



دانشگاه شهروردی، محقق سینی کالج

مجله پژوهش‌های حفاظت آب و خاک

جلد شانزدهم، شماره دوم، ۱۳۸۸

[www.gau.ac.ir/journals](http://www.gau.ac.ir/journals)

## مقایسه روش‌های مختلف پیش‌بینی شاخص خشک‌سالی SPI

معصومه عیوضی<sup>۱</sup>، ابوالفضل مساعدي<sup>۲</sup> و امیراحمد دهقانی<sup>۳</sup>

<sup>۱</sup>دانشجوی کارشناسی ارشد گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، <sup>۲</sup>دانشیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، <sup>۳</sup>استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان  
تاریخ دریافت: ۸۷/۸/۲۲؛ تاریخ پذیرش: ۸۸/۲/۳۰

### چکیده

خشک‌سالی یکی از پدیده‌های آب و هوایی است که در همه شرایط اقلیمی و در همه مناطق کره زمین به وجود می‌پیوندد. پیش‌بینی خشک‌سالی نقش مهمی در طراحی و مدیریت منابع طبیعی، سیستم‌های منابع آب، تعیین نیاز آبی گیاه و... ایفا می‌نماید. در طی دهه‌های اخیر شبکه‌های عصبی توانایی‌های زیادی را در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و غیرایستا نشان داده‌اند. از این‌رو، در این تحقیق به منظور پیش‌بینی خشک‌سالی، از دو نوع شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) و تابع پایه‌ای شعاعی (RBF) استفاده شده است. به این منظور از داده‌های بارندگی استگاه نوده با دوره آماری ۴۱ ساله در حوزه آب‌خیز گرگان‌رود، استفاده شد. وضعیت رطوبتی با استفاده از شاخص بارندگی استاندارد شده (SPI) در دوره‌های زمانی کوتاه‌مدت (۱، ۳، ۶ و ۹ ماهه) و بلندمدت (۱۲، ۲۴ و ۴۸ ماهه) محاسبه گردید. سپس از بین داده‌های محاسبه شده، دوره ۱۳۴۵-۴۶ الى ۱۳۷۷-۷۸ به عنوان داده آموزش و دوره ۱۳۷۸-۷۹ الى ۱۳۸۵-۸۶ به عنوان داده آزمون انتخاب گردید. برای تخمین مقدار SPI در زمان  $t$  از مقادیر SPI در زمان‌های قبل استفاده شد. نتایج نشان داد که شبکه عصبی مصنوعی MLP نسبت به شبکه عصبی مصنوعی RBF با دقت بالاتری مقادیر SPI و وضعیت خشک‌سالی را پیش‌بینی می‌کند. همچنین مقایسه نتایج با نتایج حاصل از به کارگیری سری زمانی ARIMA نشان‌دهنده دقت بالای این روش می‌باشد.

واژه‌های کلیدی: خشک‌سالی، پیش‌بینی، شبکه عصبی مصنوعی، SPI، RBF، MLP، ARIMA

\* مسئول مکاتبه: abmosaedi@gmail.com

## مقدمه

خشکسالی پدیده‌ای طبیعی و تکرارشدنی است که در اثر کاهش میزان بارندگی در یک دوره زمانی مشخص به وجود می‌آید (شارما و اسماختین، ۲۰۰۴). محققان مختلف نشان دادند که نداشتن صراحة و شفافیت در تعریف خشکسالی، مانع برای درک خشکسالی است، این نداشتن صراحة منجر به تردید و سنتی در بخش‌های مدیریتی، سیاست‌گذاری و... می‌شود (ویلهیت و گلانتر، ۱۹۸۵؛ ویلهیت و همکاران، ۱۹۸۶). این پدیده به کندي شروع می‌شود و تأثیر آن به تدریج و در یک دوره زمانی نسبتاً طولانی در بخش‌های مختلف منابع آب، کشاورزی، محیط زیست، اجتماعی، اقتصادی و... ظاهر می‌شود. از این‌رو تعیین دقیق زمان شروع و خاتمه این پدیده تا حدودی مشکل است. بنابراین اغلب خشکسالی را پدیده‌ای خزندۀ توصیف می‌کنند (مرید و همکاران، ۲۰۰۵). بر این اساس، به دلیل ماهیت خشکسالی و بطئی بودن شروع و خاتمه آن، تشخیص و ارزیابی آن مشکل می‌باشد (پراتامچای و همکاران، ۲۰۰۱).

پیش‌بینی خشکسالی در سیستم‌های منابع آب نقش مهمی در کاهش خسارات خشکسالی ایفا می‌نماید. به طور سنتی در چندین دهه اخیر برای پیش‌بینی خشکسالی از برآش و مدل‌های ریاضی به طور گسترده استفاده شده است. این مدل‌ها، سری‌های زمانی را به صورت مانا<sup>۱</sup> در نظر گرفته و فرآیندها را به صورت خطی مدل‌سازی می‌کنند. در دهه‌های اخیر با توجه به ماهیت غیرخطی پدیده‌ها، شبکه‌های عصبی مصنوعی<sup>۲</sup> بیشترین توانایی را در مدل‌سازی و پیش‌بینی سری‌های زمانی در هیدرولوژی و مهندسی منابع آب نشان داده است (میشرا و دیسای، ۲۰۰۶).

از مزایای استفاده از شبکه عصبی مصنوعی می‌توان به موارد زیر اشاره نمود (ASCE، ۲۰۰۰):  
شبکه‌های عصبی مصنوعی قادرند از ساختار داده‌ها، ارتباط غیرخطی بین متغیرهای ورودی و خروجی را شناسایی کنند.

۱- در این نوع شبیه‌سازی حتی وقتی مجموعه آموزش دارای اختشاش<sup>۳</sup> و خطای اندازه‌گیری است، شبکه عصبی قادر به ارایه نتایج خوبی خواهد بود.

1- Stationary

2- Artificial Neural Networks (ANN)

3- Noise

۲- اگر تغییری در شرایط محیطی در طی زمان رخ دهد، شبکه عصبی با تنظیم پارامترهای جدید قادر به ارایه نتایج جدید خواهد بود.

دوگان و همکاران (۲۰۰۷) جریان سطحی روزانه را در ترکیه با استفاده از شبکه عصبی مصنوعی و روش استوکستیک اتورگرسیو<sup>۱</sup> پیش‌بینی کردند. نتایج آنها نشان داد که مدل‌های شبکه عصبی مصنوعی در زمینه پیش‌بینی هیدرولوژیکی بهتر می‌باشد. در تحقیقی دیگر محمدی و همکاران (۲۰۰۵) با استفاده سه روش شبکه عصبی مصنوعی، سری زمانی ARIMA و مدل همبستگی آماری جریان ورودی به مخزن سد امیرکبیر در فصل بهار را پیش‌بینی نمودند. نتایج آنها نشان داد که روش شبکه عصبی مصنوعی کارایی بهتری نسبت به دو روش دیگر دارد.

رضایی (۲۰۰۱) در تحقیقی به معرفی توانایی‌های روش‌های شبکه عصبی مصنوعی، در حل مسایلی از قبیل سیل و خشکسالی پرداخت. براساس یافته‌های وی استفاده از شبکه عصبی مصنوعی در مدل‌سازی رفتاری پدیده‌ها دارای برتری نسبت به روش‌های آماری می‌باشد: کارآموز و همکاران (۲۰۰۶) در تحقیق خود با ترکیب سه شاخص SPI<sup>۲</sup> (شاخص خشکسالی اقلیمی)، SWSI<sup>۳</sup> (شاخص خشکسالی هیدرولوژیکی) و PDSI<sup>۴</sup> (شاخص خشکسالی زراعی) و با استفاده از شبکه عصبی MLP<sup>۵</sup> به پیش‌بینی و شبیه‌سازی میزان خسارات خشکسالی‌های آتی در استان اصفهان پرداختند. آنها نتیجه گرفتند که شبکه‌های عصبی در حل مسایل پیش‌بینی و شبیه‌سازی، کارآمد هستند و با استفاده از شاخص ترکیبی می‌توان با رویکردن دقیق‌تر و واقع‌بینانه‌تر دوره‌های خشکسالی را تعیین نمود.

کریپو و مورا (۱۹۹۳) برای پیش‌بینی خشکسالی در اسپانیا از مدل شبکه‌های شبکه عصبی مصنوعی استفاده نمودند. آنها از یک شبکه پرسپترون چندلایه و الگوریتم پس انتشار خطأ برای آموزش شبکه استفاده نمودند. نتایج بررسی‌های نشان داد که مدل شبکه عصبی مصنوعی می‌تواند پیش‌بینی‌هایی با دقت بالا از تعداد خشکسالی‌ها و طول متوسط خشکسالی، ارایه نماید. نجفی و همکاران (۲۰۰۶) برای پیش‌بینی خشکسالی در حوزه آبریز سد ذ از مدل شبکه عصبی مصنوعی

1- Auto Regressive

2- Standardized Precipitation Index

3- Surface Water Supply Index

4- Palmer Drought Severity Index

5- Multi Layer Perceptron

استفاده نمودند. ایشان از یک شبکه پرسپترون چندلایه و الگوریتم پس انتشار خطاب برای آموزش شبکه استفاده نمودند. نتایج بررسی‌های این محققان نشان داد که مدل شبکه عصبی مصنوعی قادر به پیش‌بینی کوتاه‌مدت و درازمدت خشک‌سالی و همچنین پیش‌بینی میزان کمبود بارش و شدت خشک‌سالی است.

