



Long-Lead Streamflow Forecasting using  
Artificial Neural Networks and Fuzzy  
Inference System

Sh. Araghinejad<sup>1</sup>, M. Karamouz<sup>2</sup>

Abstract

Conceptual models have been often used in short- or mid-term hydrologic forecasting. In this paper a framework for combining two conceptual climatic and hydrologic models is used in order to generate long-lead Ensemble Streamflow Prediction (ESP) of streamflow to Zayandeh-rud reservoir. In the proposed approach, two models based on a Fuzzy Inference System (FIS) for seasonal rainfall forecasts and Artificial Neural Networks (ANNs) for mapping hydroclimatic variables to streamflow data are used. Illusions such as clustering of rainfall and streamflow data, a proper calibration procedure as well as using a stopped training approach in ANN calibration, improve the accuracy of the forecasts. The results of the proposed approach are assessed by various criteria. Further, the results are compared with an ANN-based streamflow forecast, which uses the observed hydroclimatic data in monthly streamflow forecasting. The results show that using the proposed approach has the advantage of generating proper long-lead point and ensemble forecasts, which could be potentially used to reflect the uncertainty of future available water resources.

**Keywords:** Long-lead forecasting, Hydrologic models, Rainfall forecasting, Artificial Neural Network, Fuzzy inference system

پیش‌بینی بلند مدت رواناب  
با استفاده از شبکه‌های عصبی مصنوعی  
و سیستم استنتاج فازی

شهاب عراقی نژاد<sup>۱</sup> و محمد کارآموز<sup>۲</sup>

چکیده

مدل‌های مفهومی بر مبنای هوش مصنوعی، اغلب برای پیش‌بینی‌های کوتاه مدت و میان مدت هیدرولوژیکی به کار رفته‌اند. در این مقاله با استفاده از مفهوم تولید مجموعه‌ای از پیش‌بینی‌ها<sup>۱</sup> (ESP) و تفکیک مدل‌سازی برای متغیرهای اقلیمی و هیدرولوژیکی، از مدل‌های مفهومی برای پیش‌بینی بلندمدت حجم جریان رودخانه زاینده رود در محل ورودی به سد زاینده رود استفاده می‌شود. سیستم استنتاج فازی برای پیش‌بینی بارش فصلی به صورت عدد فازی و شبکه‌های عصبی مصنوعی برای شبیه‌سازی تبدیل اطلاعات هیدروکلیماتولوژیکی به جریان رودخانه مورد استفاده قرار می‌گیرند. فصل بندی بارش و جریان ماهانه، واسنجی مدل‌های اقلیمی و هیدرولوژیکی و استفاده از الگوریتم توقف آموزش<sup>۲</sup> در شبکه‌های عصبی، دقت پیش‌بینی مدل‌ها را در این تحقیق افزایش داده است. علاوه بر بررسی دقت رویکرد پیش‌بینی جریان در فصول مختلف، نتایج این مدل با یک مدل پیش‌بینی ماهانه بر مبنای شبکه‌های عصبی که با استفاده از اطلاعات مشاهده شده، جریان ماهانه را پیش‌بینی می‌کند، مقایسه می‌گردد. نتایج این تحقیق نشان می‌دهد که رویکرد ارائه شده علاوه بر دقت قابل قبول در پیش‌بینی نقطه‌ای و بلند مدت جریان، امکان پیش‌بینی به صورت مجموعه‌ای از جریان‌های ممکن را نیز فراهم می‌آورد که در برنامه ریزی و مدیریت منابع آب با در نظر گرفتن عدم قطعیت پیش‌بینی‌ها، حائز اهمیت است.

**کلمات کلیدی:** پیش‌بینی بلندمدت، مدل‌های هیدرولوژیک، پیش‌بینی بارندگی، شبکه عصبی مصنوعی، سیستم استنتاج فازی

1- Ph. D., School of Civil and Environmental Engineering, AmirKabir University (Tehran Polytechnic)

2- Professor, School of Engineering, University of Tehran

۱- دکترای مهندسی آب، دانشگاه صنعتی امیرکبیر (پلی تکنیک)

تهران)shahab\_araghinejad@yahoo.com

۲- استاد دانشکده فنی دانشگاه تهران، karamouz@ut.ac.ir

## ۱- مقدمه

مدل‌های مختلف آماری و مفهومی برای پیش‌بینی و مدل‌سازی متغیرهای هیدرولوژیکی مورد استفاده قرار می‌گیرند. شبکه‌های عصبی مصنوعی براساس ساختمان مغز انسان و برای اهداف مختلفی نظیر شبیه‌سازی، تشخیص الگو، کلاس بندی و بهینه‌سازی در علوم مختلف مهندسی به کار گرفته شده‌اند. قابلیت شبکه‌های عصبی برای نگاشت بین اطلاعات ورودی و خروجی با خطای قابل قبول، این مدل‌ها را به ابزار مناسبی برای مدل‌سازی فرآیندهای هیدرولوژیکی تبدیل کرده است (Hsu et al. 1995). نتایج محققین مختلف نشان داده است که مدل‌های مفهومی در اغلب اوقات توانایی بهتری در مدل‌سازی غیرخطی فرآیندهای هیدرولوژیکی نسبت به مدل‌های آماری دارند (Coulibaly et al. 2000). اغلب انواع مدل‌های بر مبنای شبکه‌های عصبی و بطور کلی مدل‌های مفهومی توانایی انعکاس و در نظر گرفتن رفتار استوکستیک متغیرهای هیدرولوژیکی را ندارند و اغلب در پیش‌بینی‌های قطعی (نقطه‌ای) استفاده می‌شوند و نمی‌توانند عدم قطعیت پیش‌بینی را در خروجی منعکس کنند. در این مقاله سعی شده است با استفاده از مدل‌سازی عدم قطعیت موجود در اطلاعات هواشناسی به عنوان ورودی‌های مدل پیش‌بینی، این نوع عدم قطعیت در پیش‌بینی‌های مبتنی بر شبکه‌های عصبی در نظر گرفته شود.

در سال‌های اخیر استفاده از سیستم‌های بر مبنای قوانین فازی جهت مطالعات اقلیمی مورد توجه محققین مختلف بوده است. از جمله این موارد می‌توان به کار محققینی چون پستی و همکاران (Pesti et al, 1996) اشاره نمود. آنها یک برنامه‌ریزی سیستمی را برای بیان ارتباط اطلاعاتی که به صورت داده‌های هواشناسی و مدل‌های چرخه عمومی (GCM)<sup>۵</sup> ارائه می‌شود و اطلاعات شاخص‌های اقلیمی ارائه دادند. ایشان با استفاده از قوانین فازی الگوهای چرخه عمومی را به شاخص شدت خشکسالی پالمر مرتبط ساختند.

رویکردی که در این مقاله به آن پرداخته می‌شود ترکیبی از دو مدل مفهومی اقلیمی و هیدرولوژیکی است. مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی (ANNs)<sup>۶</sup> و سیستم استنتاج فازی<sup>۷</sup> (FIS) به ترتیب جهت شبیه‌سازی هیدرولوژیکی و پیش‌بینی اقلیمی حوزه سد زاینده رود و برای پیش‌بینی بلند مدت (فصلی) جریان ورودی به سد مورد استفاده قرار می‌گیرد.

