



مجله پژوهش‌های حفاظت آب و خاک

مجله پژوهش‌های حفاظت آب و خاک

جلد شانزدهم، شماره دوم، ۱۳۸۸

www.gau.ac.ir/journals

مقایسه روش‌های مختلف پیش‌بینی شاخص خشک‌سالی SPI

معصومه عیوضی^۱،* ابوالفضل مساعدی^۲ و امیراحمد دهقانی^۳

^۱ دانشجوی کارشناسی ارشد گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، دانشیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ^۲ استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

تاریخ دریافت: ۸۷/۸/۲۲؛ تاریخ پذیرش: ۸۷/۲/۳۰

چکیده

خشک‌سالی یکی از پدیده‌های آب و هوایی است که در همه شرایط اقلیمی و در همه مناطق کره زمین به وقوع 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 ایستگاه 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، ۴۸ ماهه) محاسبه گردید. سپس از بین داده‌های محاسبه شده، دوره ۴۶-۱۳۴۵ الی ۷۸-۱۳۷۷ به عنوان داده آموزش و دوره ۷۹-۱۳۷۸ الی ۸۶-۱۳۸۵ 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 به‌کارگیری 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 تکرارشده 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 صراحت و شفافیت در تعریف خشک‌سالی، مانعی برای درک خشک‌سالی است، این نداشتن صراحت منجر به تردید و سستی در بخش‌های مدیریتی، سیاست‌گذاری و... می‌شود (ویلهیت و گلانترز، ۱۹۸۵؛ ویلهیت و همکاران، ۱۹۸۶). این پدیده به کندی شروع می‌شود و تأثیر آن به تدریج و در یک دوره زمانی نسبتاً طولانی در بخش‌های مختلف مانند منابع آب، کشاورزی، محیط زیست، اجتماعی، اقتصادی و... ظاهر می‌شود. از این رو تعیین دقیق زمان شروع و خاتمه این پدیده تا حدودی مشکل است. بنابراین اغلب خشک‌سالی را پدیده‌ای خزنده 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. به‌طور سنتی در چندین دهه اخیر برای پیش‌بینی خشک‌سالی از برازش و مدل‌های ریاضی به‌طور گسترده استفاده شده است. این مدل‌ها، سری‌های زمانی را به‌صورت مانا^۱ در نظر گرفته و فرآیندها را به‌صورت خطی مدل‌سازی می‌کنند. در دهه‌های اخیر با توجه به ماهیت غیرخطی پدیده‌ها، شبکه‌های عصبی مصنوعی^۲ 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 اغتشاش^۳ و خطای اندازه‌گیری است، شبکه عصبی قادر به ارائه 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^۱ 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^۲ (شاخص خشک‌سالی اقلیمی)، SWSI^۳ (شاخص خشک‌سالی هیدرولوژیکی) و PDSI^۴ (شاخص خشک‌سالی زراعی) و با استفاده از شبکه عصبی MLP^۵ 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 رویکردی دقیق‌تر و واقع‌بینانه‌تر دوره‌های خشک‌سالی را تعیین نمود.

کریسپو 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 خطا 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 دز 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 خطا 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 (۲۰۰۵b) در تحقیق خود، برای پیش‌بینی خشک‌سالی از مدل‌های احتمالاتی خطی مانند ARIMA^۱ و SARIMA^۲ با استفاده از شاخص بارش استاندارد شده (SPI) استفاده نمودند. نتایج تحقیقات آنها نشان داد که مدل‌های آماری نتایج خوبی از نظر پیش‌بینی کوتاه‌مدت خشک‌سالی (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 برازشی 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^۳ (RBF) به همراه الگوریتم‌های آموزش^۴ (LA) و توابع فعالیت^۵ (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 باران‌سنجی نوده بر روی رودخانه خرمالو در طول دوره آماری ۱۳۴۵-۴۶ تا ۱۳۸۵-۸۶ استفاده شد. این ایستگاه در موقعیت جغرافیایی ۳۷° ۴' عرض شمالی، ۵۵° ۱۵' طول شرقی و ارتفاع ۲۸۰ متر از سطح دریاهای آزاد قرار گرفته است. پس از

- 1- Auto Regressive Integrated Moving Average
- 2- Seasonal Auto Regressive Integrated Moving Average
- 3- Radial Basis Function
- 4- Learning Algorithm
- 5- 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. به‌عبارت دیگر ۷ سری زمانی شامل سری‌های زمانی SPI1، SPI3، SPI6، SPI9، SPI12، SPI24 و SPI48 برای دوره آماری ۴۶-۱۳۴۵ الی ۸۶-۱۳۸۵ 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 بر روی رطوبت خاک و در مقیاس زمانی بلندمدت بر روی رودخانه‌ها، مخازن آب و آب‌های زیرزمینی، اثر می‌گذارد. SPI قادر به محاسبه کمبود بارش در مقیاس‌های زمانی متفاوت ۳، ۶، ۹، 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 برآزش داده شده، مک‌کی و همکاران (۱۹۹۳) توزیع گاما را مناسب‌ترین توزیع برای برآزش 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).

