

Original Article



A New Forecasting Approach Using the Combination of Machine Learning to Predict Flood Susceptibility (Case Study: Karun Catchment)

Bahareh Gharedaghy^{1*} and Amir Ghasemzadeh²

Affiliation

1. MSC, Department of Environment, University of Environment, Karaj, Iran
2. Professor, Department of Environment, Islamic Azad University, Tabriz, Iran

ABSTRACT

Introduction: Due to its environmental diversity, Iran ranks high in terms of crises caused by natural disasters. Flooding, as one of these disasters, is causing severe social, economic, health, and environmental damage in many areas due to rapid urban growth and climate change. Therefore spatial forecasting of floods is crucial, as failure to identify flood risk areas in a catchment can exacerbate the destructive effects of floods. Recent advances in remote sensing, geographic information systems, machine learning, and statistical modelling have made it possible to produce highly accurate flood prediction maps. This study aims to predict flood risk areas in the Karun watershed using Sentinel satellite images and a novel ensemble approach with six machine learning models.

Materials and Methods: In this study, Synthetic Aperture Radar (SAR) data from Sentinel-1 images were used to identify areas affected by flooding. First, the dates of heavy rainfall and flooding events in the study area were identified from various sources of information. Subsequently, Sentinel-1 images were obtained from the Copernicus database, representing the area before and after the flood events. The aforementioned data were processed using the SNAP platform. The identification of flood-affected areas was achieved through the application of the thresholding technique. For this purpose, the Normalized Difference Water Index (NDWI) generated from Sentinel-2 images and land cover classes indicating permanent water bodies were employed to determine the threshold for identifying flood-affected areas. The flood polygon layer was converted to a point layer, resulting in a total of 70 flood occurrence points. A review of previous studies and local characteristics identified seven main factors that significantly affect flood occurrence in the region. These factors include the Normalized Difference Vegetation Index (NDVI), Topographic Wetness Index (TWI), slope, flow direction, flow accumulation, distance from the river, and monthly rainfall. Additionally, the Digital Elevation Model (DEM) of the region was obtained from the SRTM database, and the spatial resolution of all factors was aligned with the DEM layer. Subsequently, various machine learning algorithms were employed to develop a combined model that provides more accurate predictions of flood-prone areas. The individual models include the Generalized Linear Model (GLM), Boosted Regression Tree (BRT), Support Vector Machine (SVM), Random Forest (RF), Multivariate Adaptive Regression Splines (MARS), and Maximum Entropy (MAXENT).

Results and Discussion: The results of this study indicate that the northeast of Alijudarz city, parts of Durud and Azna in Lorestan province, Khademmirza, Shahrekhord, and Kiyar in Chaharmahal Bakhtiari province, Dana and Boyer Ahmad in Kohgiluyeh and Boyer Ahmad province, Semiroom city in Isfahan province, and the southern border areas of Karun River in Khuzestan province have the highest flood potential in this basin. The performance evaluation of the models revealed that the Random Forest (RF) and Maximum Entropy (MaxEnt) models exhibited the highest accuracy among the individual models. These models, by combining environmental information and flood occurrence data, can produce highly accurate flood susceptibility maps. These maps can serve as crucial management tools to mitigate the adverse effects of floods and prevent development in vulnerable areas.

Conclusion: Overall, this study demonstrates that the use of an ensemble approach which combines machine learning models can provide more reliable results in the prediction of flood risk areas. The findings of this research are beneficial for managers and planners, as they can prevent development in vulnerable areas and consequently help reduce financial losses and human damages in the future.

Keywords: Flood, Karun Watershed, Sentinel Satellite Images, Machine Learning Model, Ensemble Model

Citation: Gharedaghy, B. and Ghasemzadeh, A., A New Forecasting Approach Using the Combination of Machine Learning to Predict Flood Susceptibility (Case Study: Karun Catchment), *Iran J Remote Sens GIS*. 16(2):1-18.

* Corresponding Author: b.gharedaghy@gmail.com
DOI: <https://doi.org/10.48308/gisj.2022.102813>

Received: 2022.07.15
Accepted: 2022.10.09



Copyright: © 2024 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license <https://creativecommons.org/licenses/by/4.0/>.

رویکرد پیش‌بینی جدید با استفاده از ترکیب یادگیری ماشین برای پیش‌بینی مناطق حساس به وقوع سیل (مطالعه موردنی: حوضه آبریز کارون)

بهاره قره‌داغی^{۱*} و امیر قاسم‌زاده^۱

سمت

۱. کارشناس ارشد گروه محیط زیست، دانشگاه محیط زیست کرج، ایران
۲. استاد گروه محیط زیست، دانشگاه آزاد اسلامی تبریز، ایران

چکیده

سابقه و هدف: ایران به دلیل تنوع محیطی بالا، رتبه بالایی در بحران‌های ناشی از سوانح طبیعی دارد. با رشد سریع شهرها و تغییرات اقلیمی، سیل به عنوان یکی از این سوانح طبیعی خسارات اجتماعی-اقتصادی، بهداشتی و آسیب‌های محیط زیستی شدیدی را در بسیاری از مناطق به وجود آورده است. لذا، پیش‌بینی فضایی سیل بدقتی حیاتی است که عدم شناسایی مناطق مستعد سیل در یک حوضه آبریز ممکن است آثار مغرب آن را افزایش دهد. در سال‌های اخیر، با پیشرفت ابزارهای سنجش از دور، اطلاعات جغرافیایی، یادگیری ماشین و مدل‌های آماری، ایجاد نقشه‌های پیش‌بینی سیل با دقت بالا کاملاً امکان‌پذیر شده است. به همین منظور، در این پژوهش، با استفاده از تصاویر ماهواره Sentinel و استفاده از رویکرد نوین مدل همادی با شش مدل یادگیری ماشین به پیش‌بینی مکان‌های مستعد سیل در حوضه آبریز کارون پرداخته شد.

مواد و روش‌ها: در این پژوهش از رادار دیافراگم مصنوعی (SAR) به دست آمده از تصاویر Sentinel-1 برای شناسایی مناطقی که تحت تأثیر سیل قرار گرفته‌اند، استفاده شد. ابتدا تاریخ‌های بارندگی شدید و وقوع سیل در منطقه مورد مطالعه از منابع اطلاعاتی مختلف شناسایی شدند. سپس تصاویر Sentinel-1 مربوط به قبل و بعد از رویداد سیل از طریق پایگاه داده Copernicus تهیه شد. پردازش این داده‌ها با استفاده از پلتفرم SNAP انجام شد. شناسایی مناطق تحت تأثیر سیل با بهره‌گیری از روش حد آستانه صورت گرفت. برای این منظور از شاخص تفاوت نormal شده آب (NDWI) تولید شده از تصاویر-2 Sentinel و محققین مبیقات پوشش زمین که بدندهای آبی دائمی را نشان می‌دهند، استفاده شد تا آستانه‌ای که مناطق سیل زده را شناسایی می‌کند، تعیین شود. سپس لایه پلیگونی سیل به لایه نقطه‌ای تبدیل و در مجموع ۷۰ نقطه وقوع سیل ایجاد شد. با توجه به مرور مطالعات پیشین و وزیری‌های محلی، هفت عامل اصلی که به طور چشمگیری بر وقوع سیلاب در منطقه تأثیر دارند، شناسایی شدند. این عوامل شامل شاخص نormal شده تفاوت پوشش گیاهی (NDVI)، شاخص رطوبت توپوگرافی (TWI)، شبیب، جهت جریان، تجمع جریان، فاصله از رودخانه و بارندگی ماهانه هستند. مدل رقومی ارتفاع (DEM) منطقه نیز از پایگاه داده SRTM تهیه شده و تغییری همه عوامل با لایه DEM یکسان تنظیم شد. سپس، با استفاده از الگوریتم‌های مختلف یادگیری ماشین، مدلی ترکیبی توسعه داده شد که نتایج دقیق‌تری در پیش‌بینی مناطق مستعد سیل ارائه می‌دهد. مدل‌های منفرد شامل مدل خطی تعمیم‌یافته (GLM)، رگرسیون درختی پیشرفته (BRT)، مدل ماشین بردار پشتیبان (SVM)، مدل جنگل تصادفی (RF)، مدل رگرسیون سازشی چندمتغیره (MARS) و مدل پیشینه بی‌نظمه (MAXENT) هستند.

نتایج و بحث: نتایج این مطالعه نشان می‌دهد که شمال شرق شهرستان الیگودرز، بخش‌هایی از دورود و ازنا در استان لرستان، خادم‌میرزا، شهرکرد و کیار در استان چهارمحال بختیاری، دنا و بویراحمد در استان کهکلیویه و بویراحمد، شهرستان سمیرم در استان اصفهان، و مناطق جنوبی حاشیه رودخانه کارون در استان خوزستان پیشترین پتانسیل وقوع سیل را در این حوضه دارند. از پایی عملکرد مدل‌ها نشان می‌دهد که مدل‌های جنگل تصادفی (RF) و پیشینه بی‌نظمه (MaxEnt) بالاترین دقت را در بین مدل‌های منفرد داشته‌اند. این مدل‌ها با ترکیب اطلاعات محیطی و داده‌های وقوع سیل، قادر به ارائه نقشه‌های حساسیت به سیل با دقت بالا هستند. از این نقشه‌ها می‌توان به عنوان ابزار مدیریتی مهمی برای کاهش اثرات مخرب سیل و جلوگیری از توسعه مناطق آسیب‌پذیر استفاده کرد.

