



## Identifying the threshold of variables affecting flood zones using machine learning technique (Case study: the downstream region of the Karun River)

Mohamad Kazemi <sup>1\*</sup>, Atefeh Jafarpoor <sup>2</sup>

<sup>1</sup> Assistant Professor, Department of Hormoz Studies and Research Center, Hormozgan University, Bandarabaas, Iran

<sup>2</sup> Ph.D., Department of Watershed Management Engineering, Faculty of Natural Resources and Marine Sciences, Tarbiat Modares University, Noor, Iran

### Abstract

#### Introduction

Machine learning is a new artificial intelligence method that seeks to write a program with the best performance by using learning experience. Machine learning models with different algorithms can be predictive or descriptive or have both properties and be used in different fields. On the other hand, for better management of flood risk reduction, it is necessary to know the effective factors in each region and flood sensitivity analysis. Since so far, few researchers have analyzed the threshold of influence of variables affecting the occurrence of floods using machine learning methods, the current research is new in this respect. Based on this, the current research has been conducted to identify the threshold of variables affecting the zoning of flooded areas using machine learning and remote sensing data in the Karun Basin area. The results can be put on the agenda of the relevant managers in identifying the influence limits of different variables on the occurrence of floods and the management of flood-sensitive areas by relying on the effective limits of the variables in the study area.

#### Materials and Methods

Landsat OLI 8 images on April 8, 2019 were used to identify flooded areas. In this regard, to identify groundwater, the corresponding image of the previous year of the region was used to separate and identify groundwater zones. Then, the remaining pixels of the study area as whole samples and flooded areas were entered into the modelling process as target samples. Therefore, flooded areas with a code of one and other areas with a code of zero entered the modelling process as dependent variables. Also, the variables that were entered as independent variables in the machine learning process include actual evaporation and transpiration, land use, soil density mass, soil clay percentage, soil water deficit, DEM, NDVI, land cover index, Palmer drought severity index, potential evaporation and transpiration, precipitation, cumulative, soil sand percentage, soil texture, soil moisture, minimum and maximum temperature. Next, by entering these variables and performing the machine learning process, the models were evaluated and TreeNet was selected as the best model. Then the threshold of each of the studied components on flood zones was obtained from machine learning. Also, in the present study, learning and test data were used in a ratio of 70% to 30% and completely randomly. It is worth noting that the number of 200 trees with at least six nodes was set for modelling.

#### Results and Discussion

Different components have certain thresholds at the beginning of land flooding so regarding vegetation as the most important effective factor in flood zoning, it shows that the lack of vegetation causes flooding, and the higher the level of vegetation, the more it prevents flooding. Also, the cumulative precipitation threshold for flooding the studied area was 15 mm of rainfall, and less than that, the incoming rainfall did not pose a risk of flooding the studied lands. The amount of 15.5 mm of rainfall was the turning point and the threshold of the beginning of the flooding in the study area. Regarding the soil moisture deficiency index, it shows that the threshold of flooding based on this index was 144, in other words when the soil moisture profile is more than the mentioned value, the incoming precipitation must compensate for the soil moisture deficiency, and as a result, floods will be prevented. On the other hand, most flooding conditions have existed at a height of 16 m, and as the height increases, the risk of flooding the studied area decreases, so that there is a failure at a height of 19 m, and when the height reaches 22.5 m,



the risk Flooding disappears, and at a height higher than 26 m, flooding is restrained and will reach a steady state. The reason for this can be the plainness of the studied area and the widening of the flood zone in the plain.

### Conclusion

The results showed that the components of the vegetation cover index, cumulative precipitation, soil water deficit, Palmer drought index, height, and surface soil moisture respectively had the greatest effect on the flooding of the studied area. Also, in the studied area, the effect of soil sand percentage, soil clay percentage, soil density, potential evaporation and transpiration, slope direction, maximum daily temperature, and soil texture on flood zoning was insignificant. The evaluation of the efficiency of the model with the indicators of ROC, specificity, sensitivity, and overall accuracy is 0.95, 91.2, 90.43, and 91.12, respectively, which indicates accuracy. The results of flood zoning with the ground reality indicated  $R^2$  and MAE equal to 72.8% and 0.27%, which confirms the accuracy of the zoning results with the ground reality relatively well. The analysis of the results shows that there will be an increased risk of flooding in the wetland and swamp areas due to the high humidity and water level. The results of the present research can be used by planners and managers of natural hazards to reduce floods.

**Keywords:** Impact threshold, Relative importance, Evaluation, Flood zones, Machine learning.

**Article Type:** Research Article

### Conflicts of interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.

### Acknowledgment

The Hormoz Research Institute of Hormozgan University is highly appreciated for fulfilling the research goals of this article.

### Data availability statement:

All data generated during the manuscript analysis are included in the article. Further datasets are available upon a reasonable request to the corresponding author.

### Authors' contribution

**Mohamad Kazemi:** Conceptualization, Software development, Data analysis, Final editing Resources, Software, Writing, Original draft preparation; **Atefeh Jafarpoor:** Conceptualization, Data analysis, Original draft preparation.

\*Corresponding Author, E-mail: mohamad.kazemi86@gmail.com

**Citation:** Kazemi, M., & Jafarpoor, A. (2024). Identifying the threshold of variables affecting flood zones using machinelearning technique (Case study: the downstream region of the Karun River). *Water and Soil Management and Modeling*, 4(1), 214-232.

DOI: 10.22098/mmws.2023.12285.1220

DOI: .....

Received: 04 February 2023, Received in revised form: 20 February 2023, Accepted: 21 February 2023, Published online: 21 February 2023

*Water and Soil Management and Modeling*, Year 2024, Vol. 4, No. 1, pp. 214-232  
Publisher: University of Mohaghegh Ardabili © Author(s)





# مدل‌سازی و مدیریت آب و خاک



شایعه اینترنتی: ۲۵۶۰-۲۷۸۳

## شناسایی آستانه تأثیرگذار بر پهنه‌های سیلاب با استفاده از تکنیک یادگیری ماشین (مطالعه موردی: حوضه انتهاهی کارون بزرگ)

محمد کاظمی<sup>۱\*</sup>، عاطفه جعفرپور<sup>۲</sup>

<sup>۱</sup> استادیار، مرکز مطالعات و تحقیقات هرمز، دانشگاه هرمزگان، بندرعباس، ایران

<sup>۲</sup> دکتری، گروه مهندسی آبخیزداری، دانشکده منابع طبیعی و علوم دریایی، دانشگاه تربیت مدرس، نور، ایران

### چکیده

سیل یکی از شایع‌ترین مخاطرات طبیعی در سراسر جهان است که خسارت زیادی به زندگی انسان‌ها و زیرساخت‌های مختلف وارد می‌کند. از این‌رو پیش‌بینی و برآورد آستانه مؤلفه‌های مؤثر بر وقوع آن در نقاط مختلف ضرورت دارد. بر همین اساس، پژوهش حاضر با هدف پهنه‌بندی خطر سیلاب به شناسایی حدود متغیرهای تأثیرگذار بر پهنه‌های سیلاب با استفاده از تکنیک‌های یادگیری ماشین انجام شده است. برای این منظور، از تصاویر لندست OLI8 مورخ هشتم اوریل ۲۰۱۹ (فروزان ۱۳۹۸) برای شناسایی پهنه‌های سیل گیر استفاده شد. از این‌رو، مناطق سیل گیر با کد یک و مناطق غیر از آن با کد صفر به عنوان متغیر وابسته وارد فرآیند مدل‌سازی و یادگیری ماشین شدند. هم‌چنین، فرآیند یادگیری ماشین با روش درختان رگرسیون چندگانه (TreeNet) انجام شد. نتایج پهنه‌بندی خطر سیلاب نشان داد، سیلاب با ریسک زیاد ۴۲۵۶ هکتار معادل  $3/8$  درصد و پهنه سیلاب با خطر جمع‌شدتی (TreeNet) انجام شد. نتایج پهنه‌بندی خطر سیلاب نشان داد، سیلاب با ریسک زیاد ۴۲۵۶ هکتار معادل  $3/8$  درصد و پهنه سیلاب با خطر جمع‌شدتی (TreeNet) انجام شد. نتایج پهنه‌بندی خطر سیلاب نشان داد، سیلاب با ریسک خیلی کم، ۹۱۴۹۶ هکتار ریسک خیلی زیاد ۵۵۰۰ هکتار معادل  $4/99$  درصد از سطح محدوده مورد را به خود اختصاص داده‌اند. خطر سیلاب با ریسک خیلی کم، ۹۱۴۹۶ هکتار معادل  $83/132$  درصد از سطح محدوده مطالعاتی را دربرگرفته است. هم‌چنین، نتایج بررسی اهمیت نسبی متغیرها در وقوع سیلاب نشان داد به ترتیب متغیرهای پوشش گیاهی، بارش تجمعی باران، کمبود آب در خاک، شدت خشکسالی و کاربری اراضی با حدود تأثیرگذاری صفر تا  $15-16$  میلی‌متر،  $144-152$  میلی‌متر، شدت  $2/5$  (ترسالی متوسط) و اراضی ماندابی و باتلاقی بیش‌ترین تأثیر را بر بروز پهنه‌های سیلاب در محدوده مورد مطالعه داشته‌اند. ارزبایی میزان کارایی مدل با شاخص‌های سطح زیرمنحنی، ویژگی، شفافیت، صحت کلی و صحت قاعده به ترتیب  $0/18$ ،  $90/43$ ،  $91/2$ ،  $0/95$  و  $0/88$  است که نشان‌دهنده دقیق مدل است. بررسی نتایج پهنه‌بندی سیلاب با واقعیت زمینی حکایت از  $R^2$  و MAE  $72/8$  درصد و  $0/27$  داشت که صحت نتایج پهنه‌بندی با واقعیت زمینی را نسبتاً خوب تصدیق می‌نماید. نتایج پژوهش حاضر می‌تواند در شناسایی پهنه‌های سیل، رتبه‌بندی اهمیت متغیرهای مختلف در وقوع سیل و تدوین اقدامات مؤثر برای به حداقل رساندن خسارت در آینده و مدیریت مناسب متغیرهای کلیدی مؤثر بر وقوع سیلاب از طریق آستانه‌های تأثیرگذار استفاده شود.

**واژه‌های کلیدی:** آستانه تأثیرگذاری، اهمیت نسبی، ارزبایی، پهنه‌های سیلاب، یادگیری ماشین

**نوع مقاله: پژوهشی**

\* مسئول مکاتبات، پست الکترونیکی: mohamad.kazemi86@gmail.com

استناد: کاظمی، محمد، و جعفرپور، عاطفه (۱۴۰۳). شناسایی آستانه تأثیرگذار بر پهنه‌های سیلاب با استفاده از تکنیک یادگیری ماشین (مطالعه موردی: حوضه انتهاهی کارون بزرگ). مدل‌سازی و مدیریت آب و خاک، ۱(۱۴)، ۲۳۲-۲۴۳.

DOI: 10.22098/mmws.2023.12285.1220

DOR: .....

تاریخ دریافت: ۱۴۰۱/۱۱/۱۵، تاریخ بازنگری: ۱۴۰۱/۱۲/۰۱، تاریخ پذیرش: ۱۴۰۱/۱۲/۰۲، تاریخ انتشار: ۱۴۰۱/۱۲/۰۲

مدل‌سازی و مدیریت آب و خاک، سال ۱۴۰۳، دوره ۴، شماره ۱، صفحه ۲۱۴ تا ۲۳۲

ناشر: دانشگاه حقوق اردبیلی © نویسندهان



به خطر سیلاب پرداخته شد. نتایج ایشان نشان داد که مدل CART با منحنی مشخصه<sup>۲</sup> AUC معادل ۰/۹۱ و شاخص TSS معادل ۸۸/۰ بهترین مدل در پیش‌بینی پتانسیل خطر سیلاب بوده است. همچنین، Chakrabortty et al. (2022) با استفاده از سنجش از دور و سیستم اطلاعات جغرافیایی (GIS) و یک مدل یادگیری ماشین برای تهیه نقشه حساسیت به سیل حوضه رودخانه کانگ سپاتی، هند استفاده کردند. بدین‌منظور، شرایط محیطی، توپوگرافی، هیدرولوژیکی و زمین‌شناسی را در مدل‌ها استفاده و مدل نهایی بر اساس روابط بین پتانسیل عوامل ایجاد‌کننده و خطر سیل بر اساس تحلیل چند خطی انتخاب کردند. نتایج مدل با استفاده از ناحیه زیرمنحنی مشخصه عملکرد گیرنده (ROC) (AUC) تأیید و ارزیابی شد، که نشان‌دهنده وضعیت فعلی محیط است و مقدار ۰/۹۵ نشان‌دهنده خطر بیش‌تر سیل‌های ناگهانی است. مقادیر AUC برای ANN و DLNN و PSO برای مجموعه داده‌های آموزشی به ترتیب ۰/۹۱۴، ۰/۹۲۰ و ۰/۹۴۲ بود. از بین این سه مدل PSO بهترین عملکرد را با مقدار ۰/۹۴۲ AUC نشان داد. در پژوهشی، Ighile et al. (2022) به تهیه نقشه پهنه‌بندی خطر سیلاب و رتبه‌بندی متغیرهای مؤثر بر وقوع سیلاب با استفاده از شاخص اهمیت نسبی در کشور نیجریه پرداختند. آن‌ها از دو مدل یادگیری ماشین شبکه عصبی مصنوعی و جنگل تصادفی استفاده کردند. نتایج پژوهش ایشان نشان داد متغیرهای شاخص خمیدگی<sup>۳</sup>، شماره منحنی، کاربری اراضی، شاخص SPI، جهت شیب، بافت خاک، ضریب زبری و دمای هوا بیش‌ترین اهمیت را در شکل‌گیری پهنه‌های سیلابی در محدوده مورد مطالعه دارد.

