

پیش‌بینی خشکسالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی - موجکی

احمد فاخری‌فرد^۱

امین عبدالکردانی^۲

یوسف حسن‌زاده^۳

(دریافت ۹۰/۴/۲۶ پذیرش ۸۹/۴/۱۷)

چکیده

خشکسالی به عنوان یکی از مهم‌ترین بلایای طبیعی است که ممکن است در هر رژیم آب و هوایی اتفاق بیفتد. از آنجا که وقوع خشکسالی اجتناب ناپذیر است، بنابراین شناخت آن به منظور مدیریت بهینه منابع آب، از اهمیت بسیاری برخوردار است. از مؤثرترین عوامل در تدوین طرحهای مقابله با خشکسالی و مدیریت آن، طراحی سیستم‌های پیش‌بینی خشکسالی است که بتوان اثرات مخرب ناشی از آن را به حداقل رساند. به این منظور در این تحقیق برای پیش‌بینی خشکسالی‌های آتی، از تلفیق الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی - موجکی در تحلیل شاخص بارندگی استاندارد شده، استفاده گردید و در نهایت نشان داده شد که به کارگیری روش تلفیقی مذکور در مقایسه با تلفیق الگوریتم ژنتیک و شبکه عصبی، نتایج مطلوبی را ارائه می‌دهد.

واژه‌های کلیدی: پیش‌بینی خشکسالی، شاخص بارندگی استاندارد شده، الگوریتم ژنتیک، شبکه عصبی، موجک

Drought Forecasting Using Genetic Algorithm and Conjoined Model of Neural Network-Wavelet

Yousef Hassanzadeh¹

Amin Abdi Kordani²

Ahmad Fakheri Fard³

(Received July 16, 2010 Accepted June 6, 2011)

Abstract

Drought is one of the important natural disasters that may happen in any climate conditions. Since drought is inevitable phenomenon, therefore familiar with that natural disaster is very important for reliable water management. Drought prediction system design is one of the efficient ways that it can minimize the drought damages. In this research for predicting the coming drought, genetic algorithm and conjoined model of neural network-wavelet is used for analyzing standardized precipitation index. The results show that genetic algorithm and conjoined model of neural network-wavelet is more satisfactory than genetic algorithm and neural network.

Keywords: Drought Forecasting, Standardized Precipitation Index, Genetic Algorithm, Neural Network, Wavelet.

1. Prof. of Civil Eng., Dept. of Water Eng., University of Tabriz, Tabriz (Corresponding Author) (+98 411) 3392395 yhassanzadeh@tabrizu.ac.ir

2. Ph.D. Student of Civil Eng., Dept. of Water Eng., University of Tabriz, Tabriz

3. Assoc. Prof. of Water Eng., College of Agriculture, University of Tabriz, Tabriz

۱- استاد گروه مهندسی عمران- آب، دانشکده فنی مهندسی عمران، دانشگاه تبریز

(نویسنده مسئول) (۰۴۱) ۳۳۹۲۲۹۵ yhassanzadeh@tabrizu.ac.ir

۲- دانشجوی دکترا مهندسی عمران- آب، دانشکده فنی مهندسی عمران، دانشگاه تبریز

۳- دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

۱- مقدمه

کاراهان و همکاران^۵ برای پیش‌بینی شدت بارش به ازای دوره‌های بازگشت مختلف، از الگوریتم ژنتیک استفاده نموده‌اند و نشان داده‌اند که با کاربرد الگوریتم ژنتیک، دیگر هیچ نیازی به استفاده از تبدیل‌های ریاضی وجود ندارد. همچنین نتایج حاصل از کمترین خطای مربعات نشان داد که روش الگوریتم ژنتیک، بهترین برآنش را بر داده‌های اندازه‌گیری شده ارائه می‌دهد [۵]. چن و همکاران^۶ برای پیش‌بینی جریان رودخانه‌ای، به تحلیل غیرخطی سری‌های زمانی، با استفاده از الگوریتم ژنتیک پرداختند. با توجه به اینکه پیش‌بینی دقیق‌تر و صحیح‌تر، منجر به تصمیم‌گیری‌های مفید و مؤثر در منابع آب می‌شود، لذا آنها نتیجه گرفتند که الگوریتم ژنتیک نسبت به روش‌های قدیمی تحلیل سری‌های زمانی، عملکرد بسیار مناسبی دارد [۶]. موهان^۷ و ویجیال آکشمی^۸ پارامترهای هیدروگراف واحد لحظه‌ای ناش را با استفاده از روش‌های گشتاورها، الگوریتم ژنتیک و الگوریتم صعود قله برای دو حوضه با آب و هوای مختلف تخمین زدند. آنها با استفاده از معیار نیکوبی برآنش که نشان دهنده خطای بین داده‌های مشاهداتی و محاسباتی است، نتیجه گرفتند که دو روش الگوریتم ژنتیک و الگوریتم صعود قله نتایج بهتر و قابل قبولی را ارائه می‌دهند [۷].

حسن زاده و همکاران از روش‌های فرآکاوشی همچون الگوریتم ژنتیک و الگوریتم جامعه مورچگان، به منظور تخمین پارامترهای توزیعهای آماری مورد استفاده در تحلیل فراوانی جریان‌های سیلابی از قبیل مقدار حدی تعیم یافته، پیرسون نوع سوم، لوگ نرمال سه پارامتری، لجستیک تعیم یافته، پاریتوی تعیم یافته، کاپا و ویکی در استان آذربایجان شرقی استفاده نمودند و در نهایت نتیجه گرفتند که دو روش فرآکاوشی مذکور، در قیاس با سایر روش‌های معمول تخمین پارامتر همچون روش حداقل درست‌نمایی، گشتاورها و گشتاورهای وزنی احتمال جوابهای بهتری را ارائه می‌دهند [۸].

تعیین ویژگی‌های خشکسالی یا ترسالی در یک منطقه، یکی از نیازهای اساسی برنامه‌ریزی‌های محیط‌زیستی و اقتصادی به‌ویژه برنامه‌ریزی برای مدیریت منابع آب است. در بسیاری از برنامه‌های بلند مدت، لازم است که چشم‌اندازی از وضعیت آینده بارندگی و دوره‌های خشک و تر برای منطقه ترسیم گردد. بهمین دلیل، موضوع پیش‌بینی خشکسالی و تخمین ویژگی‌های آن از اهمیت بسیار زیادی در مدیریت منابع آب برخوردار است [۹]. تاکنون برای پیش‌بینی خشکسالی و سایر پیش‌بینی‌های هیدرولوژیکی،

خشکسالی به عنوان یک حادثه ناگوار طبیعی، در اثر تغییر اقلیم پدیدار می‌گردد و به طور مستقیم جوامع را از طریق تغییرات در دسترسی به منابع آب تحت تأثیر قرار می‌دهد [۱۰]. رخداد این پدیده هزینه‌های اقتصادی، اجتماعی و محیط‌زیستی زیادی را نیز به همراه داشته و خسارتی که به آن نسبت داده می‌شود، بسته به شدت خشکسالی رو به افزایش است و انسان با تمام پیشرفت‌های علمی و فنی خود هنوز توانسته زمان و محل وقوع خشکسالی‌های شدید را به طور دقیق مشخص نماید [۲].

از آنجا که جلوگیری کامل از پدیده خشکسالی در هیچ منطقه و شرایطی امکان پذیر نیست، می‌توان با تحلیل سوابق تاریخی و با تکیه بر آمار و اطلاعات موجود، دوره بازگشت‌های خشکسالی را برای مناطق مختلف برآورد نمود و با ایجاد طرحهای آمادگی برای پدیده خشکسالی، مشکلات ناشی از آن را تا حد امکان کاهش داد. در راستای تدوین طرحهای مقابله با خشکسالی و مدیریت آن، از ضروری ترین ابزار، طراحی سیستم‌های پایش خشکسالی است که اطلاعات استخراج شده از آنها، تعیین کننده نوع عملیات مقابله با خشکسالی و زمان شروع آن است. چنین سیستم‌هایی با استفاده از شخص‌های خشکسالی طراحی و ارائه می‌گردد [۳].

هدف از تهیه و کاربرد شاخصهای خشکسالی، ارائه یک ارزیابی کمی و کیفی از ویژگی‌های زمانی و مکانی رخداد خشکسالی است. از میان شاخصهای موجود برای تحلیل خشکسالی، شاخص بارندگی استاندارد شده^۱ به علت سادگی محاسبات، استفاده از داده‌های قابل دسترس بارندگی، قابلیت محاسبه برای هر مقیاس زمانی دلخواه و قابلیت بسیار زیاد در مقایسه مکانی نتایج، به عنوان مناسب‌ترین شاخص برای بدست آوردن مشخصات خشکسالی شناخته می‌شود

و در حال حاضر به طور گسترده مورد استفاده قرار می‌گیرد [۴].