ساختار این مقاله بدین شرح است که در بخش بعد رویکرد مدل‌سازی برای پیش‌بینی بیان می‌گردد و سپس محدوده مورد مطالعه

پیش‌بینی‌های بلند مدت هیدرولوژیکی دارای افق زمانی از یک ماه تا یکسال می‌باشند و برای مدیریت منابع آب مانند تخصیص آب برای آبیاری، قراردادهای بلند مدت فروش آب و انرژی برقایی و آمادگی مقابله با خشکسالی به کار می‌روند. افزایش دانش محققان در سالهای اخیر در مورد ارتباط چرخه عمومی اقیانوس- جو و میزان بارندگی و رواناب در نواحی مختلف دنیا، توجه زیادی را معطوف به انجام پیش‌بینی‌های بلندمدت نموده است. با افزایش افق زمانی پیش‌بینی، عدم قطعیت‌های آن افزایش می‌یابد و این مهمترین چالش در مدل‌سازی برای پیش‌بینی‌های بلندمدت می‌باشد. به علت خطاهای ناشی از طبیعت تصادفی فرآیندهای طبیعی و تخمین شرایط اقلیمی در بلندمدت، محدوده‌ای از پیش‌بینی‌های بلندمدت به جای یک پیش‌بینی قطعی ترجیح داده می‌شود. مهمترین مزیت این امر امکان تصمیم‌گیری بر مبنای ریسک برای برنامه‌ریزی و مدیریت منابع آب است. مهمترین عامل ایجاد عدم قطعیت در پیش‌بینی بلند مدت وضعیت اقلیمی آینده است. برای برخورد با این نوع عدم قطعیت و کمی‌کردن آن، مدل‌سازی جداگانه اقلیمی و هیدرولوژیکی توصیه شده است (Lettenmaier and Wood, 1993). مهمترین دلیل این کار اختلاف در میزان عدم قطعیت موجود در شرایط اقلیمی و هیدرولوژیکی، و امکان در نظر گرفتن آن در مدل‌سازی می‌باشد.

محققین مختلف با استفاده از رویکرد مدل‌سازی جداگانه اقلیمی و هیدرولوژیکی اقدام به پیش‌بینی بلند مدت جریان رودخانه نموده‌اند. یکی از شیوه‌های رایج در این زمینه روش پیش‌بینی مجموعه‌ای از جریان‌ها (ESP) می‌باشد. در روش ESP فرض می‌شود که هر اطلاعات تاریخی یک واقعه محتمل اقلیمی در آینده، و شرایط هیدرولوژیکی حوزه آبریز شرایط اولیه مدل پیش‌بینی می‌باشد. بنابراین مقادیر پیش‌بینی بر اساس دنباله‌های<sup>۳</sup> مختلف تولید می‌شود که هر دنباله نشان دهنده یک سناریوی اقلیمی است. سیستم پیش‌بینی رودخانه سازمان آب و هوایی ملی ایالات متحده<sup>۴</sup> با استفاده از اطلاعات دما و بارش مشاهده و پیش‌بینی شده و استفاده از آن‌ها در یک مدل هیدرولوژیکی مفهومی و یا مدل‌های هیدرولیکی که قادر به شبیه‌سازی بارش - رواناب در حوزه باشند، اقدام به تولید مجموعه‌ای از پیش‌بینی‌ها می‌کند (Day, 1983). Faber and Stedinger (2001) پیش‌بینی‌های به دست آمده از ESP را در بهره‌برداری استوکستیک مخازن سطحی به کار گرفتند. Anderson, et al, (2001) از ترکیب متغیرهای هیدرواقلمی پیش‌بینی شده هنگام وقوع پدیده النینو (فاز گرم انسو) و لانینا (فاز سرد انسو) و یک مدل هیدرولوژیکی فیزیکی، برای تعیین وقایع مختلف و محتمل جریان رودخانه استفاده نمودند.

و اطلاعات مورد استفاده معرفی می‌گردند. نتایج استفاده از مدل‌سازی استفاده از شبکه‌های عصبی مصنوعی برای حوزه سد زاینده رود ارائه می‌گردد. در بخش آخر بحث بر روی نتایج و نتیجه‌گیری ارائه می‌شود.

## ۲- رویکرد مدل‌سازی

الگوریتم مدل‌سازی برای پیش‌بینی بلند مدت در این مطالعه در شکل ۱ ارائه شده است. این الگوریتم ترکیبی از مدل‌سازی هیدرولوژیکی بر اساس شبکه‌های عصبی مصنوعی و مدل پیش‌بینی بارش بر اساس سیستم استنتاج فازی می‌باشد. برای استفاده از این الگوریتم در پیش‌بینی زمان واقعی رواناب رودخانه، از مجموعه‌ای از اطلاعات مشاهده شده هیدروکلیماتولوژیکی بهره گرفته می‌شود.

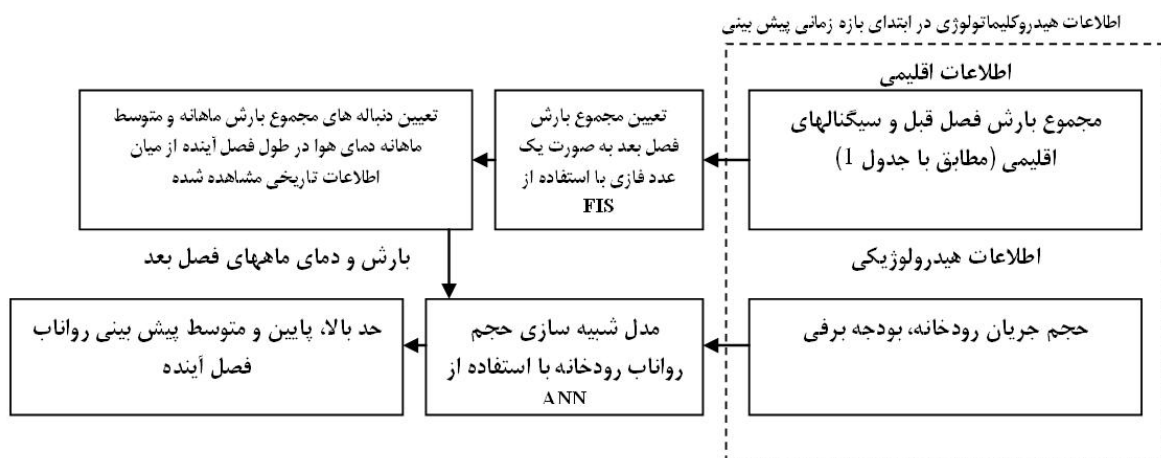
همانگونه که در شکل ۱ نشان داده شده است پیش‌بینی کننده‌های بارش (مانند سیگنال‌های هواشناسی و بارش فصل قبل) به عنوان ورودی FIS وارد محاسبات شده و خروجی به صورت عدد فازی برای مجموع بارش فصلی محاسبه می‌شود. از مقایسه مجموع بارش پیش‌بینی شده یک فصل با سری تاریخی اطلاعات، مجموعه دنباله‌های ماهانه (شامل بارش و دمای هوای ماهانه) متناظر با مجموع بارش پیش‌بینی شده برگزیده شده و به عنوان سناریوهای ممکن آب و هوایی برای فصل آینده وارد مدل هیدرولوژیکی می‌شوند. مدل هیدرولوژیکی (ANN) با استفاده از این اطلاعات و اطلاعات هیدرولوژیکی در زمان واقعی به عنوان شرایط اولیه (مانند رواناب مشاهده شده)، رواناب متناظر با هر سناریو را محاسبه می‌کند.

اقلیمی با استفاده از سیستم استنتاج فازی و مدل‌سازی هیدرولوژیکی بنا بر این مجموعه‌ای از مقادیر ممکن برای رواناب ماهانه در طول یک فصل تولید می‌شود.