نتیجه‌گیری: به طور کلی، این پژوهش نشان می‌دهد که استفاده از رویکرد همادی با ترکیب مدل‌های یادگیری ماشین می‌تواند نتایج قابل اطمینان‌تری در پیش‌بینی مناطق مستعد سیل فراهم کند. نتایج این پژوهش برای مدیران و برنامه‌ریزان کارآمد است و می‌تواند از توسعه در مناطق آسیب‌پذیر جلوگیری کند و در نتیجه به کاهش زیان‌های اقتصادی و جانی در آینده کمک کند.

واژه‌های کلیدی: سیل، حوضه آبریز کارون، تصاویر ماهواره Sentinel، مدل یادگیری ماشین، مدل همادی

استناد: قره‌داغی، ب. و قاسم‌زاده، ا.
رویکرد پیش‌بینی جدید با استفاده از ترکیب یادگیری ماشین برای پیش‌بینی مناطق حساس به وقوع سیل (مطالعه موردنی: حوضه آبریز کارون)
نشریه سنجش از دور و GIS ایران، سال ۱۶، شماره ۲، تابستان ۱۴۰۳: ۱۸-۱.



آبریز ضروری است. امروزه به دلیل پیشرفت‌های سنجش از دور، سیستم‌های اطلاعات جغرافیایی (GIS)، یادگیری ماشین (ML) و مدل‌های آماری، ایجاد نقشه دقیق‌تر مناطق مستعد سیل کاملاً امکان‌پذیر است (Zhao et al., 2018). با این حال، موفقیت در تهیه این نقشه‌ها مستلزم درک کامل فرایند وقوع سیل، شناسایی عوامل مرتبط با سیل، آگاهی از چگونگی تأثیر هر عامل بر وقوع سیل، و انتخاب مدل مناسب و یا توسعه مدل‌های نوین است (Shafizadeh-Moghadam et al., 2018).

تاکنون برای پیش‌بینی مناطق مستعد سیل رویکردهای متعددی همچون نسبت فرکانس (FR; Cao et al., 2019)، رگرسیون لجستیک (LR, Tehrany et al., 2013; Ozdemir and Altural 2013)، درختان ANN، Park et al. 2014; GLM, Conforti et al. 2014 SVM, Chapi et al., 2017 رگرسیون تقویت‌شده (RF, Chen et al., 2020)، شبکه‌های عصبی مصنوعی (ANN, Zhao et al., 2018)، ارزیابی چندمعیاره مکانی^۱ (Hammami et al., 2019) در مقیاس‌های ملی و Zhao et al., 2018)، با وجود این هریک با محدودیت‌هایی روبرو بوده‌اند. علاوه بر این روش‌هایی وجود دارند که هر کدام نتایج متفاوتی نشان می‌دهند. به همین دلیل رویکرد ترکیب پیش‌بینی الگوریتم‌های مختلف یا پیش‌بینی Ensemble یکی از کارآمدترین روش‌ها در کاهش عدم قطعیت است که در این روش نتایج چند الگوریتم با هم ترکیب و نتیجه‌های دقیق‌تر از نتایج تک‌تک مدل‌ها حاصل می‌شود. در این رویکرد از نقاط قوت چندین مدل استفاده شده و در عین حال ضعف هریک از مدل‌ها به حداقل می‌رسد (Naimi and Araújo, 2016).

با توجه به اینکه مرکز کردن یک مطالعه فقط بر یک مدل، احتمال دستیابی به نتایج غیردقیق را

۱- مقدمه

سیل یکی از مخرب‌ترین بلایای طبیعی در سراسر جهان است (Kalantari et al., 2019) که می‌تواند پیامدهای اجتماعی- اقتصادی و زیست‌محیطی داشته باشد (Markantonis et al. 2013). در دهه اخیر، به نظر می‌رسد این بلای طبیعی به دلیل افزایش تخریب بوم‌سازگان‌های طبیعی مانند رشد جمعیت، جنگل‌زدایی، شهرنشینی و امثال آن، به‌طور مکرر رخداده (Wang et al., 2019). کنترل این بلای طبیعی و اقدامات پیشگیری از آن به‌دلیل خسارات بالقوه زیاد به منابع طبیعی، کشاورزی، حمل و نقل، پل‌ها و بسیاری از جبهه‌های دیگر زیرساخت‌های شهری، نیاز به فوریت Billa et al., 2006; Huang et al., 2008; Alvarado-Aguilar et al., 2012 مکانی این فاجعه محیطی و ایجاد نقشه‌های مکان‌های مستعد سیل یک امر اضطراری برای تعیین استراتژی‌های مدیریت در پیشگیری و کاهش سیل است (Kourgialas and Karatzas, 2011).

حوضه آبریز کارون یکی از مهم‌ترین منابع آبی واردشده به خلیج فارس و دریای عمان در کشور است (Abedi et al., 2020). میانگین بارندگی سالانه در حوضه آبریز کارون با توجه به تغییرات مکانی، از ۵۰ تا ۱۸۰۰ میلی‌متر متغیر بوده و رودخانه کارون منبع اصلی تأمین آب کشاورزی، صنعتی و آب اشامیدنی چندین شهر و روستا از جمله شهر اهواز است (Rastmanesh et al., 2020). به همین دلیل اهمیت این حوضه از نظر اقتصادی- اجتماعی و سابقه سیل زیان‌بار فروردین سال ۱۳۹۸، لزوم ایجاد استراتژی مدیریت و مهار سیلاب را در این منطقه بیشتر کرده است.

وقوع سیل تحت تأثیر عوامل متعددی از جمله کاربری زمین، فاصله تا رودخانه، پوشش گیاهی، نوع خاک، ارتفاع و شیب قرار دارد (به‌طور مثال Tehrany et al., 2015). به همین دلیل، درک و تعیین کمیت تأثیر هریک از این عوامل بر وقوع سیل در هر حوضه

1. spatial multicriteria evaluation

درجه عرض شمالی است. سرچشمۀ آب رودخانه کارون از مرتفع‌ترین قله زاگرس، یعنی زردکوه بختیاری با ارتفاع ۴۴۰۰ متر است (Abdi Dehkordi et al., 2020). حوضۀ آبریز کارون در محدوده استان‌های خوزستان، فارس، کهکیلویه و بویراحمد، لرستان، مرکزی، چهارمحال و بختیاری و اصفهان واقع شده است. در این میان، استان خوزستان و استان چهارمحال و بختیاری به ترتیب بیشترین سهم را در مساحت و تولید آب دارند. شکل ۱ نقشه حوضۀ آبریز کارون و منطقه مورد مطالعه در این پژوهش را نمایش می‌دهد.

۲-۲- نقاط وقوع

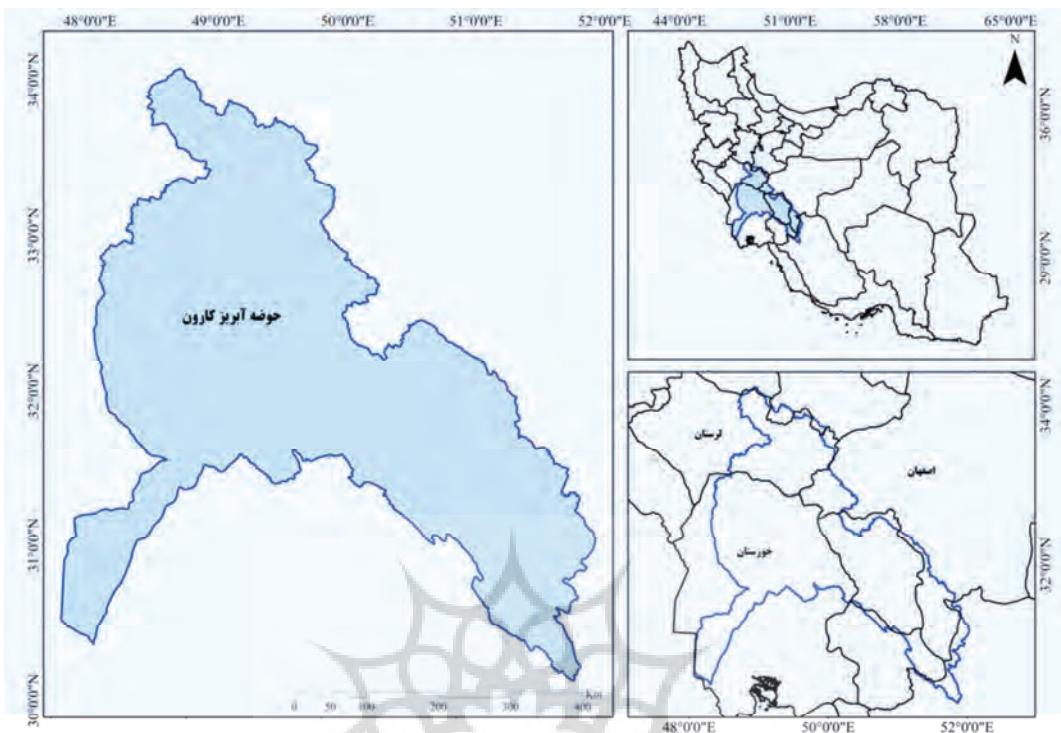
ماهواره Sentinel-1، اولین ماهواره از سری ماهواره‌های Sentinel است که توسط آژانس فضایی اروپا (ESA) در سال ۲۰۱۴ به فضا پرتاب شد. این ماهواره خورشید‌آهنگ بوده و شامل یک زوج سنجنده مدار قطبی (A, B) است که به صورت شباهه‌روزی به جمع‌آوری اطلاعات از سطح زمین می‌پردازد. تصاویر این ماهواره دارای قدرت تفکیک مکانی ۱۰ متر هستند. این سنجنده در محدوده باند C فعالیت می‌کند و دارای روزنۀ ترکیبی است (Kussul et al., 2011; Synthetic Aperture Radar (Aperture Radar Sentinel-1). ماهواره سطوح پردازش سه‌گانه (سطح صفر، یک و دو) است، سطح صفر داده‌های خامی هستند که مبنای پردازش‌های سطح بالاتر قرار می‌گیرند. داده‌های سطح یک به دو فرمت ارائه می‌شود: فرمت (Single Look Complex) SLC شامل داده‌های ژئورفرنس شده و تکمنظر در هندسه مایل است، فرمت داده‌های GRD (Ground Range Detected) SAR شامل داده‌های SAR با پردازش چندمنظري و تبدیل شده از هندسه مایل به هندسه زمینی با استفاده از یک مدل بیضوی از زمین است. در این نوع داده‌ها علاوه بر کاهش نویز لکه‌ای و توان تفکیک مکانی، اطلاعات فاز وجود نداشته و فقط حاوی اطلاعات دامنه هستند. داده‌های سطح دو شامل مؤلفه‌هایی برای مطالعه وزش باد و وضعیت امواج در سطح اقیانوس هستند (ESA, 2012).

