

پیش‌بینی جریان رودخانه با مدل‌های ANN و بررسی عملکرد آن با ورودی‌های SOI

صادیقه انوری‌تفقی^۱، بهرام ثقفیان^۲ و سعید مرید^{۳*}

^۱دانشجوی دکتری گروه سازه‌های آبی، دانشگاه تربیت مدرس، ^۲استاد پژوهشکده حفاظت خاک و آبخیزداری،

^۳دانشیار گروه سازه‌های آبی، دانشگاه تربیت مدرس

تاریخ دریافت: ۸۹/۹/۲۵؛ تاریخ پذیرش: ۸۹/۹/۲۰

چکیده

تکنیک‌های مدل‌سازی مرسوم مانند رگرسیون و سری‌های زمانی، در مدل کردن فرآیندهای غیرخطی همانند پیش‌بینی جریان رودخانه بیشتر با شکست مواجه می‌شوند. از این‌رو تکنیک‌های غیرخطی مانند شبکه‌های عصبی مصنوعی (ANN) می‌توانند ابزار کارآمدتری برای پیش‌بینی این فرآیندها باشند. در این مقاله جریان ۱ تا ۳ ماه بعد حوضه کارون، پیش‌بینی می‌گردد. در این راستا ابتدا با به کارگیری تکنیک‌های همبستگی دودویی (CC) و آنالیز مؤلفه‌های اصلی (PCA)، ۴ مدل ورودی از ANN ساخته شد. سپس با استفاده از تکنیک اعتبارسنجی حذفی (CV) و شاخص‌های ارزیابی همانند ضریب تعیین، میانگین قدر مطلق خطأ و ریشه میانگین مربعات خطأ برترین مدل ورودی شناسایی گردید. همچنین برای تعیین میزان اثربخشی هر یک از متغیرهای ورودی و مؤلفه‌های اصلی، نقش منفرد و ترکیبی هر یک از آنها بر عملکرد مدل ANN بررسی شد. در نهایت اثر شاخص نوسانات جنوبی (SOI) در زمان‌های ۱-۱ و ۲-۱ بر عملکرد بهترین مدل ورودی، مورد ارزیابی قرار گرفت. نتایج بیانگر آن بود که در حوضه کارون، متغیرهای دمایی بیشترین تأثیر را بر جریان رودخانه دارند. همچنین شاخص SOI به عنوان متغیر ورودی، به طور متوسط عملکرد این مدل‌ها را به میزان ۵ درصد برای RMSE و ۴ درصد برای MAE بهبود بخشیده است.

واژه‌های کلیدی: پیش‌بینی جریان، SOI، ANN، حوضه کارون

* مسئول مکاتبه: morid_sa@modares.ac.ir

مقدمه

پیش‌بینی جریان ورودی به مخزن سد نقش اساسی در بهره‌برداری بهینه از سیستم‌های منابع آب دارد. اهمیت این پیش‌بینی‌ها در حوضه‌های بزرگ و کوچک‌تری همانند کارون که به علت وسعت اراضی کشاورزی و تولید انرژی برقی از حوضه‌های مهم ایران محسوب می‌شود، بارزتر می‌باشد. برای انجام این پیش‌بینی‌ها استفاده از مدل‌های سری‌های زمانی رایج بوده است. این مدل‌ها و همچنین مدل‌های رگرسیونی خطی بیشتر در مدل‌سازی پدیده‌های غیرخطی با شکست مواجه می‌شوند. در مقابل تکثیک‌های غیرخطی مانند مدل‌های شبکه عصبی مصنوعی (ANN)^۱، می‌تواند ابزار کارآمدتری باشند (زیلاند و همکاران، ۱۹۹۹). طی سال‌های اخیر پژوهش‌های متنوعی در زمینه پیش‌بینی جریان با استفاده از مدل‌های ANN در سطح جهان انجام شده است. راید و همکاران (۲۰۰۴) از ANN جهت مدل کردن رابطه بارش-رواناب در حوزه اوریکا واقع در مراکش استفاده کردند. جین و کومار (۲۰۰۶) برای پیش‌بینی ماهانه جریان رودخانه کلرادو مدل‌های هیبریدی شبکه عصبی-سری‌های زمانی را به کار برداشتند. آکاوار و همکاران (۲۰۰۸) پیش‌بینی جریان رودخانه ابرو در اسپانیا را توسط مدل‌های ANN انجام دادند. سدکی و همکاران (۲۰۰۹) برای پیش‌بینی روزانه بارش و رواناب در مراکش از مدل‌های ANN استفاده کردند. پژوهش‌های نامبرده و همچنین بررسی‌های دمیرل و همکاران (۲۰۰۹) برای پیش‌بینی روزانه جریان در پرتغال با استفاده از مدل‌های ANN و مدل ابزار ارزیابی آب و خاک (SWAT)^۲، همگی بیانگر کاربرد موقیت‌آمیز مدل‌های ANN در مقایسه با سایر مدل‌های به کار رفته در پژوهش بوده‌اند. همچنین در دهه اخیر تأثیر سیگنال‌های بزرگ مقیاس اقلیمی مانند پدیده انسو (ENSO)^۳ که به صورت شاخص نوسانات جنوبی (SOI)^۴ کمی می‌شود، بر میزان بارش مناطق مختلف جهان به خوبی شناخته شده و به عنوان متغیر پیش‌گو در پیش‌بینی‌های اقلیمی و هیدرولوژیکی در مناطق مختلف به کار گرفته شده است. در رابطه با استفاده از SOI برای پیش‌بینی‌های بارندگی و جریان رودخانه می‌توان به پژوهش‌های گارن (۱۹۹۸) و کورتیس و همکاران (۲۰۰۱) اشاره کرد که در این پژوهش‌های اثر SOI بر دقت پیش‌بینی‌ها مثبت گزارش شده است. تأثیر این پدیده بر اقلیم بخش‌هایی از ایران نیز محتمل می‌باشد (ناظم السادات، ۱۹۹۹).

1- Artificial Neural Network

2- Soil and Water Assessment Tool

3- El-Nino Southern Oscillation Index

4- Southern Oscillation Index

هدف مقاله حاضر آن است که جریان ۱ تا ۳ ماه بعد رودخانه کارون (محل ایستگاه پل شالو) با استفاده از مدل‌های ANN پیش‌بینی و نقش منفرد و ترکیبی متغیرهای ورودی و مؤلفه‌های اصلی به دست آمده از آن‌ها، در مدل‌سازی بررسی گردد. همچنین بررسی تأثیر SOI بر عملکرد مدل‌های ANN، پیش‌بینی، از اهداف دیگر این مقاله به حساب آمد. لازم به ذکر است که در استفاده از مدل‌های ANN، شناسایی متغیرهای ورودی و تعیین تعداد تأخیر زمانی برای هر یک، متداول‌تری تعیین مدل‌های ورودی، کنترل خطای مرحله آموزش و در نهایت تعیین متغیرهای مؤثرتر بر عملکرد مدل، نکات مهمی است که در مقایسه با سایر پژوهش‌ها، در مدل‌سازی این پژوهش، همزمان مدنظر قرار گرفت.