از سایر پژوهش‌ها، Al-Areeq et al. (2022) پهنه‌بندی خطر سیل شهر جدہ عربستان سعودی را با استفاده از یادگیری ماشینی با چهار الگوریتم مجموعه کیسه‌ای (BE)، درخت مدل لجستیک (LT)، ماشین بردار پشتیبان هسته (k-SVM) و k-LSDیک‌ترین همسایه (KNN) بررسی کردند. در این خصوص، ۱۴۱ مکان سیل در منطقه مورد مطالعه را بر اساس تفسیر عکس‌های هوایی، داده‌های تاریخی، گوگل ارث و بررسی‌های میدانی شناسایی و استفاده کردند. نتایج اعتبارسنجی نشان داد که (RMSE) BE-C1 از نظر دقت، AUC و ویژگی و کمترین خطا (RMSE) بهترین عملکرد را داشته و عملکرد مدل‌های کلی با طیفی از AUC ۸۹-۹۷ درصد) قابل اعتماد بوده است. با این حال، برای مدیریت بهتر کاهش خطرات ناشی از سیل نیاز به شناخت عوامل مؤثر در هر منطقه و تحلیل حساسیت سیل است. در پژوهش دیگری، Saberi Tanasvan et al. (2020)

## ۱- مقدمه

سیلاب یکی از پرهزینه‌ترین مخاطرات طبیعی در سراسر جهان هست که در فواصل و بازه‌های مختلف رخ می‌دهند (Tajbakhsh Fakhraabadi and Chezgi, 2022) خسارت جدی به محیط زیست، حمل و نقل، اقتصاد، کشاورزی و زندگی مردم می‌شود (Kia et al., 2012; Iqbal et al., 2023). بنابراین، شناسایی مناطق حساس به وقوع سیل برای مدیریت Avand et al. (2020a). بر همین اساس، تهیه نقشه حساسیت به وقوع سیل به عنوان یک مرحله ضروری برای جلوگیری و مدیریت بهتر Khosravi et al., 2016; Abdi et al., 2023) این‌ها آینده شناخته شده است (). با این حال، به‌دلیل ذات پیچیده حوزه‌های آبخیز، مدل‌سازی آن‌ها با روش‌های هیدرولوژی ساده و خطی مطابقت ندارد (Pierdicca et al., 2010) و به‌دلیل رفتار چندبعدی سیل مدل‌های مختلف استفاده می‌شوند. در این راستا، در سال‌های اخیر روش‌های پیشرفته در تهیه نقشه‌های شناسایی پهنه‌های محتمل سیلاب با به‌کارگیری روش‌های یادگیری ماشین و داده‌کاوی نسبت به قلی اجرا شده است (Avand et al., 2020b). یادگیری ماشین روشنی جدید از هوش مصنوعی است که با استفاده از تجربه یادگیری به‌دبال نوشتن برنامه‌ای با بهترین عملکرد هستند. مدل‌های یادگیری ماشین با الگوریتم‌های متفاوت می‌توانند پیشگویانه یا توصیفی بوده و یا هر دو خاصیت را داشته باشند و در زمینه‌های مختلف استفاده شوند. در این میان، روش یادگیری ماشین در مدل‌سازی مخاطره‌های ناشی از سیل مورد استفاده قرار گرفته و پژوهش‌های مختلفی انجام شده است (Mosavi et al., 2018).

در این خصوص، Kazemi et al. (2022) به مدل‌سازی و پیش‌بینی مخاطره سیل طبق ویژگی‌های شهر بندی نوشیر، با استفاده از مدل‌های یادگیری ماشین پرداختند. آن‌ها از مدل‌های K نزدیک‌ترین همسایه، درخت تصمیم، یادگیری تجمعی و برای انجام صحبت‌سنگی مدل‌ها و انتخاب بهترین مدل از روش<sup>۱</sup> ROC بر اساس دو معیار ارزیابی صحبت و سطح زیر نمودار در خصوص بحران سیل استفاده کردند. نتایج نشان داد که مدل یادگیری تجمعی با صحبت ۰/۹۶ و سطح زیر نمودار ۰/۹۰ به عنوان بهترین مدل در پهنه‌بندی خطر سیلاب با روش یادگیری ماشین شناخته شد. از طرفی، Yousefi et al. (2022) به تعیین پتانسیل سیل با استفاده از مدل‌های یادگیری ماشین CART، GLM و GAM در حوزه آبخیز کشکان پرداختند. در این پژوهش به کارایی مدل‌های مذکور در شناسایی مناطق حساس

<sup>2</sup> Area under curve

<sup>3</sup> Curvature

<sup>1</sup> Receiver operating characteristic

به عبارتی هدف از پژوهش حاضر علاوه بر پهنه‌بندی خطر سیلاب با تکنیک یادگیری ماشین، مهم بود که چه حدودی از این متغیرهای مهم بر شکل گیری پهنه‌های سیلابی مؤثر بوده و اگر قرار است مدیریتی صورت بگیرد (۱) در کدام مناطق صورت گیرد (پهنه‌های سیل گیر کجاست؟)، (۲) روی کدام متغیرها (عوامل) تمرکز شود، (۳) اگر قرار است به فرض روی افزایش و بهبود اثرگذاری متغیرها بر کاهش پهنه‌های سیلابی عملیاتی انجام شود، تا چه حدودی این محقق شود (به عنوان مصدق چند درصد پوشش گیاهی در محدوده پهنه‌های سیل گیر منطقه مورد مطالعه در کاهش وقوع سیلاب مؤثر خواهد افتاد؟ در این راستا مقادیر کمتر و بیشتر از حدود تأثیرگذار این متغیر بر وقوع سیلاب چیست؟ و غیره)، و (۴) شناسایی محدوده‌های سیل گیر با وجود شاخص‌های ترکیب باندی مانند NDWI و MNDWI با وجود پوشش ابری روزهای وقوع سیلاب کار را کمی سخت خواهد کرد و حذف اثر ابر نیز باعث از بین رفتن ارزش تعدادی از پیکسل‌های تصویر خواهد شد. بنابراین، یادگیری ماشین جبران این محدودیت‌ها استفاده از شاخص‌های ترکیب باندی را در شناسایی مناطق سیل گیر فراهم خواهد نمود.

## ۲- مواد و روش

### ۲-۱- منطقه مورد مطالعه

محدوده مورد مطالعه با مختصات "۳۳° ۳۹' ۳۰" تا "۱۴°۰'۴" ۳۲° شمالي و "۴۷°۵۹'۲۸" تا "۴۹°۱۱'۵۹" شرقی در استان خوزستان قرار گرفته است. در این تصویر پهنه‌های سیلابی با استفاده از ترکیب باندی کاذب به رنگ تیره قابل مشاهده است. تصویر مورد استفاده لندست هشت سنجنده OLI مربوط به تاریخ هشت آوریل ۲۰۱۹ است. مناطق شهری مانند ملاٹانی، ویس، شبیان و قسمت اعظم شمال تا مرکز شهر اهواز در این محدوده قرار دارد. حداقل ارتفاع محدوده مورد مطالعه ۱۰۶ متر از سطح دریا است و درصد از سطح محدوده مطالعاتی را داشته‌های رسوبی تشکیل داده‌اند. بارش متوسط سالانه این محدوده بین ۲۵۰ تا ۳۰۰ میلی‌متر در سال است که قسمت اعظم بارش‌ها در زمستان و اوایل فصل بهار نازل می‌شود که گاهی به شکل رگبار باعث بروز سیلاب در منطقه می‌شود (Solaimani and Darvishi, 2020). عمده سازنده‌های این محدوده (درصد) از نهشته‌های کواترنری (Qft<sub>2</sub>) بوده و قسمت اعظم آن را کاربری اراضی کشاورزی، دیم‌زارها، اراضی باتلاقی و سوره‌زارها هست. دارای ۱۳۴ روستا است که از این تعداد ۱۵ نقطه روستایی در معرض خطر سیلاب قرار دارند. قابل ذکر است که حدود ۲۰ کیلومتر از راه‌های مواصلاتی روستایی و بالغ بر ۲۸ هکتار از اراضی شهری در معرض خطر سیلاب قرار دارند. با توجه به جاری شدن آب از

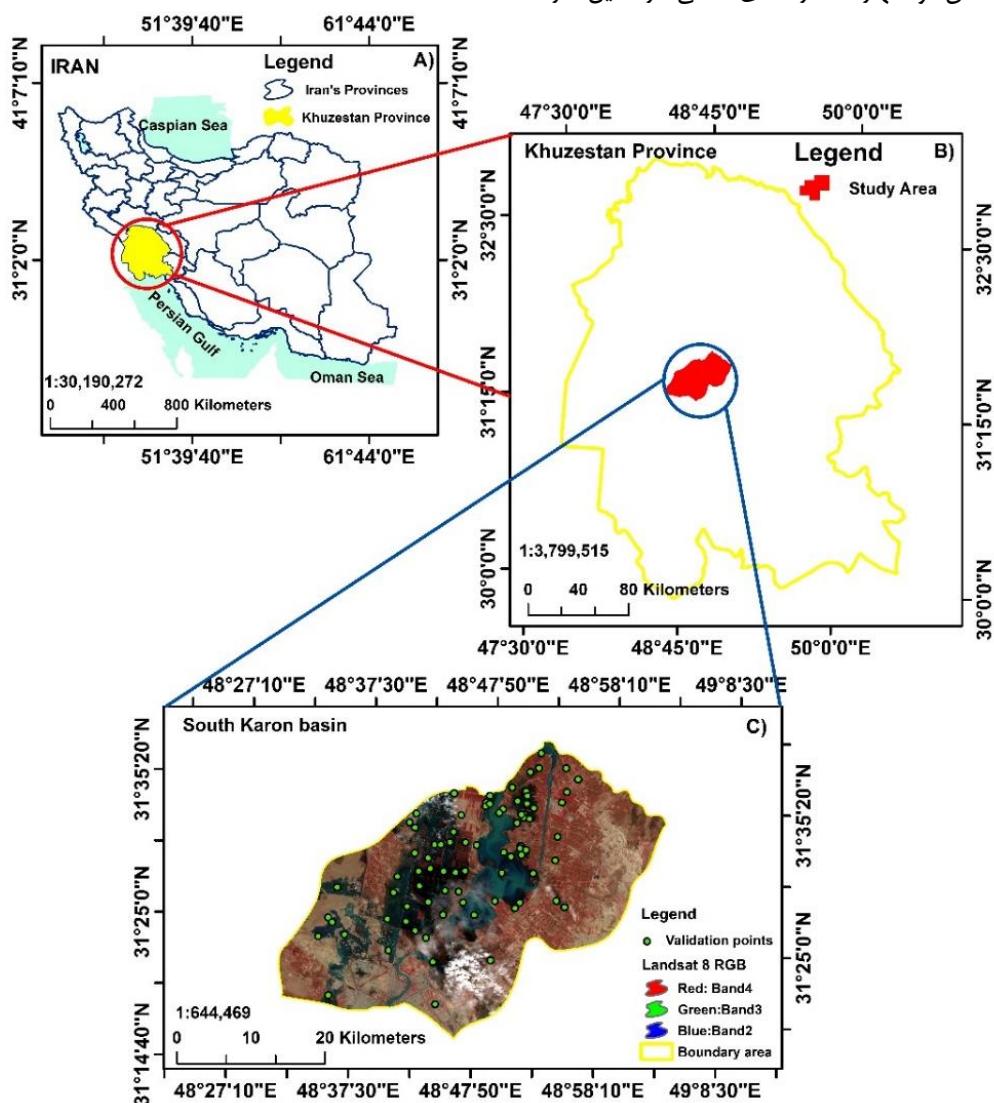
پارامترهای سیل نسبت به تغییرات زیری در منطقه شیروان را بررسی کردند. نتایج پژوهش آن‌ها نشان داد پارامتر سرعت جريان به تغییر زیری واکنش بیشتری نسبت به عمق و سطح سیل گیر دارد و عمق جريان کمترین وابستگی به میزان تغییر ضریب زیری را داشته است. در ادامه، Shafizadeh- Moghadam et al. (2018) با استفاده از روش‌های مختلف یادگیری ماشین به پهنه‌بندی خطر سیلاب و نیز شناسایی رفتار متغیرهای شاخص پوشش گیاهی، شاخص خمیدگی حوزه آبخیز، ارتفاع، پوشش اراضی، زمین‌شناسی، بارش، تراکم زهکشی، فاصله تا رودخانه، شب و شاخص‌های خشکسالی SPI و TWI در حوزه آبخیز هزار استان مازندران پرداختند. در نهايیت، Faramarzi et al. (2020) با استفاده از سه روش یادگیری ماشین جنگل تصادفی، درخت رگرسیون تقویت شده و آنتروپی بیشینه به شناسایی متغیرهای مهم در ایجاد مناطق سیل گیر و ارائه پتانسیل مخاطره سیلاب پارک ملی گلستان پرداختند. نتایج ایشان نشان داد مدل یادگیری ماشین درخت رگرسیون تقویت شده با مقدار ROC معادل ۰/۹۹ بیشترین دقت را دارد و متغیرهای ارتفاع، میانگین دمای سالانه، بارندگی و فاصله از آبراهه متغیرهای مؤثر بر وقوع سیلاب هستند.

