

## پیش‌بینی سناریوهای احتمالاتی ماهانه جریان رودخانه با رویکرد ESP (مطالعه موردی: رودخانه هلیل رود)

صدیقه انوری

استادیار گروه اکولوژی، پژوهشگاه علوم محیطی، پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته. s.anvari@kgut.ac.ir

تاریخ پذیرش: ۹۵/۱۱/۲۴

تاریخ دریافت: ۹۵/۸/۶

### چکیده

پیش‌بینی جریان ورودی به مخزن سد، ابزاری اساسی در مدیریت بهینه منابع آب محسوب می‌شود. ضرورت ارتقاء دقت و بازه زمانی پیش‌بینی جریان، برای بخش کشاورزی که بزرگ‌ترین مصرف‌کننده آب محسوب می‌شود، بارزتر می‌باشد. در این راستا استفاده از رویکردهای احتمالاتی برای پیش‌بینی‌های بلندمدت جریان و احتساب عدم قطعیت پیش‌بینی، توصیه شده است. هدف تحقیق حاضر ارائه مدلی برای پیش‌بینی احتمالاتی جریان ورودی به مخزن سد جبرفت می‌باشد. در این راستا با استفاده از رویکرد پیش‌بینی‌های گروهی جریان (ESP) و نیز به‌کارگیری مدل‌های شبکه عصبی مصنوعی (ANNs)، سناریوهای احتمالاتی جریان یک تا دوازده ماه آینده رودخانه هلیل پیش‌بینی گردید. بدین منظور با استفاده از داده‌های هواشناسی و هیدرولوژیکی حوضه رودخانه هلیل رود، پیش‌بینی‌های تجمعی جریان با مدل‌های ANN صورت گرفت و در ادامه از این پیش‌بینی‌ها برای ساخت سناریوهای احتمالاتی جریان با رویکرد ESP مصنوعی استفاده شد. نتایج نشان داد، با افزایش بازه زمانی پیش‌بینی، از مقیاس ماهانه تا سالانه، دقت نتایج، مقداری کاهش می‌یابد. همچنین از ترکیب مدل‌های ANN با رویکرد ESP مصنوعی، می‌توان سناریوهای احتمالاتی جریان را بخوبی پیش‌بینی نمود.

کلید واژه‌ها: پیش‌بینی جریان، ANN، ESP، رودخانه هلیل رود.

### مقدمه

مخزن، به دو دسته کوتاه‌مدت و بلندمدت تقسیم می‌شوند (Karamooz and Araghinezhad., 2005). کاربرد مدل‌های قطعی در پیش‌بینی جریان، همانند مدل‌های رگرسیون، سری‌های زمانی، شبکه عصبی مصنوعی (ANNs Artificial Neural Networks)، نرو-فازی (Adaptive Neuro-Fuzzy Inference System, ANFIS) و غیره که تخمینی نقطه‌ای از یک متغیر را به‌دست می‌دهند، از سابقه نسبتاً طولانی برخوردار است (Besaw et al., 2010; Nayaka et al., 2004; Shiri and Kisi, 2010). کیسی به پیش‌بینی روزانه جریان رودخانه به‌وسیله مدل ANN و مدل خود همبسته (Auto-Regressive, AR) پرداخت. نتایج، حاکی از عملکرد بهتر مدل ANN در قیاس با مدل‌های AR بود (Kisi, 2005). Aqil et al (2006) از مدل ANFIS برای پیش‌بینی جریان هفتگی رودخانه Citarum واقع در اندونزی استفاده و نتایج آن را با مدل رگرسیونی چندگانه خطی (MLR) مقایسه نمودند. نتایج آن، برتری نسبی عملکرد مدل ANFIS را نشان می‌داد. همچنین این مدل در مقایسه با مدل MLR عملکرد بهتری داشته است (Zounemat Kermani and Aqil et al. 2006). Teshnehlab (2007) جریان روزانه سه رودخانه De Soto و Brevard در ایالت فلوریدا و Rensselaer در نیویورک را با استفاده از مدل نرو-فازی پیش‌بینی کردند. نتایج، برتری عملکرد مدل‌های نرو-فازی نسبت به مدل‌های خود همبسته را نشان

در سال‌های اخیر وضعیت منابع آب در بسیاری از کشورها به مراحل بحرانی رسیده است. به نحوی که عملیات جامع و یکپارچه‌ای مورد نیاز می‌باشد. تا به واسطه آن تلفات آب، مصرف بیش از حد آن و خطرات رو به رشد خشکسالی را کاهش دهد. در این راستا، مدیریت بهینه منابع آب و در رأس آن پیش‌بینی کمیت آب، یعنی جریان ورودی رودخانه به مخزن سد، ابزاری اساسی در کاهش خسارات ناشی از کم آبی محسوب می‌شود. همچنین پیش‌بینی رواناب در چند ماه یا حتی فصل آینده، برای کارکرد زمان واقعی سیستم‌های منابع آب، همانند مخازن، لازم بوده به نحوی که دقت پیش‌بینی‌های مزبور، اثر به‌سزائی در تعیین سیاست‌های بهره‌برداری و بازده عملکرد سیستم دارد (Alcazar et al., 2008). ضرورت پیش‌بینی‌های مزبور، خصوصاً در بخش کشاورزی با اختصاص بیش از ۹۰٪ از آب‌های کشور بعنوان بزرگ‌ترین مصرف‌کننده آب و آسیب‌پذیرترین بخش در شرایط کم‌آبی، بارزتر می‌باشد (<http://news.more.gov.ir>).

پیش‌بینی (Forecasting) در هیدرولوژی به معنی تخمین شرایط هیدرولوژیکی و هواشناسی در یک بازه خاص در آینده می‌باشد. در یک مدل پیش‌بینی، با استفاده از اطلاعات مشاهده شده در شرایط فعلی، مقادیر محتمل یک یا چند متغیر اقلیمی یا هیدرولوژیکی، در یک دوره زمانی خاص، پیش‌بینی می‌گردد. پیش‌بینی‌های هیدرولوژیکی، از جمله پیش‌بینی جریان ورودی به

تدوین نمودند. آنها پیش‌بینی‌های ماهانه ESP را همراه با استفاده از مدل بارش-رواناب SSARR ( Streamflow Synthesis and Reservoir Regulation)، بکار بردند (Kim et al., 2007). در تحقیق دیگری (Eum et al., 2001)، از ترکیب مدل‌های SSDP با پیش‌بینی‌های ESP و قواعد محدود کننده بهره‌برداری، برای بهینه‌سازی بهره‌برداری از مخزن در شرایط خشکسالی استفاده نمودند (Eum et al., 2011).

بررسی مطالعات انجام شده در مورد ضرورت پیش‌بینی جریان رودخانه و استفاده از انواع مدل‌های هوشمند شامل ANN و ANFIS نشان داد که خروجی این مدل‌ها، صرفاً پیش‌بینی‌هایی نقطه‌ای و قطعی جریان را بدست می‌دهند. به این معنا که نتایج این پیش‌بینی‌ها، فقط برای شرایط خاص هواشناسی و هیدرولوژیکی صادق بوده و در آینده و رویارویی با شرایط آب و هوایی جدید، ممکن است دارای اعتبار کافی، نباشند. در حالیکه با توجه به شرایط تغییر اقلیم و نیز عدم قطعیت متغیرهای هواشناسی و هیدرولوژیکی، بهتر است از پیش‌بینی‌های احتمالاتی جریان، که رویکرد ESP مورد استفاده در این تحقیق، از جمله آنهاست، مورد استفاده قرار گیرد. در رویکرد ESP این تحقیق، از خواص احتمالاتی تابع توزیع احتمال جریان فصلی در هر ماه استفاده شده و در نهایت با استفاده از آنالیزهای آماری، پیش‌بینی‌های گروهی جریان ورودی به مخزن سد جیرفت، بدست آمد. بدین منظور با استفاده از داده‌های هواشناسی و هیدرولوژیکی حوضه رودخانه هلیل‌رود، جریان تجمعی این رودخانه با مدل‌های ANN پیش‌بینی می‌شود. در ادامه با کمک این پیش‌بینی‌ها، سناریوهای احتمالاتی جریان ورودی به سد با کمک مدل‌های پیش‌بینی گروهی جریان (ESP) تولید گردید.

