



Using citizen reports for urban flood prediction with machine learning approach and rainfall data (Case Study: Qom, Iran)

Fereshte Sadat Mousavi Pour¹ | Mohammad Hossein Niksokhan² |
Jaber Soltani³

1. Kish International Campus, University of Tehran, Kish, Iran. E-mail: fereshte.mousavi@ut.ac.ir
2. Corresponding Author, Department of Environmental Engineering, Faculty of Environment, University of Tehran, Tehran, Iran. E-mail: niksokhan@ut.ac.ir
3. Department of Water Engineering, Faculty of Agricultural Technology, University College of Agriculture & Natural Resources, University of Tehran, Tehran, Iran. E-mail: jsoltani@ut.ac.ir

Article Info	ABSTRACT
Article type: Research Article Article history: Received 30 May 2025 Received in revised form 26 July 2025 Accepted 15 August 2025 Published online 10 December 2025 Keywords: <i>Citizen reports</i> <i>Machine learning</i> <i>Qom</i> <i>Rainfall</i> <i>Urban flooding</i>	This research aims to develop a scientific and practical method for urban flood prediction using citizen reports and satellite rainfall data. The city area is divided into a grid with 3,000-meter intervals, and the intersection points of the grid lines are selected as rainfall measurement stations. Days are classified as wet, dry, and normal based on citizen reports and observed rainfall, and machine learning models including Support Vector Machine, Logistic Regression, and Random Forest are trained on these data. The results show that the Random Forest model has the highest performance, with 98percent precision and an F1 score of 66 percent in correctly identifying flood events. Considering Qom's semi-arid climate and the non-lethal damages caused by floods, emphasis was placed on the precision of models in correctly detecting flood cases to enhance confidence and prevent community anxiety due to false alarms. Stations 1 and 23 are identified as critical locations for rainfall equipment installation based on feature importance analysis. Subsequently, a critical rainfall threshold curve at a 90 percent probability level was plotted for flood prediction, and validated with real data. Rainfall above the threshold generally results in floods, while values below are considered safe. This approach is an effective tool for rapid warning systems and can aid urban disaster management to prevent financial and human losses.

Cite this article: Mousavi Pour, F. S., Niksokhan, M. H., & Soltani, J. (2025). Using citizen reports for urban flood prediction with machine learning approach and rainfall data (Case Study: Qom, Iran). *Journal of Water and Irrigation Management*, 15 (2), 443-456. DOI: <https://doi.org/10.22059/jwim.2025.396294.1235>



© The Author(s).

DOI: <https://doi.org/10.22059/jwim.2025.396294.1235>

Publisher: University of Tehran Press.



استفاده از گزارش شهروندان در پیش‌بینی سیلاب شهری با رویکرد یادگیری ماشین و داده تاریخی بارش (مطالعه موردی: شهر قم)

فرشته السادات موسوی پور^۱ | محمدحسین نیک‌سخن^۲ | جابر سلطانی^۳

۱. پردیس بین‌المللی کیش دانشگاه تهران، کیش، ایران. رایانامه: fereshte.mousavi@ut.ac.ir

۲. نویسنده مسئول، دانشکده محیط زیست، دانشگاه تهران، تهران ایران. رایانامه: niksokhan@ut.ac.ir

۳. دانشکدگان کشاورزی و منابع طبیعی، دانشکده فناوری کشاورزی (ابوریحان)، دانشگاه تهران، تهران، ایران. رایانامه: jsoltani@ut.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	پژوهش حاضر با هدف توسعه روشی علمی و کاربردی برای پیش‌بینی سیلاب‌های شهری، از گزارش‌های مردمی و داده‌های ماهواره‌ای بارش بهره گرفته‌است. محدوده شهر با استفاده از یک شبکه مربعی با فواصل ۳۰۰۰ متر تقسیم و نقاط برخورد خطوط شبکه به‌عنوان ایستگاه برداشت بارندگی انتخاب شدند. روزهای تر، خشک و عادی براساس گزارش‌های شهروندان و مشاهده بارش، دسته‌بندی گردیده و مدل‌های یادگیری ماشینی شامل ماشین بردار پشتیبان، رگرسیون لجستیکی و جنگل تصادفی آموزش داده شدند. نتایج نشان داد که مدل جنگل تصادفی با دقت ۹۸ درصد و امتیاز F1، ۶۶ درصد در شناسایی رویدادهای سیلاب، برترین مدل می‌باشد. با توجه به اقلیم نیمه‌بیابانی منطقه مورد مطالعه (شهر قم) و خسارت‌های غیرجانی سیلاب، تأکید ارزیابی مدل‌ها بر دقت در شناسایی درست موارد سیلاب جهت افزایش اطمینان و عدم ایجاد تشویش در جامعه به‌دلیل هشدارهای نادرست است. براساس تحلیل مهم‌ترین ویژگی‌ها، ایستگاه‌های ۱ و ۲۳ به‌عنوان مکان‌های کلیدی برای نصب تجهیزات بارش شناخته شدند. سپس، نمودار آستانه بارش بحرانی برای پیش‌بینی وقوع سیلاب ترسیم شد و در اعتبارسنجی با داده‌های واقعی، آستانه بحرانی سیلاب با سطح احتمال ۹۰ درصد روشی قابل درک برای پیش‌بینی سیلاب شناخته شد. بارش‌های بالای آستانه منجر به وقوع سیلاب شهری شده، درحالی‌که مقادیر پایین نمودار موارد بی‌خطر محسوب می‌شوند. این رویکرد، ابزار مؤثری در سیستم‌های هشدار سریع است و می‌تواند در مدیریت بحران شهری، از خسارت‌های مالی و جانی جلوگیری کند.
کلیدواژه‌ها: بارندگی گزارش‌های شهروندان شهر قم سیلاب شهری و یادگیری ماشین	

استناد: موسوی پور، فرشته‌السادات؛ نیک‌سخن، محمدحسین و سلطانی، جابر (۱۴۰۴). استفاده از گزارش شهروندان در پیش‌بینی سیلاب شهری با رویکرد یادگیری ماشین و داده تاریخی بارش (مطالعه موردی: شهر قم). نشریه مدیریت آب و آبیاری، ۱۵ (۲)، ۴۴۳-۴۵۶.