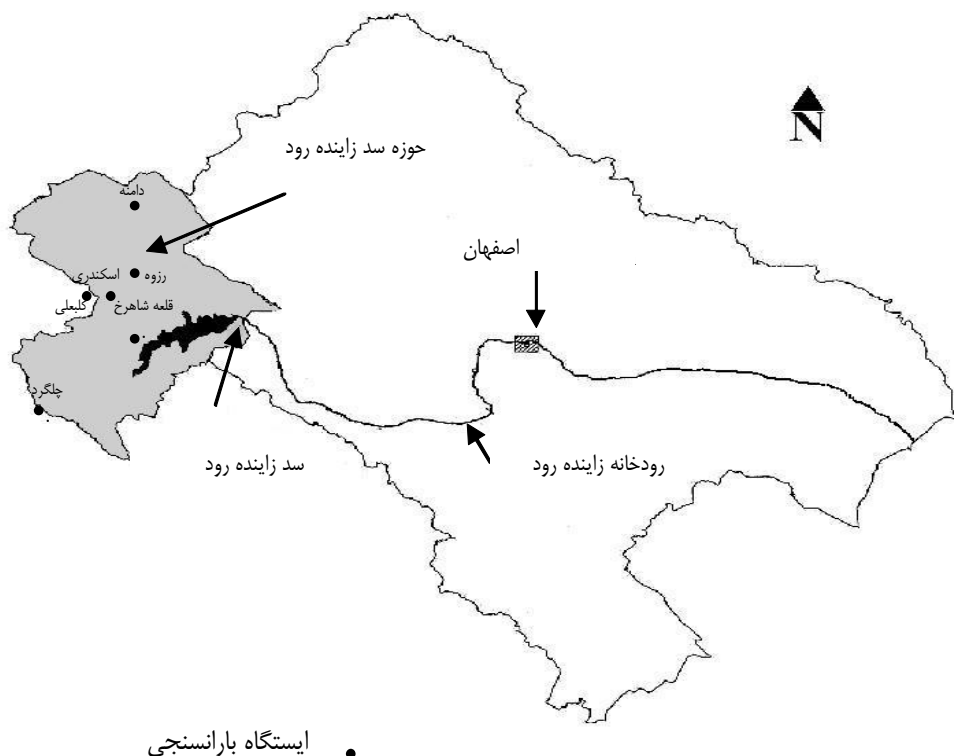
## ۳- منطقه مورد مطالعه و اطلاعات مورد استفاده

مطالعه موردی این مقاله حوزه آبریز سد زاینده رود می‌باشد. سد زاینده‌رود با حجم ۱۴۷۰ میلیون مترمکعب مهمترین منبع آب سطحی موجود در حوزه آبریز گاوخونی در بخش مرکزی ایران می‌باشد. شکل ۲ نقشه منطقه مورد مطالعه را نشان می‌دهد. متوسط حجم ورودی سالانه به سد زاینده رود ۱۶۰۰ میلیون مترمکعب شامل آورد طبیعی رودخانه زاینده رود به همراه آوردهای تونل‌های اول و دوم کوهرنگ از حوزه کوهرنگ می‌باشد. ۳۱ سال اطلاعات ماهانه از سال آبی ۱۳۵۱-۱۳۵۰ الی ۱۳۸۰-۱۳۸۱ شامل اطلاعات آورد رودخانه، متوسط میزان بارش و دمای هوا در حوزه سد، بودجه برفی و شاخص نوسانات جنوبی<sup>۸</sup> (SOI) برای پیش‌بینی حجم رواناب رودخانه زاینده رود مورد استفاده قرار می‌گیرد. لازم به ذکر است به دلیل عدم وجود اطلاعات بودجه برفی در دوره زمانی برابر با سایر اطلاعات، داده‌های ایستگاههای برف سنجی بر اساس اطلاعات بارش ساخته و تطویل شده است. ۲۴ سال اطلاعات از سال آبی ۱۳۵۰-۵۱ الی ۱۳۷۳-۷۴ برای واسنجی و ۸ سال اطلاعات از سال آبی ۱۳۷۴-۷۵ الی ۱۳۸۱-۸۲ برای صحت سنجی مدل‌ها استفاده می‌شود.

شاخص نوسانات جنوبی (SOI) شاخصی برای پایش پدیده النینو-نوسانات جنوبی<sup>۹</sup> (ENSO) می‌باشد. Troup (1965) این شاخص را به صورت مقدار استاندارد شده تفاضل بین فشار سطح دریا در تاهیتی و داروین که در عدد ۱۰ ضرب شده است تعریف کرد. در این مقاله نیز SOI به دست آمده از تعریف Troup مورد استفاده قرار می‌گیرد.



شکل ۱ - الگوریتم مدل‌سازی در پیش‌بینی بلند مدت



شکل ۲- نقشه منطقه مورد مطالعه و موقعیت ایستگاه‌های استفاده شده

بیان است. عدد فازی خروجی شامل مجموعه اعداد ممکن است که هر یک می‌توانند به عنوان خروجی قانون تلقی گردند و میزان اعتبار و پذیرش آن در مجموعه جواب، با بهره‌گیری از مقدار تابع عضویت آن عدد در خروجی فازی محاسبه می‌گردد.

سیستم استنتاج فازی سیستمی بر اساس ترکیب قوانین اگر و سپس می‌باشد. در این سیستم چند قانون فازی بیانگر حالات مختلف سیستم می‌باشند. به ازای هر ورودی خاص به سیستم، مقادیر مناسب خروجی آن با استفاده از میزان ارضای هر قانون توسط آن ورودی، و ترکیب خروجیهای مختلف محاسبه می‌گردد. در نهایت جواب نهایی بر اساس سهم فعال شدن هر قانون و ترکیب جوابهای آنها با هم به دست می‌آید. ترکیب نتایج قوانین مختلف با استفاده از روشهای مختلفی انجام می‌گیرد. روش استفاده شده در این تحقیق موسوم به روش Mamdani می‌باشد (Mamdani, 1976). به دلایل زیر استفاده از سیستم استنتاج فازی برای انجام پیش‌بینی‌های اقلیمی مناسب می‌باشد: رابطه غیر خطی بین متغیرهای مستقل و وابسته در

۴- پیش‌بینی فصلی بارش با استفاده از سیستم استنتاج فازی  
 یک سیستم استنتاج فازی بر مبنای قوانین منطقی اگر-سپس (if-then) شکل می‌گیرد. یک قانون فازی به صورت فرم کلی زیر بیان می‌گردد،

$$\text{If } x \text{ is } A \text{ then } y \text{ is } B \quad (1)$$

در قانون بالا  $A$  و  $B$  مقادیری هستند که در محدوده بازه (مجموعه)  $X$  و  $Y$  قرار می‌گیرند.  $x$  و  $y$  نیز به ترتیب متغیر مستقل و متغیر وابسته متعلق به مجموعه  $X$  و  $Y$  می‌باشند. بخش "اگر" مقدم  $1$  و بخش "سپس" تالی  $1$  قانون فازی خوانده می‌شود. عموماً در بخش مقدم اعداد بصورت غیر فازی (صریح) بیان می‌شوند و در بخش تالی خروجی بصورت یک عدد فازی می‌باشد (Ross, 1995). این خروجی فازی بعد از غیر فازی شدن، بصورت یک مقدار واحد قابل

بارش در فصل تابستان در منطقه مورد مطالعه ناچیز می‌باشد و در مدل پیش‌بینی در نظر گرفته نشده است.

#### ۴-۲- ترکیب قوانین فازی

نحوه به کارگیری روش Mamdani در ترکیب قوانین فازی در شکل ۴ نشان داده شده است. سیستم استنتاج فازی نشان داده شده در این شکل، متشکل از ۳ قانون فازی و ۲ متغیر مستقل SOI و بارش (مطابق با جدول ۱) برای پیش‌بینی مجموع بارش در فصل بهار می‌باشد. به عنوان مثالی از پیش‌بینی در زمان واقعی، مقدار متوسط SOI برابر ۸ و بارش فصل قبل برابر ۳۵۰ میلی‌متر به عنوان متغیرهای مستقل در نظر گرفته شده‌اند. این مقادیر در محدوده اعداد فازی قوانین اول و دوم قرار می‌گیرند و بنابراین این قوانین را فعال می‌کنند. میزان تاثیر هر قانون در خروجی نهایی بر اساس درجه ارضای خروجی هر قانون بدست می‌آید. اگر عملگر یا برای ترکیب متغیرهای مستقل هر قانون استفاده شوند، درجه ارضای خروجی هر قانون بر اساس بیشترین درجه عضویت متغیرهای مستقل در هر قانون بدست می‌آید. چنانچه عملگر و استفاده شود، درجه ارضای خروجی هر قانون بر اساس کمترین درجه عضویت محاسبه می‌شود. جواب نهایی بر اساس برهم‌نهی<sup>۱۲</sup> خروجی قوانین مختلف به صورت یک عدد فازی به دست می‌آید. این عدد فازی را می‌توان به صورت یک عدد صریح بیان کرد. در این مطالعه مرکز ثقل عدد فازی به عنوان میانگین این عدد فازی و پیش‌بینی نقطه‌ای در نظر گرفته شده است. در مثال ارائه شده عدد فازی پیش‌بینی در محدوده ۴۵ و ۱۵۰ میلی‌متر و پیش‌بینی نقطه‌ای برابر ۶۰ می‌باشد.

