

"Research Paper"

Development a new hydraulic method for prediction of river flood discharge

Fatemeh Shirazi¹, Abdolreza Zahiri², Jamshid Piri³ and Amir Ahmad Dehghani⁴

1- M.Sc. Student in Water Structures, Department of Water Engineering, University of Agricultural Sciences and Natural Resources, Gorgan, Iran

2- Associated Prof., Department of Water Engineering, University of Agricultural Sciences and Natural Resources, Gorgan, Iran, (Corresponding author: zahiri.areza@gmail.com)

3- Assistant Prof., Department of Water Engineering, University of Zabol, Iran

4- Prof., Department of Water Engineering, University of Agricultural Sciences and Natural Resources, Gorgan, Iran

Received: 23 October 2022 Accepted: 20 May 2023

Extended Abstract

Introduction and Objective: The correct estimation of flood flow in rivers is an important issue and plays a significant role in the optimal use of water resources, operation of dam reservoirs, and the design and planning of water projects.

Material and Methods: In this research, a simple and conceptual method based on Manning's formula in real flow conditions is used to estimate the flood flow discharge. In this method, firstly, for the combined effect of friction slope and Manning's roughness coefficient, the alpha parameter (α) was defined and calculated for 12 hydrometric stations located in three main rivers of Golestan province (including Gorganrood, Atrak, and Qarasoo).

Results: The results showed that the value of this parameter decreases continuously with the increase of the flow depth and finally asymptotically reaches a constant value. This behavior shows that the value of α is nearly constant for the upper flow depths which indicate the occurrence of floods, and hence using this constant value and the Manning formula, the river flood discharge can be estimated. In the next step, we tried to provide a regression model between the Alpha parameter and the flow depth. The regression modeling results showed that for most of the hydrometric stations, the coefficients of determination (R^2) of the presented equations are smaller than 0.3 which demonstrates its low efficiency. For this reason, machine learning models were used and the parameter was modeled by the Artificial Neural Networks (ANN), Decision Tree (M5tree), and Support Vector Regression (SVR) models.

Conclusion: The modeling results showed that the decision tree model with a mean absolute error of 0.35, determination coefficient of 0.88, and root mean square error of 0.86 has the best accuracy in the test phase. After determining the parameter α , the amount of flood discharge was predicted. The best performance among the models was the decision tree in predicting the flow rate in rivers. After comparing the observed values, the decision tree model has an average absolute error of 1.32, a determination coefficient of 0.89, and an average square root error of 63.3. It has the best accuracy in the test phase.

Keywords: Flood Discharge, Manning Roughness Coefficient, Machine Learning Models, Regression Model

**"مقاله پژوهشی"****ارائه روشی مبتنی بر هیدرولیک جریان و مدل یادگیری ماشین برای پیش‌بینی دبی سیلاب رودخانه‌ها**فاطمه شیرازی^۱، عبدالرضا ظهیری^۲، جمشید پیری^۳ و امیراحمد دهقانی^۴

۱- دانشجوی کارشناسی ارشد سازه‌های آبی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ایران
 ۲- دانشیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ایران، (نویسنده مسوول: zahiri.arezah@gmail.com)
 ۳- استادیار گروه مهندسی آب، دانشگاه زابل، ایران
 ۴- استاد گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ایران
 تاریخ دریافت: ۱۴۰۱/۸/۱ تاریخ پذیرش: ۱۴۰۲/۲/۳۰
 صفحه: ۱۱۰ تا ۱۲۳

چکیده مبسوط

مقدمه: تخمین صحیح دبی جریان سیلاب در رودخانه‌ها موضوع مهمی بوده و نقش قابل توجهی در استفاده بهینه از منابع آب، بهره‌برداری از مخازن سدها و نیز طراحی و برنامه‌ریزی پروژه‌های آبی ایفا می‌کند.

مواد و روش‌ها: در این تحقیق برای تخمین دبی سیلاب، از روشی ساده و مفهومی براساس معادله مانینگ تحت شرایط واقعی جریان استفاده شده است. در این روش، ابتدا برای تاثیر توأم شیب انرژی و ضریب زبری مانینگ، پارامتر آلفا (α) تعریف شده و برای ۱۲ ایستگاه هیدرومتری واقع در سه رودخانه اصلی استان گلستان (شامل گرگانرود، اترک و قره‌سو) محاسبه شد.

یافته‌ها: نتایج نشان داد که مقدار این پارامتر با افزایش عمق جریان کاهش یافته و در نهایت به صورت مجانب تقریباً به یک مقدار ثابت می‌رسد. این رفتار نشان می‌دهد که به‌ازاء عمق‌های زیاد جریان در رودخانه که بیانگر وقوع سیلاب می‌باشد، مقدار α ثابت شده و با استفاده از این عدد ثابت و نیز معادله مانینگ، می‌توان دبی سیلاب رودخانه را برآورد نمود. در گام بعدی، سعی شد بین این پارامتر و عمق جریان، یک رابطه رگرسیونی ارائه شود. نتایج مدل‌سازی رگرسیونی نشان داد که برای اغلب ایستگاه‌های هیدرومتری، ضریب تعیین (R^2) روابط ارائه شده کوچکتر از ۰/۳ بوده و دارای کارایی لازم نیست. به همین دلیل برای بیان این ارتباط با کارایی و دقت بیشتر، از مدل‌های یادگیری ماشین استفاده شد. به این منظور پارامتر α به کمک مدل‌های شبکه عصبی (ANN)، درخت تصمیم (M5tree) و ماشین بردار رگرسیونی (SVR) مدل‌سازی شد.

نتیجه‌گیری: نتایج مدل‌سازی نشان داد که مدل درخت تصمیم با میانگین خطای مطلق ۰/۳۵، ضریب تعیین ۰/۸۸ و خطای میانگین جذر مربعات ۰/۸۶ در مرحله آزمون بهترین دقت را دارا می‌باشد. بعد از تعیین پارامتر α ، مقدار دبی سیلاب پیش‌بینی گردید. بهترین عملکرد در بین مدل‌ها را درخت تصمیم در پیش‌بینی دبی جریان در رودخانه‌ها دارا بود، که پس از مقایسه با مقادیر مشاهداتی، مدل درخت تصمیم با میانگین خطای مطلق ۰/۳۲، ضریب تعیین ۰/۸۹ و خطای میانگین جذر مربعات ۳/۶۳ در مرحله آزمون بهترین دقت را دارا می‌باشد.

واژه‌های کلیدی: دبی سیلاب، ضریب زبری مانینگ، مدل رگرسیونی، مدل یادگیری ماشین

مقدمه

در میان بلایای طبیعی، سیلاب‌ها یکی از مخرب‌ترین پدیده‌های اقلیمی هستند که باعث آسیب گسترده به زندگی انسان، زیرساخت‌ها، کشاورزی و سیستم اجتماعی- اقتصادی جامعه می‌شوند. در سال‌های اخیر، به دلیل تغییرات آب و هوایی در کل جهان، منابع آبی با تغییرات زیادی مواجه شده‌اند که منجر به رویدادهای شدیدی مانند سیل‌های مکرر و خشکسالی شده است. وقوع این رویدادهای شدید، جان بسیاری از انسان‌ها را گرفته و باعث بی‌ثباتی اقتصادی نیز می‌شود (Kisi et al., 2022). بنابراین، برآورد دقیق دبی جریان رودخانه در شرایط سیلابی برای جلوگیری و کاهش این تلفات ضروری است. همچنین پیش‌بینی دبی جریان رودخانه و به ویژه در شرایط سیلابی برای بسیاری از مطالعات اجتماعی، اقتصادی، هیدرولوژیکی و محیط زیستی از قبیل ارزیابی اقتصادی- اجتماعی خطر سیل در محدوده شهرها و روستاها، تهیه نقشه پهنه‌بندی سیلاب در دشت‌های سیلابی، حفاظت از سواحل رودخانه‌ها، استفاده بهینه از منابع آب، بهره‌برداری از مخازن سدها و نیز طراحی و برنامه‌ریزی پروژه‌های آبی حیاتی است. مدل‌های پیش‌بینی دبی سیلاب از اهمیت زیادی برای ارزیابی خطر و مدیریت وقایع شدید برخوردار هستند. پیش‌بینی‌های قوی و دقیق به اتخاذ استراتژی‌های بهتر

مدیریت منابع آب کمک می‌کند. بنابراین، اهمیت سیستم‌های پیشرفته برای پیش‌بینی کوتاه‌مدت و بلندمدت برای سیل و دیگر وقایع هیدرولوژیکی به شدت برای کاهش آسیب مورد تاکید قرار گرفته است. با این حال، پیش‌بینی زمان پیشروی سیل و مکان وقوع آن به دلیل ماهیت پویای شرایط آب و هوایی، اساساً پیچیده است. بنابراین، مدل‌های اصلی پیش‌بینی سیلاب امروز عمدتاً مختص داده‌های دبی جریان سیل بوده و شامل فرضیات ساده شده مختلفی می‌باشند (Lohani et al., 2014). برای مدل‌سازی فرآیندهای فیزیکی و رفتار پیچیده حوضه، این مدل‌ها از تکنیک‌های خاصی مانند مدل‌های فرآیند محور (جریان‌های رودخانه یک حوضه آبریز را با استفاده از معادلات فیزیکی یا نیمه فیزیکی که فرآیندهای مختلف چرخه هیدرولوژیکی را در نظر می‌گیرند، شبیه‌سازی می‌کنند)، مدل‌های داده محور (روابط بین متغیرها را بررسی می‌کنند و ورودی‌ها را بدون درک دقیق فرآیندهای فیزیکی به خروجی ارتباط می‌دهند (Al Sawaf & Kawanisi, 2020; Bjerklie et al., 2003))، تجربی، توزیع تصادفی، قطعی، پیوسته و ترکیبی بهره می‌برند (EL Bilali et al., 2020).