$$Z = SPI = - \left[t - \frac{C_1 + C_2 t + C_3 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] \quad t = \sqrt{\ln \left[\frac{1}{H(x)^2} \right]} \quad 0 < H(x) \leq 0.5 \quad (1)$$

$$Z = SPI = + \left[t - \frac{C_1 + C_2 t + C_3 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] \quad t = \sqrt{\ln \left[\frac{1}{1 - H(x)^2} \right]} \quad 0.5 < H(x) \leq 1 \quad (2)$$

H(x): تابع احتمال تجمعی و مقادیر C_۱، C_۲، C_۳، d_۱، d_۲ و d_۳ در معادله‌های (۱) و (۲) به‌صورت زیر می‌باشند.

$$\begin{aligned} d_1 &= 1/432788 & C_1 &= 2/51557 \\ d_2 &= 0/189269 & C_2 &= 0/802853 \\ d_3 &= 0/001308 & C_3 &= 0/010328 \end{aligned}$$

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 برده شوند. همچنین این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها، یک نگاشت غیرخطی بین ورودی‌ها و خروجی‌ها ارائه 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 (کارایانیز و ونفسانوپولوس، 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 (سبینکو، 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 خطا^۱ (BP) صورت می‌پذیرد. الگوریتم پس انتشار خطا اساساً از دو مسیر اصلی تشکیل می‌شود. مسیر اول به مسیر رفت^۲ 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 Iⁿ در لایه n^{ام}، w_{ji}^n ، وزن اتصالی بین نرون i^{ام} در لایه n^{ام} و نرون j^{ام} در لایه (n-۱)، O_j^{n-1} خروجی نرون j^{ام} در لایه (n-۱) است و M تعداد نرون‌ها در لایه (n-۱)ام است.

-
- 1- Back Propagation
 - 2- Forward



شکل ۱- شبکه عصبی مصنوعی پرسپترون چند لایه.
لایه ورودی لایه میانی لایه خروجی

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:

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

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

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

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

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 نرون ها در لایه خروجی است. بعد از محاسبه تابع هدف گام دوم الگوریتم BP یعنی مسیر دوم که به مسیر بازگشت^۳ موسوم است، شروع

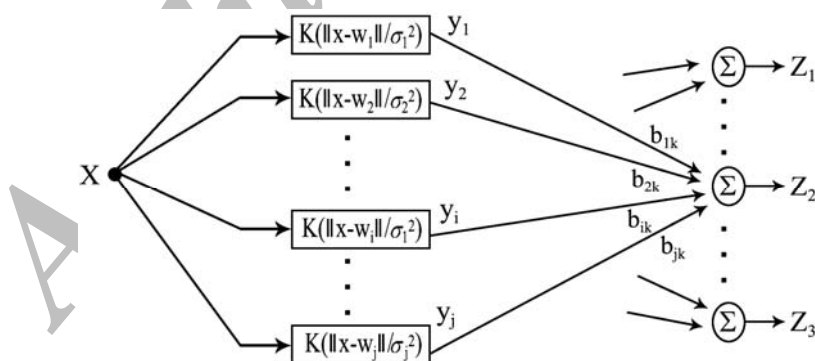
- 1- Mean of Absolute Error
- 2- Root Mean of Square Error
- 3- Backward

می‌شود. در این مسیر با استفاده از روش کاهش شیب وزن‌های شبکه برای کاهش خطا شبکه تغییر یافته و تنظیم می‌گردند.

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

در این رابطه، $\Delta w_{ji}^n(m+1)$ میزان افزایش وزن در تکرار $(m+1)$ ام، η ، سرعت یادگیری و α ، ضریب مومتوم است. این امر تا رسیدن مقدار خطا 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 نظیر 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 به‌طور عمده یادگیری از نوع بدون نظارت است که با استفاده از روش‌های خوشه‌بندی، پارامترهای توابع 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 شیب 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 مراکز 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، λ ضریب ثابت است. در نهایت خروجی‌های لایه خروجی از رابطه زیر محاسبه می‌شوند:

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

در این رابطه، b_{jk} ضریب وزن بین j آمین نرون لایه میانی و k آمین نرون لایه خروجی و y_j ، خروجی j آمین 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 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 می‌کنند. 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:

