

تخمین خشکسالی در استان لرستان با استفاده از شبکه‌های هوشمند

حسن ترابی پوده^{۱*}، رضا دهقانی^۲، سعید رستمی^۳

۱- دانشیار، گروه مهندسی آب، دانشگاه لرستان

۲- دانشجوی دکترا، سازه‌های آبی، دانشگاه لرستان

۳- سعید رستمی، دانشجوی دکترا، سازه آبی

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 ایفا می‌نماید. در این پژوهش جهت تخمین شاخص بارش استاندارد ۱۲ ماهه چهار ایستگاه باران سنجی نورآباد، الشتر، درود و بروجرد واقع در استان لرستان از مدل شبکه عصبی موجک استفاده شد و نتایج آن با سایر روش‌های هوشمند از جمله شبکه عصبی مصنوعی مقایسه گردید. برای این منظور از پارامتر بارش در مقیاس زمانی ماهانه در طی دوره آماری (۱۳۷۲-۱۳۹۲) بعنوان ورودی و شاخص بارش استاندارد بعنوان پارامتر خروجی مدلها انتخاب گردید. معیارهای ضریب همبستگی، ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا برای ارزیابی و عملکرد مدلها مورد استفاده قرار گرفت. نتایج نشان داد هر دو مدل قابلیت خوبی در تخمین شاخص بارش استاندارد دارند، لیکن از لحاظ دقت، مدل شبکه عصبی موجک در ایستگاه درود ضریب همبستگی ۰/۸۱۱ و کمترین ریشه میانگین مربعات خطا ۰/۰۶۸ میلی‌متر و کمترین میانگین قدر مطلق خطا ۰/۰۵۱ میلی‌متر، در ایستگاه بروجرد ضریب همبستگی ۰/۸۸۵ و کمترین ریشه میانگین مربعات خطا ۰/۰۵۶ میلی‌متر و کمترین میانگین قدر مطلق خطا ۰/۰۴۸ میلی‌متر، ایستگاه الشتر ضریب همبستگی ۰/۸۲۷ و کمترین ریشه میانگین مربعات خطا ۰/۰۴۵ میلی‌متر و کمترین میانگین قدر مطلق خطا ۰/۰۳۹ میلی‌متر و در نهایت در ایستگاه نورآباد با ضریب همبستگی ۰/۸۴۹ و کمترین ریشه میانگین مربعات خطا ۰/۰۵۰ میلی‌متر و کمترین میانگین قدر مطلق خطا ۰/۰۴۶ میلی‌متر در مرحله صحت‌سنجی نسبت به سایر ساختارها جهت مدل‌سازی شاخص بارش استاندارد در مقیاس زمانی ماهانه عملکرد بهتری نسبت به شبکه عصبی مصنوعی از خود نشان داده است. در مجموع نتایج نشان داد استفاده از مدل شبکه عصبی موجک می‌تواند در زمینه تخمین خشکسالی موثر باشد که در نوبه خود برای تسهیل توسعه و پیاده‌سازی استراتژی‌های مدیریتی جهت جلوگیری از ایجاد خشکسالی مفید است.

کلید واژگان: بارش، خشکسالی، شاخص بارش استاندارد، شبکه عصبی موجک

مقدمه

خشکی و خشکسالی یکی از ویژگیهای اجتناب ناپذیر و زیانبار اقلیمی کشور ایران به شمار می رود، بنابراین پژوهش و مطالعه در این زمینه بسیار ضروری است. خشکسالی غالباً یک پدیدهٔ خزنده توصیف می شود و توصیف زمانی و مکانی آن بسیار مشکل است. یکی از قدمهای مهم و اساسی در مطالعات خشکسالی و ترسالی برای بیان کمی خشکسالی و همچنین ارزیابی آن در مقیاسهای مختلف زمانی و مکانی در هر منطقه، تعیین شاخصهایی است که میتوان براساس آنها میزان شدت و تداوم خشکسالی و ترسالی را ارزیابی کرد. شاخص بارش استاندارد که یکی از جامعترین شاخص مطالعه خشکسالی و ترسالی به شمار می آید. تغییرپذیری آن باعث می شود که در مقیاسهای کوتاه مدت برای اهداف کشاورزی و در مقیاس های بلندمدت برای اهداف هیدرولوژی مورد استفاده قرار گیرد. پیشبینی خشکسالی در برنامه ریزیهای کشاورزی منابع آب با اهمیت بوده و در یک نظام هدفمند و جامع مدیریتی منجر به برنامه ریزی در ذخیره آبی سدها، پیش-بینی میزان واردات موادغذایی، تغییر الگوی کشت، اطلاع رسانی برای پیش آگاهی مبارزه با خشکسالی و غیره خواهد شد. امروزه سیستم های هوشمند به طور گسترده برای پیش بینی پدیده های غیرخطی مورد استفاده قرار می گیرد، که شبکه عصبی موجک و شبکه عصبی مصنوعی از جمله این روشها است. شبکه های عصبی مصنوعی با الهام از سیستم پردازش اطلاعات مغز طراحی که توانایی آن در تقریب الگوهای یک مساله سبب افزایش دامنه کاربرد این شبکه ها شده است. طی سالهای اخیر استفاده از روش های هوشمند در مطالعات شاخص بارش استاندارد حوضه های آبریز مورد توجه محققین قرار گرفته است، که از جمله می توان به موارد ذیل اشاره نمود:

نصیری (۱۳۸۹) با استفاده از عناصر اقلیمی و الگوهای پیوند از دور، خشک سالی های شهر شیراز را با مدل شبکه عصبی پیش بینی کرد. نتایج نشان داد که پیش بینی گسسته ی خشک سالی زمستانه به مراتب دقیق تر از پی شبینی پیوسته ی خشک سالی است. گلابی و همکاران (۱۳۹۲) عملکرد شبکه عصبی مصنوعی و سری های زمانی در مدل سازی شاخص خشکسالی بارش استاندارد را در

