

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده مهندسی عمران

پایان نامه کارشناسی ارشد مهندسی و مدیریت منابع آب

ارائه الگوریتمی برای دستیابی به عدم قطعیت مدل شبکه عصبی مصنوعی درپیش بینی

خشکسالی

نگارنده: حسن صالحی

اساتید راهنما

دکتر سعید گلیان

دکتر روح الله نوری

شهریور ۹۶

شماره: ۹۶/۲۷۳
تاریخ: ۹۶/۶/۲۷

بسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره (۳) صورتجلسه نهایی دفاع از پایان نامه دوره کارشناسی ارشد

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد آقای حسن صالحی با شماره دانشجویی: ۹۴۱۱۰۲۴ رشته مهندسی عمران گرایش مهندسی و مدیریت منابع آب تحت عنوان ارائه: الگوریتمی برای دستیابی به عدم قطعیت مدل شبکه عصبی مصنوعی در پیش بینی خشکسالی که در تاریخ ۱۳۹۶/۰۶/۲۰ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار گردید به شرح ذیل اعلام می-گردد:

قبول (با درجه) ☒ (.....) ☐ مردود نوع تحقیق: ☐ نظری ☐ عملی			
عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاد راهنمای اول	دکتر سعید گایان	استاد یار	
۲- استاد راهنمای دوم	دکتر روح الله نوری	استاد یار	
۳- استاد مشاور			
۴- نماینده تحصیلات تکمیلی	دکتر محسن کرامتی	استاد یار	
۵- استاد ممتحن اول	دکتر رامین امینی	استاد یار	
۶- استاد ممتحن دوم	دکتر مهدی عجمی	استاد یار	

نام و نام خانوادگی رئیس دانشکده: دکتر احمد احمدی

تاریخ و امضاء و مهر دانشکده: ۱۳۹۶/۰۶/۲۰

تصوه: در صورتی که کسی مردود شود حداکثر یکبار دیگر (در مدت مجاز تحصیل) می تواند از پایان نامه خود دفاع نماید (دفاع مجدد نباید زودتر از ۴ ماه برگزار شود).

تقدیم به مهربان فرشتگانی که

لحظات ناب باور بودن، لذت و غرور دانستن، جسارت خواستن، عظمت رسیدن و تمام تجربه های یکتا و زیبای زندگیم، مدیون حضور سبز آن هاست.

تقدیم به پدر و مادر عزیزم.

تقدیر

از اساتید گرامی، آقایان دکتر سعید گلیان و دکتر روح الله نوری بی نهایت سپاسگزارم. یقیناً بدون حمایت این اساتید گرامی، انجام این پایان نامه امکان پذیر نبود.

تعهد نامه

اینجانب **حسن صالحی** دانشجوی دوره کارشناسی ارشد دانشکده مهندسی عمران گرایش مهندسی و مدیریت منابع آب دانشگاه صنعتی شاهرود نویسنده پایان نامه: **ارائه الگوریتمی برای دستیابی به عدم قطعیت مدل شبکه عصبی مصنوعی در پیش بینی خشکسالی تحت راهنمایی دکتر سعید گلیان و دکتر روح الله نوری** متعهد می شوم.

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است

تاریخ ۱۳۹۶/۶/۲۰

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر

چکیده

خشکسالی پدیده‌ای خزشی و جزئی طبیعی از اقلیم هر منطقه می‌باشد که اثرات شدید اقتصادی، زیست محیطی و اجتماعی را در پی دارد. کشور ایران سرزمینی خشک می‌باشد و از شرایط خشکسالی در سال‌های اخیر زیان بسیار دیده است. توسعه ابزار به منظور نظارت مؤثر و پیش‌بینی شدت خشکسالی با دقت بالا و محاسبه عدم قطعیت آن می‌تواند به سیاست‌گذاران در جهت کاهش آسیب‌پذیری و برنامه‌ریزی دقیق در جهت مقابله با این پدیده کمک کند.

در دهه‌های گذشته شبکه‌های عصبی توانایی زیادی در مدل‌سازی و پیش‌بینی سری‌های زمانی نشان داده‌اند. در این پژوهش قرار است که با استفاده از ANN و ANFIS به مدل‌سازی و پیش‌بینی خشکسالی پرداخته شود و در گام بعدی با محاسبه عدم قطعیت هر کدام از مدل‌ها مدل مناسب با دقت بالا انتخاب گردد. از آنجا که انتخاب داده‌های ورودی نقش مهمی در آموزش شبکه‌های عصبی دارد و تاکنون در تمام تحقیقات گذشته از الگوریتم انتخاب کاملاً تصادفی استفاده شده است سعی بر ارائه الگوریتم جدیدی برای انتخاب داده‌های ورودی در مرحله آموزش شده است.

نتایج نهایی نشان می‌دهد که اگرچه مدل ANFIS نسبت به مدل ANN، مقدار R^2 کمتری را نشان می‌دهد ولی دارای عدم قطعیت کمتری نسبت به مدل ANN بوده است که این نشان از برتری مدل ANFIS نسبت به مدل ANN دارد.

کلمات کلیدی: پیش‌بینی خشکسالی، عدم قطعیت، شبکه‌های عصبی، شبکه‌های فازی

فهرست مطالب

۱. فصل اول : مقدمه و کلیات	۱
۱-۱ مقدمه	۲
۱-۲ انواع خشکسالی	۴
۱-۳ شاخص ها و تکنیکهای مورد استفاده جهت ارزیابی خشکسالی	۶
۱-۴ اهداف تحقیق	۷
۱-۵ ضرورت تحقیق	۸
۲. فصل دوم : مروری بر مطالعات و پژوهش های پیشین	۹
۲-۱ مقدمه	۱۰
۲-۲ مروری بر مدل های پیش بینی	۱۰
۲-۳ مطالعات پیش بینی خشکسالی با روش های هوش مصنوعی	۱۲
۲-۴ جمع بندی	۲۰
۳. فصل سوم : مواد و روش ها	۲۳
۳-۱ مقدمه	۲۴
۳-۲ شاخص های خشکسالی هواشناسی و تشخیص خشکسالی	۲۴
۳-۲-۱ شاخص شدت خشکسالی پالمر (PDSI)	۲۵
۳-۲-۲ شاخص SWSI	۲۶
۳-۲-۳ شاخص دهک ها	۲۸

- ۳-۲-۴ شاخص رطوبتی گیاه CMI ۳۱
- ۳-۲-۵ شاخص درصد از نرمال (PN) ۳۲
- ۳-۲-۶ شاخص SPI ۳۳
- ۳-۳ منطقه مورد مطالعه ۳۸
- ۳-۴ توسعه سری SPI ۴۱
- ۳-۵ مدل‌های پیش‌بینی برای شبکه‌های عصبی ۴۵
- ۳-۵-۱ شبکه عصبی مصنوعی ۴۶
- ۳-۵-۲ شبکه‌های عصبی-فازی ۵۲
- ۳-۶ پردازش آمار بارندگی ۵۴
- ۳-۶-۱ نرمال‌سازی داده‌ها ۵۴
- ۳-۷ برآورد عدم قطعیت در پیش‌بینی‌ها ۵۵
- ۳-۸ روش‌های ارزیابی مدل‌ها ۵۷
- ۳-۸-۱ معیار R^2 : ۵۷
- ۳-۸-۲ معیار جذر میانگین مربع خطاها (RMSE) : ۵۷
- ۳-۸-۳ معیار میانگین خطای مطلق MAE : ۵۸
- ۳-۸-۴ معیار نش-شاتکلیف: ۵۸
- ۳-۹ روش شناسی ۵۹

۵۹	 SPI محاسبه ۱-۹-۳
۶۰	 ANN توسعه ۲-۹-۳
۶۱	 ANFIS توسعه ۳-۹-۳
۶۳	 ساختار مدل های پیشنهادی ۴-۹-۳
۶۵	 فصل چهارم : نتایج و بحث
۶۶	 ۱-۴ مقدمه
۶۶	 SPI _۱ پیش بینی ۲-۴
۶۸	 SPI _۳ پیش بینی ۳-۴
۶۹	 SPI _۶ پیش بینی ۴-۴
۷۱	 SPI _۹ پیش بینی ۵-۴
۷۲	 SPI _{۱۲} پیش بینی ۶-۴
۹۰	 ۷-۴ نتایج عدم قطعیت مدل های پیش بینی
۱۰۳	 فصل پنجم : نتیجه گیری و پیشنهادها
۱۰۴	 ۱-۵ مقدمه
۱۰۴	 ۲-۵ خلاصه تحقیق
۱۰۵	 ۳-۵ نتایج
۱۰۶	 ۴-۵ پیشنهاد ها

منابع ۱۰۷

فهرست شکل ها

- شکل ۱-۳ سیستم استنتاج فازی سوگنو ۶۲
- شکل ۲-۳ معماری مدل ANFIS معادل سیستم استنتاجی فازی ۶۳
- شکل ۱-۴ مقایسه مقدار SPI مشاهداتی با SPI پیش‌بینی زاهدان در مدل ANN ۷۴
- شکل ۲-۴ مقایسه مقدار SPI مشاهداتی با SPI پیش‌بینی زاهدان در مدل ANFIS ۷۵
- شکل ۳-۴ تغییرات NS در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر مشهد ۷۶
- شکل ۴-۴ تغییرات RMSE در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر مشهد ۷۷
- شکل ۵-۴ تغییرات R در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر مشهد ۷۸
- شکل ۶-۴ تغییرات NS در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر تبریز ۷۹
- شکل ۷-۴ تغییرات RMSE در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر تبریز ۸۰
- شکل ۸-۴ تغییرات R در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر تبریز ۸۱
- شکل ۹-۴ تغییرات NS در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر زاهدان ۸۲
- شکل ۱۰-۴ تغییرات RMSE در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر زاهدان . ۸۳
- شکل ۱۱-۴ تغییرات R در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر زاهدان ۸۴
- شکل ۱۲-۴ تغییرات NS در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر بندرعباس ... ۸۵
- شکل ۱۳-۴ تغییرات NS در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر بندرعباس ... ۸۶
- شکل ۱۴-۴ تغییرات R در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر بندرعباس ۸۷
- شکل ۱۵-۴ تغییرات NS در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر شاهرود ۸۸
- شکل ۱۶-۴ تغییرات RMSE در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر شاهرود. ۸۹
- شکل ۱۷-۴ تغییرات R در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر شاهرود ۹۰

- شکل ۴-۱۸ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر مشهد در مدل ANFIS ۹۲
- شکل ۴-۱۹ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر مشهد در مدل ANN ۹۳
- شکل ۴-۲۰ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر شاهرود در مدل ANFIS ۹۴
- شکل ۴-۲۱ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر شاهرود در مدل ANN . ۹۵
- شکل ۴-۲۲ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر زاهدان در مدل ANFIS ۹۶
- شکل ۴-۲۳ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر زاهدان در مدل ANN .. ۹۷
- شکل ۴-۲۴ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر تبریز در مدل ANFIS . ۹۸
- شکل ۴-۲۵ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر تبریز در مدل ANN ۹۹
- شکل ۴-۲۶ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر بندرعباس در مدل ANFIS ۱۰۰
- شکل ۴-۲۷ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر بندرعباس در مدل ANN ۱۰۱

فهرست جدول ها

جدول ۱-۳	مقیاس طبقه‌بندی PDSI	۲۶
جدول ۲-۳	مقیاس طبقه‌بندی SWSI	۲۸
جدول ۳-۳	مقیاس طبقه‌بندی شاخص دهک ها	۳۰
جدول ۴-۳	مقیاس طبقه‌بندی شاخص رطوبتی گیاه	۳۲
جدول ۵-۳	مقیاس طبقه‌بندی شاخص درصد نرمال	۳۳
جدول ۶-۳	خلاصه کلی شاخص ها	۳۷
جدول ۷-۳	مجموعه داده‌های بارش ورودی حوضه‌ها	۴۱
جدول ۸-۳	مقیاس طبقه‌بندی شاخص SPI	۴۵
جدول ۹-۳	مدل‌های پیشنهادی برای پیش‌بینی	۶۴
جدول ۱-۴	بهترین عملکرد شبکه ANN درپیش‌بینی SPI۱	۶۷
جدول ۲-۴	بهترین عملکرد شبکه ANFIS درپیش‌بینی SPI۱	۶۷
جدول ۳-۴	بهترین عملکرد شبکه ANN درپیش‌بینی SPI۳	۶۸
جدول ۴-۴	بهترین عملکرد شبکه ANFIS درپیش‌بینی SPI۳	۶۹
جدول ۵-۴	بهترین عملکرد شبکه ANN در پیش‌بینی SPI۶	۷۰
جدول ۶-۴	بهترین عملکرد شبکه ANFIS درپیش‌بینی SPI۶	۷۰
جدول ۷-۴	بهترین عملکرد شبکه ANN درپیش‌بینی SPI۹	۷۱
جدول ۸-۴	بهترین عملکرد شبکه ANFIS در پیش‌بینی SPI۹	۷۲
جدول ۹-۴	بهترین عملکرد شبکه ANN درپیش‌بینی SPI۱۲	۷۳
جدول ۱۰-۴	بهترین عملکرد شبکه ANFIS در پیش‌بینی SPI۱۲	۷۳

جدول ۱۱-۴ نتایج مربوط به عدم قطعیت ۹۱

۱. فصل اول : مقدمه و کلیات

۱-۱ مقدمه

ایران کشور پهناوری است که به علت موقعیت خاص و ویژگی‌های توپوگرافیک، از آب‌وهوای متفاوتی برخوردار است. میزان بارندگی در کشورمان کمتر از یک‌سوم بارندگی متوسط کره زمین است. در دهه‌های اخیر در میان حوادث طبیعی که جمعیت‌های انسانی را تحت تأثیر قرار داده‌اند، تعداد و فراوانی پدیده‌های خشکسالی بیش از سایر حوادث بوده است.

خشکسالی یکی از مخاطرات طبیعی پر خسارت است که آثار آن به‌کندی نمایان می‌شود. کشور ایران به دلیل واقع‌شدن در محدوده خشک و نیمه‌خشک جهان و تغییرات اقلیمی گسترده‌ای که در بیشتر نقاط آن دیده می‌شود، همواره خسارات زیادی ناشی از خشکسالی را متحمل می‌شود. بیشتر بلایای طبیعی طی دوره‌ای کوتاه خسارات سنگین مالی و جانی به جامعه وارد می‌کنند، اما خسارات سنگین ناشی از خشکسالی به‌تدریج و در مدت طولانی‌تری ظاهر می‌شود در نتیجه بررسی آن به‌عنوان یک «بحران» با چالش‌های بیشتری مواجه است. همچنین تمایز این پدیده با سایر بلایای طبیعی در این است که برخلاف سایر بلایا، این پدیده به‌تدریج و در یک دوره زمانی نسبتاً طولانی عمل کرده و اثرات آن ممکن است پس از چند سال و با تأخیر بیشتری نسبت به سایر حوادث طبیعی ظاهر شود؛ بنابراین تعیین دقیق زمان شروع آن کار مشکلی است و ماهیت خزشی دارد [۱].

تنوع مطالعات خشکسالی به دلیل پیچیدگی آن بسیار گسترده است. مطالعاتی که در زمینه خشکسالی انجام می‌شود، از نظر موضوع بررسی‌شده در چند گروه متمایز قابل طبقه‌بندی هستند. برخی از پژوهشگران به رابطه گردش عمومی جو با خشکسالی و علت وقوع خشکسالی توجه می‌کنند. گروه دیگری از پژوهشگران به شناخت زمان وقوع خشکسالی‌ها و عوامل تأثیرپذیر از آن می‌پردازند و گروهی دیگر احتمال وقوع خشکسالی و تأثیرات آن و خسارت‌های ناشی از آن را تجزیه و تحلیل می‌کنند [۳] - [۱].

با توجه به این که وقوع خشکسالی در کشور بسیار بالاست، پیش‌بینی و اقدامات لازم برای مقابله با آن امری حیاتی است. به علت تعدد عوامل مؤثر در وقوع پدیده خشکسالی، تعریف آن کار چندان ساده‌ای نیست. تاکنون تعاریف بسیار زیادی از خشکسالی ارائه شده است. خشکسالی یک اختلال موقتی است و با خشکی تفاوت دارد چراکه خشکی صرفاً محدود به مناطقی با بارندگی اندک است و حالتی دائمی از اقلیم هست. خشکسالی یک پدیده گذرا و موقت است؛ اما هرکدام از این تعاریف دیدگاه خاصی را مدنظر داشته‌اند، به‌هرحال عدم وجود یک تعریف جامع و دقیقی از خشکسالی و متفاوت بودن معنی آن از دیدگاه‌های مختلف مانع از درک مفهوم خشکسالی شده است. نظر به اینکه مطالعات خشکسالی توسط محققین از جنبه‌های مختلفی موردبررسی و مطالعه قرار می‌گیرد، در ادامه به تعاریف ارائه شده از پدیده خشکسالی توسط محققین مختلف پرداخته می‌شود.

خشکسالی عبارت است از رخداد شرایطی که در آن بارندگی و آب باران قابل‌دسترسی پایین‌تر از حد نرمال باشد که این پدیده بر اثر نوسانات اقلیمی پدید می‌آید. در تعریف دیگر، خشکسالی عبارت است از یک رویداد شدید منطقه‌ای و پایدار که طی آن دسترسی به منابع آب زیر شرایط متوسط قرار دارد و یا خشکسالی را می‌توان کمبود مستمر و غیرطبیعی رطوبت در یک دوره زمانی خاص (معمولاً یک سال) دانست. در تعریف مذکور واژه مستمر به تداوم حالت کمبود و واژه غیرطبیعی به انحراف شاخصی از شرایط طبیعی یا میانگین اطلاق می‌گردد. یکی دیگر از تعاریف خشکسالی این است که خشکسالی عبارت از یک دوره طولانی کمبود بارندگی است که خسارات شدیدی به محصولات کشاورزی وارد آورده است و در نتیجه سبب کاهش کیفیت و کمیت محصولات می‌گردد. تعاریف کاربردی، خصوصیات و آستانه‌های شروع، ادامه و خاتمه خشکسالی را بیان می‌کنند و اساس یک سیستم هشداردهنده سریع و مؤثر هستند. همچنین، این تعاریف می‌توانند برای تحلیل فراوانی خشکسالی، شدت و مدت کمبود آب در یک دوره زمانی معین به کار روند. سازمان جهانی هواشناسی متغیرهایی را که با آن‌ها می‌توان خشکسالی را تعیین و تعریف نمود برحسب اولویت، به‌صورت

زیر بیان داشته است:

- بارندگی

- بارندگی و میانگین درجه حرارت

- رطوبت خاک و متغیرهای میزان محصول

- شاخص‌های آب‌وهوایی و برآوردهای تبخیر و تعرق

از بین متغیرهای فوق، بارندگی یکی از مهم‌ترین و عمده‌ترین متغیرهایی است که از آن در تعریف خشکسالی استفاده می‌شود. خشکسالی خود به تنهایی فاجعه محسوب نمی‌شود بلکه پیامدهای آن بر مردم و محیط‌زیست فاجعه است [۴].

۱-۲ انواع خشکسالی

از دلایل تنوع در تعاریف خشکسالی، تنوع نیازها و زمینه کاری محققان است. کاهش میزان بارندگی و افزایش دما هر یک به تنهایی و یا به کمک هم می‌تواند موجب خشکسالی شوند [۵].

از این نظر خشکسالی را می‌توان از دیدگاه‌های هواشناسی، کشاورزی و هیدرولوژیک مورد بررسی قرار داد. در نتیجه تعریفی که در یک تحلیل از خشکسالی ارائه می‌شود باید متناسب با شرایط اقلیم، نوع منابع و مقدار ذخایر آب، مصارف آب، نیازها و زمینه تحقیق محقق باشد. در بیشتر مراجع، خشکسالی‌ها را به چهار دسته خشکسالی هواشناسی، خشکسالی کشاورزی، خشکسالی هیدرولوژیکی و خشکسالی اقتصادی-اجتماعی طبقه‌بندی نموده‌اند [۶].

- خشکسالی هواشناسی

خشکسالی هواشناسی کمبود مقدار بارندگی را نسبت به شرایط میانگین درازمدت آن بررسی می‌نماید. خشکسالی هواشناسی معمولاً در قالب تعداد روزها و یا ماه‌های خشک پیاپی تعریف می‌شود. بسیاری از تعاریف خشکسالی هواشناسی بر مبنای مفهوم مجموع کمبود بارندگی نسبت به میانگین و در ارتباط با یک آستانه معین که زمان پایان خشکسالی را تعیین می‌نماید، استوار می‌باشند.