میشرا و دیسای (b) ۲۰۰۵ در تحقیق خود، برای پیش‌بینی خشک‌سالی از مدل‌های احتمالاتی خط مانند ARIMA<sup>۱</sup> و SARIMA<sup>۲</sup> با استفاده از شاخص بارش استاندارد شده (SPI) استفاده نمودند. نتایج تحقیقات آنها نشان داد که مدل‌های آماری نتایج خوبی از نظر پیش‌بینی کوتاه‌مدت خشک‌سال (تا ۲ ماه) دارد. میشرا و دیسای (۲۰۰۶) در تحقیق دیگری، برای پیش‌بینی خشک‌سالی از دو مدل شبکه عصبی مصنوعی و شاخص بارش استاندارد شده استفاده نمودند. نتایج تحقیقات آنها نشان داد که مدل‌های شبکه عصبی مصنوعی در مقایسه با مدل‌های آماری کارایی بیشتری داشته‌اند.

با توجه به اینکه اکثر مطالعات انجام شده در زمینه خشک‌سالی بیشتر توسط روش‌های سری زمانی برآژشی انجام شده است و اینکه در مواردی که از شبکه عصبی مصنوعی استفاده شده تنها از نوع شبکه عصبی پرسپترون چندلایه (MLP) استفاده شده است، بنابراین هدف از انجام این تحقیق به منظور مدل‌سازی و پیش‌بینی خشک‌سالی با استفاده از شبکه‌های عصبی پرسپترون چندلایه (MLP) و شبکه تابعی شعاعی<sup>۳</sup> (RBF) به همراه الگوریتم‌های آموزش<sup>۴</sup> (LA) و توابع فعالیت<sup>۵</sup> (AF) مختلف می‌باشد. ضمن آن که نتایج حاصل از این روش‌ها با نتایج روش‌های متعارف مدل‌سازی سری‌های زمانی مورد مقایسه قرار می‌گیرند.

## مواد و روش‌ها

در این تحقیق، از داده‌های بارندگی ماهانه ایستگاه باران‌سنگی نوده بررسی رودخانه خرمالو در طول دوره آماری ۱۳۴۵-۱۳۴۶ تا ۱۳۸۵-۱۳۸۶ استفاده شد. این ایستگاه در موقعیت جغرافیایی  $47^{\circ} 47'$  عرض شمالی،  $55^{\circ} 15'$  طول شرقی و ارتفاع ۲۸۰ متر از سطح دریاهای آزاد قرار گرفته است. پس از

۱- Auto Regressive Integrated Moving Average

۲- Seasonal Auto Regressive Integrated Moving Average

۳- Radial Basis Function

۴- Learning Algorithm

۵- Activity Function

اطمینان از صحت داده‌های بارندگی ماهانه و انجام آزمون‌های آماری لازم، سری زمانی وضعیت خشک‌سالی در طول دوره آماری براساس مقادیر SPI در دوره‌های کوتاه‌مدت (۱، ۳، ۶ و ۹ ماهه) و بلندمدت (۱۲، ۲۴ و ۴۸ ماهه) محاسبه شد. به عبارت دیگر ۷ سری زمانی شامل سری‌های زمانی SPI11، SPI12، SPI13، SPI16، SPI19، SPI24 و SPI48 برای دوره آماری ۱۳۴۵-۴۶ الى ۱۳۸۵-۸۶ تشکیل شد.

نمایه بارش استاندارد (SPI) توسط مک‌کی و همکاران (۱۹۹۳) جهت تعیین دوره‌های خشک‌سالی و ارزیابی شدت آن تدوین شد. از آنجایی که کمبود بارش در مقیاس زمانی کوتاه‌مدت برروی رطوبت خاک و در مقیاس زمانی بلندمدت برروی رودخانه‌ها، مخازن آب و آب‌های زیرزمینی، اثر می‌گذارد. SPI قادر به محاسبه کمبود بارش در مقیاس‌های زمانی متفاوت ۳، ۶، ۱۲، ۲۴ و ۴۸ ماهه می‌باشد (استینمن، ۲۰۰۳).

نمایه SPI برای هر منطقه براساس ثبت بارندگی‌های طولانی مدت و براساس میانگین متحرک زمانی محاسبه می‌شود (میشرا و دیسای، ۲۰۰۵a). در ابتدا توزیع آماری مناسبی بر آمار بارندگی بلندمدت برآش داده شده، مک‌کی و همکاران (۱۹۹۳) توزیع گاما را مناسب‌ترین توزیع برای برازش داده‌های بارندگی نشان دادند. سپس تابع تجمعی توزیع با استفاده از روابط احتمالاتی زیر به متغیر تصادفی توزیع نرمال استاندارد Z با میانگین صفر و انحراف معیار یک تبدیل می‌گردد (ادوارد و مک‌کی، ۱۹۹۷).

$$Z = SPI = - \left[ t - \frac{C_1 + C_2 t + C_3 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] \quad t = \sqrt{\ln\left[\frac{1}{H(x)}\right]} \quad . < H(x) \leq 1/5 \quad (1)$$

$$Z = SPI = + \left[ t - \frac{C_1 + C_2 t + C_3 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] \quad t = \sqrt{\ln\left[\frac{1}{1 - H(x)}\right]} \quad . /5 < H(x) \leq 1 \quad (2)$$

(1) و (2) معادله‌های (1) و (2) در میانگین صفر و انحراف معیار یک می‌باشند. به صورت زیر می‌باشند.

$$d_1 = 1/432788 \quad C_1 = 2/51557$$

$$d_2 = 0/189269 \quad C_2 = 0/802853$$

$$d_3 = 0/001308 \quad C_3 = 0/010328$$

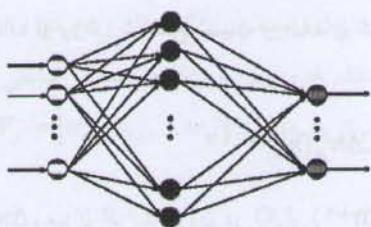
بنابراین SPI، متغیر نرمال شده Z با متوسط صفر و انحراف معیار یک می‌باشد.

شبکه‌های عصبی مصنوعی مدل‌های ریاضی و انعطاف‌پذیری هستند که می‌توانند در مدل‌سازی سیستم‌های پیچیده به کار بردند. همچنین این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها، یک نگاشت غیرخطی بین ورودی‌ها و خروجی‌ها ارایه دهند. پردازش در شبکه‌های عصبی مصنوعی براساس بسیاری از واحدهای پردازش به نام نرون یا گره انجام می‌شود. توانایی کلی شبکه عصبی مصنوعی یادگیری ارتباط غیرخطی بین داده‌ها و تعیین نتایج برای داده‌های دیگر است (کارایاتیر و نقسانویولوس، ۱۹۹۳). در مسایل سری‌های زمانی تعداد نرون‌های ورودی به تعداد مشاهدات تأخیر داده شده، که برای یافتن ارتباط موجود در سری‌های زمانی و برای پیش‌بینی‌های مقادیر آینده استفاده می‌شود، بستگی دارد. با استفاده از قضیه‌ای در ریاضی می‌توان اثبات نمود که شبکه‌های MLP سه لایه، برای تخمین هر تابع پیچیده غیرخطی با دقت مورد نظر مناسب هستند (سینکو، ۱۹۸۹).

**شبکه MLP:** شبکه‌های موسوم به پرسپترون چندلایه (MLP) که در شکل ۱ نشان داده شده است یکی از متداول‌ترین شبکه‌ها در پیش‌بینی و حل مسایل غیرخطی می‌باشند (هیچت نیلسون، ۱۹۸۷). آموزش این شبکه‌ها با استفاده از الگوریتم معروف پس انتشار خطأ<sup>۱</sup> (BP) صورت می‌پذیرد. الگوریتم پس انتشار خطأ اساساً از دو مسیر اصلی تشکیل می‌شود. مسیر اول به مسیر رفت<sup>۲</sup> موسوم است که در این مسیر، بردار ورودی به شبکه MLP اعمال می‌شود و تأثیرات آن از طریق لایه‌های پنهان، به لایه خروجی انتشار می‌یابد. مقادیر ورودی‌ها برای هر نرون، از رابطه (۳) محاسبه می‌شود:

$$net_i^n = \sum_{j=1}^m w_{ji}^n \cdot O_j^{n-1} \quad (3)$$

در این رابطه  $net_i^n$ ، مقادیر ورودی نرون  $i$  در لایه  $n$ ،  $W_{ji}^n$  وزن اتصالی بین نرون  $j$  در لایه  $n-1$  و نرون  $i$  در لایه  $(n-1)$  است.  $O_j^{n-1}$  خروجی نرون  $j$  در لایه  $(n-1)$  است و  $M$  تعداد نرون‌ها در لایه  $(n-1)$  است.