مواد و روش‌ها

منطقه پژوهش: حوضه آبریز کارون ۳ بخشی از حوضه کارون بزرگ است که در جنوب‌غربی ایران واقع شده و در حد فاصل طول شرقی ۴۹ درجه و ۳۰ دقیقه تا ۵۲ درجه و عرض شمالی ۳۰ درجه تا ۳۲ درجه و ۳۰ دقیقه قرار گرفته است. ارتفاع متوسط این حوضه تا ایستگاه هیدرومتری پل شالو که ورودی به سد کارون ۳ نیز محسوب می‌گردد، حدود ۲۴۰۰ متر و وسعت آن حدود ۲۴۰۰ کیلومترمربع می‌باشد (شکل ۱). برای این حوضه آمار دما، بارندگی و دبی در ایستگاه پل شالو و همچنین شاخص اقلیمی SOI به مدت ۳۰ سال آبی (۱۳۵۳-۵۴ تا ۱۳۸۲-۸۳) موجود می‌باشد که از آن‌ها به عنوان متغیرهای ورودی در مدل‌سازی استفاده شد.

نوسانات جنوبی و شاخص SOI: والکر (۱۹۲۳)، نشان داد که فشار هوا بین نواحی شرقی و غربی اقیانوس آرام جنوبی به صورت الکلنگی نوسان می‌کند. وی این پدیده را نوسان جنوبی (SO)^۱ نامید. شاخص SOI برای کمی کردن این پدیده به کار می‌رود که مطابق رابطه (۱) از تفاضل مقادیر استاندارد شده فشار هوای سطح آب در دو نقطه داروین استرالیا (P_D) و جزیره تاهیتی (P_T) محاسبه می‌گردد و عموماً به صورت شاخص تروب پ بیان می‌شود:

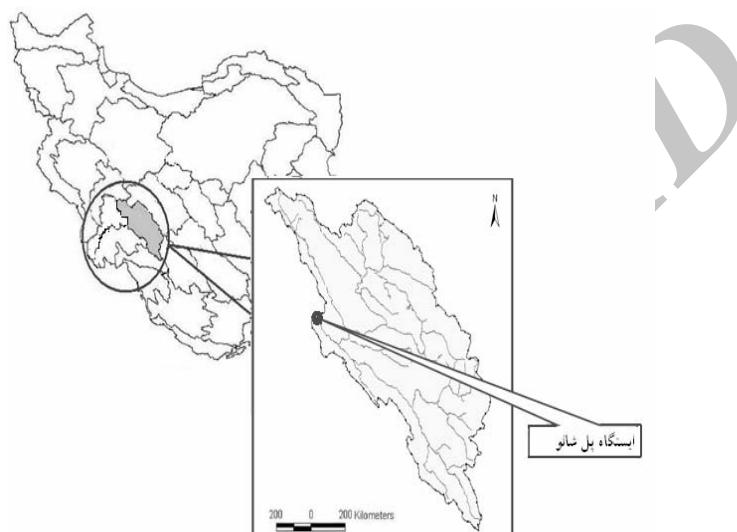
$$\text{SOI} = P_T - P_D \quad (1)$$

داده‌های مربوط به شاخص SOI بر روی شبکه جهانی اینترنت موجود است.^۲

1- Southern Oscillation

2- www.cpc.NOAAGov

شبکه‌های عصبی مصنوعی^۱: حدود ۹۰ درصد شبکه‌های عصبی که در مسایل مختلف هیدرولوژی کاربرد دارند شبکه‌های پیش‌رو هستند (کولبیالی و همکاران، ۲۰۰۰). معماری معمول این شبکه‌ها متشكل از سه لایه ورودی، پنهان و خروجی است و تعداد نرون‌های لایه پنهان، با سعی و خطاب به دست می‌آید (ای اس سی ای، ۲۰۰۰).



شکل ۱- موقعیت منطقه پژوهش.

در مدل‌سازی این پژوهش از شبکه‌های پیش‌رو سه‌لایه، تابع فعالیت سینگموئیدی، الگوریتم آموزش پسانشار و تعداد ۱۰۰ دوره آموزش استفاده گردید. همچنین، داده‌های ورودی و خروجی با استفاده از رابطه ۲ در محدوده [۰/۹-۰/۱] تغییر شکل یافتهند (زیلاند و همکاران، ۱۹۹۹؛ وانگ و همکاران، ۲۰۰۶).

$$X_n = \alpha \times \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) + \beta \quad (2)$$

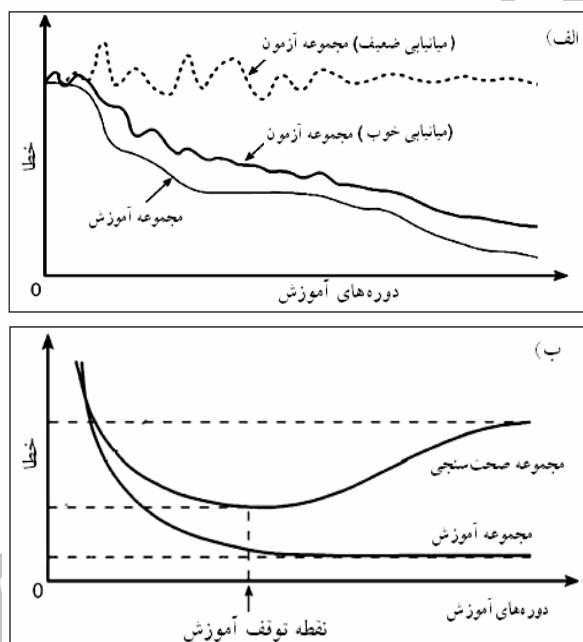
در آموزش شبکه‌های عصبی، تصمیم‌گیری در مورد توقف آموزش امر مهمی است، زیرا اگر آموزش شبکه به درستی متوقف نشود، شبکه مستعد خطای فوق برآزشی^۲ یا ضعف برآزشی^۳ می‌شود.

1- Artificial Neural Networks

2- Over Fitting

3- Under Fitting

در شکل ۲-الف مشاهده می‌شود که در هنگام فرآیند آموزش، پارامترهای شبکه طوری تعیین می‌شوند که منحنی خطای آموزش و همچنین خطای آزمون روند کاهشی داشته باشد. حال اگر در هنگام آموزش وزن‌های شبکه به گونه‌ای تغییر کند که روند کاهشی صحبت‌سنجی مدل، صعودی شود (شکل ۲-ب) آموزش شبکه باید متوقف گردد (آبراهارت، ۲۰۰۴). برای ممانعت از بروز این مشکلات یک راه حل استفاده از تکنیک توقف آموزش است (کولیبالی و همکاران، ۲۰۰۰). در این مقاله مشکل بالا برآشی با استفاده از شاخص‌های عملکرد مدل‌ها و با مشاهده نمودار فرآیند آموزش و آزمون در هر دوره آموزش کنترل شد.



