



## Prediction of Suspended Sediment Using Hydrologic and Hydrogeomorphic Data within Intelligence Models

H. Asadi<sup>1</sup>, K. Shahedi<sup>2\*</sup>, R. C. Sidle<sup>3</sup>,  
and S.M. Kalami Heris<sup>4</sup>

### Abstract

Accurate estimation of transported sediment by rivers plays an important role in water resources management. So the selection of proper methods for estimation of suspended sediment is an important objective to that goal. In this regard, application of intelligence models (e.g., ANN, SVR) has substantially improved the prediction of suspended sediment. Using these models, an important step in suspended sediment modeling is the proper input selection since input vectors determine the structure of the model and, hence, influence model results. In the most studies, only climatic and hydrological variables have been used as suspended sediment estimators using data-driven models. Therefore, this study was designed to determine the effective and accessible geomorphological variables in suspended sediment estimation for the Tamar catchment. To accomplish this goal, the effect of the Index of Connectivity (IC) as a hydrogeomorphic input, in addition to the hydrologic inputs, was investigated. Comparison of the results for different input patterns indicated that using IC along with hydrological inputs improved the model efficiency reported by decrease in the root mean squared error (9.63% and 26.36%) and increase in the Nash-Sutcliffe efficiency (25.80% and 21.85%) and in the coefficient of determination (13.20% and 45.94%) respectively for ANN and SVR models.

**Keywords:** Suspended Sediment Modeling; Artificial Neural Network; Support Vector Regression; Index of Sediment Connectivity.

Received: February 10, 2019

Accepted: June 8, 2019

## پیش‌بینی رسوب معلق با استفاده از داده‌های هیدرولوژیک و هیدروژئومورفیک در مدل‌های هوشمند

هانیه اسدی<sup>۱</sup>، کاکا شاهدی<sup>۲\*</sup>، ری سایدل<sup>۳</sup>  
و سیدمصطفی کلامی هریس<sup>۴</sup>

### چکیده

برآورد دقیق مقدار رسوبات حمل شده توسط رودخانه‌ها، در مدیریت منابع آب از اهمیت بسیاری برخوردار است. بنابراین شناسایی مدل‌های مناسب جهت برآورد رسوب معلق از اهداف مهم تلقی می‌شود. در این زمینه کاربرد مدل‌های هوشمند از جمله شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان تحول عظیمی به وجود آورده است. یک گام مهم در مدل‌سازی رسوب معلق با استفاده از این مدل‌ها، انتخاب ورودی‌های مناسب می‌باشد؛ زیرا ساختار و نتایج مدل را تحت تأثیر قرار می‌دهند. با توجه به این که در اکثر مطالعات در این زمینه، تنها از متغیرهای اقلیمی و هیدرولوژیک به عنوان متغیرهای تخمین‌گر استفاده گردیده است. بنابراین پژوهش حاضر به منظور تعیین متغیرهای ژئومورفولوژیک اثرگذار و قابل دسترس در تخمین رسوب معلق در حوضه آبخیز تمار طراحی گردید. برای دستیابی به این هدف، نقش شاخص اتصال رسوبی به عنوان یک ورودی هیدروژئومورفیک علاوه بر ورودی‌های هیدرولوژیک مورد ارزیابی قرار گرفت. مقایسه نتایج الگوهای ورودی مختلف نشان داد که کاربرد شاخص اتصال رسوبی کارایی مدل‌ها را بهبود می‌دهد و این بهبود به صورت کاهش (%۹/۶۳ و %۲۶/۳۶) در مجذور میانگین مربعات خطا و افزایش (%۲۵/۸۰ و %۲۱/۸۵) در ضریب کارایی ناش-ساتکلیف و (%۱۳/۲۰ و %۴۵/۹۴) در ضریب تبیین به ترتیب در مدل‌های شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان می‌باشد.

**کلمات کلیدی:** مدل‌سازی رسوب معلق، شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان، شاخص اتصال رسوبی.

تاریخ دریافت مقاله: ۹۷/۱۱/۲۱

تاریخ پذیرش مقاله: ۹۸/۳/۱۸

1- Ph.D. Student, Department of Watershed Management Engineering, Sari Agricultural Sciences and Natural Resources University, Sari, Iran.

2- Associate Professor, Department of Watershed Management Engineering, Sari Agricultural Sciences and Natural Resources University, Sari, Iran. Email: [k.shahedi@sanru.ac.ir](mailto:k.shahedi@sanru.ac.ir)

3- Director of Mountain Societies Research Institute and Professor of Earth and Environmental Sciences, University of Central Asia, Tajikistan.

4- Ph.D. Graduate, Faculty of Electrical Engineering, K.N.Toosi University of Technology, Tehran, Iran.

\*- Corresponding Author

۱- دانشجوی دکتری گروه مهندسی آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ایران.

۲- دانشیار گروه مهندسی آبخیزداری، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ایران.

۳- استاد علوم زمین و محیط زیست، دانشگاه آسیای میانه، تاجیکستان.

۴- دانش آموخته دکتری گروه مهندسی برق، دانشگاه صنعتی خواجه نصیرالدین طوسی، ایران.

\*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان زمستان ۱۳۹۸ امکانپذیر است.

آرکانزاس و آیداهو در آمریکا برتری مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی را در برآورد رسوب معلق نسبت به مدل‌های سنتی رگرسیونی، منحنی سنجه رسوب و سایر مدل‌ها نشان دادند. در پژوهش‌های انجام شده توسط Chiang et al. (2014) در حوضه آبخیز گودوین کریک در آمریکا و Choubin et al. (2018) در حوضه آبخیز هراز، برتری مدل SVR نسبت به مدل شبکه عصبی مصنوعی در تخمین رسوب معلق نشان داده شد. بررسی پژوهش‌های پیشین نشان می‌دهد که در این مدل‌های داده‌محور از متغیرهای اقلیمی (مانند بارش و دما) و متغیرهای هیدرولوژیکی (مانند دبی جریان، ارتفاع جریان و مقادیر رسوب پیشین) به عنوان ورودی مدل‌ها استفاده شده است.

از طرفی اتصال رسوبی به عنوان مفهومی نوظهور در مدیریت رسوب، در چند سال اخیر برای بررسی انتقال رسوب در بخش‌های مختلف حوضه‌های آبخیز مورد توجه قرار گرفته است که به انتقال رسوب از یک بخش به بخشی دیگر و پتانسیل جابه جایی برای یک ذره رسوب در سراسر سامانه آبخیز (درون دامنه‌ای، بین دامنه و آبراهه و درون آبراهه‌ای) گفته می‌شود (Bracken et al., 2013). در مطالعات خارج از کشور طی ده سال اخیر توجه ویژه‌ای به این موضوع صورت گرفته است بر همین اساس Borselli et al. (2008) دو شاخص اتصال و شاخص میدانی اتصال<sup>۲</sup> را با استفاده از اطلاعات توپوگرافی، کاربری و سیمای سرزمین، برای بررسی اتصال رواناب و رسوب در حوضه آبخیز بلانسنیو در ایتالیا معرفی کردند و بیان نمودند که با استفاده از این شاخص‌ها مفهوم اتصال کمی شده است. Lesschen et al. (2009) در چهار سناریوی مدیریتی، به بررسی کیفی و مقایسه‌ای تأثیر اتصال هیدرولوژیکی در تغییرات منابع و مخازن رسوب در سناریوهای مدنظر در حوضه آبخیز کارکاو در اسپانیا پرداختند. نتایج پژوهش مذکور نشان داد که در سناریوی حذف ترانس‌های کشاورزی، تولید رواناب و رسوب به علت افزایش اتصال، به ترتیب چهار و نه برابر شد. Cavalli et al. (2013) نیز در رابطه با شاخص اتصال، به جای استفاده از عامل پوشش گیاهی معادله جهانی فرسایش خاک، از شاخص زبری سطحی توپوگرافی<sup>۳</sup> استفاده کرده و امکان استفاده از آن را برای بررسی اتصال مناطق واریزه‌ای بدون پوشش فراهم نمودند. ایشان با تأکید بر سریع و آسان بودن این روش، بیان داشتند که تعیین توزیع اتصال رسوبی و تقسیم حوضه به مناطق همگن از این نظر، سبب ارائه نسخه‌های مدیریت رسوبی متناسب با هر منطقه شد. Wester et al. (2014) به بررسی اتصال ساختاری و عملکردی رواناب در یک حوضه آبخیز آتش‌سوزی شده در کالیفرنیا با استفاده از مدل‌های رقومی ارتفاعی در حد تفکیک مکانی چند میلی‌متر پرداختند. نتایج بیانگر آن بود که در بارندگی‌های با شدت و مقدار کمتر میزان

