

## ارزیابی مدل های تخمین میزان رسوب رودخانه با روش شبکه عصبی مصنوعی و رگرسیون چند متغیره (رودخانه ونایی)

دریافت مقاله: ۹۷/۷/۲۴ پذیرش نهایی: ۹۸/۳/۶

صفحات: ۴۱-۵۶

داریوش ابوالفتحی: دانشجوی دکتری ژئومورفولوژی دانشگاه محقق اردبیلی، اردبیل، ایران

Email: dariushablf@yahoo.com

عقیل مددی: دانشیار گروه جغرافیای طبیعی دانشگاه محقق اردبیلی، اردبیل، ایران<sup>۱</sup>

Email: aghil48madadi@yahoo.com

سیاد اصغری: دانشیار گروه جغرافیای طبیعی دانشگاه محقق اردبیلی، اردبیل، ایران

Email: Sayyad.asghari21@gmail.com

### چکیده

برآورد صحیح حجم رسوبات در رودخانه‌ها، یکی از مهم‌ترین مسائل در پروژه‌های مهندسی رودخانه، منابع آب و محیط‌زیست می‌باشد. همچنین برآورد صحیح بار (رسوبات) معلق رودخانه‌ها در جلوگیری از خسارات ناشی از سیلاب‌ها بر روی راسازه‌های آبی همانند سد‌ها و غیره می‌باشد. بخشی از رسوبات رودخانه‌ای مواد غوطه‌ور درون جریان آب هستند که همراه با آب در حرکت می‌باشند که به آنها مواد رسوبی معلق گفته می‌شود و میزان مواد رسوبی معلق را که در واحد زمان از یک مقطع رودخانه عبور کند، بار معلق مینامند. منطقه مورد مطالعه در این پژوهش حوضه آبریز رودخانه ونایی است. این منطقه در شهرستان بروجرد، در استان لرستان در جنوب غرب ایران واقع شده است، در این پژوهش ابتدا مشخصات زیرحوضه‌های این رودخانه استخراج شده است این مشخصات شامل مشخصات فیزیکی زیرحوضه‌ها از جمله مساحت، محیط و طول آبراهه‌ها و مشخصات مربوط به دبی رودخانه و میزان رسوب آن است. در ادامه با روش‌های رگرسیون خطی چند متغیره، شبکه عصبی پیشخور چندلایه (MLP) به تخمین بار رسوب پرداخته شد. پس از محاسبه شاخص‌های RMSE و MAE با توجه به این امر که هرچه قدر میزان این شاخص‌ها کمتر باشد مقدار پیش‌بینی شده به مقادیر واقعی نزدیکتر است بنابراین با توجه به شواهد حاصله مدل شبکه عصبی مصنوعی MLP دقت بهتری را نسبت به مدل دیگر در تخمین میزان رسوب منطقه نشان می‌دهد. از سوی دیگر با توجه به مقدار شاخص R2 که برای دو مدل محاسبه شده است دقت تخمین مدل به مقدار ۹۰٫۴۷ برای مدل MLP محاسبه شده است، مقدار R2 برای این مدل برابر ۰٫۸۹ است. پس از مدل شبکه عصبی مصنوعی MLP، مدل رگرسیون خطی چند متغیره با مقدار R2 برابر با ۰٫۳۵۳ قرار دارد. و این نشان دهنده‌ی دقت سه برابری مدل MLP نسبت به مدل رگرسیون می‌باشد مدل رگرسیون خطی نیز به علت این امر که تنها روابط خطی بین متغیرها را در نظر می‌گیرد بیشترین میزان خطا را دارد.

کلید واژگان: رودخانه ونایی، شبکه عصبی، تخمین رسوب، رگرسیون خطی، MLP.

۱. نویسنده مسئول: اردبیل، بلوار دانشگاه، دانشگاه محقق اردبیلی، دانشکده علوم انسانی، گروه جغرافیا

