

## Evaluation of Combined Agricultural Drought Index (CDI), Prediction Methods Based on Satellite Images via Deep Learning and Machine Learning Approaches

N. Shamloo<sup>1</sup>, M.T. Sattari<sup>2\*</sup>, Kh. Valizadeh Kamran<sup>3</sup>, H. Apaydin<sup>4</sup>

1 and 2- Ph.D. Student and Associate Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran, respectively.

(\*- Corresponding Author Email: [mtsattar@gmail.com](mailto:mtsattar@gmail.com))

3- Professor Department of Remote Sensing and GIS, Faculty of Geography & Planning, University of Tabriz, Tabriz, Iran

4- Professor Department of Agricultural, Faculty of Agriculture, University of Ankara, Ankara, Turkey

Received: 07-06-2023  
Revised: 27-08-2023  
Accepted: 20-09-2023  
Available Online: 23-09-2023

### How to cite this article:

Shamloo, N., Sattari, M.T., Valizadeh Kamran, Kh., & Apaydin, H. (2023). Evaluation of combined agricultural drought index (CDI) prediction methods based on satellite images via deep learning and machine learning methods. *Journal of Water and Soil*, 37(5), 787-807. (In Persian with English abstract).  
<https://doi.org/10.22067/jsw.2023.82798.1293>

### Introduction

Drought is one of the greatest challenges of our time due to the dangers it poses to the world. In arid and semi-arid regions, it is necessary to continuously monitor agricultural systems that face water shortages and frequent droughts. Therefore, it is necessary to have large-scale information about agricultural systems and land use for managing and making decisions for the sustainability of food security. Continuous monitoring of drought requires a large amount of information to be processed with great speed and accuracy. Due to the complexity and impact of various factors on drought, in recent years, the methods of combining several factors to create a comprehensive drought index have received much attention. Machine learning and deep learning methods can provide a more accurate and efficient tool to predict droughts and be used in drought risk management. The review of sources shows that until now no studies have been conducted in the field of drought monitoring using deep learning approach and satellite images in the catchment area of Lake Urmia in Iran. A large part of its economic activities is dedicated to agriculture. The increase in temperature, the increase in evaporation-transpiration and the excessive use of water resources for agriculture have caused an upward trend in the frequency of droughts in this basin during consecutive years, one of the harmful effects of which is a significant decrease in the lake level. Therefore, for drought management in this basin, it is very important to identify drought behavior so It is very important to determine appropriate and reliable indicators to measure and predict the effects of droughts. According to the investigations, it was observed that most of the studies in the field of drought in this basin have been carried out from the meteorological point of view, or by individual plant indicators, so in this study, using the approach of principal component analysis, we tried to provide a composite drought index for drought modeling and forecasting.

### Materials and Methods

In this research, satellite images and deep learning and machine learning methods have been used to predict the Combined Drought Index. For this purpose, satellite images were first obtained for the study area and pre-processing was done on the data. Then, all the data were converted to a scale with a spatial resolution of 500 meters, and the VCI index was calculated using NDVI data, the TCI index using the land surface temperature product, and the CWSI index using the Modis evapotranspiration product, and finally, CDI drought index was



©2023 The author(s). This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/), which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source.

<https://doi.org/10.22067/jsw.2023.82798.1293>

calculated using principal component analysis method. Then the correlation between CDI data and other meteorological variables including evapotranspiration, potential evapotranspiration, land surface temperature during the day, and land surface temperature at night was calculated. Finally, the CDI index is modeled using deep learning and machine learning methods.

## Results and Discussion

This study modeled the Combined Drought Index based on a different combination of input variables and deep learning and machine learning methods. Examining the results showed that the variables of the normalized difference vegetation index, the land surface temperature during the day and at night, evapotranspiration, and potential evapotranspiration were the most influential parameters for modeling the CDI index, and all four methods with acceptable accuracy and error have been able to model the combined drought index. The CART model with a correlation coefficient of 0.96, RMSE equal to 0.029, and Nash Sutcliffe coefficient of 0.92 was chosen as the best model among the methods.

## Conclusion

In this research, different combinations of input variables extracted from satellite image products were evaluated in the form of 6 independent scenarios to predict the Combined Drought Index. By examining the evaluation parameters including correlation coefficient, Nash Sutcliffe coefficient, and root mean square error, it was found that all four methods can estimate the combined drought index with acceptable accuracy and error. Among all the methods, the CART method performed better ( $R=0.96$  and  $RMSE=0.029$ ) than the other methods for predicting the time series of the Combined Drought Index. On the other hand, the SVM method has been able to model the combined drought index with acceptable accuracy ( $R=0.94$  and  $RMSE=0.034$ ). However, contrary to expectations, two deep learning methods were able to model the combined drought index with less accuracy than machine learning methods. In general, by examining the results, it was found that with the method presented in this research, it is possible to accurately predict the CDI combined drought index time series and predict drought in different periods of plant growth, and use its results for regional drought management and policies, especially in Basins without statistics.

**Keywords:** Agricultural drought, Combined Drought Index (CDI), Deep learning and machine learning, Satellite images

## مقاله پژوهشی

جلد ۳۷، شماره ۵، آذر-دی ۱۴۰۲، ص. ۷۸۷-۸۰۷

# ارزیابی روش‌های پیش‌بینی شاخص ترکیبی خشکسالی کشاورزی (CDI) براساس تصاویر ماهواره‌ای با روش‌های یادگیری عمیق و یادگیری ماشین

نازیلا شاملو<sup>۱</sup> - محمدتقی ستاری<sup>۲\*</sup> - خلیل ولی زاده کامران<sup>۳</sup> - حالت آب آیدین<sup>۴</sup>

تاریخ دریافت: ۱۴۰۲/۰۳/۱۷

تاریخ پذیرش: ۱۴۰۲/۰۶/۲۹

## چکیده

باتوجه به بحران خشکیدگی دریاچه ارومیه، مطالعه وضعیت پوشش گیاهی و خشکسالی کشاورزی محدوده حوضه آبریز دریاچه ارومیه که یکی از شش حوضه اصلی ایران محسوب می‌شود، از اهمیت قابل توجهی برخوردار است. در این مطالعه ابتدا یک شاخص ترکیبی خشکسالی (Combined CDI (Drought Index) مبتنی بر شاخص‌های وضعیت پوشش گیاهی (VCI)، وضعیت دمایی گیاهی (TCI) و شاخص تنش آبی محصول (CWSI) با استفاده از داده‌های سنجنده MODIS قرارگرفته در ماهواره TERRA معرفی و محاسبه گردید. سپس با روش‌های درخت تصمیم-طبقه‌بندی و درخت رگرسیون (DT-CART)، ماشین‌بردار پشتیبان (SVM) و حافظه کوتاه مدت، بلند مدت (LSTM) و حافظه کوتاه مدت دو جهته (BiLSTM)، شاخص ترکیبی خشکسالی (CDI) معرفی و تخمین زده شد. در فرآیند مدل‌سازی شاخص ترکیبی خشکسالی، محصولات شاخص‌های پوشش گیاهی، تبخیر-تعرق، تبخیر-تعرق پتانسیل، دمای سطح زمین در روز و دمای سطح زمین در شب برگرفته از سنجنده MODIS به‌عنوان ورودی مدل‌ها استفاده شد. در نهایت بررسی عملکرد مدل‌ها براساس ترکیب‌های متفاوتی از ورودی مدل‌ها با استفاده از معیارهای ارزیابی شامل ضریب همبستگی، جذر میانگین مربعات خطا و ضریب ناش ساتکلیف و همچنین به کمک نمودارهای کلوروگرام، تیلور و ویلونو بصورت بصری انجام شد. نتایج نشان داد که متغیرهای دمای سطح زمین در روز، دمای سطح زمین در شب و تبخیر-تعرق موثرترین متغیرها برای مدل‌سازی شاخص ترکیبی خشکسالی (CDI) و مطالعه خشکسالی کشاورزی می‌باشند. همچنین مدل CART با ضریب همبستگی ۰/۹۶، میانگین جذر مربعات خطا برابر با ۰/۰۲۹ و ضریب ناش ساتکلیف ۰/۹۲ به‌عنوان بهترین مدل انتخاب گردید. نتایج بدست آمده نشان داد که روش‌های یادگیری ماشین و یادگیری عمیق ابزاری توانمند در مدل‌سازی و پیش‌بینی شاخص ترکیبی خشکسالی (CDI) بوده و در بررسی و ارزیابی خشکسالی کشاورزی به‌خصوص در حوضه‌های فاقد آمار با اطمینان کافی می‌تواند مورد استفاده قرار گیرد.

**واژه‌های کلیدی:** حافظه کوتاه مدت بلند مدت، درخت تصمیم، سنجش از دور، شاخص خشکسالی، ماشین بردار پشتیبان

۱ و ۲- به‌ترتیب دانشجوی دکتری و دانشیار گروه علوم و مهندسی آب، دانشکده کشاورزی دانشگاه تبریز، تبریز، ایران  
(\*- نویسنده مسئول: Email: mtsattar@gmail.com)

۳- استاد گروه سنجش از دور و GIS، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز، تبریز، ایران

۴- استاد گروه مهندسی کشاورزی، دانشکده کشاورزی، دانشگاه آنکارا، آنکارا، ترکیه

## مقدمه

خطی و تجزیه و تحلیل روابط سلسله مراتبی و متغیرهای غیرخطی بین متغیرهای وابسته و مستقل و در نتیجه عملکرد بهتر در مقایسه با روش‌های رگرسیون خطی دارند (Guzmán et al., 2018).

روش‌های یادگیری عمیق می‌توانند روابط پیچیده غیرخطی بین متغیرها را با استفاده از آموزش چند لایه به دقت تخمین بزنند (LeCun et al., 2015). همچنین این روش‌ها توانایی کار با داده‌های متوالی را دارند (Cunha et al., 2018). از سویی یادگیری عمیق یک رویکرد بسیار امیدوارکننده برای ترسیم غیرخطی ویژگی‌های عوامل خشکسالی می‌باشد و به دلیل مستقل بودن از تئوری توزیع داده‌ها در مقایسه با روش‌های آماری عملکرد دقیق‌تر و بهتری خواهند داشت (Qian et al., 2015). مطالعات گسترده‌ای با استفاده از روش‌های یادگیری ماشین در طبقه‌بندی یا پیش‌بینی خشکسالی انجام شده‌است به طور مثال خسروی و همکاران (Khosravi et al., 2015) به بررسی کارایی چهار روش شبکه عصبی (NN)، رگرسیون بردار پشتیبان (SVR)، ماشین بردار پشتیبان کمترین مربعات (LSSVM) و همچنین یک سیستم فازی بر پایه شبکه عصبی تطبیقی (ANFIS) برای مدل‌سازی شاخص‌های هواشناسی و سنجش از دور منطقه شرقی اصفهان در سال‌های ۲۰۰۰ تا ۲۰۱۶ پرداختند و نشان دادند که از میان روش‌های مورد مطالعه روش رگرسیون بردار پشتیبان بیشترین کارایی و روش شبکه عصبی کمترین کارایی را در مدل‌سازی سری‌زمانی خشکسالی داشته است.

نیاستی و همکاران (Niasati et al., 2021)، به برآورد تبخیر-تعرق مرجع با استفاده از روش‌های یادگیری ماشین و تصاویر ماهواره و شاخص‌های خشکسالی پرداختند و پتانسیل بالای الگوریتم‌های یادگیری ماشین در برآورد تبخیرتعرق مرجع را نشان دادند. در مطالعه‌ای (Nay et al., 2018) ابزاری برای پیش‌بینی سلامت شاخص پوشش گیاهی (VHI) با استفاده از یادگیری ماشین توسعه دادند. و همبستگی بالا (۰/۷۵) بین مقادیر مدل شده و واقعی را نشان دادند. همچنین دنگ و همکاران (Dang et al., 2020) از روش‌های رگرسیون بردار پشتیبان، جنگل تصادفی و یادگیری عمیق برای پیش‌بینی محصول استفاده کردند و نشان دادند که روش یادگیری عمیق عملکرد بهتری نسبت به سایر روش‌ها دارد.