پیش‌بینی اقلیمی؛ امکان انجام پیش‌بینی‌های بلند مدت اقلیمی به صورت بازه‌های ممکن به جای یک مقدار خاص؛ امکان در نظر گرفتن مقادیر غیر صریح در تعریف پیش‌بینی کننده‌های اقلیمی.

فرایند به کارگیری سیستم استنتاج فازی در پیش‌بینی در تحقیق حاضر به شرح زیر است.

۱- تعیین قوانین فازی بر اساس مقادیر مشاهداتی متغیرهای مستقل

(پیش‌بینی کننده‌ها) و وابسته

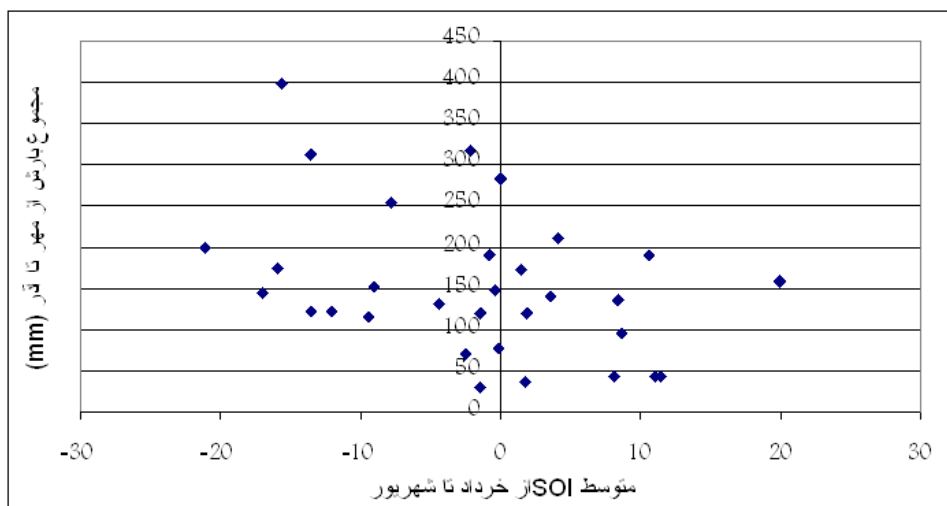
۲- ترکیب قوانین بر اساس روش Mamdani

۳- واسنجی اعداد فازی

۴- صحت سنجی مدل

#### ۴-۱- تعیین قوانین فازی

بارندگی در حوزه سد زاینده رود از مهر ماه آغاز شده و معمولاً تا اواخر خرداد ماه سال بعد ادامه می‌یابد. پدیده ENSO به عنوان پیش‌بینی کننده بارش در منطقه در نظر گرفته شده است. به عنوان نمونه ای از نحوه تغییرات SOI با بارش در منطقه مورد مطالعه، تغییرات مجموع بارش پاییز در مقابل تغییرات متوسط SOI در تابستان قبل، در شکل ۳ نشان داده شده است. از همبستگی فصلی اطلاعات بارش نیز می‌توان در پیش‌بینی بلندمدت بهره گرفت (Piechota, et al. 1998)، بنابراین به عنوان یک پیش‌بینی کننده دیگر، اطلاعات بارش فصل قبل مورد استفاده قرار می‌گیرد. از بررسی تغییرات پیش‌بینی کننده‌ها و بارش فصلی، قوانین فازی ارائه شده در جدول ۱ برای فصل پاییز زمستان و بهار به دست می‌آیند.



شکل ۳- تغییرات SOI با بارش فصل پاییز



جدول ۱- قوانین فازی پیش بینی بارش فصلی

| قوانین فازی پیش بینی  |  |  | پیش بینی کننده ها                               |                                     | فصل بارش          |
|---|--|--|---|-------------------------------------|-------------------|
| اگر SOI کم باشد<br>آنگاه بارش زیاد<br>خواهد بود                               | اگر SOI متوسط<br>باشد آنگاه بارش<br>متوسط خواهد بود                                | اگر SOI زیاد باشد<br>آنگاه بارش <sup>۲</sup> کم<br>خواهد بود                             | مقدار متوسط <sup>۱</sup> SOI از خرداد تا شهریور |                                     |                   |
| اگر SOI کم یا<br>بارش مشاهده شده<br>زیاد باشد آنگاه<br>بارش زیاد خواهد<br>بود | اگر SOI متوسط<br>یا بارش مشاهده<br>شده متوسط باشد<br>آنگاه بارش متوسط<br>خواهد بود | اگر SOI زیاد یا<br>بارش مشاهده شده<br>کم باشد آنگاه<br>بارش <sup>۳</sup> کم خواهد<br>بود | مجموع بارش از<br>آبان تا دی                     | مقدار متوسط SOI<br>از شهریور تا آذر | دی الی اسفند      |
| اگر SOI کم یا<br>بارش مشاهده شده<br>زیاد باشد آنگاه<br>بارش زیاد خواهد<br>بود | اگر SOI متوسط<br>یا بارش مشاهده<br>شده متوسط باشد<br>آنگاه بارش متوسط<br>خواهد بود | اگر SOI زیاد یا<br>بارش مشاهده شده<br>کم باشد آنگاه<br>بارش کم خواهد<br>بود              | مجموع بارش از<br>دی تا اسفند                    | مقدار متوسط SOI<br>از آبان تا اسفند | فروردین الی خرداد |

<sup>۱</sup>SOI = شاخص نوسانات جنوبی

<sup>۲</sup>بارش مشاهده شده متناظر با پیش بینی کننده معرفی شده

<sup>۳</sup>بارش متناظر با فصل معرفی شده

و بارش بیش از ۹۰ میلی‌متر به عنوان بارش زیاد شناخته می‌شود. همانطور که مشاهده می‌شود، محدوده بین مقادیر کم، متوسط و زیاد می‌توانند با هم همپوشانی نیز داشته باشند.

#### ۵- مدل سازی با استفاده از شبکه های عصبی مصنوعی

کولیبالی و همکاران (Coulibaly et al. 1999)، کاربرد مدل‌های بر مبنای شبکه‌های عصبی را در مدل‌سازی‌های هیدرولوژیکی مطالعات سالیان اخیر مرور کرده‌اند. طبق گزارش ایشان ۹۰ درصد تجارب انجام شده در این زمینه با استفاده از شبکه‌های پیش‌خور چندلایه که با الگوریتم انتشار خطا به عقب آموزش دیده‌اند، انجام شده است. در این مطالعه نیز شبکه پیش‌خور ۳ لایه با الگوریتم آموزش انتشار خطا به عقب<sup>۱۳</sup> (BP) و توقف آموزش، مورد استفاده قرار می‌گیرد. شبکه چند لایه با الگوریتم آموزش انتشار خطا به عقب از شیوه آموزش با ناظر استفاده می‌کند. شماتیک این شبکه در شکل ۵ نشان داده شده است. در این شیوه با معرفی نمونه‌های مختلفی از ورودی و خروجی به شبکه، تابع خطای زیر حداقل می‌شود.

$$E = 1/2 \sum_{p=1}^n (y_p - \hat{y}_p)^2 \quad (2)$$

#### ۴-۳- واسنجی مدل

برای سادگی محاسبات، کلیه توابع عضویت متغیرها در این مطالعه مثلی در نظر گرفته شده‌اند. محل مرکز ثقل و محدوده هر یک از این توابع مستقیماً در جواب نهایی اثر می‌گذارد. از میان مقادیر مختلف، این دو پارامتر به گونه‌ای تعیین شده‌اند که بهترین نتایج پیش‌بینی را تولید کنند. این کار در مرحله واسنجی مدل و با آزمون مقادیر مختلف برای پارامترها و مقایسه نتایج با استفاده از سه معیار زیر انجام گرفته است.