شکل ۲-الف) مراحل آموزش و آزمون در برابر تعداد دوره‌های آموزش، ب) استفاده از تکنیک توقف آموزش.

شاخص‌های ارزیابی مدل‌ها: به‌منظور ارزیابی عملکرد مدل‌ها، از شاخص‌های آماری ضریب تعیین (R^2)^۱، ریشه میانگین مربعات خطا (RMSE)^۲ و میانگین قدر مطلق خطا (MAE)^۳ استفاده شد.

- 1- Determination Coefficient
- 2- Root Mean Square Error
- 3- Mean Absolute Error

$$R^r = \frac{\left[\sum_{i=1}^n (Q_i^o - \bar{Q}^o)(Q_i^e - \bar{Q}^e) \right]}{\sum_{i=1}^n (Q_i^o - \bar{Q}^o) \sum_{i=1}^n (Q_i^e - \bar{Q}^e)} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_i^o - Q_i^e| \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i^o - Q_i^e)^2} \quad (5)$$

Q_o : دبی مشاهده‌ای، Q_e : دبی تخمینی توسط مدل‌ها، n : تعداد داده‌ها، \bar{Q}^o : میانگین دبی‌های مشاهده‌ای و \bar{Q}^e : میانگین دبی‌های محاسباتی و همگی در مقیاس ماهانه هستند. همچنین از شانص گرافیکی خط ۴۵ درجه که میزان خطای برآورده بین دبی‌های مشاهده‌ای و دبی‌های تخمینی را به صورت کیفی نشان می‌دهد، نیز استفاده شد.

تعیین تعداد تاخیرهای مناسب برای متغیرهای ورودی: به این منظور، از نمودارهای ضرایب خود همبستگی^۱ استفاده گردید (عقیل و همکاران، ۲۰۰۶). با رسم این نمودارها، تعداد ماههای تاخیر برای متغیرهای ورودی یعنی دبی، بارندگی، دمای حداقل و میانگین، در محدوده باند ۹۵ درصد اطمینان، ۲ به دست آمد، بنابراین این چهار متغیر در زمان t به همراه دو تاخیر زمانی برای هر یک، ۱۲ متغیر ورودی در این مرحله هستند که عبارتند از:

$$\left[\begin{array}{l} Q_{(t)}, Q_{(t-1)}, Q_{(t-2)}, R_{(t)}, R_{(t-1)}, R_{(t-2)}, T \min_{(t)}, T \min_{(t-1)}, T \min_{(t-2)}, \\ T \text{mean}_{(t)}, T \text{mean}_{(t-1)}, T \text{mean}_{(t-2)} \end{array} \right]$$

لازم به ذکر است که برتری متغیرهای هواشناسی و هیدرولوژیکی به عنوان متغیرهای ورودی در پژوهش (انوری، ۲۰۰۸) مورد بررسی قرار گرفته بود.

روش‌های انتخاب ورودی مدل‌ها: در این مقاله از ۳ روش ذیل برای انتخاب ورودی‌ها استفاده گردید:

1- Auto Correlation Function (ACF)

- روش آنالیز مؤلفه‌های اصلی^۱: این آنالیز تکنیکی برای کم کردن تعداد داده‌هاست، به طوری که یک مجموعه شامل p متغیر وابسته را به مجموعه‌ای کوچک‌تر شامل m مؤلفه مستقل تبدیل می‌کند (سیلان و ازبای، ۲۰۰۷). با فرض بردار X شامل p متغیر (x_1, x_2, \dots, x_p) ، مشاهده و بردار میانگین \bar{x} ، ابتدا متغیرهای ورودی استاندارد شده و ماتریس واریانس - کواریانس (Σ) به دست می‌آید. از این ماتریس مقادیر ویژه (λ) و بردارهای ویژه (A) محاسبه و در نهایت مؤلفه‌های اصلی را می‌توان با استفاده از فرمول زیر به دست آورد:

$$PC_i = a_{i1}X_1 + a_{i2}X_2 + \dots + a_{ip}X_p \quad (6)$$

که PC_i : معرف مؤلفه موردنظر، a_{ij} : درایه‌های بردار ویژه مربوطه و X_i : نیز متغیرهای اولیه می‌باشد.

- انتخاب متغیرهایی با حداقل ضریب در هر مؤلفه: با محاسبه ضریب همبستگی بین مؤلفه‌ها و متغیرهای ورودی مطابق رابطه (7)، متغیری که بیشترین همبستگی را با مؤلفه موردنظر دارد، حداقل ضریب را در آن مؤلفه به خود اختصاص می‌دهد (موریسون، ۱۹۸۶) که از آن می‌توان در انتخاب ورودی مدل‌ها استفاده کرد.

$$R(PC_i, x_j) = a_{ij} \sqrt{\frac{\lambda_i}{\sigma_{ii}}} \quad (7)$$

در رابطه بالا a_{ij} : عناصر بردار ویژه مؤلفه i ام (PC_i)، x_j متغیر j ام، λ_i مقدار ویژه و R ضریب همبستگی است.

- روش همبستگی دودویی (CC)^۲: در این روش با محاسبه ضریب همبستگی بین متغیرهای پیشگو و پیش‌بینی، متغیرهایی که سطح معنی‌داری این ضریب، کمتر از 0.05 باشد به عنوان ورودی مدل‌ها انتخاب می‌شوند.

کدگذاری مدل‌های ورودی: این مرحله شامل ۴ کدگذاری ذیل است:

- مدل ورودی ۱: عبارتست از مدل شبکه عصبی - برای پیش‌بینی جریان ۱ ماه بعد - با ورودی‌های روش آنالیز مؤلفه‌های اصلی^۳ که با کد NN-1-PCA نام‌گذاری شده است. در این مدل با استفاده از تکنیک PCA، ۵ مؤلفه اول که $94/5$ درصد کل واریانس متغیرها را داراست، به عنوان ورودی مدل‌ها انتخاب گردید (جدول ۱).

1- Principal Component Analysis

2- Cross Correlation

3- Principal Component Analysis

جدول ۱- مقادیر ویژه و درصد واریانس مربوط به هر مؤلفه.