DOI: <https://doi.org/10.22059/jwim.2025.396294.1235>



۱. مقدمه

سیلاب شهری زمانی رخ می‌دهد که بارش‌های حدی منجر به ناتوانی شبکه زه‌کشی شده و اضافه ظرفیت آب به‌صورت جریان‌های سطحی یا آب‌گرفتگی در خیابان‌ها بروز پیدا می‌کند (Beecham and Chowdhury, 2012). این پدیده ناشی از تغییرات اقلیمی و اقدامات گوناگون انسانی - شامل تغییر کاربری زمین، افزایش جمعیت، رشد سریع و برنامه‌ریزی نشده شهرنشینی، گسترش سطوح نفوذ ناپذیر و زیرساخت‌های ناکافی - از رایج‌ترین مخاطراتی است که امروزه با آن روبه‌رو هستیم (Liu et al., 2025). علاوه بر این، پیش‌بینی‌های بسیاری از برنامه‌های شبیه‌سازی اقلیمی در آینده، حاکی از افزایش بارش‌های حدی در اکثر نقاط جهان به‌ویژه در فصل بهار تا پایان سده ۲۱ می‌باشد (O'Shea et al., 2024). بنابراین، یافتن راه‌کاری برای پیش‌بینی، پیشگیری و کاهش خسارت‌های ناشی از این پدیده، تبدیل به یک چالش در سطح کلان در زمینه مدیریت آب شهری گشته است (Hill et al., 2023).

تاکنون، پژوهش‌های متعددی با رویکردهای مختلف به پیش‌بینی سیلاب و آب‌گرفتگی در مناطق شهری پرداخته‌اند. برخی از این روش‌ها بر استفاده از مدل‌های هیدرولیکی و یا ترکیب مدل‌های هیدرولیکی و هیدرولوژیکی تکیه دارند. این فرایند دربرگیرنده شبیه‌سازی یک رویداد واقعی جهت اعتبارسنجی نتایج محاسباتی مدل‌های عددی می‌باشد. سپس، در مرحله بعدی این مدل‌ها تحت سناریوهای گوناگون، بارها اجرا می‌شوند تا نتایج پیش‌بینی حاصل از هر سناریو مشخص گردد (Hassani et al., 2024). در بحث شبیه‌سازی و پیش‌بینی سیلاب شهری، انتخاب مدل مناسب و تعیین پارامترهای آن نقش کلیدی و مهمی در صحت نتایج خروجی دارند. داده‌های در دسترس، اهداف مطالعه و ویژگی‌های منحصر به فرد هر منطقه یا نمونه موردی از عواملی هستند که بر انتخاب مدل بهینه تأثیر به‌سزایی دارند.

روش‌های یادگیری ماشین، پیش‌بینی‌های با دقت بالا، بدون نیاز به کشف و درک روابط پیچیده میان پارامترهای مؤثر در رخداد یک پدیده ارائه می‌دهند. ابزار یادگیری ماشین، توانایی شناسایی احتمال رخداد سیلاب شهری در آینده، تنها با تکیه بر داده‌های تاریخی و بدون نیاز به فهم و کشف روابط و فرایندهای پیچیده اداره‌کننده این پدیده را دارد (Tang et al., 2022). افزایش پذیرش عمومی و پیشرفت‌های محاسبات نرم از جمله روش‌های یادگیری ماشین، مانند ماشین بردار پشتیبان^۱ (SVMs) (Yan et al., 2018)، جنگل تصادفی^۲ (Random Forests) (Lee et al., 2017; Feng et al., 2015)، شبکه‌های عصبی گروهی^۳ (ENNs) (Berkhahn et al., 2019)، رگرسیون لجستیکی^۴ (LR) (Lee et al., 2017; Kim et al., 2020) و تقویت گرادیان شدید^۵ (XGBoost) (Yuan et al., 2024) در سال‌های اخیر چشم‌گیر بوده است.

مطالعات متعددی برای دستیابی به درک جامع و کاملی از پیش‌بینی پدیده‌های فیزیکی به‌وسیله جفت کردن داده‌های تاریخی گزارش‌های شهروندان یا اطلاعات ثبت شده توسط پایشگرها (مانند سامانه‌های اجتماعی، توییتر، پهپادهای شناساگر، موبایل و ...) با سایر عوامل مؤثر بر رویداد یک واقعه با بهره‌گیری از یادگیری ماشین انجام شده است (Safaei-Moghadam et al., 2024).

در این پژوهش، احتمال کارایی جفت کردن گزارش‌های شهروندان با داده‌های تاریخی بارش به‌وسیله یادگیری ماشین برای دسته‌بندی^۶ و پیش‌بینی رخداد سیلاب شهری به‌عنوان یک روش نوآورانه در جهت ایجاد یک سیستم هشدار موردبررسی قرار می‌گیرد. در ادامه، پس از دسته‌بندی رخدادهای سیلاب شهری، یک نمودار آستانه سیلاب، ارائه می‌گردد که مقادیر بارش‌های بالاتر از آن منجر به وقوع آب‌گرفتگی در سطح شهر گشته و مقادیر زیر آن به‌عنوان سطح امن شناخته می‌شوند. گسترش یک رویکرد علمی که در نبود اطلاعات گسترده و پیچیده مربوط به شناخت یک پدیده، منجر به استخراج یک روش ساده و قابل فهم (نمودار آستانه سیلاب) برای مدیران شهری جهت تجهیز و آمادگی برای وقوع سیلاب شهری است، نوآوری دیگر پژوهش حاضر می‌باشد.

۲. مواد و روش‌ها

مطابق شکل (۱)، مرحله نخست شامل ایجاد شبکه ایستگاه اندازه‌گیری داده‌های باران، برداشت داده‌ها با استفاده از ماهواره GSMaP^۷، استخراج و دسته‌بندی گزارش‌های مردمی است و آموزش سه مدل یادگیری ماشین شامل SVC، LR و RF در مرحله بعدی قرار می‌گیرد. در پایان با توجه به مؤثرترین ایستگاه‌ها، اقدام به تهیه نمودار آستانه سیلاب می‌شود.




