

Presenting a combined numerical-machine learning model Galerkin-MARS for modeling meteorological drought (Case study: Khuzestan Province)

Sadaf Piri¹  | Mohammad Ansari ghojghar² 

1. Ph.D. candidate, Department of Reclamation of arid and mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Iran. Sadaf.piri@ut.ac.ir

2. Corresponding Author, Assistant Professor, Department of Reclamation of arid and mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Iran. Ansari.ghojghar@ut.ac.ir

ABSTRACT

Drought is one of the natural hazards, especially in arid and semi-arid regions. Analyzing the conditions, characteristics, and status of drought as a type of natural hazard in different regions with a focus on gathering solutions to cope drought and manage its risks is of great importance. In the present study, the analysis and prediction of meteorological drought in Khuzestan province was investigated with individual Galerkin and MARS models and the combined Galerkin-MARS model during a 30-year statistical period (1990-2020). To assess drought conditions, the Standardized Precipitation Index (SPI) obtained from data from eight synoptic stations was used. In the next step, the modeling results were compared with the aforementioned models using goodness-of-fit indices. The results indicated that the combined Galerkin-MARS model is highly efficient for estimating SPI in Khuzestan province. Also, long-term SPI time windows had higher accuracy than short-term time windows in the study area. In general, it can be said that combining numerical models with machine learning in Khuzestan Province leads to increased accuracy in SPI modeling.

Keywords: Forecasting models, Meteorological data, Nonlinear prediction, SPI

ارائه مدل تلفیقی عددی-یادگیری ماشین Galerkin-MARS به منظور مدل سازی خشک سالی هواشناسی (مطالعه موردی: استان خوزستان)

صدف پیری^۱ | محمد انصاری قوجقار^۲

۱. دانشجوی دکتری، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، ایران. رایانامه:

Sadaf.piri@ut.ac.ir

۲. نویسنده مسئول، استادیار، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، ایران. رایانامه:

Ansari.ghojghar@ut.ac.ir

چکیده

خشک سالی یکی از بلایای طبیعی، به ویژه در مناطق خشک و نیمه خشک به شمار می آید. تحلیل شرایط، مشخصات و وضعیت خشک سالی به عنوان یک نوع خطر طبیعی در مناطق مختلف با تمرکز بر جمع آوری راهکارهای مقابله با خشک سالی و مدیریت مخاطرات آن دارای اهمیت بسیار بالایی می باشد. در پژوهش حاضر، تجزیه و تحلیل و پیش بینی خشک سالی هواشناسی در استان خوزستان با مدل های انفرادی Galerkin و MARS و مدل تلفیقی هوشمند Galerkin-MARS در طول دوره آماری ۳۰ ساله (۱۳۶۹-۱۳۹۹) مورد بررسی قرار گرفت. جهت ارزیابی شرایط خشک سالی، از شاخص بارش استاندارد شده (SPI) حاصل از داده های هشت ایستگاه سینوپتیک استان خوزستان استفاده شد. در گام بعدی، نتایج مدل سازی توسط مدل های ذکر شده و با استفاده از شاخص های نیکویی برازش با یکدیگر مقایسه شدند. نتایج بیانگر این بود که مدل تلفیقی Galerkin-MARS به منظور برآورد شاخص SPI در استان خوزستان از کارایی بسیار بالایی برخوردار است. هم چنین پنجره های زمانی بلندمدت SPI از دقت بالاتری

نسبت به پنجره‌های زمانی کوتاه مدت در منطقه مورد مطالعه برخوردار بودند. به‌طور کلی می‌توان گفت که تلفیق مدل‌های عددی با یادگیری ماشین در استان خوزستان، افزایش دقت در مدل‌سازی نمایه SPI را به دنبال دارد. کلیدواژه‌ها: پیش‌بینی غیرخطی، داده‌های هواشناسی، شاخص بارش استاندارد شده، مدل‌های پیش‌بینی

۱. مقدمه

خشک‌سالی با کمبود بارش شروع شده و با توجه به شدت، مدت و تداوم آن می‌تواند مواردی از جمله رطوبت خاک، میزان پهنه‌های آبی و فعالیت‌های انسانی و اکوسیستمی را دست‌خوش تغییر کند (Woli et al., 2012). خشک‌سالی شامل چهار دسته می‌باشد؛ خشک‌سالی هواشناسی، خشک‌سالی کشاورزی، خشک‌سالی هیدرولوژیک و خشک‌سالی اجتماعی-اقتصادی (Wilhite and Glantz, 1985). تغییر اقلیم نتیجه تغییرات الگوی آب‌وهوایی به‌دلیل انتشار گازهای گلخانه‌ای ناشی از فعالیت‌های انسانی است (Fawzy et al., 2020). تغییر اقلیم نشأت گرفته از فعالیت‌های انسانی (Raymond et al., 2020) و تغییر در الگوهای بارش (Yousefi and Moridi, 2022) عوامل اساسی در افزایش ناهنجاری‌ها و بلایای طبیعی هستند. خشک‌سالی یک چالش فراگیر و رو به رشد برای جوامع انسانی است که تأثیرات عمیق و درازمدت بر امنیت غذایی دارد (Ahmed, 2020). تحلیل شرایط، مشخصات و وضعیت خشک‌سالی به‌عنوان یک نوع خطر طبیعی در مناطق مختلف با تمرکز بر جمع‌آوری راهکارهای مقابله با خشک‌سالی و مدیریت مخاطرات آن دارای اهمیت بسیار بالایی می‌باشد (Negahban et al., 2024). بنابراین، برای شناخت نوسانات مکانی و زمانی خشک‌سالی و برنامه‌ریزی در خصوص تدابیر مدیریتی اثرگذار برای مواجهه با آن، انجام تحقیقات پیرامون این موضوع، امری ضروری است (Moisa et al., 2022). تحقیقات و پژوهش‌های گوناگونی در خصوص مدل‌سازی و پیش‌بینی خشک‌سالی در داخل و خارج از کشور صورت پذیرفته است. Shamloo et al. (2023) به ارزیابی روش‌های پیش‌بینی شاخص خشک‌سالی در حوضه آبخیز دریاچه ارومیه بر پایه تصاویر ماهواره‌ای و با بهره‌گیری از روش‌های یادگیری ماشین و یادگیری عمیق پرداختند. نتایج حاصل از این پژوهش بیانگر آن بود که روش‌های یادگیری ماشین و یادگیری عمیق، از کارایی بالایی در خصوص ارزیابی، پیش‌بینی و مدل‌سازی خشک‌سالی برخوردار می‌باشند. Babaali (2024) et al. در پژوهشی به پیش‌بینی شاخص SPI¹ با استفاده از مدل هیبریدی مبتنی بر یادگیری ماشین در استان لرستان پرداختند. نتایج نشان دهنده رویکرد موثر مدل‌های هوشمند بر پایه رگرسیون بردار پشتیبان در پیش‌بینی خشک‌سالی بود. Adnan et al. (2023) به بررسی مدل‌سازی خشک‌سالی در کشور پاکستان بر اساس روش‌های اکتشافی و جدید یادگیری ماشین پرداختند. این پژوهش نشان داد که مدل‌های اکتشافی، نتایج دقیقی در خصوص پیش‌بینی خشک‌سالی ارائه می‌دهند. Babaali et al. (2019) به پیش‌بینی خشک‌سالی هواشناسی بر پایه مدل آماری با استفاده از یادگیری ماشین در استان Shaanxi چین پرداختند. نتایج نشان داد تلفیق اثرات غیرخطی و تاخیری پیش‌بینی می‌تواند به‌طور معنی‌داری دقت پیش‌بینی خشک‌سالی را بهبود بخشد. پژوهش دیگری خشک‌سالی را با توسعه یک مدل پیش‌بینی ترکیبی با بهره‌گیری از تجزیه حالت تجربی حذف‌شده^۲ (EMD) و یک شبکه باور عمیق^۳ (DBN) پیش‌بینی می‌نمایند. در روش پیشنهادی ابتدا داده‌ها را با استفاده از مدل EMD به چندین تابع حالت ذاتی^۴ (IMF) تجزیه می‌کند. نتایج به‌دست‌آمده با استفاده از روش پیشنهادی با روش‌های استاندارد مانند پرسپترون چند لایه^۵ (MLP) و رگرسیون بردار پشتیبان^۶ (SVR) مقایسه گردید. مدل ترکیبی پیشنهادی، بهبود در دقت پیش‌بینی به‌ویژه برای پیش‌بینی‌های چند مرحله‌ای را نشان داد (Agana & Homaifar, 2018). هم‌چنین Belayneh et al. (2016) از روش‌های Bootstrap و مدل تقویتی (اثر تقویتی) برای پیش‌بینی خشک‌سالی با دقت بالا با بهره‌گیری از سری SPI در حوضه رودخانه آواش اتیوپی استفاده نمود. نتایج نشانگر آن بود که دقت و عملکرد رگرسیون بردار پشتیبان تقویت‌کننده مبتنی بر موجک (SVR) بهترین کارایی را در