مؤلفه	واریانس تجمعی (درصد)	واریانس (درصد)	مقادیر ویژه
۱	۵۷/۷۴	۵۷/۷۴	۹۳/۶
۲	۸۱/۸۷	۲۴/۱۲	۲/۸۹
۳	۸۷/۲۶	۵/۳۹	۰/۶۵
۴	۹۱/۴۴	۴/۱۸	۰/۵
۵	۹۴/۴۹	۳/۰۵	۰/۳۷
۶	۹۷/۱۵	۲/۶۵	۰/۳۲
۷	۹۸/۸۳	۱/۶۹	۰/۲
۸	۹۹/۶۲	۰/۷۸	۰/۰۹
۹	۹۹/۸۱	۰/۲۰	۰/۰۲

- مدل ورودی ۲: عبارت است از مدل شبکه عصبی- برای پیش‌بینی جریان ۱ ماه بعد- با ورودی‌هایی که از حداقل همبستگی با هر مؤلفه به دست آمده و با کد NN-1-Var PCA نام‌گذاری شده است: در این مدل متغیرهای $Q_{(t-1)}$, $Q_{(t-2)}$, $R_{(t-1)}$, $R_{(t-2)}$, T_{mean} ، $Q_{(t)}$ به عنوان متغیرهای ورودی مدل‌ها انتخاب گردید.

- مدل ورودی ۳: عبارت است از مدل شبکه عصبی- برای پیش‌بینی جریان ۱ ماه بعد- با ورودی‌هایی که از روش CC محاسبه و با کد NN-1-CC نشان داده می‌شود و در آن برای پیش‌بینی $Q_{(t+1)}$ ، ورودی $Q_{(t-2)}$ ، برای پیش‌بینی $Q_{(t+2)}$ ، ورودی $Q_{(t-1)}$ و برای پیش‌بینی $Q_{(t+3)}$ ، ورودی $Q_{(t)}$ از لیست ۱۲ متغیر اصلی حذف گردید.

- مدل ورودی ۴: عبارت است از مدل شبکه عصبی- برای پیش‌بینی جریان ۱ ماه بعد- با تمام متغیرهای ورودی که با کد NN-1-TV نشان داده می‌شود.

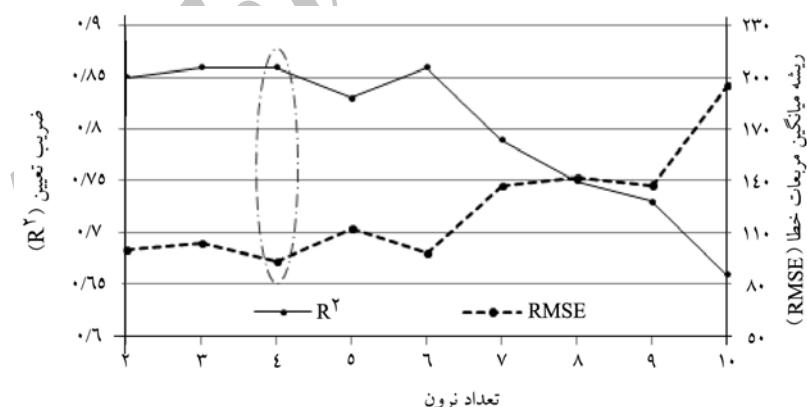
انتخاب دوره آموزش و آزمون: دوره‌های آموزش و آزمون مدل‌ها به ترتیب شامل تعداد ۳۰۰ و ۵۰ الگوی مشاهده‌ای می‌باشد که به دلیل لزوم مشارکت الگوهای متنوع‌تر و خشکسالی‌ها در فرآیند آموزش، این دوره به صورت ناپیوسته انتخاب گردید.

نتایج و بحث

در این بخش نتایج اجرای مدل‌های ANN برای پیش‌بینی‌های ۱ تا ۳ ماه بعد جریان رودخانه کارون ارایه و تأثیر داده‌های SOI بر عملکرد مدل منتخب بررسی می‌شود.

نتایج عملکرد مدل‌های ANN در پیش‌بینی ۱ ماه بعد جریان

- تعیین بهترین مدل ورودی با روش اعتبارسنجی حذفی (CV)^۱: روش کار در این مرحله به این صورت است که داده‌های اولیه، به M مجموعه (در اینجا $M=7$ شامل مجموعه‌های جدول ۲) تقسیم شد و هر بار $M-1$ مجموعه برای آموزش و یک مجموعه باقی‌مانده برای ارزیابی مدل استفاده گردید این امر M بار تکرار شد به طوری که هر یک از M مجموعه برای صحبت‌سنجی استفاده شد. در نهایت عملکرد هر یک از مدل‌های ورودی مطابق جدول ۲ با هم مقایسه گردید. مطابق این جدول، تمامی مدل‌ها طی دوره ۱۳۷۴-۷۸ بهترین عملکرد را داشتند، بنابراین این دوره به عنوان دوره پیش‌بینی ثابت شد. از سوی دیگر مدل NN-1-TV در مقایسه با سایر مدل‌ها، بهترین عملکرد را در مراحل آموزش و آزمون داشته و به عنوان مدل منتخب در پیش‌بینی جریان ۱ ماه بعد شناخته شد. همچنین منحنی شاخص‌های عملکرد مدل منتخب NN-1-TV به ازای تعداد ۲ تا ۱۰ نرون لایه پنهان در شکل ۳ آمده که در آن وجود ۴ نرون در لایه پنهان، کمترین خطای برای این مدل نتیجه می‌دهد.



شکل ۳- اثر تعداد نرون‌های لایه پنهان بر روی شاخص‌های R^2 و RMSE برای مدل NN-1-TV

1- Cross-Validation

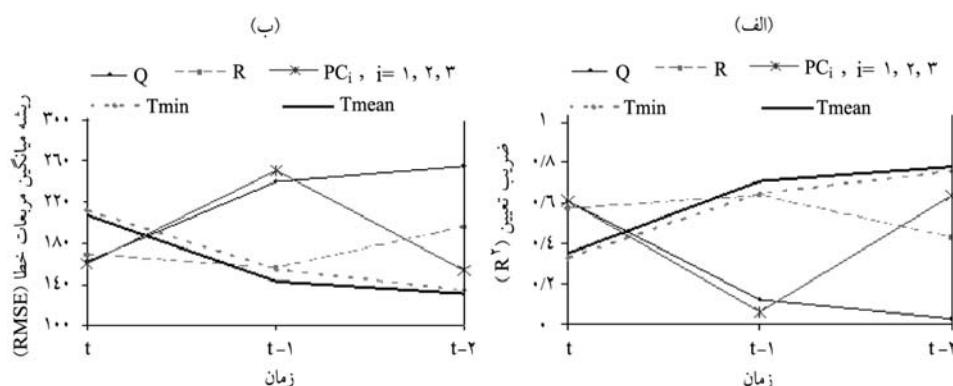
مجله پژوهش‌های حفاظت آب و خاک جلد (۱۸)، شماره (۱) ۱۳۹۰

