

## کاربرد سری های زمانی بارش و نمایه های آماری اقلیمی در پیش بینی خشکسالی به کمک شبکه CANFIS (مطالعه موردی: بیرجند - خراسان جنوبی)

۱- مجید رضایی، دانشیار گروه آمار، دانشکده علوم ریاضی و آمار، دانشگاه بیرجند

۲- هادی معماریان، استادیار گروه مرتع و آبخیزداری، دانشکده منابع طبیعی و محیط زیست، دانشگاه بیرجند

hadi\_memarian@birjand.ac.ir

دریافت: ۱۳۹۳/۰۲/۱۲

پذیرش: ۱۳۹۴/۰۴/۲۰

### چکیده

پیش بینی خشکسالی به عنوان یکی از راهکارهای مدیریتی است که به برنامه ریزان کمک خواهد کرد تا برنامه ریزی صحیحی برای استفاده از منابع محدود آب و خاک فراهم کنند. خراسان جنوبی بویژه در دهه اخیر به یکی از کانون های اصلی بحران خشکسالی در کشور تبدیل شده که این امر تاثیر بسزایی در کاهش تولید مواد غذایی، خطر گرسنگی، افت سطح آب زیرزمینی، تخریب خاک و اراضی داشته است. در این مطالعه با ترکیب سیگنال های اقلیمی بزرگ مقیاس با میزان بارش و مقادیر پیشین شاخص خشکسالی SPI، به بررسی کارایی شبکه های عصبی فازی CANFIS در پیش بینی خشکسالی منطقه اقلیمی بیرجند پرداخته شده است. از شاخص SPI به منظور تعریف و پایش خشکسالی در گام زمانی ماهانه استفاده شد. در این تحقیق و با مرور منابع انجام شده ۹ شاخص اقلیمی بزرگ مقیاس جهت پیش بینی خشکسالی انتخاب شد. از بین شاخص ها، الگوهای NINO 1+2، NINO 3، MEI، TSA، AMO و NINO 3.4 به کمک روش رگرسیون گام به گام و بررسی ماتریس همبستگی، موثر بر خشکسالی شهر بیرجند تشخیص داده شدند که در مدل سازی از آن ها بهره گرفته شد. طول دوره آماری ۴۱ سال (۲۰۱۰-۱۹۷۰) می باشد که ۶۰ درصد از این دوره جهت آموزش، ۱۵ درصد جهت اعتبار سنجی متقابل و ۲۵ درصد باقیمانده جهت آزمون شبکه مورد استفاده قرار گرفتند. الگوریتم مورد استفاده در آموزش شبکه، مومنتم و نوع تابع عضویت فازی، تابع گوسی انتخاب شد. با توجه به نتایج حاصل از روش رگرسیون گام به گام، ۱۲ مدل استخراج شد. ولی با توجه به محدودیت شبکه CANFIS در اجرای مدل های با تعداد ورودی های بیش از ۵ متغیر، فقط ۸ مدل اول توسط شبکه CANFIS شبیه سازی گردیدند. نتایج آنالیز حساسیت شبکه نشان داد که تقریباً در کلیه مدل های مختلف، شاخص های NINO و بارش بیشترین تاثیر را بر عملکرد شبکه داشته اند. در مدل شماره ۴ (بعنوان مدلی که کمترین میزان خطا را در فرآیند آموزش و آزمون نشان داد)، شاخص NINO 1+2(t-5) با متوسط حساسیت ۰/۷ بیشترین تاثیر را بر عملکرد شبکه داشت. پس از آن متغیرهای بارش، NINO 1+2(t) و NINO 3(t-6) به ترتیب با حساسیت ۰/۵۹، ۰/۲۸ و ۰/۲۸ توانستند خروجی شبکه را بیش از همه تحت تاثیر تغییرات خود قرار دهند. بر اساس محاسبات آماری و شاخص های ارزیابی شبکه مشخص شد که همبستگی با تاخیر شاخص های اقلیمی نتایج قابل قبول تری بین خشکسالی و ENSO را ارائه داد. در مجموع مدل چهارم با ترکیبی از پارامترهای ورودی NINO 1+2 (با پنج ماه تاخیر و بدون تاخیر)، بارش ماهانه و NINO 3 (با ۶ ماه تاخیر) و ضریب همبستگی ۰/۹۰۳ (بین مقادیر مشاهداتی و پیش بینی شده) به عنوان مناسب ترین مدل جهت پیش بینی خشکسالی در منطقه اقلیمی بیرجند با استفاده از شبکه CANFIS ارائه شد.

واژگان کلیدی: پیش بینی خشکسالی؛ سیگنال های اقلیمی؛ SPI؛ شبکه CANFIS؛ ENSO.

### مقدمه

مطالعه نقش و اثر خشکسالی در کشور با توجه به واقع شدن ایران در قلمرو آب و هوایی خشک و نیمه خشک جهانی ضروری است. بنابراین، با توجه به درجه اهمیت خشکسالی، نوع و شدت آن، سطوح اطلاع رسانی و در نتیجه مدیریت آن متفاوت خواهد بود [۱۷].

خشکسالی وضعیتی از کمبود بارندگی و افزایش دما است که در هر وضعیت اقلیمی ممکن است رخ دهد. بر خلاف سیل و بارندگی که می توان فهمید در چه زمانی شروع شده، در چه زمانی خاتمه پیدا کرده و در چه محدوده ای بوده است، توصیف زمانی و مکانی خشکسالی بسیار مشکل است [۳ و ۱].

نموده و یک سیستم هشداردهنده با استفاده از سیستم‌های سنجش از دور و روش‌های آماری مانند آریما جهت پیش‌بینی سیل و خشکسالی طراحی کرده است. متلاً<sup>۴</sup> [۳۳] نوسان اقلیم کره زمین و ارتباط از دور انسو و شاخص دوره‌ای کواسی و دمای سطح آب در ناحیه استوایی اقیانوس آرام را بررسی نموده است. اگرچه در بررسی خشکسالی و تغییرات اقلیمی، استفاده از مدل‌هایی بر اساس روش‌های تصادفی و احتمالاتی سابقه‌ای طولانی دارد، اما بسیاری از این روش‌ها روابط بین متغیرها را خطی فرض نموده و در مدل کردن پدیده‌های غیرخطی مانند سری‌های زمانی هیدرولوژیکی با شکست مواجه می‌شوند. از این رو پژوهشگران برای ساختن مدل‌های پیش‌بینی معتبر، به استفاده از تکنیک‌های مدل‌کننده غیر خطی نظیر سیستم‌های فازی و مدل‌های فازی-عصبی روی آورده‌اند [۱۹، ۶ و ۱۰]. در سال‌های اخیر با شناخت شاخص‌های بزرگ مقیاس اقلیمی، تلاش محققین به سمت تعریف روابطی بین این شاخص‌ها و تغییرات بارش جهت استفاده در پیش‌بینی خشکسالی‌ها سوق پیدا نموده است [۱].

پوستی‌زاده و همکاران [۳۶] در تحقیقی با استفاده از سیستم استنتاج فازی و بر اساس میزان متوسط دبی از ۶ ماه گذشته، مقدار متوسط دما در یک ماه قبل و مجموع بارش از ۴ ماه قبل، به پیش‌بینی دبی فروردین ماه در رودخانه بختیاری پرداختند. تجزیه و تحلیل مدل‌های مشابه با استفاده از روش رگرسیون چند متغیره، نشانگر نتایج مناسب‌تر سیستم استنتاج فازی بود. صداقت کردار و فتاحی [۴۰] ارتباط بین سیگنال‌های هواشناسی و بارش را برای نواحی مختلف ایران مورد بررسی قرار دادند و در نهایت مدل‌های پیش‌بینی را با استفاده از شبکه عصبی مصنوعی توسعه دادند. بررسی‌ها نشان داد که تقریباً در تمام نواحی کشور ENSO پراهمیت‌ترین سیگنال در بارش ایران می‌باشد. فرخ‌نیا و همکاران [۱۹] از سیگنال‌های بزرگ مقیاس اقلیمی به‌منظور پیش‌بینی خشکسالی استان تهران استفاده نمودند. بررسی‌ها نشان داد که ارتباط مناسبی بین سیگنال‌های SLP و SST شهریور ماه در نقاطی از منطقه با شاخص خشکسالی SPI

پیش‌بینی خشکسالی به عنوان یکی از راهکارهای مدیریتی جهت برنامه ریزی صحیح برای استفاده از منابع محدود آب است. همچنین پیش‌بینی خشکسالی به کشاورزان کمک خواهد کرد تا با تغییر در تاریخ کشت محصولات و استفاده از ارقام مقاوم به خشکی خسارات ناشی از این پدیده را به حداقل برسانند [۴].

خراسان جنوبی بویژه در دهه اخیر به یکی از کانون‌های اصلی بحران خشکسالی در کشور تبدیل شده است. به‌طوری‌که از سال ۱۳۸۴ تا کنون ۴۴ چشمه و ۱۱۳ رشته قنات استان از چرخه بهره‌وری خارج شده است. همچنین ۲۴۵ حلقه چاه بر اثر خشکسالی در استان خشک شده است. خشکسالی طی سال‌های ۱۳۸۹ تا ۱۳۹۰ بالغ بر ۱/۵ میلیارد ریال به بخش کشاورزی استان خسارت وارد کرده است. بر اساس شاخص دومارتن مشخص گردیده که در دشت بیرجند در مدت ۵۰ سال اخیر، روند خشکی ادامه داشته که این امر تاثیر بسزایی در کاهش تولید مواد غذایی، افت سطح آب زیرزمینی، تخریب خاک و اراضی داشته است [۲]. دشت بیرجند از سال ۱۳۶۰ با افت سطح سفره آب زیرزمینی روبرو شده و این روند تا کنون رو به تشدید بوده، بطوریکه متوسط افت سفره از ۲۱ سانتیمتر در سال‌های ۱۳۷۸-۱۳۶۰ به بیش از ۶۰ سانتیمتر در سال‌های ۱۳۷۸ به بعد علت افزایش برداشت و طولانی شدن دوره خشکسالی رسیده است. کسری آبخوان دشت نیز از سال ۱۳۸۱ به بعد در حدود ۱۳/۶ میلیون متر مکعب برآورد شده است [۲ و ۲۴].

