

مجله مخاطرات محیط طبیعی، سال چهارم، شماره ششم، زمستان ۹۴

تاریخ دریافت مقاله: ۹۳/۰۶/۱۷

تاریخ پذیرش مقاله: ۹۴/۱۱/۱۵

صفحات: ۲۱-۳۲

پیش‌بینی خشکسالی با بکارگیری از مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی در حوزه مُند استان فارس

مهناز رستمی^۱، دکتر احمد پهلوانروی^{*۲}، علیرضا مقدم نیا^۳

چکیده

امروزه خشکسالی یک معضل جدی و گربانگیر در بسیاری از کشورهای جهان است؛ بنابراین پیش‌بینی آن از اهمیت بهسزایی برخوردار می‌باشد. در این تحقیق، کارایی شبکه عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی به عنوان روش‌هایی مؤثر برای پیش‌بینی شدت خشکسالی حوزه "مُند" استان فارس مورد بررسی قرار گرفت. برای این منظور از داده‌های بارندگی ماهانه ایستگاه باران‌سنگی تنگاب استان فارس با دوره آماری ۳۲ ساله استفاده گردید. شدت خشکسالی در دوره ماهانه با استفاده از شاخص بارندگی استاندارد شده (SPI) تعیین شد؛ سپس بهوسیله مدل‌های ANN و ANFIS و با استفاده از شاخص SPI پیش‌بینی شدت خشکسالی انجام گردید. از بین داده‌های موجود، ۷۰ درصد به عنوان داده‌های آموزش و مابقی به عنوان داده‌های اعتبارسنگی و داده‌های آزمون انتخاب شد؛ سپس از طریق معیارهای آماری شامل ضریب همبستگی، میانگین مجذور مربعات خطأ و ضریب ناش به کارایی عملکرد مدل‌ها پرداخته شد. نتایج نشان داد که دقت روش شبکه‌های عصبی مصنوعی از روش سیستم استنتاج عصبی- فازی تطبیقی بیشتر می‌باشد؛ همچنین یافته‌های حاصل از این بررسی نشان می‌دهد که هرچه پراکنده‌تر داده‌های ورودی مدل بیشتر باشد مدل استنتاج عصبی- فازی تطبیقی دارای توانایی بیشتری در شبیه‌سازی این نوع از داده‌ها می‌باشد.

کلید واژه‌ها: خشکسالی، شبکه عصبی مصنوعی، سیستم استنتاج عصبی- فازی تطبیقی، شاخص SPI، حوزه آبریز مُند استان فارس.

۱- دانشجوی کارشناسی ارشد گروه آب و خاک دانشکده کشاورزی دانشگاه زابل

۲- دانشیار گروه آب و خاک دانشکده کشاورزی دانشگاه زابل (نویسنده مسئول)

۳- دانشیار گروه مرتع و آبخیزداری دانشکده کشاورزی دانشگاه تهران

مقدمه

خشکسالی وضعیتی از کمبود بارندگی و افزایش دماست که در هر وضعیت اقلیمی ممکن است رخ دهد (علیزاده، ۱۳۸۱: ۲۶۲). این وضعیت خطرات زیادی را برای یک منطقه ایجاد می‌کند؛ زیرا کاهش رطوبت سیستم‌های حیاتی را که به آب وابسته‌اند مختل می‌کند و چه بسا این سیستم‌ها از بین بروند (کاویانی و علیجانی، ۱۳۷۱: ۲۶۱). همچنین خشکسالی یکی از بلایای طبیعی است که در مقایسه با سایر بلایای طبیعی از نقطه نظر میزان، شدت، طول مدت واقعه، گسترش منطقه، تلفات جانی، خسارت‌های اقتصادی و اثرات بلندمدت از بلندترین درجات برخوردار است. خسارت‌های خشکسالی عمده‌تاً به شکل کاهش عملکرد مرتع، کاهش تولید محصولات زراعی - بهویژه دیم -، کاهش منابع آب کشاورزی و شرب، کاهش منابع آب سطحی و زیرزمینی، طفیان آفات و بیماری‌های گیاهی و دامی، افزایش مهاجرت و در نهایت اثرات سوء زیستمحیطی، اقتصادی و اجتماعی ظاهر می‌شود که توسعه پایدار منطقه را مورد تهدید قرار می‌دهد. بدیهی است خشکسالی یک پدیده خزنه است و نیاز به ارائه تکنیک‌ها و روش‌هایی برای پیش‌بینی نقطه شروع و خاتمه دوره خشک دارد. یک سیستم پیش‌بینی کار آمد می‌تواند در راهبرد بهینه سیستم‌های آبیاری مؤثر باشد؛ بدین خاطر متخصصان و دانشمندان علم هیدرولوژی و سایر رشته‌های مرتبط در پی ایجاد مدل‌هایی مناسب، به منظور پیش‌بینی به موقع این حوادث شده‌اند. ظهور تئوری‌های توانمندی همچون الگوریتم‌های فازی شبکه عصبی تحولی عظیم در تحلیل رفتار سیستم‌های دینامیک در علوم مختلف مربوط به آب ایجاد کرده است.