ایستگاههای منتخب استان خوزستان را مورد بررسی قرار دادند و نشان دادند مدل های سری زمانی در دوره های زمانی مورد مطالعه عملکرد بهتری در پیش بینی مقادیر شاخص بارش استاندارد نسبت به شبکه های عصبی مصنوعی دارند و شبکه عصبی مصنوعی پرسپترون چندلایه نیز نسبت به شبکه عصبی مصنوعی تابع پایه ی شعاعی توانایی بهتری دارد. نگارش و آرمش (۱۳۹۰) عملکرد شبکه عصبی مصنوعی را جهت پیش بینی خشکسالی شهر خاش مورد بررسی قرار دادند و نشان دادند شبکه عصبی مصنوعی نسبت به مدل رگرسیونی از دقت بیشتری برخوردار است. نتایج حاصل از پژوهش صف شکن و رادمنش (۱۳۹۳) که جهت پیش بینی شاخص خشکسالی بارش استاندارد از شبکه عصبی مصنوعی استفاده نمودند نشان داد که شبکه عصبی دقت بالایی در تخمین شاخص بارش استاندارد دارد. افخمی و همکاران (۱۳۹۴) در پژوهشی تاثیر پردازش متغیرهای ورودی شاخص بارش استاندارد در پیش بینی خشکسالی با استفاده از شبکه عصبی مصنوعی را مورد بررسی قرار دادند و نشان دادند شبکه عصبی مصنوعی با تبدیل موجک عملکرد قابل قبولی در پیش بینی خشکسالی دارد. میسرا و همکاران (Mishra et al., 2007) برای پیش بینی خشک سالی در حوضه ی رودخانه ی کاناباتی از مدل هیبریدی و یک شبکه غیرخطی عصبی مصنوعی استفاده کردند. نتایج نشان داد که مدل ترکیبی مورد نظر دقت بالایی برای پیش بینی خشک سالی دارد. باروا و همکاران (et al., 2010) برای پیش بینی خشک سالی روش ADI و دو نوع از شبکه های عصبی RMSNN را بکار گرفتند. نتایج نشان داد شبکه های را بکار گرفتند. نتایج نشان داد شبکه های RMSNN برای پیش بینی سه ماهه و شبکه های DMSNN برای بازه ی زمانی شش ماهه نتایج بهتری دارند. بلاینه و همکاران (Belayneh et al., 2014) جهت پیش بینی شاخص بارش استاندارد در رودخانه آواش در اتیوپی از مدل های شبکه عصبی موجک و مدل ترکیبی موجک SVR استفاده نمودند و نشان دادند مدل شبکه عصبی موجک دقت بالایی در تخمین شاخص بارش استاندارد دارد. نتایج پژوهش جلال کمالی و همکاران (et al., 2015) که جهت تخمین شاخص بارش استاندارد از

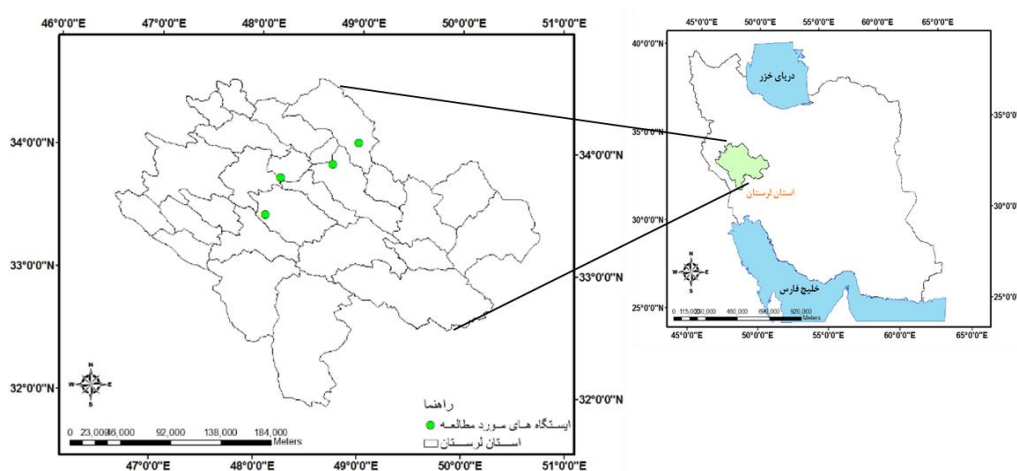
استان لرستان از لحاظ شرب و کشاورزی تغییرات شاخص بارش استاندارد به منظور پیش بینی و اقدامات مدیریتی جهت جلوگیری از خشکسالی بیش از پیش ضروری است. لذا هدف از این تحقیق تخمین شاخص بارش استاندارد این ایستگاه‌ها با استفاده از مدل شبکه عصبی موجک و شبکه های عصبی مصنوعی بر اساس پارامتر بارش به عنوان پارامترهای ورودی و شاخص بارش استاندارد بعنوان خروجی مدل در مقیاس زمانی ماهانه می باشد.

مواد و روش‌ها

منطقه مورد مطالعه

جغرافیای لرستان به دلیل قرار گرفتن این استان در رشته کوه‌های زاگرس جغرافیایی کوهستانی و چهارفصل است. این استان یکی از استانهای کوهستانی غرب ایران بوده که بیشتر مناطق این استان را کوههای زاگرس پوشانده است. آب و هوای استان لرستان متنوع و تنوع آب و هوا در آن از شمال شرق به جنوب غرب کاملاً مشهود است. استان لرستان سومین استان پر آب کشور و ۱۲ درصد آبهای کشور را در اختیار دارد. دشت های نورآباد، الشتر، بروجرد و درود در این استان در ناحیه های شمال و شمال شرق با آب و هوای معتدل مرکزی قرار دارند که در شکل ۱ موقعیت ایستگاه های هیدرومتری مورد مطالعه در استان لرستان نشان داده شده است. همچنین در جدول ۱ موقعیت جغرافیایی این ایستگاه‌ها قابل مشاهده است.