مطالعات زیادی در زمینه پیش‌بینی اقلیمی و خشکسالی با استفاده از روش‌های کمی (احتمالی و تصادفی) در سطح جهان انجام شده است. واید<sup>۱</sup> [۲۹] دوره‌های خشکسالی اسپانیا را با استفاده از زنجیره مارکوف بررسی نموده است. باری و کارلتون<sup>۲</sup> [۱۳] ناحیه‌بندی اقلیمی و بررسی خشکسالی‌ها و ترسالی‌ها و پیش‌بینی اقلیمی را با استفاده از روش‌های مختلف مانند شاخص خشکسالی پالمر، زنجیره مارکوف، میانگین متحرک، اتورگرسیو و آریما بررسی نموده است. گانگولی<sup>۳</sup> [۲۱] بر روی حوضه داخلی گنگ واوتارپرادش بنگلادش مطالعه

<sup>۱</sup>. Vide

<sup>۲</sup>. Barry and Carleton

<sup>۳</sup>. Gangully

<sup>۴</sup>. Metalka

مقادیر پیشین SPI، به بررسی کارایی شبکه‌های عصبی-فازی CANFIS در پیش‌بینی خشکسالی منطقه اقلیمی بیرجند پرداخته شود.

## مواد و روش‌ها

### منطقه مطالعاتی

شهرستان بیرجند، مرکز استان خراسان جنوبی در شرق کشور واقع شده است. با توجه به آمار ۴۰ ساله ایستگاه هواشناسی بیرجند، متوسط بارندگی ۱۷۰ میلیمتر، متوسط دما  $16/5^{\circ}\text{C}$  درجه سانتیگراد، میانگین نم نسبی ۳۷٪ و میانگین تبخیر از تشتک ۲۲۵۰ میلیمتر در سال است. بر اساس طبقه‌بندی اقلیمی آمبرژه، این منطقه جزء نواحی خشک و سرد به شمار می‌آید [۱۲]. داده‌های بارندگی ایستگاه سینوپتیک بیرجند که در دوره آماری ۱۹۷۰-۲۰۱۰ قرار دارد، علاوه بر این که طول دوره آماری مناسبی را دارا است، به لحاظ آماری نیز با کم‌ترین نواقص روبرو است. اطلاعات آماری سری زمانی بارندگی در دو مقیاس ماهانه و سالانه در جدول ۱ ارائه شده است. شکل‌های ۲ و ۳ نیز سری پیوسته بارش ایستگاه سینوپتیک بیرجند را بترتیب در دو مقیاس سالانه و ماهانه نشان می‌دهند.



شکل ۱- نقشه محدوده مورد مطالعه

در سال آبی بعد وجود دارد. سپس از شبکه‌های عصبی-فازی و شبکه‌های عصبی مصنوعی بمنظور پیش‌بینی خشکسالی استفاده گردید. باکانلی<sup>۱</sup> و همکاران [۹] از سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) بمنظور پیش‌بینی خشکسالی در کشور ترکیه استفاده نمودند. مدل‌های ینی مختلفی برای SPI با مقیاس‌های زمانی ۱، ۳، ۶، ۹ و ۱۲ ماهه مورد بررسی قرار گرفتند. نتایج نشان داد که ترکیب مقادیر پیشین بارش و شاخص SPI بهبود عملکرد مدل‌ها را به همراه دارد. مرید و همکاران [۳۴] امکان پیش‌بینی خشکسالی را با استفاده از شبکه‌های عصبی مصنوعی در استان تهران بررسی نمودند. آن‌ها دو شاخص EDI و SPI را بعنوان متغیرهای پیش‌بینی شونده و ترکیبات مختلفی از شاخص‌های مزبور، بارندگی و سیگنال‌های بزرگ مقیاس اقلیمی SOI و NAO ماقبل را بعنوان پیش‌گویی کننده استفاده نمودند. نتایج نشان داد که بهترین مدل‌ها، مدل‌هایی هستند که شامل مقدار شاخص خشکسالی ماه مشابه در سال گذشته می‌شدند.

تاکنون استفاده از شبکه‌های CANFIS<sup>۲</sup> در علوم محیطی بیشتر متمرکز بر تخمین تبخیر و تعرق و یا تخمین سیلاب بوده است. بعنوان مثال آیتک<sup>۳</sup> [۷] از شبکه CANFIS برای تخمین ETo در کالیفرنیا استفاده کرد. مدل توسعه داده شده با این شبکه در مقایسه با سایر روش‌ها برتر بوده و آن را بعنوان یک مدل تخمین ETo پیشنهاد کرد. در کاربردی دیگر، از CANFIS بمنظور تخمین منطقه ای سیلاب استفاده شد. این شبکه توانسته است بطور معنی داری باعث بهبود عملکرد مدل‌های منطقه ای آنالیز فراوانی سیلاب گردد [۸]. مطالعات مختلفی نیز به مقایسه شبکه‌های عصبی فازی با شبکه‌های عصبی معمولی در پیش‌بینی خشکسالی و پارامترهای هیدرولوژیکی پرداخته‌اند که در بیشتر آن‌ها به ارجحیت و عملکرد مناسب تر شبکه‌های عصبی-فازی نسبت به شبکه‌های عصبی معمولی اشاره شده است [۱۶، ۲۵ و ۴۱].

در این پژوهش نیز سعی بر این است که به‌وسیله ترکیب سیگنال‌های اقلیمی بزرگ مقیاس با میزان بارش و

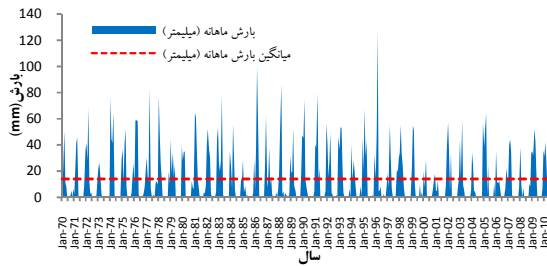
<sup>۱</sup>. Bacanli

<sup>۲</sup>. Co-Active Neurofuzzy Inference System

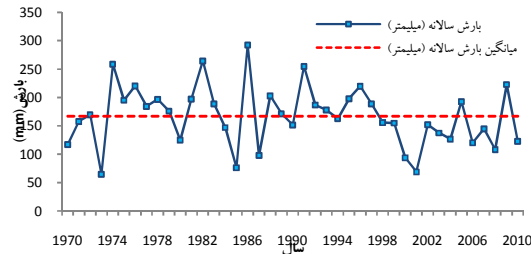
<sup>۳</sup>. Aytok

جدول ۱- اطلاعات آماری سری زمانی بارش در مقیاس زمانی ماهانه و سالانه

پارامتر آماری	ماهانه	سالانه
میانگین (mm)	۱۳/۹۲	۱۶۷/۰۷
میانه (mm)	۳/۴۵	۱۶۹/۷۰
نما	۰/۰۰	-
انحراف معیار (mm)	۲۰/۱۲	۵۲/۹۲
درجه اوج	۳/۲۹	-۰/۰۷
چولگی	۱/۷۶	۰/۱۵
دامنه (mm)	۱۲۷/۱۰	۲۲۸/۰۰
حداقل (mm)	۰/۰۰	۶۴/۷۰
حداکثر (mm)	۱۲۷/۱۰	۲۹۲/۷۰



شکل ۳- نمودار بارندگی ماهانه و میانگین ایستگاه سینوپتیک بیرجند



شکل ۲- نمودار بارندگی سالانه و میانگین ایستگاه سینوپتیک بیرجند

### شاخص بارش استاندارد (SPI)

[۳۸]. سپس احتمال تجمعی (Hx) به مقادیر تصادفی استاندارد نرمال با میانگین صفر و واریانس یک تبدیل می‌شود که این متغیر همان مقدار SPI می‌باشد [۱، ۹ و [۳۸]. مقادیر مثبت و منفی شاخص SPI بترتیب نشان دهنده شرایط تر و خشک می‌باشد.

### شاخص‌های بزرگ مقیاس اقلیمی

الگوهای ارتباط از دور، منعکس کننده تغییرات در مقیاس وسیع در امواج اتمسفری و موقعیت رودبدها بوده و بر درجه حرارت، بارش، مسیر طوفان‌ها و موقعیت و شدت رودبدها بر روی مناطق وسیع تاثیر می‌گذارند [۱]. سازمان ملی مطالعات جوی و اقیانوسی ایالات متحده آمریکا<sup>۱</sup> با برآورد اختلاف فشار و دما و سطح اقیانوس‌ها شاخص‌هایی را ارائه کرده است که جهت تحلیل تحولات جوی می‌توان از آن‌ها کمک گرفت [۳۵]. در این تحقیق و با مرور منابع انجام شده ۹ شاخص اقلیمی جهت پیش‌بینی خشکسالی انتخاب شد.

شاخص NINO 1+2 مربوط به مقادیر حدی دمای سطح اقیانوس آرام بوده و محدوده ۰ تا ۱۰ درجه جنوبی و

شاخص بارش استاندارد در سال ۱۹۹۳ توسط مک‌کی و همکاران [۲۹] به منظور تعریف و پایش خشکسالی‌ها ارائه شد. ویژگی این شاخص اینست که به کارشناس اجازه می‌دهد تا خشکسالی‌ها و ترسالی‌های نادر را در یک مقیاس زمانی معین (بعنوان مثال، ۱ ماهه، ۳ ماهه، ۶ ماهه و غیره) برای هر نقطه جغرافیایی که دارای آمار بارندگی مناسبی باشد، تعیین و بررسی کند. از نظر ریاضی شاخص SPI بر مبنای احتمالات تجمعی بارندگی‌ها در یک ایستگاه استوار می‌باشد. تام (به نقل از [۳۷]) دریافت که توزیع گاما برای سریهای زمانی بارش‌های کلیماتولوژیکی بهترین برازش را داشته است. از اینرو مک‌کی و همکاران طرح شاخص SPI را بر مبنای توزیع گاما قرار دادند. از آنجایی که تابع گاما برای  $x=0$  قابل تعریف نمی‌باشد و داده‌های بارندگی همواره دربرگیرنده تعداد زیادی مشاهده با بارندگی صفر می‌باشد، احتمال تجمعی بارندگی بایستی بدست آید [۳۸]. مک‌کی و همکاران [۳۰] یک روش تحلیلی را به همراه کد نرم افزاری برای تعیین احتمال تجمعی بکار بردند:

$$H(x) = q + (1 - q)G(x) \quad (1)$$

که در آن: q برابر است با احتمال مقادیر بارندگی صفر و G(x) احتمال تجمعی بارش بر اساس توزیع گاماست

