

مقایسه کارایی شبکه عصبی مصنوعی در پیش‌بینی خشکسالی هواشناسی با استفاده از پیوند از دور و پارامترهای اقلیمی (مطالعه موردی: جنوب استان قزوین)

- ❖ فاطمه مقصود؛ دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و علوم دریایی دانشگاه تربیت مدرس
- ❖ محمد رضا یزدانی*؛ دانشیار گروه بیابان‌زدایی دانشکده کویرشناسی، دانشگاه سمنان
- ❖ محمد رحیمی؛ دانشیار گروه بیابان‌زدایی دانشکده کویرشناسی، دانشگاه سمنان
- ❖ آرش ملکیان؛ استادیار دانشکده منابع طبیعی، دانشگاه تهران
- ❖ علی‌اصغر ذوالفقاری؛ استادیار گروه مدیریت مناطق خشک دانشکده کویرشناسی، دانشگاه سمنان

چکیده

خشکسالی در نگاهی کلی معلول یک دوره شرایط خشک غیرعادی است که به اندازه کافی دوام داشته و سبب عدم تعادل در وضعیت هیدرولوژیک یک ناحیه همچون افت منابع آب سطحی و زیرزمینی می‌گردد. هدف از این تحقیق مدل‌سازی پیش‌بینی خشکسالی هوا شنا سی در سه مقیاس زمانی کوتاه‌مدت، میان‌مدت و بلندمدت در ای سنتگاه باران سنجی واقع در دشت جنوبی استان قزوین، با استفاده از شبکه عصبی پر سپtron چندلایه و با در نظر گرفتن پارامترها و سیگنال‌های اقلیمی می‌باشد. بدین منظور سه سناریوی مختلف به عنوان ورودی‌های مدل، مورد آزمون قرار گرفت. پس از تعیین متغیرهای ورودی با روش همبستگی متقطع اقدام به تعیین ترکیب بهینه متغیرها با استفاده از آزمون گاما گردید. نتایج نشان داد که با افزایش مقیاس زمانی از کوتاه‌مدت به بلندمدت، تأثیر سیگنال‌های اقلیمی افزایش و در عوض تأثیر پارامترهای هواشناسی کمتر می‌شود. همچنین مؤثرترین سیگنال اقلیمی و پارامتر هواشناسی در هر مقیاس، به ترتیب MEI (شاخص چندمتغیرهای النینو-نوسانات جنوبی) و بارندگی معرفی گردیدند. جهت مدل‌سازی از شبکه عصبی با یک لایه مخفی با تعداد کافی نرون، با تابع سیگموئید در لایه میانی و تابع خطی در لایه خروجی استفاده شد. مناسب‌ترین تعداد نرون در هر سناریو تعیین شد. در نهایت براساس معیارهای ارزیابی، مناسب‌ترین ساختار شبکه در هر مقیاس زمانی و در سه سناریوی مورد بررسی تعیین گردید.

کلید واژگان: خشکسالی، آزمون گاما، پیش‌بینی، شبکه عصبی، سیگنال اقلیمی.

هیدرواقلیمی در مناطق مختلف دنیا توسط محققین مورد بررسی قرار گفته است. این شاخص‌ها با استفاده از اندازه‌گیری درجه حرارت و فشار هوا در نقاط مختلف اتمسفر به دست می‌آیند [۴، ۱۷]. واکر^۴ شاید اولین محققی بود که به تغییر الگوی فشار هوا و حرکت باد در اقیانوس‌ها پی‌برد. وی نوسانات فشار بین نواحی شرقی و غربی اقیانوس آرام جنوبی را شاخص نوسانات جنوبی یا النینو- نوسانات جنوبی و نوسانات اطلس شمالی را که از اختلاف ناهنجاری فشار بین منطقه کم‌فشار ایسلند و پرفشار آزور بین ماههای دسامبر تا مارس ایجاد می‌شود را نوسانات اطلس شمالی نامید [۳۹، ۴۰]. بررسی ارتباط بین نوسانات جریان دو رودخانه در اسلواکی (بلا و هورن)^۵ جهت تعیین روند درازمدت خشکسالی و ترسالی با استفاده از شاخص‌های اقلیمی نوسانات اطلس^۶، نوسانات جنوبی^۷، نوسانات اطلس شمالی و نوسانات شبهدوسالانه^۸ نشان داد که بین جریان رودخانه‌ها و شاخص‌های معرفی شده ارتباط نزدیکی وجود دارد [۳۳]. هچنین نتایج ارتباط شاخص بارش استاندارد شده (SPI) و شاخص‌های النینو- نوسانات جنوبی^۹ و نوسان دمهای اقیانوس آرام نیز نشان داد که ارتباط قوی بین SPI و دو سیگنانل اقلیمی نامبرده در زمان وقوع خشکسالی و ترسالی وجود دارد [۱۶]. در چند دهه اخیر نیز شبکه‌های عصبی مصنوعی^{۱۰} قابلیت بالای خود را در مدلسازی سری‌های نایسیتا و غیرخطی هیدرومئورولوژیکی نشان داده‌اند [۲۸، ۲۹]. مدل‌هایی که بر پایه شبکه عصبی مصنوعی هستند، دارای ماهیت تجربی بوده و قادرند راه حل‌های مناسبی برای فرمول‌بندی و استخراج روابط بر مبنای داده‌های ورودی و خروجی ارائه دهند [۲]. تاکنون مطالعات فراوانی در رابطه با از استفاده از انواع شبکه‌های عصبی مصنوعی جهت

۱. مقدمه

خشکسالی را می‌توان پدیده‌ای گذرا، آرام، تکرار‌شونده و جزئی جدانشدنی از اقلیم هر منطقه دانست. بهترین راه سازگاری با خشکسالی، شناخت صحیح این پدیده و زمان وقوع آن است. با توجه به پیشرفت تکنولوژی و افزایش روزافزون تولید داده‌ها بایستی مدل‌هایی تولید نمود که بتواند این قبیل پدیده‌ها را قبل از وقوع پیش‌بینی نماید. در این صورت می‌توان خسارات ناشی از آن را به حداقل کاهش داد [۸]. مهمترین مسائل و مشکلات پیش روی ما در زمینه پیش‌بینی خشکسالی استفاده از داده‌های محلی و منطقه‌ای، نظیر ایستگاه‌های باران‌سنجی است. از طرفی محدود بودن طول دوره آماری و کیفیت نامناسب آنها محققین را ناچار به بازسازی این داده‌ها می‌نماید [۱] که طبیعتاً در چنین شرایطی قابلیت اعتماد پذیری داده‌ها کاهش می‌باید. این در حالی است که طی دو دهه گذشته استفاده از سیگنانل‌های اقلیمی و داده‌های پیوند از دور این مشکلات را مرتفع ساخته است [۹]. سیگنانل‌های اقلیمی دارای طول دوره آماری بالا بوده، از کفايت و اعتماد بالایی برخوردار می‌باشند، به سادگی قابل دستیابی هستند و همچنین جهت پیش‌بینی خشکسالی و ترسالی، پیش‌بینی وقوع سیل، پیش‌بینی جریان کمینه یا بیشینه رودخانه، شروع فصل گرم یا سرد در دنیا مورد استفاده قرار می‌گیرند [۱۲، ۳]. تحقیقات زیادی که طی سال‌های اخیر انجام گرفته است نشان می‌دهد که روند خشکسالی و ترسالی با پدیده‌های اقلیمی در استاندارد شده پدیده‌ها به صورت شاخص‌های عددی استاندارد شده نظیر شاخص نوسانات جنوبی^۱، نوسانات اطلس شمالی^۲، نوسان دمهای اقیانوس آرام^۳ تعریف شده‌اند که با استفاده از این مقادیر عددی، همبستگی و روابط آنها با پارامترهای

^۶ Atlantic Oscillation(AO)

^۷ Southern Oscillation

^۸ Quasi-Biennial Oscillation(QBO)

^۹ El Nino Southern Oscillation (ENSO)

^{۱۰} Artificial Neural Networks(ANN)

^۱ Southern Oscillation Index (SOI)

^۲ North Atlantic Oscillation(NAO)

^۳ Pacific Decadal Oscillation (PDO)

^۴ Walker

^۵ Bela and Horn

عصبی پرسپترون چندلایه^۱ و با استفاده از آمار ایستگاه‌های سینوپتیک، کلیماتولوژی و هیدرومتری استان اصفهان نیز نشان از دقت بالای این روش جهت پیش‌بینی سیکل خشکسالی‌ها داشت به طوری که از میان فاکتورهای اقلیمی مورد استفاده دمای بیشینه، دبی و بارش نقش مثبتی را در بالابردن دقت پیش‌بینی دارا بودند [۲۰]. تأثیر ۱۰ الگوی ارتباط از دور با استفاده از مدل سیستم استنتاج فازی- عصبی تطبیقی^۲، جهت پیش‌بینی خشکسالی پاییزه در همدان نشان داد که شاخص‌های اقلیمی شامل نوسانات جنوبی، شاخص حاره ای اطلس جنوبی^۳، برخی شاخص‌های النینو، نوسانات اطلس شمالی، نوسانات دهه‌ای اطلس^۴ و همچنین بارندگی و شاخص SPI از جمله متغیرهایی هستند که می‌توانند در بازه زمانی تابستان و پاییز برای پیش‌بینی خشکسالی پاییزه مورد استفاده قرار گیرند [۳۱]. نتایج استفاده از شبکه عصبی مصنوعی و سیگنال‌های اقلیمی جهت پیش‌بینی خشکسالی هیدرولوژیکی نیز حاکی از همبستگی بالای شاخص‌های النینو- نوسانات جنوبی چندمتغیره^۵ شاخص نوسانات جنوبی، شاخص نوسانات دهه‌ای آرام، نوسانات بین دهه‌ای اطلس^۶ و ناهنجاری گرمایی اقیانوس آرام^۷ با جریان رودخانه کرخه در غرب کشور و کارایی بالای شبکه عصبی مصنوعی هنگام استفاده از سیگنال‌های اقلیمی داشت [۳]. همچنین مقایسه ارزیابی و کارایی شاخص‌های هواشناسی و پیش‌بینی خشکسالی با استفاده از شبکه عصبی مصنوعی در اقالیم مختلف نشان داد که خشکسالی طی سال‌های ۱۳۹۲-۱۳۸۸ دارای روند افزایشی می‌باشد و همچنین شبکه عصبی مصنوعی در برآورد و پیش‌بینی شدت و مدت خشکسالی در مناطق اقلیمی مختلف دارای دقت یکسانی بوده و از کارایی بالای برخوردار است [۶]. در

