

Drought Prediction Using GEP-GARCH Hybrid Model (Case Study: Salmas Synoptic Station)

ABBAS ABBASI¹, KEIVAN KHALILI^{2*}, JAVAD BEHMANESH³, AKBAR SHIRZAD⁴

1. Ph.D in Water Resources Engineering, Department of Water Engineering, Faculty of Agriculture, Urmia University, Urmia, Iran
2. Assistant Professor, Department of Water Engineering, Faculty of Agriculture, Urmia University, Urmia, Iran
3. professor, Department of Water Engineering, Faculty of Agriculture, Urmia University, Urmia, Iran
4. Assistant Professor, Department of Civil Engineering, Faculty of Civil Engineering, Urmia University of Technology, Urmia, Iran

(Received: Dec. 17, 2018- Revised: Jan. 9, 2019- Accepted: Jan. 21, 2019)

ABSTRACT

Drought prediction plays an important role in designing drought adaptation systems and implementation of relief operations. Hydrological data is a combination of a definite and random section. Given the fact that the production data of intelligent models are definite, application of a new approach, using the random part in predicting this data can increase the certainty of the model. In this research, it was attempted to provide a hybrid model for prediction of drought using a combination of the Gene Expression Programming model (GEP) and the Generalized Auto Regressive Conditional Heteroscedasticity (GARCH) time series model. For this purpose, drought prediction in Salmas station using SPEI drought index at different time scales was investigated during 35 years statistical period and with 5 different input models. The results showed that the GEP method does not have the appropriate accuracy in short-term time scale of SPEI index and it will be improved with increasing time scale. The results of the hybrid model showed that the error of GEP model decreases in all time scales, and this performance improvement is more tangible in the short-time scales, so that the correlation coefficient in three-month time scale in the GEP model has increased from 0.622 to 0.891 in the hybrid model.

Key words: Drought, Nonlinear Time Series, Intelligent Model, SPEI

پیش‌بینی خشکسالی با استفاده از مدل ترکیبی GEP-GARCH (مطالعه موردی: ایستگاه سینوپتیک سلماس)

عباس عباسی^۱، کیوان خلیلی^{۲*}، جواد بهمنش^۳، اکبر شیرزاد^۴

دکتری مهندسی منابع آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران

استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران

استاد گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران

استادیار گروه مهندسی عمران، دانشکده مهندسی عمران، دانشگاه صنعتی ارومیه، ارومیه، ایران

تاریخ دریافت: ۱۳۹۷/۹/۲۶ - تاریخ بازنگری: ۱۳۹۷/۱۰/۱۹ - تاریخ تصویب: ۱۳۹۷/۱۱/۱

چکیده

پیش‌بینی خشکسالی نقش مهمی در طراحی سیستم‌های سازگاری با خشکسالی و اجرای عملیات تسکین ایفا می‌نماید. داده‌های هیدرولوژیک به‌صورت ترکیبی از بخش قطعی و تصادفی می‌باشند. با توجه به اینکه داده‌های تولیدی مدل‌های هوشمند به‌صورت قطعی می‌باشند، استفاده از رویکردی جدید برای اعمال بخش تصادفی در پیش‌بینی این داده‌ها می‌تواند قطعیت مدل را افزایش دهد. در این تحقیق با ترکیب مدل برنامه‌ریزی بیان ژن (GEP) و مدل سری زمانی مبتنی بر واریانس ناهمسان شرطی (GARCH) سعی در ارائه مدلی ترکیبی برای پیش‌بینی خشکسالی شده است. بدین منظور پیش‌بینی خشکسالی در ایستگاه سلماس با استفاده از شاخص خشکسالی SPEI در گام‌های زمانی مختلف در طی دوره آماری ۳۵ ساله و با پنج مدل ورودی مختلف شامل مقادیر شاخص SPEI از یک تا پنج گام زمانی تأخیر، مورد بررسی قرار گرفت. نتایج نشان داد که روش GEP در مقیاس زمانی کوتاه‌مدت شاخص SPEI از دقت مناسب برخوردار نمی‌باشد و با افزایش مقیاس زمانی عملکرد مدل بهبود پیدا می‌کند. نتایج مدل ترکیبی نشان داد که خطای مدل GEP در همه مقیاس‌های زمانی کاهش پیدا می‌کند و این بهبود عملکرد در مقیاس‌های زمانی کوتاه‌مدت ملموس‌تر می‌باشد به‌نحوی که ضریب همبستگی در مقیاس زمانی سه‌ماهه در مدل ساده GEP از ۰/۶۲۲ به ۰/۸۹۱ در مدل ترکیبی افزایش پیدا کرده است.

واژه‌های کلیدی: خشکسالی، سری زمانی غیرخطی، مدل هوشمند، SPEI

مقدمه

پایش و پیش‌بینی خشکسالی برای مدیران و تصمیم‌گیران بخش آب و سایر بخش‌های اقتصادی این امکان را فراهم می‌کند که جهت کاهش خسارات آن برنامه‌ریزی بهتری انجام دهند. به منظور تحلیل کمی خشکسالی، وجود یک شاخص مناسب برای تعیین دقیق دوره‌های تر و خشک بسیار ضروری است (DaSilva, 2004). با توجه به نقش مهم تبخیر و تعرق در مقدار بارش رسیده به سطح زمین، لحاظ کردن دیگر متغیرها از جمله دما و تبخیر و تعرق برای تعیین خشکسالی ضرورت دارد. بر همین اساس می‌توان شاخص خشکسالی استاندارد شده بارش و تبخیر-تعرق (SPEI) که سه متغیر بارش، دما و تبخیر و تعرق پتانسیل را در تعیین خشکسالی لحاظ می‌کند به‌عنوان شاخصی مناسب در تعیین خشکسالی مورد استفاده قرار داد (Vicente-Serrano et al., 2010). تا کنون از روش‌های مختلف سری زمانی و هوشمند

برای پیش‌بینی وقایع هیدرولوژیک استفاده شده است. یکی از این روش‌ها برنامه‌ریزی بیان ژن (GEP^۱) می‌باشد که شاخه‌ای از الگوریتم‌های تکاملی است که توانایی مدل‌سازی فرآیندهای غیرخطی و پویا را دارد. تا کنون در مسائل هیدرولوژیک از برنامه‌ریزی بیان ژن در مدل‌سازی بارش-رواناب (Dorado et al., 2003)، برآورد جریان رودخانه‌ها (Güven, Khu et al., 2001)، پیش‌بینی تراز مخازن و دریاچه‌ها (Kisi et al., 2012) استفاده شده است که نتایج آن حاکی از دقت مناسب این روش در پیش‌بینی متغیرهای هیدرولوژیک می‌باشد. Zareh Amini et al. (2014) برای تخمین دمای خاک از روش GEP استفاده نمودند و به این نتیجه رسیدند که این روش به دلیل ارائه راه-حل‌های صریح بر روش ANN برتری دارد. Mehdizadeh et al. (2016) ارزیابی دقت دو روش GEP و شبکه بیزین (BN^۲) را در پیش‌بینی دمای روزانه هوا مورد بررسی قرار دادند و به این نتیجه رسیدند که هر دو روش از دقت قابل قبولی در پیش‌بینی دمای

