

Evaluating the Performance of Data-Driven Methods for Prediction of Total Sediment Load in Gravel-Bed Rivers

KIYOUMARS ROUSHANGAR^{1**}, SAMAN SHAHNAZI²

1. Associate Professor, Department of water engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran
 2. M. Sc. of water and hydraulic structures engineering, Department of Civil Engineering, University of Tabriz, Tabriz, Iran
- (Received: March. 4, 2018- Revised: June. 10, 2018- Accepted: Feb. 13, 2019)

ABSTRACT

Numerous studies on sediment transport, especially prediction of this phenomenon, indicate its high importance in the sciences related to engineering and water resources management. In recent years, intelligent methods have been applied successfully to predict bed, suspended and total sediment load. However, due to the lack of measured data, limited researches have been done to deal with prediction of total load in gravel-bed rivers. The aim of this study is to apply Support Vector Machine (SVM), Artificial Neural Network (ANN) and Gaussian Process Regression (GPR) to predict total sediment load for 19 gravel-bed rivers and to compare the obtained results with well-known classic methods. For this purpose, different non-dimensional parameters based on hydraulic condition and sediment characteristics were defined and the performance of these methods was evaluated. According to the obtained results, the ANN model with correlation coefficient of $R = 0.952$ and Nash-Sutcliffe efficiency ($NSE = 0.903$) showed a better performance as compared to the other methods. Finally, by performing sensitivity analysis, the ratio of mean flow to shear velocity was introduced as the most effective parameter in predicting total sediment load.

Keywords: Total load, Gravel-bed rivers, Support vector machine, Artificial neural network, Gaussian process regression

ارزیابی عملکرد روش‌های داده‌گرا در تخمین بار کل رسوبی رودخانه‌های شنی

کیومرث روشنگر^{۱*}، سامان شهنازی^۲

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

۲. کارشناس ارشد مهندسی آب و سازه هیدرولیکی، دانشکده عمران دانشگاه تبریز، تبریز، ایران

(تاریخ دریافت: ۱۳۹۶/۱۲/۱۳ - تاریخ بازنگری: ۱۳۹۷/۳/۲۰ - تاریخ تصویب: ۱۳۹۷/۱۱/۲۴)

چکیده

انجام مطالعات فراوان در رابطه با انتقال رسوب و به‌ویژه پیش‌بینی این پدیده نشانگر اهمیت بسیار بالای آن در علوم مرتبط با مهندسی و مدیریت منابع آب می‌باشد. در این بین روش‌های هوشمند در سال‌های اخیر به طور موفقیت‌آمیزی در پیش‌بینی بار بستر، بار معلق و همچنین بار کل رسوب به کار گرفته شده است. با این حال با توجه به کمبود داده‌های مرتبط به بار کل برای رودخانه‌های با بستر شنی، مطالعات انجام گرفته در این راستا محدود می‌باشد. هدف از تحقیق حاضر استفاده از روش‌های قدرتمند ماشین بردار پشتیبان، شبکه عصبی مصنوعی و رگرسیون فرآیند گاوسی به منظور پیش‌بینی بار کل رسوب در ۱۹ رودخانه شنی واقع در ایالات متحده آمریکا و مقایسه نتایج حاصل با روش‌های کلاسیک مرسوم می‌باشد. بدین منظور پارامترهای بدون بعد مختلفی مبتنی بر هیدرولیک جریان و مشخصات رسوب تعریف و عملکرد روش‌های مذکور مورد ارزیابی قرار گرفت. با توجه به نتایج به دست آمده شبکه عصبی مصنوعی با دارا بودن ضریب همبستگی و معیار ناش-ساتکیف به ترتیب برابر با $R=0.952$ و $NSE=0.903$ برای داده‌های صحت‌سنجی از عملکرد بهتری نسبت به دو روش دیگر برخوردار می‌باشد. در نهایت با انجام تحلیل حساسیت، پارامتر نسبت سرعت متوسط به سرعت برشی جریان به عنوان تأثیرگذارترین پارامتر در پیش‌بینی بار کل رسوب معرفی شد.

واژه‌های کلیدی: بار کل رسوب، رودخانه‌های شنی، ماشین بردار پشتیبان، شبکه عصبی مصنوعی، رگرسیون فرآیند گاوسی

مقدمه

پدیده انتقال رسوب از دیرباز یکی از مسائل مهم در علوم مرتبط با آب و همچنین زمین‌شناسی بوده و در دهه‌های گذشته مورد توجه محققین و مهندسين فعال در این حوزه بوده است. انتقال رسوب در رودخانه‌ها با فرآیند فرسایش و ته‌نشینی در بلندمدت موجب تغییرات مورفولوژیکی گشته و همین عامل نیز موجب تغییر شکل بستر رودخانه شده که تأثیر مستقیمی در تراز سطح آب در جریان‌های سیلابی دارا می‌باشد. این تغییرات موجب تهدید پایداری رودخانه‌ها، تضعیف عملکرد سازه‌های هیدرولیکی و اثرات مخرب زیست‌محیطی می‌گردد (Choi and Lee, 2015). همچنین تخمین دقیق مقدار بار رسوب یا میزان انتقال آن در رودخانه‌ها یکی از پارامترهای کلیدی در مدیریت مخازن و برآورد عمر سدها می‌باشد. مقدار بار کل رسوب انتقالی توسط جریان رودخانه به صورت مجموع کل بار معلق و بار بستر و یا مجموع کل دبی مواد بستر و دبی مواد شسته تعریف می‌گردد (Bejestan, 2009). به طور کلی بار کل رسوب را می‌توان با دو رویکرد مستقیم و غیرمستقیم محاسبه نمود. در روش غیرمستقیم که اولین بار

توسط Einstein (1950) پیشنهاد گردید، بار بستر و بار معلق به صورت مجزا تعیین و بار کل رسوب از این طریق محاسبه می‌گردد. این در حالی است که اکثر روابط موجود، بار کل رسوب را به صورت مستقیم تعیین می‌نمایند. با توجه به اهمیت این مسئله، تاکنون روابط تجربی و نیمه تجربی متعددی با استفاده از روش‌های مختلف توسعه داده شده‌اند. میزان کارایی هر یک از این روابط نیز در سال‌های گذشته توسط محققین مورد بحث قرار گرفته که از آن جمله می‌توان به مطالعات Khorram and Ergil (2010) اشاره نمود که با به کارگیری بیش از ۲۰۰۰ داده آزمایشگاهی و ۷۰۰ داده میدانی به بررسی ۲۳ رابطه مختلف برای تعیین بار کل رسوب پرداختند. نتایج حاصل نشان دهنده دقت بالاتر رابطه Ackers and White (1973) نسبت به سایر روابط برای هر دو نوع رودخانه با بستر شنی و ماسه‌ای می‌باشد. با توجه به پیچیدگی‌های حاکم بر پدیده انتقال رسوب، پژوهش‌های انجام شده نشان دهنده عدم کارایی روابط کلاسیک در برآورد بار رسوب می‌باشد (Roushangar and Parhiz Javan, 2014). در سال‌های اخیر روش‌های هوشمند به صورت گسترده در مباحث هیدرولیکی

