



Flood susceptibility mapping using a combination of a deep learning method and the HHO algorithm

Aminreza Neshat^{1✉} | Sina Paryani² | Saman Javadi³

1. Corresponding Author, Department of Civil Engineering, SR.C., Islamic Azad University, Tehran, Iran. E-mail: neshat.aminreza@srbiau.ac.ir
2. Department of Civil Engineering, SR.C., Islamic Azad University, Tehran, Iran. E-mail: sina_paryani@yahoo.com
3. Department of Water Engineering, Faculty of Agricultural Technology, University of Tehran, Tehran, Iran. E-mail: javadis@ut.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 17 March 2025

Received in revised form

10 July 2025

Accepted 12 August 2025

Published online 11 October 2025

Keywords:

Flood Susceptibility

CNN

HHO

ABSTRACT

Predicting flood-prone areas to enhance crisis management has been a critical focus of research in recent years. The present study aims to introduce a novel and robust hybrid method for identifying flood-vulnerable zones in Tehran. For this purpose, a Convolutional Neural Network (CNN) was integrated with the Harris Hawks Optimization (HHO) algorithm to improve predictive accuracy. To compile flood inventory data, historical flood records, social media reports, and datasets from relevant organizations were analyzed, resulting in a map of 157 documented flood events. The dataset was divided into training (70%) and validation (30%) subsets. Nine influential parameters were selected as independent variables: elevation, slope, rainfall, Stream Power Index (SPI), Topographic Wetness Index (TWI), distance from rivers, river density, geology, and land use. The model's performance was evaluated using metrics such as Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Sensitivity, Specificity, Accuracy, and the Area Under the ROC Curve (AUC-ROC). The AUC-ROC value demonstrated exceptional predictive accuracy (95%) for the CNN-HHO hybrid model. Furthermore, the results of other metrics—Accuracy (55.92%), Specificity (79.5%), Sensitivity (48.9%), MAE (0.165), and RMSE (0.277)—confirmed the model's robust capability in flood zonation mapping. The findings highlight the effectiveness of the proposed CNN-HHO hybrid model, suggesting its potential as a reliable tool for flood prediction in other regions facing similar hydrological risks.

Cite this article: Neshat, A., Paryani, S., & Javadi, S. (2025). Flood susceptibility mapping using a combination of a deep learning method and the HHO algorithm. *Journal of Water and Irrigation Management*, 15 (2), 393-409.

DOI: <https://doi.org/10.22059/jwim.2025.392100.1212>



© The Author(s).

DOI: <https://doi.org/10.22059/jwim.2025.392100.1212>

Publisher: University of Tehran Press.



تهیه نقشه حساسیت به سیل با استفاده از ترکیب روش‌های نوین یادگیری عمیق و الگوریتم HHO

امین‌رضا نشاط^{۱*} | سینا پریانی^۲ | سامان جوادی^۳

۱. نویسنده مسئول، گروه مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: neshat.aminreza@srbiau.ac.ir

۲. گروه مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: sina_paryani@yahoo.com

۳. گروه مهندسی آب، دانشکده فناوری کشاورزی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، تهران، ایران. رایانامه: javadis@ut.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۱۲/۲۷

تاریخ بازنگری: ۱۴۰۴/۰۴/۱۹

تاریخ پذیرش: ۱۴۰۴/۰۵/۲۱

تاریخ انتشار: ۱۴۰۴/۰۷/۱۹

پیش‌بینی مناطق در معرض خطر سیل به‌منظور مدیریت بهتر بحران از جمله اقداماتی است که طی سال‌های اخیر موردتوجه پژوهش‌گران قرار گرفته است. هدف از مطالعه حاضر، ارائه یک روش ترکیبی جدید و قدرتمند جهت پیش‌بینی مناطق حساس به سیل در شهر تهران می‌باشد. برای این منظور روش یادگیری عمیق CNN با الگوریتم قدرتمند HHO ترکیب شد. در این پژوهش نقشه سیل‌های رخ داده با استفاده از مطالعه تاریخ سیل‌ها، شبکه‌های اجتماعی و داده‌های سازمان‌های مربوطه تولید شد که نتیجه آن ۱۵۷ نقطه می‌باشد. ۷۰ درصد وقایع برای آموزش مدل و درصد باقیمانده نیز به‌منظور صحت‌سنجی انتخاب شد. تعداد نه پارامتر مؤثر بر وقوع سیل ارتفاع، شیب، بارندگی، شاخص قدرت جریان، شاخص رطوبت توپوگرافی، فاصله از رودخانه، تراکم رودخانه، سنگ‌شناسی و کاربری اراضی را به‌عنوان متغیرهای مستقل انتخاب کردیم. در این پژوهش از چندین شاخص شامل MAE، RMSE، Sensitivity، Specificity و Accuracy و هم‌چنین سطح زیر نمودار ROC استفاده شد تا عملکرد مدل به‌کاررفته ارزیابی شود. مقدار به‌دست‌آمده از سطح زیر نمودار ROC نشان داد مدل ترکیبی CNN-HHO با ۹۵ درصد دقت فوق‌العاده‌ای در پیش‌بینی وقوع سیل دارد. هم‌چنین نتایج به‌دست‌آمده از شاخص‌های Accuracy (۹۲/۵۵)، Specificity (۹۵/۷)، Sensitivity (۸۹/۴)، MAE (۰/۱۶۵) و RMSE (۰/۲۷۷) نیز نشان داد مدل به‌کاررفته عملکرد بسیار خوبی در پهنه‌بندی منطقه مورد مطالعه دارد. براساس نتایج، مدل ترکیبی ارائه‌شده در این پژوهش می‌تواند به‌عنوان روشی قدرتمند در مناطق دیگر نیز به‌کار گرفته شود.

کلیدواژه‌ها:

الگوریتم HHO

الگوریتم یادگیری عمیق CNN

نقشه حساسیت سیل

استناد: نشاط، امین‌رضا؛ پریانی، سینا و جوادی، سامان (۱۴۰۴). تهیه نقشه حساسیت به سیل با استفاده از ترکیب روش‌های نوین یادگیری عمیق و الگوریتم

HHO. نشریه مدیریت آب و آبیاری، ۱۵ (۲)، ۳۹۳-۴۰۹. DOI: <https://doi.org/10.22059/jwim.2025.392100.1212>



