

تخمین خشکسالی با نمایه‌های SPI و EDI با استفاده از شبکه عصبی مصنوعی - فازی بهینه شده با الگوریتم بهینه سازی ازدحام ذرات (مطالعه موردی: استان کهگیلویه و بویراحمد)

مهدی ملک محمودی

دانش آموخته کارشناسی ارشد مهندسی عمران - مدیریت منابع آب، دانشکده فنی و مهندسی، دانشگاه یاسوج، یاسوج، ایران.

مهدی کماسی

استادیار گروه مهندسی عمران، دانشگاه آیت الله بروجردی، بروجرد، ایران. komasi@abru.ac.ir

جعفر جعفری اصل

دانشجوی دکتری مهندسی عمران، دانشکده مهندسی شهید نیکبخت، دانشگاه سیستان و بلوچستان، زاهدان، ایران.

سیما اوحدی

دانشجوی دکتری مهندسی عمران، دانشکده مهندسی شهید نیکبخت، دانشگاه سیستان و بلوچستان، زاهدان، ایران.

تاریخ دریافت: 98/10/05 تاریخ پذیرش: 98/11/30

چکیده

خشکسالی یکی از اصلی‌ترین و قدیمی‌ترین بلاهای طبیعی است که عواقب زیست محیطی مهمی را به در پی دارد. در واقع میزان خشکسالی مقایسه نسبی بین میزان بارندگی هر منطقه در آن سال با میانگین بارندگی در سال‌های گذشته می‌باشد. استان کهگیلویه و بویراحمدگر چه از نظر میزان بارش دارای جایگاه سوم در کشور می‌باشد اما خشکسالی‌ها به‌طور متناوب این استان را تحت تاثیر قرار داده و خسارات جبران ناپذیری را به دنبال دارند. استفاده از نمایه‌های اندازه‌گیری خشکسالی برای پایش و ارزیابی مکانی و زمانی این پدیده به‌جهت مدیریت بحران آن ضروری و حیاتی به نظر می‌رسد. در این پژوهش از شبکه‌های عصبی مصنوعی (ANN) و مدل عصبی فازی تطبیقی (ANFIS) برای پیش‌بینی خشکسالی با نمایه بارش استاندارد (SPI) و نمایه خشکسالی موثر (EDI) استفاده گردیده است بر اساس مطالعات نمایه‌های SPI و EDI قابلیت بیشتری در پیش‌بینی نسبت به نمایه‌هایی چون پالمر، پالفی و دیگر نمایه‌ها دارند. نتایج این پژوهش حاکی از آن است که نمایه SPI قابلیت و دقت بالاتری نسبت به نمایه EDI در پیش‌بینی خشکسالی دارد و از طرفی مدل شبکه عصبی - فازی تطبیقی بهینه‌شده (PSO-ANFIS) جهت پیش‌بینی خشکسالی از کارایی بالایی برخوردار است. نتایج نشان می‌دهد که بهینه شده موجب افزایش دقت مدل‌سازی در مرحله صحت‌سنجی و واسنجی شده است همچنین مدل با ضریب واسنجی 0/97 و ضریب صحت سنجی 0/86 بهترین مدل می‌باشد.

واژه‌های کلیدی: خشکسالی، الگوریتم ازدحام ذرات، شبکه عصبی - فازی تطبیقی، کهگیلویه و بویراحمد، نمایه‌های SPI و EDI

Drought forecasting with SPI and EDI indices using adaptive neuro fuzzy network optimized by particle swarm optimization (Case Study: Kohgiluyeh and Boyerahmad)

Abstract

Drought is one of the most and oldest natural disaster that cause significant enviromental impacts. In fact, the rate of drought is the relative comparison between the regional rainfall's amounts of that year with the average rainfall in recent years. Despite Kohgiluyeh and Boyerahmad is in the third place in terms of rainfall but the drought has affect the province intermittently and causes many heavy losses. In orther to drought crisis management, finding the index measurement of the drought to predict and evaluate the spatial and temporal of this phenomenon, seems essential. In order to drought predicting with standardized precipitation index (SPI) and effective drought index (EDI), in this study the basics of adaptive neuro fuzzy network (ANFIS) model have been used. Based on studies, in comparison with indexes such as palmer, palfy and other indexes, SPI and EDI indexes predicting have capabily in predicting. The results of study indicate that the SPI index has more capability and accuracy than EDI index in predicting of drought. On the other hand according to PSO-ANFIS in modeling for predicting the drought, this new approach has more efficacy. PSO-ANFIS by calibration coefficient 0.97 and validation coefficient 0.86 is the best model.

Keywords: Drought, PSO, ANFIS, Kohgiluyeh and Boyerahmad, SPI and EDI

مقدمه

تفاوت در پارامترهای آب و هوایی و فاکتورهای اقتصادی- اجتماعی مؤثر بر خشکسالی و همچنین متغیر بودن مفهوم و میزان تقاضای آب در مناطق مختلف دنیا سبب شده است که امکان ارائه‌ی یک تعریف مشخص و جامع از خشکسالی تا حدودی دشوار به نظر برسد (میشرا و همکاران، ۲۰۱۰). یوجوویچ^۱ (۱۹۶۷) عدم وجود یک تعریف جامع و دقیق از خشکسالی و متفاوت بودن معنی آن از دیدگاه‌های مختلف را یکی از موانع اصلی در درک مفهوم خشکسالی می‌داند. بنا بر گزارش ویلهایت و گلانتز^۲ (۱۹۸۷) بیش از ۱۵۰ تعریف در خصوص خشکسالی از دیدگاه‌های مختلف ارائه شده است. اگرچه تعاریف خشکسالی متنوع است اما تشریح خشکسالی، بستگی به متغیر مورد استفاده دارد. ازاین‌رو خشکسالی می‌تواند به گروه‌های مختلف که در ذیل بحث می‌شوند، تقسیم گردد. ویلهایت و گلانتز (۱۹۸۵) و جامعه‌ی هواشناسی آمریکا^۳ (۲۰۰۴) خشکسالی را به چهار دسته خشکسالی هواشناسی^۴، کشاورزی^۵، هیدرولوژیکی^۶ و اقتصادی- اجتماعی^۷ تقسیم‌بندی نمودند. بر اساس این طبقه‌بندی خشکسالی هواشناسی، هم‌زمان با کمبود میزان بارندگی سالیانه یا هر بازه‌ی زمانی معین، نسبت به میانگین درازمدت منطقه رخ می‌دهد. ادامه‌ی خشکسالی هواشناسی به مدت طولانی سبب بروز خشکسالی هیدرولوژیکی می‌گردد که در این نوع خشکسالی سطح آب رودخانه‌ها و مخازن سطحی و زیرسطحی به پایین‌تر از میانگین درازمدت افت می‌کند. خشکسالی کشاورزی نیز معمولاً برای محصول خاصی اعلام می‌گردد، بدین معنی که این نوع خشکسالی زمانی رخ می‌دهد که میزان رطوبت خاک برای رشد آن محصول کمتر از میزان موردنیاز باشد. خشکسالی کشاورزی معمولاً پس از خشکسالی هواشناسی رخ می‌دهد؛ اما خشکسالی اقتصادی- اجتماعی در پی تأثیر کاهش مقدار آب بر جوامع انسانی و برهم زدن تعادل عرضه و تقاضای محصولات و کالاهای وابسته به آب به وقوع می‌پیوندد. در این زمان میزان تقاضای این نوع کالاها بیشتر از میزان عرضه‌ی آن‌ها خواهد شد. افزایش جمعیت یا افزایش مصرف در کنار خشکسالی هیدرولوژیکی می‌تواند عامل بروز این نوع خشکسالی باشد (سهرابی و همکاران، ۱۳۸۷).