* نویسنده مسئول: k.khalili@urmia.ac.ir

1. Standardized Precipitation Evapotranspiration Index
2. Gene Expression Programming
3. Bayesian network

ترکیب دو روش موصوف نتایج قابل قبولی در تعیین الگوی سری روزانه رودخانه مورد مطالعه ارائه داده است. عملکرد الگوهای سری‌های زمانی یک متغیره در پیش‌بینی میزان آب مصرفی در دو گام زمانی روزانه و هفتگی برای دوره آماری ۵ ساله (۲۰۰۶-۲۰۰۱) توسط Caiado (2007) مورد بررسی قرار گرفت که در این تحقیق الگوهای ARIMA و GARCH بر سری داده‌های مشاهداتی برازش و کارایی هر دو روش ارزیابی و مورد تأیید واقع گردید. (Naveh *et al.* (2012) نیز الگوی دوخطی را برای پیش‌بینی جریان ماهانه رودخانه‌های شهرچای و باراندوزچای ارومیه مورد استفاده قرار دادند که نتایج این تحقیق نیز حاکی از دقت بالای این الگو در مقایسه با الگوهای خطی می‌باشد. (Laux *et al.* (2011) با استفاده از مدل غیرخطی سری زمانی ARMA-GARCH با ارزیابی بر روی داده‌های ایستگاه‌های منتخب در منطقه آلپ آلمان، شبیه‌سازی بارش به‌عنوان پارامتر تصادفی را انجام دادند. در خصوص مدل‌های تلفیقی سری زمانی غیرخطی و خطی می‌توان به تحقیق (Nazeri Tahrodi and Khalili (2015) اشاره کرد که در این تحقیق برای پیش‌بینی دبی رودخانه سیمینه‌رود سه مدل ARCH، ARMA و PARCH بر روی داده‌های جریان رودخانه برازش داده‌شده و تلفیق دو مدل ARMA-PARCH و ARCH-ARMA نیز مورد بررسی قرار گرفت که نتایج این تحقیق نشان داد مدل تلفیقی باعث کاهش خطای پیش‌بینی و افزایش دقت برآوردها می‌گردد. (Khalili *et al.* (2013) نیز جریان روزانه رودخانه شهرچای را با الگوی غیرخطی تلفیقی BL-ARCH پیش‌بینی نمودند که نتایج این تحقیق نشان داد که الگوی تلفیقی عملکرد بسیار بهتری نسبت به الگوی دوخطی داشته و مقدار خطا را به میزان قابل توجهی کاهش می‌دهد. (Abbaszadeh Afshar *et al.* (2016) با تلفیق دو روش سری زمانی AR و ARCH نسبت به پیش‌بینی تراز سطح آب دریاچه ارومیه اقدام نمودند و به این نتیجه رسیدند که مدل تلفیقی نسبت به حالت استفاده مجزای روش‌های سری زمانی، باعث افزایش دقت پیش‌بینی می‌گردد. (Yang *et al.* (2014) نیز پیش‌بینی قیمت روزانه برق را با دو روش ماشین بردار پشتیبان و GARCH انجام و مدلی ترکیبی بر اساس الگوریتم کلونی مورچه را به منظور ترکیب دو روش SVM و GARCH توسعه دادند که نتایج این تحقیق نشان داد مدل ترکیبی نسبت به حالت مجزا از دقت بالاتری برخوردار است. (Maca and Pech (2016) با استفاده از دو روش شبکه عصبی مصنوعی نسبت به پیش‌بینی شاخص‌های خشکسالی SPI و SPEI اقدام نمودند که نتایج این تحقیق نشان

هوا برخوردار هستند ولی روش شبکه بیزین دقت بیش‌تری نسبت به روش GEP دارد. (Danandeh Mehr *et al.* (2014) با استفاده از مدل تلفیقی برنامه‌ریزی خطی ژنتیک - موجک نسبت به پیش‌بینی بلندمدت خشکسالی در ایالت تگزاس آمریکا اقدام نمودند که نتایج این تحقیق نشان داد که مدل برنامه‌ریزی ژنتیک خطی قادر به یادگیری غیرخطی بودن خشکسالی در زمان‌های طولانی - مدت بیش از ۳ ماه نیست ولی مدل تلفیقی برای پیش‌بینی خشکسالی در مقیاس‌های زمانی ۳، ۶ و ۱۲ ماهه از قابلیت بالایی برخوردار است. (Behmanesh and Mehdizadeh (2017) نیز برای برآورد دمای خاک در عمق‌های مختلف از روش‌های GEP و ANN^۱ و MLR^۲ (رگرسیون خطی چند متغیره) استفاده کردند که نتایج نشان داد هر سه مدل قادر به مدل‌سازی مناسب دمای خاک می‌باشند. (Baba Ali and Dehghani (2017) عملکرد مدل‌های هوشمند شامل GEP، ANN و ANFIS را در تخمین بارش ماهانه حوضه کاکارضا مورد مقایسه قرار دادند. نتایج این تحقیق نشان داد مدل GEP بیشترین دقت را در تخمین مقادیر بارش و به‌خصوص مدل‌سازی مقادیر حداقل و متوسط بارش داشت.

اکثر مطالعات سری‌های زمانی در هیدرولوژی و منابع آب مربوط به مدل‌های خطی می‌باشد. مدل‌های غیرخطی بیشتر در علوم اقتصاد، آمار و ریاضیات مورد استفاده قرار گرفته‌اند و به‌صورت کمتر در منابع آب مورد استفاده واقع شده‌اند. مدل‌های ARCH^۳ اولین بار توسط Engle در سال ۱۹۸۲ معرفی شدند و در سال ۱۹۸۶ به وسیله Bollerslev تحت عنوان GARCH^۴ تعمیم داده شدند (Bollerslev, 1986). یکی از دلایل استفاده از مدل‌های ARCH، وجود خطاهای پیش‌بینی کوچک و بزرگ در خوشه‌های مختلف یک سری می‌باشد و در بسیاری از مطالعات اقتصادی و مالی به‌عنوان ابزار کارآمد پیش‌بینی از آن یاد می‌شود. پس از مطالعات Engle (1982) در سال‌های بعد مطالعات زیادی در مورد مدل‌های ARCH انجام گردید. (Bollerslev *et al.* (1992) مدل‌های واریانس شرطی را برای داده‌های مالی به کار بردند و (Bera and Higgins (1993) نیز این مدل را به‌عنوان یک ابزار مؤثر در مدل‌های خودهمبسته مورد بررسی قرار دادند که نتایج این تحقیق دقت مدل موصوف در مدل‌سازی داده‌های مالی را تأیید کردند. در مطالعات هیدرولوژیکی با استفاده از روش GARCH می‌توان به تحقیق (Wang *et al.* (2005) برای برآورد جریان روزانه رودخانه زرد در چین اشاره کرد که از ترکیب روش ARMA و GARCH استفاده کردند و نتایج این تحقیق نشان داد

برازش‌های صورت گرفته با استفاده از توابع برازش مورد ارزیابی قرار می‌گیرند. اگر یک کیفیت مطلوبی از راه‌حل مسئله یافت شود و یا اینکه نسل‌ها به تعداد معینی برسند، فرآیند تکامل (تکرار) متوقف می‌شود و بهترین راه‌حل یافت شده گزارش می‌شود. با این حال، اگر شرایط توقف برنامه GEP حاصل نگردد بهترین راه‌حل یافت‌شده، نگه داشته می‌شود که به فرآیند نخبه‌گزینی معروف است. در حقیقت، افراد شایسته شانس بیشتری برای تولید فرزندان دارند. پس از آن تغییرات ژنتیکی با استفاده از عملگرهای ژنتیکی مختلف اعمال می‌شود. این روند برای نسل‌های موجود تکرار می‌شود تا کیفیت رضایت‌بخشی از راه‌حل مسئله یافت شود. در روش GEP، پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و مجموعه‌ای از ترمینال‌ها برآورد و مدل‌سازی می‌شوند. مجموعه توابع شامل توابع اصلی حسابی و یا توابع تعریف‌شده توسط کاربر هستند که وی معتقد است این توابع می‌توانند برای تفسیر مدل مناسب باشند. مجموعه ترمینال‌ها نیز از متغیرهای مستقل مسئله و مقادیر ثابت تشکیل شده‌اند. در تحقیق حاضر، از برنامه Gene Xpro Tools 4.0 برای توسعه و اجرای مدل‌های مبتنی بر برنامه‌ریزی بیان ژن استفاده شده است. فرآیند گام به گام برای مدل‌سازی شاخص SPEI در تحقیق حاضر با استفاده از مدل GEP به صورت زیر است؛

نخستین گام، انتخاب تابع برازش است که می‌تواند بر اساس روابط متعددی صورت گیرد که در این تحقیق از تابع برازش ریشه میانگین مربعات خطا (RMSE) استفاده شده است. در گام دوم، مجموعه متغیرهای ورودی و مجموعه توابع به منظور تولید کروموزوم‌ها انتخاب و معرفی می‌شوند. در این تحقیق، مجموعه متغیرهای ورودی شامل متغیرهای مستقلی هستند که به عنوان ورودی برای مدل‌سازی متغیرهای وابسته مد نظر قرار گرفتند. از چهار عملگر اصلی شامل $\{+, -, \times, \div\}$ و F_1 و نیز توابع ریاضی

$F_2 = \{\sqrt{x}, \sqrt[3]{x}, x^2, x^3, \ln(x), e^x, \sin(x), \cos(x), \text{Arctan}(x)\}$ استفاده شد. در گام سوم ساختار و معماری کروموزوم‌ها انتخاب شدند، به طوری که اندازه طول هر رأس و تعداد ژن‌ها به ترتیب برابر ۸ و ۳ مورد استفاده قرار گرفت. گام چهارم انتخاب تابع پیوندی است که تابع جمع برای ایجاد پیوند بین زیرشاخه‌ها استفاده شد. در گام پنجم نیز عملگرهای ژنتیک و نرخ هر یک از آن‌ها انتخاب گردید.