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

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 خطا تعیین شد. شبکه‌ها با الگوریتم‌های مختلف آموزش داده و ضریب همبستگی (R) و جذر میانگین مربعات خطا ($RMSE$) برای تمام مدل‌ها محاسبه شد (میشرا و دیسای، ۲۰۰۶). شبکه‌ای که کمترین جذر میانگین مربعات خطا و بیشتر ضریب همبستگی را دارا بود به‌عنوان بهترین شبکه انتخاب شد. به‌منظور بررسی عملکرد مدل‌های مورد آزمون و تعیین میزان دقت مدل طراحی شده، علاوه بر ترسیم نمودارهای مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده توسط شبکه‌ها، از دو پارامتر میانگین مطلق خطا (MAE) و جذر میانگین مربعات خطا ($RMSE$) نیز استفاده گردید.

به‌منظور یافتن بهترین شبکه، در هر یک از شبکه‌ها، به‌طور مرتب قوانین یادگیری مختلف در ارتباط با تابع انتقال مختلف به‌صورت دو به دو، تا زمان رسیدن به بهترین حالت آزمایش شد. همچنین شبکه در حالت ۱ تا ۱۱ نرون در لایه ورودی و با تغییر 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 ارایه شد. پس از آن همان‌گونه که ذکر شد، ضریب همبستگی و جذر میانگین مربعات خطا برای هر ترکیب ورودی و نرون‌های میانی محاسبه شد، شبکه‌ای که بیشترین ضریب همبستگی و کمترین جذر میانگین مربعات خطا را دارا بود به‌عنوان بهترین شبکه انتخاب شد.

سری زمانی ARIMA: سری زمانی به مجموعه‌ای از مشاهدات و یا مقادیر ثبت شده از یک متغیر گفته می‌شود که برحسب 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 به‌کار 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 بود که در صورت استفاده از مدل‌های خود هم‌بسته به تنهایی، این تغییرات به خوبی مدل نخواهند 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 به‌طور 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 غیر فصلی ARIMA (p,d,q) می‌گردد. مدل ARIMA غیر فصلی، 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 غیر فصلی به صورت زیر نوشته می‌شود:

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

که $\phi(B)$ و $\theta(B)$ چند جمله‌ای‌هایی 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 $ARIMA (P,D,Q)_s$ به وجود می‌آید.

باکس و همکاران (۱۹۹۴) با ترکیب مدل‌های فصلی و غیر فصلی، مدل‌های موسوم به آریمای فصلی مکنتر^۱ 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 غیر فصلی مدل و عبارت (P,D,Q)_s بخش فصلی مدل است که به صورت زیر بیان می‌شود:

1- Multiplicative Seasonal ARIMA

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

p: درجه اتورگرسیو غیر فصلی، d: درجه تفاضل گیری، q: درجه میانگین متحرک غیر فصلی، 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 جنکینز، 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 خطا 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 خطا و بیشترین ضریب همبستگی را خواهند داشت.

به منظور ارزیابی و بررسی عملکرد مدل های مورد آزمون و تعیین میزان دقت مدل طراحی شده علاوه بر استفاده از دو پارامتر میانگین مطلق خطا (MAE) و جذر میانگین مربعات خطا (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 بلندمدت) نشان داد.

در جدول ۱ مقادیر پارامترهای R^2 ، MAE، RMSE برای تخمین کوتاه مدت و بلندمدت SPI برای هر دو نوع شبکه آمده است (منظور از دوره کوتاه مدت دوره های ۱ تا ۹ ماهه و دوره بلندمدت ۱۲ تا ۴۸ ماهه می باشند). 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 حداکثر 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 می باشد لذا تناوب رطوبتی (وضعیت های تر و خشک) در طول دوره مورد بررسی تغییر نمی کند. ضمن آنکه کمترین مقادیر MAE و RMSE مربوط به SPI48 با استفاده از روش MLP می باشد.