به منظور تخمین پارامترهای موجود در شاخص SPI تاکنون از روش‌های کلاسیکی همچون روش حداکثر درست‌نمایی^۲ استفاده شده است، در صورتی که اخیراً روش‌های فرآکاوشی^۳ نیز به عنوان ابزار تخمین پارامتر مورد استفاده قرار می‌گیرد. یکی از این روشها، الگوریتم ژنتیک^۴ است که در بهینه‌سازی و تخمین پارامترهای مدل‌های هیدرولوژیکی کاربرد فراوان دارد و از سال ۱۹۹۰ تاکنون در زمینه‌های مختلفی از مهندسی آب استفاده شده است که برای نمونه به چند مورد اخیر اشاره می‌شود.

¹ Standardized precipitation index (SPI)

² Maximum Likelihood (ML)

³ Metaheuristic methods

⁴ Genetic Algorithm (GA)

⁵ Karahan et al.

⁶ Chen et al.

⁷ Mohan

⁸ Vijayalakshmi

نهایت به این نتیجه رسیدند که مدل مذکور نسبت به مدل‌های سری زمانی کلاسیک و همچنین استفاده از شبکه عصبی تنها، کارایی بالاتری دارد [۱۴]. کیسی^۵ برای پیش‌بینی جریان متناوب رودخانه طی یک روز آینده از مدل شبکه عصبی- موجکی استفاده نمود و نتیجه گرفت که ترکیب شبکه عصبی و تبدیل موجک، باعث بهبود خواص آن نسبت به شبکه عصبی تنها می‌شود، به‌طوری که جذر میانگین مربع خطاهای در حدود ۶۵ تا ۷۴ درصد و میانگین مطلق خطاهای حدود ۱۲ تا ۴۳ درصد و ضریب تبیین حدود ۱۱ تا ۴۷ درصد کاهش داشته‌اند [۱۵]. پارتال^۶ و سیگیزاغلو^۷ از مدل ترکیبی شبکه عصبی- موجکی برای پیش‌بینی بارش روزانه در ترکیه استفاده نمودند. نتایج تحقیق مذکور نشان داد که مدل ترکیبی قابلیت برازش بهتری را بر داده‌های مشاهداتی دارد، مخصوصاً برای ماههای تابستان با بارش صفر و همچنین ماههای دیگر که بارش حداکثری اتفاق می‌افتد. همچنین از مقایسه مدل ترکیبی با مدل شبکه عصبی معمولی و مدل رگرسیون خطی چنین نتیجه‌گیری می‌شود که کارایی مدل‌های اشاره شده از مدل ترکیبی کمتر است [۱۶].

همان‌گونه که اشاره شد در این تحقیق استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی- موجکی برای پیش‌بینی خشکسالی مد نظر بود که برای انجام این منظور از داده‌های بارندگی ماهانه ایستگاه هواشناسی شهر تبریز استفاده شد و در نهایت نتایج حاصل با مدل شبکه عصبی مورد مقایسه و ارزیابی قرار گرفت.

۲- مواد و روشها

۱-۲- منطقه مطالعاتی

تبریز یکی از شهرهای بزرگ ایران و مرکز استان آذربایجان شرقی است. این شهر با مساحتی در حدود ۱۴۰ کیلومتر مربع، بزرگ‌ترین شهر منطقه شمال غرب کشور است که در ۴۶ درجه و ۲۵ دقیقه طول شرقی، و ۳۸ درجه و ۲ دقیقه عرض شمالی از نصف النهار مبدأ واقع شده است. شهر تبریز از سمت شمال، جنوب و شرق به کوهستان و از سمت غرب به زمین‌های هموار و شوره‌زارهای تالخه رود محدود شده و به شکل یک چاله نسبتاً بزرگ و یا یک جلگه بین کوهی درآمده است. ارتفاع این شهر از سطح دریا بین ۱۳۵۰ تا ۱۵۵۰ متر در نقاط مختلف آن متغیر بوده و شیب عمومی زمین‌های تبریز به سمت مرکز شهر و سپس به سمت مغرب است. در این تحقیق از آمار بارندگی ماهانه ۴۰ ساله، مربوط به سالهای ۱۹۶۵ تا ۲۰۰۴ از ایستگاه هواشناسی شهر تبریز استفاده گردید.

⁵ Kisi

⁶ Partal

⁷ Cigizoglu

روشهای متعدد آماری مورد استفاده قرار گرفته است ولی در سالهای اخیر استفاده از مدل ترکیبی شبکه عصبی- موجکی، توجه بسیاری از محققان را به خود جلب نموده است.

کیم^۸ والدنس^۹ از مدل ترکیبی شبکه عصبی- موجکی به پیش‌بینی خشکسالی حوضه‌ای در ایالت مکزیکو آمریکا پرداختند. برای انجام این منظور پس از محاسبه شاخص خشکسالی پالمر و تجزیه آن به زیر مؤلفه‌ها توسط تبدیل موجک، از این زیر مؤلفه‌ها به عنوان ورودی در شبکه عصبی استفاده گردیده است. در نهایت از مقایسه مدل ترکیبی مذکور با سایر روش‌های آماری و همچنین مدل شبکه عصبی، چنین نتیجه گرفتند که مدل ترکیبی، توانایی خوبی در پیش‌بینی و تخمین خشکسالی را دارا است [۱۰]. ونگ^{۱۰} و دینگ^{۱۱} برای پیش‌بینی سری‌های زمانی کوتاه مدت و بلند مدت هیدرولوژیکی از مدل ترکیبی شبکه عصبی- موجکی استفاده نمودند. آنها برای انجام این کار از سری‌های زمانی تراز ماهانه آب زیرزمینی و جریان روزانه رودخانه‌ای در چین بهره جستند و به این نتیجه رسیدند که مدل ترکیبی، باعث افزایش دقت و صحت پیش‌بینی می‌شود [۱۱].

ابریشم‌چی و همکاران از مدل تلفیقی شبکه عصبی مصنوعی و تبدیلات موجک برای پیش‌بینی^{۱۲}،^{۱۳} و ۶ ماهه خشکسالی استفاده نمودند. در مدل تلفیقی پیشنهاد شده، نخست شاخص خشکسالی مؤثر ماهانه توسط تبدیلات موجک به زیر مؤلفه‌ها تجزیه شده و سپس این زیر مؤلفه‌ها به کمک مدل‌های شبکه عصبی پیش‌بینی گردیده است. برای ساخت الگوی ورودی شبکه از بارش ماهانه نیز بهره گرفته شده است. نتایج بدست آمده از مدل تلفیقی برای چهار ایستگاه واقع در حوضه آبریز سد زاینده رود، نشان دهنده کارایی مدل فوق در بهبود دقت پیش‌بینی خشکسالی نسبت به مدل شبکه عصبی بوده است [۱۲]. راهنما و نوری با استفاده از مدل ترکیبی شبکه عصبی- موجکی به پیش‌بینی جریان رودخانه‌ای به کمک داده‌های بارش- رواناب حوضه هلیل رود کرمان پرداختند. نتایج آنها نشان داد که این مدل، توانایی‌های مدل شبکه عصبی را به مقدار قابل توجهی افزایش می‌دهد و سبب عملکرد بهتر پیش‌بینی می‌شود. بر این اساس می‌توان چنین فرض نمود که قابلیت مدل ترکیبی در تخمین جریان حداکثر رودخانه‌ای، به منظور طراحی سازه‌های هیدرولوژیکی در سدسازی بسیار مفید و مؤثر خواهد بود [۱۳].

