

پیش بینی خشکسالی با استفاده از مدل تلفیقی شبکه عصبی مصنوعی - موجک و مدل سری زمانی ARIMA

محبوبه یونسی^۱، نادیا شهرکی^۲، صفر معروفی^{۳*} و حامد نوذری^۴

۱- دانشجوی دکتری، گروه مهندسی آب، دانشگاه بوعلی سینا، همدان، ایران.

۲- دانشجوی دکتری، گروه مهندسی آب، دانشگاه بوعلی سینا، همدان، ایران.

۳- نویسنده مسئول، استاد گروه مهندسی آب، دانشگاه بوعلی سینا، همدان، ایران. Smarofi@yahoo.com

۴- استادیار گروه مهندسی آب، دانشگاه بوعلی سینا، همدان، ایران.

تاریخ دریافت: ۹۵/۲/۲۳

تاریخ پذیرش: ۹۵/۱۲/۴

چکیده

تبدیل موجک یکی از روش‌های نوین و بسیار موثر در زمینه تحلیل سیگنال‌ها و سری‌های زمانی است. در این روش سیگنال شاخص بارش استاندارد (SPI) با استفاده از موجک مادر منتخب تجزیه شده، داده‌های حاصل به‌عنوان ورودی مدل شبکه عصبی مصنوعی در نظر گرفته شده و یک مدل تلفیقی برای پیش‌بینی خشکسالی ارائه می‌گردد. در این تحقیق، از شبکه‌های عصبی مصنوعی پرسپترون چند لایه (MLP) و تابع پایه‌ای شعاعی (RBF)، سری زمانی ARIMA و همچنین شبکه‌های عصبی مصنوعی - موجک پرسپترون چند لایه (WA-MLP) و تابع پایه‌ای شعاعی (WA-RBF) برای پیش‌بینی استفاده شده است. در این خصوص، از داده‌های بارندگی ایستگاه بیدستان با دوره آماری ۴۴ ساله در حوضه آبریز شور استفاده شد. وضعیت رطوبتی با استفاده از شاخص بارندگی استاندارد شده (SPI) در دوره سه ماهه محاسبه گردید. برای تخمین مقدار SPI در هر بازه زمانی، از مقادیر مربوطه در زمان‌های ماقبل، استفاده شد. نتایج نشان داد مدل WA-MLP با دقت بالاتری ($R^2 = 0.87$) مقادیر SPI و وضعیت خشکسالی کوتاه مدت را پیش‌بینی می‌کند.

کلید واژه‌ها: پیش‌بینی، خشکسالی، شبکه عصبی مصنوعی - موجک، ARIMA، SPI.

مقدمه

خشکسالی پدیده‌ای طبیعی و تکرار شدنی است که در اثر کاهش میزان بارندگی در یک دوره زمانی مشخص حادث می‌گردد (Sharma and Smakhtin, 2004). 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 و اقتصادی ظاهر می‌شود. از این‌رو تعیین دقیق زمان شروع و خاتمه این پدیده تا حدودی مشکل است. بنابراین اغلب، خشکسالی را پدیده‌ای خزنده توصیف می‌کنند (Moried and Moghaddasi, 2005). بر این اساس، به دلیل ماهیت خشکسالی و بطئی بودن شروع و خاتمه آن، تشخیص و ارزیابی آن مشکل می‌باشد (Prathumchai et al., 2001).

پیش‌بینی خشکسالی در سیستم‌های منابع آب نقش مهمی در کاهش خسارات خشکسالی دارد. به‌طور سنتی در چندین دهه اخیر، برای پیش‌بینی خشکسالی از برآزش و مدل‌های ریاضی به‌طور گسترده استفاده شده است. این مدل‌ها، سری‌های زمانی را به‌صورت ایستا (stationary) در نظر گرفته و فرآیندها را به‌صورت خطی مدل‌سازی می‌کنند. بیشتر سیگنال‌های هیدرولوژیکی مخصوصاً فصلی و ماهانه و روزانه دارای مشخصات غیر ایستا

(Non stationary)، پرش (Drift)، روند (Trend) و تغییرات ناگهانی در بسامد هستند که برای مدل‌سازی آنها استفاده از الگوریتم‌ها، معادلات غیرخطی و نظریه‌های جدید ریاضی ضروری به نظر می‌رسد (Shafae et al., 2013). در حالت کلی برای تشخیص اطلاعاتی که در سیگنال نهفته می‌باشد، باید از تبدیل کننده‌های ریاضی از قبیل سری فوریه استفاده نمود (Polikar, 1996). تبدیل موجکی تابعی است که نسخه بهبود یافته تبدیل فوریه را تداعی می‌نماید. تبدیل فوریه در تحلیل سیگنال نالیستا به شکست منجر می‌شود. در حالی که تبدیل موجکی اجازه می‌دهد که سیگنال‌های نالیستا نیز به‌خوبی تحلیل شوند (Sifuzzaman et al., 2009).

کاربرد موجک در شبکه عصبی موجکی به‌عنوان تابع آموزش، اخیراً به‌عنوان یک روش جایگزین در شبکه‌های عصبی به‌کار برده شده است. ترکیب تئوری موجکی و شبکه‌های عصبی منجر به گسترش شبکه‌های عصبی - موجکی، شده است. در این مدل‌ها موقعیت و مقیاس موجک‌ها، علاوه بر وزن‌ها، بهینه‌سازی می‌شوند. در اصل شبکه عصبی - موجکی، به شبکه عصبی با استفاده از موجک اشاره دارد. (Thuillard, 2000).

شاخص بارش استاندارد سه ماهه) با استفاده از مدل تلفیقی شبکه عصبی - موجک و مقایسه نتایج حاصل از آن، با روش‌های شبکه عصبی مصنوعی و مدل سری زمانی ARIMA صورت گرفته است، در این مقاله ۵ مدل پیش‌بینی خشکسالی کوتاه مدت با هم مقایسه گردیده و مدلی با کارایی بهتر معرفی شده است.

مواد و روش‌ها

در این تحقیق، از داده‌های بارندگی ماهانه ایستگاه باران‌سنجی بیدستان واقع در شهرستان قزوین و حوضه آبریز شور طی دوره آماری ۵۰-۱۳۴۹ الی ۹۳-۱۳۹۲ استفاده شد. متوسط بارش سالانه در این حوضه ۲۶۲ میلی‌متر می‌باشد، حداکثر ارتفاع بارش ۴۳۷۵ متر در ارتفاعات البرز و پست ترین منطقه واقع در دریاچه نمک با ارتفاع ۷۴۹ متر از سطح دریا می‌باشد. در این حوضه تنوعی از آب و هوا مانند بیابانی، خشک کویری، معتدل و سرد در نقاط مختلف وجود دارد. متوسط بارندگی در ایستگاه بیدستان طی دوره آماری مورد مطالعه، ۳۰۰/۸ میلی‌متر می‌باشد. در شکل (۱) توزیع زمانی ماهانه بارش در این ایستگاه ارائه شده است. مطابق شکل (۱) بیشترین و کمترین بارندگی به ترتیب مربوط به فروردین و مرداد ماه به میزان ۴۵/۹ و ۰/۸ میلی‌متر طی دوره آماری مورد مطالعه می‌باشد. مشخصات جغرافیایی ایستگاه بیدستان در جدول (۱) ارائه شده است. پس از اطمینان از صحت داده‌های بارندگی ماهانه و انجام آزمون‌های آماری لازم، سری زمانی وضعیت خشکسالی در طول دوره آماری بر اساس مقادیر SPI در دوره کوتاه مدت ۳ ماهه محاسبه شد.

