پژوهش های آبخیزداری
شاپا: ۲۰۳۸-۲۹۸۱
مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی فارس
سازمان تحقیقات، آموزش و ترویج کشاورزی

یادگیری تقویتی چارچوبی به‌منظور پهنه‌بندی سیل در مناطق کوهستانی با استفاده از مدل Deep Q-Learning

صالح یوسفی*[۱]، سارا مردانیان[۲] احمدرضا کریمی‌پور[۳]

۱- استادیار بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع‌طبیعی استان چهارمحال و بختیاری، سازمان تحقیقات، آموزش و ترویج کشاورزی، شهرکرد، ایران

۲- محقق بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع‌طبیعی استان چهارمحال و بختیاری، سازمان تحقیقات، آموزش و ترویج کشاورزی، شهرکرد، ایران

۳- مربی بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع‌طبیعی استان چهارمحال و بختیاری، سازمان تحقیقات، آموزش و ترویج کشاورزی، شهرکرد، ایران

چکیدهٔ مبسوط

مقدمه و هدف

درک خطر سیلاب‌ها و تلاش برای کاهش آن از اولویت‌های اصلی پژوهشگران و سیاست‌گذاران است. پهنه‌بندی حساسیت به سیلاب ابزار مهمی برای مدیریت خطر در مناطق کوهستانی به‌شمار می‌آید. زیرا، می‌توان مناطق آسیب‌پذیر را شناسایی کرد و بستر برنامه‌ریزی مکانی، آمادگی و اقدامات پیشگیرانه را فراهم آورد. رویکردهای سنتی نقشه‌برداری سیلاب مانند مدل‌سازی آب‌شناختی و تحلیل داده‌های تاریخی اغلب با محدودیت‌هایی چون کمبود داده، پیچیدگی محاسباتی و پویایی ساختارهای محیطی روبه‌رو هستند. ازاین‌رو، روش‌های نوین هوش مصنوعی به‌ویژه یادگیری ماشین و یادگیری تقویتی برای پردازش داده‌های گوناگون و شناسایی الگوهای پیچیده به‌کار گرفته شده‌اند. در میان رویکردهای هوش مصنوعی، یادگیری تقویتی به‌دلیل قابلیت تعامل با محیط و بهبود تدریجی تصمیم‌گیری، نویدبخش است. با به‌کارگیری مدل Deep Q-Learning (DQL) به‌عنوان یکی از روش‌های پیشرفته یادگیری تقویتی، می‌توان امکان کار با فضاهای حالت پیوسته و ابعاد بزرگ بدون نیاز به گسسته‌سازی را فراهم آرود. این پژوهش با هدف بهره‌گیری از مدل DQL برای تهیه نقشه حساسیت به سیلاب در استان چهارمحال و بختیاری با مناطق کوهستانی نیمه‌خشک و آسیب‌پذیر از سیلاب‌های ناگهانی ناشی از ذوب برف و بارش‌های شدید، انجام شد. هدف اصلی، ارزیابی خطر سیلاب و ارائه چارچوبی دقیق برای سیاست‌گذاران به‌منظور مدیریت بحران، کاهش خطر و بهبود تاب‌آوری به‌ویژه در شهرستان‌های آسیب‌پذیر همچون اردل و لردگان بود.

نوع مقاله: پژوهشی
***مسئول مکاتبات:** ssaleh.yousefi@gmail.com
استناد: یوسفی، ص.، مردانیان، س.، کریمی‌پور، ا.ر. ۱۴۰۵. یادگیری تقویتی چارچوبی به‌منظور پهنه‌بندی سیل در مناطق کوهستانی با استفاده از مدل Deep Q-Learning. پژوهش‌های آبخیزداری. ۳۹(۳): ۷۸-۶۴.

شناسهٔ دیجیتال: 10.22092/wmrj.2026.371991.1656

تاریخ دریافت: ۱۴۰۴/۱۰/۱۷، **تاریخ بازنگری:** ۱۴۰۴/۱۱/۲۹، **تاریخ پذیرش:** ۱۴۰۴/۱۲/۲۸، **تاریخ انتشار:** ۱۴۰۵/۰۷/۰۱

پژوهش‌های آبخیزداری، سال ۱۴۰۵، دورهٔ ۳۹، شمارهٔ ۳، شمارهٔ پیاپی ۱۵۲، پاییز ۱۴۰۵، صفحه‌های ۶۴ تا ۷۸.

ناشر: مرکز تحقیقات و آموزش کشاورزی و منابع‌طبیعی استان فارس

© نویسندگان
CC BY

مواد و روش‌ها

برای انجام این پژوهش، فهرست رخدادهای سیل شامل ۵۴۵ نقطه مکانی (۳۴۶ نقطه با سیلاب و ۱۹۹ نقطه بدون سیلاب) در بازه زمانی ۱۹۸۳ تا ۲۰۲۳ گردآوری شد. به‌طور تصادفی و لایه‌ای، ۷۱٪ از داده‌ها برای آموزش (۳۸۹ نقطه) و ۲۹٪ آن برای آزمون (۱۵۶ نقطه) استفاده شد. ابتدا ۲۱ متغیر محیطی از منابع مختلف شامل مدل رقومی ارتفاع، سری زمانی اقلیمی، تصویرهای لندست ۹ و پایگاه SoilGrid استخراج شد. پس از انجام تحلیل هم‌خطی، چهار متغیر حذف و ۱۷ متغیر نهایی (بلندی، تجمع جریان، جهت جریان، پیوستگی جریان، جهت جغرافیایی، طول شیب، انحنای افقی، نیم‌رخ، شاخص رطوبت پستی‌بلندی، ژرفا تا بستر سنگی، بیشینه بارش ۲۴ ساعته، دماهای میانگین و بیشینه، ژرفای برف، NDVI، درصد ماسه سطحی و فاصله از مناطق مسکونی) انتخاب شد. از مدل Deep Q-Learning برای پردازش متغیرهای پیوسته و تولید نقشه حساسیت به سیلاب استفاده شد. این نقشه به پنج رده (خیلی‌کم تا خیلی‌زیاد) طبقه‌بندی شد. دقت مدل به‌وسیلهٔ شاخص‌هایی مانند AUC، Kappa، Recall، Precision، Specificity و LogLoss ارزیابی شد.

