

## پتانسیل سنجی خشکسالی با استفاده از شاخص‌های سنجش از دور و شبکه عصبی مصنوعی (مطالعه موردی: استان کرمانشاه)

نادیا عباس‌زاده طهرانی<sup>۱</sup>، میلاد جانعلی‌پور<sup>۱\*</sup>، میلاد باقری<sup>۲</sup>

۱. استادیار، گروه کاربرد هوافضا در محیط زیست، مرکز زیست فضا و محیط زیست، پژوهشگاه هوافضا، وزارت علوم، تحقیقات و فناوری

۲. پژوهشگر، گروه کاربرد هوافضا در محیط زیست، مرکز زیست فضا و محیط زیست، پژوهشگاه هوافضا، وزارت علوم، تحقیقات و فناوری

(تاریخ دریافت ۱۴۰۰/۱۲/۰۸؛ تاریخ بازنگری ۱۴۰۱/۰۱/۳۰؛ تاریخ تصویب ۱۴۰۱/۰۲/۱۱)

### چکیده

خشکسالی، یک دوره ممتد کمبود بارش است که موجب بروز خسارت و کاهش عملکرد در محصولات زراعی می‌شود و بر کیفیت و کمیت منابع آب و کشاورزی منطقه تأثیر مستقیم دارد. فناوری سنجش از دور با تلفیق سیستم اطلاعات جغرافیایی (ساج) و با ایجاد امکان دسترسی، پردازش و تفسیر داده‌های مکانی، امکان پایش مطلوب‌تر خشکسالی را فراهم کرده است. هدف این مطالعه، تعیین مناسب‌ترین شاخص‌های سنجش از دوری و ارائه یک نمایه ترکیبی مبتنی بر روش هوشمند شبکه عصبی مصنوعی و در نهایت، استخراج نقشه پتانسیل خشکسالی است. بر اساس نتایج، بهترین شاخص‌های سنجش از دور جهت تعیین میزان ریسک بیابان‌زایی در منطقه، شاخص‌های پوشش گیاهی، میزان بارش و دمای سطح زمین هستند. نتایج بر اساس مقادیر شاخص بارش استاندارد شده (SPI) به دست آمده از ایستگاه‌های هواشناسی ارزیابی شدند. بر این اساس، مقدار دقت نتایج روش رگرسیون چندمتغیره،  $R^2 = 0.62$  و شبکه عصبی پرسپترون چندلایه  $R^2 = 0.91$  به دست آمد. بنابراین، روش شبکه عصبی پرسپترون چندلایه از روش رگرسیون چندمتغیره برای ایجاد یک شاخص ترکیبی خشکسالی توانایی بسیار بیشتری دارد. بر اساس نتایج، در بیشتر مناطق استان کرمانشاه پتانسیل بروز خشکسالی ماهانه وجود دارد. همچنین، پتانسیل خشکسالی سالانه، در مناطق شرقی استان بیشتر مشاهده می‌شود. اسلام‌آباد، سنقر و تا حدودی هرسین، شهرستان‌های دارای خطر پایین وقوع خشکسالی هستند.

**واژگان کلیدی:** پایش خشکسالی، شبکه عصبی، سنجش از دور، محیط زیست، تصاویر ماهواره‌ای.

## مقدمه

خشکسالی از پدیده‌های آب‌وهوایی است که هر ساله موجب بروز خسارت‌های زیادی می‌شود. این پدیده ممکن است در هر اقلیمی مشاهده شود که باعث کمبود منابع آب، غذا و غیره می‌شود [۱]. تعریف خشکسالی امری دشوار است [۲]. از این‌رو، تعاریف متنوعی برای آن از دیدگاه دانشمندان شاخه‌های علوم مختلف ارائه شده است. هواشناسان عموماً خشکسالی را به عنوان دوره‌ای در نظر می‌گیرند که طی آن بارش به طور قابل ملاحظه‌ای کمتر از میزانی باشد که به طور متعارف ریزش می‌کند. دانشمندان علوم کشاورزی، خشکسالی را از منظر حیات گیاهی و تغییرات میزان رطوبت خاک در نظر گرفته‌اند. از دیدگاه هیدرولوژیست‌ها خشکسالی در کاهش جریان آب سطحی و افت سطح آب زیرزمینی ظاهر می‌شود [۱]. خشکسالی از جمله مخاطرات طبیعی است که ارزیابی و پایش آن نیز ساده نیست، زیرا عوامل اقلیمی زیادی مانند بارندگی، دما، رطوبت هوا و خاک و تبخیر و تعرق و عوامل اقتصادی-اجتماعی در تعیین آن نقش دارند. همچنین، به‌طور بطئی و خزنده رخ می‌دهد و شروع و پایانش نامشخص است [۳]. میانگین بارش کشور ایران کمتر از یک‌سوم میانگین بارش سالانه‌ی جهان است و این میزان نیز در بازه‌های زمانی و مکان‌های مختلف متغیر است. بر اساس نظر کارشناسان، ایران در ۲۲ سال گذشته ۱۳ خشکسالی را پشت سر گذاشته است. اگر خشکسالی‌های نوع کشاورزی مد نظر قرار گیرد، وقوع خشکسالی در کشور هر دو سال یک‌بار اجتناب‌ناپذیر است [۴] و ۵. طبق نظر فائو خسارت‌های ناشی از خشکسالی در سال‌های ۲۰۰۱ و ۲۰۰۲ در ایران به‌ترتیب برابر با ۲/۵ و ۱/۷ میلیارد دلار بوده است [۶]. بنابراین، پایش این پدیده از منظر امنیت غذایی نیز حائز اهمیت است [۷]. برای مطالعه و ارزیابی خشکسالی، شاخص‌های متعددی از جمله شاخص پالم (PDSI)، آنومالی رطوبت (index-Z) [۸]، شاخص آنومالی بارندگی (RAI) [۹]، شاخص رطوبت محصول (CMI) [۱۰]، شاخص بارش استاندارد شده (SPI) [۱۱] ارائه شده است. هر یک از این شاخص‌ها مزایا و معایبی دارند. پایش خشکسالی در کشورهایمانند ایران از مشاهدات ایستگاه‌های هواشناسی، به دلیل نبود شبکه پراکنده و نیز عدم دسترسی به داده‌های بهنگام، از دقت مطلوبی

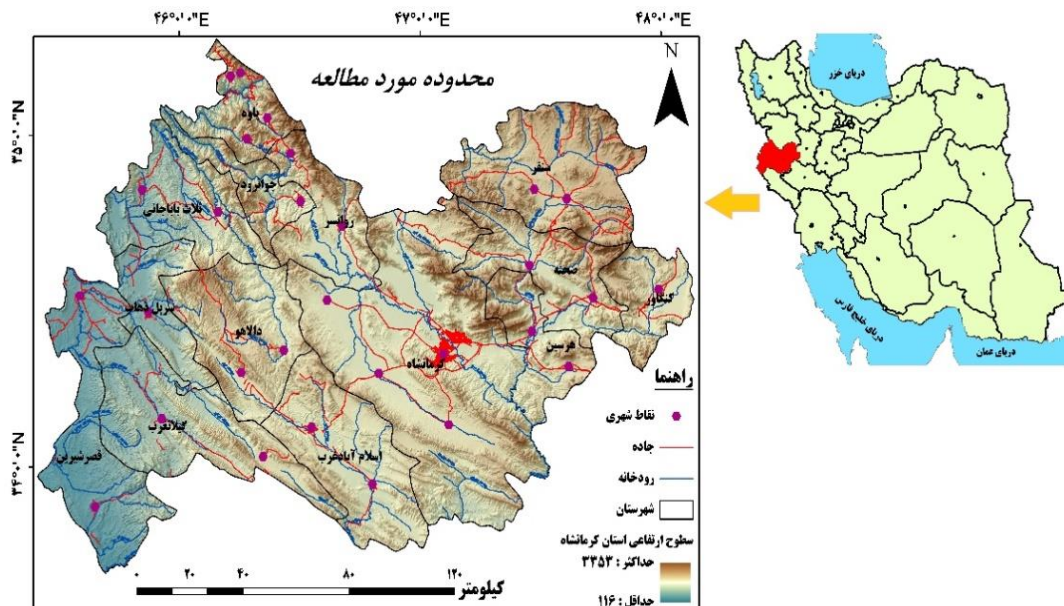
برخوردار نیست. فناوری سنجش از دور با تلفیق سیستم اطلاعات جغرافیایی و با تحلیل داده‌های مکانی و زمانی امکان ارزیابی و پایش پدیده‌های متغیر سطحی مانند خشکسالی را فراهم آورده‌اند، در دو دهه اخیر استفاده از روش‌های مبتنی بر داده‌های ماهواره‌ای برای پایش خشکسالی رو به افزایش بوده است [۱۲]. Al-Quraishi و همکاران (۲۰۲۰) برای نظارت بر خشکسالی در سلیمانیه عراق از شاخص خشکسالی هواشناسی SPI و اطلاعات سنجنده مادیس<sup>۱</sup> ماهواره ترا<sup>۲</sup> برای تهیه شاخص تفاضل نرمال شده پوشش گیاهی (NDVI)، دمای سطح زمین (LST) و شاخص آب (NDWI) استفاده کردند. بر اساس نتایج، شاخص پوشش گیاهی بیشترین همبستگی را با شاخص SPI دارد [۱۳]. Huang و همکاران (۲۰۲۰) به نظارت بر خشکسالی با استفاده از شاخص سلامت گیاهی (VHI)، شاخص خشکی دما-گیاه (TVDI) و شاخص شدت خشکسالی (DSI) پرداختند. بیشترین همبستگی، میان شاخص شدت خشکسالی و شاخص بارش استاندارد شده (SPI)، در سال‌های ۲۰۰۵-۲۰۰۹ مشاهده شد [۱۴]. Park و همکاران (۲۰۱۶) به مطالعه خشکسالی در ایالات متحده با استفاده از شانزده شاخص سنجش از دوری از جمله VCI، LST، NDVI، EVI و غیره، که از تصاویر ماهواره MODIS استخراج شده‌اند، پرداختند [۱۵]. رابطه بین شاخص‌های سنجش از دوری و SPI از طریق دو رویکرد جنگل تصادفی و رگرسیون تقویت شده بررسی شد. نتایج نشان دادند جنگل تصادفی بهترین عملکرد را برای پیش‌بینی SPI در بین دو رویکرد دارد. بر اساس نتایج، برای خشکسالی کوتاه‌مدت، شاخص دما و برای خشکسالی بلندمدت، شاخص پوشش گیاهی پیشنهاد شده است. هدف اصلی این تحقیق، ترکیب شاخص‌های مختلف سنجش از دوری با استفاده از شبکه عصبی مصنوعی جهت پایش پدیده خشکسالی است. در این راستا مشاهدات ایستگاه‌های هواشناسی و شاخص‌های سنجش از دوری منتج از پردازش تصاویر ماهواره‌ای، در شبکه عصبی مصنوعی ترکیب شده و در نهایت، نقشه پتانسیل خشکسالی استان کرمانشاه استخراج شده است.

