



تحقیقات آب و خاک ایران | دوره ۵۳ | شماره ۱ | فروردین ۱۴۰۱ (ص ۹۹-۱۱۲)

<https://dx.doi.org/10.22059/ijswr.2022.333131.669123>

(مقاله علمی - پژوهشی)

Investigation of the Effects of Hydraulic and Sedimentary Parameters on the Rate of Bed Load Transport Using Statistical Correlations and Machine Learning Methods

KIYOUMARS ROUSHANGAR¹, SAMIRA JOULAZADEH^{1*}

1. Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran.

(Received: Nov. 6, 2021- Revised: Jan. 31, 2022- Accepted: Feb. 6, 2022)

ABSTRACT

In hydraulic and river engineering, solid load sediment play an essential role in determining river behavior and morphological control; For this reason, the assessment and correct estimation of solid load sediment transport from a long time ago is one of the important issues in the sciences related to river engineering and the environment. The purpose of this study is to estimate the bed load transfer in 19 gravel-bed rivers. For this purpose, first the statistical correlation trend between sediment transport parameter (bed load discharge) and hydraulic and sedimentary parameters (flow discharge, flow depth, flow velocity, the median bed material particle diameter, Froude number,...) is investigated and the bed load discharge is estimated as a univariate regression function. According to the presented results, a favorable correlation was reached between the sediment transport parameter and hydraulic and sedimentary parameters and the results showed that these simple regression relationships in most rivers had acceptable accuracy. Also, the performance of 10 experimental formulas in bed load prediction was investigated. All formulas have had very poor results. For this reason, the parameters related to the formulas that had relatively better results than the other formulas were selected and, in order to increase the estimation accuracy, once again using two kernel-based machine learning methods: Support Vector Machine (SVM). Gaussian process regression (GPR) modeling was performed. The results showed that the machine methods have acceptable accuracy in predicting the bed load and the model is related to the parameters of Begnold formula, which includes the parameters of the stream power, the average flow depth and the median bed material particle diameter, with $R = 0.923$ and $NSE = 0.851$ has the best results in the machine methods.

Keywords: Sediment Prediction, Statistical Correlation, Experimental Formula, Support Vector Machine, Gaussian Process Regression.

* Corresponding Author's Email: kroshangar@yahoo.com

بررسی روند تأثیرات پارامترهای هیدرولیکی و رسوبی بر میزان انتقال بار بستر با استفاده از همبستگی‌های آماری و روش‌های یادگیری ماشین

کیومرث روشنگر*^۱ و سمیرا جولا زاده^۱

۱. گروه مهندسی آب، دانشکده عمران دانشگاه تبریز، تبریز، ایران

(تاریخ دریافت: ۱۴۰۰/۸/۱۵ - تاریخ بازنگری: ۱۴۰۰/۱۱/۱۱ - تاریخ تصویب: ۱۴۰۰/۱۱/۱۷)

چکیده

در مهندسی هیدرولیک و رودخانه، بارهای جامد رسوبی نقش اساسی را در تعیین رفتار رودخانه و کنترل مورفولوژی دارند؛ به همین دلیل ارزیابی و برآورد صحیح انتقال بار جامد رسوبی از دیرباز یکی از مسائل عمده و اصلی در علوم مرتبط با مهندسی رودخانه و محیط‌زیست می‌باشد. هدف از این تحقیق برآورد میزان انتقال بار بستر در ۱۹ رودخانه با بستر شنی می‌باشد. بدین منظور، ابتدا روند همبستگی آماری بین پارامتر انتقال رسوب (دبی بار بستر) و پارامترهای هیدرولیکی و رسوبی (دبی جریان، عمق جریان، سرعت متوسط جریان، قطر متوسط ذرات رسوب، عدد فرود و...) بررسی شده و دبی بار بستر به صورت تابع رگرسیونی تک‌متغیره برآورد می‌شود. مطابق نتایج ارائه شده به یک همبستگی مطلوبی بین پارامتر انتقال رسوب و پارامترهای هیدرولیکی و رسوبی رسیده شد و نتایج نشان داد این روابط رگرسیون ساده در اکثر رودخانه‌ها از دقت قابل‌قبولی برخوردار بوده است. ثانیاً، عملکرد ۱۰ رابطه تجربی در پیش‌بینی بار بستر مورد بررسی قرار گرفت. همه فرمول‌ها از نتایج خیلی ضعیفی برخوردار بوده‌اند؛ به همین دلیل پارامترهای مربوط به فرمول‌هایی که نتایج نسبتاً بهتری نسبت به فرمول‌های دیگر داشته‌اند، انتخاب شده و به منظور افزایش دقت برآورد، بار دیگر با استفاده از دو روش یادگیری ماشین مبتنی بر کرنل: ماشین بردار پشتیبان (SVM)، رگرسیون فرآیند گاوسی (GPR) مدل‌سازی انجام شد. نتایج حاصله نشان داد روش‌های ماشینی از دقت قابل‌قبولی در پیش‌بینی بار بستر برخوردار بوده‌اند و مدل مربوط به پارامترهای فرمول بگنولد که شامل پارامترهای قدرت جریان، عمق جریان و قطر متوسط ذرات رسوب می‌باشد، با دارا بودن ضریب همبستگی و شاخص نش - ساتکلیف به ترتیب برابر $R=0/923$ و $NSE=0/851$ برترین مدل حاصل از روش‌های ماشینی می‌باشد.

واژه‌های کلیدی: پیش‌بینی رسوب، همبستگی آماری، روابط تجربی، ماشین بردار پشتیبان، رگرسیون فرآیند گاوسی.

مقدمه

رسوب صورت گرفته است. اما آن‌ها هرگز به درجه جهانی برای استفاده در همه موارد نرسیدند. اغلب این فرمول‌ها به دلیل پیچیدگی مسئله تجربی، نیمه‌تجربی و گاهاً نظری از طریق اعمال برخی فرضیات ساده کننده می‌باشند. در این روش‌ها، دبی جامد به صورت تابعی از یک یا دو عامل غالب نظیر تنش برشی، سرعت متوسط جریان، شیب انرژی و دبی جریان ارائه شده است.


Barry *et al.* (2004) از داده‌های میدانی ۲۴ رودخانه برای ارزیابی عملکرد ۸ فرمول تجربی انتقال رسوب استفاده کرده؛ و نتایج نشان داده است که تفاوت اساسی در عملکرد فرمول‌ها وجود دارد، با این حال فرمول‌هایی که حاوی پارامتر آستانه حرکت برای انتقال بار بستر می‌باشد به طور معمول عملکرد ضعیف‌تری را از خود نشان می‌دهند. Zhang *et al.* (2010) با توجه به آزمایش‌ها انجام شده روی نرخ انتقال رسوب در ۱۴ رودخانه کوهستانی، دریافتند که نرخ انتقال بار بستر در واحد عرض با تغییرات ساختار بستر رودخانه و قدرت جریان در واحد عرض تغییر می‌کند؛

رودخانه یک سیستم پویا می‌باشد که توسط فرآیندهای هیدرولیکی و رسوبی کنترل می‌شود. با گذشت زمان، رودخانه به فرسایش و افزایش یا کاهش ظرفیت حمل رسوب در طول مسیر رودخانه پاسخ می‌دهد، همه این‌ها بر پایداری ساحل و مورفولوژی رودخانه تأثیر می‌گذارد. برای حفظ تحولات فرهنگی و اقتصادی در امتداد یک رودخانه، درک اصول انتقال رسوب برای کاربرد در مهندسی و مشکلات زیست‌محیطی مرتبط با وضعیت طبیعی و فعالیت‌های انسانی آن ضروری است. (Azamathulla *et al.*, 2009). حمل و نقل رسوبات یک پدیده بسیار پیچیده است و این واقعیت که بستر رودخانه‌ها از رسوبات با دانه‌بندی ضعیف تشکیل شده‌اند، مشکل را بیشتر می‌کند (Kitsikoudis *et al.*, 2014). در شرایط طبیعی، انتقال بار رسوب یک فرآیند پایدار نیست و تغییرات زمانی و مکانی فراوانی دارد (Batalla, 1997). تاکنون چندین تلاش برای یافتن رابطه‌ای برای پیش‌بینی میزان بار

انتقال رسوب در رودخانه‌های با بستر شنی دارد. Roushangar and Shahnazi (2020) در تحقیق دیگر، به ارزیابی عملکرد سه روش مبتنی بر کرنل: رگرسیون فرآیند گاوسی (GPR)، ماشین بردار پشتیبان (SVM) و یادگیری ماشین افراطی^۱ (KELM) در پیش‌بینی بار کل رسوب پرداختند. ورودی این سه مدل بر اساس دو سناریو انتخاب شده است. مطابق نتایج ارائه شده سناریو اول با در نظرگیری پارامترهای هیدرولیکی به‌عنوان ورودی، برآورد مطلوب‌تری از بار کل داشته است. همچنین مدل KELM با سه پارامتر ورودی: عدد فرود، نسبت سرعت متوسط به سرعت برشی و پارامتر شیلدز با مقدار ضریب نش - ساتکلیف $NSE=0.903$ مدل برتر بوده است. (Mahmoodzadeh et al. (2021) از چهار روش یادگیری ماشین عبارت‌اند از: SVM، GPR، شبکه عصبی مصنوعی (ANN) و رگرسیون خطی (LR) برای پیش‌بینی پارامتر زمین‌شناسی تعیین کیفیت سنگ (RQD) استفاده کردند نتایج مقایسه‌ها نشان می‌دهد که نتایج پیش‌بینی مدل GPR به‌طور کلی با نتایج واقعی مطابقت خوبی دارد. و GPR پیشنهادی، بهتر از روش‌ها SVM، ANN و LR عمل می‌کند. بررسی منابع مشخص می‌گردد که به دلیل کمبود داده‌های اندازه‌گیری شده برای رودخانه‌های شنی، تحقیقات انجام شده در این راستا محدود بوده و تحقیق چندانی در زمینه امکان‌سنجی کاربرد روش‌های هوشمند برای تخمین بار کل رسوب در رودخانه‌های شنی وجود ندارد. این در حالی است که پیچیدگی‌های حاکم بر پدیده انتقال رسوب، فرآیند پیش‌بینی با استفاده از روش‌های هوشمند و کلاسیک را در شرایط مختلف هیدرولیکی تحت تأثیر قرار داده و موجب کاهش دقت مدل‌سازی می‌شود؛ همچنین با توجه به گسترش به‌کارگیری روش‌های هوشمند در برآورد بار رسوبی رودخانه‌ها با شرایط هیدرولیکی و مورفولوژیکی مختلف، ارزیابی قابلیت این روش‌ها در برآورد بار بستر تحت این شرایط ضروری به نظر می‌رسد؛ لذا هدف از این مطالعه حاضر ارزیابی عملکرد دو روش یادگیری ماشین در پیش‌بار بستر ۱۹ رودخانه با بستر شنی می‌باشد. بدین منظور ابتدا با استفاده از تحلیل‌های همبستگی بین دبی بار بستر و پارامترهای هیدرولیکی و رسوبی، سعی شده است به یک رابطه ساده ریاضی که در آن دبی بار بستر به‌صورت یک تابع از یک متغیر هیدرولیکی و رسوبی تعریف شده، رسیده شود و پارامترهایی که بیشترین همبستگی را ارائه داده‌اند به‌عنوان ورودی شبکه‌های هوشمند استفاده شود. ثانیاً با استفاده از ۱۰ رابطه تجربی پرکاربرد به پیش‌بینی بار بستر پرداخته شده و پارامترهای فرمول‌هایی که نتایج بهتری نسبت بقیه فرمول‌ها ارائه داده‌اند انتخاب شده و به‌عنوان ورودی مدل‌های شبکه‌های

