

## مقایسه کارآمدی چهار روش هوش مصنوعی در پیش‌بینی خشک‌سالی

لاله شریفی‌پور؛ دانشجوی کارشناسی ارشد مدیریت و کنترل بیابان گروه مهندسی طبیعت دانشکده کشاورزی و منابع طبیعی دانشگاه اردکان، اردکان، ایران.

محمد جواد قانعی بافقی<sup>۱</sup>؛ استادیار گروه مهندسی طبیعت دانشکده کشاورزی و منابع طبیعی دانشگاه اردکان، اردکان، ایران.

محمد رضا کوثری؛ استادیار پژوهشی پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات آموزش و ترویج کشاورزی، تهران، ایران.

ساسان شریفی‌پور؛ دانش‌آموخته کارشناسی ارشد مهندسی کامپیوتر هوش مصنوعی دانشگاه صنعتی مالک اشتر، تهران، ایران.

دریافت مقاله: ۱۳۹۹/۱۱/۲۸  
پذیرش نهایی: ۱۴۰۰/۰۳/۲۸

### چکیده

خشک‌سالی یک اختلال موقتی است که خصوصیات آن از منطقه‌ای با منطقه دیگر متفاوت است، از این رو نمی‌توان تعریف جامع و مطلق برای خشک‌سالی بیان نمود. در تحقیق حاضر، به منظور معرفی یک روش مناسب جهت پیش‌بینی خشک‌سالی برای یک ماه آتی، چهار روش هوش مصنوعی شامل یادگیری عمیق (از شبکه الکسنت که یکی از شبکه‌های کاتولوشن می‌باشد استفاده شده است)، الگوریتم K نزدیک ترین همسایه، ماشین بردار پشتیبان چند طبقه و درخت تصمیم در نظر گرفته شد. داده‌های بارندگی ۱۱ ایستگاه سینوتوک استان بزد طی دوره آماری ۱۹۸۸-۲۰۱۷ (۲۰۱۷ تا ۱۹۸۸) به صورت ماهانه به عنوان داده‌های آزمایشی مورد استفاده قرار گرفتند. شاخص بارش استاندارد شده (SPI) برای نشان دادن وضعیت خشک‌سالی از نظر سدت و مدت در مقیاس‌های زمانی ۱، ۳، ۶، ۹، ۱۲، ۲۴ و ۳۶ ماهه محاسبه گردید. در ابتدا داده‌های بارش به عنوان ورودی شبکه‌های عصبی و کلاس‌بندی شاخص بارش استاندارد شده به عنوان خروجی شبکه‌ها قرار داده شد. ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد داده‌ها برای تست شبکه‌ها به کار گرفته شد. نتایج نشان داد که تمامی شبکه‌ها توانایی پیش‌بینی خشک‌سالی را داشته‌اند، بر اساس معیار ارزیابی مacro-<sup>f1</sup> شبکه یادگیری عمیق در مقیاس زمانی ۱ ماهه با ۲۲/۷۱ درصد، ناکارآمدترین روش و درخت تصمیم با ۶۴/۶۵ درصد، کارآمدترین روش بوده‌اند، اما با افزایش مقیاس زمانی، شبکه یادگیری عمیق عملکرد خود را بهبود بخشید، به طوریکه در مقیاس زمانی ۲۴ ماهه با ۶۵/۳۵ درصد، بهترین عملکرد مربوط به شبکه یادگیری عمیق و بعد از آن، شبکه ماشین بردار پشتیبان با ۵۷/۴۰ درصد، قرار گرفت.

واژه‌های کلیدی: خشک‌سالی، شاخص بارش استاندار شده، هوش مصنوعی، یادگیری عمیق، الکسنت، ریکارنس پلات.

#### مقدمه

کمبود یا کاهش مقدار بارندگی در طی دوره‌هایی به وجود می‌آید و باعث به هم خوردن تعادل میان تأمین آب و هدر رفت آن از طریق تبخیر و تعرق و کمبود رطوبت خاک می‌گردد، در صورتی که خشکسالی هواشناسی مدت زیادی ادامه پیدا کند، حجم جریان رودخانه‌ها و سطح آب‌های زیرزمینی کاهش می‌یابد. قحطی، مرگ‌ومیر، مهاجرت‌های دسته‌جمعی و گسترده، خشکسالی اقتصادی و اجتماعی را موجب می‌گردد (بدراfsan ۱۳۸۱). خشکسالی به عنوان یکی از مهم‌ترین بلایای طبیعی است که ممکن است در هر رژیم آب و هوایی اتفاق بیافتد. از آنجا که وقوع خشکسالی اجتناب‌ناپذیر است، بنابراین شناخت آن به منظور مدیریت بهینه منابع آب، از اهمیت بسزایی برخوردار است (حسن‌زاده و همکاران ۱۳۹۰).

پیش‌بینی خشکسالی برای مدیریت بهتر این پدیده امری ضروری است. این مهم برای مناطق مرکزی ایران که شرایط آب و هوایی آن بهشدت متأثر ای خشکسالی است اهمیت بیشتری دارد. صمدیان‌فرد و اسدی (۱۳۹۶) پیش‌بینی خشکسالی با استفاده از شاخص بارش استاندارد شده (SPI<sup>۱</sup>) را در ایستگاه سینوپتیک تبریز در بازه زمانی سال‌های ۱۳۵۸ تا ۱۳۹۱ با استفاده از روش‌های رگرسیونی بردار پشتیبان و رگرسیون خطی بررسی کردند. نتیجه حاصل شده نشان داد هر دو روش مورد مطالعه شامل رگرسیون بردار پشتیبان و خطی چندگانه پیش‌بینی‌های مناسبی از نمایه‌های خشکسالی داشته‌اند و می‌توانند با اطمینان قابل قبولی مورد استفاده قرار گیرند. کریسپو و مورا (Crespo & Mora, ۱۹۹۳) برای پیش‌بینی خشکسالی در اسپانیا از مدل شبکه‌های عصبی مصنوعی استفاده نمودند. آن‌ها از شبکه پرسپترون چندلایه و الگوریتم پس انتشار خطا برای آموزش شبکه استفاده کردند. نتیجه بررسی‌های آن‌ها نشان داد که مدل شبکه عصبی مصنوعی می‌تواند پیش‌بینی‌هایی با دقت بالا از تعداد خشکسالی‌ها و طول متوسط خشکسالی ارائه نماید. ونگ و دینگ (Wang & Ding, ۲۰۰۳) برای پیش‌بینی سری‌های زمانی کوتاه مدت و بلند مدت هیدرولوژیکی از مدل ترکیبی شبکه عصبی-موجکی استفاده نمودند. آن‌ها برای انجام این کار از سری‌های زمانی تراز ماهانه آب زیرزمینی و جریان روزانه رودخانه‌ای در چین بهره جستند و به این نتیجه رسیدند که مدل ترکیبی، باعث افزایش دقت و صحت پیش‌بینی می‌شود. بوناکورسو و همکاران (Bonaccorso et al., ۲۰۰۳) خشکسالی را در سیسیل از سال ۱۹۹۶ تا ۱۹۹۶ تجزیه و تحلیل کردند. برای شناخت خشکسالی منطقه داده‌های بارش NCEP/NCAR و داده‌های حاصل از ۴۳ سنجنده که بروی سطح جزیره به صورت یکنواخت قرار دارند، تجزیه و تحلیل انجام شده است و برای بررسی تغییر خشکسالی بلندمدت شاخص بارش SPI بکار برده شد. شاخص بارش SPI به دلیل توانایی نظارت بر شرایط اقلیمی در طیف وسیعی از مقیاس زمانی دارد، برای ارزیابی وقوع خشکسالی در نظر گرفته شده است. در نتایج حاصل، شاخص خشکسالی از دهه ۷۰ به بعد نشان دهنده دوره‌های خشکسالی بیشتری بود. تریپاتھی و همکاران (Tripathi et al., ۲۰۰۶) از تکنیک ماشین بردار پشتیبان برای برآورد آماری بارندگی ماهانه در هند استفاده کردند. نتایج نشان داده است که مدل ماشین بردار پشتیبان به عنوان گزینه برتر نسبت به سایر روش‌های معمول جهت پیش‌بینی بارش به روش آماری می‌تواند مورد استفاده قرار گیرد. پائلو و پیرایا (Paulo & Pereira, ۲۰۰۷) با استفاده از شاخص بارش استاندارد شده مجموع داده‌های ۶۷ سال مدل مارکوف برای چند مکان در آنجلو واقع در جنوب پرتغال، برای توصیف خشکسالی بکار برده شده است. در مدل مارکوف از دو فرمالیسون همگن و غیر همگن استفاده شده است و برای شاخص بارش SPI، مقیاس‌های زمانی ۳ تا ۲۴ ماه مورد استفاده قرار گرفت، مقیاس‌های زمانی کمتر و یا طولانی‌تر ممکن است تغییرات متغیری را نشان دهد. در بین دو فرمالیسون همگن و غیر همگن، غیر همگن نتیجه بهتری برای پیش‌بینی در منطقه از خود نشان داده است. میشرا و همکاران (Mishra et al., ۲۰۰۷) برای پیش‌بینی خشکسالی در حوضه‌ای در هند از یک مدل ترکیبی استفاده نمودند. به این منظور آن‌ها مدل ترکیبی خود را از ترکیب یک مدل استوکستیک با شبکه عصبی ایجاد کردند، آن‌ها

