



Prediction of flood flows based on the combined solution of Google Earth Engine data and artificial intelligence models

Mohammad Jahani¹, Mohammad Taghi Dastorani^{*2}, Alireza Rashki³

1. M.Sc. Student, Department of Range and Watershed Management, Faculty of Natural Resources, Ferdowsi University of Mashhad, Iran, Email: muhammadjahani94@gmail.com
2. Professor, Department of Range and Watershed Management, Faculty of Natural Resources and Environment, Ferdowsi University of Mashhad, Mashhad, Iran, Email: dastorani@um.ac.ir
3. Associate Professor, Department of Desert Areas Management, Faculty of Natural Resources and Environment, Ferdowsi University of Mashhad, Iran, Email: a.rashki@um.ac.ir

| ARTICLE INFO | ABSTRACT |
|--|--|
| Article type: Research Paper | Principal component analysis, Sarzab watershed, Bayesian linear regression, artificial neural network. Flooding is one of the unfortunate events in nature, which, if not predicted in time, can cause severe financial and life damages. Therefore, estimating flood peak discharge is a crucial issue in hydrological studies today. However, research on the use of remote sensing tools for predicting, modeling, and managing floods in most of the country's watersheds has received less attention. This research aims to determine the factors affecting the flood flow discharge of the Sarbaz watershed and also evaluate the role of artificial intelligence methods, including the artificial neural network (ANN) model, to predict the flood flow of this watershed. In this research, rainfall data, soil moisture and temperature, evapotranspiration, base water flow, and Enhanced Vegetation Index (EVI) from the Google Earth Engine system, as well as observational data of flood event discharges of the studied area from 1380-1401, were used. Principal component analysis was then used to determine the factors affecting flood discharge. These factors were modeled using Bayesian linear regression to implement the artificial neural network models. Finally, artificial neural network modeling was performed for flood flow analysis. The results showed that the total rainfall of the current day and the previous day, soil moisture at a depth of 0 to 10 cm of the previous day, and soil temperature of the previous day were selected as the most appropriate input patterns for modeling. The artificial neural network designed had an efficiency factor of 0.90, a determination coefficient (R^2) of 0.89, and a root mean square error (RMSE) of 50.37 for the training stage. For the validation stage, it had an efficiency factor of 0.76, an R^2 of 0.83, and an RMSE of 46.86, demonstrating a good ability to estimate peak flood discharge. The results indicated that the calibrated model for predicting flood flow using remote sensing data is practical and has acceptable accuracy. Therefore, it can be an efficient tool to help managers predict floods on time and reduce the resulting damages. |
| Article history Received: 26 July 2024 Revised: 03 August 2024 Accepted: 12 August 2024 Published online: 31 December 2024 | |
| Keywords: Principal component analysis, Sarzab watershed, Bayesian linear regression, artificial neural network. | |
| Citation: Jahani, M., Dastorani, M.T., & Rashki, A. (2024). Prediction of flood flows based on the combined solution of Google Earth Engine data and artificial intelligence models, <i>Iranian Journal of Rainwater Catchment Systems</i> , 12(4), 51-72. | |
| DOR: | |
| Publisher: Iranian Rainwater Catchment Systems Association | © Author(s) |



*Corresponding author: Mohammad Taghi Dastorani

Address: Professor, Department of Range and Watershed Management, Faculty of Natural Resources and Environment, Ferdowsi University of Mashhad, Mashhad, Iran

Tel: +989133575425

Email: dastorani@um.ac.ir



Prediction of flood flows based on the combined solution of Google Earth Engine data and artificial intelligence models

Mohammad Jahani¹, Mohammad Taghi Dastorani^{*2}, Alireza Rashki³

1. M.Sc. Student, Department of Range and Watershed Management, Faculty of Natural Resources, Ferdowsi University of Mashhad, Iran, Email: muhammadjahani94@gmail.com
2. Professor, Department of Range and Watershed Management, Faculty of Natural Resources and Environment, Ferdowsi University of Mashhad, Mashhad, Iran, Email: dastorani@um.ac.ir
3. Associate Professor, Department of Desert Areas Management, Faculty of Natural Resources and Environment, Ferdowsi University of Mashhad, Iran, Email: a.rashki@um.ac.ir

EXTENDED ABSTRACT

Introduction: Floods are one of the most widespread environmental events that occur worldwide, causing significant damage to natural resources and human societies. Today, implementing measures to manage floods and minimize flood-related damage is imperative. Therefore, the use of flow forecasting systems to create flood warning systems based on modeling, along with the use of remote sensing techniques and data, is essential to reduce costs and enhance accuracy. In this regard, artificial neural networks are used to model flood flow. Additionally, given the importance of speed and ease of operation in the use of artificial neural networks for flood forecasting and warning systems, combining remote sensing data from Google Earth Engine with the capabilities of neural network models can enable effective flood forecasting and warning in different areas. Based on this, this research aims to determine the amount of daily discharge using data analysis obtained from the Google Earth Engine (GEE) system and modeling by artificial neural networks to predict flood events affected by these floods.

Methodology: In this research, data of rainfall, soil moisture and temperature, evapotranspiration, base flow, and the enhanced vegetation index (EVI) were analyzed in the Google Earth Engine system, along with observational data of flood events in the Sarbaz watershed from 2001 to 2023. Principal component analysis (PCA) was used to determine the factors that significantly impact flood discharge. These factors were then modeled using Bayesian linear regression to implement artificial neural network models. In the final stage, principal component analysis was used to determine the factors affecting flood discharge. This analysis was conducted in the R software environment. The identified factors were then modeled using Bayesian linear regression in the JASP V0.16.3.0 software environment to implement artificial neural network models. In this research, modeling was performed using an artificial neural network in the MATLAB R2018b software environment. 80% of the data were selected for training, and the remaining 20% for the testing phase. To implement the most optimal structure of the artificial neural network, log-sigmoid and tangent-sigmoid transfer functions were used with the Levenberg-Marquardt training algorithm, utilizing a back-propagation network with a feed-forward architecture. In the artificial neural network model, trial and error was used to determine the appropriate number of hidden layers and neurons. This process continued until no improvement was observed in the R^2 and RMSE values. Finally, to select the ideal artificial neural network model, the statistical criteria of root mean square error (RMSE), determination coefficient (R^2), and Nash-Sutcliffe coefficient were used.

Results and Discussion: The results of the PCA showed that precipitation, soil moisture at a depth of 0 cm to 10 cm, soil temperature, evapotranspiration, and the vegetation index (EVI) play important roles in predicting flood discharge in the study area. Using these factors and Bayesian linear regression, the input patterns for the artificial neural network were determined. Four models with different input patterns were used in this research. Model 1 included only the precipitation factor, Model 2 included precipitation and soil moisture at a depth of 0 to 10 cm, Model 3 included precipitation and the vegetation index (EVI), and Model 4 included precipitation, soil moisture at a depth of 0 to 10 cm, and soil temperature. The artificial neural network results indicated that the most suitable input patterns were the total rainfall on the current and previous days, soil moisture at a depth of 0 cm to 10 cm

***Corresponding author:** Mohammad Taghi Dastorani

Address: Professor, Department of Range and Watershed Management, Faculty of Natural Resources and Environment, Ferdowsi University of Mashhad, Mashhad, Iran.

Tel: +989133575425

Email: dastorani@um.ac.ir

from the previous day, and soil temperature from the previous day. The designed artificial neural network effectively estimated peak flood discharge, achieving a Nash-Sutcliffe coefficient of 0.90, an R² of 0.89, and an RMSE of 50.37 for the training phase. For the validation stage, it showed a Nash-Sutcliffe of 0.76, an R² of 0.83, and an RMSE of 86.46.

Conclusion: The results of this research showed that using the data of rainfall, surface soil moisture and soil temperature, with Nash-Sutcliffe of 0.90 and a R² of 0.89 and a RMSE of 50.37 for the training stage and Nash-Sutcliffe of 0.76 and the R² of 0.83 and the RMSE of 86.46 for the validation stage can estimate the flood discharge with acceptable accuracy. Thus, integrating artificial intelligence data with remote sensing from the Google Earth Engine system has significant potential, offering sufficient accuracy and low cost in determining flood discharge. This approach can be an efficient tool to help managers in timely flood forecasting, reducing flood damages, and improving flood management. Finally, it is suggested to examine other factors influencing floods and explore other artificial intelligence methods to enhance flood discharge prediction.

Ethical Considerations

Data availability statement: The datasets are available upon a reasonable request to the corresponding author.

Funding: This research is the result of the M.Sc. Thesis, Ferdowsi University of Mashhad, Mashhad, Iran.

Authors' contribution: All the authors cooperated to prepare the article in all sections.

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

Acknowledgment: We would like to express our sincere gratitude to the Ferdowsi University of Mashhad for the financial and logistical support.



پیش‌بینی جریان‌های سیلابی بر اساس راهکار ترکیبی داده‌های گوگل ارث انجین و مدل‌های هوش مصنوعی

محمد جهانی^۱، محمدتقی دستورانی^{۲*}، علیرضا راشکی^۳

۱. دانشجوی کارشناسی ارشد، گروه منابع و آبخیزداری، دانشکده منابع طبیعی و محیط‌زیست، دانشگاه فردوسی مشهد، مشهد، ایران، muhammadjahani94@gmail.com

۲. استاد، گروه منابع و آبخیزداری، دانشکده منابع طبیعی و محیط‌زیست، دانشگاه فردوسی مشهد، مشهد، ایران، dastorani@um.ac.ir

۳. دانشیار، گروه مدیریت مناطق خشک و بیابانی، دانشکده منابع طبیعی و محیط‌زیست، دانشگاه فردوسی مشهد، مشهد، ایران، a.rashki@um.ac.ir

| مشخصات مقاله | چکیده |
|----------------------|--|
| نوع مقاله: پژوهشی | سیل یکی از حوادث ناگوار در طبیعت است که در صورت عدم پیش‌بینی به موقع می‌تواند باعث خسارت مالی و جانی شدیدی شود. لذا برآورد دی اوج سیلابی از مهم‌ترین مسائلی است که امروزه، در مطالعات هیدرولوژیکی دارای اهمیت ویژه‌ای است. با این وجود هنوز تحقیقات برای استفاده از ابزارهای سنجش از دور برای پیش‌بینی، کنترل و مدیریت سیل در اکثر حوزه‌های آبخیز کشور کمتر مورد توجه واقع شده است. هدف پژوهش حاضر، تعیین عوامل موثر بر دی جریان سیلابی حوزه آبخیز سرباز و پیش‌بینی جریان سیلابی رودخانه سرباز با استفاده از روش‌های هوش مصنوعی شامل شبکه عصبی مصنوعی (ANN) است. در این تحقیق داده‌های بارندگی، رطوبت و دمای خاک، تبخیر و تعرق، جریان آب پایه، شاخص تقویت شده پوشش گیاهی (EVI) در سامانه گوگل ارث انجین و داده‌های مشاهدهای دی رخدادهای سیل در حوضه منطقه موردمطالعه در دوره زمانی ۱۳۸۰-۱۴۰۱ به کار گرفته شد. به دنبال آن عوامل موثر بر دی سیلابی بهروش تحلیل مؤلفه اساسی تعیین و در مرحله بعد برای اجزای مدل‌های شبکه عصبی مصنوعی این عوامل به وسیله رگرسیون خطی بیزین گوبندی شد و در مرحله آخر مدل سازی شبکه عصبی مصنوعی به منظور پیش‌بینی جریان سیلابی انجام گرفت. نتایج نشان داد که عوامل مجموع بارش روز جاری و روز‌ماقبل، رطوبت خاک در عمق ۰ تا ۱۰ سانتی‌متری، دمای روز‌ماقبل و دمای خاک در روز قبل، به عنوان مناسب‌ترین الگوی ورودی برای مدل سازی انتخاب شدند. نتایج نشان داد که شبکه عصبی مصنوعی طراحی شده با ضریب کارایی ۰/۹۰ و ضریب تعیین ۰/۸۹ و ریشه میانگین مربعات خطای ۵/۳۷ برای مرحله آموزش و ضریب کارایی نش-ساتکلیف ۰/۷۶ و ضریب تعیین ۰/۸۳ و ریشه میانگین مربعات خطای ۰/۶۵ برای مرحله اعتبارسنجی، توانایی خوبی در برآورد دی اوج سیلابی دارد. نتایج نشان داد که مدل واسنجی شده به منظور پیش‌بینی دی جریان سیلابی با استفاده از داده‌های سنجش از دور کاربردی بوده و دقت قابل قبولی دارد و می‌تواند ابزاری کارآمد در یاری رساندن به مدیران برای پیش‌بینی به موقع سیلاب و کاهش خسارات ناشی از آن باشد. |
| تاریخچه مقاله | دریافت: ۰۵ مرداد ۱۴۰۳ بازنگری: ۱۳ مرداد ۱۴۰۳ پذیرش: ۲۲ مرداد ۱۴۰۳ انتشار برخط: ۱۱ دی ۱۴۰۳ |
| واژه‌های کلیدی: | تحلیل مؤلفه اساسی، حوزه آبخیز سرباز، رگرسیون خطی بیزین، شبکه عصبی مصنوعی. |
| استناد: | جهانی، محمد، دستورانی، محمدتقی، راشکی، علیرضا. (۱۴۰۳). پیش‌بینی جریان‌های سیلابی بر اساس راهکار ترکیبی داده‌های گوگل ارث انجین و مدل‌های هوش مصنوعی. سامانه‌های سطوح آبگیر باران، ۱۲(۴)، ۵۱-۷۲. |
| DOR: | ناشر: انجمن علمی سیستم‌های سطوح آبگیر باران ایران |



© نویسنده‌گان

مقدمه

سیل یکی از حوادث محیطی شایع و گسترده است که در سرتاسر جهان روی می‌دهد و خسارات زیادی را به منابع طبیعی و جوامع انسانی وارد می‌کند. این پدیده طبیعی زمانی اتفاق می‌افتد که جریانات سطحی ناشی از بارندگی بیش از ظرفیت زهکشی آبراهه بوده و در نتیجه باعث آب گرفتگی نواحی خشکی می‌شود (Rozos et al., 2014; Birkholz et al., 2014) که در نهایت می‌تواند موجب خسارت‌های مالی و جانی فراوانی شود. امروزه پرداختن به اقداماتی جهت پیش‌گیری از وقوع سیل و کاهش خسارات ناشی از آن‌ها، از جمله اقداماتی است که غیرقابل چشم پوشی است.

فرآیند هشدار سیلاب معمولاً بر اساس مدل‌های هواشناسی و پیش‌بینی‌های مبتنی بر میزان بارندگی اعلام می‌شود (امینی و ثاقبیان، ۱۴۰۱؛ عبداللهزاده و شریف‌زاده، ۱۴۰۲؛ Rozos, 2023). از آن‌جایی که این فرآیند به دلیل دقت پایین مدل‌ها، تغییرات و عدم توزیع مناسب حسگرهای زمینی هواشناسی، نیازمند استفاده از داده‌های زمینی هستند، می‌توان از سامانه‌های یکپارچه پیش‌بینی مبتنی بر مدل‌های جفت شده هواشناسی و هیدرولوژیکی و داده‌های هوشمند بر خط نظر رادار، ماهواره، سنجش از دور با فاکتور اینترنت و هر گونه اطلاعات مرتبط با موضوع در قالب یک سامانه، با بهره‌گیری از هوش مصنوعی، استفاده نمود (زارعی و همکاران، ۱۴۰۱؛ مینایی و وحیدنیا، ۱۴۰۱). به همین جهت می‌توان به کمک داده‌های ماهواره‌ای و راداری، پارامترهای پیش‌گفته را به صورت مکانی و برای مدت زمان معینی بررسی نمود، تا به صورت آنی در مدل‌های پیش‌بینی اعمال شود (امینی و همکاران، ۱۳۹۹). بنابراین می‌توان از سامانه‌های پیش‌بینی جریان برای ایجاد سامانه‌های هشدار سیل مبتنی بر مدل سازی همراه با استفاده از تکنیک‌ها و داده‌های سنجش از دور استفاده نمود تا موجب کاهش هزینه و افزایش دقت شود (سیدی‌پور و همکاران، ۱۴۰۲). در همین راستا به منظور افزایش دقت و سرعت پیش‌بینی سیل، باید روش‌های گردآوری، مدیریت داده‌های پایه و همچنین آماده‌سازی این پیش‌بینی‌ها به درستی سازماندهی شود (Mamat et al., 2021; Thielen et al., 2022).