پیش‌بینی پدیده‌ها انجام گرفته است به طوری که استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) جهت پیش‌بینی SPI حاکی از کارایی مناسب این شبکه در داده‌های هیدرواقلیمی می‌باشد [۱۹]. استفاده از شبکه عصبی مصنوعی بازگشتی و بازگشتی تأخیری جهت پیش‌بینی خشکسالی هواشناسی در استان یزد نشان داد که دو مدل مذکور دارای عملکرد بالای (از نظر دقت بالای مقادیر پیش‌بینی شده با مقادیر واقعی) بوده به طوری که ترکیبی از متغیرهای بارش و دمای بیشینه به عنوان ورودی مدل جهت دست‌یابی به دقت بالاتر مقادیر پیش‌بینی شده در این منطقه معرفی گردید [۵]. پیش‌بینی خشکسالی با استفاده از مقادیر SPI در پنجره‌های زمانی ۳، ۶، ۹ و ۲۴ ماهه و مدل شبکه عصبی مصنوعی در مناطق مختلف اقلیمی نیز حاکی از انجام پیش‌بینی دقیق‌تر خشکسالی در مقیاس‌های ۱۲ و ۲۴ ماهه بوده است [۱۵]. در مطالعه‌ای که بررسی کارایی شبکه عصبی مصنوعی در مدل‌سازی هیدرواقلیمی پیش‌بینی جریان ورودی رودخانه زاینده رود به مخزن سد آن پرداخته شد، از دو رویکرد مختلف استفاده گردید. در رویکرد اول از یک مدل برای ارتباط بین متغیرهای هیدرواقلیمی و جریان استفاده شد، به طوری که متغیرهای بارش، دمای هوای رواناب و میزان برف مشاهده شده به عنوان ورودی‌های مدل انتخاب گردید. در رویکرد دوم نیز از ترکیب دو مدل پیش‌بینی هواشناسی برای پیش‌بینی متغیرهای بارش و دمای هوای رواناب و آدلاین هیدرولوژی به همراه شبکه‌های پسانشان خطا و آدلاین تطبیقی جهت پیش‌بینی جریان رودخانه استفاده گردید که نتایج دو رویکرد، نشان دهنده برتری عملکرد شبکه عصبی مصنوعی نسبت به سایر روش‌ها می‌باشد [۱۸]. نتایج پیش‌بینی خشکسالی با استفاده از روش شبکه

^۱ Atlantic multidecadal oscillation(AMO)

^۲ Multivariate ENSO Index (MEI)

^۳ Atlantic Multidecadal Oscillation (AMO)

^۴ Pacific Warm Index (PAC WARM)

^۱ Multilayer Perceptron(MLP)

^۲ Adaptive neuro fuzzy inference system (ANFIS)

^۳ Tropical Southern Atlantic Index(TSA)

پرتفال می‌باشد و شاخص دمای سطح آب در مناطق شمالی مؤثر در پیش‌بینی می‌باشد [۳۷].

دشت قزوین با وسعتی بیش از ۴۱۳۰ کیلومتر مربع از دشت‌های حاصلخیز و وسیع کشور به شمار می‌رود که رشد جمعیت و افزایش صنایع سنگین در این استان در سال‌های اخیر، موجب شده که تقاضای آب برای مصرف کنندگان بخش‌های کشاورزی و صنعت بیشتر شود. از طرفی استفاده بی‌رویه از چاه‌ها موجب تشدید بحران کمبود آب در این منطقه شده است. لذا انجام مطالعات خشکسالی هواشناسی و پیش‌آگاهی از زمان این رخداد از جمله اقدامات مهم مدیریتی در جهت شناخت و مهار این بحران به شمار می‌رود. در زمینه پیش‌بینی خشکسالی محققین مختلف مطالعات متنوعی را با استفاده از انواع مدل‌ها انجام داده‌اند، اما تحقیقی که به استفاده از انواع پارامترهای اقلیمی و سیگنال‌های اقلیمی به عنوان فاکتورهای پیش‌بینی کننده با ساختارهای مختلف در پیش‌بینی خشکسالی در این منطقه به کار گرفته باشد، کمتر انجام شده است.

۲. روش‌شناسی

۲.۱. منطقه مورد مطالعه

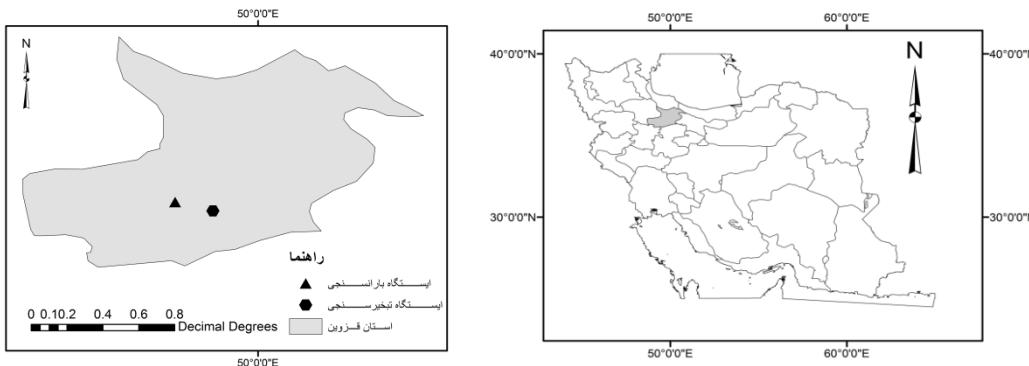
منطقه مورد نظر یکی از دشت‌های جنوبی استان قزوین شامل شهرستان‌های بویین‌زهرا و تاکستان است که در محدوده طول جغرافیایی ۴۹ درجه و ۱۰ دقیقه تا ۵۰ درجه و ۳۹ دقیقه شرقی و عرض جغرافیایی ۳۵ درجه و ۲۰ دقیقه تا ۳۶ دقیقه و ۳۰ دقیقه شمالی می‌باشد. شکل ۱ موقعیت این دشت در استان قزوین و توزیع ایستگاه‌های هیدرومتری و بارانسنجی را نشان می‌دهد.

با بررسی ایستگاه‌های بارانسنجی و تبخیرسنجی موجود در جنوب منطقه مورد مطالعه و وضعیت طول دوره آماری موجود، دو ایستگاه بارانسنجی و تبخیرسنجی دانشگاه طی دوره آماری ۱۳۶۲-۱۳۶۳ تا ۱۳۸۹۰-۱۳۹۱ انتخاب شد (جدول ۱). پارامترهای هواشناسی

تحقيقی دو روش رگرسیون چندگانه و شبکه‌های عصبی مصنوعی و همچنین شاخص‌های دور پیوندی برای پیش‌بینی خشکسالی دریاچه مهارلو بررسی شد. نتایج تحقیق بیانگر این بود که شاخص‌های اقلیمی نوسانات اطلس شمالی، شاخص آمریکای شمالی آرام و النینو متغیرهای خوبی در پیش‌بینی خشکسالی هستند. ضمن اینکه بین شاخص‌های اقلیمی و بارندگی ارتباط وجود دارد [۳۸]. نتایج بررسی چند روش مدل‌سازی با هوش مصنوعی و مدل سری زمانی میانگین متحرک اتورگرسیو برای پیش‌بینی خشکسالی با استفاده از شاخص استاندارد بارش در بیزد مبین کفايت مدل سری زمانی بوده است [۱۴]. در تحقیقی برای توسعه مدل‌های پیش‌بینی خشکسالی از متغیرهای اقلیمی دور پیوندی با شاخص‌های خشکسالی هواشناسی و روش ماشین بردار پشتیبان استفاده شد. نتایج حاکی از این بود که تلفیق داده‌ها در قالب روش مورد استفاده موجب بهبود پیش‌بینی جریان شده است [۱۱]. همچنین در تحقیق بیان شده مدل میانگین متحرک اتورگرسیو توانایی خوبی در پیش‌بینی خشکسالی دارد و استفاده از آن برای محققین توصیه شده است [۲۵]. در تحقیقی قابلیت شبکه‌های عصبی مصنوعی در ساختارهای متفاوت در پیش‌بینی خشکسالی هواشناسی در شرق استرالیا بررسی شد. در این تحقیق شاخص استاندارد بارش و شاخص تبخیر تعریف پتا سیل به عنوان تابع هدف و از پارامترهای آب و هوایی محلی و شاخص‌های اقلیمی بزرگ‌مقیاس و دور پیوندی به عنوان ورودی یا تخمین‌گر استفاده شد. نتایج مبین پتانسیل خوب شبکه‌های عصبی مصنوعی برای پیش‌بینی شاخص خشکسالی مورد استفاده و مؤلفه‌های خشکسالی بود [۷]. از قابلیت شبیه‌سازی شبکه‌های عصبی مصنوعی برای پیش‌بینی شاخص استاندارد بارش بهاره در پرتفال با استفاده از شاخص‌های دور پیوندی زمستانه (نوسانات اقیانوس اطلس شمالی و دمای سطح دریا) استفاده شد. نتایج نشان داد که شاخص نوسانات اطلس شمالی تخمین‌گر مناسبی برای پیش‌بینی خشکسالی بهاره در

روش آزمون توالی استفاده شد. لازم به ذکر است در ایستگاههای منتخب دوره آماری کامل و نیاز به باز سازی آماری نبوده است.

