

پیش‌بینی خشکسالی با نمایه‌های SPI و EDI به روش مدل‌سازی ANFIS بر مبنای خوشه‌بندی C-Mean و SC (مطالعه موردی: استان کهگیلویه و بویراحمد)

مهدی کماسی^۱، مهدی ملک‌محمودی^۲، حسین منتصری^{۳*}

تاریخ دریافت: ۱۳۹۵/۰۳/۰۵

تاریخ پذیرش: ۱۳۹۶/۰۵/۳۰

چکیده

خشکسالی از جمله اصلی‌ترین و قدیمی‌ترین بلای طبیعی است که اثرات زیست محیطی مهمی را به دنبال دارد. استان کهگیلویه و بویراحمد علیرغم آنکه از لحاظ میزان بارش مقام سوم را در سطح کشور دارا می‌باشد، اما خشکسالی‌ها به‌طور متناوب این استان را تحت تأثیر قرار داده و خسارات بسیار سنگینی را به دنبال دارند. یافتن نمایه‌های اندازه‌گیری خشکسالی برای پیش‌بینی و ارزیابی مکانی و زمانی این پدیده به‌منظور مدیریت بحران آن ضروری و حیاتی به نظر می‌رسد. در این پژوهش با استفاده از مبنای شبکه‌های عصبی مصنوعی (ANN) و مدل عصبی فازی تطبیقی (ANFIS) به همراه آنالیز خوشه‌بندی فازی برای پیش‌بینی خشکسالی با نمایه بارش استاندارد (SPI) و نمایه خشکسالی مؤثر (EDI) استفاده گردیده است. نتایج به دست آمده از پژوهش بیانگر آن است که نمایه SPI با ضریب صحت‌سنجی ۰/۸۷ نسبت به نمایه EDI با ضریب صحت‌سنجی ۰/۷۳ قابلیت و دقت بیشتری در پیش‌بینی خشکسالی دارد و از طرف دیگر راهبرد شبکه عصبی- فازی تطبیقی بر مبنای روش خوشه‌بندی تکراری (C-Mean) و کاهش (SC) در امر مدل‌سازی برای پیش‌بینی خشکسالی از کارایی بالایی برخوردار است. نتایج نشان می‌دهد که خوشه‌بندی باعث افزایش دقت مدل‌سازی در مرحله صحت‌سنجی و واسنجی شده است. همچنین خوشه‌بندی تکراری با ضریب واسنجی ۰/۹۳ و ضریب صحت‌سنجی ۰/۸۷ بهترین مدل می‌باشد.

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

مقدمه

این پدیده مطرح نگردیده است. مطالعات نشان می‌دهد که تا اوایل دهه ۱۹۸۰ بیش از ۱۵۰ نوع تعریف از خشکسالی در جهان ارائه گردیده است. دلیل وجود این تنوع معنایی آن است که کاربران و محققان رشته‌های گوناگون از دیدگاه خود به این پدیده نگرسته‌اند. 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 توأم 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^۴ (RDI) و بارش

خشکسالی یکی از پدیده‌های محیطی و بخش جدایی‌ناپذیر تغییرات اقلیمی می‌باشد. این پدیده در واقع از ویژگی‌های اصلی و تکرارشونده اقلیم‌های مختلف به شمار می‌آید. خشکسالی ممکن است در هر جایی رخ دهد و باعث کمبود آب گردد اما ویژگی‌های آن از قبیل شدت، مدت و بزرگی خشکسالی از محلی به محل دیگر متفاوت می‌باشد. به دلیل اینکه عوامل مختلفی به‌طور مستقیم و غیرمستقیم در وقوع خشکسالی مؤثرند تعریف واژه خشکسالی مشکل است و به همین جهت تاکنون تعریف جامع و کاملی از

^۱ استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه آیت الله العظمی بروجردی (ره)، بروجرد، خرم آباد
^۲ دانشجوی کارشناسی ارشد مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه یاسوج
^۳ استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه یاسوج

(*نویسنده مسئول: hmontaseri@gmail.com)

^۴ Reclamation Drought Index

همکاران (۱۳۹۲) به مطالعه پیش‌بینی خشکسالی با نمایه SPI به روش مدل‌سازی ANFIS^۴ پرداختند. نتایج نشان داد که SPI قابلیت بیشتری نسبت به سایر نمایه‌ها دارد و شبکه عصبی- فازی تطبیقی در امر مدل‌سازی برای پیش‌بینی خشکسالی از کارایی بالایی برخوردار است. ابراهیم پور و قادری (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. چوپین و همکاران (۲۰۱۴) در مطالعه‌ای به منظور پیش‌بینی خشکسالی در حوضه مهارلو بختگان از مدل عصبی فازی استفاده کردند که نتایج حاکی از برتری این مدل نسبت به مدل رگرسیونی است. دهقانی و همکاران (۲۰۱۴) به بررسی عدم قطعیت پیش‌بینی خشکسالی به وسیله شبکه عصبی مصنوعی و مدل شبیه سازی مونت کارلو پرداختند. نتایج نشان داد که شبکه عصبی مصنوعی به طور قابل توجهی بهتر از مدل مونت کارلو عمل کرده است. باکانلی و همکاران^۵ (۲۰۰۹) از مدل ANFIS به منظور پیش‌بینی خشکسالی در کشور ترکیه استفاده نمودند. همچنین در این پژوهش از مدل ANFIS جهت پیش‌بینی خشکسالی استفاده گردیده است که نتایج به دست آمده بیانگر دقت مناسب مدل ANFIS می‌باشد. مدل‌های پیش‌بینی مختلفی برای SPI با مقیاس‌های زمانی ۱، ۳، ۶، ۹ و 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. موریرا^۶ (۲۰۱۶) به بررسی شاخص SPI شش ماهه و دوازده ماهه با استفاده از مدل لگاریتم خطی پرداخت، در واقع می‌توان گفت که این مدل یک مدل‌سازی نیمه خطی می‌باشد در صورتی که شبکه‌های عصبی همانند مدل شبکه عصبی فازی تطبیقی

استاندارد^۱ (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 - تعرق پتانسیل سبب نوساناتی در نمایه RDI می‌گردد. آن‌ها همچنین نشان دادند که در طبقه خشکسالی شدید به‌علت مقادیر بارندگی کم و تبخیر - 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 در 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. نمایه خشکسالی مؤثر (EDI)^۲ می‌تواند برای بازبینی خشکسالی مناطق بزرگ به کار رود. ولی مشکل اصلی در فرم اولیه آن، استفاده از داده‌های روزانه بارندگی است که همواره موجود نمی‌باشد برای رفع این مشکل اسماختین و هوگر^۳ (۲۰۰۴) الگوریتم EDI را با حفظ اصول محاسبات آن تغییر دادند تا بتوانند با به‌کارگیری مقادیر بارندگی ماهانه، مقدار ماهانه EDI را محاسبه کنند. بنی‌مهد و خلیلی (۱۳۹۰) به بررسی و مقایسه شاخص‌های SPI و EDI در ایستگاه‌های منتخب استان مازندران پرداختند. نتایج نشان داد که این دو شاخص رفتار مشابهی دارند. همچنین با افزایش بازه زمانی تداوم خشکسالی بر اساس این دو شاخص افزایش و شدت خشکسالی کاهش می‌یابد. شیرمحمدی و همکاران (۲۰۱۳) از شبکه عصبی تطبیقی (ANFIS) برای مدل‌سازی و تجزیه و تحلیل سری زمانی شاخص‌های خشکسالی استفاده کردند، که این مقالات بر کارایی روش‌های بالا در مدل‌سازی رفتار غیر خطی سری زمانی شاخص‌های خشکسالی اذعان دارند. کماسی و

^۴ Adaptive Neuro-Fuzzy Inference System

^۵ Bacanlı et al.