شکل ۱- شبکه عصبی مصنوعی پرسپترون چند لایه.

در هر نرون مقادیر محاسبه شده از معادله (۳) با استفاده از یک تابع انتقال به عددی تبدیل شده است. تابع معمول برای این منظور، تابع سیگموئید است، که به صورت زیر مشخص شده است:

$$Sig(net_j^n) = 1/(1+Exp(-net_j^n)) \quad (4)$$

در این روابط خروجی محاسبه شده هر نرون با ضرب ماتریس وزن شبکه منتقل می‌شود. در نهایت خروجی محاسبه شده شبکه با خروجی واقعی مقایسه می‌شود. در این مرحله یک تابع هدف مناسب از قبیل میانگین مطلق خطأ<sup>۱</sup> (MAE) یا جذر میانگین مربعات خطأ<sup>۲</sup> (RMSE) که به صورت زیر محاسبه می‌شود، در نظر گرفته می‌شود.

$$MAE = \frac{\sum_{i=1}^{n_p} \sum_{j=1}^{n_o} |T_{pj} - O_{pj}|}{n_p \cdot n_o} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n_p} \sum_{j=1}^{n_o} (T_{pj} - O_{pj})^2}{n_p \cdot n_o}} \quad (6)$$

در این روابط  $T_{pj}$  خروجی هدف نرون  $j$  ام مربوط به الگوی  $p$  ام،  $O_{pj}$  خروجی محاسبه شده نرون  $j$  ام مربوط به الگوی  $p$  ام،  $n_p$  تعداد الگوها و  $n_o$  تعداد نرون‌ها در لایه خروجی است. بعد از محاسبه تابع هدف گام دوم الگوریتم BP یعنی مسیر دوم که به مسیر بازگشت<sup>۳</sup> موسوم است، شروع

1- Mean of Absolute Error

2- Root Mean of Square Error

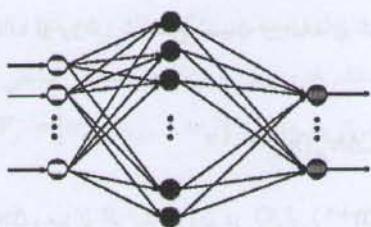
3- Backward

شبکه‌های عصبی مصنوعی مدل‌های ریاضی و انعطاف‌پذیری هستند که می‌توانند در مدل‌سازی سیستم‌های پیچیده به کار بردند. همچنین این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها، یک نگاشت غیرخطی بین ورودی‌ها و خروجی‌ها ارایه دهند. پردازش در شبکه‌های عصبی مصنوعی براساس بسیاری از واحدهای پردازش به نام نرون یا گره انجام می‌شود. توانایی کلی شبکه عصبی مصنوعی یادگیری ارتباط غیرخطی بین داده‌ها و تعیین نتایج برای داده‌های دیگر است (کارایاتیر و نقسانویولوس، ۱۹۹۳). در مسایل سری‌های زمانی تعداد نرون‌های ورودی به تعداد مشاهدات تأخیر داده شده، که برای یافتن ارتباط موجود در سری‌های زمانی و برای پیش‌بینی‌های مقادیر آینده استفاده می‌شود، بستگی دارد. با استفاده از قضیه‌ای در ریاضی می‌توان اثبات نمود که شبکه‌های MLP سه لایه، برای تخمین هر تابع پیچیده غیرخطی با دقت مورد نظر مناسب هستند (سینکو، ۱۹۸۹).

**شبکه MLP:** شبکه‌های موسوم به پرسپترون چندلایه (MLP) که در شکل ۱ نشان داده شده است یکی از متداول‌ترین شبکه‌ها در پیش‌بینی و حل مسایل غیرخطی می‌باشند (هیچت نیلسون، ۱۹۸۷). آموزش این شبکه‌ها با استفاده از الگوریتم معروف پس انتشار خطأ<sup>۱</sup> (BP) صورت می‌پذیرد. الگوریتم پس انتشار خطأ اساساً از دو مسیر اصلی تشکیل می‌شود. مسیر اول به مسیر رفت<sup>۲</sup> موسوم است که در این مسیر، بردار ورودی به شبکه MLP اعمال می‌شود و تأثیرات آن از طریق لایه‌های پنهان، به لایه خروجی انتشار می‌یابد. مقادیر ورودی‌ها برای هر نرون، از رابطه (۳) محاسبه می‌شود:

$$net_i^n = \sum_{j=1}^m w_{ji}^n \cdot O_j^{n-1} \quad (3)$$

در این رابطه  $net_i^n$ ، مقادیر ورودی نرون  $i$  در لایه  $n$ ،  $W_{ji}^n$  وزن اتصالی بین نرون  $j$  در لایه  $n-1$  و نرون  $i$  در لایه  $(n-1)$  است.  $O_j^{n-1}$  خروجی نرون  $j$  در لایه  $(n-1)$  است و  $M$  تعداد نرون‌ها در لایه  $(n-1)$  است.



شکل ۱- شبکه عصبی مصنوعی پرسپترون چند لایه.

در هر نرون مقادیر محاسبه شده از معادله (۳) با استفاده از یک تابع انتقال به عددی تبدیل شده است. تابع معمول برای این منظور، تابع سیگموئید است، که به صورت زیر مشخص شده است:

$$Sig(net_j^n) = 1/(1+Exp(-net_j^n)) \quad (4)$$

در این روابط خروجی محاسبه شده هر نرون با ضرب ماتریس وزن شبکه منتقل می‌شود. در نهایت خروجی محاسبه شده شبکه با خروجی واقعی مقایسه می‌شود. در این مرحله یک تابع هدف مناسب از قبیل میانگین مطلق خطأ<sup>۱</sup> (MAE) یا جذر میانگین مربعات خطأ<sup>۲</sup> (RMSE) که به صورت زیر محاسبه می‌شود، در نظر گرفته می‌شود.

$$MAE = \frac{\sum_{i=1}^{n_p} \sum_{j=1}^{n_o} |T_{pj} - O_{pj}|}{n_p \cdot n_o} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n_p} \sum_{j=1}^{n_o} (T_{pj} - O_{pj})^2}{n_p \cdot n_o}} \quad (6)$$

در این روابط  $T_{pj}$  خروجی هدف نرون  $j$  ام مربوط به الگوی  $p$  ام،  $O_{pj}$  خروجی محاسبه شده نرون  $j$  ام مربوط به الگوی  $p$  ام،  $n_p$  تعداد الگوها و  $n_o$  تعداد نرون‌ها در لایه خروجی است. بعد از محاسبه تابع هدف گام دوم الگوریتم BP یعنی مسیر دوم که به مسیر بازگشت<sup>۳</sup> موسوم است، شروع

1- Mean of Absolute Error

2- Root Mean of Square Error

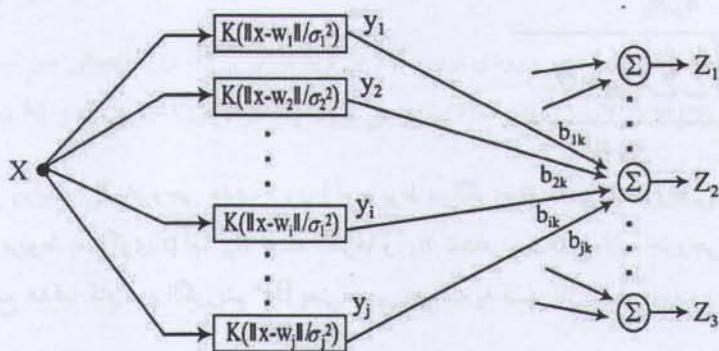
3- Backward

می‌شود. در این مسیر با استفاده از روش کاهش شبکه وزن‌های شبکه برای کاهش خطای شیک تغییریافته و تنظیم می‌گردد.

$$\Delta w_{ji}^n(m+1) = \eta \cdot \frac{\partial(E)}{\partial w_{ji}^n} + \alpha \cdot \Delta w_{ji}^n(m) \quad (7)$$

در این رابطه،  $\Delta w_{ji}^n(m+1)$ ، میزان افزایش وزن در تکرار  $(m+1)$ ،  $\eta$ ، سرعت یادگیری و  $\alpha$ ، ضریب مومنتوم است. این امر تا رسیدن مقدار خطای به یک مقدار قابل قبول ادامه می‌یابد. در اینجا مرحله یادگیری شبکه به پایان رسیده و در صورتی که شبکه در برابر یک ورودی که قبلاً آن را ندیده است قرار بگیرد می‌تواند خروجی یا خروجی‌های نظری را نگاشت نماید.