جدول ۲- نتایج روش اعتبارسنجی (CV) برای انتخاب بهترین مدل ورودی در ANN

شانص‌ها	آزمون	مجموعه‌های	مدل‌های ورودی	NN-۱-Var PCA	NN-۱-PCA
		۵۷-۱۳۵۳	۱۳۴/۸۷	۱۵۵/۳۲	۱۴۵/۸۹
		۶۱-۱۳۵۷	۱۰۷/۴۲	۱۰۲/۷۲	۱۱۸/۳
		۶۵-۱۳۶۱	۱۴۶/۹۷	۱۴۷/۷	۱۵۵/۸۶
RMSE	۶۹-۱۳۶۵	۹۷/۳۶	۱۱۶/۵۸	۱۱۵/۳۲	۱۱۹/۷۸
		۷۴-۱۳۶۹	۱۵۵/۴۲	۱۸۲/۸۶	۱۵۹/۸۵
		۷۸-۱۳۷۴	۹۳/۸۹	۱۴۳/۵۷	۱۰۰/۳
		۸۲-۱۳۷۸	۱۳۴/۶۵	۱۳۸/۸۳	۱۸۴/۷۴
میانگین		۱۲۴/۳۷	۱۴۱/۰۸	۱۴۰/۰۴	۱۳۹/۷۶
		۵۷-۱۳۵۳	۰/۷	۰/۶۸	۰/۶۵
		۶۱-۱۳۵۷	۰/۸۶	۰/۸۷	۰/۸۴
		۶۵-۱۳۶۱	۰/۷	۰/۶۹	۰/۶۵
R ^r	۶۹-۱۳۶۵	۰/۸۱	۰/۷۵	۰/۷۴	۰/۷۱
		۷۴-۱۳۶۹	۰/۷۸	۰/۷۸	۰/۷۴
		۷۸-۱۳۷۴	۰/۸۶	۰/۸۵	۰/۸۳
		۸۲-۱۳۷۸	۰/۵۷	۰/۵۱	۰/۴۸
میانگین		۰/۷۵	۰/۷۳	۰/۷۸	۰/۷۲
		۵۷-۱۳۵۳	۹۲/۴۵	۸۶/۹۳	۹۵/۷۱
		۶۱-۱۳۵۷	۷۵/۴۴	۷۸	۷۱/۷۱
		۶۵-۱۳۶۱	۹۶/۶۵	۱۰۱/۴۸	۱۱۱/۶۵
MAE	۶۹-۱۳۶۵	۶۷/۲	۷۱/۵۴	۷۱/۰۳	۷۱/۷۱
		۷۴-۱۳۶۹	۸۵/۱۴	۱۱۶/۵۵	۱۰۷/۵۴
		۷۸-۱۳۷۴	۶۰/۶۳	۸۴/۶۳	۶۷/۸۹
		۸۲-۱۳۷۸	۷۶/۶۵	۸۷/۶۷	۹۸/۳۹
میانگین		۷۹/۱۷	۸۸/۱۱	۸۹/۱۳	۸۷/۱۳

- بررسی نقش منفرد و ترکیبی متغیرهای ورودی بر ANN در پیش‌بینی ۱ ماه بعد جریان: برای بررسی نقش هر یک از متغیرهای ورودی و میزان اهمیت آن‌ها، ابتدا هر کدام از متغیرها و مؤلفه‌های اصلی به طور جداگانه در مدل‌سازی وارد شدند. سپس ترکیباتی از هر متغیر و تاخیرات آن به عنوان ورودی مدل ANN قرار گرفت. نتایج این ورودی‌ها مطابق شکل ۴ (الف و ب) نشان می‌دهد که

متغیرهای T_{mean} و T_{min} در زمان $t-1$ و $t-2$ و همچنین $R_{(t-1)}$, $Q_{(t)}$, $R_{(t)}$ بیشترین تأثیر را در خروجی مدل ANN دارند. در این میان متغیرهای دمایی مدل در مرتبه‌های اول تا چهارم و بارندگی و دبی در مرتبه‌های بعدی قرار می‌گیرند (جدول ۳).



شکل ۴- بررسی تأثیر دمای حداقل و میانگین، بارش، دبی و مؤلفه‌های اصلی (PC) بر ANN (الف) و (ب) R^* و $RMSE$

از سوی دیگر با توجه به کوهستانی بودن حوضه کارون و وجود بارش‌های برفی در ماههای سرد سال، اهمیت بیشتر متغیرهای دمایی حوضه به دلیل تأثیر بر نوع بارش، نیز قابل توجیه است.

جدول ۳- ۶ متغیر با تأثیر بیشتر بر عملکرد مدل ANN

$T_{mean}_{(t-1)}$	$T_{min}_{(t-1)}$	$T_{mean}_{(t-1)}$	$T_{min}_{(t-1)}$	$R_{(t-1)}$	$Q_{(t)}$	$R_{(t)}$	ورودی‌ها	شاخص‌ها
۰/۷۸	۰/۷۶	۰/۷۱	۰/۶۵	۰/۶۴	۰/۶۱	۰/۵۷	R^*	
۱۳۰/۷۷	۱۳۴/۰۲	۱۴۲/۹۴	۱۵۵/۱۴	۱۵۶/۴	۱۶۲/۱	۱۶۸/۹		RMSE

پس از بررسی نقش هر یک از متغیرهای ورودی و شناسایی متغیرهای مؤثرتر مطابق جدول ۳، عملکرد هر یک از مؤلفه‌های اصلی را می‌توان تفسیر کرد. بررسی نقش هر یک از مؤلفه‌ها با شاخص‌های ارزیابی، نشان داد که مؤلفه اول نقش خوبی در عملکرد ANN داشت زیرا این مؤلفه $57/7$ درصد واریانس کل متغیرها را شامل شده و از طرف دیگر با توجه به جدول ۴ متغیرهای مؤثرتر بر عملکرد مدل ANN، بیشترین ضریب را در این مؤلفه دارا هستند.

مؤلفه دوم به رغم دارا بودن ۲۴/۱۲ درصد واریانس متغیرها، به دلیل این که در آن متغیرهایی که به تنها‌یی در مدل شبکه عصبی نقش مؤثری نداشتند (دیگر زمان‌های $t-2$ و $t-1$) دارای بیشترین ضریب می‌باشند، در نتیجه عملکرد ضعیفی از خود نشان می‌دهد. به همین ترتیب برای مؤلفه‌های دیگر نیز همین استدلال قابل بیان است.

جدول ۴- ضرایب متغیرها در ۵ مؤلفه اول.

