

شبیه سازی و مقایسه ی برآورد رواناب به روش های شبکه عصبی، رگرسیون و استنتاج فازی (مطالعه ی موردی: حوضه آبریز دز)

غزاله احمدیان احمدآباد^۱ و محمود ذاکری نیری^{۲*}

^۱ دانش آموخته رشته مهندسی و مدیریت منابع آب، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی- واحد اسلامشهر، اسلامشهر، ایران
^۲ گروه عمران، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی- واحد اسلامشهر، اسلامشهر، ایران

(دریافت: ۹۹/۱۱/۱۳ پذیرش: ۱۴۰۰/۰۹/۰۷)

چکیده

به علت بروز خشکسالی های متمادی و کاهش شدید بارندگی در چند دهه اخیر، پیش بینی وضعیت اندازه جریان منابع آب های سطحی در رودخانه ها جهت مدیریت منابع آب اهمیت ویژه ای یافته است. از این نظر، اندازه ی بده ی عبوری از رودخانه ها که مهم ترین منبع تغذیه ی آب پشت سدها است، جزء مهم ترین عوامل در زمینه ی پیش بینی آب های سطحی به شمار می رود. برای ارزیابی دقت شبیه های مختلف، از داده های رواناب ۱۳ ایستگاه فاقد روند در حوضه ی آبریز دز استفاده شده است. در این تحقیق، به منظور شبیه سازی رواناب در حوضه ی آبریز دز، از روش های شبکه عصبی مصنوعی، رگرسیون و سیستم های استنتاج فازی عصبی تطبیقی با رویکرد کلاسترینگ و شبکه بندی استفاده شد. نتایج شبیه سازی رواناب با کاربرد روش های ذکر شده با استفاده از شاخص های آماری $RMSE$ ، R و NSE ارزیابی شدند. در حالت کلی نتایج حاکی از دقت قابل قبول هر سه روش است. مقایسه بین مدل های ANN ، $ANFIS$ و SVR نشان داد هر چند که اختلاف در دقت مدل ها بسیار ناچیز است، می توان گفت هر سه مدل جواب قابل قبول و نزدیک به هم داشته اند. نتایج نشان می دهد که $ANFIS$ و ANN با رویکرد کلاسترینگ به ترتیب با نش ساتکلیف $0/66$ و $0/66$ در دوره ی تست، توانایی بیشتری در شبیه سازی نسبت به دو مدل SVR و $ANFIS$ با رویکرد شبکه بندی دارند. **واژه های کلیدی:** حوضه ی آبریز دز، شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان، سیستم های استنتاج عصبی فازی تطبیقی

۱ مقدمه

استفاده شده است. مقایسه ی نتایج این شبیه ترکیبی و شبیه انفیس نشان داد که شبیه عصبی- موجکی، به شرط تنظیم فراسنج های ساختار آن بهتر از انفیس عمل کرده و می تواند جایگزین مناسبی برای شبیه های پیش بینی قبلی باشد. بهترین شبیه سازی با موجک گوسی در سطح سوم تجزیه به دست آمد. پس از آن، شبیه انفیس با استفاده از ۴ تابع عضویت گوسی و همچنین موجک دابشیز ۴ در سطح سوم تجزیه بهترین شبیه ها به دست آمدند. نتایج نشان می دهد، مدل انفیس نسبت به شبکه عصبی، فرآیند بارش رواناب را با دقت بالاتری پیش بینی نموده است. (وانگ و همکاران، ۲۰۰۹)، از مدل های ANN ،

با گسترش روز افزون کاربردهای مبتنی برهوش مصنوعی در دو دهه ی اخیر، استفاده از شبیه سازی های متکی بر شبکه های عصبی مصنوعی به طور گسترده ای در مباحث مربوط به پیش بینی فراسنجهای مختلف منابع آب مورد استفاده قرار گرفته، و محققان مختلف به دقت بالای این روش در مقایسه با شبیه های گروه زمانی تاکید نموده اند. در ادامه به تعدادی از این تحقیقات اشاره می گردد: (علیرضا یزدان پناه و همکاران، ۱۳۹۴)، از روش های شبکه عصبی مصنوعی، تجزیه موجکی و شبکه عصبی فازی ($ANFIS$) جهت پیش بینی بده رودکر