با توجه به اینکه اندازه‌گیری مستقیم سرعت جریان و دبی سیلاب در بازه‌های مختلف رودخانه‌ها با مشکلات متعددی مثل خطرات جانی، زمان طولانی برداشت‌های صحرائی و نیز

عدم قطعیت همراه است. دلیل تغییر در مقدار شیب انرژی، تغییراتی است که در هندسه مقطع رودخانه، ضریب زبری و نیز دبی جریان سیل نسبت به زمان اتفاق می‌افتد.

دسته دوم (مدل‌های داده‌محور) دارای این مزیت هستند که در مقایسه با مدل‌های قبلی، دارای توانایی یادگیری وابستگی‌های زمانی بلندمدت در داده‌ها می‌باشند که این امر منجر به پیش‌بینی‌های دقیق دبی جریان رودخانه شده است (Yassin et al., 2021). مدل‌های شبکه‌های عصبی مصنوعی (ANN)، درخت تصمیم (M5Tree) (Shiukhy & Mousavi, 2019) و ماشین بردار گرایی (SVR) از جمله مدل‌های داده‌محور می‌باشند که به فراوانی برای تخمین دبی جریان رودخانه‌ها مورد استفاده قرار گرفته‌اند (Srinivasan, 2008). مطالعات نشان داده است که طی سال‌های ۲۰۲۲-۲۰۰۹ مدل SVR با ۵۴ مورد کاربرد، بیشترین استفاده را در مطالعات مختلفی مثل تخمین و پیش‌بینی سیلاب (Tarpanelli et al., 2013)، مدل‌سازی آب و هوا (Bjerklie et al., 2003; Hasanpour Kashani et al., 2015; Zahiri et al., 2012) و پیش‌بینی تراز سطح آب داشته است (Cook & Merwade, 2009; Demir & Kisi, 2016; Goel et al., 2005). چو و همکاران (۲۰۱۱) برای پیش‌بینی دبی جریان در رودخانه‌ها به دو صورت مستقیم و مرکب با رویکرد شبکه عصبی به مطالعه پرداختند. نتایج نشان داد که میانگین درصد مطلق خطا در شبکه‌های عصبی مصنوعی در مقایسه با سایر مدل‌های داده‌محور به‌طور مداوم کم است (Sahu et al., 2011). آردیکلیوگلو و همکاران (۲۰۱۲) روش جدیدی را براساس احتمالات و تئوری آنتروپی برای تعیین دبی و توزیع سرعت جریان در رودخانه‌ها ارائه دادند. آنها مقدار حداکثر سرعت جریان و موقعیت آن را به‌عنوان تابعی از عمق آب تعیین کردند. نتایج نشان داد که روش آنتروپی به‌دلیل کاربرد فراوان در مجاری روباز، جایگزین مناسبی برای روش‌های اندازه‌گیری پارامترهای هیدرولیکی جریان است (Ardiclioglu et al., 2012). راموس و همکاران (۲۰۲۱) با استفاده از مدل‌های هیدرولوژیکی-هیدرولیکی، ضریب زبری مانینگ را در شبیه‌سازی رواناب تفسیر نمودند. تصویر کلی از نتایج ارائه شده نشان داد که برای محاسبه جریان روی سطح یک حوضه با استفاده از مدل‌های عددی هیدرودینامیکی، به مقادیر بالاتری از ضریب زبری مانینگ نسبت به مقادیر معمول مورد نیاز است (Sanz-Ramos et al., 2021).

با توجه به پیچیدگی‌های فراوانی که در خصوص محاسبه دبی جریان سیلاب در رودخانه‌ها وجود دارد، در این تحقیق بر اساس ایده کوراتو و همکاران (۲۰۱۴)، یک پارامتر ساده و مفهومی (α) برای کاهش عدم قطعیت‌های موجود در مدل‌های فیزیکی مرتبط با تخمین دبی جریان سیلاب در رودخانه‌ها معرفی شده و رفتار آن در ۱۲ ایستگاه هیدرومتری واقع در استان گلستان مورد بررسی قرار گرفته است (Corato et al., 2014). این پارامتر به‌صورت نسبت شیب انرژی یا اصطلاحی جریان به ضریب زبری مانینگ رودخانه تعریف شده و به نوعی عدم قطعیت این دو متغیر مهم هیدرولیکی و نیز اثر آنها بر دبی جریان رودخانه در زمان وقوع سیلاب را در یک پارامتر متمرکز می‌نماید. شناسایی و بیان ارتباط پیچیده پارامتر α با متغیر

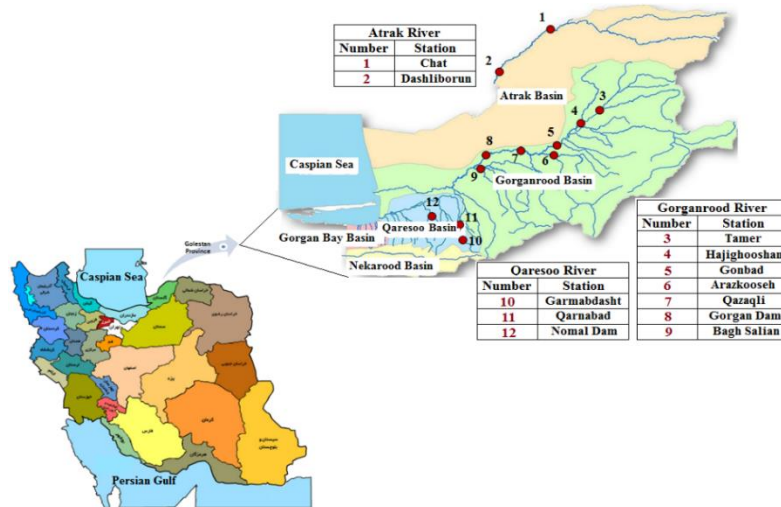
پرهزینه بودن اندازه‌گیری‌ها مواجه است، باید از راهکارهای غیرمستقیم^۱ برای برآورد دبی سیلابی رودخانه‌ها استفاده شود (Mosavi et al., 2018; Rokoni et al., 2022). به همین دلیل روش‌های بسیار مختلفی برای پیش‌بینی دبی جریان رودخانه در زمان واقعی (مثلاً در زمان وقوع سیلاب) وجود دارد (Bashirgonbad, 2022). این مدل‌ها را می‌توان به دو دسته مدل‌های فرآیندمحور^۲ و داده‌محور^۳ تقسیم کرد. مدل‌های فرآیندمحور یا مبتنی بر فیزیک مسئله، دبی جریان رودخانه در یک حوضه را با استفاده از معادلات فیزیکی یا نیمه‌فیزیکی که فرآیندهای مختلف چرخه هیدرولوژیکی را در نظر می‌گیرند، شبیه‌سازی می‌کنند، در حالی که مدل‌های داده‌محور می‌توانند روابط بین متغیرها را یاد بگیرند و ورودی‌ها را بدون درک دقیقی از فرآیندهای فیزیکی به خروجی ارتباط دهند (Al Sawaf & Kawanisi, 2020; Bjerklie et al., 2003). از میان روش‌های فرآیندمحور که تاکنون مورد استفاده قرار گرفته‌اند روش‌های الف) برون‌یابی از منحنی دبی-اشل (Braca, 2008; Hasanpour Kashani et al., 2015; Zahiri et al., 2012)، ب) نقشه‌برداری مقطع عرضی رودخانه بعد از سیلاب و محاسبه دبی سیل به کمک فرمول مانینگ (Cook & Merwade, 2009; Demir & Kisi, 2016; Goel et al., 2005)، ج) استفاده از رادار برای ثبت سرعت سطحی جریان در زمان سیل (Al Sawaf & Kawanisi, 2020; Moramarco & Singh, 2008)، د) استفاده از تئوری آنتروپی (Abril & Knight, 2004; Choo et al., 2012; Huai et al., 2009)، ه) استفاده از مدل‌های ریاضی دوعبده و سه‌بعده (Abril & Knight, 2004; Hu et al., 2010) و ... قابل اشاره هستند. کاربرد بعضی از این روش‌ها (روش‌های الف و ب) در عمل با محدودیت‌های فراوانی مواجه است. از طرف دیگر، توسعه اغلب مدل‌های فرآیندمحور (روش‌های ج تا ه) نیازمند دانش و تخصص عمیق در مورد پارامترهای هیدرولیکی و هیدرولوژیکی بوده و به‌شدت چالش برانگیز گزارش شده است (Lee & Georgakakos, 1996). همچنین اغلب این مدل‌ها در محاسبه دبی سیلاب رودخانه‌ها با عدم قطعیت‌های مختلفی مثل ضریب زبری مانینگ، شیب انرژی، هندسه مقطع رودخانه و ... مواجه هستند. با توجه به سهولت تعیین تراز سطح آب رودخانه در زمان سیلاب و با فرض عدم تغییر قابل توجه در شکل مقطع عرضی رودخانه، می‌توان از عدم قطعیت ناشی از هندسه مقطع صرف نظر نمود. با این حال عدم قطعیت‌های ناشی از ضریب زبری مانینگ و شیب انرژی مهم بوده و در تخمین دبی سیلاب رودخانه تاثیرگذار هستند. ضریب زبری مانینگ رودخانه دارای تغییرات زمانی و مکانی است. این تغییرات در زمان سیلاب نیز معمولاً قابل توجه بوده و محاسبه مستقیم این ضریب در طی وقوع سیلاب عملاً غیرممکن است. در طی عبور سیلاب، به‌دلیل افزایش تراز سطح آب و تغییرات سرعت جریان و تنش برشی بستر، عرض رودخانه با رسوبگذاری و فرسایش مواجه شده و ضریب زبری تغییر می‌کند. همچنین با توجه به سرریز شدن جریان سیلابی به دشت‌های اطراف رودخانه در زمان وقوع سیلاب، ضریب زبری مانینگ تغییر می‌کند که تعیین این ضریب دشوار می‌باشد. برای شیب انرژی نیز تغییراتی در زمان وقوع سیلاب اتفاق می‌افتد که تعیین آنها دشوار و با