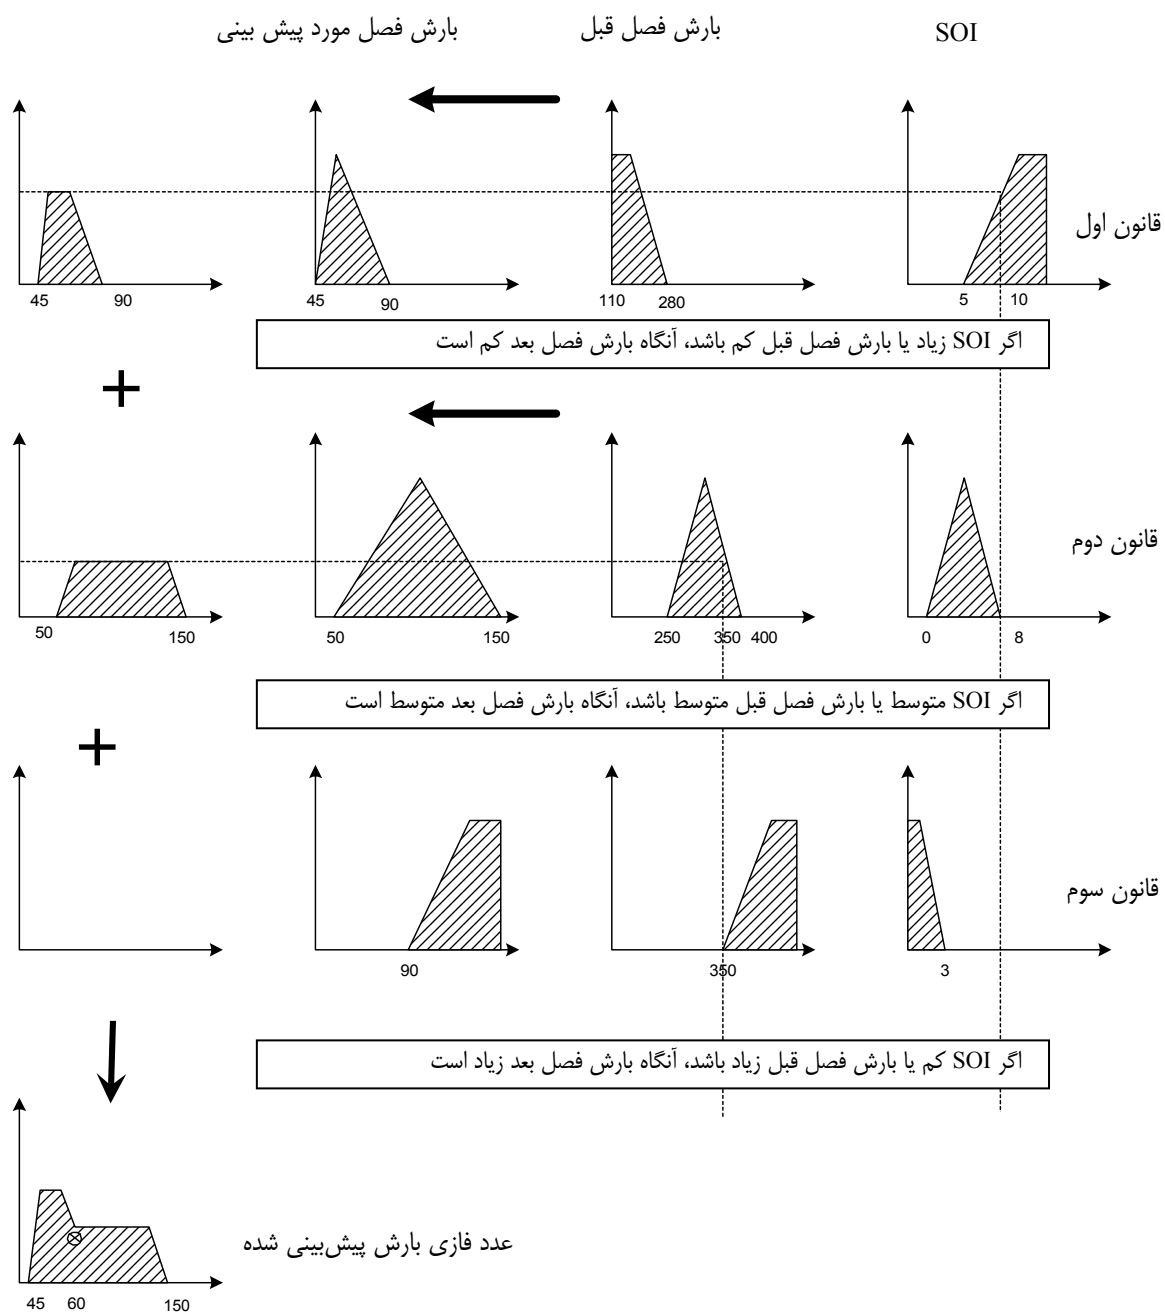
- انحراف مقادیر پیش‌بینی نقطه‌ای از مقادیر واقعی

- اطمینان پذیری پیش‌بینی‌ها (منظور از اطمینان پذیری پیش‌بینی‌ها

این است که مقادیر مشاهده شده در بازه پیش‌بینی قرار گیرند)

- بازه پیش‌بینی‌های فازی

با تغییر پارامترهای توابع عضویت متغیرهای مستقل و وابسته و مشاهده اثر آن در خروجی به صورت سعی و خطا، بهترین مقادیر پارامترها بر اساس معیارهای فوق، به دست آمده‌اند. نمونه توابع عضویت کالیبره شده پیش‌بینی کننده‌ها برای حالت‌های کم، زیاد و متوسط فصل بهار در شکل ۴ نشان داده شده است. به عنوان مثال اگر مجموع بارش فصل بهار بین ۴۵ و ۹۰ میلی‌متر باشد به عنوان بارش کم، اگر بین ۵۰ و ۱۵۰ میلی‌متر باشد به عنوان بارش متوسط،



شکل ۴- سیستم استنتاج فازی در پیش بینی بارش فصل بهار



$$I_{pi} = \sum_{j=1}^N W_{ij} x_{pj} + W_{io} \quad (7)$$

$N$  تعداد عصب‌های (نورون‌های) لایه ورودی،  $W_{ij}$  وزن اتصال عصب ورودی  $j$  ام به عصب  $i$  ام لایه میانی و  $W_{io}$  مقدار آریبی عصب  $i$  ام می‌باشد. وزنه‌های شبکه در فرآیند آموزش با استفاده از رابطه زیر به هنگام می‌گردند.

$$\Delta W_{ij} = -\eta \frac{\partial E}{\partial W_{ij}} \quad (8)$$

که در آن  $\eta$  نرخ یادگیری و عددی بین ۰ و ۱ است. مقدار این پارامتر معمولاً با انتخاب یک مقدار اولیه و سعی و خطا در رسیدن به میزان بهینه تعیین می‌شود.

#### ۵-۱- واسنجی مدل

مدل شبکه عصبی با استفاده از مجموعه آموزشی (واسنجی)، تحت آموزش قرار می‌گیرد. این بدین معنی است که پارامترهای مدل یعنی وزن‌ها و آریب‌ها محاسبه می‌گردند. یکی از معیارهای مهم در آموزش شبکه تعداد دوره‌ها یا تکرارهایی<sup>۱۵</sup> است که شبکه BP در حین آموزش انجام می‌دهد. در حالت کلی هرچه تعداد تکرار در آموزش شبکه بیشتر شود، خطای آموزشی در شبکه کمتر می‌شود. اما هنگامی که تعداد تکرارها از یک مقدار تجاوز کند، خطای دسته آزمایشی (دسته صحت سنجی اطلاعات) نیز افزایش پیدا می‌کند. بهترین تعداد تکرار آموزش مقداری است که خطای مدل در هر دو

که در آن  $n$  تعداد مجموعه‌های ورودی - خروجی،  $\hat{y}_p$  و  $y_p$  به ترتیب مقادیر پیش‌بینی شده و مشاهده شده برای زوج  $p$  ام می‌باشند. در الگوریتم BP مقدار  $E$  با استفاده از فرآیند زیر محاسبه و حداقل می‌گردد.

