



## Evaluation of machine learning models in predicting drought indicators (Case Study: Ajabshir area)

Mahtab Faramarzpour<sup>1</sup> | Ali Saremi<sup>2\*</sup> | Amir Khosrojerdi<sup>3</sup> | Hossain Babazadeh<sup>4</sup>

1. PhD Student, Water Resources Engineering and Management, Irrigation Department, Faculty of Agricultural Sciences and Food Industry, Islamic Azad University, Central Tehran Branch, Tehran. Email: [mahi.f1990@gmail.com](mailto:mahi.f1990@gmail.com)
2. Corresponding Author, Assistant Professor, Water Resources Engineering and Management, Irrigation Department, Faculty of Agricultural Sciences and Food Industry, Islamic Azad University, Central Tehran Branch, Tehran. Email: [saremi.ptmco@gmail.com](mailto:saremi.ptmco@gmail.com)
3. Assistant Professor, Water Resources Engineering and Management, Department of Water Science and Engineering, Faculty of Agricultural Sciences and Food Industry, Islamic Azad University, Central Tehran Branch, Tehran. Email: [khosrojerdi@srbiau.ac.ir](mailto:khosrojerdi@srbiau.ac.ir)
4. Professor, Water Resources Engineering and Management, Water Science and Engineering, Faculty of Agricultural Sciences and Food Industry, Islamic Azad University, Central Tehran Branch, Tehran. Email: [h\\_babazadeh@srbiau.ac.ir](mailto:h_babazadeh@srbiau.ac.ir)

### ARTICLE INFO

**Article type:**  
Research Article

**Article History:**  
Received May 12, 2023  
Revised June 12, 2023  
Accepted July 13, 2023  
Published online 12 December 2023

**Keywords:**  
*Prediction,*  
*Ajab Shir,*  
*Machine Learning,*  
*SPI,*  
*SDI.*

### ABSTRACT

Drought is one of the destructive phenomena with adverse impacts on water resources and water needs. Machine-learning models are among the helpful tools in time-series prediction that can provide suitable results without the requirements for basic information about a system. In this study, adaptive neuro-fuzzy inference system (ANFIS) and least square support vector regression (LSSVR) models were utilized to predict the standardized precipitation index (SPI) as a meteorological drought indicator and streamflow drought index (SDI) as a hydrological drought indicator for a period (2001-2019). Ajabshir, located in the northwest of Iran, was selected as the study area, where the data of Qaleh Chay meteorological and hydrological stations were used to calculate SPI and SDI, respectively. The precipitation and flow rate data were considered input variables of the machine-learning models in predicting the SPI and SDI, respectively. The results revealed that during the period under review, meteorological drought was more severe in 2004-2011. While in this period, hydrological drought was more severe in 2007-2011 ( $SPI < -3$ ). Moreover, the prediction results of the indices showed that the performance of the LSSVR model was better than that of ANFIS for both indicators. Using LSSVR, the RMSE and MAPE error evaluation criteria for SPI were 0.74 and 0.59, respectively, while these values for SDI were obtained as 0.62 and 0.46, respectively. The findings of this study show that machine-learning models are suitable tools for predicting drought indicators. Therefore, it is suggested to use such models in predicting drought indicators in other similar regions.

**Cite this article:** Faramarzpour, M.; Saremi, A.; Khosrojerdi, A. & Babazadeh, H. (2023). Evaluation of machine learning models in predicting drought indicators (Case Study: Ajabshir area). *ECO HYDROLOGY*.10 (3), 405-419. Doi: [doi.org/10.22059/ije.2023.364229.1754](https://doi.org/10.22059/ije.2023.364229.1754)



© Mahtab Faramarzpour, Ali Saremi, Amir Khosrojerdi, Hossain Babazadeh

**Publisher:** University of Tehran Press.

DOI: <http://doi.org/10.22059/ije.2023.364229.1754>



انتشارات دانشگاه تهران

## ارزیابی مدل‌های یادگیری ماشین در پیش‌بینی شاخص‌های خشک‌سالی ( مطالعه موردی: محدودهٔ عجب‌شیر )

مهتاب فرامرزیپور<sup>۱</sup> | علی صارمی<sup>۲\*</sup> | امیر خسروجردی<sup>۳</sup> | حسین بابازاده<sup>۴</sup>

۱. دانشجوی دکتری، مهندسی و مدیریت منابع آب، گروه آبیاری، دانشکدهٔ علوم کشاورزی و صنایع غذایی، دانشگاه آزاد اسلامی، واحد تهران مرکزی، تهران. رایانامه: mahi.f1990@gmail.com
۲. نویسندهٔ مسئول، استادیار، مهندسی و مدیریت منابع آب، گروه آبیاری، دانشکدهٔ علوم کشاورزی و صنایع غذایی، دانشگاه آزاد اسلامی، واحد تهران مرکزی، تهران. رایانامه: saremi.ptmco@gmail.com
۳. استادیار، مهندسی و مدیریت منابع آب، گروه علوم و مهندسی آب، دانشکدهٔ علوم کشاورزی و صنایع غذایی، دانشگاه آزاد اسلامی، واحد تهران مرکزی، تهران. رایانامه: khosrojerdi@srbiau.ac.ir
۴. استاد، مهندسی و مدیریت منابع آب، علوم و مهندسی آب، دانشکدهٔ علوم کشاورزی و صنایع غذایی، دانشگاه آزاد اسلامی، واحد تهران مرکزی، تهران. رایانامه: h\_babazadeh@srbiau.ac.ir

### اطلاعات مقاله

### چکیده

#### نوع مقاله:

پژوهشی

#### تاریخ‌های مقاله:

تاریخ دریافت: ۱۴۰۲/۰۲/۲۲

تاریخ بازنگری: ۱۴۰۲/۰۳/۲۲

تاریخ پذیرش: ۱۴۰۲/۰۴/۲۲

تاریخ انتشار: ۱۴۰۲/۰۹/۲۱

#### کلیدواژه:

پیش‌بینی،

عجب‌شیر،

یادگیری ماشین،

SPI

SDI

خشک‌سالی یکی از پدیده‌های مخرب است که می‌تواند تأثیرات منفی زیادی بر منابع آب و نیازهای آبی بگذارد. مدل‌های یادگیری ماشین یکی از ابزارهای سودمند در پیش‌بینی‌های سری زمانی هستند که می‌توانند پیش‌بینی مناسبی بدون داشتن اطلاعات اساسی از یک سامانه ارائه دهند. بنابراین، در این تحقیق از مدل‌های شبکهٔ عصبی فازی (ANFIS) و حداقل مربعات رگرسیون بردار پشتیبان (LSSVR) برای پیش‌بینی شاخص خشک‌سالی هواشناسی (SPI) و شاخص خشک‌سالی هیدرولوژیکی (SDI) برای یک دوره (۱۳۸۰-۱۳۹۸) استفاده شد. از ایستگاه‌های هواشناسی و هیدرولوژیکی آجی‌چای در محدودهٔ مطالعاتی عجب‌شیر به‌ترتیب برای محاسبهٔ شاخص‌های خشک‌سالی SPI و SDI استفاده شد. به منظور پیش‌بینی شاخص SPI داده‌های بارش و برای شاخص SDI داده‌های دبی به عنوان پارامترهای ورودی به مدل‌ها در نظر گرفته شدند. نتایج شاخص‌های خشک‌سالی نشان داد طی دورهٔ مورد بررسی، طی سال‌های ۱۳۸۵-۱۳۹۰ خشک‌سالی هواشناسی و از ۱۳۸۶ تا ۱۳۹۰ خشک‌سالی هیدرولوژیکی شدیدتر بوده است ( $SPI < -3$ ). نتایج پیش‌بینی شاخص‌ها نیز نشان داد عملکرد مدل LS-SVR بهتر از ANFIS در هر دو شاخص بوده است. LS-SVR با شاخص ارزیابی خطای RMSE و MAPE برای SPI به‌ترتیب ۰/۷۴ و ۰/۵۹ پیش‌بینی کرد که این مقادیر برای SDI به‌ترتیب ۰/۶۲ و ۰/۴۶ به دست آمد. نتایج این تحقیق نشان داد مدل‌های یادگیری ماشین ابزار مناسبی برای پیش‌بینی شاخص‌های خشک‌سالی هستند. لذا استفاده از آن‌ها برای پیش‌بینی شاخص‌های خشک‌سالی در سایر محدوده‌های مشابه پیشنهاد می‌شود.