مدل‌های ARCH و GARCH

شدت تغییرپذیری در سری‌های زمانی که به طور معمول با معیارهای واریانس یا انحراف معیار اندازه‌گیری می‌شود در بسیاری از سری‌ها از جمله نرخ ارز، بازدهی سهام، قیمت نفت، تورم و ...

ولی در نسخه دوم آن (در صورت عدم محدودیت داده) توصیه شده است که از روش پنمن - مانیتث فائو (Allen et al., 1998) استفاده شود. برای محاسبه شاخص SPEI از رابطه (۲) استفاده می‌شود.

$$\text{SPEI} = W - \frac{C_0 + C_1 W + C_2 W^2}{1 + d_1 W + d_2 W^2 + d_3 W^3} \quad (\text{رابطه } 2)$$

که در این رابطه $C_0, C_1, C_2, d_1, d_2, d_3$ مقادیر ثابت معادله SPEI می‌باشند و W از رابطه (۳) به دست می‌آید.

$$W = \begin{cases} \sqrt{-2 \ln(P)} & \text{for } P \leq 0.5 \\ \sqrt{-2 \ln(P-1)} & \text{for } P > 0.5 \end{cases} \quad (\text{رابطه } 3)$$

در این رابطه P احتمال بیشتر شدن مقادیر تعیین شده D است. این شاخص می‌تواند برای پایش دوره‌های خشک و تر مورد استفاده قرار گیرد. خشکسالی زمانی شروع می‌گردد که مقادیر شاخص به منفی یک برسد و با مثبت شدن آن خاتمه می‌یابد. برای اطلاعات بیش‌تر در خصوص نحوه محاسبه این شاخص می‌توان به مرجع (Vicente-Serrano et al., 2010) رجوع کرد.

برنامه‌ریزی بیان ژن

برنامه‌ریزی بیان ژن، تعمیم‌یافته روش الگوریتم ژنتیک می‌باشد که نخستین بار توسط (Ferreira 2002) ارائه شد و بر مبنای نظریه تکامل داروین بنا نهاده شده است. برنامه‌ریزی بیان ژن همانند الگوریتم ژنتیک و برنامه‌ریزی ژنتیک است که از جمعیتی از افراد استفاده کرده و آن‌ها را بر اساس برازندگی انتخاب می‌کند و تغییرات ژنتیکی را با استفاده از یک یا چند عملگر ژنتیکی اعمال می‌نماید. تفاوت اساسی بین سه الگوریتم یادشده، مربوط به ماهیت افراد آن‌هاست. در الگوریتم ژنتیک افراد به صورت رشته‌های خطی با طول ثابت (کروموزوم‌ها) هستند. در حالی که در برنامه‌ریزی ژنتیک، افراد به صورت نهاده‌های غیرخطی با اندازه‌ها و اشکال متفاوت (درختان تجزیه) می‌باشند. این در حالی است که در GEP، افراد در ابتدا به صورت رشته‌های خطی با طول ثابت کدگذاری می‌شوند (مشابه با الگوریتم ژنتیک) و سپس به شکل نهاده‌های غیرخطی با اندازه‌ها و اشکال متفاوت (مشابه با برنامه‌ریزی ژنتیک) بیان می‌شوند. از سوی دیگر، برنامه‌ریزی بیان ژن یک تکنیک برنامه‌ریزی خودکار می‌باشد که راه‌حل مسئله را با استفاده از برنامه‌های کامپیوتری ارائه می‌نماید. در این روش، در ابتدای فرآیند هیچ‌گونه رابطه‌ای در نظر گرفته نشده و این روش قادر به بهینه‌سازی ساختار مدل و مؤلفه‌های آن می‌باشد.

تولید جمعیت اولیه از راه‌حل‌ها، اولین مرحله در روش GEP است. این امر می‌تواند با استفاده از اطلاعات موجود یا پیشین درباره مسئله مورد بررسی و یا به صورت تصادفی انجام گیرد. کروموزوم‌ها به صورت بیان درختی نشان داده می‌شوند. سپس

مدل تلفیقی GEP-GARCH

گام‌های برازش مدل GARCH بر روی داده‌های شاخص SPEI و ترکیب آن با روش GEP به شرح زیر می‌باشد.

۱- بهترین مدل AR (رابطه ۶) یا ARMA (رابطه ۷) بر سری داده‌های ایستا و نرمال شاخص SPEI (Z_t) برازش داده شدند.

$$Z_t(p) = \sum_{i=1}^p (\phi_i Z_{t-i}) + \varepsilon_t \quad (\text{رابطه ۶})$$

$$Z_t(p, q) = \sum_{i=1}^p (\phi_i Z_{t-i}) - \sum_{j=1}^q (\theta_j \varepsilon_{t-j}) + \varepsilon_t \quad (\text{رابطه ۷})$$

که در این رابطه P مرتبه مدل AR، q مرتبه مدل MA، ϕ_i و θ_j نیز ضرایب مدل‌ها می‌باشند.

۲- مقدار خطا (نویز) یا باقی‌مانده‌ها (ε_t) با استفاده از معادلات (۴) و (۵) محاسبه می‌شوند.

۳- ε_t^2 با استفاده از مقادیر بدست آمده از گام ۲ محاسبه می‌شوند.

۴- مدل GARCH بر مقادیر بدست آمده ε_t^2 برازش می‌یابد و رابطه (۸) برای حصول جزء تصادفی داده‌های شاخص SPEI (ε_t) مورد استفاده قرار می‌گیرند.

$$\varepsilon_t = \sigma_t z_t, \quad \sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (\text{رابطه ۸})$$

۵- گام نهایی تلفیق مدل GARCH با مدل هوشمند GEP می‌باشد. نتایج مدل هوشمند GEP با نتایج مدل GARCH به صورت رابطه (۹) ادغام و ترکیب شدند.

$$P_t = D_t + R_t \quad (\text{رابطه ۹})$$

که در این رابطه D_t جزء قطعی سری‌های زمانی شاخص SPEI بدست‌آمده توسط مدل GEP، R_t جزء تصادفی سری‌های زمانی شاخص SPEI بدست‌آمده از مدل GARCH و P_t مقدار نهایی سری‌های زمانی شاخص SPEI می‌باشد. شایان ذکر است که D_t و R_t مقادیر نرمال و استاندارد شده سری‌های زمانی شاخص SPEI می‌باشند. برای پیش‌بینی شاخص SPEI در مقیاس‌های زمانی مختلف با استفاده از روش GEP، ابتدا داده‌های شاخص مطابق روابط (۱۰) و (۱۱) نرمال گردید.

$$Y_i = \frac{X_{oi}}{Xo \max}, X_{oi} \geq 0 \quad (\text{رابطه ۱۰})$$

$$Y_i = \frac{X_{oi}}{|Xo \min|}, X_{oi} < 0 \quad (\text{رابطه ۱۱})$$

که در این روابط Y_i مقادیر استاندارد شده شاخص، X_{oi} مقادیر شاخص مشاهداتی، $Xo \max$ حداکثر مقدار شاخص مشاهداتی و $Xo \min$ حداقل مقدار شاخص مشاهداتی می‌باشد.