برای پیش‌بینی خشکسالی در ایستگاه "نوده" واقع در حوضه گرگان‌رود از دو نوع شبکه عصبی پرسپترون و پایه شعاعی استفاده شده است. بررسی نتایج حاصل از این پژوهش نشان داد که شبکه عصبی پرسپترون نسبت به شبکه پایه شعاعی دارای توانایی بیشتری جهت پیش‌بینی خشکسالی است و نتایج بهتری حاصل می‌شود (عیوضی و همکاران، ۱۳۸۱).

خشکسالی‌های هیدرولوژیک در استان همدان با استفاده از شبکه عصبی مصنوعی پیش‌بینی شده، نشان دادند که مدل تأخیر زمانی شبکه عصبی، تطابق بیشتری با مقادیر مشاهده‌ای دارد و روشی مطلوب در پیش‌بینی خشکسالی‌ها در آینده است (یزدانی و بازراذ، ۱۳۸۱).

برای پیش‌بینی خشکسالی در حوضه لیقوان‌چای از شاخص‌های پیش‌بینی خشکسالی و شبکه عصبی مصنوعی استفاده شده است که مشخص شد مدل شبکه عصبی کارایی بالاتری برای پیش‌بینی خشکسالی دارد (علمی و همکاران، ۱۳۸۱).

خشکسالی استان یزد با استفاده از داده‌های اقلیمی و مدل شبکه عصبی پیش‌بینی شده است؛ نتایج حاصل از این تحقیق انعطاف‌پذیری بالای شبکه عصبی نسبت به فقدان داده‌های ورودی و توانایی خوب این شبکه جهت پیش‌بینی خشکسالی را اثبات کرد (افخمی و همکاران، ۱۳۸۹).

در مطالعه‌ای با استفاده از شبکه عصبی مصنوعی و سیگنال‌های بزرگ مقیاس اقلیمی به مطالعه خشکسالی‌های ایران پرداخته شده است. نتایج حاصل از خروجی مدل عصبی نشان داد که طی فاز گرم^۱ ENSO و فاز منفی

^۱-El Nino Southern Oscillation (ENSO)

NAO، شرایط ترسالی و طی فاز سرد ENSO و مثبت NAO، شرایط خشکسالی، در ایران به وقوع می‌پیوندد (صدقت کردار و فتاحی، ۱۳۸۷).

پیش‌بینی خشکسالی در اسپانیا با استفاده از مدل شبکه عصبی مصنوعی صورت گرفته است که در آن از یک شبکه پرسپترون چند لایه و الگوریتم پسانتشار خطا برای آموزش شبکه استفاده نمودند. نتایج بررسی‌ها نشان داد که مدل شبکه عصبی مصنوعی می‌تواند پیش‌بینی‌هایی با دقت بالا از تعداد خشکسالی‌ها و طول متوسط خشکسالی ارایه نماید (کریسیو و مورا، ۱۹۹۳).

پیش‌بینی شاخص خشکسالی SPI با استفاده از شبکه عصبی انجام شده است؛ برای پیش‌بینی خشکسالی در حوضه رودخانه کاتاباتی از مدل هیبریدی و یک شبکه غیرخطی عصبی مصنوعی استفاده کردند نتایج نشان داد که مدل ترکیبی مورد نظر دقت بالایی برای پیش‌بینی خشکسالی دارد (میشر و دیسای، ۲۰۰۶). برای پیش‌بینی خشکسالی در سه منطقه از حوضه رودخانه سان فرانسیسکو در شمال شرق بربزیل روش شبکه‌های عصبی پسانتشار بکار گرفته شده است که نتایج دقت بالای مدل شبکه عصبی را تأیید کرد (سانتوس و همکاران، ۲۰۰۹).

برای پیش‌بینی خشکسالی از شبکه‌های عصبی و مدل‌های رگرسیونی در حوضه رودخانه اتیوپی لهستان استفاده شده است. هدف از پژوهش مقایسه روش شبکه عصبی و مدل‌های رگرسیونی، برای پیش‌بینی بلند مدت خشکسالی در مناطق خشک بوده است. که نتایج نشان داد مدل رگرسیون خطی کارایی بهتری از شبکه‌های عصبی مصنوعی می‌باشد (میشر و سینگ، ۲۰۱۲).

جهت بیان کمی خشکسالی از شاخص‌های خشکسالی استفاده شده است. با استفاده از این شاخص‌ها اطلاعات لازم درباره آغاز، خاتمه و شدت خشکسالی در مقیاس‌های زمانی و مکانی مختلف فراهم می‌آید. در بین انواع شاخص‌های ارائه شده برای این منظور، شاخص بارندگی استاندارد (SPI) بیشترین توجه محققین را به خود معطوف داشته است. این شاخص بر مبنای احتمالات بارندگی در مقیاس‌های زمانی مختلف ارائه گردیده است و بسیاری از محققین به توانایی آن در پایش جنبه‌های مختلف خشکسالی اشاره داشته‌اند (فرخ‌نیا و همکاران، ۱۳۸۷).