شاخص SPI

توسط McKee et al. (1993) برای تعیین دوره‌های خشکسالی و ارزیابی شدت آن تدوین شد. از آنجایی که کمبود بارش در مقیاس زمانی کوتاه‌مدت بر رطوبت خاک؛ و در مقیاس زمانی بلندمدت بر 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 (Steinmann, 2003). نمایه SPI برای هر منطقه بر اساس ثبت بارندگی‌های طولانی مدت و بر اساس میانگین متحرک زمانی محاسبه می‌شود (Mishra and Desai, 2005). در ابتدا توزیع آماری مناسبی بر آمار بارندگی بلند مدت برآزش داده شده، McKee et al., 1993 توزیع گاما را مناسب‌ترین توزیع برای برآزش داده‌های بارندگی نشان دادند. سپس تابع تجمعی توزیع، با استفاده از روابط احتمالاتی به متغیر تصادفی استاندارد شده Z با توزیع نرمال میانگین صفر و انحراف معیار یک، تبدیل می‌گردد. لذا معرف شاخص SPI، متغیر نرمال شده Z، با میانگین صفر و انحراف معیار یک می‌باشد.

Belayneh et al. (2014) به پیش‌بینی دوره خشکسالی در حوضه رودخانه آواش دراتیوی با استفاده از شبکه عصبی - موجکی و رگرسیون بردار پشتیبان موجکی پرداختند. آنها از شاخص خشکسالی SPI بازه‌های زمانی ۱۲ و ۲۴ ماهه، استفاده شده است بررسی‌ها حاکی از برتری مدل شبکه عصبی - موجکی نسبت به مدل رگرسیون بردار پشتیبان موجکی می‌باشد.

Marofi et al. (2013) به پیش‌بینی جریان روزانه رودخانه باراندوزچای با استفاده از شبکه‌های عصبی و عصبی - موجکی پرداختند. نتایج پژوهش آنها حاکی از کارایی مناسب و دقت بالای مدل عصبی - موجکی در مقایسه با شبکه عصبی مصنوعی در پیش‌بینی جریان روزانه رودخانه بود.

Nourani et al. (2009) در مقاله‌ای، ترکیب دو قابلیت شبکه‌های عصبی مصنوعی و تحلیل موجک را با کارایی بهتر در پیش‌بینی فرآیندهای هیدرولوژیکی، به نام شبکه عصبی - موجکی، ارائه نموده و برای پیش‌بینی بارش یک ماه بعد حوضه آبریز ليقوان چای واقع در آذربایجان شرقی استفاده نمودند. نتایج نشان داد که مدل شبکه عصبی - موجکی، به علت استفاده از سری‌های زمانی چند مقیاسی در لایه ورودی، می‌تواند پیش‌بینی بارندگی در هر یک از دوره‌های یک ماهه و یا بیشتر را، به خوبی به انجام دهد.

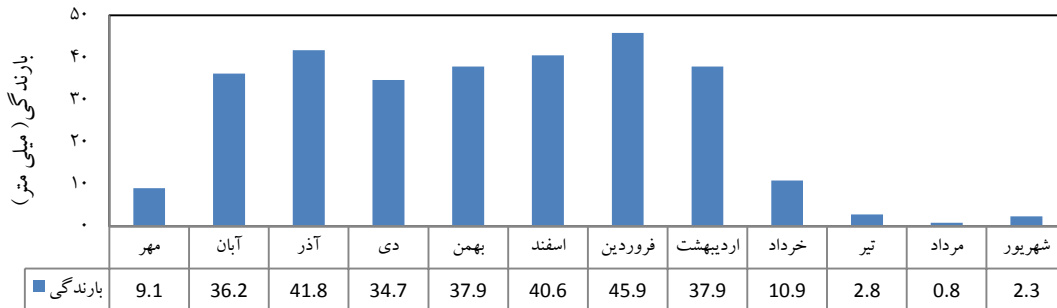
Dogan et al. (2007) جریان سطحی روزانه را در ترکیه با استفاده از شبکه عصبی مصنوعی و روش استوکستیک اتورگرسیو (Auto Regressive) پیش‌بینی کردند. نتایج آن‌ها نشان داد که مدل‌های شبکه عصبی مصنوعی در زمینه پیش‌بینی هیدرولوژیکی بهتر می‌باشد. Cannas et al. (2006) به پیش‌بینی جریان رودخانه با استفاده از شبکه عصبی موجک پرداختند. آنها از آمار ۶۹ ساله ایستگاه چیا در ایتالیا استفاده نمودند. نتایج بررسی آنها نشان داد، مدل شبکه عصبی - موجک عملکرد بهتری نسبت به مدل شبکه عصبی دارد.

با توجه به اهمیت پیش‌بینی خشکسالی‌های کوتاه مدت در مهندسی منابع آب و ویژگی غیرخطی سری زمانی SPI سه ماهه، هدف از مطالعه حاضر، ارائه یک مدل تلفیقی شبکه عصبی - موجک به منظور پیش‌بینی خشکسالی کوتاه مدت در ایستگاه بیدستان دشت قزوین می‌باشد. در این خصوص از شبکه‌های عصبی مصنوعی پرسپترون چند لایه (MLP) و تابع پایه‌ای شعاعی (RBF)، سری زمانی ARIMA و هم‌چنین شبکه‌های عصبی مصنوعی - تلفیقی موجک پرسپترون چند لایه (WA-MLP) و تابع پایه‌ای شعاعی (WA-RBF) استفاده شده است. که این امر از طریق تجزیه سری زمانی مورد بررسی توسط تبدیل موجک و ورود این زیر سری‌ها به شبکه عصبی مصنوعی صورت گرفته است.

بر اساس تحقیقات صورت گرفته در زمینه پیش‌بینی خشکسالی، تاکنون پیش‌بینی خشکسالی کوتاه مدت (با تعریف

جدول ۱- مشخصات جغرافیایی ایستگاه باران سنجی مورد مطالعه

نام ایستگاه	طول جغرافیایی (درجه شرقی)	عرض جغرافیایی (درجه شمالی)	ارتفاع از سطح دریا (متر)
بیدستان	۵۰°۵۷'	۳۶°۲۳'	۱۳۴۰



شکل ۱- توزیع زمانی ماهانه بارندگی ایستگاه بیدستان طی دوره آماری ۱۳۴۹-۵۰ الی ۱۳۹۲-۹۳

تخمین هر تابع پیچیده غیرخطی با دقت مورد نظر مناسب هستند (Cybenko, 1989). در این تحقیق از شبکه عصبی مصنوعی MLP و RBF استفاده شده است.

شبکه MLP: شبکه‌های موسوم به پرسپترون چند لایه (MLP) یکی از متداول‌ترین شبکه‌ها در پیش‌بینی و حل مسائل غیرخطی می‌باشند (Hecht- Nielson, 1989). آموزش این شبکه‌ها با استفاده از الگوریتم معروف پس انتشار خطا (Back Propagation) صورت می‌پذیرد. الگوریتم پس انتشار خطا، اساساً از دو مسیر اصلی تشکیل می‌شود. مسیر اول، تحت عنوان مسیر رفت (Forward)، که طی آن، بردار ورودی به شبکه MLP اعمال شده و تأثیراتش 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 n ام در لایه n ام، w_{ji}^n ، وزن اتصالی بین نرون n ام در لایه n ام و نرون j ام در لایه $(n-1)$ ، O_j^{n-1} ، خروجی نرون j ام در لایه $(n-1)$ است و M تعداد نرون‌ها در لایه $(n-1)$ ام است.

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، رابطه (۴) تابع سیگموئید را بیان می‌کند:

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

در این روابط خروجی محاسبه شده هر نرون با ضرب ماتریس وزن شبکه منتقل می‌شود.

$$Z = SPI = - \left[t - \frac{C_0 + C_1 t + C_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] \quad (1)$$

$$t = \sqrt{\ln \left[\frac{1}{H(x)^2} \right]} \quad 0 < H(x) \leq 0.5$$

$$Z = SPI = + \left[t - \frac{C_0 + C_1 t + C_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] \quad (2)$$

$$t = \sqrt{\ln \left[\frac{1}{1 - H(x)^2} \right]} \quad 0 < H(x) \leq 1$$

$H(x)$: تابع احتمال تجمعی و مقادیر C_0, C_1, C_2, d_1, d_2 و d_3 مقادیر ثابتی هستند که به ترتیب برابر با ۲/۵۱۵۵۷، ۰/۰۰۱۳۰۸، ۰/۱۸۹۲۶۹، ۱/۴۳۲۷۸۸، ۰/۰۱۰۳۲۸، ۰/۸۰۲۸۵۳ می‌باشند و در معادلات (۱) و (۲) به کار برده شده‌اند.