شایان ذکر است مورور منابع نشان داد که بعضی پژوهش‌گران شناسایی محدوده‌های سیل گیر را با شاخص‌های ترکیب باندی، مانند NDWI و MNDWI با وجود پوشش ابری روزهای وقوع سیلاب انجام می‌دهند (Solaimani and Darvishi, 2020). اما این موضوع کار را کمی سخت خواهد کرد و حذف اثر ابر نیز به خودی خود باعث از بین رفتن ارزش تعدادی از پیکسل‌های تصویر خواهد شد. بنابراین، یادگیری ماشین جبران این محدودیت‌ها در استفاده از شاخص‌های ترکیب باندی در شناسایی مناطق سیل گیر را خواهد نمود و پژوهش حاضر این نکته را مد نظر قرار داده است.

در خصوص نوآوری پژوهش حاضر ذکر این نکته لازم است که بیشتر پژوهش‌های صورت گرفته به استفاده چندین مدل یادگیری ماشین در خصوص پهنه‌بندی سیلاب پرداخته و سپس به انتخاب بهترین مدل بر اساس شاخص‌های ارزیابی مدل و یادگیری‌ها بستنده کرده‌اند. در این پژوهش‌ها گاهی اوقات نیز به اهمیت نسبی متغیرهای تأثیرگذار بر وقوع سیلاب پرداخته شده است (Sayyad et al., 2022). در پژوهش حاضر ضمن استفاده از تکنیک یادگیری ماشین، پهنه‌بندی سیلاب، استفاده از شاخص‌های ارزیابی مدل در خصوص میزان کارایی مدل، مطابقت نتایج پهنه‌بندی سیلاب با واقعیت زمینی، به استخراج اهمیت نسبی متغیرها بر وقوع سیلاب و شناسایی آستانه و حدود تأثیرگذاری متغیرهای مستقل بر وقوع سیلاب پرداخته است.

برنامه‌های آتی است. شکل ۱ موقعیت منطقه مورد مطالعه را در کشور و استان خوزستان نشان می‌دهد.

بالا درست در اثر رگبارهای زمستانه و بهاره به سمت نواحی پایین دست و جمع شدن آب در این نواحی با در نظر گرفتن سیل گیر بودن استان خوزستان، پهنه‌بندی و پایش سیل گامی مؤثر برای کاهش و مهار خسارت‌های ناشی از سیل در



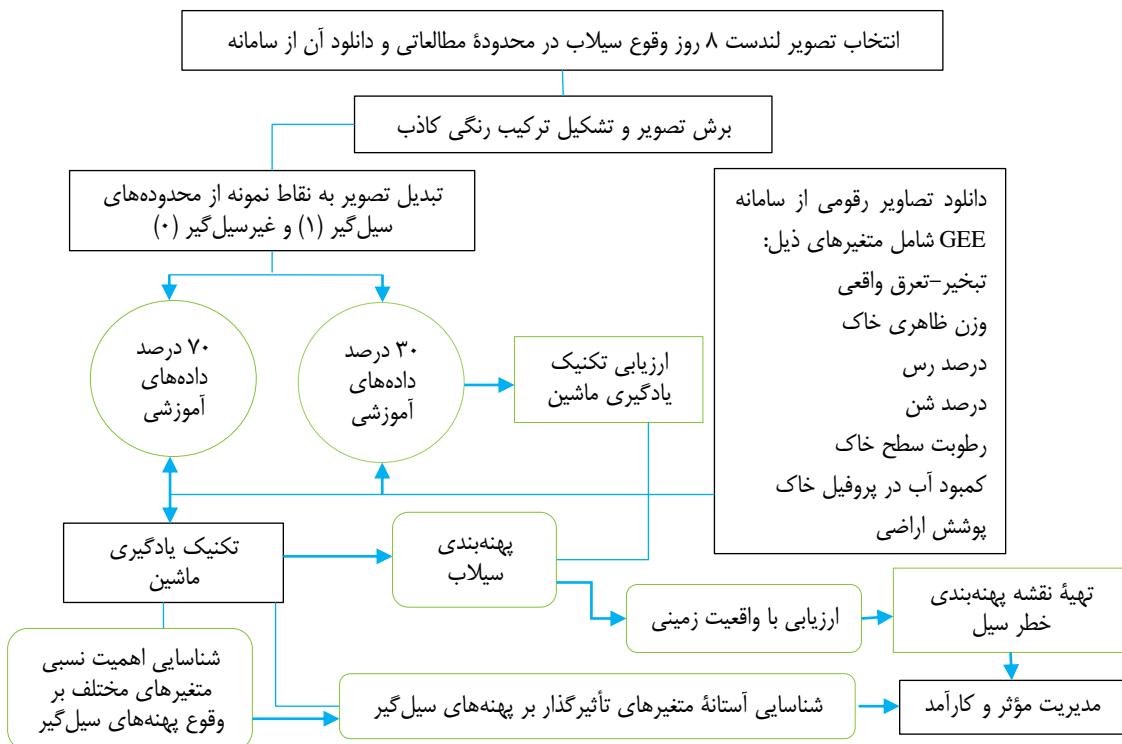
شکل ۱ - موقعیت منطقه مورد مطالعه در کشور و استان خوزستان  
Figure 1- Location of the studied area in Iran and Khuzestan Province

همین راستا، برای شناسایی آب پایه از تصویر متناظر سال ۲۰۱۸ منطقه برای جداسازی و شناسایی پهنه‌های آب پایه استفاده شد. سپس باقی‌مانده پیکسل‌های محدوده مطالعاتی به عنوان کل نمونه‌ها و پهنه‌های سیل‌زده نیز به عنوان نمونه‌های هدف وارد فرآیند مدل سازی شدند. بنابراین، مناطق سیل‌زده با کد یک و مناطق غیر آن با کد صفر به عنوان متغیر وابسته وارد فرآیند مدل سازی و یادگیری ماشین شدند. قابل ذکر است که این مهم صرفاً با استفاده از تصویر رنگی کاذب (ترکیب باندی ۴۳۲) صورت گرفته است و این پهنه‌ها با دیگر متغیرهای مستقل وارد فرآیند یادگیری ماشین و کشف روابط شدند. متغیرهایی که به عنوان

دو مرحله انجام پژوهش حاضر ارائه شده است. بدین صورت که در ابتدا از تصاویر لندست OLI8 تاریخ هشتم آوریل سال ۱۹ (۲۰۱۹ فروردین ۱۳۹۸) برای شناسایی پهنه‌های سیل گیر استفاده شد. دلیل استفاده از تصویر لندست سنتجند OLI در تاریخ مذکور، وقوع سیلاب و مشهود بودن پهنه‌های سیل گیر و بارز بودن آن مناطق در تصویر ماهواره‌ای یاد شده است. همچنین، بارش‌های سیل آسای آوریل ۲۰۱۹ در سطح کشور (از گرگان تا شیراز و خوزستان و غیره) یکی از بی‌سابقه‌ترین بارش‌های ثبت شده در ۲۰۰ سال اخیر بود که خسارات جانی و مالی فراوانی بر جای گذاشت. در

بارش تجمیعی، درصد شن خاک، بافت خاک، رطوبت خاک، جهت شبیب و حداقل و حداکثر دما بود که با استفاده از کدنویسی در محیط اسکریپت جاوا در سامانه گوگل ارت انجین (GEE) به شکل رقومی احصاء و در پژوهش حاضر ارائه شده است.

متغیرهای مستقل در فرآیند یادگیری ماشینی وارد شدند شامل تبخیر و تعرق واقعی، کاربری اراضی، وزن ظاهری خاک، درصد رس خاک، کمبود آب خاک، ارتفاع از سطح دریا، شاخص پوشش گیاهی، شاخص شدت خشکسالی پالمر، تبخیر-تعرق پتانسیل،



شکل ۲- نمودار جریانی مراحل انجام پژوهش حاضر  
Figure 2- Flowchart of the steps of the current research

آن به شرح جدول ۲ است. همچنین، کدهای کاربری اراضی ارائه شده در جدول ۱ به ترتیب شامل آب پایه، باتلاق، کلوت، مرداب، سورهزار، کفه‌های رسی، رخنمون‌ها، اراضی بدون پوشش و لخت، شن‌زار، اراضی کشاورزی، اراضی مرتعی و مناطق شهری هستند.

**۱-۱-۲-۱- درختان رگرسیون چندگانه جمع‌شدتی (TreeNet)** درخت‌های رگرسیون افزایشی چندگانه (MART) که به عنوان TreeNet نیز شناخته می‌شود یک پیشرفتی در داده‌کاوی است که توسط Friedman (2002) در دانشگاه استنفورد پیشنهاد شده است. تقویت گرادیان تصادفی یا همان ترینت یکی از معمول‌ترین الگوریتم‌های گروهی تقویتی هست. روش TreeNet از صدھا و هزاران درخت تشکیل شده که هر کدام دارای گره‌های متعددی هستند. هر درخت نقش کوچکی در تشکیل درخت اصلی مدل دارند. این روش برای اکثر مسائل مدل‌سازی قابل استفاده است. این روش روی دقت پیش‌بینی تمرکز دارد و ترکیب مدل‌هایی با بالاترین کیفیت را انجام می‌دهد تا مثل یک مدل منفرد باشند. این روش شامل داده‌های

گام بعد با وارد کردن متغیرهای هدف (پنهان‌های سیلاپی) و متغیرهای یادشده انجام فرآیند یادگیری ماشینی با روش درختان رگرسیون چندگانه جمع‌شدتی<sup>۴</sup> (TreeNet) و ارزیابی عملکرد مدل به عنوان مدل مناسب انتخاب شد و عملیات پنهان‌بندی خط سیلاپ در سامانه اطلاعات جغرافیایی انجام شد. در نهایت، رابطه بین پنهان‌های سیلاپ با متغیرهای دارای بیشترین اهمیت نسبی در فرآیند مدل‌سازی مورد تحلیل ماشین قرار گرفت و ضمن ترسیم نمودار دو بعدی همبستگی جزئی پنهان‌های سیل گیر و متغیرهای تأثیرگذار، آستانه و حدود تأثیرگذاری هر یک از مؤلفه‌های مورد مطالعه بر پنهان‌های سیل حاصل از یادگیری ماشین نیز به دست آمد. در ادامه، مراحل انجام پژوهش حاضر ارائه شده است (شکل ۲).

در جدول ۱ مشخصات مؤلفه‌های مورد استفاده در پژوهش حاضر ارائه شده است. در خصوص متغیر بافت خاک کدهای حاصل از طبقه‌بندی به روش USDA (اخذ شده از پایگاه داده Openland Map soil texture) به صورت جدول ۱ و طبقات

<sup>4</sup> Multiple additive regression trees (MART)

چند صد درخت کوچک تشکیل شده است که هر کدام معمولاً از دو تا هشت گره پایه بزرگ‌تر نیستند (Elish, 2009).