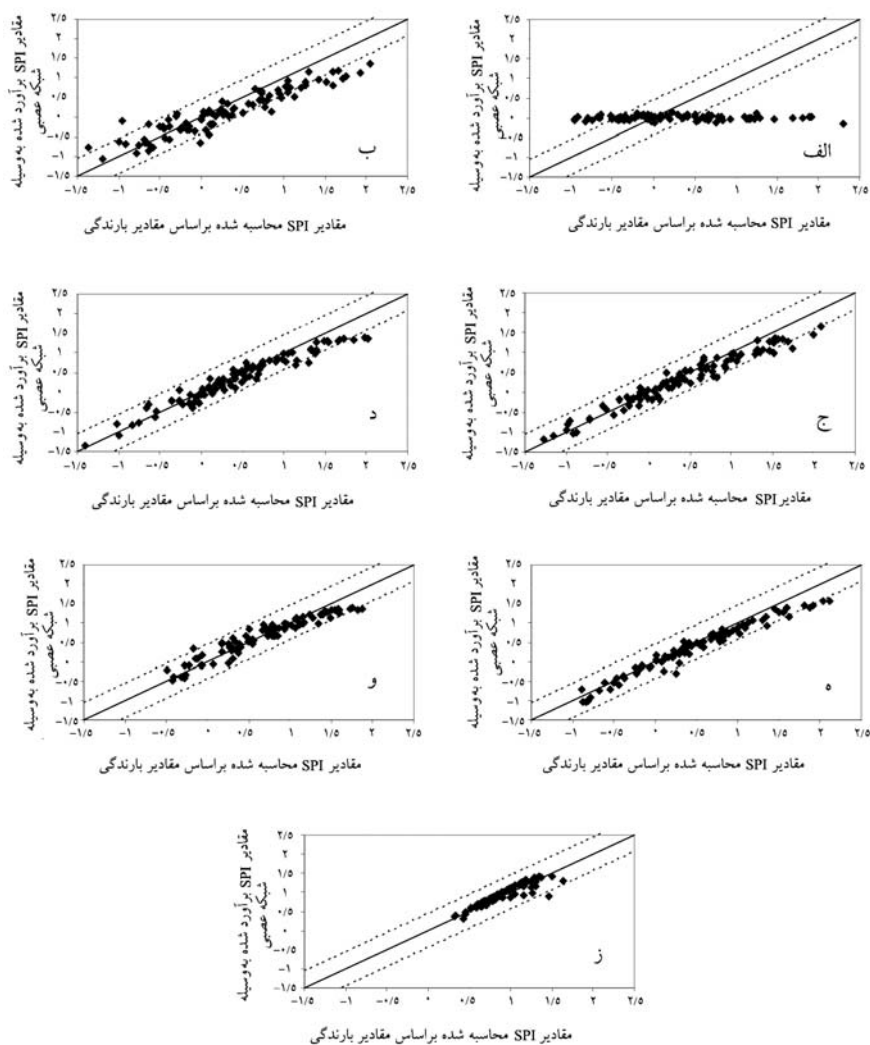
جدول ۱- نتایج حاصل از آزمایش شبکه های MLP، RBF و سری زمانی در بهترین حالت یادگیری برای هر یک از SPI ها.

| RMSE | MAE | R ² | مدل | تعداد داده ها | |
|--------|--------|----------------|------------------------------------|---------------|-------|
| ۰/۸۴۶۳ | ۰/۶۵۴۴ | ۰/۰۵۰۳ | MLP (11-25-1) | | |
| ۰/۸۵۰۴ | ۰/۶۶۰۴ | ۰/۰۱۳۰ | RBF (10-10-1) | ۴۹۸ | SPI1 |
| ۰/۸۶۵۶ | ۰/۶۸۹۷ | ۰/۰۰۰۱ | ARIMA (1,0,2) | | |
| ۰/۳۵۳۶ | ۰/۲۸۵۳ | ۰/۸۶۵۴ | MLP (6-5-1) | | |
| ۰/۵۱۹۹ | ۰/۳۰۲۳ | ۰/۸۱۷۹ | RBF (3-5-1) | ۴۹۶ | SPI3 |
| ۰/۵۷۷۳ | ۰/۳۷۹۷ | ۰/۶۰۳۱ | ARIMA (2,0,2)(1,1,1) ₁₂ | | |
| ۰/۲۱۴۴ | ۰/۱۶۷۳ | ۰/۹۵۳۳ | MLP (8-4-1) | | |
| ۰/۳۵۸۲ | ۰/۲۵۴۳ | ۰/۹۲۹۷ | RBF (5-10-1) | ۴۹۳ | SPI6 |
| ۰/۳۶۶۸ | ۰/۲۹۰۹ | ۰/۷۹۲۱ | ARIMA (1,0,1)(3,1,1) ₁₂ | | |
| ۰/۲۱۷۳ | ۰/۱۶۲۷ | ۰/۹۴۰۹ | MLP (10-2-1) | | |
| ۰/۲۴۹۷ | ۰/۱۸۱۱ | ۰/۹۲۵۲ | RBF (5-25-1) | ۴۹۰ | SPI9 |
| ۰/۳۱۱۹ | ۰/۲۷۸۰ | ۰/۸۰۶۱ | ARIMA (2,0,2)(0,0,1) | | |
| ۰/۱۹۷۴ | ۰/۱۴۷۶ | ۰/۹۵۳۸ | MLP (10-7-1) | | |
| ۰/۲۴۹۳ | ۰/۱۶۹۸ | ۰/۹۳۲۱ | RBF (3-7-1) | ۴۸۷ | SPI12 |
| ۰/۲۵۴۶ | ۰/۱۹۰۱ | ۰/۸۶۵۳ | ARIMA (1,0,2)(0,1,3) ₁₂ | | |
| ۰/۱۸۴۷ | ۰/۱۳۷۹ | ۰/۸۹۳۲ | MLP (8-5-1) | | |
| ۰/۱۸۶۴ | ۰/۱۵۳۳ | ۰/۸۶۵۵ | RBF (4-17-1) | ۴۷۵ | SPI24 |
| ۰/۲۳۳۴ | ۰/۱۸۵۴ | ۰/۸۲۱۶ | ARIMA (2,0,1)(1,0,2) ₁₂ | | |
| ۰/۱۱۳۰ | ۰/۰۸۵۲ | ۰/۸۲۰۸ | MLP (7-15-1) | | |
| ۰/۱۲۱۳ | ۰/۰۸۵۵ | ۰/۸۱۲۰ | RBF (2-6-1) | ۴۵۱ | SPI48 |
| ۰/۱۳۰۵ | ۰/۰۹۵۳ | ۰/۸۰۹۴ | ARIMA (2,1,3)(2,1,1) ₁₂ | | |