میان مدل‌های پیشنهادی داشت. (Mohammadi et al. (2022 در تحقیقی به پیش‌بینی و مدل‌سازی خشک‌سالی به روش هیبریدی موجک و الگوریتم‌های شبکه عصبی با استفاده از شاخص SPI در مقیاس‌های زمانی ۳، ۶، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه در ۱۰ ایستگاه کشور پرداختند. نتایج به‌دست آمده نشان داد که تلفیق تکنیک موجک با سه مدل انفرادی به‌کار رفته در پژوهش، موجب بهبود نتایج مدل‌سازی در پژوهش می‌شود. استان خوزستان به سبب ویژگی‌های اقلیمی منحصربه‌فرد (قرارگیری مناطق خشک و مرطوب، وابستگی به رودخانه‌های بزرگ مانند کرخه و کارون، و اثرپذیری از تغییرات اقلیمی) نیازمند مدل‌های خاص و مناسب برای پیش‌بینی خشک‌سالی است. به‌کارگیری روش Galerkin در کنار MARS می‌تواند به مدل‌سازی دقیق‌تر پویایی‌های اقلیمی و بهبود پیش‌بینی در شرایط داده‌های محدود یا پیچیده کمک کند. این رویکرد قادر است به‌عنوان یک راه‌حل برای چالش‌های موجود در مدل‌های سنتی یادگیری ماشین عمل نماید. تاکنون پژوهشی در خصوص ارائه مدل تلفیقی عددی-یادگیری ماشین به‌منظور پیش‌بینی شاخص SPI در کشور انجام نشده است. با توجه به اینکه مدل‌های عددی (ریاضی) از هزینه‌های محاسباتی کمتر و سرعت پردازش بالایی برخوردار هستند، لذا ترکیب این مدل‌ها با الگوریتم‌های فراکاوشی یادگیری ماشین، که به دلیل آموزش نوروں‌های عصبی مصنوعی از دقت بالاتری برخوردار هستند، می‌تواند نقاط ضعف هر دو نوع مدل را برطرف نموده و به ارائه یک مدل هوشمند تلفیقی و جامع منجر شود. از این رو، در پژوهش حاضر به مدل‌سازی خشک‌سالی هواشناسی با استفاده از مدل تلفیقی عددی-یادگیری ماشین Galerkin-MARS در استان خوزستان پرداخته شده است.

۲. مواد و روش‌ها

۱.۲. محدوده مطالعاتی

استان خوزستان با مساحت ۶۴۰۵۷ کیلومتر مربع بین ۲۹°۵۸' تا ۳۳°۴' عرض شمالی از خط استوا و ۴۷°۳۱' تا ۵۰°۳۹' طول شرقی از نصف‌النهار گرینویچ در جنوب غرب ایران قرار گرفته است. شمال و شرق استان خوزستان، از سلسله کوه‌های زاگرس محصور می‌باشد که به طرف جنوب غربی، ارتفاع آن کمتر شده و تا مناطق جنوبی‌تر به‌صورت تپه ماهورهایی نمایان می‌گردد. مناطق کوهستانی به‌طور عمده در شمال و شرق استان قرار دارد و حدوداً دو پنجم مساحت کل استان را در بر می‌گیرد. موقعیت کشوری و استانی منطقه مورد مطالعه و ایستگاه‌های بررسی شده آن، مطابق شکل (۱) است.