<sup>۱</sup>. Standardized Precipitation index

پیش‌بینی خشکسالی را بر اساس شاخص SPI با استفاده از یک مدل استوکستیک، دو مدل شبکه عصبی و دو مدل ترکیبی انجام دادند. مدل استوکستیک، ARIMA، دو مدل شبکه عصبی شامل مدل مستقیم چندمرحله‌ای شبکه عصبی و مدل بازگشتی چندمرحله‌ای شبکه عصبی و مدل‌های ترکیبی شامل مدل تصادفی شبکه عصبی با رویکرد مستقیم بودند. مقایسه پیش‌بینی‌های پنج مدل نشان داد مدل شبکه عصبی با رویکرد مستقیم به خوبی می‌تواند خشکسالی را در حوضه مورد مطالعه پیش‌بینی کند. آنانده‌ی و همکاران (Anandhi et al., ۲۰۰۸) برای بارش‌های نامناسب حوضه رودخانه‌ای در هند گزارش ویژه‌ای از سناریوهای انتشار (SRES) با استفاده از ماشین بردار پشتیبان ارائه کردند. متغیرهای پیش‌بینی کننده احتمالی از، پیش‌بینی محیطی (NCEP) برای بازه زمانی ۱۹۷۱-۲۰۰۰ و شبیه‌سازی‌ها از مدل گردش عمومی نسل سوم CGCM<sup>۳</sup> برای سناریوهای انتشار SRES A2 و ۱B COMMIT برای دوره ۱۹۷۱ تا ۲۱۰۰ استخراج شدند. متغیرهای NCEP که به طور واقع‌بینانه توسط CGCM<sup>۳</sup> شبیه‌سازی شدند. نتایج نشان داد بارش در آینده برای تمامی سناریوهای مطرح شده در آینده افزایش یابد. آکسوسی و داهمشی (Aksoy & Dahamsheh, ۲۰۰۹) در پژوهشی در منطقه خشک و نیمه‌خشک در نیمه‌ی شرقی اردن به وسیله شبکه عصبی مصنوعی به پیش‌بینی بارش ماهانه پرداخته‌اند. آنان مدل پرسپترون چندلایه و شبکه‌ی رادیال بیس برای سه ایستگاه (باقورا، امان، صفوی) به کار برده‌اند و با به کار گیری نتایج میانگین مربعات خطأ، میانگین خطای مطلق و ضریب تبیین ارزیابی شده، دریافتند که بهترین مدل سنجیده شده برای سه ایستگاه مدل پرسپترون چند لایه می‌باشد. پارتال و سیگیزاغلو (Partal & Cigizoglu, ۲۰۰۹) از مدل ترکیبی شبکه عصبی-موجکی برای پیش‌بینی بارش روزانه در ترکیه استفاده نمودند. نتایج تحقیق مذکور نشان داد که مدل ترکیبی قابلیت برازش بهتری را بر داده‌های مشاهداتی دارد، مخصوصاً برای ماههای تابستان با بارش صفر و همچنین ماههای دیگر که بارش حداکثری اتفاق می‌افتد. همچنین از مقایسه مدل ترکیبی با مدل شبکه عصبی معمولی و مدل رگرسیون خطی چنین نتیجه‌گیری می‌شود که کارایی مدل‌های اشاره شده از مدل ترکیبی کمتر است. ساتاری و همکاران (Sattari et al., ۲۰۱۲) با استفاده از داده‌های بارش، باد، رطوبت و دمای ماهانه ۱۸ ایستگاه هواشناسی منطقه آنکارا واقع در کشور ترکیه از سال ۱۹۲۶ تا ۲۰۰۶ شرایط خشکسالی را با روش درخت تصمیم بررسی کرده‌اند. روش پیوند تصادفی، که یک روش سلسله مراتبی است برای تحلیل خوش‌های، و خشکسالی تنها با شاخص SPI طبقه‌بندی شد. نتایج به دست آمده نشان می‌دهد صفات، به استثنای بارش و باد در شکل‌گیری درخت تصمیم ناکارآمد بودند. اگر تعداد داده‌ها بالاتر و داده‌های ناقص پایین آمده باشد، نتایج به دست آمده می‌تواند صحیح‌تر و رقیق‌تر باشد. یوریکلی و همکاران (Yurekli et al., ۲۰۱۲) از تکنیک درخت تصمیم جهت ارزیابی و پیش‌بینی طبقات خشکسالی در حوزه‌ای در ترکیه استفاده کرده‌اند و نتایج را با روش طبقه‌بندی و تحلیل خشکسالی بر اساس شاخص بارش مقایسه نموده‌اند. مقایسه نتایج، تفاوت قابل ملاحظه‌ای (SPI) را در طبقه‌بندی خشکسالی بر اساس این دو روش نشان نداده است. شاه و همکاران (Shah et al., ۲۰۱۵) به منظور محاسبه شاخص خشکسالی برای منطقه سورات گجرات با استفاده از شاخص بارش استاندارد SPI، شاخص بارش استاندارد شده برای مشاهده و توصیف خشکسالی بر اساس داده‌های بارندگی ۴۰ ساله منطقه سورت استفاده شده است. یافتن شاخص خشکسالی با مقیاس ۱۲ ماهه و مقایسه با خشکسالی واقعی ایستگاه مقادیر مثبت شاخص بارش استاندارد شده به شرایط نرمال به شرایط مرتبط نشان می‌دهد و مقادیر منفی نشان دهنده شرایط طبیعی برای خشک شدن می‌باشد. سعدا و ابورمان (Saada & Abu-Romman) به منظور شبیه‌سازی و مدل‌سازی شاخص بارش استاندارد شده در اردن از داده‌های بارندگی ۵ ایستگاه در مدت زمان ۱۹۸۳ تا ۲۰۱۳ استفاده کرده‌اند. برای تجزیه و تحلیل داده‌های بارندگی ماهانه شاخص بارش SPI ۱۲ ماهه و برای شبیه‌سازی داده‌ها از مدل (CARMA) استفاده شده است. مدل (CARMA) با حفظ ساختار همبستگی بین ۵ ایستگاه شاخص بارش استاندارد شده ۱۲ ماهه را به خوبی شبیه‌سازی کرده است. مقیاس‌های زمانی کوتاه‌تر شاخص بارش استاندارد شده (مانند ۱ و ۳ ماه) به دلیل اینکه

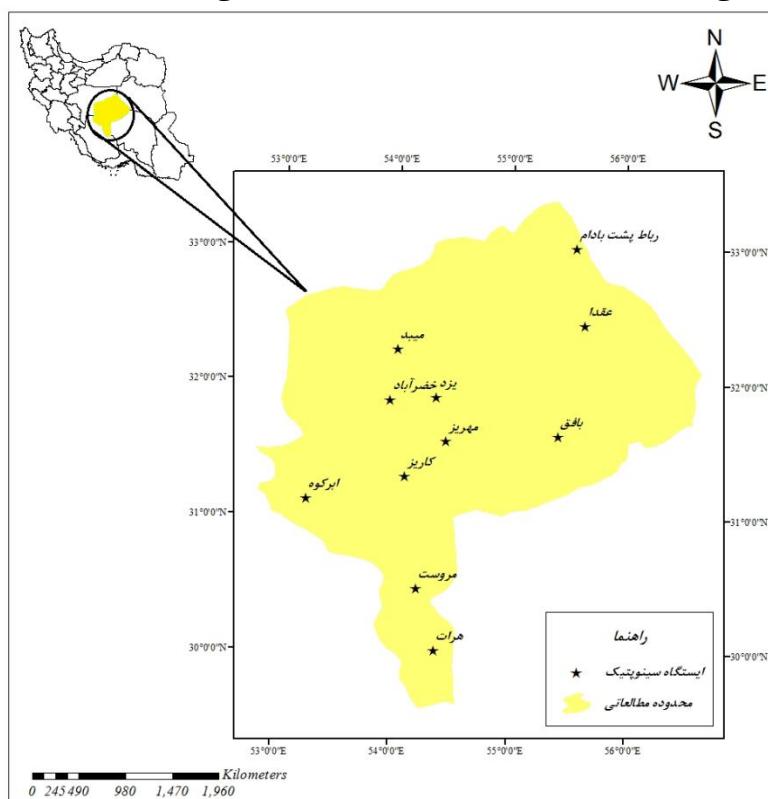
اردن یک کشور خشک است و شاخص بارش استانداردشده در مقیاس زمانی کوتاه‌تر از ضریب اطمینان پایینی برخوردار می‌باشد استفاده نشد. سینگ<sup>۱</sup> (Singh, ۲۰۱۸) به منظور پیش‌بینی بارش موسمی تابستانی در هند (ISMR) از سه تکنیک فازی، آنتروپی و شبکه عصبی استفاده کرده است. سری داده‌های ISMR به صورت فصلی و ماهانه بوده و به دو بخش داده‌های آموزشی (۱۹۶۰ تا ۱۸۷۱) و داده‌های تست (۱۹۶۱ تا ۲۰۱۴) تقسیم گردید. ISMR به دلیل داشتن طبیعت نامشخص یک روش به تنها‌ی نمی‌تواند آن را پیش‌بینی کند، بدین منظور روش فازی برای نشان دادن عدم قطعیت نامشخص ایجاد شد. آنتروپی نشان دادن خصوصیات ذاتی و شبکه عصبی برای نشان دادن نتیجه نهایی مورد استفاده قرار گرفت. نتایج نشان داد این روش کارآمد بوده است.

پژوهش حاضر با هدف معرفی یک روش هوش مصنوعی مناسب به منظور پیش‌بینی خشکسالی صورت گرفته است. در این پژوهش از شبکه الکسنت که یک شبکه پردازش تصویر است برای پیش‌بینی خشکسالی استفاده است داده‌های بارندگی با ایده روش ریکارنس پلات به صورت عکس درآمده‌اند.

## داده‌ها و روش کار

### (الف) قلمرو جغرافیایی مورد مطالعه

به منظور معرفی کارآمدترین شبکه عصبی در پیش‌بینی خشکسالی، منطقه یزد واقع در ایران مرکزی با موقعیت جغرافیایی، ۲۹ درجه و ۴۸ دقیقه تا ۳۳ درجه و ۳۰ دقیقه شمالی و ۵۲ درجه و ۴۵ دقیقه تا ۵۶ درجه و ۳۰ دقیقه شرقی از نصف‌النهار مبدأ به عنوان منطقه مطالعاتی در نظر گرفته شد (شکل ۱). داده‌های بارندگی ۱۱ ایستگاه سینوپتیک استان یزد طی دوره آماری ۲۹ سال (۱۹۸۸ - ۲۰۱۷) مورد بررسی قرار گرفتند.