مدل های هوشمند استفاده کردند نشان داد مدل ARIMAX نسبت به مدل های هوشمند از عملکرد بهتری برخوردار است. گای و همکاران (Gaye et al., 2015) در پژوهشی به تجزیه و تحلیل شاخص بارش استاندارد با استفاده از شبکه عصبی مصنوعی پرداختند در این پژوهش از داده های بارش حوضه سیواس در آناتولی مرکزی جهت بررسی شاخص بارش بهره گرفتند و نشان دادند شبکه عصبی مصنوعی دقت بالایی در پیش بینی شاخص بارش استاندارد دارد. بوی و گمانه (Djrbouai and Gamane, 2016) کاربرد شبکه عصبی موجک را جهت تجزیه و تحلیل شاخص خشکسالی حوضه الجزایر بررسی نمودند و به این نتیجه دست یافتند که شبکه عصبی موجک دقت بالاتری نسبت به شبکه عصبی مصنوعی دارد. نتایج حاصل از پژوهش ماکا و پیچ (Maca and Pech, 2016) که جهت پیش بینی شاخص خشکسالی SPI از شبکه عصبی مصنوعی در حوضه دریای ایالات متحده طی سالهای ۱۹۴۸-۲۰۰۲ استفاده نمود نشان داد شبکه عصبی مصنوعی عملکرد قابل قبولی در پیش بینی SPI دارد. ذوالفقار و همکاران (Zulifqar et al., 2017) در پژوهشی با استفاده از شبکه عصبی مصنوعی شاخص خشکسالی را در ۱۷ ایستگاه هواشناسی با استفاده از پارامتر تخییر مورد بررسی قرار دادند و به این نتیجه رسیدند شبکه عصبی مصنوعی قابلیت بالایی در تخمین شاخص خشکسالی دارد. در مجموع با توجه به پژوهشهای انجام شده و همچنین اهمیت دشت های نورآباد، الشتر، بروجرد و درود واقع در



شکل ۱- منطقه مورد مطالعه و ایستگاه های مورد بررسی

جدول ۱- مشخصات جغرافیایی ایستگاه های مورد بررسی

ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع از سطح دریا (m)	میانگین بارش (m)
دورود	۴۸/۰۶۵	۳۳/۴۷۶	۱۸۰۰	۵۷/۶۸۹
بروجرد	۴۸/۷۱۹	۳۳/۹۰۰	۱۵۳۰	۴۲/۲۷۵
الشت	۴۸/۲۰۷	۳۳/۷۸۶	۱۵۶۰	۴۸/۰۵۴
نورآباد	۴۸/۹۷۰	۳۴/۰۸۲	۱۴۵۰	۴۲/۵۶۱

شاخص بارش استاندارد (SPI)

درک اینکه بارندگی تاثیرهای مختلفی بر منابع آب مانند آب زیرزمینی، ذخایر آب سطحی و برف دارد، منجر به تدوین شاخص SPI گردید. این شاخص بمنظور پایش خشکسالی اقلیمی ایالت کلرادو آمریکا توسط مک کی و همکاران در سال ۱۹۹۳ ابداع گردید. محاسبه شاخص SPI، مستلزم برازش توزیع احتمالاتی مناسب به سری طولانی مدت داده های بارندگی در هر بازه زمانی دلخواه در هر ایستگاه است. بسیاری از پژوهشگران از جمله مک کی و همکاران (McKee et al., 1993) توزیع گاما را پیشنهاد دادند. با فرض پیروی مقدار بارندگی از توزیع گاما، گام بعدی در محاسبه شاخص SPI انتقال احتمال تجمعی بدست آمده از توزیع گاما به توزیع نرمال استاندارد تجمعی با میانگین صفر و انحراف از معیار یک است. در واقع SPI عبارتست از متغیری از تابع توزیع احتمال استاندارد که مقدار احتمال تجمعی آن با مقدار احتمال تجمعی متغیر مورد نظر از توزیع گامای بدست آمده، یکسان باشد. برای تعیین سال های شاخص خشکسالی و ترسالی در دوره آماری ۱۳۷۲-۱۳۹۲، از شاخص بارش استاندارد شده SPI استفاده شد. بسیاری از محققان انعطاف پذیری شاخص SPI و قابلیت آن برای مقیاس های مختلف زمانی را تایید نمودند (Edwards, 1997). این شاخص برای هر منطقه براساس ثبت بارش های طولانی مدت آن محاسبه می شود. ابتدا توزیع آماری مناسب برای آمار بلند مدت بارندگی ها برازش داده و سپس تابع تجمعی توزیع با استفاده از احتمالات مساوی به توزیع نرمال تبدیل می شود، بطوریکه استاندارد شده و متوسط آن برای هر منطقه و دوره مد نظر صفر شود (Edwards, 1997). مقادیر مثبت SPI نشان دهنده بارش بیش از میزان متوسط و مقادیر منفی آن معنای

عکس دارد. طبق این روش دوره خشکسالی رخ می دهد که شاخص SPI بطور مستمر منفی و به مقدار ۱- و کمتر برسد و زمانی پایان می یابد که SPI مثبت شود که در جدول ۲ نشان داده شده است. شاخص بارش استاندارد SPI طبق رابطه زیر قابل محاسبه است.

$$SPI_n = \frac{p_0 + \sum p_i - H_n}{\delta_n} \quad (1)$$

که در آن، n تعداد ماههایی که بارش تجمعی شان محاسبه شده است؛ P0 مقدار نرمال شده بارش ماه فعلی؛ P-i مقدار نرمال شده بارش ماه قبل؛ میانگین بارش تجمعی n ماه و انحراف معیار بارش تجمعی n ماه می باشد.

جدول ۲- طبقه بندی مقادیر شاخص SPI

مقادیر	طبقات
$2 >$	ترسالی بسیار شدید
$1.5 < SPI < 1.99$	ترسالی شدید
$1 < SPI < 1.49$	ترسالی
$-0.99 < SPI < 0.99$	نرمال
$-1.49 < SPI < -1$	خشکسالی
$-1.99 < SPI < -1.5$	خشکسالی شدید
$2 <$	خشکسالی بسیار شدید

شبکه عصبی موجک

تبدیل موجک به عنوان روشی جایگزین برای تبدیل فوریهی زمان کوتاه ارائه شده است و هدف از ارائه آن، غلبه بر مشکلات مربوط به قدرت تفکیک پذیری فرکانس در تبدیل فوریهی زمان کوتاه است. در تبدیل موجک همانند تبدیل فوریهی زمان کوتاه، سیگنال مورد نظر به پنجرههایی تقسیم شده و تبدیل موجک بر روی هر کدام از


تبدیل موجک به دو صورت پیوسته و گسسته تعریف می‌شود.