Figure 1. Location map of study area and selected stations

۲.۲ داده‌ها

در پژوهش حاضر برای استخراج پهنه‌های خشکسالی هشت ایستگاه هواشناسی (صفی‌آباد دزفول، بستان، آبادان، امیدیه، مسجد سلیمان، بندر ماهشهر، اهواز و رامهرمز) واقع در استان خوزستان، از داده‌های بارش طی ۳۰ سال آماری مشترک (۱۳۶۹-۱۳۹۹) استفاده گردید. در گام بعدی، پس از دریافت و آماده‌سازی داده‌های بارش از سایت هواشناسی کشور، مقادیر شاخص بارش استاندارد شده (SPI) جهت تشخیص سال‌های خشک و تر محاسبه گردید. این شاخص اولین بار توسط *McKee et al.* (1993) ارائه شد. این شاخص جهت ارزیابی خشک‌سالی مورد استفاده قرار می‌گیرد و به وسیله آن می‌توان زمان آغاز، شدت و همچنین مدت وقوع خشک‌سالی را در دوره‌های زمانی گوناگون مشخص نمود. با در نظر گرفتن ماهیت استانداردسازی شده این شاخص، اساسی‌ترین نقطه قوت آن، توانایی مقایسه مشخصه‌های خشک‌سالی در بازه‌های زمانی و مکانی گوناگون و همچنین انواع آب‌وهوا می‌باشد. برای ارزیابی این شاخص می‌توان مقادیر بارش ماهانه یا مجموع بارش در دوره‌های زمانی مدنظر را محاسبه کرد. این شاخص از طریق رابطه ۱ محاسبه می‌شود و طبقه‌بندی آن در جدول ۱ ارائه شده است.

$$SPI = \frac{(P - \mu)}{S} \quad \text{رابطه (۱)}$$

که در آن، P مقدار بارش هر ماه، μ میانگین بارش بلندمدت و S انحراف معیار مقدار بارش است.

Table 1. Drought classification based on the SPI value (*McKee et al.*, 1993)

SPI values	2.00 or more	1.50 to 1.99	1.00 to 1.49	0.0 to 0.99	0.0 to -0.99	-1.00 to -1.49	-1.50 to -1.99	-2.00 or less
Drought classification	Extreme Wet	Severe Wet	Moderate Wet	Mild Wet	Mild Drought	Moderate Drought	Severe Drought	Extreme Drought

۳.۲ روش بدون المان Galerkin (EFG)^۹

این روش نسخه پیشرفته‌تری از روش عناصر پخش شده^۹ (DEM) است که توسط *Belytschko et al.* (1994) ارائه شده است. از مشخصه‌های اصلی روش EFG می‌توان به استفاده از روش حداقل مربعات^{۱۰} (MLS) جهت ساخت توابع پایه گالرکین اشاره کرد. این روش هم‌چنین با استفاده از فرم ضعیف معادله انتگرالی مقید گالرکین^{۱۱} به عنوان یک ابزار برای تبدیل معادلات دیفرانسیل به یک سیستم معادلات جبری و تشکیل شبکه پس‌زمینه جهت انتگرال‌گیری به منظور ساخت ماتریس‌های سیستم در روش‌های عددی، می‌پردازد (*Liu et al.*, 2002). روش MLS به عنوان ابزاری جهت تولید توابع تقریب مناسب، در فضای حل، استفاده می‌شود تا خطای تقریب به حداقل برسد. این ویژگی به‌ویژه در مسائل پیچیده یا شرایطی که داده‌های با دقت پایین‌تر در دسترس هستند، بسیار کاربردی است.

۴.۲ رگرسیون اسپلاین چندمتغیره تطبیقی (MARS)^{۱۲}

رگرسیون اسپلاین چندمتغیره تطبیقی یک روش غیرخطی و ناپارامتریک در تحلیل رگرسیون است برای نخستین بار توسط (*Friedman*, 2002) معرفی و ارائه گردید. این روش، پاسخ‌های غیرخطی را میان ورودی‌ها و خروجی یک سامانه، توسط مجموعه‌ای از توابع خطی چندقطعه‌ای با گرادبان‌های گوناگون مدل‌سازی می‌کند. نقاط پایانی این توابع چندقطعه‌ای، به عنوان گره شناخته می‌شوند. گره، انتهای یک ناحیه از داده‌ها و ابتدای ناحیه‌ای دیگر از داده‌ها را مشخص می‌نماید. مدل به عنوان ترکیب خطی توابع و روابط متقابل آن‌ها تشکیل و در رابطه ۳ بیان شده است.

$$f(x) = \beta \cdot \sum_{m=1}^M \beta_m \lambda_m(x) \quad \text{رابطه (۳)}$$

که در آن، λ_m به عنوان پارامتر هموارسازی شناخته می‌شود. هر $\lambda_m(x)$ یک تابع محاسباتی چندقطعه‌ای محسوب

می‌شود و قابلیت این را دارد که از گرادیان‌های گوناگون تشکیل شود. مجموعه پارامترهای B در اصل ضرایب توابع می‌باشند که با بهره‌گیری از روش کمترین مربعات خطا ارزیابی و برآورد می‌شوند. مدل رگرسیون اسپلاین چندمتغیره تطبیقی برای داده‌های پیوسته با دامنه محدود مانند داده‌های اقلیمی مناسب است. این مدل با توابع پایه اسپلاین، بدون نیاز به فرضیات توزیعی، روابط غیرخطی و تعاملات پیچیده را به صورت تکه‌ای مدل‌سازی می‌نماید. این خصوصیت، همراه با انتخاب خودکار متغیرهای کلیدی، دقت پیش‌بینی خشک‌سالی هواشناسی را در شرایط اقلیمی متنوع خوزستان و داده‌های محدود ایستگاه‌های سینوپتیک ارتقا می‌دهد.

۵.۲. مدل‌های پیش‌بینی

در پژوهش حاضر، از مدل‌های مذکور برای پیش‌بینی شاخص SPI با پنجره‌های زمانی ۱، ۳، ۶ و ۱۲ ماهه استفاده گردید. به عنوان مثال، مدل اول پیش‌بینی می‌کند که میزان SPI_{12} در زمان $t+1$ (آینده)، تابعی از میزان SPI_{12} در زمان t (حال) است. به عبارتی دیگر، مدل از داده‌های SPI_{12} در زمان t به عنوان ورودی استفاده کرده و با بهره‌گیری از الگوریتم‌های مدنظر، میزان SPI_{12} را در زمان $t+1$ پیش‌بینی می‌نماید. در سایر مدل‌ها نیز بر حسب پنجره زمانی آن‌ها این عمل انجام می‌پذیرد.