• خشکسالی کشاورزی

خشکسالی کشاورزی اثرات ویژگی‌های مختلف هواشناسی یا هیدرولوژیکی خشکسالی را به این پدیده کشاورزی به‌ویژه کمبود بارش، اختلاف بین تبخیر و تعرق واقعی و پتانسیلی، کمبود رطوبت خاک، افت سطح آب زیرزمینی یا مخزن و امثال آن مرتبط می‌سازد. نیاز آبی گیاه بستگی به شرایط جوی غالب، خصوصیات زیستی گیاه خاص، مرحله رشد آن و خصوصیات فیزیکی و بیولوژیکی خاک دارد. تعریفی مطلوب از خشکسالی کشاورزی، تعریفی است که بتواند حساسیت متغیر گیاهان زراعی را در طی مراحل نمو گیاه از سبز شدن تا بلوغ لحاظ نماید. کمبود رطوبت در لایه‌های فوقانی خاک به هنگام کشت می‌تواند باعث تأخیر جوانه‌زنی شود که موجب کاهش تراکم بوته در هکتار و نقصان عملکرد نهایی می‌گردد. چنانچه رطوبت خاک فوقانی برای نیازهای مراحل اولیه رشد کافی باشد، کمبودهای رطوبتی در لایه‌های زیرین خاک در صورت تأمین نیازهای آبی گیاه به‌وسیله بارندگی یا آبیاری بر عملکرد نهایی گیاه تأثیر چندانی نخواهد داشت [۸]، [۷].

• خشکسالی هیدرولوژیکی

در شرایطی که خشکسالی هواشناسی مدت زیادی ادامه یابد و حجم جریان رودخانه‌ها یا سطح آب‌های زیرزمینی کاهش یابد، موجب وقوع پدیده خشکسالی هیدرولوژیکی می‌شود. این پدیده غالباً بر اثر کمبود و یا فقدان بارش زمستانی به وجود می‌آید. بر اساس میزان شدت خشکسالی های هواشناسی که منجر به

خشکسالی هیدرولوژیکی می‌شوند، می‌توان این نوع از خشکسالی را به دودسته خشکسالی آب‌های سطحی و خشکسالی آب‌های زیرزمینی تقسیم‌بندی نمود [۹].

• خشکسالی اقتصادی-اجتماعی

خشکسالی اقتصادی-اجتماعی معمولاً پس از یک دوره بسیار طولانی مدت خشکسالی هواشناسی و هیدرولوژیکی پدیدار می‌گردد و موجب قحطی، مرگ‌ومیر و مهاجرت‌های دسته‌جمعی و گسترده می‌شود. این نوع خشکسالی تأثیرات زیادی بر روی ابعاد مختلف اقتصادی و به‌ویژه انواع خاصی از محصولات و کالاهای اقتصادی می‌گذارد. تعریف خشکسالی اقتصادی-اجتماعی تلفیقی از عرضه و تقاضای برخی کالاهای اقتصادی با اجزاء خشکسالی هواشناسی، هیدرولوژیکی و کشاورزی است. این خشکسالی زمانی رخ می‌دهد که تقاضا برای یک کالای اقتصادی خاص به دلیل کاهش عرضه آب نسبت به شرایط معمول افزایش می‌یابد. خشکسالی‌هایی که در این پایان‌نامه مدنظر است، خشکسالی هواشناسی است. طبق تعاریف بالا، خشکسالی هواشناسی به حالتی از خشکی اطلاق می‌گردد که ناشی از کمبود بارندگی است و ارتباط مستقیم با میزان بارندگی دارد. خشکسالی هواشناسی پایه و اساسی خشکسالی‌های دیگر بوده و در پی آن خشکسالی‌های دیگر به وقوع می‌پیوندند. از این‌رو جلوگیری از آن، منجر به جلوگیری از خشکسالی‌های دیگر خواهد شد.

۱-۳ شاخص‌ها و تکنیک‌های مورد استفاده جهت ارزیابی خشکسالی

روش‌های زیادی در سراسر جهان جهت ارزیابی خشکسالی مورد استفاده قرار گرفته است، در این بخش به‌طور خلاصه به تکنیک‌های موجود در این زمینه پرداخته می‌شود. به این صورت که شاخص‌های خشکسالی هواشناسی را که فقط از داده‌های اقلیمی استفاده می‌نمایند توضیح داده می‌شود.

برحسب نوع خشکسالی، شاخص‌های هواشناسی متعددی برای تعیین خشکسالی ارائه شده است. شاخص

شدت خشکسالی پالمر^۱، شاخص ذخیره آب سطحی^۲، شاخص دهک‌ها^۳، شاخص بارش استاندارد^۴ و شاخص رطوبت محصول^۵، از جمله شاخص‌های معروف در این زمینه‌اند که در این تحقیق فقط از شاخصی بارش استاندارد استفاده خواهد شد. نمایه SPI نخستین بار توسط مککی^۶ و همکارانش برای پایش خشکسالی در ایالت کلرادو ارائه شد [۲].

۴-۱ اهداف تحقیق

در این تحقیق سعی بر تحلیل عدم قطعیت مدل ANN در پیش‌بینی خشکسالی است. در این راستا لازم است تا کارکرد مدل تحت الگوهای واسنجی متفاوت ارزیابی شده تا عدم قطعیت مدل حاصل از تغییرات ایجاد شده در داده‌های ورودی بررسی گردد.

۱- طراحی الگوی انتخاب داده‌ها به روش جدید

۲- طراحی مدل ANN و ANFIS برای پیش‌بینی SPI

۳- مقایسه دو مدل ANN و ANFIS بوسیله شاخص R و RMST و NS و MAE

۴- محاسبه عدم قطعیت و دقت مدل برای SPI های متفاوت

^۱ Palmer Drought severity Index (PDS)

^۲ Surface Water Supply Index (SWS)

^۳ Dexilesindex (D۱)

^۴ standardized Precipitation index (SPI)

^۵ Crop Moisture Index (CMI)

^۶ Mckee

۱-۵ ضرورت تحقیق

معمولاً ابزار ریاضی مدل‌سازی پدیده‌های طبیعی و به تبع آن پدیده‌های هیدرولوژی، مدل‌های قطعی^۱ یا مدل‌های آماری است. مدل‌های قطعی بر مبنای روابط علّی و معلولی و مدل‌های آماری، داده محور هستند. در چند دهه اخیر شبکه‌های عصبی مصنوعی^۲ (ANN) قابلیت بالای خود را در مدل‌سازی پدیده‌های هیدرولوژیکی نشان داده‌اند. این مدل‌های داده محور ماهیت تجربی داشته و قادرند راه‌حل‌های دقیقی برای داده‌های ورودی و خروجی ارائه دهند. به هر حال از آنجاکه عملکرد مدل‌های داده محور مانند ANN عملاً تابعی از اطلاعات ورودی به مدل است، تغییر الگوهای ورودی برای کالیبراسیون این مدل‌ها تأثیر زیادی بر بازده آن‌ها دارد و استفاده از نتایج آن‌ها را برای اهداف مدیریتی با چالش‌های زیادی روبرو می‌نماید. بنابراین ارزیابی عملکرد مدل‌های داده محور تحت تأثیر الگوهای متفاوتی از کالیبراسیون می‌تواند در دستیابی به عدم قطعیت این مدل‌ها و ایجاد حاشیه امنیت بیشتر برای اهداف مدیریتی بسیار سودمند واقع گردد. در این راستا هدف اصلی پژوهش حاضر ارائه الگوریتمی برای تحلیل عدم قطعیت مدل داده محور ANN در فرآیند تخمین پدیده خشکسالی است.

نتایج تحلیل عدم قطعیت مدل‌های هوشمند، بیشترین کاربرد را در پیگیری اهداف مدیریتی دارد. پرواضح است که خروجی مدل‌های هوشمند قطعی نیستند و تابعی از تغییر در الگوهای انتخابی برای کالیبراسیون می‌باشند. به عبارتی این مدل‌ها در فرآیند پیش‌بینی متغیرهای هدف، مثل متغیرهای هیدرولوژیکی، دارای عدم قطعیت هستند که عدم آگاهی از این عدم قطعیت‌ها می‌تواند چیدمان مدیریتی برای استفاده از نتایج آن‌ها را به شدت تحت تأثیر قرار دهد.

^۱ Deterministic Models

^۲ Artificial Neural Networks

۲. فصل دوم : مروری بر

مطالعات و پژوهش‌های پیشین

۲-۱ مقدمه

پیش‌بینی خشکسالی برای آمادگی و مقابله با شرایط بحرانی و کاهش خسارت‌های مالی و جانی اهمیت بسیار زیادی دارد. بالا بودن دقت و طولانی بودن زمان پیش‌بینی^۱، تأثیر زیادی در استفاده از نتایج پیش‌بینی دارد.

۲-۲ مروری بر مدل‌های پیش‌بینی

در گذشته برای پیش‌بینی خشکسالی و فرآیندهای هیدرولوژیکی از روش‌های رگرسیونی و استوکستیک استفاده می‌گردید [۱۲]–[۱۰].

گیروس^۲ و همکاران تأثیر خشکسالی سال‌های ۱۹۹۸–۱۹۹۹ برای التورمنت آمریکا را بررسی و عنوان کردند که در مقیاس یک ماهه SPI بهتر از شاخص پالمر در ثبت آغاز شرایط خشکی و شدت آن عمل می‌کند [۱۳]. بردی^۳ و همکاران برای تهیه نقشه‌های پهنه‌بندی خشکسالی از شاخصی SPI استفاده کردند [۱۴].

هنگ^۴ و همکاران از SPI در مکان‌های مختلف دنیا به منظور پایش خشکسالی بهره جستند و این شاخص را یکی از ابزارهای قوی برای مطالعه خشکسالی معرفی کردند [۱۵]. سلطانی و سعادت‌ی شاخص SPI را برای پهنه‌بندی خشکسالی در استان اصفهان به کار بردند و مناطق پرخطر را از نظر خشکسالی نشان دادند. مساعدی و همکارانش پس از برازش مدل استوکستیک بر سری‌های زمانی شاخصی SPI در مقیاس‌های زمانی ۳ تا ۴۸ ماهه به پیش‌بینی مقادیر SPI پرداختند و بر اساسی مقایسه مقادیر مشاهده شده و پیش‌بینی

^۱ Lead Time

^۲ Girux

^۳ Bordi

^۴ Hong

شده، طولانی‌ترین مدت قابل پیش‌بینی برای هر یک از مقیاس‌های زمانی SPI را معین کردند. جهان‌دیده و شیروانی به پیش‌بینی خشکسالی بر اساسی شاخصی SPI با استفاده از مدل‌های سری زمانی در استان فارسی پرداختند. پریانا^۱ با استفاده از زنجیره مارکوف و شاخصی SPI به ایجاد یک مدل تصادفی هشدار خشکسالی پرداختند. ایشان با استفاده از اطلاعات ۶۷ ساله منطقه آجالتو در جنوب پرتغال به پیش‌بینی وقوع خشکسالی در سه ماه آتی اقدام کردند [۱۶].

میشیرا^۲ و همکاران برای پیش‌بینی خشکسالی در حوضه‌ای در هند از یک مدل ترکیبی استفاده کردند. به این منظور آن‌ها مدل ترکیبی خود را از ترکیب یک مدل استوکستیک با ANNS ایجاد کردند [۱۷]. ایشان پیش‌بینی خشکسالی را بر اساس شاخص SPI با استفاده از یک مدل استوکستیک، دو مدل ANNS و دو مدل ترکیبی انجام دادند. سانجای^۳ و همکاران به ارزیابی خشکسالی در سه منطقه در هند پرداختند. ایشان در تحقیق خود همبستگی بین SPI را با شاخص‌های پوشش گیاهی با عناوین شاخصی اختلاف پوشش گیاهی نرمال شده (NDVI)، شاخص تأمین آب پوشش گیاهی (WSVT) و شاخص شرایط پوشش گیاهی (VCL) بررسی کردند. آن‌ها در محاسبه شاخص پوشش گیاهی حوضه از اطلاعات ماهواره‌ای استفاده کردند که نتایج بیانگر کارایی مناسب اطلاعات ماهواره‌ای برای پایش حوضه در شرایط خشکسالی بوده است. آنالیز همبستگی در مقیاس‌های مختلف زمانی ۱، ۲، ۳، ۶، ۹، ۱۳ ماهه انجام شد. نتایج نشان داد که میزان همبستگی بین شاخص‌های یادشده با تغییر مقیاس زمانی متفاوت خواهد میزان همبستگی شاخص‌های مختلف با شاخص SPI افزایش می‌یابد که نشان می‌دهد اثر بارش بر تغییر شاخص خشکسالی یادشده به صورت آنی نیست و بعد از گذر زمان نمایان می‌شود [۱۸]. به بیانی کاهش و افزایش

^۱ Pauloand Pereira

^۲ Mishira

^۳ Sanjay

بارش بعد از یک ماه تأثیری در مقدار شاخص پوشش گیاهی ندارد و گیاهی مشاهده می‌شود، درحالی که بعد از ۹ ماه در یک حوضه و ۳ ماه در حوضه دیگر این همبستگی بیشتر به چشم می‌خورد.

این مدل‌ها، در حقیقت پارامترها را به شکل خطی وارد فرآیندهای تصمیم‌گیری نموده که در اغلب موارد نمی‌تواند به خوبی مسائل پیچیده اقلیمی - هیدرولیکی را تحلیل نمایند و ضروری است، مدل‌هایی با کارایی بیشتر به منظور پیش‌بینی پدیده‌ای غیرخطی و پیچیده معرفی شوند [۱۹].

بدین خاطر متخصصان و دانشمندان علم هیدرولوژی و سایر رشته‌های مرتبط در پی ایجاد مدل‌هایی مناسب، به منظور پیش‌بینی بهنگام این حوادث شده‌اند. ظهور تئوری‌های توانمندی، همچون: الگوریتم‌های فازی^۱، شبکه عصبی و فیلتر آلمان، تحولی عظیم در تحلیل رفتار سیستم‌های دینامیک در علوم مختلف مربوط به آب ایجاد کرده است.

۲-۳ مطالعات پیش‌بینی خشکسالی با روش‌های هوش مصنوعی

اولین استفاده از شبکه‌های عصبی مصنوعی درزمینه^۲ مباحث هیدرولوژیکی توسط دانیل^۲ شد. وی آب مصرفی ماهانه و سیلاب را با استفاده از شبکه‌های عصبی مصنوعی پیش‌بینی کرد. نتایج نشان داد که شبکه‌های عصبی مصنوعی توانایی‌های زیادی در پیش‌بینی متغیرهای هیدرولوژیکی دارند.

کرسپو و مورا^۳ به پیش‌بینی خشکسالی در حوضه‌ی آبریز Cantabria در کشور اسپانیا پرداختند. نتایج نشان داد که مدل‌های ساده‌ی شبکه‌ی عصبی، نتایج خوبی را برای پیش‌بینی خشکسالی ارائه می‌دهند [۲۰].

^۱ Fuzzy Algorithms

^۲ Daniel

^۳ Crespo & Mora

میشیرا و دیسای^۱ به پیش‌بینی شاخصی خشکسالی SPI^۲ با استفاده از روش‌های خطی استوکستیک ARIMA^۳ و SARMIA^۴ و همین‌طور شبکه‌ی عصبی چندمرحله‌ای بازگشتی DMSN^۵ در حوضه‌ی آبریز رودخانه‌ی Kansabati در کشور هند پرداختند. نتایج نشان داد که شبکه‌های عصبی نسبت به مدل‌های خطی، خطای کمتری دارند و در هر دو مدل با افزایش زمان پیش‌بینی، دقت‌ها کاهش می‌یابد [۲۱].

مرید^۶ و همکاران با استفاده از روش شبکه‌ی عصبی و شاخص‌های اقلیمی به پیش‌بینی دو شاخص خشکسالی SPI و EDI^۷ برای ۱ تا ۱۲ ماه در استان تهران پرداختند. نتایج نشان داد که در تمام ماه‌های پیش‌بینی و در تمام ایستگاه‌ها، شاخص EDI نسبت به SPI برتری دارد و همچنین شاخص‌های NAO^۸ و SOL^۹ تأثیر کمی در بهبود نتایج مدل‌ها دارند [۲۲].

سانتوز^{۱۰} و همکاران روشی شبکه‌های عصبی پس انتشار را برای پیش‌بینی خشکسالی در سه منطقه از حوضه‌ی رودخانه‌ی Sanfrancisco در شمال شرق برزیل بکار گرفتند. نتایج، دقت بالای شبکه‌ی عصبی را تأیید کرد.

کوچر^{۱۱} و همکاران با استفاده از شاخص‌های اقلیمی^{۱۲} و روش شبکه‌ی عصبی، شاخص خشکسالی پالمر^{۱۳} در

^۱ Mishara & Desai

^۲ Standard Precipitation Index

^۳ Autoregressive Integrated Moving Average

^۴ Seasonal Autoregressive Integrated Moving Average

^۵ Direct multi-step neural network

^۶ Morid

^۷ Effective drought index

^۸ North Atlantic Oscillation

^۹ Southern Oscillation Index

^{۱۰} Santos

^{۱۱} Cutore

^{۱۲} Climate indexes

^{۱۳} Palmer drought index

سیسیل ایتالیا را پیش‌بینی کردند. نتایج نشان داد همبستگی معناداری بین شاخص NAO و EB^۱ برای شاخص خشکسالی پالمر پاییزه و زمستانه وجود دارد [۲۳].

افخمی و همکاران با استفاده از شبکه‌ی عصبی و داده‌های اقلیمی، خشکسالی استان یزد را پیش‌بینی کردند. خروجی این تحقیق انعطاف‌پذیری بالای شبکه نسبت به فقدان داده‌های ورودی را اثبات کرد.

خوشحال دستجردی و حسینی از داده‌های اقلیمی و هیدرولوژیکی و شبکه‌ی پرسپترون چندلایه برای پیش‌بینی خشکسالی در استان اصفهان استفاده کردند. نتایج نشان داد که با دقت بالای ۹۵ درصد، می‌توان سیکل خشکسالی استان را پیش‌بینی نمود.

ابرقویی^۲ و همکاران با استفاده از شبکه‌ی عصبی مصنوعی، شاخص خشکسالی SPI را برای ۱ تا ۱۲ ماه در محدوده‌ی اردکان یزد پیش‌بینی کردند. نتایج نشان داد شبکه‌های عصبی مصنوعی که به‌صورت جعبه‌ی سیاه^۳ عمل می‌کنند، قابلیت زیادی در پیش‌بینی خشکسالی دارند [۲۴].

باروا^۴ و همکاران برای پیش‌بینی خشکسالی روش ADI^۵ و دو نوع از شبکه‌های عصبی RMSNN^۶ و DMSNN^۷ را بکار گرفتند. نتایج نشان داد شبکه‌های RMSNN برای پیش‌بینی سه‌ماهه و شبکه‌های DMSNN برای بازه‌ی زمانی شش‌ماهه نتایج بهتری دارند. همچنین آن‌ها نشان دادند که این دو مدل نسبت به مدل ARIMA از دقت بالاتری برخوردارند [۲۵].

^۱ European Blocking

^۲ Abarghouei

^۳ Black box

^۴ Barua

^۵ Aggregated Drought Index

^۶ Recursive Multi-Step Neural Networks

^۷ Direct multi-step neural networks

در سال ۱۹۶۵ نظریه‌ی فازی^۱ توسط پروفیسور لطفی زاده ارائه شد. این نظریه که بر اساس قواعد اگر-آنگاه بنا شده است، توجه محققین را در زمینه^۲ هوش مصنوعی به خود جلب کرد.

پانگراز^۳ و همکاران از روشی منطبق بر منطق فازی برای تخمین شاخصی پالمر اصلاح شده^۴ در ایالت Nebraska کشور آمریکا استفاده کردند که چرخش عمومی جو و پدیده‌ی ENSO^۵ را نیز مورد توجه قرار می‌داد [۲۶].

ساده‌یر^۵ و همکاران کیفیت آب زیرزمینی دشت Ateli Block هند را به کمک تئوری سیستم فازی مورد بررسی قرار دادند. در این پژوهش، ۱۶ پارامتر کیفی آب زیرزمینی با استفاده از ۴۲ نمونه آب زیرزمینی که از ۱۵ دهکده‌ی این منطقه جمع‌آوری شده بود، مورد بررسی قرار گرفت. نتایج این بررسی نشان داد که ۶۴ درصد آب زیرزمینی منطقه از نظر شراب، مطلوب تا قابل قبول است [۲۷].

ابراهیمی و همکاران خشکسالی هواشناسی را در حوضه‌ی سدهای کرج، لار، لیان، طالقان و ماملو با استفاده از روش استنتاج فازی پیش‌بینی کردند. آن‌ها نتیجه گرفتند که استفاده از روشی نامعین همچون سیستم استنتاج فازی از منظر تئوریک دارای توجیه فنی است [۷۵].

