



مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی

پژوهش‌های آب‌بخیزداری

شاپا: ۲۰۳۸-۲۹۸۱



سازمان تحقیقات، آموزش و ترویج کشاورزی

پهنه‌بندی و پیش‌بینی خطر رخداد سیل با استفاده از مدل‌های یادگیری عمیق در آبخیز قره‌سو استان گلستان

کوروش شیرانی^{۱*}، محمدعلی صدیقی^۲

۱- دانشیار پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

۲- کارشناس ارشد دانشگاه آزاد اسلامی لنجان اصفهان، ایران

چکیده مبسوط

مقدمه و هدف

سیل یکی از ویرانگرترین بلاهای طبیعی با پیامدهای اجتماعی، اقتصادی و زیست‌محیطی است. از این رو، روش‌های یادگیری ماشین برای مدل‌سازی و پیش‌بینی آن توسعه داده شده‌اند. هدف این پژوهش، پهنه‌بندی و پیش‌بینی خطر رخداد سیل با استفاده از سه مدل یادگیری عمیق شامل مدل‌های شبکه عصبی بازگشتی واحد دروازه‌دار (GRU)، حافظه کوتاه-بلندمدت (LSTM) و شبکه‌های پیچشی زمانی (TCN) و معرفی مناسب‌ترین آن‌ها در آبخیز قره‌سو استان گلستان بود. مهم‌ترین نوآوری این پژوهش مقایسه نتایج آن با نتایج دیگر پژوهش‌های مرتبط با پهنه‌بندی خطرها در داخل کشور، به کارگیری مدل‌های جدید یادگیری عمیق و در نظر گرفتن بیشترین عامل‌های سیل‌خیزی برای تعیین کارآمدترین مدل و افزایش دقت نقشه‌های پیش‌بینی رخداد سیل بود.

مواد و روش‌ها

منطقه پژوهشی آبخیز قره‌سو گرگان انتخاب شد. سپس، نقشه‌های عامل‌های مؤثر جمع‌آوری و آماده‌سازی شد. در این پژوهش ۱۶ عامل به عنوان متغیرهای مستقل و اطلاعات دریافت‌شده از سازمان مدیریت منابع آب وزارت نیرو و بازدیدهای میدانی به عنوان متغیر وابسته، انتخاب شدند. سپس، نقشه پراکنش رخداد سیل تهیه شد. برای مدل‌سازی و پیش‌بینی خطر رخداد سیل، نقشه پراکنش رخداد سیل به دو دسته نقاط آزمایشی (۳۰٪) و آموزشی (۷۰٪) تقسیم شد. پس از اجرای مدل‌های LSTM، TCN و GRU، نقشه‌های به دست آمده از پهنه‌بندی خطر رخداد سیل به پنج رده خیلی کم، کم، متوسط، زیاد و خیلی زیاد طبقه‌بندی شدند. سرانجام، دقت طبقه‌بندی و اعتبارسنجی نقشه‌های پهنه‌بندی ارزیابی، خطر رخداد سیل پیش‌بینی و مناسب‌ترین مدل انتخاب شد.

نوع مقاله: پژوهشی

*مسئول مکاتبات: Kouroshshirani@gmail.com

استناد: شیرانی، ک.، صدیقی، م. ع. ۱۴۰۵. پهنه‌بندی و پیش‌بینی خطر رخداد سیل با استفاده از مدل‌های یادگیری عمیق در آبخیز قره‌سو استان گلستان. پژوهش‌های آبخیزداری. ۳۹(۳): ۴۴-۲۲.

شناسه دیجیتال: 10.22092/WMRJ.2026.371561.1648

تاریخ دریافت: ۱۴۰۴/۰۹/۱۸، تاریخ بازنگری: ۱۴۰۴/۱۱/۲۹، تاریخ پذیرش: ۱۴۰۵/۰۳/۳۱، تاریخ انتشار: ۱۴۰۵/۰۷/۰۱

پژوهش‌های آبخیزداری، سال ۱۴۰۵، دوره ۳۹، شماره ۳، شماره پیاپی ۱۵۲، پاییز ۱۴۰۵، صفحه‌های ۲۲ تا ۴۴.

© نویسندگان

ناشر: مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان فارس



نتایج و بحث

برای تهیه نقشه پهنه‌بندی رخداد سیل، داده‌های مکانی ۵۹ نقطه سیل (متغیر وابسته) بر اساس اطلاعات موجود و بررسی تصویرهای راداری در بازه زمانی قبل و بعد از سیلاب با استفاده نرم‌افزار گوگل‌ارث، جمع‌آوری شد. در هر یک از این نقاط رخداد سیل در دوره ۲۰ ساله (۱۴۰۳-۱۳۸۳) با ۱۰ بار تناوب رخداد سیل ثبت و گزارش شده بود. از این تعداد ۷۰٪ به‌عنوان داده‌های آموزشی و ۳۰٪ به‌عنوان داده‌های آزمایشی به‌ترتیب برای اجرا و اعتبارسنجی مدل، به‌طور تصادفی انتخاب و تقسیم شدند. در مرحله بعد، از ۱۶ عامل در قالب گروه‌های محیطی، آب‌شناسی، پستی‌بلندی آبخیز به‌همراه داده‌های اقلیمی (به‌عنوان متغیر مستقل) و برای پهنه‌بندی و مدل‌سازی استفاده شد. دقت طبقه‌بندی مدل‌ها با استفاده از دو شاخص نسبت فراوانی (FR) و مساحت سلول هسته (SCAI) ارزیابی شد. نتایج نشان داد که بیشتر نقاط سیل در رده‌های پرخطر (زیاد و خیلی‌زیاد) بودند و بیشترین سهم از مساحت منطقه نیز مربوط به این پهنه‌ها بود. افزون بر این، بر اساس مساحت زیر منحنی‌های عملکرد نسبی و هزینه مشخص شد کارآمدترین و مناسب‌ترین و اقتصادی‌ترین مدل در مقایسه با مدل‌های LSTM و GRU مدل TCN بود. در میان مدل‌های بررسی شده بیشترین و کمترین مساحت زیر منحنی‌های عملکرد نسبی و هزینه مربوط به مدل TCN به‌ترتیب ۰/۹۲ و ۰/۰۸ بود. نتایج این پژوهش نشان داد بر پایه مدل TCN، ۴۵٪ از مساحت منطقه در رده خطر خیلی‌زیاد در برگیرنده ۸۳٪ از رخداد‌های سیل بودند. همچنین، بر پایه مدل LSTM، ۲۳٪ از مساحت منطقه در برگیرنده ۶۰٪ از رخداد‌های سیل و بر پایه مدل GRU، ۱۰٪ از مساحت منطقه در برگیرنده ۴٪ از رخداد‌های سیل بودند. از نقشه‌های پهنه‌بندی خطر رخداد سیل به‌دست آمده در این پژوهش می‌توان به‌عنوان مبنایی برای برنامه‌ریزی و مدیریت بحران ناشی از رخداد سیل، کاهش خطر سیل و مدیریت آن بهره برد. افزون بر این، بر اساس عملکرد عالی هر سه مدل TCN، LSTM و GRU، نتایج این پژوهش برای توسعه طرح‌های آبی سازمان‌های گوناگون و فعال در بسیاری از کشورهای در حال توسعه لازم و ضروری است.

نتیجه‌گیری و پیشنهادها

پس از اجرای هر سه مدل TCN، LSTM و GRU، نتایج شاخص AUC-ROC، در هر دو مرحله آموزش و آزمون نشان‌دهنده عملکرد عالی مدل‌های نامبرده بود. نقشه‌های تهیه‌شده از پهنه‌بندی خطر رخداد سیل با کاربرد هر سه مدل، نشان‌دهنده دقت زیاد طبقه‌بندی پهنه‌ها و توزیع مناسب نقاط سیلابی در رده‌های زیاد و خیلی‌زیاد بود. برازش مدل TCN در پیش‌بینی رخداد سیل در مرحله آزمون در مقایسه با دو مدل دیگر، بهتر بود. ارزیابی دقت طبقه‌بندی و اعتبارسنجی مدل‌ها نشان داد دو مدل TCN و LSTM با داشتن آستانه طبقات مناسب در طبقه‌بندی، اولویت کاربرد آنها برای پهنه‌بندی و پیش‌بینی خطر رخداد سیل بیشتر است. سرانجام در این پژوهش، اندازه‌های شاخص مساحت زیر منحنی ارزش یا هزینه برای مدل‌های TCN، LSTM و GRU به‌ترتیب ۰/۰۸، ۰/۱۰ و ۰/۱۱ به‌دست آمد. پیشنهاد می‌شود بر اساس اهمیت ویژگی‌های ریخت‌سنجی در پهنه‌بندی نقشه‌های خطر رخداد سیل، در پژوهش‌های آینده از این سنج‌ها همراه با دیگر سنج‌های متداول در تهیه نقشه‌های پهنه‌بندی استفاده شود. افزون بر این، بر پایه نتایج این پژوهش پیشنهاد می‌شود از روش‌های یادگیری عمیق و ترکیب آن با یکدیگر استفاده شود. همچنین پیشنهاد می‌شود بهره‌گیری از روش‌های ترکیبی نوین (هیبریدی) و بهینه‌سازهای مناسب در دیگر آبخیزهای استان گلستان، بررسی و ارزیابی شود.

واژگان کلیدی

پهنه‌بندی، پیش‌بینی، خطر، سیل، قره‌سو، مدل‌های یادگیری عمیق

مقدمه

سیل یکی از ویرانگرترین مخاطره‌های طبیعی است که سالانه خسارت‌های زیادی به جان انسان‌ها و اقتصاد جهانی وارد می‌آورد و برآورد شده بیش از یک سوم مساحت زمین در معرض خطر آن است (کانورتینو و همکاران ۲۰۱۹؛ پرادهان ۲۰۰۹؛ رزالیس و همکاران ۲۰۱۰). در بسیاری از مناطق جهان افزایش بلندی آب رودها و طغیان سیلاب‌ها، به‌ویژه در نتیجه تغییرات کاربری زمین و گسترش بی‌رویه سکونت‌گاه‌ها، موجب افزایش خطر سیلاب شده است (دالو و همکاران ۲۰۱۸).

