

## Investigating the relation between agricultural and meteorology drought using MLP neural network in northwest Iran

Niloofer Vahedi<sup>1</sup> , Alireza Mashaieki<sup>2</sup> , Bagher Ghermez Cheshmeh<sup>3\*</sup> 

<sup>1</sup> Graduated M.Sc. Student in Water Resources Management, Faculty of Engineering, Islamic Azad University of Science & Research, Tehran, Iran

<sup>2</sup> Graduated M.Sc. Student in System Engineer, Faculty of Electrical Engineering, Khajeh Nasir Toosi University of Technology, Tehran, Iran

<sup>3</sup> Assistant Professor, Soil Conservation and Watershed Management Institute, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran

### Abstract

#### Introduction

Drought can be considered as a dry period that lasts long enough to cause an imbalance in the hydrological situation. In the calculation of drought parameters, four characteristics of drought intensity, duration, frequency and extent are studied. In general, drought is divided into 4 main categories. The most basic type of drought is defined as meteorological drought, which is caused by a lack of precipitation, an increase in air temperature, and evaporation. In the long run, this phenomenon will lead to hydrological drought and lack of surface and underground water resources, and as a result, agricultural drought and decrease in soil moisture and loss of vegetation. Agricultural drought begins when the amount of moisture in the root of the plant decreases to such an extent that it causes wilting and ultimately the reduction of agricultural products. The severity, volume of damages, the boosting trend of drought and its negative economic, social and environmental effects can be predicted and controlled. So, damages can be Minimize the consequences. Also, remote sensing technology has made it possible to evaluate variable surface phenomena namely, drought. In recent decades, due to the nonlinear nature of the phenomena, artificial neural networks have shown the best ability in modeling and forecasting time series in hydrology and water resources engineering. On the other hand, artificial neural networks are able to identify the nonlinear relationship between input and output variables from the data structure. Drought monitoring in Iran, done through methods based on weather stations, is not accurate due to the lack of a scattered network and lack of access to timely data. Remote sensing technology, along with geographic information system, by creating appropriate spatial and temporal capabilities, has made it possible to evaluate and monitor variable surface phenomena such as drought, so that in the last two decades, the use of methods based on satellite data for Drought monitoring has become one of the first priorities of research and specialized organizations. Drought prediction in water resources systems plays an important role in reducing drought damages. In the last few decades, mathematical models have been widely used to predict drought. These models take time series into account and model processes linearly. In recent decades, due to the nonlinear nature of the phenomena, artificial neural networks have shown the most ability in modeling and forecasting time series in hydrology and water resources engineering.

#### Materials and Methods

In this research, a standardized precipitation index (SPI) and the normalized difference vegetation index were used to analyze the correlation in the mountainous climate of Iran. Firstly, monthly rainfall data of 88 meteorological stations from 2000 to 2018 were gathered. After performing the necessary statistical tests, the SPI values were calculated in time scales of 1-, 3-, 6-, and 12-month). Then, OLI sensor images of Landsat 8 satellite with a resolution of 30 m were used to extract the NDVI. These images were obtained from USGS on a monthly basis between 2013 and 2018. In total, 72 months were studied in the entire statistical period. After performing radiometric and atmospheric corrections, an average image was prepared every month for NDVI calculation. Then, a multi-layer perceptron (MLP) neural network was used to predict NDVI data for the next month. Last

month's NDVI data and one-month SPI were used as input data to predict the next month's NDVI data during the growing season.

### Results and Discussion

According to NDVI, between 2013 and 2018, May is responsible for the highest amount of vegetation density. In addition, SPI-1 shows the amounts of droughts with more intensity and accuracy than other time steps. Hence, in the mountain region of Iran SPI of the dry season takes a larger amount during the first & last months of the year while during summer, especially in October, drought is much more visible. According to SPI, the return period of droughts is 5-6 years. There is a significant correlation between monthly SPI data and NDVI in the growing season. The highest Pearson correlation coefficient between SPI & NDVI is related to SPI with a 1-month time series and the value of this correlation is much higher in April and May. So, the lack of rain in these months will cause a reduction in growing agricultural products in the spring.

### Conclusion

Artificial neural networks are able to identify the nonlinear relationship between input and output. In this type of simulation, even when the set has disturbance and measurement error, the neural network will be able to provide good results. If there is a change in environmental conditions over time, the neural network will be able to provide new results by adjusting new parameters. NDVI has the highest sensitivity to changes in vegetation and is more useful against atmospheric and soil effects, except in cases where there is little vegetation. In conclusion, for predicting vegetation changes during growing seasons in the pastures of the mountainous climate of Iran, using NDVI data and the monthly SPI data is an efficient process. Therefore, it can be concluded that the neural network is a capable model in relation to agricultural drought prediction.

**Keywords:** Meteorological drought, SPI, NDVI, Northwest , Drought zoning, Neural network

**Article Type:** Research Article

\*Corresponding Author, E-mail: Niloofar\_vahedi@hotmail.com

**Citation:** Vahedi, N., Mashaieki, A., & Ghermezcheshmeh, B. (2023). Investigating the relation between agricultural and meteorological drought using multilayer perceptron (MLP) neural network in northwest Iran. *Water and Soil Management and Modeling*, 3(3), 163-179.

DOI: 10.22098/mmws.2023.11847.1175

DOR: 20.1001.1.27832546.1402.3.3.11.3

Received: 25 November 2022, Received in revised form: 07 January 2023, Accepted: 07 January 2023, Published online: 07 January 2023

*Water and Soil Management and Modeling*, Year 2023, Vol. 3, No. 3, pp. 163-179

Publisher: University of Mohaghegh Ardabili

© Author(s)





## بررسی ارتباط میان خشک‌سالی کشاورزی و هواشناسی در شمال غرب ایران با استفاده از شبکه عصبی پرسپترون چند لایه (MLP)

نیلوفر واحدی<sup>۱\*</sup>، علیرضا مشایخی<sup>۲</sup>، باقر قرمزچشمه<sup>۳</sup>

<sup>۱</sup> دانش‌آموخته کارشناسی ارشد، مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه آزاد اسلامی علوم و تحقیقات، تهران، ایران  
<sup>۲</sup> دانش‌آموخته کارشناسی ارشد، مهندسی سیستم، دانشکده مهندسی برق، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران  
<sup>۳</sup> استادیار، پژوهشکده حفاظت آب و خاک و آب‌خیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

### چکیده

خشک‌سالی پدیده‌ای طبیعی، تکراری و موقتی است که به سبب بارش اندک رخ می‌دهد و تقریباً تمامی مناطق اقلیمی جهان را تحت تأثیر قرار می‌دهد. تعیین وقوع و روند خشک‌سالی می‌تواند در مدیریت برنامه‌ریزی سیستم‌های منابع آب نقش به‌سزایی داشته باشد. در دهه‌های اخیر، شبکه‌های عصبی در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی کارایی مناسبی را نشان دادند. بر همین اساس هدف تحقیق حاضر، تعیین ارتباط میان خشک‌سالی هواشناسی و کشاورزی در شمال غرب ایران و پیش‌بینی روند تغییرات پوشش گیاهی است. ابتدا از داده‌های بارندگی ماهانه ۸۸ ایستگاه هواشناسی وزارت نیرو به مدت ۱۵ سال، ۱۳۹۵-۱۳۸۰، برای تجزیه و تحلیل خشک‌سالی‌های هواشناسی در مقیاس‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه استفاده شد. سپس با استفاده از سنجش از دور و تصاویر ماهواره‌ای لندست ۸، شاخص اختلاف نرمال شده پوشش گیاهی (NDVI) در سال‌های آبی ۱۳۹۰ تا ۱۳۹۵ مورد بررسی و محاسبه قرار گرفت. به منظور پیش‌بینی وضعیت پوشش گیاهی از شاخص NDVI و شاخص خشک‌سالی هواشناسی (SPI) (شاخص بارش استاندارد شده) و الگوریتم شبکه عصبی پرسپترون (MLP) استفاده شد. طبق بررسی‌های انجام شده مشخص شد که SPI در مقیاس زمانی ماهانه در محاسبه شدت ترسالی و خشک‌سالی کارآمد است. هم‌چنین حداکثر میزان تراکم پوشش گیاهی مربوط به فروردین و اوایل اردیبهشت و در فصل بهار بوده و دوره بازگشت این خشک‌سالی‌ها ۵-۶ ساله تعیین شد. در نهایت، ارتباط میان داده‌های NDVI پیش‌بینی شده و داده‌های ورودی (NDVI یک ماه قبل و SPI ماهانه) در گام‌های زمانی متفاوت، یک تابع غیرخطی با ضریب همبستگی ۰/۸۱ خطای ۰/۰۲۶۵ برای داده‌های بارش ماهانه است. بدین معنی که ۸۱ درصد داده‌ها قابل توجه بودند. در نهایت مشخص شد که میان NDVI و SPI همبستگی بالایی وجود دارد و می‌توان نتیجه گرفت که SPI برای پیش‌بینی خشک‌سالی کشاورزی شاخص مناسبی است.

واژه‌های کلیدی: پهنه‌بندی خشک‌سالی، شبکه عصبی پرسپترون، شمال غرب، SPI، NDVI

نوع مقاله: پژوهشی

\*مسئول مکاتبات، پست الکترونیکی: Niloofar\_vahedi@hotmail.com

استناد: واحدی، ن.، مشایخی، ع.، و قرمزچشمه، ب. (۱۴۰۲). بررسی ارتباط میان خشک‌سالی کشاورزی و هواشناسی در شمال غرب ایران با استفاده از شبکه عصبی پرسپترون چندلایه (MLP). مدل‌سازی و مدیریت آب و خاک، ۳(۳)، ۱۶۳-۱۷۹.

DOI: 10.22098/mmws.2023.11847.1175

DOR: 20.1001.1.27832546.1402.3.3.11.3

تاریخ دریافت: ۱۴۰۱/۰۹/۰۴، تاریخ بازنگری: ۱۴۰۱/۱۰/۱۷، تاریخ پذیرش: ۱۴۰۱/۱۰/۱۷، تاریخ انتشار: ۱۴۰۱/۱۰/۱۷



مدل‌سازی و مدیریت آب و خاک، سال ۱۴۰۲، دوره ۳، شماره ۳، صفحه ۱۶۳ تا ۱۷۹

© نویسندگان

ناشر: دانشگاه محقق اردبیلی

## ۱- مقدمه

خشک‌سالی را می‌توان یک دوره خشک دانست که به اندازه‌های دوام پیدا می‌کند که موجب عدم تعادل در وضعیت هیدرولوژیکی شود (He, 2009). در واقع خشک‌سالی از جمله بلایای طبیعی است که نسبت به سایر پدیده‌های طبیعی در یک بازه زمانی طولانی اتفاق می‌افتد که به‌صورت متناوب جوامع بشری را از طریق اثرات منفی بر منابع آب، کشاورزی و به‌دنبال آن اقتصاد دچار مشکل می‌سازد (Jahangir, 2021; Janbozorgi et al., 2021). در محاسبه پارامترهای خشک‌سالی، چهار ویژگی شدت، مدت، فراوانی و گستردگی خشک‌سالی مورد مطالعه قرار می‌گیرد (Magallane et al., 2022).