جانگ^۶ با ترکیب قدرت زبانی سیستم‌های فازی و قابلیت آموزش شبکه‌های عصبی، مدل شبکه‌ی عصبی-فازی را پایه‌ریزی کرد با تکامل این مدل، کاربرد آن در مدل‌سازی فرآیندهای مختلف گسترش یافته و

^۱ Fuzzy Theory

^۲ Pongracz

^۳ Palmer Modified Drought Index (PMDI)

^۴ El Niño-Southern Oscillation

^۵ Sudhir

^۶ Jang

روزبه‌روز در حال افزایش است [۲۸].

نایاک^۱ و همکاران کاربرد یک مدل ANFIS^۲ را در مدل‌سازی جریان رودخانه‌ی Baitarani در هند مورد بررسی قرار دادند. آن‌ها همچنین به‌منظور مقایسه‌ی عملکرد مدل‌ها، یک مدل شبکه‌ی عصبی مصنوعی و یک مدل میانگین متحرک خود رگرسیون^۳ را نیز برای همان حوضه توسعه دادند که مدل ANFIS هم از لحاظ روند ساخت و هم از لحاظ نتایج، عملکرد بهتری را نشان داد [۲۷].

کسکین^۴ و همکاران به پیش‌بینی جریان رودخانه در حوضه‌ی آبریز Dim در جنوب کشور ترکیه با استفاده از مدل شبکه‌ی عصبی - فازی و مدل‌های استوکستیک پرداختند. نتایج نشان داد که مدل عصبی - فازی نسبت به مدل‌های استوکستیک نتایج بهتری را نشان می‌دهد و همچنین با افزایش تعداد داده‌ها در فاز آموزش، دقت شبکه‌ی عصبی-فازی بیش‌تر می‌شود [۲۹].

باکانی^۵ و فیرات^۶ به پیش‌بینی شاخصی خشکسالی SPI با استفاده از مدل شبکه‌ی عصبی - منطق فازی در ۱۰ ایستگاه باران‌سنجی واقع در حوضه‌ی آبریز آنتالیای مرکزی کشور ترکیه پرداختند. نتایج نشان داد که استفاده از بارش و SPI به‌صورت هم‌زمان در ورودی، سبب بهبود عملکرد مدل می‌شود. آن‌ها همچنین نشان دادند که خطای شبکه‌ی عصبی - فازی نسبت به شبکه‌ی عصبی کم‌تر است [۳۰].

کرمانی و همکاران با استفاده از سیستم عصبی-فازی Sugeno به پیش‌بینی جریان روزانه‌ی سه رودخانه

^۱ Nayak

^۲ Adaptive Neuro Fuzzy Inference System

^۳ Auto Regressive Moving Average (ARMA)

^۴ Erol Keskin

^۵ Bacanli

^۶ Firat

واقع در ایالت متحدهی آمریکا پرداختند. نتایج به دست آمده از شبکهی عصبی - فازی با یک مدل رگرسیونی^۱ مورد استفاده قرار گرفت که نشانگر برتری مدل عصبی - فازی در پیش بینی بود [۳۱].

کماسی و همکاران به پیش بینی خشکسالی با مدل ANFIS بر مبنای خوشه بندی به روش C-mean فازی در حوضه ی ليقوان چای پرداختند. نتایج حاصل از مدل سازی ها نشان داد که بهره گیری از شبکهی عصبی - فازی به خوبی توانسته الگوی سری زمانی داده ها را تشخیص دهد و به نتایج خوبی منجر گردد. همچنین خوشه بندی داده ها سبب بهبود هرچه بهتر فرآیند مدل سازی و در (m) . نتیجه افزایش کارایی مدل گردید [۷۹].

شیرمحمدی و همکاران به پیش بینی شاخص خشکسالی SPI شش ماهه در دو حوضه ی آبریز صوفی چای و قلعه چای پرداختند. نتایج نشان داد که شبکه ای با تکنیک یادگیری L. Levenberg-Maquadt انتقال تانژانت Sigmoid در لایه ی مخفی و برای یک گام به جلو، بهترین مدل شبکه ی عصبی در این تحقیق بوده است [۷۸]. همچنین بر اساس نتایج، مدلی با تابع عضویت Pi در گام زمانی یک گام روبه جلو با تعداد توابع عضویت پنج، بهترین عملکرد را داشته است. در کل نتایج این تحقیق نشان داد که شبکه ی عصبی - فازی عملکرد بهتری نسبت به شبکه ی عصبی در مدل سازی و پیش بینی خشکسالی دارد.

اژدري مقدم و همکاران خشکسالی شهر زاهدان را به کمک مدل عصبی - فازی و با استفاده از ۱۹ عدد از شاخص های اقلیمی به عنوان پارامترهای ورودی پیش بینی کردند. نتایج نشان داد که از میان همه ی شاخص های اقلیمی وارد شده در مدل ها به منظور پیش بینی خشکسالی پاییزه، شاخص های Nino^۳ و SOI^۲ مناسب ترین نتایج را ارائه دادند [۷۷].

^۱ Auto Regressive

^۲ Southern Oscillation Index

وانگ^۱ و والدس^۲ به پیش‌بینی شاخص شدت خشکسالی پالمر (PDS)^۳ در حوضه‌ی آبریز Conchos در مکزیک با استفاده از مدل تلفیقی شبکه‌ی عصبی و تبدیلات موجک پرداختند. آن‌ها با استفاده از تبدیلات موجک، سری زمانی اصلی را به دو زیر سری تجزیه کردند و سپس با استفاده از شبکه‌ی عصبی هریک از این زیر سری‌ها را به‌صورت جداگانه پیش‌بینی کردند و از روی این زیر سری‌ها، سری اصلی را تشکیل دادند. نتایج آن‌ها نشان داد که استفاده از مدل تلفیقی، باعث بهبود دقت مدل پیش‌بینی می‌شود [۱۹].

ابریشم چی و همکاران به پیش‌بینی شاخص خشکسالی مؤثر (EDI)^۴ در حوضه‌ی آبریز زاینده‌رود با استفاده از مدل تلفیقی شبکه‌ی عصبی-موجکی پرداخت. نتایج وی نشان داد که اضافه کردن تبدیلات موجک در شبکه‌ی عصبی، سبب بهبود قابل ملاحظه‌ی پیش‌بینی‌های یک، سه، شش و نه‌ماهه می‌شود [۷۶].

آداموسکی^۵ و چان^۶ به کمک مدل‌های شبکه‌ی عصبی، شبکه‌ی عصبی - موجکی و ARIMA به پیش‌بینی ماهانه‌ی سطح آب زیرزمینی در حوضه‌ی آبریز Chateauguay در Quebec کانادا پرداختند. آن‌ها نتایج پیش‌بینی سطح آب زیرزمینی توسط مدل تلفیقی را با مدل شبکه‌های عصبی مصنوعی و مدل ARIMA مقایسه نمودند. نتایج این مقایسه نشان داد که مدل تلفیقی با دقت بالاتری نسبت به دو مدل دیگر، قادر به پیش‌بینی سطح آب زیرزمینی است [۳۲].

دکا^۷ و همکاران به کمک مدل‌های شبکه‌ی عصبی و عصبی - موجکی جریان آب رودخانه‌ی

^۱ Woong

^۲ Valdes

^۳ Palmer Drought Severity Index

^۴ Effective Drought Index

^۵ Adamowski

^۶ Chan

^۷ Deka

Brahmaputral در هند را برای چهار گام زمانی مختلف پیش‌بینی کردند. نتایج آن‌ها نشان داد که شبکه

ی عصبی - موجکی پیش‌بینی‌های بهتری را نسبت به شبکه‌ی عصبی انجام می‌دهد [۳۳].

آداموسکی به پیش‌بینی شاخص خشکسالی SPI با استفاده از روش‌های شبکه عصبی، عصبی - موجکی و

رگرسیون بردار پشتیبان (SVR)^۱ در حوضه‌ی آبریز رودخانه‌ی Awash در کشور اتیوپی پرداختند. آن‌ها

پیش‌بینی‌ها برای گام‌های زمانی یک تا شش ماه جلوتر انجام دادند و برای مقایسه‌ی مدل‌ها از معیارهای R^2

، RMSE^۲ و MAE^۳ استفاده کردند. نتایج نشان داد که در همه‌ی گام‌های زمانی پیش‌بینی، دقت شبکه

ی عصبی - موجکی نسبت به دو روش دیگر بالاتر است [۳۴].

کیسی^۴ به پیش‌بینی بارش روزانه با استفاده از مدل تلفیقی شبکه‌ی عصبی-فازی و تبدیلات موجک

پرداختند. نتایج نشان داد که این مدل از عملکرد بسیار مناسبی برای داده‌های مشاهداتی، مخصوصاً برای

سری‌های زمانی که دارای بارش صفر در تابستان هستند، برخوردار است. همچنین نتایج نشان داد که مدل

شبکه‌ی عصبی-فازی-موجکی نسبت به شبکه‌ی عصبی-فازی نتایج بهتری را از خود نشان می‌دهد [۳۵].

نورانی و همکاران به مدل‌سازی بارش-رواناب با استفاده از سه روش شبکه‌ی عصبی فازی تطبیقی موجکی،

شبکه‌ی عصبی موجکی و شبکه‌ی عصبی فازی تطبیقی در حوضه‌ی ليقوان چای واقع در استان آذربایجان

شرقی پرداختند. نتایج تحقیق حاکی از آن است که مدل شبکه‌ی عصبی فازی تطبیقی موجکی نسبت به

روش‌های دیگر مورد بحث، بهترین مدل برای این حوضه است [۳۶].

^۱ Support Vector Regression

^۲ Root-Mean-Square Error

^۳ Mean Absolute Error

^۴ Kisi

موسوی و همکاران به پیش‌بینی سطح آب زیرزمینی در دو زیر حوضه‌ی آبریز در استان خراسان به کمک روش شبکه‌ی عصبی-فازی-موجکی و با گام‌های زمانی یک، دو، سه و چهار ماه جلوتر پرداختند. نتایج تحقیق آن‌ها نشان داد که اضافه کردن تبدیلات موجک، می‌تواند دقت پیش‌بینی سطح آب زیرزمینی را افزایش دهد. همچنین بر اساس تحقیق ایشان تعداد نرون‌های لایه‌ی مخفی از فرمول خاصی تبعیت نمی‌کند و باید از روش سعی و خطا به دست آید [۳۷].

هرچند استفاده از مدل ANN در مدل‌سازی پدیده‌های هیدرولوژیکی سابقه‌ای با بیش از دو دهه دارد، اما مطالعات اندکی در راستای تحلیل عدم قطعیت این مدل موجود می‌باشند. از اندک مطالعات موجود در زمینه مدیریت منابع آب می‌توان به پژوهش انجام‌شده توسط نوری و همکاران برای تحلیل عدم قطعیت مدل ANN در پیش‌بینی اکسیژن خواهی بیوشیمیایی ۵ روزه (BOD_5) اشاره نمود [۳۸].

همچنین در تحقیقی دیگر نوری و همکاران اقدام به تعیین عدم قطعیت مدل ANN در پیش‌بینی ضریب پخش طولی در رودخانه‌های طبیعی نمودند [۳۹].

دهقانی و همکاران نیز در پژوهشی اقدام به تحلیل عدم قطعیت ANN در فرایند پیش‌بینی خشکسالی هیدرولوژیکی در حوزه رودخانه کارون کردند [۴۰].

در زمینه آلودگی هوا نیز نوری و همکاران الگوریتمی برای تعیین عدم قطعیت مدل ANN در راستای پیش‌بینی غلظت مونوکسید کربن در شهر تهران ارائه نمودند [۴۱].

۴-۲ جمع‌بندی

به هر حال اگرچه مطالعات انجام‌شده در زمینه تحلیل عدم قطعیت مدل ANN اندک می‌باشند، اما الگوی استفاده‌شده در تمامی این مطالعات نیز یکسان بوده و همه آن‌ها از فرآیند کاملاً تصادفی برای تعیین الگوهای

کالیبراسیون مدل ANN استفاده نموده‌اند. این در حالی است که در استفاده از الگوهای کاملاً تصادفی برای کالیبراسیون، ممکن است اصل جامع بودن الگوهای انتخابی به‌خوبی رعایت نشود. به‌عبارتی دیگر برای دست‌یابی به یک مدل داده محور کالیبره شده داده‌های انتخابی باید جامع بوده و به‌خوبی شامل داده‌های حد پایین، حد بالا و داده‌های متوسط باشد تا مدل به‌خوبی فرآیند حاکم بر متغیر هدف را آموزش ببیند. در پژوهش حاضر هدف ارائه الگوریتمی برای انتخاب الگوهای کالیبراسیون مدل ANN است به‌نحوی که هر الگوی انتخابی جامع بوده و به‌خوبی پارامتر هدف را نمایندگی نماید.

۳. فصل سوم : مواد و روش‌ها

۳-۱ مقدمه

روش‌های زیادی در سراسر جهان جهت ارزیابی خشکسالی مورد استفاده قرار گرفته است، در این بخش به طور خلاصه به تکنیک‌های موجود در این زمینه پرداخته میشود. به این صورت که شاخص‌های خشکسالی هواشناسی را که فقط از داده‌های اقلیمی استفاده می‌نمایند توضیح داده می‌شود. در قسمت بعد به توضیح در مورد شبکه‌های عصبی مورد استفاده در این تحقیق پرداخته می‌شود.

۳-۲ شاخص‌های خشکسالی هواشناسی و تشخیص خشکسالی

برحسب نوع خشکسالی، شاخص‌های هواشناسی متعددی برای تعیین خشکسالی ارائه شده است. شاخص شدت خشکسالی پالمر^۱، شاخص ذخیره آب سطحی^۲، شاخص دهک‌ها^۳، شاخص بارش استاندارد^۴، شاخص رطوبت محصول^۵ و از جمله شاخص‌های معروف در این زمینه‌اند که در این تحقیق فقط از شاخص بارش استاندارد استفاده خواهد شد. نمایه SPI نخستین بار توسط مکی^۶ برای پایش خشکسالی در ایالت کلرادو ارائه شد [۲].

کاربرد شاخص‌های خشکسالی در خلاصه‌سازی بسیاری از پارامترهای مؤثر در خشکسالی در برنامه‌ریزی‌های منابع آب مفید است و همچنین توسط شاخص‌های خشکسالی می‌توان شدت و وسعت خشکسالی را به کمیت درآورد و ارزیابی کرد [۴۲].

^۱ Palmer Drought severity Index (PDS)

^۲ Surface Water Supply Index (SWSI)

^۳ Dexilesindex (D۱)

^۴ standardized Precipitation index (SPI)

^۵ Crop Moisture Index (CMI)

^۶ Mckee

۳-۲-۱ شاخص شدت خشکسالی پالمر (PDSI)

شاخص خشکسالی پالمر ترکیبی از بارندگی رخ داده، ذخیره رطوبتی و نیاز رطوبتی است که بر اساس محاسبه بیلان آبی معرفی شده است. در محاسبات این شاخص علاوه بر داده‌های درجه حرارت (برای محاسبه تبخیر و تعرق) و بارندگی، نیاز به داده‌های رطوبت خاک است؛ اما به جهت نبود داده‌های رطوبت خاک، به کمک مدل بیلان حجمی، داده‌های رطوبت خاک برآورد شدند. از آنجاکه شاخص شدت دوره‌های خشک پالمر بر اساس معادلات بیلان آبی با نگاهی به گذشته به صورتی ارائه شده که بنیان آن بر روابط بین عرضه و تقاضای رطوبت استوار است، لذا می‌توان اظهار داشت که مقادیر محاسبه شده برای این شاخص، یک اندازه کمی واحدی را از شدت دوره‌های خشک به دست می‌دهند. به جهت حجم بالای معادلات و محاسبات شاخص پالمر و عدم امکان ارائه همه آن‌ها در یک مقاله، گام‌های اساسی محاسبه PDSI فقط نام‌برده شده‌اند که به ترتیب شامل: محاسبات هیدرولوژیکی، محاسبه ضرایب اقلیمی، محاسبه مقادیر^۱ CAFEC (شرایط مناسب اقلیمی برای شرایط موجود)، محاسبه شاخص آنومالی^۲ رطوبت و محاسبه شدت خشکسالی است.

^۱ Climatically Appropriate For Existing Condition

^۲ Anomaly

جدول ۳-۱ مقیاس طبقه‌بندی PDSI

شاخص شدت خشکسالی	درجه خشکسالی
$PDSI \leq -4/0$	خشکسالی خیلی شدید
$-4/0 < PDSI \leq -3/0$	خشکسالی شدید
$-3/0 < PDSI \leq -2/0$	خشکسالی متوسط
$-2/0 < PDSI \leq -1/0$	خشکسالی نسبی
$-1/0 < PDSI \leq +1/0$	نزدیک به نرمال
$+1/0 < PDSI \leq +2/0$	ترسالی نسبی
$+2/0 < PDSI \leq +3/0$	ترسالی متوسط
$+3/0 < PDSI \leq +4/0$	ترسالی شدید
$+4/0 < PDSI$	ترسالی خیلی شدید

۳-۲-۲ شاخص SWSI

شاخص SWSI بر اساسی منابع آب سطحی، منابع برفی، بارندگی و ذخیره آب سدها وضعیت خشکسالی را در منطقه اعلام می‌نماید. کاربرد هم‌زمان هر یک از اجزاء مؤثر بر شاخص SWSI، امکان مقایسه مناطق مختلف را از طریق این شاخص غیرممکن می‌سازد.

الیوت^۱ در مطالعات خود به جای اجزای در نظر گرفته شده و مؤثر بر شاخص SWSI (منابع برفی و بارندگی) از سری زمانی مقادیر پیش بینی شده جریان و حجم مخزن استفاده نموده است [۴۳].

بنابراین به جای در نظر گرفتن بودجه برفی به صورت یک جزء، اثر آن به طور غیرمستقیم در سری جریان و حجم مخزن ظاهر می شود.

$$SWSI = \frac{p - 50}{12} \quad \text{رابطه ۱-۳}$$

P = احتمال محاسبه شده از روی تابع توزیع احتمال برازش داده شده به سری مجموع جریان و حجم مخزن بر حسب درصد. بر این اساسی هرگاه مقدار شاخصی به کمتر از ۱- برسد خشکسالی رخ داده است.

^۱ Elliott

جدول ۳-۲ مقیاس طبقه‌بندی SWSI

شدت ترسالی یا خشکسالی	مقدار شاخص
خیلی تر	$+3 \leq SWSI < +4$
نسبتاً تر	$+2 \leq SWSI < +3$
ترسالی کم	$+1 \leq SWSI < +2$
نزدیک به نرمال	$-1 \leq SWSI < +1$
خشکسالی کم	$-2 \leq SWSI < -1$
نسبتاً خشک	$-3 \leq SWSI < -2$
خیلی خشک	$-4 \leq SWSI < -3$

۳-۲-۳ شاخص دهک‌ها^۱

شاخص دهک‌ها به‌وسیله وبیز^۲ و ماهر^۳ در سال ۱۹۶۷ ارائه‌شده است و استفاده گسترده‌ای در استرالیا شد [۵]. این روش را جهت جلوگیری از مشکلات به‌کارگیری روش درصد از نرمال ابداع نموده‌اند. در این

^۱ Deciles

^۲ Gibbse

^۳ Maher

روش داده‌های بارندگی ثبت‌شده در یک دوره طولانی مدت به ۱۰ گروه، که هر گروه یک دهک^۱ نامیده می‌شود، تقسیم می‌شود. اولین دهک میزان بارندگی است که از ۱۰٪ پایین وقوع بارندگی تجاوز نکند، در دهک دوم میزان بارندگی از ۲۰٪ پایین بارندگی تجاوز نمی‌کند،...، دهک دهم بیشترین مقدار بارندگی در داده‌های موجود را مشخص می‌کند. محاسبه این روش بسیار ساده است، اما عیب اساسی این روش در این است که به داده‌های طولانی مدت بارندگی برای محاسبه دقیق دهک‌ها نیاز است [۴۴]. جدول ۳-۳ محدوده‌های مختلف شاخص دهک‌ها را نشان می‌دهد.

