



مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی فارس

پژوهش‌های آبخیزداری

شاپا: ۲۰۳۸-۲۹۸۱



مؤسسه تحقیقات، آموزش و ترویج کشاورزی

پیش‌بینی خشک‌سالی با استفاده از سامانه‌ی بهره‌وری عصبی حالتی سازگار با محاسبه‌ی عددی فراابتکاری کلونی مورچه‌ها در آبخیز زابل

پیام ابراهیمی*

استادیار بخش تحقیقات جنگل و مرتع و آبخیزداری مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی سیستان، سازمان تحقیقات، آموزش و ترویج کشاورزی، زابل، ایران

چکیده‌ی مبسوط

مقدمه و هدف

استفاده از شبیه‌سازی‌های ترکیب شده با نمایه‌ی خشک‌سالی دقت پیش‌بینی را افزایش می‌دهد. رویکرد اکتشافی زمینه‌ی هشدار اثرهای خشک‌سالی و امکان ساز و کارهای حمایت مالی و بیمه‌ای جوامع محلی را فراهم می‌کند. مهم‌ترین بخش، کاهش آثار خشک‌سالی و بهبود دقت سامانه‌های پیش‌بینی‌کننده است.

مواد و روش‌ها

در این پژوهش دقت شبیه‌سازی جدید انفیس ترکیب‌شده با محاسبه‌ی عددی فراابتکاری کلونی مورچه‌ها در پیش‌بینی خشک‌سالی با شبیه‌سازی انفیس معمولی مقایسه شد. عملکرد شبیه‌سازی با استفاده از خطای جذر میانگین مربع‌ها، میانگین مطلق خطا و ضریب تعیین ارزیابی شد.

نتایج و بحث

اعتبارسنجی شبیه‌سازی در نمایه‌ی ۳ ماهه نشان داد اندازه‌ی خطای مطلق و خطای جذر میانگین مربع‌ها در ایستگاه زابل با کاربرد شبیه‌سازی انفیس کمتر است. در این پژوهش در آبخیز زابل، شبیه‌سازی‌های انفیس (سامانه‌ی بهره‌وری عصبی حالتی سازگار) و انفیس همراه با محاسبه‌ی عددی فراابتکاری کلونی مورچه‌ها برای پیش‌بینی خشک‌سالی بررسی شد. نتایج نشان داد که پیش‌بینی خشک‌سالی با استفاده از داده‌های بارش ماهانه‌ی ایستگاه‌های هم‌دید زابل (۱۳۶۲-۱۳۹۹)، زهک (۱۳۷۳-۱۳۹۹) و روش بهینه‌سازی کلونی مورچه‌ها سبب بهبود عملکرد شبیه‌سازی انفیس شده است. اندازه‌ی آزمون ضریب تعیین پیش‌بینی و روش بهینه‌سازی کلونی مورچه‌ها سبب بهبود عملکرد شبیه‌سازی انفیس شده است.

نوع مقاله: پژوهشی

* مسئول مکاتبات، پست الکترونیکی: p.ebrahimi@areeo.ac.ir

استناد: ابراهیمی، پ. ۱۴۰۲. پیش‌بینی خشک‌سالی با استفاده از سامانه‌ی بهره‌وری عصبی حالتی سازگار با محاسبه‌ی عددی فراابتکاری کلونی مورچه‌ها در آبخیز زابل. پژوهش‌های آبخیزداری، ۳۶ (۲): ۳۵-۱۸.

شناسه‌ی دیجیتال: 10.22092/wmrj.2022.359003.1478

تاریخ دریافت: ۱۴۰۱/۰۳/۲۴، تاریخ بازنگری: ۱۴۰۱/۰۵/۳۰، تاریخ پذیرش: ۱۴۰۱/۰۶/۳۰، تاریخ انتشار: ۱۴۰۲/۰۴/۰۱
پژوهش‌های آبخیزداری، سال ۱۴۰۲، دوره‌ی ۳۶، شماره‌ی ۲، شماره‌ی پیاپی ۱۳۹، تابستان ۱۴۰۲، صفحه‌های ۱۸ تا ۳۵.



©نویسندگان

ناشر: مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان فارس

شبیه‌سازی انفیس همراه با محاسبه‌ی عددی فراابتکاری کلونی مورچه‌ها در بازه‌های ۳، ۶، ۹ و ۱۲ ماهه، به ترتیب برابر با ۰/۷۳۸، ۰/۸۵۴، ۰/۸۰۱ و ۰/۸۹۸ در ایستگاه زابل و ۰/۷۹۲، ۰/۸۰۴، ۰/۷۵۹ و ۰/۸۸۷ در ایستگاه زهک بود. علاوه بر این شبیه‌سازی انفیس-کلونی مورچه‌ها ضریب تعیین بالاتری داشت. اعتبارسنجی شبیه‌سازی نمایه‌ی ۳ ماهه شبیه‌سازی انفیس-کلونی مورچه‌ها اندازه‌ی خطای مطلق و خطای جذر میانگین مربع‌ها کمتر و ضریب تعیین آن بالاتر بود. در ایستگاه زهک نیز شبیه‌سازی انفیس در آموزش ۳ ماهه دقت بالاتری داشت، اما در بخش اعتبارسنجی برتری با شبیه‌سازی انفیس-کلونی مورچه‌ها بود. به‌طور کلی در نمایه‌ی SPI سه ماهه، آموزش شبیه‌سازی انفیس دقت بالاتری داشت اما در اعتبارسنجی شبیه‌سازی انفیس-کلونی مورچه‌ها برتری داشت.

نتیجه‌گیری و پیشنهادها

بهینه‌سازی با کاربرد کلونی مورچه‌ها مبتنی بر جمعیت داده‌ها به تدریج راه‌حل‌های پیشنهاد شده را به راه‌حل بهینه‌ی سراسری نزدیک می‌کند. این مسئله سبب افزایش کارایی محاسبه‌ی عددی کلونی مورچه‌ها در مقایسه با انفیس در پیش‌بینی خشک‌سالی شد. شبیه‌سازی انفیس ترکیب شده با کلونی مورچه‌ها خصوصیت کارایی برای مسائلی با مقیاس بزرگ در زمان کوتاه از روش خود تنظیمی پیشنهاد داد. این خصوصیت‌ها برای داده‌های طبیعی دارای الگوی هندسی نامنظم و یا داده‌های ثبت شده با حجم بالا هزینه‌ی محاسباتی را کاهش دادند. شبیه‌سازی‌هایی که بهینه‌سازی می‌کنند در نقاط بهینه محلی دچار خطا می‌شوند. این در حالی است که شبیه‌سازی انفیس-کلونی مورچه‌ها فضای شبیه‌سازی برای پیش‌بینی خشک‌سالی را سراسری ارزیابی کرد. مقایسه‌ی شبیه‌سازی انفیس با محاسبه‌ی عددی‌های دیگر و انتخاب بهترین شبیه‌سازی برای آبخیز زابل پیشنهاد می‌شود.

واژگان کلیدی: انفیس، پیش‌بینی، خشک‌سالی، کلونی مورچه‌ها، نمایه‌ی بارش میزان شده

مقدمه

است. خشک‌سالی هواشناسی از روش نمایه‌های مختلفی قابل بررسی و اندازه‌گیری است. پرکاربردترین نمایه‌ها شامل نمایه‌ی خشک‌سالی مؤثر، نمایه‌ی بارش تبخیرتقرق میزان^۱، نمایه‌ی شدت خشکی پالمر و نمایه‌ی بارش میزان شده است (میشرا و سینگ ۲۰۱۰). آبخیز زابل در شمال استان سیستان و بلوچستان، بیش از دو دهه دچار خشک‌سالی است و هر ساله این شرایط آستانه‌های متفاوتی را ایجاد می‌کند. سهم بالایی از شغل‌ها مربوط به کشاورزی است. خشک‌سالی هر ساله در ایجاد خسارت زراعی دارای آستانه‌های متفاوتی است. نمایه‌ی SPI در مناطق خشک در مقایسه با سایر نمایه‌های بررسی شده، شرایط خشک‌سالی را با دقت بالاتری نشان می‌دهد (پودینه و همکاران ۲۰۲۰، ناد و شیوخی‌سوغانلو ۲۰۲۰، علی و همکاران ۲۰۱۹). ترکیب این روش با شبکه‌های هوش مصنوعی و یادگیری از روش محاسبه‌ی عددی دقت ارزیابی را افزایش می‌دهد. (کاماسی و شرقی ۲۰۲۰، وون و همکاران ۲۰۲۰). بنابراین پیشنهاد اطلاعات صحیح و نزدیک به واقعیت، برنامه‌ریزی تخصیص آب، بهره‌برداری و توزیع را فراهم می‌کند. کاماسی و همکاران (۲۰۱۳) خشک‌سالی را با نمایه‌ی SPI به روش شبیه‌سازی انفیس^۲ بر مبنای خوشه‌بندی C-mean حالتی پیش‌بینی کردند. نتایج نشان داد نمایه‌ی SPI قابلیت

خشک‌سالی به علت انحراف از شرایط بهنجار دسترسی به آب رخ می‌دهد و به صورت کمبود بارش در یک دوره‌ی زمانی طولانی تعریف می‌شود (خادکا و همکاران ۲۰۲۱). خشک‌سالی از جمله بلاهای طبیعی است که تغییرهای منفی شرایط یا به عبارتی کاهش بارش‌های جوی در میانگین بلندمدت رخ می‌دهد. پیش‌بینی‌هایی که با کاربرد ابزارهای مختلف تحلیل آماری انجام می‌شود عدم قطعیت‌های متفاوتی دارد. دقت در پیش‌بینی سبب کاهش هزینه‌های اقدامات و ارزیابی نزدیک به واقعیت خسارت خشک‌سالی می‌شود (میشرا و سینگ ۲۰۱۰). شکل‌گیری خشک‌سالی پدیده‌ای پویا و بسیار پیچیده است که با فرآیندهای مختلف کشاورزی، آب‌شناسی، مربوط به بوم‌شناختی، اقتصادی و اجتماعی در ارتباط است (زو و همکاران ۲۰۲۱). براساس پژوهش‌های انجام شده، مفهوم خشک‌سالی در چهار دسته‌ی خشک‌سالی هواشناسی، خشک‌سالی آب‌شناسی، خشک‌سالی کشاورزی و خشک‌سالی اقتصادی-اجتماعی طبقه‌بندی می‌شود (ویلپیت و گالانز ۱۹۸۵). با این طبقه‌بندی، خشک‌سالی صرفاً بر مبنای درجه‌ی خشکی و مدت زمان دوره‌ی خشکی تعریف می‌شود. خشک‌سالی هواشناسی به عنوان دوره‌ای با تعداد روزهای کمتر از یک اندازه‌ی معین بارندگی یا کمتر از اندازه‌ی آستانه

