

انتخاب مدل مناسب برای پیش‌بینی خشکسالی شهر سمنان در مقیاس زمانی کوتاه مدت ماهانه با استفاده از آمار هواشناسی و مدل‌های خطی و غیرخطی

مریم صادقیان، حجت کرمی* و سید فرهاد موسوی^۱

(تاریخ دریافت: ۱۳۹۴/۱۰/۰۶؛ تاریخ پذیرش: ۱۳۹۵/۱۰/۱۸)

چکیده

امروزه، شناخت بیشتر خشکسالی و ایجاد سیستم‌های پایش آن، بخصوص در دوره‌های کوتاه مدت، و افزودن قابلیت پیش‌بینی به این سیستم‌ها، می‌تواند منجر به ارائه راهکارهای مناسب‌تری در بخش‌های مدیریت تخصیص منابع آب گردد. در این پژوهش، با استفاده از روش‌های پیش‌بینی سری‌های زمانی، سیستم‌های استنتاج فازی-عصبی تطبیقی و شبکه‌های عصبی مصنوعی سعی شده مدل‌های مناسب جهت پیش‌بینی خشکسالی شهرستان سمنان ارائه گردد. در این مدل‌سازی‌ها از داده‌های میانگین ماهانه پارامترهای هواشناسی مانند بارندگی، دما، حداکثر دما، حداقل دما، رطوبت نسبی، حداکثر رطوبت نسبی، حداقل رطوبت نسبی و شاخص خشکسالی SPI طی دوره آماری ۱۹۶۶ تا ۲۰۱۳ استفاده شده است. نتایج نشان داد که از بین انبوه مدل‌های ساخته شده، مدل ANFIS با ورودی‌های میانگین بارش، میانگین حداکثر دما، SPI و داده‌های یک ماه قبل آنها، با ۱۰ قانون و تابع عضویت گوسی، با مقادیر RMSE برابر ۰/۷۷۷، MAE برابر ۰/۵۹۳ و ضریب همبستگی ۰/۴ در مرحله آموزش و RMSE برابر ۰/۸۳۷، MAE برابر ۰/۶۴۴ و ضریب همبستگی ۰/۳۶۲ در مرحله آزمون، به‌عنوان مدل برتر انتخاب شد. سپس، پارامترهای ورودی این مدل با استفاده از مدل ARIMA برای ۱۲ ماه آینده پیش‌بینی گردید و به‌عنوان ورودی به مدل مذکور معرفی شدند و SPI برای ۱۲ ماه آینده پیش‌بینی شد. روش‌های شبکه عصبی مصنوعی و سری زمانی با اختلاف کم در مقادیر خطا، در رتبه‌های بعد قرار گرفتند. پارامترهای ورودی SPI و دما عملکرد مناسب‌تر و پارامتر بارش عملکرد ضعیف‌تری را داشتند.

واژه‌های کلیدی: پیش‌بینی خشکسالی، سری زمانی، شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی

۱. گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان

*: مسئول مکاتبات: پست الکترونیکی: hkarami@semnan.ac.ir

مقدمه

در ادوار مختلف، همواره دسترسی و تأمین منابع آب یکی از اساسی‌ترین نیازهای بشر بوده است، که کمبود آن می‌تواند تأثیرات زیادی را به‌طور غیر مستقیم بر زندگی اجتماعی - اقتصادی انسان‌ها و اکوسیستم‌های طبیعی منطقه به دنبال داشته باشد. امروزه، با شناخت بیشتر خشکسالی و ایجاد سیستم‌های پایش آن، در راستای کسب اطلاعات لازم در ارتباط با زمان آغاز، خاتمه و شدت خشکسالی در مقیاس‌های مختلف زمانی و مکانی (۸) و همچنین افزودن قابلیت پیش‌بینی به سیستم‌های پایش خشکسالی که می‌تواند در بخش‌های مدیریتی، به خصوص از منظر تخصیص منابع آب، مؤثر باشد، تحقیقات بسیاری در ارتباط با پیش‌بینی خشکسالی‌ها در ایران و سایر نقاط جهان صورت گرفته است. کریسپو و مورا برای پیش‌بینی خشکسالی در اسپانیا از مدل شبکه‌های عصبی مصنوعی استفاده نمودند (۱۳). آنها از یک شبکه پرسپترون چند لایه و الگوریتم پس انتشار خطا برای آموزش شبکه استفاده نمودند. نتایج بررسی‌ها نشان داد که مدل شبکه عصبی مصنوعی می‌تواند پیش‌بینی‌هایی با دقت زیاد از تعداد خشکسالی‌ها و طول متوسط خشکسالی ارائه نماید. رضایی در تحقیقی، به معرفی توانایی‌های روش‌های شبکه عصبی مصنوعی در حل مسائلی از قبیل سیل و خشکسالی پرداخت (۲۲). براساس یافته‌های وی، استفاده از شبکه عصبی مصنوعی در مدل‌سازی رفتاری پدیده‌ها دارای برتری نسبت به روش‌های آماری می‌باشد. میسرا و دسای در تحقیق خود برای پیش‌بینی خشکسالی، از مدل‌های احتمالاتی خطی مانند ARIMA و SARIMA، و کاربرد شاخص بارش استاندارد شده (SPI)، استفاده نمودند (۱۸). نتایج تحقیقات آنها نشان داد که مدل‌های آماری نتایج خوبی از نظر پیش‌بینی کوتاه مدت خشکسالی (تا ۲ ماه) دارند. همچنین، میسرا و همکاران برای پیش‌بینی خشکسالی در تحقیقی دیگر از سه مدل آماری خطی، مدل ترکیبی (هیبریدی) و یک شبکه غیرخطی عصبی - مصنوعی استفاده کردند (۱۹). نتایج حاکی از دقت و درستی بیشتر

روش‌های ترکیبی نسبت به سایر روش‌ها بود.

شمس‌نیا و همکاران جهت مدل‌سازی خشکسالی در استان فارس، با استفاده از آمار بارندگی ۹۰ ایستگاه باران‌سنجی و سینوپتیک در این استان در راستای تعیین درجه شدت‌های خشکسالی، از شاخص استاندارد شده بارش استفاده کردند (۵). در شبیه‌سازی وقوع خشکسالی نیز با استفاده از الگوهای سری زمانی، براساس روش خود همبستگی و خود همبستگی جزئی، ارزیابی تمامی الگوهای احتمالی به لحاظ ایستا بودن، بررسی پارامترها و انواع مدل‌ها، مدل ARIMA انتخاب شد و مناسب‌ترین مدل جهت شبیه‌سازی خشکسالی در هر منطقه ارائه گردید. سلاجقه و همکاران خشکسالی در استان خراسان رضوی را با دو روش سری زمانی و شبکه عصبی پرسپترون پیش‌بینی کردند که نتایج، برتری روش سری زمانی را تأیید کرد (۴). باروا و پررا به پیش‌بینی خشکسالی در حوضه آبریز رودخانه یارا در ویکتوریای استرالیا با استفاده از شاخص خشکسالی NADI (Nonlinear Aggregated Drought Index)، مدل‌های آماری ARIMA و ANN پرداختند (۱۱). درنهایت، مدل‌های ANN از مدل ARIMA عملکرد بهتری داشت. حسین‌پور نیکنام و همکاران با استفاده از مقادیر پیشین شاخص SPI و شاخص‌های اقلیمی جهت پیش‌بینی خشکسالی یک ساله شهر زاهدان، روش سیستم استنتاج فازی - عصبی تطبیقی را در ساخت مدل‌های پیش‌بینی خشکسالی به کار بردند (۳). نتایج به‌دست آمده نشان داد که سری زمانی مشابه سال قبل پیشین شاخص SPI در پیش‌بینی خشکسالی‌های ۱۲ ماهه مؤثرتر از شاخص‌های اقلیمی می‌باشد. جلیلی و همکاران با استفاده از آمار بارش و دمای ماهانه در ۷۰۱ ایستگاه منتخب ایران، شاخص‌های خشکسالی NDVI, VCI, TCI و NDVI-Dev و مدل‌های شبکه عصبی (MLP, RBF, SVM)، به پیش‌بینی خشکسالی پرداختند (۱۴). درنهایت، مدل MLP به‌عنوان بهترین مدل معرفی شد.

