

ارزیابی روش کنترل گروهی داده‌ها (GMDH) و سیستم استنتاج فازی-عصبی (ANFIS) در پیش‌بینی خشکسالی در چند نمونه اقلیمی مختلف

حبیبه حلمی^۱، بهرام بختیاری^{۲*}، کورش قادری^۳

۱- دانشجوی کارشناسی ارشد مهندسی منابع آب؛ بخش مهندسی آب؛ دانشکده کشاورزی؛ دانشگاه شهید باهنر کرمان

۲- دانشیار بخش مهندسی آب؛ دانشکده کشاورزی؛ دانشگاه شهید باهنر کرمان

۳- دانشیار بخش مهندسی آب؛ دانشکده کشاورزی؛ دانشگاه شهید باهنر کرمان؛ کرمان

چکیده

خشکسالی پدیده‌ای است که احتمال وقوع آن در همه نقاط کره زمین و با هر شرایط اقلیمی وجود دارد. پیش‌بینی خشکسالی می‌تواند نقش مهمی در مدیریت منابع آبی و بهره‌برداری بهینه از آن‌ها ایفا کند. در این مطالعه، برای پیش‌بینی خشکسالی، کاربرد دو روش هوشمند سیستم استنتاج فازی-عصبی (ANFIS) و کنترل گروهی داده‌ها (GMDH) چند نمونه اقلیمی مختلف ایران مورد ارزیابی قرار گرفته است. به این منظور از شاخص بارش استاندارد شده (SPI) در سه مقیاس ۶، ۳ و ۱۲ ماهه استفاده شد. آمار و اطلاعات بارندگی طی یک دوره ۲۰ ساله (۲۰۱۵-۱۹۹۶) در ۷ ایستگاه سینوپتیک ایران با اقلیم‌های متفاوت بکار گرفته شد و جهت بررسی عملکرد مدل‌ها از سه معیار ریشه میانگین مربعات خطا (RMSE)، ضریب تبیین (R^2) و میانگین قدرمطلق خطا (MAE) استفاده شد. نتایج نشان داد که در روش ANFIS مقدار ضریب تبیین در کمترین حالت مربوط به SPI سه ماهه (SPI-3) با ۰/۵۹ و بیشترین آن در SPI دوازده ماهه (SPI-12) با مقدار ۰/۹۷ می‌باشد. در روش GMDH، مقادیر ضریب تبیین در هر سه مقیاس SPI و در تمامی اقلیم‌ها بین ۰/۹۰ تا ۰/۹۹ بدست آمد که نشان‌دهنده دقت قابل قبول این مدل بود. همچنین نتایج حاکی از عملکرد مناسب SPI در مقیاس دوازده ماهه بودند. در واقع، بهبود عملکرد مدل‌های ساخته شده با افزایش مقیاس زمانی محاسبه SPI، رابطه مستقیمی دارد. در نهایت نتایج مربوط به مقایسه مقادیر مشاهداتی و پیش‌بینی شده‌ی هر سه مقیاس زمانی با استفاده از روش GMDH در تمامی اقلیم‌ها نشان داد که پیش‌بینی خشکسالی با این روش قابل اطمینان و امکان استفاده از این روش برای پیش‌بینی‌های آتی میسر می‌باشد. بطور کلی نتایج تولید شده توسط هر دو روش ANFIS و GMDH دارای دقت قابل قبولی می‌باشند اما پاسخ‌های بدست آمده از روش GMDH بهتر بوده و به عنوان مدل برتر در پیش‌بینی خشکسالی در این پژوهش معرفی می‌گردد.

کلید واژگان: پیش‌بینی، دوره خشکی، ایران، ANFIS، SPI، GMDH

مقدمه

عصبی (ANFIS^۱) که ابزاری توانمند، انعطاف‌پذیر و مستقل از مدل‌های دینامیکی سیستم می‌باشند، برای مدل‌سازی و پیش‌بینی متغیرهای مهم هواشناسی از جمله خشکسالی پیشنهاد شده‌اند (Bacanli et al. 2009; Djerbouai and Souag, 2016). کیم و ولدس^۳ (2003) از شبکه عصبی برای آنالیز دوره‌های خشکسالی بر مبنای شاخص شدت خشکسالی پالمر PDSI^۴ با استفاده از داده‌های ۳۵ سال بر روی حوزه کونچوس واقع در مکزیک استفاده نمودند. نتایج این پژوهش بیانگر توانایی این روش بود. سانتوس و همکاران^۵ (2009) روش شبکه‌های عصبی پس انتشار را برای پیش‌بینی خشکسالی در سه منطقه از حوضه رودخانه سان فرانسیسکو در شمال شرق برزیل بکار گرفتند. نتایج آن‌ها دقت بالای مدل شبکه عصبی مصنوعی را تأیید کرد. اوزگر و میشر^۶ (2012) از مدل ترکیبی موجک و تئوری فازی برای پیش‌بینی خشکسالی در تگزاس استفاده کردند. نتایج حاکی از آن بود که مدل ترکیبی، عملکرد مدل را به شدت نسبت به حالت فازی بهبود می‌بخشد. مقایسه مدل شبکه عصبی مصنوعی و ترکیب شبکه عصبی-موجک نیز نشان داد که مدل ترکیبی موجک-فازی در پیش‌بینی خشکسالی دقیق‌تر می‌باشد. راوینش و همکاران^۷ (2016) در مطالعه‌ای به پیش‌بینی خشکسالی با استفاده از مدل رگرسیون چندمتغیره و ماشین بردار پشتیبان از مدل‌های هوشمند و مدل درخت M5 پرداختند. نتایج، بهتر بودن مدل درخت M5 را به دلیل کمتر بودن خطا، نسبت به روش‌های دیگر بیان ساخت. نیگوین و همکاران^۸ (2017) برای پیش‌بینی خشکسالی از سیستم استنتاج تطبیقی عصبی-فازی (ANFIS) بر مبنای دو شاخص خشکسالی SPI^۹ (شاخص بارش استاندارد شده) و SPEI^{۱۰} (شاخص بارش-تبخیرتغرق استاندارد شده) در مقیاس ۶،۳،۱ و ۱۲ ماهه در منطقه‌ای در

خشکسالی یا دوره‌های خشکی، پدیده‌ای طبیعی و تکرارشدنی است که در اثر کاهش مقدار بارندگی در یک دوره زمانی مشخص بوجود می‌آید. تعاریف دوره‌های خشکی به خصوص در رابطه با میزان تأثیر آن بر محیط طبیعی و اجتماعی دائماً در حال تغییر است. به نظر منطقی است که خشکسالی را در سطح وسیعی با زمان، طول دوره و محل رویداد آن مرتبط دانست. بطور کلی این پدیده شامل یک دوره پیوسته و پایدار است که در این دوره مقدار آب موجود در منابع آبی منطقه به حد قابل توجهی کاهش می‌یابد و دچار کمبود می‌شود (Sharma and Smakhtin, 2004).

واقع شدن ایران بر روی کمربند خشک جهانی موجب شده است که نوسانات بارندگی در این کشور شدید باشد بطوری که در برخی از سال‌ها، در اثر طغیان آبی رودخانه، سیلاب رخ داده و در بعضی سال‌ها، رخداد خشکسالی موجب آسیب‌های فراوان گردد. می‌توان گفت رخداد خشکسالی از ویژگی‌های اصلی آب و هوای ایران به شمار می‌آید که هم در قلمرو آب و هوای مرطوب و هم خشک قابل دیدن است. چالش اصلی، پیش‌بینی دوره‌های خشکسالی آینده و شدت آن‌ها و به بیان دیگر، افزایش قابلیت اعلام خطر اولیه سیستم‌های پایش از طریق پیش‌بینی خشکسالی می‌باشد (Mishra and Desai, 2005). مدیریت بهینه خشکسالی در گروه پیش‌بینی منطقی شرایط آن از چند ماه یا چند فصل قبل از وقوع است. اگرچه در بررسی این پدیده، استفاده از مدل‌هایی براساس روش‌های تصادفی و احتمالاتی سابقه ای طولانی دارد، اما بسیاری از این روش‌ها روابط بین متغیرها را خطی فرض نموده و در مدل‌سازی پدیده‌های غیرخطی مانند سری‌های زمانی هیدرولوژیک با شکست مواجه می‌شوند (David and Rappoport, 1974).