خشکسالی پدیده‌ای طبیعی است و در تمامی دوره‌ها اتفاق افتاده است، ولی اثرات آن در سال‌های اخیر که رشد جمعیت و میزان مصرف آب افزایش داشته، مشهودتر بوده است. درگذشته نیز آسیب‌های ناشی از خشکسالی به علت عدم آگاهی انسان از رموز طبیعت و عدم چاره‌جویی‌های مناسب، به‌عنوان بلایی از آسمان تلقی می‌شده که نمونه‌ای از آن در کتیبه‌های عهد هخامنشیان در ایران باستان به‌دست‌آمده است. خشکسالی دارای اثرات سنگین اجتماعی نیز هست. در سال‌های خشک، زمینه نزاع بین مصرف‌کنندگان منابع آب شدت می‌یابد. خسارت‌های مادی ناشی از کمبود آب و در نتیجه کمبود محصولات را نیز

^۱ Yevjevich

^۲ Wilhaite and Glantz

^۳ American Meteorological Society

^۴ Meteorological

^۵ Agricultural

^۶ Hydrological

^۷ Social-Economic

باید از اثرات اجتماعی آن محسوب کرد. بعد دیگر خشکسالی شامل خسارت به منابع آبی است که باعث محدودیت تغذیه و کاهش کیفیت آب می‌شود (حجاری زاده و همکاران، ۱۳۸۹).

کشور بزرگ ایران به لحاظ موقعیت خاص و ویژگی‌های توپوگرافی، از آب‌وهوای متفاوتی برخوردار است به‌طورکلی باید گفت که وقوع خشکسالی از ویژگی‌های اصلی آب‌وهوای ایران محسوب می‌شود که هم در قلمرو آب‌وهوای مرطوب و هم خشک قابل مشاهده است. این حالت در نتیجه وجود نوسانات آب و هوایی شدید در مقیاس‌های مختلف زمانی حاصل می‌شود. ویژگی‌های خشکسالی ایران نشان می‌دهد که به‌طورکلی هیچ منطقه‌ای از کشور، از این پدیده در امان نبوده و به نسبت موقعیت طبیعی خود آثار این پدیده مخرب را تجربه می‌نماید و بخش‌های جنوبی، شرقی و مرکزی کشور به علت نوسانات بیشتر در مقادیر بارندگی، از آسیب‌پذیری زیادتری برخوردار هستند (سلحشور، ۱۳۹۱).

نمایه خشکسالی امکان توصیف و بیان خشکسالی به‌صورت کمی را فراهم می‌کند. نمایه خشکسالی تابعی از عوامل مختلف محیطی است که بر پدیده خشکسالی اثر می‌گذارند. استفاده از فرم تجربی نمایه کمبود توام برای پایش خشکسالی کافی نمی‌باشد و توصیه می‌شود از فرم نظری آن استفاده شود (بذرافشان و همکاران، ۱۳۹۴). جمشیدی و همکاران (۱۳۸۸) در تحقیقی با استفاده از آمار سال‌های ۱۹۶۷ تا ۲۰۰۵ تعداد ۳۹ ایستگاه سینوپتیک در گستره‌های اقلیمی مرطوب، نیمه‌خشک و خشک ایران، به پایش خشکسالی بر اساس دو نمایه خشکسالی احیایی^۱ (RDI) و بارش استاندارد^۲ (SPI) پرداختند. نتایج آن‌ها نشان داد که نمایه RDI در اکثر ماه‌ها از مشابهت رفتاری بالایی با نمایه SPI برخوردار است، اگرچه در برخی از ماه‌ها افزایش یا کاهش مقدار تبخیر و تعرق پتانسیل سبب نوساناتی در نمایه RDI می‌گردد. آن‌ها همچنین نشان دادند که در طبقه‌های خشکسالی شدید به‌علت مقادیر بارندگی کم و تبخیر و تعرق زیاد، مقادیر نمایه RDI افزایش می‌یابد. آن‌ها در پایان با تعیین ضرایب همبستگی بین نمایه RDI و SPI بیان داشتند نمایه RDI به دلیل همبستگی بالا با نمایه SPI می‌تواند در پایش خشکسالی در طرح‌های منابع آب در ایران مورد توجه قرار گیرد. یزدانی و همکاران (۱۳۹۱) به‌منظور بررسی خشکسالی‌ها از نمایه SPI ر دو مقیاس زمانی ۳ و ۱۲ ماهه و داده‌های بارش ۱۱۹ ایستگاه واقع در داخل کشور با طول دوره آماری مشترک ۳۲ ساله (۱۳۸۴-۱۳۵۳) استفاده نمودند. نتایج نشان دادند که تعداد خشکسالی‌ها در فواصل زمانی کوتاه‌تر بیش از تعداد آن‌ها در فواصل زمانی طولانی‌تر نیز می‌باشند، همچنین در سال‌های اخیر، تکرار خشکسالی در ایران افزایش داشته ولی از شدت آن کاسته شده است. محمدیان و همکاران (۱۳۸۹) در مطالعه‌ای، وقوع، شدت و تداوم خشکسالی توسط داده‌های ماهانه بارش (۲۰۰۵-۱۹۸۶) ثبت‌شده در همه ایستگاه‌های هواشناسی در استان خراسان شمالی، ارزیابی‌شده است. نمایه‌های خشکسالی شامل SPI، نمایه دهکها (DI) و درصد نرمال (PNI) محاسبه و برای تعیین شدت، مدت و وقوع خشکسالی برای تمامی ایستگاه‌ها مقایسه شدند که نتایج نشان داد که نمایه SPI از دو نمایه دیگر قابلیت بیشتری دارد.

نمایه خشکسالی موثر (EDI) می‌تواند برای بازبینی خشکسالی مناطق بزرگ به کار رود. ولی مشکل اصلی در فرم اولیه آن، استفاده از

^۱ Reclamation Drought Index

^۲ Standardized Precipitation Index

داده‌های روزانه بارندگی است که همواره موجود نمی‌باشد برای رفع این مشکل اسماختین و هیز^۱ (۲۰۰۴) الگوریتم EDI را با حفظ اصول محاسبات آن تغییر دادند تا بتوانند با به‌کارگیری مقادیر بارندگی ماهانه، مقدار ماهانه EDI را محاسبه کنند. کماسی و همکاران (۱۳۹۲) به مطالعه پیش‌بینی خشکسالی با نمایه SPI به روش مدل‌سازی ANFIS پرداختند. نتایج حاکی از آن است که SPI دقت بالاتری نسبت به سایر نمایه‌ها دارد و شبکه عصبی-فازی تطبیقی در امر مدل‌سازی برای پیش‌بینی خشکسالی از کارایی بیشتری برخوردار است. ابراهیم پور و همکاران (۱۳۹۳) برای کاربرد روش‌های هوش مصنوعی در پیش‌بینی خشکسالی بر اساس شاخص SPI از دو روش هوش مصنوعی شامل شبکه عصبی پرسپترون چندلایه (MLP) و سیستم استنباط عصبی-فازی تطبیقی استفاده کردند نتایج نشان داد هر دو روش با دقت قابل قبولی خشکسالی را پیش‌بینی می‌کنند. باکانلی و همکاران^۲ در سال (۲۰۰۸) از مدل ANFIS به‌منظور پیش‌بینی خشکسالی در کشور ترکیه استفاده نمودند. مدل‌های پیش‌بینی مختلفی برای SPI با مقیاس‌های زمانی ۱، ۳، ۶، ۹، ۱۲ ماهه مورد بررسی قرار گرفتند. نتایج نشان داد که ترکیب مقادیر پیشین بارندگی و شاخص SPI با یکدیگر بهبود عملکرد مدل‌ها را به همراه دارد و مقایسه‌های انجام‌گرفته با نتایج روش‌های شبکه عصبی FFNN و رگرسیون خطی چندگانه، نشان از ارجحیت مدل ANFIS نسبت به دو مدل دیگر داشت اما با توجه به اینکه نمایه‌های خشکسالی دارای دامنه‌های متفاوتی هستند بهره‌گیری از یک آنالیز پیش‌پردازشگر می‌تواند روند بهتری در فرایند مدل‌سازی به وجود آورد.