## مواد و روش‌ها

### منطقه مطالعاتی و داده‌ها

باتلاق جازموریان، حوضه آبریز و دریاچه‌ای به همین نام در جنوب شرقی ایران در جنوب کوه شهبوران کرمان واقع شده است. حوضه آبریز جازموریان با وسعت ۶۹ هزار و ۶۰۰ کیلومتر مربع، از لحاظ تقسیم‌بندی، بخشی از حوضه مسدود میانی ایران بشمار می‌آید. نیمه باختری این حوضه به وسعت ۳۵۶۰۰ کیلومتر مربع در استان کرمان و نیمه خاوری آن به وسعت ۳۴۰۰۰ کیلومتر مربع، در استان سیستان و بلوچستان جای دارد. این حوضه از شمال، توسط کوه‌های لاله‌زار، جبال بارز و کوه شهبوران از حوضه آبریز کویر لوت، و از جنوب، توسط رشته کوه‌های زاگرس (کوه‌های بشاگرد)، از حوضه آبریز دریای عمان و خلیج فارس جدا می‌شود. حدود ۳۴۱۶۰ کیلومتر مربع از اراضی این حوضه را مناطق کوهستانی و حدود ۳۲۴۰۰ کیلومتر مربع آن را دشت‌ها و کوهپایه‌ها، و حدود ۳۰۰۰ کیلومتر مربع باقی‌مانده را باتلاق‌ها و شوره‌زارها، تشکیل می‌دهد. شکل (۱) موقعیت حوضه جازموریان را در بین حوضه‌های درجه ۲ کشور نشان داده است. لازم به ذکر است که منطقه مطالعاتی این تحقیق، حوضه رودخانه

می‌داد. پیش‌بینی جریان رودخان ابرو در اسپانیا را توسط مدل‌های ANN انجام دادند که نتایج حاکی از عملکرد مثبت این مدل بود (Alcazar et al., 2008). Sedki et al. (2009) برای پیش‌بینی روزانه بارش و رواناب در مراکش از مدل‌های ANN استفاده کردند. Saghafian, et al. (2013) پیش‌بینی‌های قطعی یک تا سه ماه بعد جریان رودخانه کارون را با استفاده از مدل‌های ANN، ANFIS و K-NN انجام دادند که مدل ANN در مقایسه با سایرین، بهترین عملکرد را داشت (Saghafian et al., 2013). تحقیقات نامبرده و همچنین بررسی‌های Demirel et al. (2009) برای پیش‌بینی روزانه جریان با استفاده از مدل‌های ANN و مدل ابزار ارزیابی آب و خاک (Soil and Water Assessment Tool)، همگی بیانگر کاربرد موفقیت‌آمیز مدل‌های ANN در مقایسه با سایر مدل‌های بکاررفته در تحقیق بوده‌اند.

برای پیش‌بینی‌های بلندمدت جریان که در آنها عدم قطعیت پیش‌بینی بیشتر است، استفاده از رویکردهای احتمالاتی، که خروجی مدل پیش‌بینی در برگزیده احتمالات وقوع مقادیر یا دسته‌های مختلفی از جریان رودخانه در یک شرایط خاص می‌باشد، توصیه شده است. رویکرد پیش‌بینی‌های گروهی جریان (Ensemble Streamflow Prediction, ESP) نمونه‌هایی از روش‌های پیش‌بینی احتمالاتی می‌باشند (Day, 1985). پیش‌بینی‌های گسترش یافته جریان (Extended Streamflow Prediction) اولین بار در دهه ۱۹۷۰ توسط سیستم پیش‌بینی رودخانه سرویس آب و هوایی ملی ایالات متحده (US National Weather Service River Forecast System, USNWSRFS) معرفی گردید. بعد از آن در سال ۱۹۷۵، سیستم پیش‌بینی رودخانه‌ای اصلاح شد و روش‌های پیش‌بینی دقیق‌تری توسعه یافت. در رویکرد ESP، مدل‌سازی فیزیکی حوضه رودخانه، با نمایش احتمالاتی آینده و همچنین با آمار گذشته یا تاریخی، ترکیب می‌شود. تفاوت اصلی این روش با روش‌های پیش‌بینی رایج، احتساب احتمالات و عدم قطعیت در پیش‌بینی جریان است (Faber and Stedinger, 2001). در حال حاضر ESP، یک مؤلفه کلیدی در سیستم پیش‌بینی هیدرولوژیکی پیشرفته (US National Weather Service River Forecast System, USNWSRFS) می‌باشد (Eum et al., 2011). Faber and Stedinger (2001) از قابلیت مدل‌های بهینه‌سازی بهره‌برداری از مخزن، موسوم به SSDP (Sampling Stochastic Dynamic Programming)، در ترکیب با پیش‌بینی‌های ESP، به‌منظور بهره‌برداری بهینه از مخزن، استفاده نمودند. با به‌کارگیری این مدل و استفاده از دنباله‌های پیش‌بینی‌شده از ESP، آنها توانستند همبستگی‌های زمانی و مکانی دنباله‌های جریان را در مدل‌سازی لحاظ کنند (Faber and Stedinger, 2001). در این راستا Kim et al., 2007 نیز سیاست‌های بهینه بهره‌برداری از دو سد چندمنظوره، در کره جنوبی با اهداف تأمین آب، مهار سیل و تولید برقایی را، با مدل‌های SSDP و به کارگیری پیش‌بینی‌های ESP

مدل‌ها اولین بار در سال ۱۹۴۳ توسط Pitts and McCulloch معرفی و از اوایل دهه ۱۹۹۰ تاکنون در زمینه هیدرولوژی نیز به طور موفقیت‌آمیزی به کار گرفته شده‌اند، از جمله کاربردهای موفق آن می‌توان به فرآیندهای مدل‌سازی بارش-رواناب، پیش‌بینی جریان رودخانه، مدل‌سازی آب زیرزمینی، پیش‌بینی بارندگی و ... اشاره کرد (Dawson et al., 2006 ASCE, 2000).

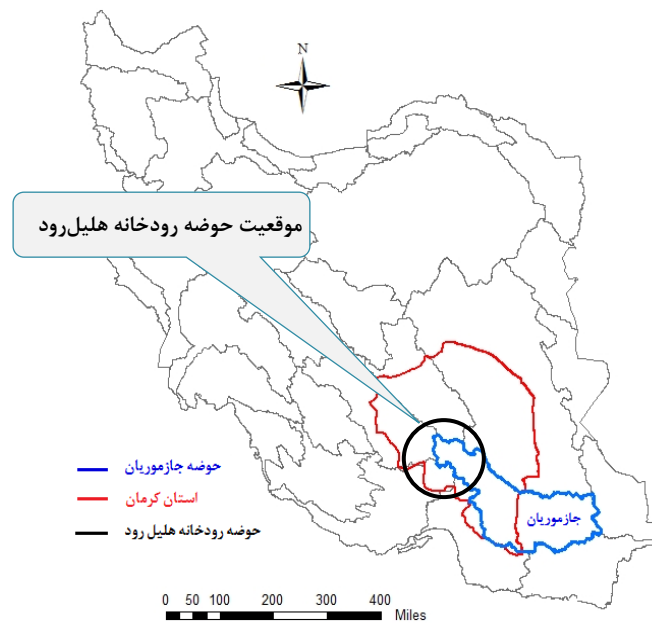
در این تحقیق از شبکه‌های پیشرو (Feedforward Neural Network, FFNN) با شمای کلی مطابق شکل (۲) استفاده شده است. معماری معمول این شبکه متشکل از سه لایه ورودی، پنهان و خروجی است. تعداد نرون‌های موجود در لایه ورودی و خروجی، بستگی به نوع مسأله دارد ولی تعداد نرون‌های لایه پنهان با سعی و خطا بدست می‌آید.