ایران به دلیل شرایط اقلیمی خشک و نیمه‌خشک، بارش‌های رگباری شدید، شیب زیاد دامنه‌ها و نفوذناپذیری خاک‌ها، از جمله کشورهای آسیب‌پذیر رخداد سیل به‌شمار می‌آید (ملکیان و همکاران ۲۰۱۲). در استان گلستان نیز به‌واسطه رگبارهای کوتاه‌مدت و شدید، همواره پدیده سیلاب‌های ویران‌گر رخ داده است؛ به‌طوری که در دوره ۲۰۱۹-۱۹۹۱ بیش از ۱۳۴ رخداد سیل در این استان ثبت شد و خسارت‌های مالی قابل‌توجهی نیز گزارش شد (اداره کل منابع طبیعی و آبخیزداری استان گلستان ۲۰۱۸). برای کاهش خسارت‌های این پدیده، مدیریت جامع آبخیز و توسعه نقشه‌های پهنه‌بندی خطر سیل، اهمیت زیادی دارد (رحمتی و همکاران ۲۰۱۶الف). با وجود پیچیدگی فرایندهای مؤثر بر رخداد سیل و کمبود داده‌های دقیق، پیش‌بینی قابل اطمینان این پدیده دشوار است. امروزه، کاربرد سامانه‌های اطلاعات جغرافیایی و مدل‌های داده‌محور برای تسریع تهیه نقشه‌های خطر افزایش‌یافته است. در سال‌های گذشته، روش‌های متنوعی برای پهنه‌بندی خطر سیل توسعه یافته‌اند که از جمله آن‌ها می‌توان به AHP (ناچاپا و همکاران ۲۰۲۰؛ دانو و همکاران ۲۰۱۹)، مدل نسبت فراوانی (چن و همکاران ۲۰۲۰؛ رحمتی و همکاران ۲۰۱۶ب)، مدل‌های احتمالاتی (شیرانی و صدری ۲۰۲۳؛ چن و همکاران ۲۰۱۹) و روش‌های یادگیری ماشین مانند RF، DT، SVM و ANN (وفاخواه و همکاران ۲۰۲۰؛ ان‌اچ‌یو و همکاران ۲۰۲۰؛

خسروی و همکاران ۲۰۱۹؛ چوبین و همکاران ۲۰۱۹؛ تهرانی و همکاران ۲۰۱۴؛ کیا و همکاران ۲۰۱۲؛ گبرهیوت و همکاران ۲۰۱۹)، اشاره کرد کاربرد مدل‌های داده‌محور به دلیل برتری و توانایی مدل‌سازی روابط غیرخطی بدون نیاز به شبیه‌سازی فیزیکی، افزایش‌یافته است (موسوی و همکاران ۲۰۱۸). در این میان، کارایی مدل‌های یادگیری عمیق مانند LSTM، CNN، RNN و GRU به دلیل توانایی استخراج خودکار ویژگی‌ها و تحلیل داده‌های سری زمانی، در مقایسه با روش‌های سنتی بیشتر است (کاور و همکاران ۲۰۲۶؛ صالح و همکاران ۲۰۲۵؛ بنتیواگلیو و همکاران ۲۰۲۲؛ لی‌کان و همکاران ۲۰۱۵؛ ابواه و همکاران ۲۰۲۳؛ کراتزرت و همکاران ۲۰۱۹). همچنین، عملکرد مدل‌های LSTM، GRU و TCN در پژوهش‌های مرتبط با زمین‌لغزش نیز خوب گزارش شده است (بهره و همکاران ۲۰۲۶؛ لی و همکاران ۲۰۲۵؛ ژاهو و همکاران ۲۰۲۲).

در این پژوهش، برای نخستین بار در استان گلستان، برای پهنه‌بندی خطر سیل سه مدل یادگیری عمیق LSTM، GRU و TCN، به‌طور هم‌زمان مقایسه شدند. با توجه به اهمیت انتخاب عامل‌های مؤثر که بسته به شرایط مکانی متفاوت هستند (کیا و همکاران ۲۰۱۲)، تعداد ۱۶ عامل مؤثر شامل متغیرهای زمین‌شناسی، آب‌شناختی، ریخت‌شناختی و اقلیمی انتخاب شدند. منطقه پژوهشی محدوده آبخیز قره‌سو در استان گلستان بود. هدف اصلی پژوهش، ارزیابی عملکرد مدل‌های نامبرده و معرفی کارآمدترین مدل برای پیش‌بینی خطر سیل در آبخیز قره‌سو بود.


مواد و روش‌ها

معرفی منطقه مطالعه‌شده

استان گلستان با مساحت ۲۰۴۳۸ کیلومتر مربع شامل ۵ آبخیز گرگان‌رود، اترک، قره‌سو، خلیج گرگان و نکارود بالادست می‌باشد که مجموعاً ۴۵ رشته رود به طول ۲۷۰۰ کیلومتر در آن امتداد دارد. میانگین سالانه بارندگی استان در شرایط عادی حدود ۴۵۰ میلی‌متر است. آبخیز قره‌سو در میان عرض‌های جغرافیایی ۳۳° ۳۶' تا ۳۷° ۰۰' شمالی و طول‌های

پوشیده‌شده از جنگل و شمال آن، دشت آبرفتی با کاربری زراعی و مسکونی است. بلندی‌های آبخیز از ۳۵- متر تا ۳۲۲۲ متر متغیر است. مناطق جنوبی به دلیل اختلاف زیاد در بلندی با دشت آبرفتی شمالی و بارندگی زیاد سبب روان شدن رودهای جنوبی- شمالی بسیار جوان و با انرژی فرساینده‌ی زیاد شده‌اند که این رودها پس از ملحق شدن به آبراهه اصلی آبخیز قره‌سو به‌سوی دریا روانه می‌شوند.

جغرافیایی ۵۴° ۰۰' تا ۵۴° ۴۵' شرقی است. این آبخیز با ۱۶۷۰ کیلومترمربع مساحت، دربرگیرنده ۸٪ از مساحت کل استان گلستان است. آبخیز قره‌سو از شمال و شرق به آبخیز گرگان‌رود، از جنوب به آبخیز نکارود و از غرب به آبخیز خلیج گرگان و نیز دریاچه بزرگ خزر محدود می‌شود و در روستای قره‌سو به این دریاچه تخلیه می‌شود (شکل ۱). ۸٪ آب سطحی استان معادل با ۱۰۰ میلیون مترمکعب در این آبخیز جریان دارد. بخش بزرگی از جنوب آبخیز قره‌سو



شکل ۱- موقعیت جغرافیایی آبخیز قره‌سو.

Figure 1- Geographical location of the Qarasu Watershed.


روش پژوهش

پراکنش رخداد سیل، در مرحله سوم کمی‌کردن، وزن‌دهی عامل‌های مؤثر و آزمون استقلال داده‌ها، در مرحله چهارم اجرای مدل‌های GRU، LSTM و TCN، تهیه نقشه‌های پهنه‌بندی خطر رخداد سیل و

تهیه نقشه‌ها و پیش‌بینی خطر رخداد سیل در ۵ مرحله اصلی انجام شد (شکل ۲). در مرحله نخست منطقه پژوهشی انتخاب و نقشه‌های عامل‌های مؤثر جمع‌آوری و آماده‌سازی شد. در مرحله دوم تهیه نقشه

شد و خطر رخداد سیل پیش‌بینی و مناسب‌ترین مدل معرفی شد.

طبقه‌بندی آنها به پنج رده خیلی کم، کم، متوسط، زیاد و خیلی زیاد انجام شد. سرانجام در مرحله پنجم دقت طبقه‌بندی و اعتبارسنجی نقشه‌های پهنه‌بندی ارزیابی



شکل ۲- نمودار روش پژوهش.

Figure 2- Diagram of research method.

تحقیقات و آموزش کشاورزی و منابع طبیعی استان گلستان، تصویرهای گوگل‌ارث برای رسم و تدقیق، بهره‌گیری شد. بر این اساس، تعداد ۵۹ نقطه سیلابی (سال‌های ۲۰۱۹-۱۹۹۱) شناسایی و نقشه پراکنش مناطق رخداد سیل در منطقه پژوهشی، تهیه شد. نقاط سیلابی در قالب دو دسته آموزشی و آزمایشی به‌ترتیب با نسبت ۷۰٪ برای واسنجی (اجرا یا توسعه) و ۳۰٪ برای اعتبارسنجی مدل‌ها به‌طور کاملاً تصادفی در محیط ArcGIS®10.5 تقسیم و انتخاب شدند.

نقشه پراکنش رخداد سیل

در این پژوهش برای استفاده از روش‌های یادگیری ماشین و مدل‌سازی پهنه‌بندی و پیش‌بینی خطر رخداد سیل از داده‌های مکانی و نقشه پراکنش سیل‌خیزی به‌عنوان متغیر وابسته استفاده شد. در راستای تهیه این نقشه، از اطلاعات سیل مدیریت منابع آب وزارت نیرو، بازدیدهای میدانی، ثبت مکانی نقاط سیل‌خیز به‌وسیله دستگاه موقعیت‌یاب جهانی (GPS)، نقشه به‌دست آمده از پردازش تصویرهای ماهواره‌ای در سال ۲۰۱۹ تهیه‌شده به‌وسیله مرکز



شکل ۳- شواهدی از رخداد سیل در منطقه مطالعه‌شده (a) و (b) رود قره‌سو، (c) و (d) شهر گرگان.
Figure 3- Evidence of flooding in the study area (a) and (b) Qarasu River (c) and (d) Gorgan City.

بارش^۸، فراوانی آبراهه^۹، ضریب نفوذ^{۱۰}، شاخص توان آبراهه^{۱۱}، شاخص رطوبت پستی‌بلندی^{۱۲}، شاخص موقعیت پستی‌بلندی^{۱۳}، انحنا^{۱۴} مقطع^{۱۴}، شاخص پوشش گیاهی^{۱۵} و فاصله از رود^{۱۶}.

نقشه‌های پایه استفاده‌شده در این پژوهش در جدول ۱ ارائه‌شده است. شایان ذکر است مقیاس تمام نقشه‌ها در محیط GIS بر اساس کوچک‌مقیاس‌ترین نقشه عامل استفاده‌شده یکسان‌سازی و عادی شد و دقت نقشه‌های خروجی بر اساس مقیاس ۱:۱۰۰۰۰۰ تحلیل شد. برای پهنه‌بندی خطر رخداد سیل، معیارها بر اساس مقیاس، موقعیت منطقه پژوهشی و روش پهنه‌بندی به‌کار برده‌شده، ارزیابی شدند.