با توجه به اهمیت حفظ منابع آب و خاک کشور و آرایه راهکارهای مناسب برای سیاست‌گذاری کلان در حوضه‌های آبخیز، آمار و اطلاعات دقیق و بهنگام که بتواند سیمای آبخیز و بخصوص وضعیت حوضه‌های حساس و بحرانی را به لحاظ فرسایش و رسوب نشان دهد مورد نیاز است. بار رسوب معلق رودخانه‌ای که حدود ۷۵ تا ۹۵ درصد کل رسوب رودخانه را شامل می‌گردد، از جنبه‌های مختلف (نظیر مهندسی منابع آب، مسائل زیست‌محیطی، کیفیت آب و غیره) حائز اهمیت بوده و می‌تواند به‌عنوان شاخصی از وضعیت فرسایش خاک و شرایط اکولوژیکی حوضه در نظر گرفته شود (Zhu et al., 2007). پیش‌بینی و تخمین بار رسوب رودخانه‌ها، در مدیریت رودخانه‌ها و مخازن سدها در پروژه‌های آبی نیز از اهمیت بالایی برخوردار است. در زمینه برآورد بار رسوب معلق با توجه به پیچیدگی پدیده رسوب و عدم توانایی تعیین دقیق معادلات حاکم، به خاطر وجود پارامترهای مختلف و تأثیر تغییرات مکانی، زمانی و شرایط هیدرولوژیکی حوضه آبخیز، محققان به استفاده از مدل‌های داده‌محور روی آورده‌اند (Rajaei et al., 2009). از جمله این مدل‌های داده‌محور که در دهه‌های اخیر، به عنوان پیش‌بینی‌کننده‌های پدیده‌های هیدرولوژیکی، تحول عظیمی در مدل‌سازی به وجود آورده‌اند، توسعه مدل‌های هوش مصنوعی، مانند شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبان<sup>۱</sup> و نظایر آن می‌باشد (Kisi et al., 2009; Yang et al., 2009). در واقع این مدل‌ها به عنوان شبکه‌های غیرخطی قادرند بدون در نظر گرفتن محدودیت فیزیکی پارامترها یک ارتباط منطقی بین ورودی و خروجی با استفاده از داده‌های مشاهداتی برقرار کنند. در چند دهه اخیر تحقیقات زیادی در زمینه کاربرد مدل‌های هوشمند در تخمین رواناب (Araghinejad and Karamouz, 2005; Fathian et al., 2019; Khosravi and Salajegheh, 2013) و رسوب و برتری دقت این مدل‌ها بر روابط هیدرولیکی و هیدرولوژیکی ارائه شده است (Sheykhalipour, 2013). پژوهش‌های انجام شده در زمینه تخمین رسوب توسط Zhu et al. (2007) در حوضه یانگ‌تسه در چین، Melesse et al. (2011) در سه رودخانه بزرگ در آمریکا، Dehghani and Vafakhah (2013) در حوضه آبخیز گرگان‌رود، Tabatabaei et al. (2014) در رودخانه کرج در ایران و Khan et al. (2019) در حوضه گانگیز در هند کارایی بهتر مدل شبکه عصبی مصنوعی را نسبت به روش‌های سنتی از جمله روش‌های رگرسیونی، منحنی سنجه رسوب و سایر مدل‌ها نشان دادند. همچنین، Kakaei Lafdani et al. (2013) در رودخانه دوبرج واقع در غرب ایران، Kumar et al. (2016) در حوضه رودخانه کوپیلی در هند و Zounemat-Kermani et al. (2016) در ایستگاه‌های دلور،

اتصال کاهش یافته، حال آن که بارندگی‌های با شدت و مقدار بالا منجر به سیلاب و جریان واریزه‌ای<sup>۴</sup> شده است. (Asadi et al. (2019) در پژوهشی در دو حوضه هوگتون و کالیپ در استرالیا نقش پارامتر شاخص اتصال را در برآورد رواناب حوضه با استفاده از مدل شبکه عصبی مصنوعی و پارامترهای هیدروکلیماتیک بررسی نمودند، نتایج حاکی از تأثیر قابل توجه این پارامتر در برآورد دقیق‌تر از رواناب حوضه‌های مذکور بود. همچنین، بر اساس تنها پژوهش صورت گرفته، در رابطه با شاخص اتصال رسوبی<sup>۵</sup> در داخل کشور، (Najafi et al. (2017) به بررسی پراکنش مکانی و تغییرات زمانی اتصال ساختاری رسوب در حوضه آبخیز تهم چای زنجان پرداختند که بر اساس نتایج بدست آمده، امکان بررسی اتصال ساختاری و تغییرات زمانی و مکانی آن در گستره آبخیز وجود داشت و از طریق آن می‌توان به تشخیص مناطق همگن از نظر میزان احتمال انتقال رسوب تولیدی دست یافت.

بررسی پژوهش‌های گذشته نشان می‌دهد که علیرغم کارایی مدل‌های هوشمند در مدل‌سازی رسوب معلق، این مدل‌ها نمی‌توانند ناهمگونی فیزیکی و خصوصیات ژئومورفولوژیکی حوضه را طی یک فرآیند هیدرولوژیکی در حوضه نشان دهند. همچنین، با توجه به اینکه در پژوهش‌های گذشته از متغیرهای اقلیمی و هیدرولوژیکی به عنوان تنها متغیرهای تخمین‌گر رسوب معلق استفاده گردیده است و تحقیقی در رابطه با استفاده از خصوصیات ژئومورفولوژیکی حوضه به عنوان متغیرهای ورودی در مدل‌های هوشمند به منظور تخمین رسوب معلق وجود ندارد. لذا در این پژوهش سعی گردید که متغیرهای ژئومورفولوژیکی اثرگذار و قابل دسترس در مدل‌سازی رسوب معلق تعیین شوند. در این راستا تأثیر استفاده از شاخص اتصال رسوبی به عنوان یک پارامتر هیدروژئومورفیک علاوه بر ورودی‌های هیدرولوژیک در مدل‌های شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان و ارزیابی آن در کارایی مدل‌های مذکور به منظور دستیابی به نتایج قابل قبول در برآورد رسوب معلق مورد بررسی قرار گرفت.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

به منظور انجام تحقیق حاضر، آبخیز بالادست سد بوستان واقع در استان گلستان، در محدوده عرض جغرافیایی "۵۹° ۲۳' ۳۷" و "۴۸° ۴۶' ۳۷" شمالی و طول جغرافیایی "۵۵° ۳۰' ۰" و "۴۷° ۴' ۵۶" شرقی با مساحت ۱۵۳۳/۲۹ کیلومتر مربع، کمینه، بیشینه و میانگین ارتفاع به ترتیب ۱۰۸، ۲۱۷۴ و ۷۵۲/۷۹ متر از سطح دریا، شیب متوسط ۲۲/۹۵ درصد، میانگین بارندگی سالانه ۴۸۳/۳ میلی‌متر و میانگین دمای سالانه ۱۷/۸ درجه سانتیگراد انتخاب شد. شمالی کلی از منطقه مورد

مطالعه در شکل ۱ نشان داده شده است. در این پژوهش از داده‌های دبی و غلظت رسوب معلق ایستگاه هیدرومتری و رسوب‌سنجی تمر (شکل ۱)، به صورت متوسط ماهانه استفاده گردید که طول دوره آماری از فروردین ۱۳۷۹ تا شهریور ۱۳۹۲ بوده و شامل ۱۶۲ داده می‌باشد. پس از بررسی داده‌های مورد استفاده، ۷۰ درصد کل داده‌ها برای آموزش (واسنجی) و ۳۰ درصد باقی‌مانده برای تست (اعتبارسنجی) انتخاب شدند. پارامترهای آماری برای مجموعه‌های واسنجی، اعتبارسنجی و کل داده‌های مورد استفاده در این پژوهش در جدول ۱ ارائه شده‌اند. با توجه به اطلاعات آماری این جدول، داده‌های غلظت رسوب معلق دارای چولگی زیاد بوده که با در نظر گرفتن سایر آماره‌های محاسبه شده، می‌توان استنباط نمود که باعث پیچیدگی مدل‌سازی رسوب معلق خواهد شد.

### ۲-۲- روش پژوهش

مراحل انجام پژوهش حاضر در شکل ۲ به صورت خلاصه ارائه شده است.

#### ۲-۲-۱- شبکه عصبی مصنوعی<sup>۶</sup>

در واقع یک شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده و مانند مغز به پردازش اطلاعات می‌پردازد. این نوع شبکه‌ها قادر هستند روابط پیچیده غیرخطی میان بردارهای ورودی و خروجی را شناسایی کنند (Haykin, 1999). با توجه به کاربرد گسترده شبکه‌های عصبی مصنوعی به عنوان یک ابزار مدل‌سازی برای فرایندهای هیدرولوژیکی، در این مطالعه از شبکه عصبی پیشخور<sup>۷</sup> که کاربرد آن در پیش‌بینی سری‌های زمانی مورد توجه است، استفاده گردید (Kumar et al., 2016). در این نوع از شبکه‌های عصبی، جهت جریان داده، از لایه ورودی به سمت لایه پنهان و از لایه پنهان به سمت لایه خروجی می‌باشد که از این نظر به آنها شبکه‌های عصبی رو به جلو یا پیشخور گفته می‌شود. این مدل از سه لایه تشکیل شده است: لایه ورودی، لایه میانی (مخفی) و لایه خروجی. در این شبکه‌ها، نرون‌های لایه اول اطلاعات ورودی را گرفته و از طریق اتصالات مربوطه به نرون‌های لایه مخفی منتقل می‌کنند. در لایه مخفی پس از محاسبه ورودی مؤثر هر نرون، این ورودی از یک تابع محرک گذرانده می‌شود. به منظور محاسبه وزن‌های بهینه شبکه نیز، الگوریتم‌های مختلفی ارائه شده‌اند که در این میان الگوریتم آموزش پس انتشارخطا و تابع آموزش لوبنبرگ-مارکواریت<sup>۸</sup> پرکاربردترین آن‌ها می‌باشند (Hagan and Menhaj, 1994). به طور کلی، مقدار خروجی

حاصل از شبکه سه لایه FFNN با استفاده از رابطه (۱) بدست می‌آید (Kim and Valdés, 2003):

مناسب نرون در لایه پنهان، از روش آزمون و خطا استفاده گردید.

### ۲-۲-۲- رگرسیون بردار پشتیبان<sup>۹</sup>

ماشین‌های بردار پشتیبان دسته‌ای از روش‌های یادگیری با ناظر هستند که توسط Vapnik (1995) معرفی گردید. این مدل به طور موفقیت‌آمیزی در زمینه‌های گوناگون، از جمله منابع آب و پیش‌بینی بار رسوب، به کار رفته است. ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد. به طور کلی ماشین‌های بردار پشتیبان شامل دو دسته می‌باشند: دسته اول طبقه‌بندی کننده بردار پشتیبان که به دسته‌بندی داده‌ها می‌پردازد و دسته دوم رگرسیون بردار پشتیبان می‌باشد که عمل رگرسیون و برازش تابع را انجام می‌دهد.