## مقدمه

در طراحی و ساخت سازه‌های آبی نظیر سدها و همچنین مدیریت پروژه های منابع آب، آگاهی از مقدار کمی بار رسوب معلق رودخانه‌ها امری ضروری است. رسوبات معلق حمل شده توسط رودخانه‌ها ممکن است سبب کاهش ظرفیت مفید مخازن سدها گردند (ناکاتو<sup>۱</sup>، ۱۹۹۰). از نظر کیفیت آب، رسوبات موجود در آب (بصورت معلق و یا بار بستر) سبب انتقال آلاینده‌هایی نظیر آفت کش‌ها، مواد غذایی و سایر مواد شیمیایی در آب می‌شوند. بنابراین برآورد دقیق رسوب برای کنترل سطح آلودگی در رودخانه‌ها و مخازن سدها امری ضروری است (لوپز<sup>۲</sup> و همکاران، ۲۰۰۱). بار رسوب معلق رودخانه‌ای بطور معمول با اندازه‌گیری مستقیم غلظت رسوب معلق یا با بکارگیری منحنی سنج رسوب انجام می‌شود. همچنین دقت منحنی سنج رسوب به دلیل برآورد زیاد (در مقادیر کم رسوب رودخانه) یا برآورد کم (در مقادیر زیاد رسوب رودخانه) پائین بوده و لذا از کارائی لازم برخوردار نیستند (والینگ و وب<sup>۳</sup>، ۱۹۸۸). سارنگی و همکاران (۲۰۰۵) به منظور پیش بینی بار رسوبی حوضه‌ای در ایالت کبک کانادا از روش شبکه عصبی استفاده کرده نتایج آن را با برآوردهای رگرسیون مقایسه نمودند. آنان در این بررسی از ویژگی‌های ژئومورفولوژی حوضه آبخیز مانند نسبت انشعاب، ضریب مساحت، ضریب طول آبراهه ضریب پستی بلندی در برآورد بار رسوبی استفاده کرده بیان میکنند استفاده از این داده‌ها موجب افزایش دقت برآوردها در هر دو روش شبکه عصبی مصنوعی و رگرسیون شده است. اولک<sup>۴</sup> و همکاران (۲۰۰۹) بر روی رودخانه گیدز ترکیه با استفاده مدل های نروفازی، شبکه های عصبی، منحنی های رسوب و رگرسیون چند متغیره انجام گرفته از نظر نتیجه همخوانی دارد در مطالعه فوق مدل های نروفازی و شبکه های عصبی نسبت به دیگر مدل ها (رگرسیون چند متغیره و منحنی های رسوب) در تخمین و برآورد رسوب از قوت و دقت بیشتری برخوردار بوده است. همچنین اندازه‌گیری به روش مستقیم، اگر چه مطمئن‌ترین روش اندازه‌گیری غلظت رسوبات معلق است با این همه این روش، اغلب زمان بر و پرهزینه است. شبکه عصبی مصنوعی روشی است که بر پایه شبیه سازی عملکرد مغز انسان برای حل مسایل متنوع ارائه و از لایه های نرون ورودی، خروجی و میانی و وزنهای مربوط به مقادیر ورودی و بایاس و تابع تحریک تشکیل شده است. از قابلیت‌های شبکه عصبی مصنوعی میتوان به مواردی مانند محاسبه یک تابع معلوم، تقریب یک نگاشت نامعلوم، شناسایی الگو، پردازش سیگنال و یادگیری اشاره کرد (انجمن مهندسان عمران آمریکا، ۲۰۰۰). از معایب روشهای شبکه عصبی نیز این است که تابعی در اختیار قرار نمی دهد که بتوان از آن به صورت صریح استفاده نمود. مطالعات زیادی در زمینه رسوب با استفاده از شبکه عصبی انجام نشده است (گاویندراجو و رامانچدرا<sup>۵</sup>، ۲۰۰۰، سارنگی و بهاتاچاری<sup>۶</sup>، ۲۰۰۵). شبکه های عصبی پس انتشار خطای رو به جلو (پیش خور) با داشتن توابع غیر خطی

1 Nakato

2 Lopes

3 Walling &amp; Webb

4 Ulke

5 Govindaraju &amp; Ramachandra

6 Sarangi &amp; Bhattacharya

(سیگموئیدی)، دارای قابلیت انعطاف پذیری زیاد بوده و می توانند در تقریب زدن یک تابع، یافتن رابطه بین ورودی و خروجی و نظایر آن بسیار کارآمد باشند. در هیدرولوژی، با توجه به اغتشاش حاکم بر داده های رواناب-رسوب، استفاده از این شبکه ها، بسیار توصیه شده است (فلود و کارتمان<sup>۱</sup>، ۱۹۹۴). سارانگی و بها تاچاریا(۲۰۰۵) درحوضه آبخیز Banha هندوستان، با استفاده از مدل های رگرسیونی و شبکه عصبی، دبی رسوب را برآورد نموده و نتیجه گرفتند که مدل شبکه عصبی از دقت بیشتری برخوردار است. تفوالا و ونگ<sup>۲</sup> (۲۰۱۶) به تخمین میزان رسوب در رودخانه شیوان در تایوان پرداختند. در این پژوهش مدل شبکه عصبی مصنوعی و روش منحنی سنج رسوب مورد استفاده قرار گرفت. نتایج نشان داد که مدل شبکه عصبی MLP توانست تخمین مناسبی از میزان رسوب با مقدار R برابر با ۰,۹۷ ارائه دهد.


جمع بندی سابقه های پژوهش نشان داد که روش های رگرسیونی استاتیک از دقت بالایی جهت برآورد دبی بار معلق رسوبات برخوردار نبوده اند. همچنین در سال های اخیر تمرکز مدل های پیش بینی از سمت رگرسیون خطی به سمت مدل های بکه عصبی تغییر کرده است. بیشتر محققین در این سال ها به ارائه مقایسه بین مدل های گوناگون شبکه عصبی پرداخته اند و همچنین در مدل سازی های نهایی خود سعی در استفاده از عوامل مربوط به مورفولوژی حوضه در مدل نهایی به منظور افزایش دقت وصحت مدل نهایی بوده اند. بنابراین در این پژوهش، از روش شبکه عصبی مصنوعی با در نظر گرفتن رفتار دینامیکی بار معلق و دبی جریان روزهای پیشین به عنوان متغیر مؤثر، استفاده شده است.

## روش تحقیق

### منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش حوضه ابریز رودخانه ونایی است. این منطقه در شهرستان بروجرد، در استان لرستان در غرب ایران واقع شده است. حوضه مزبور بین طول های  $48^{\circ}30'$  تا  $48^{\circ}55'$  درجه و عرض های  $33^{\circ}45'$  تا  $33^{\circ}00'$  درجه واقع شده است. رودخانه ونایی آب حوضه ای به مساحت ۷۰ کیلومترمربع را تخلیه می کند. ارتفاع متوسط این حوضه ۲۳۵۰ متر است. این رود از سرچشمه های متعدد در روستای ونایی در غرب این شهرستان نشأت می گیرد و در غرب شهر بروجرد در مجاورت تپه چغا از سمت شمال شاخه ای دیگر دریافت می کند.