اگر شبکه سه لایه اتصال کامل با  $m$  عصب (نورون) در لایه مخفی در نظر گرفته شود، خروجی عصب  $k$  ام لایه آخر،  $\hat{y}_{pk}$ ، از رابطه زیر محاسبه می‌شود:

$$\hat{y}_{pk} = g(I_{pk}) \quad (3)$$

که در آن

$$g(I_{pk}) = \frac{1}{1 + e^{-I_{pk}}} \quad (4)$$

و

$$I_{pk} = \sum_{i=1}^m W_{ki} z_{pi} + W_{ko} \quad (5)$$

$I_{pk}$  ورودی وزن دار شده به عصب  $k$  ام در لایه آخر برای مجموعه  $p$ ،  $m$  تعداد عصب‌های لایه میانی،  $W_{ki}$  وزن اتصال عصب مخفی (میانی)  $i$  ام به خروجی  $k$  ام، و  $W_{ko}$  مقدار آریب<sup>۱۶</sup> عصب  $k$  ام می‌باشد.  $z_{pi}$  خروجی عصب  $i$  ام لایه مخفی می‌باشد که از رابطه زیر محاسبه می‌شود.

$$z_{pi} = g(I_{pi}) \quad (6)$$

که در رابطه فوق


لایه ورودی

لایه میانی

لایه خروجی

متغیرهای ورودی

متغیرهای خروجی



شکل ۵- معماری شبکه عصبی مورد استفاده در مطالعات

شبکه‌ها عبارتند از رواناب ماه قبل، متوسط دمای هوا و بارش در ماه جاری. بودجه برفی به عنوان یک ورودی دیگر در شبکه فصل سوم در نظر گرفته شده است. بدین ترتیب تعداد عصب‌های لایه ورودی شبکه‌های فصول اول، دوم و چهارم برابر ۳ و برای شبکه سوم برابر ۴ می‌باشد. مقدار بهینه عصبها در لایه میانی برای فصول اول تا چهارم به ترتیب برابر ۲، ۳، ۴ و ۴ می‌باشد. تعداد عصب‌های لایه خروجی کلیه شبکه‌ها برابر یک می‌باشد. تعداد بهینه تکرارها برای شبکه‌های اول تا چهارم به ترتیب ۳۲۰۰، ۲۸۰۰، ۲۵۰۰ و ۲۲۰۰ به دست آمده است. لازم به ذکر است که تعداد زوج اطلاعات در نظر گرفته شده برابر با اطلاعات در نظر گرفته شده برای واسنجی بوده است.

#### ۶- پیش‌بینی حجم جریان رودخانه

##### ۶-۱- نتایج پیش‌بینی بارش

نتایج پیش‌بینی فصلی بارش برای سالهای آبی ۷۵-۱۳۷۴ الی ۸۲-۱۳۸۱ (مجموعه صحت سنجی اطلاعات) در شکل ۶ ارائه شده است. نتایج به صورت کمترین، بیشترین و متوسط فازی برای هر فصل ارائه شده است. متوسط خطای پیش‌بینی با استفاده از میانگین فازی به صورت درصد اختلاف با مقدار واقعی برای فصول اول (پاییز)، دوم (زمستان) و سوم (بهار) به ترتیب ۵۸، ۲۶ و ۴۰ درصد می‌باشد. اطمینان پذیری پیش‌بینی‌ها برای فصول اول و سوم ۱۰۰ درصد و برای فصل دوم ۸۷/۵ درصد بدست آمده است. خطای پیش‌بینی فصل دوم در ۹۰ درصد موارد، برابر یا کمتر از ۴۰ درصد بوده است.

دسته آزمایشی و آموزشی تا حد ممکن کمینه گردند. در شبکه‌های عصبی روش و رابطه خاصی برای تعیین مقدار مناسب آموزش و قدرت یادگیری وجود ندارد. در مدل‌سازی‌های این مطالعه به جهت استفاده از کلیه اطلاعات موجود و اندازه‌گیری شده، از الگوریتم صحت سنجی متقاطع<sup>۱۴</sup> برای ارزیابی تاثیر تعداد تکرارها و تعداد عصب‌های لایه میانی در ارزیابی عملکرد شبکه استفاده می‌گردد. در این الگوریتم در هر مرحله از یادگیری شبکه، کلیه زوج‌های اطلاعات ورودی و خروجی به غیر از یکی در آموزش شبکه استفاده شده و خطای پیش‌بینی زوج ورودی-خروجی کنار گذاشته شده، محاسبه می‌گردد. این کار بر روی تمام زوج اطلاعات موجود انجام می‌شود. خطای نهایی آزمایش برابر مجموع خطاهایی است که بدین ترتیب محاسبه می‌گردد. کارایی شبکه نهایی انتخاب شده با انجام پیش‌بینی‌ها برای مجموعه‌هایی که در آموزش شرکت نکرده‌اند و مقایسه جوابهای واقعی با مقدار پیش‌بینی شده ارزیابی می‌گردد.

بر اساس شباهت بین مقادیر آماری جریان ماهانه رودخانه زاینده رود و تأثیرپذیری آن از متغیرهای هواشناسی، ۴ فصل هیدرولوژیکی برای جریان رودخانه تعریف شده است (کارآموز، ۱۳۸۲).

فصل ۱- آبان تا دی

فصل ۲- بهمن و اسفند

فصل ۳- فروردین تا تیر

فصل ۴- مرداد تا مهر


برای هر فصل یک شبکه تدوین شده است. بدین معنی که اطلاعات کلیه ماههای یک فصل به عنوان مقادیر ورودی-خروجی یک شبکه در نظر گرفته شده‌اند. ورودیهای در نظر گرفته شده برای

## ۲-۶- نتایج شبیه سازی هیدرولوژیکی

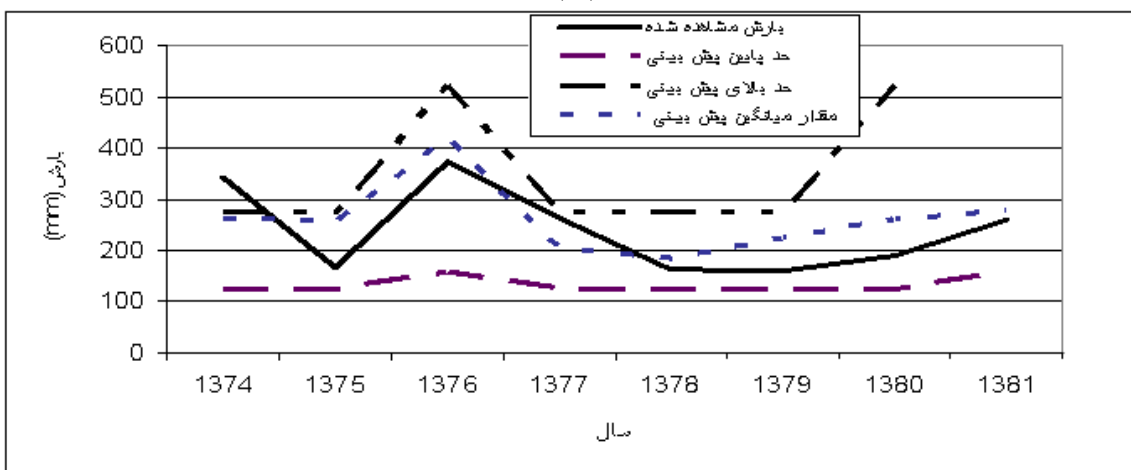
نتایج استفاده از مدل‌های هیدرولوژیکی برای دوره صحت سنجی (سالهای ۷۵-۱۳۷۴ الی ۸۲-۱۳۸۱) در بازه‌های زمانی ماهانه در شکل ۷ نشان داده شده است. بیشترین میزان خطای متوسط ماهانه در اسفند ماه و برابر با ۲۵/۴ درصد اختلاف از مقدار واقعی می‌باشد. کمترین خطا در ماه مرداد و بطور متوسط برابر با ۱۰ درصد اختلاف از مقدار واقعی می‌باشد. متوسط خطا در فصل اول برابر با ۱۹/۶ درصد و بیش از بقیه فصول بوده است، در حالی که متوسط خطای فصل سوم برابر با ۱۰/۹ درصد و کمترین مقدار خطا بوده است. نتایج پیش‌بینی نشان داده شده در شکل ۷ و بررسی خطاهای شبیه‌سازی، نشان دهنده کارایی خوب مدل‌های تدوین شده برای شبیه‌سازی هیدرولوژیکی حوزه می‌باشد.

