. تعداد تکرار برای این الگوریتم برابر ۱۰۰۰ در نظر گرفته شد و تعداد نرون میانی مناسب به ازای بهترین الگوی ورودی برابر ۷ حاصل شد. برای بهترین الگوی

اگر چه این برتری و بهبود در عملکرد مدل چندان محسوس نمی‌باشد.

مقایسه نتایج مدل‌های فازی-عصبی و شبکه‌های عصبی حاکی از برتری نسبی مدل فازی-عصبی دارد



شکل (۴): نمودار سری زمانی و پراکندگی مقادیر دبی روزانه‌مشاهداتی و شبیه‌سازی شده با مدل شبکه‌های عصبی



شکل (۵): نمودار سری زمانی و پراکندگی مقادیر دبی روزانه‌مشاهداتی و شبیه‌سازی شده با مدل فازی-عصبی

داده‌های بخش آزمون و با بکارگیری بهترین الگوی ورودی نشان داده شده است. با توجه به شکل (۶)، می‌توان گفت که عملکرد مدل در پیش‌بینی مقادیر حداقل و متوسط جریان ماهانه مناسب بوده است. همچنین دقت مدل در پیش‌بینی مقادیر حداکثر و سیلابی جریان کمتر بوده است و پیش‌بینی‌های از عدم قطعیت بیشتری برخوردارند.

در شکل (۷) نیز نمودار سری زمانی داده‌های مشاهداتی و شبیه‌سازی شده جریان ماهانه با مدل فازی-عصبی ارائه شده است. در مدل فازی-عصبی نیز مشابه مدل شبکه‌های عصبی بهترین الگوی ورودی شامل مقادیر دبی جریان با یک ماه تاخیر و ضریب فصلی بود. مقدار شعاع طبقه‌بندی به ازای بهترین الگوی ورودی برابر ۰/۵۹ بدست آمد. قابل ذکر



پیش‌بینی دبی جریان ماهانه

با بکارگیری مدل شبکه‌های عصبی و بررسی الگوهای ورودی مختلف، مناسبترین الگوی ورودی شامل ترکیبی از مقدار دبی در ماه قبل و ضریب α بود. بهترین الگوریتم آموزشی شبکه نیز از نوع لونیبرگ-مارکوات بود و تعداد تکرار لازم برای این الگوریتم برابر ۱۰۰۰ بدست آمد. به ازای بهترین الگوی ورودی، تعداد نرون میانی در ساختار شبکه‌های عصبی برابر ۶ بدست آمد. به ازای بهترین الگوی ورودی برای مدل شبکه‌های عصبی، مقادیر شاخص‌های خطا شامل R ، $RMSE$ و MAE به ترتیب برابر ۰/۷۹، ۳/۹۳ و ۴/۲۱ بدست آمدند. در شکل ۶ نمودار سری زمانی و پراکندگی مقادیر جریان ماهانه مشاهداتی و پیش‌بینی شده با شبکه‌های عصبی به ازای سری



ماهانه نیز عملکرد مدل فازی-عصبی اندکی بهتر از مدل شبکه‌های عصبی بوده است. همچنین مقایسه عملکرد مدل‌های مختلف در پیش‌بینی‌های انجام شده روزانه و ماهانه حاکی از آن است که هر دو مدل به ازای الگوهای ورودی یکسان در پیش‌بینی روزانه عملکرد بهتری در مقایسه با مقیاس زمانی ماهانه داشته‌اند. مقایسه نتایج بدست آمده با مطالعه Sanikhani and Kisi (2012) نشان می‌دهد که در این تحقیق نیز استفاده از ضریب فصلی موجب بهبود قابل توجهی در پیش‌بینی جریان ماهانه رودخانه گردید.

است که هر چه مقدار شعاع طبقه‌بندی کمتر باشد تعداد توابع عضویت و قوانین فازی در مدل فازی-عصبی افزایش می‌یابد. به ازای بهترین الگوی ورودی برای مدل فازی-عصبی، مقادیر شاخص‌های خطا شامل R، RMSE و MAE به ترتیب برابر ۰/۸۲، ۳/۹۰ و ۴/۱۷ بدست آمدند.