هلیل‌رود بوده که بخشی از حوضه درجه دو جازموریان بشمار می‌آید.

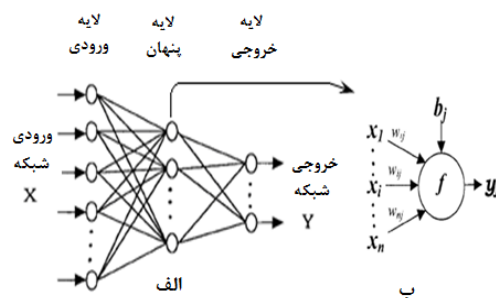
برای پیش‌بینی سناریوهای احتمالاتی جریان، از آمار و اطلاعات ۲۱ ساله دوره ۱۳۶۸-۱۳۸۸ شامل متغیرهای دمای حداقل، میانگین و حداکثر (Tmax, Tmean, Tmin)، بارندگی (Rain) و جریان (Q) به عنوان متغیرهای پیشگو استفاده گردید. در این راستا به منظور پیش‌بینی‌های تجمعی جریان و نهایتاً سناریوهای ESP، از آمار ایستگاه سینوپتیک کهنوج و مقادیر آبدهی ایستگاه حسین آباد استفاده شد.

### مدل‌های ANN و ساختار آن‌ها

به دلیل ماهیت غیر خطی روابط حاکم بر فرآیندهای هیدرولوژیکی، همانند جریان رودخانه، برای پیش‌بینی‌های تجمعی جریان در هر ماه، از مدل‌های ANN استفاده شده است. این



شکل ۱- موقعیت حوضه رودخانه هلیل‌رود در بین حوضه‌های آبریز درجه دو و استان کرمان



شکل ۲- شمای کلی شبکه‌های پیشرو سه لایه (ب) شمای زامین گره از آن (ASCE, 2000)

هواشناسی یک سال تاریخی را بتوان با هیدروگراف جریان آن سال تاریخی نشان داد. حال اگر سری‌های جریان مشاهداتی در دست باشند سال‌های ابتدایی جایگزین الگوهای هواشناسی و سال‌های دیگر می‌توانند به عنوان الگوهایی مد نظر باشند که در آینده وقوع آنها انتظار می‌رود (Faber and Stedinger, 2001).

ایده کلی پیش‌بینی‌های ESP مورد نظر در تحقیق حاضر، مشابه ESP های مصنوعی پیشنهاد شده توسط فابر و استدینجر، است (Faber and Stedinger, 2001). با این تفاوت که ایشان از روابط رگرسیونی مبتنی بر ورودی‌هایی نظیر بودجه برفی، رطوبت خاک و غیره برای تولید پیش‌بینی‌های تجمعی جریان، به عنوان عنصر اصلی در تولید سناریوهای ESP، استفاده کردند؛ حال آنکه در تحقیق حاضر از مدل ANN، با متغیرهای پیشگویی کننده، متناسب با خصوصیات و اطلاعات مطالعه موردی تحقیق حاضر نظیر دما، بارندگی و جریان، استفاده شده است. منطق محاسباتی ESP مستلزم تعیین الگوهای هواشناسی و الگوهای مورد انتظار در آینده است. در ادامه، نحوه تعیین دو الگوی مذکور که به ترتیب الگوهای کالیبراسیون و صحت‌سنجی نامیده می‌شوند، تشریح می‌شوند. لازم به ذکر است که پیش‌بینی‌های تجمعی مزبور از روش‌های مختلف مبتنی بر مدل‌های مفهومی بارش-رواناب و یا روش‌های داده-محور نظیر مدل‌های ANN، قابل برآورد بوده که در تحقیق حاضر از مدل ANN استفاده گردید. مراحل محاسباتی در رویکرد ESP مصنوعی عبارتند از:

- ۱- تقسیم داده‌ها به دو دسته بمنظور واسنجی و صحت‌سنجی به ترتیب با  $M$  و  $N$  سال؛
- ۲- برازش تابع توزیع احتمالاتی به مقادیر جریان‌های فصلی ( $Q$ ) همه الگوهای صحت‌سنجی، بمنظور تشخیص توزیع احتمال داده‌های مورد نظر، توابع چگالی احتمال نرمال و لوگ نرمال، به ترتیب مطابق روابط (۱) و (۲) می‌باشند (Chow et al., 1981).

$$f_x(X) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-0.5\left(\frac{x-\mu}{\sigma}\right)^2\right] \quad (1)$$

$$F_x(X) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-0.5\left(\frac{x-\mu}{\sigma}\right)^2\right], x > 0 \quad (2)$$

در روابط بالا  $\mu$  و  $\sigma$  به ترتیب میانگین و انحراف معیار و به عبارتی پارامترهای توزیع نرمال یا لوگ نرمال می‌باشند.

- ۳- محاسبه تابع تجمعی احتمال  $F_x(x)$  با استفاده از رابطه (۳) (Chow et al., 1981):

$$F_x(X) = P(X \leq x) = \int_{-\infty}^x f_x(X) dx \quad (3)$$

با تعریف متغیر نرمال استاندارد  $Z$ ، رابطه بالا به شکل زیر تبدیل می‌شود:

در شکل (۲)  $(x_1, \dots, x_i, i=1, \dots, n)$  بردار ورودی‌ها،  $w_{ij}$  وزن اتصالی از آمین گره به آمین گره در لایه بعد،  $b_j$  بایاس مربوط به گره  $j$ ام،  $y_j$ ها خروجی‌های هر لایه،  $Y$  خروجی نهائی ANN است. در شبکه‌های پیشرو، اتصالات میان گره‌هایی وجود دارد که در لایه‌های متفاوت قرار دارند. همچنین ورودی‌ها در لایه ورودی شبکه نمایش داده شده و عمل تحریک، از ورودی به سمت خروجی شبکه شروع می‌شود (ASCE, 2000) و (Dawson et al., 2006).

### پیش‌بینی‌های تجمعی جریان با مدل ANN

در این بخش، از مدل‌های ANN برای پیش‌بینی‌های تجمعی جریان استفاده شده است. به طوری که افق زمانی پیش‌بینی، یک‌ساله و گام‌های زمانی، در مقیاس ماهانه خواهند بود. از آنجا که جریان تجمعی پیش‌بینی شده، یک مؤلفه اصلی در تولید سناریوهای ESP می‌باشد، روش به‌کار گرفته شده برای تولید آن منطبق بر، رویکرد مصنوعی ارائه شده توسط فابر و استدینجر بوده (Faber and Stedinger, 2001) و اطلاعات هیدرولوژیکی-هواشناسی حوضه، از ملزومات اصلی می‌باشد. لذا در این بخش برای پیش‌بینی جریان تجمعی در هر ماه، از متغیرهای دمای حداقل، میانگین و حداکثر ( $T_{max}$ ,  $T_{mean}$ ,  $T_{min}$ )، بارندگی (Rain) و جریان ( $Q$ )، به عنوان متغیرهای پیشگو استفاده شده است. شایان ذکر است که این متغیرها، در حوضه رودخانه هلیل‌رود، برای دوره ۲۱ ساله ۱۳۶۸-۱۳۸۸ موجود می‌باشند. انتخاب متغیرهای ورودی به مدل‌های ANN، با استفاده از تحلیل همبستگی و فرایند سعی و خطا صورت می‌گیرد. برای تعیین معماری مدل‌های ANN، از شبکه‌های پیشروی سه لایه (شامل یک لایه ورودی، پنهان و خروجی)، با تابع فعالیت سیگموئیدی و الگوریتم آموزش لونیبرگ مارکوارت (Levenberg-Marquardt Algorithm, LM) استفاده گردید. همچنین تعداد نرون‌های لایه پنهان با سعی و خطا به دست آمده است.

