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

یوسف حسن‌زاده[1] امین عبدی کردانی[2] احمد فاخری‌فرد[3]

(دریافت ۸۹/٤/۲٦ پذیرش ۹۰/۳/۱۷)

چکیده

خشکسالی به‌عنوان 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 به‌منظور مدیریت بهینه منابع آب، از اهمیت بسزایی 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 به‌کارگیری 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 Hassanzadeh[1] *Amin Abdi Kordani*[2] *Ahmad Fakheri Fard*[3]

(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.

۱- استاد گروه مهندسی عمران- آب، دانشکده فنی مهندسی عمران، دانشگاه تبریز
(نویسنده مسئول) ۳۳۹۲۳۹۵ (۰٤۱۱) yhassanzadeh@tabrizu.ac.ir
۲- دانشجوی دکترای مهندسی عمران- آب، دانشکده فنی مهندسی عمران، دانشگاه تبریز
۳- دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

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

Archive of SID
www.SID.ir

۱- مقدمه

خشکسالی به‌عنوان یک حادثه ناگوار طبیعی، در اثر تغییر اقلیم پدیدار می‌گردد و به‌طور مستقیم جوامع را از طریق تغییرات در دسترسی به منابع آب تحت تأثیر قرار می‌دهد [۱]. رخداد این پدیده هزینه‌های اقتصادی، اجتماعی و محیط‌زیستی زیادی را نیز به‌همراه داشته و خساراتی که به آن نسبت داده می‌شود، بسته به‌شدت خشکسالی رو به افزایش است و انسان با تمام پیشرفتهای علمی و فنی خود هنوز نتوانسته زمان و محل وقوع خشکسالی‌های شدید را به‌طور 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 ضروری‌ترین 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 شاخص‌های خشکسالی طراحی و ارائه می‌گردند [۳].

هدف از تهیه و کاربرد شاخصهای خشکسالی، ارائه یک ارزیابی کمّی و کیفی از ویژگی‌های زمانی و مکانی رخداد خشکسالی است. از میان شاخصهای موجود برای تحلیل خشکسالی، شاخص بارندگی استاندارد شده[1] به‌علت سادگی محاسبات، استفاده از داده‌های قابل دسترس بارندگی، قابلیت محاسبه برای هر مقیاس زمانی دلخواه و قابلیت بسیار زیاد در مقایسه مکانی نتایج، به‌عنوان مناسب‌ترین شاخص برای به‌دست آوردن مشخصات خشکسالی شناخته می‌شود و در حال حاضر به‌طور گسترده مورد استفاده قرار می‌گیرد [۴].

به‌منظور تخمین پارامترهای موجود در شاخص SPI تاکنون از روشهای کلاسیکی همچون روش حداکثر درست‌نمایی[2] استفاده شده است، در صورتی که اخیراً روشهای فراکاوشی[3] نیز به‌عنوان ابزار تخمین پارامتر مورد استفاده قرار می‌گیرد. یکی از این روشها، الگوریتم ژنتیک[4] 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.

کاراهان و همکاران[5] 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 برازش را بر داده‌های اندازه‌گیری شده ارائه می‌دهد [۵]. چن و همکاران[6] 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[7] و ویجیال آکشمی[8] 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 نیکویی برازش 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].

حسن‌زاده و همکاران از روشهای فراکاوشی همچون الگوریتم ژنتیک و الگوریتم جامعه مورچگان، به‌منظور تخمین پارامترهای توزیعهای آماری مورد استفاده در تحلیل فراوانی جریان‌های سیلابی از قبیل مقدار حدی تعمیم یافته، پیرسون نوع سوم، لوگ نرمال سه پارامتری، لجستیک تعمیم یافته، پاریتوی تعمیم یافته، کاپا و ویکبی در استان آذربایجان شرقی استفاده نمودند و در نهایت نتیجه گرفتند که دو روش فراکاوشی مذکور، در قیاس با سایر روشهای معمول تخمین پارامتر همچون روش حداکثر 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 محیط زیستی 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. به‌همین 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،

[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

Archive of SID
www.SID.ir

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

کیم[1] و والدس[2] 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 به‌عنوان 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[3] و دینگ[4] 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 ۱، ۳ 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 به‌کمک مدل‌های شبکه عصبی پیش‌بینی گردیده است. برای ساخت الگوی ورودی شبکه از بارش ماهانه نیز بهره گرفته شده است. نتایج به‌دست 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 به‌کمک 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، به‌منظور طراحی سازه‌های هیدرولیکی 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 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[5] 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 خطاها در حدود ۶۵ تا ۷۴ درصد و میانگین مطلق خطاها حدود ۱۲ تا ۴۳ درصد و ضریب تبیین حدود ۱۱ تا ۴۷ درصد کاهش داشته‌اند [۱۵]. پارتال[6] و سیگیزاغلو[7] 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

۲-۱- 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 مبدا واقع شده است. شهر تبریز از سمت شمال، جنوب و شرق به کوهستان و از سمت غرب به زمین‌های هموار و شوره‌زارهای تلخه‌رود 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 به‌سمت مرکز شهر و سپس به‌سمت مغرب است. در این تحقیق از آمار بارندگی ماهانه ۴۰ ساله، مربوط به سالهای ۱۹۶۵ تا ۲۰۰۴ از ایستگاه هواشناسی شهر تبریز استفاده گردید.