مشکوک می‌شود (Friedman, 2003). در این روش کسری از نمونه‌های آموزشی برای آموزش هر درخت استفاده می‌شوند. این مدل، در واقع شکه درختی است که معمولاً از چند ده تا

جدول ۱- مشخصات مؤلفه‌های مورد استفاده در پژوهش

Table 1- Specifications of the components used in the current study

نام متغیر	واحد	نام اختصاری	حداکثر	حداقل	میانگین	اتحراف میانگین
تبخیر- تعرق واقعی	میلی‌متر	Aet	22.2	13	17.23	2.43
جهت شیب	-	Aspect	10	1	5	2.74
وزن ظاهری خاک	کیلوگرم بر مترمکعب	Bulk	169	0	147.89	22.16
محتوای رس خاک	درصد	Clay	37	0	23.52	5.21
کمبود آب در خاک	میلی‌متر	Def	158.1	127.8	144.62	7.68
ارتفاع از سطح دریا	متر	DEM	106	0	23.28	4.62
شاخص پوشش گیاهی	-	NDVI	0.69	-0.45	0.09	0.168
کاربری اراضی	-	Land Cover	13	1	8	3.92
شاخص خشکسالی پالمر	-	PDSI	2.7	1.6	1.93	0.25
تبخیر- تعرق مرجع	میلی‌متر	Pet	171.6	149.6	161.8	5.83
بارش تجمیعی	میلی‌متر	Pr	21	12	15.81	2.54
محتوای شن خاک	درصد	Sand	72	0	43.56	9.63
بافت خاک	-	Soil texture	9	0	6	1.7
رطوبت سطح خاک	میلی‌متر	Soil moisture	13.9	5	9.01	1.94
حداکثر دمای روزانه	درجه سانتی‌گراد	TMMN	17.29	15.5	16.56	0.47
حداقل دمای روزانه	درجه سانتی‌گراد	TMMX	32.5	30.4	31.56	0.5

جدول ۲- کدبندی متغیر بافت خاک به روش USDA

Table 2- Coding of soil texture variable by USDA method

نوع بافت خاک											
Sa	LoSa	Si	SaLo	SiLo	Lo	SaClLo	SiClLo	ClLo	SaCl	SiCl	Cl
12	11	10	9	8	7	6	5	4	3	2	1

## ۲-۲-۲- ارزیابی نتایج مدل

برای ارزیابی نتایج یادگیری ماشینی از شاخص‌های حساسیت<sup>۱</sup>، ویژگی<sup>۲</sup>، صحت کلی<sup>۳</sup> و میانگین حساسیت مدل برای طبقات هدف و غیرهدف طبق رابطه‌های زیر استفاده شد (Avand et al., 2020a).

$$\text{Sensitivity} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (3)$$

$$\text{Mean of Sensivity} = \frac{\text{Sensitivity}_1 + \text{Sensitivity}_0}{2} \quad (4)$$

در رابطه‌های بالا، TP تعداد مثبت صحیح (تعداد نمونه‌هایی که بدسترسی به کلاس سیل تشخیص داده شده)، TN تعداد مثبت کاذب (تعداد نمونه‌هایی که به اشتباه به کلاس سیل تشخیص داده شده)، FN تعداد منفی کاذب (تعداد نمونه‌هایی کلاس سیل که به اشتباه به کلاس غیرسیل تشخیص داده شده‌اند) و FP تعداد مثبت کاذب هستند (تعداد نمونه‌هایی کلاس

در پژوهش حاضر هر درخت با ۳۰ درصد از نمونه‌های آموزشی، آموزش دیده‌اند که به شکل تصادفی و رندوم انتخاب شده‌اند. این روش واریانس کوچک و فرآیند آموزش سریعی دارد.

به طور کلی درخت رگرسیون چندگانه جمع‌شدنی یک الگوریتم دارای تکرار هست که بر اساس رابطه (۱) در هر تکرار  $T_m(x_i\{R_{jm}\}, j=1, \dots, m)$ ، یک درخت رگرسیون مانند: (j) ساخته شد، که در هر کدام یک متغیر پیش‌بینی کننده  $x$ ، مناطق جداگانه  $z$  و یک مقدار ثابت جداگانه پیش‌بینی شد (Monteiro 2002).

$$T_m(x; \{R_{jm}\})_1^j = \sum_{i=1}^j \bar{y}_{jm} I(x \in R_{jm}) \quad (1)$$

در رابطه بالا،  $\bar{y}_{jm}$  میانگین مقدار شبیه پیش‌بینی در هر موقعیت،  $R_{jm}$  در تکرار  $m$  امین است. در پژوهش حاضر از داده‌های یادگیری و آزمون به نسبت ۷۰ به ۳۰ درصد و به صورت کاملاً تصادفی استفاده شد. شایان ذکر است که تعداد ۲۰۰ درخت حداقل با شش گره برای مدل‌سازی تنظیم شد. تعداد کل نمونه‌های وارد به مدل ۲۷۵۱۵ نقطه نمونه بوده است.

<sup>1</sup> Sensitivity

<sup>2</sup> Specificit

<sup>3</sup> Overall accuracy

و به تعداد  $n$  بار مدل تکرار می‌شود. در هر بار تکرار یک متغیر از داده‌های آموزشی مدل حذف و خطای RMSE مدل محاسبه می‌شود. در انتهای خطای به دست آمده با بزرگ‌ترین مقدار RMSE به دست آمده نرمال می‌شود و دامنه‌ای بین صفر تا یک را به خود اختصاص می‌دهد. بنابراین، متغیری که بالاترین میزان RMSE را در هر بار تکرار داشته باشد از الگوریتم حذف و نهایتاً همه متغیرها به نسبت شاخص مذکور با یکدیگر مقایسه می‌شوند (Were et al., 2015; Reis et al., 2018).

### ۳- نتایج و بحث

پژوهش حاضر با هدف پنهان‌بندی، برآورد اهمیت نسبی و شناسایی حدود متغیرهای مؤثر بر پنهان‌های سیلاب با استفاده از روش یادگیری ماشین انجام شد. بر همین اساس، در جدول ۳ نتایج ارزیابی مدل مورد استفاده ارائه شده است و بیان‌گر عملکرد مناسب مدل TreeNet در مدل‌سازی پنهان‌های سیلاب است. از این‌رو، مدل مذکور برای انجام سایر مراحل و تحلیل‌های بین پنهان‌های سیلاب و متغیرهای مستقل دیگر استفاده شد. همچنین، در جدول ۴ پارامترهای میزان یادگیری و آموزش مدل آورده شده است. در جدول ۴ مقدار ROC برای داده‌های یادگیری و آزمایشی به ترتیب ۰/۹۶ و ۰/۹۷ می‌باشد. به دست آمده که مقدار بسیار مناسبی است. فرآیند یادگیری ماشین با استفاده از مدل TreeNet در شکل ۲ ارائه شده است. با توجه به شکل ۲، مدل در درخت شماره ۲۰۰ به مقدار بهینه متغیر واپسیه معادل ۰/۱۵۱ رسیده است.

**جدول ۳- شاخص‌های حساسیت، ویژگی، صحت کلی مدل و میانگین حساسیت کلاس‌ها در مدل یادگیری ماشین TreeNet**  
Table 3- Sensitivity, specificity, the overall accuracy of the model, and the average sensitivity of the classes in the TreeNet machine-learning model

نام مدل	حساسیت	ویژگی	صحت کلی	میانگین حساسیت
مدل (درصد)	(درصد)	(درصد)	(درصد)	
TreeNet	90.43	91.2	91.12	90.81

**جدول ۴- میزان آموزش و یادگیری مدل TreeNet در یادگیری ماشین جهت پنهان‌بندی سیلاب حوزه آبریز انتهایی کارون**  
Table 4- The amount of training and learning of the TreeNet model in machine learning for flood zoning in the Karun Basin

یادگیری	آزمایشی	شاخص	
0.97	0.96	(AUC) ROC	سطح زیرمنحنی
7.71	6.89	(Lift)	شاخص میزان منطقی بودن قاعده

غیرسیل که به اشتباه در کلاس سیل تشخیص داده شده‌اند) (Congalton and Green, 2008). در خصوص معیار ارزیابی صحت کلی، مقصود نمایش آماری دقت کلی است، که با تقسیم تعداد درست نمونه‌های هدف (پیکسل‌هایی که به درستی پنهان‌های سیلاب تشخیص داده شده‌اند) بر مجموع کل نمونه‌ها در ماتریس خط‌باختر است (Congalton and Green, 2008):

$$\text{Overall accuracy} = \frac{\sum_{i=1}^{i=k} X_i}{N} \quad (5)$$

در رابطه (5)،  $\sum_{i=1}^{i=k} X_i$  جمع قطری ماتریس خط‌باختر،  $N$  جمع کلی نمونه‌ها در ماتریس خط‌باختر است. همچنین، از مقادیر شاخص Lift در خصوص میزان منطقی بودن قاعده و نشان دادن همبستگی مثبت در وقوع آیتم پنهان‌های سیلاب (آیتم  $X$ ) استفاده شد. مقادیر بزرگ‌تر از یک حاکی از وابستگی قوی‌تر و به عنوان یک قاعدة بالارزش و منطقی بین متغیر هدف و سایر متغیرهای مستقل ورودی به یادگیری ماشینی هست (Hong et al., 2020).

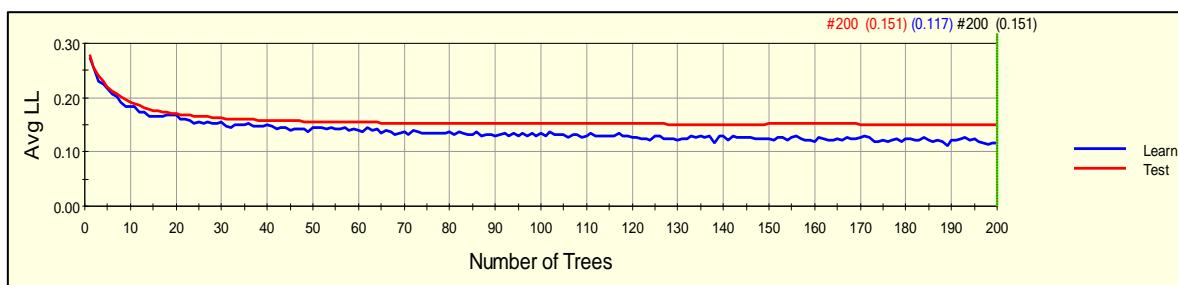
به منظور ارزیابی مدل پنهان‌بندی سیلاب از منحنی تشخیص عملکرد نسبی استفاده شد. منحنی ROC نمایشی گرافیکی از موازن نزخ خطای منفی و مثبت برای هر مقدار احتمالی از برش‌های است. سطح زیرمنحنی که به AUC مشهور است بیان‌گر مقدار پیش‌بینی سیستم از طریق توصیف توانایی آن در تخمین درست و قایع رخ داده (وقوع سیلاب و شکل‌گیری پنهان سیلابی) و عدم وجود آن (عدم وجود سیلاب و پنهان‌های سیلابی) است (Avand et al., 2020a). مقادیر سطح زیرمنحنی از ۰/۵ تا ۱/۰ متفاوت است که هر چه این مقدار به سمت یک نزدیک‌تر باشد بیان‌گر دقیق‌تر نشانه پنهان‌بندی سیلاب است. همچنین، جهت ارزیابی نتایج پنهان‌بندی مدل با واقعیت زمینی از شاخص‌های  $R^2$  و RMSE استفاده شد که به شرح روابط (۶) تا (۸) هستند. در همین راستا، برای صحت پنهان‌های به دست آمده نتایج با ۸۲ نقطه با واقعیت زمینی مطابقت داده شد که نقاط کنترل زمینی پنهان‌های سیلابی در شکل ۱ آورده شده است.

$$R^2 = \frac{\sum(X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum(X - \bar{X})^2} \sqrt{\sum(Y - \bar{Y})^2}} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (8)$$

جهت محاسبه اهمیت نسبی هر متغیر مدل یادگیری ماشین روی تعداد متغیرهای ورودی به مدل ( $n=16$ ) تنظیم



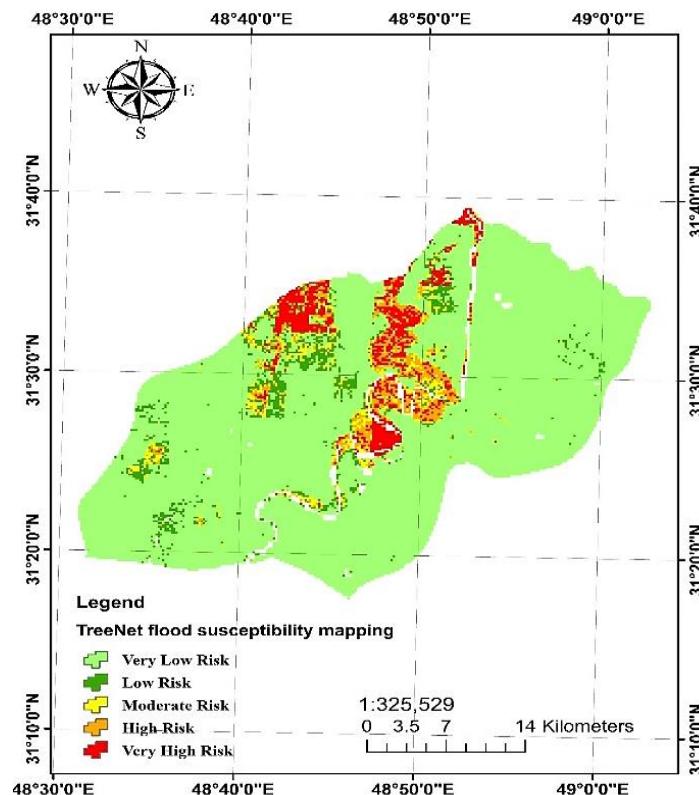
شکل ۲- نتایج مدل‌سازی TreeNet در یادگیری ماشین پهنه‌بندی سیلاب آبریز کارون  
Figure 2- The results of TreeNet modeling in machine learning for flood zoning of Karun Basin

زمانی که پوشش وجود نداشته باشد بارش مستقیم به سطح زمین برخورد می‌کند و با تخریب خاک میزان رواناب تولیدی را افزایش خواهد داد. بنابراین، سیلابی شدن افزایش خواهد یافت و یا در صورتی که مناطق بدون پوشش شامل اراضی آسفالت شده و یا با نفوذپذیری کم باشد بارش ورودی به رواناب تبدیل شده و سیلابی شدن را افزایش خواهد داد. از این‌رو، وجود پوشش گیاهی هم به سبب نقش گیاه در جذب بارش به صورت برگاب و ساقاب و هدایت رواناب به دوران لایه خاک باعث افزایش نفوذپذیری شده و در نتیجه سیلابی شدن را کاهش خواهد داد. متوسط وزنی پوشش گیاهی منطقه  $0.09$  است. میزان پوشش گیاهی که مؤثر واقع شده دامنه صفر تا  $0.2$  بوده است. به عبارتی پوشش گیاهی منطقه مورد مطالعه بیش از این نبوده است که اثرگذار باشد. با افزایش پوشش گیاهی پهنه‌های سیلابی کاهش می‌یابد و نمودار هم عکس این موضوع را ارائه نکرده است. منتها قابلیت پوشش گیاهی محدوده مورد مطالعه بیش از این نیست، مگر این که اگر پوشش غنی‌تر بود این روند کاهش بیش‌تر خود را نشان می‌داد.