به‌طوری‌که با افزایش قدرت جریان در واحد عرض، میزان انتقال بار بستر به طرز چشمگیری افزایش می‌یابد. (Azamathulla et al. (2010) از روش ماشین بردار پشتیبان (SVM) به‌عنوان یک مدل جدید برای پیش‌بینی بار رسوب در سه رودخانه مالزی استفاده کردند. عملکرد روش SVM قابلیت پیش‌بینی آن و امکان تعمیم مدل به مسائل غیرخطی برای برنامه‌های مهندسی رودخانه را نشان می‌دهد. (López et al. (2013) از ۱۰ فرمول تجربی و یک رابطه رگرسیونی ساده بین دبی بار بستر و دبی جریان با $R^2=0.46$ برای پیش‌بینی بار بستر یک رودخانه بزرگ با بستر درشت‌دانه استفاده کردند. هیچ رابطه آشکاری بین قدرت پیش‌بینی و رویکرد نظری (دبی، قدرت جریان و احتمال) یافت نشده است. در تحقیق انجام‌شده توسط (Tarrío et al. (2015) ابتدا با تحلیل رگرسیونی ساده بین پارامتر انتقال بار بستر و تنش برشی مرزی به یک همبستگی خوبی با $R^2=0.847$ رسیده شده است. سپس عملکرد معادله پیش‌بینی بار بستر نسبت به این معادله ساده رگرسیونی و نسبت به مقادیر مشاهداتی، ارزیابی و مقایسه شده است. که به‌استثنای فرمول ویلکاک - کرو هیچ‌کدام از فرمول‌ها برآورد دقیقی از میزان انتقال رسوب نداشته‌اند. (Roushangar and Koosheh (2015) از روش SVM برای پیش‌بینی بار بستر در سه رودخانه با بستر شنی استفاده کردند و همچنین از الگوریتم ژنتیک به‌منظور بهینه‌سازی پارامترهای ورودی بهره بردند. در این تحقیق از چهار تابع کرنل برای مدل‌سازی استفاده شده است؛ که نتایج حاصل نشان می‌دهد مدل GA-SVM با تابع شعاعی نمایی (ERBF) دقت بالاتری نسبت به سایر مدل‌ها دارد. در تحقیق انجام شده توسط (Joudi and Sattari (2016) میزان بار رسوب معلق رودخانه صوفی چای، با استفاده از روش‌های سنتی مانند منحنی سنجه رسوب و با روش‌های مدرن ماشینی مبتنی بر توابع کرنل مانند رگرسیون فرآیند گاوسی و رگرسیون بردار پشتیبان برآورد شده است. نتایج نشان می‌دهد که هر دو روش بررسی شده در این مطالعه بهتر از روش‌های سنتی عمل می‌کنند. و در بین دو روش مذکور، روش رگرسیون فرآیند گاوسی با تابع کرنل پایه شعاعی نتایج قابل‌اطمینان‌تری را ارائه داده است. (Roushangar and Shahnazi (2019) از رگرسیون فرآیند گاوسی (GPR) و SVM برای پیش‌بینی میزان انتقال رسوب استفاده کردند. نتایج به‌دست‌آمده نشان داد که مدل‌های GPR در مقایسه با مدل‌های SVM و سایر فرمول‌های تجربی رسوب عملکرد بهتری دارند. و آنالیز حساسیت نشان داد که نسبت سرعت متوسط به سرعت جریان برشی مؤثرترین پارامتر بوده و عدد فرود به‌عنوان پارامتر ورودی در همه مدل‌های برتر نقش مهمی را در پیش‌بینی میزان

دارای بستر درشتی هستند که عمدتاً از شن و سنگریزه تشکیل شده‌اند. میانگین قطر متوسط مواد بستر سطحی بین ۰/۷۳ الی ۲/۹ میلی‌متر، متوسط دبی جریان از ۰/۵ الی ۴۰ مترمکعب بر ثانیه، مساحت حوضه آبریز از ۲۱ الی ۹۹۰ کیلومتر مربع و شیب متوسط از ۰/۰۰۲۵ الی ۰/۰۴۱۴ متغیر است. خلاصه‌ای از مشخصات داده‌های به‌کاررفته در این مطالعه در جدول (۱) ارائه شده است. بررسی جامع منطقه مورد مطالعه و جزئیات روش‌های به‌کاررفته برای اندازه‌گیری و جمع‌آوری داده‌های مختلف به تفصیل در تحقیقات (King et al. (2004 آمده است.



شکل ۱- منطقه مورد مطالعه

ماشینی استفاده خواهد شد. و در نهایت نتایج روش‌ها و مدل‌های ذکر شده مقایسه خواهد شد.

مواد و روش تحقیق

منطقه مورد مطالعه

در سال ۱۹۸۰، سازمان جنگل‌داری ایالات متحده^۱ با همکاری سازمان زمین‌شناسی آبرای درک بهتری از ماهیت انتقال رسوبات در رودخانه‌های منطقه آیداهو^۲، تعدادی ایستگاه اندازه‌گیری در مرکز و جنوب ایالت آیداهو به منظور اندازه‌گیری دبی آب و رسوب و سایر مشخصات هیدرولیکی و رسوبی رودخانه‌ها ایجاد نمودند. بخش اعظمی از این داده‌ها در بین سال‌های ۱۹۹۴ و ۲۰۰۰ اندازه‌گیری شده‌اند که شامل مقادیر مربوط به هندسه کانال، مشخصات هیدرولیکی و مشخصات رسوبی شامل بار بستر، بار معلق و قطر متوسط ذرات رسوبی (D₅₀) است. در این تحقیق نیز از داده‌های مربوط به این پایگاه داده که شامل ۱۱۰۸ داده^۴ مربوط به ۱۹ رودخانه می‌باشد، برای پیش‌بینی انتقال بار بستر استفاده خواهد شد. اهمیت این پایگاه داده به این دلیل می‌باشد که طیف وسیعی از ویژگی‌های جریان را شامل می‌شود. تمامی رودخانه‌های مورد مطالعه زیر حوضه رودخانه اسنیک^۴ بوده و از جریان‌ها و رودخانه‌های مختلفی با شرایط مختلف توپوگرافی، زمین‌شناسی، هیدرولیکی و رسوبی تشکیل شده است (شکل ۱). همه^۴ رودخانه‌ها

