مرتع و آبخیزداری، مجله منابع طبیعی ایران
دوره ۷۰، شماره ۴، زمستان ۱۳۹۶
ص ۱۰۳۰-۱۰۱۵

تاریخ دریافت: ۱۳۹۴/۰۲/۰۷
تاریخ تصویب: ۱۳۹۵/۰۲/۱۱

مقایسهٔ کارایی شبکهٔ عصبی مصنوعی در پیش‌بینی خشکسالی هواشناسی با استفاده از پیوند از دور و پارامترهای اقلیمی (مطالعهٔ موردی: جنوب استان قزوین)

❖ **فاطمه مقصود**؛ دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشکدهٔ منابع‌طبیعی و علوم دریایی دانشگاه تربیت مدرس

❖ **محمدرضا یزدانی***؛ دانشیار گروه بیابان‌زدایی دانشکدهٔ کویرشناسی، دانشگاه سمنان

❖ **محمد رحیمی**؛ دانشیار گروه بیابان‌زدایی دانشکدهٔ کویرشناسی، دانشگاه سمنان

❖ **آرش ملکیان**؛ استادیار دانشکدهٔ منابع طبیعی، دانشگاه تهران

❖ **علی‌اصغر ذوالفقاری**؛ استادیار گروه مدیریت مناطق خشک دانشکدهٔ کویرشناسی، دانشگاه سمنان

چکیده

خشکسالی در نگاهی کلی معلول یک دورهٔ شرایط خشک غیرعادی است که به اندازهٔ 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 ستگاه باران سنجی واقع در د شت جنوبی ا ستان قزوین، با ا ستفاده از شبکهٔ ع صبی پر سپترون چندلایه و با در نظر گرفتن پارامترها و سیگنال‌های اقلیمی می‌با شد. بدین منظور سه سناریوی مختلف به‌عنوان ورودی‌های مدل، مورد آزمون قرار گرفت. پس از تعیین متغیرهای ورودی با روش همبستگی متقاطع اقدام به تعیین ترکیب بهینهٔ 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 چندمتغیرهٔ النینو- نوسانات جنوبی) و بارندگی معرفی گردیدند. جهت مدل‌سازی از شبکهٔ عصبی با یک لایهٔ مخفی با تعداد کافی نرون، با تابع سیگموئید در لایهٔ میانی و تابع خطی در لایهٔ 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، پیش بینی، شبکهٔ عصبی، سیگنال اقلیمی.

* نویسنده مسئول: شماره تماس: ۹۸۲۳۳۳۳۳۵۴۰۵+
Email: m_yazdani@semnan.ac.ir

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 زمینهٔ پیش‌بینی خشکسالی استفاده از داده‌های محلی و منطقه‌ای، نظیر ایستگاه‌های بارانسنجی است. از طرفی محدود بودن طول دورهٔ آماری و کیفیت نامناسب آنها محققین را ناچار به بازسازی این داده‌ها می‌نماید [۱] که طبیعتاً در چنین شرایطی قابلیت اعتمادپذیری داده‌ها کاهش می‌یابد. این در حالی است که طی دو دههٔ گذشته استفاده از سیگنال‌های اقلیمی و داده‌های پیوند از دور این مشکلات را مرتفع ساخته است [۹]. سیگنال‌های اقلیمی دارای طول دورهٔ آماری بالا بوده، از کفایت و اعتماد بالایی برخوردار می‌باشند، به سادگی قابل دستیابی هستند و همچنین جهت پیش‌بینی خشکسالی و ترسالی، پیش‌بینی وقوع سیل، پیش‌بینی جریان کمینه یا بیشینهٔ 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 ارتباط است. این پدیده‌ها به صورت شاخص‌های عددی استاندارد شده نظیر شاخص نوسانات جنوبی[۱]، نوسانات اطلس شمالی[۲]، نوسان دهه‌ای اقیانوس آرام[۳] تعریف شده‌اند که با استفاده از این مقادیر عددی، همبستگی و روابط آنها با پارامترهای هیدرواقلیمی در مناطق مختلف دنیا توسط محققین مورد بررسی قرار گفته است. این شاخص‌ها با استفاده از اندازه گیری درجهٔ 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 دراقیانوس‌ها پی برد. 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 منطقهٔ 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 شاخص های 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]. همچنین نتایج ارتباط شاخص بارش استانداردشده (*SPI*) و شاخص‌های النینو- نوسانات جنوبی[۹] و نوسان دهه‌ای اقیانوس آرام نیز نشان داد که ارتباط قوی بین *SPI* و دو سیگنال اقلیمی نامبرده در زمان وقوع خشکسالی و ترسالی وجود دارد [۱۶]. در چند دههٔ اخیر نیز شبکه‌های عصبی مصنوعی[۱۰] قابلیت بالای خود را در مدلسازی سری‌های ناایستا و غیرخطی هیدرومتئورولوژیکی نشان داده‌اند [۲۸، ۲۹]. مدل‌هایی که بر پایه شبکهٔ عصبی مصنوعی هستند، دارای ماهیت تجربی بوده و قادرند راه‌حل‌های 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] Southern Oscillation Index (SOI)
[۲] North Atlantic Oscillation(NAO)
[۳] Pacific Decadal Oscillation (PDO)
[۴] Walker
[۵] Bela and Horn
[۶] Atlantic Oscillation(AO)
[۷] Southern Oscillation
[۸] Quasi-Biennial Oscillation(QBO)
[۹] El Nino Southern Oscillation (ENSO)
[۱۰] Artificial Neural Networks(ANN)