**شبکه RBF:** شبکه‌های تابع پایه شعاعی (RBF) که در شکل ۲ نشان داده شده است، از نوع شبکه‌های رو به جلو همراه با یک لایه میانی هستند که برای اولین بار توسط برومهد و لاو (۱۹۸۸) معرفی شدند. در این روش اغلب، تابع انتقال در لایه میانی، تابع گوسین و در لایه خروجی تابع خطی است (دیبیک و همکاران، ۱۹۹۹؛ ماسون و همکاران، ۱۹۹۶). عموماً آموزش شبکه RBF به دو بخش تقسیم می‌شود. بخش اول به طور عمده یادگیری از نوع بدون نظارت است که با استفاده از روش‌های خوشبندی، پارامترهای تابع پایه (مراکز و عرض‌ها)، با استفاده از اطلاعات ورودی تعیین می‌شود و در بخش دوم که یادگیری از نوع با نظارت است وزن‌های بین لایه میانی و لایه خروجی با استفاده از روش‌های کاهش شبیب و رگرسیون خطی تعیین می‌شود.



شکل ۲- شبکه عصبی مصنوعی تابع پایه‌ای شعاعی

نرون میانی RBF با پارامترهای وزن به هر یک از نرون‌های ورودی متصل شده است. این پارامترها مرآکر نرون‌ها هستند. خروجی هر نرون میانی تابعی از فاصله بین بردار ورودی،  $X = [x_1, x_2, \dots, x_n]$ ، و بردار مرکز شعاعی،  $W_j = [w_{1j}, w_{2j}, \dots, w_{nj}]$ ، است که به صورت زیر محاسبه می‌شود:

$$\delta = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} \quad (8)$$

خروجی نرون میانی به روش‌های مختلفی می‌تواند محاسبه شود. عمده‌ترین تابع انتقال برای این منظور تابع گوسین است که به صورت زیر محاسبه می‌شود (ماسون و همکاران، ۱۹۹۶):

$$f(\delta_j) = \text{Exp}(-\lambda \cdot \delta_j^2) \quad (9)$$

در این رابطه،  $\lambda$  ضریب ثابت است. در نهایت خروجی‌های لایه خروجی از رابطه زیر محاسبه می‌شوند:

$$Z_k = \sum_{j=1}^J b_{jk} y_j \quad (10)$$

در این رابطه،  $b_{jk}$  ضریب وزن بین  $j$ -امین نرون لایه میانی و  $k$ -امین نرون لایه خروجی و  $y_j$ ، خروجی  $j$ -امین نرون لایه میانی است.

طراحی ساختار شبکه عصبی مصنوعی: به منظور مدل‌سازی داده‌های هر یک از سری‌های زمانی، SPI‌ها به دو بخش تقسیم شدند. مجموعه مقادیر SPI از سال آبی ۱۳۴۵-۴۶ الی ۱۳۷۷-۷۸ به عنوان داده‌های آزمون شبکه آموزش شبکه و مقادیر SPI از سال ۱۳۷۸-۷۹ الی ۱۳۸۵-۸۶ به عنوان داده‌های آزمون شبکه مورد استفاده قرار گرفتند. همچنین به منظور آموزش بهتر شبکه‌ها ۲۰ درصد داده‌های آموزش را به صورت تصادفی انتخاب و برای ارزیابی مدل قرار داده شد. برای پیش‌بینی سری‌های زمانی با استفاده از شبکه عصبی مصنوعی، تعیین تعداد نرون‌های ورودی (سری مقادیر مشاهده شده در گام‌های پیشین) برای شناسایی فرآیندها در گام‌های زمانی آینده از اهمیت ویژه‌ای برخوردار است. تابع انتقال، روابط بین ورودی‌ها و خروجی‌های نرون‌های شبکه را تعیین می‌کند. در پژوهش حاضر پس از سعی و خطای فراوان، تابع سیگموئید به عنوان تابع انتقال در شبکه‌ها انتخاب شد.

اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای دوری از چنین شرایطی و همچنین به منظور یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال‌سازی صورت می‌گیرد که این کار مانع از کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام

نرون‌ها می‌گردد (بهمنی و همکاران، ۲۰۰۶). بنابراین قبل از آموزش، برای نرمال‌سازی داده‌های مورد استفاده از رابطه (۹) استفاده شد:

$$x_n = \frac{X_n - X_{\min}}{X_{\max} - X_{\min}} \quad (11)$$

$X_n$ : مقدار نرمال شده پارامتر،  $X$ : مقدار واقعی هر پارامتر،  $X_{\min}$ : کمترین مقدار پارامتر مورد نظر و  $X_{\max}$ : بیشترین مقدار پارامتر مورد نظر می‌باشد.

نرون‌های ورودی از ۱ تا ۱۱ برای تمام SPI‌ها آزمون شدند، تعداد نرون‌های لایه ورودی و لایه میانی با سعی و خطأ تعیین شد. شبکه‌ها با الگوریتم‌های مختلف آموزش داده و ضریب همبستگی (R) و جذر میانگین مربعات خطأ (RMSE) برای تمام مدل‌ها محاسبه شد (میشرا و دیسائی، ۲۰۰۶). شبکه‌ای که کمترین جذر میانگین مربعات خطأ و بیشتر ضریب همبستگی را دارا بود به عنوان بهترین شبکه انتخاب شد. به‌منظور بررسی عملکرد مدل‌های مورد آزمون و تعیین میزان دقیق مدل طراحی شده، علاوه‌بر ترسیم نمودارهای مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده توسط شبکه‌ها، از دو پارامتر میانگین مطلق خطأ (MAE) و جذر میانگین مربعات خطأ (RMSE) نیز استفاده گردید.

به‌منظور یافتن بهترین شبکه، در هر یک از شبکه‌ها، به‌طور مرتب قوانین یادگیری مختلف در ارتباط با تابع انتقال مختلف به صورت دو به دو، تا زمان رسیدن به بهترین حالت آزمایش شد. همچنین شبکه در حالت ۱ تا ۱۱ نرون در لایه ورودی و با تعییر افزایش تعداد نرون‌های لایه میانی در هر دو شبکه، برای هر یک از سری‌های زمانی SPI آزمایش شد. که در نهایت ۱۵۳ مدل برای شبکه MLP و ۱۸۴ مدل برای شبکه RBF، برای هر سری زمانی SPI ارزایه شد. پس از آن همان‌گونه که ذکر شد، ضریب همبستگی و جذر میانگین مربعات خطأ برای هر ترکیب ورودی و نرون‌های میانی محاسبه شد، شبکه‌ای که بیشترین ضریب همبستگی و کمترین جذر میانگین مربعات خطأ را دارا بود به عنوان بهترین شبکه انتخاب شد.

**سری زمانی ARIMA:** سری زمانی به مجموعه‌ای از مشاهدات و یا مقادیر ثبت شده از یک متغیر گفته می‌شود که بر حسب زمان مرتب شده باشد. مدل‌های استوکستیک که به مدل‌های سری زمانی معروف هستند در زمینه‌های مختلف از جمله اقتصاد، علوم مهندسی و... کاربردهای زیادی را دارد. روش‌های مدل‌سازی سری‌های زمانی یک روش تجربی سیستماتیکی را برای شبیه‌سازی و پیش‌بینی رفتار سیستم‌های هیدرولوژیکی نامعلوم و برای کمی‌سازی دقت مورد انتظار پیش‌بینی‌ها به کار می‌برند.

در اوایل دهه ۶۰ میلادی مدل‌های اتورگرسیو استفاده‌ای گسترده‌ای در مهندسی هیدرولوژی و منابع آب داشته‌اند. یکی از مشکلاتی که در مدل‌های خود همبسته برای مدل‌سازی سری‌های زمانی هیدرولوژیکی وجود داشت، تغییرات سری در شرایط خاص بودکه در صورت استفاده از مدل‌های خود همبسته به تنها، این تغییرات به خوبی مدل نخواهد شد. جهت رهایی از این مشکل، بخش دیگری تحت عنوان میانگین متحرک به رابطه ارایه و یک مدل ترکیبی تحت عنوان مدل خود همبسته میانگین متحرک (ARMA) ارایه شد.

شرط استفاده از مدل‌های ARMA، ایستا بودن سری زمانی است. در صورت ایستا نبودن سری زمانی، آن را باید ایستا نمود. باکس و جنکینز در سال ۱۹۷۶ با استفاده از اولین، دومین یا به طور کلی  $d$  امین تفاضل سری، سری زمانی را ایستا و با مدل‌سازی آن با ARMA $(p,q)$  منجر به پیدایش سری جدیدی از مدل‌های آماری موسوم به مدل‌های آریما غیرفصلی (ARIMA $(p,d,q)$ ) می‌گردد. مدل ARIMA غیرفصلی، اتورگرسیو با درجه  $p$ ، میانگین متحرک با درجه  $q$  و عملگر  $d$  امین تفاضل‌گیری از سری زمانی است. بنابراین مدل ARIMA با سه پارامتر  $(p,d,q)$  که می‌تواند صفر یا مثبت باشد مشخص می‌شود.