جمع‌آوری اطلاعات و تهیه عامل‌های مؤثر بر سیل عامل‌های مؤثر بر رخداد سیل (داده‌های مستقل) صرف‌نظر از قابلیت اندازه‌گیری، از کل منطقه مطالعه‌شده جمع‌آوری و تهیه شدند. چندین سنجه ممکن است در رخداد سیل برای یک منطقه خاص مؤثر باشند، در حالی که این سنجه‌ها ممکن است برای محیط‌های دیگر اهمیت کمی داشته باشند. روش انتخاب دقیقی برای اینکه کدام سنجه باید در ارزیابی خطر سیل استفاده شود، وجود ندارد. با این حال، برخی از متغیرها بیشتر به‌وسیله محققین استفاده شده‌اند که بیانگر اهمیت و نقش مهم آنها در پژوهش‌های سیلاب است. در این پژوهش، بر اساس سابقه پژوهش‌های انجام‌شده (شیرانی و صدری ۲۰۲۳، رحمتی و همکاران ۲۰۱۶ الف و ب، حقی‌زاده و همکاران ۲۰۱۷)، منابع موجود و تجارب متخصصان، ۱۶ عامل اثرگذار برای تهیه نقشه خطر رخداد سیل انتخاب شدند. این عامل‌ها عبارت بودند از: بلندی^۱، شیب^۲، تراکم زهکشی^۳، سنگ‌شناسی^۴، کاربری زمین^۵، نوع خاک^۶، میانگین سالانه بارش^۷، شدت

-
- 6- Soil Type
 - 7- Average Annual Rainfall
 - 8- Rainfall Intensity
 - 9- Stream Frequency
 - 10- Infiltration Number
 - 11- Stream Power Index
 - 12- Topographic Wetness Index
 - 13- Topographic Position Index
 - 14- Profile Curvature
 - 15- Normalized Difference Vegetation Index
 - 16- Distance to River

-
- 1- Elevation
 - 2- Slope
 - 3- Drainage Density
 - 4- Lithology
 - 5- Land Use

جدول ۱- نقشه‌های پایه استفاده‌شده برای منطقه مطالعه‌شده.

Table 1- Basic maps used for the study area.

Map	Year	Scale/pixel size	Information Extracted	Source
Geological map of Golestan province	2002	1:100,000	Different classes of geology	Geology and Mineral Exploration Organization of Iran
Topography Map		1:50,000		Iranian Surveying Organization
Landsat 8 satellite images	2021	50*50 (m)	NDVI	United States Geological Survey
Land use map of Golestan province	2017	1:100,000	land use classes	Golestan Province Agricultural and Natural Resources Research Center
Rainfall contour map	2000-2021	50*50 (m)	Annual Rainfall - Intensity of Daily Rainfall	Iran Meteorological Organization
Aerial photos		1:40,000		
Digital Elevation Model (DEM)	-	12.5*12.5 (m)	Elevation-Slope-Curvature-TPI-TWI-SPI-SF-DD-DFR-IN*	Japan Space Agency
Soil type	-	50*50 (m)	Classification of soil units	Soil map of Golestan Province

*: شاخص موقعیت پستی‌بلندی، شاخص رطوبت پستی‌بلندی، شاخص توان آبراهه، فراوانی آبراهه، تراکم زهکشی، فاصله از رود، ضریب نفوذ.


*: Topographic Position Index, Topographic Wetness Index, Stream Power Index, Stream Frequency, Drainage Density, Distance to River, Infiltration Number.

تمام نقشه‌ها با ابعاد پیکسل ۵۰×۵۰ مترمربع نمونه‌برداری شدند.


مدل‌سازی نقشه‌های خطر رخداد سیل

حافظه کوتاه‌بلندمدت (LSTM^{۱۷}) نوعی شبکه عصبی در قلمرو یادگیری عمیق ماشین است. با بهره‌گیری از این شبکه با ترکیب واحدهای حافظه و واحدهای دروازه‌ای (شامل دروازه‌های ورودی، دروازه‌های فراموشی و دروازه‌های خروجی) می‌توان انتقال و ذخیره اطلاعات را به‌طور دقیق بررسی کرد (چن و همکاران ۲۰۲۳). افزون بر این، می‌توان روندهای بلندمدت رخداد سیل را ثبت کرد. ساختار سلولی شبکه LSTM در شکل ۵ نشان‌داده شده است. از شبکه LSTM با دروازه فراموشی برای تعیین اینکه کدام اطلاعات باید از سلول حافظه (St) حذف شوند، استفاده می‌شود.

نقشه میانگین سالانه بارش و شدت بارش روزانه با آمار ۲۱ ساله ایستگاه‌های هواشناسی در محدوده بررسی‌شده (۷۷ ایستگاه باران‌سنجی، ۱۴ ایستگاه اقلیم‌شناسی و ۱۰ ایستگاه همدید) و روش میان‌یابی کریجینگ در محیط ArcGIS®10.5 برای آبخیز مطالعه‌شده، تهیه شد. نقشه شاخص عادی‌شده تفاوت پوشش گیاهی و کاربری زمین منطقه پژوهشی به‌ترتیب بر اساس تصویرهای ماهواره لندست ۸ و اطلاعات مرکز تحقیقات کشاورزی و منابع طبیعی استان گلستان با مقیاس ۱:۱۰۰۰۰۰ در محیط نرم‌افزار ENVI®4.5 تصحیح و تهیه شد. شاخص وضعیت پستی‌بلندی، شاخص توان آبراهه و شاخص رطوبت پستی‌بلندی با استفاده از مدل رقومی ارتفاعی در نرم‌افزار SAGA®9.9 تهیه و تولید شدند (شکل ۴). برای یکپارچه‌سازی داده‌ها و ورود آنها به مدل‌ها، دوباره



شکل ۴ - عامل‌های اثرگذار بر رخداد سیل در منطقه مطالعه‌شده.
Figure 4- Flood conditioning factors of the study area.



شکل ۵- ساختار سلولی شبکه LSTM.
Figure 5- LSTM network cell structure.

می‌شود که کدام اطلاعات به‌روزرسانی شوند. با این دروازه می‌توان دریافت که آیا داده‌های رخداد سیل جدید به حالت سلول اضافه شده‌اند یا خیر. با یادگیری، شبکه اهمیت داده‌های سیل‌خیزی جدید را تعیین کرده و بر این اساس اطلاعات مرتبط را در حالت سلول حافظه (S_{t-1}) می‌توان به‌روزرسانی کرد.

این تصمیم بر اساس خروجی گره لایه پنهان قبلی (h_{t-1}) و ورودی کنونی رخداد سیل (x_t) است. داده‌های تعداد رخداد در هر نقطه زمانی، ثبت می‌شود. با عملکرد لایه S دروازه فراموشی (σ) یا این اطلاعات حفظ می‌شود یا فراموش می‌شود و فقط آنچه را که برای پیش‌بینی رخداد آینده مفید است، نگه‌داشته می‌شود. با استفاده از دروازه ورودی مشخص

پردازش داده‌های ترتیبی مانند متن، صدا یا سری‌های زمانی استفاده می‌شود. هر سلول GRU شامل دو دروازه است:

الف- دروازه به‌روزرسانی^{۱۹} تعیین‌کننده آن است که چه اندازه از حالت یا حافظه قبلی باید حفظ شود و چه اندازه از ورودی جدید باید جایگزین شود.

ب- دروازه بازنشانی^{۲۰} تصمیم‌گیرنده آن است که چه اندازه از اطلاعات قبلی باید فراموش شود.

GRU یک نوع بهینه‌شده از RNN سنتی است. این شبکه حافظه دارد و عملکرد آن در مواجهه شدن با مسائل توالی، خوب است (ژانگ و همکاران ۲۰۲۱). با این حال، در مقایسه با RNN سنتی، از بروز مشکلات ناپدید شدن شیب و انفجار شیب جلوگیری می‌کند (چن و همکاران ۲۰۲۱). افزون بر این، GRU بسیار ساده‌تر و کارآمدتر از نوع دیگر، LSTM، است. این شبکه فقط از دروازه به‌روزرسانی و دروازه تنظیم مجدد تشکیل شده است. دروازه به‌روزرسانی معادل ترکیب دروازه فراموشی و دروازه ورودی LSTM است. با این دروازه می‌توان به شکل خطی عامل فراموشی و حالت به‌روزرسانی را بررسی کرد و اندازه حافظه قبلی ذخیره‌شده در گام زمانی کنونی را تعریف کرد. با دروازه تنظیم مجدد بخشی از اطلاعات حالت کنونی را که باید در حالت بعدی استفاده شود، می‌توان بررسی کرد و شیوه ترکیب اطلاعات ورودی جدید با حافظه قبلی را نیز تعیین کرد (وانگ و همکاران ۲۰۲۰). ساختار سلولی GRU در شکل ۶ نشان داده شده است. محتوای خاص تابع به شرح زیر است: I_t : دروازه تنظیم مجدد، z : دروازه به‌روزرسانی، (h_{t-1}) : خروجی دروازه جدید در زمان قبل، $\tilde{h}_t$: اطلاعات حالت پنهان و h_t اندازه خروجی در زمان کنونی است.

$$r_t = \sigma(W_r \cdot [x_t, h_{t-1}] + b_r) \quad (9)$$

$$z_t = \sigma(W_z \cdot [x_t, h_{t-1}] + b_z) \quad (10)$$

$$\tilde{h}_t = \tanh(W_{\tilde{h}} \cdot [x_t, r_t h_{t-1}]) \quad (11)$$

$$h_t = z_t \tilde{h}_t + (1 - z_t) h_{t-1} \quad (12)$$

با دروازه خروجی اطلاعات و خروجی‌های لازم به دست می‌آید (h_t). با این دروازه مشخص می‌شود که کدام اطلاعات مهم باید از حالت سلول استخراج شوند. با این سازوکار و با بهره‌گیری از مدل می‌توان روند سیل‌خیزی را بر اساس داده‌های رخداد گذشته و کنونی به طور دقیق پیش‌بینی کرد. توابع فعال‌سازی S و تانژانت به شکل معادله‌های ۱ و ۲ بود.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

در این پژوهش معادله دروازه فراموشی استفاده شده به شکل رابطه ۳ بود.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

W : عبارت وزنی، b : عبارت بایاس، (h_{t-1}) : خروجی رخداد سیل در لحظه قبل $t-1$ است.

معادله‌های ورودی دروازه به شکل رابطه‌های ۴ و ۵ بود.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$g_t = \tanh(W_g \cdot [h_{t-1}, x_t] + b_g) \quad (5)$$

سپس، وضعیت سلول حافظه به S_t به‌روزرسانی شد. معادله سلول حافظه داخلی به شکل رابطه ۶ بود.

$$S_t = f_t \cdot S_{t-1} + i_t \cdot g_t \quad (6)$$

معادله‌های دروازه خروجی به شکل رابطه‌های ۷ و ۸ بودند.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$


$$h_t = o_t \cdot \tanh(S_t) \quad (8)$$

مدل واحد بازگشتی دروازه‌ای^{۱۸} یکی از انواع شبکه‌های عصبی بازگشتی (RNN) است که برای

19- Update Gate

20- Reset Gate

18- Gated Recurrent Unit



شکل ۶ - ساختار سلولی GRU.
Figure 6- GRU cell structure.

