

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

چکیده

پیش بینی مناطق در معرض خطر سیل به منظور مدیریت بهتر بحران از جمله اقداماتی است که طی سال های اخیر مورد توجه پژوهشگران قرار گرفته است. هدف از مطالعه حاضر، ارائه یک روش ترکیبی جدید و قدرتمند جهت پیش بینی مناطق حساس به سیل می باشد در شهر تهران می باشد. برای این منظور روش یادگیری عمیق CNN با الگوریتم قدرتمند HHO ترکیب شد. با استفاده از دادههای تاریخی سیلابها، شبکه های اجتماعی و سازمانهای مرتبط، نقشهای شامل ۱۵۷ نقطه سیلاب تهیه شد. ۷۰٪ دادهها برای آموزش مدل و ۳۰٪ برای اعتبارسنجی استفاده شدند. ۹ پارامتر مؤثر (ارتفاع، شیب، بارندگی، شاخص قدرت جریان، شاخص رطوبت توپوگرافی، فاصله از رودخانه، تراکم رودخانه، سنگشناسی و کاربری اراضی) به عنوان متغیرهای مستقل انتخاب. عملکرد مدل با شاخصهای RMSE، MAE، Sensitivity، Specificity، Accuracy و سطح زیر منحنی ROC ارزیابی گردید. مقدار به دست آمده از سطح زیر نمودار ROC نشان داد مدل ترکیبی CNN-HHO با ۹۵٪ دقت فوق العاده ای در پیش بینی وقوع سیل دارد. همچنین نتایج به دست آمده از شاخص های Accuracy (۹۲/۵۵)، Specificity (۹۵/۷)، Sensitivity (۸۹/۴)، MAE (۰/۱۶۵) و RMSE (۰/۲۷۷) نیز نشان داد مدل بکار رفته عملکرد بسیار خوبی در پهنه بندی منطقه مورد مطالعه دارد. براساس نتایج، مدل ترکیبی ارائه شده در این پژوهش می تواند به عنوان روشی قدرتمند در مناطق دیگر نیز بکار گرفته شود. کلید واژه ها: نقشه حساسیت سیل، یادگیری عمیق CNN، الگوریتم HHO

مقدمه

انسان ها از دیرباز تا کنون با توجه به امکانات موجود همواره در پی راهکارهایی جهت مقابله با عواقب ناشی از فجایع طبیعی مانند سیل بوده اند. امروزه سیلاب یکی از خطرناک ترین رخدادهای طبیعی در نقاط مختلف جهان محسوب می شود که در برخی از موارد بیش تر از سایر بلایای طبیعی خسارات های مالی و جانی به همراه دارد (Arora et al, 2021). طبق برآوردها خسارات اقتصادی وارد شده در سطح جهان بین سال های ۲۰۰۰ تا ۲۰۱۹ حدوداً ۶۵۱ میلیارد (USD) می باشد (Tellman et al, 2021). همچنین از نظر انسانی آمارها نشان می دهد سیل آسیب زیادی به زندگی انسان ها وارد می کند. برای مثال در آسیا بیش از ۹۰٪ 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 مهم ترین عوامل ایجاد سیل در ایران تغییر الگوهای بارشی می باشد که ناشی از تغییرات اقلیمی است. روند افزایشی سیلاب در پنج دهه اخیر نشان می دهد تعداد سیلاب ها در دهه ۹۰ نسبت به دهه ۴۰ تقریباً ۱۲ برابر شده است (عبدی ۱۳۸۵). آمارها نشان می دهد طی یک دهه گذشته سیل تبدیل به یک معضل زیست محیطی شده است. این پدیده در کشور ایران بیش تر به علت به هم خوردن تعادل طبیعی و شرایط جغرافیایی منطقه ایجاد می گردد به طوریکه حتی بروز بارش های معمولی نیز منجر به جاری شدن سیلاب می شود (آوند و همکاران، ۱۳۹۹). سیل ها نه تنها در مناطق برون شهری بلکه در مناطق شهری نیز خسارات زیادی وارد می کنند. برای مثال، وقوع بارش های شدید در فروردین ۹۸ موجب جاری شدن سیل در ۲۵ استان ایران از جمله ۲۰۰ شهر و بیش از ۴۳۰۰ روستا شد. طبق برآورد های انجام شده علاوه بر زیان مالی بین ۳۰ تا ۳۵ هزار میلیارد تومانی، بیش از ۵۰ مورد نیز تلفات انسانی در پی داشته است. همچنین طی

سال های گذشته حدوداً ۷۰ درصد اعتبارهای سالانه طرح کاهش اثرهای بلایای طبیعی و ستاد حوادث غیر مترقبه صرف جبران خسارت های ناشی از سیل شده است (چراغی و همکاران، ۱۳۹۹).

