

# مقایسه روش های مختلف پیش بینی شاخص خشکسالی SPI

منصور رضائی کلانتری<sup>۱</sup>، مرتضی نبیزاده\*

<sup>۱</sup>دانش آموخته کارشناسی ارشد مهندسی منابع آب، گروه مهندسی آب دانشگاه علوم کشاورزی و منابع طبیعی گرگان.

[Mansur13770@yahoo.com](mailto:Mansur13770@yahoo.com)

\* مسئول مکاتبه: [Nabizade49@gmail.com](mailto:Nabizade49@gmail.com) 09113152357

## چکیده

در این تحقیق به منظور پیش بینی خشکسالی، از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) استفاده شده است. به این منظور از داده های بارندگی ایستگاه کردخیل با دوره آماری 42 ساله در حوزه آبخیز تجن استفاده شد. وضعیت رطوبتی با استفاده از شاخص بارندگی استاندارد شده (SPI) در دوره های زمانی کوتاه مدت (9,6,3 ماهه) و بلند مدت (24,12 و 48 ماهه) محاسبه گردید. سپس از بین داده های محاسبه شده دوره 1345-46 الی 1377-78 به عنوان داده آموزش و دوره 1378-79 الی 87-1386 به عنوان داده آزمون انتخاب گردید. برای تخمین مقدار SPI در زمان  $t$  از مقادیر SPI در زمان های قبل استفاده شد. نتایج نشان داد که شبکه عصبی مصنوعی MLP با دقت بالای مقادیر SPI و وضعیت خشکسالی را پیش بینی می کند. همچنین مقایسه نتایج با نتایج حاصل از به کار گیری سری زمانی ARIMA نشان دهنده دقت بالای دقت بالای این روش می باشد.

واژه های کلیدی: خشکسالی، پیش بینی، شبکه عصبی مصنوعی، SPI,MLP,ARIMA

## مقدمه

خشکسالی پدیده ای طبیعی و تکرار شدنی است که در اثر کاهش میزان بارندگی در یک دوره زمانی مشخص حادث می گردد (شارما و اسماختین، 2004). محققین مختلف نشان دادند که عدم صراحة و شفافیت در تعریف خشکسالی، مانعی برای درک خشکسالی است. این عدم صراحة منجر به تردید و سستی در بخش های مدیریتی، سیاست گذاری و غیره می شود (ویلهت و همکاران، 2000).

پیش بینی خشکسالی در سیستم های منابع آب نقش مهمی در کاهش خسارات خشکسالی ایفا می نماید. به طورستی در چندین دهه اخیر برای پیش بینی خشکسالی از برازش و مدل های ریاضی به طور گسترده استفاده شده است. این مدل ها، سری های زمانی را به صورت مانا<sup>۱</sup> در نظر گرفته و فرآیندها را به صورت خطی مدل سازی می کنند. در دهه های اخیر با توجه به ماهیت غیرخطی پدیده ها، شبکه های عصبی مصنوعی بیشترین توانایی را در مدل سازی و پیش بینی سری های زمانی در هیدرولوژی و مهندسی منابع آب نشان داده است (میشرا و دیزای، 2005).

از مزایای استفاده از شبکه عصبی مصنوعی می توان به موارد زیر اشاره نمود:

شبکه های عصبی مصنوعی قادرند از ساختار داده ها، ارتباط غیرخطی بین متغیرهای ورودی و خروجی را شناسایی کنند.

۱- در این نوع شیوه سازی حتی وقتی مجموعه آموزش دارای اغتشاش و خطای اندازه گیری است، شبکه عصبی

قادر به ارائه نتایج خوبی خواهد بود.

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

جدید خواهد بود (ASCE, 2000).

بارواو همکاران (2010) برای پیش بینی خشکسالی روشن ADI و دو نوع از شبکه های عصبی RMSNN و DMSNN را بکار گرفتند. نتایج نشان داد شبکه های RMSNN برای پیش بینی سه ماهه و شبکه های DMSNN برای بازه زمانی شش ماهه نتایج بهتری دارند. کاتوره و همکاران (2009) با استفاده از شاخص های اقلیمی و روشن

