

پیش‌بینی خشکسالی با استفاده از مدل‌های هوش مصنوعی (مطالعه موردی استان فارس)

محمد ابراهیم عقیقی^{۱*} و وحید سهرابی^۲

تاریخ دریافت: ۱۴۰۲/۰۳/۳۱ تاریخ پذیرش: ۱۴۰۲/۰۹/۰۵

چکیده

گام ضروری برای مقابله با خشکسالی و تعدیل تبعات آن، شناخت و درک دقیق ابعاد آسیب‌پذیری هر منطقه است. این امر ضرورت مطالعه در زمینه تعیین آسیب‌پذیری و شناسایی عوامل اثرگذار بر آن در مناطق مختلف کشور را مشهود می‌سازد در تحقیق حاضر، به‌منظور معرفی یک روش مناسب جهت پیش‌بینی خشکسالی برای یک ماه آتی، چهار روش هوش مصنوعی شامل یادگیری عمیق (از شبکه الکس نت که یکی از شبکه‌های کانولوشن است استفاده شده است)، الگوریتم K نزدیک‌ترین همسایه، ماشین بردار پشتیبان چندطبقه و درخت تصمیم در نظر گرفته شد. داده‌های بارندگی ۱۱ ایستگاه سینوتیک استان فارس طی دوره آماری ۲۹ ساله (۱۹۸۸ تا ۲۰۱۷) به‌صورت ماهانه به‌عنوان داده‌های آزمایشی مورد استفاده قرار گرفتند. شاخص بارش استاندارد شده (SPI) برای نشان دادن وضعیت خشکسالی از نظر شدت و مدت در مقیاس‌های زمانی ۱، ۳، ۶، ۹، ۱۲ و ۲۴ ماهه محاسبه گردید. در ابتدا داده‌های بارش به‌عنوان ورودی شبکه‌های عصبی و کلاس‌بندی شاخص بارش استاندارد شده به‌عنوان 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 ماکرو-F۱ 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.

کلمات کلیدی: خشکسالی، هوش مصنوعی، استان فارس.

۱ استاد تمام، گروه خاکشناسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. نویسنده مسئول m.torkashvand54@yahoo.com

۲ استاد تمام، گروه خاکشناسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

Standardized Precipitation Index^۳

مقدمه

خشکسالی‌ها همیشه زندگی و فعالیت‌های انسانی را با خطر جدی مواجه کرده و می‌کند؛ در دهه‌های اخیر موجب خسارات فراوان جانی و مالی در جهان شده است. این پدیده دارای خصوصیتی است که آن را از سایر بلایای طبیعی جدا می‌کند. تحقیقات انجام شده نشان می‌دهد که در بین حوادث طبیعی، خسارات ناشی از خشکسالی بیشترین مقدار را شامل است؛ لذا پایش گسترده آن و ایجاد یک نظام هشدار و پیش‌آگاهی در مناطق مستعد خشکسالی، امری اجتناب‌ناپذیر است. یکی از ابزارهای اصلی پایش خشکسالی، استفاده از شاخص‌های خشکسالی می‌باشد. برای کم و بی‌اثر نمودن این پدیده ابتدا باید آن را به خوبی شناخت و انگهی با استفاده از یافته‌های علمی و داده‌های آب‌وهواشناسی خشکسالی را پیش‌بینی کرد و این پدیده خطرناک را یوسف دار مدیریت نمود. kogan. در ایالات متحده در دهه ۱۹۸۰ با استفاده از شاخص NDVI^۱ خشکسالی‌های روی داده را بررسی کرد و به این نتیجه رسید که این شاخص از طریق نشان‌دادن تغییرات در پوشش گیاهی می‌تواند به خوبی خشکسالی‌ها را نشان دهد. (۱)، از شاخص NDVI برای بررسی پوشش گیاهی، برآورد مقدار محصولات کشاورزی و شناسایی خشکسالی در جنوب آفریقا استفاده نمودند. (۲) از داده‌های سنجنده AVHRR^۲ برگرفته از ماهواره NOAA برای طبقه‌بندی و پایش پوشش گیاهی با استفاده از شاخص NDVI در هند استفاده کردند. Saura

و Migul با استفاده از داده‌های ماهواره IRS- WiFS به تهیه نقشه برای پوشش جنگلی پرداختند، به و این نتیجه رسیدند که می‌توان از این داده‌ها برای تیپ‌بندی پوشش گیاهی استفاده کرد. (۳) در شمال آمریکا در برای یک علفزار همبستگی بین پارامترهای بیوفیزیکی گیاهان مانند بیوماس و شاخص سطح برگ را با شاخص NDVI بررسی کردند. (۴) در شمال چین با استفاده از تصاویر نوآ تغییرات پوشش گیاهی را بررسی کردند، نتیجه نشان داد که در مناطق علفزار همبستگی بسیار بالایی بین تغییرات پوشش گیاهی و بارندگی وجود دارد. (۵) با استفاده از تصاویر ماهواره MODIS^۳ و شاخص NDVI را دوره ۱۳۹۶-۱۳۹۸ در فصل‌های رشد گیاهی وضعیت پوشش گیاهی را در شمال غربی آمریکا بررسی کردند. تغییرات NDVI در طول این دوره کاهش معنی‌داری را در سلامت پوشش گیاهی نشان داد (۶) رابطه نوسانات بارندگی و تغییرات پوشش گیاهی را در سد درودزن در بخشی از مراتع استان فارس مورد بررسی قرار دادند. در این پژوهش از اطلاعات بارندگی ماهیانه ایستگاه‌های هواشناسی و تصاویر ماهواره NOAA استفاده شد. نتایج به‌دست‌آمده بیانگر ارتباط