واحد TCN به خروجی‌های لایه‌های پیچشی گسترده می‌افزایند. این رویکرد آموزش هم‌گرایی را آسان‌تر کرده و توانایی تعمیم مدل را افزایش می‌دهد.

$$o = \text{SeLU}(x + F(x)) \quad (14)$$

x و o : به ترتیب اندازه‌های مشاهده‌شده و پیش‌بینی‌شده رخداد سیل، F : مجموعه‌ای از عملیات (توابع پیچشی گسترده و فعال) است. برای اطمینان از اینکه ورودی X (رخداد‌های متوالی) با اندازه $F(x)$ مطابقت دارد، یک لایه پیچشی 1×1 اضافه شد. از این‌رو، رابطه ۱۴ به شکل رابطه ۱۵ تغییر یافت.

$$o = \text{SeLU}(\text{conv}_{1 \times 1}(x) + F(x)) \quad (15)$$

برای اجرای مدل‌ها با استفاده از نرم‌افزار MATLAB®9، ۱۶ عامل مؤثر بر رخداد سیل (متغیر مستقل) و نقشه پراکنش نقاط سیل (متغیر وابسته) در محیط ArcGIS®10.5 به شکل یک پایگاه اطلاعات مکانی واحد سلول مبنا با اندازه سلولی ۵۰ متر و ساختار مختصات جغرافیایی UTM منطقه ۴۰ تهیه شدند. برای تقسیم‌بندی داده‌ها برای مراحل آموزش و آزمایش از ۷۰٪ از داده‌ها برای آموزش و ۳۰٪ باقی‌مانده برای آزمون و اعتبارسنجی مدل‌ها استفاده شد.


σ : تابع S، $\tanh$: تابع تانژانت هایپربولیک، x_t : ورودی در زمان t ، W : ماتریس وزن‌های مختلف و b : بایاس است.

شبکه پیچشی زمانی^{۲۱} (TCN) نوعی شبکه عصبی است که برای پردازش داده‌های ترتیبی طراحی شده است (ژانگ و همکاران) و از فناوری پیچشی گسترده استفاده شده است و شامل درج شکاف‌هایی در هسته‌های پیچشی است. این رویکرد، میدان دریافت هسته را بدون اضافه کردن سنج‌های بیشتر افزایش می‌دهد. در نتیجه توانایی شبکه برای ثبت وابستگی‌های بلندمدت در رخداد سیل‌های متوالی افزایش می‌یابد. برای محاسبه میان لایه پیچشی گسترده و توالی ورودی جابجایی از رابطه ۱۳ استفاده شد.

$$F(s) = (X * df)(s) = \sum_{i=0}^{k-1} f(i) \cdot X_{s-d \cdot i} \quad (13)$$

X : سیل‌های متوالی به عنوان ورودی، $f: \{0, \dots, k-1\} \rightarrow \mathbb{R}$ - فیلتر، d : اندازه ضریب اتساع، k : اندازه هسته فیلتر و $s - d \cdot i$: نورون قبل از لایه پیچشی گسترده شده است.

در مدل TCN، معرفی بخش‌های باقی‌مانده، سبب افزایش عملکرد مدل می‌شود (شکل ۷). با الگوبرداری از ساختار بلوک باقی‌مانده موجود در ResNet، این بخش‌ها ورودی‌های اصلی رخداد سیل را از بخش



شکل ۷- ساختار سلولی TCN.
Figure 7- TCN cell structure.

^{۲۵}TP: تشخیص درست رخداد سیل است و بیانگر آن است که در واقعیت سیل رخ داده است و مدل نیز سیل را پیش‌بینی کرده است.

^{۲۶}FN: تشخیص ندادن سیل (خطای خطرناک) است و بیانگر آن است که در واقعیت سیل رخ داده است ولی مدل رخداد سیل را پیش‌بینی نکرده است.

مساحت زیر منحنی ROC بیانگر اندازه پیش‌بینی ساختار با توصیف توانایی آن در برآورد صحیح بودن و نبودن رخدادها است. AUC-ROC دقت یک مدل پیش‌بینی‌کننده را با تعیین توانایی ساختار برای انتظار بودن یا نبودن رخداد صحیح (رویدادها) از پیش تعریف‌شده توصیف می‌کند (پوررتقی و پورقاسمی ۲۰۱۵). در شرایطی که مدل با داده‌های نامشخص محاسبه شود اندازه AUC از ۰/۵ تا ۰/۶ متغیر بوده و نشان‌دهنده ناکارآمدی مدل است (شیرانی و همکاران ۲۰۲۴). اندازه AUC از ۰/۶ تا ۰/۷ نشان‌دهنده یک مدل ضعیف است و اندازه AUC از ۰/۷ تا ۰/۸ نشان‌دهنده یک مدل نسبتاً خوب با عملکرد متوسط است. هنگامی که اندازه AUC بیشتر از ۰/۸ باشد نشان‌دهنده برازش زیاد با مجموعه داده‌ها و کارآمدی مدل است (ساجدی‌حسینی و همکاران ۲۰۱۸).

برای تحلیل و مقایسه ارزش‌های طبقه‌بندی‌شده نادرست مدل‌ها، از شاخص مساحت زیر منحنی ارزش یا هزینه^{۲۷}(CC) استفاده شد (شیرانی و همکاران ۲۰۲۴). ارزش کل طبقه‌بندی نادرست یک مدل به

روش ارزیابی دقت طبقه‌بندی مدل‌ها

از منحنی عملکرد نسبی یا گیرنده (ROC)^{۲۲}، برای مقایسه و ارزیابی مدل‌های پهنه‌بندی استفاده و اعتبار و صحت مدل تعیین شد. در سال‌های گذشته این منحنی به‌عنوان کارآمدترین روش ارزیابی به‌وسیله پژوهشگران پرشماری استفاده‌شده است (فام و همکاران ۲۰۲۰، کستیچ و زهریا ۲۰۱۷، رحمتی و همکاران ۲۰۲۰). از لحاظ گرافیکی ارتباط میان نرخ‌های مثبت کاذب (محور X) و نرخ‌های مثبت واقعی (محور Y) برای هر اندازه در قالب ماتریس ابهام (Confusion Matrix)، ممکن خواهد بود (رابطه‌های ۱۶ و ۱۷) (پورقاسمی و همکاران ۲۰۱۴).

$$X = FPR = 1 - \text{specify} = 1 - \left[\frac{TN}{TN + FP} \right] \quad (16)$$

$$Y = TPR = \text{sensitivity} = \left[\frac{TP}{TP + FN} \right] \quad (17)$$

^{۲۳}TN: تشخیص درست نبودن رخداد سیل است و بیانگر آن است که در داده‌های واقعی رخداد سیل مشاهده‌نشده و مدل نیز رخداد سیل را پیش‌بینی نکرده است.

^{۲۴}FP: هشدار نادرست رخداد سیل است و بیانگر آن است که در داده‌های واقعی پدیده سیل رخ نداده است، اما مدل رخداد سیل را پیش‌بینی کرده است.

25- True Positive

26- False Negative

27- Area Under the Cost Curve

22- Receiver Operating Characteristic

23- True Negative

24- False Positive

هستند، رسم شد. هرچه ارزش قابل انتظار عادی‌شده کمتر باشد، مدل مدنظر برای پهنه‌بندی رخداد سیل مناسب‌تر است. افزون بر این، تفاوت میان توانایی‌های پیش‌بینی مدل‌های خطر سیل بر اساس فاصله عمودی میان دو منحنی ارزش اندازه‌گیری شد.

برای ارزیابی عملکرد و طبقه‌بندی طبقه‌ها در هر مدل از شاخص‌های نسبت فراوانی (FR) و مساحت سلول هسته (SCAI) استفاده شد (شیرانی و همکاران ۲۰۲۴). شاخص نسبت فراوانی (FR) بیانگر نسبت مساحت نقطه سیلابی در هر طبقه به مساحت همان طبقه است. این شاخص نشان‌دهنده دقت برای انتخاب مدل‌ها است. برای محاسبه شاخص مساحت سلول هسته (SCAI)، منطقه مطالعه‌شده به شبکه‌هایی از سلول‌ها تقسیم و بر اساس نسبت پیکسل سیلابی محاسبه شد. به بیان دیگر برعکس نسبت فراوانی (FR) با تقسیم درصد مساحت هر پهنه به درصد مساحت سلول‌های سیلابی، شاخص نامبرده عادی محاسبه شد. شاخص مساحت سلول هسته SCAI نشان‌دهنده تراکم نقاط محدوده سیل در پهنه‌هاست و برای ارزیابی دقت در انتخاب مدل استفاده شد (شیرانی و همکاران ۲۰۱۸).

نتایج و بحث

نتایج طبقه‌بندی نقشه‌های پهنه‌بندی خطر رخداد سیل نشان داد مساحت رده‌های خطر خیلی کم، کم، متوسط، زیاد، خیلی زیاد در مدل TCN به ترتیب با نسبت‌های ۳۴/۶۶، ۳/۰۰، ۰۶/۰۳، ۱۱/۲۲ و ۴۵/۰۹٪؛ در مدل GRU به ترتیب با نسبت‌های ۲۷/۶۸، ۰۶/۶۵، ۲۲/۰۲، ۳۴/۱۶ و ۰۹/۴۹ و در مدل LSTM به ترتیب با نسبت‌های ۳۷/۵۷، ۰۹/۳۳، ۱۱/۴۷، ۱۸/۸۳ و ۲۲/۸۰٪ از مساحت ۱۶۷۰ کیلومترمربعی منطقه مطالعه‌شده را پوشش داد (جدول ۲، شکل ۸). افزون بر این، از هم‌پوشانی نقشه پراکنش سیلاب با نقشه طبقه‌بندی پهنه‌بندی خطر رخداد سیل مشخص شد در مدل‌های TCN، GRU و LSTM رده‌های خطر خیلی کم تا کم به ترتیب ۰۵/۰۸، ۰۳/۳۹ و ۱۰/۱۶٪ و رده‌های متوسط، خطر زیاد و خیلی زیاد به ترتیب

درصد واحدهای واقعیت زمینی که به اشتباه طبقه‌بندی شده‌اند، احتمال پیش‌بینی رخداد سیل در منطقه و ارزش‌های به اشتباه طبقه‌بندی از انواع مختلف خطا، بستگی دارد (دراموند و هولت ۲۰۰۰). منحنی ارزش، نشان‌دهنده ارزش قابل انتظار عادی‌شده به عنوان تابعی از تابع احتمال-ارزش است. ارزش قابل انتظار عادی‌شده NE(C) با استفاده از رابطه ۱۸ محاسبه شد.

$$NE(C) = \frac{(1 - TP \cdot P(+) \cdot C(-|+) + FP \cdot P(-) \cdot C(+|-))}{P(+) \cdot C(-|+) + P(-) \cdot C(+|-)} \quad (18)$$

در این رابطه بیشینه ارزش قابل انتظار عادی در شرایطی به دست می‌آید که تمام داده‌ها (بودن و نبودن رخداد) به اشتباه طبقه‌بندی شده باشند. به عنوان مثال زمانی که FN و FP هر دو یکسان باشند، بیشینه و کمینه ارزش عادی‌شده به ترتیب یک و صفر است. اندازه عادی‌شده $P(+) \cdot C(-|+)$ با استفاده از رابطه ۱۹ محاسبه شد.

$$PC(+) = \frac{(P(+) \cdot C(-|+))}{P(+) \cdot C(-|+) + P(-) \cdot C(+|-)} \quad (19)$$


$PC(+)$: تابع احتمال-ارزش است. دامنه $PC(+)$ از صفر تا یک متغیر است.