<sup>۱</sup>.National Oceanic and Atmospheric Administration (NOAA)

معمول فازی اینست که ورودی‌های فازی را با شبکه مادولار عصبی ادغام کرده تا بتواند تخمینی سریع و صحیح از توابع پیچیده داشته باشد. ضمن این‌که توانایی درج چندین خروجی و محاسبات منطبق بر آن‌ها را نیز دارا می‌باشد. در واقع با تسهیم ارزش‌های عضویت فازی، قوانین فازی در این نوع از شبکه‌ها بگونه‌ای ساخته می‌شوند که بتوانند همبستگی بین خروجی‌ها را نیز در شبیه‌سازی لحاظ کرده و جهت تسریع در یافتن جواب صحیح از آن استفاده کنند [۲۲ و ۴۲]. مولفه اصلی CANFIS یک نورون فازی است که تابع عضویت را بر روی ورودی‌ها اعمال می‌کند. دو نوع از توابع عضویت بطور معمول مورد استفاده قرار می‌گیرند: تابع بل<sup>۸</sup> و تابع گوسی<sup>۹</sup>. این شبکه همچنین دارای یک آکسون نرمال کننده است که خروجی را در دامنه بین صفر تا یک استاندارد می‌کند. دومین مولفه اصلی این ساختار یک شبکه مادولار است که قوانین تابعی را بر روی ورودی‌ها اعمال می‌نماید. تعداد شبکه‌های مادولار منطبق است بر تعداد خروجی‌های شبکه و تعداد عناصر پردازش کننده در هر شبکه نیز منطبق بر تعداد توابع عضویت است. CANFIS همچنین دارای یک آکسون ترکیب‌کننده است که خروجی‌های توابع عضویت را بر روی خروجی‌های شبکه مادولار اعمال می‌کند. در آخر خروجی‌های ترکیب شده بدون لایه خروجی نهایی هدایت شده و خطا بسمت توابع عضویت و شبکه‌های مادولار پس انتشار می‌یابد. هر گره در لایه اول رتبه عضویتی است از یک مجموعه فازی (A1, A2, B1, B2) و تعیین‌کننده درجه عضویت متغیر ورودی به یکی از مجموعه‌های فازی است. مجموعه‌های فازی بوسیله توابع عضویت تعریف می‌شوند. لایه دوم دریافت کننده ورودی است بشکل ضرب جفت‌های خروجی از لایه اول. لایه سوم دارای دو مولفه است. مولفه بالایی اعمال کننده توابع عضویت بر هر یک از ورودی‌ها است در حالی‌که مولفه پایینی بیانی است از شبکه مادولار که برای هر خروجی جمع وزن‌ها را محاسبه می‌کند. لایه چهارم خروجی نهایی شبکه را تولید می‌کند. در این مطالعه از ساختار فازی سوگنو<sup>۱۰</sup> بهره گرفته شده است [۷].

۸۰ تا ۹۰ درجه غربی را در بر می‌گیرد. شاخص NINO3 مربوط به دمای سطح اقیانوس آرام بوده و محدوده ۵ درجه شمالی تا ۵ درجه جنوبی و ۹۰ تا ۱۵۰ درجه غربی را در بر می‌گیرد. شاخص NINO3.4 مربوط به دمای سطح اقیانوس آرام بوده و محدوده ۵ درجه شمالی تا ۵ درجه جنوبی و ۱۲۰ تا ۱۷۰ درجه غربی را در بر می‌گیرد. شاخص<sup>۱</sup> TSA مربوط به دمای سطح اقیانوس اطلس بوده و محدوده استوا تا ۲۰ درجه جنوبی و ۱۰ درجه شرقی تا ۳۰ درجه غربی را شامل می‌شود. شاخص<sup>۲</sup> SW MRR یا شاخص بارش منطقه مونسون که بر اساس میانگین بارش ماهیانه ساحل برای منطقه آریزونا و نیومکزیکو است. شاخص<sup>۳</sup> SOI یا شاخص نوسانات جنوبی که بر اساس فشار سطح آب محاسبه می‌گردد. شاخص<sup>۴</sup> NAO که مرتبط با نوسانات فشار اقیانوس اطلس شمالی و تغییرات شدت و مکان رودبادهاست. شاخص<sup>۵</sup> MEI یا شاخص چند متغیره ENSO که مرتبط با پارامترهایی مثل فشار سطح آب، سرعت باد، دمای سطح آب و غیره می‌باشد. شاخص<sup>۶</sup> AMO یا شاخص نوسانات چند دهه‌ای اقیانوس اطلس که مرتبط با نوسانات دمایی اقیانوس اطلس شمالی است. اطلاعات تفصیلی این شاخص‌ها در وبسایت آزمایشگاه تحقیقاتی سامانه زمین<sup>۷</sup> متعلق به اداره ملی علوم جوی و اقیانوسی ایالات متحده آمریکا آمده است. از بین این شاخص‌ها الگوهای NINO 1+2, NINO 3, MEI, TSA, AMO و NINO3.4 به کمک روش رگرسیون گام به گام و بررسی ماتریس همبستگی، موثر بر خشکسالی شهر بیرجند تشخیص داده شدند که در مدل‌سازی از آن‌ها بهره گرفته شد.

### شبکه فازی-عصبی CANFIS

این ساختار حاصل تلفیق شبکه تطبیقی عصبی با قوانین فازی است (شکل ۴). CANFIS می‌تواند به‌عنوان تخمین‌زننده کلی برای توابع غیرخطی مورد استفاده قرار بگیرد [۲۳]. برتری این شبکه نسبت به سیستم‌های

<sup>1</sup>. Tropical Southern Atlantic Index

<sup>2</sup>. SW Monsoon Region Rainfall

<sup>3</sup>. Southern Oscillation Index

<sup>4</sup>. North Atlantic Oscillation

<sup>5</sup>. Multivariate ENSO Index

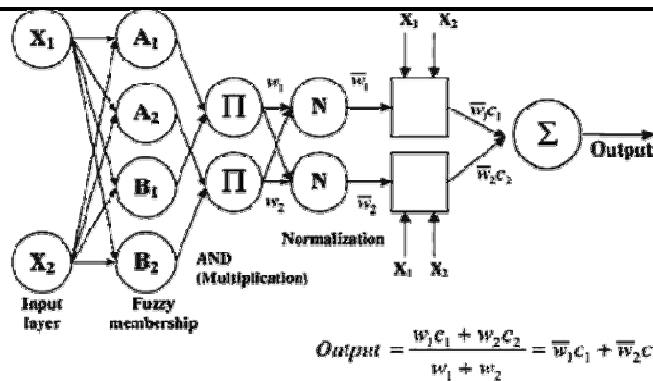
<sup>6</sup>. Atlantic Multidecadal Oscillation

<sup>7</sup>. Earth System Research Laboratory

<sup>8</sup>. Bell

<sup>9</sup>. Gaussian

<sup>10</sup>. Sugeno



شکل ۴- شبکه [vCANFIS]

تابع انتقال مورد استفاده در این مطالعه، تابع سیگموئید (لجستیک) می‌باشد که خروجی این تابع در دامنه صفر تا یک بوده و به صورت زیر تعریف می‌شود:

$$\phi(y_i) = (1 + e^{-w_i})^{-1} \quad (۴)$$

که در این تابع  $y_i$  خروجی نورون  $i$  ام و  $w_i$  جمع وزنی سیناپس‌های ورودی است [۳۲]. جهت ایجاد شبکه‌ای با بهترین درجه از تعمیم یافتگی از معیار اطلاعاتی آکایی<sup>۳</sup> و طول توصیف حداقل<sup>۴</sup> استفاده شد. معیار AIC ایجاد تعادل بین اندازه و عملکرد شبکه را بر عهده دارد. معیار MDL کارکردی مشابه AIC دارد و سطح تعمیم یافتگی مدل را تعیین می‌کند.

در نرم افزار NeuroSolutions، دو نوع کلی از توابع عضویت فازی وجود دارد: تابع بل<sup>۵</sup> و تابع گوسی<sup>۶</sup>. تابع بل نسبت به تابع گوسی با توجه به داشتن سه پارامتر آزاد جهت تصحیح در مقابل دو پارامتر تابع گوسی، قابلیت انعطاف بیشتری دارد [۳۷]. بنابراین در این مطالعه نیز از این تابع در یادگیری شبکه استفاده شد. با توجه به بررسی‌های انجام شده [۳۷] و اندازه داده‌های ورودی به شبکه جهت آموزش، در همه مدل‌های اجرا شده، از سه تابع عضویت فازی برای هر ورودی بهره گرفته شد. اما در نهایت و بمنظور ارتقای عملکرد شبکه (مدل) نهایی انتخاب شده، از ۵ تابع عضویت فازی جهت آموزش بهترین شبکه استفاده گردید.

آموزش شبکه مبتنی بر روش تصحیح خطاست و مشخص بودن پاسخ مطلوب از الزامات این روش است. در این روش خطای لحظه ای  $e_i(n)$  بصورت زیر تعریف می‌شود:

$$e_i(n) = d_i(n) - y_i(n) \quad (۲)$$

که در آن:  $y_i(n)$  پاسخ سیستم در نورون  $i$  ام و تکرار  $n$  ام و  $d_i(n)$  پاسخ مطلوب است. با تکیه بر تئوری آموزشی کاهش گرادیان [۱۱ و ۳۷]، هر وزن در شبکه در تکرار  $n+1$  با استفاده از رابطه ۳ بصورت زیر محاسبه می‌شود:

$$w_{ij}(n+1) = w_{ij}(n) + \eta \delta_i(n) x_j(n) + \alpha (w_{ij}(n) - w_{ij}(n-1)) \quad (۳)$$

خطای محلی یا  $\delta_i(n)$  به صورت مستقیم از  $e_i(n)$  در نورون خروجی بدست می‌آید و یا این که به صورت جمع وزنی خطاهای نورون‌های داخلی محاسبه می‌گردد. ثابت  $\eta$  اندازه گام و  $\alpha$  نرخ گشتاور است. این روش که به الگوریتم پس انتشار خطا معروف است، بر روش مومنتم سوار شده و حساسیت تابع هزینه را با در نظر گرفتن هر وزن در شبکه محاسبه کرده و هر وزن را متناسب با حساسیت آن به هنگام می‌نماید [۳۲]. در این مطالعه از تکنیک آموزش افزایشی<sup>۱</sup> بجای آموزش یکجا<sup>۲</sup> استفاده گردید. آموزش افزایشی سرعت بیشتری داشته و توانایی بیشتری در فرار از حداقل‌های محلی دارد [۴۳]. در این مطالعه، با توجه آزمون و خطاهای انجام شده، اندازه گام و نرخ گشتاور بترتیب برابر با ۱ و ۰/۷ انتخاب شد.