از مدل ANFIS^۱ به منظور پیش‌بینی خشکسالی در کشور ترکیه استفاده نمودند، مدل‌های پیش‌بینی مختلفی برای SPI با مقیاس‌های زمانی ۱، ۳، ۹ و ۱۲ ماهه مورد بررسی قرار گرفتند. نتایج نشان داد که ترکیب مقادیر پیش‌بینی بارندگی و شاخص SPI با یکدیگر، بهبود عملکرد مدل‌ها را به همراه دارد. مقایسه‌های انجام گرفته با نتایج روش‌های شبکه عصبی FFNN^۲ و رگرسیون خطی چندگانه، نشان از ارجحیت مدل ANFIS نسبت به دو مدل دیگر داشت (باکانلی و همکاران، ۲۰۰۱).

از قابلیت‌های سیستم استنتاج عصبی-فازی تطبیقی برای پیش‌بینی خشکسالی‌های پاییزه شهر زاهدان استفاده شده است. برای این منظور از متغیرهایی نظیر بارندگی و شاخص‌های اقلیمی به عنوان ورودی‌های مدل‌ها استفاده کردند و به پیش‌بینی شاخص خشکسالی SPI پاییزه پرداختند. نتایج نشان از قابلیت مدل ANFIS در پیش‌بینی

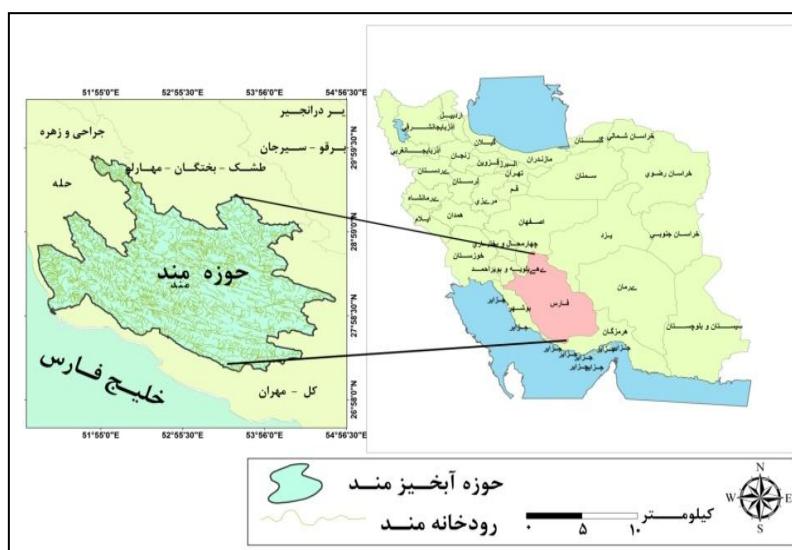
1-(ANFIS) Adaptive Neuro-Fuzzy Inference System
2-Fast Forward Neural Network (FFNN)

فصلی خشکسالی در منطقه مورد مطالعه داشت (نیکنام و همکاران، ۱۳۱۹). پیش‌بینی خشکسالی زاهدان با استفاده از مدل عصبی-فازی، شاخص‌های اقلیمی، بارندگی و شاخص خشکسالی انجام شده است؛ نتایج به دست آمده نشان داد که شاخص خشکسالی SPI تنها در بازه زمانی سه ماهه سپتامبر-اکتیر-نوامبر نتایج قابل قبولی را برای پیش‌بینی خشکسالی پاییزه به دست می‌دهد (اژدری مقدم و همکاران، ۱۳۹۰).

مطالعه حاضر تلاشی در جهت پیش‌بینی خشکسالی در ایستگاه سینوپتیک تنگاب حوزه مند است که در آن با استفاده از داده‌های بارندگی، دما و شاخص خشکسالی SPI به بررسی قابلیت مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی-فازی تطبیقی پرداخته شده است.

داده‌ها و روش شناسی

حوزه آبخیز رودخانه مند ۴۷۶۵۴ کیلومترمربع مساحت دارد که بخشی از حوزه آبریز خلیج فارس و دریای عمان می‌باشد و اصلی‌ترین رودخانه این حوزه، رودخانه مند می‌باشد. بخش عمده‌ای از این حوضه در استان فارس و فقط قسمت کمی از آن در استان بوشهر قراردارد. این منطقه بین $51^{\circ}55'30''E$ - $54^{\circ}56'30''E$ طول شرقی و $27^{\circ}0'30''N$ - $29^{\circ}55'30''N$ عرض شمالی واقع شده‌است. حداکثر ارتفاع در این حوزه ۳۱۸۵ متر در خرمکوه در شمال شرق حوزه و حداقل آن ۵ متر در حاشیه خلیج فارس می‌باشد. شکل (۱) موقعیت منطقه مورد مطالعه را نشان می‌دهد:



شکل ۱:موقعیت منطقه مورد مطالعه

در این تحقیق جهت پیش‌بینی خشکسالی ایستگاه تنگاب حوزه مند از داده‌های بارش و دما برای یک دوره ۳۲ ساله (۱۹۷۹-۲۰۱۲) استفاده شده است. در ابتدا، آزمون همگنی داده‌ها در نرم افزار SPSS محاسبه شده است. آزمون گردش حول میانگین یا «ران تست» یکی از متداولترین آزمون‌های غیر نموداری مورد استفاده برای تأیید همگنی

داده هاست (مجرد قره باغ، ۱۳۷۶). نتایج آزمون ران تست در جدول (۱) آورده شده است. تفسیر خروجی نرم افزار بیانگر این مطلب است که تصادفی بودن داده ها و فرضیه صفر رد می شود و داده ها از راندمان خوبی برخوردار می باشند.