که وزن نرون  $w_{ij}$  نام لایه ورودی در اتصال با نرون زام لایه مخفی و  $w_{jk}$  وزن نرون زام لایه مخفی در اتصال با نرون  $k$ ام لایه خروجی است.  $b_j$  و  $b_k$  مقادیر بایاس به ترتیب زامین نرون مخفی و  $k$ امین نرون خروجی و  $f_o$  و  $f_h$  توابع محرک به ترتیب لایه مخفی و خروجی هستند.  $x_i$  متغیر ورودی و  $y_k$  متغیر خروجی،  $N$  تعداد نرون‌های لایه ورودی و  $M$  تعداد نرون‌های لایه مخفی می‌باشند. در این مطالعه از ANN با الگوریتم پس انتشارخطا و تابع آموزش لونیبرگ-مارکوارت و تعداد تکرار ۱۰۰۰ استفاده شد. علاوه بر این، توابع فعال‌سازی مورد استفاده برای لایه مخفی و خروجی ترکیبی از توابع سیگموئید

$$y_k = f_o \left[ \sum_{j=1}^M w_{jk} \cdot f_h \left( \sum_{i=1}^N w_{ij} x_i + b_j \right) + b_k \right] \quad (1)$$

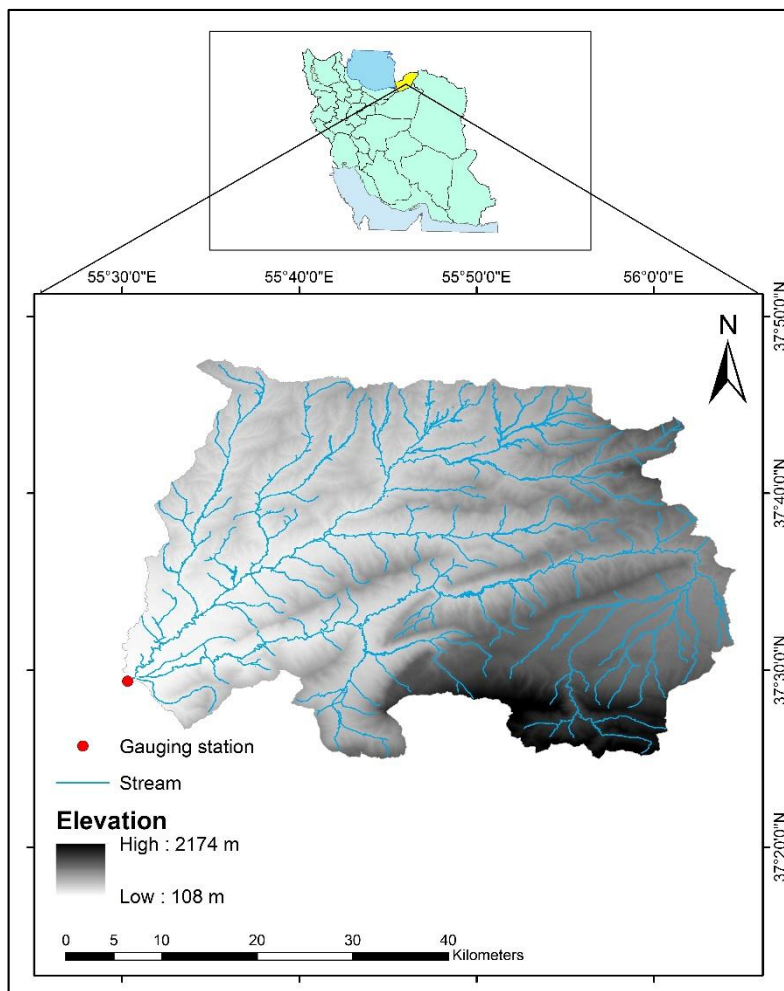


Fig. 1- Drainage network and location of the gauging stations in Tamar catchment

شکل ۱- نقشه ایستگاه و شبکه زهکشی حوضه تمر

**Table 1- Statistical parameters of monthly suspended sediment concentration, discharge and IC**

جدول ۱- پارامترهای آماری غلظت رسوب معلق، دبی و شاخص اتصال رسوبی ماهانه

Variable	Statistical parameter	Tamar Catchment		
		Calibration (70%)	Validation (30%)	Total data
	Number of data (n)	114	48	162
	Period (m/y)	4/2000-9/2009	10/2009-9/2013	4/2000-9/2013
SSC (mg/l)	$x_{min}$	0.01	0.24	0.01
	$x_{max}$	9259.15	299.63	9259.15
	$\bar{x}$	199.99	45.14	154.11
	$\sigma_x$	940.87	68.59	792.28
	$G_1$	8.46	1.97	10.07
	$\beta_2$	78.50	3.50	111.40
Q (m <sup>3</sup> /s)	$x_{min}$	0.00	0.01	0.00
	$x_{max}$	10.40	3.13	10.40
	$\bar{x}$	1.04	0.84	0.98
	$\sigma_x$	1.11	0.75	1.02
	$G_1$	2.96	1.53	2.93
	$\beta_2$	14.30	1.61	14.80
IC	$x_{min}$	0.60	0.70	0.60
	$x_{max}$	1.72	1.74	1.74
	$\bar{x}$	1.50	1.53	1.51
	$\sigma_x$	0.16	0.14	0.15
	$G_1$	-1.36	-1.2	-1.35
	$\beta_2$	1.30	0.98	1.27

SSC غلظت رسوب معلق، Q دبی جریان، IC شاخص اتصال رسوبی، n تعداد داده‌ها،  $x_{min}$  مقدار حداقل،  $x_{max}$  مقدار حداکثر،  $\bar{x}$  میانگین،  $\sigma_x$

انحراف استاندارد،  $G_1$  چولگی و  $\beta_2$  کشیدگی داده‌ها هستند.

SSD: suspended sediment concentration, Q: discharge, IC: Index of Connectivity, n: the number of data,  $x_{min}$ : minimum amount,  $x_{max}$ : maximum amount,  $\bar{x}$ : average amount,  $\sigma_x$ : standard deviation,  $G_1$ : skewness,  $\beta_2$ : Kurtosis

از توابع کرنل شناخته شده در ماشین‌های بردار پشتیبان (Chen and Yu, 2007) به صورت رابطه (۳)، استفاده گردید:

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (3)$$

بدین ترتیب در این مطالعه مدل SVR با استفاده از تابع کرنل RBF مورد آزمایش قرار گرفت و مقادیر بهینه پارامتر تابع کرنل RBF ( $\sigma$ ) و نیز مقادیر بهینه پارامترهای آموزشی SVR (C و  $\epsilon$ ) با استفاده از روش آزمون و خطا تعیین گردید.

### ۲-۲-۳- تبیین مدل‌ها

در هر دو مدل هوشمند مذکور، شبیه‌سازی غلظت رسوب معلق تحت ۶ سناریو انجام گرفت که عبارتند از سناریوی اول: تنها استفاده از داده‌های دبی جریان، سناریوی دوم: تنها استفاده از داده‌های غلظت رسوب معلق، سناریوی سوم: ترکیب داده‌های دبی جریان و غلظت رسوب معلق، سناریوی چهارم: ترکیب داده‌های دبی جریان و شاخص

به طور کلی، ایده اصلی در ماشین‌های بردار پشتیبان این است که با فرض جداپذیری خطی کلاس‌ها از هم، ابر صفحاتی که قادر به جدا نمودن کلاس‌ها از هم باشند را به دست می‌آورد. در مسائلی که داده‌ها به صورت خطی جداپذیر نباشند با استفاده از هسته‌های غیرخطی، داده‌ها را به فضای با ابعاد بیشتر نگاشت می‌دهد تا بتوان آن‌ها را در این فضای جدید جدا نمود که معادله آن به صورت زیر خواهد بود:

$$Y = \text{Sign}\left(\sum_{i=1}^N y_i \alpha_i K(X, X_i) + b\right) \quad (2)$$

که در آن Y خروجی معادله،  $y_i$  ارزش طبقه نمونه آموزشی  $X_i$  می‌باشد. b بایاس تابع رگرسیون،  $\alpha$  ضریب لاگرانژ و  $K(X, X_i)$  تابع کرنل می‌باشد. در ساختار SVR هم از توابع کرنل استفاده می‌شود و به کارگیری آن نیازمند تعیین مقادیر بهینه پارامترهای موجود می‌باشد. در واقع همان ابرصفحه جداکننده مبحث ماشین بردار پشتیبان در SVR به تابع برازش بین داده‌ها تبدیل می‌شود که دارای همان خصوصیات قبلی می‌باشد در این مطالعه، تابع پایه شعاعی<sup>۱۰</sup>