جدول ۱- مشخصات هیدرولیکی و رسوبی رودخانه‌های مورد مطالعه

نام رودخانه	تاریخ اندازه‌گیری (میلادی)	تعداد داده‌ها	مساحت حوضه آبریز (کیلومتر مربع)	شیب متوسط	بازه D ₅₀ بار بستر (میلی متر)	بازه دبی (متر مکعب بر ثانیه)
Big Wood	۱۹۹۹-۲۰۰۰	۳۸	۳۵۶/۱	۰/۰۰۹۱	۰/۷-۴۰/۷	۶/۰۳-۳۰/۸۷
Bruneau Final	۱۹۹۸-۲۰۰۲	۲۷	۹۸۹/۴	۰/۰۰۵۴	۰/۶۹-۳۴/۹۲	۴/۸۱-۲۰/۷۸
Fourth of July Creek	۱۹۹۴-۱۹۹۵	۳۹	۴۴/۳	۰/۰۲۰۲	۰/۳۸-۳/۱۱	۰/۱۵-۳/۸۸
Hawley Creek	۱۹۹۰-۱۹۹۶	۶۵	۱۰۹/۳	۰/۰۲۳۳	۰/۴۸-۹/۷۹	۰/۲۸-۲/۶۸
Herd Creek	۱۹۹۴-۱۹۹۵	۳۳	۲۸۴/۹	۰/۰۰۷۷	۰/۳-۹/۷	۰/۲۹-۸/۱۳
Jarbridge Final	۱۹۹۸-۲۰۰۲	۲۷	۷۹/۳	۰/۰۱۶	۰/۸۵-۳۵/۳۵	۱/۴۳-۱۱/۸۹
Johns Creek	۱۹۸۶-۱۹۹۵	۴۰	۲۹۲/۷	۰/۰۲۰۷	۰/۳۴-۵/۲۸	۰/۶-۲۱/۲۴
Little Slate Creek	۱۹۸۶-۱۹۹۷	۹۶	۱۶۳/۱	۰/۰۲۶۸	۰/۴۲-۱۷/۵	۰/۵۳-۱۸/۳۲
Lolo Creek	۱۹۸۲-۱۹۹۷	۴۷	۱۰۶/۳	۰/۰۰۹۷	۰/۴۶-۱۰/۲۳	۰/۷۶-۲۲/۹۱
Main Ford Red	۱۹۸۶-۱۹۹۹	۱۲۵	۱۲۸/۷	۰/۰۰۵۹	۰/۳۱-۳۸/۹۰	۰/۲۸-۱۸/۳۹
Marsh Creek	۱۹۹۴-۱۹۹۵	۴۲	۲۰۵/۹	۰/۰۰۶	۰/۶۹-۲۳/۳۶	۰/۸۵-۲۲/۵۴
Rapid	۱۹۸۶-۲۰۰۰	۱۱۶	۲۷۹/۷	۰/۰۱۰۸	۰/۳۱-۳۷/۲۰	۰/۹۱-۳۶/۸۱
Salmon near Obsidian	۱۹۹۹	۲۰	۲۴۶/۲	۰/۰۰۶	۰/۸۶-۱۰/۷۳	۷/۴۸-۲۰/۹۳
South Fork Red	۱۹۸۶-۱۹۹۹	۱۲۲	۹۸/۹	۰/۰۱۴۶	۰/۴۳-۴۰	۰/۱۷-۵/۳۸
South Fork Salmon	۱۹۸۵-۱۹۹۷	۵۱	۸۵۲/۹	۰/۰۰۲۵	۰/۵۴-۲/۲۹	۳/۸۸-۱۴/۹۵
Squaw Creek (USFS)	۱۹۹۱-۱۹۹۶	۳۸	۳۷	۰/۰۲۴	۰/۵۹-۵/۹۳	۰/۰۳-۱/۵۲
Squaw Creek (USGS)	۱۹۹۴-۱۹۹۵	۴۳	۱۸۵/۴	۰/۰۱	۲/۰۸-۱۰/۲۹	۰/۱۴-۱/۳۷
Thompson Creek	۱۹۹۴-۱۹۹۵	۴۰	۵۶/۵	۰/۰۱۵۳	۰/۳۹-۷/۰۷	۰/۲۳-۳/۵۱
Trapper Creek	۱۹۸۶-۱۹۹۷	۹۹	۲۰/۸	۰/۰۴۱۴	۰/۴۶-۶/۴۱	۰/۰۵-۳/۸۲

در این تحقیق به بررسی روند همبستگی بین دبی بار بستر و ۱۴

پارامترهای هیدرولیکی و رسوبی

ویلکاک - کرو (W-C)، وانگ و پارکر (W-P) و باتاچاریا و همکاران (Bt) به پیش‌بینی میزان انتقال بار بستر پرداخته می‌شود. نتایج حاصل از این ۱۰ فرمول با استفاده از شاخص اختلاف r ارزیابی شده است. شاخص r مطابق رابطه (۱) برابر است با نسبت مقدار پیش‌بینی شده به مقدار مشاهداتی (López et al., 2013)؛ به بیان دیگر، نسبت برآورد هر فرمول را نشان می‌دهد. به دلیل ماهیت منحصر به فرد هر رودخانه، عملکرد فرمول‌ها برای هر رودخانه به صورت جداگانه بررسی شده است. فرمول‌های مذکور به تفصیل در جدول (۲) شرح داده شده‌اند که در این جدول Q دبی جریان، Y عمق جریان، V سرعت متوسط جریان، D_{50} قطر متوسط ذرات رسوب، Fr عدد فرود، Re عدد رینولدز، S شیب بستر، τ تنش برشی بستر، Θ پارامتر شیلدز، U^* سرعت برشی، Fgr عدد فرود ذره، Re^* عدد رینولدز مرزی، ω قدرت جریان در واحد عرض، ω_c قدرت جریان بحرانی در ابتدای حرکت، K مقاومت بستر، K' مقاومت ناشی از زبری دانه‌ها، W^* نرخ بی‌بعد انتقال رسوب، D^* قطر بی‌بعد ذرات، T پارامتر حرکت و q_s دبی بار بستر بر حسب کیلوگرم بر ثانیه در واحد عرض می‌باشد.

$$r = \frac{Q_{pi}}{Q_{oi}} \quad (\text{رابطه ۱})$$

پارامتر مختلف هیدرولیکی و رسوبی به صورت مجزا پرداخته شده است. ۱۴ پارامتر به کاررفته عبارت‌اند از: دبی جریان (Q)، عمق جریان (Y)، سرعت متوسط جریان (V)، قطر متوسط ذرات رسوب (D_{50})، عدد فرود (Fr)، عدد رینولدز (Re)، شیب بستر (S)، تنش برشی بستر (τ)، پارامتر شیلدز (Θ)، سرعت برشی (U^*)، نسبت سرعت متوسط به سرعت برشی (V/U^*)، عدد فرود ذره (Fgr)، عدد رینولدز مرزی (Re^*) و قدرت جریان در واحد عرض (ω) می‌باشد. ابتدا سعی خواهد شد بین بستر دبی بار بستر و پارامترهای انتخاب شده به یک همبستگی قابل قبولی رسیده شود؛ سپس با استفاده از روابط ساده رگرسیونی که در آن دبی بار بستر به صورت تابعی از پارامتر هیدرولیکی یا رسوبی بیان می‌شود، به پیش‌بینی بار بستر پرداخته می‌شود. به دلیل ماهیت مختلف رودخانه‌های مختلف در انتقال رسوب، داده‌های ۱۹ رودخانه به صورت جداگانه تحلیل شده‌اند.

فرمول‌های تجربی

در این تحقیق با استفاده از ۱۰ فرمول بار بستر انتخاب شده از تحقیق (Khorram and Ergil (2010) که عبارت‌اند از: میر - پیتر و مولر (MP-M)، شوکلیچ (Sch)، اینشتین - براون (E-B)، روتنر (R)، بگنولد (B)، پارکر و همکاران (P-K-M)، ون راین (V)

جدول ۲- فرمول‌های بار بستر

فرمول	نام فرمول و تئوری	محدوده کاربرد
$q_s = 8 \left[\frac{\gamma_s}{\gamma_s - \gamma} \right] \left[\frac{g}{\gamma} \right]^{\frac{1}{2}} \left[\left(\frac{K'}{K} \right)^{\frac{3}{2}} \gamma R S - 0.047 (\gamma_s - \gamma) D_{50} \right]^{\frac{3}{2}}$	میر - پیتر و مولر ^۲ (۱۹۴۸) تئوری تعادل شیب انرژی	$0.4 \leq D_{50} \leq 30$ (mm) $0.25 \leq G_s \leq 3.2$ $\theta_{cr} = 0.047$ $1 \leq R_h \leq 120$ (cm) $0.25 \leq S_f \leq 3.2$
$q_s = 2.5 \rho_s \left[\frac{\gamma_s}{\gamma} \right]^{-1} S^{\frac{3}{2}} (q - q_c)$ $q_c = 0.26 \left[\frac{\gamma_s}{\gamma} - 1 \right]^{\frac{5}{3}} D_{50}^{\frac{3}{2}} S^{\frac{7}{6}}$	شوکلچ ^۳ (۱۹۵۰) تئوری دبی بحرانی	$0.305 \leq D_{50} \leq 7.02$ (mm) $0.24 \leq V \leq 1.37$ (m/s) $3.66 \times 10^{-5} \leq S_f \leq 0.017$
$q_s = \rho_s \left[\frac{\gamma_s - \gamma}{\gamma} g D_{50}^3 \right]^{\frac{1}{2}} \left[\left[\frac{2}{3} + \frac{36v^2}{g(s-1)D^3} \right]^{0.5} - \left[\frac{36v^2}{g(s-1)D^3} \right]^{0.5} \right] f'$ $f' = \begin{cases} 2.15 \exp\left(-\frac{0.391}{\theta}\right) & \theta < 0.182 \\ 40\theta^3 & \theta \geq 0.182 \end{cases}$	اینشتین - براون ^۴ (۱۹۵۰) تئوری احتمالاتی	$0.088 \leq D_{50} \leq 5.66$ (mm)
$q_s = \rho_s \left[\frac{\gamma_s - \gamma}{\gamma} g y^3 \right]^{\frac{1}{2}} \left[\frac{V}{\left[\frac{\gamma_s - \gamma}{\gamma} g y \right]^{\frac{1}{2}}} \left(\frac{2}{3} \left(\frac{D_{50}}{y} \right)^{\frac{2}{3}} + 0.14 \right) - 0.778 \left(\frac{D_{50}}{y} \right)^{\frac{2}{3}} \right]^3$	روتنر ^۵ (۱۹۵۹) تحلیل رگرسیونی	$0.088 \leq D_{50} \leq 45.3$ (mm)

$$q_s = q_{sr} \rho_s \frac{\rho_s}{\rho_s - \rho} \left[\frac{\omega - \omega_c}{(\omega - \omega_c)_r} \right]^{\frac{3}{2}} \left[\frac{y}{y_r} \right]^{-\frac{2}{3}} \left[\frac{D_{50}}{D_{50r}} \right]^{-\frac{1}{2}}$$

بگنولد^۱ (۱۹۸۰)

$$\omega = \rho y S V \quad , \quad \omega_c = 290 D_{50}^{\frac{3}{2}} \log \left(\frac{12y}{D_{50}} \right) \quad , \quad (\omega - \omega_c)_r = 0.5 \text{ km}^{-1} \text{ s}^{-1}$$

تئوری قدرت جریان

$$q_{sr} = 0.1 \text{ km}^{-1} \text{ s}^{-1} \quad , \quad y_r = 0.1 \text{ m} \quad , \quad D_{50r} = 0.0011 \text{ m.}$$