مورد استفاده شامل دمای حداکثر، دمای حداقل، دمای حداکثر مطلق، دمای حداقل مطلق، متوسط دمای ماهانه و تبخیر ماهانه می‌باشد. جهت کنترل همگنی داده‌ها از



شکل ۱. نقشه موقعیت دشت مورد مطالعه در کشور و موقعیت ایستگاههای منتخب

جدول ۱. مشخصات ایستگاههای مورد مطالعه

| عرض جغرافیایی | طول جغرافیایی | نام ایستگاه | نوع ایستگاه |
|---------------|---------------|-------------|-------------------|
| ۳۵ ۴۹ | ۴۹ ۴۵ | دانسفهان | دماسجی-تبخیر سنجی |
| ۳۵ ۵۲ | ۴۹ ۳۲ | دانسفهان | بارانسجی |

گیرند. بدین ترتیب از این شاخص برای مقیاس‌های زمانی ۳، ۶، ۱۲ و ۲۴ ماهه استفاده می‌نمایند. به عبارت دیگر *SPI* عبارت است از مقداری از تابع توزیع نرمال استاندارد که احتمال تجمعی آن با احتمال تجمعی متغیر بارندگی از تابع توزیع معین مساوی باشد [۲۶]. در جدول (۲) طبقات شدت خشک‌سالی برای این شاخص آورده شده است.

مراحل اجمالی محاسبه شاخص *SPI*، به ترتیب زیر است:

- تشکیل سری‌های زمانی بارندگی در مقیاس زمانی i ماهه ($i = 1, 4, 6, \dots, 12, \dots, 24$).
- برآش توزیع آماری گاما بر سری‌های بارندگی حاصل از مرحله قبل و محاسبه احتمالات تجمعی توزیع گاما.

۲.۲. شاخص بارندگی استانداردشده (*SPI*)

شاخص بارندگی استاندارد^۱ (*SPI*)، نخستین بار توسط مک‌کی^۲، برای پایش خشکسالی در ایالت کلرادو ارائه شد. *SPI* صرفاً از داده‌های بارندگی ماهانه استفاده نموده و برای تشخیص کمبود میزان بارندگی در مقیاس‌های زمانی چندگانه طراحی شده است. این مقیاس‌های زمانی منعکس کننده اثرات ویژه خشکسالی بر روی قابلیت دسترسی به منابع آبی مختلف می‌باشد. به طوری که شرایط رطوبتی خاک نسبت به ناهنجاری‌های نسبتاً کوتاه‌مدت بارندگی واکنش نشان می‌دهد؛ در حالی که آب‌های زیرزمینی، جریان آب رودخانه و ذخیره مخازن تحت تأثیر ناهنجاری‌های بلند‌مدت بارندگی قرار می‌

^۱ McKee

^۲ Standardized Precipitation Index

احتمال گاما برای هر ایستگاه و در هر مقیاس زمانی (۳، ۶، ۱۲، ۲۴، ۴۸، ۵۴ ماه و غیره) و برای هر ماه از سال طی دوره آماری ۲۷ ساله (۱۳۶۳-۱۳۹۰).)

- محاسبه‌ی SPI شامل برآش تابع چگالی احتمال گاما بر توزیع فراوانی بارندگی کل برای یک ایستگاه معین.
- برآورد پارامترهای α و β مربوط به تابع چگالی

جدول ۲- طبقات شدت خشکسالی بر اساس SPI (به نقل از [22])

| SPI | مقادیر | طبقه خشکسالی |
|-----------|----------|--------------------|
| >۲ | | کاملاً مرطوب |
| ۱/۹۹-۱/۵ | | خوبی مرطوب |
| ۱/۴۹-۱ | | نسبتاً مرطوب |
| ۰/۹۹-۰ | | مرطوب ملایم |
| -۰/۹۹-۰ | | خشکسالی ملایم |
| -۱/۴۹-۱ | تا -۱/۴۹ | خشکسالی متوسط |
| -۱/۹۹-۱/۵ | تا -۱/۹۹ | خشکسالی شدید |
| <۲ | | خشکسالی بسیار شدید |

عددی بین ۰/۱ و ۰/۹ قرار گرفتند که در نهایت مقادیر خروجی به دست آمده از شبکه نیز با معکوس نمودن رابطه مذکور به حالت اولیه برگردانده شدند.

$$y = 0.8 \left(\frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right) + 1 \quad (1)$$

در این رابطه، x_{\min} کو چکترین داده و x_{\max} بزرگ‌ترین داده سری می‌باشد.

پس از این مرحله داده‌ها به سه دسته آموزشی، صحت‌سننجی و تست تقسیم شدند به طوری که با توجه به طول دوره آماری منتخب و اهمیت مرحله آموزش یا کالیبراسیون مدل، نسبت داده‌های آموزش، صحت‌سننجی و تست به ترتیب ۰/۱۵، ۰/۱۵ و ۰/۷۵ در نظر گرفته شد.

تحقیقات نشان می‌دهد که شبکه‌های عصبی مصنوعی با یک لایه مخفی با توابع تبدیل زیگموئیدی در لایه میانی قادر به تقریب کلیه توابع غیرخطی با هر درجه تقریبی است، مشروط به آنکه به اندازه کافی نرون در لایه مخفی داشته باشیم. تعداد لایه‌ها و نرون‌های یک شبکه در قالب معماری شبکه تعیین می‌گردد. همچنین

۲.۰.۳ شبکه عصبی مصنوعی

ایدها اصلی شبکه‌های عصبی مصنوعی بر مبنای شبیه‌سازی شبکه عصبی انسان است. مهم‌ترین عنصر پردازش در سیستم‌های زیستی نرون است که در واقع یک واحد ریاضی یا یک دستگاه غیر خطی است، که از ترکیب آن‌ها یک شبکه تشکیل شده و هر شبکه می‌تواند از یک یا چند لایه به این صورت تشکیل شود [۲۱، ۲۴]. بر اساس ترکیب مختلف نرون‌ها و قوانین مختلف یادگیری؛ شبکه‌های مختلفی تشکیل می‌شود که یکی از کاربردی‌ترین آنها در علوم مهندسی برای نگاشت غیرخطی، شبکه‌های پرسپترون چندلایه می‌باشد [۲۷]. عماری شبکه عصبی معمولاً از سه لایه ورودی (لایه‌ای که داده‌ها را وارد شبکه می‌کند)، پنهان (لایه‌ای که داده‌ها را پردازش می‌کند) و خروجی (نتایج را به ازای ورودی‌های مشخص استخراج می‌کند) تشکیل شده است. نرمالیزه نمودن داده‌ها از جمله اقداماتی است که قبل از ورود داده‌ها به شبکه انجام می‌گیرد. چرا که وارد نمودن داده‌ها به صورت خام سبب کاهش سرعت و دقت شبکه خواهد شد. بدین منظور داده‌ها با استفاده از رابطه (۱) در دامنه

مشاهداتی، pre و \bar{pre} نیز به ترتیب زماد مقادیر پیش‌بینی شده و میانگین مقادیر پیش‌بینی شده می‌باشند.

۲.۵. تعیین متغیرهای ورودی با روش همبستگی مقاطعه^۵

همبستگی مقاطعه نوعی روش استاندارد برای تعیین درجه همبستگی بین دو سری زمانی است. چنانچه مقدار R و $x_{(i)}$ و $y_{(i)}$ با $i=0,1,2,\dots,N-1$ دو متغیر باشند مقدار همبستگی مقاطعه آنها به شکل رابطه (۵) است.

$$\left\{ \begin{array}{l} \text{For: } 0, \pm 1, \pm 2, \dots \\ \text{If: } i - d < 0, \quad i - d \geq N \end{array} \right. \quad (5)$$

$$CCF = \frac{\sum_{i=1}^n (x_{(i)} - \bar{x})(y_{(i-d)} - \bar{y})}{\sqrt{\sum_{i=1}^n ((x_{(i)} - \bar{x})^2)} \sqrt{\sum_{i=1}^n (y_{(i-d)} - \bar{y})^2}}$$

در این رابطه مقادیر \bar{x} و \bar{y} مقدار میانگین هر یک از سری‌های زمانی $x_{(i)}$ و $y_{(i)}$ هستند، اگر رابطه (۵) را برای همه تأخیرهای زمانی مشخص $d=0, \pm 1, \pm 2, \dots, N-1$ محاسبه کنیم، در یکی از گام‌های تأخیر بالاترین همبستگی را خواهیم داشت.

