

Predicting the effect of biological measures on flood generation in the Behesht Abad watershed using machine learning methods

Fariba Darabi¹, Ali Najafinejad^{1*}, Hamidreza Pourghasemi², Amir Sadoddin¹

1. Department of Watershed Management, Faculty of Rangeland and Watershed Management, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

2. Department of Natural Resources and Environmental Engineering, Shiraz University, Shiraz, Iran

* Corresponding author: najafinejad@gau.ac.ir

(Received: 21 Jun 2024

Revised: 27 August 2024

Accepted: 10 September 2024)

Extended Abstract

Introduction: Flood events are among the most significant natural disasters, causing substantial damage each year in Iran. One effective approach in watersheds for mitigating the consequences of flooding is the implementation of watershed management operations. Moreover, evaluating the effects of each operation is crucial. In natural disaster management, particularly in the case of floods, timing is the most critical factor. This underscores the need for a rapid response model to facilitate precautionary actions and early warnings. Numerous studies have been conducted to measure and classify the effects of floods from various perspectives. Generally, the damages are evaluated both directly and indirectly in flood impact assessments. Advances in various fields of artificial intelligence, especially in water resources, have made these technologies viable options for modeling hydrological and hydraulic processes. Consequently, the present research employs machine learning methods to predict the impact of water management measures on floods in the Behesht Abad watershed.

Materials and methods: The main focus of this research is to simulate the effects of watershed operations using machine learning methods in the Behesht Abad watershed. Discharge and rainfall data from 1999 to 2020 were used. Effective factors in flood occurrence, including canopy cover, soil, and topography, were analyzed in ArcGIS using satellite imagery, GEE, and field surveys. Furthermore, the effects of watershed management actions, particularly biological operations, were simulated using Support Vector Machine (SVM) and Random Forest (RF) models. In summary, discharge flow predictions were made based on a dataset comprising 7,850 records, with 70% (5,495 records) used for model training and 30% (2,355 records) for testing. Biological measures such as mounding, sowing, seeding, and seedling were simulated to assess their impact on flow rates. By implementing these predicted biological plans in the studied watershed, changes in vegetation and land use parameters were modeled. The predicted layers were then used to update numerical values related to vegetation cover, including the NDVI index and land use, which were recalculated and integrated into the modeling process.

Results and Discussion: In this watershed, the SVM simulation indicated that the highest discharge flow occurred in 2003, reaching approximately 500 m³/s. According to the RF simulation, this value increased to 520 m³/s in 2016. The results demonstrate that biological operations reduce discharge flow and have the least impact on peak discharge flow. A comparison between SVM and RF revealed that SVM performed better in discharge flow prediction. Based on the results, the R² values for the training and testing phases were 0.96 and 0.89, respectively, while the NTS values for the training and testing phases were 0.95 and 0.86, respectively.

Conclusion: The role of biological watershed management measures in reducing surface runoff and their effect on flood variables, particularly through their influence on the watershed's concentration time and curve number, is undeniable. It is also essential to examine the impact of these measures on the watershed's hydrological processes. The results indicate that applying machine learning models is a cost- and time-effective approach for discharge flow estimation, flood management, and flood control in planning and projects. By leveraging these methods, communities and governments can enhance flood preparedness, improve management strategies, and ultimately reduce the impact of flooding events on human lives and infrastructure.

Keywords: Artificial intelligence, Behesht Abad basin, Flood management, Random forest (RF), Support vector machine model (SVM).

Citation: Darabi, F., Najafinejad, A., Pourghasemi, H., & Sadoddin, A. (2025). Predicting the effect of biological measures on flood generation in the Behesht Abad watershed using machine learning methods. *Integrated Watershed Management*, 5(1), 79-96. doi: 10.22034/iwm.2024.2032264.1159

Copyrights:

Copyright for this article is retained by the author(s), with publication rights granted to Integrated Watershed Management. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>).



پیش‌بینی اثر اقدامات بیولوژیک بر سیل‌خیزی حوزه آبخیز بهشت‌آباد با استفاده از روش‌های یادگیری ماشین

فریبا دارابی^۱، علی نجفی‌نژاد^{۱*}، حمیدرضا پورقاسمی^۲، امیر سعدالدین^۱

۱. گروه علوم و مهندسی آبخیز، دانشکده منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران.

۲. گروه منابع طبیعی و مهندسی محیط زیست، دانشگاه شیراز، شیراز، ایران

*نویسنده مسئول: najafinejad@gau.ac.ir

تاریخ پذیرش: ۱۴۰۳/۰۶/۲۰

تاریخ بازنگری: ۱۴۰۳/۰۶/۰۶

تاریخ دریافت: ۱۴۰۳/۰۴/۰۱

چکیده مبسوط

مقدمه: سیل یکی از انواع بلایای طبیعی است که هر ساله موجب ایجاد خسارات زیادی در ایران می‌شود. اجرای اقدامات آبخیزداری در سطح حوزه‌های آبخیز، یکی از راهکارهای موثر در مدیریت سیل و جلوگیری از خسارات ناشی از آن است. از طرفی بررسی میزان تأثیر این اقدامات بر فرآیندهای هیدرولوژیک حوزه آبخیز اجتناب‌ناپذیر است. در مدیریت مخاطرات طبیعی به‌ویژه در مدیریت سیل، زمان یکی از مهم‌ترین عوامل است، به عبارتی مدل به‌کار گرفته شده باید توانایی مدل‌سازی یا شبیه‌سازی در کوتاه‌ترین زمان ممکن را دارا باشد تا به اقدامات پیشگیرانه و هشدار اولیه کمک نماید. مطالعات زیادی به منظور اندازه‌گیری و طبقه‌بندی اثرات سیل از دیدگاه‌های مختلف انجام شده است. در همین راستا پیشرفت در زمینه‌های مختلف هوش مصنوعی مخصوصاً در زمینه مطالعات مربوط به منابع آب موجب شده که به‌عنوان گزینه مناسب برای مدل‌سازی فرآیندهای هیدرولوژیکی و هیدرولیکی مورد توجه قرار گیرند. بر همین اساس پژوهش حاضر با هدف پیش‌بینی اثر اقدامات آبخیزداری بر سیل‌خیزی حوزه آبخیز بهشت‌آباد با استفاده از روش یادگیری ماشین برنامه‌ریزی شد.

مواد و روش‌ها: داده‌های مورد استفاده شامل دبی و بارش در دوره‌های ۱۳۷۸-۱۳۹۹ بود. عوامل مؤثر بر سیل از جمله پوشش گیاهی، خاک و توپوگرافی نیز با استفاده از تصاویر ماهواره‌ای، سامانه گوگل ارث انجین و مطالعات میدانی در محیط نرم‌افزار ArcGIS تهیه شد. همچنین تأثیر اقدامات آبخیزداری شامل عملیات بیولوژیک با مدل‌های ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) شبیه‌سازی شد. به‌طور کلی پیش‌بینی دبی جریان بر اساس مجموعه داده‌های موجود (۷۸۵۰ سری) در دو دسته داده‌های آموزش مدل (Train) شامل ۷۰ درصد داده‌ها (۵۴۹۵ سری) مربوط به دوره ۱۳۷۸ تا ۱۳۹۳ و داده‌های آزمون مدل (Test) شامل ۳۰ درصد داده‌ها (۲۳۵۵ سری) در دوره ۱۳۹۳ تا ۱۳۹۹ انجام شد. براساس مطالعات تفصیلی-اجرایی صورت گرفته، اقدامات بیولوژیک شامل کپه‌کاری، بذرپاشی و نهال‌کاری شبیه‌سازی شد و اثر اقدامات بیولوژیک بر دبی جریان، در نظر گرفته شد. بنابراین با انجام طرح‌های بیولوژیک پیش‌بینی شده در سطح حوزه آبخیز مورد مطالعه، پارامترهای پوشش گیاهی و کاربری اراضی، تغییر نموده و از لایه‌های پیش‌بینی شده استفاده شد، لذا مقادیر عددی مربوط به پوشش گیاهی حوضه از جمله شاخص NDVI و کاربری اراضی در پیکسل‌هایی که عملیات پیشنهاد شده بود، تغییر داده شد که مقادیر آن‌ها مجدداً محاسبه و وارد فرآیند مدل‌سازی گردید.

نتایج و بحث: بیش‌ترین میزان دبی شبیه‌سازی شده در حوضه با مدل‌های ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) به ترتیب حدود ۵۰۰ و ۵۲۰ مترمکعب بر ثانیه بوده که در سال‌های ۱۳۸۳ و ۱۳۹۵ رخ داده است. نتایج نشان داد اقدامات بیولوژیک حجم دبی جریان را کاهش داده و اثر کمتری بر مقدار دبی اوج داشته است. مقایسه نتایج دو مدل SVM و RF نشان داد که مدل SVM عملکرد بهتری نسبت به مدل RF در پیش‌بینی دبی جریان رودخانه داشته است به نحوی که طبق نتایج به‌دست آمده از مدل SVM، مقدار ضریب تبیین در مرحله آموزش و آزمون به ترتیب برابر ۰/۸۹ و ۰/۸۹ بوده است. همچنین مقدار شاخص نش-ساتکلیف برای مرحله آموزش برابر ۰/۹۵ و برای مرحله آزمون برابر ۰/۸۶ می‌باشد.