نتایج و بحث

نقشه طبقه‌بندی با استفاده از مدل Deep Q-Learning (DQL) و بر اساس روش Natural break تهیه شد. در این نقشه، سطح منطقه مطالعه‌شده (۱۶۵۵۳۰۰ هکتار) به پنج طبقهٔ حساسیت به سیلاب شامل خیلی‌کم (۶٪، برابر با ۹۷۲۲۱ هکتار)، کم (۲۰٪، برابر با ۳۳۶۱۹۰ هکتار)، متوسط (۲۶٪، برابر با ۴۲۹۴۵۳ هکتار)، زیاد (۲۶٪، برابر با ۴۳۵۲۹۳ هکتار) و خیلی‌زیاد (۲۲٪، برابر با ۳۵۷۱۴۰ هکتار) تقسیم شد. شاخص‌های ارزیابی دقت، نشان‌دهنده کارایی بسیارخوب مدل بودند. نتایج شاخص AUC (۰/۹۳) بیانگر توانایی تفکیک عالی، شاخص Kappa (۰/۷۲) بیانگر توافق قابل‌قبول میان پیش‌بینی و واقعیت، شاخص Recall (۰/۸۷) بیانگر شناسایی زیاد نقاط سیلابی، بود. شاخص Precision برابر با ۰/۹۰ ، Specificity برابر با ۰/۸۵ و LogLoss برابر ۰/۶۵، محاسبه شد. تحلیل اهمیت متغیرها نشان داد بیشترین اثر مربوط به ژرفای برف بود که بر ذوب برف در سیلاب‌های بهاره بسیار اثرگذار است. پس از آن تجمع جریان (ویژگی‌های پستی‌بلندی)، فاصله از مناطق مسکونی (اثرات انسانی و توسعه شهری)، شاخص NDVI (پوشش گیاهی و نفوذپذیری)، دمای میانگین (شرایط اقلیمی) و طول شیب بودند. مناطق با حساسیت خیلی‌زیاد عمدتاً در نواحی پست، دره‌ها و امتداد رودهای اصلی مانند کارون و زاینده‌رود به‌ویژه در شهرستان‌های اردل و لردگان بودند. مقایسه نتایج این پژوهش با پژوهش‌های مشابه مبتنی بر مدل‌های یادگیری ماشین نظارت‌شده نشان داد که با کاربرد مدل DQL می‌توان خطر سیلاب در محیط‌های ناهمگن کوهستانی را به‌طور قابل قبول‌تری پیش‌بینی کرد و خطر سیلاب را با دقت بیشتری مدیریت کرد.

نتیجه‌گیری و پیشنهادها

نتایج این پژوهش بیانگر آن بود که مدل Deep Q-Learning (DQL) به‌عنوان یک روش یادگیری تقویتی عمیق، کارایی زیادی در پهنه‌بندی حساسیت به سیلاب به‌ویژه در مناطق پیچیده کوهستانی مانند استان چهارمحال و بختیاری دارد. با بهره‌گیری از این مدل و با پردازش متغیرهای محیطی پیوسته و شناسایی دقیق روابط غیرخطی، نقشه‌های معتبر و کاربردی تولید شد و بر اساس آن مناطق پرخطر به‌طور دقیق شناسایی شد. نتایج این پژوهش مؤید آن است که عامل‌های اصلی سیلاب در منطقه مطالعه‌شده شامل ذوب برف، ویژگی‌های پستی‌بلندی، توسعه انسانی و کاهش پوشش گیاهی است. این یافته‌ها با واقعیت‌های میدانی منطقه نیز هم‌راستا بود. از نقشه‌های تولیدشده می‌توان به‌عنوان الگوی عملی برای برنامه‌ریزی کاربری زمین، بهبود زیرساخت‌های دفع آب باران، حفاظت از مناطق مسکونی در برابر سیلاب‌های ناگهانی و بازسازی بوم‌سازگان‌های گیاهی به‌منظور افزایش نفوذپذیری خاک استفاده کرد. به‌طور کلی، نتایج این پژوهش رویکرد نوین و چارچوب دقیقی برای مدیریت پایدار خطر سیلاب در مناطق مشابه ایران و جهان ارائه داد که سیاست‌گذاران می‌توانند در بهبود تاب‌آوری جوامع محلی از آن بهره ببرند. برای بهبود دقت مدل در

پژوهش‌های آینده، پیشنهاد می‌شود فهرست گسترده‌تری از رخدادهای سیلاب با داده‌های فصلی و زمانی دقیق‌تر گردآوری شود و متغیرهای پویا مانند تغییرات روزانه دما و چرخه‌های ذوب برف نیز بررسی شوند. افزون بر این، پیشنهاد می‌شود اعتبارسنجی میدانی گسترده‌تری به‌ویژه در بلندی‌های زیاد و مناطق شهری انجام شود. همچنین، ترکیب DQL با دیگر روش‌های یادگیری تقویتی یا مدل‌های ترکیبی به‌منظور افزایش کارایی آن پیشنهاد می‌شود.

واژگان کلیدی
ارزیابی خطر سیل، بلندی‌های ایران، یادگیری تقویتی، یادگیری ماشین

مقدمه

درک خطر سیلاب‌ها و تلاش برای کاهش آن از اولویت‌های اصلی پژوهشگران و سیاست‌گذاران است (خارزمی و همکاران ۲۰۱۸، کوندولف و همکاران ۲۰۰۷، محمدی و همکاران ۲۰۲۵ و یال و تالوکدار ۲۰۱۸). بررسی سیلاب‌ها افزون بر کمی‌سازی اثرات آنها، برای توسعه راهبردهای کاهش خطر، سازگاری و تاب‌آوری اهمیت دارد (باری و همکاران ۲۰۲۳). نقشه‌برداری حساسیت به سیلاب ابزار مهمی در مدیریت خطر است. زیرا، می‌توان مناطق آسیب‌پذیر را شناسایی کرد و بستر برنامه‌ریزی مکانی، آمادگی و اقدامات پیشگیرانه فراهم آورد (عربامری و همکاران ۲۰۲۲، دوان ۲۰۱۳، حسین و مومو ۲۰۲۴). افزون بر این، نقشه‌برداری حساسیت به سیلاب پشتوانهٔ راهبردهای سازگاری با اقلیم است. زیرا، با شناسایی مناطقی با زیرساخت‌های سبز مانند تالاب‌ها یا حوضچه‌های ذخیره، می‌توان اثرات سیلاب را کاهش داد (باتزر ساریتز ۲۰۰۷، چن ۲۰۲۰). رویکردهای سنتی نقشه‌برداری سیلاب مانند مدل‌سازی آب‌شناختی و تحلیل داده‌های تاریخی سیلاب غالباً با محدودیت‌هایی مانند کمبود داده، پیچیدگی محاسباتی و پویایی ساختارهای محیطی، روبه‌رو هستند (هال و همکاران ۲۰۱۴). ازاین‌رو، روش‌های نوین مانند هوش مصنوعی[1](AI) و به‌ویژه یادگیری ماشین[2] (ML) و یادگیری عمیق[3] (DL) به‌کار گرفته شده‌اند تا بتوان داده‌های گوناگون را با دقت زیاد پردازش و الگوهای پیچیده را شناسایی کرد (آلسومایت و همکاران ۲۰۲۴، زو و همکاران ۲۰۲۴،۲۰۱۹ و خان و همکاران ۲۰۲۳). در میان رویکردهای AI، یادگیری تقویتی (RL)[4] به‌دلیل قابلیت تعامل با محیط و بهبود تدریجی تصمیم‌گیری، نویدبخش است و امکان سازگاری با شرایط پویا و نامطمئن را دارد (بواس و همکاران ۲۰۲۱، کویین و همکاران ۲۰۲۴). مدل‌های یادگیری تقویتی مبتنی بر یادگیری عمیق (DL-based RL) برای بهبود تاب‌آوری در سامانه‌های زهکشی شهری توسعه‌داده شدند و مشخص شد که این مدل‌ها با کاهش سیلاب و سرریز فاضلاب‌های ترکیبی، موجب بهبود تاب‌آوری می‌شوند (تیان و همکاران ۲۰۲۵). بویاس و همکاران (۲۰۲۱) کارایی RL را برای مهار بلادرنگ آب‌های سطحی در نورفولک، ویرجینیا ارزیابی کردند و دریافتند که در مقایسه با سامانه‌های غیرفعال و مبتنی بر قواعد که با وجود بهبود کیفیت آب موجب افزایش سیلاب می‌شوند، با کاربرد RL چهار درصد سیلاب و ۵۲٪ خروجی TSS کاهش یافت که موضوع نشان‌دهندهٔ کارایی زیاد آن در سطح ساختار بود. بر اساس پژوهش‌های تیان و همکاران (۲۰۲۳)، RL مدیریت زهکشی شهری را برای کاهش سیلاب بهبود بخشید. با یادگیری ایمن، سطح آب کاهش یافت و دفعات باز و بسته‌شدن دریچه‌ها نیز کمتر شد. در پژوهشی، فنگ و همکاران (۲۰۲۶) کارایی روش یادگیری تقویتی در