[1] Kim
[2] Valdes
[3] Wang
[4] Ding
[5] Kisi
[6] Partal
[7] Cigizoglu

www.SID.ir
Archive of SID

۲-۲- 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، مک‌کی و همکاران[1] در سال ۱۹۹۳ شاخص جدیدی را به‌نام SPI به‌منظور 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 دراز مدت بارندگی برای همان فاصله زمانی در طول دوره آماری به‌دست 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، درصورتی 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 مک کی و همکاران مقیاسهای زمانی ۳، ۶، ۱۲، ۲۴ و 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 ۳، ۶، ۱۲، ۲۴ و ۴۸ ماهه تشکیل داده شد و سپس هر یک از سری‌های زمانی با مقیاس زمانی متفاوت، با توزیع گاما برازش داده شدند تا احتمال تجمعی بارندگی برای ماه معین و مقیاس زمانی مشخص، به‌دست آید. تابع چگالی احتمال[2] توزیع گاما به‌صورت زیر است [۱۹]

$$f(x) = \frac{1}{\beta^{\alpha}\Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \qquad (۱)$$

که در این رابطه

$x \geq 0$ مقدار بارندگی، $\alpha > 0$ پارامتر شکل[3]، $\beta > 0$ پارامتر مقیاس[4] 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].

جدول ۱- طبقه‌بندی خشکسالی بر اساس شاخص SPI

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

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 شانس 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].

روند کلی حل مسائل توسط الگوریتم ژنتیک به این گونه است که ابتدا تعدادی از جوابهای شدنی مسئله مورد نظر را به‌صورت تصادفی و یا گاهی به‌صورت از قبل تعیین شده، به‌عنوان جمعیت اولیه انتخاب می‌کند و سپس هر یک از جوابها به‌صورت 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، شانس خود را برای بقا در سیستم افزایش می‌دهد. در عملگر انتخاب، والدین به‌صورت زوج درآمده، به این ترتیب که هر کروموزوم با یک کروموزوم دیگری که به‌صورت 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 حداکثر 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].

[1] McKee et al.
[2] Probability density function (pdf)
[3] Shape parameter
[4] Scale parameter

www.SID.ir
Archive of SID

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

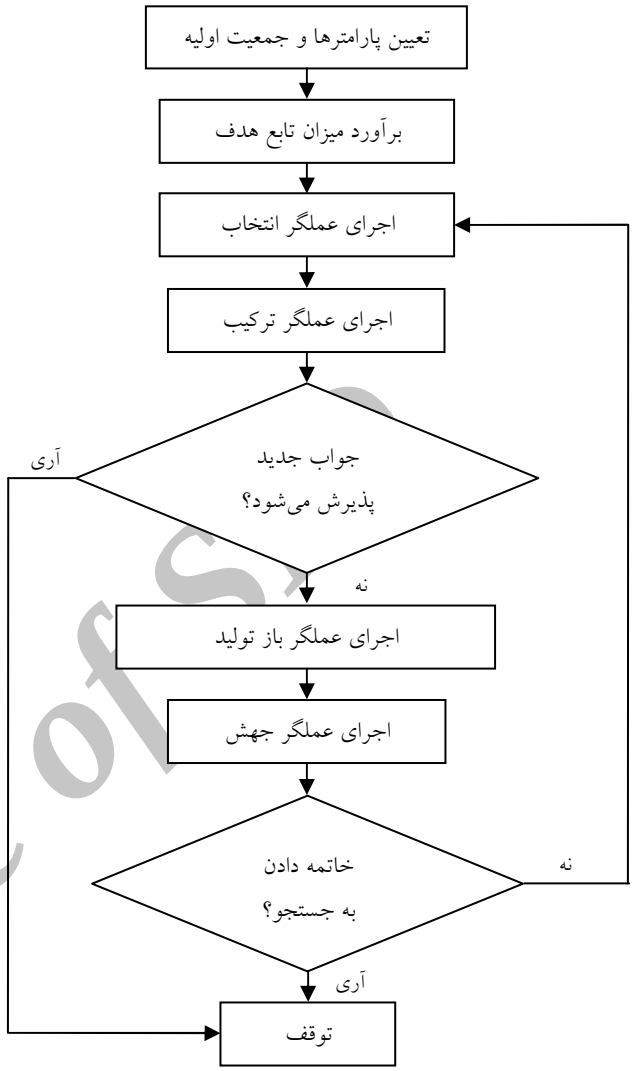

شکل ۱- ساختار پایه‌ای الگوریتم ژنتیک

۲-۴- 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 به‌عهده دارند. این نرون‌ها به یکدیگر متصل شده و بسته به چگونگی این اتصالات، شبکه‌ها و مدل‌های مختلفی به‌وجود می‌آیند.