Fechter and Storch, 2014; Amiri et al., 2021). بدین‌گاهی، عدم نظارت قانونی بر ساخت و سازهای فشرده اطراف رودخانه‌ها و تغییرات اقلیمی، سیلاب‌های متعددی در ایران رخ داده است. از این‌رو تهیۀ نقشه مناطق مستعد سیل به عنوان یک ابزار مدیریتی مناسب برای شناسایی مناطق سیل‌خیز برای جلوگیری از ساخت‌وساز در آن مناطق و حفاظت از منابع طبیعی ضروری است (Tehrany et al., 2013). بنابراین، براساس نگرانی‌های یادشده، هدف اصلی این مقاله: (الف) بررسی منحنی‌های پاسخ است که رفتار عوامل مختلف مؤثر بر وقوع سیل را نشان می‌دهد، (ب) بررسی عملکرد هشت مدل یادگیری ماشین و رگرسیون لجستیک، (ج) تحلیل و بحث در خصوص رویکرد همادی برای ترکیب نتایج مدل‌های فردی و ایجاد مدل‌های تعمیم‌پذیرتر و پایدارتر است. از آنجاکه مدل‌های یادگیری ماشینی براساس کمی کردن روابط بین دو گروه از داده‌ها شامل متغیرهای هدف و متغیرهای پیش‌بینی کننده کار می‌کنند، در این مطالعه داده‌های وقوع سیل براساس تصاویر ماهواره‌ای Sentinel-1 و متغیرهای پیش‌بینی کننده براساس مرور مطالعات پیشین تهیۀ شد.

۲- مواد و روش‌ها

۲-۱- منطقۀ مورد مطالعه

حوضۀ آبریز کارون از نظر زمین‌شناسی در پهنه زاگرس قرار دارد. این حوضه در بخش‌هایی از هر سه زیرپهنه زاگرس رانده، زاگرس چین خورده و دشت‌های زاگرس جاری است. این حوضه در داخل ارتفاعات زاگرس میانی واقع شده و محدود به مشخصات جغرافیایی $48^{\circ}-52^{\circ}$ درجه طول شرقی و $30^{\circ}-34^{\circ}$ و $0^{\circ}-5^{\circ}$ درجه عرض شمالی است.



شکل ۱. نقشه منطقه مورد مطالعه

و نقشه‌برداری سیل استفاده کرد، اما در پژوهش حاضر، قطبش خطی عمودی^۱، به دلیل میزان انرژی در دسترس بیشتر و توانایی بهتر برای تفکیک مناطق آبی و غیرآبی و ترسیم سیل استفاده شد (Clement et al., 2018).

^۲. پیش‌پردازش-کالیبره کردن و فیلتر کردن لکه‌های داده‌ها: هرچند تصاویر کالیبره‌نشده برای استفاده کیفی کافی‌اند، ولی برای استفاده کمی از داده‌های Sayedain et al., 2020. هدف از کالیبراسیون تصاویر Sentinel-1^۳ تبدیل ارزش پیکسل خام به مقدار بازپخش زمینی آن پیکسل است (Yokoya et al., 2016). همچنین تصاویر راداری با نوعی اختلال تحت عنوان نویز اسپکل مواجه‌اند که باعث ظاهر شدن دانه‌های ریز و درشت و تداخل سیگنال‌های بازتابیده می‌شود. در این پژوهش

1. Vertical Co-polarization

در این پژوهش از رادار دیافراگم مصنوعی (SAR) به دست آمده از تصاویر Sentinel-1 برای شناسایی مناطقی استفاده کردیم که تحت تأثیر سیل هستند. برای انجام این کار، ما تاریخ‌هایی را شناسایی کردیم که پس از بارندگی شدید (مثلثاً ۲۵ مارس ۲۰۱۹)، سیل در منطقه رخ داده است، و سپس تصاویر Sentinel-1 قبل و بعد از رویداد سیل تهیه شد. این فرایند در ۵ مرحله اجرا شد:

۱. دانلود داده‌های Sentinel-1: تصاویر ماهواره‌ای Sentinel-1 برای پردازش از طریق سنجش براساس تاریخ‌های وقوع بارش شدید و سیل در منطقه تنظیم شد.

۲. فرآخوانی تصاویر در پلتفرم SNAP^۴ برای پردازش داده‌های Sentinel-1 از پلتفرم SNAP استفاده شد، اگرچه هریک از باندها را می‌توان برای تجزیه و تحلیل

۶. تبدیل محدوده‌های سیل به نقاط وقوع: به دلیل اینکه برای استفاده از الگوریتم‌های یادگیری ماشین و رگرسیون به داده‌هایی از نوع نقطه‌ای نیاز است، در محیط QGIS، لایه چندشکلی سیل به لایه نقطه‌ای تبدیل شد و در مجموع ۷۰ نقطه وقوع سیل ایجاد شد.

۳-۱- داده‌های محیطی

با توجه به مور مطالعات پیشین، هفت عامل اصلی که به طور چشمگیری بر وقوع سیلاب در منطقه مورد مطالعه تأثیر داشت، شناسایی شدند. این پارامترها شامل شاخص نرمال‌شده تفاوت پوشش گیاهی (NDVI)، شاخص رطوبت توپوگرافی (TWI)، شیب، جهت جریان، تجمع جریان، فاصله از رودخانه و بارندگی ماهانه است. مدل رقومی ارتفاع (DEM)^۸ منطقه مورد مطالعه از پایگاه داده SRTM^۹ تهیه شد. از آنجاکه بیشتر فاکتورها از لایه DEM مشتق شده‌اند، تفکیک مکانی همه عوامل با لایه DEM در محیط QGIS یکسان تنظیم شد. با در نظر گرفتن DEM در عنوان ورودی، لایه‌های شیب، جهت جریان، تجمع جریان و فاصله از رودخانه با استفاده از الگوریتم D8 در Arc GIS Pro تهیه شد، یکی از مؤثرترین عوامل در وقوع سیل است (Chapi et al., 2017). نسبت بین مساحت حوضه خاص و شیب TWI نامیده می‌شود که به صورت زیر محاسبه می‌شود (Beven, 1979):