1 Flood & Kartam  
2 Tfwala & Wang



شکل (۱). موقعیت منطقه مورد مطالعه و ایستگاه مورد بررسی

در حوضه رودخانه ونایی به منظور تخمین میزان رسوب رودخانه از دو ایستگاه ونایی و سازمان آب استفاده شده است. موقعیت این دو ایستگاه نسبت به رودخانه ونایی و زیرحوضه های مربوط به آن در شکل (۱) نشان داده شده است. در جدول (۱) نیز مشخصات سه ایستگاه مربوطه آورده شده است.


جدول (۱). مشخصات ایستگاه‌های هواشناسی واقع در محدوده مطالعاتی و پیرامون محدوده مطالعاتی

نوع ایستگاه	سال تأسیس	مشخصات جغرافیایی			حوضه آبریز رودخانه	نام ایستگاه	کد ایستگاه
		ارتفاع (متر)	عرض	طول			
تبخیر سنج	۱۳۶۵	۱۴۹۰	۳۳°۲۷'۱۴"	۴۸°۴۸'۳"	چالان چولان	رحیم آباد (بروجرد)	۲۳۳۹۱۱۰۱۱
باران سنج	۱۳۴۵	۱۵۵۰	۳۳°۳۰'۴"	۴۸°۱۶'۲۰"	چالان چولان	تپه چغای ونایی	۲۲۱۱۱۳۰۰۱
باران سنج	۱۳۶۵	۱۵۶۰	۳۳°۳۰'۱۱"	۴۹°۰۳'۱۹"	هرود	بیاتون	۲۳۴۱۱۳۰۰۱

### داده و روش کار

داده های دبی رودخانه و میزان رسوب این دو ایستگاه از سال ۱۳۵۰ و ۱۳۵۵ موجود می باشد و تا سال ۱۳۹۱ به طور منظم جمع آوری شده است که در این مطالعه مورد استفاده قرار گرفته است. در این تحقیق از آمار دبی لحظه ای - رسوب لحظه ای ثبت شده مربوط به دوره آماری سال ۱۳۵۰ تا ۱۳۹۱ سازمان آب منطقه ای لرستان استفاده شده است. این آمار شامل دبی لحظه ای روزانه به مترمکعب بر ثانیه و رسوب روزانه لحظه ای به تن در روز است که به صورت همزمان اندازه گیری شده اند. ویژگی های مورفولوژیکی حوضه شامل مساحت، طول رودخانه و محیط آن به کمک نرم افزار Arc Map پارامترهای ژئومورفولوژیکی حوضه با استفاده از خصوصیات طبیعی حوضه بر اساس دستورالعمل سینگ و همکاران (۲۰۰۹) با استفاده از افزونه Arc Hydro که بر روی نرم افزار فوق نصب می شود، محاسبه گردیده است.

در این پژوهش در قدم نخست با استفاده از نرم افزار Arc MAP و افزونه Arc Hydro محدوده حوضه آبریز رودخانه ونایی استخراج شد. سپس پارامترهای مورد نیاز برای مدل سازی که شامل دو دسته پارامترهای مربوط به مورفولوژی رودخانه و پارامترهای مربوط به مورفولوژی حوضه آبریز هستند، تهیه و استفاده گردید. این پارامترها با استفاده از افزونه Arc Hydro در محیط GIS استخراج شده اند. در ادامه داده های مربوط به دبی و رسوب که از ایستگاه های زمینی تهیه شده است پیش پردازش شده برای ورود به نرم افزار SPSS آماده سازی شده است. مدل سازی شبکه عصبی مصنوعی و رگرسیون خطی در نرم افزار Matlab انجام شده است. پس از مدل سازی و پیش بینی داده ها اعتبارسنجی آن ها در نرم افزار Excel انجام پذیرفته است. در شکل ۲ روند انجام این پژوهش در قالب یک نمودار آورده شده است.