کشور ایران، با بارندگی کمتر از یک سوم متوسط جهانی، در ردیف کشورهای خشک قرار می‌گیرد و خشکی جزو صفات

جدول ۱. طبقه‌بندی اقلیمی براساس روش کوپن

مرز	بارندگی زمستان	دوران بارندگی نامشخص است	بارندگی تابستانی
بیابانی / استپی	$P=T$	$P=T+7$	$P=T+14$
استپی / مرطوب	$P=2T$	$P=2(T+7)$	$P=2(T+14)$

در رابطه فوق، I = ضریب خشکی، T = متوسط دمای سالانه (سانتی‌گراد) و P = متوسط بارندگی سالانه (میلی‌متر) می‌باشد (۷). آب و هوای شهرستان سمنان در تابستان گرم و در زمستان نسبتاً سرد می‌باشد و بارندگی‌های این شهر معمولاً در فصول سرد سال صورت می‌گیرد. در این پژوهش، آمار و اطلاعات هواشناسی از ایستگاه هواشناسی سینوپتیک شهرستان سمنان که در سال ۱۳۴۱ (۱۹۶۵ میلادی) تأسیس شده، اخذ گردیده است. این ایستگاه در طول جغرافیایی ۵۳ درجه و ۲۳ دقیقه شرقی و عرض جغرافیایی ۳۵ درجه و ۳۴ دقیقه شمالی قرار گرفته و ارتفاع آن از سطح دریا ۱۱۳۰/۸ متر است.

پارامترهای مورد استفاده در این تحقیق شامل آمار و اطلاعات هواشناسی و شاخص خشکسالی بارش استاندارد (SPI: Standardized Precipitation Index) بود. شاخص SPI پس از بررسی چندین شاخص خشکسالی، به‌عنوان شاخص برتر در تعیین شدت خشکسالی انتخاب شده است. پارامترهای هواشناسی شامل بارندگی ماهانه (P)، دمای ماهانه (T)، حداقل دمای ماهانه (T_{min})، حداکثر دمای ماهانه (T_{max})، رطوبت نسبی ماهانه (RH)، حداقل رطوبت نسبی ماهانه (RH_{min})، حداکثر رطوبت نسبی ماهانه (RH_{max}) در زمان حال و تا سه تأخیر زمانی پیشین و شاخص خشکسالی SPI در زمان حال و تا چهار تأخیر زمانی پیشین می‌باشند. هر کدام از این پارامترها دوره آماری ۴۷ ساله (۲۰۱۳-۱۹۶۶) را تشکیل می‌دهند. بررسی صحت و سقم داده‌های مورد استفاده با آزمون ناپارامتریک اسپیرمن برای تعیین استقلال و روند داده‌ها و همچنین آزمون دنباله‌ها برای بررسی تصادفی و همگن بودن داده‌ها و عدم وجود روند در آنها صورت گرفته است (۱) که صحت داده‌ها را تأیید می‌کنند.

ذاتی آن محسوب می‌شود. وضعیت اقلیم و تأثیر خشکسالی‌ها بر استان‌های مرکزی ایران نیز چندان رضایت بخش نیست. همچنین، آنچه از وضعیت آب و هوا و خصوصیات خشکسالی‌ها در استان سمنان نیز استنباط می‌گردد این گونه است که وقوع این پدیده از ویژگی‌های اصلی آب و هوای آن می‌باشد. پژوهش حاضر، تلاشی است تا با استفاده از آمار و اطلاعات موجود هواشناسی، شاخص خشکسالی مناسب، مدل‌ها و الگوهای خطی و غیرخطی سری‌های زمانی، شبکه‌های عصبی مصنوعی و سیستم استنتاجی فازی-عصبی-تطبیقی، مدل مناسبی برای پیش‌بینی خشکسالی شهر سمنان در مقیاس زمانی کوتاه مدت ماهانه ارائه گردد.

مواد و روش‌ها

منطقه مورد مطالعه و پارامترهای مورد استفاده

شهر سمنان، مرکز استان سمنان، در جنوب رشته کوه البرز و شمال دشت کویر واقع شده است. اقلیم غالب استان با توجه به محاسبات دو روش طبقه‌بندی اقلیم کوپن و دومارتن، به جز باریکه‌ای از مرز کوهستانی در شمال استان، به‌ترتیب بیابانی و خشک است. در روش طبقه‌بندی کوپن سه نوع آب و هوا بیابانی، استپی و مرطوب. را می‌توان متمایز ساخت مرز مربوط به هر یک از این اقلیم‌ها به مقدار بارندگی سالانه برحسب سانتی‌متر (P)، دمای سالانه برحسب درجه سانتی‌گراد (T) و زمان وقوع بارندگی بستگی دارد که در جدول (۱) مشخص شده است.

همچنین دومارتن جهت طبقه‌بندی اقلیم بین دما و مقدار بارندگی رابطه تجربی (۱) را پیدا کرد:

$$I = \frac{P}{(T+10)} \quad (1)$$

جدول ۲. تقسیم‌بندی ارزیابی شاخص بارش استاندارد

SPI شاخص	وضعیت خشکسالی
-۲	خشکسالی بسیار شدید
-۱/۹۹ تا -۱/۵	خشکسالی شدید
-۱ تا -۱/۴۹	خشکسالی متوسط
-۰/۹۹ تا صفر	خشکسالی ضعیف
صفر	نرمال
صفر تا ۰/۹۹	ترسالی ضعیف
۱ تا ۱/۴۹	ترسالی متوسط
۱/۵ تا ۱/۹۹	ترسالی شدید
۲	ترسالی بسیار شدید

می‌گردد که همان مقدار SPI است. طبقه‌بندی ارزیابی شاخص SPI در جدول (۲) آورده شده است.