نورانی و همکاران از مدل ترکیبی شبکه عصبی- موجکی برای مدلسازی بارش حوضه لیقوان چای تبریز استفاده نمودند و در

¹ Kim

² Valdes

³ Wang

⁴ Ding

جدول ۱- طبقه‌بندی خشکسالی بر اساس شاخص SPI

| شدت خشکسالی | مقادیر شاخص |
|-------------------|----------------|
| ترسالی خیلی شدید | ۰/۲ و بیشتر |
| ترسالی شدید | ۰/۹۹ تا ۱/۵۰ |
| ترسالی ملایم | ۰/۹۹ تا ۱/۴۹ |
| نرده‌کی به نرمال | -۰/۹۹ تا ۰/۹۹ |
| خشکسالی ملایم | -۱/۴۹ تا -۱/۰۰ |
| خشکسالی شدید | -۱/۹۹ تا -۱/۵۰ |
| خشکسالی خیلی شدید | -۰/۲ کمتر |

۲-۳- الگوریتم ژنتیک

تفکر اصلی الگوریتم ژنتیک از نظریه تکامل داروین گرفته شده است. نظریه داروین بیانگر این نکته است که آن دسته از خصوصیات و صفاتی در طبیعت پایدار می‌مانند که با قانون طبیعت سازگاری بیشتری داشته باشند و هر چه این سازگاری بیشتر باشد شناس ادامه حیات آن بیشتر است. به این ترتیب می‌توان دید که طبیعت با بهره‌گیری از یک روش بسیار ساده (حذف تدریجی گونه‌های نامناسب و در عین حال تکثیر بالاتر گونه‌های بهینه) توانسته است، دائماً هر نسل را از لحاظ خصوصیات مختلف ارتقا بخشد [۲۱].

روندهای حل مسائل توسط الگوریتم ژنتیک به این گونه است که ابتدا تعدادی از جوابهای شدنی مسئله مورد نظر را به صورت تصادفی و یا گاهی به صورت از قبل تعیین شده، به عنوان جمعیت اولیه انتخاب می‌کند و سپس هر یک از جوابها به صورت رشته‌هایی که کروموزوم نامیده شده، کدگذاری می‌شوند، برای تولید نسل بعدی از روی نسل فعلی، از عملگرهای ژنتیکی شامل انتخاب، ترکیب، باز تولید، جهش و دیگر عملگرهای احتمالی استفاده می‌شود. انتخاب، روندی است که اگر کروموزومی دارای لیاقت بالاتری باشد، شناس خود را برای بقا در سیستم افزایش می‌دهد. در عملگر انتخاب، والدین به صورت زوج درآمدند، به این ترتیب که هر کروموزوم با یک کروموزوم دیگری که به صورت تصادفی انتخاب می‌شود، ترکیب می‌گردد تا نسل جدید را ایجاد کند. در عملگر باز تولید، کروموزومی از نسل فعلی، مستقیماً و بدون تغییر به نسل بعدی منتقل می‌شود. عملگر جهش، مکانیسمی است که در اثر آن یک تغییر غیر سازمان یافته و کاملاً تصادفی به یک رشته داده می‌شود، پس از مراحل فوق، جمعیت جدیدی جایگزین جمعیت پیشین می‌شود و این چرخه ادامه می‌یابد. هنگامی جستجو نتیجه بخش خواهد بود که به حداقل نسل مورد نظر رسیده و یا همگرایی حاصل شده باشد، یا زمان اجرای برنامه از یک مقدار معینی تجاوز کند و یا با گذشت چند نسل، بهبودی در لیاقت جمعیت ایجاد نشود [۲۱].

۲-۴- شاخص بارندگی استاندارد شده

با توجه به بررسی تأثیرات متفاوت بارش بر روی آبهای زیرزمینی، ذخایر و منابع آبهای سطحی، رطوبت خاک، پوشش‌های برفی و جریان آبراهه‌ها، مکانیکی و همکاران^۱ در سال ۱۹۹۳ شاخص جدیدی را به نام SPI به منظور پایش وضعیت خشکسالی توسعه دادند [۱۷]. شاخص SPI با مقایسه کل بارندگی تجمعی برای ایستگاه یا ناحیه‌ای خاص در یک فاصله زمانی مشخص با میانگین دارای مدت بارندگی برای همان فاصله زمانی در طول دوره آماری به دست می‌آید. مشخصه اصلی SPI، انعطاف‌پذیری در اندازه‌گیری خشکسالی در مقیاسهای زمانی متفاوت است زیرا خشکسالی‌ها از لحاظ مدت، بسیار گسترده هستند. بنابراین تشخیص و پیش‌بینی آنها با انواع مقیاسهای زمانی مهم است. مقیاس زمانی، اثرات خشکسالی را بر روی میزان توانایی منابع آب نشان می‌دهد. کمبود بارش در مقیاس زمانی کوتاه مدت عمدتاً بر روی وضعیت رطوبت خاک اثر می‌گذارد، در صورتی که کمبود بارش در مقیاس زمانی طولانی مدت اغلب بر آبهای زیرزمینی، جریان رودخانه و ذخایر و منابع آب تأثیرگذار است. با توجه به این موضوع مکانیکی و همکاران مقیاسهای زمانی ۰/۲۴، ۰/۱۲، ۰/۴۸ ماهه را برای تحلیل خشکسالی مدنظر قرار دادند [۱۸].

محاسبه SPI به این ترتیب انجام پذیرفت که ابتدا سری زمانی داده‌های بارندگی ماهانه در بازه‌های زمانی ۰/۴۸، ۰/۲۴، ۰/۱۲، ۰/۶، ۰/۳ ماهه تشکیل داده شد و سپس هر یک از سری‌های زمانی با مقیاس زمانی متفاوت، با توزیع گاما برآش داده شدند تا احتمال تجمعی بارندگی برای ماه معین و مقیاس زمانی مشخص، به دست آید. تابع چگالی احتمال^۲ توزیع گاما به صورت زیر است [۱۹]

$$f(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \quad (1)$$

که در این رابطه

$x \geq 0$ مقدار بارندگی، $\alpha > 0$ پارامتر شکل^۳، $\beta > 0$ پارامتر مقیاس^۴ و $\Gamma(\alpha)$ تابع گاما هستند.

این احتمال سپس به متغیر تصادفی نرمال Z، تبدیل گردید که یک مقدار نرمال شده با میانگین صفر و انحراف معیار یک است. از این‌رو در حقیقت SPI مقدار انحرافات استانداردی است که یک رویداد مشخص از شرایط نرمال منحرف می‌شود. به این ترتیب طبقه‌بندی خشکسالی بر اساس مقادیر SPI در جدول ۱ ارائه شده است [۲۰].

¹ McKee et al.

² Probability density function (pdf)

³ Shape parameter

⁴ Scale parameter

برای پیش‌بینی سری‌های زمانی در هیدرولوژی مورد استفاده قرار می‌گیرد. مدل ریاضی مورد استفاده برای بیان مقدار یک خروجی از شبکه عصبی، توسط رابطه زیر ارائه می‌شود [۱۰]

$$\hat{y}_k = f_0 \left[\sum_{j=1}^m w_{kj} \cdot f_h \left(\sum_{i=1}^n w_{ij} x_i + w_{jo} \right) + w_{ko} \right] \quad (2)$$

که در این رابطه

n تعداد کل نرون‌های لایه ورودی، m تعداد کل نرون‌های لایه میانی، k تعداد کل نرون‌های لایه خروجی، f_0 تابع حرک مورد استفاده در لایه میانی، f_h تابع حرک مورد استفاده در لایه میانی، w_{kj} مقدار وزن اریب نرون j ام لایه میانی، w_{jo} مقدار وزن اریب نرون j ام لایه خروجی، w_{ko} مقدار وزنی است که به نرون k ام لایه ورودی اختصاص داده می‌شود تا بر اساس آن، نرون k ام لایه میانی به دست آید. w_{kj} مقدار وزنی است که به نرون k ام لایه میانی اختصاص داده می‌شود تا بر اساس آن نرون k ام لایه خروجی به دست آید.

برای اینکه شبکه عصبی بتواند خروجی را تا حد امکان به هدف نزدیک کند، به فرایند آموزش نیاز دارد. آموزش عبارت است از پیدا کردن مناسب‌ترین بردار وزن و بردار اریب و کمینه کردن تابع خطابین داده‌های محاسباتی (خروجی) و داده‌های مشاهداتی (هدف) که معمولاً از رابطه میانگین مرربع خطاهای^۱ استفاده می‌شود. یکی از الگوریتم‌های آموزشی، روش انتشار برگشتی^۲ است که با به دست آوردن مقدار وزن‌های اصلاح شده در هر مرحله، سبب بهبود نتایج می‌شود. در نهایت بعد از اینکه آموزش پایان یافته، شبکه برای دادن جوابهای منطقی به داده‌های جدید توانا می‌شود.

۵-۲- تبدیل موجک

موجک، یک موج کوچک است که انرژی آن در ناحیه کوچکی متتمرکز شده و ابزار مناسبی برای بررسی پدیده‌های گذرا^۳ است. موجک نوسان حداقلی دارد که به سمت صفر نزول می‌کند و این نزول باید در جهات مثبت و منفی واقع در دامنه‌اش محدود شود. این مشخصه باعث می‌شود که موجک انتعطاف‌پذیر بوده و مانند یک تابع رفتار کند. لذا با توجه به رفتارهای موجی نامنظم پدیده‌های هیدرولوژیک، قابلیت مدل‌سازی این پدیده‌ها توسط امواج نامنظم (موجک‌ها) نسبت به امواج منظم (امواج سینوسی) بیشتر است [۲۲].