نتیجه‌گیری: نقش اقدامات آبخیزداری به‌صورت بیولوژیک در حوزه‌های آبخیز در کاهش میزان رواناب سطحی و اثرگذاری آن بر متغیرهای سیل، از طریق تأثیر آن‌ها بر زمان تمرکز و شماره منحنی حوزه آبخیز امری غیرقابل انکار است. از طرفی بررسی میزان تأثیر این اقدامات بر فرآیندهای هیدرولوژیک حوزه آبخیز اجتناب‌ناپذیر است. براساس نتایج، استفاده از مدل‌های یادگیری ماشین گزینه مناسبی برای صرفه‌جویی در وقت و هزینه طرح‌ها و پروژه‌های پیش‌بینی جریان روخانه و جریان سیلی و کنترل و مدیریت سیل در حوزه‌های آبخیز می‌باشند. می‌توان اظهار نمود پیش‌بینی سیل با استفاده از روش‌های مبتنی بر هوش مصنوعی می‌تواند در زمان و هزینه به‌صرفه باشد و با آموزش صحیح مدل و استفاده از داده‌های جامع پیش‌بینی دقیق‌تری ارائه داشت.

واژه‌های کلیدی: مدل جنگل تصادفی (RF)، حوضه بهشت‌آباد، مدل ماشین بردار پشتیبان (SVM)، مدیریت سیل، هوش مصنوعی

استناد: دارابی، ف.، نجفی‌نژاد، ع.، پورقاسمی، ح.؛ و سعدالدین، الف. (۱۴۰۴). پیش‌بینی اثر اقدامات بیولوژیک بر سیل‌خیزی حوزه آبخیز بهشت‌آباد با استفاده از روش‌های یادگیری ماشین. مدیریت جامع حوزه‌های آبخیز، ۵(۱): ۷۹-۹۶.

حق چاپ:



حق چاپ برای نویسنده (گان) این مقاله محفوظ است. بر اساس قوانین انتشارات با دسترسی آزاد، تمام مطالعات چاپ شده در این نشریه به‌صورت آزاد در وبسایت نشریه برای عموم بدون پرداخت هزینه قابل‌دسترس است.

مقدمه

سیل یکی از خطرناک‌ترین بلایای طبیعی است که باعث تخریب اموال و به‌خطر افتادن جان انسان‌ها می‌شود (Gharakhanlou & Perez, 2023) و سالانه حدود ۶۰ میلیارد دلار خسارات اقتصادی در اقصی نقاط دنیا به‌بار می‌آورد (Convertino *et al.*, 2019). از سال ۲۰۱۱، زیان اقتصادی ناشی از حوادث سیل، ۱۸۵ میلیارد دلار تخمین زده شد. همچنین نزدیک به ۳۱ درصد از خسارات اقتصادی ناشی از حوادث طبیعی، مربوط به فاجعه سیل است (Sönmez & Bizimana, 2020). روند افزایش وقوع سیل در پنج دهه گذشته نشان می‌دهد که تعداد وقوع آن در دهه ۸۰ نسبت به دهه ۴۰ کمابیش ده برابر شده است (Abdi, 2016). به همین دلیل سیل با تأثیر بر زندگی بشر و ایجاد آسیب‌های شدید اقتصادی در سراسر جهان به‌عنوان شاخص‌ترین بلای طبیعی مشهور است. بر این اساس، پیش‌بینی سیل و کنترل آن از مهم‌ترین اقداماتی است که در دهه اخیر مدنظر محققان بوده است. به‌طوری‌که این اقدام در طراحی سازه‌های آبی از قبیل سرریزها، مجاری فاضلاب‌های شهری، طرح‌های کنترل و سازه‌های آبخیزداری در حوضه‌ها اهمیت زیادی دارد (Silveira *et al.*, 2000). فرآیند وقوع سیل بسیار پیچیده بوده و عوامل مختلفی در رخداد آن نقش دارند؛ از این‌رو، پیش‌بینی وقوع آن نیز مشکل است. به‌منظور پیش‌بینی پارامترهای مختلف هیدرولوژیکی مانند سیل، استفاده از روش‌های یادگیری ماشین مثل ماشین بردار پشتیبان (SVM)، مدل درخت تصمیم-گیری (M5)، شبکه عصبی مصنوعی (ANN)، برنامه‌ریزی ژنتیک و منطق فازی به‌طور فزاینده‌ای مورد توجه قرار گرفته است (Sattari *et al.*, 2016). از طرفی با توجه به غیرخطی بودن فرآیند بارش-رواناب و همچنین وابستگی این فرآیند به ویژگی‌های فیزیوگرافیک و هیدرولوژیک حوزه آبخیز، استفاده از

مدل‌هایی که قابلیت برقراری نداشت غیرخطی بین بارش و رواناب داشته باشند، باید مدنظر قرار گیرد؛ بنابراین استفاده از روش‌های مبتنی بر هوش مصنوعی راهکار مفید و مؤثری به‌شمار می‌رود (Hasani *et al.*, 2021). بر همین اساس مطالعات مختلفی در سراسر جهان صورت گرفته است.

Puttinaovarat و Horkaew (۲۰۲۰) به بررسی پیش‌بینی سیل با استفاده از مجموعه داده‌های ثبت شده بر اساس الگوریتم‌های یادگیری ماشین شامل جنگل تصادفی (RF)، پرسپترون چندلایه (MLP)، شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و هسته تابع پایه شعاعی (RBF) پرداختند. نتایج ارزیابی در مناطق مورد مطالعه نشان داد بهترین عملکرد به‌ترتیب الگوریتم‌های ANN، MLP، SVM و RF بودند. Zehra (۲۰۲۰) به ارزیابی الگوریتم‌های یادگیری ماشین در پیش‌بینی سیل پرداخت. نتایج این مطالعه نشان داد که روش الگوی خود برآزش برونزای غیرخطی (NARX)^۱ می‌تواند نتایج دقیق و بهتری برای پیش‌بینی سیل ارائه دهد. Bagherian Kalat و همکاران (۲۰۲۱) به بررسی تأثیر اقدامات آبخیزداری بر فرسایش و رسوب حوزه آبخیز کاخک در استان خراسان رضوی پرداختند که نتایج نشان داد مقدار رسوب به میزان ۵۰ درصد در اثر اقدامات آبخیزداری کاهش پیدا کرد. Lawal و همکاران (۲۰۲۱) به پیش‌بینی سیل با استفاده از مدل‌های یادگیری ماشین در ایالت Kebbi کشور نیجریه پرداختند. ایشان از سه الگوریتم درخت تصمیم، رگرسیون لجستیک و رگرسیون با ماشین بردار (SVR) استفاده کردند. نتایج نشان داد که رگرسیون لجستیک، در مقایسه با دو الگوریتم دیگر، نتایج دقیق‌تری دارد و دقت عملکرد بالایی را ارائه می‌دهد. de Oliveira Serrão و همکاران (۲۰۲۲) نیز با شبیه‌سازی تأثیر پوشش گیاهی و تغییر کاربری اراضی بر میزان رسوب حوزه آبخیز آمازون در


پژوهشی به اثربخشی اقدامات آبخیزداری در کاهش فرسایش خاک و تولید رسوب پرداختند که نتایج ایشان نشان داد بر اثر اجرای اقدامات آبخیزداری، میزان رسوب آبخیز به میزان ۲۱ درصد کاهش یافت. Mostafaei و همکاران (۲۰۲۳) اقدام به ارزیابی عملکرد مدل‌های یادگیری عمیق، شبکه عصبی چندجمله‌ای و مدل HEC-HMS در پیش‌بینی جریان رودخانه در حوزه‌های آبخیز بار اربه، کسلیان و لتیان کردند. نتایج نشان دهنده عملکرد متوسط مدل MLP با متوسط NRMSE معادل ۵۱/۱۷ درصد، عملکرد مناسب مدل GMDH با متوسط NRMSE معادل ۴۴/۶ درصد و عملکرد بسیار خوب مدل LSTM با متوسط NRMSE معادل ۲۶/۸ درصد می‌باشد.