1- Artificial Intelligence
2- Machine Learning
3- Deep Learning
4- Reinforcement Learning

مدل‌سازی و اطلاع‌رسانی در تصمیم‌گیری‌های اقلیمی تطبیقی به‌منظور کاهش خطر سیل در شهر منهتن در ایالات متحده آمریکا را بررسی کردند. نتایج ایشان نشان داد که هنگام طراحی دیوارهای ساحلی تطبیقی برای محافظت از نیویورک، راهبرد برگرفته از RL به‌طور قابل توجهی هزینه خالص مد نظر را تا ۷۷٪ کاهش داد. لی و وانگ (۲۰۲۵) مسیر نجات برای سیل شهری تحت یک رویکرد مبتنی بر یادگیری تقویتی عمیق را برنامه‌ریزی و بررسی کردند. در پژوهش نامبرده با گسترش مقیاس سناریوها به سطوح بی‌سابقه، پیشرفت نظری در برنامه‌ریزی مسیر نجات سیل شهری، بهبود یافت. بر اساس نتایج پژوهش‌ها تاکنون از مدل DQL و یادگیری تقویتی برای پهنه‌بندی مخاطرات طبیعی و به‌ویژه سیلاب در داخل کشور استفاده‌نشده است. ازاین‌رو، این پژوهش در این زمینه برای اولین بار با هدف بهره‌گیری از روش یادگیری تقویتی و مدل DQL برای توسعه چارچوب نقشه‌برداری حساسیت سیلاب در استان چهارمحال و بختیاری ایران انجام شد. این منطقه کوهستانی و آسیب‌پذیر از سیلاب‌های ناگهانی بود. در این پژوهش، با ترکیب داده‌های آموزشی دقیق و RL، نقشه‌های کاربردی تولید شد که سیاست‌گذاران می‌توانند از آنها در مدیریت بحران، کاهش خطر و بهبود تاب‌آوری، بهره ببرند.

مواد و روش‌ها

معرفی منطقهٔ مطالعه‌شده

منطقه پژوهشی، استان چهارمحال و بختیاری در جنوب‌غربی ایران است (شکل ۱). این استان کوهستانی با مساحت حدود ۱۶۵۵۳ کیلومترمربع در برگیرندهٔ یک درصد از مساحت کل ایران است (یوسفی و همکاران ۲۰۲۲). موقعیت استان در گستره کوه‌های زاگرس به دامنه‌های تند، دره‌های ژرف و شبکه‌های زهکشی گسترده‌ای منجرشده که در پویایی‌های آب‌شناختی منطقه نقش قابل‌توجهی دارد (یوسفی و همکاران ۲۰۲۰).

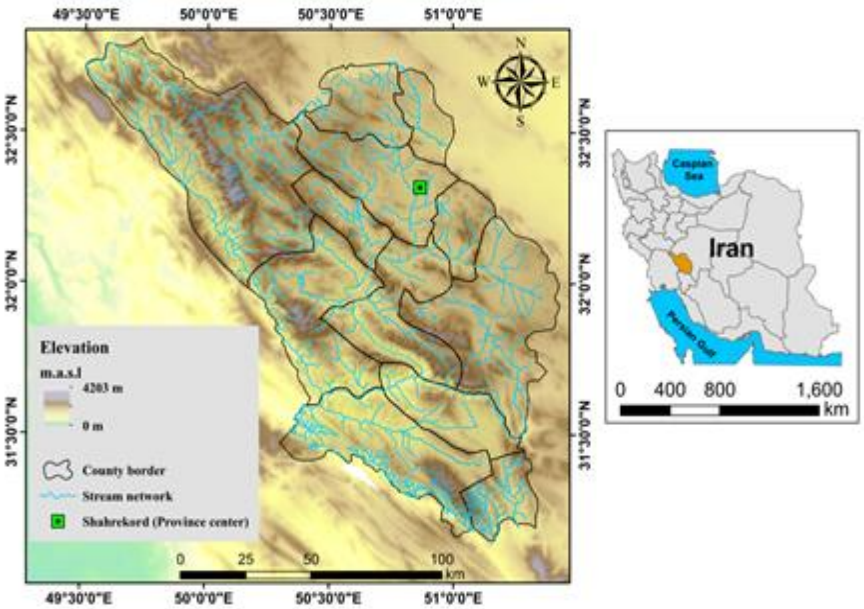

شکل ۱- موقعیت جغرافیایی استان چهارمحال و بختیاری در ایران.

Figure 1- Geographic location of Chaharmahal and Bakhtiari Province in Iran.

در استان نامبرده، رخدادهای بارشی شدید در اواخر زمستان و اوایل بهار اغلب موجب سیلاب‌های ناگهانی و سیلاب‌های رودخانه‌ای می‌شوند (آردالی و همکاران ۲۰۱۵؛ (نقیبی و پورقاسمی ۲۰۱۵). رخدادهای سالانه سیلاب در استان باعث خسارت‌های قابل‌توجهی به زیرساخت‌ها، زمین‌های کشاورزی و جوامع محلی

می‌شوند که اثرات بارزی بر نواحی پست همچون شهرستان‌های لردگان و اردل دارند. نمایی از خسارت‌های واردشده ناشی از سیلاب در منطقه بارده در سال ۱۳۹۹ در شکل ۲ نشان‌داده شده است.

شکل ۲- خسارت سیلاب در روستای بارده فروردین ۱۳۹۹.
Figure 2- Flood damage in Barde Village, Farvardin 2020.

روش پژوهش

متغیرهای شرطی

در این پژوهش، برای تهیه نقشه‌های حساسیت به سیلاب استان چهارمحال و بختیاری، از ۲۱ متغیر محیطی استفاده شد. متغیرها از منابع داده پرشماری گردآوری شدند. این منابع شامل مدل رقومی ارتفاع (DEM)[5] تولیدشده از نقشه‌های پستی‌بلندی (مقیاس ۱:۲۵،۰۰۰)، سری زمانی اقلیمی ۴۰ ساله (۱۹۸۳-۲۰۲۳) از ایستگاه‌های اقلیمی منطقه‌ای، شاخص پوشش گیاهی تفاضلی بهنجارشده (NDVI)[6] از تصویرهای ماهواره‌ای لندست ۹ و داده‌های خاک از پایگاه SoilGrid (شبکه۳۰×۳۰ متر) بودند (اینی و همکاران ۲۰۲۰ف پورقاسمی و همکاران ۲۰۱۹ و رمضانی و همکاران ۲۰۰۹). متغیرها در چهار دسته پستی‌بلندی، اقلیمی، پوشش زمین و انسانی سازماندهی شدند تا تحلیل و تفسیر آسان شود.