به‌طور کلی خشک‌سالی به چهار دسته اصلی تقسیم‌بندی می‌شود. ابتدایی‌ترین نوع خشک‌سالی را خشک‌سالی هواشناسی تعریف می‌کنند که به‌دلیل کمبود بارش، افزایش دمای هوا و افزایش میزان تبخیر حاصل می‌شود. این پدیده در طولانی‌مدت منجر به ایجاد خشک‌سالی هیدرولوژیکی و کمبود منابع آب سطحی و زیرزمینی و به تبع آن خشک‌سالی کشاورزی و کاهش رطوبت خاک و از بین رفتن پوشش گیاهی خواهد شد (Mitter et al., 2014). خشک‌سالی در مقایسه با سایر حوادث طبیعی مانند سیلاب، زلزله و طوفان‌های حاره‌ای از نظر درجه، شدت، مدت، مجموع فضای تحت پوشش، خسارت‌های جانی و مالی و اثرات شدید طولانی‌مدت در بالاترین درجه از نظر بزرگی و اهمیت قرار دارد (Mirmohammadhosseini et al., 2021a). خشک‌سالی کشاورزی زمانی آغاز می‌شود که مقدار رطوبت موجود در محیط ریشه گیاه به‌حدی کاهش یابد که موجب پژمردگی و در نهایت کاهش محصولات کشاورزی شود (Ebadi Nehari et al., 2018). از این‌رو بخش کشاورزی اولین بخش از فعالیتهای انسانی است که تحت تاثیر خشک‌سالی قرار می‌گیرد (Loukas et al., 2008).

پایش خشک‌سالی در کشورهایی مانند ایران که از طریق روش‌های مبتنی بر ایستگاه‌های هواشناسی صورت می‌گیرد، به‌دلیل عدم وجود شبکه پراکنده و نیز عدم دسترسی به داده‌های به‌هنگام از دقت مطلوبی برخوردار نیست. فن‌آوری سنجش از دور با همراهی سامانه اطلاعات جغرافیایی با ایجاد قابلیت‌های مناسب مکانی و زمانی، امکان ارزیابی و پایش پدیده‌های متغیر سطحی مانند خشک‌سالی را فراهم آورده است، به‌طوری‌که در دو دهه اخیر استفاده از روش‌های مبتنی بر داده‌های ماهواره‌ای برای پایش خشک‌سالی‌ها از اولویت‌های اول سازمان‌های تحقیقاتی و تخصصی شده است (Lillesand and Kiefer, 1994). هم‌چنین،

رصد ماهواره‌ای محاسبه توزیع فضایی و دستیابی به داده‌های با وضوح بیش‌تر را آسان‌تر می‌کند (Alahacoon and Edirisinghe, 2022).

پیش‌بینی خشک‌سالی در سیستم‌های منابع آب نقش مهمی در کاهش خسارات خشک‌سالی ایفا می‌نماید. در چندین دهه اخیر برای پیش‌بینی خشک‌سالی از برازش و مدل‌های ریاضی به‌طور گسترده استفاده شده است (Dutta, 2013). این مدل‌ها، سری‌های زمانی را به‌صورت مانا در نظر گرفته و فرآیندها را به‌صورت خطی مدل‌سازی می‌کنند. در دهه‌های اخیر با توجه به ماهیت غیرخطی پدیده‌ها، شبکه‌های عصبی مصنوعی بیش‌ترین توانایی را در مدل‌سازی و پیش‌بینی سری‌های زمانی در هیدرولوژی و مهندسی منابع آب نشان داده است (D'Odorico et al., 2013). از مزایای استفاده از شبکه عصبی مصنوعی در پایش خشک‌سالی می‌توان گفت شبکه‌های عصبی مصنوعی قادرند از ساختار داده‌ها، ارتباط غیرخطی بین متغیرهای ورودی و خروجی را شناسایی کنند. در این نوع شبیه‌سازی حتی وقتی مجموعه دارای اغتشاش و خطای اندازه‌گیری است، شبکه عصبی قادر به ارائه نتایج خوبی خواهد بود. اگر تغییری در شرایط محیطی در طی زمان رخ دهد، شبکه عصبی با تنظیم پارامترهای جدید قادر به ارائه نتایج جدید خواهد بود (Jang et al., 2022). در ایران بیش‌تر مطالعات انجام شده برای پایش ارزیابی خشک‌سالی با استفاده از تصاویر AVHRR و شاخص اختلاف نرمال شده پوشش گیاهی (NDVI) صورت گرفته است (Karimi and Shahedi, 2018).

در اغلب مطالعات صورت گرفته برای پایش خشک‌سالی به بررسی شاخص‌های مختلف خشک‌سالی از جمله SPI پرداخته شده و یا فقط از داده‌های سنجش از دور (شاخص‌های گیاهی) استفاده شده است. در حالی‌که مطالعات بسیار محدودی در رابطه با کاربرد هم‌زمان داده‌های سنجش از دور و SPI برای پایش خشک‌سالی صورت گرفته است. هم‌چنین بر اساس نتایج به‌دست‌آمده SPI و NDVI از میزان همبستگی بیش‌تری در بین سایر شاخص‌ها برخوردارند. NDVI بیش‌ترین حساسیت را به تغییرات پوشش گیاهی داشته و در مقابل اثرات جوی و در زمینه خاک، به‌جز در مواردی که پوشش گیاهی کم باشد، کاربردی‌تر است. با توجه به این‌که تصاویر AVHRR دارای توان تفکیک مکانی یک کیلومتر هستند و برآورد ضعیفی از میزان پوشش گیاهی دارند، لذا استفاده از سایر تصاویر ماهواره‌ای مانند لندست که دارای توان تفکیک ۳۰ متر است و می‌تواند برآورد دقیق‌تری از پوشش گیاهی ارائه کند، ضروری به نظر می‌رسد.

کم‌تر مورد توجه قرار گرفته است و همچنین بررسی میزان تطابق کلاس‌های خشک‌سالی میان SPI با NDVI نام برد.

## ۲- مواد و روش‌ها

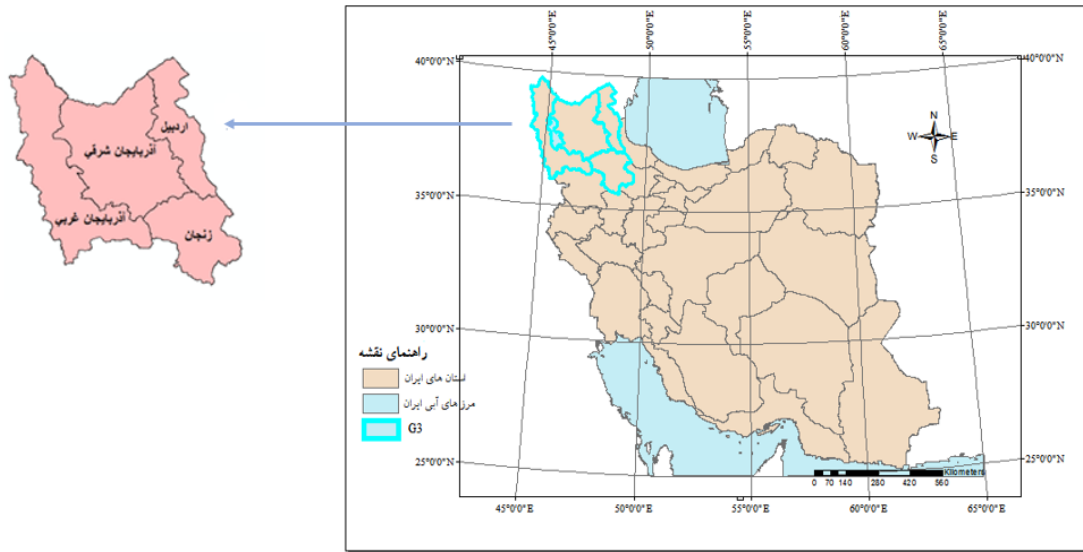
### ۲-۱- منطقه مورد مطالعه

ایران کشوری در غرب آسیا با مساحتی در حدود  $۱۰۶ \times ۱۶۵$  کیلومتر مربع است. ایران در میان طول جغرافیایی ۴۴ و ۶۳ شرقی و عرض جغرافیایی ۲۵ و ۴۰ شمالی واقع شده است و دارای طیف گسترده‌ای از توپوگرافی و تنوع آب و هوایی است. ارتفاع از بیش از ۵۵۰۰ متر در کوهستانی در غرب تا زیر سطح متوسط دریا (۲۴- متر) در امتداد ساحل شمالی متغیر است. بارندگی زیاد و دما در ارتفاعات بالاتر در امتداد رشته کوه‌ها کم است. بارش به تدریج از منطقه پربارش شمال غرب به منطقه کم‌بارش جنوب شرقی کاهش می‌یابد، در حالی که دما از شمال غرب به جنوب شرق به تدریج افزایش می‌یابد. ایران از نظر تنوع بارش به هشت اقلیم تقسیم‌بندی می‌شود و الگوی بارندگی در ایران با طول و عرض جغرافیایی تغییر می‌کند (Sharafati et al., 2020). منطقه مورد مطالعه در این پژوهش (شکل ۱)، شمال غرب ایران بوده که شامل استان‌های آذربایجان غربی، آذربایجان شرقی، اردبیل و زنجان است (Sharafati et al., 2020). شمال غرب ایران شامل کوهستان‌های غربی است که دامنه‌های غربی رشته‌کوه‌های مرکزی را شامل می‌شود. به‌طور کلی میانگین دمای هوا در گرم‌ترین ماه سال در آن‌ها بیش از ۱۰ و میانگین حداقل دمای هوا کم‌تر از ۳- درجه سانتی‌گراد است. گرمای شدید دره‌ها در تابستان زیاد و در زمستان بسیار کم است. زمستان‌ها طولانی، سرد و سخت بوده و چندین ماه از سال زمین پوشیده از یخ است. میزان بارندگی در تابستان کم و در زمستان زیاد است. فصل بهار کوتاه بوده و زمستان و تابستان را از هم جدا می‌کند. شهرهای تبریز و ارومیه را می‌توان در این اقلیم قرار داد. در سراسر این منطقه زمستان‌ها به‌شدت سرد است و سرما از اوایل آذر شروع می‌شود و تا آخر فروردین کم و بیش ادامه می‌یابد (Modarres & Sarhadi, 2009).