با توجه به شرط در رابطه (۵)، نقاط $i < 0$ و $i \geq N$ مورد توجه نبوده و مقدار ضریب همبستگی مقاطعه همواره $-1 \leq R \leq +1$ خواهد بود. در این تحقیق همبستگی مقاطعه بین مقادیر شاخص بارش استاندارد شده در سه مقیاس زمانی با پارامترهای هواشناسی و سیگنال‌های اقلیمی مورد بررسی قرار گرفت.

۲.۶. متغیرهای ورودی به مدل

raigترین الگوریتم آموزش، الگوریتم پسانشوار خطا است که طبق گزارشات، ۹۰٪ تجارت انجام شده در این زمینه با شبکه‌های پیش‌خور چندلازه با الگوریتم پسانشوار خطا صورت می‌گیرد [۲۲]. لذا در این تحقیق از الگوریتم پسانشوار خطا و تعداد نرون‌های لایه پنهان از ۲ تا ۱۴ نرون مورد آزمون قرار گرفت. سپس در مرحله صحتسنجی، مدل به وسیله داده‌هایی که در مرحله آموزش شرکت نداشته‌اند اجرا شد. در این تحقیق به دلیل جامعیت و سهولت کاربردی از جعبه ابزار شبکه عصبی مصنوعی در نرم‌افزار مطلب استفاده شد.

۲.۴. معیارهای ارزیابی خطای شبکه

در این تحقیق جهت تعیین بهترین ساختار مدل و مقایسه آن درجهت انتخاب بهترین روش و ساختار، از معیارهای ضریب همبستگی^۶ (R^2)، جذر میانگین مربعات خطای^۷ و میانگین قدر مطلق خطای^۸ استفاده شد که به صورت روابط (۲)، (۳) و (۴) آورده شده است.

$$R^2 = \frac{\sum_{i=1}^n (obs - \bar{obs})(pre - \bar{pre})}{\sqrt{\sum_{i=1}^n (obs - \bar{obs})^2 \sum_{i=1}^n (pre - \bar{pre})^2}} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (obs - pre)^2}{n}} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |obs - pre|}{n} \quad (4)$$

در روابط بالا n تعداد کل داده‌ها، obs و \bar{obs} ترکیب زماد مقادیر مشاهداتی و میانگین مقادیر

^۶ Root Mean Square Error(RMSE)

^۷ Mean Absolute Error(MAE)

^۸ Cross Correlation Function

^۱ Back Propagation

^۲ Correlation Coefficient(R^2)

نوسانات جنوبی (MEI) از شش متغیر آب و هوایی در منطقه حاره‌ای اقیانوس آرام محسّبه می‌گردد. مد نصف‌النهاری اطلس^۱ (AMM) تغییرات ناهمگن دمای سطح دریا در جهت نصف‌النهاری است و بیانگر تغییرات نصف‌النهاری در نواحی حاره‌ای اقیانوس اطلس می‌باشد. نوسانات دهه‌ای اقیانوس اطلس (AMO) مبتنی بر مدهای متفاوت در مقیاس‌های زمانی دهه‌ای اقیانوس اطلس است که دمای سطح دریا در قسمت شمالی اقیانوس اطلس را مؤثر می‌سازد.

در این تحقیق، متغیرهای ورودی به این مدل شامل پارامترهای هواشناسی و سیگنال‌های اقلیمی می‌باشد که در جدول (۳) آورده شده است. نوسان دهه‌ای اقیانوس آرام (PDO) یک پدیده اقلیمی است که با پایداری الگوهای اقلیمی دو فازی در اقیانوس آرام شمالی همراه است و با دوره‌های زمانی از مرتبه ۵۰ سال نوسان می‌کند. شاخص نوسانات جنوبی (SOI) شاخص استانداردشده فشار سطح دریا است که از اختلاف فشار بین منطقه تاهیتی و داروین استرالیا به دست می‌آید. شاخص چندمتغیرهای النینو-

جدول ۳. متغیرهای ورودی مورد استفاده

| پارامترهای هواشناسی | سیگنال اقلیمی |
|---------------------|---------------|
| بارندگی | PDO |
| دماهی حداقل مطلق | SOI |
| دماهی حداقل مطلق | MEI |
| میانگین دما | AMM |
| دماهی حداقل | AMO |
| دماهی حداقل | |
| تبخیر و تعرق | |

$$\{(x_i, y_i), 1 \leq i \leq M\} \quad (6)$$

در این رابطه x بردار مشاهداتی ورودی بوده که در این تحقیق شامل پارامترهای هواشناسی و سیگنال‌های اقلیمی است و y نیز بردار خروجی مشاهداتی بوده که شامل مقادیر شاخص بارش استاندارد شده در سه مقیاس زمانی می‌باشد. چنانچه رابطه (۷) بین ورودی و خروجی برقرار باشد، متغیر تصادفی^۲ نشان‌دهنده خطای می‌باشد و انجام این آزمون در واقع تخمینی برای واریانس خروجی مدلی غیرهموار^۳ می‌باشد.

$$Y=f(x)+r \quad (7)$$

این آزمون بر اساس $N[i,k]$ که شامل لیستی از

۲.۰.۷ استفاده از آزمون گاما جهت تعیین ترکیب

بهینه‌متغیرهای ورودی به مدل

یکی از مراحل مهم در مدل‌سازی جهت پیش‌بینی، تعیین ترکیب بهینه‌متغیرهای ورودی می‌باشد. از بین روش‌های مختلف، آزمون گاما یک روش غیرمتغیری است که ابزاری مناسب برای یافتن بهترین ترکیب از متغیرهای ورودی به مدل غیرخطی به شمار رفته و مقدار میانگین مربعات خطای مدل را پیش از استفاده محاسبه و ترکیب بهینه‌متغیرهای ورودی را شناسایی می‌کند [۳۴].

فرض می‌کنیم مجموعه داده‌های مشاهداتی به صورت رابطه (۶) می‌باشد:

^۱ Atlantic Meridional Mode (AMM)

^۲ Smooth function

۳. نتایج

در این تحقیق برای پیش‌بینی خشکسالی هواشناسی از شاخص SPI در ایستگاه دانسفهان در سه مقیاس زمانی کوتاه مدت (۳ ماهه)، میان مدت (۹ ماهه) و بلند مدت (۲۴ ماهه)، طی سال‌های ۱۳۹۰-۱۳۶۳ استفاده شد. بدین منظور از شبکه عصبی پرسپترون چندلایه با یک لایه مخفی با تابع سیگموئید در لایه میانی و تابع خطی در لایه خروجی استفاده و تعداد نمونهای لایه میانی به روش آزمون و خطا از ۲ تا ۱۴ نمونه آزمون قرار گرفت. همچنین تعداد داده‌های آموزش، ۷۰ درصد کل داده‌ها و تعداد داده‌های اعتبارسنجی و تست نیز هر کدام ۱۵ درصد کل داده‌ها را تشکیل دادند.

۳.۱. نتایج حاصل از تابع همبستگی متقطع (CCF)

برای انتخاب بهترین متغیرهای پیش‌بینی کننده

برای انتخاب متغیرهای بهینه ابتدا از همبستگی متقطع استفاده گردید. جدول ۴، نتایج همبستگی متقطع شاخص SPI را با سیگنال‌های بزرگ مقیاس اقلیمی از قبیل AMO AMM MEI SOI و PDO و همچنین پارامترهای هواشناسی از قبیل بارندگی، تبخیر و تعرق، حداقل دما، حداکثر دما، حداقل دمای مطلق، حداکثر دمای مطلق و میانگین دما را در گام‌های زمانی مشخص و در سطح معنی‌داری ۵ درصد نشان می‌دهد.

در مقیاس زمانی کوتاه مدت، سیگنال‌های PDO و AMM با SPI3 در هیچ تأخیری (تا ۱۲ ماه) دارای همبستگی معنی‌دار نبوده و بیشترین همبستگی ابتدا با شاخص SOI با ۹ گام تأخیر ($R=-0.207$) و بعد از آن به ترتیب با شاخص‌های AMO (AM) ($R=0.118$) و MEI ($R=0.164$) در گام تأخیر ۶ می‌باشد. برای جداکثر دمای مطلق $0/13$ ، حداقل دمای مطلق $0/14$ ، میانگین دما $0/11$ ، جداکثر دما $0/1$ و حداقل دما $0/12$ همگی در گام تأخیر ۱۰ محاسبه شده است. همچنین برای بارندگی

$x_i(1 \leq i \leq M)$ امین همسایگی برای هر بردار (۸) تابع δ میانگین مجدد فاصله کامین همسایگی را محاسبه می‌کند که در آن $| \cdot |$ نشان‌دهنده فاصله اقلیدسی^۱ بوده و تابع گاما متناظر آن طبق رابطه (۹) است که در آن $y_{N[i,k]}$ مقدار y متناظر با کامین همسایگی در x_i است.

$$\delta_M^{(k)} = \frac{1}{M} \sum_{i=1}^M \left| X_{N[i,k]} - X_i \right|^2 \quad (8)$$

$$\gamma_M^{(k)} = \frac{1}{2M} \sum_{i=1}^M \left| X_{N[i,k]} - Y_i \right|^2 \quad (9)$$

همچنین یک خط رگرسیون خطی از p نقطه بر مقادیر (k) و $\delta_m(k)$ جهت محاسبه Γ برازش داده می‌شود. طبق رابطه (۱۰) عرض از مبدأ خط $= 0$ ، مقدار Γ را نشان می‌دهد و $\gamma_M(k)$ نیز واریانس خطاهای می‌باشد.

$$\gamma = A\delta + \Gamma \quad (10)$$

لازم به ذکر است این آزمون در محیط نرم‌افزاری Wingamma انجام گرفت که در آن در هر بار یک متغیر از ترکیب ورودی حذف گردیده و مقادیر گاما نسبت به حالتی که همه متغیرها حضور داشتند، بررسی شد. به طوری که چنانچه با حذف یک پارامتر ورودی مقدار گاما افزایش یافت، یعنی آن پارامتر اثر مثبتی در مدل‌سازی دارد و بهتر است در ترکیب ورودی باشد و هرگاه مقدار گاما کم باشد یعنی اثر پارامتر کم شده؛ منفی بوده و باید از ترکیب ورودی حذف گردد. همچنین هر چه مقدار زیاد و یا کم شدن مقدار گاما بیشتر باشد اثر مثبت و یا منفی پارامتر بیشتر است.