همان‌گونه که ملاحظه می‌شود، در تحقیقاتی که تاکنون به‌منظور پیش‌بینی خشکسالی انجام شده است، عمدتاً شاهد به‌کارگیری یک روش و عدم مقایسه روش‌های گوناگون با یکدیگر هستیم. به‌علاوه بیشتر تحقیقات بر کاربرد روش شبکه عصبی مصنوعی در پیش‌بینی خشکسالی متمرکز شده‌اند. همچنین به علت اهمیت این پدیده و اثرات آن بر جنبه‌های مختلف زندگی، در این تحقیق سعی بر آن است که با استفاده از نمایه‌های SPI و EDI خشکسالی هواشناسی استان کهگیلویه و بویراحمد را بررسی کرده و با قرار دادن این نمایه‌ها به‌عنوان ورودی مدل ANFIS که به کمک الگوریتم ازدحام ذرات بهینه‌سازی شده به پیش‌بینی خشکسالی استان کهگیلویه و بویراحمد پرداخته شود.

مواد و روش‌ها

نمایه بارش استاندارد شده (SPI)

اساس نمایه SPI را داده‌های بارندگی ماهانه ایستگاه‌های باران‌سنجی تشکیل می‌دهند پس از اطمینان از آماده‌سازی داده‌های ماهانه، سری زمانی در بازه‌های ۳، ۶، ۱۲، ۲۴ و ... ماهه تشکیل می‌شود و سری زمانی آن با توزیع گاما برازش داده می‌شود که تابع دانسیته احتمال یا فراوانی آن به‌صورت رابطه (۱) تعیین می‌شود: (مک کی و همکاران^۳، ۱۹۹۳).

^۱ Smakhtin and Hughes

^۲ Bacanlı et al

^۳ McKee et al

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}} \quad \text{for } x > 0 \quad (1)$$

α و β به ترتیب پارامتر شکل و پارامتر مقیاس می‌باشند. $\Gamma(\alpha)$ تابع گاما می‌باشد که برابر است با:

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

ملکی و همکاران ۱۹۹۳ با بهره‌گیری از روش حداکثر درست‌نمایی بهینه ضرایب α و β را بر اساس معادلات (۳) تا (۵) برآورد نمودند:

$$A = \ln(\bar{x}) - \frac{\sum \ln(x)}{n} \quad (3)$$

$$\hat{\alpha} = \frac{1}{4A} \left[1 + \sqrt{1 + \frac{4A}{3}} \right] \quad \alpha > 0 \quad (4)$$

$$\hat{\beta} = \frac{\bar{x}}{\hat{\alpha}} \quad \beta > 0 \quad (5)$$

تابع احتمال تجمعی به صورت معادله (۶) تعریف می‌شود:

$$G(x) = \int_0^x g(x) dx = \frac{1}{\hat{\beta}^{\hat{\alpha}} \Gamma(\hat{\alpha})} \int_0^x x^{\hat{\alpha}-1} e^{-\frac{x}{\hat{\beta}}} dx \quad (6)$$

از آنجائی که تابع فوق برای $x=0$ تعریف نشده است، بنابراین در صورت وجود صفر در داده‌های بارندگی، احتمال تجمعی با معادله (۷) محاسبه می‌گردد:

$$H(x) = q + (1-q)G(x) \quad (7)$$

که در آن q احتمال بارندگی صفر در سری زمانی مورد بررسی هست که معادل با نسبت تعداد صفرها به کل داده‌ها است. سپس با داشتن $H(x)$ و روابط (۸) تا (۱۱) SPI به دست می‌آید.

$$Z = SPI = - \left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right) \quad 0 < H(x) \leq 0.5 \quad (8)$$

$$Z = SPI = + \left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right) \quad 0.5 < H(x) \leq 1.0 \quad (9)$$

$$t = \sqrt{\ln \left(\frac{1}{(H(x))^2} \right)} \quad 0 < H(x) \leq 0.5 \quad (10)$$

$$t = \sqrt{\ln \left(\frac{1}{(1-H(x))^2} \right)} \quad 0.5 < H(x) \leq 1.0 \quad (11)$$

$$c_0 = 2.515517 \quad d_1 = 1.432788$$

$$c_1 = 0.802853 \quad d_2 = 0.189269$$

$$c_2 = 0.010328 \quad d_3 = 0.001308$$

مقادیر مثبت SPI نشان‌دهنده بارندگی بیشتر از بارش متوسط و مقادیر منفی آن معنای عکس را دارد. طبق این روش دوره خشکسالی هنگامی اتفاق می‌افتد که SPI به‌طور مستمر منفی و به مقدار -1 یا کمتر برسد و هنگامی پایان می‌یابد که SPI مثبت گردد.

نمایه خشکسالی مؤثر (EDI)

نمایه EDI تابعی از مقدار بارندگی موردنیاز برای جبران کمبود تجمعی بارش از ابتدای دوره خشکسالی می‌باشد. در محاسبه نمایه EDI در مرحله اول باید مقدار بارش مؤثر (EP) محاسبه گردد. بارش مؤثر مفهوم اصلی و جدید در محاسبه نمایه EDI هست که بیان‌کننده مجموع بارش‌های روزانه یا ماهانه با یک تابع زمانی کاهشدهنده است. به عبارت دیگر بارش مؤثر (EP) تابعی از بارندگی ماه حاضر و بارندگی‌های وزن شده ماه‌های قبلی در دوره مورد بررسی هست. چنانچه P_m بارندگی، $M-1$ ماه قبل تا ماه فعلی و N دوره موردبررسی باشد مقدار EP به‌صورت زیر تعریف می‌گردد.

$$EP = \sum_{m=1}^N \left(\frac{\sum_{i=1}^m P_m}{m} \right) = P_1 + \frac{P_1 + P_2}{2} + \frac{P_1 + P_2 + P_3}{3} + \dots + \frac{P_1 + P_2 + \dots + P_N}{N} \quad (12)$$

EP برای هرماه محاسبه می‌گردد و با محاسبه تفاضل مقادیر EP ماهانه از میانگین بارش مؤثر (MEP) سری زمانی DEP حاصل می‌گردد.

$$DEP = EP - MEP \quad (13)$$

سپس مقادیر PRN به‌صورت زیر محاسبه می‌گردد.

$$PRN = DEP / \sum (1/N) \quad (14)$$

در نهایت مقدار نمایه EDI از رابطه (15) محاسبه میشود.

$$EDI = PRN / Std(PRN) \quad (15)$$

مدل‌سازی هوش مصنوعی

برای پیش‌بینی رفتار پدیده‌های هیدرولوژیکی با توجه به اینکه قوانین احتمالات بر آن‌ها حاکم است غالباً متغیرها به‌صورت سری زمانی در نظر گرفته شده و مراحل تجزیه و تحلیل به‌گونه‌ای است که از اطلاعات گذشته سری در جهت ایجاد الگو یا مدل پیش‌بینی کننده سری زمانی برای آینده بهره‌گیری می‌شود. در بین مدل‌های موجود در سری زمانی خود همبسته با میانگین متحرک و مدل خود همبسته تجمعی با میانگین متحرک و یا مدل جعبه سیاه هر دو از این ساختار، پیروی می‌کنند.