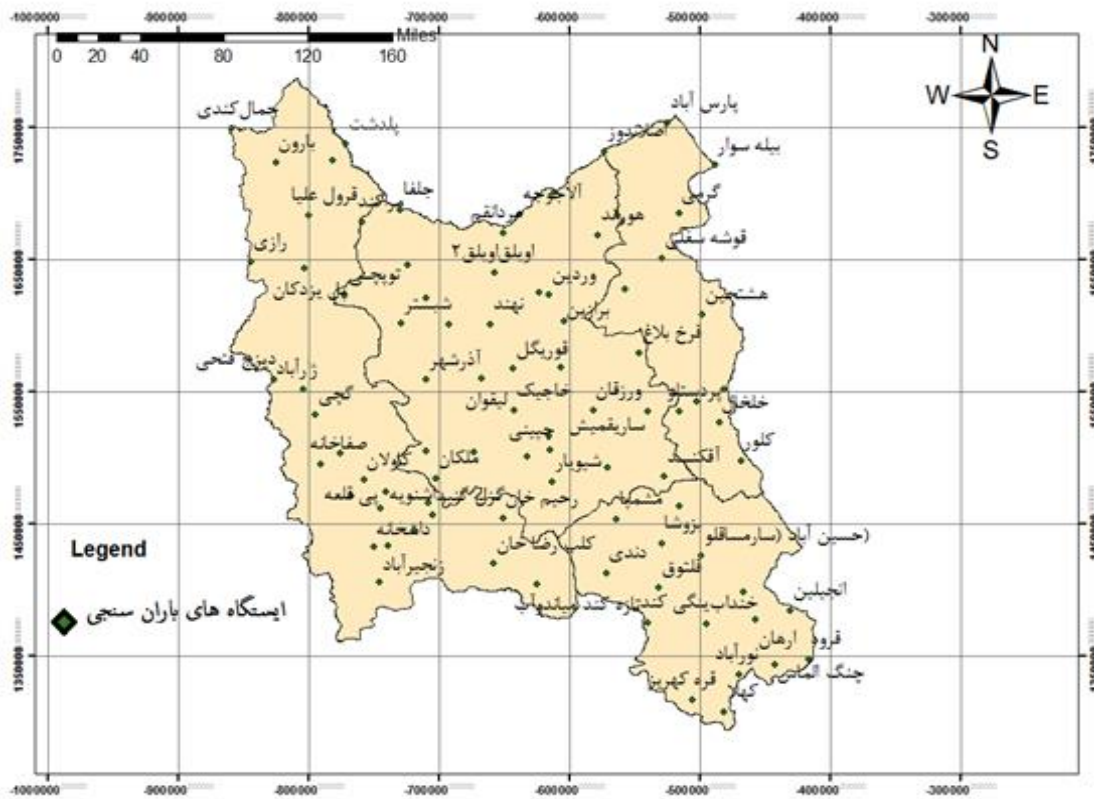
در این پژوهش برای بررسی قابلیت شاخص تفصل پوشش گیاهی نرمال شده NDVI، از شاخص اقلیمی دیگری به نام شاخص بارش استاندارد شده (SPI) استفاده شده است. بدین منظور ابتدا از داده‌های بارش ماهانه در ۸۸ ایستگاه (شکل ۲) هواشناسی وزارت نیرو در بازه ۱۳۹۵-۱۳۸۰ استفاده شد. پس از اطمینان از صحت داده‌های آماری ماهانه و انجام آزمون‌های آماری لازم، مقادیر SPI طی ۱۵ سال و در مقیاس‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه مورد محاسبه قرار گرفت.

Zare Abianeh et al. (2004) خشک‌سالی هواشناسی منطقه همدان را به‌صورت سالانه و فصلی با توجه به آمار بارندگی ۵۲ ساله ایستگاه اکباتان و نوزه در بازه زمانی ۱۳۸۰-۱۳۲۸ مورد بررسی قرار دادند. Baaghdeh et al. (2011) برای شناسایی شاخص جایگزین به‌جای شاخص‌های اقلیمی ارزیابی و پایش خشک‌سالی‌ها، از آمار بارش ماهانه دوره رشد ایستگاه‌های هواشناسی و تصاویر ماهواره‌ای NOAA استفاده کردند. در بین دوره‌های زمانی مختلف SPI، دوره زمانی سه‌ماهه، همبستگی بالایی نشان داد و مابقی محاسبات توسط این دوره زمانی محاسبه شد. در پژوهشی دیگر، (Dutta et al., 2013) با استفاده از محاسبه دو شاخص SPEI و NDVI به پیش‌بینی خشک‌سالی کشاورزی در طی سال‌های آتی پرداختند. نتایج نشان داد که همبستگی بالایی میان NDVI دو هفته قبل و پیش‌بینی NDVI ماه جاری وجود دارد. در پژوهشی دیگر، (Jahangir et al., 2020) به پایش خشک‌سالی برای ۱۱ ایستگاه هواشناسی و ۱۱ ایستگاه هیدرومتری و با استفاده از SPI و جریان دبی استاندارد (SSI) پرداختند. نتایج نشان داد که این دو شاخص با یکدیگر رابطه مستقیم دارند. همچنین مشخص شد که SPI برای پیش‌بینی شروع خشک‌سالی و SSI برای سنجش شدت و تداوم خشک‌سالی بهتر هستند. Karimi and Shahedi (2018) به بررسی رابطه خشک‌سالی هواشناسی، هیدرولوژیکی و کشاورزی با استفاده از شاخص‌های خشک‌سالی و سنجش از دور در حوزه آبخیز قره‌سو پرداختند. برای این منظور، از تصاویر سنجنده مادیس، داده‌های بارندگی پنج ایستگاه باران‌سنجی و داده‌های دبی پنج ایستگاه هیدرومتری از سال ۲۰۰۵-۲۰۰۰ استفاده نمودند. Younesi et al. (2018) از شبکه‌های عصبی مصنوعی پرسپترون چندلایه MLP، تابع پایه‌ای شعاع WA-RBF، سری زمانی ARIMA، شبکه‌های عصبی مصنوعی موجک پرسپترون چندلایه برای پیش‌بینی سری‌های زمانی SPI استفاده نمودند. در این بین شبکه عصبی MLP نسبت به سایر روش‌ها نتایج بهتری نشان داد.

هدف از این پژوهش تعیین تاثیرپذیری خشک‌سالی کشاورزی از خشک‌سالی هواشناسی در شمال غرب ایران و پیش‌بینی خشک‌سالی کشاورزی با استفاده از NDVI و SPI است. همچنین، شبکه عصبی مصنوعی پرسپترون چندلایه MLP، برای پیش‌بینی وضعیت خشک‌سالی کشاورزی از دقت بالاتری در میان سایر مدل‌ها برخوردار است. بر این اساس جنبه نوآوری در این پژوهش را می‌توان ارزیابی متغیر هواشناسی نظیر بارش بر وقوع خشک‌سالی، استفاده از شاخص NDVI به‌عنوان یک شاخص مناسب پوشش گیاهی که در پژوهش‌های قبلی



شکل ۱- موقعیت منطقه مورد مطالعه در ایران  
Figure 1- Location of the study area in Iran



شکل ۲- موقعیت ایستگاه های باران سنجی مورد مطالعه  
Figure 2- The location of the studied rain gauge stations

به صورت ماهانه تهیه شدند. این دوره در برگیرنده سال های خشک و مرطوب است. در مجموع در کل دوره آماری، ۷۲ ماه مورد بررسی قرار گرفت. این تعداد آمار برای تهیه مدل های رگرسیونی کافی است. در این مرحله به منظور جبران کمبودها و حذف پارازیت های موجود و داشتن تصویری با کیفیت مطلوب

سپس برای استخراج شاخص پوشش گیاهی NDVI تصاویر سنجنده OLI ماهواره Landsat 8 با قدرت تفکیک ۳۰ متر استفاده شد. این تصاویر از سازمان زمین شناسی ایالات متحده آمریکا (USGS)<sup>۱</sup> و ناسا در بازه زمانی ۱۳۹۶ تا ۱۳۹۰

<sup>1</sup> United States Geological Survey

جدول ۱- طبقه‌بندی NDVI بر اساس تراکم پوشش زمین  
Table 1- Classification of NDVI based on land cover density (Nateghi, 2017)

طبقه‌بندی بر اساس NDVI	دامنه تغییرات NDVI
پوشش گیاهی متراکم	$0.5 < NDVI \leq 1$
پوشش گیاهی پراکنده	$0.2 < NDVI \leq 0.5$
زمین بایر	$0 < NDVI \leq 0.2$
پهنه آبی	$MIN < NDVI \leq 0$

تصاویر ماهواره‌ای به‌طور منظم و با دقت تفکیک مکانی بالا، از سطح زمین تهیه می‌شوند و می‌توانند شرایط دستیابی منظم و گسترده‌ای برای دستیابی به داده‌ها فراهم کنند. سنجش از دور به جهت ارائه اطلاعات بروز، پوشش‌های تکراری، سنجش در محدوده طیفی بیش‌تر از طیف مرئی، ارزان بودن، تنوع اشکال داده، سنجش کمی و رقومی پدیده‌های سطح زمین، در ارزیابی منابع طبیعی از اهمیت بالایی برخوردار بوده و بهترین وسیله در تهیه نقشه‌های کاربری اراضی محسوب می‌شود (Ke, 2015).

#### ۲-۲-۲- شاخص هواشناسی SPI

شاخص بارش استاندارد (SPI) نخستین بار برای تعیین دوره خشک‌سالی و ارزیابی شدت آن تبیین شد. محاسبه این شاخص مستلزم برازش توزیع احتمالاتی مناسب به سری طولانی مدت داده‌های بارندگی در هر بازه زمانی دلخواه (۱، ۳، ۶ و ۱۲ ماهه) در هر ایستگاه است (Mckee et al., 1993). این شاخص برای هر دوره زمانی قابل استخراج است. برای محاسبه این شاخص، از برازش تابع چگالی احتمال گاما بر توزیع فراوانی بارندگی استفاده می‌شود. این شاخص نشان‌دهنده تعداد دوره‌های خشک نسبت به دوره‌های نرمال است (Vicente-Serrano et al., 2010). اگر این ارزش از عدد صفر به پایین باشد، نشان‌دهنده خشک‌سالی است (Hao et al., 2018). در جدول ۲، طبقه‌بندی شدت خشک‌سالی بر اساس این شاخص بیان شده است.