نتایج به دست آمده نشان داد که استفاده از ضریب فصلی می‌تواند موجب بهبود عملکرد مدل‌ها در پیش‌بینی‌های ماهانه گردد و این مطلب رفتار فصلی جریانات ماهانه را تأیید می‌کند. در پیش‌بینی‌های



شکل (۶): نمودار سری زمانی و پراکندگی مقادیر دبی ماهانه مشاهداتی و شبیه سازی شده با مدل شبکه‌های عصبی



شکل (۷): نمودار سری زمانی و پراکندگی مقادیر دبی ماهانه مشاهداتی و شبیه سازی شده با مدل فازی-عصبی

همچنین عملکرد نسبی مدل فازی-عصبی در مقایسه با مدل شبکه‌های عصبی بهتر است. لذا در این بخش نتایج با اجرای مدل فازی-عصبی مورد بررسی قرار می‌گیرد. همچنین با انتخاب الگوی بهینه در بخش پیش‌بینی ماهانه و اضافه نمودن ترکیب‌های مختلفی از متغیرهای اقلیمی بزرگ مقیاس شامل شاخص

اثر متغیرهای اقلیمی در پیش‌بینی جریان ماهانه

در این بخش به بررسی اثرات متغیرهای اقلیمی بزرگ مقیاس بر روی عملکرد مدل در پیش‌بینی‌های ماهانه پرداخته می‌شود. با توجه به نتایج پیش‌بینی ماهانه مشخص گردید که بهینه‌ترین الگو شامل مقادیر دبی جریان در ماه قبل و ضریب فصلی می‌باشد و

طبقه‌بندی به ازای الگوهای ورودی لحاظ شده در مدل فازی-عصبی ارائه شده است.

با توجه به جدول ۳ (۳)، با بکارگیری متغیرهای اقلیمی بزرگ مقیاس، عملکرد مدل در پیش‌بینی جریان ماهانه بهبود یافته است. بهترین عملکرد مدل به ازای الگوی شماره ۱ بوده است که در آن از متغیر اقلیمی نوسانات جنوبی در همان ماه در ترکیب با دبی جریان در ماه قبل و ضریب فصلی استفاده شده است.

نوسانات جنوبی (SIO) و شاخص نوسانات اتلانتیک شمالی (NAO) به بررسی اثرات متغیرهای اقلیمی در پیش‌بینی ماهانه پرداخته می‌شود. الگوهای ورودی تعریف شده، در جدول ۲ آمده است. اثر شاخص اقلیمی SIO در زمان‌های t ، $t-1$ و $t-2$ به ترتیب با $S(t)$ ، $S(t-1)$ و $S(t-2)$ نشان داده شده‌اند. همچنین اثر شاخص اقلیمی NAO در زمان‌های t ، $t-1$ و $t-2$ به ترتیب با $N(t)$ ، $N(t-1)$ و $N(t-2)$ نشان داده شده‌اند. در جدول ۳ نیز مقادیر شاخص‌های خطا و شعاع

جدول (۲): الگوهای ورودی مدل با لحاظ نمودن اثر متغیرهای اقلیمی بزرگ مقیاس

شماره الگو	الگوی ورودی
۱	$Q(t-1), \alpha, S(t)$
۲	$Q(t-1), \alpha, S(t), S(t-1)$
۳	$Q(t-1), \alpha, S(t), S(t-1), S(t-2)$
۴	$Q(t-1), \alpha, N(t)$
۵	$Q(t-1), \alpha, N(t), N(t-1)$
۶	$Q(t-1), \alpha, N(t), N(t-1), N(t-2)$

جدول (۳): اثر متغیرهای اقلیمی بر عملکرد مدل فازی-عصبی در پیش‌بینی جریان ماهانه

شماره الگو	مقدار شعاع طبقه‌بندی	R	RMSE (m^3/s)	MAE (m^3/s)
۱	۰/۴۶	۰/۹۱	۳/۵۶	۳/۷۳
۲	۰/۷۲	۰/۸۸	۳/۶۸	۴/۸۴
۳	۰/۴۳	۰/۸۷	۳/۷۱	۴/۸۸
۴	۰/۶۵	۰/۸۳	۳/۸۵	۴/۱۲
۵	۰/۳۹	۰/۸۲	۳/۸۶	۴/۱۴
۶	۰/۶۱	۰/۸۲	۳/۸۷	۴/۱۶