^۱ Deciles

جدول ۳-۳ مقیاس طبقه‌بندی شاخص دهک‌ها

دهک	مفهوم اقلیمی
۲-۱ پایین‌ترین ۲۰٪	خشکسالی شدید
۴-۳ بعد از ۲۰٪ پایین‌ترین	خشکسالی ضعیف
۸-۷ ۲۰٪ وسطی	نرمال
۸-۷ ۲۰٪ بالایی	مرطوب
۱۰-۹ بالا‌ترین ۲۰٪	خیلی مرطوب

۳-۲-۴ شاخص رطوبتی گیاه CMI^۱

شاخص CMI در سال ۱۹۶۸ به وسیله پالمر پایه گذاری شده است. مفهوم این شاخص بر اساس میانگین دما و مجموع بارش هر هفته در یک تقسیم اقلیمی نسبت به مقادیر CMI هفته قبل استوار است و با توجه به زمان و مکان دارای ضرایب وزنی است. فاکتورهای اساسی مورد استفاده در این شاخص دما و بارش است و در مقیاس زمانی هفتگی به کار می رود. شاخص CMI که یکی از شاخص های مهم برای محاسبه شرایط رطوبتی محصول است، منعکس کننده مقادیر رطوبت در دوره های زمانی کوتاه (چند هفته) و در مورد محصولات زراعی عمده است. اساس روش شاخصی (CMI) بر پایه محاسبات (PDSI) بود که این شاخص نیز توسط پالمر پایه ریزی شده است. تفاوت اساسی این دو شاخص در این است که شاخص CMI نمی تواند به بررسی درازمدت شرایط رطوبتی بپردازد و در صورت استفاده از آن برای دوره طولانی، اطلاعات به دست آمده از این شاخص فاقد اعتبار خواهد بود توصیف مقادیر این شاخص طبق جدول ۳-۴ است.

^۱ Crop Moisture Index

جدول ۳-۴ مقیاس طبقه‌بندی شاخص رطوبتی گیاه

حدود شاخص CMI	توصیف
$CMI < -3$	خیلی زیاد خشک
$-2 < CMI < -2,9$	زیاد خشک
$-1 < CMI < -1,9$	تقریباً خشک
$-0,9 < CMI < 0,9$	خیلی کم خشک تا کم مرطوب
$1 < CMI < 1,5$	تقریباً مرطوب
$-1 < CMI < -1,5$	مرطوب
$CMI > 3$	خیلی مرطوب

۳-۲-۵ شاخص درصد از نرمال (PN)

شاخص درصد از نرمال (PN) یکی از ساده‌ترین معیارهای بارندگی برای تحلیل خشکسالی یک محل است. این شاخص در سال ۱۹۹۴ توسط ویلیک^۱ و همکارانش ارائه شد و مفهوم اساسی آن تقسیم بارش واقعی بر بارش نرمال (میانگین ۳۰ ساله) و ضرب آن در عدد ۱۰۰ است [۴۵].

تنها فاکتور موردنیاز جهت محاسبه آن بارش است و همچنین در مقیاس زمانی ماهیانه به‌کاربرده می‌شود.

^۱ Willeke

تحلیل‌هایی که با استفاده از شاخص در صد از نرمال بارندگی انجام می‌گیرند، برای بررسی خشکسالی یا ترسالی در یک منطقه یا فصل معین بسیار مناسب است. این شاخص برای استفاده در مقیاس‌های زمانی ماهانه و سالانه قابل استفاده است. از آنجاکه داده‌های بارندگی معمولاً از توزیع نرمال پیروی نمی‌کنند و بین میانگین و میانه اختلاف وجود دارد استفاده از این روش باعث ایجاد خطا می‌شود، که این موضوع یکی از معایب این روش است. هرچند جامعیت این روش و آسان بودن محاسبه آن باعث شده است تا محققان بسیاری از این روش استفاده نمایند. مفهوم اقلیمی شاخص در صد نرمال طبق جدول ۳-۵ است [۴۴].

جدول ۳-۵ مقیاس طبقه‌بندی شاخص درصد نرمال

مفهوم اقلیمی	حدود شاخص PN
خشکسالی ضعیف	$70 < PN < 80$
خشکسالی متوسط	$55 < PN < 70$
خشکسالی شدید	$40 < PN < 55$
خشکسالی خیلی شدید	$PN < 40$

۳-۲-۶ شاخص SPI

درک اینکه بارندگی تأثیرهای مختلفی بر منابع آب مانند آب زیرزمینی، ذخایر آب سطحی و برف دارد، منجر به تدوین و ارائه‌ی شاخص SPI گردید. برای محاسبه این شاخص، ابتدا با برازش توزیع گاما بر داده‌های بارندگی ماهیانه یا مجموع بارندگی در هر بازه‌ی زمانی دلخواه، تابع احتمال تجمعی آن را محاسبه نموده سپس با انتقال احتمال تجمعی به‌دست‌آمده به توزیع تجمعی نرمال استاندارد شده، مقادیر شاخص

SPI محاسبه می‌شود [۵۳]–[۴۶], [۲].

در حال حاضر شاخص SPI به‌طور گسترده‌ای در امور تحقیقاتی و اجرایی در سراسر جهان جهت پایش خشکسالی استفاده می‌شود. این شاخص به علت سادگی محاسبات، استفاده از داده‌های قابل‌دسترس بارندگی، قابلیت محاسبه برای هر مقیاس زمانی دلخواه و قابلیت بسیار زیاد در مقایسه‌ی مکانی نتایج، به‌عنوان مناسب‌ترین شاخص برای تحلیل خشکسالی به‌ویژه تحلیل‌های مکانی شناخته می‌شود، [۵۰], [۴۹], [۵۴], [۵۲].

مهم‌ترین مزیت شاخص SPI، قابلیت محاسبه در مقیاس‌های زمانی مختلف است که باعث می‌شود. این شاخص بتواند اثرات دوره‌های کوتاه‌مدت ذخایر آب (ازجمله رطوبت خاک که در تولیدات کشاورزی نقش مهمی دارد) و اثرات دوره‌های طولانی‌مدت منابع آب (ازجمله ذخایر آب زیرزمینی، سطح آب مخازن و جریان رودخانه‌ای) را پایش نماید. کمبود بارش در مقیاس زمانی کوتاه‌مدت، سبب ایجاد نوسان در رطوبت خاک و دوره‌های طولانی‌تر باعث تغییرات در منابع آب زیرزمینی و سطح آب مخازن می‌شود [۵۵], [۴۹].

در محاسبه‌ی شاخص SPI طول دوره‌ی آماری و نوع توزیع فراوانی برآزش یافته بر مقادیر داده‌های بارندگی، از اهمیت به سزایی برخوردارند. زیرا عدم انتخاب دوره‌های طولانی‌مدت و همچنین نامناسب بودن توزیع گاما برای داده‌های بارندگی، می‌تواند منجر به برآورد مقادیر نادرستی از شاخصی SPI شود [۴۹].

علاوه بر این، متفاوت بودن طول دوره‌های زمانی داده‌های بارندگی مورد استفاده برای استخراج مقادیر شاخص SPI می‌تواند منجر به نتایج متفاوتی در طبقه‌های مختلف خشکسالی شود. مک کی و همکاران حداقل سی سال آماری را برای محاسبه‌ی شاخص SPI لازم می‌دانند [۲].

ویو و همکاران تأثیر طول دوره‌های مختلف بارندگی بر مقادیر شاخص SPI را با استفاده از معیارهای ضریب همبستگی، شاخص توافق و میزان ثبات دوره‌های خشک و مرطوب مورد بررسی قرار دادند و بر متفاوت بودن

نتایج در طول دوره‌های مختلف تأکید نمودند [۱۵]. زیرا طول دوره، تأثیر مستقیمی بر مقادیر پارامترهای شکل و مقیاس تابع احتمالی گاما دارد. تابع توزیع احتمال ابزاری مؤثر و مفید برای توصیف جامع هر متغیر هواشناسی یا هیدرولوژیکی است [۵۲]. در بررسی‌های هیدرولوژیکی سعی می‌شود بر داده‌هایی که به‌صورت تجربی اندازه‌گیری و ثبت شده‌اند. توابع احتمالاتی مناسبی برازش داده شود و بهترین تابعی که با داده‌ها مطابقت داشته باشد به‌عنوان تابع توزیع احتمال برگزیده شود تا از روی آن به ازای هر احتمال مشخص مقدار متغیر موردنظر به دست آید. برازش توابع مختلف توزیع فراوانی بر داده‌های بارندگی، همانند طول دوره‌های آماری، می‌تواند سبب برآورد مقادیر متفاوتی از شاخص SPI شود (۱۶). توابع توزیع گوناگونی برای برازش بر داده‌های بارندگی مورداستفاده قرار گرفته‌اند که برخی از آن‌ها عبارت‌اند از: توزیع گاما [۲] [۴۹]، توزیع پیرسون تیپ سه [۴۷]، توزیع پواسون-گاما^۱ [۵۶]، توزیع ویبول، توزیع لوگ نرمال [۴۸] [۵۷]، توابع توزیع حد نهایی^۲ و توزیع نمایی^۳ [۵۳]، توزیع نمایی ترکیبی^۴ [۵۸]. لویید-هوگوس و ساندرس [۴۸] ضمن تحقیقات خود بیان داشتند که در مناطق خشک و نیمه‌خشک که توزیع بارندگی به‌طور طبیعی فصلی است و نباریدن باران در برخی از فصل‌ها طبیعی است، در بعضی از فصل‌ها در سری زمانی تعداد بسیار زیادی صفر وجود خواهد داشت. در چنین مناطقی، مقادیر محاسبه‌شده SPI در مقیاس‌های زمانی کوتاه‌مدت به خاطر چولگی زیاد داده‌های بارندگی ممکن است به‌صورت نرمال توزیع نشده باشد و توزیع گاما نیز نتواند به‌خوبی بر داده‌های بارندگی برازش یابد. بنابراین، این موضوع می‌تواند سبب بروز خطاهای فاحش هنگام تعیین تابع توزیع داده‌ها در مناطق خشک در نمونه‌های کوچک گردد. ویسک و هاس [۵۲] پیروی مقدار بارندگی روزانه در هر سال و فصل‌های مختلف از توزیع گاما در ۹۰ ایستگاه از اروپا را بر اساس

^۱ Poisson-gamma

^۲ Extreme Value

^۳ Exponential

^۴ Mixed exponential

آزمون‌های کلموگروف-اسمیرنوف^۱ (K-S) و K-S تصحیح‌شده، مورد بررسی قرار دادند. آن‌ها بر متفاوت بودن نتایج حاصل دو آزمون تأکید و همچنین بیان داشتند که مقدار بارندگی زمستانه در بیش از ۴۰ درصد ایستگاه‌های مورد بررسی با توزیع گامای دو پارامتری مطابقت ندارد.

هر یک از شاخص‌های ارائه‌شده دارای مزایا و معایب خاص خودشان می‌باشند. مزایای استفاده از شاخص بارش استاندارد عبارت‌اند از:

- این شاخص فقط از اطلاعات داده‌های بارشی استفاده می‌کند، بنابراین در صورتی که سایر داده‌های هیدرولوژی در دسترس نباشد، می‌توان از آن استفاده کرد.
- تحت تأثیر توپوگرافی منطقه نیست.
- شاخصی استاندارد است، به این معنی که فراوانی پدیده‌ها در هر مقیاس زمانی و مکانی، مقداری ثابت است. نکته دیگر اینکه این شاخص یکی از مناسب‌ترین و کاربردی‌ترین شاخص‌های پیشنهادشده جهت مطالعه خشکسالی است که امروزه در سطح گسترده‌ای در سطح جهان مورد استفاده قرار می‌گیرد و مورد پذیرش بسیاری از جوامع علمی قرار گرفته است. دلیل استفاده از این شاخص نیز به همین خاطر است. در اکثر شاخص‌های تعیین و تشخیص خشکسالی آورده شده است. در جدول ۳-۶ خلاصه‌ای از اکثر شاخص‌های خشکسالی آورده شده است.

^۱ Kolmogorov-Smirnov

جدول ۳-۶ خلاصه کلی شاخص ها

نام شاخص	علامت اختصاری	ارائه دهنده	سال ارائه	مقیاس زمانی	فاکتورهای مؤثر
شاخص شدت خشکسالی پالمر	PDSI	Palmer	۱۹۶۵	ماهانه	دما-بارش-رواناب-تبخیر و تعرق- رطوبت خاک
شاخص ذخیره آب سطحی	SWSI	Shafer Decman	۱۹۸۲	ماهانه	بارش و پوشش برف
شاخص درصد از نرمال	PN	Willeke	۱۹۹۴	ماهانه، فصلی، سالانه	بارش
شاخص دهکها	Deciles	Gibbs Maher	۱۹۶۷	ماهانه، فصلی، سالانه	بارش
شاخص بارش/استاندارد	SPI	Mckee	۱۹۹۳	۱-۳-۶-۱۲ - ۲۴-۴۸ ماهه	بارش
شاخص رطوبت محصول	CMI	Palmer	۱۹۶۸	هفتگی	بارش و دما
شاخص خشکسالی رطوبت خاک	SMDI	Hollinher	۱۹۹۴	فصلی	رطوبت خاک
شاخص خشکسالی محصول ویژه	CSDI	Meyer	۱۹۹۳	فصلی	تبخیر
شاخص بارش کلی یا سرا سری	RI	Gommes Petrassi	۱۹۹۴	قرن و سالانه	بارش
شاخص نابهنجاری و بی نظمی بارش	RDI	Rooy	۱۹۶۵	ماهانه و سالیانه	بارش
شاخص خشکسالی حیاتی	RDI	Weghorst	۱۹۹۶	ماهانه	سطح آب رودخانه - بارش برف - جریانات سطحی - ذخایر آب و دما
شاخص بارش مؤثر	EDI	Wilhite Byum	۱۹۹۹	سالانه و روزانه	بارش روزانه

۳-۳ منطقه مورد مطالعه

برای ایجاد مدل‌های پیش‌بینی بارش، نیاز به تعیین و معرفی منطقه‌ای جهت انتخاب داده‌ها است. در این تحقیق سعی بر این بوده است که بیشتر آب‌وهوای ایران شامل این تحقیق بوده باشد که برای رسیدن به این هدف ۵ ایستگاه هواشناسی در شهرهای مشهد، بندرعباس، شاهرود، زاهدان و تبریز انتخاب شد. خصوصیات مختصری در مورد هر کدام از این شهرها در ادامه خواهد آمد.

۳-۳-۱ خصوصیات منطقه‌ای مشهد

مشهد کلان‌شهری در شمال شرقی ایران و مرکز استان خراسان رضوی است. شهر مشهد در حوزه رودخانه کشف‌رود و در دشت مشهد بین کوه‌های هزارمسجد و بینالود گسترده شده است. بیشینه ارتفاع شهر مشهد ۱۱۵۰ متر و کمینه آن ۹۵۰ متر است. شهر مشهد دارای آب‌وهوای متغیر، اما معتدل و متمایل به سرد و خشک است و از تابستان‌های گرم و خشک و زمستان‌های سرد و مرطوب برخوردار است. بیشینه درجه حرارت در تابستان‌ها ۴۳ درجه بالای صفر و کمینه آن در زمستان‌ها ۲۳ درجه زیر صفر است.

۳-۳-۲ خصوصیات منطقه‌ای بندرعباس

شهر بندرعباس که در جنوب استان هرمزگان واقع شده است از شمال به ارتفاعات و کوه‌ها و از جنوب به دریا منتهی می‌شود؛ بنابراین شیب عمومی شهر در راستای شمال به جنوب است.

آب‌وهوای این شهر گرم و مرطوب است. به‌طور کلی در بندرعباس از نیمه آبان تا نیمه فروردین دارای آب‌وهوای مطبوعی است. ماه‌های اردیبهشت و خرداد هوا خشک، ماه‌های تیر تا مهر دارای آب‌وهوای مرطوب است. دمای هوای شهر بندرعباس در گرم‌ترین روزها به ۵۲ درجه سانتی‌گراد و در سردترین روزها به ۲ درجه

سانتی‌گراد می‌رسد. میانگین بارش بندرعباس در حدود ۲۰۰ میلی‌متر است.

۳-۳-۳ خصوصیات منطقه‌ای شاهرود

شاهرود، در حدفاصل دو نوع آب‌وهوای مرطوب و پرباران در شمال و کویری، در جنوب جای گرفته که آب‌وهوایی معتدل و مطلوب برای این شهر فراهم کرده است. در اکثر ماه‌های سال آب‌وهوا معتدل سرد است. شاهرود یکی از شهرهای خوش آب‌وهوای ایران است. قسمت مرکزی و نواحی شرقی شاهرود دارای آب‌وهوای معتدل و نواحی شمالی آن کوهستانی با آب‌وهوایی سرد و مرطوب است. قسمت جنوبی که در مجاورت کویر واقع شده آب‌وهوای نسبتاً گرم است. متوسط درجه حرارت سالانه در این شهر ۱۴ درجه سانتی‌گراد و میانگین بارندگی سالانه کمتر از ۱۵۰ میلی‌متر است. شاهرود به علت واقع شدن در دامنه کوه از لحاظ آب‌های سطحی به‌صورت رودخانه‌های دائمی، سهمی نداشته و رودخانه‌های سیلابی و فصلی در این شهر جاری است.

۳-۳-۴ خصوصیات منطقه‌ای زاهدان

زاهدان یکی از کلان‌شهرهای ایران و مرکز استان سیستان و بلوچستان و در منطقه جنوب شرق ایران درد محدوده سرحد بلوچستان قرار دارد. آب‌وهوای زاهدان در بیش‌تر روزهای سال گرم و معتدل است. تنها در شب‌های تابستان آب‌وهوای این شهر رو به سردی می‌گراید. آب آشامیدنی زاهدان لوله‌کشی بوده و از طریق انتقال آب چاه نیمه‌های سیستان و چاه‌های نیمه عمیق پیرامون خود شهر تأمین می‌گردد. آب‌وهوای زاهدان در بیش‌تر روزهای سال گرم و خشک بوده و معمولاً در این شهر برف نمی‌بارد. زاهدان در فصل تابستان روزهایی بسیار گرم و شب‌هایی با حرارت نسبی کم را تجربه می‌کند.

در طول سال، بادهایی با جهت جنوب غربی-شمال شرقی این شهر را تحت تأثیر خود قرار می‌دهند که در

این میان، بادهای سیستان که ۱۲۰ روزه در زاهدان می‌وزند، از شدت گرمای هوای این شهر می‌کاهند.

۳-۳-۵ خصوصیات منطقه‌ای تبریز

تبریز در غرب استان آذربایجان شرقی و در منتهی‌الیه مشرق و جنوب شرق جلگه تبریز قرار گرفته است. این شهر از سمت شمال به کوه‌های پکه‌چین و عون بن علی، از سمت شمال شرق به کوه‌های گوزنی و باباباگی، از سمت شرق به گردنه پایان و از سمت جنوب به دامنه‌های رشته‌کوه سهند محدود شده است. آب‌وهوای تبریز استپی خشک با تابستان‌های گرم و خشک و زمستان‌های سرد است. سرمای زمستانی، تأثیر پذیرفته از ارتفاع بالا و توپوگرافی کوهستانی منطقه است. آب‌وهوای این شهر در تابستان‌ها خشک و گرم است؛ اگرچه حرارت به دلیل نزدیکی به کوه سهند و وجود باغ‌های زیادی در پیرامون شهر تعدیل می‌گردد.

میانگین دمای تبریز در تیرماه ۲۵/۴ درجه سانتی‌گراد، در دی‌ماه ۲/۵- درجه سانتی‌گراد، در فروردین‌ماه ۱۰/۵ درجه سانتی‌گراد و در مهرماه ۱۴/۱ درجه سانتی‌گراد و میانگین سالانه دما ۱۱/۹ درجه سانتی‌گراد است. میانگین بارندگی سالیانه تبریز حدود ۲۹۰ میلی‌متر در سال است. معمولاً در طول فصل تابستان، میزان بارندگی بسیار ناچیز بوده و به‌ندرت بارش رخ می‌دهد.

داده‌های استفاده شده در این تحقیق به صورت بارش ماهیانه هر ایستگاه بوده و سپس به SPI تبدیل شده است.

پارامترهای آماری، حداقل مقدار، حداکثر مقدار، میانگین، انحراف معیار، واریانس، چولگی، کشیدگی برای مجموعه داده‌های ورودی در جدول ۳-۷ نمایش داده شده است.

جدول ۳-۷ مجموعه داده‌های بارش ورودی حوضه‌ها

Kurtosis	Skewness	Variance (mm ^۲)	Std. Deviatoin (mm)	Mean (mm)	Maximum (mm)	تعداد داده‌ها	نام شهر
۲,۷۰۲	۱,۶۰۷	۶۲۷,۶۴۵	۲۵,۰۵۲۹	۲۰,۶۲۹	۱۳۲	۷۶۸	مشهد
۵,۳۱۹	۲,۰۴۲	۲۵۰,۲۹۵	۱۵,۸۲۰۷	۱۲,۶۰۸	۱۰۲,۷	۷۶۸	شاهرود
۲,۴۸۱	۱,۴۴۹	۵۴۳,۱۳۵	۲۳,۳۰۵۳	۲۳,۶۳۲	۱۲۸,۴	۷۶۸	تبریز
۵۵۱,۱۰۸	۲۱,۷۷۹	۱۲۲۹,۸۸۵	۳۵,۰۶۹۷	۸,۴۳۹	۹۰۲	۷۶۸	زاهدان
۱۲,۶۷۳	۳,۳۵۷	۱۱۵۹,۱۰۵	۳۴,۰۴۵۶	۱۴,۵۱۴	۲۶۳	۶۹۶	بندرعباس

۳-۴ توسعه سری SPI

برای محاسبه SPI نیاز به تابع توزیع احتمال برای مجموعه ماه‌های جمع شده (۱,۳,۶,۱۲,۲۴) است. تابع چگالی احتمال سپس به یک شاخص استاندارد تبدیل می‌شود که مقادیر آن طبقه‌بندی خشکسالی را مشخص می‌کند که برای هر مکان و زمان قابل استفاده است [۵۹].