سری‌های زمانی

از جمله مدل‌های آماری پرکاربرد سری‌های زمانی می‌باشند که مهم‌ترین هدف از تحلیل آنها، پیش‌بینی مقادیر آینده است. معمولاً برای تحلیل یک سری زمانی، تغییراتی که نتیجه چهار مؤلفه روند، تغییرات فصلی، دوره‌ای و نامنظم (تصادفی) می‌باشد، در نظر گرفته می‌شوند. مراحل ساخت مدل‌های سری زمانی شامل آماده‌سازی داده‌ها، شناسایی مدل، برازش مدل و تشخیص اعتبار مدل می‌باشد (۶). مراحل فوق با استفاده از دو نرم‌افزار EViews7 و Minitab16 انجام شده است. تعیین فرم اولیه مدل، یکی از مهم‌ترین مراحل است. لذا، بر مبنای تحقیقات گذشته، مدل‌سازی در خانواده آرما، آریمای فصلی از شیوه‌های مهم و معتبر در شبیه‌سازی و پیش‌بینی پارامترهای اقلیمی می‌باشند که علاوه بر تولید، قابلیت پیش‌بینی داده‌ها در آینده را نیز دارند (۱۲). فرم کلی مدل‌های ARIMA، که قابلیت مدل‌سازی برخی از سری‌های زمانی نایستا را با تفاضلی کردن سری مورد نظر دارند به صورت معادله (۲) می‌باشد (۱۲):

$$\varphi(B)\nabla^d X_t = \theta(B)Z_t \quad (3)$$

شاخص خشکسالی منتخب در این پژوهش (SPI) در سال ۱۹۹۳ توسط مک‌کی و همکاران ارائه شد (۱۷). این شاخص براساس تفاوت بارش از میانگین برای یک مقیاس زمانی مشخص و سپس تقسیم آن بر انحراف معیار به دست می‌آید و تنها فاکتور مؤثر در محاسبه آن، عنصر بارندگی می‌باشد. این شاخص را می‌توان در مقیاس‌های زمانی کوتاه مدت و بلند مدت محاسبه کرد. شاخص SPI از معادله (۲) به دست می‌آید:

$$SPI = \frac{P_i - \bar{P}}{S} \quad (2)$$

که P_i مقدار بارش در دوره مورد نظر (\bar{P} ، میانگین درازمدت بارش برای دوره مورد نظر و S انحراف معیار مقدار بارش می‌باشند. از آنجا که توزیع بارندگی معمولاً از توزیع نرمال تبعیت نمی‌کند، محاسبه SPI تا حدودی پیچیده است. برای محاسبه این شاخص، ابتدا از یک توزیع مناسب مانند توزیع گاما یا پیرسون تیپ سه برای برازش داده‌های بلندمدت بارش استفاده می‌شود (۳). سپس، محاسبه و تعیین پارامترهای مربوط به SPI انجام می‌گیرد. محاسبه SPI شامل برازش تابع چگالی احتمال گاما بر توزیع فراوانی بارندگی می‌باشد و چون تابع گاما برای مقادیر صفر بارش تعریف نشده است از احتمال تجمعی کل، مقدار متغیر تصادفی نرمال استاندارد هم احتمال با احتمال مذکور، با میانگین صفر و انحراف معیار یک، محاسبه

هیپربولیک می‌باشند که در این تحقیق در مدل‌های ساخته شده کارایی هر دو تابع در لایه پنهان بررسی گردیده است. در بخش یادگیری شبکه‌های چند لایه پیش‌خور بر پایه الگوریتم یادگیری پس انتشار خطا (BP) از تابع مارکوارت-لونبرگ که سریع‌تر بوده و جزو تکنیک‌های استاندارد بهینه‌سازی عددی محسوب می‌گردد استفاده شده است (۱۰). در همه ترکیب‌های پارامترهای ورودی، هر دو تابع لگاریتم سیگموئید و تانژانت هیپربولیک با تعداد نرون‌های متفاوت در لایه پنهان از ۲ تا ۳۰ نرون بررسی شدند. بدیهی است که در لایه ورودی تعداد نرون با تعداد پارامترهای ورودی برابر می‌باشد. در لایه خروجی نیز یک خروجی با تابع محرک خطی استفاده شده است. مدل‌سازی‌ها با استفاده از جعبه ابزار نرم‌افزار MATLAB R2013a انجام گردید.

شبکه‌های تابع پایه شعاعی از نوع شبکه‌های رو به جلو با یک لایه میانی هستند. در این شبکه‌ها، معمولاً تابع محرک لایه میانی، تابع گوسی و در لایه خروجی تابع خطی می‌باشد (۱۶). تعداد زیادی مدل با شبکه RBF برای ترکیب‌های مختلف ورودی و ثابت‌های گسترش متفاوت با کدنویسی در محیط نرم‌افزار MATLAB ساخته شدند. تنها متغیر در شبکه RBF برای هر ترکیب ورودی، ثابت گسترش است که با سعی و خطا، مقدار بهینه آن تعیین می‌گردد.

در مدل‌سازی‌ها با هر دو شبکه مذکور، ابتدا استانداردسازی داده‌ها به منظور جلوگیری از عدم دقت و کاهش سرعت شبکه، با استفاده از رابطه (۶) انجام شد، سپس به‌عنوان ورودی به مدل‌ها معرفی شدند:

$$X_n = 0.05 + 0.95 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) \quad (6)$$

در این رابطه، x معرف داده مشاهده شده، x_{\max} و x_{\min} به ترتیب حداقل و حداکثر داده‌ها و X_n نیز داده استاندارد شده می‌باشد. چون برای ورودی‌های نزدیک به صفر و یا یک، تغییرات وزن نرون‌ها حداقل خواهد بود و عناصر پردازشگر کند عمل می‌کنند، بدین منظور، داده‌ها طبق فرمول بین ۰/۰۵ و ۰/۹۵ قرار داده می‌شوند.

که در آن، چند جمله‌ای‌های مرتبه p و q به صورت زیر است:


$$\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \quad (4)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (5)$$

در روابط فوق، p درجه اتورگرسیو، d درجه تفاضل‌گیری و q درجه میانگین متحرک می‌باشد. جهت تعیین توانایی و کیفیت مدل آزمون‌های استقلال زمانی، نرمال بودن باقیمانده‌ها و ایستاد بودن پارامترهای برآورد شده روی فرضیات مدل، مقایسه نمودار همبستگی نگار مدل با همبستگی نگار سری تاریخی و برای واسنجی کفایت پارامترهای مدل از معیار اطلاعات آکائیک (AIC) استفاده شده است. هر چه مقدار AIC کمتر باشد مدل عملکرد مناسب‌تری دارد (۲ و ۶).

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN) یک سیستم پردازش اطلاعات است که براساس شبیه‌سازی عملکرد مغز انسان بنا نهاده شده و قادر است روابط بین یک سری از متغیرهای ورودی و خروجی را مدل کند (۲۰). بررسی پژوهش‌های صورت گرفته حاکی از عملکرد مناسب دو نوع شبکه عصبی پرسپترون چند لایه (MLP: Multi-Layer Perceptron) و تابع پایه شعاعی (RBF: Radial Basis Function) می‌باشد که در این پژوهش در مدل‌سازی‌ها استفاده شده‌اند. شبکه‌های MLP متشکل از سه لایه به نام‌های لایه ورودی، لایه یا لایه‌های میانی (پنهان) و لایه خروجی می‌باشند که در تعداد لایه‌های پنهان محدودیتی ندارد. در این شبکه‌ها، مجموع ورودی‌های وزن‌دار شده (ورودی خالص) از طریق یک تابع محرک به مقدار خروجی تبدیل می‌شود. در لایه خروجی می‌توان از یک تابع خطی استفاده نمود. کاربرد این تابع در لایه پنهان پیشنهاد نمی‌شود، به این دلیل که کارایی شبکه کاهش یافته و قادر به حل مسائل غیرخطی در دنیای واقعی نخواهد بود. از رایج‌ترین توابع محرک غیرخطی که در لایه پنهان استفاده می‌شود توابع سیگموئیدی و تانژانت