شبکه عصبی شاخص خشکسالی پالمر در سیسیل ایتالیا را پیش بینی کردند. نتایج نشان داد همبستگی معناداری بین شاخص NAO و EB برای شاخص خشکسالی پالمر پاییزه و زمستانه وجود دارد. مرید و همکاران (2007) از شاخص های اقلیمی و روش شبکه عصبی برای پیش بینی دو شاخص خشکسالی SPI و EDI استفاده کردند. خروجی مدل ها نشان داد شاخص های NAO و SOI تأثیر کمی در بهبود نتایج مدل ها دارند. میشرار و دیزای (2006) در تحقیق دیگر، برای پیش بینی خشکسالی از دو مدل شبکه عصبی مصنوعی و شاخص بارش استاندارد شده استفاده نمودند. نتایج تحقیقات آنها نشان داد که مدل های شبکه عصبی مصنوعی در مقایسه با مدل های آماری کارایی بیشتری داشته اند. میشرار و دیزای (2005) در تحقیق خود، برای پیش بینی خشکسالی از مدل های احتمالاتی خطی مانند ARIMA و SARIMA با استفاده از شاخص بارش استاندارد شده (SPI) استفاده نمودند. نتایج تحقیقات آنها نشان داد که مدل های آماری نتایج خوبی از نظر پیش بینی کوتاه مدت خشکسالی (تا 2 ماه) دارد. فدائی کرمانی و همکاران (1390) به معرفی شاخص SPI و چگونگی تعیین دوره خشکسالی به کمک این شاخص برای شهرستان بم از استان کرمان برای دوره زمانی 30 ساله پرداختند و دوره های خشکسالی با مقیاس های زمانی مختلف در این منطقه پیش بینی و ارزیابی کردند. محمدی مطلق و همکاران (1390) با استفاده از سری های زمانی حاصل از شاخص بارش استاندارد شده (SPI) و زنجیره مارکوف، پایش، پیش بینی و گسترش خشکسالی در سطح استان فارس مورد بررسی قرار دادند و به این نتیجه رسیدند که در تمامی ایستگاه ها وضعیت تقریبا نرمال بر اساس شاخص SPI با مقیاس زمانی شش ماهه، بیشترین فراوانی را دارا می باشد.

با توجه به اینکه اکثر مطالعات انجام شده در زمینه خشکسالی بیشتر توسط روش های سری های زمانی برآورشی 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 مدل سازی و پیش بینی خشکسالی با استفاده از شبکه های عصبی پرسپترون چندلایه (MLP) به همراه الگوریتم های آموزش (LA) و توابع فعالیت (AF) مختلف می باشد.

## مواد و روش ها

در این تحقیق از داده های بارندگی ماهانه ایستگاه باران سنجری کردخیل بر روی رودخانه تجن در طول دوره آماری 46-1345 الی 1386-87 استفاده شد. این ایستگاه در موقعت جغرافیایی  $36^{\circ}05'05''$  عرض شمالی  $53^{\circ}28'00''$  طول شرقی و ارتفاع 280 متر از سطح دریاهای آزاد قرار گرفته است. پس از اطمینان از صحت داده های بارندگی ماهانه و انجام آزمون های آماری لازم، سری زمانی وضعیت خشکسالی در طول دوره آماری براساس مقادیر SPI در دوره های کوتاه مدت 3، 6، 9، 12، 24، 48 ماهه) و بلند مدت (46-1345 الی 1386-87 تشکیل شد. نمایه بارش استاندارد (SPI) توسط مک کی و همکاران (1993) جهت تعیین دوره های خشکسالی و ارزیابی شدت آن تدوین شد. از آن جایی که کمبود بارش در مقیاس زمانی کوتاه مدت بر روی رطوبت خاک و در مقیاس زمانی بلند مدت بر روی رودخانه ها، مخازن آب و آب های زیر زمینی، اثر می گذارد. SPI قادر به محاسبه کمبود بارش در مقیاس های زمانی متفاوت 3، 6، 9، 12، 24 و 48 ماهه می باشد (استینمن، 2003).

نمایه SPI برای هر منطقه براساس ثبت بارندگی های طولانی مدت و بر اساس میانگین متحرک زمانی محاسبه می شود (میشرار و دیزای، 2005). در ابتدا توزیع آماری مناسبی بر آمار بارندگی بلند مدت برازش داده شده، مک کی و همکاران (1993) توزیع گاما را مناسب ترین توزیع برای برازش داده های 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 مک کی 1997).

$$(1) \quad Z = SPI = -\left[ t - \frac{C_0 + C_1 t + C_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] t = \sqrt{\ln\left[\frac{1}{H(x)^2}\right]} \quad 0 \subset H(x) \leq 0.5$$

$$(2) \quad Z = SPI = +\left[ t - \frac{C_0 + C_1 t + C_2 t^3}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] t = \sqrt{\ln\left[\frac{1}{1 - H(x)^2}\right]} \quad 0.5 \subset H(x) \leq 1$$

$H(x)$ : تابع احتمال تجمعی و مقادیر  $d_3, d_2, d_1, C_2, C_1, C_0$  در معادلات (1) و (2) به صورت زیر می‌باشند.

$$\begin{array}{ll} C_0 = 2.51557 & d_1 = 1.432788 \\ C_1 = 0.802853 & d_2 = 0.189269 \\ C_2 = 0.010328 & d_3 = 0.001308 \end{array}$$

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

### طراحی ساختار شبکه عصبی مصنوعی (شبکه MLP)

به منظور مدل سازی داده‌های هریک از سری‌های زمانی، SPI‌ها به دو بخش تقسیم شدند. مجموعه مقادیر SPI از سال آبی 46-1345 الی 78-1377 به عنوان داده‌های آموزش شبکه و مقادیر SPI از سال 79-1378 الی 87-1386 به عنوان داده‌های آزمون شبکه مورد استفاده قرار گرفتند. همچنین به منظور آموزش بهتر شبکه‌ها 20 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 نمونه‌های 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 خروجی‌ها نمونه‌های 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 شایطی و همچنین به منظور یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال‌سازی صورت می‌گیرد. لذا قبل از آموزش، برای نرمال‌سازی داده‌های مورد استفاده از رابطه (3) استفاده شد:

$$(3) \quad X_n = \frac{X_0 - X_{\min}}{X_{\max} - X_{\min}}$$

$X_n$ : مقدار نرمال شده پارامتر،  $X_0$ : مقدار واقعی هر پارامتر،  $X_{\min}$ : کمترین مقدار پارامتر موردنظر و  $X_{\max}$ : بیشترین مقدار پارامتر موردنظر می‌باشد.