آن‌ها شبکه عصبی مصنوعی، یکی از مدل‌های مطلوب در این زمینه است (دستورانی، ۱۳۹۰؛ روشان و همکاران، ۱۴۰۰).

با توجه به اهمیت پیش‌بینی به موقع سیل و نیاز به کنترل و مدیریت به موقع آن، پژوهشگران مطالعات فراوانی را برای پیش‌بینی دبی جریان‌های سیلابی انجام داده‌اند (Rangari et al., 2020; Du et al., 2021; Fu-wei et al., 2022; Zalnezhad et al., 2022). شبکه عصبی مصنوعی، سیستم را به صورت یک جعبه سیاه در نظر گرفته و با توجه به رفتار گذشته سیستم، رفتار سیستم در زمان آینده را پیش‌بینی می‌نماید که به این مدل‌ها، مدل‌های مبتنی بر داده یا آمار گفته می‌شود (Sahoo et al., 2022؛ سیدیان و همکاران، ۱۳۹۷). مطالعات Dtissibe و همکاران (۲۰۲۰)، که بر روی رودخانه گاردون در کشور فرانسه با استفاده از ۲۵ واقعه سیل به طراحی یک سیستم پیش‌بینی سیل به کمک مدل شبکه عصبی مصنوعی پرداخته‌اند، نتایج آن‌ها نشان داد که بهره‌گیری از شبکه عصبی مصنوعی برای پیش‌بینی سیل، می‌تواند یک سیستم کارآمد در جلوگیری از خسارات ناگهانی آن باشد. همچنین نتایج مطالعه Karl و Lohani (۲۰۱۰) در حوضه ماهاندی کشور هند برای پیش‌بینی دبی سیلاب، ۸۰ واقعه دبی یک سیلابی (۱۹۹۶ تا ۲۰۰۷) را با مدل شبکه عصبی مصنوعی و روش‌های آماری مدل‌سازی کرده‌اند و به این نتیجه رسیدند که پیش‌بینی دبی سیلاب با استفاده از شبکه عصبی مصنوعی نسبت به روش‌های آماری (همبستگی) کارآمدتر است.

از آن‌جاکه در سامانه‌های پیش‌بینی سیل، پیچیدگی و ماهیت غیر خطی فرآیند بارش-رواناب و ناشناخته بودن تاثیر عوامل بر روی یکدیگر وجود دارد، باید از مدل‌هایی استفاده شود که در عین سادگی دقت زیادی را داشته باشند؛ به طوری که با توجه به شرایط عدم قطعیت موجود در طبیعت، برآورده با کمترین اختلاف بین نتایج خروجی و داده‌های ورودی دارا باشند. در همین راستا مطالعات این محققان نشان داد که مهم‌ترین دلیل استفاده از شبکه‌های عصبی مصنوعی برای مدل سازی فرآیندهای هیدرولوژیکی، توانایی بالای آن‌ها در برقراری نگاشت غیرخطی بین متغیرهای ورودی و خروجی است (دستورانی، ۱۳۹۰؛ رستمی خلچ و همکاران، ۱۳۹۹). در ادامه از آن‌جاکه برای استفاده از شبکه‌های عصبی مصنوعی در سیستم‌های پیش‌بینی و هشدار سیل، سرعت و سهولت اجرای عملیات نقش بسیار مهمی دارد، می‌توان از داده‌های سنجش از دور، در جهت افزایش سرعت و تکمیل داده‌های زمینی به منظور سهولت تعیین متغیرها ورودی و خروجی مدل، استفاده نمود (Samantaray et al., 2022). لذا مطالعات Motta و همکاران (۲۰۲۱) و Yang و همکاران (۲۰۲۲) نشان‌دهنده این موضوع بود که با تلفیق کاربرد تکنیک‌های سنجش از دور (RS¹) و بهره‌گیری از قابلیت‌های مدل شبکه عصبی، می‌توان تبیه پیش‌بینی و هشدار سیل را برای مناطق مختلف فعال نمود. در همین زمینه نیز Rostami و همکاران (۲۰۲۲) در مطالعه‌ای بر روی استان لرستان در کشور ایران با استفاده از داده‌های سنجش از دور سامانه گوگل ارث انجین و به کمک روش‌های هوش مصنوعی به پیش‌بینی دبی سیلاب پرداخته‌اند، آن‌ها به این نتیجه دست یافته‌ند که بهره‌گیری از داده‌های سنجش از دور و روش‌های هوش مصنوعی می‌تواند در پیش‌بینی دبی و ایجاد سامانه‌های هشدار سیل مؤثر باشد.

¹ Remote Sensing

بررسی‌های انجام شده در ایران نیز نشان داده است که رخداد سیل یکی از سه مخاطره طبیعی و اصلی است و به جرأت می‌توان گفت که حداقل هر سال در مناطقی از این سرزمین سیلاب قابل توجهی رخ می‌دهد (کاظمی و پرهمنت، ۱۴۰۰؛ بیاتی خطيبي و همكاران، ۱۴۰۰). سیل خیز بودن اکثر حوزه‌های آبخیز کشور، گسترش طرح‌های توسعه منابع آب در حوزه‌ها و پیشرفت فناوری کامپیوترا، ضرورت مدیریت و پیش‌بینی سیلاب از طریق مدل‌سازی و ابزارهای سنجش از دور را دو چندان کرده است. به خصوص که هزینه‌های عملیاتی این‌گونه روش‌های مدیریتی در مقایسه با روش‌های سنتی بسیار ناچیز بوده است (گنجی و همکاران، ۱۴۰۰). در این راستا زیارتی و همکاران (۱۴۰۰) و رحمانی و همکاران (۱۳۹۸) در مطالعات خود نشان دادند که در اکثر حوزه‌های آبخیز کشور به مسئله کنترل و مدیریت سیل و توسعه ابزارهای سنجش از دور کمتر از روش‌های سنتی و قدیمی بها داده شده و این موضوع سبب شده که در زمینه به کارگیری تکنولوژی‌های مربوطه نسبت به کشورهای توسعه یافته و در حال توسعه پیشرفت کمتری حاصل شود. بر این اساس هدف این پژوهش، تعیین دبی سیلابی با تحلیل وقایع با ضریب تغییرات بالا طی دوره زمانی ۱۳۸۰-۱۴۰۱ با بهره‌گیری از داده‌های بازتحلیل و سنجش از دور موجود در سامانه گوگل ارت انجین^۱ (GEE) و مدل سازی توسط شبکه عصبی مصنوعی برای پیش‌بینی دبی جریان وقایع سیلابی در منطقه مورد مطالعه است. به همین منظور از روش آماری کاهش داده‌ها (تجزیه و تحلیل مؤلفه‌های اصلی و احتمالات بیزین) جهت تدوین مدل‌های ورودی هوش مصنوعی استفاده شد.

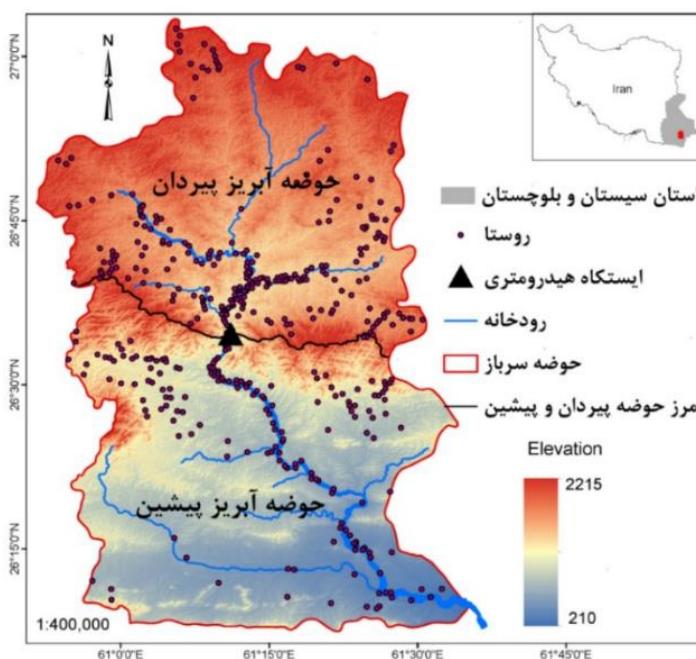
مواد و روش تحقیق منطقه مورد مطالعه

حوزه آبخیز سریاز با مساحت ۵۰۰۴ کیلومتر مربع در جنوب استان سیستان و بلوچستان در محدوده $56^{\circ} ۶۱' ۳۵''$ طول شرقی و $۲۶^{\circ} ۲۷' ۰۵''$ عرض شمالی واقع شده است. بیشتر ارتفاع در این حوزه ۲۰۱۷ متر و کمینه آن ۲۹۹ متر است و شبیه متوسط آن $۱۶/۸$ درصد است. این حوضه دارای دو زیرحوضه پیردان با مساحت ۲۴۰۰ کیلومتر مربع و زیر حوضه پیشین با مساحت ۲۶۰۰ کیلومتر مربع است. میانگین بارندگی سالانه در این حوضه، از $۱۰۲/۱$ تا $۱۷۹/۴$ میلی‌متر متغیر است. رودخانه سریاز تنها رودخانه دائمی است که در این حوزه آبخیز جریان دارد و جهت آن از شمال به جنوب بوده و متوسط دبی سالانه آن در ایستگاه هیدرومتری پیردان حدود $۲/۲$ متر مکعب بر ثانیه است. میانگین حداکثر دما ۲۹ درجه سانتی گراد و متوسط حداقل دما ۱۵ درجه سانتی گراد است (Gorji et al., 2020). به طور کلی در این حوضه ۱۰ کاربری اصلی در منطقه وجود دارد. بیشترین درصد مساحت زمین را مراتع فقیر (۵۴ درصد) و کمترین آن را سطوح آبی ($۱/۰$ درصد) تشکیل می‌دهند. $۴/۵$ درصد از اراضی این حوضه را باغات، اراضی کشاورزی و مسکونی تشکیل می‌دهند که عمدتاً در داخل مسیل قرار دارند (دامادی و همکاران، ۱۴۰۰؛ شکل ۱).

این منطقه با توجه به شرایط آب و هوایی در سال‌های اخیر به دفعات تحت تأثیر سیلاب‌های شدید قرار گرفته است (آرمش و همکاران، ۱۳۹۶). دبی رودخانه سریاز تحت تأثیر رژیم‌های بارش در دو فصل تابستان و زمستان است (دامادی و همکاران، ۱۴۰۰). همه ساله در فصل باران‌های موسومی که از اوایل بهار شروع می‌شود و تا اواخر تابستان ادامه دارد، دریای عمان و جنوب استان سیستان و بلوچستان را دستخوش تغییرات اقلیمی می‌کند و بارندگی‌ها و بادهای موسومی دریا را موج و رودخانه‌ها را طغیانی می‌کند و سیلاب جاری می‌شود. همچنین در زمستان نیز، جریان زمستانه ناشی از بارندگی‌های جبهه‌های سرد سیبری و مدیترانه موجب طغیان رودخانه‌های فصلی و جاری شدن سیلاب در جنوب این استان می‌شود. به همین دلیل با توجه به شرایط جغرافیایی، توپوگرافی و زمین‌شناسی جنوب استان و ظرفیت پتانسیل بالای سیل خیزی آن، لازم است سامانه پیش‌بینی سطح جریان برای این حوزه راهاندازی شود (نگارش و همکاران، ۱۳۹۲؛ ملازه‌ی و همکاران، ۱۳۹۹).

در این مطالعه، هدف برآورد دبی سیلاب در رودخانه سریاز است. در منطقه مورد مطالعه، ایستگاه هیدرومتری پیردان واقع شده است. این ایستگاه دارای دوره آماری از سال ۱۴۰۱ تا ۱۳۶۱ است (شرکت آب منطقه سیستان و بلوچستان). در شکل ۱ موقعیت جغرافیایی این ایستگاه و در جدول ۱ مشخصات این ایستگاه نشان داده شده است (نوری قیداری و همکاران، ۱۳۹۳). برای ایجاد یک سامانه پیش‌بینی سیل، در ابتدا نیاز به بسترهای ارتباطی و زیرساخت های هواشناسی و پردازش داده مناسب است، که با وجود بسترهای ارتباطی کنونی، امکان ایجاد این سامانه در اکثر نقاط جنوبی استان وجود ندارد، چرا که با اندک بارندگی ارتباط ایستگاه‌های بارانسنجی قطع می‌شود. بنابراین ایجاد یک سامانه پیش‌بینی سیل مبتنی بر هوش مصنوعی و استفاده از داده‌های همیشه در دسترس سنجش از دور در حوضه‌های آبخیز جنوبی این استان امری ضروری و اجتناب‌ناپذیر است.

^۱- Google Earth Engine



شکل ۱- نقشه موقعیت جغرافیایی منطقه مورد مطالعه
Figure 1- Geographical location map of the studied area

جدول ۱- مشخصات ایستگاه هیدرومتری مورد مطالعه

Table 2- Characteristics of the hydrometric station of the studied area

| نام ایستگاه | عرض جغرافیایی | طول جغرافیایی | ارتفاع سطح دریا (متر) | متوسط سطح دریا (متر) | متوسط تغیرات دبی سالانه (m^3/s) | ضریب ابدی دبی سالانه | متوسط بارش سالانه (mm) | ضریب چوگانی رواناب (%) |
|----------------|---------------|---------------|-----------------------|----------------------|-------------------------------------|----------------------|------------------------|------------------------|
| ایستگاه پیردان | 26°34' | 61°13' | 750 | 10.2 | 2.14 | 52.3 | 140.7 | 11.7 |

جمع آوری داده‌ها

همان‌طور که گفته شد سامانه گوگل ارت انجین، یک منبع داده با ارزش برای توسعه سیستم‌های پیشگیری و هشدار سیل است. در این مطالعه، محصولات سامانه گوگل ارت انجین به دلیل سهولت تجزیه و تحلیل داده‌های بلندمدت و همچنین در دسترس بودن بسیاری از مجموعه داده‌ها در این بازه زمانی مورد استفاده قرار گرفتند (DeVries et al., 2014). عوامل طبیعی زیادی بر وقوع سیل در یک منطقه مؤثر هستند، از عوامل طبیعی، اقلیمی، پوشش گیاهی و خصوصیات خاک و از عوامل انسانی شهرسازی، جنگل‌زدایی و فعالیت‌های کشاوری را می‌توان نام برد (Hong et al., 2013). با توجه به علل طبیعی و تأثیر تغییرات آب و هوایی بر وقوع سیل در یک منطقه، در این مطالعه سه دسته از داده‌های گوگل ارت انجین برای هریک از وقایع سیلابی استخراج و مورد استفاده قرار گرفته است که در زیر به معرفی مختصر آن‌ها پرداخته شده است.

داده‌های MODIS

پوشش گیاهی یکی از پارامترهای ضروری در جلوگیری از وقوع سیل یا کاهش شدت آن است. در واقع، پوشش گیاهی این‌بهتر از آسیب‌های احتمالی سیل جلوگیری می‌کند، در حالی که پوشش گیاهی تکثر می‌تواند خطر افزایش دبی جریان سیل را به همراه داشته باشد (روشن نکو، ۱۳۹۳)، بنابراین در این پژوهش از داده‌های با وضوح زمانی روزانه و وضوح مکانی ۵۰۰ متر شاخص پوشش گیاهی (EVI) استفاده شد (پاشایی‌نژاد و همکاران، ۱۳۹۲). در همین راستا برای بهره‌مندی از این داده، از میانگین نزدیک‌ترین تصویر ماقبل روز مورد نظر برای حوضه بالادست منطقه مورد مطالعه استفاده شده است.