در جدول ۵ ارزش نسبی هر یک از مؤلفه‌های مورد استفاده در پهنه‌بندی سیلاب ارائه شده است. با مشخص شدن اهمیت نسبی متغیرهای مورد استفاده بر پهنه‌بندی سیل، در شکل ۴ آستانه و حدود تأثیرگذاری این متغیرها در وقوع سیلاب ارائه شده است.

شکل ۳، نتایج پهنه‌بندی سیلاب و خطر (ریسک) را نشان می‌دهد. بر همین اساس، خطر سیلاب با ریسک خیلی کم، کم، متوسط، زیاد و خیلی زیاد به ترتیب با  $0.1496$ ،  $0.120$ ،  $0.151$ ،  $0.117$  و  $0.151$  هکتار از سطح محدوده مورد مطالعه را به ترتیب با  $4256$  و  $5500$  درصد به خود اختصاص داده‌اند. از طرفی مقایسه مناطق وقوع سیلاب، ثبت موقعیت زمینی آن‌ها و مقایسه با نتایج پهنه‌بندی حاصل از یادگیری ماشین، مقدار  $R^2$  معادل  $0.728$  درصد را نشان داد. همچنین، میزان RMSE معادل  $0.052$ ، MAE معادل  $0.027$  بود که نشان از عملکرد نسبتاً خوب مدل در قیاس با واقعیت زمینی است. نتایج شکل ۳ نشان می‌دهد مؤلفه‌های مختلف (متغیرهای مختلف) آستانه‌های مشخصی در شروع سیلابی شدن اراضی دارند. شکل ۳-الف در خصوص پوشش گیاهی به عنوان مهم‌ترین عامل مؤثر در پهنه‌بندی سیل و بروز آن نشان می‌دهد، نبود پوشش گیاهی باعث سیلابی شدن می‌شود و هر چقدر سطح پوشش گیاهی افزایش یابد از سیلابی شدن جلوگیری می‌کند. این روند به محض موجود شدن پوشش گیاهی باعث افت چشمگیر وقوع سیلاب تا حد آستانه نزدیک  $0.2$  می‌شود و بعد از این حد، حالت ثابت و بدون اثر در نمودار ۳-الف مشاهده می‌شود. همان گونه که از نمودار یاد شده برمی‌آید حدود اثرگذاری از صفر تا  $0.18$  بوده و نقطه عطف آن  $0.1$  است. دلیل آن نقش پوشش گیاهی در هیدرولوژی رواناب حاصل از بارش هست. به عبارتی





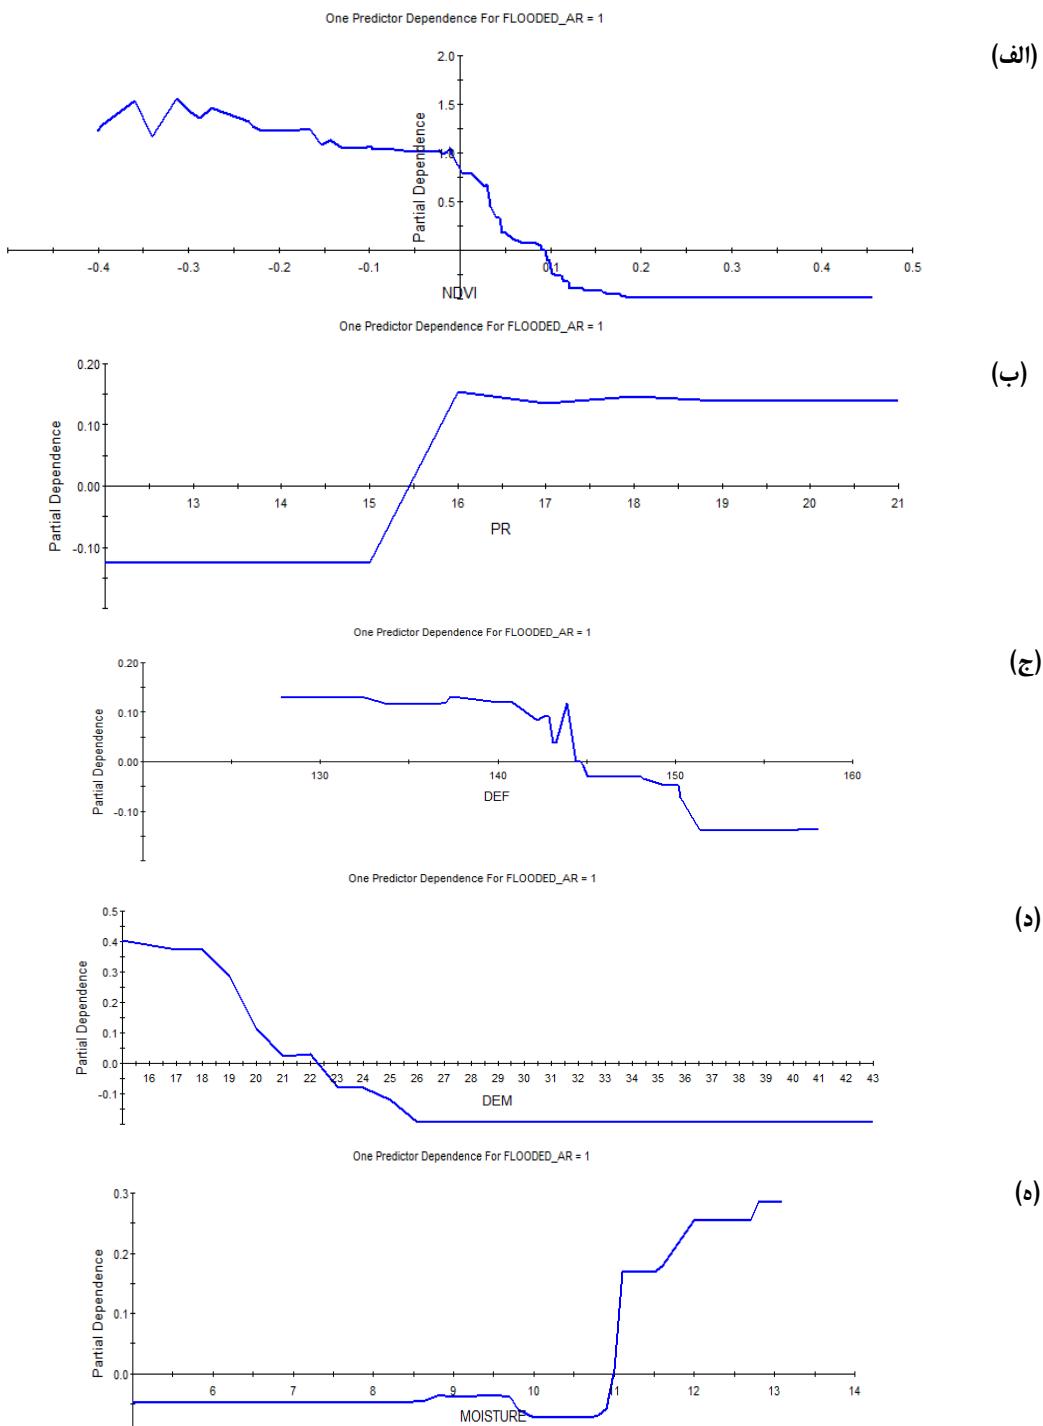
شکل ۳- نقشهٔ پهنه‌بندی خطر سیلاب منطقهٔ مورد مطالعه

Figure 3- Flood risk zoning map of the study area

جدول ۵- اهمیت نسبی متغیرهای مورد استفاده در پهنه‌بندی سیلاب با استفاده از رویکرد یادگیری ماشینی

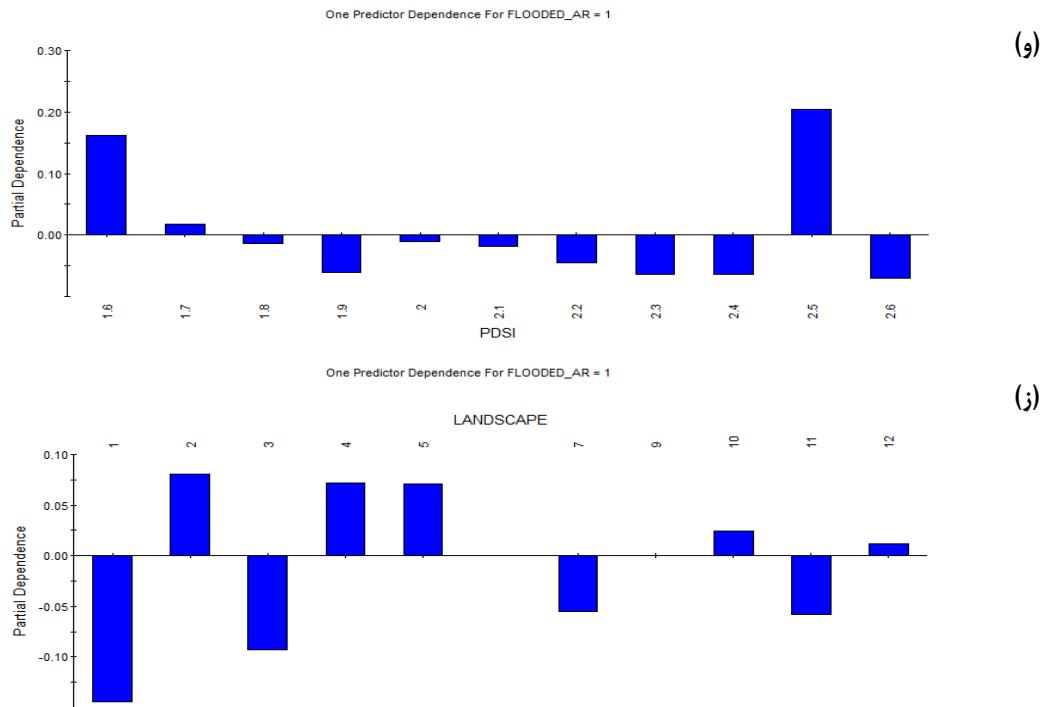
Table 5- Relative importance of variables used in flood zoning using a machine learning approach

متغیر	ارزش	اهمیت نسبی
شاخص پوشش گیاهی	0.37	
بارش تجمعی (میلی‌متر)	0.23	
كمبود آب در خاک (میلی‌متر)	0.12	
شاخص شدت خشکسالی پالمر	0.12	
کاربری اراضی	0.10	
ارتفاع (متر)	0.09	
رطوبت خاک (میلی‌متر)	0.09	
تبخیر و تعرق واقعی (میلی‌متر)	0.09	
حداقل دمای روزانه (°C)	0.08	
درصد شن خاک	0.08	
درصد رس خاک	0.07	
وزن ظاهری خاک (گرم بر سانتی‌مترمکعب)	0.07	
تبخیر و تعرق پتانسیل (میلی‌متر)	0.06	
جهت شب	0.05	
حداکثر دمای روزانه (درجه سانتی‌گراد)	0.05	
بافت خاک	0.04	



شکل ۴- آستانه شاخص‌های مورد استفاده در پهنه‌بندی سیلاب حوزه آبخیز کارون با استفاده از روش یادگیری ماشین: (الف) شاخص پوشش گیاهی، (ب) بارش تجمعی، (ج) کمبود آب خاک، (د) ارتفاع، (ه) رطوبت سطحی خاک، و (ز) کاربری اراضی

Figure 4- Threshold of the indicators used in Karun Basin flood zoning using machine learning method: a) NDVI, b) Cumulative rainfall, c) Soil water deficit, d) DEM, e) Soil surface moisture, f) Palmer drought index, and g) land use



ادامه شکل ۴- آستانه شاخص‌های مورد استفاده در بهنده‌بندی سیالاب حوزه آبخیز کارون با استفاده از روش یادگیری ماشین: (الف) شاخص پوشش گیاهی، (ب) بارش تجمعی، (ج) کمبود آب خاک، (د) ارتفاع، (ه) رطوبت سطحی خاک، (و) شاخص خشکسالی پالمر و (ز) کاربری اراضی

Continued Figure 4- Threshold of the indicators used in Karun basin flood zoning using machine learning method: a) NDVI, b) Cumulative rainfall, c) Soil water deficit, d) DEM, e) Soil surface moisture, f) Palmer drought index, and g) land use

عمل کرده‌اند و مقادیر بیش از ۰/۰ نیز رفتاری شبیه نتایج پژوهش Shafizadeh-Moghadam et al. (2018) نشان داده است. از طرفی نتایج روش درخت رگرسیون تقویت شده در پژوهش‌های Faramarzi et al. (2020) نقش پوشش گیاهی در بروز مخاطره سیالاب در پارک ملی گلستان را ۰/۵ درصد اعلام کردند و مقادیر کمتر از ۰/۰۲ را دارای بیشترین احتمال در خصوص شکل‌گیری پهنه‌های سیالابی دانسته‌اند. قابل ذکر است در پژوهش ایشان با افزایش پوشش گیاهی به میزان بسیار کم خطر شکل‌گیری پهنه‌های سیالابی نزول کرده و احتمال آن کاسته شده است.