برای جلوگیری از کوچک شدن وزن‌های مدل ANN، داده‌های ورودی و خروجی در بازه [0.1-0.9] تغییر مقیاس یافته‌اند (Wang et al., 2006). همچنین ۷۰ و ۳۰ درصد داده‌های ورودی به ترتیب برای آموزش و آزمون شبکه‌ها، به کار گرفته شده‌اند. در نهایت از شاخص‌هایی همانند ریشه میانگین مربعات خطا (Root Mean Square Error, RMSE)، ضریب تعیین ( $R^2$ ) و میانگین قدر مطلق خطا (Mean Absolute Error, MAE) که همگی در مقیاس میلیون متر مکعب (MCM) هستند، برای ارزیابی و انتخاب بهترین مدل در هر ماه استفاده شده است. در بخش‌های بعد، از پیش‌بینی‌های تجمعی بدست آمده توسط ANN، برای پیش‌بینی‌های ESP استفاده می‌شود.

تولید سناریوهای احتمالاتی جریان با رویکرد ESP مصنوعی

منطق محاسباتی در ESP آنست که شرایط آب و هوایی رخ داده در قبل، می‌تواند در آینده هم تکرار گردد. بر این اساس، در روش ESP مصنوعی، این پیش فرض برقرار است که الگوهای

۷- برای هر دوره پیش‌بینی  $t$  از هر سال صحت‌سنجی  $N$ ، هیدروگراف جریان مربوط به سال  $i$  ام الگوهای صحت‌سنجی، طوری تغییر می‌یابد که مقدار کل جریان زیر نمودار برابر با  $\tilde{Q}_i$  شود. روابط به کار گرفته شده در این بخش در ادامه تشریح شده است:

$$P = 1 - P_i \rightarrow \text{if } \begin{cases} 0 \leq P \leq 0.5 \rightarrow P' = P \\ P > 0.5 \rightarrow P' = 1 - P \end{cases} \quad (10)$$

که  $P_i$  احتمال عدم وقوع (تجمعی) و  $P$  احتمال وقوع می‌باشد.

$$\omega = \left[ \ln \frac{1}{P_i^2} \right] \quad (11)$$

در این مرحله با استفاده از  $\omega$  محاسبه شده پارامتر  $Z'$  و همان متغیر نرمال استاندارد است محاسبه می‌شود.

$$\tilde{Q}_i = \overline{QF} - \sigma_{QF} \times \phi^{-1}\{P_i\} \quad (12)$$

رابطه (۱۲) همان فرمول chow می‌باشد که در آن  $\phi^{-1}\{P_i\}$  متغیر نرمال استاندارد مربوط به احتمال  $P_i$  بوده و فاکتور تناوب نامیده می‌شود (Chow et al., 1981).

۸- در گام آخر چنانچه در ابتدای دوره صحت‌سنجی یعنی سال  $N = 1$  و دوره  $t = 1$ ، پیش‌بینی  $M$  هیدروگراف جریان (خوشه جریان) مد نظر باشد، مقادیر جریان در  $M$  سناریوی کالیبراسیون با توجه به مقادیر  $\tilde{Q}_i$  حاصل از مرحله قبل تغییر می‌یابد. این کار با اعمال یک ضریب اصلاحی به نحوی انجام می‌شود که مقدار جریان در سناریوی مورد نظر و برای یک دوره معین از مقدار معادل آن در الگوهای تاریخی، به مقدار  $\tilde{Q}_i$  تبدیل شود. این کار برای تمامی سال‌ها و ماه‌های الگوهای صحت‌سنجی، انجام شده و در نهایت سناریوهای ماهانه ESP، برای تمامی ماه‌های سال محاسبه می‌شوند.

### نتایج و بحث

در این بخش نتایج پیش‌بینی‌های تجمعی جریان با مدل ANN و نیز نتایج اجرای مدل ESP برای تولید سناریوهای احتمالاتی جریان رودخانه هلیل‌رود ارائه می‌شود.

#### تجمعی جریان‌های ماهانه با مدل ANN

برای انجام پیش‌بینی‌های تجمعی جریان، ابتدا با استفاده از روش تحلیل همبستگی، متغیرهای دما (در مقیاس‌های حداکثر، میانگین و حداقل)، بارندگی و جریان بعنوان مناسب‌ترین متغیرهای پیشگو برای پیش‌بینی جریان ماه‌های آینده در حوضه هلیل‌رود، شناسائی شدند. بعد از تعیین متغیرهای پیشگو، معماری مدل‌های ANN شامل تعداد لایه‌های پنهان، تعداد نرون در هر لایه و نوع توابع فعالیت به نحوی تعیین شد که مدل هم در مرحله آموزش و هم در مرحله آزمون بهترین عملکرد را از نظر شاخص‌های خطا شامل  $RMSE$ ،  $R^2$ ،  $MAE$  داشته باشد. در ادامه

$$F(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} du \quad (4)$$

که در آن  $u$  یک متغیر ساختگی برای انتگرال بوده و شکل تحلیلی ندارد.

۴- برای هر سال از الگوهای کالیبراسیون، احتمال تجمعی  $P_i$  با استفاده از توزیع احتمال تجمعی به دست آمده از رابطه (۵) محاسبه می‌شود. شایان ذکر است که  $P_i$  احتمال عدم وقوع متغیر نرمال شده  $Z$  می‌باشد. مقادیر  $F(Z)$  و  $P_i$  با استفاده از روابط زیر محاسبه می‌شوند (Chow et al., 1981):

$$\alpha = F(z) = 0.5 \times [1 + 0.196854|z| + 0.115194|z|^2 + 0.000344|z|^3 + 0.19527|z|^4]^{-4} \quad (5)$$

$$\text{If } \begin{cases} z < 0, & \text{then } P_i = \alpha \\ z \geq 0, & \text{then } P_i = 1 - \alpha \end{cases} \quad (6)$$

۵- مقادیر جریان فصلی (تجمعی) سال‌های صحت‌سنجی، با مدل ANN پیش‌بینی می‌شود. بدین ترتیب که با انجام آنالیز آماری، متغیرهای ورودی مناسب  $t$  انتخاب و بهترین معماری برای مدل ANN با سعی و خطا به دست می‌آید. نهایتاً پیش‌بینی‌های فصلی  $(Y)$  جریان برای هر ماه محاسبه می‌شود.

۶- با استفاده از روابط رگرسیون بین مقادیر جریان تجمعی الگوهای صحت‌سنجی ( $Q$ ) و مقادیر پیش‌بینی‌های فصلی در هر دوره  $Y$ ، میانگین و واریانس شرطی مقادیر پیش‌بینی یعنی به ترتیب شامل  $E[Q] = \overline{QF}$  و  $V[Q] = \sigma_{QF}^2 = Se^2$  با استفاده از روابط (۷) و (۸) تعیین می‌شود.

$$b_1 = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sum(X_i - \bar{X})^2}, \quad b_0 = \bar{Y} - b_1 \bar{X}, \quad (7)$$

$$e_i = Y_i - (b_0 + b_1 X_i)$$

$$E[Q] = \overline{QF} = E(Y_i) = b_0 + b_1 X_i \quad (8)$$

$$Var[Q] = \sigma_{QF}^2 = \sum \frac{e_i^2}{n-2} \quad (9)$$

که  $QF$ : مقدار پیش‌بینی جریان تجمعی در هر دوره  $t$  و هر سال صحت‌سنجی  $i$ ،  $Se$ : خطای استاندارد رگرسیون (انحراف معیار توزیع نرمال)، عبارت‌های  $Var[Q]$  و  $E[Q]$  به ترتیب واریانس شرطی و میانگین مقادیر پیش‌بینی هستند. در روابط رگرسیون، مقادیر جریان تجمعی و پیش‌بینی فصلی هر دوره، به ترتیب متغیرهای مستقل ( $X$ ) و وابسته ( $Y$ ) و  $i$  اندیس سال صحت‌سنجی می‌باشد.