داده‌های GLDAS

GLDAS یک محصول جدید جهانی و در دسترس عموم است که توسط سیستم اطلاعات زمین ناسا ارائه شده است. در این مدل نیز به صورت ترکیبی از داده‌های ماهواره‌ای و زمینی با دقت ۲۵ کیلومتری برای شبیه‌سازی پارامترهای اقلیمی از سال ۱۹۴۸ میلادی، استفاده شده است و می‌تواند برای مطالعات هیدرولوژیکی و سیستم‌های پیش‌بینی سیل استفاده شود (Zhao et al., 2022). بارندگی همیشه به

نهایی شاخص شدت سیل نیست و شرایط پیشین رطوبتی حوضه، فاکتور مهم دیگری است که به شدت بر بزرگی سیل تاثیر گذار است خصوصیات خاک، بهویژه رطوبت و نفوذپذیری خاک به عنوان پیشرانه سیل ها به خوبی شناخته شده است که نقش غیرقابل انکاری در یک سیستم پیش‌بینی سیل دارد. باید در نظر داشت از آن جاکه رطوبت خاک و نفوذپذیری خاک رابطه منفی و نزدیکی دارد و از طرفی مطالعه دامادی و همکاران (۱۴۰۰) نشان داد که در حدود ۹۰ درصد از مساحت حوضه در کلاس نفوذپذیری کم قرار دارند، لذا تنها عامل رطوبت خاک در مدل‌سازی مدنظر قرار گرفت. همچنین تغییر بر میزان جریان پایه به عنوان یکی دیگر از شرایط پیشین رطوبتی حوضه، می‌تواند باعث تغییرات در میزان سیلاب در منطقه شود (Boithias et al., 2021). دمای خاک نیز ارتباط نزدیکی با رطوبت دارد و می‌تواند باعث افزایش یا کاهش جذب آب در هنگام بارندگی شود (زاهدی و قرمذشمه، ۱۴۰۰). بنابراین در این مطالعه از داده‌های میانگین رطوبت در عمق ۰ تا ۱۰ سانتی‌متر و ۱۰۰ تا ۲۰۰ سانتی‌متر و دمای خاک روز قبل و قریب‌تر آب پایه روز قبل واقعه برای حوضه بالادست که از محصول GLDAS با وضوح زمانی روزانه استخراج شده، استفاده شده است.

داده‌های CHIRPS

داده‌های این محصول بر اساس اطلاعات قبلی با استفاده از تکنیک‌های هوشمند و بر مبنای داده‌های طولانی مدت ثبت شده بارش بر اساس مشاهدات مادون قرمز ابر؛ میزان بارش را تخمین می‌زنند. داده‌های CHIRPS از مقادیر ۶ ساعته تا سه ماهه در دسترس است. تقریباً تمام داده‌ها دارای درجه وضوح مکانی 0.05° درجه است. داده‌های بارش از سال ۱۹۸۱ تا نزدیک‌ترین زمان به حال حاضر با پوشش ۵۰ درجه شمالی تا ۵۰ درجه جنوبی ارائه می‌شود (شرافتی و شبیری، ۱۴۰۰). در این مطالعه نیز از داده‌های این محصول با وضوح زمانی روزانه برای میانگین مجموع بارش روز جاری و روز ما قبل وقایع برای حوضه بالادست مورد استفاده قرار گرفته است.

پیش‌پردازش داده‌ها

محاسبه دبی سیلابی

برای انجام این پژوهش از داده‌های دبی متوسط روزانه وقایع سیلابی رودخانه سرباز در محل ایستگاه آبسنجی پیردان طی سال‌های ۱۴۰۱-۱۳۸۰ (شرکت آب منطقه سیستان و بلوچستان) استفاده شد. برای شناسایی سایر وقایع سیلابی، متوسط دبی روزانه (حدود ۲/۲ متر مکعب بر ثانیه) محاسبه شد و به عنوان مرز انتخاب وقایع سیلابی در نظر گرفته شد. چرا که با توجه به تعریف، سیل عبارتست از جریانی که از مقدار دبی متوسط رودخانه بیش‌تر است (نگارش و همکاران، ۱۳۹۲؛ Hong et al., 2013؛ Abbott, 2006). در نهایت در طی این دوره ۸۴ واقعه سیلابی در منطقه مورد مطالعه شناسایی شد. از آن جاکه داده‌های دبی پیک سیلابی تنها برای برخی وقایع سیلابی ثبت شده بود. برای تعیین دبی پیک سیلابی هر کدام از این وقایع سیلابی، رابطه رگرسیونی بین داده‌های موجود دبی متوسط روزانه و دبی پیک وقایع ثبت شده آن‌ها برقرار و دبی پیک سیلابی ($R^2=0.82$) آن‌ها برآورد شد (Dastorani et al., 2013).

تجزیه و تحلیل مؤلفه‌های اصلی (PCA^۱)

این تحلیل از روش‌های آماری چند متغیره است و در مواردی که با حجم زیادی از اطلاعات روبرو هستیم، می‌توان از این روش به‌منظور کاهش پیچیدگی تحلیل متغیرها و عوامل رودودی به مدل و همچنین تفسیر بهتر این اطلاعات استفاده نمود. در همین راستا اولین گام برای پیاده‌سازی این روش تعیین و تشخیص مناسب بودن داده‌ها است. روش‌های وجود دارد که پژوهشگر به‌وسیله آن‌ها می‌تواند این موضوع را مورد آزمایش قرار دهند. از جمله این روش‌ها می‌توان به محاسبه فاکتور کفایت نمونه‌گیری^۲ KMO اشاره کرد. مقدار این عامل همواره بین صفر و یک در نوسان است در صورتی که KMO کمتر از 0.5 باشد، داده‌ها برای روش تحلیل مؤلفه‌های اصلی مناسب نخواهند بود و اگر مقدار آن بین 0.5 و 0.69 باشد، همبستگی داده‌ها متوسط و اگر این مقدار بزرگ‌تر از 0.70 باشد همبستگی‌های موجود در بین داده‌ها برای تحلیل مؤلفه‌های اصلی مناسب خواهند بود (شیخ‌الاسلامی و همکاران، ۱۳۹۳).

همان‌طور که گفته شد تحلیل مؤلفه‌های اصلی یک تکنیک آماری است که با تبدیل متغیرهای اصلی به تعداد کمتری از متغیرهای جدید بعد داده‌ها را کاهش می‌دهد. این متغیرهای جدید مؤلفه‌های اصلی نامیده می‌شوند، که بیش‌ترین تغییرات داده را توصیف می‌کنند. در این تحلیل، ارزش ویژه (Eigen value) میزان واریانسی را که هر مؤلفه اصلی توصیف می‌کند نشان می‌دهند. از نمودار اسکری (Scree plot)، برای نمایش ارزش‌های ویژه که به ترتیب نزولی رسم می‌شود استفاده می‌شود. در همین راستا ارزش ویژه برای تعیین تعداد بهینه مؤلفه‌های اصلی مورد استفاده قرار می‌گیرد. قاعده عمومی آن است که مؤلفه‌هایی که ارزش ویژه آن‌ها بزرگ‌تر از ۱ است به عنوان مؤلفه‌های اصلی انتخاب می‌شوند. بردارهای ویژه (Eigen vector) همان ضرایب ترکیب خطی متغیرهای اصلی هستند که هر مؤلفه اصلی

¹- Principal Component Analysis

²- Kaiser-Meyer-Olkin Measure of sampling

را تشکیل می‌دهند. از بردارهای ویژه برای تفسیر معنای هر مؤلفه اصلی، با توجه به علامت و بزرگی ضرایب، استفاده می‌شود، یک ضریب مثبت یا منفی بزرگ به این معنی است که متغیر به مؤلفه اصلی دخالت یا مشارکت مثبت یا منفی دارد. این در حالی است که یک ضریب کوچک یا صفر نشان‌دهنده تأثیر کم یا عدم تأثیر متغیر بر مؤلفه اصلی است. در بسته‌های استفاده شده در این تحقیق از میزان مشارکت هر متغیر (Contribution) به عنوان بردار ویژه در هر مؤلفه برای توجیه بزرگی ارتباطات استفاده شد. در این پژوهش تحلیل مؤلفه‌های اصلی برای خلاصه‌سازی داده‌ها در محیط R و با استفاده از بسته‌های Factoextra و FactoMineR انجام شد و میزان وابستگی هر یک از پارامترها به هر مؤلفه اصلی، تغییرات امتیاز هر مؤلفه و همبستگی آن‌ها مورد بررسی قرار گرفت.

الگوسازی و رودی‌های شبکه عصبی مصنوعی به وسیله رگرسیون خطی بیزین^۱

در آمار، رگرسیون خطی بیزین نوعی از رگرسیون خطی است که در آن تجزیه و تحلیل آماری در چارچوب استنباط بیزی انجام می‌شود. در این روش، داده‌ها با اطلاعات اضافی در قالب یک توزیع احتمال پیشین مورد بررسی قرار می‌گیرند و توزیع پسین که با استفاده از قانون بیز، توزیع پیشین وتابع درست نمایی به دست می‌آید برای پیش‌بینی و الگوسازی مدل مورد استفاده قرار می‌گیرد (Permai & Tanty, 2018). به این ترتیب از «توزیع پیشین» (Prior Distribution) به عنوان اطلاعات پیشین استفاده کرده و با استفاده از قضیه بیز تابع پسین به روزآوری شود. در اینجا بهتر است ابتدا نگاهی به قضیه یا قانون بیز شود:

قضیه بیز برای دو پیشامد و براساس احتمال شرطی آن‌ها، به صورت زیر (رابطه ۵) نوشته می‌شود:

$$p(M) \times \frac{p(data|M)}{p(data)} = p(M|data) \quad (5)$$

که در این رابطه $p(M)$ نشان‌دهنده احتمالات قبلی است، که احتمالات نسبی فرضیه‌ها را قبل از در نظر گرفتن هرگونه داده منعکس می‌کند، $\frac{p(data|M)}{p(data)}$ خود فاکتور بیزین است، که شواهد ارائه شده توسط داده‌ها را نشان می‌دهد و $p(M|data)$ احتمالات پسین است، که احتمالات نسبی فرضیه‌ها را پس از در نظر گرفتن داده‌ها نشان می‌دهد.

در رگرسیون خطی بیز، فاکتور بیزین، می‌تواند از ۰ تا بی‌نهایت متغیر باشد، که ۰ نشان‌دهنده عدم پذیرش و بی‌نهایت نشان‌دهنده پذیرش قطعی برای یک فرضیه در مقابل فرضیه دیگر است. تفسیر مقادیر خاص شاخص بیز می‌تواند متفاوت باشد، اما دستورالعمل‌های پذیرفته شده به طور کلی به این نکته اشاره می‌کنند که مقادیر بین ۱ و ۳ نشان‌دهنده شواهد تصادفی؛ مقادیر بین ۳ و ۱۰ نشان‌دهنده شواهد متوسط؛ و مقادیر بیشتر از ۱۰ نشان‌دهنده شواهد قوی برای فرضیه مورد نظر هستند (Bergh et al., 2021).

در ادامه می‌توان گفت که در رگرسیون خطی بیز، بهترین مدل یا الگو، مدلی است که نسبت به مدل صفر (یا همان مدل پایه که شامل هیچ پیش‌بینی‌کننده‌ای به جز عرض مبدأ نیست) به بهترین شکل تعادل بین برازش و پیچیدگی را حفظ می‌کند، که اغلب توسط بالاترین احتمال پسین یا کمترین فاکتور بیزین هنگام مقایسه با سایر مدل‌ها تعیین می‌شود. این شامل در نظر گرفتن احتمال داده‌ها با توجه به مدل و باورهای قلی در مورد پارامترهای مدل است. لازم به ذکر است که در این مطالعه الگویی متنبهره‌ای پیش‌بینی کننده دیجیتال سیالاب به کمک رگرسیون خطی بیزین در محیط JASP V0.16.3.0 (Jeffreys's Amazing Statistics Program) انجام گرفت.

پیش‌بینی دیجیتال سیالابی به کمک شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN)، سیستم‌ها و روش‌های محاسباتی مدرن برای یادگیری ماشین، نمایش دانش و در نهایت به کارگیری دانش به دست آمده برای پیش‌بینی پاسخ‌های خروجی سیستم‌های پیچیده هستند. ایده اصلی چنین شبکه‌هایی تا حدودی الهام گرفته شده از نحوه عملکرد سیستم عصبی بیولوژیکی برای پردازش داده‌ها و اطلاعات بهمنظور یادگیری و ایجاد دانش است (Falah et al., 2022). عنصر کلیدی این ایده ایجاد ساختارهای جدید برای سیستم پردازش اطلاعات است.

این سیستم از تعداد زیادی عنصر پردازشی بسیار به هم پیوسته به نام نورون‌ها تشکیل شده است، این نورون‌ها با اتصالات وزن دار بهم متصل شده‌اند. هر نورون مجموع وزنی سینگل‌های ورودی را با استفاده از یک تابع غیرخطی به نام تابع تحریک، به سینگل خروجی تبدیل می‌کند. پرکاربردترین نوع شبکه عصبی مصنوعی، شبکه‌های پیش‌رو هستند که در آن‌ها تعداد نورون‌ها و لايه‌های پنهان با سعی و خطا به دست می‌آید (Anuar et al., 2019). در این پژوهش، مدل‌سازی به کمک شبکه عصبی مصنوعی در محیط نرم‌افزار R MATLAB b 2018 صورت گرفت. در ادامه تعیین تعداد نورون‌ها بهمنظور مدل‌سازی بهطور تجربی و با کمک آزمون خط انجام شد. در مطالعه حاضر، برای اجرای مدل‌سازی بهمنظور پیش‌بینی دیجیتال سیالابی از شبکه پس انتشار با معماری پیشخور و توابع انتقال تانژانت سیگموئید (Tansig) و لگاریتم سیگموئید (Logsig) و الگوریتم آموزش لونبرگ-مارکوارت (LM) استفاده شد. دلیل استفاده از این الگوریتم، سرعت و کارایی بالا در مواجه با حجم زیاد داده‌های ورودی است.