شکل ۱. نمونه‌ای از ساختار ANFIS

مدل‌سازی‌های سیستم‌های استنتاج فازی - عصبی تطبیقی با استفاده از جعبه‌ابزار ANFIS در نرم‌افزار MATLAB صورت گرفت. در این روش نیز ابتدا داده‌ها با رابطه (۶) استانداردسازی شده و سپس به‌عنوان ورودی در مدل‌ها استفاده شدند. جهت مدل‌سازی از سیستم فازی سوگنو و توابع عضویت ناقوسی و گوسی استفاده شده است. روش تولید قوانین خوشه‌بندی کاهشی، الگوریتم آموزشی هیبرید جهت آموزش و تعداد دوره‌های آموزش برابر ۲۰۰ عدد در نظر گرفته شده است. همچنین، برای عملگرهای عطفی AND و OR به‌ترتیب از ضرب و احتمال و برای غیرفازی‌سازی نیز از غیرفازی‌ساز متوسط وزن‌دار استفاده گردید. در مدل‌سازی‌های هوشمند پارامترهای ورودی هواشناسی، شاخص خشکسالی SPI و مقادیر پیشین آنها در مقیاس زمانی ماهانه استفاده شده است. خروجی این مدل‌ها، شاخص خشکسالی SPI با یک گام زمانی جلوتر ((SPI(t+1)) می‌باشد. در مدل‌های سری زمانی، شاخص خشکسالی SPI در مقیاس زمانی ماهانه تشکیل شد و به‌عنوان ورودی به مدل‌ها معرفی گردید. در مرحله آموزش از ۸۰٪ داده‌ها و در مرحله آزمون از ۲۰٪ آنها استفاده گردید. در تمامی مدل‌سازی‌ها، جهت ارزیابی و تحلیل نتایج، از آماره‌های جذر میانگین مربعات خطاها (RMSE)، میانگین مطلق خطاها (MAE) و ضریب همبستگی (R) (به‌ترتیب روابط ۷، ۸ و ۹) استفاده گردید (۳، ۱۱ و ۲۱):

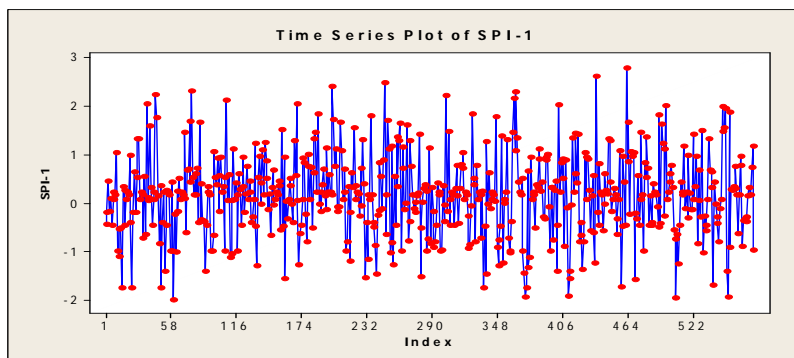
سیستم‌های فازی بر پایه شبکه عصبی تطبیقی (ANFIS)

سیستم فازی قادر به استفاده از زبان بشری می‌باشد و می‌تواند از تجربیات بشری و افراد متخصص و خبره استفاده کند؛ اما قابلیت از آموزش با داده‌های مشاهده‌ای دارا نمی‌باشند. همچنین، شبکه‌های عصبی با استفاده از مجموعه داده‌ها، قابلیت خود آموزی دارند و قادر به استفاده از زبان بشری نمی‌باشند (۹). جانگ با استفاده از قدرت زبانی سیستم‌های فازی و آموزش شبکه‌های عصبی، سیستم‌های فازی بر پایه شبکه عصبی تطبیقی (ANFIS) را ارائه نمود که شامل یک شبکه پیش‌خور چند لایه می‌باشد و از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به‌منظور ترسیم یک فضای ورودی به یک فضای خروجی استفاده می‌کند (۱۵). به‌عنوان مثال، در یک سیستم استنتاجی با دو ورودی X و Y و یک خروجی Z برای یک مدل فازی تاکاگی - سوگنو درجه اول، می‌توان یک مجموعه قانون نمونه را با دو قانون اگر - آنگاه فازی به‌صورت زیر بیان نمود:

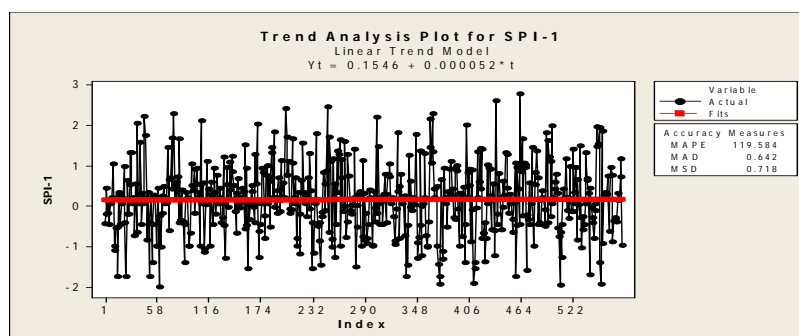
- اگر X برابر A₁ و Y برابر B₁ باشد آنگاه: $z_1 = p_1x_1 + q_1y_1 + r_1$

- اگر X برابر A₂ و Y برابر B₂ باشد آنگاه: $z_2 = p_2x_2 + q_2y_2 + r_2$

که در این قوانین، ϕ_i و q_i برای $i = 1, 2, \dots$ پارامترهای خطی در بخش تالی مدل فازی تاکاگی - سوگنو درجه اول هستند. ساختار ANFIS شامل پنج لایه می‌شود که در شکل (۱) نشان داده شده است (۱۵).



شکل ۲. نمودار سری زمانی شاخص خشکسالی SPI در مقیاس زمانی ماهانه



شکل ۳. بررسی روند سری زمانی شاخص خشکسالی SPI در مقیاس زمانی ماهانه

مدل‌سازی در نرم‌افزار Minitab انجام شده است. ابتدا سری مورد نظر رسم گردید، که در شکل (۲) نمودار آن آورده شده است. سپس، وجود مؤلفه روند در سری بررسی شد که در شکل (۳) نشان داده شده است. با توجه به معادله رگرسیونی روند خطی سری $SPI_t = 0.000052t + 0.1546$ و P-value مربوط به ضریب رگرسیون خطی (۰/۵۵۶) نشان می‌دهد که شیب این خط رگرسیونی در سطح ۵٪ معنی‌دار نمی‌باشد. لذا، روند خطی از نظر آماری زیاد نیست. در مدل‌های $ARIMA(p,d,q)$ پارامترهای p و q از مرتبه صفر تا ۵ و به علت ایستایی سری، پارامتر d از مرتبه صفر در نظر گرفته شدند. جهت ارزیابی مدل‌های اولیه از نمودارهای خود همبستگی (ACF) و خود همبستگی جزئی (PACF) استفاده شده است. نتایج ارزیابی این مدل‌ها در جدول (۳) آورده شده است. با در نظر گرفتن مقادیر آماره‌های به کار رفته جهت ارزیابی این

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^o - x_i^p)^2} \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i^o - x_i^p| \quad (8)$$

$$R = \frac{\sum_{i=1}^n (x_i^o - \bar{x}^o)(x_i^p - \bar{x}^p)}{\sqrt{\sum_{i=1}^n (x_i^o - \bar{x}^o)^2 \sum_{i=1}^n (x_i^p - \bar{x}^p)^2}} \quad (9)$$

در این روابط، X_i^o مقادیر مشاهداتی، X_i^p مقادیر پیش‌بینی شده، \bar{X}_i^o میانگین مقادیر مشاهداتی و \bar{X}_i^p میانگین مقادیر پیش‌بینی شده می‌باشند. هر چه مقادیر RMSE و MAE به صفر نزدیک‌تر و مقادیر ضریب همبستگی، که بین -۱ و ۱ متغیر است، به مقدار ۱ نزدیک‌تر باشد نشان دهنده عملکرد بهتر مدل است.