ردی و پراساد (Reddy & Prasad, 2018) با استفاده از روش LSTM و تصاویر سنجنده مودیس شاخص پوشش گیاهی NDVI را در منطقه جزایر نیکوبار در هندوستان پیش‌بینی نمودند. آن‌ها از ۸۶۱ تصویر شاخص پوشش گیاهی NDVI از سال ۲۰۰۰ تا ۲۰۱۶ استفاده

خشکسالی به دلیل به وجود آوردن خطراتی برای جهان، یکی از بزرگ‌ترین چالش‌های عصر ما می‌باشد (Balti et al., 2020). در مناطق خشک و نیمه‌خشک پایش مستمر سیستم‌های کشاورزی که با کمبود آب و خشکسالی‌های مکرر مواجه‌اند، ضروری است (Winkler et al., 2017). نظارت مستمر بر خشکسالی نیازمند حجم وسیع و گسترده‌ای از اطلاعات است تا با سرعت و دقت بسیار زیاد پردازش شوند (Balti et al., 2020). باتوجه به وجود شرایط اقلیمی متنوع، دلایل فیزیکی و پتانسیل بخش‌های تأثیرپذیر، ساختار و عملکرد سیستم نظارت بر خشکسالی می‌بایست مطابق با نیازهای خاص منطقه باشد (Heim Jr & Brewer, 2012).

اگرچه روش‌های پایش خشکسالی هواشناسی توسط سایر محققین به گستردگی استفاده شده‌اند، اما در مقایسه با آن بررسی‌های پاسخ پوشش گیاهی به خشکسالی که مربوط به تنش آبی محصول می‌باشد کمتر مورد توجه قرار گرفته‌است. استفاده از روش‌های سنجش از دور، توزیع مکانی و زمانی سریع و پیوسته‌ای از رشد گیاه و خشکسالی ارائه می‌دهند. از آنجایی که روش‌های سنتی پایش خشکسالی توسط سنجش از دور تنها به بررسی یک عامل مانند رشد گیاه یا رطوبت خاک می‌پردازند، نمی‌توانند به خوبی اطلاعات جامعی درباره خشکسالی ارائه دهند. باتوجه به پیچیدگی و تأثیرگذاری عوامل مختلف بر خشکی، در سال‌های اخیر روش‌های ترکیب چندین عامل برای ساخت شاخص جامع خشکسالی مورد توجه بسیاری قرار گرفته است (Yin et al., 2018; AghaKouchak et al., 2015).

پیش‌بینی خشکسالی با استفاده از مدل‌های تصادفی فقط مقادیر حال و گذشته یک متغیر (دما و بارش) را در نظر می‌گیرد و اثرات سایر متغیرها را نادیده می‌گیرد. از آنجایی که این مدل‌ها، مدل‌های خطی می‌باشند برای پیش‌بینی پدیده‌های پیچیده غیرخطی قابل استفاده نمی‌باشند. اخیراً روش‌های یادگیری ماشین و مدل‌های هیبرید به‌عنوان جایگزینی برای مدل‌های آماری، سری‌های زمانی و مدل‌های احتمالی استفاده می‌شوند که قابلیت‌های بسیاری در مدل‌سازی پیش‌بینی سری زمانی غیرخطی و دینامیکی خشکسالی دارند. روش‌های یادگیری ماشین (Machine learning) و یادگیری عمیق (Deep Learning) می‌تواند ابزاری دقیق و کارآمدتر برای پیش‌بینی خشکسالی‌ها ارائه کند و در مدیریت ریسک خشکسالی‌ها استفاده شود (Proadhan et al., 2022). روش‌های یادگیری ماشین توانایی جداسازی اثرات متغیرهای

1- Neural Network

2- Least-Squares Support-Vector Machines

3- Adaptive Neuro-Fuzzy Inference System

4- Vegetation Health Index

نرمال شده گیاهی، دمای سطح زمین در روز و شب، تبخیر-تعرق، تبخیر-تعرق پتانسیل می‌باشد. کارایی شاخص ترکیبی خشکسالی و همچنین تعیین متغیرهای مهم اقلیمی و تاثیرگذار در مدل‌سازی شاخص ترکیبی خشکسالی در منطقه مورد مطالعه اهداف فرعی دیگر این پژوهش می‌باشد.

## مواد و روش‌ها

### منطقه مورد مطالعه

حوضه آبریز دریاچه ارومیه دارای مساحت تقریبی ۵۲۷۰۰ کیلومتر مربع می‌باشد که ۳/۱۵ درصد کل مساحت ایران را و ۷ درصد کل سطح آب‌های کشور را به خود اختصاص داده‌است. این حوضه از ۴۴/۲۲ تا ۴۷/۸۹ درجه شرقی و ۳۵/۶۷ تا ۳۸/۴۷ درجه شمالی گسترش یافته‌است. براساس روش طبقه‌بندی اقلیمی کوپن این منطقه دارای اقلیم نیمه‌خشک می‌باشد. مقدار متوسط بارندگی منطقه حدود ۴۰۰ میلی‌متر در سال است. این حوضه آبریز در سه استان آذربایجان شرقی، آذربایجان غربی و کردستان واقع شده‌است (et Rezaei Moghadam, 2012).

### تصاویر ماهواره‌ای

در این مطالعه از محصولات سنجنده مودیس قرار گرفته در ماهواره ترا به شرح جدول ۱ استفاده شده است. تمامی داده‌ها برای سال‌های ۲۰۰۱ تا ۲۰۲۰ از سایت Google Earth Engine دریافت گردید. با توجه به بازه زمانی ۱۶ روزه تصاویر شاخص پوشش گیاهی، در این مطالعه ۷۰ درصد داده‌ها از تاریخ ۲۰۰۱/۰۱/۰۱ تا ۲۰۱۵/۰۱/۱۷ برای آموزش و ۳۰ درصد داده‌ها از تاریخ ۲۰۱۵/۰۲/۰۲ تا ۲۰۲۰/۱۱/۱۶ برای آزمون مورد استفاده قرار گرفته است.

در این مطالعه از تصاویر ماهواره‌ای و روش‌های یادگیری ماشین و عمیق برای پیش‌بینی شاخص ترکیبی خشکسالی کشاورزی استفاده شده است. به این منظور در ابتدا تصاویر ماهواره‌ای برای منطقه مورد مطالعه دریافت و پیش‌پردازش روی داده‌ها انجام گرفت. سپس تمامی داده‌ها به مقیاس یکسان با رزولوشن مکانی ۵۰۰ متر تبدیل و شاخص‌های VCI با استفاده از داده‌های NDVI، شاخص TCI با استفاده از محصول دمای سطح زمین و شاخص CWSI با استفاده از محصول تبخیر-تعرق سنجنده مودیس محاسبه و در نهایت شاخص ترکیبی خشکسالی CDI با روش آنالیز مولفه‌های اصلی بدست آمد. سپس همبستگی بین داده‌های CDI با سایر متغیرهای هواشناسی شامل تبخیر-تعرق، تبخیر-تعرق پتانسیل، دمای سطح زمین در روز و دمای

نموده و با مدل‌های LSTM و هوش مصنوعی به پیش‌بینی سری زمانی NDVI پرداختند و نشان دادند که روش LSTM عملکرد بهتری نسبت به دیگر روش‌های هوش مصنوعی دارد. شن و همکاران (Shen et al., 2020) با استفاده از عوامل مختلف خطر ساز در توسعه خشکسالی بدست آمده از تصاویر ماهواره MODIS و TRMM به توسعه یک شاخص پیچیده سنجنش از دور با استفاده از روش‌های یادگیری عمیق پرداختند و با کمک آن خشکسالی را در استان هنان چین پیش‌بینی نموده و در نهایت نشان دادند که مدل جامع خشکسالی بدست آمده با روش‌های یادگیری عمیق کاربرد دقیقی در پایش خشکسالی هواشناسی و کشاورزی دارد. البلتاگی و همکاران (Elbeltagi et al., 2021) شاخصی به نام شاخص ترکیبی تبخیر-تعرق (CTEI)<sup>۱</sup> برای منطقه رودخانه گنگا ارائه دادند و از طریق آن به پیش‌بینی خشکسالی با استفاده از ۵ روش یادگیری ماشین پرداختند و نشان دادند که روش ماشین بردار پشتیبان (SVM) با ضریب تبیین ۰/۸۲ و میانگین جذر مربعات خطا ۰/۳۳ بهترین روش برای پیش‌بینی خشکسالی می‌باشد. لی و همکاران (Li et al., 2021) به مطالعه پیش‌بینی شاخص خشکسالی نرمال شده پوشش گیاهی در سال‌های ۲۰۰۱ تا ۲۰۱۸ با روش‌های یادگیری ماشین پرداختند و نشان دادند که روش‌های یادگیری ماشین پتانسیل زیادی برای نظارت بر پویایی پوشش گیاهی و رشد محصول دارد.

حوضه آبریز دریاچه ارومیه یکی از شش حوضه اصلی ایران محسوب می‌شود که به علت شرایط اقلیمی و اجتماعی مناسب، بخش وسیعی از فعالیت‌های اقتصادی در آن به کشاورزی اختصاص یافته‌است (Mohammadi et al., 2018). افزایش دما، بالا رفتن تبخیر-تعرق و استفاده بیش از حد از منابع آب برای کشاورزی موجب روند صعودی در فراوانی خشکسالی در طی سال‌های متوالی در این حوضه گردیده است. تعیین شاخص‌های مناسب و قابل اعتماد به طوری که بتواند اثرات ناشی از خشکسالی در این حوضه را اندازه‌گیری و پیش‌بینی کند، بسیار حائز اهمیت است. با توجه به بررسی‌های انجام شده، مشاهده گردید که بیشتر مطالعات در زمینه خشکسالی در این حوضه از منظر هواشناسی، یا توسط شاخص‌های منفرد گیاهی انجام گرفته است (Shamloo et al., 2019). بنابراین در این مطالعه با استفاده از رویکرد آنالیز مولفه‌های اصلی و داده‌های سنجنش از دور اقدام به ارائه شاخص ترکیبی خشکسالی شد و با استفاده از روش‌های جدید یادگیری عمیق به مدل سازی و پیش‌بینی خشکسالی پرداخته شد. در حالت کلی هدف از مطالعه حاضر مقایسه عملکرد روش‌های یادگیری ماشین و یادگیری عمیق شامل DT-CART<sup>۲</sup>، SVM<sup>۳</sup>، LSTM<sup>۴</sup> و BiLSTM<sup>۵</sup> در پیش‌بینی شاخص ترکیبی خشکسالی (CDI)<sup>۶</sup> براساس داده‌های شاخص تفاضل

4- Long Short-Term Memory

5- Bidirectional Long Short-Term Memory

6- Combined Drought Index

1- Combined Terrestrial Evapotranspiration Index


2- Decision Tree-Classification and Regression Tree

3- Support Vector Machine

شاخص‌های خشکسالی

در جدول ۲ شاخص‌های مورد استفاده در این مطالعه و روابط مربوطه برای محاسبه هر شاخص نشان داده شده‌است.

سطح زمین در شب محاسبه شد. در نهایت مدل سازی شاخص CDI با استفاده از روش‌های یادگیری عمیق، یادگیری ماشین و ترکیبی از متغیرهای ورودی مختلف انجام شد. فلوچارت ارائه شده در شکل ۲ فرایند کلی مورد استفاده در این مطالعه برای پیش‌بینی سری زمانی شاخص ترکیبی خشکسالی را نشان می‌دهد.