شبکه عصبی فازی تطبیقی (ANFIS)

این ساختار حاصل تلفیق شبکه تطبیقی با قوانین فازی است. در این ساختار هیچ محدودیتی بر روی توابع گره‌ای وجود ندارد به‌جز اینکه باید به‌طور قطعه‌ای مشتق‌پذیر باشند. قوانین فازی به‌صورت تاکاگی-سوگینو در نظر گرفته می‌شوند و اگر x و y دو متغیر بخش مقدمه قانون فازی i ام باشند، مؤخره این قانون فازی به‌صورت ترکیب خطی x و y به همراه یک مقدار ثابت خواهد بود.


ساختار شبکه ANFIS با پنج لایه، در شکل ۱ نشان داده شده است. لایه اول دارای گره‌های قابل تنظیم است که معمولاً توابع تعلق مربوط به

آن‌ها به صورت گاوسی یا زنگوله شکل، با مقدار بیشینه‌ای برابر یک و کمینه‌ای برابر صفر می‌باشند. پارامترهای توابع تعلق که همان پارامترهای مقدمه قوانین فازی هستند، بر اساس توصیف زبانی مربوط به متغیرها و زیر فضاهای فازی و بر اساس روش هایبرید تنظیم می‌شوند.

گره‌های لایه دوم ثابت در نظر گرفته می‌شوند. این گره‌ها دو سیگنال ورودی را در هم ضرب کرده و حاصل را به عنوان خروجی تحویل شبکه می‌دهند. سیگنال‌های ورودی این گره‌ها در واقع میزان سازگاری ورودی با هر یک از توابع تعلق و خروجی آن‌ها، وزن مربوط به هر یک از قوانین است. گره‌های لایه سوم نیز ثابت بوده و وظیفه آن‌ها محاسبه وزن نرمال نمودن هر یک از قوانین است گره‌های لایه چهارم وزن نرمال نمودن هر یک از قوانین فازی را در خروجی بخش مؤخره آن قانون ضرب کرده و تنها گره لایه پنجم نیز کلیه سیگنال‌های خروجی از گره‌های لایه چهارم را جمع کرده و به عنوان خروجی شبکه تحویل می‌دهد.

الگوریتم هایبرید به صورت مستقیم برای شناسایی و تخمین پارامترهای شبکه قابل اعمال است. پارامترهای مؤخره پارامترهای خطی شبکه هستند که به روش تخمین زده می‌شوند. پارامترهای مقدمه نیز به روش کاهش گرادیان تنظیم می‌شود.

الگوریتم هایبرید به صورت مستقیم برای شناسایی و تخمین پارامترهای شبکه قابل اعمال است. پارامترهای مؤخره قوانین همان پارامترهای خطی شبکه هستند که به روش LSE تخمین زده می‌شوند. پارامترهای مقدمه نیز به روش کاهش گرادیان تنظیم می‌شود.



شکل ۱- ساختار شبکه ANFIS با پنج لایه (جانگ^۱ ۱۹۹۳)

الگوریتم بهینه‌سازی مبتنی بر رفتار اجزای جمعی (PSO)


الگوریتم بهینه‌سازی مبتنی بر رفتار اجزای جمعی (PSO)، اولین بار در سال ۱۹۹۵ توسط کندی و ابرهارت مطرح شد و به سرعت به عنوان یک ابزار بهینه‌سازی قدرتمند مورد توجه قرار گرفت. به منظور تشریح بهتر روش بهینه‌سازی PSO فرض کنید شما و دوستانتان به دنبال گنج می‌گردید. هر یک از اعضای گروه یک فلزیاب و یک بی‌سیم دارد که می‌تواند مکان و وضعیت خود را به همسایگان خود اطلاع دهد. بنابراین شما می‌دانید کدام یک از همسایگان شما به گنج نزدیکتر است و با حرکت به سمت او شانس شما برای رسیدن به گنج بیشتر از زمانی می‌شود که تنها باشید.

در الگوریتم PSO، می‌توان هر پاسخ را به صورت پرنده‌ای در دسته‌ای از پرندگان تصور نمود، که به آن جزء می‌گویند. در چنین ساختاری پرندگان علاوه بر هوش فردی، دارای نوعی رفتار گروهی نیز می‌باشند که آنان را به سمت هدف راهنمایی می‌کند. ابتدا، فرآیند از یک دسته از اجزا، که هر کدام یک پاسخ^۱ برای مسئله می‌باشند و به صورت

^۱ Jang

^۱مجموعه مقادیری که به مجموعه متغیرهای تصمیم نسبت داده شده است.

تصادفی انتخاب شده‌اند، آغاز می‌شود. در ادامه با حرکت دسته‌ای از اجزاء، فضای جستجو در جهت یافتن بهترین پاسخ جستجو می‌شود. در این الگوریتم هر جزء دارای یک سرعت انطباقی است که بیانگر بردار حرکت جزء در فضای جستجو می‌باشد. علاوه بر آن دارای حافظه نیز می‌باشد، یعنی بهترین موقعیتی را که تا آن مرحله به آن رسیده است، را به خاطر می‌سپارد. در الگوریتم اولیه PSO که به PSO استاندارد معروف است، حرکت هر جزء تنها در دو جهت، یکی به سوی بهترین موقعیتی که تا کنون ملاقات کرده و دیگری به سوی موقعیتی که بهترین جزء در کل جمعیت آن را ملاقات کرده است، صورت می‌گیرد.



شکل ۲- نمایش همسایگی محلی (همسایگی دایره‌ای) برای جزء ۱ و جزء ۸

بعدها انواع دیگری از الگوریتم PSO معرفی شدند که در آن‌ها هر جزء علاوه بر دو جهت قبلی به سمت بهترین موقعیت در همسایگی محلی^۱ خود نیز حرکت می‌کند. همسایگی محلی انواع مختلفی دارد. شکل ۴-۱ یک نوع همسایگی محلی به نام همسایگی دایره‌ای را نشان می‌دهد.