^۱ Normalized Difference Vegetation Index

^۲ سنجنده ی تشخیص تابش

^۳ Moderate Resolution Imaging Spectroradiometer

معنی‌دار تیپ‌های پوشش گیاهی فورب و گراس با نوسانات بارندگی و عدم ارتباط یا ارتباط ضعیف تیپ‌های بوته‌زار، درختی و درختچه‌ها با بارندگی می‌باشد. (۷) به بررسی تغییرات پوشش گیاهی با استفاده از تصاویر MSS^۱ و ETM در حوزه سد ایلام پرداختند. در این مطالعه روش‌های مختلفی برای بررسی تغییرات استفاده شده و در نهایت مشخص گردید که روش تفاضل باند قرمز بیش‌ترین دقت را داشته است. (۸) به بررسی پوشش گیاهی با استفاده از تصاویر ماهواره‌های در سیستان پرداختند. در این پژوهش روند تغییرات پوشش گیاهی منطقه در دوره ۲۰۱۵ تا ۲۰۱۸ بررسی شده است. نتایج نشان داد که سطح پوشش گیاهی در سال ۲۰۱۸ معادل ۱۰۱۲۴۷ هکتار بوده است؛ اما در سال ۲۰۱۵ به ۲۶۴۷۵ هکتار کاهش یافته است. (۹) به پایش تغییرات پوشش گیاهی با استفاده از داده‌های بارش و تصاویر NOVA در استان کرمانشاه پرداختند. آنها رابطه بارش با پوشش گیاهی را بین سال‌های ۲۰۱۵ تا ۲۰۱۹ بررسی کردند. در این مطالعه مشخص شد که رابطه بین پوشش گیاهی و بارش به نوع پوشش گیاهی و فصل بستگی دارد. (۱۰) به تهیه نقشه پوشش گیاهی و پایش تغییرات آن با استفاده از تکنیک‌های سنجش‌ازدور و سیستم اطلاعات جغرافیایی در شهرستان بهبهان پرداختند. در این پژوهش جهت‌نمایش تغییرات زمانی و مکانی پوشش گیاهی شهرستان بهبهان از اطلاعات باندهای ماهواره لندست سنجنده‌های ETM+ و OLI در دو سال ۱۳۹۰ و ۱۳۹۵ استفاده و مقدار شاخ NDVI برای دو سال محاسبه گردد. همچنین به منظور بررسی تغییرات کیفی پوشش گیاهی مقادیر عددی این شاخص به ۴ کلاس مختلف سربسزی شامل اراضی با پوشش عالی، پوشش بسیار خوب، پوشش خوب و ضعیف طبقه‌بندی شد. سپس تغییرات رخ داده با استفاده از CROSSTAB^۲ مشخص شد. نتایج نشان داد تغییرات کمی و کیفی پوشش گیاهی در طی ۱۴ سال برای منطقه مورد مطالعه گسترده بوده است به طوری که اراضی با پوشش عالی، بسیار خوب و ضعیف افزایش مساحت و اراضی با پوشش خوب کاهش مساحت را داشته است. بیشترین افزایش مساحت در اراضی با پوشش گیاهی عالی صورت گرفته، به طوری که از ۵۰۶۹/۷۹ هکتار در سال ۱۳۹۰ به ۷۷۳۵/۵ هکتار در سال ۱۳۹۲ افزایش یافته است. همچنین بیشترین کاهش مساحت در اراضی با پوشش خوب می‌باشد که از ۳۴۰۶۱/۴ هکتار به ۲۷۴۳۴/۴۳ هکتار رسیده است. در مقاله ای که توسط روزگار و همکاران تدوین گردید. (۴) مطالعه خشکسالی هواشناسی حوزه آبخیز سد درودزن به صورت سالیانه و فصلی با توجه به آمار بارندگی ۲۵ ساله ایستگاه سد درودزن مورد بررسی قرار گرفت. آزمون صحت و همگنی داده‌ها به روش ران تست و جرم مضاعف صورت گرفت. سپس فراوانی و شدت خشکسالی بر اساس شش شاخص: آستانه ۶۰ درصد، درصدی از نرمال، استاندارد بارش، انحراف از میانگین، کلاسه بندی دامنه بارش و دهک‌ها در مقیاس فصلی و سالیانه مطالعه گردید. با

^۱ Managed Security Services

^۲ Cross Tabulation

توجه به کاهش میزان نزولات جوی، مشخص گردید که خشکسالی در برخی موارد به صورت سالیانه و در برخی موارد نیز به صورت فصلی رخ داده است. با توجه به نتایج حاصل از شش شاخص برآورد خشکسالی، می توان گفت که روش SD^1 و PC^2 در پیش بینی خشکسالی از دقت بالاتری نسبت به شاخص های دیگر برخوردارند. بررسی ها نشان می دهد که در سا های مورد بررسی در حوزه سد درودزن، خشکسالی با شدت های متفاوت رخ داده است.

عیفی در تحقیقی به بررسی اثر خشکسالی بر روی پوشش گیاهی با استفاده از تکنیک های سنجش از دور مطالعه موردی حوزه آبریز سد درودزن پرداخت.(۱۲)

پژوهش حاضر باهدف معرفی یک روش هوش مصنوعی مناسب به منظور پیش بینی خشکسالی صورت گرفته است. در این پژوهش از شبکه الکسنت که یک شبکه پردازش تصویر است برای پیش بینی خشکسالی استفاده شده است. داده های بارندگی با ایده روش ریکارنس پلات به صورت عکس درآمده اند

مواد و روش

ویژگی های منطقه مورد مطالعه

استان فارس از شمال با استان اصفهان، از شمال غرب و غرب با استان های کهگیلویه و بویراحمد و بوشهر، از جنوب و جنوب شرق با استان هرمزگان، از شرق با استان کرمان و از شمال شرق با استان یزد همسایه است.

این استان در موقعیت جغرافیایی $27^{\circ}03'$ تا $31^{\circ}40'$ عرض شمالی و $50^{\circ}36'$ تا $55^{\circ}35'$ طول شرقی قرار داشته و وسعتی معادل 121825 کیلومترمربع دارد که حدود، $7/5$ درصد از مساحت کشور ایران را دربر گرفته است.

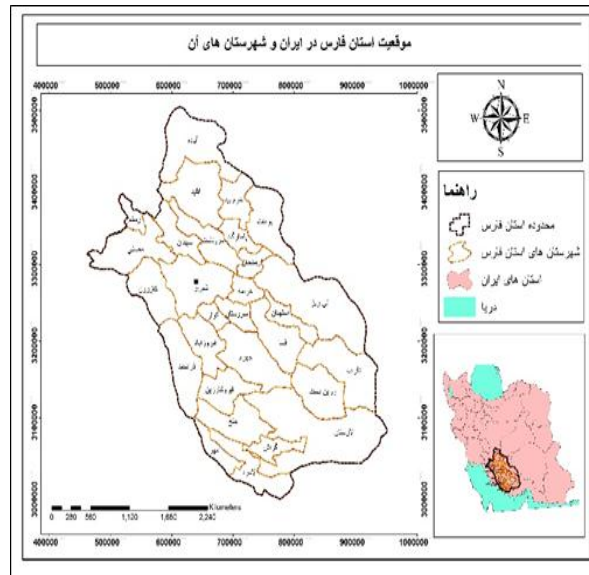
ناهمواری های استان فارس دنباله رشته کوه های زاگرس است که همچون دیواره ای عظیم غرب کشور را فراگرفته و امتداد آن تا جنوب کشیده شده است. ناهمواری های استان فارس را می توان به دو قسمت کوه و دشت تقسیم کرد.

کوه های استان فارس خود به سه قسمت قابل تقسیم است. کوه های شمالی که مرتفع ترین نقاط استان و منشأ بیشتر رود های استان هستند، کوه های مرکزی که به واسطه وجود دشت های وسیع، مهم ترین مناطق روستایی و شهری را در خود جای داده است و بالاخره کوه های جنوبی که جهت آن ها غربی -

¹ Standard Deviation

² روش تجزیه

شرقی و کم‌ارتفاع‌تر از بقیه کوه‌های فارس هستند. کوه سفید به ارتفاع ۳۹۴۳ متر از سطح دریا در شمال استان در شهرستان اقلید، خرمن کوه به ارتفاع ۳۱۸۵ متر و دَلُوْ به ارتفاع ۳۰۹۷ متر در مرکز و کوه‌های مروارید به بلندی ۳۰۲۵ متر در شهرستان‌های داراب و کوه فَرَّاشَبَند به بلندی ۲۷۸۰ متر در جنوب و در شهرستان فیروزآباد از مهم‌ترین ارتفاعات استان هستند.



شکل ۱. نمایی از موقعیت جغرافیایی استان فارس در ایران منبع: (نگارنده)

روش تحقیق

داده‌های بارندگی استان فارس طی دوره آماری ۲۹ساله (۱۹۸۸ تا ۲۰۱۷) به‌صورت ماهانه مورد استفاده قرار گرفت. به‌منظور مشخص کردن مدت و شدت خشکسالی از شاخص بارش استاندارد شده در مقیاس‌های زمانی ۱، ۳، ۶، ۹، ۱۲ و ۲۴ استفاده گردید و برای پیش‌بینی خشکسالی، ۴ روش هوش مصنوعی یادگیری عمیق، الگوریتم K نزدیک‌ترین همسایه، ماشین بردار پشتیبان چندطبقه و درخت تصمیم انتخاب گردید. در هر ۴ روش ۸۰ درصد داده‌ها برای آموزش شبکه و ۲۰ درصد داده‌ها برای تست در نظر گرفته شد. شبکه‌های هوش مصنوعی استفاده شده بر اساس شاخص بارش استاندارد شده. شدت خشکسالی را در ۷ کلاس (کلاس‌های شاخص بارش استاندارد شده به‌صورت کمی از شماره ۱. خشکسالی بسیار شدید تا شماره ۷. ترسالی بسیار شدید برای روش‌ها تعریف شده است)، کلاس‌بندی کرده و پیش‌بینی صورت گرفته است. اما داده‌های ورودی برای شبکه یادگیری عمیق به‌صورت عکس بود که از روش ریکارنس پلات ایده گرفته شد، سری زمانی داده‌های بارندگی به‌عکس تبدیل گردید و به‌عنوان ورودی شبکه الکس نت (یک شبکه یادگیری عمیق) که یک شبکه پردازش عکس استقرار گرفت.