<sup>۳</sup>. Akaike's information criterion (AIC)

<sup>۴</sup>. Minimum Description Length (MDL)

<sup>۵</sup>. Bell-shaped curve

<sup>۶</sup>. Gaussian-shaped curve

<sup>۱</sup>. Online learning

<sup>۲</sup>. Batch learning

که در این معادله،  $x_i$  پارامتر شبیه‌سازی در گام  $i$ ،  $\mu$  میانگین پارامتر شبیه‌سازی در طی آنالیز حساسیت، و  $N$  تعداد گام‌های تغییر بر اساس انحراف معیار است [۳۲] و [۳۷].

### مدل‌های پیش‌بینی

جهت پیش‌بینی خشکسالی، SPI در مقیاس یک ماهه در تمام سال‌های دوره آماری محاسبه و به‌عنوان پارامتر پیش‌بینی شونده یا همان خروجی مدل‌ها در نظر گرفته شد. جهت تعیین بهترین ترکیب از پارامترها (بارندگی، شاخص پیشین SPI و شاخص‌های بزرگ مقیاس اقلیمی) از نتایج حاصل از محاسبه ماتریس همبستگی (بر اساس ضریب همبستگی پیرسون) (جدول ۲) و رگرسیون گام به گام<sup>۱</sup> (جدول ۳) استفاده شد. اندیس‌های  $t-1$ ،  $t-2$ ،  $t-3$ ،  $t-4$ ،  $t-5$  و  $t-6$  به ترتیب نشان دهنده ارزش پارامترها در گام‌های زمانی یک ماه، دو ماه، سه ماه، چهار ماه، پنج ماه و شش ماه قبل می‌باشند.

با توجه به نتایج حاصل از روش رگرسیون گام به گام، ۱۲ مدل استخراج شد. ولی با توجه به محدودیت شبکه CANFIS در اجرای مدل‌های با تعداد ورودی‌های بیش از ۵ متغیر، فقط ۸ مدل اول توسط شبکه CANFIS شبیه‌سازی گردیدند. این محدودیت ناشی از وجود رابطه نمایی بین تعداد ورودی‌ها و تعداد عناصر پردازشی داخلی (نورون‌ها) می‌باشد که نیازمند وجود سیستم‌های قوی پردازشی رایانه‌ای است. به‌عنوان مثال جهت ساخت شبکه‌ای با ۹ متغیر ورودی نیاز به ۱۹۶۸۳ نورون داخلی است که این تعداد عنصر پردازشی زمان اجرای مدل را بسیار افزایش می‌دهند. حال اگر تعداد توابع عضویت فازی نیز افزایش یابند، زمان اجرای مدل بسیار بیشتر خواهد بود. البته همان‌طور که در جدول مشاهده می‌شود نیز تغییرات F در نتیجه افزایش تعداد ورودی‌ها از مدل ششم به بعد بشدت کاهش می‌یابد. که این خود نشان‌دهنده این است که کارآمدترین پارامترها در افزایش عملکرد مدل به ترتیب عبارتند از  $NINO_{1+2(t-5)}$ ،  $R(t)$ ،  $NINO_{1+2(t)}$  و  $NINO_{3(t-6)}$ ،  $MEI(t)$ .

طول دوره آماری در مجموع ۴۱ سال (۱۹۷۰-۲۰۱۰) می‌باشد که ۶۰ درصد از این دوره (معادل ۲۵ سال) جهت آموزش، ۱۵ درصد جهت اعتبار سنجی متقابل و ۲۵ درصد باقیمانده (معادل ۱۰ سال) جهت آزمون شبکه استفاده شد.

### معیارهای آزمون و اعتبار سنجی شبکه

در این مطالعه از سنج‌های اعتبار سنجی زیر در آزمون شبکه استفاده گردید:

$$MSE = \frac{\sum_{j=0}^p \sum_{i=0}^N (d_{ij} - y_{ij})^2}{NP} \quad (۵)$$

$$NMSE = \frac{P \cdot NMSE}{\sum_{j=0}^p \frac{N \sum_{i=0}^N d_{ij}^2 - (\sum_{i=0}^N d_{ij})^2}{N}} \quad (۶)$$

$$r = \frac{\frac{\sum_i (x_i - \bar{x})(d_i - \bar{d})}{N}}{\sqrt{\frac{\sum_i (d_i - \bar{d})^2}{N}} \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{N}}} \quad (۷)$$

که در آن‌ها:  $P$ : تعداد خروجی عناصر پردازش شده،  $N$  تعداد نمونه‌ها در مجموعه داده‌ها،  $y_{ij}$  خروجی شبکه برای نمونه  $i$  در عنصر پردازش شده  $j$ ،  $d_{ij}$  خروجی مورد نظر برای نمونه  $i$  در عنصر پردازش شده  $j$  می‌باشد. MSE اختلاف بین مقدار مشاهده شده و مقدار محاسبه شده را نشان می‌دهد. کمترین مقدار MSE بالاترین صحت پیشگویی را بیان می‌کند. همچنین  $r$  نشانگر میزان بازده شبکه می‌باشد که در آن  $x_i$  خروجی شبکه،  $d_i$  خروجی مورد نظر،  $\bar{x}$  میانگین خروجی شبکه و  $\bar{d}$  میانگین خروجی مورد نظر می‌باشد. بهترین جواب برای مدل هنگامی ایجاد خواهد شد که  $r$  و MSE به ترتیب به یک و صفر میل کنند [۳۱].

### حساسیت سنجی شبکه

تحلیل حساسیت شبکه به تغییرات در متغیرهای ورودی، جهت تحلیل سناریوهای مختلف با استفاده از معادله ۸ به صورت زیر انجام شد:

$$Sensitivity = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (۸)$$

<sup>۱</sup>. Stepwise regression

جدول ۲- ضرایب همبستگی بین SPI(t) و سایر متغیرها

متغیر	ضریب همبستگی	Sig. (2-tailed)	متغیر	ضریب همبستگی	Sig. (2-tailed)
SPI(t-1)	.354**	.000	NINO 3.4(t)	.091*	.043
SPI(t-2)	.132**	.003	NINO 3.4(t-1)	.196**	.000
SPI(t-3)	-.050	.268	NINO 3.4(t-2)	.296**	.000
R(t)	.188**	.000	NINO 3.4(t-3)	.338**	.000
R(t-1)	-.252**	.000	NINO 3.4(t-4)	.269**	.000
R(t-2)	-.187**	.000	NINO 3.4(t-5)	.117**	.010
R(t-3)	-.001	.977	NINO 3.4(t-6)	-.034	.448
AMO(t)	.041	.365	NINO 3(t)	-.124**	.006
AMO(t-1)	.054	.231	NINO 3(t-1)	.040	.377
AMO(t-2)	.036	.431	NINO 3(t-2)	.241**	.000
AMO(t-3)	-.014	.751	NINO 3(t-3)	.401**	.000
MEI(t)	.133**	.003	NINO 3(t-4)	.441**	.000
MEI(t-1)	.140**	.002	NINO 3(t-5)	.352**	.000
MEI(t-2)	.147**	.001	NINO 3(t-6)	.173**	.000
MEI(t-3)	.134**	.003	SOI(t)	-.153**	.001
NAO(t)	.074	.102	SOI(t-1)	-.126**	.005
NAO(t-1)	.103*	.023	SOI(t-2)	-.084	.064
NAO(t-2)	.032	.481	SOI(t-3)	-.106*	.019
NAO(t-3)	-.009	.847	SWMRR(t)	.357**	.000
NINO 1+2(t)	-.339**	.000	SWMRR(t-1)	.244**	.000
NINO 1+2(t-1)	-.199**	.000	SWMRR(t-2)	-.049	.276
NINO 1+2(t-2)	.006	.896	SWMRR(t-3)	-.182**	.000
NINO 1+2(t-3)	.233**	.000	TSA(t)	-.072	.112
NINO 1+2(t-4)	.425**	.000	TSA(t-1)	-.051	.264
NINO 1+2(t-5)	.497**	.000	TSA(t-2)	-.031	.494
NINO 1+2(t-6)	.427**	.000	TSA(t-3)	-.032	.480

\*\*معنی‌دار در سطح ۰/۰۱، \*معنی‌دار در سطح ۰/۰۵

جدول ۳- خلاصه نتایج آماری حاصل از مدل سازی بروش رگرسیون گام به گام

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics				
					R Square Change	F Change	df1	df2	Sig. F Change
1	.497 <sup>a</sup>	.247	.245	.8135586	.247	158.749	1	484	.000
2	.756 <sup>b</sup>	.571	.570	.6144064	.324	365.617	1	483	.000
3	.824 <sup>c</sup>	.679	.677	.5321592	.108	161.836	1	482	.000
4	.862 <sup>d</sup>	.744	.741	.4762560	.064	120.796	1	481	.000
5	.879 <sup>e</sup>	.773	.771	.4482024	.030	63.097	1	480	.000
6	.882 <sup>f</sup>	.778	.776	.4437097	.005	10.770	1	479	.001
7	.885 <sup>g</sup>	.783	.780	.4394840	.005	10.255	1	478	.001
8	.887 <sup>h</sup>	.786	.783	.4364672	.003	7.631	1	477	.006
9	.889 <sup>i</sup>	.790	.786	.4329329	.004	8.820	1	476	.003
10	.890 <sup>j</sup>	.793	.788	.4308453	.002	5.624	1	475	.018
11	.892 <sup>k</sup>	.795	.791	.4285530	.003	6.095	1	474	.014
12	.893 <sup>l</sup>	.798	.793	.4264316	.002	5.728	1	473	.017

a. Predictors: (Constant), NINO 1+2(t-5)

b. Predictors: (Constant), NINO 1+2(t-5), R(t)

c. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t)

d. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t), NINO 3(t-6)

e. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t), NINO 3(t-6), MEI(t)

f. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t), NINO 3(t-6), MEI(t), NINO 3(t-4)

g. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t), NINO 3(t-6), MEI(t), NINO 3(t-4), TSA(t)

h. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t), NINO 3(t-6), MEI(t), NINO 3(t-4), TSA(t), AMO(t-2)

i. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t), NINO 3(t-6), MEI(t), NINO 3(t-4), TSA(t), AMO(t-2), NINO 3.4(t-6)

j. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t), NINO 3(t-6), MEI(t), NINO 3(t-4), TSA(t), AMO(t-2), NINO 3.4(t-6), SPI(t-2)

k. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t), NINO 3(t-6), MEI(t), NINO 3(t-4), TSA(t), AMO(t-2), NINO 3.4(t-6), SPI(t-2), NINO 1+2(t-4)

l. Predictors: (Constant), NINO 1+2(t-5), R(t), NINO 1+2(t), NINO 3(t-6), MEI(t), NINO 3(t-4), TSA(t), AMO(t-2), NINO 3.4(t-6), SPI(t-2), NINO 1+2(t-4), NINO 1+2(t-6)

p. Dependent Variable: SPI(t)

