

ارزیابی شاخص های خشکسالی در پیش‌بینی خشکسالی با استفاده از

شبکه‌های عصبی مصنوعی و روش‌های رگرسیونی

کیارش باقرزاده چهره^۱ و هادی تشكربی بهشتی^۱

۱- گروه آبیاری و زهکشی، شرکت مهندسی مشاور طوس آب، مشهد، ایران

(Kiarash_bch@yahoo.com, 09125344330)

چکیده

خشکسالی از وقایع مخرب طبیعی است که بیشترین صدمات را به منابع آبی وارد می‌نماید. پیش‌بینی خشکسالی می‌تواند نقش مهمی در مدیریت این منابع و بهره‌برداری بهینه از آنها در چنین شرایطی ایفا کند. این تحقیق تلاشی است برای پیش‌بینی خشکسالی با استفاده تکنیک شبکه‌های عصبی مصنوعی (ANNs)^۱ و شاخص‌های خشکسالی (توابع پیوسته ای از بارش که درجه خشکی را در هر دوره زمانی نشان می‌دهند). در این راستا، شاخص‌های استفاده شده سری زمانی مقادیر متغیر شاخص‌های خشکسالی EDI^۲ (شاخص خشکسالی موثر) و SPI^۳ (شاخص بارش استاندارد شده) می‌باشند. پیش‌بینی‌ها با استفاده از ترکیبات مختلفی از سری‌های زمانی بارندگی‌های گذشته، شاخص‌های خشکسالی مذکور در ماههای پیشین انجام گرفت. علاوه بر تعریف شاخص‌ها به عنوان ورودی به شبکه، بارندگی و شاخص‌های اقلیمی SOI^۴ (شاخص نوسان جنوبی) و NAO^۵ (شاخص اطلس شمالی) نیز به شبکه معرفی شد که هیچکدام به اندازه سری زمانی شاخص‌ها موثر نبودند. مدل‌های متعدد زیادی برای هر دو شاخص EDI و SPI با سری‌های زمانی ۱ تا ۱۲ ماهه و با استفاده از آمار چندین ایستگاه بارانسنجی در استان تهران در ایران مورد ارزیابی قرار گرفت. بهترین مدل از بین مدل‌های بررسی شده برای هر دو شاخص، مدلی بود که مقدار متناظر شاخص همان ماه را از سال قبل دربر داشت. نتایج نشان داد که روش بکار رفته تا حدود ۸۰٪ وضعیت شش ماه آینده را بدقتی پیش‌بینی می‌کند. این مقدار برای دوره‌های ۹ و ۱۲ ماهه به ترتیب ۶۸٪ و ۶۰٪ می‌شود. هرچند نتایج مربوط به دو شاخص نزدیک هستند، ولی شدت خطا در SPI بیشتر از EDI است، بطوریکه برای این شاخص بر اساس طبقات تعريف شده از خشکسالی و ترسالی، شاهد اختلاف طبقات خشکسالی پیش‌بینی شده و مشاهدهای تا ۴ طبقه هستیم که در EDI تماماً زیر ۲ طبقه است. مدل نهایی پیش‌بینی می‌تواند برای هشدار خشکسالی‌های قریب الوقوع در ایران مورد استفاده قرار گیرد.

کلمات کلیدی: پیش‌بینی خشکسالی، شاخص‌های خشکسالی، شبکه‌های عصبی مصنوعی، استان تهران، ایران

^۱-Artificial Neural Networks

^۲- Effective Drought Index

^۳- Standard Precipitation Index

^۴- Southern Oscillation Index

^۵- North Atlantic Oscillation Index

مقدمه

پیش‌بینی خشکسالی یکی از موضوعات اصلی تحقیقات در دهه‌های اخیر می‌باشد. بکارگیری مدل‌های مختلف آماری در این زمینه دارای پیشینه طولانی می‌باشد مانند کارهای تحقیقاتی Gabriel and Neumann (1962) و Torranin (1976) که برای پیش‌بینی خشکسالی به ترتیب از مدل‌های مارکوف و همبستگی استفاده نمودند. اما در دهه اخیر تکنیک جدید شبکه‌های عصبی مصنوعی به جمع این مدل‌ها افزوده شده که نتایج بسیار مثبتی از آنها عمدهاً برای پیش‌بینی جریانات هیدرولوژیکی گزارش شده است (ASCE, 2000; Govindaraju and Rao, 2000). Jain و همکاران (1999) شبکه عصبی مصنوعی و مدل سری زمانی ARIMA^۱ را جهت پیش‌بینی جریان ورودی به مخزن حوزه اوریسا هند بکار برdenد. Luk و Sharma (2000) با موفقیت از ANN برای پیش‌بینی دوره‌های کوتاه مدت بارندگی استفاده کردند. Birikundavyi و همکاران (2000) نیز بکارگیری یک مدل تلفیقی ANN در پیش‌بینی جریانات روزانه رودخانه می‌ستاسیبی در کبک را گزارش کردند.

علت رویکرد به ANNs را می‌توان در قابلیت یادگیری و ذخیره‌سازی، پردازش توزیعی اطلاعات، قابلیت تعمیم و مدل‌سازی و پیش‌بینی سری‌های زمانی غیر ایستا و غیرخطی دانست که این ویژگی‌ها می‌تواند آن را در پیش‌بینی های خشکسالی کارآمد سازد (Hornik et al., 1989; Luk et al., 2000). در استفاده از ANNs از مهم‌ترین عواملی که لازم می‌باشد مد نظر قرار گیرد، بکارگیری ورودی‌های موثر بر فرآیند است (Yapo et. al., 1996; Zealand et. Al., 1999). همانگونه که در پیش‌بینی جریان رودخانه‌ها اطلاعات قبلی جریان به عنوان اصلی‌ترین ورودی بکار می‌روند، اطلاعات قبلی خشکسالی نیز لازم است در پیش‌بینی آن مد نظر باشد. یکی از بهترین این عوامل که می‌توانند حاوی اطلاعات قبلی باشند، خود سری زمانی شاخص‌های خشکسالی هستند که در پایش از آنها استفاده می‌گردد و کمتر برای پیش‌بینی بکار رفته است. مرید و همکاران (۱۳۸۲) هفت شاخص از شاخص‌های مطرح خشکسالی را برای استان تهران ارزیابی کردند و نهایتاً EDI را مناسب‌تر یافتند. از این‌رو این شاخص برای اهداف این تحقیق مورد استفاده قرار خواهد گرفت. همچنین در در زمینه پیش‌بینی‌های میان‌مدت و بلندمدت بارش در حوزه‌های آبریز مختلف جهان اثر سیگنال‌های بزرگ مقیاس اقلیمی بطور گسترده‌ای مد نظر بوده است که زهراei و همکاران (۱۳۸۳) به تعدادی از آنها اشاره کرده‌اند.