استناد: فرامرزیپور، مهتاب؛ صارمی، علی؛ خسروجردی، امیر و بابازاده، حسین (۱۴۰۲). ارزیابی مدل‌های یادگیری ماشین در پیش‌بینی شاخص‌های خشک‌سالی (مطالعهٔ موردی: محدودهٔ عجب‌شیر). آب هیدرولوژی، ۱۰ (۳) ۴۰۵-۴۱۹.

DOI: <http://doi.org/10.22059/ije.2023.364229.1754>

© مهتاب فرامرزیپور، علی صارمی، امیر خسروجردی، حسین بابازاده. ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <http://doi.org/10.22059/ije.2023.364229.1754>



## ۱. مقدمه

خشک‌سالی از مخرب‌ترین مخاطرات طبیعی است که بر سامانه کشاورزی، در دسترس بودن آب و اقتصاد هر منطقه تأثیر می‌گذارد [۱]. خشک‌سالی به عنوان یکی از بلایای زیست‌محیطی در زمینه‌های مختلف از جمله محیط زیست، اکولوژی، هیدرولوژی، هواشناسی، زمین‌شناسی و کشاورزی بسیار مورد توجه قرار گرفته است. خشک‌سالی می‌تواند به شکل‌های مختلف، به عنوان مثال کشاورزی، هیدرولوژیکی یا اجتماعی اقتصادی رخ دهد که رایج‌ترین آن‌ها خشک‌سالی هواشناسی است [۲]. خشک‌سالی هواشناسی زمانی رخ می‌دهد که میانگین بارندگی بسیار کم باشد. این شاخص بر مبنای بارش تدوین شده است که شاخص بارش استاندارد<sup>۱</sup> (SPI) نام دارد [۳]. این شاخص مطالعه‌شده‌ترین نوع شاخص برای پیش‌بینی خشک‌سالی است، زیرا اغلب باعث شروع سایر خشک‌سالی‌ها می‌شود [۴ و ۵]. به‌تازگی در نقاط مختلف جهان خشک‌سالی مکرر رخ داده و اثرات آن به دلیل افزایش تقاضای آب و تغییرات اقلیمی مضرتر بوده است [۱]. از این‌رو، پدیده خشک‌سالی توجه بسیاری از محققان را به خود جلب کرده و بررسی ویژگی‌های این پدیده از زوایای مختلف موضوع اولویت بالایی برای محققان بوده است [۶]. همچنین، از بین جنبه‌های تصادفی و احتمالی، بارش نقش حیاتی در مناطق خشک و نیمه‌خشک دارد. بنابراین، کمبود بارش و افزایش دما به شدت بر رواناب سطحی و زیرزمینی تأثیر می‌گذارد [۷]. شاخص‌های خشک‌سالی بخش مهمی از سامانه پیش‌بینی خشک‌سالی است. محققان شاخص‌های مختلفی را برای پیش‌بینی شرایط خشک‌سالی و همچنین، بررسی اثرات کمی آن ایجاد کرده‌اند. شرایط پیش‌بینی خشک‌سالی می‌تواند اطلاعات مفیدی را ارائه دهد که به کاهش پیامدهای ناشی از خشک‌سالی کمک می‌کند. شاخص خشک‌سالی هیدرولوژیکی<sup>۲</sup> (SDI) به عنوان متداول‌ترین روش مورد استفاده برای کمی‌سازی خشک‌سالی‌های هیدرولوژیکی مبتنی بر جریان رودخانه در نظر گرفته می‌شود. به بیان دیگر، SDI امکان مقایسه دقیق شرایط هیدرولوژیکی جریان رودخانه را فراهم می‌کند [۷]. در دهه‌های گذشته مدل‌های سنتی مانند مدل‌های رگرسیون خطی و چندخطی [۸]، مدل‌های آماری [۶ و ۹] برای پیش‌بینی شاخص‌های خشک‌سالی استفاده می‌شد [۱۰ و ۱۱]. اما به دلیل وجود روابط پیچیده و غیرخطی همراه با عدم قطعیت در متغیرهای ورودی محققان را به استفاده از مدل‌های بهتر و با دقت بالاتر سوق داده است [۶]. یکی از روش‌هایی که کارایی آن‌ها در تحقیقات مختلف پیش‌بینی استفاده می‌شود، مدل‌های مبتنی بر داده‌محور است. یادگیری ماشین به عنوان یک روش داده‌محور از مناسب‌ترین روش‌ها برای پیش‌بینی این پدیده است. مدل‌های یادگیری ماشین شامل مدل‌های شبکه عصبی مصنوعی<sup>۳</sup> (ANN)، ماشین بردار پشتیبان<sup>۴</sup> (SVM) و سامانه‌های مبتنی بر قوانین فازی مانند سیستم استنتاج عصبی فازی تطبیقی<sup>۵</sup> (ANFIS) است که برای پیش‌بینی پدیده‌های هیدرولوژیکی با موفقیت مورد استفاده قرار گرفته‌اند. رستمی و همکاران [۱۲] با استفاده از مدل‌های ANN و ANFIS شاخص خشک‌سالی SPI را در حوزه مَند استان فارس پیش‌بینی کردند. نتایج پژوهش آن‌ها نشان داد دقت ANN از ANFIS بالاتر است و هرچه پراکندگی داده‌های ورودی مدل بیشتر باشد، مدل ANFIS دارای توانایی بیشتری در شبیه‌سازی این نوع از داده‌ها است. در تحقیق دیگری Nguyen و همکاران [۱۳] با استفاده از ANFIS به پیش‌بینی شاخص استاندارد شده بارش (SPI) و شاخص استاندارد تبخیر و تعرق بارش (SPEI) پرداختند. نتایج پژوهش آن‌ها نشان داد مدل ANFIS شاخص SPI را در مقایسه با شاخص SPEI با دقت بیشتری تخمین می‌زند. در تحقیق مشابه Mokhtarzad و همکاران [۱۴] برای پیش‌بینی SPI سه مدل ANN، ANFIS و SVM را مقایسه کردند (Mokhtarzad et al., 2017). نتایج پژوهش آن‌ها بیانگر دقت زیاد مدل SVM در مقایسه با دو مدل دیگر بود [۱۵]. Pande و همکاران برای پیش‌بینی SPI دو مدل ANN و مدل درخت M5 را مقایسه کردند [۱۶]. در سطح ملی نیز تحقیقات زیادی در این زمینه انجام شده است که می‌توان به تحقیقات قربانی و همکاران (۱۳۹۸) استفاده از SARIMA در پیش‌بینی شاخص SPI، استفاده از زنجیره مارکوف<sup>۶</sup> در پیش‌بینی SPI توسط شکری کوچک و بهینا (۱۳۹۲)، استفاده از روش مدل درختی<sup>۷</sup> (MT) و

1. Standardized Precipitation Index
2. Streamflow drought index
3. Artificial neural network
4. Support vector machine
5. Adaptive neuro-fuzzy inference system
6. Markov Chain
7. Tree Model

رگرسیون چندمتغیره تطبیقی اسپالین<sup>۱</sup> (MARS) توسط امیرانی پور و همکاران (۱۴۰۰) در پیش‌بینی شاخص بارش تبخیر و تعرق استاندارد شده<sup>۲</sup> (SPEI)، استفاده از روش تلفیقی موجک شبکه عصبی در پیش‌بینی خشک‌سالی هواشناسی، هیدرولوژیکی و کشاورزی توسط مشایخی و ذاکری نیری (۱۳۹۹) اشاره کرد [۱۷-۲۰].