در چند دهه اخیر استفاده از روش‌های هوشمند مانند شبکه عصبی مصنوعی (ANN^۱) و سیستم استنتاج فازی-

2. Adaptive Neuro-Fuzzy Inference Systems
3. Kim and Valdes
4. Palmer Drought Severity Index
5. Santos et al
6. Ozger and Mishra
7. Ravinesh et al
8. Nguyen et al
9. Standardized Precipitation Index
10. Standardized Precipitation Evapotranspiration Index

1. Artificial Neural Network

یکی دیگر از این روش‌ها، مدل هوشمند کنترل گروهی داده‌ها (GMDH) می‌باشد که توسط ایواخنکو (Ivakhnenko, 1968) به عنوان یک روش تجزیه و تحلیل چند متغیره برای شناسایی و مدل‌سازی سیستم‌های پیچیده توسعه داده شد. روش GMDH دارای ساختار یک شبکه چند لایه و رو به جلو بوده و دربرگیرنده مجموعه‌ای از نرون‌هاست که از پیوند جفت‌های مختلف ورودی از طریق یک چندجمله‌ای درجه دوم بوجود می‌آیند. هر لایه در این شبکه از یک یا چند واحد پردازشگر تشکیل شده که هر یک از آن‌ها دارای دو ورودی و یک خروجی است. این روش امروزه کاربرد وسیعی در پیش‌بینی مسائل مختلف منابع آب و کشاورزی پیدا کرده است. سامسودین و همکاران^۲ (2010) با ترکیب روش GMDH و ماشین بردار پشتیبان به پیش‌بینی دبی رودخانه پرداختند. نتایج نشان داد که ترکیب روش GMDH با ماشین بردار پشتیبان می‌تواند به عنوان یک ابزار قدرتمند در مدل‌سازی دبی رودخانه بکارگرفته شود. رالز و همکاران^۳ (2003) اثر کربن کربن آلی خاک بر حفظ خاک را با استفاده از GMDH بررسی نمودند. نتایج این تحقیق بالا بودن عملکرد روش مذکور را نشان داد. آزامادالا و همکاران^۴ (2013) برای پیش‌بینی عمق آبشستگی از روش کنترل گروهی داده‌ها استفاده نمودند. نتایج نشان داد، GMDH می‌تواند پیش‌بینی دقیق‌تری نسبت به معادله‌های سنتی بدست آمده، ارائه کند. قادری و همکاران (۱۳۸۹) در تحقیق خود برای بهره‌برداری سیستماتیک از مخازن چندگانه موجود در دشت تهران مدل‌هایی بر اساس GMDH توسعه دادند. نتایج نشان‌دهنده عملکرد مناسب روش کنترل گروهی داده‌ها در مدل‌سازی بهره‌برداری از مخازن می‌باشد. همچنین در مطالعه‌ای دیگر قادری و همکاران (۱۳۹۵) به برآورد بار معلق در سیستم رودخانه‌ای با استفاده از GMDH پرداختند. نتایج نشان داد روش GMDH دارای قابلیت بالایی برای پیش‌بینی و شبیه‌سازی نرخ انتقال رسوب در رودخانه‌ها است. حسین زاده و همکاران (۱۳۹۵) به بررسی مدل‌سازی رابطه دبی -

ویتنام، استفاده نمودند. نتایج، بهتر بودن شاخص SPEI نسبت به SPI در عملکرد مدل عصبی-فازی را برای بیشتر مدل‌های انجام شده، نشان داد. کارآموز و همکاران (2006) در تحقیق خود با ترکیب سه شاخص SPI، SWSI^۱ (شاخص ذخیره آب سطحی) و PDSI (شاخص شدت خشکسالی پالم) و با استفاده از شبکه عصبی پرسپترون چند لایه به پیش‌بینی و شبیه‌سازی میزان خسارات خشکسالی‌های آبی در استان اصفهان پرداختند. آن‌ها نتیجه گرفتند که شبکه‌های عصبی در حل مسائل پیش‌بینی و شبیه‌سازی، کارآمد بوده و با استفاده از شاخص ترکیبی می‌توان با رویکردی دقیق‌تر و واقع‌بینانه‌تر دوره‌های خشکسالی را تعیین نمود. فتح آبادی و همکاران (2009) با استفاده از شاخص SPI شرایط خشکسالی در ۵ ایستگاه در شمال غربی ایران را بررسی و با استفاده از شبکه عصبی مصنوعی، سری‌های زمانی و روش نزدیک ترین همسایگی مقادیر SPI را پیش‌بینی نمودند. نتایج آن‌ها نشان داد که روش سری‌های زمانی نسبت به روش شبکه عصبی و نزدیک ترین همسایگی در مدل‌سازی و پیش‌بینی مقادیر SPI برتر بوده و پیش‌بینی‌های انجام شده با SPI در مقیاس‌های زمانی ۹ و ۱۲ ماهه بهتر از SPI در مقیاس‌های زمانی ۳ و ۶ بودند. بدرفاشان و همکاران (۱۳۸۸) در مطالعه‌ای موردی در بندرانزلی به ارزیابی کارایی مدل‌های هیبرید شبکه عصبی استوکاستیک برای پیش‌بینی خشکسالی پرداختند. این مطالعه بر مبنای سری زمانی شاخص SPI در مقیاس ۱۲ ماهه انجام و نتایج نشان داد که در تمام گام‌های پیش‌بینی، ترکیب مدل‌های شبکه عصبی-استوکاستیک (هیبرید) نتیجه بسیار مناسب‌تری نسبت به کاربرد مجزای آن‌ها داشته و با افزایش گام زمانی اختلاف دقت مدل‌های هیبرید با سایر مدل‌ها افزایش می‌یابد. کمالی و همکاران (۲۰۱۵) با استفاده از داده‌های بارش ماهانه سال‌های ۱۹۶۱ تا ۲۰۱۲ ایستگاه سینوپتیک یزد به پیش‌بینی خشکسالی با مدل‌های شبکه عصبی مصنوعی، سیستم استنتاج عصبی فازی، ماشین بردار پشتیبان و مدل سری زمانی و مقایسه آن‌ها پرداختند.

2. Group Method of Data Handling
3. Sumsodin et al
4. Rawls et al
5. Azamathulla et al

1. Surface Water Supply Index

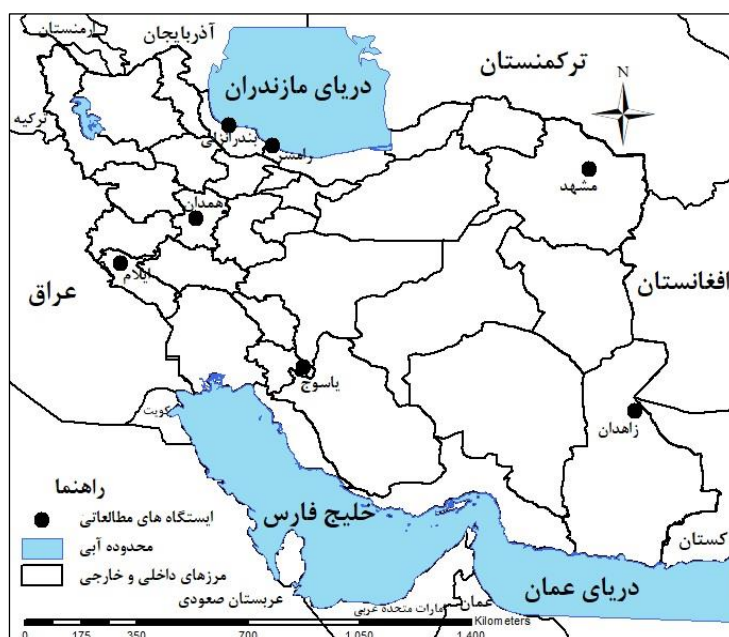
میلی‌متر بین دو نصف النهار 44° و 64° شرقی و دو مدار 25° و 40° شمالی واقع شده است. حدود $94/8$ درصد از سطح آن، در زمره مناطق خشک و نیمه‌خشک با ریزش‌های جوی کم و تبخیرتغرق زیاد قرار دارد. در این تحقیق، ایستگاه‌های هواشناسی براساس طبقه‌بندی اقلیمی دومارتن گسترش یافته طبق معادله (۱) $I = \frac{P}{T+10}$ تعریف شدند. P میانگین سالانه بارش و T میانگین سالانه دمای هوا می‌باشد (علیزاده و همکاران، ۱۳۸۸). همچنین در طبقه‌بندی دومارتن گسترش یافته از میانگین حداقل دمای هوای روزانه در سردترین ماه سال (m) استفاده می‌شود که اقلیم‌های مختلف را به چهار دسته گرمسیر ($5 < m$)، معتدل ($0 < m < 5$)، سردسیر ($-7 < m < 0$) و فراسرد ($m < -7$) تقسیم می‌کند (رحیمی و همکاران، ۲۰۱۲). در سیستم دومارتن، مقادیر کوچکتر از ۵ شاخص خشکی (I)، اقلیم فراخشک و برای مقادیر بزرگتر از ۵۵، نوع اقلیم را بسیار مرطوب (ب) معرفی می‌کند. دسته بندی اقلیم‌های مختلف این سیستم در جدول ۱، موقعیت مکانی ایستگاه‌های مورد مطالعه در گستره ایران، در شکل ۱ و همچنین مشخصات جغرافیایی و اقلیمی ایستگاه‌های مذکور در جدول ۲ آورده شده است.

اشل در رودخانه با استفاده از روش هوشمند داده محور (GMDH) پرداختند. نتایج بدست آمده از این روش، دارای دقت خوب و قابل قبولی جهت شبیه‌سازی رابطه دبی - اشل بودند.

با توجه به اهمیت مسأله خشکسالی و آسیب‌هایی که در بخش‌های مختلف منابع آب کشور وارد می‌سازد، انتخاب روشی مناسب که به عنوان یک ابزار قدرتمند بتواند زمان و چگونگی وقوع این پدیده را مدل‌سازی و پیش‌بینی نماید، امری ضروری می‌باشد. بنابراین هدف از این مطالعه، بررسی و مدل‌سازی وضعیت خشکسالی در نمونه‌های اقلیمی متفاوت ایران براساس شاخص بارش استاندارد شده (SPI) می‌باشد. در این راستا عملکرد مدل کنترل گروهی داده‌ها (GMDH) و سیستم استنتاج فازی-عصبی (ANFIS) که از دسته مدل‌های هوشمند محسوب می‌شوند، مورد بررسی قرار گرفت.