منطقه مطالعاتی

استان کهگیلویه و بویراحمد در جنوب غربی ایران بین عرض‌های ۳۰°:۰۹' تا ۳۱°:۳۲' شمالی و ۴۹°:۵۷' تا ۴۲°:۵۱' شرقی واقع گردیده است. این استان از شمال به استان چهارمحال و بختیاری، از جنوب به استان‌های فارس و بوشهر، از غرب به استان خوزستان و از شرق به استان‌های اصفهان و فارس محدود می‌گردد. وسعت این استان ۱۶۲۶۴ کیلومترمربع است. بلندترین نقطه استان قله دنا به ارتفاع ۴۴۰۹ متر و پست‌ترین نقطه آن چرهن با ارتفاع ۱۹۷ متر از سطح دریا است. روی هم‌رفته شرایط جغرافیایی و طبیعی منطقه به‌گونه‌ای است که هر چه از نواحی شمال و شمال شرق به سوی جنوب و جنوب غرب نزدیکتر شوید، از ارتفاع کوه‌ها کاسته شده و به همین نسبت میزان بارندگی نیز کاهش می‌یابد و متقابلاً بر درجه حرارت و خشکی هوا افزوده می‌شود. با توجه به شرایط جغرافیایی استان، مناطق واقع شده در امتداد رشته‌کوه‌های زاگرس، دارای زمستان سرد و پرباران بوده و در تابستان دارای آب‌وهوای نسبتاً معتدل می‌باشد. میزان متوسط بارندگی در این مناطق حدود ۸۵۰ میلی‌متر در سال است. مناطق جنوب و جنوب

^۱ Local Neighborhood

غربی استان از میزان بارش کمتری برخوردار بوده و به همین دلیل دارای آب و هوایی گرم و خشک می‌باشد.

نتایج مدل‌سازی، تجزیه و تحلیل

به منظور مدل‌سازی سری زمانی SPI، با استفاده از نرم افزار DIP، داده‌های بارندگی را به SPI تبدیل کردیم که به عنوان متغیر ورودی در مدل شبکه عصبی - فازی تطبیقی مورد استفاده قرار گرفت. در این پژوهش برای مدل‌سازی خشکسالی از داده‌های ماهانه استفاده گردید. برای دستیابی به نتایج حاصله از روش شبکه عصبی- فازی تطبیقی برای مدل‌سازی خشکسالی با دوره ماهانه، برنامه‌ای به زبان Matlab نوشته شد. برای ارزیابی و مقایسه عملکرد مدل‌ها در پیش‌بینی نتایج از آماره‌های ضریب تبیین (DC) و جذر میانگین مربع خطاها (RMSE) به شرح روابط ذیل استفاده گردید.

$$DC = 1 - \frac{\sum_{i=1}^n (SPI_i - SPI_i)^2}{\sum_{i=1}^n (\bar{SPI}_i - \bar{SPI}_i)^2} \quad (16)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SPI_i - \bar{SPI}_i)^2}{n}} \quad (17)$$

هر اندازه که نمایه DC به عدد یک نزدیکتر و مقدار RMSE کمتر باشد نشانگر از دقت بالای روش است. ابتدا به منظور بررسی تأثیر فازی سازی داده‌ها و استفاده از روش‌های بهینه‌سازی، از روش شبکه عصبی مصنوعی استفاده شده است بدین منظور آرایش‌های مختلفی با تعداد نرون‌های ورودی (q) و تعداد نرون‌های لایه میانی (m) مورد آزمایش قرار گرفت (q,m,1). لذا چهار نوع ساختار ورودی‌های مختلف برای حالت‌هایی که به تعداد 2، 3، 4 و 5 وابستگی در شبکه وجود دارد با تعداد 1 تا 30 نرون برای لایه میانی مورد آموزش قرار گرفت. نتایج مربوط به استفاده از شبکه‌های مصنوعی با ساختارهای مختلف در جدول‌های (1) و (2) آورده شده است.

جدول 1- نتایج و آماره‌های مدل‌سازی نمایه SPI با روش شبکه عصبی مصنوعی

ساختار شبکه	متغیرهای ورودی به شبکه	ساختار بهینه شبکه	DC		RMSE	
			واسنجی	صحت سنجی	واسنجی	صحت سنجی
(2,m,1)	SPI _t , SPI _{t-1}	(2,15,1)	0/7	0/69	0/12	0/11
(3,m,1)	SPI _t , SPI _{t-1} , SPI _{t-2}	(3,8,1)	0/73	0/72	0/11	0/12
(4,m,1)	SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3}	(4,8,1)	0/76	0/68	0/10	0/13
(5,m,1)	SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3} , SPI _{t-4}	(5,5,1)	0/77	0/64	0/09	0/15

جدول 2- نتایج و آماره‌های مدل‌سازی نمایه EDI با روش شبکه عصبی مصنوعی

ساختار شبکه	متغیرهای ورودی به شبکه	ساختار بهینه شبکه	DC		RMSE	
			واسنجی	صحت سنجی	واسنجی	صحت سنجی
(2,m,1)	EDI _t , EDI _{t-1}	(2,6,1)	0/71	0/64	0/13	0/14
(3,m,1)	EDI _t , EDI _{t-1} , EDI _{t-2}	(3,9,1)	0/75	0/70	0/11	0/12

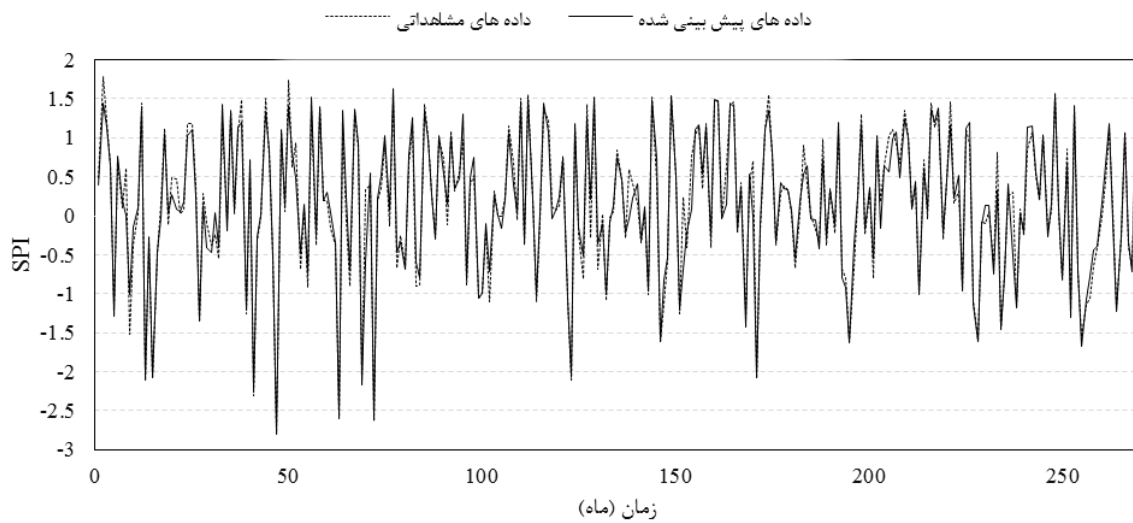
($\xi, m, 1$)	$EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}$	($\xi, 1, \xi, 1$)	0/71	0/70	0/12	0/11
($\theta, m, 1$)	$EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}, EDI_{t-4}$	($\theta, 9, 1$)	0/71	0/68	0/10	0/09

هما
نگو


نه که در جداول فوق نشان داده شده است به این دلیل تعداد وابستگی‌ها بیشتر در نظر گرفته نشده که در صورت افزایش وابستگی، گرچه دقت در مرحله صحت‌سنجی افزایش می‌یابد ولی در مرحله واسنجی تأثیری ندارد و حتی موجب کاهش دقت می‌گردد؛ بنابراین داشتن دید دو سویه به نتایج صحت‌سنجی و واسنجی یک اصل مهم در مدل‌سازی است. در بخش دوم این تحقیق برای در نظر گرفتن ماهیت فازی و عدم قطعیت‌های موجود در پدیده خشکسالی از شبکه عصبی-فازی تطبیقی و همچنین شبکه عصبی تطبیقی بهینه شده با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات جهت پیش‌بینی استفاده گردید. ابتدا از روش آنالیز حساسیت برای تنظیم پارامترهای شبکه عصبی-فازی به جهت انطباق بیشتر با داده‌های سری زمانی SPI یا EDI استفاده شد و از چهار سناریو با توابع عضویت گوسی، مثلثی و پیش‌فرض برنامه که جزء توابع پرکاربرد و مهم در سیستم‌های فازی هستند استفاده شد. برای بررسی تأثیر تعداد و شکل تابع عضویت هر یک از سناریوها به همراه سه نوع تابع عضویت مورد آزمون قرار گرفتند که نتایج آن برای کلیه حالت‌های مرحله صحت‌سنجی و واسنجی در جدول 3 و 4 آورده شده است. شکل‌های (3) تا (14) نیز به ترتیب مقایسه مقادیر محاسباتی و پیش‌بینی‌شده نمایه SPI و EDI با مدل‌های شبکه عصبی-فازی تطبیقی در مرحله واسنجی و صحت‌سنجی ارائه شده است.