متغیرها	مؤلفه اول	مؤلفه دوم	مؤلفه سوم	مؤلفه چهارم	مؤلفه پنجم	متغیرها
	=۵۷/۷ درصد	=۲۴/۱ درصد	=۵/۴ درصد	=۴/۲ درصد	=۳/۱ درصد	= مؤلفه پنجم
Tmean _(t-۲)	-۰/۳۴	-۰/۱۷	-۰/۲۹	۰/۰۱	-۰/۳۴	-۰/۳۴
Tmean _(t-۱)	-۰/۰۵	۰/۱	-۰/۱۸	-۰/۰۲	-۰/۰۵	-۰/۰۵
Tmean _(t)	۰/۲۴	۰/۳۴	۰/۰۳	۰/۰۳	۰/۲۴	۰/۲۴
Tmin _(t-۲)	-۰/۴۲	-۰/۳۴	-۰/۳	۰/۰۲	-۰/۴۲	-۰/۴۲
Tmin _(t-۱)	-۰/۰۷	۰/۱	-۰/۲۱	۰/۰۴	-۰/۰۷	-۰/۰۷
Tmin _(t)	۰/۲۶	۰/۳۳	-۰/۰۴	۰/۰۱	۰/۲۶	۰/۲۶
R _(t-۲)	-۰/۷۲	۰/۲۷	۰/۱۹	-۰/۱۷	-۰/۷۲	-۰/۷۲
R _(t-۱)	-۰/۰۳	۰/۳	-۰/۳۳	۰/۶۹	-۰/۰۳	-۰/۰۳
R _(t)	۰/۱۷	۰/۲۴	-۰/۵	-۰/۵۶	۰/۱۷	۰/۱۷
Q _(t-۲)	-۰/۰۹	۰/۰۳	۰/۰۲	-۰/۳۴	-۰/۰۹	-۰/۰۹
Q _(t-۱)	-۰/۰۹	۰/۱۷	-۰/۲۶	۰/۲۲	-۰/۰۹	-۰/۰۹
Q _(t)	۰/۱	۰/۲۷	-۰/۵۳	-۰/۱	۰/۱	۰/۱

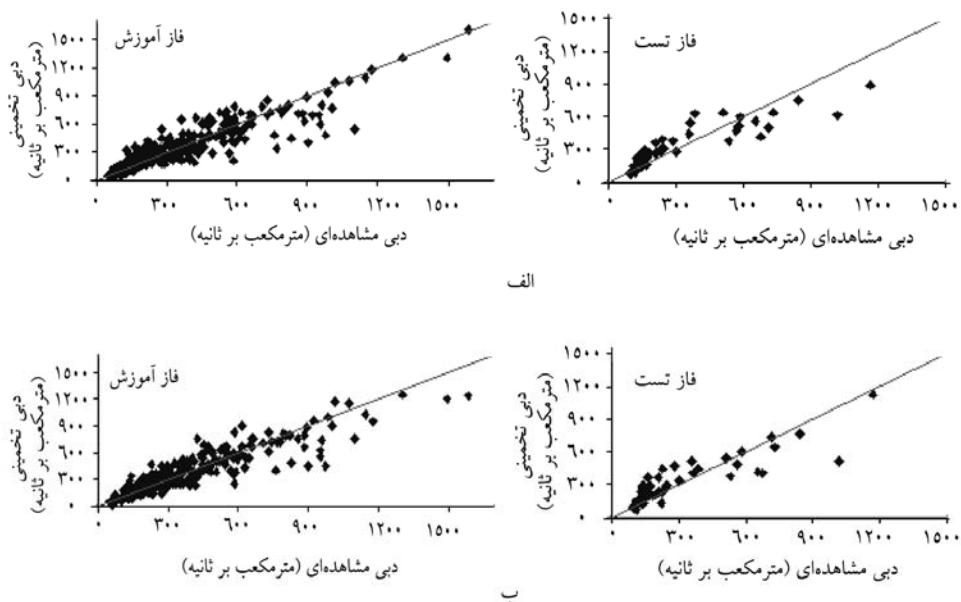
بررسی اثر SOI در ورودی مدل ANN برای پیش‌بینی جریان ۱ ماه بعد: اثر شاخص اقلیمی SOI در زمان‌های $t-1$ و $t-2$ که به ترتیب با $SOI_{(1)}$ و $SOI_{(2)}$ نشان داده شده است به صورت منفرد و ترکیبی بر عملکرد مدل ANN با مدل ورودی منتخب NN-TV-1-NN بررسی شد (جدول ۵).

جدول ۵- تأثیر $SOI_{(t)}$ به صورت منفرد و ترکیبی بر نتایج بهترین مدل ANN

آموزش						آزمون			کل		مدل ورودی
RMSE	R ²	MAE	RMSE	R ²	MAE	RMSE	R ²	MAE			
۹۲/۱۹	۰/۸۸	۶۰/۸۶	۹۳/۸۹	۰/۸۶	۶۰/۶۳	۹۲/۴۴	۰/۸۷	۶۰/۸۳	NN-۱-TV		
۸۵/۱۹	۰/۸۹	۵۰/۹۶	۱۰۸/۳۹	۰/۸۳	۷۲/۳۵	۸۸/۸۸	۰/۸۸	۵۴/۰۲	NN-۱-TV+ $SOI_{(1,2)}$		
۱۰۰/۸۱	۰/۸۵	۶۰/۹۰	۱۰۶/۵۷	۰/۸۷	۶۵/۱۸	۱۰۱/۶۶	۰/۸۵	۶۱/۵۱	NN-۱-TV+ $SOI_{(1,2)}$		
۸۲/۸۴	۰/۹۰	۵۷/۷۷	۹۹/۹۰	۰/۸۸	۶۳/۲۱	۸۵/۴۸	۰/۸۹	۵۸/۵۴	NN-۱-TV+ $SOI_{(1)}$		
۱۰/۱	-۲/۳	۵/۱	-۶/۴	-۲/۳	-۴/۳	۷/۵	-۲/۳	۳/۸	درصد تأثیر		
۱۰۳/۰۰	۰/۸۵	۶۵/۳۸	۹۴/۴۸	۰/۸۸	۷۰/۶۲	۱۰۱/۸۳	۰/۸۵	۶۷/۱۳	NN-۱-TV+ $SOI_{(1)}$		
۱۱۴/۸۰	۰/۸۱	۶۷/۲۱	۸۹/۴۳	۰/۸۸	۶۲/۳۱	۱۱۱/۵۲	۰/۸۲	۶۷/۳۷	NN-۱-TV+ $SOI_{(2)}$		

نتایج جدول ۵ بیانگر آن است که شاخص $SOI_{(t)}$ به عنوان متغیر ورودی بر پیش‌بینی جریان ۱ ماه بعد اثر داشته به طوری که بیشترین تأثیر آن هنگامی است که این متغیر به صورت $SOI_{(t)}$ در مدل‌سازی وارد می‌شود و توانسته مقادیر شاخص‌های ارزیابی RMSE، R² و MAE را به ترتیب به میزان ۷/۵ و ۲/۳ و ۳/۸ بهبود بخشد.