$$TWI = \ln(\alpha / \tan \beta) \quad (1)$$

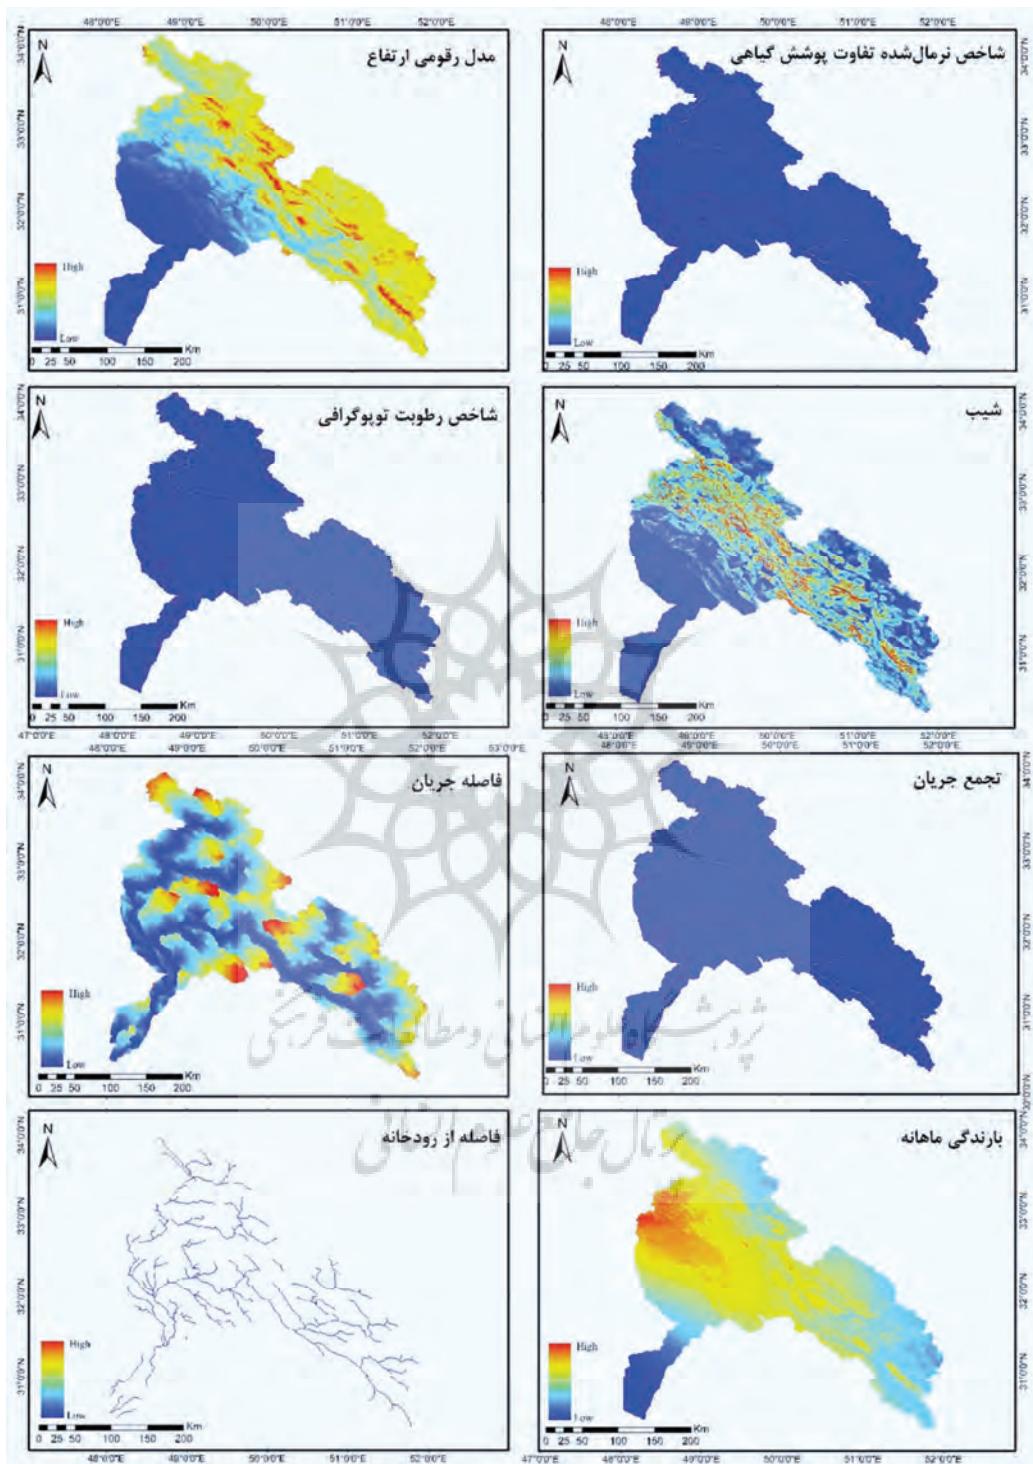
شاخص نرمال‌شده تفاوت پوشش گیاهی از طریق ماهواره Sentinel-2 تهیه شد. داده‌های بارندگی ماهانه نیز از طریق Worldclim 2.1 تهیه شد.

1. Image Texture
2. Visual Interpretation
3. Image Statistic-Based Active Contour Models
4. The Edge Detection Approach
5. Maximum Entropy Method
6. Minimum Interclass Variance Method
7. Backscatter
8. Digital Elevation Model
9. Shuttle Radar Topography Mission

برای نرم کردن داده لکه‌دار از فیلتر حذف لکه استفاده شد، فیلتر حذف لکه،وضوح و جزئیات تصویر را حفظ، ولی نویز لکه را از بین می‌برد و در نهایت پیکسل فیلترشده با ارزش محاسبه شده از پیکسل‌های اطراف، جایگزین می‌شود (Yommy et al., 2015). برای این منظور از ابزار کالیبراسیون و اسپکل فیلتر در پلتفرم SNAP استفاده شد.

۴. تعیین مناطق سیل‌زده: روش‌های متعددی برای استخراج پهنه‌های آب از تصاویر SAR وجود دارد، مانند تجزیه و تحلیل بافت تصویر^۱ (Caballero et al., 2020)، تفسیر بصری^۲ (Brivio et al., 2002)، حد آستانه هیستوگرام (Matgen et al., 2004)، مدل‌های منحنی میزان فعال آمار مبنای عکس^۳ (Horritt et al., 2001)، روش تشخیص لبه^۴ (Tayfehrostami et al., 2021)، روش اوتسو (Otsu et al., 1979)، روش حدآکثر آنتروپی^۵ (Kapur et al., 1985)، روش حداقل واریانس بین طبقه^۶ (Radhika et al., 2009) و حد آستانه (Schumann et al., 2009)، در این مطالعه شناسایی مناطق تحت تأثیر سیل با استفاده از روش حد آستانه انجام شد. برای انجام این کار، مقایسه‌ای از نحوه تغییر مقادیر شدت پس‌پراکنده‌گی^۷ در مناطق سیل‌زده در نظر گرفته شد. ما همچنین از یک شاخص تفاوت نرمال‌شده آب (NDWI)، تولیدشده با استفاده از تصاویر Sentinel-2^۸، و همچنین طبقات پوشش زمین که بدهنه‌های آبی دائمی را نشان می‌دهند، برای مقایسه تصاویر و شناسایی آستانه‌ای که مناطق سیل‌زده شناسایی می‌شوند، استفاده کردیم. با استفاده از آستانه ۲۱- دسی بل (Conde et al., 2019)، تصاویر باینریزه شدن و سپس با استفاده از روش مقایسه نقشه دودویی، مناطق سیل‌زده شناسایی شدند.

۵. پس‌پردازش - تصحیح هندسی داده‌ها: به دلیل اینکه تصویر پردازش شده فاقد سیستم مختصات جغرافیایی است و قابلیت نقشه‌سازی در محیط QGIS را ندارد، در پلتفرم SNAP برای تصویر، سیستم مختصات تعريف شد.



شکل ۲. پارامترهای محیطی مؤثر بر وقوع سیل

طبقه‌بندی کننده دودویی است، این مدل براساس نظریه یادگیری آماری بنا نهاده شده و یک روش آماری غیرپارامتریک ناظارت شده است (Cortes and Vapnik, 1995). SVM برای طبقه‌بندی تفکیک گروه‌ها به کار می‌رود. به عبارت دیگر، پس از مشخص شدن داده‌های ورودی مدل (متغیرهای مستقل) و داده‌های هدف (متغیر وابسته)، مدل ماشین بردار پشتیبان تجزیه و تحلیل بین متغیرهای مستقل و وابسته (کالیبراسیون) را آغاز کرده و داده‌ها را به گروه‌های متمایزی تقسیم می‌کند (Cortes and Vapnik, 1995).

مدل جنگل تصادفی: بریمن و همکاران در سال ۱۹۹۶ را توسعه دادند، این مدل براساس یک ترکیب از مجموعه‌ای از درخت‌های تصمیم است که هر درخت با انتخاب یک دستهٔ تصادفی از متغیرها و نمونه‌های تصادفی از مجموعه داده آموزشی آموزش داده می‌شود. در این روش تعداد زیادی درخت‌های تصمیم ساخته می‌شود که در نهایت از آن‌ها میانگین گرفته می‌شود (Breiman et al., 2001).

مدل رگرسیون سازشی چندمتغیره: مدل MARS، مانند مدل GAM است، با این تفاوت که از تابع خطی قطعی استفاده می‌کند (Leathwick et al., 2005). MARS از توابع معیار گام‌به گام خطی تشکیل شده است که استفاده آن برای پیش‌بینی مکانی بسیار ساده‌تر است. MARS تعامل بین متغیرها را نه در سطح تمام دامنه پیش‌بینی کننده‌ها، بلکه به صورت محلی و بین نواحی از هر

تابع معیار در نظر می‌گیرد (Franklin, 2010).

مدل بیشینه بی‌نظمی: MaxEnt روشی است که از سال ۲۰۰۴ در دسترس است، به طور گسترده برای مدل‌سازی وقوع پدیده‌ها استفاده شده است و عملکرد پیش‌بینی کننده آن معمولاً با روش‌های دارای بالاترین عملکرد قابل رقابت است (Elith et al., 2006). رابطه بین تأثیر عوامل محیطی را بر روی سوابق وقوع پدیده در مکان‌های خاص تخمین می‌زنند (Franklin, 2010). از همین رویکرد برای ارزیابی تأثیر عوامل محیطی بر وقوع سیل در این مطالعه استفاده شده است.

۴-۲- الگوریتم‌های رگرسیون و یادگیری ماشین

در این مطالعه مدل همادی (میانگین گیری وزنی) را با ترکیب شش الگوریتم یادگیری ماشین شامل مدل خطی تعمیم‌یافته (GLM; McCullagh and Nelder, 2019), رگرسیون درختی پیشرفته (BRT; Friedman, 2001), مدل ماشین بُردار پشتیبان (SVM; Gunn, 1998), مدل جنگل تصادفی (RF; Breiman, 2001), مدل رگرسیون سازشی چندمتغیره (MARS; Friedman, 1991), مدل بیشینه بی‌نظمی (MaxEnt; Phillips et al., 2006) در محیط برنامه‌نویسی R با بهره‌گیری از بستهٔ آماری sdm استفاده کردیم (Naimi and Araújo, 2016).

مدل خطی تعمیم‌یافته: GLM با تابع رگرسیون لجستیک به طور گسترده برای مدل‌سازی متغیرهای باینری یا داده‌های حضور و عدم حضور استفاده شده است. در این پژوهش، از یک رگرسیون لجستیک (LR) برای ارتباط نقاط وقوع سیل با پارامترهای محیطی استفاده شد. این مدل علاوه‌بر اینکه در هر سلول احتمال وقوع سیلاب را نشان می‌دهد، اهمیت هریک از متغیرهای محیطی را نیز مشخص می‌کند. ویژگی متمایز این مدل با سایر مدل‌ها خطی این است که تفسیر ضریب به دست آمده از GLM شبیه مدل‌های خطی معمول نیست، زیرا رابطه بین متغیرها براساس یک خط مستقیم نیست (James et al., 2013). این مدل به خوبی می‌تواند متغیرهای گسلسته و پیوسته را مدیریت کند.