است. این رودخانه از استان خراسان شمالی وارد استان گلستان می‌شود. رودخانه اترک منبع تامین آب بسیاری از کشاورزان استان‌های خراسان شمالی و گلستان و نیز تالاب‌های بین‌المللی استان (آلاگل، آلمگل و آجی‌گل) است. این رودخانه نیز دارای رژیم سیلابی است و در مواقع سیلاب، خسارات قابل توجهی به اراضی و سازه‌های اطراف هر دو کشور ایران و ترکمنستان وارد می‌شود. رودخانه قره‌سو نیز یکی از مهمترین منابع آبی تغذیه کننده خلیج گرگان بوده و از مراکز عمده تکثیر انواع ماهیان استخوانی نظیر کلمه، سفید، سیم، کپور و کفال است. برای تامین آب آشامیدنی شهر گرگان و آبیاری زمین‌های کشاورزی، سد کوثر بر روی یکی از شاخه‌های اصلی این رودخانه احداث شده است. در این مطالعه از داده‌های هیدرولیکی (شامل دبی جریان، سرعت، عمق و هندسه مقطع عرضی رودخانه) ۱۲ ایستگاه هیدرومتری واقع در مسیر این ۳ رودخانه برای بررسی روش پیشنهادی استفاده شده است. در شکل ۱ موقعیت رودخانه‌ها و ایستگاه‌های هیدرومتری مورد استفاده در این تحقیق نشان داده شده است. ایستگاه‌های هیدرومتری مورد مطالعه شامل چات و داشلی‌برون (واقع بر رودخانه اترک)، تمر، حاجی‌قوشان، گنبد، ارازکوسه، قزاقلی، سدوشمگیر و باغ سالیان (واقع بر رودخانه گرگانرود)، گرمابدشت، قرن‌آباد، و خروجی سد نامل (واقع بر رودخانه قره‌سو) می‌باشند.

ساده‌ای مثل تراز سطح آب و نهایتاً با دبی سیلاب رودخانه، نوآوری و کاربرد عملی این پژوهش است. به این منظور برای بیان ریاضی رفتار، از مدل‌های رگرسیونی و نیز مدل‌های یادگیری ماشین استفاده شده است.

مواد و روش‌ها منطقه مطالعاتی

استان گلستان با مساحتی حدود ۲۲۰۰۰ کیلومتر مربع، در عرض جغرافیایی ۳۶ درجه و ۳۰ دقیقه تا ۳۸ درجه و ۸ دقیقه شمالی و طول جغرافیایی ۵۳ درجه و ۵۷ دقیقه تا ۵۶ درجه و ۲۲ دقیقه شرقی واقع شده است. این استان دارای ۵ حوضه رودخانه‌ای است که از این میان، ۳ رودخانه مهم گرگانرود، اترک و قره‌سو دارای اهمیت بیشتری است. رودخانه گرگانرود با حدود ۴۷ درصد از وسعت استان، حدود ۷۴ درصد از منابع آب استان را تامین می‌کند. این رودخانه در مسیر خود دارای ۳ سد مخزنی مهم بوده و منبع تامین آب بسیاری از کشاورزان استان می‌باشد. این رودخانه از منظر سیلاب و خسارات ناشی از آن نیز بسیار مهم بوده و تقریباً هر ساله با وقوع سیلاب‌های کوچک و بزرگ در این رودخانه، خسارات قابل توجهی به استان وارد می‌شود. رودخانه اترک نیز به دلیل دارا بودن مرز مشترک با ترکمنستان، رودخانه بین‌المللی بوده و دارای اهمیت بسیاری



شکل ۱- موقعیت رودخانه‌ها و ایستگاه‌های هیدرومتری مورد مطالعه
Figure 1. Location of studied rivers and hydrometric stations

هیدرولیکی تابع تراز سطح آب بوده و با معلوم بودن تراز سطح آب در زمان سیل (به کمک دستگاه سطح‌سنج (لیمنوگراف) و یا حتی داغاب سیل) به‌سادگی قابل برآورد می‌باشند، این در حالی است که تعیین دو پارامتر S_f و n در حالت وقوع سیلاب در رودخانه با مشکلات عدیده‌ای همراه هستند. عدم قطعیت در تعیین یک مقدار مناسب و قابل اعتماد برای این دو پارامتر باعث شده است که کاربرد این فرمول و نیز اغلب معادلات هیدرولیکی یک بعدی و دو بعدی مرتبط با جریان‌های سیلابی (مثل معادلات سنت ونانت و شیونو-نایت) با محدودیت مواجه شود.

مبانی روش پیشنهادی

فرمول مانینگ (رابطه ۱) یکی از مهمترین روابط هیدرولیکی است که کاربرد گسترده‌ای در محاسبه سرعت و دبی جریان کانال‌ها و رودخانه‌ها دارد:

$$Q = VA = \frac{\sqrt{S_f}}{n} AR^{2/3} \quad (1)$$


در این رابطه Q دبی جریان، V سرعت متوسط جریان، A مساحت جریان، n ضریب زبری مانینگ، شعاع هیدرولیکی و S_f شیب خط انرژی یا شیب اصطکاکی است. در شرایط جریان یکنواخت از شیب کف آبراهه (S) به جای شیب اصطکاکی استفاده می‌شود. در فرمول فوق، مساحت جریان و شعاع

ضریب آلفا در مقابل افزایش عمق جریان دیده نمی‌شود، اما در این ایستگاه هم تقریباً روند تغییرات ضریب آلفا در نهایت به یک مقدار ثابت رسیده است. در ایستگاه Amont des Gorges به‌طور کلی روند اشاره شده در فوق قابل مشاهده نبوده و تقریباً هیچ روندی بین ضریب آلفا و عمق جریان وجود ندارد. البته به‌نظر می‌رسد که عدم وجود مجانب در این ایستگاه به عدم دسترسی به داده‌های عمق بالای جریان مربوط می‌شود. به‌طور کلی و برای تغییرات متفاوت در ایستگاه‌ها می‌توان اظهار نمود که این تغییرات احتمالاً مرتبط با تفاوت پارامترهای هیدرولیکی و به‌صورت عمده مرتبط با خصوصیات زبری رودخانه است. مشاهده می‌شود که این تغییرات دارای روند خاصی است و با افزایش عمق جریان، مقدار پارامتر α کاهش می‌یابد. استخراج فرم ریاضی این تغییرات، هدف اصلی این تحقیق است که در ادامه مورد بررسی قرار گرفته است. نکته مهم و کاربردی دیگری که از شکل ۲ قابل دریافت است این است که اگر عمق جریان رودخانه از یک مقدار مشخصی فراتر رود (بیانگر وضعیت سیلاب)، آنگاه پارامتر α تقریباً به یک مقدار ثابت نزدیک شده و نسبت به محور افقی (عمق جریان یا تراز سطح آب) حالت مجانب پیدا می‌کند. با توجه به این وضعیت (حصول یک مقدار تقریباً ثابت برای پارامتر α در شرایط سیلابی)، می‌توان به‌کمک رابطه (۲) و صرفاً با معلوم بودن مساحت جریان و شعاع هیدرولیکی، دبی سیلاب رودخانه را محاسبه نمود.

کوراتو و همکاران (۲۰۱۴) با تلفیق دو پارامتر S_f و n پارامتر α را به‌صورت رابطه ۲ معرفی نمودند:

$$Q = \alpha (h) AR^{2/3} \quad (2)$$

در رابطه فوق، ضریب یا پارامتر $\alpha(h)$ برای دخالت توام شیب انرژی و ضریب زبری مانینگ در نظر گرفته شده و مشابه سطح مقطع و شعاع هیدرولیکی، به‌عنوان تابعی از تراز سطح آب معرفی شده است. اهمیت فرم این رابطه در کاربردی‌تر بودن آن نسبت به فرمول مانینگ است به‌طوری‌که اگر بتوان به‌کمک اندازه‌گیری‌های میدانی از رودخانه‌های موردنظر، ارتباط مشخصی بین پارامتر α و تراز سطح آب رودخانه به‌ویژه در زمان وقوع سیلاب پیدا نمود، آنگاه محاسبه این ضریب در هر تراز سطح آب دلخواه به‌سادگی میسر بوده و به‌تبع آن، دبی جریان رودخانه در سیلاب‌های مختلف قابل برآورد است. در شکل ۲ تغییرات پارامتر α نسبت به عمق جریان در ۴ رودخانه مختلف نشان داده شده است. شکل موردنظر نشان می‌دهد که تقریباً از ۴ ایستگاه مورد مطالعه، منحنی‌های تغییرات ضریب آلفا در مقابل عمق جریان برای ۲ ایستگاه (Fer a Chavel و Ponte Nuovo) دارای روندی است که با افزایش عمق جریان، ضریب آلفا به‌صورت محسوسی کاهش یافته و نهایتاً به یک مقدار تقریباً ثابت می‌رسد. برای ایستگاه Rosciano، داده‌های مربوط به عمق کم جریان موجود نبوده و کاهش



شکل ۲- منحنی α - h برای چهار رودخانه مختلف در کشور ایتالیا (کوراتو و همکاران، ۲۰۱۴)
Figure 2. α - h curves for four different rivers in Italy (Corato et al., 2014)


خصوصیات سلول عصبی بیولوژیکی طراحی شده‌اند. به‌طور ذاتی، دسته‌ای از ورودی‌هایی به‌کار برده می‌شوند که هرکدام معرف خروجی سلول عصبی دیگری هستند. هر ورودی در وزن متناظرش که بیانگر قدرت اتصالی است ضرب می‌شود و سپس همه این ورودی‌های وزن‌دار با یکدیگر جمع می‌گردند تا سطح تحریک سلول عصبی را معین نمایند. شکل ۳ مدلی را نشان می‌دهد که با این نظریه توسعه داده شده است. علی‌رغم تنوع در الگوهای شبکه، تقریباً همه آنها بر اساس این ساختار بنا نهاده شده‌اند. در این تحقیق، تمام مراحل کدنویسی این روش در نرم‌افزار متلب صورت گرفت.