انوری: پیش بینی سناریوهای احتمالاتی ماهانه جریان ...


مطابق جدول (۱) شاخص‌های ارزیابی از اولین ماه پیش‌بینی تا آخرین ماه، یعنی از مهر تا شهریور، بهبود یافته است. علت آن می‌باشد که برای اولین ماه، افق پیش‌بینی حدود ۱۲ ماه است که این افق بلند مدت باعث کاهش دقت شاخص‌های پیش‌بینی می‌شود، ولی به تدریج با کاهش افق زمانی خطای پیش‌بینی کاهش می‌یابد.

### تولید سناریوهای پیش‌بینی جریان با رویکرد ESP مصنوعی

در این بخش از سری ۲۱ ساله داده‌های تاریخی جریان ورودی به سد جیرفت برای پیش‌بینی سناریوهای جریان با رویکرد ESP استفاده گردید. بدین منظور  $M = 13$  سال اول دوره (۱۳۶۸ تا ۱۳۸۰) به عنوان الگوهای جریان مرحله کالیبراسیون و سال‌های ۱۳۷۶ تا ۱۳۸۸ به عنوان الگوهای جریان مرحله صحت‌سنجی ( $N = 13$ ) به کار گرفته شدند.

با استفاده از بهترین معماری مدل‌های ANN، جریان‌های تجمعی ماه‌های مهر تا شهریور پیش‌بینی گردیدند. نتایج حاصل برای ماه اسفند در دو مرحله آموزش و آزمون در شکل (۳) ارائه شده است. مطابق این شکل همبستگی و خطای مقادیر دبی پیش‌بینی نسبت به دبی مشاهداتی برای جریان تجمعی ماه اسفند به ترتیب با معیار ضریب تعیین و شاخص گرافیکی خط ۴۵ درجه، ارزیابی شده است.

در نهایت با استفاده از مدل ANN برای هر ماه به‌طور جداگانه، پیش‌بینی‌های تجمعی جریان صورت گرفت. بدین صورت که ابتدا با استفاده از تحلیل رگرسیون، بهترین متغیرهای پیشگو، به‌عنوان ورودی مدل‌های ANN انتخاب گردید. جدول (۱) نتایج تحلیل همبستگی در تعیین متغیرهای پیشگوی مناسب، بهترین ساختار مدل‌ها و نیز نتایج مدل پیش‌بینی ANN در مراحل آموزش و آزمون برای پیش‌بینی تجمعی جریان ماه‌های مهر تا شهریور نشان می‌دهد.



شکل ۳- پراکنش مقادیر جریان تجمعی پیش‌بینی و مشاهداتی برای ماه اسفند (مراحل آموزش و آزمون)

جدول ۱- نتایج پیش‌بینی‌های تجمعی جریان ماه‌های مهر تا شهریور به همراه متغیرهای پیشگو و ساختار ANNs

مرحله آموزش			مرحله آزمون			ساختار ANN	متغیرهای پیشگو	ماه پیش‌بینی
RMSE (m <sup>3</sup> /s)	R <sup>2</sup>	MAE (m <sup>3</sup> /s)	RMSE (m <sup>3</sup> /s)	R <sup>2</sup>	MAE (m <sup>3</sup> /s)			
۷۱/۸	۰/۶۴	۵۲/۷۴	۹۰	۰/۶۶	۵۶/۷۷	۲-۲-۱	Tmin_MHR, Q_TIR	مهر
۶۱/۲	۰/۷۱	۴۷/۸۳	۸۹/۸	۰/۷۳	۵۲/۹۱	۲-۲-۱	Tmin_MHR, Q_TIR	آبان
۴۱/۳	۰/۸۵	۳۰/۹۳	۵۹/۱	۰/۹۸	۴۱/۸۱	۲-۲-۱	T_MIN_MEH, Q_AZR	آذر
۵۸/۴	۰/۶۸	۴۴/۸۹	۶۶/۳	۰/۷۳	۵۹/۲۲	۲-۲-۱	Q_AZR, Q_DEY	دی
۱۵/۷	۰/۹۴	۱۰/۴	۶۶/۹	۰/۸۴	۵۰/۱	۲-۲-۱	Q_DEY, Q_BAH	بهمن
۴۹/۲	۰/۶۳	۳۵/۹۵	۴۴/۷۱	۰/۹۳	۳۸/۳	۲-۲-۱	Q_DEY, Q_ESF	اسفند
۲۳/۹	۰/۸۵	۱۵/۳۱	۱۴/۵۷	۰/۸۷	۸/۴۷	۲-۲-۱	Q_BAH, Q_FAR	فروردین
۱۲/۹	۰/۸۴	۶/۹۸	۱۳/۳۱	۰/۹۹	۸/۵	۲-۲-۱	Q_BAH, Q_ORD	اردیبهشت
۱۱/۹	۰/۷۹	۶/۴۸	۷/۹۶	۰/۶	۶/۷۲	۲-۲-۱	Q_Ord, Q_KHO	خرداد
۵/۲	۰/۹۴	۳/۳۸	۵/۹۳	۰/۹۹	۳/۶	۲-۲-۱	Q_kho, Q_tir	تیر
۴/۴	۰/۹۱	۲/۷۲	۳/۴۵	۰/۹۴	۲/۲۹	۲-۲-۱	Q_tir, Q_mor	مرداد
۳/۹	۰/۸	۲/۱	۵/۶۷	۰/۹۱	۴/۱	۲-۲-۱	Q_tir, Q_mor	شهریور

تاریخی و پیش‌بینی جریان فصلی همه الگوهای صحت‌سنجی (حاصل از مدل ANN) محاسبه گردید. انحراف معیار میانگین شرطی ( $\sigma$ )، نیز از مقادیر پیش‌بینی آن دوره که از مدل ANN موجود می‌باشد، حاصل گردید. در ادامه برای هر دوره پیش‌بینی  $t$  از هر سال صحت‌سنجی  $\hat{t}$  با استفاده از رابطه تحلیل فراوانی Chow، مقدار کل جریان زیر نمودار مربوط به آن سال یعنی  $\{P_i\}^{-1} \times \sigma_{QF} - \overline{QF} = \hat{Q}_i$  محاسبه شد (Chow et al., 1981). این مقادیر برای اولین سال صحت‌سنجی در جدول (۳) ارائه شده است.

در ادامه به مقادیر جریان‌های تجمعی همه الگوهای صحت‌سنجی، توابع مختلف از توزیع‌های احتمال، برازش و بهترین توزیع با استفاده از آزمون نکویی برازش و آماره کلموگروف اسمیرنوف (KS) انتخاب گردید. سپس از دو توزیع نرمال و لوگ نرمال (روابط ۱ و ۲)، برای محاسبه توابع چگالی احتمال الگوهای صحت‌سنجی استفاده شد. در مرحله بعد با استفاده از پارامترهای توزیع، برای هر سال از الگوهای کالیبراسیون، احتمال عدم وقوع متغیر استاندارد  $Z$  مطابق رابطه (۶) محاسبه گردید. سپس با استفاده از فرمول (۱۲) مقادیر فاکتور تناوب  $\phi^{-1}$  مربوط به احتمال  $P_i$  مطابق جدول (۲) تعیین شد.