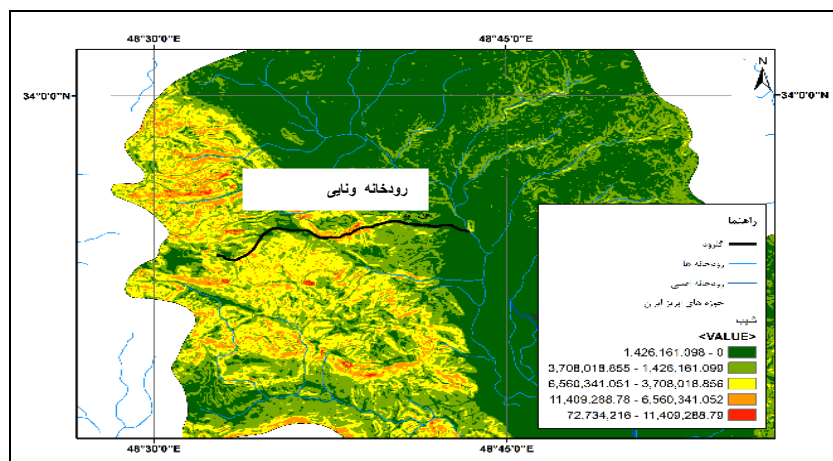


شکل (۲). فرایند کلی انجام پژوهش

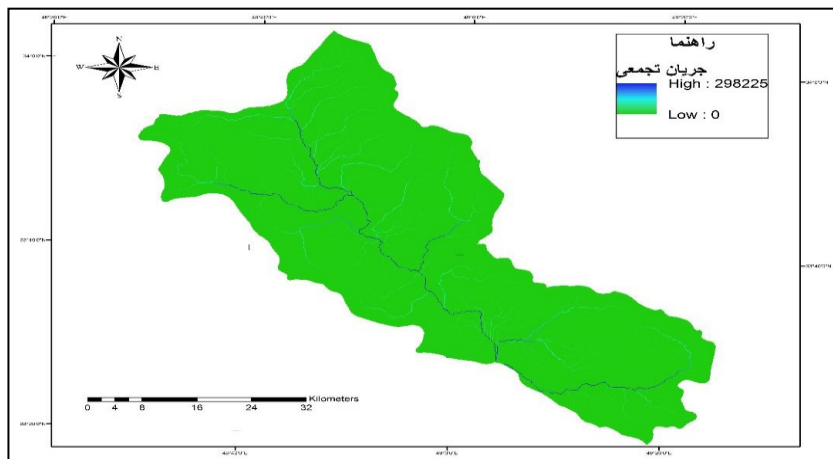
در انتخاب متغیرهای ورودی مدل بایستی متغیرهای نسبتاً مستقل، اثرگذار و قابل دسترس تعیین شوند. از جمله این متغیرها می توان به مشخصات فیزیکی حوضه اشاره کرد. این امر موجب جلوگیری از افزایش بدون دلیل عامل ها (ورودی ها) و افزودن بر پیچیدگی های مدل، با داده های جمع آوری شده موجود مدل مناسبی ساخته شود. به عبارت دیگر با افزایش تعداد ورودی ها، لزوماً تعداد بیشتری داده مورد نیاز است. ورودی های مدل از نظر ویژگی طبیعی به دو بخش قابل تقسیم هستند. دسته نخست، شامل ورودی هایی است که در ارتباط با ویژگی های ذاتی حوضه آبخیز هستند و به آنها متغیرها و یا ورودی های ثابت گفته می شود. این متغیرها شامل مساحت زیر حوضه ها به کیلومتر مربع، ارتفاع متوسط زیر حوضه از سطح دریا به متر، طول آبراهه اصلی به کیلومتر، شیب آبراهه اصلی (درصد) هستند. بخش دوم شامل ورودی هایی هستند که تابعی از

عوامل اقلیمی بوده و بعنوان متغیرها و یا ورودی‌های متحرک گفته می‌شوند. این متغیرها در مدل شامل بارندگی و دبی روزانه به مترمکعب بر ثانیه می‌باشد. متغیر خروجی مدل تنها دبی رسوب در روز است. داده‌ها بر اساس رویه معمول برای آموزش، آزمون و اعتبارسنجی مدل به سه بخش مجزا از هم تقسیم می‌شوند. برای آموزش ۰/۸۰ منظور شده و ۰/۲۰ نیز برای آزمون و اعتبارسنجی مدل اختصاص داده می‌شوند. داده‌های منظور شده برای آزمون و اعتبارسنجی در آموزش شبکه شرکت داده نمی‌شوند.


به منظور استخراج خصوصیات زیر حوضه‌های منطقه در فاز نخست با استفاده از لایه ارتفاعی DEM ماهواره استر و ابزار Arc Hydro به ترتیب لایه‌های مربوط به آبراهه‌های منطقه شیب شکل (۳)، جریان تجمعی شکل (۴)، شبکه آبراهه‌ها شکل (۵) و در نهایت زیر حوضه‌های مورد نظر برای هر ایستگاه در شکل (۶) مشخص شد.




شکل (۳). شیب منطقه



شکل (۴). جریان تجمعی



شکل (۵). شبکه ابراهه استخراج شده از DEM



شکل (۶). زیر حوضه های استخراج شده برای هر ایستگاه

پس از محاسبه این پارامترها با استفاده از نرم افزار ARC MAP پارامترهای محیط، مساحت، میانگین شیب، طول رودخانه، حداقل، حداکثر و میانگین ارتفاع منطقه محاسبه شده است. در مرحله بعد همبستگی بین این پارامترها با میزان رسوب هر ایستگاه برای دو زیرحوضه مشخص شده به کمک نرم افزار SPSS محاسبه گردید.

#### مدل سازی آماری

در این بخش دو روش مدل سازی آماری برای تخمین میزان رسوب رودخانه اجرا شده است. روش نخست روش مدل سازی به روش رگرسیون خطی چند متغیره است. روش دوم شبکه عصبی مصنوعی است که در آن مدل MLP اجرا شده است. در این مدل پارامتر وابسته، میزان رسوب جریان در نقاط اندازه گیری است و سایر پارامترها از جمله میزان دبی، مساحت حوضه، طول رودخانه و ... به عنوان پارامترهای پیش بینی مورد استفاده قرار گرفته است.