عملکرد مدل‌های ANN در پیش‌بینی‌های ۲ و ۳ ماه بعد جریان و بررسی تأثیر شاخص $SOI_{(t)}$: برای پیش‌بینی‌های ۲ و ۳ ماه بعد جریان، ۴ مدل ورودی شبکه عصبی با تعداد نمونه‌های بین ۲ تا ۱۰ عدد و کدبندی‌هایی که در قبل به آن اشاره شد اجرا، مدل منتخب شناسایی و اثر شاخص $SOI_{(t)}$ به عنوان و روی بر آن بررسی گردید. نتایج مدل‌سازی بیانگر آن بود که در پیش‌بینی‌های ۲ ماه بعد جریان با استفاده از مدل‌های ANN، مدل ورودی NN-۲-TV بهترین عملکرد را داشته است. در نتیجه، اثر شاخص $SOI_{(t)}$ به عنوان ورودی بر این مدل بررسی و مشاهده شد که در زمان $t=1$ این متغیر باعث ارتقاء نتایج ANN می‌شود. اضافه نمودن متغیر $SOI_{(1)}$ به مدل منتخب NN-۲-TV، مقادیر شاخص‌های ارزیابی RMSE، R² و MAE را به ترتیب به میزان ۵، ۲/۵ و ۴/۹ درصد بهبود بخشد. این مقادیر بهبود، به طور متوسط برای دوره‌های آموزش و آزمون مدل‌ها به دست آمد. نتایج مدل‌های NN-۲-TV + $SOI_{(1)}$ و NN-۲-TV در شکل ۵ ارایه شده است.



شکل ۵- نتایج مدل‌های شبکه عصبی در مراحل آموزش و آزمون: (الف) مدل $NN-2-TV$

(ب) مدل $NN-2-TV + SOI_{(1)}$

در جدول ۶ نیز نتایج اجرای مدل ANN برای پیش‌بینی ۳ ماه بعد جریان، ارایه شده و در ادامه اثر شاخص اقلیمی SOI بر عملکرد مدل‌ها بررسی گردید.

جدول ۶- نتایج پیش‌بینی ۳ ماه بعد جریان به‌وسیله مدل‌های ANN

مدل ورودی	آموزش						آزمون						کل
	RMSE	R ²	MAE										
NN-۳-PCA	۱۷۵/۷۸	۰/۰۵	۱۲۵/۲۱	۱۸۶/۰۳	۰/۰۴	۱۴۶/۰۰	۱۷۴/۰۲	۰/۰۶	۱۲۱/۷۵	۱۷۵/۷۸	۰/۰۵	۱۲۵/۲۱	
NN-۳-Var PCA	۱۷۷/۷۲	۰/۰۴	۱۲۲/۰۷	۱۶۷/۲۴	۰/۰۶	۱۲۳/۰۱	۱۷۹/۴۱	۰/۰۳	۱۲۱/۹۱	۱۷۷/۷۲	۰/۰۴	۱۲۲/۰۷	
NN-۳-CC	۱۳۵/۷۰	۰/۰۷۳	۸۸/۱۱	۱۳۸/۸۹	۰/۰۷۳	۹۱/۸۹	۱۳۵/۱۶	۰/۰۷۳	۷۸/۴۸	۱۳۵/۷۰	۰/۰۷۳	۸۸/۱۱	
NN-۳-TV	۱۳۰/۸۳	۰/۰۷۵	۹۰/۲۳	۱۳۶/۸۶	۰/۰۷۳	۱۰۸/۶۲	۱۲۹/۸۰	۰/۰۷۶	۸۷/۱۶	۱۳۰/۸۳	۰/۰۷۵	۹۰/۲۳	
NN-۳-TV+SOI ₍₁₎	۱۲۴/۷۱	۰/۰۷۷	۸۱/۰۰	۱۲۷/۵۳	۰/۰۷۶	۸۹/۳۵	۱۲۴/۲۴	۰/۰۷۸	۸۰/۱۹	۱۲۴/۷۱	۰/۰۷۷	۸۱/۰۰	
درصد تأثیر	۴/۷	-۲/۷	۹/۷	۶/۸	-۴/۱	۱۷/۷	۴/۳	-۲/۶	۸/۰	۴/۷	-۲/۷	۹/۷	

در این جدول با توجه به شاخص‌های ارزیابی مدل، از بین ۴ مدل ورودی، مدل $NN-3-TV$ به عنوان مدل منتخب شناخته شد، همچنین شاخص اقلیمی SOI باعث ارتقاء عملکرد آن شده است. نتایج این پژوهش نشان داد که بهترین مدل‌های ANN در پیش‌بینی جریان رودخانه عملکرد خوبی داشته و سایر پژوهش‌های انجام شده نیز این امر را تأیید می‌نمایند (زیلاند و همکاران، ۱۹۹۹؛ کولیبالی و همکاران، ۲۰۰۰؛ راید و همکاران، ۲۰۰۴؛ ANN در تمامی مدل‌های ANN تعداد ۲ تا ۶ نرون در لایه پنهان، بهترین عملکرد را به دنبال داشته است که این مهم با پژوهش‌های دیگر نیز مشابه است زیادی دارد (عقیل و همکاران، ۲۰۰۶؛ وانگ و همکاران، ۲۰۰۶). سیگنال‌های بزرگ مقایسه همانند شاخص اقلیمی SOI نیز در پیش‌بینی جریان رودخانه کارون اثر مثبتی به همراه داشت که تأثیرگذاری این شاخص بر فرآیندهای بارش-رواناب در پژوهش‌های گارن (۱۹۹۸) و کورتیس و همکاران (۲۰۰۱) نیز اثبات شده است. بررسی عملکرد مدل‌های ANN به تفکیک ماههای خشک و تر، نشان داد که به دلیل زیادتر بودن الگوهای خشک و معتدل در سری تاریخی فرآیند آموزش، این مدل‌ها در در دوره‌های خشک و معتدل قابلیت پیش‌بینی بهتری نسبت به دوره‌های تر سالی داشته‌اند، لازم به ذکر است که برای انجام این پیش‌بینی‌ها، عملکرد سایر مدل‌ها همانند سیستم‌های استنتاجی نروفازی تطبیقی ($ANFIS$)^۱ هم مبنای مقایسه قرار گرفت که مدل‌های ANN نتایج بهتری را نشان دادند (انوری، ۲۰۰۸). همچنین با بررسی نتایج مشاهده شد که در عملکرد مدل‌های شبکه عصبی، متغیرهای دمایی حوضه (دمای میانگین و حداقل) نقش مهم‌تری نسبت به سایر متغیرها دارند که این مهم نیز با توجه به کوهستانی بودن حوضه کارون و بارش برف در منطقه از نظر فیزیکی قابل توجیه است.