شکل ۱. موقعیت قرارگیری ایستگاه‌های مطالعاتی در استان یزد

### ب) روش کار

داده‌های بارندگی استان یزد طی دوره آماری ۲۹ ساله (۱۹۸۸ تا ۲۰۱۷) به صورت ماهانه مورد استفاده قرار گرفت. به منظور مشخص کردن مدت و شدت خشکسالی از شاخص بارش استاندارد شده در مقیاس‌های زمای ۱، ۳، ۶، ۹ و ۱۲، ۲۴ استفاده گردید و برای پیش‌بینی خشکسالی،  $\chi$  روش هوش مصنوعی یادگیری عمیق، الگوریتم K نزدیک‌ترین همسایه، ماشین بردار پشتیبان چند طبقه و درخت تصمیم انتخاب گردید. در هر  $\chi$  روش ۸۰ درصد داده‌ها برای آموزش شبکه و ۲۰ درصد داده‌ها برای تست در نظر گرفته شد. شبکه‌های هوش مصنوعی استفاده شده براساس شاخص بارش استاندارد شده شدت خشکسالی را در ۷ کلاس (کلاس‌های شاخص بارش استاندارد شده به صورت کمی از شماره ۱. خشکسالی بسیار شدید تا شماره ۷. تراسالی بسیار شدید برای روش‌ها تعریف شده است)، کلاس‌بندی کرده و پیش‌بینی صورت گرفته است. اما داده‌های ورودی برای شبکه یادگیری عمیق به صورت عکس بود که از روش ریکارنس پلات ایده گرفته شد، سری زمانی داده‌های بارندگی به عکس تبدیل گردید و به عنوان ورودی شبکه الکس نت (یک شبکه یادگیری عمیق) که یک شبکه پردازش عکس است قرار گرفت.

### • شاخص بارش استاندارد شده (SPI):

این شاخص در سال ۱۹۹۵ توسط مک‌کی و همکارانش ارائه شد. این شاخص بر اساس تفاوت بارش از میانگین برای یک مقیاس زمانی مشخص و سپس تقسیم آن بر انحراف معیار به دست می‌آید و تنها فاکتور مؤثر در محاسبه این شاخص عنصر بارندگی می‌باشد. این شاخص را می‌توان در مقیاس‌های زمانی ۳، ۶، ۹، ۱۲، ۲۴ و ۴۸ ماهه محاسبه کرد. ویژگی دیگر شاخص بارش استاندارد شده این است که بر اساس این شاخص علاوه بر محاسبه شدت خشکسالی، مدت آن را نیز می‌تواند تعیین نماید. شاخص بارش استاندارد شده بر اساس احتمال بارش برای هر بازه زمانی می‌باشد. و به منظور هشدار اولیه و پایش شدت خشکسالی اهمیت زیادی دارد. این شاخص برای کمی نمودن کمبود بارش در بازه‌های زمانی چندگانه طراحی شده است (بذرافشان ۱۳۸۱). تجربه نشان داده است که توزیع گاما توزیع مناسبی برای برازش روی داده‌های بارندگی است، در صورتی که فرض شود بارندگی در یک منطقه از توزیع گاما تبعیت می‌کند و  $\chi$  مقادیر بارندگی باشد،تابع چگالی احتمال دو پارامتری گاما به صورت زیر تعریف می‌شود: (جهانگیری ۱۳۹۴)

$$(X)f = \frac{1}{\beta^{\alpha} \Gamma(\alpha)} \chi^{\alpha-1} e^{-\frac{\chi}{\beta}} \quad \chi > 0. \quad \text{رابطه (۱)}$$

در رابطه  $\alpha$ ،  $\beta$  پارامتر شکل،  $\Gamma$  تابع گاما است که به صورت زیر تعریف می‌شود:

$$\Gamma(\alpha) = \int_{0}^{\infty} \gamma^{\alpha-1} e^{-\gamma} d\gamma \quad \text{رابطه (۲)}$$

ضرایب  $\beta$  و  $\alpha$  بهینه نیز از طریق روابط زیر حساب می‌شوند:

$$\hat{\alpha} = \frac{1}{\bar{A}} [1 + \sqrt{1 + \frac{4A}{3}}] \quad \text{رابطه (۳)}$$

$$\bar{A} = \ln(\bar{\chi}) - \frac{\sum \ln(x)}{n} \quad \text{رابطه (۴)}$$

$$\hat{\beta} = \frac{\bar{\chi}}{\hat{\alpha}}$$

به منظور محاسبه  $A$ ، باید دقت کرد که پارامتر  $n$  تعداد مشاهدات بارندگی است.

در محاسبه شاخص SPI از توزیع احتمال تجمعی گاما استفاده می‌شود، که رابطه آن به صورت زیر است:

$$F(\chi) = \frac{1}{\Gamma(\alpha)} \int_{0}^{\chi} t^{\hat{\alpha}-1} e^{-t} dt \quad t = \chi/\hat{\beta} \quad \text{رابطه (۵)}$$

از آنجا که در رابطه بالا مقدار لگاریتم صفر تعریف نشده است و توزیع بارندگی ممکن است مقادیر صفر داشته باشد، بنابراین در این شرایط احتمال تجمعی از رابطه ۶ محاسبه می‌شود.

$$H(\chi) = q + (1-q)F(\chi) \quad \text{رابطه (۶)}$$

در این رابطه  $q$  احتمال بارندگی صفر است. برای محاسبه  $q$  می‌توان از رابطه کالیفرنیا (رابطه ۷) استفاده کرد.

$$q = \frac{m}{n} \quad \text{رابطه (۷)}$$

در این رابطه  $m$  تعداد داده‌های صفر موجود در سری زمانی و  $n$  نیز تعداد کل داده‌های بارندگی است. گام بعدی در محاسبه SPI، انتقال احتمال تجمعی  $H(x)$  که از توزیع گامای تجمعی به دست آمده به توزیع نرمال استاندارد تجمعی با میانگین صفر و انحراف معیار یک است. در واقع شاخص بارش استاندارد شده عبارت است از متغیری ازتابع توزیع نرمال استاندارد، که مقدار احتمال تجمعی آن با مقدار احتمال تجمعی متغیر مدنظر در توزیع گاما مساوی باشد. جدول ۳-۳ طبقه‌بندی شدت خشکسالی بر اساس شاخص شاخص بارش استاندارد شده را نشان می‌دهد.

جدول ۱. تقسیم‌بندی ارزیابی شاخص بارش استاندارد شده (SPI)

SPI	شاخص	وضعیت خشکسالی
-۲	- یا کمتر	خشکسالی بسیار شدید (ED)
-۱/۵۰ تا -۱/۹۹	(SD)	خشکسالی شدید
-۱/۴۹ تا -۱	(MD)	خشکسالی متوسط
۰/۹۹ تا -۰/۹۹	(N)	نرمال
۱/۴۹ تا ۱	(MW)	ترسالی متوسط
۱/۹۹ تا ۱/۵۰	(SW)	ترسالی شدید
۲	(EW)	ترسالی بسیار شدید
۱ بیشتر		

### • پلات برگشتی<sup>۱</sup>

اکمون و همکاران (۱۹۸۷) (Eckmann et al., ۱۹۸۷) ریکارنس پلات را معرفی کردند که راه را برای تجسم ماهیت دوره‌ای یک مسیر از طریق یک فاز فضایی ارائه می‌دهد. ساخت ریکارنس پلات ما را قادر می‌سازد تا جنبه‌های متفاوتی از مسیر فضایی M را از طریق نمایندگی دو بعدی بررسی کنیم. ریکارنس پلات مجموعه‌ای از جفت زمان‌هایی را نشان می‌دهد که مسیر آن در یک مکان است یعنی مجموعه  $\{(i, j) | \vec{x}(i) = \vec{x}(j)\}$  مثلاً اگر این مسیر به طور دوره‌ای با دوره T باشد، می‌تواند بسیاری از موارد را نشان دهد و سپس تمام جفت بارها با چندین دوره T تفکیک می‌شوند و به صورت خطوط مورب قابل مشاهده هستند. برگشتی/غیر برگشتی<sup>۲</sup> را می‌توان با استفاده از تابع باینری ثبت کرد.

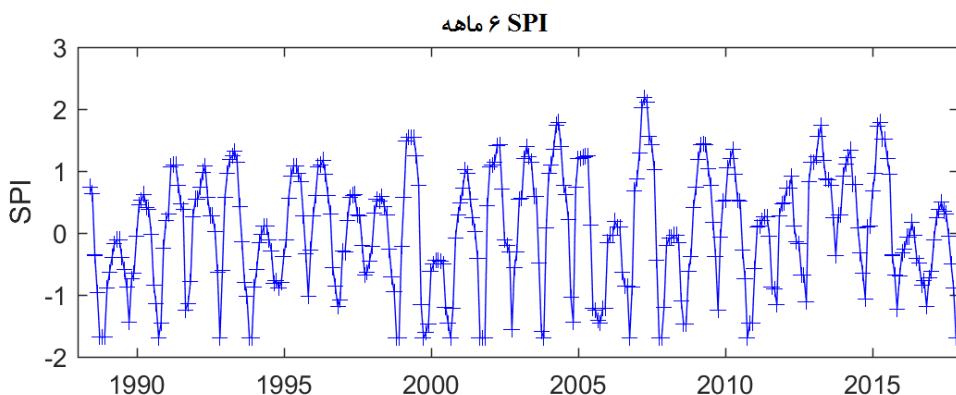
$$R(i, j) = \begin{cases} 1, & \text{if } \|\vec{x}(i) - \vec{x}(j)\| \leq \epsilon \\ 0, & \text{otherwise} \end{cases} \quad \text{رابطه (۸)}$$

همانطور که توضیح داده شد ریکارنس پلات یک روش برای تبدیل سری‌های زمانی از حالت نموداری به صورت عکس می‌باشد که در آن هر داده براساس معیارهای مختلف دارای طیف رنگی است. در این پژوهش برای تبدیل داده‌ها به عکس از این روش ایده گرفته شده است. عکس‌ها به دو صورت رنگی و سیاه و سفید تهیه گردید. هر عکس رنگی متشکل از ۳ صفحه R, G, B می‌باشد و هر کدام از صفحه‌ها به صورت جداگانه ساخت شد و نهایتاً با یکدیگر ادغام گردید، هر پیکسل در عکس‌های رنگی مقدار عددی بین ۰ تا ۲۵۵ دارد و اعداد در هر صفحه بین ۰ تا ۲۵۵ گنجانده شد.