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 نگاهت غیرخطی بین ورودی‌ها و خروجی‌ها ارائه دهند. پردازش در شبکه‌های عصبی مصنوعی بر اساس 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 (Karayiannis and Venetsanopoulos, 1993). در مسائل 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

وزن‌های بین لایه میانی و لایه خروجی با استفاده از روش‌های کاهش شیب و رگرسیون خطی تعیین می‌شود.

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 رابطه (۸) محاسبه خروجی نرون را نشان می‌دهد:

$$\delta = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} \quad (۸)$$

طراحی ساختار شبکه عصبی مصنوعی

به منظور مدل‌سازی، داده‌های سری زمانی SPI به دو بخش تقسیم شد. مجموعه مقادیر SPI از سال آبی ۱۳۴۹-۵۰ الی ۱۳۸۴-۸۵ به عنوان داده‌های آموزش شبکه و مقادیر SPI از سال ۱۳۸۴-۸۵ الی ۱۳۹۲-۹۳ به عنوان داده‌های ارزیابی شبکه مورد استفاده قرار گرفتند. 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. لذا قبل از آموزش، برای نرمال‌سازی داده‌های مورد استفاده از رابطه (۹) استفاده شد:

$$X_n = \frac{X_0 - X_{\min}}{X_{\max} - X_{\min}} \quad (۹)$$

X_n : مقدار نرمال شده داده، X_0 : مقدار واقعی هر داده، X_{\min} و X_{\max} : به ترتیب کمینه و بیشینه داده مورد نظر می‌باشد.

در این پژوهش به پیش‌بینی میزان SPI (در بازه زمانی سه ماهه) در یک گام جلوتر پرداخته شد، از این رو نرون خروجی در تمام شبکه‌های عصبی یک و همچنین به منظور بررسی و تعیین وابستگی‌های زمانی SPIها و اینکه با چه تأخیر زمانی قبل بهترین میزان SPI را خواهیم داشت، تعداد نرون‌های ورودی از یک نرون تا پنج نرون تغییر داده شد و در نهایت بهترین تعداد تأخیر زمانی

ارزیابی: به منظور ارزیابی مدل‌های مورد نظر، داده‌های خروجی محاسبه شده توسط شبکه‌های عصبی، با مقادیر واقعی مقایسه می‌شود. در این مرحله از توابع ارزیابی میانگین مطلق خطا (Mean of Absolute Error) و جذر میانگین مربعات خطا (Root Mean of Square Error) استفاده می‌گردد. روابط مربوطه به صورت زیر محاسبه می‌شود.

$$MAE = \frac{\sum_{i=1}^{n_p} \sum_{j=1}^{n_o} |T_{pj} - O_{pj}|}{n_p \cdot n_o} \quad (۵)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n_p} \sum_{j=1}^{n_o} (T_{pj} - O_{pj})^2}{n_p \cdot n_o}} \quad (۶)$$

در این روابط، T_{pj} خروجی هدف نرون زام مربوط به الگوی m ، O_{pj} خروجی محاسبه شده نرون زام مربوط به الگوی m ، n_p تعداد الگوها و n_o تعداد نرون‌ها در لایه خروجی است. بعد از محاسبه شاخص خطاها، چنانچه خطاهای مربوطه، بیش از مقادیر مورد نظر باشند، در گام بعدی (الگوریتم BP)، مسیر دوم تحت عنوان مسیر بازگشت (Backward)، شروع می‌شود. در این مسیر، با استفاده از روش کاهش شیب وزن‌های شبکه، در جهت کاهش خطا، شبکه تغییر یافته و تنظیم می‌گردند.

$$\Delta w_{ji}^n(m+1) = \eta \cdot \frac{\partial(E)}{\partial w_{ji}^n} + \alpha \cdot \Delta w_{ji}^n(m) \quad (۷)$$

در این رابطه، $\Delta w_{ji}^n(m+1)$ میزان افزایش وزن در تکرار $(m+1)$ ام، η سرعت یادگیری و α ، ضریب مومنتوم است. این امر تا رسیدن مقدار خطا به یک مقدار قابل قبول ادامه می‌یابد. در اینجا مرحله یادگیری شبکه به پایان رسیده و در صورتیکه 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) از نوع شبکه‌های رو به جلو همراه با یک لایه میانی هستند که برای اولین بار توسط Broomhed and Lowe, 1988 معرفی شدند. در این روش اغلب، تابع انتقال در لایه میانی، تابع گوسین و در لایه خروجی، تابع خطی است (Dibike et al., 1999) و (Mason et al., 1996). عموماً آموزش شبکه RBF به دو بخش تقسیم می‌شود. بخش اول عمدتاً 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

$$\int \psi(t) dt = 0 \quad (10)$$

که در آن $\psi(t)$ تابع موجکی می‌باشد. تبدیل موجکی بر دو نوع شامل، تبدیل‌های موجکی پیوسته (CWT) و گسسته (DWT) می‌باشند. تبدیل گسسته موجک برای پردازش و تحلیل سری‌های زمانی، مناسب‌تر از تبدیل پیوسته موجکی می‌باشد. زیرا داده‌های تبدیل یافته با DWT، اجزای اضافه نداشته، بنابراین تبدیل معکوس را می‌توان برای هر دسته از داده‌های زمان-بسامد، به کار برد (Nakhaei and Saberi Nasr, 2012 و Rajaei, 2011). فرآیند تجزیه سیگنال شامل یک یا چند مرحله است که در تجزیه چند مرحله‌ای، موج پس از اولین مرحله تفکیک با تجزیه مجدد قسمت تقریبی، تجزیه موج ادامه می‌یابد.

در تحقیق حاضر از تبدیل موجک گسسته استفاده شده است. برای مدل ترکیبی عصبی-موجک ابتدا سری زمانی SPI سه ماهه به‌وسیله موجک‌های مادر Db2, Db4, Db6, Db8, Haar و Meyer به‌صورت گسسته و با دو سطح تجزیه شدند. انتخاب سطح تجزیه بر اساس فرمول تجربی $l = \text{int}[\log(n)]$ صورت گرفت (Moosavi et al., 2013). در این فرمول l : سطح تجزیه، n : تعداد داده‌های سری زمانی است. با توجه به اینکه تعداد داده‌های مورد استفاده در این پژوهش ۵۲۶ است، سطح تجزیه دو حاصل می‌گردد. به کار بردن سطح تجزیه بالا مطلوب نیست، زیرا سطح تجزیه بالا با اینکه ممکن است دقت آموزش شبکه را افزایش دهد، نتیجه معکوس روی داده‌های آزمون دارد. نکته مهم انتخاب موجک مادر است این موجک باید به طبیعت رخداد پدیده و نوع سری زمانی مشاهده شده شبیه باشد (Rajaei and Ebrahimi, 2013). در ادامه بهترین موجک مادر انتخاب شد. بعد از تجزیه سیگنال مورد بررسی (SPI بازه زمانی ۳ ماهه) توسط موجک مادر منتخب، زیرسری‌های حاصل به عنوان ورودی شبکه عصبی مصنوعی طبق جدول (۲) تعریف شدند.

سری زمانی ARIMA

در اوایل دهه ۶۰ میلادی مدل‌های اتورگرسیو استفاده‌ای گسترده‌ای در مهندسی هیدرولوژی و منابع آب داشته‌اند.

تعیین شد (Golabi et al., 2013). بردار ورودی ترکیب متفاوتی از مقادیر SPI پیشین بود که بهترین بردار ورودی با سعی و خطا مشخص گردید. مجموعه‌ی بردارهای ورودی در جدول (۲) نشان داده شده است. شبکه‌ها با الگوریتم‌های مختلف آموزش داده و ضریب همبستگی (R)، جذر میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (AME) و ضریب کارایی نش - ساتکلیف (NS) برای تمام مدل‌ها محاسبه شد (میشرا و دیزای، ۲۰۰۶). شبکه‌ای که کمترین جذر میانگین مربعات خطا، میانگین قدر مطلق خطا و بیشترین ضریب همبستگی، ضریب کارایی نش - ساتکلیف را دارا بود به‌عنوان بهترین شبکه انتخاب شد. به‌منظور بررسی عملکرد مدل‌های مورد آزمون و تعیین میزان دقت مدل طراحی شده، نمودارهای مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده توسط شبکه‌ها نیز ترسیم گردید.