پیش‌بینی پدیده‌ها انجام گرفته است به طوری که استفاده از شبکهٔ عصبی مصنوعی پرسپترون چند لایه (*MLP*) جهت پیش‌بینی SPI حاکی از کارایی مناسب این شبکه در داده‌های هیدرواقلیمی می‌باشد [۱۹]. استفاده از شبکهٔ عصبی مصنوعی بازگشتی و بازگشتی تأخیری جهت پیش بینی خشکسالی هواشناسی در استان یزد نشان داد که دو مدل مذکور دارای عملکرد بالایی (از نظر دقت بالای مقادیر پیش‌بینی شده با مقادیر واقعی) بوده به طوری که ترکیبی از متغیرهای بارش و دمای بیشینه به‌عنوان ورودی مدل جهت دست‌یابی به دقت بالاتر مقادیر پیش‌بینی شده در این منطقه معرفی گردید [۵]. پیش بینی خشکسالی با استفاده از مقادیر SPI در پنجره‌های زمانی ۳، ۶،۹، ۱۲ و ۲۴ ماهه و مدل شبکهٔ 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 شبکهٔ عصبی مصنوعی در مدلسازی هیدرواقلیمی پیش‌بینی جریان ورودی رودخانهٔ 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 هوا، رواناب و میزان برف مشاهده شده به‌عنوان ورودی‌های مدل انتخاب گردید. در رویکرد دوم نیز از ترکیب دو مدل پیش‌بینی هواشناسی برای پیش‌بینی متغیرهای بارش و دمای هوا و یک مدل هیدرولوژی به‌همراه شبکه‌های پس‌انتشار خطا و آدلاین تطبیقی جهت پیش‌بینی جریان رودخانه استفاده گردید که نتایج دو رویکرد، نشان‌دهندهٔ برتری عملکرد شبکهٔ عصبی مصنوعی نسبت به سایر روش‌ها می‌باشد [۱۸]. نتایج پیش‌بینی خشکسالی با استفاده از روش شبکهٔ 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 بازهٔ زمانی تابستان و پاییز برای پیش‌بینی خشکسالی پاییزه مورد استفاده قرارگیرند [۳۱]. نتایج استفاده از شبکهٔ 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 رودخانهٔ کرخه در غرب کشور و کارایی بالای شبکهٔ عصبی مصنوعی هنگام استفاده از سیگنال‌های اقلیمی داشت [۳]. همچنین مقایسهٔ ارزیابی و کارایی شاخص‌های هواشناسی و پیش بینی خشکسالی با استفاده از شبکهٔ عصبی مصنوعی در اقالیم مختلف نشان داد که خشکسالی طی سال‌های ۱۳۸۸-۱۳۹۲ دارای روند افزایشی می‌باشد و همچنین شبکهٔ عصبی مصنوعی در برآورد و پیش‌بینی شدت و مدت خشکسالی در مناطق اقلیمی مختلف دارای دقت یکسانی بوده و از کارایی بالایی برخوردار است [۶]. در

[۱] Multilayer Perceptrom(MLP)
[۲] Adaptive neuro fuzzy inference system (ANFIS)
[۳] Tropical Southern Atlantic Index(TSA)
[۴] Atlantic multidecadal oscillation(AMO)
[۵] Multivariate ENSO Index (MEI)
[۶] Atlantic Multidecadal Oscillation (AMO)
[۷] Pacific Warm Index (PAC WARM)

تحقیقی دو روش رگرسیون چندگانه و شبکه‌های عصبی مصنوعی و همچنین شاخص های 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 یزد مبین کفایت مدل سری زمانی بوده است [۱۴]. در تحقیقی برای توسعه مدل‌های پیش‌بینی خشکسالی از متغیرهای اقلیمی دور پیوندی با شاخص های 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 تعرق پتانسیل به‌عنوان تابع هدف و از پارامترهای آب و هوایی محلی و شاخص‌های اقلیمی بزرگ‌مقیاس و دور پیوندی به‌عنوان 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 شبیه سازی شبکه‌های عصبی مصنوعی برای پیش‌بینی شاخص استاندارد بارش بهاره در پرتغال 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 پرتغال 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 استفادهٔ 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 پارامتر های اقلیمی و سیگنال های اقلیمی به‌عنوان فاکتورهای پیش‌بینی کننده با ساختارهای مختلف در پیش‌بینی خشکسالی در این منطقه به کار گرفته باشد، کمتر انجام شده است.