۱. مقدمه

انسان‌ها از دیرباز تاکنون با توجه به امکانات موجود همواره در پی راه‌کارهایی جهت مقابله با عواقب ناشی از فجایع طبیعی مانند سیل بوده‌اند. امروزه سیلاب یکی از خطرناک‌ترین رخدادهای طبیعی در نقاط مختلف جهان محسوب می‌شود که در برخی از موارد بیش‌تر از سایر بلایای طبیعی خسارات‌های مالی و جانی به‌همراه دارد (Arora et al., 2021). طبق برآوردها خسارت‌های اقتصادی وارد شده در سطح جهان بین سال‌های ۲۰۰۰ تا ۲۰۱۹ حدوداً ۶۵۱ میلیارد (USD) می‌باشد (Tellman et al., 2021). همچنین از نظر انسانی آمارها نشان می‌دهد سیل آسیب زیادی به زندگی انسان‌ها وارد می‌کند. برای مثال، در آسیا بیش از ۹۰ درصد تلفات انسانی مربوط به فجایع طبیعی ناشی از سیل است (Khosravi et al., 2018). ایران که در غرب آسیا واقع شده از جمله کشورهایی است که همواره در معرض وقوع سیل قرار داشته است. مانند سایر نقاط جهان، یکی از مهم‌ترین عوامل ایجاد سیل در ایران تغییر الگوهای بارشی می‌باشد که ناشی از تغییرات اقلیمی است. روند افزایشی سیلاب در پنج دهه اخیر نشان می‌دهد تعداد سیلاب‌ها در دهه ۹۰ نسبت به دهه ۴۰ تقریباً ۱۲ برابر شده است (عبدی، ۱۳۸۵). آمارها نشان می‌دهد طی یک دهه گذشته سیل تبدیل به یک معضل زیست‌محیطی شده است. این پدیده در کشور ایران بیش‌تر به‌علت به‌هم‌خوردن تعادل طبیعی و شرایط جغرافیایی منطقه ایجاد می‌گردد، به‌طوربه‌طوری که حتی بروز بارش‌های معمولی نیز منجر به جاری‌شدن سیلاب می‌شود. سیل‌ها نه‌تنها در مناطق برون‌شهری بلکه در مناطق شهری نیز خسارت‌های زیادی وارد می‌کنند. برای مثال، وقوع بارش‌های شدید در فروردین‌ماه ۱۳۹۸ موجب جاری‌شدن سیل در ۲۵ استان ایران از جمله ۲۰۰ شهر و بیش از ۴۳۰۰ روستا شد. طبق برآوردهای انجام‌شده علاوه بر زیان مالی بین ۳۰ تا ۳۵ هزار میلیارد تومانی، بیش از ۵۰ مورد نیز تلفات انسانی در پی داشته است. همچنین طی سال‌های گذشته حدوداً ۷۰ درصد اعتبارهای سالانه طرح کاهش اثرهای بلایای طبیعی و ستاد حوادث غیرمترقبه صرف جبران خسارت‌های ناشی از سیل شده است (چراغی و همکاران، ۱۳۹۹).

پهنه‌بندی منطقه مورد مطالعه با استفاده از سیستم اطلاعات جغرافیایی و سنجش از دور یک راه بسیار کاربردی جهت پیش‌بینی است. نقشه حساسیت سیل ابزاری است که محدوده سیل و پراکنش آن را با دقت نشان می‌دهد، بنابراین توسعه آن‌ها به‌منظور کنترل سیل یک امر ضروری است (Saravanan et al., 2023). با کمک این نقشه‌ها می‌توان اقدامات پیشگیرانه قبل از سیل و همچنین عملیات‌های بعد از وقوع سیل را بهتر مدیریت کرد (Arabameri et al., 2022).

هدف از پژوهش حاضر، استفاده از یک مدل ترکیبی جدید با استفاده از هوش مصنوعی به‌منظور پتانسیل‌یابی کلان شهر تهران نسبت به وقوع سیل است. در این پژوهش برای اولین بار از ترکیب الگوریتم هوشمند HHO و روش یادگیری عمیق CNN استفاده شد تا یک نقشه دقیق از مناطق حساس به وقوع سیل شهر تهران تولید شود. این نقشه می‌تواند به‌عنوان ابزاری مهم در اختیار تصمیم‌گیران قرار گیرد تا از خسارت‌ها و تلفات احتمالی در آینده جلوگیری شود.

۲. روش‌شناسی پژوهش

۲.۱. منطقه مورد مطالعه

شهر تهران با مساحت در حدود ۷۳۰ کیلومتر مربع و جمعیتی در حدود ۹/۴ میلیون نفر پرجمعیت‌ترین و بزرگ‌ترین شهر غرب آسیا و ۲۴ امین شهر پرجمعیت جهان می‌باشد (ویکی پدیا) (شکل ۱). این شهر که در دامنه‌های جنوبی رشته کوه البرز واقع شده با طول جغرافیایی ۵۱ درجه و ۶ دقیقه تا ۵۱ درجه و ۳۸ دقیقه و عرض جغرافیایی ۳۵ درجه و ۳۴ دقیقه تا ۳۵ درجه و ۵۱ دقیقه پایتخت کشور ایران می‌باشد. ارتفاع آن از سطح دریا حدوداً ۱۰۱۶ متر برای جنوب شهر و ۱۸۰۰ متر برای شمال شهر می‌باشد. همچنین بلندترین نقطه، قله توچال با ارتفاع ۳۹۰۰ متر می‌باشد که در ارتفاعات شمال شهر واقع شده است. بخش

شمالی به دلیل این که تحت تأثیر منطقه کوهستانی است دارای آب و هوای معتدل و بقیه شهر نیز آب و هوای گرم و خشکی دارد. میانگین بارش در بخش شمالی شهر حدوداً ۴۲۲ میلی متر و در جنوب حدوداً ۱۴۵ میلی متر است (Afsari *et al.*, 2022). این شرایط موجب شده است تا در شمال شهر تهران شاهد رودهای دائمی و فصلی متعددی باشیم که همواره تحت تأثیر سیلاب بوده است. وجود چندین رود دره در بخش دامنه های شمالی و همچنین بارش های ناگهانی در مدت زمان کم همواره از عوامل وقوع سیل در این شهر بوده است. از نظر فعالیت های انسانی نیز توسعه غیرعلمی شهرسازی مانند اشغال حریم آبراهه ها و مسیل ها و همچنین عدم لایه رویی رودخانه ها از عوامل مؤثر بر وقوع سیل هستند. جدول (۱)، سیل های اتفاق افتاده طی یک قرن اخیر را نشان می دهد. کاملاً واضح است که پهنه بندی شهر تهران به منظور شناسایی مناطق در معرض خطر و انجام تمهیدات لازم به منظور کاهش تلفات جانی و خسارت های اقتصادی ناشی از وقوع سیل در آینده کاملاً حیاتی است.




Figure 1. Location of study area

Table 1. Flood history

Year	Region
1954	Farahzad-Northwest Tehran
1955	Kan Area
1981	Kan Area
1987	Tajrish-Darband
2012	Kan River
2015	Kan River
2022	Imamzadeh Davood

۲. نقشه سیل‌های رخ داده

آگاهی از سیل‌های گذشته به منظور پیش‌بینی سیل‌های آینده ضروری است (Pham *et al.*, 2021). در این مطالعه به دلیل وجود پوشش ابر و همچنین عدم ثبت تصویر در زمان بعد از وقوع سیل از داده‌های ماهواره‌ای استفاده نشد. یکی دیگر از دلایل عدم استفاده از تصاویر ماهواره‌ای در این پژوهش این است که برخی از سیل‌ها زمانی رخ داده که هنوز ماهواره‌ای نظارتی ساخته نشده بود مانند سیل‌های ۱۳۳۳ محدوده فرحزاد و شمال غرب تهران، سیل ۱۳۳۴ محدوده کن و سیل مردادماه سال ۱۳۶۶ میدان تجریش. بنابراین در این مطالعه از داده‌های سازمان مدیریت منابع آب ایران، تاریخچه سیل‌های ثبت شده و اطلاعات منتشر شده در شبکه‌های اجتماعی استفاده شد. استفاده از گزارش‌های شبکه‌های اجتماعی یکی از روش‌های استخراج داده‌های مورد نیاز مربوط به یک فاجعه می‌باشد که در بسیاری از مطالعات مورد توجه پژوهش‌گران قرار گرفته است (Fu *et al.*, 2022; Songchon *et al.*, 2021). به علاوه در این مطالعه از نرم‌افزار Google Earth نیز استفاده شد تا استخراج نمونه‌ها با دقت بیش‌تر انجام شود. نمونه‌ها شامل سیل‌های ناگهانی است که طی یک قرن اخیر در شهر تهران رخ داده است. پس از آماده‌سازی، داده‌ها به دو گروه تقسیم‌بندی شد. یکی از گروه‌ها که شامل ۷۰ درصد نمونه‌ها می‌باشد برای آموزش مدل و ۳۰ درصد باقیمانده نیز برای صحت‌سنجی مدل انتخاب شد. به علاوه، به صورت تصادفی ۱۵۷ نقطه غیر سیل نیز در منطقه مطالعه انتخاب شد و به طور مشابه با داده‌های سیل به دو گروه ۳۰/۷۰ گروه‌بندی شد. شکل (۲) روند انجام این پژوهش را نشان می‌دهد.