گرفته شده و رابطه‌ای از این طریق برای پیش‌بینی بار کل رسوب توسعه داده شد (Zakaria et al, 2010). در پژوهشی دیگر okcu et al. (2016) با بهره‌گیری از الگوریتم 'PBSR' و همچنین استفاده از ۱۰ پارامتر بدون بعد مستخرج از روابط پرکاربرد رابطه-ای برای پیش‌بینی بار کل رسوب توسعه دادند که در هر دو محدوده داده‌های میدانی و آزمایشگاهی دارای عملکرد مناسبی می‌باشد. Sahraei et al. (2017) با استفاده از دو روش حداقل مربعات رگرسیون بردار پشتیبان (LSSVR) و مدل M5 و همچنین به کارگیری ۳۱۵ داده آزمایشگاهی و ۳۲۷ داده میدانی به پیش‌بینی بار مواد بستر پرداختند و به منظور بهینه‌سازی پارامترهای کرنل از الگوریتم بهینه‌سازی توده ذرات (PSO) استفاده نمودند. نتایج به دست آمده نشان‌دهنده برتری مدل هیبریدی PSO-LSSVR در مقایسه با مدل M5 و روابط کلاسیک بوده است. با بررسی منابع موجود مشخص می‌گردد که به دلیل کمبود داده‌های اندازه‌گیری شده برای رودخانه‌های شنی، تحقیقات انجام گرفته در این راستا محدود بوده و تحقیق چندانی در زمینه امکان‌سنجی کاربرد روش‌های هوشمند برای تخمین بار کل رسوب در رودخانه‌های شنی وجود ندارد. همچنین عمده تحقیقات انجام شده شامل طیف محدودی از داده‌های میدانی و آزمایشگاهی می‌باشد. لذا هدف از مطالعه حاضر ارزیابی عملکرد روش‌های رگرسیون فرآیند گاوسی به عنوان یکی از روش‌های نوین داده‌کاوی و همچنین ماشین بردار پشتیبان و شبکه‌های عصبی مصنوعی در پیش‌بینی بار کل رسوب در ۱۹ رودخانه با بستر شنی می‌باشد. بدین منظور پارامترهای بدون بعد مختلفی به عنوان ورودی‌های مدل تعریف شده و نتایج حاصل از روش‌های هوشمند با روابط کلاسیک مقایسه خواهد شد.

مواد و روش‌ها

داده‌های مورد استفاده

داده‌های مورد مطالعه در این تحقیق شامل نزدیک به ۹۰۰ داده جمع‌آوری شده از ۱۹ رودخانه با بستر شنی از ایالت آیداهو آمریکا می‌باشد که بخش اعظمی از آن‌ها بین سال‌های ۱۹۹۳ تا ۲۰۰۰ اندازه‌گیری شده‌اند. داده‌های مربوطه شامل بار بستر، بار معلق و مشخصات هیدرولیکی جریان از قبیل دبی جریان (Q) عمق متوسط (V)، سرعت متوسط جریان (V)، عرض رودخانه (B) و همچنین مشخصات فیزیکی ذرات رسوبی مانند متوسط اندازه ذرات رسوب (D_{50}) می‌باشند. تمامی رودخانه‌ها زیر حوزه رودخانه اسنیک بوده و از جریان‌ها و رودخانه‌های مختلفی با شرایط

به کار گرفته شده و توانایی بالای خود را در حل مسائل با عدم قطعیت بالا نشان داده‌اند.

در این خصوص، اولین مطالعه توسط Dogan et al. (2007) انجام پذیرفت که با بهره‌گیری از داده‌های آزمایشگاهی به تخمین بسیار خوبی از بار کل رسوب با استفاده از شبکه‌های عصبی مصنوعی دست یافتند. همچنین نتایج حاصل از پژوهش-های آن‌ها نشان دهنده تأثیر بالای دبی جریان، متوسط اندازه ذرات رسوب و شیب بستر در پیش‌بینی‌های مربوطه بوده است. عملکرد شبکه‌های عصبی مصنوعی در محدوده داده‌های آزمایشگاهی توسط Falamaki et al. (2013) نیز مورد بررسی قرار گرفته که نشان دهنده کارایی بهتر شبکه‌های پرسپترون چند لایه (MLP) نسبت به شبکه توابع پایه شعاعی (RBF) در پیش-بینی بار کل رسوب بوده است. با توجه به شرایط کاملاً متفاوت داده‌های آزمایشگاهی و میدانی، تعیین مدلی که دارای انعطاف‌پذیری کافی در هر دو شرایط مذکور باشد، از اهمیت بالایی برخوردار است. بدین منظور کارایی شبکه‌های عصبی مصنوعی برای داده‌های جمع‌آوری شده از ۱۰ رودخانه واقع در ایالات متحده آمریکا نیز مورد ارزیابی قرار گرفته و توانایی بالای آن در پیش‌بینی بار کل رسوب در محدوده داده‌های میدانی به اثبات رسید (Yang et al., 2009). با توجه به قدرت بالای شبکه-های عصبی مصنوعی در حل مسائل با عدم قطعیت بالا، این روش به منظور پیش‌بینی بار کل رسوب در محدوده داده‌های جمع‌آوری شده توسط Brownlie (1981) نیز به کار گرفته شد (Bhattacharya et al., 2007; Kumar, 2012). مقایسه کارایی سیستم‌های استنتاج عصبی فازی (ANFIS) با شبکه‌های عصبی مصنوعی و برنامه‌ریزی بیان ژن (GEP) در پیش‌بینی بار کل در رودخانه‌های مالزی نشان دهنده دقت کمتر سیستم‌های استنتاج عصبی فازی در مقایسه با دو روش دیگر می‌باشد (Chang et al., 2012). نتایج حاصل از ارزیابی و اصلاح شبیه‌سازی انتقال بار کل رسوب در رودخانه قطور چای واقع در آذربایجان غربی با استفاده از برنامه‌ریزی بیان ژن و سیستم‌های استنتاج عصبی فازی حاکی از آن بود که اصلاح و تقویت روابط کلاسیک با استفاده از روش-های هوشمند، باعث بهبود نتایج پیش‌بینی و ارتقای کارایی روابط مذکور می‌گردند (Roushangar et al, 2014). همچنین در یک مقایسه کلی، می‌توان گفت مدل‌هایی که بر مبنای توان جریان توسعه یافته‌اند، عملکرد بهتری نسبت به مدل‌هایی دارند که مفهوم تنش برشی در ساختار آن‌ها بکار گرفته شده است. همچنین برنامه‌ریزی بیان ژن برای رودخانه‌های مالزی نیز به کار

(al., 2004). برای هر یک از رودخانه‌ها ۷۵ درصد از داده‌ها به صورت تصادفی برای قسمت آموزش و ۲۵ درصد نیز به عنوان داده‌های صحت‌سنجی انتخاب شد. خلاصه‌ای از مشخصات داده‌های به کار رفته در این مطالعه در جدول (۱) ارائه شده است.