ایران به دلیل قرار گرفتن در یک منطقه خشک و نیمه‌خشک، هر منطقه از آن در معرض خشک‌سالی قرار دارد. در سال‌های اخیر، با توجه به اینکه الگوی بارش‌ها دچار تغییرات زیادی شده است و از طرف دیگر، وجود پدیده تغییر اقلیم که باعث افزایش دما و کاهش بارش‌ها در بیشتر مناطق می‌شود و متعاقب آن باعث کاهش رواناب و جریان رودخانه می‌شود، بررسی خشک‌سالی‌ها در مناطق مختلف از ایران ضروری به نظر می‌رسد. از این‌رو پایش خشک‌سالی با استفاده از شاخص‌های SPI و SDI مورد هدف این تحقیق بود. محدوده عجب‌شیر و رودخانه قلعه‌چای واقع در شمال غرب ایران به عنوان محدوده مطالعاتی انتخاب شد. با استفاده از داده‌های بارش و دبی رودخانه دو شاخص SPI و SDI به منظور مطالعه خشک‌سالی هواشناسی و هیدرولوژیکی محاسبه شد. با توجه به اهمیت موضوع، از دو مدل ANFIS و LS-SVR به منظور تخمین شاخص‌های خشک‌سالی استفاده و بهترین مدل پیش‌بینی‌کننده نیز انتخاب شد.

## ۲. مواد و روش‌ها

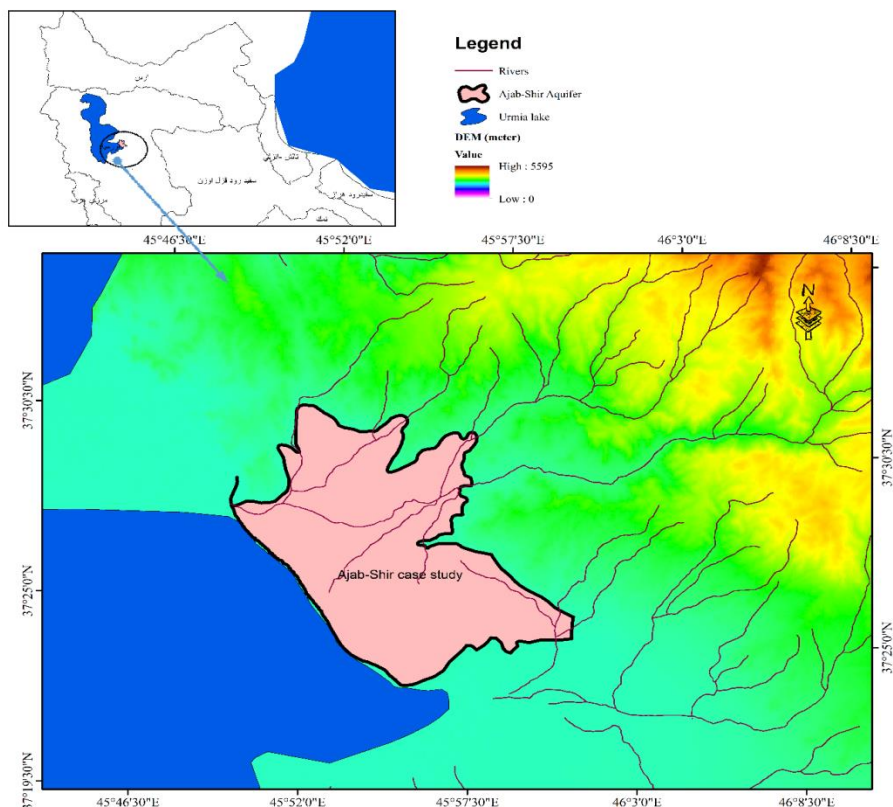
### ۲.۱. منطقه مطالعه شده

محدوده مطالعاتی عجب‌شیر با مساحت ۱۵۰۸ کیلومتر مربع حدود ۲/۹ درصد از کل حوضه آبریز دریاچه ارومیه را دربرمی‌گیرد. از این میزان ۲۴۹ کیلومتر مربع مربوط به وسعت دشت و ۱۲۵۹ کیلومتر مربع را نیز ارتفاعات محدوده تشکیل می‌دهد (شکل ۱). رودخانه عجب‌شیر چای به عنوان اصلی‌ترین رودخانه در جهت جنوب به شمال این محدوده مطالعاتی جریان دارد. این محدوده در موقعیت جغرافیایی با طول ۴۵ درجه و ۴۳ دقیقه شرقی و عرض جغرافیایی ۳۶ درجه و ۴۶ دقیقه شمالی قرار گرفته و ارتفاع آن از سطح دریا ۱۳۸۵ متر است. بررسی آمار درازمدت بارندگی در ایستگاه سینوپتیک عجب‌شیر نشان می‌دهد حداکثر بارش سالانه در این منطقه ۶۷۸/۴ میلی‌متر و حداقل میزان بارش ۱۷۳/۴ میلی‌متر ثبت شده است. پارامتر دما نقش مهمی در وضعیت اقلیم منطقه دارد. شهرستان عجب‌شیر به دلیل قرار گرفتن در ارتفاعات از دمای مناسبی برخوردار است. میانگین حداقل و حداکثر دما طی سال‌های ۱۳۶۳ تا ۱۴۰۰ به ترتیب برابر ۶/۵ و ۱۹/۰ درجه سلسیوس است.

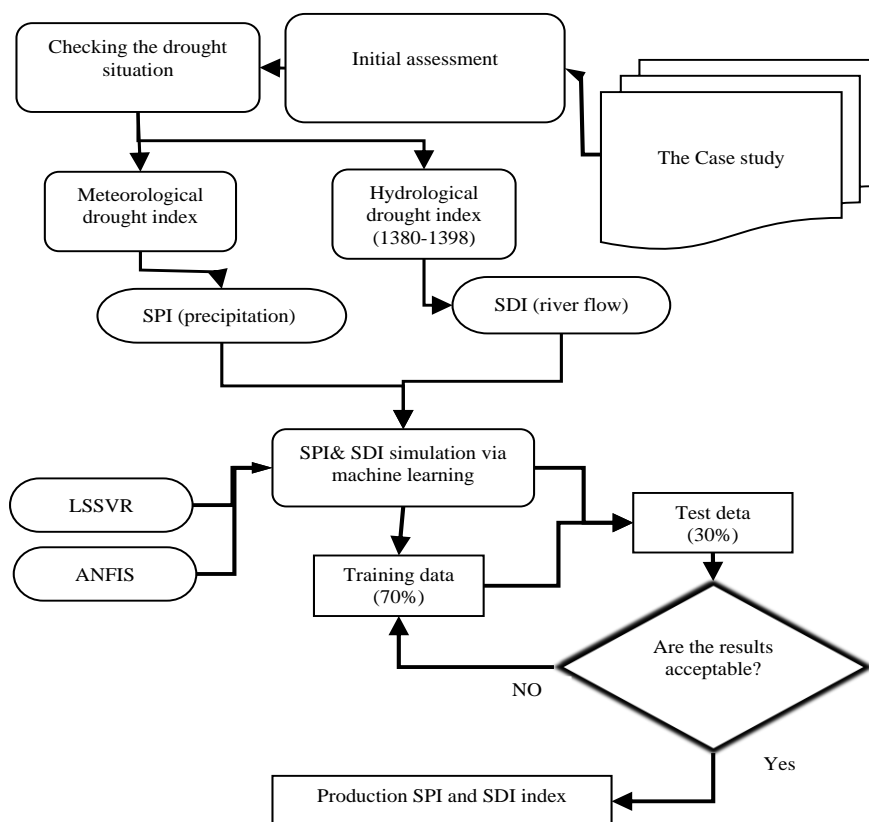
### ۲.۲. فلوجارت تحقیق و داده‌های مورد استفاده

در این تحقیق به منظور بررسی نتایج مدل‌ها برای پیش‌بینی شاخص‌های خشک‌سالی، ابتدا با استفاده از داده‌های بارش و دبی طی دوره ۱۳۸۰-۱۳۹۸ به ترتیب شاخص‌های سه‌ماهه SPI و SDI محاسبه و تحلیل شد. در ادامه روند انجام کار در شکل ۲ به صورت فلوجارت ارائه شده است. شاخص‌های محاسبه شده به عنوان خروجی مدل‌ها مورد استفاده قرار گرفتند که توسط مدل‌های یادگیری ماشین تخمین زده شدند. برای پیش‌بینی شاخص SPI، داده‌های بارش و برای پیش‌بینی شاخص SDI داده‌های دبی به عنوان داده‌های ورودی در نظر گرفته شدند و مقدار دو شاخص با استفاده از دو مدل ANFIS و LS-SVR پیش‌بینی شدند. از بین داده‌های موجود، ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد نیز برای آزمون مدل‌ها به کار گرفته شد. نتایج مدل‌ها با استفاده از معیارهای ارزیابی سنجیده شد، در صورتی که نتایج قابل قبول از طریق معیارهای ارزیابی خطا به دست آمد، داده‌های خروجی مدل‌ها استخراج شد، در غیر این صورت، فرایند دوباره تکرار شد.