^۱ Euclidean distance

ضعیف با شاخص SPI می‌باشند. در این مقیاس زمانی نیز همچنان دو پارامتر بارندگی و حداقل دمای مطلق دارای بیشترین همبستگی می‌باشند. در مقیاس زمانی بلند مدت نیز اعداد همبستگی در مورد سیگنال‌های اقلیمی افزایش یافته و بیشترین تأثیر در دو شاخص PDO و MEI بوده و در مورد پارامترهای هواشناسی نیز همچنان بارندگی و حداقل دمای مطلق و حداقل دما دارای بیشترین همبستگی می‌باشند.

۰/۴۹ بوده (در گام تأخیر ۲) که با توجه به ماهیت شاخص خشکسالی مدنظر طبیعی است. همچنانی بیشترین تأثیر پارامترهای هواشناسی ابتدا بارندگی با ۲ گام تأخیر و سپس حداقل دمای مطلق با ۱۰ گام تأخیر می‌باشد. این بدان معنی است تأثیر پدیده بارندگی نسبت به دما بر بروز خشکسالی در مقیاس زمانی کوتاه مدت بسیار سریع‌تر می‌باشد. در مقیاس زمانی میان‌مدت، سیگنال‌های اقلیمی AMO و MEI به نوعی دارای همبستگی

جدول ۴. همبستگی متقاطع بین سری زمانی مقادیر SPI ۲۴ ماهه و سیگنال‌های اقلیمی و پارامترهای هواشناسی

| متغیرها | SPI3 | | | SPI9 | | | SPI24 | | |
|-------------------|------------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | ضریب همبستگی | ضریب همبستگی | ضریب همبستگی | ضریب همبستگی | ضریب همبستگی | ضریب همبستگی | ضریب همبستگی | ضریب همبستگی | ضریب همبستگی |
| سیگنال‌های اقلیمی | PDO | * | * | * | -۰/۰۹ | ۹ | ۰/۰۵ | ۰/۲۱ | * |
| | SOI | -۰/۲۱ | ۹ | <۰/۰۰۱ | -۰/۲ | ۱۱ | * | -۰/۲۴ | ۱۱ |
| | AMM | * | * | * | -۰/۱ | ۶ | ۰/۰۴ | ۰/۱ | * |
| | AMO | ۰/۱۲ | * | ۰/۰۲ | ۰/۱۳ | ۲ | ۰/۰۱ | ۰/۱۶ | * |
| | MEI | ۰/۱۶ | ۶ | * | ۰/۱۴ | ۱۰ | ۰/۰۱ | ۰/۲۷ | ۹ |
| متغیرهای هواشناسی | بارندگی | ۰/۴۹ | ۲ | <۰/۰۰۱ | ۰/۳۳ | ۷ | <۰/۰۰۱ | ۰/۲۵ | ۳ |
| | حداکثر دمای مطلق | ۰/۱۳ | ۱۰ | ۰/۰۱ | ۰/۰۹ | ۴ | ۰/۰۶ | ۰/۱ | ۸ |
| | حداقل دمای مطلق | ۰/۱۴ | ۱۰ | ۰/۰۱ | ۰/۱۱ | ۴ | ۰/۰۳ | ۰/۱۲ | ۷ |
| | میانگین دما | ۰/۱۱ | ۱۰ | ۰/۰۲ | -۰/۰۹ | * | ۰/۰۵ | ۰/۱ | ۷ |
| | حداکثر دما | ۰/۱ | ۱۰ | ۰/۰۳ | -۰/۱ | * | ۰/۰۴ | -۰/۱ | ۱ |
| | حداقل دما | ۰/۱۲ | ۱۰ | ۰/۰۱ | ۰/۰۹ | ۴ | ۰/۰۵ | ۰/۱۲ | ۷ |
| | تبخیر تعرق | * | * | * | * | * | * | ۰/۱۱ | ۹ |

ورودی تنها شامل شاخص SPI با تأخیرهای ۱، ۲، ۳، ۴، ۵، ۱۰، ۱۱ و ۱۲ می‌باشد. در ساختار سوم (MET-IND^۳) نیز عوامل ورودی شامل پارامترهای هواشناسی و SPI با تأخیرهای مشخص می‌باشد. جدول (۵)، عوامل ورودی برای سه ساختار مذکور را نشان می‌دهد.

جدوال ۶، ۷ و ۸ نتایج آزمون گاما برای سه ساختار مورد بررسی را نشان می‌دهد. در این جداول D، PRE و

۳.۰.۲. نتایج استفاده از انواع ساختارهای ورودی به شبکه عصبی مصنوعی

در این تحقیق پس از مشخص شدن ترکیب‌های بهینه با آزمون گاما، سه ساختار ورودی به شبکه عصبی مصنوعی از ترکیبات ممکن تعیین گردید. در ساختار اول (SIG-IND^۱) علاوه بر SPI با تأخیر مشخص، از سیگنال‌های اقلیمی شامل MEI، AMM، SOI و AMO نیز استفاده می‌شود. در ساختار دوم (IND^۲) عوامل PDO

^۱ METEORLOGICAL & INDEX

^۲ SIGNAL & INDEX

^۳ INDEX

۱۲ مقادیر گاما افزایش یافته است به طوری که ورودی شاخص با ۱۲ گام تأخیر بیشترین تأثیر را در مدلسازی دارد می باشد. در سناریوی دوم بیشترین تأثیر مدلسازی متعلق به ورودی های شاخص با ۱ و ۱۲ گام زمانی تأخیر می باشد. در سناریوی سوم هم حذف شاخص و هم حذف پارامترهای اقلیمی سبب افزایش مقادیر گاما شده است و بیشترین تأثیر متغیر ورودی مربوط به شاخص با یک گام تأخیر و دمای حداقل مطلق با ۴ گام تأخیر می باشد.

جدول ۵. ترکیب ساختارهای ورودی برای ورود به شبکه عصبی مصنوعی در سه مقیاس زمانی SPI

| ساختار | ترکیب |
|------------------------|---------------------------------------------------------------------------|
| - ساختار اول (SIG-IND) | شاخص SPI با تأخیرهای ۱، ۲، ۳، ۴، ۵، ۱۰، ۱۱ و ۱۲ + سیگنال های اقلیمی |
| - ساختار دوم (IND) | شاخص SPI با تأخیرهای ۱، ۲، ۳، ۴، ۵، ۱۰، ۱۱ و ۱۲ |
| - ساختار سوم (MET-IND) | شاخص SPI با تأخیرهای ۱، ۲، ۳، ۴، ۵، ۱۰، ۱۱، ۱۲ و ۱۳ + پارامترهای هواشناسی |

مؤثرترین ورودی ها می باشد. در سناریوی سوم نیز مؤثرترین پارامتر مربوط به SPI با تأخیر ۱ ماهه و از میان پارامترهای هواشناسی مربوط به حداقل دمای مطلق با ۷ گام تأخیر می باشد.

EVA به ترتیب نماد بارندگی، دبی و تبخیر تعرق و Abs_Tmin و Abs_Tma به ترتیب حداقل و حداقل دمای مطلق و Tmin، Tmean، Tmax نیز به ترتیب حداقل، میانگین و حداقل دما می باشند.