وقتی ارزش‌های نادرست طبقه‌بندی شده برابر باشند، عبارت به شکل $PC(+) = P(+)$ خواهد بود. به طور کلی، $PC(+) = 0$ زمانی به دست می‌آید که ارزش فقط به موارد منفی وابسته باشد، یعنی موارد مثبت $(P(+) = 0)$ یا ارزش نادرست طبقه‌بندی شده آن‌ها هرگز رخ نمی‌دهد. اگر $C(-|+) = 1$ باشد، اندازه $PC(+) = 1$ مربوط به اندازه‌های بیشینه است. یعنی: $P(-) = 0$ یا $C(+|-) = 0$ است.

منحنی‌های ارزش برای ارزیابی و مقایسه مدل‌های پهنه‌بندی سیل بر اساس ارزش قابل انتظار عادی‌شده (محور y) در مقابل تابع ارزش احتمالی (محور x) که به ترتیب نشان‌دهنده عملکرد طبقه‌بندی و نقاط عملیاتی (داده‌های به دست آمده از واقعیت زمینی)

نتایج به‌دست آمده از محاسبه شاخص‌های نسبت فراوانی (FR) و مساحت سلول هسته (SCAI) برای ارزیابی دقت طبقه‌بندی نقشه‌های پهنه‌بندی خطر رخداد سیل از اجرای مدل‌ها نشان داد دو مدل TCN و LSTM در مقایسه با GRU کارآمدتر بودند (جدول ۲).

۹۱/۵۲، ۷۹/۶۶ و ۷۹/۶۶٪ از نقاط سیل را کسب کردند. در مدل TCN، مناطقی که در برگیرنده بیشترین نقاط سیل بودند سهم بیشتری را نیز کسب کردند و رده خطر خیلی‌زیاد به‌طور قابل توجهی افزایش یافت ولی در مدل LSTM و GRU این مناطق کاهش یافتند (جدول ۲ و شکل ۸).



شکل ۸- نقشه‌های پهنه‌بندی خطر رخداد سیل با اجرای مدل‌های TCN، GRU و LSTM.

Figure 8- Flood hazard zonation maps by implementing TCN, GRU and LSTM models.

جدول ۲- مساحت رده‌های خطر رخداد سیل، نسبت فراوانی و شاخص سلول هسته.

Table 2- Area of hazard classifications and flood occurrence, FR and SCAI.

Model	Flood hazard zones	Flood point	Flood point (%)	Pixel of zones	Pixel of zones (%)	Frequency ratio (FR)	Seed (%)	SCAI
TCN	Very low	2	3.39	59811	34.66	0.03	3.39	10.23
	Low	1	1.69	5185	3.00	0.02	1.69	1.77
	Moderate	2	3.39	10399	6.03	0.03	3.39	1.78
	High	5	8.47	19354	11.22	0.08	8.47	1.32
	Very high	49	83.05	77799	45.09	0.83	83.05	0.54
GRU	Very low	0	0.00	11474	6.65	0.00	0.00	0.00
	Low	2	3.39	47759	27.68	0.03	3.39	8.17
	Moderate	10	16.95	37988	22.02	0.17	16.95	1.30
	High	45	76.27	58944	34.16	0.76	76.27	0.45
	Very high	2	3.39	16383	9.49	0.03	3.39	2.80
LSTM	Very low	3	5.08	64819	37.57	0.05	5.08	7.39
	Low	3	5.08	16099	9.33	0.05	5.08	1.83
	Moderate	6	10.17	19795	11.47	0.10	10.17	1.13
	High	12	20.34	32493	18.83	0.20	20.34	0.93
	Very high	35	59.32	39342	22.80	0.59	59.32	0.38


مدیریت کرد. از این رو، نقشه کاربری زمین در سال‌های ۲۰۱۷ و ۲۰۲۰ با استفاده از ماهواره سنتینل ۲ تهیه شد. نتایج به دست آمده بر اساس مساحت هر یک از کاربری‌های مختلف نشان داد که بیشترین سهم آبخیز مربوط به مناطق جنگلی و زراعی است. از این رو، در سال‌های گذشته با افزایش مساحت مناطق مسکونی و ساخت و ساز در بافت جنگلی منطقه، پوشش گیاهی آبخیز مطالعه شده کاهش یافته است. افزون بر این، زمین‌های زراعی به دلیل ضریب نفوذپذیری خاک و عملیات کشاورزی به طور ویژه بخشی از رواناب تشکیل شده از رخدادهای سیل را متوقف کرده و عاملی برای جلوگیری از شدت سیل است. بر پایه نتایج این پژوهش مساحت این کاربری نیز کاهش یافته است (جدول ۳ و شکل ۹).

بر اساس رابطه منطقی و نسبی موجود میان تعداد نقاط سیل و پهنه‌های خطر، به ترتیب برای پهنه‌های با خطر خیلی کم تا خیلی زیاد اندازه نسبت فراوانی (FR) افزایش و شاخص مساحت سلول هسته (SCAI) به طور قرینه و معکوس کاهش یافت. روند شاخص FR در مدل‌های TCN و LSTM افزایشی بود و در رده‌های پرخطر (زیاد و خیلی زیاد) اندازه‌های آن قابل قبول بود. روند کاهش شاخص SCAI، نشان‌دهنده عملکرد خوب این دو مدل بود. اما، اندازه‌های هر دو شاخص FR و SCAI مدل GRU در رده خطر خیلی زیاد قابل قبول نبود (جدول ۲). از آنجایی که شیوه‌های مدیریتی کاربری زمین بیشترین اثر را بر منابع طبیعی (پوشش گیاهی، آب، مواد غذایی و خاک) دارد، در نتیجه با بهره‌گیری از اطلاعات کاربری زمین می‌توان مشکلات منابع طبیعی را

جدول ۳- مساحت کاربری‌های منطقه مطالعه شده در سال‌های ۲۰۱۷ و ۲۰۲۰.

Table 3- Land use area of the study area in 2017 and 2020.

Land use	Area-2017 (km ²)	Percent-2017	Area-2020 (km ²)	Percent-2020
Water	1.84	0.11	3.173	0.19
Forest	566.63	33.93	559.45	33.50
Crops	857.55	51.35	852.869	51.07
Built Area	110.22	6.60	117.067	7.01
Bare Ground	1.17	0.07	0.501	0.03
Rangeland	132.60	7.94	136.94	8.20



شکل ۹- توزیع کاربری‌های مختلف در سال‌های ۲۰۱۷ و ۲۰۲۰.


Figure 9- Distribution of different land uses in 2017 and 2020.

بر پایه نتایج مساحت زیر منحنی ROC، دقت هر سه مدل در مرحله آزمون یا اعتبارسنجی عالی (بیش از ۰/۹) بود.

از این رو، استفاده و بهره‌گیری از این مدل‌ها برای تهیه نقشه پهنه‌بندی خطر رخداد سیل در عملیات‌های زیربنایی و توسعه‌ای پیشنهاد می‌شود. اما، در جایگاه مقایسه با یکدیگر، نتایج به‌دست آمده از اندازه‌های مساحت زیر منحنی (AUC) در مدل TCN در هر دو مرحله آموزش و آزمون (۰/۹۶ و ۰/۹۲) بیانگر عملکرد خوب این مدل بود. این یافته نشان‌دهنده همبستگی زیاد میان نقشه خطر رخداد سیل تهیه‌شده و نقشه پراکنش تعداد رخداد سیل است. از سوی دیگر، اندازه‌های مساحت زیر منحنی (AUC) دو مدل LSTM و GRU در مرحله آموزش بیشتر بود. اما، در مرحله آزمون این اندازه‌ها به‌ترتیب در مدل LSTM و GRU، ۰/۸۶ و ۰/۸۴ و کمتر از ۰/۹ بود (شکل ۱۱).

با توجه به دوره ۳۰ ساله (۱۹۹۱-۲۰۱۹) موقعیت نقاط سیلابی (۵۹ نقطه) در سال‌های مختلف بر مبنای تعداد رخداد سیل (مجموعاً ۹۵ رخداد) در جدول ۴، ارائه شده است. با همپوشانی نقشه‌های پهنه‌بندی به‌دست آمده از اجرای مدل‌ها و نقاط سیل مشخص شد در مدل TCN تعداد ۴۹ نقطه با تکرار مجموعاً ۷۸ رخداد (حدود ۸۲٪) در پهنه خطر خیلی زیاد و تعداد ۵ نقطه با تکرار ۵ رخداد در پهنه خطر زیاد بودند.

در مدل GRU ۲ نقطه با تکرار مجموعاً ۳ رخداد در پهنه خطر خیلی زیاد و تعداد ۴۵ نقطه با تکرار مجموعاً ۷۱ رخداد (تقریباً ۷۵٪) در پهنه خطر زیاد بودند. در مدل LSTM تعداد ۳۵ نقطه با تکرار مجموعاً ۵۳ رخداد (تقریباً ۵۶٪) در پهنه خطر خیلی زیاد و تعداد ۱۲ نقطه با تکرار مجموعاً ۲۲ رخداد (تقریباً ۲۳٪) در پهنه خطر زیاد بودند (جدول ۴ و شکل ۱۰).



شکل ۱۰- موقعیت نقاط سیلابی براساس تعداد رخداد.

Figure 10- Location of flood points based on the number of events.


در مقایسه با دو مدل دیگر بیشتر بود و این مدل کارآمدتر بود (شکل ۱۲).

افزون بر این، هرچه شاخص مساحت زیر منحنی هزینه (CC) کمتر باشد، دقت مدل بیشتر است. در این پژوهش، بر پایه شاخص (CC) دقت مدل TCN


جدول ۴- مشخصات نقاط سیلابی (محدوده روستاها).