رگرسیون درختی پیشرفته: یک روش Ensemble برای برازش مدل‌های آماری است که به طور اساسی با روش‌های معمول که قصد برازش یک مدل واحد صرفه‌جو را دارند، متفاوت است. BRT نقاط قوت دو الگوریتم Boosting و Regression Trees را با هم ترکیب می‌کند. مدل BRT یک مدل رگرسیون افزایشی به شمار می‌آید که در آن term‌های انفرادی، درختان ساده هستند، که در یک سبک رو به جلو و مرحله‌ای برازش داده می‌شوند (Elith et al., 2008).

مدل ماشین بُردار پشتیبان: SVM در واقع یک

۳-۳. پیش‌بینی وقوع سیل براساس مدل‌های منفرد

براساس مدل GLM پتانسیل وقوع سیل در شهرستان‌های دورود و ازنا در استان لرستان، بویراحمد، مارگون و دنا در استان کهگیلویه و بویراحمد، خادم‌میرزا در چهارمحال بختیاری و حاشیه جنوبی رودخانه کارون در استان خوزستان پیش‌بینی شده است. براساس مدل‌های RF و BRT بیشترین احتمال وقوع سیل در استان خوزستان (خرمشهر، کارون، شادگان و اهواز) و لکه‌هایی در سمیرم (استان اصفهان) و دورود (استان لرستان) پیش‌بینی شده است. براساس مدل SVM به‌جز شهرستان‌های شمالی استان خوزستان (کرخه، شوشتر، گتوند، مسجد سلیمان، دزفول، شوش، اندیمشک، لالی و اندیکا) مابقی مناطق دارای پتانسیل متوسط برای وقوع سیل هستند. براساس پیش‌بینی مدل MARS صرفاً حاشیه باریکی از رودخانه کارون به‌عنوان منطقه‌ای با احتمال وقوع سیل پیش‌بینی شده است. مدل MAXENT نیز شهرستان‌های درود و ازنا در استان لرستان، شهرکرد و دنا در استان چهارمحال بختیاری، سمیرم در استان اصفهان و بویراحمد و دنا در استان کهگیلویه و بویراحمد را به‌عنوان سیل خیزترین مناطق پیش‌بینی کرده است.

۳-۴- نتایج

۳-۱- ارزیابی عملکرد مدل‌ها

در این مطالعه، هشت مدل مجزا (GLM, BRT, RF, SVM, MARS, MaxEnt) برای سیل کالیبره و پیاده‌سازی شدند. بهترین عملکرد در بین شش مدل براساس AUC متعلق به مدل‌های RF و Maxent به‌ترتیب ۰.۹۲ و ۰.۹۳ و براساس TSS نیز برای RF به‌ترتیب ۰.۸ و ۰.۷۶ نشان داده شده است. دامنه مقادیر AUC بین صفر و ۱ قرار دارد که ۰.۵ نشان‌دهنده عدم تمایز بین مدل و پیش‌بینی کننده تصادفی است و عدد ۱ نشان‌دهنده بهترین عملکرد مدل است (Grenouillet et al., 2011). دامنه مقادیر TSS بین ۱-تا ۱+ است که هر چقدر به ۱+ نزدیک‌تر باشد، نشان‌دهنده عملکرد بالای مدل است. نتایج ارزیابی عملکرد مدل‌ها در جدول ۱ نمایش داده شده است.

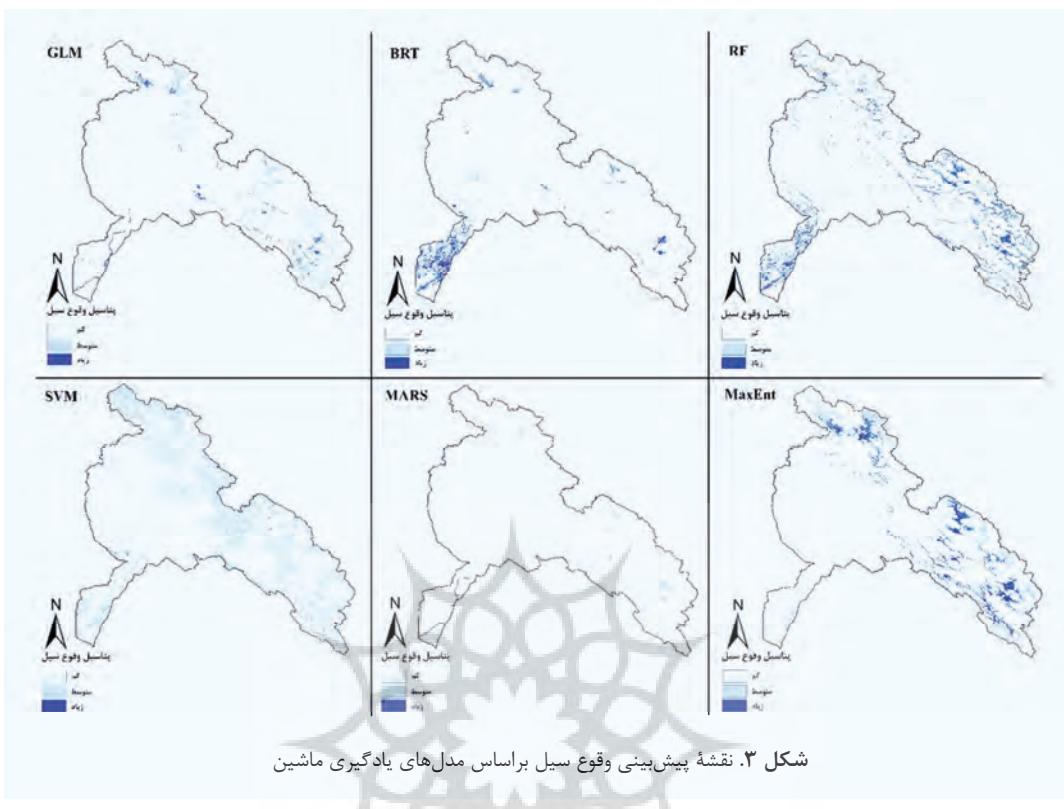
۳-۲- اهمیت متغیرهای محیطی برای پیش‌بینی مناطق مستعد سیل براساس مدل همادی
نتایج حاصل از مدل‌سازی وقوع سیل در منطقه مورد مطالعه نشان داد متغیر میزان بارندگی ماهانه و شاخص نرمال‌شده تفاوت پوشش گیاهی بیشترین تأثیر را در وقوع سیلاب در حوضه آبریز کارون دارد. جدول ۳ میزان اهمیت متغیرهای محیطی برای وقوع سیل را نشان می‌دهد.

جدول ۱. نتایج ارزیابی عملکرد مدل‌ها با استفاده از AUC و TSS

	GLM	BRT	RF	SVM	MARS	Maxent
AUC	۰.۹	۰.۹	۰.۹	۰.۹۱	۰.۸۰	۰.۹
TSS	۰.۷۳	۰.۷۲	۰.۸	۰.۷۴	۰.۷۳	۰.۷

جدول ۲. اهمیت متغیرهای محیطی برای پیش‌بینی مناطق مستعد سیل براساس مدل همادی

متغیر	درصد اهمیت متغیر
شاخص نرمال‌شده تفاوت پوشش گیاهی (NDVI)	%۱۶
شاخص رطوبت توپوگرافی (TWI)	%۹
شیب	%۱۰
جهت جریان	%۱۱
تجمع جریان	%۹
فاصله از رودخانه	%۱۸
بارندگی ماهانه	%۲۵



(Martínez-López et al., 2015; Thorup et al., 2021)

سیستم‌های مدل‌سازی به دلیل در دسترس بودن، تصمیم‌گیرندگان را قادر می‌سازد تا برنامه‌های زیستمحیطی کارآمد را ایجاد و اجرا کنند (Hill and Minsker, 2010). اما مدل‌های مختلفی به صورت جداگانه در مناطق مختلف استفاده شده است. مثلاً، تهرانی و همکاران (۲۰۱۵) به منظور تهیئة نقشهٔ پیش‌بینی وقوع سیل از مدل SVM در مالزی استفاده کردند، ناچاپا و همکاران (Nachappa, 2020) روش تحلیل تصمیم چندمعیاره و مدل‌های یادگیری ماشین را برای پیش‌بینی وقوع سیل در اتریش مقایسه کردند. روشن است که روش‌های متعدد و نتایج گوناگون سبب اختلال در مدیریت خطر سیل برای تصمیم‌گیران خواهد بود از این‌رو استفاده از یک مدل مناسب برتر ضروری به نظر می‌رسد (Araujo and New, 2007).