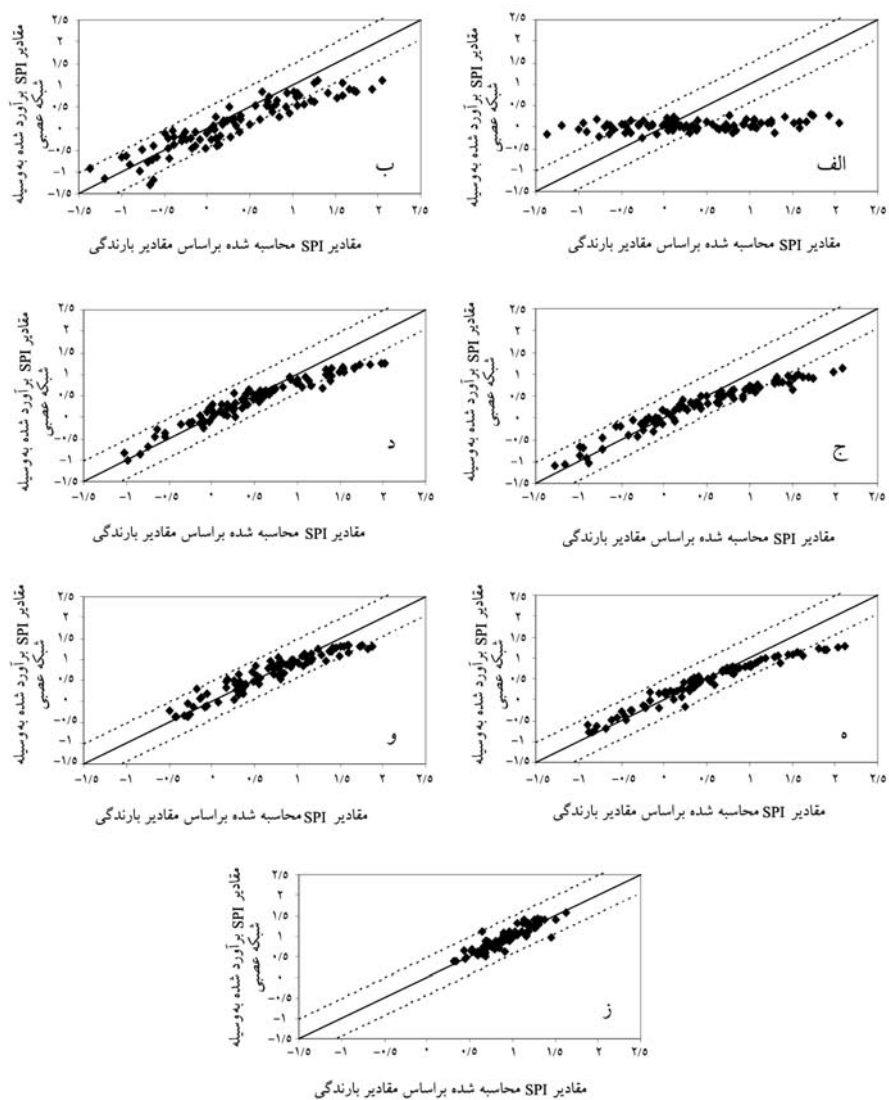
با توجه به جدول ۱ ملاحظه می‌شود که در شبکه MLP با افزایش دوره زمانی شاخص خشک‌سالی از SPI1 تا SPI48 مقادیر MAE و RMSE هر دو کاهش می‌یابند به‌طور مثال مقدار قدرمطلق خطا در وضعیت خشک‌سالی یک ماهه (SPI1) با مدل MLP (11-25-1) مقدار ۰/۶۵۴۴ می‌باشد که در مورد وضعیت خشک‌سالی ۴۸ ماهه (SPI48) به ۰/۰۸۵۲ کاهش می‌یابد که با نتایج میشرای و دیسای (۲۰۰۶) هم‌سو بوده است. ضمن آنکه ضریب همبستگی در SPI1 بسیار کم (۰/۵۰۳) 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 کریسپو 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. به‌عبارت دیگر وضعیت رطوبتی، خشک‌تر از مقدار واقعی برآورد شده است در حالی‌که در دوره‌های درازمدت (شکل‌های ۳ و ۴ قسمت‌های ه، و، و ز) به‌خصوص SPI12 این خطا کمتر است و وضعیت خشک‌سالی واقعی با مقادیر برآورد شده توسط روش‌های MLP، RBF به یکدیگر نزدیک‌تر هستند.