شاخص بارش استاندارد شده (SPI):^۱

این شاخص در سال ۱۹۹۵ توسط مک کی 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 می آید و تنها فاکتور مؤثر در محاسبه این شاخص عنصر بارندگی می باشد. این شاخص را می توان در مقیاس های زمانی ۳، ۶، ۱۲، ۲۴ و ۴۸ ماهه محاسبه کرد. ویژگی دیگر شاخص بارش استاندارد شده این است که بر اساس این شاخص علاوه بر محاسبه ی شدت خشک سالی، مدت آن را نیز می تواند تعیین نماید. شاخص بارش استاندارد شده بر اساس احتمال بارش برای هر بازه زمانی می باشد و به منظور هشدار اولیه و پایش شدت خشک سالی اهمیت زیادی دارد. این شاخص برای کمی نمودن کمبود بارش در بازه های زمانی چندگانه طراحی شده است (۱۳). تجربه نشان داده است که توزیع گاما توزیع مناسبی برای برآزش روی داده های بارندگی است، در صورتی که فرض شود بارندگی در یک منطقه از توزیع گاما تبعیت می کند و χ مقادیر بارندگی باشد، تابع چگالی احتمال دو پارامتری گاما به صورت زیر تعریف می شود: (۱۴)

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

در رابطه ۱، α پارامتر شکل، β پارامتر مقیاس توزیع و $\Gamma(\alpha)$ تابع گاما است که به صورت زیر تعریف می شود:

$$\int_0^{\infty} \gamma^{\alpha-1} e^{-\gamma} d\gamma = (\alpha) \Gamma \quad \text{رابطه (۲)}$$

ضرایب α و β بهینه نیز از طریق روابط زیر حساب می شود:

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

$$A = \ln(\bar{\chi}) - \frac{\sum \ln(\chi)}{n}$$

$$\hat{\beta} = \frac{\bar{\chi}}{\hat{\alpha}} \quad \text{رابطه (۴)}$$

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

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

$$F(\chi) = \frac{1}{\Gamma(\hat{\alpha})} \int_0^{\chi} t^{\hat{\alpha}-1} e^{-t} dt \quad t = \chi/\hat{\beta} \quad \text{رابطه (۵)}$$

^۱ Standardized Precipitation Index

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

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

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

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

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 از تابع 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 بارش استاندارد شده را نشان می‌دهد.

جدول ۱- تقسیم‌بندی ارزیابی شاخص بارش استاندارد شده SPI منبع: (نگارنده)

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

۱. پلات برگشتی^۱

اکمون و همکاران (۱۹) ریکارنس پلات را معرفی کردند که راه را برای تجسم ماهیت دوره‌ای یک مسیر از طریق یک‌فاز فضایی ارائه می‌دهد. ساخت ریکارنس پلات ما را قادر می‌سازد تا جنبه‌های متفاوتی از مسیر فضایی M را از طریق نمایندگی دوبعدی بررسی کنیم. ریکارنس پلات مجموعه‌ای از جفت زمان‌هایی را نشان می‌دهد که مسیر آن در یک مکان است؛ یعنی مجموعه (i, j) که $\vec{x}(i) = \vec{x}(j)$ 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^۲ را می‌تواند با استفاده از تابع باینری ثبت کرد.

^۱ Recurrence plot


^۲ Recurrence non- / Recurrence

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

همان طور که توضیح داده شد ریکارنس پلات یک روش برای تبدیل سری های زمانی از حالت نموداری به صورت عکس است که در آن هر داده بر اساس معیارهای مختلف دارای طیف رنگی است. در این پژوهش برای تبدیل داده ها به عکس از این روش ایده گرفته شده است. عکس ها به دو صورت رنگی و سیاه و سفید تهیه گردید. هر عکس رنگی متشکل از ۳ صفحه R, G, B است و هر کدام از صفحه ها به صورت جداگانه ساخت شد و نهایتاً با یکدیگر ادغام گردید، هر پیکسل در عکس های رنگی مقدار عددی بین ۰-۲۵۵ دارد و اعداد در هر صفحه بین ۰ تا ۲۵۵ گنجانده شد.

برای ساخت عکس رنگی نیاز به سه صفحه R, G و B هست، این سه لایه بر مبنای فرمول شاخص بارش استاندارد شده با استفاده از ایده ریکارنس پلات ساخته شد، اما به دلیل کمبود داده ها برای ساخت صفحه ها، با کمک مباحث ریاضی تغییراتی در چگونگی ساخت صفحه ها صورت گرفت، چگونگی ساخت هر صفحه به شرح زیر هست:

شکل ۲، نمودار شاخص بارش استاندارد شده ۶ ماهه ایستگاه مهریز است، سه صفحه R, G و B با استفاده از داده های بارندگی این ایستگاه در مقیاس زمانی ۶ ماهه ایجاد شد (که به عنوان نمونه ارائه گردیده است).



شکل ۲- نمودار SPI ۶ ماهه ایستگاه مهریز منبع: (نگارنده)

صفحه R :

داده ها در آرایه یک بعدی به طول n هستند. برای مثال داده های خام در بارش ۶ ماهه یک آرایه به طول ۶ است که در آیه i ام برابر با مقدار بارش در ماه متناظر آن است.

این آرایه d نامیده می شود.

برای تولید صفحه R یک آرایه دوبعدی $n \times n$ 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 دوبعدی $n \times n$ 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 دوبعدی $n \times n$ 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 نرم‌افزار 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 (۱۵). 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 هستند معمولاً محققان از وزن‌های این شبکه‌ها به عنوان وزن‌های اولیه شبکه برای داده‌های مد نظرشان 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 مد نظرشان است بهینه و تغییر می‌دهند (۱۶).