۲. روش‌شناسی

۲.۱. منطقهٔ مورد مطالعه

منطقهٔ مورد نظر یکی از دشت‌های جنوبی استان قزوین شامل شهرستان‌های بویین‌زهرا و تاکستان است که در محدودهٔ طول جغرافیایی ۴۹ درجه و ۱۰ دقیقه تا ۵۰ درجه و ۳۹ دقیقهٔ شرقی و عرض جغرافیایی ۳۵ درجه و ۲۰ دقیقه تا ۳۶ دقیقه و ۳۰ دقیقهٔ 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 منطقهٔ مورد مطالعه و وضعیت طول دورهٔ آماری موجود، دو ایستگاه بارانسنجی و تبخیرسنجی دانسفهان طی دورهٔ آماری ۱۳۶۲-۱۳۶۳ تا ۱۳۸۹-۱۳۹۱ انتخاب شد (جدول ۱). پارامترهای هواشناسی

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

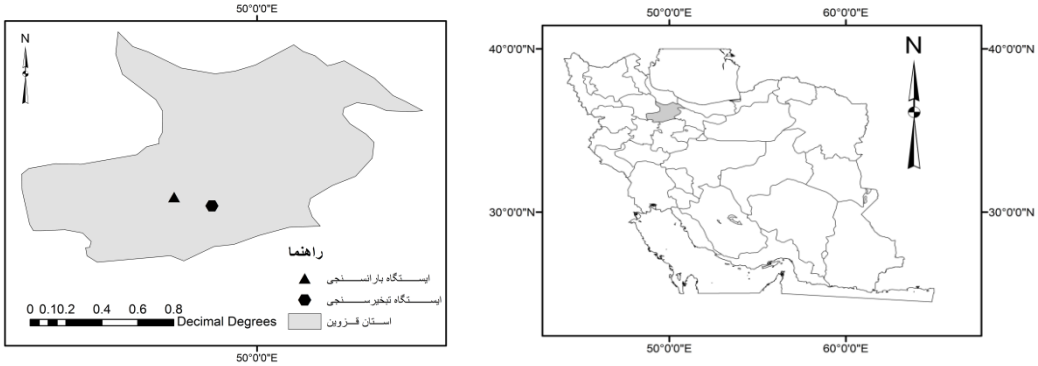

شکل ۱. نقشهٔ موقعیت دشت مورد مطالعه در کشور و موقعیت ایستگاه‌های منتخب

جدول ۱. مشخصات ایستگاه‌های مورد مطالعه

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

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 مقیاس های زمانی چندگانه طراحی شده است. این مقیاس‌های زمانی منعکس‌کنندهٔ اثرات ویژهٔ 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 آب های زیرزمینی، جریان آب رودخانه و ذخیرهٔ مخازن تحت تأثیر ناهنجاری های بلندمدت بارندگی قرار می گیرند. بدین ترتیب از این شاخص برای مقیاس‌های زمانی ۳، ۶، ۱۲ و ۲۴ ماهه استفاده می‌نمایند. به‌عبارت 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 محاسبهٔ شاخص *SPI*، به ترتیب زیر است:

- تشکیل سری‌های زمانی بارندگی در مقیاس زمانی i ماهه (۲۴، ۴۸،...،۱۲،...،۶،...،۱ = i).
- برازش توزیع آماری گاما بر سری‌های بارندگی حاصل از مرحلهٔ قبل و محاسبهٔ احتمالات تجمعی توزیع گاما.

[۱] Standardized Precipitation Index

[۲] Mckee

- محاسبه‌ی *SPI* شامل برازش تابع چگالی احتمال گاما بر توزیع فراوانی بارندگی کل برای یک ایستگاه معین.
- برآورد پارامتر های α و β مربوط به تابع چگالی احتمال گاما برای هر ایستگاه و در هر مقیاس زمانی (۳، ۶، ۱۲، ۲۴، ۴۸ ماه و غیره) و برای هر ماه از سال طی دورهٔ آماری ۲۷ ساله (۱۳۶۳-۱۳۹۰).

جدول۲- طبقات شدت خشکسالی بر اساس *SPI* (به نقل از [22])

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

۲.۳. شبکهٔ عصبی مصنوعی

ایدهٔ اصلی شبکه‌های عصبی مصنوعی بر مبنای شبیه سازی شبکهٔ 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؛ شبکه های مختلفی تشکیل می‌شود که یکی از کاربردی‌ترین آنها در علوم مهندسی برای نگاشت غیر خطی، شبکه‌های پرسپترون چندلایه می‌باشد[۲۷]. معماری شبکهٔ عصبی معمولاً از سه لایهٔ 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 داده ها 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 رابطهٔ (۱) در دامنهٔ عددی بین ۰/۱ و ۰/۹ قرار گرفتند که در نهایت مقادیر خروجی به دست آمده از شبکه نیز با معکوس نمودن رابطهٔ مذکور به حالت اولیه برگردانده شدند.

$$y = 0.8\left(\frac{x_i - x_{min}}{x_{max} - x_{min}}\right) + 1 \qquad (۱)$$

در این رابطه، X_{min} کوچک‌ترین داده و X_{max} بزرگ ترین دادهٔ سری می‌باشد.