در مرحله بعد، میانگین و واریانس شرطی مقادیر پیش‌بینی (مطابق رابطه ۸ و ۹) با استفاده از رابطه رگرسیونی بین مقادیر


جدول ۲- فاکتور تناوب  $\phi^{-1}$  مربوط به احتمال  $P_i$

سال	مهر	شهریور	مرداد	تیر	خرداد	اردیبهشت	فروردین	اسفند	بهمن	دی	آذر	آبان
۱۳۶۸-۶۹	۰/۲۵	۰/۲۳	۰/۲۳	۰/۲۴	۰/۲۷	۰/۴۱	۰/۱۴	۰/۱۳	۰/۱۱	۰/۱۶	۰/۲۱	۰/۲۳
۱۳۶۹-۷۰	۰/۲۲	۰/۳۰	۰/۳۷	۰/۴۳	۰/۳۴	۰/۲۶	۰/۳۴	۰/۱۱	۰/۰۷	۰/۱۲	۰/۱۷	۰/۲۰
۱۳۷۰-۷۱	۰/۴۱	۰/۰۱	۰/۱۶	۰/۲۶	۰/۳۵	۰/۲۷	۰/۳۰	۰/۳۱	۰/۲۹	۰/۳۰	۰/۳۵	۰/۳۸
۱۳۷۱-۷۲	۰/۲۲	۰/۴۵	۰/۴۳	۰/۴۲	۰/۴۱	۰/۴۲	۰/۴۰	۰/۴۲	۰/۴۴	۰/۵۰	۰/۴۸	۰/۲۰
۱۳۷۲-۷۳	۰/۰	۰/۴۶	۰/۴۱	۰/۴۰	۰/۳۹	۰/۰۹	۰/۰۳	۰/۰۵	۰/۰۸	۰/۱۱	۰/۱۱	۰/۰۱
۱۳۷۳-۷۴	۰/۰	۰/۴۲	۰/۲۳	۰/۱۰	۰/۰۱	۰/۰۳	۰/۰	۰/۰	۰/۰	۰/۰	۰/۰	۰/۰
۱۳۷۴-۷۵	۰/۰	۰/۴۹	۰/۴۷	۰/۴۴	۰/۳۹	۰/۰۸	۰/۰۱	۰/۰	۰/۰	۰/۰	۰/۰	۰/۰
۱۳۷۵-۷۶	۰/۰۲	۰/۰	۰/۰	۰/۰	۰/۰	۰/۰	۰/۰۱	۰/۰۱	۰/۰۲	۰/۰۴	۰/۰۶	۰/۰۵
۱۳۷۶-۷۷	۰/۰	۰/۰۱	۰/۰۳	۰/۰۴	۰/۰۱	۰/۰	۰/۰	۰/۰	۰/۰	۰/۰	۰/۰	۰/۰
۱۳۷۹-۸۰	۰/۴۲	۰/۳۵	۰/۴۴	۰/۴۵	۰/۴۴	۰/۴۷	۰/۴۹	۰/۴۷	۰/۴۶	۰/۴۷	۰/۴۷	۰/۴۶
۱۳۸۰-۸۱	۰/۳۷	۰/۳۷	۰/۳۹	۰/۴۲	۰/۴۳	۰/۴۳	۰/۴۱	۰/۴۳	۰/۴۸	۰/۴۹	۰/۴۶	۰/۴۲
۱۳۸۱-۸۲	۰/۴۳	۰/۵۰	۰/۴۷	۰/۵۰	۰/۴۷	۰/۴۴	۰/۴۲	۰/۴۲	۰/۴۲	۰/۴۲	۰/۴۲	۰/۴۲
۱۳۸۲-۸۳	۰/۳۳	۰/۳۴	۰/۳۵	۰/۳۵	۰/۳۵	۰/۳۶	۰/۳۶	۰/۳۶	۰/۳۶	۰/۳۵	۰/۳۵	۰/۳۴
۱۳۸۳-۸۴	۰/۲۵	۰/۲۳	۰/۲۳	۰/۲۴	۰/۲۷	۰/۴۱	۰/۱۴	۰/۱۳	۰/۱۱	۰/۱۶	۰/۲۱	۰/۲۳
۱۳۸۴-۸۵	۰/۲۲	۰/۳۰	۰/۳۷	۰/۴۳	۰/۳۴	۰/۲۶	۰/۳۴	۰/۱۱	۰/۰۷	۰/۱۲	۰/۱۷	۰/۲۰

جدول ۳- مقادیر  $Q_i$  برای سناریوها و دوره‌های مختلف در سال اول صحت‌سنجی

سال	مهر	آبان	آذر	دی	بهمن	اسفند	فروردین	اردیبهشت	خرداد	تیر	مرداد	شهریور
۷۷-۷۶	۱۳۶	۱۳۷	۴۵۹	۴۱۳	۴۲۴	۲۸۴	۱۶۴	۸۷	۷۲	۶۲	۴۱	۳۲
۷۸-۷۷	۱۳۸	۱۴۱	۴۶۸	۴۲۴	۴۴۳	۲۸۶	۱۲۵	۹۹	۶۷	۵۳	۳۶	۳۱
۷۹-۷۸	۹۴	۹۵	۴۰۶	۳۶۴	۳۵۵	۲۳۹	۱۳۳	۹۹	۶۷	۶۲	۴۵	۴۷
۸۰-۷۹	۱۴۱	۱۴۲	۳۷۱	۳۱۸	۳۱۷	۲۲۱	۱۲۰	۸۸	۶۵	۵۳	۳۴	۲۷
۸۱-۸۰	۳۲۳	۲۷۷	۴۹۷	۴۳۱	۴۲۵	۳۱۴	۲۰۴	۱۲۱	۶۵	۵۳	۳۴	۲۷
۸۲-۸۱	۳۲۶	۳۲۵	۷۰۸	۶۳۹	۶۸۴	۴۷۳	۳۲۷	۱۳۷	۱۰۸	۷۵	۴۲	۲۸
۸۳-۸۲	۴۴۵	۴۴۵	۸۶۲	۷۵۴	۷۲۸	۵۱۸	۲۱۷	۱۲۱	۶۴	۵۰	۳۲	۲۷
۸۴-۸۳	۲۵۵	۲۱۲	۵۳۷	۴۸۱	۵۰۲	۳۶۰	۲۳۹	۱۶۵	۱۳۴	۱۲۴	۸۱	۵۹
۸۵-۸۴	۳۳۷	۳۳۶	۷۰۳	۵۹۶	۵۹۴	۴۰۱	۲۵۶	۱۵۹	۱۱۰	۸۶	۵۶	۴۷
۸۶-۸۵	۹۳	۷۹	۳۷۵	۳۲۵	۳۱۳	۲۱۲	۱۰۸	۸۳	۶۲	۵۰	۳۳	۲۹
۸۷-۸۶	۱۰۴	۸۸	۳۷۵	۳۱۹	۳۰۸	۲۱۸	۱۱۷	۸۷	۶۳	۵۳	۳۵	۳۰
۸۸-۸۷	۸۹	۸۶	۳۸۵	۳۳۵	۳۲۱	۲۱۹	۱۱۶	۸۵	۶۰	۴۸	۳۳	۲۷
۸۹-۸۸	۱۱۲	۱۰۴	۴۰۷	۳۵۲	۳۲۸	۲۳۰	۱۲۴	۹۱	۶۷	۵۵	۳۶	۳۰

انوری: پیش بینی سناریوهای احتمالاتی ماهانه جریان ...



شکل ۴- مقادیر جریان ماهانه تبدیل یافته (خوشه نهایی پیش بینی) برای دوره اول و تمام سال های صحت سنجی

گام های پیش بینی ماهانه در نظر گرفته شد. در نهایت با کمک این پیش بینی ها، خصوصیات توابع توزیع احتمال آنها، سناریوهای احتمالاتی جریان ورودی با رویکرد ESP مصنوعی تولید گردید. در راستای نیل به اهداف تحقیق، مدل های پیش بینی مختلف اجرا و مورد ارزیابی قرار گرفت که نتایج زیر بدست آمد.

