

# پیش‌بینی خشکسالی با نمایه SPI به‌روش مدل‌سازی ANFIS بر مبنای خوشه‌بندی C-mean فازی

مهدي كمامسي<sup>۱</sup>

محمد تقی اعلمی<sup>۲</sup>

وحید نورانی<sup>۳</sup>

(دریافت ۹۰/۳/۱۰)

پذیرش ۹۱/۴/۲۰)

## چکیده

خشکسالی نتیجه اندرکنش بین محیط زیست و چرخه آب در طبیعت است که تهدیدی مخاطره آمیز برای محیط زیست و حیات گونه‌های زیستی محسوب می‌شود. لذا یافتن نمایه‌های اندازه‌گیری خشکسالی برای پیش‌بینی و ارزیابی مکانی و زمانی این پدیده به‌منظور مدیریت بحران آن ضروری و حیاتی به‌نظر می‌رسد. در این مقاله ابتدا به بیان مفهوم خشکسالی و مقایسه نمایه‌های اندازه‌گیری آن پرداخته شد و سپس از مبنای شبکه‌های عصبی-فازی به‌همراه آنالیز خوشه‌بندی برای پیش‌بینی خشکسالی با نمایه بارش استاندارد استفاده شد. نتایجی حاکی از آن است که نمایه SPI قابلیت بیشتری در پیش‌بینی نسبت به نمایه‌هایی چون پالمر، پالفی و دیگر نمایه‌ها دارد و از سویی راهبرد شبکه عصبی-فازی تطبیقی بر مبنای روش خوشه‌بندی C-mean در امر مدل‌سازی برای پیش‌بینی خشکسالی از کارایی بالایی برخوردار است.

واژه‌های کلیدی: خشکسالی، نمایه SPI، شبکه‌های عصبی-فازی تطبیقی، C-mean، ليقوان چای

## Drought Forecasting by SPI Index and ANFIS Model Using Fuzzy C-mean Clustering

Mehdi Komasi<sup>1</sup>

Mohamad Taghi Alami<sup>2</sup>

Vahid Nourani<sup>3</sup>

(Received May 31, 2011 Accepted July 10, 2012)

### Abstract

Drought is the interaction between environment and water cycle in the world and affects natural environment of an area when it persists for a longer period. So, developing a suitable index to forecast the spatial and temporal distribution of drought plays an important role in the planning and management of natural resources and water resource systems. In this article, firstly, the drought concept and drought indexes were introduced and then the fuzzy neural networks and fuzzy C-mean clustering were applied to forecast drought via standardized precipitation index (SPI). The results of this research indicate that the SPI index is more capable than the other indexes such as PDSI (Palmer Drought Severity Index), PAI (Palfai Aridity Index) and etc. in drought forecasting process. Moreover, application of adaptive neuro-fuzzy network accomplished by C-mean clustering has high efficiency in the drought forecasting.

**Keywords:** Drought, SPI, Adaptive Neuro-Fuzzy Inference System, C-mean, Lighvanchai.

1. Ph.D. Student, Dept. of Civil Eng., Tabriz University, Tabriz  
2. Assoc. Prof., Dept. of Civil Eng., Tabriz University, Tabriz  
3. Assoc. Prof., Dept. of Civil Eng., Tabriz University, Tabriz  
(Corresponding Author) (+98 411) 33942409 nourani@tabrizu.ac.ir

۱- دانشجوی دکترا، دانشکده مهندسی عمران، دانشکده تبریز  
۲- دانشیار، دانشکده مهندسی عمران، دانشگاه تبریز  
۳- دانشیار، دانشکده مهندسی عمران، دانشگاه تبریز (نویسنده مسئول) (۳۳۹۴۲۴۰۹) (۰۴۱۱) nourani@tabrizu.ac.ir

۱۹۸۴ نمایه خشکی پالفی<sup>۴</sup> به وسیله پالفی طراحی شد. این نمایه که از چند پارامتر هیدرولوژیکی و هواشناسی تشکیل شده است به منظور مشخص کردن شدت وضعیت خشکی در یک منطقه به وسیله یک عدد یک رقمی طراحی گردیده است [۵]. همچنین از دیگر نمایه‌ها، نمایه خشکسالی RDI<sup>۵</sup> است که توسط دفتر عمران اراضی آمریکا تهیه شده و به عنوان ابزاری برای توصیف شدت، دوام خشکسالی و پیش‌بینی آغاز و پایان آن مورد استفاده قرار می‌گیرد. مزیت نمایه خشکسالی RDI آن است که با دخالت دادن مؤلفه درجه حرارت، تبخیر را نیز لحاظ می‌کند اما از آنجا که این نمایه مختص یک حوضه است، از نظر کاربردی دارای محدودیت است [۶]. همچنین هر بست و همکاران<sup>۶</sup> با استفاده از بسط منحنی باقیمانده‌ها میزان دور شدن متغیر بارش از مقدار میانگین را به عنوان نمایه خشکسالی مطرح کردند [۷]. در یک پژوهش دیگر براون<sup>۷</sup> و گوستارد<sup>۸</sup> با استفاده از نمایه منحنی تداوم جریان، مقدار جریانی را که بیش از ۹۵ درصد از اوقات جریان بیش از آن باشد را به صورت نمایه  $Q_{95\%}$  به عنوان معیاری برای ارزیابی شدت کم آبی ارائه کرده‌اند [۸]. با توجه به ضعف نمایه‌های گفته شده و تأثیرات متفاوت بارش بر روی آبهای زیرزمینی، ذخایر و منابع آب سطحی، رطوبت خاک، پوشش‌های برفی و جریان آبراهه مک کی و همکاران<sup>۹</sup> از محققان دانشگاه کلرادو نمایه جدیدی به نام نمایه بارش استاندارد شده<sup>۱۰</sup> را به منظور پایش وضعیت خشکسالی مطرح ساختند [۹]. اما آنچه که علاوه بر استفاده از نمایه مناسب برای ارزیابی خشکسالی اهمیت دارد پیش‌بینی دقیق آن با استفاده از داده‌های گذشته است. در دهه‌های گذشته از برخی مدل‌های جعبه سیاه برای مدل‌سازی سری زمانی استفاده می‌شد که از این منظر می‌توان به مدل‌هایی همچون مدل سری زمانی ARIMA<sup>۱۱</sup> اشاره نمود که کاربردهای فراوانی در پیش‌بینی فرایندهای هیدرولوژیکی پیدا نموده است [۱۰]. در این نگرش تنوریکی، مدل‌ها بدون توجه به ساختار فیزیکی پدیده، رابطه‌ای را در قالب یک فرمول رگرسیونی میان داده‌های ورودی و خروجی برقرار می‌نمایند. هر چند که این نگرش منجر به ایجاد مدل‌هایی می‌گردد که اساساً دارای ساختار خطی هستند و غالباً برای سری‌های ایستا کاربرد دارند ولی به هر حال توانایی محدودی در

یکی از موانع اصلی برای ارزیابی خشکسالی فقدان یک تعریف دقیق از آن است. آغاز بررسی پدیده خشکسالی را می‌توان در اوایل قرن بیستم جستجو نمود از جمله اولین پژوهش‌ها در این زمینه مطالعات پالمر<sup>۱</sup> در سال ۱۹۶۵ است [۱]. همچنین یکی از جامع‌ترین تعریف‌ها در مورد خشکسالی تعریف پالمر است که خشکسالی را کمبود رطوبت مستمر و غیر طبیعی می‌داند که در این تعریف واژه مستمر به استمرار حالت کمبود و واژه غیر طبیعی به انحراف نمایه مورد نظر از شرایط طبیعی یا میانگین اطلاق می‌شود. امروزه محققان تحقیقات خود را در زمینه خشکسالی در چهار رده هواشناختی، کشاورزی، آب‌شناسی و اقتصادی-اجتماعی دسته‌بندی می‌کنند [۲]. اما آنچه که در این میان بسیار مهم و ضروری به نظر می‌رسد شناخت ایده و راهکاری درست برای پیش‌بینی درست پدیده خشکسالی به منظور به حداقل رساندن اثرات سو آن بر طبیعت و محیط زیست است.