Table 4- Specifications of Flood points (Village boundaries).

Village	City	X Coordinates	Y Coordinates	Years of Event	Number of Flood Events	LSTM Class	TCN Class	GRU Class
Chapaghli	Turkaman	240343.4601	4094039.54	1992-2010-2016	3	Low	Very High	Moderate
Sejwal	Turkaman	242992.9336	4086180.688	2005-2010-2010	3	High	Very High	High
Deraznow	Kurdkoy	245089.9309	4062058.652	1991-2010-2012	3	Very Low	Very Low	Low
Khajehlor	Turkaman	251327.666	4093047.907	2010-2012-2019	3	High	Very High	High
Kelasingal	Gorgan	259997.249	4076636.17	2009-2010-2012	3	Very High	Very High	High
Ziarat	Gorgan	274752.8091	4065446.493	1992-2009-2016	3	Very Low	Very Low	Low
Gharesu	Turkaman	236788.7583	4079589.751	1996-2016	2	Very High	Very High	High
Zaboli Mahalleh Alia	Turkaman	246624.7537	4084286.727	2001-2015	2	Very High	Very High	High
Panjpeikar	Turkaman	247020.7155	4092993.221	2010-2019	2	Very High	Very High	High
Chahardeh	Kurdkoy	248483.9749	4076149.027	2008-2015	2	Very High	Very High	High
Gorji Mahalleh	Kurdkoy	252420.2122	4078186.303	1995-2015	2	High	Very High	High
Miander	Kurdkoy	252433.9407	4073938.937	1994-1995	2	High	Very High	Moderate
Dangalan Khajeh	Kurdkoy	253484.6607	4076200.621	1995-2009	2	Very High	Very High	High
Islamabad	Kurdkoy	254401.8022	4076780.802	1998-1998	2	Very High	Very High	High
Shamushk Sefli	Gorgan	256670.8215	4073715.1	1991-2008	2	Very High	Very High	High
Shamushk Alia	Gorgan	256721.6967	4071417.124	1991-2008	2	Moderate	Moderate	High
Nodije	Gorgan	256837.8233	4080410.933	2009-2010	2	Very High	Very High	High
Gamishlinezar	Turkaman	257825.4829	4089181.611	2012-2014	2	High	Very High	High
Kafshgiri	Gorgan	258137.6751	4076171.111	2012-2014	2	High	Very High	High
Nochman	Gorgan	259463.2838	4072287.414	2008-2009	2	Very High	Moderate	High
Qajar Kalajan	Gorgan	259513.7298	4079348.402	2009-2012	2	High	Very High	High
Laddwin	Gorgan	260632.8664	4083958.788	2012-2014	2	Very High	Very High	High
Versen	Gorgan	261439.5657	4080710.643	2012-2014	2	Very High	Very High	High
Hashemabad	Gorgan	263510.1259	4086210.227	2012-2014	2	Very High	Very High	Moderate
Sistani mahalleh	Gorgan	266184.178	4088004.824	2012-2014	2	High	Very High	Very High
Ojaben	Gorgan	267628.7135	4083503.844	2012-2012	2	Very High	Very High	High
Mamaee	Gorgan	268078.1848	4086307.586	2012-2014	2	Very High	Very High	High
Qurbanabad	Gorgan	271874.2084	4090241.602	2012-2014	2	Very High	Very High	High
Chaharchenar	Gorgan	282031.7223	4087738.507	2012-2015	2	Very High	Very High	High
Tuskastan	Gorgan	284428.6017	4073389.346	1999-2015	2	Moderate	Low	Moderate
Niazabad	Turkaman	239860.0426	4082916.471	2014	1	Low	Very High	Moderate
Zaboli Mahalleh Sefli	Turkaman	245003.2564	4083338.651	2014	1	Moderate	Very High	Moderate
Ivanabad	Turkaman	246223.9609	4086962.233	2016	1	Moderate	Very High	High
Ghareghashli	Turkaman	248120.2042	4087222.216	2016	1	Very High	Very High	High
Zera Mahalleh	Kurdkoy	251541.9095	4076670.823	1995	1	Very High	Very High	High
Khorramabad	Kurdkoy	251899.2717	4073370.745	2014	1	Very High	Very High	High
Gharetappeh	Turkaman	252299.1659	4086756.372	2014	1	Very High	Very High	High
Mofid Abad	Kurdkoy	252374.7581	4077491.216	2014	1	Very High	Very High	High
Chaqr	Kurdkoy	253186.597	4072782.776	2008	1	Very High	Very High	High
Dangalan Sadat	Kurdkoy	253982.8568	4076274.988	1995	1	Very High	Very High	High
Namen	Kurdkoy	254461.1587	4074132.877	1999	1	Very High	Very High	High
Kalajan Sadat	Gorgan	258241.1164	4079215.344	2012	1	High	Very High	High
Esbomahleh	Gorgan	258722.052	4076342.22	2012	1	Moderate	Very High	High
Takhshi mahalleh	Gorgan	259595.0915	4083575.394	2012	1	Very High	Very High	High
Seddon	Gorgan	261226.8251	4076702.61	2003	1	Low	High	Moderate
Seyed Miran	Gorgan	261820.7543	4075375.732	2008	1	Very Low	High	Moderate
Touch	Gorgan	262387.8743	4080731.359	2012	1	Very High	Very High	High
Suleiman Tepe	Gorgan	263296.6182	4088887.134	2010	1	Moderate	Very High	Moderate
Kalu	Gorgan	263415.7744	4077517.002	2002	1	Very High	High	Very High
Lamlang	Gorgan	265463.771	4082722.216	2009	1	Very High	Very High	High
Mahmud's Castle	Gorgan	265777.2645	4085685.087	2012	1	Very High	Very High	High
Saadabad	Gorgan	266222.0673	4077996.068	1998	1	High	High	High
Zangian	Gorgan	268113.7446	4082199.885	2014	1	Very High	Very High	High
Shourhayat	Gorgan	274005.5287	4093402.999	2012	1	High	Very High	High
Etrachal	Gorgan	274723.8306	4087406.148	2016	1	Very High	Very High	High
Sultanabad	Gorgan	277573.5456	4088809.55	2012	1	High	High	Moderate
Nodeh Sharif	Gorgan	283562.1783	4090871.566	2014	1	Very High	Very High	High
Sarkhankelate	Gorgan	283562.2087	4085835.689	2012	1	Very High	Very High	High
Shamsabad	Gorgan	285745.7945	4087952.288	2012	1	Very High	Very High	High



شکل ۱۱- منحنی ROC نقشه‌های خطر رخداد سیل به‌دست آمده از مدل‌های LSTM و GRU، TCN
Figure 11 - ROC curve of hazard maps to flood events resulting from TCN, GRU, and LSTM models.



شکل ۱۲- منحنی ارزش یا هزینه نقشه‌های خطر رخداد سیل به‌دست آمده از مدل‌های LSTM و GRU، TCN
Figure 12 - Cost curve of hazard maps to flood events resulting from TCN, GRU, and LSTM models.

می‌شود که باید تا حد امکان کاهش یابند. در ایران، استان گلستان نیز از این قاعده مستثنی نیست و در سال‌های گذشته در آبخیزهای این استان از جمله

نتیجه‌گیری و پیشنهادها
سیل‌ها ویرانگرترین پدیده در سراسر جهان هستند. رخدادهای پیاپی سیل سبب خسارت‌های جانی و مالی

افزایش یافت. در این راستا، نتایج رخداد سیل سال ۲۰۱۹ با میانگین بارش ۱۶۰ میلی‌متر در آبخیز قره‌سو مؤید آن است که رعایت نکردن حریم رود از سوی شهروندان و نبودن نظارت و مدیریت دقیق شهری بر ساخت و سازهای بدون مجوز سبب خسارت‌های فراوانی خواهد شد. از این‌رو، تجاوز نکردن به بستر رود و رعایت حریم آن در ساخت بناها، اصل اجتناب‌ناپذیری در کاهش مخاطره‌های سیل به‌ویژه در سکونتگاه‌های روستایی به‌شمار می‌آید. پیشنهاد می‌شود بر اساس اهمیت ویژگی‌های ریخت‌سنجی در پهنه‌بندی نقشه‌های خطر رخداد سیل، در پژوهش‌های آینده از این سنجه‌ها همراه با دیگر سنجه‌های متداول در تهیه نقشه‌های پهنه‌بندی استفاده شود. افزون بر این، بر پایه نتایج این پژوهش پیشنهاد می‌شود از روش‌های یادگیری عمیق و ترکیب آن با یکدیگر استفاده شود. همچنین پیشنهاد می‌شود بهره‌گیری از روش‌های ترکیبی نوین (هیبریدی) و بهینه‌سازهای مناسب در دیگر آبخیزهای استان گلستان، بررسی و ارزیابی شود.

تضاد منافع نویسندگان

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

دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله ارائه شده است.

مشارکت نویسندگان

نویسنده اول: مفهوم‌سازی، برنامه‌نویسی و توسعه مدل‌های یادگیری عمیق، تحلیل‌های آماری و اعتبارسنجی، نگارش و ویرایش مقاله
نویسنده دوم: تهیه نقشه‌ها و شکل‌ها، نگارش نسخه اولیه مقاله، بازبینی نتایج

آبخیز قره‌سو سیل‌های زیادی رخ داده است. از این‌رو، تهیه نقشه خطر رخداد سیل برای مدیریت یکپارچه آبخیزها برای پیشگیری و کاهش خطر سیل ضروری است. در این پژوهش، مناطق آسیب‌پذیر سیل با استفاده از مدل‌های LSTM، TCN، GRU و شناسایی شدند. برای تهیه نقشه پهنه‌بندی و پیش‌بینی خطر سیل، از ۵۹ نقطه سیلابی و ۱۶ عامل مؤثر بر رخداد سیل استفاده شد و مدل‌سازی در محیط GIS انجام شد. از ۵۹ نقطه سیل ۷۰٪ آن برای مرحله آموزش و ۳۰٪ آن برای مرحله آزمون در نظر گرفته شد. پس از اجرای مدل‌های LSTM، TCN، GRU و ROC، نتایج شاخص مساحت زیر منحنی (AUC) در مرحله آموزش در هر سه مدل نشان‌دهنده عملکرد عالی مدل‌های نامبرده (۰/۹-۱) در مدل‌سازی بود. اما برازش مدل TCN در مدل‌سازی در هر دو مرحله آموزش و آزمون عالی (بیش از ۰/۹) بود. ارزیابی دقت طبقه‌بندی و اعتبارسنجی مدل‌ها نشان داد دو مدل TCN و LSTM با داشتن آستانه طبقات مناسب در طبقه‌بندی، اولویت کاربرد آنها برای پهنه‌بندی و پیش‌بینی خطر رخداد سیل بیشتر است. اندازه‌های مساحت زیر منحنی هزینه برای مدل‌های TCN، LSTM و GRU به ترتیب ۰/۰۸، ۰/۱۰ و ۰/۱۱ به دست آمد. این یافته بیانگر آن بود که مدل TCN با کمترین اندازه هزینه، کارآمدترین مدل در مدل‌سازی است.