به منظور یافتن بهترین شبکه، در هر یک از شبکه‌ها، مرتباً 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 یک تا پنج نرون در لایه ورودی و با تغییر افزایش تعداد نرون‌های لایه میانی در هر دو شبکه، برای سری زمانی SPI آزمایش شد.

تحلیل موجکی

تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در زمینه پردازش سیگنال است. موجک تابع ریاضی است که شکل مقیاس - زمان از سری‌های زمانی و روابط آنها برای تحلیل سری‌های زمانی که شامل متغیرها و غیرثابت‌ها می‌باشد را ارائه می‌دهد. تحلیل موجکی استفاده از فاصله‌های زمانی طول مدت را برای اطلاعات دارای بسامد پایین و تناوب‌های کوتاه‌تر را برای اطلاعات دارای بسامد بالا ارائه می‌دهد. تحلیل موجکی قادر به نمایش جنبه‌های مختلف داده‌های متفاوت، نقاط شکست و ناپیوستگی‌ها می‌باشد که ممکن است دیگر روش‌های تحلیل سیگنال آن‌ها را نشان ندهند (Nourani et al., 2009).

موجک به معنی موج کوچک و دارای سه مشخصه تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود و میانگین صفر است. سه ویژگی شرط لازم برای موجک تابع است. ویژگی‌های مذکور را شرط مقبولیت متغیر می‌نامند که به صورت رابطه (۱۰) بیان می‌شود:

جدول ۲- بردارهای ورودی مورد استفاده در شبکه‌های عصبی مصنوعی

ورودی	تعداد نرون ورودی
SPI_{t-1}	۱
SPI_{t-1}, SPI_{t-2}	۲
$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$	۳
$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, SPI_{t-4}$	۴
$SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, SPI_{t-4}, SPI_{t-5}$	۵

Desai (2005) نیز استفاده از مدل فصلی ARIMA را در مدل سازی خشکسالی ها پیشنهاد نموده اند.

در مرحله تخمین، پارامترهای مدل با استفاده از روش های گشتاور و کمترین مربعات تعیین شدند. در نهایت مدلی که کمترین Pvalue و کمترین میانگین مربعات خطا (MSE) را ارائه داد، به عنوان بهترین مدل در نظر گرفته شد. در ادامه توانایی مدل سازی سری زمانی با استفاده از معیارهای مختلف سنجیده شد. از جمله معیارهای مختلف، آزمون نرمال بودن و استقلال باقیمانده ها و بررسی نمودارهای ACF و PACF باقی مانده ها می باشد.

همچنین معیار ارزیابی، شاخص آکائیک (AIC) برای تشخیص کارایی مدل به کار برده شد. شاخص آکائیک طبق اصل امساک باید حداقل باشد. (Niromand, 1997).

نتایج و بحث

پردازش داده ها با استفاده از شبکه عصبی مصنوعی MLP و RBF

ابتدا بدون هیچ گونه پیش پردازشی، مدل های شبکه عصبی مصنوعی MLP و RBF برای مدل سازی سری شاخص بارش استاندارد در بازه زمانی سه ماهه استفاده شد. 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. نتایج حاصل از آزمایش تعداد نرون های بالاتر از ۱۰ در لایه پنهان نشان داد که این افزایش نرون سبب کارایی بهتر نمی شود و دقت آن همچنان ثابت می ماند. این نتیجه توسط محققان دیگر نیز در هیدرولوژی اثبات شده است (Nourani et al., 2009). به منظور ارزیابی و بررسی عملکرد مدل های مورد آزمون و تعیین میزان دقت مدل طراحی شده علاوه بر استفاده از چهار معیار میانگین مطلق خطا (MAE)، جذر میانگین مربعات خطا (RMSE)، ضریب تعیین (R^2) و ضریب کارایی نش - ساتکلیف (NS)، 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 برای سری زمانی SPI بازه زمانی سه ماهه (کوتاه مدت) نشان داد.

در جدول (۳) مقادیر پارامترهای R^2 ، MAE، RMSE، NS برای تخمین کوتاه مدت SPI برای کلیه مدل های مورد بررسی آمده است. براساس محاسبات انجام شده، بیشترین مقدار R^2 و NS به ترتیب ۰/۸۶۹ و ۰/۷۵، کمترین مقادیر MAE و RMSE در مرحله تست به ترتیب برابر ۰/۰۳ و ۰/۰۵۸ است که مربوط به مدل شبکه عصبی موجک (WA-MLP) می باشد.

چنانچه مقادیر محاسبه شده SPI توسط دو نوع شبکه عصبی برای سری زمانی، در برابر داده های مشاهده ای ترسیم شوند شکل های (۲) و (۳) حاصل می گردند. نتایج نشان می دهد که

Box و Jenkins (1976) با استفاده از اولین، دومین یا به طور کلی دامین تفاضل سری، سری زمانی را ایستا و سپس با مدل سازی با ARMA(p,q) مدل جدیدی موسوم به مدل فصلی ARIMA(p,d,q) غیر فصلی ارائه نمودند. مدل فصلی ARIMA(p,d,q) غیر فصلی، اتورگرسیو با درجه p، میانگین متحرک با درجه q و عملگر دامین تفاضل گیری از سری زمانی است. بنابراین مدل ARIMA با سه پارامتر (p,d,q) که می تواند صفر یا مثبت باشد؛ مشخص می شود. مدل آریما غیر فصلی به صورت زیر نوشته می شود:

$$\phi(B)\nabla^d Z_t = \theta(B)a_t \quad (11)$$

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

$$\phi(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \quad (12)$$

$$\theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \quad (13)$$

در صورت استفاده از عملگر تفاضل فصلی با تأخیر s و برازش آن ها با مدل ARMA(p,q)، مدل آریما فصلی ARIMA(P,D,Q)_s بوجود می آید. Box et al. (1994) با ترکیب مدل های فصلی و غیر فصلی، مدل های موسوم به آریمای فصلی مکرر ARIMA(p,d,q)(P,D,Q)_s را توسعه دادند. عبارت (p,d,q) بخش غیر فصلی مدل و عبارت (P,D,Q)_s بخش فصلی مدل است که به صورت زیر بیان می شود:

$$\phi_p(B)\phi_P(B^s)\nabla^d \nabla_s^D Z_t = \theta_q(B)\theta_Q(B^s)a_t \quad (14)$$

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 (Box and Jenkins, 1976). مرحله شناسایی مدل شامل تبدیل داده ها به سری های نرمال (در صورت لزوم) و شناسایی فرم کلی مدل می باشد. به منظور شناسایی مدل اولیه در این تحقیق از دو نمودار ACF (Auto Correlation Function) و PACF (Partial Auto Correlation Function) استفاده شد. که بر اساس این دو نمودار و تناوب های ایجاد شده در سری بعد از محاسبه SPI سه ماهه، مدل فصلی ARIMA به عنوان بهترین مدل در نظر گرفته شد. Modarres (2007) و Mishra و

مقایسه نتایج شبکه‌های عصبی MLP و RBF با مدل‌های

WA-MLP، WA-RBF و سری زمانی ARIMA

در این مقاله از تبدیل موجک، برای تجزیه سیگنال شاخص بارش استاندارد استفاده شد. سپس به منظور افزایش دقت مدل شبکه عصبی مصنوعی، داده‌های پیش پردازش شده توسط تبدیل موجک گسسته به عنوان ورودی‌های شبکه عصبی در نظر گرفته شد. اولین قدم برای تجزیه سیگنال با موجک، انتخاب موجک مادر است. بر اساس جدول (۴) از میان موجک‌های مورد بررسی موجک مادر (Meyer) بیشترین R^2 و کمترین RMSE را دارا می‌باشد. این موجک شباهت بیشتری با سری زمانی SPI در بازه زمانی سه ماهه دارا می‌باشد. بنابراین موجک میر، برای تجزیه سری زمانی مورد نظر، با دو سطح تجزیه انتخاب شد. تجزیه سیگنال‌های کاملاً تصادفی هواشناسی، با کمک نظریه موجک، منجر به ساده‌تر شدن این سیگنال‌ها شده و امکان مدل بندی این داده‌ها را فراهم می‌کند. بر اساس جدول (۳) نتایج، حاکی از برتری روش شبکه عصبی - موجکی نسبت به سایر روش‌های پیش‌بینی به کار رفته در این تحقیق می‌باشد. مدل شبکه عصبی موجک WA-MLP، نسبت به مدل WA-RBF، از دقت بالاتری برخوردار می‌باشد. به طوریکه بیشترین R^2 (۰/۸۷)، NS (۰/۷۶) و کمترین مقدار RMSE و MAE به ترتیب ۰/۰۵ و ۰/۰۳ مربوط به مدل WA-MLP می‌باشد.

