

دوره ۳۳، شماره ۱، شماره‌ی پیاپی ۱۲۶، بهار ۱۳۹۹، صفحه‌های ۵۵-۳۹
شناسه‌ی دیجیتال: 10.22092/wmej.2019.125825.1204

پژوهش‌های آبخیزداری

ارزیابی مدل‌های تلفیقی شبکه‌ی عصبی مصنوعی-موجک و برنامه‌ریزی بیان ژن-موجک در پیش‌بینی کردن خشک‌سالی کوتاه‌مدت

محبوبه یونسی

دانشجوی دکترای مهندسی منابع آب، گروه مهندسی علوم آب، دانشکده‌ی کشاورزی، دانشگاه بوعلی سینا، همدان

حامد نوذری

(نویسنده‌ی مسئول)* دانشیار مهندسی منابع آب، گروه مهندسی علوم آب، دانشکده‌ی کشاورزی، دانشگاه بوعلی سینا، همدان

رایانامه‌ی نویسنده‌ی مسئول: h.nozari@basu.ac.ir

تاریخ دریافت: ۲۲ فروردین ۱۳۹۸ تاریخ پذیرش: ۲۶ آذر ۱۳۹۸

چکیده

پیش‌بینی کردن خشک‌سالی نقش مهمی در طراحی و مدیریت کردن منابع طبیعی، سامانه‌های منابع آب و تعیین کردن نیاز آبی گیاه دارد. از سوی دیگر، تبدیل موجک یکی از روش‌های نوین و بسیار موثر در تجزیه کردن پیام‌ها و مجموعه‌های زمانی است. در این تحقیق پیام شاخص بارش معیار (SPI) با موجک مادر تجزیه کرده، و نتیجه‌ی آن ورودی مدل‌های شبکه‌ی عصبی مصنوعی و برنامه‌ریزی بیان ژن گرفته شد. برای پیش‌بینی کردن خشک‌سالی شبکه‌های عصبی مصنوعی شناسنده‌ی چندلایه، تابع پایه‌ی شعاعی، برنامه‌ریزی بیان ژن، شبکه‌های عصبی مصنوعی-موجک شناسنده‌ی چندلایه، تابع پایه‌ی شعاعی، و برنامه‌ریزی بیان ژن-موجک به‌کاربرده شد. داده‌های بارندگی از ایستگاه هواشناسی بیدستان با دوره‌ی داده‌برداری ۴۴ ساله در آبخیز شور استان قزوین گرفته شد. وضعیت رطوبتی با شاخص بارندگی به‌معیار شده در دوره‌ی سه‌ماهه محاسبه کرده شد. برای تخمین مقدار شاخص بارندگی به‌معیار شده در هر بازه‌ی زمانی، اندازه‌های زمان‌های پیش‌تر به‌کاربرده شد. نتیجه‌ها نشان داد که از میان ۶ مدل بررسی شده، برنامه‌ریزی بیان ژن-موجک با دقت بیش‌تری شاخص بارش معیار و وضعیت خشک‌سالی کوتاه‌مدت را پیش‌بینی می‌کند. در بهترین حالت نیز اندازه‌ی شاخص‌های MAE ، $RMSE$ ، R^2 و NS در مرحله‌ی صحت‌سنجی برای مدل $WA-GEP$ به ترتیب $۰/۹۱۱$ ، $۰/۰۳۷$ ، $۰/۰۲۲$ و $۰/۸۴۵$ بود.

واژگان کلیدی: برنامه‌ریزی بیان ژن-موجک، شاخص بارش استاندارد، شبکه‌ی عصبی مصنوعی-موجک، پیش‌بینی

خشک‌سالی

مقدمه

نتایج پیش‌بینی کردن دوره‌ی خشک‌سالی در حوزه‌ی رودخانه‌ی آواش در اتیوپی با شبکه‌ی عصبی-موجکی (WA-ANN) و وایزی (رگرسیون) بردار پشتیبان موجکی (WA-SVR) نشان داد که مدل WA-ANN می‌تواند شاخص خشک‌سالی SPI را در بازه‌های زمانی ۱۲ و ۲۴ ماهه پیش‌بینی کند (بلاینه و همکاران ۲۰۱۴). نتایج کماسی و همکاران (۲۰۱۷) نشان داد که مدل WA-ANN در مقایسه با ANN و مدل مجموعه‌ی زمانی، می‌تواند با دقت بیش‌تری تراز آب دریاچه‌ی ارومیه را پیش‌بینی کند. نورانی و همکاران (۲۰۰۹) بارش یک‌ماهه بعد آبخیز ليقوان چای در آذربایجان شرقی را با مدل شبکه‌ی عصبی-موجکی (WA-ANN) پیش‌بینی کردند و نشان دادند که مدل WA-ANN به‌علت به‌کاربردن مجموعه‌های زمانی چندمقیاسی در لایه‌ی ورودی، می‌تواند بارندگی در هر دو دوره‌ی یک‌ماهه و بیش‌تر را به‌خوبی پیش‌بینی کند. پیش‌بینی جریان رودخانه‌ی رودخانه با مدل موجک ترکیبی (هیبرید) و شبکه‌ی عصبی در ایستگاه آب‌سنجی ونیاز در آبخیز آجی‌چای (شفایی و همکاران ۲۰۱۴) نشان داد که دقت WA-ANN بیش‌تر از ANN است. پیش‌بینی نقطه‌ی شبنم روزانه با برنامه‌ریزی بیان ژن (GEP) نیز نشان داد که با داده‌های ثبت‌شده در این دو ایستگاه و روش GEP، به‌خوبی می‌توان نقطه‌ی شبنم روزانه را پیش‌بینی کرد (مهدی‌زاده و همکاران ۲۰۱۷). نتایج وانگ و همکاران (۲۰۱۹) در پیش‌بینی کردن توان تبخیر و تعرق مرجع با GEP دقت زیاد این مدل را نشان می‌دهد. سلگی و همکاران (۲۰۱۸) در بررسی عمل‌کرد مدل GEP با روش‌های پیش‌پردازش برای مدل‌سازی کردن جریان رودخانه، تبدیل کردن موجک را برای پیش‌پردازش کردن داده‌ها به‌کار بردند؛ نتیجه‌ی آنان برتری مدل ترکیبی WA-GEP را به GEP نشان می‌دهد. داندانه‌مهر و همکاران (۲۰۱۴) با مدل تلفیقی موجک-ژنی طول دوره‌ی خشک‌سالی را پیش‌بینی کردند. نتایج آن‌ها در به‌کاربردن WA-ANN، WA-LGP، ANN، LGP و فزای-موجک (WA-FL)، برتری WA-LGP را نشان داد. نتیجه‌های شعیب و همکاران (۲۰۱۵) در پیش‌بینی کردن روان‌آب برتری WA-GEP را در مقابل GEP نشان می‌دهد. نتیجه‌ی پیش‌بینی مقدار سدیم اشباع در رودخانه‌ها با WA-ANN، LGP، ANN و WA-ANN، LGP نیز نشان‌دهنده‌ی برتری WA-LGP است (روانسالار و همکاران ۲۰۱۶). یوسفی و همکاران (۲۰۱۷) هم تقاضای آب در بلندمدت را با مدل WA-GEP پیش‌بینی کردند.

خشک‌سالی پدیده‌ی طبیعی و تکرارشده‌ی است که بر اثر کاهش یافتن بارندگی در دوره‌ی زمانی مشخص روی می‌دهد (شارما و اسماختین ۲۰۰۴). این پدیده به‌کندی شروع می‌شود و تأثیر آن به‌تدریج در دوره‌ی زمانی نسبتاً طولانی در بخش‌های مختلف مانند منابع آب، کشاورزی، محیط‌زیست، اجتماعی و اقتصادی ظاهر می‌شود. از این‌رو، تعیین کردن دقیق زمان شروع و خاتمه‌ی این پدیده تا حدودی مشکل است. بنابراین اغلب خشک‌سالی را پدیده‌ی خزنده توصیف می‌کنند (مرید و همکاران ۲۰۰۵).

پیش‌بینی کردن خشک‌سالی از عامل‌های اساسی مدیریت کردن حوزه است. در سال‌های اخیر اهمیت آن به‌دلیل افزایش یافتن تقاضای آب و تغییر کردن آب و هوا تشدید شده‌است (میشرا و همکاران ۲۰۱۰). برای پیش‌بینی کردن خشک‌سالی از روش‌های مختلفی نظیر شبکه‌ی عصبی مصنوعی، منطق فازی، و برنامه‌ریزی بیان ژن بهره می‌برند. شبکه‌های عصبی مصنوعی می‌تواند هر تابع ریاضی ناخطی را به تقریب معینی درآورد، و این خاصیت سبب می‌شود که خشک‌سالی با این شبکه‌ها به‌خوبی پیش‌بینی کرده شود. برنامه‌ریزی بیان ژن از الگوریتم‌های فراکاوشی است که مبنای همه‌ی آن‌ها نظریه‌ی تکامل داروین است. این الگوریتم‌ها تابع هدفی را در قالب معیارهای کیفی تعریف می‌کند، و آن را برای اندازه‌گیری کردن و مقایسه کردن روش‌های مختلف حل کردن، در فرآیند گام‌به‌گام تصحیح ساختار داده‌ها به‌کار می‌گیرد، و روش حل مناسبی به‌دست می‌دهد.