شکل ۲ یک مدل شبکه عصبی پیش‌خور[1]، متشکل از سه لایه ورودی، میانی (یا مخفی) و خروجی را نشان می‌دهد که معمولاً 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]

$$\hat{y}_k = f_0\left[\sum_{j=1}^{m} w_{kj}.f_h\left(\sum_{i=1}^{n} w_{ij}x_i + w_{jo}\right) + w_{ko}\right] \qquad (۲)$$

که در این رابطه

n تعداد کل نرون‌های لایه ورودی، m تعداد کل نرون‌های لایه میانی، k تعداد کل نرون‌های لایه خروجی، f_o تابع محرک مورد استفاده در لایه خروجی، f_h تابع محرک مورد استفاده در لایه میانی، W_{jo} مقدار وزن اریب نرون jام لایه میانی، W_{ko} مقدار وزن اریب نرون kام لایه خروجی، W_{ji} مقدار وزنی است که به نرون iام لایه ورودی اختصاص داده می‌شود تا بر اساس آن، نرون jام لایه میانی به‌دست آید. W_{kj} مقدار وزنی است که به نرون jام لایه میانی اختصاص داده می‌شود تا بر اساس آن نرون kام لایه خروجی به‌دست آید.

برای اینکه شبکه عصبی بتواند خروجی را تا حد امکان به‌هدف نزدیک کند، به فرایند آموزش نیاز دارد. آموزش عبارت است از پیدا کردن مناسب‌ترین بردار وزن و بردار اریب و کمینه کردن تابع خطا بین داده‌های محاسباتی (خروجی) و داده‌های مشاهداتی (هدف) که معمولاً از رابطه میانگین مربع خطاها[2] استفاده می‌شود. یکی از الگوریتم‌های آموزشی، روش انتشار برگشتی[3] است که با به‌دست آوردن مقدار وزن‌های اصلاح شده در هر مرحله، سبب بهبود نتایج می‌شود. در نهایت بعد از اینکه آموزش پایان یافت، شبکه برای دادن جوابهای منطقی به داده‌های جدید توانا می‌شود.

۲-۵- تبدیل موجک

موجک، یک موج کوچک است که انرژی آن در ناحیه کوچکی متمرکز شده و ابزار مناسبی برای بررسی پدیده‌های گذرا[4] است. موجک نوسان حداقلی دارد که به‌سمت صفر نزول می‌کند و این نزول باید در جهات مثبت و منفی واقع در دامنه‌اش محدود شود. این مشخصه باعث می‌شود که موجک انعطاف‌پذیر 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.

[1] Feed forward

[2] Mean square error (MSE)

[3] Back propagation

[4] Non stationary

Archive of SID
www.SID.ir

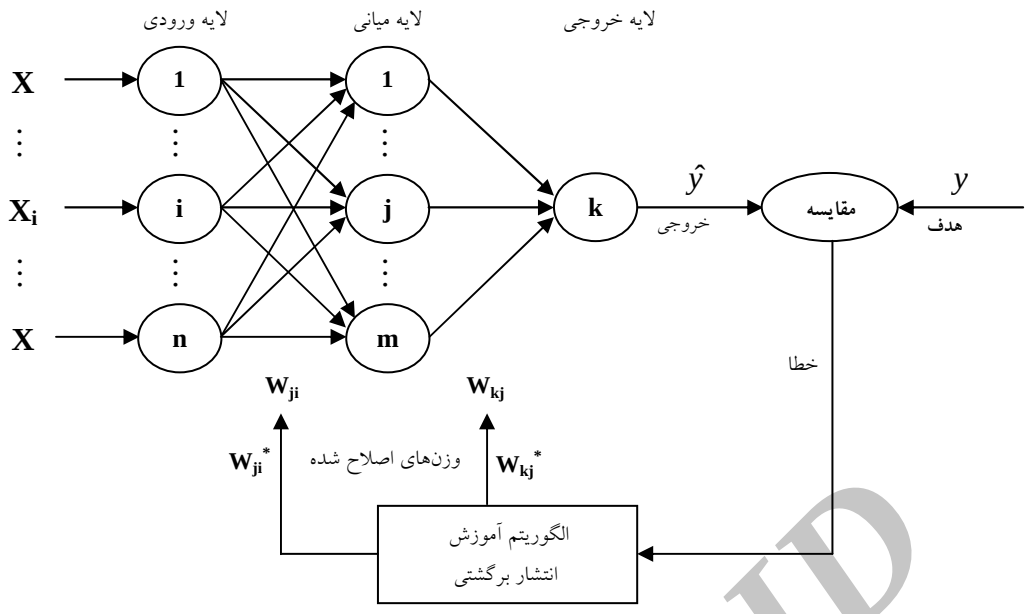

شکل ۲- ساختار شماتیک شبکه عصبی پیش‌خور- الگوریتم انتشار برگشتی

در تابع موجک $\psi(t)$، که به آن موجک مادر نیز گفته می‌شود، باید شرط زیر ارضا شود