مدل ELM کمترین مقدار RMSE حدود ۲۱.۳ درصد نسبت به SVR^۸ و تقریباً ۴۴.۷ درصد نسبت به GRNN به دست آمده است. (نورانی و همکاران، ۲۰۱۷)، از روش EANN^۹ برای مدلسازی بارش رواناب دو زیر حوضه lobsholecreek و moselle با دو شرایط آب و هوایی متفاوت استفاده کرده است. عملکرد مدل EANN را با مدل FFNN مورد مقایسه قرار داده اند. نتایج نشان می دهد که EANN نسبت به FFNN^{۱۰} نتایجش مطلوب تر بوده است. نتایج نشان می دهد که EANN به طور مرسوم مدل شبکه عصبی را تا ۱۳ درصد و ۳۴ درصد از لحاظ آموزش و کارایی (بهره وری) بهبود بخشیده است. EANN نسبت به ANN در تشخیص شرایط خشک و مرطوب، برتر است. EANN با ANN مورد مقایسه قرار داده شده است که بیشتر از ANN در مدل سازی استفاده می شود. بررسی سوابق مطالعاتی انجام شده نشان می دهد، مطالعات فوق اقدام به پیش بینی به صورت ماهانه و ساعتی نموده اند، این مطالعه نیز اقدام به پیش بینی رواناب به صورت ماهانه نموده است. هدف اصلی این تحقیق، شبیه سازی رواناب حوضه ی دز با استفاده از رویکرد کلاسترینگ و در نتیجه مقایسه و سنجش توانایی آن با رویکرد شبکه بندی، شبکه عصبی و رگرسیون است. نتایج تحقیق حاضر با تحقیق انجام شده توسط (وانگ و همکاران، ۲۰۰۹)، نیز مطابقت دارد.

۲ مواد و روش ها

۱-۲- منطقه ی مورد مطالعه و اطلاعات مورد استفاده
حوضه آبریز رودخانه دز از لحاظ موقعیت جغرافیایی ۴۸ درجه ۲۷ دقیقه ۲۸ ثانیه طول شرقی و ۳۲ درجه ۳۶ دقیقه ۳۳ ثانیه عرض شمالی واقع شده است. سطح حوضه ی آبخیز رود تا محل سد بختیاری ۶۳۶۹ کیلومتر مربع تا محل سد

ANFIS^۱، GP^۲ و SVM^۲ جهت پیش بینی دبی ماهانه استفاده کرده اند و نتایجش با مدل ARMA^۳ مورد مقایسه قرار داده شده است. در مطالعه ی فوق الذکر، نیروگاه آبی manwan در رودخانه ی Lancangjiang به عنوان منطقه ی مورد مطالعه انتخاب شده است. در مرحله ی تایید مدل ANFIS پیش بینی مدل ARMA را با ۶/۰۶ درصد و ۲۰/۱۲ درصد کاهش در مقادیر RMSE و MAPE بهبود می بخشیده است. مطالعات نشان می دهد مدل ANFIS، GP و SVM در مدل سازی دبی ماهانه مناسب می باشند. (طالعی و همکاران، ۲۰۱۲)، اثر تاخیرات زمانی در مدل سازی بارش- رواناب در یک حوضه ی آبریز در سنگاپور را با استفاده از مدل انفیس مورد مطالعه قرار داده اند. عملکرد انفیس را با ANN^۴، SWMM^۵ مورد مقایسه قرار داده اند. نتایج نشان می دهد، مدل انفیس نتیجه ی مطلوب تری در پیش بینی دبی پیک از خود نشان داده است. به عبارتی دیگر، انفیس نتایج بهتری را در مقایسه با مدل SWMM از خود نشان می دهد. (بدرزاده و همکاران، ۲۰۱۵)، از مدل های شبکه عصبی مصنوعی، سیستم های استنتاج عصبی فازی تطبیقی، شبکه های عصبی موجک و ترکیب سیستم های استنتاج عصبی فازی تطبیقی با موجک را جهت پیش بینی رواناب استفاده کرده اند. تمامی مدل ها به طور قابل ملاحظه ای تا حداکثر ۱۲ ساعت زمان مورد استفاده قرار گرفته شده اند. نتایج

نشان می دهد مدل های پایه ای موجک به طور قابل توجهی نتایج بهتری نسبت به شبکه عصبی و سیستم های فازی در پیش بینی های طولانی مدت از خود نشان داده اند. (یاسین و همکاران، ۲۰۱۶)، از مدل های ELM^۶، رگرسیون بردار پشتیبان و مدل GRNN^۷ جهت پیش بینی جریان ماهانه ی رودخانه ی Tigris در عراق استفاده نموده اند. نتایج نشان می دهد که مدل ELM از سایر مدل ها مطلوب تر بوده است.