جدول ۲- طبقه‌بندی نمایه خشک‌سالی بر اساس SPI  
Table 2- Drought classification based on SPI (Li, 2019)

دامنه تغییرات SPI	طبقه‌بندی SPI
$2 < SPI \leq MAX$	ترسالی خیلی شدید
$1.5 < SPI \leq 2$	ترسالی شدید
$1 < SPI \leq 1.5$	ترسالی متوسط
$1 < SPI \leq -1$	بارش نرمال
$1.5 < SPI \leq -1$	خشک‌سالی متوسط
$2 < SPI \leq -1.5$	خشک‌سالی شدید
$MIN < SPI \leq -2$	خشک‌سالی خیلی شدید

جهت استفاده، اقدام به عملیات پردازش و پیش‌پردازش تصاویر ماهواره‌ای شد. عوامل ایجادکننده این خطا، سنجنده، زمین و اتمسفر هستند. هم‌چنین امواج مرئی و مادون قرمز قابلیت عبور از ابرهای موجود در اتمسفر را ندارند. بر همین اساس با استفاده از ترکیب تصاویر سری زمانی، ابرهای موجود در تصاویر حذف شد (Mokhtari and Akhoondzadeh, 2019). در نتیجه پس از انجام تصحیحات رادیومتریک و اتمسفری به‌طور متوسط در هر ماه یک تصویر برای محاسبه NDVI تهیه شد. در نهایت همبستگی بین SPI و NDVI در نواحی مختلف شمال غرب ایران سنجیده شد. بدین‌منظور از شبکه عصبی MLP و الگوریتم لوبنرگ-مارکوارت استفاده شد.

#### ۲-۲-۲- داده‌های مورد استفاده و آماده‌سازی داده‌ها

##### ۲-۲-۲-۱- شاخص گیاهی NDVI

این شاخص از معروف‌ترین، ساده‌ترین و کاربردی‌ترین شاخص‌هایی است که در زمینه مطالعات پوشش گیاهی شناخته شده است (Gandhi, 2015). در شرایط سلامت کامل، کلروفیل گیاهی، نور مرئی بیش‌تری را جذب می‌کند و  $P_{red}$  میزان بازتاب کم‌تری دارد و میزان انعکاس در  $P_{nir}$  نیز بیش‌تر است. با اندازه‌گیری NDVI می‌توان تغییرات در محتوای آب و کلروفیل (از طریق جذب رادیواکتیوی قرمزمرئی) و مزوفیل اسفنجی (از طریق خصوصیات انعکاسی مادون قرمز نزدیک) در داخل پوشش گیاهی به‌دست آورد (Dutta et al., 2013).

$$NDVI = \frac{P_{nir} - P_{red}}{P_{nir} + P_{red}} \quad (1)$$

شاخص NDVI با استفاده از رابطه ۱ محاسبه شده است. در رابطه ۱،  $P_{nir}$  باند انعکاسی مادون قرمز نزدیک و  $P_{red}$  باند مرئی قرمز است. در این پژوهش برای محاسبه NDVI از باندهای ۴ و ۵ تفکیک شده استفاده شد.

نیاز آبی با مراحل مختلف رشد گیاه متفاوت است و اواسط فصل رشد حساس‌ترین دوره به رطوبت برای بیش‌تر گیاهان است (Jalili et al., 2014). با مطالعه گذشته NDVI توانایی تشخیص تنش گیاهی مرتبط با خشک‌سالی خصوصاً در مراتع میسر می‌شود (Tian et al., 2018). تفاوت در نمایه NDVI خشک‌سالی و غیرخشک‌سالی نشان‌دهنده تفاوت در میزان بارندگی رخ داده در سال‌های مربوطه است. نوسانات در NDVI منعکس‌کننده شرایط رشد است و می‌توان از آن برای پیش‌بینی کاهش عملکرد استفاده کرد (Gandhi et al., 2015). جدول ۱، طبقه‌بندی NDVI بر اساس تراکم پوشش زمین را نشان می‌دهد (Nateghi et al., 2017).

### ۳-۱- بررسی و تحلیل نمودارهای SPI در گام‌های زمانی متفاوت در یک ایستگاه

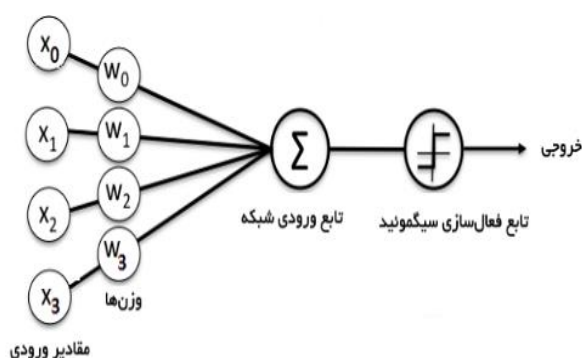
با بررسی بارندگی و میزان نوسانات آن در ۱۵ سال اخیر ۱۳۹۵-۱۳۸۰ در ۸۸ ایستگاه باران‌سنج منطقه با استفاده از SPI ظال‌های خشک و مرطوب به لحاظ بارندگی مشخص شد. با توجه به اطلاعات به‌دست آمده از SPI، بیش‌تر خشک‌سالی‌های شدید در سری زمانی پنج‌ساله مورد مطالعه، در سال‌های آبی ۱۳۸۰-۸۱، ۱۳۸۶-۸۷ و ۱۳۹۲-۹۳ به وقوع پیوسته است. همچنین شدیدترین میزان ترسالی‌ها در سال‌های آبی ۸۴-۸۳، ۹۰-۸۹ و ۱۳۸۹-۹۰ و ۱۳۹۴-۹۵ است. با توجه به نقشه پهنه‌بندی خشک‌سالی هواشناسی با استفاده از SPI-12 (شکل ۴)، مناطق تحت تاثیر خشک‌سالی و ترسالی مشخص شده‌اند.

۳-۲- ارزیابی شدت خشک‌سالی پوشش گیاهی در بهار و تابستان با توجه به شکل ۵، هر چه به اواخر فصل تابستان نزدیک‌تر می‌شود، از میزان رطوبت منطقه کاسته شده و به میزان خشکی آن افزوده می‌شود. با توجه به نقشه‌های پهنه‌بندی NDVI (شکل ۶)، به‌طور متوسط در هر سال، حداکثر فراوانی پوشش گیاهی متعلق به فروردین است و سپس در ماه‌های بعد به‌تدریج از میزان پوشش گیاهی متراکم و پراکنده کاسته شده تا در نهایت در مرداد این میزان به کم‌ترین میزان خود می‌رسد. همچنین، بیش‌ترین میزان خشک‌سالی پوشش گیاهی در مرداد ۱۳۹۳ رخ داده و نزدیک به ۶۸ درصد کل مساحت منطقه را زمین‌های بایر در بر گرفته است و کم‌تر از یک سوم مساحت آن پوشش گیاهی با تراکم مناسب وجود دارد.

۳-۳- مقایسه NDVI در سال‌های خشک، نرمال و مرطوب با توجه به شکل ۷، NDVI ماهانه در یکی از ایستگاه‌های مورد مطالعه (ایستگاه خلخال) مشخص شده است. NDVI ماهانه در ایستگاه خلخال در سال‌های خشک، نرمال و مرطوب در سری زمانی ۱۳۹۱ تا ۱۳۹۶ به‌طور قابل توجهی متفاوت بوده است. از آن جایی که شروع بارندگی در بخش شمال غربی ایران، از دی تا اواخر اردیبهشت متغیر است، مقادیر NDVI بر این اساس افزایش می‌یابد. به‌طور کلی بیش‌تر محصولات به‌طور مستقیم به بارندگی‌های فراگیر مدیترانه‌ای وابسته هستند. بنابراین، نسبت به نوسانات میزان بارندگی بسیار حساس هستند. با توجه به شکل ۷، بیش‌ترین میزان خشک‌سالی در ایستگاه خلخال مربوط به مهر ۱۳۹۲ است. بیش‌ترین میزان ترسالی و پوشش گیاهی مربوط به اسفند ۱۳۹۳ است.

### ۳-۲-۲- شبکه عصبی MLP

شبکه‌های عصبی مدل‌های محاسباتی هستند که قادرند رابطه میان ورودی‌ها و خروجی‌های یک سیستم فیزیکی را توسط شبکه‌ای از گره‌ها که همگی به هم متصل هستند تعیین نمایند (Ghasemi et al., 2021). یکی از پایه‌ای‌ترین مدل‌های عصبی موجود، مدل پرسپترون چندلایه MLP<sup>۳</sup> است که عملکرد انتقالی مغز انسان را شبیه‌سازی می‌کند و از شبکه‌های عصبی مصنوعی پیشخور<sup>۴</sup> محسوب می‌شوند. این شبکه دارای اجزای تحلیل‌گر غیرخطی<sup>۵</sup> (تابع سیگموئید<sup>۶</sup> و تانژانت هایپربولیک<sup>۷</sup>) است. آموزش در شبکه پرسپترون چندلایه، به کمک الگوریتم پس انتشار خطا<sup>۸</sup> انجام می‌شود. الگوریتم پس انتشار خطا در دو مسیر forward و backward در شبکه حرکت می‌کند و می‌تواند مقدار گرادیان خطا را نسبت به هر پارامتر شبکه، وزن و محاسبه کند. در شکل ۳، یک نورون چند ورودی نشان داده شده است. در این پژوهش به‌منظور درک وضعیت پوشش گیاهی، رابطه SPI و NDVI با استفاده از مدل‌سازی شبکه عصبی MLP و نرم‌افزار متلب بررسی می‌شود. تعداد لایه‌های مخفی ۱، ۲ و ۳ لایه برای آموزش شبکه در نظر گرفته شد تا مناسب‌ترین تابع به داده‌ها برازش داده شود. در این پژوهش در مجموع ۱۳۴ داده به‌عنوان داده‌های نمونه، ۲۹ داده برای اعتبارسنجی و ۲۹ داده برای آزمون استفاده شد.