پهنه بندی منطقه مورد مطالعه با استفاده از سیستم اطلاعات جغرافیایی و سنجش از دور یک راه بسیار کاربردی جهت پیش بینی است. نقشه حساسیت سیل ابزاری است که محدوده سیل و پراکنش آن را با دقت نشان می دهد بنابراین توسعه آنها به منظور کنترل سیل یک امر ضروری است (Saravanan et al, 2023). با کمک این نقشه ها می توان اقدامات پیشگیرانه قبل از سیل و همچنین عملیات های 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 به منظور پتانسیل یابی 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 می تواند به عنوان ابزاری مهم در اختیار تصمیم گیران قرار گیرد تا از خسارات و تلفات احتمالی در آینده جلوگیری شود.

منطقه مورد مطالعه

شهر تهران با مساحت حدوداً 730 KM^2 و جمعیتی در حدود ۹.۴ میلیون نفر پرجمعیت ترین و بزرگترین شهر غرب آسیا و ۲۴ امین شهر پرجمعیت جهان می باشد (ویکی پدیا) (شکل ۱). این شهر که در دامنه های جنوبی رشته کوه البرز واقع شده با طول جغرافیایی $51^\circ 6'$ تا $51^\circ 38'$ و عرض جغرافیایی $35^\circ 34'$ تا $35^\circ 51'$ پایتخت کشور ایران می باشد. ارتفاع آن از سطح دریا حدوداً ۱۰۱۶ متر برای جنوب شهر و ۱۸۰۰ متر برای شمال شهر می باشد. همچنین بلندترین نقطه، قله توچال با ارتفاع ۳۹۰۰ متر می باشد که در ارتفاعات شمال شهر واقع شده است. بخش شمالی به دلیل اینکه تحت تاثیر 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 تاثیر 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 غیر علمی شهرسازی مانند اشغال حریم آبراهه ها و مسیل ها و همچنین عدم لایه روبی رودخانه ها از عوامل موثر 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	64
1955	Kan Area	65
1981	Kan Area	
1987	Tajrish-Darband	66
2012	Kan River	
2015	Kan River	67
2022	Imamzadeh Davood	68

آگاهی از سیل های گذشته به منظور پیش بینی سیل های 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 داده های ماهواره ای استفاده نشد. یکی دیگر از دلایل عدم استفاده از تصاویر ماهواره ای در این پژوهش این است که برخی از سیل ها زمانی رخ داده که هنوز ماهواره ای نظارتی ساخته نشده بود مانند سیل های ۱۳۳۳ محدوده فرحزاد و شمال غرب تهران، سیل ۱۳۳۴ محدوده کن و سیل مرداد ماه سال ۱۳۶۶ میدان تجریش. بنابراین در این مطالعه از داده های سازمان مدیریت منابع آب ایران، تاریخچه سیل های ثبت شده و اطلاعات منتشر شده در شبکه های اجتماعی استفاده شد. استفاده از گزارش های شبکه های اجتماعی یکی از روش های استخراج داده های مورد نیاز مربوط به یک فاجعه می باشد که در بسیاری از مطالعات مورد توجه پژوهشگران قرار گرفته است (Fu et al; 2022; Songchon et al, 2021). بعلاوه در این مطالعه از نرم افزار Google Earth نیز استفاده شد تا استخراج نمونه ها با دقت بیشتر انجام شود. نمونه ها شامل سیل های ناگهانی است که طی یک قرن اخیر در شهر تهران رخ داده است. پس از آماده سازی، داده ها به دو گروه تقسیم بندی شد. یکی از گروه ها که شامل ۷۰٪ نمونه ها می باشد برای آموزش مدل و ۳۰٪ باقی مانده نیز برای صحت سنجی مدل انتخاب شد. بعلاوه، به صورت تصادفی ۱۵۷ نقطه غیر سیل نیز در منطقه مطالعه انتخاب شد و به طور مشابه با داده های سیل به دو گروه ۳۰/۷۰ گروه بندی شد. شکل ۲ روند انجام این پژوهش را نشان می دهد.




Figure 2. Flowchart

براساس ویژگی های سیل های گذشته، دیتاهای در دسترس و همچنین بررسی پژوهش های گذشته (Li et al, 2023; Yariyan et al, 2020; Shahabi et al, 2021; Costache et al, 2020)، نه عامل موثر 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 سازمان های مدیریت منابع آب، وزارت نیرو و سازمان هواشناسی گرفته شد. به علاوه به منظور صحت سنجی و آپدیت رودخانه ها و مسیل های سطح شهر و کاربری اراضی از Google Earth Pro استفاده شد. همه مراحل شامل ایجاد پایگاه داده، تولید لایه ها و نقشه های خروجی در نرم افزار ArcGIS 10.5 انجام شد. جدول ۲ مشخصات داده های بکار رفته در این پژوهش را نشان می دهد.