جدول 3- بررسی تأثیر ورودی‌ها و شکل تابع عضویت نمایه SPI در مدل‌سازی

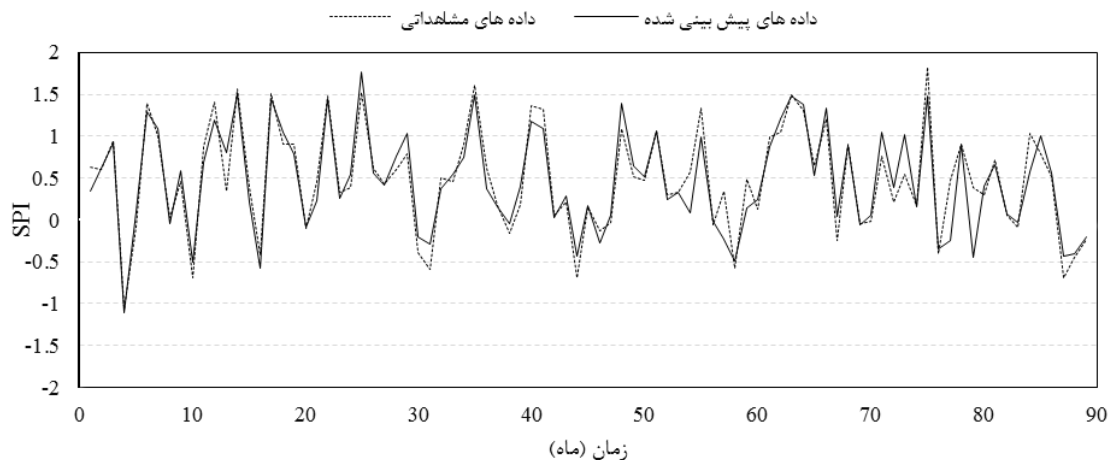
نوع تابع عضویت	ورودی مدل	ANFIS			
		DC		RMSE	
		واسنجی	صحت‌سنجی	واسنجی	صحت‌سنجی
trimf	Comb (1): SPI_t, SPI_{t-1}	0/91	0/82	0/05	0/08
trimf	Comb (2): $SPI_t, SPI_{t-1}, SPI_{t-2}$	0/95	0/85	0/04	0/07
trimf	Comb (3): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$	0/97	0/61	0/03	0/09
trimf	Comb (4): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, SPI_{t-4}$	0/97	0/30	0/03	0/15
gaumsf	Comb (1): SPI_t, SPI_{t-1}	0/92	0/87	0/05	0/06
gaumsf	Comb (2): $SPI_t, SPI_{t-1}, SPI_{t-2}$	0/94	0/87	0/04	0/05
gaumsf	Comb (3): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$	0/96	0/56	0/03	0/13
gaumsf	Comb (4): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, SPI_{t-4}$	0/98	0/33	0/02	0/13
define	Comb (1): SPI_t, SPI_{t-1}	0/88	0/86	0/06	0/08
define	Comb (2): $SPI_t, SPI_{t-1}, SPI_{t-2}$	0/93	0/86	0/04	0/05
define	Comb (3): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$	0/96	0/77	0/04	0/08
define	Comb (4): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, SPI_{t-4}$	0/96	0/67	0/03	0/1
gbellmf	Comb (1): SPI_t, SPI_{t-1}	0/92	0/85	0/05	0/06
gbellmf	Comb (2): $SPI_t, SPI_{t-1}, SPI_{t-2}$	0/95	0/86	0/04	0/05
gbellmf	Comb (3): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$	0/97	0/72	0/03	0/08
gbellmf	Comb (4): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, SPI_{t-4}$	0/97	0/63	0/03	0/1



شکل ۳- مقایسه مقادیر مشاهداتی و پیش‌بینی‌شده SPI با استفاده از شبکه عصبی- فازی تطبیقی در مرحله واسنجی



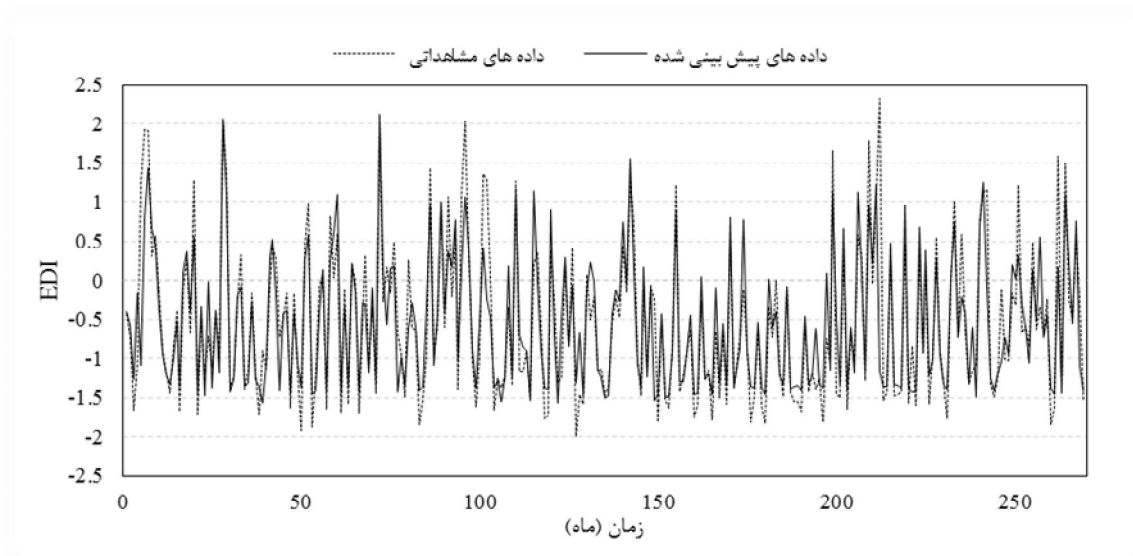
شکل ۴- مقایسه مقادیر SPI پیش‌بینی‌شده با شبکه عصبی- فازی تطبیقی با مقادیر محاسباتی در مرحله صحت سنجی




شکل ۵- مقایسه مقادیر مشاهداتی و پیش‌بینی‌شده SPI با استفاده از شبکه عصبی- فازی تطبیقی در مرحله صحت‌سنجی