Figure 2. Flowchart

۳.۲. تهیه فاکتورهای مؤثر بر سیلاب

براساس ویژگی‌های سیل‌های گذشته، دیتاهای در دسترس و همچنین بررسی پژوهش‌های گذشته (Li et al., 2023; Yariyan et al., 2020; Shahabi et al., 2021; Costache et al., 2020)، نه عامل مؤثر بر وقوع سیل در شهر تهران در نظر گرفته شد که شامل فاکتورهای توپوگرافی (ارتفاع و شیب)، فاکتورهای هیدرولوژی (بارش، فاصله از رودخانه، تراکم رودخانه، شاخص قدرت جریان و شاخص رطوبت توپوگرافی)، کاربری اراضی و زمین شناسی است. در این پژوهش از مدل رقومی ارتفاع ماهواره ASTER با رزولوشن 30×30 متر استفاده شد تا پارامترهای ارتفاع، شیب، جهت شیب، شاخص قدرت جریان و شاخص رطوبت توپوگرافی استخراج شود. همچنین بقیه دیتاها از سازمان‌های مدیریت منابع آب، وزارت نیرو و سازمان هواشناسی گرفته شد. به‌علاوه به‌منظور صحت‌سنجی و آپدیت رودخانه‌ها و مسیل‌های سطح شهر و کاربری اراضی از Google Earth Pro استفاده شد. همه مراحل شامل ایجاد پایگاه داده، تولید لایه‌ها و نقشه‌های خروجی در نرم‌افزار ArcGIS 10.5 انجام شد. جدول (۲) مشخصات داده‌های به‌کاررفته در این پژوهش را نشان می‌دهد.

Table 2. Dataset used in this study

Type	Factor	GIS type
Topographic	Elevation (m)	Raster
	Slope angle (°)	Raster
Water-related	Distance to river (m)	Shapefile-Line
	SPI	Raster
	TWI	Raster
	River density (Km/Km^2)	Shapefile-Line
Land cover	Rainfall (mm)	Shapefile-Point
	Land use	Shapefile-Polygon
	Lithology	Shapefile-Polygon
Flood records	Flood records	Shapefile-Point

ارتفاع در مناطق کوهستانی یکی از پارامترهای تأثیرگذار در وقوع سیل است. با کاهش ارتفاع زمین هموارتر شده و احتمال وقوع سیل نیز افزایش می‌یابد (Vojtek and Vojteková, 2019). شیب به‌عنوان یک پارامتر مهم و تأثیرگذار در پژوهش‌های مختلف همواره به‌کاررفته است (Cao et al., 2016; Pham et al., 2021)، زیرا رواناب از مناطقی با شیب زیاد به سمت مناطقی با شیب کم جریان می‌یابد (Wang et al., 2020). بارندگی یکی از مهم‌ترین عوامل مؤثر بر وقوع سیل است. بارندگی شدید می‌تواند در یک بازه زمانی کوتاه به‌راحتی باعث وقوع یک سیل ناگهانی شده به‌طوربه‌طوری که با افزایش شدت آن احتمال وقوع این خطر نیز افزایش می‌یابد (Ma et al., 2021). در این پژوهش به‌منظور انجام یک مدل‌سازی واقع‌گرایانه از میانگین بارش سال‌هایی استفاده شد که سیل‌های ناگهانی رخ داده است. برای این منظور از داده‌های آماری ایستگاه‌های سینوپتیک و باران‌سنجی سازمان هواشناسی و وزارت نیرو استفاده شد. شاخص قدرت جریان نشان‌دهنده قدرت فرسایشی رواناب سطحی است که همواره به‌عنوان یک فاکتور مهم در پیش‌بینی سیل به‌کاررفته است (Liuzzo et al., 2019; Vilasan and Kapse., 2022). این پارامتر به‌ویژه در مناطق کوهستانی که حرکت سریع رواناب و شیب‌های تند عامل اصلی وقوع سیل هستند به‌کار می‌رود (Al-Kindi and Alabri, 2024). شاخص رطوبت توپوگرافی به‌دلیل این که با مقدار رطوبت خاک در ارتباط است همواره به‌عنوان یک پارامتر مهم در پهنه‌بندی سیل موردتوجه قرار گرفته است. هرچقدر مقدار TWI^1 بیش‌تر باشد نشان‌دهنده اشباع بیش‌تر زمین است که می‌تواند منجر به وقوع یک سیل ناگهانی شود (Swain et al., 2020). از آنجایی که مناطق مجاور رودخانه بیش‌تر مستعد وقوع سیل هستند، بنابراین فاصله از رودخانه به‌عنوان یک فاکتور مهم و تأثیرگذار شناخته می‌شود (Yariyan et al., 2020). اهمیت این فاکتور به‌ویژه در وقوع سیل‌های ناگهانی بسیار دارای اهمیت است. تراکم رودخانه میزان تجمع رودخانه‌ها را در یک واحد سطح نشان می‌دهد (Paul et al., 2019). سنگ‌شناسی پارامتری است که با تأثیر گذاشتن بر تغییرات هیدرولوژیکی و تولید

رسوب نقش مهمی در وقوع سیل دارد (Prasad *et al.*, 2022). یکی از دلایل افزایش وقوع سیل طی سال‌های اخیر، تغییر کاربری اراضی است (Shahabi *et al.*, 2021). کاملاً واضح است که این پارامتر نقش بسیار مهمی ایفا می‌کند. شکل (۳) لایه‌های تولیدشده پارامترهای مؤثر بر وقوع سیل را نشان می‌دهد.