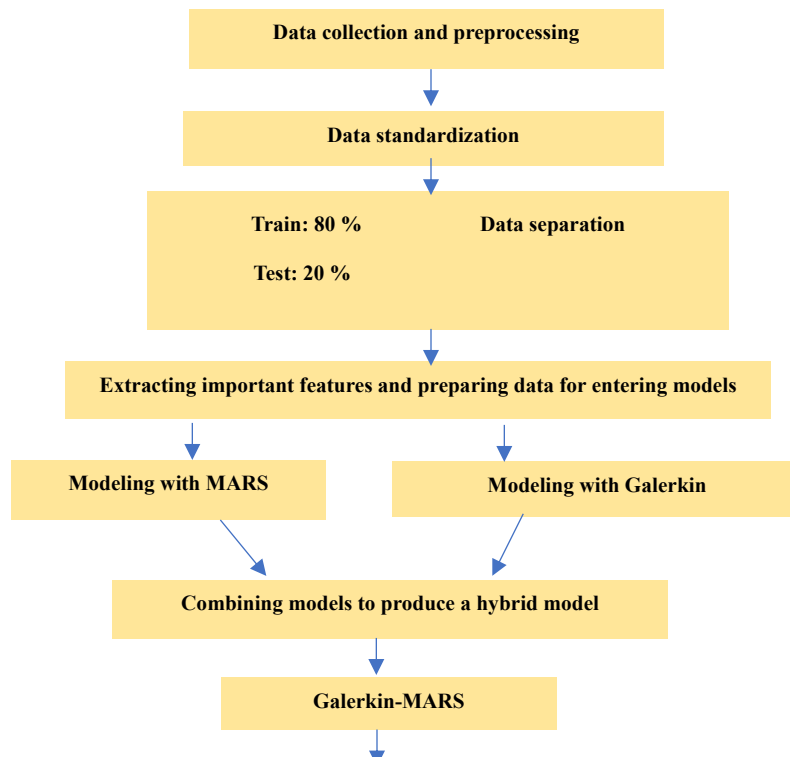
مدل یک $SPI_{12(t+1)} = f(SPI_{12(t)})$

مدل دو $SPI_{6(t+1)} = f(SPI_{6(t)})$

مدل سه $SPI_{3(t+1)} = f(SPI_{3(t)})$

مدل چهار $SPI_{1(t+1)} = f(SPI_{1(t)})$

نمودار جریانی پژوهش حاضر در شکل ۲ نمایش داده شده است.






Figure 2. Flowchart of modeling steps with the hybrid Galerkin-MARS model

۳. نتایج و بحث

هدف از این پژوهش، پیش‌بینی خشک‌سالی هواشناسی و تعیین کارایی الگوریتم‌های یادگیری ماشین برای نشان دادن شرایط خشک‌سالی است؛ از این رو هشت ایستگاه سینوپتیک واقع در استان خوزستان (صفی‌آباد دزفول، بستان، آبادان، امیدیه، مسجد سلیمان، بندر ماهشهر، اهواز و رامهرمز) مورد مطالعه و بررسی قرار گرفت. در شکل ۳، پهنه‌بندی خشک‌سالی هواشناسی ایستگاه‌های مورد مطالعه در طول دوره آماری ذکر شده نمایش داده شده است.




Figure 3. Zoning of meteorological drought at the studied stations during the statistical period

نتایج به‌دست آمده از محاسبه معیارهای ارزیابی R ، $RMSE$ ، NS و MAE برای تعیین بهترین مدل در جدول‌های ۲ تا ۴ ارائه گردیده است. بر اساس جدول ۲ و با توجه به نتایج به‌دست آمده از معیارهای ارزیابی نیکویی برازش در هشت ایستگاه مورد مطالعه، به‌صورت کلی، SPI ۱۲ ماهه و ۶ ماهه نتایج بهتر و با دقت بالاتری را نسبت به SPI ۳ ماهه و ۱ ماهه ارائه دادند. در مقایسه SPI ۱۲ ماهه با ۶ ماهه نیز SPI ۱۲ ماهه عملکرد بهتری از خود نشان داد. به‌عنوان مثال، در ایستگاه رامهرمز، استفاده از SPI ۱۲ ماهه به جای SPI ۱ ماهه موجب کاهش مقادیر $RMSE$ و MAE به‌ترتیب از ۰/۴۳۱ و ۰/۳۸۹ به ۰/۴۲۷ و ۰/۳۸۳ گردید. علاوه بر این، مقادیر R و NS نیز از ۰/۶۸۷ و ۰/۶۵۹ به ۰/۶۹۱ و ۰/۶۶۲ افزایش یافت. بنابراین استفاده از پنجره‌های زمانی بلندمدت در مدل‌سازی و پیش‌بینی شاخص SPI در مقایسه با پنجره‌های زمانی کوتاه‌مدت توسط مدل Galerkin در استان خوزستان سبب افزایش عملکرد و بهبود خروجی‌ها می‌گردد، اما به‌طور کلی مدل انفرادی Galerkin در مقایسه با مدل یادگیری ماشین MARS نتایج دقیقی در خصوص پیش‌بینی