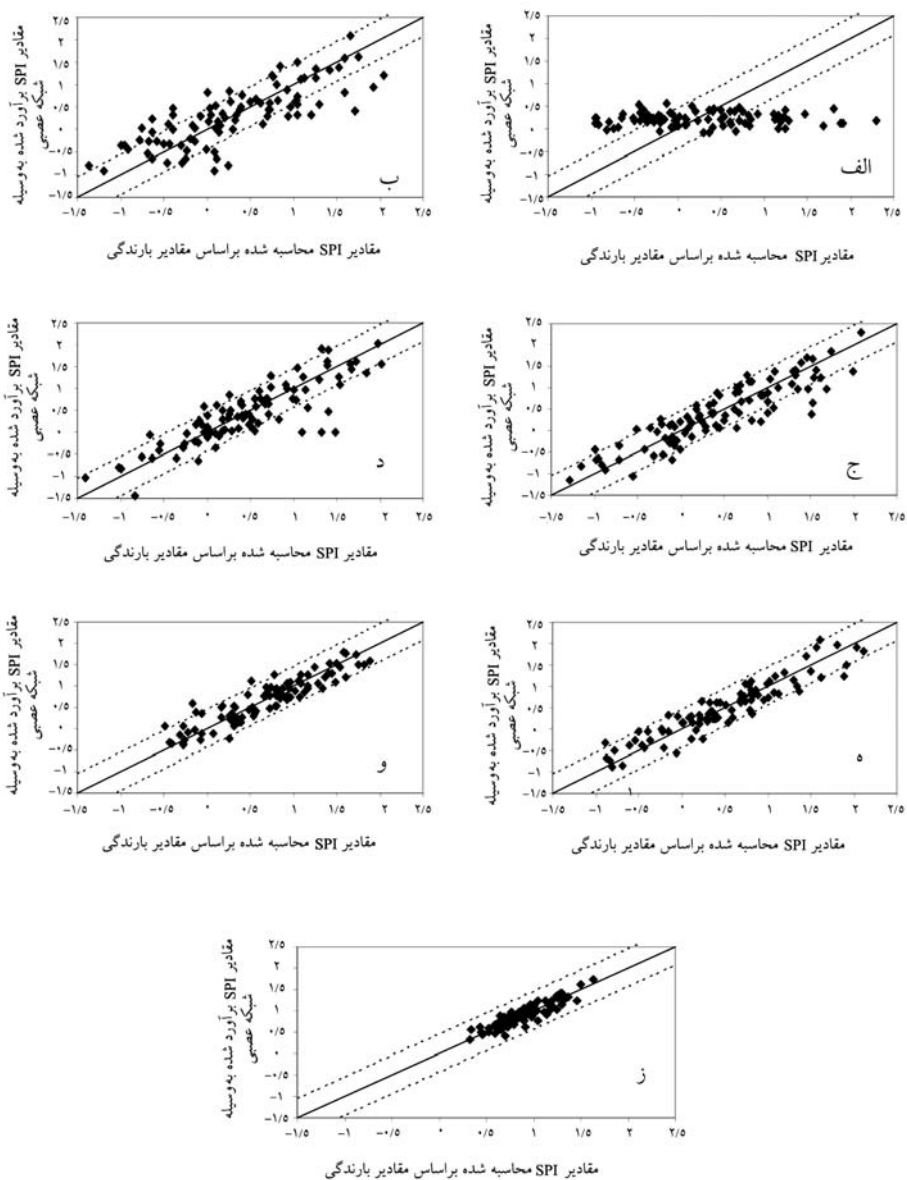
شکل ۳- مقایسه نتایج حاصل از به کارگیری شبکه عصبی مصنوعی MLP در دوره‌های مختلف زمانی SPI. الف- SPI1 (یک ماهه)، ب- SPI3 (سه ماهه)، ج- SPI6 (شش ماهه)، د- SPI9 (نه ماهه)، هـ- SPI12 (دوازده ماهه)، و- SPI24 (بیست و چهار ماهه)، ز- SPI48 (چهل و هشت ماهه)