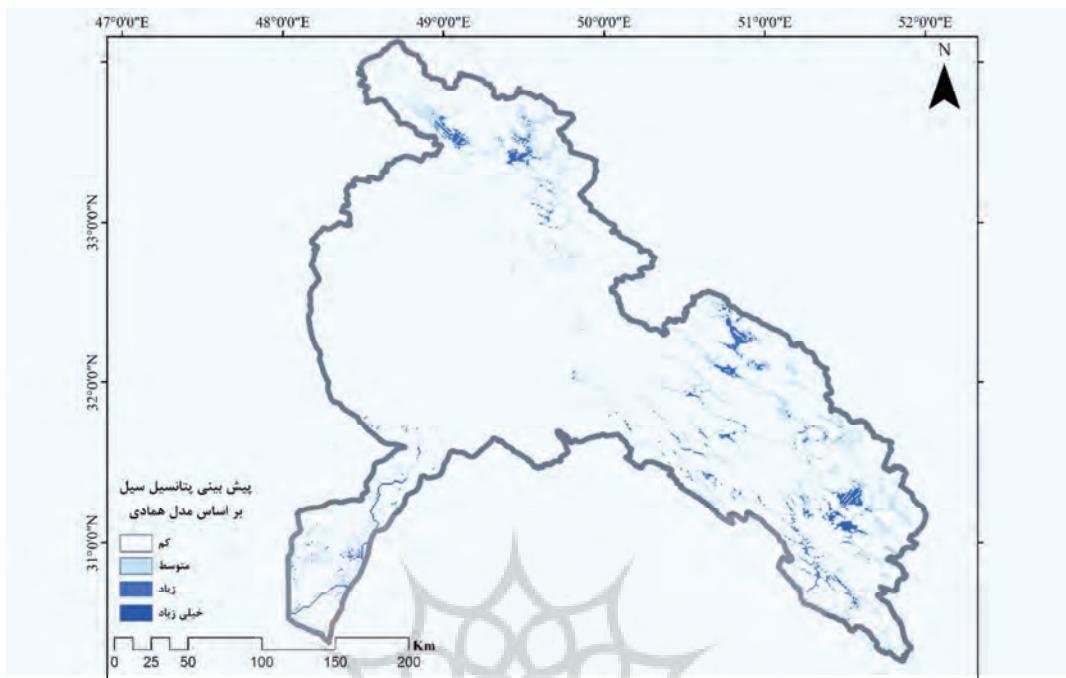
راه حل ممکن برای برآورد این تغییرات بین مدلی،

۴-۳- پیش‌بینی وقوع سیل براساس مدل همادی

براساس مدل همادی، شمال شرق شهرستان الیگودرز، بخش‌هایی از دورود و ازنا در استان لرستان، خادم‌میرزا، شهرکرد و کیار در استان چهارمحال پختیاری، دنا و بویراحمد در استان کهکیلویه و بویراحمد، شهرستان سمیرم در استان اصفهان و مناطق جنوبی حاشیه رودخانه کارون در استان خوزستان بیشترین پتانسیل وقوع سیل را نشان داده است (شکل ۴).

۴- بحث و نتیجه‌گیری

سیستم‌های مدل‌سازی ابزارهای با ارزشی برای پشتیبانی تصمیم برای گسترش دانش در زمینه مدیریت خطر سیل هستند (Abbaspour et al., 2011; Garcia et al., 2022)، با این حال، ساختار و ماهیت رویکردهای مدل‌سازی متفاوت است و به عملکرد و خروجی‌های بسیار متفاوتی منجر می‌شود



شکل ۴. نقشه پیش‌بینی وقوع سیل براساس مدل همادی

منطقه هستند که نتایج این پژوهش تاحدودی با یافته‌های چاپی و همکاران (Chapi et al., 2017) تطابق دارد. نتایج اعتبارسنجی این مطالعه نشان داد MAXENT و RF دقیق‌ترین مدل‌ها در بین شش مدل فردی به کاربرده شده هستند. RF از مهم‌ترین متغیرها یا نقاط تقسیم در زیرگروه‌های متغیر برای ایجاد درخت رشد است که به طور تصادفی از مجموعه‌ای از عوامل استفاده می‌کند و بنابراین اهمیت هر درخت رگرسیون فردی را کاهش می‌دهد. این امر نرخ تطابق و خطای مدل را کاهش می‌دهد (Breiman, 2001). این روش پایداری و دقت طبقه‌بندی را بهبود می‌بخشد، واریانس را کاهش می‌دهد و از برآذش بیش از حد جلوگیری می‌کند (Gayen et al., 2019; Shahabi et al., 2019). نتایج این مطالعه در خصوص مدل RF که یک مدل دقیق برای پیش‌بینی و تعیین پدیده‌های مختلف است، با نتایج مطالعات تالب و همکاران (Taalab et al. 2018)، آوند و همکاران (Avand, 2019)، حسین‌علیزاده و

استفاده از پیش‌بینی‌های همادی توسط شبیه‌سازی در کل یک مجموعه به جای استفاده از یک روش Thuiller, 2003; Araujo and New, 2007. به همین دلیل در این مطالعه از این رویکرد برای پیش‌بینی دقیق احتمال وقوع سیل در حوضه آبریز کارون استفاده شد.

به تازگی ابزارهای سنجش از دور تحولات بزرگی در مطالعات علوم محیطی فراهم آورده است (Cavender- Bares et al., 2022; Ebrahimi et al., 2023). رویکرد به کاربرده شده در این پژوهش برای برآورد مکانی مناطق وقوع سیل چارچوبی را برای آشکارسازی مناطق سیل‌زده با استفاده از داده‌های Sentinel فراهم می‌کند که راه حلی مقرر به صرفه برای پایش زمان واقعی رخداد سیل است.

رابطه میان هشت عامل مؤثر بر وقوع سیل و نقاط وقوع سیل در مطالعه حاضر نشان می‌دهد بارش ماهانه و فاصله از رودخانه از مؤثرترین عوامل در سیل خیزی

- Karun River Basin Landscape under the Utilization of Development Projects in Study or Implementation Based on the System Dynamics Approach. *Iranian Journal of Soil and Water Research.* 51 (2), 489-501. <https://doi.org/10.22059/ijswr.2019.284941.662825>
- Abedi, M., Moghadam, H., Morid, S., Booij, M., and Delavar, M., 2020, Evaluation of ECMWF mid-range ensemble forecasts of precipitation for the Karun River basin: Theoretical and Applied Climatology, 141, 61-70. <https://doi.org/10.1007/s00704-020-03160-0>
- Alvarado-Aguilar, D., Jiménez, J. A., & Nicholls, R. J. (2012). Flood hazard and damage assessment in the Ebro Delta (NW Mediterranean) to relative sea level rise. *Natural Hazards*, 62, 1301-1321. <https://doi.org/10.1007/s11069-012-0149-x>
- Amato, U., Antoniadis, A., De Feis, I., Goude, Y., & Lagache, A. (2021). Forecasting high resolution electricity demand data with additive models including smooth and jagged components. *International Journal of Forecasting*, 37(1), 171-185. <https://doi.org/10.1016/j.ijforecast.2020.04.001>
- Amiri, N., Vaissi, S., Aghamir, F., Saberi Pirooz, R., Rödder, D., Ebrahimi, E., & Ahmadzadeh, F. (2021). Tracking climate change in the spatial distribution pattern and the phylogeographic structure of Hyrcanian wood frog, *Rana pseudodalmatina* (Anura: Ranidae). *Journal of Zoological Systematics and Evolutionary Research*, 59(7), 1604-1619. <https://doi.org/10.1111/jzs.12503>
- Araujo M.B., New M., 2007. Ensemble forecasting of species Distributions, *TRENDS in Ecology and Evolution*, 22 (1): 42-47. <https://doi.org/10.1016/j.tree.2006.09.010>
- Austin, M. P. (2002). Spatial prediction of species distribution: an interface between ecological theory and statistical modelling. *Ecological modelling*, 157(2-3), 101-118. [https://doi.org/10.1016/S0304-3800\(02\)00205-3](https://doi.org/10.1016/S0304-3800(02)00205-3)
- همکاران (2019)، و گین Hosseinalizadeh et al., 2019
همکاران (2019) و یوسفی و همکاران Gayen et al., 2019
همپوشانی کامل دارد. نتایج Yousefi et al., 2020
این مطالعه در خصوص مدل Maxent که یک مدل دقیق برای پیش‌بینی و تعیین پدیده‌های مختلف است، با نتایج مطالعات قیومی و همکاران (Ghyoumi et al., 2019)
محمدی و همکاران (Mohammadi et al., 2019)
شیخی اینالو و همکاران (Sheykhi Ilanloo et al., 2021;
Ghayoumi et al., 2020)
Ghayoumi and (et al., 2022)
Ghayoumi and ابراهیمی (Ebrahimi, 2020)
همپوشانی دارد.
به طور کلی نتایج این پژوهش برای کاهش اثرات مخرب سیل، ایجاد نقشه‌های دقیق پتانسیل وقوع سیل در منطقه مورد مطالعه که به تازگی در معرض سیل‌های متعدد بوده است، ضروری به نظر می‌رسید. در این مطالعه شش روش یادگیری ماشینی و آماری جدآگانه برای پیش‌بینی مناطق مستعد سیل استفاده شد. تنوع در بین پیش‌بینی مدل‌های فردی، نشان می‌دهد که هر مدل برای برخی مکان‌ها پیش‌بینی خوبی دارد و برای مناطق دیگر پیش‌بینی‌های دقیق‌تری ایجاد می‌کند، اما ادغام مدل‌های فردی با رویکرد همادی نوین با قایلیت پیش‌بینی بالا در این پژوهش بهمنزله رویکردی جدید معرفی شد. توجه به نتایج مطالعات شناسایی مناطق دارای پتانسیل وقوع سیل، از جمله این مطالعه، می‌تواند زیان مالی و اقتصادی را در آینده به‌طور چشمگیری کاهش دهد و سبب جلوگیری از توسعه مناطق مسکونی یا تجاری در مناطق آسیب‌پذیر شود.