شاخص SPI ارائه نمی‌دهد. با عنایت به این که این روش بر اساس حل معادلات فیزیکی و دیفرانسیل جزئی عمل می‌کند، ممکن است در شناسایی و مدل‌سازی الگوهای غیرخطی مانند تغییرات اقلیمی و خشک‌سالی عملکرد ضعیفی داشته باشد و توانایی شبیه‌سازی پیچیدگی‌های جوی را نداشته باشد. پدیده‌های اقلیمی هم‌چون خشک‌سالی واضحاً غیرخطی بوده و وقوع آن‌ها به عوامل گوناگونی بستگی دارند. در جدول ۳ نیز نتایج حاصله از شاخص‌های نیکویی برازش مدل MARS ارائه شده است. در این مدل نیز SPI ۱۲ ماهه، دقت بالاتری نسبت به سایر پنجره‌های زمانی دارا می‌باشد. به عنوان مثال، در ایستگاه مسجدسلیمان، استفاده از SPI ۱۲ ماهه به جای SPI ۶ ماهه موجب کاهش مقادیر RMSE و MAE به ترتیب از ۰/۳۱۵ و ۰/۱۸۹ به ۰/۳۱۳ و ۰/۱۸۸ گردید. علاوه بر این، مقادیر R و NS نیز از ۰/۹۴۴ و ۰/۹۱۴ به ۰/۹۴۶ و ۰/۹۱۵ افزایش یافت. بنابر نتایج حاصله از جدول ۲ و ۳، مدل MARS با اختلاف معنی‌داری نسبت به مدل Galerkin از دقت بیشتری برخوردار است. به بیان دیگر می‌توان اظهار نمود که مدل یادگیری ماشین MARS قادر است در شرایطی که مدل‌های عددی دارای ضعف هستند، ارتباطات پنهان در داده‌های هواشناسی را استخراج نموده و دقت پیش‌بینی را افزایش دهد. بنابراین این مدل نسبت به مدل عددی Galerkin قادر به شناخت بهتر روابط غیرخطی میان متغیرهای اقلیمی می‌باشد. در جدول ۴ با ترکیب مدل Galerkin و MARS سعی شد عملکرد مدل به منظور افزایش دقت و بهبود نتایج پیش‌بینی خشک‌سالی در ایستگاه‌های مورد مطالعه افزایش یابد. مقادیر RMSE، R، NS و MAE پس از ترکیب دو مدل مذکور نسبت به مدل‌های انفرادی، به ترتیب با کاهش، افزایش، افزایش و کاهش روبرو شد. به عنوان مثال در ایستگاه آبادان، مقادیر NS و R مدل هیبریدی Galerkin-MARS در مقایسه با مدل انفرادی Galerkin، به ترتیب از ۰/۶۸۵ و ۰/۷۰۹ به ۰/۹۴۹ و ۰/۹۷۳ رسید. بر همین اساس می‌توان نتیجه گرفت که مدل تلفیقی عددی-یادگیری ماشین Galerkin-MARS افزایش عملکرد را نسبت به مدل‌های انفرادی Galerkin و MARS از خود نشان داد. این مدل، بهترین خصیصه‌های هر دو روش از جمله حفظ مدل‌سازی فیزیکی و دینامیکی و هم‌چنین کاهش خطا در پیش‌بینی را شامل می‌شود. به عبارتی این مدل تلفیقی الگوهای پیچیده را شناسایی نموده و با بهینه‌سازی پیش‌بینی‌ها یک مدل دقیق‌تر و کارآمدتر را ارائه می‌دهد. از سویی دیگر، فاصله شایان توجهی از لحاظ دقت میان مدل تلفیقی Galerkin-MARS و دو مدل انفرادی ذکر شده وجود دارد. از این رو می‌توان نتیجه گرفت که مدل تلفیقی Galerkin-MARS به منظور برآورد نمایه SPI در استان خوزستان از کارایی بالایی برخوردار است. نتایج این بخش با برخی از پژوهش‌ها مطابقت دارد و در بررسی خشک‌سالی با استفاده از مدل‌های تلفیقی مبتنی بر داده‌های اقلیمی، برتری قابل توجه مدل‌های تلفیقی را نسبت به مدل‌های انفرادی گزارش کردند.

(Bazrafshan, et al 2015; Hosseini-Moghari et al 2016 ;Mohammadi et al., 2022)

Table 2. Statistical results of the Galerkin model for predicting SPI

Test dataset				Train dataset				Combination number	Station
R	NS	MAE	RMSE	R	NS	MAE	RMSE		
0.709	0.685	0.352	0.411	0.741	0.697	0.308	0.391	SPI ₁₂	Abadan
0.709	0.684	0.353	0.412	0.739	0.696	0.308	0.391	SPI ₆	
0.707	0.683	0.354	0.412	0.736	0.695	0.311	0.394	SPI ₃	
0.711	0.682	0.355	0.413	0.735	0.694	0.314	0.392	SPI ₁	
0.706	0.682	0.357	0.414	0.734	0.693	0.317	0.393	SPI ₁₂	Bostan
0.703	0.681	0.359	0.415	0.733	0.692	0.321	0.395	SPI ₆	
0.702	0.679	0.361	0.416	0.732	0.691	0.323	0.397	SPI ₃	

0.702	0.678	0.362	0.416	0.731	0.689	0.322	0.399	SPI₁	Ahvaz
0.701	0.676	0.364	0.417	0.734	0.688	0.324	0.401	SPI₁₂	
0.701	0.676	0.365	0.418	0.729	0.687	0.325	0.403	SPI₆	
0.699	0.675	0.366	0.419	0.727	0.686	0.327	0.405	SPI₃	
0.698	0.674	0.367	0.421	0.726	0.685	0.328	0.407	SPI₁	
0.697	0.673	0.369	0.422	0.725	0.684	0.329	0.406	SPI₁₂	Bandar mahshahr
0.696	0.671	0.371	0.423	0.724	0.683	0.331	0.409	SPI₆	
0.695	.669	0.372	0.424	0.723	0.681	0.332	0.411	SPI₃	
0.695	0.668	0.374	0.425	0.721	0.679	0.334	0.413	SPI₁	
0.694	0.667	0.376	0.425	0.719	0.678	0.335	0.414	SPI₁₂	
0.693	0.666	0.373	0.425	0.718	0.676	0.337	0.415	SPI₆	Omidiyeh
0.692	0.664	0.379	0.425	0.716	0.675	0.339	0.416	SPI₃	
0.691	0.663	0.381	0.426	0.715	0.674	0.341	0.417	SPI₁	
0.691	0.662	0.383	0.427	0.714	0.673	0.342	0.418	SPI₁₂	
0.689	0.661	0.385	0.427	0.714	0.671	0.344	0.419	SPI₆	
0.688	0.661	0.386	0.429	0.713	0.669	0.345	0.421	SPI₃	Ramhormoz
0.687	0.659	0.389	0.431	0.712	0.668	0.346	0.423	SPI₁	
0.686	0.657	0.391	0.432	0.711	0.667	0.347	0.424	SPI₁₂	
0.683	0.656	0.392	0.433	0.710	0.665	0.348	0.425	SPI₆	
0.675	0654	0.392	0.434	0.709	0.664	0.349	0.427	SPI₃	
0.674	0.653	0.393	0.435	0.708	0.663	0.351	0.427	SPI₁	Masjed soleyman
0.673	0.652	0.395	0.437	0.706	0.662	0.353	0.429	SPI₁₂	
0.675	0.651	0.396	0.438	0.705	0.661	0.357	0.431	SPI₆	
0.671	0.649	0.397	0.439	0.704	0.659	0.359	0.432	SPI₃	
0.669	0.648	0.399	0.441	0.703	0.657	0.361	0.433	SPI₁	
0.673	0.652	0.395	0.437	0.706	0.662	0.353	0.429	SPI₁₂	Safiabad Dezful
0.675	0.651	0.396	0.438	0.705	0.661	0.357	0.431	SPI₆	
0.671	0.649	0.397	0.439	0.704	0.659	0.359	0.432	SPI₃	
0.669	0.648	0.399	0.441	0.703	0.657	0.361	0.433	SPI₁	
0.673	0.652	0.395	0.437	0.706	0.662	0.353	0.429	SPI₁₂	