مدل‌های یادگیری ماشین

برای استخراج فرم ریاضی تغییرات پارامتر α نسبت به عمق جریان، استفاده از مدل‌های رگرسیون لازم است. با توجه به کارایی و قابلیت مناسب مدل‌های یادگیری ماشین در بیان رفتار پیچیده بین متغیرهای مختلف، در این تحقیق از ۳ مدل یادگیری ماشین استفاده شده است:

شبکه‌های عصبی مصنوعی (ANN)

شبکه‌های عصبی یکی از روش‌های یادگیری ماشین است که برای مدل‌سازی و پیش‌بینی پارامترهای خطی و غیرخطی مورد استفاده قرار می‌گیرد. این شبکه‌ها به‌منظور تقلید از



شکل ۳- یک نمونه از شبکه‌های عصبی مصنوعی
Figure 3. An example of artificial neural networks

هستند. طبق نظر کوئیلان، ساخت یک مدل درختی، دو مرحله اصلی زیر را طی می‌کند (Pham et al., 2018):

الف- مرحله رشد (ایجاد یک DT)
ب- مرحله هرس کردن درخت: در این مرحله بر اساس انحراف معیار، خطای مدل‌سازی برای درختی که رشد کرده است ارزیابی شده و نسبت به هرس و یا کاهش تعداد شاخه‌های آن تصمیم‌گیری می‌شود. خطا در هر گره بر اساس انحراف معیار (SDR) هر شاخه به صورت رابطه ۴ قابل محاسبه است:

$$SDR = sd(T) - \sum \frac{|T_i|}{|T|} sd(T_i) \quad (4)$$

که T_i زیرمجموعه‌ای از آزمون نام، T تعداد مثال‌های رسیده به گره و sd انحراف معیار مشاهدات است. در این تحقیق، تمام مراحل کدنویسی این روش در نرم‌افزار متلب صورت گرفت.

ماشین‌های بردار رگرسیون

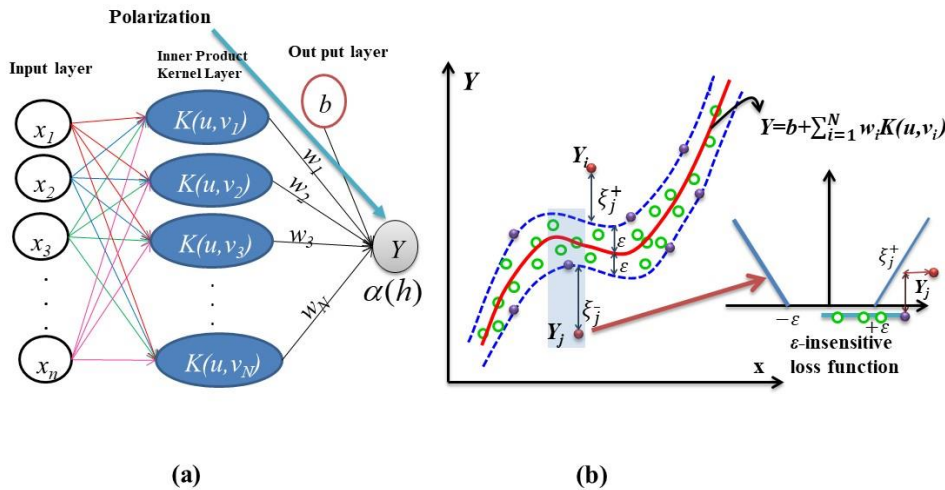
رگرسیون بردار پشتیبان^۱ (SVR) در ماشین بردار پشتیبان (SVM) برای حل مسایل رگرسیونی استفاده می‌شود (شکل ۴). لین و همکاران گزارش نمودند که این روش در فرایند محاسبات خود، کاهش ریسک ساختاری را برای رسیدن به کاهش ریسک تجربی ترکیب می‌کند (Lin et al., 2006). در روش کاهش ریسک ساختاری، با حداقل‌سازی ریسک تجربی ظرفیت تعمیم مناسبی با حداقل خطای تعمیم در مقابل خطای آموزش ایجاد می‌شود (Pham et al., 2018). فرضیه اساسی SVR، نگاشت غیرخطی داده‌های اولیه به یک فضای ویژگی با ابعاد بالاتر است. هسته، تابعی برای انجام رگرسیون خطی در فضای ویژگی است (Maity et al., 2010; Piri et al., 2015). اگرچه کرنل‌های مختلفی مانند چندجمله‌ای، خطی و سیگموئید را می‌توان در SVR به کار برد، اما تابع پایه شعاعی^۲ (RBF) در شبیه‌سازی متغیرهای هیدرولوژی بهتر از کرنل‌های دیگر عمل می‌کند (Lin et al., 2006). بنابراین در مطالعه حاضر از این کرنل استفاده شد.

مدل درخت تصمیم (M5tree)

مدل M5tree نسخه اصلاح‌شده درخت تصمیم اصلی (DT) است که توسط کوئیلان پیشنهاد شد (Quinlan, 1992). در ابتدا مدل DT برای حل مسائل طبقه‌بندی، روش تقسیم (بر اساس سه نوع گره داخلی، ریشه‌ها و برگ‌ها) پیشنهاد شد. مدل M5tree برای موضوعات مختلفی مثل پیش‌بینی مصرف انرژی در ساختمان‌ها (Afsarian et al., 2018)، مدل‌سازی کیفیت هوا (García Nieto et al., 2018)، پیش‌بینی تابش خورشیدی (Deo et al., 2017) و پیش‌بینی تراز سطح آب در رودخانه‌ها (Pham et al., 2018) استفاده شده است. مدل درختی یک مدل رگرسیون است که در آن، داده‌های آموزشی از طریق ساخت یک درخت به زیرمجموعه‌های کوچک‌تر تقسیم می‌شوند و با استفاده از معیار نسبت افزایش، یک مدل رگرسیون منحصر به فرد برای هر زیرمجموعه ساخته می‌شود (Quinlan, 1992). هنگامی که درخت ساخته شد، فرایند آموزش آغاز می‌شود و تلاش می‌کند که بهترین جداسازی به زیرمجموعه‌های مختلف را با توجه به دو شرط انجام دهد: الف- گره‌های برگ درخت تنها شامل الگوهای یک زیرمجموعه هستند. ب- جداسازی تا زمانی که بهبود قابل توجهی در نسبت بهره مشاهده نشود، رخ نمی‌دهد. برای n گره می‌توان k معادله نامساوی تعریف نمود که هر زیرمجموعه از معادلات نامساوی به صورت یک مدل خطی بر اساس رابطه ۳ قابل بیان است:

$$Y = \left\{ \begin{array}{l} \lambda_{01} + \lambda_{11} x \text{ if } x \leq Z_1 \\ \lambda_{02} + \lambda_{12} x \text{ if } x \leq Z_1 \\ \dots \\ \lambda_{0n-1} + \lambda_{1n-1} x, \text{ if } x \leq Z_k \\ \lambda_{0n} + \lambda_{1n} x, \text{ if } x > Z_k \end{array} \right. \quad (3)$$

که Y متغیر خروجی مسئله (پارامتر α)، x متغیر ورودی انتخاب شده برای توسعه مدل، $\lambda_{0i}, \lambda_{1i}$ پارامترهای مدل‌های خطی، nt تعداد برگ و $Z_{1:k}$ مقادیر نقاط شکست



شکل ۴- نمونه‌ای از معماری ماشین بردار رگرسیونی
Figure 4. An example of regression vector machine architecture

معرفی متغیرهای کمبود ζ_i^+ و ζ_i^- در رابطه ۷ لحاظ شود که در نهایت بر اساس اصل کمینه‌سازی خطای ساختاری، محدوده خطا به‌وسیله مسئله بهینه‌سازی در رابطه ۷ مطلوب و بهینه می‌گردد (Eslami & Hasanlou, 2019):

$$\text{Minimize: } \frac{1}{2} (w \cdot w) + C \sum_{i=1}^N (\zeta_i^+ + \zeta_i^-) \quad (۷)$$

$$\text{Constraint s: } \begin{cases} w \cdot x_i + b - y_i \leq \varepsilon + \zeta_i^+ & i = 1, 2, 3, \dots, N \\ y_i - (w \cdot x_i + b) \leq \varepsilon + \zeta_i^- & i = 1, 2, 3, \dots, N \\ \zeta_i^+ \geq 0, \zeta_i^- \geq 0 & i = 1, 2, 3, \dots, N \end{cases}$$

در رابطه فوق، ε محدوده بی‌اثری مدل را نسبت به خطا محاسبه نموده و C یک ضریب ثابت مثبت است. به‌طور کلی رگرسیون‌گیری داده‌ها به شیوه خطی به‌ندرت اتفاق می‌افتد و در عمل نحوه قرارگیری داده‌ها به‌صورت غیرخطی است. در این صورت از روش غیرخطی SVR استفاده می‌شود. در این حالت الگوهای ورودی به فضایی با ابعاد بیشتر نگاشت می‌یابند به‌طوری‌که در فضای نگاشت یافته می‌توان به‌صورت خطی رگرسیون‌گیری کرد. یافتن نگاشت مربوط به تابع کرنل بر اساس آزمون، نیازمند اطلاع از مسائل طبقه‌بندی رگرسیون و همچنین ملاحظات نظری است.