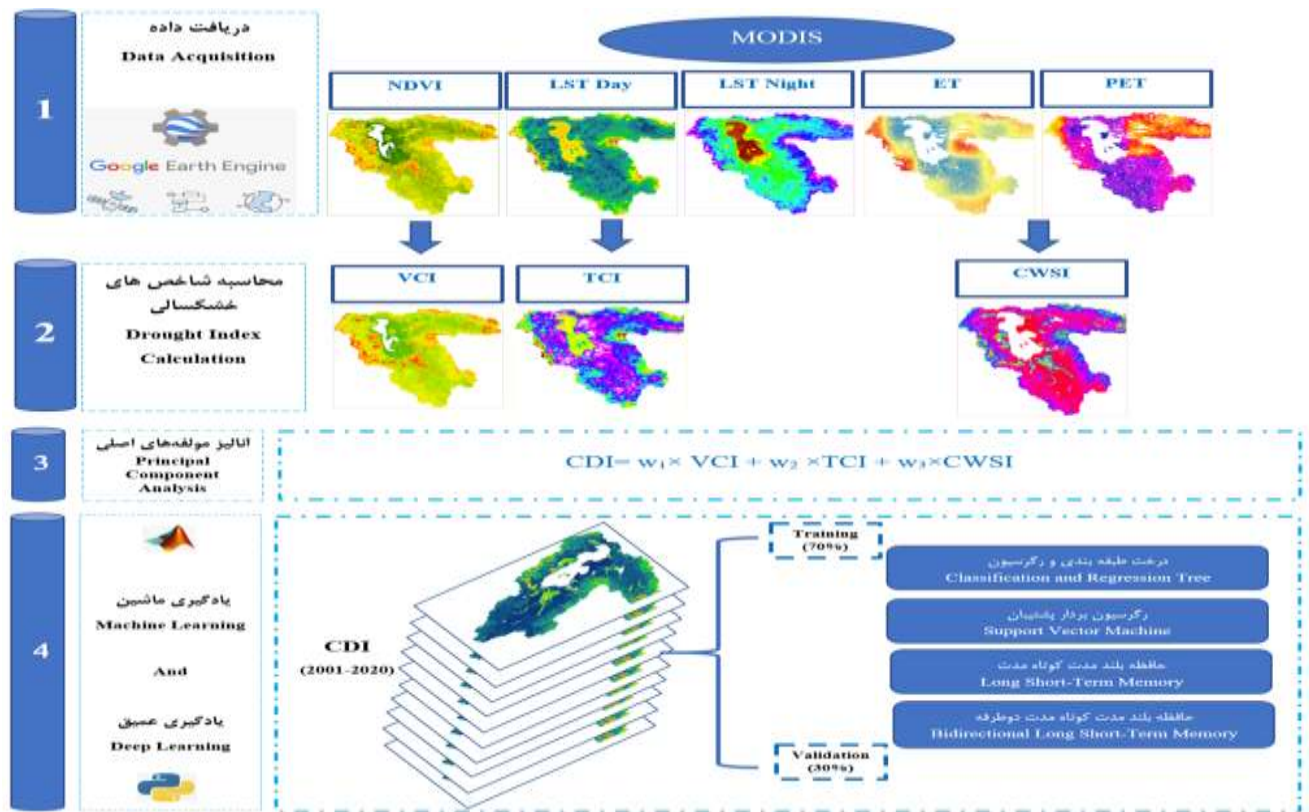
شکل ۱- منطقه مورد مطالعه

Figure 1- Location of the study area

جدول ۱- مشخصات تصاویر ماهواره‌ای مورد استفاده

Table1- Satellite products used

| محصولات<br>Products | شاخص<br>Index        | تعریف<br>Definition  | رزولوشن مکانی<br>Spatial Resolution | رزولوشن زمانی<br>Temporal Resolution | سنجنده<br>Sensor |
|---------------------|----------------------|--|-------------------------------------|--------------------------------------|------------------|
| MOD16A2             | ET                   | تبخیر-تعرق<br>Evapotranspiration                                     | 500 m                               | ۸ روزه<br>8 day                      | MODIS            |
| MOD16A2             | PET                  | تبخیر-تعرق پتانسیل<br>Potential Evapotranspiration                   | 500 m                               | ۸ روزه<br>8 day                      | MODIS            |
| MOD11A2             | LST <sub>day</sub>   | دمای سطح زمین در روز<br>Land Surface Temperature-Day                 | 1000 m                              | ۸ روزه<br>8 day                      | MODIS            |
| MOD11A2             | LST <sub>night</sub> | دمای سطح زمین در شب<br>Land Surface Temperature- Night               | 1000 m                              | ۸ روزه<br>8 day                      | MODIS            |
| MOD13A1             | NDVI                 | شاخص تفاضل نرمال شده گیاهی<br>Normalized Difference Vegetation Index | 500 m                               | ۱۶ روزه<br>16 day                    | MODIS            |
| MOD13A1             | EVI                  | شاخص بهبود یافته گیاهی<br>Enhanced vegetation index                  | 500 m                               | ۱۶ روزه<br>16 day                    | MODIS            |



شکل ۲- فلوجارت روش انجام مطالعه  
Figure 2- Flowchart of the study method

جدول ۲- شاخص‌های مورد استفاده

Table 2- used indices

| مرجع<br>References     | فرمول<br>Formula  | شاخص<br>Index  |
|------------------------|---|--|
| (Tucker, 1979)         | $NDVI = \frac{NIR - RED}{NIR + RED}$                            | ۱ شاخص اختلاف پوشش گیاهی نرمال شده ( Normalized Difference )<br>(Vegetation Index) |
| (Kogan, 1995)          | $VCI = \frac{(NDVI_j - NDVI_{min})}{(NDVI_{max} - NDVI_{min})}$ | ۲ شاخص وضعیت پوشش گیاهی<br>(Vegetation Condition Index)                            |
| (Kogan, 1995)          | $TCI = \frac{(T_{max} - T_i)}{(T_{max} - T_{min})}$             | ۳ شاخص وضعیت دمایی<br>(Temperature Condition Index)                                |
| (Jackson et al., 1988) | $CWSI = 1 - \frac{ET}{PET}$                                     | ۴ شاخص تنش آبی محصول<br>(Crop Water Stress Index)                                  |
|                        | $CDI = w_1 \times VCI + w_2 \times TCI + w_3 \times CWSI$       | ۵ شاخص ترکیبی خشکسالی<br>(Combined Drought Index)                                  |

روی دومین محور مختصات و به همین ترتیب برای سایر محورها ادامه می‌یابد. با استفاده از تحلیل مولفه اصلی می‌توان تعداد زیادی متغیر همبسته را با تعداد محدودی متغیر جدید که مؤلفه اصلی نامیده می‌شوند و ناهمبسته‌اند جایگزین نمود و به این ترتیب بعد مسأله را کاهش داد. مراحل محاسبات این روش به این ترتیب است (۱) ابتدا مقادیر داده‌ها در هر بعد از میانگین خودشان در همان بعد کم می‌شوند، (۲) ماتریس

### روش آنالیز مؤلفه اصلی (PCA)

تحلیل مؤلفه اصلی تبدیلی در فضای برداری است که غالباً برای کاهش ابعاد مجموعه داده‌ها مورد استفاده قرار می‌گیرد. این تحلیل شامل تجزیه مقدار ویژه ماتریس کوواریانس می‌باشد. در واقع در این روش داده‌ها به دستگاه مختصات جدیدی برده می‌شوند که بزرگترین واریانس داده بر روی اولین محور مختصات، دومین واریانس بزرگ بر

این روش‌ها به مدل‌های ماشین‌های بردار پشتیبان و مدل‌های رگرسیون بردار پشتیبان تقسیم‌بندی می‌شوند.

یکی از روش‌های متداول برای حل مسائل غیرخطی، استفاده از توابع کرنل می‌باشد که بر اساس ضرب داخلی داده تعریف می‌شود. در واقع با یک تبدیل غیرخطی از فضای ورودی به فضای با ابعاد بیشتر (حتی نامتناهی) می‌توان مسائل را به صورت خطی، تفکیک‌پذیر ساخت.

$$f(x) = w \times \phi(x) + b \quad (6)$$

که در آن  $f$  تابع رگرسیون  $\phi$  تابع انتقال و  $w$  و  $b$  وزن‌ها و بایاس‌ها می‌باشند.

که مساله بهینه‌سازی می‌تواند به صورت معادله  $\gamma$  تعریف شود

$$\text{Minimize: } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (7)$$

$$\text{Subject to: } \begin{cases} y_i - f(x) \leq \varepsilon + \xi_i \\ f(x) - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i = 1, 2, 3, \dots, N \end{cases} \quad (8)$$

که  $C$  پارامتر خطا و  $\xi_i, \xi_i^*$  سکون متغیرها و  $\varepsilon$  مقدار مرزی می‌باشد. با استفاده از ضرب لاگرانژ مساله بهینه‌سازی به برنامه‌نویسی درجه دوم و غیرخطی تبدیل می‌شود. که تابع رگرسیون به صورت ذیل بیان می‌شود.

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (9)$$

که  $K(x, x_i)$  تابع کرنل و  $\alpha_i, \alpha_i^*$  متغیرهای دو گانه می‌باشند توابع کرنل هسته رگرسیون بردار پشتیبان هستند. انواع توابع کرنل شامل خطی، چند جمله‌ای، سگموئید و RBF وجود دارد. که در این مطالعه از تابع کرنل RBF که عملکرد خوبی در مطالعات بسیاری داشته‌است استفاده شده‌است (Maroufpoor et al., 2019). تابع کرنل RBF به صورت ذیل بیان می‌شود.

$$K(x, x_i) = \exp(-\gamma \|x_i - x\|^2) \quad (10)$$

که  $\gamma$  پارامتر تابع کرنل و مهمترین عامل در افزایش یا کاهش عملکرد رگرسیون بردار پشتیبان می‌باشد.

### مدل LSTM

یکی از انواع شبکه‌های عصبی بازگشتی روش LSTM می‌باشد که برای پیش‌بینی سری‌زمانی با یادگیری طولانی مدت استفاده می‌شوند (Hochreiter & Schmidhuber, 1997). این یک روش خاص عصبی بازگشتی می‌باشد که برای مدل‌سازی توالی و وابستگی‌های طولانی مدت ساخته شده‌است. LSTM یک تکامل با کیفیت بالا از شبکه‌های عصبی بازگشتی (RNN) می‌باشد. این شبکه عصبی برای رفع مشکلات موجود در شبکه‌های عصبی بازگشتی با اضافه نمودن تعاملات بیشتر در هر سلول ارائه شده‌است. روش LSTM به دلیل به

کوواریانس داده‌ها محاسبه می‌شود و (۳) سپس براساس این ماتریس مقادیر بردارهای ویژه محاسبه می‌شود. به طوری که هر بردار ویژه‌ای که دارای بیشترین مقدار ویژه نیز باشد، به عنوان مؤلفه اصلی در نظر گرفته می‌شود. سپس داده‌هایی که از مقدار میانگین خود در هر بعد کم شده‌اند در مقدار بردار ویژه‌ای که به عنوان مؤلفه اصلی در نظر گرفته شده ضرب می‌شود. حاصل محاسبات فوق داده‌هایی است که دارای یک بعد و غیرهمبسته به یکدیگر هستند (Smith, 2002).

پس از محاسبه شاخص ترکیبی خشکسالی براساس روش آنالیز مؤلفه‌های اصلی، به مدل‌سازی و پیش‌بینی این شاخص توسط روش‌های یادگیری ماشین و یادگیری عمیق پرداخته شد.

### درخت تصمیم (CART)

CART (Breiman et al., 1984) یک الگوریتم ساخت درخت تصمیم است که توسط (Breiman et al., 1984) ارائه شد. این روش به دلیل ویژگی‌هایی از قبیل استقلال از پارامترها، اجرای آسان و سرعت بالا در بسیاری از مطالعات سنجش از دور شامل طبقه‌بندی و پیش‌بینی استفاده شده‌است (Hu & Dong, 2018; Shao & Lunetta, 2012). برای اولین بار اصطلاح درخت تصمیم را به کار برد و بعد از آن این روش به صورت گسترده در حوزه‌های مختلف علوم به کار برده شد. درخت‌های تصمیم ابزاری قدرتمند و رایج برای طبقه‌بندی و پیش‌بینی می‌باشند. درخت تصمیم روشی است که با استفاده از الگوریتم‌های خاص، داده‌ها را به شکل درخت در کلاس‌ها و دسته‌های مجزا طبقه بندی می‌کند. روش درخت تصمیم، یک مدل تخمینی و ارزیابی و یکی از پرکاربردترین ابزارها و روش‌ها برای طبقه‌بندی و خوشه‌بندی داده‌ها در کاربردهای مختلف داده‌کاوی می‌باشد (Sattari et al., 2012). هدف از این روش، ایجاد یک مدل برای پیش‌بینی عددی متغیر هدف با استفاده از متغیرهای ورودی براساس دسته‌بندی‌های مختلفی است که ارائه می‌دهد.

### ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یکی از روش‌های یادگیری است که در سال ۱۹۹۲ میلادی توسط بوسر و همکاران بر پایه تئوری یادگیری آماری ارائه شد (Boser et al., 1992). آن‌ها طی سال‌های بعد تئوری ابر صفحه بهینه را به عنوان طبقه‌بندی کننده خطی ارائه داده و طبقه‌بندی کننده‌های غیرخطی را به کمک توابع کرنل معرفی نمودند. اصول اساسی آن‌چه که امروز به عنوان ماشین بردار پشتیبان شناخته می‌شود نتایج کارهای بوسر و همکاران است و در نهایت گسترش ماشین بردار پشتیبان براساس رگرسیون نیز در سال ۱۹۹۵ توسط وپنیک به نتیجه رسید (Vapnik, 1995). ماشین بردار پشتیبان مبتنی بر کمینه کردن ساختاری ریسک می‌باشد که از نظریه آموزش آماری گرفته شده‌است.



باشند.

مقدار اولیه این توالی  $x(x_1)$  در اولین واحد LSTM اجرا می‌شود و اولین لایه پنهان  $h_1$  و سلول به روز شده  $c_1$  نتیجه می‌دهد. در گام زمانی  $T$ ، ورودی LSTM  $(c_{t-1}, h_{t-1})$  می‌باشد که خروجی  $h_t$  و سلول به روز شده  $c_t$  می‌باشد (Hochreiter & Schmidhuber, 1997).