## مواد و روش‌ها

## منطقه‌ی مطالعه‌شده

استان کرمانشاه با مساحت ۲۴۶۴۰ کیلومترمربع، هفدهمین استان ایران از نظر وسعت به شمار می‌رود که ۱/۵ درصد از مساحت کشور را در بر می‌گیرد. مختصات جغرافیایی استان کرمانشاه برابر با طول جغرافیایی ۴۵ درجه و ۲۰ دقیقه و ۳۹ ثانیه شرقی تا ۴۸ درجه و ۱ دقیقه و ۵۸ ثانیه شرقی و از عرض جغرافیایی ۳۳ درجه و ۳۷ دقیقه و ۸ ثانیه شمالی تا ۳۵ درجه و ۱۷ دقیقه و ۸۸ ثانیه شمالی است (شکل ۱). استان کرمانشاه با توجه به موقعیت جغرافیایی خود، یعنی قرار داشتن در ناحیه‌ی

کوهستانی زاگرس و واقع شدن در مسیر سیکلون‌های باران‌زا همواره از بارش‌های مناسبی برخوردار بوده است. در سال‌های اخیر با افزایش رخداد خشکسالی از جمله خشکسالی سال ۲۰۰۸-۲۰۰۹ در این بخش از زاگرس، خسارت‌ها و اثرات منفی درخور توجهی بر محیط طبیعی این ناحیه وارد آمده است. حداقل و حداکثر ارتفاع استان به ترتیب ۱۱۶ و ۳۳۵۳ متر است. میانگین بارش شهر کرمانشاه بین سال ۱۹۵۶ تا ۲۰۱۰ میلادی ۴۳۹ میلی‌متر بوده است. علاوه بر این، میانگین دمای تابستان در مناطق گرمسیر و سردسیر به ترتیب ۲۶ و ۳۲ درجه بوده است.



شکل ۱. موقعیت استان کرمانشاه و منطقه‌ی مطالعه‌شده

توزیع آماری مناسب، بر آمار بلندمدت بارندگی‌ها برآزش داده می‌شود. سپس، تابع تجمعی توزیع با استفاده از احتمالات مساوی به توزیع نرمال تبدیل می‌شود. به همین دلیل، برای به دست آوردن خشکسالی سال‌های ۱۳۹۲ تا ۱۳۹۸ از داده‌های بارندگی ۱۹ ساله ایستگاه‌ها استفاده شد تا در واقع آمار خشکسالی این ۷ سال مورد مطالعه، با توجه به بارندگی ۱۹ ساله به دست آید.

## داده‌های ماهواره‌ای

در این پژوهش از دو سری داده‌ی ماهواره‌ای شامل مادیس و تی.آر.ام<sup>۱</sup> استفاده شد. برای استخراج شاخص پوشش

## داده‌های استفاده‌شده

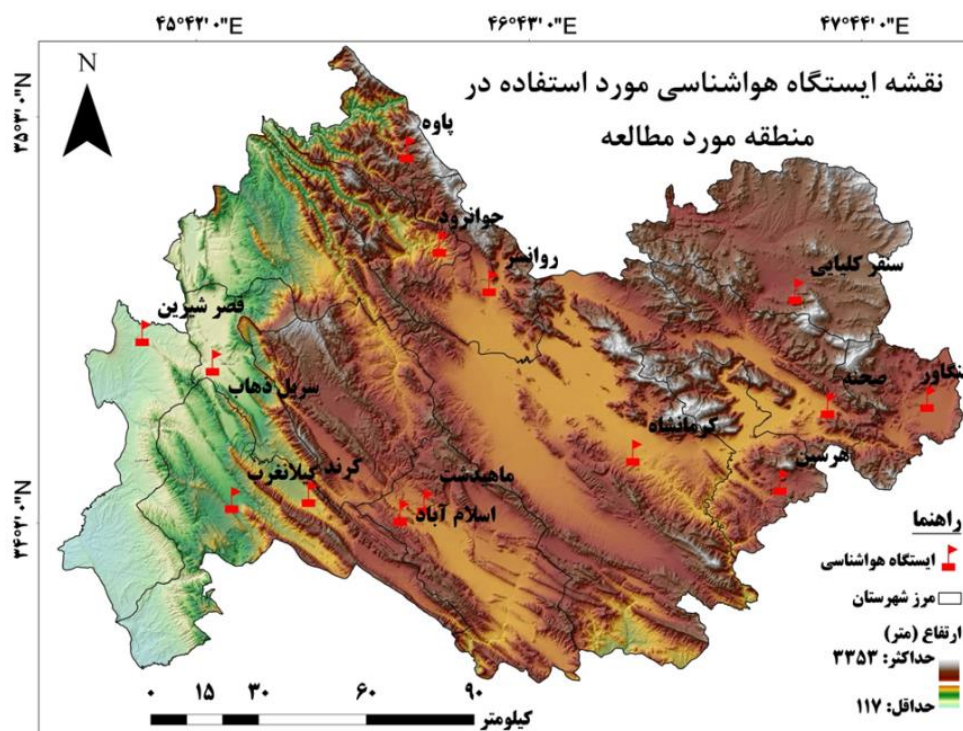
**داده‌های زمینی:** به منظور آموزش شبکه‌ی عصبی، نیاز به اخذ مشاهدات بارش در ایستگاه‌های هواشناسی است. بنابراین، داده‌های ماهانه‌ی بارندگی ۱۴ ایستگاه هواشناسی که در شکل ۲ نمایش داده شده‌اند، تهیه شد. این داده‌های به صورت ماهانه و در بازه ۱۹ ساله از ۱۳۸۰ تا ۱۳۹۸ تهیه و مرتب شدند. محاسبه‌ی شاخص خشکسالی SPI برای تمام ایستگاه‌های هواشناسی استان به صورت یک‌ماهه، سه‌ماهه و سالانه از سال ۱۳۹۲ تا ۱۳۹۸ (یک بازه ۷ ساله) با استفاده از نرم‌افزار DIP انجام شد. شاخص SPI برای هر منطقه بر اساس ثبت بارندگی‌های طولانی آن محاسبه می‌شود. ابتدا

جمع‌آوری تصاویر سنجش از دور از محصولات مادیس و پردازش آن‌ها و تهیه شاخص‌های سنجش از دوری از منطقه مطالعه‌شده؛ (۲) از داده‌های مربوط به ایستگاه‌های هواشناسی منطقه، شاخص بارش استاندارد شده<sup>۱</sup> به‌عنوان شاخص مرجع خشکسالی تهیه شد؛ (۳) با توجه به در اختیار داشتن داده‌های خشکسالی سری زمانی مربوط به سال‌های مورد مطالعه اقدام به پهنه‌بندی و تحلیل خشکسالی منطقه شد؛ (۴) با توجه به ارتباط بین شاخص‌های سنجش از دوری و شاخص مرجع خشکسالی (SPI)، بهترین شاخص‌های سنجش از دوری برای پایش خشکسالی با استفاده از تحلیل رگرسیون تعیین شد؛ (۵) شبکه عصبی برای ایجاد ارتباط میان شاخص‌های سنجش از دور و شاخص SPI آموزش داده شد؛ (۶) نقشه پتانسیل پدیده خشکسالی استان کرمانشاه تهیه شد. شکل ۳ روند کلی پژوهش را نشان می‌دهد.

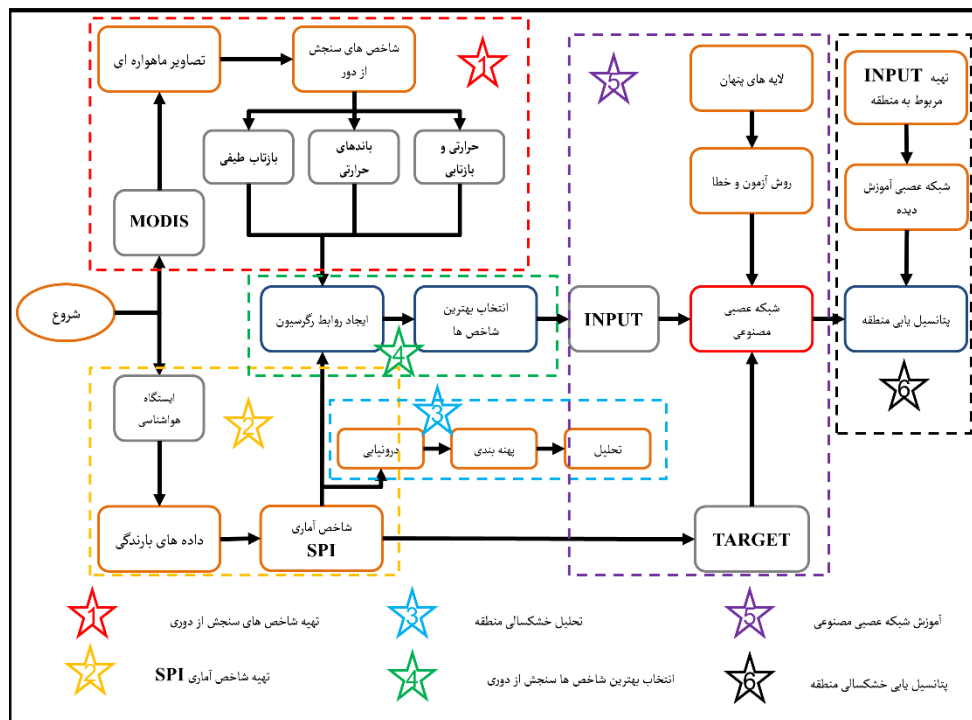
گیاهی و دما از محصولات MOD11\_A1 و MOD09GQ مادیس استفاده می‌شود [۱۶ و ۱۷]. از ماهواره TRMM اندازه‌گیری بارش در سطح خشکی‌ها و به‌خصوص مناطقی که دارای آمار و اطلاعات ثبت‌شده مناسبی نیستند، می‌توان استفاده کرد. در این مطالعه از داده‌های نرخ بارندگی سه‌ساعتی ماهواره TRMM B433 با توان تفکیک مکانی ۰/۲۵ درجه (۲۷/۷۵ کیلومتر) استفاده شده است [۱۸]. شاخص‌ها و تصاویر از سال ۱۳۹۲ تا ۱۳۹۸ مطابق مشاهدات ایستگاه‌های هواشناسی تهیه شدند. نکته درخور توجه این است که مشاهدات ماهواره‌ای دارای قدرت تفکیک زمانی متنوع هستند که با میانگین‌گیری متناظرسازی می‌شوند. به منظور استفاده از شبکه عصبی آموزش‌دیده از مشاهدات ماهواره‌ای سال ۱۳۹۹ نیز استفاده می‌شود.