1- Standardized Precipitation Index (SPI)

2 - Adaptive Neuro Fuzzy Inference System (ANFIS)

آسیب‌پذیری خشک‌سالی و مدیریت پاسخ پیشنهاد دادند. با توجه به نتایج پژوهش‌ها استفاده از شبیه‌سازی‌های ترکیب شده با نمایه‌ی خشک‌سالی دقت پیش‌بینی را افزایش می‌دهد. هدف این پژوهش مقایسه‌ی دقت پیش‌بینی خشک‌سالی بود که از آمار بارندگی ماهانه‌ی دو ایستگاه هم‌دید زابل و زهک واقع در آبخیز زابل استفاده شد. این پژوهش با استفاده از رویکرد اکتشافی، زمینه‌ی هشدار اثرهای خشک‌سالی و امکان ساز و کارهای حمایت مالی و بیمه‌ای جوامع محلی را فراهم می‌کند. مهم‌ترین بخش، کاهش اثرهای خشک‌سالی و بهبود دقت سامانه‌های پیش‌بینی کننده است. براساس پژوهش‌های انجام شده در آبخیز زابل، محاسبه‌ی عددی فراابتکاری دقت پیش‌بینی را افزایش می‌دهد. این آبخیز فقط دارای دو ایستگاه هم‌دید است. برای بررسی دقت پیش‌بینی خشک‌سالی از آمار بارندگی ایستگاه‌ها (از ابتدای تأسیس ایستگاه‌ها) استفاده شد. براساس پژوهش کماسی و همکاران (۲۰۱۷) کاربست پیش‌بینی خشک‌سالی در آبخیز زابل با استفاده از رویکردهای اکتشافی و روش‌های بهینه‌سازی ارتقا می‌یابد. در این پژوهش دقت شبیه‌سازی جدید انفیس ترکیب شده با محاسبه‌ی عددی فراابتکاری کلونی مورچه‌ها در پیش‌بینی خشک‌سالی بررسی و عملکرد شبیه‌سازی با شبیه‌سازی انفیس معمولی مقایسه شد. عملکرد شبیه‌سازی با استفاده از خطای جذر میانگین مربع‌ها، میانگین مطلق خطا و ضریب تعیین ارزیابی شد.

مواد و روش‌ها

معرفی منطقه‌ی پژوهش

آبخیز زابل در شرق کشور ایران و در شمال استان سیستان و بلوچستان واقع شده است. منطقه‌ی پژوهش در شمال استان سیستان و بلوچستان است. آبخیز زابل در طول جغرافیایی ۳۰° تا ۳۸° و عرض جغرافیایی ۵۴° تا ۶۱° واقع شده است (گندم‌کار و خادم‌الحسینی، ۲۰۰۹). میانگین بارندگی بلندمدت آن ۵۰ میلی‌متر و کمینه و بیشینه‌ی دمای مطلق روزانه در منطقه $۱۱/۹-$ و $۴۹/۶$ درجه سانتی‌گراد است. داده‌های بارندگی ماهانه‌ی ایستگاه‌های هم‌دید زابل و زهک در منطقه‌ی پژوهش از ابتدای سال تأسیس به ترتیب برای دوره‌ی آماری ۱۳۶۲ تا ۱۳۹۹ و ۱۳۷۳ تا ۱۳۹۹ از سازمان هواشناسی کشور دریافت شد. محدوده‌ی پژوهش در شکل (۱) نشان داده شده است.

بیشتری در پیش‌بینی خشک‌سالی در مقایسه با دیگر نمایه‌ها دارد و راهبرد شبکه‌ی عصبی در زمینه‌ی شبیه‌سازی برای پیش‌بینی خشک‌سالی کارایی بالایی دارد. صادقیان و همکاران (۲۰۲۰) و یردلن و همکاران (۲۰۲۱) در مناطق خشک نیز مناسب‌ترین روش برای پیش‌بینی خشک‌سالی را تعیین کردند. با استفاده از روش سری‌های زمانی، شبکه‌ی عصبی مصنوعی^۳ و انفیس، شبیه‌سازی‌هایی برای پیش‌بینی خشک‌سالی پیشنهاد شده است. نتایج این پژوهش‌ها نشان داد که ترکیب این شبیه‌سازی‌ها دقت پیش‌بینی را افزایش داده است (خان و همکاران ۲۰۲۰). پژوهش‌های پیش‌بینی خشک‌سالی در مناطق خشک با استفاده از رویکردهای اکتشافی و ترکیب با محاسبه‌ی عددی بهبوددهنده نتایج قابل قبولی دارند (عاقل‌پور و همکاران ۲۰۲۰). کیسی و همکاران (۲۰۱۹) دقت چهار روش عصبی حالتی تکاملی^۴ ترکیب انفیس با بهینه‌سازی ازدحام ذرات^۵، ترکیب انفیس با بهینه‌سازی کلونی مورچه^۶، انفیس با محاسبه‌ی عددی ژنتیک و ترکیب انفیس با روش بهینه‌یابی پروانه^۷ را بررسی کردند. دقت این روش‌ها در برآورد سری‌های زمانی نمایه‌ی SPI بیانگر برتری روش‌های تکاملی در مقایسه با روش انفیس در برآورد نمایه‌ی خشک‌سالی است شبیه‌سازی‌های خشک‌سالی همواره با شبیه‌سازی‌های فراابتکاری دقت بالاتری دارند (جهانگیر و همکاران ۲۰۱۹). بررسی نمایه‌های خشک‌سالی مانند PDSI، SPI و MSPI در پژوهش‌های عاقل‌پور و همکاران (۲۰۲۰) و SPI و SPEI در پژوهش‌های برا و همکاران (۲۰۲۱) نشان داد دقت شبیه‌سازی SPI به صورت اصلاح شده و ترکیب با شبیه‌سازی‌های بهبوددهنده، بیشتر است. شبیه‌سازی‌های فراابتکاری مانند ترکیب انفیس با بهینه‌سازی کلونی مورچه، انفیس با محاسبه‌ی عددی ژنتیک، ترکیب انفیس با بهینه‌سازی ازدحام ذرات و ترکیب نمایه‌ی SPI همراه با کاپولا CJDI برای پیش‌بینی نمایه‌ی خشک‌سالی استفاده شده است (ون و همکاران ۲۰۲۰). نتایج نشان داد محاسبه‌ی عددی استفاده شده اندازه‌های پیش‌بینی شده را بهبود می‌دهند. رحمتی و همکاران (۲۰۲۰) در پژوهشی از رویکرد شبیه‌سازی مکانی برپایه‌ی رویکردهای بهینه‌سازی از جمله محاسبه‌ی عددی زنبور عسل برای پیش‌بینی وقوع خشک‌سالی در کوئینزلند استرالیا استفاده کردند. نمایه‌های خشک‌سالی با ترکیب شبیه‌سازی و محاسبه‌ی عددی برای تعیین مکان‌هایی که امکان وقوع خشک‌سالی داشتند نتایج بهتری در برآورد

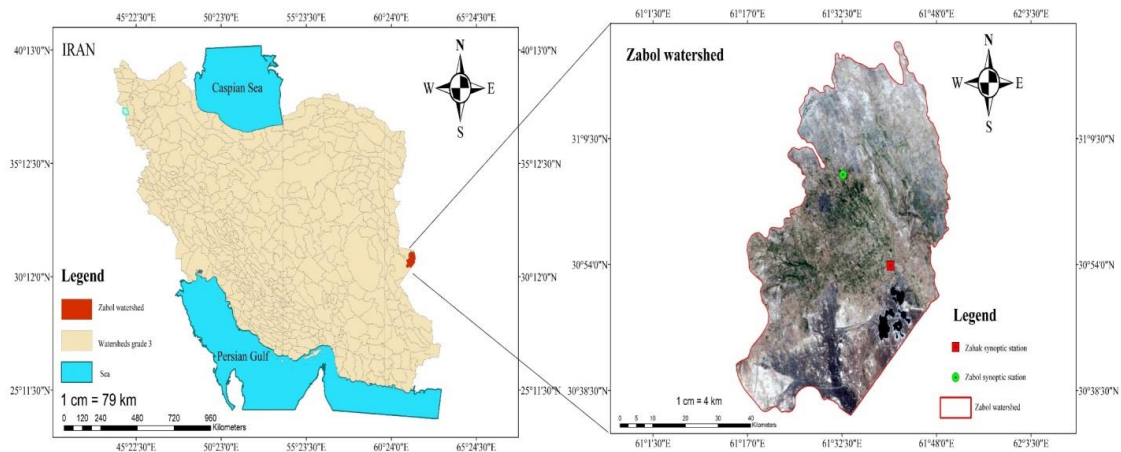
3- Artificial Neural Network (ANN)

4 - Particle Swarm Optimization (PSO)

5 - Ant Colony Optimization (ACO)

6 - Genetic Algorithm (GA)

7 - Butterfly Optimization Algorithm (BOA)



شکل ۱- محدوده‌ی پژوهش.
Figure 1- Case Study Area.

n تعداد مشاهده‌های بارندگی و \bar{X} میانگین بارندگی برای یک دوره‌ی مشخص است و احتمال تجمعی $G(X)$ از رابطه‌ی ۴ به‌دست می‌آید.

$$G(x) = \int_0^x g(x) \quad (4)$$

از آن‌جا که اندازه‌ی بارندگی می‌تواند برابر صفر باشد، احتمال تجمعی از معادله‌ی ۵ محاسبه‌شده.

$$H(x) = q + (1 - q)G(x) \quad q = \frac{m}{n} \quad (5)$$

m تعداد روزهای با بارش صفر و n تعداد بارش مشاهده‌شده است. به این ترتیب، اندازه‌ی SPI از معادله‌های ۶ تا ۹ محاسبه می‌شود (لویدهوگزر و ساندرز ۲۰۰۲).

$$SPI = -\left(t - \frac{c_0 + c_1t + c_2t^2}{1 + d_1t + d_2t^2 + d_3t^3}\right), \quad 0 < H(x) \leq 0.5 \quad (6)$$

$$SPI = +\left(t - \frac{c_0 + c_1t + c_2t^2}{1 + d_1t + d_2t^2 + d_3t^3}\right), \quad 0.5 < H(x) \leq 1 \quad (7)$$

$$t = +\sqrt{\ln\left(\frac{1}{H(x)^2}\right)} \quad 0 < H(x) \leq 0.5 \quad (8)$$

$$t = +\sqrt{\ln\left(\frac{1}{(1-H(x))^2}\right)} \quad 0.5 < H(x) \leq 1 \quad (9)$$

در این رابطه‌ها ضریب‌های ثابت از جدول ۱ جای‌گذاری می‌شود.