نمونه‌های ورودی از 1 تا 11 برای تمام SPI‌ها آزمون شدند، تعداد نمونه‌های لایه ورودی و لایه میانی با سعی و خطای تعیین شد. شبکه‌ها با الگوریتم مختلف آموزش داده و ضریب همبستگی (R) و جذر میانگین مربعات خطای (RMSE) برای تمام مدل‌ها محاسبه شد (میشرا و دیزای 2006). شبکه‌ای که کمترین جذر میانگین مربعات خطای و بیشتر ضریب همبستگی را دارا بود به عنوان بهترین شبکه انتخاب شد. به منظور بررسی عملکرد مدل‌های مورد آزمون و تعیین میزان

دقیق مدل طراحی شده، علاوه بر ترسیم نمودارهای مقادیر مشاهده شده در برابر مقادیر پیش بینی شده توسط شبکه ها، از دو پارامتر میانگین مطلق خطای (MAE) و جذر مربعات خطای (RMSE) نیز استفاده گردید.

$$(4) \quad MAE = \frac{\sum_{i=1}^{n_p} \sum_{j=1}^{n_0} |T_{pj} - O_{pj}|}{n_p \cdot n_0}$$

$$(5) \quad RMSE = \sqrt{\frac{\sum_{i=1}^{n_p} \sum_{j=1}^{n_0} (T_{pj} - O_{pj})^2}{n_p \cdot n_0}}$$

به منظور یافتن بهترین شبکه، در هر یک از شبکه ها، مرتبًا قوانین یادگیری مختلف در ارتباط با تابع انتقال مختلف به صورت دو به دو تا زمان رسیدن به بهترین حالت آزمایش شد. همچنین شبکه در حالت ۱ تا ۱۱ نرون در لایه ورودی و با تغییر افزایش تعداد نرون های لایه میانی در هر دو شبکه، برای هر یک از سری های زمانی SPI آزمایش شد. که در نهایت ۱۵۳ مدل برای شبکه MLP و ۱۸۴ مدل برای شبکه RBF، برای هر سری زمانی SPI ارائه شد. پس از آن همان گونه که ذکر شد، ضریب همبستگی و جذر میانگین مربعات خطای برای هر ترکیب ورودی و نرون های میانی محاسبه شد، شبکه ای که بیشترین ضریب همبستگی و کمترین جذر میانگین مربعات خطای را دارا بود به عنوان بهترین شبکه انتخاب شد.

### سری زمانی ARIMA

مدل ARIMA غیر فصلی، اتورگرسیو با درجه  $p$ ، میانگین متخرک با درجه  $q$  و عملکرد  $d$  امین 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:

$$(6) \quad \phi(B)\Delta^d Z_t = \theta(B)a_t$$

که  $\phi(B), \theta(B)$  چندجمله ایهایی از درجه  $p, q$  به ترتیب هستند:

$$(7) \quad \phi(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$$

$$(8) \quad \theta(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$$

در صورت استفاده از عملکردن تفاضل فصلی با تأخیر  $s$  و برازش آنها با مدل های ARMA( $p,q$ ) مدل های فصلی آریما ARIMA( $P,D,Q_s$ ) به وجود می آید (باکس و جنکیز، 1976).

باکس و همکاران (1994) با ترکیب مدل های فصلی و غیر فصلی، مدل های موسوم به آریما فصلی مکثرا که به SARIMA معروف است را تشکیل می دهند. در کل مدل ساریما به صورت ARIMA( $p,d,q$ )( $P,D,Q_s$ ) نامیده می شود که 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:

$$(6) \quad \phi_P(B)\phi_p(B^s)\nabla^d \nabla_s^D Z_t = \theta_q(B)\Theta \underset{\approx}{\bigcirc}(B^s)a_t$$

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.

### پردازش داده ها با استفاده از شبکه عصبی مصنوعی MLP

نتایج نشان داد که از بین توابع یادگیری، تابع انتقال سیگموئید و از بین قوانین یادگیری، قانون یادگیری Delta Bar کمترین خطأ و بیشترین ضریب همبستگی را دارند. در شبکه MLP تعداد نمونه های لایه میانی 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 نمونه های لایه میانی کمتر از تعداد نمونه های ورودی، کمترین خطأ و بیشترین ضریب همبستگی را خواهند داشت.