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

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

رایج‌ترین الگوریتم آموزش، الگوریتم پس‌انتشار خطا[۱] است که طبق گزارشات، ۹۰٪ تجارب انجام شده در این زمینه با شبکه‌های پیش‌خور چندلایه با الگوریتم پس انتشار خطا صورت می‌گیرد [۲۲]. لذا در این تحقیق از الگوریتم پس‌انتشار خطا و تعداد نرون‌های لایه پنهان از ۲ تا ۱۴ نرون مورد آزمون قرار گرفت. سپس در مرحلهٔ صحت‌سنجی، مدل به وسیله داده‌هایی که در مرحلهٔ آموزش شرکت نداشته‌اند اجرا شد. در این تحقیق به دلیل جامعیت و سهولت کاربردی از جعبه ابزار شبکهٔ عصبی مصنوعی در نرم‌افزار مطلب استفاده شد.

۲.۴. معیارهای ارزیابی خطای شبکه

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

$$R^2 = \frac{\sum_{i=1}^{n}(obs-\overline{obs})(pre-\overline{pre})}{\sqrt{\sum_{i=1}^{n}(obs-\overline{obs})^2\sum_{i=1}^{n}(pre-\overline{pre})^2}} \qquad (۲)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(obs-pre)^2}{n}} \qquad (۳)$$

$$MAE = \frac{\sum_{i=1}^{n}|obs-pre|}{n} \qquad (۴)$$

در روابط بالا n، تعداد کل داده‌ها، obs و $\overline{obs}$ به ترتیب نماد مقادیر مشاهداتی و میانگین مقادیر مشاهداتی، pre و $\overline{pre}$ نیز به ترتیب نماد مقادیر پیش‌بینی شده و میانگین مقادیر پیش‌بینی شده می باشند.

۲.۵. تعیین متغیرهای ورودی با روش همبستگی متقاطع[۵]

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

$$\begin{cases} \text{For: } 0,\ \pm1,\pm2,\pm3,\ldots\ldots\ldots \\ \text{If: } \ i-d<0\,,\ \ i-d\geq N \end{cases} \qquad (۵)$$

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

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

با توجه به شرط در رابطه (۵)، نقاط i<0 و i≥N مورد توجه نبوده و مقدار ضریب همبستگی متقاطع همواره $-1\leq R\leq +1$ خواهد بود. در این تحقیق همبستگی متقاطع 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

[۱] Back Propagation
[۲] Correlation Coeficient(R^2)
[۳] Root Mean Square Error(RMSE)4-
[۴] Mean Absolute Error(MAE)
[۵] Cross Correlation Function

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 پدیدهٔ 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 استانداردشدهٔ فشار سطح دریا است که از اختلاف فشار بین منطقهٔ تاهیتی و داروین استرالیا به دست می‌آید. شاخص چندمتغیرهٔ النینو-نوسانات جنوبی (MEI) از شش متغیر آب و هوایی در منطقهٔ حاره‌ای اقیانوس آرام محاسبه می‌گردد. مد نصف‌النهاری اطلس[1] (AMM) تغییرات ناهمگن دمای سطح دریا در جهت نصف‌النهاری است و بیانگر تغییرات نصف النهاری 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 متأثر می‌سازد.

جدول۳. متغیرهای ورودی مورد استفاده

پارامترهای هواشناسی	سیگنال اقلیمی
بارندگی	*PDO*
دمای حداکثر مطلق	*SOI*
دمای حداقل مطلق	*MEI*
میانگین دما	*AMM*
دمای حداکثر	*AMO*
دمای حداقل	
تبخیر و تعرق	

۲.۷. استفاده از آزمون گاما جهت تعیین ترکیب بهینهٔ متغیرهای ورودی به مدل

یکی از مراحل مهم در مدلسازی جهت پیش‌بینی، تعیین ترکیب بهینهٔ متغیرهای ورودی می‌باشد. از بین روش‌های مختلف، آزمون گاما یک روش غیر متغیری 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 بهینهٔ متغیرهای ورودی را شناسایی می‌کند [۳۴].

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

$$\{(xi, yi), 1 \le i \le M)\} \qquad (۶)$$

در این رابطه x_i بردار مشاهداتی ورودی بوده که در این تحقیق شامل پارامترهای هواشناسی و سیگنال‌های اقلیمی است و y_i نیز بردار خروجی مشاهداتی بوده که شامل مقادیر شاخص بارش استاندارد شده در سه مقیاس زمانی می‌باشد. چنانچه رابطهٔ (۷) بین ورودی و خروجی برقرار باشد، متغیر تصادفی r، نشان‌دهندهٔ خطا می‌باشد و انجام این آزمون در واقع تخمینی برای واریانس خروجی مدلی غیرهموار[2] می‌باشد.

$$Y=f(x)+r \qquad (۷)$$

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

[1] Atlantic Meridional Mode (AMM)