مدل آریما غیرفصلی به صورت زیر نوشته می‌شود:

$$\phi(B)\nabla^d Z_t = \theta(B)a_t \quad (12)$$

که  $\phi(B)$  و  $\theta(B)$  چندجمله‌ای‌هایی از درجه  $p$  و  $q$  به ترتیب هستند:

$$\phi(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \quad (13)$$

$$\theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \quad (14)$$

در صورت استفاده از عملگر تفاضل فصلی با تأخیر  $s$  و برازش آنها با مدل‌های ARMA $(p,q)$  مدل‌های فصلی آریما $(P,D,Q)_s$  ARIMA $(P,D,Q)_s$  به وجود می‌آید.

باکس و همکاران (۱۹۹۴) با ترکیب مدل‌های فصلی و غیرفصلی، مدل‌های موسوم به آریمای فصلی مکث<sup>۱</sup> را که به SARIMA معروف است را تشکیل می‌دهند. در کل مدل ساریما به صورت ARIMA $(p,d,q)(P,D,Q)_s$  نامیده می‌شود که عبارت  $(p,d,q)$  بخش غیرفصلی مدل و عبارت  $(P,D,Q)_s$  بخش فصلی مدل است که به صورت زیر بیان می‌شود:

$$\phi_p(B)\phi_p(B^S)\nabla^d \nabla^D_S Z_t = \theta_q(B)\Theta Q(B^S)a_t \quad (15)$$

$p$ : درجه اتورگرسیو غیرفصلی،  $d$ : درجه تفاضل گیری،  $q$ : درجه میانگین متحرک غیرفصلی،  $P$ : درجه اتورگرسیو فصلی،  $D$ : درجه تفاضل گیری فصلی،  $Q$ : درجه میانگین متحرک فصلی و  $S$ : طول فصل است. به طور کلی مدل سازی سری های زمانی شامل سه مرحله شناسایی مدل، تخمین پارامترهای مدل و تشخیص درستی مدل است (باکس و جنکنز، ۱۹۷۶).

## نتایج و بحث

پردازش داده ها با استفاده از شبکه عصبی مصنوعی MLP و RBF: نتایج نشان داد که از بین توابع یادگیری، تابع انتقال سیگموئید و از بین قوانین یادگیری، قانون یادگیری Delta Bar Delta کمترین خطأ و بیشترین ضریب همبستگی را دارند. در شبکه MLP تعداد نرون های لایه میانی و در شبکه RBF تعداد مراکز به ترتیب افزایش یافت و برای هر یک از سری زمانی SPI ها آزمایش شدند. نتایج نشان داد که شبکه های عصبی مصنوعی MLP با تعداد نرون های لایه میانی کمتر از تعداد نرون های ورودی و شبکه های عصبی مصنوعی RBF مراکز بیشتر از تعداد نرون های ورودی، کمترین خطأ و بیشترین ضریب همبستگی را خواهند داشت.

به منظور ارزیابی و بررسی عملکرد مدل های مورد آزمون و تعیین میزان دقیق مدل طراحی شده علاوه بر استفاده از دو پارامتر میانگین مطلق خطأ (MAE) و جذر میانگین مربعات خطأ (RMSE) از ترسیم زوج های مرتب مقادیر مشاهده شده در برابر مقادیر پیش بینی شده توسط شبکه ها، نیز استفاده گردید. نتایج، برتری کارایی شبکه MLP را نسبت به شبکه RBF در تمام سری های زمانی SPI ها (کوتاه مدت و بلند مدت) نشان داد.

در جدول ۱ مقادیر پارامترهای  $R^2$ , MAE, RMSE برای تخمین کوتاه مدت و بلند مدت برای هر دو نوع شبکه آمده است (منظور از دوره کوتاه مدت دوره های ۱ تا ۹ ماهه و دوره بلند مدت ۱۲ تا ۴۸ ماهه می باشد). به عنوان مثال برای تخمین SPI12 با استفاده از شبکه عصبی MLP، بهترین ساختار به صورتی است که در لایه ورودی ۱۰ نرون، در لایه نهان ۷ نرون و در لایه خروجی ۱ نرون وجود داشته باشد. یعنی با تأخیر زمانی ۱۰ ماهه قبل می توان یک ماه جلوتر را پیش بینی کرد. در این حالت مقدار  $R^2$  برابر ۰/۹۵۳۸، مقادیر MAE و RMSE به ترتیب برابر ۰/۱۴۷۶ و ۰/۱۹۷۴ می باشد. نتایج این جدول نشان می دهد که حداقل مقدار  $R^2$  در هر سه روش مربوط به SPI12 می باشد. که

توسط شبکه MLP تخمین زده شده است. با توجه به اینکه SPI12 میانگین متحرک زمانی ۱۲ ماهه می‌باشد لذا تناوب رطوبتی (وضعیت‌های تر و خشک) در طول دوره مورد بررسی تغییر نمی‌کند. ضمن آنکه کمترین مقادیر MAE و RMSE مربوط به SPI48 با استفاده از روش MLP می‌باشد.

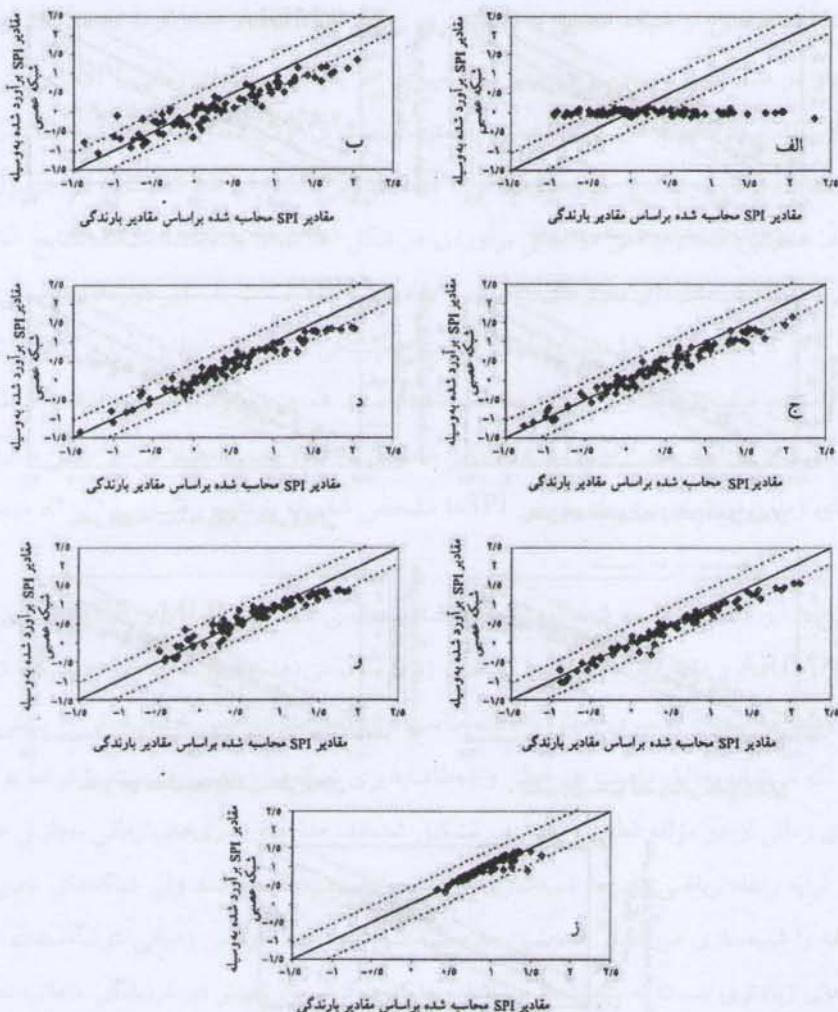
جدول ۱- نتایج حاصل از آزمایش شبکه‌های RBF، MLP و سری زمانی در بهترین حالت یادگیری برای هر یک از SPI‌ها.