^۶ extreme learning machine

^۷ Generalized Regression Neural Network

^۸ Support Vector Machine

^۹ Emotional Artificial Neural Network

^{۱۰} Feed Forward Neural Network

^۱ Genetic-Programming

^۲ Support Vector Machine

^۳ Auto Regressive Moving Average

^۴ Artificial Neural Network


^۵ Storm Water Management Model

۲-۲- مجموعه داده های مورد استفاده یکی از مهم ترین مراحل در مدل سازی، انتخاب الگوی مناسب از متغیرهای ورودی است. از این رو، ابتدا همبستگی بین ایستگاهها مورد بررسی قرار گرفت، سپس ایستگاه های دارای همبستگی اندک حذف شدند. سپس ایستگاههای دارای بیشترین همبستگی، با استفاده از آزمون من کندال، مورد بررسی قرار گرفته شده اند. سپس ایستگاههای فاقد روند انتخاب شدند. از کل مجموعه داده ها بصورت تصادفی، ۷۰ درصد جهت کالیبراسیون و ۳۰ درصد باقی مانده جهت تست انتخاب شدند. در این مطالعه، از الگوهای ورودی مطابق جدول (۱) جهت پیش بینی رواناب ماه تر، براساس سوابق گذشته که ماه خشک است، استفاده شده است. $Q(t)$: خروجی یا مقادیر پیش بینی جریان، $Q(t-1)$: اولین ورودی با یک ماه تاخیر و f : نشان دهنده ی نوع مدل است

دز ۱۷۴۲۸ کیلومتر مربع است. میانگین شیب و ارتفاع سد بختیاری و دز به ترتیب ۲۰/۶۵ و ۱۶/۱۱ درصد و ۲۲۱۲ و ۱۹۷۴ متر از سطح دریا است. این رود از دو شاخه ی عمدی و چند شاخه ی کوچک دیگر تشکیل می شود. آب بختیاری یا آب زالکی و رود سزار، شاخه های بزرگ رود دز را به وجود آورده اند. در این تحقیق، هدف ساخت شبیه پیش بینی بده ی ماهانه ی حوضه ی آبریز دز است که اطلاعات آماری آن برگرفته از ۱۳ ایستگاه فاقد روند است. ایستگاههای فاقد روند شامل دزفول، تله زنگ، تنگ پنج (بختیاری)، کشور، گوکان، چرخ و فلک، کاکلستان، کمال صالح، مروئک، حسن اباد، ونایی (سراب سفید)، سازمان آب و تپه چغا است. در این مطالعه داده های سری زمانی دبی ماهانه از پایگاه wrs.wrm.ir/amar/login.asp استخراج شده است. شکل ۱، موقعیت مکانی حوضه ی آبریز است.

جدول ۱. الگوهای ورودی اعمال شده به مدل ها.

میزان تاخیر	الگوهای ورودی
یک ماه	$Q(t)=f[Q(t-1)]$
دو ماه	$Q(t)=f[Q(t-1),Q(t-2)]$
سه ماه	$Q(t)=f[Q(t-1),Q(t-2),Q(t-3)]$



شکل ۱. موقعیت مکانی حوضه آبریز دز

۲-۳- شبکه عصبی مصنوعی

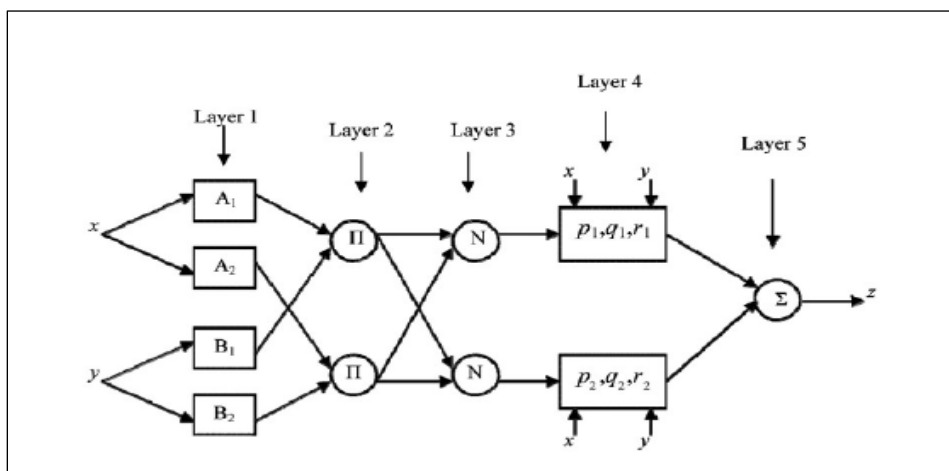
شبکه عصبی مصنوعی، سیستمی است که با پردازش روی داده های موجود، رابطه ی نهفته بین داده ها را شناسایی می کند و هدف از آموزش شبکه عصبی این است که شبکه قانون کار را یاد بگیرد و پس از آموزش به ازای هر ورودی، خروجی مناسب را ارائه دهد (شکفته و همکاران، ۱۳۹۹). هر شبکه عصبی به طور کلی از سه لایه تشکیل شده است. (شکل ۲). لایه ی ورودی که نقش معرفی فراسنج های ورودی به شبکه را برعهده دارد، لایه ی خروجی محل استقرار فراسنج های خروجی شبکه و لایه ی پنهان (لایه ی ما بین لایه ی ورودی و خروجی) که در واقع نقش پردازشگری اطلاعات را برعهده دارند (صف شکن و همکاران، ۱۳۹۶). یک شبکه عصبی مصنوعی علائم را از واحدهای ورودی دریافت کرده و این علائم در طول انتشار یافته و در نهایت به سوی نرون خروجی حرکت می نمایند. شبکه عصبی مورد استفاده، شبکه عصبی MLP با یک لایه ی پنهان است. نوع تابع فعال سازی برای لایه پنهان و خروجی به تبعیت از تحقیق (وانگ و همکاران، ۲۰۰۹) به ترتیب: تانژانت معکوس (tansig) و تابع خطی (purelin) است. از الگوریتم یادگیری لوبنرگ-مارکوآرت LM (Levenberg-Marquardt) جهت آموزش شبکه استفاده شده است.