Table 2. Dataset used in this study

Type	Factor	GIS type	101
Topographic	Elevation (m)	Raster	102
	Slope angle (°)	Raster	
Water-related	Distance to river (m)	Shapefile-Line	103
	SPI	Raster	
	TWI	Raster	104
	River density (Km/Km^2)	Shapefile-Line	
Land cover	Rainfall (mm)	Shapefile-Point	105
	Land use	Shapefile-Polygon	106
	Lithology	Shapefile-Polygon	
Flood records	Flood records	Shapefile-Point	107

ارتفاع در مناطق کوهستانی یکی از پارامترهای تاثیر گذار در وقوع سیل است. با کاهش ارتفاع زمین هموارتر شده و احتمال وقوع سیل نیز افزایش می یابد (Vojtek and Vojteková, 2019). شیب به عنوان یه پارامتر مهم و تاثیر گذار در پژوهش های مختلف همواره بکار رفته است (Cao et al, 2016; Pham et al, 2021) زیرا رواناب از مناطقی با شیب زیاد به سمت مناطقی با شیب کم جریان می یابد (Wang et al, 2020). بارندگی یکی از مهم ترین عوامل موثر بر وقوع سیل است. بارندگی شدید می تواند در یک بازه زمانی کوتاه به راحتی باعث وقوع یک سیل ناگهانی شده به طوریکه، با افزایش شدت آن احتمال وقوع این خطر نیز افزایش می یابد (Ma et al, 2021). در این پژوهش به منظور انجام یک مدل سازی واقع گرایانه از میانگین بارش سال هایی استفاده شد

115 که سیل های ناگهانی رخ داده است. برای این منظور از داده های آماری ایستگاه های سینوپتیک و بارانسنجی سازمان هواشناسی و
116 وزارت نیرو استفاده شد. شاخص قدرت جریان نشان دهنده قدرت فرسایشی رواناب سطحی است که همواره به عنوان یک فاکتور
117 مهم در پیش بینی سیل بکار رفته است (Liuzzo et al, 2019; Vilasan and Kapse, 2022). این پارامتر به خصوص در
118 مناطق کوهستانی که حرکت سریع رواناب و شیب های تند عامل اصلی وقوع سیل هستند به کار می رود (Al-Kindi and
119 Alabri, 2024). شاخص رطوبت توپوگرافی به دلیل اینکه با مقدار رطوبت خاک در ارتباط است همواره به عنوان یک پارامتر مهم
120 در پهنه بندی سیل مورد توجه قرار گرفته است. هرچقدر مقدار TWI¹ بیشتر باشد نشان دهنده اشباع بیشتر زمین است که می
121 تواند منجر به وقوع یک سیل ناگهانی شود (Swain et al, 2020). از آنجاییکه مناطق مجاور رودخانه بیشتر مستعد وقوع سیل
122 هستند بنابراین فاصله از رودخانه به عنوان یک فاکتور مهم و تاثیر گذار شناخته می شود (Yariyan et al, 2020). اهمیت این
123 فاکتور به خصوص در وقوع سیل های ناگهانی بسیار حائز اهمیت است. تراکم رودخانه میزان تجمع رودخانه ها را در یک واحد سطح
124 نشان می دهد (Paul et al, 2019). سنگ شناسی پارامتری است که با تاثیر گذاشتن بر تغییرات هیدرولوژیکی و تولید رسوب
125 نقش مهمی در وقوع سیل دارد (Prasad et al, 2022). یکی از دلایل افزایش وقوع سیل طی سال های اخیر، تغییر کاربری اراضی
126 است (Shahabi et al, 2021). کاملاً واضح است که این پارامتر نقش بسیار مهمی ایفا می کند. شکل ۳ لایه های تولید شده
127 پارامترهای موثر بر وقوع سیل را نشان می دهد.

¹ Topographic Wetness Index






Figure 3. Conditioning factors

روش ها

تحلیل نسبت ارزیابی وزن دهی تدریجی (SWAR)²

SWARA یکی از روش های تصمیم گیری چندمعیاره می باشد که در سال ۲۰۱۰ توسط Kersūliene و همکاران 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

² Stepwise Weight Assessment Ratio Analysis

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 بکار گرفته شد تا به عنوان داده ورودی الگوریتم استفاده شود. گرچه 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 (Keršulienė et al, 2010):

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

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:

$$K_j = S_j + 1 \quad (2)$$

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

$$W_j = \frac{X_j - 1}{K_j} \quad (3)$$

$$X_j - 1 = W_1$$

گام آخر نیز شامل نرمال سازی وزن ها می باشد. طبق معادله زیر داریم:

$$Q_j = \frac{W_j}{\sum_{j=1}^m W_j} \quad (4)$$

در اینجا، j نشان دهنده شماره هر معیار و m نیز تعداد کل معیارها می باشد.

