



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

Sadaf Piri¹ | Mohammad Ansari Ghojghar²

1. Department of Reclamation of arid and mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Iran. E-mail: Sadaf.piri@ut.ac.ir
2. Corresponding Author, Department of Reclamation of arid and mountainous regions Engineering, Faculty of Natural Resources, University of Tehran, Iran. E-mail: Ansari.ghojghar@ut.ac.ir

Article Info	ABSTRACT
Article type: Research Article Article history: Received 20 March 2025 Received in revised form 16 May 2025 Accepted 8 June 2025 Published online 11 October 2025 Keywords: <i>Forecasting models</i> <i>Meteorological data</i> <i>Nonlinear prediction</i> <i>SPI</i>	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.

Cite this article: Piri, S., & Ansari Ghojghar, M. (2025). Presenting a combined numerical-machine learning model Galerkin-MARS for modeling meteorological drought (Case study: Khuzestan Province). *Journal of Water and Irrigation Management*, 15 (2), 301-314. DOI: <https://doi.org/10.22059/jwim.2025.392401.1213>





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. گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، ایران. رایانامه: Sadaf.piri@ut.ac.ir
۲. نویسنده مسئول، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، ایران. رایانامه: Ansari.ghojghar@ut.ac.ir

چکیده	اطلاعات مقاله
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 راه کارهای 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. همچنین پنجره های زمانی بلندمدت SPI از دقت بالاتری نسبت به پنجره های زمانی کوتاه مدت در منطقه مورد مطالعه برخوردار بودند. به طور کلی می توان گفت که تلفیق مدل های عددی با یادگیری ماشین در استان خوزستان، افزایش دقت در مدل سازی نمایه SPI را به دنبال دارد.	نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۳/۱۲/۳۰ تاریخ بازنگری: ۱۴۰۴/۰۲/۲۶ تاریخ پذیرش: ۱۴۰۴/۰۳/۱۸ تاریخ انتشار: ۱۴۰۴/۰۷/۱۹ کلیدواژه ها: پیش بینی غیرخطی داده های هواشناسی شاخص بارش استاندارد شده مدل های پیش بینی

استناد: پیری، صدف و انصاری قوجقار، محمد (۱۴۰۴). ارائه مدل تلفیقی عددی-یادگیری ماشین Galerkin-MARS به منظور مدل سازی خشک سالی هواشناسی (مطالعه موردی: استان خوزستان). نشریه مدیریت آب و آبیاری، ۱۵ (۲)، ۳۰۱-۳۱۴. DOI: <https://doi.org/10.22059/jwim.2025.392401.1213>