Table 3. Statistical results of the MARS model for predicting SPI

Test dataset				Train dataset				Combination number	Station
R	NS	MAE	RMSE	R	NS	MAE	RMSE		
0.861	0.843	0.284	0.317	0.894	0.871	0.256	0.303	SPI ₁₂	
0.861	0.841	0.285	0.319	0.893	0.869	0.257	0.304	SPI ₆	Abadan
0.860	0.839	0.286	0.321	0.892	0.867	0.259	0.305	SPI ₃	
0.859	0.838	0.287	0.323	0.891	0.865	0.261	0.305	SPI ₁	
0.857	0.837	0.287	0.325	0.887	0.864	0.263	0.306	SPI ₁₂	
0.854	0.837	0.289	0.328	0.886	0.863	0.265	0.307	SPI ₆	Bostan
0.853	0.837	0.291	0.328	0.885	0.863	0.267	0.307	SPI ₃	
0.852	0.836	0.292	0.329	0.884	0.862	0.269	0.309	SPI ₁	
0.851	0.835	0.292	0.331	0.883	0.861	0.271	0.313	SPI ₁₂	
0.849	0.834	0.292	0.332	0.881	0.859	0.276	0.314	SPI ₆	Ahvaz
0.848	0.831	0.293	0.334	0.879	0.857	0.275	0.315	SPI ₃	
0.847	0.829	0.294	0.336	0.877	0.856	0.279	0.316	SPI ₁	
0.847	0.827	0.295	0.337	0.876	0.855	0.281	0.316	SPI ₁₂	
0.847	0.824	0.295	0.337	0.875	0.853	0.283	0.319	SPI ₆	Bandar mahshahr
0.847	0.823	0.295	0.341	0.873	0.851	0.285	0.321	SPI ₃	
0.846	0.821	0.296	0.342	0.872	0.849	0.289	0.322	SPI ₁	
0.845	0.819	0.299	0.343	0.871	0.848	0.291	0.325	SPI ₁₂	
0.844	0.818	0.301	0.345	0.869	0.847	0.293	0.327	SPI ₆	Omidiyeh
0.843	0.816	0.302	0.347	0.868	0.846	0.293	0.331	SPI ₃	
0.841	0.815	0.305	0.351	0.865	0.845	0.295	0.332	SPI ₁	
0.839	0.814	0.309	0.352	0.864	0.843	0.294	0.334	SPI ₁₂	
0.837	0.812	0.308	0.353	0.863	0.842	0.297	0.337	SPI ₆	Ramhormoz
0.834	0.811	0.311	0.354	0.861	0.841	0.297	0.341	SPI ₃	
0.833	0.809	0.312	0.355	0.859	0.839	0.298	0.343	SPI ₁	
0.831	0.808	0.314	0.357	0.857	0.837	0.299	0.347	SPI ₁₂	
0.829	0.808	0.317	0.359	0.856	0.836	0.301	0.348	SPI ₆	Masjed soleyman

0.827	0.805	0.319	0.361	0.854	0.835	0.302	0.349	SPI₃	Safiabad Dezful
0.826	0.804	0.320	0.362	0.853	0.834	0.304	0.349	SPI₁	
0.825	0.802	0.322	0.363	0.852	0.833	0.306	0.351	SPI₁₂	
0.823	0.801	0.323	0.363	0.851	0.831	0.307	0.354	SPI₆	
0.821	0.799	0.325	0.364	0.847	0.829	0.309	0.357	SPI₃	
0.817	0.796	0.327	0.365	0.843	0.827	0.309	0.358	SPI₁	







Table 4. Statistical results of the Galerkin-MARS model for predicting SPI

Test dataset				Train dataset				Combination number	Station
R	NS	MAE	RMSE	R	NS	MAE	RMSE		
0.973	0.949	0.157	0.271	0.994	0.976	0.096	0.243	SPI₁₂	Abadan
0.971	0.948	0.158	0.274	0.994	0.975	0.096	0.244	SPI₆	
0.968	0.947	0.159	0.275	0.993	0.974	0.097	0.247	SPI₃	
0.969	0.946	0.161	0.275	0.992	0.971	0.099	0.251	SPI₁	
0.967	0.945	0.162	0.279	0.991	0.969	0.101	0.252	SPI₁₂	Bostan
0.967	0.944	0.163	0.283	0.989	0.968	0.104	0.253	SPI₆	
0.966	0.943	0.165	0.284	0.987	0.967	0.107	0.256	SPI₃	
0.965	0.942	0.166	0.285	0.984	0.967	0.108	0.257	SPI₁	
0.965	0.941	0.167	0.286	0.985	0.967	0.109	0.259	SPI₁₂	Ahvaz
0.964	0.939	0.169	0.289	0.985	0.966	0.111	0.261	SPI₆	
0.963	0.937	0.171	0.288	0.983	0.965	0.112	0.262	SPI₃	
0.962	0.936	0.172	0.291	0.982	0.964	0.113	0.263	SPI₁	
0.961	0.935	0.173	0.293	0.981	0.963	0.117	0.265	SPI₁₂	Bandar mahshahr
0.960	0.933	0.174	0.294	0.981	0.962	0.121	0.268	SPI₆	
0.959	0.931	0.175	0.295	0.979	0.961	0.123	0.269	SPI₃	
0.958	0.929	0.176	0.297	0.978	0.965	0.119	0.271	SPI₁	
0.957	0.927	0.177	0.299	0.976	0.963	0.125	0.274	SPI₁₂	Omidyeh
0.956	0.925	0.179	0.302	0.975	0.961	0.127	0.275	SPI₆	

0.954	0.924	0.181	0.303	0.974	0.959	0.131	0.278	SPI₃	
0.951	0.923	0.183	0.304	0.973	0.957	0.132	0.281	SPI₁	
0.948	0.922	0.184	0.305	0.969	0.954	0.133	0.284	SPI₁₂	
0.947	0.921	0.185	0.307	0.972	0.953	0.134	0.287	SPI₆	Ramhormoz
0.946	0.919	0.186	0.309	0.971	0.952	0.135	0.289	SPI₃	
0.946	0.917	0.187	0.311	0.967	0.951	0.137	0.291	SPI₁	
0.946	0.915	0.188	0.313	0.965	0.949	0.138	0.292	SPI₁₂	
0.944	0.914	0.189	0.315	0.964	0.948	0.141	0.293	SPI₆	Masjed soleyman
0.943	0.913	0.191	0.317	0.963	0.947	0.142	0.293	SPI₃	
0.941	0.913	0.192	0.319	0.961	0.946	0.143	0.293	SPI₁	
0.939	0.911	0.193	0.321	0.959	0.945	0.145	0.295	SPI₁₂	
0.937	0.909	0.194	0.322	0.957	0.944	0.146	0.296	SPI₆	Safiabad Dezful
0.934	0.907	0.195	0.323	0.956	0.943	0.147	0.294	SPI₃	
0.933	0.905	0.196	0.324	0.954	0.942	0.148	0.297	SPI₁	