تبدیل موجک پیوسته^۴ (CWT)

تبدیل موجک پیوسته‌ی تابع $f(t)$ به صورت روابط (۲) و (۳) تعریف می‌شود (واپنیک، ۱۹۹۸).

رابطه‌ی (۲) یک رابطه با دو متغیر S و τ است که S پارامتر مقیاس^۵ (عکس فرکانس) و τ پارامتر انتقال^۶ می‌باشند. علامت * نیز نشان دهنده‌ی مزدوج مختلط است. Ψ تابع پنجره یا موجک مادر^۷ و $\frac{1}{\sqrt{|s|}}\Psi(\frac{t-\tau}{s})$ موجک‌های حاصل از انتقال و تغییر مقیاس موجک مادر هستند (وانگ و همکاران، ۲۰۰۰). واژه‌ی مادر به این سبب به کار می‌رود که تمامی نسخه‌های انتقال یافته و مقیاس شده (موجک‌های دختر^۸)، همگی از این تابع به دست می‌آیند. یعنی موجک مادر یک الگو برای سایر پنجره‌هاست. علامت (...) نیز نشان دهنده‌ی ضرب برداری دو تابع در فضای سیگنال است. نمونه‌ای از ساختار شبکه سه لایه ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۲ نشان داده شده است.

این پنجره‌ها به صورت جداگانه انجام می‌گیرد (Vapnik.,1998). اما مهم‌ترین تفاوت آن‌ها در این است که در تبدیل موجک علاوه بر اینکه قدرت تفکیک فرکانس‌های یک سیگنال یا طول پنجره، متناسب با نوع فرکانس تغییر می‌کند، هم‌زمان عرض پنجره یا مقیاس فرکانس نیز متناسب با نوع فرکانس تغییر می‌کند. به عبارت دیگر، در تبدیل موجک به جای فرکانس، مقیاس وجود دارد. یعنی تبدیل موجک، نوعی تبدیل زمان - مقیاس است. بر همین اساس با استفاده از تبدیل موجک، در مقیاس‌های بالا سیگنال منبسط شده و جزئیات سیگنال قابل تجزیه و تحلیل است و در مقیاس‌های پایین سیگنال منقبض شده و کلیات سیگنال قابل بررسی می‌باشد (Wang et al.,2000). یک موجک به معنای موج کوچک، بخشی یا پنجره‌ای از سیگنال اصلی است که انرژی آن در زمان متمرکز شده است. با استفاده از تبدیل یا آنالیز موجک می‌توان یک سیگنال یا سری زمانی مادر را به موجک‌هایی با سطح تفکیک و مقیاس‌های مختلف تجزیه کرد. بنابراین موجک‌ها نمونه‌های انتقال یافته^۱ و مقیاس شده^۲ سیگنال مادر هستند که نوساناتی در یک طول متناهی داشته و شدیداً میرا هستند. بر اساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی نامانا و گذرا^۳ را به صورت موضعی مورد تجزیه و تحلیل قرار داد (Shin et al.,2005).



شکل ۲- نمای کلی یک شبکه عصبی موجک سه لایه‌ای

- 4. Continues Wavelet Transform
- 5 Scaling
- 6 TranslatiOn
- 7 Mother Wavelet
- 8 Daughter Wavelets

- 1. Translation
- 2. Translation
- 3. Transient

$$CWT_f^\psi(s, \tau) = \Psi_f^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \Psi^* \left(\frac{t-\tau}{s} \right) dt = \langle f(t), \Psi_{s,\tau}(t) \rangle \quad (2)$$

$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \Psi \left(\frac{t-\tau}{s} \right) \quad (3)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum |x_i - y_i| \quad (6)$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام های زمانی، \bar{x} و \bar{y} نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان نیز جهت تحلیل بیشتر نتایج استفاده شده است.

یافته ها

در این تحقیق به منظور بررسی نتایج مدلها جهت پیش بینی شاخص بارش استاندارد از داده های ماهانه ۴ ایستگاه بارانسنجی در طی دوره آماری (۱۳۹۲-۱۳۷۲) استفاده گردید. ابتدا مقادیر شاخص بارش استاندارد ۱۲ ماهه محاسبه و تحلیل شد و سپس بعنوان خروجی در مدلها با توجه به پارامتر ورودی بارش در هر ایستگاه مورد بررسی، منظور گردید. تعداد ۸۰ درصد از داده ها (۹۲ رکورد)، به منظور آموزش و ۲۰ درصد باقی (۴۸ رکورد)، برای صحت سنجی انتخاب گردید یک نکته مهم در آموزش شبکه های عصبی نرمال سازی داده ها قبل از استفاده در مدل می باشد این عمل خصوصا وقتی دامنه تغییرات ورودی ها زیاد باشد کمک شایانی به آموزش بهتر و سریعتر مدل می کند. اصولا وارد کردن داده ها بصورت خام باعث کاهش سرعت و دقت شبکه می شود (ژو و همکاران، ۲۰۰۷). برای نرمال سازی داده های تحقیق از رابطه زیر استفاده شده است:

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (10)$$

که در آن X_n مقدار نرمال شده ورودی X_i و X_{\min} و X_{\max} به ترتیب حداکثر و حداقل داده ها می باشد.

شبکه عصبی مصنوعی


امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (Nourani et al., 2011). ساختار شبکه عصبی معمولا از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال دهنده و وسیله ای برای تهیه کردن داده ها، لایه خروجی شامل مقادیر پیش بینی شده توسط شبکه و لایه میانی یا مخفی که از گره های پردازشگر تشکیل شده اند، محل پردازش داده ها است. نخستین کاربرد عملی شبکه های عصبی مصنوعی با معرفی شبکه های پرسپترون چند لایه^۱ انجام گرفت. در این شبکه ها ثابت شده است که از میان الگوریتم های یادگیری، الگوریتم پس انتشار خطا^۲ با ساختار شبکه پیش خور^۳ و تعداد سه لایه بطور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه سازی و پیش بینی سری های زمانی هیدرولوژیکی کاربرد دارد (Nourani et al., 2009). از رایج ترین توابع محرک استفاده شده در شبکه های انتشار برگشتی می توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (Tokar and Johnson., 1999). نمونه ایی از ساختار شبکه سه لایه ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۳ نشان داده شده است.