در این تلاش خواهد شد تا با تکنیک شبکه عصبی و استفاده از سری زمانی شاخص‌های مورد اشاره در بالا، این شاخص‌ها تا فواصل یکسال آتی پیش‌بینی شود و بر اساس آنها نسبت به وضعیت آینده خشکسالی در استان تهران اظهار نظر گردد. همچنین تاثیر بارندگی و سیگنال‌های بزرگ مقیاس اقلیمی با استفاده از شاخص‌های SOI و NAO بر ارتقاء دقت پیش‌بینی‌ها نیز مورد ارزیابی قرار خواهد گرفت.

مواد و روشها

داده‌های بارش

برای این تحقیق شش ایستگاه در سطح استان تهران شامل فیروزکوه، آبعلی، امامه، مهرآباد (تهران)، سیرا و ده‌صومعه کردان (متعلق به وزارت نیرو و سازمان هوشناسی کشور) انتخاب شدند که به اندازه کافی معرف شرایط مختلف اقلیمی استان هستند. در ادامه تقویم آماری دو سری ایستگاه‌ها بر اساس سال‌های میلادی همزمان شدند و دوره آماری ۱۹۶۹-۲۰۰۰ آنها مورد استفاده قرار گرفت.

شاخص‌های SOI و NAO

دو شاخص هوشناسی SOI و NAO در این تحقیق به منظور پیش‌بینی خشکسالی مورد استفاده قرار گرفتند. شاخص نوسانات جنوبی (SOI) بیانگر شدت گرادیان فشار در امتداد شرقی- غربی اقیانوس آرام می‌باشد. این شاخص که میان ویژگی‌های اتمسفری پدیده ENSO می‌باشد، عموماً بر اساس تفاضل مقادیر استاندارد شده فشار هوای سطح آب در داروین استرالیا و جزیره تاهیتی (در نواحی مرکزی اقیانوس آرام) محاسبه می‌گردد. نوسانات اطلس شمالی یک وضعیت از تغییرات آب و هوایی زمستانه نواحی اطلس شمالی، بین آمریکای شمالی تا اروپا و آسیای شمالی می‌باشد. شاخص NAO معیاری است برای نشان دادن شدت آن و از اختلاف فشار در توده اتمسفری بین ناحیه محدود به مرکز پر فشار استوایی و کم فشار قطبی محاسبه می‌شود.

مدرس پور (۱۹۹۵) و کوره پزان (۲۰۰۳) به ترتیب ارتباط این شاخص‌ها را با بارندگی و سالهای خشکسالی در نقاطی از ایران نشان دادند. مقادیر ماهانه شاخص‌های SOI و NAO طی سال‌های ۱۹۶۹ تا ۲۰۰۰ میلادی از طریق شبکه اینترنت از آدرس‌های www.cru.uea.ac.uk/cru/data/nao.htm و www.cru.uea.ac.uk/cru/data/soi.htm تهیه گردید.

شاخص EDI

Whihite و Byun در سال ۱۹۹۶ شاخص‌های زیادی را ارائه کردند که همگی در تعیین زمان دقیق پایان دوره خشکسالی دارای محدودیت بودند. چندی بعد آنها شاخص EDI را که تا حد زیادی معایب شاخص‌های دیگر را پوشش می‌داد، پیشنهاد دادند. در این شاخص، خشکسالی بطور روزانه پایش می‌شود که این قابلیت در شاخص‌های قبلی مد نظر نبوده است. این شاخص تابعی از محاسبه "شاخص بارندگی مورد نیاز برای برگشت به شرایط نرمال روزانه" (PRN)^۱ یا به عبارت دیگر مقدار بارندگی لازم برای برگشت به شرایط نرمال، از شروع خشکسالی را نشان می‌دهد.

$$EDI_j = \frac{PRN_j}{ST(PRN_j)} \quad (1)$$

$$PRN_j = \frac{DEP_j}{\sum_{N=j}^j (1/N)} \quad (2)$$

$$DEP = EP - MEP \quad (3)$$

در این روابط z تداوم واقعی، $ST(PRN)$ دهنده انحراف معيار روزهای PRN، EP بارش موثر و MEP ميانگين هر روز می‌باشد. اصلی‌ترین مفهوم در این شاخص بارش موثر (EP) بارش روزانه با یک تابع کاهشی وابسته به زمان می‌باشد و در واقع نقش یک حافظه را برای شاخص ایفا می‌کند. به عبارت دیگر EP هر روز، تابعی از بارندگی همان روز و یک دوره ماقبل خود بوده که در آن بارش‌های اخیر نسبت به بارش‌های قدیمی‌تر وزن بیشتری را دارند. مراحل محاسباتی شاخص

۱-Precipitation needed for a Return to Normal

۲-Effective Precipitation

EDI با انتخاب دوره فرضی کمبود آب آغاز می‌گردد و در ادامه محاسبات، دوره واقعی آن تعیین خواهد شد. این دوره فرضی می‌تواند ۳۶۵ روز (نماینده مقدار کل منابع آب ذخیره شده برای یک دوره طولانی) و یا ۱۵ روز (نماینده مقدار کل منابع آب ذخیره شده برای یک دوره کوتاه مدت) باشد. در این تحقیق دوره ۳۶۵ روز که سیکل بارندگی قالب جهانی و حاکم بر کشور است، انتخاب گردید. بعد از انتخاب تداوم فرضی می‌توان محاسبات را مطابق مراحل زیر ادامه داد:

$$EP_i = \sum_{n=i}^i \left[\left(\sum_{m=1}^n P_m \right) / n \right] \quad (4)$$

که در آن i تداوم فرضی و P_m بارندگی تا $m-1$ روز قبل می‌باشد. شرح کامل محاسبه این شاخص‌ها در Byun و EDI (1996) آمده است که بدلیل طولانی بودن از ارائه کامل آن پرهیز می‌گردد. . تحوه طبقه‌بندی شاخص در جدول(۱) آمده است.