[2] Smooth function

$k(1\le k\le p)$ امین همسایگی برای هر بردار $x_i(1\le i\le M)$ است، می‌باشد. همچنین طبق رابطهٔ (۸) تابع δ میانگین مجذور فاصلهٔ kامین همسایگی را محاسبه می‌کند که در آن $|\ |$، نشان‌دهندهٔ فاصله اقلیدسی[۱] بوده و تابع گاما متناظر آن طبق رابطهٔ (۹) است که در آن $y_{N[i,k]}$ مقدار y متناظر با kامین همسایگی در x_i است.

$$\delta_M^{(k)} = \frac{1}{M}\sum_{i=1}^{M}\left|X_{N[i,k]} - X_i\right|^2 \qquad (۸)$$

$$\gamma_M^{(k)} = \frac{1}{2M}\sum_{i=1}^{M}\left|X_{N[i,k]} - Y_i\right|^2 \qquad (۹)$$

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

$$\gamma = A\delta + \Gamma \qquad (۱۰)$$

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 همهٔ 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.

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 (۲۴ماهه)، طی سال‌های ۱۳۶۳-۱۳۹۰ استفاده شد. بدین منظور از شبکهٔ عصبی پرسپترون چندلایه با یک لایهٔ مخفی با تابع سیگموئید در لایهٔ میانی و تابع خطی در لایهٔ خروجی استفاده و تعداد نرون‌های لایهٔ میانی به روش آزمون و خطا از ۲ تا ۱۴ نرون مورد 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 متقاطع (*CCF*) برای انتخاب بهترین متغیرهای پیش‌بینی‌کننده

برای انتخاب متغیرهای بهینه ابتدا از همبستگی متقاطع استفاده گردید. جدول۴، نتایج همبستگی متقاطع شاخص SPI را با سیگنال‌های بزرگ مقیاس اقلیمی از قبیل *SOI*، *MEI*، *AMM*، *AMO* و *PDO* و همچنین پارامترهای هواشناسی از قبیل بارندگی، تبخیرو 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 کوتاه‌مدت، 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(R=0.118) در گام اول و *MEI* (R=0.164) در گام تأخیر ۶ می‌باشد. برای حداکثر دمای مطلق ۰/۱۳، حداقل دمای مطلق ۰/۱۴، میانگین دما ۰/۱۱، حداکثر دما ۰/۱ و حداقل دما ۰/۱۲ همگی در گام تأخیر ۱۰ محاسبه شده است. همچنین برای بارندگی

[۱] Euclidean distance

۰/۴۹ بوده (در گام تاخیر۲) که با توجه به ماهیت شاخص خشکسالی مدنظر طبیعی است. همچنین 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 پدیدهٔ بارندگی نسبت به دما بر بروز خشکسالی در مقیاس زمانی کوتاه مدت بسیار سریع‌تر می‌باشد. در مقیاس زمانی میان‌مدت، سیگنال های اقلیمی *AMO* و *MEI* به نوعی دارای همبستگی ضعیف با شاخص SPI می‌باشند. در این مقیاس زمانی نیز همچنان دو پارامتر بارندگی و حداقل دمای مطلق دارای بیشترین همبستگی می‌باشند. درمقیاس 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.

جدول۴. همبستگی متقاطع بین سری زمانی مقادیرSPI ۲۴ماهه و سیگنال‌های اقلیمی و پارامترهای هواشناسی

متغیرها		SPI3			SPI9			SPI24		
		ضریب همبستگی	گام تأخیر	P	ضریب همبستگی	گام تأخیر	P	ضریب همبستگی	گام تأخیر	P
سیگنال اقلیمی	PDO	*	*	*	-۰/۰۹	۹	۰/۰۵	۰/۲۱	۰	<۰/۰۰۰۱
	SOI	-۰/۲۱	۹	<۰/۰۰۰۱	-۰/۲	۱۱	۰	-۰/۲۴	۱۱	<۰/۰۰۰۱
	AMM	*	*	*	-۰/۱	۶	۰/۰۴	۰/۱	۰	۰/۰۴
	AMO	۰/۱۲	۰	۰/۰۲	۰/۱۳	۲	۰/۰۱	۰/۱۶	۰	۰
	MEI	۰/۱۶	۶	۰	۰/۱۴	۱۰	۰/۰۱	۰/۲۷	۹	<۰/۰۰۰۱
پارامتر هواشناسی	بارندگی	۰/۴۹	۲	<۰/۰۰۰۱	۰/۳۳	۷	<۰/۰۰۰۱	۰/۲۵	۳	<۰/۰۰۰۱
	حداکثر دمای مطلق	۰/۱۳	۱۰	۰/۰۱	۰/۰۹	۴	۰/۰۶	۰/۱	۸	۰/۰۴
	حداقل دمای مطلق	۰/۱۴	۱۰	۰/۰۱	۰/۱۱	۴	۰/۰۳	۰/۱۲	۷	۰/۰۲
	میانگین دما	۰/۱۱	۱۰	۰/۰۲	-۰/۰۹	۰	۰/۰۵	۰/۱	۷	۰/۰۳
	حداکثر دما	۰/۱	۱۰	۰/۰۳	-۰/۱	۰	۰/۰۴	-۰/۱	۱	۰/۰۵
	حداقل دما	۰/۱۲	۱۰	۰/۰۱	۰/۰۹	۴	۰/۰۵	۰/۱۲	۷	۰/۰۱
	تبخیرتعرق	*	*	*	*	*	*	۰/۱۱	۹	۰/۰۳