داده‌های موجودی سیلاب

داده‌های استفاده‌شده برای آموزش و ارزیابی مدل شامل ۵۴۵ نقطه مکانی در استان چهارمحال و بختیاری بود. از این تعداد، ۳۴۶ نقطه با سیلاب (برگرفته از رخدادهای مستند سیلاب در نواحی پست و در امتداد رودهایی چون زاینده‌رود و کارون) و ۱۹۹ نقطه بدون سیلاب (مناطق مشابه از نظر شرایط محیطی اما بدون سابقه سیلاب) بود. این داده‌ها در بازه زمانی ۲۰۲۳-۱۹۸۳ از منابع مختلف شامل سوابق شرکت آب منطقه‌ای، گزارش‌های مدیریت بحران و بازدیدهای میدانی گردآوری شدند (پورقاسمی و همکاران ۲۰۲۱ و سلطانی و همکاران ۲۰۲۱). برای مدل‌سازی، داده‌ها به‌طور تصادفی و با رویکرد لایه‌ای در پایتون به دو بخش آموزش و آزمون تقسیم شدند. بخش آموزش شامل ۳۸۹ نقطه (۲۵۲ نقطه با سیلاب، ۱۳۷ نقطه بدون سیلاب؛ برابر با ۷۱٪ کل داده‌ها) برای آموزش

5- Digital Elevation Model
6- Normalized Difference Vegetation Index

الگوریتم DQL و بخش آزمون ۱۵۶ نقطه (۹۴ نقطه با سیلاب، ۶۲ نقطه بدون سیلاب؛ برابر با ۲۹٪ کل داده‌ها) برای ارزیابی مدل تقسیم شدند.

این روش موجب شد نسبت نقاط با سیلاب و بدون سیلاب حفظ شده و سوگیری کاهش یابد. توزیع مکانی نقاط در شکل ۳ نشان‌داده شده است.

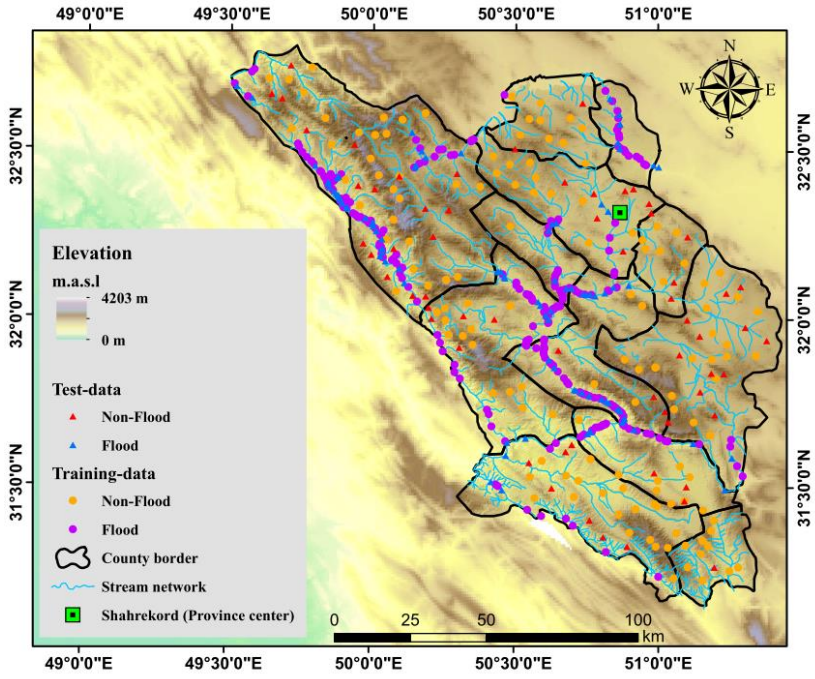

شکل ۳- توزیع مکانی نقاط با سیلاب و بدون سیلاب.

Figure 3- Spatial distribution of flood and non-flood points.

کاربرد مدل‌های یادگیری تقویتی

در این پژوهش از مدل یادگیری تقویتی (RL) و یادگیری عمیق Deep Q-Learning برای تهیه نقشه‌های حساسیت به سیلاب استان چهارمحال و بختیاری استفاده شد. یادگیری تقویتی یک الگوی یادگیری ماشین است که در آن یک عامل با تعامل با محیط و دریافت پاداش‌ها یا تنبیه‌ها بر اساس اقدام‌هایش می‌آموزد تصمیم‌های بهینه اتخاذ کند (سمید و همکاران ۲۰۰۹).

یادگیری عمیق (DQL)

در روش یادگیری تقویتی برای مدل DQL، می‌توان اندازهٔ Q را در QL با استفاده از یک شبکه عصبی عمیق به‌منظور تقریب تابع، گسترش داد و امکان کار با فضاهای حالت پیوسته و ابعاد بزرگ را فراهم آورد (داسیلوا ۲۰۲۲، تان ۲۰۲۱).

در نقشه‌برداری حساسیت سیل، DQL محدوده کامل متغیرهای شرطی را بدون گسسته‌سازی پردازش می‌کند و دقت پیش‌بینی را در محیط‌های ناهمگن بهبود می‌بخشد. از رابطهٔ ۱ برای به‌روزرسانی DQL با کمینه‌سازی تابع زیان استفاده شد (فوی ۲۰۱۹).

(θ): سنجه‌های شبکه Q، (θ^{-}): سنجه‌های شبکه

$$\left[L(\theta) = E\left[\left(r_t + \gamma \max_{a'} Q\left(s_{t+1}, a'; \theta^{-}\right) - Q(s_t, a_t; \theta)\right)^2\right]\right]$$

هدف که به‌طور دوره‌ای به‌روزرسانی می‌شوند، $(Q(s_t,a_t))$: اندازهٔ Q برای حالت (s_t) و عمل (a_t) در زمان (t)، (α): نرخ یادگیری (برابر با ۰/۱)، که اندازه گام به‌روزرسانی را مهار می‌کند، (r_t): پاداش دریافت‌شده پس از انجام عمل (a_t) در حالت (s_t) (برای مثال ۱+ برای طبقه‌بندی درست و ۱- برای طبقه‌بندی نادرست)، (γ): ضریب تنزیل (برابر با ۰/۹)، که تعادل میان پاداش‌های آنی و پاداش‌های آتی را برقرار می‌کند، (S_{t+1}): حالت بعدی پس از انجام عمل (at)، $\max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t)$: بیشینه اندازهٔ Q

برای حالت بعدی در میان تمام اعمال ممکن منهای اندازهٔ Q حالت فعلی و عمل انتخاب‌شده است. سیاست اکتشاف از راهبرد ε-greedy (رابطهٔ ۲) استفاده می‌کند.

$$a_t = \begin{cases} random\ action, & with\ probability\ \epsilon \\ arg\ max_a\ Q(s_t, a; \theta), & with\ probability\ 1-\epsilon' \end{cases}$$

ارزیابی دقت

برای ارزیابی کارایی یادگیری تقویتی (RL) در تولید نقشه‌های حساسیت سیل، از پنج شاخص مساحت زیر منحنی مشخصه عملکرد (AUC)، کاپا، بازیابی (Recall)، دقت مثبت پیش‌بینی‌شده (Precision)، و نرخ منفیِ درست (Specificity) و (LogLoss)، استفاده شد. این شاخص‌ها با استفاده از داده‌های آزمون شامل ۱۵۶ نقطه (۹۴ محل با سیل و ۶۲ محل بدون سیل از فهرست سیل) محاسبه شدند تا ارزیابی کارایی مدل‌ها بی‌طرفانه باشد. برای اطمینان از قابلیت اطمینان مدل‌های RL، تحلیل هم‌خطی روی ۲۱ متغیر طبقه‌بندی‌شده اولیه (رزولوشن ۳۰×۳۰ متر) انجام شد. بر اساس نتایج، چهار متغیر از فرایند مدل‌سازی حذف شدند. سرانجام، ۱۷ متغیر برای آموزش و آزمون مدل‌های تقویتی استفاده شد. این متغیرها شامل مدل رقومی ارتفاع ، تجمع جریان[۷]، جهت جریان [۸]، پیوستگی جریان[۹]، جهت جغرافیایی[۱۰]، طول شیب[۱۱]، انحنای افقی[۱۲]، انحنای نیم‌رخ[۱۳]، شاخص رطوبت پستی‌بلندی[۱۴]، ژرفا تا بستر سنگی[۱۵]، بیشینه بارش ۲۴ ساعته[۱۶]، دمای میانگین[۱۷]، دمای بیشینه[۱۸]، ژرفای برف[۱۹]، شاخص NDVI، درصد ماسه سطحی[۲۰]، فاصله از مناطق مسکونی[۲۱]، بودند. از این متغیرها برای آموزش و آزمون مدل‌های RL استفاده شد تا مشارکت‌های ویژگی مستقل و قوی باشد.