## مدل سازی به روش رگرسیون خطی چند متغیره

در این حالت به منظور ارائه مدلی مبنی بر داده های اقلیمی به منظور تخمین میزان رسوب از مدل رگرسیون خطی چند متغیره استفاده شده است. جهت تاثیر دادن پارامترهای ژئومورفولوژی بر روی دبی لحظه ای و ارتباط غیرخطی بین این متغیرهای مستقل با رسوب لحظه ای، از روش مارس استفاده شده است. رابطه (۱).

$$S = aR\sqrt{Ff} + bR\sqrt{Df} + cR\sqrt{Rf} + d$$

در معادله مارس (معادله فوق)  $a, b, c, d$  ضرایب معادله  $Df, Rf, Ff$  به ترتیب مساحت هر زیر حوضه، میانگین حوضه، میانگین شیب، میزان طول رود خانه و  $S$  میزان بار رسوب هستند. مدل کلی در این حالت به صورت رابطه (۲) است.

$$\text{Sediment} = \alpha + \beta(\text{Discharge}) + \gamma(\text{Area}) + \delta(\text{slope}) + \epsilon(\text{Length}) + \zeta(\text{Primeter}) + \xi(\text{AvgElevation}) + \eta(\text{minElavation}) + \theta(\text{maxElevation})$$

که در آن به ترتیب میزان دبی جریان، میزان مساحت هر زیر حوضه، میانگین شیب هر زیر حوضه، میزان طول رودخانه، میزان محیط هر زیرحوضه، میانگین ارتفاع زیرحوضه، حداقل ارتفاع زیرحوضه و حداکثر ارتفاع زیرحوضه استفاده شده است. شکل های (۳، ۴، ۵ و ۶)

همچنین ضرایب  $\alpha, \beta, \gamma, \delta, \epsilon, \zeta, \eta, \theta$  ضرایب خط برازش شده با توجه به مقادیر این پارامترها و میزان رسوب ایستگاه های مربوطه است. پس از اجرای این مدل در نرم افزار SPSS2007 مدل نهایی تولید شده است. رابطه (۳) نتایج مربوط به مدل رگرسیون خطی استخراج شده به منظور تخمین میزان رسوب را نشان می دهد. رابطه (۳).

$$\text{Sediment} = 19258.789 + 299.859(\text{Discharge}) + 22.743(\text{Area}) + 2.965(\text{Length}) + 19.394(\text{Lenght}) + 0.008(\text{Primeter}) + 13.723(\text{MinElevation}) + 5.387(\text{maxElevation})$$

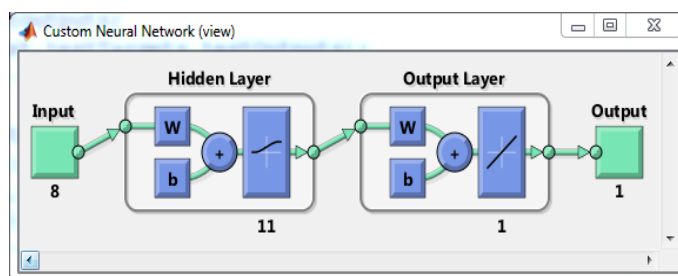
## تعیین ساختار مناسب برای تخمین بار رسوب

به منظور تعیین بهترین ساختار برای شبکه عصبی مصنوعی تعداد زیادی شبکه عصبی ایجاد گردید که در تعداد تکرار نرون های موجود در لایه پنهان و ضریب یادگیری متفاوت بودند و برای بدست آوردن مقدار بهینه هر پارامتر شبکه، شبیه سازی های متعددی صورت پذیرفت که در طی آن برای تعداد معینی از تکرار، یک پارامتر متغیر و پارامترهای دیگر ثابت در نظر گرفته شد. در تمامی شبیه سازی صورت پذیرفته شاخص متوسط مجذور مربعات خطا به عنوان یک شاخص راهنما، بیانگر کارایی شبکه در یادگیری الگوهای موجود استفاده

۱ در این روش دبی با استفاده از توان رسانی پارامترهای ژئومورفولوژی به تعداد متغیر مستقل تبدیل شده و با استفاده از آنالیز رگرسیون چند متغیره پارامترهای تاثیر گذار تعیین شده است. به عبارت دیگر در این روش هر یک از پارامترهای مورفولوژیکی حوضه که به صورت یک داده نقطه ای هستند با تلفیق شدن در یک بردار داده، نظیر آمار سیلاب به یک بردار جدید تبدیل می شود و بردارهای جدید که منبای رگرسیون چند گانه میباشد قرار گرفته و مدل مناسب حاصل می شود.



گردید. بعد از تعیین این پارامترها ۸ نرون در لایه ورودی، ۱۱ نرون در لایه پنهان و ۱ نرون در لایه خروجی مناسب تشخیص داده شد. شکل (۴) و بر اساس این ساختار تخمین نهایی صورت گرفته است.



شکل (۴). ساختار شبکه عصبی مصنوعی برای تخمین بار رسوب در رودخانه ونای

### مراحل تعیین وزن در شبکه عصبی مصنوعی

تعیین وزن در شبکه عصبی شامل دو مرحله است. در مرحله اول وزن ها به صورت تصادفی تعیین می شوند. کاوژوگلو (۲۰۰۵) وزن های اولیه را به صورت تصادفی بین  $-0.3$  تا  $0.3$ ، وزن های اولیه را به صورت تصادفی بین  $-0.5$  تا  $0.5$ ، نسفلیوک و همکاران (۲۰۰۸) وزن های اولیه را بین  $-1$  و  $1$  انتخاب کردند. در این تحقیق در مرحله اول وزن ها به صورت تصادفی و بین  $-0.7$  تا  $0.7$  انتخاب شده است. علت استفاده از مقدار وزن ها در بازه یاد شده جلوگیری از به دام افتادن مساله در بهینه های محلی و و دوری از عملگرایی زود رس می باشد و همچنین در این بازه کمترین خطا تولید می شود.