شکل ۴ معماری و جزئیات روش LSTM را نشان می‌دهد.

بنابراین در LSTM لایه پنهان  $h_t$  توسط معادلات ۱۱ تا ۱۶ محاسبه خواهد شد.

$$i_t = \sigma(W_i X_t + U_i h_{t-1} + b_i) \quad (11)$$

$$f_t = \sigma(W_f X_t + U_f h_{t-1} + b_f) \quad (12)$$

$$O_t = \sigma(W_o X_t + U_o h_{t-1} + b_o) \quad (13)$$

$$\tilde{C}_t = \tanh(W_c X_t + U_c h_{t-1} + b_c) \quad (14)$$


$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (15)$$

$$h_t = \tanh(C_t) * O_t \quad (16)$$


خاطر سپردن اطلاعات برای طولانی مدت روشی خاص می‌باشد که از چهار لایه تعاملی ضروری که روش‌های ارتباطی مختلفی با یکدیگر دارند تشکیل شده است. همچنین این روش از یک بلوک حافظه تشکیل شده است. که این بلوک‌ها سلول گفته می‌شود. به طوری که اطلاعات در یک سلول ذخیره شده و توسط دروازه‌های کنترل به سلول‌های دیگر منتقل می‌شود. با کمک این دروازه‌ها تجزیه و تحلیل اطلاعات به سادگی و با دقت انجام می‌شود. واحدهای LSTM یا بلوک‌ها بخشی از شبکه عصبی تکرار شونده هستند. شبکه عصبی تکرار شونده برای استفاده از فرایندهای حافظه مصنوعی که به این الگوریتم‌های هوش مصنوعی برای شبیه‌سازی اندیشه انسان کمک می‌کنند می‌باشد.

بنابراین مزیت استفاده از LSTM این است که قادر است فرایندهای یادگیری متوالی نظارت‌شده را اجرا کند. همانطور که در شکل ۳ مشاهده می‌شود.

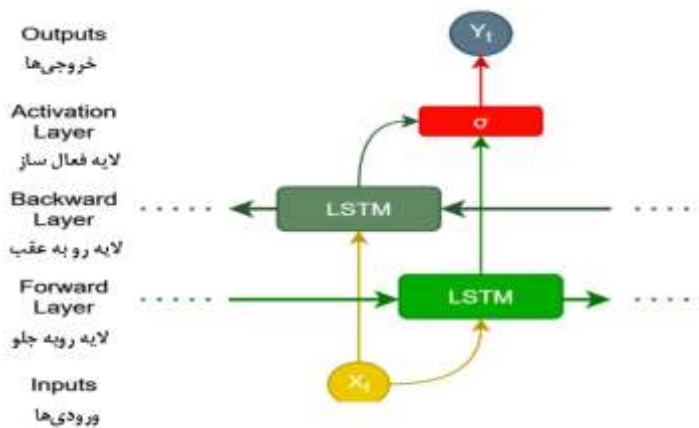
که داده‌های  $X=(x_1, x_2, x_3, \dots, x_n)$  به عنوان داده‌های ورودی برای ارزیابی، خروجی  $H=(h_1, h_2, \dots, h_3)$  و سلول‌ها  $C=(c_1, c_2, \dots, c_n)$  می‌باشد.



شکل ۳- روش LSTM (Arslan & Sekertekin, 2019)  
Figure 3- LSTM method (Arslan & Sekertekin, 2019)



شکل ۴- معماری روش LSTM (Crisóstomo de Castro Filho et al., 2020)  
Figure 4- LSTM method architecture (Crisóstomo de Castro Filho et al., 2020)



شکل ۵- معماری روش BiLSTM (Crisóstomo de Castro Filho *et al.*, 2020)  
Figure 5- BiLSTM method architecture (Crisóstomo de Castro Filho *et al.*, 2020)

که  $CDI^o$  مقادیر اصلی شاخص ترکیبی خشک سالی و  $CDI^r$  مقادیر بدست آمده از مدل‌ها می‌باشد  $CDI^o$  و  $CDI^r$  مقادیر متوسط داده‌های اصلی و داده‌های ساخته شده توسط مدل می‌باشد. در بررسی نكویی برازش مدل‌ها مدلی که RMSE (میانگین جذر مربعات خطا) کمتر و R (همبستگی) و NSE (ضریب ناش ساتکلیف) بیشتری داشته باشند، مدل بهتری خواهد بود.

در این مطالعه از نمودارهای کورلوگرام، دیاگرام تیلور و نمودار ویولونی جهت ارزیابی بصری عملکرد مدل‌ها استفاده گردید. نمودار کورلوگرام یا ماتریس همبستگی به شکل یک ماتریس است که متغیرها در سطر و ستون آن تکرار شده‌اند. قطر اصلی این ماتریس شامل هیستوگرام‌هایی برای بررسی توزیع آماری متغیرها و سایر درایه‌های آن شامل نمودارهای پراکنندگی برای بررسی رابطه بین متغیرها هستند.

نمودار ویولونی ترکیبی از نمودار جعبه‌ای و نمودار چگالی می‌باشد که اوج‌ها و توزیع داده‌ها را نشان می‌دهد. عرض هر منحنی مربوط به فرکانس تقریبی نقاط داده در هر منطقه است. بنابراین، نقطه سفید در وسط نشانگر مقدار میانه و نوار سیاه ضخیم در وسط، محدوده بین ذره‌های را نشان می‌دهد. خط سیاه نازک که از نوار سیاه گسترش می‌یابد، حداکثر و حداقل مقادیر را در داده نشان می‌دهد. از نمودارهای ویولون برای مقایسه توزیع بین چند گروه، در مدل‌های پیش‌بینی استفاده می‌شود (Hintz & Nelson, 1998).

دیاگرام تیلور نموداری است که ارزیابی مقایسه‌ای بین چندین مدل را آسان می‌کند. در این نمودار از ضریب همبستگی پیرسون، میانگین مربعات خطا و انحراف معیار برای اندازه‌گیری میزان تطابق بین رفتار داده‌های مدل شده و مشاهده شده استفاده می‌شود (Taylor, 2001).

که  $x_t$  به عنوان بردار ورودی،  $u_i$  و  $w_i$  پارامترهای آموزش و سیگما تابع فعال‌سازی می‌باشد.  $C_t$  و  $h_t$  به ترتیب خروجی سلول و خروجی لایه می‌باشند.

#### مدل BiLSTM

مدل BiLSTM یکی دیگر از انواع مدل‌های شبکه عصبی مصنوعی بازگشتی می‌باشد. جزئیات روش در شکل ۵ نشان داده شده است. در واقع این مدل از دو لایه متصل برای پردازش لایه ورودی تشکیل شده است. یک لایه در جهت توالی داده‌ها و لایه دیگر در خلاف جهت توالی لایه‌ها اعمال می‌شود. در نهایت نتایج توسط روش‌های مختلف ادغام با یکدیگر ترکیب می‌شود (Fan *et al.*, 2014).

در این پژوهش، در روش‌های LSTM و BiLSTM اندازه تکرار در هر دنباله سری زمانی ۲۰۰ و از بهینه ساز لحظه‌ای (Adam) برای آموزش شبکه استفاده شد.

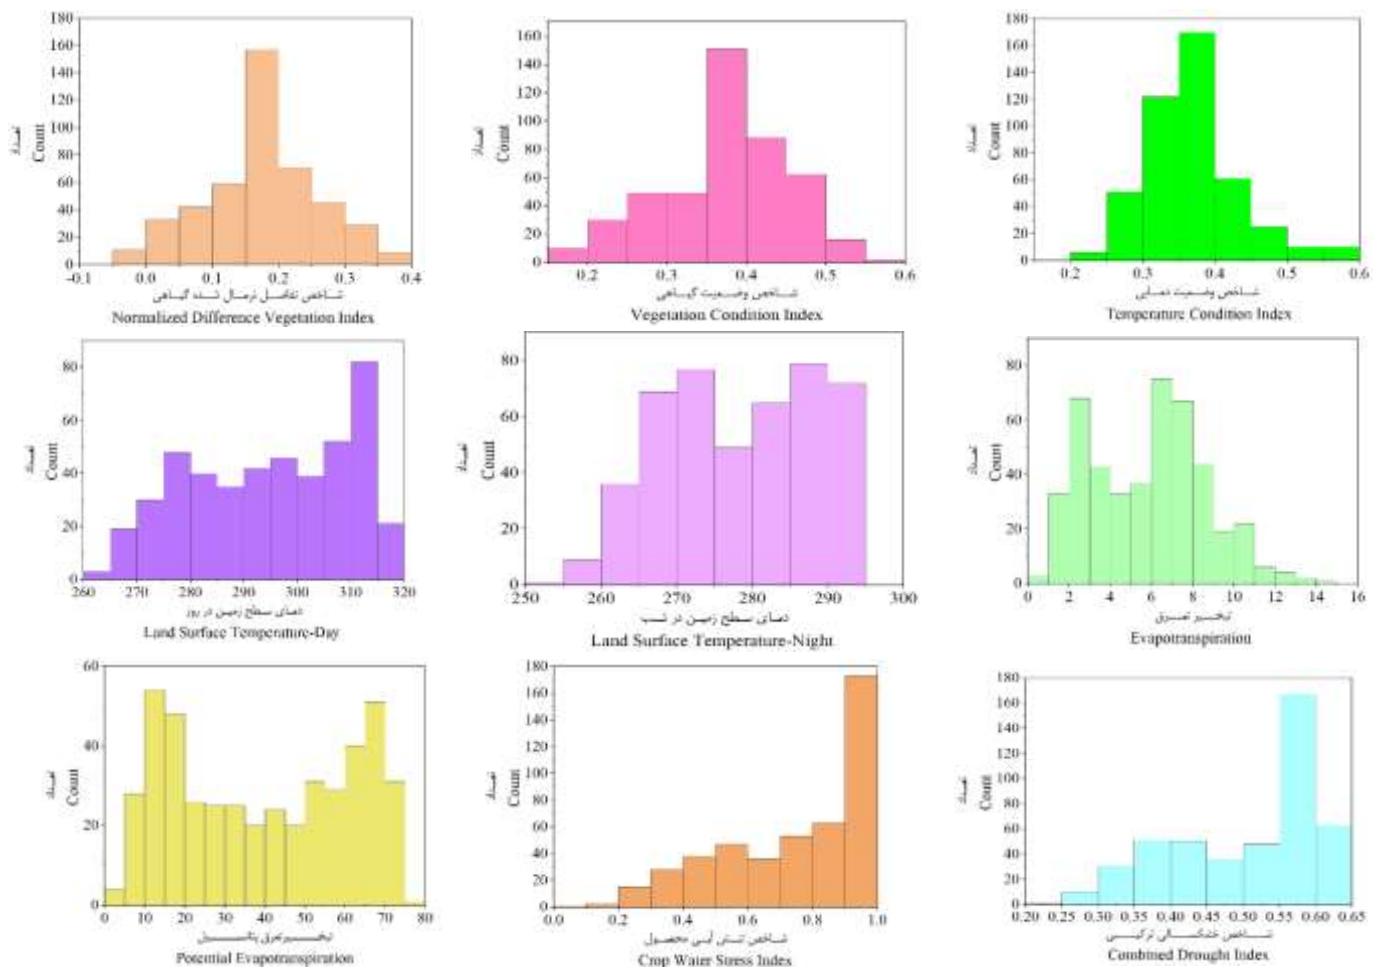
#### ارزیابی عملکرد مدل

به منظور ارزیابی عملکرد مدل‌های ارائه شده از روش‌های نموداری و محاسباتی استفاده شد. در روش‌های محاسباتی از پارامترهای مختلف ضریب همبستگی (Rao, 1973)، میانگین مربعات خطا (Willmott & Matsuura, 2005) و ضریب ناش ساتکلیف (Nash & Sutcliffe, 1970) برای ارزیابی نیکویی برازش استفاده شد.

$$R = \frac{\sum(CDI^o - \overline{CDI^o})(CDI^r - \overline{CDI^r})}{\sqrt{\sum(CDI^o - \overline{CDI^o})^2 \sum(CDI^r - \overline{CDI^r})^2}} \quad (17)$$

$$RMSE = \sqrt{\frac{\sum(CDI^r - CDI^o)^2}{n}} \quad (18)$$

$$NSE = 1 - \frac{\sum(CDI^r - CDI^o)^2}{\sum(CDI^o - \overline{CDI^o})^2} \quad (19)$$



شکل ۶- هیستوگرام داده‌های استفاده شده در منطقه مورد مطالعه  
Figure 6- Histogram of the data used in the study area

تصویر ۶ هیستوگرام داده‌های مورد استفاده در منطقه مورد مطالعه را نشان می‌دهد.