<sup>۱</sup>Recurrence plot

<sup>۲</sup>Recurrence non- / Recurrence

برای ساخت عکس رنگی نیاز به سه صفحه R، G و B می‌باشد، این سه لایه بر مبنای فرمول شاخص بارش استاندارد شده با استفاده از ایده ریکارنس پلات ساخته شد، اما به دلیل کمبود داده‌ها برای ساخت صفحه‌ها، با کمک مباحث ریاضی تغییراتی در چگونگی ساخت صفحه‌ها صورت گرفت، چگونگی ساخت هر صفحه به شرح زیر می‌باشد: شکل (۲)، نمودار شاخص بارش استاندارد شده ۶ ماهه ایستگاه مهریز می‌باشد، سه صفحه R، G و B با استفاده از داده‌های بارندگی این ایستگاه در مقیاس زمانی ۶ ماهه ساخته شد (که به عنوان نمونه ارائه گردیده است).



شکل ۲. SPI ۶ ماهه ایستگاه مهریز

صفحه R :

داده‌های ما در آرایه یک بعدی به طول n هستند. برای مثال داده‌های خام در بارش ۶ ماهه یک آرایه به طول 6 می-باشد که در آرایه آن برابر با مقدار بارش در ماه متناظر آن است. این آرایه d نامیده می‌شود.

1	....	n
---	------	---

برای تولید صفحه R یک آرایه دو بعدی n\*n داریم که فرمول محاسبه برای هر عنصر به صورت زیر است :

$$r_{i,j} = |d_i - d_j| \quad \text{رابطه (۹)}$$

صفحه G :

برای تولید صفحه G یک آرایه دو بعدی n\*n داریم که فرمول محاسبه برای هر عنصر به صورت زیر است :

$$g_{i,j} = \frac{d_j}{\sum_{k=1, k \neq i}^n d_k} \quad \text{رابطه (۱۰)}$$

صفحه B :

برای تولید صفحه B یک آرایه دو بعدی n\*n داریم که فرمول محاسبه برای هر عنصر به صورت زیر است :

$$b_{i,j} = \frac{r_{i,j} + g_{i,j}}{2} \quad \text{رابطه (۱۱)}$$

با استفاده از سه صفحه ساخته در نرم افزار متلب و ادغام آنها خروجی به صورت عکس بوده است که به عنوان ورودی شبکه الکسنت قرار داده شد.

### • شبکه الکس-نت

شبکه عصبی کانولوشن عمیق نیز یکی از مهمترین و پرکاربردترین الگوریتم‌های مورد استفاده در یادگیری عمیق است (حسنپور و سعادتی ۱۳۹۵). معماری‌های زیادی برای شبکه‌های کانولوشنال عمیق در سال‌های اخیر ارائه شده است. معماری و نحوه آموزش شبکه‌ها از اهمیت زیادی برخوردار است و معمولاً بسته به نوع داده‌های مدنظر تعیین می‌شود. VGG و الکس-نت دو شبکه بسیار مشهور در زمینه دسته‌بندی تصاویر هستند این دو شبکه روی مجموعه داده عظیمی از تصاویر که شامل ۱۰۰۰ کلاس متفاوت هستند آموزش دیده‌اند. از آنجایی که فراهم کردن این همه داده و آموزش شبکه‌ای با این تعداد داده بسیار هزینه‌بر استنده معمولاً محققان از وزن‌های این شبکه‌ها به عنوان وزن‌های اولیه شبکه برای داده‌های مدنظرشان استفاده می‌کنند سپس با آموزش روی داده‌های خودشان وزن‌های شبکه را تنظیم و یا روش‌های یادگیری انتقال مانند وزن‌های شبکه و یا ساختار شبکه را مطابق آنچه مدنظرشان است بهینه و تغییر می‌دهند (سبکرو ۱۳۹۵).

### • معیارهای ارزیابی

برای ارزیابی اثربخشی استراتژی طبقه‌بندی، از معیارهای استاندارد صحت، دقت میکرو- $F_1$  و مacro- $F_1$  استفاده شده است (Benevenuto et al. ۲۰۰۹).

صحت (R) کلاس X، نسبت تعداد داده‌هایی که به درستی کلاس‌بندی شده‌اند به تعداد داده کلاس X است. دقت (p) کلاس X، نسبت تعداد داده‌هایی است که به درستی کلاس‌بندی شده‌اند به کل داده‌هایی که پیش‌بینی شده، عضو کلاس X باشند شاخص‌های دقت(p) و صحت(r) به این صورت محاسبه می‌شوند:

$$\begin{aligned} p &= a / (a + c) \\ r &= a / (a + b) \end{aligned} \quad \text{رابطه (۱۲)}$$

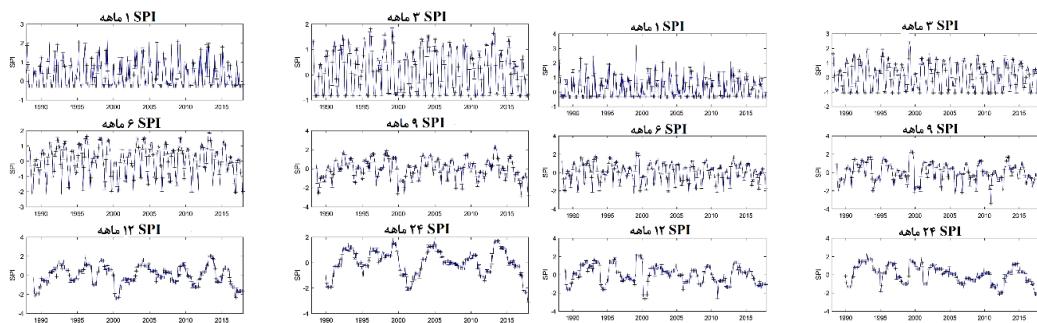
معیار  $F_1$  میانگین هارمونیک بین دو معیار دقت و صحت است، و به صورت  $F_1 = 2pr / (p + r)$  تعریف شده است. دو نوع  $F_1$ ، یعنی میکرو و مacro، معمولاً برای ارزیابی اثربخشی طبقه‌بندی به کار می‌روند.

معیار میکرو- $F_1$  با محاسبه دقت عمومی و صحت تمام طبقات به دست می‌آید و سپس  $F_1$  محاسبه می‌شود. معیار میکرو- $F_1$ -اهمیت یکسانی را برای دسته‌بندی هر داده در نظر می‌گیرد و اساساً قابلیت دسته‌بندی برای پیش‌بینی کلاس صحیح برای هر داده را اندازه‌گیری می‌کند. در مقابل، برای محاسبه مقدار مacro- $F_1$  ابتدا مقدار  $F_1$  برای هر کلاس به صورت جداگانه محاسبه می‌شود، سپس میانگین تمام کلاس‌ها محاسبه می‌شود. معیار مacro- $F_1$  مستقل از اندازه هر کلاس اهمیت یکسانی برای هر کلاس قائل است.

به این ترتیب، دو معیار ارزیابی تکمیلی برای اثربخشی طبقه‌بندی ارائه شد. معیار مacro- $F_1$  به منظور بررسی اینکه آیا طبقه‌بندی در کلاس‌های کوچک‌تر نیز به خوبی کارایی دارد؛ اهمیت دارد، به خصوص در جاهایی که توزیع کلاس بسیار اریب است، همان طور که برای داده‌های ما نیز این‌گونه است. (بینونتو ۲۰۱۰)

### شرح و تفسیر نتایج

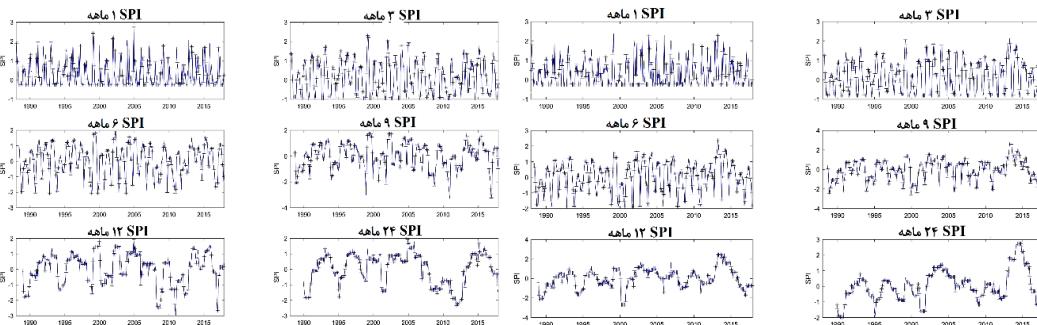
برای هر یک از ۱۱ ایستگاه سینوپتیک استان یزد شاخص بارش استاندارد شده (SPI) محاسبه گردید، نتایج به صورت نمودار در مقیاس‌های زمانی ۱، ۳، ۶، ۹، ۱۲ و ۲۴ ماهه آورده شده است. (بینونتو ۲۰۱۰)



شکل ۴. ایستگاه ریاض پشت بادام

در نمودار SPI مربوط به ایستگاه یزد در تمامی مقیاس‌های زمانی SPI در سال ۱۹۹۹ ترسالی شدید قابل روئیت است، در ۹ SPI و ۱۲ SPI خشکسالی‌های شدیدی دیده می‌شود.