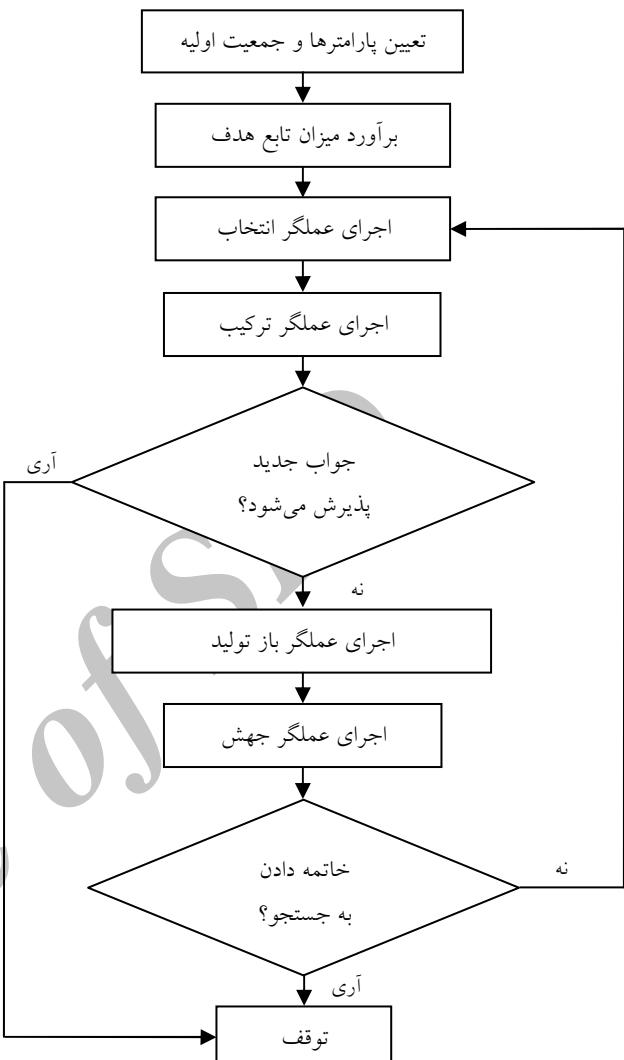
تابع موجک دارای دو ویژگی مهم نوسانی و کوتاه مدت بودن است.

² Mean square error (MSE)

³ Back propagation

⁴ Non stationary

شکل ۱ ساختار پایه‌ای الگوریتم ژنتیک را در یک نمای کلی نشان می‌دهد.



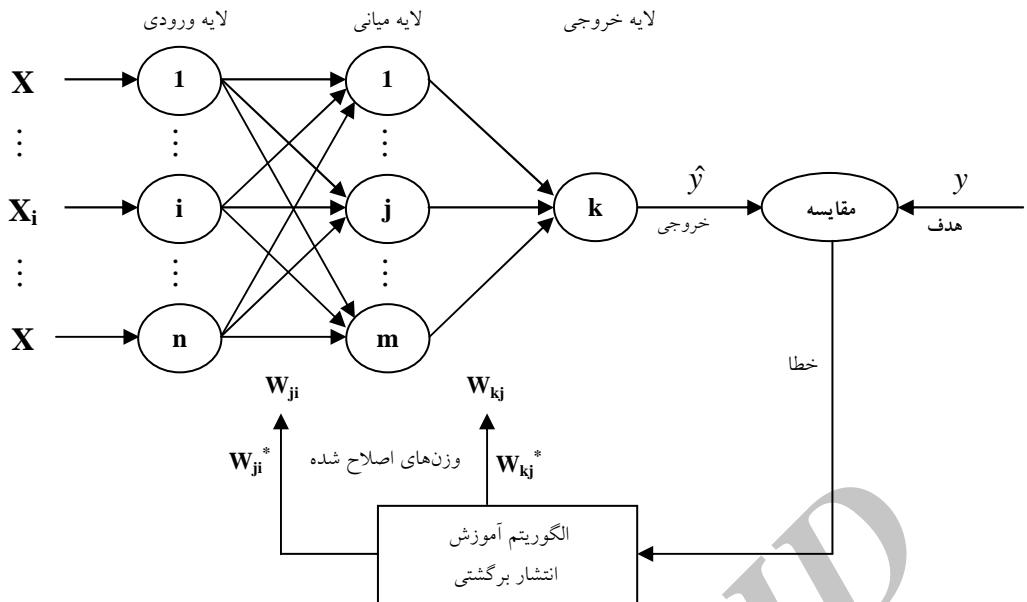
شکل ۱- ساختار پایه‌ای الگوریتم ژنتیک

۴-۲- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی روشی بر پایه پردازش اطلاعات و داده‌ها است که بر اساس سیستم مغز و اعصاب انسان و عملکرد آنها شبیه‌سازی شده است. در این مدل اجزای کوچکی به نام نرون، وظیفه پردازش اطلاعات را به عهده دارند. این نرون‌ها به یکدیگر متصل شده و بسته به چگونگی این اتصالات، شبکه‌ها و مدل‌های مختلفی به وجود می‌آیند.

شکل ۲ یک مدل شبکه عصبی پیش‌خور^۱، متشکل از سه لایه ورودی، میانی (یا مخفی) و خروجی را نشان می‌دهد که معمولاً

¹ Feed forward



شکل ۲- ساختار شماتیک شبکه عصبی پیش خور- الگوریتم انتشار برگشتی

که در آن $\bar{\Psi}(t)$ تابعی مرکب از (t) است. همچنین برای به دست آوردن تبدیل موجک گستته^۱، با جاگذاری مقادیر a_0^j . $a = a_0^j$. $b \in R$. $j \in Z$. $a_0 > 1$. $b = kb_0a_0^j$ در رابطه بالا رابطه حاصل می‌گردد

$$CWT(j, k) = W_\Psi f(j, k) = a_0^{-j/2} \int_{-\infty}^{+\infty} f(t) \bar{\Psi}(a_0^{-j}t - kb_0) dt \quad (6)$$

در این تحقیق از تبدیل موجک ناپیوسته در به دست آوردن ضرایب موجک استفاده شد. همچنین موجکهای مادر مورد استفاده عبارت بودند از موجکهای ^۵db4, ^۶dmey, ^۷coif5 و ^۸sym4 که همگی به طور گسترده در تبدیلهای موجک به کار گرفته می‌شوند.

۶-۲- معیار نیکویی برازش
به منظور بررسی صحت نتایج خروجی که در واقع بیان کننده اختلاف بین داده‌های مشاهداتی و محاسباتی است، از معیارهای متفاوتی استفاده می‌گردد. معیارهای نیکویی برازش به دو صورت گرافیکی^۹ و آماری^۱ هستند که هر کدام از آنها ویژگی‌های منحصر

در تابع موجک (t) ، که به آن موجک مادر نیز گفته می‌شود، باید شرط زیر ارضاء شود

$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0 \quad (3)$$

تابع موجک مادر توسط دو عملگر انتقال^۱ و مقیاس^۲ در طول سیگнал مورد تحلیل، تغییر اندازه و تغییر محل می‌یابند و به صورت زیر بیان می‌گردد [۱۵]

$$\Psi_{a,b}(t) = |a|^{-1/2} \Psi\left(\frac{t-a}{b}\right), \quad b \in R, a \in R, a \neq 0 \quad (4)$$

که در آن a پارامتر مقیاس یا فرکانس، b پارامتر انتقال یا زمان و R محدوده اعداد حقیقی است.