نتایج این پژوهش نشان داد بر پایه مدل TCN، ۴۵٪ از مساحت منطقه در رده خطر خیلی زیاد در برگیرنده ۸۳٪ از رخدادهای سیل بودند. همچنین، بر پایه مدل LSTM، ۲۳٪ از مساحت منطقه در برگیرنده ۶۰٪ از رخدادهای سیل و بر پایه مدل GRU، ۱۰٪ از مساحت منطقه در برگیرنده ۴٪ از رخدادهای سیل بودند.

سرانجام در این پژوهش، نتایج بررسی نقشه‌های کاربری زمین میان سال‌های ۲۰۱۷ و ۲۰۲۰ نشان داد با افزایش مناطق مسکونی و کاهش پوشش گیاهی احتمال خطر رخداد سیل در آبخیز مطالعه‌شده

فهرست منابع

- Aboah A, Adu-Gyamfi Y, Gursoy SV, Merickel J, Rizzo M, Sharma A. 2023. Driver maneuver detection and analysis using time series segmentation and classification. *Journal of Transportation Engineering, Part A, Systems*. 149(3): 1–15. <https://doi.org/10.1061/JTEPBS.TEENG-7312>
- GDNRWM- General Department of Natural Resources and Watershed Management of Golestan Province, Iran. 2018.
- Behera I, Jain N, Martha TR, Bose M. 2026. Optimizing sampling strategies for AI-based landslide susceptibility mapping: a case study of Idukki, Kerala. *Nat Hazards*. 122(1). <https://doi.org/10.1007/s11069-025-07842-8>
- Bentivoglio R, Isufi E, Jonkman SN, Taormina R. 2022. Deep learning methods for flood mapping: a review of existing applications and future research directions. *Hydrology and Earth System Sciences*. 26(16): 4345–4378. <https://doi.org/10.5194/hess>
- Chen H, Lu T, Huang J, He X, Yu K. 2023. An improved VMD-LSTM model for time-varying GNSS time series prediction with temporally correlated noise. *Remote Sensing*. 15: 3694. <https://doi.org/10.3390/rs15143694>
- Chen J, Li Q, Wang H, Deng M. 2020. A machine learning ensemble approach based on random forest and radial basis function neural network for risk evaluation of regional flood disaster: a case study of the Yangtze River Delta, China. *International Journal of Environmental Research Public Health*. 17(1): 49. <https://doi.org/10.3390/ijerph17010049>
- Chen W, Panahi M, Tsangaratos P, Shahabi H, Ilia I, Panahi S, Ahmad BB. 2019. Applying population-based evolutionary algorithms and a neuro-fuzzy system for modeling landslide susceptibility. *Catena*. 172: 212–231. <https://doi.org/10.1016/j.catena.2018.08.025>
- Chen Y, He Y, Zhang LF. 2021. Prediction of InSAR deformation time-series using a long short-term memory neural network. *International Journal of Remote Sensing*. 42(18): 6921–6944. <https://doi.org/10.1080/01431161.2021.1947540>
- Choubin B, Moradi E, Golshan M, Adamowski J, Sajedi-Hosseini F, Mosavi A. 2019. An ensemble prediction of flood susceptibility using multivariate discriminant analysis, classification and regression trees, and support vector machines. *Science of the Total Environment*. 651: 2087–2096. <https://doi.org/10.1016/j.scitotenv.2018.10.064>
- Convertino M, Annis A, Nardi F. 2019. Information-theoretic portfolio decision model for optimal flood management. *Environmental Modelling and Software* 119: 258–274. <https://doi.org/10.1016/j.envsoft.2019.06.013>
- Costache R, Zaharia L. 2017. Flash-flood potential assessment and mapping by integrating the weights-of-evidence and frequency ratio statistical methods in GIS environment–case study: Bâca Chiojdului River catchment (Romania). *Journal of Earth System Science*. 126(4): 1–19. <https://doi.org/10.1007/s12040-017-0828-9>
- Dalu MT, Shackleton CM, Dalu T. 2018. Influence of land cover, proximity to streams and household topographical location on flooding impact in informal settlements in the Eastern Cape, South Africa. *International Journal of Disaster Risk Reduction* 28: 481–490. <https://doi.org/10.1016/j.ijdr.2017.12.009>
- Dano UL, Balogun AL, Matori AN, Wan Yusouf K, Abubakar IR, Said Mohamed MA, Aina YA, Pradhan B. 2019. Flood susceptibility mapping using GIS-based analytic network process: A case study of Perlis, Malaysia. *Water*. 11(3): 615. <https://doi.org/10.3390/w11030615>
- Dodangeh E, Choubin B, Eigdir AN, Nabipour N, Panahi M, Shamsheirband S, Mosavi A. 2020a. Integrated machine learning methods with resampling algorithms for flood susceptibility prediction. *Science of the Total Environment*. 705: 135983. <https://doi.org/10.1016/j.scitotenv.2019.135983>
- Dodangeh E, Panahi M, Rezaie F, Lee S, Bui DT, Lee CW, Pradhan B. 2020b. Novel hybrid intelligence models for flood-susceptibility prediction: Meta optimization of the GMDH and SVR models with the genetic algorithm and harmony search. *Journal of Hydrology*. 590: 125423. <https://doi.org/10.1016/j.jhydrol.2020.125423>
- Drummond C, Holte RC. 2006. Cost curves: An improved method for visualizing classifier performance. *Machine Learning*. 65: 95–130. <https://doi.org/10.1007/s10994-006-8199-5>
- Eslaminezhad SA, Eftekhari M, Akbari M. 2020. GIS-based flood risk zoning based on data-driven models. *Journal of Hydraulic Structures*. 6(4): 75–98. <https://doi.org/10.22055/jhs.2021.36629.1163>
- Gebrehiwot A, Hashemi-Beni L, Thompson G, Kordjamshidi P, Langan T. 2019. Deep convolutional neural nNetwork for flood extent mapping using unmanned aerial vehicles data. *Sensors*. 19(7): 1486. <https://doi.org/10.3390/s19071486>

- Islam ARMT, Talukdar S, Mahato S, Kundu S, Eibek KU, Pham QB, Linh NTT. 2021. Flood susceptibility modelling using advanced ensemble machine learning models. *Geoscience Frontiers*. 12(3): 101075. <https://doi.org/10.1016/j.gsf.2020.09.006>
- Kaur S, Kaur A, Kumar M. 2026. Recent Advances in Computational Methods in Science and Technology: Volume 1 (1st ed.). CRC Chemical Rubber Company Press. <https://doi.org/10.1201/9781003662839>
- Khosravi K, Shahabi H, Pham BT, Adamowski J, Shirzadi A, Pradhan B, Dou J, Ly HB, Gróf G, Ho HL. 2019. A comparative assessment of flood susceptibility modeling using Multi-Criteria Decision-Making Analysis and Machine Learning Methods. *J. Hydrol Journal of Hydrology*. 573: 311–323. <https://doi.org/10.1016/j.jhydrol.2019.03.073>
- Kia MB, Pirasteh S, Pradhan B, Mahmud A R, Sulaiman WNA, Moradi A. 2012. An artificial neural network model for flood simulation using GIS: Johor River Basin, Malaysia. *Environ. Earth Science*. 67: 251–264. <https://doi.org/10.1007/s12665-011-1504-z>
- Kratzert F, Hermegger M, Klotz D, Hochreiter S, Klambauer G. 2019. Neural hydrology—interpreting LSTMs in hydrology. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 11700 Lecture Notes in Computer Science. pp. 347–362. <https://doi.org/10.1007/978-3-030-28954-6>
- LeCun Y, Bengio Y, Hinton G. 2015. Deep learning. *Nature*. 521(7553): 436–444. <https://doi.org/10.1038/nature14539>
- Li J, Fan C, Zhao K, Zhang Z, Duan P. 2025. Landslide displacement prediction using time series InSAR with combined LSTM and TCN. Application to the Xiao Andong landslide, Yunnan Province, China. *Natural Hazards*. 121(4): 3857–3884. <https://doi.org/10.1007/s11069-024-06937-y>
- Maier HR, Jain A, Dandy GC, Sudheer KP. 2010. Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions. *Environmental Modelling and Software*. 25: 891–909. <https://doi.org/10.1016/j.envsoft.2010.02.003>
- Malekian A, Khozani AO, Ashoornejad Gh. 2012. Zoning of flooding potential of Akhtarabad watershed using fuzzy hierarchical analysis method. *Natural Geography Research*. 4(44):162–191. (In Persian). <https://doi.org/10.22059/jphgr.2012.30246>
- Mosavi A, Ozturk P, Chau KW. 2018. Flood prediction using machine learning models: Literature Review. *Water*. 10(11): 1536. <https://doi.org/10.3390/w10111536>
- Nachappa TG, Piralilou ST, Gholamnia K, Ghorbanzadeh O, Rahmati O, Blaschke T. 2020. Flood Susceptibility Mapping with Machine Learning, Multi-Criteria Decision Analysis and Ensemble Using Dempster Shafer Theory. *Journal of Hydrology*. 590: 125275. <https://doi.org/10.1016/j.jhydrol.2020.125275>
- Nhu VH, Mohammadi A, Shahabi H, Ahmad BB, Al-Ansari N, Shirzadi A, Clague JJ, Jafari A, Chen W, Nguyen H. 2020. Landslide susceptibility mapping using machine learning algorithms and remote sensing data in a tropical environment. *International Journal of Environmental Research and Public Health* 17(14): 4933. <https://doi.org/10.3390/ijerph17144933>
- Pham BT, Avand M, Janizadeh S, Phong T V, Al-Ansari N, Ho LS, Das S, Le HV, Amini A, Bozchaloei SK, Jafari F, Prakash, I. 2020. GIS based hybrid computational approaches for flash flood susceptibility assessment. *Water*. 12(3):683. <https://doi.org/10.3390/w12030683>
- Pourghasemi HR, Moradi HR, Aghda SMF, Gokceoglu C, Pradhan B. 2014. GIS-based landslide susceptibility mapping with probabilistic likelihood ratio and spatial multi-criteria evaluation models (North of Tehran, Iran). *Arabian Journal of Geosciences*. 7: 1857–1878. <https://doi.org/10.1007/s12517-012-0825-x>
- Pourtaghi ZS, Pourghasemi HR. 2015. GIS-based groundwater spring potential assessment and mapping in the Birjand Township. Southern Khorasan Province, Iran. *Hydrogeology Journal*. 22: 643–662. <https://doi.org/10.1007/s10040-013-1089-6>
- Pradhan B. 2009. Flood susceptible mapping and risk area delineation using logistic regression, GIS and remote sensing. *Journal of Spatial Hydrology*. 9(2): 1–18. <https://scholarsarchive.byu.edu/josh/vol9/iss2/4>
- Rahmati O, Darabi H, Panahi M, Kalantari Z, Naghibi SA, Ferreira CS, Kornejady A, Karimidastenaie Z, Mohammadi F, Stefanidis S, Tien Bui D. 2020. Development of novel hybridized models for urban flood susceptibility mapping. *Scientific Reports*. Jul 31. 10(1): 12937. <https://doi.org/10.1038/s41598-020-69703-7>
- Rahmati O, Haghizadeh A, Stefanidis S. 2016a. Assessing the accuracy of GIS-based analytical hierarchy process for watershed prioritization. *Gorganrood River Basin, Iran*.