در مدل SVR برای پیش‌بینی از مجموعه توابع به فرم رابطه ۵ استفاده می‌شود:

$$f(x, w) = \sum_{i=1}^m W_i \cdot g_i(x) + b \quad (۵)$$

که W وزن بردار $g(x)$ اشاره به یک مجموعه از انتقال‌های خطی دارد و b ترم بایاس می‌باشد (Eslami & Hasanlou, 2019). رابطه ۵ بر اساس آزمون خطا حداقل می‌شود تا وزن مناسب حاصل گردد. بنابراین با استفاده از این ویژگی‌ها یک مدل خطی ساخته می‌شود. مقدار خطا از تابع ۶ و بر اساس تابع غیرحساس ε قابل برآورد است (Eslami & Hasanlou, 2019; Maity et al., 2010; Piri et al., 2015):

$$L(y, f(x, w)) = \begin{cases} 0 & |y - f(x, w)| \leq \varepsilon \\ |y - f(x, w)| - \varepsilon, & \text{otherwise} \end{cases} \quad (۶)$$

ترم ε منطبق بر کمترین قدر مطلق است. SVR یک مدل رگرسیونی خطی را در ابعاد بالایی از فضای ویژگی‌ها با استفاده از ε غیرحساس اجرا می‌کند و سعی می‌کند که پیچیدگی مدل را با کمترین $\|W\|^2$ کاهش دهد. این مسئله می‌تواند به‌وسیله

جدول ۱- مهمترین توابع کرنلی (Willmott & Matsuura, 2005; Yassin et al., 2021)

Table 1. The most important kernel functions

| | Formula | Kernels |
|------|---|------------|
| (۸) | $k(u_i, v_j) = u_i \cdot v_j$ | Linear |
| (۹) | $k(u_i, v_j) = (1 + u_i \cdot v_j)^d$ | Polynomial |
| (۱۰) | $k(u_i, v_j) = \exp\left(-\frac{\ u_i - v_j\ ^2}{2\sigma^2}\right), \frac{1}{2\sigma^2} = \gamma$ | RBF |

و σ می‌توان دقت و صحت روش ماشین بردار پشتیبان را افزایش داد.

که k تابع کرنل، d عملکرد تابع برای کرنل چند جمله‌ای و σ انحراف معیار استاندارد است. با تنظیم مقادیر پارامترهای d

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (12)$$

برای ساده‌سازی، فرض شده است که در حال حاضر n نمونه از خطاهای مدل داریم که به صورت ذیل محاسبه شده‌اند:
 $(e_i = (e_p - e_s), i = 1, 2, \dots, n)$

نتایج و بحث

تحلیل آماری داده‌های هیدرولیکی رودخانه‌ها

نتایج تحلیل آماری داده‌های دبی جریان رودخانه‌های گرگانرود، اترک و قره‌سو برای سال‌های آماری ۹۴-۸۹ شامل میانگین، حداکثر، حداقل، چولگی و کشیدگی به ترتیب در جدول ۱ تا ۳ ارائه شده است.

در تحقیق حاضر ورودی‌های مدل‌ها عبارتند از اشل، سطح مقطع و شعاع هیدرولیکی می‌باشند.
مدل‌های تحلیل آماری

برای ارزیابی دقت مدل‌های یادگیری ماشین معمولاً از میانگین مطلق خطا (MAE) و ریشه دوم میانگین مربعات خطا (RMSE) استفاده می‌شود. اگرچه ویلموت و ماتسورا (Willmott & Matsuura, 2005) نشان دادند که RMSE شاخص خوبی برای بیان عملکرد متوسط مدل‌ها نبوده و ممکن است شاخصی گمراه‌کننده باشد، اما با توجه به گستردگی استفاده از این معیار، در تحقیق حاضر برای مقایسه مدل‌ها از هر دو معیار فوق‌الذکر استفاده شد. این دو معیار به صورت روابط ۱۱ و ۱۲ قابل محاسبه است:

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (11)$$

جدول ۲- مشخصات آماری دبی جریان در ایستگاه‌های رودخانه‌های گرگانرود، اترک و قره سو

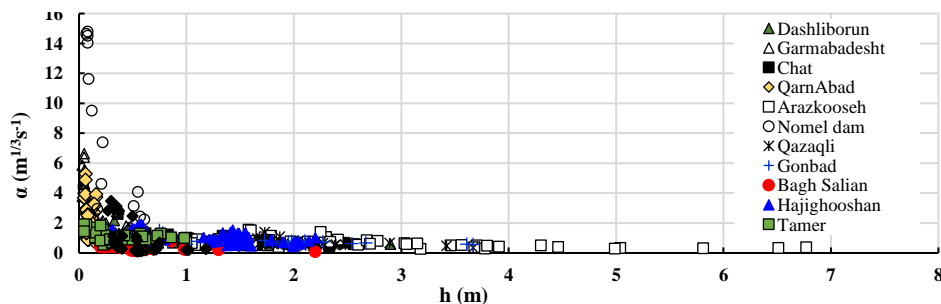
Table 2. Statistical characteristics of flow in Gorganrud, Etrak and Qarasoo rivers stations

| Mean (m ³ /s) (میانگین) | Max (m ³ /s) (حداکثر) | Min (m ³ /s) (حداقل) | Skewness (چولگی) | Kurtosis (کشیدگی) | Hydrometric Station |
|---------------------------------------|-------------------------------------|------------------------------------|------------------|-------------------|---------------------|
| 1.066 | 8.123 | 0.005 | 3.155 | 13.111 | Tamer |
| 8.247 | 72.825 | 0.053 | 2.800 | 8.675 | Arazkooseh |
| 2.960 | 2.025 | 0.002 | 6.917 | 0.942 | Hajighooshan |
| 2.925 | 19.047 | 0.039 | 2.916 | 9.385 | Qazaqli |
| 6.879 | 45.610 | 0.135 | 2.139 | 4.862 | Gonbad |
| 0.480 | 15.609 | 0.006 | 6.828 | 47.006 | Bagh Salian |
| 0.407 | 1.941 | 0.096 | 2.088 | 3.982 | Voshmgir Dam |
| 6.159 | 36.605 | 0.013 | 2.393 | 6.392 | Dashliboron |
| 1.625 | 22.506 | 0.006 | 4.710 | 23.729 | Chat |
| 0.138 | 1.144 | 0.011 | 4.201 | 20.733 | Garmabdasht |
| 0.123 | 0.302 | 0.038 | 1.193 | 1.894 | Qarnabad |
| 0.454 | 1.262 | 0.064 | 0.762 | -1.305 | Nomal Dam |

نتایج کوراتو و همکاران (۲۰۱۴) برای رودخانه‌های ایتالیا (شکل ۲) کاملاً همخوانی دارد. مقدار ضریب α در ناحیه مجانب برای تمامی ایستگاه‌های هیدرومتری حدود ۱-۰/۲ بدست آمده است که با نتایج کوراتو و همکاران (۲۰۱۴) که حدود ۰/۸-۰/۶ است مطابقت دارد. رفتار خاص پارامتر α با عمق جریان و به‌ویژه در عمق‌های بالای جریان، می‌تواند کاربردهای مناسبی در زمینه تخمین دبی سیلاب رودخانه‌ها فراهم نماید (Corato et al., 2014).

بررسی تغییرات پارامتر α با عمق جریان

در شکل ۶ تغییرات پارامتر α نسبت به عمق جریان در تمامی ایستگاه‌های هیدرومتری مورد مطالعه نشان داده شده است. همان‌طور که مشاهده می‌شود به‌ازای عمق‌های جریان تا حدود ۷ متر، مقدار این پارامتر در محدوده ۰ تا ۱۵ متغیر است. همچنین به‌وضوح مشخص است که با افزایش عمق جریان، پارامتر α سریعاً کاهش یافته و این کاهش در نهایت به‌صورت مجانب با محور افقی به یک عدد ثابت می‌رسد. این رفتار با



شکل ۶- تغییرات پارامتر α نسبت به عمق جریان برای تمامی ایستگاه‌های هیدرومتری مورد مطالعه

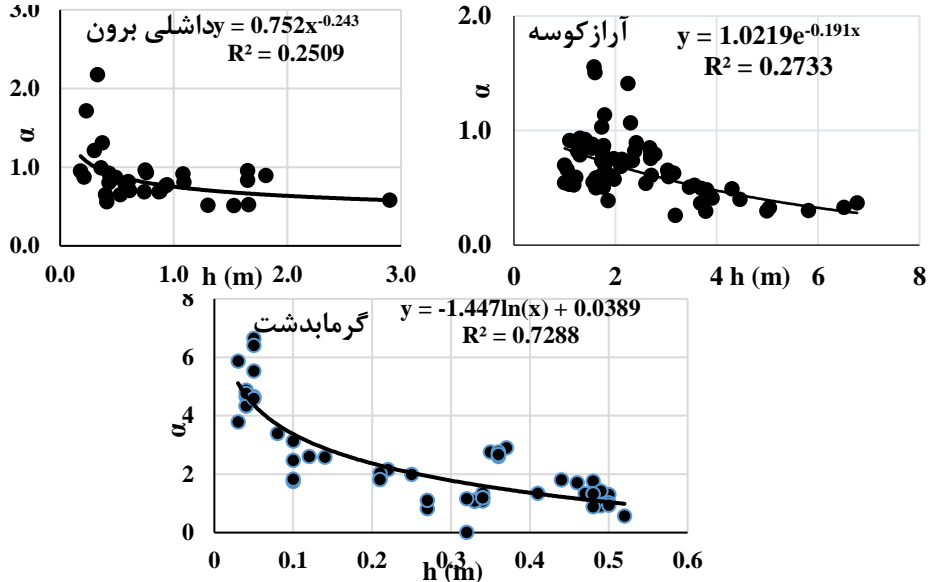
Figure 6. The changes of parameter α in relation to the flow depth for all studied hydrometric stations.