شبکه MLP در مقایسه با شبکه RBF با دقت بالاتری مقادیر را پیش‌بینی می‌کند. نتایج مذکور با نتایج (Crespo and mora, 1993) مطابقت دارد. به جهت مقایسه در این شکل‌ها محدوده ۳۰ درصد خطا نیز نشان داده شده است و همچنین شیب خط رگرسیون با شیب خط ۱:۱ (خط ۴۵ درجه) مقایسه شد.

مقایسه نتایج شبکه‌های عصبی مصنوعی MLP و RBF با

نتایج سری زمانی ARIMA

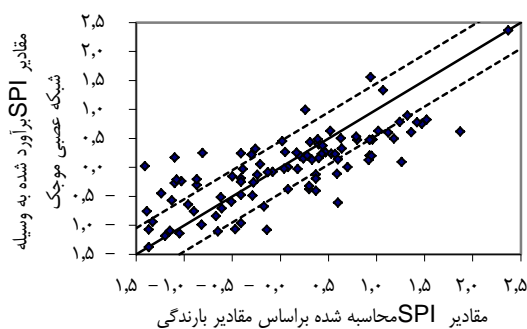
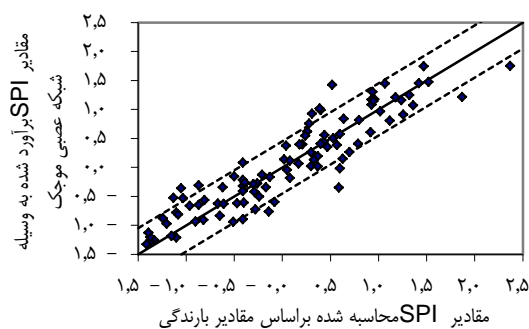
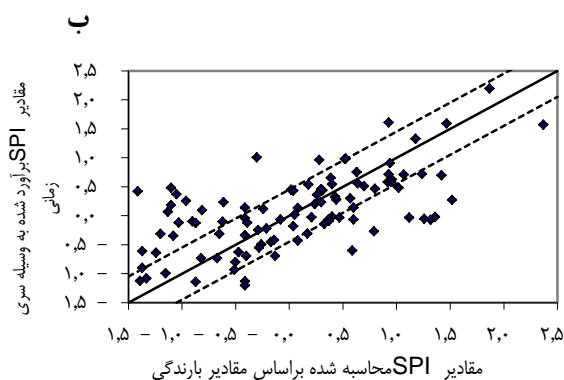
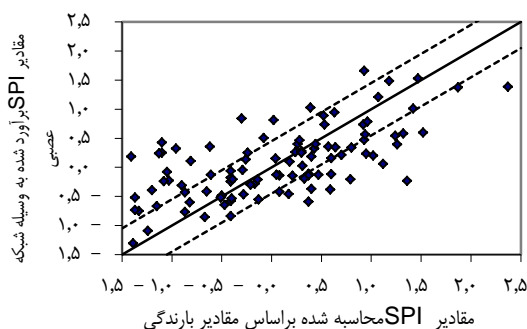
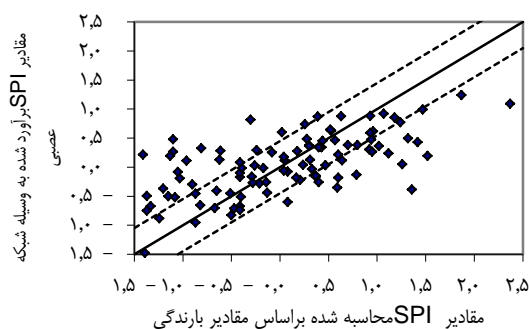
همان‌گونه که ذکر شد در این تحقیق، مدل آریمای برای بررسی تغییرات سری زمانی SPI بازه زمانی سه ماهه و پیش‌بینی آن در ایستگاه بیدستان استفاده شد. برای تخمین پارامترهای مدل از روش کمترین مربعات خطا استفاده شد. در نهایت برای این سری زمانی، بهترین مدل ارائه شد که نتیجه در جدول (۳) ارائه شده است. مطابق این جدول مقادیر R^2 ، NS، MAE و RMSE برای بهترین مدل سری زمانی در مرحله تست به ترتیب برابر با ۰/۴۷، ۰/۱۴، ۰/۱۱ و ۰/۴۵۶ می‌باشد اعداد مزبور کارایی نسبی شبکه‌های عصبی مصنوعی را نسبت به مدل‌های سری زمانی نشان می‌دهد. نتایج مزبور با نتایج رضایی (Rezaee, 2001) و (Mishra and Desai, 2006) همسو بوده است. مقادیر مشاهده‌ای در مقابل برآوردی در شکل (۲) نشان داده شده است.

جدول ۳- نتایج حاصل از آزمایش شبکه‌های MLP، RBF، WA-ANN و سری زمانی در بهترین حالت یادگیری برای SPI بازه زمانی سه ماهه

NS	MAE	RMSE	R^2	شاخص	مدل
۰/۴۶	۰/۱۱	۰/۱۲۳	۰/۴۸	آموزش	MLP
۰/۴۶	۰/۰۹۱	۰/۱۲۱	۰/۴۸۸	تست	
۰/۴۷	۰/۱	۰/۱۲	۰/۴۹	ارزیابی	۵-۴-۱
۰/۴۵	۰/۱۱	۰/۱۵	۰/۴۶۷	آموزش	RBF
۰/۴۷	۰/۱	۰/۱۳	۰/۴۷۵	تست	
۰/۴۶	۰/۱	۰/۱۴	۰/۴۷	ارزیابی	۴-۱۰-۱
۰/۴۷	۰/۱۲	۰/۱۴	۰/۴۹	آموزش	ARIMA
۰/۴۵۶	۰/۱۱	۰/۱۴	۰/۴۷	تست	
۰/۴۵	۰/۱۲	۰/۱۵	۰/۴۶	ارزیابی	(۱۰ و ۲) (۲ و ۱)
۰/۷۵	۰/۰۳۵	۰/۰۶	۰/۸۶	آموزش	WA-MLP
۰/۷۵	۰/۰۳	۰/۰۵۸	۰/۸۶۹	تست	
۰/۷۶	۰/۰۳	۰/۰۵	۰/۸۷	ارزیابی	۳-۱۰-۱
۰/۵۸	۰/۰۵	۰/۱۲	۰/۶۰	آموزش	WA-RBF
۰/۵۹	۰/۰۵	۰/۱۱	۰/۶۱	تست	
۰/۶	۰/۰۵۵	۰/۱۱	۰/۶۱	ارزیابی	۲-۵-۱

شبکه عصبی مصنوعی، در مقایسه با مدل سری زمانی، نتایج بهتری برای پیش بینی خشکسالی کوتاه مدت ارائه نمودند. شایان ذکر است که علت برتری مزبور ماهیت غیرخطی و انعطاف‌پذیری شبکه‌های عصبی می‌باشد. با توجه به اینکه هر سری زمانی از دو مؤلفه معین و تصادفی تشکیل شده، مدل‌های سری زمانی، به دلیل خطی بودن، قادر به شبیه‌سازی مؤلفه تصادفی سری نمی‌باشند. لیکن شبکه‌های عصبی، هر دو مؤلفه را شبیه‌سازی می‌کنند.