۳.۲. نتایج استفاده از انواع ساختارهای ورودی به شبکهٔ عصبی مصنوعی

در این تحقیق پس از مشخص شدن ترکیب‌های بهینه با آزمون گاما، سه ساختار ورودی به شبکهٔ عصبی مصنوعی از ترکیبات ممکن تعیین گردید. در ساختار اول (SIG-IND[1]) علاوه بر SPI با تأخیر مشخص، از سیگنال‌های اقلیمی شامل MEI، SOI، AMM، AMO و PDO نیز استفاده می‌شود. در ساختار دوم (IND[2]) عوامل ورودی تنها شامل شاخص SPI با تأخیرهای ۱، ۲، ۳، ۴، ۵، ۱۰، ۱۱ و ۱۲ می‌باشد. در ساختار سوم (MET-IND[3]) نیز عوامل ورودی شامل پارامترهای هواشناسی و SPI با تأخیرهای مشخص می‌باشد. جدول (۵)، عوامل ورودی برای سه ساختار مذکور را نشان می‌دهد.

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

[1] SIGNAL & INDEX
[2] INDEX
[3] METEOLOGICAL & INDEX

EVA بـه ترتیـب نمـاد بـارنـدگی، دبی و تبخیرتعرق و Abs_Tma و Abs_Tmin به ترتیب حداکثر و حداقل دمـای مطلق و Tmin، Tmean، Tmax نیز بـه ترتیـب حداقل، میانگین و حداکثر دما می‌باشند.

در SPI9 مشاهده می‌شود که در سناریوی اول، تمامی متغیرهای ورودی بجز مقادیر SPI9 با ۲، ۳ و ۴ گام تأخیر اثر مثبتی در مدلسـازی دارد. همچنین مشـاهده می‌شـود که با افزایش گام زمانی تأخیر در شـــاخص SPI9 از ۵ به ۱۲ مقادیر گاما افزایش یافته اســـت به طوری که ورودی شـاخص با ۱۲گام تأخیر بیشـترین تأثیر را در مدلسـازی دارا می‌با شد. در سناریوی دوم بیشترین تأثیر مدلسازی متعلق به ورودی‌های شـاخص با ۱ و ۱۲ گام زمانی تأخیر می‌باشد. 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 می‌باشد.

جدول۵. ترکیب ساختارهای ورودی برای ورود به شبکهٔ عصبی مصنوعی در سه مقیاس زمانی SPI.

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

در SPI24 نیز در سناریوی اول، SPI با تأخیر ۱۲ ماهه و از میان سیگنال‌های اقلیمی *AMM* و *AMO* در زمان t ورودی‌های با بیشترین تأثیرگذاری بر مدلسازی می‌باشند. در ســـناریوی دوم تنها SPI با تأخیر های ۱۱ و ۱۲ مؤثرترین ورودی‌ها می‌باشـــد. در ســـناریوی ســـوم نیز مؤثرترین پارامتر مربوط به SPI با تأخیر ۱ماهه و از میان پارامترهای هواشناسی مربوط به حداقل دمای مطلق با ۷ گام تأخیر می‌باشد.

جدول۶. نتایج آزمون گاما برای SPI ۳، ۹ و ۲۴ ماهه، در ساختار شمارهٔ یک (شاخص به همراه سیگنال‌های اقلیمی)