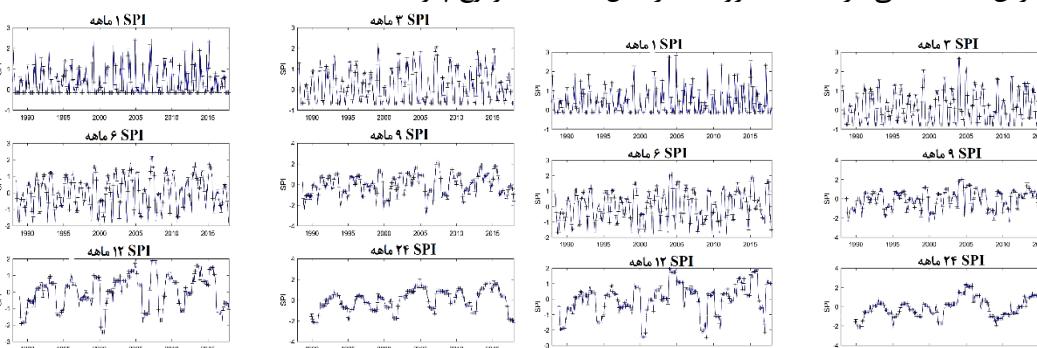
در ایستگاه ریاض پشت بادام در ۱ SPI ۱ ماهه و ۳ SPI ۳ ماهه وضعیت به صورت نرمال و ترسالی می‌باشد اما با افزایش مقیاس زمانی SPI خشکسالی‌های نمود پیدا می‌کنند.



شکل ۵. ایستگاه ریاض مروست

شکل ۵. ایستگاه میبد

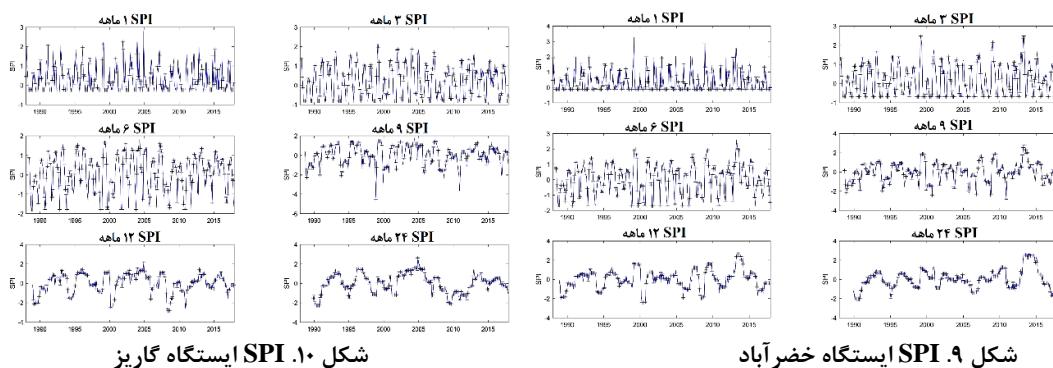
در شکل ۵ مشاهده می‌شود که ۶ SPI ، ۹ SPI و ۱۲ SPI ۱ ماهه در ایستگاه میبد نشان دهنده خشکسالی‌های شدیدی که در دوره زمانی‌های مختلفی رخ داده است. می‌توان گفت شدیدترین خشکسالی در ایستگاه مروست در سال ۲۰۱۱ به وقوع پیوسته است.



شکل ۶. ایستگاه ریاض مهریز

شکل ۶. ایستگاه هرات

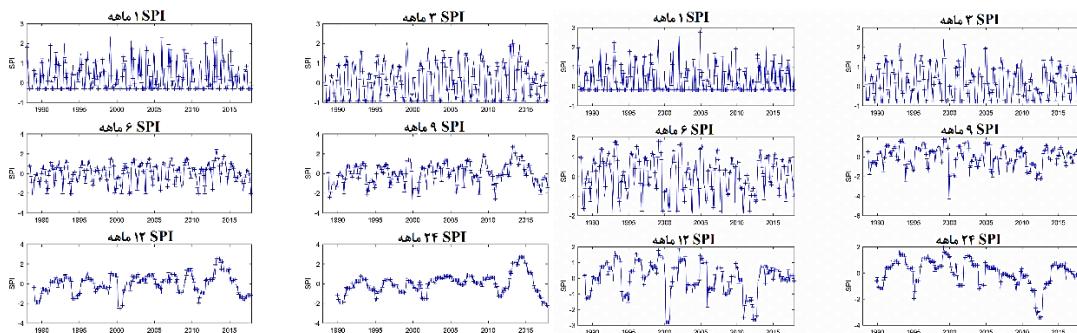
با توجه به شکل‌های ۷ و ۸ با افزایش مقیاس زمانی SPI دوره خشکسالی بیشتر می‌شود و در ۱۲ ماهه، سال‌های ۲۰۰۱ و ۲۰۰۹ خشکسالی باشدت بالایی به وقوع پیوسته است. در ایستگاه مهریز دوره‌های ترسالی و خشکسالی به صورت متناوب مشاهده می‌شود.



شکل ۱۰ SPI ایستگاه خضرآباد

شکل ۹ SPI ایستگاه خضرآباد

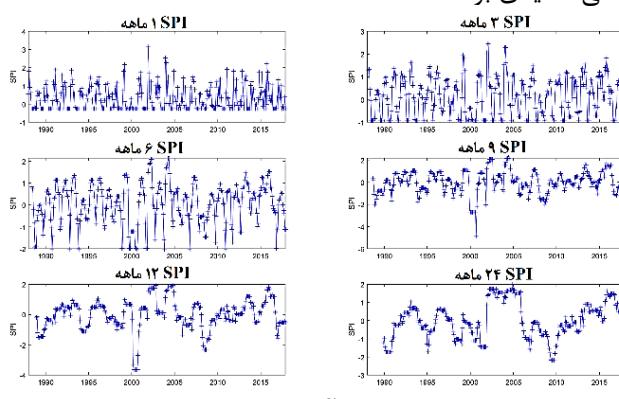
در ایستگاه خضرآباد (شکل ۹) در ۳ ماهه شدیدترین ترسالی تقریباً در سال ۱۹۹۸ به وقوع پیوسته است که در ۶، ۹، ۱۲، ۲۴ ماهه باشد کمتری قابل مشاهده است، در ۱۲ ماهه وقوع یک خشکسالی شدید در سال ۲۰۰۰ قابل مشاهده است. در ایستگاه گاریز در ۹ ماهه خشکسالی‌های بسیار شدیدی رخداده است، که در ۱۲ SPI باشد کمتری قابل مشاهده است.



شکل ۱۱ SPI ایستگاه بافق

شکل ۱۱ SPI ایستگاه بافق

ایستگاه بافق در ۶ و ۹ ماهه در سال ۲۰۰۰ خشکسالی شدیدی رخداده است که در ۲۴ SPI باشد تقریباً در سال ۲۰۱۳ مشاهده می‌شود. بر اساس مقادیر SPI در سال ۲۰۰۰ و ۲۰۱۱ خشکسالی شدیدی رخداده است و در سال ۲۰۱۴ ایستگاه عقداً دارای ترسالی شدیدی بوده است.




شکل ۱۳ SPI ایستگاه ابرکوه

با توجه به شکل (۱۳) در ایستگاه ابرکوه شدیدترین خشکسالی در سال ۲۰۰۰ به وقوع پیوسته است و بر اساس SPI ۱۲ و ۲۴ ماهه از سال ۲۰۰۶ تا ۲۰۰۲ ترسالی در این ایستگاه رخداده است.

روش ریکارنس پلات روشنی است برای تبدیل سری‌های زمانی به عکس، هر عکس از سه لایه R, G, B تشکیل می‌گردد برای تبدیل داده‌های بارندگی به عکس در مقیاس‌های زمانی ۱، ۳، ۶، ۹، ۱۲، ۲۴ و ۲۴ ماهه لایه‌های عکس‌ها با استفاده از فرمول بارش استاندارد شده ساخته شد و با ادغام این سه لایه خروجی به صورت عکس‌های سیاه و سفید (شکل ۱۵) و رنگی (شکل ۱۶) بدست آمد. عکس‌های سیاه و سفید دارای دو بعد  $f^1$  و زمینه باشند و مقدار هر پیکسل عددی بین ۱-۰ قرار دارد، عکس‌های سیاه و سفید ساخته شده به دلیل کم بودن داده‌های مورد استفاده از کیفیت عددی بین ۱-۰ قرار دارد، عکس‌های سیاه و سفید ساخته شده به دلیل کم بودن داده‌های مورد استفاده از کیفیت لازم برخوردار نبوده است از این رو عکس رنگی برای داده‌ها ساخته شد و به عنوان ورودی شبکه الکس نت قرار گرفتند.



شکل ۱۵. عکس سیاه و سفید



شکل ۱۶. عکس رنگی

جداول مربوط به معیارهای ارزیابی دقت (P)، صحت (R)، میانگین هارمونیک ( $f^1$ )، ماکرو- $f^1$  و میکرو- $f^1$  آورده شده است. برای معیارهای دقت (P)، صحت (R) و میانگین هارمونیک ( $f^1$ ) نتایج مربوط به کوتاه مدت، ۳ ماهه میان مدت، ۹ ماهه و بلندمدت ۲۴ ماهه آورده شده است، اما برای دو معیار ماکرو- $f^1$  و میکرو- $f^1$  نتایج مربوط به تمام مقیاس‌های زمانی آورده شده است.