مدل‌های به‌کاررفته برای پیش‌بینی، مجموعه‌های زمانی را مانا^۱ می‌گیرد، و فرآیندها را خطی مدل‌سازی می‌کند. در بیش‌تر پیام‌های آب‌شناسختی مخصوصاً فصلی و ماهانه و روزانه مشخصه‌های بسامد نایستا^۲، پرش^۳، روند^۴ و تغییرات ناگهانی است، و برای مدل‌سازی کردن آن‌ها به‌کاربردن الگوریتم‌ها، معادله‌های ناخطی و نظریه‌های جدید ریاضی ضروری است (شفایی و همکاران ۲۰۱۴). در حالت کلی برای تشخیص دادن اطلاعاتی که در پیام نهفته است باید از تبدیل‌کننده‌های ریاضی مانند مجموعه‌ی فوریه استفاده کرد. تبدیل موجکی تابعی شبیه به نسخه‌ی بهبودیافته‌ی تبدیل فوریه است. تبدیل فوریه در تحلیل کردن پیام نایستا شکست می‌خورد، در حالی که تبدیل موجکی اجازه می‌دهد که پیام‌های نایستا نیز به‌خوبی تحلیل کرده شود (سیفوزامان و همکاران ۲۰۰۹).


- 1- Stationary
- 2- Non stationary
- 3- Drift
- 4 -Trend

مواد و روش‌ها

منطقه‌ی بررسی شده

داده‌های بارندگی ماهانه‌ی ایستگاه باران‌سنجی بیدستان در شهرستان قزوین و آبخیز شور در دوره‌ی داده‌برداری ۵۰-۱۳۴۹ تا ۹۳-۱۳۹۲ به کار برده شد. متوسط بارش سالانه در این حوزه ۲۶۲ میلی‌متر، و بیشینه‌ی ارتفاع ۴۳۷۵ متر در بلندی‌های البرز، و پست‌ترین منطقه در دریاچه‌ی نمک با ارتفاع ۷۴۹ متر از تراز دریا است. ایستگاه بیدستان در ۵۰° ۷' شرقی و ۳۶° ۲۳' شمالی و ارتفاع ۱۳۴۰ متر از تراز دریا است. متوسط بارندگی در این ایستگاه در دوره‌ی داده‌برداری بررسی شده ۳۰۰ میلی‌متر بود. در شکل ۱ توزیع زمانی ماهانه‌ی بارش در این ایستگاه آورده شده است. بیش‌ترین و کم‌ترین بارندگی در دوره‌ی داده‌برداری به ترتیب در فروردین و مرداد (۴۵/۹ و ۰/۸ میلی‌متر) بود. پس از اطمینان یافتن از صحت داده‌های بارندگی ماهانه و انجام‌دادن آزمون‌های آماری، مجموعه‌ی زمانی وضعیت خشک‌سالی در دوره‌ی داده‌برداری بر اساس SPI در دوره‌ی کوتاه مدت ۳ ماهه محاسبه کرده‌شد.

تحقیق‌های گذشته دقت مدل‌های شبکه‌ی عصبی-موجک و برنامه‌ریزی بیان ژنی-موجک در پیش‌بینی سنجه‌های آب‌شناختی، اهمیت پیش‌بینی کردن خشک‌سالی‌های کوتاه‌مدت در مهندسی منابع آب، و ویژگی ناخطی مجموعه‌ی زمانی SPI در بازه‌ی زمانی ۳ ماهه را نشان داد. در این تحقیق دقت مدل‌های تلفیقی شبکه‌ی عصبی-موجک و برنامه‌ریزی بیان ژنی-موجک در پیش‌بینی کردن خشک‌سالی کوتاه‌مدت ارزیابی کرده شد. شبکه‌های عصبی مصنوعی شناسنده‌ی چندلایه (MLP) و تابع پایه‌ی شعاعی (RBF)، برنامه‌ریزی بیان ژنی (GEP) و شبکه‌های عصبی مصنوعی-تلفیقی موجک شناسنده‌ی چندلایه (WA-MLP)، تابع پایه‌ی شعاعی (WA-RBF)، و برنامه‌ریزی بیان ژنی موجک (WA-GEP) به کار گرفته شد. تاکنون پیش‌بینی خشک‌سالی کوتاه مدت (با تعریف شاخص بارش به معیار شده‌ی سه ماهه) با مدل‌های تلفیقی شبکه‌ی عصبی موجک و برنامه‌ریزی بیان ژنی موجک اجرا نشده، و نتیجه‌ی آن با روش‌های شبکه‌ی عصبی مصنوعی و مدل برنامه‌ریزی بیان ژنی مقایسه نشده است.



شکل ۱- توزیع زمانی ماهانه‌ی بارندگی ایستگاه بیدستان در دوره‌ی داده‌برداری ۵۰-۱۳۴۹ تا ۹۳-۱۳۹۲.

شاخص SPI:

α سنجه‌ی شکل، β سنجه‌ی مقیاس توزیع، و $\Gamma(\alpha)$ تابع گاما است که با رابطه‌ی ۲ تعریف می‌شود.

$$\Gamma(\alpha) = \int_0^{\infty} y^{\alpha-1} e^{-y} dy \quad (2)$$

در محاسبه‌ی شاخص SPI توزیع احتمال تجمعی گاما به کار برده می‌شود (رابطه‌ی ۳).

$$t = x/\beta \quad (3)$$

$$F(x) = \frac{1}{\Gamma(\alpha)} \int_0^x t^{\alpha-1} e^{-t} dt$$

از آن‌جا که در رابطه‌ی ۳ مقدار لگاریتم صفر تعریف نشده است، و توزیع بارندگی ممکن است به اندازه‌ی صفر باشد، در این شرایط احتمال تجمعی از رابطه‌ی ۴ حساب می‌شود.

مک‌کی و همکاران (۱۹۹۳) معیار (SPI) را برای پیش خشک‌سالی شاخص بارندگی معرفی کردند. این شاخص تنها به اطلاعات بارندگی نیازمند است و می‌تواند در مقیاس‌های زمانی مختلف ۱، ۳، ۶، ۹، ۱۲، ۲۴ و ۴۸ ماهه حساب کرده شود. مسئله‌ی اصلی در محاسبه‌ی SPI برازش کردن توزیع آماری مناسب بر اطلاعات بارندگی است. تجربه نشان داده است که توزیع گاما توزیع مناسبی برای برازش کردن داده‌های بارندگی است. اگر فرض کنیم بارندگی در منطقه از توزیع گاما تبعیت می‌کند، و X اندازه‌های بارندگی باشد، تابع چگالی احتمال دو سنجه‌ی گاما با رابطه‌ی ۱ تعریف می‌شود.

$$f(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \quad x > 0 \quad (1)$$

خروجی گره λ م در لایه‌ی $(1-n)$ ، و M تعداد گره‌ها در لایه‌ی $(1-n)$ ام است.

در هر گره اندازه‌های محاسبه‌شده از معادله‌ی ۶ با تابع انتقال به عددی تبدیل شده است. تابع معمول برای این کار تابع سیگموئید است (رابطه‌ی ۷).

$$\text{Sig}(net_j^n) = 1 / (1 + \text{Exp}(-net_j^n)) \quad (7)$$

خروجی محاسبه‌شده‌ی هر گره با ضرب کردن چارچوب (ماتریس) وزن شبکه منتقل می‌شود.

در مسیر دوم (مسیر بازگشت^۸) با روش کاهش دادن شیب وزن‌های شبکه، برای کاهش دادن خطا، شبکه تغییر داده و تنظیم کرده می‌شود.

$$\Delta w_{ji}^n(m+1) = \eta \cdot \frac{\partial(E)}{\partial w_{ji}^n} + \alpha \cdot \Delta w_{ji}^n(m) \quad (8)$$

یادگیری، و α ضریب تکانه^۹ است. این کار تا رسیدن مقدار خطا به مقداری پذیرفتنی ادامه می‌یابد. در این جا مرحله‌ی یادگیری شبکه به پایان رسیده است، و اگر شبکه با ورودی از پیش‌نندیده روبه‌رو شود می‌تواند خروجی یا خروجی‌های نظیر را نگاشته کند.

شبکه‌ی RBF: شبکه‌های تابع پایه‌ی شعاعی (RBF) از نوع شبکه‌های روبه‌جلو همراه با لایه‌ی میانی است (برومهد و لائو ۱۹۸۸). در این روش اغلب تابع انتقال در لایه‌ی میانی، تابع گوسین و در لایه‌ی خروجی تابع خطی است. آموزش شبکه‌ی RBF عموماً به دو بخش تقسیم می‌شود. بخش اول عمدتاً یادگیری از نوع بی‌نظارت است که با روش‌های خوشه‌بندی، سنج‌های تابع پایه (مرکزها و عرض‌ها)، با اطلاعات ورودی تعیین کرده می‌شود، و در بخش دوم که یادگیری از نوع بانظارت است وزن‌های بین لایه‌ی میانی و لایه‌ی خروجی با روش‌های کاهش شیب و وایازی خطی تعیین کرده می‌شود.

شاخص بارش به‌معیار شده (در بازه‌ی زمانی ۳ ماهه) در یک گام جلوتر پیش‌بینی کرده شد. گره خروجی در همه‌ی شبکه‌های عصبی یک بود، و برای تعیین کردن وابستگی‌های زمانی اندازه‌های SPI با اندازه‌های پیشین خود، تأخیرهای زمانی متفاوت تعریف شد. بنابراین تعداد گره‌های ورودی از یک تا پنج تغییر داده، تا در نهایت بهترین تعداد تأخیر زمانی تعیین کرده شد (گلابی و همکاران ۲۰۱۴). بردار ورودی ترکیب متفاوتی از اندازه‌های SPI پیشین بود و بهترین بردار ورودی با سعی و خطا مشخص کرده شد. ساختارهای ورودی در جدول ۱ نشان داده شده است.

$$H(x) = q + (1 - q)F(x) \quad (4)$$

q احتمال بارندگی صفر است. برای محاسبه‌ی q می‌توان رابطه‌ی کالیفرنیا (رابطه‌ی ۵) را به کار برد.

$$q = \frac{m}{n} \quad (5)$$

m تعداد داده‌های صفر موجود در مجموعه‌ی زمانی، و n تعداد کل داده‌های بارندگی است.