مواد و روش‌ها

ایران با متوسط بارش سالانه ۲۴۱ میلی‌متر بین دو نصف النهار 44° و 64° شرقی و دو مدار 25° و 40° شمالی واقع شده است. حدود $94/8$ درصد از سطح آن، در زمره مناطق خشک و نیمه‌خشک با ریزش‌های جوی کم و تبخیرتغرق زیاد قرار دارد. ایران با متوسط بارش سالانه ۲۴۱



شکل ۱- پراکنش ایستگاه‌های هواشناسی مورد مطالعه بر گستره ایران

جدول ۱- دسته‌بندی اقلیم‌های مختلف سیستم دمارتن

اقلیم اصلی	فراخشک	خشک	نیمه خشک	مدیترانه‌ای	نیمه مرطوب	مرطوب	بسیار مرطوب الف	بسیار مرطوب ب
I	I < 5	5 < I < 10	10 < I < 20	20 < I < 24	24 < I < 28	28 < I < 35	35 < I < 45	I < 55

جدول ۲- مشخصات جغرافیایی و اقلیمی ایستگاه‌های مورد مطالعه در سیستم طبقه‌بندی دمارتن گسترش یافته در دوره آماری ۲۰ ساله

ایستگاه	طول جغرافیایی (درجه)	عرض جغرافیایی (درجه)	ارتفاع از سطح دریا (متر)	نوع اقلیم
زاهدان	۶۰/۹۰	۲۹/۴۷	۱۳۷۰	فراخشک معتدل
مشهد	۵۹/۶۳	۳۶/۲۴	۹۹۹/۲	خشک سردسیر
همدان	۴۸/۵۳	۳۴/۸۷	۱۷۴۰/۸	نیمه‌خشک فراسرد
ایلام	۴۶/۳۹	۳۳/۵۹	۱۳۳۷	مدیترانه‌ای معتدل
یاسوج	۵۱/۵۵	۳۰/۶۹	۱۸۱۶/۳	مرطوب سردسیر
رامسر	۵۰/۶۷	۳۶/۹۰	-۲۰	بسیار مرطوب (الف) معتدل
بندرانزلی	۴۹/۴۵	۳۷/۴۸	-۲۳/۶	بسیار مرطوب (ب) معتدل

شاخص بارش استاندارد شده (SPI) $\hat{\beta} = \frac{\bar{x}}{\hat{\alpha}}$ (۵)

که در آن:

$$A = \ln(\hat{x}) - \frac{\sum \ln(x)}{n} \quad (6)$$

که n تعداد مشاهدات بارش می‌باشد.

برای محاسبه SPI، ابتدا یک توزیع گاما با پارامترهای محاسبه شده به اطلاعات بارش هر ایستگاه برازش داده می‌شود. پارامترهای α و β برای هر سری بارش باید به طور جداگانه محاسبه شود. در محاسبه SPI از تابع توزیع احتمال تجمعی استفاده می‌شود که احتمال تجمعی از معادله ۷ محاسبه می‌گردد (Bordi et al, 2004):

$$F(x) = \int_0^x f(x) dx = \frac{1}{\Gamma(\alpha)\beta} \int_0^x x^{\alpha-1} e^{-\frac{x}{\beta}} dx \quad (7)$$

گام بعدی در محاسبه SPI، انتقال احتمال تجمعی از توزیع گامای بدست آمده به توزیع نرمال استاندارد تجمعی با میانگین صفر و انحراف معیار یک می‌باشد. در واقع SPI عبارت از متغیری از تابع توزیع نرمال استاندارد است که مقدار احتمال تجمعی آن با مقدار احتمال تجمعی متغیر مورد نظر از تابع توزیع گامای بدست آمده مساوی باشد. بهترین حالت انتقال یک متغیر از یک توزیع آماری به توزیع آماری دیگر، انتقال هم احتمال می باشد که در آن احتمال‌های کمتر یا مساوی دو متغیر از دو توزیع برابر با هم فرض می‌شوند. مقادیر طبقه‌های مختلف شدت خشکسالی برای شاخص SPI در جدول ۳ ارائه شده است.

شاخص بارش استاندارد شده (SPI) توسط مکی و همکاران (McKee, 1993) به منظور تعیین و پایش خشکسالی ارائه گردید. هدف از ارائه شاخص SPI، ارائه یک شاخص عددی بود که بتواند ریزش‌های جوی مناطق با اقلیم‌های متفاوت را با هم مقایسه کند. تنوع کاربرد، به شاخص SPI این امکان را داده است که خشکسالی را هم برای مقیاس‌های کوتاه‌مدت و هم برای مقیاس‌های درازمدت پایش نماید.

به تجربه ثابت شده است که توزیع احتمال بارش در یک ایستگاه غالباً از تابع توزیع احتمال گاما پیروی می‌کند. تابع چگالی احتمال این توزیع به صورت معادله ۲ است (Bordi et al, 2004):

$$f(x) = \frac{1}{\beta \alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}} \quad x > 0 \quad (2)$$

که در این معادله، x مقدار متغیر، α پارامتر شکل و β پارامتر مقیاس توزیع و $\Gamma(x)$ تابع گاما است که معادله آن به صورت معادله ۳ می‌باشد.

$$\Gamma(x) = \int_0^{\infty} y^{\alpha-1} e^{-y} dy \quad (3)$$

ضرایب α و β بهینه نیز از طریق معادلات ۴ و ۵ محاسبه می‌شوند (Edwards and McKee, 1997):

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

جدول ۳- طبقه بندی خشکسالی براساس شاخص SPI (Edwards and McKee, 1997)

مقدار SPI	طبقه بندی خشکسالی
۲ و بیشتر	ترسالی بسیار شدید
۱/۵ تا ۱/۹۹	خیلی مرطوب
۱ تا ۱/۴۹	ترسالی متوسط
۰/۹۹ تا ۰/۰۱	ترسالی ملایم
۰ تا ۰/۹۹	نرمال
-۱ تا -۱/۴۹	خشکسالی متوسط
-۱/۵ تا -۱/۹۹	خشکسالی شدید
-۲ و کمتر	خشکسالی بسیار شدید

یک چندجمله‌ای درجه دوم فرض می‌شوند (معادله ۹). پارامترهای مجهول الگوریتم GMDH ضرائب چندجمله‌ای معادله ۹ است. به منظور محاسبه مقدار خروجی برای هر بردار ورودی براساس معادله ۹، باید میانگین مربعات خطا (معادله ۱۰) به حداقل برسد.

$$y_i = a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2 + a_4x_1^2 + a_5x_2^2 \quad (9)$$

$$e = \sum_{i=1}^n (\hat{y}_i - y)^2 \quad (10)$$

که در آن، a_0 تا a_5 ضرائب چندجمله‌ای، x_1 و x_2 بردارهای ورودی و y_i خروجی مدل می‌باشد.

در طراحی روش GMDH، هدف جلوگیری از رشد و اگرایی شبکه و نیز مرتب کردن شکل و ساختار شبکه به یک یا چند پارامتر عددی بوده، به گونه‌ای که با تغییر این پارامتر ساختار شبکه نیز تغییر می‌کند. شماتیکی از این روش همراه با ساختار هر نرون در شکل ۲ نشان داده شده است.

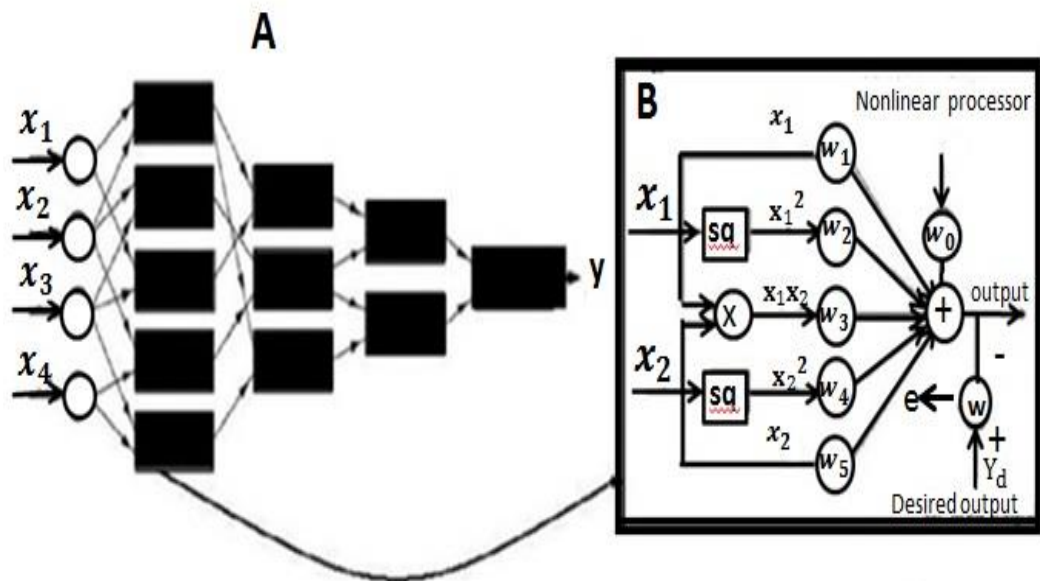
روش کنترل گروهی داده‌ها (GMDH)

به طور کلی برای مدل کردن سیستم‌های پیچیده‌ای که شامل مجموعه‌ای از داده‌ها با چندین ورودی و یک خروجی می‌باشند می‌توان از چندجمله‌ای‌های کولموگوروف-گابور (VKG) که در معادله ۸ ذکر شده است، استفاده نمود (Ivakhnenko, 1968).