معیارهای ارزیابی

در این تحقیق به منظور ارزیابی دقت و کارایی مدل ها، از نمایه های ضریب همبستگی (R)، ریشه میانگین مربعات خطا ($RMSE$) و میانگین قدر مطلق خطا طبق روابط زیر استفاده گردید. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و صفر می باشد.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (4)$$

1. Multi-Layer Perceptron
2. Back Propagation (BP)
3. Feed Forward



شکل ۳- نمای کلی یک شبکه عصبی مصنوعی سه لایه

مکزیکی به‌عنوان توابع فعال‌سازی که مشتق دوم تابع گوسی بوده، تبدیل می‌یابند. جهت آموزش شبکه از الگوریتم گرادینان نزولی که در یادگیری شبکه‌های عصبی و حداقل سازی مقدار خطای و تنظیم پارامترهای شبکه استفاده می‌شود، بکار گرفته شد. همچنین جهت مقایسه نتایج شبکه عصبی موجک از مدل شبکه عصبی مصنوعی استفاده شد که در این شبکه تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. آموزش شبکه‌های پرسپترون چند لایه با استفاده از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لونیبرگ - مارکووارت به دلیل همگرایی سریع‌تر در آموزش شبکه، استفاده شد. همچنین از ترکیبات مختلف توابع محرک در لایه (های) مخفی استفاده گردید. تعداد تکرارهای لازم در فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه به کمک معیار میانگین مربعات خطا مورد ارزیابی قرار گرفته است. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مساله مورد بررسی مشخص شده، حال آن‌که تعداد نرون‌های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید. روند کار با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه می‌یابد که افزایش نرون‌های بیشتر تاثیری در بهبود خطا نداشته باشد، ادامه می‌یابد.

همانطور که در جدول ۳ مشاهده می‌شود شبکه عصبی موجک دقت بیشتر و خطای کمتری نسبت به شبکه عصبی

هدف کلی از مدل‌های هوشمند بیان ارتباط بین متغیرهایی است که یافتن پیچیدگی آنها در طبیعت کاری دشوار با عدم قطعیت بالا است. شاخص بارش استاندارد از پارامترهای مهم خشکسالی است که تخمین آن در گام‌های زمانی آینده از اهمیت بالایی برخوردار است. به این منظور در جهت کاهش خطا و همچنین برآورد پارامتر شاخص بارش استاندارد با دقت بالا با استفاده از کمترین پارامترهای ورودی روش ذکر شده مورد استفاده قرار گرفت که در مقایسه با روش‌های تقریبی بمراتب عملکرد بهتری را ارائه خواهد داد. هدف از این پژوهش دریافت این پیچیدگی طبیعی بین پارامترهای هواشناسی و ارائه مدل جهت پیش‌بینی در آینده است و از آنجاییکه بارش از اهمیت بالاتری نسبت به دیگر پارامترها برخوردار می‌باشد بنابراین این پارامتر بعنوان متغیر هدف انتخاب شد. تفکیک داده‌ها بصورت تصادفی صورت گرفته است لازم به ذکر است جهت مدل‌سازی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده جهت تست، بصورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد، انتخاب شد (Kisi et al., 2006; Nagy et al., 2002).

به‌منظور مدل‌سازی شاخص بارش استاندارد در ایستگاه‌های باران‌سنجی دورود، بروجرد، الشتر و نورآباد واقع در استان لرستان از مدل شبکه عصبی موجکی با لایه‌های پنهان و با تعداد نرون‌های متفاوت استفاده شده است. در مدل عصبی موجکی ابتدا موجک مناسب (سیملت) انتخاب گردید. سپس با اعمال تبدیل روی داده‌ها، ضرایب تقریب و جزئیات آنها استخراج گردید و داده‌ها بوسیله تابع موجک کلاه

میانگین مربعات خطا ۰/۰۴۵ میلی متر و کمترین میانگین قدر مطلق خطا ۰/۰۳۹ میلی متر و در نهایت در ایستگاه نورآباد با ضریب همبستگی ۰/۸۴۹ و کمترین ریشه میانگین مربعات خطا ۰/۰۵۰ میلی متر و کمترین میانگین قدر مطلق خطا ۰/۰۴۶ میلی متر در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدل سازی شاخص بارش استاندارد در مقیاس زمانی ماهانه مناسب تر خواهد بود.

مصنوعی برخوردار است بگونه ای که در ایستگاه درود ضریب همبستگی ۰/۸۱۱ و کمترین ریشه میانگین مربعات خطا ۰/۰۶۸ میلی متر و کمترین میانگین قدر مطلق خطا ۰/۰۵۱ میلی متر، در ایستگاه بروجرد ضریب همبستگی ۰/۸۸۵ و کمترین ریشه میانگین مربعات خطا ۰/۰۵۶ میلی متر و کمترین میانگین قدر مطلق خطا ۰/۰۴۸ میلی متر، ایستگاه الشتر ضریب همبستگی ۰/۸۲۷ و کمترین ریشه

جدول ۳- ساختار و توابع محرک بهینه در مدل های شبکه های عصبی موجک و شبکه عصبی مصنوعی و شاخص های آماری در