نمایه‌ی بارش نمونه

نمایه‌ی SPI به‌وسیله‌ی مک‌کی و همکاران (۱۹۹۳) معرفی شد و برای محاسبه‌ی آن از میانگین و انحراف میزان بلندمدت اندازه‌های بارندگی در دوره‌ی انجام این پژوهش استفاده شد. در این پژوهش مقیاس‌های زمانی ۳، ۶، ۹ و ۱۲ ماهه مانند پژوهش‌های ژانگ و همکاران (۲۰۱۷) استفاده شد. نمایه‌ی SPI از نظر ریاضی براساس احتمال تجمعی داده‌های بارش است و بارش از توزیع گاما پیروی می‌کند. تابع چگالی احتمال گاما از معادله‌ی ۱ محاسبه می‌شود.

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

α و β به‌ترتیب ویژگی شکل و ویژگی مقیاس و $\Gamma(\alpha)$ تابع گاما است که به‌شکل رابطه‌ی ۲ تعریف می‌شود.

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

ویژگی‌های α و β مربوط به تابع چگالی گاما برای هر ایستگاه و برای هر مقیاس زمانی و هر ماه از سال برآورد شده است. مک‌کی و همکاران (۱۹۹۳) با استفاده از روش بیشینه‌ی درست‌نمایی، ضرایب بهینه‌ی α و β را براساس رابطه‌ی ۳ محاسبه کردند.

$$\alpha = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{a}} \right) \quad A = \ln(\bar{X}) - \frac{\sum \ln(X)}{n} \quad \beta = \frac{\bar{X}}{a} \quad (3)$$

جدول ۱- ضریب‌های ثابت معادله‌های محاسبه‌ی نمایه‌ی SPI.

Table 1- Constant Coefficients of SPI Index Calculation Equations.

d_3	d_2	d_1	c_2	c_1	c_0
0.001308	0.189269	1.432788	0.010328	0.802853	2.515517

دو ایستگاه وارد محیط برنامه شد. پس از فراخوانی داده‌ها در محیط، اجرای تابع مقیاس‌ها انجام شد. همچنین در میانگین متحرک، تابع گاما، ضرایب α و β و محاسبه‌ها از جدول ۲ استفاده شد.

نرم افزار پایتون^۸ یکی از روش‌های تحلیل مقیاس‌های زمانی ۳، ۶، ۹ و ۱۲ ماهه استفاده از برنامه‌ی پایتون در محیط ویژوال استودیو کد^۹ است. در این پژوهش با استفاده از کتابخانه‌ی پانداس^{۱۰}، نامپای^{۱۱}، سای‌پای^{۱۲} و مٹ‌پلات^{۱۳} داده‌های بارندگی

جدول ۲- دستور محاسبه‌ی میانگین متحرک، تابع گاما و ضریب‌های α و β .

Table 2- Instructions for Calculating Moving Average, Gamma Function and α and β Coefficients.

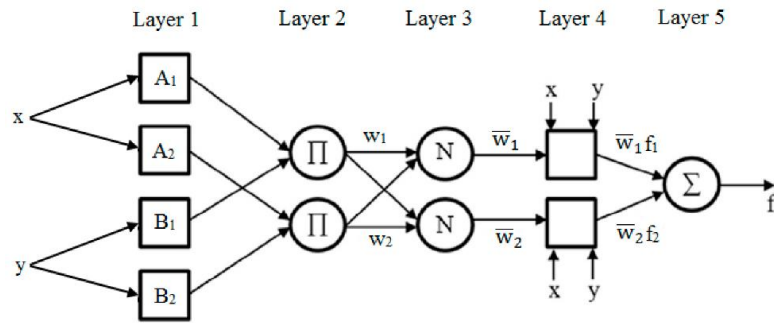
The Title of the Commands	Running Commands in the Visual Studio Code Environment
The General Equation	def spi(ds, thresh):
The Limits of Eq	#ds - data ; thresh - time interval / scale ds_ma =
How to Learn Simulation	ds.rolling(thresh, center=False).mean()
Logarithm	ds_In = np.log(ds_ma)
The Largest Lower Bound	ds_In[np.isinf(ds_In) == True] = np.nan
Average	ds_mu = np.nanmean(ds_ma)
Total	ds_sum = np.nansum(ds_In)
Data Length	n = len(ds_In[thresh-1:])
The Exponent of the Equation A	A = np.log(ds_mu) - (ds_sum/n)
Alpha Coefficient Value	alpha = (1/(4*A))*(1+(1+((4*A)/3))*0.5)
The Value of the Beta Coefficient	beta = ds_mu/alpha
The Value of the Gamma Coefficient	gamma = st.gamma.cdf(ds_ma, a=alpha, scale=beta)
SPI Standard Value	norm_spi = st.norm.ppf(gamma, loc=0, scale=1) #loc is mean and scale is standard dev.
Viewing the Results of the Equations	return ds_ma, ds_In, ds_mu, ds_sum, n, A, alpha, beta, gamma, norm_spi

مثلی، دوزنقه‌ای و گاوسی^{۱۵} استفاده می‌شود. دومین لایه به‌عنوان لایه‌ی تعیین قانون است که از عمل‌گر ضرب استفاده می‌کند. خروجی لایه‌ی سوم، شکل بهنجار شده‌ی لایه‌ی قبل است. لایه‌ی چهارم لایه‌ی غیرحالتی سازی و لایه‌ی پنجم شامل گره‌های خروجی است و از مجموع خروجی‌های لایه‌ی چهارم به‌دست می‌آید (کیسی و همکاران ۲۰۱۹). قانون یادگیری انفیس براساس کمینه‌سازی میانگین مربع‌های خطا بین خروجی شبکه و خروجی واقعی است (شکل ۲).

سامانه‌ی بهره‌وری عصبی حالتی تطبیقی^{۱۴}

این روش در سال ۱۹۹۱ ابداع شد (جانگ ۱۹۹۱). ساختار انفیس شامل ۵ لایه‌ی گره‌های ورودی، گره‌های قاعده، گره‌های متوسط، گره‌های نتیجه و گره‌های خروجی است. گره‌ها به‌طور مستقیم با هم در ارتباط است. هر گره دارای تابعی با ویژگی‌های قابل تنظیم است. هر گره، لایه‌ی اول اندازه‌ی عضویت ویژگی‌های ورودی را تعیین می‌کند (لایه‌ی حالتی‌سازی). در این لایه تابع‌های عضویت مختلفی مانند

- 8 - Python
- 9 - Visual Studio Code
- 10 - Pandas
- 11 - Numpy
- 12 - Scipy
- 13 - Matplotlib
- 14 - Adaptive Neuro Fuzzy Inference System
- 15 - Gaussian



شکل ۲- نمایی از ساختار انفیس (جانگ ۱۹۹۱).

Figure 2- A View of the Anfis Structure (Jang 1991).

شد. شبیه‌سازی انفیس با استفاده از سامانه‌ی بهره‌وری حالتی تاکاجی-سوگنو به‌شکل ساختار شبکه‌ای پیش‌رونده و پنج لایه بود. در این سامانه فرض بر آن بود که دو ورودی و یک خروجی است. در لایه‌ی ابتدایی هر نرون درجه‌ی عضویت متغییر تعیین شد. در این پژوهش، لایه‌ی اول خروجی نرون i ام در لایه‌ی k ام به شکل Q_i^k نشان داده شد و با استفاده از تابع زنگوله‌ای به‌عنوان تابع عضویت خروجی Q_i^1 از معادله‌ی ۱۰ محاسبه شد.

$$Q_i^1 = \mu_{Ai}(x) = \frac{1}{1 + ((x - c_i)/a_i)^{2b_i}} \quad (10)$$

در این معادله و معادله‌های دیگر x یا y ورودی نرون و A_i یا B_i سامانه‌ی حالتی مربوطه و a_i و b_i و c_i متغیرهای تطبیقی هستند که به‌عنوان ویژگی‌های فرض معرفی شده‌اند. در لایه‌ی دوم، مجموعه‌ی قوانین میان ورودی‌ها با به‌کارگیری قاعده‌ی اشتراک حالتی معادله سازی شد. برای هر قانون ضرب استفاده شد و ساختار ایجاد شده به‌شکل معادله‌ی ۱۱ به‌دست آمد. در لایه‌ی سوم و چهارم نرون i ام ضرب به‌هم‌چراشده و تأثیر قانون i ام در خروجی شبیه‌سازی محاسبه شد (معادله‌های ۱۲ و ۱۳).