نتیجه‌گیری

در این مقاله جریان ۱ تا ۳ ماه بعد رودخانه کارون در محل ایستگاه هیدرومتری پل شالو با استفاده از مدل شبکه عصبی مصنوعی (ANN) پیش‌بینی و اثر شاخص اقلیمی نوسانات جنوبی (SOI) بر عملکرد مدل یاد شده بررسی گردید. نتایج بدست آمده از اجرای تکنیک اعتبارسنجی حذفی (CV) نشان داد که مدل ورودی $NN-i-TV$ ($i=1, 2, 3$) در مقایسه با ۳ مدل ورودی دیگر بهترین عملکرد را داشته و به عنوان مدل منتخب شناسایی شد، همچنین استفاده از تکنیک نامبرده نشان داد که مدل منتخب نه تنها در سال‌های مورد آزمون (۱۳۷۴-۷۸) بهترین عملکرد را داشته بلکه در دوره‌های دیگر

1- Adaptive-Network-Based Fuzzy Inference Systems

نیز قابلیت تعمیم بهتری نسبت به سایر مدل‌های ورودی ارایه کرده است. بررسی نقش منفرد و ترکیبی انواع متغیرهای ورودی بر عملکرد مدل‌های ANN، نشان داد که متغیرهای دمای میانگین و حداقل در منطقه مطالعاتی، بیشترین تأثیر را در عملکرد مدل‌های ANN داشتند که این نتیجه هم از اجرای مدل‌های ANN و هم با استفاده از تکنیک آنالیز مؤلفه‌های اصلی (PCA) به دست آمد. همچنین این امر با توجه به کوهستانی بودن حوضه کارون و وجود سطوح پوشیده از برف در ارتفاعات آن، از نظر فیزیکی و فیزیوگرافی حوضه نیز قابل استناد است. نتایج پژوهش نشان داد که وجود شاخص اقلیمی SOI به عنوان ورودی مدل‌های ANN، عملکرد این مدل‌ها را به طور متوسط ۵ درصد برای RMSE و ۴ درصد برای R^2 بهبود بخشیده است.

منابع

- 1.Abrahart, R.J. 2004. Neural Network Modelling: Basic Tools and Broader Issues School of Geography, University of Nottingham, UK, Pp: 1-23.
- 2.Alcazar, J., Palau, A., and Vega-Garcí, C. 2008. A neural net model for environmental flow estimation at the Ebro River Basin, Spain. *J. Hydrol.* 349: 44-55.
- 3.Anvari, S. 2008. Advancement of Intelligent Models for Streamflow Forecasting Using Distributed Climatic Data and Snow Cover. M.Sc. Thesis. Agriculture faculty, tarbiat modares university, 145p. (In Persian)
- 4.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. *J. Environ. Manag.* 10: 1-9.
- 5.ASCE. 2000. Task Committee on Application of Artificial Neural Networks in Hydrology. Artificial neural networks in hydrology, I: preliminary concepts. *J. Hidrol. Eng.* 5: 2. 115-123.
- 6.Ceylan, R., and Ozbay, Y. 2007. Comparison of FCM, PCA and WT techniques for classification EC G arrhythmias using artificial neural network. *Expert Syst with Appl.* 33: 286-295.
- 7.Coulibaly, P., Anctil, F., and Bobée, B. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *J. Hydrol.* 230: 244-257.
- 8.Curtis, S., Piechota, T.C., and Dracup, J.A. 2001. Evaluation of tropical and extratropical precipitation anomalies during the 1997-1999 ENSO cycle. *Int. J. Climatol.* 21: 961-971.
- 9.Demirel, M.C., Venancio, A., and Kahya, E. 2009. Flow forecast by SWAT model and ANN in Pracana basin, Portugal. *Advances in Eng. Soft.* 40: 467-473.

- 10.Garen, D.C. 1998. ENSO indicators and long-lead climate outlooks: Usage in seasonal streamflow volume forecasting in the western united states. American Geophysical Union, Fall meeting, San Francisco, California, 79: 1-7.
- 11.Jain, A., and Kumar, A.M. 2006. Hybrid neural network models for hydrologic time series forecasting. *Appl. Soft. Comput.* 6: 295-306.
- 12.Morrison, D.F. 1986. Multivariate Statistical Methods. 2nd Fed. Auckland, McGraw-Hill Book Company, Pp: 266-302.
- 13.Nazemosadat, S.M.J. 1999. Investigation of ElNino-Southern Oscilation effect on autumn rainfall in Iran. The second conference on climate change, Meteorological Organization. Tehran, Iran, Pp: 252-265. (In Persian)
- 14.Raid, S., Mania, J., Bouchaou, L., and Najjar, Y. 2004. Rainfall-Runoff model using artificial neural networks approaches. *Math. Computer Modell.*, 40: 839-846.
- 15.Sedki, A., Ouazar, D., and El Mazoudi, E. 2009. Evolving neural network using real coded genetic algorithm for daily rainfall-runoff forecasting. *Expert Syst with Applicat.* 36: 4523-4527.
- 16.Walker, G.T. 1923. Correlation in seasonal variations of weather, A preliminary study of word weather. *Mem-Inddian meteor. Dept.* 24: 75-131.
- 17.Wang, W., Van Gelder, P.H.A.J.M., Vrijling, J.K., and Ma, J. 2006. Forecasting daily streamflow using hybrid ANN models. *J. Hydrol.* 324: 383-399.
- 18.Zealand, C.M., Burn, D.H., and Simonovic, S.P. 1999. Short term streamflow forecasting using artificial neural networks. *J. Hydrol.* 214: 32-48.



J. of Water and Soil Conservation, Vol. 18(1), 2011
www.gau.ac.ir/journals

Stream flow forecast using ANN models and investigation of model's performance by SOI inputs

S. Anvari Tafti¹, B. Saghafian² and *S. Morid³

¹Ph.D. Student, Dept. of Water Structure, Tarbiat Modares University,

²Professor of Soil and Water Conservation Research Institute,

³Associate Prof., Dept. of Water Structure, Tarbiat Modares University

Received: 2009/12/16; Accepted: 2010/12/11

Abstract

Traditional modeling techniques such as regression and time series, often fail in the modeling of nonlinear hydrological processes like stream flow forecasts. Therefore, nonlinear techniques such as Artificial Neural Networks (ANNs) could be more efficient tools for forecasting these processes. This study aims to forecast the next 1- to 3-months flow of Karoon basin. For these forecasts, first four input models of ANN have been constructed by Principal Component Analysis (PCA) and Cross Correlation (CC) techniques. Then, using Cross Validation (CV) method and model performance evaluation indices like determination coefficient, mean absolute error and root mean square error, the best input model was identified. Also, to determine the effectiveness of each input variables and principal components, their single and compound role on ANN performance was investigated. Finally, the effect of SOI index at t, t-1 and t-2 times on the best model performance was evaluated. Results showed that thermal variables have the greatest influence on Karoon basin streamflow. Also, SOI index as input variable can improve the performance of model averagely about 5% in MAE and RMSE and 4% in R² values.

Keywords: Stream flow forecast, ANN, SOI, Karoon basin

* Corresponding Author; Email: morid_sa@modares.ac.ir