در جدول (۲) کاربرد فرمولها جهت تعیین وزن نهایی طبقات هر عامل در شبکه عصبی مصنوعی، تابع فعال که معمولاً یک تابع غیر خطی است برای دادن مجموعه وزنه های خروجی از هر لایه به لایه بعدی، میزان خطای شبکه الگوریتم پس انتشار خطا تا موقعی که خطای کل شبکه حداقل شده و یا به مقدار مورد نظر برسد، وزن نسبی یک یا چند واحد پردازشگر لایه های پنهان و لایه های خروجی و در نهایت در طی تکرار این روابط یا فرمولها خطا در مرحله آموزش کم شده و هر طبقه از عوامل ورودی دارای وزنهایی است که جهت پیش بینی استفاده می شود.


جدول (۲). کاربرد فرمولها جهت تعیین وزن نهایی طبقات هر عامل در شبکه عصبی مصنوعی

	$W_i = (\text{RAND}(S_i, 8) - 0.7/0.7)$	$O_j = f(\text{NET}_j)$	$F'(\text{NET}_j) = f(\text{NET}_j)(1 - F(\text{NET}_j))$
$\delta_j = (d_k - o_k) f'(net_k)$ لایه های پنهان	$w_{ij}(n+1) = \eta(\delta_j o_i) + \alpha \Delta w_{ij}$	$E = \frac{1}{2} \sum_k (d_k - o_k)^2$	
$w_j o_k = \frac{1}{j} \sum_{j=1}^j  w_{jk} $	$f'(net_k) \times \frac{\delta(net_k)}{\delta o_j} = f'(net_k) \times w_{jk}$	$\delta_j = (\sum_k \delta_k w_{jk}) f'(net_k)$ لایه های خروجی	
$t_j = \frac{1}{k} \sum_{j=1}^k t_{jk}$	$\sum_{j=1}^j t_{jk} = J$	$\frac{ w_{jk} }{\frac{1}{j} \sum_{j=1}^j  w_{jk} } = \frac{J  w_{jk} }{\sum_{j=1}^j  w_{jk} }$	

$st_j = \frac{1}{J} \sum_j s_{ij} t_j$	$s_i = \frac{1}{J} \sum_{j=1}^J s_{ij}$	$s_{ij} = \frac{ \omega_{ij} }{\frac{1}{I} \sum_{i=1}^I  \omega_{ij} } = \frac{I  \omega_{ij} }{\sum_{i=1}^I  \omega_{ij} }$
$\frac{ \delta o_k }{ \delta o_j } / \frac{ \delta o_k }{ \delta o_j } \frac{ \delta o_k }{ \delta o_j o } \frac{ \delta o_k }{ \delta o_j o } = \frac{ f'(net_k) w_{jk} }{ f'(net_k) w_{j o_k} } = \frac{ w_{jk} }{ w_{j o_k} }$		

جهت استفاده از تعیین وزن مناسب و برآورد کمترین خطا

شکل (۵) ۷ دوره زمانی را نشان می دهد که در شبکه عصبی در ۷ دوره داده های واقعی را تحلیل کرده و بهترین تخمین را در دوره ۱ به دست آورده است در این تحلیل از روش مینیمم خطا استفاده شده و سطح معنی داری را پیدا کرده است. همان طور که در نمودار فوق با دایره محل یاد شده مشخص می باشد، داده های Train از نتیجه بهینه دور شده و داده های دوره یک کمترین خطا را داشته است.



شکل (۶). نمودار تحلیل شبکه عصبی طی دوره های مختلف جهت بررسی دقت پیشبینی

### ارزیابی مدل

یکی از مهم ترین موارد مطالعات پارامترهای حوضه ابریز، شناخت روابط موجود بین متغیرهای مورد مطالعه است. روابط آماری متعددی برای شناخت رابطه بین متغیرها وجود دارد که هم به صورت معادلات خطی و هم به صورت معادلات غیر خطی بیان می شود. از معیارهایی که در پژوهش های فوق الذکر جهت ارزیابی به کار می رود تعیین ضریب همبستگی یا  $R^2$  است که از رابطه (۴) محاسبه می شود.

رابطه (۴)

$$R^2 = \text{RSS}/\text{TSS}$$

RSS: مجموع مربعات رگرسیون

TSS: مجموع مربعات کل

ضریب همبستگی ابزاری آماری برای تعیین نوع و درجه رابطه یک متغیر کمی با متغیر کمی دیگر است. همبستگی بین دو متغیر تصادفی  $X$  و  $Y$  به صورت رابطه (۵) تعریف می‌شود:

$$\text{corr}(x, y) = \frac{\text{cov}(x, y)}{\delta_x \delta_y}$$

در رابطه بالا  $\sigma$  انحراف معیار و  $\text{Cov}(x, y)$  کواریانس بین دو متغیر  $x$  و  $y$  است. همبستگی بین مقادیر ذکر شده توسط نرم افزار SPSS محاسبه شده است.