جدول(۱) طبقه‌بندی شاخص EDI

مقدار	وضعیت	EDI
۳	خیلی خیلی مرطوب	۲/۵
۲	خیلی مرطوب	۲/۵
۱	کمی مرطوب	۲/۵
۰	نزدیک به نرمال	۲/۵
-۱	کمی خشک	۲/۵
-۲	خشک شدید	۲/۵
-۳	بسیار زیاد خشک	۲/۵

شبکه‌های عصبی مصنوعی (ANN)

شبکه عصبی مدل‌های محاسباتی هستند که قادرند رابطه میان ورودی‌ها و خروجی‌های یک سیستم فیزیکی را توسط شبکه‌ای از گره‌ها که همگی با هم متصل هستند، تعیین نمایند که در آن میزان فعالیت هر یک از این اتصالات توسط اطلاعات تاریخی تنظیم می‌شود (فرآیند یادگیری) و در نهایت مدل قادر خواهد بود قوانین مرتبط میان ورودی‌ها و خروجی‌ها را کشف نماید. نحوه محاسبات در شبکه‌های عصبی بدین شکل است که ورودی‌های به نرون (x_1 تا x_n) در اوزان (w_1 تا w_n) ضرب شده که مدل ریاضی آن بصورت رابطه زیر است:

$$S_j = w_{0j} + x_1 w_{1j} + x_2 w_{2j} + \dots + x_n w_{nj} \quad (5)$$

که در آن x_1, x_2, \dots, x_n ورودی ها ، $w_{1j}, w_{2j}, \dots, w_{nj}$ وزنها، S_j خروجی شبکه می باشند و عبارت افزوده شده w_{0j} وزن اریب^۱ نامیده می شود. در ادامه، مجموع ورودی های هر نرون پس از ضرب در وزن های متناظر، در یک تابع موسوم به محرك^۲ (f) اعمال می شوند. مرسوم ترین تابع در اين خصوص تابع سigmoid^۳ می باشد که محدوده آن صفر تا یک است. ANN توانایی دسته بندی و پردازش اطلاعات ورودی را دارد. رايچ ترين ANN برای مسایل هيدرولوژيکی و منابع آب الگوريتم انتشار برگشتی (BPN)^۴ می باشد. در اين روش، اطلاعات در مسیری پيشرو از لاييه های ورودی به سمت لاييه های پنهان و خروجي پردازش می شوند. هدف پيدا کردن وزن هاست بطور يك مقادير محاسبه شده در حد دقت مورد نظر به مشاهدات نزديك باشند و اين عمل با اصلاح وزن ها در شبکه انجام می شود. اين روش کاربرد گسترده ای دارد و (2000) Clobaly گزارش کرد که در ۹۰٪ محاسبات فرآيندهای هيدرولوژيکی با ANNs، از آن استفاده شده است. به طور کلي اين روش الگوريتمی است که بر اساس مقایسه هدف ها و مقادير خروجي ANN و بهينه کردن وزنها به منظور به حداقل رساندن خطاي شبکه عمل می کند.

نتایج و بحث

تأثیر ENSO بر بارندگی منطقه

در اين تحقيق به بررسی وضعیت بارندگی در سال های وقوع فاز گرم رویداد ENSO (SOI<-2.5) همراه با يک و دو سال بعد از آن پرداخته شد. بدین منظور ابتدا اين بارندگی ها برای ایستگاه های مورد نظر نرمال شدند تا بررسی و مقایسه آنها راحت تر انجام شود. در طی دوره آماری ۳۲ ساله مورد مطالعه (۱۹۶۹-۲۰۰۱)، ۹ رویداد ENSO رخ داده که دو سال آن به صورت متوالی بوده است که تنها إنسوی سال دوم به منظور ارائه نتایج انتخاب شد. سال های انتخابی به منظور بررسی

۱-Biase weight

۲-Transfer Function

۳-Sigmoid

۴-Back Propagation Network

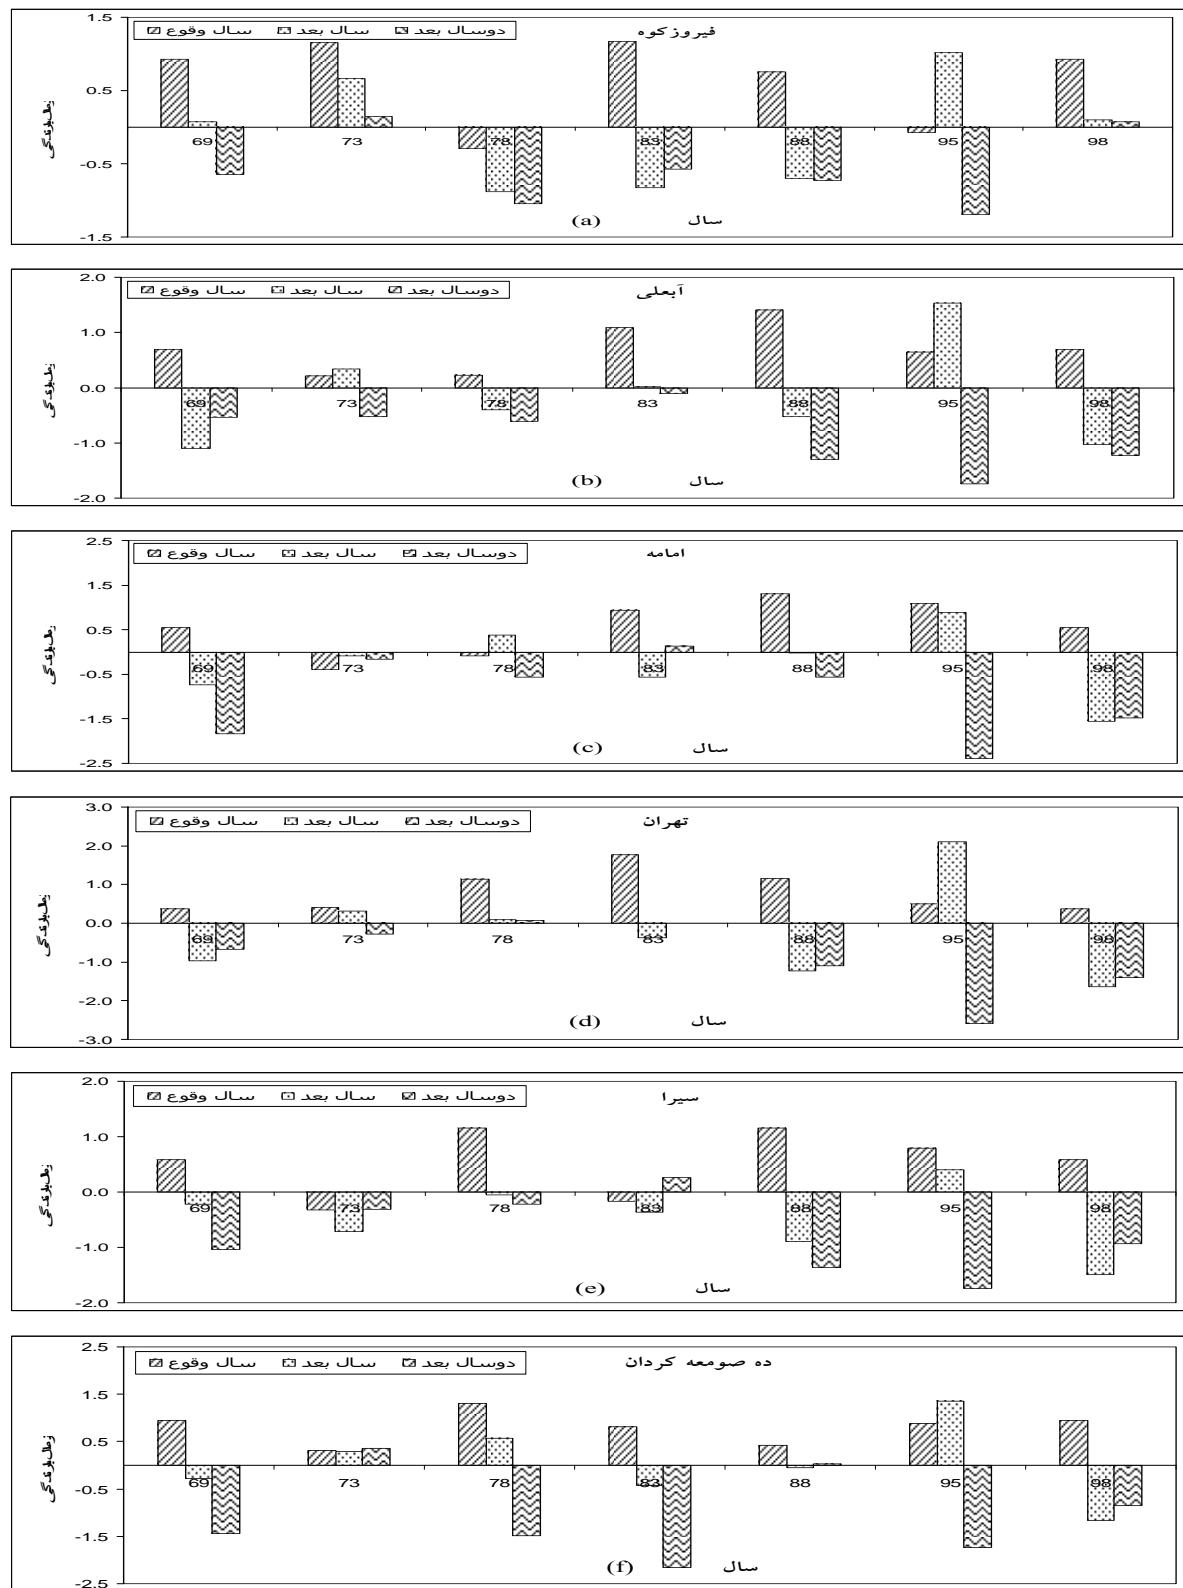
وقوع رویداد ENSO شامل ۱۹۶۹، ۱۹۷۲، ۱۹۷۷، ۱۹۸۲، ۱۹۸۴ و ۱۹۹۷ می باشد. شکل(۱) وضیت بارندگی نرمال شده در این سال‌ها را برای ایستگاه‌های منتخب نشان می‌دهد. نتایج حاکی از آن است که سال‌های وقوع فاز گرم ENSO در اکثر موارد با وقوع ترسالی همراه بوده است. همچنین مواجهه خشکسالی نیز دو سال بعد از وقوع ENSO برای بیش از ۷۰٪ موارد به چشم می‌خورد. در بررسی‌های مشابه برای NAO ارتباط معنی‌داری بدست نیامد.