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \dots \quad (8)$$

که در آن x_i عبارت است از (x_1, x_2, \dots, x_n) به عنوان بردارهای ورودی، y مقدار خروجی مدل و a_i ها ضرائب چندجمله‌ای می‌باشند.

چندجمله‌ای‌های VKG با استفاده از چندجمله‌ای‌های درجه دوم تقریب زده می‌شوند. این چندجمله‌ای‌های درجه دوم براساس ترکیبات دوتایی ورودی‌های شبکه ساخته می‌شوند. الگوریتم GMDH با استفاده از این ایده به عنوان روش یادگیری، برای مدل‌سازی سیستم‌های پیچیده معرفی شده است (Ivakhnenko, 1968). روش GMDH به خانواده روش‌های فراکاوشی خودسازماندهی تعلق دارد که از مفاهیم جعبه سیاه، مفهوم همبستگی و استقرا استفاده می‌کند. روش GMDH دارای ساختار یک شبکه چند لایه و رو به جلو است و دربرگیرنده مجموعه‌ای از نرون‌ها است که از پیوند جفت‌های مختلف ورودی از طریق یک چندجمله‌ای درجه دوم بوجود می‌آیند. هرلایه در این شبکه از یک یا چند واحد پردازشگر تشکیل شده است که هر یک از آن‌ها دارای دو ورودی و یک خروجی است. این واحدها عملاً نقش اجزای سازنده مدل را ایفا می‌نمایند و به شکل



شکل ۲- ساختار GMDH (A لایه‌ها و متغیرهای ورودی B) ساختار هر نرون (قادری و همکاران، ۱۳۸۹)

از داده‌ها که در مرحله آموزش به‌کار نرفته، به عنوان ورودی در مرحله صحت‌سنجی مورد استفاده قرار می‌گیرند تا از دقت و اعتبار مدل اطمینان حاصل شود. مطابق شکل ۳ مدل ANFIS غالباً از یک سیستم فازی سوگنو استفاده کرده و به صورت ساختار شبکه‌ای پیش‌رونده، دارای پنج لایه می‌باشد (Aqil et al, 2007). ANFIS شبکه تطبیق‌پذیر و قابل آموزشی است که به لحاظ عملکرد کاملاً مشابه سیستم استنتاج فازی است (Chua and Wong, 2010). برای سادگی کار فرض می‌شود که سیستم فازی دارای دو ورودی x و y و خروجی f است. حال قوانین آن به صورت معادلات ۱۱ می‌باشند، ساختار ANFIS پنج لایه در شکل ۳ نشان داده است.

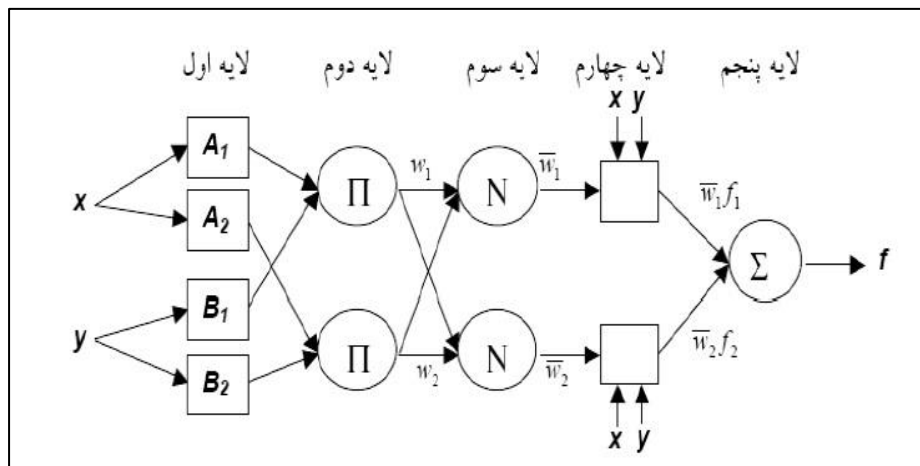
سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)

سیستم استنتاج فازی-عصبی (Jang, 1993)، اجازه می‌دهد سیستم‌های فازی در مباحث آموزش پارامترها، از الگوریتم آموزش تطبیقی استفاده نمایند (Morgan, 1998). در سیستم استنتاج فازی-عصبی تطبیقی ابتدا ساختار یک مدل با پارامترهای مشخص که متناسب با ورودی‌ها، درجه عضویت و قوانین است، انتخاب می‌شود. سپس بخشی از داده‌های موجود که در برگیرنده تمامی خصوصیات داده‌ها (پیشینه و کمینه) باشد، انتخاب شده و در مرحله آموزش با حداقل کردن میزان خطا، پارامترهای مدل به مقادیر واقعی نزدیک می‌شود. پس از آموزش سیستم و انتخاب پارامترهای مناسب، نیاز به صحت‌سنجی مدل است. از این رو بخشی

$$\text{Rule 1: if } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = p_1x + q_1y + r_1$$

$$\text{Rule 2: if } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f_2 = p_2x + q_2y + r_2$$

(۱۱)



شکل ۳- ساختار کلی مدل فازی-عصبی تطبیقی (Jang, 1993)

نتایج و بحث

توسعه GMDH جهت مدل‌سازی خشکسالی

یکی از مسائل مهم در طراحی شبکه GMDH جهت بدست آوردن رابطه‌ی مطلوب بین متغیرهای ورودی و خروجی، تعیین مقدار لایه‌ها و نرون‌های هر لایه و ارتباط بین نرون‌ها می‌باشد (سلیمانی‌کیا، ۲۰۰۷). براساس مشاهدات تجربی و مطالعه سایر محققان، متغیرهای ورودی موثر در پیش‌بینی و مدل‌سازی خشکسالی در یک منطقه، براساس شاخص خشکسالی انتخاب شده می‌باشد. با توجه به استفاده از شاخص SPI در این پژوهش، از داده‌های مربوط به بارندگی در ایستگاه‌های مطالعاتی ذکر شده با تاخیرهای زمانی $P(t-1)$ ، $P(t-2)$ ، $P(t-3)$ و با طول دوره آماری بیست سال، از سال ۱۹۹۶ تا ۲۰۱۵ استفاده شده است. پس از انتخاب متغیرها، ۷۰ درصد داده‌ها برای آموزش شبکه و ۳۰ درصد داده‌ها برای آزمون مدل توسعه داده شده مورد استفاده قرار گرفته است.

پس از محاسبه شاخص SPI در مقیاس‌های زمانی ۶، ۳ و ۱۲ ماهه، ورودی‌های مدل که ترکیب‌های متفاوتی از مقادیر شاخص و بارندگی در گام‌های تاخیر مختلف بود، با سعی و خطا (تغییر در تعداد لایه‌ها و نرون‌ها) انتخاب شدند. با توجه به شاخص، ۹ مدل برای SPI برای هر ایستگاه براساس جدول ۴ در نظر گرفته شد. افزایش تعداد لایه‌ها و نرون‌ها سبب پیچیده‌تر شدن محاسبات و کاهش خطای مدل‌سازی می‌شود اما با مشکلاتی چون افزایش

معیارهای آماری

به‌منظور بررسی و مقایسه نتایج بدست آمده از مدل‌سازی از معیارهای آماری رایج و پرکاربرد استفاده می‌شود. در این پژوهش از معیارهای آماری ریشه میانگین مربعات خطا (RMSE)، ضریب تبیین (R^2) و میانگین قدرمطلق خطا (MAE)، طبق معادلات ۱۲ تا ۱۴ برای ارزیابی کارایی مدل‌ها و در نتیجه انتخاب بهترین مدل استفاده شده است. کمیت R^2 که ضریب تبیین نیز نامیده می‌شود، نسبت تغییرات (متغیرهای) تعریف شده به کل تغییرات (متغیرها) می‌باشد. مقدار ضریب تبیین در محدوده صفر و یک بوده و معرف درصدی از خوانده‌هاست که به خط رگرسیون نزدیک‌تر می‌باشند. شاخص‌های RMSE و MAE مثبت بوده و هر چه به صفر نزدیک‌تر باشند، دلالت بر وجود اختلافات کمتر بین مقادیر پیش‌بینی شده یک متغیر توسط یک مدل و مقادیر واقعی مشاهده شده آن متغیر می‌باشد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - t_i)^2}{n}} \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (O_i - t_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |t_i - O_i| \quad (14)$$

که در معادلات بالا، O_i و t_i به ترتیب مقادیر مشاهده شده و پیش‌بینی شده (خروجی مدل) و \bar{O}_i میانگین مقادیر مشاهداتی در گام زمانی i ام و n تعداد داده‌ها می‌باشند.