گرمابدشت (رودخانه قره‌سو) به‌عنوان نمونه در شکل ۷ ارائه شده‌اند. بررسی منحنی‌ها نشان می‌دهد که برای تمامی ایستگاه‌های مورد مطالعه، رفتار پارامتر α تقریباً یکسان است. برای استخراج رابطه‌ای ریاضی بین پارامتر α و عمق جریان در

برای بررسی بیشتر این رفتار، تغییرات پارامتر α نسبت به عمق جریان به‌صورت مجزا برای تمامی ایستگاه هیدرومتری محاسبه شد که منحنی‌های مرتبط با ۳ ایستگاه هیدرومتری آرازکوسه (رودخانه گرگانرود)، داشلی‌برون (رودخانه اترک) و

رگرسیون حدود 0.3 به دست آمد. به همین دلیل برای استخراج ارتباط دقیق‌تر بین پارامتر α و عمق جریان، از مدل‌های یادگیری ماشین استفاده خواهد شد.

این ایستگاه‌ها، از روابط مختلف رگرسیونی استفاده شد. همان‌طور که در شکل ۷ مشاهده می‌شود در اغلب ایستگاه‌های هیدرومتری، رابطه رگرسیونی دارای ضریب تعیین (R^2) بالایی نیست. ضریب تعیین برای اکثر این ایستگاه‌ها با بهترین مدل



شکل ۷- تغییرات پارامتر α نسبت به عمق جریان برای چند ایستگاه هیدرومتری

Figure 7. Changes of parameter α in relation to flow depth for several hydrometric stations

از کم‌آبی در طول سال جریان دارند که بیشتر فراوانی دبی آنها حدود یک مترمکعب بر ثانیه می‌باشد. طول زیاد دامنه منحنی توزیع احتمال بیانگر این است که سیلاب‌های این رودخانه‌ها، فصلی بوده و در چند روز رخ می‌دهند. این شکل نشان می‌دهد که برای عمق جریان و پارامتر α ، چولگی مثبت از راست می‌باشد.

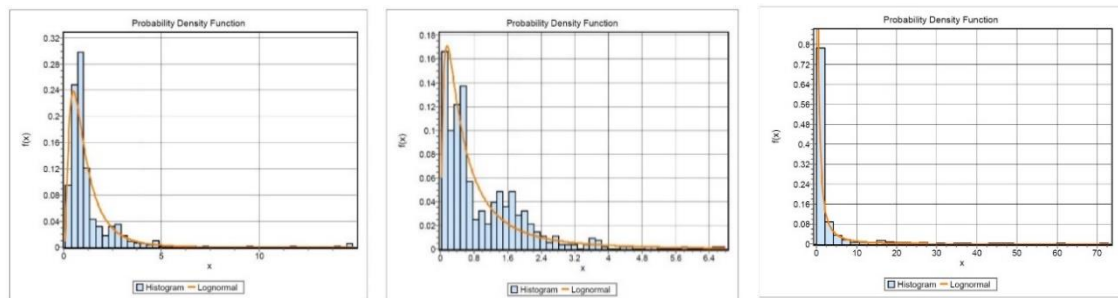
نتایج آزمون آماری نیکویی

نتایج مقادیر مربوط به آماره آزمون نیکویی برای دبی رودخانه‌های گرگانرود، اترک و قره‌سو در سطح اطمینان ۹۵٪ انجام شد. این نتایج در جدول ۳ و شکل ۸ ارائه شده است. مشخص شد که توزیع لوگ نرمال برای هر سه متغیر دبی جریان، عمق جریان و پارامتر α بهترین توزیع است. نتایج شکل ۸ نشان می‌دهد که رودخانه‌های دائمی مورد مطالعه با میزانی

جدول ۳- مقادیر مربوط به آماره آزمون نیکویی برای داده‌های دبی، عمق و پارامتر α

Table 3. Values related to goodness-of-fit test statistic for discharge, depth and α parameter data

| پارامتر | توزیع احتمالی | اندرون-دارلینگ | Anderson-Darling |
|----------|---------------|----------------|------------------|
| Q | Lognormal | 3.33 | 3.33 |
| | Normal | 123.58 | 123.58 |
| h | Lognormal | 5.62 | 5.62 |
| | Normal | 26.77 | 26.77 |
| α | Lognormal | 7.12 | 7.12 |
| | Normal | 76.52 | 76.52 |



شکل ۸- نمودار مربوط به شدت احتمال داده‌های دبی رودخانه، عمق جریان و پارامتر α

Figure 8. The diagram related to the probability intensity of river flow data, flow depth and α parameter

مدل به صورت مجزا و برای هر دو مرحله آموزش و آزمون در شکل ۹ ارائه شده است. تحلیل آماری نتایج هر سه مدل در جدول ۴ آمده است. نتایج حاکی از برتری مدل درختی در برآورد پارامتر α دارد. خطای مطلق این مدل حدود ۰/۳۴ و ضریب تعیین حدود ۰/۸۸ به دست آمده است.

در معماری مدل شبکه عصبی مصنوعی از سه لایه پنهان با ۹ نرون مخفی و در مرحله خروجی از تابع خطی استفاده گردید. همچنین در اجرای این مدل از تابع سیگموئید، الگوریتم لونیگ مارکورت و ۵۰۰۰ اپوک استفاده شد. برای اجرای مدل بردار رگرسیونی، تابع کرنل به صورت گوسی و مقادیر $\lambda = 1 \times 10^{-8}$ و $\epsilon = 0.01$ ، C درختی نیز حداقل ابعاد برگ‌ها و درختان به ترتیب ۵ و ۱۰ و حداقل مقدار خطا ۰/۰۱ انتخاب شدند.

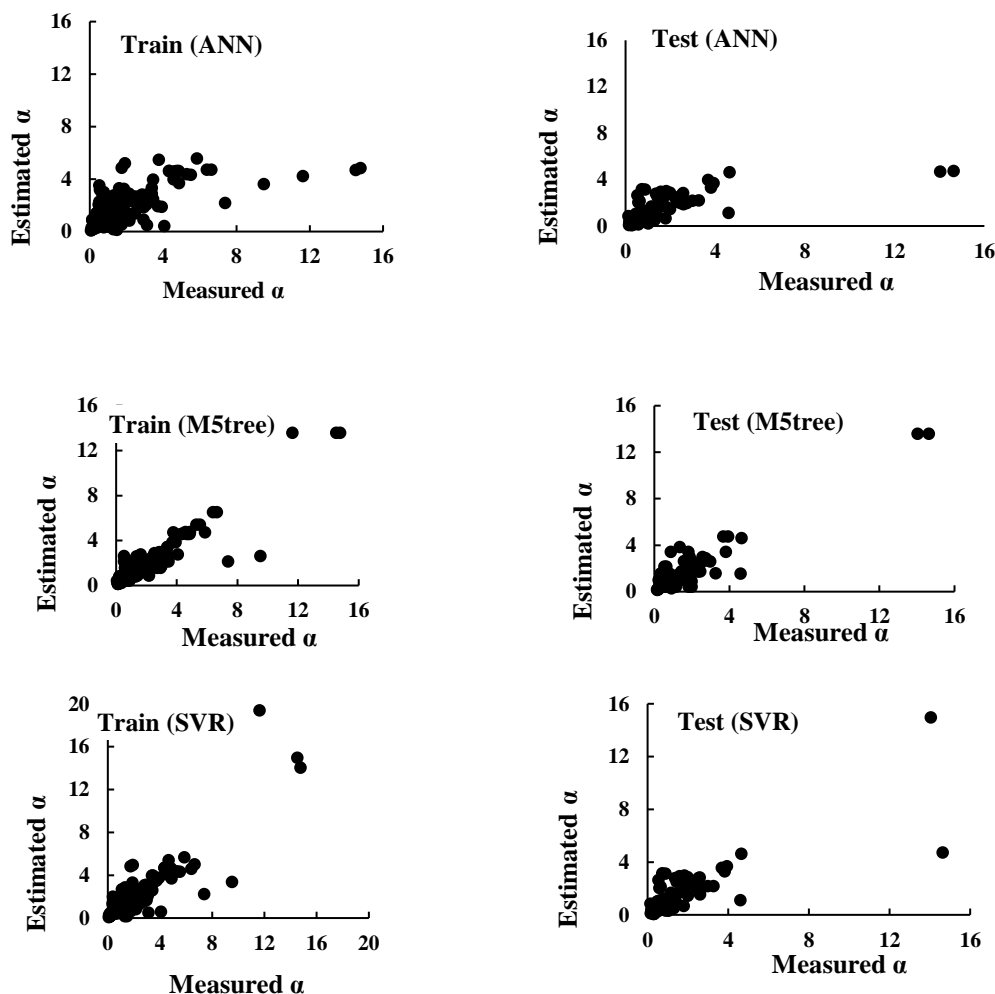
نتایج تخمین پارامتر α به کمک مدل‌های یادگیری ماشین با توجه به عدم کارایی روش‌های رگرسیونی در تخمین پارامتر α ، مدل‌های یادگیری ماشین مورد استفاده قرار گرفتند. مقدار دبی واقعی رودخانه در بخش آموزش با نتایج حاصل از مدل‌سازی با استفاده از مقادیر متنوع شیب زبری (α) که براساس تراز سطح آب، سطح مقطع و شعاع هیدرولیکی برآورد می‌گردد مقایسه شده است. ضریب زبری براساس یک فرآیند مدل‌سازی هوش مصنوعی تخمین زده می‌شود و در مدل‌سازی دبی با استفاده از روش‌های درختی، شبکه عصبی و رگرسیون بردار پشتیبان مورد استفاده قرار می‌گیرد.