## ۳-۶- پیش بینی فصلی

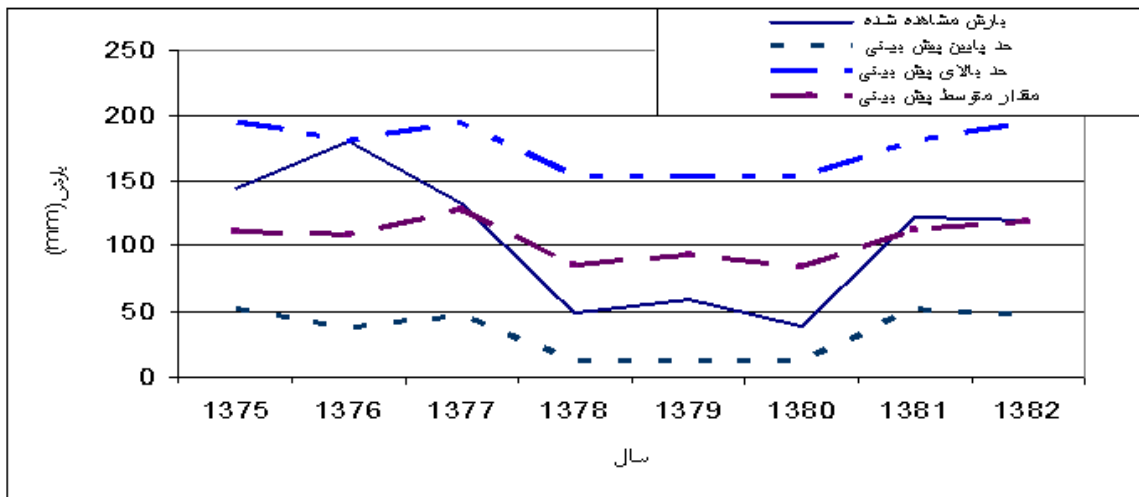
مطابق با الگوریتم ارائه شده در بخش ۲، بارش پیش‌بینی شده فصلی برای تعیین دنباله‌های ماهانه متغیرهای هواشناسی که می‌توانند یک سناریوی آب و هوایی ممکن در فصل بعد باشند، مورد استفاده قرار می‌گیرد. این دنباله‌ها شامل بارش و متوسط دمای هوای ماهانه می‌باشند. با فرض همبستگی بین مجموع بارش فصلی و تغییرات درون فصلی متغیرهای هواشناسی، این دنباله‌ها به گونه‌ای انتخاب می‌شوند که مجموع بارش فصلی آنها در محدوده بارش پیش‌بینی شده قرار داشته باشد. درجه امکان‌پذیری هر یک از این دنباله‌ها از مقایسه مجموع بارش فصلی آنها با مقادیر بیشترین، متوسط و کمترین بارش پیش‌بینی شده در بخش ۴ به دست می‌آید. دنباله‌های تاریخی که مجموع بارش فصلی آنها به بیشترین، متوسط و کمترین



(الف)




(ب)



(ج)

شکل ۶- نتایج پیش بینی بارش برای مجموعه صحت سنجی اطلاعات با استفاده از FIS (الف: فصل اول ب: فصل دوم ج: فصل سوم)



شکل ۷- نتایج شبیه سازی حجم رواناب رودخانه با در نظر گرفتن اطلاعات همزمان آب و هوایی

پیش‌بینی‌ها در ابتدای هر فصل بارش انجام شده و به مقادیر ماهانه تبدیل می‌شود. خطای پیش‌بینی برای حد بالا، پایین و متوسط پیش‌بینی در شکل ۸ نشان داده شده و خلاصه نتایج در جدول ۲ ارائه شده است. تحلیل خطاها نشان می‌دهد که اطمینان پذیری پیش‌بینی برای روش ارائه شده ۸۶ درصد می‌باشد. بدین معنی که در ۸۶ درصد مواقع مقادیر واقعی در محدوده پیش‌بینی‌ها قرار داشته است. کمترین خطا در فصل‌های سوم و چهارم مشاهده شده است که در آنها حجم رواناب، همبستگی کمتری با متغیرهای همزمان بارش و دما دارد. در سالهای مشاهده فاز گرم ENSO

بارش فصلی پیش‌بینی شده نزدیک‌ترین باشند به ترتیب به عنوان دنباله‌های ماهانه حد بالا، متوسط و پایین پیش‌بینی شده، در نظر گرفته می‌شوند. این دنباله‌ها به عنوان ورودی برای مدل‌های هیدرولوژیکی، در پیش‌بینی زمان واقعی به کار می‌روند. از میان دنباله‌های مختلف تنها نتایج بدست آمده از مقادیر متناظر با بیشترین، کمترین و متوسط انتخاب شده ارائه می‌گردند. شایان ذکر است که برای فصل تابستان که مدل پیش‌بینی بارش در نظر گرفته نشده است، بیشترین، متوسط و کمترین بارش مشاهده شده تاریخی به ترتیب به عنوان حد بالا، مقدار متوسط و حد پائین برای مدل هیدرولوژیکی در نظر گرفته شده است.

(SOI>0) مقادیر پیش‌بینی از دقت بیشتری برخوردارند زیرا مدل اقلیمی با دقت بیشتری پیش‌بینی های آب و هوایی را تولید کرده است.


#### ۴-۶- مقایسه با یک مدل پیش‌بینی ماهانه

نتایج پیش‌بینی با استفاده از مدل ارائه شده، با نتایج مدل ماهانه پیش‌بینی با استفاده از شبکه های عصبی که مقادیر مشاهده شده هیدرولوژیکی (جریان و بودجه برفی) و هواشناسی (بارش و دما) ماه قبل را به عنوان ورودی در نظر می‌گیرد، مقایسه می‌گردد. روش مدل‌سازی این مدل ماهانه همانند فرآیند ارائه شده در بخش ۴


می‌باشد. افق زمانی پیش‌بینی این مدل، یک ماه می‌باشد در حالی که افق زمانی پیش‌بینی مدل ارائه شده برابر با یک فصل بارش می‌باشد. نتایج پیش‌بینی با استفاده از دو مدل برای مجموعه صحت سنجی در شکل ۹ نشان داده شده است. نتایج مقایسه نشان می‌دهد که علیرغم افق زمانی طولانی تر، نتایج پیش‌بینی نقطه ای مدل ارائه شده، حدود ۶ درصد انحراف کمتری از مقادیر واقعی داشته است. معیار متوسط درصد خطای مطلق در رویکرد ارائه شده ۱۴/۵ درصد و این مقدار برای مدل پیش‌بینی با تاخیر زمانی در ورودی های هواشناسی، ۲۰/۳ می‌باشد.