جدول ۱: نتایج آزمون ران تست

Asymp. Sig. (2-tailed)	Z	Number of Runs	Total Cases	Cases >= Test Value	Cases < Test Value	Test Value	
....	-۱۳/۲۸۴	۷۱	۴۰۸	۲۰۴	۲۰۴	۱۸	dama
....	-۱۱/۸۹۶	۸۵	۴۰۸	۲۰۴	۲۰۴	۹	barsh

تفسیر خروجی

• آزمون فرض: H_0 توالی گردش ها تصادفی است:

• آماره آزمون: H_1 توالی گردش ها تصادفی نیست :

• آماره آزمون: $R=Number\ of\ Runs,\ Z=|z|$

• مقدار بحرانی: $Z_{0.01}=2.327$

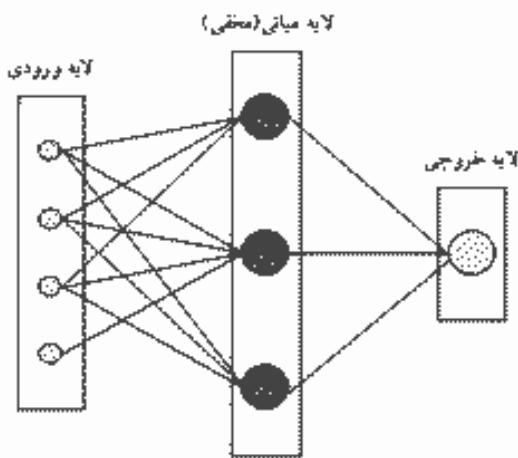
چون $|z| > Z_{0.01}=2.327$ می باشد فرض H_0 رد می شود و نتیجه می گیریم که توالی گردش داده ها در کلیه ایستگاه ها تصادفی نمی باشد.

شاخص مورد استفاده، شاخص بارش استاندارد شده یا SPI می باشد که توسط مک کی و همکاران به منظور پایش خشکسالی اقلیمی ابداع گردید (مک کی و همکاران^۱، ۱۹۹۳). برای تعیین شاخص SPI ابتدا یک توزیع گاما به داده های بارش ایستگاه برآذش داده می شود، در مرحله بعد تبدیل احتمال تجمعی از توزیع گامای به دست آمده به توزیع نرمال استاندارد تجمعی با میانگین صفر و واریانس یک صورت می گیرد؛ بدین ترتیب مقادیر SPI مطابق رابطه ۱ در توزیع نرمال استاندارد به دست می آید (ادوارد^۲، ۱۹۹۷).

$$SPI = \frac{X_{ik} - \bar{X}_i}{\delta_i} : 1$$

σ_i انحراف از معیار داده‌های i امین ایستگاه، x_{ik} مقادیر بارندگی برای i امین ایستگاه و K امین مشاهده و \bar{x}_i متوسط بارندگی ایستگاه i ام می‌باشد.

شبکه‌های عصبی مصنوعی با ساختار پرسپترون چند لایه رایج‌ترین شبکه‌های عصبی می‌باشد. این شبکه‌ها جزء شبکه‌های عصبی پیشخور می‌باشند که قادرند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها، یک نگاشت غیرخطی را با دقت دلخواه انجام دهند. پارامترهای قابل تنظیم در شبکه‌های MLP وزن اتصالات مابین لایه‌ها است و فرآیند آموزش در این شبکه‌ها به معنی یافتن مقادیر مناسب برای وزن‌های اتصالات بین نرون‌ها است. متداول‌ترین الگوریتم یادگیری این شبکه‌ها الگوریتم پس‌انتشار خطا است. در شبکه‌های پیشخور نرون‌ها در لایه‌هایی که در لایه اول (ورودی)، شروع و به لایه خروجی ختم می‌شوند، آرایش می‌یابند (فتحی و کوچکزاده، ۱۳۸۳).

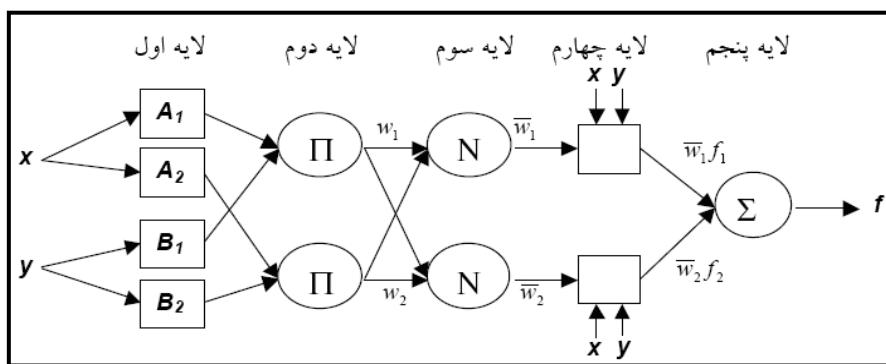


شکل ۲: ساختار شبکه عصبی مصنوعی پرسپترون چند لایه (منهاج، ۱۳۸۷)