Figure 1. The main steps of the study

۲.۱. معرفی منطقه مورد مطالعه

مطالعه حاضر بر شهر قم که در عرض و طول جغرافیایی از $34^{\circ}57'$ تا $34^{\circ}78'$ درجه شمالی و $50^{\circ}78'$ تا $50^{\circ}98'$ درجه شرقی در بخش مرکزی ایران قرار دارد، متمرکز است (شکل ۲). شهر قم مساحتی برابر 11613 کیلومترمربع را در بر می‌گیرد. رقوم ارتفاعی استان قم از 800 تا 3300 متر بالاتر از سطح دریا می‌باشد و این تغییرات زیاد باعث گوناگونی شرایط آب‌وهوایی از نیمه‌کوهستانی تا بیابانی گردیده است. اما بیش از 75 درصد مساحت استان شرایط نیمه‌بیابانی دارد (Panahi et al., 2022). جمعیت شهر بالغ بر 1380000 نفر در سال 1400 گزارش شده است. آمارها حاکی از رشد بیش از دو برابری جمعیت شهر در بازه زمانی 30 سال (از 1358 تا 1390) می‌باشد. اگرچه میزان بارش سالیانه در این شهر 150 میلی‌متر است، در فروردین‌ماه 1398 (آوریل 2019) تنها در دو ایستگاه باران‌سنجی مقادیر 137 و 139 میلی‌متر بارش ثبت شده که اندکی کمتر از کل بارش سالیانه می‌باشد.




Figure 2. The situation of the city of Qom (study area) in Qom province and central part of Iran

۲.۲. تعیین شبکه برداشت داده‌های بارش

مطابق شکل (۳)، محدوده شهر قم به‌وسیله شبکه مربعی با فواصل ۳۰۰۰ متر تقسیم‌بندی شده و ۲۹ نقطه تقاطع خطوط شبکه به‌عنوان ایستگاه‌های برداشت داده‌های بارندگی انتخاب شدند. انتخاب فواصل کمتر یا بیش‌تر منجر به بارش‌های یکسان در ایستگاه‌ها یا کاهش تعداد ویژگی‌های^۸ یادگیری ماشین می‌گردد.




Figure 3. Rainfall measuring stations

۳.۲. برداشت داده‌های بارش

مقادیر بارش ۲۴ ساعته در ۲۹ ایستگاه مشخص‌شده در شکل (۳) از ماهواره GSMaP در بازه زمانی ۱۶ مردادماه ۱۳۹۷ (هفتم آگوست ۲۰۱۸) تا ۱۶ مهرماه ۱۴۰۳ (هفتم اکتبر ۲۰۲۴) برداشت شد. دقت بالای مکانی و زمانی داده‌های بارندگی این ماهواره، در مطالعات متعددی به‌ویژه در زمینه شبیه‌سازی مناطق متراکم شهری مورد‌ارزیابی و مقایسه با اندازه‌گیری‌های میدانی قرار گرفته و نتایج قابل‌قبولی ارائه داده است (Priyambodoho et al., 2021).

۴.۲. مشاهدات و گزارش‌های شهروندان

در سال ۱۳۹۷ (۲۰۱۸) شهرداری قم یک سرویس ارتباط مردمی به نام سامانه ۱۳۷ راهاندازی کرد. به‌وسیله این سامانه، شهروندان می‌توانند مشکلات خود را در زمینه‌های تجهیزات و امکانات شهری مانند خرابی راه‌ها، رواناب سطحی، جمع‌آوری پسماند، شبکه زه‌کش شهری و ... با مسئولان محلی درمیان گذاشته و فرایند رفع مشکل را پیگیری نمایند. این گزارش‌ها به‌وسیله تلفن جمع‌آوری شده و شامل اطلاعاتی مانند شماره تلفن شهروند، تاریخ و محل حادثه، یک توضیح کوتاه درباره مشکل و اقدامات صورت‌گرفته توسط واحد مربوطه می‌باشد. از میان تمام موضوعات گزارش‌شده، مطالب مربوط به مشاهده سیلاب شهری جدا گردیده و سایر موارد کنار گذاشته شد. برای این منظور، ۲۲۵۴ روز از تاریخ ۱۶ مردادماه ۱۳۹۷ تا ۱۶ مهرماه ۱۴۰۳ تمامی گزارش‌های ثبت‌شده در سامانه ۱۳۷ موردبررسی قرار گرفت.

۱۳۷۰ روز، به‌عنوان روزهای غیربارانی خشک با توجه به عدم بارندگی در هیچ‌یک از ۲۹ ایستگاه مشخص‌شده شناخته شد. در روزهای خشک، تعداد متوسط گزارش‌های مرتبط با آب‌گرفتگی در شهر که توسط شهروندان اعلام شده بود برابر ۵/۶ به‌دست آمد. این عدد، معیار تمایز روزهای عادی یا شرایط معمولی شهر و روزهای سیلابی در نظر گرفته شد. از میان ۸۸۴ روز بارانی تر باقیمانده، آن‌هایی که تعداد گزارش آب‌گرفتگی شهری بیش‌تر یا مساوی ۶ دارند، به‌عنوان روزهای مشاهده سیلاب شهری شناخته شدند. به این ترتیب، برای دسته‌بندی یادگیری ماشین، روزهای تر دارای مقادیر بیش‌تر یا مساوی ۶ گزارش مشاهده سیلاب شهری، در دسته ۱ و روزهای تر دارای کم‌تر از شش گزارش، در دسته صفر قرار گرفتند.

ازآنجاکه بیش‌تر بارندگی‌ها (بیش از ۹۷ درصد) در روزهای تر در بازه زمانی مهرماه تا خردادماه رخ داده، آمار این بازه زمانی به‌عنوان داده‌های اصلی مطالعه لحاظ گشته و اطلاعات ماه‌های تیر، مرداد و شهریور حذف شد. با این کار، ۲۲۱ عدد از دسته صفر (غیر سیلاب) کم شده و ناترازی^۹ تعداد دسته صفر و ۱ کاهش پیدا کرد. در نهایت، از ۸۸۴ داده در روزهای تر، ۱۶۷ عدد در دسته ۱ و ۴۸۴ رخداد در دسته صفر قرار گرفتند درحالی‌که در حالت نخست، شمارگان دسته ۱ به صفر برابر ۱۷۹ به ۷۰۵ بود.

۵.۲. یادگیری ماشین

به‌منظور تحقق اهداف پژوهش، سه مدل یادگیری ماشین شامل بردار پشتیبان، رگرسیون لجستیکی و جنگل تصادفی آموزش داده شد. تمامی رویدادها به دو دسته کلاس ۱ و صفر تقسیم شدند که به‌ترتیب نماینده وقوع سیلاب شهری و عدم وقوع آن است. برای ارزیابی و مقایسه کارایی مدل‌ها، از ماتریس درهم ریختگی^{۱۰}، دقت^{۱۱}، حساسیت^{۱۲} و امتیاز $F1$ ^{۱۳} استفاده گردید. برای پیشگیری از رخداد بیش‌برازش^{۱۴} از روش اعتبارسنجی متقاطع k -fold^{۱۵} بهره گرفته شد.