^۶ Moreira

^۱ Standardized Precipitation Index

^۲ Effective Drought Index

^۳ Smakhtin and Hughes

توجه به حداقل طول دوره آماری برابر ۳۰ و پراکندگی مناسب ایستگاه‌ها در سطح استان ۱۱ ایستگاه یاسوج، دهدشت، سی سخت، دوگنبدان، بوطاری، کتا، شامختار، سپیدار، پاتاوه، بی‌بی حکیمه و بی‌بی جان آباد برای محاسبه شاخص‌ها انتخاب شد که مشخصات این ایستگاه‌ها در جدول ۱ نشان داده شده است.

جدول ۱- مشخصات ایستگاه‌های منتخب

ایستگاه	سال تأسیس	عرض جغرافیایی (N)	طول جغرافیایی (E)
یاسوج	۱۳۴۵	۳۰° ۴۰'	۵۱° ۳۵'
دهدشت	۱۳۶۰	۳۰° ۴۸'	۵۰° ۳۴'
سی سخت	۱۳۵۰	۳۰° ۵۱'	۵۱° ۲۷'
دوگنبدان	۱۳۳۹	۳۰° ۲۶'	۵۰° ۴۸'
بوطاری	۱۳۴۹	۳۰° ۵۲'	۵۱° ۲۰'
کتا	۱۳۵۵	۳۱° ۱۱'	۵۱° ۱۵'
شامختار	۱۳۵۰	۳۰° ۴۲'	۵۱° ۳۲'
سپیدار	۱۳۵۸	۳۰° ۳۶'	۵۱° ۲۲'
پاتاوه	۱۳۵۰	۳۰° ۵۷'	۵۱° ۱۶'
بی‌بی حکیمه	۱۳۷۹	۳۰° ۰۲'	۵۰° ۳۶'
بی‌بی جان آباد	۱۳۴۶	۳۰° ۱۵'	۵۰° ۴۵'

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 نام 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 به‌صورت 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 به‌عنوان 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

(ANFIS) در واقع یک مدل غیرخطی می‌باشد. در این راستا، اصفهانیان و همکاران (۲۰۱۷) در یک پژوهش جامع به ارزیابی شاخص‌های مختلف خشکسالی پرداختند. چوبین و همکاران^۱ (۲۰۱۶) دریافتند که امروزه استقبال نسبت به مدل‌های داده کاوی در پیش‌بینی پدیده پیچیده خشکسالی مورد توجه فرا گرفته است. در این راستا دثو و همکاران^۲ (۲۰۱۷) به ارزیابی خشکسالی با شاخص SPI توسط سه مدل ماشین بردار پشتیبان با حداقل مربعات (LSSVM) مدل درختی (M5Tree) و مدل مارس (MARS) پرداختند. بهره‌گیری از یک آنالیز پیش‌پردازشگر می‌تواند روند بهتری در فرایند مدلسازی به وجود آورد از این رو در این پژوهش از خوشه‌بندی فازی به روش C-mean و SC جهت آنالیز و مدلسازی با استفاده از روش ANFIS پرداخته شده است 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 به پیش‌بینی خشکسالی استان کهگیلویه و بویراحمد پرداخته شود و با استفاده از تکنیک خوشه‌بندی دقت مدل را تا حد بالایی افزایش داد.

مواد و روش‌ها

منطقه مطالعاتی

استان کهگیلویه و بویراحمد در جنوب غربی ایران بین عرض‌های $۳۰^{\circ} ۰۹'$ تا $۳۱^{\circ} ۳۲'$ شمالی و $۴۹^{\circ} ۵۷'$ تا $۵۱^{\circ} ۴۲'$ شرقی واقع گردیده است. 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. در مجموع شرایط جغرافیایی و طبیعی منطقه به‌گونه‌ای است که هر چه از نواحی شمال و شمال شرق به‌سوی جنوب و جنوب غرب نزدیک‌تر شوید، از ارتفاع کوه‌ها کاسته شده و به همین نسبت میزان بارندگی نیز کاهش می‌یابد و متقابلاً بر دما و خشکی هوا افزوده می‌شود. طولانی بودن دوره آماری و پراکنش مکانی ایستگاه‌ها دو معیار اساسی در انتخاب ایستگاه جهت تحلیل خشکسالی می‌باشد. همچنین با

^۱ Choubin et al.

^۲ Deo et al.

در راستای بهبود کارایی روش‌های پیشین خوشه‌بندی مطرح گشت. در این روش نحوه‌ی گروه‌بندی داده‌ها در فضای چندبعدی به تعداد معینی از خوشه‌های مختلف تشریح شده است. تابع FCM با شروع از یک حدس اولیه به‌عنوان مراکز خوشه‌ها کار خود را آغاز می‌کند. معمولاً این حدس اولیه نادرست بوده و مکان درست مراکز را مشخص نمی‌کند. سپس FCM هر یک از نقاط را با درجه‌ای از عضویت به هر یک از خوشه‌ها مربوط می‌سازد. با تکرار به‌روزرسانی مراکز خوشه‌ها و درجه عضویت هر یک از نقاط، به تدریج مراکز خوشه‌ها به مکان درست و واقعی خود در مجموعه داده‌ها انتقال پیدا می‌کنند. این به‌روز رسانی‌ها بر مبنای حداقل سازی تابع هدف انجام می‌شود. تابع هدف ارائه‌دهنده فاصله بین هر یک از نقاط تا مرکز خوشه، بر مبنای درجه عضویت آن هست.

خوشه‌بندی کاهشی^۳ (SC)

در این روش داده‌ها به گروه‌هایی دسته‌بندی می‌شوند. به‌طوری‌که داده‌های مشابه در یک گروه قرار می‌گیرند. در روش خوشه‌بندی کاهشی انتخاب تعداد خوشه‌ها به عهده سیستم هست. عملکرد خوشه‌بندی کاهشی در چند مرحله در زیر بیان شده است:

۱. یافتن داده‌ای که بیشترین پتانسیل اولین مرکز بودن را دارا باشد.