معیارهای ارزیابی

برای ارزیابی اثربخشی استراتژی طبقه‌بندی، از معیارهای استاندارد صحت، دقت میکرو -F1 و ماکرو-F1 استفاده شده است (۱۷)

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:

$$p = a / (a + c) \quad \text{رابطه (۱۲)}$$

$$r = a / (a + b)$$

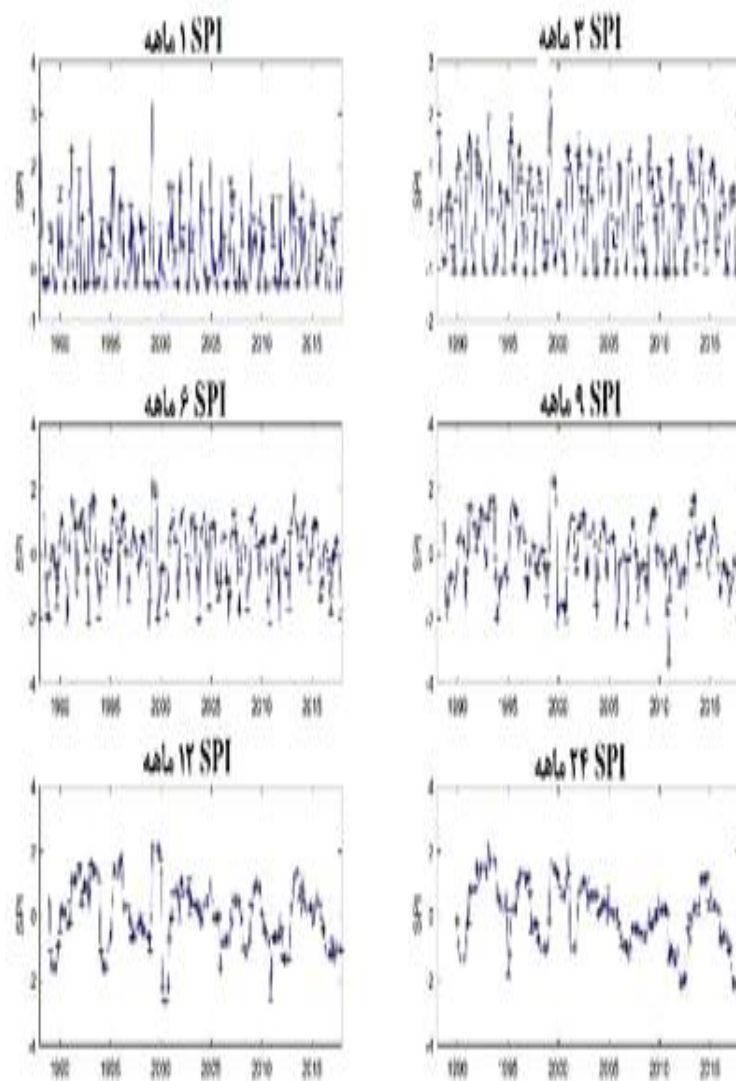
معیار $F1$ میانگین هارمونیک بین دو معیار دقت و صحت است، و به صورت $F1 = 2pr / (p + r)$ تعریف شده است. دو نوع $F1$ ، یعنی میکرو و ماکرو، معمولاً برای ارزیابی اثربخشی طبقه‌بندی به کار می‌روند.

معیار میکرو $F1$ - با محاسبه دقت عمومی و صحت تمام طبقات به دست می‌آید و سپس $F1$ محاسبه می‌شود. معیار میکرو $F1$ - 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 ماکرو $F1$ - ابتدا مقدار $F1$ برای هر کلاس به صورت جداگانه محاسبه می‌شود، سپس میانگین تمام کلاس‌ها محاسبه می‌شود. معیار ماکرو $F1$ - مستقل از اندازه هر کلاس اهمیت یکسانی برای هر کلاس قائل است.


به این ترتیب، دو معیار ارزیابی تکمیلی برای اثرگذاری طبقه‌بندی ارائه شد. معیار ماکرو $F1$ - 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، همان‌طور که برای داده‌های ما نیز این‌گونه است. (۱۷)

نتایج

برای هر یک از ۱۱ ایستگاه سینوپتیک استان فارس. 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.

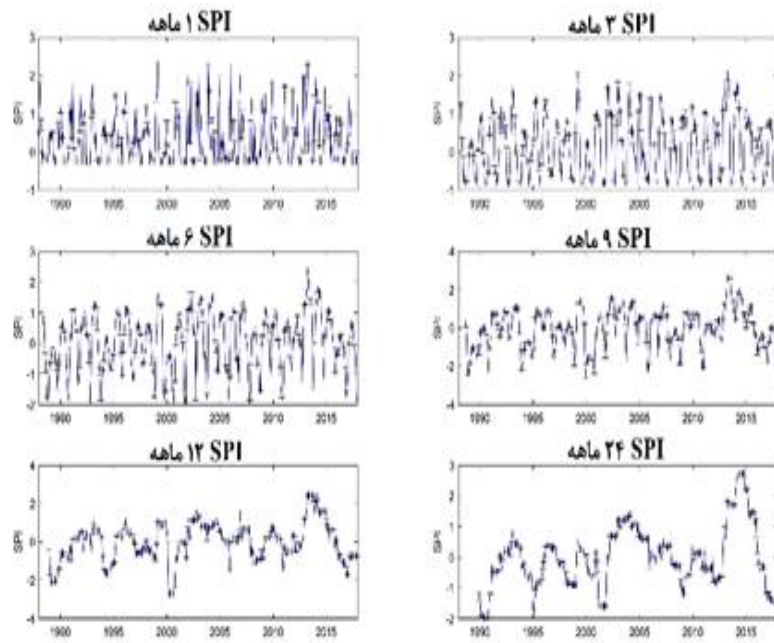


شکل ۳- نمودار SPI ایستگاه استهبان منبع: (نگارنده)




شکل ۴- نمودار SPI ایستگاه شیراز منبع: (نگارنده)

در نمودار SPI مربوط به ایستگاه شیراز در تمامی مقیاس های زمانی SPI در سال ۱۹۹۹ ترسالی شدید قابل رویت است، در SPI ۹ و SPI ۱۲ ماهه خشک سالی های شدیدی دیده می شود. در ایستگاه استهبان در SPI ۱ ماهه و SPI ۳ ماهه وضعیت به صورت نرمال و ترسالی است؛ اما با افزایش مقیاس زمانی SPI خشک سالی هایی نمود پیدا می کنند.

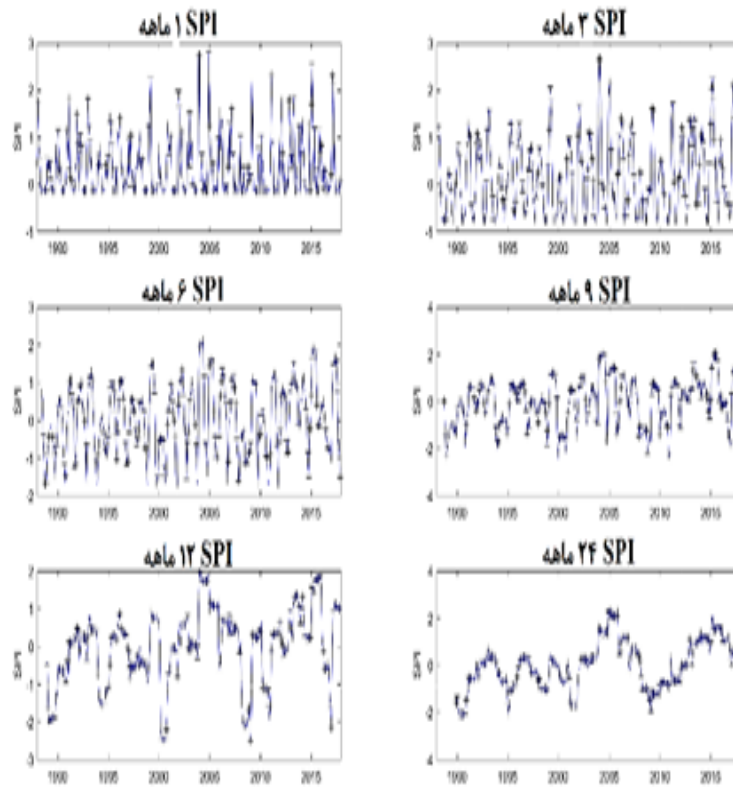


شکل ۵- نمودار SPI ایستگاه آباده منبع: (نگارنده)