نتایج و بحث

نقشه‌برداری حساسیت به سیلاب

در این پژوهش، از مدل یادگیری عمیق (DQL) برای تولید نقشه‌های حساسیت به سیلاب استان چهارمحال و بختیاری، استفاده شد (شکل ۴).

در این نقشه‌ها مساحت منطقه مطالعه‌شده (۱۶۵۵۳۰۰ هکتار) به پنج طبقه حساسیت بسیارکم، کم، متوسط، زیاد و بسیارزیاد، بر اساس الگوریتم شکست طبیعی (natural break) تفکیک شد (جعفری و همکاران ۲۰۲۴).

در مدل DQL، مساحت طبقه بسیارکم ۹۷۲۲۱ هکتار (۶٪)، طبقهٔ کم ۳۳۶۱۹۰ هکتار (۲۰٪)، طبقهٔ متوسط ۴۲۹۴۵۳ هکتار (۲۲٪)، طبقهٔ زیاد ۴۳۵۲۹۳ هکتار (۲۶٪) و طبقهٔ بسیارزیاد ۳۵۷۱۴۰ هکتار (۲۶٪) بود. در این پژوهش بر اساس نتایج پهنه‌بندی سیلاب بر پایهٔ مدل DQL بیشترین خطر رخداد سیلاب مربوط به مناطق جنوبی و غربی استان در آبخیز کارون بود. این مناطق به‌دلیل بارش بیشتر و فرایند ذوب برف در بلندی‌ها به‌ویژه در فصل بهار نیازمند مدیریت رواناب با استفاده از اقدامات آبخیزداری زیست-سازه‌ای هستند. از سوی دیگر، خطر رخداد سیلاب در مناطق شرقی استان به‌ویژه شهرستان بروجن کمتر بود.

ارزیابی دقت

دقت مدل با پنج شاخص ارزیابی شد. نتایج AUC (۰/۹۳) بیانگر قدرت خوب مدل در تفکیک بود. اندازه‌های Kappa (۰/۷۲) و LogLoss (۰/۶۵) نشان‌دهنده توافق بسیار زیاد و قابلیت اطمینان در مدل‌سازی بود. منحنی مشخصه عملکرد (ROC)[۲۲] مدل DQL در شکل ۵ نشان‌داده شده است.

7- Flow Accumulation
8- Flow Direction
9- Flow Connectivity
10- Aspect
11- Slope Lengt
12- Plan Curvature
13- Profile Curvature
14- Topographic Wetness Index
15- Depth to Bedrock
16- Maximum 24-Hour Rainfall
17- Average Temperature
18- Maximum Temperature
19- Snow Depth
20- Percent of Surface Sand
21- Distance from Residential Areas
22- Receiver operating characteristic

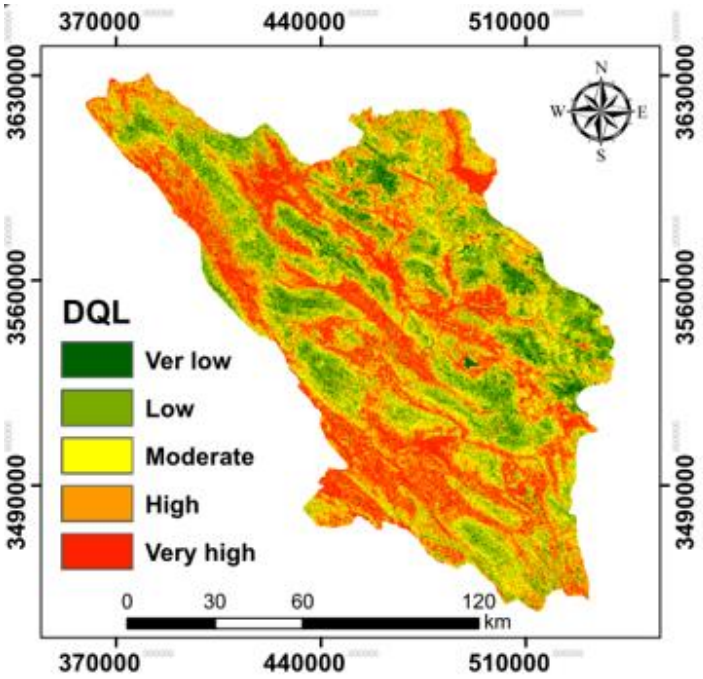

شکل۴- نقشه حساسیت به سیلاب در استان چهارمحال و بختیاری با استفاده از الگوریتم‌های DQL.

Figure 4- Flood susceptibility map of Chaharmahal and Bakhtiari Province using the DQL algorithm.

منحنی ROC با رسم نسبت یا نرخ مثبت صحیح (TPR)[۲۳] برحسب نرخ مثبت کاذب (FPR)[۲۴] ایجاد شد. اندازه‌های زیاد در این منحنی نشان‌دهنده دقت زیاد مدل در پیش‌بینی مناطق سیلابی در سطح استان چهار محال و بختیاری بود.

شاخص بازیابی برای مدل DQL برابر ۰/۸۷ بود که نشان‌دهنده یک مبادله کوچک در شناسایی مکان‌های سیلابی است. اندازه شاخص Precision برابر ۰/۹۰ و Specificity برابر با ۰/۸۵ محاسبه شدند که نشان‌دهنده دقت زیاد مدل در پهنه‌بندی سیلاب در سطح استان چهارمحال و بختیاری بود. افزون بر این، اندازه‌های کم Kappa برابر ۰/۷۲ و LogLoss برابر ۰/۶۵ نشان‌دهنده خطاهای پیش‌بینی متوسط و قدرت تبیینی مناسب مدل بود، که ممکن است به‌دلیل چالش‌ها در بهینه‌سازی برای مقیاس داده‌ها باشد.

نتایج ارزیابی نشان‌دهندهٔ کارایی نسبتاً خوب مدل DQL بود. کارآیی ساختاری DQL در ترکیب QL با شبکه‌های DL پنهان است. درنتیجه، می‌توان اندازه‌های Q را در فضاهای با ابعاد بزرگ برآورد کرد (مینه و همکاران۲۰۱۵). با این متغیر و به‌وسیلهٔ DQL می‌توان روابط غیرخطی پیچیده میان متغیرهای محیطی و آب‌شناختی را به‌طور دقیق‌تر در مقایسه با QL ثبت کرد. نتایج بسیارخوب بررسی شاخص‌های طبقه‌بندی مؤید کارایی بازنمایی مدل بود و از محدودیت‌ها، می‌توان به سوگیری بیش برآورد در پیش‌بینی‌های اندازهٔ Q و بی‌ثباتی در آموزش به‌دلیل وابستگی مکانی در داده‌های متوالی اشاره کرد. نتایج پژوهش‌های کدنکو و خوسلا (۲۰۲۵) نیز با نتایج این پژوهش هم‌راستا است.