SPI تنها زمانی می‌تواند محاسبه شود که به اندازه کافی طولانی (حداقل ۳۰ سال) و سری زمانی داده‌های بارش ماهانه موجود باشد [۵۹]. در بیشتر موارد، توزیع احتمال که بهترین داده‌های بارش باران را مدل می‌کند، توزیع گاما است [۵۹].

تابع احتمال چگالی برای توزیع گاما به صورت زیر بیان می‌شود: [۵۹]

برای $x > 0$:

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \quad \text{رابطه ۲-۳}$$

$\alpha > 0$ پارامتر شکل، $\beta > 0$ پارامتر مقیاس و $x > 0$ مقدار بارش است.

$\Gamma(\alpha)$: ارزش انجام شده توسط تابع ریاضی استاندارد شناخته شده به عنوان تابع گاما است، که توسط انتگرال تعریف شده است:

$$\Gamma(a) = \int_0^\infty x^{a-1} e^{-x} dx \quad \text{رابطه ۳-۳}$$

به طور کلی، تابع گاما به صورت عددی ارزیابی می شود و یا با استفاده از مقادیر جدول با استفاده از مقدار گرفته شده توسط پارامتر α .

به منظور مدل سازی داده های مشاهده شده با تابع چگالی توزیع گاما، لازم است که پارامترهای α و β به طور مناسب برآورد شود. برای محاسبه این دو پارامتر روش های مختلف پیشنهاد شده است. به عنوان مثال تقریب تام^۱ (۱۹۵۸) برای این دو پارامتر پیشنهاد می دهد:

$$\alpha = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \quad \text{رابطه ۴-۳}$$

^۱ Thom

$$\beta = \frac{\bar{x}}{\alpha}$$

رابطه ۵-۳

$$A = \sum_{i=1}^n \ln(x_i)$$

رابطه ۶-۳

برآورد پارامترها می‌تواند با استفاده از رویکرد تعاملی پیشنهاد شده در Wilks (۱۹۹۵) بهبود یابد. پس از برآورد ضرایب α و β ، تابع $g(x)$ با توجه به x بدست می‌آید.

پس از برآورد ضرایب α و β چگالی تابع احتمالی $g(x)$ با توجه به x بدست می‌آید و یک عبارت برای تابع احتمال $G(x)$ بدست می‌آید که مقدار مشخصی از بارش برای یک ماه مشخص شده و برای یک مقیاس زمان خاص است [۵۹].

$$G(x) = \int_0^x g(x) dx = \frac{1}{\beta \Gamma(\alpha)} = \int_0^x x^{\alpha-1} e^{-x/\beta} dx \quad \text{رابطه ۷-۳}$$

تابع گاما در $x = 0$ تعریف نمی‌شود و از آنجا که ممکن است هیچ بارشی وجود نداشته باشد، احتمال تجمعی بدین صورت بدست می‌آید: [۵۹]

$$H(x) = q + (1-q)G(x) \quad \text{رابطه ۸-۳}$$

جایی که q احتمال بارش صفر باشد تابع $H(x)$ تابع احتمال تجمعی بارش است. احتمال تجمعی پس از آن به یک توزیع استاندارد شده با میانگین صفر و واریانس تبدیل شده و که از آن شاخص SPI بدست می‌آید.

با این وجود، اگر تعداد زیادی نقطه در شبکه برای محاسبه SPI وجود داشته باشد رویکرد فوق نه عملی است و نه عددی ساده برای استفاده است بدست می‌آید. در این مورد یک روش جایگزین توسط ادواردز و مک کی^۱ [۴۶] با استفاده از تکنیک تبدیل تقریبی توسعه یافته که توسط ابرامویچ و استوگن^۲ توصیف شده است، احتمال تجمعی را به یک متغیر استاندارد Z تبدیل می‌کند. SPI به صورت زیر تعریف می‌گردد: [۵۹]

$$\text{رابطه ۹-۳} \quad 0 < H(x) < 0.5 \quad \text{برای} \quad Z = SPI = -\left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3}\right)$$

$$\text{رابطه ۱۰-۳} \quad 0.5 < H(x) < 1 \quad \text{برای} \quad Z = SPI = +\left(t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3}\right)$$

که t برابر است با :

$$\text{رابطه ۱۱-۳} \quad 0 < H(x) < 0.5 \quad \text{برای} \quad t = \sqrt{\ln \left[\frac{1}{(H(x))^2} \right]},$$

$$\text{رابطه ۱۲-۳} \quad 0.5 < H(x) < 1 \quad \text{برای} \quad t = \sqrt{\ln \left[\frac{1}{1 - (H(x))^2} \right]},$$

که در آن x مقدار بارش است، H (x) احتمال تجمعی بارش مشاهده شده است و c_۰، c_۱، c_۲، d_۰، d_۱، d_۲ ثابت با مقادیر زیر است:

$$c_0 = 2,515517 \quad c_1 = 0,802853 \quad c_2 = 0,010328$$

$$d_0 = 1,432788 \quad d_1 = 0,189269 \quad d_2 = 0,001308$$

^۱ Edwards and McKee

^۲ Abramowitz and Stegun

جدول ۳-۸ مقیاس طبقه‌بندی شاخص SPI

مقادیر شاخص SPI	طبقات خشکسالی
$SPI > 2$	ترسالی خیلی شدید
$1/5 < SPI < 2$	ترسالی شدید
$1 < SPI < 1/5$	ترسالی متوسط
$0/5 < SPI < 1$	ترسالی ملایم
$-0/5 < SPI < 0/5$	نرمال
$-1 < SPI < -0/5$	خشکسالی ملایم
$-1/5 < SPI < 1$	خشکسالی متوسط
$-2 < SPI < -1/5$	خشکسالی شدید
$SPI < -2$	خشکسالی خیلی شدید

۳-۵ مدل‌های پیش‌بینی برای شبکه‌های عصبی

در این تحقیق از دو روش ANN و ANFIS برای پیش‌بینی مدل‌های پیش‌بینی استفاده شده است که هر کدام به اختصار توضیح داده شده است.

۳-۵-۱ شبکه عصبی مصنوعی

نوع اولی که در روش پیش‌بینی SPI که در این تحقیق مورد بررسی قرار می‌گیرد، شبکه‌های عصبی مصنوعی (ANNs) است. شبکه‌های عصبی مصنوعی به‌طور فزاینده‌ای تبدیل به ابزاری محبوب برای مدل‌سازی سری‌های زمانی است و کاربرد گسترده‌ای در پیش‌بینی خشکسالی برای هر دو پارامتر SPI و PDSI دارد [۶۲]–[۶۰], [۳۰], [۲۳], [۲۱].

مدل‌های تصادفی مانند ARIMA و MLR در مدل‌سازی و پیش‌بینی داده‌های سری زمانی، زمانی مؤثر هستند که خطی باشند. این مدل‌های تصادفی اساساً مدل‌های خطی هستند که فرض می‌کنند داده‌های مورد بحث ثابت هستند. آن‌ها توانایی محدودی برای ضبط غیرمستقیم و غیرخطی در داده‌ها دارند. بنابراین، هنگامی که داده‌های غیرخطی نقش مهمی در پیش‌بینی دارد، باید مدل‌های جایگزین را مدنظر قرار گیرد [۲۱]. داده‌های غیرخطی نقش مهمی در پیش‌بینی اکثر داده‌های هیدرولوژیکی، از جمله خشکسالی دارد. به‌عنوان یک جایگزین، ANN ها برای پیش‌بینی دوره‌های هیدرولوژیکی، از جمله خشکسالی استفاده شده‌اند. شبکه عصبی مصنوعی یک سامانه‌پردازشی داده‌ها است که از مغز انسان ایده گرفته و پردازش داده‌ها را به عهده‌ی پردازنده‌های کوچک و بسیار زیادی سپرده که به‌صورت شبکه‌ای به‌هم‌پیوسته و موازی با یکدیگر رفتار می‌کنند تا یک مسئله را حل نمایند. در این شبکه‌ها به کمک دانش برنامه‌نویسی، ساختار داده‌ای طراحی می‌شود که می‌تواند همانند نورون عمل کند. که به این ساختار داده نورون گفته می‌شود. بعد با ایجاد شبکه‌ای بین این نورون‌ها و اعمال یک الگوریتم آموزشی به آن، شبکه را آموزش می‌دهند.

به دلیل سادگی و راحتی کار اغلب از پرسپترون چندلایه در پیش‌بینی هیدرولوژیکی استفاده می‌شود. پرسپترون‌ها شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. لایه پنهان حاوی عناصر

پردازش است که لایه‌های ورودی و خروجی را به هم مرتبط می‌سازد [۱۹].

در این حافظه یا شبکه عصبی نورون‌ها دارای دو حالت فعالی (روشن یا ۱) و غیرفعال (خاموشی یا ۰) اند و هر یال (سیناپس یا ارتباط بین گره‌ها) دارای یک وزن است. یال‌های با وزن مثبت، موجب تحریک یا فعالی کردن گره غیرفعال بعدی می‌شوند و یال‌های با وزن منفی، گره متصل بعدی را غیرفعال یا مهار (در صورتی که فعالی بوده باشد) می‌کنند.

شبکه‌های عصبی با توانایی قابل توجه خود در استنتاج نتایج از داده‌های پیچیده می‌توانند در استخراج الگوها و شناسایی گرایش‌های مختلفی که برای انسان‌ها و کامپیوتر شناسایی آن‌ها بسیار دشوار است استفاده شوند.

مزایای شبکه‌های عصبی مصنوعی

از مزایای شبکه‌های عصبی می‌توان موارد زیر را نام برد:

۱. یادگیری تطبیقی: توانایی یادگیری اینکه چگونه وظایف خود را بر اساس اطلاعات داده‌شده به آن و یا تجارب اولیه انجام دهد در واقع اصلاح شبکه را گویند.
۲. خودسازمان‌دهی: یک شبکه عصبی مصنوعی به صورت خودکار سازمان‌دهی و ارائه داده‌هایی که در طول آموزش دریافت کرده را انجام دهد. نورون‌ها باقاعده یادگیری سازگار شده و پاسخ به ورودی تغییر می‌یابد.
۳. عملگرهای بی‌درنگ: محاسبات در شبکه عصبی مصنوعی می‌تواند به صورت موازی و به وسیله سخت‌افزارهای مخصوصی که طراحی و ساخت آن برای دریافت نتایج بهینه قابلیت‌های شبکه عصبی مصنوعی است انجام شود.
۴. تحمل خطا: با ایجاد خرابی در شبکه مقداری از کارایی کاهش می‌یابد ولی برخی امکانات آن با وجود

مشکلات بزرگ همچنان حفظ می‌شود.

۵. دسته‌بندی: شبکه‌های عصبی قادر به دسته‌بندی ورودی‌ها برای دریافت خروجی مناسب می‌باشند.

۶. تعمیم دهی: این خاصیت شبکه را قادر می‌سازد تا تنها با برخورد با تعداد محدودی نمونه، یک قانون کلی از آن را به دست آورده، نتایج این آموخته‌ها را به موارد مشاهده از قبل نیز تعمیم دهد. توانایی که در صورت نبود آن سامانه باید بی‌نهایت واقعیت‌ها و روابط را به خاطر بسپارد.

تقسیم‌بندی شبکه‌های عصبی

بر مبنای روش آموزشی به چهار دسته تقسیم می‌شوند:

۱. وزن ثابت: آموزشی در کار نیست و مقادیر وزن‌ها به هنگام نمی‌شود. کاربرد بهینه‌سازی اطلاعات (کاهش

حجم، تفکیک‌پذیری و فشرده‌سازی) و حافظه‌های تناظری

۲. آموزش بدون سرپرست: وزن‌ها فقط بر اساس ورودی‌ها اصلاح می‌شوند و خروجی مطلوب وجود ندارد تا با مقایسه خروجی شبکه با آن و تعیین مقدار خطا وزن‌ها اصلاح شود. وزن‌ها فقط بر اساس اطلاعات الگوهای ورودی به هنگام می‌شوند. هدف استخراج مشخصه‌های الگوهای ورودی بر اساس راهبرد خوشه یابی و یا دسته‌بندی و تشخیص شباهت‌ها (تشکیل گروه‌هایی با الگوی مشابه) است، بدون اینکه خروجی یا کلاس‌های متناظر با الگوهای ورودی از قبل مشخص باشد. این یادگیری معمولاً بر پایه شیوه برترین هم‌خوانی انجام می‌گیرد. شبکه بدون سرپرست وزن‌های خود را بر پایه خروجی حاصل‌شده از ورودی تغییر می‌دهد تا در برخورد بعدی پاسخ مناسبی را برای این ورودی داشته باشد. در نتیجه شبکه یاد می‌گیرد چگونه به ورودی پاسخ بدهد. اصولاً هدف این است که با تکنیک نورون غالب نورونی که بیشترین تحریک آغازین را دارد برگزیده شود. بنابراین در شبکه‌های بدون سرپرست یافتن نورون غالب یکی از مهم‌ترین کارها است.

۳. آموزش با سرپرست: به ازای هر دسته از الگوهای ورودی خروجی‌های متناظر نیز به شبکه نشان داده می‌شود و تغییر وزن‌ها تا موقعی صورت می‌گیرد که اختلاف خروجی شبکه به ازای الگوهای آموزشی از خروجی‌های مطلوب در حد خطای قابل قبولی باشد. در این روش‌ها یا از خروجی‌ها به وزن‌ها ارتباط وجود دارد یا خطا به صورت پس انتشار از لایه خروجی به ورودی توزیع شده است و وزن‌ها اصلاح می‌شوند. هدف طرح شبکه‌ای است که ابتدا با استفاده از داده‌های آموزشی موجود، آموزش ببیند و سپس با ارائه بردار ورودی به شبکه که ممکن است شبکه آن را قبلاً فراگرفته یا نگرفته باشد کلاس آن را تشخیص دهد. چنین شبکه‌ای به طور گسترده برای کارهای تشخیص الگو به کار گرفته می‌شود.

۴. آموزش تقویتی: کیفیت عملکرد سامانه به صورت گام به گام نسبت به زمان بهبود می‌یابد. الگوهای آموزشی وجود ندارد اما با استفاده از سیگنالی به نام نقاد بیانی از خوب و یا بد بودن رفتار سامانه به دست می‌آید (حالتی بین یادگیری با سرپرست و بدون سرپرست).

معایب شبکه‌های عصبی

باوجود برتری‌هایی که شبکه‌های عصبی نسبت به سامانه‌های مرسوم دارند، معایبی نیز دارند که پژوهشگران این رشته تلاش دارند که آن‌ها را به حداقل برسانند، ازجمله:

- قواعد یا دستورات مشخصی برای طراحی شبکه جهت یک کاربرد اختیاری وجود ندارد.
- در مورد مسائل مدل‌سازی، صرفاً نمی‌توان با استفاده از شبکه عصبی به فیزیک مسئله پی برد. به عبارت دیگر مرتبط ساختن پارامترها یا ساختار شبکه به پارامترهای فرایند معمولاً غیرممکن است.
- دقت نتایج بستگی زیادی به اندازه مجموعه آموزش دارد.
- آموزش شبکه ممکن است مشکل و یا حتی غیرممکن باشد.

- پیش‌بینی عملکرد آینده شبکه (عمومیت یافتن) آن به‌سادگی امکان‌پذیر نیست.

در دهه‌های اخیر، ANN ها توانایی‌های زیادی در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی در هیدرولوژی و مهندسی منابع آب به علت ویژگی غیرخطی ذاتی و انعطاف‌پذیری آن‌ها برای مدل‌سازی نشان داده‌اند. مدل‌های ANN مدل‌های غیرخطی داده‌ای می‌باشند که می‌توانند راه‌حل‌های قدرتمند برای بسیاری از مشکلات مدل‌سازی پیچیده ارائه دهند. آن‌ها دارای ویژگی‌های بسیاری هستند که آن‌ها را برای استفاده در پیش‌بینی جذاب می‌کند. یکی از ویژگی‌هایی که باعث توسعه سریع ANN ها شد این بود که این مدل‌ها به اطلاعات بسیار دقیق در مورد ویژگی‌های فیزیکی منطقه مورد مطالعه را نیازی ندارند. یکی دیگر از این ویژگی‌ها زمان اجرای سریع آن‌ها است. هنگامی که ANN ها کالیبراسیون می‌شوند، آن‌ها سریع اجرا می‌شوند و در زمان کمی به جواب می‌رسند. یکی از ویژگی‌های ANN که آن‌ها را برای مدل‌سازی هیدرولوژیکی جذاب می‌سازند این است که آن‌ها قادر به تشخیص رابطه بین متغیرهای ورودی و خروجی بدون ملاحظات صریح هستند.

ANN حتی اگر در مجموعه داده‌های آموزشی خطاهای نویز و اندازه‌گیری وجود داشته باشد باز هم به خوبی کار می‌کند و آن‌ها قادر با تطبیق با شرایط زیادی هستند [۲۱].

به غیر از هیدرولوژی، ANN ها به‌طور گسترده‌ای برای مدل‌سازی سری‌های زمانی در زمینه‌های مختلف برنامه‌های کاربردی مانند سیستم‌های دینامیکی، پردازش سیگنال غیرخطی، تشخیص الگو، شناسایی و طبقه‌بندی استفاده شده است [۶۳].

ANN ها به‌عنوان یک جایگزین برای پیش‌بینی‌های سری زمانی خطی و غیرخطی استفاده شده‌اند [۶۴]. آن‌ها قادر به طبقه‌بندی گسترده‌ای از توابع غیرخطی هستند و به همین دلیل نامزدهای ایده آل برای توسعه مدل‌های تجربی (نوع رگرسیون) هستند.

به‌طور کلی، ANN ها از یک لایه ورودی تشکیل شده که از طریق آن اطلاعات به شبکه می‌رسد، یک یا چند لایه پنهان، که اطلاعات آن روت شده است، و یک لایه خروجی، که نتایج آن ارائه می‌شود [۶۵].

چندین مدل از ANN ها وجود دارند که برای پیش‌بینی خشکسالی کاربرد بیشتری دارند. مدل پس انتشار (Feed-Forward) و سیستم استنتاج فازی مبتنی بر شبکه‌های عصبی (ANFIS) از این مدل‌ها هستند. مدل پس انتشار، بیشترین استفاده برای بیش‌بینی خشکسالی را دارد [۵۰], [۳۲], [۲۳]–[۲۱] [۶۲], [۶۱].

اگرچه که مدل‌های ANFIS هم جای خود را در پیش‌بینی خشکسالی پیدا کردند [۳۰].

شبکه‌های feed-forward

محبوب‌ترین نوع شبکه عصبی برای پیش‌بینی سری زمانی، مدل پس انتشار است [۲۱].

یک مدل پس انتشار به‌صورت پیش‌فرض متشکل از سه لایه که شامل لایه ورودی، لایه خروجی و لایه مخفی است. گره‌های ورودی شامل اطلاعات مشابه شده قبلی با تأخیرهای نسبت به زمان فعلی، درحالی‌که داده‌های خروجی شامل زمانی می‌شود که پیش‌بینی موردنظر است [۲۱].

گره‌های (nodes) پنهان با توابع انتقال غیره خطی مناسب برای پردازش اطلاعات دریافت شده توسط گره‌های ورودی مورد استفاده قرار می‌گیرند.

برای ایجاد یک مدل برای پیش‌بینی، شبکه عصبی در سه مرحله پردازش می‌شود. مرحله آموزش که در آن شبکه برای پیش‌بینی داده‌های آینده آموزش داده می‌شود، که بر اساس داده‌های حال و گذشته است. مرحله اعتبار سنجی که در آن شبکه آزمایش می‌شود برای متوقف کردن آموزش یا ادامه آن و مرحله تست برای پیش‌بینی داده‌های آینده و محاسبه اندازه‌های مختلف خطا آن است.