¹- Bayesian linear regression

²- Artificial Neural Networks

ارزیابی مدل‌ها

در این تحقیق، به منظور ارزیابی و مقایسه کارایی مدل‌های اجرا شده شبکه عصبی مصنوعی و شناسایی بهترین الگو برای پیش‌بینی دبی سیلابی در منطقه مورد مطالعه از معیارهای آماری جذر میانگین مربعات خطأ، ضریب تبیین و ضریب نش-ساتکلیف طبق رابطه‌های ۶ تا ۸ استفاده شده است:

$$R^2 = \left[\frac{\sum_{i=1}^n (Q_i - \bar{Q})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^n (Q_i - \bar{Q})^2} \sqrt{\sum_{i=1}^n (S_i - \bar{S})^2}} \right]^2 \quad (6)$$

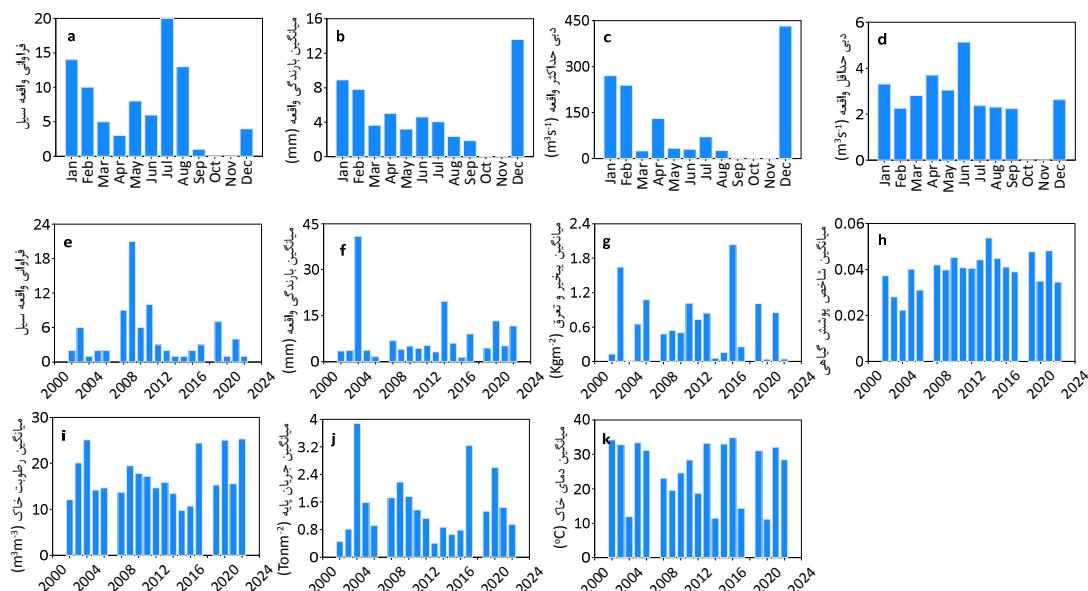
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i - \bar{Q})^2} \quad (7)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_i - S_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \quad (8)$$

هرچه مقدار R^2 به سمت یک نزدیک‌تر باشد، نشان‌دهنده این است که بین داده‌های مشاهداتی و داده‌های پیش‌بینی شده همبستگی بالاتری برقرار بوده و هرچه مقدار $RMSE$ مربوط به نتایج مدل‌ها کم‌تر باشد نشان‌دهنده خطا کم‌تر آن مدل در مقایسه با سایر مدل‌ها است. در مطالعات مقادیر NSE بین صفر تا ۱ در نظر گرفته می‌شود که هرچه این مقدار به صفر نزدیک‌تر باشد نشان‌دهنده کارآیی ضعیف مدل پیش‌بینی کننده است و هرچه این ضریب به سمت یک نزدیک‌تر باشد، نشان‌دهنده کارآیی خوب مدل پیش‌بینی کننده است (فرخناکیان و همکاران، ۱۴۰۲). در این روابط Q_i و S_i به ترتیب نشان‌دهنده دبی سیلابی مشاهداتی و محاسبه‌ای، \bar{Q} و \bar{S} به ترتیب نشان‌دهنده میانگین دبی سیلابی مشاهداتی و محاسبه‌ای و n تعداد داده‌ها است.

نتایج و بحث

نتایج نشان داد ۲۴ درصد سیلاب‌ها در ماه‌های سرد سال (زانویه-فوریه) رخ داده است که علت آن را می‌توان به بارش‌های فصل سرد و بارش‌های شدیدی که طغیان رودخانه‌های فصلی و جاری شدن سیلاب در این استان را به همراه دارد، نسبت داد که این یافته با نتایج نگارش و همکاران (۱۳۹۲) همسو است. همچنین ۳۳ درصد سیلاب‌ها هم در ماه‌های گرم سال (جولای-اکوست) رخ داده است که در ارتباط با بارش‌های موسمی تابستانه (Gassabi et al., 2023) است (شکل ۲ a تا d).



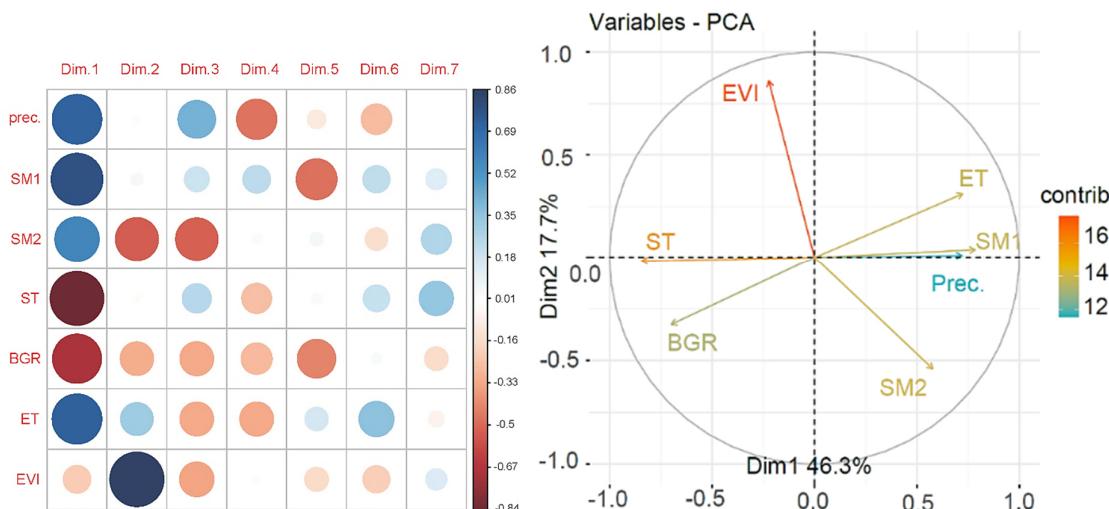
شکل ۲- فراوانی ماهانه و سالانه وقایع سیل (a و e)، میانگین تغییرات ماهانه بارندگی (b)، دبی حداکثر (c)، دبی حداقل (d) و سالانه بارندگی (f)، تبخیر و تعرق (g)، شاخص بوشش گیاهی (h)، رطوبت خاک (i)، جریان پایه (j)، دمای خاک (k)، شاخص گیاهی (h)، شاخص گیاهی (h)، شاخص گیاهی (h)

Figure 2- Monthly and annual frequency of flood events (a and e), average monthly rainfall changes (b), maximum discharge (c), minimum discharge (d) and annual rainfall (f), evaporation and transpiration (g), vegetation index (h), soil moisture (i), base current (j), soil temperature (k)

در طول دوره آماری، تبخیر و تعرق، جریان آب پایه، رطوبت خاک و دمای خاک در مقایسه با پوشش گیاهی تغییرات بیشتری داشتند. سیالاب‌هایی ماههای سرد (گرم) سال با بیشترین (کمترین) بیشترین (بیشترین) میزان رطوبت و دمای خاک همراه بودند و میزان تبخیر و تعرق هم نسبت به ماههای گرم (سرد) سال کمتر (بیشتر) است. همچنین مقدار جریان آب پایه هم در فصول سرد سال بیشتر بود (شکل ۲f تا k). ۵۵ درصد از رخدادهای ثبت شده در فاصله سال‌های ۲۰۰۸-۲۰۱۱ است، مصادف با سال‌هایی است که در آن‌ها رطوبت خاک، جریان آب پایه و دمای سطح خاک تقریباً تغییرات اندکی داشتند و در سایر وقایع این موارد تغییرات بیشتری داشتند. در سال‌های ۲۰۱۹ و ۲۰۰۳ بهترتبی ۶ و ۷ مورد سیل رخ داده است، در این وقایع دمای سطح خاک در مقایسه با سال‌های قبل و بعد از آن بالاتر بود و رطوبت خاک و جریان آب پایه کمتر بوده است در حالی که درصد پوشش گیاهی در هر دو سال بیشتر بود. بیشترین دبی سیل ثبت شده مربوط به ماه دسامبر ۲۰۰۴ و ۴۳۲ مترمکعب بر ثانیه بود (شکل e2).

تجزیه و تحلیل مؤلفه‌های اصلی

برای انجام تجزیه و تحلیل مؤلفه اساسی ابتداء مقدار KMO برای داده‌های محاسبه شد، مقدار KMO برای داده‌های این مطالعه ۰/۷۳۲ به دست آمد که نشان‌دهنده این موضوع است که همبستگی‌های موجود در بین داده‌ها برای تحلیل مؤلفه‌های اصلی مناسب خواهند بود. مقادیر ارزش ویژه (Eigen value) برای تعیین تعداد مؤلفه‌های مورد قبول در تحلیل مؤلفه‌های اصلی کاربرد دارد. براساس معیار Kaiser مولفه‌هایی که مقدار آن بالاتر از یک بود انتخاب شدند.



شکل ۳- درصد مشارکت آنها در مؤلفه‌های اول و دوم (چپ) و Heat Map (راحت) همبستگی بین مؤلفه‌ها

Figure 3- The percentage of their participation in the first and second components (left) and Heat Map of the correlation between the components (right)

ارزش ویژه در واقع کل واریانسی را که هر مؤلفه تبیین می‌کند را ارایه می‌دهد. نتایج نشان داد که مؤلفه‌های اول و دوم (با مقادیر ارزش ویژه ۳/۲۴ و ۱۲۳/۶۳/۹) درصد تغییرات داده‌ها را توصیف می‌کند. مؤلفه اول (Dim1) ۴۶٪ درصد و مؤلفه دوم (Dim2) در حدود ۱۷٪ درصد داده‌ها را توصیف می‌کند. مقدار ارزش ویژه مؤلفه سوم کمتر از ۱ حاصل شد (۰/۸۹)، عموماً در تحلیل مؤلفه‌های اصلی انتخاب مؤلفه‌های اساسی باید ۶۰ درصد واریانس داده‌ها را توجیه نماید (شکل ۳).

مؤلفه اول: در این مؤلفه، متغیرهای دمای خاک، رطوبت خاک در سطح اول (SM1)، تبخیر و تعرق (ET) و بارش (Prec.) بیشترین مشارکت (Contribution) به مقدار ۱۶/۱، ۱۹/۳۱/۹ و ۱۶/۱ و ۱۶ درصد را بهترتبی دارند. بعد از این پارامترها، متغیر جریان آب پایه (BGR) و رطوبت خاک در سطح دوم (SM2) بیشترین مشارکت را در این مؤلفه دارند (۱۵ و ۱۰/۰ درصد). شکل ۳ درصد مشارکت هر یک از آن‌ها در مؤلفه اول را نشان می‌دهد. رابطه منفی دمای سطح خاک با این مؤلفه را این‌گونه می‌توان توجیه کرد که در زمان‌های وقوع سیل به خاطر وجود رطوبت و همچنین وجود آب‌های زیرزمینی (جریان آب پایه)، کمتر است و یا در فصل سرد رخ می‌دهند. همچنین باید اضافه نمود که همبستگی معنی‌دار قوی بارش و رطوبت خاک در سطح اول با این مؤلفه نشان می‌دهد که در زمان‌هایی که در آستانه‌های خود بالاتر هستند، احتمال وقوع سیل بالاتر است. بنابراین، عوامل بارش، رطوبت خاک در سطح اول، دمای خاک و تبخیر و تعرق در این مؤلفه نقش مهمی در دبی سیالابی منطقه موردمطالعه دارند (شکل ۳). قابل ذکر است که در این مؤلفه شاخص پوشش گیاهی (EVI) تنها با ۱/۵ درصد، حداقل دخالت را دارد. دمای خاک و تبخیر و تعرق همبستگی معنی‌دار قوی منفی با این مؤلفه دارند. این در حالی است که دو پارامتر رطوبت خاک در سطح اول و بارش

همبستگی معنی‌دار قوی مثبت دارند ($p=0.00$) (شکل ۳). با توجه به موارد اشاره شده در بالا به نظر می‌رسد که رطوبت پیشین خاک نقش مهمی را در تولید سیلاب در منطقه بازی می‌کند.

مؤلفه دوم: بر خلاف مولفه اول، مولفه دوم تقریباً ۱۷/۷ درصد تغییرات داده‌ها را معرفی می‌کند و شاخص پوشش گیاهی حداکثر مشارکت (درصد) را در این مولفه به خود اختصاص داده است. البته نباید از مشارکت ۲۳ درصدی رطوبت خاک در سطح دوم در این مولفه چشم پوشی کرد. همبستگی معنی‌دار ($p<0.05$) شاخص پوشش گیاهی و رطوبت سطح دوم خاک با مولفه دوم بهترتبیب بسیار قوی مثبت و نسبتاً قوی منفی است (شکل ۳). با توجه به موارد ذکر شده می‌توان گفت این مولفه نماینده پوشش گیاهی منطقه موردمطالعه است. یعنی زمانی که پوشش گیاهی، درصد مناسبی از سطح منطقه را پوشش داده باشد، دبی سیلاب کاهش خواهد یافت. لذا در این مولفه شاخص پوشش گیاهی (EVI) نقش مهمی در دبی سیلابی منطقه موردمطالعه دارد. شکل ۳ درصد مشارکت هر یک از پارامترها را در مولفه دوم نشان می‌دهد. با توجه به همبستگی منفی و معنی‌دار رطوبت خاک در سطح دوم با این مولفه می‌توان گفت که افزایش رطوبت خاک در سطح دوم اثر کنترل کنندگی پوشش گیاهی را در وقوع سیل کاهش می‌دهد.

همچنین باید اضافه نمود که همبستگی معنی‌دار ($p=0.00$) قوی بارش و رطوبت خاک در سطح اول با این مولفه نشان می‌دهد که در زمان‌های که این دو پارامتر از آستانه‌های خود بالاتر هستند، احتمال وقوع سیل بالاتر است. بنابراین، عوامل بارش، رطوبت خاک در سطح اول، دمای خاک و تبخیر و تعرق در این مولفه نقش مهمی در دبی سیلابی منطقه موردمطالعه دارند (شکل ۳).

با توجه به این که ارزش ویژه مولفه سوم کمتر از یک بود، جز مولفه‌های اصلی در نظر گرفته نشد. این موضوع نشان می‌دهد برای درک بهتر وقوع سیلاب در منطقه، عوامل دیگری غیر از عوامل اشاره شده در بالا مانند اثرات فعالیت‌های انسانی (شیوه‌های کشاورزی، تبدیل کاربری و رعایت حریم و ستر و رودخانه‌ها) نیز در تحلیل مولفه‌های اصلی باید در نظر گرفته شود. البته نباید از احتمال اینکه شاخص EVI، شاخص مناسبی برای توصیف وضعیت پوشش گیاهی سطح منطقه نباشد، صرف‌نظر کرد. بالاخره نباید فراموش کرد که دبی‌های سیلابی در مناطق خشک ضریب تغییرات بسیار بالایی دارند. همبستگی امتیازات مولفه‌ها نشان داد که مولفه اول همبستگی مثبت نسبتاً قوی معنی‌داری با دبی وقایع سیلابی در سطح ۹۹ درصد دارد، لذا می‌توان این را مولفه نماینده دبی سیلابی دانست. مولفه دوم هم همبستگی متوسط و منفی معنی‌داری در سطح ۹۵ درصد با دبی وقایع سیلابی داشت (جدول ۲). با توجه به این که پوشش گیاهی بیشترین مشارکت و بالاترین همبستگی مثبت و معنی‌داری را با این مولفه داشت می‌توان استنباط اثر کنترل کنندگی پوشش گیاهی در وقوع سیل را که در بالا به آن پرداخته شده را توجیه کرد.

جدول ۲- جدول همبستگی امتیازات مولفه اساسی با دبی

Table 2- Correlation table of basic component scores with flow rate

| نام متغیر | مولفه اول | مولفه دوم | دبی سیلابی |
|------------|-----------|-----------|------------|
| مولفه اول | 1 | | |
| مولفه دوم | | 4.7E-11 | |
| دبی سیلابی | | 0.583*** | -0.346** |

* $p < .05$, ** $p < .01$, *** $p < .001$

به طور کلی در بین عوامل مولفه اول، بارش، رطوبت خاک در سطح اول، دمای خاک، تبخیر و تعرق و در بین عوامل مولفه دوم، پوشش گیاهی (EVI) نقش مهمی در پیش‌بینی دبی سیلابی در منطقه موردمطالعه دارند. تحقیق (Rostami et al., 2022) خزایی و همکاران، (۱۳۹۵) همسو با این پژوهش نشان داد که رطوبت خاک (در سطح اول)، دمای خاک و پوشش گیاهی بر پیش‌بینی دبی تأثیرگذار بوده است. همچنین نتایج تحلیل مولفه اساسی (خزایی و همکاران، ۱۳۹۵) در تعیین پارامترهای پیش‌بینی کننده دبی، نشان داد که تبخیر و تعرق می‌تواند یکی از عوامل پیش‌بینی کننده دبی باشد. به علاوه نتایج تحقیق حاضر نشان داد که آب پایه نسبت به سایر عوامل تأثیر کمتری در مقایسه با سایر عوامل کلیدی در پیش‌بینی دبی جریان دارد که این نتیجه با نتایج (Rostami et al., 2022) هم خوانی ندارد. همچنین (Soltani et al., 2021) به این نتیجه رسیدند که پوشش گیاهی یکی از عوامل پیش‌بینی کننده دبی جریان است که با نتایج این تحقیق هم خوانی دارد. بالاخره نتایج (Fu-wei et al., 2022) رضایی، (۱۳۹۳) نشان داد تحلیل مولفه‌های اصلی یکی از روش‌های مناسب برای تعیین عوامل موثر در پیش‌بینی دبی جریان است، خروجی تحقیق آن‌ها همانند تحقیق حاضر نشان داد که بارندگی در پیش‌بینی دبی سیلابی موثر است.