$$Q_i^2 = w_i = \mu_{Ai}(x), \mu_{Bi}(y) \quad i = 1, 2 \quad (11)$$

$$Q_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i = 1, 2 \quad (12)$$

$$Q_i^4 = \bar{w}_i(p_i x + q_i y + r_i) = \bar{w}_{if_i} \quad (13)$$

در لایه‌ی پنجم از معادله‌ی کلی انفیس استفاده شد. علاوه‌براین، تابع هدف براساس خوشه‌بندی حالتی در شبیه‌سازی سوگنو کمینه شد. معادله‌های ۱۴ و ۱۵ شبیه‌سازی انفیس و تابع هدف را نشان می‌دهند. در این معادله d_{ij} فاصله‌ی اقلیدسی بین مرکز خوشه‌ی i ام و j ام و m تعداد متغیرها و V_{ki} مرکز خوشه‌ی i ام از داده‌ی k ام

محاسبه‌ی عددی کلونی مورچه‌ها

محاسبه‌ی عددی کلونی مورچه‌ها ACO^{16} یک محاسبه‌ی عددی بهینه‌سازی است و از رفتار مورچه‌ها الهام گرفته شده است. در ابتدا محاسبه‌ی عددی مورچه‌ها برای حل مسائل بهینه‌سازی در یک فضای گسسته پیشنهاد شد و سپس برای فضای پیوسته توسعه یافت (سوچا و دوریگو ۲۰۰۸). در محاسبه‌ی عددی ACO در یک فضای گسسته، در هر مرحله، یک مورچه مسیر خود را براساس یک رابطه‌ی احتمالی ایجاد می‌کند. این ساختار احتمالی براساس توزیع احتمال گسسته پایه‌گذاری شده است. در محاسبه‌ی عددی $ACOR^{17}$ ، توزیع احتمال گسسته به یک تابع چگالی احتمال پیوسته تبدیل شده است. در محاسبه‌ی عددی $ACOR$ از یک بایگانی برای ذخیره‌ی مجموعه راه‌حل‌ها استفاده می‌شود. برای یک سامانه با n متغیر تصمیم، k تابع گاوسی منفرد برای هر متغیر تصمیم در بایگانی داده شده تنظیم می‌شود. راه‌حل‌های موجود در بایگانی مطابق با کیفیت آن‌ها به‌ترتیب نزولی مرتب و ذخیره می‌شوند (لیائو و همکاران ۲۰۱۴). فرآیند به‌روزرسانی محتوای فرمون در محاسبه‌ی عددی $ACOR$ با ذخیره‌ی راه‌حل‌های برتر و حذف راه‌حل‌های ضعیف در بایگانی راه‌حل‌ها انجام می‌شود. در این پژوهش، ۷۰٪ داده‌ها برای آموزش شبیه‌سازی، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمون شبیه‌سازی شده است. ویژگی‌های استفاده شده در شبیه‌سازی در جدول (۴) آمده است. از شبکه‌ی عصبی برای ساخت سامانه‌ی حالتی شبکه‌های عصبی مصنوعی از روش حالتی براساس رابطه‌ی بین متغیرهای ورودی و خروجی استفاده شد. سپس ساختار شبیه‌سازی با ویژگی‌های متناسب با ورودی‌ها، درجه‌ی عضویت و قانون‌ها انتخاب شد. بخشی از داده‌های موجود که تمام خصوصیت‌های بیشینه و کمینه‌ی داده‌ها را داشتند انتخاب شدند و در مرحله‌ی آموزش با کمینه‌سازی میزان خطا، اندازه‌های شبیه‌سازی به اندازه‌های واقعی نزدیک شدند. پس از آموزش شبیه‌سازی و انتخاب ویژگی‌های مناسب، صحت‌سنجی شبیه‌سازی انجام

16 - Ant Colony Optimization

17 - ACO Continuous

برای شبیه‌سازی نمایه‌ی SPI متغیرهای ورودی به شبکه، ساختار شبکه‌ی عصبی مطابق با مقیاس‌های زمانی ۳، ۶، ۹ و ۱۲ ماهه در چهار لایه بررسی شد (جدول ۳). در این ساختار n تعداد نرون لایه‌ی میانی و SPI(t+1) متغیر خروجی شبکه است. افزایش متغیرهای ورودی در بخش آموزش سبب بهینه‌سازی در مقیاس محلی شد و در لایه‌ی پنجم ضریب واستجی افزایش دقت قابل توجهی در مقایسه با متغیرهای قبلی نشان نداد.

و $m' \in [1, \infty]$ است. برای شبیه‌سازی خشک‌سالی از برنامه‌ی پایتون و بارش ماهانه استفاده شد.

$$\text{Overall output} = Q_i^5 = \frac{\sum_i W_i f_i}{\sum_u W_i} \quad (14)$$

$$\text{Jm}(\tilde{U}, V) = \sum_{i=1}^c \sum_{j=1}^n (u_{ij})^{m'} (d_{ij})^2 \quad (15)$$

$$d_{ij} = \left[\sum_{k=1}^m (x_{kj} - v_{ki})^2 \right]^{\frac{1}{2}}$$

جدول ۳- متغیرهای ورودی و ساختار شبکه.

Table 3- Input Variables and Network Structure.

Neural Network Structure	Input Variables	Validation	Calibration
(2 n, 1)	SPIt, SPI t-1	0.79	0.61
(3 n, 1)	SPIt, SPIt-1, SPIt-2	0.84	0.76
(4 n, 1)	SPIt, SPIt-1, SPIt-2, SPIt-3	0.89	0.79
(5 n, 1)	SPIt, SPIt-1, SPIt-2, SPIt-3, SPIt-4	0.91	0.80
(6 n, 1)	SPIt, SPIt-1, SPIt-2, SPIt-3, SPIt-4, SPIt-5	0.92	0.805

جدول ۴- ویژگی‌های استفاده شده‌ی هر روش در پیش‌بینی SPI.

Table 4- Features Used by Each Method in SPI Prediction.

Simulation	Attributes
ANFIS	The Type of Membership Function in the First to Fourth Layers is Gaussian and in the Fifth Layer it is Linear. Sogno-type State Inference System
ANFIS-ACOR	Data From the Deductive Clustering Method and the Number of Repetitions: 2000 Selection Pressure (Intensity Factor): 0.5, Distance-Error Rate: 1, Sample Size: 500, Number of Replications: 2000

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (\bar{Y} - Y_i)^2} \quad (10)$$

خطای مطلق^{۱۹}

خطای مطلق نشانه‌ی نبودن قطعیت اندازه‌ی برآورد شبیه‌سازی با اندازه‌ی حقیقی اندازه‌گیری است.

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |X_i - Y_i| \quad (11)$$

خطای جذر میانگین مربع‌ها^{۲۰}

تفاوت میان اندازه‌ی پیش‌بینی شده به‌وسیله‌ی شبیه‌سازی یا برآوردگر آماری و اندازه‌ی واقعی است.

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2} \quad (12)$$

X_i و Y_i و m به‌ترتیب اندازه‌ی اُامین پیش‌بینی و اندازه‌ی اُامین مشاهده و تعداد داده است.

در این پژوهش از میزان‌های ضریب تعیین، خطای مطلق و خطای جذر میانگین مربع‌ها (معادله‌های ۱۰ تا ۱۲) استفاده شده است (چیکو و همکاران ۲۰۲۱).

ضریب تعیین^{۱۸}

این ضریب میزان احتمال هم‌بستگی میان دو دسته داده در آینده است. نتایج تقریبی، ویژگی مد نظر در آینده را براساس شبیه‌سازی ریاضی تعریف می‌کند و با داده‌های موجود مطابقت می‌دهد. ضریب تعیین نشان می‌دهد چند درصد تغییر متغیرهای وابسته در یک شبیه‌سازی وایازی (رگرسیون) با متغیر مستقل تبیین می‌شود. به‌عبارت دیگر، چه اندازه از تغییرهای متغیر وابسته‌ی مسئله تحت تأثیر متغیر مستقل مسئله بوده است. همچنین تا چه حدی تغییرهای متغیر وابسته‌ی مسئله، مربوط به سایر عامل‌های موجود در مسئله است. معادله‌ی این ضریب به‌شکل رابطه‌ی ۱۰ است.

18 - Coefficient of determination (R2 or R-squared)

19 - Mean Absolute Error (MAE)

20 - Root Mean Square Error (RMSE)

نتایج

در این پژوهش از شبیه‌سازی ترکیبی انفیس-کلونی مورچه‌ها برای پیش‌بینی خشک‌سالی و برآورد نمایه‌های ۳-SPI، ۶-SPI، ۹-SPI و ۱۲-SPI در دو ایستگاه زابل و زهک آبخیز زابل استفاده شد. نتایج بخش‌های آموزش، اعتبارسنجی و آزمون این شبیه‌سازی‌ها با استفاده از انفیس و شبیه‌سازی ترکیبی انفیس-کلونی مورچه‌ها در جدول‌های ۵ تا ۱۲ نشان داده شده است. اعتبارسنجی شبیه‌سازی انفیس و انفیس-کلونی مورچه‌ها در نمایه‌ی ۳ ماهه نشان داد که اندازه‌ی خطای مطلق و خطای جذر میانگین مربع‌ها در ایستگاه زابل با کاربرد شبیه‌سازی انفیس کمتر است و در مقایسه با شبیه‌سازی انفیس-کلونی مورچه‌ها ضریب تعیین بالاتری دارد. در اعتبارسنجی شبیه‌سازی نمایه‌ی ۳ ماهه‌ی شبیه‌سازی انفیس-کلونی مورچه‌ها، اندازه‌ی خطای مطلق و خطای جذر میانگین مربع‌ها کمتر و ضریب تعیین بالاتر بود. در ایستگاه زهک نیز شبیه‌سازی انفیس در آموزش ۳ ماهه دقت بالاتری داشت، اما در بخش اعتبارسنجی برتری با شبیه‌سازی انفیس-کلونی مورچه‌ها بود. به‌طور کلی در نمایه‌ی ۳-SPI سه ماهه، آموزش شبیه‌سازی با کاربرد انفیس دقت بالاتری داشت اما در اعتبارسنجی، شبیه‌سازی انفیس-کلونی مورچه‌ها برتری داشت. در آزمون هر دو ایستگاه در نمایه‌ی ۳-SPI سه ماهه، شبیه‌سازی انفیس-کلونی مورچه‌ها کارایی بالاتری در مقایسه با انفیس داشت. در نمایه‌ی ۳-SPI شش ماهه، نتایج شبیه‌سازی انفیس-کلونی مورچه‌ها در سه بخش آموزش، اعتبارسنجی و آزمون در هر دو ایستگاه دقت بالاتری داشت. نمایه‌ی ۳-SPI نه ماهه ایستگاه زابل نشان داد که شبیه‌سازی انفیس-کلونی مورچه‌ها در بخش آموزش، اعتبارسنجی و آزمون ضریب تعیین بالاتری در مقایسه با انفیس داشت. نمایه‌ی ۳-SPI نه ماهه در ایستگاه زهک در دو بخش آموزش و اعتبارسنجی دقت شبیه‌سازی انفیس، نتایج بهتری را نشان داد اما، در بخش آزمون همچنان برتری با شبیه‌سازی انفیس-کلونی مورچه‌ها بود. نمایه‌ی ۱۲-SPI ماهه‌ی ایستگاه زابل در بخش آموزش دقت بیشتر شبیه‌سازی انفیس را نشان داد اما، در بخش اعتبارسنجی شبیه‌سازی انفیس-کلونی مورچه‌ها دقت بالاتری داشت. در ایستگاه زهک در هر دو بخش آموزش و اعتبارسنجی شبیه‌سازی انفیس، ضریب تعیین بالاتر و میزان خطای مطلق کمتر بود. سرانجام آزمون شبیه‌سازی‌ها نشان داد که شبیه‌سازی انفیس-کلونی مورچه‌ها دقت بیشتری در مقایسه با انفیس داشت.