پیش‌بینی خشکسالی

همانطور که اشاره شد، در این تحقیق پیش‌بینی بر مبنای شاخص‌های خشکسالی به انجام رسیده و ورودی‌های مورد استفاده عمدتاً خود شاخص‌ها با گام‌های زمانی مختلف قبل تر و در کنار آنها بارندگی ماهانه و شاخص‌های SOI و NAO بوده است. بدین منظور روش‌های همبستگی پیرسون، رگرسیون متوالی و شبکه‌های عصبی مصنوعی مورد ارزیابی قرار گرفتند.

همبستگی پیرسون

روش همبستگی پیرسون آزمونی است برای فهمیدن ارتباط معنی‌دار میان سیگنال‌ها و بارندگی‌های سالانه، فصلی و ماهانه جاری و آینده، به عنوان مثال جدول(۲) ضریب همبستگی (R^2) میان بارندگی‌های فصلی (a to d) و متosteنهای سه ماهه SOI متناظر آنها را برای هر فصل (۱تا۴) نشان می‌دهد. ارتباط معنی‌داری برای ایستگاه‌های آبلی، امامه و تهران که بیانگر وجود همگرایی منفی بین SOI و بارندگی پاییزه در این ایستگاه‌ها می‌باشد مشاهده شد، ولی بین داده‌های حال SOI و مقادیر بارندگی در آینده این ارتباط دیده نشد. همچنین برای NAO نیز نتایج مشابه بدست آمد.



شکل(۱) وضیت بارندگی نرمال شده در سال وقوع ENSO، یک و دو سال بعد از آن برای ایستگاههای منتخب (شروع از سال ۱۹۶۵)

جدول(۲) ضریب همبستگی (R^2) میان بارندگی‌های فصلی و متoste‌های سه ماهه SOI متناظر آنها را برای هر فصل

	1-a	1-b	1-c	1-d	2-b	2-c	2-d	3-c	3-d	4-d
فیروزکوه	-0.33	0.38	-0.16	0.04	0.35	0.23	-0.16	-0.03	-0.03	0.00
آبعلی	-0.46	-0.07	-0.04	0.00	-0.07	0.07	0.06	-0.02	-0.22	-0.15
اماوه	-0.44	-0.25	-0.21	0.29	-0.13	-0.01	0.09	-0.07	-0.11	0.10
تهران	-0.46	-0.15	-0.11	0.23	0.03	-0.04	-0.11	0.02	-0.06	0.05
سپیدا	-0.40	-0.07	0.00	0.27	0.04	0.07	0.03	0.14	-0.04	0.08
ده صومه کردان	-0.37	0.03	-0.13	0.30	0.05	0.24	-0.04	0.04	0.14	0.19

(اعداد ۱ تا ۴ بانگر فصول SOI و حروف a تا d معرف فصول بارندگی می‌باشند)

بکارگیری روش رگرسیون متوالی (SCA)

برای تحلیل بهتر واقعیت ارتباط موجود بین سیگنال‌های مطرح شده و بارندگی روش رگرسیون متوالی جهت محاسبه همبستگی بین این پارامترها مورد استفاده قرار گرفت. این روش برای تعیین همبستگی بین دو متغیر که ارتباط آنها در طول زمان ثابت نبوده و تغییر نماید مناسب می‌باشد (ناظم السادات، ۱۳۷۸). فرض می‌کنیم دو سری زمانی A و B دارای n عضو بوده و می‌خواهیم با روش SCA همبستگی آنها را تعیین نماییم. تعداد معینی مثلاً ۲۰ داده از سری (a₁, a₂, ... a₂₀) و مقادیر متناظر آن از سری B (b₁, b₂, ... b₂₀) را انتخاب کرده و ضریب همبستگی بین آنها را (r₁) تعیین می‌کنیم. در مراحل بعدی ضریب همبستگی بین (y_{n-19}, x_{n-18}, ..., x_n) با (a₂, a₃, ..., a₂₁) و نهایتاً (b₂, b₃, ..., b₂₁) با (y_{n-18}, ..., y_{n-19}) محاسبه کرده و به ترتیب r₂, r₃, ..., r₁₉ می‌نماییم. در این حالت ۲۰ را طول پنجره زمانی ^۳ می‌نماییم. این روش بر اساس محاسبه ضرایب همبستگی متوالی برای یک دوره ۲۴ ماهه پایه گذاری شده است. به عنوان مثال جدول(۳) این مقدار را برای پنجره زمانی سه ماهه ایستگاه مهرآباد نشان می‌دهد. همانطور که در جدول مشخص است ارتباط معنی داری که از بتوان در پیش بینی خشکسالی استفاده کرد وجود ندارد.