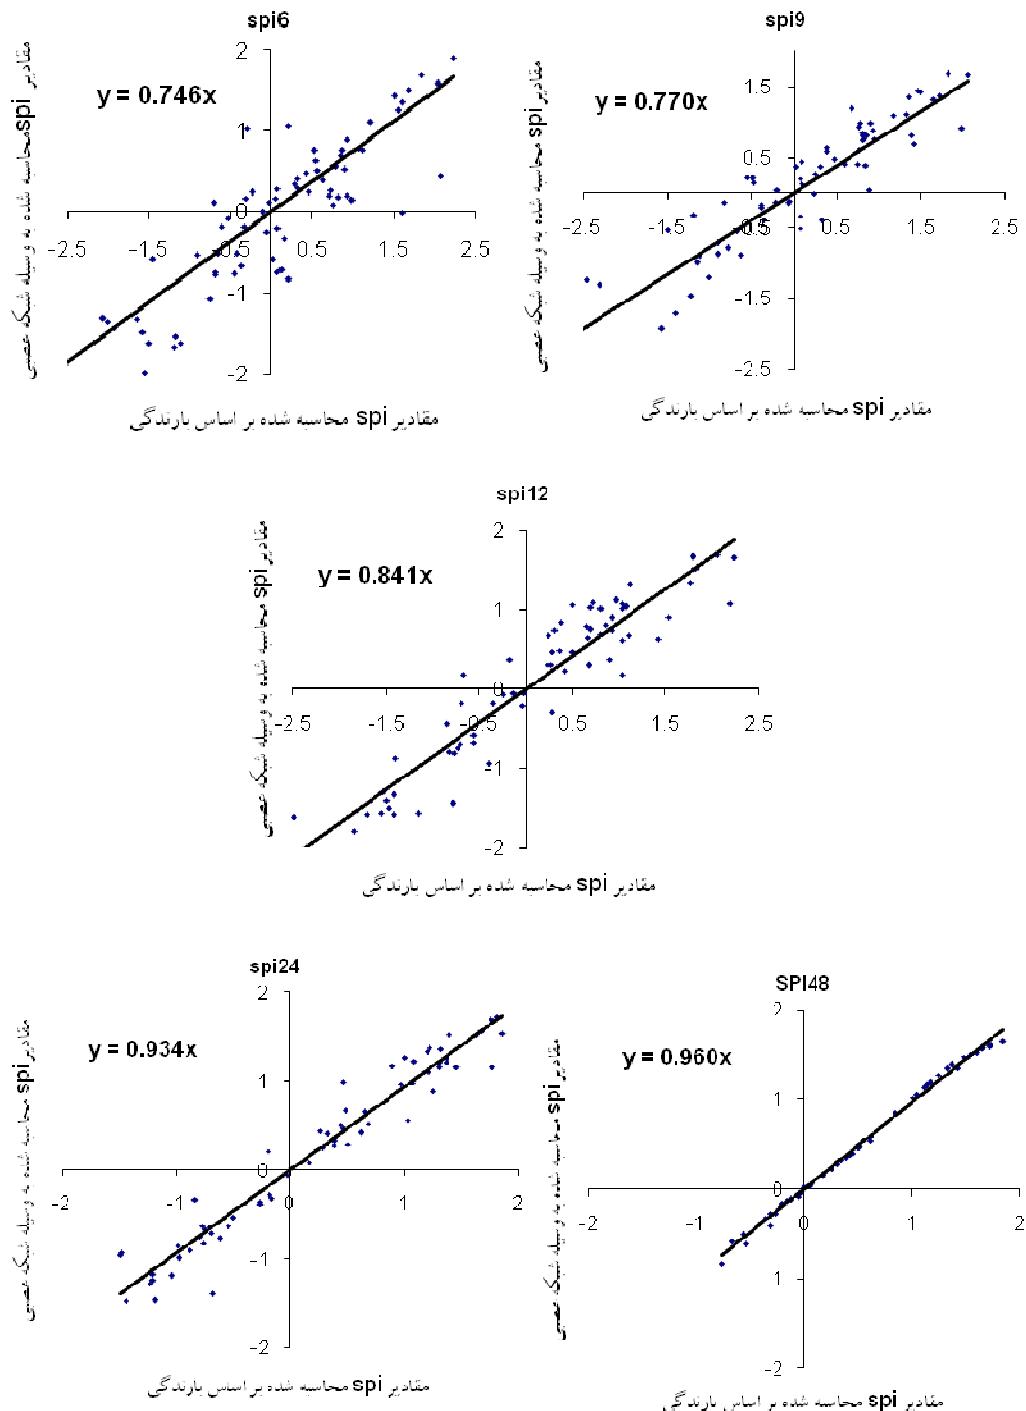
به منظور ارزیابی و بررسی عملکرد مدل های مورد آزمون و تعیین میزان دقیق مدل طراحی شده علاوه بر استفاده از دو پارامتر میانگین مطلق خطأ (MAE) و جذر میانگین مربعات خطأ (RMSE)، از ترسیم زوج های مرتب مقادیر مشاهده شده در برابر مقادیر پیش بینی شده توسط شبکه ها، نیز استفاده گردید. نتایج، کارایی شبکه MLP را در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