حجم و زمان محاسبات و پیچیدگی فرایند پیش‌بینی همراه خواهد بود.

جدول ۴- ساختار مدل‌های پیش‌بینی برای شاخص SPI در مدل GMDH

مدل	ساختار ورودی‌ها							خروجی
M1	SPI(t-1)	SPI(t-2)						SPI(t)
M2	SPI(t-1)	SPI(t-2)	SPI(t-3)					SPI(t)
M3	SPI(t-1)	SPI(t-2)	SPI(t-3)	SPI(t-4)				SPI(t)
M4	SPI(t-1)	SPI(t-2)	SPI(t-3)	SPI(t-4)	SPI(t-5)			SPI(t)
M5	P(t-1)	P(t-2)						SPI(t)
M6	P(t-1)	P(t-2)	P(t-3)					SPI(t)
M7	SPI(t-1)	SPI(t-2)	SPI(t-3)	P(t-1)	P(t-2)			SPI(t)
M8	SPI(t-1)	SPI(t-2)	SPI(t-3)	SPI(t-4)	P(t-1)	P(t-2)		SPI(t)
M9	SPI(t-1)	SPI(t-2)	SPI(t-3)	SPI(t-4)	SPI(t-5)	P(t-1)	P(t-2)	SPI(t)

توسعه ANFIS برای مدل‌سازی خشکسالی

برای آموزش سیستم فازی-عصبی دو روش افراز شبکه‌ای و خوشه‌بندی جزئی وجود دارد. تفاوت عمده این دو روش در چگونگی تعیین تابع عضویت فازی است. در روش جداسازی شبکه‌ای، نوع و تعداد تابع عضویت بردار اطلاعات ورودی، توسط کاربر تعیین می‌شود و در روش خوشه‌بندی جزئی نوع تابع عضویت با توجه به خصوصیات بردار اطلاعات ورودی و دسته‌بندی‌های موجود در آن‌ها، توسط مدل تعیین می‌گردد. برای مدل فازی-عصبی از نوع افراز شبکه، ساختار اصلی مدل شامل نوع تابع عضویت و تعداد توابع عضویت می‌باشد. در پژوهش حاضر، جهت استفاده از سیستم ANFIS با روش جداسازی شبکه‌ای، برنامه‌ای در محیط نرم افزار MATLAB ver. R2017a تدوین گردید. دو نوع تابع عضویت مثلثی، گوسی که نسبت به سایر توابع کاربردی‌تر هستند، مورد استفاده قرار گرفتند. همچنین برای هر تابع عضویت، تعداد توابع ۲، ۳ و ۴ مورد بررسی قرار گرفتند و سپس از الگوی ورودی که برای شاخص SPI تعریف شد (شاخص SPI-بارش)، در نهایت بهترین تابع عضویت و تعداد آن بر مبنای مقادیر بهینه معیارهای آماری انتخاب گردید. لازم به ذکر است داده‌ها به دو دسته‌ی آموزش و آزمون تقسیم شدند. مجموعه آموزش ۷۰ درصد کل داده‌ها و مجموعه آزمون ۳۰ درصد کل داده‌ها در هر یک از مقیاس‌های زمانی در نظر گرفته شد.

نتایج توسعه GMDH جهت مدل‌سازی

خشکسالی

برای مدل‌سازی خشکسالی در اقلیم‌های مختلف توسط مدل GMDH، از داده‌های بارش در ایستگاه‌های ذکر شده و شاخص SPI استفاده شد. با توجه به حالت‌های مختلف به عنوان ورودی که در جدول ۴ نشان داده شد، مدل توسعه داده شده GMDH بطور جداگانه برای هر حالت اجرا گردید. لازم به ذکر است پس از بررسی نمودارهای همبستگی، در رابطه با شاخص SPI، بارش و SPI به ترتیب پس از گام تأخیر دوم و پنجم با یکدیگر رابطه معنی‌داری داشته‌اند. ۷۰ درصد داده‌ها برای آموزش شبکه و ۳۰ درصد داده‌ها برای آزمون مدل توسعه داده شده در دوره آماری بیست ساله، مورد استفاده قرار گرفته است. در مرحله آموزش فرض می‌شود که خروجی هر نرون برابر با خروجی نهایی از کل سیستم می‌باشد و سپس مقادیر وزن‌ها از روش تخمین حداقل مربعات بدست می‌آیند. پس از اینکه شبکه GMDH برای پیش‌بینی پدیده خشکسالی، در تمامی ایستگاه‌های ذکر شده، توسعه و آموزش داده شد و ماتریس‌های وزنی در نرون‌های منتخب در هر لایه تهیه شد، با استفاده از یک سری داده‌های جداگانه که در فرایند آموزش هیچ دخالتی نداشته‌اند، نتایج بدست آمده از دوره آموزش کنترل شد. همانطور که قبلاً ذکر شد در این پژوهش ۳۰ درصد از کل داده‌ها، جهت استفاده در مرحله

آزمون در نظر گرفته شد. با استفاده از این داده‌ها کد مجددا اجرا و نتایج آن با نتایج حاصل از سری آموزش مقایسه می‌شود. در ادامه نتایج مربوط به بهترین مدل، پس از اجرای ۹ مدل برای شاخص SPI در هر سه گام زمانی، برای هر ایستگاه (اقلیم) با توجه به مقادیر معیارهای خطا، ارائه می‌گردد. در جداول ۵ تا ۷، مقدار معیارهای خطای بهترین مدل در هر ایستگاه در هر دو مرحله آموزش و آزمون، آورده شده است.

جدول ۵- نتایج عملکرد بهترین مدل مناسب برای SPI-3 در همه ایستگاه‌ها در مدل GMDH

ایستگاه	مرحله آموزش			مرحله آزمون		
	R ²	RMSE	MAE	R ²	RMSE	MAE
زاهدان	۰/۳۸	۱/۹۱	۰/۹۲	۰/۳۵	۱/۸۱	۰/۹۳
مشهد	۰/۳۵	۱/۹۵	۰/۹۵	۰/۴۱	۲/۲۲	۰/۹۱
همدان	۰/۴۱	۲/۷۲	۰/۹۰	۰/۳۸	۲/۶۶	۰/۹۲
ایلام	۰/۴۱	۳/۱۲	۰/۹۱	۰/۳۸	۳/۰۲	۰/۹۲
یاسوج	۰/۳۶	۳/۱۶	۰/۹۳	۰/۴۱	۳/۲۵	۰/۹۱
رامسر	۰/۴۱	۳/۸۹	۰/۹۰	۰/۴۰	۳/۸۵	۰/۹۱
بندر انزلی	۰/۳۶	۴/۲۲	۰/۹۳	۰/۳۶	۴/۲۵	۰/۹۳

جدول ۶- نتایج عملکرد بهترین مدل مناسب برای SPI-6 در همه ایستگاه‌ها در مدل GMDH

ایستگاه	مرحله آموزش			مرحله آزمون		
	R ²	RMSE	MAE	R ²	RMSE	MAE
زاهدان	۰/۳۶	۱/۷۲	۰/۹۲	۰/۳۰	۱/۶۵	۰/۹۵
مشهد	۰/۳۱	۲/۷۲	۰/۹۴	۰/۳۰	۲/۶۹	۰/۹۴
همدان	۰/۲۹	۲/۸۹	۰/۹۵	۰/۳۱	۲/۹۵	۰/۹۴
ایلام	۰/۳۶	۳/۴۴	۰/۹۲	۰/۳۰	۳/۱۵	۰/۹۵
یاسوج	۰/۳۱	۳/۶۶	۰/۹۴	۰/۳۱	۳/۵۹	۰/۹۵
رامسر	۰/۳۴	۴/۱۴	۰/۹۳	۰/۳۵	۴/۰۹	۰/۹۳
بندر انزلی	۰/۳۱	۴/۹۲	۰/۹۴	۰/۳۰	۴/۸۶	۰/۹۴

جدول ۷- نتایج عملکرد بهترین مدل مناسب برای SPI-12 در همه ایستگاه‌ها در مدل GMDH

ایستگاه	مرحله آموزش			مرحله آزمون		
	R ²	RMSE	MAE	R ²	RMSE	MAE
زاهدان	۰/۱۷	۰/۱۰	۰/۹۹	۰/۱۸	۰/۰۹	۰/۹۹
مشهد	۰/۲۵	۰/۲۲	۰/۹۵	۰/۱۸	۰/۱۱	۰/۹۸
همدان	۰/۲۵	۰/۱۴	۰/۹۶	۰/۲۰	۰/۱۱	۰/۹۸
ایلام	۰/۱۸	۰/۱۰	۰/۹۹	۰/۲۳	۰/۱۸	۰/۹۷
یاسوج	۰/۱۸	۰/۱۳	۰/۹۹	۰/۱۸	۰/۰۹	۰/۹۹
رامسر	۰/۲۴	۰/۱۵	۰/۹۶	۰/۲۳	۰/۱۸	۰/۹۷
بندر انزلی	۰/۲۴	۰/۱۶	۰/۹۸	۰/۱۸	۰/۱۰	۰/۹۹


نیز همین روند افزایشی RMSE در مقادیر بدست آمده در جدول‌ها دیده می‌شود. در واقع عملکرد مدل‌های ذکر شده در روش کنترل گروهی داده‌ها در اقلیم‌های مدیترانه‌ای، مرطوب و بسیار مرطوب (الف و ب) به دلیل افزایش مقدار RMSE، پایین‌تر از اقلیم‌های فراخشک، خشک و نیمه خشک می‌باشد. علت این روند را می‌توان در تأثیر میزان بارش در مدل‌سازی و پیش‌بینی در اقلیم، جستجو کرد.