گام بعدی در محاسبه‌ی SPI انتقال احتمال تجمعی $H(x)$ به‌دست‌آمده از توزیع گامای تجمعی، به توزیع بهنجار به‌معیار شده‌ی تجمعی با میانگین صفر و انحراف معیار یک است. در واقع SPI متغیری است از تابع توزیع بهنجار به‌معیار شده، که مقدار احتمال تجمعی آن با مقدار احتمال تجمعی متغیر در توزیع گاما مساوی باشد (موغاری و عراقی‌نژاد ۲۰۱۷).

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی، مدل‌های ریاضی انعطاف‌پذیری است که ممکن است در مدل‌سازی سامانه‌های پیچیده به کار برده شود. پردازش در شبکه‌های عصبی مصنوعی در واحدهای بسیاری به نام نورون یا گره انجام می‌شود. این شبکه‌ها با انتخاب کردن مناسب تعداد لایه‌ها و گره‌ها، نگاهشستی ناخطی بین ورودی‌ها و خروجی‌ها به‌دست می‌دهد. توانایی کلی شبکه‌ی عصبی مصنوعی یادگیری ارتباط ناخطی بین داده‌ها و تعیین کردن نتایج برای داده‌های دیگر است (کارایانیز و ونفسانوپولوس ۱۹۹۳). در مجموعه‌های زمانی تعداد گره‌های ورودی به تعداد مشاهده‌های تأخیر داده شده بستگی دارد. در این تحقیق شبکه‌ی عصبی مصنوعی MLP و RBF به کار برده شد.

شبکه‌ی MLP: شبکه‌های شناسنده‌ی^۵ چندلایه (MLP) از متداول‌ترین شبکه‌ها در پیش‌بینی و حل کردن مسئله‌های غیرخطی است. آموزش این شبکه‌ها با الگوریتم پس‌انتشار خطا^۶ (BP) است که در اساس دو مسیر اصلی دارد. در مسیر اول که مسیر رفت^۷ است، بردار ورودی به شبکه‌ی MLP اعمال می‌شود، و تأثیرهای آن از راه لایه‌های پنهان به لایه‌ی خروجی انتشار می‌یابد. اندازه‌ی ورودی‌ها برای هر گره از رابطه‌ی ۶ حساب کرده می‌شود (عیوضی و همکاران ۲۰۱۰):

$$net_i^n = \sum_{j=1}^m w_{ji}^n \cdot O_j^{n-1} \quad (6)$$

net_i^n اندازه‌های ورودی گره λ م در لایه‌ی n ام، w_{ji}^n وزن اتصالی بین گره λ م در لایه‌ی n ام و گره λ م در لایه‌ی $(n-1)$ ، O_j^{n-1}

- 5 - Perceptron
- 6 - Back Propagation
- 7 - Forward
- 8 - Backward
- 9 - Momentum

۱ تا ۵ گره در لایه‌ی ورودی، و افزایش تعداد گره‌های لایه میانی در هر دو شبکه، برای مجموعه‌ی زمانی SPI آزمایش کرده شد.

برای یافتن بهترین شبکه، در هر یک از شبکه‌ها، قانون‌های یادگیری مختلف تابع‌های انتقال مختلف، دوبه‌دو تا زمان رسیدن به بهترین حالت آزمایش کرده شد. شبکه در حالت

جدول ۱- ترکیب سنج‌های ورودی مدل‌های بررسی شده.

شماره‌ی مدل	ساختار ورودی	خروجی
۱	SPI _t	SPI _{t+1}
۲	SPI _t , SPI _{t-1}	SPI _{t+1}
۳	SPI _t , SPI _{t-1} , SPI _{t-2}	SPI _{t+1}
۴	SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3}	SPI _{t+1}
۵	SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3} , SPI _{t-4}	SPI _{t+1}

نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه‌ی خود، و میانگین صفر دارد که شرط مقبولیت نامیده می‌شود (رابطه‌ی ۹).

$$\int \psi(t) dt = 0 \quad (9)$$

$\psi(t)$ تابع موجکی است.

دو نوع تبدیل موجکی پیوسته^{۱۲} (CWT) و گسسته^{۱۳} (DWT) هست. تبدیل موجکی پیوسته با یکی از رابطه‌های ۱۰ بیان می‌شود.

$$CWT_s^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int s(t) \psi_{s,\tau}^*(t) dt \quad (10)$$

رابطه‌ی ۱۰ تابعی از دو متغیر s و τ است و در آن نشان‌دهنده‌ی انتقال^{۱۴} S ، بیانگر مقیاس^{۱۵} (عکس بسامد) و نشان‌دهنده‌ی مزدوج مختلط^{۱۶} است. سنج‌های S و عددهای حقیقی است و S همیشه مثبت است، که ممکن است اندازه‌های پیوسته یا گسسته بگیرد. S و در تبدیل موجکی پیوسته اندازه‌های پیوسته، و در تبدیل موجکی گسسته اندازه‌های گسسته دارد (طوفانی و همکاران ۲۰۱۲).

تبدیل گسسته‌ی موجک برای پردازش و تحلیل کردن مجموعه‌های زمانی مناسب‌تر از تبدیل پیوسته‌ی موجکی است، زیرا داده‌های تبدیل‌یافته با DWT اجزای اضافه ندارد، بنابراین تبدیل معکوس را می‌توان برای هر دسته از داده‌های زمان-بسامد به کار برد (نخعی ۲۰۱۲ و رجایی ۲۰۱۱).

در این تحقیق تبدیل موجک گسسته به کار برده شد. برای مدل

برنامه‌ریزی بیان ژن^{۱۰}


روش برنامه‌ریزی بیان ژن (فریرا ۲۰۰۱) ترکیبی از روش‌های برنامه‌ریزی ژنتیک و الگوریتم ژنتیک است که در آن کروموزوم‌های خطی و ساده با طول ثابت، مشابه با آن چه در الگوریتم ژنتیک به کار می‌رود، و ساختارهای شاخه‌یی با اندازه‌ها و شکل‌های متفاوت، مشابه با درختان تجزیه در برنامه‌ریزی ژنتیک، ترکیب می‌شود. در این روش همه‌ی ساختارهای شاخه‌یی با اندازه و شکل‌های متفاوت در کروموزوم‌های خطی با طول ثابت شناسه‌گذاری می‌شود. به‌طور خلاصه در برنامه‌ریزی بیان ژن به‌سازی‌ها در یک ساختار خطی اتفاق می‌افتد، و سپس با ساختار درختی بیان می‌شود. این موجب می‌شود که تنها ژنوم اصلاح‌شده به نسل بعد منتقل شود، و نیازی به ساختارهای سنگین برای تکثیر و جهش نباشد (فریرا ۲۰۰۱).

تحلیل موجکی^{۱۱}


تبدیل موجک از تبدیل‌های ریاضی کارآمد در پردازش پیام است. موجک‌ها تابع‌هایی ریاضی است که شکل مقیاس-زمان از مجموعه‌های زمانی و رابطه‌های آن‌ها برای تحلیل کردن مجموعه‌های زمانی شامل متغیرها و ناثابت‌ها را به دست می‌دهد. تحلیل موجکی کاربرد فاصله‌های زمانی طولانی را برای اطلاعات کم‌بسامد و کم‌تناوب برای اطلاعات پر‌بسامد می‌دهد، و جنبه‌های مختلف داده‌ها، نقطه‌های شکست و ناپیوستگی‌هایی را نمایش می‌دهد که ممکن است دیگر روش‌های تحلیل پیام آن‌ها را نشان ندهند (نورانی و همکاران ۲۰۰۹). موجک سه مشخصه‌ی تعداد

- 10 - Gene Expression Programming
- 11 - Wavelet transforms
- 12 - Continues Wavelet transform
- 13 - Discrete Wavelet transform
- 14 - Translation
- 15 - Scale
- 16 - Complex Conjugate


است دقت آموزش شبکه را افزایش دهد، اما بر داده‌های آزمون نتیجه‌ی عکس دارد (موسوی و همکاران ۲۰۱۳). نکته‌ی مهم انتخاب کردن موجک مادر است. این موجک باید به طبیعت رخداد پدیده و نوع مجموعه‌ی زمانی مشاهده‌شده شبیه باشد (رجایی ۲۰۱۳). شکل ۲ نمودار چند موجک مادر را نشان می‌دهد. بعد از تجزیه‌ی پیام بررسی‌شده (SPI بازه‌ی زمانی ۳ ماهه) با موجک مادر منتخب، زیرمجموعه‌های به‌دست‌آمده‌ی ورودی شبکه‌ی عصبی-مصنوعی و برنامه‌ریزی بیان زن مانند جدول ۱ تعریف شد.



پ



ب



الف

شکل ۲- نمودار تابع‌های موجک مادر به‌کاررفته بر دامنه‌ی آن‌ها. الف) Haar (ب) Db2 (پ) Meyer.

۳ ماهه محاسبه، و برای مدل‌سازی، داده‌های مجموعه‌ی زمانی SPI به دو بخش تقسیم کرده شد. مجموعه‌ی اندازه‌های SPI از سال آبی ۵۰-۱۳۴۹ تا ۸۴-۱۳۸۳ برای داده‌های آموزش، و از سال ۸۵-۱۳۸۴ تا ۹۳-۱۳۹۲ برای داده‌های صحت‌سنجی به‌کار گرفته شد.