در SPI9 مشاهده می شود که در سناریوی اول، تمامی متغیرهای ورودی بجز مقادیر SPI9 با ۲، ۳ و ۴ گام تأخیر اثر مثبتی در مدلسازی دارد. همچنین مشاهده می شود که با افزایش گام زمانی تأخیر در شاخص ۹ از ۵ به

در SPI24 نیز در سناریوی اول، SPI با تأخیر ۱۲ ماهه و از میان سیگنال های اقلیمی AMO و AMM در زمان t ورودی های با بیشترین تأثیرگذاری بر مدلسازی می باشند. در سناریوی دوم تنها SPI با تأخیرهای ۱۱ و ۱۲

جدول ۶. نتایج آزمون گاما برای SPI ۳، ۹ و ۲۴ ماهه، در ساختار شماره یک (شاخص به همراه سیگنال های اقلیمی)

| شماره ترکیب | SPI3 | | SPI9 | | SPI24 | |
|-------------|------------------------|------------|------------------------|------------|-------------------------|------------|
| | پارامتر حذفی | مقدار گاما | پارامتر حذفی | مقدار گاما | پارامتر حذفی | مقدار گاما |
| ۱ | - | .۰۰۱۰۹۵۸ | - | .۰۰۰۱۳۹۵ | - | .۰۰۰۱۵۷۱ |
| ۲ | SPI3 _(t-1) | .۰۰۱۱۵۸۸ | SPI9 _(t-1) | .۰۰۰۲۳۳۹ | SPI24 _(t-1) | .۰۰۰۱۹۱۱ |
| ۳ | SPI3 _(t-2) | .۰۰۰۸۲۸۱ | SPI9 _(t-2) | .۰۰۰۰۵۴۹ | SPI24 _(t-2) | .۰۰۰۲۰۹۸ |
| ۴ | SPI3 _(t-3) | .۰۰۰۹۵۰۱ | SPI9 _(t-3) | .۰۰۰۱۰۹۵ | SPI24 _(t-3) | .۰۰۰۱۲۵۵ |
| ۵ | SPI3 _(t-4) | .۰۰۱۰۸۹۸ | SPI9 _(t-4) | .۰۰۰۱۲۸۸ | SPI24 _(t-4) | .۰۰۰۱۲۱۱ |
| ۶ | SPI3 _(t-5) | .۰۰۰۹۶۸۳ | SPI9 _(t-5) | .۰۰۰۱۴۱۷ | SPI24 _(t-5) | .۰۰۰۱۴۵۸ |
| ۷ | SPI3 _(t-10) | .۰۰۰۸۶۷۲ | SPI9 _(t-10) | .۰۰۰۳۰۱۵ | SPI24 _(t-10) | .۰۰۰۱۳۲۴ |
| ۸ | SPI3 _(t-11) | .۰۰۰۸۹۲۵ | SPI9 _(t-11) | .۰۰۰۲۷۳۴ | SPI24 _(t-11) | .۰۰۰۲۱۸۷ |
| ۹ | SPI3 _(t-12) | .۰۰۰۸۷۱۲ | SPI9 _(t-12) | .۰۰۰۳۲۱۸ | SPI24 _(t-12) | .۰۰۰۳۴۵۷ |
| ۱۰ | SOI _(t-9) | .۰۰۱۰۳۵۵ | PDO _(t-9) | .۰۰۰۱۷۵۱ | PDO _(t) | .۰۰۰۰۹۹۷ |
| ۱۱ | AMO _(t) | .۰۰۰۹۶۶۸ | SOI _(t-11) | .۰۰۰۲۱۹ | SOI _(t-11) | .۰۰۰۱۴۴۵ |
| ۱۲ | | | AMM _(t-6) | .۰۰۰۲۵۳۱ | AMM _(t) | .۰۰۰۱۷۵۷ |

| | | | | | |
|----|--|-----------------------|-----------|----------------------|-----------|
| ۱۳ | | AMO _(t-2) | ۰/۰۰ ۲۲۶۸ | AMO _(t) | ۰/۰۰ ۱۷۵۷ |
| ۱۴ | | MEI _(t-10) | ۰/۰۰ ۱۴۳۸ | MEI _(t-9) | ۰/۰۰ ۱۶۸۶ |

Archive of SID

جدول ۷. نتایج آزمون گاما برای SPI ۳، ۹ و ۲۴ ماهه در ساختار شماره دو (شاخص

| شماره ترکیب | SPI3 | | SPI9 | | SPI24 | |
|-------------|------------------------|------------|------------------------|------------|-------------------------|------------|
| | پارامتر حذفی | مقدار گاما | پارامتر حذفی | مقدار گاما | پارامتر حذفی | مقدار گاما |
| ۱ | - | ۰/۰۰۹۴۵۵ | - | ۰/۰۰۴۴۴۹ | - | ۰/۰۰۳۰۳ |
| ۲ | SPI3 _(t-1) | ۰/۰۱۴۵۴۱ | SPI9 _(t-1) | ۰/۰۰۵۳۹۳ | SPI24 _(t-1) | ۰/۰۰۲۸۴ |
| ۳ | SPI3 _(t-2) | ۰/۰۱۰۶۳۳ | SPI9 _(t-2) | ۰/۰۰۴۱۴۶ | SPI24 _(t-2) | ۰/۰۰۲۴۷۶ |
| ۴ | SPI3 _(t-3) | ۰/۰۱۱۱۸۶ | SPI9 _(t-3) | ۰/۰۰۳۲۸۴ | SPI24 _(t-3) | ۰/۰۰۱۶۵۱ |
| ۵ | SPI3 _(t-4) | ۰/۰۱۰۵۸۲ | SPI9 _(t-4) | ۰/۰۰۳۲۲۷ | SPI24 _(t-4) | ۰/۰۰۱۹۲۸ |
| ۶ | SPI3 _(t-5) | ۰/۰۱۰۸۰۸ | SPI9 _(t-5) | ۰/۰۰۳۷۱۲ | SPI24 _(t-5) | ۰/۰۰۲۲۰۴ |
| ۷ | SPI3 _(t-10) | ۰/۰۱۰۱۳۶ | SPI9 _(t-10) | ۰/۰۰۴۳۱۲ | SPI24 _(t-10) | ۰/۰۰۲۴۴۲ |
| ۸ | SPI3 _(t-11) | ۰/۰۰۷۲۶۸ | SPI9 _(t-11) | ۰/۰۰۴۱۴۹ | SPI24 _(t-11) | ۰/۰۰۳۱۲ |
| ۹ | SPI3 _(t-12) | ۰/۰۰۹۹۸ | SPI9 _(t-12) | ۰/۰۰۵۶۵۹ | SPI24 _(t-12) | ۰/۰۰۳۶۷۳ |

جدول ۸. نتایج آزمون گاما برای SPI ۳، ۹ و ۲۴ ماهه در ساختار شماره سه (شاخص به همراه پارامترهای اقلیمی)

| شماره ترکیب | SPI3 | | SPI9 | | SPI24 | |
|-------------|----------------------------|------------|---------------------------|------------|---------------------------|------------|
| | پارامتر حذفی | مقدار گاما | پارامتر حذفی | مقدار گاما | پارامتر حذفی | مقدار گاما |
| ۱ | - | ۰/۰۰۸۲۹۱ | - | ۰/۰۰۳۲۳۴ | - | ۰/۰۰۱۱۹۹ |
| ۲ | SPI3 _(t-1) | ۰/۰۱۲۸۴۳ | SPI9 _(t-1) | ۰/۰۰۵۹۲۴ | SPI24 _(t-1) | ۰/۰۰۳۳۱۵ |
| ۳ | SPI3 _(t-2) | ۰/۰۰۷۲۵۷ | SPI9 _(t-2) | ۰/۰۰۲۹۷۵ | SPI24 _(t-2) | ۰/۰۰۱۲۰۹ |
| ۴ | SPI3 _(t-3) | ۰/۰۰۷۸۲۵ | SPI9 _(t-3) | ۰/۰۰۳۳۲۵ | SPI24 _(t-3) | ۰/۰۰۱۶۱۱ |
| ۵ | SPI3 _(t-4) | ۰/۰۰۷۴۸۹ | SPI9 _(t-4) | ۰/۰۰۳۰۴۳ | SPI24 _(t-4) | ۰/۰۰۱۳۶۱ |
| ۶ | SPI3 _(t-5) | ۰/۰۰۷۸۰۱ | SPI9 _(t-5) | ۰/۰۰۴۲۱۳ | SPI24 _(t-5) | ۰/۰۰۱۳۱۴ |
| ۷ | SPI3 _(t-10) | ۰/۰۰۹۴۲۲ | SPI9 _(t-10) | ۰/۰۰۲۵۵۱ | SPI24 _(t-10) | ۰/۰۰۱۷۵۷ |
| ۸ | SPI3 _(t-11) | ۰/۰۰۸۸۶۲ | SPI9 _(t-11) | ۰/۰۰۳۸۰۴ | SPI24 _(t-11) | ۰/۰۰۲۲۵۲ |
| ۹ | SPI3 _(t-12) | ۰/۰۰۷۸۰۷ | SPI9 _(t-12) | ۰/۰۰۲۸۵۳ | SPI24 _(t-12) | ۰/۰۰۲۱۲۴ |
| ۱۰ | MEI _(t-6) | ۰/۰۰۸۳۰۸ | PRE _(t-7) | ۰/۰۰۲۹۹۹ | PRE _(t-3) | ۰/۰۰۱۴۳۲ |
| ۱۱ | PRE _(t-2) | ۰/۰۰۹۶۴۹ | Abs_TMax _(t-4) | ۰/۰۰۳۵۹۸ | Abs_TMax _(t-7) | ۰/۰۰۱۰۵ |
| ۱۲ | Abs_Tmax _(t-10) | ۰/۰۰۸۴۱ | Abs_TMin _(t-4) | ۰/۰۰۴۴۲۹ | Abs_TMin _(t-7) | ۰/۰۰۱۶۷۴ |
| ۱۳ | Abs_Tmin _(t-10) | ۰/۰۰۸۳۵ | TMean _(t) | ۰/۰۰۳۸۱۳ | TMean _(t-7) | ۰/۰۰۱۴۵۴ |
| ۱۴ | Tmean _(t-10) | ۰/۰۰۷۶۷ | TMax _(t) | ۰/۰۰۴۰۶۹ | TMAX _(t-7) | ۰/۰۰۱۳۱۴ |
| ۱۵ | Tmax _(t-10) | ۰/۰۰۷۸۸۸ | TMIn _(t-4) | ۰/۰۰۴۱۹۹ | TMIN _(t-7) | ۰/۰۰۱۴۱۱ |
| ۱۶ | Tmin _(t-10) | ۰/۰۰۷۶۸۴ | | | | |

به دست آمده در هر ساختار به عنوان ورودی به مدل شبکه عصبی وارد و خروجی های SPI24 ماهه پیش بینی گردیدند.