۱. مقدمه

خشک سالی با کمبود بارش شروع شده و با توجه به شدت، مدت و تداوم آن می تواند مواردی از جمله رطوبت خاک، میزان پهنه های آبی و فعالیت های انسانی و اکوسیستمی را دستخوش تغییر کند (Woli et al., 2012). خشک سالی شامل چهار دسته می باشد؛ خشک سالی هواشناسی، خشک سالی کشاورزی، خشک سالی هیدرولوژیک و خشک سالی اجتماعی- اقتصادی (Wilhite and Glantz, 1985). تغییر اقلیم نتیجه تغییرات الگوی آب و هوایی به دلیل انتشار گازهای گلخانه ای ناشی از فعالیت های انسانی است (Fawzy et al., 2020). تغییر اقلیم نشأت گرفته از فعالیت های انسانی (Raymond et al., 2020) و تغییر در الگوهای بارش (Yousefi and Moridi, 2022) عوامل اساسی در افزایش ناهنجاری ها و بلایای طبیعی هستند. خشک سالی 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 خشک سالی به عنوان یک نوع خطر طبیعی در مناطق مختلف با تمرکز بر جمع آوری راه کارهای مقابله با خشک سالی و مدیریت مخاطرات آن دارای اهمیت بسیار بالایی می باشد (Negahban et al., 2024). بنابراین، برای شناخت نوسانات مکانی و زمانی خشک سالی و برنامه ریزی در خصوص تدابیر مدیریتی اثرگذار برای مواجهه با آن، انجام پژوهش هایی پیرامون این موضوع، امری ضروری است (Moisa et al., 2022). پژوهش های گوناگونی در خصوص مدل سازی و پیش بینی خشک سالی در داخل و خارج از کشور صورت پذیرفته است. Shamloo et al. (2023) به ارزیابی روش های پیش بینی شاخص خشک سالی در حوضه آبخیز دریاچه ارومیه بر پایه تصاویر ماهواره ای و با بهره گیری از روش های یادگیری ماشین و یادگیری عمیق پرداختند. نتایج حاصل از این پژوهش بیانگر آن بود که روش های یادگیری ماشین و یادگیری عمیق، از کارایی بالایی در خصوص ارزیابی، پیش بینی و مدل سازی خشک سالی برخوردار می باشند. Babaali et al. (2024) در پژوهشی به پیش بینی شاخص SPI^۱ با استفاده از مدل هیبریدی مبتنی بر یادگیری ماشین در استان لرستان پرداختند. نتایج نشان دهنده رویکرد مؤثر مدل های هوشمند بر پایه رگرسیون بردار پشتیبان در پیش بینی خشک سالی بود. Adnan et al. (2023) به بررسی مدل سازی خشک سالی در کشور پاکستان براساس روش های اکتشافی و جدید یادگیری ماشین پرداختند. این پژوهش نشان داد که مدل های اکتشافی، نتایج دقیقی در خصوص پیش بینی خشک سالی ارائه می دهند. Babaali et al. (2019) به پیش بینی خشک سالی هواشناسی بر پایه مدل آماری با استفاده از یادگیری ماشین در استان Shaanxi چین پرداختند. نتایج نشان داد تلفیق اثرات غیرخطی و تاخیری پیش بینی می تواند به طور معنی داری دقت پیش بینی خشک سالی را بهبود بخشد. پژوهش دیگری خشک سالی را با توسعه یک مدل پیش بینی ترکیبی با بهره گیری از تجزیه حالت تجربی حذف شده (EMD)^۲ و یک شبکه باور عمیق (DBN)^۳ پیش بینی می نمایند. در روش پیشنهادی ابتدا داده ها را با استفاده از مدل EMD به چندین تابع حالت ذاتی (IMF)^۴ تجزیه می کند. نتایج به دست آمده با استفاده از روش پیشنهادی با روش های استاندارد مانند پرسپترون چند لایه (MLP)^۵ و رگرسیون بردار پشتیبان (SVR)^۶ مقایسه گردید. مدل ترکیبی پیشنهادی، بهبود در دقت پیش بینی به ویژه برای پیش بینی های چند مرحله ای را نشان داد (Agana & Homaifar, 2018). همچنین Belayneh et al. (2016) از روش های Bootstrap و مدل تقویتی (اثر تقویتی) برای پیش بینی خشک سالی با دقت بالا با بهره گیری از سری SPI در حوضه رودخانه آواش اتیوپی استفاده نمود. نتایج نشانگر آن بود که دقت و عملکرد رگرسیون بردار پشتیبان تقویت کننده مبتنی بر موجک (SVR) بهترین کارایی را در میان مدل های پیشنهادی داشت. Mohammadi et al. (2022) در پژوهشی به پیش بینی و مدل سازی خشک سالی به روش هیبریدی موجک و الگوریتم های شبکه عصبی با استفاده از شاخص SPI در مقیاس های زمانی سه، شش، ۱۲، ۱۸، ۲۴ و ۴۸ ماهه در ۱۰ ایستگاه کشور پرداختند. نتایج به دست آمده نشان داد که تلفیق تکنیک موجک با سه مدل انفرادی به کاررفته در پژوهش، موجب بهبود نتایج مدل سازی در پژوهش می شود. استان خوزستان به سبب ویژگی های اقلیمی منحصربه فرد (قرارگیری مناطق خشک و مرطوب، وابستگی به رودخانه های 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 این که مدل‌های عددی (ریاضی) از هزینه‌های محاسباتی کم‌تر و سرعت پردازش بالایی برخوردار هستند، لذا ترکیب این مدل‌ها با الگوریتم‌های فراکاوشی یادگیری ماشین، که به‌دلیل آموزش نوروهای 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 این‌رو، 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