همچنین نتایج حاکی از عملکرد مناسب SPI در مقیاس دوازده ماهه دارد. SPI سه ماهه توانایی کمتری در پیش‌بینی خشکسالی دارد. علت این موضوع می‌تواند پراکندگی و تغییرات شدید SPI در مقیاس سه ماهه باشد. در واقع، بهبود عملکرد مدل‌های ساخته شده با افزایش مقیاس زمانی محاسبه SPI، رابطه مستقیمی دارد. بدین معنی که با افزایش مقیاس محاسبه SPI، مقادیر معیارهای ارزیابی مورد استفاده بهبود می‌یابد.


جهت ارزیابی کارایی مدل GMDH در پیش‌بینی خشکسالی، پس از اجرای مدل، نمودار پراکنش مربوط به داده‌های پیش‌بینی شده و داده‌های مشاهده شده ترسیم شد. با بررسی این نمودارها و مقادیر خطای پیش‌بینی، می‌توان کارایی مدل را برای پیش‌بینی خشکسالی تعیین نمود. به دلیل محدودیت و جلوگیری از افزایش حجم مطالب، نمودار مقایسه‌ی داده‌های مشاهده‌شده با داده‌های پیش‌بینی شده مقیاس‌های زمانی مختلف SPI، تنها در سه اقلیم، در شکل‌های ۴ تا ۶ ارائه شده است.

با توجه به نتایج ارائه شده در جداول ۵ تا ۷، در مدل‌سازی با روش GMDH، مدل‌های M4 و M9 به ترتیب با متغیرهای ورودی $\{SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4), SPI(t-5)\}$ و $\{SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4), SPI(t-5), P(t-1), P(t-2)\}$ دارای خطای کم و دقت بالاتری بوده و شاخص‌های آماری محاسبه شده برای داده‌های آموزش و آزمون در دامنه قابل قبول و رضایت‌بخش می‌باشند. نتایج مدل‌های M5 و M6 که تنها بارش را به عنوان متغیر ورودی در نظر می‌گیرند با دارا بودن مقادیر بالای RMSE، از عملکرد پایینی برخوردار بوده‌اند.


جداول ۵ تا ۷ نشان می‌دهند که مقادیر ضریب تبیین در هر سه مقیاس و در تمامی ایستگاه‌ها در سطح اعنماد ۰/۹۵، قابل قبول بوده و معنادار هستند. مقدار R^2 در تمامی مقیاس‌های SPI، بین ۰/۹۰ و ۰/۹۹ بوده و این نشان‌دهنده عملکرد خوب مدل GMDH است. مقدار RMSE، با تغییر نوع اقلیم از خشک به سمت مرطوب، رو به افزایش است. بطوریکه برای ایستگاه‌های زاهدان، مشهد و همدان مقدار RMSE مرحله آزمون در مقیاس سه ماهه به ترتیب برابر است با ۱/۸۱، ۲/۲۲، ۲/۶۶ و ایستگاه‌های ایلام، یاسوج، رامسر و بندرانزلی به ترتیب با اقلیم‌های مدیترانه‌ای معتدل، مرطوب سردسیر، بسیار مرطوب (الف) و بسیار مرطوب (ب) معتدل در مقیاس سه ماهه دارای مقادیر RMSE، به ترتیب ۳/۰۲، ۳/۲۵، ۳/۸۵ و ۴/۲۵ می‌باشند. در مقیاس شش ماهه



شکل ۴- نمودار پراکنش مقادیر مشاهداتی و پیش‌بینی شده SPI-12 و SPI-6 و SPI-3 ماهه در ایستگاه زاهدان



شکل ۵- نمودار پراکنش مقادیر مشاهداتی و پیش‌بینی شده SPI-12 و SPI-6 و SPI-3 ماهه در ایستگاه ایلام



شکل ۶- نمودار پراکنش مقادیر مشاهداتی و پیش‌بینی شده SPI-12 و SPI-6 و SPI-3 ماهه در ایستگاه بندرانزلی

ورودی دوم و تا ورودی آخر به همین شکل ارائه شده است.

برای مثال در ایستگاه زاهدان، الگویی که شامل بارش در گام تاخیر دو و شاخص SPI سه ماهه در تاخیر زمانی سه با تابع عضویت از نوع گوسی و تعداد توابع برای متغیرهای ورودی به ترتیب برابر ۲، ۲، ۳، ۳، ۳، استفاده شود، با توجه به مقادیر معیارهای آماری، بهترین مدل تعیین گردید. در مقیاس‌های شش و دوازده ماهه SPI ایستگاه زاهدان نیز تابع گوسی با تعداد توابع عضویت ۲، ۳، ۳، ۳ و ۲ برای مقیاس شش ماهه و ۳، ۲، ۲، ۳ و ۲ برای مقیاس دوازده ماهه بهترین مدل انتخاب شد.

نتایج توسعه ANFIS جهت مدل سازی خشکسالی

نتایج مدل‌سازی سیستم استنتاج فازی-عصبی، در جدول‌های ۸ تا ۱۰، بهترین مدل برای هر سه مقیاس زمانی شاخص SPI در تمامی ایستگاه‌های مطالعاتی، به ازای ورودی‌های مختلف ارائه شده است. لازم به ذکر است در جدول‌های ۸ تا ۱۰، در ستون سوم بعد از نوع تابع (گوسی، gaussmf و مثلثی، trimf)، تعداد توابع برای هر یک از متغیرهای ورودی نشان داده شده است. اولین عدد مربوط به تعداد توابع ورودی اول، عدد دوم مربوط به توابع عضویت

جدول ۸- نتایج عملکرد بهترین مدل مناسب برای SPI-3 در همه ایستگاه‌ها در مدل ANFIS

آزمون			آموزش					
R ²	RMSE	MAE	R ²	RMSE	MAE	تعداد توابع	نوع تابع	ایستگاه
۰/۶۸	۰/۷۴	۰/۴۰	۰/۷۹	۰/۶۵	۰/۲۸	۲۳۲۳۴	trimf*	زاهدان
۰/۷۸	۰/۵۸	۰/۲۷	۰/۸۶	۰/۵۶	۰/۲۱	۲۲۲۳۳	gaussmf**	
۰/۶۸	۰/۷۴	۰/۴۰	۰/۶۱	۰/۵۹	۰/۳۱	۴۳۲۲۲	trimf	مشهد
۰/۷۳	۰/۶۴	۰/۲۶	۰/۷۸	۰/۵۸	۰/۲۷	۳۳۲۲۲	gaussmf	
۰/۷۵	۰/۵۲	۰/۲۳	۰/۷۹	۰/۶۵	۰/۲۸	۲۳۲۳۳	trimf	همدان
۰/۶۳	۰/۶۵	۰/۳۸	۰/۷۱	۰/۵۸	۰/۲۷	۲۳۳۳۳	gaussmf	
۰/۷۳	۰/۵۴	۰/۲۳	۰/۷۴	۰/۴۹	۰/۲۱	۲۲۳۴۲	trimf	ایلام
۰/۶۰	۰/۷۷	۰/۴۶	۰/۷۱	۰/۶۴	۰/۴۲	۲۳۳۲۲	gaussmf	
۰/۷۸	۰/۵۷	۰/۲۶	۰/۷۹	۰/۶۵	۰/۲۸	۳۲۲۳۳	trimf	یاسوج
۰/۷۴	۰/۴۹	۰/۲۴	۰/۷۱	۰/۵۸	۰/۲۷	۳۲۳۴۳	gaussmf	
۰/۵۹	۰/۵۹	۰/۲۵	۰/۶۱	۰/۵۹	۰/۳۱	۴۳۲۲۲	trimf	رامسر
۰/۶۷	۰/۶۹	۰/۴۹	۰/۷۱	۰/۶۴	۰/۴۲	۲۳۳۴۲	gaussmf	
۰/۵۹	۰/۷۵	۰/۵۰	۰/۶۴	۰/۶۶	۰/۳۵	۲۳۳۳۲	trimf	بندر انزلی
۰/۶۰	۰/۷۷	۰/۴۶	۰/۷۱	۰/۶۴	۰/۴۲	۲۳۳۲۲	gaussmf	