تعداد داده‌ها	مدل	R <sup>2</sup>	MAE	RMSE
	MLP (11-25-1)	0.903	0.3544	0.8463
498	RBF (10-10-1)	0.9130	0.6604	0.8504
	ARIMA (1,0,2)	0.9001	0.8897	0.8656
	MLP (6-5-1)	0.8654	0.2803	0.3536
496	RBF (3-5-1)	0.8179	0.3023	0.5199
	ARIMA (2,0,2)(1,1,1) <sub>12</sub>	0.7631	0.3797	0.5773
	MLP (8-4-1)	0.9033	0.1673	0.2144
493	RBF (5-10-1)	0.9297	0.2543	0.3582
	ARIMA (1,0,1)(3,1,1) <sub>12</sub>	0.7921	0.2909	0.3668
	MLP (10-2-1)	0.9409	0.1627	0.2173
490	RBF (5-25-1)	0.9202	0.1811	0.2497
	ARIMA (2,0,2)(0,0,1)	0.8071	0.2780	0.3119
	MLP (10-7-1)	0.9038	0.1479	0.1974
487	RBF (3-7-1)	0.9321	0.1698	0.2493
	ARIMA (1,0,2)(0,1,3) <sub>12</sub>	0.8603	0.1901	0.2046
	MLP (8-5-1)	0.8932	0.1379	0.1827
476	RBF (4-17-1)	0.8605	0.1533	0.1864
	ARIMA (2,0,1)(1,0,2) <sub>12</sub>	0.8216	0.1804	0.2234
	MLP (7-15-1)	0.8208	0.0802	0.1130
461	RBF (2-6-1)	0.8120	0.1000	0.1213
	ARIMA (2,1,3)(2,1,1) <sub>12</sub>	0.8094	0.0903	0.1305

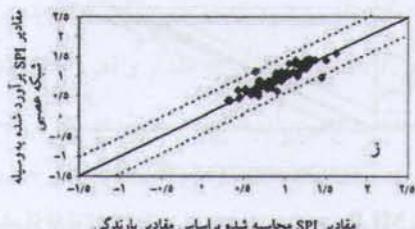
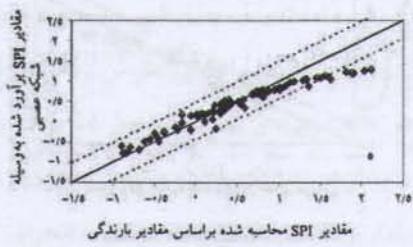
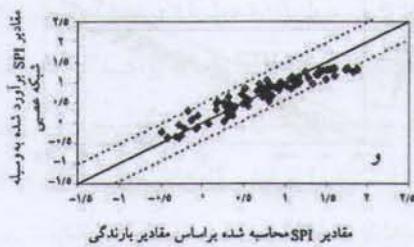
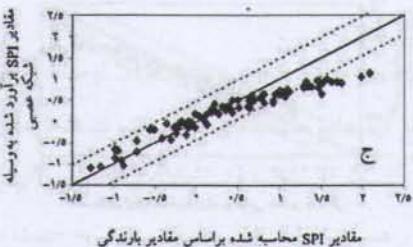
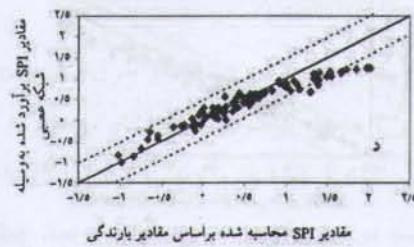
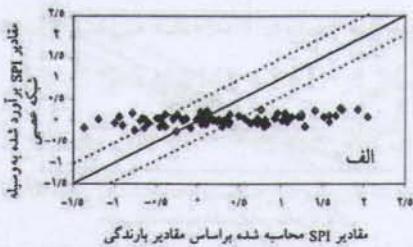
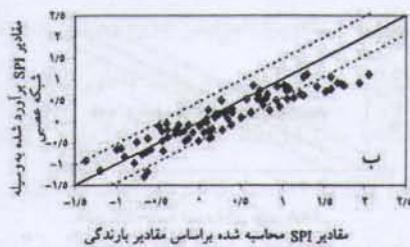
با توجه به جدول ۱ ملاحظه می‌شود که در شبکه MLP با افزایش دوره زمانی شاخص خشکسالی از SPI1 تا SPI48 مقادیر MAE و RMSE هر دو کاهش می‌یابند به طور مثال مقدار قدر مطلق خطا در وضعیت خشکسالی یک ماهه (SPI1) با مدل (11-25-1) MLP مقدار ۰/۶۵۴۴ می‌یابد که در مورد وضعیت خشکسالی ۴۸ ماهه (SPI48) به ۰/۰۸۵۲ کاهش می‌یابد که با نتایج میشرا و دیسای (۲۰۰۶) همسو بوده است. ضمن آنکه ضریب همبستگی در SPI1 بسیار کم (۰/۰۵۰۳) می‌باشد.

چنان‌چه مقادیر محاسبه شده SPI توسط دو نوع شبکه عصبی برای هر یک از سری‌های زمانی، در برابر داده‌های مشاهده‌ای ترسیم شوند شکل‌های ۳ و ۴ حاصل می‌شوند. نتایج نشان می‌دهد که در مجموع شبکه MLP با دقت بالاتری مقادیر را پیش‌بینی می‌کنند که با نتایج کریپسو و مورا (۱۹۹۳) و نجفی و همکاران (۲۰۰۶) مطابقت دارد. به جهت مقایسه در این شکل‌ها محدوده  $\pm 30$  درصد خطا نیز نشان داده شده است و همچنین شیب خط رگرسیون با شیب خط ۱:۱ (خط ۴۵ درجه) مقایسه شد. نتایج نشان می‌دهد که با افزایش مقیاس زمانی از SPI1 ماهه تا SPI48 ماهه، پراکندگی داده‌ها در محدوده  $\pm 30$  درصد و در اطراف خط ۴۵ درجه بیشتر و همچنین شیب خط رگرسیون نیز بیشتر می‌شود. با توجه به اینکه SPI، میانگین متحرک زمانی است و با افزایش گام‌های میانگین‌گیری (از ۱ تا ۴۸ ماه)، نوسانات کاهش یافته در نتیجه انحراف داده‌ها از خط ۴۵ درجه بیشتر خواهد شد.

با توجه به شکل‌های ۳ و ۴ ملاحظه می‌شود که در دوره‌های کوتاه‌مدت (الف، ب، ج و د) در هر دو روش MLP و RBF مقادیر SPI بزرگ، کمتر از مقدار واقعی تخمین زده شده‌اند. بدعا بر دیگر وضعیت رطوبتی، خشک‌تر از مقدار واقعی برآورده شده است در حالی که در دوره‌های درازمدت (شکل‌های ۳ و ۴ قسمت‌های ه، و، و ز) به خصوص SPI12 این خطا کمتر است و وضعیت خشکسالی واقعی با مقادیر برآورده شده توسط روش‌های MLP و RBF به یکدیگر نزدیک‌تر هستند.



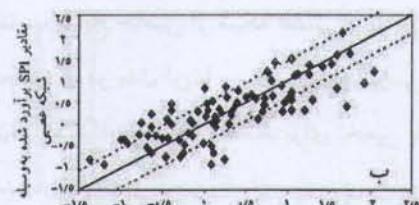
شکل ۳- مقایسه نتایج حاصل از به کار گیری شبکه عصبی مصنوعی MLP در دوره های مختلف زمانی SPI  
 الف- SPI1 (یک ماهه)، ب- SPI3 (سه ماهه)، ج- SPI6 (شش ماهه)، د- SPI9 (نه ماهه)  
 ه- SPI12 (دوازده ماهه)، و- SPI24 (بیست و چهار ماهه)، ز- SPI48 (چهل و هشت ماهه)



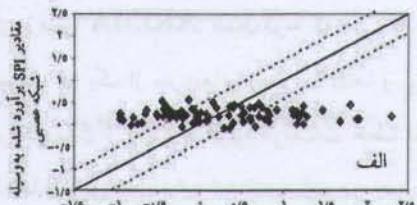
شکل ۴- مقایسه نتایج حاصل از به کار گیری شبکه عصبی مصنوعی RBF در دوره های مختلف زمانی SPI  
الف- SPI1 (یک ماهه)، ب- SPI3 (سه ماهه)، ج- SPI6 (شش ماهه)، د- SPI9 (نه ماهه)  
ه- SPI12 (دوازده ماهه)، و- SPI24 (بیست و چهار ماهه)، ز- SPI48 (چهل و هشت ماهه)

مقایسه نتایج حاصل از شبکه عصبی با نتایج سری زمانی ARIMA: همان‌گونه که ذکر شد در این تحقیق، از دو مدل آریما و ساریما برای بررسی تغییرات هر یک از سری‌های زمانی SPI‌ها و پیش‌بینی آن در ایستگاه نوده استفاده شد. برای تخمین پارامترهای مدل از روش کمترین مربعات خطأ استفاده شد. در نهایت برای هر یک از سری‌های زمانی SPI‌ها بهترین مدل ارایه شد که نتایج در جدول (۱) ارایه شد. همچنین مقادیر واقعی در مقابل برآوردهای SPI12 نسبت به سایر دوره‌های زمانی این نشان می‌دهد که در مدل‌های سری‌های زمانی نیز مقادیر شاخص (۱، ۳، ۶، ۹، ۲۴ و ۴۸ ماهه) حداقل ضریب همبستگی و کمترین خطأ را دارا می‌باشد. نتایج حاصل از شبکه عصبی مصنوعی و سری‌های زمانی برتری کارایی نسبی شبکه‌های عصبی مصنوعی در مقابل مدل‌های سری‌های زمانی در تمام سری‌های زمانی SPI‌ها مشخص شد. که با نتایج رضایی (۲۰۰۱)، میشرا و دیسای (۲۰۰۶) هم‌سو بوده است.