۲. جداسازی همه داده‌های مجاور اولین مرکز توسط شعاع مشخص شده به‌منظور تعیین خوشه و مرکز خوشه بعدی.

۳. تکرار مراحل بالا تا زمانی که همه داده‌ها در مراکز خوشه‌ها قرار گیرند.

شعاع خوشه را باید برای هر دسته از داده‌های ورودی و دسته داده خروجی در برنامه تعیین کرد و مقدار آن را می‌توان برای دسته‌های پارامترهای ورودی و دسته پارامتر خروجی یکسان فرض کرد و یا به هر دسته، از بازه (۰-۱) عددی نسبت داد که معمولاً مقادیر میانی به علت بازدهی بهتر انتخاب می‌شود. هر نقطه مانند x_i می‌تواند برای مرکز خوشه کاندید شود. تابع چگالی برای نقطه x_i به صورت معادله ۱ تعریف می‌شود (توافان و همکاران^۴، ۲۰۱۲).

$$D_i = \sum_{j=1}^n \exp\left(-\frac{\|x_i - x_j\|^2}{\left(\frac{r_a}{2}\right)^2}\right) \quad (1)$$

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 به‌عنوان خروجی شبکه تحویل می‌دهد. الگوریتم هیبرید به‌صورت 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 هیبرید به‌صورت 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)

خوشه‌بندی فازی

خوشه‌بندی داده‌های عددی، پایه و اساس بسیاری از الگوریتم‌های طبقه‌بندی و مدل‌سازی سیستم‌ها می‌باشد. هدف از خوشه‌بندی، گروه‌بندی مجموعه داده‌های بسیار بزرگ و فراهم آوردن یک نمایش ساده و مختصر از رفتار سیستم می‌باشد. جعبه‌ی ابزار منطق فازی، قابلیت یافتن کلاسترها در داده‌های آموزشی و ورودی-خروجی را در اختیار کاربر قرار می‌دهد. می‌توان از داده‌های کلاستر شده برای ایجاد یک سیستم استنتاج فازی نوع سوگنو با حداقل قواعد و حداکثر کارایی استفاده کرد.

خوشه‌بندی تکراری (C-Means)

خوشه‌بندی فازی تکراری یک تکنیک خوشه‌بندی است که در آن هر نقطه با درجه‌ی خاصی (که با توجه به امتیاز عضویت تعیین می‌شود) به یک کلاستر متعلق می‌باشد. این تکنیک اولین بار توسط جیم بزدک^۲ (۱۹۸۱)

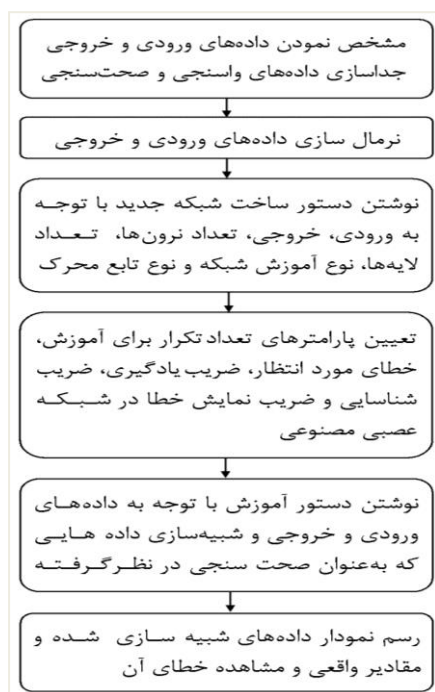
^۳Subtractive Clustering

^۴Tawafan et al.

^۱Jang

^۲Bezdek

گردید. برای تشخیص اینکه برای ارزیابی شدت خشکسالی در منطقه مورد مطالعه کدام شاخص بهتر عمل می‌کند، از یک فرضیه به‌عنوان سنج کارآمد برای پایش خشکسالی استفاده شد (خلیلی و بذرافشان، ۱۳۸۲). طبق این فرضیه در ابتدا کمینه مقادیر بارندگی در طول دوره مشترک آماری استخراج و توسط شاخص‌های خشکسالی ارزیابی شده است. نحوه وارد نمودن داده‌های ورودی و چگونگی نوشتن برنامه شبکه عصبی و عصبی-فازی در شکل ۲ نشان داده شده است.



شکل ۲- روندنمای تهیه کد برنامه شبکه عصبی و عصبی-فازی

نتایج و بحث

نتایج مدل‌سازی، تجزیه و تحلیل

با استفاده از آزمون سنج کارآمد شاخص SPI به عنوان مناسب‌ترین شاخص در ایستگاه‌های مورد مطالعه انتخاب گردید و همچنین شاخص EDI به دلیل شباهت در استانداردسازی و طبقه‌بندی به شاخص SPI مورد بررسی قرار گرفت. در گام نخست به‌منظور بررسی تأثیر فازی سازی داده‌ها از روش شبکه عصبی مصنوعی استفاده شده است. به این منظور آرایش‌های مختلفی از این شبکه که دارای ورودی‌های متفاوتی است به‌صورت کلی $(P, n, 1)$ مورد آزمایش قرار گرفت که در این ساختار P تعداد ورودی‌های شبکه (نرون‌های ورودی) و n تعداد نرون‌های لایه میانی است که به‌صورت متغیر می‌تواند انتخاب گردد.

که در این معادله، x_i نقاط همسایگی x_i و r_a مقدار مثبت دارد که درواقع radii انتخابی خوشه می‌باشد. از میان نقاط داده‌ها، نقطه‌ای که دارای نقاط بیشتری در همسایگی خود باشد، چگالی بالاتری خواهد داشت و به‌عنوان اولین مرکز خوشه انتخاب خواهد شد. اگر x_{C1} به‌عنوان اولین مرکز خوشه و چگالی آن R^2 باشد آنگاه تابع چگالی بعدی برای هر نقطه x_i به‌صورت معادله ۲ تعریف می‌شود.

$$D_i = D_i - D_{C1} \exp\left(-\frac{\|x_i - x_j\|}{\left(\frac{r_b}{2}\right)^2}\right) \quad (2)$$

که در این معادله r_b ثابت مثبت است که ۱/۵ برابر r_a است و دومین مرکز خوشه انتخاب می‌شود. این فرآیند تا زمانی ادامه دارد که تعداد کافی مراکز خوشه تولید شود (تاوفان و همکاران، ۲۰۱۲).