طبق بررسی‌های صورت گرفته در مناطق مختلف جهان با استفاده از روش‌ها و مدل‌های مختلف به ارزیابی اثر اقدامات آبخیزداری و همچنین توانایی مدل‌های مختلف در ارزیابی اثر این اقدامات پرداخته شده است و نتایج نشان داد شناسایی مناطق سیل‌خیز به برنامه‌ریزی و مدیریت مناسب کمک کرده و در نتیجه می‌تواند به کاهش خطرات و تلفات کمک نماید (Dawson et al., 2006).

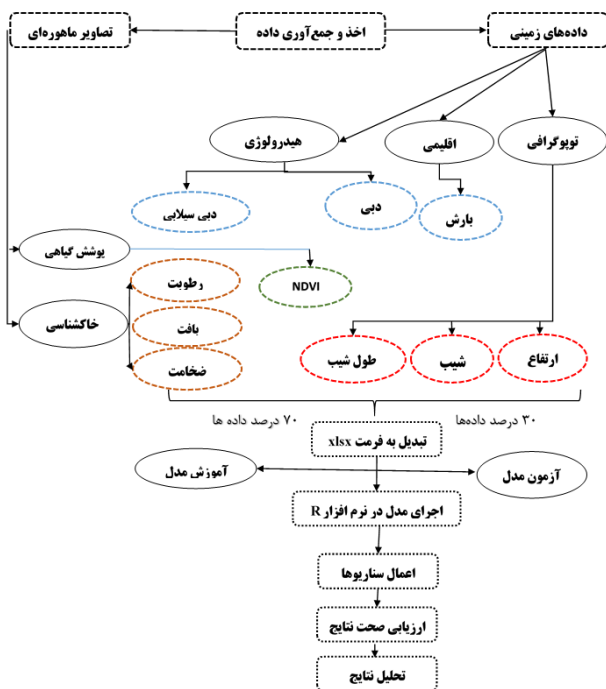
همچنین پیش‌بینی احتمال وقوع سیل به مدیران در جهت کاهش خسارات سیل کمک کرده و فرصتی فراهم می‌نماید تا توزیع آب را مدیریت و آسیب‌های احتمالی ناشی از آن را کاهش دهند (Saedi et al., 2020). بر این اساس تعیین و تبیین استراتژی‌های مدیریت سیل یک امر اجتناب‌ناپذیر به نظر می‌رسد و مهار نسبی خطرات سیل، یکی از چالش‌های عمده مدیریت کشور است (Panahi et al., 2023).

طبق نتایج حاصل از بررسی پژوهش‌های صورت گرفته، مدل ماشین بردار پشتیبان یکی از مدل‌هایی نظارت شده یادگیری است که جهت طبقه‌بندی تفکیک گروه‌ها به کار می‌رود و به لحاظ به کارگیری الگوریتم‌های تخمین توزیع، تکرار بالای فرایند مدل‌سازی و طبیعت داده‌محور، توانایی بالایی در

برزیل بیان داشتند که رابطه معکوسی بین افزایش پوشش گیاهی با رسوب حوزه آبخیز وجود دارد. Jiang و همکاران (۲۰۲۲) به منظور پیش‌بینی سیل حوزه آبخیز Yangtze از داده‌های اقلیمی مبتنی بر روش‌های یادگیری ماشین استفاده کردند. نتایج نشان داد که مدل جنگل تصادفی و ادراک چندگانه عملکرد خوبی در پیش‌بینی سیل دارند. Saedi و همکاران (۲۰۲۰) اقدام به ارزیابی عملکرد هفت مدل عددی پیش‌بینی گروهی بارش به پیش‌بینی سیل سال ۱۳۹۸ در زیرحوضه سالیان از حوزه آبریز گرگان‌رود، پرداختند. نتایج نشان داد مدل‌های NCEP و CMA نسبت به سایر مدل‌ها، دقت کمتری در پیش‌بینی سیل داشتند. Eslahi و همکاران (۲۰۲۲) با استفاده از تخمین حداکثر بارش محتمل (PMP) سیل را در حوزه آبخیز دریاچه ارومیه پیش‌بینی کردند. خروجی نقشه‌های پهنه‌بندی روش‌های آماری همدیدی بیانگر این بود که جنوب و جنوب‌غرب حوضه دارای بیش‌ترین و شرق حوضه دریاچه دارای کم‌ترین مقدار حداکثر بارش محتمل است. Ahmadi و Rahimi (۲۰۲۲) به منظور پیش‌بینی سیل در منطقه کن-سولقان در استان تهران از مدل مبتنی بر یادگیری عمیق و آزمون من-کندال استفاده کردند. نتایج نشان داد میزان اختلاف پیش‌بینی سیل منطقه به تفکیک ماهیانه برای شبکه عصبی کانولوشن (CNN) برابر با ۰/۰۶۵۴ و برای روش من-کندال ۰/۱۹۵۳۲ به دست آمد که بیانگر دقت بالای روش CNN در تخمین میزان سیل در منطقه مورد مطالعه می‌باشد. Fallah و همکاران (۲۰۲۲) از الگوریتم‌های یادگیری ماشین از جمله رگرسیون بردار پشتیبان (SVR)، شبکه عصبی مصنوعی با پس انتشار خطا (ANN-BP) و رگرسیون تقویت گرادیان (GBR) و داده‌های هواشناسی و پوشش برف سنجنده MODIS جریان سطحی روزانه را در دو حوضه مختلف لتیان و ناورود پیش‌بینی کردند. نتایج نشان داد مدل GBR دارای بالاترین و مدل SVR کم‌ترین کارایی را داشتند. Koohdarzi Moghaddam و همکاران (۲۰۲۲) در



شکل ۱- موقعیت جغرافیایی محدوده مورد مطالعه
Figure 1- Geographical location of the study area



شکل ۲- نمودار جریان پژوهش حاضر

Figure 2- The flowchart of the current research

داده‌های پژوهش

هواشناسی و هیدرولوژی

در پژوهش حاضر داده‌های ایستگاه باران‌سنجی، سینوپتیک و هیدرومتری موجود در حوضه از شرکت آب منطقه‌ای، اداره کل هواشناسی استان چهارمحال و بختیاری، سازمان هواشناسی کل کشور و شرکت مدیریت منابع آب با مقیاس روزانه اخذ شد. داده‌های جمع‌آوری شده ابتدا مورد بازبینی قرار گرفت و تجزیه

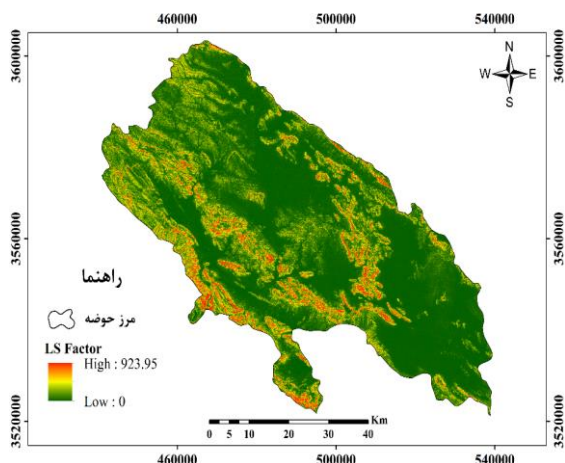
شناسایی رفتار وقوع خطر سیل داشته و در پژوهش‌های متعددی برتری نسبی خود را نسبت به مدل‌های آماری دومتغیره و چندمتغیره اثبات نموده است.

بررسی مطالعات نشان داد تاکنون در حوزه آبخیز مورد مطالعه هیچگونه مطالعه‌ای در راستای پژوهش حاضر صورت نگرفته است و با توجه به موقعیت قرارگیری و شرایط خاص توپوگرافی منطقه، انجام مطالعات در خصوص سیل و شناسایی مدل‌هایی که در محدوده از توانایی بالایی در شبیه‌سازی برخوردار باشند، اجتناب‌ناپذیر است. پیشرفت در زمینه‌های مختلف هوش مصنوعی مخصوصاً در زمینه مطالعات مربوط به منابع آب موجب شده که به‌عنوان گزینه مناسب برای مدل‌سازی فرآیندهای هیدرولوژیکی و هیدرولیکی مورد توجه قرار گیرند که بر همین اساس پژوهش حاضر نیز با هدف پیش‌بینی اثر اقدامات آبخیزداری بر سیل‌خیزی حوزه آبخیز بهشت‌آباد با استفاده از روش یادگیری ماشین برنامه‌ریزی شد.

مواد و روش‌ها

منطقه مورد مطالعه

حوزه آبخیز بهشت‌آباد در منتهی‌الیه شمال شرق استان چهارمحال و بختیاری یکی از زیرحوضه‌های هشت‌گانه حوزه آبخیز بزرگ کارون شمالی می‌باشد که بین طول‌های $51^{\circ} 24' 42''$ تا $50^{\circ} 22' 21''$ شرقی و عرض‌های $31^{\circ} 49' 50''$ تا $32^{\circ} 34' 05''$ شمالی قرار دارد. این حوزه آبخیز دارای مساحت ۳۸۶۶ کیلومترمربع، محیط ۳۸۹ کیلومتر، طول آبراهه ۱۲۰ کیلومتر، شیب متوسط ۳/۱۱ درصد و ارتفاع متوسط ۲۳۱۷ متر است. شکل (۱) موقعیت جغرافیایی محدوده مورد مطالعه و ایستگاه‌های هواشناسی و شکل (۲) نمودار جریانی پژوهش حاضر را نشان می‌دهد.