• ماشین بردار پشتیبان، الگوریتم یادگیری توانایی است که اغلب در دسته‌بندی داده‌ها به روش دودویی ۱ و صفر (مثلاً سیلاب یا غیر سیلاب) به‌کار می‌رود. این الگوریتم با توجه به هسته^{۱۶} مورداستفاده دارای انواع خطی^{۱۷}، چندجمله‌ای^{۱۸}، سیگموئید^{۱۹} و تابع پایه شعاعی^{۲۰} برای افزایش قدرت دسته‌بندی داده‌های پیچیده می‌باشد (Rifath et al., 2024).

• رگرسیون لجستیکی، یک روش آماری است که برای بررسی رابطه بین متغیرهای پاسخ دسته‌ای، چه اسمی یا ترتیبی و یک یا چند متغیر توضیحی کمی یا دسته‌ای استفاده می‌شود. این تحلیل به‌عنوان یک روش پایه برای دسته‌بندی عمل می‌کند و نشان می‌دهد چگونه یک متغیر پاسخ دودویی (Y) که ممکن است نشان‌دهنده نتایج مثل موفقیت یعنی مقدار Y برابر ۱ و شکست به‌ازای Y برابر صفر، با متغیرهای پیش‌بینی X باشد. نتیجه دسته‌ای است و معمولاً دو مقدار دارد، مانند ۰/۱ که نشان‌دهنده رویداد سیل یا عدم وقوع آن است (Tella et al., 2023).

• جنگل تصادفی، یک الگوریتم یادگیری ماشین گروهی نظارتی است که چندین درخت تصمیم غیرهمبسته را

ترکیب می‌کند. این درخت‌ها با ساختن از مجموعه‌های آموزش مختلف که به صورت تصادفی از روی مجموعه داده اصلی نمونه‌گیری شده‌اند، غیرهمبسته می‌شوند. این فرآیند از تکنیک بسته‌بندی^{۲۱} استفاده می‌کند تا تنوع بین درخت‌ها و دقت مدل افزایش یابد (Golabi et al., 2020).

به دلیل محدودیت‌های تعدادی در داده‌های تاریخی این مطالعه، از روش اعتبارسنجی متقاطع k-fold استفاده شده است، زیرا این روش عملکرد قوی‌تر و پایدارتری نسبت به تقسیم داده‌ها به ۳۰ درصد برای آزمایش و ۷۰ درصد برای آموزش فراهم می‌کند (Tian et al., 2019). در روش فوق که برای ارزیابی مدل و پیشگیری از بیش‌برازش می‌باشد (Montesinos López et al., 2022)، پس از ارزیابی مقادیر مختلف foldها، دو مقدار پنج و هفت بسته به مدل یادگیری به کار گرفته شد. بیش‌برازش که به موفقیت صددرصدی کاذب ماشین در دسته‌بندی داده‌ها اشاره دارد. در حقیقت، شرایطی است که در آن ماشین چیزی را یاد نگرفته بلکه با دسته‌بندی همه داده‌ها (هر داده در یک دسته) و تنها از برگردن آن‌ها به موفقیت نادرست در پیش‌بینی رسیده است. علاوه بر این، برای تنظیم^{۲۲} پارامترهای مدل‌ها از روش جستجوی شبکه‌ای^{۲۳} استفاده گردید. این روش در یک فرایند آزمون و خطا ترکیبات ممکن از پارامترهای تعریف‌شده مدل را تولید می‌نماید. سپس، هر ترکیب را آزمایش کرده و مجموعه‌ای از بهترین پارامترها که دارای عملکرد بهتری با معیار مشخص (در اینجا صحت)^{۲۴} دارند را مشخص می‌کند.

ماتریس درهم‌ریختگی، یک جدول دو بعدی است که برای ارزیابی عملکرد دسته‌بندی‌های چندکلاسه استفاده می‌شود. این جدول شامل چهار مؤلفه اصلی است؛ منفی‌های درست (TN)^{۲۵}، مثبت‌های درست (TP)^{۲۶}، منفی‌های نادرست (FN)^{۲۷} و مثبت‌های نادرست (FP)^{۲۸}. در این زمینه، FP نشان‌دهنده تعداد رویدادهایی است که به نادرستی به عنوان سیل شناخته شده‌اند، در حالی که FN نشان‌دهنده تعداد رخدادهایی است که به صورت نادرست به عنوان غیرسیل دسته‌بندی شده‌اند. برعکس، TN و TP به ترتیب تعداد رویدادهایی است که به درستی به عنوان رویداد غیرسیل و سیل شناسایی شده‌اند (Heydarian et al., 2022).

دقت، یکی از معیارهای استاندارد سنجش در یادگیری ماشین است که نشان می‌دهد چند عدد از رویدادهای سیلی که مدل پیش‌بینی کرده است، با سیل‌های واقعی مطابقت دارند (Ghosh et al., 2022). دقت بالا نشان‌دهنده کم‌بودن نرخ مثبت‌های نادرست مدل است. این معیار را می‌توان به صورت زیر محاسبه کرد:

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (\text{رابطه ۱})$$

حساسیت، نسبت رویدادهای واقعی سیل که به درستی توسط مدل پیش‌بینی شده‌اند، است (Tanim et al., 2022). حساسیت بالا نشان‌دهنده این است که نرخ منفی‌های نادرست مدل کم است. این مقدار را می‌توان با استفاده از رابطه زیر محاسبه کرد:

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (\text{رابطه ۲})$$

امتیاز F1، میانگین هارمونیک دقت و حساسیت است (Ghosh et al., 2022). امتیاز F1 بالا نشان‌دهنده تعادل مناسب بین دقت و حساسیت است. فرمول امتیاز F1 در رابطه (۳) نشان داده شده است.

$$\text{F1-score} = \text{TP} / (\text{TP} + (\text{FP} + \text{FN}) / 2) \quad (\text{رابطه ۳})$$

۳. نتایج

۳.۱. نتیجه عملکرد مدل‌های یادگیری ماشین

نتایج و معیارهای ارزیابی دقت، حساسیت و امتیاز F1 آموزش سه مدل یادگیری ماشین شامل SVC، LR و RF در جدول (۱)