بین نرون‌های لایه‌های مختلف اتصالاتی وجود دارد که هر کدام دارای وزن‌هایی می‌باشد. طی فرآیند آموزش این وزن‌ها و مقادیر ثابتی که با آن‌ها جمع می‌شود و در اصطلاح بایاس نامیده می‌شود، به طور پی در پی تغییر می‌کند تا خطای بین مقادیر تخمین زده شده و مقادیر واقعی به حداقل مقدار خود برسد. برای انتقال خروجی‌های هر لایه به لایه‌های بعدی از توابع محرک استفاده می‌شود. جهت یادگیری شبکه عصبی مصنوعی از فرآیند آموزش استفاده می‌شود (حسن‌پور کاشانی و همکاران، ۱۳۸۶).

مدل‌های عصبی – فازی که توسط جانگ^۱ در سال ۱۹۹۳ گسترش یافت، جهت تسهیل فرآیند یادگیری و انطباق، منطق فازی را با شبکه‌های عصبی مصنوعی ترکیب می‌کند. یک شبکه تطبیقی، ساختار پیشرو چندلایه‌ای است که رفتار کلی خروجی آن به وسیله مقدار یک مجموعه از پارامترهای قابل اصلاح تعیین می‌گردد. با استفاده از این شبکه عصبی تطبیقی، مشکل اصلی استفاده از سیستم استنتاج فازی که همان به دست آوردن قواعد "اگر-آنگاه"

فازی و بهینه سازی پارامترهای مدل می باشد، بر طرف می گردد که پارامترهای آن را می توان با ترکیب روش های حداقل مربعات خطاب و انتشار خطاب به عقب بر اساس کاهش گرادیان برآورد نمود (فرخ نیا و همکاران، ۱۳۸۷).



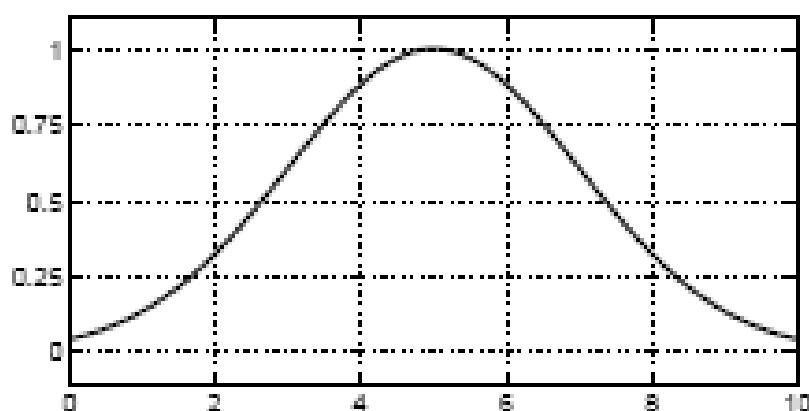
شکل ۳: معماری کلی مدل فازی- عصبی تطبیقی (Chang , 1990)

تابع عضویت بکار رفته در این پژوهش از نوع گوسی می باشد که به شرح ذیل می باشد:

تابع عضویت گوسی : یک تابع عضویت گوسی با دو پارامتر $\{c, \sigma\}$ مشخص می شود:

$$gaussian(x; c, \sigma) = \exp\left(-\left(\frac{x - c}{\sigma}\right)^2\right) \quad : ۲$$

در رابطه فوق، c مرکز و σ عرض تابع عضویت محاسبه می شود. شکل (۴) نمودار تابع عضویت گوسی را نشان می دهد:



شکل ۴: نمودار تابع عضویت گوسی (Sivanandam et al. ,2007)

برای مدل‌سازی داده‌های نرمال‌شده به سه دسته آموزش، صحبت‌سنگی و آزمون تقسیم شد که به ترتیب ۷۰، ۱۵ و ۱۵ درصد داده‌ها به هر قسمت تخصیص داده شدند. در ابتدا جهت آموزش شبکه از ورودی‌های نرمال شده استفاده شد که رابطه ۳ به این منظور مورد استفاده قرار گرفته است.

$$N = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad : 3$$

که در آن N مقادیر استاندارد شده؛ X_i مقادیر واقعی؛ X_{\max} حداکثر مقادیر واقعی و X_{\min} حداقل مقادیر واقعی می‌باشد.