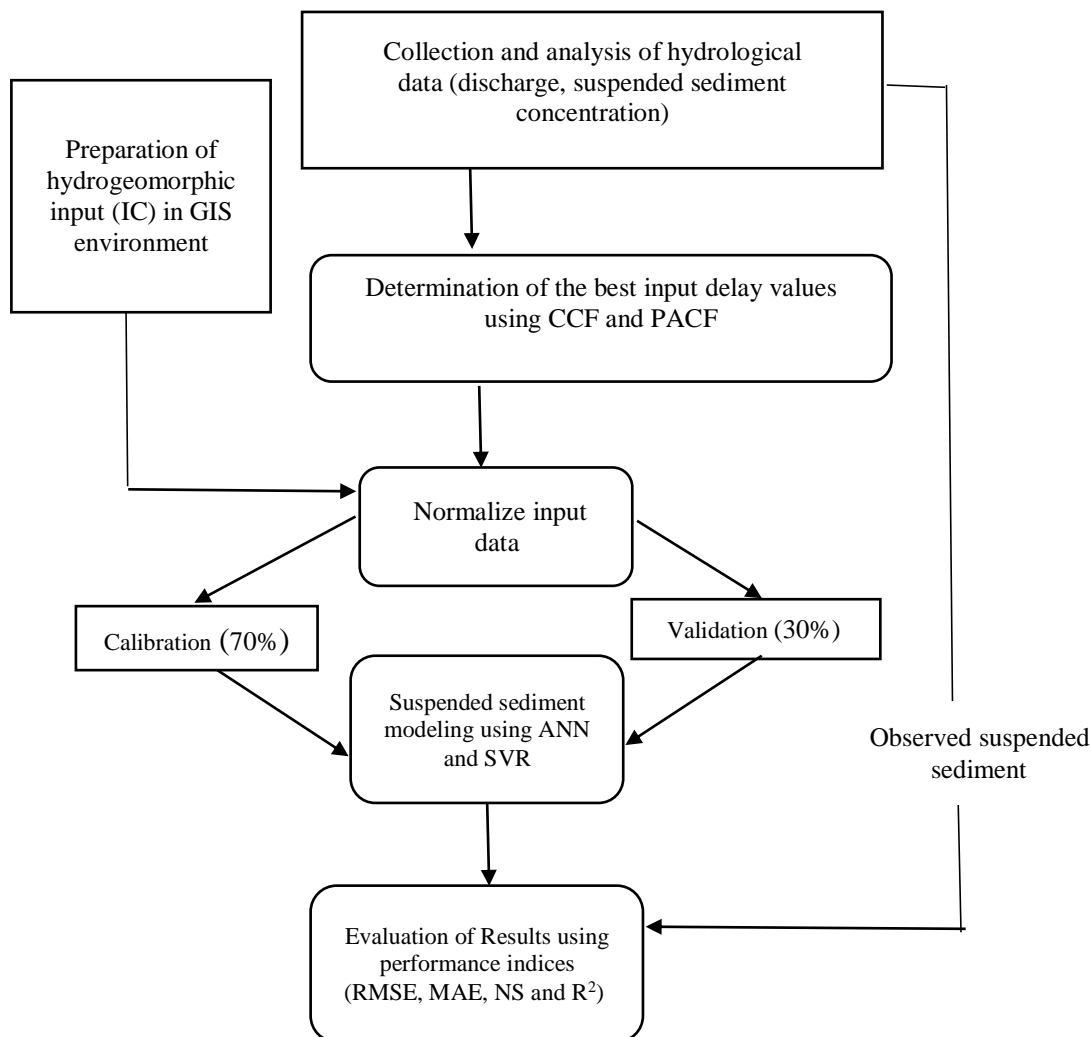


Fig. 2- Flow chart of research methodology

شکل ۲- روندنمای روش انجام پژوهش

#### ۲-۲-۴- پیش پردازش داده‌ها

اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای احتراز از چنین شرایطی و همچنین به منظور یکسان‌سازی ارزش داده‌ها برای شبکه و هماهنگی بین برد تابع محرک و خروجی شبکه نیاز به نرمال‌سازی داده‌ها می‌باشد. این عمل در واقع به معنای تغییر مقیاس داده‌ها برای محدود کردن مقادیر آنها در یک بازه خاص است. در این تحقیق کلیه داده‌های ورودی قبل از معرفی به شبکه با استفاده از رابطه (۴) نرمال شده‌اند (Vafakhah, 2013) تا در محدوده [۰-۱] قرار بگیرند.

$$X_{\text{norm}} = \frac{X_i - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \quad (4)$$

که در آن  $X_{\text{norm}}$  داده نرمال شده،  $X_i$  داده مورد نظر،  $X_{\text{min}}$  داده کمینه و  $X_{\text{max}}$  داده بیشینه است.

اتصال رسوبی، سناریوی پنجم: ترکیب داده‌های غلظت رسوب معلق و شاخص اتصال رسوبی و سناریوی ششم: ترکیب داده‌های دبی جریان، غلظت رسوب معلق و شاخص اتصال رسوبی. از طرفی یک گام مهم برای تنظیم مدل‌های پیش‌بینی، تعیین بهترین مقادیر تأخیر ورودی‌ها در رابطه با خروجی مدل است. در پژوهش حاضر پارامترهای آماری، از جمله توابع همبستگی متقاطع<sup>۱۱</sup> و خود همبستگی جزئی<sup>۱۲</sup> برای حل این مسأله و دوری کردن از آزمون و خطا استفاده گردید (Kumar et al., 2016). همچنین از آنجا که میانگین دبی‌های متوسط همان ماه و ماه قبل دارای همبستگی بالایی با خروجی مورد نظر بود لذا به عنوان یک ورودی مورد نیاز، علاوه بر ورودی‌های دیگر برای تخمین رسوب معلق در نظر گرفته شد.

## ۲-۲-۵- شاخص اتصال رسوبی

مقادیر NDVI در این حوضه با استفاده از تصاویر ماهواره‌ای مودیس در طول دوره آماری ۲۰۰۰ تا ۲۰۱۳ برای هر ماه محاسبه گردید که با توجه به ناچیز بودن تغییرات این شاخص در طول یک ماه، از تصاویر در اواسط هر ماه که بدون پوشش ابری بودند به منظور محاسبه NDVI ماهانه استفاده گردید. شکل ۳ نمودار سری زمانی مقادیر NDVI ماهانه را در مقایسه با داده‌های دبی جریان ماهانه در حوضه تمر در طول دوره آماری مذکور نشان می‌دهد. محاسبه این شاخص بر اساس معادله زیر می‌باشد:

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (9)$$

که در آن RED باند قرمز و NIR باند مادون قرمز می‌باشد. دامنه تغییرات NDVI از -۱ تا +۱ است که -۱ نشان‌دهنده خاک لخت و +۱ نشان‌دهنده تراکم پوشش گیاهی می‌باشد (Lillesand, 1994).

به منظور محاسبه IC، ابتدا نقشه مدل رقومی ارتفاعی منطقه و نقشه‌های رستری عامل وزنی با توان تفکیک ۳۰×۳۰ متر به عنوان ورودی‌های اصلی مدل تهیه شدند. سپس مدل شاخص اتصال رسوبی از طریق Model Builder در محیط ArcGIS 10.3 پیاده‌سازی گردید. این مدل با استفاده از الگوریتم‌ها و ابزارهای موجود در Spatial Analyst و نیز ابزار TauDEM 5.3.7 پیاده‌سازی و اجرا گردید (Cavalli et al., 2013). جزئیات کامل تئوری شاخص اتصال و پیاده‌سازی مدل آن در محیط نرم‌افزار ArcGIS به‌وسیله Borselli et al. (2008) بیان شده است. نتایج حاصل از مدل مذکور، به صورت نقشه‌های رستری شاخص اتصال رسوبی می‌باشد (مانند شکل ۴) که در نهایت، برای به‌دست آوردن مقادیر عددی شاخص اتصال رسوبی ماهانه در سطح حوضه، متوسط پیکسل‌ها در نقشه‌های رستری محاسبه گردید (جدول ۱).

## ۲-۲-۶- شاخص‌های ارزیابی نتایج

برای ارزیابی و مقایسه کارایی مدل‌های مورد استفاده، از معیارهای آماری جذر میانگین مربعات خطا<sup>۱۴</sup>، میانگین خطای مطلق<sup>۱۵</sup>، ضریب کارایی ناش-ساتکلیف<sup>۱۶</sup> و ضریب تبیین<sup>۱۷</sup> طبق روابط زیر استفاده گردید (Zounemat-Kermani et al., 2016):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - M_i)^2} \quad (10)$$

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

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - M_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (12)$$

شاخص اتصال رسوبی یک نوع شاخص اتصال هیدرولوژیکی می‌باشد که پتانسیل جابجایی ذرات رسوب در سراسر سامانه آبخیز را با استفاده از خصوصیات توپوگرافی و سایر خصوصیات حوضه مورد بررسی قرار می‌دهد. شاخص اتصال رسوبی در محیط نرم‌افزار GIS و براساس عناصر اصلی شاخص اتصال هیدرولوژیکی، از قبیل کاربری اراضی (به عنوان یک عنصر دینامیک) و خصوصیات توپوگرافی (به عنوان عنصر استاتیک) قابل محاسبه می‌باشد که به صورت زیر بیان گردیده است (Borselli et al., 2008):

$$IC = \log_{10} \left( \frac{D_{up}}{D_{dn}} \right) \quad (5)$$

که در آن  $D_{dn}$  و  $D_{up}$  به ترتیب جزء بالادست شاخص اتصال و جزء پایین‌دست شاخص اتصال می‌باشند. بر اساس این رابطه، شاخص اتصال رسوبی از نظر ریاضی بدون حد بوده و در دامنه  $\pm \infty$  قرار می‌گیرد. هرچه این شاخص مثبت‌تر باشد، اتصال ساختاری برای انتقال رسوب بیشتر است و هر چه به سمت منفی میل کند، این اتصال کاهش خواهد یافت. محاسبه جزء بالادست و پایین‌دست شاخص اتصال به ترتیب با استفاده از معادلات ۶ و ۷ صورت می‌گیرد:

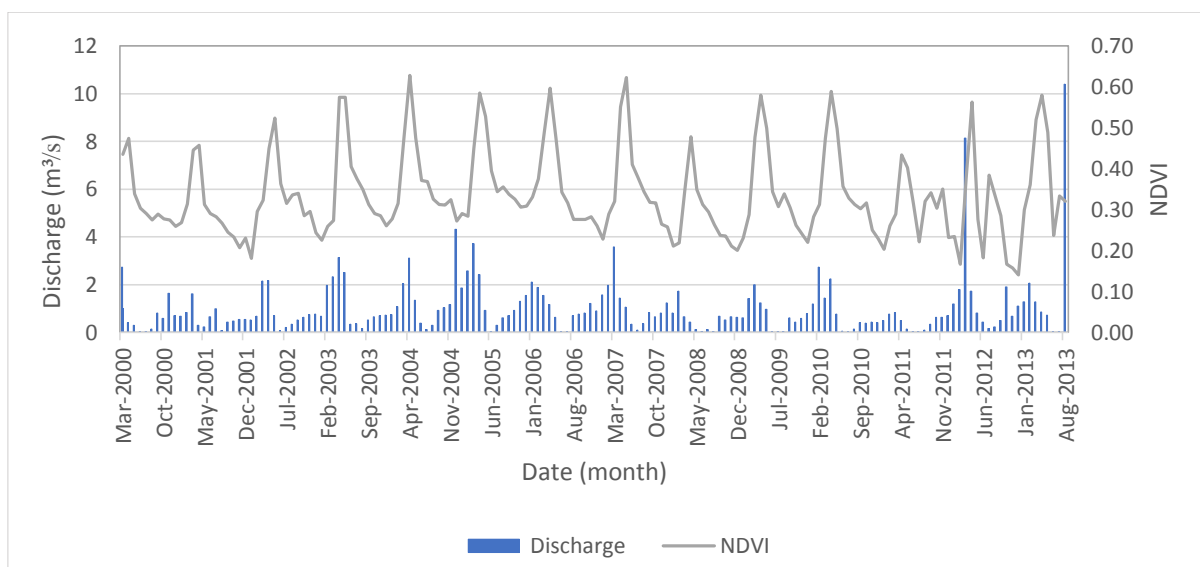
$$D_{up} = \bar{W} S \sqrt{A} \quad (6)$$

که  $\bar{W}$ ، میانگین عامل وزنی سطح مشارکت بالادست (بدون بعد)،  $S$  میانگین تندی شیب سطح مشارکت بالادست (متر بر متر) و  $A$  سطح مشارکتی بالادست (متر مربع) می‌باشند.

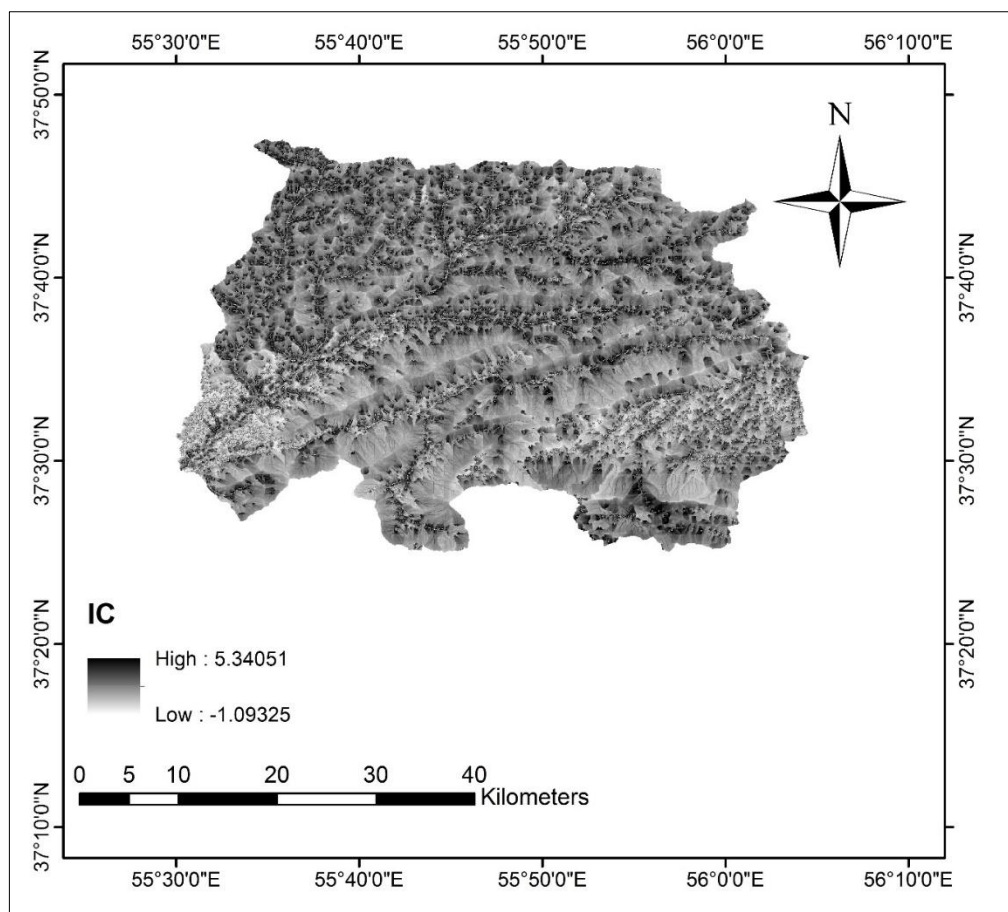
$$D_{dn} = \sum_i \frac{d_i}{W_i S_i} \quad (7)$$

که  $d_i$  طول مسیر به سمت پایین دست در سلول نام نقشه شبکه‌ای مورد استفاده (به متر)،  $W_i$  عامل وزنی سلول نام و  $S_i$  تندی شیب مربوط به سلول نام است. عامل وزنی ( $W$ ) یکی از اجزای اصلی شاخص اتصال رسوبی (معادلات ۶ و ۷) است که مقاومت هر سلول را در مقابل جریان رواناب و رسوب براساس خصوصیات کاربری اراضی و زبری سطح خاک نشان می‌دهد (Borselli et al., 2008). از آنجا که می‌توان عامل وزنی را براساس عامل پوشش گیاهی (فاکتور C، در مدل USLE-RUSLE) (Wischmeier and Smith, 1978; Renard et al., 1997) دست آورد و با توجه به نتایج Durigon et al. (2014) که از شاخص  $^{13}NDVI$  جهت تخمین فاکتور C استفاده نمودند، در مطالعه حاضر بر اساس معادله (۸) (Durigon et al., 2014) عامل وزنی محاسبه گردید. دامنه مقادیر فاکتور C و همچنین W از صفر تا یک می‌باشد که صفر نشان‌دهنده تراکم پوشش گیاهی و خاک حفاظت شده و یک نشان‌دهنده خاک در معرض فرسایش می‌باشد.

$$W = C = \left( \frac{-NDVI + 1}{2} \right) \quad (8)$$



**Fig. 3- Monthly NDVI time series plot compared with monthly discharge data (2000-2013)**  
 شکل ۳- نمودار سری زمانی مقادیر NDVI ماهانه در مقایسه با داده‌های دبی جریان ماهانه (۲۰۰۰-۲۰۱۳)



**Fig. 4- Map of index of connectivity (IC) in Tamar catchment (January, 2003)**  
 شکل ۴- نقشه شاخص اتصال رسوبی حوضه تمر (ژانویه، ۲۰۰۳)



همبستگی بین غلظت رسوب معلق در هر ماه با غلظت رسوب معلق ماهانه (تا ۷ ماه تاخیر) می‌باشد. نتایج نشان داد که مقادیر رسوب معلق در هر ماه با مقادیر این داده در یک ماه قبل بالاترین همبستگی را دارد. در نهایت، بر اساس تجزیه و تحلیل توابع مذکور و با استفاده از داده‌های هیدرولوژیک و هیدروژئومورفیک، ۱۴ الگوی ورودی در مدل‌های ANN و SVR برای ارزیابی شبیه‌سازی رسوب معلق در نظر گرفته شد (جدول ۲).

### ۳-۲- تجزیه و تحلیل الگوهای ورودی در مدل‌های ANN و SVR

نتایج نهایی ارزیابی مدل‌های ANN و SVR با استفاده از آماره‌های RMSE، MAE، NS و  $R^2$  برای مراحل واسنجی و اعتبارسنجی در حوضه مورد مطالعه، در جدول ۲ نشان داده شده‌اند. در این جدول دو گروه الگوی ورودی وجود دارد، در گروه اول، فقط ورودی‌های هیدرولوژیک و در گروه دوم ترکیبی از ورودی‌های هیدرولوژیک و هیدروژئومورفیک استفاده شده است. مقایسه همه نتایج نشان داد که بهترین الگوهای ورودی در مرحله اعتبارسنجی با استفاده از مدل‌های ANN و SVR در این حوضه به ترتیب  $Q_t + SSC_{t-1} + IC_t$  و  $Q_t + \bar{Q}_{t,t-1} + SSC_{t-1} + IC_t$  می‌باشند. به منظور مقایسه کارایی الگوهای ورودی با استفاده از ترکیب داده‌های هیدرولوژیک و هیدروژئومورفیک، نسبت به الگوهای ورودی با استفاده از تنها داده‌های هیدرولوژیک، میانگین شاخص‌های عملکرد RMSE، MAE، NS و  $R^2$  محاسبه گردید.

$$R^2 = \left[ \frac{\sum_{i=1}^n (O_i - \bar{O})(M_i - \bar{M})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (M_i - \bar{M})^2}} \right]^2 \quad (13)$$

که در این روابط  $O_i$  و  $M_i$ ، به ترتیب مقادیر مشاهده شده و مقادیر برآورد شده،  $\bar{O}$  و  $\bar{M}$  به ترتیب میانگین مقادیر مشاهده شده و میانگین مقادیر برآورد شده و  $n$  تعداد نمونه‌ها می‌باشد.