نمایش داده شده است. مدل‌های SVM با هسته‌های مختلف- خطی، چندجمله‌ای، سیگموئید و RBF- تعداد رویدادهای درست سیلاب (TP) را به ترتیب ۳۵، ۲۲، ۴۶ و ۳۳ از مجموع ۱۶۷ رویداد واقعی سیلاب پیش‌بینی کردند. قابلیت این مدل‌ها در تشخیص درست رویدادهای غیرسیلاب (TN) بسیار بالا بود و در بازه ۴۵۳ تا ۴۸۲ از ۴۸۴ مورد واقعی غیرسیلاب قرار داشتند. دقت مدل‌ها در پیش‌بینی سیلاب و غیرسیلاب به ترتیب در بازه‌های ۶۰ تا ۹۲ درصد و ۷۷ تا ۷۹ درصد قرار دارد. امتیاز F1 برای شناسایی سیلاب کمتر از ۴۰ درصد است، درحالی‌که برای تشخیص غیرسیلاب حدود ۸۷ درصد است.

مطابق نتایج مدل LR، تعداد نمونه‌های درست مثبت (TP) برابر با ۴۳ و نمونه‌های نادرست منفی (FN) برابر با ۱۲۴ است، همچنین تعداد نمونه‌های منفی درست (TN) برابر با ۴۷۰ و نمونه‌های نادرست مثبت (FP) برابر با ۱۴ است. این اعداد منجر به دقت ۷۵ درصد و حساسیت ۲۶ درصد برای موارد سیلاب شده است. در مقابل، برای رویدادهای غیرسیلاب، دقت ۷۹ درصد و حساسیت ۹۷ درصد محاسبه شده است. مقایسه امتیاز F1 مدل LR با مدل‌های SVM تفاوت معنی‌داری بین آن‌ها نشان نمی‌دهد.

در میان سه مدل یادگیری ماشین، مدل RF بیش‌ترین تعداد شناسایی مثبت درست (۸۳)، منفی درست (۴۸۲) و شاخص‌های عملکرد را به دست آورد، با دقت ۹۸ درصد، حساسیت ۵۰ درصد و امتیاز F1 برابر با ۶۶ درصد برای موارد سیلاب.

Table 1. The results of 3 ML models including confusion matrix, precision, recall and F1-score

		Actual Flood (1)	Actual Non-Flood (0)	Precision	Recall	F1-score
SVM (Linear)	Predicted Flood (1)	TP= 35 35 flood events are truly identified as floods	FP= 9 9 non-flood events are incorrectly predicted as floods	0.8	0.21	0.33
	Predicted Non-Flood (0)	FN= 132 132 flood events are incorrectly identified as non-floods	TN= 475 475 of non-flood events are truly identified as non-floods	0.78	0.98	0.87
SVM (Poly-Nominal)	Predicted Flood (1)	TP= 22 22 flood events are truly identified as floods	FP= 2 2 non-flood events are incorrectly predicted as floods	0.92	0.13	0.23
	Predicted Non-Flood (0)	FN= 145 145 flood events are incorrectly identified as non-floods	TN= 482 482 of non-flood events are truly identified as non-floods	0.77	1	0.87
SVM (Sigmoid)	Predicted Flood (1)	TP= 46 46 flood events are truly identified as floods	FP= 31 31 non-flood events are incorrectly predicted as floods	0.6	0.28	0.38
	Predicted Non-Flood (0)	FN= 121 121 flood events are incorrectly identified as non-floods	TN= 453 453 of non-flood events are truly identified as non-floods	0.79	0.94	0.86
SVM (RBF)	Predicted Flood (1)	TP=33 33 flood events are truly identified as floods	FP= 13 13 non-flood events were incorrectly predicted as floods	0.72	0.2	0.31
	Predicted Non-Flood (0)	FN= 134 134 flood events were incorrectly identified as non-floods	TN= 471 471 of non-flood events are truly identified as non-floods	0.78	0.97	0.87
LR	Predicted Flood (1)	TP= 43 43 flood events are truly identified as floods	FP= 14 14 non-flood events are incorrectly predicted as floods	0.75	0.26	0.38
	Predicted Non-Flood (0)	FN= 124 124 flood events are incorrectly identified as non-floods	TN= 470 470 of non-flood events are truly identified as non-floods	0.79	0.97	0.87
RF	Predicted Flood (1)	TP=83 83 flood events are truly identified as floods	FP= 2 2 non-flood events are incorrectly predicted as flood	0.98	0.5	0.66
	Predicted Non-Flood (0)	FN= 84 84 flood events are incorrectly identified as non-floods	TN= 482 482 of non-flood events are truly identified as non-floods	0.85	1	0.92

برای اطمینان از صحت کارایی مدل‌ها و عدم وقوع بیش‌برازش از روش اعتبارسنجی متقاطع k-fold (تعداد پنج و هفت) به همراه تنظیم‌نمودن ابرپارامترهای هر مدل با روش جستجوی شبکه‌ای استفاده شده است. برای بررسی این موضوع از روش اجرای هر مدل به صورت جداگانه روی داده‌های آموزشی و آزمایشی استفاده گردید (Bishop &

است. اختلاف ناچیز (حدود ۰/۰۵) نتایج معیارهای ارزیابی در آموزش و آزمون حاکی از تعمیم‌پذیری و پایداری قابل قبول مدل می‌باشد (شکل ۴) (Dietterich, 1998; Kohavi, 1995).




Figure 4. Comparison of RF model performance metrics on training and testing datasets (0 = Non-Flood, 1 = Flood)

۲.۳. مهم‌ترین ویژگی‌ها

با وجود تفاوت در عملکرد مدل‌ها، تمام مدل‌ها به‌جز مدل SVM با هسته سیگموئید، به‌طور متفق ایستگاه‌های ۱ و ۲۳ را به‌عنوان مهم‌ترین ویژگی‌ها در یادگیری ماشین برای پیش‌بینی سیلاب شهری تشخیص دادند. نتایج مربوط به ضریب اهمیت هریک از ایستگاه‌ها (ویژگی‌ها) در جدول (۳) نمایش داده شده است و بیش‌ترین ضریب اهمیت مستخرج از هر مدل به رنگ سبز مشخص می‌باشد.