از ویژگی‌های خشک‌سالی می‌توان به شدت، تداوم، گستره و فراوانی آن اشاره کرد که با استفاده از شاخص‌های ارزیابی خشک‌سالی تعیین می‌شوند. در تحقیق حاضر به دلیل اهمیت خشک‌سالی هواشناسی و هیدرولوژیکی از دو شاخص خشک‌سالی هیدرولوژیکی (SDI) و شاخص خشک‌سالی بارش استاندارد شده (SPI) استفاده شده است.



شکل ۱. موقعیت حوضه آبریز عجب‌شیر



شکل ۲. نمای شماتیک مراحل پیش‌بینی شاخص‌های خشک‌سالی

### ۳.۲ شاخص خشک‌سالی هواشناسی

این شاخص عبارت است از: متغیری از تابع توزیع احتمال استاندارد که مقدار احتمال تجمعی آن یا مقدار احتمال تجمعی متغیر مورد نظر از توزیع گامای به‌دست‌آمده یکسان باشد. این شاخص به دلیل انعطاف‌پذیری و قابلیت آن برای مقیاس‌های زمانی مختلف مورد توجه بسیاری از محققان قرار گرفته است [۲۰]. شاخص SPI برای هر منطقه بر اساس ثبت بارش‌های طولانی‌مدت آن محاسبه می‌شود. برای محاسبه این شاخص، ابتدا توزیع آماری مناسب برای آمار بلندمدت بارندگی‌ها برآزش داده می‌شود و سپس تابع تجمعی توزیع با استفاده از احتمالات مساوی به توزیع نرمال تبدیل می‌شود، به طوری که استاندارد شده و متوسط آن برای هر منطقه و دوره مورد مطالعه صفر شود [۲۰ و ۲۱]. شاخص SPI با استفاده از رابطه ۱ محاسبه می‌شود.

$$SPI = \frac{P_0 + \sum P_{-i} - \mu_n}{\delta_n} \quad (1)$$

در این رابطه n تعداد ماه‌هایی که بارش تجمعی‌شان محاسبه شده است.  $P_0$  مقدار بارش نرمال شده در ماه جاری،  $P_{-i}$  مقدار بارش نرمال شده در ماه قبلی،  $\mu_n$  میانگین بارش تجمعی n ماه و  $\delta_n$  انحراف معیار بارش تجمعی n ماه است. جدول ۱ طبقه‌بندی مقادیر شاخص SPI را نشان می‌دهد. مطابق جدول ۱ در صورتی که شاخص SPI بیشتر از یک باشد، وضعیت ترسالی و اگر کمتر از منفی یک باشد وضعیت خشک‌سالی رخ می‌دهد.

جدول ۱. طبقه‌بندی شاخص SPI [۲۰]

مقادیر SPI	دسته‌بندی
$2 < SPI$	ترسالی خیلی شدید
$1.5 < SPI < 1.99$	ترسالی شدید
$1 < SPI < 1.49$	ترسالی ملایم
$-0.99 < SPI < 0.99$	نرمال
$-1.49 < SPI < -1$	خشک‌سالی ملایم
$-1.99 < SPI < -1.5$	خشک‌سالی شدید
$SPI < -2$	خشک‌سالی خیلی شدید

### ۴.۲ شاخص خشک‌سالی هیدرولوژیکی

یکی دیگر از شاخص‌هایی که برای مطالعه خشک‌سالی یک منطقه استفاده می‌شود، شاخص SDI است که با استفاده از داده‌های دبی رودخانه محاسبه می‌شود. شاخص SDI مطابق رابطه ۲ محاسبه می‌شود:

$$SDI_{j,k} = V_{j,k} - V_k / S_k \quad (2)$$

$$V_{j,k} = \sum_{j=1}^{3k} Q_{i,j} \quad i=1,2,3,\dots k=1,2,3,4 j=1,2,\dots,12 \quad (3)$$

در این روابط i سال هیدرولوژیکی، j ماه (که در اینجا برای ماه مهر عدد ۱ و برای شهریور عدد ۱۲ است). Q مقادیر دبی حجمی جریان تجمعی و همچنین پارامترهای و به‌ترتیب میانگین و انحراف معیار داده‌های تجمعی دبی است (مفیدی‌پور و همکاران، ۱۳۹۱). جدول ۲ طبقه‌بندی وضعیت خشک‌سالی را بر اساس شاخص خشک‌سالی SDI نشان می‌دهد. مطابق این جدول، وضعیت ترسالی از مقدار SDI بزرگ‌تر از یک و وضعیت خشک‌سالی از مقدار SDI کمتر از منفی یک شروع می‌شود.

جدول ۲. طبقه‌بندی شاخص SDI [۲۲].

مقادیر SDI	دسته‌بندی
$2 < SDI$	ترسالی خیلی شدید
$1.5 < SDI < 1.99$	ترسالی شدید
$1 < SDI < 1.49$	ترسالی ملایم
$-0.99 < SDI < 0.99$	نرمال
$-1.49 < SDI < -1$	خشک‌سالی ملایم
$-1.99 < SDI < -1.5$	خشک‌سالی شدید
$SDI < -2$	خشک‌سالی خیلی شدید

در ادامه به تشریح دو مدل ANFIS و LS-SVM پرداخته شده است.

## ۲.۵. مدل‌های یادگیری ماشین

مدل‌های یادگیری ماشین به دلیل آنکه ماهیت داده‌ها در آن در نظر گرفته نمی‌شود و همچنین، از تنوع روش‌های زیادی برخوردار هستند بسیار مورد توجه قرار می‌گیرد. در بین روش‌های موجود دو مدل ANFIS و LS-SVM به دلیل آنکه در زمینه‌های مختلف نتایج مناسبی از پیش‌بینی یک سامانه ارائه داده، بیشتر مورد توجه است. تشریح ساختار و روابط به‌کاررفته در این روش‌ها در ادامه بیان شده است.

### ۲.۵.۱. مدل شبکه عصبی-فازی

مدل سامانه استنتاج عصبی-فازی تطبیقی (ANFIS) در سال ۱۹۹۳ توسط [۲۳] ارائه شد. این مدل ترکیبی از شبکه عصبی مصنوعی و سامانه استنتاج فازی است. رایج‌ترین روش آموزش در مدل ANFIS تابع سوگنو<sup>۱</sup> است که از الگوریتم یادگیری پیوندی برای تعیین پارامترهای سیستم فازی به منظور آموزش مدل استفاده می‌کند. برای دو ورودی  $(x_2, x_1)$  از نوع Sugeno و با قوانین فازی if-then، با خروجی  $y$  ساختار ANFIS را می‌توان به شرح روابط ۴ و ۵ توصیف کرد.

$$\text{Rule 1. If } (x_1 \text{ is } A_1) \text{ and } (x_2 \text{ is } B_1) \text{ then } f_1 = p_1x_1 + q_1x_2 + r_1 \quad (4)$$

$$\text{Rule 2. If } (x_1 \text{ is } A_2) \text{ and } (x_2 \text{ is } B_2) \text{ then } f_2 = p_2x_1 + q_2x_2 + r_2 \quad (5)$$

که  $A$  و  $B$  به ترتیب مجموعه‌های فازی هستند،  $q$ ،  $p$  و  $r$  پارامترهای نتیجه مدل هستند که در مرحله آموزش ارزیابی می‌شوند. ساختار ANFIS شامل ۵ لایه است. در لایه اول (لایه ورودی)، ورودی‌ها از توابع عضویت مختلف عبور می‌کند و درجه عضویت گره‌های ورودی به بازه‌های مختلف فازی با استفاده از توابع عضویت مشخص می‌شود. توابع عضویت انواع مختلفی دارد که می‌توان به توابع مثلثی، دوزنقه‌ای، گوسی و تابع زنگوله‌ای اشاره کرد. در این تحقیق از تابع عضویت گوسی استفاده شده است [۲۳]. در لایه دوم یا گره قاعده که در آن مقادیر ورودی به هر گره در هم ضرب شده و حاصل که وزن قانون‌ها است به دست می‌آید. در این لایه از عملگر "AND" استفاده شده است. لایه سوم، گره‌های این لایه وزن قانون‌ها را نرمال‌سازی می‌کنند. گره‌های نتیجه که لایه قوانین نامیده می‌شود و در این لایه قانون‌ها به دست می‌آیند. لایه پنجم آخرین لایه شبکه است که شامل یک تک‌گره بوده و با جمع کردن همه مقادیر ورودی به آن، خروجی کلی سیستم را محاسبه می‌کند. این لایه نتایج هر قانون فازی را طی فرایند غیرفازی سازی به خروجی غیرفازی تغییر شکل می‌دهد [۲۴].