با استفاده از نتایج به دست آمده در گام قبل، ترکیب بهینه نهایی حاصل از سه ساختار جهت ورود به شبکه عصبی مصنوعی به دست آمد (جدول ۹) سپس متغیرهای

جدول ۹. نتیجه نهایی ترکیب بهینه متغیرهای ورودی در سه سناریوی مورد مطالعه.

| عامل | نام سناریو | شماره سناریو | شاخص |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|--------------|-------|
| - | SIG-IND | اول | |
| SPI3 _(t-4) ، SPI3 _(t-3) ، SPI3 _(t-2) ، SPI3 _(t-1) ، SPI3 _(t-12) ، SPI3 _(t-5) ، SPI3 _(t-10) ، | IND | دوم | SPI3 |
| SPI3 _(t-1) ، SPI3 _(t-10) ، SPI3 _(t-11) ، MEI _(t-6) ، PRE _(t-2) ، Abs_Tmax _(t-10) ، Abs_Tmin _(t-10) | MET-IND | سوم | |
| SPI9 _(t-1) ، SPI9 _(t-5) ، SPI9 _(t-10) ، SPI9 _(t-11) ، SPI9 _(t-12) ، PDO _(t-9) ، SOI _(t-11) ، AMM _(t-6) ، AMO _(t-2) ، MEI _(t-10) | SIG-IND | اول | SPI9 |
| SPI9 _(t-1) ، SPI9 _(t-5) ، SPI9 _(t-11) ، Abs_TMax _(t-4) ، Abs_TMin _(t-4) ، TMean _(t) ، TMax _(t) ، TMin _(t-4) | MET-IND | سوم | |
| SPI24 _(t-1) ، SPI24 _(t-2) ، SPI24 _(t-11) ، SPI24 _(t-12) ، AMM _(t) ، AMO _(t) ، MEI _(t-9) | SIG-IND | اول | SPI24 |
| SPI24 _(t-11) ، SPI24 _(t-12) | IND | دوم | |
| SPI24 _(t-1) ، SPI24 _(t-2) ، SPI24 _(t-3) ، SPI24 _(t-4) ، SPI24 _(t-5) ، SPI24 _(t-10) ، SPI24 _(t-11) ، SPI24 _(t-12) ، PRE _(t-3) ، Abs_TMin _(t-7) ، TMean _(t-7) ، TMAX _(t-7) ، TMIN _(t-7) | MET-IND | سوم | |

آمده بهترین عملکرد مدل در ساختار اول، یعنی زمانی که از سیگنال‌های اقلیمی به عنوان پیش‌بینی کننده استفاده شد، می‌باشد.

در جدول (۱۰) نتایج معیارهای ارزیابی شبکه عصبی جهت پیش‌بینی خشکسالی هواشناسی در سه پنجره زمانی ۳، ۹ و ۲۴ ماهه، در سه ساختار معرفی شده با ترکیب بهینه؛ ارائه شده است که طبق نتایج به دست

جدول ۱۰. نتایج معیارهای ارزیابی شبکه برای پیش‌بینی SPI ۳، ۹ و ۲۴ ماهه در ترکیب‌های مختلف

| آموزش | R | RMSE | | MAE | | آرایش نمونه (خروجی-مخفي-ورودي) | ساختار | شاخص |
|-------|------|-------|------|-------|------|--------------------------------|--------|-------|
| | | آموزش | تست | آموزش | تست | | | |
| - | - | - | - | - | - | - | اول | |
| ۰/۷۵ | ۰/۶۴ | ۰/۶۵ | ۰/۷۳ | ۰/۵۱ | ۰/۵۸ | ۷-۶-۱ | دوم | SPI3 |
| ۰/۷۰ | ۰/۶۵ | ۰/۷۱ | ۰/۷۲ | ۰/۵۶ | ۰/۵۵ | ۷-۲-۱ | سوم | |
| ۰/۹۲ | ۰/۸۶ | ۰/۴۰ | ۰/۴۹ | ۰/۲۹ | ۰/۳۹ | ۱۰-۶-۱ | اول | SPI9 |
| ۰/۸۶ | ۰/۸۳ | ۰/۵۴ | ۰/۵۰ | ۰/۳۷ | ۰/۳۷ | ۲-۲-۱ | دوم | |
| ۰/۹۲ | ۰/۸۹ | ۰/۴۱ | ۰/۴۳ | ۰/۲۷ | ۰/۳۴ | ۹-۶-۱ | سوم | |
| ۰/۹۸ | ۰/۹۲ | ۰/۲۴ | ۰/۲۳ | ۰/۱۸ | ۰/۱۶ | ۷-۱۰-۱ | اول | SPI24 |
| ۰/۶۱ | ۰/۶۷ | ۰/۸۷ | ۰/۶۳ | ۰/۶۴ | ۰/۵۲ | ۲-۴-۱ | دوم | |
| ۰/۹۸ | ۰/۹۰ | ۰/۱۹ | ۰/۲۵ | ۰/۱۴ | ۰/۱۷ | ۱۳-۱۰-۱ | سوم | |

خشکسالی هواشناسی به عنوان نیروی محرکه دیگر خشکسالی‌ها و پیش‌بینی و مدلسازی آن، از جمله اقدامات اولیه و مهم مدیریتی در جهت شناخت و مهار این بحران به شمار می‌رود. همانطور که ذکر شد در این مطالعه جهت مدلسازی خشکسالی هواشناسی در سه مقیاس زمانی، سه

۴. بحث و نتیجه گیری

در سال‌های اخیر، عوامل بسیاری سبب افت شدید سطح آب زیرزمینی در سطح آبخوان‌های واقع در استان قزوین گردیده است که به تبع ادامه این روند سبب بروز شرایط بحرانی در آنها خواهد شد. لذا انجام مطالعات

به شمار روند. هرچند با توجه به نتایج به دست آمده این شاخص‌ها معنی‌دار هستند، اما میزان این همبستگی‌ها پایین است که می‌توان دلیل آن را تأثیرپذیری کمتر منطقه به خاطر فاصله جغرافیایی زیاد آن دانست که با نتایج محققین دارای هم‌خوانی می‌باشد [۳۶، ۳۰، ۲۳، ۹، ۱]. همچنین نتایج استفاده از متغیرهای هواشناسی نشان داد که علاوه بر بارندگی که به علت استفاده از آن در تعیین شاخص خشکسالی دارای همبستگی بالایی می‌باشد، متغیرهای دمای حداقل و دمای حداقل مطلق نیز با شاخص استفاده شده همبستگی دارند [۲۰]. در بین ساختارهای مورد استفاده در شبکه MLP با توجه به ورودی‌های مختلف، ساختار یک که حاوی سیگنال‌های اقلیمی و مقادیر SPI در گام‌های تأخیر مختلف بود نسبت به دو ساختار دیگر، بهترین عملکرد را در پیش‌بینی خشکسالی داشت، که با نتایج محققین مبنی بر بهبود عملکرد شبکه در استفاده از سیگنال‌های اقلیمی مطابقت دارد [۹، ۳، ۱].

در این تحقیق علاوه بر بررسی ارتباط بین سیگنال‌های اقلیمی با خشکسالی در دشت قزوین و معروفی قوی‌ترین پیش‌بینی کننده‌ها در خشکسالی، قابلیت شبکه عصبی مصنوعی پرسپترون چندلایه در سه ساختار یکی بازندگی به عنوان یک ورودی و ساختار دوم، بارندگی و سیگنال‌های اقلیمی و ساختار سوم بارندگی و پارامترهای اقلیمی در پیش‌بینی خشکسالی مورد ارزیابی قرار گرفت، که نتایج نشان‌دهنده تأثیرگذاری سیگنال‌های اقلیمی در بهبود عملکرد شبکه است. با توجه به اهمیت زیاد پیش‌آگاهی در زمینه بروز خشکسالی و یا ترسالی آتی در بحث مدیریت خشکسالی انجام مطالعات تکمیلی با سایر شاخص‌های خشکسالی و الگوهای دور پیوندی، مطالعات آتی محققان در این زمینه ضرورت می‌یابد.

ساختار از ترکیبات بهینه متغیرهای ورودی مورد بررسی قرار گرفت. به طور کلی در SPI9 علمکرد مدل شبکه نسبت به SPI3 بهتر می‌باشد و بهترین حالت پیش‌بینی در سناریوی سوم، یعنی حالتی که عوامل ورودی شامل شاخص و پارامترهای هواشناسی می‌باشد، مشاهده شد. (MAE=0.34 و RMSE=0.43, R=0.89).

در این تحقیق از میان شاخص‌های اقلیمی در طول دوره آماری (۱۳۹۱-۱۳۶۱) روابط معنی‌داری بین شاخص‌های اقلیمی AMO, AMM, PDO, SOI و MEI با نمایه استانداردشده باران (SPI) در مقیاس زمانی مورد مطالعه وجود دارد. بین SOI با نمایه SPI رابطه معکوس و بین سایر شاخص‌ها رابطه مستقیم وجود دارد.