ثابت نبوده و در طول زمان تغییر می‌کند. در این نوع تغییرپذیری که از آن تحت عنوان تغییرپذیری خوشه‌ای^۱ یاد می‌شود، نوسانات و تغییرات بزرگ، منجر به تغییرات بزرگ و نوسانات و تغییرات کوچک، منجر به تغییرات کوچک در سری زمانی می‌گردد. یکی از مشکلات مهم در مدل‌های سری زمانی، تعیین بخش تصادفی مدل است. زیرا با هر بار قرار دادن یک سری داده تصادفی جدید، سری جدیدی تولید می‌شود. در حالی که ممکن است داده‌های جدید تصادفی تأثیری در روند کلی مقادیر پیش‌بینی شده نداشته باشند. از سوی دیگر، در بیشتر مطالعات مربوط به مدل‌سازی و فرآیندهای هیدرولوژیکی، توجه اصلی بر روی میانگین داده‌ها متمرکز است. در حالی که کمتر به پدیده متغیر بودن واریانس نسبت به زمان توجه شده است. با توجه به پیشرفت مطالعات انجام‌گرفته در زمینه ریسک و عدم قطعیت در مهندسی آب، توسعه و کاربرد روش‌های مدل‌سازی تغییرات واریانس نسبت به زمان نیز ضروری به نظر می‌رسد. مدل ARCH یک مدل غیرخطی سری زمانی است که برای مدل‌سازی تغییرات واریانس نسبت به زمان توسط Engle (1982) به صورت رابطه (۴) ارائه شده است.

$$\varepsilon_t = \sigma_t z_t, \quad \sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 \quad (\text{رابطه ۴})$$

که در این رابطه σ_t^2 واریانس شرطی، ε_t عبارت خطا یا باقی‌مانده مدل، $\alpha_0, \alpha_i \geq 0$ پارامترهای مدل ARCH، m مرتبه مدل و $z_t \sim N(0, 1)$ سری تصادفی نرمال و استاندارد می‌باشند. مدل GARCH نیز در ابتدا توسط Bollerslev (1986) ارائه شد. در حقیقت، مدل GARCH تعمیم‌یافته مدل ARCH است. واریانس شرطی در مدل GARCH به صورت رابطه (۵) بیان می‌شود.

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2; \quad p \geq 0, q > 0, \alpha_0 > 0, \alpha_i \geq 0, \beta_j \geq 0 \quad (\text{رابطه ۵})$$

که در این رابطه q و p به ترتیب مرتبه مدل‌های ARCH و GARCH هستند. اگر p برابر صفر باشد مدل GARCH(p,q) به مدل ARCH(q) تبدیل خواهد شد. اگر p و q هر دو صفر باشند، فرآیند ε_t یک فرآیند نویز سفید^۲ خواهد بود. غیر منفی بودن پارامترهای α_0 و β_j, α_i شرط کافی برای اطمینان از مثبت بودن واریانس شرطی σ_t^2 است. در این تحقیق، مدل سری زمانی GARCH برای تعیین بخش تصادفی (غیرخطی) داده‌های شاخص خشکسالی SPEI در ایستگاه سلماس مورد استفاده قرار گرفت. برای برازش مدل GARCH در این تحقیق از نرم‌افزارهای اقتصادسنجی Eviews و Stata استفاده گردید.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_i - \hat{Q}_i| \quad (\text{رابطه ۱۸})$$

$$RMSE = \left(\frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{n} \right)^{0.5} \quad (\text{رابطه ۱۹})$$

که در این روابط Q_i مقدار داده مشاهداتی در گام زمانی نام، \hat{Q}_i مقدار داده پیش‌بینی شده در همان زمان، n تعداد داده‌ها، \bar{Q}_i میانگین مقادیر مشاهداتی و \bar{Q}_i میانگین مقادیر پیش‌بینی شده می‌باشد. هر چه مقادیر R به یک نزدیکتر باشد و MAE و $RMSE$ به صفر نزدیک‌تر باشد، نتایج دقیق‌تر و قابل اعتمادتر می‌باشند.

یافته‌ها و بحث

در این تحقیق از پنج سناریو برای بررسی مدل GEP شامل یک تا پنج تأخیر برای تخمین شاخص SPEI در گام زمانی آتی استفاده شد. نخست دقت مدل ساده GEP در تخمین شاخص SPEI ایستگاه‌های مورد مطالعه مورد بررسی قرار گرفت. سپس عملکرد مدل ترکیبی GEP-GARCH ارزیابی و با مدل ساده GEP مورد مقایسه قرار گرفت.

نتایج روش برنامه‌ریزی بیان ژن

گام اول در اجرای مدل برنامه‌ریزی بیان ژن، پیدا کردن بهترین مدل ورودی به مدل می‌باشد که بر اساس آن بهترین خروجی حاصل گردد. از بین الگوهای مختلف ورودی، الگویی که کمترین خطا را ایجاد می‌کند به‌عنوان مناسب‌ترین الگوی ورودی در نظر گرفته می‌شود. برای آموزش مدل با استفاده از روش انتخاب تصادفی از ۸۰ درصد داده‌ها استفاده شد و از ۲۰ درصد باقی‌مانده برای صحت‌سنجی مدل استفاده گردید. در ادامه با در دست داشتن سری زمانی شاخص SPEI اقدام به پیش‌بینی خشکسالی با استفاده از روش برنامه‌ریزی بیان ژن شد. به دلیل اینکه روند تکاملی در این مدل دارای یک فرآیند از پیش تعیین‌شده و مشخص نمی‌باشد، با یک بار اجرای برنامه نمی‌توان به جواب مطلوب و بهینه دست یافت. به همین دلیل برای تنظیم بهینه و دقیق پارامترهای مدل باید از روش سعی و خطا با تکرارهای مختلف استفاده کرد. در این تحقیق از حداقل سی بار اجرای برنامه برای یافتن مقادیر پارامترها و تنظیمات مختلف استفاده گردید که نتایج بهترین ساختارها و تنظیمات آن در استخراج مدل پیش‌بینی خشکسالی در جدول (۱) نشان داده شده است.

سپس ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده آن برای صحت‌سنجی انتخاب گردید. به‌منظور پیش‌بینی کمی خشکسالی در این تحقیق از پنج مدل مختلف ورودی مطابق روابط (۱۲) الی (۱۶) استفاده شد. در مدل ۱، برای پیش‌بینی شاخص SPEI در ماه بعد از سری زمانی SPEI در ماه جاری استفاده گردید. در مدل ۲ پیش‌بینی شاخص در ماه بعد بر اساس مقادیر شاخص تا یک ماه قبل صورت پذیرفت و به‌طور مشابه در مدل ۳، ۴ و ۵ پیش‌بینی بر اساس مقادیر شاخص تا دو، سه و چهار ماه قبل انجام شد.

$$\text{Model 1: } SPEI_{(t+1)} = f(SPEI_{(t)}) \quad (\text{رابطه ۱۲})$$

$$\text{Model 2: } SPEI_{(t+1)} = f(SPEI_{(t)}, SPEI_{(t-1)}) \quad (\text{رابطه ۱۳})$$

$$\text{Model 3: } SPEI_{(t+1)} = f(SPEI_{(t)}, SPEI_{(t-1)}, SPEI_{(t-2)}) \quad (\text{رابطه ۱۴})$$

$$\text{Model 4: } SPEI_{(t+1)} = f(SPEI_{(t)}, SPEI_{(t-1)}, SPEI_{(t-2)}, SPEI_{(t-3)}) \quad (\text{رابطه ۱۵})$$

$$\text{Model 5: } SPEI_{(t+1)} = f(SPEI_{(t)}, SPEI_{(t-1)}, SPEI_{(t-2)}, SPEI_{(t-3)}, SPEI_{(t-4)}) \quad (\text{رابطه ۱۶})$$

سپس بر اساس معیارهای ارزیابی بهینه‌ترین مدل در پیش‌بینی شاخص خشکسالی در مقیاس‌های زمانی مختلف انتخاب گردید. در مدل ۱، برای پیش‌بینی شاخص SPEI در ماه بعد از سری زمانی SPEI در ماه جاری استفاده گردید. در مدل ۲ پیش‌بینی شاخص در ماه بعد بر اساس مقادیر شاخص تا یک ماه قبل صورت پذیرفت و به‌طور مشابه در مدل ۳، ۴ و ۵ پیش‌بینی بر اساس مقادیر شاخص تا دو، سه و چهار ماه قبل انجام شد.