تبدیل موجک در دو نوع پیوسته و گستته در زمان به کار می‌رود. اختلاف انواع مختلف تبدیل موجک، مربوط به روشهای است که مقیاس و انتقال را پیاده سازی می‌کند. برای یک سری زمانی با تابع $f(t)$ ، تبدیل موجک پیوسته^۳ آن به صورت زیر است

$$CWT(a, b) = W_\Psi f(a, b) = |a|^{-1/2} \int_{-\infty}^{+\infty} f(t) \bar{\Psi}\left(\frac{t-b}{a}\right) dt \quad (5)$$

$$CWT(a, b) = W_\Psi f(a, b) = |a|^{-1/2} \int_{-\infty}^{+\infty} f(t) \bar{\Psi}\left(\frac{t-b}{a}\right) dt$$

¹ Translation

² Dilation

³ Continuous Wavelet Transform (CWT)

⁴ Discrete wavelet transform (DWT)

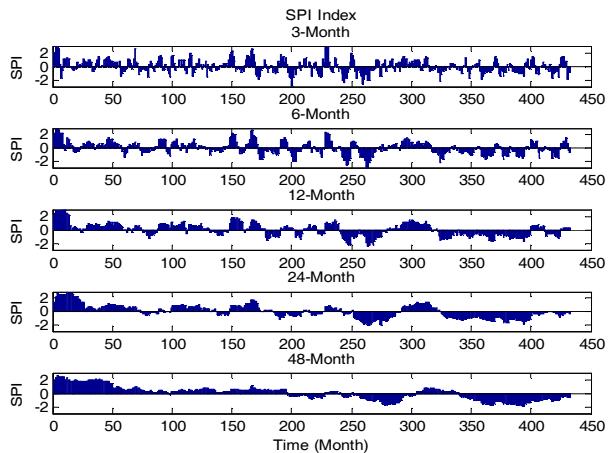
⁵ Daubechies wavelet

⁶ Discrete approximation of meyer wavelet

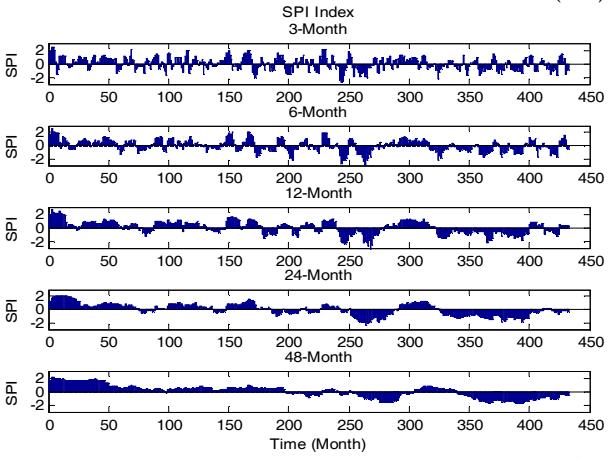
⁷ Coiflets wavelet

⁸ Symlets wavelet

⁹ Graphical display



(الف)



(ب)

شکل ۳- روند تغییرات شاخص بارندگی استاندارد شده در مقیاس‌های زمانی مختلف (الف) ML (ب) GA

رخداد خشکسالی به دست آمده از دو مدل، نشان می‌دهند که تعداد رویدادهای خشکسالی بر اساس شاخص SPI با بازه‌های زمانی مختلف، از خشکسالی ملایم به طرف خشکسالی حاد، روند کاهشی داشته است. یعنی احتمال وقوع خشکسالی شدید و حاد، نسبت به دیگر خشکسالی‌ها کمتر است.

از شکل ۴ می‌توان چنین نتیجه گرفت که اولاً روش GA در مقایسه با روش ML جوابهای بهتری را نتیجه می‌دهد. علت را می‌توان به کاربرد موفقیت‌آمیز الگوریتم ژنتیک در تخمین پارامتر نسبت داد که با استفاده از راهکارهای مختلف تعیین شایستگی، از گیرافتادن در نقطه‌های بهینه محلی رهایی می‌یابند و در نهایت به بهینه‌ترین جواب ممکن دست می‌یابند. ثانیاً با افزایش بازه زمانی، ضرایب راندمان به دست آمده از شاخص SPI، افزایش می‌یابد و همچنین اختلاف ضرایب راندمان بین دو روش کاهش پیدا می‌کند. یعنی اختلاف بین روش GA و روش ML در حدود ۱ تا ۲ درصد تغییر می‌کند. علت را می‌توان چنین بیان نمود که SPI با بازه

به خود را داشته و به منظور خاصی به کار می‌رond. از آنجا که روش گرافیکی روش دقیقی نیست و بسته به نظر اشخاص، نتایج متفاوتی به دست می‌آید، بنابراین از معیارهای آماری استفاده می‌شود. معیارهای آماری با استفاده از روابط آماری برای تعیین خطای بین داده‌های مشاهداتی و محاسباتی انجام می‌گیرد که در این تحقیق از ضریب راندمان (بازده)^۱ استفاده شد [۸]

$$E = 1 - \frac{\sum_{i=1}^n (X_{oi} - X_{ci})^2}{\sum_{i=1}^n (X_{oi} - \bar{X}_0)^2}, \quad -\infty < E \leq 1 \quad (7)$$

که در این رابطه E ضریب راندمان، n تعداد کل داده‌ها، X_{oi} داده‌های مشاهداتی، X_{ci} داده‌های محاسباتی و \bar{X}_0 میانگین داده‌های مشاهداتی است.

۳- نتایج و بحث

در این تحقیق ابتدا به بررسی و تحلیل نتایج حاصل پایش خشکسالی با استفاده از شاخص SPI (در مقیاس‌های زمانی ۳، ۶، ۱۲ و ۲۴ و ۴۸ ماهه) در شهر تبریز پرداخته شد. همان‌طوری که قبل از ذکر شد، برای محاسبه شاخص بارندگی استاندارد شده از برآذش توزیع احتمال گاما بر داده‌های دراز مدت بارندگی ماهانه استفاده می‌شود که تابع حاصل برای به دست آوردن احتمال تجمعی بارندگی برای یک ایستگاه و در مقیاس زمانی مشخص به کار می‌رود. با توجه به انتخاب روش تخمین پارامترهای توزیع گاما، می‌توان نتایج متفاوتی را به دست آورد که در این تحقیق از دو روش حداکثر درست‌نمایی و الگوریتم ژنتیک برای تخمین پارامترها استفاده شد که نتایج حاصل از آنها در شکل‌های ۳ و ۴ ارائه شده است. قابل توجه اینکه تابع هدف مورد استفاده در الگوریتم ژنتیک به صورت زیر بیان می‌شود که متغیرهای مورد استفاده در آن در رابطه ۷ آورده شده است [۸]

$$\text{Minimize} \left(\frac{\sum_{i=1}^n (X_{oi} - X_{ci})^2}{\sum_{i=1}^n (X_{oi} - \bar{X}_0)^2} \right) \quad (8)$$

با توجه به شکل ۳، سالهای آماری ۱۹۹۰ تا ۱۹۹۱ بر اساس شاخص SPI کوتاه مدت (۳ و ۶ ماهه) و سالهای ۱۹۹۸ تا ۲۰۰۲ بر اساس شاخص SPI بلند مدت (۱۲، ۲۴ و ۴۸ ماهه) به عنوان سالهای بحرانی شناخته می‌شوند. همچنین فراوانی‌های رخداد

¹ Statistical test criteria

² Efficiency coefficient

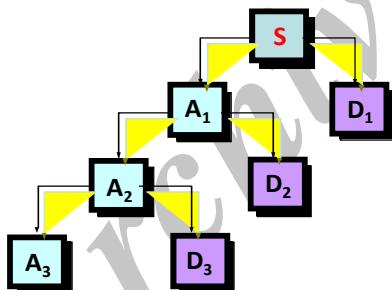
بر اساس مدل شبکه عصبی (مدل ۱)، از شبکه پیشرو-انتشار برگشتی که توسط الگوریتم لونبرگ-مارگارت^۱ آموزش دیده شده است، برای پیش‌بینی خشکسالی استفاده شد.تابع محرك از نوع tansig بوده و مدل از سه لایه ورودی، میانی و خروجی تشکیل شد. بر این اساس، ضرایب راندمان در دو مرحله واسنجی و صحبت‌سنجی مدل، برای شاخص SPI با بازه‌های زمانی مختلف به دست آمد که بهترین نتایج حاصله در جدول ۲ آورده شده است.

مدل ترکیبی شبکه عصبی-موجکی (مدل ۲). از لحاظ الگوریتم آموزش، تابع محرك و تعداد لایه‌های شبکه، همانند مدل ۱ است، با این تفاوت که داده‌ها قبل از ورود به شبکه عصبی، توسط تبدیل موجک، پیش‌پردازش شده و سپس وارد شبکه عصبی می‌شوند. در هنگام استفاده از تبدیل موجک به دو مورد باید توجه تجزیه.