روش مدل‌سازی

در مدل‌سازی سری زمانی SPI، با استفاده از نرم‌افزار DIP، داده‌های بارندگی به SPI تبدیل شد و سپس از این داده‌ها به‌عنوان متغیر ورودی در روش شبکه عصبی - فازی تطبیقی استفاده گردید. در این پژوهش از دوره ماهانه برای مدل‌سازی خشکسالی 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. که این برنامه برای حالت‌های مختلف آرایش شبکه می‌تواند اجرا گردد. همچنین در این برنامه‌ها برای ارزیابی و مقایسه عملکرد مدل‌ها در پیش‌بینی نتایج از آماره‌های ضریب تبیین (R^2) و جذر میانگین مربع خطاها (RMSE) بر اساس معادلات ۳ و ۴ استفاده شد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (SPI_i - \widehat{SPI}_i)^2}{\sum_{i=1}^n (\widehat{SPI}_i - \overline{SPI}_i)^2} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SPI_i - \widehat{SPI}_i)^2}{n}} \quad (4)$$

که \widehat{SPI}_i ، \overline{SPI}_i و SPI_i به ترتیب داده‌های مشاهداتی، داده‌های محاسباتی، میانگین داده‌های مشاهداتی و تعداد داده‌ها می‌باشند. مشخص است که نزدیک بودن R^2 به عدد یک و کم بودن مقدار RMSE حاکی از دقت روش است.

ارزیابی شاخص‌های منتخب خشکسالی

به منظور بررسی انتخاب بهترین شاخص توصیف‌گر ابتدا محاسبات کلیه شاخص‌ها در مقیاس سالانه انجام

به این منظور چهار ساختار برای حالت‌هایی که به تعداد ۲، ۳، ۴ و ۵ وابستگی در شبکه وجود دارد با تعداد ۱ تا ۳۰ نرون برای لایه میانی مورد آموزش قرار گرفت که نتایج این ساختارها در جدول‌های ۲ و ۳ آورده شده است.

جدول ۲- نتایج و آماره‌های مدل‌سازی نمایه SPI با روش شبکه عصبی مصنوعی

RMSE		R ²		ساختار بهینه شبکه	متغیرهای ورودی به شبکه	ساختار شبکه
صحت سنجی	واسنجی	صحت سنجی	واسنجی			
۰/۱۱	۰/۱۲	۰/۶۹	۰/۷	(۲،۱۵،۱)	SPI _{t-1} , SPI _t	(۲،n،۱)
۰/۱۲	۰/۱۱	۰/۷۲	۰/۷۳	(۳، ۸،۱)	SPI _{t-2} , SPI _{t-1} , SPI _t	(۳،n،۱)
۰/۱۳	۰/۱۰	۰/۶۸	۰/۷۶	(۴،۸،۱)	SPI _{t-3} , SPI _{t-2} , SPI _{t-1} , SPI _t	(۴،n،۱)
۰/۱۵	۰/۰۹	۰/۶۴	۰/۷۷	(۵،۵،۱)	SPI _{t-4} , SPI _{t-3} , SPI _{t-2} , SPI _{t-1} , SPI _t	(۵،n،۱)

جدول ۳- نتایج و آماره‌های مدل‌سازی نمایه EDI با روش شبکه عصبی مصنوعی

RMSE		R ²		ساختار بهینه شبکه	متغیرهای ورودی به شبکه	ساختار شبکه
صحت سنجی	واسنجی	صحت سنجی	واسنجی			
۰/۱۴	۰/۱۳	۰/۶۴	۰/۷۱	(۲،۶،۱)	EDI _{t-1} , EDI _t	(۲،n،۱)
۰/۱۲	۰/۱۱	۰/۷۰	۰/۷۵	(۳،۹،۱)	EDI _{t-2} , EDI _{t-1} , EDI _t	(۳،n،۱)
۰/۱۱	۰/۱۲	۰/۷۰	۰/۷۱	(۴،۱۴،۱)	EDI _{t-3} , EDI _{t-2} , EDI _{t-1} , EDI _t	(۴،n،۱)
۰/۰۹	۰/۱۰	۰/۶۸	۰/۷۱	(۵،۹،۱)	EDI _{t-4} , EDI _{t-3} , EDI _{t-2} , EDI _{t-1} , EDI _t	(۵،n،۱)

نتایج حاصله در جدول ۴ آورده شده است. در گام دوم این پژوهش برای در نظر گرفتن ماهیت فازی و عدم قطعیت‌های موجود در پدیده خشکسالی از روش شبکه عصبی- فازی تطبیقی به‌عنوان مدل پیش‌بینی کننده استفاده گردید. در این میان یکی از نکات مهم و اساسی در مورد مدل عصبی - فازی تنظیم پارامترهای شبکه است بنابراین برای یافتن ساختاری مناسب که انطباق بهتری با داده‌های سری زمانی SPI یا EDI دارد می‌توان از آنالیز حساسیت استفاده نمود. به این معنی که ساختارهای متفاوتی از تعداد ورودی‌ها و تعداد و شکل تابع عضویت باید مورد بررسی قرار گیرد. برای این منظور چهار سناریوی زیر با توابع عضویت گوسی، مثلثی و پیش‌فرض برنامه که از توابع پرکاربرد و مهم در سیستم‌های فازی هستند در این پژوهش استفاده گردید.

همان‌طور که از جدول‌های ۲ و ۳ پیداست علت اینکه تعداد وابستگی‌ها بیشتر گرفته نشده این است که در صورت افزایش وابستگی، دقت در مرحله صحت‌سنجی افزایش یافته ولی در مرحله واسنجی تأثیر چندانی ندارد و حتی باعث کاهش دقت می‌گردد؛ بنابراین داشتن دید دو سویه به نتایج صحت‌سنجی و واسنجی یک اصل مهم در مدل‌سازی می‌باشد. در بخش دوم این گام برای بررسی متغیرهای مختلف برای پیش‌بینی خشکسالی از متغیرهای دما، رطوبت و نم نسبی نیز استفاده گردید. آرایش‌های مختلفی از این شبکه که دارای چهار ورودی است به‌صورت کلی (1، n، ۴) مورد آزمایش قرار گرفت که در این ساختار ۴ تعداد ورودی‌های شبکه (نرون‌های ورودی) شامل SPI یا EDI، نم نسبی، دما و رطوبت و n تعداد نرون‌های لایه میانی است که به‌صورت متغیر می‌تواند انتخاب گردد که

جدول ۴- نتایج و آماره‌های مدل‌سازی متغیرهای مختلف برای پیش‌بینی خشکسالی با روش شبکه عصبی مصنوعی

RMSE		R ²		ساختار بهینه شبکه	متغیرهای ورودی به شبکه	ساختار شبکه عصبی
صحت سنجی	واسنجی	صحت سنجی	واسنجی			
۰/۱۰	۰/۱۱	۰/۶۹	۰/۷۲	(۴،۶،۱)	Evaporation, Temp, Moisture, SPI _{t-1}	(۴،n،۱)
۰/۱۱	۰/۱۲	۰/۷۹	۰/۸۰	(۴،۱۲،۱)	Evaporation, Temp, Moisture, EDI _{t-1}	(۴،n،۱)

با مدل‌های شبکه عصبی- فازی تطبیقی بدون در نظر گرفتن خوشه‌بندی و بالحاظ کردن خوشه‌بندی در مرحله واسنجی و صحت‌سنجی ارائه شده است. در بخش دوم برای بررسی متغیرهای مختلف برای پیش‌بینی خشکسالی از متغیرهای دما، رطوبت و تبخیر نیز استفاده گردید که در جداول ۷ و ۸ پیداست که در این حالت تابع عضویت زنگوله‌ای