RMSE ریشه توان دوم خطاها به منظور محاسبه میزان تفاوت بین مقادیر واقعی و مقادیر پیش بینی شده در مدل استفاده شده است. این شاخص هم به خطاهای تصادفی و هم به خطاهای سیستماتیک حساسیت دارد. برای محاسبه این پارامتر از رابطه (۶) استفاده می‌شود:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{predict} - \text{ground})^2}$$

که در آن،  $n$  برابر با تعداد کل داده ها، Predict برابر با مقدار پیش بینی شده توسط مدل و Ground برابر با مقدار داده های زمینی است. این شاخص هرچقدر کمتر باشد نشان دهنده صحت بهتر مدل نهایی است. MAE میانگین خطاهای مطلق یکی از پر استفاده ترین شاخص ها برای نشان دادن میانگین خطاها است. به منظور محاسبه این شاخص از رابطه (۷) استفاده شده است.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\text{predict} - \text{ground}|$$

با توجه به جدول (۴) اختلاف مقادیر واقعی از مقادیر اندازه گیری شده در مدل LMP عدد ۲۸۹، در مدل رگرسیون خطی ۱۴۴ و مقدار واقعی عدد ۳۱۲ می باشد که قابل چشم پوشی بوده و این نشان دهنده قوت و میزان دقت مدل MLP می باشد.

### نتایج


به منظور مدل سازی تخمین بار رسوب در ابتدا بایستی همبستگی بین داده های ورودی مدل مورد بررسی قرار بگیرد. در جدول (۱) همبستگی بین داده های ورودی نسبت به داده های رسوب آورده شده است. بیشترین میزان همبستگی بین میزان بار رسوب با دبی جریان و با مقدار معناداری ۰/۶۷۵ است. در مرحله دوم بیشترین همبستگی با میزان شیب حوضه با مقدار ۰/۲۶۴ و سپس با طول رودخانه با مقدار ۰/۲۵۸ است. پس از آن که متغیر های حوضه مشخص شدند و میزان همبستگی آنها با رسوب منطقه بدست آمد بایستی در یک مدل رگرسیون خطی و مدل شبکه عصبی مصنوعی ترکیب شوند که بتوان میزان رسوب را تخمین زد.

جدول (۳). همبستگی بین داده های ورودی مدل شبکه عصبی مصنوعی نسبت به داده های رسوب

پارامتر	دبی جریان	مساحت حوضه	محیط حوضه	حداکثر ارتفاع	حداقل ارتفاع	میانگین ارتفاع	شیب	طول رودخانه
میزان رسوب	۰/۶۹۱*	۰/۱۸۵	۰/۱۲۱	۰/۱۵۲	۰/۱۷۶	۰/۱۵۸	۰/۳۱۲	۰/۲۳۷

\* در سطح ۵٪ دارای رابطه معنادار است.

پس از مدل سازی داده ها توسط دو مدل شبکه عصبی مصنوعی و مدل رگرسیون خطی مقدار رسوب برای هر سال محاسبه توسط این مدل ها محاسبه شده است و مقادیر شاخص های MAE و RMSE برای آنها محاسبه شده و در جدول (۴) نمایش داده شده است. در شکل (۶) نمودار پراکندگی بین داده های واقعی با داده های تخمین زده شده توسط مدل های شبکه عصبی مصنوعی و رگرسیون خطی آورده شده است. مقایسه میزان  $R^2$  و نحوه پراکنش داده ها در هر دو مدل نشان میدهد که نمودار a که مربوط به مدل رگرسیون خطی می باشد دارای همبستگی پایین و نحوه پراکنش نامنتظمی می باشد این در حالیست که نمودار b دارای ضریب همبستگی نسبتاً قابل قبولی به مقدار ۰,۸۸ و پراکنش متقارن تری نسبت به خط همبستگی می باشد. باتوجه به فشردگی نقاط در اطراف خط هم بستگی میزان همبستگی در داده ها مشخص می گردد که این میزان در نمودار مربوط به مدل MLP قابل قبول بوده و علت پراکنش این است که نتایج به دست آمده با دبی رسوب همگرایی بیشتری داشته و در نتیجه پراکنش متقارن تری دارد این در حالی است که پراکنش در مدل رگرسیون خطی نامنتظم و نامتقارن می باشد.



شکل (۶). نمودار پراکندگی داده های واقعی و داده های پیش بینی شده توسط هر مدل، (a) مدل رگرسیون خطی چند متغیره، (b) مدل شبکه عصبی مصنوعی MLP

در جدول (۴) نیز مقادیر مربوط به شاخص های MAE و RMSE آورده شده است. این دو شاخص نشان دهنده این امر است که میزان اختلاف مقادیر پیش بینی شده با مقادیر واقعی چه مقدار است. همانگونه این که این

جدول نشان می‌دهد میزان شاخص RMSE برای مدل رگرسیون خطی بیشتر از مدل دیگر است. مدل MLP نیز کمترین میزان را دارد.

جدول ۴ مقادیر شاخص های MAE، RMSE و R2 در مدل شبکه عصبی مصنوعی

مدل	MAE	RMSE	R2
MLP	۴۸/۱۱۲	۹۰/۴۷	۰/۸۹۱
رگرسیون	۷۵۹/۰۹۲۰۱	۱۵۹/۷۱۹۷	۰/۳۵۳

مقایسه پارامترهای آماری (میانگین، میانه، مد و انحراف معیار) حاصل از مدل شبکه عصبی مصنوعی (MLP) در تخمین رسوب و دانه ونایی و داده های واقعی میزان بار رسوب در ایستگاه های زمینی می‌باشد. جدول (۵).