مختلف توپوگرافی، زمین‌شناسی و هیدرولیکی و رسوبی تشکیل شده است. متوسط اندازه ذرات رسوبی (D50) برای لایه سطحی در همه رودخانه‌ها بیش از مقادیر مربوط به لایه زیرسطحی می‌باشد که نشان از درشت دانه بودن رودخانه‌های مذکور است (King et

جدول ۱- مشخصات داده‌های به کار رفته در تحقیق

نام رودخانه	دوره اندازه- تعداد داده	گیری به کار رفته	آموزش	داده‌های صحت سنجی	مساحت حوضه آبریز (Km ²)	شیب متوسط	بازه D ₅₀ میلی‌متر (mm)	بازه دبی مترمکعب بر ثانیه (m ³ /sec)
Big Wood River	۱۹۹۹-۲۰۰۰	۲۶	۱۷	۸	۳۴۹/۷	۰/۰۰۹۱	۰/۷-۴۰/۷	۹/۶-۳۰/۸
Bruneaul River	۱۹۹۸-۲۰۰۲	۲۷	۱۸	۹	۹۸۹	۰/۰۰۵۴	۰/۷۲-۳۴/۹۲	۴/۷-۲۰/۹
Fourth Of July	۱۹۹۴-۱۹۹۵	۲۵	۱۷	۸	۴۴/۲۸	۰/۰۲۰۲	۰/۳۸-۳/۱۱	۰/۳-۳/۸
Herd Creek	۱۹۹۴-۱۹۹۵	۲۲	۱۵	۷	۲۹۲/۶	۰/۰۰۷۷	۰/۵-۵/۷	۰/۵-۸/۱
Jarbidge River	۱۹۹۸-۲۰۰۲	۲۶	۱۸	۹	۷۹/۳۵	۰/۰۱۶۰	۰/۷۹-۳۵/۳۵	۱/۴-۸
Johns Creek	۱۹۸۶-۱۹۹۵	۲۲	۱۴	۷	۲۹۳/۱	۰/۰۲۰۷	۰/۶۴-۲/۳۸	۰/۹۷-۲۶
Little Slate Creek	۱۹۸۶-۱۹۹۷	۷۹	۵۵	۲۴	۱۶۸/۵	۰/۰۲۶۸	۰/۴۲-۱۷/۵	۰/۵۲-۱۵/۷
Lolo Creek	۱۹۸۰-۱۹۹۷	۴۱	۲۸	۱۳	۱۰۷/۷	۰/۰۰۹۷	۰/۴۶-۴/۲۲	۱/۸-۱۶/۲
Main Fork Red River	۱۹۸۶-۱۹۹۹	۱۱۰	۷۷	۳۳	۱۲۹/۳	۰/۰۰۵۹	۰/۳۱-۵/۲۸	۰/۲۹-۱۸/۳
Marsh Creek	۱۹۹۴-۱۹۹۵	۲۷	۱۸	۹	۱۹۱/۵	۰/۰۰۶۰	۱/۱-۲۲/۶۵	۳/۳۶-۲۳/۲
Rapid River	۱۹۸۶-۲۰۰۰	۷۲	۵۰	۲۲	۲۷۹/۵	۰/۰۱۰۸	۰/۴۱-۳۷/۳۰	۰/۹۱-۳۶/۸
South Fork Red River	۱۹۸۶-۱۹۹۹	۹۷	۶۷	۳۰	۹۷/۸	۰/۰۱۴۶	۰/۴۳-۱۰/۷۱	۰/۳-۱۱
South Fork Salmon River	۱۹۸۵-۱۹۹۷	۵۱	۳۵	۱۶	۸۵۲/۶	۰/۰۰۲۵	۰/۵۲-۲/۰۲	۳/۸-۱۲۴/۳
Squaw Creek (USGS)	۱۹۹۴-۱۹۹۵	۳۲	۲۲	۱۰	۱۹۲	۰/۰۱۰۰	۰/۴۴-۲/۶۸	۰/۴-۵/۷
Thompson Creek	۱۹۹۴-۱۹۹۵	۲۴	۱۶	۸	۵۸/۱	۰/۰۱۵۳	۰/۴۷-۷/۰۷	۰/۴-۳/۵
Trapper Creek	۱۹۸۵-۱۹۹۷	۸۷	۶۰	۲۷	۳۲/۲	۰/۰۴۱۴	۰/۵-۱/۷۸	۰/۰۵-۲/۸
Hawley Creek	۱۹۹۰-۱۹۹۶	۶۵	۴۵	۲۰	۱۰۴/۸	۰/۰۲۳۳	۰/۴۸-۳/۶۹	۰/۳۷-۲/۶
Salmon River near Obsidian	۱۹۹۰	۱۹	۱۴	۶	۲۴۳/۹	۰/۰۰۶۶	۰/۸۶-۴/۵۲	۱۱/۴۴-۲۰/۹
Squaw Creek (USFSD)	۱۹۹۰-۱۹۹۶	۳۸	۲۶	۱۲	۳۷/۶	۰/۰۲۴۰	۰/۵۹-۵/۵۵	۰/۱۸-۱/۵

در روابط فوق، K ماتریس کوواریانس با درایه‌های $[K]_{i,j}$ در صورت $COV(x_i, x_j)$ بردار K_* به صورت $[K_*]_i = COV(x_i, x_*)$ و $COV(x_*, x_*)$ ماتریس همبستگی می‌باشند. با توجه به رابطه (۲) مشاهده می‌شود که فرایند 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 کوواریانس بایستی از روی داده‌های موجود تخمین زده شوند که به آن‌ها هایپرپارامتر گفته می‌شود. هایپرپارامترها در واقع تعریف کننده ویژگی‌های توزیع احتمالی پیش‌بینی شده می‌باشند. مقادیر هایپرپارامترها معمولاً با بیشینه‌سازی $\log p(y|X)$ که درست‌نمایی بر حسب لگاریتم می‌باشد، به دست می‌آید. (Rasmussen and Williams, 2006)

(رابطه ۳)

$$\log p(y|X) = -\frac{1}{2}y^T(K + \sigma_n^2 I)^{-1}y - \frac{1}{2}\log(|K + \sigma_n^2 I|) - \frac{n}{2}\log(2\pi) \quad (۳)$$

رگرسیون فرآیند گاوسی

رگرسیون فرآیند گاوسی رویکردی غیر پارامتریک و مبتنی بر احتمالات برای حل مسائل رگرسیون غیر خطی ارائه می‌نماید. فرض اصلی رگرسیون فرآیند گاوسی این است که مقادیر متغیرهای خروجی y به شکل زیر اندازه‌گیری می‌شوند:

$$y = f(x(k)) + \varepsilon \quad (رابطه ۱)$$

که در رابطه فوق، x نمایانگر مقادیر داده‌های اندازه‌گیری شده ورودی، f تابع وابسته مجهول و ε نیز مقدار نویز گاوسی با واریانس σ_n^2 می‌باشد. رگرسیون فرآیند گاوسی به طور کامل توسط میانگین $m(x)$ و تابع کوواریانس خود $COV(x, x')$ تعریف می‌شود. پس از تعیین میانگین و کوواریانس، پیش‌بینی متغیرهای خروجی برای یک نمونه از متغیرهای ورودی x_* به صورت توزیع گاوسی پیش‌بینی شده $p(y_*|X, y, x_*)$ با میانگین و تابع کوواریانس به شکل زیر ارائه می‌شود:

$$\hat{y}_* = m(x_*) + K_*^T(K + \sigma_n^2 I)^{-1}(y - m(x_*)) \quad (رابطه ۲)$$

$$\sigma_{y_*}^2 = k_* + \sigma_n^2 - k_*^T(K + \sigma_n^2 I)^{-1}K_*$$

ماشین بردار پشتیبان

به منظور استفاده از روشهای کرنل محور، انتخاب مقادیر بهینه پارامترهای مربوط به تابع کرنل به دلیل تأثیر مستقیم خود در دقت نتایج به دست آمده از اهمیت بالایی برخوردار می باشد. همچنین در رگرسیون فرآیند گاوسی نیز به مشخص کردن مقدار بهینه نویز گاوسی نیاز می باشد که در این تحقیق تمامی پارامترهای مذکور با استفاده از روش آزمون و خطا بهینه سازی شدند.