جدول ۲. معیار ارزیابی دقت (P)

مقیاس زمانی	روش یادگیری	کلاس	۱	۲	۳	۴	۵	۶	۷
۳ ماهه	یادگیری عیقین		۳۳/۳۳	۴۷/۶۲	۵۴/۳۷	۹۱/۹۱	۰	۰	.
	K نزدیک‌ترین همسایه		۳۷/۵۰	۳۰/۳۰	۵۶/۱۲	۹۲/۷۲	۰	۰	.
	درخت تصمیم		۴۵/۴۵	۳۷/۵۰	۵۲/۳۸	۹۱/۸۵	۰	۰	.
	ماشین بردار پشتیبان		۳۳/۳۳	۷۱/۴۳	۵۴/۳۱	۹۲/۶۵	۰	۰	.
۹ ماهه	یادگیری عیقین		۶۶/۶۷	۵۰/۰۰	۴۹/۲۸	۸۱/۸۰	۵۱/۹۲	۴۶/۱۵	۵۰/۰۰
	K نزدیک‌ترین همسایه		۱۲/۵۰	۱۳/۳۳	۴۳/۲۴	۸۴/۷۳	۴۶/۱۵	۵۶/۷۶	۵۰/۰۰
	درخت تصمیم		۱۶/۶۷	۱۶/۶۷	۲۸/۸۷	۸۳/۱۴	۴۰/۲۸	۵۶/۶۷	۷۳/۶۸
	ماشین بردار پشتیبان		۰/۰۰	۰/۰۰	۴۹/۳۰	۸۲/۸۳	۶۶/۶۷	۶۰/۹۸	۷۳/۶۸
۲۴ ماهه	یادگیری عیقین		۹۰/۹۱	۷۲/۲۲	۶۷/۱۴	۹۰/۸۲	۷۴/۱۹	۶۶/۶۷	۶۰/۰۰
	K نزدیک‌ترین همسایه		۶۶/۶۷	۸/۸۲	۱۵/۷۹	۷۷/۶۱	۳۶/۷۳	۳۰/۲۳	۰/۰۰
	درخت تصمیم		۹/۰۹	۷/۶۹	۱۵/۰۰	۷۳/۹۴	۱۱/۵۴	۲۷/۰۳	۱۷/۵۵
	ماشین بردار پشتیبان		۱۰۰/۰۰	۰/۰۰	۰/۰۰	۷۲/۵۳	۰/۰۰	۴۶/۶۷	۰/۰۰

معیار دقت، نشان دهنده اطمینان روش یادگیری از کلاس تشخیص داده است. برای مثال روش یادگیری عمیق در کلاس ۱ به دقت ۳۳.۳۳ درصد در مقیاس زمانی ۳ ماهه دست پیدا کرده است، که بیانگر اطمینان ۳۳.۳۳ درصدی این روش یادگیری برای کلاس ۱ در مقیاس زمانی ۳ ماهه می‌باشد. به عبارت دیگر زمانی که در مقیاس زمانی ۳ ماهه روش یادگیری عمیق برای داده خاصی کلاس ۱ را پیش‌بینی می‌کند، ۳۳.۳۳ درصد اطمینان وجود دارد که کلاس واقعی آن داده ۱ بوده باشد و ۶۶.۳۳ درصد احتمال تعلق آن داده به کلاس دیگری وجود دارد. براساس معیار ارزیابی دقت عدد صفر به این معناست که شبکه نتوانسته است چنین کلاسی را تشخیص دهد.

با افزایش مقیاس زمانی روش‌های K نزدیک‌ترین همسایه، درخت تصمیم و ماشین بردار پشتیبان عملکردشان بهتر شده است، اما این بهبود کاملاً پایدار نبوده است، اما روش یادگیری عمیق بهبود مناسبی در معیار دقت داشته است و هر چقدر مقیاس زمانی افزایش پیدا می‌کند، اطمینان این روش نیز بر روی پیش‌بینی‌های کلاس‌های مختلف بیشتر می‌شود. برای مثال در کلاس ۲ یادگیری عمیق در بازه زمانی ۳ ماهه دقت ۴۷.۶۲ درصد، در بازه زمانی ۹ ماهه دقت ۵۰ درصدی و در بازه زمانی ۲۴ ماهه دقت ۷۲.۲۲ درصدی دست یافته است.

جدول ۳. معیار ارزیابی صحت (R)

۷	۶	۵	۴	۳	۲	۱	کلاس روش یادگیری	مقیاس زمانی
.	.	.	۹۴/۳۶	۵۴/۳۷	۳۴/۴۸	۳۷/۵۰	یادگیری عمیق	۳ ماهه
.	.	.	۹۳/۸۹	۵۳/۹۲	۳۵/۷۱	۴۲/۸۶	K نزدیک‌ترین همسایه	
.	.	.	۹۳/۵۷	۴۳/۱۴	۵۳/۵۷	۷۱/۴۳	درخت تصمیم	
.	.	.	۹۴/۸۳	۶۱/۷۶	۱۷/۸۶	۴۲/۸۶	ماشین بردار پشتیبان	
.	.	.	۹۴/۳۶	۵۴/۳۷	۳۴/۴۸	۳۷/۵۰	یادگیری عمیق	۹ ماهه
۷۶/۱۹	۵۲/۵۰	۴۴/۱۲	۸۵/۲۲	۳۹/۰۲	۱۳/۳۳	۱۲/۵۰	K نزدیک‌ترین همسایه	
۶۶/۶۷	۴۲/۵۰	۴۲/۶۵	۸۲/۳۴	۳۴/۱۵	۱۶/۶۷	۱۲/۵۰	درخت تصمیم	
۶۶/۶۷	۶۲/۵۰	۴۴/۱۲	۹۴/۴۳	۴۲/۶۸	۰/۰۰	۰/۰۰	ماشین بردار پشتیبان	
۶۰/۰۰	۵۱/۴۳	۷۴/۱۹	۹۵/۴۷	۶۲/۶۷	۴۸/۱۵	۶۶/۶۷	یادگیری عمیق	۲۴ ماهه
۰/۰۰	۳۸/۲۴	۲۹/۰۳	۸۳/۲۷	۸/۱۱	۱۱/۱۱	۴۲/۸۶	K نزدیک‌ترین همسایه	
۱۵/۷۹	۲۹/۴۱	۹/۶۸	۷۲/۰۵	۲۰/۲۷	۷/۴۱	۷/۱۴	درخت تصمیم	
۰/۰۰	۴۱/۱۸	۰/۰۰	۹۹/۸۰	۰/۰۰	۰/۰۰	۲۸/۵۷	ماشین بردار پشتیبان	

معیار صحت نشان دهنده توانایی روش یادگیری برای تشخیص صحیح داده‌های یک کلاس خاص می‌باشد، به عبارت دیگر چه درصدی از داده‌های یک کلاس توسط روش یادگیری مد نظر به درستی تشخیص داده شده‌اند. بر اساس معیار دقت در مقیاس زمانی ۳ ماهه هر ۴ روش یادگیری عمیق، K نزدیک‌ترین همسایه، درخت تصمیم و ماشین بردار پشتیبان نتوانسته‌اند کلاس‌های ۵، ۶ و ۷ را تشخیص بدene. در مقیاس زمانی ۹ ماهه ماشین بردار پشتیبان کلاس‌های ۱ و ۲ را تشخیص نداده است و در ۲۴ ماهه روش K نزدیک‌ترین همسایه کلاس ۷ و ماشین بردار پشتیبان کلاس‌های ۲، ۳، ۵ و ۷ را تشخیص نداده‌اند، میزان دقت در این کلاس‌ها صفر شده است (که به این معناست روش استفاده شده نتوانسته چنین کلاسی را تشخیص بدهد) در معیار صحت هم مقادیر صفر مربوط به کلاس‌هایی بوده‌اند که دقت آنها صفر شده است.

روش یادگیری عمیق در مقیاس زمانی ۳ و ۹ ماهه در معیار صحت عملکرد یکسانی داشته است ولی در مقیاس زمانی ۲۴ ماهه برای تمامی کلاس‌ها، معیار صحت آن افزایش داشته است. در مقیاس زمانی ۳ و ۹ ماهه اگرچه معیار صحت تغییری نداشته است، اما با توجه به معیار دقت می‌توان نتیجه گرفت که در مجموع روش یادگیری بهبود پیدا کرده و اطمینان از کلاس‌های پیش‌بینی شده افزایش پیدا کرده است.

جدول ۴. معیار ارزیابی میانگین هارمونیک بین R و P<sub>f1</sub>

کلاس								مقیاس زمانی
روش یادگیری								کلاس
۳ ماهه	.	.	.	۹۳/۱۲	۵۴/۳۷	۴۰/۰۰	۳۵/۲۹	یادگیری عمیق
	.	.	.	۹۳/۳۰	۵۵/۰۰	۳۲/۷۹	۴۰/۰۰	K نزدیک‌ترین همسایه
	.	.	.	۹۲/۷۰	۴۷/۳۱	۴۴/۱۲	۵۵/۵۶	درخت تصمیم
	.	.	.	۹۳/۷۳	۵۷/۸۰	۲۸/۵۷	۳۷/۵۰	ماشین بردار پشتیبان
۹ ماهه	۴۵/۰۰	۴۵/۰۰	۴۴/۶۳	۸۵/۱۱	۴۴/۷۴	۴۶/۴۳	۵۳/۳۳	یادگیری عمیق
	۶۰/۳۸	۵۴/۵۵	۴۵/۱۱	۸۴/۹۸	۴۱/۰۳	۱۳/۱۳	۱۲/۵۰	K نزدیک‌ترین همسایه
	۷۰/۰۰	۴۸/۵۷	۴۱/۴۳	۸۲/۷۴	۳۱/۲۸	۱۶/۶۷	۱۴/۲۹	درخت تصمیم
	۷۰/۰۰	۶۱/۷۳	۵۳/۱۰	۸۸/۲۵	۴۵/۷۵	۰/۰۰	۰/۰۰	ماشین بردار پشتیبان
۲۴ ماهه	۶۰/۰۰	۵۸/۰۶	۷۴/۱۹	۹۳/۰۹	۶۴/۸۳	۵۷/۷۸	۷۶/۹۲	یادگیری عمیق
	۰/۰۰	۳۳/۷۷	۳۲/۴۳	۸۰/۳۴	۱۰/۷۱	۹/۸۴	۵۲/۱۷	K نزدیک‌ترین همسایه
	۱۶/۶۷	۲۸/۱۷	۱۰/۵۳	۷۲/۹۸	۱۷/۲۴	۷/۵۵	۸/۰۰	درخت تصمیم
	۰/۰۰	۴۳/۷۵	۰/۰۰	۸۴/۰۱	۰/۰۰	۰/۰۰	۴۴/۴۴	ماشین بردار پشتیبان

معیار میانگین هارمونیک ترکیبی از معیارهای دقت و صحت است که در جدول فوق آورده شده است. این معیار نشان می‌دهد که ۳ روش K نزدیک‌ترین همسایه، درخت تصمیم و ماشین بردار پشتیبان با افزایش مقیاس زمانی عملکردشان بهبود نیافته است، اما روش یادگیری عمیق در تمامی کلاس‌ها بهبود قابل ملاحظه‌ای کرده است و اختلاف معناداری با بقیه روش‌های یادگیری دارد.