$$\int_{-\infty}^{+\infty}\Psi(t)dt = 0 \qquad (۳)$$

توابع موجک مادر توسط دو عملگر انتقال[1] و مقیاس[2] در طول سیگنال مورد تحلیل، تغییر اندازه و تغییر محل می‌یابند و به‌صورت زیر بیان می‌گردد [۱۵]

(۴)

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

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 گسسته در زمان به‌کار می‌رود. اختلاف انواع مختلف تبدیل موجک، مربوط به روشی است که مقیاس و انتقال را پیاده سازی می‌کند. برای یک سری زمانی با تابع f(t)، تبدیل موجک پیوسته[3] آن به‌صورت زیر است

(۵)

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

که در آن

$\overline{\Psi}(t)$ تابعی مرکب از $\Psi(t)$ است. همچنین برای به‌دست آوردن تبدیل موجک گسسته[4]، با جاگذاری مقادیر $a = a_0^j$، $b = kb_0a_0^j$، $a_0 > 1$، $b\in R$، $k, j\in Z$ در رابطه بالا رابطه ۶ حاصل می‌گردد

(۶)

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

در این تحقیق از تبدیل موجک ناپیوسته در به‌دست آوردن ضرایب موجک استفاده شد. همچنین موجکهای مادر مورد استفاده عبارت بودند از موجکهای db4[5]، dmey[6]، coif5[7] و sym4[8] که همگی به‌طور گسترده در تبدیلهای موجک به‌کار گرفته می‌شوند.

۲-۶- معیار نیکویی برازش

به‌منظور 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[9] و آماری[1] هستند که هر کدام از آنها ویژگی‌های منحصر

[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

Archive of SID
www.SID.ir

به‌خود را داشته و به‌منظور خاصی به‌کار می‌روند. از آن‌جا که روش گرافیکی روش دقیقی نیست و بسته به نظر اشخاص، نتایج متفاوتی به‌دست 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)[2] استفاده شد [۸]

$$E = 1 - \frac{\sum_{i=1}^{n}(X_{oi} - X_{ci})^2}{\sum_{i=1}^{n}(X_{oi} - \overline{X_0})^2} \quad , \; -\infty < E \le 1 \qquad (۷)$$

که در این رابطه

E ضریب راندمان، n تعداد کل داده‌ها، X_{oi} داده‌های مشاهداتی، X_{ci} داده‌های محاسباتی و $\overline{X_0}$ 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، ۲۴ و ۴۸ ماهه) در شهر تبریز پرداخته شد. همان طوری که قبلاً ذکر شد، برای محاسبه شاخص بارندگی استاندارد شده از برازش توزیع احتمال گاما بر داده‌های دراز مدت بارندگی ماهانه استفاده می‌شود که تابع حاصل برای به‌دست آوردن احتمال تجمعی بارندگی برای یک ایستگاه و در مقیاس زمانی مشخص به‌کار می‌رود. با توجه به انتخاب روش تخمین پارامترهای توزیع گاما، می‌توان نتایج متفاوتی را به‌دست 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 به‌صورت زیر بیان می‌شود که متغیرهای مورد استفاده در آن در رابطه ۷ آورده شده است [۸]

$$\text{Minimize}\left(\frac{\sum_{i=1}^{n}(X_{oi} - X_{ci})^2}{\sum_{i=1}^{n}(X_{oi} - \overline{X_0})^2}\right) \qquad (۸)$$

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) به‌عنوان سالهای بحرانی شناخته می‌شوند. همچنین فراوانی‌های رخداد