معیارهای ارزیابی

در این تحقیق به‌منظور ارزیابی مدل‌های موردنظر از معیارهای ضریب همبستگی، میانگین قدر مطلق خطا و جذر میانگین مربعات خطا استفاده می‌شود. شاخص $RMSE$ اختلافات مابین مقادیر مشاهداتی و مدل‌سازی شده متغیر مستقل را نشان می‌دهد. شاخص MAE نشانگر متوسط قدر مطلق اختلافات مابین مقادیر مشاهداتی و مدل‌سازی شده متغیر مستقل است. ضریب همبستگی R درجه همبستگی مابین مقادیر مشاهداتی و مدل‌سازی شده متغیر مستقل را اندازه‌گیری می‌کند. روابط این معیارها به‌صورت روابط (۱۷) الی (۱۹) می‌باشد (Hosseini-Moghari and Araghinejad, 2015).

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (Q_i - \bar{Q}_i)(\hat{Q}_i - \bar{\hat{Q}}_i)}{\sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i - \bar{Q}_i)^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Q}_i - \bar{\hat{Q}}_i)^2}} \quad (\text{رابطه ۱۷})$$

جدول ۱. مشخصات مدل برنامه‌ریزی بیان ژن مورد استفاده در این تحقیق

عملگرهای ژنتیکی		تنظیمات کلی	
۰/۰۴۴	نرخ جهش	۳۰	تعداد کروموزوم‌ها
۰/۱	نرخ وارون‌سازی	۸	اندازه رأس
۰/۱	نرخ ترانهش درج متوالی	۳	تعداد ژن‌ها در هر کروموزوم
۰/۱	نرخ ترانهش ریشه درج متوالی	۱۰۰۰	تعداد جمعیت تولیدی
۰/۳	نرخ ترکیب تک نقطه‌ای	جمع (+)	تابع پیوند
۰/۳	نرخ ترکیب دو نقطه‌ای		
۰/۱	نرخ ترکیب ژن	RMSE	تابع برازش معیار خطا
۰/۱	نرخ ترانهش ژن		

جدول ۲. نتایج مدل GEP در مقیاس‌های زمانی مختلف شاخص SPEI

عملگر	معیارهای ارزیابی	مدل	SPEI1	SPEI3	SPEI6	SPEI12	SPEI24	SPEI48
F ₁	RMSE	۱	۰/۳۷۸	۰/۲۳۶	۰/۱۷	۰/۱۲	۰/۰۶۸	۰/۰۴۸
		۲	۰/۳۶۷	۰/۲۳۹	۰/۱۷۱	۰/۱۲۳	۰/۰۷۹	۰/۰۴۴
		۳	۰/۳۶	۰/۲۳۳	۰/۱۷	۰/۱۲۱	۰/۰۶۸	۰/۰۴۲
		۴	۰/۳۶۵	۰/۲۳۴	۰/۱۷۱	۰/۱۲۴	۰/۰۶۸	۰/۰۴۲
		۵	۰/۳۶۹	۰/۲۳۸	۰/۱۷۲	۰/۱۲	۰/۰۶۷	۰/۰۴۴
	MAE	۱	۰/۳۰۹	۰/۱۸۷	۰/۱۳۳	۰/۰۹	۰/۰۵۱	۰/۰۳۹
		۲	۰/۳۰۲	۰/۱۹۵	۰/۱۳۳	۰/۰۹۴	۰/۰۵۹	۰/۰۳۵
		۳	۰/۳۰۴	۰/۱۸۵	۰/۱۳۲	۰/۰۸۹	۰/۰۵۱	۰/۰۳۳
		۴	۰/۲۹۷	۰/۱۸۷	۰/۱۳۱	۰/۰۹۲	۰/۰۵	۰/۰۳۳
		۵	۰/۳۰۱	۰/۱۸۹	۰/۱۳۷	۰/۰۹۱	۰/۰۵	۰/۰۳۵
	R	۱	۰/۰۱۲	۰/۶۵۱	۰/۸۴۵	۰/۹۳۷	۰/۹۷۸	۰/۹۸۴
		۲	۰/۰۱۵	۰/۶۷۹	۰/۸۴۴	۰/۹۳۴	۰/۹۸۶	۰/۹۸۶
		۳	۰/۰۳	۰/۶۷۶	۰/۸۴۵	۰/۹۳۷	۰/۹۷۸	۰/۹۸۶
		۴	۰/۰۲۷	۰/۶۶۷	۰/۸۴۷	۰/۹۳۳	۰/۹۷۸	۰/۹۸۶
		۵	۰/۰۲۵	۰/۶۷۶	۰/۸۴۴	۰/۹۳۷	۰/۹۷۸	۰/۹۸۶
F ₂	RMSE	۱	۰/۳۵۶	۰/۲۳۶	۰/۱۷	۰/۱۲	۰/۰۶۸	۰/۰۴۴
		۲	۰/۳۶۳	۰/۲۴۱	۰/۱۷۵	۰/۱۲۵	۰/۰۶۸	۰/۰۴۳
		۳	۰/۳۶۲	۰/۲۳۵	۰/۱۷۴	۰/۱۲۹	۰/۰۶۸	۰/۰۴۳
		۴	۰/۳۶۷	۰/۲۳۴	۰/۱۷۱	۰/۱۲۲	۰/۰۶۷	۰/۰۴۲
		۵	۰/۳۵۷	۰/۲۳۵	۰/۱۷۲	۰/۱۲	۰/۰۶۸	۰/۰۴۲
	MAE	۱	۰/۲۸۵	۰/۱۸۹	۰/۱۳۳	۰/۰۸۹	۰/۰۵	۰/۰۳۵
		۲	۰/۲۹۶	۰/۱۹۳	۰/۱۴	۰/۰۹۵	۰/۰۵۱	۰/۰۳۳
		۳	۰/۲۹۸	۰/۱۸۵	۰/۱۳۷	۰/۰۹۷	۰/۰۵۱	۰/۰۳۴
		۴	۰/۳۰۱	۰/۱۸۵	۰/۱۳۳	۰/۰۹۳	۰/۰۵	۰/۰۳۲
		۵	۰/۲۹	۰/۱۸۵	۰/۱۳۶	۰/۰۹۱	۰/۰۵	۰/۰۳۳
	R	۱	۰/۰۲۱	۰/۶۵۵	۰/۸۴۵	۰/۹۳۷	۰/۹۷۸	۰/۹۸۶
		۲	۰/۰۰۷	۰/۶۶۴	۰/۸۴	۰/۹۳۴	۰/۹۷۷	۰/۹۸۶
		۳	۰/۰۱۱	۰/۶۶۷	۰/۸۴	۰/۹۲۸	۰/۹۷۸	۰/۹۸۶
		۴	۰/۰۱	۰/۶۷۲	۰/۸۴۵	۰/۹۳۶	۰/۹۷۹	۰/۹۸۷
		۵	۰/۰۰۲	۰/۶۷	۰/۸۴۲	۰/۹۳۷	۰/۹۷۸	۰/۹۸۶

ارزیابی RMSE، MAE و برای هر دو ترکیب عملگر ریاضی و در تمامی مقیاس‌های زمانی در جدول (۲) ارائه شده است. بر اساس این جدول مشخص می‌گردد که استفاده از ترکیب هر دو

در این تحقیق علاوه بر عملگرهای ریاضی پیش‌فرض برنامه (F₁) از ترکیب چهار عملگر اصلی (F₂) نیز استفاده شده است. نتایج روش GEP در پیش‌بینی خشکسالی بر اساس معیارهای

موضوع را می‌توان در پراکندگی و تغییرات شدید شاخص SPEI در مقیاس یک‌ماهه جستجو کرد. بهبود عملکرد روش GEP با افزایش مقیاس زمانی محاسبه SPEI رابطه مستقیمی دارد. بدین معنی که با افزایش مقیاس محاسبه SPEI، مقادیر معیارهای ارزیابی مورد استفاده بهبود می‌یابد. در این خصوص نتایج مشابهی توسط Hosseini-Moghari و Mishra and Desai (2005,2006) and Araghinejad (2015) برای پیش‌بینی شاخص SPI گزارش شده است.