۲.۱. محدوده مطالعاتی

استان خوزستان با مساحت ۶۴۰۵۷ کیلومتر مربع بین ۲۹ درجه و ۵۸ دقیقه تا ۳۳ درجه و ۴ دقیقه عرض شمالی از خط استوا و ۴۷ درجه و ۳۱ دقیقه تا ۵۰ درجه و ۳۹ دقیقه طول شرقی از نصف‌النهار گرینویچ در جنوب غرب ایران قرار گرفته است. شمال و شرق استان خوزستان، با سلسله کوه‌های زاگرس محصور می‌باشد که به طرف جنوب غربی، ارتفاع آن کم‌تر شده و تا مناطق جنوبی‌تر به‌صورت تپه‌ماهورهایی 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. داده ها

در پژوهش حاضر برای استخراج پهنه های خشک سالی هشت ایستگاه هواشناسی (صفی آباد دزفول، بستان، آبادان، امیدیه، مسجد سلیمان، بندر ماهشهر، اهواز و رامهرمز) واقع در استان خوزستان، از داده های بارش طی ۳۰ سال آماری مشترک (۱۳۶۹-۱۳۹۹) استفاده گردید. در گام بعدی، پس از دریافت و آماده سازی داده های بارش از سایت هواشناسی کشور، مقادیر شاخص بارش استاندارد شده (SPI) جهت تشخیص سال های خشک و تر محاسبه گردید. این شاخص اولین بار توسط McKee *et al.* (1993) ارائه شد. این شاخص جهت ارزیابی خشک سالی مورد استفاده قرار می گیرد و به وسیله آن می توان زمان آغاز، شدت و همچنین مدت وقوع خشک سالی را در دوره های زمانی گوناگون مشخص نمود. با در نظر گرفتن ماهیت استاندارد سازی شده این شاخص، اساسی ترین نقطه قوت آن، توانایی مقایسه مشخصه های خشک سالی در بازه های زمانی و مکانی گوناگون و همچنین انواع آب و هوا می باشد. برای ارزیابی این شاخص می توان مقادیر بارش ماهانه یا مجموع بارش در دوره های زمانی مدنظر را محاسبه کرد. این شاخص از طریق رابطه (۱) محاسبه می شود و طبقه بندی 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 بلند مدت 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)^۸

این روش نسخه پیشرفته تری از روش عناصر پخش شده^۹ (DEM) است که توسط Belytschko *et al.* (1994) ارائه شده است. از مشخصه های اصلی روش EFG می توان 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 پس زمینه جهت انتگرال گیری به منظور ساخت ماتریس های سیستم در روش های عددی، می پردازد (Liu *et al.*, 2002). روش MLS به عنوان ابزاری جهت تولید توابع تقریب مناسب، در فضای حل، استفاده می شود تا خطای تقریب به حداقل برسد. این ویژگی به ویژه در مسائل پیچیده یا شرایطی که داده های با دقت پایین تر 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، پاسخ های غیرخطی را میان ورودی ها و خروجی یک سامانه، توسط مجموعه ای از توابع خطی چندقطعه ای با گرادین های گوناگون مدل سازی می کند. نقاط پایانی این توابع چندقطعه ای، به عنوان گره شناخته می شوند. گره، انتهای یک ناحیه از داده ها و ابتدای ناحیه ای دیگر از داده ها را مشخص می نماید. مدل به عنوان ترکیب خطی توابع و روابط متقابل آن ها تشکیل و در رابطه (۲) بیان شده است.

$$f(x) = \beta \cdot \sum_{m=1}^M \beta_m \lambda_m(x) \quad \text{رابطه ۲}$$

که در آن، λ_m به عنوان پارامتر هموارسازی شناخته می‌شود. هر $\lambda_m(x)$ یک تابع محاسباتی چند نقطه‌ای محسوب می‌شود و قابلیت این را دارد که از گرادینان‌های گوناگون تشکیل شود. مجموعه پارامترهای β 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 یک، سه، شش 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 برحسب پنجره زمانی آن‌ها این عمل انجام می‌پذیرد.

$$SPI_{12(t+1)} = f(SPI_{12(t)}) \quad \text{مدل ۱}$$

$$SPI_{6(t+1)} = f(SPI_{6(t)}) \quad \text{مدل ۲}$$

$$SPI_{3(t+1)} = f(SPI_{3(t)}) \quad \text{مدل ۳}$$

$$SPI_{1(t+1)} = f(SPI_{1(t)}) \quad \text{مدل ۴}$$

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 این‌رو، 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.