به‌طور کلی در مقیاس‌های ۳، ۶، ۹ و ۱۲ ماهه در بخش آموزش شبیه‌سازی، عملکرد انفیس دقت بهتری را نشان می‌دهد. بخش اعتبارسنجی و آزمون شبیه‌سازی نشان داد در نمایه‌های بررسی

شده، در شبیه‌سازی انفیس ترکیب شده با کلونی مورچه‌ها، اندازه‌های ضریب تعیین بالاتر و اندازه‌های خطای مطلق و خطای جذر میانگین مربع‌ها کمتر بود. اندازه‌های به‌دست آمده از شبیه‌سازی‌های انفیس و انفیس-کلونی مورچه‌ها و اندازه‌های مشاهده شده در شکل‌های ۳ و ۴ نشان داده شده است. داده‌های مشاهده شده در مدت زمان پژوهش در دو ایستگاه زابل و زهک با رنگ سبز نشان داده شده است. نمودار به سه بخش آموزش، اعتبارسنجی و آزمون در دو شبیه‌سازی انفیس و انفیس-کلونی مورچه‌ها تقسیم شده است. شبیه‌سازی‌های نشان داده شده در نمایه‌های ۳ و ۱۲ ماهه به‌ترتیب بیشترین خطا و کمترین خطای شبیه‌سازی را داشتند. در بخش آزمون، شبیه‌سازی در ایستگاه‌های معرفی شده مطابقت بیشتری با داده‌های مشاهده شده داشت. تعیین خشک‌سالی با استفاده از شبیه‌سازی انفیس-کلونی مورچه‌ها شبیه‌سازی بهتری در مقایسه با انفیس نشان داد اما، این شرایط در تمام نمایه‌ها وجود نداشت. کمترین اندازه‌ی خطای جذر میانگین مربع‌ها در اعتبارسنجی انفیس-کلونی مورچه‌ها و ۳-SPI دوازده ماهه‌ی ایستگاه زابل به‌اندازه‌ی ۰/۳۰۱ بود. با کاربرد شبیه‌سازی انفیس در اعتبارسنجی ۳-SPI سه ماهه‌ی ایستگاه زابل بیشترین اندازه‌ی خطای جذر میانگین مربع‌ها ۰/۵۴۱ مشاهده شد. در بخش اعتبارسنجی داده‌های ایستگاه زابل کمترین خطای مطلق، نمایه‌ی ۳-SPI دوازده ماهه‌ی شبیه‌سازی انفیس-کلونی مورچه‌ها ۰/۲۱۱ بود. در آزمون نمایه‌ی ۳-SPI سه ماهه‌ی ایستگاه زهک در شبیه‌سازی انفیس، بیشترین خطای مطلق ۰/۴۲۱ بود. به‌طور کلی استفاده از هر دو روش در نقاط کمینه و بیشینه کارایی لازم را نداشت. زیرا این شبیه‌سازی‌ها توانایی حذف تغییرهای ناگهانی یا مهار نقاط بیشینه یا کمینه را ندارند. پیش‌پردازش داده‌ها به کاهش خطای این نقاط کمک می‌کند اما در ساختار طبیعی اندازه‌های حدی اشکال ایجاد می‌کند. یکی از علت‌های افزایش اندازه‌ی خطای جذر میانگین مربع‌ها در شبیه‌سازی‌ها، اندازه‌های حدی شبیه‌سازی است. با این حال ضریب تعیین هر دو شبیه‌سازی در ایستگاه‌ها کارایی بالاتری را در پیش‌بینی خشک‌سالی آبخیز زابل با استفاده از ۳-SPI در مقایسه با حالت ساده‌ی آن نشان داد. ارزیابی‌ها نشان داد شبیه‌سازی استفاده شده در پیش‌بینی هر ایستگاه هم‌دید ممکن است متفاوت باشد. به‌عبارت دیگر شبیه‌سازی‌های پیشنهاد شده در هر ایستگاه رفتاری متفاوت با ایستگاه مجاور خواهد داشت و در ۳-SPI های مختلف نیز این خصوصیت تکرار می‌شود. بنابراین در جدول‌های ۵ تا ۱۲ برای هر کدام از شبیه‌سازی‌ها، ایستگاه‌ها، دوره‌های ارزیابی و بخش‌های آموزش، اعتبارسنجی و آزمون نتایج به‌صورت جداگانه آمده است.

جدول ۵- نتایج آموزش و اعتبارسنجی در پیش‌بینی SPI3.

Table 5- Training and Validation Results in SPI3 Prediction.

Station	Simulation	Statistical Criteria					
		Training			Validation		
		MAE	R ²	RMSE	MAE	R ²	RMSE
Zabol	ANFIS	0.241	0.877	0.397	0.281	0.812	0.541
	ANFIS-ACOR	0.298	0.759	0.431	0.272	0.896	0.489
Zahak	ANFIS	0.325	0.821	0.422	0.387	0.798	0.401
	ANFIS-ACOR	0.386	0.801	0.448	0.311	0.857	0.382

جدول ۶- نتایج آزمون شبیه‌سازی در پیش‌بینی SPI3.

Table 6- Simulation Test Results in SPI3 Prediction.

Station	Simulation	Statistical Criteria		
		MAE	R ²	RMSE
Zabol	ANFIS	0.398	0.682	0.528
	ANFIS-ACOR	0.322	0.738	0.467
Zahak	ANFIS	0.421	0.721	0.486
	ANFIS-ACOR	0.368	0.792	0.422

جدول ۷- نتایج آموزش و اعتبارسنجی در پیش‌بینی SPI6.

Table 7- Training and Validation Results in SPI6 Prediction.

Station	Simulation	Statistical Criteria					
		Training			Training		
		MAE	R ²	RMSE	MAE	R ²	RMSE
Zabol	ANFIS	0.288	0.821	0.375	0.412	0.735	0.411
	ANFIS-ACOR	0.267	0.850	0.362	0.367	0.784	0.315
Zahak	ANFIS	0.294	0.831	0.421	0.313	0.698	0.457
	ANFIS-ACOR	0.291	0.874	0.401	0.301	0.752	0.367

جدول ۸- نتایج آزمون شبیه‌سازی در پیش‌بینی SPI6.

Table 8- Simulation Test Results in SPI6 Prediction.

Station	Simulation	Statistical Criteria		
		MAE	R ²	RMSE
Zabol	ANFIS	0.401	0.810	0.472
	ANFIS-ACOR	0.387	0.854	0.421
Zahak	ANFIS	0.385	0.794	0.531
	ANFIS-ACOR	0.354	0.804	0.498

جدول ۹- نتایج آموزش و اعتبارسنجی در پیش‌بینی SPI9.

Table 9- Training and Validation Results in SPI9 Prediction.

Station	Simulation	Statistical Criteria					
		Training			Training		
		MAE	R ²	RMSE	MAE	R ²	RMSE
Zabol	ANFIS	0.271	0.785	0.367	0.347	0.657	0.422
	ANFIS-ACOR	0.257	0.812	0.302	0.321	0.728	0.409
Zahak	ANFIS	0.238	0.848	0.382	0.289	0.791	0.421
	ANFIS-ACOR	0.248	0.821	0.399	0.302	0.590	0.474

جدول ۱۰- نتایج آزمون شبیه‌سازی در پیش‌بینی SPI9

Table 10- Simulation Test Results in SPI9 Prediction.

Station	Simulation	Statistical Criteria		
		MAE	R ²	RMSE
Zabol	ANFIS	0.374	0.741	0.489
	ANFIS-ACOR	0.304	0.801	0.425
Zahak	ANFIS	0.397	0.698	0.467
	ANFIS-ACOR	0.311	0.759	0.411

جدول ۱۱- نتایج آموزش و اعتبارسنجی در پیش‌بینی SPI12

Table 11- Training and Validation Results in SPI12 Prediction.