### ۳- نتایج و بحث

#### ۳-۱- نتایج بهترین مقادیر تأخیر ورودی

در این مطالعه، با استفاده از تابع همبستگی متقاطع انتخاب مقادیر پیشین دبی جریان که دارای بیشترین همبستگی با غلظت رسوب معلق در هر ماه بود، صورت گرفت. همچنین از تابع خود همبستگی جزئی برای تعیین رابطه مقادیر رسوب معلق در هر ماه با مقادیر پیشین رسوب معلق استفاده گردید. نتایج کاربرد این توابع به صورت نمودار به ترتیب در شکل‌های ۵a و ۵b نشان داده شده است. در شکل ۵a محور Xها، زمان برحسب ماه را نشان می‌دهد (مقادیر منفی، نشان دهنده ماه‌های قبل و مقادیر مثبت، نشان دهنده ماه‌های بعد می‌باشند) و محور Yها نشان دهنده مقادیر همبستگی بین غلظت رسوب معلق در هر ماه با دبی جریان ماهانه (تا ۷ ماه) می‌باشد. نتایج نشان داد که داده‌های رسوب معلق در هر ماه با داده‌های دبی جریان در همان ماه و یک ماه قبل بیشترین همبستگی را دارد. در شکل ۵b محور Xها، زمان تأخیر برحسب ماه را نشان می‌دهد و محور Yها نشان دهنده مقادیر




Fig. 5- Cross correlation between runoff and SSC (a) and Partial autocorrelation of SSC (b)

شکل ۵- نمودارهای همبستگی متقاطع بین رواناب و غلظت رسوب معلق (a) و خود همبستگی جزئی غلظت رسوب معلق (b)

متغیرهای هیدرولوژیکی در مدل‌های SVR ( $Q_t + \bar{Q}_{t-1} + SSC_{t-1}$ ) و ANN ( $Q_t$ ) در مقایسه با بهترین الگوهای ورودی با استفاده از ترکیب ورودی‌های هیدرولوژیکی و هیدروژئومورفیک (بولد شده در جدول ۲) در شکل‌های ۷a و ۷b نشان داده شده است. این نمودارها تطابق منحنی رسوب معلق مشاهده‌ای و شبیه‌سازی شده را در دوره اعتبار سنجی، زمانی که IC به همراه ورودی‌های هیدرولوژیکی می‌باشد را به خصوص در مدل SVR تایید می‌کند و نشان می‌دهند که هنگامی که فقط از ورودی‌های هیدرولوژیکی استفاده شده است، برازش کمتری با داده‌های مشاهداتی وجود دارد. همچنین آنچه که از نتایج استنباط می‌شود این است که هیچ کدام از ترکیبات ورودی به کار گرفته شده نتوانسته‌اند مقادیر اوج رسوب معلق را به خوبی برآورد نمایند، با این حال دقت مدل‌هایی که از ورودی‌های هیدروژئومورفیک استفاده کرده‌اند، بیشتر از سایر مدل‌ها بوده است.

#### ۴- نتیجه‌گیری

این مطالعه به منظور بهبود مدل‌سازی رسوب معلق، با استفاده از الگوهای ورودی مختلف در مدل‌های هوشمند ANN و SVR در حوضه آبخیز تمر طراحی گردید. هدف ما بررسی مؤثرترین و در دسترس‌ترین متغیرهای ورودی برای دستیابی به تخمین بهتر رسوب معلق ماهانه بود. برای رسیدن به این هدف، اثرات IC به عنوان ورودی هیدروژئومورفیک همراه با داده‌های رواناب و رسوب معلق پیشین به عنوان ورودی‌های هیدرولوژیکی در تخمین رسوب معلق ارزیابی گردید.

نتایج نشان داد ترکیب پارامترهای ژئومورفیک و بیوفیزیکی حوضه به عنوان یک پارامتر واحد (IC) همراه با ورودی‌های هیدرولوژیکی، باعث افزایش دقت مدل‌سازی رسوب معلق ماهانه با استفاده از مدل‌های ANN و SVR گردید. همچنین بهترین الگوهای ورودی در مرحله اعتبارسنجی با استفاده از مدل‌های ANN و SVR در این حوضه به ترتیب،  $Q_t + SSC_{t-1} + IC_t$  و  $Q_t + \bar{Q}_{t-1} + SSC_{t-1} + IC_t$  بودند که مقادیر شاخص‌های آماری مربوط به آنها به ترتیب ۴۱/۹۵ و ۳۲/۷۵ میلی‌گرم بر لیتر برای مجذور میانگین مربعات خطا، ۰/۵۷ و ۰/۷۴ برای ضریب کارایی ناش-ساتکلیف و ۰/۷۹ و ۰/۷۸ برای ضریب تبیین بود. بدین ترتیب نتایج به دست آمده حاکی از این می‌باشد که IC همراه با متغیرهای هیدرولوژیکی، در مدل‌های ANN و SVR، باعث افزایش عملکرد مدل‌سازی رسوب معلق می‌گردد. این بهبود در پیش‌بینی رسوب معلق برای برنامه‌ریزی و مدیریت منابع آب ارزشمند می‌باشد.

ارزیابی نتایج (در مقایسه با مدل‌ها با استفاده از تنها ورودی‌های هیدرولوژیکی) نشان داد که در مدل SVR، متغیر IC به عنوان ورودی NS و  $R^2$  را به طور متوسط به ترتیب، ۲۱/۸۵٪ و ۴۵/۹۴٪ افزایش داد و RMSE و MAE را به ترتیب، ۲۶/۳۶٪ و ۲۸/۲۴٪ کاهش داد. در مدل ANN نیز متغیر IC به عنوان ورودی، NS و  $R^2$  را به طور متوسط به ترتیب، ۲۵/۸۰٪ و ۱۳/۲۰٪ افزایش داد و RMSE و MAE را نیز به ترتیب، ۹/۶۳٪ و ۱۵/۶۷٪ کاهش داد. نتایج نشان می‌دهد که تنها استفاده از رواناب برای تخمین رسوب معلق کافی نیست و در هر دو مدل مذکور، تلفیق با مقادیر پیشین رسوب معلق، پیش‌بینی‌ها را بهبود می‌دهد. به طور کلی مقایسه میان نتایج نشان داد که ترکیب داده‌های هیدرولوژیکی با IC نتایج بهتری (مقادیر NS و  $R^2$  بالاتر و RMSE و MAE کمتر) در مقایسه با مدل‌ها با استفاده از تنها داده‌های هیدروژئومورفیک همراه با متغیرهای هیدرولوژیکی در مدل‌های ANN و SVR، باعث افزایش عملکرد مدل‌سازی رسوب معلق می‌گردد. از طرفی در این مطالعه، بالا بودن نسبی مقادیر آماره‌های جذر میانگین مربعات خطا و میانگین خطای مطلق به دلیل نوع داده‌های مورد استفاده می‌باشد. به طوری که در طول دوره آماری مورد مطالعه، تغییرات زیادی در مقادیر رسوب معلق وجود دارد که مقدار بالای انحراف معیار تاییدکننده این مطلب است (جدول ۱). همچنین نتیجه به دست آمده از این تحقیق نشان می‌دهد که مدل SVR نسبت به ANN از دقت و کارایی بیشتری برخوردار است که با نتایج Chiang et al. (2014) و Choubin et al. (2018) مطابقت دارد.

همچنین به منظور ارزیابی کارایی مدل‌ها، نمودار پراکنش داده‌های مشاهده‌ای در مقابل داده‌های محاسباتی مدل‌ها ترسیم و معادله خط رگرسیون و ضریب تبیین بهترین خط برازش برای بهترین الگوی ورودی در هر دو مدل SVR (شکل ۶a) و ANN (شکل ۶b) برای هر دو مجموعه واسنجی و اعتبارسنجی تعیین گردید. همانطور که در شکل‌های ۶a و ۶b نشان داده شده، این مقادیر در مدل SVR (کالیبراسیون:  $R^2 = 0.92$ ، اعتبارسنجی:  $R^2 = 0.78$ ) و در مدل ANN (کالیبراسیون:  $R^2 = 0.95$ ، اعتبارسنجی:  $R^2 = 0.79$ ) می‌باشند. مقایسه مقادیر پراکنش بین داده‌های مشاهده شده و شبیه‌سازی شده برای هر دو مدل نشان می‌دهد که مقادیر شبیه‌سازی شده در طول دوره واسنجی نسبت به دوره اعتبارسنجی تطابق بیشتری با مقادیر مشاهده‌ای دارند.

علاوه بر این، نمودار تغییرات زمانی رسوب معلق مشاهده‌ای و رسوب معلق شبیه‌سازی شده از بهترین الگوهای ورودی با استفاده از تنها

Table 2- Results of monthly time series modeling by SVR and ANN with different input patterns