شبکه‌های پس انتشار^۱ (BPN) توسط رامل هرت^۲ و همکاران توسعه یافت. در فرایند یادگیری BPN، وزن‌های اتصال با استفاده از روش همگرایی خطا برای به دست آوردن خروجی مطلوب برای ورودی داده شده تنظیم می‌شود. به‌طور کلی، خطا در لایه خروجی در مدل BPN به سمت لایه ورودی از طریق لایه مخفی در شبکه حرکت می‌کند تا نتیجه مطلوب نهایی را بدست آورد. روش تبادل گرادیان^۳ برای محاسبه وزن شبکه استفاده می‌شود و وزن اتصالات را برای به حداقل رساندن خطای خروجی تنظیم می‌کند. عنصر دیگر ANNs تابع فعال‌سازی (تابع انتقال) است. این رابطه بین ورودی‌ها و خروجی‌ها و گره‌ها را تعیین می‌کند و درجه‌ای از غیرخطی را که برای اکثر برنامه‌های ANN ارزشمند است معرفی می‌کند.

توابع فعال شناخته شده عبارت‌اند از توابع لگاریتمی، تنگستن هذلولی، سینوسی (یا کسینوسی) و توابع خطی.

در میان آن‌ها، تابع انتقال لگاریتمی یکی از محبوب‌ترین‌هاست [۲۱].

۳-۵-۲ شبکه‌های عصبی-فازی^۴

نوع دوم این روش‌ها عبارت است از ANFIS که به توضیح آن پرداخته می‌شود. منطق فازی یا Fuzzy Logic برای اولین بار در سال ۱۹۶۰ توسط دکتر لطفی زاده، استاد علوم کامپیوتری دانشگاه برکلی کالیفرنیا (Berkeley)، ابداع شد.

^۱ back propagation network

^۲ Rumelhart

^۳ gradient descent

^۴ ANFIS

سیستم‌های فازی چگونه سیستم‌هایی هستند؟

سیستم‌های فازی سیستم‌ها مبتنی بر دانش یا قواعد است. قلب یک سیستم فازی یک پایگاه دانش بوده که از قواعد اگر-آنگاه فازی تشکیل شده است. یک قاعده اگر-آنگاه فازی یک عبارت اگر-آنگاه بوده که بعضی کلمات آن به وسیله توابع تعلق پیوسته مشخص شده‌اند.

مقاله کلاسیک پرفسور لطفی زاده درباره مجموعه فازی که در سال ۱۹۶۵ به چاپ رسید، سرآغاز جهتی نوین در علوم و مهندسی سیستم و کامپیوتر بود. پس از آن پرفسور لطفی زاده به پژوهش‌های خود در زمینه مجموعه فازی ادامه داد تا آنکه در سال ۱۹۷۳ طی یک مقاله کلاسیک دیگر تحت عنوان "شرحی بر دیدی نو در تجزیه و تحلیل سیستم‌های پیچیده و فرایندهای تصمیم‌گیری" مفهوم استفاده از متغیرهای زبانی را در سیستم‌های حافظه و کنترل مطرح کرد. این مقاله اساس تکنولوژی کنترل بر مبنای منطق فازی است که در آینده اثرات عمیق در طراحی سیستم‌های کنترل هوشیار خواهد داشت. گرچه منطق فازی کاربردی خیلی وسیع‌تر از منطق متداول دارد ولی پرفسور لطفی زاده معتقد است که منطق فازی اکسیر و نوشدارو نیست. وی می‌گوید "کارهای زیادی هست که انسان می‌تواند به آسانی انجام دهد در حالی که کامپیوترها و سیستم‌های منطقی قدرت فازی یک فرا مجموعه از منطق بولی است که بر مفهوم درستی نسبی، دلالت می‌کند. منطق کلاسیک هر چیزی را بر اساس یک سیستم دوتایی نشان می‌دهد (درست یا غلط، ۰ یا ۱، سیاه یا سفید) ولی منطق فازی درستی هر چیزی را با یک عدد که مقدار آن بین صفر و یک است نشان می‌دهد. مثلاً اگر رنگ سیاه را عدد صفر و رنگ سفید را عدد ۱ نشان دهیم، آنگاه رنگ خاکستری عددی نزدیک به صفر خواهد بود. در سال ۱۹۶۵، دکتر لطفی زاده نظریه سیستم‌های فازی را معرفی کرد. در فضایی که دانشمندان علوم مهندسی به دنبال روش‌های ریاضی برای شکست دادن مسائل دشوارتر بودند، نظریه فازی به گونه‌ای دیگر از مدل‌سازی، اقدام کرد.

با توجه به کمبود مطالعه در مورد عدم قطعیت مواردی همچون شبکه‌های عصبی مصنوعی، شبکه‌های عصبی-فازی این تحقیق می‌تواند گامی در ارزیابی عدم قطعیت پیش‌بینی خشکسالی باشد.

با این حال، این تحقیق پیش‌بینی خشکسالی با روش‌های شبکه عصبی مصنوعی، شبکه عصبی-فازی را برای کوتاه‌مدت انجام می‌دهد. شبکه‌های عصبی نشان داده‌اند که نتایج قابل اعتماد برای پیش‌بینی‌های SPI ارائه می‌دهند [۳۰]، [۲۱].

با توجه به اینکه این تحقیق برای عدم قطعیت پیش‌بینی خشکسالی در دوره‌های کوتاه‌مدت است این مطالعه نیز به پیش‌بینی SPI_۱ و SPI_۳ و SPI_۶ و SPI_۹ و SPI_{۱۲} می‌پردازد تا بهترین پیش‌بینی معلوم شود و عدم قطعیت آن محاسبه گردد.

۳-۶ پردازش آمار بارندگی

با توجه به اینکه آموزش یک شبکه عصبی مصنوعی از روی ارائه مجموعه داده‌های آموزشی ورودی-خروجی صورت می‌گیرد، در انتخاب و نحوه ارائه داده به شبکه عصبی، بایستی دقت نمود [۶۶]. فرم ارائه داده‌ها به مدل، ممکن است یک مسئله قابل حل ساده را به یک مسئله غیرقابل حل تبدیل سازد [۶۷].

نرمال‌سازی داده‌ها

چنانچه در بالا گفته شد، نحوه ارائه داده‌ها به مدل شبکه عصبی از اهمیت بسزایی برخوردار است. در بیشتر مدل‌های شبکه عصبی، با توجه به برد تابع فعال‌ساز، از داده‌های دوتایی مثبت^۱ (۰ یا ۱)، یا دوتایی مثبت-منفی^۲ (۱ یا -۱)، استفاده می‌شود [۶۸]. در صورتی که داده‌های مورد نظر مسئله، به اشکال مذکور موجود

^۱ Binary

^۲ Bipolar

نباشد، در عمل رسم بر این است که قبل از ارائه این داده‌ها به شبکه، آن‌ها را بر محدوده‌ای بین منفی یک و یک تصویر می‌کنند. با انجام این کار، داده‌ها از توزیع نسبتاً یکسانی برخوردار می‌گردند و تشخیص و جداسازی داده‌های پرت^۱، آسان‌تر می‌شود. مزیت دیگر استفاده از این روش افزایش دقت و سرعت شبکه است.

۳-۷ برآورد عدم قطعیت در پیش‌بینی‌ها

مهم‌ترین هدف این تحقیق بررسی و تخمین عدم قطعیت در خروجی مدل‌های ANN و ANFIS بود. اساس کار روش شبیه‌سازی مونت-کارلو بر پایه استفاده از اعداد تصادفی و حصول تابع توزیع احتمالاتی خروجی یک مدل است. به این صورت که متغیرها (ورودی به مدل) با استفاده از تابع توزیع احتمالاتی مربوطه، به‌طور تصادفی تولید شده و سپس خروجی معادل آن‌ها از مدل مورد نظر بدست می‌آید و این عمل بارها تکرار می‌شود. در مرحله بعد نیز عدم قطعیت خروجی (تابع) از طریق محاسبه شاخص‌های آماری و یا تعیین تابع توزیع احتمالاتی برآورد می‌شود [۶۹].

تفاوت روش مورد بحث در این تحقیق با تعریف بالا، استفاده از نمونه‌های تصادفی گرفته‌شده به‌جای اعداد تصادفی ساخته‌شده بود. این روش به روش دودویی Bootstrap بسیار شباهت داشته و تنها فرق آن در عدم تکرار یک الگو در یک نمونه است [۷۰].

در این روش ابتدا از اطلاعاتی که برای تست مدل در نظر گرفته شده‌اند به دفعات زیاد (در این تحقیق ۱۰۰۰ بار) بدون تکرار نمونه‌گیری می‌شود به نحوی که تعداد داده‌های تست در هر نمونه یکسان باشد و برای هر نمونه عملیات تست مدل انجام می‌گردد [۳۶]. در نتیجه پارامترهای مدل به دفعات زیاد و هر بار بر

^۱ Noise

اساس نمونه‌ای از وقایع اتفاق افتاده در گذشته، به دست می‌آیند. با استفاده از این تکنیک محاسبات حجیم، به‌جای پیش‌بینی یک عدد مطلق مطابق با آنچه در تحقیقات مشابه انجام گرفته، محدوده‌ای از خروجی که نتیجه عدم قطعیت مدل ساخته شده است، حاصل خواهد شد. برای بررسی عدم قطعیت، حدود اطمینان ۹۵ درصد^۱ (۹۵PPU) برای پیش‌بینی‌ها مد در نظر قرار گرفت که طریقه به دست آوردن آن تعیین حدود ۲/۵ درصد (X_L) و ۹۷/۵ درصد (X_U) توزیع نرمال تجربی به‌دست‌آمده از ۱۰۰۰ پیش‌بینی انجام شده، بود. حدود اطمینان مناسب حدودی است که بالای ۸۰ درصد از پیش‌بینی‌های انجام گرفته توسط هریک از دو مدل ANN و ANFIS، در آن حدود قرار گرفته و دارای عرض متوسط قابل قبولی باشد [۳۶].

برای سنجش عرض متوسط باند اطمینان، شاخص فاکتور عرض باند مطابق رابطه ۳-۱۳ (پیشنهاد شد. [۷۱])

$$d - factor = \frac{\overline{d_x}}{\sigma_x} \quad \text{رابطه ۳-۱۳}$$

که در این رابطه σ_x انحراف استاندارد مقادیر اندازه‌گیری شده و $\overline{d_x}$ عرض متوسط باند اطمینان است که مطابق رابطه ۳-۱۴ (تعریف می‌شود:

$$\overline{d_x} = \frac{1}{k} \sum_{i=1}^k (X_U - X_L) \quad \text{رابطه ۳-۱۴}$$

در حالت کلی مقدار عرض باند کوچک‌تر از ۱ مناسب به‌حساب می‌آید [۷۱].

^۱ ۹۵ Percent Prediction Uncertainty (۹۵PPU)

۸-۳ روش‌های ارزیابی مدل‌ها

برای ارزیابی عملکرد مدل‌های بدست آمده با داده‌های ذکرشده از ضوابط زیر استفاده شده است:

۱-۸-۳ معیار R^2 :

$$R^2 = \frac{\sum_{i=1}^N (f_i - \bar{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad \text{رابطه ۱۵-۳}$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad \text{رابطه ۱۶-۳}$$

جایی که y_i مقدار مشاهده شده، f_i مقدار پیش‌بینی شده و N تعداد نمونه است. R^2 اندازه‌گیری میزان همبستگی بین مقادیر مشاهده شده و پیش‌بینی شده است. این اندازه‌گیری از قدرت مدل در ایجاد ارتباط بین متغیرهای ورودی و خروجی است. هرچه مقدار R^2 بالاتر باشد (بالاترین مقدار ممکن ۱ است)، عملکرد این مدل بهتر است.

۲-۸-۳ معیار جذر میانگین مربع خطاها (RMSE):

$$RMSE = \sqrt{\frac{SSE}{N}} \quad \text{رابطه ۱۷-۳}$$

که SSE برابر است با مجموع مربع خطاها و N برابر است با تعداد داده‌های مورد استفاده و SSE به وسیله رابطه ۱۸-۳ نشان داده می‌شود:

رابطه ۱۸-۳

$$SSE = \sum_{i=1}^N (f_i - y_i)^2$$

با متغیرهایی که قبلاً تعریف شده‌اند. RMSE واریانس خطاها را مستقل از اندازه نمونه ارزیابی می‌کند. هرچه مقدار $RMSE$ به صفر نزدیک‌تر باشد، نشان‌دهنده کوچک‌تر بودن مقادیر خطا و صحیح‌تر و دقیق‌تر بودن جواب‌هاست.

۳-۸-۳ معیار میانگین خطای مطلق MAE:

رابطه ۱۹-۳

$$MAE = \frac{\sum_{i=1}^N |f_i - y_i|}{N}$$

MAE برای اندازه‌گیری مقادیر پیش‌بینی شده نزدیک به مقادیر مشاهده شده استفاده می‌شود.

۳-۸-۴ معیار نش-شاتکلیف:

رابطه ۲۰-۳

$$NS = EI = 1 - \frac{\sum_{i=1}^N (y_i - f_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

که y_i می‌شود SPI مشاهداتی در زمان t و f_i می‌شود SPI شبیه‌سازی شده در زمان t و $\bar{y}$ می‌شود میانگین SPI مشاهداتی.

اگر $NS = 0.5$ باشد یعنی دقت شبیه‌سازی‌ها در حد متوسط مقادیر مشاهداتی است.

اگر $NS < 0$ باشد یعنی واریانس خطاها (صورت کسر) بیشتر از واریانس مقادیر مشاهداتی (مخرج کسر) است.

اگر $NS = 1$ باشد یعنی مدل کامل است.

۳-۹ روش شناسی

این بخش شامل نحوه محاسبه SPI و نیز نحوه پیش‌بینی SPI در مقیاس کوتاه‌مدت با استفاده از Feedforward و ANFIS است.

SPI ماهانه با تأخیرهای مناسب $(t-1), (t-2), (t-3)$ برای ورودی اطلاعات در نظر گرفته شده است.

۳-۹-۱ محاسبه SPI

اولین گام در محاسبه SPI، تعیین یک تابع چگالی احتمال است که مجموعه داده‌های بارندگی بلندمدت را توصیف می‌کند [۵۹].

هنگامی که این توزیع تعیین می‌شود، احتمال تجمعی مقدار بارش مشاهده شده محاسبه می‌شود. تابع توزیع گاما به منظور جمع‌آوری داده‌های بارش در این مطالعه انتخاب شد.

SPI یک شاخص نرمال در زمان و مکان است. این ویژگی به مقادیر مختلف در مکان‌های جغرافیایی اجازه می‌دهد تا مقایسه شوند [۵۹].

سری زمانی SPI را می‌توان برای نظارت خشکسالی و تعریف شروع و پایان خشکسالی استفاده کرد. برای تحلیل شدت خشکسالی، مقادیر جمع‌آوری شده SPI می‌تواند مورد استفاده قرار گیرد. در این مطالعه، نرم‌افزار بسته شاخص‌های خشکسالی (Drought Indicis Package)، برای محاسبه شاخص‌های خشکسالی (SPI) برای هر ایستگاه در هر حوضه و برای هر ماه استفاده شد. با استفاده از اطلاعات دریافت شده از شاخص بارندگی و برنامه SPI فوق، مقادیر SPI_1 و SPI_3 و SPI_6 و SPI_9 و SPI_{12} محاسبه شد.

SPI_1 بسیار شبیه به ۷۳ درصد بارش معمولی در یک ماه است. SPI_1 شرایط نسبتاً کوتاه مدت را نشان می‌دهد؛ کاربرد آن می‌تواند در ارتباط با سنجش رطوبت کوتاه مدت خاک بخصوص در فصل رشد باشد. به همین ترتیب، یک SPI_3 میزان بارش آن دوره را با همان دوره‌های ۳ ماهه قبل مقایسه می‌کند. یک SPI_3 روند تغییرات کوتاه مدت و متوسط را در بارش نشان می‌دهد و هنوز هم حساسیت بیشتری نسبت به شرایط شاخص پالمر در همین شرایط را داراست. SPI_3 می‌تواند در نشان دادن روند فصلی بارش، بسیار مؤثر باشد. در مقابل، SPI های طولانی مانند SPI_{12} و SPI_{24} منعکس کننده الگوهای بارندگی بلندمدت است.

SPI_{12} مقایسه بارش ۱۲ ماه متوالی با همان ۱۲ ماه متوالی در طول سال‌های قبل از داده‌های موجود است. از آنجاکه این مقیاس‌های زمانی نتیجه تجمعی دوره‌های کوتاه‌تر است که ممکن است بالاتر یا کمتر از حد نرمال باشد، SPI های طولانی‌تر تمایل به نزدیک شدن به صفر را دارند مگر اینکه یک روند خاص در حال انجام باشد.

۳-۹-۲ توسعه ANN

ANN ها چارچوب محاسبات انعطاف پذیر برای مدل سازی طیف وسیعی از مشکلات غیرخطی هستند. در طول دهه گذشته، ANN ها به طور گسترده در زمینه پیش بینی هیدرولوژیکی مورد استفاده قرار گرفته اند. آن‌ها دارای ویژگی‌های فراوانی از قبیل زمان اجرای سریع و توانایی آن‌ها برای مقابله با مقادیر زیاد داده‌ها بدون اطلاع دقیق از ویژگی‌های فیزیکی پدیده هستند که موجب توسعه سریع آن‌ها گردیده است [۶۵]. مدل‌های ANN که در این تحقیق مورد استفاده قرار می‌گیرند دارای معماری پیش به جلو (Feed forward) پرسپترون چندلایه (MLP) بوده که به وسیله الگوریتم پس انتشار لونیگ-مارکارت (LM) آموزش دیده است. الگوریتم لونیگ-مارکارت روشی است برای یافتن کمینه یک تابع غیرخطی چند

متغیره که به عنوان یک روش استاندارد برای حل مسئله کمینه مربعات برای توابع غیرخطی درآمده است. الگوریتم لونبرگ-مارکوارت (LMA) بین الگوریتم گاوس-نیوتون (GNA) و روش نزول گرادیانی درونیایی می کند. پرتعدادترین الگوریتم برازش خم است و کاربران کمی ممکن است به روش های دیگر برازش خم نیاز پیدا کنند.

مدل های ANN استفاده شده برای پیش بینی SPI مدل های بازگشتی بودند. لایه ورودی برای مدل ها از مقادیر SPI محاسبه شده از هر شهر بود. داده های ورودی بین بازه ی ۱- و ۱+ استاندارد شده است. تمام مدل های ANN، با نرم افزار MATLAB و تولباکس ANN ساخته شده است. تابع انتقال تانژانت هیپربولیک تابع فعال سازی برای لایه های مخفی بود در حالی که تابع فعال سازی برای لایه خروجی یک تابع خطی بود. تمام مدل های ANN در این مطالعه با استفاده از الگوریتم لونبرگ-مارکوارت آموزش داده شد. الگوریتم لونبرگ-مارکوارت به دلیل کارایی آن و کاهش زمان محاسباتی در مدل های آموزشی انتخاب شد. بین ۱۱ تا ۱۱ ورودی برای هر مدل ANN وجود دارد. تعداد نوروں های ورودی به واسطه آزمایش و خطا تعیین می شود و نوروں هایی که حداقل مقدار متوسط خطای مربع (RMSE) را در مجموعه آموزشی تعیین می کنند، نمایش داده می شود. ورودی ها و خروجی ها بین ۱- و ۱ نرمال شده اند.

۳-۹-۳ توسعه ANFIS

ANFIS یکی از مدل های توسعه یافته فازی بر مبنای به کارگیری تکنیک های آموزش مختلف در ANN است که عملکرد موفقی را در مدل سازی توابع غیرخطی از خود نشان داده است.

این مدل از یک شبکه پیش خور برای بهینه کردن پارامترهای سیستم استنتاج فازی (FIS) ^۱ استفاده


^۱ Fuzzy Inference System (FIS)

می‌کند. الگوریتم آموزش برای مدل ANFIS شامل یک الگوریتم ترکیبی متشکل از روش‌های کاهش گرادیان و حداقل مربعات است [۷۳], [۷۲].


معمول‌ترین نوع FIS که قابلیت قرارگیری در یک شبکه تطبیقی را داراست، سیستم فازی سوگنو است که خروجی آن یک رابطه خطی است و پارامترهای آن را می‌توان با ترکیب روش‌های حداقل مربعات خطا و انتشار خطا به عقب بر اساس کاهش گرادیان برآورد نمود [۷۲].

در مورد ANFIS و الگوریتم ترکیبی مورد استفاده آن، مطالعات گسترده‌ای صورت گرفته است [۷۲] [۷۴].

در شکل ۱-۳ و شکل ۲-۳ به ترتیب نمونه‌ای از سیستم استنتاج فازی سوگنو مرتبه اول که دارای دو ورودی x و y و خروجی z است و همچنین معماری ANFIS آن نشان داده شده است.



شکل ۱-۳ سیستم استنتاج فازی سوگنو



شکل ۲-۳ معماری مدل ANFIS معادل سیستم استنتاجی فازی

۴-۹-۳ ساختار مدل‌های پیشنهادی

یکی از مهم‌ترین مراحل در ایجاد یک مدل پیش‌بینی رضایت بخش، انتخاب متغیرهای ورودی است. زیرا که این متغیرها ساختار مدل پیش‌بینی را تعیین می‌کنند و ضریب وزنی و نتایج مدل را تحت تأثیر قرار می‌دهند.