نتایج و بحث

به منظور مدل‌سازی سری‌های زمانی، پس از تأیید ایستایی سری ماهانه SPI با استفاده از نرم‌افزار EViews، ادامه مراحل

جدول ۳. ارزیابی نتایج پیش‌بینی خشکسالی با مدل سری زمانی ARIMA

آزمون			آموزش			فرم مدل	
Corr.	MAE	RMSE	AIC	Corr.	MAE	RMSE	
۰/۰۵۴	۰/۶۶	۰/۸۷۲	-۱۶۱/۷	۰/۱۴۱	۰/۶۳۴	۰/۸۴	ARIMA (۱,۰,۰)
۰/۰۷۴	۰/۶۵۸	۰/۸۷	-۱۶۰/۵	۰/۱۴۲	۰/۶۳۵	۰/۸۳۸	ARIMA (۱,۰,۱)
۰/۲۱	۰/۶۶	۰/۸۵	-۱۵۸/۵	۰/۱۴۷	۰/۶۳۵	۰/۸۴	ARIMA (۱,۰,۲)
۰/۰۹۷۳	۰/۶۵	۰/۸۶۹	-۱۵۸/۵	۰/۱۴۷	۰/۶۳۵	۰/۸۳۹	ARIMA (۲,۰,۱)
۰/۲۲	۰/۶۴۹	۰/۸۵۱	-۱۵۶/۵	۰/۱۴۷	۰/۶۳۵	۰/۸۳۹	ARIMA (۲,۰,۲)
۰/۱۲۴	۰/۶۵۲	۰/۸۶۶	-۱۵۷/۱	۰/۱۵۱	۰/۶۳۶	۰/۸۳۸	ARIMA (۳,۰,۱)
۰/۲۰۳	۰/۶۴۹	۰/۸۵۴	-۱۷۱/۴	۰/۲۳۷	۰/۶۳۲	۰/۸۲۳	ARIMA (۳,۰,۲)
۰/۱۸۹	۰/۶۴۷	۰/۸۵۷	-۱۵۶/۷	۰/۱۷۴	۰/۶۳۸	۰/۸۳۵	ARIMA (۳,۰,۳)
۰/۱۳	۰/۶۵۶	۰/۸۶۵	-۱۵۵/۱	۰/۱۵۱	۰/۶۳۶	۰/۸۳۸	ARIMA (۴,۰,۱)

جدول ۴. مقادیر ضرایب و خطای استاندارد آن

P-value	ضریب	مرتبه	نوع
۰/۰۰۰	۰/۵۸۲۱	۱	AR
۰/۰۰۰	-۰/۹۷۷۴	۲	AR
۰/۰۰۲	۰/۱۴۸۴	۳	AR
۰/۰۰۰	۰/۴۴۵۱	۱	MA
۰/۰۰۰	-۰/۹۸۵۴	۲	MA
۰/۰۰۰	۰/۲۰۹۷۱	-	ثابت


جدول ۵. P-value آماره آزمون Ljung-Box با ۴۸ تأخیر

آزمون Ljung-Box				
تأخیر	۱۲	۲۴	۳۶	۴۸
P-value	۰/۳۵۹	۰/۱۵۶	۰/۲۹۵	۰/۴۸۰

مدل‌ها و همچنین مقایسه نمودارهای ACF و PACF مدل با نمودارهای ACF و PACF سری تاریخی، در نهایت مدل ARIMA(۲,۰,۳) به عنوان مدل برتر انتخاب گردید. مقادیر خطای مرحله آموزش در این مدل RMSE، MAE، ۰/۸۲۳، ۰/۶۳۲، ضریب همبستگی ۰/۲۳۷ و مقدار معیار آکاییک (AIC) ۱۷۱/۴- می‌باشد و در مرحله آزمون مقدار خطای RMSE، MAE، ۰/۸۵۴، ۰/۶۴۹ و ضریب همبستگی ۰/۲۰۳ است.

ضرایب مدل برتر و همچنین P-value آماره خطای استاندارد هر ضریب (t) نشان داد که تمامی ضرایب در سطح ۵٪ معنی‌دار می‌باشند، که مقادیر آنها در جدول (۴) آورده شده است. همچنین P-value آماره آزمون Ljung-Box نیز در تأخیرهای مختلف، که بزرگ‌تر از سطح معنی‌داری ۵٪ می‌باشند فرض صفر، که فرض ناهمبسته بودن باقیمانده‌ها است، را تأیید می‌کند. این مقادیر در جدول (۵) نشان داده شده است.

مدل‌ها و همچنین مقایسه نمودارهای ACF و PACF مدل با نمودارهای ACF و PACF سری تاریخی، در نهایت مدل ARIMA(۲,۰,۳) به عنوان مدل برتر انتخاب گردید. مقادیر خطای مرحله آموزش در این مدل RMSE، MAE، ۰/۸۲۳، ۰/۶۳۲، ضریب همبستگی ۰/۲۳۷ و مقدار معیار آکاییک (AIC) ۱۷۱/۴- می‌باشد و در مرحله آزمون مقدار خطای RMSE، MAE، ۰/۸۵۴، ۰/۶۴۹ و ضریب همبستگی ۰/۲۰۳ است.



شکل ۴. نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده SPI(t) با مدل ARIMA(۲,۰,۳)

جدول ۶. ارزیابی نتایج پیش‌بینی خشکسالی با شبکه عصبی MLP

آزمون		آموزش			تعداد نورون	تابع محرک	تابع محرک	پارامتر(های) ورودی	
Corr.	MAE	RMSE	Corr.	MAE	RMSE	لایه پنهان	لایه خروجی		
۰/۲۲	۰/۶۴۵	۰/۸۳۲	۰/۲۶۶	۰/۶۲	۰/۸۱۸	۶	Purelin	logsig	SPI(t, t-۱, t-۲, t-۳, t-۴)
۰/۱۳۵	۰/۶۴۹	۰/۸۵۴	۰/۲	۰/۶۳	۰/۸۳۲	۱۲	Purelin	Tansig	P(t, t-۱)
۰/۲۷	۰/۶۳۵	۰/۸۱۵	۰/۲۷۳	۰/۶۳	۰/۸۱۷	۲۵	Purelin	logsig	Tmax(t, t-۱)
۰/۱۸۸	۰/۶۵۱	۰/۸۳۴	۰/۲۰۷	۰/۶۴	۰/۸۳	۱۲	Purelin	Tansig	RH(t, t-۱, t-۲)
۰/۲۷۶	۰/۶۴۴	۰/۸۱۹	۰/۲۹	۰/۶۴	۰/۸۱	۲۵	Purelin	Tansig	SPI(t), Tmax(t)
۰/۲۳	۰/۶۵۷	۰/۸۳	۰/۲۸۲	۰/۶۳	۰/۸۱۷	۱۸	Purelin	Tansig	SPI(t), P(t), Tmax(t)

همبستگی ۰/۲۹ و RMSE، ۰/۸۱۹، MAE، ۰/۶۴۴ و ضریب همبستگی ۰/۲۷۶ در مرحله آزمون، با عملکرد مناسب نسبت به سایر مدل‌ها به عنوان مدل برتر انتخاب شد. در شکل (۵) نمودار مقایسه مقادیر مشاهداتی (SPI(t+۱)) و مقادیر پیش‌بینی شده با استفاده از مدل مذکور آورده شده است.