شبکه های عصبی مصنوعی

مدل های مختلفی از شبکه های عصبی مصنوعی بر حسب کاربرد و عملکرد آنها وجود دارند. در این پژوهش از شبکه معمول و پر کاربرد پرسپترون چند لایه با قانون یادگیری پس انتشار خطا (FFBP) استفاده شده است. تابع فعال ساز به کار رفته، تابع تانژانت هیپربولیک و تعداد نورون های لایه میانی نیز با سعی و خطا به دست آمده است. با توجه به تعدد منابع موجود برای شبکه های عصبی مصنوعی از ارائه توضیحات بیشتر در این قسمت صرفه نظر می گردد.

روابط کلاسیک

به منظور مقایسه نتایج به دست آمده از روش های داده گرا با روابط کلاسیک مرسوم از پنج رابطه پر کاربرد Engelund and Hansen (1967)، Ackers and White (1973)، Karim (1998)، (2006) Yang و Shen and Hung (1972) استفاده گردید. روابط مذکور به همراه تئوری مربوطه و محدوده کاربرد هر یک در جدول (۳) ارائه شده اند.

معیارهای ارزیابی

به منظور ارزیابی مدل های تعریف شده برای پیش بینی بار کل رسوب از پارامترهای آماری ضریب همبستگی (R)، جذر میانگین مربعات خطا (RMSE) و معیار ناش-ساتکلیف استفاده گردید. تعریف ریاضی پارامترهای مذکور به شکل زیر می باشد:

$$R = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2 \times \sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad \text{(رابطه ۶)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{N}} \quad \text{(رابطه ۷)}$$

$$NSE = 1 - \frac{\sum_{i=1}^N (X_i - Y_i)^2}{\sum_{i=1}^N (X_i - \bar{X})^2} \quad \text{(رابطه ۸)}$$

در این روابط X شامل مقادیر مشاهداتی و Y شامل مقادیر محاسباتی هستند. هر چه مقادیر R و NSE نزدیک به ۱ و RMSE مقادیر نزدیک به صفر داشته باشند، نشان دهنده کارکرد ایده آل مدل مورد نظر خواهد بود.

مدل رگرسیون بردار پشتیبان مشهور به SVR - ε اولین بار توسط Cortes and Vapnik (1995) معرفی شد. در یک مدل رگرسیونی SVM لازم است وابستگی تابعی متغیر وابسته y به مجموعه ای از متغیرهای مستقل x همانند رابطه (۱) مشخص گردد. بنابراین موضوع اصلی پیدا کردن فرم تابع f است که بتواند به صورت صحیح، موارد جدیدی را که SVM تاکنون تجربه نکرده است پیش بینی کند. این تابع به وسیله آموزش مدل SVM بر روی یک مجموعه داده به عنوان مجموعه آموزش که شامل فرآیندی به منظور بهینه سازی دائمی تابع خطا است، قابل دسترسی است. برای این مدل، تابع خطا به صورت زیر تعریف می شود.

$$\frac{1}{2} W^T W + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i \quad \text{(رابطه ۴)}$$

تابع خطای مذکور لازم است که با توجه به محدودیت های زیر کمینه گردد.

$$W^T \phi(X_i) + b - y_i \leq \varepsilon + \xi_i \quad \text{(رابطه ۵)}$$

$$y_i - W^T \phi(X_i) - b \leq \varepsilon + \xi_i$$

$$\xi_i, \xi_i \geq 0 \quad . i = 1, \dots, N$$

که در این روابط:

C ثابت گنجایش^۱، W بردار ضرایب، W^T ترانزاده بردار ضرایب، ξ_i و ξ_i ضرایب کمبود^۲، b ضریبی ثابت، N الگوی آموزش مدل و ϕ تابع کرنل است. ضمن این که پارامترهای γ ، C و ε نیز در نرم افزار Statistica با استفاده از روش سعی و خطا بهینه شدند به نحوی که میانگین مربع خطا را کمینه و مقادیر مربوط به ضریب همبستگی و معیار ناش-ساتکلیف را نیز بیشینه کند.

هر دو الگوریتم ماشین بردار پشتیبان و رگرسیون فرآیند گاوسی از روش های یادگیری ماشین با فرمول متفاوت می باشند. مفهوم تابع کوواریانس در رگرسیون فرآیند گاوسی مشابه تابع کرنل می باشد. در میان توابع کرنل مختلف که در جدول (۲) ارائه شده، کرنل تابع پایه شعاعی به عنوان بهترین انتخاب از بین دیگر توابع کرنل گزارش شده است (Roushangar anf Ghasempour, 2017). بنابراین در این تحقیق از تابع مذکور به عنوان تابع کرنل استفاده گردید.

جدول ۲- توابع کرنل

رابطه	کرنل
$K(x_i, x_j) = (x_i, x_j)$	Linear
$K(x_i, x_j) = ((x_i, x_j) + 1)^d$	Polynomial
$K(x_i, x_j) = \exp(-\frac{\ x_i - x_j\ ^2}{2\gamma^2})$	RBF
$K(x_i, x_j) = \exp(-\frac{\ x_i - x_j\ }{2\gamma^2})$	ERBF