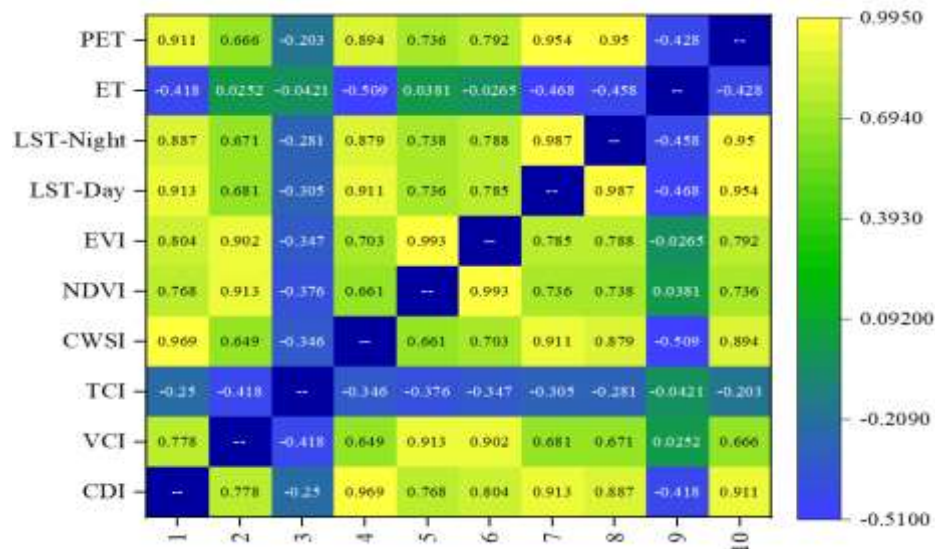
از شکل ۶ مشاهده می‌شود که متغیرهای مورد استفاده در مدل سازی از توزیع نرمال پیروی نمی‌کنند. در روش‌های هوش مصنوعی و داده‌کاوی احتیاجی به نرمال بودن توزیع داده‌ها نمی‌باشد. همانطور که مشاهده می‌شود داده‌های دمای سطح زمین در روز، دمای سطح زمین در شب و شاخص تنش آبی محصول CWSI و شاخص ترکیبی خشکسالی چوله به راست و داده‌های شاخص وضعیت گیاهی، شاخص وضعیت دمایی، تبخیر-تعرق و تبخیر-تعرق پتانسیل چوله به چپ می‌باشند. جهت بررسی دقت تصاویر ماهواره‌ای مورد استفاده ابتدا همبستگی بین داده‌های دمای سطح زمین در روز، دمای سطح زمین در شب با داده‌های دمای حداقل، دمای حداکثر و دمای متوسط روزانه در ۵ ایستگاه هواشناسی محاسبه گردید.

## نتایج و بحث

جهت انجام این پژوهش حوضه آبریز دریاچه ارومیه انتخاب شد. ابتدا تصاویر شاخص تفاضل نرمال شده گیاهی، شاخص بهبود یافته گیاهی، تبخیر-تعرق، تبخیر-تعرق پتانسیل، دمای سطح زمین در روز، دمای سطح زمین در شب برای سال‌های ۲۰۰۱ تا ۲۰۲۰ دانلود شد. پس از پیش پردازش و حذف قسمت‌های دارای ابرناکی سری زمانی مقادیر متوسط حوضه محاسبه و سپس شاخص‌های وضعیت گیاهی (VCI)، وضعیت دمایی (TCI) و شاخص تنش آبی محصول (CWSI) محاسبه و شاخص ترکیبی خشکسالی با استفاده از روش آنالیز مولفه‌های اصلی محاسبه گردید در نهایت مدل‌سازی شاخص ترکیبی خشکسالی بر اساس ترکیب مختلفی از ورودی‌ها تحت عنوان سناریوهای مختلف و با استفاده از روش‌های یادگیری ماشین و یادگیری عمیق انجام شد.

جدول ۳- همبستگی داده‌های ایستگاه‌های هواشناسی با داده‌های سنجش از دور  
Table 3- Correlation of meteorological station data with remote sensing data

| ایستگاه هواشناسی<br>Station | داده<br>Data                       | همبستگی<br>Correlation |                    |                    |
|-----------------------------|------------------------------------|------------------------|--------------------|--------------------|
|                             |                                    | دما حداقل<br>Tmin      | دما حداکثر<br>Tmax | دما متوسط<br>Tmean |
| تبریز<br>Tabriz             | دمای سطح زمین در روز<br>LST day    | 0.919                  | 0.929              | 0.935              |
|                             | دمای سطح زمین در شب<br>LST night   | 0.945                  | 0.956              | 0.960              |
|                             | شاخص تفاضل نرمال شده گیاهی<br>NDVI | 0.672                  | 0.671              | 0.677              |
| ارومیه<br>Urmia             | دمای سطح زمین در روز<br>LST day    | 0.920                  | 0.934              | 0.947              |
|                             | دمای سطح زمین در شب<br>LST night   | 0.932                  | 0.943              | 0.956              |
|                             | شاخص تفاضل نرمال شده گیاهی<br>NDVI | 0.646                  | 0.650              | 0.658              |
| مراغه<br>Maragheh           | دمای سطح زمین در روز<br>LST day    | 0.829                  | 0.922              | 0.918              |
|                             | دمای سطح زمین در شب<br>LST night   | 0.870                  | 0.947              | 0.948              |
|                             | شاخص تفاضل نرمال شده گیاهی<br>NDVI | 0.562                  | 0.592              | 0.597              |
| مهاباد<br>Mahabad           | دمای سطح زمین در روز<br>LST day    | 0.907                  | 0.941              | 0.945              |
|                             | دمای سطح زمین در شب<br>LST night   | 0.920                  | 0.947              | 0.953              |
|                             | شاخص تفاضل نرمال شده گیاهی<br>NDVI | 0.591                  | 0.611              | 0.616              |
| تکاب<br>Tekab               | دمای سطح زمین در روز<br>LST day    | 0.876                  | 0.939              | 0.937              |
|                             | دمای سطح زمین در شب<br>LST night   | 0.907                  | 0.947              | 0.956              |
|                             | شاخص تفاضل نرمال شده گیاهی<br>NDVI | 0.602                  | 0.606              | 0.615              |



شکل ۷- نقشه همبستگی  
Figure 7- Correlation map

جدول ۴- همبستگی شاخص‌ها

Table 4- Correlation

| شاخص‌ها  | CDI    | VCI    | TCI    | CWSI   | NDVI   | LST Day | LSTNight | ET     | PET    |
|--|--------|--------|--------|--------|--------|---------|----------|--------|--------|
| شاخص ترکیبی خشکسالی<br>Combined Drought Index                        | 1      | 0.778  | -0.25  | 0.969  | 0.768  | 0.913   | 0.887    | -0.418 | 0.911  |
| شاخص وضعیت گیاهی<br>Vegetation Condition Index                       | 0.778  | 1      | -0.418 | 0.649  | 0.913  | 0.681   | 0.671    | 0.025  | 0.666  |
| شاخص وضعیت دمایی<br>Temperature Condition Index                      | -0.25  | -0.418 | 1      | -0.346 | -0.376 | -0.305  | -0.281   | -0.042 | -0.203 |
| شاخص تنش آبی محصول<br>Crop Water Stress Index                        | 0.969  | 0.649  | -0.346 | 1      | 0.661  | 0.911   | 0.879    | -0.509 | 0.894  |
| شاخص تفاضل نرمال شده گیاهی<br>Normalized Difference Vegetation Index | 0.768  | 0.913  | -0.376 | 0.661  | 1      | 0.736   | 0.738    | 0.038  | 0.736  |
| دمای سطح زمین در روز<br>Land Surface Temperature-Day                 | 0.913  | 0.681  | -0.305 | 0.911  | 0.736  | 1       | 0.987    | -0.468 | 0.954  |
| دمای سطح زمین در شب<br>Land Surface Temperature-Night                | 0.887  | 0.671  | -0.281 | 0.879  | 0.738  | 0.788   | 1        | -0.458 | 0.950  |
| تبخیر تعرق<br>Evapotranspiration                                     | -0.418 | 0.025  | -0.042 | -0.509 | 0.038  | -0.468  | -0.458   | 1      | -0.428 |
| تبخیر تعرق پتانسیل<br>Potential Evapotranspiration                   | 0.911  | 0.666  | -0.203 | 0.894  | 0.736  | 0.954   | 0.950    | -0.428 | 1      |

سطح زمین در روز و دمای سطح زمین در شب و شاخص وضعیت گیاهی دارد. و از سویی همبستگی منفی و معنی‌داری ۰/۲۵- و ۰/۴۱۸- با شاخص وضعیت دمایی و تبخیر تعرق دارد.

پس از محاسبه همبستگی بین داده‌ها، از ۳۸۶ تصویر، ۷۰ درصد داده‌ها تعداد ۲۷۰ تصویر برای آموزش مدل‌ها و ۳۰ درصد داده‌ها تعداد ۱۱۵ تصویر برای تست استفاده شد. جدول ۵ متغیرهای مختلف برای مدل‌سازی شاخص ترکیبی خشکسالی CDI را تحت عنوان سناریوهای ۱ تا ۶ نشان می‌دهد.

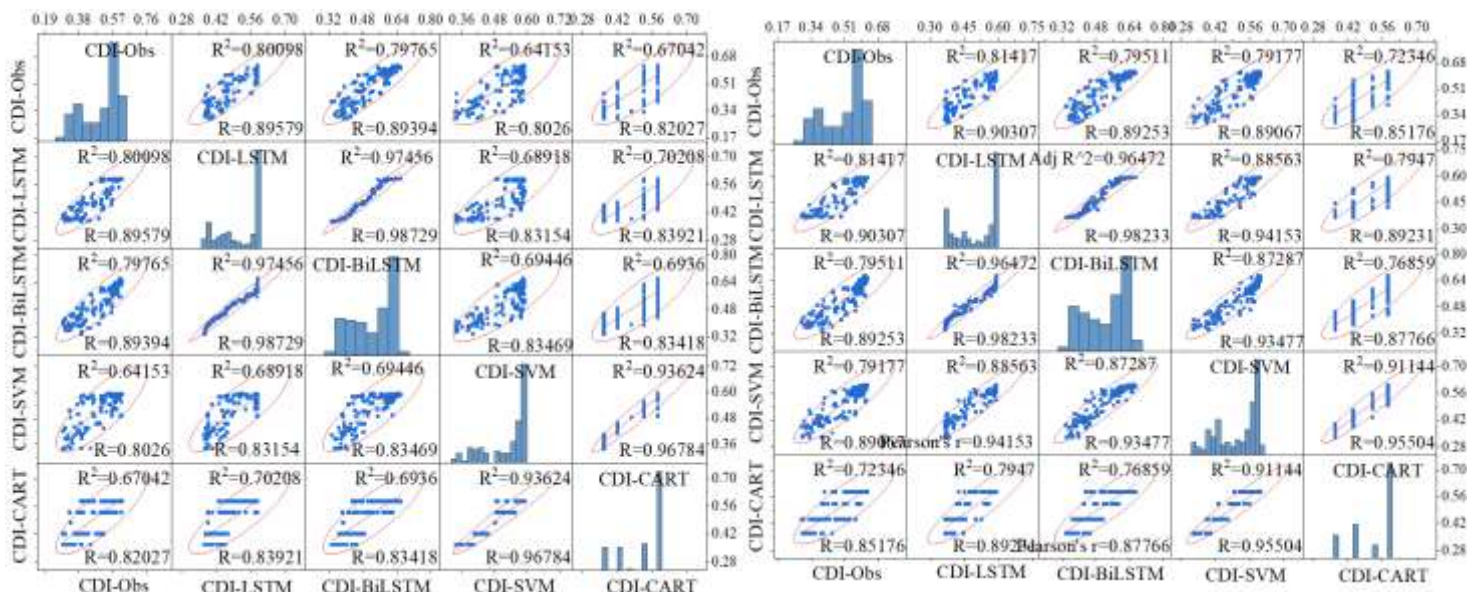
نتایج در جدول ۳ نشان داده شده‌است. همبستگی بالا بین داده‌های روزانه ایستگاه هواشناسی با تصاویر ماهواره‌ای دقت خوب سنجنده مودیس را در این منطقه نشان می‌دهد.