23- True Positive Rate
24- False Positive Rate

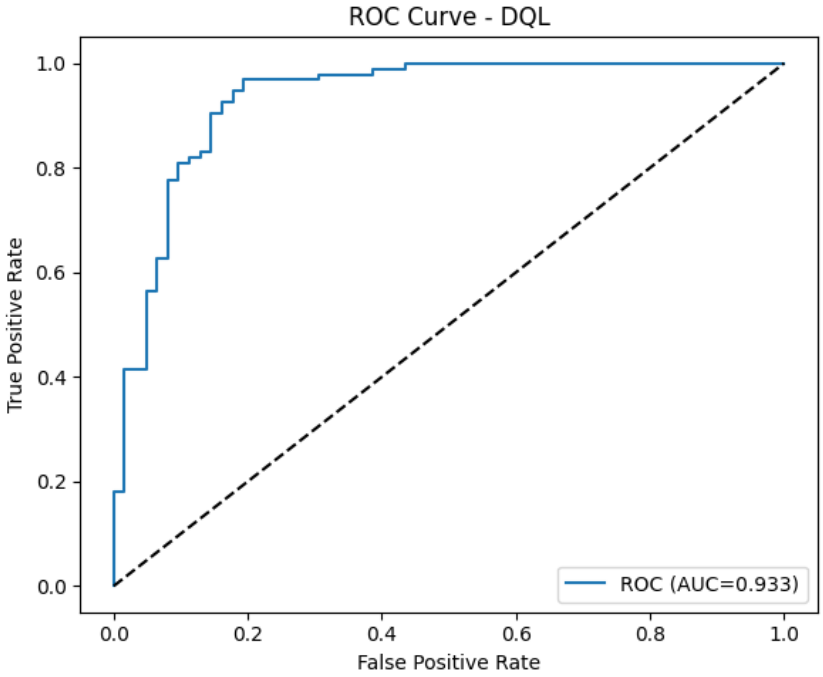

شکل ۵- منحنی مشخصه عملکرد مدل DQL در مدل‌سازی سیلاب در منطقه مطالعه‌شده.

Figure 5- Receiver Operating Characteristic curve of the DQL model on flood modeling in the study area.

این مشکلات با ماهیت هم‌بستگی مکانی داده‌های حساسیت به سیل، در مناطق همسایه که اغلب ویژگی‌های مشابهی دارند، تشدید شدند. اگرچه روش‌هایی مانند بازپخش تجربه و شبکه‌های هدف برای تثبیت DQL طراحی شده‌اند، اما کاربرد آن‌ها به‌طور کامل ناپایداری را برطرف نمی‌کند. با استفاده از داده‌های بیشتر و گوناگون سیلاب و بدون سیلاب و همراه با پراکنش مکانی آنها در پهنهٔ سطح منطقه مطالعه‌شده میتوان این محدودیت را در مدل DQL به حداقل رساند.

نتیجه‌گیری و پیشنهادها

در این پژوهش، از (DQL) برای نقشه‌برداری حساسیت به سیل در استان چهارمحال و بختیاری، ایران، رابطه‌های پیچیده میان طراحی الگوریتم، پویایی‌های محیطی و روش‌شناختی در شکل‌دهی پهنه‌بندی حساسیت، استفاده شد. نتایج این پژوهش نشان داد کارایی یادگیری تقویتی، به‌ویژه مدل Deep Q-Learning (DQL)، در نقشه‌برداری حساسیت به سیلاب در شرایط پیچیده و متغیر استان چهارمحال و بختیاری بسیارخوب بود. با گردآوری فهرست جامع سیلاب‌ها، تحلیل هم‌خطی برای حذف متغیرهای تکراری و استفاده از ۱۷ متغیر محیطی و آموزش و اعتبارسنجی دقیق مدل‌ها، نقشه‌های حساسیت قابل اطمینان تولید شد. با کاربرد DQL می‌توان نواحی پرخطر را به‌طور دقیق شناسایی کرد و ارتباط این خطرات را با واقعیت‌های زیست‌محیطی منطقه مانند ذوب برف در کوهرنگ، شیب‌های تند و توسعه شهری در لردگان آشکار ساخت. با این نتایج می‌توان الگوی عملی مانند بهبود شبکه‌های دفع آب، بهبود زیرساخت‌های شهری در برابر سیلاب ناشی از ذوب برف، و بازسازی پوشش گیاهی برای افزایش نفوذ آب برای مدیریت سیلاب فراهم آورد.

به‌طور کلی، نتایج این پژوهش نشان داد با بهره‌وری از RL و به‌ویژه DQL می‌توان چارچوب دقیقی برای درک ساز و کارهای سیلاب به‌منظور پشتیبانی از برنامه‌ریزی پایدار کاربری زمین و مدیریت خطر در مناطق آسیب‌پذیر، ارائه داد.

بر اساس نتایج این پژوهش و به‌منظور ارتقای مدل‌ها گسترش موجودی سیلاب با داده‌های فصلی، افزودن داده‌های زمانی مانند چرخه‌های ذوب برف و تغییرات دما، و انجام اعتبارسنجی میدانی به‌ویژه در مناطق مسکونی و بلندی‌های زیاد، پیشنهاد می‌شود.

تضاد منافع نویسندگان

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

دسترسی به داده‌ها

داده‌ها و نتایج استفاده‌شده در این پژوهش، با مکاتبه با نویسندهٔ مسئول در اختیار مخاطب قرار خواهد گرفت.

مشارکت نویسندگان

نویسندهٔ اول: مفهوم‌سازی، انجام تحلیل‌های نرم‌افزاری/آماری، نگارش نسخهٔ اولیهٔ مقاله

نویسندهٔ دوم: راهنمایی، ویرایش و بازبینی مقاله، بازبینی نتایج

نویسندهٔ سوم: راهنمایی، ویرایش و بازبینی مقاله، بازبینی نتایج

فهرست منابع

AD. 2023. Floods and debris flows in Ladakh: Past history and future hazards, in: Advances in Asian Human-Environmental Research. Springer. pp. 31–52. https://doi.org/10.1007/978-3-031-42494-6_3

Chen W, Li Y, Xue W, Shahabi H, Li S, Hong H, Wang X, Bian H, Zhang S, Pradhan B, Ahmad B, Bin H. 2020. Modeling flood susceptibility using data-driven approaches of naïve Bayes tree, alternating decision tree, and random forest methods. Sci. Total Environ. 701: 134979. https://doi.org/10.1016/j.scitotenv.2019.134979

da Silva AR. 2022. Double Q-Learning for citizen relocation during natural hazards. arXiv Prepr. arXiv2209.03800.