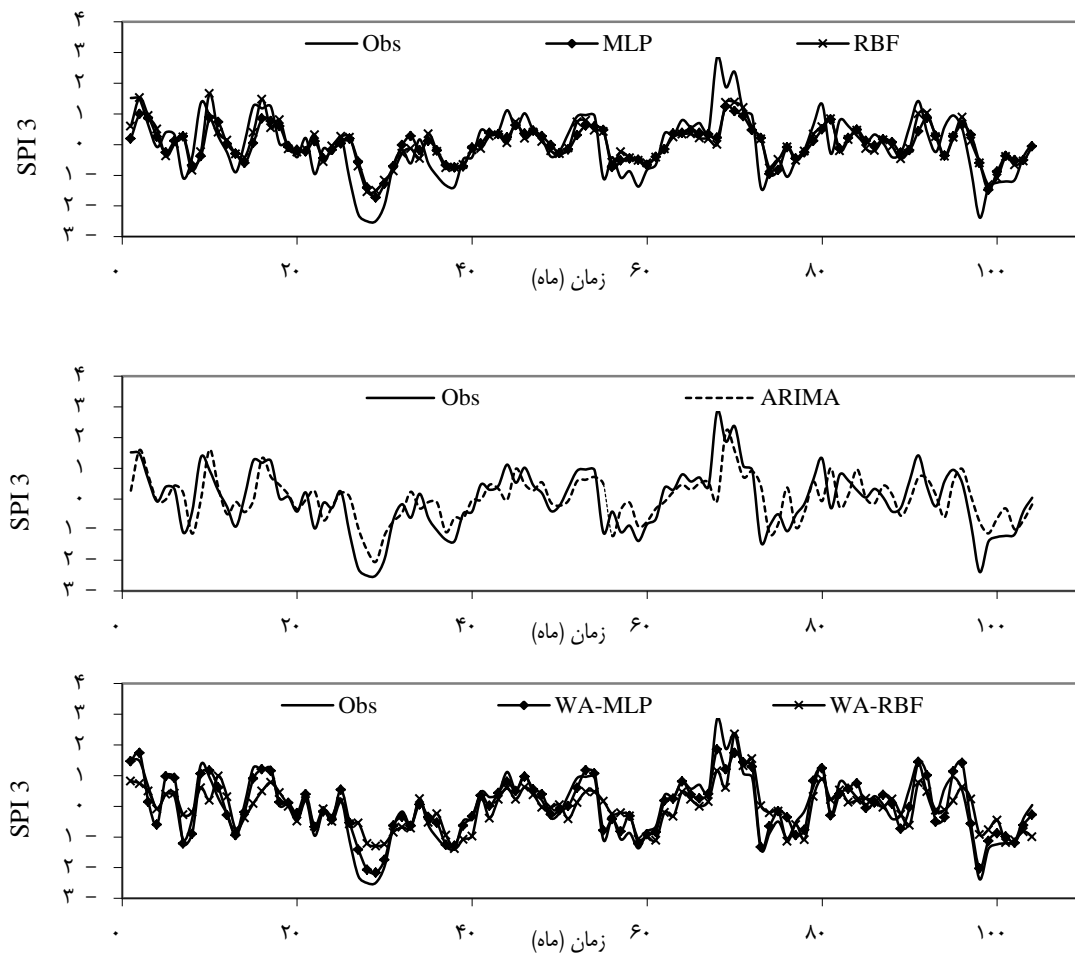
نتایج نشان می‌دهد که شبکه عصبی مصنوعی- موجک نسبت به مدل شبکه عصبی و سری زمانی با دقت مناسب‌تری تغییرات شاخص خشکسالی را پیش‌بینی می‌کند که با نتایج تحقیق (Cannas et al., 2006) و (Adamowski and Fung, 2011) (Chan, 2011) مطابقت دارد. دقت بالاتر مدل شبکه عصبی- موجک، نه تنها به دلیل پیش پردازش و پارتیشن بندی موجک، به زیر سیگنال‌های مختلف می‌باشد، بلکه به علت توجه به تأثیر هر زیر سیگنال تجزیه‌ای بوسیله بزرگنمایی نسبی وزن آن زیر سیگنال می‌باشد.



شکل ۲- مقایسه نتایج حاصل از به کارگیری MLP، RBF، ARIMA، WA-MLP و WA-RBF در دوره زمانی سه ماهه مرحله تست الف) شبکه عصبی MLP، ب) شبکه عصبی RBF، ج) سری زمانی ARIMA، د) شبکه عصبی- موجک WA-RBF، ر) شبکه عصبی- موجک WA-MLP

جدول ۴- نتایج حاصل به کارگیری موجک های مختلف جهت تجزیه سیگنال SPI سه ماهه با دو سطح تجزیه

شاخص ارزیابی	Haar	Db1	Db2	Db4	Db6	Db8	Meyer
R^2	۰/۴۱	۰/۴۵	۰/۵۲	۰/۶۳	۰/۶۷	۰/۶۹	۰/۹۰
RMSE	۰/۷۱	۰/۶۴	۰/۶۰	۰/۵۷	۰/۵۵	۰/۵۰	۰/۲۹

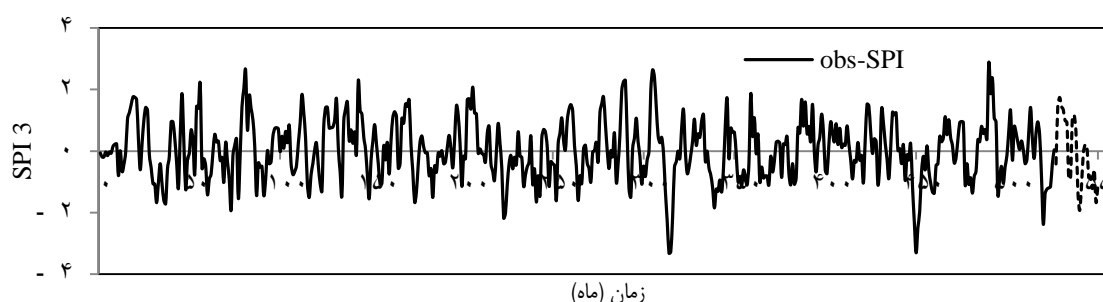


شکل ۳- مقایسه نتایج پیش بینی مدل های MLP، RBF، ARIMA، WA-MLP و WA-RBF با مقادیر واقعی در مرحله تست ایستگاه بیدستان

ایستگاه بیدستان دارای وضعیت رطوبتی نرمال خواهد بود و در برخی ماهها مقدار شاخص بارش استاندارد در بازه زمانی سه ماهه ترسالی متوسط را نشان می دهد. همچنین برای سال دوم در برخی ماهها احتمال وقوع خشکسالی متوسط و شدید وجود خواهد داشت و در شش ماه وضعیت رطوبتی نرمال برای این ایستگاه پیش بینی می گردد. این نتایج به برنامه ریزی آینده و ارائه راهکارهای مدیریتی حائز اهمیت می باشد.

پیش بینی خشکسالی با استفاده از مدل WA-MLP

نتایج این تحقیق نشان داد که با استفاده از بهترین مدل برتر در بین مدل های مختلف، می توان شاخص بارش استاندارد در بازه زمانی سه ماهه را بخوبی پیش بینی نمود. لذا با استفاده از مدل WA-MLP (مدل برتر)، شاخص SPI در بازه زمانی سه ماهه برای ۲۴ ماهه آینده، پیش بینی و نتایج حاصل در شکل (۴) ارائه گردید. بر اساس نتایج پیش بینی، مشخص گردید که سال اول،



شکل ۴- نمودار پیش بینی سری زمانی SPI در بازه زمانی سه ماهه برای ۲۴ ماهه آینده

به منظور شبیه سازی دقیق، ملزم به استفاده از شبکه عصبی- موجکی می‌باشد. زیرا شبکه عصبی مصنوعی به تنهایی قادر به غلبه بر ناپیوستگی سیگنال نمی‌باشد. در حالی که تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پایین، ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد.