داده‌ها به صورت تصادفی به دو بخش آموزش و آزمایش تقسیم شده است که ۷۰ درصد آن در بخش آموزش و ۳۰ درصد باقی‌مانده برای آزمایش مدل‌ها استفاده شد. نتایج این سه

جدول ۴- معیارهای ارزیابی مدل‌های یادگیری ماشین در برآورد پارامتر α (مرحله آزمون)

Table 4. Evaluation criteria of machine learning models in estimating α parameter (test stage)

| R ² | RMSE | MAE | Model |
|----------------|-------|-------|--------|
| 0.500 | 1.550 | 0.650 | ANN |
| 0.880 | 0.850 | 0.340 | M5tree |
| 0.660 | 1.170 | 0.480 | SVR |



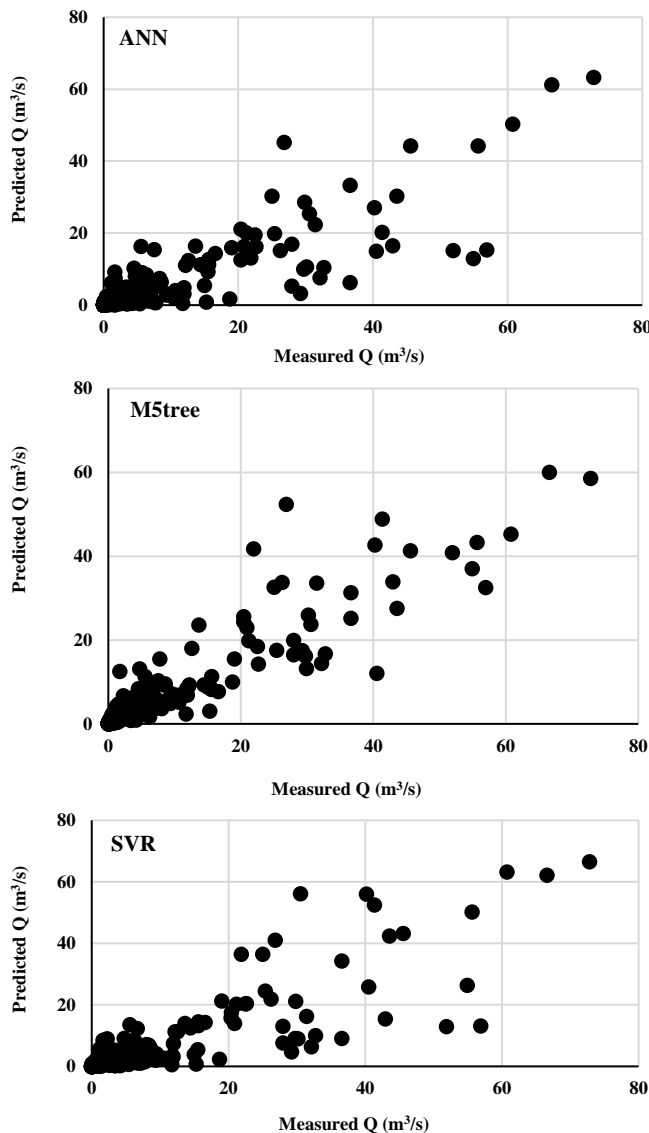
شکل ۹- تخمین پارامتر α با استفاده از مدل‌های ANN، M5tree و SVR در دو مرحله آموزش و آزمون مدل

Figure 9. Estimation of α parameter using ANN, M5tree and SVR models in two stages of model training and testing

شده و با مقدار واقعی مقایسه گردید. نتایج این مقایسه در جدول ۵ و شکل ۱۰ ارائه شده است. مقایسه مدل‌ها نشان می‌دهد که از لحاظ آماری، مدل M5tree در تخمین دبی جریان دارای دقت بالاتری است.

نتایج تخمین دبی سیلاب رودخانه به کمک مدل‌های یادگیری ماشین

پس از شبیه‌سازی پارامتر α با مدل‌های هوش مصنوعی، مقادیر دبی جریان رودخانه به‌ازاء عمق‌های مختلف محاسبه



شکل ۱۰- تخمین دبی جریان با استفاده از پارامتر α به کمک مدل‌های یادگیری ماشین

Figure 10. Estimation of flow rate using α parameter with the help of machine learning models

جدول ۵- نتایج معیارهای ارزیابی مدل‌های یادگیری ماشین در تخمین دبی جریان رودخانه (مرحله آزمون)

Table 5. The results of the evaluation criteria of machine learning models in river flow estimation (test stage)

| R ² | RMSE | MAE | Model |
|----------------|-------|-------|--------|
| 0.890 | 3.630 | 1.320 | M5tree |
| 0.780 | 5.090 | 1.720 | SVR |
| 0.790 | 4.880 | 1.580 | ANN |

مانینگ استوار است که برای محاسبه دبی جریان، به ضریب زبری مانینگ، مشخصات هندسی و هیدرولیکی رودخانه و شیب انرژی یا اصطکاکی نیازمند است. برآورد ضریب زبری مانینگ و شیب اصطکاکی رودخانه‌ها به‌ویژه در شرایط سیلاب دشوار بوده و با عدم قطعیت‌های زیادی مواجه است. به این منظور و

نتیجه‌گیری کلی

در این تحقیق با توجه به چالش عمده و فراگیری که در محاسبه دبی جریان‌های سیلابی در رودخانه‌ها وجود دارد، از یک ایده ساده هیدرولیکی برای تخمین دبی جریان در شرایط عادی و سیلابی استفاده شد. پایه و اساس این ایده بر فرمول

حدود ۰/۳ بود. برای افزایش دقت رابطه $(\alpha-h)$ ، از مدل‌های هوش مصنوعی یا یادگیری ماشین شامل شبکه‌های عصبی مصنوعی، مدل درختی و مدل ماشین بردار گرگسیون استفاده شد. برای اجرای این مدل‌ها از تراز سطح آب، سطح مقطع و شعاع هیدرولیکی به‌عنوان متغیر ورودی و پارامتر α به‌عنوان متغیر خروجی استفاده شد. نتایج هر سه مدل در مرحله آزمون بیانگر افزایش دقت نسبت به روش رگرسیون کلاسیک بود. این افزایش دقت در محدوده مقادیر کم پارامتر α که بیانگر شرایط سیلابی رودخانه است، قابل ملاحظه می‌باشد. از میان این سه مدل، مدل درختی با خطای مطلق ۰/۳۴، ضریب تعیین ۰/۸۸ و جذر میانگین خطای ۰/۸۵ بهترین برآورد پارامتر α را ارائه نموده است. در مدل درختی حداقل ابعاد برگ‌ها و درختان به ترتیب ۵ و ۱۰ و حداقل مقدار خطا ۰/۰۱ انتخاب شدند. با محاسبه پارامتر α ، دبی جریان رودخانه‌های مورد مطالعه در عمق‌های مختلف محاسبه شد و با مقادیر دبی‌های اندازه‌گیری شده مقایسه گردید. نتایج این مدل‌ها به‌جز مدل ماشین بردار گرگسیون حاکی از دقت مناسب آنها در تمام محدوده‌های عمق جریان (شرایط سیلابی و غیرسیلابی) است. خطای مطلق مدل‌های درختی و شبکه عصبی به ترتیب ۱/۳۲ و ۱/۵۸ به‌دست آمد. با توجه به دقت مناسب این مدل‌ها و به‌ویژه مدل درختی، توصیه می‌شود از نتایج این مدل در مطالعات مرتبط با سیلاب در رودخانه‌های واقعی استفاده شود.

برای کاهش این عدم قطعیت، در این تحقیق از یک پارامتر به‌نام α برای دخالت تاثیر توأم ضریب زبری مانینگ (بستر و کناره‌ها) و شیب اصطکاکی رودخانه استفاده شد. برای آزمون ایده پیشنهادی در رودخانه‌های استان گلستان، داده‌های هندسی، هیدرولیکی و شیب طولی ۱۲ ایستگاه هیدرومتری واقع بر سه رودخانه اصلی استان گلستان (رودخانه‌های اترک، گرگانرود و قره‌سو) جمع‌آوری شد و پارامتر α برای هر ایستگاه در تمامی عمق‌های جریان محاسبه شد. نتایج نشان داد که تغییرات این پارامتر نسبت به عمق جریان روندی کاهشی داشته و در عمق‌های بالا (بیانگر شرایط وقوع سیلاب)، این روند کاهشی، محسوس‌تر است. بر اساس این روند، مقادیر ضریب آلفا در بازه انتهایی منحنی $\alpha-h$ برای سه رودخانه اترک، گرگانرود و قره‌سو به ترتیب ۰/۰۶-۰/۵، ۰/۰۸-۰/۱ و ۰/۲-۱ به‌دست آمد. این مقادیر ضریب آلفا برای محاسبه دبی سیلاب رودخانه‌های موردنظر به‌کمک فرمول مانینگ تا حدودی قابل استفاده است. برای تعمیم این محاسبات برای تمامی عمق‌های جریان (سیلابی و غیرسیلابی)، لازم است رابطه‌ای بین پارامتر α و عمق جریان $(\alpha-h)$ استخراج شود. کاربرد روش رگرسیون غیرخطی کلاسیک نشان داد که این روش قادر به برقراری ارتباطی قوی و معنی‌دار بین پارامتر α و عمق جریان نمی‌باشد، به‌طوریکه ضریب تعیین (R^2) برای اغلب روابط به‌دست آمده $(\alpha-h)$ در ایستگاه‌های هیدرومتری