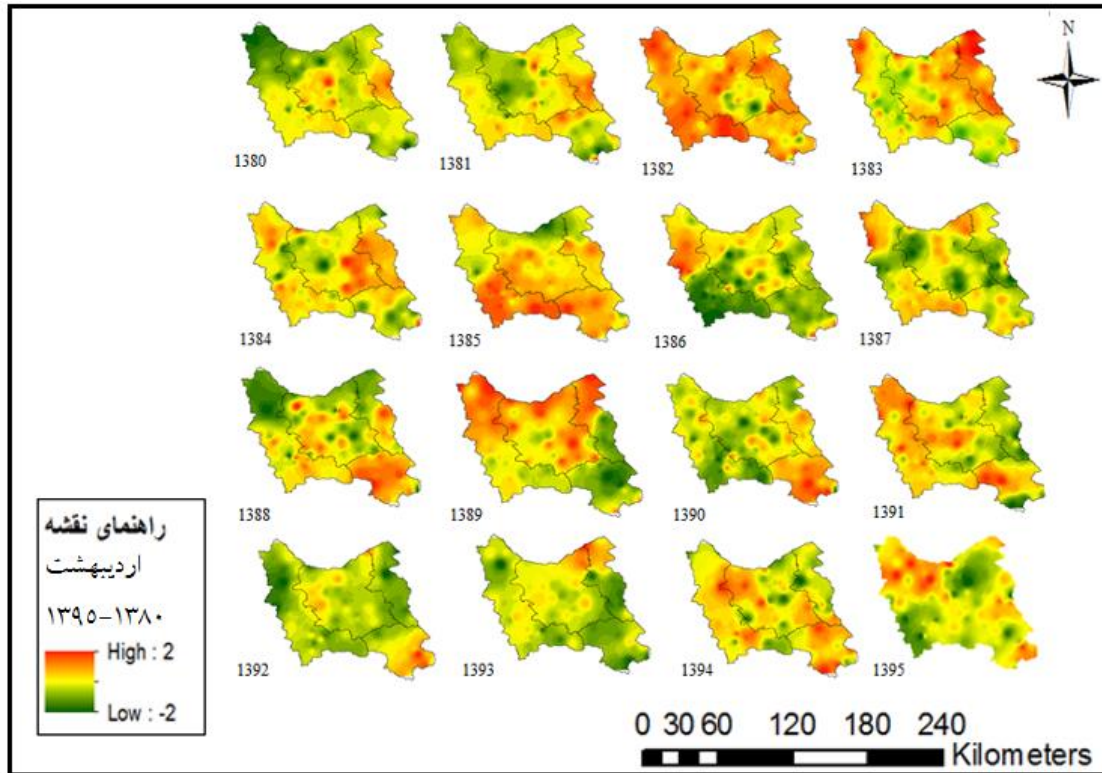


شکل ۳- مدل یک نورون چند ورودی  
Figure 3- Model of a multi-input neuron


### ۳- نتایج و بحث

- 1 Neural network
- 2 Neurons
- 3 Multi-Layer Perceptron
- 4 Feedforward
- 5 Processing Elements
- 6 Sigmoid Function
- 7 Hyperbolic Function
- 8 Back propagation
- 9 Bias
- 1 Matlab

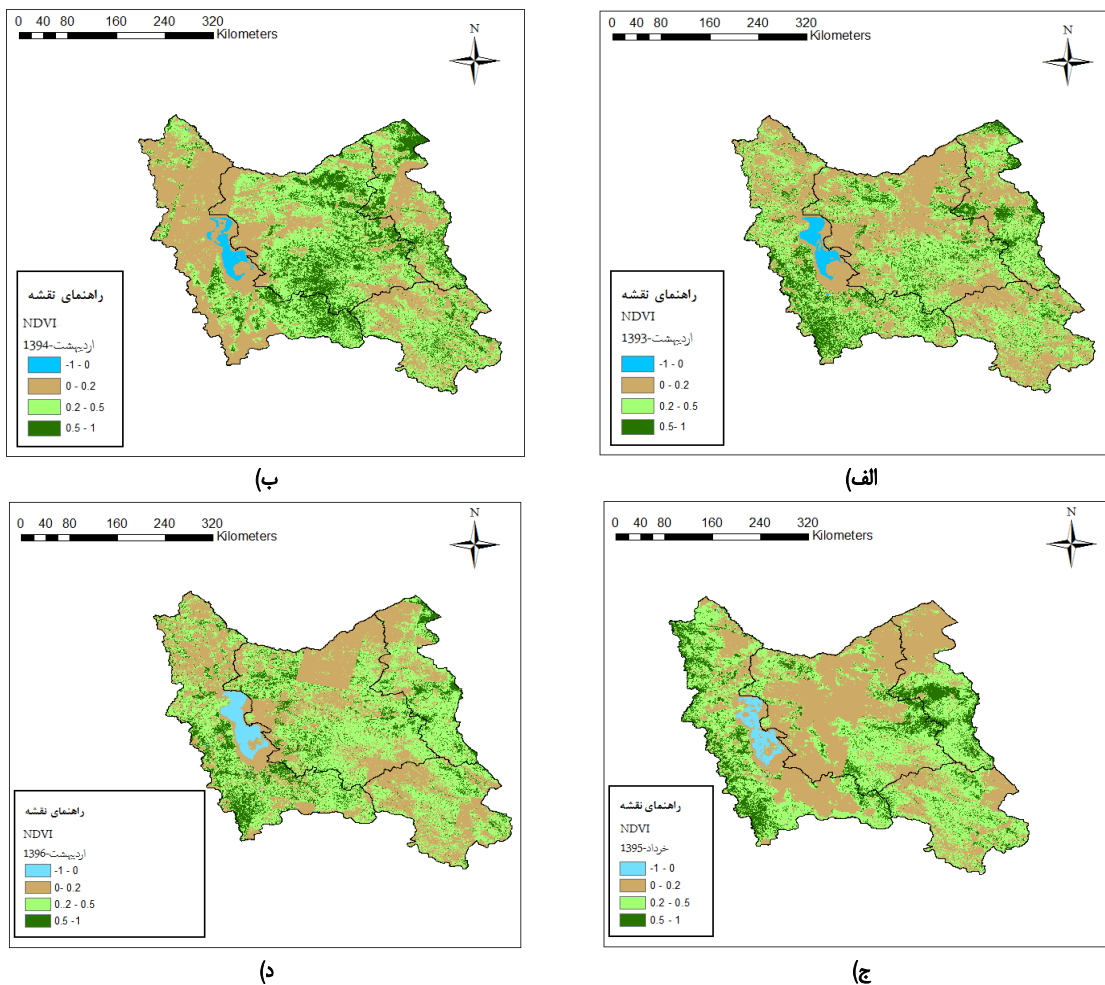





شکل ۴- پهنه‌بندی خشکسالی با استفاده از SPI-12 در اردیبهشت ۱۳۸۰-۱۳۹۵  
Figure 4- Drought zoning using twelve-month SPI in May 2001-2016



شکل ۵- روند تغییرات پوشش گیاهی ۱۳۹۲-۱۳۹۷  
Figure 5- Vegetation change process 2013-2018



شکل ۶- نقشه پهنه‌بندی خشک‌سالی در میانگین متحرک یک‌ماهه SPI طی سال‌های ۱۳۹۳-۱۳۹۶  
 Figure 6- Drought zoning map in 1-month moving average of SPI during 2015-2016



شکل ۷- تغییرات NDVI در طول سال‌های خشک، نرمال و مرطوب در ایستگاه خلخال  
 Figure 7- NDVI changes during dry, normal and wet years at Khalkhal station

SPI که همواره از آن به‌عنوان شاخص خشک‌سالی هواشناسی یاد می‌شود بر اساس میزان بارندگی دریافتی است. بارش عامل اصلی

۴-۳- بررسی روابط میان شاخص خشک‌سالی هواشناسی و شاخص پوشش گیاهی

و در فروردین و اردیبهشت ماه قابل توجه است. بنابراین می‌توان نتیجه گرفت به‌منظور پیش‌بینی تغییرات پوشش گیاهی در طی فصول رشد در مراتع شمال غرب ایران، می‌توان از داده‌های NDVI یک ماه قبل و داده‌های SPI ماهانه بهره برد که با نتایج (2021) Ghermezecheshme et al. هم‌خوانی دارد. بنابراین، می‌توان نتیجه گرفت که شبکه عصبی در رابطه با پیش‌بینی خشک‌سالی کشاورزی مدل کارآمدی است.

(2013) Dutta et al. در مطالعه خود نشان دادند که تاخیر پاسخ NDVI به بارندگی ۴-۸ هفته است. از ۳ تا ۶ ماه، همبستگی‌ها بهبود نیافتند، زیرا SPI مقیاس طولانی‌تر تمایل به کاهش واریانس در داده‌های بارش دارند و مقادیر SPI را هموار می‌کنند (Dutta, 2013). هم‌چنین نتایج همبستگی پیرسون بین NDVI و SPI نشان می‌دهد که NDVI به‌طور قابل توجهی با SPI همه مقیاس‌های زمانی همبستگی ندارد. جدول ۳، مقادیر همبستگی میان NDVI و SPI برای سال‌های ۱۳۹۶-۱۳۹۰ نشان می‌دهد.

جدول ۳- مقادیر همبستگی میان NDVI و SPI برای سال‌های ۱۳۹۶-۱۳۹۰  
Table 3- Correlation values between NDVI and SPI during 2011-2017

SPI-12	SPI-6	SPI-3	SPI-1	NDVI
0.76	0.80	0.82	0.86	اسفند
-	-	-	0.40	فروردین
-	-	-	0.51	اردیبهشت

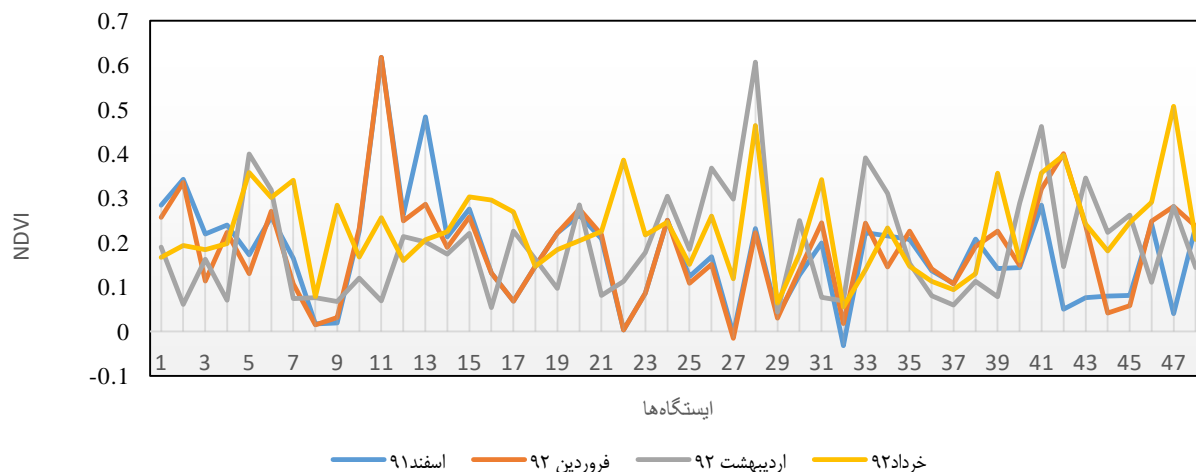
### ۳-۵- ضریب همبستگی میان داده‌های NDVI جاری و داده‌های NDVI یک‌ماه گذشته

هر نوع پوشش گیاهی یک دورهٔ رویشی معمولی دارد و بنابراین NDVI ماه گذشته می‌تواند پیش‌بینی‌کنندهٔ وضعیت آن نوع پوشش گیاهی در ماه‌های آینده باشد (Dutta, 2013). در نتیجه NDVI ماه‌های گذشته نقش مهمی در NDVI ماه جاری دارد. در این پژوهش به بررسی تغییرات NDVI در طول فصل رشد در سال‌های مختلف و محاسبه همبستگی میان داده‌های NDVI هر ماه با NDVI ماه‌های آینده با تاخیر زمانی ۱، ۲ و ۳ ماهه پرداخته شد. با توجه به شکل ۸، در طول فصل رشد مقادیر NDVI با تاخیر زمانی یک‌ماهه بیش‌ترین همبستگی را داشتند. با توجه به جدول ۴، بیش‌ترین ضریب همبستگی مربوط به داده‌های اسفند و فروردین است. تغییرات ضرایب همبستگی با تاخیرهای مختلف ۱، ۲ و ۳ ماهه بیش‌تر می‌شود. هم‌چنین بیش‌ترین همبستگی NDVI در اردیبهشت برای تمام تاخیرهای آزمایش شده NDVI مشاهده شد. هم‌چنین روند ضریب همبستگی ۱، ۲ و ۳ ماهه NDVI افزایش یافته است.