برای ارزیابی تأثیر تعداد و شکل تابع عضویت، هر سناریو به همراه سه نوع تابع عضویت مورد آزمایش قرار گرفت که نتایج آن برای هر یک از حالت‌ها به‌صورت ضریب تبیین مرحله صحت‌سنجی و واسنجی در جداول ۵ و ۶ آورده شده است. در شکل‌های ۳ تا ۱۰ به ترتیب مقایسه مقادیر محاسباتی و پیش‌بینی شده نمایه SPI و EDI

می‌توان در تعداد کم متغیرهای ورودی در امر مدل‌سازی دانست و دلیل افت سناریوی ۴ در قیاس با سناریوی ۲ را می‌توان در تعداد زیاد پارامترها و قوانین حاکم بر آن‌ها دانست؛ زیرا با فرض یک خطای کوچک برای هر یک از پارامترها در کل خطای مجموع عدد بزرگی را نتیجه می‌دهد.


(gbellmf) نتایج بهتری را ارائه داده است. نتایج نشان می‌دهد که نمایه SPI دقت بالاتری نسبت به نمایه EDI دارد و همچنین سناریوی ۲ و تابع زنگوله‌ای نسبت به سایر سناریوها ضریب تبیین بیشتری دارد. دلیل اینکه سناریوی ۱ دارای کارایی و دقت کمتری نسبت به سناریوی ۲ است را

جدول ۵- بررسی تأثیر ورودی‌ها و شکل تابع عضویت نمایه SPI در مدل‌سازی ANFIS

RMSE		R ²		ورودی مدل	نوع تابع عضویت
صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی		
۰/۰۸	۰/۰۵	۰/۸۲	۰/۹۱	Comb (1): SPI _t , SPI _{t-1}	trimf
۰/۰۷	۰/۰۴	۰/۸۵	۰/۹۵	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}	trimf
۰/۰۹	۰/۰۳	۰/۶۱	۰/۹۷	Comb (3): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3}	trimf
۰/۱۵	۰/۰۳	۰/۳۰	۰/۹۷	Comb (4): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3} , SPI _{t-4}	trimf
۰/۰۶	۰/۰۵	۰/۸۷	۰/۹۲	Comb (1): SPI _t , SPI _{t-1}	gaumf
۰/۰۵	۰/۰۴	۰/۸۷	۰/۹۴	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}	gaumf
۰/۱۳	۰/۰۳	۰/۵۶	۰/۹۶	Comb (3): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3}	gaumf
۰/۱۳	۰/۰۲	۰/۳۳	۰/۹۸	Comb (4): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3} , SPI _{t-4}	gaumf
۰/۰۸	۰/۰۶	۰/۸۶	۰/۸۸	Comb (1): SPI _t , SPI _{t-1}	define
۰/۰۵	۰/۰۴	۰/۸۶	۰/۹۳	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}	define
۰/۰۸	۰/۰۴	۰/۷۷	۰/۹۶	Comb (3): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3}	define
۰/۱	۰/۰۳	۰/۶۷	۰/۹۶	Comb (4): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3} , SPI _{t-4}	define
۰/۰۶	۰/۰۵	۰/۸۵	۰/۹۲	Comb (1): SPI _t , SPI _{t-1}	gbellmf
۰/۰۵	۰/۰۴	۰/۸۶	۰/۹۵	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}	gbellmf
۰/۰۸	۰/۰۳	۰/۷۲	۰/۹۷	Comb (3): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3}	gbellmf
۰/۱	۰/۰۳	۰/۶۳	۰/۹۷	Comb (4): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3} , SPI _{t-4}	gbellmf




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




شکل ۴- مقایسه مقادیر مشاهداتی و پیش‌بینی شده SPI با استفاده از شبکه عصبی - فازی تطبیقی در مرحله صحت‌سنجی

جدول ۶- بررسی تأثیر ورودی‌ها و شکل تابع عضویت نمایه EDI در مدل‌سازی ANFIS

RMSE		R ²		ورودی مدل	نوع تابع عضویت
صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی		
۰/۱۲	۰/۱۱	۰/۷۰	۰/۷۱	Comb (1): EDI _t , EDI _{t-1}	trimf
۰/۱۲	۰/۱۰	۰/۶۹	۰/۷۶	Comb (2): EDI _t , EDI _{t-1} , EDI _{t-2}	trimf
۰/۱۳	۰/۱۰	۰/۶۲	۰/۷۷	Comb (3): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3}	trimf
۰/۱۵	۰/۰۹	۰/۳۸	۰/۸۳	Comb (4): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3} , EDI _{t-4}	trimf
۰/۱۴	۰/۱	۰/۵۹	۰/۷۵	Comb (1): EDI _t , EDI _{t-1}	gausmf
۰/۱۱	۰/۱	۰/۷۰	۰/۷۷	Comb (2): EDI _t , EDI _{t-1} , EDI _{t-2}	gausmf
۰/۱۵	۰/۱	۰/۵۰	۰/۷۹	Comb (3): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3}	gausmf
۰/۱۷	۰/۱	۰/۳۲	۰/۷۹	Comb (4): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3} , EDI _{t-4}	gausmf
۰/۱۲	۰/۱۱	۰/۶۷	۰/۷۳	Comb (1): EDI _t , EDI _{t-1}	define
۰/۱۲	۰/۱۰	۰/۶۹	۰/۷۶	Comb (2): EDI _t , EDI _{t-1} , EDI _{t-2}	define
۰/۱۴	۰/۱	۰/۵۴	۰/۷۹	Comb (3): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3}	define
۰/۱۹	۰/۰۸	۰/۳۰	۰/۸۴	Comb (4): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3} , EDI _{t-4}	define
۰/۱۰	۰/۱۱	۰/۷۱	۰/۷۲	Comb (1): EDI _t , EDI _{t-1}	gbellmf
۰/۱۱	۰/۱۰	۰/۷۱	۰/۷۵	Comb (2): EDI _t , EDI _{t-1} , EDI _{t-2}	gbellmf
۰/۱۴	۰/۰۹	۰/۵۴	۰/۷۹	Comb (3): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3}	gbellmf
۰/۱۶	۰/۰۸	۰/۳۹	۰/۸۴	Comb (4): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3} , EDI _{t-4}	gbellmf



شکل ۵- مقایسه مقادیر مشاهده‌ای و پیش‌بینی شده EDI با استفاده از شبکه عصبی - فازی تطبیقی در مرحله واسنجی



شکل ۶- مقایسه مقادیر مشاهده‌ای و پیش‌بینی شده EDI با استفاده از شبکه عصبی - فازی تطبیقی در مرحله صحت‌سنجی