منابع

- Abbaspour, M., Mahiny, A. S., Arjmandy, R., & Naimi, B. (2011). Integrated approach for land use suitability analysis. *International Agrophysics*, 25(4). bwmeta1.element.agro-babd4e54-f64e-4413-9f46-3df1073f8d02
- Abdi Dehkordi, M., Bozorg Haddad, O., & Salavitarbar, A. (2020). Investigation of the

- Avand, M., Janizadeh, S., Naghibi, S. A., Pourghasemi, H. R., Khosrobeigi Bozchaloei, S., & Blaschke, T. (2019). A comparative assessment of random forest and k-nearest neighbor classifiers for gully erosion susceptibility mapping. *Water*, 11(10), 2076. <https://doi.org/10.3390/w11102076>
- Beven, K. (1979). On the generalized kinematic routing method. *Water Resources Research*, 15(5), 1238-1242. <https://doi.org/10.1029/WR015i005p01238>
- Billa, L., Mansor, S., Mahmud, A. R., & Ghazali, A. H. (2006). Modelling rainfall intensity from NOAA AVHRR data for operational flood forecasting in Malaysia. *International Journal of Remote Sensing*, 27(23), 5225-5234. <https://doi.org/10.1080/01431160500192603>
- Breiman, L. Random forests. *Mach. Learn.* 45, 5–32 (2001).
- Breiman, L., & Cutler, A. (2001). Random forest. *Machine Learning Statistics Department University of California*, 1, 33.
- Brivio, P. A., R. Colombo, M. Maggi, and R. Tomasoni (2002). Integration of remote sensing data and GIS for accurate mapping of flooded areas. *International Journal of Remote Sensing*, 23 (3), 429-441. <https://doi.org/10.1080/01431160010014729>
- Caballero, G. R., Platzeck, G., Pezzola, A., Casella, A., Winschel, C., Silva, S. S., Delegido, J. (2020). Assessment of multi-date Sentinel-1 polarizations and GLCM texture features capacity for onion and sunflower classification in an irrigated valley: an object level approach. *Agronomy*, 10(6), 845. <https://doi.org/10.3390/agronomy10060845>
- Cao, H., Zhang, H., Wang, C., & Zhang, B. (2019). Operational flood detection using Sentinel-1 SAR data over large areas. *Water*, 11(4), 786. <https://doi.org/10.3390/w11040786>
- Carreño Conde, F., & De Mata Muñoz, M. (2019). Flood monitoring based on the study of Sentinel-1 SAR images: The Ebro River case study. *Water*, 11(12), 2454. <https://doi.org/10.3390/w11122454>
- Cavender-Bares, J., Schneider, F. D., Santos, M. J., Armstrong, A., Carnaval, A., Dahlin, K. M., ... & Wilson, A. M. (2022). Integrating remote sensing with ecology and evolution to advance biodiversity conservation. *Nature Ecology & Evolution*, 6(5), 506-519. <https://doi.org/10.1038/s41559-022-01702-5>
- Chapi, K., Singh, V. P., Shirzadi, A., Shahabi, H., Bui, D. T., Pham, B. T., & Khosravi, K. (2017). A novel hybrid artificial intelligence approach for flood susceptibility assessment. *Environmental modelling & software*, 95, 229-245. <https://doi.org/10.1016/j.envsoft.2017.06.012>
- Chen, W., Li, Y., Xue, W., Shahabi, H., Li, S., Hong, H., ... & Ahmad, B. B. (2020). Modeling flood susceptibility using data-driven approaches of naïve bayes tree, alternating decision tree, and random forest methods. *Science of The Total Environment*, 701, 134979. <https://doi.org/10.1016/j.scitotenv.2019.134979>
- Clement, M. A., Kilsby, C. G., & Moore, P. (2018). Multi-temporal synthetic aperture radar flood mapping using change detection. *Journal of Flood Risk Management*, 11(2), 152-168. <https://doi.org/10.1111/jfr3.12303>
- Conforti, M., Muto, F., Rago, V., & Critelli, S. (2014). Landslide inventory map of north-eastern Calabria (South Italy). *Journal of maps*, 10(1), 90-102. <https://doi.org/10.1080/17445647.2013.852142>
- Ebrahimi, E., Araújo, M. B., & Naimi, B. (2023). Flood susceptibility mapping to improve models of species distributions. *Ecological Indicators*, 157, 111250. <https://doi.org/10.1016/j.ecolind.2023.111250>
- Ebrahimi, E., Ranjbaran, Y., Sayahnia, R., & Ahmadzadeh, F. (2022). Assessing the climate change effects on the distribution pattern of the Azerbaijan Mountain Newt (*Neurergus crocatus*). *Ecological Complexity*, 50, 100997. <https://doi.org/10.1016/j.ecocom.2022.100997>
- Elith, J., Leathwick, J. R., & Hastie, T. (2008). A working guide to boosted regression trees.

- Journal of animal ecology, 77(4), 802-813. <https://doi.org/10.1111/j.1365-2656.2008.01390.x>
- ESA, ESA's radar observatory mission for GMES operational services, vol. 1, no. sp-1322/1. 2012.
- Fechter, D., & Storch, I. (2014). How many wolves (*Canis lupus*) fit into Germany? The role of assumptions in predictive rule-based habitat models for habitat generalists. *PloS one*, 9(7), e101798. <https://doi.org/10.1371/journal.pone.0101798>
- Franklin, J. (2010). Moving beyond static species distribution models in support of conservation biogeography. *Diversity and Distributions*, 16(3), 321-330. <https://doi.org/10.1111/j.1472-4642.2010.00641.x>
- Friedman, J. H. (1991). Multivariate Adaptive Regression Splines. *The annals of statistics*, 19(1), 1-67.
- Garcia, C. A., Savilaakso, S., Verburg, R. W., Stoudmann, N., Fernbach, P., Sloman, S. A., ... & Waeber, P. O. Strategy games to improve environmental policymaking. *Nat Sustain* 5, 464–471 (2022). <https://doi.org/10.1038/s41893-022-00881-0>
- Gayen, A., Pourghasemi, H. R., Saha, S., Keesstra, S. & Bai, S. Gully erosion susceptibility assessment and management of hazardprone areas in India using different machine learning algorithms. *Science of The Total Environment*. 668, 124–138 (2019). <https://doi.org/10.1016/j.scitotenv.2019.02.436>
- Gayen, A., Pourghasemi, H. R., Saha, S., Keesstra, S., & Bai, S. (2019). Gully erosion susceptibility assessment and management of hazard-prone areas in India using different machine learning algorithms. *Science of The Total Environment*, 668, 124-138. <https://doi.org/10.1016/j.scitotenv.2019.02.328>
- Ghayoumi, R., & Ebrahimi, E. (2020). Predicting the potential distribution of *Avicennia marina* across mangrove forest area in Southern Iran using Biochemical database. *Journal of Oceanography*, 10(40), 55-63. <http://joc.inio.ac.ir/article-1-1530-en.html>
- Ghayoumi, R., Ebrahimi, E., & Mousavi, S. M. (2022). Dynamics of mangrove forest distribution changes in Iran. *Journal of Water and Climate Change*, 13(6), 2479-2489. <https://doi.org/10.2166/wcc.2022.069>
- Ghyoumi, R., Ebrahimi, E., Hosseini, F., Hosseini Taifeh, M., Kashtkar, M. (2019). Predicting the Effects of Climate Changes on the Distribution of Mangrove Forests in Iran Using Maximum Entropy Model, Remote Sensing, and Geographic Information System in Natural Resources. *Journal of Remote Sensing & GIS in Natural Resources*, 10(2), 34-47. <http://dorl.net/dor/20.1001.1.26767082.1398.10.2.3.2>
- Goetz, J. N., Guthrie, R. H., & Brenning, A. (2011). Integrating physical and empirical landslide susceptibility models using generalized additive models. *Geomorphology*, 129(3-4), 376-386. <https://doi.org/10.1016/j.geomorph.2011.03.001>
- Gunn, S. R. (1998). Support vector machines for classification and regression. *ISIS technical report*, 14(1), 5-16.
- Hammami, S., Zouhri, L., Souissi, D., Souei, A., Zghibi, A., Marzougui, A., & Dlala, M. (2019). Application of the GIS based multi-criteria decision analysis and analytical hierarchy process (AHP) in the flood susceptibility mapping (Tunisia). *Arabian Journal of Geosciences*, 12(21), 1-16. <https://doi.org/10.1007/s12517-019-4754-9>
- Hill, D. J., Minsker, B. S. (2010). Anomaly detection in streaming environmental sensor data: A data-driven modeling approach. *Environmental Modelling & Software*, 25(9), 1014-1022. <https://doi.org/10.1016/j.envsoft.2009.08.010>
- Horritt, M. S., Mason, D. C., & Luckman, A. J. (2001). Flood boundary delineation from synthetic aperture radar imagery using a statistical active contour model. *International Journal of Remote Sensing*, 22(13), 2489-2507. <https://doi.org/10.1080/01431160116902>
- Hosseinalizadeh, M., Kariminejad, N., Rahmati, O., Keesstra, S., Alinejad, M., & Behbahani, A. M. (2019). How can statistical and artificial intelligence approaches predict