جدول ۳- روابط کلاسیک به کار رفته در تحقیق

محدوده کاربرد	رهیافت	رابطه
$0.15 \leq D_{50} \leq 0.93$	Hansen and Engelund (1967) تئوری انرژی	$q_t = q C_w$ $C_w = 0.05 \left(\frac{G_s}{G_s - 1} \right) \frac{VS}{\sqrt{(G_s - 1)gD_{50}}} \frac{RS}{(G_s - 1)D_{50}}$
$0.04 \leq D_{50} \leq 4$ $0.022 \leq V \leq 2.44$ $0.183 \leq S_f \times 10^3 \leq 1.13$	White and Ackers (1973) تئوری توان جریان	$\frac{Q_t}{Q} = C \frac{D_{50}}{R} \left(\frac{V}{U_*} \right)^n \left(\frac{F_g}{A} - 1 \right)^m$ $F_g = \frac{U_*^n}{\sqrt{[gD_* \left(\frac{\rho_s}{\rho} - 1 \right)]}} \left[32 \log(10R/D_*) \right]^{1-n}$ $D_* > 60 \begin{cases} A = 0.17 \\ C = 0.025 \\ m = 1.78 \\ n = 0 \end{cases} \quad D_* \leq 1 \begin{cases} A = 0.17 \\ C = 0.025 \\ m = 1.78 \\ n = 1 \end{cases}$ $1 < D_* < 60 \begin{cases} A = \frac{0.23}{\sqrt{D_*}} + 0.14 \\ \text{Log} C = 2.86 \text{Log} D_* - (\text{Log} D_*)^2 - 3.53 \\ m = \frac{9.66}{D_*} + 1.34 \\ n = 1 - 0.56 \text{Log} D_* \end{cases}$
$0.088 \leq D_{50} \leq 1.41$	Karim (1998) تحلیل رگرسیونی	$\frac{q_t}{(G_s - 1)gd_{50}^3} = 0.00139 \left(\frac{V}{(G_s - 1)gd_{50}} \right)^{2.97} \left(\frac{U_*}{\omega_s} \right)$
$2 \leq D_{50} \leq 10$ $0.43 \leq V \leq 1.56$ $1.2 \leq S_f \times 10^3 \leq 29$	تئوری توان جریان Yang (2006)	$q_t = \gamma V C_{ppm} \times 10^6$ $\log C_{ppm} = 6.681 - 0.633 \log \left(\frac{\omega_s D_{50}}{v} \right) - 4.816 \left(\frac{U_*}{\omega_s} \right) + \left[2.784 - 0.305 \log \left(\frac{\omega_s D_{50}}{v} \right) - 0.282 \log \left(\frac{U_*}{\omega_s} \right) \log \left(\frac{VS_f}{\omega_s} - \frac{V_{cr} S_f}{\omega_s} \right) \right]$ $\frac{V_{cr}}{\omega_s} = \frac{2.5}{\log \frac{U_* D_{50}}{v} + 0.06} \quad 1.2 < \frac{U_* D_{50}}{v} \leq 70$ $\frac{V_{cr}}{\omega_s} = 2.05 \quad \frac{U_* D_{50}}{v} > 70$
$0.06 \leq D_{50} \leq 1.41$	Shen and Hung (1972) تحلیل رگرسیونی Yang (2006)	$q_t = \gamma V C_{ppm} \times 10^6$ $\log C_{ppm} = -107404.46 + 324214.75X - 326309.589X^2 + 109503.872X^3$ $X = \left(\frac{VS_f^{0.57159}}{\omega_s^{0.31988}} \right)^{0.007502}$

در روابط فوق، q_t دبی بار کل رسوب در واحد عرض رودخانه، q دبی جریان در واحد عرض، R شعاع هیدرولیکی، U_* سرعت برشی جریان، ω_s سرعت سقوط ذره، G_s چگالی ویژه ذرات رسوب، g شتاب ثقل، γ و γ_s به ترتیب وزن واحد حجم آب و ذرات رسوب، D_* عدد ذره، V_{cr} سرعت متوسط جریان در آستانه حرکت و یا سرعت بحرانی، C_{ppm} غلظت وزنی بار کل رسوب (ppm)

نرمال شده‌اند. همچنین ۷۵ درصد از داده‌های هر رودخانه به صورت جداگانه برای آموزش مدل و ۲۵ درصد نیز برای قسمت صحت سنجی انتخاب شده و در نهایت مجموع داده‌های فوق برای مدل‌سازی به کار گرفته شدند.

$$x_{istd} = 0.1 + 0.9 \times \left(\frac{x_i - x_{imin}}{x_{imax} - x_{imin}} \right) \quad (\text{رابطه ۹})$$

پیش‌پردازش داده‌ها

یکی از مراحل اصلی در استفاده از روش‌های هوشمند پیش-پردازش داده‌ها می‌باشد. با توجه به دامنه وسیع داده‌های ورودی و به منظور افزایش دقت و سرعت مدل‌سازی، داده‌های مورد استفاده در این تحقیق با استفاده از رابطه (۹) در بازه (۰/۰-۱/۹)

همچنین جذر میانگین مربعات خطا برابر با ۰/۰۲۱ برای داده‌های صحت‌سنجی به عنوان مدل برتر در پیش‌بینی بار کل رسوب انتخاب می‌گردد. با انجام فرآیند سعی و خطا مشخص گردید جایگزینی پارامتر $V^3/gR\omega_s$ به جای R/D_{50} باعث بهبود نتایج حاصل از مدل‌سازی می‌گردد. این پارامتر از رابطه Molinas and Wu (۲۰۰۱) به دست آمده و بر اساس تئوری نیروی ثقل Velicanov می‌باشد. مبنای این تئوری به این صورت می‌باشد که توان موجود در جریان برابر با مجموع توان مورد نیاز برای غلبه بر مقاومت جریان و نیز توان مورد نیاز برای غلبه بر نیروی ثقل برای نگه‌داشتن ذرات رسوب در حالت معلق می‌باشد. همچنین استفاده از پارامتر بی‌بعد شیلدز (θ) به جای عدد ذره (D_*) در ارتقای مقادیر معیارهای ارزیابی کمک می‌کند. با بررسی نتایج حاصل مشاهده می‌شود پارامتر بی‌بعد نسبت سرعت متوسط به سرعت برشی جریان (V/U_*) عضو مشترک در اکثر مدل‌های برتر بوده و نقشی اساس در پیش‌بینی بار کل رسوب ایفا می‌کند. این نسبت در واقع نشان دهنده مقاومت جریان و زبری کف کانال می‌باشد. مقایسه دو روش ماشین بردار پشتیبان و رگرسیون فرآیند گاوسی به عنوان دو روش مبتنی بر کرنل نیز نشان دهنده برتری رگرسیون فرآیند گاوسی در پیش‌بینی بار کل رسوب می‌باشد. این روش با مقادیر کمتر پارامتر گاما (γ) کارایی بالاتری را نسبت به ماشین بردار پشتیبان از خود نشان می‌دهد. هنگام استفاده از تابع کرنل RBF مقدار پارامتر نویز فرآیند گاوسی با استفاده از آزمون و خطا بین ۰/۰۱ تا ۰/۱ در نظر گرفته شد و ملاحظه گردید در نظر گرفتن پارامتر نویز برابر با ۰/۱ بهترین نتایج را به دنبال دارد. به طور کلی بررسی نتایج مدل‌سازی نشان‌دهنده کارایی بالای شبکه عصبی مصنوعی در پیش‌بینی بار کل و عملکرد ضعیف ماشین بردار پشتیبان می‌باشد. نتایج حاصل از مدل‌سازی بار کل رسوب در جدول (۵) و نمودار پراکنش بین داده‌های مشاهداتی و پیش‌بینی شده برای سری داده‌های آموزش و صحت‌سنجی برای مدل TL(IV) به عنوان مدل برتر در شکل ۱ آورده شده است. با توجه به پراکندگی بالای داده‌ها در بارهای کم، جهت مشاهده بهتر پراکندگی داده‌ها از نمودار لگاریتمی استفاده گردید.