شکل ۳- نقشه‌های مدل رقومی ارتفاع (الف)، شیب (ب)

و طول شیب (ج) منطقه مورد مطالعه

Figure 3- The maps of DEM (a), slope (b) and slope length (c) of the studied area

بر اساس شکل (۳) بیش‌ترین ارتفاع ۳۷۲۳ متر و کم‌ترین مقدار ۱۶۵۱ متر می‌باشد. نقشه شیب نیز بیان‌گر تغییرات شدید میزان شیب در حوضه می‌باشد که از مناطق با شیب صفر شروع شده و در مناطق صخره‌ای به شیب‌های خیلی زیاد می‌رسد. بیش‌ترین مساحت طبقه شیب مربوط به شیب‌های صفر تا ۵ درجه و کم‌ترین آن شیب‌های بالای ۳۵ درجه می‌باشد.

کاربری اراضی و پوشش گیاهی

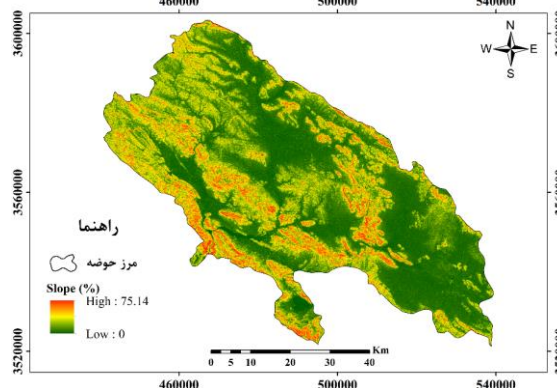
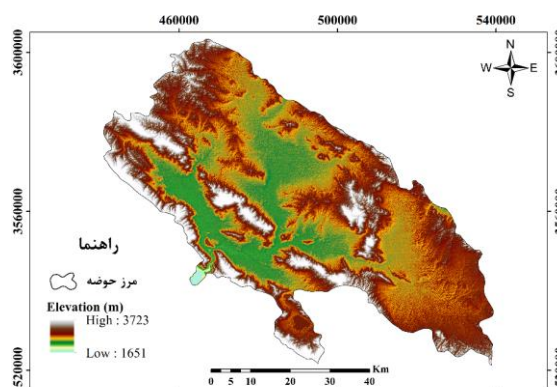
در پژوهش حاضر نقشه کاربری اراضی برای دوره ۱۳۷۹ تا ۱۳۹۹ (سال‌های ۱۹۹۹ تا ۲۰۲۰) برای هر سال بر اساس داده‌های ماهواره سری لندست ۵، ۷ و ۸ با استفاده از روش طبقه‌بندی حداکثر احتمال (MLC^2) در محیط گوگل ارث انجین^۳ (GEE) با قدرت تفکیک مکانی ۳۰ متر به‌دست آمد.

تصاویر ماهواره لندست ۷ دارای خطای راه راه شدگی با استفاده از تابع Focal Mean و به کمک تکنیک Gap fill اصلاح و برطرف گردید. جهت ارزیابی نقشه‌های کاربری تولید شده از ضریب کاپا استفاده شد (جدول ۱).

و تحلیل اولیه شامل رفع نواقص آماری، آزمون نرمال بودن و تست همگنی انجام شد. با انتخاب بازه زمانی مشترک بین ایستگاه‌ها، دوره زمانی ۱۳۷۸ تا ۱۳۹۹ به‌عنوان دوره مورد ارزیابی انتخاب شد. به همین منظور از ۲ ایستگاه کلیماتولوژی، ۳ ایستگاه سینوپتیک، ۵ ایستگاه باران‌سنجی و ۶ ایستگاه هیدرومتری استفاده شد.

توپوگرافی

ویژگی‌های توپوگرافی زمین، عامل مؤثر بر وقوع سیل در حوزه آبخیز می‌باشند. در این مطالعه برای تهیه لایه‌های توپوگرافی شامل طبقات ارتفاعی، درصد شیب، طول شیب (LS) از مدل رقومی ارتفاع (DEM) استفاده شد. نقشه مدل رقومی ارتفاع (DEM) نیز از ماهواره SRTM با توان تفکیک مکانی ۳۰ متری تهیه شد. شکل (۳) نقشه ویژگی‌های توپوگرافی منطقه مورد مطالعه را نشان می‌دهد.



جدول ۱- مقادیر ضریب کاپا حاصل از ارزیابی نقشه‌های کاربری اراضی

Table 1- Kappa coefficient values obtained from the land use maps evaluation

سال	ضریب کاپا
Year	Kappa coefficient
1999	0.81
2004	0.79
2006	0.83
2009	0.84
2013	0.76
2016	0.83
2020	0.88


برای محاسبه شاخص پوشش گیاهی تفاضلی نرمال شده (NDVI) از تصاویر ماهواره سری لندست ۵، ۷ و ۸ بر مبنای رابطه ۱ استفاده شد.

$$NDVI = \frac{Band\ NIR - Band\ Red}{Band\ NIR + Band\ Red} \quad (1)$$

که در آن، NDVI: شاخص تفاضلی نرمال شده پوشش گیاهی است، NIR: میزان انعکاس در باند مادون قرمز نزدیک و Red: میزان انعکاس در باند قرمز است.

خاک‌شناسی

در پژوهش حاضر به منظور تهیه نقشه میزان رطوبت خاک از تصاویر ماهواره ERA5-Land در دوره مورد بررسی در محیط گوگل ارث انجین با دقت ۳۰ متری استفاده شد. همچنین داده‌های مربوط به خصوصیات فیزیکی خاک از اداره منابع طبیعی و آبخیزداری استان دریافت شد و به منظور تهیه نقشه بافت خاک در نقاط مشخص شده پروفیل خاک حفر و تا عمق ۳۰ سانتی‌متر از خاک منطقه نمونه برداری شد و پس از انتقال به آزمایشگاه خاک با استفاده از مثلث بافت خاک نوع بافت مشخص گردید. شکل (۴) نقشه عمق و بافت خاک را در منطقه مورد مطالعه نشان می‌دهد.



شکل ۴- نقشه عمق خاک (الف) و بافت خاک (ب) حوضه مورد مطالعه

Figure 4- Map of soil depth (a) and soil texture (b) of the study area

اجرای سناریوی اقدامات بیولوژیک

بعد از تهیه عوامل موثر در وقوع سیل در بازه زمانی مورد بررسی، لایه‌ها بر اساس تعداد کل پیکسل‌هایی که سطح حوزه آبخیز مورد مطالعه را پوشش می‌دهند، در محیط ArcGIS به فایل نقطه‌ای تبدیل شدند. سپس ارزش عددی در سطح پیکسل‌ها به صورت داده نقطه‌ای به دست آمد. با توجه به همسان‌سازی اندازه پیکسل‌های همه پارامترها، کلیه مقادیر عددی پارامترها دارای سری زمانی یکسان می‌باشند که در نهایت در قالب فایل Excel برای مدل‌سازی آماده‌سازی شد. در مرحله بعد با فراخوانی داده‌ها در محیط برنامه‌نویسی R پایگاه داده برای شبیه‌سازی آماده شد. با توجه به این‌که مقادیر عددی پارامترهای موردنظر در محدوده‌های متفاوت می‌باشد برای یکسان‌سازی اثرات در مدل‌سازی از استانداردسازی داده‌ها بهره گرفته شد. سناریوهای اقدامات آبخیزداری

شبیه‌سازی سیل با مدل جنگل تصادفی

جنگل تصادفی^۶ نوعی الگوریتم یادگیری گروهی^۷ است که چندین درخت تصمیم را برای پیش‌بینی ترکیب می‌کند. هر درخت تصمیم در جنگل تصادفی بر روی یک زیر مجموعه تصادفی از داده‌های آموزشی و یک زیر مجموعه تصادفی از فیچرها آموزش داده می‌شود. سپس خروجی جنگل تصادفی با تجمیع پیش‌بینی‌های همه درخت‌های تصمیم تعیین می‌شود. این رویکرد به جنگل تصادفی اجازه می‌دهد تا بسیار دقیق و مقاوم در برابر مشکل بیش‌برازش، یک مشکل رایج در یادگیری ماشین که در آن مدل در داده‌های آموزشی خوب عمل می‌کند اما در داده‌های جدید ضعیف است، باشد. پیش‌بینی سیل با استفاده از مدل جنگل تصادفی (RF) نیز بر اساس مجموعه داده‌های موجود (۷۸۵۰ سری) در دو دسته داده‌های آموزش مدل (Train) شامل ۷۰ درصد داده‌ها (۵۴۹۵ سری) مربوط به دوره ۱۳۷۸/۰۷/۰۱ تا ۱۳۹۳/۰۷/۱۸ (دوره اول) و داده‌های آزمون مدل (Test) شامل ۳۰ درصد داده‌ها (۲۳۵۵ سری) در دوره ۱۳۹۳/۰۷/۱۹ تا ۱۳۹۹/۱۲/۳۰ (دوره دوم) انجام شد.