رشد پوشش گیاهی بوده که توسط NDVI منطقه نشان داده شده است. بنابراین می‌توان ثابت کرد که میان SPI و NDVI با یکدیگر همبستگی وجود دارد. قدرت پوشش گیاهی در این منطقه که شامل مراتع است تا حد زیادی تحت تأثیر نوسانات بارندگی است. قدرت پوشش گیاهی این قسمت از منطقه مورد مطالعه نسبت به میزان بارندگی بسیار حساس است. بنابراین، NDVI هر ماه در فصل رشد به‌طور قابل توجهی با SPI ماه گذشته در این مناطق همبستگی دارد. مدل‌های رگرسیون چندگانه برای پیش‌بینی ماهانه NDVI بر اساس ضرایب همبستگی در مناطق مختلف کشاورزی-اقليمی ساخته شده‌اند. در این مطالعه SPI نقش موثرتری در توضیح داده‌های پیش‌بینی شده نسبت به NDVI (ضرایب استاندارد b بالاتر) داشت، اما گنجاندن NDVI می‌تواند سایر عوامل مرتبط با مدیریت و توسعه محصول را خلاصه کند.

قدرت پوشش گیاهی در هر ماه بستگی به میزان بارندگی دریافتی در یک یا دو ماه قبل دارد. بدین ترتیب ضریب همبستگی برای SPI-3 از بین رفته و ضریب همبستگی برای SPI-6 با پایان فصل رشد افزایش یافته است. ضریب همبستگی SPI-1 برای پیش‌بینی مدل‌ها کارآمدتر بود. از آنجایی که ضرایب SPI-3 و SPI-6 معنادار نیستند، رد شدند و SPI-1 برای مدل پیش‌بینی پذیرفته شد. نتایج رگرسیون حاصل از ارتباط میان شاخص NDVI در ماه‌های رشد (فروردین، اردیبهشت و خرداد) با SPI نشان داد که در بین سال‌های ۱۳۹۱ تا ۱۳۹۶ بیش‌ترین ضریب همبستگی برای SPI-۱ و مربوط به ماه‌های فروردین و اردیبهشت برابر با ۰/۸۶ است. این نتایج در واقع بیان می‌کنند که چنانچه در ماه‌های اسفند، فروردین و اردیبهشت بارندگی بیش‌تری رخ دهد، در فصل بهار رشد خوب داریم مورد انتظار است. این امر به این دلیل اتفاق می‌افتد که بارندگی اثر آبی بر قدرت پوشش گیاهی ندارد. در بیش‌تر موارد، بارش در یک ماه به‌شدت بر پوشش گیاهی آن ماه تأثیر می‌گذارد، اما پاسخ در دوره‌های طولانی‌تر از یک ماه قابل توجه نیست (Zambrano et al., 2018).

نتایج (2021b) Mirmohammadhosseini et al. نیز در اراضی دیم استان لرستان با SPI خرداد تا فروردین ارتباط معنادار نشان داد. بدین معنا که اگر در اسفند و فروردین میزان بارندگی مناسب باشد، رشد دیم در فصل بهار قابل ملاحظه خواهد بود. هم‌چنین عدم بارندگی در این ماه‌های سال باعث کاهش و یا عدم رشد محصولات کشاورزی در فصل بهار خواهد شد. بنابراین میان داده‌های SPI ماهانه در فصل رشد و NDVI همبستگی مناسبی وجود دارد. همبستگی میان داده‌های NDVI با تاخیر زمانی یک‌ماهه



شکل ۸- همبستگی میان داده‌های NDVI طی سال‌های ۹۲-۱۳۹۱  
Figure 8- Correlation between NDVI data during the years 2013-2014

جدول ۴- ضریب همبستگی میان داده‌های NDVI در طی فصل رشد  
Table 4- Correlation coefficient between NDVI data during the growing season


خرداد	اردیبهشت	فروردین	ضریب همبستگی
0.62	0.68	0.73	اسفند
0.44	0.81	-	فروردین
0.34	-	-	اردیبهشت

با توجه به شکل ۱۰، می‌توان نتیجه گرفت که میان داده‌های ورودی (NDVI یک‌ماه قبل و SPI ماهانه) و NDVI پیش‌بینی شده همبستگی ۰/۸۱ برقرار است. این عدد نشان می‌دهد که حدود ۸۱ درصد پراکندگی‌ها با هم قابل توجیه است. شکل ۱۱، نمودار هیستوگرام خطا را در مدل پیش‌بینی نشان می‌دهد. با بررسی نمودار می‌توان نتیجه گرفت که پیش‌بینی به خوبی و با دقت مناسبی امکان‌پذیر است. به علاوه شکل مرتبط نشان‌دهنده مناسب این برازش است. بنابراین، با توجه به این که خطا در صفر کم‌تر از سه درصد است، خطای شبکه کم و شبکه مناسب و قابل قبول است. در شکل ۱۲، مقادیر واقعی و پیش‌بینی شده NDVI نشان داده شده است. با بررسی و مقایسه این دو نمودار می‌توان تحلیل کرد که به غیر از ماه‌هایی که میزان ریزش باران بسیار زیاد بوده، سایر داده‌ها بر هم منطبق شدند. به عبارت دیگر، مقادیر پیش‌بینی شده و مقادیر واقعی با روندی یکسان کاهش و افزایش یافتند.

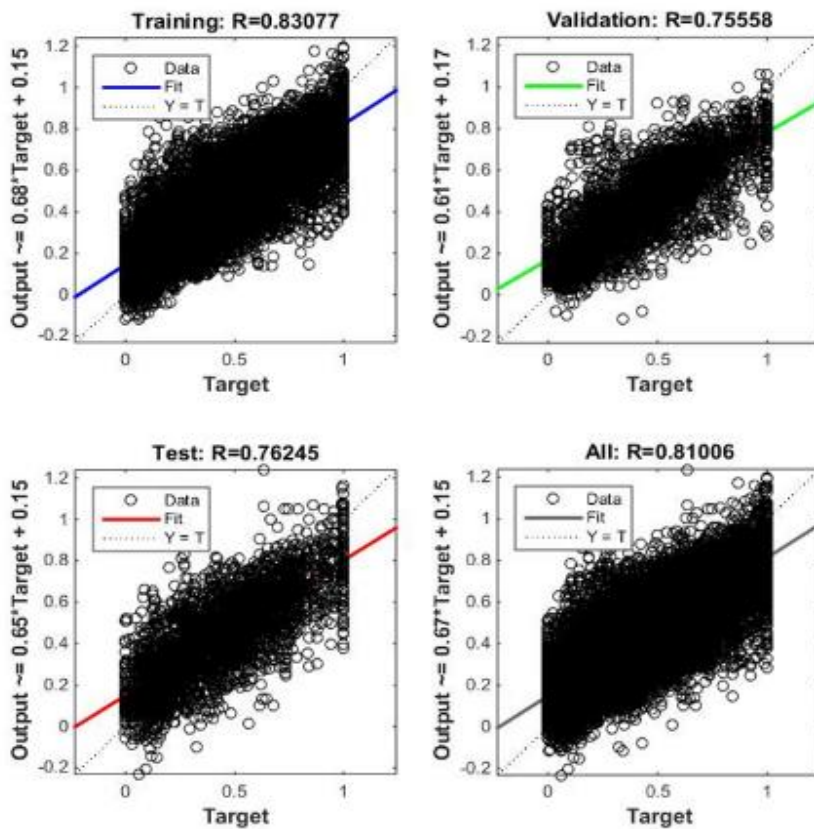
### ۳-۶- مدل پیش‌بینی NDVI

سلامت پوشش گیاهی بیش‌تر به میزان بارندگی بستگی دارد. با توجه به همبستگی‌های قوی که میان NDVI و SPI یک‌ماه گذشته برای پیش‌بینی NDVI فصل رشد یافت شد، به‌عنوان شاخص مناسبی برای پیش‌بینی NDVI انتخاب شده است. بنابراین، از یک مدل رگرسیون چندگانه با دو متغیر SPI-1 و NDVI یک‌ماه قبل برای پیش‌بینی NDVI ماه آینده استفاده شده است.


به‌منظور پیش‌بینی داده‌های NDVI برای یک ماه آینده از شبکه عصبی پرسپترون چندلایه، استفاده شد. از داده‌های NDVI ماه گذشته و SPI-1 به‌عنوان داده‌های ورودی برای پیش‌بینی داده‌های NDVI یک‌ماه آینده در طول فصل رشد استفاده شد. با توجه به شکل ۹، خطای مدل‌سازی و اعتبارسنجی مقدار ۰/۰۲۶۵ را نشان داد.