### روش پژوهش

این تحقیق در ۶ بخش پیاده‌سازی شده است: (۱)



شکل ۲. موقعیت ایستگاه‌های هواشناسی استفاده‌شده در منطقه مورد مطالعه



شکل ۳. نمودار روند انجام پژوهش برای تهیه نقشه ریسک خشکسالی

و بیشینه مقادیر NDVI برای پیکسل  $i$  ام هستند. همچنین،  $L$  فاکتور تصحیح است.

#### محاسبه شاخص LST و TCI

دمای سطح زمین (LST) عاملی مهم در پایش تغییر جهانی اقلیم، رشد پوشش گیاهی، یخچال‌های طبیعی و خشکسالی است. دورسنجی و تصاویر ماهواره‌ای از جمله ابزارهایی هستند که می‌توانند در تخمین دمای سطح زمین و پایش خشکسالی بسیار مفید عمل کنند [۲۱، ۲۲، ۷ و ۲۶-۲۸]. شاخص وضعیت دما (TCI) در سال ۱۹۹۵ توسط Kogan، به عنوان ابزاری مکمل برای شاخص VCI به منظور بررسی دقیق‌تر پدیده خشکسالی معرفی شد. این شاخص که اساس آن بر دمای درخشندگی مبتنی است، برای بررسی عملکرد پوشش گیاهی نسبت به دما ارائه شده است.

$$TCI = \frac{LST_{i,max} - LST_{ijk}}{LST_{i,max} - LST_{i,min}} \quad (4)$$

که در آن،  $LST_{ijk}$  نشان‌دهنده مقدار LST برای پیکسل  $i$  ام، ماه (و یا هفته و یا روز از سال)  $k$  ام و سال  $j$  ام هستند. مقادیر  $LST_{i,max}$  و  $LST_{i,min}$  نیز به ترتیب نشان‌دهنده

#### محاسبه شاخص‌های پوشش گیاهی VCI, SAVI, NDVI

در این تحقیق سه شاخص پوشش گیاهی  $NDVI^1$ ،  $SAVI^2$  و  $VCI^3$  استفاده شده‌اند که به دلیل تعدد استفاده موفقیت‌آمیز از این شاخص‌ها در مطالعات پیشین [۷، ۱۹-۲۵]، مورد استفاده قرار گرفتند. فرمول شاخص‌ها در روابط ۱-۳ ارائه شده است:

$$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R} \quad (1)$$

$$SAVI = \frac{(1+L)(\rho_{NIR} - \rho_R)}{\rho_{NIR} + \rho_R + L} \quad (2)$$

$$VCI = \frac{NDVI_{ijk} - NDVI_{i,min}}{NDVI_{i,max} - NDVI_{i,min}} \quad (3)$$

که در آن  $\rho_{NIR}$  و  $\rho_R$  مقادیر انعکاسی در باندهای مادون قرمز نزدیک و قرمز هستند. که در آن،  $NDVI_{ijk}$  نشان‌دهنده مقدار NDVI برای پیکسل  $i$  ام، ماه (و یا هفته و یا روز از سال)  $k$  ام و سال  $j$  ام هستند. مقادیر  $NDVI_{i,max}$  و  $NDVI_{i,min}$  نیز به ترتیب نشان‌دهنده کمینه

1. Normalized difference vegetation index  
2. Soil adjusted vegetation index  
3. Vegetation Condition Index

4. Land Surface Temperature

### شبکه‌های عصبی مصنوعی

به زبان ساده، شبکه عصبی مصنوعی مدلی از ذهن انسان است. ذهن انسان می‌تواند مطالب جدید را یاد بگیرد و بر اساس آن تصمیم‌گیری کند. مؤلفه مهم ذهن انسان، یادگیری است که در زمان و مکان باعث تصمیمات خواهد شد. ذهن انسان از هزاران سلول عصبی به نام نورون تشکیل شده است. این نورون‌ها در شبکه عصبی طبیعی انسان وظیفه یادگیری را به عهده دارند. شبکه‌های عصبی مصنوعی مدلی از شبکه عصبی طبیعی هستند که هدف آن‌ها، مدل‌سازی مسائل در محیط رایانه و نرم‌افزار است. یک شبکه عصبی مصنوعی شامل ورودی، خروجی و لایه‌های میانی است. لایه‌های میانی از مجموعه نورون‌ها تشکیل شده‌اند که این نورون‌ها با توابعی به یکدیگر متصل هستند. ارتباط میان ورودی‌ها و خروجی‌ها با استفاده از آموزش لایه‌های میانی ایجاد می‌شود. از این‌رو، روش‌های یادگیری نظیر پس‌انتشار خطا توسعه داده شده‌اند [۳۳]. در این پژوهش هدف ایجاد ارتباط میان شاخص‌های خشکسالی استخراج‌شده از تصاویر سنجنش از دور به عنوان ورودی و شاخص SPI، به عنوان خروجی است. برای آموزش شبکه عصبی، از مشاهدات ایستگاه‌های هواشناسی استفاده شد. بنابراین، از مشاهدات ۱۴ ایستگاه هواشناسی در ۷ سال، ماهانه و سالانه به ترتیب ۱۱۷۶ و ۹۸ داده آموزشی برای شبکه عصبی آماده شد.

### نتایج و بحث

اعداد به دست آمده SPI سالانه از نرم‌افزار DIP برای ایستگاه‌های هواشناسی، با استفاده از روش IDW در محیط نرم‌افزار ARCGIS درون‌یابی و نقشه SPI سالانه برای ۷ سال مورد مطالعه تهیه شد. شکل ۴ مقدار SPI سالانه استان کرمانشاه را در سال‌های مختلف نمایش می‌دهد.

مقادیر شاخص‌های NDVI، SAVI، LST، TCI، VCI و VHI برای هر ایستگاه هواشناسی در ماه‌های مختلف در جدول ۱ نمایش داده شده است. همان‌طور که مشاهده می‌شود، ۱۱۷۶ نمونه برای هر شاخص محاسبه شده که مربوط به موقعیت جغرافیایی ایستگاه‌های هواشناسی است که در ماه‌های مختلف بازه زمانی مورد مطالعه، تهیه شده است.

کمینه و بیشینه مقادیر LST در چندین سال (بازه مطالعاتی) برای پیکسل i ام هستند.

### محاسبه شاخص‌های VHI و NDVI/LST

شاخص سلامت گیاه (VHI) توسط Kogan در سال ۱۹۹۵ ارائه شده است. این شاخص ترکیبی، برای نمایش خشکسالی و اثر ترکیبی تنش‌های رطوبتی و حرارتی است. از این شاخص برای تعداد زیادی از حوزه‌های مطالعاتی در سراسر جهان استفاده شده است [۲۹-۳۱]. شاخص VHI یک شاخص ترکیبی شامل TCI و VCI است و شیوه محاسبه آن در رابطه ۵ نمایش داده شده است.