شكل ۳- ب نشان می‌دهد حد آستانه بارش تجمعی در سیالابی شدن منطقه مورد مطالعه ۱۵ میلی‌متر بارندگی بوده است و کمتر از آن بارش ورودی خطری برای سیالابی شدن اراضی مورد مطالعه نداشته است. اما زمانی که میزان بارش تجمعی به ۱۶ میلی‌متر برسد سیل پهنه‌های حوزه آبخیز مطالعاتی را تهدید خواهد کرد و مقدار ۱۵/۵ میلی‌متر بارش نقطه عطف و آستانه شروع سیالابی شدن منطقه مطالعاتی بوده است. در پژوهشی، Shafizadeh-Moghadam et al. (2018) بیان کرده‌اند که در حوزه آبخیز هراز، استان مازندران مقادیر بیش از ۴۰۰ میلی‌متر بر احتمال وقوع سیالاب اثر چندانی ندارد (به مقدار ثابتی رسیده است) و مقادیر بارش حدود ۲۲۰ میلی‌متر بیشترین احتمال در رخداد سیالاب را به خود اختصاص داده

با توجه به روند کاهشی میزان پهنه‌های سیل‌گیر با افزایش میزان پوشش گیاهی، حد آستانه کاهشی متغیر وابسته، صفر تا ۰/۲ محاسبه شد. متوسط وزنی شاخص پوشش گیاهی محدوده مورد مطالعه مقدار ۰/۰۹ محاسبه شد که این مهم حکایت از کمبود پوشش گیاهی در محدوده چهت کاستن از پهنه‌های سیل‌گیر دارد. نتایج پژوهش‌های سایر پژوهش‌های مختلف است که بین میانگین حجم رواناب در پوشش‌های مختلف گیاهی اختلاف معناداری وجود دارد (Kavianpour et al., 2014). نتایج پژوهش نامبرده نشان داد میانگین زمان شروع رواناب در پوشش گیاهی حداقل به طور معناداری از همه بیشتر بوده، ولی بین پوشش‌های گیاهی متوسط و حداقل اختلاف آماری معناداری وجود ندارد و نیز بین ضریب رواناب در پوشش‌های مختلف گیاهی اختلاف آماری معناداری مشاهده شده است. در پژوهشی، Shafizadeh-Moghadam et al. (2018) در خصوص نقش پوشش گیاهی بر احتمال وقوع سیالاب اعلام کرده بیشترین احتمال وقوع سیالاب در مطالعه منفی شاخص NDVI وجود دارد. مقادیر صفر تا ۰/۰۲ در مطالعه ایشان با رشد احتمال وقوع سیالاب مواجه و مقادیر بیشتر از ۰/۰ نیز رفتار شبیه خط صاف (رسیدن به مقدار ثابت) را نشان داد و احتمال وقوع سیالاب را بیش از مقادیر صفر و گاهی منفی شاخص عنوان کرد. در حالی که در پژوهش حاضر مقادیر مثبت پوشش گیاهی در نقش کاهنده شکل‌گیری پهنه‌های سیالابی

۱۵-۲۶ متر رخ داده است و آب حالت راکد و مانداب به خود گرفته است. با افزایش ارتفاع جریان آب بیشتر و شرایط مانداب و رکود آب و تشکیل پهنه‌های سیلابی مشاهده نشده است. شرایط تشکیل پهنه‌های سیلاب در ارتفاع ۱۶ متر و قبلاً وجود داشته است و هر چه ارتفاع بیشتر می‌شود از خطر تشکیل پهنه‌های سیلابی در منطقه مورد مطالعه کاسته می‌شود به طوری که در ارتفاع بالاتر از ۲۶ متر تشکیل پهنه‌های سیلابی بهشتد کاسته شده و به حالت ثابتی رسیده است. دلیل این اتفاق می‌تواند دشتی بودن منطقه و گستردگی شدن پهنه سیل در دشت باشد. در پژوهش Faramarzi et al. (2020) تأثیر ارتفاع با اهمیت نسبی ۳۸/۹ درصد بیشتر از سایر متغیرها با استفاده از روش درخت رگرسیون تقویت شده بر مخاطره سیل پارک ملی گلستان بیان و حدآستانه ارتفاعات کمتر از ۵۰۰ متر اعلام شده است. همچنین، ایشان تأثیر این عامل بر مخاطره سیل را با استفاده از روش آنتروپی بیشینه کمتر از ۰/۵ و با افزایش ارتفاع احتمال شکل‌گیری پهنه‌های سیلابی را کمتر دانسته‌اند. نتایج Ha et al. (2022) مبنی بر نقش ارتفاع در وقوع سیل هم‌خوانی دارد. به‌طوری که در نتایج ایشان نیز اعلام شد مؤثرترین عامل در وقوع سیل ارتفاع بوده است و بیشترین سیل‌ها در مناطق با ارتفاع کم و با تراکم رودخانه به وجود آمده است. با این حال با نتایج Avand et al. (2020b) مطابقت ندارد چرا که افزایش ارتفاع در نتایج ایشان باعث افزایش سیلابی شدن و در پژوهش حاضر کاهش سیلابی شدن را نشان داده است و دلیل آن موقیت کوهستانی و دشتی بودن مناطق مورد مطالعه بوده است. در پژوهش‌های دیگر از جمله Dodangeh et al. (2020) و Wang et al. (2020) نشان می‌دهند که ارتفاع یک مکان نقش حیاتی در تعیین شدت سیل و شناسایی مکان‌های مستعد سیل دارد. ارتفاع بدليل اهمیت آن در وقوع سیل به عنوان یک عامل شرطی‌سازی انتخاب می‌شود؛ زیرا پژوهش‌های قبلی نشان می‌دهد که مکان‌هایی با افزایش ارتفاع بالا رواناب را افزایش می‌دهند، در حالی که مناطق مسطح بدليل دبی بالای آب بیشتر مستعد سیل هستند (Ighile et al., 2022).

بررسی نقش کاربری اراضی و شکل ۳-ز بهترتبیب شامل آب پایه، باتلاق، کلوت، مرداب، شورهزار، کفه‌های رسی، رخمنون‌ها، اراضی بدون پوشش و لخت، شنزار، اراضی کشاورزی، اراضی مرتعی و مناطق شهری بوده است که بر وقوع سیل در منطقه مورد مطالعه نشان داد بیشترین پهنه‌های سیل در کلاس‌های دو، چهار، پنج، ۱۰ و ۱۲ که بهترتبیب شامل تالاب، باتلاق، اراضی نمکی، کشاورزی و زمین‌های شهری بوده است. تحلیل نتایج نشان می‌دهد در مناطق تالاب و باتلاقی به علت بالا بودن رطوبت و سطح آب خطر سیلابی شدن افزایش

است. در مطالعه حاضر بارش ۱۵ تا ۱۶ میلی‌متر بیشترین نقص را در شکل‌گیری پهنه‌های سیلاب داشته است و مقادیر بیش از ۱۶ میلی‌متر اثر چندانی بر وقوع سیلاب نداشته و نیز مقادیر کمتر از ۱۵ میلی‌متر نیز باعث وقوع سیلاب نشده است. در مطالعه Faramarzi et al. (2020) میزان بارش ۲۵۰ میلی‌متر حد آستانه بیشترین احتمال شکل‌گیری پهنه‌های سیلابی اعلام شده است و اهمیت نسبی این متغیر در مقایسه با بقیه متغیرهای تأثیرگذار بر سیلاب، کسب رتبه سوم با مقدار ۱۳/۳ درصد بوده است. در پژوهش حاضر بارش تجمعی در رتبه دوم متغیرهای اثرگذار بر شکل‌گیری پهنه‌های سیلاب قرار دارد. همچنین، Chakrabortty et al. (2022) در پهنه‌بندی خطر سیل در حوضه رودخانه Kangsabati هند مقدار بارندگی را به عنوان سومین عامل مهم و مؤثر در بروز سیلابی شدن معرفی کرده‌اند. بررسی شکل ۳-ج در خصوص شاخص کمبود رطوبت خاک (کمبود آب در خاک) نشان می‌دهد آستانه سیلابی شدن بر اساس این شاخص مقدار ۱۴۴ میلی‌متر بوده است. به عبارتی تا زمانی که کمبود رطوبت پروفیل خاک بیش از ۱۴۴-۱۵۲ باشد بارش ورودی باید کمبود رطوبت خاک را جبران کند و در نتیجه از رخداد سیل جلوگیری خواهد کرد. به عبارتی هر چه این مقدار بیشتر باشد از وقوع سیلاب کاسته خواهد شد و این کاسته شدن تا مقدار ۱۵۲ میلی‌متر در پروفیل خاک مؤثر است و بعد از آن تأثیر چندانی نخواهد شد. نقطه عطف در این نمودار مقدار ۱۵۰ میلی‌متر بوده است. همچنین، نتایج شکل ۳-ه که نشان‌دهنده مقدار رطوبت سطحی خاک است نیز حاکی از آن است که رطوبت کمتر از ۱۱ خطری برای سیلابی شدن ندارد اما مقدار بیش از آن باعث سیل‌گیر شدن اراضی خواهد شد. در مقدار ۱۱ میلی‌متر نمودار جهش یکباره داشته و با افزایش مقادیر رطوبت سطحی خاک به رشد صعودی خود تا مقدار ۱۴ میلی‌متر ادامه داده است. لذا، ۱۱ تا ۱۴ میلی‌متر به عنوان آستانه‌های تأثیرگذار بر وقوع سیلاب در این مطالعه در خصوص رطوبت سطحی خاک شناخته شده است. به عبارتی وجود رطوبت در سطح خاک و یا در عمق خاک خود عاملی است که باعث تبدیل بارش ورودی به سیل و یا نفوذ به لایه‌های عمقی خاک خواهد شد. هر چه رطوبت خاک بیشتر باشد لایه‌های خاک زودتر اشباع شده و در نتیجه بارش ورودی زمانی برای نفوذ کردن نخواهد داشت و به صورت سیل در سطح زمین جاری خواهد شد. نتایج پژوهش حاضر با یافته‌های Ahlmer et al. (2018) در خصوص نقش رطوبت خاک در وقوع سیل مطابقت دارد. آن‌ها در پژوهش خود بیان کرده‌اند که استفاده از داده‌های ماهواره‌ای رطوبت خاک در بهبود قابلیت اطمینان سیل مؤثر است.