$0.088 \leq D_{50} \leq 1.41 \text{ (mm)}$

$$q_s = \frac{W^* u_*^3 \rho_s}{\left(\frac{y_s}{\gamma} - 1 \right) g} \quad , \quad \phi_{50} = \frac{\theta}{\theta_c} \quad , \quad \theta = \frac{\gamma R S}{(\gamma_s - \gamma) D_{50}} \quad , \quad \theta_c = 0.0876$$

$$W^* = \begin{cases} 11.2 \left(1 - \frac{0.822}{\phi_{50}} \right)^{4.5} & \phi_{50} > 1.65 \\ 0.0025 \exp[14.2(\phi_{50} - 1) - 9.28(\phi_{50} - 1)^2] & 0.95 < \phi_{50} < 1.65 \\ 0.0025 \phi_{50}^{14.2} & \phi_{50} < 0.95 \end{cases}$$

پارکر و همکارانش^۲ (۱۹۸۲)

تئوری
جابه‌جایی مساوری

$2 \leq D_{50} < 45.3 \text{ (mm)}$
 $\theta_{cr} = 0.0876$
 $0.003 < S_f$

$$q_s = 0.053 \rho_s \left[\frac{y_s - \gamma}{\gamma} g D_{50}^3 \right]^{\frac{1}{2}} T_*^{2.1} \quad , \quad T_* = \frac{\theta - \theta_c}{\theta_c} \quad , \quad \theta = \frac{\gamma R S}{(\gamma_s - \gamma) D_{50}} \quad , \quad D_* = D_{50} \left[\frac{(\gamma_s - \gamma) g}{v^2} \right]^{1/3}$$

ون راین^۳ (۱۹۸۴)

تحلیل رگرسیونی

$0.2 \leq D_{50} \leq 2 \text{ (mm)}$
 $0.9 > Fr$
 $0.31 \leq V \leq 1.29 \text{ (m/s)}$
 $0.1 \leq R_h \leq 1 \text{ (m)}$
 $0.001 \leq S_f \leq 0.01$

$$q_s = \frac{W^* u_*^3 \rho_s}{\left(\frac{y_s}{\gamma} - 1 \right) g} \quad \phi_{50} = \frac{\theta}{\theta_c} \quad , \quad \theta = \frac{\gamma R S}{(\gamma_s - \gamma) D_{50}}$$

$$W^* = \begin{cases} 14 \left(1 - \frac{0.894}{\phi_{50}^{0.5}} \right)^{4.5} & \phi_{50} \geq 1.35 \\ 0.002 \phi_{50}^{7.5} & \phi_{50} < 1.35 \end{cases}$$

ویلکاک - کرو^۴ (۲۰۰۳)

تئوری
جابه‌جایی مساوری

$2 \leq D_{50} \leq 45.3 \text{ (mm)}$

$$q_s = 4.93 \rho_s \left[\frac{y_s - \gamma}{\gamma} g D_{50}^3 \right]^{\frac{1}{2}} \left[\frac{\gamma R S}{(\gamma_s - \gamma) D_{50}} - 0.047 \right]^{1.6}$$

وانگ - پارکر^۵ (۲۰۰۶)

تئوری تنش برشی

$0.088 \leq D_{50} \leq 4 \text{ (mm)}$

$$q_s = \rho_s \left[\frac{y_s - \gamma}{\gamma} g D_{50}^3 \right]^{\frac{1}{2}} \Phi_b \quad T_* = \frac{\theta - \theta_c}{\theta_c} \quad , \quad \theta = \frac{\gamma R S}{(\gamma_s - \gamma) D_{50}}$$

$$\Phi_b = \begin{cases} 0.072078 \frac{T_*^{0.893}}{D_*^{0.353}} & T_* > 0.04 \\ 0.000182 \frac{T_*^{0.13}}{D_*^{0.0673}} & T_* \leq 0.04 \text{ \& } D_* \leq 181.3 \\ 0.0000124 \frac{T_*^{0.13}}{D_*^{0.0673}} & T_* \leq 0.04 \text{ \& } D_* > 181.3 \end{cases}$$

باتاچاریا و همکاران^۶ (۲۰۰۷)

تحلیل رگرسیونی و یادگیری
ماشین

$0.088 \leq D_{50} \leq 5.66 \text{ (mm)}$

شده در اثر ذره را مشخص می‌کند. که در این تحقیق با فرض نبودن فرم بستر ضریب $\frac{K^*}{K}$ برابر واحد در نظر گرفته می‌شود. رابطه شوکلیچ از دبی بحرانی برای پیش‌بینی بار بستر بهره می‌جوید. دبی بحرانی، دبی است که تحت آن مواد بستر در آستانه‌ی حرکت قرار دارند. در رابطه سوم، اینشتین بر مبنای اصول فیزیک سعی کرد تا رابطه‌ای برای محاسبه میزان بار بستر ارائه دهد. در این روش اولاً از اصل آستانه حرکت در به‌وجود آوردن رابطه اجتناب

مطابق جدول (۲)، رابطه میر - پیتر و مولر، رابطه مبتنی بر داده‌های آزمایشگاهی و با ملحوظ داشتن ضریب $\frac{K^*}{K}$ که در این رابطه تأثیر فرم بستر را در نظر می‌گیرد، ارائه شده است. در حقیقت شیب خط انرژی S_f میزان استهلاک انرژی را مشخص می‌کند. با فرض این که حمل بار بستر متناسب با میزان انرژی مستهلک شده در اثر ذره می‌باشد و نه با میزان انرژی مستهلک شده در اثر فرم بستر، در آن صورت $\frac{K^*}{K} S_f$ میزان انرژی مستهلک

2. Bagnold
3. Parker et al.
4. Van Rijn
5. Wilcock and Crowe
6. Wong and Parker
7. Bhattacharya et al.

شده است و ثانیاً میزان حمل بار بستر به شدت جریان درهم و تغییرات آن ربط داده شده است و نه به میزان متوسط نیروهایی که به ذره وارد می‌شود. از این رو در این روش آستانه‌ی حرکت ذرات بر مبنای احتمالات می‌باشد. فرمول روتنر معادله ساده‌ای بر اساس تحلیل ابعادی و با در نظر گیری چند ضریب تجربی ارائه داده است. بگنولد، فرمول انتقال رسوبات بستر را بر اساس مفاهیم تعادل انرژی توسعه داد. وی اظهار داشت که قدرت موجود جریان، انرژی لازم انتقال رسوبات بستر را تأمین می‌کند. معادله پارکر و همکارانش از محدود روابطی است که از داده‌های میدانی بدست آمده است. دو رابطه پارکر - همکارانش و ویلکاک - کرو بر اساس اندازه متوسط ذرات لایه زیرین بستر استوار است. از مزایای این رویکرد، عدم نیاز به وجود آستانه برای انتقال رسوب می‌باشد. ون راین با انجام تحلیل رگرسیونی و ارزیابی ۶۰۰ داده آزمایشگاهی، معادله‌ای را به صورت تابعی از قطر بی‌بعد ذرات D^* و پارامتر حرکت T پیشنهاد دادند. وانگ - پارکر معادله‌ای را بر اساس معادله میر - پیتر و مولر توسعه دادند؛ آن‌ها ضریب مربوط به مقاومت ناشی از زبری بستر را ضریبی غیر ضروری برای پیش‌بینی انتقال بار بستر دانسته و در غیاب این ضریب به نتایج بهتری رسیدند. و در نهایت با تغییر ضرایب ثابت مربوط به معادله میر - پیتر و مولر معادله جدیدی را ارائه دادند. باتاچاریا و همکارانش از دو روش یادگیری ماشین شامل شبکه عصبی مصنوعی و مدل درختی برای مدل‌سازی انتقال بار بستر استفاده کردند. داده‌های ورودی این مدل‌ها با استفاده از تحلیل‌های رگرسیونی متناسب سازی شده‌اند. و در نهایت منجر به ایجاد چند روابط ساده ریاضی شده است.

رگرسیون فرآیند گاوسی

روش‌های رگرسیون به‌عنوان یکی از روش‌های نوین بهینه‌سازی مدل‌های غیرخطی مورد استفاده بوده و کاربردهای فراوانی دارد. رگرسیون یعنی بازگشت، یعنی پیش‌بینی و بیان تغییرات یک متغیر بر اساس اطلاعات متغیر دیگر است و مدل‌های رگرسیون فرآیند گاوسی بر مبنای این فرض هستند که مشاهدات تنظیم باید حامل اطلاعاتی درباره‌ی همدیگر باشد. فرآیندهای گاوسی راهی برای مشخص کردن اولییتی به صورت مستقیم روی فضای تابع هستند. این کار تعمیم طبیعی توزیع گاوسی است که به طور کامل توسط میانگین $m(x)$ و تابع کواریانس خود $cov(x, x')$ که به ترتیب یک بردار و ماتریس است تعریف می‌شود. توزیع گاوسی روی بردارها است درحالی‌که فرآیند گاوسی روی توابع است و در نتیجه، مدل‌های فرآیند گاوسی به دلیل دانش قبلی درباره‌ی وابستگی‌های تابعی و داده‌ها، برای تعمیم، به هیچ فرآیند

$$y = f(x(k)) + \xi \quad \text{(رابطه ۲)}$$

که در رابطه فوق، x و y به ترتیب نشان دهنده‌ی دامنه‌ای از ورودی‌ها و خروجی‌ها، f تابع وابسته مجهول و ξ مقدار نویز گاوسی با واریانس σ^2 می‌باشد. پس از تعیین میانگین و کواریانس، پیش‌بینی متغیرهای خروجی برای نمونه از متغیرهای ورودی x_* به صورت توزیع گاوسی پیش‌بینی شده $p(y_*|X_*, y_*, x_*)$ با میانگین و تابع کواریانس به شکل زیر ارائه می‌شود:

(رابطه ۳)

$$\hat{y}_* = m(x_*) + K_*^T (K + \sigma_n^2 I)^{-1} (y - m(x_*)) \quad \text{(رابطه ۴)}$$

که در روابط فوق، K ماتریس کواریانس و I ماتریس همانی می‌باشند. باتوجه به رابطه بالا، مشاهده می‌شود که فرآیند پیش‌بینی مبتنی بر آموزش داده‌های x و y بوده که در تضاد با روش‌های مرسوم رگرسیون می‌باشد و در آن‌ها فقط از پارامترها به منظور پیش‌بینی مسئله مورد نظر استفاده می‌گردد. به منظور پیش‌بینی دقیق، پارامترهای میانگین و تابع کواریانس بایستی از روی داده‌های موجود تخمین زده شوند که به آن‌ها هایپر پارامتر گفته می‌شود. هایپر پارامترها در واقع تعریف کننده ویژگی‌های توزیع احتمال پیش‌بینی می‌باشند. مقادیر پارامترها معمولاً با بیشینه‌سازی $\log p(y|X)$ که درست نمایی بر حسب لگاریتم می‌باشد، به دست می‌آید (Rasmussen and William, 2006).