در مدل‌سازی روش شبکه عصبی RBF، با توجه به حجم بالای مدل‌ها، برای ترکیب‌های مختلف ورودی فقط برخی نتایج حاصل از مدل با ثابت گسترش بهینه و کمترین مقدار خطا در جدول (۷) آورده شده است. پس از ارزیابی نتایج مشخص گردید که این نوع از شبکه‌های عصبی عملکرد ضعیف‌تری را نسبت به شبکه عصبی MLP در مدل‌سازی از خود نشان داد. از بین این مدل‌ها، مدل RBF با پارامترهای ورودی SPI(t)، SPI(t-۱)، SPI(t-۲)، Tmax(t)، Tmax(t-۱) و Tmax(t-۲) با ثابت گسترش ۸۰ و مقادیر خطای RMSE، ۰/۸۱۶، MAE، ۰/۶۳۳ و ضریب همبستگی ۰/۲۷۱ در مرحله آموزش و RMSE، ۰/۸۲۱، MAE، ۰/۶۳۸ و ضریب همبستگی ۰/۲۴۴ در

معادله مدل ARIMA(۲,۰,۳) به صورت رابطه (۱۰) بیان می‌گردد:

$$X_t = 0.5821(X_{t-1}) - 0.9774(X_{t-2}) + 0.1484(X_{t-3}) + 0.20971 + 0.4451(\varepsilon_{t-1}) - 0.9854(\varepsilon_{t-2}) \quad (10)$$

در شکل (۴)، نمودار مقادیر مشاهداتی (SPI(t)) و مقادیر پیش‌بینی شده با استفاده از مدل مذکور آورده شده است.

در مدل‌سازی‌های شبکه عصبی MLP، با توجه به حجم بالای مدل‌ها، فقط نتایج برتر برخی از ترکیب‌های ورودی در جدول (۶) آورده شده است. پس از ارزیابی نتایج مشخص گردید که پارامترهای شاخص خشکسالی SPI، میانگین دما و میانگین حداکثر دما عملکرد بهتری را نسبت به سایر پارامترها دارا بودند و پارامتر میانگین بارش ضعیف‌ترین عملکرد را از خود نشان داد. در نهایت، با بررسی مقادیر خطای تمامی مدل‌ها، مدل MLP با پارامترهای ورودی SPI(t) و Tmax(t) با تابع محرک تانژانت هیپربولیک و ۲۵ نرون در لایه پنهان و مقادیر خطای مرحله آموزش RMSE، ۰/۸۱، MAE، ۰/۶۴ و ضریب




شکل ۵. نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده $SPI(t+1)$ با مدل MLP با دو ورودی $SPI(t)$ ، $Tmax(t)$ و

تابع تانژانت هیپربولیک و ۲۵ نورون در لایه پنهان

جدول ۷. ارزیابی نتایج پیش‌بینی خشکسالی با شبکه عصبی RBF

آموزش			آزمون			ثابت گسترش	پارامتر(های) ورودی
Corr.	MAE	RMSE	Corr.	MAE	RMSE		
۰/۱۵۶	۰/۶۳۸	۰/۸۴۱	۰/۲۲۶	۰/۶۲۷	۰/۸۲۶	۱۰۰	$SPI(t, t-1, t-2, t-3, t-4)$
۰/۱۰۴	۰/۶۴۵	۰/۸۴۲	۰/۱۲۷	۰/۶۳۲	۰/۸۴۱	۱۰۰	$p(t, t-1)$
۰/۱۴۹	۰/۶۴۳	۰/۸۳۷	۰/۱۱۹	۰/۶۴	۰/۸۴۲	۱۰۰	$Tmax(t, t-1, t-2)$
۰/۱۴۹	۰/۶۶۸	۰/۸۳۹	۰/۲	۰/۶۴۹	۰/۸۳۱	۱۰۰	$RHmin(t, t-1)$
۰/۲۴۴	۰/۶۳۸	۰/۸۲۱	۰/۲۷۱	۰/۶۳۲	۰/۸۱۶	۸۰	$SPI(t, t-1, t-2), Tmax(t, t-1, t-2)$
۰/۲۴۲	۰/۶۴۴	۰/۸۲۱	۰/۲۶۷	۰/۶۳۲	۰/۸۱۷	۹۰	$SPI(t), P(t), T(t), RH(t)$



شکل ۶. نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده $SPI(t+1)$ با مدل RBF با شش ورودی $SPI(t)$ ، $SPI(t-1)$ ، $SPI(t-2)$ ،

$Tmax(t)$ ، $Tmax(t-1)$ ، $Tmax(t-2)$ و ثابت گسترش ۸۰


پارامترهای شاخص خشکسالی SPI ، میانگین دما و میانگین حداکثر دما عملکرد بهتری را نسبت به سایر پارامترها دارا بودند و پارامتر میانگین بارش عملکرد ضعیفی را از خود نشان داد. پس از ارزیابی نتایج، مدل با شش پارامتر ورودی $SPI(t)$ ، $SPI(t-1)$ ، $P(t)$ ، $P(t-1)$ و $Tmax(t)$ با ۱۰ قانون و تابع عضویت گوسی و مقادیر خطای $RMSE$ ، ۰/۷۷۷، MAE ، ۰/۵۹۳ و ضریب همبستگی ۰/۴ در مرحله آموزش و

مرحله آزمون، به عنوان مدل برتر انتخاب شد. در شکل (۶) نمودار مقایسه مقادیر مشاهداتی $SPI(t+1)$ و مقادیر پیش‌بینی شده با استفاده از این مدل آورده شده است.