رگرسیون خطی بیزین

به منظور بررسی ارتباط بین متغیرهای پیش‌بینی کننده و دبی سیلاب ایستگاه پیردان (به عنوان معرف خروجی حوضه) از روش رگرسیون خطی بیزین استفاده شد. این روش یک روش استنتاج آماری است که ویژگی اصلی آن استفاده از توزیع‌های احتمال برای توصیف عدم قطعیت همه مجھولات از جمله پارامترهای مدل است، با این فرض که هیچ روندی در متغیرها وجود ندارد و تعامل بین آن‌ها نیز قابل اغماض است.

در روش رگرسیون خطی بیزین، برای انتخاب بهترین الگو، مدل‌های با احتمال پسین بالاتر (نسبت به احتمال پیشین) و یا به عبارتی مدل‌هایی که فاکتور مشارکت ($BF_{inclusion}$) بالاتری نسبت به مدل‌های دیگر نشان می‌دادند در نظر گرفته شده و با حذف ضرایبی که این احتمال را کاهش می‌دهند مدل بهینه در مقایسه با بهترین مدل برای الگوهای ورودی به شکه عصبی انتخاب می‌شود.

مقدار فاکتور بیزین برای مشارکت عامل بارش (جدول ۳) نسبت به سایر عوامل بسیار زیاد بود. این موضوع نشان دهنده این است که دلالت عامل بارش در الگوها برای پیش‌بینی دبی سیلابی در منطقه موردمطالعه کاملاً ضروری است. در این بین عامل رطوبت خاک (در سطح اول)، شاخص پوشش گیاهی (EVI) و دمای خاک بهترتبه با مقدار $0/49$ ، $0/33$ و $0/26$ بیشترین سهم مشارکت را در پیش‌بینی دبی سیلابی دارند. در این بین پارامترهای تبخر و تعرق، آب پایه و رطوبت خاک در سطح دوم بهترتبه با مقدار $0/14$ ، $0/13$ و $0/10$ کمترین میزان مشارکت را در برآورد دبی سیلابی را دارند (جدول ۳).

از آن جاکه در روش رگرسیون خطی بیزین، هدف این است که به مدلی برسیم که با اضافه نمودن پارامترهای دیگر بتوان دقت پیش‌بینی را افزایش داد، بنابراین در این مطالعه سعی شد که عوامل که می‌توان در کنار عامل بارش به کار بست را معرفی نمود. در رگرسیون بیزین برای گنجاندن یک متغیر پیش‌بینی کننده خاص، از مدل‌هایی که آن پیش‌بینی کننده را در خود دارند، میانگین گیری می‌شود. به عنوان مثال احتمال قبلی گنجاندن متغیر رطوبت خاک در سطح اول در مدل $0/5$ است. به طور مشابه، احتمال قبلی گنجاندن بارش هم $0/5$ است. پس از مشاهده یا ورود متغیرها در مدل، این احتمالات قبلی به احتمالات پسین بهروز می‌شوند یا تبدیل می‌شوند و احتمال بعدی گنجاندن بارش به 1 افزایش می‌یابد. این عدد از جمع احتمالات بعدی برای مدل‌هایی که بارش را در بر دارند بدست می‌آید. یا به عبارتی احتمال بعدی حذف متغیر بارش خیلی ناچیز و یا $10^{-13} \times 1/55$ است. جدول ۳ احتمال پسین مشارکت سایر عامل‌ها را نشان داده است. پس از عامل بارش، رطوبت خاک در سطح اول، شاخص پوشش گیاهی (EVI) و دمای خاک بیشترین مشارکت را دارند. احتمال حذف عامل‌های رطوبت خاک در سطح اول و دمای خاک به ترتیب $0/671$ و $0/794$ به دست آمد که در مقایسه با عامل‌های دیگر کمتر است اما در مقایسه با بارش بسیار بیشتر هستند (جدول ۳).

جدول ۳- خلاصه ضرایب پسین رگرسیون بیزین
Table 3- Summary of posterior coefficients of Bayesian regression

| نام متغیر | احتمال پیشین عدم مشارکت | عرض از مبدأ (Intercept) |
|-----------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|
| Prec. | 6.472×10^{12} | 1.549×10^{-13} | 1.000 | 0.500 | 0.500 | 1.851 |
| SM1 | 0.491 | 0.671 | 0.329 | 0.500 | 0.500 | 2.104 |
| SM2 | 0.105 | 0.905 | 0.095 | 0.500 | 0.500 | 0.258 |
| ST | 0.259 | 0.794 | 0.206 | 0.500 | 0.500 | 1.114 |
| ET | 0.145 | 0.874 | 0.126 | 0.500 | 0.500 | 8.279 |
| BGR | 0.129 | 0.886 | 0.114 | 0.500 | 0.500 | 0.006 |
| EVI | 0.326 | 0.754 | 0.246 | 0.500 | 0.500 | 14.796 |

به منظور الگوسازی در این روش، توزیع احتمال پیشین مدل‌ها با بهترین مدل و با استفاده از ضریب BF_{10} مقایسه شد. طبق جدول ۴ مقایسه فاکتور BF_{10} در بین الگوها نشان داد که چهار مدل اول نسبت به سایر مدل‌ها عملکرد بهتری در پیش‌بینی دبی سیلابی دارند. از آن‌جاکه، فاکتوری است که شانس (نسبت احتمال دو مدل) ارجحیت مدل را بعد از افزودن پارامترها به مدل افزایش می‌دهد می‌توان گفت که با اضافه شدن متغیر بارش شانس ارجحیت مدل با فاکتور $0/78$ به عنوان بهترین مدل افزایش می‌یابد. در ادامه مدل‌های دوم و سوم بهترتبه با اضافه کردن رطوبت خاک در سطح اول و عامل پوشش گیاهی به بارش و مدل چهارم با اضافه شدن متغیرهای دمای خاک و رطوبت خاک در سطح اول به بارش شانس ارجحیت الگوهای ورودی را با فاکتورهای $0/17/59$ ، $0/18/05$ و $0/19/05$ در مقایسه با مدل صفر افزایش می‌دهد.

به طور کلی مقایسه ضرایب تبیین (R^2) نشان می‌دهد که مدل‌های دوم، سوم و چهارم در برابر مدل اول می‌توانند به ترتیب $0/43$ ، $0/27$ و $0/4$ درصد بیشتر تغییرات دبی سیل را پیش‌بینی نمایند. از این موضوع این‌گونه می‌توان استنتاج کرد که بارش به طور واضح پیش‌بینی کننده دبی سیلاب است اما اضافه کردن عوامل دیگری همچون دمای خاک، رطوبت خاک در سطح اول و پوشش گیاهی به ورودی‌های شکه عصبی می‌تواند باعث بهبود پیش‌بینی دبی سیلابی شود که این موضوع با نتایج (G. Cruz et al., 2018, Jahangir et al., 2019) همخوانی دارد.

۱- Bayes Factor of 10

جدول ۴- مقایسه مدل‌های رگرسیون خطی بیزین با مدل صفر

Table 4- Comparison of Bayesian regression models against null model

| الگو | مدل | احتمال پیشین مدل | احتمال پسین مدل | فاکتور بیزین (BFM) | ضریب تبیین (BF ₁₀) | فاکتور کفاایت |
|------|-------------------|------------------|-------------------------|-------------------------|--------------------------------|---------------|
| - | (Null model) | 0.125 | 1.496×10^{-16} | 1.047×10^{-15} | 1.000 | 0.000 |
| 1 | Prec. | 0.018 | 0.420 | 39.779 | $1.964 \times 10^{+16}$ | 0.633 |
| 2 | SM1 + Prec. | 0.006 | 0.098 | 18.051 | $1.370 \times 10^{+16}$ | 0.650 |
| 3 | EVI + Prec. | 0.006 | 0.095 | 17.592 | $1.338 \times 10^{+16}$ | 0.650 |
| 4 | ST + SM1 + Prec. | 0.004 | 0.064 | 19.050 | $1.496 \times 10^{+16}$ | 0.669 |
| 5 | ET + Prec. | 0.006 | 0.027 | 4.685 | $3.831 \times 10^{+15}$ | 0.638 |
| 6 | EVI + SM1 + Prec. | 0.004 | 0.020 | 5.752 | $4.727 \times 10^{+15}$ | 0.659 |
| 7 | ST + Prec. | 0.006 | 0.020 | 3.341 | $2.754 \times 10^{+15}$ | 0.635 |

* مدل صفر (null model) مدلی است که تنها ورودی آن عرض از مبدأ است.

پیش‌بینی دبی و قایع سیلابی به کمک شبکه عصبی مصنوعی

چهار الگوی بهینه که توسط رگرسیون بیزین حاصل شد برای مدل‌سازی دبی و قایع سیلابی با استفاده از شبکه عصبی مصنوعی به کار گرفته شد (جدول ۳). درصد داده‌ها برای آموزش و ۲۰ درصد باقی‌مانده برای آزمون انتخاب شدند. برای اجرای بهینه‌ترین ساختار شبکه عصبی مصنوعی، از توابع انتقال لاغ سیگموئید و تانژانت سیگموئید با الگوریتم آموزش لونبرگ-مارکوارت با استفاده از شبکه پس‌انتشار با معماری پیشخور استفاده شد. در مدل شبکه عصبی مصنوعی، برای تعیین تعداد مناسب لایه‌های پنهان و تعداد نرون‌ها از آزمون و خطا استفاده شد، این روند تا زمانی ادامه پیدا نمود که بهبودی در مقادیر R^2 و RMSE مشاهده نشد.

پس از بررسی الگوهای ورودی با توابع مذکور، بهترین الگو براساس آماره‌های جذر میانگین مربعات خطأ (RMSE)، ضریب تبیین (R^2) و ضریب کارآیی نش - ساتکلیف (NSE) برای پیش‌بینی دبی و قایع سیلابی در حوزه آبخیز موردمطالعه تعیین شد. توابع انتقالی، توابع آموزش و بهترین ترکیب در مدل‌سازی شبکه عصبی مصنوعی به همراه آماره‌های R^2 ، RMSE و NSE برای مقایسه کارآیی الگوها در جدول (۶) ارائه شده است. نتایج نشان داد که الگوی چهارم با تابع انتقال لگاریتم سیگموئید و تابع آموزش لونبرگ-مارکوارت با تعداد ۳ لایه و ۶ نرون ارائه شده است. نتایج نشان داد که الگوی چهارم با تابع انتقال لگاریتم سیگموئید و تابع آموزش لونبرگ-مارکوارت با تعداد ۳ لایه و ۶ نرون با $NSE = 0.9$ ، $RMSE = 0.89$ ، $R^2 = 0.83$ و $NSE = 0.75$ در مرحله آموزش و با $NSE = 0.83$ ، $RMSE = 0.86$ در مرحله آزمون به عنوان بهترین ترکیب پیش‌بینی کننده دبی و قایع سیلابی در منطقه موردمطالعه است. همچنین الگوی سوم با تابع انتقال لگاریتم سیگموئید و تابع آموزش لونبرگ-مارکوارت با تعداد ۲ لایه و ۴ نرون با $NSE = 0.88$ ، $RMSE = 0.77$ و $R^2 = 0.72$ در مرحله آموزش و $NSE = 0.72$ ، $RMSE = 0.74$ در مرحله آزمون کمترین کارآیی را در بین تمامی الگوها داشت (جدول ۵).

همان‌طور که در شکل (۴) مشخص است تطابق منحنی دبی‌های محاسباتی الگوی چهارم با منحنی دبی‌های مشاهداتی پیش‌تر از سایر الگوها است. این شکل نشان می‌دهد که الگوی چهارم نسبت به سایر الگوها توانایی پیش‌تری در تخمین دبی‌های سیلابی با دوره بازگشت بالاتر را داشته است. در مقابل الگوی اول، نسبت به سایر الگوها در برآورد دبی‌های سیلابی با دوره بازگشت پایین‌تر به خصوص در قایعی سیلابی که در بازه سال‌هایی که با خشکسالی رو به رو بوده‌اند نسبت به وقایعی که در دوره ترسالی اتفاق افتاده است، کارآیی بهتری از خود نشان می‌دهد که این موضوع می‌تواند موید این باشد که در منطقه موردمطالعه در موقعی که با ترسالی رو به رو هستیم، وقوع سیلاب‌ها، می‌تواند به عواملی دیگری به‌غیر از بارش بستگی داشته باشد. در الگوی سوم مشاهده می‌شود که برای برخی از مقادیر حداقلی دبی، مقادیر کمتر از صفر را پیش‌بینی نموده است که به لحاظ فیزیکی این امر غیرممکن بوده و نشان از خطای زیاد مدل در برآورد دبی سیلابی توسط این الگو بوده است (شکل ۴). همچنین باید اشاره کرد که الگوی دوم و چهارم هر دو ضریب تبیین بالاتری را نسبت به دو الگوی دیگر نشان دادند. الگوی چهارم به‌دلیل حضور متغیر دمای خاک دقت بالاتری را در تعیین دبی جریان سیلابی نسبت به الگوی دوم نشان داد (شکل ۴ و جدول ۵). نتایج شبکه عصبی مصنوعی نشان داد که دبی در هر روز به مجموع بارندگی همان روز و روز قبل، رطوبت خاک (در سطح اول) روز قبل و دمای خاک در روز قبل بستگی دارد.