*تابع عضویت مثلثی

**تابع عضویت گوسی

جدول ۹- نتایج عملکرد بهترین مدل مناسب برای SPI-6 در همه ایستگاه‌ها در مدل ANFIS

آزمون			آموزش					
R ²	RMSE	MAE	R ²	RMSE	MAE	تعداد توابع	نوع تابع	ایستگاه
۰/۸۱	۰/۶۰	۰/۲۰	۰/۸۷	۰/۵۲	۰/۱۸	۲۲۲۲۲	trimf*	زاهدان
۰/۸۷	۰/۳۷	۰/۱۶	۰/۹۰	۰/۳۵	۰/۱۵	۲۴۳۳۲	gaussmf**	
۰/۸۰	۰/۶۴	۰/۳۰	۰/۹۳	۰/۲۹	۰/۱۵	۳۳۲۲۳	trimf	مشهد
۰/۸۷	۰/۳۶	۰/۱۷	۰/۸۹	۰/۴۳	۰/۱۸	۳۲۲۲۳	gaussmf	
۰/۸۳	۰/۵۷	۰/۲۶	۰/۸۴	۰/۵۸	۰/۲۶	۳۴۲۲۲	trimf	همدان
۰/۷۵	۰/۶۴	۰/۳۷	۰/۸۱	۰/۴۱	۰/۱۸	۴۲۲۲۳	gaussmf	
۰/۸۱	۰/۶۱	۰/۲۰	۰/۸۷	۰/۵۲	۰/۱۸	۲۲۲۲۲	trimf	ایلام
۰/۷۹	۰/۶۹	۰/۴۴	۰/۸۱	۰/۶۱	۰/۲۲	۲۳۳۲۳	gaussmf	
۰/۸۴	۰/۵۸	۰/۳۴	۰/۸۲	۰/۶۰	۰/۲۱	۴۲۳۳۳	trimf	یاسوج
۰/۷۹	۰/۷۴	۰/۴۹	۰/۸۱	۰/۴۱	۰/۱۸	۴۲۳۳۳	gaussmf	
۰/۷۹	۰/۶۲	۰/۳۴	۰/۸۲	۰/۶۰	۰/۲۱	۳۲۲۲۳	trimf	رامسر
۰/۸۱	۰/۶۰	۰/۳۲	۰/۸۴	۰/۵۹	۰/۴۳	۳۳۲۲۳	gaussmf	
۰/۸۳	۰/۴۲	۰/۲۰	۰/۸۷	۰/۵۳	۰/۱۸	۲۳۳۲۳	trimf	بندر انزلی
۰/۸۰	۰/۶۱	۰/۳۳	۰/۸۱	۰/۶۱	۰/۲۹	۲۳۳۲۲	gaussmf	

*تابع عضویت مثلثی

** تابع عضویت گوسی

جدول ۱۰- نتایج عملکرد بهترین مدل مناسب برای SPI-12 در همه ایستگاه‌ها در مدل ANFIS


آزمون			آموزش			تعداد توابع	نوع تابع	ایستگاه
R ²	RMSE	MAE	R ²	RMSE	MAE			
۰/۸۸	۰/۳۲	۰/۱۵	۰/۸۰	۰/۴۳	۰/۱۶	۳۲۲۲۳	trimf*	زاهدان
۰/۹۷	۰/۱۳	۰/۰۸	۰/۹۸	۰/۱۴	۰/۰۸	۳۲۲۳۲	gaussmf**	
۰/۹۷	۰/۱۹	۰/۰۸	۰/۹۷	۰/۱۹	۰/۰۸	۳۳۲۲۳	Trimf	مشهد
۰/۹۴	۰/۲۸	۰/۱۵	۰/۹۵	۰/۲۴	۰/۱۲	۲۳۲۲۳	gaussmf	
۰/۸۸	۰/۳۲	۰/۱۶	۰/۸۵	۰/۴۴	۰/۲۲	۲۲۲۲۳	Trimf	همدان
۰/۹۲	۰/۲۹	۰/۱۵	۰/۹۵	۰/۳۶	۰/۱۷	۳۲۲۲۳	gaussmf	
۰/۹۳	۰/۲۹	۰/۱۵	۰/۹۷	۰/۱۴	۰/۰۸	۲۳۲۲۳	Trimf	ایلام
۰/۹۵	۰/۲۳	۰/۱۲	۰/۹۰	۰/۴۴	۰/۱۵	۲۳۲۲۲	gaussmf	
۰/۹۲	۰/۳۰	۰/۱۵	۰/۹۴	۰/۲۹	۰/۱۵	۳۳۳۲۲	Trimf	یاسوج
۰/۹۱	۰/۳۳	۰/۱۶	۰/۹۵	۰/۳۴	۰/۱۷	۲۳۳۲۲	gaussmf	
۰/۹۲	۰/۲۹	۰/۱۶	۰/۹۷	۰/۱۴	۰/۰۸	۲۳۲۲۳	Trimf	رامسر
۰/۹۱	۰/۳۳	۰/۱۶	۰/۹۰	۰/۴۴	۰/۱۶	۲۳۲۲۳	gaussmf	
۰/۹۱	۰/۳۰	۰/۱۷	۰/۸۹	۰/۳۴	۰/۱۸	۲۳۳۲۲	Trimf	بندرانزلی
۰/۹۰	۰/۳۲	۰/۱۷	۰/۹۱	۰/۴۲	۰/۱۶	۲۲۲۳۴	gaussmf	

*تابع عضویت مثلثی


** تابع عضویت گوسی

تعیین نمود. به دلیل محدودیت و جلوگیری از افزایش حجم مطالب، نمودار مقایسه‌ی داده‌های مشاهده‌شده با داده‌های پیش‌بینی شده مقیاس‌های زمانی مختلف SPI، تنها در سه اقلیم، در شکل‌های ۷ تا ۹ ارائه شده است.


در بحث مربوط به ارزیابی کارایی مدل ANFIS در پیش‌بینی خشکسالی، پس از اجرای مدل، نمودار مقایسه‌ای مربوط به داده‌های پیش‌بینی شده و داده‌های مشاهده‌شده ترسیم شد. با بررسی این نمودارها و مقادیر خطای پیش‌بینی، می‌توان کارایی مدل را برای پیش‌بینی خشکسالی



شکل ۷-مقایسه شاخص SPI-12month و SPI-6month و SPI-3month پیش‌بینی شده و مشاهده شده در ایستگاه زاهدان



شکل ۸-مقایسه شاخص SPI-12month و SPI-6month و SPI-3month پیش‌بینی شده و مشاهده شده در ایستگاه ایلام



شکل ۹-مقایسه شاخص SPI-12month و SPI-6month و SPI-3month پیش‌بینی شده و مشاهده شده در ایستگاه بندرانزلی

مقایسه مقادیر ضریب تبیین در سه مقیاس SPI، نشان داد که با افزایش مقیاس زمانی شاخص، عملکرد مدل به طور قابل توجهی بهبود می‌یابد. مقادیر ضریب تبیین، از SPI-3 به سمت SPI-12 روند افزایشی داشته و نشان‌دهنده کاهش خطا هستند. علت این موضوع می‌تواند پراکندگی و تغییرات شدید SPI در مقیاس زمانی سه ماهه باشد. در واقع یافته‌های حاصل نشان می‌دهد که هرچه پراکندگی داده‌های ورودی مدل بیشتر باشد، مدل استنتاج فازی-عصبی تطبیقی

نتایج نشان دادند بدون توجه به نوع شاخص و مقیاس‌های زمانی آن، هرچه بر تعداد توابع عضویت فازی افزوده شود صرفاً پیچیدگی مدل را به همراه داشته و تأثیری بر بهبود عملکرد مدل نداشته و از بین دو تابع انتخاب شده گوسی و مثلثی، هر دو در شرایط مختلف ورودی‌ها (تعداد توابع عضویت ورودی‌های مدل) و نوع اقلیم، می‌توانند برآورد خوبی از مدل را ارائه دهند.

در مرحله آزمون بین ۰/۵۹ تا ۰/۷۸ بوده، در مقیاس SPI-6 این مقادیر از ۰/۷۵ تا ۰/۸۷ تغییر کرده و در مقیاس SPI-12 بین ۰/۸۸ تا ۰/۹۷ بدست آمده است. مقایسه سه مقیاس SPI در سیستم ANFIS نشان می‌دهد که عملکرد مدل با افزایش مقیاس زمانی به طور قابل توجهی بهبود می‌یابد. همچنین با توجه به نتایج این بخش، دریافت می‌شود که نوع اقلیم در کاهش خطا و عملکرد مدل‌سازی در سیستم استنتاج فازی-عصبی برای خشکسالی تأثیری نداشته است. در رابطه با مقایسه دو روش هوشمند ANFIS و GMDH، با توجه به معیارهای آماری، برتری عملکرد مدل GMDH نتیجه می‌شود. همچنین از نظر سرعت محاسبات نیز سرعت اجرای کد و انجام محاسبات GMDH به مراتب بیشتر از مدل ANFIS بوده است. نتایج مربوط به مقایسه مقادیر مشاهداتی و محاسبه شده هر سه مقیاس شاخص SPI با استفاده از مدل GMDH نشان داد پیش‌بینی خشکسالی با این روش قابل اطمینان و امکان استفاده از این مدل برای پیش‌بینی‌های آبی میسر می‌باشد. بطور کلی نتایج تولید شده توسط هر دو روش ANFIS و GMDH دارای دقت قابل قبولی بودند ولی نتایج بدست آمده از مدل GMDH بهتر بوده و به عنوان مدل برتر در پیش‌بینی خشکسالی در این پژوهش معرفی می‌گردد.