## ۲- ارزیابی نمایه‌های خشکسالی

هدف از تهیه و کاربرد نمایه‌های خشکسالی، ارائه یک ارزیابی ساده و کمی از سه خصوصیت خشکسالی یعنی شدت، تداوم و گستردگی مکانی آن است [۳]. از نخستین نمایه‌ها می‌توان به نمایه شدت خشکسالی پالمر<sup>۲</sup> که در سال ۱۹۶۵ توسط پالمر برای اندازه‌گیری انحراف از شرایط نرمال رطوبتی تعریف شد، اشاره داشت. پالمر نمایه خود را بر اساس معادله بیلان آب پایه گذاری نمود [۱]. البته محدودیتهای قابل توجهی هنگام استفاده از نمایه پالمر وجود دارد از جمله اینکه از این نمایه در مناطقی می‌توان استفاده کرد که از لحاظ توپوگرافی یکنواخت باشند. علاوه بر این نمایه پالمر برای کشاورزی طراحی شده است و تأثیرات هیدرولوژیکی ناشی از خشکسالی‌های بلند مدت را نشان نمی‌دهد [۴]. بنابراین نمایه ذخیره آب سطحی<sup>۳</sup> به منظور تکمیل نمایه پالمر در منطقه کلرودا آمریکا در سال ۱۹۸۲ طراحی شد زیرا نمایه پالمر اساساً یک الگوریتم تنظیم شده برای رطوبت در نواحی متجانس بود که برای سطوحی از یک ناحیه که تنوع توپوگرافی زیادی داشت طراحی نشده بود. همچنین این نمایه، توده‌های برف و رواناب متوالی ناشی از آن را لحاظ نکرده بود اما با توجه به اینکه نمایه SWSI برای یک حوضه است و مقایسه SWSI بین حوضه‌ها و مناطق مشکل است در سال

<sup>4</sup> Palfai Aridity Index (PAI)

<sup>5</sup> Reclamation Drought Index (RDI)

<sup>6</sup> Herbst et al.

<sup>7</sup> Beran

<sup>8</sup> Gustard

<sup>9</sup> Mckee et al.

<sup>10</sup> Standard Precipitation Index (SPI)

<sup>11</sup> Auto- Regressive Integrated Moving Average

<sup>1</sup> Palmer

<sup>2</sup> Palmer Drought Severity Index (PDSI)

<sup>3</sup> Surface Water Storage Index (SWSI)

مدل کردن سری‌های ناپایستا و پدیده‌های که دارای ماهیت غیرخطی هستند، دارند. بنابراین برای حل مشکل یاد شده دسته دیگری از مدل‌های جعبه سیاه بر پایه شبکه‌های عصبی - مصنوعی توسعه و گسترش یافته‌اند [۱۱]. در این راستا یک بررسی و ارزیابی میان شبکه‌های عصبی - مصنوعی و روشهای رگرسیونی خطی برای پیش بینی میزان جریان رودخانه توسط آبراهارت<sup>۱</sup> و سی<sup>۲</sup> در سال ۲۰۰۰ میلادی انجام پذیرفت که نتایج آن حاکی از قابلیت و برتری شبکه‌های عصبی نسبت به روشهای رگرسیونی خطی بوده است [۱۲]. همچنین یک پژوهش مشابه دیگر بین شبکه‌های عصبی - مصنوعی و روش ARIMA توسط هو و همکاران<sup>۳</sup> در سال ۲۰۰۲ انجام شده است که موضوع یاد شده را تأیید می‌نماید [۱۳]. در زمینه پیش‌بینی با سری‌های زمانی باید توجه داشت که روشهایی مانند ARIMA توانایی کاربرد برای سری‌هایی که خطی هستند و یا دارای الگوی فصلی می‌باشند مناسب تشخیص داده شده‌اند در حالیکه شبکه‌های عصبی علاوه بر موارد یاد شده توانایی مانیتور کردن سری‌های غیرخطی و نویزدار با الگوهای مختلف و گوناگون را نیز دارا هستند. گذشته از آن مدل ARIMA نیازمند داده‌های پیوسته گذشته است در حالیکه در شبکه‌های عصبی نیاز اساسی به داده‌های پیوسته نیست [۱۴]. تفاوت‌های دیگر مدل‌های شبکه‌های عصبی با مدل‌های رایج دیگر توسط پژوهشگران مختلف برای کاربردهای مختلف هیدرولوژیکی گزارش شده است [۱۵ و ۱۶]. در زمینه خشکسالی نیز پژوهش‌هایی با استفاده از شبکه عصبی برای پیش‌بینی این فرایندها انجام شده است به‌عنوان نمونه کیم<sup>۴</sup> و والدز<sup>۵</sup> از شبکه عصبی برای آنالیز دوران خشکسالی با نمایه PDSI<sup>۶</sup> با استفاده از داده‌های ۳۵ سال بر روی حوضه کونچوس واقع در مکزیک استفاده نموده‌اند [۱۷]. همچنین در سال ۲۰۰۶ میشرا<sup>۷</sup> و دسای<sup>۷</sup> پژوهش مشابهی با استفاده از نمایه SPI و شبکه عصبی انجام داده‌اند که بیانگر توانایی این روش است [۱۸].

نکته مهم در امر مدل‌سازی پدیده‌های هیدرولوژیکی از جمله خشکسالی، وجود عدم قطعیت در این پدیده‌ها است به این معنی که اعداد و ارقام در این علم نمایانگر واقعیت دقیق پدیده نیست و نسبی بودن اعداد همیشه در این پدیده‌ها مطرح است. گذشته از آن مقادیری که گزارش می‌شوند نماینده کل حوضه و

خصوصیات واقعی آن نیستند بلکه یک تقریب و متوسط کلی از کل حوضه را بیان می‌کنند. اینکه فرض شود یک مدل دقیقاً بیانگر ماهیت واقعی پدیده است یک تصور غیر واقعی است. بنابراین هر مدل با هر دقت و ساختاری دارای احتمال خطا است. خطای مدل‌های پیش‌بینی کننده به دلیل ساده سازی‌های مدل (همانند تعریف و شبیه سازی سیستم، انتخاب روش ریاضیات مسئله، روش حل عددی و تعیین برخی پارامترها توسط کالیبره کردن) جزء جدایی ناپذیر آنهاست. بنابراین خطا در مدل‌سازی خشکسالی در مراحل مختلف اجتناب ناپذیر است. امروزه از دیدگاه عدم قطعیت، فازی‌سازی پدیده‌ها به‌ویژه در فرایندهایی که با سری زمانی سروکار دارند به دلیل عدم پایداری ناشی از ناپایستا بودن سری زمانی گسترش چشمگیری داشته است. از این رهگذر ایده ترکیبی بر مبنای شبکه‌های عصبی و سیستم‌های فازی (عصبی - فازی) برای خشکسالی مطرح گردید. در قیاس با حجم انبوه پژوهش‌ها در زمینه مدل‌سازی خشکسالی با شبکه عصبی، تعداد اندکی مدل‌سازی با استفاده از مبانی فازی گزارش گردیده است [۱۹، ۲۰ و ۲۱]. با توجه به نکات گفته شده در پیشینه پژوهش و نیز نسبی بودن دامنه و مرز پدیده خشکسالی در این پژوهش تلاش شد که با بهره گیری شبکه‌های عصبی - فازی تطبیقی به پیش‌بینی سری زمانی خشکسالی با نمایه SPI پرداخته شود تا این مهم به گونه مناسبی مورد توجه قرار گیرد. همچنین از سوئی، نوآوری و نکته مهم دیگری که در این پژوهش مورد توجه قرار گرفت پیش پردازش داده‌ها به وسیله آنالیز خوشه بندی C-mean قبل از ورود به شبکه عصبی - فازی تطبیقی بود که می‌تواند بازدهی مدل را تا حد مناسبی افزایش دهد.