در جدول 1 مقادیر پارامترهای RMSE, MAE و  $R^2$  برای تخمین کوتاه مدت و بلند مدت SPI (منظور از دوره کوتاه مدت دوره های 1 تا 9 ماهه و دوره بلند مدت 12 تا 48 ماهه می باشد) به عنوان مثال برای تخمین SPI12 با استفاده از شبکه عصبی MLP، بهترین ساختار به صورتی است که در لایه ورودی 10 نمونه، در لایه نهان 7 نمونه و در لایه خروجی 1 نمونه وجود داشته باشد. یعنی با تأخیر زمانی 10 ماهه قبل می توان یک ماه جلوتر را پیش بینی کرد. در این حالت مقدار  $R^2$  برابر 0.9538 و مقادیر MAE و RMSE به ترتیب برابر 0.01476 و 0.0001974 می باشد. نتایج این جدول نشان می دهد که حداقل مقدار  $R^2$  در هردو روش مربوط به SPI12 می باشد که توسط شبکه MLP تخمین زده شده است. با توجه به این که SPI12 میانگین متحرک زمانی 12 ماهه می باشد لذا تناوب رطوبتی (وضعیت های تر و خشک) در طول دوره مورد بررسی تغییر نمی کند. ضمن آن که کمترین مقادیر MAE و RMSE مربوط به SPI48 با استفاده از روشن MLP می باشد.

جدول (1) نتایج حاصل از آزمایش شبکه های عصبی هوشمند و سری های زمانی در بهترین حالت یادگیری

spI	مدل	$R^2$	MAE	RMSE	تعداد داده ها
spi3	ARIMA()	0.1551	0.8389	1.0426	358
spi6	MLP(9-3-1)	0.5687	0.5368	0.7108	355
spi9	ARIMA()	0.6784	0.4204	0.6162	352
spi12	MLP(9-3-1)	0.7657	0.4063	0.533	349
spi24	ARIMA()	0.6966	0.4279	0.5868	337
spi48	MLP(10-3-1)	0.8469	0.3084	0.4266	313
	ARIMA()	0.7863	0.3747	0.5023	
	MLP()	0.8774	0.282	0.385	
	ARIMA()	0.8864	0.2269	0.3462	
	MLP(7-3-1)	0.9478	0.1646	0.2302	
	ARIMA()	0.8773	0.1632	0.2599	
	MLP(2-2-1)	0.9964	0.0424	0.0563	

با توجه به جدول 1 ملاحظه می شود که در شبکه MLP با افزایش دوره زمانی شاخص خشکسالی از SPI3 تا SPI48 مقادیر MAE و RMSE هر دو کاهش می یابند. مثلاً مقدار قدر مطلق خطا در وضعیت خشکسالی یک ماهه با SPI3 با مدل (11-25-1) مقدار 0/6544 می باشد که در وضعیت خشکسالی 48 ماهه (SPI48) به 0/0852 می یابد که با نتایج میشرا و دیزای 2006 همسو بوده است. ضمن آن که ضریب همبستگی در SPI3 بسیار که 0/503 می باشد.