در بین پنج شاخص، شاخص‌های SOI و MEI بالاترین ضریب همبستگی و بهترین روند برای ورود به مدل و پیش‌بینی را داشته‌اند. نتایج تحقیقات محققین نیز مؤید این مطلب بود [۳۰، ۳، ۳۲]. به طوری که آنها مؤثرترین شاخص‌ها بر منطقه را SOI, MEI و PDO معرفی نمودند. همچنین شاخص SOI بر بارش پاییزه حوزه آبخیز ارومیه دارای بیشترین تأثیر می‌باشد [۳۵، ۱۰، ۳۴]. همچنین نتایج این تحقیق مبنی بر ضریب بالا و معکوس بین مقادیر AMO و AMM بر بارندگی در منطقه مورد مطالعه است که طبق نتایج محققین نیز شاخص AMO و AMM (نوسانات اقیانوس اطلس) به عنوان بهترین پیش‌بینی کننده‌ها در کشور معرفی گردیده است [۱۳، ۳، ۱]. نتایج این تحقیق به طور کلی نشان داد که با افزایش مقیاس زمانی از کوتاه مدت به بلند مدت، تأثیر سیگنال‌های اقلیمی افزایش و در عوض تأثیر پارامترهای هواشناسی کمتر می‌شود. همچنین مؤثرترین سیگنال MEI اقلیمی و پارامتر هواشناسی در هر مقیاس، به ترتیب و بارندگی می‌باشد. این بدان معنی است که این دو پارامتر می‌توانند به عنوان ورودی‌های مهم در مدلسازی

References

- [1] Bakhshairesh Manesh, K. (2014). Evaluating the relationship between effective teleconnection patterns with precipitation and SPI (Case Study: Central region of Iran). M.Sc thesis In Watershed Science and Engineering, Kashan university.
- [2] Basheer, I.A., Hajmeer, M. (2000). Artificial Neural Networks: fundamentals, computing, design and application. Journal of Microbiol Methods, 43, 3-31.
- [3] Bazrafshan, O. (2013). Hydrologic drought forecasting using teleconnection and intelligent models (Case study: Karkheh watershed). Ph.D Thesis in Watershed Science and Engineering, University of Tehran.
- [4] Cordery, I., McCall, M. (2000). A Model for forecasting drought from teleconnections. Water Resources Research, 36(3), 763–76.
- [5] Dastorani M.T., Afkhami H. (2011). Application of artificial neural networks for drought prediction in Yazd (Central Iran). Desert Journal, 16, 39-48.
- [6] Dehbozorgi, M. (2012). Evaluation of efficiency of different drought indices for drought severity mapping and forecasting using artificial neural networks in different climatic conditions of Iran. M.Sc thesis, International Desert Research Center, Tehran University.
- [7] Deo, R.S. and Sahin, M. (2015). Application of the artificial neural network model for prediction of monthly standardized precipitation and evapotranspiration index using hydrometeorological parameters and climate indices in eastern Australia. Atmospheric Research, 161–162, 65–81.
- [8] Ensafi Moghaddam, T. (2007). An investigation of climatological indices and determination of suitable index for climatological droughts prediction in the Salt Lake Basin of Iran. Iranian journal of Range and Desert Research, 14(2), 271-288.
- [9] Fatehi Maraj, A. (2007). Stream flow forecasting using climate signals. Ph.D Thesis, Department Of Civil Engineering, Khaje- Nasir Toosi University of Technology.
- [10] Fatehi Maraj, A., Borhani Darian, A. and Mahdian, M. (2006). Rainfall seasonal forecasting using teleconnection pattern (Case Study: Orumiyeh Lake Basin). Water and Soil Science Journal, 10(3), 45-58.
- [11] Ganguli, P. and Reddy, M.J. (2014).Ensemble prediction of regional droughts using climate inputs and the SVM–copula approach. Hydrological Processes, 28(9), 4989–5009.
- [12] Gholami Beiraghdar, M.A. (1997). Elnino and Atmospheric Oscillation. Geographical Research, 45, 155-168.
- [13] HoseinPour Niknam, H. (2010). Drought forecasting using neuro-fuzzy and climatics signals (case stude: Sistan Baloochestan Province). M.Sc thesis in civil Engineering, Sistan Baloochestan University.
- [14] Jalalkamali, A., Moradi, M. and Moradi,N.(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, 12,1201-1210.
- [15] Jamshidi, H., Arian, A. and Rezaeian-Zade,M. (2011). Drought forcasting using multilayer perceptron network in different climatology Regions. International Congress on Irrigation and Drainage.
- [16] Julio Canon, J., Gonzalez, J. and Valde's, J. (2007). Precipitation in the Colorado River Basin an its low frequency associations with PDO and ENSO Signals. Journal of Hydrology, 344, 252-264.
- [17] Kahya, E., Dracup, J. (1993). U.S. stream flow patterns In relation to the El Niño/Southern oscillation. Water Resources Research, 29(8), 2491-2503.
- [18] Karamouz, M., Araghnejzhd, Sh. (2010). Advanced Hydrology. Amir Kabir University Press.
- [19] Keshin, M.E., Terzi, O., Taylan, D. and Küçükýaman D. (2011). Meteorological Drought Analysis Using Artificial Neural Networks. Scientific Research and Essays. 6(21), 4469-4477.
- [20] Khoshhal Dastjerdi, J., Hosseini, S.M. (2010). Application of neural network in predicting climate parameters and drought (Case Study: Isfahan Province). Journal of Geography and Environmental Planning, 39(3), 107-120.

- [21] Kia, Mostafa. (2012). Application of neural network in Matlab. Kian Press.
- [22] Kim, T.W, Valdes, JB. (2003). A Comparison of statistical and model-based downscaling techniques forecasting local climate variations. *Journal of Climate*, 11, 735-753.
- [23] Kourepazan Dezfoli, A. (2003). Precipitation forecasting affected by climatic signals. M.Sc thesis, Department of Civil Engineering, Amir Kabir University.
- [24] Maier H.R., Jain A., Dandy G.C., and Sudheer K.P. (2010). Methods used for development of neural networks For the prediction of water resource variables in rivers systems: current status and future directions. *Environmental Modeling & Software*, 1-19.
- [25] Mossad, A. Alazba, A.A. (2015). Drought forecasting using stochastic models in a hyper-arid climate. *Atmosphere*, 6(4), 410-430.
- [26] McKee B.P., Doeske N.J. and Kliest J. (1993). The relationship of drought frequency and duration to time scales. 8th Conference on Applied Climatology, Anaheim, California.
- [27] Menhaj, M.B. (2008). Fundamentals computational intelligence of neural networks. Sharif University of Technology Press, Vol 1.
- [28] Moghaddamnia, A., Ghafari Gousheh, M., Piri, J., Amin, S., and Han, D. (2008). Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*, 32, 88-97.
- [29] Moghaddamnia, A., Remesan, R., Hassanpour Kashani, M., Mohammadi, M., Han, D. and Piri, J. (2009). Comparison of LLR, MLP, Elman, NNARX and ANFIS models-with a case study in solar radiation estimation. *Journal of Atmospheric and Solar-Terrestrial Physics*, 71, 975–982.
- [30] Nasiri, M. (2010). Drought forecasting using artificial neural networks (Case Study: Shiraz Synoptic Station). M.Sc Thesis of Meteorology, Sistan and Baluchestan University.
- [31] Niknam, H., Azhdari Moghaddam, M. and Khosravi, M. (2010). Drought forecasting using adaptive Neuro-Fuzzy inference systems (ANFIS) and Teleconnections Patterns (Case Study: Zahedan). 4th International Congress of the Islamic World Geographers (ICIWG), 14-16 April, Zahedan, Iran.
- [32] Nikzad, B. (2010). Drought monitoring and study relation between oceanic – atmospheric and climatic using data mining. MSc thesis of Water Resources, College of Aburaihan, Tehran University.
- [33] Pekarova, P., Pekar, J. (2007). Teleconnections of inter-annual streamflow fluctuation in Slovakia with Arctic oscillation, North Atlantic Oscillation, Southern Oscillation, and Quasi-Biennial Oscillation Phenomena. *Advances in Atmospheric Science*. 24(4), 655–663.
- [34] Pongracz, R., Bartholy, J. (2006). Regional effects of ENSO in Central/Eastern Europe. *Journal of Advances in Geosciences*, 6, 133-137.
- [35] Pozo, D. (2005). El-Nino-Southern Oscillation events and associated European winter precipitation anomalies. *International Journal of Climatology*, 17-31.
- [36] SedaghatKerdar, A., Fattahi, A. (2011). Drought preparation Indeces in Iran. *Journal of Geography and Development*, 11, 59-76.
- [37] Santos, J.F., Portela, M.M. and Calvo, I.P. (2014). Spring drought prediction based on winter NAO and global SST in Portugal. *Hydrological Processes*, 28(3), 1009–1024.
- [38] Sigaroodi, S.K., Chen, Q., Ebrahimi, S., Nazari, A and Choobin, B.(2014). Long-term precipitation forecast for drought relief using atmospheric circulation factors: a study on the Maharloo Basin in Iran. *Hydrology and Earth System Science*, 18(5), 1995-2006.
- [39] Walker, G.T. (1925). Correlation in seasonal variation of weather, A Furhter Study of World Weather. *Monthly Weather Review*, 52(6), 252-256.
- [40] Walker, G.T. (1928). World Weather III. The quarterly Journal of Royal Meteorological Society, 54(226), 79-87.