در مدل‌سازی با استفاده از روش ANFIS، با توجه به حجم بالای مدل‌ها، برای ترکیب‌های مختلف ورودی، فقط برخی نتایج مدل‌ها با تعداد قوانین بهینه و کمترین خطا در جدول (۸) آورده شده است. پس از ارزیابی نتایج مشخص گردید که

جدول ۸ ارزیابی نتایج پیش‌بینی خشکسالی با سیستم استنتاج فازی-عصبی تطبیقی ANFIS

آزمون			آموزش			تعداد	تابع عضویت	تابع عضویت	پارامتر(های) ورودی
Corr.	MAE	RMSE	Corr.	MAE	RMSE	قوانین	خروجی	عضویت	
۰/۱۷۲	۰/۶۵۷	۰/۸۲۶	۰/۳۷۳	۰/۶۰۹	۰/۷۸۷	۳	Linear	gaussmf	$SPI(t, t-1, t-2, t-3, t-4)$
۰/۰۸	۰/۶۶۴	۰/۸۵۲	۰/۲۲۶	۰/۶۲۷	۰/۸۲۶	۶	Linear	gaussmf	$P(t, t-1, t-2)$
۰/۲۳۴	۰/۶۴۶	۰/۸۲۷	۰/۳۱۲	۰/۶۲۸	۰/۸۰۶	۶	Linear	gbellmf	$T(t)$
۰/۱۸۷	۰/۶۴۲	۰/۸۳	۰/۱۸۵	۰/۶۳۶	۰/۸۳۳	۵	Linear	gaussmf	$RHmin(t, t-1)$
۰/۳۱۶	۰/۶۶۵	۰/۸۱۹	۰/۴۰۱	۰/۶	۰/۷۷۸	۳	Linear	gbellmf	$SPI(t, t-1, t-2), RHmin(t, t-1, t-2)$
۰/۳۶۲	۰/۶۴۴	۰/۸۳۷	۰/۴	۰/۵۹۳	۰/۷۷۷	۱۰	Linear	gaussmf	$SPI(t, t-1), P(t, t-1), Tmax(t-1)$




شکل ۷. نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده $SPI(t+1)$ با مدل ANFIS با شش ورودی $SPI(t), SPI(t-1), P(t), P(t-1), Tmax(t), Tmax(t-1)$ و تابع عضویت گوسی و ۱۰ قانون

گوسی و ۱۰ قانون به‌عنوان مدل برتر انتخاب گردید. جهت پیش‌بینی خشکسالی برای ۱۲ ماه آینده شهر سمنان، ابتدا سری زمانی پارامترهای میانگین بارش در ماه جاری و میانگین حداکثر دما در ماه جاری تشکیل شدند و با استفاده از مدل ARIMA برای ۱۲ ماه آینده پیش‌بینی گردیدند. تمام مراحل مدل‌سازی برای هر دو سری زمانی همانند آنچه پیشتر ذکر گردید انجام شد که به دلیل حجم بالای مطالب از ذکر آنها خودداری شده است. پس از مدل‌سازی‌ها و بررسی نتایج، مدل $ARIMA(3,0,3)$ به‌عنوان مدل برتر جهت مدل‌سازی سری زمانی میانگین بارش در ماه جاری و مدل $ARIMA(0,1,4)$ به‌عنوان مدل برتر جهت مدل‌سازی سری زمانی میانگین حداکثر دما در ماه جاری انتخاب شدند و مقادیر این دو پارامتر برای ۱۲ ماه آینده پیش‌بینی شدند. همچنین، پیش‌بینی شاخص خشکسالی SPI با مدل $ARIMA(2,0,3)$ برای ۱۲ ماه بعدی صورت گرفت. درنهایت، دوازده ماه پیش‌بینی شده آینده برای

۰/۳۶۲ همبستگی و ضریب همبستگی ۰/۶۴۴، MAE، ۰/۸۳۷، RMSE، ۰/۶۴۴ و ضریب همبستگی ۰/۳۶۲ در مرحله آزمون، به‌عنوان مدل برتر انتخاب شد. در شکل (۷) نمودار مقایسه مقادیر مشاهداتی $SPI(t+1)$ و مقادیر پیش‌بینی شده با استفاده از مدل مذکور آورده شده است.

پس از بررسی نتایج سه روش سری‌های زمانی، ANN و ANFIS، نشان داده شد که مدل‌های ساخته شده با استفاده از ANFIS برای اکثر ترکیب‌های ورودی، عملکرد بهتری را نسبت به دو روش دیگر در پیش‌بینی خشکسالی دارا می‌باشند و روش ANN و سری زمانی به‌ترتیب در رتبه‌های بعدی قرار می‌گیرند. همچنین، نتایج به‌دست آمده با نتایج سایر تحقیقات صورت گرفته که در بخش مقدمه به آنها اشاره گردیده است، مطابقت دارد. در انتها، از بین انبوه مدل‌ها، مدل ANFIS با ترکیب پارامترهای ورودی شاخص خشکسالی SPI در ماه جاری و یک ماه قبل، میانگین بارش در ماه جاری و یک ماه قبل، و میانگین حداکثر دما در ماه جاری و یک ماه قبل با تابع عضویت



شکل ۸. نمودار مقادیر پیش بینی شده شاخص خشکسالی SPI برای دوازده ماه آینده با شش ورودی $P(t-1)$, $P(t)$, $SPI(t-1)$, $SPI(t)$, $Tmax(t-1)$, $Tmax(t)$ و مدل ANFIS (تابع عضویت گوسی و ۱۰ قانون)

انتظار داشتیم، روش ANFIS ارجح تر تشخیص داده شد و روش های شبکه عصبی مصنوعی و سری زمانی در رتبه های بعدی قرار گرفتند و مقادیر خطای به دست آمده در هر دو مرحله آموزش و آزمون در مدل های برتر تا حدود زیادی مشابه با پژوهش حسین پور نیکنام و همکاران می باشد (۳). در مدل های شبکه عصبی، مدل های ساخته شده با شبکه عصبی MLP از عملکرد مناسب تری نسبت به شبکه RBF برخوردار بودند. همچنین، در ترکیب های مختلف ورودی تابع محرک، لگاریتم سیگموئید عملکرد بهتری را دارا بود و در مدل های ANFIS نیز تابع عضویت گوسی در اکثر مدل ها عملکرد مناسبی را نشان داد. اما، این توابع به طور قطع تابع محرک برتر تشخیص داده نشدند. از بین پارامترهای ورودی، شاخص خشکسالی SPI و مقادیر پیشین آن و پارامتر هواشناسی دما عملکرد بهتری را در بهبود مدل سازی ها دارا بودند. میانگین بارش نیز ضعیف ترین عملکرد را نشان داد که این امر ممکن است به سبب وجود تغییرات ناگهانی در مقادیر داده ها و تعدد مقدار کمینه (صفر) در آمار بارش باشد.

هر پارامتر به سری تاریخی آن اضافه شدند و به عنوان ورودی به مدل انتخاب شده معرفی گردیدند. پس از مدل سازی، مقدار شاخص خشکسالی SPI در زمان $t+1$ برای ۱۲ ماه آینده (فوریه ۲۰۱۴ تا ژانویه ۲۰۱۵) پیش بینی گردید. در شکل (۸) نمودار این مقادیر نشان داده شده است.

نتیجه گیری

در این پژوهش، سعی بر این بود که مدل های مناسبی جهت پیش بینی خشکسالی شهرستان سمنان ارائه گردد. پس از بررسی تمامی روش های مدل سازی، با تک تک پارامترهای ورودی و ترکیب های مختلفی از آنها، نتایج نشان داد که مدل ANFIS با شش پارامتر ورودی $P(t-1)$, $P(t)$, $SPI(t-1)$, $SPI(t)$, $Tmax(t-1)$ و $Tmax(t)$ با ۱۰ قانون و تابع عضویت گوسی با مقادیر خطای $RMSE$, 0.0777 , MAE , 0.0593 و ضریب همبستگی، 0.4 در مرحله آموزش و $RMSE$, 0.0837 , MAE , 0.0644 و ضریب همبستگی، 0.362 در مرحله آزمون، عملکرد مناسب تری را دارا بود. پس از ارزیابی روش های مدل سازی مختلف، همان طور که از بررسی پژوهش های صورت گرفته

منابع مورد استفاده

- انوری، ص. ۱۳۸۷. ارتقاء مدل های هوشمند جهت پیش بینی جریان رودخانه با استفاده از داده های توزیع مکانی اقلیمی و سطح برف. پایان نامه کارشناسی ارشد سازه های آبی، دانشگاه تربیت مدرس، تهران.