نتایج به‌دست‌آمده از محاسبه معیارهای ارزیابی R، RMSE، NS و MAE برای تعیین بهترین مدل در جدول‌های (۲) تا (۴) ارائه گردیده است. براساس جدول (۲) و با توجه به نتایج به‌دست‌آمده از معیارهای ارزیابی نیکویی برازش در هشت ایستگاه مورد مطالعه، به‌صورت کلی، SPI ۱۲ ماهه و شش ماهه نتایج بهتر و با دقت بالاتری را نسبت به SPI سه ماهه و یک ماهه ارائه دادند. در مقایسه SPI ۱۲ ماهه با شش ماهه نیز SPI ۱۲ ماهه عملکرد بهتری از خود نشان داد. به‌عنوان مثال، در ایستگاه رامهرمز، استفاده از SPI ۱۲ ماهه به جای SPI یک ماهه موجب کاهش مقادیر MAE و RMSE به‌ترتیب از ۰/۴۳۱ و ۰/۳۸۹ به ۰/۴۲۷ و ۰/۳۸۳ گردید.




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

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 این‌که این روش براساس 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 به‌طور واضح 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. به‌عنوان مثال، در ایستگاه مسجد سلیمان، استفاده از SPI ۱۲ ماهه به جای SPI شش ماهه موجب کاهش مقادیر MAE و RMSE به‌ترتیب 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 به‌منظور 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، به‌ترتیب با کاهش، افزایش و کاهش روبه‌رو شد. به‌عنوان مثال، در ایستگاه آبادان، مقادیر NS و R مدل هیبریدی Galerkin-MARS در مقایسه با مدل انفرادی Galerkin، به‌ترتیب 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. به‌عبارتی، 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 این‌رو، می‌توان نتیجه گرفت که مدل تلفیقی Galerkin-MARS به‌منظور 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 قابل‌توجه مدل‌های تلفیقی را نسبت به مدل‌های انفرادی گزارش کردند (Mohammadi et al., 2022; Bazrafshan et al., 2015; Hosseini-Moghari et al., 1994).

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

Station	Combination number	Train dataset				Test dataset			
		RMSE	MAE	NS	R	RMSE	MAE	NS	R
Abadan	SPI ₁₂	0.391	0.308	0.697	0.741	0.411	0.352	0.685	0.709
	SPI ₆	0.391	0.308	0.696	0.739	0.412	0.353	0.684	0.709
	SPI ₃	0.394	0.311	0.695	0.736	0.412	0.354	0.683	0.707
	SPI ₁	0.392	0.314	0.694	0.735	0.413	0.355	0.682	0.711
Bostan	SPI ₁₂	0.393	0.317	0.693	0.734	0.414	0.357	0.682	0.706
	SPI ₆	0.395	0.321	0.692	0.733	0.415	0.359	0.681	0.703
	SPI ₃	0.397	0.323	0.691	0.732	0.416	0.361	0.679	0.702
	SPI ₁	0.399	0.322	0.689	0.731	0.416	0.362	0.678	0.702
Ahvaz	SPI ₁₂	0.401	0.324	0.688	0.734	0.417	0.364	0.676	0.701
	SPI ₆	0.403	0.325	0.687	0.729	0.418	0.365	0.676	0.701
	SPI ₃	0.405	0.327	0.686	0.727	0.419	0.366	0.675	0.699
	SPI ₁	0.407	0.328	0.685	0.726	0.421	0.367	0.674	0.698
Bandar mahshahr	SPI ₁₂	0.406	0.329	0.684	0.725	0.422	0.369	0.673	0.697
	SPI ₆	0.409	0.331	0.683	0.724	0.423	0.371	0.671	0.696
	SPI ₃	0.411	0.332	0.681	0.723	0.424	0.372	0.669	0.695
	SPI ₁	0.413	0.334	0.679	0.721	0.425	0.374	0.668	0.695
Omidiyeh	SPI ₁₂	0.414	0.335	0.678	0.719	0.425	0.376	0.667	0.694
	SPI ₆	0.415	0.337	0.676	0.718	0.425	0.373	0.666	0.693
	SPI ₃	0.416	0.339	0.675	0.716	0.425	0.379	0.664	0.692
	SPI ₁	0.417	0.341	0.674	0.715	0.426	0.381	0.663	0.691
Ramhormoz	SPI ₁₂	0.418	0.342	0.673	0.714	0.427	0.383	0.662	0.691
	SPI ₆	0.419	0.344	0.671	0.714	0.427	0.385	0.661	0.689
	SPI ₃	0.421	0.345	0.669	0.713	0.429	0.386	0.661	0.688
	SPI ₁	0.423	0.346	0.668	0.712	0.431	0.389	0.659	0.687
Masjed soleyman	SPI ₁₂	0.424	0.347	0.667	0.711	0.432	0.391	0.657	0.686
	SPI ₆	0.425	0.348	0.665	0.710	0.433	0.392	0.656	0.683
	SPI ₃	0.427	0.349	0.664	0.709	0.434	0.392	0.654	0.675
	SPI ₁	0.427	0.351	0.663	0.708	0.435	0.393	0.653	0.674
Safiabad Dezful	SPI ₁₂	0.429	0.353	0.662	0.706	0.437	0.395	0.652	0.673
	SPI ₆	0.431	0.357	0.661	0.705	0.438	0.396	0.651	0.675
	SPI ₃	0.432	0.359	0.659	0.704	0.439	0.397	0.649	0.671
	SPI ₁	0.433	0.361	0.657	0.703	0.441	0.399	0.648	0.669