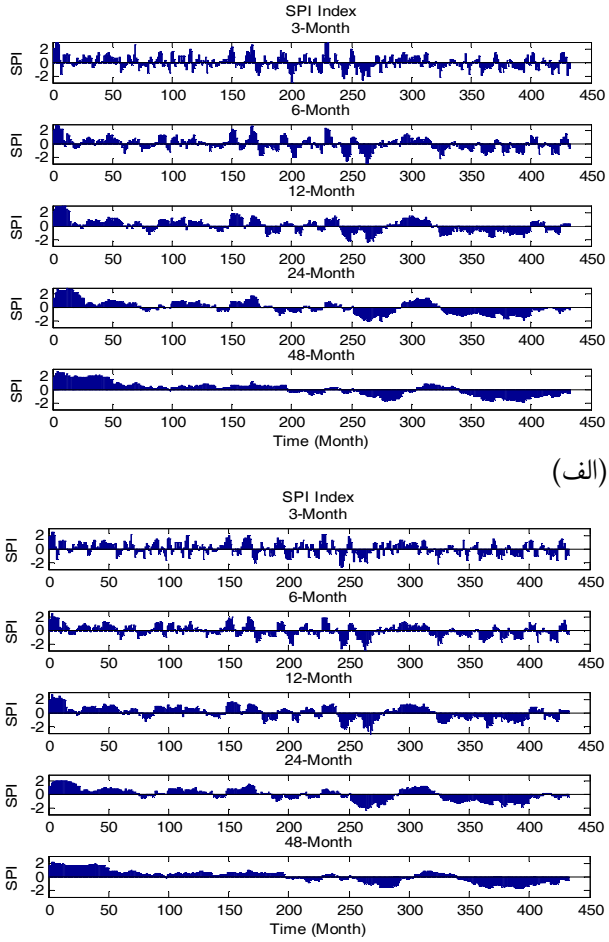

(الف)

(ب)

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

رخداد خشکسالی به‌دست 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 گیر افتادن در نقطه‌های بهینه محلی رهایی می‌یابند و در نهایت به بهینه‌ترین جواب ممکن دست می‌یابند. ثانیاً با افزایش بازه زمانی، ضرایب راندمان به‌دست 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

[1] Statistical test criteria
[2] Efficiency coefficient

Archive of SID
www.SID.ir

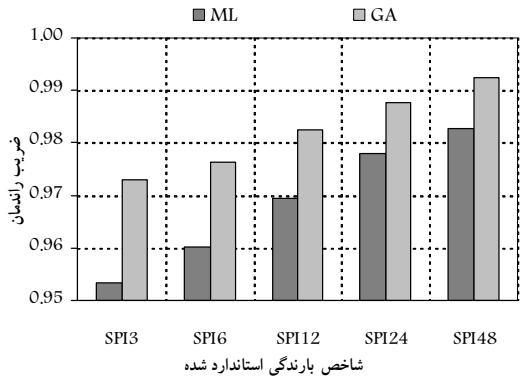

شکل ۴- نمودار مقدار ضرایب راندمان

زمانی کمتر، نسبت به تغییرات بارش حساس است و در طول زمان وقوع، از پراکندگی بیشتری در منطقه برخوردار است، درحالی 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 برعکس.

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 به‌کار 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 صحت‌سنجی مدل استفاده شد. بر این اساس ابتدا برای هر بازه زمانی، داده‌های شاخص مطابق رابطه زیر نرمال شده، سپس شاخصهای ماههای گذشته به‌عنوان ورودی و شاخصهای ماههای آتی به‌عنوان خروجی در شبکه عصبی مورد استفاده قرار گرفتند.

$$\begin{cases} Y_i = \dfrac{X_{oi}}{X_{o\max}}, X_{oi} \geq 0 \\ Y_i = \dfrac{X_{oi}}{|X_{o\min}|}, X_{oi} < 0 \end{cases} \qquad (۹)$$

که در این رابطه Y_i مقادیر استاندارد شده، X_{oi} مقادیر شاخص مشاهداتی، X_{omax} حداکثر مقدار شاخص مشاهداتی و X_{omin} حداقل شاخص مشاهداتی هستند.

بر اساس مدل شبکه عصبی (مدل ۱)، از شبکه پیشرو- انتشار برگشتی که توسط الگوریتم لونبرگ- مارگارت[1] آموزش دیده شده است، برای پیش‌بینی خشکسالی استفاده شد. تابع محرک 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 صحت‌سنجی مدل، برای شاخص SPI با بازه‌های زمانی مختلف به‌دست آمد که بهترین نتایج حاصله در جدول ۲ آورده شده است.

مدل ترکیبی شبکه عصبی- موجکی (مدل ۲)، از لحاظ الگوریتم آموزش، تابع محرک و تعداد لایه‌های شبکه، همانند مدل ۱ است، با این تفاوت که داده‌ها قبل از ورود به شبکه عصبی، توسط تبدیل موجک، پیش پردازش شده و سپس وارد شبکه عصبی می‌شوند. در هنگام استفاده از تبدیل موجک به دو مورد باید توجه نمود: الف) انتخاب نوع تابع موجک، ب) تعیین درجه تجزیه.

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

$$l = \text{int}[\log(N)] \qquad (۱۰)$$

که N و l به‌ترتیب طول سری زمانی و درجه تجزیه هستند. با توجه به اینکه در این تحقیق، N=۴۳۲ بود، بنابراین درجه تجزیه برابر ۳ به‌دست آمد. در شکل ۵ شماتیک تجزیه سری زمانی داده‌های مشاهداتی (S) نشان داده شده است.