-انجام آنالیز همبستگی بین متغیرهای پیشگو و پیش بینی، توانست متغیرهای مؤثر بر مسأله را بخوبی شناسایی و زمان و حجم محاسبات را کاهش دهد.

-مدل هایی با ساختار یک لایه پنهان و تعداد نرون های بین ۵ تا ۵ عدد، توانست بهترین خروجی ها را برای مدل های ANN پیش بینی کند.

-شاخص های  $RMSE$ ،  $R^2$  و  $MAE$  برای ارزیابی عملکرد مدل های ANN در پیش بینی تجمعی جریان رودخانه هلیل رود مورد استفاده قرار گرفت. مقایسه و ارزیابی این شاخص ها نشان داد که مقادیر آن ها از اولین ماه پیش بینی، تا آخرین ماه، شامل ماه های مهر تا شهریور، بهبود یافته است. علت آن می باشد که برای اولین ماه، افق پیش بینی حدود ۱۲ ماه است که این افق بلند مدت باعث کاهش دقت شاخص های پیش بینی می شود، ولی به تدریج با کاهش افق زمانی خطای پیش بینی کاهش می یابد.

-با بکارگیری خروجی مدل های ANN که در برگزیده پیش بینی های تجمعی جریان هستند و نیز انجام آنالیزهای آماری، استفاده از خصوصیات توزیع احتمال این پیش بینی ها و تعیین پارامترهای توزیع های آماری جریان تجمعی هر ماه و نهایتاً استفاده از تکنیک ESP مصنوعی، برای هر سال از دوره شبیه سازی،

در نهایت تولید سناریوهای پیش بینی ESP انجام می گردد. بدین ترتیب که بعنوان نمونه در ابتدای دوره صحت سنجی، یعنی سال ۱۳۶۹ و دوره (ماه) اول، ۱۳ هیدروگراف جریان پیش بینی شده (خوشه جریان) مورد نظر باشد. لذا مقادیر جریان در الگوهای ۱۳ ساله مرحله کالیبراسیون، با توجه به مقادیر  $\tilde{Q}$  متناظر با آن، در جدول (۳) تغییر می نمایند تا جایی که ضریب تغییر تمامی سناریوها، برآورد گردد.

حاصل فرآیند مزبور، تولید ۱۳ مجموعه، که هر یک، ۱۳ سناریوی ۱۲ ماهه پیش بینی جریان، برای سال های ۷۶ تا ۱۳۸۸ را در بر می گیرد. سناریوهای ESP را اصطلاحاً خوشه (دنباله) جریان می نامند. برای بقیه سال ها و ماه های صحت سنجی نیز به همین ترتیب عمل شد و در نهایت برای تمام دوره های پیش بینی، ۱۶۹ سناریوی ESP (۱۳ مجموعه و هر کدام در برگزیده ۱۳ سناریوی) تولید می شود. شکل (۴) شماتیک سناریوهای احتمالاتی تولید شده را نشان می دهد.

### نتیجه گیری

از آنجا که پیش بینی کمیت جریان رودخانه از مؤلفه های اصلی مدیریت سیستم های منابع آب است، در این تحقیق سعی بر آن شد تا با استفاده از پیش بینی های تجمعی جریان و خصوصیات احتمالاتی آنها، سناریوهای احتمالاتی جریان ورودی به سد جیرفت با کمک مدل های پیش بینی گروهی جریان (ESP) تولید گردد. بدین منظور با استفاده از داده های هواشناسی و هیدرولوژیکی حوضه رودخانه هلیل رود، پیش بینی های تجمعی جریان با مدل های شبکه عصبی مصنوعی (ANN) صورت گرفت. لازم به ذکر است که افق این پیش بینی های تجمعی سالانه و



محیطی (دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته) با شماره ۳۱۶۴/۹۴/ص/۷ مورخ ۱۳۹۴/۰۷/۰۱ به ثبت رسیده و منابع مالی آن توسط پژوهشگاه نامبرده تأمین شده است، که بدینوسیله از همکاری ریاست محترم آن مرکز و همکارانشان تشکر و قدردانی می‌شود.

سناریوهای ۱۳ گانه جریان ورودی به رودخانه هلیلرود پیش‌بینی گردید.

### تشکر و قدردانی

این مقاله بخشی از یک طرح پژوهشی بوده که قرارداد همکاری آن در پژوهشگاه علوم و تکنولوژی پیشرفته و علوم

### منابع

- 1- Alcázar, J., Palau, A. and Vega-Garcı, C., 2008. A neural net model for environmental flow estimation at the Ebro River Basin, Spain. *Journal of hydrology*, 349(1-2), pp.44-55.
- 2- Aqil, M., Kita, I., Yano, A. and Nishiyama, S., 2006. Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool. *Journal of Environmental Management*, 10, pp.1-9.
- 3- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000. Artificial neural networks in hydrology, I: preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), pp. 115-123.
- 4- Besaw, L.E., Rizzo, D.M., Bierman, P.R. and Hackett, W.R., 2010. Advances in ungauged streamflow prediction using artificial neural networks. *Journal of Hydrology*, 386(1-4), pp.27-37.
- 5- Chow, V.T., Maidment, D.R. and Larry W., 1981. *Applied Hydrology*.
- 6- Dawson, C.W., Abrahart, R.J., Shamseldin, A.Y. and Wibly, R.L., 2006. Flood estimation at ungauged sites using artificial neural networks. *Journal of Hydrology*, 319, pp.391-409.
- 7- Day, G.N., 1985. Extended streamflow forecasting using NWSRFS. *Journal of Water Resources Planning and Management*, 111(2), pp.157-170.
- 8- Demirel, M.C., Venancio, A. and Kahya, E., 2009. Flow forecast by SWAT model and ANN in Pracana basin, Portugal. *Advances in Engineering Software*, 40(7), pp.467-473.
- 9- Eum, H., Kim, Y.O. and Palmer, R., 2011. Optimal drought management using sampling stochastic dynamic programming with a hedging rule. *Journal of Water Resources Planning and Management*. 137(1), pp.113-122.
- 10- Faber, B.A. and Stedinger, J.R., 2001. Reservoir optimization using sampling SDP with ensemble steamflow prediction (ESP) forecasts. *Journal of Hydrology*, 249, pp.113-133.
- 11- <http://news.moe.gov.ir/News/Details.aspx?ANWID = 11722>
- 12- Karamooz, M. and Araghinezhad, SH., 2005. *Advanced hydrology*, Amirkabir University of Technology Press, Tehran, 465p, (In Persian).
- 13- Kim, Y.O., Eum, H., Lee E.G. and Ko, I.H., 2007. Optimizing operational policies of a korean multireservoir system using sampling stochastic dynamic programming with ensemble streamflow prediction. *Journal of Water Resources Planning and Management*, 133(1), pp.4-14.
- 14- Kisi, O., 2005. Daily river flow forecasting using artificial neural networks and auto-regressive models. *Turkish Journal of Engeering and Environmental Science*, 29, pp.9-20.
- 15- Nayaka, P.C., Sudheerb, K.P., Ranganc, D.M. and Ramasastrı, K.S., 2004. A neuro- fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*, 291, pp.52-66.
- 16- Saghafian, B., Anvari, S. and Morid, S., 2013. Effect of SOI and spatial climatic data on ANN, ANFIS and K-NN models in the stream flow forecasts. *Expert Systems Journal*, 30(4), pp.367-380.