- از میان موجک‌های مادر Haar، Db1، Db2، Db4، Db6، Db8 و Meyer، موجک مادر Meyer به عنوان بهترین موجک انتخاب گردید.

- شبکه‌های عصبی مصنوعی، در مقابل روش‌های آماری از دقت بیشتری برای پیش بینی سری زمانی SPI در بازه زمانی سه ماهه برخوردار هستند. همچنین شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) و الگوریتم پس انتشار خطا، نسبت به شبکه عصبی RBF، نتایج بهتری را نشان داد.

- 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.

- نتایج حاصل از پیش بینی با استفاده از مدل WA-MLP وضعیت رطوبتی نرمال در سال اول برای ایستگاه بیدستان را نشان داد. و برای سال دوم نتایج حاکی از آن است که در برخی ماه‌ها احتمال وقوع خشکسالی متوسط و شدید وجود خواهد داشت و در شش ماه وضعیت رطوبتی نرمال برای این ایستگاه پیش بینی شد.

نتیجه گیری

در پژوهش حاضر، پیش‌بینی سری‌های زمانی SPI با استفاده از شبکه‌های عصبی مصنوعی پرسپترون چند لایه (MLP) و تابع پایه‌ای شعاعی (RBF)، روش آماری ARIMA، شبکه‌های عصبی- موجک WA-MLP و WA-RBF، در مقیاس زمانی سه ماهه مورد بررسی قرار گرفت که به عنوان نتیجه‌گیری می‌توان به موارد زیر اشاره نمود.

- برتری کارایی نسبی شبکه‌های عصبی مصنوعی- موجک در مقایسه با روش‌های آماری و شبکه عصبی مصنوعی مشخص شد. همچنین شبکه عصبی مصنوعی- موجک پرسپترون چند لایه (WA-MLP) و الگوریتم پس انتشار خطا، نسبت به شبکه عصبی- موجک WA-RBF، نتایج بهتری در پیش‌بینی سری‌های زمانی SPI بازه زمانی سه ماهه نشان داد.

- استفاده از تبدیل موجک، دقت پیش‌بینی مدل ترکیبی شبکه عصبی مصنوعی- موجک را افزایش می‌دهد. دقت بالاتر مدل شبکه عصبی- موجک نه تنها به خاطر پیش پرداز و پارتیشن بندی موجک به زیر سیگنال‌های مختلف است، بلکه علت آن می‌تواند به دلیل توجه به تأثیر هر زیر سیگنال تجزیه‌ای، بوسیله بزرگنمایی نسبی وزن آن زیر سیگنال باشد.

- علیرغم اینکه مدل شبکه عصبی مصنوعی بخاطر در اختیار داشتن کرنل غیرخطی، توانایی مدل‌سازی رفتارهای غیرخطی را داراست، لیکن با توجه به ویژگی‌های ناپیوستگی و غیر خطی بودن سری زمانی شاخص بارش استاندارد در بازه زمانی سه ماهه،

منابع

- 1- Adamowski, J., Fung Chan, H. 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*. Vol. 407, pp. 28-40.
- 2- Belayneh, A., Adamowski, J., Khalil and Ozga-Zielinski, B. 2014. Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression. *Journal of Hydrology*. Vol. 508, pp.418-429.
- 3- Box, G. E. P. and Jenkins, G. M. 1976. *Time series analysis forecasting and control*, Holden-Day, San Francisco.
- 4- Box, G. E. P., Jenkins, G. M. and Reinsel, G. C. 1994. *Time series analysis, forecasting and control*, Prentice Hall, Englewood Cliffs, NJ.

- 5- Broomhed, D.S., and Lowe, D. 1988. Multivariable Functional Interpolation and Adaptive Networks, *Complex system*. Vol. 2, pp. 321-355.
- 6- Cannas, B., Fanni, A., See, L., and Sias, G. 2006. Data preprocessing for river flow forecasting using neural network: wavelet transforms and data partitioning. *Physics and Chemistry of the Earth*. 31(18), pp. 1164-1171.
- 7- Crespo, J. L., and Mora, E. 1993. Drought estimation with neural networks. *Advances in Engineering Software*. 18(3), pp. 167-170.
- 8- Cybenko, G., 1989. Approximation by super positions of a sigmoid function. *Mathematics of Control, Signals and Systems*. 2(4), pp. 303-314.
- 9- Dibike, Y. B., Solomatin, D. P. and Abbot, M. B. 1999. On the encapsulation of numerical- Hydraulic models in artificial neural networks. *Journal of Hydraulic Research*. 37(2), pp. 147-161.
- 10- Dogan, E., Isik, S., Toluk, T. and Sanaal, M. 2007. Daily stream flow forecasting using artificial neural network, http://www.dsi.gov.tr/english/congress2007/chapter_4/108.pdf.
- 11- Golabi, M. R., Radmanesh, F., Akhondali, A. M. 2013. An investigation of artificial neural network and time series performance in the index standard precipitation drought modeling (Case study: selected stations of Khuzestan Province). *Arid Biome Scientific and Research Journal*. 3(1), pp. 82-87. (In Persian).
- 12- Hecht- Nielson, R. 1989. Kolmogorov's mapping neural network existence theorem. *1 st IEEE ICNN, vol. 3 San Diego, CA*.
- 13- Karayiannis, N. B. and Venetsanopoulos, A. N. 1993. *Artificial neural network: Learning algorithms, performance evaluation and application*. Kluwer Academic Publisher, Boston.
- 14- Marofi, S., Amir Moradi, K., Parsafar, N. 2013. River flow prediction using artificial neural network and wavelet neural network models (Case study: Barandozchay river). *Water and Soil Science*. 3(23), pp. 93-103. (In Persian).
- 15- Mason, J. C., Price, R. K. and tem' me. 1996. A neural network model of rainfall-runoff using radial basis functions. *Journal of Hydraulic Research*. 34(4), pp: 537-548.
- 16- McKee, T. B., Doesken, N. J. and Kleist, J. 1993. The relation of drought frequency and duration to time scales. Preprints, *8th Conference on Applied Climatology, Anaheim, California*.
- 17- Mishra, A.k. and Desai, V. R. 2005. Drought forecasting using stochastic models. *Stochastic Environmental Research and Risk Assessment*. 19 (5), pp. 326-339.
- 18- Mishra, A. K., Desai, V. R. 2006. Drought forecasting using feed-forward recursive neural network. *Ecological Modeling*. 198(1-2), pp. 127-138.
- 19- Modarres, R 2007. Stream flow drought time series forecasting. *Stochastic Environmental Research and Risk Assessment*. 21 (3), pp. 223-233.
- 20- Moried, S., Moghaddasi, M. 2005. Monitoring the Drought During 1998 to 2000 in Tehran Province, Using EDI, SPI, DI Indices and Geographical Information System. *Journal of Spatial Planning*. 9(1), pp. 197-215.
- 21- Moosavi, V., Vafakhah, M., Shirmohammadi, B., and Behnia, N. 2013. A wavelet- ANFIS hybrid model for groundwater level forecasting for different prediction periods. *Water Resource Management*. 27(5), pp. 1301-1321
- 22- Nakhai, M., Saberi Nasr, A. 2012. A Combined wavelet-artificial neural network model and its applications to the prediction of groundwater level fluctuations. *Geopersia*. 2(2), pp. 77-91.