نتایج انتخاب نوع تابع موجک، ب) تعیین درجه تجزیه. در مورد انتخاب نوع تابع موجک از طریق سعی و خطأ و استفاده از توابع مختلف، می‌توان به این مهم دست یافت، در صورتی که در مورد تعیین درجه تجزیه، می‌توان از فرمول پیشنهادی زیر استفاده نمود [۱۱ و ۲۳]

$$l = \text{int}[\log(N)] \quad (10)$$

که N بهترین طول سری زمانی و درجه تجزیه هستند. با توجه به اینکه در این تحقیق، $N=422$ بود، بنابراین درجه تجزیه برابر ۳ به دست آمد. در شکل ۵ شماتیک تجزیه سری زمانی داده‌های مشاهداتی (S) نشان داده شده است.



$$\begin{aligned} S &= A_1 + D_1 \\ A_1 &= A_2 + D_2 \\ A_2 &= A_3 + D_3 \\ S &= A_3 + D_3 + D_2 + D_1 \end{aligned}$$

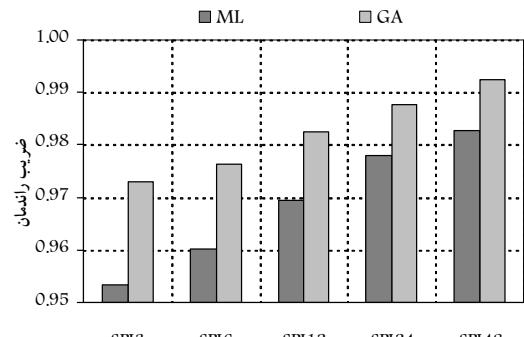
شکل ۵-نمایش تجزیه سری زمانی توسط تبدیل موجک
(درجه تجزیه: ۳)

شکل ۵ نشان دهنده تجزیه یک سیگنال به دو مؤلفه تقریبها^۲ و جزئیات^۳ است که در واقع تقریبها، فیلترهای پایین‌گذر و جزئیات، فیلترهای بالاگذر را تداعی می‌کنند. به عبارت دیگر فرکانس‌های بالا و اغتشاشات، بیشتر خود را در جزئیات نشان می‌دهند و

¹ Levenberg- Marquardt (LM)

² Approximations

³ Details



شکل ۴-نمودار مقدار ضرایب راندمان

زمانی کمتر، نسبت به تغییرات بارش حساس است و در طول زمان وقوع، از پراکندگی بیشتری در منطقه برخوردار است، در حالی که با افزایش بازه زمانی، تغییرات بارش و بالطبع پراکندگی شاخص خشکسالی کمتر بوده و از یکنواختی بهتری برخوردار است. بنابراین هرچه تغییرات بارش بیشتر باشد، خطای بین داده‌های مشاهداتی و محاسباتی نیز بیشتر می‌شود و بر عکس.

در فرایند مدلسازی برای پیش‌بینی خشکسالی از دو مدل استفاده شد که مدل اول فقط بر اساس شبکه عصبی و مدل دوم بر اساس مدل ترکیبی شبکه عصبی-موجکی بود. متغیرهایی که برای پیش‌بینی خشکسالی به کار می‌روند شامل مقادیر شاخص بارندگی استاندارد شده هستند که توسط الگوریتم ژنتیک محاسبه شده‌اند. تمامی موارد مذکور، با استفاده از جعبه افزار مربوط به روش‌های الگوریتم ژنتیک، موجک و شبکه عصبی مصنوعی در نرم افزار MATLAB نسخه 7.6 انجام گرفت.

از میان داده‌های شاخص SPI با بازه‌های زمانی مختلف (۳، ۶، ۱۲، ۲۴ و ۴۸ ماهه) و در طی دوره آماری ۴۰ ساله، ۷۵ درصد داده‌ها برای واسنجی مدل و ۲۵ درصد بقیه برای صحبت‌سنجی مدل استفاده شد. بر این اساس ابتدا برای هر بازه زمانی، داده‌های شاخص مطابق رابطه زیر نرمال شده، سپس شاخصهای ماهه‌ای گذشته به عنوان ورودی و شاخصهای ماهه‌ای آتی به عنوان خروجی در شبکه عصبی مورد استفاده قرار گرفتند.

$$\begin{cases} Y_i = \frac{X_{oi}}{X_{o\max}}, X_{oi} \geq 0 \\ Y_i = \frac{X_{oi}}{|X_{o\min}|}, X_{oi} < 0 \end{cases} \quad (9)$$

که در این رابطه

X_{oi} مقادیر استاندارد شده، $X_{o\max}$ مقادیر شاخص مشاهداتی، $X_{o\min}$ حداقل مقادیر شاخص مشاهداتی و $X_{o\max}$ حداقل شاخص مشاهداتی هستند.

جدول ۴- مقایسه مقدار ضرایب راندمان به دست آمده از دو مدل

| مدل ۲ | مدل ۱ | شاخص | مرحله | پیش‌بینی خشکسالی |
|-------|-------|-------|----------|------------------|
| ۰/۷۹ | ۰/۴۵ | SPI3 | | |
| ۰/۸۵ | ۰/۷۱ | SPI6 | | |
| ۰/۹۰ | ۰/۸۵ | SPI12 | واسنجه | |
| ۰/۹۶ | ۰/۹۲ | SPI24 | | |
| ۰/۹۸ | ۰/۹۷ | SPI48 | | |
| ۰/۷۲ | ۰/۳۱ | SPI3 | | |
| ۰/۸۰ | ۰/۶۱ | SPI6 | | |
| ۰/۸۵ | ۰/۷۵ | SPI12 | صحت‌سنجه | |
| ۰/۹۱ | ۰/۸۷ | SPI24 | | |
| ۰/۹۷ | ۰/۹۳ | SPI48 | | |

از جدول مذکور می‌توان چنین نتیجه گرفت که در شاخص SPI با بازه زمانی کمتر، اختلاف مقدار ضرایب راندمان دو مدل بیشتر بوده و به تدریج با افزایش بازه زمانی، اختلاف کمتر می‌شود. همچنین با افزایش بازه زمانی، ضرایب راندمان به دست آمده از شاخص SPI در دو مدل شبکه عصبی، افزایش می‌یابد. علت را می‌توان به نوسانات بیشتر بارش و شاخص SPI در بازه زمانی کمتر مرتبط دانست که باعث عملکرد ضعیف شبکه عصبی تنها (مدل ۱) می‌شود. ولی از آنجا که در شبکه عصبی ترکیبی (مدل ۲) بر روی داده‌ها پردازش صورت می‌گیرد، سپس داده‌های تجزیه شده و با فرکانس‌های مختلف وارد شبکه عصبی می‌شوند، بنابراین از کارایی بالاتری برخوردار هستند.

همچنین موجک sym4 به لحاظ دارا بودن شکل هندسی مناسب برای سری‌های زمانی خشکسالی، جوابهای مناسب‌تری نسبت به سه موجک دیگر مورد استفاده در مدل ۲ (db4, db5 و dme4) (coif5) را نتیجه می‌دهد.

نمودارهای دو مرحله واسنجی و صحت‌سنجه، برای پیش‌بینی خشکسالی به روش شبکه عصبی-موجکی و با استفاده از تابع موجک sym4، در شکل ۶ آورده شده است.

با توجه به شکل ۶ هر چه بازه زمانی شاخص SPI افزایش پیدا کند، اغتشاشات سیگنال کاهش یافته و در نتیجه فیلترهای پایین‌گذر، دارای اغتشاشات کمی خواهد بود که با استفاده در شبکه عصبی مصنوعی به عنوان ورودی، حاصلی هموارتر و منطبق‌تر با داده‌های شاخص اندازه‌گیری شده خواهد داشت.