۱۱ مدل با تعداد ورودی و ساختارهای مختلف برای هر مرحله با استفاده از این متغیرها ساخته شد که در جدول ۹-۳ نشان داده شده است.

جدول ۹-۳ مدل‌های پیشنهادی برای پیش‌بینی

خروجی	ساختار ورودی	مدل
$SPI(t)$	$SPI(t-1)$	M_1
$SPI(t)$	$SPI(t-1), SPI(t-2)$	M_2
$SPI(t)$	$SPI(t-1), SPI(t-2), SPI(t-3)$	M_3
$SPI(t)$	$SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4)$	M_4
$SPI(t)$	$SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4), SPI(t-5)$	M_5
$SPI(t)$	$SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4), SPI(t-5), SPI(t-6)$	M_6
$SPI(t)$	$SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4), SPI(t-5), \dots, SPI(t-7)$	M_7
$SPI(t)$	$SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4), SPI(t-5), \dots, SPI(t-8)$	M_8
$SPI(t)$	$SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4), SPI(t-5), \dots, SPI(t-9)$	M_9
$SPI(t)$	$SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4), SPI(t-5), \dots, SPI(t-10)$	M_{10}
$SPI(t)$	$SPI(t-1), SPI(t-2), SPI(t-3), SPI(t-4), SPI(t-5), \dots, SPI(t-11)$	M_{11}

۴. فصل چهارم : نتایج و بحث

۴-۱ مقدمه

در این مطالعه توانایی مدل‌های فوق به‌طور مؤثر برای پیش‌بینی SPI در زمان‌های مختلف مورد ارزیابی قرار گرفت و در نهایت منجر به رسیدن ارائه الگوریتمی برای دستیابی به عدم قطعیت مدل شبکه عصبی مصنوعی در تخمین خشکسالی شد.

در بخش‌های زیر، نتایج پیش‌بینی شده برای بهترین مدل‌های توسعه داده در هر زیر مجموعه ارائه شده است. پیش‌بینی‌ها و عدم قطعیت ارائه شده در سری زمانی SPI_۱ و SPI_۳ بیشتر برای توصیف خشکسالی کوتاه‌مدت (خشکسالی کشاورزی) مورد استفاده بوده است. SPI_۱ شاخص خوبی برای انحراف بارش از میانگین بلندمدت است.

۴-۲ پیش‌بینی SPI_۱

در پیش‌بینی SPI_۱ از مدل‌های ANN و ANFIS بهره برده شده است و نتایج هر کدام در جداولی جدا ارائه شده است. در مدل ANN تعداد لایه‌های پنهان متفاوتی مورد بررسی قرار گرفته است که بهترین جواب‌ها از نظر معیارهای R و RMSE و MAE بررسی شده و در جدول ۴-۱ و جدول ۴-۲ ارائه شده است. با این حال، تمام پیش‌بینی‌های SPI_۱ نتایج پایینی را نشان می‌دهد.

جدول ۱-۴ بهترین عملکرد شبکه ANN در پیش بینی SPI۱

نام ایستگاه	نوع ساختار	نوع ورودی ها	R	RMSE	MAE	NS
شاهرود	S۳	۸-۹-۱	۰/۳۲۴	۰/۸۵۲	۰/۰۰۲	-۰/۰۳۸
بندرعباس	S۲	۷-۸-۱	۰/۳۸۲	۰/۸۶۲	۰/۰۰۳	۰/۰۴
مشهد	S۵	۳-۴-۱	۰/۲۹۹	۰/۹۱۹	۰/۰۰۲	۰/۰۷
تبریز	S۱	۴-۵-۱	۰/۳۷۰	۰/۹۲۴	۰/۰۰۱	-۰/۰۴
زاهدان	S۳	۲-۳-۱	۰/۳۸۵	۰/۹۵۴	۰/۰۰۵	۰/۰۶

جدول ۲-۴ بهترین عملکرد شبکه ANFIS در پیش بینی SPI۱

نام ایستگاه	نوع ساختار	R	RMSE	MAE	NS
شاهرود	S۳	۰/۲۵۰	۰/۸۱۰	۰/۰۰۲	-۰/۰۲۱
بندرعباس	S۳	۰/۵۰۹	۰/۷۶۹	۰/۰۰۲	۰/۱۲۰
مشهد	S۱	۰/۳۱۹	۰/۸۷۳	۰/۰۰۲	۰/۱۰۱
تبریز	S۲	۰/۲۷۵	۰/۹۶۳	۰/۰۰۳	-۰/۰۴۴
زاهدان	S۱	۰/۵۲۵	۰/۷۴۸	۰/۰۰۲	۰/۱۸۵

۳-۴ پیش‌بینی SPI_3

نتایج SPI_3 برای تمام مدل‌ها در جدول ۳-۴ بهترین عملکرد شبکه ANN درپیش‌بینی SPI_3 ارائه شده است. بهترین نتیجه گروه ANN برای شهر تبریز با $R=0/719$ بدست آمده است که دارای $RMSE=0/869$ است. بهترین نتیجه گروه ANFIS برای شهر تبریز با $R=0/726$ بدست آمده است. تبریز دارای $RMSE=0/755$ است.

جدول ۳-۴ بهترین عملکرد شبکه ANN درپیش‌بینی SPI_3

نام ایستگاه	نوع ساختار	نوع ورودی‌ها	R	RMSE	MAE	NS
شاهرود	S2	۴-۵-۱	۰/۶۷۹	۰/۸۱۳	۰/۰۰۳	۰/۲۱۰
بندرعباس	S3	۶-۷-۱	۰/۶۵۵	۰/۷۳۰	۰/۰۰۲	۰/۲۵۷
مشهد	S1	۷-۸-۱	۰/۶۷۹	۰/۸۳۲	۰/۰۰۲	۰/۲۵۷
تبریز	S3	۵-۶-۱	۰/۷۱۹	۰/۸۶۹	۰/۰۰۳	۰/۲۰۷
زاهدان	S1	۸-۹-۱	۰/۶۳۴	۰/۷۵۷	۰/۰۰۲	۰/۲۷۳

جدول ۴-۴ بهترین عملکرد شبکه ANFIS در پیش بینی SPI۳

نام ایستگاه	نوع ساختار	R	RMSE	MAE	NS
شاهرود	S۱	۰/۶۷۲	۰/۷۶۷	۰/۰۰۲	۰/۳۵۴
بندرعباس	S۳	۰/۶۴۸	۰/۶۷۲	۰/۰۰۱	۰/۳۲۲
مشهد	S۱	۰/۶۸۶	۰/۷۷۴	۰/۰۰۲	۰/۴۳۷
تبریز	S۳	۰/۷۲۶	۰/۷۵۵	۰/۰۰۲	۰/۴۲۵
زاهدان	S۳	۰/۶۱۶	۰/۶۴۱	۰/۰۰۳	۰/۳۷۱

۴-۴ پیش بینی SPI۶

بهترین نتیجه گروه ANN برای شهر تبریز با $R=0/845$ بدست آمده است که دارای $RMSE=0/836$ است.

بهترین نتیجه گروه ANFIS برای شهر تبریز با $R=0/844$ بدست آمده است که دارای $RMSE=0/565$ است.

جدول ۴-۵ بهترین عملکرد شبکه ANN در پیش‌بینی SPI۶

نام ایستگاه	نوع ساختار	نوع ورودی‌ها	R	RMSE	MAE	NS
شاهرود	S۲	۴-۵-۱	۰/۸۲۱	۰/۵۹۳	۰/۰۰۱	۰/۶۳۷
بندرعباس	S۵	۷-۸-۱	۰/۷۸۲	۰/۶۸۲	۰/۰۰۲	۰/۳۶۱
مشهد	S۱	۷-۸-۱	۰/۸۲۱	۰/۶۵۷	۰/۰۰۳	۰/۳۴۸
تبریز	S۵	۵-۶-۱	۰/۸۴۵	۰/۸۳۶	۰/۰۰۱	۰/۶۹۳
زاهدان	S۳	۹-۱۰-۱	۰/۷۶۷	۰/۷۴۳	۰/۰۰۳	۰/۴۱۲

جدول ۴-۶ بهترین عملکرد شبکه ANFIS در پیش‌بینی SPI۶

نام ایستگاه	نوع ساختار	R	RMSE	MAE	NS
شاهرود	S۷	۰/۸۰۸	۰/۶۲۸	۰/۰۰۲	۰/۶۳۷
بندرعباس	S۴	۰/۷۵۱	۰/۶۲۴	۰/۰۰۱	۰/۵۵۴
مشهد	S۴	۰/۷۸۸	۰/۶۱۷	۰/۰۰۱	۰/۶۲۰
تبریز	S۳	۰/۸۴۴	۰/۵۶۵	۰/۰۰۱	۰/۷۲۰
زاهدان	S۴	۰/۷۴۹	۰/۵۵۵	۰/۰۰۱	۰/۵۶۱

۴-۵ پیش‌بینی SPI_9

نتایج SPI_9 برای تمام مدل‌ها در ارائه شده است. بهترین نتیجه گروه ANN برای شهر تبریز با $R=0/907$ بدست آمده است که دارای $RMSE=0/785$ است. بهترین نتیجه گروه ANFIS برای شهر تبریز با $R=0/886$ بدست آمده است که دارای $RMSE=0/471$ می باشد.

جدول ۴-۷ بهترین عملکرد شبکه ANN در پیش‌بینی SPI_9

نام ایستگاه	نوع ساختار	نوع ورودی‌ها	R	RMSE	MAE	NS
شاهرود	S_2	۴-۵-۱	۰/۸۸۹	۰/۵۳۱	۰/۰۰۳	۰/۶۷۵
بندرعباس	S_3	۳-۴-۱	۰/۸۵۷	۰/۵۸۲	۰/۰۰۱	۰/۶۷۶
مشهد	S_4	۴-۵-۱	۰/۸۷۷	۰/۵۷۳	۰/۰۰۳	۰/۴۷۷
تبریز	S_8	۶-۷-۱	۰/۹۰۷	۰/۷۸۵	۰/۰۰۳	۰/۷۳۸
زاهدان	S_2	۷-۸-۱	۰/۸۳۴	۰/۷۰۶	۰/۰۰۳	۰/۶۱۲

جدول ۸-۴ بهترین عملکرد شبکه ANFIS در پیش‌بینی SPI^۹

نام ایستگاه	نوع ساختار	R	RMSE	MAE	NS
شاهرود	S _۵	۰/۸۷۴	۰/۴۸۲	۰/۰۰۱	۰/۷۶۲
بندرعباس	S _۵	۰/۸۷۶	۰/۴۸۲	۰/۰۰۱	۰/۸۷۵
مشهد	S _۴	۰/۸۵۸	۰/۵۲۶	۰/۰۰۱	۰/۷۳۶
تبریز	S _۱	۰/۸۸۶	۰/۴۷۱	۰/۰۰۱	۰/۷۷۵
زاهدان	S _۵	۰/۸۱۱	۰/۴۷۶	۰/۰۰۱	۰/۶۵۱

۴-۶ پیش‌بینی SPI^{۱۲}

نتایج SPI^{۱۲} برای تمام مدل‌ها در جدول ۹-۴ و جدول ۱۰-۴ ارائه شده است. بهترین نتیجه گروه ANN برای شهر تبریز با $R=0/924$ بدست آمده است که دارای $RMSE=0/517$ است. بهترین نتیجه گروه ANFIS برای شهر بندرعباس با $R=0/920$ بدست آمده است که دارای $RMSE=0/384$ است.


جدول ۹-۴ بهترین عملکرد شبکه ANN در پیش‌بینی SPI۱۲

نام ایستگاه	نوع ساختار	نوع ورودی	R	RMSE	MAE	NS
شاهرود	S۶	۶-۷-۱	۰/۹۱۷	۰/۴۷۴	۰/۰۰۳	۰/۶۹۲
بندرعباس	S۴	۱۰-۱۱-۱	۰/۹۱۷	۰/۵۶۱	۰/۰۰۳	۰/۷۲۱
مشهد	S۵	۴-۵-۱	۰/۹۱۳	۰/۵۰۲	۰/۰۰۳	۰/۵۱۵
تبریز	S۷	۹-۱۰-۱	۰/۹۲۴	۰/۵۱۷	۰/۰۰۳	۰/۷۵۱
زاهدان	S۱۱	۵-۶-۱	۰/۹۰۵	۰/۵۲۵	۰/۰۰۳	۰/۷۲۱


جدول ۱۰-۴ بهترین عملکرد شبکه ANFIS در پیش‌بینی SPI۱۲

نام ایستگاه	نوع ساختار	R	RMSE	MAE	NS
شاهرود	S۲	۰/۹۰۹	۰/۴۴۲	۰/۰۰۱	۰/۸۲۵
بندرعباس	S۳	۰/۹۲۰	۰/۳۸۴	۰/۰۰۱	۰/۸۴۶
مشهد	S۸	۰/۹۰۷	۰/۴۴۴	۰/۰۰۱	۰/۸۱۹
تبریز	S۸	۰/۹۱۶	۰/۵۱۲	۰/۰۰۱	۰/۷۰۶
زاهدان	S۱۱	۰/۸۹۶	۰/۳۵۱	۰/۰۰۱	۰/۸۰۳

در نمودارهای زیر نتایج پیش‌بینی SPI_{12} برای بهترین مدل ایستگاه زاهدان انتخاب شده قابل مشاهده است.




شکل ۴-۱ مقایسه مقدار SPI_{12} مشاهداتی با SPI_{12} پیش‌بینی زاهدان در مدل ANN




شکل ۲-۴ مقایسه مقدار SPI_{12} مشاهداتی با SPI_{12} پیش‌بینی زاهدان در مدل ANFIS


نمودار تغییرات R ، $RMSE$ و NS با افزایش SPI در شکل های زیر قابل مشاهده است. در اکثر نمودار های با افزایش SPI مقدار خطا رو به بهبود رفته است بدین ترتیب که خطای $RMSE$ با افزایش SPI کاهش یافته است. این کاهش در مدل ANFIS با شیب بیشتری همراه بوده است.




شکل ۳-۴ تغییرات NS در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر مشهد




شکل ۴-۴ تغییرات RMSE در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر مشهد




شکل ۴-۵ تغییرات R در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر مشهد




شکل ۴-۶ تغییرات NS در مدل ANFIS و ANN در متفاوت SPI در ایستگاه شهر تبریز




شکل ۴-۷ تغییرات RMSE در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر تبریز




شکل ۴-۸ تغییرات R در مدل ANN و ANFIS در SPI متفاوت در ایستگاه شهر تبریز




شکل ۹-۴ تغییرات NS در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر زاهدان




شکل ۴-۱۰ تغییرات RMSE در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر زاهدان




شکل ۴-۱۱ تغییرات R در مدل ANFIS و ANN در متفاوت SPI در ایستگاه شهر زاهدان




شکل ۴-۱۲ تغییرات NS در مدل ANFIS و ANN در متغیرات SPI در ایستگاه شهر بندرعباس




شکل ۴-۱۳ تغییرات RMSE در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر بندرعباس




شکل ۴-۱۴ تغییرات R در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر بندرعباس



شکل ۴-۱۵ تغییرات NS در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر شاهرود



شکل ۴-۱۶ تغییرات RMSE در مدل ANFIS و ANN در SPI متفاوت در ایستگاه شهر شاهرود



شکل ۴-۱۷ تغییرات R در مدل ANFIS و ANN در متفاوت SPI در ایستگاه شهر شاهرود

۴-۷ نتایج عدم قطعیت مدل های پیش بینی


در بررسی نتایج دقت مدل های پیش بینی در فصول قبل به تشریح روش محاسبه دقت و عدم قطعیت مدل ها پرداخته شد و در جدول ۴-۱۱ نتایج قابل مشاهده است.

در حالت کلی مقدار d-factor مدل ANN برای هر مرحله از مقدار توصیه شده ۱، بزرگ تر بوده در حالی که این مقادیر در مدل ANFIS برای هر مرحله از مقادیر مطلوبی برخوردار است. لذا با توجه به این فاکتور، برتری مدل ANFIS نسبت به مدل ANN مشاهده شد.


جدول ۱۱-۴ نتایج مربوط به عدم قطعیت

نتایج مربوط به ANFIS		نتایج مربوط به ANN		نتایج هر شهر
R	d-factor	R	d-factor	
۰/۹۰۷	۰/۹۵	۰/۹۱۳	۱/۴۳	مشهد
۰/۹۱۷	۰/۸۷	۰/۹۱۷	۱/۵۹	شاهرود
۰/۹۲۰	۱/۰۵	۰/۹۱۷	۱/۳۵	بندرعباس
۰/۹۱۶	۰/۹۲	۰/۹۲۴	۱/۲۴	تبریز
۰/۸۹۶	۰/۸۲	۰/۹۰۶	۱/۱۲	زاهدان


همانطور که در شکل های زیر مشاهده می شود در اکثر پیش بینی ها، ANN دارای عدم قطعیت بیشتری در مقادیر خروجی بود. همچنین عرض باند اطمینان ۹۵ درصد ANN نسبت به مدل ANFIS پهنای بیشتری داشت به طوری که مقدار d-factor مدل ANN از مقدار d-factor مدل ANFIS بیشتر بوده است. در شکل های زیر عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI در مدل ANN و ANFIS برای یکی از ایستگاه های شهرهای مشهد - شاهرود - زاهدان - تبریز و بندرعباس قابل مشاهده است.




شکل ۴-۱۸ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر مشهد در مدل ANFIS




شکل ۴-۱۹ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI۱۲ در شهر مشهد در مدل ANN




شکل ۴-۲۰ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر شاهرود در مدل ANFIS




شکل ۴-۲۱ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر شاهرود در مدل ANN




شکل ۴-۲۲ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر زاهدان در مدل ANFIS




شکل ۲۳-۴ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر زاهدان در مدل ANN




شکل ۴-۲۴ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI۱۲ در شهر تبریز در مدل ANFIS



شکل ۴-۲۵ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI۱۲ در شهر تبریز در مدل ANN



شکل ۴-۲۶ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر بندرعباس در مدل ANFIS



شکل ۴-۲۷ عرض باند اطمینان ۹۵ درصد برای پیش بینی SPI_{12} در شهر بندرعباس در مدل ANN

۵. فصل پنجم : نتیجه گیری و

پیشنهادهای

۵-۱ مقدمه

خشکسالی پدیده ای طبیعی است که ضررهای زیادی را بر زندگی انسان و محیط زیست برجای میگذارد. پیش بینی خشکسالی نقش مهمی در مدیریت سیستم های منابع آب و محیط زیست ایفا می کند. با توجه به وضعیت اقلیمی ایران که در کمربند خشک و نیمه خشک کره زمین قرار دارد و ابعاد گسترده ی خساراتی که خشکسالی های گذشته در سال های گذشته در ایران بر جای گذاشته است، سعی در ارائه ی مدلی دقیق تر با استفاده از فناوری های جدید برای پیش بینی خشکسالی اهمیت پیدا می کند. وجود راهکاری برای پیش بینی خشکسالی با قطعیت بالا می تواند کمک بسیاری در برنامه ریزی برای مقابله با این پدیده باشد. در سال های گذشته شبکه های عصبی نشان داده اند که ابزاری مفید برای پیش بینی سری های زمانی هستند.

در این فصل نتیجه گیری های کلی این تحقیق و پیشنهادهایی درباره زمینه های تحقیق در آینده ارائه می شود.

۵-۲ خلاصه تحقیق

در این تحقیق جهت پیش بینی SPI مدل های مبتنی بر شبکه های عصبی مصنوعی در محیط نرم افزار MATLAB ایجاد شد. دو مدل ANN و ANFIS در راستای این مدل سازی به کار گرفته شد که جزئیات بحث در مورد این شبکه ها در فصول قبل ارائه شده است.

مدل های ارائه شده قادر به پیش بینی SPI با یک گام جلوتر می باشد. در واقع مدل با دریافت SPI ماه های قبل، قادر به پیش بینی ماه آینده می باشد.

مدل های مذکور توسط داده های پنج ایستگاه شهر های مشهد، شاهرود، زاهدان، بندرعباس و تبریز آموزش

و تست شده اند. داده های خام که به صورت بارش ماهانه بوده است به وسیله نرم افزار DIP به SPI تبدیل شد.

بعد از تشکیل شبکه و آموزش آن توسط مقداری از داده ها، به وسیله مقدار دیگری از داده ها که تکراری نمی باشد تست شد و نتایج آن با معیارهای R، RMSE، MAE و NS مورد ارزیابی قرار گرفت.