Figure 3. Layers: Elevation Map (a) Slope Map (b) Rainfall Map (c) SPI Map (d) TWI Map (e) Distance to river Map (f) River density Map (g) Lithology Map (h) Land cover Map (I)



Continued figure 3. Layers: Elevation Map (a) Slope Map (b) Rainfall Map (c) SPI Map (d) TWI Map (e) Distance to river Map (f) River density Map (g) Lithology Map (h) Land cover Map (I)

۴.۲. تحلیل نسبت ارزیابی وزن دهی تدریجی (SWAR)^۲

SWARA یکی از روش های تصمیم گیری چندمعیاره می باشد که توسط Keršuliene و همکاران (2010) معرفی شده است. بررسی مطالعات انجام شده در موضوع های مختلف نشان داده است این روش کارآمد بوده و در موضوعات مختلف تصمیم گیری نتایج خوبی داشته است (Bordbar et al., 2022; Sargın et al., 2024; Wang et al., 2019). مانند هر روش تصمیم گیری چندمعیاره هدف استفاده از این روش وزن دهی به کلاس های هر پارامتر می باشد. وزن دهی به کلاس ها اولین گام از آماده سازی دیتا جهت استفاده از الگوریتم های هوشمند است. بنابراین این روش در پژوهش حاضر به کار گرفته شد تا به عنوان داده ورودی الگوریتم استفاده شود. اگرچه اساس این روش استفاده از نظرات کارشناسی می باشد اما در پژوهش حاضر به جای استفاده از نظرات کارشناس، از روش FR استفاده شد تا اهمیت هر معیار مشخص شود. از معایب نظرات کارشناس این است که دارای عدم قطعیت بوده و ممکن است همراه با تعصب باشد (Ghiasi et al., 2021; Dano et al., 2019). در اینجا وقتی صحبت از معیار می کنیم منظور کلاس های هر پارامتر است (جدول ۳). گام بعدی این روش شامل مقایسه هر معیار با معیار قبلی است که با استفاده از معادله زیر انجام می شود (Keršuliene et al., 2010):

$$S_j = \frac{\sum_{i=1}^n A_i}{n} \quad \text{رابطه (۱)}$$

در گام بعدی، کلاس ها به ترتیب از مهم ترین تا کم اهمیت ترین به صورت نزولی چیده شد (جدول ۳). سپس ضریب K_j برای همه کلاس ها محاسبه شد:

$$K_j = S_j + 1 \quad \text{رابطه (۲)}$$

در گام سوم، با استفاده از معادله زیر، وزن هر معیار (W_j) محاسبه شد (Keršulienė et al., 2010):

$$W_j = \frac{X_j - 1}{K_j} \quad \text{رابطه ۳}$$

$$X_j - 1 = W_1$$

گام آخر نیز شامل نرمال‌سازی وزن‌ها می‌باشد. طبق معادله زیر داریم:

$$Q_j = \frac{W_j}{\sum_{j=1}^m W_j} \quad \text{رابطه ۴}$$

در اینجا، z نشان‌دهنده شماره هر معیار و m نیز تعداد کل معیارها می‌باشد.

جدول (۳)، نمونه محاسبه وزن SWARA برای کلاس‌های پارامتر شیب را نشان می‌دهد. برای دیگر فاکتورها نیز همین روند تکرار شد.

Table 3. Sample

Factor (Classes)	Weight	S_j	K_j	W_j	Q_j	Sorting
Slope (degree)						
0 - 3.86	0.13	1.00	1	1	0.28	0.087
3.86 - 7.34	0.32	0.70	1.70	0.59	0.17	0.125
7.34 - 12.35	0.70	0.32	1.32	0.44	0.12	0.165
12.35 - 18.72	1.00	0.28	1.28	0.35	0.10	0.281
18.72 - 25.19	0.28	0.13	1.13	0.31	0.09	0.098
25.19 - 31.44	0.02	0.05	1.05	0.29	0.08	0.081
31.44 - 38.60	0.00	0.02	1.02	0.29	0.08	0.081
38.60 - 66.30	0.05	0.00	1.00	0.29	0.08	0.083

۵.۲. روش یادگیری عمیق شبکه عصبی کانولوشن (CNN)

الگوریتم CNN که یکی از شناخته‌شده‌ترین روش‌های یادگیری عمیق است همواره نقش مهمی در حل مسائل مختلف مانند کلاس‌بندی تصویر، پردازش زبان و تشخیص متن داشته است (Gu et al., 2018). این الگوریتم که نوعی از کلاس ANN به حساب می‌آید، به نحوی طراحی شده تا به صورت خودکار و تطبیقی، ویژگی‌های فضایی را از الگوهای سطح پایین تا سطح بالا یاد بگیرد (Yamashita et al., 2018). ساختار آن الهام گرفته از قشر بصری مغز بوده که مشابه اتصال نورون‌ها می‌باشد و معمولاً دارای یک شبکه سه بلوکی شامل convolution، pooling و Fully connected می‌باشد که اساس آن را تشکیل می‌دهد. کانولوشن‌ها وظیفه استخراج ویژگی‌های داده‌های ورودی را بر عهده دارند و این کار را با فیلترها و کرنل‌های مختلف انجام می‌دهند (Ullah et al., 2022) و Pooling layer نیز با کاهش تعداد ساختارهای پیچیده، عملکرد محاسباتی را بهبود می‌بخشد (Panahi et al., 2020). لایه Fully connected معمولاً در انتهای شبکه قرار می‌گیرد و هدف آن‌ها پیش‌بینی نهایی با استفاده از ویژگی‌های ورودی است. همچنین در این مطالعه از لایه dropout به منظور جلوگیری از بیش‌برازش و از لایه concatenate به منظور ادغام لایه‌ها استفاده شد.

۶.۲. الگوریتم HHO

الگوریتم HHO یک الگوریتم محاسباتی مبتنی بر جمعیت است که از رفتار گروهی شاهین‌ها برای حل مسائل بهینه‌سازی الگوبرداری کرده است. این الگوریتم که در سال ۲۰۱۹ معرفی شده در مطالعات مختلفی به کار گرفته است (Zhang et al., 2022; Tinh et al., 2024; Malik et al., 2021). همان‌طور که از اسم آن مشخص است این الگوریتم بر پایه شکار طعمه (خرگوش) توسط شاهین هریس مدل‌سازی شده است. بهترین راه‌حل انتخابی در هر مرحله به عنوان طعمه موردنظر انتخاب می‌شود. پیاده‌سازی این الگوریتم مطابق زیر و طی چند مرحله انجام می‌شود. مرحله اول شامل شناسایی طعمه توسط شاهین‌های هریس با دو استراتژی مختلف می‌باشد که به صورت ریاضی در زیر مدل شده است (Heidari et al., 2019):

$$X(it+1) = \begin{cases} X_{rand}(it) - r_1|X_{rand}(it) - 2r_2X(it) & \text{if } q \geq 0.5 \\ (X_{rabbit}(it) - X_m(it)) - r_3(LB + r_4(UB - LB)) & \text{if } q < 0.5 \end{cases} \quad \text{رابطه ۵}$$

در اینجا، $X_{rabbit}(it)$ موقعیت خرگوش، $X(it)$ موقعیت شاهین، LB حد پایین، UB حد بالا، $X_{rand}(it)$ شاهین انتخاب شده به صورت تصادفی، $X_m(it)$ میانگین موقعیت جمعیت شاهین ها و همچنین r_1, r_2, r_3, r_4 نیز اعداد تصادفی در بازه صفر تا یک می باشند. میانگین موقعیت شاهین ها با استفاده از معادله زیر قابل محاسبه می باشد:

$$X_m(it) = \frac{1}{N} \sum_{i=1}^N X_i(it) \quad \text{رابطه ۶}$$

انرژی طعمه در حین فرار به مرور زمان روند کاهشی پیدا می کند که می توان آن را به صورت زیر محاسبه کرد (Heidari et al., 2019):

$$E = 2E_0 \left(1 - \frac{it}{T}\right) \quad \text{رابطه ۷}$$

در اینجا، E_0 انرژی اولیه و T نیز نشان دهنده حداکثر تکرار می باشد.