۲-۴- امانه ی استنتاج تطبیقی عصبی-فازی

منطق فازی به وسیله ی دانشمند بزرگ ایرانی پروفیسور لطفی زاده ارائه شد، به مرور گسترده شد تا جایی که به عنوان ابزار بسیار قوی در پیش بینی، شبیه سازی، تنظیم و بررسی و بسیاری مسائل دیگر خصوصا در حوزه ی هوش مصنوعی تبدیل شد (یزدان پناه و همکاران، ۱۳۹۴). این سامانه همانند شبکه های عصبی مصنوعی با الگوبرداری از سامانه کارکرد مغز انسان، با پردازش داده های تجربی، و بدون توجه به فیزیک مساله، قانون نهفته ی ما بین این اطلاعات را کشف می نماید. ANFIS قابلیت خوبی را در آموزش، ساخت و طبقه بندی داشته، و هم چنین

دارای این مزیت است که اجازه ی استخراج قوانین فازی را از اطلاعات عددی می دهد، و به طور تطبیقی یک قاعده-بنیاد می سازد (حسن پور و همکاران، ۱۳۹۳). علاوه بر این، می تواند تبدیل پیچیدگی هوش بشری را به سامانه های فازی تنظیم کند. مشکل اصلی شبیه پیش بینی ANFIS، احتیاج نسبتا زیاد به زمان برای آموزش ساختار و تعیین فراسنجهاست. ساختار شبیه سازی ANFIS از پنج لایه تشکیل می گردد شکل (۳). به منظور ساده سازی، فرض می شود که سامانه استنتاجی مورد نظردو ورودی x ، y و یک خروجی Z دارد. برای یک شبیه سازی تاکاگی-سوگنودر درجه اول، می توان یک مجموعه قانون نمونه را با دو قانون "اگر-آن گاه" فازی به صورت زیر بیان کرد: قانون اول: اگر X برابر $A1$ و y برابر $B1$ باشد، آن گاه $Z1 = P1X + q1Y + r$ قانون دوم: اگر X برابر $A2$ و Y برابر $B2$ باشد، آن گاه $Z2 = P2 + q2Y + r2$ که qi و pi ($i=1,2$)

فراسنجهای خطی در بخش تالی شبیه سازی تاکاگی-سوگنو درجه اول هستند. ویژگی متمایز کننده ی ANFIS، فراهم کردن الگوریتم یادگیری پیوندی، روش شیب، و روش حداقل مربعات، به منظور اصلاح فراسنج ها است. روش شیب بکار گرفته می شود تا فراسنج های غیر خطی مقدماتی را تنظیم کند، در حالی که روش حداقل مربعات مورد استفاده قرار می گیرد تا فراسنج های خطی بخش تالی را تعیین کند. در ابتدا فراسنج های بخش مقدم (توابع عضویت) ثابت فرض شده و با استفاده از روش حداقل مربعات فراسنجهای بخش تالی تعیین می شوند، سپس علائم خطا پس انتشار می یابند. روش شیب استفاده می شود تا فراسنج های مقدماتی از طریق حداقل کردن تابع هزینه در درجه دوم کلی، اصلاح شود. در این مطالعه، به تبعیت از تحقیق (بدر زاده و همکاران، ۲۰۱۵)، تابع عضویت bell-shaped اعمال شده است. انفیس از الگوریتم یادگیری هیبرید جهت بهینه سازی پارامترهایش استفاده می کند. در این مطالعه از دو رویکرد جهت ایجاد FIS پایه استفاده شده است: ۱- رویکرد مبتنی بر شبکه بندی ۲- رویکرد مبتنی بر کلاسترینگ



شکل ۳. نمای کلی از شبکه استنتاج عصبی فازی تطبیقی

۵-۲- رگرسیون بردار پشتیبان

ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه سازی مقید است که از اصل استقرار کمیته سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می گردد (سبحانی و همکاران، ۱۳۹۶). هدف پیدا کردن فرم تابعی برای $f(x)$ است.