وارد کردن داده‌های خام باعث کاهش یافتن سرعت و دقت شبکه‌های عصبی می‌شود. بنابراین، برای جلوگیری کردن از این شرایط، و برای یکسان-کردن ارزش داده‌ها برای شبکه، بهنجارسازی می‌شود تا از کوچک‌شدن بیش‌ازحد وزن‌ها و اشباع‌شدن زود هنگام گره‌ها جلوگیری کرده شود (بهمنی و همکاران ۲۰۰۶). این عمل به‌خصوص هنگامی که دامنه‌ی تغییرات ورودی‌ها زیاد باشد، کمک شایانی به آموزش دیدن بهتر و سریع‌تر مدل می‌کند. بنابراین قبل از آموزش دادن، رابطه‌ی ۱۶ برای بهنجارسازی داده‌ها به‌کاربرده شد:

$$x_n = \frac{X_0 - X_{\min}}{X_{\max} - x_{\min}} \quad (16)$$

X_n مقدار بهنجارشده‌ی سنجه، X_0 مقدار واقعی هر سنجه، X_{\max} کم‌ترین مقدار سنجه‌ی در نظر گرفته، و x_{\min} بیش‌ترین مقدار سنجه‌ی در نظر است.

نتیجه‌ی شبکه‌ی عصبی مصنوعی MLP و RBF ابتدا بی‌هیچ پیش‌پردازشی مدل‌های شبکه‌ی عصبی مصنوعی

ترکیبی عصبی موجک مجموعه‌ی زمانی SPI در بازه‌ی زمانی ۳ ماهه با موجک‌های مادر Haar, Db2, Db4, Db6, Db8 و Meyer به‌شکل گسسته و با دو تراز تجزیه کرده شد. تراز تجزیه با رابطه‌ی ۱۱ انتخاب شد (موسوی و همکاران ۲۰۱۳).

$$l = \text{int}[\log(n)] \quad (11)$$

l: تراز تجزیه و n: تعداد داده‌های مجموعه‌ی زمانی است. با تعداد داده‌های به‌کاررفته در این پژوهش (۵۲۶)، تراز تجزیه ۲ به‌دست آمد. به‌کاربردن تراز تجزیه‌ی زیاد مطلوب نیست، زیرا ممکن

معیارهای ارزیابی

برای ارزیابی کردن دقت و کارایی مدل‌ها نمایه‌های ضریب همبستگی (R)، جذر میانگین مربع‌های خطا (RMSE)، میانگین مطلق خطا (MAE) و ضریب نش‌ساتکلیف (NS) در رابطه‌های ۱۲ تا ۱۵ به‌کارگرفته شد.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (12)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (13)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - y_i| \quad (14)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad (15)$$

x_i و y_i به‌ترتیب اندازه‌های مشاهده‌ی و محاسبه‌ی در گام زمانی i ام، N تعداد گام‌های زمانی، و \bar{x} و \bar{y} به‌ترتیب میانگین اندازه‌های مشاهده‌ی و محاسبه‌ی است.

نتایج و بحث

شاخص بارش معیار (SPI) ایستگاه بیدستان در بازه‌ی زمانی

در جدول ۲ اندازه‌ی سنجه‌های R^2 ، NS، RMSE، MAE در تخمین‌زدن کوتاه‌مدت SPI برای دو مدل شبکه‌ی عصبی MLP و RBF آورده شده است. براساس محاسبه‌ها، بیش‌ترین مقدار R^2 و NS به‌اندازه‌ی ۰/۴۸۸ و ۰/۴۶۳ و کم‌ترین اندازه‌ی MAE و RMSE در مرحله‌ی صحت‌سنجی ۰/۰۹۱ و ۰/۱۲۱ (در مدل شبکه‌ی عصبی MLP) بود. از میان دو شبکه‌ی بررسی‌شده، MLP با ترکیب ۱-۴-۵ نتیجه‌ی بهتری از سایر ترکیب‌ها برای پیش‌بینی کردن SPI در بازه‌ی زمانی ۳ ماهه نشان داد. در واقع شبکه‌ی MLP با ۵ گره ورودی که نشان‌دهنده‌ی تأخیر زمانی شاخص بارش معیار است، و ۴ گره در لایه‌ی پنهان نتیجه‌ی بهتری از RBF به‌دست داد (جدول ۱).


MLP و RBF برای مدل‌سازی مجموعه‌ی شاخص بارش به‌معیار در بازه‌ی زمانی ۳ ماهه به‌کاربرده شد. نتایج نشان داد که کم‌ترین خطا و بیش‌ترین ضریب همبستگی بین تابع‌های یادگیری در تابع انتقال سیگموئید، و بین قانون‌های یادگیری در قانون یادگیری Delta Bar Delta است. تعداد گره‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسئله مشخص، و برای کاهش دادن مقدار خطا تعداد گره‌های لایه‌ی پنهان با سعی و خطا مشخص کرده شد. نتیجه‌ی آزمایش کردن تعداد گره‌های بیش‌تر از ۱۰ در لایه‌ی پنهان نشان داد که این افزایش گره سبب کارایی بهتر نمی‌شود و دقت آن ثابت می‌ماند. این نتیجه با پژوهش نورانی و همکاران (۲۰۰۹) و روانسالا و همکاران (۲۰۱۶) هم‌خوانی دارد.

جدول ۲- نتیجه‌ی کارایی مدل‌های شبکه‌ی عصبی مصنوعی MLP و RBF.

شبکه	مدل	ترکیب منتخب	آموزش				صحت‌سنجی			
			R^2	RMSE	MAE	NS	R^2	RMSE	MAE	NS
MLP	۱	۱-۸-۱	۰/۴۶	۰/۱۳۵	۰/۱۳	۰/۴۳	۰/۴۷۱	۰/۱۳۲	۰/۴۳	
	۲	۲-۷-۱	۰/۴۵۵	۰/۱۵	۰/۱۳۴	۰/۴۱	۰/۴۶۱	۰/۱۴۳	۰/۴۲	
	۳	۳-۸-۱	۰/۴۸	۰/۱۴	۰/۱۳	۰/۴۵۱	۰/۴۸۳	۰/۱۲۹	۰/۴۵	
	۴	۴-۶-۱	۰/۴۷۶	۰/۱۴۵	۰/۱۳۱	۰/۴۶	۰/۴۸۴	۰/۱۲۹	۰/۴۶	
	۵	۵-۴-۱	۰/۴۸	۰/۱۲۳	۰/۱۱	۰/۴۶	۰/۴۸۸	۰/۱۲۱	۰/۴۶۳	
RBF	۱	۱-۶-۱	۰/۳۸	۰/۱۶۱	۰/۱۶	۰/۳۵	۰/۳۸۴	۰/۱۶۵	۰/۳۶	
	۲	۲-۳-۱	۰/۴۰	۰/۱۶۰	۰/۱۵۵	۰/۳۶	۰/۴۰۸	۰/۱۶۲	۰/۳۶	
	۳	۳-۲-۱	۰/۴۱	۰/۱۵	۰/۱۴	۰/۳۸	۰/۴۲۲	۰/۱۵۱	۰/۳۷۶	
	۴	۴-۱۰-۱	۰/۴۶۷	۰/۱۵	۰/۱۱	۰/۴۵	۰/۴۷۵	۰/۱۳	۰/۴۵۵	
	۵	۵-۶-۱	۰/۴۳	۰/۱۵۵	۰/۱۲	۰/۴۰	۰/۴۵۴	۰/۱۵۰	۰/۴۱	

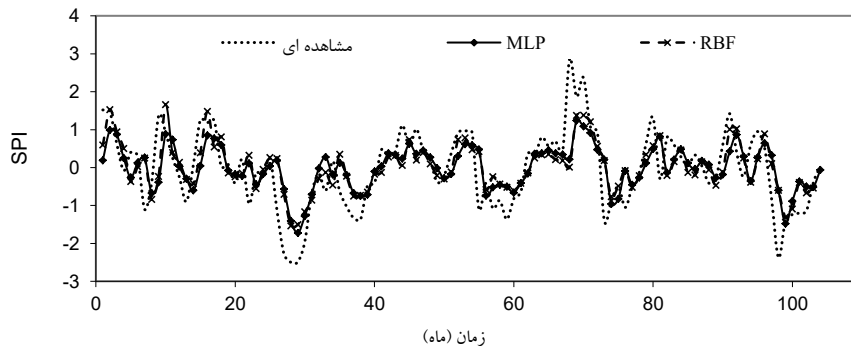
پیش‌بینی می‌کند، و این با یافته‌های کریسپو و مورا (۱۹۹۳) و عیوضی و همکاران (۲۰۱۰) مطابقت دارد. برای مقایسه در این شکل‌ها محدوده‌ی $\pm 30\%$ خطا نیز نشان داده و شیب خط وایازی با شیب خط ۱:۱ (خط ۴۵ درجه) مقایسه شد.

اگر اندازه‌های محاسبه‌شده‌ی SPI با دو نوع شبکه‌ی عصبی برای مجموعه‌ی زمانی (SPI:MLP و SPI:RBF)، در برابر داده‌های مشاهده‌ی (SPI) ترسیم شود (شکل ۳) می‌توان گفت که شبکه‌ی MLP اندازه‌ها را با دقت بیش‌تری از شبکه‌ی RBF



ب

الف



ج

شکل ۳- نمودار مدل‌های شبکه‌ی عصبی مصنوعی MLP و RBF برای داده‌های ثبت‌شده‌ی مرحله‌ی صحت‌سنجی. الف: نمودار پراکنش میان اندازه‌های مشاهده‌ی و محاسبه‌ی در مدل MLP. ب: نمودار پراکنش میان اندازه‌های مشاهده‌ی و محاسبه‌ی در مدل RBF و ج: اندازه‌های محاسبه‌ی و مشاهده‌ی نسبت به زمان.

$$F1: \{+, -, *, /, EXP, \sqrt{\quad}, Ln, ^2, ^3, \}$$
 (۱۸)

$$F3: \{+, -, *, /, \sqrt{\quad}, EXP, Ln, ^2, ^3, \sqrt[3]{\quad}, sin, cos, Atan\}$$
 (۱۹)

نتیجه‌ی مدل برنامه‌ریزی بیان ژن با سه عملگر (جدول ۴) بیانگر این است که مدل ترکیبی شماره‌ی ۳ (جدول ۱) با عملگر F۳ در هر دو مرحله‌ی آموزش و صحت‌سنجی بیش‌ترین مقدار R۲ و NS (۰/۴۹ و ۰/۴۸۳)، و کم‌ترین اندازه‌های MAE و RMSE (۰/۰۸۹ و ۰/۱۱۵) را دارد و دقت آن از سایر مدل‌ها بیش‌تر بود. بنابراین، دقت عملگر F۳ (رابطه‌ی ۱۹)، شامل چهار عملگر اصلی ریاضی، توانی، لگاریتمی و مثلثاتی در تخمین خشک‌سالی ایستگاه بیدستان، بیش‌ترین بود. این نتیجه با پژوهش مهدی زاده و همکاران (۲۰۱۷)، شعیب و همکاران (۲۰۱۵) و وانگ و همکاران (۲۰۱۹) همخوانی دارد.