مراحل آموزش و صحت سنجی


صحت سنجی			آموزش			تابع محرک	ساختار	ایستگاه	مدل
MAE	RMSE	R	MAE	RMS E	R				
۰/۰۵۱	۰/۰۶۸	۰/۸۱۱	۰/۰۵۰	۰/۰۵۷	۰/۸۲۰	کلاه مکزیکی	۱-۷-۱	دورود	شبکه عصبی موجک
۰/۰۴۸	۰/۰۵۶	۰/۸۸۵	۰/۰۴۱	۰/۰۴۸	۰/۸۹۰	کلاه مکزیکی	۱-۵-۱	بروجرد	
۰/۰۳۹	۰/۰۴۵	۰/۸۲۷	۰/۰۴۵	۰/۰۵۷	۰/۸۳۸	کلاه مکزیکی	۱-۸-۱	الشتر	
۰/۰۴۶	۰/۰۵۰	۰/۸۴۹	۰/۰۳۰	۰/۰۴۰	۰/۸۵۷	کلاه مکزیکی	۱-۱۰-۱	نورآباد	شبکه عصبی مصنوعی
۰/۰۸۹	۰/۱۰۲	۰/۷۸۴	۰/۰۷۶	۰/۰۹۳	۰/۷۹۲	تانزانته هیپربولیک	۱-۶-۱	دورود	
۰/۰۶۷	۰/۰۸۹	۰/۷۵۲	۰/۰۵۷	۰/۰۷۵	۰/۷۶۰	تانزانته هیپربولیک	۱-۷-۱	بروجرد	
۰/۰۵۹	۰/۰۷۵	۰/۷۲۶	۰/۰۵۳	۰/۰۶۱	۰/۷۵۰	تانزانته هیپربولیک	۱-۹-۱	الشتر	نورآباد
۰/۰۷۹	۰/۰۹۷	۰/۷۹۱	۰/۰۶۳	۰/۰۷۴	۰/۸۰۰	تانزانته هیپربولیک	۱-۸-۱	دورود	

دورود و بروجرد نسبت به سایر ایستگاه ها عملکرد بهتری در تخمین مقادیر داشته است. در مجموع همانطور که در اشکال ۴ و ۵ قابل مشاهده است نتایج حاکی از برتری کامل مدل شبکه عصبی-موجکی نسبت به مدل شبکه عصبی در پیش بینی شاخص بارش استاندارد می باشد. با اینکه مدل ANN بخاطر در اختیار داشتن کرنل غیرخطی توانایی مدل سازی رفتارهای غیرخطی را داراست، ولی با توجه به ویژگی های نا ایستایی و غیر خطی بودن سری شاخص بارش استاندارد، به منظور پیش بینی و شبیه سازی دقیق ملزم به استفاده از شبکه عصبی- موجکی می باشیم. چرا که شبکه عصبی به تنهایی قادر به غلبه بر نایستایی سیگنال نمی باشد. در حالیکه تبدیل موجکی با جدا نمودن سیگنال به فرکانس های بالا و پائین ویژگی های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می برد.

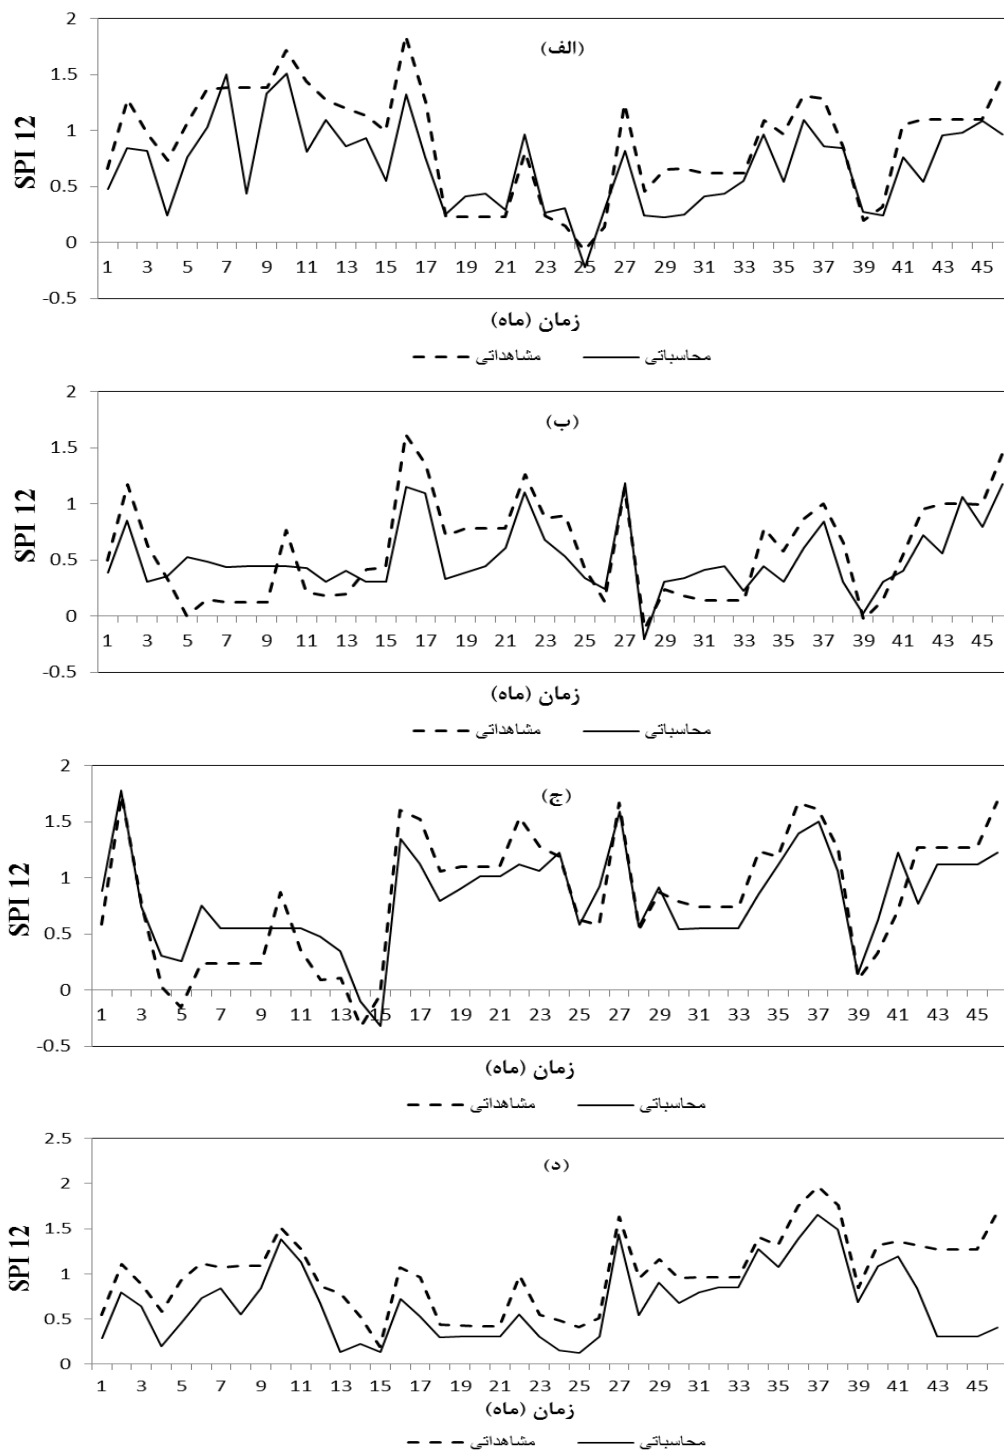
در شکل ۴ نمودار بهترین مدل حاصل شده برای داده های بخش صحت سنجی مدل شبکه عصبی موجک نشان داده شده است. که در این شکل تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان قابل مشاهده است، همانطور که مشاهده می شود مدل شبکه عصبی موجکی در تخمین اکثر مقادیر در هر چهار ایستگاه مورد بررسی عملکرد قابل قبولی داشته است. همانطور که در این شکل نشان داده شده است در ایستگاه های الشتر و نورآباد در تخمین مقادیر بیشینه توانایی مدل مشهود است. اما در ایستگاه های دورود و بروجرد در تخمین مقادیر کمینه نتایج خوبی از خود نشان داده است بگونه ای که این مقادیر را نزدیک به مقدار واقعیشان تخمین زده است. در شکل ۵ نمودار مدل شبکه عصبی مصنوعی برای ایستگاه های دورود، بروجرد، الشتر و نورآباد نشان داده شده است در این شکل ایستگاه های