نتایج پیش‌بینی شاخص SPI بیانگر عملکرد مناسب مدل تلفیقی عددی-یادگیری ماشین Galerkin-MARS در هشت ایستگاه مورد مطالعه در استان خوزستان است. علاوه بر این، مدل ذکر شده با دارا بودن بیشترین مقدار R و ضریب NS و کمترین مقدار MAE و RMSE، بهترین مدل برای پیش‌بینی در این استان می‌باشد. مدل Galerkin که کمترین عملکرد را در بین سه مدل بررسی شده دارد برای مدل‌سازی فرآیندهای پیچیده و حل معادلات دیفرانسیل کارایی مناسبی دارند اما ممکن است به‌کارگیری انفرادی آن‌ها در برخی شرایط، دقت و صحت لازم را نداشته باشند اما ترکیب مدل‌های عددی و یادگیری ماشین در استان خوزستان موجب افزایش دقت و بهبود عملکرد شدند. هم‌چنین با توجه به نتایج کلی مدل‌ها، پنجره‌های زمانی بلندمدت نسبت به پنجره‌های زمانی کوتاه مدت، نتایج بهتری به‌منظور پیش‌بینی شاخص SPI در استان خوزستان نشان داد. در نواحی خشک و نیمه‌خشک هم‌چون استان خوزستان که بارش اکثراً در فصول خاصی رخ می‌دهد و به‌طور معمول فرآیند بارندگی در آن پراکندگی مکانی و زمانی دارد، SPI ۱۲ ماهه بهتر می‌تواند تغییرات الگوی بارش و مشخصات خشک‌سالی را نمایش دهد. در مقابل، پنجره‌های زمانی کوتاه‌مدت تحت تاثیر نوسانات مقطعی بارش می‌باشند و نتیجه واضح و واقعی از شرایط خشک‌سالی نشان نمی‌دهد. شکل ۴، مقادیر مشاهده شده و پیش‌بینی شده شاخص SPI ۱۲ ماهه را برای داده‌های بخش آزمون ایستگاه‌های استان خوزستان نمایش می‌دهد. در این شکل، رابطه بین مقادیر مشاهده شده و پیش‌بینی شده شاخص SPI در تمامی ایستگاه‌ها، با نیم‌ساز ۴۵ درجه ارزیابی گردید. مدل Galerkin با کمترین دقت و بیشترین پراکندگی نسبت به سایر مدل‌ها، بیشترین اختلاف و فاصله را با نیم‌ساز ربع اول و سوم دارد. مدل تلفیقی Galerkin-MARS نیز با بیشترین تطابق نسبت به نیم‌ساز ربع اول و سوم،

بیشترین بازدهی و کارایی را در بین مدل‌های بررسی شده به همراه دارد. شکل ۵ نیز نشان دهنده مقایسه مقادیر مشاهده شده و پیش‌بینی شده شاخص SPI با استفاده از شاخص‌های نیکویی برازش در استان خوزستان می‌باشد.







Figure 4. Comparison of observed and predicted SPI values using Galerkin, MARS, and Galerkin-MARS models






Figure 5. Comparison of goodness of fit indices for stations in Khuzestan province - SPI₁₂ combination

۴. جمع‌بندی و نتیجه‌گیری

خشک‌سالی یکی از بلاای طبیعی، علی‌الخصوص در مناطق خشک و نیمه‌خشک به‌شمار می‌آید. استان خوزستان به سبب دارا بودن موقعیت جغرافیایی حساس و وابستگی شدید به منابع آب، در مقابل خشک‌سالی به‌شدت آسیب‌پذیر است. خشک‌سالی در این استان می‌تواند تبعاتی هم‌چون کاهش سطح آب تالاب‌های استراتژیک، کاهش آب مورد نیاز صنایع، کاهش تولیدات کشاورزی، ایجاد مشکلات اجتماعی و مهاجرت روستاییان به شهرها و عدم امنیت غذایی را به همراه داشته باشد. بر همین اساس در پژوهش حاضر، دقت و عملکرد دو مدل Galerkin و MARS و هم‌چنین تلفیق آن‌ها به‌صورت مدل دوگانه Galerkin-MARS در هشت ایستگاه سینوپتیک استان خوزستان (صفی‌آباد دزفول، بستان، آبادان، امیدیه، مسجد سلیمان، بندر ماهشهر، اهواز و رامهرمز) در طول دوره آماری ۳۰ ساله (۱۳۶۸ تا ۱۳۹۹) مقایسه و تحلیل گردید. طبق نتایج مدل‌ها، به‌طور کلی مدل Galerkin نتایج دقیقی در خصوص پیش‌بینی شاخص SPI ارائه نمی‌دهد. هم‌چنین مدل MARS با اختلاف معنی‌داری نسبت به مدل Galerkin از دقت بیشتری برخوردار است. در نهایت مدل تلفیقی عددی-یادگیری ماشین Galerkin-MARS بهبود عملکرد را نسبت به مدل‌های انفرادی Galerkin و MARS از خود نشان داد. از سویی دیگر فاصله قابل توجهی از لحاظ دقت میان مدل تلفیقی Galerkin-MARS و