جدول ۲- نتایج مدل سازی سری زمانی ماهانه توسط SVR و ANN با الگوهای ورودی مختلف

Model	Input patterns	Tamar catchment							
		Calibration				Validation			
		RMSE (mg/l)	NS	MAE (mg/l)	R <sup>2</sup>	RMSE (mg/l)	NS	MAE (mg/l)	R <sup>2</sup>
SVR	Q <sub>t</sub>	591.06	0.60	128.54	0.76	55.99	0.56	30.12	0.61
	Q <sub>t</sub> +Q <sub>t-1</sub>	211.41	0.95	83.40	0.95	92.54	0.38	66.66	0.44
	Q <sub>t</sub> +Q̄ <sub>t,t-1</sub>	843.84	0.19	138.60	0.22	87.84	0.29	43.96	0.36
	SSC <sub>t-1</sub>	939.83	0.002	298.43	0.003	174.41	-0.24	167.81	0.14
	Q <sub>t</sub> +SSC <sub>t-1</sub>	251.62	0.92	146.61	0.93	107.95	0.17	95.99	0.22
	Q <sub>t</sub> +Q <sub>t-1</sub> +SSC <sub>t-1</sub>	913.56	0.05	179.60	0.11	90.95	0.10	69.91	0.07
	Q <sub>t</sub> +Q̄ <sub>t,t-1</sub> +SSC <sub>t-1</sub>	784.67	0.30	130.70	0.39	52.20	0.61	25.32	0.65
	Q <sub>t</sub> +IC <sub>t</sub>	271.83	0.91	87.75	0.92	44.86	0.62	30.75	0.66
	Q <sub>t</sub> +Q <sub>t-1</sub> +IC <sub>t</sub>	210.64	0.94	82.33	0.95	83.64	0.52	54.59	0.77
	Q <sub>t</sub> +Q̄ <sub>t,t-1</sub> +IC <sub>t</sub>	186.64	0.96	54.24	0.99	44.72	0.63	30.28	0.77
	SSC <sub>t-1</sub> +IC <sub>t</sub>	938.86	0.004	271.15	0.004	147.64	0.12	137.18	0.18
	Q <sub>t</sub> +SSC <sub>t-1</sub> +IC <sub>t</sub>	244.95	0.93	106.58	0.94	69.42	0.20	53.30	0.23
	Q <sub>t</sub> +Q <sub>t-1</sub> +SSC <sub>t-1</sub> +IC <sub>t</sub>	177.80	0.96	96.49	0.96	52.93	0.32	33.81	0.36
	<b>Q<sub>t</sub>+Q̄<sub>t,t-1</sub>+SSC<sub>t-1</sub>+IC<sub>t</sub></b>	<b>283.36</b>	<b>0.90</b>	<b>70.37</b>	<b>0.92</b>	<b>32.75</b>	<b>0.74</b>	<b>19.88</b>	<b>0.78</b>
ANN	Q <sub>t</sub>	256.37	0.92	78.11	0.92	67.66	0.43	49.07	0.54
	Q <sub>t</sub> +Q <sub>t-1</sub>	192.07	0.95	66.15	0.95	141.33	0.19	68.17	0.47
	Q <sub>t</sub> +Q̄ <sub>t,t-1</sub>	191.92	0.95	78.41	0.95	85.92	0.30	71.13	0.57
	SSC <sub>t-1</sub>	939.11	0.003	289.29	0.003	173.23	-0.26	154.91	0.32
	Q <sub>t</sub> +SSC <sub>t-1</sub>	222.59	0.94	76.47	0.94	73.88	0.41	50.09	0.46
	Q <sub>t</sub> +Q <sub>t-1</sub> +SSC <sub>t-1</sub>	206.15	0.95	62.53	0.95	84.95	0.35	43.05	0.70
	Q <sub>t</sub> +Q̄ <sub>t,t-1</sub> +SSC <sub>t-1</sub>	229.42	0.94	70.91	0.94	77.98	0.39	48.00	0.66
	Q <sub>t</sub> +IC <sub>t</sub>	203.87	0.95	62.68	0.95	52.05	0.48	39.08	0.63
	Q <sub>t</sub> +Q <sub>t-1</sub> +IC <sub>t</sub>	183.94	0.96	38.20	0.99	92.88	0.44	60.91	0.64
	Q <sub>t</sub> +Q̄ <sub>t,t-1</sub> +IC <sub>t</sub>	190.99	0.95	58.36	0.95	76.11	0.39	46.12	0.58
	SSC <sub>t-1</sub> +IC <sub>t</sub>	938.39	0.005	278.74	0.006	159.28	-0.04	152.32	0.14
	<b>Q<sub>t</sub>+SSC<sub>t-1</sub>+IC<sub>t</sub></b>	<b>209.90</b>	<b>0.95</b>	<b>61.95</b>	<b>0.95</b>	<b>41.95</b>	<b>0.57</b>	<b>35.24</b>	<b>0.79</b>
	Q <sub>t</sub> +Q <sub>t-1</sub> +SSC <sub>t-1</sub> +IC <sub>t</sub>	177.87	0.96	55.06	0.96	73.41	0.41	42.20	0.71
	Q <sub>t</sub> +Q̄ <sub>t,t-1</sub> +SSC <sub>t-1</sub> +IC <sub>t</sub>	189.01	0.95	58.84	0.95	42.97	0.50	35.43	0.67

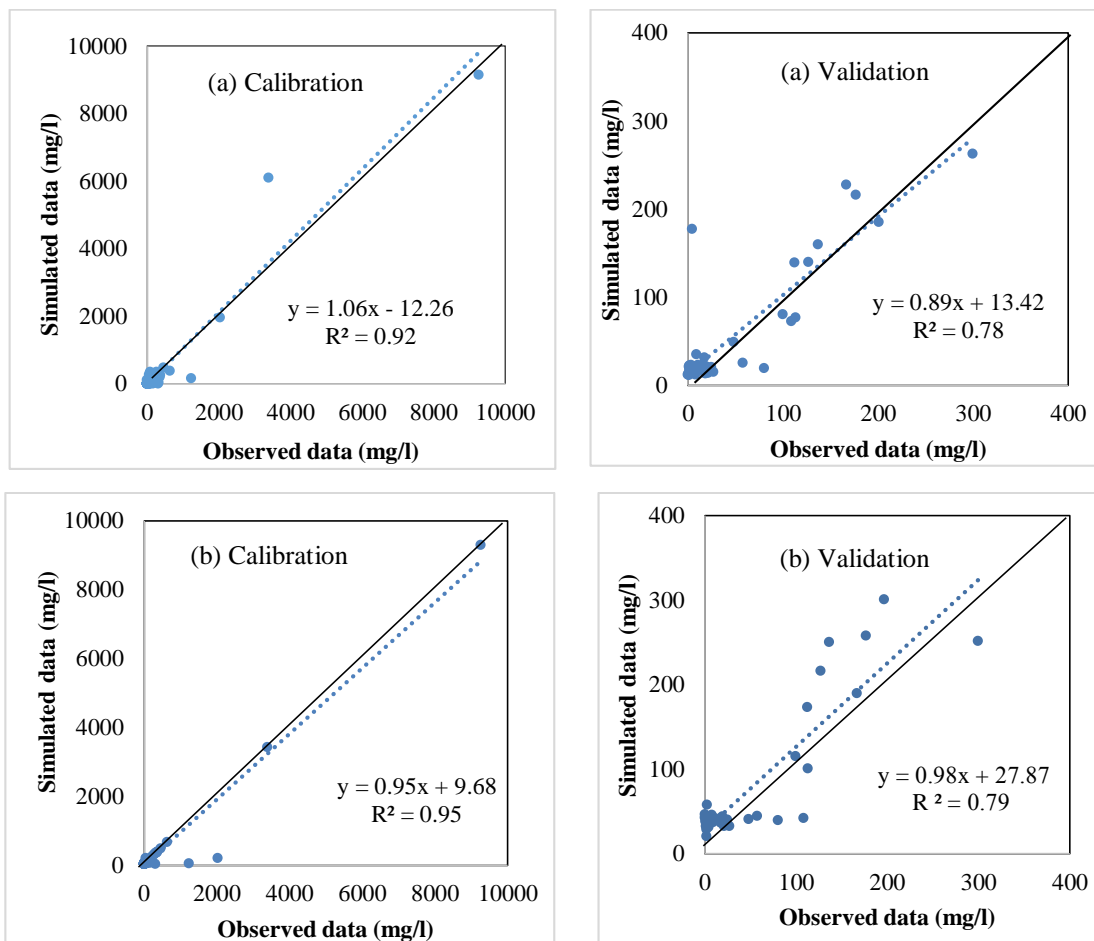


Fig. 6- Scatter plot of the best input pattern of SVR (a) and ANN (b) models  
 شکل ۶- نمودار پراکنش بهترین الگوی ورودی با استفاده از مدل‌های SVR (a) و ANN (b)

(به عنوان مثال الگوریتم ژنتیک) در تنظیم پارامترهای مدل‌های SVR و بهینه‌سازی وزن‌ها و بایاس‌های ANN می‌توانند دقت مدل‌سازی برآورد رسوب معلق را افزایش دهند.

### ۵- تشکر

این تحقیق با حمایت و مساعدت مرکز تحقیقات پایداری در دانشگاه سان شاین کوست استرالیا طی دوره فرصت مطالعاتی دکتری انجام شده که بدینوسیله از این مؤسسه و راهنمای‌های بسیار ارزنده Prof. Roy Sidle و Dr. Ben Jarihani تشکر و قدردانی می‌گردد.

از طرفی اگرچه نتایج ما نشان داد که IC به عنوان ورودی به مدل‌های SVR و ANN برای شبیه‌سازی بهتر فرآیندهای رسوب معلق، یک ابزار امیدوارکننده و قابل اطمینان است، اما ارزیابی کارایی این ورودی‌ها باید در سایر موارد، از قبیل شبیه‌سازی بارش- رواناب، مدل‌سازی با استفاده از سایر مدل‌های هوشمند (نظیر مدل‌های نروفازی، برنامه‌ریزی بیان ژن، درخت تصمیم‌گیری و غیره) و مقایسه نتایج آن‌ها با پژوهش حاضر و نیز کاربرد آن در آبخیزهای دیگر مورد بررسی قرار گیرد. در راستای تکمیل پژوهش صورت گرفته بهتر است، علاوه بر متغیرهای هیدرولوژیکی حوضه، از متغیرهای اقلیمی (نظیر بارش، دما) و نیز دیگر متغیرهای حوضه به عنوان ورودی‌های مدل‌ها استفاده شود. همچنین، استفاده از الگوریتم‌های فراابتکاری