این مقاله ابتدا به معرفی نمایه SPI و مبانی مدل‌سازی هوش مصنوعی با محوریت دو روش شبکه عصبی - مصنوعی و شبکه عصبی - فازی تطبیقی با تأکید بر آنالیز خوشه بندی C-mean پرداخت و سپس نتایج به دست آمده با این دو روش مورد بحث قرار گرفت.

### ۳- مواد و روشها

#### ۳-۱- نمایه بارش استاندارد شده

نمایه SPI یک ابزار قوی در پردازش داده‌های بارندگی است و هدف آن اختصاص ارزش عددی به بارندگی است که از این طریق بتوان نواحی با آب و هوای متفاوت را با هم مقایسه کرد. از مزیت‌های SPI این است که محاسبه SPI بر پایه داده‌های بارندگی استوار بوده و به شرایط رطوبت خاک بستگی ندارد و

1 Abrahart

2 See

3 Ho et al.

4 Kim

5 Valdes

6 Mishra

7 Desai

جدول ۱- طبقه‌بندی خشکسالی بر اساس نمایه SPI

ردیف	شدت خشکسالی	دامنه SPI	احتمال وقوع
۱	شدیداً مرطوب (مرطوب حدی)	بزرگتر از ۲	۰/۰۲۲۸
۲	خیلی مرطوب	۱/۵ ~ ۱/۹۹	۰/۰۴
۳	مرطوب متوسط	۱ ~ ۱/۴۹	۰/۰۹۱۹
۴	مرطوب خفیف (تقریباً نرمال)	۰ ~ ۰/۹۹	۰/۳۴۱۳
۵	خشک خفیف (تقریباً نرمال)	-۰/۹۹ ~ ۰	۰/۳۴۱۳
۶	خشک متوسط	۱- ~ ۱/۴۹	۰/۰۹۱۹
۷	خیلی خشک	-۱/۵ ~ -۱/۹۹	۰/۰۴
۸	شدیداً خشک (خشک حدی)	کوچک‌تر از -۲	۰/۰۲۲۸

که در این رابطه  $\alpha$  و  $\beta$  به ترتیب پارامتر شکل و پارامتر مقیاس و  $\Gamma(\alpha)$  تابع گاما است که به صورت زیر تعریف می‌شود

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

که در این رابطه پارامترهای  $\alpha$  و  $\beta$  مربوط به تابع چگالی گاما برای هر ایستگاه و برای هر مقیاس زمانی و هر ماه از سال برآورد می‌شود. مک کی و همکاران با استفاده از روش حداکثر درست‌نمایی بهینه، ضرایب  $\alpha$  و  $\beta$  را بر اساس رابطه زیر برآورد نمودند [۹]

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

که در این رابطه  $n$  تعداد مشاهدات بارندگی و  $\bar{X}$  میانگین بارندگی برای یک دوره چند ماهه مشخص است. سپس پارامترهای محاسبه شده برای پیدا کردن احتمال تجمعی بارندگی برای مقیاس زمانی مشخص برای هر یک از ایستگاهها به کار گرفته می‌شود که این احتمال را با فرض  $t = \frac{X}{\beta}$  می‌توان بر طبق رابطه ۴ تبدیل به تابع گامای ناقص نمود

$$G(X) = \int_0^X g(x) dx = \frac{1}{\Gamma(\alpha)} \int_0^X t^{(\alpha-1)} e^{-t} dt \quad (4)$$

از آنجایی که تابع گاما برای  $X=0$  تعریف نشده است هرگاه توزیع بارندگی دارای مقدار صفر باشد، احتمال تجمعی به صورت زیر محاسبه می‌شود

$$H(X) = q + (1-q)G(X) \quad (5)$$

$q$  احتمال بارندگی صفر و  $m$  تعداد صفرها در سری‌های زمانی بارندگی است که  $q$  را به صورت حاصل تقسیم  $m$  بر تعداد کل داده‌ها ( $n$ ) تخمین می‌زند سپس با داشتن  $H(x)$  و روابط ۸ تا ۱۱ SPI به دست می‌آید

مضافاً اینکه این نمایه از توپوگرافی تاثیر نمی‌پذیرد. مشخصه اصلی SPI انعطاف پذیری آن در اندازه‌گیری خشکسالی در مقیاسهای زمانی متفاوت است زیرا خشکسالی از لحاظ دوره دارای دامنه بسیار گسترده‌ای است. بنابراین تشخیص و پایش آن با انواع مقیاسهای زمانی مهم است. محاسبه SPI برای هر منطقه بر پایه آمار بلند مدت بارندگی (حداقل ۳۰ ساله) برای یک دوره سه ماهه، شش ماهه و غیره استوار است که این آمار دراز مدت به یک تابع توزیع احتمال (به توصیه مک کی و همکاران تابع توزیع احتمال گاما) برازش یافته و تابع حاصل برای پیدا کردن احتمال تجمعی بارندگی برای یک ایستگاه و یک مقیاس زمانی مشخص می‌تواند استفاده شود که این احتمال سپس به متغیر تصادفی نرمال تبدیل می‌شود و بیانگر نمایه SPI است که دامنه تغییرات و طبقه بندی آن برای بیان شدت خشکسالی در جدول ۱ آورده شده است [۹].

بنابراین مقدار SPI انحراف استاندارد است که یک رویداد مشخص از شرایط نرمال نشان می‌دهد و به طور کلی این نمایه بر اساس توضیحات گفته شده برای بیان خشکسالی چنین تعریف می‌شود: دوره ای که SPI دائماً منفی است و به مقدار (-۱) و کمتر از آن می‌رسد و زمانی پایان می‌پذیرد که مقدار آن مثبت شود بنابراین مقادیر مثبت نمایانگر بارشی بیش از مقدار متوسط و مقادیر منفی بیانگر بارشی کمتر از بارش متوسط هستند [۹].

### ۳-۲- روش محاسبه نمایه SPI

داده‌های اصلی نمایه SPI را داده‌های بارندگی ماهانه ایستگاههای باران‌سنجی تشکیل می‌دهند. پس از اطمینان از همگن و تصادفی بودن داده‌های ماهانه، سری زمانی در بازه‌های ۳، ۶، ۱۲ و ۲۴ ماهه تشکیل می‌شود و سری زمانی آن با توزیع گاما برازش داده می‌شود که تابع دانسیته احتمال یا فراوانی آن به صورت زیر تعیین می‌شود [۹]:

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} X^{(\alpha-1)} e^{-x/\beta} X \quad (1)$$

### ۳-۴- معماری شبکه‌های عصبی- مصنوعی<sup>۳</sup>

یکی از انواع مهم شبکه‌های عصبی- مصنوعی، شبکه پرسپترون چند لایه<sup>۴</sup> است که شامل یک لایه ورودی، یک یا چند لایه مخفی و یک لایه خروجی است [۱۲]. در این مقاله از یک شبکه سه لایه مطابق شکل ۱ با تابع محرک سیگموئید استفاده شد که تعداد نرون‌های لایه اول در شبکه با توجه به این نکته که SPI در زمان  $t+1$  به SPI در زمان‌های  $t$ ،  $t-1$ ،  $t-2$ ،  $t-3$ ، ... می‌تواند وابسته شود، ۲، ۴، ۶ و ... نرون در نظر گرفته شد. همچنین تعداد نرون‌های لایه میانی متغیر گرفته شده و برای حالت‌های مختلف بین ۳ تا ۳۰ نرون بررسی صورت گرفت. لایه خروجی نیز شامل یک نرون و مقدار SPI در زمان  $t+1$  است.