- piping erosion susceptibility?. *Science of the Total Environment*, 646, 1554-1566.
<https://doi.org/10.1016/j.scitotenv.2018.07.368>
- Huang, X., Tan, H., Zhou, J., Yang, T., Benjamin, A., Wen, S. W., ... & Li, X. (2008). Flood hazard in Hunan province of China: an economic loss analysis. *Natural Hazards*, 47, 65-73.
<https://doi.org/10.1007/s11069-007-9197-z>
- Iilanloo, S. S., Ebrahimi, E., Valizadegan, N., Ashrafi, S., Rezaei, H. R., & Yousefi, M. (2020). Little owl (*Athene noctua*) around human settlements and agricultural lands: Conservation and management enlightenments. *Acta Ecologica Sinica*, 40(5), 347-352.
<https://doi.org/10.1016/j.chnaes.2020.06.001>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning (Vol. 112, p. 18). New York: Springer.
- Kalantari, Z., Ferreira, C. S. S., Koutsouris, A. J., Ahlmer, A. K., Cerdà, A., & Destouni, G. (2019). Assessing flood probability for transportation infrastructure based on catchment characteristics, sediment connectivity and remotely sensed soil moisture. *Science of the total environment*, 661, 393-406.
<https://doi.org/10.1016/j.scitotenv.2019.01.009>
- Kapur, J. N., Sahoo, P. K., Wong, A. K. (1985). A new method for gray-level picture thresholding using the entropy of the histogram. *Computer vision, graphics, and image processing*, 29(3), 273-285.
[https://doi.org/10.1016/0734-189X\(85\)90125-2](https://doi.org/10.1016/0734-189X(85)90125-2)
- Kourgialas, N. N., & Karatzas, G. P. (2011). Flood management and a GIS modelling method to assess flood-hazard areas—a case study. *Hydrological Sciences Journal—Journal des Sciences Hydrologiques*, 56(2), 212-225.
<https://doi.org/10.1080/02626667.2011.555836>
- Kussul, N. Shelestov, A. and Skakun, S. 2011. Flood monitoring from SAR data. In: Use of Satellite and In-Situ Data to Improve Sustainability. Springer, Dordrecht. pp. 19-29. https://doi.org/10.1007/978-90-481-9618-0_3
- Markantonis, V., Meyer, V., & Lienhoop, N. (2013). Evaluation of the environmental impacts of extreme floods in the Evros River basin using Contingent Valuation Method. *Natural hazards*, 69, 1535-1549.
<https://doi.org/10.1007/s11069-013-0762-3>
- Martínez-López, J., Martínez-Fernández, J., Naimi, B., Carreño, M. F., & Esteve, M. A. (2015). An open-source spatio-dynamic wetland model of plant community responses to hydrological pressures. *Ecological Modelling*, 306, 326-333.
<https://doi.org/10.1016/j.ecolmodel.2014.11.024>
- Matgen, P., Henry, J. B., Pappenberger, F., Pfister, L., De Fraipont, P., & Hoffmann, L. (2004). Uncertainty in calibrating flood propagation models with flood boundaries derived from synthetic aperture radar imagery. *Proc. 20th Congr. Int. Soc. Photogramm. Remote Sens.*, Istanbul, Turkey, 352-358.
- McCullagh, P. (2019). Generalized linear models. Routledge.
<https://doi.org/10.1201/9780203753736>
- McCullagh, P., & Nelder, J. A. (1989). Generalized linear models, volume 37 of. Monographs on statistics and applied probability, 37.
- Mohammadi, S., Ebrahimi, E., Shahriari Moghadam, M., & Bosso, L. (2019). Modelling current and future potential distributions of two desert jerboas under climate change in Iran. *Ecol Inf*, 52: 7-13.
<https://doi.org/10.1016/j.ecoinf.2019.04.003>
- Nachappa, T. G., Piralilou, S. T., Gholamnia, K., Ghorbanzadeh, O., Rahmati, O., & Blaschke, T. (2020). Flood susceptibility mapping with machine learning, multi-criteria decision analysis and ensemble using Dempster Shafer Theory. *Journal of hydrology*, 590, 125275.
<https://doi.org/10.1016/j.jhydrol.2020.125275>
- Naimi, B., & Araújo, M. B. (2016). sdm: a reproducible and extensible R platform for species distribution modelling. *Ecography*, 39(4), 368-375.
<https://doi.org/10.1111/ecog.01881>

- Otsu, N. (1975). A threshold selection method from gray-level histograms. *Automatica*, 11(285-296), 23-27.
<https://doi.org/10.1109/TSMC.1979.4310076>
- Ozdemir, A., & Altural, T. (2013). A comparative study of frequency ratio, weights of evidence and logistic regression methods for landslide susceptibility mapping: Sultan Mountains, SW Turkey. *Journal of Asian Earth Sciences*, 64, 180-197.
<https://doi.org/10.1016/j.jseaea.2012.12.014>
- Park, D., & Markus, M. (2014). Analysis of a changing hydrologic flood regime using the Variable Infiltration Capacity model. *Journal of Hydrology*, 515, 267-280.
<https://doi.org/10.1016/j.jhydrol.2014.05.004>
- Phillips, S. J., Anderson, R. P., & Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, 190, 231-259.
<https://doi.org/10.1016/j.ecolmodel.2005.03.026>
- Radhika, K. R., Sekhar, G. N., & Venkatesha, M. K. (2009, April). Pattern recognition techniques in on-line hand written signature verification-A survey. In 2009 International Conference on Multimedia Computing and Systems (pp. 216-221). IEEE.
<https://doi.org/10.1109/MMCS.2009.5256701>
- Rastmanesh, F., Barati-haghghi, T., and Zaravandi, A., 2020, Assessment of the impact of 2019 Karun River flood on river sediment in Ahvaz city area, Iran. *Environmental Monitoring and Assessment*, 192, <https://doi.org/10.1007/s10661-020-08607-5>
- Rozalis, S., Morin, E., Yair, Y., & Price, C. (2010). Flash flood prediction using an uncalibrated hydrological model and radar rainfall data in a Mediterranean watershed under changing hydrological conditions. *Journal of Hydrology*, 394, 245255.
<https://doi.org/10.1016/j.jhydrol.2010.03.021>
- Sayedain, S. A., Maghsoudi, Y., & Eini-Zinab, S. (2020). Assessing the use of cross-orbit Sentinel-1 images in land cover classification. *International Journal of Remote Sensing*, 41(20), 7801-7819.
- <https://doi.org/10.1080/01431161.2020.1763512>
- Schumann, G., Di Baldassarre, G., Bates, P. D. (2009). The utility of spaceborne radar to render flood inundation maps based on multialgorithm ensembles. *IEEE Transactions on Geoscience and Remote Sensing*, 47(8), 2801-2807.
<https://doi.org/10.1109/TGRS.2009.2017937>
- 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.
<https://doi.org/10.1016/j.jenvman.2018.03.089>
- Shahabi, H. et al. A semi-automated object-based gully networks detection using different machine learning models: A case study of Bowen catchment, Queensland, Australia. *Sensors (Switzerland)* 19, 4893 (2019).
<https://doi.org/10.3390/s19224893>
- Sheykhi Ilanloo, S., Khani, A., Kafash, A., Valizadegan, N., Ashrafi, S., Loercher, F., Ebrahimi, E., Yousefi, M. (2021). Applying opportunistic observations to model current and future suitability of the Kopet Dag Mountains for a Near Threatened avian scavenger. *Avian Biology Research*, 14(1), 18-26.
<https://doi.org/10.1177/1758155920962750>
- Taalab, K., Cheng, T., & Zhang, Y. (2018). Mapping landslide susceptibility and types using Random Forest. *Big Earth Data*, 2(2), 159-178.
<https://doi.org/10.1080/20964471.2018.1472392>
- Tayfehrostami, A., Azmoudeh Ardalan, A. R., Roohi, S., & Pourmina, A. H. (2021). Dams Surface Area Monitoring from VV and VH Polarization of Sentinel-1 Mission SAR Images (Case study: Doroudzan Dam, Shiraz, Iran). *Journal of Geomatics Science and Technology*, 10(4), 103-116.
<http://jgst.issgeac.ir/article-1-988-en.html>
- Tehrany, M. S., Pradhan, B., & Jebur, M. N. (2013). Spatial prediction of flood susceptible

- areas using rule based decision tree (DT) and a novel ensemble bivariate and multivariate statistical models in GIS. *Journal of hydrology*, 504, 69-79.
<https://doi.org/10.1016/j.jhydrol.2013.09.034>
- Tehrany, M. S., Pradhan, B., & Jebur, M. N. (2015). Flood susceptibility analysis and its verification using a novel ensemble support vector machine and frequency ratio method. *Stochastic environmental research and risk assessment*, 29(4), 1149-1165.
<https://doi.org/10.1007/s00477-015-1021-9>
- Thorup, K., Pedersen, L., Da Fonseca, R. R., Naimi, B., Nogués-Bravo, D., Krapp, M., ... & Rahbek, C. (2021). Response of an Afro-Palearctic bird migrant to glaciation cycles. *Proceedings of the National Academy of Sciences*, 118(52), e2023836118.
<https://doi.org/10.1073/pnas.2023836118>
- Thuiller W., 2003. BIOMOD—optimizing predictions of species distributions and projecting potential future shifts under global change. *Global Change Biology*, 9 (10): 1353-1362. <https://doi.org/10.1046/j.1365-2486.2003.00666.x>
- Wang, S. S. Y., Kim, H., Coumou, D., Yoon, J. H., Zhao, L., & Gillies, R. R. (2019). Consecutive extreme flooding and heat wave in Japan: Are they becoming a norm?. *Atmospheric Science Letter*.
<https://doi.org/10.1002/asl.933>
- Yokoya, N., Chan, J. C. W., & Segl, K. (2016). Potential of resolution-enhanced hyperspectral data for mineral mapping using simulated EnMAP and Sentinel-2 images. *Remote Sensing*, 8(3), 172.
<https://doi.org/10.3390/rs8030172>
- Yommy, A.-S. Liu, R. and Wu, S. 2015. SAR image despeckling using refined Lee filter. In 2015 7th IEEE International Conference on Intelligent Human Machine Systems and Cybernetics. pp. 260-265. <https://doi.org/10.1109/IHMSC.2015.236>
- Yousefi, S., Pourghasemi, H. R., Emami, S. N., Rahmati, O., Tavangar, S., Pouyan, S., ... & Nekoeimehr, M. (2020). Assessing the susceptibility of schools to flood events in Iran. *Scientific reports*, 10(1), 18114. <https://doi.org/10.1038/s41598-020-75291-3>