جدول ۷- نتایج و آماره‌های مدل‌سازی متغیرهای مختلف برای پیش‌بینی خشکسالی با روش شبکه عصبی - فازی تطبیقی

RMSE		R ²		ورودی مدل	نوع تابع عضویت
صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی		
۰/۱۱	۰/۰۸	۰/۶۳	۰/۸۲	SPI _{t-1} , Moisture, Temp, Evaporation	define
۰/۱۲	۰/۰۹	۰/۶۲	۰/۷۸	SPI _{t-1} , Moisture, Temp, Evaporation	trimf
۰/۱	۰/۰۸	۰/۶۴	۰/۸۰	SPI _{t-1} , Moisture, Temp, Evaporation	gausmf
۰/۱۱	۰/۰۷	۰/۶۶	۰/۸۲	SPI _{t-1} , Moisture, Temp, Evaporation	gbellmf

جدول ۸- نتایج و آماره‌های مدل‌سازی متغیرهای مختلف برای پیش‌بینی خشکسالی با روش شبکه عصبی- فازی تطبیقی

RMSE		R ²		ورودی مدل	نوع تابع عضویت
صحت سنجی	واسنجی	صحت سنجی	واسنجی		
۰/۱	۰/۰۹	۰/۷۳	۰/۸۷	EDI _{t-1} , Moisture, Temp, Evaporation	define
۰/۱۲	۰/۰۸	۰/۷۲	۰/۸۵	EDI _{t-1} , Moisture, Temp, Evaporation	trimf
۰/۱۱	۰/۰۷	۰/۷۶	۰/۸۶	EDI _{t-1} , Moisture, Temp, Evaporation	gausmf
۰/۰۹	۰/۰۶	۰/۸۱	۰/۸۷	EDI _{t-1} , Moisture, Temp, Evaporation	gbellmf

به ذکر است که ضریب R_d برداری است که محدوده مراکز خوشه‌ها را مشخص می‌کند. از طریق آزمون و خطا مقدار بهینه آن برابر با ۰/۳ در نظر گرفته می‌شود. نتایج برای چهار سناریوی بالا برای ورودی‌های EDI و SPI در جداول ۹ و ۱۰ آمده است.

در گام سوم این پژوهش برای پیاده‌سازی خوشه‌بندی کاهشی (SC) در مدل anfis از تابع genfis2 استفاده گردید. تابع genfis2 از تابع subclust برای ایجاد یک سیستم استنتاج فازی سوگنو با استفاده از مجموعه داده‌های آموزشی ورودی/ خروجی استفاده می‌کند. لازم

جدول ۹- نتایج و آماره‌های مدل‌سازی نمایه SPI با روش شبکه عصبی- فازی تطبیقی بر مبنای خوشه‌بندی کاهشی


RMSE		R ²		ورودی مدل
صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی	
۰/۰۶	۰/۰۶	۰/۸۷	۰/۸۸	Comb (1): SPI _t , SPI _{t-1}
۰/۰۵	۰/۰۴	۰/۸۶	۰/۹۳	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}
۰/۰۸	۰/۰۵	۰/۷۷	۰/۹۶	Comb (3): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3}
۰/۱	۰/۰۳	۰/۶۶	۰/۹۶	Comb (4): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3} , SPI _{t-4}
۰/۰۹	۰/۰۸	۰/۷۱	۰/۷۹	SPI _{t-1} , Moisture, temp, evaporation

جدول ۱۰- نتایج و آماره‌های مدل‌سازی نمایه EDI با روش شبکه عصبی- فازی تطبیقی بر مبنای خوشه‌بندی کاهشی


RMSE		R ²		ورودی مدل
صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی	
۰/۱۲	۰/۱۱	۰/۷۰	۰/۷۳	Comb (1): SPI _t , SPI _{t-1}
۰/۱۱	۰/۱۰	۰/۷۲	۰/۷۷	Comb (2): EDI _t , EDI _{t-1} , EDI _{t-2}
۰/۱۴	۰/۱۲	۰/۵۳	۰/۷۸	Comb (3): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3}
۰/۱۹	۰/۰۸	۰/۳۰	۰/۸۴	Comb (4): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3} , EDI _{t-4}
۰/۱۲	۰/۰۷	۰/۶۶	۰/۸۹	EDI _{t-1} , Moisture, Temp, Evaporation

شده است. در گام چهارم این پژوهش برای اجرای خوشه‌بندی تکراری در مدل ANFIS از تابع genfis3 استفاده گردید. تابع genfis3 یک FIS با استفاده از خوشه‌بندی تکراری به وسیله استخراج مجموعه‌ای از قوانینی که مدل رفتار کرده است را تولید می‌کند.

نتایج نشان می‌دهد که در خوشه‌بندی کاهشی هم نمایه SPI دقت بالاتری نسبت به نمایه EDI داشته است و سناریوی ۲ نسبت به سایر سناریوها ضریب تبیین بیشتری دارد و همچنین نتایج بیانگر این مهم است که خوشه بندی کاهشی سبب افزایش دقت مدل ANFIS



شکل ۷- مقایسه مقادیر مشاهده‌ای و پیش‌بینی شده SPI با استفاده از شبکه عصبی- فازی تطبیقی بر مبنای خوشه‌بندی کاهشی



شکل ۸- مقایسه مقادیر مشاهداتی و پیش‌بینی شده SPI با استفاده از شبکه عصبی- فازی تطبیقی بر مبنای خوشه‌بندی کاهشی

داده‌های ورودی خیلی زیاد نمی‌باشد برابر با ۳ در نظر گرفته می‌شود. در نهایت جهت مقایسه نهایی نتایج به دست آمده از روش‌های مدل‌سازی سری زمانی خشکسالی ارائه شده در این مقاله، نتایج بهترین ساختار برای هر یک از روش‌های یاد شده در جداول ۱۴ و ۱۵ آورده شده است که از مقایسه کلی جداول نتیجه‌گیری می‌شود که کاربرد روش عصبی- فازی به همراه آنالیز خوشه‌بندی 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.