Station	Simulation	Statistical Criteria					
		Training			Training		
		MAE	R ²	RMSE	MAE	R ²	RMSE
Zabol	ANFIS	0.234	0.890	0.321	0.330	0.837	0.385
	ANFIS-ACOR	0.247	0.878	0.369	0.211	0.849	0.301
Zahak	ANFIS	0.278	0.921	0.312	0.226	0.878	0.324
	ANFIS-ACOR	0.324	0.883	0.328	0.308	0.826	0.374

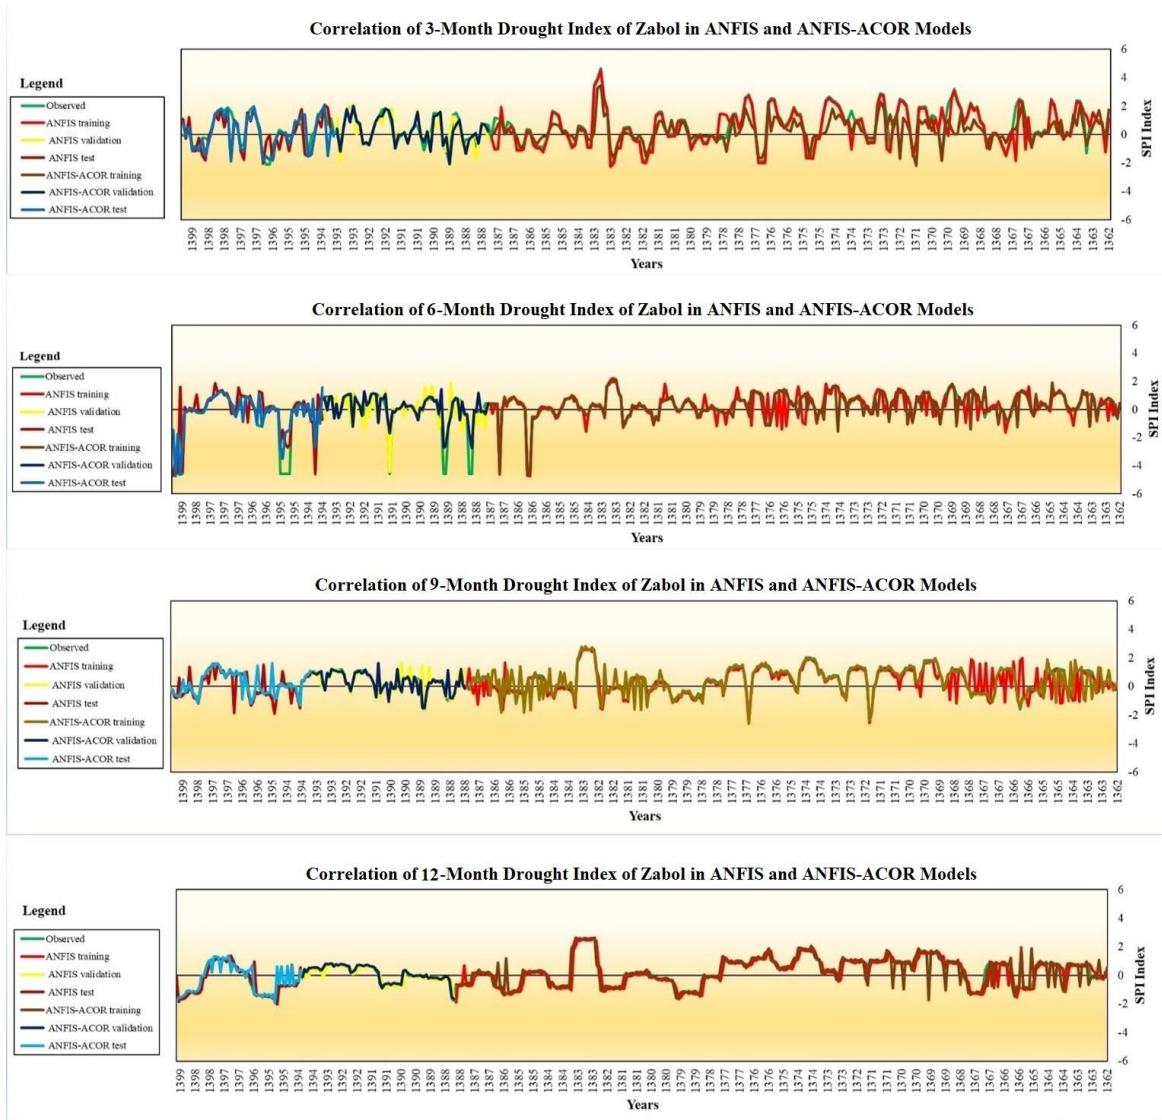
جدول ۱۲- نتایج آزمون شبیه‌سازی در پیش‌بینی SPI12

Table 12- Simulation Test Results in SPI12 Prediction.

Station	Simulation	Statistical Criteria		
		MAE	R ²	RMSE
Zabol	ANFIS	0.357	0.874	0.459
	ANFIS-ACOR	0.294	0.898	0.397
Zahak	ANFIS	0.366	0.815	0.421
	ANFIS-ACOR	0.301	0.887	0.384

شبیه‌سازی را از روش مداخله مهار کرد. داده‌ها به صورت بطئی تغییر کردند و خطای به دست آمده در تمام شبکه (آموزش، اعتبارسنجی و آزمون) به صورت یکنواخت توزیع یافت. در حالتی که فقط نقاط کمینه و بیشینه در مقایسه با میانگین بلندمدت تنظیم شد، به ویژه در بخش آموزش و اعتبارسنجی، ساختار شبکه خود تنظیم شد. نتایج شبیه‌سازی دقت بیشتری پیدا کرد و ضریب تعیین بالاتری در مقایسه با بهنجارسازی داده‌ها به دست آمد. در حالت سوم با استفاده از داده‌های خام، ضریب تعیین کاهش و خطای مطلق و خطای جذر میانگین مربع‌ها در مقایسه با بهنجارسازی داده‌ها افزایش یافت. اما ضریب تأثیر اندازه‌های داده‌های تاریخی ثبت شده در آن حفظ شد که با داده‌های ثبت شده مطابقت داشت. به عبارت دیگر ارزش داده‌ها حفظ شد و در فرآیند شبیه‌سازی وزن داده‌ها به کار گرفته شد. نتایج این ارزیابی در شکل‌های ۳ و ۴ ایستگاه‌ها نشان داده شده است.

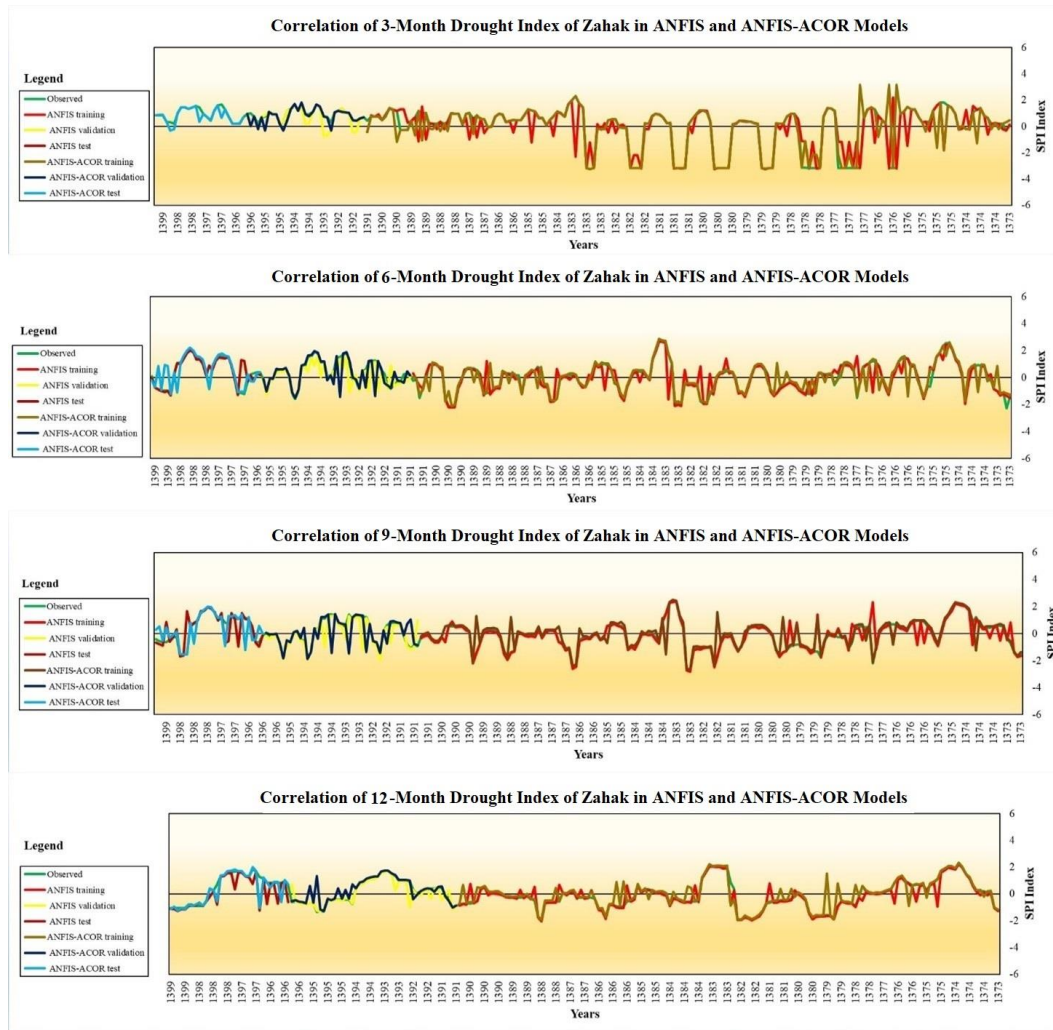
تغییرهای نمایه‌ی SPI در ایستگاه هم‌دید زهک در مقایسه با ایستگاه زابل با توجه به دوره‌ی زمانی مشابه (۱۳۷۳ تا ۱۳۹۹) شدیدتر است. این تغییرها سبب کاهش دقت پیش‌بینی در شبیه‌سازی می‌شود. نقاط بیشینه و کمینه‌ی این نمایه، بخش‌های آموزش و آزمون شبیه‌سازی را بیشتر تحت تأثیر قرار می‌دهد. علاوه بر این، تغییرهای دمایی در سال‌های اخیر پیش‌بینی را با خطای بیشتری برآورد می‌کند. در نمایه‌ی ۶ ماهه‌ی ایستگاه زابل و ۳ ماهه‌ی زهک، نقاط بیشینه و کمینه تغییرهای شدیدتری داشت. خشک‌سالی‌های کوتاه‌مدت، فراوانی وقوع بالاتری داشتند و با افزایش مقیاس زمانی، فراوانی خشک‌سالی کاهش یافت. ساختار داده‌ها در سه حالت خام یا طبیعی، بهنجار شده و حذف نقاط کمینه و بیشینه‌ی تاریخی به وسیله‌ی کاربر انجام شد. در حالت بهنجار شده، داده‌ها از ضریب تعیین فاصله ثابتی داشتند و خطای مطلق به صورت یکسان سبب فیلتر داده‌ها و مهار کردن اندازه‌های بیشینه و کمینه شد. این شرایط پیش‌بینی،



شکل ۳- نمودار اندازه‌های مشاهده شده‌ی SPI و اندازه‌های محاسبه شده‌ی شبیه‌سازی ANFIS و ANFIS-ACOR در ایستگاه زابل.
 Figure 3- The Graph of the Observed SPI Values and the Calculated Values of ANFIS-ACOR and ANFIS Simulation at Zabol Station.