### نتایج و بحث

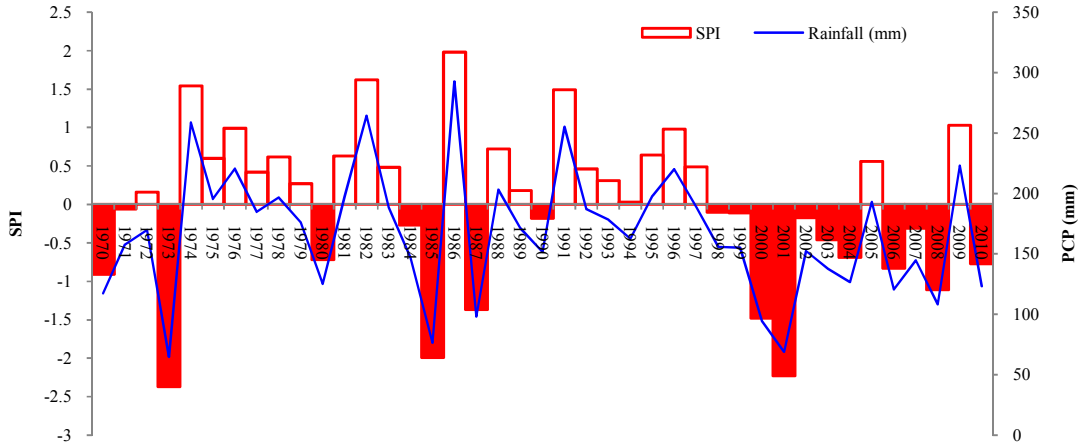
خشکسالی شدید و باقی سال ها در دوره آماری بجز ۱۹۷۴، ۱۹۸۲، ۱۹۸۶، ۱۹۹۱ و ۲۰۰۹ (که شرایط ترسالی

نتایج محاسبه SPI نشان دهنده اینست که سال‌های ۱۹۷۳ و ۲۰۰۱ خشکسالی‌های بسیار شدید، سال ۱۹۸۵



دوره‌های قبلی در دوره آماری مطالعاتی، طولانی بوده و همچنان نیز ادامه دارد.

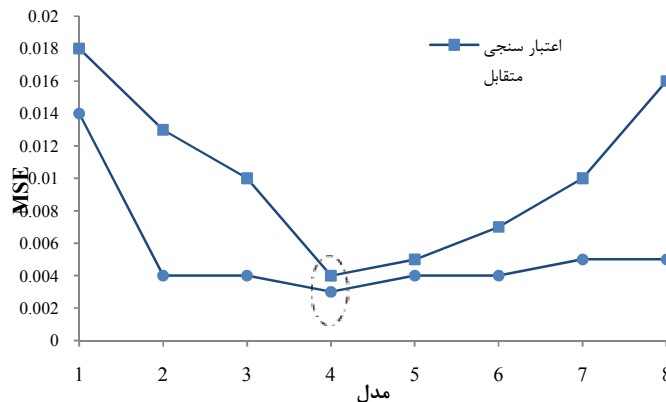
را داشته‌اند) شرایط نزدیک نرمال را تجربه کرده‌اند (شکل ۵). همان‌طور که در شکل ۵ دیده می‌شود بیرجند از سال ۱۹۹۸ وارد دوره خشکسالی شده و این دوره بر خلاف



شکل ۵- انطباق خشکسالی و بارش در دوره آماری ۱۹۷۰-۲۰۱۰ ایستگاه سینوپتیک بیرجند

(بترتیب ۰/۰۰۳ و ۰/۰۰۴) در مدل ۴ دیده می‌شود. اما همان‌طور که در جدول ۳ آمده است، این تفاوت در مدل‌های رگرسیونی بجز بین مدل ۱ با سایر مدل‌ها چندان مشهود نیست. اگرچه تغییرات آماره F در اکثر آن‌ها به لحاظ آماری معنی‌دار است ولی از مدل پنجم به بعد تغییرات ضرایب تبیین و همبستگی جزئی و بسیار تدریجی است.

نتایج ارزیابی مدل‌ها در طی آموزش و اعتبارسنجی متقابل شبکه نشان‌دهنده تفاوت صحت معنی‌داری بین مدل‌های مختلف است (شکل ۶). این تفاوت بخصوص بین مدل‌های چهار و پنج با یک، دو و سه و همچنین بین مدل‌های چهار و پنج با شش، هفت و هشت به طور کامل مشهود است. به طوری که بیشترین صحت شبکه و کم‌ترین خطا (MSE) در طی آموزش و اعتبارسنجی متقابل

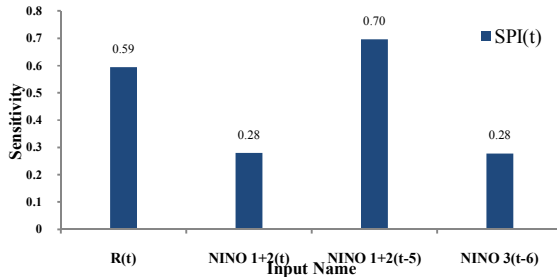


شکل ۶- نمودار خطای مدل‌های مختلف برای سری داده‌های آموزش و اعتبارسنجی متقابل

$1+2(t-5)$  با متوسط حساسیت ۰/۷ بیش‌ترین تاثیر را بر عملکرد شبکه داشته است. پس از آن متغیرهای  $R(t)$ ،  $NINO\ 1+2(t)$  و  $NINO\ 3(t-6)$  به ترتیب با حساسیت ۰/۵۹، ۰/۲۸ و ۰/۲۸ توانسته اند خروجی شبکه را بیش از

نتایج آنالیز حساسیت شبکه نشان می‌دهد که تقریباً در کلیه مدل‌های مختلف، شاخص‌های NINO و بارش بیشترین تاثیر را بر عملکرد شبکه داشته‌اند. همان‌طور که در شکل ۸ دیده می‌شود در مدل ۴، شاخص NINO

است تغییر در خروجی شبکه ایجاد کند. پس از NINO1+2(t-5) با متوسط حساسیت ۰/۳۵، خروجی شبکه بیش از همه تحت تاثیر متغیر بارش در گام زمانی t (با متوسط حساسیت ۰/۱۸) بوده است.



شکل ۸- نتیجه آنالیز حساسیت مدل شماره ۴

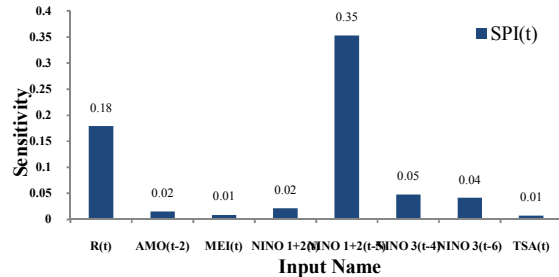
مرتبط با دمای سطح اقیانوس می باشد) بر وقوع و شدت خشکسالی منطقه اقلیمی بیرجند باشد.

بر اساس تحلیل‌های آماری انجام شده (جدول‌های ۲ و ۳) مشخص گردید که شاخص‌های NAO و SOI تاثیر معنی‌داری در بهبود نتایج مدل‌ها ندارند. این نتایج نیز با یافته‌های حاصل از تحقیقات مرید و همکاران [۳۳] و نگارش و آرمش [۳۵] مطابقت دارد.

نتایج این پژوهش نشان می‌دهد که همبستگی با تاخیر شاخص‌های اقلیمی نتایج قابل قبول‌تری بین خشکسالی و ENSO را ارائه می‌دهد. بر اساس مطالعات فتاحی و همکاران [۲۰] و چپو<sup>۳</sup> و همکاران [۱۵] علت بکار بردن چنین شیوه‌ای توجه به فاصله مکانی زیاد بین ایران و مکان اصلی و خاستگاه سیگنال‌های بزرگ مقیاس اقلیمی است.

همچنین نتایج محاسبات آماری و اجرای شبکه با مقادیر پیشین SPI نشان داد که این متغیر توانایی چندانی در افزایش عملکرد شبکه و کاهش خطای مدل ندارد و این نتایج نیز تا حدودی با یافته‌های اژدری مقدم و همکاران [۱] همخوانی دارد. لازم بذکر است که در این مطالعه بمنظور اطمینان از عدم افزایش عملکرد شبکه با مقادیر پیشین SPI، در مدل چهارم متغیر ورودی NINO 3(t-6) با متغیر ورودی SPI(t-1) جایگزین شد و شبکه دوباره آموزش و آزمون گردید که نتایج بدست آمده حاکی از افزایش خطای مدل نسبت به مدل قبلی داشت.