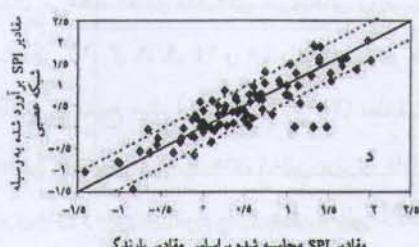
شکل ۶ نیز مقادیر محاسبه شده توسط شبکه‌های عصبی مصنوعی MLP و RBF، سری‌های زمانی ARIMA و مقادیر مشاهده‌ای را در طول زمان نشان می‌دهد. نتایج نشان می‌دهد که شبکه عصبی مصنوعی نسبت به سری زمانی با دقت مناسب‌تری تغییرات شاخص خشک‌سالی را پیش‌بینی می‌کند. که می‌توان به دلیل ماهیت غیرخطی و انعطاف‌پذیری شبکه‌های عصبی دانست. با توجه به اینکه هر سری زمانی از دو مؤلفه قطعی و تصادفی تشکیل شده‌اند، مدل‌های سری‌های زمانی به دلیل خطی بودن و ارایه رابطه ریاضی قادر به شبیه‌سازی مؤلفه تصادفی سری نمی‌باشند ولی شبکه‌های عصبی هر دو مؤلفه را شبیه‌سازی می‌کنند. همچنین ملاحظه می‌شود که مقیاس زمانی کوتاه‌مدت دارای نوسان‌های زیادتری نسبت به بلندمدت می‌باشد و با کوچک‌ترین تغییر در بارندگی ماهانه سریعاً عکس العمل نشان می‌دهد. ضمن این‌که خشک‌سالی‌های کوتاه‌مدت، از فراوانی و قوع بیشتری برخوردار است به طوری که با افزایش مقیاس زمانی از فراوانی خشک‌سالی‌های کاسته شده است (شکل ۶).



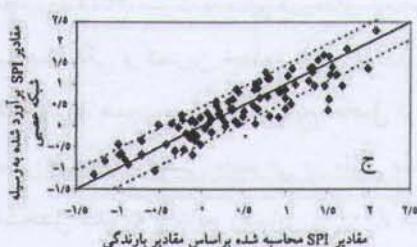
مقادیر SPI محاسبه شده براساس مقادیر بارندگی



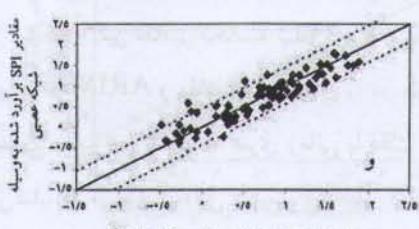
مقادیر SPI محاسبه شده براساس مقادیر بارندگی



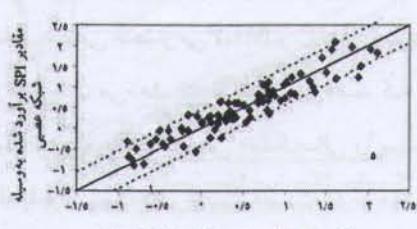
مقادیر SPI محاسبه شده براساس مقادیر بارندگی



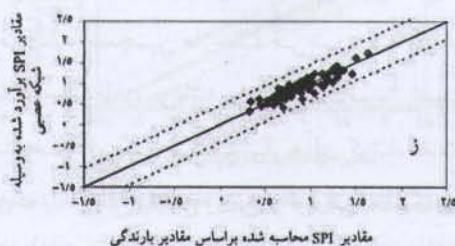
مقادیر SPI محاسبه شده براساس مقادیر بارندگی



مقادیر SPI محاسبه شده براساس مقادیر بارندگی

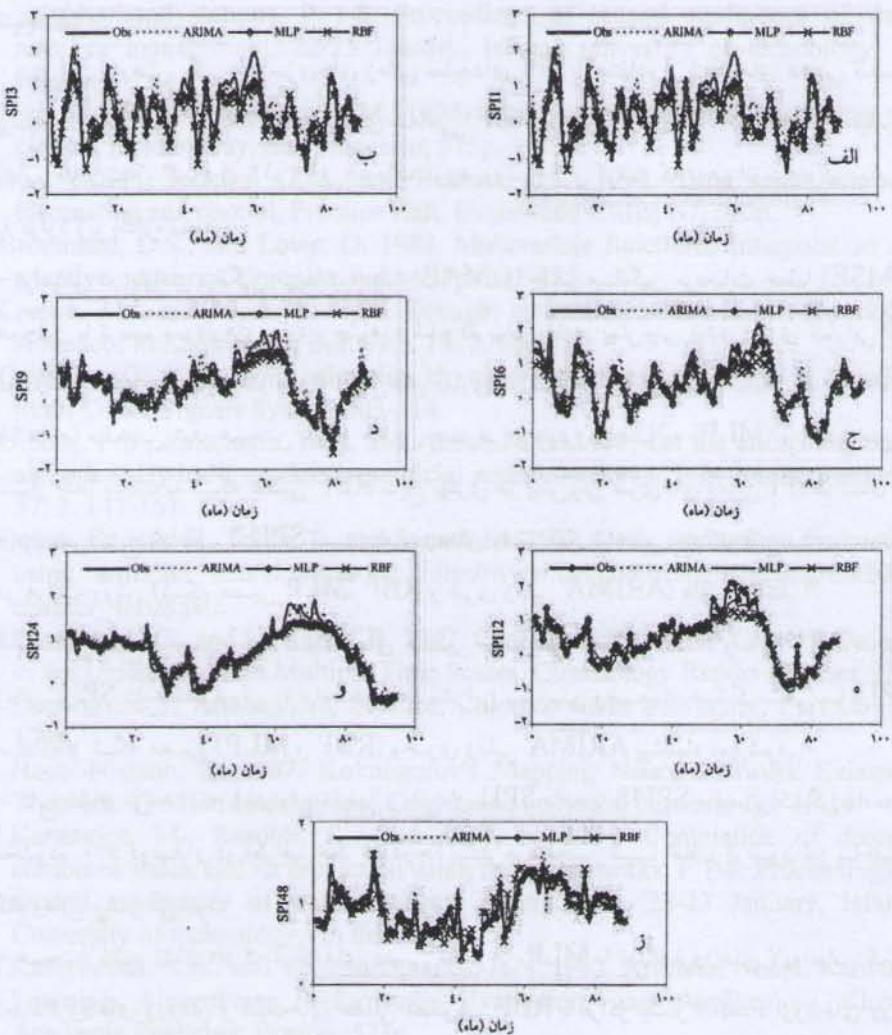


مقادیر SPI محاسبه شده براساس مقادیر بارندگی



مقادیر SPI محاسبه شده براساس مقادیر بارندگی

شکل ۵- مقایسه نتایج حاصل از به کار گیری سری زمانی ARIMA در دوره های مختلف زمانی SPI  
الف- SPI1 (یک ماهه)، ب- SPI3 (سه ماهه)، ج- SPI6 (شش ماهه)، د- SPI9 (نه ماهه)  
ه- SPI12 (دوازده ماهه)، و- SPI24 (بیست و چهار ماهه)، ز- SPI48 (چهل و هشت ماهه)



شکل ۶- مقایسه نتایج پیش‌بینی مدل‌های ARIMA و RBF با مقداری واقعی ایستگاه نوده در طول دوره آزمون (مهر ۱۳۷۸ الی شهریور ۱۳۸۶).

الف- SPI1 (یک ماهه)، ب- SPI3 (سه ماهه)، ج- SPI6 (شش ماهه)، د- SPI9 (نه ماهه)  
ه- SPI12 (دوازده ماهه)، و- SPI24 (پیست و چهار ماهه)، ز- SPI48 (چهل و هشت ماهه)

### نتیجه‌گیری

در این پژوهش پیش‌بینی سری‌های زمانی نمایه‌های SPI با استفاده از شبکه‌های عصبی مصنوعی پرسپترون چندلایه (MLP) و تابع پایه‌ای شعاعی (RBF) و روش آماری ARIMA، در مقیاس‌های زمانی متفاوت ۱، ۳، ۶، ۹، ۱۲، ۲۴ و ۴۸ ماهه مورد بررسی قرار گرفت که به عنوان نتیجه‌گیری می‌تواند به موارد زیر اشاره نمود.