۱-Sequential Correlation Analysis

۲-Window Width (WW)

شبکه های عصبی مصنوعی

در بخش قبل قابلیت روش های همبستگی در برقراری ارتباط بین بارندگی و سیگنال ها به منظور پیش بینی ارزیابی گردید. در این بخش با متداولوئی دیگری این مهم به انجام می رسد و طی آن امکان پیش بینی شاخص خشکسالی EDI که در قبل به آنها اشاره شد با استفاده از شبکه های عصبی مصنوعی ارزیابی می گردد. ورودی های شبکه بر اساس آمار حال و گذشته شاخص و همچنین مقادیر بارندگی، NAO و SOI با دروه های زمانی مختلف انتخاب شدند و بنا به توصیه های ارائه شده بین ۰/۹ و ۰/۱ استاندارد شدند (Sajikumar et. al., 1999). در کنار موارد فوق، معماری های مختلفی نیز برای شبکه که طی آن تعداد لایه ها و نرون ها تعیین می گردد مورد ارزیابی قرار گرفت و سعی شد که بخصوص شبکه با مشکل فوق برآژشی^۱ [Dawson and Wibily, 1998] مواجهه نگردد (جدول ۴). برای آموزش شبکه سال های ۱۳۶۹-۷۰ لغایت ۱۹۹۳-۹۴ به عنوان دوره آموزش و سال های ۱۹۹۴-۹۵ لغایت ۱۹۹۹-۲۰۰۰ به عنوان دوره صحت یابی انتخاب گردید. برای ارزیابی عملکرد شبکه های عصبی سه معیار ضریب همبستگی (R^2)، ریشه میانگین مجذور خطای RMSE^۲ و متوسط قدر مطلق خطای MAE^۳ بکار برده شد. R^2 معیاری بدون بعد و بهترین مقدار آن برابر یک می باشد. RMSE و MAE نیز نشان دهنده میزان خطای مدل با بعد متغیرها است که بهترین مقدار برای آنها برابر صفر می باشد. بالغ بر ۲۵ مدل مختلف مورد آزمون قرار گرفت که به ۹ مورد از آنها که نتایج بهتری داشت در ادامه اشاره می شود:

$$E_{(t+n)}=f(R_t, R_{t-1}, R_{t-2}) \quad (1)$$

$$E_{(t+n)}=f(S_t, S_{t-1}, S_{t-2}) \quad (2)$$

$$E_{(t+n)}=f(N_t, N_{t-1}, N_{t-2}) \quad (3)$$

$$E_{(t+n)}=f(E_t, E_{t-1}, E_{t-2}, E_{t-3}) \quad (4)$$

$$E_{(t+n)}=f((E_t, E_{t-1}, E_{t-2}), (R_t, R_{t-1}, R_{t-2})) \quad (5)$$

$$E_{(t+n)}=f((E_t, E_{t-1}, E_{t-2}), (So_t, So_{t-1}, So_{t-2})) \quad (6)$$

$$E_{(t+n)}=f((E_t, E_{t-1}, E_{t-2}), (N_t, N_{t-1}, N_{t-2})) \quad (7)$$

$$E_{(t+n)}=f((E_t, E_{t-1}, E_{t-2}), (R_t, R_{t-1}, R_{t-2}), (S_t, S_{t-1}, S_{t-2})) \quad (8)$$

$$E_{(t+n)}=f((E_t, E_{t-1}, E_{t-2}, E_{t-12}), (R_t, R_{t-1})) \quad (9)$$

۱-Over fitting

۲-Root Mean Square Errors

۳-Mean Absolute Errors

در این موارد E، شاخص EDI، R بارندگی، SOI، N شاخص NAO و n گام زمانی پیشترمی باشد (به عنوان مثال $n=2$ به معنی پیش‌بینی دو ماه جلوتر می‌باشد).

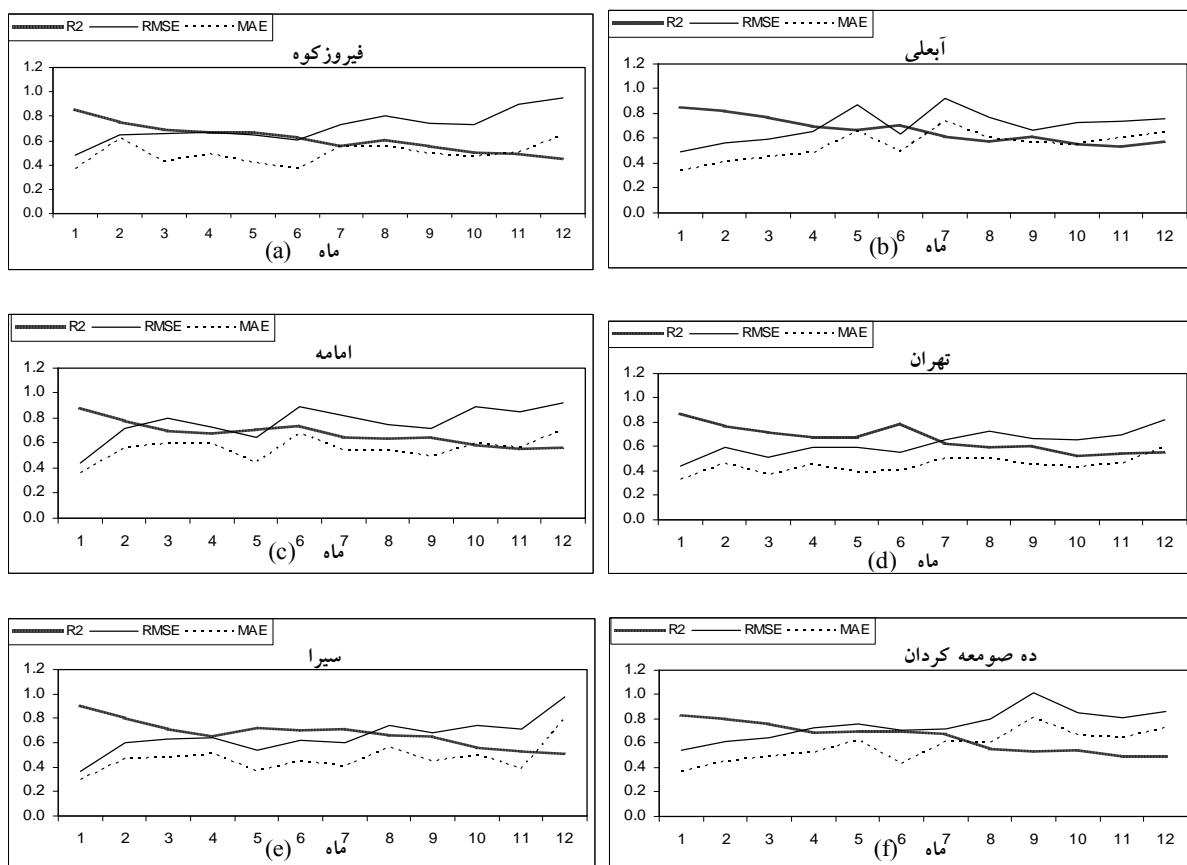
جدول (۴) نتایج مدل‌های ورودی مختلف برای پیش‌بینی ۶ ماه آینده شاخص EDI در ایستگاه مهرآباد