جدول ۳ نمونه محاسبه وزن SWARA برای کلاس های پارامتر شیب را نشان می دهد. 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	0.08170
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	0.165171
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	0.098172
25.19 - 31.44	0.02	0.05	1.05	0.29	0.08	0.08173
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	0.08174

روش یادگیری عمیق شبکه عصبی کانولوشن (CNN)

CNN که یکی از شناخته شده ترین روش های یادگیری عمیق است همواره نقش مهمی در حل مسائل مختلف مانند کلاس بندی تصویر، پردازش زبان و تشخیص متن داشته است (Gu et al, 2018). این الگوریتم که نوعی از کلاس ANN به حساب می آید به نحوی طراحی شده تا به صورت خودکار و تطبیقی، ویژگی های 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 نورون ها می باشد و معمولا دارای یک شبکه سه بلوکی شامل pooling، convolution و Fully connected می باشد که اساس آن را تشکیل می دهد. کانولوشن ها وظیفه استخراج ویژگی های داده های ورودی را بر عهده دارند و این کار را با فیلتر ها و کرنل های مختلف انجام می دهند (Ullah et al, 2022) و Pooling layer ها نیز با کاهش تعداد ساختارهای پیچیده، عملکرد محاسباتی را بهبود می بخشند (Panahi et al, 2020). لایه Fully connected معمولا در انتهای شبکه قرار می گیرد و هدف آنها پیش بینی نهایی با استفاده از ویژگی های ورودی است. همچنین در این مطالعه از لایه dropout به منظور جلوگیری از بیش برازش، و از لایه concatenate به منظور ادغام لایه ها استفاده شد.

الگوریتم HHO

الگوریتم HHO یک الگوریتم محاسباتی مبتنی بر جمعیت است که از رفتار گروهی شاهین ها برای حل مسائل بهینه سازی الگو برداری کرده است. این الگوریتم که در سال ۲۰۱۹ معرفی شده در مطالعات مختلفی بکار رفته 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 مدل سازی شده است. بهترین راه حل انتخابی در هر مرحله به عنوان طعمه مورد نظر انتخاب می شود. پیاده سازی این الگوریتم مطابق زیر و طی چند مرحله انجام می شود.

مرحله اول شامل شناسایی طعمه توسط شاهین های هریس با دو استراتژی مختلف می باشد که به صورت ریاضی در زیر مدل شده است (Heidari et al, 2019):

$$X(it+1) = \begin{cases} X_{rand}(it) - r_1 | X_{rand}(it) - 2r_2 X(it) & \text{if } q \geq 0.5 \\ (X_{rabbit}(it) - X_m(it)) - r_3(LB + r_4(UB - LB)) & \text{if } q < 0.5 \end{cases} \quad (5)$$

در اینجا، $X_{rabbit}(it)$ موقعیت خرگوش، $X(it)$ موقعیت شاهین، LB حد پایین، UB حد بالا، $X_{rand}(iter)$ شاهین انتخاب شده به صورت تصادفی، $X_m(iter)$ میانگین موقعیت جمعیت شاهین ها و همچنین r_1, r_2, r_3 و r_4 نیز اعداد تصادفی در بازه ۰ تا ۱ می باشند. میانگین موقعیت شاهین ها با استفاده از معادله زیر قابل محاسبه می باشد:

$$X_m(it) = \frac{1}{N} \sum_{i=1}^N X_i(it) \quad (6)$$

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

$$E = 2E_0 \left(1 - \frac{it}{T}\right) \quad (7)$$

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:
محاصره نرم

$$X(it+1) = \Delta X(it) - E|X_{rabbit}(it) - X(it)| \quad (8)$$

$$\Delta X(it) = X_{rabbit}(it) - X(it)$$

برای محاصره سخت نیز طبق معادله زیر میتوان مدل سازی کرد:

$$X(it+1) = X_{rabbit}(it) - E|\Delta X(it)| \quad (9)$$

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 ۲۳، ۲۴، ۲۵، ۲۶ و ۲۷ نحوه محاسبه این پارامترها رو 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).

$$Sensitivity = \frac{TP}{TP+FN} \quad (23)$$

$$Specificity = \frac{TN}{TN+FP} \quad (24)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (25)$$

مقادیر ۰/۹-۰/۸ نشان دهنده عملکرد خیلی خوب و مقدار بین ۰/۹-۱ نشان دهنده عملکرد فوق العاده مدل بکار رفته است. بعلاوه در این مطالعه، به منظور ارزیابی مدل های ترکیبی جدید بکار رفته از دو شاخص RMSE و MAE نیز استفاده شد که معادلات آنها به صورت زیر است:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_p - Z_a)^2} \quad (26)$$

$$MAE = \sqrt{\frac{1}{n} \sum_{i=1}^n |Z_p - Z_a|} \quad (27)$$

در اینجا، Z_p ، Z_a و n 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 مقداری است که الگوریتم پیش بینی نموده است. مقدار واقعی همان مقادیر واقعی می باشد که به عنوان دیتا صحت سنجی وارد الگوریتم شد. این دو پارامتر همواره مورد توجه محققان به منظور ارزیابی عملکرد الگوریتم های هوشمند در موضوعات مختلف بوده است (Paryani et al, 2022; Pourghasemi et al, 2020).