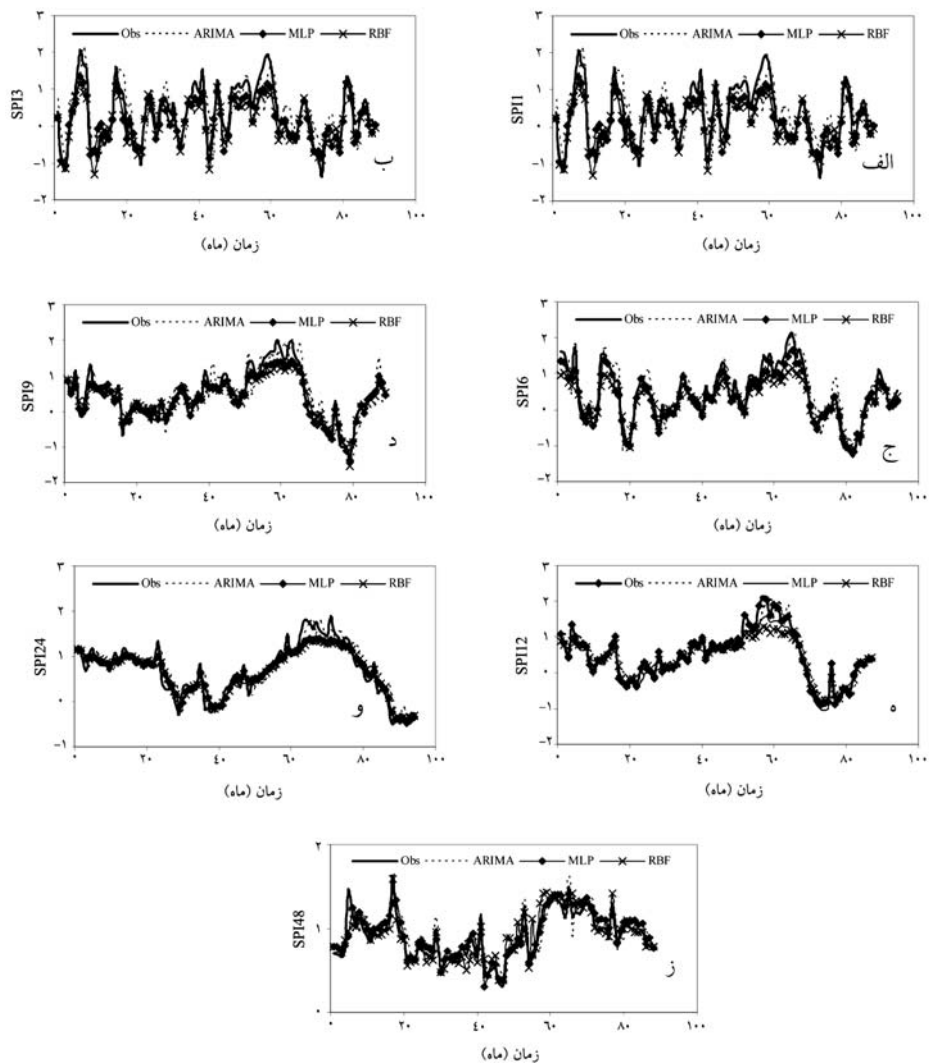
شکل ۴- مقایسه نتایج حاصل از به کارگیری شبکه عصبی مصنوعی RBF در دوره‌های مختلف زمانی SPI. الف- SPI1 (یک ماهه)، ب- SPI3 (سه ماهه)، ج- SPI6 (شش ماهه)، د- SPI9 (نه ماهه) ه- SPI12 (دوازده ماهه)، و- SPI24 (بیست و چهار ماهه)، ز- SPI48 (چهل و هشت ماهه)