در شکل ۱، آرایش معماری شبکه عصبی  $X_i$  متغیر ورودی (نمایه SPI)،  $y$  متغییر خروجی،  $w$  ضرایب وزن در شبکه،  $n$ ،  $m$  و  $k$  به ترتیب تعداد نرون در لایه ورودی، لایه میانی و لایه خروجی است که این آرایش را می‌توان به صورت رابطه زیر بیان داشت

$$\hat{y}_k = f_0 \left[ \sum_{j=1}^M W_{kj} f_h \left( \sum_{i=1}^N W_{ji} x_i + W_{j0} \right) + W_{k0} \right] \quad (10)$$

در این تحقیق از الگوریتم LM<sup>۵</sup> استفاده گردید. از این الگوریتم

$$SPI = - \left[ t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] 0 < H(X) \leq 0.5 \quad (6)$$

$$SPI = + \left[ t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] 0.5 < H(X) < 1 \quad (7)$$

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

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

که در این روابط ضرایب ثابت  $d_3, d_2, d_1, c_2, c_1, c_0$  باید از جدول ۲ در روابط ۶ تا ۹ جایگذاری گردد [۹].

### ۳-۳- مبانی مدل‌سازی هوش مصنوعی

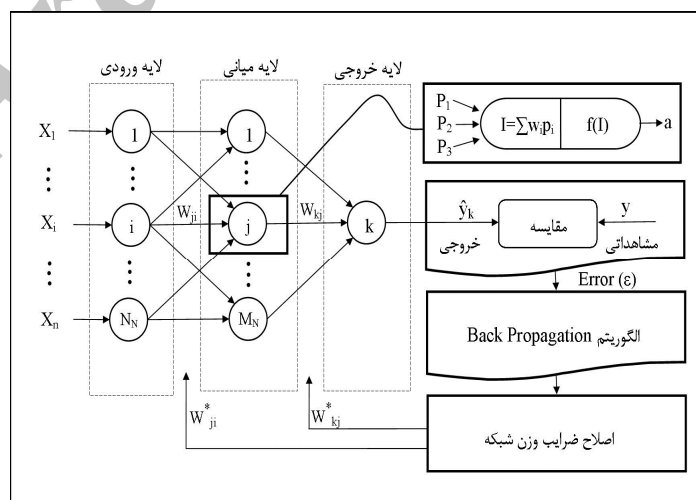
به طور کلی برای پیش‌بینی رفتار پدیده‌های هیدرولوژیکی که بیشتر قوانین احتمالات بر آنها حاکم است در اکثر موارد متغیرها به صورت سری زمانی در نظر گرفته شده و روند تجزیه و تحلیل به‌گونه‌ای است که از اطلاعات گذشته سری در جهت ایجاد الگو یا مدل پیش‌بینی‌کننده سری زمانی برای آینده بهره‌گیری می‌شود. در بین مدل‌های موجود در سری زمانی، مدل خودهمبسته با میانگین متحرک و مدل خود همبسته تجمعی با میانگین متحرک<sup>۱</sup> و یا مدل‌های جعبه سیاه، هر دو از این ساختار پیروی می‌کنند. در این مقاله نیز از دو ساختار شبکه عصبی- مصنوعی و شبکه عصبی- فازی تطبیقی<sup>۲</sup> به منظور مدل‌سازی خشکسالی به‌وسیله نمایه SPI استفاده شد.

<sup>1</sup> Auto Regressive Integrated Moving Average (ARIMA)

<sup>2</sup> Adaptive Neuro-Fuzzy Inference System (ANFIS)

جدول ۲- مقادیر ضرایب ثابت فرمول‌های محاسبه SPI

ضرایب	$d_1$	$d_2$	$d_3$	$c_0$	$c_1$	$c_2$
مقدار	۱/۴۳۲۷۸۸	۰/۱۸۹۲۶۹	۰/۰۰۱۳۰۸	۲/۵۱۵۵۱۷	۰/۸۰۲۸۵۳	۰/۰۱۰۳۲۸

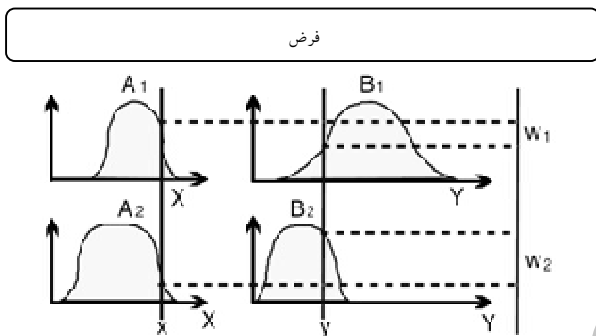


شکل ۱- طرح و آرایش شبکه عصبی- مصنوعی

صورت ساختار شبکه‌ای پیش‌رونده و دارای پنج لایه است. به‌عنوان نمونه یک مدل ANFIS مرتبه اول تاکاجی - سوگنو با دو ورودی، یک خروجی و دو تابع عضویت برای هر یک از ورودی‌ها در شکل ۲ نشان داده شده است [۲۲]. مطابق با شکل ۲ فرض گردیده که سیستم فازی دارای ورودی  $x$  و  $y$  و یک خروجی  $f$  است. برای چنین مدلی می‌توان قوانین معمولی را با در نظر گرفتن دو قانون فازی اگر - آنگاه به‌صورت زیر تعریف می‌گردد

Rule 1: If  $\mu(x)$  is  $A_1$  and  $\mu(y)$  is  $B_1$ ; then  $f_1 = p_1x + q_1y + r_1$   
 Rule 2: If  $\mu(x)$  is  $A_2$  and  $\mu(y)$  is  $B_2$ ; then  $f_2 = p_2x + q_2y + r_2$

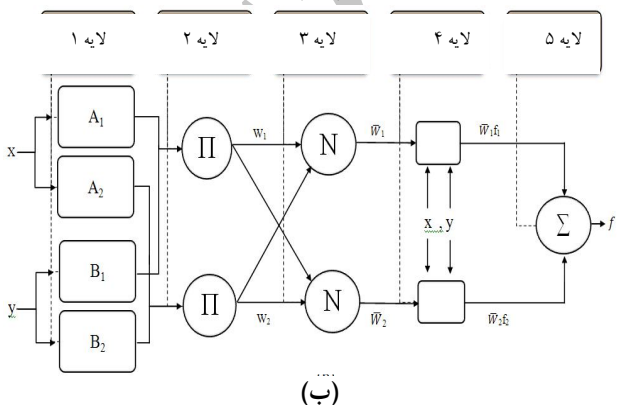
که متغیرهای  $A_1, B_1, A_2, B_2$  به ترتیب توابع عضویت برای ورودی‌های  $x$  و  $y$  هستند و  $p_1, q_1, r_1$  و  $p_2, q_2, r_2$  پارامترهای تابع خروجی هستند. بنابراین در این حالت فرمول بندی ANFIS از یک آرایش شبکه عصبی پنج لایه پیشرو پیروی می‌کند.



نتیجه

$$\left. \begin{aligned} f_1 &= p_1x + q_1y + r_1 \\ f_2 &= p_2x + q_2y + r_2 \end{aligned} \right\} f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2}$$

(الف)



شکل ۲- الف - مکانیسم قوانین سیستم فازی تاکاجی - سوگنو ب - آرایش معادل ANFIS

به‌منظور شناسایی بهترین روش با بالاترین بازده برای آموزش شبکه استفاده می‌شود. در واقع این الگوریتم یک روش استاندارد برای مسائل حداقل مربعات غیر خطی بوده و به‌عنوان ترکیبی از روش نیوتن گوس و بیشترین شیب نزول بیان می‌شود که برای پیدا کردن راه حلی مناسب برای مسائلی که نیاز به کمینه‌سازی دارند با فرمول بندی زیر به‌کار می‌رود

$$X_{k+1} = X_k - (J^T J + \mu I)^{-1} J^T + e \quad (۱۱)$$

که در این رابطه

$X$  وزن‌های شبکه عصبی،  $J$  ژاکوبین ماتریس معیار اجرای شبکه که باید حداقل شود،  $\mu$  عددی است که فرایند آموزش را کنترل می‌کند و  $e$  بردار خطای باقیمانده است [۱۷].