خوشه‌های تخمین زده شده در گام سوم (روش خوشه‌بندی کاهشی) را به عنوان مقدار اولیه در روش خوشه‌بندی تکراری (FCM) در نظر گرفته شده است که نتایج برای این مرحله در جداول ۱۲ و ۱۳ آمده است. با توجه به اعداد جدول ۱۱ می‌توان دریافت که افزایش دقت نتایج برای حالتی که از ۲ خوشه استفاده گردیده است چندان تأثیرگذار نبوده اما با افزایش خوشه‌ها به ۳ و ۴ خوشه مدل کارایی بهتری نسبت به حالت عدم خوشه‌بندی نشان داده و کارایی آن افزایش یافت. با توجه به جدول ۱۰ مقدار بهینه تعداد خوشه‌ها با توجه به اینکه تعداد

جدول ۱۱- بررسی تأثیر تعداد خوشه‌ها در نتایج مدل‌سازی نمایه SPI با روش شبکه عصبی- فازی تطبیقی

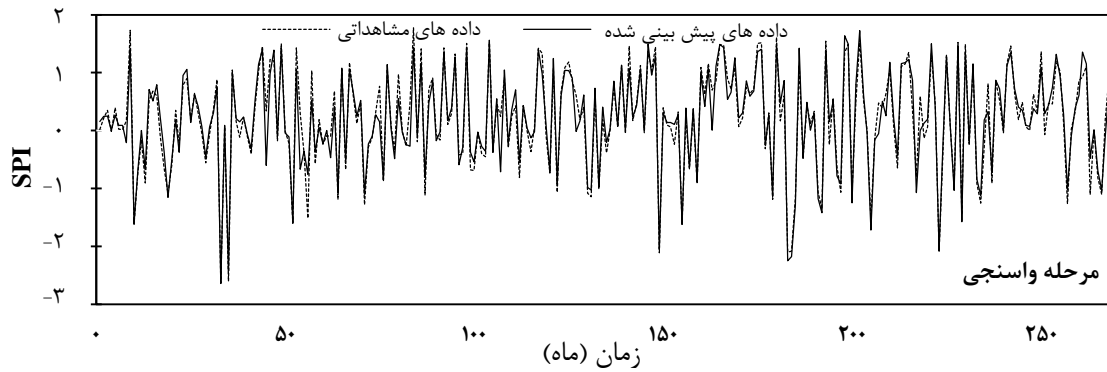
RMSE		R ²		متغیرهای ورودی به شبکه	تعداد خوشه‌ها
صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی		
۰/۰۸	۰/۰۴	۰/۸۳	۰/۹۳	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}	۲
۰/۰۷	۰/۰۶	۰/۸۷	۰/۹۳	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}	۳
۰/۰۸	۰/۰۴	۰/۸۳	۰/۹۳	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}	۴
۰/۰۷	۰/۰۵	۰/۸۸	۰/۹۳	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}	۸

جدول ۱۲- نتایج و آماره‌های مدل‌سازی نمایه SPI با روش شبکه عصبی- فازی تطبیقی بر مبنای خوشه‌بندی تکراری


RMSE		R ²		ورودی شبکه	N=3
صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی		
۰/۰۸	۰/۰۶	۰/۸۱	۰/۹۰	Comb (1): SPI _t , SPI _{t-1}	
۰/۰۷	۰/۰۴	۰/۸۷	۰/۹۳	Comb (2): SPI _t , SPI _{t-1} , SPI _{t-2}	
۰/۰۸	۰/۰۵	۰/۸۰	۰/۹۵	Comb (3): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3}	
۰/۱	۰/۰۳	۰/۶۴	۰/۹۵	Comb (4): SPI _t , SPI _{t-1} , SPI _{t-2} , SPI _{t-3} , SPI _{t-4}	
۰/۱۱	۰/۰۸	۰/۶۰	۰/۸۱	SPI _{t-1} , Moisture, Temp, Evaporation	

جدول ۱۳- نتایج و آماره‌های مدل‌سازی نمایه EDI با روش شبکه عصبی- فازی تطبیقی بر مبنای خوشه‌بندی تکراری

RMSE		R ²		ورودی شبکه	N=3
صحت‌سنجی	واسنجی	صحت‌سنجی	واسنجی		
۰/۱۱	۰/۱۱	۰/۷۰	۰/۷۲	Comb (1): EDI _t , EDI _{t-1}	
۰/۱۲	۰/۱	۰/۷۳	۰/۷۷	Comb (2): EDI _t , EDI _{t-1} , EDI _{t-2}	
۰/۱۴	۰/۰۹	۰/۵۳	۰/۸۰	Comb (3): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3}	
۰/۱۵	۰/۰۸	۰/۴۵	۰/۸۱	Comb (4): EDI _t , EDI _{t-1} , EDI _{t-2} , EDI _{t-3} , EDI _{t-4}	
۰/۱۴	۰/۰۸	۰/۶۵	۰/۸۷	EDI _{t-1} , Moisture, Temp, Evaporation	



شکل ۹- مقایسه مقادیر مشاهداتی و پیش‌بینی شده SPI با استفاده از شبکه عصبی- فازی تطبیقی بر مبنای خوشه‌بندی تکراری



شکل ۱۰- مقایسه مقادیر مشاهداتی و پیش‌بینی شده SPI با استفاده از شبکه عصبی- فازی تطبیقی بر مبنای خوشه‌بندی تکراری

جدول ۱۴- ارزیابی مدل‌های مختلف در مدل‌سازی خشکسالی با نمایه SPI

RMSE		R ²		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 بدون خوشه‌بندی
۰/۰۵	۰/۰۴	۰/۸۶	۰/۹۳	شبکه عصبی- فازی تطبیقی با خوشه‌بندی کاهشی
۰/۰۷	۰/۰۴	۰/۸۷	۰/۹۳	شبکه عصبی- فازی تطبیقی با خوشه‌بندی تکراری

جدول ۱۵- ارزیابی مدل‌های مختلف در مدل‌سازی خشکسالی با نمایه EDI

RMSE		R ²		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 بدون خوشه‌بندی
۰/۱۱	۰/۱	۰/۷۰	۰/۷۷	شبکه عصبی- فازی تطبیقی با خوشه‌بندی کاهشی
۰/۱۱	۰/۱	۰/۷۳	۰/۷۷	شبکه عصبی- فازی تطبیقی با خوشه‌بندی تکراری

نتیجه‌گیری

ورودی به شبکه عصبی و عصبی- فازی استفاده گردید که نتایج حاصل از این مدل‌سازی نشان می‌دهد که ضریب تبیین (R²) در مرحله واسنجی و صحت‌سنجی برای شاخص SPI با استفاده از شبکه عصبی مصنوعی به ترتیب ۰/۷۳ و ۰/۷۲ می‌باشد که با فازی سازی داده‌ها این ضرایب به ۰/۹۵ و ۰/۸۶ افزایش یافته است که نشان می‌دهد بهره‌گیری از شبکه عصبی- فازی به خوبی

ترکیب مدل شبکه عصبی- فازی با آنالیز خوشه‌بندی یک ایده نو برای به‌وجود آمدن شبکه‌ای توانمندتر است. در این پژوهش از داده‌های نمایه SPI و EDI که با استفاده از آزمون سنجه کارآمد در مقایسه با سایر نمایه‌ها از شرایط مطلوب‌تری برخوردار است به عنوان داده‌های

اساس نمایه‌های آماری. اولین همایش بیابان تهران،

مرکز تحقیقات بین‌المللی بیابان، دانشگاه تهران.