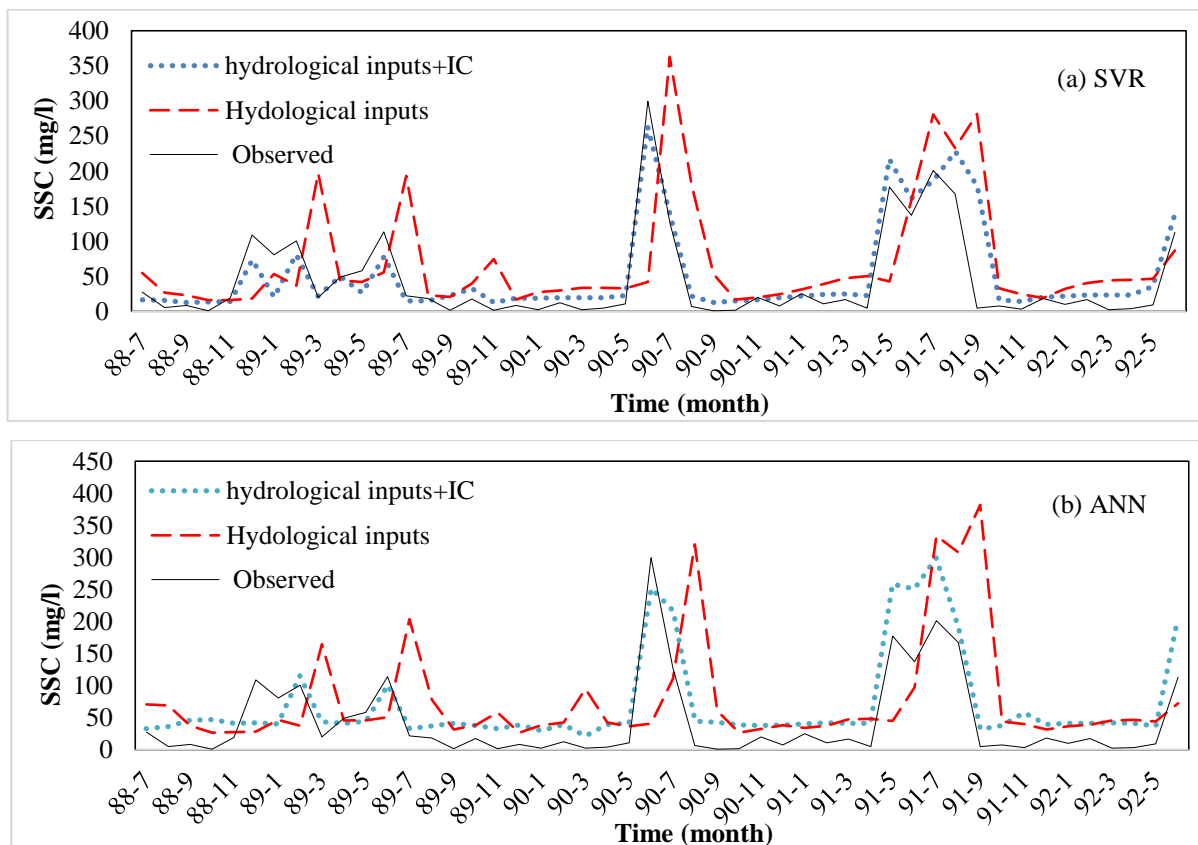


Fig. 7- Time-series of observed SSC versus simulated SSC of the best input patterns

شکل ۷- منحنی‌های سری زمانی غلظت رسوب معلق مشاهده‌ای و شبیه‌سازی شده از بهترین الگوهای ورودی

networks and fuzzy inference system. Iran-Water Resources Research 1(2):29-41 (In Persian)

Asadi H, Shahedi K, Jarihani B, Sidle RC (2019) Rainfall-runoff modelling using hydrological connectivity index and artificial neural network approach. Water 11(2):212

Borselli L, Cassi P, Torri D (2008) Prolegomena to sediment and flow connectivity in the landscape: A GIS and field numerical assessment. Catena 75(3):268-277

Bracken LJ, Wainwright J, Ali GA, Tetzlaff D, Smith MW, Reaney SM, Roy AG (2013) Concepts of hydrological connectivity: Research approaches, Pathways and future agendas. Earth-Science Reviews 119:17-34

Cavalli M, Trevisani S, Comiti F, Marchi L (2013) Geomorphometric assessment of spatial sediment connectivity in small Alpine catchments. Geomorphology 188:31-41

Chen ST and Yu PS (2007) Pruning of support vector networks on flood forecasting. Journal of Hydrology 347(1-2):67-78

پی‌نوشت‌ها

- 1- Support Vector Machine (SVM)
- 2- Field Index of Connectivity (FIC)
- 3- Topographic Surface Roughness
- 4- Debris Flow
- 5- Index of Connectivity (IC)
- 6- Artificial Neural Network (ANN)
- 7- Feed Forward Neural Network (FFNN)
- 8- Levenberg–Marquardt
- 9- Support Vector Regression (SVR)
- 10- Radial Basis Function (RBF)
- 11- Cross-Correlation Function (CCF)
- 12- Partial Autocorrelation Function (PACF)
- 13- Normalized Difference Vegetation Index (NDVI)
- 14- Root Mean Squared Error (RMSE)
- 15- Mean Absolute Error (MAE)
- 16- Nash–Sutcliffe Model Performance Coefficient (NS)
- 17- Coefficient of Determination ( $R^2$ )

۶- مراجع

Araghinejad Sh, Karamouz M (2005) Long-lead streamflow forecasting using artificial neural

- watershed. In EGU General Assembly Conference Abstracts 16:52-85
- Lesschen JP, Schoorl JM, Cammeraat LH (2009) Modelling runoff and erosion for a semi-arid catchment using a multi-scale approach based on hydrological connectivity. *Geomorphology* 109(3-4):174-183
- Tabatabaei M, Solaimani K, Habibnejad Roshan M, Kaviani A (2014) Estimation of daily suspended sediment concentration using artificial neural networks and data clustering by self organizing map (Case study: Sierra Hydrometry Station- Karaj Dam Watershed). *Journal of Watershed Management* 5:98-116 (In Persian)
- Melesse AM, Ahmad S, McClain ME, Wang X, Lim YH (2011) Suspended sediment load prediction of river systems: An artificial neural network approach. *Agricultural Water Management* 98(5):855-866
- Dehghani N, Vafakhah M (2013) Comparison of daily suspended sediment load estimations by sediment rating curve and neural network models (Case study: Ghazaghli Station in Golestan Province). *Journal of Water and Soil Conservation* 20(2):1-10 (In Persian)
- Rajaei T, Mirbagheri SA, Zounemat-Kermani M, Nourani V (2009) Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models. *Science of the Total Environment* 407(17):4916-4927
- Renard KG, Foster GR, Weesies G, McCool D, Yoder D (1997) Predicting soil erosion by water: A guide to conservation planning with the Revised Universal Soil Loss Equation (RUSLE). *Agriculture Handbook*, 703
- Najafi S, Sadeghi SHR, Heckmann T (2017) Temporospatial variations of structural sediment connectivity patterns in Taham-Chi watershed in Zanjan province, Iran. *Journal of Water and Soil Conservation* 24(3):131-147 (In Persian)
- Sheykhalipour Z (2013) Comparison of artificial intelligence methods and equations of sediment transformation in Sistan River. Master's thesis, Zabol university, 144p (In Persian)
- Lillesand TM, Kiefer RW (1994) Remote sensing and photo interpretation. John Wiley and Sons: New York
- Vafakhah M (2013) Comparison of cokriging and adaptive neuro-fuzzy inference system models for suspended sediment load forecasting. *Arabian Journal of Geosciences* 6(8):3003-3018
- Vapnik VN (1995) The nature of statistical learning theory. *IEEE Transactions on Neural Networks*
- Choubin B, Darabi H, Rahmati O, Sajedi-Hosseini F, Kløve B (2018) River suspended sediment modelling using the CART model: A comparative study of machine learning techniques. *Science of the Total Environment* 615:272-281
- Durigon VL, Carvalho DF, Antunes MAH, Oliveira PTS, Fernandes MM (2014) NDVI time series for monitoring RUSLE cover management factor in a tropical watershed. *International Journal of Remote Sensing* 35:441-453
- Fathian H, Shafeizadeh M, and Nikbakht Shahbazi AR (2019) Continuous rainfall-runoff simulation by artificial neural networks based on efficient input variables selection using partial mutual information (PMI) algorithm. *Iran-Water Resources Research* 15(2):120-130 (In Persian)
- Hagan MT, Menhaj MB (1994) Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks* 5:989-993
- Haykin S (1999) *Neural networks: A comprehensive foundation second edition*. Pearson Education
- Kakaei Lafdani E, Moghaddam Nia A, Ahmadi A (2013) Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology* 478(25):50-62
- Khan MYA, Tian F, Hasan F, Chakrapani GJ (2019) Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges Basin, India. *International Journal of Sediment Research* 34(2):95-107
- Khosravi M, Salajegheh A (2013) Peak discharge forecast in the downstream station using the upstream stations by neural network (Case study: Taleghan). *Iran-Water Resources Research* 9(1):96-100 (In Persian)
- Kim T-W, Valdés JB (2003) Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering* 8:319-328
- Kişî Ö (2009) Evolutionary fuzzy models for river suspended sediment concentration estimation. *Journal of Hydrology* 372:68-79
- Kisi O, Haktanir T, Ardiclioglu M, Ozturk O, Yalcin E, Uludag S (2009) Adaptive neuro-fuzzy computing technique for suspended sediment estimation. *Advances in Engineering Software* 40:438-444
- Kumar D, Pandey A, Sharma N, Flügel WA (2016) Daily suspended sediment simulation using machine learning approach. *Catena* 138:77-90
- Chiang L, Tsai K J, Chen Y R, Lee MH, Sun JW (2014) Suspended sediment load prediction using support vector machines in the Goodwin Creek experimental

- Zhu YM, Lu XX, Zhou Y (2007) Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment, China. *Geomorphology* 84(1):111-125
- Zounemat-Kermani M, Kişi Ö, Adamowski J, Ramezani-Charmahineh A (2016) Evaluation of data driven models for river suspended sediment concentration modeling. *Journal of Hydrology* 535:457-472
- Wester T, Wasklewicz T, Staley D (2014) Functional and structural connectivity within a recently burned drainage basin. *Geomorphology* 206: 362-373
- Wischmeier WH, Smith DD (1978) Predicting rainfall erosion losses: A guide to conservation planning. U.S. Department of Agriculture, Agriculture Handbook No. 537
- Yang CT, Marsooli R, Aalami MT (2009) Evaluation of total load sediment transport formulas using ANN. *International Journal of Sediment Research* 24:274-286