### ۳-۵- مدل شبکه عصبی فازی تطبیقی

یک سیستم فازی، سیستمی منطبق بر قواعد منطقی اگر - آنگاه<sup>۱</sup> است که با تئوری‌های احتمال کلاسیک قابل تحلیل نیست. نقطه شروع ساخت یک سیستم فازی، به‌دست آوردن مجموعه‌ای از قواعد اگر - آنگاه فازی است. بنابراین داشتن روشی که با استفاده از آن بتوان اطلاعات موجود برای ساخت این قواعد را تعیین کرد به‌عنوان ابزاری کارآمد به‌شمار می‌رود. در این میان شبکه‌های عصبی - مصنوعی به‌دلیل قابلیت‌های آموزش‌پذیری و با استفاده از الگوهای مختلف آموزشی می‌تواند ارتباط مناسبی بین متغیرهای ورودی و خروجی ایجاد نماید. لذا استفاده ترکیبی از سیستم استنتاج فازی و شبکه‌های عصبی - مصنوعی می‌تواند ابزار قدرتمندی را تحت عنوان سیستم استنتاج فازی - عصبی تطبیقی به‌وجود آورد. در این روش ترکیبی، بخش فازی، رابطه بین متغیرهای ورودی و خروجی را ایجاد کرده و پارامترهای مربوط به توابع عضویت بخش فازی به وسیله شبکه عصبی بهینه می‌شود.

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 (بیشینه 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 بررسی صحت سنجی مدل است. از این رو بخشی از داده‌ها که در مرحله آموزش به‌کار نرفته است، به‌عنوان ورودی در مرحله صحت سنجی مورد استفاده قرار می‌گیرد تا از دقت و اعتبار مدل اطمینان حاصل شود. مدل ANFIS غالباً با استفاده از یک سیستم فازی تاکاجی - سوگنو به

<sup>1</sup> If-then rules

در لایه نخست هر نرون درجه عضویت متغیر را تعیین می‌نماید. اگر خروجی نرون  $i$ -ام در لایه  $k$ -ام به صورت  $Q_i^k$  نشان داده شود بنابراین با رویداشت به تابع زنگوله‌ای به عنوان تابع عضویت خروجی  $Q_i^1$  به صورت زیر محاسبه می‌گردد

$$Q_i^1 = \mu_{A_i}(x) = \frac{1}{1 + ((x - c_i)/a_i)^{2b_i}} \quad (12)$$

که در این رابطه

$x$  (یا  $y$ ) ورودی نرون و  $A_i$  (یا  $B_i$ ) سیستم فازی مربوطه و همچنین  $\{a_i, b_i, c_i\}$  متغیرهای تطبیقی هستند که به عنوان پارامترهای مقدم (فرض) شناخته می‌شوند.

در لایه دوم تمامی قوانین موجود میان ورودی با به‌کارگیری قاعده تقاطع یا همان اشتراک فازی (AND) فرمول‌بندی می‌گردند. برای هر قانون عملیات ضرب برای برآورد ضریب مورد استفاده قرار می‌گیرد.

$$Q_i^2 = w_i = u_{A_i}(x), \mu_{B_i}(y) \quad i=1,2 \quad (13)$$

در لایه سوم نرون  $i$ -ام ضریب نرمال شده را به صورت زیر محاسبه می‌کند

$$Q_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2 \quad (14)$$

در لایه چهارم نرون  $i$ -ام چگونگی مشارکت و یا به عبارتی تاثیر قانون  $i$ -ام را در خروجی مدل محاسبه می‌نماید

$$Q_i^4 = \bar{w}_i(p_i x + q_i y + r_i) = \bar{w}_i f_i \quad (15)$$

که در این رابطه

$\bar{w}_i$  خروجی لایه سوم و  $\{p_i, q_i, r_i\}$  پارامترهای تنظیمی هستند که در حقیقت به عنوان پارامترهای تالی (نتیجه) مطرح هستند.

در لایه آخر نیز خروجی نهایی و کلی ANFIS به صورت زیر محاسبه می‌گردد [22].

$$\text{Overall output} = Q_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_u w_i} \quad (16)$$

پارامترهایی که باید در روند مدل ANFIS بهینه‌سازی گردند عبارت‌اند از پارامترهای مقدم  $\{a_i, b_i, c_i\}$  و پارامترهای تالی  $\{p_i, q_i, r_i\}$ . جانگ و همکاران<sup>1</sup> یک الگوریتم حل ترکیبی برای یافتن یافتن مقادیر دقیق پارامترهای مدل ANFIS ارائه نموده‌اند که دارای قابلیت بیشتری نسبت به روش کلاسیک بازگشتی است

<sup>1</sup> Jang et al.

[23]. شیوه آموزش در این سیستم ترکیبی از الگوریتم پس انتشار خطا و الگوریتم حداقل مربعات خطا است. در این سیستم با استفاده از الگوریتم حداقل مربعات خطا، میزان خطا به سمت ورودی‌ها پخش شده و پارامترها تصحیح می‌شوند. همچنین در این مقاله به منظور استخراج قواعد در مدل فازی تاکاجی- سوگنو از روش خوشه‌بندی فازی C-mean استفاده شد. خوشه‌بندی اولین بار توسط بزدرک در سال ۱۹۸۱ ارائه گردید. در این روش، داده‌ها به  $c$  خوشه و با درجه عضویت مشخص به هر خوشه تقسیم بندی می‌شوند. حداکثر تعداد خوشه‌های مورد استفاده این روش در بازه  $\sqrt{n} < C \max < 2$  قرار دارد که در این بازه  $n$  تعداد مشاهدات آماری است. میزان درجه عضویت هر داده به هر خوشه، در ماتریس عضویت  $U = [u_{ij}]_{c \times n}$  مشخص می‌شود. در این روش دو محدودیت اصلی وضع شده است اول اینکه، هیچ خوشه‌ای نباید تهی باشد که این محدودیت را می‌توان به صورت رابطه زیر بیان نمود [10]

$$0 < \sum_{j=1}^n u_{i,j} < n \quad \forall i \in \{1,2,3,\dots,c\} \quad (17)$$

محدودیت دوم محدودیت نرمالسازی است. به بیان دیگر مجموع درجات عضویت هر داده به همه خوشه‌ها باید برابر یک باشد.

$$\sum_{i=1}^c u_{i,j} = 1 \quad \forall j \in \{1,2,3,\dots,n\} \quad (18)$$

روش خوشه‌بندی فازی C-mean سعی دارد تا برای یک مجموعه نقاط، داده‌های بیاباد تا تابع هدف زیر را کمینه کند

$$J_m(\tilde{U}, V) = \sum_{i=1}^c \sum_{j=1}^n (u_{ij})^m (d_{ij})^2 \quad (19)$$

به طوری که  $d_{ij}$  فاصله اقلیدسی بین مرکز خوشه  $i$ -ام و داده  $j$ -ام است

$$d_{ij} = \left[ \sum_{k=1}^m (x_{kj} - v_{ki})^2 \right]^{\frac{1}{2}} \quad (20)$$


که در این روابط

$m$  تعداد متغیرها و  $v_{ki}$  مرکز خوشه  $i$ -ام از داده  $k$ -ام و  $m' \in [1, \infty]$  است و میزان فازی بودن را مشخص می‌کند و معمولاً عددی بین عدد ۲ تا ۲/۵ را به خود می‌گیرد [24].