(رابطه ۵)

$$\log p(y|X) = -\frac{1}{2} y^T (K + \sigma^2 I)^{-1} y - \frac{1}{2} \log |K + \sigma^2 I| - \frac{n}{2} \log(2\pi)$$

ماشین بردار پشتیبان

مدل ماشین بردار پشتیبان (SVM) اولین بار توسط Vapnik (1995) برای حل مسائل طبقه‌بندی اطلاعات و طبقه‌بندی مجموعه داده‌ها مطرح شده و سپس برای حل مسائل رگرسیون غیرخطی و تخمین چگالی توسعه داده شده است (Kumar, 2009). در روش SVM ابتدا کل داده‌ها به دو دسته آموزش و آزمون جدا می‌شوند؛ هر نمونه‌ای از داده‌های مجموعه آموزش دارای یک مقدار هدف x و چندین ویژگی d (ویژگی یا متغیر مشاهداتی) می‌باشد. هدف در روش SVM ایجاد مدلی بر اساس داده‌های آموزش است؛ به طوری که بتوان مقادیر هدف داده‌های

و خطا بهینه می‌شوند.

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i, x_j\|^2}{2\gamma^2}\right) \quad (\text{رابطه ۹})$$

روند آموزش

یکی از مراحل پیش‌پردازش داده‌ها، نرمال‌سازی آن‌ها می‌باشد که می‌تواند باعث افزایش کارایی مدل‌های هوشمند باشد. وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود لذا نرمالیزه کردن داده‌ها خصوصاً زمانی که دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. به همین دلیل در این تحقیق ابتدا داده‌ها به روش (Legates and McCabe, 1999) در بازه ۰,۱ و ۱ مطابق رابطه (۱۰) نرمال‌سازی می‌شود. نرمالیزه کردن داده‌ها تنها محدوده (مقیاس) داده‌ها را عوض می‌کند و پس از مدل‌سازی کردن می‌توان آن‌ها را به محدوده واقعی برگرداند. برای رسیدن به نتایج بهتر و دقیق‌تر روند آموزش چند بار تکرار گردیده و در نهایت ۷۵ درصد داده‌ها برای آموزش مدل و ۲۵ درصد نیز برای قسمت صحت‌سنجی استفاده شده است.

$$x_n = 0.1 + 0.9 \times \frac{(x - x_{min})}{x_{max} - x_{min}} \quad (\text{رابطه ۱۰})$$

در این رابطه x_{min} و x_{max} به ترتیب حداقل و حداکثر داده‌ها و x_n داده‌ها نرمال شده می‌باشد.

به منظور ارزیابی مدل‌ها و پیش‌بینی دقیق آن‌ها، شاخص‌های آماری مختلفی تدوین شده است. که در این تحقیق پرکاربردترین آنها عبارت‌اند از: ضریب همبستگی (R)، شاخص نش - ساتکلیف (NSE) و جذر میانگین مربعات خطاها (RMSE) مورد استفاده قرار خواهند گرفت. که هرچقدر R و NSE بیشتر و به یک نزدیک‌تر و برعکس RMSE کمتر و به صفر نزدیک‌تر باشد بیانگر مطلوب بودن مدل و دقت قابل قبول آن می‌باشد.

(رابطه ۱۱)

$$R = \frac{\sum_{i=1}^n (Q_{oi} - Q_{om}) \times (Q_{pi} - Q_{pm})}{\sqrt{\sum_{i=1}^n (Q_{oi} - Q_{om})^2 \times \sum_{i=1}^n (Q_{pi} - Q_{pm})^2}} \quad (\text{رابطه ۱۲})$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{oi} - Q_{pi})^2}{n}} \quad (\text{رابطه ۱۳})$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{oi} - Q_{pi})^2}{\sum_{i=1}^n (Q_{oi} - Q_{om})^2}$$

در روابط ذکر شده Q_{oi} بیانگر مقادیر مشاهداتی، Q_{pi} مقادیر پیش‌بینی شده، Q_{om} میانگین مقادیر مشاهداتی، Q_{pm} میانگین

آزمون (x) را از روی ویژگی‌های داده‌های آزمون (d) پیش‌بینی کرد. ایده اصلی SVM برای رگرسیون، انتقال غیرخطی داده‌های اصلی x در یک فضای با ابعاد بالاتر و اعمال یک رگرسیون خطی در فضای ویژگی‌ها است. با توجه به مجموعه داده‌های آموزش $\{(x_i, d_i)\}_i^N$ که N تعداد الگوهای داده‌ها است؛ تابع کلی رگرسیون SVM به شرح زیر است:

$$f(x) = w\varphi(x) + b \quad (\text{رابطه ۶})$$

که w بردار وزن، b ثابت بایز و $\varphi(x)$ یک تابع انتقال غیرخطی از ویژگی‌های ورودی x می‌باشد. متغیرهای w و b را می‌توان با بهینه‌سازی تابع خطا رابطه (۷) و اعمال محدودیت‌های رابطه (۸) پیش‌بینی کرد (Wang, 2013).

(رابطه ۷)

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (\text{رابطه ۸})$$

$$\left. \begin{aligned} w_i \varphi(x_i) + b_i - d_i &\leq \varepsilon + \xi_i^* \\ d_i - w_i \varphi(x_i) + b_i &\leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \right\} \quad i=1, \dots, N$$


که در این روابط، C تابع جریمه، ξ_i^* و ξ_i ضرایب کمبود می‌باشند. در روش ماشین بردار پشتیبان، برای تفکیک خطی داده‌ها، متغیرهای ورودی x به یک فضای با ابعاد بیشتر منتقل می‌شوند، که در این فضا از نظر تئوری یک رگرسیون خطی ساده می‌تواند با رگرسیون پیچیده غیرخطی فضای ورودی مقابله کند (Vapnik, 1995). برای این انتقال، تابعی غیرخطی به نام تابع کرنل^۴ به صورت، $K(x_i, x_j) = \varphi_i \times \varphi_j$ تعریف می‌شود. در رگرسیون فرآیند گاوسی نیز، تابع کواریانس مفهومی مشابه با تابع کرنل در روش ماشین بردار پشتیبان دارد. بر اساس تحقیقات قبلی، از میان توابع کرنل مختلف، تابع پایه شعاعی (RBF) مطابق رابطه (۹) مطلوب‌ترین عملکرد را داشته است (Pal et al., 2014; Dibikey et al., 2001; Roushangar and Ghasempour, 2017; Azamathulla et al., 2016) به همین دلیل در این تحقیق نیز از تابع کرنل پایه شعاعی استفاده خواهد شد. هر دو روش ماشین بردار پشتیبان و رگرسیون فرآیند گاوسی در محیط نرم افزار Matlab کدنویسی شده و اجرا شده‌اند. در روش SVM، انتخاب سه پارامتر حداکثر حاشیه اطمینان ε ، پارامتر جریمه C و از همه مهم‌تر پارامتر تابع کرنل λ و در روش GPR انتخاب دو پارامتر، تابع کرنل و مقدار نویز گاوسی تأثیر زیادی در دقت پیش‌بینی مدل دارند؛ این پارامترها برای افزایش دقت مدل‌ها به روش سعی

مقادیر پیش‌بینی شده و n تعداد کل داده‌ها می‌باشد.