مرحله آخر، محاصره طعمه می باشد که به دلیل فرار انرژی خود را از دست داده است. برای این فاز دو نوع محاصره داریم:

$$X(it+1) = \Delta X(it) - E|X_{rabbit}(it) - X(it)| \quad \text{محاصره نرم:}$$

$$\Delta X(it) = X_{rabbit}(it) - X(it) \quad \text{رابطه ۸}$$

برای محاصره سخت نیز طبق معادله زیر می توان مدل سازی کرد:

$$X(it+1) = X_{rabbit}(it) - E|\Delta X(it)| \quad \text{رابطه ۹}$$

۷.۲. معیارهای ارزیابی مدل

در این مطالعه به منظور ارزیابی عملکرد مدل ترکیبی CNN-HHO از چندین روش آماری مختلف شامل MAE، RMSE، Sensitivity، Specificity و Accuracy استفاده شد (جدول ۴). معادلات (۱۰)، (۱۱)، (۱۲) و (۱۳) نحوه محاسبه این پارامترها را نشان می دهد. TP نشان دهنده تعداد پیکسل هایی است که مدل به درستی به عنوان سیل کلاس بندی کرده است، TN نشان دهنده نواحی است که مدل به درستی پیش بینی کرده که سیل اتفاق نمی افتد، FP نشان دهنده این است که مدل به اشتباه یک منطقه را به عنوان وقوع سیل کلاس بندی کرده است و FN نیز نشان دهنده پیکسل هایی است که مدل به اشتباه به عنوان عدم وقوع سیل کلاس بندی کرده است (Khosravi et al., 2019).

$$Sensitivity = \frac{TP}{TP+FN} \quad \text{رابطه ۱۰}$$

$$Specificity = \frac{TN}{TN+FP} \quad \text{رابطه ۱۱}$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad \text{رابطه ۱۲}$$

مقادیر ۰/۸-۰/۹ نشان دهنده عملکرد خیلی خوب و مقدار بین ۰/۹-۱ نشان دهنده عملکرد فوق العاده مدل به کار رفته است.

به علاوه در این مطالعه، به منظور ارزیابی مدل های ترکیبی جدید به کار رفته از دو شاخص RMSE و MAE نیز استفاده شد که معادلات آنها به صورت زیر است:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_p - Z_a)^2} \quad \text{رابطه ۱۳}$$

$$MAE = \sqrt{\frac{1}{n} \sum_{i=1}^n |Z_p - Z_a|} \quad \text{رابطه ۱۴}$$

در اینجا، Z_p و Z_a به ترتیب نشان دهنده مقدار پیش بینی، مقدار واقعی و تعداد نمونه ها می باشد (Ramayanti et al., 2022). مقدار پیش بینی شده نیز همان مقادیری است که الگوریتم پیش بینی نموده است. مقدار واقعی همان مقادیر واقعی

می‌باشد که به‌عنوان دیتا صحت‌سنجی وارد الگوریتم شد. این دو پارامتر همواره موردتوجه پژوهش‌گران به‌منظور ارزیابی عملکرد الگوریتم‌های هوشمند در موضوعات مختلف بوده است (Paryani et al., 2022; Pourghasemi et al., 2020).

۸.۲. منحنی مشخصه عملکرد سیستم (ROC)

منحنی ROC یک ابزار گرافیکی است که به‌منظور ارزیابی عملکرد مدل به‌کار می‌رود (Shahabi et al., 2021). محور X نشان‌دهنده نرخ مثبت کاذب و محور Y نیز نشان‌دهنده نرخ مثبت واقعی است. در تفسیر این روش، از مساحت زیر سطح نمودار استفاده می‌شود. هرچه مقدار این مقدار به یک نزدیک‌تر باشد نشان‌دهنده عملکرد بهتر مدل در پیش‌بینی است (Miraki et al., 2019). به‌طور کلی، مقدار زیر سطح نمودار از معادله زیر قابل محاسبه می‌باشد (شکل ۴):

$$\frac{TP}{TP+FN} = TPR \quad \text{رابطه ۱۵}$$

$$\frac{FP}{FP+TN} = FPR \quad \text{رابطه ۱۶}$$

Table 4. Model performance

No	Evaluation metrics	CNN-HHO
1	True positive	42
2	True negative	45
3	False positive	2
4	False negative	5
5	Sensitivity	89.4
6	Specificity	95.7
7	Accuracy	92.55
8	AUC	95.9
9	RMSE	0.277
10	MAE	0.165




Figure 4. Test error plot

۳. نتایج

در این پژوهش با استفاده از چندین رفرنس مختلف و معتبر، ۱۱۰ نقطه برای آموزش و ۴۷ نقطه برای صحت‌سنجی انتخاب شد. همچنین نه فاکتور مؤثر بر وقوع سیل در منطقه مورد مطالعه را در نظر گرفتیم که در بخش آماده‌سازی دیتا به‌طور کامل توضیح داده شد. به‌منظور پیاده‌سازی مدل‌های ترکیبی در این پژوهش، از محیط برنامه‌نویسی پایتون استفاده شد. همچنین از دو شاخص مهم RMSE و MAE به‌منظور برآورد عملکرد مدل به‌کاررفته در آموزش شبکه و پیش‌بینی مقادیر واقعی نیز استفاده شد. هرچه مقدار مقادیر این دو پارامتر به صفر نزدیک‌تر باشد نشان‌دهنده عملکرد بهتر مدل است. این دو شاخص با مقایسه بین مقدار پیش‌بینی و مقدار واقعی قدرت عملکرد شبکه را در پیش‌بینی نشان

می‌دهد (شکل ۴). نتایج مشخص کرد الگوریتم ترکیبی CNN-HHO ($RMSE=0/277$ و $MAE=0/165$) عملکرد بسیار خوبی در پیش‌بینی مناطق حساس به سیل داشته است (جدول ۴).

۱.۳. تولید نقشه حساسیت سیل

در این مرحله مقادیر پیش‌بینی شده از محیط پایتون به نرم‌افزار ArcMap 10.5 انتقال داده شد تا نقشه‌های تولید شده طبقه‌بندی شود. شکل (۵) نقشه تولید شده با استفاده از الگوریتم CNN-HHO را نشان می‌دهد. همان‌طور که مشخص است به پنج کلاس خیلی کم، کم، متوسط، زیاد و خیلی زیاد تقسیم‌بندی شده است. این که از چه روشی برای طبقه‌بندی نقشه حساسیت استفاده کنیم بستگی به عوامل مختلفی داشته و روش قطعی وجود ندارد. در این مطالعه همه روش‌های کلاس‌بندی شامل Equal Interval، Natural Breaks، Quantile، Geometrical Interval امتحان شد و در نهایت روش Qauntile انتخاب شد، زیرا بهترین عملکرد را از خود نشان داد. هم‌چنین شکل (۶)، درصد پوشش تعداد پیکسل‌های هر کلاس را نشان می‌دهد. کلاس خیلی زیاد ۲۰/۰۷ درصد از منطقه را پوشش می‌دهد. هم‌چنین کلاس خیلی کم با مقدار ۱۷/۱۹ درصد کم‌ترین پوشش را دارد.