در این تحقیق از نرم‌افزار Matlab ۲۰۱۲ برای تدوین مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی-فازی تطبیقی و انجام محاسبات مربوط به آن‌ها استفاده گردید. ساختار شبکه عصبی از نوع پرسپترون چندلایه و نحوه آموزش پساننتشار خطأ و الگوریتم یادگیری از نوع پیشخور با طول دوره آماری ۳۲ ساله می‌باشد و از تابع عضویت گوسی در مدل استنتاج عصبی- فازی تطبیقی استفاده شده است که در آن $Q_t = f(D_t, P_t)$ به عنوان ورودی در دو مدل ANN و ANFIS استفاده شده است که D_t و P_t به ترتیب دما و بارش ماهانه است. برای ارزیابی کارایی مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی در پیش‌بینی خشکسالی، مقدار داده‌های آزمون به وسیله مدل‌های تدوین شده برآورد، با داده‌های واقعی مقایسه و معیارهای آماری محاسبه شد. به منظور ارزیابی دقت مدل‌های پیش‌بینی از معیارهای ناش (رابطه ۴)، ضریب همبستگی (رابطه ۵)، و ریشه میانگین مربعات خطأ (رابطه ۶) استفاده گردید (پهلوانی، ۱۳۸۸).

$$E = 1 - \frac{\sum(o_i - p_i)^2}{\sum(o_i - \bar{o})^2} \quad : 4$$

$$CORR = \frac{\sum_{i=1}^n (Q_i^o - \bar{Q}^o)(Q_i^s - \bar{Q}^s)}{\sqrt{\sum_{i=1}^n (Q_i^o - \bar{Q}^o)^2 \sum_{i=1}^n (Q_i^s - \bar{Q}^s)^2}} \quad : 5$$

$$RMSE = \sqrt{\left(\frac{1}{n} \sum_{i=1}^n (Q_i^o - Q_i^s)^2 \right)} \quad : 6$$

مباحث و یافته ها

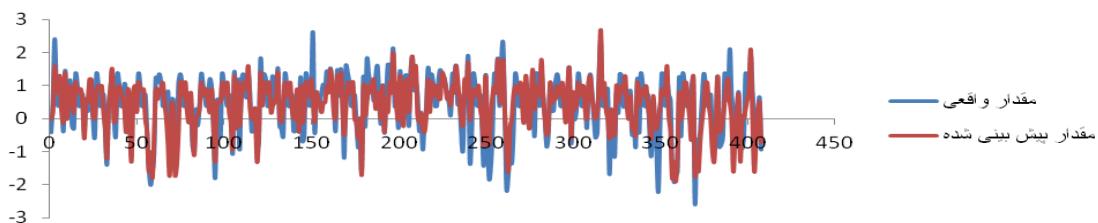
برای ایستگاه مورد مطالعه از طریق مدل های شبکه عصبی مصنوعی (ANN) سیستم استنتاج عصبی - فازی تطبیقی (ANFIS)، با استفاده از داده های دما و بارش محاسبه و با داده های مشاهده ای مورد مقایسه قرار گرفت. برای این منظور از ۷۰ درصد داده ها برای واسنجی (آموزش) و ۳۰ درصد جهت اعتبارسنجی (آزمون) استفاده شد. در این بررسی از مدل شبکه عصبی با ساختار پرسپترون چندلایه و سیستم استنتاج عصبی - فازی تطبیقی با تابع عضویت گوسی برای پیش بینی خشکسالی در سری زمانی ماهانه در ایستگاه تنگاب حوزه مُند استفاده شد. ساختار مورد استفاده شامل یک لایه ورودی (مقدار بارش و دما)، یک لایه خروجی (مقدار SPI سری مورد نظر) و لایه پنهان بود. تعداد لایه پنهان و تابع انتقال مناسب به صورت سعی و خطأ تعیین گردید. برای آموزش شبکه از روش آموزشی پس انتشار خطأ استفاده و از میان الگوریتم های مختلف این روش آموزشی، الگوریتم پیشخور با سعی و خطأ تعیین گردید؛ همچنین روند آموزش الگو به الگو در تدوین مدل های شبکه عصبی و سیستم استنتاج عصبی - فازی تطبیقی به کار رفت. در نهایت شبکه ای که دارای کمترین مقدار جذر میانگین مربعات خطأ^۱ بود و به عبارتی نزدیک ترین نتیجه را با واقعیت داشت به عنوان شبکه اصلی انتخاب گردید. مشخصات شبکه عصبی مصنوعی به کار رفته در ایستگاه تنگاب و نتایج ارزیابی و دقت مدل های شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی با استفاده از شاخص SPI در جدول ۲ آورده شده است:

جدول ۲: مشخصات و نتایج ارزیابی مدل های شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی با استفاده از شاخص SPI در ایستگاه تنگاب