نتایج حاصل از روابط کلاسیک

نتایج مربوط به چهار رابطه کلاسیک بررسی شده در این تحقیق در جدول (۶) ارائه شده است. بر اساس پارامترهای آماری مربوطه، هیچ یک از روابط دقت مناسبی در برآورد بار کل رسوب نداشته و با دارا بودن مقادیر منفی معیار ناش-سانتکلیف از قابلیت اعتماد کافی برخوردار نمی‌باشند. از دلایل ضعف این روابط می‌توان به توسعه آن‌ها در شرایط آزمایشگاهی اشاره نمود. Molinas and

که در آن X_{imin} کمترین داده و X_{imax} بیشترین داده از نظر مقدار است.

تعریف مدل‌ها با پارامترهای ورودی

انتخاب پارامترهای مختلف به عنوان ترکیب ورودی تأثیر بسیاری در دقت نتایج حاصل دارا می‌باشد. برای تعیین ورودی‌های مدل، ترکیب مختلفی از پارامترهای بدون بعد مبتنی بر هیدرولیک جریان مانند عدد فرود ($Fr = V/\sqrt{gy}$)، نسبت سرعت متوسط به سرعت برشی جریان (V/U_*) و نسبت عمق به عرض رودخانه (y/B) به همراه سایر پارامترهای مبتنی بر مشخصات رسوب مانند نسبت شعاع هیدرولیکی به متوسط ذرات رسوب (R_H/D_{50})، نسبت عمق به متوسط ذرات رسوب (y/D_{50}) استفاده گردید. پارامتر عدد حرکت به صورت زیر تعریف می‌گردد:

$$T = \frac{\theta' - \theta_{cr}}{\theta_{cr}} \quad (\text{رابطه } 10)$$

در رابطه بالا θ' پارامتر حرکت مربوط به زبری ذره θ_{cr} نیز عدد شیلدز بحرانی است که برابر است با:

$$\theta' = \frac{v^2}{(G_s - 1)D_{50}C^2} \quad (\text{رابطه } 11)$$

$$C = 18 \log \left(\frac{4y}{D_{90}} \right) \quad (\text{رابطه } 12)$$

$$\theta_{cr} = \frac{\tau_c}{(\rho_s - \rho_w)gD_{50}} \quad (\text{رابطه } 13)$$

که τ_c تنش برشی جریان در آستانه حرکت ذره است. به منظور دستیابی به مدل‌هایی با قابلیت اعتماد بالا، ترکیب مختلفی از پارامترهای فوق تعریف شده و پس از انجام فرآیند سعی و خطا، مدل‌های برتر انتخاب شدند. مدل‌های تعریف شده برای پیش‌بینی بار کل رسوب در جدول (۴) ارائه شده‌اند.

جدول ۴- مدل‌های تعریف شده برای پیش‌بینی بار کل رسوب

مدل	پارامترهای ورودی
TL(I)	$\left(Re_* \cdot D_* \cdot \frac{R}{D_{50}} \right)$
TL(II)	$\left(\frac{V}{U_*} \cdot D_* \cdot \frac{R}{D_{50}} \right)$
TL(III)	$\left(Fr \cdot \frac{V}{U_*} \cdot D_* \cdot \frac{R}{D_{50}} \right)$
TL(IV)	$\left(Fr \cdot \frac{V}{U_*} \cdot \theta \cdot \frac{V^3}{g \cdot y \cdot \omega_s} \right)$
TL(V)	$\left(Fr \cdot \frac{V}{U_*} \cdot \theta \cdot T \cdot \frac{V^3}{g \cdot y \cdot \omega_s} \right)$

نتایج و بحث

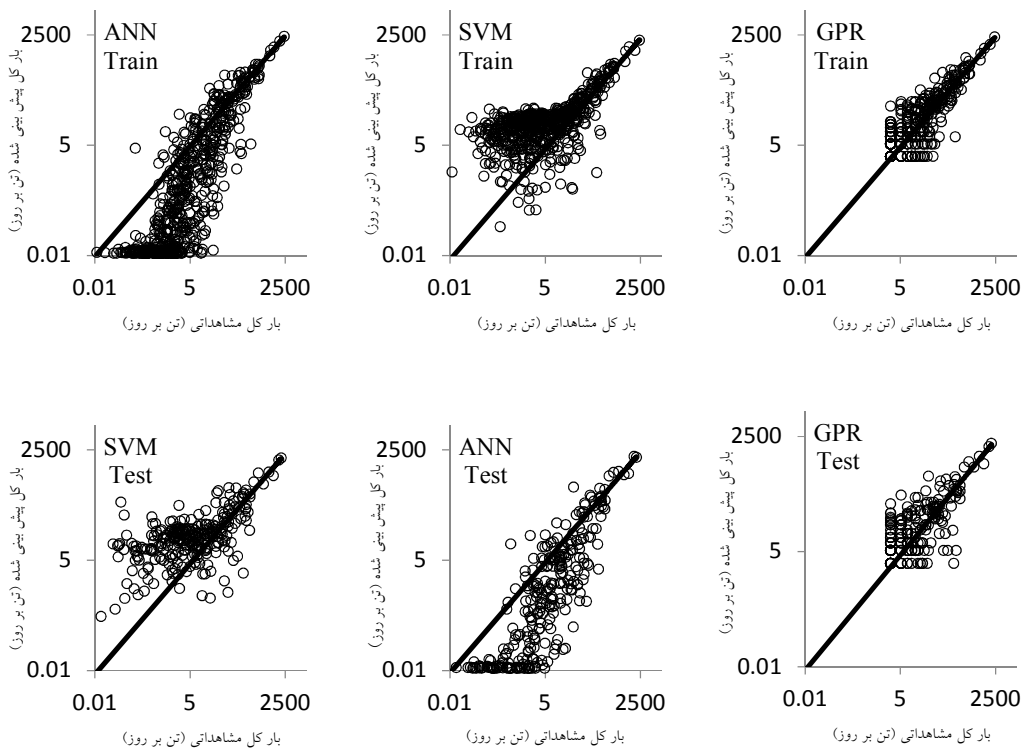
با توجه به مقادیر معیارهای ارزیابی (R ، NSE و $RMSE$) شبکه عصبی مصنوعی از برتری کاملی نسبت به دو روش دیگر برخوردار می‌باشد. نتایج به دست آمده از این روش در تمامی مدل‌ها برتری کاملی نسبت به SVM و GPR دارا می‌باشد. مدل TL(IV) با استفاده از شبکه عصبی مصنوعی و ۹ نرون و با مقادیر ضریب همبستگی و معیار ناش-سانتکلیف به ترتیب ۰/۹۵۲ و ۰/۰۰۳ و

گرفتند روابط ذکر شده قابلیت استفاده در رودخانه‌های بزرگ را ندارند. نمودار پراکنش بین داده‌های مشاهداتی و پیش‌بینی شده به وسیله روابط کلاسیک در شکل (۲) آورده شده است.