مقایسه نتایج حاصل از شبکه عصبی با نتایج سری زمانی **ARIMA**: همان گونه که ذکر شد در این تحقیق، از دو مدل آریمای و ساریما برای بررسی تغییرات هر یک از سری های زمانی **SPI** ها و پیش بینی آن در ایستگاه نوده استفاده شد. برای تخمین پارامترهای مدل از روش کمترین مربعات خطا استفاده شد. در نهایت برای هر یک از سری های زمانی **SPI** ها بهترین مدل ارائه شد که نتایج در جدول (۱) ارائه شد. همچنین مقادیر واقعی در مقابل برآوردی در شکل (۵) نشان داده شده است. نتایج حاصل نشان می دهد که در مدل های سری های زمانی نیز مقادیر **SPI12** نسبت به سایر دوره های زمانی این شاخص (۱، ۳، ۶، ۹، ۲۴ و ۴۸ ماهه) حداکثر ضریب همبستگی و کمترین خطا را دارا می باشد. نتایج حاصل با نتایج میشرای و دیسای (۲۰۰۵) مطابقت داشته است. همچنین با مقایسه نتایج حاصل از شبکه عصبی مصنوعی و سری های زمانی برتری کارایی نسبی شبکه های عصبی مصنوعی در مقابل مدل های سری های زمانی در تمام سری های زمانی **SPI** ها مشخص شد. که با نتایج رضایی (۲۰۰۱)، میشرای و دیسای (۲۰۰۶) هم سو بوده است.

شکل ۶ نیز مقادیر محاسبه شده توسط شبکه های عصبی مصنوعی **MLP** و **RBF**، سری های زمانی **ARIMA** و مقادیر مشاهده ای را در طول زمان نشان می دهد. نتایج نشان می دهد که شبکه عصبی مصنوعی نسبت به سری زمانی با دقت مناسب تری تغییرات شاخص خشک سالی را پیش بینی می کند. که می توان به دلیل ماهیت غیر خطی و انعطاف پذیری شبکه های عصبی دانست. با توجه به اینکه هر سری زمانی از دو مؤلفه قطعی و تصادفی تشکیل شده اند، مدل های سری های زمانی به دلیل خطی بودن و ارایه رابطه ریاضی قادر به شبیه سازی مؤلفه تصادفی سری نمی باشند ولی شبکه های عصبی هر دو مؤلفه را شبیه سازی می کنند. همچنین ملاحظه می شود که مقیاس زمانی کوتاه مدت دارای نوسان های زیادتری نسبت به بلندمدت می باشد و با کوچک ترین تغییر در بارندگی ماهانه سریعاً عکس العمل نشان می دهد. ضمن این که خشک سالی های کوتاه مدت، از فراوانی وقوع بیشتری برخوردار است به طوری که با افزایش مقیاس زمانی از فراوانی خشک سالی های کاسته شده است (شکل ۶).



شکل ۵- مقایسه نتایج حاصل از به کارگیری سری زمانی ARIMA در دوره‌های 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 MLP, RBF و ARIMA با مقادیر 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 (بیست و چهار ماهه)، ز- SPI48 (چهل و هشت ماهه)

نتیجه گیری

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 به‌عنوان نتیجه‌گیری می‌توان به موارد زیر اشاره نمود.

- براساس دو پارامتر میانگین مربعات خطا (MAE) و جذر میانگین مربعات خطا (RMSE) و 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 پس انتشار خطا نسبت به شبکه عصبی RBF نتایج بهتری در پیش‌بینی سری‌های زمانی SPIها نشان داد.

- براساس نتایج حاصل، SPI12 نسبت به دوره‌های زمانی این شاخص حداکثر ضریب همبستگی را در هر سه روش (شبکه عصبی MLP، RBF و سری زمانی ARIMA) دارا می‌باشد.

- براساس نتایج به‌دست آمده، شبکه‌های عصبی مصنوعی MLP، RBF و ARIMA در سری زمانی SPI1 نتایج قابل‌قبولی را ارائه ندادند. بنابراین پیش‌بینی وضعیت خشک‌سالی با SPI1 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 $\pm 30\%$ درصد و در اطراف خط ۴۵ درجه بیشتر و همچنین شیب خط رگرسیون 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 مراکز بیشتر از تعداد نرون‌های ورودی، کمترین خطا 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.Broomhed, 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., Solomatin, 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.
 - 10.Edwards, D.C., and McKee, T.B. 1997. Characteristics of 20th 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, 8th 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 Asin 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. Mored, 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, 22th 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.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 16(2), 2009
www.gau.ac.ir/journals

Comparison of different approaches for predicting SPI

M. Eivazi¹, * A. Mosaedi² and A.A. Dehghani³

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