شمارهٔ ترکیب	SPI3		SPI9		SPI24	
	پارامتر حذفی	مقدار گاما	پارامتر حذفی	مقدار گاما	پارامتر حذفی	مقدار گاما
۱	-	۰/۰۱۰۹۵۸	-	۰/۰۰۱۳۹۵	-	۰/۰۰۱۵۷۱
۲	$SPI3_{(t-1)}$	۰/۰۱۱۵۸۸	$SPI9_{(t-1)}$	۰/۰۰۲۳۳۹	$SPI24_{(t-1)}$	۰/۰۰۱۹۱۱
۳	$SPI3_{(t-2)}$	۰/۰۰۸۲۸۱	$SPI9_{(t-2)}$	۰/۰۰۰۵۴۹	$SPI24_{(t-2)}$	۰/۰۰۲۰۹۸
۴	$SPI3_{(t-3)}$	۰/۰۰۹۵۰۱	$SPI9_{(t-3)}$	۰/۰۰۱۰۹۵	$SPI24_{(t-3)}$	۰/۰۰۱۲۵۵
۵	$SPI3_{(t-4)}$	۰/۰۱۰۸۹۸	$SPI9_{(t-4)}$	۰/۰۰۱۲۸۸	$SPI24_{(t-4)}$	۰/۰۰۱۲۱۱
۶	$SPI3_{(t-5)}$	۰/۰۰۹۶۸۳	$SPI9_{(t-5)}$	۰/۰۰۱۴۱۷	$SPI24_{(t-5)}$	۰/۰۰۱۴۵۸
۷	$SPI3_{(t-10)}$	۰/۰۰۸۶۷۲	$SPI9_{(t-10)}$	۰/۰۰۳۰۱۵	$SPI24_{(t-10)}$	۰/۰۰۱۳۲۴
۸	$SPI3_{(t-11)}$	۰/۰۰۸۹۲۵	$SPI9_{(t-11)}$	۰/۰۰۲۷۳۴	$SPI24_{(t-11)}$	۰/۰۰۲۱۸۷
۹	$SPI3_{(t-12)}$	۰/۰۰۸۷۱۲	$SPI9_{(t-12)}$	۰/۰۰۳۲۱۸	$SPI24_{(t-12)}$	۰/۰۰۳۴۵۷
۱۰	$SOI_{(t-9)}$	۰/۰۱۰۳۵۵	$PDO_{(t-9)}$	۰/۰۰۱۷۵۱	$PDO_{(t)}$	۰/۰۰۰۹۹۷
۱۱	$AMO_{(t)}$	۰/۰۰۹۶۶۸	$SOI_{(t-11)}$	۰/۰۰۲۱۹	$SOI_{(t-11)}$	۰/۰۰۱۴۴۵
۱۲			$AMM_{(t-6)}$	۰/۰۰۲۵۳۱	$AMM_{(t)}$	۰/۰۰۱۷۵۷

۱۳		$AMO_{(t-2)}$	۰/۰۰۲۲۶۸	$AMO_{(t)}$	۰/۰۰۱۷۵۷
۱۴		$MEI_{(t-10)}$	۰/۰۰۱۴۳۸	$MEI_{(t-9)}$	۰/۰۰۱۶۸۶

جدول۷. نتایج آزمون گاما برای SPI ۳، ۹ و ۲۴ ماهه در ساختار شمارهٔ دو (شاخص SPI)

شمارهٔ 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

جدول۸. نتایج آزمون گاما برای SPI ۳، ۹ و ۲۴ ماهه در ساختار شمارهٔ سه (شاخص به‌همراه 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	$SPI24_{(t-12)}$	۰/۰۰۳۱۲۴
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				

با ا ستفاده از نتایج به د ست آمده در گام قبل، ترکیب بهینهٔ نهایی حا صل از سه ساختار جهت ورود به شبکهٔ عصبی مصنوعی به دست آمد (جدول ۹) سپس متغیرهای به دســـت آمده در هر ســـاختار به‌عنوان ورودی به مدل شبکهٔ ع صبی وارد و خروجی‌های SPI24 ماهه پیش‌بینی گردیدند.

جدول ۹. نتیجهٔ نهایی ترکیب بهینهٔ متغیرهای ورودی در سه سناریوی مورد مطالعه.

شاخص	شمارهٔ سناریو	نام سناریو	عوامل
SPI3	اول	SIG-IND	-
	دوم	IND	$SPI3_{(t-4)}$ ،$SPI3_{(t-3)}$ ،$SPI3_{(t-2)}$،$SPI3_{(t-1)}$ $SPI3_{(t-12)}$،$SPI3_{(t-5)}$, $SPI3_{(t-10)}$،
	سوم	MET-IND	$SPI3_{(t-1)}$, $SPI3_{(t-10)}$, $SPI3_{(t-11)}$, $MEI_{(t-6)}$, $PRE_{(t-2)}$, $Abs_Tmax_{(t-10)}$, $Abs_Tmin_{(t-10)}$
SPI9	اول	SIG-IND	$SPI9_{(t-1)}$, $SPI9_{(t-5)}$, $SPI9_{(t-10)}$, $SPI9_{(t-11)}$, $SPI9_{(t-12)}$, $PDO_{(t-9)}$, $SOI_{(t-11)}$, $AMM_{(t-6)}$, $AMO_{(t-2)}$, $MEI_{(t-10)}$
	دوم	IND	$SPI9_{(t-1)}$, $SPI9_{(t-12)}$
	سوم	MET-IND	$SPI9_{(t-1)}$, $SPI9_{(t-3)}$, $SPI9_{(t-5)}$, $SPI9_{(t-11)}$, $Abs_TMax_{(t-4)}$, $Abs_TMin_{(t-4)}$, $TMean_{(t)}$, $TMax_{(t)}$, $TMin_{(t-4)}$
SPI24	اول	SIG-IND	$SPI24_{(t-1)}$, $SPI24_{(t-2)}$, $SPI24_{(t-11)}$, $SPI24_{(t-12)}$, $AMM_{(t)}$, $AMO_{(t)}$, $MEI_{(t-9)}$
	دوم	IND	$SPI24_{(t-11)}$, $SPI24_{(t-12)}$
	سوم	MET-IND	$SPI24_{(t-1)}$, $SPI24_{(t-2)}$, $SPI24_{(t-3)}$, $SPI24_{(t-4)}$, $SPI24_{(t-5)}$, $SPI24_{(t-10)}$, $SPI24_{(t-11)}$, $SPI24_{(t-12)}$, $PRE_{(t-3)}$, $Abs_TMin_{(t-7)}$, $TMean_{(t-7)}$, $TMAX_{(t-7)}$, $TMIN_{(t-7)}$