Figure 5. Flood susceptibility map




Figure 6. Percentage of classes

همان‌طور که پیش‌تر گفته شد در این پژوهش انواع شاخص‌های آماری به‌منظور ارزیابی دقیق مدل ترکیبی استفاده شد. جدول (۴) نتایج سه شاخص sensitivity، specificity و accuracy را نشان می‌دهد. Sensitivity و specificity به‌ترتیب نشان‌دهنده توانایی الگوریتم در شناسایی موارد مثبت واقعی و موارد منفی واقعی است. نتایج به‌دست‌آمده نشان می‌دهد که Sensitivity و Specificity به‌ترتیب مقادیر ۸۹/۴ و ۹۵/۷ را به خود اختصاص داده‌اند. برای شاخص Accuracy نیز نتایج مقدار ۹۲/۵۵ را نشان می‌دهد که حاکی از عملکرد بسیار خوب مدل در دقت کلاس‌بندی منطقه مورد مطالعه می‌باشد. شکل (۶)، سطح زیر نمودار ROC را نشان می‌دهد. همان‌طور که مشخص است مقدار سطح زیر نمودار ۹۵/۹ درصد می‌باشد. همان‌طور که گفته شد هرچه قدر سطح زیر نمودار بزرگ‌تر باشد (فاصله بیش‌تری از خط رفرنس داشته باشد) نشان‌دهنده عملکرد بهتر مدل در پیش‌بینی است. مقدار به‌دست‌آمده حاکی از عملکرد فوق‌العاده مدل CNN-HHO دارد.




Figure 6. ROC curve

۴. بحث

تمامی مدل‌های به‌کاررفته در پژوهش‌های مختلف دارای مزایا و معایبی هستند. این موضوع باعث می‌شود تا پژوهش‌گران مدل‌ها و ترکیب‌های جدیدی را توسعه دهند تا نقشه‌های واقع‌گرایانه و کاربردی‌تر تولید کنند. در این پژوهش از روش قدرتمند یادگیری عمیق CNN و ترکیب آن با الگوریتم HHO استفاده شد. از مزایای روش‌های یادگیری عمیق مانند CNN می‌توان به توانایی آن‌ها در کشف ساختارهای پیچیده، قدرت بالا در استخراج ویژگی‌های داده‌ها و آموزش در سطح بالا به‌وسیله حجم زیادی از دیتا اشاره کرد (Sagi and Rokach, 2018; Romero *et al.*, 2015). این دو روش در پژوهش‌های مختلفی به‌کاررفته و عملکرد بسیار خوبی از خود نشان داده است. برای مثال، Youssef *et al.* (2022) از یادگیری عمیق CNN و مقایسه آن با روش سنتی یادگیری ماشین SVM استفاده نمودند. نتایج آن‌ها نشان داد CNN نسبت به SVM برتری داشته و نقشه‌های حساسیت سیل دقیق‌تری تولید می‌کند. در مطالعه‌ای دیگر (Fang *et al.*, 2020) الگوریتم CNN را با روش‌های SVM، RF و LR مقایسه نموده‌اند. آن‌ها گزارش نمودند که الگوریتم CNN بر دیگر روش‌های یادگیری ماشین برتری دارد. همچنین آن‌ها نشان دادند ترکیب CNN با دیگر الگوریتم‌ها باعث بهبود نتایج می‌شود. همچنین برخی از پژوهش‌گران CNN را با الگوریتم‌های فراابتکاری ترکیب نموده و به این نتایج دست یافته‌اند. برای مثال، Hakim *et al.* (2022) با استفاده از CNN و

ترکیب آن با الگوریتم‌های فراابتکاری GWO و ICA گزارش نمودند که مدل ترکیبی عملکرد بهتری در مقابل CNN دارد. به بیان دیگر، ترکیب یادگیری عمیق با الگوریتم‌های فراابتکاری شبکه‌ای قدرتمندتر می‌سازد. نتایج این مطالعه نیز مشخص کرد ترکیب CNN با الگوریتم فراابتکاری HHO عملکرد فوق‌العاده‌ای دارد به‌طوریکه مقدار سطح زیر نمودار ROC برابر ۹۵/۹ درصد به‌دست آمد.

۱.۴. بررسی نقشه‌های حساسیت تولیدشده

همان‌طور که بر روی نقشه مشخص است از بین مناطق ۲۲ گانه تهران، مناطق ۱، ۲، ۳، ۴، ۵ و ۸ آسیب‌پذیرتر از مناطق دیگر هستند (شکل ۳). ما دو کلاس حساسیت خیلی زیاد و زیاد را مینا قرار دادیم زیرا مناطق بحرانی‌تر در اولویت قرار دارند. البته این نکته نباید فراموش شود که تاریخچه سیل‌ها نشان داده است که شروع این فاجعه از رود دره‌های شمال تهران است. بنابراین اگر بخواهیم اولویت‌بندی کنیم شمال مناطق یک، دو، پنج و ۲۲ اولین مواجهه با سیل را خواهند داشت. این ناحیه دقیقاً مرز بین کوه‌های شمال شهر با شهر است. سابقه سیل‌های رخ داده نیز نشان داده است که ابتدا در رود دره‌های شمال شهر جریان آب حرکت کرده و پس از آن به پایین‌دست جاری شده است. شمال غرب تهران نیز که بخش وسیعی از آن را کن و حصارک تشکیل می‌دهد از جمله مناطقی است که بسیار آسیب‌پذیر است. همچنین براساس نتایج، شمال و شمال‌شرق نیز پتانسیل بالایی دارند. این مناطق شامل رود دره‌های دربند و گلاب‌دره، درکه، ولنجک و دارآباد می‌باشد. از سیل‌های رخ داده در این محدوده می‌توان به سیل سال ۱۳۶۶ میدان تجریش اشاره نمود که با تلفات جانی و مالی سنگینی همراه بود. اگرچه طی سال‌های اخیر سیل در این مناطق گزارش نشده است، اما اطلاعات ثبت‌شده مربوط به دبی جریان آب در برخی از رودخانه‌ها که با استفاده از ایستگاه‌های هیدرومتری انجام گرفته است نشان‌دهنده طغیان آب در هنگام بارش‌های شدید است. عدم لایه‌روبی رودخانه‌ها و یا مسدودشدن رودخانه‌ها توسط اجسام خارجی منجر به یک فاجعه خواهد شد. به‌علاوه، نتایج نشان داد رودخانه‌ها و مسیرهای شهر تهران کاملاً آسیب‌پذیر بوده و احتمال طغیان آن‌ها هنگام بارش‌های شدید و ناگهانی وجود دارد. همچنین تراکم جمعیتی بالا در اطراف رودخانه‌ها و همچنین ساخت‌وسازهای غیراصولی و غیرمجاز در مسیر مسیرها از دیگر عواملی است که نشان می‌دهد در صورت بروز یک سیل ناگهانی شدید در آینده با یک فاجعه روبه‌رو خواهیم بود. نقشه تولیدشده می‌تواند به‌عنوان یک ابزار کاربردی در اختیار برنامه‌ریزان، مدیران شهری و مهندسان قرار گیرد تا با آگاهی بیش‌تری تصمیم‌گیری نمایند. با توجه به مناطق حساس به وقوع سیل‌های ناگهانی در کلان‌شهر تهران، باید تدابیر و تصمیم‌های مهم و لازم را قبل از وقوع فاجعه و بعد از آن اتخاذ نمود که این امر با استفاده از نقشه حساسیت سیل امکان‌پذیر است.