منحنی مشخصه عملکرد سیستم (ROC) منحنی ROC یک ابزار گرافیکی است که به منظور ارزیابی عملکرد مدل بکار می رود (Shahabi et al, 2021). محور X نشان دهنده نرخ مثبت کاذب و محور Y نیز نشان دهنده نرخ مثبت واقعی است. در تفسیر این روش، از مساحت زیر سطح نمودار استفاده می شود. هرچه قدر این مقدار به ۱ نزدیک تر باشد نشان دهنده عملکرد بهتر مدل در پیش بینی است (Miraki et al, 2019). به طور کلی مقدار زیر سطح نمودار از معادله زیر قابل محاسبه می باشد (شکل ۴):

$$\frac{TP}{TP + FN} = TPR \quad (29)$$


$$\frac{FP}{FP + TN} = FPR \quad (30)$$

Table 4. Model performance

No	Evaluation metrics	CNN-HHO	246
1	True positive	42	
2	True negative	45	
3	False positive	2	247
4	False negative	5	
5	Sensitivity	89.4	248
6	Specificity	95.7	
7	Accuracy	92.55	
8	AUC	95.9	249
9	RMSE	0.277	
10	MAE	0.165	250

نتایج

در این پژوهش با استفاده از چندین رفرنس مختلف و معتبر، ۱۱۰ نقطه برای آموزش و ۴۷ نقطه برای صحت سنجی انتخاب شد. همچنین نه فاکتور موثر بر وقوع سیل در منطقه مورد مطالعه را در نظر گرفتیم که در بخش آماده سازی دیتا به طور کامل توضیح داده شد. به منظور پیاده سازی مدل های ترکیبی در این پژوهش، از محیط برنامه نویسی پایتون استفاده شد. همچنین از دو شاخص مهم RMSE و MAE به منظور برآورد عملکرد مدل بکار رفته در آموزش شبکه و پیش بینی مقادیر واقعی نیز استفاده شد. هرچقدر مقادیر این دو پارامتر به صفر نزدیک تر باشد نشان دهنده عملکرد بهتر مدل است. این دو شاخص با مقایسه بین مقدار پیش بینی و مقدار واقعی قدرت عملکرد شبکه را در پیش بینی نشان می دهد (شکل ۴). نتایج مشخص کرد الگوریتم ترکیبی CNN-HHO (RMSE=0.277 و MAE=0.165) عملکرد بسیار خوبی در پیش بینی مناطق حساس به سیل داشته است (جدول ۴).



تولید نقشه حساسیت سیل

در این مرحله مقادیر پیش بینی شده از محیط پایتون به نرم افزار ArcMap 10.5 انتقال داده شد تا نقشه های تولید شده طبقه بندی شود. شکل ۵ نقشه تولید شده با استفاده از الگوریتم CNN-HHO را نشان می دهد. همانطور که مشخص است به پنج کلاس خیلی کم، کم، متوسط، زیاد و خیلی زیاد تقسیم بندی شده است. اینکه از چه روشی برای طبقه بندی نقشه حساسیت استفاده کنیم بستگی به عوامل مختلفی داشته و روش قطعی وجود ندارد. در این مطالعه همه روش های کلاس بندی شامل Equal Interval, Quantile, Natural Breaks و Geometrical Interval امتحان شد و نهایتاً روش Qauntile انتخاب شد زیرا بهترین عملکرد را از خود نشان داد. همچنین شکل ۶ درصد پوشش تعداد پیکسل های هر کلاس را نشان می دهد. کلاس خیلی زیاد ۲۰/۰۷ درصد از منطقه را پوشش می دهد. همچنین کلاس خیلی کم با مقدار ۱۷/۱۹ درصد کمترین پوشش را دارد.




Figure 5. Flood susceptibility map




Figure 6. Percentage of classes

302

303

همانطور که پیش تر گفته شد در این پژوهش انواع شاخص های آماری به منظور ارزیابی دقیق مدل ترکیبی استفاده شد. جدول ۴ نتایج سه شاخص sensitivity, specificity و accuracy را نشان می دهد. Sensitivity و specificity به ترتیب نشان دهنده توانایی الگوریتم در شناسایی موارد مثبت واقعی و موارد منفی واقعی است. نتایج به دست آمده نشان می دهد که Sensitivity و Specificity به ترتیب مقادیر ۸۹/۴ و ۹۵/۷ را به خود اختصاص داده اند. برای شاخص Accuracy نیز نتایج مقدار ۹۲/۵۵ را نشان می دهد که حاکی از عملکرد بسیار خوب مدل در دقت کلاس بندی منطقه مورد مطالعه می باشد. شکل ۶ سطح زیر نمودار ROC را نشان می دهد. همانطور که مشخص است مقدار سطح زیر نمودار ۹۵/۹٪ می باشد. همانطور که گفته شد هرچقدر سطح زیر نمودار بزرگتر باشد (فاصله بیشتری از خط رفرنس داشته باشد) نشان دهنده عملکرد بهتر مدل در پیش بینی است. مقدار به دست آمده حاکی از عملکرد فوق العاده مدل CNN-HHO دارد.