همه تحت تاثیر تغییرات خود قرار دهند. در مدل ۸ نیز همان‌طور که در شکل ۷ نشان داده شده است، از بین شاخص‌های بزرگ مقیاس اقلیمی، تغییرات در شاخص‌های NINO 1+2 و NINO 3 بیشتر از دیگر شاخص‌ها توانسته



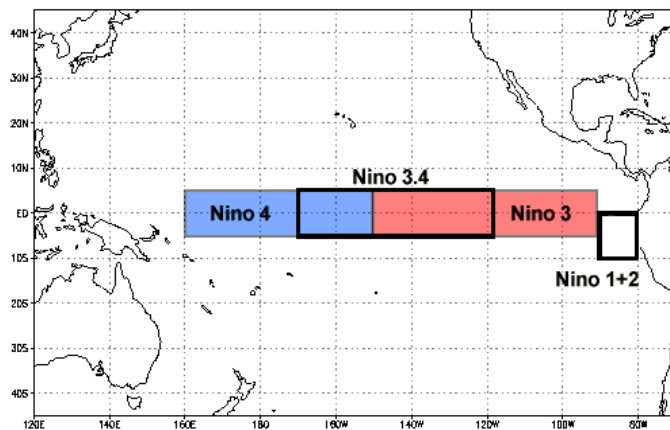
شکل ۷- نتیجه آنالیز حساسیت مدل شماره ۸

البته همان‌طور که در تعریف شاخص NINO 1+2 نیز گفته شد، این شاخص از سنجه‌های اصلی پدیده ENSO بوده و بیانگر نوسانات درجه حرارت سطح دریا در شرقی‌ترین بخش اقیانوس آرام است که نزدیک‌ترین فاصله را با ایران داراست (شکل ۹). بنابراین می‌تواند توانمندی بالاتری از نظر تاثیر بر خشکسالی‌های منطقه اقلیمی شرق کشور داشته باشد. اژدری مقدم و همکاران [۱] نیز در مدل‌سازی خشکسالی پاییزه به کمک شبکه عصبی-فازی شاخص‌های NINO 3, NINO 1+2 و NINO 3,4 و همچنین میانگین سه ماهه بارش را در بین مناسب‌ترین متغیرها جهت شبیه‌سازی قرار دادند. این نتایج با یافته‌های حاصل از تحقیقات فتاحی و همکاران [۲۰] نیز همخوانی دارد. البته آنها در پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی نشان دادند که پدیده ENSO در مناطق NINO 3, NINO 1+2 و NINO 3.4 بعنوان موثرترین سیگنال در پیش‌بینی بارش می‌باشد. آلن<sup>۱</sup> و همکاران [۵] و کریپالانی و کولکارانی<sup>۲</sup> [۲۷] نیز بر این نکته تاکید می‌کنند که ENSO از مهم‌ترین پدیده‌های شناخته شده‌ای است که ناشی از واکنش‌های متقابل اقیانوس-جو و خشکی بوده و تغییرات اقلیمی سالانه در سطح کره زمین را موجب می‌گردد. با توجه به نکات گفته شده در بالا، شکل ۱۰ می‌تواند اثبات‌کننده انطباق پدیده اقلیمی ENSO (که همراه با وقوع سیگنال‌های غیر نرمال

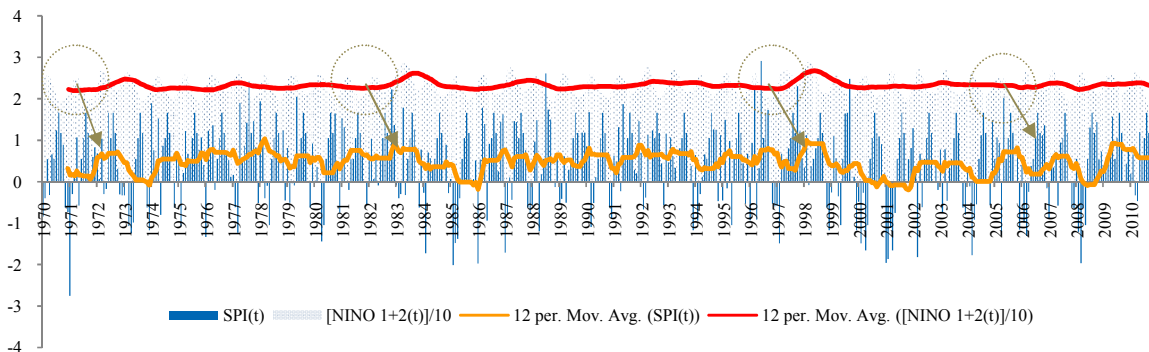
<sup>۱</sup>.Allen

<sup>۲</sup>. Kripalani and Kulkarani

<sup>۳</sup>.Chiew



شکل ۹- نواحی چهارگانه NINO در اقیانوس آرام



شکل ۱۰- انطباق ENSO (شاخص NINO 1+2(t)) بر مهم‌ترین وقایع خشکسالی در طی دوره آماری ایستگاه سینوپتیک بیرجند

جدول ۴- معیارهای ارزشیابی در طی آزمون شبکه

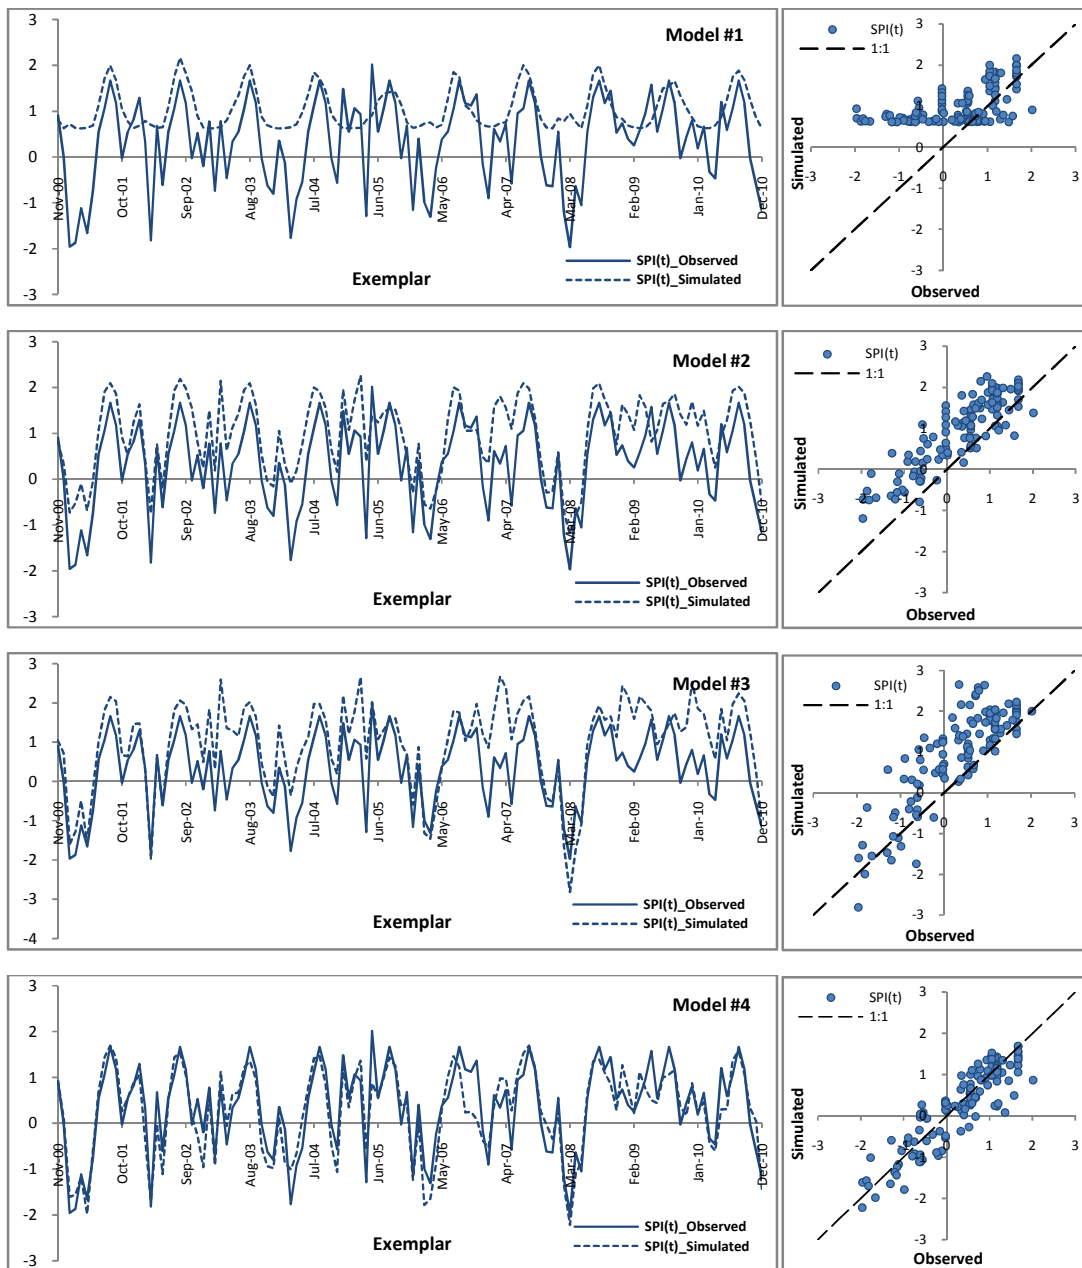
r	NMSE	MSE	مدل
-۰/۵۹۵	۱/۱۹۳	۱/۰۷۴	۱
-۰/۸۷۲	-۰/۶۸۴	-۰/۶۱۵	۲
-۰/۸۴۵	-۰/۸۵	-۰/۷۶۵	۳
-۰/۹۰۳	-۰/۱۹۶	-۰/۱۷۶	۴
-۰/۸۸۶	-۰/۲۳۲	-۰/۲۰۹	۵
-۰/۸۵۱	-۰/۴۵۹	-۰/۴۱۳	۶
-۰/۸۴۶	-۰/۶۹۶	-۰/۶۲۶	۷
-۰/۸۲۸	۱/۰۴	-۰/۹۳۶	۸

بعد نتوانست میزان خطا را بطور معنی‌داری کاهش دهد. ضمن این‌که زمان لازم برای آموزش شبکه و اجرای مدل با توجه به پیچیدگی بیشتر شبکه، بشدت افزایش می‌یابد. بر اساس شکل ۱۱، مشاهده می‌شود که عملکرد شبکه از مدل پنجم به بعد با افزایش تعداد ورودی‌ها به عملکرد مدل شماره ۱ نزدیک می‌شود، به طوری‌که مدل ۸ همانند مدل ۱ توانایی پیش‌بینی حتی خشکسالی‌های نزدیک به نرمال را هم ندارد. همانطور که توسط برخی محققین [۳۲ و ۳۴] نیز تاکید شده است، گاهی اوقات افزایش پیچیدگی شبکه چه در تعداد ورودی‌ها و چه در ساختار و معماری