- 17- Sedki, A., Ouazar, D. and El Mazoudi, E., 2009. Evolving neural network using real coded genetic algorithm for daily rainfall–runoff forecasting. *Expert Systems with Applications*, 36(3), pp.4523-4527.
- 18- Shiri, J. and Kisi, O., 2010. Short-term and long-term streamflow forecasting using a wavelet and neuro-fuzzy conjunction model. *Journal of Hydrology*, 394(3-4), pp.486-493.
- 19- Wang, W., Van Gelder, H.A.J.M., Vrijling, J.K. and Ma, J., 2006. Forecasting daily streamflow using hybrid ANN models. *Journal of Hydrology*, 324, pp.383–399.
- 20- Zounemat Kermani, M. and Teshnehlab, M., 2007. Using adaptive neuro-fuzzy inference system for hydrological time series prediction. *Applied Soft Computing*, Available online at [www.Sciencedirect.com](http://www.Sciencedirect.com).

**EXTENDED ABSTRACT****Probabilistic Forecasts of Streamflow Scenarios Using ESP Approach  
(Case study: Halil River)**

S. Anvari

Assistant Professor, Department of Ecology, Environmental Research Center, Institute of Science and High Technology and Environmental Science, Graduate University of Advanced Technology (*s.anvari@kgut.ac.ir*).

Received: 27 October 2016

Accepted: 12 February 2017

**Keywords:** Stream flow Forecast, ANN, ESP, Halil River.**Introduction**

Stream flow forecast is a fundamental tool that could be utilized for appropriate water resource management. The enhancement of accuracy as well as the increase of time horizon for stream flow forecasts is essential especially for agricultural sector which is the most vulnerable sector during water shortages. In this regard, the application of stochastic approaches like Ensemble Streamflow Prediction (ESP) procedure for long-term forecast with respect to streamflow uncertainty can be proposed. The ESP procedure produces streamflow forecasts in the form of multiple hydrographs, each a possible realization of seasonal streamflow (Day, 1985). One example of ensemble streamflow forecasts is the National Weather Service's ESP procedure. Faber and Stedinger (2001) successfully combined reservoir operation models with updated information from ESP of the National Weather Service (Faber and Stedinger, 2001). Using ESP forecasts, Eum et al. (2011) also developed a procedure to calculate optimal water release curtailments during droughts using a future value function derived with a sampling stochastic dynamic programming model.

The main objective of this paper is to present a probabilistic approach and forecast the inflows to Jiroft dam reservoir. In this regards, using ESP approach as well as Artificial Neural Networks (ANNs) the 1- to 12- month ahead probabilistic scenarios of Halil river were forecasted.

**Methodology**

In this section, the meteorological, as well as hydrological data of Halil river were employed to forecast cumulative streamflow using ANNs. Finally, using ESP models, the probabilistic scenarios of inflows were forecasted. First, we carried out a correlation analysis to select the most appropriate input variables for the ANN models. Based on available data, the maximum, mean, and minimum temperature (Tmax, Tmean, Tmin), precipitation (R), and past inflows (Q) were selected as the most relevant input variables (predictors). Then, the next 1-month to 12-month cumulative inflows were forecast by using different ANNs. The models were of three-layer feed-forward network type with a sigmoidal activation function trained by the Levenberg-Marquardt (LM) algorithm. 70% and 30% of data were used for training and testing purposes, respectively. The number of neurons in the hidden layer was determined by trial and error. Moreover, input and output data were rescaled in 0.1-0.9 range (ASCE 2000; Wang et al. 2006; Besaw et al. 2010). Finally, the performance of ANN models was compared based on the indices of determination coefficient (R<sup>2</sup>), root mean squared error (RMSE), and mean absolute error (MAE).

### Case study

The Hamoon Jazmoorian Lake is an important lake of Kerman province, with a variable capacity of water. The same does not account as a permanent lake of this region. The Halil Rood and Bampour Rivers flow into this lake from the west and east, respectively. Jazmoorian Basin covers an area of 69,600 km<sup>2</sup>. This lake is located between the provinces of Sistan and Baluchestan and Kerman, and the western section of its basin encompasses the townships of Baft, Kahnooj and Sabzvaran.

### Data description

Precipitation (Rain), temperature in three scales i.e. minimum, average and maximum (T<sub>max</sub>, T<sub>mean</sub>, T<sub>min</sub>) as well as discharge (Q) are the data that used in this paper. All data are in monthly scale and cover a period of 21 water years from 1989–2009 water years.

### Artificial Neural Networks (ANNs)

Neural networks are parallel processing systems. These networks can map linear and nonlinear relations between input–output pairs in any phenomenon of interest (ASCE Task Committee, 2000a,b). The ANNs used in this paper are three-layer feed-forward networks with sigmoid function and LM training algorithm (Coulibaly et al., 2000). Optimum number of neurons in the hidden layer was determined through trial and error (Saghafian et al.; 2013).

### ESP approach for generation of stochastic streamflow scenarios

ESP is a forecasting procedure that combines physical modeling of the river basin with a probabilistic representation of the future using historical weather data. The National Weather Service River Forecast System (NWSRFS) Operational Forecast System generates short-range streamflow forecasts by inputting observed and forecast precipitation and temperature data into conceptual hydrologic and hydraulic models that simulate the snow accumulation and ablation, rainfall/runoff, watershed routing, and channel routing processes to produce simulated streamflow (Day, 1985; Faber and Stedinger, 2001).

The general idea of using ESP forecasts is similar to that proposed by Faber and Stedinger (2001), but with a clear distinction. In the current study, ANNs are used to generate monthly cumulative forecasts as the fundamental elements in ESP generation, rather than using a linear regression approach. To calculate ESP scenarios, the following equations have been employed (Chow, 1981):

$$f_x(X) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-0.5\left(\frac{x-\mu}{\sigma}\right)^2\right] \quad (1)$$

$$F_x(X) = P(X \leq x) = \int_{-\infty}^x f_x(X) dx \quad (2)$$

### Conclusions and future challenges

The aim of this study is to present a probabilistic approach and forecast the inflows to Jiroft dam reservoir. In this regard, using ESP approach as well as ANNs the 1- to 12-month ahead probabilistic scenarios of Halil river were forecasted. Results showed that by an increase of forecast horizon, the accuracy of ANN forecasts will be decreased. Also, combination of ANN with the artificial approach of ESP could accurately forecast the probabilistic scenarios of streamflow. Also, the ANNs with the number of 1-5 neurons in hidden layers had the best performance.

### References

- 1- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000. Artificial neural networks in hydrology, I: preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), pp. 115-123.

- 2- Besaw, L.E., Rizzo, D.M., Bierman, P.R. and Hackett, W.R., 2010. Advances in ungauged streamflow prediction using artificial neural networks. *Journal of Hydrology*, 386(1-4), pp.27–37.
- 3- Chow, V.T., Maidment, D.R. and Larry W., 1981. *Applied Hydrology*.
- 4- Day, G.N., 1985. Extended streamflow forecasting using NWSRFS. *Journal of Water Resources Planning and Management*, 111(2), pp.157-170.
- 5- Eum, H., Kim, Y.O. and Palmer, R., 2011. Optimal drought management using sampling stochastic dynamic programming with a hedging rule. *Journal of Water Resources Planning and Management*. 137(1), pp.113-122.
- 6- Faber, B.A. and Stedinger, J.R., 2001. Reservoir optimization using sampling SDP with ensemble steamflow prediction (ESP) forecasts. *Journal of Hydrology*, 249, pp.113-133.
- 7- Kim, Y.O., Eum, H., Lee E.G. and Ko, I.H., 2007. Optimizing operational policies of a korean multireservoir system using sampling stochastic dynamic programming with ensemble streamflow prediction. *Journal of Water Resources Planning and Management*, 133(1), pp.4-14.
- 8- Saghafian, B., Anvari, S. and Morid, S., 2013. Effect of SOI and spatial climatic data on ANN, ANFIS and K-NN models in the stream flow forecasts. *Expert Systems Journal*, 30(4), pp.367–380.
- 9- Wang, W., Van Gelderp, H.A.J.M., Vrijling, J.K. and Ma, J., 2006. Forecasting daily streamflow using hybrid ANN models. *Journal of Hydrology*, 324, pp.383–399.