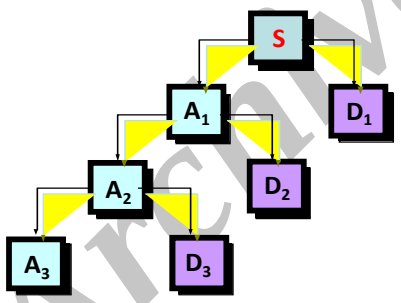

$S=A_1+D_1$
$A_1=A_2+D_2$
$A_2=A_3+D_3$
$S=A_3+D_3+D_2+D_1$

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

شکل ۵ نشان دهنده تجزیه یک سیگنال به دو مؤلفه تقریبها[2] و جزئیات[3] است که در واقع تقریبها، فیلترهای پایین‌گذر و جزئیات، فیلترهای بالاگذر را تداعی می‌کنند. به‌عبارت دیگر فرکانس‌های بالا و اغتشاشات، بیشتر خود را در جزئیات نشان می‌دهند و

[1] Levenberg- Marquardt (LM)
[2] Approximations
[3] Details

Archive of SID
www.SID.ir

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

شاخص	ساختار شبکه	ضریب راندمان	
		آموزش	آزمون
SPI3	۱-۴-۱	۰/۴۵۴۳	۰/۳۰۹۱
SPI6	۱-۴-۱	۰/۷۰۶۸	۰/۶۱۰۵
SPI12	۱-۴-۱	۰/۸۴۹۴	۰/۷۵۳۳
SPI24	۱-۴-۱	۰/۹۱۵۵	۰/۸۶۸۵
SPI48	۱-۴-۱	۰/۹۶۷۸	۰/۹۲۶۱

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 به‌دست 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 تفاوتی در جواب حاصله ایجاد نمی‌کند، بلکه فقط زمان اجرای برنامه را طولانی‌تر می‌کند. همچنین برای مقایسه بهتر نتایج مربوط به مقدار ضرایب راندمان به‌دست آمده از مراحل واسنجی و صحت‌سنجی دو مدل شبکه عصبی، از جدول ۴ استفاده گردید.

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

شاخص	ساختار شبکه	نوع موجک	ضریب راندمان	
			آموزش	آزمون
SPI3	۴-۴-۱	dmey	۰/۷۶۱۵	۰/۷۰۹۰
	۴-۴-۱	db4	۰/۷۷۶۰	۰/۷۱۰۲
	۴-۴-۱	coif5	۰/۷۳۱۳	۰/۷۰۷۸
	۴-۴-۱	sym4	۰/۷۸۶۰	۰/۷۱۸۵
SPI6	۴-۴-۱	dmey	۰/۸۵۰۳	۰/۷۹۶۱
	۴-۴-۱	db4	۰/۸۴۱۹	۰/۷۸۵۴
	۴-۴-۱	coif5	۰/۸۴۹۲	۰/۷۸۹۷
	۴-۴-۱	sym4	۰/۸۵۱۴	۰/۷۹۹۳
SPI12	۴-۴-۱	dmey	۰/۹۰۲۸	۰/۸۴۷۲
	۴-۴-۱	db4	۰/۹۰۱۰	۰/۸۳۴۶
	۴-۴-۱	coif5	۰/۹۰۱۷	۰/۸۳۹۳
	۴-۴-۱	sym4	۰/۹۰۳۹	۰/۸۴۹۵
SPI24	۴-۴-۱	dmey	۰/۹۶۰۷	۰/۹۱۰۱
	۴-۴-۱	db4	۰/۹۵۵۰	۰/۹۰۶۹
	۴-۴-۱	coif5	۰/۹۶۰۴	۰/۹۰۹۳
	۴-۴-۱	sym4	۰/۹۶۱۷	۰/۹۱۱۵
SPI48	۴-۴-۱	dmey	۰/۹۸۱۷	۰/۹۶۶۷
	۴-۴-۱	db4	۰/۹۸۰۰	۰/۹۵۷۵
	۴-۴-۱	coif5	۰/۹۸۳۱	۰/۹۶۷۳
	۴-۴-۱	sym4	۰/۹۸۴۴	۰/۹۶۸۶

جدول ۴- مقایسه مقدار ضرایب راندمان به‌دست آمده از دو مدل پیش‌بینی خشکسالی

مرحله	شاخص	مدل ۱	مدل ۲
واسنجی	SPI3	۰/۴۵	۰/۷۹
	SPI6	۰/۷۱	۰/۸۵
	SPI12	۰/۸۵	۰/۹۰
	SPI24	۰/۹۲	۰/۹۶
	SPI48	۰/۹۷	۰/۹۸
صحت‌سنجی	SPI3	۰/۳۱	۰/۷۲
	SPI6	۰/۶۱	۰/۸۰
	SPI12	۰/۷۵	۰/۸۵
	SPI24	۰/۸۷	۰/۹۱
	SPI48	۰/۹۳	۰/۹۷

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 به‌دست 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، dmey و coif5) را نتیجه می‌دهد.