در خصوص نقش ارتفاع در بروز سیل شکل ۳-د نشان می‌دهد بیشتر پهنه‌های سیلابی (مانداب) در شرایط ارتفاعی

بيان گر زمان آغاز تا پایان خشکسالی یا زمان تداوم، و واژه غیرطبیعی به انحراف یا نوسان منفی نسبت به شرایط میانگین طبیعی دلالت دارد (Shahbazi et al., 2014). علت استفاده از شاخص شدت خشکسالی پالمر آن است که این شاخص از دیرزمان تاکنون استفاده و در مناطق زیادی آزمون شده و مورد تأیید قرار گرفته است. این شاخص بر اساس ویژگی‌های اقلیمی دما و بارش و خصوصیات خاک، استاندارد شده و مقایسه آن در اقلیم‌های مختلف کرده زمین امکان‌پذیر است (Shahbazi et al., 2014). پژوهش‌گران دیگر از جمله Mo and Chelliah (2006) از شاخص‌هایی مانند SPI یا TWI که بر مبنای بارش است استفاده کردند. شاخص PDSI نیز با استفاده از داده‌های دما و بارندگی ماهانه و به کمک یک معادله ساده بیلان آب خاک دو لایه و تعریف معیاری به نام بارندگی مناسب برای اقلیم منطقه یا ترازیندی آب در خاک کار می‌کند. لذا، تناسب بیشتری چهت تحلیل پهنه‌های سیل‌گیر در محدوده مطالعه دارد. همچنین، Shafizadeh-Moghadam et al. (2018) بر کاربرد شاخص توزیع مکانی وضعیت رطوبت در تعیین رفتار آن بر احتمال وقوع سیلاب تأکید دارند. ایشان از شاخص SPI و TWI استفاده کردند و بیان داشتند که مقادیر کم شاخص SPI بر احتمال وقوع با احتمال بالای سیل مؤثر است و هر چه مقدار SPI به صفر نزدیک باشد احتمال وقوع سیلاب بیشتر خواهد بود. بر عکس شاخص SPI شاخص TWI است که هر چه مقادیر آن بیشتر باشد احتمال وقوع سیلاب بیشتر خواهد بود. در مطالعه حاضر نیز شاخص خشکسالی PDSI رفتاری شبیه به شاخص TWI از خود نشان داده است و هر چه قدر مقادیر این شاخص بیشتر باشد شکل‌گیری پهنه‌های سیلابی بیشتر خواهد بود. (Ighile et al. 2022) از SPI شاخص را در رتبه چهارم در خصوص اهمیت نسبی متغیرها در وقوع سیلاب در کشور نیجريه اعلام کردند.

#### ۴- نتیجه‌گیری

مطالعه و شناسایی نواحی مستعد سیلاب و ارائه راهکارهای مؤثر مبتنی بر متغیرهای تأثیرگذار بر وقوع آن بهمنظور مدیریت سیلاب یکی از اقدامات اساسی در کاهش خسارات ناشی از سیلاب است. با توسعه سنجش از دور و دسترسی به پایگاه‌های اطلاعات مکانی برخط مانند سامانه گوگل ارت انجین (GEE) علاوه‌بر دسترسی به حجم قابل توجهی از داده‌های بهنگام و وسیع، می‌توان از آن‌ها در تکنیک‌های نوبنی همچون یادگیری‌های ماشین استفاده و با استفاده از سیستم اطلاعات جغرافیایی امر بررسی و پایش مخاطرات طبیعی مانند سیلاب را به طور دقیق و کاوی نمود. تهیه نقشه پهنه‌بندی سیلاب و تحلیل متغیرهای مؤثر بر وقوع آن با استفاده از سیستم اطلاعات جغرافیایی و تکنیک‌های یادگیری

خواهد داشت. همچنین، در اراضی شور بالا بودن میزان املاح تأثیرگذار خواهد بود. در پژوهشی، Ighile et al. (2022) نسبی متغیر کاربری اراضی در خصوص وقوع سیلاب در کشور نیجریه را در رتبه سوم ارزیابی کردند و میزان اهمیت نسبی آن را ۱۲ درصد برآورد کردند. آن‌ها چهت برآورد شاخص اهمیت نسبی از روش شبکه عصبی مصنوعی و اوزان ناشی از نورون‌ها استفاده کردند. همچنین، متغیر نوع بافت خاک را بین پنج تا ۱۰ درصد اهمیت نسبی طبقه‌بندی کردند و آن را در رتبه ششم اهمیت نسبی با توجه به بقیه متغیرها در شکل‌گیری سیلاب در محدوده مورد مطالعه دانستند. در پژوهش حاضر نوع کاربری اراضی جزء متغیرهای تأثیرگذار و در رتبه پنجم قرار دارد و نوع بافت خاک جزء متغیرهای کم تأثیر و در آخرین رتبه تأثیرگذاری با توجه به شاخص اهمیت نسبی قرار گرفته است و از این حیث با مطالعه (Ighile et al. 2022) مطالعه (Shafizadeh-Moghadam et al. 2018) کاربری اراضی در وقوع سیلاب نشان داد بیشترین احتمال در رخداد سیل روی اراضی با پیر حوزه آبخیز هزار استان مازندران رخ داده است و در پژوهش حاضر نیز کاربری‌های اراضی مستعد تشکیل پهنه‌های سیل‌گیر (با خط‌ریسک بالا) شامل سوره‌زارها و باتلاق‌ها بوده است. از طرفی، اراضی کشاورزی نیز به سبب شخم و به هم خوردگی خاک می‌تواند در افزایش رواناب سطحی و به وجود آمدن سیل نقش داشته باشد. در اراضی شهری نیز سطح اراضی آسفالت و مناطق غیرقابل نفوذ در جاری شدن سیل مؤثر هستند. در محدوده مورد مطالعه پژوهش حاضر بیشترین سطح در خصوص کاربری‌های اراضی متعلق به کاربری‌های کشاورزی، باتلاق‌ها و سوره‌زارها بوده است و نتایج پژوهش حاضر با نتایج Khalidi et al. (2023) مبنی بر تأثیر کاربری اراضی بر وقوع سیل بر حسب نوع کاربری‌های اراضی محتمل وقوع پهنه‌های سیلابی هم خوانی دارد. همچنین، Faramarzi et al. (2020) نقش کاربری‌های اراضی را بر احتمال مخاطره سیلاب معادل ۱/۱ درصد دانسته و نقشی بیش از رتبه هشتم تأثیرگذاری بر شکل‌گیری پهنه‌های سیلابی برای آن متغیر متصور نیستند.

در رابطه با شکل ۳-و شاخص شدت خشکسالی پالمر، مناطقی از محدوده مورد مطالعه که شدت خشکسالی پالمر در این مناطق حکایت از ترسالی متوسط یا ترسالی خفیف می‌کند، پهنه‌های مستعد سیل‌گیر هستند و به عبارتی پهنه‌های سیل‌گیر روی مناطقی با این شدت از خشکسالی پالمر رخ داده است. در این راستا مقادیر PDSI بین دو تا سه و نیز مقادیر PDSI بین یک تا دو به ترتیب نشان از ترسالی متوسط و ترسالی خفیف دارند. قابل ذکر است؛ در تعریف شدت خشکسالی پالمر منظور، کمبود رطوبت مستمر و غیرطبیعی بوده است. در تعریف مذکور، واژه مستمر،

حساس به سیل با تکیه بر حدود مؤثر متغیرها در منطقه مورد مطالعه در دستور کار مدیران مربوطه قرار گیرد.

### تضاد منافع نویسندها

نویسندها این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافعی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

### سپاسگزاری

بدین‌وسیله از پژوهشکده هرمز دانشگاه هرمزگان در راستای تحقق اهداف پژوهشی این نوشتار تقدير می‌شود.

### دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

### مشارکت نویسندها

**محمد کاظمی:** مفهوم‌سازی، توسعه نرم‌افزار، انجام تحلیل‌های نرم‌افزاری و تفسیر داده‌ها، ویرایش و بازبینی مقاله، کنترل نتایج؛  
**عاطفه جعفرپور:** مفهوم‌سازی، تفسیر داده‌ها، نگارش نسخه اولیه مقاله.

### منابع

- آوند، محمدتقی، مرادی، حمیدرضا، و رمضان‌زاده لسیوئی، مهدی (۱۳۹۹). تهیه نقشه سیل با استفاده از دو مدل یادگیری ماشین جنگل تصادفی و مدل خطی تعمیم‌یافته بیزین. *محیط زیست و مهندسی آب*, ۶(۱)، ۸۳-۹۵. doi: 10.22034/jewe.2020.220593.1351
- تاجبخش‌فخرآبادی، سیدمحمد، و چزگی، جواد (۱۴۰۱). اولویت‌بندی سیل‌خیزی زیرهوزه‌های آبخیز شمال دشت بیرجند با استفاده از عوامل مورفومتری و مدل ویکور. *مدل‌سازی و مدیریت آب و خاک*, ۳(۳)، ۲۴۰-۲۵۵. doi: 10.22098/mmws.2022.11855.1179
- سلیمانی، کریم، و درویشی، شادمان (۱۳۹۹)، پهنه‌بندی و خطر پایش سیل بهار ۱۳۹۸ خوزستان با استفاده از داده‌های لنdest ۸ اکوهیدرولوژی، ۷(۳)، ۶۴۷-۶۶۲. doi: IJE.2020.302703.1333
- شهبازی، سمیرا، بذرافشان، جواد، ایران‌نژاد، پروین، و سهرابی، تیمور (۱۳۹۴). واسنجی شاخص شدت خشکسالی پالمر تحت شرایط اقلیمی خشک و نیمه‌خشک مناطق غرب و جنوب غرب ایران. *پژوهش‌های حفاظت آب و خاک*, ۵(۵)، ۲۳-۴۴. doi: 20.1001.1.23222069.1394.22.5.2.2
- صابری‌تسوان، مهران، گنجی‌نوروزی، زهرا، دلقدی، مهدی، نیک‌قلب عاشوری، سیعده، درستکار، وجیهه (۱۳۹۹). بررسی آنالیز حساسیت پارامترهای سیل نسبت به تغییرات زیری (مطالعه

ماشین)، یکی از اقدامات مؤثر جهت پایش و کاستن از خسارات سیلاب‌های آتی خواهد بود. نتایج مطالعه حاضر که با هدف پهنه‌بندی و شناسایی آستانه و حدود متغیرهای تأثیرگذار بر وقوع سیلاب سال ۱۳۹۸ در حوزه انتهایی کارون بزرگ بود. نتایج نشان داد، روش TreeNet با ضریب تبیین ۷۲/۸ درصد در مقایسه با نقاط کنترل زمینی عملکرد نسبتاً مناسبی در خصوص پهنه‌بندی سیلاب انجام داده است. هم‌چنین، ارزیابی عملکرد مدل نیز با شاخص‌های dift، ROC، حساسیت، ویژگی و ارزیابی کلی با مقادیر ۶/۸۸، ۰/۹۵، ۹۰/۴۳، ۹۱/۱۲، ۹۱/۲ سیار خوب ارزیابی شد. نتایج پهنه‌بندی سیلاب نشان داد، پهنه‌های سیلاب با خطر خیلی زیاد و زیاد بهترتبی ۴/۹۹ و ۳/۸۶ درصد و خیلی کم حدود ۸۳ درصد از سطح محدوده مورد مطالعه را به خود اختصاص داده‌اند. شایان ذکر است تعیین آستانه عوامل مؤثر در وقوع سیل برای ایجاد استراتژی‌های مدیریت سیلاب و برنامه‌ریزی کاربری پایدار زمین بسیار مهم است. از این‌رو پژوهش حاضر با استفاده از مدل‌های یادگیری ماشین آستانه و حدود متغیرهای مختلف بر وقوع پهنه‌های سیلاب را در محدوده انتهایی کارون بزرگ مورد بررسی قرار داد. نتایج نشان داد مؤلفه‌های شاخص پوشش گیاهی، بارش تجمعی، کمبود آب خاک، شاخص خشکسالی پالمر، ارتفاع و رطوبت سطحی خاک به ترتیب بیشترین تأثیر در تشکیل پهنه‌های سیل‌گیر منطقه مورد مطالعه داشته‌اند و در این بین حدود و آستانه تأثیرگذاری متغیرهای یاد شده بر بروز پهنه‌های سیلابی شناسایی شد. به نحوی که پوشش گیاهی صفر تا ۰/۱۸ میلی‌متر ( نقطه عطف ۰/۱)، بارش تجمعی ۱۵-۱۶ میلی‌متر ( نقطه عطف ۱۵/۵)، کمبود آب در خاک کمتر از ۱۴۴ میلی‌متر، رطوبت سطحی خاک ۱۱-۱۴ میلی‌متر، ارتفاع ۱۵-۲۶ متر از سطح دریا و کاربری‌های اراضی باطلی و شوره‌زارها بیشترین میزان تأثیر را بر وقوع پهنه‌های سیل‌گیر در محدوده مورد مطالعه داشتند.