#### ۴- حوضه ليقوان چای

حوضه ليقوان چای واقع در استان آذربایجان شرقی در دامنه شمالی سهند با مساحتی حدود ۷۵ کیلومتر مربع است که در شکل ۳ موقعیت جغرافیایی و نقشه DEM (مدل رقومی





شکل ۳- موقعیت جغرافیایی و نقشه (Digital Elevation Model) حوزه ليقوان چای



شکل ۴- داده‌های بارندگی و رواناب حوزه آبریز ليقوان چای

جدول ۳- مشخصات آماری داده‌های روزانه بارش حوزه ليقوان چای (بر حسب میلی‌متر)

بازه زمانی	داده‌های واسنجی				داده‌های صحت سنجی			
	انحراف معیار	میانگین	کمینه	بیشینه	انحراف معیار	میانگین	کمینه	بیشینه
ماهانه	۲۳/۷۵	۱۸/۲۲	۰	۱۵۱	۱۹/۲۰	۲۲/۹۲	۰	۸۹
روزانه	۵/۲۰	۰/۷۷	۰	۲۲	۴/۲۱	۰/۷۶	۰	۱۹

تبدیل شد و سپس از این داده‌ها به‌عنوان متغیر ورودی در روشهای شبکه عصبی و شبکه عصبی- فازی تطبیقی استفاده گردید. در این پژوهش از دوره ماهانه برای مدلسازی خشکسالی استفاده گردید. برای دستیابی به نتایج حاصله از روش شبکه عصبی و شبکه عصبی- فازی تطبیقی برای مدلسازی خشکسالی با دوره ماهانه، دو برنامه به زبان Matlab نوشته شد که این برنامه برای حالت‌های مختلف آرایش شبکه می‌تواند اجرا گردد. همچنین در این برنامه‌ها برای ارزیابی و مقایسه عملکرد مدل‌ها در پیش‌بینی نتایج از آماره‌های ضریب تبیین<sup>۱</sup> ( $R^2$ ) و جذر میانگین مربع خطاها<sup>۲</sup> (RMSE) به شرح روابط استفاده شد [۲۵]

ارتفاعی) حوزه نشان داده شده است. بلندترین نقطه حوزه با ارتفاع ۳۶۲۰ متر از سطح دریای آزاد و پایین‌ترین نقطه حوزه با ارتفاع ۲۱۴۰ متر در محل ایستگاه ليقوان است. در این پژوهش از آمار بارندگی حوزه ليقوان چای بین سالهای ۱۳۵۳ تا ۱۳۸۶ در مدلسازی خشکسالی استفاده گردید. در شکل ۴ به‌عنوان نمونه دوازده سال از داده‌های بارندگی و رواناب حوزه نشان داده شده است. در جدول ۳ اطلاعات بارندگی به‌همراه تحلیل آماری داده‌های بارش حوزه آورده شده است.

##### ۵- نتایج و بحث

در مدلسازی سری زمانی SPI نخست با الگوریتم گام به گام یاد شده در بخش روش محاسبه نمایه SPI، داده‌های بارندگی به

<sup>1</sup> Determination Coefficient  
<sup>2</sup> Root Mean Square Error



شبکه‌های عصبی-مصنوعی می باشد. همین امر در فرایند آموزش یک شبکه می تواند وجود داشته باشد به این صورت که در صورتی که یک شبکه بیش از اندازه آموزش داده شود این شبکه دچار بیش برآزش<sup>۱</sup> در مرحله صحت سنجی می‌گردد و در نتیجه از دقت نتایج در مرحله واسنجی می‌کاهد. این پدیده در شکل ۵ به خوبی داده شده است. بنابراین از این دیدگاه بهینه‌ترین ساختار برای شبکه عصبی را می‌توان ساختار سوم دانست که دارای چهار متغیر ورودی است.

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

- Comb (1):  $SPI_t, SPI_{t-1}$   
 Comb (2):  $SPI_t, SPI_{t-1}, SPI_{t-2}$   
 Comb (3):  $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$   
 Comb (4):  $SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, SPI_{t-4}$

برای ارزیابی تاثیر تعداد و شکل تابع عضویت هر یک از سناریوها به‌همراه سه نوع تابع عضویت یاد شده با دو و سه تابع عضویت مورد آزمایش قرار گرفتند که نتایج آن برای هر یک از حالتها به‌صورت ضریب تبیین مرحله صحت‌سنجی و واسنجی در شکل ۶ آورده شده است.

<sup>1</sup> Overfitting

$$R^2 = 1 - \frac{\sum_{i=1}^n (SPI_i - \widehat{SPI}_i)^2}{\sum_{i=1}^n (\widehat{SPI}_i - \overline{SPI}_i)^2} \quad (21)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SPI_i - \widehat{SPI}_i)^2}{n}} \quad (22)$$

که در این رابطه

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


در گام نخست به‌منظور بررسی کارایی روش شبکه عصبی در مدل‌سازی داده‌های سری زمانی خشکسالی، آرایش‌های مختلفی از این شبکه که دارای ورودی‌های متفاوتی است به‌صورت کلی  $(P, n, 1)$  مورد آزمایش قرار گرفت که در این ساختار P تعداد ورودی‌های شبکه (نرون‌های ورودی) و n تعداد نرون‌های لایه میانی است که به‌صورت متغیر می‌تواند انتخاب گردد. به این منظور چهار ساختار برای حالت‌هایی که به تعداد ۲، ۳، ۴ و ۵ وابستگی در شبکه وجود دارد با تعداد ۱ تا ۳۰ نرون برای لایه میانی مورد آموزش قرار گرفت که نتایج این ساختارها در جدول ۴ آورده شده است.

همانگونه که از جدول ۴ پیداست علت اینکه تعداد وابستگی‌ها بیشتر گرفته نشده این است که در صورت افزایش وابستگی، دقت بیشتر در مرحله آموزش (صحت سنجی) افزایش یافته و برای مرحله شبیه‌سازی (واسنجی) تاثیر چندانی نمی‌گذارد و حتی باعث کاهش دقت نیز می‌گردد زیرا الگوی شبکه بیشتر به داده‌های آموزش منطبق می‌شود و به‌جای یافتن روند کلی سری زمانی در دام تغییرات موضعی می‌افتد که این تغییرات موضعی به‌طور مشابه ممکن است در آینده وجود نداشته باشد لذا در حالت کلی روند دراز مدت سری از درجه اول اهمیت برخوردار است بنابراین داشتن دید دو سویه به نتایج صحت سنجی و واسنجی یک اصل مهم در مبانی مدل‌سازی


جدول ۴- نتایج و آماره‌های مدلسازی نمایه SPI با روش شبکه عصبی- مصنوعی

ساختار شبکه عصبی	متغیرهای ورودی به شبکه*	ساختار بهینه شبکه	ضریب تبیین ( $R^2$ )	
			صحت سنجی	واسنجی
$(2, n, 1)$	$SPI_t, SPI_{t-1}$	$(2, 6, 1)$	۰/۸۰	۰/۶۵
$(3, n, 1)$	$SPI_t, SPI_{t-1}, SPI_{t-2}$	$(3, 8, 1)$	۰/۸۵	۰/۷۱
$(4, n, 1)$	$SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}$	$(4, 11, 1)$	۰/۸۷	۰/۷۶
$(5, n, 1)$	$SPI_t, SPI_{t-1}, SPI_{t-2}, SPI_{t-3}, SPI_{t-4}$	$(5, 8, 1)$	۰/۸۹	۰/۷۴

\* $SPI_{t+1}$ : متغیر خروجی شبکه و n: تعداد نرون لایه میانی



شکل ۵- چگونگی یافتن حالت بهینه آموزش شبکه برای جلوگیری از بیش برآزش در شبکه عصبی



شکل ۶- بررسی تأثیر ورودی‌ها و شکل تابع عضویت در مدل‌سازی به روش ANFIS

کارایی و دقت کمتری نسبت به سناریوی ۲ است را می‌توان در تعداد کم متغیرهای ورودی در امر مدل‌سازی دانست و دلیل افت دقت سناریوی ۴ در قیاس با سناریوی ۲ را می‌توان در تعداد زیاد پارامترها و قوانین حاکم بر آنها دانست زیرا با فرض یک خطای کوچک برای هر یک از این پارامترها در کل خطای مجموع عدد بزرگی را نتیجه می‌دهد. نتیجه به دست آمده با نتایج

همانگونه که در شکل ۶ نشان داده شده است سناریوی ۲ به همراه تابع زنگوله‌ای نسبت به سایر سناریوها دارای ضریب تبیین بیشتری است (مرحله صحت سنجی ۰/۹۳/مرحله واسنجی ۰/۸۹). بنابراین می‌توان چنین نتیجه گرفت که این سناریو به عنوان مناسب‌ترین آرایش شبکه در روش مدل‌سازی با ANFIS می‌تواند مطرح باشد. دلیل اینکه سناریوی ۱ دارای

مطالعه دستورانی و همکاران در سال ۱۳۹۰ در کاملاً سازگار است [۲۶]. با توجه به اینکه داده‌های SPI مورد استفاده در شبکه از تنوع زیادی برخوردارند بنابراین شایسته است که بر روی داده‌ها قبل از ورود به شبکه، پیش‌پردازش صورت پذیرد. از این منظر، امروزه دسته دیگری از مدل‌ها بر پایه ایده ترکیبی توسط پژوهشگران بنیان نهاده شده است که هدف آن یافتن ساختار مناسب و افزایش دقت مدل‌ها است [۲۷].