### ۲.۵.۲. مدل حداقل مربعات میانگین رگرسیون بردار پشتیبان

این مدل ابتدا به عنوان ماشین بردار پشتیبان<sup>۲</sup> (svm) مطرح شد [۲۵]، سپس در سال ۱۹۹۹، Chen و همکاران [۲۶] مدل حداقل مربعات ماشین بردار پشتیبان<sup>۳</sup> (LS-SVM) را معرفی کردند. مدل LS-SVM در مقایسه با SVM محدودیت‌های یکسانی دارد، اما پیچیدگی محاسبات کمتر، دقت و سرعت زیادتری دارد. مجموعه داده‌های آموزشی مانند  $\{x_k, y_k\}_{k=1}^N$  که داده ورودی آن شامل  $x_k \in R^N$  و داده‌های خروجی  $y_k \in R$  معرفی می‌شود. بنابراین، تابع رگرسیون غیرخطی در فضای وزن‌دهی اولیه به صورت رابطه ۶ به دست می‌آید [۲۷].

$$y(x) = W^T \varphi(x) + b \quad (6)$$

که در آن  $W$ ،  $b$ ،  $T$  به ترتیب بیانگر وزن‌ها، بایاس تابع رگرسیون و نشان‌دهنده ترانزاده هستند.  $\varphi(x)$  ترسیم غیرخطی ورودی‌ها در فضای ویژگی با ابعاد بالا است. رگرسیون غیرخطی یادشده توسط رابطه بهینه‌سازی  $\gamma$  قابل حل است.

$$\min j(w, e) = \frac{1}{2} W^T W + \frac{1}{2} \gamma \sum_{k=1}^N e_k^2 \quad (7)$$

1. Sugeno  
2. Support vector machine  
3. Least-squares support vector machine

با توجه به محدودیت‌ها داریم:

$$y_k = W^T \varphi(\chi) + b + e_k, \quad k = 1, 2, \dots, N \quad (۸)$$

$\gamma$  پارامتر تنظیم‌کننده بخش خطا است و  $e$  میزان خطا را نشان می‌دهد. مقدار  $\gamma$  همواره تابع تقریب را کنترل می‌کند، بنابراین مقدار آن اگر بزرگ باشد خطای بیشتری ایجاد می‌کند. حل با استفاده از شکل لاگرانژی از تابع هدف اصلی و از رابطه ۹ به دست می‌آید:

$$L(w, b, e, \alpha) = j(w, e) - \sum_{i=1}^N \alpha_i \{W^T \varphi(\chi) + b + e_k - y_k\} \quad (۹)$$

که در آن  $\alpha_i$  ضریب لاگرانژ<sup>۱</sup> است. بر اساس شرایط کان - تاکر<sup>۲</sup> مدل LS-SVM به منظور تابع تقریب به صورت رابطه ۱۰ نوشته می‌شود:

$$y(\chi) = \sum_{k=1}^N \alpha_k K(\chi, \chi_k) + b \quad (۱۰)$$

$K(\chi, \chi_k)$  تابع کرنل<sup>۳</sup> نامیده می‌شود و مقدار آن طبق رابطه ۱۱ محاسبه می‌شود:

$$K(\chi, \chi_k) = \exp\left(-\frac{\|\chi - \chi_k\|^2}{\sigma^2}\right) \quad (۱۱)$$

در این تحقیق از تابع کرنل پایه شعاعی<sup>۴</sup> برای حل استفاده شده است.

## ۲.۷. معیارهای ارزیابی خطا

برای ارزیابی الگوها معیارهای ارزیابی برای سنجش الگوها از خطای جذر میانگین مربعات<sup>۵</sup> (RMSE) و درصد میانگین مطلق خطا<sup>۶</sup> (MAPE) استفاده شده است. هرچقدر مقدار RMSE و MAPE به صفر نزدیک‌تر باشند، کارایی مدل مورد نظر نیز بهتر است.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (x_p - x_o)^2}{n}} \quad (۱۲)$$

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{x_o - x_p}{x_o} \right|}{n} \times 100 \quad (۱۳)$$


که در آن  $x_p$  و  $x_o$  به ترتیب مقدار داده‌های واقعی و شبیه‌سازی شده هستند. مجله را ندارند.

## ۳. یافته‌ها


نتایج شاخص‌های خشک‌سالی SPI و SDI که با استفاده از داده‌های بارش و دبی محاسبه شده‌اند، در شکل‌های ۳ و ۴ ارائه شده است. مطابق شکل‌های یادشده شاخص SPI، محدوده مطالعاتی طی سال‌های ۱۳۸۰ تا ۱۳۸۴ وضعیت نزدیک به نرمال را سپری کرده است. اما از سال ۱۳۸۴ به بعد، با نامنظم شدن بارش‌ها، در سال‌های ۱۳۸۵، ۱۳۸۶، ۱۳۸۹ و ۱۳۹۰ در برخی ماه‌ها خشک‌سالی خیلی شدید حاکم است. طی دوره مورد مطالعه، به‌خصوص در سال‌های انتهایی با بیشتر شدن بارش‌ها شاخص SPI نیز وضعیت نرمال به سمت ترسالی را نشان می‌دهد. شاخص SDI نیز نشان می‌دهد از سال ۱۳۸۰ تا ۱۳۸۶ بیشتر وضعیت ترسالی حاکم بوده است. بین سال‌های ۱۳۸۶ تا ۱۳۹۰ نیز خشک‌سالی هیدرولوژیکی ظاهر شده است. در سال‌های انتهایی دوره نیز وضعیت خشک‌سالی هیدرولوژیکی نرمال به سمت مرطوب بوده است.

1. Lagrangian
2. Karush – Kuhn- Tucker
3. Kernel function
4. Radial Basis Function
5. Root Mean Square Error
6. Mean absolute percentage error





شکل ۳. نتایج شاخص SPI



شکل ۴. نتایج شاخص SDI

### ۲.۳. نتایج مدل‌های پیش‌بینی‌کننده شاخص‌های خشک‌سالی



برای ایستگاه مورد مطالعه با استفاده از دو مدل ANFIS و LS-SVR شاخص‌های خشک‌سالی SPI و SDI تخمین زده شد. برای شاخص SPI داده‌های بارش به عنوان ورودی به مدل‌ها و شاخص SPI نیز به عنوان خروجی در نظر گرفته شد. مقادیر بهینه پارامترهای LS-SVM، هسته گاوسی در روش LS-SVM دارای دو پارامتر  $\sigma^2$  و  $\gamma$  است که مقدار بهینه آن به ترتیب برابر با ۵/۳۶۵ و ۱۳۶/۰۳ به دست آمد. برای مدل ANFIS تابع عضویت گاوسی به عنوان مناسب‌ترین تابع عضویت فازی انتخاب شد. از آنجا که ANFIS از روش Sugeno-type استفاده می‌کند، تابع خطی به عنوان بهترین تابع خروجی مدل انتخاب شد. جدول ۳ نتایج تخمین شاخص‌های SPI و SDI را با استفاده از دو مدل ANFIS و LS-SVR بیان می‌کند. برای تخمین شاخص SPI مدل LS-SVR دقت بیشتری نسبت به ANFIS دارد. در مدل LS-SVR مقادیر RMSE و MAPE برای داده‌های آموزش به ترتیب ۰/۶۶ و ۰/۵۱ به دست آمده است، در حالی که این مقادیر برای داده‌های آزمون تفاوت چندانی با داده‌های آموزش ندارد، به طوری که مقادیر RMSE و MAPE برای داده‌های آزمون به ترتیب برابر ۰/۷۴ و ۰/۵۹ است. در مقابل مقدار این شاخص‌ها برای مدل ANFIS برای داده‌های آزمون به ترتیب ۱/۰۳ و ۰/۸۴ به دست آمده است. عملکرد مدل‌ها برای شاخص SDI متفاوت از نتایج شاخص SPI است. مقادیر معیارهای ارزیابی خطا برای داده‌های آموزش و آزمون نزدیک به

هم است. همانند شاخص SPI در این شاخص نیز مدل LS-SVR عملکرد بهتری نسبت به ANFIS دارد. مقدار RMSE برای مدل LS-SVR برابر ۰/۶۲ و برای مدل ANFIS برابر ۰/۷۸ است.