قابل ذکر است در پژوهش حاضر از واستگی جزئی، یعنی واستگی تابع به چند متغیر مستقل به همراه مشتق‌های جزئی آن متغیرها استفاده شد. به عبارتی متغیر پهنه‌ندی با مشتق جزئی متغیرهای مستقل در معادلات پارشال لحاظ شده و تحت محور واستگی جزئی آمده است. معادلات دیفرانسیل پارشال دسته‌ای از معادلات دیفرانسیل است که توابع مجھول برحسب چند متغیر مستقل به همراه مشتق جزئی آن متغیرها در معادله است. هم‌چنین، علت استفاده از روش TreeNet این است که از آن به عنوان انعطاف‌پذیرترین و قدرتمندترین ابزار یادگیری ماشین که قادر به تولید مدل‌های بسیار دقیق است یاد می‌شود. این ابزار به مقاومت در برابر یادگیرنده بیش از ظرفیت نیز مشهور است. نتایج پژوهش حاضر می‌تواند در شناسایی حدود تأثیرگذاری متغیرهای مختلف بر بروز سیل و مدیریت مناطق

- doi: ۱۰.۶۸-۱۰.۵۵ گلستان، اکوهیدرولوژی، ۴(۶)، ۱۰.۲۲۰۵۹/ije.۲۰۱۹.۲۸۵۴۳۰.۱۱۶۳
- کاظمی‌قهی، حسن، منصوری، بنی‌الله، و جوزی، سیدعلی (۱۴۰۰). پهنه‌بندی خطر سیلاب در شهر نوشهر با استفاده از مدل‌های یادگیری ماشین. *مسکن و محیط رومتا*، ۴۰(۷۶)، ۷۱-۸۶. doi: 10.22034/40.176.71
- کاویانپور، امیرحسین، اسماعلی، اباز، جعفریان، زینب، و کاویان، عط الله (۱۳۹۴). اثر پوشش گیاهی بر کاهش رواناب و هدرفت خاک با استفاده از شبیه‌ساز باران در مراتع نشو استان مازندران. *جغرافیا و برنامه‌بری محیطی*، ۲۶(۲)، ۱۷۹-۱۹۰. doi: 10.1001.1.20085362.1394.26.2.12.3
- یوسفی، حین، یونسی، حجت‌الله، داوی مقدم، داد، ارشیا، آزاده، و شمسی، زهرا (۱۴۰۱). تعیین پتانسیل سیل با استفاده از مدل‌های یادگیری ماشین CART، GLM و GAM (مطالعه موردی: حوضه کشکان). *مهندسی آبیاری و آب/یران*، ۱۲(۴۸)، ۸۴-۱۰۵. doi: 10.22125/iwe.2022.15068.
- موردی: منطقه شیروان). مهندسی آبیاری و آب/یران، ۱۰(۴)، ۱۵۷-۱۸۰. doi: 10.22125/IWE.2020.110081
- صیاد، دانیال، قضاوی، رضا، و امیدوار، ابراهیم (۱۴۰۱). ارائه استراتژی‌های مناسب مدیریتی زیرساخت‌های شهری در برابر سیلاب از منظر پدافند غیرعامل با استفاده از SWOT و QSPM (مطالعه موردی: شهر کاشان). *مدل‌سازی و مدیریت آب و خاک*، ۱۲(۱)، ۴۲-۵۲. doi: 10.22098/MMWS.2022.9651.1055
- عبدی، مصطفی، نهتانی، محمد، دهقانی، مرتضی، و هاک‌سفیدی، عباس (۱۴۰۲). تعیین تغییرات سیل خیزی ناشی از دوره‌های خشکسالی در حوزه آبخیز دهک استان خراسان جنوبی. *مدل‌سازی و مدیریت آب و خاک*، ۱۳(۱)، ۱۴۹-۱۶۴. doi: 10.22098/MMWS.2022.11296.1118
- فرامرزی، حسن، حسینی، سیدمحسن، پورقاسمی، حمیدرضا، و فرنقی، مهدی (۱۳۹۸). ارزیابی و پهنه‌بندی موقعیت سیلاب در پارک ملی

## References

- Abdi, M., Nohtani, M., Dehghani, M., & Khaksefid, A. (2023). Determining the changes in flood potential caused by drought periods in the Dehak watershed of south Khorasan province. *Water and Soil Management and Modeling*, 3(1), 149-164. doi:10.22098/MMWS.2022.11296.1118. [In Persian]
- Ahlmer, A.K., Cavalli, M., Hansson, K., Koutsouris, A.J., Crema, S., & Kalantari, Z. (2018). Soil moisture remote-sensing applications for identification of flood-prone areas along transport infrastructure. *Environmental Earth Sciences*, 77, 1-17. doi:10.1007/s12665-018-7704-z
- Al-Areeq, A.M., Abba, S.I., Yassin, M.A., Benaafi, M., Ghaleb, M., & Aljundi, I.H. (2022). Computational machine learning approach for flood susceptibility assessment integrated with remote sensing and GIS techniques from Jeddah, Saudi Arabia. *Remote Sensing*, 14(21), 5515. doi:10.3390/rs14215515
- Avand, M., Janizadeh, S., Bui, D.T., Pham, V.H., Ngo, T.T., & Nhu, V. (2020a). A tree-based intelligence ensemble approach for spatial prediction of potential groundwater. *International Journal Digital Earth*, 13(12), 1-22. doi:10.1080/17538947.2020.1718785
- Avand, M.T., Moradi, H.R., Ramazanzadeh, M. (2020b). Flood susceptibility mapping using random forest machine learning and generalized bayesian linear model. *Environment and Water Engineering*, 6(1), 83-95. doi:10.22034/jewe.2020.220593.1351. [In Persian]
- Chakrabortty, R., Chandra Pal, S., Rezaie, F., Arabameri, A., Lee, S., Roy, P., Saha, A., Chowdhuri, I., & Moayedi, H. (2022). Flash-flood hazard susceptibility mapping in Kangabati River Basin, India. *Geocarto International*, 37(23), 6713-6735. doi:10.1080/10106049.2021.1953618
- Congalton, R.G. & Green, K. (2008). Assessing the accuracy of remotely sensed data: principles and practices. CRC Press. 364 p. doi:10.1201/9780429052729
- Dodangeh, E., Choubin, B., Eigdir, A.N., Nabipour, N., Panahi, M., Shamshirband, S., & Mosavi, A. (2020). Integrated machine learning methods with resampling algorithms for flood susceptibility prediction. *Science of the Total Environment*, 705, 135983. doi:10.1016/j.scitotenv.2019.135983
- Elish, M.O. (2009). Improved estimation of software project effort using multiple additive regression trees. *Expert Systems with Applications*, 36(7), 10774-10778. doi:10.1016/j.eswa.2009.02.013
- Faramarzi, H., Hosseini, S.M., Pourghasemi, H.R., & Farneghi, M. (2020). Flood reduction in urban basins using LID-BMPs in SWMM model and selecting the best option with AHP-TOPSIS (Case study: Golestan area in Semnan). *Ecohydrology*, 6(4), 1003-1013. doi:10.22059/ije.2019.285430.1163. [In Persian]
- Friedman, J.H. (2002). Stochastic gradient boosting. *Computational Statistics & Data Analysis*, 38(4), 367-378. doi:10.1016/S0167-9473(01)00065-2
- Friedman, J.H., & Meulman, J.J. (2003). Multiple additive regression trees with application in epidemiology. *Statistics in Medicine*, 22(9), 1365-1381. doi:10.1002/sim.1501
- Ha, M.C., Vu, P.L., Nguyen, H.D., Hoang, T.P., Dang, D.D., Dinh, T.B.H., Serban, G., Rus, I., & Brećan, P. (2022). Machine learning and remote sensing application for extreme climate evaluation: Example of flood susceptibility in the Hue Province, Central Vietnam

- region. *Water*, 14(10), 1617. doi:10.3390/w14101617
- Hong, J., Tamakloe, R., & Park, D. (2020). Application of association rules mining algorithm for hazardous materials transportation crashes on expressway. *Accident Analysis & Prevention*, 142, 105497. doi:10.1016/j.aap.2020.105497
- Ighile, E.H., Shirakawa, H., & Tanikawa, H. (2022). Application of GIS and machine learning to predict flood areas in Nigeria. *Sustainability*, 14(9), 5039. doi:10.3390/su14095039
- Iqbal, U., Riaz, M.Z.B., Zhao, J., Barthelemy, J., & Perez, P. (2023). Drones for flood monitoring, mapping and detection: a bibliometric review. *Drones*, 7(1), 32. doi:10.3390/drones7010032
- Kavianpour, A.H., Jafarian, Z., Ismali, A., & Kavian, A.A. (2014). Effect of vegetation covers on decreasing runoff and soil loss using rainfall simulation in Nesho rangeland, Mazandaran province. *Geography and Environmental Planning*, 26(2), 179-190. doi: 20.1001.1.20085362.1394.26.2.12.3. [In Persian]
- Kazemi, H., Mansouri, N., & Jozi, S.A. (2022). Flood risk zoning in Nowshahr city using machine learning models. *Journal of Housing and Rural Environment*, 40(176), 71-86. doi:10.22034/40.176.7. [In Persian]
- Khaldi, L., Elabed, A., & El Khanchoufi, A. (2023). Quantitative assessment of the relative impacts of different factors on flood susceptibility modelling: case study of Fez-Meknes region in Morocco. E3S Web of Conferences, 364(4), 02005. doi:10.1051/e3sconf/202336402005
- Khosravi, K., Nohani, E., Maroufinia, E., & Pourghasemi, H.R. (2016). A GIS-based flood susceptibility assessment and its mapping in Iran: a comparison between frequency ratio and weights-of-evidence bivariate statistical models with multi-criteria decision-making technique. *Natural Hazards*, 83(2), 947-987. doi:10.1007/s11069-016-2357-2
- Kia, M.B., Pirasteh, S., Pradhan, B., Mahmud, A.R., Sulaiman, W.N.A., Moradi, A., Nor, W., Sulaiman, A., & Moradi, A. (2012). An artificial neural network model for flood simulation using GIS: Johor River Basin, Malaysia. *Environmental Earth Sciences*, 67, 251-264. doi:10.1007/s12665-011-1504-z
- Mo, K.C., & Chelliah, M. (2006). The modified Palmer drought severity index based on the NCEP North American Regional Reanalysis. *Journal of Applied Meteorology and Climatology*, 45(10), 1362-1375. doi:10.1175/JAM2402.1
- Monteiro, D.S., & Antonio, J.F. (2002). Multiple additive regression trees a methodology for predictive data mining for fraud detection.
- Naval Postgraduate School Monterey Ca.93PP
- Mosavi, A., Ozturk, P., & Chau, K.W. (2018). Flood prediction using machine learning models: Literature review. *Water*, 10(11), 1536. doi:10.3390/w10111536
- Pierdicca, N., Pulvirenti, L., Chini, M., Guerriero, L., & Ferrazzoli, P. (2010). A fuzzy-logic-based approach for flood detection from Cosmo-SkyMed data. In 2010 IEEE International Geoscience and Remote Sensing Symposium, Pp. 4796-4798. doi:10.1109/IGARSS.2010.5650903
- Reis, A.A., Carvalho, M.C., de Mello, J.M., Gomide, L.R., Ferraz Filho, A.C., & Acerbi Junior, F.W. (2018). Spatial prediction of basal area and volume in Eucalyptus stands using Landsat TM data: an assessment of prediction methods. *New Zealand Journal of Forestry Science*, 48(1), 1-17. doi:10.1186/s40490-017-0108-0
- Saberi Tanasvan, M., Ganji Noroozi, Z., Delghandi, M., Dorostkar, V. (2020). Sensitivity analysis of flood parameters to roughness variation. *Journal of Irrigation and Water Engineering*, 10(4), 167-180. doi: 10.22125/TWE.2020.110081. [In Persian]
- Sayyad, D., Ghazavi, R., & Omidvar, E., (2022). Appropriate urban infrastructure management strategies against floods from the perspective of passive defense using SWOT and QSPM (Case study: Kashan City). *Water and Soil Management and Modeling*, 2(1), 45-52. doi:10.22098/MMWS.2022.9651.1055. [In Persian].
- Shafizadeh-Moghadam, H., Valavi, R., Shahabi, H., Chapi, K., & Shirzadi, A. (2018). Novel forecasting approaches using combination of machine learning and statistical models for flood susceptibility mapping. *Journal of Environmental Management*, 217, 1-11. doi:10.1016/j.jenvman.2018.03.089
- Shahbazi, S., Bazrafshan, J., Irannejad, P., & Sohrabi, T. (2014). Palmer drought severity index's calibration under the climatic conditions of arid and semiarid regions of the west and south west of Iran. *Journal of Water and Soil Conservation*, 22(5), 23-44. doi: 20.1001.1.23222069.1394.22.5.2.2. [In Persian]
- Solaimani, K., & Davishi, S. (2020). Zoning and monitoring of spring 2019 flood hazard in Khuzestan using landsat-8 data. *Ecohydrology*, 7(3), 647-662. doi: 10.22059/IJE.2020.302703.1333. [In Persian]
- Tajbakhsh Fakhrabadi, S.M., & Chezgi, J. (2022). Prioritization of flooding sub-basins in the north of the Birjand Plain using morphometric factors and VIKOR model. *Water and Soil Management and Modeling*, 3(3), 240-255. doi:10.22098/MMWS.2022.11855.1179. [In Persian]

- Wang, Y., Fang, Z., Hong, H., & Peng, L. (2020). Flood susceptibility mapping using convolutional neural network frameworks. *Journal of Hydrology*, 582, 124–482. doi:10.1016/j.jhydrol.2019.124482
- Were, K., Bui, D.T., Dick, Ø.B., & Singh, B.R. (2015). A comparative assessment of support vector regression, artificial neural networks, and random forests for predicting and mapping soil organic carbon stocks across an Afromontane landscape. *Ecological Indicators*, 52, 394-403. doi:10.1016/j.ecolind.2014.12.028
- Yousefi, H., Yonesi, H., Davoudimoghadam, D., Arshia, A., & Shamsi, Z. (2022). Determination of flood potential using CART, GLM and GAM machine learning models. *Journal of Irrigation and Water Engineering*. 12(4): 84-105. doi: 10.22125/IWE.2022.15068. [In Persian]