مدل ورودی	معماری	آموزش			صحت یابی		
		R ²	RMSE	MAE	R ²	RMSE	MAE
۱	۵-۲-۱	۰.۴۹	۰.۴۶	۰.۳۴	۰.۳	۰.۷۵	۰.۶۳
۲	۶-۳-۱	۰.۳۴	۰.۸۶	۰.۶۷	۰.۱	۱.۳۳	۰.۸۸
۳	۵-۲-۱	۰.۴۴	۰.۷۳	۰.۵۵	۰.۲	۱.۵۱	۱.۱۰
۴	۴-۳-۱	۰.۶۱	۰.۵۴	۰.۳۶	۰.۴	۰.۶۸	۰.۵۵
۵	۶-۲-۱	۰.۵۷	۰.۴۲	۰.۶۰	۰.۴	۰.۶۲	۰.۴۵
۶	۶-۴-۱	۰.۴۱	۰.۷۹	۰.۹۰	۰.۱	۱.۱۱	۰.۷۰
۷	۴-۳-۱	۰.۳۱	۰.۸۸	۰.۵۰	۰.۱	۱.۲۱	۰.۷۵
۸	۵-۴-۱	۰.۴۵	۰.۹۲	۰.۷۵	۰.۱	۱.۰۱	۰.۸۸
۹	۵-۶-۱	۰.۸۴	۰.۳۶	۰.۲۴	۰.۷	۰.۵۵	۰.۳۳

عملکرد مدل‌ها

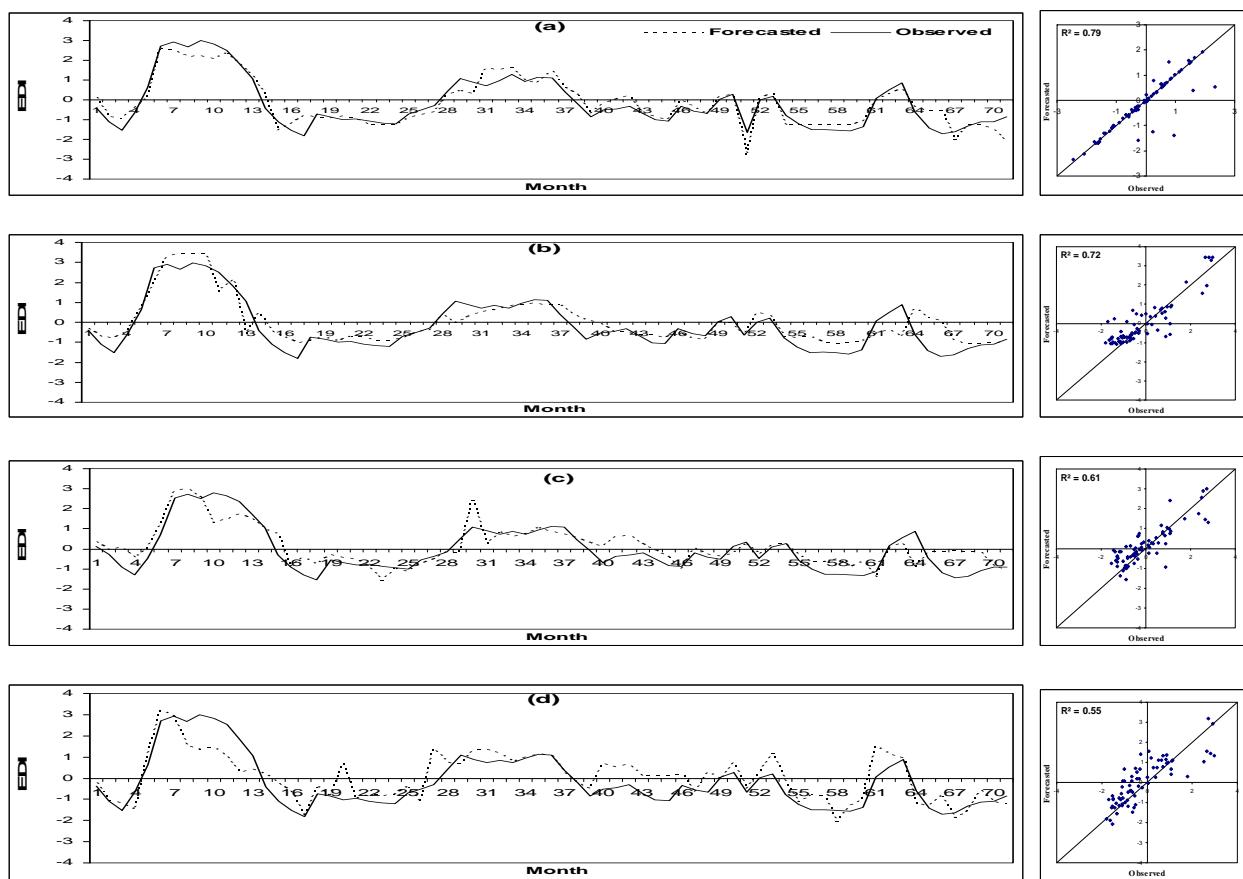
مدل‌های ورودی فوق بر اساس معماری‌های مختلف با استفاده از معیارهای ذکر شده در قبل برای تمامی ایستگاه‌ها و دوره کامل یکساله مورد ارزیابی قرار گرفت که به منظور پرهیز از طولانی شدن مطالب نتایج تفصیلی تنها برای پیش‌بینی ۶ ماه جلوتر ایستگاه مهرآباد در جدول (۴) آمده است. جدول نشان می‌دهد که از بین مدل‌های ۱ تا ۴ ورودی، مدل ۴ (خود شاخص با چهار گام زمانی قبل) نتایج نسبتاً مطلوبی را ارائه داده است ولی سایر ورودی‌ها بطور مستقل نتوانسته‌اند به شکل مطلوبی پیش‌بینی را انجام دهند. در مدل‌های ۵ تا ۸ با وجود بکارگیری ترکیبات مختلف ورودی نتایج قابل قبولی بدست نیامد. اما نتایج تنها در مدل ۹ به نحو کاملاً محسوسی افزایش یافته است، بطوریکه به عنوان مثال مقادیر R² برای دوره آموزش و صحت یابی به ترتیب ۰/۸۴ و ۰/۷۹ می‌باشد. نکته قابل ذکر در مدل ۹ وجود مقادیر ماه مشابه سال قبل آن شاخص است مانند آنچه در مدل ARIMA اتفاق می‌افتد. قابل ذکر می‌باشد که نتایج فوق با بکارگیری معماری نسبتاً