منابع

- Abril, J., & Knight, D. (2004). Stage-discharge prediction for rivers in flood applying a depth-averaged model. *Journal of Hydraulic Research*, 42(6), 616-629. <https://doi.org/10.1080/00221686.2004.9628315>
- Afsarian, F., Saber, A., Pourzangbar, A., Olabi, A. G., & Khanmohammadi, M. A. (2018). Analysis of recycled aggregates effect on energy conservation using M5' model tree algorithm. *Energy*, 156, 264-277. <https://doi.org/10.1016/j.energy.2018.05.099>
- Al Sawaf, M. B., & Kawanisi, K. (2020). Assessment of mountain river streamflow patterns and flood events using information and complexity measures. *Journal of Hydrology*, 590, 125508. <https://doi.org/10.1016/j.jhydrol.2020.125508>
- Ardiclioglu, M., Genc, O., Kalin, L., & Agiralioglu, N. (2012). Investigation of flow properties in natural streams using the entropy concept. *Water and Environment Journal*, 26(2), 147-154. <https://doi.org/10.1111/j.1747-6593.2011.00270.x>
- Bashirgonbad, M. (2022). Rainfall-runoff modeling to predict maximum daily flow under climate change conditions. *Journal of watershed management research*, 13(26), 115-124. <https://doi.org/10.52547/jwmr.13.26.115>
- Bjerklie, D. M., Dingman, S. L., Vorosmarty, C. J., Bolster, C. H., & Congalton, R. G. (2003). Evaluating the potential for measuring river discharge from space. *Journal of Hydrology*, 278(1-4), 17-38. [https://doi.org/10.1016/S0022-1694\(03\)00129-X](https://doi.org/10.1016/S0022-1694(03)00129-X)
- Braca, G., 2008. Stage-discharge relationships in open channels: Practices and problems. London, UK: Univ. degli Studi di Trento, Dipartimento di Ingegneria Civile e Ambientale: 1- 6.
- Choo, T., Maeng, S., Yoon, H., Kim, D., & Kim, S. (2012). A study on the derivation of a mean velocity formula from Chiu's velocity formula and bottom shear stress. *International Journal of Environmental Research*, 6(2), 537-546. <https://doi.org/10.22059/ijer.2012.523>
- Cook, A., & Merwade, V. (2009). Effect of topographic data, geometric configuration and modeling approach on flood inundation mapping. *Journal of Hydrology*, 377(1-2), 131-142. <https://doi.org/10.1016/j.jhydrol.2009.08.015>
- Corato, G., Ammari, A., & Moramarco, T. (2014). Conventional point-velocity records and surface velocity observations for estimating high flow discharge. *Entropy*, 16(10), 5546-5559. <https://doi.org/10.3390/e16105546>

- Demir, V., & Kisi, O. (2016). Flood hazard mapping by using geographic information system and hydraulic model: Mert River, Samsun, Turkey. *Advances in Meteorology*, 2016. <https://doi.org/10.1155/2016/4891015>.
- Deo, R. C., Downs, N., Parisi, A. V., Adamowski, J. F., & Quilty, J. M. (2017). Very short-term reactive forecasting of the solar ultraviolet index using an extreme learning machine integrated with the solar zenith angle. *Environmental research*, 155, 141-166. <https://doi.org/10.1016/j.envres.2017.01.035>
- EL Bilali, A., Taleb, A., EL Idrissi, B., Brouziyne, Y., & Mazigh, N. (2020). Comparison of a data-based model and a soil erosion model coupled with multiple linear regression for the prediction of reservoir sedimentation in a semi-arid environment. *Euro-Mediterranean Journal for Environmental Integration*, 5, 1-13. <https://doi.org/10.1007/s41207-020-00205-8>
- Eslami, S., & Hasanlou, M. (2019). Coral Reef modeling using Support Vector Regression and applying spectral indices. *Iranian journal of Marine technology*, 6(1), 31-44. <https://doi.org/20.1001.1.24236853.1398.6.1.3.3>
- García Nieto, P. J., García-Gonzalo, E., Bernardo Sánchez, A., & Rodríguez Miranda, A. (2018). Air quality modeling using the PSO-SVM-based approach, MLP neural network, and M5 model tree in the metropolitan area of Oviedo (Northern Spain). *Environmental Modeling & Assessment*, 23, 229-247. <https://doi.org/10.1007/S10666-017-9578-Y>.
- Goel, N., Then, H. H., & Arya, D. (2005). Flood hazard mapping in the lower part of Chindwin River Basin, Myanmar. In *International conference on innovation advances and implementation of flood forecasting technology*, 10, 17-19.
- Hasanpour Kashani, M., Daneshfaraz, R., Ghorbani, M., Najafi, M., & Kisi, O. (2015). Comparison of different methods for developing a stage-discharge curve of the Kizilirmak River. *Journal of Flood Risk Management*, 8(1), 71-86. <https://doi.org/10.1111/jfr3.12064>
- Hu, C., Ji, Z., & Guo, Q. (2010). Flow movement and sediment transport in compound channels. *Journal of Hydraulic Research*, 48(1), 23-32. <https://doi.org/10.1080/00221680903568600>
- Huai, W., Zeng, Y., Xu, Z., & Yang, Z. (2009). Three-layer model for vertical velocity distribution in open channel flow with submerged rigid vegetation. *Advances in Water Resources*, 32(4), 487-492. <https://doi.org/10.1016/j.advwatres.2008.11.014>.
- Kisi, O., Heddami, S., Keshtegar, B., Piri, J., & Adnan, R. M. (2022). Predicting daily streamflow in a cold climate using a novel data mining technique: radial M5 model tree. *Water*, 14(9), 1449. <https://doi.org/10.3390/w14091449>.
- Lee, T. H., & Georgakakos, K. P. (1996). Operational Rainfall Prediction on Meso- γ Scales for Hydrologic Applications. *Water Resources Research*, 32(4), 987-1003. <https://doi.org/10.1029/95WR03814>.
- 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>
- Lohani, A. K., Goel, N. K., & Bhatia, K. (2014). Improving real time flood forecasting using fuzzy inference system. *Journal of Hydrology*, 509, 25-41. <https://doi.org/10.1016/j.jhydrol.2013.11.021>
- Maity, R., Bhagwat, P. P., & Bhatnagar, A. (2010). Potential of support vector regression for prediction of monthly streamflow using endogenous property. *Hydrological Processes: An International Journal*, 24(7), 917-923. <https://doi.org/10.1002/hyp.7535>.
- Moramarco, T., & Singh, V. (2008). Streamflow measurements and discharge assessment during high flood events. *Hydrology and Hydraulics*, VP Singh, ed, 899. <https://doi.org/10.1186/s40562-018-0113-z>
- Mosavi, A., Bathla, Y., & Varkonyi-Koczy, A. (2018). Predicting the future using web knowledge: state of the art survey. In *International conference on global research and education*: 341-349. https://doi.org/10.1007/978-3-319-67459-9_42.
- Pham, H. T., Marshall, L., Johnson, F., & Sharma, A. (2018). Deriving daily water levels from satellite altimetry and land surface temperature for sparsely gauged catchments: A case study for the Mekong River. *Remote Sensing of Environment*, 212, 31-46. <https://doi.org/10.1016/j.rse.2018.04.034>
- Piri, J., Shamshirband, S., Petković, D., Tong, C. W., & ur Rehman, M. H. (2015). Prediction of the solar radiation on the earth using support vector regression technique. *Infrared Physics & Technology*, 68, 179-185. <https://doi.org/10.1016/j.infrared.2014.12.006>
- Quinlan, J. R. (1992). Learning with continuous classes. In *5th Australian joint conference on artificial intelligence*, 92: 343-348.
- Rokoni, A., Zhang, L., Soori, T., Hu, H., Wu, T., & Sun, Y. (2022). Learning new physical descriptors from reduced-order analysis of bubble dynamics in boiling heat transfer. *International Journal of Heat and Mass Transfer*, 186, 122501. <https://doi.org/10.1016/j.ijheatmasstransfer.2021.122501>.

- Sahu, M., Khatua, K., & Mahapatra, S. (2011). A neural network approach for prediction of discharge in straight compound open channel flow. *Flow Measurement and Instrumentation*, 22(5), 438-446. <https://doi.org/10.1016/j.flowmeasinst.2011.06.009>
- Sanz-Ramos, M., Bladé, E., González-Escalona, F., Olivares, G., & Aragón-Hernández, J. L. (2021). Interpreting the manning roughness coefficient in overland flow simulations with coupled hydrological-hydraulic distributed models. *Water*, 13(23), 3433. <https://doi.org/10.3390/w13233433>
- shukhy, S., & Mousavi, M. (2019). The Effect of Large-Scale Climatic Signals on Rainfall in Mazandaran Province. *Journal of watershed management research*, 10(20), 13-24. <https://doi.org/10.29252/jwmr.10.20.13>.
- Srinivasan, D. (2008). Energy demand prediction using GMDH networks. *Neurocomputing*, 72(1-3), 625-629. <https://doi.org/10.1016/j.neucom.2008.08.006>
- Tarpanelli, A., Barbetta, S., Brocca, L., & Moramarco, T. (2013). River discharge estimation by using altimetry data and simplified flood routing modeling. *Remote Sensing*, 5(9), 4145-4162. <https://doi.org/10.3390/rs5094145>
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82. <https://doi.org/10.3354/cr030079>
- Yassin, M., Asfaw, A., Speight, V., & Shucksmith, J. D. (2021). Evaluation of Data-Driven and Process-Based Real-Time Flow Forecasting Techniques for Informing Operation of Surface Water Abstraction. *Journal of Water Resources Planning and Management*, 147(7), 04021037. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001397](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001397)
- Zahiri, A., Dehghani, A., & Hezarjaribi, A. (2012). Determination of stage discharge curve for laboratory and river compound channels applying genetic algorithm. *Journal of Water and Soil Conservation*, 19(2), 179-192.