متغیرهای اقلیمی، میزان بهبود در نتایج مدل روند نزولی از خود نشان می‌دهد. در یک مقایسه کلی بین نتایج حاصل شده در این بخش که در آن از متغیرهای اقلیمی استفاده شده است، با نتایج بخش قبلی که متغیرهای اقلیمی نقشی در الگوهای ورودی نداشتند می‌توان گفت که استفاده از این متغیرها موجب افزایش دقت مدل گردیده است به طوری که در بهینه‌ترین الگو میزان شاخص‌های ضریب همبستگی، ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا به ترتیب به میزان ۱۱، ۹ و ۱۱ درصد بهبود یافته

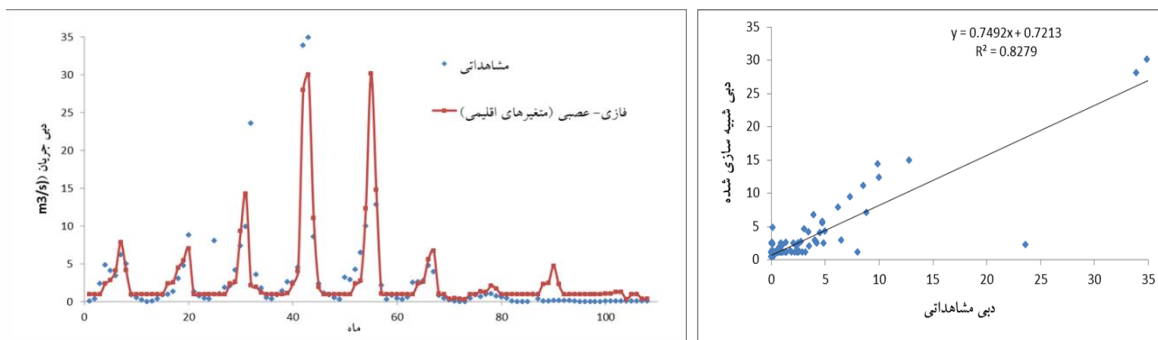
به طور کلی با توجه به نتایج بدست آمده می‌توان گفت که تاثیر شاخص نوسانات جنوبی بر روی عملکرد مدل به مراتب بیشتر از شاخص نوسانات اتلانتیک شمالی بوده است. نتایج ارائه شده در جدول (۳) نشان می‌دهد که اگر چه شاخص نوسانات اتلانتیک شمالی موجب بهبود عملکرد مدل پیش‌بینی شده است اما این بهبود چندان معنی‌دار نبوده است. همچنین نتایج نشان می‌دهد که استفاده از متغیرهای اقلیمی در همان ماه تاثیر بیشتری بر عملکرد مدل پیش‌بینی داشته است و با افزایش تعداد تاخیرهای زمانی

نکته قابل توجه، بهبود عملکرد مدل در پیش‌بینی مقادیر حداکثر جریان است که مدل در مقایسه با شکل ۷، نتایج قابل قبولی در پیش‌بینی مقادیر حداکثر جریان داشته است. دامنه مطالعات انجام شده در خصوص بررسی اثر متغیرهای اقلیمی بزرگ مقیاس بر روی میزان دبی جریان کم و محدود است. نتایج به دست آمده در این بخش همخوانی قابل قبولی با تحقیقات انوری تفتی و همکاران (۱۳۹۰) دارد. در مطالعات آن‌ها نیز استفاده از متغیر اقلیمی نوسانات جنوبی موجب بهبود عملکرد مدل شبکه‌های عصبی در پیش‌بینی دبی جریان گردید.

است که این میزان در پیش‌بینی می‌تواند حائز اهمیت باشد.

نمودار سری زمانی و پراکندگی دبی جریان ماهانه به ازای الگوی بهینه (الگوی ۱) با مقادیر شبیه‌سازی شده توسط مدل فازی-عصبی در شکل ۸ نشان داده شده است.

با توجه به شکل (۸)، می‌توان دید که با بکارگیری متغیر اقلیمی نوسانات جنوبی، عملکرد مدل فازی-عصبی در مقایسه با مدلی که در آن اثر این متغیرها لحاظ نشده بود (شکل ۷) تفاوت محسوسی دارد و مقدار دقت مدل افزایش قابل توجهی داشته است.