همچنین معمولاً دقت روش‌های مبتنی بر نگرش هوش مصنوعی در نقاط اوج کمتر از بقیه نقاط است زیرا اساساً این مدل‌ها یک رگرسیون خود همبسته<sup>۱</sup> هستند که مطابق با قاعده زنجیره‌ای مارکوف به همدیگر ارتباط می‌یابند بنابراین توانایی مانیتور کردن نقاطی که دارای تغییرات ناگهانی در سری زمانی هستند را به خوبی نقاط دیگر دارا نیستند. در این راستا پژوهشگران برای رفع مشکل یاد شده از روش‌های پیش‌پردازش داده‌ها استفاده می‌نمایند [۲۸ و ۲۹]. از نوآوری‌های این مقاله نیز استفاده از پیش‌پردازش اولیه داده‌ها در قالب تبدیل سری بارش به یک سری شاخص است که در قیاس با سری بارش دارای تغییرات محدود تری است و نیز خوشه‌بندی این داده‌ها برای کاهش مجدد تغییرات و در نتیجه افزایش دقت در نقاط پیک. در این تحقیق برای دسته‌بندی داده‌ها از آنالیز خوشه بندی C-mean استفاده گردید. به بیان دیگر ایده ترکیب مدل ترکیبی شبکه عصبی-فازی به همراه آنالیز خوشه‌بندی در گام سوم مورد استفاده قرار می‌گیرد. با توجه به تعریفی که از نمایه SPI در جدول ۱ ارائه گردید برای بیان میزان خشکسالی از یک سری دامنه توصیفی اعداد استفاده شد. بنابراین می‌توان از این دسته‌بندی داده‌ها به‌عنوان یک رهیافت مناسب در جهت آنالیز خوشه‌بندی بهره‌گرفت. نکته مهم در آنالیز خوشه‌بندی، انتخاب تعداد دسته‌های خوشه‌بندی است با توجه به اینکه داده‌های SPI در دو طیف مثبت (ترسالی) و منفی (خشکسالی) و هر طیف نیز دارای چهار زیر دسته است بنابراین در حالت کلی هشت دسته جزئی طبقه بندی را می‌توان برای خوشه‌بندی داده‌های SPI در نظر گرفت. به این منظور

<sup>1</sup> Auto-regression

مدل ANFIS با مشخصات ساختاری سناریوی ۲ را برای سه حالت خوشه‌بندی که در آن تعداد خوشه‌ها دو، چهار و هشت خوشه است می‌توان مورد استفاده قرار داد که نتایج این ارزیابی در جدول ۵ آورده شده است.

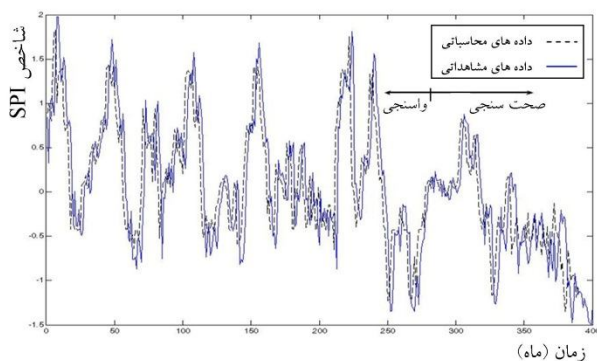
با توجه به اعداد جدول ۵ می‌توان دریافت که افزایش دقت نتایج برای حالتی که از دو خوشه استفاده گردیده است چندان تاثیر گذار نبوده اما با افزایش تعداد خوشه‌ها به ۴ و ۸ خوشه، مدل کارایی بهتری را نشان داده و توانسته است نتایج بهتری نسبت به حالتی که هیچ خوشه‌بندی بر روی داده‌ها صورت نپذیرفته را نشان دهد. ارزیابی کمی داده‌های SPI مشاهداتی و محاسباتی برای مرحله واسنجی و صحت‌سنجی مدل (با ۸ خوشه) در شکل ۷ نشان داده شده است و در شکل ۸ نیز دامنه تغییرات SPI‌های محاسباتی و مشاهداتی نشان داده شده است. در شکل ۸ باید توجه داشت که داده‌های SPI، بی‌بعد هستند. همچنین در این شکل دو مرز ترسالی و خشکسالی نشان داده شده است که بیانگر فیزیک مسئله و یا به تعبیری بیانگر شدت و ضعف خشکسالی هستند. همانگونه که شکل ۸ نشان می‌دهد دامنه تغییرات SPI محاسباتی بسیار نزدیک به اعداد SPI مشاهداتی است هر چند که این اختلاف در نقاط اوج و یا فرود بیشتر است اما با این وجود نیز اگر SPI مشاهداتی در بالای پایین خشکسالی قرار داشته باشد، SPI محاسباتی نیز در پایین مرز قرار دارد. همین موضوع در دامنه مرز ترسالی نیز صدق می‌کند. بنابراین می‌توان نتیجه گرفت که مدل عصبی-فازی با خوشه‌بندی فازی به خوبی توانسته الگوی خشکسالی و یا ترسالی را در سری زمانی تشخیص دهد.

در نهایت برای مقایسه نهایی نتایج به دست آمده از روش‌های مدل‌سازی سری زمانی خشکسالی ارائه شده در این مقاله، نتایج بهترین ساختار برای هر یک از روش‌های یاد شده در جدول ۶ آورده شده است که از مقایسه کلی اعداد جدول نتیجه‌گیری می‌شود که کاربرد روش عصبی-فازی به همراه آنالیز خوشه‌بندی می‌تواند به‌عنوان یک ابزار مناسب برای پیش‌بینی این پدیده به‌کار گرفته شود.


جدول ۵- نتایج و آماره‌های مدل‌سازی نمایه SPI با روش شبکه عصبی-فازی تطبیقی با خوشه بندی داده‌ها

تعداد خوشه‌ها	متغیرهای ورودی به شبکه*	تابع عضویت	ضریب تبیین ( $R^2$ )	وا سنجی	صحت سنجی
۲	$SPI_t, SPI_{t-1}$	gbelmf-3	۰/۹۳	۰/۸۹	
۴	$SPI_t, SPI_{t-1}$	gbelmf-3	۰/۹۵	۰/۹۱	
۸	$SPI_t, SPI_{t-1}$	gbelmf-3	۰/۹۶	۰/۹۱	

\* $SPI_{t+1}$ : متغییر خروجی شبکه



شکل ۸- نمودار SPI های محاسباتی و مشاهداتی برای مرحله واسنجی و صحت سنجی



شکل ۷- نمودار دامنه تغییرات SPI های محاسباتی و مشاهداتی در مرز ترسالی و خشکسالی

جدول ۶- ارزیابی مدل های مختلف در مدلسازی خشکسالی

صحت سنجی		واسنجی		روش مدلسازی
R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	
۰/۸۷	۰/۰۷۱	۰/۷۶	۰/۰۸۵	شبکه عصبی- مصنوعی
۰/۹۳	۰/۰۶۰	۰/۸۹	۰/۰۶۹	شبکه عصبی- فازی تطبیقی بدون خوشه بندی
۰/۹۶	۰/۰۵۲	۰/۹۱	۰/۰۰۵۶	شبکه عصبی- فازی تطبیقی با خوشه بندی

رهگذر یک شبکه آموزش دیده برای آن حوضه داشت. بنابراین هر شبکه آموزش یافته برای داده‌های همان حوضه قابل اعتبار است و تنها برای همان حوضه می‌تواند به‌کار گرفته شود. به‌عبارتی شبکه عصبی- فازی تنها برای حوضه آموزش دیده قابل کاربرد است ولی متدلوژی و روش یاد شده در مقاله، قابل تعمیم و کاربرد برای تمامی حوضه‌های دیگر است.