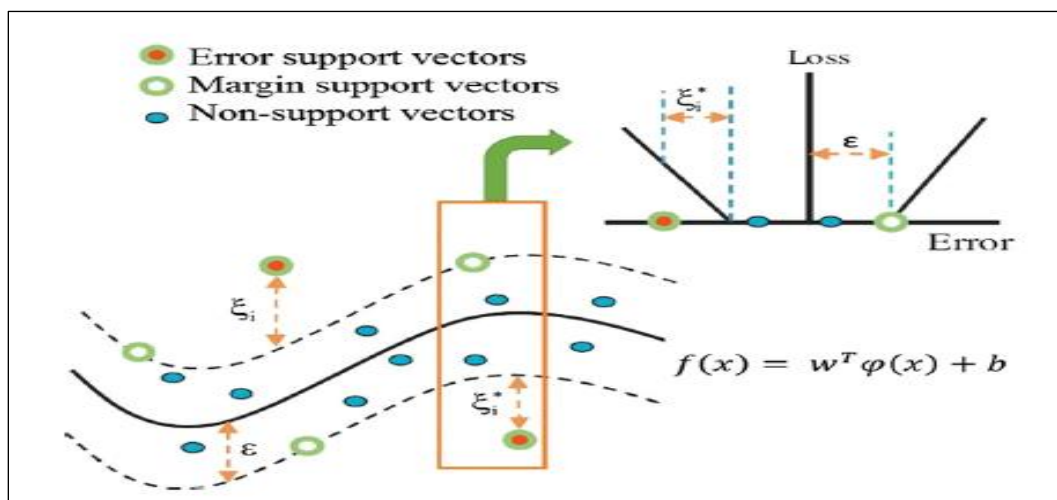
$$f(x) = W^T \cdot \phi(X) + b \quad (1)$$

بردار ضرایب W ، ثابت b و تابع کرنل ϕ در این رابطه با حل مسئله بهینه سازی محدب و با استفاده از روش لاگرانژی واصل کمیته سازی خطای ساختار بدست می آیند. در مطالعات

اصل کمیته بارش رواناب عمدتاً از تابع RBF استفاده می شود زیرا ماشین بردار پشتیبان در مقایسه با سایر توابع از دقت بیشتری در شبیه سازی برخوردار است.

$$k(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{\sigma^2}\right) \quad (2)$$

تابع کرنل مورد استفاده در این تحقیق نیز به تبعیت از تحقیق (یاسین و همکاران، ۲۰۱۶)، RBF است. برای انجام فرایند محاسبات، کدی در متلب نوشته شده است. در شکل ۴، ماشین بردار پشتیبان غیر خطی نشان داده شده است.



شکل ۴. ماشین بردار پشتیبان غیر خطی (یاسین و همکاران، ۲۰۱۶)

۳ نتایج و بحث

دقیق تر بوده و خطای کمتری را دارد. مقدار R و NSE به یک نزدیک تر باشد، نشان دهنده ی تطابق بهتر مقادیر تخمین و مقادیر اندازه گیری شده است. RMSE به صفر نزدیک باشد، نشان دهنده ی خطای پایین مدل در برآورد رواناب است. Q_{obs} : میانگین دبی مشاهداتی، Q_{for} : میانگین دبی شبیه سازی شده

در نهایت برای ارزیابی عملکرد روش های مختلف در برآورد رواناب ماهانه، برخی معیارهای اساسی از جمله ضریب همبستگی، ریشه میانگین مربعات خطا و ضریب نش- ساتکلیف مورد استفاده قرار گرفته اند. هر شبیه سازی، مقداری خطا را دارا است. در واقع هر اندازه مقدار واقعی Q_{obs} به مقدار پیش بینی شده به وسیله ی شبیه Q_{for} نزدیک تر باشد، شبیه سازی

$$RMSE = \sqrt{\left(\frac{1}{N} \sum_{i=1}^N (Q_{for.i} - Q_{obs.i})\right)^2} \quad (۳)$$

$$, \infty \leq E_{NS} \leq 1 E_{NS} = 1 - \left(\frac{\sum_{i=1}^N (Q_{for.i} - Q_{obs.i})^2}{\sum_{i=1}^N (Q_{for.i} - \overline{Q_{for.i}})^2}\right) \quad (۴)$$

$$R = \left(\frac{\sum_{i=1}^N (Q_{obs.i} - \overline{Q_{obs.i}}) \sum_{i=1}^N (Q_{for.i} - \overline{Q_{for.i}})}{\sqrt{\left(\frac{1}{N} \sum_{i=1}^N (Q_{obs.i} - \overline{Q_{obs.i}})\right)^2} \sqrt{\left(\frac{1}{N} \sum_{i=1}^N (Q_{for.i} - \overline{Q_{for.i}})\right)^2}} \right) \quad (۵)$$