۵. نتیجه‌گیری

یکی از وظایف تصمیم‌گیران دانش کافی و آگاهی داشتن از مناطق در معرض سیل به‌منظور جلوگیری از تکرار حوادث گذشته در آینده است. نقشه حساسیت سیل یک ابزار کاربردی است که تا در افزایش این آگاهی نقش بسیار مهمی دارد. در این پژوهش روش قدرتمند یادگیری عمیق CNN با الگوریتم HHO ترکیب شد تا یک نقشه سیل برای کلان‌شهر تهران با دقت بالا تولید شود. در ادامه عملکرد مدل با استفاده از چندین شاخص آماری شامل MAE، RMSE، Accuracy، Specificity، Sensitivity و ROC ارزیابی شد و درنهایت مشخص شد CNN-HHO دارای عملکرد عالی می‌باشد. نتایج این مطالعه می‌تواند به‌عنوان یک پژوهش جامع در اختیار سازمان‌های مربوطه قرار گرفته و به‌عنوان ابزاری ارزشمند جهت مدیریت سیل به‌کار رود. همچنین آگاهی از مناطقی که احتمال وقوع سیل در آن‌ها وجود دارد می‌تواند

منجر به پیاده‌سازی سیستم‌های جمع‌آوری آب شود. این مهم علاوه بر این که از گسترش سیل جلوگیری می‌کند، می‌تواند حجم زیادی از آب را جمع‌آوری کند. مطالعه حاضر نشان داد مدل ترکیبی به کاررفته می‌تواند در مناطق دیگر نیز مورد استفاده قرار گیرد. پیشنهاد می‌شود که در مطالعات آینده از آن استفاده شده و با روش‌های جدید مقایسه شود.

۶. پی‌نوشت‌ها

1. Topographic Wetness Index
2. Stepwise Weight Assessment Ratio Analysis

۷. تشکر و قدردانی

صمیمانه از شرکت مدیریت منابع آب ایران به‌خاطر حمایت مالی از این پروژه، تشکر و قدردانی می‌گردد.

۸. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۹. منابع

- Afsari, R., Nadizadeh Shorabeh, S., Kouhnavard, M., Homaei, M., & Arsanjani, J. J. (2022). A spatial decision support approach for flood vulnerability analysis in urban areas: A case study of Tehran. *ISPRS International Journal of Geo-Information*, 11(7), 380.
- Al-Kindi, K. M., & Alabri, Z. (2024). Investigating the role of the key conditioning factors in flood susceptibility mapping through machine learning approaches. *Earth Systems and Environment*, 8(1), 63-81.
- Arabameri, A., Seyed Danesh, A., Santosh, M., Cerda, A., Chandra Pal, S., Ghorbanzadeh, O., Roy, P., & Chowdhuri, I. (2022). Flood susceptibility mapping using meta-heuristic algorithms. *Geomatics, Natural Hazards and Risk*, 13(1), 949-974.
- Arora, A., Pandey, M., Siddiqui, M. A., Hong, H., & Mishra, V. N. (2021). Spatial flood susceptibility prediction in Middle Ganga Plain: comparison of frequency ratio and Shannon's entropy models. *Geocarto International*, 36(18), 2085-2116.
- Bordbar, M., Aghamohammadi, H., Pourghasemi, H. R., & Azizi, Z. (2022). Multi-hazard spatial modeling via ensembles of machine learning and meta-heuristic techniques. *Scientific Reports*, 12(1), 1451.
- Cao, C., Xu, P., Wang, Y., Chen, J., Zheng, L., & Niu, C. (2016). Flash flood hazard susceptibility mapping using frequency ratio and statistical index methods in coalmine subsidence areas. *Sustainability*, 8(9), 948.
- Costache, R., Țincu, R., Elkhachy, I., Pham, Q.B., Popa, M.C., Diaconu, D.C., Avand, M., Costache, I., Arabameri, A., & Bui, D.T. (2020). New neural fuzzy-based machine learning ensemble for enhancing the prediction accuracy of flood susceptibility mapping. *Hydrological Sciences Journal*, 65(16), 2816-2837.
- Dano, U.L., Balogun, A.L., Matori, A.N., Wan Yusouf, K., Abubakar, I.R., Said Mohamed, M.A., Aina, Y.A., & Pradhan, B. (2019). Flood susceptibility mapping using GIS-based analytic network process: A case study of Perlis, Malaysia. *Water*, 11(3), 615.
- Fang, Z., Wang, Y., Peng, L., & Hong, H. (2020). Integration of convolutional neural network and conventional machine learning classifiers for landslide susceptibility mapping. *Computers & Geosciences*, 139, 104470.
- Fu, S., Lyu, H., Wang, Z., Hao, X., & Zhang, C. (2022). Extracting historical flood locations from news media data by the named entity recognition (NER) model to assess urban flood susceptibility. *Journal of Hydrology*, 612, 128312.
- Ghiasi, V., Ghasemi, S. A. R., & Yousefi, M. (2021). Landslide susceptibility mapping through continuous fuzzification and geometric average multi-criteria decision-making approaches. *Natural Hazards*, 107(1), 795-808.

- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
- Hakim, W. L., Rezaie, F., Nur, A. S., Panahi, M., Khosravi, K., Lee, C. W., & Lee, S. (2022). Convolutional neural network (CNN) with metaheuristic optimization algorithms for landslide susceptibility mapping in Icheon, South Korea. *Journal of environmental management*, 305, 114367.
- Hashemkhani Zolfani, S., Yazdani, M., & Zavadskas, E. K. (2018). An extended stepwise weight assessment ratio analysis (SWARA) method for improving criteria prioritization process. *Soft Computing*, 22, 7399-7405.
- Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019). Harris hawks optimization: Algorithm and applications. *Future generation computer systems*, 97, 849-872.
- Keršulienė, V., Zavadskas, E. K., & Turskis, Z. (2010). Selection of rational dispute resolution method by applying new step-wise weight assessment ratio analysis (SWARA). *Journal of business economics and management*, 11(2), 243-258.
- Khosravi, K., Pham, B.T., Chapi, K., Shirzadi, A., Shahabi, H., Revhaug, I., Prakash, I., & Bui, D.T. (2018). A comparative assessment of decision trees algorithms for flash flood susceptibility modeling at Haraz watershed, northern Iran. *Science of the Total Environment*, 627, 744-755.
- Khosravi, K., Shahabi, H., Pham, B.T., Adamowski, J., Shirzadi, A., Pradhan, B., Dou, J., Ly, H.B., Gróf, G., Ho, H.L., & Hong, H. (2019). A comparative assessment of flood susceptibility modeling using multi-criteria decision-making analysis and machine learning methods. *Journal of Hydrology*, 573, 311-323.
- Li, Y., Osei, F. B., Hu, T., & Stein, A. (2023). Urban flood susceptibility mapping based on social media data in Chengdu city, China. *Sustainable Cities and Society*, 88, 104307.
- Liuzzo, L., Sammartano, V., & Freni, G. (2019). Comparison between different distributed methods for flood susceptibility mapping. *Water Resources Management*, 33, 3155-3173.
- Malik, A., Tikhamarine, Y., Sammen, S. S., Abba, S. I., & Shahid, S. (2021). Prediction of meteorological drought by using hybrid support vector regression optimized with HHO versus PSO algorithms. *Environmental Science and Pollution Research*, 28, 39139-39158.
- Miraki, S., Zanganeh, S. H., Chapi, K., Singh, V. P., Shirzadi, A., Shahabi, H., & Pham, B. T. (2019). Mapping groundwater potential using a novel hybrid intelligence approach. *Water resources management*, 33, 281-302.
- Panahi, M., Sadhasivam, N., Pourghasemi, H. R., Rezaie, F., & Lee, S. (2020). Spatial prediction of groundwater potential mapping based on convolutional neural network (CNN) and support vector regression (SVR). *Journal of Hydrology*, 588, 125033.
- Paryani, S., Neshat, A., Pourghasemi, H. R., Ntona, M. M., & Kazakis, N. (2022). A novel hybrid of support vector regression and metaheuristic algorithms for groundwater spring potential mapping. *Science of The Total Environment*, 807, 151055.
- Paryani, S., Bordbar, M., Jun, C., Panahi, M., Bateni, S.M., Neale, C.M., Moeini, H., & Lee, S. (2023). Hybrid-based approaches for the flood susceptibility prediction of Kermanshah province, Iran. *Natural Hazards*, 116(1), 837-868.
- Paul, G. C., Saha, S., & Hembram, T. K. (2019). Application of the GIS-based probabilistic models for mapping the flood susceptibility in Bansloi sub-basin of Ganga-Bhagirathi river and their comparison. *Remote Sensing in Earth Systems Sciences*, 2, 120-146.
- Pamučar, D., Ecer, F., Cirovic, G., & Arlasheedi, M. A. (2020). Application of improved best worst method (BWM) in real-world problems. *Mathematics*, 8(8), 1342.
- Prasad, P., Loveson, V. J., Das, B., & Kotha, M. (2022). Novel ensemble machine learning models in flood susceptibility mapping. *Geocarto International*, 37(16), 4571-4593.
- Pham, B.T., Jaafari, A., Van Phong, T., Yen, H.P.H., Tuyen, T.T., Van Luong, V., Nguyen, H.D., Van Le, H., & Foong, L.K. (2021). Improved flood susceptibility mapping using a best first decision tree integrated with ensemble learning techniques. *Geoscience Frontiers*, 12(3), 101105.
- Ramayanti, S., Nur, A. S., Syifa, M., Panahi, M., Achmad, A. R., Park, S., & Lee, C. W. (2022). Performance comparison of two deep learning models for flood susceptibility map in Beira area, Mozambique. *The Egyptian Journal of Remote Sensing and Space Science*, 25(4), 1025-1036.
- Romero, A., Gatta, C., & Camps-Valls, G. (2015). Unsupervised deep feature extraction for remote sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 54(3), 1349-1362.

- Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 8(4), e1249.
- Saravanan, S., Abijith, D., Reddy, N. M., Parthasarathy, K. S. S., Janardhanam, N., Sathiyamurthi, S., & Sivakumar, V. (2023). Flood susceptibility mapping using machine learning boosting algorithms techniques in Idukki district of Kerala India. *Urban Climate*, 49, 101503.
- Sarçın, B., Alaboz, P., Karaca, S., & Dengiz, O. (2024). Pythagorean fuzzy SWARA weighting technique for soil quality modeling of cultivated land in semi-arid terrestrial ecosystems. *Computers and Electronics in Agriculture*, 227, 109466.
- Shahabi, H., Shirzadi, A., Ronoud, S., Asadi, S., Pham, B.T., Mansouripour, F., Geertsema, M., Clague, J.J., & Bui, D.T. (2021). Flash flood susceptibility mapping using a novel deep learning model based on deep belief network, back propagation and genetic algorithm. *Geoscience Frontiers*, 12(3), 101100.
- Songchon, C., Wright, G., & Beevers, L. (2021). Quality assessment of crowdsourced social media data for urban flood management. *Computers, Environment and Urban Systems*, 90, 101690.
- Swain, K. C., Singha, C., & Nayak, L. (2020). Flood susceptibility mapping through the GIS-AHP technique using the cloud. *ISPRS International Journal of Geo-Information*, 9(12), 720.
- Tellman, B., Sullivan, J.A., Kuhn, C., Kettner, A.J., Doyle, C.S., Brakenridge, G.R., Erickson, T.A., & Slayback, D.A. (2021). Satellite imaging reveals increased proportion of population exposed to floods. *Nature*, 596(7870), 80-86.
- Tinh, L. D., Thao, D. T. P., Bui, D. T., & Trong, N. G. (2024). Integrating Harris Hawks optimization and TensorFlow deep learning for flash flood susceptibility mapping using geospatial data. *Earth Science Informatics*, 1-16.
- Ullah, K., Wang, Y., Fang, Z., Wang, L., & Rahman, M. (2022). Multi-hazard susceptibility mapping based on Convolutional Neural Networks. *Geoscience Frontiers*, 13(5), 101425.
- Vilasan, R. T., & Kapse, V. S. (2022). Evaluation of the prediction capability of AHP and F-AHP methods in flood susceptibility mapping of Ernakulam district (India). *Natural Hazards*, 112(2), 1767-1793.
- Vojtek, M., & Vojteková, J. (2019). Flood susceptibility mapping on a national scale in Slovakia using the analytical hierarchy process. *Water*, 11(2), 364.
- Wang, R., Lu, S., & Li, Q. (2019). Multi-criteria comprehensive study on predictive algorithm of hourly heating energy consumption for residential buildings. *Sustainable Cities and Society*, 49, 101623.
- Wang, Y., Hong, H., Chen, W., Li, S., Panahi, M., Khosravi, K., Shirzadi, A., Shahabi, H., Panahi, S., & Costache, R. (2019). Flood susceptibility mapping in Dingnan County (China) using adaptive neuro-fuzzy inference system with biogeography based optimization and imperialistic competitive algorithm. *Journal of environmental management*, 247, 712-729.
- Wang, Y., Fang, Z., Hong, H., & Peng, L. (2020). Flood susceptibility mapping using convolutional neural network frameworks. *Journal of hydrology*, 582, 124482. https://fa.wikipedia.org/wiki/%D8%B3%DB%8C%D9%84_%DB%B1%DB%B3%DB%B6%DB%B6_%D8%AA%D8%AC%D8%B1%DB%8C%D8%B4
- Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, 9, 611-629.
- Yariyan, P., Avand, M., Abbaspour, R.A., Torabi Haghighi, A., Costache, R., Ghorbanzadeh, O., Janizadeh, S., & Blaschke, T. (2020). Flood susceptibility mapping using an improved analytic network process with statistical models. *Geomatics, Natural Hazards and Risk*, 11(1), 2282-2314.
- Youssef, A. M., Pradhan, B., Dikshit, A., & Mahdi, A. M. (2022). Comparative study of convolutional neural network (CNN) and support vector machine (SVM) for flood susceptibility mapping: a case study at Ras Gharib, Red Sea, Egypt. *Geocarto International*, 37(26), 11088-11115.
- Zhang, H., Nguyen, H., Bui, X. N., Pradhan, B., Asteris, P. G., Costache, R., & Aryal, J. (2022). A generalized artificial intelligence model for estimating the friction angle of clays in evaluating slope stability using a deep neural network and Harris Hawks optimization algorithm. *Engineering with Computers*, 1-14.
- Zhang, P., Jia, Y., & Shang, Y. (2022). Research and application of XGBoost in imbalanced data. *International Journal of Distributed Sensor Networks*, 18(6), 15501329221106935.