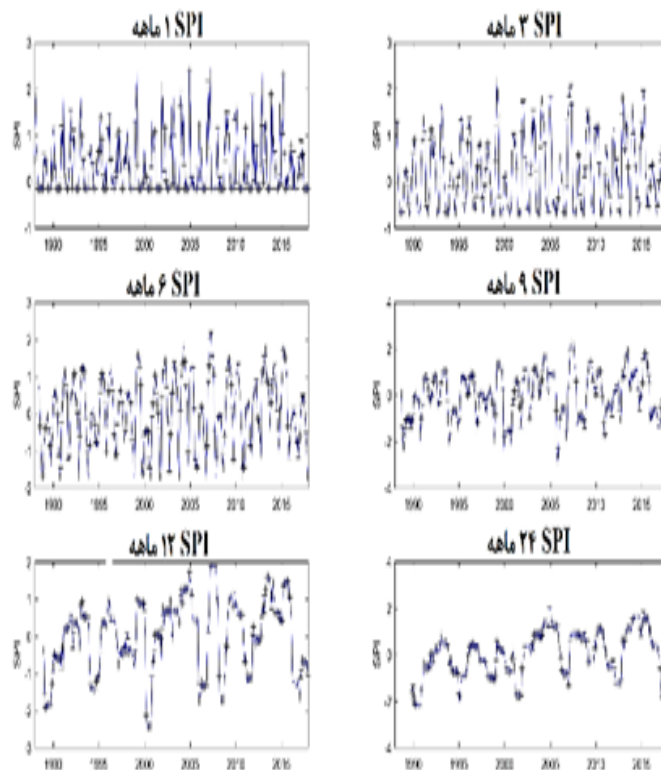


شکل ۶- نمودار SPI ایستگاه مرودشت منبع: (نگارنده)

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




شکل ۷. نمودار SPI ایستگاه نی ریز منبع: (نگارنده)




شکل ۸- نمودار SPI ایستگاه فیروزآباد منبع: (نگارنده)

باتوجه به شکل های ۷ و ۸ با افزایش مقیاس زمانی SPI دوره خشک سالی بیشتر می شود و در SPI

۱۲ ماهه، سال‌های ۲۰۰۱ و ۲۰۰۹ خشک‌سالی با شدت بالایی به وقوع پیوسته است. در ایستگاه نی‌ریز دوره‌های ترسالی و خشک‌سالی به صورت متناوب مشاهده می‌شود.

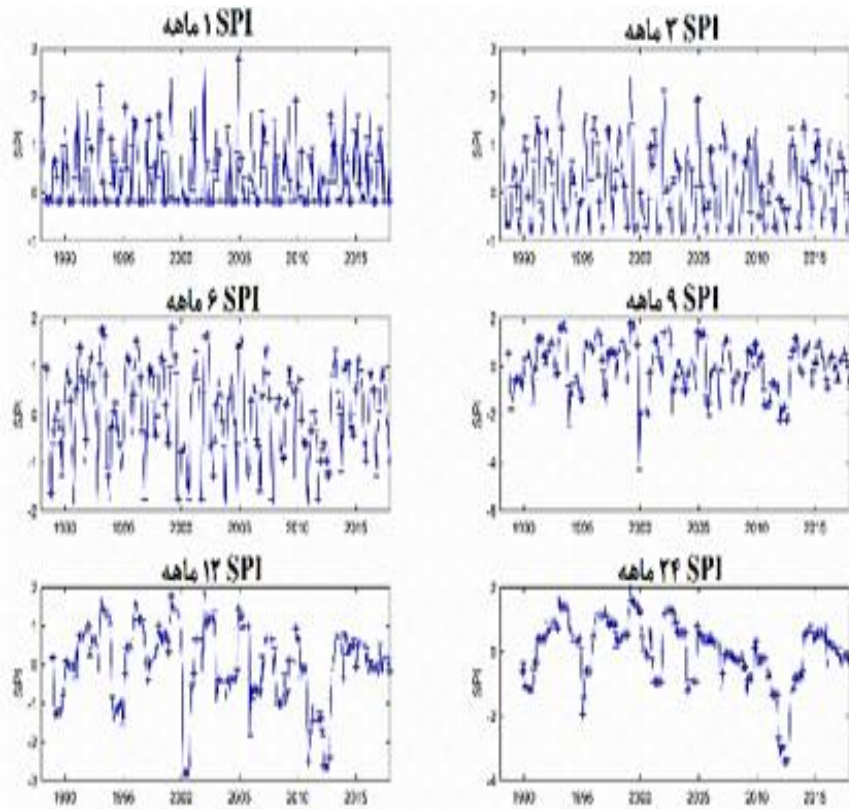


شکل ۹- نمودار SPI ایستگاه لارستان منبع: (نگارنده)

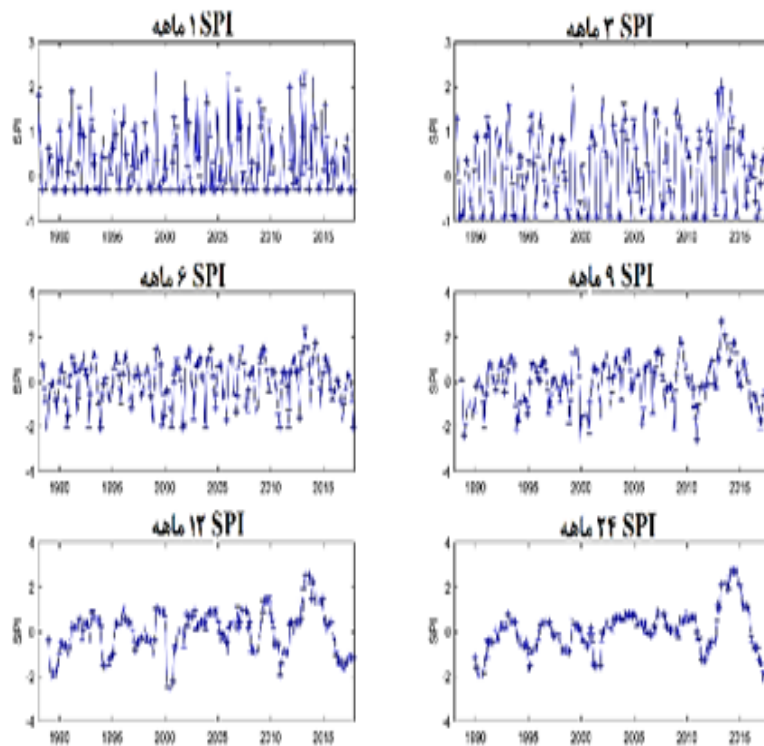


شکل ۱۰- نمودار SPI ایستگاه جهرم منبع: (نگارنده)

در ایستگاه لارستان (شکل ۹) در SPI ۳ ماهه شدیدترین ترسالی تقریباً در سال ۱۹۹۸ به وقوع پیوسته است که در SPI ۶، ۹، ۱۲ و ۲۴ ماهه با شدت کمتری قابل مشاهده است، در SPI ۱۲ ماهه وقوع یک خشکسالی شدید در سال ۲۰۰۰ قابل مشاهده است. در ایستگاه جهرم در SPI ۹ ماهه خشکسالی های بسیار شدیدی رخ داده است که در SPI ۱۲ با شدت کمتری قابل مشاهده است.



شکل ۱۱- نمودار SPI ایستگاه داراب منبع: (نگارنده)




شکل ۱۲- نمودار SPI ایستگاه سپیدان منبع: (نگارنده)

ایستگاه داراب در SPI ۶، ۹ و ۱۲ ماهه در سال ۲۰۰۰ خشک‌سالی شدیدی رخ داده است که در

SPI ۲۴ ماهه خشک سالی با این شدت تقریباً در سال ۲۰۱۳ مشاهده می شود.