زهدک، ۶ ماهه‌ی زابل، ۶ ماهه‌ی زهدک، ۹ ماهه‌ی زابل، ۳ ماهه‌ی زهدک، ۹ ماهه‌ی زهدک و ۳ ماهه‌ی زابل به‌دست آمد. در شبیه‌سازی انفیس-کلونی مورچه‌ها به‌ترتیب بیشترین ضریب تعیین را ۱۲ ماهه‌ی زابل، ۱۲ ماهه‌ی زهدک، ۶ ماهه‌ی زابل، ۹ ماهه‌ی زهدک، ۳ ماهه‌ی زهدک، ۹ ماهه‌ی زهدک و ۳ ماهه‌ی آبخیز زابل داشتند. براساس نتایج، بیشترین دقت در پیش‌بینی خشک‌سالی با استفاده از ترکیب شبیه‌سازی انفیس و کلونی مورچه‌ها در آبخیز زابل بود.

میانگین اندازه‌های ضریب تعیین شبیه‌سازی‌ها در جدول ۱۳ نشان داده شده است. کارایی شبیه‌سازی‌ها در بخش پیش‌بینی، برتری شبیه‌سازی انفیس-کلونی مورچه‌ها را در مقایسه با انفیس تأیید کرد. میانگین اندازه‌های ضریب تعیین در شبیه‌سازی انفیس-کلونی مورچه‌ها برابر با ۰/۸۱۶ و در شبیه‌سازی انفیس ۰/۷۶۶ بود. بیشترین میانگین اندازه‌های ضریب تعیین در ایستگاه زابل و زهدک با کاربرد شبیه‌سازی انفیس-کلونی مورچه‌ها به‌ترتیب ۰/۸۲۲ و ۰/۸۱۰ به‌دست آمد. در شبیه‌سازی انفیس، بیشترین اندازه‌ی ضریب تعیین نمایه‌ی SPI به‌ترتیب در ۱۲ ماهه‌ی زابل، ۱۲ ماهه‌ی



شکل ۴- نمودار اندازه‌های مشاهده شده SPI و اندازه‌های محاسبه شده‌ی شبیه‌سازی ANFIS-ACOR و ANFIS در ایستگاه زهک.
 Figure 4- The Graph of the Observed SPI Values and the Calculated Values of ANFIS-ACOR and ANFIS Simulation at Zahak Station.

جدول ۱۳- میانگین اندازه‌های ضریب تعیین شبیه‌سازی‌های ANFIS و ANFIS-ACOR

Row	Simulation	Station	SPI	Zabol Test	Zahak Test	The Average Values of the Coefficient of Determination in the Simulation Test
1	ANFIS	Zabol	3	0.682	-	0.766
		Zahak		-	0.721	
Zabol		6	0.810	-		
Zahak			-	0.794		
Zabol		9	0.741	-		
Zahak			-	0.698		
Zabol		12	0.874	-		
Zahak			-	0.815		
ANFIS Average				0.776	0.757	
5	ANFIS-ACOR	Zabol	3	0.738	-	0.816
		Zahak		-	0.792	
Zabol		6	0.854	-		
Zahak			-	0.804		
Zabol		9	0.801	-		
Zahak			-	0.759		
Zabol		12	0.898	-		
Zahak			-	0.887		
ACOR-ANFIS Average				0.822	0.810	
Total Average of Both Stations				0.816	0.783	-

بحث و نتیجه‌گیری

مورچه‌ها مبتنی بر جمعیت داده‌ها به تدریج راه‌حل‌های پیشنهاد شده را به راه‌حل بهینه‌ی سراسری نزدیک می‌کند. این مسئله سبب افزایش کارایی محاسبه‌ی عددی کلونی مورچه‌ها در مقایسه با انفیس در پیش‌بینی خشک‌سالی شد. دوره‌ی آموزش ایستگاه زهک در مقایسه با زابل کوتاه‌تر بود. این خصوصیت در شبیه‌سازی، سبب کاهش دقت پیش‌بینی در شبیه‌سازی در مقایسه با ایستگاه زابل شد. شبیه‌سازی انفیس ترکیب شده با کلونی مورچه‌ها حل مسائل با مقیاس بزرگ و در زمان کوتاه‌تر از روش خودتنظیمی پیشنهاد داد. این خصوصیت‌ها برای داده‌های طبیعی که الگوی هندسی منظمی ندارند و یا داده‌های ثبت شده حجم بالایی دارند هزینه‌ی محاسبه‌ی اطلاعات خروجی را کاهش می‌دهند. شبیه‌سازی‌هایی که بهینه‌سازی می‌کنند در نقاط بهینه‌ی محلی دچار خطا می‌شوند. این در حالی است که شبیه‌سازی انفیس-کلونی پیش‌بینی خشک‌سالی را در فضای سراسری ارزیابی می‌کند. همچنین پیش‌بینی خشک‌سالی SPI دوازده ماهه بیشترین دقت را در هر دو شبیه‌سازی نشان داد. به عبارت دیگر پیش‌بینی بلندمدت در مقایسه با کوتاه‌مدت با کاهش یا نرم کردن ناریبی داده‌ها آموزش شبیه‌سازی را آسان کرد و این مسئله با پژوهش‌های عباسی و همکاران (۲۰۲۰) مطابقت داشت. براساس پژوهش‌های صادقیان و همکاران (۲۰۲۰) شبیه‌سازی انفیس در مقایسه با شبیه‌سازی‌های سری

نتایج پژوهش نشان داد استفاده از شبیه‌سازی انفیس همراه با کلونی مورچه‌ها سبب افزایش دقت پیش‌بینی خشک‌سالی در آبخیز زابل شد. استفاده از نمایه‌ی SPI در مقیاس‌های زمانی ۳، ۶، ۹ و ۱۲ ماهه همراه با شبیه‌سازی انفیس-کلونی مورچه‌ها در بازه‌های زمانی کوتاه‌تر در پیش‌بینی خشک‌سالی دقت کمتری داشت. علت این مسئله فراوانی وقوع خشک‌سالی کوتاه مدت است. به‌طور کلی استفاده از شبیه‌سازی انفیس همراه با کلونی مورچه‌ها ۵٪ دقت بیشتر داشت. با استفاده از بهنجارسازی داده‌ها دقت ناحیه‌ای شبیه‌سازی افزایش یافت، اما دقت کل شبکه با داده‌های مشاهده شده مطابقت نداشت. داده‌های تاریخی در شبیه‌سازی انفیس-کلونی مورچه‌ها در حالت بهنجارسازی شده و طبیعی استفاده شد و نتایج نشان داد ناهنجاری داده‌ها را می‌توان در این روش به‌خوبی شبیه‌سازی کرد. این یافته، پژوهش‌های شادمهری و همکاران (۲۰۱۵) را در شبیه‌سازی اندازه‌های حدی تأیید می‌کند. شبیه‌سازی انفیس ترکیب شده با کلونی مورچه‌ها به دلیل شبیه‌سازی داده‌ها با هندسه‌ی پیچیده می‌تواند در پیش‌بینی خشک‌سالی عملکرد بهتری داشته باشد. نتایج این پژوهش از شبیه‌سازی پیشنهاد شده برای هر دو ایستگاه در آبخیز زابل دقت شبیه‌سازی کلونی مورچه‌ها در مقایسه با شبیه‌سازی انفیس بهبود یافته و آزمون شبیه‌سازی انجام شد. بهینه‌سازی با کاربرد کلونی

تشکر و قدردانی

این مقاله برگرفته از یافته‌های طرح تحقیقاتی با عنوان بررسی زیست‌پذیری آبخیزها و ارتباط آن با نمایه‌های خشک‌سالی (مطالعه‌ی موردی: زابل، سلسله و خرم‌آباد) با کد مصوب ۰۰۰۹۰۶-۰۴۹-۲۹-۶۶-۰ است. نویسنده تشکر صمیمانه‌ی خود را از حمایت مادی و معنوی پژوهش‌شکده‌ی حفاظت خاک و آبخیزداری در انجام این پژوهش را اعلام می‌کند.

زمانی و شبکه‌ی عصبی دقت بالاتری دارد و این پژوهش در گامی فراتر شبیه‌سازی انفیس و انفیس-کلونی مورچه‌ها را برای پیش‌بینی خشک‌سالی با یکدیگر مقایسه کرد. نتایج نشان داد شبیه‌سازی انفیس توانست با سایر شبیه‌سازی‌های بهبود یافته سازگار شده و دقت بالاتری را نشان دهد. پیشنهاد می‌شود شبیه‌سازی انفیس با محاسبه‌ی عددی‌های دیگر مقایسه شود و بهترین شبیه‌سازی برای آبخیز زابل انتخاب شود.