این روند حدود ۱۰۰۰ بار برای هرمدل در معماری و ورودی های متفاوت انجام گرفت. مرحله بعد محاسبه عدم قطعیت هرکدام از مدل های ارائه شده است.

۵-۳ نتایج

نتایج بیانگر دقت قابل قبول در هر دو مدل ANN و ANFIS بود به طوری که شاخص R در SPI۱۲ که بهترین نتیجه را داراست در مدل ANN و ANFIS به ترتیب معادل ۰/۹۲۴ و ۰/۹۲۰ به دست آمده است. در فصل قبل اشاره شد که با افزایش SPI مدل ها به R دقیق تری می رسند. این روند در خطای RMSE و معیار NS نیز مشاهده شده است. بدین صورت که در اکثر موارد مدل ANFIS نتایج بهتری نسبت به مدل ANN داده است. در مرحله بعد آنالیز عدم قطعیت مدل های مذکور انجام گرفت که نتایج آن بیانگر عدم قطعیت کمتر مدل ANFIS نسبت به مدل ANN بود که نشان دهنده پایداری و اطمینان پذیری این مدل در پیش بینی SPI است. بنابراین می توان در آینده برای موارد مطالعاتی و کاربردی که در اختیار داشتن SPI ماه های آینده مورد نیاز باشد، از مدل ANFIS توسعه داده شده در این تحقیق استفاده نمود.

۵-۴ پیشنهاد ها

۱- استفاده از سایر شبکه‌های عصبی و تغییر پارامترهای مدل‌های استفاده‌شده، به‌منظور دستیابی به معماری مناسب‌تر.

۲- استفاده از یکی از روش‌های بهینه‌سازی مانند الگوریتم ژنتیک در تعیین معماری شبکه.

۳- افزودن اطلاعات آب‌وهوایی از قبیل درجه حرارت و درصد رطوبت به داده‌های ورودی مدل.

۴- استفاده از مدل شبکه عصبی برای پیش‌بینی طولانی مدت در آینده

- [1] P.-S. Chu, A. J. Nash, and F.-Y. Porter, "Diagnostic studies of two contrasting rainfall episodes in Hawaii: Dry 1981 and wet 1982," *J. Clim.*, vol. 6, no. 7, pp. 1457–1462, 1993.
- [2] T. B. McKee, N. J. Doesken, and J. Kleist, "The relationship of drought frequency and duration to time scales," in *Proceedings of the 8th Conference on Applied Climatology*, 1993, vol. 17, no. 22, pp. 179–183.
- [3] D. A. Wilhite, M. J. Hayes, C. Knutson, and K. H. Smith, "Planning for drought: Moving from crisis to risk management," *JAWRA J. Am. Water Resour. Assoc.*, vol. 36, no. 4, pp. 697–710, 2000.
- [4] M. H. Glantz, *Climate affairs*. Island Press, 2003.
- [5] S. Morid, V. Smakhtin, and M. Moghaddasi, "Comparison of seven meteorological indices for drought monitoring in Iran," *Int. J. Climatol.*, vol. 26, no. 7, pp. 971–985, 2006.
- [6] D. A. Wilhite and M. H. Glantz, "Understanding: the drought phenomenon: the role of definitions," *Water Int.*, vol. 10, no. 3, pp. 111–120, 1985.
- [7] D. A. Wilhite, "Responding to drought: common threads from the past, visions for the future," *JAWRA J. Am. Water Resour. Assoc.*, vol. 33, no. 5, pp. 951–959, 1997.

- [8] V. Kumar and U. Panu, "PREDICTIVE ASSESSMENT OF SEVERITY OF AGRICULTURAL DROUGHTS BASED ON AGRO-CLIMATIC FACTORS," *Jawra J. Am. Water Resour. Assoc.*, vol. 33, no. 6, pp. 1255–1264, 1997.
- [9] D. Wilhite, "Improving Drought Management in the West: The Role of Mitigation and Preparedness: Report to the Western Water Policy Review Advisory Commission," Western Water Policy Review Advisory Commission, 1997.
- [10] P.-C. Tao and J. W. Delleur, "Seasonal and nonseasonal ARMA models in hydrology," *J. Hydraul. Div.*, vol. 102, no. 10, pp. 1541–1559, 1976.
- [11] J. D. Salas, *Applied modeling of hydrologic time series*. Water Resources Publication, 1980.
- [12] A. Montanari, R. Rosso, and M. S. Taqqu, "Fractionally differenced ARIMA models applied to hydrologic time series: Identification, estimation, and simulation," *Water Resour. Res.*, vol. 33, no. 5, pp. 1035–1044, 1997.
- [13] L. Dupigny-Giroux, "TOWARDS CHARACTERIZING AND PLANNING FOR DROUGHT IN VERMONT-PART I: A CLIMATOLOGICAL PERSPECTIVE," *JAWRA J. Am. Water Resour. Assoc.*, vol. 37, no. 3, pp. 505–525, 2001.
- [14] I. Bordi, S. Frigio, P. Parenti, A. Speranza, and A. Sutera, "The analysis of the Standardized Precipitation Index in the Mediterranean area: regional patterns," 2001.

- [15] H. Wu, M. J. Hayes, D. A. Wilhite, and M. D. Svoboda, "The effect of the length of record on the standardized precipitation index calculation," *Int. J. Climatol.*, vol. 25, no. 4, pp. 505–520, 2005.
- [16] A. A. Paulo and L. S. Pereira, "Prediction of SPI drought class transitions using Markov chains," *Water Resour. Manag.*, vol. 21, no. 10, p. 1813, 2007.
- [17] A. K. Mishra and V. R. Desai, "Drought forecasting using stochastic models," *Stoch. Environ. Res. Risk Assess.*, vol. 19, no. 5, pp. 326–339, 2005.
- [18] S. K. Jain, R. Keshri, A. Goswami, and A. Sarkar, "Application of meteorological and vegetation indices for evaluation of drought impact: a case study for Rajasthan, India," *Nat. hazards*, vol. 54, no. 3, pp. 643–656, 2010.
- [19] T.-W. Kim and J. B. Valdés, "Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks," *J. Hydrol. Eng.*, vol. 8, no. 6, pp. 319–328, 2003.
- [20] J. L. Crespo and E. Mora, "Drought estimation with neural networks," *Adv. Eng. Softw.*, vol. 18, no. 3, pp. 167–170, 1993.
- [21] A. K. Mishra and V. R. Desai, "Drought forecasting using feed-forward recursive neural network," *Ecol. Modell.*, vol. 198, no. 1, pp. 127–138, 2006.
- [22] S. Morid, V. Smakhtin, and K. Bagherzadeh, "Drought forecasting using artificial neural networks and time series of drought indices," *Int. J.*

- Climatol.*, vol. 27, no. 15, pp. 2103–2111, 2007.
- [23] P. Cutore, G. Di Mauro, and A. Cancelliere, “Forecasting palmer index using neural networks and climatic indexes,” *J. Hydrol. Eng.*, vol. 14, no. 6, pp. 588–595, 2009.
 - [24] H. B. Abarghouei, M. R. Kousari, and M. A. A. Zarch, “Prediction of drought in dry lands through feedforward artificial neural network abilities,” *Arab. J. Geosci.*, vol. 6, no. 5, pp. 1417–1433, 2013.
 - [25] S. Barua, A. W. M. Ng, and B. J. C. Perera, “Artificial neural network–based drought forecasting using a nonlinear aggregated drought index,” *J. Hydrol. Eng.*, vol. 17, no. 12, pp. 1408–1413, 2012.
 - [26] R. Pongracz, I. Bogardi, and L. Duckstein, “Application of fuzzy rule-based modeling technique to regional drought,” *J. Hydrol.*, vol. 224, no. 3, pp. 100–114, 1999.
 - [27] P. C. Nayak, K. P. Sudheer, D. M. Rangan, and K. S. Ramasastri, “Short-term flood forecasting with a Neurofuzzy model,” *Water Resour. Res.*, vol. 41, no. 4, 2005.
 - [28] J.-S. Jang, “ANFIS: adaptive-network-based fuzzy inference system,” *IEEE Trans. Syst. Man. Cybern.*, vol. 23, no. 3, pp. 665–685, 1993.
 - [29] M. E. Keskin, D. Taylan, and O. Terzi, “Adaptive neural-based fuzzy inference system (ANFIS) approach for modelling hydrological time series,” *Hydrol. Sci. J.*, vol. 51, no. 4, pp. 588–598, 2006.
 - [30] U. G. Bacanlı, M. Firat, and F. Dikbas, “Adaptive neuro-fuzzy inference system for drought forecasting,” *Stoch. Environ. Res. Risk Assess.*, vol.

- 23, no. 8, pp. 1143–1154, 2009.
- [31] M. Zounemat-Kermani and M. Teshnehlab, “Using adaptive neuro-fuzzy inference system for hydrological time series prediction,” *Appl. Soft Comput.*, vol. 8, no. 2, pp. 928–936, 2008.
- [32] J. Adamowski and H. F. Chan, “A wavelet neural network conjunction model for groundwater level forecasting,” *J. Hydrol.*, vol. 407, no. 1, pp. 28–40, 2011.
- [33] S. D. Khandekar and P. C. Deka, “Waveletneural network conjunction model in flow forecasting of sub-Himalayan river Brahmaputra,” *Int. J. Civ. Engg. Technol.*, vol. 3, no. 2, pp. 415–425, 2012.
- [34] A. Belayneh and J. Adamowski, “Standard precipitation index drought forecasting using neural networks, wavelet neural networks, and support vector regression,” *Appl. Comput. Intell. Soft Comput.*, vol. 2012, p. 6, 2012.
- [35] Ö. Kişi, “Streamflow forecasting using different artificial neural network algorithms,” *J. Hydrol. Eng.*, vol. 12, no. 5, pp. 532–539, 2007.
- [36] R. Noori, M. A. Abdoli, A. Farokhnia, and M. Abbasi, “RETRACTED: Results uncertainty of solid waste generation forecasting by hybrid of wavelet transform-ANFIS and wavelet transform-neural network.” Elsevier, 2009.
- [37] V. Moosavi, M. Vafakhah, B. Shirmohammadi, and N. Behnia, “A wavelet-ANFIS hybrid model for groundwater level forecasting for different prediction periods,” *Water Resour. Manag.*, vol. 27, no. 5, pp.

1301–1321, 2013.

- [38] R. Noori, A. R. Karbassi, K. Ashrafi, M. Ardestani, and N. Mehrdadi, “Development and application of reduced-order neural network model based on proper orthogonal decomposition for BOD5 monitoring: Active and online prediction,” *Environ. Prog. Sustain. Energy*, vol. 32, no. 1, pp. 120–127, 2013.
- [39] R. Noori, Z. Deng, A. Kiaghadi, and F. T. Kachoosangi, “How reliable are ANN, ANFIS, and SVM techniques for predicting longitudinal dispersion coefficient in natural rivers?,” *J. Hydraul. Eng.*, vol. 142, no. 1, p. 4015039, 2015.
- [40] M. Dehghani, B. Saghafian, F. Nasiri Saleh, A. Farokhnia, and R. Noori, “Uncertainty analysis of streamflow drought forecast using artificial neural networks and Monte-Carlo simulation,” *Int. J. Climatol.*, vol. 34, no. 4, pp. 1169–1180, 2014.
- [41] R. Noori, G. Hoshyaripour, K. Ashrafi, and B. N. Araabi, “Uncertainty analysis of developed ANN and ANFIS models in prediction of carbon monoxide daily concentration,” *Atmos. Environ.*, vol. 44, no. 4, pp. 476–482, 2010.
- [42] R. R. Heim, “Drought indices: a review.,” *Drought a Glob. Assess.*, pp. 159–167, 2000.
- [43] D. B. Elliott and M. A. Bullimore, “Assessing the reliability, discriminative ability, and validity of disability glare tests.,” *Invest. Ophthalmol. Vis. Sci.*, vol. 34, no. 1, pp. 108–119, 1993.

- [44] D. A. Wilhite, *Preparing for drought: A guidebook for developing countries*. Diane Publishing, 1994.
- [45] I. Bordi and A. Sutera, “Drought monitoring and forecasting at large scale,” *Methods Tools Drought Anal. Manag.*, pp. 3–27, 2007.
- [46] D. C. Edwards, “Characteristics of 20th century drought in the United States at multiple time scales.,” AIR FORCE INST OF TECH WRIGHT-PATTERSON AFB OH, 1997.
- [47] N. B. Guttman, “Accepting the standardized precipitation index: a calculation algorithm,” *JAWRA J. Am. Water Resour. Assoc.*, vol. 35, no. 2, pp. 311–322, 1999.
- [48] B. Lloyd-Hughes and M. A. Saunders, “A drought climatology for Europe,” *Int. J. Climatol.*, vol. 22, no. 13, pp. 1571–1592, 2002.
- [49] A. K. Mishra and V. P. Singh, “A review of drought concepts,” *J. Hydrol.*, vol. 391, no. 1, pp. 202–216, 2010.
- [50] A. K. Mishra, V. P. Singh, and V. R. Desai, “Drought characterization: a probabilistic approach,” *Stoch. Environ. Res. Risk Assess.*, vol. 23, no. 1, pp. 41–55, 2009.
- [51] A. A. Paulo, E. Ferreira, C. Coelho, and L. S. Pereira, “Drought class transition analysis through Markov and Loglinear models, an approach to early warning,” *Agric. water Manag.*, vol. 77, no. 1, pp. 59–81, 2005.
- [52] O. Vlček and R. Huth, “Is daily precipitation Gamma-distributed?: Adverse effects of an incorrect use of the Kolmogorov–Smirnov test,” *Atmos. Res.*, vol. 93, no. 4, pp. 759–766, 2009.

- [53] H. Wu, M. D. Svoboda, M. J. Hayes, D. A. Wilhite, and F. Wen, "Appropriate application of the standardized precipitation index in arid locations and dry seasons," *Int. J. Climatol.*, vol. 27, no. 1, pp. 65–79, 2007.
- [54] G. Tsakiris, D. Pangalou, and H. Vangelis, "Regional drought assessment based on the Reconnaissance Drought Index (RDI)," *Water Resour. Manag.*, vol. 21, no. 5, pp. 821–833, 2007.
- [55] H. Wu, M. J. Hayes, A. Weiss, and Q. Hu, "An evaluation of the Standardized Precipitation Index, the China-Z Index and the statistical Z-Score," *Int. J. Climatol.*, vol. 21, no. 6, pp. 745–758, 2001.
- [56] X. Lana, C. Serra, and A. Burgueño, "Patterns of monthly rainfall shortage and excess in terms of the standardized precipitation index for Catalonia (NE Spain)," *Int. J. Climatol.*, vol. 21, no. 13, pp. 1669–1691, 2001.
- [57] T. Shoji and H. Kitaura, "Statistical and geostatistical analysis of rainfall in central Japan," *Comput. Geosci.*, vol. 32, no. 8, pp. 1007–1024, 2006.
- [58] J. T. Schoof, "Application of the multivariate spectral weather generator to the contiguous United States," *Agric. For. Meteorol.*, vol. 148, no. 3, pp. 517–521, 2008.
- [59] C. Cacciamani, A. Morgillo, S. Marchesi, and V. Pavan, "Monitoring and forecasting drought on a regional scale: Emilia-Romagna region," *Methods tools drought Anal. Manag.*, pp. 29–48, 2007.
- [60] A. P. Barros and G. J. Bowden, "Toward long-lead operational forecasts

- of drought: An experimental study in the Murray-Darling River Basin,” *J. Hydrol.*, vol. 357, no. 3, pp. 349–367, 2008.
- [61] M. Karamouz, K. Rasouli, and S. Nazif, “Development of a hybrid index for drought prediction: case study,” *J. Hydrol. Eng.*, vol. 14, no. 6, pp. 617–627, 2009.
- [62] A. F. Marj and A. M. J. Meijerink, “Agricultural drought forecasting using satellite images, climate indices and artificial neural network,” *Int. J. Remote Sens.*, vol. 32, no. 24, pp. 9707–9719, 2011.
- [63] S. BuHamra, N. Smaoui, and M. Gabr, “The Box–Jenkins analysis and neural networks: prediction and time series modelling,” *Appl. Math. Model.*, vol. 27, no. 10, pp. 805–815, 2003.
- [64] E. Eğrioğlu, Ç. H. Aladağ, and S. Günay, “A new model selection strategy in artificial neural networks,” *Appl. Math. Comput.*, vol. 195, no. 2, pp. 591–597, 2008.
- [65] A. T. Committee, “Artificial neural networks in hydrology. I: Preliminary concepts,” *J. Hydrol. Eng.*, vol. 5, no. 2, pp. 115–123, 2000.
- [66] L. Fu, “Neural Networks in Computer Intelligence. 1994.” McGraw-Hill, New York, 1994.
- [67] L. Fausett and L. Fausett, *Fundamentals of neural networks: architectures, algorithms, and applications*, no. 006.3. Prentice-Hall, 1994.
- [68] S. Haykin, “Neural networks a comprehensive introduction.” Prentice Hall, New Jersey, 1999.

- [69] K. Eckhardt, L. Breuer, and H.-G. Frede, "Parameter uncertainty and the significance of simulated land use change effects," *J. Hydrol.*, vol. 273, no. 1, pp. 164–176, 2003.
- [70] B. Efron and R. J. Tibshirani, "An Introduction to the Bootstrap: Monographs on Statistics and Applied Probability, Vol. 57," *New York London Chapman Hall/CRC*, 1993.
- [71] K. C. Abbaspour, J. Yang, I. Maximov, R. Siber, K. Bogner, J. Mieleitner, J. Zobrist, and R. Srinivasan, "Modelling hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT," *J. Hydrol.*, vol. 333, no. 2, pp. 413–430, 2007.
- [72] J.-S. R. Jang, C.-T. Sun, and E. Mizutani, "Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence," 1997.
- [73] J.-S. R. Jang, "Rule extraction using generalized neural networks," in *Proc. of the 4th IFSA World Congress*, 1991, pp. 82–86.
- [74] J.-S. R. Yang and N. Gulley, "Fuzzy Logic Toolbox For Use with MATLAB. The MathWorks." Inc, 1995.

[75] ابراهیمی, ر., زهرایی, ب., & ناصری, م. (۱۳۸۹). پیش بینی شاخص استاندارد شده بارش با استفاده از سیستم استنتاج فازی. منابع آب/یران.

[76] ابریشم چی, ا., تجریشی, م., & مهدیخانی, ح. (۱۳۸۵). توسعه مدل تلفیقی غیرخطی پیش بینی

خشکسالی مبتنی بر شبکه عصبی مصنوعی و تبدیلات موجک: مطالعه موردی: زیرحوضه سد زاینده رود.
دومین کنفرانس مدیریت منابع آب.

[77] اژدری مقدم, م., خسروی, م., & حسین پور نیکنام, ح. (۱۳۹۱). پیش بینی خشکسالی یک ساله با استفاده از مدل فازی-عصبی، سری های زمانی خشکسالی و شاخصهای اقلیمی (مطالعه موردی: زاهدان). فصلنامه آب و فاضلاب.

[78] شیرمحمدی, ب., مرادی, ح., طائی, م., & موسوی, و. (۱۳۹۱). مقایسه شبکه عصبی با سیستم فازی-عصبی تطبیقی در پیش بینی خشکسالی هواشناسی. همایش ملی بیابان.

[79] کماسی, م., اعلمی, م., & نورانی, و. (۱۳۹۲). پیش بینی خشکسالی با نمایه SPI به روش مدلسازی ANFIS بر مبنای خوشه بندی C-mean فازی. فصلنامه آب و فاضلاب .

Abstract

drought is a natural creep and slight phenomenon of any area's climate which entails strong economical ecological and social effects.

Iran is a country of dryness and has witnessed numerous detriments from drought condition in recent years.

For effective controlling and predicting the intensity of drought with high precision and calculating the lack of certainty tool development can help politicians to lessen vulnerability and plan precisely to confront this phenomenon.

Through last decades, a large number of abilities in series modeling and prediction were shown by neural networks.

by this research, drought modeling and prediction will be proceeded by using ANFIS, ANN.

by evaluating the uncertainty of each model through next step, the appropriate model will be chosen.

as long as input data play a significant role in neural networks instruction and through all recent researches up to now absolutely coincidental selection algorithm was used tried to present a new algorithm in order to choose input data in instruction level.

Final results show that although ANFIS model shows less R^2 than ANN model but it has less lack of certainty than ANN model which it proves the superiority of ANFIS model than ANN model.

Keywords: Drought prediction, Uncertainty, Neural networks, Fuzzy networks



Faculty of Civil Engineering

M.Sc. Thesis in Water Resources Engineering and Management

**An Algorithm for Achieving Uncertainty in the Artificial Neural Network
Model in Drought Estimation**

By : hassan salehi

Supervisors:

Dr. Saeed Goliyan

Dr. Rohollah Nuri

September 2017