Dewan AM. 2013. Floods in a megacity: Geospatial techniques in assessing hazards, risk and vulnerability, Floods in a Megacity: Geospatial Techniques in Assessing Hazards, Risk and Vulnerability. Springer. https://doi.org/10.1007/978-94-007-5875-9

Eini M, Kaboli HS, Rashidian M, Hedayat H. 2020. Hazard and vulnerability in urban flood risk mapping: Machine learning techniques and considering the role of urban districts. International Journal of Disaster Risk Reduction. 50: 101687. https://doi.org/10.1016/j.ijdrr.2020.101687

Feng K, Lin N, Kopp RE, Xian S, Oppenheimer M. 2025. Reinforcement learning–based adaptive strategies for climate change adaptation: An application for coastal flood risk management. Proceedings of the

Alsumayt A, El-Haggar N, Amouri L, Alfawaer ZM, Aljameel SS. 2023. Smart flood detection with AI and Blockchain integration in Saudi Arabia using drones. Sensors. 23: 5148. https://doi.org/10.3390/s23115148

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: 949–974. https://doi.org/10.1080/19475705.2022.2060138

Ardali EO, Tahmasebi P, Bonte D, Milotić T, Pordanjani IR, Hoffmann M. 2015. Ecological sustainability in rangelands: The contribution of dung beetles in secondary seed dispersal (Case study: Chaharmahal and Bakhtiari Province, Iran). European Journal of Sustainable Development. 5: 133. https://doi.org/10.14207/ejsd.2016.v5n3p133

Batzer DP, Sharitz RR. 2007. Ecology of freshwater and estuarine wetlands, Ecology of Freshwater and Estuarine Wetlands. Univ of California Press. 375 p. https://doi.org/10.1525/california/9780520247772.003.0001

Bowes BD, Tavakoli A, Wang C, Heydarian A, Behl M, Beling PA, Goodall JL. 2021. Flood mitigation in coastal urban catchments using real-time stormwater infrastructure control and reinforcement learning. Journal of Hydroinformaticss. 23: 529–547. https://doi.org/10.2166/HYDRO.2020.080

Bray J, Wasson RJ, Srivastava P, Ziegler

National Academy of Sciences, 122(12), e2402826122.

Foy, P., 2019. Deep Reinforcement Learning: Guide to Deep Q-Learning, in: Mlq. Springer. pp. 475–483

Jaafari A, Mafi-Gholami D, Yousefi S. 2024. A spatiotemporal analysis using expert-weighted indicators for assessing social resilience to natural hazards. Sustainable Cities and Society. 100: 105051

Hall J, Arheimer B, Borga M, Brazdil R, Claps P, Kiss A, Kjeldsen TR, Kriauciuniene J, Kundzewicz ZW, Lang M, Llasat MC, Macdonald N, McIntyre N, Mediero L, Merz B, Merz R, Molnar P, Montanari A, Neuhold C, Parajka J, Perdigao RAP, Plavcova L, Rogger M, Salinas JL, Sauquet E, Schar C, Szolgay J, Viglione A, Bloschl G. 2014. Understanding flood regime changes in Europe: A state-of-the-art assessment. Hydrology and Earth System Sciences. 18: 2735–2772. https://doi.org/10.5194/hess-18-2735-2014

Hossain MN, Mumu UH. 2024. Flood susceptibility modelling of the Teesta River Basin through the AHP-MCDA process using GIS and remote sensing. Natural Hazards. 120: 12137–12161. https://doi.org/10.1007/s11069-024-06677-z

Khan TA, Shahid Z, Alam M, Su'ud MM, Kadir K. 2019. Early flood risk assessment using Machine Learning: A Comparative study of SVM, Q-SVM, K-NN and LDA, in: MACS 2019 - 13th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics, Proceedings. IEEE, pp. 1–7. https://doi.org/10.1109/MACS48846.2019.9024796

Kharazmi R, Tavili A, Rahdari MR, Chaban L, Panidi E, Rodrigo-Comino J. 2018. Monitoring and assessment of seasonal land cover changes using remote sensing: A 30-year (1987–2016) case study of Hamoun Wetland, Iran. Environmental Monitoring and Assessment. 190: 1–23. https://doi.org/10.1007/s10661-018-6726-z

Kondolf GM, Piégay H, Landon N. 2007. Changes in the riparian zone of the lower Eygues River, France, since 1830. Landscape Ecology. 22: 367–384. https://doi.org/10.1007/s10980-006-9033-y

Li XY, Wang X. 2025. Rescue path planning for urban flood: A deep reinforcement learning–based approach. Risk Analysis. 45(4): 928-943.

Mohammadi M, Abdi Y, Rahimian FP. 2025. Blockchain for water management, in: Digital Twin and Blockchain for Sensor Networks in Smart Cities. Elsevier. pp. 229–242. https://doi.org/10.1016/B978-0-443-30076-9.00011-X

Naghibi SA, Pourghasemi HR. 2015. A comparative assessment between three machine learning models and their performance comparison by bivariate and multivariate statistical methods in groundwater potential mapping. Water Resources Management. 29: 5217–5236. https://doi.org/10.1007/s11269-015-1114-8

Pal S, Talukdar S. 2018. Application of frequency ratio and logistic regression models for assessing physical wetland vulnerability in Punarbhaba river basin of Indo-Bangladesh. Human and Ecological Risk Assessment: An International Journal. 24: 1291–1311. https://doi.org/10.1080/10807039.2017.1411781

Pourghasemi HR, Gayen A, Edalat M, Zarafshar M, Tiefenbacher JP. 2019. Is multi-hazard mapping effective in assessing natural hazards and integrated watershed management? Geoscience Frontiers. 11(4): 1203-1217. https://doi.org/10.1016/j.gsf.2019.10.008

Qin H, Liang Q, Chen H, De Silva V. 2024. A coupled human and natural systems (CHANS) framework integrated with reinforcement learning for urban flood mitigation. Journal of Hydrology. 643: 131918. https://doi.org/10.1016/j.jhydrol.2024.131918

Remesan R, Bray M, Shamim MA, Han D. 2009. Rainfall-runoff modelling using a wavelet-based hybrid SVM scheme, in: IAHS-AISH Publication. IAHS Press. pp. 41–50.

Schmid U, Rösch P, Krause M, Harz M, Popp J, Baumann K. 2009. Gaussian mixture discriminant analysis for the single-cell differentiation of bacteria using micro-Raman spectroscopy. Chemometrics and Intelligent Laboratory Systems. 96: 159–171. https://doi.org/10.1016/j.chemolab.2009.01.008

Soltani K, Ebtehaj I, Amiri A, Azari A, Gharabaghi B, Bonakdari H. 2021. Mapping the spatial and temporal variability of flood susceptibility using remotely sensed normalized difference vegetation index and the forecasted changes in the future. Science of the Total Environment. 770: 145288. https://doi.org/10.1016/j.scitotenv.2021.145288

Tan H. 2021. Reinforcement learning with deep deterministic policy gradient, in: Proceedings - 2021 International Conference on Artificial Intelligence, Big Data and Algorithms, CAIBDA 2021. IEEE, pp. 82–85. https://doi.org/10.1109/CAIBDA53561.2021.00025

Tian W, Xin K, Zhang Z, Zhao M, Liao Z, Tao T. 2023. Flooding mitigation through safe and trustworthy reinforcement learning. Journal

Yousefi S, Pourghasemi HR, Emami SN, Pouyan S, Eskandari S, Tiefenbacher JP. 2020. A machine learning framework for multi-hazards modeling and mapping in a mountainous area. Scientific Reports. 10: 1–14. https://doi.org/10.1038/s41598-020-69233-2

Zhu X, Guo H, Huang JJ. 2024. Urban flood susceptibility mapping using remote sensing, social sensing and an ensemble machine learning model. Sustainable Cities and Society. 108: 105508. https://doi.org/10.1016/j.scs.2024.105508

of Hydrology 620: 129435. https://doi.org/10.1016/j.jhydrol.2023.129435

Tian W, Zhang Z, Xin K, Liao Z, Yuan Z. 2025. Enhancing the resilience of urban drainage system using deep reinforcement learning. Water Research. 281: 123681.