نمودارهای دو مرحله واسنجی و صحت‌سنجی، برای پیش‌بینی خشکسالی به‌روش 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 خواهند بود که با استفاده در شبکه عصبی مصنوعی به‌عنوان ورودی، حاصلی هموارتر و منطبق‌تر با داده‌های شاخص اندازه‌گیری شده خواهند داشت.

Archive of SID

www.SID.ir

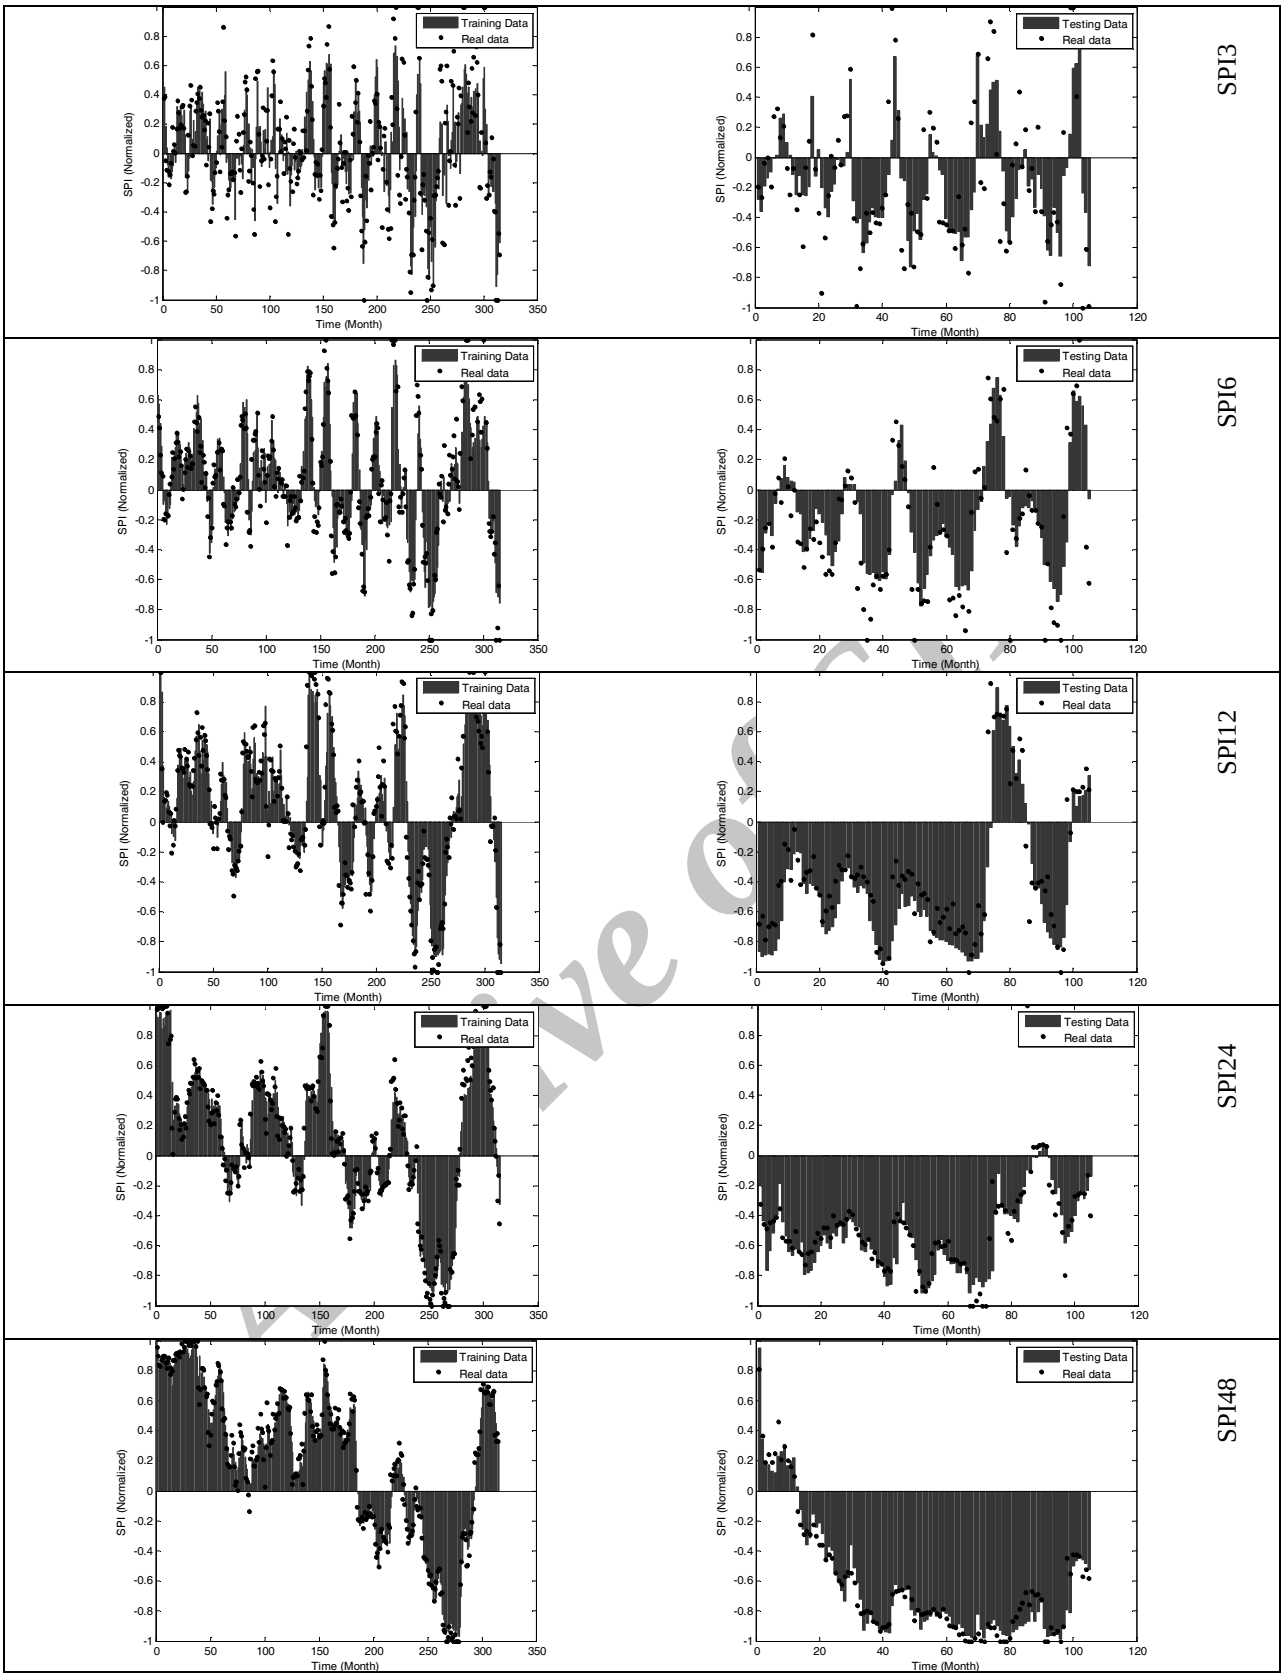

شکل ۶- نمودارهای دو مرحله واسنجی و صحت سنجی مدل ۲ برای شاخص SPI با بازه‌های زمانی مختلف

www.SID.ir

۴- نتیجه‌گیری

با توجه به نتایج حاصل در این تحقیق، می‌توان جمع‌بندی‌های زیر را ارائه نمود:

۱- شاخص SPI به‌عنوان یک ابزار مناسب به‌منظور پایش شرایط خشکسالی قابل استفاده است، زیرا از خصوصیات مهم این شاخص، چند کاره بودن آن است که می‌تواند 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 می‌نماید.

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 می‌دهد.

۴- در مدل‌های شبکه عصبی مصنوعی (تنها یا ترکیبی) با تعداد کم نرون لایه میانی، می‌توان به جواب مطلوب دست یافت و استفاده از تعداد زیاد نرون لایه میانی، نه تنها تفاوتی در جواب حاصله ایجاد نمی‌کند، بلکه فقط زمان اجرای برنامه را طولانی‌تر می‌کند.