جدول ۲- خطای ماهانه و فصلی پیش بینی جریان رودخانه برای مجموعه صحت سنجی اطلاعات به صورت درصد اختلاف از مقدار مشاهده شده

| مهر  | شهریور | مرداد | تیر  | خرداد | اردیبهشت | فروردین | اسفند | بهمن | دی   | آذر  | آبان | ماهانه  | خطای حد       |
|------|--------|-------|------|-------|----------|---------|-------|------|------|------|------|---------|---------------|
| ۳۵/۴ | ۱۹/۷   | ۱۴/۹  | ۲۱/۳ | ۱۲/۵  | ۱۳/۸     | ۱۹/۸    | ۲۸/۵  | ۲۹/۷ | ۲۲/۳ | ۲۲/۸ | ۵۸/۳ | خطای حد | بالا          |
| ۲۲/۸ |        |       | ۱۵/۴ |       |          | ۲۹/۱    |       | ۳۳/۴ |      |      | فصلی |         |               |
| ۲۲/۸ | ۹/۷    | ۱۱/۸  | ۱۶/۴ | ۱۰/۱  | ۵/۳      | ۱۴/۹    | ۱۱/۷  | ۱۸/۱ | ۱۲/۱ | ۱۸/۸ | ۲۳/۴ | خطای حد | مقدار میانگین |
| ۱۵/۲ |        |       | ۱۰/۱ |       |          | ۱۴/۹    |       | ۱۸/۱ |      |      | فصلی |         |               |
| ۱۱/۹ | ۵/۷    | ۱۰/۴  | ۴/۹  | ۷/۴   | ۶/۷      | ۱۶/۲    | ۹/۷   | ۱۰/۷ | ۹/۱  | ۱۲/۳ | ۱۲/۱ | خطای حد | پائین         |
| ۹/۴  |        |       | ۱۰/۱ |       |          | ۱۰/۲    |       | ۱۱/۲ |      |      | فصلی |         |               |



شکل ۸- خطای مقدار میانگین حد بالا و پائین پیش بینی بر حسب درصد اختلاف از مقدار مشاهده شده



شکل ۹- خطای پیش بینی بر حسب درصد اختلاف از مقدار مشاهده شده برای الگوریتم ارائه شده و مدل با ورودی اطلاعات هواشناسی غیرهمزمان

مجموعه‌ای از مقادیر جریان (ESP) را فراهم آورده است. پیش‌بینی بارش که با عدم قطعیت زیادی همراه است به صورت اعداد فازی انجام گرفته است. در نظر گرفتن ورودی‌های مختلف برای متغیرهای هواشناسی بر اساس این پیش‌بینی فازی، امکان پیش‌بینی مجموعه‌ای از مقادیر جریان در افق زمانی پیش‌بینی را فراهم آورده است. از مطالعات ارائه شده در این مقاله نتایج زیر به دست آمده است:

#### ۷- خلاصه و نتیجه گیری

در این مطالعه سعی شده است علاوه بر بهره‌گیری از قابلیت مدل‌سازی غیرخطی روش‌های مفهومی، امکان به کارگیری این مدل‌ها در پیش‌بینی‌های بلندمدت به صورت تولید محدود‌های از جواب‌های محتمل و ممکن که به آن مجموعه پیش‌بینی (ESP) اطلاق می‌شود، ارائه گردد. کاربرد و قابلیت استفاده از سیستم استنتاج فازی و شبکه‌های عصبی مصنوعی برای پیش‌بینی بلندمدت بارش و رواناب در این مطالعه ارائه گردید. تفکیک مدل‌سازی متغیرهای اقلیمی و هیدرولوژیکی امکان پیش‌بینی به صورت

- استفاده از سیستم استنتاج فازی در پیش بینی بارش دارای حداکثر خطای ۵۸ درصد برای فصل پاییز و حداقل ۲۶ درصد برای فصل زمستان بوده است.

- 14. Cross Validation
- 15. Epoch

## ۹- مراجع

کارآموز، محمد (۱۳۸۲) "سیستم پشتیبانی در تصمیم‌گیری سد زاینده‌رود و مدیریت خشکسالی" دانشگاه صنعتی امیرکبیر- کارفرما: سازمان آب منطقه ای اصفهان

Anderson. M. L., M. L. Kavvas and Mierzwa, M. D. (2001), "Probabilistic/ensemble forecasting: a case study using hydrologic response distributions associated with El Niño/Southern Oscillation (ENSO)" *Journal of Hydrology*, 249, pp. 134-147.

Coulibaly, P., Anctil, F. and Bobée, B. (2000), "Daily reservoir inflow forecasting using artificial neural networks with stopped training approach", *Journal of Hydrology*, 230, pp. 244-257.

Day, G. N. (1983), "Extended Streamflow Forecasting Using NWSRFS", *ASCE Water Resources Planning and Management*, Vol. (111), No. 2. pp. 157-170.

Mamdani E. H. (1976), "Advances in linguistic synthesizes of fuzzy controllers", *J. Man mach. Stud.*, vol. 8, pp. 669-678.

Faber. B. A., and Stedinger. J. R., (2001), "Reservoir optimization using sampling SDP with ensemble streamflow prediction (ESP) forecast", *Journal of Hydrology*, 249, pp. 113-133.

Hsu, K.-L., Gupta, H. V. and Sorooshian, S. (1995), "Artificial neural networks modeling of rainfall-runoff process", *Water Resources Research*, 31(10), pp. 2517-2530.

Lettenmaier, D.P. and Wood. E.F. (1993), *Hydrologic Forecasting, Handbook of Hydrology, Chap. 26*, Maidment (Ed.) McGraw-Hill, Hightstown, NJ.

Pesti. G., Shresta.B. P., Duekstein.L., and Bogardi.I., (1996), "A fuzzy rule-based approach to drought assessment" *Water Res. Res.* Vol. 132. No. 6. pp. 1741-1747.

Piechota. T. C., Chiew. F. H. S., and Dracup. J. A. (1998), "Seasonal streamflow forecasting in eastern Australia and the El Nino – Southern Oscillation" *Water Resou. Res.* Vol. 34. No. 11, pp. 3035-3044.

Ross, T. J., (1995), *Fuzzy Logic with Engineering Applications*, McGraw-Hill, Hightstown, NJ, 600 pp.

Troup, A. J. (1965), "The southern oscillation." *Quarterly J. Royal Meteorological Soc.*, 91, pp. 490-506.

▪ شبیه سازی هیدرولوژیکی با استفاده از شبکه های عصبی دارای دقت بسیار خوب و خطای متوسط کمتر از ۲۰ درصد برای تمام فصول بوده است.

▪ پیش بینی فصلی با استفاده از رویکرد ارائه شده برای تمام فصول، خطای متوسطی کمتر از ۲۰ درصد داشته است.

▪ استفاده از رویکرد ارائه شده در پیش بینی ماهانه، خطای پیش‌بینی را نسبت به مدلی که از اطلاعات هواشناسی غیر همزمان استفاده می کند تا ۳۰ درصد کاهش داده است.

رویکرد مدل سازی ارائه شده در استفاده از روشهای مفهومی، امکان انجام پیش‌بینیهای ESP را فراهم آورده است که می‌تواند به عنوان گزینه ای علاوه بر روش های احتمالاتی مطرح گردد. مدل‌های بر مبنای شبکه عصبی و با استفاده از اطلاعات کامل هواشناسی (اطلاعات همزمان)، از دقت بیشتری در شبیه سازی جریان رودخانه ماهانه نسبت به مدل های با ورودی اطلاعات مشاهده شده هواشناسی (اطلاعات با تاخیر زمانی) برخوردارند و در صورت وجود مدل مناسب هواشناسی می‌توانند جهت پیش‌بینی جریان مورد استفاده قرار گیرند. برای پیش‌بینی هیدرولوژیکی در ماههایی که منبع اصلی جریان از بارش تامین می‌شود، پیش‌بینی منفرد جریان با استفاده از روش ارائه شده دقت بیشتری نسبت به پیش‌بینی با در نظر گرفتن اطلاعات مشاهده شده هواشناسی دارد. سادگی مدل‌سازی در عین دقت قابل قبول، این رویکرد را به روش مناسبی برای پیش‌بینی بلند مدت جریان رودخانه با در نظر گرفتن عدم قطعیت شرایط اقلیمی تبدیل کرده است.

## ۸- تشکر

داده‌های استفاده شده در این مطالعه از شرکت آب منطقه‌ای اصفهان و چهارمحل بختیاری دریافت شده است. بدینوسیله از مدیرعامل و کارشناسان محترم آن شرکت قدردانی می گردد.

## پی‌نوشت‌ها

1. Ensemble Streamflow Prediction
2. Stopped training
3. Traces
4. National Weather Services for River Forecast: NWSRF
5. General Circulation Models
6. Artificial Neural Networks
7. Fuzzy Inference System
8. Southern Oscillation Index
9. El-Nino Southern Oscillation
10. Premise (antecedent)
11. Conclusion (consequent)
12. Superposition
13. Back propagation

تاریخ پذیرش مقاله: ۲۴ فروردین ۱۳۸۴

تاریخ دریافت مقاله: ۵ آذر ۱۳۸۳