در مرحله بعد همبستگی مقادیر شاخص ترکیبی خشکسالی با دیگر شاخص‌ها محاسبه گردید. در تصویر ۷ و جدول ۴ همبستگی برای مقادیر متوسط شاخص‌ها در منطقه مورد مطالعه نشان داده شده‌است. همانطور که مشاهده می‌شود شاخص ترکیبی خشکسالی CDI همبستگی بسیار بالایی ۰/۹۱۳ و ۰/۸۸۷ و ۰/۷۷۸ با داده‌های دمای

جدول ۵- متغیرهای ورودی جهت مدل‌سازی شاخص CDI

Table 5- Input variables for CDI index modeling

| سناریو<br>Scenario | تعداد<br>متغیرها<br>Number of<br>variables | NDVI | EVI | LST-Day | LST-Night | ET | PET |
|--------------------|--|------|-----|---------|-----------|----|-----|
| 1                  | 1  | ✓    |     |         |           |    |     |
| 2                  | 2  | ✓    | ✓   |         |           |    |     |
| 3                  | 3  | ✓    | ✓   | ✓       |           |    |     |
| 4                  | 4  | ✓    | ✓   | ✓       | ✓         |    |     |
| 5                  | 5  | ✓    | ✓   | ✓       | ✓         | ✓  |     |
| 6                  | 6  | ✓    | ✓   | ✓       | ✓         | ✓  | ✓   |



شکل ۸- ماتریس همبستگی سناریو ۱ (سمت چپ) و سناریو ۲ (سمت راست)

Figure 8- Correlation matrix of scenario 1 (left side) and scenario 2 (right side)

مدل برای پیش‌بینی شاخص ترکیبی خشکسالی می‌باشد. و پس از آن مدل SVM با ضریب همبستگی ۰/۹۴ به‌عنوان بهترین مدل انتخاب شد. مدل‌های LSTM و BiLSTM با ضریب همبستگی ۰/۹ همبستگی کم‌تری نسبت به مدل‌های SVM و CART از خود نشان داده است.

جدول ۶ خلاصه نتایج مدل‌سازی سناریوهای مختلف با روش‌های LSTM، BiLSTM، SVM و DT-CART برای منطقه مورد نظر را نشان می‌دهد.

همانطور که از جدول ۶ نیز مشاهده می‌شود تمامی مدل‌ها با دقت قابل‌قبولی شاخص ترکیبی خشکسالی را مدل نموده‌اند ولی از میان تمامی روش‌ها مدل SVM و CART در سناریوهای ۵ و ۶ با مقدار جذر میانگین مربعات خطا کمتر و ضریب همبستگی بیشتر مدل توانمندتری در پیش‌بینی سری‌زمانی شاخص ترکیبی خشکسالی می‌باشند.

همچنین از بین تمامی سناریوهای سناریو ۶ با مقدار خطای کمتر (۰/۰۲۹) و همبستگی بیشتر (۰/۹۶) و ضریب ناش ساتکلیف بیشتر (۰/۹۲) موثرترین متغیرهای ورودی جهت پیش‌بینی مقادیر CDI را دارا می‌باشند.

در شکل‌های ۱۱ تا ۱۳ برازش سری‌زمانی شاخص ترکیبی خشکسالی CDI برای داده‌های صحت‌سنجی توسط مدل‌های مختلف و سناریوهای مختلف در محدوده مورد مطالعه نشان داده شده است. با بررسی تصاویر ۱۱ تا ۱۳ مشاهده می‌شود که تمامی روش‌ها دقت مناسبی در مدل‌سازی و پیش‌بینی سری‌زمانی شاخص ترکیبی خشکسالی دارند.

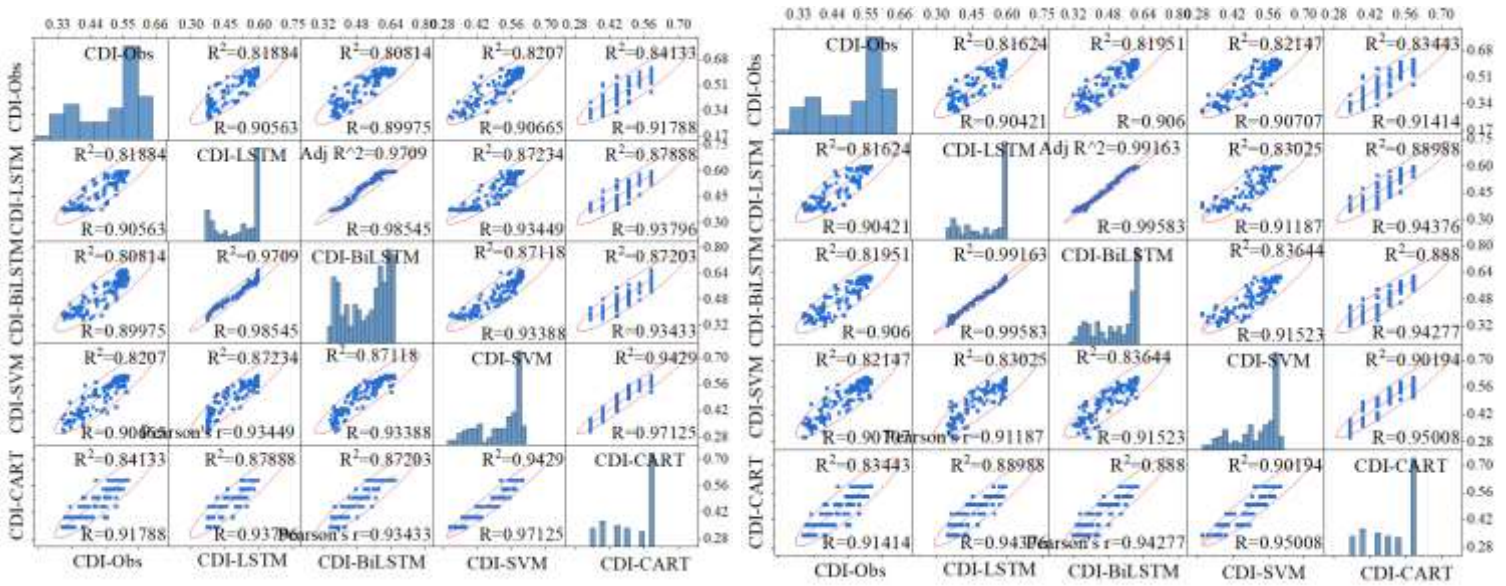
سپس مدل‌سازی سناریوهای روش‌های SVM، DT-CART، LSTM و BiLSTM انجام شد که نتایج آن در شکل‌های ۸ تا ۱۰ نشان داده شده است.

در تصویر ۸ ماتریس همبستگی مدل‌های مختلف در سناریوهای ۱ و ۲ آورده شده است.

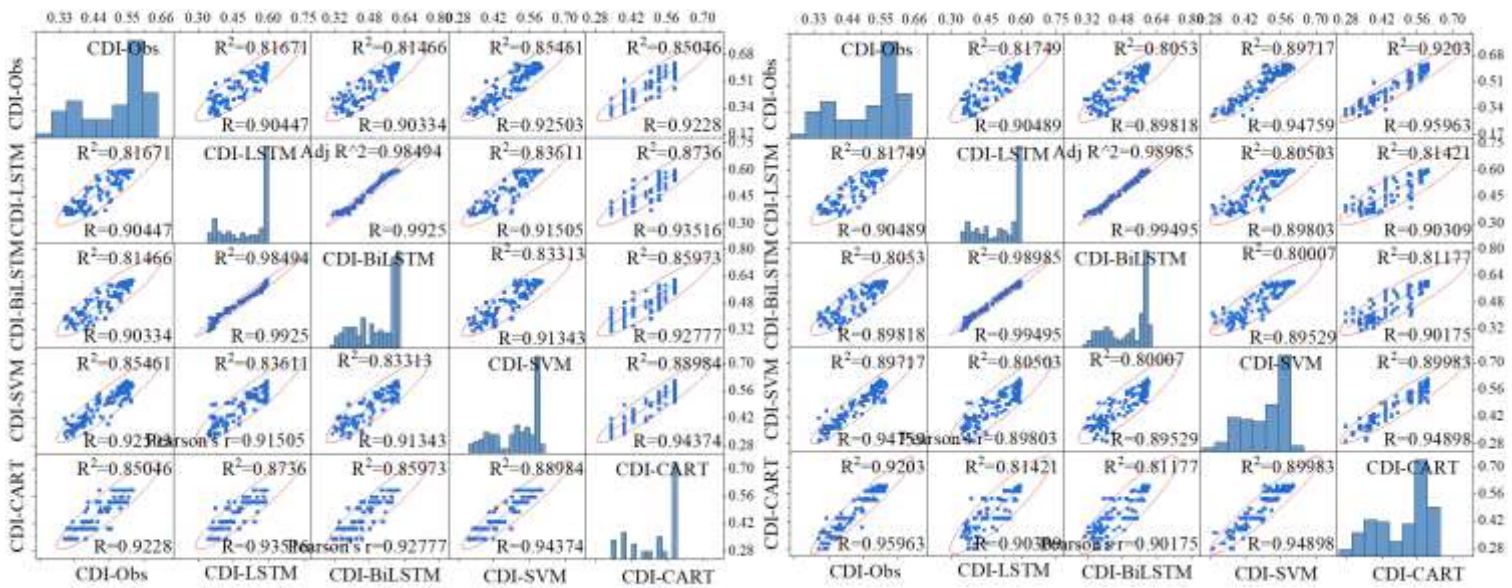
همانطور که در شکل ۸ مشخص می‌شود در سناریو ۱ که تنها داده ورودی به مدل‌سازی شاخص تفاضل نرمال شده گیاهی NDVI می‌باشد، مدل‌ها همبستگی کم‌تری نسبت به سناریو ۲ که داده‌های شاخص بهبود یافته گیاهی نیز به‌عنوان ورودی به مدل در نظر گرفته شده‌اند، دارند. در سناریو ۱ مدل‌های LSTM و BiLSTM با همبستگی ۰/۸۹ بهترین مدل‌ها انتخاب گردیدند. در سناریو ۲ مدل LSTM با ضریب همبستگی ۰/۹ بهترین برازش را برای پیش‌بینی داده‌های CDI با متغیر ورودی شاخص تفاضل نرمال شده پوشش گیاهی و شاخص بهبود یافته گیاهی از خود نشان داد.

باتوجه به شکل ۹ در سناریو ۳ با اضافه شدن متغیر ورودی دمای سطح زمین در روز مدل‌های LSTM و SVM با ضریب همبستگی ۰/۹۱ و مدل CART با ضریب همبستگی ۰/۹۲ پیش‌بینی شاخص ترکیبی خشکسالی را انجام داده‌اند ولی در سناریو ۴ با اضافه شدن متغیر دمای سطح زمین در شب به ورودی‌های مدل دقت برازش‌ها تغییر قابل ملاحظه‌ای نداشته است.

باتوجه به شکل ۱۰ در سناریو ۵ با اضافه شدن تبخیر-تعرق به عنوان متغیر ورودی مدل‌های SVM و CART با ضریب همبستگی ۰/۹۲ با دقت تقریباً یکسانی پیش‌بینی شاخص ترکیبی خشکسالی را انجام داده‌اند. سناریو ۶ با اضافه شدن متغیر تبخیر-تعرق پتانسیل به داده‌های ورودی مشاهده شد که مدل CART با ضریب ۰/۹۶ بهترین



شکل ۹- ماتریس همبستگی سناریو ۳ (سمت چپ) و سناریو ۴ (سمت راست)  
 Figure 9- Correlation matrix of scenario 3 (left) and scenario 4 (right)




شکل ۱۰- ماتریس همبستگی سناریو ۵ (سمت چپ) و سناریو ۶ (سمت راست)  
 Figure 10- Correlation matrix of scenario 5 (left) and scenario 6 (right)