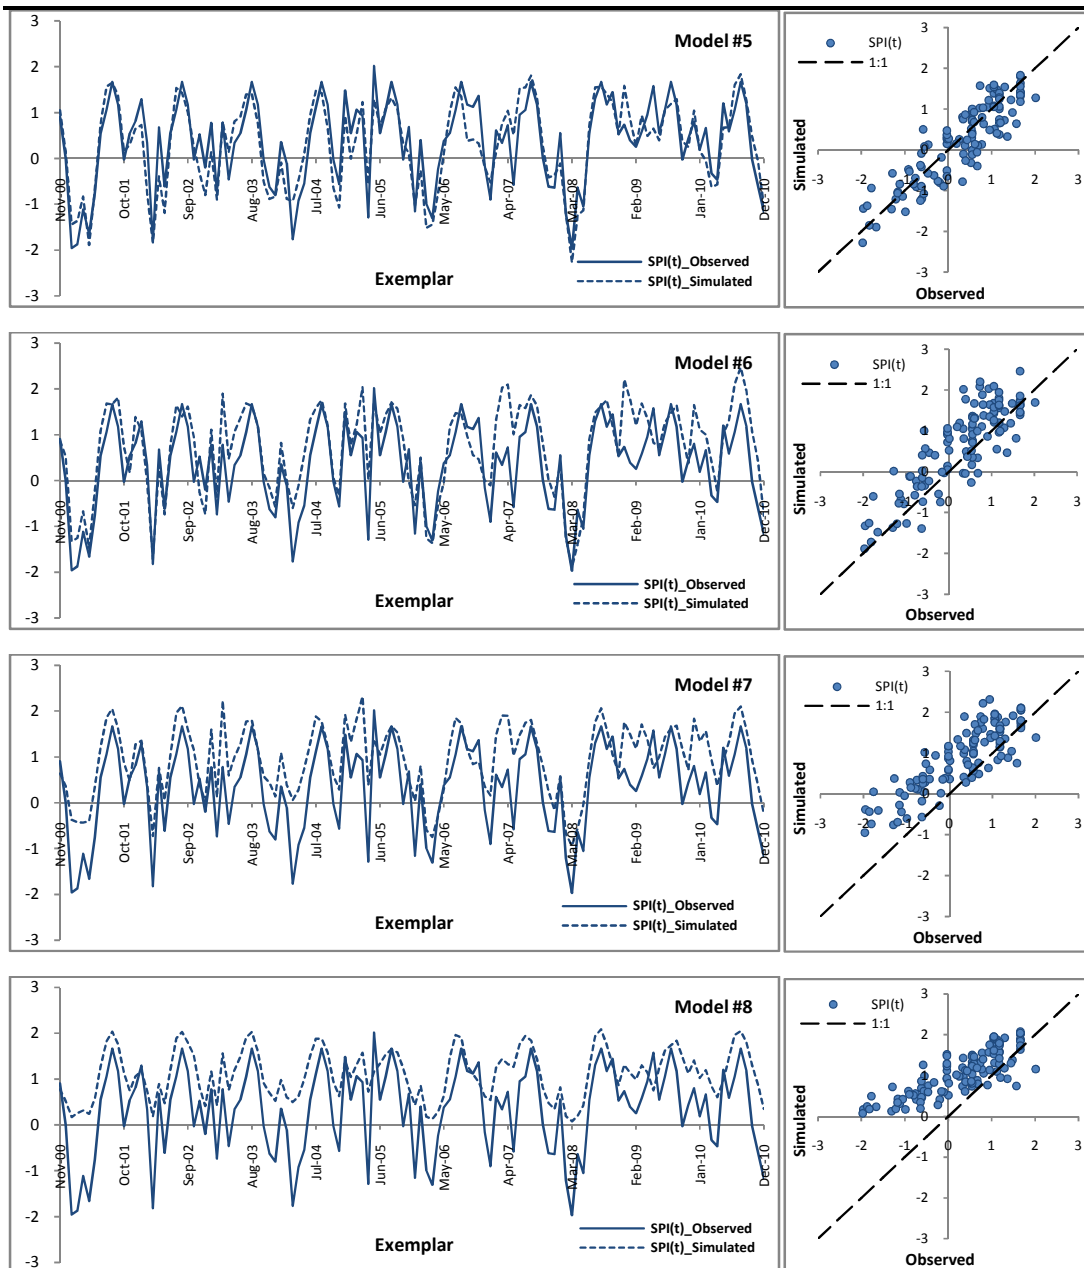
همان‌طور که در جدول ۴ و شکل ۱۱ نشان داده شده، در طی آزمون شبکه، میزان MSE و NMSE از مدل اول تا چهارم با افزایش تعداد ورودی‌ها کاهش می‌یابد. به طوری‌که میزان MSE از ۱/۰۷۴ به ۰/۱۷۶ و میزان NMSE از ۱/۱۹۳ به ۰/۱۹۶ رسیده است که خود نشان‌دهنده کاهش حدود ۱۰ برابری میزان خطا است. اما با افزایش تعداد ورودی‌ها بعد از مدل چهارم، عملکرد شبکه نه تنها افزایش نیافت بلکه میزان خطا تا حدود ۵ برابر در مدل هشتم افزایش پیدا کرد. لازم بذکر است که افزایش تعداد توابع عضویت (تا ۷ تابع) از مدل پنجم به

مدل چهارم با ضریب همبستگی ۰/۹۰۳ (بین مقادیر مشاهداتی و پیش بینی شده) را به عنوان مناسبترین مدل جهت پیش بینی خشکسالی در منطقه اقلیمی بیرجند ارائه داد.

آن نمی‌تواند کمکی به بهبود عملکرد شبکه نماید و چه بسا همانند آنچه که در این تحقیق مشاهده شد، حتی موجب کاهش عملکرد و افزایش خطای مدل گردد. در مجموع، با بررسی معیارهای ارزیابی شبکه در طی مراحل آموزش، اعتبار سنجی متقابل و آزمون می‌توان



شکل ۱۱- مقایسه داده‌های مشاهداتی و نتایج شبیه‌سازی حاصل از مدل‌های مختلف در طی آزمون شبکه



ادامه شکل ۱۱- مقایسه داده‌های مشاهداتی و نتایج شبیه‌سازی حاصل از مدل‌های مختلف در طی آزمون شبکه

### نتیجه‌گیری

تاثیر را بر عملکرد شبکه داشته‌اند. در مدل شماره ۴ نیز، شاخص  $NINO\ 1+2(t-5)$  با متوسط حساسیت  $0/7$  بیشترین تاثیر و پس از آن متغیرهای  $R(t)$ ،  $NINO\ 1+2(t)$  و  $NINO\ 3(t-6)$  بترتیب با حساسیت  $0/۲۸$ ،  $0/۵۹$  و  $0/۲۸$  توانستند خروجی شبکه را بیش از همه تحت تاثیر تغییرات خود قرار دهند. این نتایج اثبات کننده همبستگی قابل قبول پدیده اقلیمی ENSO با خشکسالی منطقه اقلیمی بیرجند است.

در این پژوهش عملکرد سیگنال‌های بزرگ مقیاس اقلیمی، بارش و مقادیر پیشین شاخص خشکسالی SPI جهت پیش‌بینی خشکسالی منطقه اقلیمی بیرجند به کمک شبکه CANFIS مورد ارزیابی قرار گرفت. نتایج به‌دست آمده از این تحقیق را می‌توان بصورت زیر خلاصه کرد:  
- آنالیز حساسیت شبکه نشان داد که تقریباً در همه مدل‌های مختلف، شاخص‌های NINO و بارش بیشترین

پیش‌بینی شده) به‌عنوان مناسب‌ترین مدل جهت پیش‌بینی خشکسالی در منطقه اقلیمی بیرجند با استفاده از شبکه CANFIS ارائه شد.

– شبکه CANFIS توانست با اعتبار نسبتاً خوب و تعداد ورودی‌های کمتر نسبت به مدل‌های آماری، با موفقیت در پیش‌بینی خشکسالی منطقه اقلیمی بیرجند بکار گرفته شود.

### سپاسگزاری

پژوهش حاضر با حمایت مالی دانشگاه بیرجند تحت قرار داد شماره ۱۹۵۸۷/د/۱۳۹۲ انجام شده است.

### References

- [1]. Ajdarimoghadam, M., Khosravi, M., Hoseinpoor Niknam, H., & Jafari Nadooshan, E. (2012). Drought forecasting using neuro-fuzzy system, climatic indices, rainfall and drought index (Case study: Zahedan). *Journal of Geography and Development*, 26, 61-72 (in Farsi).
- [2]. Akbari, M., & Akbari, M. (2010). Investigation of climate change on drought and desertification (Case study: Birjand plain). *The conference on application of natural geography in environmental planning*, Khorramabad, Iran, (in Farsi).
- [3]. Alizadeh, A. (2004). *Applied Hydrology*. 17<sup>th</sup> edition. University of Imam Reza, Mashad, (in Farsi).
- [4]. Alizadeh, A., & Ashgar toosi, S. (2008). Development of a model for drought monitoring and forecasting (Case study: Khorasan Razavi Province). *Journal of Agricultural Sciences and Industries*, 22(1), 223-234, (in Farsi).
- [5]. Allen, R.J., Beard, G.S., Close, A., Herczeg, A.L., Jones, P.D., & Simpson, H.J. (1996). *Mean sea level pressure indices of the El Nino-Southern Oscillation: relevance to stream discharge in south-eastern Australia*. CSIRO, Institute of Natural Resources and Environment, Division of Water Resources.
- [6]. Anvari, S. (2008). The development of intelligent models for flow prediction using spatial distributed climatic data and snow level. MSc thesis, University of Tarbiat Modarres, (in Farsi).