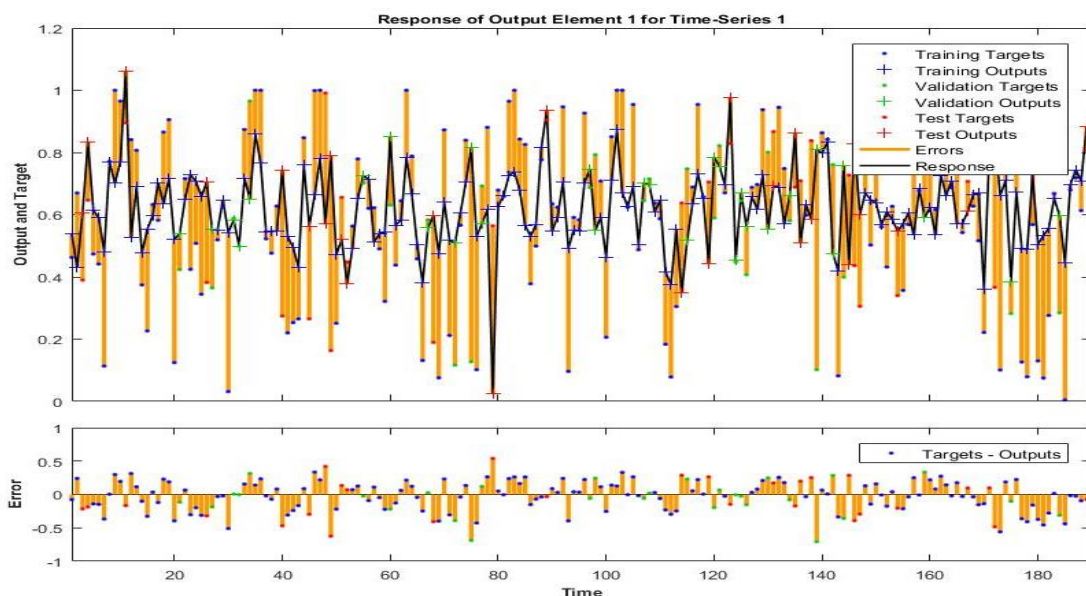
شکل ۹- نمودار خطای میانگین مربعات  
Figure 9- Mean square error chart



شکل ۱۰- همبستگی میان داده‌های ورودی و پیش‌بینی شده  
Figure 10- Correlation between input and predicted data



شکل ۱۱- نمودار هیستوگرام خطا  
Figure 11- Error histogram diagram



شکل ۱۲- همبستگی میان داده‌های ورودی و پیش‌بینی شده  
Figure 12- Correlation between input and predicted data

#### ۴- نتیجه‌گیری

هدف از این پژوهش تعیین تاثیرپذیری خشک‌سالی کشاورزی از هواشناسی در شمال غرب ایران بوده است. نتایج نشان داد که شاخص SPI در مقیاس زمانی یک‌ماهه با شدت و دقت بیشتری نسبت به سایر گام‌های زمانی، میزان ترسالی‌ها و خشک‌سالی‌ها را نشان می‌دهد. در ماه‌های آغازین و پایانی سال SPI زمان ترسالی‌ها عدد بزرگ‌تری به خود می‌گیرد اما در ماه‌های فصل تابستان و خصوصاً شهریور SPI مربوط به زمان خشک‌سالی عدد بزرگ‌تری را نشان می‌دهد. شدیدترین میزان خشک‌سالی‌ها در سال‌های آبی ۱۳۸۰-۱۳۸۱، ۱۳۸۶-۱۳۸۷ و ۱۳۹۳-۱۳۹۲ به وقوع پیوسته است.

به این ترتیب دوره بازگشت این خشک‌سالی‌ها پنج‌ساله است. هم‌چنین شدیدترین میزان ترسالی‌ها در سال‌های آبی ۱۳۸۴-۱۳۸۳، ۱۳۹۰-۱۳۸۹ و ۱۳۹۵-۱۳۹۴ و دوره بازگشت ترسالی در این اقلیم پنج‌ساله است. هم‌چنین با توجه به نتایج حاصل از محاسبه NDVI، به‌طور کلی حداکثر میزان تراکم پوشش گیاهی در سال‌های ۱۳۹۰-۱۳۹۵ مربوط به اردیبهشت بوده که در فصل بهار اتفاق افتاده است. در نهایت بررسی روابط میان شاخص خشک‌سالی هواشناسی و پوشش گیاهی NDVI نشان داد که بیش‌ترین ضریب همبستگی پیرسون مربوط به SPI با سری زمانی یک‌ماهه و مقدار این

با توجه به پیش‌آگاهی خشک‌سالی می‌توان به پیش‌بینی خشک‌سالی پرداخت تا در صورت نیاز بتوان قبل از آغاز این پدیده، اخطار و آگاهی‌های لازم در رابطه با در پیش‌بودن پدیده خشک‌سالی داده شود. همچنین استفاده از شاخص‌های جدید برآوردکننده خشک‌سالی می‌تواند زمینه خوبی برای پژوهش‌های آینده باشد. در نهایت خشک‌سالی پیوند ناگسستی با اقلیم و به‌طور کلی پارامترهای اقلیمی دارد. آگاهی از این پارامترها و ایجاد ارتباط معنادار و دقیق بین خشک‌سالی همراه با فن‌آوری سنسجس از دور و حتی ایجاد و معرفی شاخص‌های ترکیبی موضوع پر اهمیتی برای پژوهش‌های آینده است.

### سپاسگزاری

از همکاری سازمان‌های هواشناسی و وزارت نیرو که داده‌های این پژوهش را در اختیار نویسندگان مقاله حاضر قرار دادند، تشکر و قدردانی می‌شود.

حوضه آبریز دریاچه ارومیه با استفاده از شاخص تلفیقی

خشک‌سالی. تحقیقات کاربردی علوم جغرافیایی، ۱۷(۴)، ۲۴۳-۲۵۷

قاسمی، پوریا، کرباسی، مسعود، زمانی نوری، علیرضا، و سرائی تبریزی، مهدی (۱۳۹۰). SPEI 12 کاربرد مدل ترکیبی شبکه عصبی

مصنوعی و الگوریتم‌های بهینه‌سازی فراابتکاری در پیش‌بینی.

مدیریت آب و آبیاری، ۱۱(۲)، ۱۷۳-۱۸۸.

doi:10.22059/jwim.2021.318390.859

قرمزچشمه، باقر، زند، م.، کوثری، م.ر.، کارگر، ه.، شکر، ا.، علیوردلو، م.،

و نوروزی، خ. (۱۴۰۱). بررسی و ارزیابی خشک‌سالی مرتعی در

استان لرستان. پژوهشکده حفاظت خاک و آبخیزداری، گزارش

پروژه تحقیقاتی، ۹۱ صفحه.

کریمی، مهشید، و شاهدی، کاکا (۱۳۹۸). بررسی خشک‌سالی هواشناسی

هیدرولوژیکی و کشاورزی با استفاده از شاخص‌های

خشک‌سالی. سنسجس از دور و سامانه اطلاعات جغرافیایی در منابع

طبیعی، ۹(۲)، ۱۴۴-۱۵۸.

محمدرضایی، مریم، سلطانی، سعید، و مدرس، رضا (۱۴۰۱). تأثیر

شاخص‌های دمایی انسو بر خشک‌سالی هواشناسی در نیمه غربی

ایران. مدل‌سازی و مدیریت آب و خاک، ۲(۲)، ۱۳-۲۷.

doi:10.22098/mmws.2022.9632.1053

میرمحمدحسینی، طاهره سادات، قرمزچشمه، باقر، حسینی، سید عباس، و

شرافتی، احمد (۱۴۰۰). ارزیابی ارتباط بین خشک‌سالی هواشناسی و

پوشش گیاهی زمین‌های دیم در استان لرستان. پژوهش‌های

همبستگی برای SPI فروردین و اردیبهشت بسیار بیش‌تر از سایر ماه‌ها بود.

در پاسخ به نحوه تغییر روند پوشش گیاهی در آینده می‌توان

نتیجه گرفت که با توجه به تحلیل شاخص‌های SPI و NDVI،

به‌طور کلی روند تغییرات پوشش گیاهی در سال‌های ۱۳۹۵-۱۳۸۰

الگوی ثابتی بوده و به‌جز در سال‌هایی که خشک‌سالی خیلی شدید و

یا ترسالی خیلی شدید اتفاق افتاده، همواره حدود دو درصد مساحت

منطقه پوشش گیاهی مترکم، ۴۱ درصد پوشش گیاهی پراکنده، ۱۳

درصد پهنه آبی و ۴۳ درصد زمین‌های بایر تشکیل داده است.

همچنین نظر به نتایج به‌دست‌آمده حاصل از شبکه عصبی MLP،

می‌توان نتیجه گرفت که، با استفاده از شاخص‌های NDVI و SPI

یک‌ماهه می‌توان تغییرات پوشش گیاهی را با دقت ۸۱ درصد و

خطای کم‌تر از ۳ درصد پیش‌بینی نمود. با توجه به بررسی SPI در

سری زمانی ۱۳۹۵-۱۳۸۰، تحلیل سال‌های کم‌بارش و پربارش و

مقایسه آن با داده‌های NDVI ماه‌های آتی به درستی و صحت این

شاخص در پیش‌بینی‌های آینده داده‌های کشاورزی می‌توان پی برد.

### منابع

باعقیده، محمد، علیجانی، بهلول، و رضاییان، پرویز (۱۳۹۰). بررسی

امکان استفاده از شاخص پوشش گیاهی NDVI در تحلیل

خشک‌سالی‌های استان اصفهان. مطالعات جغرافیایی مناطق خشک،

۱۶-۱.

جان‌بزرگی، محمد، حنیفیه‌پور، مهین، و خسروی، حسن (۱۴۰۰). تغییرات

زمانی خشک‌سالی هواشناسی-هیدرولوژیکی (مطالعه موردی:

استان گیلان). مدیریت و مدل‌سازی آب و خاک، ۱(۲)، ۱-۱۳.

doi:10.22098/mmws.2021.1215

جهانگیر، محمدحسین، حسین‌دوست، محمدصادق، و ارست، مینا (۱۴۰۰).

ارزیابی وضعیت خشک‌سالی استان گیلان با استفاده از شاخص

کچ-بایرام (KBDI) در انطباق با شاخص درصد نرمال بارندگی

(PNPI). مدل‌سازی و مدیریت آب و خاک، ۱(۴)، ۵۷-۶۷.

doi:10.22098/mmws.2021.9407.1038

جهانگیر، محمدحسین، اصغری کلشانی، فاطمه، و ستاریان اصیل، کتایون

(۱۴۰۱). مطالعه تطبیقی شاخص‌های خشک‌سالی هواشناسی

(SPI) و هیدرولوژیکی (SSI) بر اساس بهترین تابع توزیع تجمعی

برای حوضه آبریز ارومیه. مدل‌سازی و مدیریت آب و خاک، ۲(۴)،

۵۳-۶۳. doi:10.22098/mmws.2022.10810.1089

زارع ایبانه، حمید، محبوبی، علی‌اکبر، و نیشابوری، محمدرضا (۱۳۸۳).

بررسی وضعیت خشک‌سالی و روند آن در منطقه همدانی بر اساس

شاخص‌های آماری خشک‌سالی. پژوهش و سازندگی، ۳(۲)، ۷-۲.