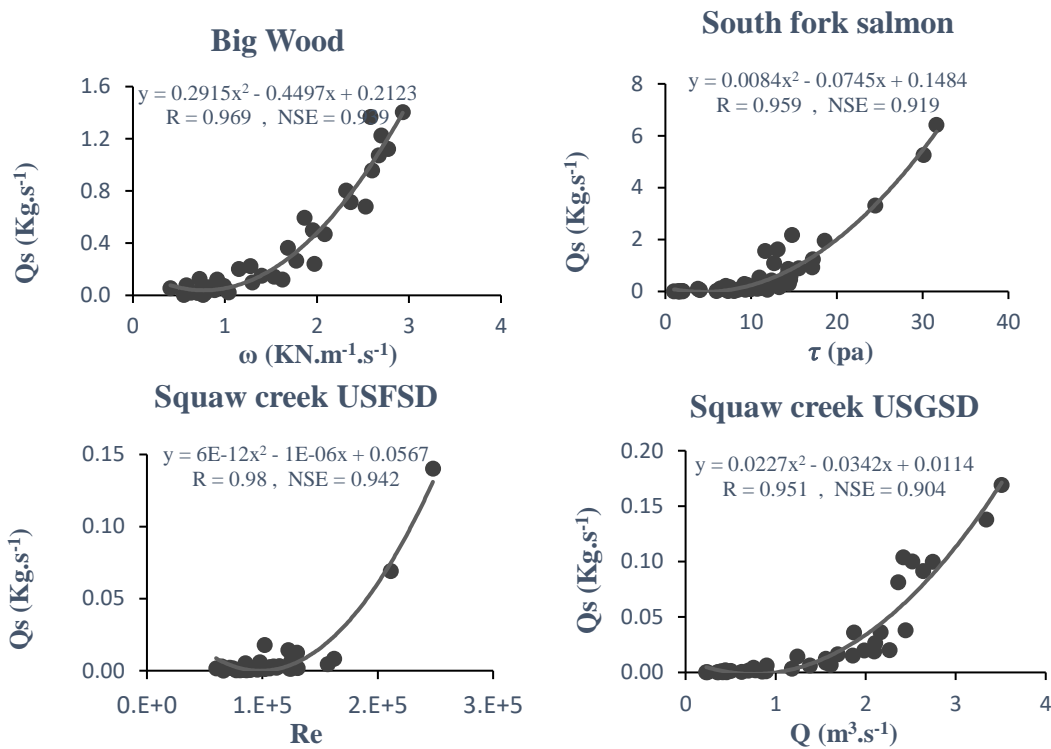
نتایج و بحث

در شکل (۲) نمودار مربوط به نتایج همبستگی بین پارامتر انتقال رسوب و پارامترهای هیدرولیکی و رسوبی برای ۱۹ رودخانه نمایش داده شده است. در نمودار مذکور برای هر رودخانه پارامتری که بیشترین همبستگی را با دبی بار بستر داشته است انتخاب شده و همراه با ضریب همبستگی مربوطه نمایش داده شده است. در اکثر رودخانه‌ها، تابع رگرسیون چندجمله‌ای درجه‌دو از بهترین نتایج برخوردار بوده است. به همین دلیل تمامی توابع به‌کاررفته در این قسمت از نوع تابع چندجمله‌ای درجه‌دو انتخاب شده است. برای ارزیابی نتایج از شاخص‌های R و NSE استفاده شده است. همان‌طور که قابل مشاهده است در اکثر رودخانه‌های مورد مطالعه به یک همبستگی مطلوبی بین پارامتر انتقال رسوب و پارامترهای هیدرولیکی و رسوبی رسیده شده است و نتایج نشان می‌دهد این روابط رگرسیون ساده دقت قابل‌قبولی را در پیش‌بینی بار بستر

داشته‌اند. از میان ۱۴ پارامتر ذکر شده چهار پارامتر دبی جریان (Q)، عدد رینولدز (Re)، تنش برشی بستر (τ) و قدرت جریان در واحد عرض (ω) بیشترین همبستگی را با دبی بار بستر ارائه داده‌اند. به‌طوری‌که دبی بار بستر در ۵ رودخانه ضریب همبستگی بالاتر از ۰/۸ با دبی بار بستر داشته است. عدد رینولدز در دو رودخانه بیشترین همبستگی را با دبی بار بستر داشته به‌طوری‌که در رودخانه (USFSD) Squaw creek این ضریب به مقدار ۰/۹۸ نیز رسیده است. تنش برشی بستر در دو رودخانه مورد مطالعه ضریب همبستگی بالاتر از ۰/۹ را ارائه داده است و پارامتر قدرت جریان در واحد عرض در ۴ رودخانه بیشترین همبستگی را با دبی بار بستر داشته و در اکثر رودخانه‌ها ضریب همبستگی بالاتر از ۰/۸ را با دبی بار بستر ارائه داده است. نمودار مربوط به پراکندگی داده‌های بار بستر نسبت به ۴ پارامتر مذکور برای رودخانه‌هایی که در آن‌ها دبی بار بستر بیشترین همبستگی را با پارامترهای مذکور داشته همراه با معادله و شاخص‌های آماری مربوطه، در شکل (۳) نمایش داده شده است.



شکل ۲- نتایج حاصل از همبستگی‌های آماری برای ۱۹ رودخانه مورد مطالعه



شکل ۳- پراکندگی داده‌های بار بستر نسبت به ۴ پارامتر برتر در ۴ رودخانه


باتاچاریا با جذر میانگین مربعات خطاها $RMSE=1/9$ می‌باشد. از میان روابط موجود فرمول اینشتین با مقدار $RMSE=716/5$ و $R=0/502$ ضعیف‌ترین نتایج را داشته و ۹۵ درصد داده‌ها را با شاخص اختلاف بیش از ۱۰۰ پیش‌بینی کرده است. در شکل (۴) نتایج مربوط به ۱۰ فرمول تجربی با شاخص اختلاف r به صورت نمودار جعبه‌ای نمایش داده شده و مقایسه شده است. در این نمودار برای نمایش بهتر پراکندگی داده‌ها از مقیاس لگاریتمی برای محور قائم استفاده شده و مقدار شاخص اختلاف $r=1$ با خط پررنگ نشان داده شده است که هرچه قدر مقادیر مربوطه به فرمول‌ها به این مقدار نزدیک‌تر باشد نشان‌دهنده بهتر بودن نتایج آن فرمول می‌باشد. همان‌طور که مشاهده می‌شود فرمول اینشتین - براون بیشترین فاصله از خط مذکور را داشته و دو فرمول روتنر و باتاچاریا نزدیک‌ترین نمودار به این خط می‌باشند.

نتایج حاصل از روابط تجربی

میانگین نتایج کلی ۱۰ فرمول برای ۱۹ رودخانه در جدول (۳) آورده شده است. نتایج حاصل بیانگر عملکرد ضعیف ۱۰ فرمول در پیش‌بینی بار بستر می‌باشد. به طوری که درصد شاخص اختلاف (r) برای هر ۱۰ فرمول در بازه ۰/۵ الی ۲ کمتر از ۱۰ درصد می‌باشد. و اکثر فرمول‌ها، بار بستر را با شاخص اختلاف r بیشتر از ۱۰۰ پیش‌بینی کرده‌اند. تمامی ۱۰ فرمول مقدار شاخص NSE منفی و خطای $RMSE$ زیاد و نامطلوبی ارائه داده‌اند. فرمول روتنر با شاخص اختلاف ۱۳/۳ درصد در بازه ۰/۱ الی ۱۰ و ۴۱/۹ درصد در بازه ۱۰ الی ۱۰۰ در این تحقیق دقت نسبتاً بهتری نسبت به بقیه فرمول‌ها در پیش‌بینی بار رسوب داشته است. همچنین بیشترین ضریب همبستگی مربوط به فرمول روتنر با $R=0/513$ و کمترین خطا مربوط به فرمول

جدول ۳- نتایج حاصل از فرمول‌های تجربی

فرمول	$r(>100\%)$	$r(10-100\%)$	$r(0/1-10\%)$	$r(0/2-5\%)$	$r(0/5-2\%)$	NSE	R	RMSE
MP-M	۹۵	۳/۴	۰/۴	۰/۳	۰/۲	-۱۸۸۹۵۵	۰/۴۸۷	۵۵/۸
Sch	۶۳/۵	۲۶/۴	۵/۲	۲/۳	۰/۷	-۶۴۴۱	۰/۴۰۱	۱۰/۳
E-B	۹۴/۳	۳/۹	۱/۵	۰/۶	۰	-۳۱۱۶۷۹۰۳	۰/۲۰۵	۷۱۶/۵
R	۳۸/۹	۴۱/۹	۱۳/۳	۶/۹	۲/۶	-۱۴۲۷	۰/۵۱۳	۴/۹
B	۶۴/۸	۲۶/۵	۵/۸	۲/۶	۰/۷	-۱۱۱۹۳	۰/۳۲۸	۱۳/۶
P-K-M	۹۳/۸	۱/۶	۱/۸	۱/۲	۰/۳	-۴۱۳۰۰۰	۰/۴۷۷	۸۲/۵
V	۷۵/۶	۱۸	۴/۹	۲/۸	۰/۹	-۴۳۰۳۱	۰/۲۲۹	۲۶/۶
W-C	۷۹/۸	۱۳/۴	۴/۲	۲/۴	۱/۲	-۸۳۳۵۳	۰/۳۷۲	۳۷/۱
W-P	۹۱/۸	۶/۱	۰/۸	۰/۴	۰/۱	-۷۵۵۴۹	۰/۴۶۹	۳۵/۳
Bt	۵۵/۲	۳۸/۶	۵/۳	۱/۳	۰/۴	-۲۲۱	۰/۴۷۵	۱/۹



شکل ۴- نمودار مربوط به نتایج حاصل از فرمول‌های تجربی

نتایج حاصل از روش‌های ماشینی

برای تعیین پارامترهای ورودی مدل‌ها از نتایج بخش‌های قبلی بهره گرفته شده است. مطابق جدول (۴) در ۵ مدل اول از پارامترهای به‌کاررفته در فرمول‌های تجربی استفاده می‌شود. از مدل‌سازی چهار فرمول میر - پیتر و مولر، اینشتین - براون، پارکر و همکاران و وانگ و پارکر که نتایج ضعیفی نسبت به فرمول‌های دیگر داشته‌اند، صرف‌نظر شده است. و دو فرمول باتاچاریا و ون‌راین که دارای پارامترهای مشترک می‌باشند به‌صورت یک مدل ارائه شده‌اند. و در چهار مدل دیگر از پارامترهای فرمول‌های روتنر، بگنولد، شوکلیچ و ویلکاک - کرو بهره گرفته شده است. در واقع هدف از انتخاب این مدل‌ها این است که آیا پارامترهای انتخابی هر فرمول می‌تواند به‌عنوان ورودی شبکه‌های هوشمند به جواب دقیق‌تری برسد. در مدل نیز آخر برای مدل‌سازی، از نتایج مربوط به همبستگی‌های آماری استفاده شده و چهار پارامتری که بیشترین همبستگی را با پارامتر انتقال رسوب داشته‌اند به‌عنوان ورودی مدل ششم به کار رفته‌اند.