نتایج برنامه‌ریزی بیان ژن

برنامه‌ریزی بیان ژن به این دلیل به کار برده شد که امکان انتخاب کردن متغیرهای موثر بر مدل، حذف کردن متغیرهای با تأثیر کم‌تر، و به‌دست‌دادن رابطه‌ی صریح برای تخمین‌زدن خشک‌سالی را دارد. هر پنج ورودی برای تعیین کردن متغیرهای معنی‌دار به کار رفت. برای بررسی کردن بیش‌تر، علاوه بر مجموعه‌ی چهار عملگر اصلی (F۱)، حالت‌هایی بر اساس عملگرهای ریاضی (F۲) و F۳ نیز به کار برده شد. نحوه و دلیل انتخاب این نوع عملگرها بر پایه‌ی پژوهش‌های پیشین (قربانی و همکاران ۲۰۱۲ و ۲۰۱۶) بود. سنجه‌های به کار رفته و نرخ آن‌ها در استخراج کردن مدل‌های پیش‌بینی خشک‌سالی با برنامه‌ریزی بیان ژن در جدول ۳ آورده شده است.

$$F1: \{+, -, *, /, \}$$
 (۱۷)

جدول ۳- اندازه‌ی سنج‌های به‌کاررفته در برنامه‌ریزی بیان ژن (قربانی ۲۰۱۶).



عملگرهای ژنتیکی		تنظیم‌های کلی	
۰/۰۴۴	نرخ جهش	۳۰	تعداد کروموزوم‌ها
۰/۱	نرخ وارون‌سازی	۸	اندازه‌ی رأس
۰/۱	نرخ ترانهش درج متوالی	۳	تعداد ژن در هر کروموزوم
۰/۱	نرخ ترانهش ریشه‌ی متوالی	۱۰۰۰	تعداد جمعیت تولیدشده
۰/۳	نرخ ترکیب تک نقطه‌یی	جمع (+)	تابع پیوند

قدر مطلق اندازه‌های بیشینه‌ی شاخص بارش معیار ضعیف عمل کرده و آن‌ها را کم‌تر از مقدار واقعی تخمین زده‌اند.

نمودار مدل برتر برنامه‌ریزی بیان ژن برای داده‌های ثبت‌شده‌ی مرحله‌ی صحت‌سنجی در شکل ۴ آورده شده است. مدل‌های شبکه‌ی عصبی-مصنوعی و برنامه‌ریزی بیان ژن در تخمین‌زدن

جدول ۴- نتیجه‌ی مدل برنامه‌ریزی بیان ژن (GEP) برای مدل‌های مختلف با سه مجموعه‌ی عملگر منتخب.

مدل	عملگر	آموزش				صحت‌سنجی			
		NS	MAE	RMSE	R ²	NS	MAE	RMSE	R ²
۱	F1	۰/۳۹۵	۰/۰۹۷	۰/۱۲	۰/۳۹۶	۰/۴۶۱	۰/۱۱۹	۰/۴۶۱	۰/۴۵
	F2	۰/۳۸۷	۰/۰۹۸	۰/۱۲۰	۰/۳۹۰	۰/۴۵۸	۰/۱۱۹	۰/۴۵۸	۰/۴۵۸
	F3	۰/۳۹۷	۰/۰۹۶	۰/۱۱۲	۰/۳۹۸	۰/۴۵۱	۰/۱۱۹	۰/۴۵۱	۰/۴۴۹
۲	F1	۰/۳۸۸	۰/۰۹۸	۰/۱۲۱	۰/۳۹۸	۰/۴۶۸	۰/۱۱۸	۰/۴۶۸	۰/۴۶۴
	F2	۰/۳۸۵	۰/۰۹۷	۰/۱۲۱	۰/۳۹۵	۰/۴۶۳	۰/۱۲۰	۰/۴۶۳	۰/۴۳۳۴
	F3	۰/۴۰۶	۰/۰۹۵	۰/۱۱۹	۰/۴۰۹	۰/۴۶۴	۰/۱۱۷	۰/۴۶۴	۰/۴۶۳
۳	F1	۰/۳۹۶	۰/۰۹۷	۰/۱۲۱	۰/۴۰۹	۰/۴۷۰	۰/۱۱۸	۰/۴۷۰	۰/۴۶۰
	F2	۰/۴۳۱	۰/۰۹۶	۰/۱۱۹	۰/۴۵۹	۰/۴۷۱	۰/۱۱۷	۰/۴۷۱	۰/۴۶۷
	F3	۰/۴۷	۰/۰۹۱	۰/۱۱۶	۰/۴۸۲	۰/۴۹	۰/۱۱۵	۰/۴۹	۰/۴۸۳
۴	F1	۰/۴۱۰	۰/۰۹۴	۰/۱۱۸	۰/۴۲۰	۰/۴۷۶	۰/۱۱۹	۰/۴۷۶	۰/۴۵۴
	F2	۰/۴۱۱	۰/۰۹۴	۰/۱۱۸	۰/۴۲۲	۰/۴۷۳	۰/۱۱۶	۰/۴۷۳	۰/۴۷۳
	F3	۰/۴۲۰	۰/۰۹۴	۰/۱۱۸	۰/۴۲۰	۰/۴۷۶	۰/۱۱۹	۰/۴۷۶	۰/۴۵۴
۵	F1	۰/۳۹۸	۰/۰۹۵	۰/۱۲۱	۰/۴۲۷	۰/۴۶۱	۰/۱۲۲	۰/۴۶۱	۰/۴۲۷
	F2	۰/۳۹۸	۰/۰۹۶	۰/۱۲۱	۰/۴۲۲	۰/۴۶۱	۰/۱۲۲	۰/۴۶۱	۰/۴۲۸
	F3	۰/۴۴۰	۰/۰۹۵	۰/۱۱۸	۰/۴۲۶	۰/۴۶۹	۰/۱۱۷	۰/۴۶۹	۰/۴۷

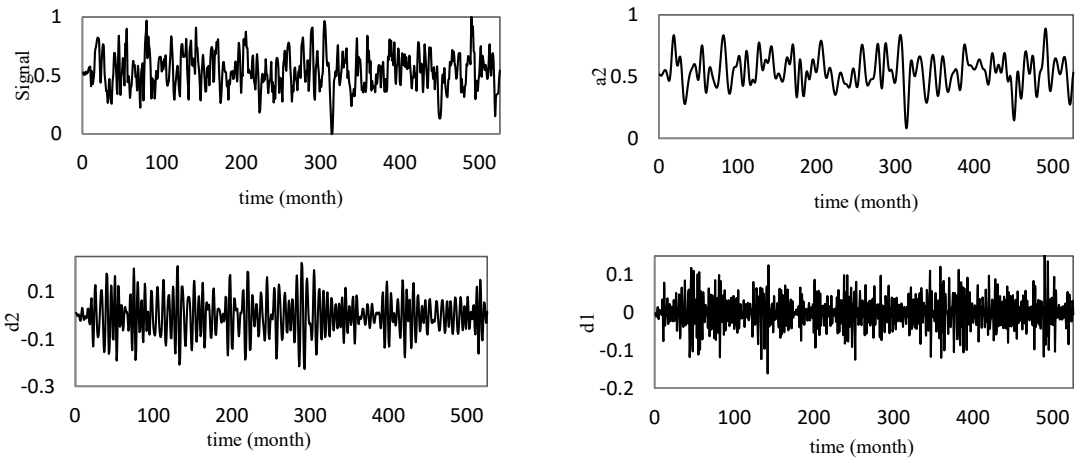


شکل ۴- نمودار مدل برتر برنامه‌ریزی بیان ژن (GEP) برای داده‌های ثبت‌شده مرحله‌ی صحت‌سنجی. الف: پراکنش میان اندازه‌های مشاهده‌یی و محاسبه‌یی، ب: اندازه‌های مشاهده‌یی و محاسبه‌یی نسبت به زمان.

با دو تراز تجزیه انتخاب شد. این انتخاب با تحقیق نورانی و همکاران (۲۰۰۹)، شفیایی و همکاران (۲۰۱۴)، و شعیب و همکاران (۲۰۱۵) مطابقت دارد. زیرمجموعه‌ی جزئی و تقریبی مجموعه‌ی زمانی SPI در بازه‌ی زمانی ۳ ماهه‌ی به‌دست‌آمده از تجزیه‌ی موجکی در شکل ۵ نشان داده شده است. تجزیه‌ی موجکی در شکل ۵ نشان داده شده است. تجزیه‌ی موجکی در شکل ۵ نشان داده شده است. تجزیه‌ی موجکی در شکل ۵ نشان داده شده است. تجزیه‌ی موجکی در شکل ۵ نشان داده شده است.