Table 3. The results of feature importance for three ML models

Feature	SVC Linear	SVC Polynomial	SVC Sigmoid	SVC RBF	LR	RF
Importance						
1	0.6908	0.0040	-0.0007	0.0040	1.2305	0.0676
2	0.1721	0.0001	0.0000	0.0034	0.2982	0.0225
3	0.1721	0.0001	0.0000	0.0010	0.2982	0.0215
4	0.1721	0.0001	0.0000	0.0010	0.2982	0.0240
5	0.1721	0.0001	0.0000	0.0035	0.2982	0.0224
6	0.1721	0.0001	0.0000	0.0034	0.2982	0.0227
7	0.1426	0.0003	0.0006	0.0000	0.1233	0.0397
8	0.1426	0.0003	0.0006	0.0000	0.1233	0.0366
9	0.0175	0.0015	0.0023	0.0035	0.0076	0.0304
10	0.0175	0.0015	0.0023	0.0035	0.0076	0.0360
11	0.0175	0.0015	0.0023	0.0035	0.0076	0.0312
12	0.0480	0.0014	-0.0007	0.0035	0.0812	0.0361
13	0.0480	0.0014	-0.0007	0.0035	0.0812	0.0326
14	0.0175	0.0015	0.0023	0.0034	0.0076	0.0265
15	0.0175	0.0015	0.0023	0.0035	0.0076	0.0345
16	0.0175	0.0015	0.0023	0.0034	0.0076	0.0273
17	0.0480	0.0014	-0.0007	0.0000	0.0812	0.0412
18	0.0480	0.0014	-0.0007	0.0000	0.0812	0.0299
19	0.0175	0.0015	0.0023	0.0035	0.0076	0.0267
20	0.0175	0.0015	0.0023	0.0035	0.0076	0.0318
21	0.0175	0.0015	0.0023	0.0025	0.0076	0.0306
22	0.0480	0.0014	-0.0007	0.0035	0.0812	0.0309
23	0.6502	0.0016	0.0015	0.0034	0.9553	0.0741
24	0.0175	0.0015	0.0023	0.0000	0.0076	0.0327
25	0.0175	0.0015	0.0023	0.0035	0.0076	0.0368
26	0.1602	0.0002	0.0025	0.0035	0.2705	0.0420
27	0.1602	0.0002	0.0025	0.0035	0.2705	0.0422
28	0.0186	0.0001	0.0020	0.0034	0.3411	0.0330
29	0.0186	0.0001	0.0020	0.0034	0.3411	0.0364

۳.۳. نمودار آستانه سیلاب

با توجه به این که مدل RF بیشترین امتیاز را در زمینه‌های دقت و امتیاز F1 در بین تمام مدل‌های مقایسه‌شده در پیش‌بینی رویدادهای سیلاب و غیرسیلاب کسب کرده است، منحنی آستانه بارش بحرانی از روی این مدل استخراج شده و در شکل (۵) نشان داده شده است. با در نظر گرفتن احتمالات ۹۵ و ۹۰ درصد، مقدار بارش‌های بالای آستانه، احتمالاً منجر به سیلاب‌های شهری می‌شود، به‌ویژه در ایستگاه‌های ۱ و ۲۳ که به‌عنوان مهم‌ترین ویژگی‌ها شناسایی شده‌اند. در مقابل، نقاط زیر منحنی احتمال کم‌تری برای وقوع سیل دارند. آستانه‌های بحرانی بارش برای مهم‌ترین ویژگی‌ها (ایستگاه‌های ۱ و ۲۳) در حدود ۵/۸۷ میلی‌متر و ۵/۴۲ میلی‌متر در سطح احتمالی ۹۵ درصد و در حدود ۳/۲۲ میلی‌متر و ۳/۱۷ میلی‌متر در سطح احتمالی ۹۰ درصد اطمینان از درستی تشخیص سیلاب شهری است.




Figure 5. Flood threshold diagrams at probability levels of 95 and 90 percent

۴. بحث

۴.۱. بررسی عملکرد مدل‌های یادگیری ماشین

همان‌طور که پیش‌تر ذکر شد، قم در منطقه‌ای خشک و بیابانی در قسمت مرکزی ایران قرار دارد. بنابراین، سیلاب‌های ناگهانی اغلب منجر به جریان‌های سطحی، آب‌گرفتگی خیابانی، اختلال در حمل و نقل، خسارت به اموال و در موارد نادر، خطرات جانی می‌شوند. نسبت هشدارهای نادرست (FP) بالا می‌تواند اعتماد عمومی را تضعیف کرده، تمایل مردم به پاسخگویی به سیستم‌های هشداردهنده را کاهش دهد (Barnes et al., 2007; Nikolopoulos et al., 2014; Staley et al., 2013). دقیقاً به همین منظور، مفهوم دقت مطرح می‌شود که نشان می‌دهد چند درصد از پیش‌بینی‌های سیلاب، واقعاً درست بوده‌اند. برعکس، زمانی که هدف اصلی شناسایی تمامی رخداد‌های سیلاب است و در شرایطی که حتی عدم پیش‌بینی یک مورد، مخاطرات جدی در پی دارد، معیار حساسیت اهمیت پیدا می‌کند تا میزان توانایی مدل در تشخیص تمامی سیلاب‌ها ارزیابی شود.

در این مطالعه، نقش دقت بسیار مهم است و همراه با امتیاز F1، کارایی مدل‌های یادگیری ماشین را نشان می‌دهد. مدل RF بیش‌ترین نمره‌ها را هم در تشخیص سیلاب و هم در عدم وقوع آن دارد. با دقت ۹۸ درصد، حساسیت ۵۰ درصد و نمره F1 برابر با ۶۶ درصد برای رویدادهای سیلاب و دقت، حساسیت و نمره F1 به‌ترتیب ۸۵، ۱۰۰ و ۹۲ درصد در موارد عدم سیلاب.

۲.۴. ارزیابی نمودار آستانه سیلاب

اطلاعات بارش باران روزانه مرتبط با دوازده رویداد با بیش‌ترین مجموع گزارش‌ها در پایگاه داده‌ها (بیش از ۲۰۰ گزارش در روز) مورد استفاده قرار گرفت تا کارایی منحنی‌های آستانه بحرانی سیلاب در سطوح احتمال ۱۰۰، ۹۵ و ۹۰ درصد ارزیابی شود. مطابق شکل (۶)، در آستانه احتمال ۱۰۰ درصد، تنها چهار رویداد (A، H، C و K) در تمامی ایستگاه‌ها بالای نقاط آستانه سیلاب قرار می‌گیرند که نشان‌دهنده وقوع قطعی سیلاب ناشی از بارش است. آستانه ۹۰ درصد تمام رویدادهای سیلاب را با موفقیت شناسایی می‌کند، بدون این‌که سیلابی را از دست بدهد، به‌ویژه در نقاط ۱ و ۲۳. بنابراین، نصب باران‌سنج در این مکان‌ها می‌تواند به تحلیل الگوهای سیلاب و بهبود سیستم‌های هشدار سریع در شهر کمک کند.