بر اساس مقادیر SPI در سال ۲۰۰۰ و ۲۰۱۱ خشک سالی شدیدی رخ داده است و در سال ۲۰۱۴ ایستگاه سپیدان دارای ترسالی شدیدی بوده است.



شکل ۱۲- نمودار SPI ایستگاه فسا منبع: (نگارنده)

باتوجه به شکل ۱۳ در ایستگاه فسا شدیدترین خشک سالی در سال ۲۰۰۰ به وقوع پیوسته است و بر اساس SPI ۱۲ و ۲۴ ماهه از سال ۲۰۰۲ تا ۲۰۰۶ ترسالی در این ایستگاه رخ داده است.

روش ریکارنس پلات روشی است برای تبدیل سری های زمانی به عکس، هر عکس از سه لایه B, G, R تشکیل می گردد برای تبدیل داده های بارندگی به عکس در مقیاس های زمانی ۱، ۳، ۶، ۹، ۱۲ و ۲۴ ماهه لایه های عکس ها با استفاده از فرمول بارش استاندارد شده ساخته شد و با ادغام این سه لایه خروجی به صورت عکس های سیاه و سفید و رنگی به دست آمد. عکس های سیاه و سفید دارای دو بعد i و j هستند و مقدار هر پیکسل عددی بین ۰-۱ قرار دارد، عکس های سیاه و سفید ساخته شده به دلیل کم بودن داده های مورد استفاده از کیفیت لازم برخوردار نبوده است؛ از این رو عکس رنگی برای داده ها ساخته شد و به عنوان ورودی شبکه الکس نت قرار گرفتند.

جداول مربوط به معیارهای ارزیابی دقت (P)، صحت (R)، میانگین هارمونیک (f1)، ماکرو-f1 و میکرو-f1 آورده شده است. برای معیارهای دقت (P)، صحت (R) و میانگین هارمونیک (f1) نتایج مربوط به کوتاه مدت، ۳ ماهه میان مدت، ۹ ماهه و بلند مدت ۲۴ ماهه آورده شده است، اما برای دو معیار ماکرو-f1 و میکرو-f1 نتایج مربوط به تمام مقیاس های زمانی آورده شده است.

جدول ۲- معیار ارزیابی دقت (P) (نگارنده)

مقیاس ۳ ماهه				کلاس روش یادگیری
ماشین بردار پشتیبان	درخت تصمیم	K نزدیک‌ترین همسایه	یادگیری عمیق	
۳۳/۳۳	۴۵/۴۵	۳۷/۵۰	۳۳/۳۳	۱
۷۱,۴۳	۳۷,۵	۳۰,۳۰	۴۷,۶۲	۲
۵۴,۳۱	۵۲,۳۸	۵۶,۱۲	۵۴,۳۷	۳
۹۲,۶۵	۹۱,۸۵	۹۲,۷۲	۹۱,۹۱	۴
.	.	.	.	۵
.	.	.	.	۶
.	.	.	.	۷

مقیاس ۹ ماهه				کلاس روش یادگیری
ماشین بردار پشتیبان	درخت تصمیم	K نزدیک‌ترین همسایه	یادگیری عمیق	
.	۱۶/۶۷	۱۲/۵۰	۶۶/۶۷	۱
.	۱۶/۶۷	۱۳/۳۳	۵۰/۰۰	۲
۴۹/۳۰	۲۸/۸۷	۴۳/۲۴	۴۹/۲۸	۳
۸۲/۸۳	۸۳/۱۴	۸۴/۷۳	۸۱/۸۰	۴
۶۶/۶۷	۴۰/۲۸	۴۶/۱۵	۵۱/۹۲	۵
۶۰/۹۸	۵۶/۶۷	۵۶/۷۶	۴۶/۱۵	۶
۷۳/۶۸	۷۳/۶۸	۵۰/۰۰	۵۰/۰۰	۷

مقیاس ۲۴ ماهه				کلاس روش یادگیری
درخت تصمیم	K نزدیک‌ترین همسایه	یادگیری عمیق	ماشین بردار پشتیبان	
۱۰۰/۰۰	۹/۰۹	۶۶/۶۷	۹۰/۹۱	۱
.	۷/۶۹	۸/۸۲	۷۲/۲۲	۲
.	۱۵/۰۰	۱۵/۷۹	۶۷/۱۴	۳
۷۲/۵۳	۷۳/۹۴	۷۷/۶۱	۹۰/۸۲	۴
.	۱۱/۵۴	۳۶/۷۳	۷۴/۱۹	۵
۴۶/۶۷	۲۷/۰۳	۳۰/۲۳	۶۶/۶۷	۶
.	۱۷/۶۵	.	۶۰/۰۰	۷

معیار دقت، نشان‌دهنده 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 است. 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 ۶۶/۶۷ درصد احتمال تعلق آن داده به کلاس دیگری وجود دارد. بر اساس معیار ارزیابی دقت عدد صفر به

این معناست که شبکه نتوانسته است چنین کلاسی را تشخیص دهد. با افزایش مقیاس زمانی روش های K نزدیک ترین 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 می کند، اطمینان این روش نیز بر روی پیش بینی های کلاس های مختلف بیشتر می شود. 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) (منبع: نگارنده)

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

معیار صحت نشان دهنده توانایی روش یادگیری برای تشخیص صحیح داده های یک کلاس خاص است، به عبارت دیگر چه درصدی از داده های یک کلاس توسط روش یادگیری مدنظر به درستی تشخیص داده شده اند. بر اساس معیار دقت در مقیاس زمانی ۳ ماهه هر ۴ روش یادگیری عمیق، k نزدیک ترین همسایه، درخت تصمیم و ماشین بردار پشتیبان نتوانسته اند کلاس های ۵، ۶ و ۷ را تشخیص بدهند. در مقیاس زمانی ۹ ماهه ماشین بردار پشتیبان کلاس های ۱ و ۲ را تشخیص نداده است و در ۲۴ ماهه روش k نزدیک ترین همسایه کلاس ۷ و ماشین بردار پشتیبان کلاس های ۲، ۳، ۵ و ۷ را تشخیص نداده اند، میزان دقت در این کلاس ها صفر شده است (که به این معناست روش استفاده شده نتوانسته چنین کلاسی را تشخیص بدهد) در معیار صحت هم مقادیر سفر مربوط به کلاس هایی بوده اند 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 کلاس ها، 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 می توان 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 P و R (منبع: نگارنده)

مقیاس زمانی	روش یادگیری	کلاس						
		۷	۶	۵	۴	۳	۲	۱
۳ ماهه	یادگیری عمیق	۰	۰	۰	۹۳/۱۲	۵۴/۳۷	۴۰/۰۰	۳۵/۲۹
	K نزدیک‌ترین همسایه	۰	۰	۰	۹۳/۳۰	۵۵/۰۰	۳۲/۷۹	۴۰/۰۰
	درخت تصمیم	۰	۰	۰	۹۲/۷۰	۴۷/۳۱	۴۴/۱۲	۵۵/۵۶
۹ ماهه	ماشین بردار پشتیبان	۰	۰	۰	۹۳/۷۳	۵۷/۸۰	۲۸/۵۷	۳۷/۵۰
	یادگیری عمیق	۴۵/۰۰	۴۵/۰۰	۴۴/۶۳	۸۵/۱۱	۴۴/۷۴	۴۶/۴۳	۵۳/۳۳
	K نزدیک‌ترین همسایه	۶۰/۳۸	۵۴/۵۵	۴۵/۱۱	۸۴/۹۸	۴۱/۰۳	۱۳/۳۳	۱۲/۵۰
۲۴ ماهه	درخت تصمیم	۷۰/۰۰	۴۸/۵۷	۴۱/۴۳	۸۲/۷۴	۳۱/۲۸	۱۶/۶۷	۱۴/۲۹
	ماشین بردار پشتیبان	۷۰/۰۰	۶۱/۷۳	۵۳/۱۰	۸۸/۲۵	۴۵/۷۵	۰/۰۰	۰/۰۰
	یادگیری عمیق	۶۰/۰۰	۵۸/۰۶	۷۴/۱۹	۹۳/۰۹	۶۴/۸۳	۵۷/۷۸	۷۶/۹۲
۲۴ ماهه	K نزدیک‌ترین همسایه	۰/۰۰	۳۳/۷۷	۳۲/۴۳	۸۰/۳۴	۱۰/۷۱	۹/۸۴	۵۲/۱۷
	درخت تصمیم	۱۶/۶۷	۲۸/۱۷	۱۰/۵۳	۷۲/۹۸	۱۷/۲۴	۷/۵۵	۸/۰۰
	ماشین بردار پشتیبان	۰/۰۰	۴۳/۷۵	۰/۰۰	۸۴/۰۱	۰/۰۰	۰/۰۰	۴۴/۴۴