برای ارزیابی عملکرد شبکه‌های هوش مصنوعی دو معیار ارزیابی ماکرو- $f_1$  و میکرو- $f_1$  برای هر ۴ شبکه هوش مصنوعی در ۵ مقیاس زمانی مختلف برآورده شد و نتیجه حاصل در جدول ۵ و ۶ آورده شده است.

جدول ۵. معیار ارزیابی ماکرو- $f_1$ 

مقیاس زمانی							روش یادگیری
۲۴	۱۲	۹	۶	۳	۱		روش یادگیری
۶۵/۳۵	۵۴/۸۸	۵۲/۰۳	۵۰/۶۸	۵۵/۶۹	۲۲/۷۱		یادگیری عمیق
۳۶/۵۴	۳۸/۶۸	۴۴/۵۵	۴۶/۲۰	۵۵/۲۷	۶۴/۴۱		K نزدیک‌ترین همسایه
۲۳/۰۲	۳۲/۷۸	۴۳/۵۷	۴۷/۸۷	۵۹/۹۲	۶۴/۶۵		درخت تصمیم
۵۷/۴۰	۲۹/۱۳	۴۵/۵۵	۴۲/۲۱	۵۴/۴۰	۶۴/۲۲		ماشین بردار پشتیبان

معیار ماکرو- $f_1$  برای کلاس‌های مختلف اهمیت یکسانی قائل است. شبکه یادگیری عمیق در مقیاس زمانی ۱ ماهه با ۲۲.۷۱ درصد بدترین و درخت تصمیم با ۶۴.۶۵ درصد بهترین عملکرد را در پیش‌بینی خشکسالی داشته‌اند اما با افزایش مقیاس زمانی و افزایش داده‌های استفاده شده روش یادگیری عمیق عملکرد خود را بهبود بخشید و با اختلاف،

نسبت به شبکه‌های K نزدیک‌ترین همسایه، درخت تصمیم و ماشین بردار پشتیبان با  $65/35\%$  پیشی گرفته است. رفتار شبکه K نزدیک‌ترین همسایه ثابت بود و با افزایش مقیاس زمانی کارآایی آن کاهش یافت، شبکه درخت تصمیم در کوتاه مدت نسبت به بقیه روش‌ها عملکرد بهتری داشته است اما با افزایش مقیاس زمانی عملکردش کاهش یافته است بطوریکه در ۲۴ ماهه بدترین عملکرد را داشته است، شبکه ماشین‌بردار پشتیبان رفتار منطقی و قابل اتکایی از خود نشان نداده است.

جدول ۶. معیار ارزیابی میکرو- $f^1$ 

شبکه‌ها	مقیاس زمانی	۱	۳	۶	۹	۱۲	۲۴
پادگیری عمیق	۸۳/۲۳	۸۵/۱۵	۸۰/۳۱	۷۳/۲۰	۷۷/۹۹	۸۵/۰۴	۸۵/۰۴
K نزدیک‌ترین همسایه	۸۷/۷۲	۸۴/۹۷	۷۹/۰۵	۷۱/۱۷	۷۱/۳۷	۶۳/۵۵	۶۳/۵۵
درخت تصمیم	۸۷/۲۲	۸۴/۲۰	۷۶/۷۴	۶۷/۹۲	۶۵/۱۰	۵۴/۶۱	۵۴/۶۱
ماشین بردار پشتیبان	۸۹/۱۱	۸۶/۱۱	۸۰/۷۲	۷۷/۴۰	۷۴/۱۲	۷۱/۱۴	۷۱/۱۴

بر اساس معیار میکرو- $f^1$  هر ۴ شبکه با درصد بالای ۵۰ در تمام مقیاس‌های زمانی قادر به پیش‌بینی خشکسالی بوده‌اند و در هر مقیاس زمانی با اختلاف کمی نسبت به یکدیگر قادر به پیش‌بینی بوده‌اند. براساس معیار میکرو- $f^1$  روش پادگیری عمیق در هر ۶ مقیاس زمانی ۷۰ درصد به بالا توانسته خشکسالی را پیش‌بینی کند این در صورتی است که در معیار ارزیابی ماکرو- $f^1$  این چنین نیست و در مقیاس زمانی ۱ ماهه روش پادگیری عمیق با ۲۲/۷۱ درصد توانسته است کلاس-ها را به درستی تشخیص بدهد.

همانطور که توضیح داده شد برای داده‌هایی که اریب می‌باشند و توزیع داده‌ها به صورت نرمال نمی‌باشد معیار ماکرو- $f^1$  از اهمیت بیشتری برخوردار است، به دلیل اینکه داده‌های بارندگی به کار برد شده دارای پراکنش زیاد و کج‌شدنگی به یک سمت می‌باشند معیار ماکرو- $f^1$  برای مقایسه روش‌های پادگیری با یکدیگر در نظر گرفته شد. به طور کلی تمام روش‌های پادگیری توانسته‌اند پیش‌بینی را انجام دهند که با پژوهش‌های یوریکلی و همکاران (Yurekli et al. ۲۰۱۲) که از تکنیک‌های درخت تصمیم برای پیش‌بینی خشکسالی استفاده کرده‌اند و تریپاتهی و همکاران (۲۰۰۶) که از روش ماشین بردار پشتیبان برای پیش‌بینی بارش استفاده کرده‌اند مطابقت داشته است. در این پژوهش سعی شده است که با ترکیب استفاده از روش پلات بازگشتی و شبکه پادگیری عمیق پیش‌بینی خشکسالی انجام شود که دارای نوآوری قابل توجهی می‌باشد، اما موضوع قابل تأمل نیاز شبکه‌های پادگیری عمیق به حجم بالای اطلاعات برای آموزش است. به طور کلی روش پادگیری عمیق در کوتاه مدت به دلیل کم بودن داده‌ها از خود عملکرد خوبی نشان نداده است اما در بلندمدت با افزایش داده‌ها به مرور عملکرد روش پادگیری عمیق بهتر از دیگر روش‌های استفاده شده است، روش‌های درخت تصمیم و K نزدیک‌ترین همسایه در کوتاه مدت و برای داده‌های کم عملکرد بهتری نسبت به بلند مدت و برای داده‌های زیاد داشته‌اند اما در کوتاه مدت می‌توان گفت روش درخت تصمیم بهتر بوده است، می‌توان در صورت دارا بودن داده‌های زیاد از روش پادگیری عمیق استفاده کرد و در داده‌های کم از روش درخت تصمیم استفاده کرد و یا از شبکه‌های عصبی و یا تلفیقی از چند روش پادگیری دیگر می‌توان برای پیش‌بینی خشکسالی که یک پدیده طبیعی و غیرمنتظره است استفاده کرد همانند سینگ (Singh, ۲۰۱۸) که به منظور پیش‌بینی بارش ISMR از سه تکنیک فازی، آنتروپی و شبکه عصبی استفاده کرده و موفق بوده است. بر اساس نتایج حاصل از شاخص بارش استاندارد شده (SPI) خشکسالی به صورت پراکنده در بعضی از ایستگاه‌ها قابل مشاهده است اما تقریباً در تمام ایستگاه‌ها در مقیاس زمانی ۱۲ ماهه در سال ۲۰۰۰ شاهد بروز خشکسالی بوده‌ایم، در این میان

شدیدترین خشکسالی در ایستگاه ابرکوه در مقیاس زمانی ۹ ماهه رخ داده است. بر اساس معیار ماکرو-f<sub>1</sub> در مقیاس زمانی ۱ و ۳ ماهه با مقادیر ۶۴/۶۵ و ۵۲/۹۹، روش درخت تصمیم و در مقیاس زمانی ۶، ۱۲، ۹ و ۲۴ ماهه با مقادیر ۵۰/۰۳، ۵۲/۰۳ و ۵۴/۸۸، روش یادگیری عمیق بهتر عمل کرداند. روش ماشین‌بردار پشتیبان رفتار متغیر و غیرقابل اتكایی از خود نشان داد به این معنا که نمیتوان گفت روش ماشین‌بردار پشتیبان در کدام مقیاس زمانی توانایی پیش‌بینی بهتری را دارد بدین صورت که در مقیاس زمانی ۲۴ ماهه با ۵۴/۴۰ بعد از روش یادگیری عمیق بهترین عملکرد را در تشخیص درست کلاس‌بندی داشته است اما در صورتیکه در مقیاس زمانی ۱۲ ماهه با ۲۹/۱۳ بدترین عملکرد را داشته است، میزان تغییر رفتار روش ماشین‌بردار پشتیبان همچون یک نمودار سهمی می‌باشد. روش K نزدیک‌ترین همسایه در کوتاه مدت در ۱ ماهه ۶۴/۴۱ درصد توانسته است خشکسالی را پیش‌بینی کند اما با افزایش مقیاس زمانی عملکردی را که در کوتاه مدت داشته است از دست داد و در مقیاس زمانی بلند مدت عملکرد قابل قبولی را از خود نشان نداده است و نتوانسته خشکسالی را به درستی پیش‌بینی کند. روش درخت تصمیم رفتاری مشابه روش K نزدیک‌ترین همسایه داشته است، روش درخت تصمیم در کوتاه مدت بهتر از روش K نزدیک‌ترین همسایه خشکسالی را پیش‌بینی کرده است به طوریکه در مقیاس زمانی ۱ ماهه بهترین عملکرد با ۶۴/۶۵ مربوط به روش درخت تصمیم و روش K نزدیک‌ترین همسایه با ۶۴/۴۱ بعد از روش درخت تصمیم قرار می‌گیرد اما در مقیاس زمانی بلند مدت روش K نزدیک‌ترین همسایه بهتر از روش درخت تصمیم بود بطوریکه در مقیاس زمانی ۲۴ ماهه بدترین عملکرد در پیش‌بینی خشکسالی مربوط به روش درخت تصمیم با ۲۳/۰۲ می‌باشد، روش K نزدیک‌ترین همسایه با نوسان کمتری نسبت به روش درخت تصمیم در مقیاس‌های زمانی مختلف پیش‌بینی کرده است رفتار این دو روش به صورت یک نمودار خطی می‌باشد که از مقیاس زمانی کم به سمت مقیاس زمانی زیاد در حال کاهش پیدا کردن است و شبیه خط روش درخت تصمیم بیشتر از روش K نزدیک‌ترین همسایه می‌باشد.