جدول ۴- بررسی تأثیر ورودی‌ها و شکل تابع عضویت نمایه EDI در مدل‌سازی ANFIS


نوع تابع عضویت	ورودی مدل	DC		RMSE	
		و اسنجی	صحت سنجی	و اسنجی	صحت سنجی
trimf	Comb (۱): EDI_t, EDI_{t-1}	۰/۷۱	۰/۷۰	۰/۱۱	۰/۱۲
trimf	Comb (۲): $EDI_t, EDI_{t-1}, EDI_{t-2}$	۰/۷۶	۰/۶۹	۰/۱۰	۰/۱۲
trimf	Comb (۳): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}$	۰/۷۷	۰/۶۲	۰/۱۰	۰/۱۳
trimf	Comb (۴): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}, EDI_{t-4}$	۰/۸۳	۰/۳۸	۰/۰۹	۰/۱۵
gaumssf	Comb (۱): EDI_t, EDI_{t-1}	۰/۷۵	۰/۵۹	۰/۱	۰/۱۴
gaumssf	Comb (۲): $EDI_t, EDI_{t-1}, EDI_{t-2}$	۰/۷۷	۰/۷۰	۰/۱	۰/۱۱
gaumssf	Comb (۳): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}$	۰/۷۹	۰/۵۰	۰/۱	۰/۱۵
gaumssf	Comb (۴): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}, EDI_{t-4}$	۰/۷۹	۰/۳۲	۰/۱	۰/۱۷
define	Comb (۱): EDI_t, EDI_{t-1}	۰/۷۳	۰/۶۷	۰/۱۱	۰/۱۲
define	Comb (۲): $EDI_t, EDI_{t-1}, EDI_{t-2}$	۰/۷۶	۰/۶۹	۰/۱۰	۰/۱۲
define	Comb (۳): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}$	۰/۷۹	۰/۵۴	۰/۱	۰/۱۴
define	Comb (۴): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}, EDI_{t-4}$	۰/۸۴	۰/۳۰	۰/۰۸	۰/۱۹
gbellmf	Comb (۱): EDI_t, EDI_{t-1}	۰/۷۲	۰/۷۱	۰/۱۱	۰/۱۰
gbellmf	Comb (۲): $EDI_t, EDI_{t-1}, EDI_{t-2}$	۰/۷۵	۰/۷۱	۰/۱۰	۰/۱۱
gbellmf	Comb (۳): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}$	۰/۷۹	۰/۵۴	۰/۰۹	۰/۱۴
gbellmf	Comb (۴): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}, EDI_{t-4}$	۰/۸۴	۰/۳۹	۰/۰۸	۰/۱۶



شکل ۶- مقایسه مقادیر مشاهده‌ای و پیش‌بینی‌شده EDI با استفاده از شبکه عصبی- فازی تطبیقی در مرحله واسنجی



شکل ۷- مقایسه مقادیر EDI پیش‌بینی‌شده با شبکه عصبی- فازی تطبیقی با مقادیر محاسباتی در مرحله صحت سنجی



شکل ۸- مقایسه مقادیر مشاهداتی و پیش‌بینی‌شده EDI با استفاده از شبکه عصبی- فازی تطبیقی در مرحله صحت سنجی

نتایج بیانگر دقت بالای نمایه SPI نسبت به نمایه EDI می‌باشد و همچنین سناریو شماره ۲ به همراه تابع زنگوله‌ای نسبت به سایر سناریوها دارای ضریب تبیین بیشتری می‌باشد.

در ادامه، برای استفاده از PSO در مدل ANFIS از تابع $genfis_2$ استفاده گردید. تابع $genfis_2$ از تابع $subclust$ برای ایجاد یک سیستم استنتاج فازی سوگنو با استفاده از مجموعه داده‌های آموزشی ورودی/خروجی استفاده می‌کند. همچنین پارامترهای بهینه PSO برای دستیابی به پارامترها طبق جدول ۵ انتخاب گردید.

جدول ۵- پارامترهای الگوریتم بهینه‌سازی ازدحام ذرات

پارامترها	
۲۰۰	تعداد ذرات
۵۰۰	تعداد تکرارها
۱	C ₁
۲	C ₂
۱	w
۰٫۹۹	نسبت میرایی وزن اینرسی

نتایج برای چهار سناریوی بالا برای ورودی‌های SPI و EDI در جداول زیر آمده است.

جدول ۶- نتایج و آماره‌های مدل‌سازی نمایه SPI با روش شبکه عصبی- فازی تطبیقی بهینه شده


ورودی مدل	DC		RMSE	
	و اسنجی	صحت سنجی	و اسنجی	صحت سنجی
Comb (۱): SPI_t, SPI_{t-1}	۰/۸۸	۰/۸۷	۰/۰۶	۰/۰۶
Comb (۲): $SPI_t, SPI_{t-1}, SPI_{t-2}$	۰/۹۷	۰/۸۶	۰/۰۴	۰/۰۵
Comb (۳): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$	۰/۹۶	۰/۷۷	۰/۰۵	۰/۰۸
Comb (۴): $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, SPI_{t-4}$	۰/۹۶	۰/۶۶	۰/۰۳	۰/۱
$SPI_{t-1}, Moisture, temp, evaporation$	۰/۷۹	۰/۷۱	۰/۰۸	۰/۰۹

جدول ۷- نتایج و آماره‌های مدل‌سازی نمایه EDI با روش شبکه عصبی- فازی تطبیقی بهینه شده


ورودی مدل	DC		RMSE	
	و اسنجی	صحت سنجی	و اسنجی	صحت سنجی
Comb (۱): EDI_t, EDI_{t-1}	۰/۷۳	۰/۷۰	۰/۱۱	۰/۱۲

Comb (۲): $EDI_t, EDI_{t-1}, EDI_{t-2}$	۰/۷۷	۰/۷۲	۰/۱۰	۰/۱۱
Comb (۳): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}$	۰/۷۸	۰/۵۳	۰/۱۲	۰/۱۴
Comb (۴): $EDI_t, EDI_{t-1}, EDI_{t-2}, EDI_{t-3}, EDI_{t-4}$	۰/۸۴	۰/۳۰	۰/۰۸	۰/۱۹
$EDI_{t-1}, Moisture, Temp, Evaporation$	۰/۸۹	۰/۶۶	۰/۰۷	۰/۱۲


نتایج بیانگر دقت نمایه SPI نسبت به نمایه EDI می‌باشد و سناریوی شماره ۲ نسبت به سایر سناریوها ضریب تبیین بیشتری دارد؛ و همچنین مشخص است که بهینه‌سازی پارامترهای ANFIS موجب افزایش دقت مدل شده است.



شکل ۹- مقایسه مقادیر مشاهداتی و پیش‌بینی‌شده SPI با استفاده از شبکه عصبی- فازی تطبیقی بهینه‌شده در مرحله واسنجی



شکل ۱۰- مقایسه مقادیر SPI پیش‌بینی‌شده با شبکه عصبی- فازی تطبیقی بهینه شده با مقادیر محاسباتی در مرحله صحت سنجی



شکل ۱۱- مقایسه مقادیر مشاهداتی و پیش‌بینی‌شده SPI با استفاده از شبکه عصبی- فازی تطبیقی بهینه‌شده کاهش در مرحله صحت سنجی

نهایتاً برای مقایسه نتایج به دست آمده از روش‌های مدل‌سازی سری زمانی خشکسالی ارائه شده در این تحقیق، نتایج بهترین ساختار برای هر یک از روش‌های مذکور در جدول (۸) و (۹) آورده شده است که از مقایسه اعداد جدول می‌توان نتیجه گرفت که روش عصبی- فازی بهینه شده می‌تواند به عنوان یک ابزار مناسب برای پیش‌بینی این پدیده به کار گرفته شود و همچنین نمایه SPI نتایج بهتری نسبت به نمایه EDI گزارش کرده است.