Figure 6. Flood threshold evaluation at probability levels of 100, 95, and 90 percent based on 12 real events (A to L) with more than 200 reports (rpt)

۳.۴. محدودیت‌های پژوهش

با این‌که گزارش‌های شهروندان می‌توانند جایگزین ارزشمندی برای مدل‌های هیدرولوژیکی و هیدرولیکی پیچیده باشند، همچنان ابهاماتی وجود دارد، مانند تأخیر زمانی در دریافت گزارش‌ها. ممکن است بارندگی در شب رخ داده و گزارش‌ها در روز بعد ثبت شوند یا این‌که مشکلات ناشی از بارندگی پس از گذشت زمان ایجاد شده باشند. علاوه بر این، به‌روزرسانی‌ها و ارتقای دوره‌ای شبکه زه‌کشی شهری آب نیز در نظر گرفته نشده است. تراکم جمعیتی نیز بر حجم گزارش‌ها تأثیر دارند، مناطق پر جمعیت معمولاً گزارش‌های بیش‌تری دارند.

۵. نتیجه‌گیری و پیشنهادها

گزارش‌های سیلاب ثبت‌شده توسط شهروندان، داده‌های بارش و مدل‌های یادگیری ماشین، نقش قابل‌اعتمادی در جایگزینی مدل‌های هیدرولیکی و هیدرولوژیکی در پیش‌بینی سیلاب‌های شهری در قم، ایران را دارند. این نتیجه با یافته‌های پژوهش‌های دیگر مبنی بر تأیید کارایی تلفیق اطلاعات میدانی توده مردم و روش‌های عددی همسو است (Ke et al., 2020; Wasko et al., 2021).

نتایج در توافق با سایر مطالعات (Yang and Cervone, 2019) نشان می‌دهد که مدل جنگل تصادفی بیش‌ترین انطباق در پیش‌بینی سیلاب شهری را ارائه داده است؛ با معیارهایی مانند دقت ۹۸ درصد و امتیاز F1، ۶۶ درصد برای رویدادهای سیلاب و دقت و امتیاز F1 به‌ترتیب ۸۵ و ۹۲ درصد برای رویدادهای غیرسیلاب. با توجه به آب‌وهوای بیابانی منطقه مورد مطالعه و درجات غیرمهلک آسیب سیلاب شهری، توجه پژوهش بر معیار سنجش دقت، برای کارایی مدل است تا از شناسایی درست رویدادهای سیلاب اطمینان حاصل شده و تعداد پیش‌بینی‌های نادرست سیلاب کاهش یابد. این دیدگاه در پژوهش‌ها دیگر به مسئله پرداخته نشده است.

تهیه روش‌های ساده کاربرپسند به‌عنوان سیستم هشدار سیلاب به‌ویژه در شهرهای ساحلی و پرباران در مطالعات دیگر با استفاده از اطلاعات آماری و نرم‌افزاری صورت گرفته است (Martina et al., 2006; Tian et al., 2019). در این مطالعه به‌عنوان نوآوری با تمرکز بر مهم‌ترین ویژگی‌ها و استفاده از یادگیری ماشین، آستانه بارش بحرانی منجر به وقوع سیلاب در سطوح احتمالاتی ۱۰۰، ۹۵ و ۹۰ درصد با مشاهدات میدانی رویدادها ارزیابی شده و مشخص گشت سطح احتمال ۹۰ درصد به‌عنوان مؤثرترین آستانه سیلاب می‌باشد و بارش‌های متناظر با وقوع سیلاب بالای آن قرار می‌گیرند. مهم‌تر این‌که، با تمرکز بر روی ایستگاه‌های ۱ و ۲۳ به‌عنوان مکان‌های مهم‌ترین ویژگی‌ها برای پیش‌بینی سیلاب‌های ناشی از بارش، می‌توان به جانمایی برای راه‌اندازی ایستگاه‌های باران‌سنجی دست یافت. یافته‌ها بر نیاز به مکانیزم‌های بهبود یافته گزارش‌دهی در زمان و مختصات جغرافیایی واقعی مانند برنامه‌های موبایل برای افزایش قابلیت اطمینان مدل‌ها تأکید می‌کنند. این پیشنهاد در برخی مطالعات دیگر نیز تأکید شده است (Hill et al., 2023; Safaei-Moghadam et al., 2024).

۶. پی‌نوشت‌ها

1. Support Vector Machines (SVMs)
2. Random Forests (RFs)
3. Ensemble Neural Networks (ENNs)
4. Logistic Regression (LR)
5. eXtreme Gradient Boosting (XGBoost)
6. Classification
7. Global Surface Water Mapper (GSMap)
8. Features
9. Imbalance
10. Confusion Matrix
11. Precision
12. Recall
13. F1-score
14. Overfitting
15. K-fold cross validation
16. Kernel
17. Linear
18. Polynomial
19. Sigmoid
20. Radial Basis Function (RBF)
21. Bagging
22. Tuning