۵- از میان توابع موجک مورد استفاده در مدل ترکیبی، موجک sym4 به لحاظ دارا بودن شکل هندسی مناسب برای سری‌های زمانی خشکسالی، جوابهای مناسب‌تری را نسبت سایر موجکها نتیجه می‌دهد.

۶- با افزایش بازه زمانی در دو مدل شبکه عصبی، مقدار ضرایب راندمان به‌دست آمده از شاخص SPI افزایش می‌یابد. 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 می‌شود. به‌عبارت دیگر اختلاف به‌دست آمده از شاخص SPI ۳ ماهه و ۴۸ ماهه در دو مدل به‌ترتیب برابر با ۴۱ و ۴ درصد است.

۵- قدردانی

این مقاله با حمایت مالی و اعتبار ویژه پژوهشی دانشگاه تبریز تهیه گردیده است. به‌این وسیله نویسندگان مقاله از معاونت محترم پژوهش و فناوری دانشگاه تبریز تقدیر و تشکر می‌نمایند.

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- Raziei, T., Daneshkar Arasteh, P., Akhtari, R., and Saghafian, B. (2007). “Investigation of metrological drought in the Sistan and Balochestan 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.

Archive of SID
www.SID.ir

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 conjuction 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 extractionand decomposition strategies for financial forecasting." *J. of Computational Intelligencein Finance*, 6(2), 5-12.

Archive of SID

www.SID.ir