Figure 6. ROC curve

320

321

تمامی مدل های بکار رفته در پژوهش های مختلف دارای مزایا و معایبی هستند. این موضوع باعث می شود تا پژوهشگران مدل ها و ترکیب های جدیدی را توسعه دهند تا نقشه های واقع گرایانه و کاربردی تر تولید کنند. در این پژوهش از روش قدرتمند یادگیری عمیق CNN و ترکیب آن با الگوریتم HHO استفاده شد. از مزایای روش های یادگیری عمیق مانند CNN می توان به توانایی آنها در کشف ساختارهای پیچیده، قدرت بالا در استخراج ویژگی های داده ها و آموزش در سطح بالا به وسیله حجم زیادی از دیتا اشاره کرد (Sagi and Rokach, 2018; Romero et al, 2015). این دو روش در پژوهش های مختلفی به کار رفته 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 نقشه های حساسیت سیل دقیق تری تولید می کند. در مطالعه ای دیگر، Fang et al, 2020 الگوریتم CNN را با روش های SVM، RF و LR مقایسه نموده اند. آنها گزارش نمودند که الگوریتم CNN بر دیگر روش های یادگیری ماشین برتری دارد. همچنین آنها نشان دادند ترکیب CNN با دیگر الگوریتم ها باعث بهبود نتایج می شود. همچنین برخی از پژوهشگران CNN را با الگوریتم های فراابتکاری ترکیب نموده و به این نتایج دست یافته اند. برای مثال، Hakim et al, 2022 با استفاده از CNN و ترکیب آن با الگوریتم های فراابتکاری GWO و ICA گزارش نمودند که مدل ترکیبی عملکرد بهتری در مقابل CNN دارد. به بیان دیگر ترکیب یادگیری عمیق با الگوریتم های فراابتکاری شبکه ای قدرتمند تر می سازد. نتایج این مطالعه نیز مشخص کرد ترکیب CNN با الگوریتم فراابتکاری HHO عملکرد فوق العاده ای دارد به طوریکه مقدار سطح زیر نمودار ROC برابر ۹۵/۹٪ به دست آمد.

بررسی نقشه های حساسیت تولید شده

همانطور که بر روی نقشه مشخص است از بین مناطق ۲۲ گانه تهران، مناطق ۱، ۲، ۳، ۴، ۵ و ۸ آسیب پذیرتر از مناطق دیگر هستند (شکل ۳). ما دو کلاس حساسیت خیلی زیاد و زیاد را مینا قرار دادیم زیرا مناطق بحرانی تر در اولویت قرار دارند. البته این نکته نباید فراموش شود که تاریخچه سیل ها نشان داده است که شروع این فاجعه از رود دره های شمال تهران است. بنابراین اگر بخواهیم اولویت بندی کنیم شمال مناطق ۱، ۲، ۵ و ۲۲ اولین مواجهه با سیل را خواهند داشت. این ناحیه دقیقا مرز بین کوه های شمال شهر با شهر است. سابقه سیل های رخ داده نیز نشان داده است که ابتدا در رود دره های شمال شهر جریان آب حرکت کرده و پس از آن به پایین دست جاری شده است. شمال غرب تهران نیز که بخش وسیعی از آن را کن و حصارک تشکیل می دهد از جمله مناطقی است که بسیار آسیب پذیر است. همچنین براساس نتایج، شمال و شمال شرق نیز پتانسیل بالایی دارند. این مناطق شامل رود دره های دربند و گلاب دره، درکه، ولنجک و دارآباد می باشد. از سیل های رخ داده در این محدوده می توان به سیل سال ۱۳۶۶ میدان تجریش اشاره نمود که با تلفات جانی و مالی سنگینی همراه بود. اگرچه طی سال های اخیر سیل در این مناطق گزارش نشده است اما اطلاعات ثبت شده مربوط به دبی جریان آب در برخی از رودخانه ها که با استفاده از ایستگاه های هیدرومتری انجام گرفته است نشان دهنده طغیان آب در هنگام بارش های شدید است. عدم لایه ربوی رودخانه ها و یا مسدود شدن رودخانه ها توسط اجسام خارجی منجر به یک فاجعه خواهد شد. بعلاوه نتایج نشان داد رودخانه ها و مسیل های شهر تهران کاملا آسیب پذیر بوده و احتمال طغیان آنها هنگام بارش های شدید و ناگهانی وجود دارد. همچنین تراکم جمعیتی بالا در اطراف رودخانه ها و همچنین ساخت و سازهای غیر اصولی و غیر مجاز در مسیر مسیل ها از دیگر عواملی است که نشان می دهد در صورت بروز یک سیل ناگهانی شدید در آینده با یک فاجعه روبرو خواهیم بود. نقشه تولید شده می تواند به عنوان یک ابزار کاربردی در اختیار برنامه ریزان، مدیران شهری و مهندسان قرار گیرد تا با آگاهی بیشتری تصمیم گیری نمایند. با توجه به مناطق حساس به وقوع سیل های ناگهانی در کلان شهر