شکل (۸): نمودار سری زمانی و پراکندگی مقادیر دبی ماهانه مشاهداتی و شبیه‌سازی شده با مدل فازی-عصبی (اثر متغیرهای اقلیمی)

پیش‌بینی‌های روزانه و ماهانه، عملکرد مدل فازی-عصبی در مقایسه با شبکه‌های عصبی بهتر بود. هر چند این تفاوت در حدود ۳ درصد و چندان محسوس نبود. به ازای الگوهای ورودی یکسان، هر دو مدل شبکه‌های عصبی و فازی-عصبی عملکرد بهتری در پیش‌بینی‌های دبی روزانه در مقایسه با مقادیر ماهانه داشتند. استفاده از متغیرهای اقلیمی بزرگ موجب بهبود عملکرد مدل‌ها در پیش‌بینی ماهانه گردید و در این میان شاخص نوسانات جنوبی سهم بیشتری در بهبود عملکرد مدل داشت.

تقدیر و تشکر

لازم به ذکر است تحقیق حاضر برگرفته از یک طرح پژوهشی دانشگاه اراک می‌باشد که توسط

نتیجه‌گیری

در این مطالعه مدل‌سازی جریان ورودی به مخزن سد کمال صالح در مقیاس‌های روزانه و ماهانه بررسی شد. بهترین پیش‌بینی روزانه و ماهانه به ازای الگوی ورودی شامل مقادیر دبی جریان تا چهار روز قبل و مقدار بارش در همان روز برای هر دو مدل شبکه‌های عصبی و فازی-عصبی بدست آمد. در مدل‌سازی روزانه تعداد نرون میانی شبکه عصبی برابر ۷ بدست آمد. همچنین مقدار شعاع طبقه‌بندی برابر ۰/۴۸ به ازای بهترین الگو حاصل شد. استفاده از ضریب فصلی موجب بهبود عملکرد مدل‌ها در پیش‌بینی‌های ماهانه گردید. بهترین الگوی ورودی در پیش‌بینی‌های ماهانه برای هر دو مدل شبکه‌های عصبی و فازی-عصبی شامل مقدار دبی در ماه قبل و ضریب فصلی بود. در

نویسندگان این مقاله به پایان رسیده است و لذا از معاونت پژوهشی و فن‌آوری دانشگاه اراک که انجام این تحقیق را برای نویسندگان این مقاله میسر نموده‌اند کمال تشکر و قدردانی می‌شود.

منابع

- انوری تفتی، ص.، ب. ثقفیان و س. مرید. ۱۳۹۰. پیش‌بینی جریان رودخانه با مدل‌های ANN و بررسی عملکرد آن با ورودی‌های SIO. مجله پژوهش‌های حفاظت آب و خاک. سال هجدهم، شماره اول، ص ۱۸۰-۱۶۳.
- عبداله‌پور آزاد، م. ر. و م. ت. ستاری. ۱۳۹۴. پیش‌بینی جریان روزانه رودخانه اهرچای با استفاده از روش‌های شبکه‌های عصبی مصنوعی (ANN) و مقایسه آن با سیستم استنتاج فازی-عصبی تطبیقی (ANFIS). مجله پژوهش‌های حفاظت آب و خاک. جلد بیست و دوم، شماره اول، ص ۲۹۸-۲۸۷.
- Chang F. J. and Y. C. Chen. 2001. Counter propagation fuzzy-neural network modelling approach to real time streamflow prediction. *Journal of Hydrology*, 245:153-164.
- Chiu, S., 1994. Fuzzy model identification based on cluster estimation. *Journal of Intelligent and Fuzzy Systems* 2 (3): 267-278.
- Haykin, S., 1999. *Neural Networks: A Comprehensive Foundation*, Prentice-Hall, Upper Saddle River, New Jersey, 842pp.
- Hsu K., H. V.Gupta and S. Sorooshian. 1995. Artificial neural network modelling of the rainfall-runoff process. *Water Resources Research*, 31(10):2517-2530.
- Imrie, C. E., S. Durucan and A. Korre. 2000. River flow prediction using artificial neural networks: generalisation beyond the calibration range. *Journal of Hydrology*, 233(1): 138-153.
- Jang J. S. R. 1993. ANFIS: adaptive-network-based fuzzy inference system *IEEE. Trans System Manage Cybernet.* 23(3):665-685.
- Karayiannis, N. B., and A. N.Venetsanopoulos. 1993. *Artificial Neural Network: Learning Algorithms, Performance Evaluation, and Application*. Kluwer Academic Publisher, Boston.
- Kisi, O. 2004. River flow modelling using artificial neural networks. *Journal of HydrologicEngineering*, 9(1): 60-63.
- Kisi O. 2007. Streamflow forecasting using different artificial neural network algorithms. *ASCE Journal of Hydrologic Engineering*, 12 (5):532-539.
- Kisi O. 2008. River flow forecasting and estimation using different artificial neural network techniques. *Hydrology Research*, 39(1):27-40.
- Kisi, O. and H. Kerem Cigizoglu. 2007. Comparison of different ANN techniques in river flow prediction. *Civil Engineering and Environmental Systems*, 24(3): 211-231.
- Lohani A. K., R. Kumar and R. D. Singh. 2012. Hydrological time series modelling: A comparison between adaptive neuro-fuzzy, neural network and autoregressive techniques. *Journal of Hydrology*, 442-443: 23-35.
- Maier H. R. and G. Dandy. 2000. Neural networks for prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling and Software*, 15(10):1-124.
- Nayak, P. C., K. P.Sudheer, D.M.Rangan and K.S. Ramasastri. 2004. A neuro-fuzzy computing technique for modelling hydrological time series. *Journal of Hydrology*, 29:52-66.
- Sanikhani H. and O. Kisi. 2012. River flow estimation and forecasting by using two different adaptive neuro-fuzzy approaches. *Water Resources Management*, 26:1715-1729.
- Sattari M. T., K. Yurekli, M. Pal. 2012. Performance evaluation of artificial neural network approaches in forecasting reservoir inflow. *Applied Mathematical Modeling*, 36:2649-2657.
- Tamea, S., F. Laio and L. Ridolfi. 2005. Probabilistic nonlinear prediction of river flows. *Water resources research*, 41(9).