ارزیابی مدل‌های یادگیری ماشین

ارزیابی عملکرد مدل برای جریان شبیه‌سازی شده و مشاهده شده با استفاده از مقایسه‌های آماری انجام شد. برای مقایسه آماری بین جریان مشاهده‌شده (OBS) و جریان شبیه‌سازی شده (SIM) در مقیاس زمانی روزانه، از ضریب تبیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، ضریب نش-ساتکلیف (NSE) و میانگین خطای مطلق (MAE) بر اساس رابطه‌های ۲ الی ۵ استفاده شد:

$$R^2 = \left[\frac{\sum_{i=1}^n (SIM_i - \overline{SIM})(OBS_i - \overline{OBS})}{\sqrt{\sum_{i=1}^n (SIM_i - \overline{SIM})^2 \sum_{i=1}^n (OBS_i - \overline{OBS})^2}} \right]^2 \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (OBS_i - SIM_i)^2}{n}} \quad (3)$$

انجام شده به صورت اقدامات بیولوژیک مدنظر قرار گرفت. براساس مطالعات تفصیلی اجرایی صورت گرفته، اقدامات بیولوژیک شامل کپه‌کاری، بذکاری، بذرپاشی و نهال‌کاری شبیه‌سازی شد و اثر اقدامات بیولوژیک بر دبی جریان، در نظر گرفته شد. لذا با انجام طرح‌های بیولوژیک پیش‌بینی شده در سطح حوزه آبخیز مورد مطالعه، پارامترهای پوشش گیاهی و کاربری اراضی، تغییر نموده و از لایه‌های پیش‌بینی شده استفاده شد؛ بنابراین مقادیر عددی مربوط به پوشش گیاهی حوضه از جمله شاخص NDVI و کاربری اراضی در پیکسل‌هایی که عملیات پیشنهاد شده بود، تغییر کرد که مقادیر آن‌ها مجدداً محاسبه و وارد فرآیند مدل‌سازی شد.

شبیه‌سازی سیل با مدل ماشین بردار پشتیبان

ماشین بردار پشتیبان^۴ که به اختصار به آن SVM گفته می‌شود یک الگوریتم یادگیری ماشین با ناظر است که نمونه داده‌هایی را به صورت یکسری نقاطی در فضا نشان داده شده است، با استفاده از یک خط یا هایپرپلین^۵، از هم جدا می‌کند. این جداسازی به‌گونه‌ای است که نقاط داده‌ای که در یک طرف خط هستند مشابه‌به‌هم و در یک گروه قرار می‌گیرند. نمونه داده‌های جدید هم بعد از اضافه‌شدن به همان فضا در یکی از دسته‌های موجود قرار خواهند گرفت. به منظور پیش‌بینی سیل عوامل مؤثر به صورت مقادیر عددی و با فرمت xlsx وارد نرم‌افزار R شدند و شبیه‌سازی دبی جریان با استفاده از مجموعه داده‌ها انجام شد. داده‌های موجود شامل ۷۸۵۰ سری هستند که به دو دسته داده‌های آموزش مدل (Train) که حاوی ۷۰ درصد سری داده‌ها (۵۴۹۵ سری) مربوط به دوره ۱۳۷۸/۰۷/۰۱ تا ۱۳۹۳/۰۷/۱۸ و داده‌های آزمون مدل (Test) که حاوی ۳۰ درصد سری داده‌ها (۲۳۵۵ سری) در بازه زمانی ۱۳۹۳/۰۷/۱۹ تا ۱۳۹۹/۱۲/۳۰ طبقه‌بندی شدند.

6- Random Forest

7- Ensemble Learning Algorithm

4- Support Vector Machine (SVM)

5- Hyperplane


نتایج

یکی از مهم‌ترین مسائل هیدرولوژی حوزه آبخیز، مدل‌سازی و شبیه‌سازی فرآیند بارش-رواناب می‌باشد. به‌منظور شبیه‌سازی دبی جریان سیلی از داده‌های بارندگی طبق شرح ارائه شده در بخش قبلی استفاده شد. شکل‌های ۵ تا ۸ نتایج دبی شبیه‌سازی شده را نشان می‌دهد. بر این اساس نتایج شکل‌های ۵ تا ۸ نشان می‌دهند که عملکرد مدل‌های SVM و RF، حاکی از اختلاف اندک بین میزان مقادیر مشاهداتی و شبیه‌سازی شده است. همچنین مدل RF در مقایسه با مدل SVM تعداد کم‌برآوردی بیشتری نسبت به مدل SVM دارد.

$$NSE = 1 - \frac{\sum_{i=1}^n (SIM_i - OBS_i)^2}{\sum_{i=1}^n (OBS_i - \overline{OBS})^2} \quad (4)$$


$$MAE = \frac{\sum_{i=1}^n |OBS_i - SIM_i|}{n} \quad (5)$$

که در آن‌ها: n تعداد کل جفت داده‌های شبیه‌سازی شده و مشاهده شده است و \overline{OBS} و \overline{SIM} نشان‌دهنده مقدار متوسط داده‌های مشاهده شده و شبیه‌سازی شده می‌باشند. مقدار خطا عدم توافق بین میانگین مقادیر شبیه‌سازی شده و مشاهده شده را اندازه‌گیری می‌کند. NSE از منفی بی‌نهایت تا یک متغیر است و مقادیر بالاتر نشان دهنده توافق بهتر است (Legates & McCabe Jr, 1999) و R^2 میزان احتمال همبستگی بین داده‌های مشاهده شده و شبیه‌سازی شده را اندازه‌گیری می‌کند.




شکل ۵- دبی شبیه‌سازی شده مرحله آموزش مدل SVM

Figure 5- Simulated discharge of the training step of the SVM model




شکل ۶- دبی شبیه‌سازی شده مرحله آزمون مدل SVM

Figure 6- Simulated discharge of the test step of the SVM model



شکل ۷- دبی شبیه‌سازی شده مرحله آموزش مدل RF

Figure 7- Simulated discharge of the terrain step of the RF model



شکل ۸- دبی شبیه‌سازی شده مرحله آزمون مدل RF

Figure 8- Simulated discharge of the test step of the RF model

فرض می‌شود. ارزیابی مدل از شبیه‌سازی دبی جریان با استفاده از مدل RF نشان‌دهنده دقت کم این مدل نسبت به مدل SVM بود.

جدول ۲- نتایج ارزیابی عملکرد مدل‌ها در شبیه‌سازی دبی جریان در مرحله آموزش و آزمون (بدون اقدامات بیولوژیک)


Table 2- Performance evaluation results of the models in simulating flow rate during the training and test steps (without biological measures)

مدل ماشین بردار پشتیبان (SVM)		مدل جنگل تصادفی (RF)		معیار ارزیابی
آموزش	آزمون	آموزش	آزمون	
0.97	0.98	0.69	0.56	R^2
3.80	3.19	15.04	13.42	RMSE
0.97	0.79	0.71	0.50	NSE
0.98	1.10	9.11	7.38	MAE

جدول ۲ نتایج حاصل از ارزیابی عملکرد مدل در شبیه‌سازی دبی جریان در مرحله آموزش و آزمون را در وضع موجود نشان می‌دهد. همانطور که در جدول (۲) نشان داده شده است ضریب تبیین حاصل از این شبیه‌سازی با مدل SVM در مرحله آموزش برابر ۰/۹۸ و شاخص نش-ساتکلیف برابر ۰/۷۹ است. همچنین در مرحله آزمون نیز مقادیر ضریب تبیین و شاخص نش-ساتکلیف به ترتیب برابر ۰/۹۷ و ۰/۹۷ این در حالی است که مقادیری که R^2 می‌تواند اختیار کند بین صفر و یک است و هرچه به یک نزدیک‌تر باشد قابل قبول‌تر است. از طرف دیگر اگر شاخص نش-ساتکلیف بیشتر از ۰/۷۵ باشد مدل عالی، اگر بین ۰/۳۶ تا ۰/۷۵ باشد رضایت‌بخش و اگر کم‌تر از ۰/۳۶ باشد غیرقابل قبول

توسط کاربری‌های مراتع و جنگل‌های پراکنده پوشیده شده است که با گذشت زمان سطح آنها در حال کاهش است. شکل (۹) کاربری اراضی محدوده مورد مطالعه را از سال ۱۹۹۹ تا ۲۰۲۰ نشان می‌دهد.