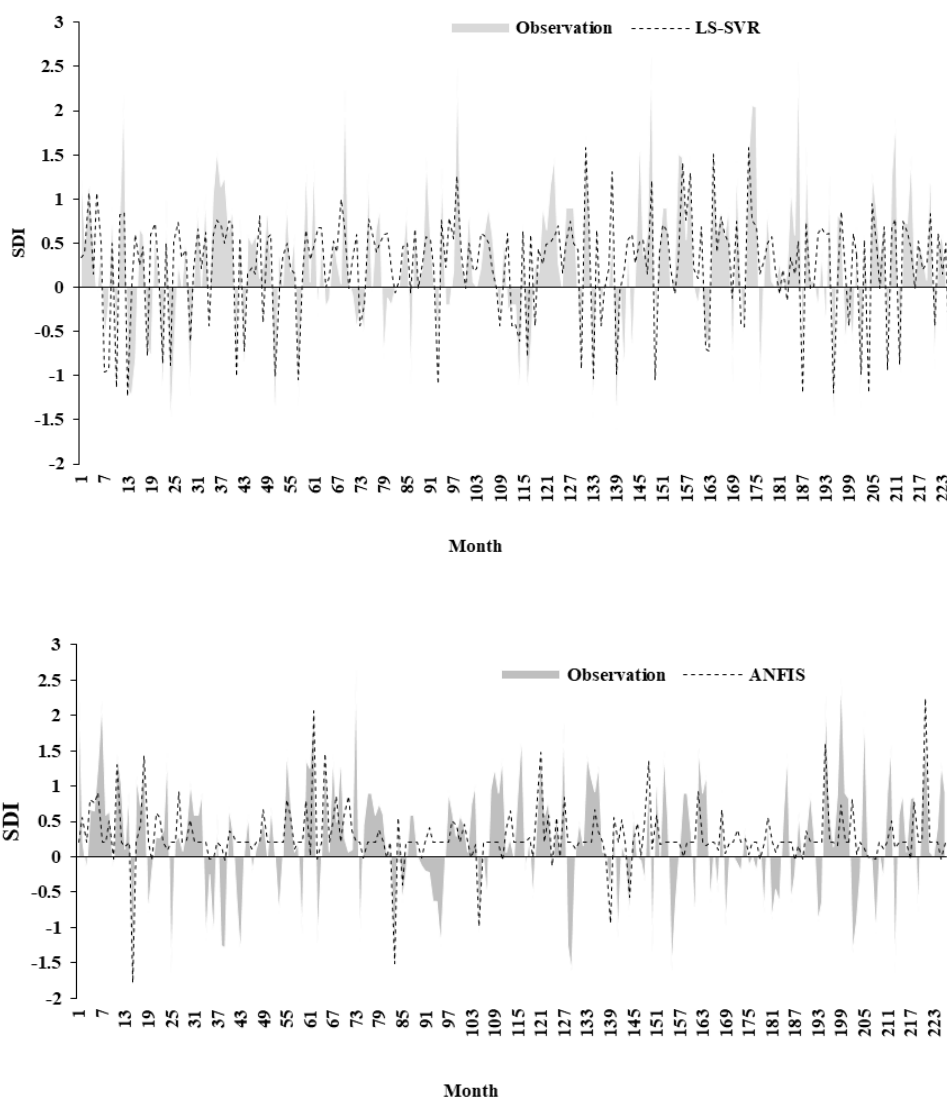
نمودار سری زمانی داده‌های مشاهداتی و شبیه‌سازی شده با مدل‌های ANFIS و LS-SVR برای دو شاخص SPI و SDI به ترتیب در شکل‌های ۵ و ۶ ارائه شده است. مطابق شکل ۵، برای شاخص SPI مدل ANFIS در چندین گام زمانی داده‌ها را بیشتر از مقدار واقعی یا کمتر از مقدار واقعی تخمین زده است، اما در مدل LS-SVR چنین ضعف‌هایی کمتر مشاهده شده است. در شاخص SDI، مدل ANFIS در پیش‌بینی شاخص، به‌خصوص در گام‌هایی انتهایی عملکرد ضعیفی داشته است. با توجه به نتایج به‌دست‌آمده می‌توان بیان کرد که برای هر دو شاخص مدل LS-SVR عملکرد بهتری داشته است.

جدول ۳. نتایج پیش‌بینی شاخص‌های خشک‌سالی با استفاده از مدل‌های ANFIS و LS-SVR

Drought index	Models	RMSE		MAPE	
		Training	Test	Training	Test
SPI	LS-SVR	0.66	0.74	0.51	0.59
	ANFIS	0.79	1.03	0.62	0.84
SDI	LS-SVR	0.58	0.62	0.44	0.46
	ANFIS	0.74	0.78	0.54	0.61

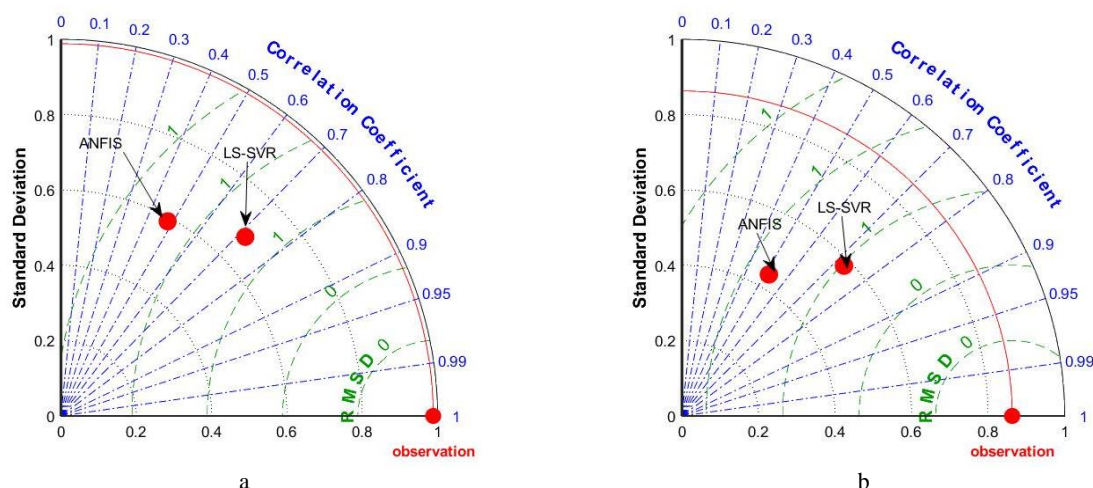


شکل ۵. نمودار سری زمانی داده‌های مشاهده‌شده شاخص SPI و شبیه‌سازی شده با استفاده از مدل‌های ANFIS و LS-SVR.



شکل ۶. نمودار سری زمانی داده‌های مشاهده شاخص SDI و شبیه‌سازی شده با استفاده از مدل‌های ANFIS و LS-SVR

برای بررسی بیشتر، مقایسه مدل‌ها با استفاده از دیاگرام تیلور انجام شده و نتایج آن برای هر یک از شاخص‌ها در شکل ۷ نشان داده است. در این دیاگرام مقایسه مدل‌ها با سه معیار انحراف معیار (محور عمودی)، RMSD (کمان‌های داخل ربع دایره) و ضریب همبستگی (کمان ربع دایره) انجام می‌شود. مطابق این دیاگرام، هر مدلی که موقعیت آن به موقعیت داده‌های مشاهده‌ای نزدیک‌تر باشد، تخمین بهتری از شاخص‌های خشک‌سالی داشته است. در شکل مربوط به شاخص‌ها، ضریب همبستگی داده‌های حاصل از مدل LS-SVR بین ۰/۷ و ۰/۸ است، در حالی که این ضریب برای داده‌های ANFIS حدود ۰/۵ است. از طرف دیگر، موقعیت LS-SVR به داده‌های مشاهده‌ای نزدیک‌تر است. بنابراین، مدل LS-SVR تخمین بهتری از شاخص SPI داشته است. بنابراین، نتایج دیاگرام تیلور تأییدکننده نتایج معیارهای ارزیابی خطا است.