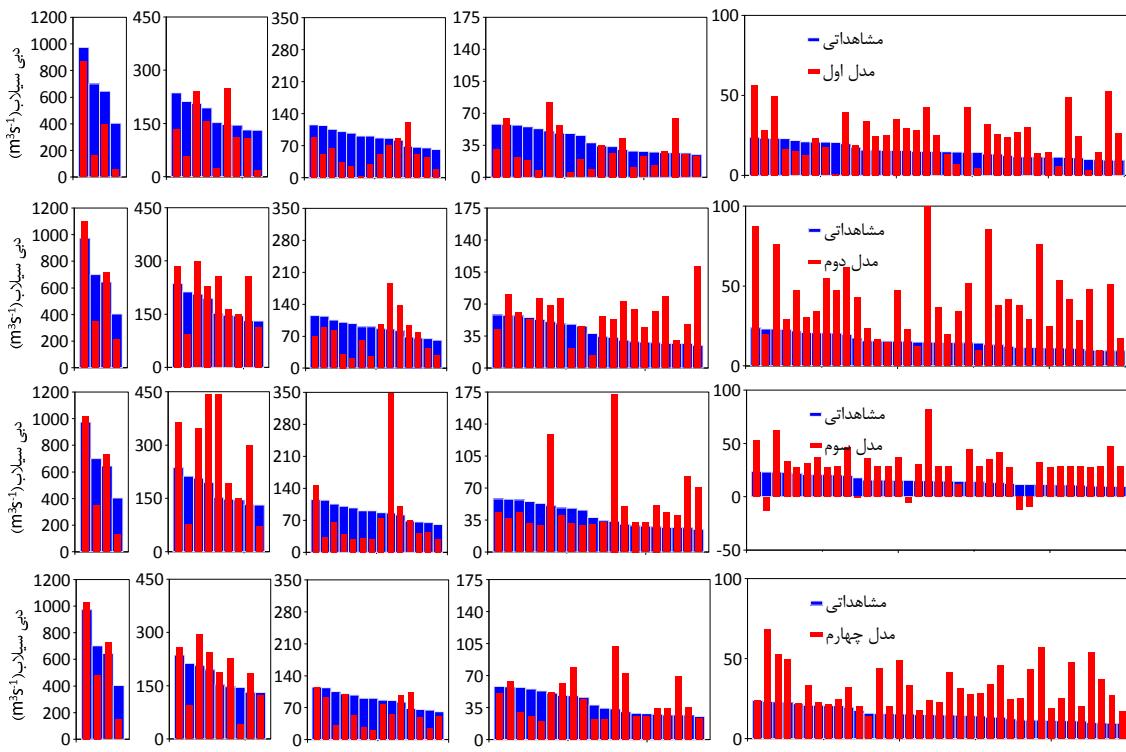
جدول ۵- نتایج مدل‌سازی به کمک شبکه عصبی مصنوعی با چهار الگوی ورودی
Table 5- Modeling results using artificial neural network with four input patterns

| آزمون | | | | | | آموزش | | بهترین ترکیب | | تابع آموزش | تابع انتقال | الگو |
|-------|---------|----------------|-------|--------|----------------|---------------------|---------------|-----------------|------------------|------------|-------------|------|
| NSE | RMSE | R ² | NSE | RMSE | R ² | تعداد لایه‌های مخفی | تعداد نرون‌ها | تابع آموزش | تابع انتقال | الگو | | |
| 0.655 | 122.620 | 0.526 | 0.854 | 61.089 | 0.822 | 3 | 2 | لونبرگ-مارکوارت | لگاریتم سیگموئید | 1 | | |
| 0.597 | 130.425 | 0.433 | 0.803 | 74.273 | 0.682 | 2 | 2 | | | | | |
| 0.736 | 105.201 | 0.738 | 0.865 | 58.810 | 0.849 | 3 | 3 | لونبرگ-مارکوارت | لگاریتم سیگموئید | 2 | | |
| 0.672 | 112.427 | 0.682 | 0.781 | 69.144 | 0.784 | 3 | 3 | | | | | |
| 0.579 | 140.724 | 0.407 | 0.725 | 79.457 | 0.581 | 2 | 4 | لونبرگ-مارکوارت | لگاریتم سیگموئید | 3 | | |
| 0.602 | 131.829 | 0.445 | 0.799 | 71.798 | 0.759 | 2 | 2 | | | | | |
| 0.756 | 86.456 | 0.829 | 0.901 | 50.377 | 0.898 | 3 | 6 | لونبرگ-مارکوارت | لگاریتم سیگموئید | 4 | | |
| 0.738 | 97.526 | 0.751 | 0.868 | 62.753 | 0.821 | 3 | 5 | | | | | |

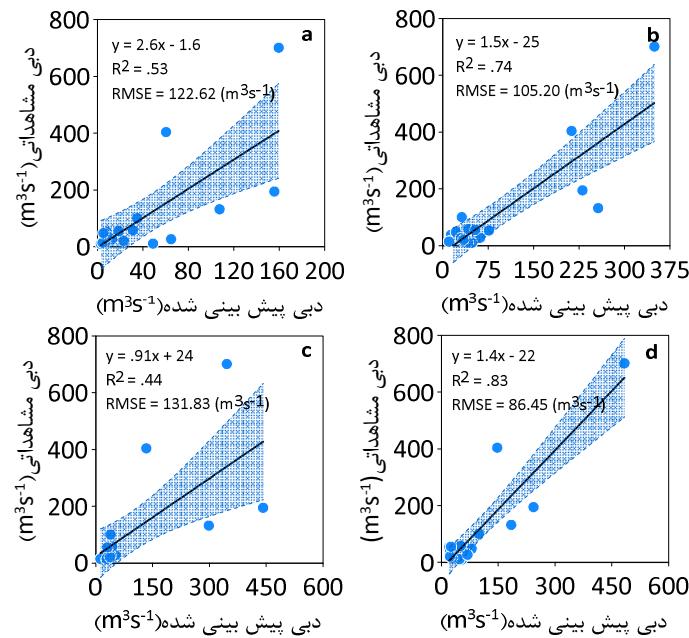
آن‌چه از نتایج برآمده‌اید مدل‌های چهارگانه به‌ویژه در الگوهای دوم و سوم در برآورد وقایع دبی سیلابی کمتر از ۲۵ مترمکعب بر ثانیه به خوبی عمل نمی‌کنند، الگوهای اول و چهارم در این محدوده دبی تا حدودی بهتر از دو الگوی دیگر بودند. در دبی‌های بالاتر از این مقدار الگوی چهارم بهتر از سایر الگوهای عمل کرده است. همان‌طور که در شکل (۴) مشخص است تطابق دبی وقایع محاسباتی با دبی وقایع مشاهداتی در الگوی چهارم بیش‌تر از سایر الگوها است. در الگوی سوم مشاهده می‌شود که برای برخی از مقادیر حداقلی دبی، مقادیر کمتر از صفر پیش‌بینی شده است و نشان از خطای زیاد مدل در برآورد دبی سیلابی توسط این الگو دارد (شکل ۴). الگوی دوم و چهارم هر دو ضریب تبیین بالاتر را نسبت به دو الگوی دیگر نشان دادند. الگوی چهارم به‌دلیل حضور متغیر دمای خاک دقت بالاتری را در تعیین دبی جریان سیلابی نسبت به الگوی دوم نشان داد (شکل ۴ و جدول ۵). در کل نتایج شبکه عصبی مصنوعی نشان داد که دبی در هر روز به مجموع بارندگی همان روز و روز قبل، رطوبت خاک (در سطح اول) روز قبل و دمای خاک در روز قبل بستگی دارد. نتایج مدل‌سازی نشان داد که دبی جریان برای هر روز را می‌توان به صورت زیر تعریف می‌شود:

$Q_t = F(\sum P_{t-1}, \sum SMI_{t-1}, \sum ST_{t-1}, \dots, \sum P_{t-n} + P_{t-(n-1)}, \sum SMI_{t-(n-1)}, \sum ST_{t-(n-1)})$
که در آن Q ، P و ST به ترتیب دبی جریان، بارندگی، رطوبت خاک در سطح اول و دمای خاک هستند. n شماره روز را نشان می‌دهد. همچنین می‌توان اضافه کرد که الگوی چهارم نسبت به سایر الگوهای توانایی بیش‌تری در تخمین دبی وقایع سیلابی با دوره بازگشت بالاتر را دارد.

در مقابل آن الگوی اول، نسبت به سایر الگوها در برآورد دبی‌های سیلابی با دوره بازگشت کوتاه‌تر است. کارآبی بهتری از خود نشان می‌دهد (شکل ۲). اکثر این وقایع سیلابی در بازه سال‌های همزمان با خشکسالی است (شکل ۲)، این موضوع می‌تواند مovid این باشد که در منطقه موردمطالعه در موقعی که با ترسالی روبرو هستیم، وقوع سیلاب‌ها به عواملی دیگری به‌غیر از بارش هم بستگی دارد. باید به این نکته هم اشاره شود که در سال‌های خشکسالی در منطقه که عموماً با سال‌های لانینا همراه است (Barlow et al., 2016) با عبور از سال یا سال‌های لانینا به النینو در کشور و بدخصوص جنوب شرق ایران، احتمال بارش‌های شدید و سیلابی زیاد است (Bahrami et al., 2021). بالاخره نباید فراموش کرد که سال‌های لانینا که عموماً با قوت گرفتن مونسون هند همراه است در منطقه می‌تواند بارش‌های تابستانه را به همراه داشته باشد (Ghassabi et al., 2023). این موضوع نشان می‌دهد که شاخص‌های خشکسالی هم می‌توانند فاکتور مهمی در پیش‌بینی وقایع سیلابی و دبی آن‌ها باشد. چرا که خشکسالی به نوبه خود پوشش گیاهی و رطوبت خاک را به طور مستقیم تحت تأثیر قرار می‌دهد. این تأثیرات می‌تواند به صورت همزمان یا با تأخیر در رطوبت و پوشش گیاهی مشاهده شود که این موارد نیاز به بررسی‌های دقیق‌تری دارد.



شکل ۴- مقایسه گرافیکی الگوهای مدل‌های چهار گانه مدل‌سازی شده و داده‌های مشاهداتی رخداد سیلان در منطقه موردمطالعه
Figure 4- Comparison of the four modeled patterns or models and observational data of flood events in the studied area



شکل ۵- نمودار پراکنش بهترین الگوی ورودی در دوره آزمون با استفاده از مدل شبکه عصبی مصنوعی، الگوی ۱ (a)، الگوی ۲ (b)، الگوی ۳ (c) و الگوی ۴ (d) (باذه اطمینان با رنگ آبی مشخص شده است.)

Figure 5- The distribution diagram of the best input pattern in the test period using the artificial neural network model, pattern 1 (a), pattern 2 (b), pattern 3 (c) and pattern 4 (d) (the confidence interval is marked with blue color)

همان‌طور که در نمودار پراکنش نقطه‌ای در دوره آزمون در الگوی چهارم مشخص است مقدار میانگین پیش‌بینی دی سیلانی به مقدار میانگین پیش‌بینی دی مشاهداتی در فاصله اطمینان ۹۵ درصد نزدیک‌تر است (شکل ۵d) و کارایی بهتری دارد، اما آن‌چه که مشخص است در

سایر الگوها بیشتر نقاط در خارج از فاصله اطمینان ۹۵ درصدی پراکنش دارند (شکل ۵ a, b و c) که حکایت از تفاوت زیادتر مقدار میانگین پیش‌بینی شده دبی سیلابی از دبی میانگین مشاهداتی در مدل برآش شده دارد. الگوهای چهارم و دوم در مقایسه با الگوهای اول و سوم کارآیی بهتری دارند، می‌توان این موضوع را به رفتار بهتر این الگوها در دبی‌های بالاتر از ۲۵ مترمکعب بر ثانیه نسبت داد. همان‌طور که می‌دانیم حضور پوشش گیاهی باعث کاهش جریان و دبی پیک می‌شود (روشن نکو، ۱۳۹۳) این احتمال وجود دارد که حضور پوشش گیاهی در الگوی سوم کارآیی آن را کاهش داده باشد (شکل ۵). حسن استفاده از روش شبکه عصبی مصنوعی این است که تأثیر همزمان چندین عامل را برای پیش‌بینی دبی در هر زمان مورد بررسی قرار می‌دهد این نتیجه با نتایج (Sakiri et al., 2018) همخوانی دارد. همچنین تابع انتقال تائزانت سیگموئید بهترین نتایج را در برآورد دبی جریان داشت، که با نتایج (حلاجیان، ۱۳۹۴) مطابقت دارد. علاوه‌بر این، نتایج تحقیق (روشن و همکاران، ۱۴۰۰؛ اسدی و همکاران، ۱۴۰۱) نشان داد که بارش عضو جدانشدنی از عوامل پیش‌بینی کننده دبی جریان است یعنی هر گونه تغییر در احتمال وقوع بارش می‌تواند بر نتایج مدل تأثیر بگذارد.

نتیجه‌گیری

امروزه بهره‌مندی از روش‌های نوین هوش مصنوعی برای مدل‌سازی فرایندهای هیدرولوژیکی بهمنظور بررسی خصوصیات سیلابها متداول شده است. در این بین پیش‌بینی جریان سیلابی یکی از مؤلفه‌های مهم و تاثیرگذار در سامانه‌های هشدار سیل برای جلوگیری از خسارات احتمالی است. در این تحقیق ابتدا داده‌های مؤلفه‌های احتمالی تاثیرگذار بر روی دبی جریان رودخانه سرباز با استفاده از داده‌های Google Earth Engine استخراج شد. سپس با استفاده از تحلیل مؤلفه اساسی عامل‌های تاثیرگذار بر دبی جریان شناسایی شد. در مرحله بعد با کمک رگرسیون خطی بیزین این عوامل بهصورت الگوهای ورودی به شبکه عصبی مصنوعی تبدیل شده و در نهایت بهترین الگو برای پیش‌بینی دبی‌های سیلابی با استفاده از شبکه عصبی مصنوعی (ANN) به کمک سه معیار R^2 و RMSE و NSE شناسایی شد.

نتایج این تحقیق نشان داد که با استفاده از داده‌های بارندگی، رطوبت سطحی خاک و دمای خاک، با ضریب کارایی ۹۰٪ و ضریب تعیین ۸۹٪ و ریشه میانگین مربعات خطای ۵۰٪ برای مرحله آموزش و ضریب کارایی نش-ساتکلیف ۷۶٪ و ضریب تعیین ۸۳٪ و ریشه میانگین مربعات خطای ۴۶٪ برای مرحله انتبارسنجی می‌تواند دبی سیلابی را با دقت قابل قبولی برآورد نماید. همچنین نتایج این مطالعه نشان داد که استفاده الگوبندی مناسب ورودی‌ها و همچنین ساختار معماری درست باعث بهبود نتایج پیش‌بینی دبی سیلابی جریان با استفاده از داده‌های سنجش از دور و مدل‌های هوش مصنوعی می‌شود.

اگرچه مدل شبکه عصبی مصنوعی عملکرد خوبی در پیش‌بینی رویدادهای جریان سیل از خود نشان داده است، اما نتایج آن با عدم قطعیت زیادی مواجه است. این عدم قطعیت را می‌توان به مقیاس داده‌ها، تفاوت زیاد دبی‌های واقعی سیلابی، فصلی بودن سیل‌ها و حساسیت اکولوژیکی منطقه به تغییرات اقلیمی نسبت داد. بنابراین، برای کاهش عدم قطعیت در پیش‌بینی دبی سیلاب، پیشنهاد می‌شود این تحقیق در مناطقی که از نظر ویژگی‌های اقلیمی و هیدرولوژیکی با منطقه مورد مطالعه متفاوت هستند تکرار و نتایج آن مورد بررسی و آزمون قرار گیرد. به علاوه برای کاهش این عدم قطعیت می‌توان ریزمقیاس‌سازی داده‌ها را هم مدنظر قرار داد از آن جاکه در این پژوهش از میانگین داده‌ها برای کل حوضه استفاده شده است پیشنهاد می‌شود تا برای بهبود نتایج، از داده‌های تجمعی زیرحوضه‌های این حوضه استفاده شود. همچنین جهت افزایش دقت مدل‌سازی، استفاده از سایر روش‌ها و مدل‌های نوین هوش مصنوعی بهمنظور تخمین دبی جریان سیلابی و مقایسه نتایج آن‌ها با پژوهش حاضر و بررسی سایر عوامل تاثیرگذار که در بالا به آن اشاره شده پیشنهاد می‌شود. با توجه به فصلی بودن سیل‌ها می‌توان این مدل‌سازی را در مقیاس فصلی هم انجام داد و به احتمال زیاد نتایج بهتری حاصل خواهد شد. پیشنهاد می‌شود در مطالعات آتی اثرات خشکسالی‌ها و عوامل انسانی (مانند برداشت آب‌های زیرزمینی) بر هم‌زمانی و یا تاخر پوشش گیاهی و رطوبت خاک در رابطه با دبی و قاعی سیلابی مورد بررسی قرار گیرد. در نهایت این انجام این پیشنهادها می‌تواند راهگشای تحقیقات پیش‌تر برای درک آmadگی منطقه در مواجه با شرایط گرم‌تر جهانی باشد. در پایان می‌توان گفت نتایج این تحقیق می‌تواند ابزاری کارآمد در یاری رساندن به مدیران برای پیش‌بینی بهموقع سیلاب و کاهش خسارات ناشی از آن باشد و نتایج آن می‌تواند در طراحی سامانه‌های هشدار سیل مورد بررسی قرار گیرد.

ملاحظات اخلاقی

دسترسی به داده‌ها: داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

حمایت مالی: این تحقیق با حمایت مالی دانشگاه فردوسی مشهد در قالب بخشی از پایان‌نامه کارشناسی ارشد و با کد طرح ۵۹۳۲۰/۳ انجام شده است.