نتیجه‌ی مدل‌های WA-MLP، WA-RBF

برای تجزیه‌کردن پیام شاخص بارش معیار تبدیل موجک به‌کاربرده شد. برای افزایش دقت مدل شبکه‌ی عصبی مصنوعی، این پیام با تبدیل کردن موجک گسسته پیش‌پردازش کرده، و ورودی شبکه‌ی عصبی گذاشته شد. اولین قدم برای تجزیه‌کردن پیام با موجک، انتخاب کردن موجک مادر است. از میان موجک‌های بررسی‌شده، موجک مادر Meyer شباهت بیش‌تری با مجموعه‌ی زمانی SPI در بازه‌ی زمانی ۳ ماهه دارد. بنابراین موجک Meyer برای تجزیه‌کردن مجموعه‌ی زمانی در نظر گرفته




شکل ۵- زیر مجموعه‌ی جزئی و تقریبی d_1 ، d_2 و a_2 به‌دست‌آمده از تجزیه‌ی موجکی ($signal = a_2 + d_2 + d_1$).

زیرپیام باشد. با توجه به تشکیل‌شدن هر مجموعه‌ی زمانی از دو مؤلفه‌ی معین و تصادفی، ماهیت ناخطی و انعطاف‌پذیری شبکه‌های عصبی و خصوصیت‌های تبدیل موجک، می‌توان نتیجه گرفت که اگر تبدیل موجک در جای پیش‌پردازش مجموعه‌ی زمانی بارش معیارشده در بازه‌ی زمانی ۳ ماهه به‌کار برده شود، با دقتی پذیرفتنی می‌توان خشک‌سالی کوتاه‌مدت را پیش‌بینی کرد. در واقع، تبدیل موجکی با جداکردن پیام به بسامدهای زیاد و کم، ویژگی‌های چندمقیاسی پیام را می‌گیرد و دقت مدل را بسیار زیاد می‌کند. مقایسه‌ی شکل‌های ۳ و ۶ به‌خوبی نشان‌دهنده‌ی کارایی بهتر مدل شبکه‌ی عصبی-موجک در برابر مدل شبکه‌ی عصبی مصنوعی است.


نتیجه‌ها برتری چشم‌گیر روش شبکه‌ی عصبی-موجکی را به روش‌های شبکه‌ی عصبی مصنوعی در پیش‌بینی کردن نشان داد. مدل شبکه‌ی عصبی-موجک WA-MLP دقت بیش‌تری از WA-RBF دارد، به‌طوری که بیش‌ترین R^2 و NS (۰/۸۷ و ۰/۷۶) و کم‌ترین $RMSE$ و MAE (۰/۰۵ و ۰/۰۳) از مدل WA-MLP با ۳ گره ورودی و ۱۰ گره در لایه‌ی پنهان بود. نتایج نشان داد که دقت شبکه‌ی عصبی مصنوعی-موجک در پیش‌بینی کردن خشک‌سالی مناسب‌تر از مدل شبکه‌ی عصبی با تغییر شاخص است، و این با نتیجه‌ی تحقیق آداموسکی و همکاران (۲۰۱۱)، بلاینه و همکاران (۲۰۱۴)، کماسی و همکاران (۲۰۱۷)، و روانسالار (۲۰۱۶) مطابقت دارد. دقت بیش‌تر مدل شبکه‌ی عصبی-موجک نه‌تنها به‌دلیل پیش‌پردازی و بخش‌بندی موجک به زیرپیام‌های مختلف است، بل که علت آن ممکن است توجه به تأثیر هر زیرپیام تجزیه‌ی با بزرگ‌نمایی نسبی وزن آن

جدول ۵- نتیجه کارآیی مدل های شبکه‌ی عصبی مصنوعی-موجک WA-MLP و WA-RBF.


صحت‌سنجی				آموزش				ترکیب	مدل	شبکه
NS	MAE	RMSE	R ²	NS	MAE	RMSE	R ²	منتخب		
۰/۷۰	۰/۰۵۵	۰/۰۷۰	۰/۸۲۶	۰/۶۷	۰/۰۷۱	۰/۰۹۱	۰/۷۹	۱-۷-۱	۱	WA-MLP
۰/۷۰	۰/۰۶	۰/۰۷۱	۰/۸۲۶	۰/۶۶	۰/۰۷۳	۰/۰۹۱	۰/۸۰	۲-۹-۱	۲	
۰/۷۶	۰/۰۳	۰/۰۵	۰/۸۷	۰/۷۵	۰/۰۳۵	۰/۰۶	۰/۸۶	۳-۱۰-۱	۳	
۰/۷۵	۰/۰۴۲	۰/۰۶۲	۰/۸۵۷	۰/۷۶	۰/۰۴۵	۰/۰۷	۰/۸۵	۴-۹-۱	۴	
۰/۷۲	۰/۰۴	۰/۰۶۲	۰/۸۵۸	۰/۷۰	۰/۰۴۵	۰/۰۷۱	۰/۸۴	۵-۱۰-۱	۵	
۰/۵۰	۰/۰۸	۰/۱۲	۰/۵۷	۰/۴۸	۰/۰۸۱	۰/۱۲	۰/۵۲	۱-۶-۱	۱	WA-RBF
۰/۱۶	۰/۰۵۵	۰/۱۱	۰/۶۱	۰/۵۸	۰/۰۵	۰/۱۲	۰/۶۰	۲-۵-۱	۲	
۰/۵۵	۰/۰۹	۰/۱۲	۰/۵۹۶	۰/۵۴	۰/۰۹۲	۰/۱۴	۰/۵۲	۳-۱-۱	۳	
۰/۴۸	۰/۰۸۱	۰/۱۳	۰/۴۶	۰/۴۹	۰/۰۹	۰/۱۴	۰/۴۶	۴-۸-۱	۴	
۰/۴۷	۰/۰۸	۰/۱۳	۰/۴۷	۰/۴۷	۰/۱۰	۰/۱۴	۰/۴۵	۵-۱۰-۱	۵	



ب



الف



ج

شکل ۶- نمودار مدل های شبکه‌ی عصبی مصنوعی-موجک WA-RBF و WA-MLP برای داده‌های ثبت‌شده‌ی مرحله‌ی صحت‌سنجی.

الف: نمودار پراکنش میان اندازه‌های مشاهده‌یی و محاسبه‌یی در مدل WA-MLP، ب: نمودار پراکنش میان اندازه‌های مشاهده‌یی و محاسبه‌یی در مدل WA-RBF و ج: اندازه‌های محاسبه‌یی و مشاهده‌یی در گذر زمان.

نتایج برنامه‌ریزی بیان ژن-موجک


برای افزایش دادن دقت مدل برنامه‌ریزی بیان ژن، مجموعه‌ی زمانی شاخص بارش معیار (SPI) در بازه‌ی زمانی ۳ ماهه با موجک مادر Meyer در دو تراز تجزیه کرده شد. زیرمجموعه‌های به‌دست‌آمده طبق مدل‌های جدول ۱ ورودی برنامه‌ریزی بیان ژن تعریف کرده شد. با توجه به معیارهای ارزیابی، مدل ترکیبی شماره‌ی ۳ (جدول ۱) با عملگر ۳ (رابطه‌ی ۱۹) در هر دو مرحله‌ی آموزش و صحت‌سنجی، نتیجه‌ی بهتری از سایر مدل‌ها در پیش‌بینی شاخص بارش معیار می‌دهد (جدول ۵). بیش‌ترین مقدار R^2 و NS مدل برتر ۰/۹۳ و ۰/۸۴۵، و کم‌ترین اندازه‌ی MAE و RMSE به‌ترتیب ۰/۰۲۲ و ۰/۰۳۷ بود (جدول ۶).

نمودار مدل برتر برنامه‌ریزی بیان ژن-موجک برای داده‌های ثبت‌شده‌ی مرحله‌ی صحت-سنجی نشان می‌دهد که مدل WA-GEP می‌تواند به‌خوبی و با دقت زیاد شاخص بارش معیار (SPI) را در بازه‌ی زمانی ۳ ماهه‌ی ایستگاه بیدستان پیش‌بینی کند (شکل ۷).


کاربرد تبدیل موجک قبل از ورود اطلاعات به شبکه‌ی عصبی و برنامه‌ریزی بیان ژن، دقت کار را بسیار افزایش داده است و توانایی بهتری در پیش‌بینی دارد (جدول ۴ و ۶). این یافته با نتیجه‌ی داننده‌مهر و همکاران (۲۰۱۴)، شعیب و همکاران (۲۰۱۵)، روانسالار و همکاران (۲۰۱۶)، یوسفی و همکاران (۲۰۱۷)، و سلگی و همکاران (۲۰۱۸) مطابقت دارد.

جدول ۶- نتیجه‌ی مدل برنامه‌ریزی بیان ژن-موجک (WA-GEP) برای مدل‌های مختلف با سه مجموعه‌ی عملگر منتخب.