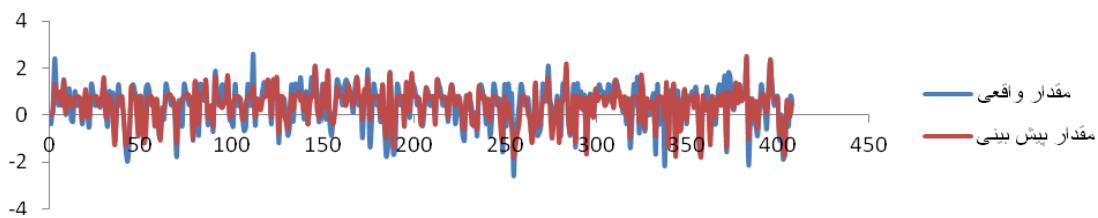
نوع شبکه	مدل بهینه شبکه													
	نوع الگوریتم	تابع انتقال	تعداد مخفی	تعداد نمون	تعداد ورودی	آموزش			اعتبارسنجی			آزمایش		
						R2	RMSE	E	R2	RMSE	E	R2	RMSE	E
ANN	پس انتشار خطأ	تائزانت سیگموئید	۱	-۲۰۱	۲	0/82	0/09	۰/۶۳	۰/۹	۰/۰۹	۰/۶۳	۰/۸۳	۰/۰۹	۰/۶۳
ANFIS	پس انتشار	گوسی	۱	-۲۰۱	۲	0/61۵	0/010۴	۰/۷	۰/۶۳۵	۰/۰۱۱۳	۰/۷۲	۰/۸۰۱	۰/۰۰۷۴	۰/۷

طبق نتایج به دست آمده از جدول (۲)، مدل شبکه عصبی MLP با ساختار ۱-۲۰-۲ با تابع آستانه تائزانت سیگموئید در مقایسه با مدل ANFIS نتایج بهتری را ارائه داده است. معیارهای ناش (E) و ضریب همبستگی (R2) که میزان رابطه بین دو متغیر را نشان می دهند به ترتیب در بازه $-\infty$ تا $+1$ و $+1$ تا $-\infty$ تغییر می کنند. نزدیکی این

دو معیار به یک، نشان دهنده رابطه قوی بین دو متغیر است. سایر معیارهای بیان شده نیز مقادیری مثبت بوده و هر چه به صفر نزدیک‌تر باشند، میزان خطای دو متغیر نسبت به هم کمتر و دو متغیر به هم نزدیک‌ترند. با توجه به مقدار RMSE در مدل شبکه عصبی مصنوعی، میزان خطا کمتر از مدل سیستم استنتاج عصبی- فازی تطبیقی می- باشد که بیانگر دقیق‌تر بالای مدل شبکه عصبی نسبت به مدل استنتاج عصبی- فازی تطبیقی است. مقادیر SPI مشاهده شده و برآورد شده برای بهترین مدل شبکه عصبی و سیستم استنتاج عصبی- فازی تطبیقی تدوین شده، در شکل‌های (۵) و (۶) آرائه شده است:



شکل ۵: نمودار مقادیر مشاهده‌ای و پیش‌بینی با استفاده از SPI شده با مدل MLP



شکل ۶: نمودار مقادیر مشاهده‌ای و پیش‌بینی شده با استفاده از SPI با مدل سیستم استنتاج فازی- عصبی تطبیقی

نتیجه

با جمع‌بندی نتایج حاصل از این دو روش، می‌توان دریافت که دقیق‌تر روش شبکه‌های عصبی مصنوعی از روش سیستم استنتاج عصبی- فازی تطبیقی، بیشتر می‌باشد. همچنین از نتایج و ارزیابی پارامترهای آماری می‌توان دریافت که سیستم استنتاج عصبی- فازی تطبیقی در شرایطی که داده‌های ورودی و خروجی دارای عدم قطعیت باشند، به عنوان یک مدل پیش‌بینی می‌تواند با دقیق‌ترین نسبت بالایی این فرایند را انجام دهد. شایان ذکر است که مطابق نتایج حاصل از این پژوهش، هر چقدر پراکندگی داده‌های ورودی مدل بیشتر باشد، مدل استنتاج فازی- عصبی تطبیقی دارای توانایی بیشتری در شبیه‌سازی این نوع از داده‌ها می‌باشد.