در جدول (۱۰) نتایج معیارهای ارزیابی شبکهٔ 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 آمده بهترین عملکرد مدل در ساختار اول، یعنی زمانی‌که از سیگنال‌های اقلیمی به‌عنوان پیش‌بینی کننده استفاده شد، می‌باشد.

جدول۱۰. نتایج معیارهای ارزیابی شبکه برای پیش‌بینی SPI ۳، ۹ و ۲۴ ماهه در ترکیب‌های مختلف

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

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 ادامهٔ این روند سبب بروز شرایط بحرانی در آنها خواهد شد. لذا انجام مطالعات خشکسالی هواشناسی به‌عنوان نیروی محرکهٔ دیگر خشکسالی‌ها و پیش‌بینی و مدلسازی آن، از جمله اقدامات اولیه و مهم مدیریتی در جهت شناخت و مهار این بحران به‌شمار می‌رود. همانطور که ذکر شد در این مطالعه جهت مدلسازی خشکسالی هواشناسی در سه مقیاس زمانی، سه

ساختار از ترکیبات بهینهٔ متغیرهای ورودی مورد بررسی قرار گرفت. به طورکلی 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. (R=0.89، RMSE=0.43 و MAE=0.34).

در این تحقیق از میان شاخص‌های اقلیمی در طول دورهٔ آماری (۱۳۶۱-۱۳۹۱) روابط معنی‌داری بین شاخص‌های اقلیمی *MEI*، *SOI*، *PDO*، *AMM* و *AMO* با نمایهٔ استانداردشدهٔ باران (SPI) در مقیاس زمانی مورد مطالعه وجود دارد. بین *SOI* با نمایهٔ SPI رابطه معکوس و بین سایر شاخص‌ها رابطهٔ مستقیم وجود دارد.

در بین پنج شاخص، شاخص‌های *MEI* و *SOI* بالاترین ضریب همبستگی و بهترین روند برای ورود به مدل و پیش‌بینی را داشته‌اند. نتایج تحقیقات محققین نیز مؤید این مطلب بود [۳،۳۰، ۳۲]. به طوری که آنها مؤثرترین شاخص‌ها بر منطقه را *SOI*، *MEI* و *PDO* معرفی نمودند. همچنین شاخص *SOI* بر بارش پاییزهٔ حوزهٔ آبخیز ارومیه دارای بیشترین تأثیر می‌باشد [۳۴،۱۰،۳۵]. همچنین نتایج این تحقیق مبنی بر ضریب بالا و معکوس بین مقادیر *AMO* و *AMM* بر بارندگی در منطقهٔ مورد مطالعه است که طبق نتایج محققین نیز شاخص *AMO* و *AMM* (نوسانات اقیانوس اطلس) به عنوان بهترین پیش‌بینی‌کننده ها در کشور معرفی گردیده است [۱،۳،۱۳]. نتایج این تحقیق به طورکلی 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* و بارندگی می‌باشد. این بدان معنی است که این دو پارامتر می‌توانند به عنوان ورودی‌های مهم در مدلسازی 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 فاصلهٔ جغرافیایی زیاد آن دانست که با نتایج محققین دارای هم‌خوانی می‌باشد [۳۶، ۳۰، ۲۳، ۱۰، ۹، ۳، ۱]. همچنین نتایج استفاده از متغیر های 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 شبکهٔ *MLP* با توجه به ورودی‌های مختلف، ساختار یک که حاوی سیگنال های اقلیمی و مقادیر SPI در گام های 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 [۱،۳،۹].

در این تحقیق علاوه بر بررسی ارتباط بین سیگنال‌های اقلیمی با خشکسالی در دشت قزوین و معرفی قوی‌ترین پیش‌بینی‌کننده‌ها در خشکسالی، قابلیت شبکهٔ عصبی مصنوعی پرسپترون چندلایه در سه ساختار یکی بارندگی به‌عنوان 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 زمینهٔ 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.

References

[1] Bakhshaiesh 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] Fatehei Maraj, A. (2007). Stream flow forcasting 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 Balochestan 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 percepetron 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., Araghinejzhad, Sh. (2010). Advanced Hydrology. Amir Kabir University Press.

[19] Keshin, M.E., Terzi, O., Taylan, D. and Küçükyaman 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 forcasting 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 forcasting using artificial neural networks (Case Study: Shiraz Synoptic Station). M.Sc Thesis of Meteorology, Sistan and Balochestan 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 – athmospheric 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.