- Bacanli, U. G., Firat, M., Dikbas, F. 2009. Adaptive neuro-fuzzy inference system for drought forecasting. *Stoch. Environ. Res. Risk Assess.*, 23(8): 1143-1154.
- Bezdek, J. C. 1981. *Pattern recognition with fuzzy objective function algorithms*, Plenum Press, New York.
- Choubin, B., Khalighi, Sh., Malekian, A., Ahmad, S., Attarod, P. 2014. Drought forecasting in a semi-arid watershed using climate signals: a neuro fuzzy modeling approach. *J. Mt. Sci.*, 11(6): 1593-1605.
- Choubin, B., Malekian, A., Golshan, M. 2016. Application of several data-driven techniques to predict a standardized precipitation index. *Atmosfera*, 29(2): 121-128.
- Dehghani, M., Saghafian, B., Naseri, F., Farokhnia, A., Noori, R. 2014. Uncertainty analysis of streamflow drought forecast using artificial neural networks and Monte-Carlo simulation. *Int. J. Climatol.*, 34(6): 1169-1180.
- Deo, R. C., Kisi, O., Singh, V. P. 2017. Drought forecasting in eastern Australia using multivariate adaptive regression spline, least square support vector machine and M5Tree model. *Atmos. Res.*, 184: 149-175.
- Esfahanian, E., Nejadhashemi, A. P., Abouali, M., Adhikari, U., Zhang, Z., Daneshvar, F., Herman, M. R. 2017. Development and evaluation of a comprehensive drought index. *J. Environ. Manag.*, 185: 31-43.
- Jang, J. S. R. 1993. ANFIS: Adaptive network based fuzzy inference system. *IEEE Trans. Syst. Man Cybern.*, 23 (3): 665-683.
- Moreira, E. E. 2016. SPI drought class prediction using log-linear models applied to wet and dry seasons. *J. Phys. Chem. Earth*, 94(A/B/C): 136-145.
- Shirmohammadi, B., Moradi, H., Moosavi, V., Semiromi, M. T., Zeinali, A. 2013. Forecasting of meteorological drought using Wavelet-ANFIS hybrid model for different time steps (case study: southeastern part of east Azerbaijan province, Iran). *Nat. hazards*, 69(1): 389-402.
- Smakhtin, V. U., Hughes, D. A. 2004. Review, automated estimation and analyses of drought indices in South Asia. *IWMI*, (Vol. 83).
- Tawafan, A. H., Bin Sulaiman, M., Bin Ibrahim, Z. 2012. Adaptive Neural Subtractive Clustering Fuzzy Inference System for the Detection of High Impedance Fault on Distribution Power System. *Int. J. Artif. Intell.*, 1(2): 63-72.

توانسته الگوی سری زمانی داده‌ها را تشخیص داده و به نتایج منجر گردد. همچنین از خوشه‌بندی داده‌ها برای افزایش کارایی مدل استفاده شد که نتایج نشان داد که خوشه‌بندی تکراری با ضریب واسنجی ۰/۹۳ و ضریب صحت سنجی ۰/۸۷ بهترین مدل می‌باشد. نتایج نشان می‌دهند شاخص SPI قابلیت و دقت بیشتری نسبت به شاخص EDI در پیش‌بینی خشکسالی در منطقه مورد مطالعه داشته است. از مقایسه نتایج این پژوهش با پژوهشی که چوبین و همکاران (۲۰۱۴) در حوضه مهارلو بختگان انجام دادند نتیجه می‌شود که خوشه‌بندی فازی نتایج بهتری به دنبال داشته است.

منابع

- ابراهیم پور، ا.، قادری، س. ج. ۱۳۹۳. کاربرد روش‌های هوش مصنوعی در پیش‌بینی خشکسالی بر اساس شاخص SPI. پانزدهمین کنفرانس دانشجویان عمران سراسر کشور، دانشگاه ارومیه، ارومیه.
- بذرافشان، ج.، هاشمی نسب، آ.، نازی قمشلو، آ. ۱۳۹۴. ارزیابی نمایه‌های خشکسالی کمبود توأم تحت شرایط اقلیمی ایران. نشریه حفاظت منابع آب و خاک، ۴(۳)، ۵۳-۶۳.
- بنی‌مهد، س. ا.، خلیلی، د. ۱۳۹۰. بررسی و مقایسه شاخص‌های خشکسالی EDI و SPI در ایستگاه‌های منتخب استان مازندران. همایش منطقه‌ای دانش محوری در مدیریت پایدار کشاورزی و منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان.
- جمشیدی، ج.، خلیلی، د.، کامگار، ع. ۱۳۸۸. بررسی و مقایسه نمایه‌های خشکسالی SPI و RDI در ایستگاه‌های منتخب سینوپتیک کشور، دومین همایش ملی اثرات خشکسالی و راهکارهای مدیریت آن، اصفهان، مرکز تحقیقات کشاورزی و منابع طبیعی.
- خلیلی، ع.، بذرافشان، ج. ۱۳۸۲. ارزیابی کارایی چند نمایه خشکسالی هواشناسی در نمونه‌های اقلیمی مختلف ایران. نشریه نیوار، ۴۸ (۴ و ۴۹): ۷۹-۹۳.
- کماسی، م.، اعلمی، م.، نورانی، و. ۱۳۹۲. پیش‌بینی خشکسالی با نمایه SPI به روش مدل‌سازی ANFIS. نشریه آب و فاضلاب، ۲۴(۴): ۱۰۲-۹۰.
- یزدانی، م.، رفیعیانی، ا.، رحیمی، م. ۱۳۹۱. بررسی و تحلیل خشکسالی هواشناسی در استان اصفهان بر



Drought forecasting by SPI and EDI indices using ANFIS method based on C-mean and SC clustering (Case study: Kohgiluyeh and Boyer Ahmad Province)

M. Komasi¹, M. Malekmahmoudi², H. Montaseri^{3*}

Received: 25/05/2016

Accepted: 21/08/2017

Abstract

Drought is one of the most and oldest natural disaster that cause significant environmental impacts. Despite Kohgiluyeh and Boyer Ahmad is in the third place in terms of rainfall but the drought has affect the province intermittently and causes many heavy losses. In other 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 this research, using Artificial Neural Networks (ANN) and Adaptive Neuro Fuzzy System (ANFIS) model with phase clustering analysis with standardized precipitation index (SPI) and effective drought index (EDI) were used to predict drought. The results of study indicate that the SPI index by validation coefficient 0.87 has more capability and accuracy than EDI index by validation coefficient 0.73 in predicting of drought. On the other hand according to C-mean and SC clustering in modeling for predicting the drought, ANFIS approach has more efficacy the result show that, clustering causes the increasing of model accuracy in verification and calibration stages. C-mean clustering by calibration coefficient 0.93 and validation coefficient 0.87 is the best model.

Keywords: Drought, Clustering, ANFIS, Kohgiluyeh and Boyer Ahmad, SPI and EDI



¹ Assistant Professor, Department of Civil Engineering, University of Ayatollah Ozma Borujerdi, Iran

² M.Sc. of water resources management, Department of civil Engineering, Yasouj University, Iran

³ Assistant Professor, Department of Civil Engineering, Yasouj University, Iran

(*Corresponding Author's Email Address: hmontaseri@gmail.com)