منابع

- ازدری مقدم، مهدی، محمود خسروی، حسین حسین‌پور نیکنام، احسان جعفری‌ندوشن (۱۳۹۰). پیش‌بینی خشکسالی با استفاده از مدل فازی-عصبی، شاخص‌های اقلیمی، بارندگی و شاخص خشکسالی استان زاهدان، مجله جغرافیا و توسعه، مشهد، ۲۶، صص: ۷۲-۶۱.
- اعلمی، محمدتقی، یوسف حسین‌زاده، مهدی کمامی (۱۳۸۸). ارزیابی و مقایسه نمایه‌های خشکسالی و پیش‌بینی آن با شاخص SPI به روش مدل‌سازی دو متغیره با شبکه عصبی مصنوع، هشتمین سمینار بین‌المللی مهندسی رودخانه، دانشگاه شهید چمران اهواز.
- افخمی، حمیده، محمدتقی دستورانی، حسین ملکی‌نژاد، حسین مبین (۱۳۸۹). بررسی تأثیر عناصر اقلیمی بر افزایش دقت روش شبکه عصبی مصنوعی در پیش‌بینی خشکسالی استان یزد، مجله علوم و فنون کشاورزی و منابع طبیعی، اصفهان، ۵۱، صص: ۱۷-۱۵۷.
- پهلوانی، حمید (۱۳۸۸). ارزیابی کارایی مدل‌های شبکه عصبی مصنوعی در تخمین هوشمند هیدرولوگراف سیل ورودی به سد مخزنی شیرین دره در مقایسه با مدل‌های تطبیقی عصبی-فازی، پایان‌نامه کارشناسی ارشد آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، دانشکده منابع طبیعی، گروه مرتع و آبخیزداری، صفحه: ۱۲۳.
- حسین‌پور کاشانی، م.، منتصری، م.، ع.، لطف‌الهی یقین، م. (۱۳۸۶). پیش‌بینی سیل در حوضه‌های فاقد آمار با استفاده از مدل رگرسیون و شبکه عصبی مصنوعی، سومین کنگره ملی مهندسی عمران.
- صداقت‌کردار، ع.، فتاحی، الف (۱۳۸۷). شاخص‌های پیش‌آگهی خشکسالی در ایران، مجله جغرافیا و توسعه، ۱۶(۱)، صص: ۷۶-۵۹.
- علیزاده، امین (۱۳۸۱). اصول هیدرولوژی کاربردی، مشهد انتشارات آستان قدس رضوی، جلد چهاردهم، صفحه: ۲۶۲.
- عیوضی، معصومه، ابوالفضل مساعدی، امیر احمد دهقانی (۱۳۸۸). مقایسه روش‌های مختلف پیش‌بینی شاخص خشکسالی SPI، مجله پژوهش‌های حفاظت آب و خاک، گرگان، ۱۶(۲)، صص: ۱۶۷-۱۴۵.
- فتحی، پ.، کوچک‌زاده، م. (۱۳۸۳). تخمین تعریق خیار گلخانه‌ای با استفاده از شبکه عصبی مصنوعی، مجله علوم خاک و آب، جلد ۱۸، شماره ۲.
- فرخنی، اشکان، سعید مرید، هوشنگ قائمی (۱۳۸۷). داده‌کاوی روی سیگنال‌های بزرگ مقیاس اقلیمی برای پیش‌بینی بلندمدت خشکسالی، سومین کنفرانس مدیریت منابع آب ایران، دانشکده مهندسی عمران دانشگاه تبریز.
- کاویانی، محمد رضا و بهلول علیجانی (۱۳۷۸). مبانی آب و هواشناسی، تهران انتشارات سمت، جلد ششم، صفحه: ۲۶۸.
- مجرد قره‌باغ، فیروز (۱۳۷۶). تحلیل و پیش‌بینی یخ‌بندان در آذربایجان رساله دوره دکتری، دانشگاه تربیت مدرس، دانشکده علوم انسانی.

- منهاج، محمد باقر. (۱۳۸۷). مبانی شبکه‌های عصبی هوش محاسباتی، جلد اول، چاپ پنجم، انتشارات دانشگاه صنعتی امیرکبیر تهران.
- نیکنام، حسین، مهدی اژدری مقدم، محمود خسروی (۱۳۸۹). استفاده از مدل فازی عصبی و الگوهای ارتباط از دور جهت پیش‌بینی خشکسالی زاهدان، چهارمین کنگره بین المللی جغرافی‌دانان جهان اسلام، دانشگاه سیستان و بلوچستان زاهدان.
- یزدانی، وحید و حسین باززاد (۱۳۸۸). پیش‌بینی خشکسالی هیدرولوژیکی استان اصفهان با استفاده از شبکه عصبی مصنوعی، دومین همایش ملی اثرات خشکسالی و راهکارهای مدیریت آن، مرکز تحقیقات کشاورزی و منابع طبیعی اصفهان.
- Bacanli, U, Firat, M, Dikbas, F, 2008, Adaptive neuro-fuzzy inference system for drought forecasting. Stochastic Environmental Research and Risk Assessment. 8: 1143-1154.
- Crespo, J.L, Mora, E, 1993, Drought estimation with neural networks, Advances in Engineering Software18, 167–170.
- Chang, F. and Chang, Y.1990. Adaptive neuro-fuzzy inference system for prediction of water level in reservoir, Advances in Water Resources, Vol.29, Issue 1, Pp: 1-10.
- Jang, J.-S.R, 1993, ANFIS adaptive network based fuzzy inference system, IEEE Transactions on Systems, Man and Cybernetics, 3: 665–683.
- McKee, T.B, Doesken, N.J and Kleist, J, 1993, The relationship of drought frequency and duration to time scales. 8th conference on Applied Climatology. 17-22 January California 176-184.
- Mishra, A.K and Desai V.R, 2006, Drought forecasting using feed-forward recursive neural network, Ecological Modelling, 198: 127-138.
- Mishra, A.K, Singh, V.P, 2012, Simulating hydrological drought properties at different spatial units in the United States based on wavelet-bayesian approach Earth Interactions Journal of Hydrology,17: 1–23.
- Santos, Celso Augusto, G, Morais, Bruno S, Silva, Gustavo, B L, 2009, Drought forecast using an artificial neural network for three hydrological zones in San Francisco River basin, Brazil, Proceedings of Symposium, Convention of The International Association of Hydrological Sciences, India 312 – 302.
- Sivanandam, S.N, Sumathi, S and Deepa, S.N. 2007. Introduction to Fuzzy Logic using MATLAB, Springer Berlin Heidelberg, New York.