همان‌طور که پیش‌تر نیز اشاره شد در گام بعدی، برای بررسی تاثیر اقدامات آبخیزداری بر سیل حوزه آبخیز مورد مطالعه، ابتدا اقدام به بررسی وضعیت کاربری و روند آن در حوزه آبخیز بهشت‌آباد شد. نتایج بررسی کاربری اراضی نشان داد که بیش‌ترین سطح منطقه



شکل ۹- نقشه‌های کاربری اراضی در دوره ۱۹۹۹ تا ۲۰۲۰

Figure 9- Land use maps from 1999 to 2020

جنگل‌زدایی حدود ۳۰ درصد از حوضه باعث افزایش ۲۴ درصدی دبی متوسط سالانه می‌شود. بر همین اساس در گام بعدی از این پژوهش اقدام به شبیه‌سازی عملیات بیولوژیک در سطح حوزه آبخیز بهشت‌آباد شد و سپس میزان تاثیر آن بر دبی جریان شبیه‌سازی شد.

سطح کاربری‌های مختلف در سال‌های زمانی مورد بررسی در جدول (۳) ارائه شده است. نتایج شکل ۹ و جدول ۳ نشان می‌دهد که بیش‌ترین مساحت حوضه از کاربری مرتع تشکیل شده است. جنگل‌های زاگرس و درخچه‌های پراکنده نیز در رده دوم مساحت پوششی اراضی در حوضه قرار دارد. به‌طوری‌که نتایج نشان داد

جدول ۳- سطح کاربری اراضی در سال‌های مورد بررسی


Table 3- Land use area in time studied

سال Year		مساحت (کیلومتر مربع)				کاربری Landuse
2020	2016	2013	2009	2004	1999	جنگل Forest
1189.22	1148.67	1068.05	916.02	812.32	810.02	سطح درصد
30.03	28.99	26.95	23.10	20.49	20.44	مرتع Rangeland
2027.22	2090.09	219.42	2374.88	2465.44	2336/83	سطح درصد
51.19	52.74	55.50	59.90	62.19	58.95	تالاب Marsh
5.19	5.19	4.46	2.32	0.21	0.43	سطح درصد
0.13	0.13	0.11	0.06	0.01	0.01	کشاورزی Farming
281.22	277.47	286.44	326.02	324.49	309.55	سطح درصد
7.10	7.00	7.23	8.22	8.19	7.81	مسکونی Urban
132.25	116.97	116.88	116.14	116.26	116.31	سطح درصد
3.34	2.95	2.95	2.93	2.93	2.93	بایر Bareland
323.32	322.49	285.91	227.74	241.49	387.04	سطح درصد
8.16	8.14	7.22	5.74	6.09	9.76	پهنه آبی Waterbody
1.74	1.74	1.45	1.58	3.88	3.67	سطح درصد
0.04	0.04	0.04	0.04	0.10	0.09	سطح درصد

در پیکسل‌هایی که عملیات بیولوژیک پیش‌بینی شده، مجدداً محاسبه و وارد مدل‌سازی شد. پیکسل‌هایی که موقعیت مستعد برای اجرای عملیات بیولوژیک را داشتند مشخص شد و مقادیر کاربری و NDVI در آن‌ها تغییر پیدا کرد. بر اساس تقسیم‌بندی که در مقادیر NDVI وجود دارد مقادیر مربوط به پوشش گیاهی متوسط به بالا در نظر گرفته شد. شکل‌های (۱۰) تا (۱۳) نتایج اجرای این سناریو در بازه موردنظر (۱۳۷۸/۰۷/۰۱ تا ۱۳۹۹/۱۲/۳۰) بر مبنای مدل SVM و RF را نشان داده است.


نتایج سناریوی انجام عملیات بیولوژیک

در حوضه مورد مطالعه عملیات بیولوژیک شامل کپه‌کاری، بذکاری، بذرپاشی و نهال‌کاری انجام شده است که می‌تواند با تأثیر بر روی پارامترهای پوشش گیاهی و کاربری اراضی، ویژگی‌های سیل‌خیزی آن‌را تغییر دهد. بر اساس این سناریو در صورتی که تمامی عملیات بیولوژیک پیشنهاد شده در مطالعات این حوضه انجام شود، باعث بهبود ۳۰ درصدی پوشش گیاهی حوضه خواهد شد که جهت بررسی میزان تاثیر این تغییرات مقادیر عددی شاخص NDVI و کاربری اراضی




شکل ۱۰- دبی شبیه‌سازی شده مرحله آموزش مدل SVM برای دوره اول

Figure 10- Simulated discharge of the SVM model during training step for first period




شکل ۱۱- دبی شبیه‌سازی شده مرحله آزمون مدل SVM برای دوره دوم

Figure 11- Simulated discharge of the SVM model during the test step for the second period



شکل ۱۲- دبی شبیه‌سازی شده مرحله آموزش مدل RF برای دوره اول

Figure 12- Simulated discharge of the RF model during training step for the first period



شکل ۱۳- دبی شبیه‌سازی شده مرحله آزمون مدل RF برای دوره دوم

Figure 13- Simulated discharge of the RF model during the test step for the second period

جدول ۴- نتایج ارزیابی عملکرد مدل‌ها در شبیه‌سازی جریان در مرحله آموزش و آزمون

Table 4- Performance evaluation results of the models in flow simulation during the training and test steps

مدل جنگل تصادفی (RF)		مدل ماشین بردار پشتیبان (SVM)		معیار ارزیابی Evaluation Criteria
آموزش (Train)	آزمون (Test)	آموزش (Train)	آزمون (Test)	
0.07	0.52	0.89	0.96	R ²
22.54	13.86	7.62	4.35	RMSE
-0.03	0.47	0.86	0.95	NSE
10.29	8.48	1.89	1.17	MAE

همان‌گونه‌که در جدول (۴) مشخص است، نتایج آموزش و آزمون نشان‌دهنده کارایی خوب مدل SVM برای شبیه‌سازی هیدرولوژیک حوزه آبخیز بهشت‌آباد است. به‌نحوی که طبق نتایج به‌دست آمده مقدار ضریب تبیین در مرحله آموزش و آزمون به‌ترتیب برابر ۰/۹۶ و ۰/۸۹ بوده است. همچنین مقدار شاخص نش-ساتکلیف برای مرحله آموزش برابر ۰/۹۵ و برای مرحله آزمون ۰/۸۶ بوده است.

بحث

در حوزه آبخیز بهشت‌آباد عملیات بیولوژیک شامل کپه‌کاری، بذکاری و بذپاشی و نهال‌کاری انجام شده

همان‌طور که در شکل‌های ۱۰ تا ۱۳ نشان داده شد، بیش‌ترین میزان جریان دبی شبیه‌سازی شده با مدل SVM در منطقه مورد مطالعه حدود ۵۰۰ مترمکعب بر ثانیه بوده که در سال ۱۳۸۳ رخ داده است و همچنین بیش‌ترین میزان جریان دبی شبیه‌سازی شده با مدل RF حدود ۵۲۰ مترمکعب بر ثانیه بوده که در سال ۱۳۹۵ رخ داده است.

معیارهای ارزیابی مدل‌ها

به‌منظور ارزیابی دقت و قابلیت مدل‌های SVM و RF جهت شبیه‌سازی دبی جریان بر اساس مقادیر مشاهداتی و شبیه‌سازی شده از معیارهای ارزیابی ضریب تبیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش-ساتکلیف (NSE) و میانگین خطای مطلق (MAE) استفاده شد. بر اساس نتایج به‌دست آمده از این تحقیق در سناریوی اجرای اقدامات بیولوژیک، مدل ماشین بردار پشتیبان در مقایسه با مدل جنگل تصادفی عملکرد بهتری در پیش‌بینی دبی جریان رودخانه داشته است. جدول (۴) نتایج ارزیابی عملکرد مدل‌ها در شبیه‌سازی جریان در مرحله آموزش و آزمون را نشان می‌دهد.