دو مدل انفرادی ذکر شده وجود دارد. از این رو می‌توان نتیجه گرفت که مدل تلفیقی Galerkin-MARS به‌منظور برآورد شاخص SPI در استان خوزستان از کارایی بالایی برخوردار است. هم‌چنین پنجره‌های زمانی بلندمدت SPI از دقت بالاتری نسبت به پنجره‌های زمانی کوتاه مدت برخوردار بودند. در نواحی خشک و نیمه‌خشک هم‌چون استان خوزستان که بارش اکثراً در فصول خاصی رخ می‌دهد و به‌طور معمول فرآیند بارندگی در آن پراکندگی مکانی و زمانی دارد، SPI ۱۲ ماهه بهتر می‌تواند تغییرات الگوی بارش و مشخصات خشک‌سالی را نمایش دهد. به‌طور کلی می‌توان عنوان نمود که تلفیق مدل‌های عددی با یادگیری ماشین در استان خوزستان، افزایش دقت در مدل‌سازی شاخص SPI را به دنبال دارد. یافته‌های این پژوهش در خصوص بررسی وضعیت خشک‌سالی و پیش‌بینی آن در استان خوزستان می‌تواند دید جامع، یکپارچه و وسیعی در مورد مدیریت اصولی و بهینه به مسئولین ذی‌ربط بدهد و تاب‌آوری در برابر بحران‌های محتمل محیط‌زیستی در این مناطق را تا حد مطلوب افزایش دهد. هم‌چنین این تحقیق بیانگر آن است که مدل‌های تلفیقی هوشمند، پتانسیل و توانایی تغییر و تحول در پیش‌بینی‌های اقلیمی را دارند. لذا استفاده از این مدل‌های دقیق هیبریدی در قالب طراحی سیستم‌های پیش‌آگاهی و هشدار، کاربست فناوری‌های نوین به منظور عینیت‌بخشی مدل‌سازی‌های صورت گرفته، آگاهی‌بخشی به مردم از طریق اپلیکیشن‌های طراحی شده به‌وسیله مدل‌سازی‌های هیبریدی و... می‌تواند از جمله راهکارهای جامع مدیریتی به‌منظور کاهش خسارات ناشی از پدیده‌های مخرب اقلیمی محسوب شود.

۵. پی‌نوشت‌ها

1. Standardized precipitation index (SPI)
2. Empirical Mode Decomposition
3. Deep belief network
4. intrinsic mode functions
5. Multilayer perceptron
6. Support Vector Regression
7. Inverse Distance Weighted
8. Element- Free Galerkin Method
9. Diffuse Element Method
10. Moving Least Squares
11. Constrained Galerkin Integral Equation
12. Multivariate adaptive regression splines

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

- Adnan, R. M., Dai, H. L., Kuriqi, A., Kisi, O., & Kermani, M. Z. (2023). Improving drought modeling based on new heuristic machine learning methods. *Ain Shams Engineering Journal*, 14(2023), 1-13.
- Agana, N.A., Homaifar, A., 2018. EMD-based predictive deep belief network for time series prediction: an application to drought forecasting. *Hydrology* 5. <https://doi.org/10.3390/hydrology5010018>.
- Ahmed, S. M. (2020). Impacts of drought, food security policy and climate change on performance of irrigation schemes in Sub-saharan Africa: The case of Sudan. *Agricultural Water Management*, 232, 106064.
- Babaali, H., Nohani, E., & Dehghani, R. (2024). Evaluation of the Standardized Precipitation Index with a hybrid model based on machine learning (case study: Lorestan province). *Journal of Climate Research*, Accepted Manuscript Available Online from 02 December 2024. (In Persian).
- Bazrafshan, O., Salajegheh, A., Mahdavi, Mohammad., & Fatehi, A. (2015). A study of Efficiency of the Hybrid model Artificial Neural Network Models-stochastic in Hydrological Drought Forecasting using kappa statistics (case study: Gamasiab Watershed Basin). *Iranian Journal of Watershed Management Science*. 8(27), 35-48. (In Persian).
- Belayneh, A., Adamowski, J., Khalil, B., Quilty, J. (2016). Coupling machine learning methods with wavelet transforms and the bootstrap and boosting ensemble approaches for drought prediction. *Atmospheric Research*, 172, 37-47.
- Belytschko, T., Lu, Y. Y., & Gu, L. (1994). Element-free Galerkin methods. *International Journal for Numerical Methods in Engineering*, 37(22), 229229–256256.
- Fawzy, S., Osman, A. I., Doran, J., & Rooney, D. W. (2020). Strategies for mitigation of climate change: a review. *Environmental Chemistry Letters*, 18, 2069-2094.
- Friedman, J. H. (1991). Multivariate adaptive regression splines. *Ann. Stat.*, 19, pp. 1-141 (1991).
- Hosseini-Moghari, S. M., & Araghinejad, S. (2016). Application of Statistical, Fuzzy and Perceptron Neural Networks in Drought Forecasting (Case Study: Gonbad-e Kavous Station). *Water and Soil*, 30(1), 247-259. (In Persian).
- Liu, G. R., Chen, X. L., & Reddy, J. N. (2002). Buckling of symmetrically laminated composite plates using the element-free Galerkin method. *International Journal of Structural Stability and Dynamics*, 2(03), 281-294

- McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. *Proceedings of the 8th Conference on Applied Climatology*.
- Negahban, S., Mokarram, M., & Moradizadeh Kermani, R. (2024). Assessing the effects of drought hazards on rural communities surrounds Maharlu Lake, Iran. *Environmental Hazards Management*, 11(1), 1-13.
- Mohammadi, J., Vafaeinezhad, A., Behzadi, S., Aghamohammadi, H., & Hemmasi, A. (2022). Drought prediction and modeling by hybrid wavelet method and neural network algorithms. *RS and GIS for Natural Resources*, 4(13), 87-111. (In Persian).
- Moisa, M. B., Merga, B. B., & Gemed, D.O. (2022). Multiple indices-based assessment of agricultural drought: A case study in Gilgel Gibe Sub-basin, Southern Ethiopia. *Theoretical and Applied Climatology*, 148(1), 455-464. doi:10.1007/s00704-022-03962-4.
- Raymond, C., Horton, R. M., Zscheischler, J., Martius, O., AghaKouchak, A., Balch, J., Bowen, S. G., Camargo, S. J., Hess, J., & Kornhuber, K. (2020). Understanding and managing connected extreme events. *Nature climate change*, 10(7), 611-621.
- Shamloo, N., Sattari, M. T., Valizadeh Khalil, K., & Apaydin, H. (2023). Evaluation of Combined Agricultural Drought Index (CDI), Prediction Methods Based on Satellite Images via Deep Learning and Machine Learning Approaches. *Water and Soil*, 37(5), 787-807. (In Persian).
- Wilhite, D. A., & Glantz, M. H. (1985). Understanding: the drought phenomenon: the role of definitions. *Water international*, 10(3), 111-120.
- Woli, P., Jones, J. W., Ingram, K. T., & Fraisse, C. W. (2012). Agricultural reference index for drought (ARID). *Agronomy Journal*, 104(2), 287-300.
- Yousefi, H., & Moridi, A. (2022). Multiobjective optimization of agricultural planning considering climate change impacts: Minab reservoir upstream watershed in Iran. *Journal of Irrigation and Drainage Engineering*, 148(4), 04022007. (In Persian).