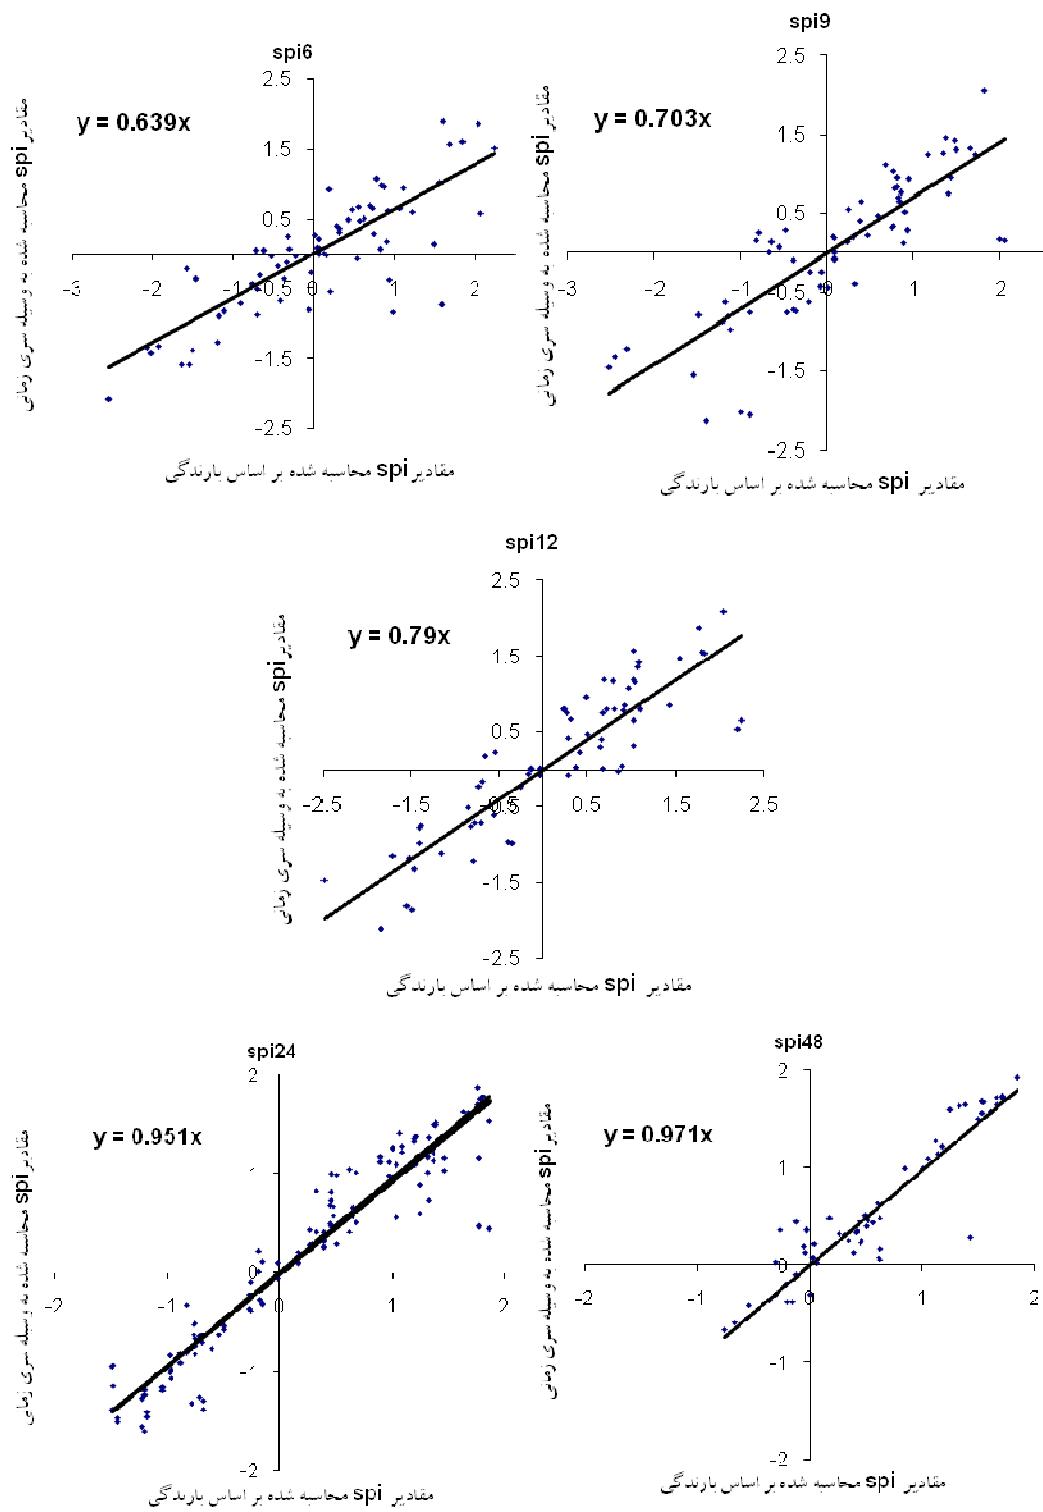
شکل (1) نمودار پراکندگی SPI محاسبه شده بوسیله بارندگی در مقابل SPI محاسبه شده بوسیله شبکه عصبی

با توجه به شکل های فوق ملاحظه می شود که در دوره های کوتاه مدت در روش MLP و مقادیر SPI بزرگ، کمتر از مقدار واقعی تخمين زده شده اند. به عبارت دیگر وضعیت رطوبتی، خشک تراز مقدار واقعی برآورده است در حالی که در دوره های دراز مدت به خصوص SPI12 این خطا کمتر است و وضعیت خشکسالی واقعی با مقادیر برآورده توسط روش MLP به یکدیگر نزدیک تر هستند.