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

Station	Combination number	Train dataset				Test dataset			
		RMSE	MAE	NS	R	RMSE	MAE	NS	R
Abadan	SPI ₁₂	0.303	0.256	0.871	0.894	0.317	0.284	0.843	0.861
	SPI ₆	0.304	0.257	0.869	0.893	0.319	0.285	0.841	0.861
	SPI ₃	0.305	0.259	0.867	0.892	0.321	0.286	0.839	0.860
	SPI ₁	0.305	0.261	0.865	0.891	0.323	0.287	0.838	0.859
Bostan	SPI ₁₂	0.306	0.263	0.864	0.887	0.325	0.287	0.837	0.857
	SPI ₆	0.307	0.265	0.863	0.886	0.328	0.289	0.837	0.854
	SPI ₃	0.307	0.267	0.863	0.885	0.328	0.291	0.837	0.853
	SPI ₁	0.309	0.269	0.862	0.884	0.329	0.292	0.836	0.852
Ahvaz	SPI ₁₂	0.313	0.271	0.861	0.883	0.331	0.292	0.835	0.851
	SPI ₆	0.314	0.276	0.859	0.881	0.332	0.292	0.834	0.849
	SPI ₃	0.315	0.275	0.857	0.879	0.334	0.293	0.831	0.848
	SPI ₁	0.316	0.279	0.856	0.877	0.336	0.294	0.829	0.847
Bandar mahshahr	SPI ₁₂	0.316	0.281	0.855	0.876	0.337	0.295	0.827	0.847
	SPI ₆	0.319	0.283	0.853	0.875	0.337	0.295	0.824	0.847
	SPI ₃	0.321	0.285	0.851	0.873	0.341	0.295	0.823	0.847
	SPI ₁	0.322	0.289	0.849	0.872	0.342	0.296	0.821	0.846
Omidyeh	SPI ₁₂	0.325	0.291	0.848	0.871	0.343	0.299	0.819	0.845
	SPI ₆	0.327	0.293	0.847	0.869	0.345	0.301	0.818	0.844
	SPI ₃	0.331	0.293	0.846	0.868	0.347	0.302	0.816	0.843
	SPI ₁	0.332	0.295	0.845	0.865	0.351	0.305	0.815	0.841
Ramhormoz	SPI ₁₂	0.334	0.294	0.843	0.864	0.352	0.309	0.814	0.839
	SPI ₆	0.337	0.297	0.842	0.863	0.353	0.308	0.812	0.837
	SPI ₃	0.341	0.297	0.841	0.861	0.354	0.311	0.811	0.834
	SPI ₁	0.343	0.298	0.839	0.859	0.355	0.312	0.809	0.833
Masjed soleyman	SPI ₁₂	0.347	0.299	0.837	0.857	0.357	0.314	0.808	0.831
	SPI ₆	0.348	0.301	0.836	0.856	0.359	0.317	0.808	0.829
	SPI ₃	0.349	0.302	0.835	0.854	0.361	0.319	0.805	0.827
	SPI ₁	0.349	0.304	0.834	0.853	0.362	0.320	0.804	0.826
Safiabad Dezful	SPI ₁₂	0.351	0.306	0.833	0.852	0.363	0.322	0.802	0.825
	SPI ₆	0.354	0.307	0.831	0.851	0.363	0.323	0.801	0.823
	SPI ₃	0.357	0.309	0.829	0.847	0.364	0.325	0.799	0.821
	SPI ₁	0.358	0.309	0.827	0.843	0.365	0.327	0.796	0.817