ارائه داده است. در مدل ۲ که مربوط به فرمول باتاچاریا می‌باشد روش SVM در هر دو قسمت آموزش و آزمون دقیق‌تر از روش GPR عمل کرده است. همچنین در مدل ۳ که مربوط به فرمول بگنولد می‌باشد با اینکه دقت شبکه GPR برای داده‌های آموزش بهتر است ولی در قسمت آزمون روش SVM مطابق دو شاخص R و NSE نتایج بهتری داشته است. ولی باین‌حال نتایج روش GPR نزدیک به روش SVM بوده و اختلاف اندکی دارد. در بقیه مدل‌های مورد بررسی (مدل‌های ۱، ۴، ۵ و ۶) مشاهده می‌شود که روش GPR برای دو هر دو قسمت آموزش و آزمون نتایج دقیق‌تری را نسبت به روش SVM ارائه داده است. در مقایسه مدل‌های مذکور، مدل ۳ که مربوط به فرمول بگنولد با پارامترهای ورودی: قدرت جریان در واحد عرض، عمق جریان و قطر متوسط ذرات رسوب می‌باشد، برترین مدل حاصل از دو روش مذکور می‌باشد. مدل ۱ مربوط به فرمول روتنر به دلیل داشتن دو پارامتر مشترک با مدل بگنولد (عمق جریان و قطر متوسط ذرات رسوب) نتایج خیلی نزدیکی را با نتایج فرمول مذکور داشته است که این نشان‌دهنده اهمیت دو پارامتر عمق جریان و قطر متوسط ذرات رسوب در پیش‌بینی بار رسوب می‌باشد. همچنین مدل ۴ که مربوط به فرمول شوکلیچ می‌باشد نیز از دقت قابل‌قبولی برخوردار است. پارامتر مشترک این سه مدل ذکر شده، پارامتر قطر متوسط ذرات رسوب (D_{50}) می‌باشد که نشان‌دهنده نقش کلیدی این پارامتر در پیش‌بینی بار بستر می‌باشد. دو مدل ۲ و ۵ که مربوط به فرمول‌های باتاچاریا و ویلکاک - کرو می‌باشند ضعیف‌ترین نتایج را نسبت به مدل‌های دیگر داشته‌اند. فرمول باتاچاریا که در قسمت فرمول‌های تجربی دارای کمترین خطای RMSE بود در روش‌های ماشینی بیشترین خطا را ارائه داده است؛ دلیل آن می‌تواند تعداد و نوع پارامترهای به‌کاررفته در مدل‌ها باشد. به‌طوری

جدول ۴- مدل‌های تعریف شده برای روش‌های ماشینی

مدل	فرمول	پارامترهای ورودی
model 1	روتنر	(Y , V , D ₅₀)
model 2	باتاچاریا	(D* , T)
model 3	بگنولد	(Y , ω , D ₅₀)
model 4	شوکلیچ	(q , S , D ₅₀)
model 5	ویلکاک-کرو	(Ø ₅₀ , u*)
model 6	پارامترهای همبستگی	(ω , τ , Re , Q)

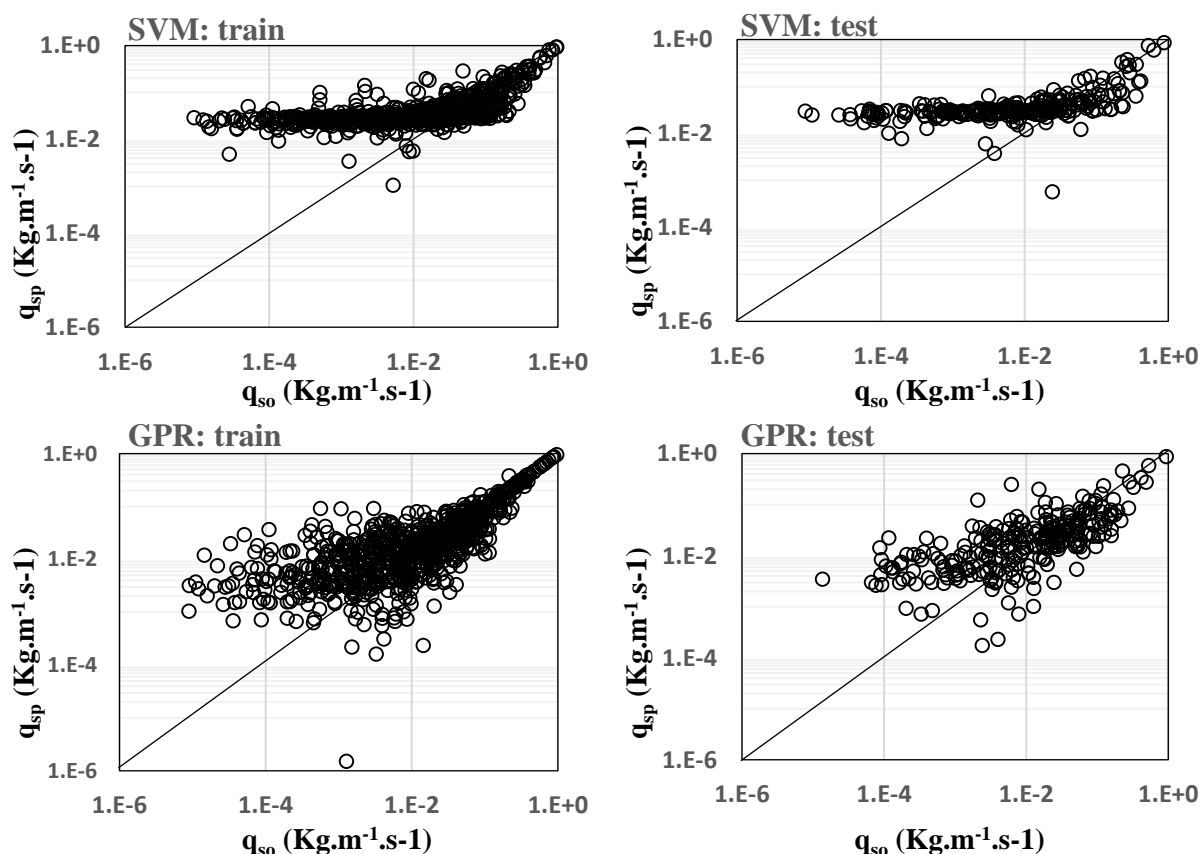
نتایج حاصل از دو روش SVM و GPR و ۶ مدل تعریف شده مطابق جدول (۵) می‌باشد. همان‌طور که مشاهده می‌شود در اکثر مدل‌ها روش GPR نتایج دقیق‌تری نسبت به روش SVM

مدل مربوط به فرمول بگنولد حاصل از روش GPR با $R=0/970$ و $NSE=0/942$ برای قسمت آموزش و با $R=0/923$ و $NSE=0/851$ برای قسمت آزمون برترین مدل این تحقیق می‌باشد. نمودارهای مربوط به پراکنش داده‌های مشاهداتی و پیش‌بینی شده برای مدل برتر در شکل (۵) نشان داده شده است. باتوجه به پراکنندگی بالای داده‌ها از نمودار لگاریتمی جهت مشاهده بهتر پراکنندگی داده‌ها استفاده گردید.

که در سه فرمول برتر از ۳ پارامتر ورودی استفاده شده ولی در مدل‌های ۲ و ۵ فقط از ۲ پارامتر ورودی استفاده شده است. در مدل ۶ انتظار می‌رفت پارامترهایی که در رودخانه‌های مختلف همبستگی مطلوبی را با دبی بار بستر داشته‌اند بتوانند مدلی را برای کل داده‌ها ارائه دهند که بتوانند بار بستر را با دقت بیشتری پیش‌بینی کنند. ولی نتایج نشان می‌دهد که این مدل از نظر دقت عملکرد، ضعیف‌تر از ۳ مدل دیگر عمل کرده است. در نهایت

جدول ۵- نتایج حاصل از روش‌های یادگیری ماشین

روش	مدل	پارامترهای بهینه			آموزش			آزمون			
		نویز	λ	C	ϵ	NSE	R	RMSE	NSE	R	RMSE
SVM	model 1	-	۳۲	۳	۰/۰۲	۰/۸۳۹	۰/۹۱۶	۰/۰۴۵	۰/۸۱۸	۰/۹۱۰	۰/۰۵۱
	model 2	-	۴۰	۳	۰/۰۳	۰/۵۷۴	۰/۷۶۶	۰/۰۷۸	۰/۵۳۵	۰/۷۳۵	۰/۰۷۹
	model 3	-	۵۰	۵	۰/۰۱	۰/۸۷۶	۰/۹۴۲	۰/۰۴۱	۰/۸۶۲	۰/۹۳۲	۰/۰۴۹
	model 4	-	۳۰	۳	۰/۰۱	۰/۸۵۸	۰/۹۲۷	۰/۰۴۴	۰/۸۱۹	۰/۹۱۳	۰/۰۵۰
	model 5	-	۵۰	۴	۰/۰۳	۰/۶۶۶	۰/۸۳۱	۰/۰۶۷	۰/۵۵۴	۰/۷۶۱	۰/۰۷۱
	model 6	-	۳۵	۱	۰/۰۱	۰/۸۰۳	۰/۸۵۹	۰/۰۴۵	۰/۷۵۵	۰/۸۷۰	۰/۰۶۰
GPR	model 1	۰/۱	۱۰	-	-	۰/۹۳۰	۰/۹۶۵	۰/۰۲۸	۰/۸۴۴	۰/۹۲۲	۰/۰۴۹
	model 2	۰/۱	۱۰	-	-	۰/۵۱۰	۰/۷۳۱	۰/۰۷۸	۰/۴۵۴	۰/۶۷۷	۰/۰۷۹
	model 3	۰/۱	۱۰	-	-	۰/۹۴۲	۰/۹۷۰	۰/۰۲۶	۰/۸۵۱	۰/۹۲۳	۰/۰۴۸
	model 4	۰/۱	۱۰	-	-	۰/۹۱۴	۰/۹۵۶	۰/۰۳۱	۰/۸۳۱	۰/۹۱۲	۰/۰۵۰
	model 5	۰/۱	۱۰	-	-	۰/۷۰۹	۰/۸۴۶	۰/۰۶۲	۰/۵۷۲	۰/۷۵۹	۰/۰۶۷
	model 6	۰/۱	۱۰	-	-	۰/۸۷۴	۰/۹۳۵	۰/۰۳۹	۰/۸۰۴	۰/۸۹۸	۰/۰۵۵



شکل ۵- نمودار پراکنش بین داده‌های مشاهداتی و پیش‌بینی شده در مدل برتر (مدل ۳)