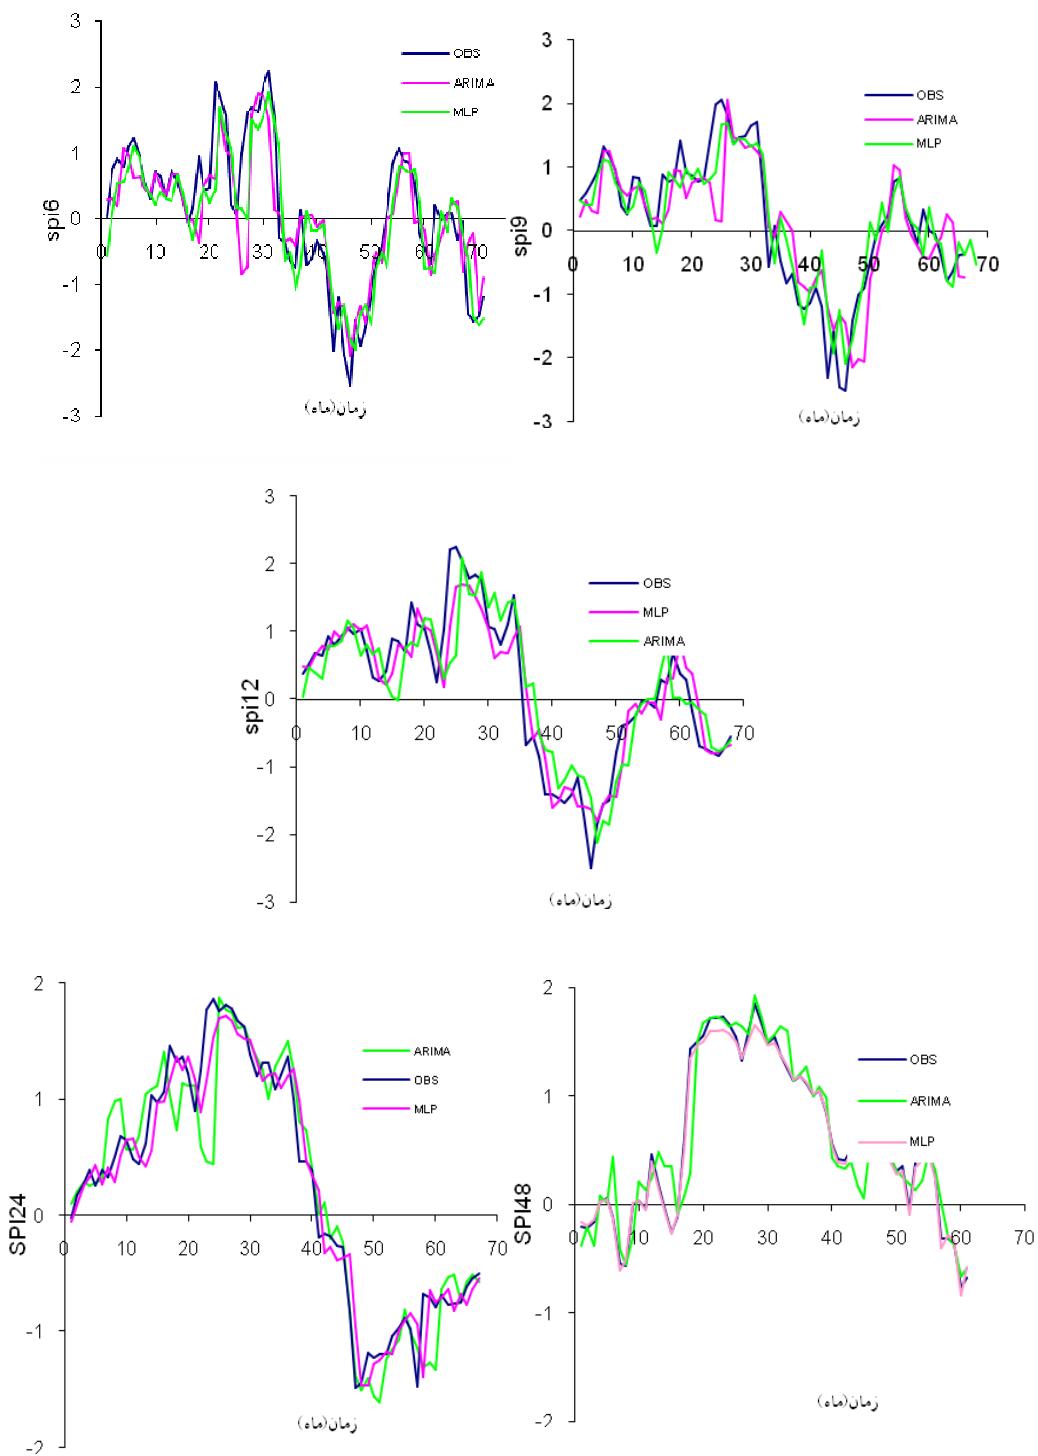
### مقایسه نتایج حاصل از شبکه عصبی با نتایج سری زمانی ARIMA

همان گونه که ذکر شد در این تحقیق، از دو مدل آریما و ساریما برای بررسی تغییرات هر یک از سری های زمانی SPI ها و پیش بینی آن در ایستگاه کردنخیل استفاده شد. برای تخمين 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 1 ارائه شد. همچنین مقادیر واقعی در مقابل برآورده در شکل 2 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 حداکثر ضریب همبستگی و کمترین خطا را دارا می باشد. نتایج حاصل با نتایج میشرا و دیزای 2005 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 زمان SPI ها مشخص شد که با نتایج رضایی 2001 و میشرا و دیزای 2006 همسو بوده است.