داشته است. Tongal و Booiz (۲۰۱۸) جریان را در چهار رودخانه در ایالات متحده با رگرسیون بردار پشتیبانی (SVR)، شبکه‌های عصبی مصنوعی و جنگل تصادفی (RF) به عنوان تابعی از بارش، دما و تبخیر و تعرق بالقوه شبیه‌سازی کردند. نتایج نشان داد عملکرد مدل RF نسبت به بقیه مدل‌ها در شبیه‌سازی جریان بهتر بوده است. Essam و همکاران (۲۰۲۲) به منظور پیش‌بینی جریان سطحی از روش‌های یادگیری ماشین استفاده کردند و بیان داشتند که مدل شبکه عصبی مصنوعی نسبت به ماشین بردار پشتیبان قابلیت بالاتری در پیش‌بینی جریان رودخانه دارد. همچنین Lin و همکاران (۲۰۰۶) با پیش‌بینی دبی ماهانه رودخانه مان‌وان با روش‌های یادگیری ماشین (شبکه عصبی مصنوعی، سری زمانی آرما و ماشین بردار پشتیبان) اعلام کردند که مدل ماشین بردار پشتیبان یک روش بسیار کارآمد جهت پیش‌بینی سیل در رودخانه مورد بررسی می‌باشد. در مطالعه Bigdeli و همکاران (۲۰۲۳) با هدف استفاده از مدل‌های جنگل تصادفی و شبکه عصبی مصنوعی در مدل‌سازی بارش-رواناب حوزه آبخیز آجی‌چای، بیان داشتند که مدل شبکه عصبی مصنوعی عملکرد و کارایی بالاتری نسبت به مدل جنگل تصادفی داشته است. بر اساس نتایج، استفاده از مدل‌های یادگیری ماشین گزینه مناسبی برای صرفه‌جویی در وقت و هزینه‌ی طرح‌ها و پروژه‌های پیش‌بینی جریان روخانه و جریان سیلی و کنترل و مدیریت سیل در حوزه‌های آبخیز می‌باشند. در اغلب مطالعات از جمله Zaniyal و همکاران (۲۰۲۳)، Bak و Bae (۲۰۲۳) نیز استفاده از مدل‌های هوش مصنوعی در پیش‌بینی جریان با عملکرد و دقت بالا گزارش شده است.

نتیجه‌گیری کلی

نقش اقدامات آبخیزداری به‌صورت بیولوژیک در حوزه‌های آبخیز در کاهش میزان رواناب سطحی و

است که می‌تواند با تأثیر بر پارامترهای پوشش گیاهی و کاربری اراضی، ویژگی‌های سیل‌خیزی حوضه را تغییر دهد. تغییرات کاربری اراضی در طول دوره مورد بررسی بیان‌گر کاهش سطح پوشش گیاهی و افزایش زمین‌های انسان‌ساخت (کاربری مسکونی) می‌باشد که اهمیت زیادی در شماره منحنی (CN) و فرآیند تبدیل بارش به رواناب در حوضه دارد که بر اساس مدل‌سازی هیدرولوژیکی، مطالعه Dos Santos و همکاران (۲۰۱۸) نشان می‌دهد که تغییرات پوشش زمین به‌طور قابل‌توجهی بر جریان (Q) و اجزای تعادل آب^۸ (WBC) در یک حوضه گرمسیری تأثیر می‌گذارد. همچنین با توجه به کاهش پوشش جنگلی در محدوده مورد مطالعه امکان افزایش رواناب و کاهش نفوذ نیز وجود دارد که در مطالعه Costa و همکاران (۲۰۰۳) نیز مورد تایید قرار گرفته است.

نتایج اجرای این سناریو در بازه موردنظر (۱۳۷۸/۰۷/۰۱ تا ۱۳۹۹/۱۲/۳۰) بر مبنای مدل‌های SVM و RF نشان داد که اقدامات بیولوژیک توانسته دبی جریان را کاهش دهد و اثر کم‌تری روی دبی اوج داشته باشد. عملیات آبخیزداری سبب نفوذ رواناب به داخل خاک می‌شود و از طریق جریان آب زیرزمینی به چرخه آب باز می‌گردد که نتایج به دست آمده از پژوهش حاضر با نتایج Golzari و همکاران (۲۰۲۰) و Mehri و همکاران (۲۰۲۳) همسو بود. مقایسه نتایج به‌دست آمده با پژوهش‌های مشابه بیانگر نزدیک بودن آماره‌های به دست آمده با پژوهش Essam و همکاران (۲۰۲۲) است. با توجه به بالا بودن میزان معیارهای ارزیابی مدل SVM در شبیه‌سازی دبی جریان حوزه آبخیز مورد بررسی نسبت به مدل RF نتایج بهتری را ارائه داد.

مقایسه نتایج مدل‌های SVM و RF نشان داد که مدل ماشین بردار پشتیبان عملکرد بهتری نسبت به مدل جنگل تصادفی در پیش‌بینی دبی جریان رودخانه

آبخیزداری سبب نفوذ رواناب به داخل خاک می‌شود و از طریق جریان آب زیرزمینی به چرخه آب باز می‌گردد. مقایسه نتایج دو مدل یادگیری ماشین، مدل ماشین بردار پشتیبان و جنگل تصادفی نشان داد که مدل ماشین بردار پشتیبان عملکرد بهتری نسبت به مدل جنگل تصادفی در پیش‌بینی دبی جریان رودخانه داشته است. بر اساس نتایج استفاده از مدل‌های یادگیری ماشین جهت صرفه‌جویی در هزینه و زمان انجام طرح‌ها و پروژه‌های مدیریت و کنترل سیلاب بسیار حائز اهمیت می‌باشد. نتایج کلی نشان‌دهنده تأثیر قابل قبول اقدامات آبخیزداری در سطح آبخیز مورد بررسی بوده است. به‌نحوی که طبق نتایج به‌دست آمده در صورت اجرای عملیات آبخیزداری میزان حجم دبی را کاهش دهد. لذا، پیشنهاد می‌گردد با پتانسیل‌سنجی منطقه نسبت به اقدامات آبخیزداری به صورت بند توری‌سنگی، سنگی ملاتی، بانکت‌بندی و خشکه‌چین که سبب کاهش رواناب سطحی نسبت به عدم اجرای عملیات آبخیزداری خواهد شد اقدام گردد.

اثرگذاری آن بر متغیرهای سیل، از طریق تأثیر آنها بر زمان تمرکز و شماره منحنی حوزه آبخیز، امری غیرقابل انکار است. از طرفی، بررسی میزان تأثیر این اقدامات بر فرآیندهای هیدرولوژیک حوزه آبخیز اجتناب‌ناپذیر است. حوزه آبخیز بهشت‌آباد یکی از حوزه‌های آبخیز مهم کشور به دلیل موقعیت خاص قرارگیری آن بوده که سیل حاصل از آن به‌صورت مستقیم وارد مراکز مسکونی می‌شود. بر همین اساس، پژوهش حاضر نیز با هدف شبیه‌سازی اثر اقدامات آبخیزداری بر سیل‌خیزی حوزه آبخیز بهشت‌آباد با استفاده از روش یادگیری ماشین، برنامه‌ریزی شد. نتایج کلی نشان‌دهنده تأثیر قابل قبول این اقدامات در سطح حوزه آبخیز مورد بررسی بوده است. به‌نحوی که طبق نتایج به‌دست آمده، اقدامات بیولوژیک توانسته دبی جریان را کاهش دهد و اثر کم‌تری بر روی دبی اوج داشته باشد. در حوزه آبخیز بهشت‌آباد عملیات بیولوژیک شامل کپه‌کاری، بذکاری و بذپاشی و نهال‌کاری انجام شده است که می‌تواند با تأثیر روی پارامترهای پوشش گیاهی و کاربری اراضی، ویژگی‌های سیل‌خیزی حوضه را تغییر دهد. عملیات

References

- Abdi, P. (2016). Investigating the flood potential of Zanjanroud basin with SCS method and geographic information system, National Committee for Irrigation and Drainage, Technical workshop for coexistence with floods. (In Persian)
- Ahmadi, H., & Rahimi, H. (2022). Using a deep learning approach to estimate floods based on area precipitation pattern. *Water and Irrigation Management*, 11(4), 753-767. <https://doi.org/10.22059/jwim.2022.328451.909> (In Persian)
- Bagherian Kalat, A., Lashkaripour, Gh.R., & Gafoori, Mohammad. (2021). Evaluating the Impacts of Implemented Watershed Management Project on Vegetal Cover and Sediment Yield in Kakhk Watershed Project. *Journal of Environmental Science and Technology*, 23(7), 51-63. [10.30495/jest.2022.27360.3642](https://doi.org/10.30495/jest.2022.27360.3642) (In Persian)
- Bak, G., & Bae, Y. (2023). Deep learning algorithm development for river flow prediction: PNP algorithm. *Soft Computing*, 27(18), 13487-13515. <https://doi.org/10.1007/s00500-023-08254-1>
- Bigdeli, Z., Majnooni Heris, A., Delirhasannia, R., & Karimi, S. (2023). Rainfall-Runoff Modeling of Aji Chai Basin Using Random Forest and Artificial Neural Network Models. *New Research in Sustainable Water Engineering*, 1(2), 27-42. <https://doi.org/10.22103/mrswe.2023.20278.1013> (In Persian)
- Botsis, D., Latinopulos, P., & Diamantaras, K. (2011, September). *Rainfall-runoff modeling using support vector regression and artificial neural networks*. In 12th International Conference on Environmental Science and Technology (CEST2011) (pp. 8-10).
- Convertino, M., Annis, A., & Nardi, F. (2019). Information-theoretic portfolio decision model for optimal flood management. *Environmental Modelling & Software*, 119, 258-274.