مشارکت نویسنده‌گان: محمدجهانی: مفهوم‌سازی، انجام تحلیل‌های نرم‌افزاری/آماری، نگارش نسخه اولیه مقاله؛ محمدتقی دستورانی: راهنمایی،

ویرایش و بازبینی مقاله، کنترل نتایج؛ علیرضا راشکی: راهنمایی، ویرایش و بازبینی مقاله، کنترل نتایج

تضاد منافع نویسنده‌گان: نویسنده‌گان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافعی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

سپاس گزاری: نویسنده‌گان این مقاله، از کلیه همکاران دانشکده منابع طبیعی و محیط‌زیست دانشگاه فردوسی مشهد که در اجرای این تحقیق همیاری نموده‌اند کمال تشکر و قدردانی را دارند.

منابع

۱. اسدی، هانیه، دستورانی، محمدتقی، و شاهدی، کاکا. (۱۴۰۱). بررسی تأثیر توالی دبی روزانه در پیش‌بینی جریان رودخانه با استفاده از الگوریتم‌های هوشمند (مطالعه موردی: حوزه آبخیز کسیلیان). *جغرافیا و توسعه*, ۲۰(۶۸)، ۱۶۳-۱۸۳. doi: 10.22111/gdij.2022.7007
۲. امینی نیا، کریم، و ثاقبیان، سیدمه‌هدی. (۱۴۰۱). بررسی پارامترهای تاثیرگذار در مدلسازی بارش ماهانه با استفاده از مدل‌های تلفیقی هوشمند مبتنی بر تجزیه سری زمانی. *آبیاری و زهکشی ایران*, ۱۶(۴)، ۸۰۳-۷۸۹. https://idj.aiid.ir/article_155373.html
۳. امینی، ستاره، عزیزیان، اصغر، و داشن کار آراسته، پیمان. (۱۳۹۹). بهبود عملکرد سامانه‌های پیش‌بینی بارش جهانی در اقلیم‌های مختلف ایران با روش تصحیح اربی نگاشت چندک. *تحقیقات آب و خاک ایران*, ۵۱(۹)، ۲۲۹۱-۲۲۷۵. doi: 10.22059/ijswr.2020.302208.668602
۴. آرمش، محسن، علیجانی، بهلول، و دنیادوست، هادی. (۱۳۹۶). تحلیل همیدی سیلان در حوضه آبریز سرباز. *فضای جغرافیایی*, ۵۸(۵)، ۴۹-۷۰. URL: <http://geographical-space.iau-ahar.ac.ir/article-1-1073-fa.html>
۵. بیاتی خطیبی، مريم، ساری صراف، بهروز، و کرمی، فربیبا. (۱۴۰۰). بررسی و برآورد اثرات هیدرولوژیک ناشی از تغییرات کاربری در حوضه اوجان چای (دامنه شرقی کوهستان سهند، شمال غرب ایران). *جغرافیا و توسعه*, ۶۲(۱۹)، ۷۹-۱۰۲. doi: 10.22111/gdij.2021.6004
۶. پاشایی نژاد، مژگان، راشکی، علیرضا و سپهر، عادل. (۱۳۹۴). استفاده از شاخص‌های گیاهی جهت بررسی آسیب‌پذیری استان خراسان رضوی به بیابان زایی، کنفرانس بین المللی محیط زیست و منابع طبیعی، شیراز. <https://civilica.com/doc/551106>
۷. حلاجیان، محسن. (۱۳۹۴). شبیه‌سازی و پیش‌بینی دبی جریان با استفاده از شبکه عصبی مصنوعی، دانشگاه آزاد اسلامی، واحد مرودشت.
۸. خرازی، مجید، شهریور، عبدال، و گوهرگانی، جعفر. (۱۳۹۵). تجزیه و تحلیل مولفه‌های اصلی موثر بر پیش‌بینی دبی جریان رودخانه. هماش ملی علوم و مهندسی آبخیزداری ایران (توسعه مشارکتی در مدیریت حوزه‌های آبخیز). SID. <https://sid.ir/paper/886489/fa>
۹. دامادی، سکینه، دهواری، عبدالحمید، دهمرد قلعه نو، محمدرضا، و ابراهیمیان، محبوبه. (۱۴۰۰). پهنگندی سیلان با استفاده از مدل هیدرولوکی HEC-RAS در رودخانه سرباز استان سیستان و بلوچستان. *مهندسی و مدیریت آبخیز*, ۱۳(۳)، ۵۹۰-۶۰۱. doi: 10.22092/ijwmse.2021.124028.1573
۱۰. دستورانی، محمدتقی، شریفی دارانی، حامد، طالبی، علی، و مقدم نیا، علیرضا. (۱۳۹۰). کارایی شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی-فازی تطبیقی در مدل سازی بارش-رواناب در حوزه آبخیز سد زاینده‌رود. *آب و فاضلاب*, ۲۲(۴)، ۱۱۴-۱۲۵. http://www.wwjournal.ir/article_729_c46bc8e7245f61caad30554a39b2d09b.pdf
۱۱. رحمانی، احمد، بهزادفر، مصطفی، نصیری، اصغر، و حمزه، مسعود. (۱۳۹۸). سیلان و شهرسازی. *طبیعت ایران*, ۴(۴)، ۷۴-۵۹. doi: 10.22092/irn.2019.120100
۱۲. رحمانی، شیما، عزیزیان، اصغر، و صمدی، امیر. (۱۳۹۸). تعیین درجه خطر سیلخیزی حوضه‌های آبریز استان مازندران با استفاده از یک روش توزیعی مبتنی بر GIS. *هیدرولیک*, ۱۴(۱)، ۱۲۳-۱۳۹. doi: 10.30482/jhyd.2019.155838.1342
۱۳. رستمی خاج، محمد، سلاجقه، علی، مقدم نیا، علیرضا، خلیقی سیگارودی، شهرام، و آذرخشی، مريم. (۱۳۹۸). مدل سازی بارش-رواناب مبتنی بر رویکرد پویایی سیستم، مطالعه موردی: حوضه کارده مشهد. *مهندسی و مدیریت آبخیز*, ۱۱(۱)، ۲۷-۱۵. doi: 10.22092/ijwmse.2019.118432
۱۴. رضایی، حامد. (۱۳۹۳). مدلسازی دبی رودخانه به کمک تجزیه و تحلیل مولفه‌های اصلی مطالعه موردی: رودخانه بشار، کنفرانس بین المللی توسعه پایدار، راهکارها و چالش‌ها با محوریت کشاورزی، منابع طبیعی، محیط زیست و گردشگری، تبریز. <https://civilica.com/doc/354920>
۱۵. روشان سیدحسین، شاهدی کاکا، و حبیب نژاد روشن محمود. (۱۴۰۰). مقایسه عملکرد روش‌های هوش مصنوعی ANN و SVM در مدل سازی فرایند بارش-رواناب (مطالعه موردی: حوزه آبخیز کارون شمالی). *علوم آب و خاک*, ۲۵(۲)، ۷۷-۹۰. <http://jstnar.iut.ac.ir/article-1-4016-fa.html>
۱۶. روش نکو، پروین. (۱۳۹۳). اولویت‌بندی حوضه‌های آبریز جهت مدیریت سیلان براساس ویژگی‌های مورفومتری، مطالعه موردی البرز شمالی حوضه آبریز گلنرود. وزارت علوم، تحقیقات و فناوری، دانشگاه مازندران، دانشکده علوم انسانی و اجتماعی
۱۷. زارعی مهدی، زندی رحمان، و ناعمی تبار مهناز. (۱۴۰۱). ارزیابی پتانسیل وقوع سیل با استفاده از مدل‌های داده کاوی ماشین بردار پشتیبان، چاید و جنگل تصادفی (مطالعه موردی: حوزه آبخیز فریزی). *پژوهشنامه مدیریت حوزه آبخیز*, ۱۳(۲۵)، ۱۴۴-۱۳۳. <http://jwmr.sanru.ac.ir/article-1-1140-fa.html>

۱۸. زاهدی، صلاح الدین، و قرمز چشم، باقر. (۱۴۰۱). پایش دگرگونی رطوبت سطحی خاک با تحلیل گروه زمانی داده‌های لندست ۸ در آبخیز گاوده کردستان. پژوهش‌های آبخیزداری، ۴(۳۵)۲۰-۳۳.
۱۹. زیاری، کرامت الله، رجایی، سید عباس، و داراب خانی، رسول. (۱۴۰۰). پنهانه‌بندی ظرفیت سیل خیزی با استفاده از تحلیل سلسه‌مراتبی و منطق فازی در محیط GIS نمونه موردي: شهر ایلام. مدیریت بحران، ۱۰(۱)، ۲۱-۳۰. doi: 10.22092/wmrj.2022.356743.1444
۲۰. سیدیان، سید مرتضی، باقرپور، مهسا، فتح آبادی، ابوالحسن، و محمدی، امین. (۱۳۹۷). پیش‌بینی رواناب با استفاده از مدل‌های جعبه سیاه و خاکستری. تحقیقات منابع آب ایران، ۱۴(۵)، ۴۰-۲۰. URL: http://www.iwrr.ir/article_66467_9b3f7941d08e01a8310dd0e35dfcf3e9.pdf
۲۱. شرافتی، احمد، و شبیری، شاهین. (۱۴۰۰). ارزیابی داده‌های بارش CHIRPS در تحلیل روند مشخصه‌های بارش در نواحی اقلیمی مختلف ایران. پژوهش‌های اقلیم‌شناسی، ۴۸(۱۴۰۰)، ۱۱۱-۱۲۴.
۲۲. شیخ‌الاسلامی، نونا، قهرمان، بیژن، مساعدی، ابوالفضل، داوری، کامران، و مهارجپور، مهدی. (۱۳۹۳). پیش‌بینی تبخیر و تعرق گیاه مرجع (ETO) با استفاده از روش آنالیز مؤلفه‌های اصلی (PCA) و توسعه مدل رگرسیونی خطی چندگانه (MLR-PCA) (مطالعه موردي: ایستگاه مشهد). آب و خاک، ۲۸(۲)، ۴۰-۴۲.
۲۳. عبداللهزاده، غلامحسین، و شریف‌زاده محمد، شریف. (۱۴۰۲). شناسایی تعیین‌کننده‌های مشارکت در اقدامات تعییل خطر سیل: مطالعه نواحی روستایی در معرض سیل استان گلستان. دانش پیشگیری و مدیریت بحران، ۱۳(۳)، ۳۱۸-۳۳۵.
۲۴. عیدی‌پور، امین، آخوندعلی، علی محمد، و مراح، محمد امین. (۱۴۰۲). پیش‌بینی گروهی و هشدار وقوع سیل در سد مخزنی ذی با بهره‌گیری از داده‌های پیش‌بینی-مجدد بارش و دما GEFsv12. مهندسی آبیاری و آب ایران، ۱۴(۱)، ۳۲۶-۳۰۸.
۲۵. کاظمی، رحیم، و پرهیمت، جهانگیر. (۱۴۰۰). تحلیل عامل‌های مؤثر بر شدت سیل خیزی در ایران. پژوهش‌های آبخیزداری، ۳۴(۱)، ۵۹-۷۳.
۲۶. گنجی، کامران، قره چلو، سعید، و احمدی، احمد. (۱۴۰۰). تعیین عوامل مؤثر بر سیل خیزی رودخانه گرگانرود و ریز پنهانه‌بندی خطر سیلاب شهرستان آق‌قلا با استفاده از تحلیل سلسه مراتبی AHP. جغرافیا و مخاطرات محیطی، ۱۰(۴)، ۲۵-۴۶.
۲۷. ملازه‌ی، اسدالله، پودینه، محمدرضا، خسروی، محمود، آرمش، محسن، و دهواری، علی اصغر. (۱۳۹۹). پتانسیل سنگی خطر سیلاب در حوضه آبریز سرباز با استفاده از سامانه اطلاعات جغرافیایی. نشریه تحقیقات کاربردی علوم جغرافیایی، ۵۸(۲۰)، ۴۱-۲۶۰.
۲۸. مینایی، مژده، و وحیدنیا، محمد حسن. (۱۴۰۱). راهکارهای بازدارنده برای جلوگیری از سیل به کمک سنجش از دور و مدل‌سازی عامل مبنای (مطالعه موردي: شهرستان شوش). مخاطرات محیط طبیعی، ۱۱(۳۳)، ۱۹۷-۱۶۲.
۲۹. نگارش، حسین، ازدری مقمن، مهدی، و آرمش، محسن. (۱۳۹۲). کاربرد شبکه‌ی عصبی مصنوعی در شبیه‌سازی و پیش‌بینی سیلاب در حوضه آبریز سرباز. جغرافیا و توسعه، ۱۱(۳۱)، ۱۵-۲۸.
۳۰. نوری قیداری، محمد حسین، دانکو، علی، و شهرکی، مهدی. (۱۳۹۳). کاربرد قانون توانی در تحلیل فراوانی سیلاب در رودخانه سرباز. دانش آب و خاک، ۴۵(۴)، ۴۵-۵۹.
- <https://doi.org/10.22092/wmje.2020.342597.1330>
- <https://doi.org/10.22092/wmrj.2022.356743.1444>
- <https://doi.org/10.22067/geoh.2021.68419.1011>
- <https://doi.org/10.22111/jneh.2022.38718.1812>
- <https://doi.org/10.22111/gdij.2013.791>
- https://water-soil.tabrizu.ac.ir/article_3152.html

References

- Abbott, P. L., (2006), Natural disasters, 5th Edition. New York: McGraw-Hill Companies Inc.
- Abdollahzadeh, G., & Sharifzadeh, M. S. (2023). Identifying the determinants of public participation in flood risk management: A case study of flood-prone rural areas in Golestan Province, Iran. *Disaster Prev. Manag. Know*, 13(3), 318-335. URL: <http://dpmk.ir/article-1-625-fa.html>. [In Persian]
- Amini, S., Azizian, A., & Daneshkar Arasteh, P. (2020). Improving the Performance of Global Rainfall Forecasting Systems in Different Climate Areas of Iran Using Quantile Mapping Method. *Iranian Journal of Soil and Water Research*, 51(9), 2275-2291. doi: 10.22059/ijswr.2020.302208.668602. [In Persian]
- Amininia, K., & SAGHEBIAN, S. (2022). Investigation of effective parameters in modeling monthly precipitation using intelligent integrated models based on time series decomposition. *Iranian Journal of Irrigation & Drainage*, 16(4), 789-803. [In Persian]
- Armesh, M., Alijani, B., & Dunyadoost, H. (2016). Synopsis analysis of floods in Sarbaz catchment. *Geographical space*, 17(58), 49-70. URL: <http://geographical-space.iau-ahar.ac.ir/article-1-1073-fa.html>. [In Persian]
- Asadi, H., Dastorani, M. T., & Shahedi, K. (2022). Investigating the effect of daily discharge sequence in river flow forecasting using intelligent algorithms (Case study: Kasilian watershed). *Geography and Development*, 20(68), 163-183. doi: 10.22111/gdij10.22111.2022.7007. [In Persian]