شکل 6 نیز مقادیر محاسبه شده توسط شبکه های عصبی مصنوعی MLP و 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 خشکسالی را پیش بینی می کند که می تواند به دلیل ماهیت غیرخطی و انعطاف پذیری شبکه های عصبی دانست. با توجه به این که هر سری زمانی از دو مولفه قطعی و تصادفی تشکیل شده اند. مدل های سری های زمانی به دلیل خطی بودن شان و ارائه رابطه ریاضی قادر به شبیه سازی مولفه تصادفی سری نمی باشند ولی شبکه عصبی هر دو مولفه را شبیه سازی می کنند. همچنین ملاحظه می شود که مقیاس زمانی کوتاه مدت دارای نوسانات زیادتری نسبت به بلند مدت می باشد و با کوچکترین تغییر در بارندگی ماهانه سریعا عکس العمل نشان می دهد. ضمن اینکه خشکسالی های کوتاه مدت، از فراوانی وقوع بیشتری برخوردار است به طوری که با افزایش مقیاس زمانی از فراوانی خشکسالی های کاسته شده است (شکل 3).



شکل (2) نمودار پراکندگی SPI محاسبه شده بوسیله بارندگی در مقابل SPI محاسبه شده بوسیله سری زمانی



شکل (3) نمودار مقایسه نتایج مدل های سری زمانی و شبکه عصبی در مقایسه با داده های واقعی

## جمع‌بندی و نتیجه‌گیری

در این پژوهش پیش‌بینی سری‌های زمانی نمایه‌های SPI با استفاده از شبکه‌های عصبی مصنوعی پرسپترون چند لایه ARIMA و روش آماری MLP، در مقیاس‌های زمانی متفاوت 1، 3، 6، 9، 12، 24، 48 ماهه مورد بررسی قرار گرفت که به عنوان نتیجه‌گیری می‌توان به موارد زیر اشاره نمود.

بر اساس دو پارامتر میانگین مربعات خطأ (MAE) و جذر میانگین مربعات خطأ (RMSE) و همچنین با ترسیم نمودار های مقادیر مشاهده شده در برابر مقادیر پیش‌بینی شده، برتری کارایی شبکه‌های عصبی مصنوعی در مقابل روش های آماری در تمام سری‌های زمانی (48، 24، 12، 9، 6 ماهه) مشخص شد.

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

بر اساس نتایج به دست آمده، شبکه‌های عصبی و ARIMA در سری زمانی SPI1 نتایج قبل قبولی را ارائه نداده‌اند. بنابراین پیش‌بینی وضعیت خشکسالی با SPI1 با استفاده از شبکه عصبی (MLP) و سری زمانی ARIMA پیشنهاد نمی‌شود.

1. فدائی کرمانی، ا. بارانی، غ. 1390. بررسی چگونگی پایش خشکسالی با استفاده از شاخص بارش استاندارد SPI. پنجمین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک-اسفند 1390.
2. محمدی مطلق، م. معتضدی، ا. امیری مهدی پور، ن. 1390. پایش پیش‌بینی خشکسالی استان فارس با استفاده از شاخص خشکسالی SPI و زنجیره مارکوف. پنجمین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک-اسفند 1390.
3. ASCE Task Committee. 2000. Artificial neural networks in hydrology-I: Preliminary concepts. *Journal of Hydrologic Engineering*. 5(2), Pp: 115-123.
4. Barua, Shishutosh and Perera, B. J. C. A. W. M. Ng and Tran, D. H (2010) Drought forecasting using an aggregated drought index and artificial neural networks *Journal of water and climate change*, 1 (3).pp.193 ,-.206.
5. Box, G.E.P, and Jenkins, G.M. 1976. Time Series Analysis Forecasting and Control. San Francisco: Holden-Day
6. Cutore P, Di Mauro G, Cancelliere A (2009) Forecasting Palmer Index Using Neural Network and Climatic Indexes/*Journal of Hydrologic Engineering*/ vol 14 ,Issue 6, pp. 588-595.
7. Edward, D. C., and McKee, T. B. 1997. Characteristics of 20<sup>th</sup> century drought in the United States at multiple time scales. *Climatology Report Number 97-2*, Department of atmospheric science, Colorado State University, Fort Collins, 174pp.
8. Mishra, A. K., and Desai, V. R. 2006. Drought forecasting using feed-forward recursive neural network. *J. Ecological Modelling*, 127-138.
9. Mishra, A.k. and Desai, V. R. 2005. Drought forecasting using Stochastic models. *J. Stochastic Environmental Research and Risk Assessment (SERRA)*, 19 (5):326-339.
10. Morid S , Smakhtin V, Bagherzadeh K(2007) Drought forecasting using artificial neural networks and time series of drought indices *International Journal of Climatology*, Vol. 27, pp. 2103-2111.
11. Sharma, B. R. and Smakhtin, V. U. 2004. Potential of water harvesting as a strategic tool for drought mitigation, *International Water Management Institute*. 24 pp.
12. Steinmann, A. 2003. Drought indicators and triggers: A stochastic approach to evaluation. *J. American Water Resources Association (JAWRA)*, 39(5):1217-1233.
13. Wilhite, D.A., Hayes, M. J., Knutson, C., and Smith, K. H. 2000. Planning for drought: moving from crisis to risk management. *J. Amer. Water Res. Assoc*, 36:697-710.