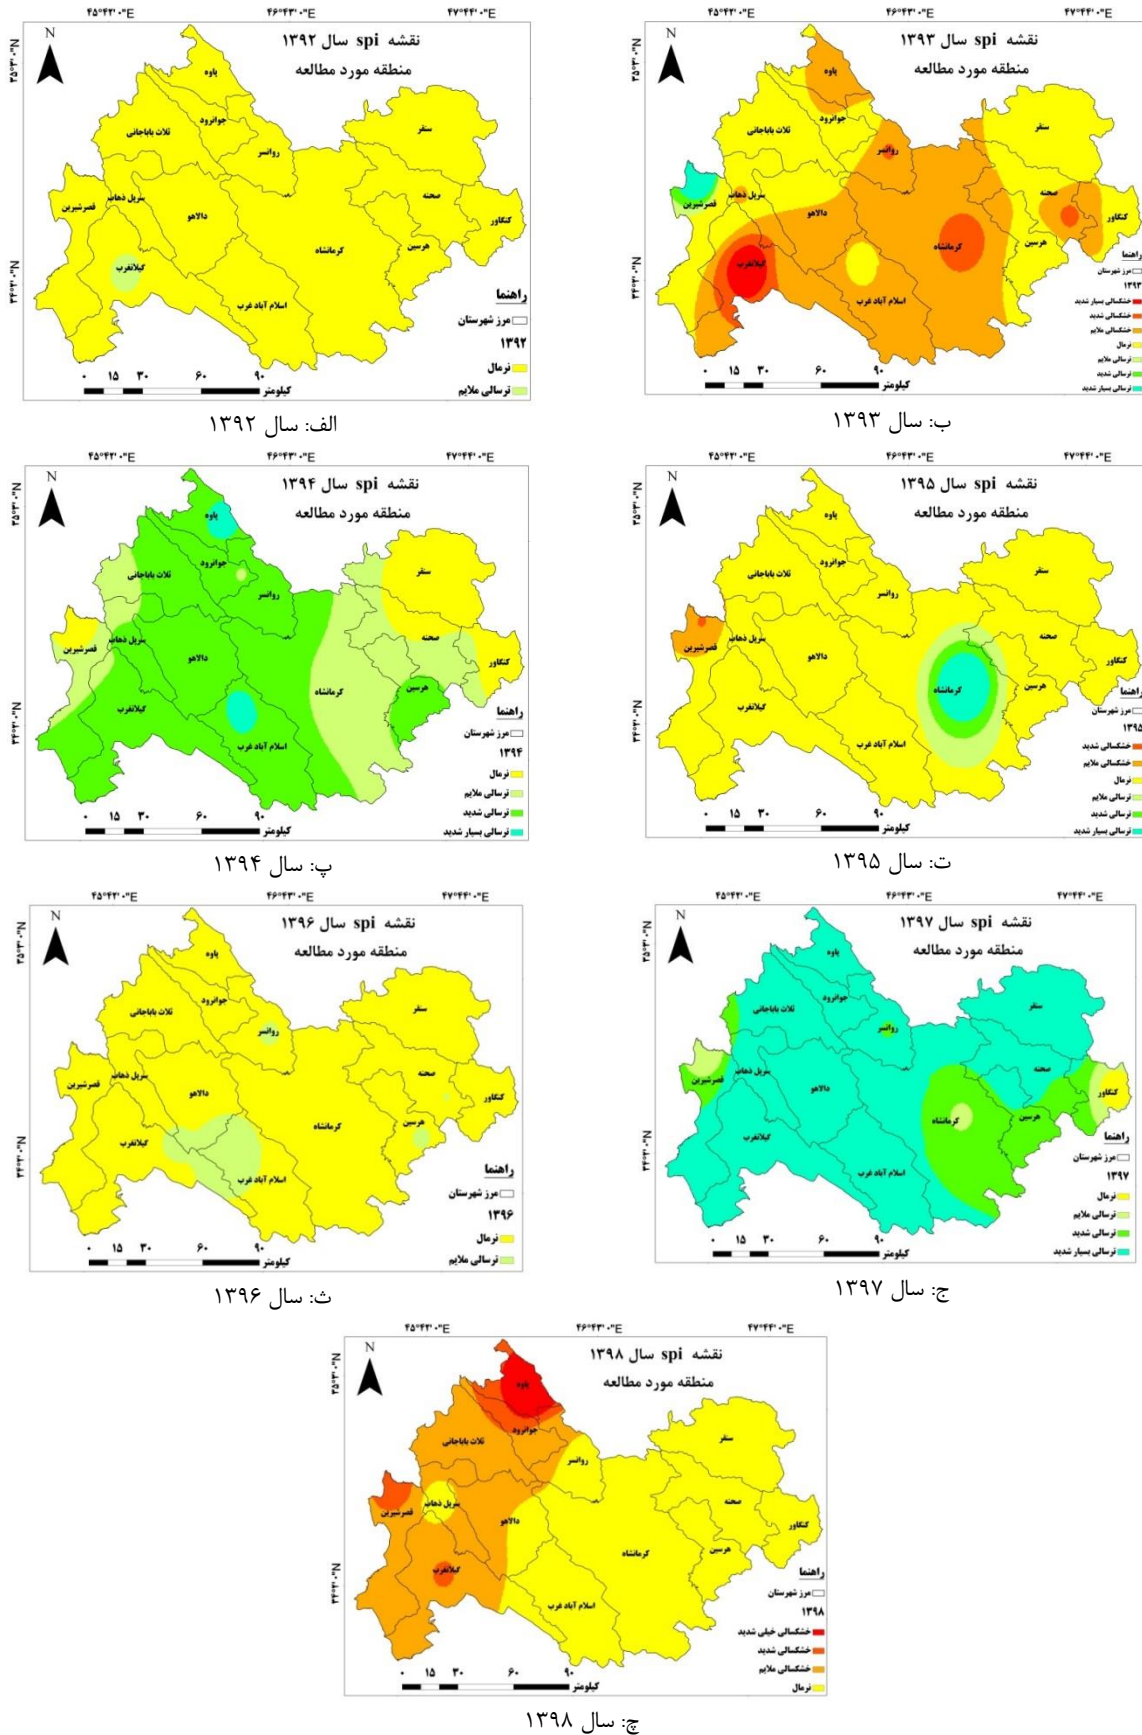
$$VHI = W1 \times VCI + W2 \times TCI \quad (5)$$

وزن‌های  $W1$  و  $W2$  به ازای مناطق و مطالعات مختلف، متفاوت خواهند بود و شیوه به دست آوردن آن‌ها نیز تفاوت خواهد داشت. در تعیین این اوزان، برای رسیدن به دقت مناسب، توجه به این نکته ضروری است که در شرایط عادی، گیاه در زمان شکل‌پذیری (برگ دادن) به رطوبت و در زمان گل دادن به دما وابستگی بیشتری دارد. در عمل به دلیل در اختیار نداشتن اطلاعات کافی از اطلاعات زمینی پوشش گیاهی از اعداد برابر ۰/۵ برای هر دو استفاده می‌شود که نتایج مناسب برای منطقه مورد مطالعه حاصل می‌کند. نمایی و همکاران با بررسی بین NDVI و دمای سطح زمین به همبستگی منفی بین این دو متغیر پی بردند. از نتایج تحقیق آن‌ها با استفاده از ماهواره NOAA می‌توان به تأثیر قوی کسر پوشش گیاهی در تغییرات مکانی دمای سطح زمین، حساسیت زیاد شاخص  $(\frac{LST}{NDVI})$  نسبت شاخص NDVI به شرایط رطوبتی سطح اشاره کرد [۳۲].

### رگرسیون چندمتغیره

به منظور ارزیابی و مقایسه نسبی نتایج روش شبکه عصبی از رگرسیون چندمتغیره استفاده می‌شود. به این منظور، ارتباط میان شاخص SPI و شاخص‌های NDVI، VCI، TCI، VHI و بارش TRMM مطابق رابطه ۶ برقرار می‌شود. ضرایب مجهول با استفاده از روش کمترین مربعات برآورد خواهد شد.

$$SPI = a_0 + a_1 \times NDVI + a_2 \times VCI + a_3 \times TCI + a_4 \times VHI + a_5 \times TRMM \quad (6)$$



شکل ۴. نقشه طبقه‌بندی خشکسالی استان کرمانشاه از سال ۱۳۹۲ تا ۱۳۹۸ (الف-ج) که از ایستگاه‌های هواشناسی به دست آمده‌اند

جدول ۱. داده‌های ماهانه شاخص‌های گیاهی

ID	NDVI	SAVI	LST	TCI	VCI	VHI
۱	۰,۱۲	۰,۱۸	۲۹۵,۵	۰,۷۶	۰,۵۶	۰,۶۶
۲	۰,۱۲	۰,۱۹	۳۰۳	۰,۷۶	۰,۵۶	۰,۶۶
۳	۰,۱۱	۰,۱۷	۳۰۷	۰,۷۶	۰,۵۴	۰,۶۶
۴	۰,۱۲	۰,۱۸	۳۱۰,۹	۰,۷۵	۰,۵۴	۰,۶۵
...	...	...	...	...	...	...
۱۱۷۶	۰,۱۱	۰,۱۶	۳۱۵,۵	۰,۷۵۱	۰,۵۶	۰,۶۵

می‌شود که بین شاخص‌های بازتابی شاخص NDVI و VCI با شاخص خشکسالی SPI رابطه مستقیمی وجود دارد. بنابراین، هرچه شاخص‌های بازتابی ما افزایش پیدا کنند مقدار شاخص خشکسالی SPI نیز افزایش پیدا می‌کند و در نتیجه، مقدار خشکسالی کاهش پیدا می‌کند. از آنجا که جنس شاخص‌های بازتابی از پوشش گیاهی است می‌توان به این نتیجه رسید که هرچه پوشش گیاهی در یک منطقه بیشتر باشد، مقدار شاخص خشکسالی در آن منطقه کمتر بوده است.

رابطه شاخص حرارتی شاخص TCI با مقدار شاخص خشکسالی SPI معکوس بوده است. بنابراین، با افزایش شاخص حرارتی مقدار عددی شاخص خشکسالی SPI کمتر شده و در نتیجه، خشکسالی در منطقه افزایش پیدا می‌کند. از آنجا که شاخص TCI از دمای سطح زمین استخراج می‌شود، بنابراین می‌توان به این نتیجه رسید که افزایش خشکسالی در یک منطقه به‌وضوح باعث افزایش دمای زمین در آن منطقه می‌شود. هر چه خشکسالی در یک منطقه افزایش پیدا کند، به همان نسبت مقدار پوشش گیاهی کاهش پیدا کرده و مقدار دمای سطح زمین افزایش پیدا می‌کند.

#### نتایج رگرسیون چندمتغیره

تحلیل رگرسیون روشی آماری است که در آن رابطه بین دو یا چند متغیر کمی بررسی می‌شود تا یک متغیر از متغیر و یا از متغیرهای دیگر پیش‌بینی شود. اگر در رگرسیون فقط دو متغیر وجود داشته باشد به آن رگرسیون ساده می‌گویند. رگرسیون چندمتغیره مشابه رگرسیون خطی ساده است با این تفاوت که در رگرسیون چندمتغیره چندین متغیر وابسته داریم و هدف تحلیل اثرات چند متغیر وابسته بر متغیر مستقل هست [۳۴ و ۳۵]. در این مطالعه شاخص خشکسالی SPI متغیر مستقل

به منظور نمایش ارتباط میان شاخص‌های سنجش از دور و شاخص SPI نمودار مقادیر ماهانه، سه‌ماهه و سالانه ترسیم شد. شکل ۵ ارتباط میان SPI سه‌ماهه و مقادیر شاخص‌های سنجش از دور را نمایش می‌دهد. خط برازش داده‌شده و معادله آن در شکل ۵ مشاهده می‌شود. بر این اساس، مقدار SPI با شاخص‌های NDVI، SAVI، VCI و VHI ارتباط مستقیم و با شاخص‌های LST و TCI ارتباط غیرمستقیم دارد.

بر اساس نتایج، شاخص SPI بیشترین همبستگی را با شاخص‌های بازتابی NDVI و VCI با  $R^2 = 0.23$  و  $R^2 = 0.35$  دارد. از بین شاخص‌های حرارتی شاخص TCI با  $R^2 = 0.33$  و از بین شاخص‌های بازتابی-حرارتی شاخص VHI با  $R^2 = 0.39$  بیشترین ضریب همبستگی را با SPI دارند. شاخص NDVI/LST به علت نوسان‌های زیاد و عدم ارتباط با شاخص SPI از مطالعه حذف شد.

مشابه نمودار سه ماه، برای داده‌های ماهانه و سالانه نیز ارتباط بررسی شد که نتایج در اینجا ارائه می‌شود. در SPI ماهانه از بین شاخص‌های بازتابی شاخص NDVI و VCI با  $R^2 = 0.20$  و  $R^2 = 0.27$  بیشترین ضریب همبستگی را به خود اختصاص داده‌اند. از بین شاخص‌های حرارتی شاخص TCI با  $R^2 = 0.32$  و از بین شاخص‌های بازتابی-حرارتی شاخص VHI با  $R^2 = 0.35$  بیشترین ضریب همبستگی را به خود اختصاص داده‌اند.