منابع

1. Azmathulla, M., Najafi, M., Hazi, A. 2013. Group Method of Data Handling to predict scour depth around bridge piers. *Neural Computing and Application*. 23(7), 2107-2112
2. Aqil, M., Kita, I., Yano, A., Nishiyama, S. 2007. Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool. *Journal of Environmental Management*. 85, 215-223
3. Bacanli, U., Firat, M., Dikbas, F. 2009. Adaptive Neuro-Fuzzy Inference System for drought forecasting. *Stochastic Environmental Research and Risk Assessment*. 23, 1143-1154
4. Bordi, I., Sutera, A. 2004. Drought variability and its climatic implications, *Global and Planetary Change*. 40(2), 115-127
5. Chua, L.H.C., Wong, T.S.W. 2010. Improving event-based rainfall-runoff modeling using a combined artificial neural

توانایی کمتری در شبیه‌سازی این نوع داده‌ها دارد. هر کدام از متغیرهای ورودی اعم از بارندگی و مقادیر پیشین SPI، در بازه زمانی دوازده ماهه از قابلیت مناسبی برای پیش‌بینی خشکسالی بهره‌مند هستند. بهبود عملکرد مدل‌های ساخته شده با افزایش مقیاس زمانی SPI رابطه مستقیمی دارد. در این خصوص نتایج مشابهی توسط صمدیان فرد واسدی (۱۳۹۵) ارائه شده است. نتایج آن‌ها در مطالعه‌ای برای مدل‌سازی پدیده خشکسالی نشان داد که با افزایش دوره زمانی شاخص SPI، دقت پیش‌بینی‌ها افزایش نموده و خطای مدل‌سازی با افزایش مقیاس زمانی کاهش می‌یابد. همچنین با توجه به نتایج ذکر شده، دریافت می‌شود که نوع اقلیم در کاهش خطا و عملکرد مدل‌سازی در سیستم استنتاج فازی-عصبی برای خشکسالی تأثیری نداشته است.

استفاده از متغیر بارندگی به عنوان ورودی مدل، با تاخیر زمانی دو، نتایج قابل قبولی را ارائه می‌دهد و مقادیر همبستگی در سطح اعتماد ۰/۹۵، معنادار می‌باشند اما در گام‌های زمانی بالاتر و تاخیرهای بیشتر، تغییرات ضریب تبیین و همبستگی، جزئی و بسیار تدریجی است و به لحاظ آماری معنادار نمی‌باشند.

نتیجه‌گیری

در پژوهش حاضر، به منظور مدل‌سازی و پیش‌بینی خشکسالی از دو روش هوشمند کنترل گروهی داده‌ها (GMDH) و سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) استفاده شده است. در این مطالعه هدف اصلی، مدل‌سازی خشکسالی با روش کنترل گروهی داده‌ها و مقایسه‌ی آن با سیستم استنتاج فازی-عصبی تطبیقی در اقلیم‌های مختلف در گستره ایران است. نتایج هر کدام از مدل‌ها به‌طور جداگانه ارائه شدند. نتایج روش GMDH نشان دادند مقادیر R^2 بدست آمده از روش GMDH در هر سه مقیاس ذکر شده شاخص SPI در محدوده ۰/۹۰ تا ۰/۹۹ تغییر کرده که نشان‌دهنده دقت بسیار مطلوب این مدل می‌باشد. نتایج سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) نشان داد که استفاده از هر دو تابع عضویت گوسی و مثلثی در شرایط مختلف ورودی‌ها و نوع اقلیم، می‌تواند برآورد خوبی از مدل را داشته باشد. مقادیر R^2 مدل‌های بهینه هر ایستگاه برای SPI-3 در سیستم ANFIS

- conjunction of wavelet transforms and neural networks. *Journal of Hydrological Engineering*. 8(6), 319-328
17. McKee, T.B., Doesken, N.J. 1993. The relationship of drought frequency and duration to time scales. Eight Conference on Applied Climatology. Anaheim, CA, American Meteorological Society
 18. Mishra, A.K., Desai, V.R., 2005. Drought forecasting using stochastic models. *Stochastic Environmental Research and Risk Assessment*. 19, 326-339
 19. Morgan, G.C. 1998. Fuzzy logic Routledge Encyclopedia of Philosophy. 3first edition Craig,E. Routledge, London
 20. Nguyen, V., Li, O., Nguyen, L. 2017. Drought forecasting using ANFIS- a case study in drought prone area of Vietnam. *The International Society of Paddy and Water Environment Engineering*. 15(3), 605-616
 21. Özger, M., Mishra, A.K. 2012. Long lead time drought forecasting using wavelet and fuzzy logic combination model: a case study in Texas. *Journal of Hydrometeorology*. 13(1), 284-297
 22. Qaderi, K., Arab, D.R., Teshnelab, M., Ghazagh, A. 2009. Intelligent Operation Modeling of Reservoirs Using Group Method of Data Handling (GMDH). *Iran Water Resources Research*. 6(3), 55-67
 23. Qaderi, K., Eivani, Z., Ahmadi, M.M. 2016. Estimation of Suspended Sediment Load Concentration in River System using Group Method of Data Handling (GMDH). *Journal of Watershed Management Research*. 7(13), 218-229
 24. Rahimi, J., Ebrahimipour, M., Khalili, A. 2012. Spatial changes of Extended De Martonne climatic zones affected by climate change in Iran. *Theoretical and Applied Climatology*. 112, 409-418
 25. Rawls, W.J., Pachepsky, Y.A., Ritchie, J.C., Sobecki, T.M., Bloodworth, h. 2003. Effect of soil organic carbon on soil water retention. *Journal of Water and Soil Resources*. 116(1), 61-76
 26. Ravinesh, C.D., Ozgur, K., Vijay, P.S. 2016. Drought forecasting in eastern Australia using multivariate adaptive regression spline least square support vector machine and M5Tree model. *Atmospheric Research*. 184, 149-175
 27. Samadianfard, S., Asadi, E. 2017. Prediction of SPI drought index using support vector and multiple linear regressions. *Journal of Water and Soil Resources*. 6(4), 1-16
 - network-kinematic wave approach. *Journal of Hydrology*. 390(1), 92-107
 6. David, J., Rappoport, P.N. 1974. The Use of Time Series Analysis techniques in forecasting meteorological drought. *Bulletin of the American Meteorological Society, Monthly Weather Review*. 102(2), 176-180
 7. Djerbouai, S., Souage, D. 2016. Drought Forecasting Using Neural Networks, Wavelet Neural Networks, and Stochastic Models: Case of the Algerois Basin in North Algeria. *Water Resources Management*. 30, 2445-2464
 8. Edwards, D.C., McKee, T.B. 1997. Characteristics of 20th century drought in the United States at multiple time scales. *Climatology Report*. Colorado State University Fort Collins Colorado
 9. Fathabadi, A., Gholami, H., Salajeghe, A., Azaivand, H., Khosravi, H. 2009. Drought forecasting using neural network and stochastic models. *American Eurasian Network for Scientific Information* 3(2), 137-146
 10. Hoseinzadeh, M., Qaderi, K., Ahmadi, M.M. 2015. Stage-discharge relationship modeling in river using artificial neural networks (ANN) and group method of data handling (GMDH) methods (Case study: Schuykill river). *Journal of water and soil Conservation*. 23(2), 171-184
 11. Hurst, H. 1951. Long Term Storage Capacity of Reservoirs, *Transactions of the American Society of Civil Engineers*. 116, 770-799
 12. Ivakhnenko, A.G. 1968. The Group Method of Data Handling-a Rival of the Method of Stochastic Approximation, *Soviet Automatic Control c/c of Avtomatika*. 1, 43-55
 13. Jang, J.S.R. 1993. ANFIS adaptive network based fuzzy inference system, *IEEE Transactions on Systems, Man and Cybernetics*. 3, 665-683
 14. Kamali, A., Moradi, M., Moradi, N. 2015. Application of several artificial intelligence models and ARIMAX model for forecasting drought using the Standardized Precipitation Index. *Journal of Environment Science Technology*. 2 (12), 1201-1210
 15. Karamooz, M., Rasooli, K., Nazif, S. 2006. Completion of drought combined index and its prediction using neural networks. *Proceedings of second conference of water resource management*
 16. Kim, T., Valdes, J.B. 2003. Nonlinear model for drought forecasting based on a

- International Association of Hydrogeologists. 333, 302-312
30. Sharma, B.R., Smakhtin, V.U. 2004. Potential of water harvesting as a strategic tool for drought mitigation. International Water Management Institute. 29(1), 112-118
31. Soleimanikia, F. 2007. Gasoline prices modeling and forecasting in the Exchange Singapore using a genetic algorithm based neural network (GMDH). Master's thesis, Faculty of Economics of Tehran Unniversity
28. Sumsudin, R., Ismail, S., Shabri, A. 2010. River flow forecasting: A Hybrid Model of Self Organizing Maps and Least Square Suport Vector Machine. Stochastic Environmental Research and Risk Assessment. 7, 8179-8212
29. Santos, C., Morais, B., Silva, B. 2009. Drought forecast using an artificial neural network for three hydrological zones in San Francisco River basin Brazil. Proceedings of Symposium HS.2 at the Joint Convention of The International Association of Hydrological Sciences (IAHS) and The