نتیجه‌گیری

در پیش‌بینی بار بستر داشته‌اند به طوری که اکثر فرمول‌ها، دبی بار بستر را با شاخص اختلاف بیش از ۱۰۰ پیش‌بینی کرده و تمامی فرمول‌ها مقدار شاخص NSE منفی و خطای RMSE زیاد و نامطلوبی ارائه داده‌اند. روش‌های یادگیری ماشین، از روش‌های جدیدی است که در دهی اخیر به دلیل پیشرفت روزافزونش توجه پژوهشگران زیادی را به خود جلب کرده است. در این تحقیق نیز از دو روش یادگیری ماشین، رگرسیون فرآیند گاوسی و ماشین بردار پشتیبان برای پیش‌بینی بار بستر استفاده گردید. نتایج حاصل از روش‌های یادگیری ماشین، قابلیت و کارایی بالای این روش‌ها را در برآورد میزان انتقال بار بستر به اثبات رساند. خروجی مدل‌های به‌کاررفته نشان‌دهنده دقت بالاتر روش رگرسیون فرآیند گاوسی نسبت به ماشین بردار پشتیبان می‌باشد. در مقایسه مدل‌ها، مدل مربوط به فرمول بگنولد با پارامترهای ورودی: قدرت جریان θ عرض واحد، عمق جریان و قطر متوسط ذرات رسوب برترین مدل حاصل از این تحقیق می‌باشد. پارامتر مشترک ۳ مدل برتر این تحقیق، پارامتر قطر متوسط ذرات رسوب می‌باشد که نشان‌دهنده نقش کلیدی این پارامتر در پیش‌بینی بار بستر می‌باشد.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

REFERENCES

- Azamathulla, H.M., Chang, C.K., Ghani, A.A., Ariffin, J., Zakaria, N.A. & Hasan, Z.A. (2009). An ANFIS-based approach for predicting the bed load for moderately sized rivers. *Journal of Hydro-Environment Research*, 3(1), 35–44.
- Azamathulla, H.M., Ghani, A.A., Chang, C.K., Hasan Z.A. & Zakaria, N.A. (2010). Machine learning approach to predict sediment load a case study. *Clean – Soil, Air, Water*, 38(10), 969–976.
- Azamathulla, H. M., Haghiabi, A. H. & Parsaie, A. (2016). Prediction of side weir discharge coefficient by support vector machine technique. *Water Science and Technology: Water Supply*, 16(4), 1002–1016.
- Bagnold, R.A. (1980). An empirical correlation of bed load transport rates in flumes and natural rivers. *Proceedings of the Royal Society of London. Series A* 372, 453–473.
- Barry, J.J., Buffington, J.M. & King, J.G. (2004). A general power equation for predicting bed load transport rates in gravel bed rivers. *Water Resour* 40, W10401.
- Batalla, R.J. (1997). Evaluating bed-material transport equations from field measurements in a sandy gravel-bed river. *Earth Surface Processes and Landforms*, 21, 121–130.
- Bhattacharya, B., Price, R. K. & Solomatine, D. P. (2007). Machine learning approach to modeling sediment transport. *Journal of Hydraulic Engineering*, 133(4), 440–450.
- Brown, C.B. (1950). Sediment transportation. *Engineering hydraulic*, edited by H. Rouse, John Wiley, New York, pp. 769–857
- Dibike, Y.B., Velickov, S., Solomatine, D. & Abbott, M.B. (2001). Model induction with support vector machines: introduction and applications. *Journal of Computing in Civil Engineering*, 15(3), 208–216.
- Khorrarn, S. & Ergil, M. (2010b). Most influential parameters for the bed-load sediment flux equations used in alluvial rivers. *JAWRA Journal of the American Water Resources Association*, 46(6), 1065–1090.
- King, J.G., Emmett, W.W., Whiting, P.J., Kenworthy, R.P. & Barry, J.J. (2004). Sediment transport Data and Related Information for Selected Coarse-Bed Streams and Rivers in Idaho. *Gen. Tech. Rep. RMRS-GTR-131. Fort Collins, CO: US Department of Agriculture, Forest Service, Rocky Mountain Research Station.*
- Kitsikoudis, V., Sidiropoulos, E. & Hrisanthou, V. (2014). Machine learning utilization for bed load transport in gravel-bed rivers. *Water Resources Management*, 28(11), 3727–3743.
- Kumar, M. & Kar, I.N. (2009). Non-linear HVAC computations using least square support vector machines. *Energy Conversion and Management*, 50(6), 1411–1418.
- Mahmoodzadeh, A., Mohammadi, M., Ibrahim, H. H., Rashid, T. H., Aldalwie, A. H. M., Ali, H. F. H. &

پیش‌بینی انتقال بار بستر به دلیل پیچیدگی‌های حاکم بر جریان رودخانه در شرایط مختلف به یک مسئله دشوار برای محققان تبدیل شده است. در پژوهش حاضر طیف وسیعی از داده‌های جمع‌آوری شده از ۱۹ رودخانه با بستر شنی با ویژگی‌های هیدرولیکی و رسوبی مختلف برای پیش‌بینی انتقال بار بستر استفاده شد. ابتدا سعی شد بین دبی بار بستر و پارامترهای انتخاب شده به یک همبستگی قابل‌قبولی رسیده شود. سپس با استفاده از روابط ساده رگرسیونی که در آن دبی بار بستر به صورت تابعی از پارامتر هیدرولیکی یا رسوبی بیان می‌شود، به پیش‌بینی بار بستر پرداخته شود. در اکثر رودخانه‌های مورد مطالعه به یک همبستگی مطلوبی بین پارامتر انتقال رسوب و پارامترهای هیدرولیکی و رسوبی رسیده شده و نتایج نشان داد این روابط رگرسیون ساده دقت قابل‌قبولی را در پیش‌بینی بار بستر داشته‌اند. چهار پارامتر: دبی جریان، قدرت جریان در واحد عرض، عدد رینولدز و تنش برشی بستر در اکثر رودخانه‌ها ضریب همبستگی بالایی با دبی بار بستر ارائه داده‌اند. ثانیاً به بررسی ۱۰ فرمول تجربی پرکاربرد پرداخته شده است که نتایج نشان داد کلیه فرمول‌های تجربی مورد بررسی در این تحقیق نتایج خیلی ضعیفی



- Daraei, A. (2021). Tunnel geomechanical parameters prediction using Gaussian process regression. *Machine Learning with Applications*, 3.
- Meyer-Peter, E. & Müller, R. (1948). Formulas for bed-load transport. In Proceedings of the 2nd Meeting of the International Association for Hydraulic Structures Research, pp. 39-64.
- Legates, D.R. & McCabe, G.J. (1999). Evaluating the Use of "Goodness-of-Fit" Measures in Hydrologic and Hydroclimatic Model Validation. *Water Resources Research*, 35, 233-241.
- López, R., Vericat, D. & Batalla, R.J. (2013). Evaluation of bed load transport formulae in a large regulated gravel bed river: the lower Ebro (NE Iberian Peninsula). *Journal of Hydrology*, 510, 164-181.
- Pal, M. & Deswal, S. (2010). Modelling pile capacity using Gaussian process regression. *Computers and Geotechnics*, 37, 942-947.
- Pal, M., Singh, N. K. & Tiwari, N. K. (2014). Kernel methods for pier scour modeling using field data. *Journal of Hydroinformatics*, 16(4), 784-796.
- Parker, G., Klingeman, P.C. & McLean, D.G. (1982). Bedload and the size distribution of paved gravel-bed streams. *Journal of the Hydraulics Division*, 108(4), 544-571.
- Rasmussen, C. E. & Williams, C. K. (2006). *Gaussian process for machine learning*. volume 2. MIT press Cambridge, MA.
- Rezazadeh Joude, A. & Sattari, M. T. (2016). Performance assessment of Kernel-Based methods in estimation of suspended sediment loads (Case study: Maragheh SofiChay River). *Physical Geography Research Quarterly*, 48(3), 413-428.
- Rottner, J. (1959). A formula for bed load transportation. *La Houille Blanche*, 3(4), 301-307.
- Roushangar, K. & Koosheh, A. (2015). Evaluation of GA-SVR method for modeling bed load transport in gravel-bed rivers. *Journal of Hydrology*, 527, 1142-1152.
- Roushangar, K. & Ghasempour, R. (2017). Prediction of Non-Cohesive Sediment Transport in Circular Channels in Deposition and Limit of Deposition States Using SVM. *Water Science and Technology: Water Supply*, 17(2), 537-551.
- Roushangar, K. & Shahnazi, S. (2019). Prediction of sediment transport rates in gravel-bed rivers using Gaussian process regression. *Journal of Hydroinformatics*, 22(2), 249-262.
- Roushangar, K. & Shahnazi, S. (2020). Determination of influential parameters for prediction of total sediment loads in mountain rivers using kernel-based approaches. *Journal of Mountain Science*, 17(2).
- Schoklitsch, A. (1950). *Handbuch des wasserbaues* [Handbook of hydraulic engineering]. 2nd Ed., Springer, New York.
- VanRijn, L.C. (1984a). Sediment transport, Part I: Bedload transport. *Journal of Hydraulic Engineering*, 110(10), 1431-1456.
- Vapnik, V. (1995). The Nature of Statistical Learning Theory. *Data Mining and Knowledge Discovery*, 1-47.
- Vázquez-Tarrío, D. & Menéndez-Duarte, R. (2015). Assessment of bedload equations using data obtained with tracers in two coarse-bed mountain streams (Narcea River basin, NW Spain). *Geomorphology*, 238, 78-93.
- Wang, W., Xu, D., Chau, K. & Chen, S. (2013). Improved annual rainfall-runoff forecasting using PSO-SVM model based on EEMD. *Journal of Hydroinformatics* 15, 1377-1390.
- Wilcock, P.R. & Crowe, J.C. (2003). Surface-based transport model for mixed-size sediment. *Journal of Hydraulic Engineering*, 129(2), 120-128.
- Wong, M. & Parker, G. (2006). Reanalysis and correction of bed-load relation of Meyer-Peter and Müller using their own database. *Journal of Hydraulic Engineering*, 132(11), 1159-1168.
- Zhang, K., Wang, Z.Y. & Liu, L. (2010). The effect of riverbed structure on bed load transport in mountain streams. *Mouth* 6, 0-03.