Wu (2001) نیز علت عدم کارایی سه رابطه (Engelund and Hansen (1967) و Ackers and White (1973) و Yang (2006) را توسعه آن‌ها در شرایط آزمایشگاهی با عمق کم اعلام کرده و نتیجه

جدول ۵- نتایج حاصل از مدل‌سازی بار کل رسوب


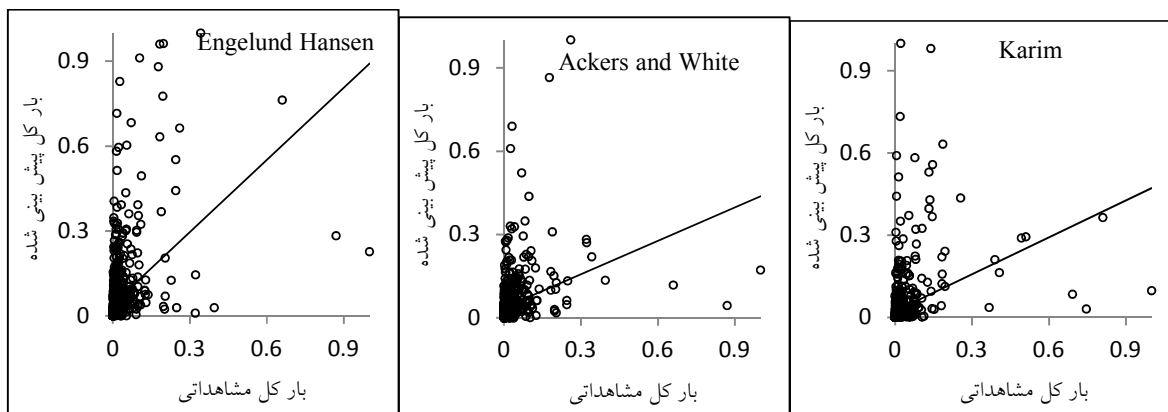
معیارهای ارزیابی						پارامترهای بهینه				روش	مدل
صحت سنجی			آموزش								
RMSE	NSE	R	RMSE	NSE	R	C	ϵ	γ	نویز	تعداد نرون	
۰/۰۶۱	۰/۲۱۱	۰/۵۰۸	۰/۰۴۴	۰/۴۱۵	۰/۷۱۷	۱	۰/۰۰۱	۱۰	-	-	TL(I)
۰/۰۵۰	۰/۴۶۶	۰/۷۷۱	۰/۰۳۸	۰/۵۵۴	۰/۸۰۰	۱	۰/۰۰۱	۶۰	-	-	TL(II)
۰/۰۳۸	۰/۶۸۸	۰/۸۶۴	۰/۰۳۱	۰/۷۰۱	۰/۸۹۶	۳	۰/۰۰۱	۱۲	-	-	TL(III)
۰/۰۲۶	۰/۸۵۸	۰/۹۳۲	۰/۰۱۹	۰/۸۹۲	۰/۹۵۵	۴	۰/۰۰۱	۲۵	-	-	TL(IV)
۰/۰۵۱	۰/۴۵۷	۰/۷۱۷	۰/۰۲۷	۰/۷۷۴	۰/۸۸۲	-	-	۱۰	۰/۱	-	TL(I)
۰/۰۳۹	۰/۶۶۷	۰/۸۲۰	۰/۰۳۳	۰/۶۷۴	۰/۸۲۲	-	-	۱۵	۰/۱	-	TL(II)
۰/۰۳۰	۰/۸۰۴	۰/۸۹۷	۰/۰۲۰	۰/۸۷۱	۰/۹۳۶	-	-	۵	۰/۱	-	TL(III)
۰/۰۲۲	۰/۸۹۴	۰/۹۴۸	۰/۰۱۴	۰/۹۳۵	۰/۹۶۸	-	-	۱۲	۰/۱	-	TL(IV)
۰/۰۲۵	۰/۸۶۹	۰/۹۳۶	۰/۰۱۴	۰/۹۳۹	۰/۹۶۹	-	-	-	-	۷	TL(I)
۰/۰۳۷	۰/۷۱۱	۰/۸۹۰	۰/۰۱۶	۰/۹۱۵	۰/۹۵۷	-	-	-	-	۸	TL(II)
۰/۰۲۸	۰/۸۳۰	۰/۹۱۴	۰/۰۱۲	۰/۹۵۰	۰/۹۷۶	-	-	-	-	۵	TL(III)
۰/۰۲۱	۰/۹۰۳	۰/۹۵۲	۰/۰۱۳	۰/۹۴۸	۰/۹۷۴	-	-	-	-	۱۰	TL(IV)



شکل ۱- نمودار پراکنش بین داده‌های مشاهداتی و پیش‌بینی شده برای مدل برتر

جدول ۶- نتایج حاصل از روابط کلاسیک

رابطه تجربی	R	RMSE	NSE
Engelund and Hansen (1967)	۰/۴۳۸	۰/۱۱۷	-۲/۱۴
Ackers and White (1973)	۰/۳۳۲	۰/۰۸۴	-۰/۶۵۱
Karim (1998)	۰/۳۴۴	۰/۰۹۳	-۰/۸۳۶
Yang (2006)	۰/۱۰۱	۰/۲۴۳	-۰/۲۳۷
Shen and Hung (1972)	۰/۴۲۴	۰/۱۲۸	-۲/۴۶



شکل ۲- نمودار پراکنش بین داده‌های مشاهداتی و پیش‌بینی شده با استفاده از روابط کلاسیک

که معیار ناش-ساتکلیف به دست آمده از ماشین بردار پشتیبان برای داده‌های صحت‌سنجی از ۰/۸۵۸ به ۰/۰۶۱ کاهش پیدا نموده است. بنابراین همان‌طور که در قسمت‌های قبل نیز بیان گردید نسبت سرعت متوسط به سرعت برشی جریان به عنوان تأثیرگذارترین پارامتر در فرآیند پیش‌بینی بار کل رسوب در رودخانه‌های با بستر شنی انتخاب می‌گردد. پس از این نسبت، عدد فرود (Fr) و عدد بی‌بعد شیلدز (θ) و در نهایت نیز پارامتر بی‌بعد ($V^3/gy\omega_s$) به دست آمده از رابطه تجربی Molinas and Wu (2001) به عنوان پارامترهای تأثیرگذار معرفی می‌گردند.

تحلیل حساسیت

به منظور بررسی میزان تأثیر پارامترهای مختلف در فرآیند پیش-بینی بار کل رسوب از تحلیل حساسیت در این قسمت استفاده گردید. بدین منظور با حذف هر یک از پارامترهای مدل TL(IV) به عنوان مدل برتر و آموزش مجدد آن در ماشین بردار پشتیبان، میزان تغییرات پارامترهای آماری بررسی و پارامترهای اصلی معرفی شدند. نتایج حاصل از تحلیل حساسیت در جدول (۷) ارائه شده است.