مدل	عملگر	آموزش				صحت‌سنجی			
		NS	MAE	RMSE	R^2	NS	MAE	RMSE	R^2
۱	F1	۰/۵۹۰	۰/۰۷۹	۰/۰۹۹	۰/۵۹۴	۰/۶۷۵	۰/۰۷۳	۰/۰۹۲	۰/۶۷۶
	F2	۰/۵۵۱	۰/۰۸۳	۰/۱۰۳	۰/۵۹۴	۰/۶۴۶	۰/۰۷۷	۰/۰۹۶	۰/۶۶۹
	F3	۰/۵۹۲	۰/۰۷۸	۰/۰۹۹	۰/۵۹۷	۰/۶۷۸	۰/۰۷۲	۰/۰۹۱	۰/۶۸۰
۲	F1	۰/۶۷۸	۰/۰۶۹	۰/۰۸۸	۰/۷۵۵	۰/۷۵۴	۰/۰۶۱	۰/۰۸۱	۰/۸۰۶
	F2	۰/۶۴۹	۰/۰۷۳	۰/۰۹۲	۰/۷۳۳	۰/۷۴۱	۰/۰۶۳	۰/۰۸۱	۰/۷۹۲
	F3	۰/۶۹۴	۰/۰۶۸	۰/۰۸۷	۰/۷۲۹	۰/۷۴۶	۰/۰۶۵	۰/۰۸۲	۰/۷۷۲
۳	F1	۰/۶۹۵	۰/۰۵۰	۰/۰۷۸	۰/۷۴۰	۰/۶۸۲	۰/۰۵۲	۰/۰۷۲	۰/۷۷۷
	F2	۰/۷۸۳	۰/۰۴۲	۰/۰۷۷	۰/۷۹۶	۰/۷۶۲	۰/۰۴۷	۰/۰۶۵	۰/۸۳۳
	F3	۰/۸۳۵	۰/۰۳۰	۰/۰۵۰	۰/۹۰۳	۰/۸۴۵	۰/۰۲۲	۰/۰۳۷	۰/۹۱۱
۴	F1	۰/۸۱۹	۰/۰۵۲	۰/۰۶۶	۰/۸۲۱	۰/۸۲۹	۰/۰۴۳	۰/۰۴۶	۰/۸۶
	F2	۰/۶۵۸	۰/۰۷۱	۰/۰۹۰	۰/۶۶۵	۰/۷۰۸	۰/۰۷۰	۰/۰۸۷	۰/۷۱۰
	F3	۰/۷۰۷	۰/۰۶۶	۰/۰۸۴	۰/۷۱۱	۰/۷۴۵	۰/۰۶۵	۰/۰۸۱	۰/۷۵۰
۵	F1	۰/۷۰۱	۰/۰۶۵	۰/۰۸۵	۰/۷۰	۰/۷۰۸	۰/۰۶۶	۰/۰۸۶	۰/۷۱۰
	F2	۰/۶۷۶۰	۰/۰۶۹	۰/۰۸۹	۰/۶۸۶	۰/۷۱۶	۰/۰۶۸	۰/۰۸۶	۰/۷۳۰
	F3	۰/۷۱۵	۰/۰۶۵	۰/۰۸۳	۰/۷۲۰	۰/۷۴۷	۰/۰۶۲	۰/۰۸۱	۰/۷۵۰



ب



الف

شکل ۷- نمودار مدل برتر برنامه‌ریزی بیان ژن-موجک (WA-GEP) برای داده‌های ثبت‌شده‌ی مرحله‌ی صحت‌سنجی. الف: پراکنش اندازه‌ی های مشاهده‌یی و محاسبه‌یی، ب: اندازه‌های مشاهده‌یی و محاسبه‌یی در گذر زمان.

با اختلافی اندک به مدل MLP برتری داشت. این مدل‌ها در تخمین قدرمطلق اندازه‌های بیشینه‌ی شاخص بارش معیار ضعیف عمل کردند، و آن‌ها را کم‌تر از مقدار واقعی تخمین زدند (شکل ۳-ج و ۴-ب). تجزیه‌ی مجموعه‌ی زمانی شاخص معیار با تبدیل کردن موجک و به کار بردن مدل‌های شبکه‌ی عصبی مصنوعی و برنامه‌ریزی بیان ژنی، باعث افزایش یافتن دقت این مدل‌ها شد، به طوری که اندازه‌ی R^2 و NS در مدل برنامه‌ریزی بیان ژن-موجک به ترتیب به ۰/۹۱۱ و ۰/۸۴۵ بود. نتیجه‌ی برنامه‌ریزی بیان ژن-موجک در مرحله‌ی صحت‌سنجی نشان داد که این مدل به خوبی اندازه‌های شاخص بارش معیار در نقطه‌ی بیشینه و کمینه را تخمین می‌زند.

مقایسه‌ی عملکرد مدل‌ها

جواب بهینه‌ی هر یک از روش‌های هوشمند انتخاب و با یکدیگر مقایسه کرده شد. از بین روش‌های به کار رفته، برنامه‌ریزی بیان ژن-موجک بیش‌ترین ضریب همبستگی (۰/۹۱۱)، کم‌ترین جذر میانگین مربع‌های خطا (۰/۰۳۷)، بیش‌ترین ضریب نش-ساتکلیف (۰/۸۴۵)، و کم‌ترین میانگین قدر مطلق خطا (۰/۰۲۲) را در مرحله‌ی صحت‌سنجی نشان داد (جدول ۷). مقایسه‌ی شبکه‌ی عصبی مصنوعی MLP و RBF نیز نشان‌دهنده‌ی برتری روش MLP است. عملکرد هر دو مدل MLP و GEP در پیش‌بینی شاخص بارش معیار در بازه‌ی زمانی ۳ ماهه مشابه بود (جدول ۲ و ۴)، در حالی که مدل GEP

جدول ۷- نتیجه‌ی نهایی روش‌های MLP، RBF، GEP، WA-MLP، WA-RBF، WA-GEP.

صحت‌سنجی			آموزش				مدل	
NS	MAE	RMSE	R^2	NS	MAE	RMSE	R^2	
۰/۴۶۳	۰/۰۹۱	۰/۱۲۱	۰/۴۸۸	۰/۴۶	۰/۱۱	۰/۱۲۳	۰/۴۸	MLP
۰/۴۵۵	۰/۱	۰/۱۳	۰/۴۷۵	۰/۴۵	۰/۱۱	۰/۱۵	۰/۴۶۷	RBF
۰/۴۸۳	۰/۰۸۹	۰/۱۱۵	۰/۴۹	۰/۴۷	۰/۰۹۱	۰/۱۱۶	۰/۴۸۲	GEP
۰/۷۶	۰/۰۳	۰/۰۵	۰/۸۷	۰/۷۵	۰/۰۳۵	۰/۰۶	۰/۸۶	WA-MLP
۰/۶	۰/۰۵۵	۰/۱۱	۰/۶۱	۰/۵۸	۰/۰۵	۰/۱۲	۰/۶۰	WA-RBF
۰/۸۴۵	۰/۰۲۲	۰/۰۳۷	۰/۹۱۱	۰/۸۳۵	۰/۰۳۰	۰/۰۵۰	۰/۹۰۳	WA-GEP

موجک WA-RBF بود، که با نتیجه‌ی آداموسکی و همکاران (۲۰۱۱)، بلاینه و همکاران (۲۰۱۴)، کماسی و همکاران (۲۰۱۷)، و روانسالار (۲۰۱۶) مطابقت دارد. نشان داده شد که به کار بردن تبدیل موجک دقت پیش‌بینی مدل تلفیقی شبکه‌ی عصبی مصنوعی-موجک و برنامه‌ریزی بیان ژن-موجک را افزایش می‌دهد. این یافته با نتیجه‌های داندنمه‌هر و همکاران (۲۰۱۴)، شعیب و همکاران (۲۰۱۵)، روانسالار و همکاران (۲۰۱۶)، یوسفی و همکاران (۲۰۱۷)، و سلگی و همکاران (۲۰۱۸) مطابقت دارد. دقت بیش‌تر مدل‌های تلفیقی نه تنها به دلیل پیش‌پردازش شدن و بخش‌بندی شدن موجک به زیرپیام‌های مختلف است، بل که علت آن می‌تواند توجه به تأثیر هر زیرپیام تجزیه‌ی به‌وسیله‌ی بزرگ‌نمایی نسبی وزن آن زیرپیام باشد. از میان موجک‌های مادر Db_1 ، Haar، Db_2 ، Db_4 ، Db_6 ، Db_8 و Meyer، موجک مادر Meyer به دلیل شباهت آن با پیام بررسی‌شده بهترین موجک دانسته شد، که با نتیجه‌های نورانی و همکاران (۲۰۰۹)، شفایی و همکاران (۲۰۱۴)، و شعیب و همکاران (۲۰۱۵) مطابقت دارد. با توجه به ویژگی‌های نالیستایی و ناخطی بودن مجموعه‌ی زمانی شاخص بارش معیار در بازه‌ی زمانی ۳ ماهه، برای

نتیجه‌گیری


در این تحقیق عمل‌کرد روش‌های مختلف در پیش‌بینی کردن شاخص بارش به معیار (SPI) در بازه‌ی زمانی ۳ ماهه در ایستگاه بیدستان ارزیابی کرده شد. مدل‌های به کار رفته شبکه‌های عصبی مصنوعی شناسنده‌ی چندلایه (MLP) و تابع پایه‌ی شعاعی (RBF)، برنامه‌ریزی بیان ژن، شبکه‌های عصبی-موجک WA-MLP و WA-RBF، و برنامه‌ریزی بیان ژن-موجک (WA-GEP) بود. اندازه‌های SPI مشاهده‌ی و محاسبه‌ی با معیارهای ارزیابی مقایسه کرده شد. برتری روش برنامه‌ریزی بیان ژن-موجک به دیگر روش‌های بررسی‌شده برای پیش‌بینی مجموعه‌ی زمانی SPI در بازه‌ی ۳ ماهه مشخص کرده شد. کم‌ترین خطا و بیش‌ترین دقت در روش برنامه‌ریزی بیان ژن-موجک (WA-GEP) با شاخص بارش معیار ۳ دوره‌ی قبل بود و بهترین الگوی ساخته‌شده برای این روش دانسته شد. کارایی نسبی شبکه‌های عصبی مصنوعی-موجک بر روش‌های شبکه‌ی عصبی مصنوعی برتری داشت. نتیجه‌ی شبکه‌ی عصبی مصنوعی-موجک شناسنده‌ی چندلایه (WA-MLP) و الگوریتم پس‌انتشار خطا در پیش‌بینی-کردن مجموعه‌های زمانی SPI در بازه‌ی زمانی ۳ ماهه بهتر از شبکه‌ی عصبی-

برای مدل برنامه‌ریزی بیان ژن، بیش-ترین دقت در تخمین‌زدن خشک‌سالی ایستگاه بیدستان در عملگر F₃، که شامل چهار عملگر اصلی، ریاضی، توانی، لگاریتمی و مثلثاتی است دیده شد. شبکه‌ی عصبی مصنوعی شناسنده‌ی چندلایه (MLP) و الگوریتم پس‌انتشار خطا نتیجه‌ی بهتری از شبکه‌ی عصبی تابع پایه‌ی شعاعی RBF نشان داد، و این نیز با نتیجه‌ی کریسپو و مورا (۱۹۹۳) و عیوضی و همکاران (۲۰۱۰) مطابقت دارد.