سبک (دو لایه و حداقل ۶ نرون) بدست آمده است. برای سایر ایستگاه‌ها و دوره‌های پیش‌بینی نیز همین نتایج حاصل شد و مدل ۹ بهترین جوابها را ارائه داد. شکل (۲) تغییرات معیارهای ارزیابی دوره‌های پیش‌بینی ۱ تا ۱۲ ماهه شاخص EDI برای تمام ایستگاه‌ها را نشان می‌دهد. جهت مشاهده بهتر نتایج روند تغییرات مقادیر مشاهده‌ای و پیش‌بینی شده شاخص EDI برای دوره‌های سه، شش، نه و دوازده ماهه ایستگاه مهرآباد در شکل (۳) نشان داده شده است. در کنار اشکال اصلی نمودار پراکندگی و ضریب همبستگی (R^2) مقادیر مشاهده‌ای و پیش‌بینی شده برای دوره صحبت‌یابی آمده که همگی در سطح ۱٪ معنی دار هستند.



شکل (۲) روند تغییرات معیارهای ارزیابی مدل نهم EDI در دوره‌های پیش‌بینی برای مرحله صحبت‌یابی

تحلیلی دیگر که برای مقایسه عملکرد نتایج پیش‌بینی انجام گرفت، بررسی طبقه وضعیت خشکسالی و یا ترسالی اعلام شده توسط مدل می‌باشد و اینکه ارقام شاخص EDI پیش‌بینی شده منتج به چه طبقه‌ای می‌گردد و سپس مقایسه آن با طبقه واقعی صورت پذیرفت که نتایج مربوط در جدول (۵) آمده است. نتایج نشان می‌دهد در طی دوره آماری ایستگاه‌ها، در ۷۲٪ تا ۸۹٪ ماه‌ها EDI طبقه خشکسالی یا ترسالی مربوط را برای ۶ ماه آینده به درستی برآورد کرده است (مقدار DC در ردیف صفر جدول ۵). این مقدار برای ۹ ماه آینده به ترتیب ۵۹٪ تا ۸۰٪ و برای ۱۲ ماه ۵۵٪ تا ۷۲٪ می‌باشد



شکل (۳) مقایسه مقادیر مشاهده‌ای و پیش‌بینی شده شاخص EDI در ایستگاه مهرآباد (a) سه ماهه، b) شش ماهه، c) نه ماهه و d) دوازده ماهه

جدول(۳) ضرایب همبستگی SOI و بارندگی های ماهانه در ایستگاه مهرآباد

	1-3	2-4	3-5	4-6	5-7	6-8	7-9	8-10	9-11	10-12	11-13	12-14	13-15	14-16	15-17	16-18	17-19	18-20	19-21	20-22	21-23	22-24	23-25	24-26	25-27
1-3	-0.46	-0.41	-0.10	-0.15	-0.12	-0.22	-0.11	-0.08	0.31	0.23	0.01	0.11	0.09	0.17	0.09	-0.04									
2-4		-0.31	-0.09	-0.15	-0.16	-0.29	-0.16	-0.12	0.33	0.24	0.15	0.10	0.08	0.07	-0.01	-0.03	-0.07								
3-5			-0.05	-0.09	-0.14	-0.23	-0.16	-0.21	0.07	-0.03	0.16	-0.01	0.01	-0.06	-0.11	-0.09	0.04	0.07							
4-6				0.03	-0.01	-0.06	-0.04	-0.15	0.00	-0.11	0.09	-0.14	-0.12	-0.16	-0.11	-0.01	0.13	0.18	0.22						
5-7					0.00	-0.09	-0.02	-0.19	-0.02	-0.18	0.02	-0.15	-0.06	-0.03	0.01	-0.03	0.11	0.14	0.23	-0.02					
6-8						-0.10	0.03	-0.20	0.06	-0.16	0.02	-0.07	0.04	0.13	0.14	0.00	0.09	0.10	0.22	-0.06	0.05				
7-9							0.02	-0.20	0.19	-0.06	0.10	0.13	0.15	0.25	0.16	0.05	0.08	0.05	0.16	-0.14	-0.09	-0.13			
8-10								-0.10	0.26	0.03	0.09	0.19	0.13	0.20	0.09	0.01	-0.01	-0.07	0.07	-0.18	-0.19	-0.18	0.16		
9-11									0.31	0.11	0.06	0.14	0.07	0.16	0.12	-0.01	-0.07	-0.17	-0.02	-0.22	-0.11	-0.09	0.25	0.07	
10-12										0.05	-0.05	0.06	0.06	0.17	0.20	-0.09	-0.13	-0.25	-0.05	-0.24	-0.11	-0.15	0.22	0.11	0.07

جدول(۵) فراوانی اختلاف طبقات پیش بینی شده و مشاهدهای شاخص EDI

DC*	Firouzkoh				Abali				Ammameh				Mehrabad				Siera				Deh Someh			
	3	6	9	12	3	6	9	12	3	6	9	12	3	6	9	12	3	6	9	12	3	6	9	12
0	75	72	70	63	90	87	70	65	81	83	68	62	71	73	66	59	91	89	80	72	78	72	59	55
1	25	28	30	32	10	13	30	35	19	17	32	37	29	27	30	34	9	11	20	27	22	28	39	42
2	0	0	0	4	0	0	0	0	0	0	0	1	0	0	4	7	0	0	0	1	0	0	1	3
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

(DC اختلاف طبقات پیش بینی شده و مشاهدهای برای شرایط خشک و تر)

جمع‌بندی

تحقیق حاضر تلاشی بود برای پیش‌بینی خشکسالی در استان تهران با استفاده از ANNs که در آن نقش سری زمانی شاخص خشکسالی EDI، بارندگی و شاخص‌های SOI و NAO به عنوان ورودی به شبکه بررسی و ارزیابی گردید. نتایج

زیر از این تلاش قابل ارائه است:

-۱- پیش‌بینی بارندگی‌ها با روش‌های بکار رفته میسر نشد ولی پیش‌بینی مقادیر سری زمانی شاخص EDI

نتایج قابل قبولی در بر داشت.