23. GridsearchCV
24. Accuracy
25. True Negative
26. True Positive
27. False Negative
28. False Positive

۷. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۸. منابع

- Barnes, L. R., Gruntfest, E. C., Hayden, M. H., Schultz, D. M., & Benight, C. (2007). False alarms and close calls: A conceptual model of warning accuracy. *Weather and Forecasting*, 22(5), 1140-1147.
- Beecham, S., & Chowdhury, R. (2012, May). Effects of changing rainfall patterns on WSUD in Australia. In *Proceedings of the Institution of Civil Engineers-Water Management* (Vol. 165, No. 5, pp. 285-298). Thomas Telford Ltd.
- Berkhahn, S., Fuchs, L., & Neuweiler, I. (2019). An ensemble neural network model for real-time prediction of urban floods. *Journal of hydrology*, 575, 743-754.
- Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4). Springer .
- Dietterich, T. G. (1998). Approximate statistical tests for comparing supervised classification learning algorithms. *Neural computation*, 10(7), 1895-1923.
- Feng, Q., Liu, J., & Gong, J. (2015). Urban flood mapping based on unmanned aerial vehicle remote sensing and random forest classifier-A case of Yuyao, China. *Water*, 7(4), 1437-1455.
- Ghosh, B., Garg, S., & Motagh, M. (2022). Automatic flood detection from sentinel-1 data using deep learning architectures. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3, 201-208.
- Golabi, M. R., Radmanesh, F., Akhoond-Ali, A. M., Niksokhan, M. H., & Kisi, O. (2020). Development of an indirect method for modelling the water footprint of electricity using wavelet transform coupled with the random forest model. *Hydrological Sciences Journal*, 65(15), 2521-2534.
- Hassani, M. R., Niksokhan, M. H., Janbehsarai, S. F. M., & Nikoo, M. R. (2024). Integrated nonurban-urban flood management using multi-objective optimization of LIDs and detention dams based on game theory approach. *Journal of Cleaner Production*, 142737.
- Heydarian, M., Doyle, T. E., & Samavi, R. (2022). MLCM: Multi-label confusion matrix. *Ieee Access*, 10, 19083-19095.
- Hill, B., Liang, Q., Boshier, L., Chen, H., & Nicholson, A. (2023). A systematic review of natural flood management modelling: Approaches, limitations, and potential solutions. *Journal of Flood Risk Management*, 16(3), e12899.
- Ke, Q., Tian, X., Bricker, J., Tian, Z., Guan, G., Cai, H., Huang, X., Yang, H., & Liu, J. (2020). Urban pluvial flooding prediction by machine learning approaches—a case study of Shenzhen city, China. *Advances in Water Resources*, 145, 103719.
- Kim, H. I., Han, K. Y., & Lee, J. Y. (2020). Prediction of urban flood extent by LSTM model and logistic regression. *KSCE Journal of Civil and Environmental Engineering Research*, 40(3), 273-283.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *Ijcai*.
- Lee, S., Kim, J.-C., Jung, H.-S., Lee, M. J., & Lee, S. (2017). Spatial prediction of flood susceptibility using random-forest and boosted-tree models in Seoul metropolitan city, Korea. *Geomatics, Natural Hazards and Risk*, 8(2), 1185-1203.
- Liu, Y., Zhang, X., Liu, J., Wang, Y., Jia, H., & Tao, S. (2025). A flood resilience assessment method of green-grey-blue coupled urban drainage system considering backwater effects. *Ecological Indicators*, 170, 113032.
- Martina, M., Todini, E., & Libralon, A. (2006). A Bayesian decision approach to rainfall thresholds based flood warning. *Hydrology and earth system sciences*, 10(3), 413-426.

- Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Overfitting, model tuning, and evaluation of prediction performance. In *Multivariate statistical machine learning methods for genomic prediction* (pp. 109-139). Springer.
- Nikolopoulos, E. I., Crema, S., Marchi, L., Marra, F., Guzzetti, F., & Borga, M. (2014). Impact of uncertainty in rainfall estimation on the identification of rainfall thresholds for debris flow occurrence. *Geomorphology*, 221, 286-297.
- O'Shea, D., Nathan, R., Wasko, C., Ho, M., & Sharma, A. (2024). Evaluation of key flood risk drivers under climate change using a bottom-up approach. *Journal of Hydrology*, 640, 131694.
- Panahi, D. M., Destouni, G., Kalantari, Z., & Zahabiyoun, B. (2022). Distinction of driver contributions to wetland decline and their associated basin hydrology around Iran. *Journal of Hydrology: Regional Studies*, 42, 101126.
- Priyambodoho, B. A., Kure, S., Yagi, R., & Januriyadi, N. F. (2021). Flood inundation simulations based on GSMap satellite rainfall data in Jakarta, Indonesia. *Progress in Earth and Planetary Science*, 8(1), 34.
- Rifath, A. R., Muktadir, M. G., Hasan, M., & Islam, M. A. (2024). Flash flood prediction modeling in the hilly regions of Southeastern Bangladesh: A machine learning attempt on present and future climate scenarios. *Environmental Challenges*, 17, 101029.
- Safaei-Moghadam, A., Hosseinzadeh, A., & Minsker, B. (2024). Predicting real-time roadway pluvial flood risk: A hybrid machine learning approach coupling a graph-based flood spreading model, historical vulnerabilities, and Waze data. *Journal of Hydrology*, 131406.
- Staley, D. M., Kean, J. W., Cannon, S. H., Schmidt, K. M., & Laber, J. L. (2013). Objective definition of rainfall intensity-duration thresholds for the initiation of post-fire debris flows in southern California. *Landslides*, 10, 547-562.
- Tang, X., Machimura, T., Li, J., Yu, H., & Liu, W. (2022). Evaluating seasonal wildfire susceptibility and wildfire threats to local ecosystems in the largest forested area of China. *Earth's Future*, 10(5), e2021EF002199.
- Tanim, A. H., McRae, C. B., Tavakol-Davani, H., & Goharian, E. (2022). Flood detection in urban areas using satellite imagery and machine learning. *Water*, 14(7), 1140.
- Tella, A., Mustafa, M. R. U., Balogun, A. O., Okolie, C. J., Bello Yamusa, I., & Ibrahim, M. (2023). Spatial prediction of flood in Kuala Lumpur City of Malaysia using logistic regression. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 48, 363-369.
- Tian, X., Schleiss, M., Bouwens, C., & van de Giesen, N. (2019). Critical rainfall thresholds for urban pluvial flooding inferred from citizen observations. *Science of the total environment*, 689, 258-268.
- Wasko, C., Nathan, R., Stein, L., & O'Shea, D. (2021). Evidence of shorter more extreme rainfalls and increased flood variability under climate change. *Journal of Hydrology*, 603, 126994.
- Yan, J., Jin, J., Chen, F., Yu, G., Yin, H., & Wang, W. (2018). Urban flash flood forecast using support vector machine and numerical simulation. *Journal of Hydroinformatics*, 20(1), 221-231.
- Yang, L., & Cervone, G. (2019). Analysis of remote sensing imagery for disaster assessment using deep learning: a case study of flooding event. *Soft Computing*, 23(24), 13393-13408.
- Yuan, H., Wang, M., Zhang, D., Ikram, R. M. A., Su, J., Zhou, S., Wang, Y., Li, J., & Zhang, Q. (2024). Data-driven urban configuration optimization: An XGBoost-based approach for mitigating flood susceptibility and enhancing economic contribution. *Ecological Indicators*, 166, 112247.