- براساس دو پارامتر میانگین مربعات خطأ (MAE) و جذر میانگین مربعات خطأ (RMSE) همچنین با ترسیم نمودارهای مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده، برتری کارایی نسبی شبکه‌های عصبی مصنوعی در مقابل روش‌های آماری در تمام سری‌های زمانی (۱، ۳، ۶، ۹، ۱۲، ۲۴ و ۴۸ ماهه) مشخص شد. همچنین شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) و الگوریتم پرسپترون خطأ نسبت به شبکه عصبی RBF نتایج بهتری در پیش‌بینی سری‌های زمانی SPIها نشان داد.
- براساس نتایج حاصل، SPI12 نسبت به دوره‌های زمانی این شاخص حداقل ضریب همبستگی را در هر سه روش (شبکه عصبی RBF، MLP و سری زمانی ARIMA) دارا می‌باشد.
- براساس نتایج بدست آمده، شبکه‌های عصبی مصنوعی RBF، MLP و ARIMA در سری زمانی SPI1 نتایج قابل قبولی را ارایه نداده‌اند. بنابراین پیش‌بینی وضعیت خشکسالی با استفاده از شبکه عصبی (MLP و RBF) و سری زمانی ARIMA پیشنهاد نمی‌شود.
- نتایج نشان می‌دهد که با افزایش مقیاس زمانی از SPI1 ماهه تا SPI48 ماهه، پراکندگی داده‌ها در محدوده  $\pm 30^\circ$  درصد و در اطراف خط  $45^\circ$  درجه بیشتر و همچنین شبکه عصبی RBF نیز با افزایش گام زمانی بیشتر می‌شود.
- همچنین نتایج نشان داد که شبکه‌های عصبی مصنوعی MLP با تعداد نرون‌های لایه میانی کمتر از تعداد نرون‌های ورودی و شبکه‌های عصبی مصنوعی RBF با مرکز بیشتر از تعداد نرون‌های ورودی، کمترین خطأ و بیشترین ضریب همبستگی را خواهند داشت.

### منابع

1. ASCE, Task Committee on Application of Artificial Neural Networks in Hydrology. 2000. Artificial neural networks in hydrology. I. Preliminary concepts. J. Hydro. Eng. 5: 2. 124-137.
2. Bahmani, A., Ebrahimi, SH., and Gholinejad, S. 2006. Development of rainfall-runoff ANN model for watershed and investigation its extend ability for

- neighborhood stations, P 1-8, Proceedings of second conference of water resource management, 22-23 January, Isfahan university of technology. (In Persian).
- 3.Box, G.E.P., and Jenkins, G.M. 1976. Time series analysis forecasting and control, Holden-Day, San Francisco, 575p.
  - 4.Box, G.E.P., Jenkins, G.M., and Reinsel, G.C. 1994. Time series analysis, forecasting and control, Prentice Hall, Englewood Cliffs, NJ, 520p.
  - 5.Broomhead, D.S., and Lowe, D. 1988. Multivariate functional interpolation and adaptive networks, Complex system, Pp: 321-355.
  - 6.Crespo, J.L., and Mora, E. 1993. Drought estimation with neural networks, *J. Advances in Engineering Software*. 18: 3. 167-170.
  - 7.Cybenko, G. 1989. Approximation by super positions of a sigmoid function. *Math Contr. Signals Syst.* 2: 303-314.
  - 8.Dibike, Y.B., Solomatine, D.P., and Abbot, M.B. 1999. On the encapsulation of numerical-Hydraulic models in artificial neural networks, *J. hydraulic Research*, 37: 2. 147-161.
  - 9.Dogan, E., Isik, S., Toluk, T., and Sanaal, M. 2007. Daily streamflow forecasting using artificial neural network, [http://www.dsi.gov.tr/english/congress2007/chapter\\_4/108.pdf](http://www.dsi.gov.tr/english/congress2007/chapter_4/108.pdf).
  - 10.Edwards, D.C., and McKee, T.B. 1997. Characteristics of 20<sup>th</sup> Century Drought in the United States at Multiple Time Scales. Climatology Report Number 97-2, Department of Atmospheric Science, Colorado State University, Fort Collins, 174p.
  - 11.Hecht-Nielson, R. 1987. Kolmogorov's Mapping Neural Network Existence Theorem. The first International Conference on neural network, Pp: 11-14.
  - 12.Karamooz, M., Rasooli, K., and nazif, S. 2006. Completion of drought combined index and its prediction using neural networks, P 1-8, Proceedings of second conference of water resource management, 22-23 January, Isfahan University of technology. (In Persian).
  - 13.Karayiannis, N.B., and Venetsanopoulos, A.N. 1993. Artificial Neural Network: Learning Algorithms, Performance Evaluation, and Application. Kluwer Academic Publisher, Boston, 523p.
  - 14.Mason, J.C., Price, R.K., and tem'me. 1996. A neural network model of rainfall-runoff using radial basis functions. *J. of Hydraulic Research*, 34: 537-548.
  - 15.McKee, T.B., Doesken, N.J., and Kleist, J. 1993. The relation of drought frequency and duration to time scales. Preprints. P 379-384, 8<sup>th</sup> Conference on Applied Climatology, 17-22 January.
  - 16.Mishra, A.K., and Desai, V.R. 2006. Drought forecasting using feed-forward recursive neural network, *Ecological Modeling*, 98: 127-138.
  - 17.Mishra, A.K., and Desai, V.R. 2005a. Spatial and temporal drought analysis in the Kansabati river basin, India. *Int. J. of River Basin Manag. IAHR*, 3: 1. 31-41.

18. Mishra, A.K., and Desai, V.R. 2005b. Drought Forecasting Using Stochastic Models, *Stochastic Environmental Research and Risk Assessment (SERRA)*, 19: 5. 326-339.
19. Mohammadi, K., Eslami, H.R., and Dayyani Dardashti, Sh. 2005. Comparison of Regression, ARIMA and ANN Models for Reservoir Inflow Forecasting using Snowmelt Equivalent (a Case study of Karaj), *J. Agri. Sci. Techn.* 7: 17-30.
20. Moried, S., Moghaddasi, M., Paemozd, SH., and Ghaemi, H. 2005. Designing drought monitoring system of Tehran province, *Applied research report ministry Energy*, 253p. (In Persian).
21. Najafi, M., Bazrafshan, J., and Poorasef, F. 2006. Management of daily drought risk for water resources of DEZ watershed, Pp: 1-12.
22. Prathumchai, K., Honda, K., and Nualchawee, K. 2001. Drought Risk Evaluation Using Remote Sensing and GIS: A case study in Lopburi Province. P 1-12, 22<sup>th</sup> Asian Conference on Remote Sensing.
23. Rezaee, A. 2001. Modeling flood and drought using artificial neural networks (ANN), P 247-256, Proceedings of the first national conference in water crisis, 8-9 March, Zabool University.
24. Sharma, B.R., and Smakhtin, V.U. 2004. Potential of water harvesting as a strategic tool for drought mitigation, International Water Management Institute, 24p. (In Persian).
25. Steinmann, A. 2003. Drought Indicators and Triggers: A Stochastic Approach to Evaluation. *Journal of the American Water Resources Association (JAWRA)*, 39: 5. 1217-1233.
26. Wilhite, D.A., and Glantz, M.H. 1985. Understanding the drought phenomenon: the role of definition. *Water Int.* 10: 111-120.
27. Wilhite, D.A., Rosenberg, N.J., and Glantz, M.H. 1986. Improving federal response to drought. *J. Climate Appl. Meteorol.* 25: 332-342.



## Comparison of different approaches for predicting SPI

**M. Eivazi<sup>1</sup>, \*A. Mosaedi<sup>2</sup> and A.A. Dehghani<sup>3</sup>**

<sup>1</sup>M.Sc. Student, Dept. of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, <sup>2</sup>Associate Prof., Dept. of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, <sup>3</sup>Assistant Prof., Dept. of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources

### Abstract

Drought is one of the most important climatic phenomena which occur in all climate conditions and regions of the earth. When the drought remains for a longtime in a region, it will affect all environmental factors in that region. Drought forecasting, therefore plays an important role in designing and management of natural resources and water resources systems, assessing plant water requirement, etc. In recent decades, (ANNs) have shown great ability in modeling and forecasting nonlinear and non-stationary time series. In this study, two types of artificial neural networks, i.e. Multi Layer Perceptron and Radial Basis Function, and ARIMA time series were applied for drought forecasting. The rainfall data of Now-deh station on Khormaloo River in Golestan province (Iran) were used. Drought conditions were calculated using SPI in short time and long time periods. Among 41 years SPI data, the first 33 years data were selected for training of models and the last 8 years data were used as test data. The results showed that artificial neural networks were able to forecast the SPI and drought conditions with higher accuracy. Meanwhile ARIMA model had also significant results for forecasting.

**Keywords:** Drought, Prediction, Artificial Neural Networks, ARIMA, MLP, RBF, SPI

---

\* Corresponding Author; Email: abmosaedi@gmail.com