-۲- بکارگیری شاخص‌های SOI و NAO به عنوان ورودی در بهبود پیش‌بینی‌ها در هر دو روش رگرسیون و ANN

(در منطقه مورد مطالعه) موثر نبودند.

-۳- در روش ANN نتایج بهتری برای پیش‌بینی خشکسالی نسبت به روش رگرسیون بدست آمد.

-۴- از میان مدل‌های مختلف که برای ورودی ANN بکار رفت، مدلی که از ترکیب بارندگی، خود شاخص همچنین

مقادیر ماه مشابه سال قبل آن شاخص تشکیل شده بود بهترین نتایج را در بر داشت.

-۵- استفاده از معماری سبک و قرار دادن ۲ الی ۶ نرون در لایه پنهان در تمام موارد نتایج بهتری را نشان داد.

همچنین در بهترین مدل بکار رفته به منظور پیش‌بینی میان مدت و دراز مدت خشکسالی، مقدار R^2 معادل ۰.۷۹

برای EDI بدست آمد که دقیق‌ترین پیش‌بینی را نشان می‌دهد.

-۶- پدیده ENSO در ایستگاه‌های منتخب معمولاً همراه با بارندگی سالیانه بالاتر از نرمال بوده است. همچنین در دو

سال بعد از وقوع این پدیده، ایستگاه‌ها در شرایط زیر نرمال قرار گرفته‌اند.

-۷- متداول‌ترین تحقیق حاضر، این برتری را داشت که در اعلام وضعیت آتشی، تنها شرایط تر و خشک گزارش نمی‌گردد

بلکه شدت آن نیز ارائه می‌شود که از آن می‌توان در پایش و هشدار خشکسالی‌های قریب الوقوع استفاده کرد.

منابع

فهمی، هدایت (۱۳۸۰). "ارزیابی اثرات خشکسالی بر منابع آب کشور". کارگاه تخصصی منابع آب کشور. مرید، سعید، م، مقدسی، ه، قائمی، و ش، پایمذد، (۱۳۸۳). "طرح تحقیقاتی "طراحی سیستم پایش خشکسالی استان تهران"، وزارت نیرو.

میرابوالقاسمی، هادی و سعید مرید، (۱۳۸۰). "طرح جامع خشکسالی، حلقه گمشده در برنامه‌ریزی مدیریت منابع آب ایران"، مجموعه مقالات اولین کنفرانس ملی بررسی راه کارهای مقابله با بحران آب، جلد اول، ۴۵۴-۴۴۳ص.

زهراei، بنفشه، م، کارآموز و س، اقدامی راد (۱۳۸۳). "پیش‌بینی بارش فصلی با استفاده از سیگنال‌های هواشناسی: کاربرد در حوزه آبریز رودخانه کارون". اولین کنفرانس سالانه مدیریت منابع آب ایران.

ASCE Task Committee on Applications of Artificial Neural Networks in Hydrology (2000). Artificial neural networks in hydrology: I: preliminary concepts; II: hydrologic applications. *J. Hydrol. Engineering* 5(2): 115- 137

Birikundavyi S., Labib R., Trung HT. and Rousselle J. 2002. Performance of neural networks in daily streamflow forecasting. *Journal of Hydrologic Engineering*. ASCE. 7(5): 392-398.

Boken. V.K., Cracknell A.P., Heathcote, R.L. (Eds.) 2005. Monitoring and Predicting Agricultural Drought: a global study. Oxford University Press, NY: 472

Byun HR, Wilhite DA. 1996. Daily quantification of drought severity and duration. *Journal of Climate* 5: 1181-1201.

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

Demuth H. and Beale M. 1995. Neural Network Toolbox, for use with MATLAB, User's Guide , The MathWork, Inc.

Edwars DC. and McKee TB. 1997. Characteristics of 20th century drought in the university, Colorado.

Gabriel KR. and Neumann. 1962. A Markov chain model for daily rainfall occurrences. *Journal of Roy. Meteorol. Soc.*: 90-95.

Govindaraju, R.S. and Rao, R. A. 2000. Artificial neural networks in hydrology. Kluwer Academy Publishers, The Netherlands

Hornik K., Stinchcombe M. and White H. 1990. Universal approximation of an unknown mapping and its derivatives using multi layer feed forward networks. *Neural networks* 3: 551-560.

Hsu K., Gupta HV. and Sorooshian S. 1995. Artificial neural network of the rainfall-runoff process. *Water Resources Research* 31(10): 2517-2530.

Jain SK., Das. A. and Sirvastava DK. 1999. Application of ANN for reservoir inflow prediction and operation. *ASCE. Journal of Water Resource Planning and Management*. 125: 263-271

Luk, K.C., Ball, J.E., and Sharma, A. 2000. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *Journal of Hydrology*. 227: 56-65.

Koureh Pazan A. (2003) Impact of meteorological signals on forecasting rainfall variations, M.Sc. thesis. Amir Kabir University.

McKee TB., Doesken NJ. and Kliest J. 1993. The relationship of drought frequency and duration to time scale. Preprints 8th Conference on Applied Climatology: 179-184.

Salas J.D., Markus M. and Tokar, AS. 2000. Streamflow forecasting based on artificial neural networks. In: Artificial neural networks in hydrology , ed. Govindaraju, R.S. and Ramachandra, A., PP.23-51. West Lafayette Indiana,U.S.A

Sajikumar K. and Thandaveswara BS. 1999. A non-linear rainfall-runoff model using an artificial neural network. *Journal of Hydrology*. 216: 32-55.

Rumelhart J. Hinton G.E. and Williams R.J. 1986. Learning internal representation by error propagation. In: Rumelhart, D.E., MaClelland, J.L. (Eds), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol. 1, MIT Press, Cambridge, MA: 318-362.

Thirumalaiah K. and Deo, MC. 1998. River Stage Forecasting Using Artificial Neural Networks, *ASCE. Journal of Hydrological Engineering* 3(1): 26-32.

Torranin P. 1976. Proceeding of the second international symposium in hydrology. Fort Collins, Colorado, U.S.A, p: 595-604.

Yapo PO. Gupta VH. and Sorooshian S. 1996. Automatic calibration of conceptual rainfall runoff models: sensitivity to calibration data. *Journal of Hydrology*. 181: 23-48