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

Station	Combination number	Train dataset				Test dataset			
		RMSE	MAE	NS	R	RMSE	MAE	NS	R
Abadan	SPI ₁₂	0.243	0.096	0.976	0.994	0.271	0.157	0.949	0.973
	SPI ₆	0.244	0.096	0.975	0.994	0.274	0.158	0.948	0.971
	SPI ₃	0.247	0.097	0.974	0.993	0.275	0.159	0.947	0.968
	SPI ₁	0.251	0.099	0.971	0.992	0.275	0.161	0.946	0.969
Bostan	SPI ₁₂	0.252	0.101	0.969	0.991	0.279	0.162	0.945	0.967
	SPI ₆	0.253	0.104	0.968	0.989	0.283	0.163	0.944	0.967
	SPI ₃	0.256	0.107	0.967	0.987	0.284	0.165	0.943	0.966
	SPI ₁	0.257	0.108	0.967	0.984	0.285	0.166	0.942	0.965
Ahvaz	SPI ₁₂	0.259	0.109	0.967	0.985	0.286	0.167	0.941	0.965
	SPI ₆	0.261	0.111	0.966	0.985	0.289	0.169	0.939	0.964
	SPI ₃	0.262	0.112	0.965	0.983	0.288	0.171	0.937	0.963
	SPI ₁	0.263	0.113	0.964	0.982	0.291	0.172	0.936	0.962
Bandar mahshahr	SPI ₁₂	0.265	0.117	0.963	0.981	0.293	0.173	0.935	0.961
	SPI ₆	0.268	0.121	0.962	0.981	0.294	0.174	0.933	0.960
	SPI ₃	0.269	0.123	0.961	0.979	0.295	0.175	0.931	0.959
	SPI ₁	0.271	0.119	0.965	0.978	0.297	0.176	0.929	0.958
Omidyeh	SPI ₁₂	0.274	0.125	0.963	0.976	0.299	0.177	0.927	0.957
	SPI ₆	0.275	0.127	0.961	0.975	0.302	0.179	0.925	0.956
	SPI ₃	0.278	0.131	0.959	0.974	0.303	0.181	0.924	0.954
	SPI ₁	0.281	0.132	0.957	0.973	0.304	0.183	0.923	0.951
Ramhormoz	SPI ₁₂	0.284	0.133	0.954	0.969	0.305	0.184	0.922	0.948
	SPI ₆	0.287	0.134	0.953	0.972	0.307	0.185	0.921	0.947
	SPI ₃	0.289	0.135	0.952	0.971	0.309	0.186	0.919	0.946
	SPI ₁	0.291	0.137	0.951	0.967	0.311	0.187	0.917	0.946
Masjed soleyman	SPI ₁₂	0.292	0.138	0.949	0.965	0.313	0.188	0.915	0.946
	SPI ₆	0.293	0.141	0.948	0.964	0.315	0.189	0.914	0.944
	SPI ₃	0.293	0.142	0.947	0.963	0.317	0.191	0.913	0.943
	SPI ₁	0.293	0.143	0.946	0.961	0.319	0.192	0.913	0.941
Safiabad Dezful	SPI ₁₂	0.295	0.145	0.945	0.959	0.321	0.193	0.911	0.939
	SPI ₆	0.296	0.146	0.944	0.957	0.322	0.194	0.909	0.937
	SPI ₃	0.294	0.147	0.943	0.956	0.323	0.195	0.907	0.934
	SPI ₁	0.297	0.148	0.942	0.954	0.324	0.196	0.905	0.933