مطابق با نتایج به دست آمده مشاهده می‌شود با حذف پارامترهای آماری بیشترین کاهش را نشان داده به نحوی

جدول ۷- نتایج حاصل از تحلیل حساسیت

داده‌های صحت سنجی			معیارهای ارزیابی			پارامتر حذف شده	مدل برتر
NSE	RMSE	R	NSE	RMSE	R		
۰/۶۹۹	۰/۰۳۸	۰/۸۹۶	۰/۷۸۸	۰/۰۲۶	۰/۹۱۳	Fr	TL(IV)
۰/۰۶۱	۰/۰۶۷	۰/۳۷۶	۰/۱۹۲	۰/۰۵۲	۰/۵۵۳	V/U_*	
۰/۸۲۵	۰/۰۲۸	۰/۹۱۲	۰/۹۰۶	۰/۰۱۷	۰/۹۵۳	θ	
۰/۸۴۰	۰/۰۲۷	۰/۹۱۷	۰/۹۱۴	۰/۰۱۷	۰/۹۵۷	$V^3/gy\omega_s$	

نتیجه‌گیری

مختلفی از پارامترهای بدون بعد مبتنی بر هیدرولیک جریان و مشخصات رسوب استفاده گردید. خروجی مدل‌های مربوطه نشان دهنده کارایی بالای شبکه عصبی مصنوعی در برآورد بار کل رسوب بوده است. همچنین با توجه به مقادیر معیارهای ارزیابی، ماشین بردار پشتیبان از دقت کمتری نسبت به سایر روش‌های به کار گرفته شده برخوردار بود. از بین روش‌های کلاسیک انتخاب شده نیز معیارهای ارزیابی مقادیر ضعیفی را به دنبال داشته و هیچ یک از روابط از قابلیت اطمینان کافی برخوردار نبودند. همچنین مطابق با نتایج تحلیل حساسیت، نسبت سرعت متوسط به سرعت برشی جریان (V/U_*) و پس از آن عدد فرود (Fr) به عنوان تأثیرگذارترین پارامترها در پیش‌بینی بار کل رسوب انتخاب گردید.

پیش‌بینی مقدار بار رسوب انتقالی با توجه به اهمیت خود در مدیریت مخازن و برآورد عمر سدها، طراحی سازه‌های هیدرولیکی، مباحث مربوط به کیفیت و تصفیه آب، تغییر کاربری اراضی و بسیاری از موارد دیگر، از اهمیت ویژه‌ای برخوردار می‌باشد. در این بین با وجود پیچیده‌تر بودن فرآیند انتقال رسوب در رودخانه‌های درشت دانه، کمبود داده‌های مرتبط موجب محدود بودن مطالعات در رابطه با پیش‌بینی بار رسوب کل در این نوع رودخانه‌ها شده است. در این تحقیق با استفاده از ۹۰۰ داده جمع‌آوری شده از رودخانه‌های با بستر شنی به پیش‌بینی آن با استفاده از روش‌های هوشمند پرداخته شد. بدین منظور از ترکیب

REFERENCES

- Ackers, P. and White, W.R. (1973). Sediment transport: new approach and analysis. *Journal of the Hydraulics Division*, 99(hy11).
- Bhattacharya, B., Price, R. K. and Solomatine, D. P. (2007). Machine learning approach to modeling sediment transport. *Journal of Hydraulic Engineering*, 133(4), 440-450.
- Brownlie, W. R. (1981). Prediction of flow depth and sediment discharge in open channels. Report No. KH-R-43A, Keck Laboratory of Hydraulics and Water Resources, California Institute of Technology, Pasadena, CA, USA.
- Chang, C. K., Azamathulla, H. M., Zakaria, N. A. and Ab Ghani, A. (2012). Appraisal of soft computing techniques in prediction of total bed material load in tropical rivers. *Journal of earth system science*, 121(1), 125-133.
- Choi, S.U. and Lee, J. (2015). Assessment of total sediment load in rivers using lateral distribution method. *Journal of Hydro-environment Research*, 9(3): 381-387.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3): 273-297.
- Doğan, E., Yüksel, İ. and Kişi, Ö. (2007). Estimation of total sediment load concentration obtained by experimental study using artificial neural networks. *Environmental fluid mechanics*, 7(4):271-288.
- Einstein, H.A. (1950). *The bed-load function for sediment transportation in open channel flows* (Vol. 1026). Washington DC: US Department of Agriculture.
- Engelund, F. and Hansen, E. (1967). A monograph on sediment transport in alluvial streams. *Technical University of Denmark Ostervoldgade 10, Copenhagen K.*
- Falamaki, A., Eskandari, M. Baghlani, A., and Ahmadi, S. A. (2013). Modeling total sediment load in rivers using artificial neural networks. *Journal of Soil and Water Resources Conservation*. 2(3), 13-26. (In Farsi)
- Karim, F. (1998). Bed material discharge prediction for nonuniform bed sediments. *Journal of Hydraulic Engineering*, 124(6):597-604.
- Khorram, S. and Ergil, M. (2010). A Sensitivity Analysis of Total-Load Prediction Parameters in Standard Sediment Transport Equations. *JAWRA Journal of the American Water Resources Association*, 46(6):1091-1115.
- King, J.G., Emmett, W.W., Whiting, P.J., Kenworthy, R.P. and Barry, J.J. (2004). Sediment transport data and related information for selected coarse-bed streams and rivers in Idaho. *General technical report. U. S. Department of Agriculture, Forest*

- Service, Rocky Mountain Research Station, (131):26.
- Kumar, B. (2012). Neural network prediction of bed material load transport. *Hydrological sciences journal*, 57(5), 956-966.
- Molinas, A. and Wu, B. (2001). Transport of sediment in large sand-bed rivers. *Journal of hydraulic research*, 39(2):135-146.
- Okcu, D., Pektas, A.O. and Uyumaz, A. (2016). Creating a non-linear total sediment load formula using polynomial best subset regression model. *Journal of Hydrology*, 539:662-673.
- Rasmussen, C. E. and Williams, C. K. (2006). *Gaussian process for machine learning*. MIT press.
- Roushangar, K. and 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., Javan, F. P. (2014). Evaluation of artificial intelligent technique in prediction of sediment transport rate in Ajichai river. *Journal of Geographic Space*. 14(46), 173-197. (In Farsi)
- Roushangar, K., Mehrabani, F.V. and Shiri, J. (2014). Modeling river total bed material load discharge using artificial intelligence approaches (based on conceptual inputs). *Journal of hydrology*, 514:114-122.
- Sahraei, S., Alizadeh, M. R., Talebbeydokhti, N. and Dehghani, M. (2017). Bed material load estimation in channels using machine learning and meta-heuristic methods. *Journal of Hydroinformatics*, 20(1):100-116.
- Shafai Bejestan, M. (2009). Basic theory and practice of Hydraulic of sediment transport. Shahid Chamran University.
- Shen, H. W, and Hung, C. S. (1972). An engineering approach to total bed material load by regression analysis. Proc., Sedimentation Symposium, Chap. 14, 14.1-14.7.
- Yang, C. T. (2006). Reclamation managing water in the west. Erosion and sedimentation manual. US Department of the Interior, Bureau of Reclamation.
- Yang, C.T., Marsooli, R. and Aalami, M.T. (2009). Evaluation of total load sediment transport formulas using ANN. *International Journal of Sediment Research*, 24(3):274-286.
- Zakaria, N. A., Azamathulla, H. M., Chang, C. K. and Ghani, A. A. (2010). Gene expression programming for total bed material load estimation—a case study. *Science of the total environment*, 408(21): 5078-5085.