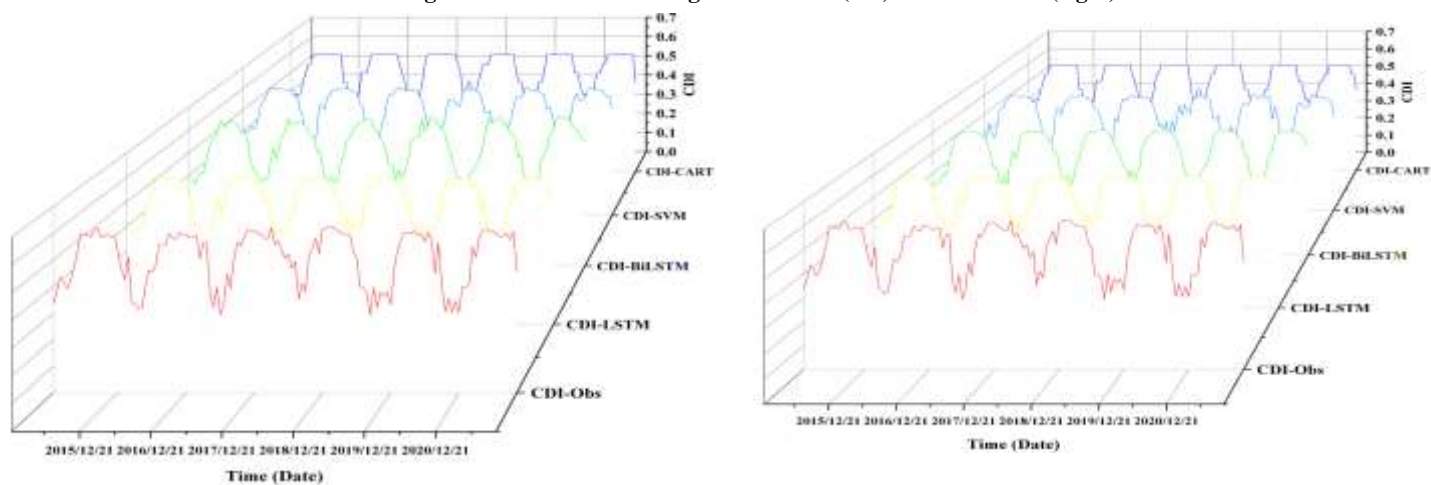
جدول ۶- خلاصه نتایج مدل سازی شاخص CDI با استفاده از مدل‌های مختلف

Table 6- summarizes the results of CDI index modeling using different models


| سناریو<br>Scenario | CART |      |       | SVM  |      |       | BiLSTM |      |       | LSTM |      |       |
|--------------------|------|------|-------|------|------|-------|--------|------|-------|------|------|-------|
|                    | NSE  | R    | RMSE  | NSE  | R    | RMSE  | NSE    | R    | RMSE  | NSE  | R    | RMSE  |
| 1                  | 0.64 | 0.82 | 0.061 | 0.61 | 0.80 | 0.063 | 0.56   | 0.85 | 0.105 | 0.83 | 0.89 | 0.045 |
| 2                  | 0.71 | 0.85 | 0.055 | 0.79 | 0.89 | 0.047 | 0.75   | 0.89 | 0.050 | 0.81 | 0.90 | 0.044 |
| 3                  | 0.84 | 0.92 | 0.041 | 0.81 | 0.91 | 0.044 | 0.76   | 0.90 | 0.050 | 0.82 | 0.91 | 0.044 |
| 4                  | 0.83 | 0.91 | 0.042 | 0.81 | 0.91 | 0.044 | 0.81   | 0.91 | 0.044 | 0.82 | 0.90 | 0.044 |
| 5                  | 0.85 | 0.92 | 0.040 | 0.85 | 0.92 | 0.040 | 0.81   | 0.90 | 0.044 | 0.81 | 0.90 | 0.044 |
| 6                  | 0.92 | 0.96 | 0.029 | 0.88 | 0.94 | 0.034 | 0.80   | 0.90 | 0.045 | 0.81 | 0.90 | 0.044 |



شکل ۱۱- برازش سری زمانی سناریو ۱ (سمت چپ) و سناریو ۲ (سمت راست)  
 Figure 11- Time series fitting of scenario 1 (left) and scenario 2 (right)




شکل ۱۲- برازش سری زمانی سناریو ۳ (سمت چپ) و سناریو ۴ (سمت راست)  
 Figure 12 Time series fitting of scenario 3 (left) and scenario 4 (right)



شکل ۱۳- برازش سری زمانی سناریو ۵ (سمت چپ) و سناریو ۶ (سمت راست)  
 Figure 13- Time series fitting of scenario 5 (left) and scenario 6 (right)

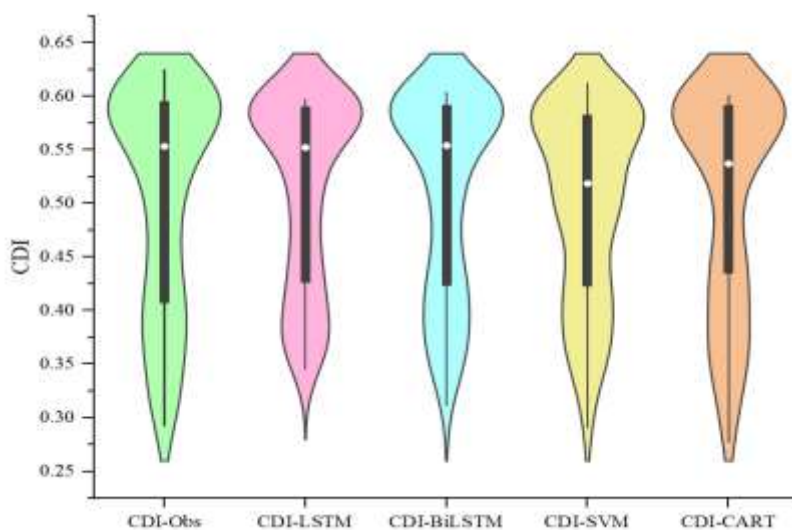




شکل ۱۴- دیاگرام تیلور سناریو ۶ (سمت چپ) و سناریو ۱ (سمت راست)  
 Figure 14- Taylor diagram of scenario 6 (left) and scenario 1 (right)

بالایی در پیش‌بینی خشکسالی را داشته‌اند. ژو و همکاران (Zhu et al., 2021) نشان داد که روش SVM با توابع کرنل RBF روش توانمند در پیش‌بینی رطوبت خاک و خشکسالی منطقه می‌باشند. در مطالعه‌ای دیگر (Rhif et al., 2020) عملکرد خوب روش LSTM و BiLSTM را در سری زمانی شاخص گیاهی نشان داد. کماسی و شرقی (Komasi & Sharghi, 2017) به پیش‌بینی خشکسالی حوضه آبریز دریاچه ارومیه با استفاده از مدل ترکیبی ماشین بردار پشتیبان موجکی و شاخص SPI پرداختند و نشان دادند که مدل ترکیبی ماشین بردار پشتیبان موجکی در مقایسه با مدل منفرد ماشین بردار پشتیبان توانایی بسیاری در پیش‌بینی سری زمانی شاخص SPI دارد. کریمزادگان و همکاران (Karimzadegan et al., 2018) به بررسی کارایی مدل‌های شبکه بیزین و حداقل مربعات ماشین بردار پشتیبان در پیش‌بینی تراز سطح دریاچه ارومیه با استفاده از پارامترهای تبخیر، بارش، دما، باد، میانگین رطوبت هوا، رواناب ورودی و تراز سطح آب دریاچه پرداختند و عملکرد بهتر مدل حداقل مربعات ماشین بردار پشتیبان در مقایسه با شبکه بیزین را نشان دادند. در شکل ۱۵ نمودار ویولونی داده‌ها برای بهترین سناریو (سناریو ۶) نشان داده شده‌است.

جهت بررسی بهتر عملکرد مدل‌ها از دیاگرام تیلور استفاده شد. با مشاهده مقادیر بدست‌آمده در جدول ۶ سناریو ۱ به‌عنوان بدترین و سناریو ۶ بهترین سناریو انتخاب شدند و در نهایت دیاگرام تیلور برای سناریو ۱ و ۶ در شکل ۱۴ نشان داده شده‌است. همانطور که ملاحظه می‌شود در سناریو ۶، مدل‌های SVM و CART عملکرد بسیار نزدیک به هم دارند و نزدیک‌ترین مدل به داده‌های مشاهداتی می‌باشد. ولی مدل‌های BiLSTM و LSTM بر خلاف انتظار عملکرد نسبتاً ضعیف‌تری در مقایسه با روش‌های یادگیری ماشین در سناریوهای مختلف از خود نشان داده‌اند. در این مطالعه از روش‌های هوش مصنوعی برای پیش‌بینی شاخص ترکیبی خشکسالی استفاده شد. همانطور که مشاهده شد متغیرهایی مانند متغیرهای دمای روز و دمای شب سطح زمین، تبخیر-تعرق و تبخیر-تعرق پتانسیل عملکرد خوبی بر بهبود پیش‌بینی شاخص ترکیبی خشکسالی داشتند. به‌طور کلی تمامی روش‌ها با دقت مناسبی شاخص ترکیبی خشکسالی را مدل کرده‌اند نتایج بدست‌آمده با نتایج بدست‌آمده توسط پژوهشگران دیگر همخوانی داشت (Reddy & Prasad, 2018). شریفی پور و همکاران (Sharifi pour et al., 2021)، به پیش‌بینی خشکسالی با استفاده از شاخص SPI و چهار روش هوش مصنوعی شامل یادگیری عمیق، الگوریتم K نزدیک‌ترین همسایه، ماشین بردار پشتیبان چند طبقه و درخت تصمیم پرداختند. و نشان دادند که تمامی شبکه‌ها توانایی



شکل ۱۵- نمودار ویولونی مدل‌ها (سناریو ۶)  
Fig 15- Violin diagram of models (scenario 6)

این پژوهش نشان داد که ترکیب داده‌های ماهواره‌ای مختلف شامل داده‌های دمای سطح زمین در روز و در شب، تبخیر-تعرق، تبخیر-تعرق پتانسیل و شاخص تفاضل نرمال شده گیاهی به عنوان ورودی مدل‌های یادگیری عمیق و یادگیری ماشین می‌تواند باعث افزایش قابل توجه دقت پیش‌بینی شاخص ترکیبی خشکسالی CDI گردد. در این پژوهش ترکیب‌های مختلفی از متغیرهای ورودی مستخرج از محصولات تصاویر ماهواره‌ای در قالب ۶ سناریوی مستقل جهت پیش‌بینی شاخص ترکیبی خشکسالی مورد ارزیابی قرار گرفت. بررسی ترکیب‌های مختلف متغیرهای ورودی به مدل‌ها نشان داد افزودن متغیرهای دمای سطح زمین در روز و شب به سناریوی اول و دوم (که تنها شامل شاخص‌های گیاهی بود)، باعث افزایش دقت (از همبستگی ۰/۸۲ به ۰/۹۰) پیش‌بینی شاخص ترکیبی خشکسالی در همه روش‌ها به ویژه مدل‌های SVM و CART می‌گردد. بنابراین مشخص گردید که در حوضه آبریز دریاچه ارومیه متغیر دمای سطح زمین در روز و شب متغیرهای موثری در پیش‌بینی شاخص ترکیبی خشکسالی می‌باشند. با بررسی پارامترهای ارزیابی شامل ضریب همبستگی، ضریب ناش ساتکلیف و جذر میانگین مربعات خطا مشخص شد که هر چهار روش با دقت و خطای قابل قبولی می‌توانند، شاخص ترکیبی خشکسالی را تخمین بزنند. به طوری که از میان همه روش‌ها روش CART عملکرد بهتری (همبستگی ۰/۹۶ و جذر میانگین مربعات خطا ۰/۰۲۹) نسبت به سایر روش‌ها برای پیش‌بینی سری زمانی شاخص ترکیبی خشکسالی CDI داشت.

با بررسی نتایج مشخص شد که روش SVM نیز با دقت قابل قبولی (همبستگی ۰/۹۴ و جذر میانگین مربعات خطا ۰/۰۳۴) توانسته است مدل‌سازی شاخص ترکیبی خشکسالی را انجام دهد. اما برخلاف انتظار دو روش یادگیری عمیق با دقت کمتری (همبستگی ۰/۹۰)

باتوجه به نمودار ویولونی داده‌ها (شکل ۱۵)، مشاهده می‌شود که مدل‌ها کم و بیش دارای توزیع یکسان و مشابه با داده‌های مشاهداتی شاخص ترکیبی خشکسالی می‌باشند. همانطور که ملاحظه می‌شود حداقل مقدار بدست‌آمده از تمامی مدل‌ها حدود ۰/۲۵ است که با داده‌های مشاهداتی منطبق می‌باشد. از سویی میانه داده‌ها در مدل‌های LSTM، BiLSTM و CART نیز بسیار نزدیک به میانه داده‌های مشاهداتی می‌باشد. در صورتی که میانه داده‌ها در روش SVM مقدار کمتری را نشان می‌دهد.

## نتیجه‌گیری

خشکسالی یکی از گسترده‌ترین بلایای طبیعی در جهان می‌باشد که منجر به تهدیدهای جدی برای امنیت آب و غذا و به طور بالقوه موجب کاهش عملکرد محصول می‌شود. یکی از عوامل خشکسالی کاهش عملکرد محصول می‌باشد که به مرحله رشد گیاه در زمان وقوع خشکسالی بستگی دارد. بنابراین خشکسالی می‌تواند اثرات مختلفی در مراحل مختلف رشد از خود باقی بگذارد. برای نظارت و ارزیابی عملکرد محصول، بدست‌آوردن سری زمانی دقیق خشکسالی بسیار ضروری می‌باشد. حوضه آبریز دریاچه ارومیه به علت شرایط اقلیمی و اجتماعی مناسب، بخش وسیعی از فعالیت‌های اقتصادی در آن به کشاورزی اختصاص یافته‌است. از این رو در این مطالعه به بررسی روش‌های مختلف یادگیری ماشین و یادگیری عمیق مانند SVM، DT، CART، LSTM و BiLSTM برای پیش‌بینی شاخص ترکیبی خشکسالی CDI با استفاده از تصاویر ماهواره MODIS پرداخته شد که تاکنون در منطقه مورد مطالعه انجام نشده‌است.