- <https://doi.org/10.1016/j.envsoft.2019.06.013>
- Costa, M. H., Botta, A., & Cardille, J. A. (2003). Effects of large-scale changes in land cover on the discharge of the Tocantins River, Southeastern Amazonia. *Journal of hydrology*, 283(1-4), 206-217. [https://doi.org/10.1016/S0022-1694\(03\)00267-1](https://doi.org/10.1016/S0022-1694(03)00267-1)
- Dawson, C. W., Abrahart, R. J., Shamseldin, A. Y., & Wilby, R. L. (2006). Flood estimation at ungauged sites using artificial neural networks. *Journal of hydrology*, 319(1-4), 391-409. <https://doi.org/10.1016/j.jhydrol.2005.07.032>
- de Oliveira Serrão E A, Silva M T Ferreira T, R, de Ataide LC P, dos Santos C A, de Lima AMM, Gomes DJ C. (2022). Impacts of land use and land cover changes on hydrological processes and sediment yield determined using the SWAT model. *International J. of Sediment Research*. 37(1), 54-69. <https://doi.org/10.1016/j.ijsrc.2021.04.002>
- Dos Santos, V., Laurent, F., Abe, C., & Messner, F. (2018). Hydrologic response to land use change in a large basin in eastern Amazon. *Water*, 10(4), 429. <https://doi.org/10.3390/w10040429>
- Eslahi, M., Poursasghar, F., Mansouri Derakhshan, N., & Akbarzadeh, U. (2022). The estimation of Probable Maximum Precipitation (PMP) with Flood Forecast Approach in Urmia Lake Basin. *Journal of Climate Research*, 1401(49), 103-114. <https://doi.org/10.1016/j.envsoft.2022.105436> (In Persian)
- Essam, Y., Huang, Y. F., Ng, J. L., Birima, A. H., Ahmed, A. N., & El-Shafie, A. (2022). Predicting streamflow in Peninsular Malaysia using support vector machine and deep learning algorithms. *Scientific reports*, 12(1), 3883. <https://doi.org/10.1038/s41598-022-07693-4>
- Fallah, M., Bahrami, H., Asadi, H. (2022). Investigating Capabilities of Machine Learning Techniques in Forecasting Daily Streamflow Using Some Meteorological Data and Normalized Difference Snow Index (Case Study: Latian and Navroud Basins). *Iranian Journal of Soil and Water Research*, 53(5), 1127. <https://doi.org/10.22059/ijswr.2022.338986.669207> (In Persian)
- Gharakhanlou, N. M., & Perez, L. (2023). Flood susceptible prediction through the use of geospatial variables and machine learning methods. *Journal of Hydrology*, 617, 129121. <https://doi.org/10.1016/j.jhydrol.2023.129121>
- Golzari S, Zareabyaneh H, Delavar M, Mobargaei Dinan N. (2020). Performance of SWAT Model in Quantitative and Qualitative Simulation of Runoff and Watershed Protective Measures in Zarrinehrood Basin. *JWMMR*, 11(22) :111-120. <https://doi.org/10.52547/jwmmr.11.22.111> (In Persian)
- Hasani, A., Modaresi, F., & Ebrahimi, K. (2021). Evaluation of intelligent prediction models towards precision of flood peak flows. *Iranian Journal of Irrigation & Drainage*, 15(4), 794-804. <https://dorl.net/dor/20.1001.1.20087942.2021.15.4.5.5> (In Persian)
- Jiang, Z., Yang, S., Liu, Z., Xu, Y., Xiong, Y., Qi, S., ... & Xu, T. (2022). Coupling machine learning and weather forecast to predict farmland flood disaster: A case study in Yangtze River basin. *Environmental Modelling & Software*, 155, 105436. <https://doi.org/10.1016/j.envsoft.2022.105436>
- Jonkman, S. N. (2005). Global perspectives on loss of human life caused by floods. *Natural hazards*, 34(2), 151-175. <https://doi.org/10.1007/s11069-004-8891-3>
- Koohdarzi Moghaddam, M., Taghipour, S. M., & Erfani Pourghasemi, V. (2022). Effectiveness of watershed management measures on soil erosion and sediment yield reduction (Case study: Doholkooch Watershed, South Khorasan Province). *Water and Soil Management and Modelling*, 2(4), 1-17. <https://doi.org/10.22098/mmws.2022.10282.1080> (In Persian)
- Lawal, Z. K., Yassin, H., & Zakari, R. Y. (2021, December). Flood prediction using machine learning models: a case study of Kebbi state Nigeria. In *2021 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE)* (pp. 1-6). IEEE.

- Legates, D. R., & McCabe Jr, G. J. (1999). Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. *Water resources research*, 35(1), 233-241. <https://doi.org/10.1029/1998WR900018>
- Lin, J. Y., Cheng, C. T., & Chau, K. W. (2006). Using support vector machines for long-term discharge prediction. *Hydrological sciences journal*, 51(4), 599-612. <https://doi.org/10.1623/hysj.51.4.599>
- Mehri S, Moradi H.R, Mostafazadeh R. (2023). Simulation and determination of hydrological balance components in the upstream of Gheshlagh dam using SWAT model. *Environment and Water Engineering*. doi: <https://doi.org/10.22034/ewe.2023.360340.1805> (In Persian)
- Mostafaei, S., Moosavi, V., & Berndtsson, R. (2023). Comparing the Performance of Deep Learning, Polynomial Neural Network and HEC-HMS Models in Predicting Daily Runoff. *Iran-Water Resources Research*, 19(4), 16-33. <https://doi.org/10.22034/iwrr.2023.172260> (In Persian)
- Panahi, A., Janbaz Ghobadi, Gh., khaledi, Sh., Motavalli, S. (2023). Forecasting and zoning flood potential according to climate change algorithms (Case Study: Garganrood Watershed). *Geography*, 21(78): 109-134. <https://doi.org/20.1001.1.27833739.1402.21.78.7.2> (In Persian)
- Puttinaovarat, S., & Horkaew, P. (2020). Flood forecasting system based on integrated big and crowdsource data by using machine learning techniques. *IEEE Access*, 8, 5885-5905. <https://doi.org/10.1109/ACCESS.2019.2963819>
- Saedi, A., Saghafian, B., & Moazami, S. (2020). Uncertainty of Flood Forecasts via ensemble precipitation forecasts of seven NWP Models for Spring 2019 Golestan Flood. *Iran-Water Resources Research*, 16(1), 347-359. <https://doi.org/20.1001.1.17352347.1399.16.1.23.7> (In Persian)
- Sattari, M., Abdollah Pourazad, M., & Mirabbasi Najafabadi, R. (2016). Technical Note: Hourly river flow forecast of Aharchay River using machine learning methods. *Watershed Engineering and Management*, 8(1), 115-127. <https://doi.org/10.22092/ijwmse.2016.105979>. (In Persian)
- Shabanlou, S., Sedghi, H., Saghafian, B., & Mousavi, S. H. (2008). Flood zoning in Golestan's rivers network using GIS. *Iranian Water Researches Journal*, 2(2), 11-22. <https://doi.org/10.1029/1998WR900018> (In Persian)
- Silveira, L., Charbonnier, F., & Genta, J. L. (2000). The antecedent soil moisture condition of the curve number procedure. *Hydrological sciences journal*, 45(1), 3-12. <https://doi.org/10.1080/02626660009492302>
- Sönmez, O., & Bizimana, H. (2020). Flood hazard risk evaluation using fuzzy logic and weightage-based combination methods in geographic information system. *Scientia Iranica. Transaction A, Civil Engineering*, 27(2), 517-528. <https://doi.org/10.24200/sci.2018.21037>
- Tongal, H., & Booi, M. J. (2018). Simulation and forecasting of streamflows using machine learning models coupled with base flow separation. *Journal of hydrology*, 564, 266-282. <https://doi.org/10.1016/j.jhydrol.2018.07.004>
- Zanial, W. N. C. W., Malek, M. B. A., Reba, M. N. M., Zaini, N., Ahmed, A. N., Sherif, M., & Elshafie, A. (2023). River flow prediction based on improved machine learning method: Cuckoo Search-Artificial Neural Network. *Applied Water Science*, 13(1), 28. <https://doi.org/10.1007/s13201-022-01830-0>
- Zehra, N. (2020). Prediction analysis of floods using machine learning algorithms (NARX & SVM). *International Journal of Sciences: Basic and Applied Research (IJSBAR)*, 49(2), 24-34. <https://doi.org/10.1109/ACCESS.2019.2963819>