یکی از قابلیت‌های مهم روش GEP، ارائه روابط ریاضی برای متغیرهای هیدرولوژیکی می‌باشد. روابط نهایی برای مجموعه عملگر F_2 و برای ترکیب منتخب شاخص SPEI در مقیاس‌های زمانی مختلف برای ایستگاه سلماس در جدول (۳) نشان داده شده است.

نوع تابع F_1 و F_2 در مقیاس‌های زمانی بالا از دقت مناسب برخوردار است و نتایج آن‌ها به هم نزدیک است و به دلیل اینکه روابط حسابی (F_2) دارای ساختار ساده ریاضی و سهولت در محاسبه می‌باشند و از دقت نسبتاً یکسانی با ترکیب F_1 برخوردار هستند، لذا ترکیب F_2 به عنوان عملگر مناسب در پیش‌بینی شاخص SPEI در این تحقیق انتخاب گردید. بر اساس آماره‌های ارزیابی ارائه شده در جدول (۲) در مرحله صحت‌سنجی، بهترین الگوی ورودی برای پیش‌بینی شاخص SPEI در گام زمانی ۱، ۳، ۴، ۱۲، ۲۴ و ۴۸ ماهه به ترتیب مدل ۱، ۴، ۱، ۴ و ۴ می‌باشد (آماره‌های ارزیابی برجسته (بولد) شده در این جدول مربوط به مدل برتر می‌باشد). همچنین نتایج حاکی از عملکرد مناسب روش برنامه‌ریزی بیان ژن در مقیاس‌های بالای شاخص SPEI می‌باشد. در خصوص شاخص SPEII روش برنامه‌ریزی بیان ژن توانایی قابل قبولی در پیش‌بینی خشکسالی نداشته است. علت این

جدول ۳. روابط ریاضی حاصل از بهترین مدل پیش‌بینی برنامه‌ریزی بیان ژن

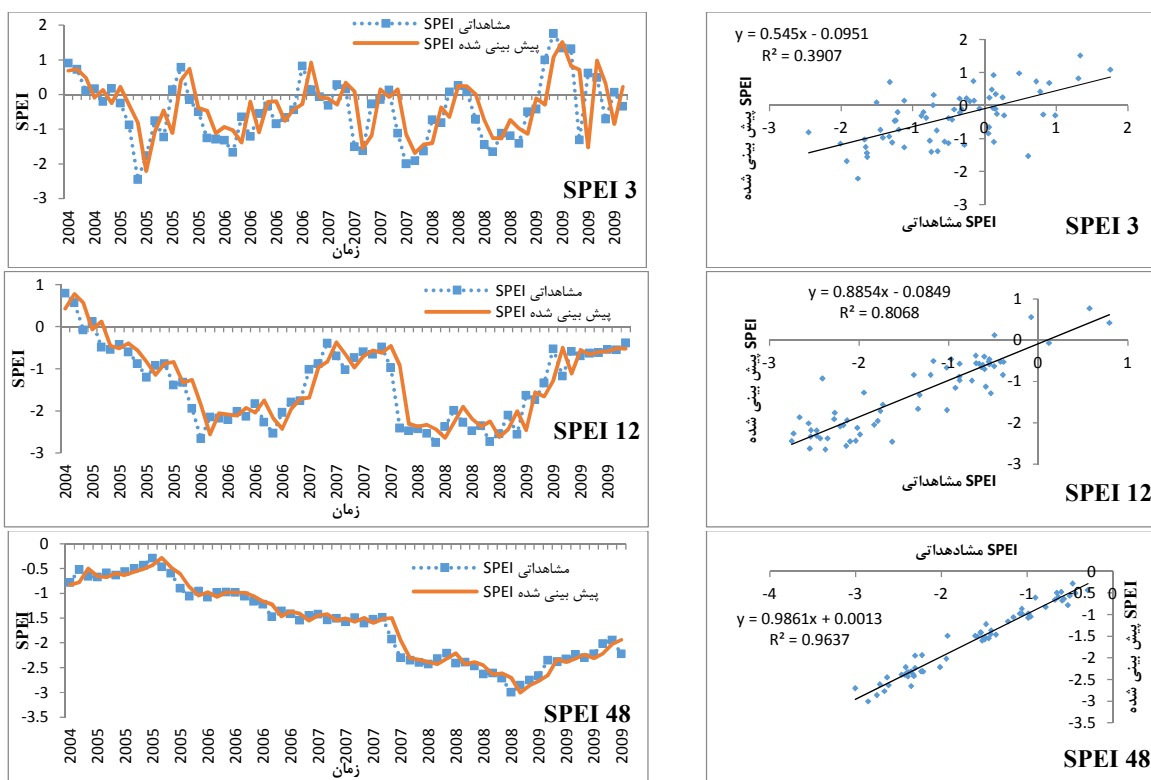
مقیاس زمانی	مدل برتر	رابطه ریاضی مدل برنامه‌ریزی بیان ژن
۱	۱	$SPEI(t+1) = \frac{SPEI(t)^3}{9.4868} + \frac{2SPEI(t)}{6.74}$
۳	۴	$SPEI(t+1) = -SPEI(t-2)^2 \times SPEI(t-1) \times SPEI(t) + \frac{SPEI(t-1)}{-3.84 - SPEI(t-1)} + SPEI(t-3)$
۶	۱	$SPEI(t+1) = 0.565 SPEI(t) - 0.856$
۱۲	۱	$SPEI(t+1) = -2.03 SPEI(t) + \frac{0.601 + SPEI(t)}{-28.04 - 18.96 SPEI(t)}$
۲۴	۴	$SPEI(t+1) = SPEI(t) - 2 SPEI(t-3) + \frac{SPEI(t-2) \times SPEI(t)}{-47.259 SPEI(t-1)}$
۴۸	۴	$SPEI(t+1) = SPEI(t) + 2 ((SPEI(t-3) - SPEI(t-3)) \times (SPEI(t-1) - SPEI(t)))$

گرفت. با توجه به اینکه داده‌های ورودی به مدل‌های سری زمانی مستلزم نرمال و استانداردسازی می‌باشند، کلیه مقادیر شاخص SPEI با استفاده از روابط (۱۰) و (۱۱) نرمال و استاندارد گردیدند. همچنین با توجه به اینکه در بخش قبلی، نتایج روش ساده GEP مورد تحلیل و بررسی قرار گرفت، از پنج مدل ورودی بر اساس آماره‌های ارزیابی، مدل برتر در هر مقیاس زمانی انتخاب گردید. بنابراین مدل برتر به دست آمده توسط روش GEP در مقیاس‌های زمانی مختلف برای استفاده و تحلیل با استفاده از روش ترکیبی GEP-GARCH مورد استفاده قرار گرفت. در جدول (۴) مدل‌های GARCH برازش داده شده بر روی باقی‌مانده‌های مدل GEP برای مقیاس‌های زمانی مختلف ارائه شده است.

پراکنش و سری زمانی مقادیر پیش‌بینی شده و مشاهداتی برای مدل‌های برتر و برای مقیاس زمانی ۳، ۱۲ و ۴۸ ماهه در شکل (۲) ارائه شده است که بر اساس آن مشخص می‌گردد در مقیاس‌های زمانی بالای شاخص SPEI مقادیر مشاهداتی و پیش‌بینی شده بسیار به هم نزدیک بوده و مدل GEP از دقت بالایی برخوردار است.