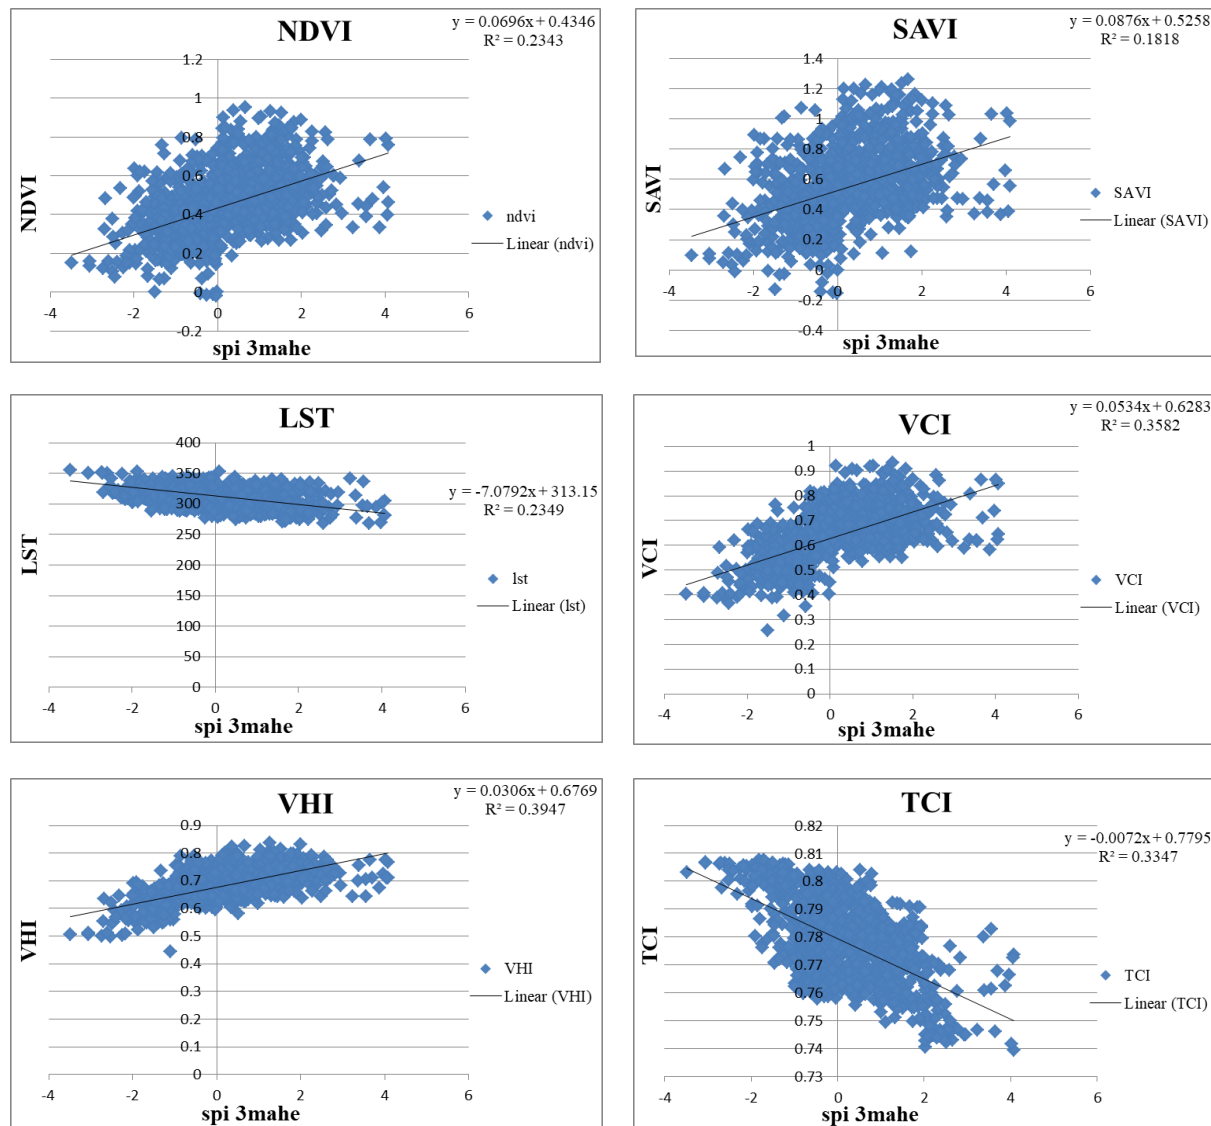
در SPI سالانه از بین شاخص‌های بازتابی شاخص NDVI و VCI با  $R^2 = 0.19$  و  $R^2 = 0.31$  بیشترین ضریب همبستگی را به خود اختصاص داده‌اند. از بین شاخص‌های حرارتی شاخص TCI با  $R^2 = 0.26$  و از بین شاخص‌های بازتابی-حرارتی شاخص VHI با  $R^2 = 0.29$  بیشترین ضریب همبستگی را به خود اختصاص داده‌اند.

با توجه به نمودارهای مربوط به بازه سه‌ماهه مشاهده



نمایش داده شده است. همان‌طور که مشاهده می‌شود بیشترین مقدار همبستگی میان SPI سه‌ماهه و شاخص‌های سنجش از دور مشاهده می‌شود.

و شاخص‌های NDVI، VCI، TCI، VHI و TRMM متغیرهای وابسته هستند. در زیر روابط رگرسیون چندمتغیره برای سه بازه‌ی زمانی ماهانه، سه‌ماهه و سالانه



شکل ۵. معادلات رگرسیونی، خط برازش و ضرایب تعیین SPI سه‌ماهه و شاخص‌های سنجش از دوری

جدول ۲. مقدار همبستگی و RMSE میان رگرسیون چندمتغیره حاصل از شاخص‌های سنجش از دور و SPI

رابطه	R2	RMSE
$SPI\ Mahane = 3.2 \times NDVI + 2.7 \times VCI - 8.4 \times TCI + 5.8 \times VHI - 4 \times TRMM + 1.26$	۰٫۶۰	۰٫۷۳
$SPI3Mahane = 2.3 \times NDVI + 3.7 \times VCI - 6.7 \times TCI + 3.8 \times VHI - 3.3 \times TRMM + 0.79$	۶۲٫۰۰	۰٫۶۸
$SPI\ Salane = 4.5 \times NDVI - 95.3 \times VCI + 118.3 \times TCI + 124.8 \times VHI + 3.6 \times TRMM - 121.6$	۴۰٫۰۰	۰٫۹۸

## نتایج شبکه عصبی مصنوعی

شبکه عصبی انواع مختلفی دارد که در این پژوهش از روش پرسپترون چندلایه<sup>۱</sup> با روش یادگیری پس انتشار خطا<sup>۲</sup> استفاده شد. الگوریتم پس انتشار خطا، دارای سه الگوریتم یادگیری است: شبکه با ضریب یادگیری ساده، شبکه با ضریب یادگیری متغیر و شبکه با روش لوببرگ - مارکوات. در این مطالعه از روش لوببرگ - مارکوات برای آموزشی شبکه عصبی استفاده شده است، زیرا در مطالعات پیشین نتایج مطلوبی داشته است [۳۶]. برای اجرای شبکه عصبی پرسپترون چندلایه از نرم افزار متلب<sup>۳</sup> استفاده شد. بعد از تهیه معیارهای ورودی که شامل ۵ عامل مؤثر در خشکسالی است و داده های شاخص SPI هفت ساله از ۱۴ ایستگاه هواشناسی تهیه شدند. این داده ها به سه بخش تقسیم شدند: بخش نخست به آموزش شبکه مربوط است، بخش دوم برای توقف محاسبات هنگامی که خطا رو به افزایش می گذارد و بخش سوم برای راستی آزمایی شبکه است [۳۳]. با توجه به تعداد داده های شاخص SPI که برای دوره ۷ ساله و ۱۴ ایستگاه است، تعداد داده های تعلیمی ۱۱۷۶ نمونه برای SPI ماهانه و سه ماهه و تعداد ۹۸ نمونه برای SPI سالانه به دست آمد. ۷۰ درصد نقاط در آموزش شبکه، ۱۵ درصد برای اعتبارسنجی که به منظور کالیبره کردن مدل استفاده می شود و ۱۵ درصد باقی مانده برای ارزیابی و نتیجه گیری استفاده شد.

برای انتخاب تعداد نورون های لایه های میانی یا پنهان، از روش آزمون و خطا<sup>۴</sup> استفاده شد. در این روش، بهترین انتخاب برای تعداد نورون های لایه میانی، مقداری است که طی مراحل آموزش و آزمایش شبکه، خطای شبکه به حداقل ممکن برسد [۳۷]. برای شبکه عصبی یادشده ۱۲ لایه پنهان برای SPI ماهانه و سه ماهه و ۱۰ نورون برای SPI سالانه انتخاب شد. در این آزمون ابتدا با افزایش تعداد نورون های لایه میانی خطای شبکه کمتر و دقت شبکه رو به افزایش می رفت، ولی از یک آستانه به بعد مقادیر خطا افزایش و دقت شبکه کاهش می شد. جدول ۳ نتایج خطای برازش شبکه عصبی مصنوعی آموزش داده شده برای نمونه آموزش (Training R)، نمونه چک (Validation R)، نمونه

ارزیابی (Test R) و تمامی نقاط (All R) نمایش داده شده است. بر اساس نتایج این جدول، مقدار R برای شبکه عصبی با ۱۲ نورون بیشتر از سایر موارد است. همچنین، در شبکه های عصبی با تعداد نورون کم، مقدار خطا زیاد است. بنابراین، پیشنهاد می شود در مطالعات آتی، برای تعیین مناسب ترین تعداد نورون، آنالیز حساسیت انجام شود.

نمودار همگرایی و مقادیر برآوردشده از شبکه عصبی در شکل ۶ نمایش داده شده است. نمودارهای سمت راست تعداد دفعات تکرار در شبکه را نشان می دهند. در بازه های ماهانه، سه ماهه و سالانه به ترتیب شبکه بعد از ۲۸، ۳۵ و ۱۰ بار تکرار متوقف شد و به آموزش های لازم دست یافت که در نتیجه تکرارهای ۲۲، ۲۹ و ۴ بهینه ترین حالت ممکن یعنی بیشترین همبستگی و کمترین خطا را دارند. در این نمودارها مشاهده می شود که بعد از حالت بهینه، باز هم شبکه تکرار شده است، اما مشاهده می شود که بعد از ۶ بار عدم همگرایی شبکه در نمونه های اعتبارسنجی، آموزش متوقف شده است. در نمودارهای سمت چپ برازش و ضرایب رگرسیون مراحل آموزش، صحت سنجی و آزمون نهایی و رگرسیون کلی شبکه عصبی نشان داده شده است.