جدول ۲- نتایج مدل ۱ برای شاخص SPI با بازه‌های زمانی مختلف

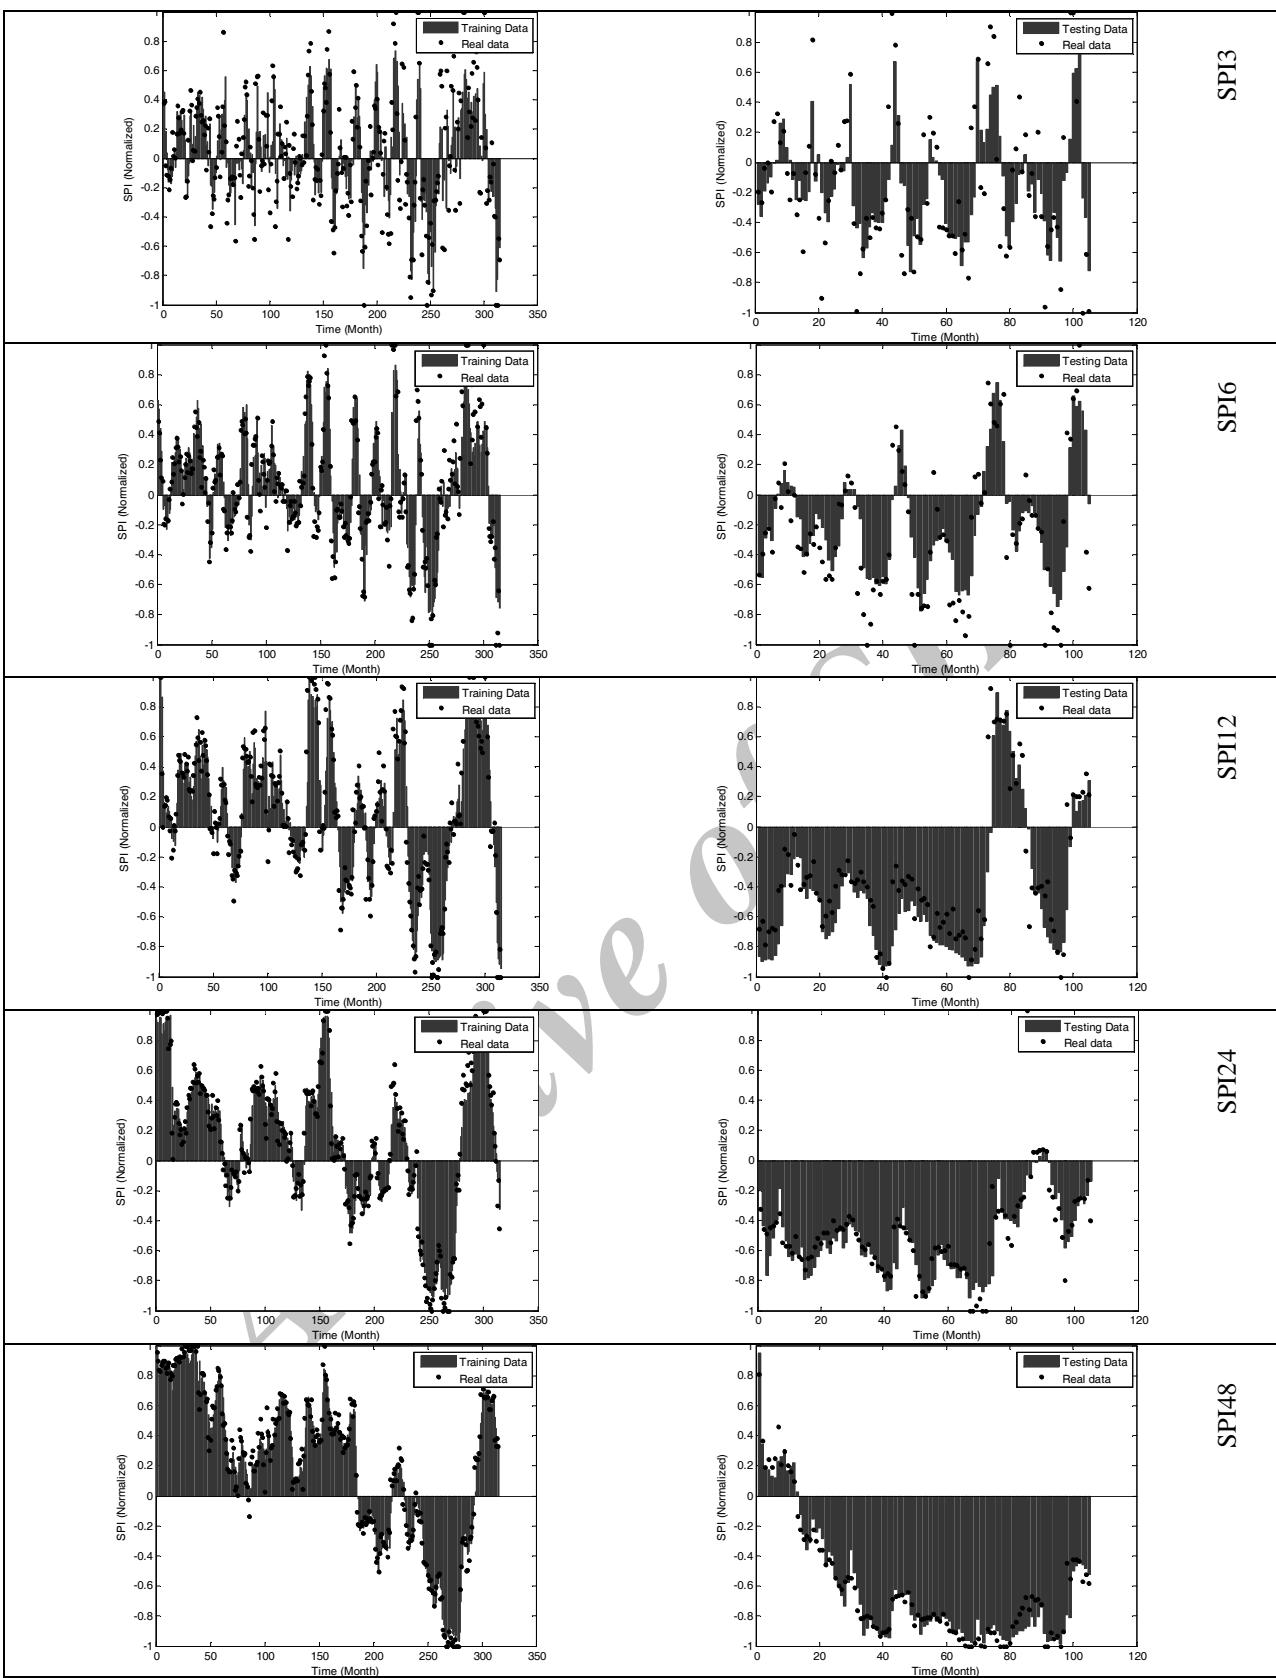
| شاخص | ساختمان شبکه | ضریب راندمان | آزمون آموزش |
|------|--------------|--------------|-------------|
| | | ۱-۴-۱ | ۰/۳۰۹۱ |
| | | ۱-۴-۱ | ۰/۴۵۴۳ |
| | | ۱-۴-۱ | ۰/۷۰۶۸ |
| | | ۱-۴-۱ | ۰/۸۴۹۴ |
| | | ۱-۴-۱ | ۰/۹۱۵۵ |
| | | ۱-۴-۱ | ۰/۹۶۷۸ |
| | | SPI3 | ۰/۷۵۳۳ |
| | | SPI6 | ۰/۸۶۸۵ |
| | | SPI12 | ۰/۹۲۶۱ |
| | | SPI24 | |
| | | SPI48 | |

فرکانس‌های پایین و تغییرات اقلیمی هموار و طولانی مدت، خود را در تقریبها نمایان می‌سازند. همچنین با استفاده از توابع موجک مختلف، نتایج متفاوتی از مدل مذکور به دست می‌آید که بهترین آنها در جدول ۳ ارائه شده است.

از جدولهای ۲ و ۳ چنین استنباط می‌شود که در مدل‌های شبکه عصبی مصنوعی (تنها یا ترکیبی) با تعداد کم نرون لایه میانی (یعنی ۴ نرون) می‌توان به جواب مطلوب دست یافت و استفاده از تعداد زیاد نرون لایه میانی، نه تنها نفاوتی در جواب حاصله ایجاد نمی‌کند، بلکه فقط زمان اجرای برنامه را طولانی تر می‌کند. همچنین برای مقایسه بهتر نتایج مربوط به مقدار ضرایب راندمان به دست آمده از مراحل واسنجی و صحت‌سنجه دو مدل شبکه عصبی، از جدول ۴ استفاده گردید.