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 فرایندهای پیچیده و حل معادلات دیفرانسیل کارایی مناسبی دارند. درحالی‌که 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 کوتاه‌مدت، 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 فرایند 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 تأثیر نوسانات مقطعی بارش می‌باشند و نتیجه واضح و واقعی از شرایط خشک‌سالی نشان نمی‌دهد. شکل (۴)، مقادیر مشاهده‌شده و پیش‌بینی‌شده شاخص SPI ۱۲ ماهه را برای داده‌های بخش آزمون ایستگاه‌های استان خوزستان نمایش می‌دهد. در این شکل، رابطه بین مقادیر مشاهده‌شده و پیش‌بینی‌شده 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 بررسی‌شده به‌همراه دارد. شکل (۵) نیز نشان‌دهنده مقایسه مقادیر مشاهده‌شده و پیش‌بینی‌شده 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



Continued 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



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

۴. نتیجه گیری

خشک سالی یکی از بلایای طبیعی، به ویژه در مناطق خشک و نیمه خشک به شمار می آید. استان خوزستان به سبب دارا بودن موقعیت جغرافیایی حساس و وابستگی شدید به منابع آب، در مقابل خشک سالی به شدت آسیب پذیر است. خشک سالی در این استان می تواند تبعاتی هم چون کاهش سطح آب تالاب های 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 آن ها به صورت مدل دوگانه Galerkin-MARS در هشت ایستگاه سینوپتیک استان خوزستان (صفی آباد 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 مدل ها، به طور کلی مدل Galerkin نتایج دقیقی در خصوص پیش بینی شاخص SPI ارائه نمی دهد. همچنین مدل MARS با اختلاف معنی داری نسبت به مدل Galerkin از دقت بیشتری برخوردار است. در نهایت مدل تلفیقی عددی-یادگیری ماشین Galerkin-MARS به عملکرد را نسبت به مدل های 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، می توان نتیجه گرفت که مدل تلفیقی Galerkin-MARS به منظور برآورد شاخص SPI در استان خوزستان از کارایی بالایی برخوردار است. همچنین پنجره های زمانی بلندمدت SPI از دقت بالاتری نسبت به پنجره های زمانی کوتاه مدت برخوردار بودند. در نواحی خشک و نیمه خشک هم چون استان خوزستان که بارش اکثراً در فصول خاصی رخ می دهد و به طور معمول فرایند بارندگی در آن پراکندگی مکانی و زمانی

دارد، SPI ۱۲ ماهه بهتر می تواند تغییرات الگوی بارش و مشخصات خشک سالی را نمایش دهد. به طور کلی، می توان عنوان نمود که تلفیق مدل های عددی با یادگیری ماشین در استان خوزستان، افزایش دقت در مدل سازی شاخص SPI را به دنبال دارد. یافته های این پژوهش در خصوص بررسی وضعیت خشک سالی و پیش بینی آن در استان خوزستان می تواند دید جامع، یکپارچه و وسیعی در مورد مدیریت اصولی و بهینه به مسئولین ذی ربط بدهد و تاب آوری در برابر بحران های محتمل محیط زیستی در این مناطق را تا حد مطلوب افزایش دهد. همچنین این پژوهش بیانگر آن است که مدل های تلفیقی هوشمند، پتانسیل و توانایی تغییر و تحول در پیش بینی های اقلیمی را دارند. لذا استفاده از این مدل های دقیق هیبریدی در قالب طراحی سیستم های پیش آگاهی و هشدار، کاربست فناوری های نوین به منظور عینیت بخشی مدل سازی های صورت گرفته، آگاهی بخشی به مردم از طریق اپلیکیشن های طراحی شده به وسیله مدل سازی های هیبریدی و ... می تواند از جمله راه کارهای جامع مدیریتی به منظور کاهش خسارت های ناشی از پدیده های مخرب اقلیمی محسوب شود.

۵. پی نوشت ها

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

هیچ گونه 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, M., & 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*, 3737(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, 1-141.
- 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, January). The relationship of drought frequency and duration to time scales. In *Proceedings of the 8th Conference on Applied Climatology* (Vol. 17, No. 22, pp. 179-183).
- 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).