در شبکه عصبی مصنوعی جلوگیری از یادگیری بیش از حد شبکه، امری بسیار مهم است، زیرا در این حالت شبکه به جای یادگیری و درک روابط بین پارامترها شروع به از بر کردن اطلاعات می کند که در اختیار آن گذاشته شده است [۳۸]. بخش دوم داده های آموزشی برای همین امر در شبکه تعبیه شده که با توجه به ضریب ۰/۸۶، ۰/۹۰ و ۰/۷۲ این مرحله برای سه بازه زمانی مورد مطالعه، می توان اطمینان حاصل کرد که به خوبی از یادگیری بیش از حد شبکه جلوگیری شده است.

مشاهده می شود که در نمودار تعداد دفعات تکرار، ابتدا با هر بار تکرار شبکه، مقدار خطا به شدت کاهش پیدا می کند سپس شدت این کاهش خطا به مرور کمتر می شود تا زمانی که مقدار خطای نمونه های ارزیابی، ثابت شده و سپس، مقدار خطای این بخش رو به افزایش می گذارد. به همین دلیل، بعد از توقف شبکه بهترین تکرار آخرین آن در شبکه نیست و تکراری که در آن مقدار اعتبارسنجی، حداقل مقدار را دارد، به عنوان بهترین و بهینه ترین تکرار توسط شبکه انتخاب می شود. نمونه های اعتبارسنجی به عنوان یک عامل کنترل برای یادگیری شبکه در ساختار

1. Multilayer Perceptron
2. Back-propagation
3. MATLAB
4. Trial and Error

سال ۱۳۹۹ وضعیت خشکسالی سالانه را تجربه کرده‌اند و شدت آن در شهرستان‌های کرمانشاه، کنگاور، روانسر، گیلان‌غرب، قصر شیرین و پاوه بیشتر بوده است. با تهیه شاخص‌های VHI، TCI، VCI، NDVI و TRMM برای بازه ماهانه و معرفی آن به شبکه عصبی که برای بازه ماهانه و سه‌ماهه آموزش دیده است، می‌توان شدت خشکسالی ماهانه و سه‌ماهه را برای هر یک از ۱۲ ماه سال ۱۳۹۹ به دست آورد.

#### پتانسیل‌یابی خشکسالی در منطقه

پس از آموزش شبکه عصبی مصنوعی، برای پتانسیل‌یابی خشکسالی منطقه، باید ورودی شبکه عصبی که برای آموزش شبکه مورد استفاده قرار گرفته است، برای بازه زمانی هفت‌ساله تهیه شود. ورودی‌ها شامل VCI، NDVI، TCI، VHI و TRMM هستند به صورت میانگین هفت‌ساله برای منطقه مطالعه‌شده در محیط گوگل ارث انجین تهیه شد. سپس، به شبکه آموزش دیده معرفی شده و شبکه آموزش دیده، مطابق آنچه در مرحله آموزش فرا گرفته است، منطقه مطالعه‌شده را از لحاظ پتانسیل خشکسالی پهنه‌بندی می‌کند. شکل ۸ نتیجه نقشه‌های پتانسیل خشکسالی در منطقه مطالعه‌شده را نمایش می‌دهد.

شبکه تعبیه شده و کنترل می‌کند که یادگیری شبکه در هر بار تکرار، افزایش پیدا کند. در نمودار سمت چپ، مقدار رگرسیون مراحل مختلف شبکه نمایش داده شده است.

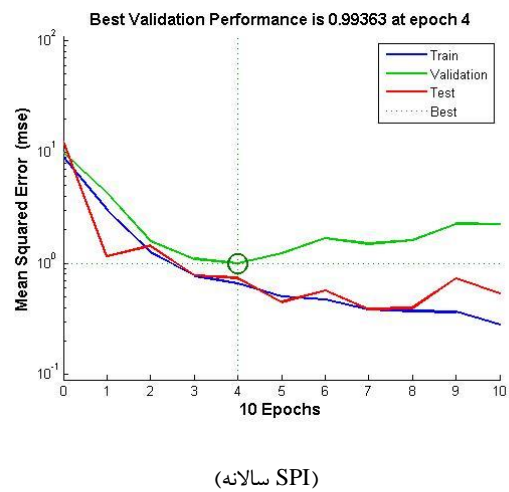
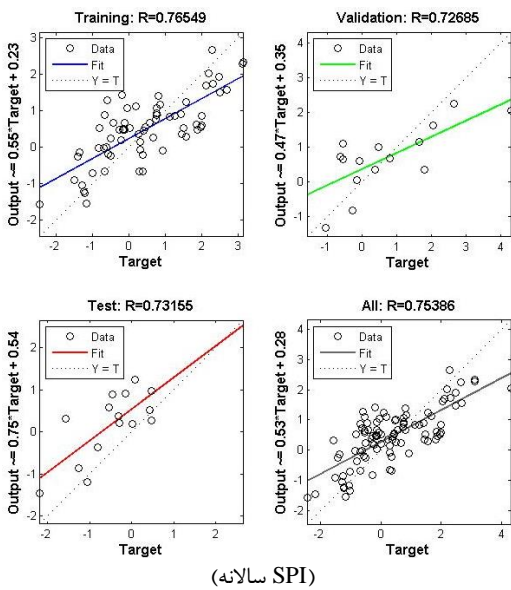

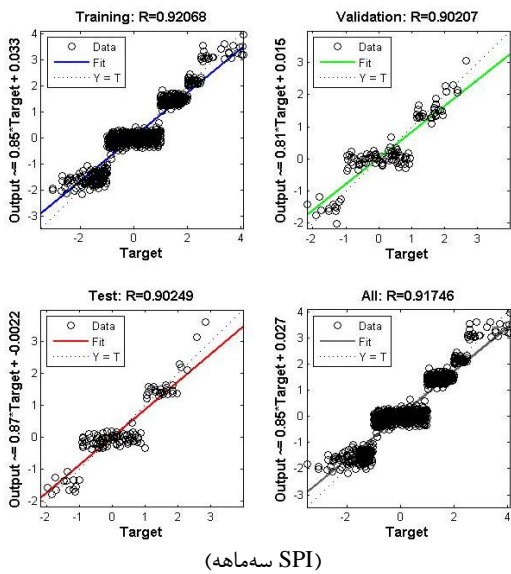
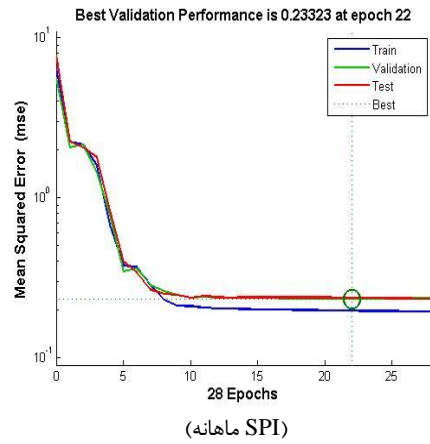
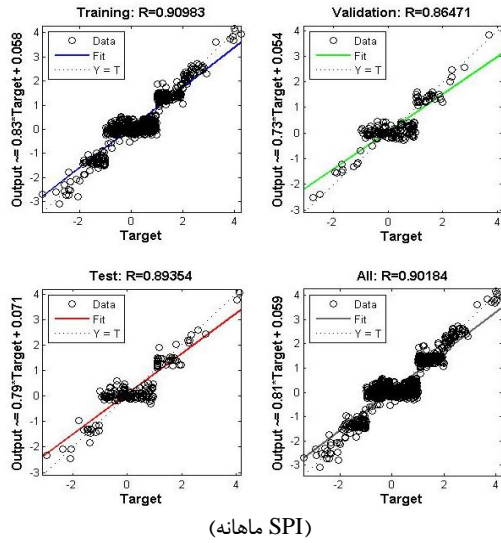
#### وضعیت خشکسالی سال ۱۳۹۹

بعد از تهیه شبکه آموزش دیده، به راحتی می‌توان منطقه را از لحاظ خشکسالی در هر سال و در هر بازه زمانی (ماهانه، سه‌ماهه و سالانه) با استفاده از آن بررسی و مطالعه کرد. برای این کار باید تمامی ورودی‌های که برای آموزش شبکه عصبی مصنوعی استفاده شده را برای بازه زمانی و سال مورد نظر تهیه کرده و آن را در اختیار شبکه عصبی قرار داد تا شبکه با توجه به آنچه آموخته است وضعیت منطقه را از لحاظ خشکسالی مشخص کند. برای نمونه، داده‌های ورودی به شبکه را که شامل شاخص‌های VHI، TCI، VCI، NDVI و TRMM است برای بازه سالانه در سال ۱۳۹۹ تهیه و در اختیار شبکه قرار گرفت و شبکه مطابق آموخته‌های خود خشکسالی منطقه را در سال ۱۳۹۹ مشخص کرد که در شکل ۷ نمایش داده شده است.