شبیه‌سازی کردن دقیق باید تبدیل موجک را به‌کاربرد، چرا که شبکه‌ی عصبی مصنوعی و برنامه‌ی بیان ژن به تنهایی نمی‌تواند بر نالیستایی پیام غلبه کند. تبدیل موجکی با داشتن امکان جداکردن پیام به فرکانس‌های زیاد و کم، ویژگی‌های چندمقیاسی پیام را دارد، و دقت مدل‌ها را بسیار زیاد می‌کند، و این با نتیجه‌های داننده‌مهر و همکاران (۲۰۱۴) و شعیب و همکاران (۲۰۱۵) مطابقت دارد. از میان ۳ عملگر به‌کاررفته

- Adamowski J, Fung Chan H. 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*. 407: 28–40.
- Bahmani A, Ebrahimi SH, Gholinejad S. 2006. Development of rainfall-runoff ANN model for watershed and investigation its extend ability for neighborhood stations. *Proceedings of second conference of water resource management*. 22–23 January, Isfahan university of technology. 1–8.
- Belayneh A, Adamowski J, Khalil , Ozga-Zielinki B. 2014. Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression. *Journal of Hydrology*. 508: 418–429.
- Broomhed D.S, Lowe D. 1988. Multivariate functional interpolation and adaptive networks. *Complex system*. 2: 321–355.
- Crespo J, Mora E. 1993. Drought estimation with neural networks. *Advances in engineering software*. 8(3):167–170.
- Danandeh Mehr A, Kahya E, Ozger M. 2014. A gene-wavelet model for long lead time drought forecasting. *Journal of Hydrology*. 517: 691–699.
- Eivazi M, Mosaedi A, Dehghani A. 2010. Comparison of different approaches for predicting SPI. *Journal of Water and Soil Conservation*. 16(2):145167.
- Ferreira C. 2001. Gene expression programming: a new adaptive algorithm for solving problems. *Complex Systems*. 13(2): 87–129.
- Ghorbani M, Dehghani R. 2016. Application of Bayesian Neural Networks, Support Vector Machines and Gene Expression Programming Analysis of Rainfall - Runoff Monthly (Case Study: Kakarza River). *Science and irrigation engineering Scientific and Research Journal*. 39(2): 125–138.
- Ghorbani M, Khatibi R, Asadi H, Yousefi P. 2012. Inter comparison of an evolutionary programming model of suspended sediment time-series with other local model. *Journal of Hydrology*. 511: 530–545.
- Golabi M, Radmanesh F, Akhondali A. 2014. An investigation of artificial neural network and time series performance in the index standard precipitation drought modeling (Case study: selected stations of Khuzestan Province). *Arid Biome Scientific and Research Journal*. 3(1): 82–87. (In Persian).
- Hosseini Moghari S, Araghinejad SH. 2017. Application of Statistical, Fuzzy and Perceptron Neural Networks in Drought Forecasting (Case Study: Gonbad-e Kavous Station). *Journal of Water and Soil*. 30(1): 247–259. (In Persian).
- Karayiannis N. B, Venetsanopoulos A. N. 1993. *Artificial neural network: Learning algorithms, performance evaluation, and application*. kluwer academic publisher, Boston. 523 pp.
- Komasi M, Nozari H, Gheshlaghi N. 2017. Forecasting of water level in Urmia Lake using Time series, Artificial Neural Network and Neural Network-Wavelet. *Water Engineering and Irrigation Science and Research Quarterly*. 6(24): 64–77.
- McKee T, Doesken N, Kleist J. 1993. The relation of drought frequency and duration to time scales. *Preprints*. 8th Conference on Applied Climatology, 17-22 January, 379–384.
- Mehdizadeh S, Behmanesh J, Khalili K. 2017. Application of gene expression programming to predict daily dew point temperature. *Applied Thermal Engineering*. 112: 1097–1107
- Mishra A, Desai V. 2006. Drought forecasting using feed- forward recursive neural network. *Ecological modeling*. 198(1–2): 127–138.
- Mishra A, Singh V. 2010. A review of drought

- concepts, *Journal of Hydrology*. 391 (1–2): 202–216.
- Moosavi V, Vafakhah M, Shirmohammadi B, Behnia N. 2013. A wavelet- ANFIS hybrid model for groundwater level forecasting for different prediction periods. *Journal of Water Resource Management*. 27(5): 1301–1321.
- Moried S, Moghaddasi M, Paemozd SH, Ghaemi H. 2005. Monitoring the Drought During 1998 to 2000 in Tehran Province, Using EDI, SPI, DI Indices and Geographical Information System. *Journal of Spatial Planning*. 9(1): 197–215.
- Nakhaei M, Saberi Nasr A. 2012. A Combined wavelet-artificial neural network model and its applications to the prediction of groundwater level fluctuations. *Geopersia*. 2(2): 77–91.
- Nourani V, Alami M, Aminfar M. 2009. A combined neural- wavelet model for prediction of Lighvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*. 22: 466–472.
- Prathumchai K, Honda K, Nualchawee K. 2001. Drought risk evaluation using remote sensing and GIS: A case study in Lopburi Province. 22nd Asian Conference on Remote Sensing. National University of Singapore. Singapore.
- Rajaei T. 2011. Wavelet and ANN combination model for prediction of daily suspended sediment load in river. *Science of the Total Environment*. 409(15): 2917–2928.
- Rajaei T, Ebrahimi H. 2013. Modeling of groundwater fluctuations by wavelet transform and dynamic neural network. *Water and irrigation management*. 4(14): 73–87. (In Persian).
- Ravansalar M, Rajaei T, Zounemat-kermani M. 2016. A wavelet- linear genetic programming model for sodium concentration forecasting in rivers. *Journal of Hydrology*. 537: 398–407.
- Shafaei M, Fakheri Fard A, Darbandi S, Ghorbani M. 2014. Prediction Daily Flow of Vanyar Station Using ANN and Wavelet Hybrid Procedure. *Water Engineering and Irrigation Science and Research Quarterly*. 4(14): 113–128. (In Persian).
- Sharma B, Smakhtin V. 2004. Potential of water harvesting as a strategic tool for drought mitigation. International Water Management Institute. Colombo, Sri Lanka.
- Shoaib M, Shamseldin A, Melville B, and Munner Khan M. 2015. Runoff forecasting using hybrid Wavelet Gene Expression Programming (WGEP) approach. *Journal of Hydrology*. 527:326–344
- Sifuzzaman M, M Islam, M Ali. 2009. Application of wavelet transform and its advantages compared to fourier transform. *Journal of Physical Sciences*, 13:121–134.
- Solgi A, Zarei H, Golabi M.R. 2018. Performance assessment of gene expression programming model using data preprocessing methods to modeling river flow. *Journal of Water and Soil Conservation*. 27(2):185–201. (In Persian).
- Toufani P, Mosaedi A, Fakheri Fard A. 2012. Prediction of Precipitation Applying Wavelet Network Model (Case study: Zarringol station, Golestan province, Iran). *Journal of Water and Soil*. 25(5): 1217–1226. (In Persian).
- Wang Sh, Lian J, Peng Y, Hu B, and Chen H. 2019. Generalized reference evapotranspiration models with limited climatic data based on random forest and gene expression programming in Guangxi, China. *Agricultural Water Management*. 221: 220–230
- Yousefi P, Shabani S, Mohammadi H, and Naser Gh. 2017. Gene expression programming in long term water demand forecasts using wavelet decomposition. *Procedia Engineering*. 186: 544 – 550



Watershed Management Research

VOL. 33, No. 1, Ser. No: 126, Spring 2020, pp.39 -55
DOI: 10.22092/wmej.2019.125825.1204

Evaluation of Integrated Models of Wavelet-Artificial Neural Network and Wavelet-Gene Expression Programming in the Short-Term Drought Prediction

Mahbobeh Younesi

Ph.D. Student in Water Resources Engineering, Department of Water Sciences Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

Hamed Nozari *

(Corresponding Author)* Associate Professor. Department of Water Sciences Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

*Corresponding Author Email: h.nozari@basu.ac.ir

Received: 11 April 2019 Accepted: 17 December 2019

Abstract

Drought prediction plays an important role in the planning and management of natural resources, water resources and plant water requirements. Wavelet transform is one of the new and highly effective methods for analysing signals and time series. Using the mother wavelet, the standard precipitation index (SPI) signal was analyzed and the results were considered as inputs of the artificial neural network models and the gene expression programming (GEP). Multi-layer perceptron (MLP), radial basis function (RBF), (GEP), as well as the wavelet-artificial neural networks integrated model and multi-layer perceptron (WA-MLP), radial basis function (WA- RBF) and wavelet- gene expression programming (WA- GEP) were used for drought forecasting. The rainfall data collected at the Bidestan Station for a period of 44 years were used on the Shoor Watershed in the Province of Qazvin. Moisture condition was calculated using the SPI in the short-term period of 3 months. To estimate the SPI in each period, the respective amounts were considered from the previous cycles. The results showed that among the six applied models, the WA-GEP predicted the SPI values and the short-term drought condition with a higher accuracy. The WA-GEP model proved to be the best scenario in the validation stage of R2, RMSE, MAE and NS of 0.911, 0.37, 0.22 and 0.845, respectively.

Keywords: Drought prediction, standard precipitation index, wavelet-artificial neural networks, wavelet-gene expression programming