۲. جهان‌دیده، م. و ا. شیروانی. ۱۳۹۰. پیش‌بینی خشکسالی بر پایه نمایه بارش استاندارد شده با استفاده از مدل‌های سری‌های زمانی در استان فارس. مجله پژوهش آب ایران ۵(۹): ۲۸-۱۹.
۳. حسین‌پور نیکنام، ح.، م. اژدری مقدم و م. خسروی. ۱۳۹۱. پیش‌بینی خشکسالی یک ساله با استفاده از مدل فازی-عصبی، سری‌های زمانی خشکسالی و شاخص‌های اقلیمی (مطالعه موردی: زاهدان). مجله آب و فاضلاب ۲۳(۲): ۵۱-۴۲.
۴. سلاجقه، ع.، ا. فتح‌آبادی و م. نجفی حاجی‌ور. ۱۳۸۷. مقایسه شبکه عصبی و سری‌های زمانی در پیش‌بینی خشکسالی (مطالعه موردی: استان خراسان رضوی). مجله علوم و مهندسی آبخیزداری ایران ۲(۴): ۷۷-۷۴.
۵. شمس‌نیا، س.، ا. ن. پیرمردیان و س. ن. امیری. ۱۳۸۷. مدل‌سازی خشکسالی در استان فارس با استفاده از تحلیل سری‌های زمانی. نشریه جغرافیا و برنامه‌ریزی ۱۴(۲۸): ۱۸۹-۱۶۵.
۶. صفوی، ح. ر. ۱۳۹۰. هیدرولوژی مهندسی. چاپ سوم، انتشارات ارکان دانش، اصفهان.
۷. علیزاده، ا. ۱۳۹۴. اصول هیدرولوژی کاربردی. انتشارات دانشگاه امام رضا (ع).
۸. فرخ‌نیا، ا.، س. مرید و ه. قائمی. ۱۳۸۷. داده‌کاوی روی سیگنال‌های بزرگ مقیاس اقلیمی برای پیش‌بینی بلندمدت خشکسالی. سومین کنفرانس مدیریت منابع آب ایران، دانشکده مهندسی عمران، دانشگاه تبریز. ۲۳ تا ۲۵ مهر ۱۳۸۷.
۹. کارتاپولوس، اس. وی. ۱۳۸۷. منطق فازی و شبکه‌های عصبی (مفاهیم و کاربرد). ترجمه محمود جورابیان و رحمت هوشمند، چاپ چهارم، انتشارات دانشگاه شهید چمران، اهواز.
۱۰. کیا، م. ۱۳۸۷. شبکه‌های عصبی در *MATLAB*. انتشارات کیان رایانه سبز، تهران.
11. Barua, S. and B. J. C. Perera. 2012. Artificial neural network-based drought forecasting using a nonlinear aggregated drought index. *J. Hydrol. Eng., ASCE* 17: 1408-1413.
12. Box, G. E. P., G. M. Jenkins and G. C. Reinsel. 2002. *Time Series Analysis: Forecasting and Control*. Fourth Edition, John Wiley Publication, 734 p.
13. Crespo, J. L. and E. Mora. 1993. Drought estimation with neural networks. *J. Adv. Eng. Software* 18(3): 167-170.
14. Jalili, M., J. Gharibshah, S. M. Ghavami, M. R. Beheshtifar and R. Farshi. 2013. Nationwide prediction of drought conditions in Iran based on remote sensing data. *IEEE Trans. Comput.* 63(1): 90-101.
15. Jang, J. S. R. 1993. ANFIS: adaptive-network based fuzzy inference system. *IEEE Trans. Sys. Man. Cyber.* 23(3): 665-685.
16. Mason, J. C., R. K. Price and A. Tem'Me. 1996. A neural network model of rainfall runoff using radial basis functions. *J. Hyd. Res.* 34: 537-548.
17. McKee, T. B., N. J. Doesken and J. Kleist. 1993. The relation of drought frequency and duration to time scales. Preprints, 8th Conference on Applied Climatology, 17-22 Jan. Anaheim, California, pp. 379-384.
18. Mishra, A. K. and V. R. Desai. 2005. Drought forecasting using stochastic models. *Stoch. Environ. Res. Risk Assess.* 19(5): 326-339.
19. Mishra A. K., V. R. Desai and P. Singh. 2007. Drought forecasting using a hybrid stochastic and neural network Model. *J. Hydrol. Eng.* 12(6): 626-638.
20. Morid, S., V. Smakhtin and K. Bagherzadeh. 2007. Drought forecasting using artificial neural networks and time series of drought indices. *Int. J. Climatol.* 27(15): 2103-2111.
21. Ozger, M., A. K. Mishra and V. P. Singh. 2010. Estimating Palmer drought severity index using a wavelet fuzzy logic model based on meteorological variables. *Int. J. Climatol.* 31: 2021-2032.
22. Rezaee, A. 2001. Modeling flood and drought using artificial neural networks (ANN). *Proceedings of the First National Conference in Water Crisis*, 8-9 March, Zabol University, pp. 247-256.

Selection of a Proper Model to Predict Monthly Drought in Semnan Using Weather Data and Linear and Nonlinear Models

M. Sadeghian, H. Karami* and S.F. Mousavi¹

(Received: Dec. 27-2015 ; Accepted: Jan. 07-2017)

Abstract

Nowadays, greater recognition of drought and introducing its monitoring systems, particularly for the short-term periods, and adding predictability to these systems, could lead to presentation of more effective strategies for the management of water resources allocation. In this research, it is tried to present appropriate models to predict drought in city of Semnan, Iran, using time series, adaptive neuro-fuzzy inference system (ANFIS) and artificial neural networks (MLP and RBF). For these modeling processes, average monthly meteorological parameters of rainfall, temperature, minimum temperature, maximum temperature, relative humidity, minimum relative humidity, maximum relative humidity and SPI drought index were used during the period 1966 to 2013. The results showed that among the many developed models, the ANFIS model, with input data of average rainfall, maximum temperature, SPI and its last-month value, 10 rules and Gaussian membership function, showed appropriate performance at each stage of training and testing. The values of RMSE, MAE and R at training stage were 0.777, 0.593 and 0.4, respectively, and at testing stage were 0.837, 0.644 and 0.362, respectively. Then, the input parameters of this model were predicted for the next 12 months using ARIMA model, and SPI values were predicted for the next 12 months. The ANN and time series methods with low difference in error values were ranked next, respectively. The input parameters SPI and temperature had better performance and rainfall parameter had weaker performance.

Keywords: Adaptive neuro-fuzzy inference system, Artificial neural network, Prediction of drought, Time-series.

1. Dept. of Water Eng. and Hydraulic Struc., Faculty of Civil Eng., Semnan Univ., Semnan. Iran.*: Corresponding Author, Email: hkarami@semnan.ac.ir