تهران، باید تدابیر و تصمیم های مهم و لازم را قبل از وقوع فاجعه و بعد از آن اتخاذ نمود که این امر با استفاده از نقشه حساسیت سیل امکان پذیر است.

جمع بندی

یکی از وظایف تصمیم گیران دانش کافی و آگاهی داشتن از مناطق در معرض سیل به منظور 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 کلان شهر تهران با دقت بالا تولید شود. در ادامه عملکرد مدل با استفاده از چندین شاخص آماری شامل RMSE, MAE, Sensitivity, Specificity, Accuracy and ROC ارزیابی شد و نهایتاً مشخص شد CNN-HHO دارای عملکرد عالی می باشد. نتایج این مطالعه می تواند به عنوان یک پژوهش جامع در اختیار سازمان های مربوطه قرار گرفته و به عنوان ابزاری ارزشمند جهت مدیریت سیل بکار رود. همچنین آگاهی از مناطقی که احتمال وقوع سیل در آنها وجود دارد می تواند منجر به پیاده سازی سیستم های جمع آوری آب شود. این مهم علاوه بر اینکه از گسترش سیل جلوگیری می کند، می تواند حجم زیادی از آب را جمع آوری کند. مطالعه حاضر نشان داد مدل ترکیبی بکار رفته می تواند در مناطق دیگر نیز مورد استفاده قرار گیرد. پیشنهاد می شود که در مطالعات آینده، از آن استفاده شده و با روش های جدید مقایسه شود.

References

- 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., ... & 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., ... & 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., ... & 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.

415 Ghiasi, V., Ghasemi, S. A. R., & Yousefi, M. (2021). Landslide susceptibility mapping through
 416 continuous fuzzification and geometric average multi-criteria decision-making
 417 approaches. *Natural Hazards*, 107(1), 795-808.

418 Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2018). Recent
 419 advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.

420 Hakim, W. L., Rezaie, F., Nur, A. S., Panahi, M., Khosravi, K., Lee, C. W., & Lee, S. (2022).
 421 Convolutional neural network (CNN) with metaheuristic optimization algorithms for landslide
 422 susceptibility mapping in Icheon, South Korea. *Journal of environmental management*, 305,
 423 114367.

424 Hashemkhani Zolfani, S., Yazdani, M., & Zavadskas, E. K. (2018). An extended stepwise weight
 425 assessment ratio analysis (SWARA) method for improving criteria prioritization process. *Soft*
 426 *Computing*, 22, 7399-7405.

427 Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019). Harris hawks
 428 optimization: Algorithm and applications. *Future generation computer systems*, 97, 849-872.

429 Keršulienė, V., Zavadskas, E. K., & Turskis, Z. (2010). Selection of rational dispute resolution
 430 method by applying new step-wise weight assessment ratio analysis (SWARA). *Journal of*
 431 *business economics and management*, 11(2), 243-258.

432 Khosravi, K., Pham, B. T., Chapi, K., Shirzadi, A., Shahabi, H., Revhaug, I., ... & Bui, D. T.
 433 (2018). A comparative assessment of decision trees algorithms for flash flood susceptibility
 434 modeling at Haraz watershed, northern Iran. *Science of the Total Environment*, 627, 744-755.

435 Khosravi, K., Shahabi, H., Pham, B. T., Adamowski, J., Shirzadi, A., Pradhan, B., ... & Prakash,
 436 I. (2019). A comparative assessment of flood susceptibility modeling using multi-criteria decision-
 437 making analysis and machine learning methods. *Journal of Hydrology*, 573, 311-323.

438 Li, Y., Osei, F. B., Hu, T., & Stein, A. (2023). Urban flood susceptibility mapping based on social
 439 media data in Chengdu city, China. *Sustainable Cities and Society*, 88, 104307.

440 Liuzzo, L., Sammartano, V., & Freni, G. (2019). Comparison between different distributed
 441 methods for flood susceptibility mapping. *Water Resources Management*, 33, 3155-3173.