سازی شده می باشند. نتایج حاصل ارایه شده اند. جدول ۲، نتایج حاصل از شبیه سازی شبکه عصبی است. نتایج نشان می دهد الگوی ورودی شماره ۲ به عنوان الگوی

۳-۱- نتایج در قالب جدول و نمودار


سامانه استنتاج عصبی فازی (انفیس) با رویکرد کلاسترینگ و شبکه بندی، شبکه عصبی و رگرسیون از جمله روش های پیاده

جدول ۲. مقادیر شاخص های ارزیابی نتایج شبکه عصبی با الگوهای ورودی مختلف


شبکه عصبی						
کالیبراسیون						تست
NSE	RMSE	R	NSE	RMSE	R	میزان تاخیر
۰/۶۹	۷۹/۴۱	۰/۸۳	۰/۶۲	۹۵/۷۱	۰/۸۰	یک ماه
۰/۷۰	۷۹/۹۱	۰/۸۴	۰/۶۶	۹۲/۲۰	۰/۸۱	دوماه
۰/۷۱	۷۶/۴۵	۰/۸۴	۰/۶۵	۱۰۰/۷۳	۰/۸۱	سه ماه

داده شده است. نتایج نشان می‌دهد، شبکه عصبی، در مرحله آموزش و آزمون با ضریب همبستگی ۰/۸۴ و ۰/۸۱ با توجه به در اولویت قرار دادن مقدار ضریب همبستگی و ضریب نش در مرحله ی آزمون، شبیه سازی خوبی از رواناب داشته است.


برتر با توجه به در اولویت قرار دادن مقدار ضریب همبستگی و ضریب نش - ساتکلیف در مرحله ی تست، انتخاب شد. در شکل ۵، نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده و در شکل ۶ مقادیر جریان اندازه گیری و شبیه سازی شده نشان




شکل ۵-الف. نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با شبکه عصبی در دوره ی آموزش



شکل ۵-ب. نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با شبکه عصبی در دوره ی آزمون



شکل ۶-الف. مقادیر جریان اندازه گیری شده و شبیه سازی شده با شبکه عصبی در دوره ی آموزش




شکل ۶-ب. مقادیر جریان اندازه گیری شده و شبیه سازی شده با شبکه عصبی در دوره ی آزمون

فازی تطبیقی با رویکرد شبکه بندی است. با توجه به مقادیر بدست آمده در جدول ۳، الگوی ورودی شماره ۱ با ضریب نش ۰/۶۳ در مرحله ی آزمون شبکه، بعنوان الگوی برتر انتخاب شد. در شکل ۷، نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده و در شکل ۸، مقادیر جریان اندازه گیری و شبیه سازی شده نشان داده شده است


نتایج نشان می دهد شبکه عصبی در مرحله آموزش و آزمون با ضریب همبستگی ۰/۸۴ و ۰/۸۱ و ضریب نش ۰/۶۶ با توجه به در اولویت قرار دادن مقدار ضریب همبستگی و ضریب نش در مرحله ی آزمون، شبیه سازی خوبی از رواناب داشته است. مقادیر R و NSE هر چه به یک نزدیک تر باشد، نشان دهنده ی تطابق بهتر مقادیر مشاهداتی و شبیه سازی شده است. جدول ۳، نتایج حاصل از شبیه سازی با سیستم های استنتاج عصبی

جدول ۳. مقادیر شاخص های ارزیابی نتایج سیستم های فازی با رویکرد شبکه بندی


آموزش			آزمون			
NSE	RMSE	R	NSE	RMSE	R	میزان تاخیر
۰/۷۰	۸۰/۸۸	۰/۷۰	۰/۶۳	۹۱/۷۲	۰/۵۸	یک ماه
۰/۷۲	۷۲/۱۰	۰/۷۲	۰/۶۰	۱۱۰/۹	۰/۴۸	دوماه
۰/۷۷	۷۴/۲۰	۰/۷۷	۰/۶۰	۸۳/۹۲	۰/۷۱	سه ماه




شکل ۷-الف. نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با سیستم های استنتاج فازی با رویکرد شبکه بندی در مرحله ی آموزش.



شکل ۷-ب. نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با سیستم های استنتاج فازی با رویکرد شبکه بندی در دوره ی آزمون



شکل ۸-الف. مقادیر جریان اندازه گیری و شبیه سازی با سیستم های فازی با رویکرد شبکه بندی در دوره ی آموزش.



شکل ۸-ب. مقادیر جریان اندازه گیری و شبیه سازی با سیستم های فازی با رویکرد شبکه بندی در دوره ی آزمون


در شکل ۱۰، مقادیر جریان اندازه گیری و شبیه سازی شده نشان داده شده است. به وضوح دیده می شود که سیستم های استنتاج فازی با رویکرد کلاسترینگ در مرحله آموزش و آزمون به ترتیب با ضریب همبستگی ۰/۶۵ و ۰/۶۶ و ضریب نش ۰/۶۶ در دوره ی آزمون، شبیه سازی خوبی از رواناب داشته است.