در نهایت نتایج پژوهش فوق با نتایج پژوهش‌های ذوالفقار و همکاران (Zulifqar et al., 2017)، بوای و گمانه (2016) و همکاران (Djerbouai and Gamane, 2016)، ماکا و پچ (2016) .., (Maca and Pech et al., 2014)، بلانیه و همکاران (Belayneh et al., 2015)، جلال کمالی و همکاران (Jalalkamali) همخوانی دارد در تبیین این نتایج میتوان بیان نمود تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را

در اختیار داشته و دقت مدل را تا حد قابل‌توجهی، بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرم‌تر می‌شود.



شکل ۴ - نمودار مقادیر بهینه مشاهداتی و محاسباتی مدل شبکه عصبی موجک برای داده‌های مرحله صحت‌سنجی (الف) دورود (ب) بروجرود (ج) الشتر (د) نورآباد



شکل ۵- نمودار مقادیر بهینه مشاهداتی و محاسباتی مدل شبکه عصبی مصنوعی برای داده های مرحله صحت سنجی
الف) دورود ب) بروجرد ج) الشتر د) نورآباد

بحث و نتیجه گیری

شناخت ویژگی های خشکسالی لازمه مدیریت منابع آب است. تحلیل پایش خشکسالی از نیازهای اساسی برنامه

ریزی های مدیریتی کشاورزی و منابع آبی محسوب می شود. بدین منظور باید از شاخص های خشکسالی استفاده گردد. شاخص استاندارد شده بارش (SPI) یکی از شاخص

تحقیق نشان می‌دهد استفاده از مدل شبکه عصبی موجک می‌تواند در زمینه تخمین شاخص بارش استاندارد موثر باشد. و همچنین این مدل می‌تواند در نوبه خود برای تسهیل توسعه و پیاده سازی استراتژی های مدیریتی جهت جلوگیری از ایجاد خشکسالی مفید باشد. و گامی در اتخاذ تصمیمات مدیریتی در جهت بهبود منابع آب می باشد.

منابع

1. Afkhami, H., M. Ekhtesasi and M. Mohammadi, 2014, Effect of input variables preprocessing in SPI(Standardized Precipitation Index) prediction using artificial neural network and wavelet transformation. *Iranian Journal of Range and Desert Research*, Vol.22, No.3, pp.570-582
2. Barua, S., B.J.C. Perera, A.M. NG and D.H. Tran, 2010, Drought forecasting using an aggregated drought index and artificial neural networks. *Journal of water and climate change*, Vol. 1, No.3, pp. 206 193 .
3. Belayneh, A., J. Adamowski, B. Khalil and B. Zielinski, 2014, Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models. *Journal of Hydrology*, Vol.508, No.4, pp.418-429.
4. Djerbouai, M and D. Gamane, 2016, Drought Forecasting Using Neural Networks, Wavelet Neural Networks, and Stochastic Models: Case of the Algerois Basin in North Algeria. *Water Resources Management: An International Journal*, Published for the European Water Resources Association (EWRA), Vol.30, No.7, pp.2445-2464
5. Edwards, D.C, 1997, Characteristics of 20th century drought in the United States at multiple time scales. *Climatology Report Number 97-2*, Colorado State University, Fort Collins, Colorado
6. Gaye, O., O. Yildiz and A. Duvan, 2015, A Drought Analysis Of Sivas Using The Standardized Precipitation Index (SPI) Method And Drought Estimation With The Artificial Neural Networks. *International Journal of Advances in Mechanical and Civil Engineering*, Vol.2, No.5, pp. 1-7
7. Golabi, M. R., F. Radmanesh and A. M. Akhondali, 2012, An Investigation of Artificial Neural Network and Time Series Performance in the Index Standard Precipitation Drought Modeling (Case Study: Selected Stations of Khuzestan Province).