442 Malik, A., Tikhamarine, Y., Sammen, S. S., Abba, S. I., & Shahid, S. (2021). Prediction of
 443 meteorological drought by using hybrid support vector regression optimized with HHO versus
 444 PSO algorithms. *Environmental Science and Pollution Research*, 28, 39139-39158.

445 Miraki, S., Zanganeh, S. H., Chapi, K., Singh, V. P., Shirzadi, A., Shahabi, H., & Pham, B. T.
 446 (2019). Mapping groundwater potential using a novel hybrid intelligence approach. *Water*
 447 *resources management*, 33, 281-302.

448 Panahi, M., Sadhasivam, N., Pourghasemi, H. R., Rezaie, F., & Lee, S. (2020). Spatial prediction
 449 of groundwater potential mapping based on convolutional neural network (CNN) and support
 450 vector regression (SVR). *Journal of Hydrology*, 588, 125033.

451 Paryani, S., Neshat, A., Pourghasemi, H. R., Ntona, M. M., & Kazakis, N. (2022). A novel hybrid
 452 of support vector regression and metaheuristic algorithms for groundwater spring potential
 453 mapping. *Science of The Total Environment*, 807, 151055.

454 Paryani, S., Bordbar, M., Jun, C., Panahi, M., Bateni, S. M., Neale, C. M., ... & Lee, S. (2023).
 455 Hybrid-based approaches for the flood susceptibility prediction of Kermanshah province,
 456 Iran. *Natural Hazards*, 116(1), 837-868.

457 Paul, G. C., Saha, S., & Hembram, T. K. (2019). Application of the GIS-based probabilistic models
 458 for mapping the flood susceptibility in Bansloi sub-basin of Ganga-Bhagirathi river and their
 459 comparison. *Remote Sensing in Earth Systems Sciences*, 2, 120-146.

460 Pamučar, D., Ecer, F., Cirovic, G., & Arlasheedi, M. A. (2020). Application of improved best
 461 worst method (BWM) in real-world problems. *Mathematics*, 8(8), 1342.

462 Prasad, P., Loveson, V. J., Das, B., & Kotha, M. (2022). Novel ensemble machine learning models
 463 in flood susceptibility mapping. *Geocarto International*, 37(16), 4571-4593.

464 Pham, B. T., Jaafari, A., Van Phong, T., Yen, H. P. H., Tuyen, T. T., Van Luong, V., ... & Foong,
 465 L. K. (2021). Improved flood susceptibility mapping using a best first decision tree integrated with
 466 ensemble learning techniques. *Geoscience Frontiers*, 12(3), 101105.

467 Ramayanti, S., Nur, A. S., Syifa, M., Panahi, M., Achmad, A. R., Park, S., & Lee, C. W. (2022).
 468 Performance comparison of two deep learning models for flood susceptibility map in Beira area,
 469 Mozambique. *The Egyptian Journal of Remote Sensing and Space Science*, 25(4), 1025-1036.

470 Romero, A., Gatta, C., & Camps-Valls, G. (2015). Unsupervised deep feature extraction for remote
 471 sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 54(3), 1349-
 472 1362.

473 Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley interdisciplinary reviews: data
 474 mining and knowledge discovery*, 8(4), e1249.

475 Saravanan, S., Abijith, D., Reddy, N. M., Parthasarathy, K. S. S., Janardhanam, N., Sathiyamurthi,
 476 S., & Sivakumar, V. (2023). Flood susceptibility mapping using machine learning boosting
 477 algorithms techniques in Idukki district of Kerala India. *Urban Climate*, 49, 101503.

478 Sarçın, B., Alaboz, P., Karaca, S., & Dengiz, O. (2024). Pythagorean fuzzy SWARA weighting
 479 technique for soil quality modeling of cultivated land in semi-arid terrestrial
 480 ecosystems. *Computers and Electronics in Agriculture*, 227, 109466.

481 Shahabi, H., Shirzadi, A., Ronoud, S., Asadi, S., Pham, B. T., Mansouripour, F., ... & Bui, D. T.
 482 (2021). Flash flood susceptibility mapping using a novel deep learning model based on deep belief
 483 network, back propagation and genetic algorithm. *Geoscience Frontiers*, 12(3), 101100.

484 Songchon, C., Wright, G., & Beevers, L. (2021). Quality assessment of crowdsourced social media
 485 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., ... & 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., ... & 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., ... & 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.

- 521 Zhang, H., Nguyen, H., Bui, X. N., Pradhan, B., Asteris, P. G., Costache, R., & Aryal, J. (2022).
522 A generalized artificial intelligence model for estimating the friction angle of clays in evaluating
523 slope stability using a deep neural network and Harris Hawks optimization algorithm. *Engineering*
524 *with Computers*, 1-14.
- 525 Zhang, P., Jia, Y., & Shang, Y. (2022). Research and application of XGBoost in imbalanced
526 data. *International Journal of Distributed Sensor Networks*, 18(6), 15501329221106935.

مقاله آماده انتشار