فهرست منابع

- Abbasi A, Khalili K, Behmanesh J, Shirzad A. 2020. Application of support vector machine and bayesian network for agricultural drought prediction. *Watershed engineering and management*. 12(1): 107-124. (In Persian).
- Aghelpour P, Bahrami Pichaghchi H, Kisi O. 2020. Comparison of three different bio-inspired algorithms to improve ability of neuro fuzzy approach in prediction of agricultural drought, based on three different indexes. *Computers and Electronics in Agriculture*. 170(3): 257-279.
- Ali M, Deo RC, Maraseni T, Downs NJ. 2019. Improving SPI-derived drought forecasts incorporating synoptic-scale climate indices in multi-phase multivariate empirical mode decomposition model hybridized with simulated annealing and kernel ridge regression algorithms. *Journal of Hydrology*. 576(1): 164-184.
- Bera B, Shit PK, Sengupta N, Saha S, Bhattacharjee S. 2021. Trends and variability of drought in the extended part of Chhota Nagpur plateau (Singbhum Protocontinent), India applying SPI and SPEI indices. *Environmental Challenges*. 5(100310): 1-10.
- Chicco D, Warrens MJ, Jurman G. 2021. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *Peer Review Journal Computer Science*. 7(623): 1-24.
- Gandomkar A, Khadem Alhosseini A. 2009. The study of precipitation changes on zabol (Iran). *Environmental based territorial planning*. 2(6): 65-76. (In Persian).
- Jahangir M, Noorazar I, Azimi E. 2019. Analyzing time series of spi, spei and spti drought indices by using artificial neural network sofm method and numerical comparison in chaharmahal va bakhtiari. *Iranian journal of ecohydrology*. 6(3): 837-847. (In Persian).
- Jang JSR. 1991. Fuzzy modeling using generalized neural networks and Kalman filter algorithm. *Proceedings of the ninth national conference on artificial intelligence*. pp.762-767.
- Khadka D, Babel MS, Shrestha S, Viridis SGP, Collins M. 2021. Multivariate and multi-temporal analysis of meteorological drought in the northeast of Thailand. *Weather and Climate Extremes* 34(100399): 1-18.
- Khan MMH, Muhammad NS, El-Shafie A. 2020. Wavelet based hybrid ANN-ARIMA models for meteorological drought forecasting. *Journal of Hydrology*. 590(125380): 1-14.
- Kisi O, Docheshmeh Gorgij A, Zounemat-Kermani M, Mahdavi Meymand A, Kim S. 2019. Drought forecasting using novel heuristic methods in a semi-arid environment. *Journal of Hydrology*. 578(124053): 1-19.
- Komasi M, Alami M, Nourani V. 2013. Drought forecasting by spi index and anfis model using Fuzzy C-mean clustering. *Water and wastewater*. 24(4): 90-102. (In Persian).
- Komasi M, Malekmahmoudi M, Montaseri H. 2017. Drought forecasting by spi and edi indices using anfis method based on C-mean and sc clustering (case study: kohgiluyeh and boyer ahmad province). *Journal of agricultural meteorology*. 5(1): 36-47. (In Persian).
- Komasi M, Sharghi S. 2020. Drought Forecasting Using Wavelet-Support Vector Machine and Standardized Precipitation Index (Case Study: Urmia Lake-Iran). *Journal of environmental science and technology*. 22(7): 83-101. (In Persian).
- Liao T, Stützle T, Montes de Oca MA, Dorigo

- M. 2014. A unified ant colony optimization algorithm for continuous optimization. *European Journal of Operational Research*. 234(3): 597-609.
- Lloyd-Hughes B, Saunders MA. 2002. A drought climatology for Europe. *International Journal of Climatology*. 22(13): 1571-1592.
- McKee TB, Doesken NJ, Kleist J. 1993. The relationship of drought frequency and duration to time scales. *Eighth Conference on Applied Climatology*. 73(10). pp.1-6.
- Mishra AK, Singh VP. 2010. A review of drought concepts. *Journal of hydrology*. 391(1-2): 202-216.
- Nadi M, Shiukhy Soqanloo S. 2020. Comparison of SPI and SPImod in Drought Monitoring of Several Climatic Samples of Iran. *journal of watershed management research*. 11(21): 108-118. (In Persian).
- Pudineh M, Heidarinia M, Mousavi SR, Dousti Moghaddam H. 2020. Monitoring drought indicators in Zahedan at different time intervals. *Natural Geography*. 13(47): 133-143. (In Persian).
- Rahmati O, Panahi M, Kalantari Z, Soltani E, Falah F, Dayal KS, Mohammad F, Ravinesh CD, Tiefenbacher J, Dieu TB. 2020. Capability and robustness of novel hybridized models used for drought hazard modeling in southeast Queensland, Australia. *Science of The Total Environment*. 718(134656): 1-9.
- Sadeghian M, Karami H, Mousavi S. 2020. Evaluating the performance of time-series, neural network and neuro-fuzzy models in Prediction of Meteorological Drought (Case study: Semnan Synoptic Station). *Irrigation Sciences and Engineering*. 43(2): 1-18. (In Persian).
- Shadmehri MM, Sharifi M, Ebrahimzadeh Ardestani V, Safari A, Baghani A. 2015. Inversion of gravity data using ant colony algorithm (case study: gotvand-iran). *Journal of Geomatics Science and Technology*. 4(4): 193-207. (In Persian).
- Socha K, Dorigo M. 2008. Ant colony optimization for continuous domains. *European Journal of Operational Research*. 185(3): 1155-1173.
- Wilhite DA, Glantz MH. 1985. Understanding: the drought phenomenon: the role of definitions. *Water International*. 10(3): 111-120.
- Won J, Choi J, Lee O, Kim S. 2020. Copula-based Joint Drought Index using SPI and EDDI and its application to climate change. *Science of the Total Environment*. 744(140701):1-7.
- Yerdelen C, Abdelkader M, Eris E. 2021. Assessment of drought in SPI series using continuous wavelet analysis for Gediz Basin, Turkey. *Atmospheric Research*. 260(105687): 1-14.
- Zhang Y, Li W, Chen Q, Pu X, Xiang L. 2017. Multi-models for SPI drought forecasting in the north of Haihe River Basin, China. *Stochastic Environmental Research and Risk Assessment*. 31(10): 2471-2481.
- Zuo DD, Hou W, Zhang Q, Yan PC. 2021. Sensitivity analysis of standardized precipitation index to climate state selection in China. *Advances in Climate Change Research*. 13(1): 42-50.



Drought Prediction Using Compatible Adaptive Neuro Fuzzy Inference System with the Ant Colony Optimization Algorithm in Zabol Watershed

Payam Ebrahimi*

Assistant Professor, Forests, Rangelands and Watershed Research Department, Sistan Agricultural and Natural Resources Research and Education Center AREEO, Zabol, Iran

Extended Abstract

Introduction and Objective

The use of simulations combined with the drought index enhances forecast accuracy. The exploratory approach provides the scope for drought warning and the opportunity for financial support and insurance mechanisms for local communities. The most important part related to the reduction of the effects of drought is the improvement of the precision of forecasting systems.

Materials and Methods

In this research, the precision of the new Anfis Simulation combined with the meta-heuristics of ant colonies in drought prediction is compared to the normal ANFIS Simulation. Simulation performance is estimated using the Mean Squared Error, Mean Absolute Error and Coefficient of Determination.

Results and Discussion

Validation of the simulation in the three month profile shows that the Absolute Error Value and the Root Mean Square Error in the Zabol Station are lower by Anfis Simulation. This article examines the Compatible Adaptive Neuro Fuzzy Inference System (ANFIS) and ANFIS models with Ant Colony Optimization Algorithm (ANFIS-ACOR) for drought forecasting. Drought forecasting was done using monthly precipitation data from synoptic stations Zabol (1983-2020) and Zahak (1994-2020). The results showed (ANFIS-ACOR) improved the performance of the Adaptive

Article Type: Research Article

*Corresponding Author E-mail: p.ebrahimi@areeo.ac.ir

Citation: Ebrahimi, P. 2023. Drought Prediction Using Compatible Adaptive Neuro Fuzzy Inference System with the Ant Colony Optimization Algorithm in Zabol Watershed. *Watershed Management Research*. 36(2): 18-35.

DOI: 10.22092/wmtj.2022.359003.1478

Received: 14 June 2022, **Received in revised form:** 21 August 2022, **Accepted:** 21 September 2022,

Published online: 22 June 2023

Watershed Management Research, VOL. 36, No. 2, Ser. No: 139, Summer 2023, pp. 18-35.

Publisher: Fars Agricultural and Natural Resources Research and Education Center ©Author(s)



Neuro Fuzzy Inference System. The model predictive correlation test (ANFIS-ACOR) values in the 3, 6, 9 and 12-month intervals are equal to 0.738, 0.854, 0.801 and 0.898 at the Zabol Station. As well 0.792, 0.804, 0.759 and 0.887 at Zahak Station, respectively. In addition, Anfis Simulation - ant colony has a higher coefficient of determination. Validation of the simulation related to the three-month profile of Anfis-ant Colony Simulation showed that the absolute error and the Root Mean Square Error are lower and the coefficient of determination is higher. In the Zahak Station, the Anfis Simulation is more accurate in the 3-month formation, but in the validation section, the Anfis-ant Colony Simulation is superior. Overall, in the three-month SPI profile, Anfis Simulation training is more accurate, but Anfis Colony Simulation is superior in validation.

Conclusion and Suggestions

Ant colony optimization as a function of the data population progressively brings the proposed solutions closer to the overall optimal solution. This problem increased the efficiency of the numerical calculation of the ant colony compared with the Anfis in predicting drought. Anfis Simulation in combination with ant colony provides efficiency for large-scale problems in a short time by auto-tuning. These features reduce the cost of calculating natural data with irregular geometric pattern or data recorded in high volume. Simulations which optimize will fail at the local optimum level. Anfis-Ant Colony Simulation evaluates simulation space for predicting droughts on a global scale. This research proposes to compare the Anfis Simulation with other numerical calculations and to choose the best simulation for the Zabol Watershed.

Keywords: ANFIS, ANFIS-ACOR, drought, forecast, SPI