عبادی نهاری، زهرا، عرفانیان، مهدی، و کاظم پورچورسی، سیما (۱۳۹۸).

ارائه یک روش نوین برای ارزیابی و پایش جامع خشک‌سالی

یونسی، محبوبه، شهرکی، نادیا، معروفی، صفر، و نوذری، حامد (۱۳۹۵). پیش‌بینی خشکسالی با استفاده از مدل تلفیقی شبکه عصبی مصنوعی- مویک و مدل سری زمانی ARIMA. *علوم و مهندسی آبیاری*، ۴(۲)، ۱۶۷-۱۸۱.  
doi:10.22055/jise.2018.13669

آبخیزداری، ۳۴(۲)، ۷۷-۹۰.  
doi:10.22092/wmej.2020.342647.1332  
ناطق، سعید، نوحه‌گر، احمد، احسانی، امیرهوشنگ، و بذرافشان، ام‌البین (۱۳۹۵). بررسی تغییرات پوشش گیاهی براساس شاخص‌های گیاهی با استفاده از سنجش از دور. *تحقیقات مرتع و بیابان ایران*، ۲۴(۴)، ۷۷۸-۷۹۰.  
doi:10.22092/ijrdr.2017.114889

## References

- Alahacoon, N., & Edirisinghe, M. (2022). A comprehensive assessment of remote sensing and traditional based drought monitoring indices at global and regional scale. *Geomatics, Natural Hazards and Risk*, 13(1), 762-799. doi:10.1080/19475705.2022.2044394
- Baaghideh, M., Alijani, B., & Raziaian, P. (2011). Evaluating the possibility of using the NDVI index to analyze and monitor droughts in Esfahan Province. *Journal of Arid Regions Geographic Studies*, 1(4), 1-16. [In Persian]
- Ebadi Nehari, Z., Erfanian, M., & Porchorsi Sima, K. (2018). Presenting a new method for the comprehensive evaluation and monitoring of drought in the Urmia Lake catchment area using the integrated drought index. *Journal of Geographical Sciences*, 23(68), 243-257. [In Persian]
- D'Odorico, P., Gonsamo, A., Damm, A., & Schaepman, M.E. (2013). Experimental evaluation of sentinel-2 spectral response functions for NDVI time-series continuity. *IEEE Transactions on Geoscience and Remote Sensing*, 51(3), 1336-1348. doi:10.1109/TGRS.2012.2235447
- Dutta, D., Kundu, A., & Patel, N.R. (2013). Predicting agricultural drought in eastern Rajasthan of India using NDVI and standardized precipitation index. *Geocarto International*, 28(3), 192-209. doi:10.1080/10106049.2012.679975
- Gandhi, G.M., Parthiban, S., Thummalu, N., & Christy, A. (2015). NDVI: Vegetation change detection using remote sensing and GIS - A Case Study of Vellore District. *Procedia Computer Science*, 57, 1199-1210. doi:10.1016/j.procs.2015.07.415
- Ghasemi, P., Karbasi, M., Nouri, A.Z., & Tabrizi, M.S. (2021). SPEI 12 Application of combined artificial neural network model and meta-heuristic optimization algorithms in predicting. *Water and Irrigation Management*, 11(2), 173-188. doi:10.22059/jwim.2021.318390.859 [In Persian]
- Ghermezecheshme, B., Zand, M., Kothari, M.R., Kargar, H., Shokri, A., Aliwardlo, M., & Nowrozi, Kh. (2021). Investigation and evaluation of pasture drought in Lorestan province. Soil Conservation and Watershed Research Institute. *Research Project Report*, 91 pages. [In Persian]
- Jahangir, M., Asghari Kalshani, F., & Satarian Asil, K. (2022). Comparative study of meteorological (SPI) and hydrological (SSI) drought indices based on the best cumulative distribution function for Urmia catchment. *Soil and Water Modeling and Management*, 2(4), 53-63. doi:10.22098/mmws.2022.10810.1089 [In Persian]
- Jahangir, M., Hosseindoost, M., & Arast, M. (2021). Assessment of drought condition in Guilan Province using the Keetch-Byram Drought Index (KBDI) in accordance with the Percent of Normal Precipitation Index (PNPI). *Water and Soil Management and Modeling*, 1(4), 57-67. doi:10.22098/mmws.2021.9407.1038 [In Persian]
- Janbozorgi, M., Hanifepour, M., & Khosravi, H. (2021). Temporal changes in meteorological-hydrological drought (Case study: Guilan Province). *Water and Soil Management and Modelling*, 1(2), 1-13. doi:10.22098/mmws.2021.1215 [In Persian]
- Hao, Z., Singh, V.P., & Xia, Y. (2018). Seasonal Drought Prediction: Advances, Challenges, and Future Prospects. *Reviews of Geophysics*, 56(1), 108-141. doi:10.1002/2016RG000549
- He, Y., Wetterhall, F., Cloke, H.L., Pappenberger, F., Wilson, M., & Freer, J. (2009). Tracking the uncertainty in flood alerts driven by grand. *Meteorological Applications*, 101, 91-101. doi:10.1002/met.132
- Jalili, M., Gharibshah, J., Ghavami, S.M., Beheshtifar, M., & Farshi, R. (2014). Nationwide prediction of drought conditions in Iran based on remote sensing data. *IEEE Transactions on Computers*, 63(1), 90-101. doi:10.1109/TC.2013.118
- Jang, O.J., Moon, H.T., & Moon, Y.I. (2022). Pronóstico de sequías para tomadores de decisiones utilizando análisis de balance hídrico y redes neuronales profundas. *Water*, 14(12), 1922.
- Karimi, M., & Shahedi, K. (2018). Investigation of meteorological, hydrological and agricultural drought using drought indices (Case study: Gharehsou watershed). *Remote Sensing and*



- Geographical Information System in Natural Resources*, 9(2), 144-158. [In Persian]
- Ke, Y., Im, J., Lee, J., Gong, H., & Ryu, Y. (2015). Characteristics of Landsat 8 OLI-derived NDVI by comparison with multiple satellite sensors and in-situ observations. *Remote Sensing of Environment*, 164, 298-313. doi:10.1016/j.rse.2015.04.004
- Li, S., Yao, Z., Liu, Z., Wang, R., Liu, M., & Adam, J.C. (2019). The spatio-temporal characteristics of drought across Tibet, China: derived from meteorological and agricultural drought indices. *Theoretical and Applied Climatology*, 137(3-4), 2409-2424. doi:10.1007/s00704-018-2733-9
- Lillesand, T.M., & Kiefer, R.W. (1994). Remote sensing and image interpretation. 3rd edition. In *Remote sensing and image interpretation*.
- Loukas, A., Vasiladias, L., & Tzabiras, J. (2008). Climate change effects on drought severity. *Advances in Geosciences*, 17, 23-29. doi:10.5194/adgeo-17-23-2008
- Magallane, R., Tejada, C.E., Galván, J.I., Méndez, S. de J., García-Domínguez, A., & Gamboa-Rosales, H. (2022). Narx neural networks models for prediction of standardized precipitation index in Central Mexico. *Atmosphere*, 13(8), 1254. doi:10.3390/atmos13081254
- McKee, T.B., Doesken, N.J., & Kleist, J. (1993) The relationship of drought frequency and duration to time scales. 8<sup>th</sup> Conference on Applied Climatology, Anaheim, Pp.179-184.
- Mitter, H., Schmid, E., & Schneider, U.A. (2014). Modelling impacts of drought and adaptation scenarios on crop production in Austria. *Journal of the Austrian Society of Agricultural Economics*, 24, 223-232.
- Mohammadrezaei, M., Soltani, S., & Modares, R. (2022). The effect of Enso temperature indices on meteorological drought in the western half of Iran. *Soil and Water Modeling and Management*, 2(2), 13-27. doi:10.22098/mmws.2022.9632.1053 [In Persian]
- Modarres, R., & Sarhadi, A. (2009). Rainfall trends analysis of Iran in the last half of the twentieth century. *Journal of Geophysical Research Atmospheres*, 114(3), 1-9. doi:10.1029/2008JD010707
- Mokhtari, R., & Akhoondzadeh, M. (2019). Neural network method for drought modeling using satellite data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences-ISPRS Archives*, 42(4/W18), 749-753. doi:10.5194/isprs-archives-XLII-4-W18-749-2019
- Mirmohammadhosseini, T., Hosseini, S.A., Ghermezcheshmeh, B., & Sharafati, A. (2021a). Impact of meteorological drought on vegetation in non-irrigated lands. *Quarterly Journal of the Hungarian Meteorological Service*, 125(3), 463-476. doi:10.28974/idojaras.2021.3.6
- Mirmohammad Hosseini, T., Karmazecheshme, B., Hosseini, A., & Shrafati, A. (2021b). An assessment of the relationships between meteorological drought index and vegetation condition in dry farming in the Province of Lorestan. *Watershed Management Research*, 34(2), 77-90. [In Persian] doi:10.22092/wmej.2020.342647.1332
- Nateghi, S., Nohegar, A., Ehsani, A.H., & Bazrafshan, O. (2017). Evaluating the vegetation changes upon vegetation index by using remote sensing. *Iranian Journal of Rangeland and Research*, 24(4), 778-790. doi:10.22092/ijrdr.2017.114889 [In Persian]
- Sharafati, A., Nabaei, S., & Shahid, S. (2020). Spatial assessment of meteorological drought features over different climate regions in Iran. *International Journal of Climatology*, 40(3), 1864-1884. doi:10.1002/joc.6307
- Tian, Y., Xu, Y.P., & Wang, G. (2018). Agricultural drought prediction using climate indices based on support vector regression in Xiangjiang River basin. *Science of the Total Environment*, 622-623, 710-720. doi:10.1016/j.scitotenv.2017.12.025
- Vicente-Serrano, S.M., Beguería, S., & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *Journal of Climate*, 23(7), 1696-1718. doi:10.1175/2009JCLI2909.1
- Younesi, M., Shahraki, N., Marofi, S., & Nozari, H. (2018). Artificial wavelet neural network integrated model (WA-ANN) and time series model (ARIMA). *Irrigation Science and Engineering*, 41(2), 167-181. doi:10.22055/jise.2018.13669 [In Persian]
- Zare Abianeh, H., Mehboubi, A., & Nishaburi, M. (2004). Investigating the drought situation and its trend in Hamedani region based on drought statistical indicators. *Pajouhesh Va Sazandgi*, 3(2), 2-7. [In Persian]
- Zambrano, F., Vrieling, A., Nelson, A., Meroni, M., & Tadesse, T. (2018). Prediction of drought-induced reduction of agricultural productivity in Chile from MODIS, rainfall estimates, and climate oscillation indices. *Remote Sensing of Environment*, 219(25), 15-30. doi:10.1016/j.rse.2018.10.006