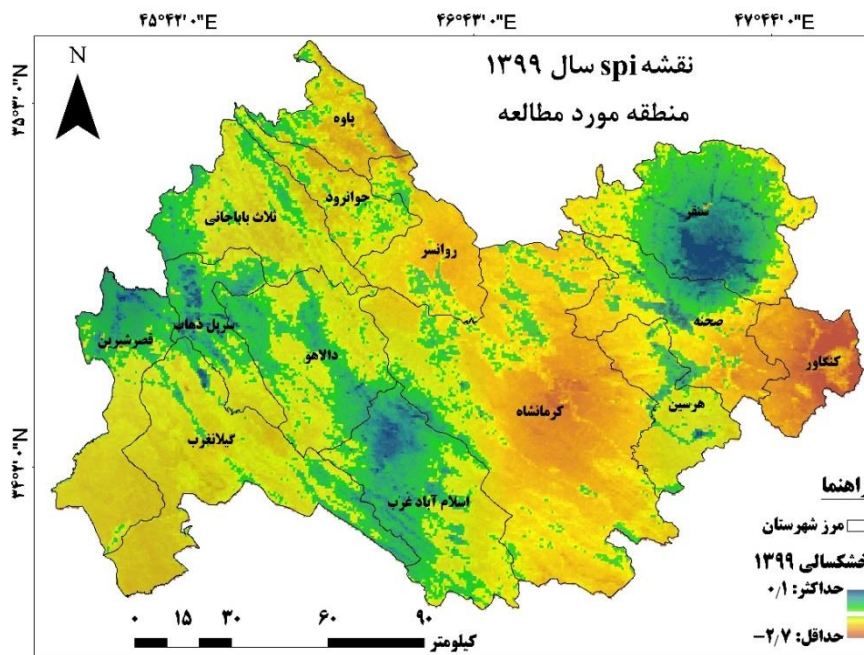
با توجه به راهنمای نقشه که مقدار حداکثر و حداقل خشکسالی در منطقه مطالعه‌شده را بین ۰/۱ تا منفی ۲/۷ نشان می‌دهد، مشاهده می‌شود که بیشتر نقاط استان در

جدول ۳. آزمون و خطای تعداد لایه‌های میانی شبکه عصبی برای SPI سه‌ماهه

تعداد لایه	R Training	R Validation	R Test	R All
۵	۰,۶۵۳	۰,۶۱۳	۰,۶۳۴	۰,۶۴۸
۶	۰,۷۱۲	۰,۶۳۶	۰,۶۸۱	۰,۶۸۱
۷	۰,۷۷	۰,۷۵۴	۰,۷۵۹	۰,۷۴۱
۸	۰,۸۷۵	۰,۷۵۲	۰,۸۲۳	۰,۸۴۶
۹	۰,۸۶۵	۰,۸۲۱	۰,۸۷۱	۰,۸۶۴
۱۰	۰,۸۷۷	۰,۸۶۱	۰,۸۸۲	۰,۸۸۶
۱۱	۰,۸۹۸	۰,۸۷۴	۰,۸۷۹	۰,۸۹۴
۱۲	۰,۹۲	۰,۹۰۲	۰,۹۰۲	۰,۹۱۷
۱۳	۰,۸۸۷	۰,۸۵۶	۰,۸۷۱	۰,۸۷۸
۱۴	۰,۸۸۱	۰,۸۱۱	۰,۸۶۱	۰,۸۷۱
۱۵	۰,۸۵۳	۰,۷۵۲	۰,۸۱۳	۰,۸۳۱



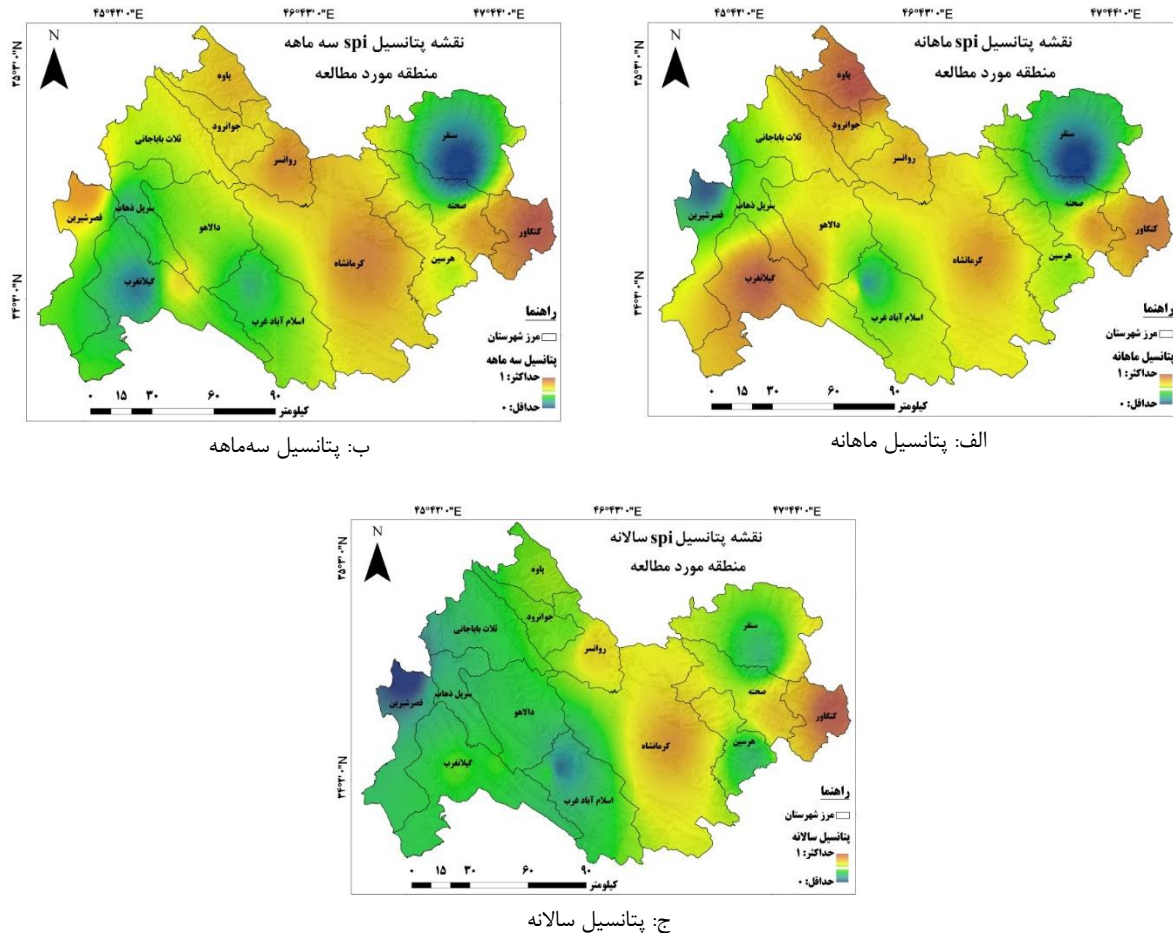
شکل ۶. نمودار همگرایی شبکه‌های عصبی آموزش دیده (سمت راست) مقادیر هدف و برآورد شده توسط شبکه عصبی (سمت چپ)



شکل ۷. نقشه خشکسالی برای سال ۱۳۹۹ و بازه سالانه

مختص یک ناحیه خاص از استان نیست و در بیشتر مناطق مشاهده می‌شود. در نقشه پتانسیل سه‌ماهه مشاهده می‌شود که پهنا مناطق دارای پتانسیل خشکسالی کمتر شده و در سمت شرق و مرکز استان دیده می‌شوند. مراکز دارای پتانسیل بیشتر وقوع خشکسالی در شهرستان‌ها کرمانشاه، کنگاور و روانسر وجود دارند. مناطقی که در مرکز و بخش شرقی استان قرار دارند با توجه به اینکه بارندگی از غرب استان به سمت شرق استان کمتر می‌شود، مناطق شرقی استان، پتانسیل بیشتری جهت وقوع خشکسالی دارند. در نقشه پتانسیل سالانه مشاهده می‌شود که این پتانسیل خشکسالی به شدت کمتر شده و بیشتر در مناطق شرق استان وجود دارند. بیشترین پتانسیل خشکسالی در این بازه زمانی در کنگاور و کرمانشاه با شدت کمتر نسبت به دو بازه زمانی دیگر وجود دارد. بیشتر بودن پتانسیل خشکسالی ماهانه نسبت به پتانسیل خشکسالی سالانه گویای آن است که نوسان‌های بارندگی در کوتاه‌مدت نسبت به بلندمدت بسیار بیشتر است و می‌توان اظهار کرد که در بازه سالانه کمبود بارش در یک ماه ممکن است با فزونی بارش در ماه‌های دیگر جبران شود.

پتانسیل‌یابی به معنای مقایسه پهنه مطالعه شده از لحاظ پتانسیل رخداد پدیده خشکسالی (احتمال وقوع خشکسالی در یک منطقه نسبت به مناطق دیگر) است. مقادیر پیکسل‌های تصویر حاصل از خروجی شبکه عصبی مصنوعی با توجه به لزوم نرمال کردن داده‌ها بین صفر و یک، برای ورود به شبکه دارای یک دامنه بین صفر و یک خواهد بود. در واقع، منطقه با ارزش عدد صفر در تصویر خروجی، نشان‌دهنده عدم احتمال وقوع خشکسالی در آن منطقه نیست، بلکه نشان‌دهنده کمترین احتمال وقوع خشکسالی در آن منطقه نسبت به سایر مناطق در منطقه مورد مطالعه خواهد بود. همان‌طور که عدد یک نشان‌دهنده بیشترین احتمال وقوع خشکسالی در منطقه با ارزش یک نسبت به سایر مناطق خواهد بود. مشاهده می‌شود که پتانسیل ماهانه خشکسالی، بیشتر مناطق استان را در بر می‌گیرد و بیشتر مراکز خشکسالی ماهانه در شهرستان‌های پاوه، گیلان غرب، کرمانشاه و کنگاور و تا حدودی روانسر وجود دارد. می‌توان نتیجه گرفت که پتانسیل خشکسالی ماهانه در سرتاسر مناطق استان وجود دارد. با توجه به نوسان‌های فراوان بارندگی ماهیانه با توجه به زمان سیکلون‌های باران‌زای غربی، خشکسالی ماهیانه



شکل ۸. نقشه پتانسیل منطقه مطالعه شده (SPI ماهانه، سه ماهه و سالانه)

دارد. بر اساس نتایج، پتانسیل خشکسالی ماهانه در بیشتر مناطق استان، پتانسیل خشکسالی سه ماهه، سمت شرق و مرکز استان و پتانسیل خشکسالی سالانه، اکثراً در مناطق شرق استان مشاهده شدند. شهرستان‌های اسلام‌آباد، سنقر و تا حدودی هرسین، دارای خطر کم وقوع خشکسالی بودند و این شهرستان‌ها برای افزایش سطح زیر کشت و کشاورزی دقیق و با ریسک کمتر پیشنهاد می‌شوند. همچنین، توصیه می‌شود در پژوهش‌های آتی، روش‌های جدید یادگیری ماشین به همراه اطلاعات و محصولات حاصل از سایر تصاویر ماهواره‌ای برای پایش خشکسالی به کار گرفته شوند. روش پیشنهادی می‌تواند در سایر مناطق با شرایط اقلیمی متفاوت نیز مورد آزمون قرار گیرد. عبده کلاهچی و همکاران با استفاده از داده‌های TRMM و مشاهدات ایستگاه‌های هواشناسی، خشکسالی ماهانه، سه ماهه و سالانه استان کرمانشاه را مدل‌سازی کردند. مطابق نتایج به دست آمده TRMM برای پایش