- Water Resources Management. 30(3): 1131–1150. <https://doi.org/10.1007/s11269-015-1215-4>
- Rahmati O, Pourghasemi HR, Zeinivand H. 2016b. Flood susceptibility mapping using frequency ratio and weights-of-evidence models in the Golestan Province, Iran. *Geocarto International*. 31(1): 42–70. <https://doi.org/10.1080/10106049.2015.1041559>
- Rozalis S, Morin E, Yair Y, Price C. 2010. Flash flood prediction using an uncalibrated hydrological model and radar rainfall data in a Mediterranean watershed under changing hydrological conditions. *Journal of Hydrology*. 394: 245–255. <https://doi.org/10.1016/j.jhydrol.2010.03.021>
- Sajedi-Hosseini F, Malekian A, Choubin B, Rahmati O, Cipullo S, Coulon F, Pradhan B. 2018. A novel machine learning-based approach for the risk assessment of nitrate groundwater contamination. *Science of the Total Environment*. 644: 954–962. <https://doi.org/10.1016/j.scitotenv.2018.07.054>
- Saleh A, Tan ML, Nazri FM, Yaseen ZM, Zhang F. 2025. Advancing tropical flood susceptibility mapping with multi-head attention mechanism and deep learning models. *Advances in Space Research*. <https://doi.org/10.1016/j.asr.2025.07.022>
- Shahabi H, Shirzadi A, Ghaderi K, Omidvar E, Al-Ansari N, Clague JJ, Geertsema M, Khosravi K, Amini A, Bahrami S, Rahmati O. 2020. Flood detection and susceptibility mapping using sentinel-1 remote sensing data and a machine learning approach: Hybrid intelligence of bagging ensemble based on k-nearest neighbor classifier. *Remote Sensing*. 12(2): 266. <https://doi.org/10.3390/rs12020266>
- Shirani K, Sadri MA. 2023. Prioritizing effective factors and zoning of flood events using probabilistic models and GIS in the Gorganrood watershed of Golestan province. *Watershed Management Research*. 36(1): 111–131. (In Persian). <https://doi.org/10.22092/wmrj.2022.358648.1473>
- Shirani K, Pasandi M, Arabameri A. 2018. Landslide susceptibility assessment by dempster-shafer and index of entropy models, Sarkhoun basin, southwestern Iran. *Natural Hazards*. 93: 1379–1418. <https://doi.org/10.1007/s11069-018-3356-2>
- Shirani K, Peyrowan HR, Naderi Samani R. 2024. Applied principles of zonation and prediction landslide susceptibility (Machine Learning and Programming in MATLAB). *Soil Conservation and Watershed Management Institute*. 259 p. (In Persian).
- Tehrany MS, Pradhan B, Jebur MN. 2014. Flood susceptibility mapping using a novel ensemble weights-of-evidence and support vector machine models in GIS. *Journal of Hydrology*. 512: 332–343. <https://doi.org/10.1016/j.jhydrol.03.008>
- Vafakhah M, Looor SMH, Pourghasemi HR, Katebikord A. 2020. Comparing performance of random forest and adaptive neuro-fuzzy inference system data mining models for flood susceptibility mapping. *Arabian Journal of Geosciences*. 13: 417. <https://doi.org/10.1007/s12517-020-05363-1>
- Wang Y, Fang Z, Wang M. 2020. Comparative study of landslide susceptibility mapping with different recurrent neural networks. *Computers and Geosciences*. 138: 104445. <https://doi.org/10.1016/j.cageo.2020.104445>
- Zhang D, Yang J, Li F, Han S, Qin L. 2022. Landslide risk prediction model using an attention-based temporal convolutional network connected to a recurrent neural network. *IEEE Access*. 10: 37635–37645. <https://doi.org/10.1109/ACCESS.2022.3165051>
- Zhang YG, Tang J, He ZY. 2021. A novel displacement prediction method using gated recurrent unit model with time series analysis in the Erdaohe landslide. *Nat Hazards*. 105: 783–813. <https://doi.org/10.1007/s11069-020-04337-6>
- Zhao ZA, He Y, Yao S, Yang W, Wang W, Zhang L, Sun Q. 2022. A comparative study of different neural network models for landslide susceptibility mapping. *Advances in Space Research*. 70(2): 383–401. <https://doi.org/10.1016/j.asr.2022.04.055>



Flood Hazard Zonation and Prediction using Deep Learning Models in the Qarasu Watershed, Golestan Province

Kourosh Shirani^{1*}, Mohammad Ali Sadri²

1- Associate Professor, Soil Conservation and Watershed Management Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran

2- M.Sc., Islamic Azad University, Lenjan, Isfahan, Iran

Extended Abstract

Introduction and Goal

Flooding is one of the most destructive natural disasters with social, economic and environmental consequences. Therefore, machine learning methods have been developed to model and predict it. The purpose of this research was to zone and predict flood hazard using three deep learning models, including Gated Recurrent Unit (GRU), Long Short-Term Memory (LSTM) and Temporal Convolutional Network (TCN) models, and to introduce the most suitable ones in the Qarasu watershed of Golestan Province. The most important innovation of this research was comparing its results with the results of other research related to susceptibility zonation within the country, using new deep learning models, and considering the most flood factors to determine the most efficient model and increase the accuracy of flood prediction maps.

Materials and Methods

The research area of the Qarasu watershed in Gorganwas was selected. Then maps of the effective factors were collected and prepared. In this study, 16 factors were selected as independent variables and information received from the Ministry of Energy and field visits were selected as dependent variable. Then, a flood event distribution map was prepared. To model and predict flood susceptibility, the flood event distribution map was divided into two groups of experimental points (30%) and training points (70%). After running the TCN, LSTM and GRU models, the maps obtained from flood hazard zonation maps were classified into five classes: very low, low, moderate, high and very high. Finally, the classification accuracy and validation of the zonation and prediction maps were evaluated the flood susceptibility was predicted, and the most appropriate model was selected.

Results and Discussion

To prepare a flood event zonation map, spatial data of 59 flood occurrence points (dependent variable) were collected using available information and by analyzing radar images acquired before and after flood events in Google Earth. Each of these locations experienced 10 recorded and documented flood events during the 20- year study period (2004–2024).

Article Type: Research Article

***Corresponding Authors' E-mail:** Kouroshshirani@gmail.com

Citation: Shirani, K., Sadri, M.A. 2026. Flood Hazard Zonation and Prediction Using Deep Learning Models in the Qarasu Watershed, Golestan Province. Watershed Management Research. 39(3): 22-44.

DOI: 10.22092/WMRJ.2026.371561.1648

Received: 09 December 2025, **Received in revised form:** 18 February 2026, **Accepted:** 21 June 2026,

Published online: 23 September 2026

Watershed Management Research, Vol. 39, No. 3, Ser. No, 152, Autumn 2026, pp. 22-44.

Publisher: Fars Agricultural and Natural Resources and Education Center

©Author(s)



Of the total dataset, 70% were randomly selected and divided as training data and 30% as test data for model implementation and validation, respectively. In the next step, 16 factors in the form of environmental groups, hydrology, watershed topography along with climatic data (as independent variables) for zonation and modeling. The classification accuracy of the models was evaluated using two indices, frequency ratio (FR) and kernel cell area (SCAI). The results showed that most flood areas were in the high-hazard class (high and very high) and the largest share of the area of the region was also related to these areas. In addition, based on the area under the relative operator curves and cost, it was determined that the most efficient, appropriate, and cost-effective model was the TCN model compared to the LSTM and GRU models. Among the models studied, the highest and lowest areas under the relative operator and cost curves of the TCN model were 0.92 and 0.08, respectively. The results of this study showed that, based on the TCN model, 45% of the area of the region was in the very high susceptibility class, containing 83% of flood events. Also, based on the LSTM model, 23% of the region contained 60% of the flood events, and based on the GRU model, 10% of the region contained 4% of the flood events. The flood hazard zonation maps obtained in this study can be the basis for planning and crisis management caused by flood events, reducing flood hazard, and managing it. Furthermore, based on the excellent performance of all three TCN, LSTM, and GRU models, the results of this research are necessary and essential for the development of future projects of various organizations operating in many developing countries.

Conclusion and Suggestions

After running all three TCN, LSTM, and GRU models, the AUC-ROC index results in both training and testing step showed excellent performance of the mentioned models. The maps prepared from flood hazard zonation using all three models indicated high accuracy in zone classification and appropriate distribution of flood points in high and very high class. The fit of the TCN model in predicting flood occurrence in the test phase was better compared to the other two models. The evaluation of classification accuracy and validation of the models showed that two TCN and LSTM models, having the appropriate thresholds for classification, are the priority of their application for zonation and predicting the hazard of flooding. Finally, in this study, the area under the value or cost curve index values for TCN, LSTM, and GRU models were obtained as 0.08, 0.10, and 0.11, respectively. Based on the importance of morphometric features in the zoning of flood hazard maps, it is suggested that future research should use these metrics along with other common metrics in the preparation of zoning maps. Furthermore, based on the findings of this study, the application of deep learning methods and their combinations is recommended. It is also suggested that novel hybrid approaches and suitable optimization algorithms be investigated and evaluated in other watersheds of Golestan Province.

Keywords: Deep learning models, floods, hazard, prediction, Qarasu, zonation

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

All information and results are presented in the text of the article.

Authors' Contribution

Author 1: Conceptualization, Programming and development of deep learning models, Statistical analyses and validation, writing, and manuscript editing

Author 2: Preparing maps and figures, drafting the original manuscript, and review of the results