های مهمی است که هدف آن اختصاص ارزش عددی به مهم ترین فاکتور اقلیمی (بارندگی) است. این شاخص برای تعیین کمبود بارش در مقیاس های زمانی مختلف بکار می رود. مقیاس های زمانی، تاثیرات خشکسالی را در توانایی منابع آب نشان می دهند. در پژوهش حاضر عملکرد مدل های شبکه عصبی موجک و شبکه عصبی مصنوعی را جهت شبیه سازی شاخص بارش استاندارد در ۴ ایستگاه باران سنجی در طی دوره آماری (۱۳۷۲-۱۳۹۲) مورد ارزیابی قرار گرفت. مقادیر شاخص بارش استاندارد مشاهداتی با شاخص تخمین زده شده این مدلها با استفاده معیارهای ارزیابی بررسی گردید. نتایج تحقیق نشان داد مدل شبکه عصبی موجک در ایستگاه درود با ضریب همبستگی ۰/۸۱۱ و کمترین ریشه میانگین مربعات خطا ۰/۰۶۸ میلی متر و کمترین میانگین قدر مطلق خطا ۰/۰۵۱ میلی متر، در ایستگاه بروجرد ضریب همبستگی ۰/۸۸۵ و کمترین ریشه میانگین مربعات خطا ۰/۰۵۶ میلی متر و کمترین میانگین قدر مطلق خطا ۰/۰۴۸ میلی متر، ایستگاه الشتر ضریب همبستگی ۰/۸۲۷ و کمترین ریشه میانگین مربعات خطا ۰/۰۴۵ میلی متر و کمترین میانگین قدر مطلق خطا ۰/۰۳۹ میلی متر و در نهایت در ایستگاه نورآباد با ضریب همبستگی ۰/۸۴۹ و کمترین ریشه میانگین مربعات خطا ۰/۰۵۰ میلی متر و کمترین میانگین قدر مطلق خطا ۰/۰۴۶ میلی متر در مرحله صحت سنجی نسبت به مدل شبکه عصبی مصنوعی عملکرد بهتری از خود نشان داده است. و همچنین این مدل (شبکه عصبی موجک) در تخمین اکثر مقادیر دقت قابل قبولی از خود نشان داده است. که این نتایج با نتایج پژوهش های ذوالفقار و همکاران (2017) et Djerbouai and ., 2016), بوی و گمانه (Zulifqar al., Gamane همخوانی دارد در تبیین این نتایج می توان بیان نمود شبکه عصبی موجک قادر به پیش بینی شاخص خشکسالی در حجم بالا، که احتیاج به اندازه گیری و کارهای آزمایشگاهی آنها پرهزینه و زمانبر هستند، می باشد. همچنین دقت بالای شبکه عصبی موجک ناشی از تجزیه سیگنال با کمک تابع گسسته موجک، منجر به ساده تر شدن این سیگنال ها شده و باعث ایجاد برتری محسوسی نسبت به مدل شبکه عصبی مصنوعی می باشد. در مجموع این

17. Nourani, V., M.T. Alami and M.H. Aminfar, 2009, A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*, Vol. 22, No.2, pp.466-472.
18. Nourani, V., O. Kisi and M. Komasi, 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*, Vol.402, No. 1-2, pp. 41-59.
19. Safshekan, F., Pir Moradian, N., and R. A. Sharifian, 2011, Simulation of rainfall-runoff hydrograph according to the time pattern of rainfall and the use of artificial neural network in the famous Kasilian Basin. *Engineering Sciences Iranian Journal of Watershed Management*, Vol.5, No.15, pp. 1-10
20. Shin, S., D. Kyung, S. Lee, J. Taik & Kim and J. Hyun, 2005, An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, Vol. 28, No.1, pp. 127-135.
21. Tokar, A and P. Johnson, 1999, Rainfall-Runoff Modeling Using Artificial Neural Networks. *J Hydrol. Eng*, Vol.4, No.3, pp.232-239
22. Vapnik, V.N, 1988, *Statistical Learning Theory*. Wiley, New York.
23. Wang, D., A.A. Safavi and J.A. Romagnoli, 2000, Wavelet-based adaptive robust M-estimator for non-linear system identification. *AIChE Journal*, Vol. 46, No.8, pp.1607-1615.
24. Zhu, Y.M., X.X. Lu and Y. Zhou, 2007 Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjian River in the Upper Yangtze Catchment. *Geomorphology*, Vol.84, No.1, pp.111-125.
25. Zulifqar, A., I. Hussain, M. Faisal, H. Mamona Nazir, T. Hussain, M. Yosafshad, A.M. Shoukry and S. Gani, S, 2017, Forecasting Drought Using Multilayer Perceptron Artificial Neural Network Model. *Advances in Meteorology*, Vol.25, No.1, pp.1-10
- Arid Biome Scientific and Research Journal , Vol.3, No.1, pp.82-87
8. Jalalkamali, A., M. Moradi and M. Moradi, 2015, Application of several artificial intelligence models and ARIMAX model for forecasting drought using the Standardized Precipitation Index. *International Journal of Environmental Science and Technology*. Vol.4, No.12, pp.1201-1210
9. Kaveh, A., and A. Iran Manesh, 2005, *Artificial Neural Networks in Structural Optimization*, Third Edition. Publications Building and Housing Research Center.
10. Kisi, O., M. Karahan and Z. Sen, 2006, River suspended sediment modeling using fuzzy logic approach. *Hydrol Process*, Vol.20, No.2, pp. 4351-4362.
11. Maca, P and P. Pech, 2016, Forecasting SPEI and SPI Drought Indices Using the Integrated Artificial Neural Networks. *Computational Intelligence and Neuroscience*, Vol.24, No.3, pp. 40-57
12. McKee, T.B., N.J. Doesken and J. Kleist, 1993, The Relationship of Drought Frequency and Duration to Time Scales. Eighth Conference on Applied Climatology, January 17e22, Anaheim, California, 179-184.
13. Mishra, A.K., V.R. Desai and P. Singh, 2007, Drought Forecasting Using a Hybrid Stochastic and Neural Network Model. *Journal of Hydrologic Engineering*, Vol.12, No.6, pp. 626-638
14. Nagy, H., K. Watanabe and M. Hirano, 2002, Prediction of sediment load concentration in rivers using artificial neural network model. *Journal of Hydraulics Engineering*, Vol.128, No.4, pp.558-559.
15. Nasiri, M. 2009, Drought prediction using Artificial Neural Networks Case Study of Shiraz Synoptic Station. Master's Degree in Climatology, Sistan and Baluchestan University
16. Negaresh, H and M. Armesh, 2010, Drought Forecasting in Khash City by Using Neural Network Model. *Arid Regions Geographic Studies*, Vol.2, No.6, pp.33-50