معیار میانگین هارمونیک ترکیبی از معیارهای دقت و صحت است که در جدول فوق آورده شده است. این معیار نشان می‌دهد که 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 قابل‌ملاحظه‌ای کرده است و اختلاف معناداری با بقیه روش‌های یادگیری دارد.

برای ارزیابی عملکرد شبکه‌های هوش مصنوعی دو معیار ارزیابی ماکرو -f1 و میکرو-f1 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 -f1 (منبع: نگارنده)

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

معیار ماکرو -f1 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 ۶۵/۳۵٪ پیشی گرفته است. رفتار شبکه K نزدیک‌ترین همسایه ثابت بود و با افزایش مقیاس زمانی کارآرایی آن کاهش یافت، شبکه درخت

تصمیم در کوتاه مدت نسبت به بقیه روش ها عملکرد بهتری داشته است؛ اما با افزایش مقیاس زمانی عملکردش کاهش یافته است طوریکه در ۲۴ ماهه بدترین عملکرد را داشته است، شبکه ماشین بردار پشتیبان رفتار منطقی و قابل اتکایی از خود نشان نداده است.

جدول ۶. معیار ارزیابی میکرو-f1 (منبع: نگارنده)

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

بر اساس معیار میکرو-f1 هر ۴ شبکه با درصد بالای ۵۰ در تمام مقیاس های زمانی قادر به پیش بینی خشکسالی بوده اند و در هر مقیاس زمانی با اختلاف کمی نسبت به یکدیگر قادر به پیش بینی بوده اند. بر اساس معیار میکرو-f1 روش یادگیری عمیق در هر ۶ مقیاس زمانی ۷۰ درصد به بالا توانسته خشکسالی را پیش بینی کند این در صورتی است که در معیار ارزیابی ماکرو-f1 این چنین نیست و در مقیاس زمانی ۱ ماهه روش یادگیری عمیق با ۲۲/۷۱ درصد توانسته است کلاس ها را به درستی تشخیص بدهد.

همان طور که توضیح داده شد برای داده هایی که اریب هستند و توزیع داده ها به صورت نرمال نمی باشد معیار ماکرو-f1 از اهمیت بیشتری برخوردار است، به دلیل اینکه داده های بارندگی به کار برده شده دارای پراکنش زیاد و کج شدگی به یک سمت هستند معیار ماکرو-f1 برای مقایسه روش های یادگیری با یکدیگر در نظر گرفته شد.

به طور کلی تمام روش های یادگیری توانسته اند پیش بینی را انجام دهند که با پژوهش های یوریکلی و همکاران (22) که از تکنیک های درخت تصمیم برای پیش بینی خشکسالی استفاده کرده اند و (۲۱) که از روش ماشین بردار پشتیبان برای پیش بینی بارش استفاده کرده اند مطابقت داشته است. در این پژوهش سعی شده است که با ترکیب استفاده از روش پلات بازگشتی و شبکه یادگیری عمیق پیش بینی خشکسالی انجام شود که دارای نوآوری قابل توجهی است، اما موضوع قابل تأمل نیاز شبکه های یادگیری عمیق به حجم بالای اطلاعات برای آموزش است. به طور کلی روش یادگیری عمیق در کوتاه مدت به دلیل کم بودن داده ها از خود عملکرد خوبی نشان نداده است؛ اما در بلندمدت با افزایش داده ها به مرور عملکرد روش یادگیری عمیق بهتر از دیگر روش های استفاده شده است، روش های درخت تصمیم و K نزدیک ترین همسایه در کوتاه مدت و برای داده های کم عملکرد بهتری نسبت به بلندمدت و برای داده های زیاد داشته اند؛ اما در کوتاه مدت میتوان گفت روش درخت تصمیم بهتر بوده است، می توان در صورت دارا بودن داده های زیاد از روش یادگیری عمیق استفاده کرد و در داده های کم از روش درخت تصمیم استفاده کرد و یا از شبکه های عصبی و یا تلفیقی از چند روش یادگیری دیگر می توان برای پیش بینی خشکسالی که یک پدیده طبیعی و غیرمنتظره است استفاده کرد همانند سینگ (۲۰) که به منظور پیش بینی 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 ب بوده‌ایم، در این میان شدیدترین خشکسالی در ایستگاه ابرکوه در مقیاس زمانی ۹ ماهه رخ داده است. بر اساس معیار ماکرو-f1 در مقیاس زمانی ۱ و ۳ ماهه با مقادیر ۶۴/۶۵ و ۵۲/۹۹، روش درخت تصمیم و در مقیاس زمانی ۶، ۹، ۱۲ و ۲۴ ماهه با مقادیر ۵۰/۶۸، ۵۲/۰۳، ۵۴/۸۸ و ۶۵/۳۵، روش یادگیری عمیق بهتر عمل کردند. روش ماشین‌بردار پشتیبان رفتار متغیر و غیرقابل اتکایی 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 صورتی که در مقیاس زمانی ۱۲ ماهه با ۲۹/۱۳ بدترین عملکرد را داشته است، میزان تغییر رفتار روش ماشین‌بردار پشتیبان همچون یک نمودار سهمی است. روش K نزدیک‌ترین همسایه در کوتاه‌مدت در ۱ ماهه ۶۴/۴۱ درصد توانسته است خشکسالی را پیش‌بینی کند؛ اما با افزایش مقیاس زمانی عملکردی را که در کوتاه‌مدت داشته است از دست داد و در مقیاس زمانی بلندمدت 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 کوتاه‌مدت بهتر از روش K نزدیک‌ترین همسایه خشکسالی را پیش‌بینی کرده است به طوری که 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 بلندمدت روش K نزدیک‌ترین همسایه بهتر از روش درخت تصمیم بود طوریکه در مقیاس زمانی ۲۴ ماهه بدترین عملکرد در پیش‌بینی خشکسالی مربوط به روش درخت تصمیم با ۲۳/۰۲ است، 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 است که از مقیاس زمانی کم به سمت مقیاس زمانی زیاد در حال کاهش پیدا کردن است و شیب خط روش درخت تصمیم بیشتر از روش K نزدیک‌ترین همسایه است.