نتایج روش تلفیقی GEP-GARCH

در این بخش، برای بررسی تلفیق مدل سری زمانی GARCH با روش‌های هوشمند از ترکیب این روش با مدل GEP استفاده گردید و مدل تلفیقی پیشنهادی GEP-GARCH با مدل ساده GEP در تخمین شاخص خشکسالی SPEI مورد مقایسه قرار



شکل ۲. سری زمانی و پراکنش شاخص خشکسالی مشاهداتی و پیش‌بینی‌شده با مدل برتر توسط روش GEP

جدول ۴. مدل‌های GARCH برازش شده

مدل GARCH	مقیاس زمانی
$\sigma_t^2 = 0.0128 + 0.127\varepsilon_{t-1}^2 + 0.619\sigma_{t-1}^2$	۱
$\sigma_t^2 = 0.0019 + 0.1136\varepsilon_{t-1}^2 + 0.745\sigma_{t-1}^2$	۳
$\sigma_t^2 = 0.0014 + 0.0716\varepsilon_{t-1}^2 + 0.441\sigma_{t-1}^2$	۶
$\sigma_t^2 = 0.00006 + 0.234\varepsilon_{t-1}^2 + 0.126\sigma_{t-1}^2$	۱۲
$\sigma_t^2 = 0.00002 + 0.026\varepsilon_{t-1}^2 + 0.897\sigma_{t-1}^2$	۲۴
$\sigma_t^2 = 0.00002 + 0.274\varepsilon_{t-1}^2 + 0.596\sigma_{t-1}^2$	۴۸

در مقیاس‌های زمانی بالا نیز سبب افزایش دقت عملکرد مدل گردیده است.

در شکل (۳) پراکنش مقادیر مشاهداتی و پیش‌بینی‌شده شاخص SPEI با استفاده از روش ترکیبی GEP-GARCH ارائه شده است که بر اساس آن مشخص می‌گردد در این روش نیز با افزایش مقیاس زمانی، میزان دقت مدل بهبود پیدا می‌کند که بهترین عملکرد در مقیاس زمانی ۴۸ ماهه حاصل گردیده است. همچنین در این روش نیز مشاهده می‌گردد که افزایش دقت مدل پیش‌بینی با افزایش مقیاس شاخص خشکسالی رابطه مستقیم دارد. در مقیاس زمانی ۱ ماهه و ۳ ماهه نیز مقادیر مشاهداتی و پیش‌بینی‌شده به هم نزدیک‌تر و مطابقت بیشتری پیدا کرده‌اند و روش ترکیبی سبب بهبود عملکرد مدل برنامه‌ریزی بیان ژن

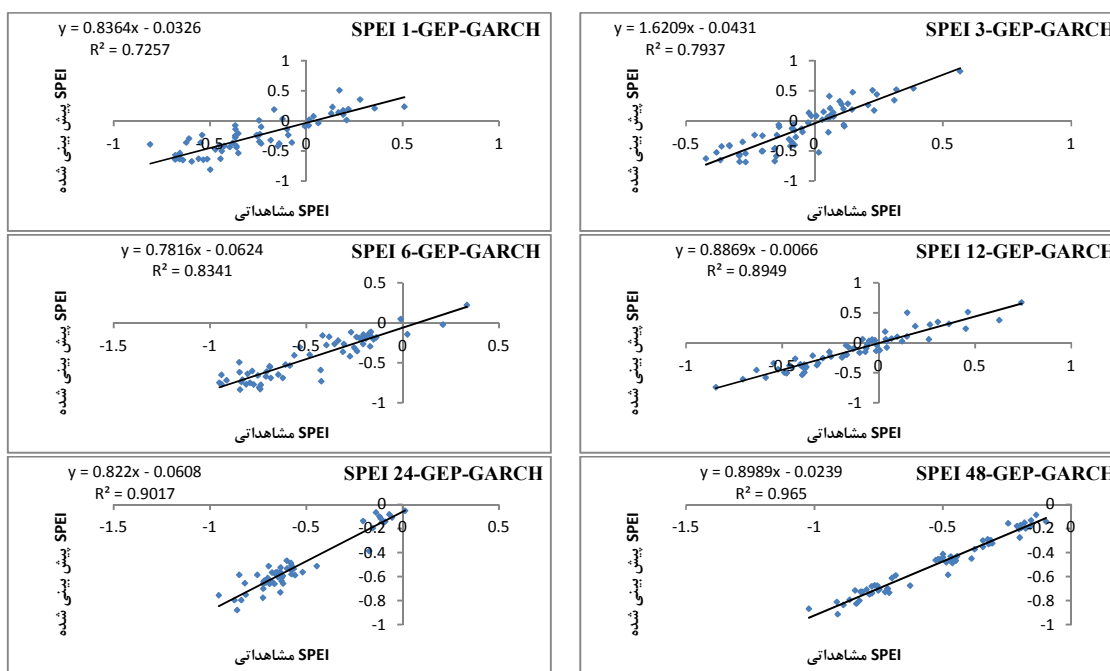
در جدول (۵) مقایسه دو مدل ترکیبی GEP-GARCH با مدل ساده GEP مورد بررسی قرار گرفته است. بر اساس آماره‌های ارزیابی مشخص می‌گردد که مدل ترکیبی سبب افزایش عملکرد کلیه مقیاس‌های زمانی شاخص SPEI می‌گردد. در مقیاس زمانی کوتاه‌مدت که روش GEP از دقت مناسب برخوردار نیست، روش ترکیبی سبب بهبود بسیار مناسب عملکرد پیش‌بینی در این حالت می‌گردد به نحوی که ضریب همبستگی در مقیاس زمانی یک‌ماهه در این ایستگاه از ۰/۲۱ به ۰/۸۵۱ و RMSE از ۰/۳۵۶ به ۰/۰۷۹ رسیده است. همچنین با توجه به اینکه مدل ساده GEP در مقیاس زمانی بلندمدت و میان‌مدت دارای دقت نسبتاً مناسبی می‌باشد، میزان تغییر در آماره‌های ارزیابی آن نسبت به مقیاس کوتاه‌مدت کمتر می‌باشد. ولی با این وجود، مدل ترکیبی

سری زمانی غیرخطی ARCH و PARCH برای پیش‌بینی بیشینه سیلاب لحظه‌ای مطابقت دارد.

گردیده است. این نتایج با نتایج تحقیق Nazeri Tahroudi and Khalili (2015) در استفاده از روش ترکیبی سری زمانی خطی با

جدول ۵. شاخص‌های آماری محاسبه‌شده برای مدل‌های مختلف GEP و GEP-ARCH در دوره آزمون

روش		روش		مدل برتر	مقیاس زمانی
GEP-GARCH	GEP	GEP-GARCH	GEP		
R	RMSE	R	RMSE		
۰/۸۵۱	۰/۰۷۹	۰/۰۲۱	۰/۳۵۶	۱	۱
۰/۸۹۱	۰/۰۵۹	۰/۶۲۲	۰/۲۳۴	۴	۳
۰/۹۱۳	۰/۰۴۶	۰/۸۴۵	۰/۱۷	۱	۶
۰/۹۴۶	۰/۰۳۷	۰/۹۳۷	۰/۱۲	۱	۱۲
۰/۹۸۹	۰/۰۲۹	۰/۹۷۸	۰/۰۶۷	۴	۲۴
۰/۹۹۳	۰/۰۲	۰/۹۸۶	۰/۰۴۲	۴	۴۸



شکل ۳. پراکنش مقادیر مشاهداتی و پیش‌بینی‌شده شاخص SPEI در مقیاس‌های زمانی مختلف با استفاده از مدل ترکیبی GEP-GARCH

بخش تصادفی سری‌های زمانی هیدرولوژیک است. برای غلبه بر این ضعف، می‌توان از مدل‌های سری زمانی برای مدل‌سازی بخش تصادفی سری‌های زمانی هیدرولوژیک استفاده نمود؛ بنابراین در این تحقیق در بحث پیش‌بینی خشکسالی، به منظور بررسی و مقایسه عملکرد مدل‌های سری زمانی و هوشمند، بخش تصادفی و یا باقی‌مانده مدل‌ها با استفاده از روش GARCH برازش داده شد و مدل ترکیبی GEP-GARCH حاصل گردید. نتایج نشان داد روش برنامه‌ریزی بیان ژن در مقیاس‌های زمانی بلندمدت شاخص SPEI از دقت مناسب برخوردار می‌باشد ولی در مقیاس‌های کوتاه‌مدت عملکرد مناسبی ندارد. همچنین نتایج نشان داد