#### ۷- پیشنهاد

به‌دلیل اینکه پدیده خشکسالی دارای دوره‌های رخداد و بازگشت بلندمدت است پیشنهاد می‌گردد که از تبدیلاتی همچون تبدیل موجک برای پیش‌پردازش بهتر داده‌ها و دریافت اطلاعات بلندمدت و کوتاه مدت سری زمانی داده‌ها استفاده گردد. همچنین بهره‌گیری از دیگر تکنیک‌های دانش هوش مصنوعی و یا بهره‌گیری از چند پارامتر دیگر در کنار نمایه SPI به‌منظور مدل‌سازی چند متغیره پدیده خشکسالی می‌تواند یک رهیافت مناسب در زمینه مدل‌سازی پدیده خشکسالی باشد.

#### ۶- نتیجه‌گیری

ترکیب مدل شبکه عصبی- فازی با آنالیز خوشه‌بندی C-mean یک ایده نو برای به‌وجود آمدن شبکه‌ای توانمندتر است. پردازش داده‌های سری زمانی در خوشه‌هایی یکسان میزان تأثیر هر پارامتر در خروجی شبکه را به‌طور واضح مورد بررسی قرار می‌دهد. در این پژوهش از داده‌های نمایه SPI که در مقایسه با سایر نمایه‌ها از شرایط مطلوب‌تری برخوردار است به‌عنوان داده‌های ورودی به شبکه عصبی- فازی استفاده گردید که نتایج حاصل از این مدل‌سازی نشان می‌دهد که بهره‌گیری از شبکه عصبی- فازی به‌خوبی توانسته الگوی سری زمانی داده‌ها را تشخیص دهد و به نتایج منجر گردد. همچنین خوشه‌بندی داده‌ها سبب بهبود هر چه بهتر فرایند مدل‌سازی و در نتیجه افزایش کارایی مدل گردید.

با توجه به اینکه مدل شبکه عصبی- فازی بر نگرش هوش مصنوعی بر پایه روش داده‌کاوی استوار است، این مدل را می‌توان برای هر حوضه دلخواه مورد آموزش قرار داد و از این

#### ۸- مراجع

- Palmer, W.C. (1965). *Meteorological drought*, Research Paper No. 45, US. Weather Bureau, Washington, D.C.
- Wilhite, D.A., and Glantz, M. H. (1985). "Understanding the drought phenomenon: The role of definitions." *Water International*, 10 (3), 111-120.
- Hayes, M.J., Svoboda, M.D., Wilhite, D. A., and Vanyarkho, O.V. (1999). *Monitoring the 1996 drought using the standardized precipitation index*, National Drought Mitigation Center, Lincoln, Nebraska.

- 4- Vermes, L. (2001). *How to work out a drought mitigation strategy*, European Regional Conference of ICID.
- 5- Palafi, I., and Petrasovits, L.V. (1995). "Some methodological questions of the European drought-sensitivity map." *Proceedings of the International ICID Workshop on Drought*, Budapest- Alsogod, 131-142.
- 6- Ghvami, M.R., and Gharemoahadlo, H.R. (2001). *Drought indexes*, Regional Water Office, Azarbayejan and Ardabil Provinces. (In Persian)
- 7- Herbst, P.H., and Bredenkamp, D. (1966). "A thechniqe for the drought for rainfall data." *Journal of Hydrology*, 4(3), 264-272.
- 8- Beran, M.A., and Gustard, A. (1977). "The forest cycle and low river flows: A review of UK and international studies." *J. of Hydrology*, 109, 385-411.
- 9- McKee, T. B., Doesken, N. J., and Kleist, J. (1993). "The relationship of drought frequency and duration to time scales." *Proceedings of the 8<sup>th</sup> Conference on Applied Climatology*, 179-184.
- 10- Salas, J.D., Delleur, J.W., Yevjevich, V., and Lane, W.L. (1980). *Applied modeling of hydrologic time series*, Water Resources Publications, Littleton, Colorado.
- 11- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). "Artificial neural networks in hydrology 1: Hydrology application." *J. of Hydrological Engineering*, 5(2), 124-137.
- 12- Abrahart, R.J., and See, L. (2000). "Comparing neural network (NN) and auto regressive moving average (ARMA) techniques for the provision of continuous river flow forecasts in two contrasting catchments." *Hydrological Processes*, 14, 2157-2172.
- 13- Ho, D.W.C., Zhang, P.A., and Xu, J. (2001). "Fuzzy wavelet networks for function learning." *IEEE Transactions on Fuzzy Systems*, 9(1), 200-211.
- 14- Zhang, G.P. (2003). "Time series forecasting using a hybrid ARIMA and neural network model." *Neurocomputing*, 50, 159-175.
- 15- Chang, F.J., Chang, L.C., and Huang, H.L. (2002). "Real-time recurrent learning neural network for stream-flow forecasting." *Hydrological Processes*, 16, 2577-2588.
- 16- Coulibaly, P., Anctil, F., and Bobee, B. (1999). "Hydrological forecasting using artificial neural networks." *Canadian Journal of Civil Engineering*, 26(3), 293-304.
- 17- Kim, T., and Valdes, J.B. (2003). "Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks." *J. of Hydrological Engineering*, 8(6), 319-328.
- 18- Mishra, A.K., and Desai, V.R. (2006). "Drought forecasting using feed-forward recursive neural network." *Ecological Modelling*, 198(15), 127-138.
- 19- Bacanlı, U. G., Firat, M., and Dikbas, F. (2009). "Adaptive neuro-fuzzy inference system for drought forecasting." *Stochastic Environmental Research and Risk Assessment*, 23(8), 1143-1154.
- 20- Keskin, M. E., Terzi, O., Taylan, E. D., and Ücukyaman, D. K. (2009). "Meteorological drought analysis using data-driven models for the lakes district, Turkey." *Hydrological Sciences Journal*, 54(6), 1114-1124.
- 21- Farokhnia, A., Morid, S., and Byun, H.R. (2011). "Application of global SST and SLP data for drought forecasting on Tehran plain using data mining and ANFIS techniques." *Theoretical and Applied Climatology*, 104(1-2), 71-81
- 22- Aqil, M., Kita, I., Yano, A., and Nishiyama, S. (2007). "Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool." *J. of Environmental Management*, 85, 215-223.
- 23- Jang, J.S.R., Sun, C.T., and Mizutani, E. (1997). "Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence." 3<sup>rd</sup> Ed., Prentice Hall, New Jersey.
- 24- Bezdek, J. C. (1981). *Pattern recognition with fuzzy objective function algoritms*, Plenum Press, New York.
- 25- Legates, D.R., and McCabe, Jr. G.J. (1999). "Evaluating the use of goodness-of-fit measures in hydrologic and hydroclimatic model validation." *Water Resource Researches*, 35(1), 233-241.
- 26- Dastorani, M. T., Sharifi Darani, H., Talebi, A., and Moghadam Nia, A. (2011). "Evaluation of the application of artificial neural networks and adaptive neuro-fuzzy inference systems for rainfall-runoff modeling in Zayandeh-rood dam basin." *J. of Water and Wastewater*, 80, 114-125. (In Persian)
- 27- Mishra, A.K., and Singh, V.J. (2011). Drought modeling – A review, *J. of Hydrology*, 403, 157-175.
- 28- Nourani, V., Komasi, M., and Mano, A. (2009). "A multivariate ANN-wavelet approach for rainfall-runoff modeling." *Water Resource Management*, 23, 2877-2894.
- 29- Keshavarz, M., Karami, E., and Vanclay, F. (2012). "The social experience of drought in rural Iran." *Land Use Policy*, 30, 120-29.