شکل ۷. نمودار تیلور (a) شاخص SPI (b) شاخص SDI

#### ۴. بحث

در تحقیق حاضر به منظور تخمین دو شاخص خشک‌سالی SPI و SDI از دو مدل یادگیری ماشین ANFIS و LS-SVR استفاده شد. نتایج این تحقیق نشان داد مدل‌های یادگیری ماشین با دقت مناسبی شاخص‌های خشک‌سالی را تخمین می‌زنند. نتایج این تحقیق همسو با نتایج تحقیق صمدیان فرد و اسدی [۲۸] است. همچنین، کماسی و همکاران [۲۹] در تحقیق خود به کارایی این مدل‌ها دست یافته بودند. در این تحقیق، عملکرد مدل LS-SVR در پیش‌بینی هر دو شاخص خشک‌سالی بهتر از مدل ANFIS بود. مدل ANFIS در برخی از حالت‌ها عملکرد ضعیفی در پیش‌بینی‌ها نشان می‌دهد که می‌تواند ناشی از به دام افتادن الگوریتم‌های آموزش‌دهنده در نقاط کمینه محلی باشد که باعث کاهش دقت مدل می‌شود. ضعف این عملکرد در سایر تحقیقات در مسائل هیدرولوژی نیز دیده شد که می‌توان به تحقیقات آریا‌آذر و همکاران (۲۰۲۲) در پیش‌بینی تبخیر از مخازن سدها، کی همایون و همکاران (۲۰۲۳) در پیش‌بینی انرژی برقایی اشاره کرد [۳۰-۳۳]. با وجود اینکه در این تحقیق، مدل ANFIS از کارایی بالایی در پیش‌بینی شاخص‌ها برخوردار بود، نتایج مدل ANFIS همچنین همسو با نتایج تحقیق گل‌دوست و سبحانی [۳۱] بود که نشان دادند مدل ANFIS برای پیش‌بینی شاخص SPI در دشت اردبیل از کارایی بالایی در بخش آزمون برخوردار نیست. از این رو و با توجه به نتایج به‌دست‌آمده مدل LS-SVR به عنوان ابزاری قدرتمند برای پیش‌بینی شاخص خشک‌سالی معرفی شد که می‌تواند در مدیریت مسائل و مخاطرات زیست‌محیطی برای مدیران بخش‌های مختلف مؤثر باشد. داده‌های مورد استفاده در این تحقیق بارش و میزان جریان رواناب بود که می‌توان از سایر اطلاعات هواشناسی برای تخمین مقادیر شاخص‌ها استفاده کرد. همچنین، با وجود تعداد زیادی از مدل‌های یادگیری ماشین استفاده از سایر مدل‌ها در تخمین مقادیر SPI و SDI و همچنین، سایر شاخص‌های خشک‌سالی پیشنهاد می‌شود. مقایسه نتایج سایر مدل‌ها با نتایج این تحقیق می‌تواند گامی مؤثر در انتخاب مدل مناسب یادگیری ماشین در این زمینه باشد. همان‌طور که بیان شد، نتایج این تحقیق عدم توانایی بالای ANFIS در تخمین مقادیر شاخص‌ها بود که به‌خصوص در داده‌های مربوط به آزمون مشاهده شد، لذا برای رفع چنین نقی می‌توان از الگوریتم‌های تکاملی به جای الگوریتم‌های سنتی موجود در ANFIS استفاده کرد.

#### ۵. نتیجه‌گیری

این تحقیق با هدف تخمین شاخص‌های خشک‌سالی SPI و SDI محدوده مطالعاتی عجب‌شیر با استفاده از دو مدل یادگیری ماشین ANFIS و LS-SVR انجام شد. ابتدا با استفاده از داده‌های ماهانه بارش و دبی طی سال‌های ۱۳۸۰ تا ۱۳۹۸ دو شاخص خشک‌سالی SPI و SDI محاسبه شد. در ادامه، با استفاده از دو مدل یادگیری ماشین ANFIS و LS-SVR شاخص‌های یادشده تخمین زده شد. برای تخمین SPI از داده‌های بارش و برای تخمین SDI از داده‌های دبی به عنوان ورودی به مدل‌ها استفاده شد.

در نهایت، عملکرد مدل‌ها برای پیش‌بینی شاخص‌ها با استفاده از معیارهای RMSE و MAPE، نمودار سری زمانی و نمودار تیلور مورد مقایسه قرار گرفت. نتایج به‌دست‌آمده را می‌توان به صورت موارد زیر بیان کرد:

۱. نتایج شاخص خشک‌سالی SPI نشان داد در محدوده مطالعاتی، در سال‌های ۱۳۸۵، ۱۳۸۶، ۱۳۸۹ و ۱۳۹۰ خشک‌سالی شدیدی حاکم بوده است، اما در سال‌های انتهایی مورد بررسی وضعیت نزدیک به نرمال و به سمت ترسالی بوده است.

۲. مطابق شاخص SDI، محدوده مطالعاتی در دوره ۱۳۸۶ تا ۱۳۹۰ خشک‌سالی شدید هیدرولوژیکی را سپری کرده است.

۳. نتایج معیارهای ارزیابی مدل‌های پیش‌بینی‌کننده نشان داد برای پیش‌بینی هر دو شاخص، مدل LS-SVR عملکرد بهتری نسبت به ANFIS دارد.

۴. مقایسه بین مدل‌ها با استفاده از دیاگرام تیلور نیز نشان داد موقعیت داده‌های حاصل از LS-SVR به موقعیت داده‌های مشاهداتی نزدیک‌تر است. میزان همبستگی بین داده‌های مشاهداتی و محاسباتی برای هر دو شاخص در مدل LS-SVR بین ۰/۷ تا ۰/۸ بود. از این‌رو، عملکرد LS-SVR در پیش‌بینی شاخص‌ها بهتر از ANFIS بود.

بنابراین، با توجه به نتایج به‌دست‌آمده می‌توان LSSVR را به عنوان یک ابزار مناسب برای تخمین شاخص‌های خشک‌سالی معرفی کرد که قابل اجرا در سایر زمینه‌های مشابه باشد. این تحقیق با استفاده از دو مدل منفرد انجام شد، با توجه به اثرات مخرب تغییر اقلیم به‌خصوص در مناطق خشک و نیمه‌خشک که بیشتر در معرض این پدیده هستند، پیشنهاد می‌شود اثر این پدیده نیز در نظر گرفته شود. همچنین، با توجه به تعدد الگوریتم‌های تکاملی، لازم است تا عملکرد این الگوریتم در بهبود نتایج مدل‌های منفرد مورد ارزیابی قرار گیرد. این رویکرد قابل پیاده‌سازی برای تخمین سایر شاخص‌های خشک‌سالی است.