نتیجه‌گیری

هدف از این تحقیق ارائه مدلی جدید برای پیش‌بینی خشکسالی با استفاده از ترکیب روش‌های هوشمند و سری زمانی غیرخطی بود. برای این منظور از داده‌های دما و بارش ایستگاه سلماس به منظور محاسبه شاخص خشکسالی SPEI استفاده گردید. با توجه به ماهیت غیرقطعی مسائل اقلیمی و هیدرولوژی، استفاده از مدل‌های اتفاقی و سری‌های زمانی به‌عنوان یکی از روش‌های توصیه‌شده در پیش‌بینی‌ها می‌تواند مورد استفاده قرار گیرد. یکی از ضعف‌های روش‌های هوش مصنوعی و هوشمند در مدل‌سازی متغیرهای هیدرو-اکولوژیک همانند خشکسالی نادیده گرفتن

در مقیاس‌های زمانی مختلف معرفی کرد. همچنین پیشنهاد می‌گردد در مطالعات آتی، ترکیب سایر روش‌های هوشمند با روش‌های سری زمانی غیرخطی مختلف به منظور پیش‌بینی خشکسالی نیز مورد بررسی و تحلیل قرار گیرد.

استفاده از روش سری زمانی غیرخطی GARCH و ترکیب آن با روش GEP سبب بهبود عملکرد مدل پیش‌بینی در همه مقیاس‌های زمانی می‌گردد و این بهبود عملکرد خصوصاً در مقیاس‌های کوتاه‌مدت بیش‌تر می‌باشد. لذا می‌توان روش ترکیبی GEP-GARCH را به‌عنوان روشی مناسب برای پیش‌بینی خشکسالی

REFERENCES

- Abbaszadeh Afshar, M., Khalili, K. and Behmanesh, J. (2016). Application of Combined AR-ARCH model in Forecasting Urmia Lake Water Level. *Water and Soil Science*, 25(4/2), 175-184. (In Farsi)
- Allen R.G., Pereira L.S., Raes D. and Smith M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements. FAO Irrigation and drainage paper. 56 FAO, Rome 300:D05109.
- Bera, A. K. and Higgins, M. L. (1993). ARCH models: properties, estimation and testing. *Journal of economic surveys*, 7(4), 305-366.
- Bollerslev, T. (1986). Generalized autoregressive heteroskedasticity. *J. Econom.* 52, 307-327.
- Bollerslev, T., Chou, R. Y. and Kroner, K. F. (1992). ARCH modeling in finance: A review of the theory and empirical evidence. *Journal of econometrics*, 52(1-2), 5-59.
- Baba Ali, H.R. and Dehghani, R. (2017). Compare intelligent models to Estimate monthly Precipitation Kakareza Basian. *Iranian journal of Ecohydrology*, 4(1), 1-11. doi: 10.22059/ije.2017.60911. (In Farsi)
- Behmanesh, J. and Mehdizadeh, S. (2017). Estimation of soil temperature using gene expression programming and artificial neural networks in a semiarid region. *Environmental Earth Sciences*, 76(2), 76.
- Caiado, J. (2007). Forecasting water consumption in Spain using univariate time series models. 415-423.
- Danandeh Mehr, A., Kahya, E. and Ozger, M. (2014). A gene-wavelet model for long lead time drought forecasting. *Journal of Hydrology*, 517, 691-699.
- DaSilva, V.d.P.R. (2004). On climate variability in Northeast of Brazil. *Journal of Arid Environments*, 58(4), 575-596.
- Dastorani, M., & Afkhami, H. (2011). Application of artificial neural networks on drought prediction in Yazd (Central Iran). *Desert*, 16(1), 39-48. (In Farsi)
- Dorado, J., RabuñAL, J. R., Pazos, A., Rivero, D., Santos, A. and Puertas, J. (2003). Prediction and modeling of the rainfall-runoff transformation of a typical urban basin using ANN and GP. *Applied Artificial Intelligence*, 17(4), 329-343.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the Econometric Society*, 987-1007.
- Ferreira, C. (2002). Gene expression programming in problem solving. In *Soft computing and industry* (pp. 635-653). Springer, London.
- Guven, A. (2009). Linear genetic programming for time-series modelling of daily flow rate. *Journal of earth system science*, 118(2), 137-146.
- Hosseini-Moghari, S. M. and Araghejad, S. (2015). Monthly and seasonal drought forecasting using statistical neural networks. *Environmental Earth Sciences*, 74(1), 397-412.
- Khalili, K., Fakheri Fard, A., Dinpaghoh, Y., Ahmadi, F. and Behmanesh, J. (2013). aIntroducing and Application of Combined BL-ARCH Model for Daily River flow Forecasting (Case study: Shahar-Chai River). *Journal of Water and Soil*, 27(2), 342-350. (In Farsi)
- Khu, S. T., Liong, S. Y., Babovic, V., Madsen, H. and Muttil, N. (2001). Genetic Programming and its Application in Real-time Runoff Forecasting. *JAWRA Journal of the American Water Resources Association*, 37(2), 439-451.
- Kisi, O., Shiri, J. and Nikoofar, B. (2012). Forecasting daily lake levels using artificial intelligence approaches. *Computers & Geosciences*, 41, 169-180.
- Laux, P., Vogl, S., Qiu, W., Knoche, H. R. and Kunstmann, H. (2011). Copula-based statistical refinement of precipitation in RCM simulations over complex terrain. *Hydrology and Earth System Sciences*, 15(7), 2401-2419.
- Maca P. and Pech P (2016) Forecasting SPEI and SPI drought indices using the integrated artificial neural networks. *Computational intelligence and neuroscience*, 2016(14).
- Mehdizadeh, S., Behmanesh, J. and Saadatnejad Gharahassanlou, H. (2016). Evaluation of gene expression programming and Bayesian networks methods in predicting daily air temperature. *Journal of Agricultural Meteorology*, 4(2), 1 -13. (In Farsi)
- Mishra, A. and Desai, V. (2005). Drought forecasting using stochastic models. *Stochastic Environmental Research and Risk Assessment*. 19(5):326-339.
- Mishra, A. and Desai, V. (2006). Drought forecasting using feed-forward recursive neural network. *ecological modelling*. 198(1-2):127-138.
- Naveh, H., Khalili, K., Alami, M. and Behmanesh, J. (2012). Forecasting River flow By Bilinear Nonlinear Time Series Model (Case Study: Barandoz-Chay & Shahar-Chai rivers). *Journal Of Water And Soil*, 26(5), 1299-1307. (In Farsi)

- Nazeri Tahrodi, M. and Khalili, K. (2015). Comparing Combined ARMA-PARCH and ARMA-ARCH Models for Modeling Peak Flow Discharge (Case Study: Siminehrood River in the West Azarbaijan Province). *Water and Soil Science*, 25(1-4), 113-127. (In Farsi)
- Thornthwaite, C.W. (1948). An approach toward a rational classification of climate. *Geographical review*. 38(1):55-94.
- Vicente-Serrano, S.M, Begueria, S. and Lopez-Moreno, J.I. (2010). A multiscale drought index sensitive to global warming: the standardized precipitation evapotranspiration index. *Journal of Climate*. 23(7):1696-1718.
- Wang, W., Van Gelder, P., Vrijling, J. and Ma, J. (2005). Testing and modelling autoregressive conditional heteroskedasticity of streamflow processes. *Nonlinear processes in Geophysics*, 12(1), 55-66.
- Yang, Y., Dong, Y., Chen, Y. and Li, C. (2014). Intelligent optimized combined model based on GARCH and SVM for forecasting electricity price of New South Wales, Australia. Paper presented at the Abstract and Applied Analysis.
- Zareh Amini, F., Ghorbani, M.A. and Darbandi, S. (2014). Evaluation of Genetic Programming in Estimation of Soil Temperature. *Geographical Space*. 47(4), 19-38. (In Farsi)