جدول ۸- ارزیابی مدل‌های مختلف در مدل‌سازی خشکسالی با نمایه SPI

RMSE		DC		روش مدل‌سازی
صحت سنجی	واسنجی	صحت سنجی	واسنجی	
۰/۱۲	۰/۱۱	۰/۷۲	۰/۷۳	شبکه عصبی- مصنوعی
۰/۰۵	۰/۰۴	۰/۸۶	۰/۹۵	شبکه عصبی- فازی تطبیقی
۰/۰۵	۰/۰۴	۰/۸۶	۰/۹۷	شبکه عصبی- فازی تطبیقی با خوشه‌بندی کاهش

جدول ۹- ارزیابی مدل‌های مختلف در مدل‌سازی خشکسالی با نمایه EDI

RMSE		DC		روش مدل‌سازی
صحت سنجی	واسنجی	صحت سنجی	واسنجی	
۰/۱۲	۰/۱۱	۰/۷۰	۰/۷۵	شبکه عصبی- مصنوعی
۰/۱۱	۰/۱	۰/۷۱	۰/۷۵	شبکه عصبی- فازی تطبیقی
۰/۱۱	۰/۱	۰/۷۰	۰/۷۷	شبکه عصبی- فازی تطبیقی بهینه‌شده

نتیجه‌گیری

استفاده از الگوریتم‌های بهینه‌سازی فراکاوشی جهت تنظیم مقادیر شبکه عصبی- فازی یک ایده نو برای به وجود آمدن مدلی قدرتمند است. در این مطالعه از شاخص‌های SPI و EDI که نسبت به سایر شاخص‌های موجود از شرایط بهتری برخوردار است به عنوان متغیرهای ورودی به شبکه عصبی- فازی و عصبی- فازی بهینه‌شده استفاده گردید که نتایج حاصل از مدل‌سازی حاکی از آن است که بهره‌گیری از شبکه عصبی- فازی بهینه‌سازی شده با الگوریتم توانمند اجتماع ذرات به خوبی توانسته الگوی سری زمانی داده‌ها را تشخیص داده و به نتایج دقیق منجر

گردد. همچنین مقادیر ضرایب واسنجی و صحت سنجی به ترتیب برابر ۰/۹۷ و ۰/۸۶ برای بهترین مدل شبکه عصبی - فازی بهینه شده می باشد.

منابع

سهرابی، ر. ا. سهرابی، ح. عرب، د. ر (۱۳۸۷). "بررسی شاخص‌های پایش خشکسالی از مناظر تحول، ماهیت و عملکرد و پیشنهاد فرآیند انتخاب شاخص متناسب با شرایط مناطق"، مجموعه مقالات سومین کنفرانس مدیریت منابع آب، دانشکده مهندسی عمران تبریز، ایران.

حجازی زاده، ز. جوی زاده، س (۱۳۸۹). مقدمه ای بر خشکسالی و شاخص های آن، تهران: انتشارات سمت.

سلحشور دستگردی، م (۱۳۹۱). "تحلیل فراوانی منطقه ای خشکسالی هیدرولوژیک با استفاده از شاخص خشکسالی جریان سطحی: مطالعه موردی حوزه کارون شمالی"، پایان نامه کارشناسی ارشد مهندسی بیابان زدایی، دانشکده منابع طبیعی، دانشگاه صنعتی اصفهان.

بذرافشان، ج. و همکاران. (۱۳۹۴). " ارزیابی نمایه های خشکسالی کمبود توام تحت شرایط اقلیمی ایران"، نشریه حفاظت منابع آب و خاک، سال چهارم، شماره سوم، ۶۳-۵۳.

جمشیدی، ح.، خلیلی، د.، کامگار، ع. ۱۳۸۸. بررسی و مقایسه نمایه های خشکسالی SPI و RDI در ایستگاه های منتخب سینوپتیک کشور، دومین همایش ملی اثرات خشکسالی و راهکارهای مدیریت آن، اصفهان، مرکز تحقیقات کشاورزی و منابع طبیعی اصفهان، http://www.civilica.com/Paper-NSDEM۰۲-NSDEM۰۲_۰۲۳.html

یزدانی، م.، رفیعیانی، ا.، رحیمی، م. ۱۳۹۱. بررسی و تحلیل خشکسالی هواشناسی در استان اصفهان بر اساس نمایه های آماری، اولین همایش بیابان تهران.

محمدیان، آ.، و همکاران ۱۳۸۹. مقایسه پایش خشکسالی با استفاده از شاخص های SPI، DI و PNI و پهنه بندی آنها در استان خراسان شمالی. پژوهش های حفاظت آب و خاک (علوم کشاورزی و منابع طبیعی)، دوره ۱۷، شماره ۱، ۱۸۴-۱۷۷.

کماسی، م.، اعلمی، م.، نورانی، و. ۱۳۹۲. پیش بینی خشکسالی با نمایه SPI به روش مدلسازی ANFIS فصلنامه علمی- پژوهشی آب و فاضلاب، دوره ۲۴، شماره چهارم، ۱۰۲-۹۰.

ابراهیم پور، ا.، قادری، س. ج. ۱۳۹۳. کاربرد روشهای هوش مصنوعی در پیش بینی خشکسالی بر اساس شاخص SPI. پانزدهمین کنفرانس دانشجویان عمران سراسر کشور.

Antakli, S., Sarkis, N., & Hajar, A. A. (۲۰۱۳). Determination of Cd, Pb and Ni in Syrian cow milk by graphite furnace atomic absorption spectrometry. *Asian Journal of Chemistry*, ۲۵(۲): ۱۰۶۳.

Bacanli, U.G., M. Firat, and F. Dikbas. ۲۰۰۹. Adaptive neuro-fuzzy inference system for drought forecasting. *Stochastic Environmental Research and Risk Assessment*, ۲۳(۸): ۱۱۴۳-۱۱۵۴.

Jang, J. S.R. ۱۹۹۳. ANFIS: Adaptive network based fuzzy inference system. *IEEE Transactions on Systems, Man and Cybernetics*, ۲۳(۳): ۶۶۵-۶۸۳.

McKee, T.B., Doesken, N.J., Kleist, J. ۱۹۹۳. The Relationship of Drought Frequency and Duration to Time Scales. *In Proc. ۸th Conf. on Applied Climatology*, ۱۷-۲۲ Jan, ۱۹۹۳. American Meteorological Society, Massachusetts. ۱۷۹-۱۸۴.

Mishra, A. K. Singh, V. P. (۲۰۱۰) " A review of drought concepts ". *Journal of Hydrology*, pp. ۲۰۲-۲۱۶.

Smakhtin, V.U. and Hughes, D.A. ۲۰۰۴. Review, Automated Estimation and Analyses of Drought Indices in South Asia. *IWMI Working Paper N ۸۳ - Drought Series Paper N ۱*. IWMI: Colombo, ۲۴

Wilhite, D. A. Hayes, M. J. & Svodoba, M. D. (۲۰۰۰). " Drought monitoring and assessment in the US In: Voght JV, Somma F (eds) Drought and drought mitigation in Europe. Kluwers, Dordrecht " .