### نتیجه‌گیری

در این مطالعه با استفاده از شاخص‌های سنجش از دوری منتخب و شبکه عصبی مصنوعی، پتانسیل خشکسالی استان کرمانشاه مورد بررسی قرار گرفته است. بر اساس نتایج، از بین شاخص‌های بازتابی، شاخص‌های NDVI و VCI بیشترین ضریب همبستگی را با SPI سه ماهه، ماهانه و سالانه نشان دادند. همچنین، از بین شاخص‌های حرارتی، شاخص TCI و از بین شاخص‌های بازتابی-حرارتی شاخص VHI بیشترین ضریب همبستگی را با شاخص SPI داشتند. در روش رگرسیون چندمتغیره، بیشترین ضریب همبستگی مربوط به بازه زمانی سه ماهه با  $R^2 = 0.62$  بود که در مقابل، در روش شبکه عصبی برای همان بازه زمانی، برابر با  $R^2 = 0.91$  به دست آمد. به وضوح می‌توان مشاهده کرد که روش شبکه عصبی پرسپترون چندلایه از روش رگرسیون چندمتغیره برای ایجاد یک شاخص ترکیبی خشکسالی دقیق‌تر، توانایی بسیار بیشتری

- [8]. Mika J, Horvath S, Makra L, Dunkel Z. The Palmer Drought Severity Index (PDSI) as an indicator of soil moisture. *Physics and Chemistry of the Earth, Parts A/B/C*. 2005;30(1-3):223-30.
- [9]. Olukayode Oladipo E. A comparative performance analysis of three meteorological drought indices. *Journal of Climatology*. 1985;5(6):655-64.
- [10]. Juhasz T, Kornfield J. The Crop Moisture Index: unnatural response to changes in temperature. *Journal of applied meteorology*. 1978;17(12):1864-6.
- [11]. Agnew C. Using the SPI to identify drought. 2000.
- [12]. Zargar A, Sadiq R, Naser B, Khan FI. A review of drought indices. *Environmental Reviews*. 2011;19(NA):333-49.
- [13]. Al-Quraishi AMF, Qader SH, Wu W. Drought monitoring using spectral and meteorological based indices combination: a case study in Sulaimaniyah, Kurdistan region of Iraq. *Environmental Remote Sensing and GIS in Iraq: Springer*; 2020. p. 377-93.
- [14]. Huang J, Zhuo W, Li Y, Huang R, Sedano F, Su W, et al. Comparison of three remotely sensed drought indices for assessing the impact of drought on winter wheat yield. *International Journal of Digital Earth*. 2020;13(4):504-26.
- [15]. Park S, Im J, Jang E, Rhee J. Drought assessment and monitoring through blending of multi-sensor indices using machine learning approaches for different climate regions. *Agricultural and forest meteorology*. 2016;216:157-69.
- [16]. Vermote E, Wolfe R. MOD09GA MODIS/terra surface reflectance daily L2G global 1 km and 500 m SIN grid V006. NASA EOSDIS Land Processes DAAC. 2015.
- [17]. Wan Z. University of California Santa Barbara, Simon Hook, Glynn Hulley-JPL and MODAPS SIPS-NASA. MOD11A1 MODIS/Terra Land Surface Temperature and the Emissivity Daily L3 Global 1km SIN Grid NASA LP DAAC. 2015.
- [18]. Mission TRM. TRMM (TMPA) Rainfall Estimate L3 3 hour 0.25 degree x 0.25 degree V7, Greenbelt, MD, Goddard Earth Sciences Data and Information Services Center (GES DISC). TRMM\_3B42\_7.html. 2011.
- [19]. Jiao W, Zhang L, Chang Q, Fu D, Cen Y, Tong Q. Evaluating an enhanced vegetation condition index (VCI) based on VIUPD for drought monitoring in the continental United States. *Remote Sensing*. 2016;8(3):224.
- خشکسالی مناسب است و همچنین، تعداد موارد خشکسالی از ترسالی در استان بیشتر است که این نتایج با آنچه در این پژوهش به دست آمده است، مطابقت دارد [۳۹]. بر اساس نتایج پژوهش سلطانی و همکاران ترکیب اطلاعات دما و پوشش گیاهی در پایش گیاهی در پایش خشکسالی شهرستان کرمانشاه مناسب هستند. پیشنهاد آن‌ها برای پایش خشکسالی شاخص VHI است که نتایج آن‌ها با خروجی‌های این پژوهش مطابقت دارد [۴۰]. شهبازی و همکاران با استفاده از مشاهدات ایستگاه‌های هواشناسی تأثیر تغییرات اقلیم بر خشکسالی استان کرمانشاه را بررسی کردند. بر اساس نتایج آن‌ها بیشترین ریسک خشکسالی در شمال و غرب استان مشاهده می‌شود که این نتایج با نقشه پتانسیل ماهانه به دست آمده در این پژوهش مطابقت دارد [۴۱].

#### منابع

- [1]. AghaKouchak A, Farahmand A, Melton F, Teixeira J, Anderson M, Wardlow BD, et al. Remote sensing of drought: Progress, challenges and opportunities. 2015;53(2):452-80.
- [2]. Lloyd-Hughes B, Saunders MA. A drought climatology for Europe. *International Journal of Climatology: A Journal of the Royal Meteorological Society*. 2002;22(13):1571-92.
- [3]. Bhuiyan C, Singh R, Kogan F. Monitoring drought dynamics in the Aravalli region (India) using different indices based on ground and remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*. 2006;8(4):289-302.
- [4]. javizadeh s, hejazizadeh z. Analysis of Drought Spatial Statistics in Iran %J Journal of Applied researches in Geographical Sciences. 2019;19(53):251-77.
- [5]. Modarres R, Sarhadi A, Burn DHJG, Change P. Changes of extreme drought and flood events in Iran. 2016;144:67-81.
- [6]. Rojas OJW, Extremes C. Agricultural extreme drought assessment at global level using the FAO-Agricultural Stress Index System (ASIS). 2020;27:100184.
- [7]. AghaKouchak A, Farahmand A, Melton F, Teixeira J, Anderson M, Wardlow BD, et al. Remote sensing of drought: Progress, challenges and opportunities. *Reviews of Geophysics*. 2015;53(2):452-80.

- [20]. Hazaymeh K, Hassan QK. Remote sensing of agricultural drought monitoring: A state of art review. *AIMS Environ Sci.* 2016;3:604-30.
- [21]. Jiao W, Wang L, McCabe MF. Multi-sensor remote sensing for drought characterization: current status, opportunities and a roadmap for the future. *Remote Sensing of Environment.* 2021;256:112313.
- [22]. Belal A-A, El-Ramady HR, Mohamed ES, Saleh AM. Drought risk assessment using remote sensing and GIS techniques. *Arabian Journal of Geosciences.* 2014;7(1):35-53.
- [23]. Gaikwad SV, Kale KV, Kulkarni SB, Varpe AB, Pathare GN. Agricultural drought severity assessment using remotely sensed data: a review. *International Journal of Advanced Remote Sensing and GIS.* 2015;4(1):1195-203.
- [24]. Vicente-Serrano SM. Evaluating the impact of drought using remote sensing in a Mediterranean, semi-arid region. *Natural Hazards.* 2007;40(1):173-208.
- [25]. West H, Quinn N, Horswell M. Remote sensing for drought monitoring & impact assessment: Progress, past challenges and future opportunities. *Remote Sensing of Environment.* 2019;232:111291.
- [26]. Bento VA, Trigo IF, Gouveia CM, DaCamara CC. Contribution of land surface temperature (TCI) to vegetation health index: A comparative study using clear sky and all-weather climate data records. *Remote Sensing.* 2018;10(9):1324.
- [27]. Amalo LF, Hidayat R, editors. Comparison between remote-sensing-based drought indices in East Java. *IOP Conference Series: Earth and Environmental Science*; 2017: IOP Publishing.
- [28]. Rostami N, Fathizad HJA. Spatial and temporal changes of land uses and its relationship with surface temperature in western Iran. 2022;35(4):701-17.
- [29]. Masitoh F, Rusydi A, editors. Vegetation Health Index (VHI) analysis during drought season in Brantas Watershed. *IOP Conference Series: Earth and Environmental Science*; 2019: IOP Publishing.
- [30]. Rhee J, Im J, Carbone GJJRSoe. Monitoring agricultural drought for arid and humid regions using multi-sensor remote sensing data. 2010;114(12):2875-87.
- [31]. Gidey E, Dikinya O, Sebege R, Segosebe E, Zenebe AJES, Environment. Using drought indices to model the statistical relationships between meteorological and agricultural drought in Raya and its environs, Northern Ethiopia. 2018;2(2):265-79.
- [32]. Nemani R, Pierce L, Running S, Goward S. Developing satellite-derived estimates of surface moisture status. *Journal of Applied Meteorology and Climatology.* 1993;32(3):548-57.
- [33]. Janalipour M, Mohammadzadeh A. A fuzzy-ga based decision making system for detecting damaged buildings from high-spatial resolution optical images. *Remote Sensing.* 2017;9(4):349.
- [34]. Gatz DF, Smith L. The standard error of a weighted mean concentration—I. Bootstrapping vs other methods. *Atmospheric Environment.* 1995;29(11):1185-93.
- [35]. Tehrani NA, Janalipour M, Babaei HJRSiESS. Estimating Water Surface Chlorophyll-a Concentration by Big Remote Sensing Data in the Persian Gulf, Bushehr. 2021;4(1):87-95.
- [36]. Mousavi SA, Janalipour M, Abbaszadeh Tehrani NJJoRS, GIS. Estimation of crop area cultivation using Sentinel-2 satellite imagery (Case study: Chaypara area above Zanjan city). 2021.
- [37]. Bagheri M, Jelokhani Noaryki M, Bagheri K. Investigation of the land potential of Kermanshah province for rainfed wheat cultivation using artificial neural network %J *Journal of RS and GIS for Natural Resources.* 2018;8(4):36-48.
- [38]. Gomez H, Kavzoglu T, Mather P, editors. Artificial neural network application in landslide hazard zonation in the Venezuelan Andes. 15th International Conference on Geomorphology, Tokyo, Japan; 2001.
- [39]. Kolahchi A, Eftekhar Dadkhah M, Mirzai M. Investigation of the effect of drought on water resources using TRMM satellite imagery in Kermanshah Province %J *Watershed Engineering and Management.* 2021;13(1):65-80.
- [40]. SOLTANI M, soltani A, Kalehhouei M, SOLAIMANI KJGD. Monitoring the regional drought using the LANDSAT images Case Study: The City of Kermanshah. 2019;28(109 #R00459):-.
- [41]. SHAHBAZI K, HESHMATI M, SAI EEDIFAR ZJDM. Investigating the Effect of Climate Change on Drought and Desertification Risk in Kermanshah Province. 2021;8(16 #T001304):-.