Yousefi S, Jaafari A, Valjarević A, Gomez C, Keesstra S. 2022. Vulnerability assessment of road networks to landslide hazards in a dry-mountainous region. Environmental Earth Sciences. 81: 521. https://doi.org/10.1007/s12665-022-10650-z

Fars Agricultural and Natural Resources and Education Center

Watershed Management Research

ISSN: 2981- 2038

Agricultural Research, Education and Extension Organization

A Reinforcement Learning Framework for Flood Zoning in Mountainous Areas using the Deep Q-Learning Model

Saleh Yousefi[1*], Sara Mardanian[2], Ahmad Reza Karimipour[3]

1- Assistant Professor in Soil Conservation and Watershed Management Research Department, Chaharmahal and Bakhtiari Agricultural and Natural Resources Research and Education Center, AREEO, Shahrekord, Iran

2- Scholar in Soil Conservation and Watershed Management Research Department, Chaharmahal and Bakhtiari Agricultural and Natural Resources Research and Education Center, AREEO, Shahrekord, Iran

3- Instructor in Soil Conservation and Watershed Management Research Department, Chaharmahal and Bakhtiari Agricultural and Natural Resources Research and Education Center, AREEO, Shahrekord, Iran

Extended Abstract

Introduction and Goal

Understanding flood risk efforts to reduce it are top priorities for researchers and policymakers. Flood susceptibility mapping is an important tool for risk management in mountainous regions. Because, it is possible to identify prone areas and provide a platform for spatial planning, preparedness, and preventive measures. Traditional flood mapping approaches, such as hydrological modeling and historical data analysis, often face limitations including data scarcity, computational complexity, and the dynamic of environmental systems. Therefore, modern artificial intelligence (AI) methods—particularly machine learning (ML) and reinforcement learning (RL)—have been employed to process diverse datasets and identify complex patterns. Among AI approaches, reinforcement learning is promising due to its capacity to interact with the environment and progressively improve decision-making. The Deep Q-Learning (DQL) model, as an advanced reinforcement learning technique, enables operation in continuous and high-dimensional state spaces without requiring discretization. This study aims to apply the DQL model to produce a flood susceptibility map in the Chaharmahal and Bakhtiari Province, a mountainous and semi-arid region prone to flash floods caused by snowmelt and intense rainfall. The main objective is to provide a precise framework for flood hazard assessment and to support policymakers and crisis managers in reducing risk and enhancing resilience, particularly in vulnerable counties such as Ardal and Lordegan.

Materials and Methods

To conduct this research, a list of flood events including 545 spatial points (346 flood and 199 non-flood locations) from 1983 to 2023 was compiled. In a random and stratified manner, 71% of the data was used for training (389 points) and 29% for testing (156 points). Initially, 21 environmental variables were extracted from multiple sources, including a Digital Elevation Model (DEM), climatic time series, Landsat 9 imagery, and the SoilGrid database.

Article Type: Research Article
***Corresponding Authors' E-mail:** ssaleh.yousefi@gmail.com
Citation: Yousefi, S., Mardanian, S., Karimipour. A.R. 2026. A Reinforcement Learning Framework for Flood Zoning in Mountainous Areas using the Deep Q-Learning Model. Watershed Management Research. 39(3): 64-78.

DOI: 10.22092/wmrj.2026.371991.1656

Received: 07 January 2026, **Received in revised form:** 18 February 2026, **Accepted:** 19 March 2026, **Published online:** 23 September 2026

Watershed Management Research, Vol. 39, No. 3, Ser. No, 152, Autumn 2026, pp. 64-78.

Publisher: Fars Agricultural and Natural Resources and Education Center

©Author(s)

CC BY

After multicollinearity analysis, four variables were removed, and 17 final variables (elevation, flow accumulation, flow direction, stream connectivity, aspect, slope length, plan and profile curvature, Topographic Wetness Index (TWI), depth to bedrock, maximum 24-hour precipitation, mean and maximum temperature, snow depth, NDVI, surface sand percentage, and distance from residential areas) were selected. The Deep Q-Learning model was applied to process continuous variables and generate a flood susceptibility map. This map was classified into five categories (very low to very high). The accuracy of the model was evaluated by indicators such as AUC, Kappa, Recall, Precision, Specificity, and LogLoss metrics.

Results and Discussion

The classification map was prepared using the Deep Q-Learning (DQL) model and based on the Natural break method. In this map, the area of the study area (1,655,300 hectares) was divided into five flood susceptibility classes: very low (6%, 97,221 ha), low (20%, 336,190 ha), moderate (26%, 429,453 ha), high (26%, 435,293 ha), and very high (22%, 357,140 ha). Accuracy assessment indicated very good model performance. The results of the AUC index (0.93) indicated excellent discriminative ability, the Kappa coefficient index (0.72) indicating acceptable agreement between predictions and observations, and the Recall index (0.87) indicated high identification of flood points. The Precision index and was calculated to be 0.90, Specificity was 0.85, and LogLoss was 0.65. Analysis of the significance of the variables showed that the greatest effect was related to snow depth, which has a significant impact on snowmelt in spring floods. This was followed by flow accumulation (topographic characteristics), distance from residential areas (human and urban development impacts), NDVI (vegetation cover and soil permeability), mean temperature (climatic conditions), and slope length. Areas classified as very high susceptibility were mainly concentrated in low-lying areas, valleys, and along major rivers such as the Karoon and Zayandeh-Rud Rivers, particularly within Ardal and Lordegan counties. Comparison the results of this study with similar studies based on supervised machine learning models showed that using the DQL model, flood risk in heterogeneous mountainous environments can be predicted more reliably and flood risk can be managed more accurately.

Conclusion and Suggestions

The results of this study demonstrated that the Deep Q-Learning (DQL) model, as a deep reinforcement learning approach, has high capability for flood susceptibility mapping, especially in complex mountainous regions such as Chaharmahal and Bakhtiari Province. By utilizing this model, processing continuous environmental variables and accurately identifying nonlinear relationships, valid and practical maps were produced, and based on that, high-risk areas were accurately identified. The findings of this study confirm that the main flood drivers in the region include snowmelt, topographic characteristics, human development, and vegetation degradation. These findings were also consistent with the field realities of the region. The generated maps can serve as a practical basis for land-use planning, strengthening stormwater infrastructure, protecting residential areas against flash floods, and restoring vegetation ecosystems to enhance soil permeability. Overall, the results of this study provided a novel approach and a detailed framework for sustainable flood risk management in similar regions in Iran and the world, which policymakers can benefit from in improving the resilience of local communities. To improve the accuracy of the model in future research, it is recommended that a broader list of flood events be compiled with more accurate seasonal and temporal data, and that dynamic variables such as daily temperature changes and snowmelt cycles be examined. Additionally, it is recommended to conduct more extensive field validation, especially in high altitudes and urban areas. It is also suggested to combine DQL with other reinforcement learning methods or hybrid models to increase its efficiency.

Keywords: **Flood risk assessment, Iranian highlands, machine learning, reinforcement learning**

Article Type: Research Article

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

Data Availability Statement
The datasets are available upon a reasonable request to the corresponding author.

Authors' Contribution
Author 1: Conceptualization, software/statistical analyses, writing the first draft of the manuscript
Author 2: Guidance, editing and revision of the manuscript, review of results
Author 3: Guidance, editing and revision of the manuscript, review of results