- 23-Niromand, H. 1997. *Time Series Analysis- One Variable and Multi Variable Methods*. Ferdowsi University Press, Mashhad. (In Persian).
- 24-Nourani, V., Alami, M., and Aminfar, M. 2009. A combined neural- wavelet model for prediction of Lighvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*.vol 22, pp. 466-472.
- 25-Polikar, R. 1996. *Fundamental concept and an overview of The wavelet theory wavelet tutorial*. Rowan University Press, New jersey.
- 26-Prathumchai, K., Honda, K. and Nualchawee, K. 2001.Drought risk evaluation using remote sensing and GIS: A case study in Lopburi Province, *22nd Asian Conference on Remote Sensing. National University of Singapore. Singapore*.
- 27-Rajaei, T., Ebrahimi, H. 2013. Modeling of groundwater fluctuations by wavelet transform and dynamic neural network. *Water and irrigation mamagement*. 4(14), pp.73-87. (In Persian).
- 28-Rajaei, T. 2011. Wavelet and ANN combination model for prediction of daily suspended sediment load in river. *Science of the Total Environment*. 409(15), pp. 2917-2928.
- 29-Rezaei, A. 2001. Modeling flood and drought using artificial neural networks (ANN). *Proceedings of the first national conference in water crisis, Zabol University, Zabol, Iran*.
- 30-Shafaei, M., Fakheri Fard, A., Darbandi, S., Ghorbani, N. A. 2013. Prediction Daily Flow of Vanyar Station Using ANN and Wavelet Hybrid Procedure. *Irrigation and Water Engineering*. 4 (14), pp. 113-128. (In Persian).
- 31-Sharma, B. R., and Smakhtin, V. U. 2004. Potential of water harvesting as a strategic tool for drought mitigation. *International Water Management Institue. Colombo, Sri Lanka*.
- 32-Sifuzzaman, M., M.R. Islam, M.Z. Ali. 2009. Application of wavelet transform and its advantages compared to fourier transform. *Journal of Physical Sciences*. Vol. 13, pp. 121-134.
- 33-Steinmann, A. 2003. Drought Indicators and Triggers: A Stochastic Approach to Evaluation. *Journal of the American Water Resources Association (JAWRA)*. 39 (5), pp: 1217-1233.
- 34-Thuillard, M. 2000. A review of wavelet networks, wavelet, fuzzy wavelet and their application. ESIT. *In Presented in Conference, Aachen, Germany*.



EXTENDED ABSTRACT

Drought Forecasting Using Artificial Wavelet Neural Network Integrated Model (WA-ANN) and Time Series Model (ARIMA)

M. Younesi¹, N. Shahraki², S. Marofi^{3*} and H. Nozari⁴

- 1- Ph.D. Student on Water Resources Engineering, Department of Science and Water Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran.
- 2- Ph.D. Student on Water Resources Engineering, Department of Science and Water Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran.
- 3* - Corresponding Author, Professor, Department of Science and Water Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran. (*smarofi@yahoo.com*)
- 4- Assistant Professor, Department of Science and Water Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran.

Received: 12 May 2016

Accepted: 22 February 2017

Keywords: ARIMA, Artificial Wavelet Neural Networks, Drought, Forecasting, SPI.

Introduction

Drought prediction in water resources systems plays an important role in reducing drought damage. In recent decades, Traditional methods including: fitting and mathematical models have been widely used to predict droughts. The combination of wavelet theory and neural networks has led to the expansion of the wavelet-neural networks. The application of the wavelet as training function in the neural network has recently been identified as a substitute method in neural networks. In these models, the position and scale coefficients of the wavelets are optimized in addition to the weights (Thuillard, 2000). Considering the importance of short-term drought prediction in water resources engineering and the nonlinear characteristics of the SPI series of three months, the purpose of this study is to present an Artificial Wavelet Neural Networks integrated model for predicting short-term drought at Bidestan station in Qazvin plain. In this research, Multi-Layer Perceptron (MLP), Radial Base Function (RBF), ARIMA time series, as well as Artificial Wavelet Neural Networks integrated model and Multi-layer Perceptron (WA-MLP) and Radial Bonding Function (WA- RBF) were used, which is done by analyzing the time series investigated by the wavelet transformation and the entry of these sub-series into an artificial neural network.

According to previous researches on drought prediction, short-term drought prediction (with the definition of a three-month standard rainfall index) using the combined model of Wavelet-Neural Network and comparing its results with artificial neural network and ARIMA time series models has not been compared. In this paper, five short-term drought prediction models have been compared and a better performance model has been introduced.

Methodology

In the current study, monthly rainfall data of the Bidestan Rainfall Station in Qazvin and Shoor watershed was used during the statistical period of 1970-1971 to 2013-2014. After ensuring the accuracy of the monthly rainfall data and performing the required statistical tests, the time series of the drought situation was calculated during the statistical period based on the SPI values in the short-term period of 3 months.

Artificial neural networks are able to provide a nonlinear mapping between inputs and outputs by selecting appropriate number of layers and neurons. In time series issues, the number of input neurons depends on the number of observations that are used to find relationships in time series

and to predict future values. Using mathematical equations, it is proved that the three-layer MLP networks are suitable for estimating each non-linear complex function with the desired accuracy. In this research, the artificial wavelet neural network MLP and RBF have been used. For modeling, SPI time series data were divided into two parts; Part I: The SPI values set from 1970-1971 to 2005-2006 as network education data and Part II: the SPI values were used as network evaluation data from 2005-2006 to 2013-2014.

Wavelet transform is one of the most efficient mathematical transformations in signal processing. It consists of two types of continuous wavelet transform (CWT) and discrete wavelet transform (DWT). A discrete wavelet transform for processing and analysis of time series is more appropriate than its continuous type. After analysis of the signal (within a three months period) by selected mother wavelet, the wavelet coefficients were defined as artificial neural network inputs.

The ARIMA model was used to model the time series of the standard rainfall index within a three-months time series.

Results and Discussion

In order to evaluate and review the performance of the tested models and determine the accuracy of the selected model, four criteria including absolute mean error (MAE), root mean square error (RMSE), coefficient of determination (R^2) and Nash-Sutcliffe coefficient (NS) were used according to table (1).

Table 1- Results of testing of MLP, RBF, WA-ANN networks and time series for the SPI optimal learning environment within a three-months period

Model	Step	Index Evaluation			
		R^2	RMSE	MAE	NS
MLP 5-4-1	Education	0.48	0.123	0.11	0.46
	Test	0.488	0.121	0.91	0.46
	Evaluation	0.49	0.12	0.01	0.47
RBF 4-10-1	Education	0.467	0.15	0.11	0.45
	Test	4.75	0.13	0.01	0.47
	Evaluation	0.47	0.14	0.01	0.46
ARIMA (1,0,1),(2,0,2)	Education	0.49	0.14	0.12	0.47
	Test	0.47	0.14	0.11	0.456
	Evaluation	0.46	0.15	0.12	0.45
WA-MLP 3-10-1	Education	0.86	0.06	0.35	0.75
	Test	0.869	0.58	0.03	0.75
	Evaluation	0.87	0.05	0.03	0.76
WA-RBF 2-5-1	Education	0.60	0.12	0.05	0.58
	Test	0.61	0.11	0.05	0.59
	Evaluation	0.61	0.11	0.55	0.60

The results showed that the efficiency of the MLP network is higher than the RBF network for the SPI within a three-months (short-term) time series.

In order to use the wavelet-neural network model, we must first, select the mother wavelet. In this research, Mayer wavelet is selected as the mother wavelet. Based on Table 1, the results indicated that the wavelet-neural network method is superior to other predictive methods used in this study. The wavelet-neural network model of the WA-MLP has higher accuracy than the WA-RBF model. The highest regression coefficient ($R^2=0.87$), NS coefficient (0.76), the lowest RMSE and MAE were 0.05 and 0.03, respectively, related to the WA-MLP model.

The results showed that the ARIMA model provided poor results for drought prediction than the other models used in this study.

Conclusions

The comparison of the models' efficiency studied in this research showed that wavelet neural network WA-MLP has better performance compared with the other models in predicting the standard rainfall index (three month intervals). The higher accuracy of the wavelet-neural network model is not only due to the preprocessor and the wavelet coefficients under various signals, but because of the attention to the effect of each sub-parser signal by its relative weight magnification sub signals.

References

Thuillard, M. 2000. A review of wavelet networks, wavelet, fuzzy wavelet and their application. ESIT. *In Presented in Conference, Aachen, Germany.*