در جدول ۴، نتایج حاصل از شبیه سازی با رویکرد کلاسترینگ است. نتایج نشان می دهد، الگوی ورودی شماره ۳ به عنوان الگوی برتر با توجه به در اولویت قرار دادن مقدار ضریب همبستگی و ضریب نش در مرحله تست، انتخاب شد. در شکل ۹، نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده و


جدول ۴. مقادیر شاخص های ارزیابی نتایج سیستم های عصبی فازی تطبیقی با رویکرد کلاسترینگ

سیستم های استنتاج عصبی فازی تطبیقی با رویکرد کلاسترینگ							
آموزش				آزمون			
میزان تاخیر	NSE	RMSE	R	NSE	RMSE	R	تعداد کلاسترها
یک ماه	۰/۶۵	۸۹/۱۵	۰/۶۵	۰/۶۶	۸۷/۱۵	۰/۶۰	۹
دو ماه	۰/۶۸	۸۹/۲۱	۰/۶۸	۰/۵۹	۱۰۰/۸۶	۰/۶۵	۹
سه ماه	۰/۶۵	۸۶/۳۹	۰/۶۵	۰/۶۶	۹۱/۷۱	۰/۶۵	۹


شبیه سازی و مقایسه ی برآورد رواناب به روش های شبکه عصبی، رگرسیون و استنتاج فازی ...




شکل ۹-الف. نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با رویکرد کلاسترینگ در دوره ی آموزش



شکل ۹-ب. نمودار پراکندگی دبی مشاهداتی و شبیه سازی شده با رویکرد کلاسترینگ در دوره ی آزمون



شکل ۱۰-الف. مقادیر جریان اندازه گیری و شبیه سازی شده با رویکرد کلاسترینگ در دوره ی آموزش




شکل ۱۰-ب. مقادیر جریان اندازه گیری و شبیه سازی شده با رویکرد کلاسترینگ در دوره ی آزمون

جدول ۵. مقادیر شاخص های ارزیابی نتایج رگرسیون بردار پشتیبان با الگوهای ورودی مختلف.


رگرسیون بردار پشتیبان							
کالیبراسیون				تست			
میزان تاخیر	NSE	RMSE	R	NSE	RMSE	R	پارامترهای رگرسیون بردار پشتیبان
یک ماه	۰/۶۷	۸۷/۸۱	۰/۸۲	۰/۴۶	۱۳۵/۶۱	۰/۶۹	C=6000,Epsilon=40,Sigma=50
دو ماه	۰/۸۰	۶۹/۴۹	۰/۸۹	۰/۲۴	۱۰۳/۳۹	۰/۶۷	C=6000,Epsilon=40,Sigma=50
سه ماه	۰/۹۱	۴۵/۱۶	۰/۹۵	۰/۳۱	۱۴۰/۱۴	۰/۶۰	C=6000,Epsilon=40,Sigma=50

برتر انتخاب شد. در شکل ۱۱، نمودار پراکنندگی دبی شبیه سازی شده در مقابل دبی مشاهداتی نشان داده شده است. در شکل ۱۲، مقادیر جریان اندازه گیری و شبیه سازی شده نشان داده شده است.

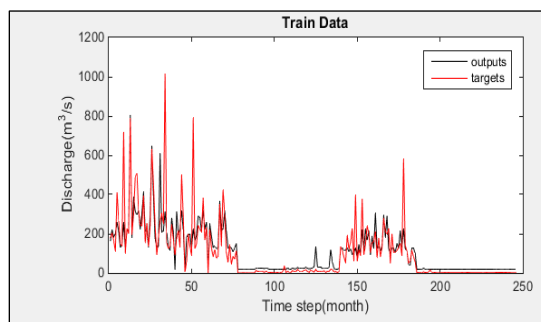
در جدول ۵، نتایج حاصل از شبیه سازی با رگرسیون بردار پشتیبان نشان داده شده است. پارامترهای مدل رگرسیون بردار پشتیبان C، epsilon و sigma است. نتایج نشان می دهد، الگوی ورودی شماره ۱ با ضریب نش ۰/۴۶ به عنوان الگوی




شکل ۱۱-الف. نمودار پراکنندگی دبی مشاهداتی و شبیه سازی شده با رگرسیون بردار پشتیبان در دوره ی آموزش.



شکل ۱۱-ب. نمودار پراکنندگی دبی مشاهداتی و شبیه سازی شده با رگرسیون بردار پشتیبان در دوره ی آموزش.



شکل ۱۲-الف. مقادیر جریان اندازه گیری شده و شبیه سازی شده با رگرسیون بردار پشتیبان در دوره ی آموزش.