### نتیجه‌گیری

پیش‌بینی خشکسالی برای یک ماه آتی در استان یزد با استفاده از داده‌های بارندگی ماهانه ۱۱ ایستگاه سینوپتیک طی ۲۹ سال با کمک ۴ روش یادگیری عمیق، K نزدیک‌ترین همسایه، درخت تصمیم و ماشین‌بردار پشتیبان صورت گرفت. هر چهار روش توانایی پیش‌بینی خشکسالی را داشته‌اند. اگرچه در مقیاس‌های زمانی کوتاه مانند ۳ و ۹ ماهه معیارهای ارزیابی دقت و صحت برای بعضی از کلاس‌ها صفر بوده و عملاً روش‌های یادگیری از این کلاس‌ها به دلیل کم بودن داده‌های آنها چشم‌پوشی کرده‌اند اما در مقیاس‌های زمانی بزرگ‌تر این موضوع مرتفع شده و داده‌های آن کلاس‌ها نیز به خوبی دسته‌بندی شده‌اند. برای آموزش شبکه یادگیری عمیق به تصویر نیاز بوده است، که این تصاویر با استفاده از روش پلات برگشتی ایجاد شده‌اند. ترکیب این دو روش، پلات برگشتی برای ایجاد تصاویر و شبکه یادگیری عمیق برای کلاس‌بندی داده‌های خشکسالی برای اولین بار در این پژوهش استفاده شده است. شبکه یادگیری عمیق که ورودی آن به صورت تصویر بوده است در کوتاه مدت به دلیل کم بودن داده‌ها نتوانسته است به خوبی پیش‌بینی را انجام دهد اما در بلند مدت به دلیل افزایش داده‌های عملکرد خود را بهبود بخشیده است و بهترین عملکرد را داشته است. روش SVM در مقیاس‌های زمانی مختلف رفتارهای غیر قابل اتكا و متغیری از خود نشان داده است که بطور قطع نمی‌توان گفت روش مناسبی برای پیش‌بینی خشکسالی در مقیاس‌های زمانی مختلف باشد، روش‌های Decision Tree و KNN پیش‌بینی خشکسالی را در کوتاه مدت بهتر از بلند مدت توانسته‌اند پیش‌بینی را انجام دهند، این دو روش رفتاری نزدیک به یکدیگر داشته‌اند. برای تحقیقات آینده پیشنهاد می‌شود از روش‌های Decision Tree و KNN

برای پیش‌بینی خشکسالی در کوتاه مدت استفاده شود، در این پژوهش با افزایش مقیاس زمانی و بیشتر شدن داده‌های بکار برده شده این دو روش کارایی خود را نسبت به کوتاه مدت از دست داده‌اند.

#### منابع.

- بذرافشان، جواد. ۱۳۸۱. مطالعه تطبیقی برخی شاخص‌های خشکسالی هواشناسی در چند نمونه اقلیمی ایران. پایان‌نامه کارشناسی ارشد، دانشکده منابع طبیعی، دانشگاه تهران.
- حسن‌پور متی کلایی، سید حسین. رضا سعادتی. ۱۳۹۵. مروری بر کاربردهای شبکه عصبی کانولوشن و یادگیری عمیق در بینایی کامپیوتر. سومین کنفرانس ملی مهندسی برق و کامپیوتر سیستم‌های توزیع شده و شبکه‌های هوشمند کاشان، دانشگاه آزاد اسلامی واحد کاشان
- حسن‌زاده، یوسف؛ امین عبدی کردانی، احمد فاخری‌فرد. ۱۳۹۰. پیش‌بینی خشکسالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی موجکی. مجله آب و فاضلاب، ۳: ۴۸-۵۹.
- جهانگیر، محمد حسین؛ میمنه خوش‌مشربان، حسین یوسفی. ۱۳۹۴. پایش و پیش‌بینی وضعیت خشکسالی با استفاده از شاخص بارندگی استاندارد (SPI) و شبکه عصبی پرسپترون چندلایه (مطالعه موردی: استان‌های تهران و البرز). مجله اکوهیدرولوژی، ۲(۴): ۴۲۸-۴۱۷.
- صدیقان‌فرد، سعید؛ اسماعیل اسدی. ۱۳۹۶. پیش‌بینی نمایه خشکسالی SPI به روش‌های رگرسیونی بردار پشتیبان و خطی چندگانه. نشریه حفاظت منابع آب و خاک، ۶(۴): ۱-۱۶.
- سیکرو، م. ۱۳۹۵. تشخیص به موقع ناهنجاری در ویدیو. رساله دکتری تخصصی رشته مهندسی کامپیوتر-گرایش هوش مصنوعی، دانشکده مهندسی کامپیوتر، دانشگاه مالک اشتر.

Aksoy, H. and Dahamsheh, A. ۲۰۰۹. Artificial neural network models for forecasting monthly precipitation in Jordan. *Stochastic Environmental Research and Risk Assessment*, ۲۳(۷): ۹۱۷-۹۳۱.  
 Anandhi, A.; Srinivas, V.V.; Nanjundiah, R.S. and Kumar, N. ۲۰۰۸. Downscaling precipitation to river basin in India for IPCC SRES scenarios using support vector machine. *International journal climatology*, ۲۸: ۴۰۱-۴۲۰.

Benevenuto, F., Rodrigues, T., Almeida, V., Almeida, J., & Ross, K. ۲۰۰۹. Video interactions in online video social networks. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 5(4): ۱-۲۰.

Benevenuto, F.; Magno, G.; Rodrigues, T. and Almeida, V. ۲۰۱۰. Detecting Spammers on Twitter. *Seventh annual Collaboration, Electronic messaging, AntiAbuse and Spam Conference* July, Redmond, Washington, US (CEAS).

Bonaccorso, B.; Bordi, I.; Cancellere, A.; Rossi, G. and Sutera, A. ۲۰۰۳. Spatial Variability of Drought: An Analysis of the SPI in Sicily. *Water Resources Management* 17: ۲۷۳-۲۹۶.

Crespo, J. L. and Mora, E. ۱۹۹۳. Drought estimation with neural networks. *Advances in Engineering Software*, 18(3): ۱۶۷-۱۷۰.

Eckmann, J. P.; Kamphorst, S. O. and Ruelle, D. ۱۹۸۷. Recurrence Plots of Dynamical Systems. *Europhysics Letters*. 5 (9): ۹۷۳-۹۷۷

Huang, Y.; Tat Ang, J.; Tiong, Y.; Mirzaei, M. and Zaki Mat, M. ۲۰۱۶. Drought Forecasting using SPI and under RCP- $4.5$  Climate Change Scenarios For Langat River Basin, Malaysia. *12 th International Conference on Hydroinformatics*, Procedia Engineering 104: ۷۱۰-۷۱۷.

Mishra A.K.; Desa V.R. and Singh V.P. ۲۰۰۷. Drought forecasting Using a Hybrid Stochastic and Neural Network Model. *Journal of Hydrologic Engineering*, 12(6): ۶۲۶-۶۳۸.

Partal, T. and Cigizoglu, H.K. ۲۰۰۹. Prediction of daily precipitation using wavelet-neural networks. *Journal of Hydrological Sciences*, 54(2): ۲۳۴-۲۴۶.

Paulo, A. and Pereira, L. S. ۲۰۰۷. Prediction of SPI Drought Class Transitions Using Markov Chains. *Water Resour Manage*, 21: ۱۸۱۳-۱۸۲۷.

- Singh, P., ۲۰۱۸. Indian summer monsoon rainfall (ISMR) forecasting using time series data: A fuzzy-entropy- neuro based expert system. *Geoscience Frontiers*, ۹: ۱۲۴۳-۱۲۵۷.
- Saada, N. and Abu-Romman, A. ۲۰۱۷. Multi-site Modeling and Simulation of the Standardized Precipitation Index (SPI). *Jordan of Hydrology: Reglonal Studies*, ۱۶: ۸۳-۹۱.
- Sattari, T.; Anli, S.; Apaydin, H and Kodal, S. ۲۰۱۲. Decision trees to determine the possible drought periods. Ankara. *Atmosfera* ۲۰(۱): ۶۵-۸۳.
- Shah, R.; Bharadiya, N. and Manekar, V. ۲۰۱۰. Drought Index Computation Using Standardized Precipitation Index (SPI) Method For Surat District, Gujarat. *Aquatic Procedia* ۴: ۱۲۴۳ – ۱۲۴۹.
- Tripathi, Sh.; Srinivas, V. V. and Nanjundiah, R. S. ۲۰۰۶. Downscaling of precipitation for climate change scenarios: A support vector machine approach. *Journal of Hydrology*, ۳۳۰: ۶۲-۶۴۰.
- Wang, W. and Ding, J. ۲۰۰۳. Wavelet network model and its application to the prediction of hydrology. *Nature and Science*, ۱(۱): ۶۷-۷۱.
- Yurekli, K.; Taghi Sattari, M. T.; Anli, A.S. and Hinis, M.A. ۲۰۱۲. Seasonal and annual regional drought Prediction by using data-mining approach, *Atmosfera*, ۲۰(۱): ۸۵-۱۰۰.