خشکسالی به‌خصوص در حوضه‌های فاقد آمار استفاده نمود. درنهایت استفاده از سنجنده‌هایی با قدرت تفکیک بالا از جمله Sentinel می‌تواند در بهبود نتایج پیش‌بینی شاخص ترکیبی خشکسالی و ارزیابی دقیق‌تر خشکسالی کشاورزی و مدیریت مؤثر و بهنگام خشکی مفید باشد.

نسبت به روش‌های یادگیری ماشین توانسته‌اند شاخص ترکیبی خشکسالی را مدل‌سازی نمایند. به‌طور کلی با بررسی نتایج مشخص شد که با روش ارائه شده در این پژوهش می‌توان با دقت مناسبی سری‌زمانی شاخص ترکیبی خشکسالی CDI را پیش‌بینی نمود و به ارزیابی مدل‌های پیش‌بینی خشکسالی در دوره‌های مختلف رشد گیاه پرداخت و از نتایج آن برای مدیریت و سیاست‌گذاری‌های منطقه‌ای

## منابع

1. AghaKouchak, A., Farahmand, A., Melton, F.S., Teixeira, J., Anderson, M.C., Wardlow, B.D., & Hain, C. R. (2015). Remote sensing of drought: Progress, challenges and opportunities. *Reviews of Geophysics*, 53(2), 452-480. <https://doi.org/10.1002/2014RG000456>
2. Arslan, N., & Sekertekin, A. (2019). Application of long short-term memory neural network model for the reconstruction of MODIS Land Surface Temperature images. *Journal of Atmospheric and Solar-Terrestrial Physics*, 194, 105100. <https://doi.org/10.1016/j.jastp.2019.105100>
3. Babajafari, H., Paimazd, Sh., Moghadasi, M., & Hosseiniwardanjani, M. (2022). Assessment monitoring spatio-temporal of drought lake Urmia basin using ETDI remote sensing index and SPI ground index. *Journal of Water and Soil Science*, 26(3), 281-302
4. Balti, H., Abbas, A.B., Mellouli, N., Farah, I.R., Sang, Y., & Lamolle, M. (2020). A review of drought monitoring with big data: Issues, methods, challenges and research directions. *Ecological Informatics*, 60, 101136. <https://doi.org/10.1016/j.ecoinf.2020.101136>
5. Boser, B.E., Guyon, I.M., & Vapnik, V.N. (1992). A training algorithm for optimal margin classifiers. Proceedings of the fifth annual workshop on Computational learning theory. <https://doi.org/10.1145/130385.130401>
6. Breiman, L., Friedman, J., Stone, C.J., & Olshen, R.A. (1984). *Classification and regression trees*. CRC press .
7. Crisóstomo de Castro Filho, H., Abílio de Carvalho Júnior, O., Ferreira de Carvalho, O.L., Pozzobon de Bem, P., dos Santos de Moura, R., Olineo de Albuquerque, A., Rosa Silva, C., Guimarães Ferreira, P.H., Fontes Guimarães, R., & Trancoso Gomes, R.A. (2020). Rice crop detection using LSTM, Bi-LSTM, and machine learning models from Sentinel-1 time series. *Remote Sensing*, 12(16), 2655. <https://doi.org/10.3390/rs12162655>
8. Cunha, R.L., Silva, B., & Netto, M.A. (2018). A scalable machine learning system for pre-season agriculture yield forecast. 2018 IEEE 14<sup>th</sup> International Conference on e-Science (e-Science), <https://doi.org/10.1109/eScience.2018.00131>
9. Dang, C., Liu, Y., Yue, H., Qian, J., & Zhu, R. (2020). Autumn crop yield prediction using data-driven approaches: support vector machines, random forest, and deep neural network methods. *Canadian Journal of Remote Sensing*, 1-20. <https://doi.org/10.1080/07038992.2020.1833186>
10. Elbeltagi, A., Kumari, N., Dharpure, J.K., Mokhtar, A., Alsafadi, K., Kumar, M., Mehdinejadani, B., Ramezani Etedali, H., Brouziyne, Y., & Towfiqul Islam, A.R.M. (2021). Prediction of combined terrestrial evapotranspiration index (CTEI) over large river basin based on machine learning approaches. *Water*, 13(4), 547. <https://doi.org/10.3390/w13040547>
11. Fan, Y., Qian, Y., Xie, F.-L., & Soong, F.K. (2014). TTS synthesis with bidirectional LSTM based recurrent neural networks. Fifteenth annual conference of the international speech communication association.
12. Guzmán, S.M., Paz, J.O., Tagert, M.L.M., Mercer, A.E., & Pote, J.W. (2018). An integrated SVR and crop model to estimate the impacts of irrigation on daily groundwater levels. *Agricultural Systems*, 159, 248-259. <https://doi.org/10.1016/j.agry.2017.01.017>
13. Heim Jr, R.R., & Brewer, M.J. (2012). The global drought monitor portal: The foundation for a global drought information system. *Earth Interactions*, 16(15), 1-28. <https://doi.org/10.1175/2012EI000446.1>
14. Hintz, J.L., & Nelson, R.D. (1998). Violin plots: A box plot-density trace synergism. *The American Statistician*, 52(2), 181-184 .
15. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
16. Hu, Y., & Dong, Y. (2018). An automatic approach for land-change detection and land updates based on integrated NDVI timing analysis and the CVAPS method with GEE support. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 347-359. <https://doi.org/10.1016/j.isprsjprs.2018.10.008>
17. Jackson, R.D., Kustas, W.P., & Choudhury, B.J. (1988). A reexamination of the crop water stress index. *Irrigation Science*, 9, 309-317.
18. Karimzadegan, S., Behmanesh, J., & Rezaie, H. (2018). Application of bayesian network and LS-SVM methods in predicting water surface level of Urmia Lake. *Journal of Water and Soil Conservation*, 25(3), 2018.

19. Kazempour Choursi, S., Erfanian, M., & Ebadi Nehari, Z. (2019). Evaluation of MODIS and TRMM satellite data for drought monitoring in the Urmia lake basin. *Journal of Geography and Environmental Planning*, 30(2), 74.
20. Kogan, F.N. (1995). Droughts of the late 1980s in the United States as derived from NOAA polar-orbiting satellite data. *Bulletin of the American Meteorological Society*, 76(5), 655-668. <https://doi.org/10.1175/1520-0477>
21. Komasi, M., & Sharghi, S. (2020). Drought forecasting using wavelet-support vector machine and standardized precipitation index (Case study: Urmia Lake-Iran). *Journal of Environmental Science and Technology*, 22(7), 83-101.
22. Khosravi, I., Akhundzadeh, M., & Khoshgovtar, M. (2015). Modeling and forecasting the time series of drought indicators with machine learning methods in order to manage risks (case study: Eastern region of Isfahan). *Environmental Risk Management*, 2(1), 51-65. (In Persian with English abstract)
23. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
24. Li, X., Yuan, W., & Dong, W. (2021). A machine learning method for predicting vegetation indices in China. *Remote Sensing*, 13(6), 1147. <https://doi.org/10.3390/rs13061147>
25. Maroufpoor, S., Maroufpoor, E., Bozorg-Haddad, O., Shiri, J., & Yaseen, Z.M. (2019). Soil moisture simulation using hybrid artificial intelligent model: Hybridization of adaptive neuro fuzzy inference system with grey wolf optimizer algorithm. *Journal of Hydrology*, 575, 544-556. <https://doi.org/10.1016/j.jhydrol.2019.05.045>
26. Mohammadi, H., Nasiri Kashani, K., Maleki, S., & Rostami, H. (2018). Identify and prioritize the factors affecting on the drying of Urmia Lake with Integrated Fuzzy DEMATEL; Analytic Network Process (F.D.ANP). *Emergency Management*, 7(1), 13-26.
27. Nash, J.E., & Sutcliffe, J.V. (1970). River flow forecasting through conceptual models part I—A discussion of principles. *Journal of Hydrology*, 10(3), 282-290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
28. Nay, J., Burchfield, E., & Gilligan, J. (2018). A machine-learning approach to forecasting remotely sensed vegetation health. *International Journal of Remote Sensing*, 39(6), 1800-1816. <https://doi.org/10.1080/01431161.2017.1410296>
29. Niasati, Z., Ebadi, H., & Kayani, A. (2021). Estimation of reference evaporation and transpiration using remote sensing data in Hamadan Bahar Plain. *Iran Water Research*, 15(4), 45-58. (In Persian with English abstract)
30. Proadhan, F.A., Zhang, J., Hasan, S.S., Sharma, T.P.P., & Mohana, H.P. (2022). A review of machine learning methods for drought hazard monitoring and forecasting: Current research trends, challenges, and future research directions. *Environmental Modelling & Software*, 149, 105327.
31. Qian, Y., Zhou, W., Yan, J., Li, W., & Han, L. (2015). Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery. *Remote Sensing*, 7(1), 153-168. <https://doi.org/10.3390/rs70100153>
32. Rao, C. (1973). 10.1002/9780470316436, John Wiley and Sons, New York.
33. Rezaei Moghadam, M.H., Valizadehkamran, Kh., Rostamzadeh, H., & Rezaei, A. (2012) Evaluation of the efficiency of MODIS sensor data in estimating drought (Case study: Urmia Lake catchment). *Geography and Environmental Sustainability*, 5: 37-52.
34. Reddy, D.S., & Prasad, P.R.C. (2018). Prediction of vegetation dynamics using NDVI time series data and LSTM. *Modeling Earth Systems and Environment*, 4(1), 409-419.
35. Rhif, M., Abbes, A.B., Martinez, B., & Farah, I.R. (2020). A deep learning approach for forecasting non-stationary big remote sensing time series. *Arabian Journal of Geosciences*, 13(22), 1-11.
36. Sattari, M.T., Apaydin, H., Ozturk, F., & Baykal, N. (2012). Application of a data mining approach to derive operating rules for the Eleviyan irrigation reservoir. *Lake and Reservoir Management*, 28(2), 142-152. <https://doi.org/10.1080/07438141.2012.678927>
37. Sharifipour, L., Ghanei-Bafghi, M., Kosari, M., & Sharifipour, S. (2021). Comparing the efficiency of four artificial intelligence methods in drought prediction. *Scientific Journal System*, 8(3), 139-156. (In Persian with English abstract)
38. Shamloo, N., Sattari, M.T., & Apaydin, H. (2022). Agricultural drought survey using MODIS-based image indices at the regional scale: case study of the Urmia Lake Basin, Iran. *Theoretical and Applied Climatology*, 149(1-2), 39-51.
39. Shen, R., Huang, A., Li, B., & Guo, J. (2019). Construction of a drought monitoring model using deep learning based on multi-source remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, 79, 48-57. <https://doi.org/10.1016/j.jag.2019.03.006>
40. Shao, Y., & Lunetta, R.S. (2012). Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. *ISPRS Journal of Photogrammetry and Remote Sensing*, 70, 78-87. <https://doi.org/10.1016/j.isprsjprs.2012.04.001>
41. Smith, L. (2002). *A Tutorial on Principal Components Analysis*. Page 1-26.
42. Taylor, K.E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*, 106(D7), 7183-7192. <https://doi.org/10.1029/2000JD900719>
43. Tucker, C.J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing*

- of Environment*, 8(2), 127-150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
44. Vapnik, V.N. (1995). The nature of statistical learning. Theory.
45. Willmott, C.J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82. <https://doi.org/10.3354/cr030079>
46. Winkler, K., Gessner, U., & Hochschild, V. (2017). Identifying droughts affecting agriculture in Africa based on remote sensing time series between 2000–2016: rainfall anomalies and vegetation condition in the context of ENSO. *Remote Sensing*, 9(8), 831. <https://doi.org/10.3390/rs9080831>
47. Yin, J., Zhan, X., Hain, C.R., Liu, J., & Anderson, M.C. (2018). A method for objectively integrating soil moisture satellite observations and model simulations toward a blended drought index. *Water Resources Research*, 54(9), 6772-6791. <https://doi.org/10.1029/2017WR021959>
48. Zhu, X.X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F., & Fraundorfer, F. (2017). Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4), 8-36. <https://doi.org/10.1109/MGRS.2017.2762307>