شکل ۱۲-ب. مقادیر جریان اندازه گیری و شبیه سازی شده با رگرسیون بردار پشتیبان در دوره ی آزمون.

۴ نتایج

پیش بینی دبی جریان در رودخانه ها یکی از مهم ترین موضوعات مهندسی آب است. در این تحقیق سعی بر آن شد عملکرد مدل هایی جهت شبیه سازی جریان ماهانه ی حوضه ی آبریز دز با استفاده از داده های ماهانه مورد ارزیابی قرار گیرد. مدل های به کار رفته شامل مدل های ماشین بردار پشتیبان، شبکه عصبی و سیستم های استنتاج فازی با رویکرد کلاسترینگ و شبکه بندی است. مقادیر جریان مشاهداتی با جریان پیش بینی شده با استفاده از معیارهای ارزیابی مورد مقایسه قرار گرفت. نتایج تحقیق را می توان به صورت زیر خلاصه کرد: در حالت کلی، نتایج حاکی از دقت قابل قبول هر سه روش در شبیه سازی دبی ماه تر است و همچنین نتایج نشان می دهد که ANN و ANFIS با رویکرد کلاسترینگ توانایی بیشتری در شبیه سازی نسبت به دو مدل SVR و ANFIS با رویکرد شبکه بندی دارند.

۵ منابع

حسن پور، ف و شیخعلی پور، ز، ۱۳۹۳، مقایسه روش های هوش مصنوعی و ماسکینگهام در تخمین روند یابی سیلاب، مجله مهندسی منابع آب، سال ۷، شماره ۲۱، صفحات ۹۷ تا ۱۰۸.

رستمی، ر، صدقی، ح و معتمدی، ع، ۱۳۸۸، تحلیل سیلاب حوضه ی دز، مجله مهندسی آب، سال ۲، شماره ۳، صفحات ۶۱ تا ۷۰.

قربانی، م، ازانی، ع و محمودی وانعلیا، س، ۱۳۹۴، مدل سازی بارش - رواناب با استفاده از مدل های هوشمند هیبریدی، تحقیقات منابع آب ایران، سال ۱۱، شماره ۲، صفحات ۱۴۶ تا ۱۵۰.

یزدان پناه، ع، و برهمند، ن، ۱۳۹۴، پیش بینی با کاربرد شبیه تلفیقی شبکه ی عصبی مصنوعی و تجزیه

مجازی مجازی شبکه های توزیع آب با استفاده از شبکه ی عصبی مصنوعی، مجله تحقیقات منابع آب ایران، شماره ۳، صفحات ۴۷ تا ۶۲.

8. Badrzadeh, H., Sarukkalige, R. and Jayawardena, A.W., 2015. Hourly runoff forecasting for flood risk management: Application of various computational intelligence models. *Journal of Hydrology*, 529, pp.1633-1643.
- Yaseen, Z.M., Jaafar, O., Deo, R.C., Kisi, O., Adamowski, J., Quilty, J. and El-Shafie, A., 2016. Stream-flow forecasting using extreme learning machines: a case study in a semi-arid region in Iraq. *Journal of Hydrology*, 542, pp.603-614.
- Wang, W.C., Chau, K.W., Cheng, C.T. and Qiu, L., 2009. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of hydrology*, 374(3-4), pp.294-306.
- Nourani, V., 2017. An Emotional ANN (EANN) approach to modeling rainfall-runoff process. *Journal of Hydrology*, 544, pp.267-277.
- Talei, A. and Chua, L.H., 2012. Influence of lag time on event-based rainfall-runoff modeling using the data driven approach. *Journal of hydrology*, 438, pp.223-233.

موجکی و مقایسه نتایج با شبیه انفیس (مطالعه موردی: رود کر)، مجله مهندسی منابع آب، سال ۸، شماره ۲۶، صفحات ۲۳ تا ۳۴.

صف شکن، ف.، پیرمردیان، ن و افشین شریفیان، ر.، ۱۳۹۶، ارزیابی و مقایسه روش شبکه عصبی مصنوعی و نرم افزار HEC-HMS در شبیه سازی آنمود بارش - رواناب در حوضه آبخیز معرف کسلیان، مجله مهندسی منابع آب، سال ۱۰، شماره ۳۵، صفحات ۷۱ تا ۸۴

سبحانی، ب.، عیسی زاده، م و شیرزاد، م.، ۱۳۹۶، شبیه سازی خود همبسته جریان حوضه آبریز زرینه رود با استفاده از روش تجزیه پروکراستس و مدل های شبکه عصبی مصنوعی و ماشین بردار پشتیبان، نشریه حفاظت منابع آب و خاک، سال ۶، شماره ۴، صفحات ۱۳۴ تا ۱۱۹.

شکفته، م.، ر.، جلیلی قاضی زاده، م.، ر و یزدی، ج.، ۱۳۹۹، تئوری شناسایی محدوده نشست در نواحی