7. Bahrami, F., Saadatabadi, A. R., Krakauer, N. Y., Mesbahzadeh, T., & Sardoo, F. S. (2021). Synoptic-dynamic patterns affecting Iran's autumn precipitation during ENSO phase transitions. *Climate*, 9(7), 106.
8. Barlow, M., Zaitchik, B., Paz, S., Black, E., Evans, J., & Hoell, A. (2016). A review of drought in the Middle East and southwest Asia. *Journal of climate*, 29(23), 8547-8574.
9. Anuar, N., Khan, M., Pasupuleti, J., & Ramli, A. (2019). Flood risk prediction for a hydropower system using artificial neural network. *International Journal of Recent Technology and Engineering (IJRTE)*. <http://dx.doi.org/10.35940/ijrte.D5134.118419>
10. Bayati khatibi, M., sarysaraf, B., & karami, F. (2021). Investigation and Estimation of hydrological effects of caused by land use changes in the Ojan Chay basin (Sahand mountain range, northwest of Iran). *Geography and Development*, 19(62), 79-102. doi: 10.22111/gdij.2021.6004. [In Persian]
11. Bergh, D. V. D., Clyde, M. A., Gupta, A. R. K. N., de Jong, T., Gronau, Q. F., Marsman, M., & Wagenmakers, E. J. (2021). A tutorial on Bayesian multi-model linear regression with BAS and JASP. *Behavior Research Methods*, 1-21.
12. Birkholz, S., Muro, M., Jeffrey, P., & Smith, H.M. (2014). Rethinking the relationship between flood risk perception and flood management. *Science of The Total Environment*, 478, 12-20. <https://doi.org/10.1016/j.scitotenv.2014.01.061>.
13. Boithias, L., Ribolzi, O., Lacombe, G., Thammahacksa, C., Silvera, N., Latsachack, K., Soulileuth, B., Viguer, M., Auda, Y., Robert, E., Evrard, O., Huon, S., Pommier, T., Zouiten, C., Sengtaeuanghong, O., & Rochelle-Newall, E. (2021). Quantifying the effect of overland flow on Escherichia coli pulses during floods: Use of a tracer-based approach in an erosion-prone tropical catchment. *Journal of Hydrology*, 594, 125935. <https://doi.org/https://doi.org/10.1016/j.jhydrol.2020.125935>
14. Damadi, S., Dehvari, A., Dahmardeh ghaleno, M. R., & Ebrahimiyan, M. (2021). Flood hazard zonation using HEC-RAS hydraulic model in Sarbaz River, Sistan and Baluchestan Province. *Watershed Engineering and Management*, 13(3), 590-601. doi: 10.22092/ijwmse.2021.124028.1573. [In Persian]
15. Dastorani, M. T., Salimi Koochi, J., Sharifi Darani, H., Talebi, A., & Rahimian, M. H. (2013). River instantaneous peak flow estimation using daily flow data and machine-learning-based models. *Journal of Hydroinformatics*, 1, 15(4), 1089–1098. doi: <https://doi.org/10.2166/hydro.2013.245>
16. DeVries, B., Huang, C., Armston, J., Huang, W., Jones, J. W., & Lang, M. W. (2020). Rapid and robust monitoring of flood events using Sentinel-1 and Landsat data on the Google Earth Engine. *Remote Sensing of Environment*, 240, 111664. <https://doi.org/10.1016/j.rse.2020.111664>
17. Dosturani, M. T., Sharifi Darani, H., Talebi, A., & Moghadamnia, A. (2013). Effectiveness of artificial neural networks and adaptive neural-fuzzy inference system in rainfall-runoff modeling in Zayandeh Rood Dam watershed. *Water and Sewage*, 22(4 (series 80)), 114-125. [In Persian]
18. Dtissibe, F. Y., Ari, A. A. A., Titouna, C., Thiare, O., Gueroui, A.M., (2020). Flood forecasting based on an artificial neural network scheme. *Nat. Hazards*, 104, 1211–1237. <https://doi.org/10.1007/s11069-020-04211-5>.
19. Du, J., Kimball, J. S., Bindlish, R., Walker, J. P., & Watts, J. D. (2022). Local Scale (3-m) Soil Moisture Mapping Using SMAP and Planet Super Dove. *Remote Sens.*, 14, 3812. <https://doi.org/10.3390/rs14153812>
20. Eidipour, A., Akhondali, A. M., & maddah, M. A. (2023). Ensemble forecasting and flood warning in Dez Dam Reservoir using GEFSv12 Re-forecast temperature and precipitation data. *Irrigation and Water Engineering*, 14(1), 308-326. doi: 10.22125/iwe.2023.365211.1682. [In Persian]
21. Falah, F., Rahmati, O., Rostami, M., Ahmadisharaf, E., Daliakopoulos, I. N., & Pourghasemi, H. R. (2019). Artificial neural networks for flood susceptibility mapping in data-scarce urban areas. In H. R. Pourghasemi & C. Gokceoglu (Eds.), *Spatial Modeling in GIS and R for Earth and Environmental Sciences*, (pp. 323-336). Elsevier. <https://doi.org/https://doi.org/10.1016/B978-0-12-815226-3.00014-4>
22. Fu-wei, L. I., Ai-me, B. A. O., Xing-sheng, S. H. U., & Wei, D. (2022). Long-term runoff prediction for Huanren River basin based on multiple models. *China Rural Water and Hydropower*, 0(11), 6-12. <https://doi.org/10.12396/znsd.220146>
23. G. Cruz, F., Binag, M. G., Ga, M. R. G., & Uy, F. A. A. (2018). "Flood prediction using multi-layer artificial neural network in monitoring system with rain gauge, Water Level, Soil Moisture Sensors, *TENCON 2018 - 2018 IEEE Region 10 Conference*, pp. 2499-2503. <https://doi.org/10.1109/TENCON.2018.8650387>
24. Ganji, K., Gharechelou, S., & Ahmadi, A. (2022). Determining effective factors on Gorganrood River flooding and micro-zoning of flood risk analysis in Aq'Qala county using AHP method. *Journal of Geography and Environmental Hazards*, 10(4), 25-46. doi: 10.22067/geoeh.2021.68419.1011. [In Persian]
25. Ghassabi, Z., Karami, S., Vazifeh, A., & Habibi, M. (2023). Investigating the unprecedented summer 2022 penetration of the Indian monsoon to Iran and evaluation of global and regional model forecasts. *Dynamics of Atmospheres and Oceans*, 103, 101386.
26. Gorgij, K., Dehvari, A., & Dahmardeh Ghaleno, M. (2020). Uncertainty Analysis of Hydrological Parameters of Sarbaz Watershed Using SWAT Model and SUFI-2 Algorithm. *Journal of Hydrosciences and Environment*. 4(7), 43-56. doi: 10.22111/jhe.2021.37151.1065
27. Halajian, M. (2014). Simulation and prediction of flow rate using artificial neural network, Islamic Azad University, Marvdash branch. [In Persian]
28. Hong, Y., Adhikari, P., Gourley, J. J. (2013). Flood hazard and disaster. In: Bobrowsky, P.T. (eds) *Encyclopedia of Natural Hazards. Encyclopedia of Earth Sciences Series*. Springer, Dordrecht. https://doi.org/10.1007/978-1-4020-4399-4_138.

29. <https://doi.org/https://doi.org/10.1016/j.ijdrr.2021.102154>
30. Jahangir, M. H., Mousavi Reineh, S. M., & Abolghasemi, M. (2019). Spatial predication of flood zonation mapping in Kan River Basin, Iran, using artificial neural network algorithm. *Weather and Climate Extremes*, 25, 100215. <https://doi.org/10.1016/j.wace.2019.100215>.
31. Karl, A. K., & Lohani, A. K. (2010). Development of flood forecasting system using statistical and ANN techniques in the downstream catchment of mahanadi basin. India. *Journal of Water Resource and Protection*. 02, 880–887. <https://doi.org/10.4236/jwarp.2010.210105>.
32. Kazemi, R., & Porhemmat, J. (2021). An Analysis of the factors Affecting Flooding Severity in Iran. *Watershed Management Research*, 34(1), 59-73. doi: 10.22092/wmef.2020.342597.1330. [In Persian]
33. Khazaei, M., Shahrivar, A., & Goharghani, J. (2015). Analysis of the main components affecting the prediction of river flow. *Iran National Watershed Science and Engineering Conference (participatory development in watershed management)*. SID. <https://sid.ir/paper/886489/fa>. [In Persian]
34. Mamat, N. H., Othman, M. H., Othman, W. Z., & Noor, M. F. M. (2021). Internet of things in flood warning system: An overview on the hardware implementation. In *Proceedings of the 1st International Conference on Electronics, Biomedical Engineering, and Health Informatics: ICEBEHI 2020, 8-9 October, Surabaya, Indonesia* (pp. 269-279). Springer Singapore. https://doi.org/10.1007/978-981-33-6926-9_23
35. Minaei, M., & Vahidnia, M. H. (2022). Flood prevention solutions using remote sensing and agent-based modeling (Case study: Shoush city). *Journal of Natural Environmental Hazards*, 11(33), 197-216. doi: 10.22111/jneh.2022.38718.1812. [In Persian]
36. Mollazehi, A., Pudineh, M., Khosravi, M., Armesh, M., & Dehvari A.(2020). Assessment of the potential flood risk in Sarbaz Drainage Basin. *jgs*, 20 (58), 241-260. URL: <http://jgs.knu.ac.ir/article-1-3223-fa.html>. [In Persian]
37. Motta, M., de Castro Neto, M., & Sarmento, P. (2021). A mixed approach for urban flood prediction using Machine Learning and GIS. *International Journal of Disaster Risk Reduction*, 56, 102154.
38. Negaresh, H., azhdareimogadam, M., & armesh, M. (2013). The Usage of Artificial Neural Network in Simulation and Prediction of Flood at Sarbaz Drainage Basin. *Geography and Development*, 11(31), 15-28. doi: 10.22111/gdij.2013.791. [In Persian]
39. Nouri Gheidari, M., Danko, A., & Shahraki, M. (2015). Application of power law in flood frequency analysis of Sarbaz River. *Water and Soil Science*, 24(4), 45-59. [In Persian]
40. Pashainejad, M., Rashki, A. & Adel, S. (2014). Using plant indicators to assess the vulnerability of Razavi Khorasan province to desertification, *International Conference on Environment and Natural Resources*, Shiraz. <https://civilica.com/doc/551106>. [In Persian]
41. Permai, S. D., & Tanty, H. (2018). Linear regression model using bayesian approach for energy performance of residential building. *Procedia Computer Science*, Volume 135, Pages 671-677, ISSN 1877-0509. <https://doi.org/10.1016/j.procs.2018.08.219>.
42. Rahmani, A., Behzadfar, M., Nasiri, A., & Hamze, M. (2019). Flood and urban engineering. *Iran Nature*, 4(4), 59-74. doi: 10.22092/irn.2019.120100. [In Persian]
43. Rahmani, S., Azizian, A., & Samadi, A. (2019). Determining the Flood Hazard Level of Mazandaran Sub-Basins Using a GIS-based Distributed Method. *Journal of Hydraulics*, 14(1), 123-139. doi: 10.30482/jhyd.2019.155838.1342. [In Persian]
44. Rangari, V. A., Umamahesh, N. V., & Bhatt, C. M. (2019). Assessment of inundation risk in urban floods using HEC RAS 2D. *Modeling Earth Systems and Environment*, 5(4), 1839-1851. <http://dx.doi.org/10.2166/h2oj.2021.111>
45. Rezaei, H. (2013). River discharge modeling with the help of analyzing the main components of the case study: Bashar River, *International Conference on Sustainable Development, solutions and challenges focusing on agriculture, natural resources, environment and tourism*, Tabriz. <https://civilica.com/doc/354920>. [In Persian]
46. Roshan Neko, P. (2013). Prioritization of watersheds for flood management based on morphometric characteristics, a case study of Northern Alborz, Glendrud watershed, Ministry of Science, Research and Technology, Mazandaran University, Faculty of Humanities and Social Sciences. [In Persian]
47. Roshun, S. H., Shahedi, K., & Habibnejad Roshan, M. (2021). Comparison of the Performance of ANN and SVM Methods in Rainfall-Runoff Process Modeling (Case Study: North Karun Watershed). *jwss*, 25 (2), 77-90. URL: <http://jstnar.iut.ac.ir/article-1-4016-fa.html>. [In Persian]
48. Rostami Khalaj, M., & Salajeghe, A. (2019). Rainfall-runoff modeling based on system dynamics approach (Case study: Mashhad Kardeh dam basin). *Watershed Engineering and Management*, 11(1), 15-27. doi: 10.22092/ijwmse.2019.118432. [In Persian]
49. Rostami, A., Akhoondzadeh, M., & Amani, M. (2022). A fuzzy-based flood warning system using 19-year remote sensing time series data in the Google Earth Engine cloud platform. *Advances in Space Research*, 70(5), 1406-1428.
50. Rozos, E., Bellos, V., Kalogiros, J., & Mazi, K. (2023). Efficient Flood Early Warning System for Data-Scarce, Karstic, Mountainous Environments: A Case Study. *Hydrology*, 10(10), 203.
51. Sahoo, B., Nanda, T., & Chatterjee, C. (2022). Flood Forecasting Using Simple and Ensemble Artificial Neural Networks. *Geospatial Technologies for Land and Water Resources Management*, 429-456. https://doi.org/10.1007/978-3-030-90479-1_24

52. Sakiri, K., Marsellos, A., Kapetanakis, S. (2018). Artificial Neural Network and Multiple Linear Regression for Flood Prediction in Mohawk River, New York. *Water*, 10, 1158. <https://doi.org/10.3390/w10091158>
53. Samantaray, S., Das, S. S., Sahoo, A., & Satapathy, D. P. (2022). Evaluating the application of metaheuristic approaches for flood simulation using GIS: A case study of Baitarani river Basin, India. *Materials Today: Proceedings*, 61, 452-465. <https://doi.org/10.1016/j.matpr.2021.11.561>.
54. Seyedian, S. M., Bagherpour, M., Fathabadi, A., & Mohammadi, A. (2019). Runoff prediction using black and gray box models. *Iran-Water Resources Research*, 14(5), 204-219. [In Persian]
55. Shahiri Tabarestani, E., Afzalimehr, H. (2021). Artificial neural network and multi-criteria decision-making models for flood simulation in GIS: Mazandaran Province, Iran. *Stoch Environ Res Risk Assess* 35, 2439–2457. <https://doi.org/10.1007/s00477-021-01997-z>
56. Sharafati, A., & Shobeiri, S. (2022). Evaluation of CHIRPS precipitation data in the analysis of precipitation characteristics trends in different climatic regions of Iran. *Journal of Climate Research*, 1400(48), 111-124. [In Persian]
57. Sheikholeslami, N. (2014). Estimating reference evapotranspiration by using principal component analysis (PCA) and the development of a regression model (MLR-PCA) (Case Study: Mashhad Station). *Water and Soil*, 28(2), 420-429. doi: 10.22067/jsw.v0i0.25711. [In Persian]
58. Soltani, K., Ebtehaj, I., Amiri, A., Azari, A., Gharabaghi, B., & Bonakdari, H. (2021). Mapping the spatial and temporal variability of flood susceptibility using remotely sensed normalized difference vegetation index and the forecasted changes in the future. *Science of The Total Environment*, 770, 145288, ISSN 0048-9697.
59. Thieken, A. H., Bubeck, P., Heidenreich, A., von Keyserlingk, J., Dillenardt, L., & Otto, A. (2022). Performance of the flood warning system in Germany in July 2021 – insights from affected residents. *EGU Sphere*, 1-26. <https://doi.org/10.5194/egusphere-2022-244>
60. Yang, L., Driscol, J., Sarigai, S., Wu, Q., Chen, H., & Lippitt, C. D. (2022). Google Earth Engine and artificial intelligence (AI): A comprehensive review. *Remote Sens.*, 14, 3253. <https://doi.org/10.3390/rs14143253>
61. Zahedi, S., & Ghermezcheshmeh, B. (2022). Monitoring changes in soil surface moisture by analyzing the time series of Landsat 8 Data in Gavdare Watershed, Kurdistan Province. *Watershed Management Research*, 35(4), 20-33. doi: 10.22092/wmrj.2022.356743.1444. [In Persian]
62. Zalnezhad, A., Rahman, A., Nasiri, N., Vafakhah, M., Samali, B., & Ahamed, F. (2022). Comparing performance of ANN and SVM methods for regional flood frequency analysis in South-East Australia. *Water*, 14, 3323. <https://doi.org/10.3390/w14203323>
63. Zarei, M., Zandi, R., & Naemitaabar, M. (2022). Assessment of flood occurrence potential using data mining models of support vector machine, Chaid and Random Forest (Case study: Frizi watershed). *Journal pf Watershed Management Research*. 13(25), 133-144. doi:10.52547/jwmr.13.25.133. [In Persian]
64. Zhao, X., Xia, H., Liu, B., Jiao, W. (2022). Spatiotemporal comparison of drought in Shaanxi–Gansu–Ningxia from 2003 to 2020 using various drought indices in Google Earth Engine. *Remote Sensing*, 14, 1570. <https://doi.org/10.3390/rs14071570>
65. Ziari, K., Rajai, S. A., & Darabkhani, R. (2021). Flood zoning using hierarchical analysis and fuzzy logic in GIS Case Study: Ilam City. *Emergency Management*, 10(1), 21-30. [In Persian]