- بر اساس محاسبات آماری و شاخص‌های ارزیابی شبکه مشخص شد که همبستگی با تاخیر شاخص‌های اقلیمی نتایج قابل قبول‌تری بین خشکسالی و ENSO را ارائه می‌دهد. به‌طوری‌که استفاده از شاخص NINO 1+2 با پنج ماه تاخیر توانست بیشترین تاثیر را بر عملکرد شبکه CANFIS داشته باشد.
- نتایج محاسبات آماری و اجرای شبکه با مقادیر پیشین SPI نشان داد که این متغیر توانایی چندانی در افزایش عملکرد شبکه و کاهش خطای مدل ندارد.
- در مجموع مدل چهارم با ترکیبی از پارامترهای ورودی NINO 3(t-6) و NINO 1+2(t), R(t), NINO 1+2(t-5) و ضریب همبستگی ۰/۹۰۳ (بین مقادیر مشاهداتی و

- [7]. Aytek, A. (2009). Co-active neurofuzzy inference system for evapotranspiration modeling. *Soft Computing*, 13(7), 691-700.
- [8]. Aziz, K., Rahman, A., Shamseldin, A. Y., & Shoaib, M. (2013). Co-Active Neuro Fuzzy Inference System for Regional Flood Estimation in Australia. *Editorial Board*, 11.
- [9]. Bacanli, U.G., Firat, M., & Dikbas, F. (2009). Adaptive neuro-fuzzy inference system for drought forecasting. *Stochastic Environmental Research and Risk Assessment*, 23(8), 1143-154.
- [10]. Bagherzade Chehre, K. (2005). Evaluation of meteorological signals in drought forecasting using artificial neural networks in Tehran province. MSc thesis, University of Tarbiat Modarres, (in Farsi).
- [11]. Baldi, P. (1995). Gradient descent learning algorithm overview: A general dynamical systems perspective. *Neural Networks, IEEE Transactions on*, 6(1), 182-195.
- [12]. Banihashemi, E. (2011). Vados zone modeling using Groundwater Vistas (Case study: Birjand plain). MSc thesis, University of Birjand, (in Farsi).
- [13]. Barry, R.G., & Carleton, A.M. (2001). *Synoptic and dynamic climatology*. Psychology Press.
- [14]. Bloutsos, A.A. et al. (2001). Arima modeling of mean Temperature at the 1000/500 hpa layer over Europe. P.95. [www.cyf-kr.edu.pl/Zinied2w/paper009.html](http://www.cyf-kr.edu.pl/Zinied2w/paper009.html).

- [15]. Chiew, F.H., Piechota, T.C., Dracup, J. A., & McMahon, T. A. (1998). El Nino/Southern Oscillation and Australian rainfall, streamflow and drought: Links and potential for forecasting. *Journal of Hydrology*, 204(1), 138-149.
- [16]. Dehghani, A., Asgari, M., & Mosaedi, A. (2009). Comparison of artificial neural network with adaptive neuro-fuzzy inference system and geostatistical techniques for groundwater level interpolation (Case study: Ghazvin plain). *Journal of Agriculture and Natural Resources*, 16, 517-528, (in Farsi).
- [17]. Edalatgostar, M., Farzadian, A., & Amiri, N. (2009). A stochastic model for drought forecasting in Shiraz. *The National Conference on Water Crisis Management*, Marvdasht, Iran, (in Farsi).
- [18]. Estrela, M.J., Peñarrocha, D., & Millán, M. (2000). Multi-annual drought episodes in the Mediterranean (Valencia region) from 1950–1996. A spatio-temporal analysis. *International Journal of Climatology*, 20(13), 1599-1618.
- [19]. Farokhnia, A., Morid, S., & Ghaemi, H. (2008). Data mining on global climatic signals for long-term drought forecasting. *The 3<sup>rd</sup> conference on Iran's Water Resources Management*, Tabriz, (in Farsi).
- [20]. Fattahi, E., Sedaghatkerdar, A., & Delavar, M. (2008). Long-term forecasting of precipitation using artificial neural network. *Journal of Research and Development in Natural Resources*, 80, 44-50, (in Farsi).
- [21]. Gangully, A.R. (2002). Forecasting Rainfall and Floods Advances and way Forward. P.32. [Web.mit.edu/auroop/www/interests.html](http://web.mit.edu/auroop/www/interests.html).
- [22]. Hemachandra, S., & Satyanarayana, R.V.S. (2013). Co-Active Neuro-Fuzzy Inference System for prediction of electric load. *International Journal of Electrical and Electronics Engineering Research*, 3(2), 217-222.
- [23]. Jang, J.S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *Systems, Man and Cybernetics, IEEE Transactions on*, 23(3), 665-685.
- [24]. Javan, J., & Falsoleyman, M. (2008). Water crisis and necessity of attention to agricultural water use efficiency in arid regions (Case study: Birjand plain). *Journal of Geography and Development*, 11, 115-138, (in Farsi).
- [25]. Kholghi, M., & Hosseini, S.M. (2009). Comparison of groundwater level estimation using Neuro-Fuzzy and ordinary Kriging. *Journal of Environmental Modeling and Assessment*, 14(6), 729-753.
- [26]. Khosravi, M. (2004). Relationship assessment between global circular patterns of northern hemisphere with Sistan and Baloochestan's droughts. *Journal of Geography and Development*, 3, 167-188, (in Farsi).
- [27]. Kripalani, R.H., & Kulkarni, A. (1997). Rainfall variability over South-east Asia—connections with Indian monsoon and ENSO extremes: new perspectives. *International Journal of Climatology*, 17(11), 1155-1168.
- [28]. Martin, M., Cremades, L. V., & Santabarbara, J.M. (1999). Analysis and modelling of time series of surface wind speed and direction. *International journal of climatology*, 19(2), 197-209.
- [29]. Martin-Vide, J., & Gomez, L. (1999). Regionalization of peninsular Spain based on the length of dry spells. *International Journal of Climatology*, 19(5), 537-555.
- [30]. McKee, T.B., Doesken, N.J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In *Proceedings of the 8th Conference on Applied Climatology* (Vol. 17, No. 22, pp. 179-183). Boston, MA: American Meteorological Society.
- [31]. Memarian, H., & Balasundram, S.K. (2012). Comparison between Multi-Layer Perceptron and Radial Basis Function Networks for Sediment Load Estimation in a Tropical Watershed. *Journal of Water Resource & Protection*, 4(10).
- [32]. Memarian, H., Balasundram, S.K., & Tajbakhsh, M. (2013). An expert integrative approach for sediment load simulation in a tropical watershed. *Journal of Integrative Environmental Sciences*, 10(3-4), 161-178.
- [33]. Metalka, R.L. (1997). Analysis of secular time series of climatological characteristics. Doctoral thesis. P.42. [www.chmi.cz/poboc/HK/ok/PUBLIKACE/DISSERT/Diser.htm](http://www.chmi.cz/poboc/HK/ok/PUBLIKACE/DISSERT/Diser.htm)
- [34]. Morid, S., Smakhtin, V., & Bagherzadeh, K. (2007). Drought forecasting using artificial neural networks and time series

- of drought indices. *International Journal of Climatology*, 27(15), 2103-2111.
- [35]. Negaresh, H., & Armesh, M. (2011). Using neural network for drought forecasting in Khash. *Geographic Studies of Arid Regions*, 6, 33-50, (in Farsi).
- [36]. Poostizadeh, N., Mohamadvali Samani, J., & Koorepazan Dezfooli, A. (2008). Stream flow forecasting using Fuzzy system. *Water Resources Research*, 4(2), 23-34, (in Farsi).
- [37]. Principe, J.C, Lefebvre, W.C., Lynn, G., Fancourt, C., Wooten, D. (2007). Neuro Solutions – documentation, the manual and on-line help. Version 5.05. Neuro Dimension, Inc.
- [38]. Raziei, T., Daneshkar Arasteh, P., Akhtari, R., Saghafian, B. (2007). Investigation of meteorological droughts in the Sistan and Balouchestan province using the Standardized Precipitation Index and Markov chain model. *Iran-Water Resource Research*, 3(1), 25-35, (in Farsi).
- [39]. Safdari, A. (2003). Quantitative analysis of intensity, duration and the extent of drought using precipitation data (Case study: Karoon basin). MSc thesis, University of Tehran, (in Farsi).
- [40]. Sedaghat kerdar, A., & Fatahi, E. (2008). The prediction indices of drought in Iran. *Journal of Geography and Development*, 11, 59-76, (in Farsi).
- [41]. Shirmohamadi, B., Moradi, H., Taei, M., & Moosavi, V. (2012). Comparison of artificial neural network with adaptive neuro-fuzzy inference system in drought forecasting. *The 1<sup>st</sup> National Conference on Desert*, Tehran, Iran, (in Farsi).
- [42]. Tfwala, S.S., Wang, Y. M., Lin, Y.C. (2013). Prediction of Missing Flow Records Using Multilayer Perceptron and Coactive Neurofuzzy Inference System. *The Scientific World Journal*.
- [43]. Wilson, D.R., & Martinez, T.R. (2003). The general inefficiency of batch training for gradient descent learning. *Neural Networks*, 16(10), 1429-1451.



## Application of Rainfall Time Series and Climatic Indices for Drought Prediction using Co-Active Neurofuzzy Inference System (Case Study: Birjand, Southern Khorasan)

1- M. Rezaei, Associate Professor, Department of Statistics, University of Birjand

2- H. Memarian, Assistant Professor, Department of Range and Watershed Management, University of Birjand  
hadi\_memarian@birjand.ac.ir

Received: 02 May 2014

Accepted: 11 Jul 2015

### Abstract

Drought forecasting is an important tool for managers for exploitation of the limited resources of soil and water. Recently, Southern Khorasan has become one of the main centers in the country which suffers from severe drought. This study was aimed to assess the capability of CANFIS for drought forecasting of Birjand area through the combination of global climatic signals with rainfall and previous values of Standardized Precipitation Index (SPI). SPI was used to define and monitor the drought event in monthly time scale. In this study, nine global climatic indices were selected for drought simulation. Using stepwise regression and correlation analyses, the signals NINO 1+2, NINO 3, MEI, TSA, AMO and NINO 3.4 were recognized as the effective signals on the drought event in Birjand. In this work, for modeling, 41 years of climatic data records (1970-2010) were collected in which 60%, 15%, and 25% of them were extracted to be used in training, cross validation and testing processes, respectively. The momentum algorithm with Gaussian fuzzy membership function was utilized in network training process. Based on the results from stepwise regression analysis, 12 models were extracted for further processing by CANFIS. However, due to the limitation of CANFIS in the execution of training process with the inputs higher than 5, only 8 models were analyzed using CANFIS. Sensitivity analysis showed that for all models, NINO indices and rainfall variable had the largest impact on network performance. In model No. 4, as the model with the lowest error during training and testing processes, NINO 1+2(t-5) with an average sensitivity of 0.7 showed the highest impact on network performance. After that, the variables rainfall, NINO 1+2(t) and NINO 3(t-6) with the average sensitivity of 0.59, 0.28 and 0.28, respectively could have the highest effect on network performance. According to network performance metrics, it was established that the global indices with a time lag represented a better correlation with ENSO. Finally, the fourth model with a combination of the input variables NINO 1+2 (with 5 months of lag and without any lag), monthly rainfall and NINO 3 (with 6 months of lag) showed a correlation coefficient of 0.903 (between observed and simulated SPI) and was selected as the most accurate model for drought forecasting using CANFIS in the climatic region of Birjand.

**Keywords:** Drought forecasting; Climatic signals; SPI; CANFIS; ENSO.