## منابع

- [1]. Tyagi S, Zhang X, Saraswat D, Sahany S, Mishra SK, Niyogi D. Flash Drought: Review of Concept, Prediction and the Potential for Machine Learning, Deep Learning Methods. *Earth's Future*. 2022 Nov;10(11):e2022EF002723. <https://doi.org/10.1029/2022EF002723>
- [2]. Ray DK, Gerber JS, MacDonald GK, West PC. Climate variation explains a third of global crop yield variability. *Nature communications*. 2015 Jan 22; 6(1):5989. 10.1038/ncomms6989
- [3]. Bahrami N. Forecasting SPI drought index using Wavelet-Neural Networks and Support Vector Regression Models (Case study: East Azerbaijan province). Master thesis. University of Tabriz. 2017; 10-120. [In Persian]
- [4]. Ahmed K, Shahid S, Chung ES, Wang XJ, Harun SB. Climate change uncertainties in seasonal drought severity-area-frequency curves: Case of arid region of Pakistan. *Journal of Hydrology*. 2019 Mar 1;570:473-85. <https://doi.org/10.1016/j.jhydrol.2019.01.019>
- [5]. Pande CB, Al-Ansari N, Kushwaha NL, Srivastava A, Noor R, Kumar M, et al. Forecasting of SPI and meteorological drought based on the artificial neural network and M5P model tree. *Land*. 2022 Nov 14;11(11):2040. 10.3390/land11112040
- [6]. Mishra AK, Desai VR. Drought forecasting using stochastic models. *Stochastic environmental research and risk assessment*. 2005 Nov;19:326-39. 10.1007/s00477-005-0238-4
- [7]. Shamshirband S, Hashemi S, Salimi H, Samadianfard S, Asadi E, Shadkani S, et al. Predicting standardized streamflow index for hydrological drought using machine learning models. *Engineering Applications of Computational Fluid Mechanics*. 2020 Jan 1;14(1):339-50. <https://doi.org/10.1080/19942060.2020.1715844>
- [8]. Liu WT, Juárez RN. ENSO drought onset prediction in northeast Brazil using NDVI. *International Journal of Remote Sensing*. 2001 Jan 1;22(17):3483-501. <https://doi.org/10.1080/01431160010006430>
- [9]. Han P, Wang PX, Zhang SY. Drought forecasting based on the remote sensing data using ARIMA models. *Mathematical and computer modelling*. 2010 Jun 1;51(11-12):1398-403. <https://doi.org/10.1016/j.mcm.2009.10.031>
- [10]. Moreira EE, Paulo AA, Pereira LS, Mexia JT. Analysis of SPI drought class transitions using loglinear models. *Journal of Hydrology*. 2006 Nov 30;331(1-2):349-59. <https://doi.org/10.1016/j.jhydrol.2006.05.022>
- [11]. Paulo AA, Pereira LS. Prediction of SPI drought class transitions using Markov chains. *Water resources management*. 2007 Oct;21:1813-27. <https://doi.org/10.1007/s11269-006-9129-9>
- [12]. Rostami M, Pahlevanravi A, Moghadam Nia A. Comparison of artificial neural network models and adaptive neuro-fuzzy interface system in predicting the drought Mond basin of Fars province. *Journal of Natural Environment Hazard*. 2016; 4(6): 21-32. [In Persian] <https://sid.ir/paper/259188/en>
- [13]. Nguyen V, Li Q, Nguyen L. Drought forecasting using ANFIS-a case study in drought prone area of Vietnam. *Paddy and water environment*. 2017 Jul;15:605-16. <https://doi.org/10.1007/s10333-017-0579-x>
- [14]. Mokhtarzad M, Eskandari F, Jamshidi Vanjani N, Arabasadi A. Drought forecasting by ANN, ANFIS, and SVM and comparison of the models. *Environmental earth sciences*. 2017 Nov;76:1-10. <https://doi.org/10.1007/s12665-017-7064-0>
- [15]. Jalili Galgachi B. Prediction of Spi Drought Index Using Soft Calculations (Case Study of Synoptic Station of West Azerbaijan Province). Master thesis. Saba college of higher education. 2017; 132. [In Persian]
- [16]. Yacoub E, Tayfur G. Evaluation and assessment of meteorological drought by different methods in Trarza region, Mauritania. *Water Resources Management*. 2017 Feb;31:825-45. <https://doi.org/10.1007/s11269-016-1510-8>
- [17]. Ghorbani H, Vali A, Zarepour H. Prediction and Investigation of Meteorological Drought Using SARIMA Time Series and SPI Index In Isfahan Province. *jwss* 2020; 23 (4) :313-328, URL: <http://jstnar.iut.ac.ir/article-1-3840-fa.html> [In persian]
- [18] Shokrikochak S, Behnia A. Monitoring and Prediction of Khuzestan Province, Iran Drought Using SPI drought Index and Markov Chain. *Irrigation Sciences and Engineering*, 2013; 36(3): 1-12. [In persian] <https://dorl.net/dor/20.1001.1.25885952.1392.36.3.1.6>
- [19]. Amiranipur M, najafzadeh M, Mohamadi S. Forecasting Drought Situation by Standardized Precipitation Evapotranspiration Index and Artificial Intelligence Models (Case Study: Kerman Synoptic Station). *Journal of Meteorology and Atmospheric Science*, 2021; 4(3): 260-71. [In persian] doi: 10.22034/jmas.2022.356011.1184.
- [20]. Mashayekhi M, Zakeri Niri M. Meteorological, Hhydrological And Agricultural Droughts Prediction Using Wavelet Method In Tehran. *Iran-Water Resources Research*, 2020; 16(3): 120-32. [In persian]
- [21]. Achite M, Jehanzaib M, Elshaboury N, Kim TW. Evaluation of machine learning techniques for hydrological drought modeling: A case study of the Wadi Ouahrane basin in Algeria. *Water*. 2022 Jan 30;14(3):431.
- [22]. Nalbantis I, Tsakiris G. Assessment of hydrological drought revisited. *Water resources management*. 2009 Mar;23:881-97. 10.1007/s11269-008-9305-1

- [23]. Jang JS. ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*. 1993 May;23(3):665-85. <https://doi.org/10.1109/21.256541>
- [24]. Milan SG, Kayhomayoon Z, Azar NA, Berndtsson R, Ramezani MR, Moghaddam HK. Using machine learning to determine acceptable levels of groundwater consumption in Iran. *Sustainable Production and Consumption*. 2023 Jan 1;35:388-400. <https://doi.org/10.1016/j.spc.2022.11.018>
- [25]. Cawley GC, Talbot NL. Improved sparse least-squares support vector machines. *Neurocomputing*. 2002 Oct 1;48(1-4):1025-31. [https://doi.org/10.1016/S0925-2312\(02\)00606-9](https://doi.org/10.1016/S0925-2312(02)00606-9)
- [26]. Chen LH, Chen CT, Pan YG. Groundwater level prediction using SOM-RBFN multisite model. *Journal of Hydrologic Engineering*. 2010 Aug;15(8):624-31. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000218](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000218)
- [27]. Van Gestel T, Suykens JA, Lanckriet G, Lambrechts A, De Moor B, Vandewalle J. Bayesian framework for least-squares support vector machine classifiers, Gaussian processes, and kernel Fisher discriminant analysis. *Neural computation*. 2002 May 1;14(5):1115-47. [10.1162/089976602753633411](https://doi.org/10.1162/089976602753633411)
- [28]. Samadianfard S. Prediction of SPI drought index using support vector and multiple linear regressions. *Journal of Water and Soil Resources Conservation*, 2017; 6(4):1-16. [In Persian] 20.1001.1.22517480.1396.6.4.1.4
- [29]. Komasi M, Malekmahmoudi M, Montaseri H. Drought forecasting by SPI and EDI indices using ANFIS method based on C-mean and SC clustering (Case study: Kohgiluyeh and Boyer Ahmad Province). *Journal of Agricultural Meteorology*, 2017; 5(1): 36-47. [In Persian] doi: 10.22125/agmj.2017.54982
- [30]. Goldust A, Sobhani B. Studying drought and evaluating its prediction possibility in Ardabil province by using SPI index and ANFIS model. *Geographical Research*, 2015; 30(116): 135-52. [In Persian] [https://jgr.ui.ac.ir/article\\_18102.html?lang=fa](https://jgr.ui.ac.ir/article_18102.html?lang=fa)
- [31]. Steinemann A. Drought indicators and triggers: a stochastic approach to evaluation 1. *JAWRA Journal of the American Water Resources Association*. 2003 Oct;39(5):1217-33. <https://doi.org/10.1111/j.17521688.2003.tb03704.x>
- [32]. Arya Azar N, Ghordoyee Milan S, Kayhomayoon Z. Predicting monthly evaporation from dam reservoirs using LS-SVR and ANFIS optimized by Harris hawks optimization algorithm. *Environmental Monitoring and Assessment*. 2021 Nov;193:1-4. <https://doi.org/10.1007/s10661-021-09495-z>
- [33]. Kayhomayoon Z, Arya Azar N, Ghordoyee Milan S, Berndtsson R, Najafi Marghmaleki S. Application of soft computing and evolutionary algorithms to estimate hydropower potential in multi-purpose reservoirs. *Applied water science*. 2023 Sep;13(9):183. <https://doi.org/10.1007/s13201-023-02001-5>