Vernieuwe H., O. Georgieva, B. De Baets, V. Pauwels, N. E. Verhoest, and F.P. De Troch. 2005. Comparison of data-driven Takagi–Sugeno models of rainfall–discharge dynamics. *Journal of Hydrology*, 302(1):173-186.

Wang, W. C., K. W. Chau, C. T. Cheng and L. Qiu. 2009. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*, 374: 294–306.

Forecasting of Inflow to Kamal Saleh Reservoir using Soft Computing

Nazanin Shahkarami¹, Hadi Sanikhani², Mojtaba Moradi³

Abstract

Forecasting of inflow to reservoirs is essential in efficient planning and operation of water resources. In this research, the application of two different intelligent models including Artificial Neural Networks (ANNs) and Adaptive Neuro-fuzzy Inference System (ANFIS) technique based on subtractive clustering method are investigated for forecasting inflow to Kamal Saleh reservoir in Markazi province, Iran. For this purpose precipitation and discharge data in a 31-year statistic period (1981-2011) were used and forecasting of inflow was done in the daily and monthly time steps. The amount of discharge and precipitation in previous time steps were used as input patterns for models. Both ANNs and ANFIS models had very acceptable performances at daily and monthly forecasts of inflow based on the error measures; R, RMSE and MAE, however ANFIS model performance was better than ANNs (less than 3%). Using seasonality coefficient (α) improved the performance of models in monthly forecasts. In the following, the effect of large scale climate variables including North Atlantic Oscillation (NAO) index and Southern Oscillation Index (SOI) examined on monthly forecast that was resulted from the best input pattern in optimized model of the previous section. The results showed that using climatic indices in input combination can improve the performance of model to forecast the inflow. Although SOI had greater impact on improving the monthly inflow forecast. So that the statistical indices to evaluate the error of ANFIS model including R, RMSE and MAE obtained as 0.91, 3.56 and 3.73 respectively, this shows the potential of this way to increase the precision by improving the evaluation criteria about 11%, 9% and 11%, respectively.

Keywords: adaptive neuro-fuzzy, artificial neural networks, climatic indices, forecast, subtractive clustering.

¹Assistant Professor of civil engineering, Arak University; n-shahkarami@araku.ac.ir

²Assistant Professor of water engineering, Kurdistan University; hsanikhani12@gmail.com

³Manager of surface water, Markazi Regional Water Authority; mojtaba.moradi54@gmail.com