جدول ۳- نتایج مدل ۲ برای شاخص SPI با بازه‌های زمانی مختلف

| شاخص | ساختمان | نوع | ضریب راندمان | آزمون آموزش | موجک | شبکه |
|------|---------|-------|--------------|-------------|-------|------|
| | | ۴-۴-۱ | | ۰/۷۶۱۵ | dme4 | |
| | | ۴-۴-۱ | | ۰/۷۷۶۰ | db4 | |
| | | ۴-۴-۱ | | ۰/۷۳۱۳ | coif5 | |
| | | ۴-۴-۱ | | ۰/۷۸۶۰ | sym4 | |
| | | ۴-۴-۱ | | ۰/۸۰۰۳ | dme4 | |
| | | ۴-۴-۱ | | ۰/۸۴۱۹ | db4 | |
| | | ۴-۴-۱ | | ۰/۸۴۹۲ | coif5 | |
| | | ۴-۴-۱ | | ۰/۸۵۱۴ | sym4 | |
| | | ۴-۴-۱ | | ۰/۹۰۲۸ | dme4 | |
| | | ۴-۴-۱ | | ۰/۹۰۱۰ | db4 | |
| | | ۴-۴-۱ | | ۰/۹۰۱۷ | coif5 | |
| | | ۴-۴-۱ | | ۰/۹۰۳۹ | sym4 | |
| | | ۴-۴-۱ | | ۰/۹۶۰۷ | dme4 | |
| | | ۴-۴-۱ | | ۰/۹۵۵۰ | db4 | |
| | | ۴-۴-۱ | | ۰/۹۶۰۴ | coif5 | |
| | | ۴-۴-۱ | | ۰/۹۶۱۷ | sym4 | |
| | | ۴-۴-۱ | | ۰/۹۸۱۷ | dme4 | |
| | | ۴-۴-۱ | | ۰/۹۸۰۰ | db4 | |
| | | ۴-۴-۱ | | ۰/۹۸۳۱ | coif5 | |
| | | ۴-۴-۱ | | ۰/۹۸۴۴ | sym4 | |
| | SPI3 | | | | | |
| | SPI6 | | | | | |
| | SPI12 | | | | | |
| | SPI24 | | | | | |
| | SPI48 | | | | | |



شکل ۶- نمودارهای دو مرحله و اسننجی و صحت سنجی مدل ۲ برای شاخص SPI با بازه‌های زمانی مختلف

۵- از میان توابع موجک مورد استفاده در مدل ترکیبی، موجک

به لحاظ دارا بودن شکل هندسی مناسب برای سری های زمانی خشکسالی، جوابهای مناسب تری را نسبت سایر موجکها نتیجه می دهد.

۶- با افزایش بازه زمانی در دو مدل شبکه عصبی، مقدار ضرایب راندمان به دست آمده از شاخص SPI افزایش می یابد. همچنین در شاخص SPI با بازه زمانی کمتر، اختلاف مقدار ضرایب راندمان دو مدل بیشتر بوده و به تدریج با افزایش بازه زمانی، اختلاف کمتر می شود. به عبارت دیگر اختلاف به دست آمده از شاخص SPI ^۳ ماهه و ^{۴۸} ماهه در دو مدل به ترتیب برابر با ^{۴۱} و ^۴ درصد است.

۵- قدردانی

این مقاله با حمایت مالی و اعتبار ویژه پژوهشی دانشگاه تبریز تهیه گردیده است. به این وسیله نویسندهای مقاله از معاونت محترم پژوهش و فناوری دانشگاه تبریز تقدیر و تشکر می نمایند.

۴- نتیجه‌گیری

با توجه به نتایج حاصل در این تحقیق، می توان جمع‌بندی های زیر را ارائه نمود:

۱- شاخص SPI به عنوان یک ابزار مناسب به منظور پایش شرایط خشکسالی قابل استفاده است، زیرا از خصوصیات مهم این شاخص، چند کاره بودن آن است که می تواند برای هر مقیاس زمانی محاسبه شود و خصوصیات خشکسالی را نشان دهد.

۲- برای پایش خشکسالی، استفاده از الگوریتم ژنتیک جوابهای بهتری را نسبت به روش حداکثر درست‌نمایی ارائه می نماید.

۳- از میان دو مدل مورد استفاده برای پیش‌بینی خشکسالی، استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی- موجکی، جوابهای بهتری را نسبت به الگوریتم ژنتیک و مدل شبکه عصبی ارائه می دهد.

۴- در مدل های شبکه عصبی مصنوعی (تنها یا ترکیبی) با تعداد کم نرون لا یه میانی، می توان به جواب مطلوب دست یافته و استفاده از تعداد زیاد نرون لا یه میانی، نه تنها تفاوتی در جواب حاصله ایجاد نمی کند، بلکه فقط زمان اجرای برنامه را طولانی تر می کند.

۶- مراجع

- 1- Loukas, A., Vasiliades, L., and Tzabiras, J. (2007). "Evaluation of climate change on drought impulses in Thessaly, Greece." *European Water*, 17/18, 17-28.
- 2- Yurekli, K., and Kurunc, A. (2004). "Simulation of drought periods using stochastic models." *Turkish J. of Engineering and Environmental Science*, 28, 181-190.
- 3- Wilhite, D.A. (2000). "Drought as a natural hazard: Concepts and definitions." Wilhite, D.A. (ed.). *Drought: A global assessment*, Vol. 1, Routledge, New York, 1-18.
- 4- Hayes, M.J., Svoboda, M.D., Wilhite, D.A., and Vanyarkho, O.V. (1999). "Monitoring the 1996 drought using the standardized precipitation index." *Bulletin of American Meteorological Society*, 80(3), 429-438.
- 5- Karahan, H., Ceylan, H., and Ayvaz, M.T. (2007). "Predicting rainfall intensity using a genetic algorithm approach." *Hydrological Processes*, 21, 470-475.
- 6- Chen, C.S., Liu, C.H., and Su, H.C. (2008). "A nonlinear time series analysis using two-stage genetic algorithms for streamflow forecasting." *Hydrological Processes*, 22, 3697-3711.
- 7- Mohan, S., and Vijayalakshmi, D.P. (2008). "Estimation of Nash's IUH parameters using stochastic search algorithms." *Hydrological Processes*, 22, 3507-3522.
- 8- Hassanzadeh, Y., Abdi, A., Talatahari, S., and Singh, V.P. (2011). "Meta-heuristic algorithms for hydrologic frequency analysis." *Water Resources Management*, 25, 1855-1879.
- 9- Razie, T., Daneshkar Arasteh, P., Akhtari, R., and Saghafian, B. (2007). "Investigation of metrological drought in the Sistan and Baluchestan province." *Using the Standardized Precipitation Index and Markov Chain Model*, 3(1), 25-35.
- 10- Kim, T.W., and Valdes, J.B. (2003). "Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks." *J. of Hydrologic Engineering*, 8(6), 319-328.
- 11- Wang, W., and Ding, J. (2003). "Wavelet network model and its application to the prediction of hydrology." *Nature and Science*, 1(1), 67-71.

- 12- Abrishamchi, A., Mehdikhani, H., Tajrishy, M., and Marino, M.A. (2007). "Application of conjunctive nonlinear model based on wavelet transforms and artificial neural networks to drought forecasting." *American Geophysical Union, Fall Meeting, Abstract Number: PA33A-1021*.
- 13- Rahnama, M.B., and Nouri, M. (2008). "Developing of Halil river rainfall-runoff model, using conjunction of wavelet transform and artificial neural network." *Research J. of Environmental Science*, 2(5), 385-392.
- 14- Nourani, V., Alami, M.T., and Aminfar, M.H. (2009). "A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation." *Engineering Applications of Artificial Intelligence*, 22, 466-472.
- 15- Kisi, O. (2009). "Neural networks and wavelet conjunction model for intermittent streamflow forecasting." *J. of Hydrologic Engineering*, 14(8), 773-782.
- 16- Partal, T., and Cigizoglu, H.K. (2009). "Prediction of daily precipitation using wavelet-neural networks." *J. of Hydrological Sciences*, 54(2), 234-246.
- 17- McKee, T.B., Doesken, N.J., and Kleist, J. (1993). "The relationship of drought frequency and duration to time scales." *8th Conference on Applied Climatology*, Anaheim, CA, 179-184.
- 18- Guttman, N.B. (1999). "Comparing the drought index and the standardized precipitation index." *J. of American Water Resources Association*, 35(2), 311-322.
- 19- Mishra, A.K., and Desai, V.R. (2005). "Drought forecasting using stochastic models." *J. of Stochastic Environmental Research and Risk Assessment*, 19, 326-339.
- 20- Mishra, A.K., Singh, V.P., and Desai, V.R. (2009). "Drought characterization: A probabilistic approach." *Stochastic Environmental Research and Risk Assessment*, 23, 41-55.
- 21- Sivanandam, S.N., and Deepa, S.N. (2008). *Introduction to Genetic Algorithm*, Springer-Verlag, Berlin.
- 22- Nori, R., Farokhnia, A., Morid, S., and Riahi Madvar, H. (2009). "Effect of input variables preprocessing in artificial neural network on monthly flow prediction by PCA and wavelet transformation." *J. of Water and Wastewater*, 1, 13-22. (In Persian)
- 23- Aussem, A., Campbell, J., and Murtagh, F. (1998). "Wavelet-based feature extraction and decomposition strategies for financial forecasting." *J. of Computational Intelligence in Finance*, 6(2), 5-12.