بحث و نتیجه‌گیری

پیش‌بینی خشکسالی برای یک ماه آتی در استان فارس 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 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 کوتاه‌مدت به

دلیل کم بودن داده ها نتوانسته است به خوبی پیش بینی را انجام دهد؛ اما در بلندمدت به دلیل افزایش داده های عملکرد خود را بهبود بخشیده است و بهترین عملکرد را داشته است. روش SVM در مقیاس های زمانی مختلف رفتارهای غیرقابل اتکا و متغیری از خود نشان داده است که به طور قطع نمی توان گفت روش مناسبی برای پیش بینی خشکسالی در مقیاس های زمانی مختلف باشد، روش های Decision Tree و KNN پیش بینی خشکسالی را در کوتاه مدت بهتر از بلندمدت توانسته اند پیش بینی را انجام دهند، این دو روش رفتاری نزدیک به یکدیگر داشته اند. برای تحقیقات آینده پیشنهاد می شود از روش های Decision Tree و KNN برای پیش بینی خشکسالی در کوتاه مدت استفاده شود، در این پژوهش با افزایش مقیاس زمانی و بیشتر شدن داده های بکار برده شده این دو روش کارایی خود را نسبت به کوتاه مدت از دست داده اند.

References:

- 1.Kogan, F. N., Vegetation index for areal analysis of crop conditions. Proceedings of 18th Conference on Agricultural and Forest Meteorology, AMS, W. Lafayette, Indiana, on 15–18 September 2018 (Indiana, USA), 2018, 103–106.
- 2.Singh, A (2017), Digital change detection techniques using remotely sensed data, International Journal of of Remote Sensing, 10, 989- 1003
- 3.Singh, R. P., Roy, S., Kogn, F., Vegetation and temperature condition indices from NOAA AVHRR data for drought monitoring over India, Int. J. Remote Sens., 20184393-4402.
- 4.Wylie, B. K., D. J. Meyer, L. L. Tieszen and S. Mannel. 2017. Satellite mapping of surface biophysical parameters at the biome scale over the North American grasslands: A case study. Remote Sensing of Environment 79(2-3): 266-278.
- 5.time, messenger Suleimanpour, Mohammad. Jokar, Leila (2018). Investigation of the drought situation and its trend in the Darudzen dam area based on drought statistical indicators. The first desert conference
- 6.Salamat, A. Al-Yasin, M. (2016) Guide to dealing with drought. Publisher: National Irrigation and Drainage Committee of Iran
- 7.Afifi, Mohammad Ebrahim, Chaterazer, Hadi, (2016) Monitoring vegetation changes due to drought in Darudzen watershed using MODIS images, Master's Thesis of Islamic Azad University of Larestan
- 8.Lashkari, Hassan, Matkan, Ali Akbar, Azadi, Hamid, Mohammadi, Zeinab (2016), Collaborative analysis of the high pressure role of subtropical subtropical in the subtropical river in severe droughts in the south and southwest of Iran, Danesh Zemin Research - 8th year, no. 30, p. 141 to p. 163
- 9.Shafii, Hassan. Hosseini, Mohammad (2016) Investigating vegetation cover using satellite data in Sistan region, Journal of Plant Ecophysiology, third year, pages 91-105.
10. Hadian, Fariba. Hosseini, Zahra, . Seyed Hosni, Marjan (2016) monitoring vegetation changes using rainfall data and NOAA AVHRR satellite images in Kermanshah province, Mortadari magazine, volume 1, 2013, 46-62.
11. Mohammadyari, Fariba. Pourakhsaz, Hassan. Tawakli, Mehdi. Aqdar, Hassan (2017) Preparation of vegetation cover map and monitoring of its changes using remote sensing techniques and geographic information system (case study: Behbahan city), Scientific-Research Quarterly of Geographical Information, No. 92, Winter 2017, 23-34.
12. Afifi.Mohammed Ebrahim 1400 Investigating the effect of drought on vegetation using remote sensing techniques (Case study of Drogen Dam catchment area) Geography Quarterly Volume 9 Number 70 Fall 1400 pp.153-
13. Bazar Afshan, Javad. 2012 Comparative study of some meteorological drought indicators in some climatic samples of Iran. Master's thesis, Faculty of Natural Resources, University of Tehran.
14. Jahangir, Mohammad Hossein; Maimene Khush-Mashraban, Hossein

Yousefi.2014. Monitoring and forecasting the drought situation using Standard Rainfall Index (SPI) and Multilayer Perceptron Neural Network (case study: Tehran and Alborz provinces). *Journal of Ecohydrology*, 2(4): 428-417.

15. Hasanpour Matikalai, Seyyed Hossein. Reza Saadati 2015. A review of applications of convolutional neural network and deep learning in computer vision. The 3rd National Conference of Electrical and Computer Engineering, Distributed Systems and Smart Networks, Kashan, Kashan Islamic Azad University

16. Sobak-Ro, 2015. Timely detection of anomalies in video. Doctoral dissertation in the field of computer engineering-artificial intelligence, Faculty of Computer Engineering, Malik Ashtar University.

17. Benevenuto, F., Rodrigues, T., Almeida, V., Almeida, J., & Ross, K. 2009. Video interactions in online video social networks. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 5(4): 1-25.

18. Benevenuto, F.; Magno, G.; Rodrigues, T. and Almeida, V. 2010. Detecting Spammers on Twitter. Seventh annual Collaboration, Electronic messaging, AntiAbuse and Spam Conference July, Redmond, Washington, US (CEAS).

19. Eckmann, J. P.; Kamphorst, S. O. and Ruelle, D. 1987. Recurrence Plots of Dynamical Systems. *Europhysics Letters*. 5 (9): 973-977

20. Singh, P., 2018. Indian summer monsoon rainfall (ISMR) forecasting using time series data: A fuzzy-entropy- neuro based expert system. *Geoscience Frontiers*, 9: 1243-1257.

21. Tripathi, Sh.; Srinivas, V. V. and Nanjundiah, R. S. 2006. Downscaling of precipitation for climate change scenarios: A support vector machine approach. *Journal of Hydrology*, 330: 62-640.

22. Yurekli, K.; Taghi Sattari, M. T.; Anli, A.S. and Hinis, M.A. 2012. Seasonal and annual regional drought Prediction by using data-mining approach, *Atmosfera*, 25(1): 85-105.

Drought prediction using artificial intelligence models (case study of Fars province)

Mohammadebrahim Afifi^{1*}, Vahid Sohrabi²

Abstract

The necessary step to deal with drought and adjust its consequences is to know and understand the vulnerability dimensions of each region. This shows the necessity of studying in the field of determining vulnerability and identifying the factors affecting it in different regions of the country. In this research, in order to introduce a suitable method for predicting drought for the next month, four artificial intelligence methods including deep learning (from Alexnet network) which is one of the convolution networks), K-nearest neighbor algorithm, multi-layer support vector machine and decision tree were considered. The monthly rainfall data of 11 synoptic stations of Fars province during the statistical period of 29 years (1988 to 2017) were used as experimental data. Standardized Precipitation Index (SPI) was calculated to show the drought situation in terms of intensity and duration in time scales of 1, 3, 6, 9, 12 and 24 months. At first, the precipitation data was placed as the input of the neural networks and the classification of the standardized precipitation index was placed as the output of the networks. 80% of the data was used for training and 20% of the data was used for testing the networks. The results showed that all the networks had the ability to predict drought, based on the evaluation criterion of the macro-f1 deep learning network in the time scale of 1 month with 22.71%, the most inefficient method and the decision tree with 64.65%, the most efficient method, but with an increase The time scale, the deep learning network improved its performance, so that in the 24-month time scale with 65.35%, the best performance related to the deep learning network was placed, followed by the support vector machine network with 57.40%.

Keywords: Drought, artificial intelligence, Fars province.

¹ Professor, Soil Science Department, Science and Research Branch; Islamic Azad University, Tehran, Iran.
Corresponding Author [.m.torkashvand54@yahoo.com](mailto:m.torkashvand54@yahoo.com)

² Professor, Soil Science Department, Science and Research Branch, Islamic Azad University, Tehran, Iran.