جدول ۵: مقادیر شاخص های MAE، RMSE و R2 در مدل MLP

مدل	میانگین	میانه	مد	انحراف معیار
MLP	۴۰۷/۲۳	۲۲۸	۲۷۷/۱۷	۲۸۹/۱۵
مقادیر واقعی	۳۹۲/۱۲	۲۴۲	۱۳۲	۳۱۲/۱۲
رگرسیون چند متغییره	۳۵۷/۴۲	۲۴۰/۸۵	۲۶۰	۱۴۴/۰۳۲

جدول (۶) شامل داده های آماری مربوط به موارد تخمین زده شده و موجود می باشد. این داده ها شامل میانگین، میانه، مد و انحراف معیار داده های پیش بینی شده توسط دو مدل شبکه عصبی و رگرسیون چند متغیره و داده های واقعی میزان بار رسوب در ایستگاه های زمینی است. بر اساس این جدول مدل MLP دارای میانگینی برابر با ۴۰۷،۲۳ است که در حدود ۲۵ واحد با مقدار واقعی تفاوت دارد. در مورد شاخص میانه مدل MLP دارای میانه نزدیکتری به مقادیر واقعی است. شاخص مد که نشان دهنده داده های با بیشترین تکرار در مجموعه آماری است، برای مقادیر واقعی عدد ۱۳۲ و برای مدل MLP عدد ۲۷۷ است که نزدیکترین مقدار به مقدار واقعی محسوب میشود. بر اساس نتایج این جدول می‌توان ذکر کرد که مدل MLP با وجود ارائه مقادیر عددی RMSE کمتر ولی پراکندگی بیشتری را در کل داده ها موجب می‌شود. از سوی دیگر داده های مربوط به این امر از روی مقادیر انحراف معیار نیز قابل مشاهده است به صورتی که نزدیکترین میزان انحراف معیار به مقادیر واقعی را مدل MLP دارا است.

جدول (۶). پارامترهای آماری مدل شبکه عصبی مصنوعی در تخمین رسوب رودخانه ونایی

مدل	میانگین	میانه	مد	انحراف معیار
MLP	۴۰۷/۲۳	۲۲۸	۲۷۷/۱۷	۲۸۹/۱۵
مقادیر واقعی	۳۹۲/۱۲	۲۴۲	۱۳۲	۳۱۲/۱۲

## نتیجه گیری

تاکنون به منظور تخمین میزان رسوب رودخانه ها مدل های پیش بینی مختلفی استفاده شده است. برخی از این مدل ها با ترکیب پارامترهای مختلف فیزیکی حوضه، اقلیمی و حتی خروجی تصاویر ماهواره ای به تخمین میزان رسوب پرداخته اند. مدل های شبکه عصبی مصنوعی امروزه به طور گسترده ای در پیش بینی مدل های جغرافیایی کاربرد دارند. در این پژوهش دو مدل شبکه عصبی مصنوعی RBF، شبکه عصبی مصنوعی MLP و مدل رگرسیون خطی چند متغیره به منظور تخمین رسوب رودخانه استفاده شده است. پس از محاسبه شاخص های RMSE و MAE با توجه به این امر که هرچه قدر میزان این شاخص ها کمتر باشد مقدار پیش بینی شده به مقادیر واقعی نزدیکتر است بنابراین مدل شبکه عصبی مصنوعی MLP دقت بهتری را نسبت به دو مدل دیگر در تخمین میزان رسوب منطقه نشان میدهد. از سوی دیگر با توجه به مقدار شاخص R2 که برای دو مدل محاسبه شده است دقت تخمین مدل به مقدار ۰,۴۷, ۹۰ برای مدل MLP محاسبه شده است، مقدار R2 برای این مدل برابر ۰,۸۹ است. در رتبه دوم نیز مدل رگرسیون خطی چند متغیره با مقدار R2 برابر با ۰,۳ قرار دارد.

همانگونه که در این پژوهش نیز مشخص شد مدل های رگرسیون چند متغیره توانایی تخمین بار رسوب را با دقت بالایی ندارند. در پیشینه تحقیق نیز همواره این مدل ها دارای صحت و درصد همبستگی پایینی با داده های زمینی هستند. در این پژوهش نیز مدل شبکه عصبی MLP مورد مطالعه قرار گرفت. مدل MLP توانست داده های رسوب را با دقت بهتری نسبت به سایر مدل ها تخمین بزند. بنابراین می توان امکان سنجی استفاده از مدل های شبکه عصبی پیشخور را در تخمین بار رسوب تایید کرد. بر اساس سری های زمانی موجود، برآورد دقیق تر نیاز به دوره های طولانی مدت دارد و همچنین در نظر داشتن تغییرات آب و هوایی را در این تحقیقات می تواند به بهبود نتایج و صحت و دقت پیش بینی میزان رسوب کمک کند. از سوی دیگر در نظر گرفتن پارامترهای مربوط به جنس خاک منطقه و قابلیت نفوذ آب در خاک برای هر زیرحوضه می تواند در بهبود نتایج موثر باشد. نتایج این پژوهش نشان داد که تغییر در مقدار تولید رسوب معلق با شدت وقایع رواناب رابطه معنی داری دارد. از بین مشخصات فیزیکی حوضه مساحت حوضه و طول رودخانه اصلی جز عوامل دیگری هستند که در تخمین میزان رسوب پایین دست رودخانه اثر گذار است.

نتایج حاصل از این تحقیق با نتایج تحقیقات سمکل و همکاران (۲۰۱۶) که در حوزه رودخانه شیوان به منظور تخمین بار رسوبات معلق در رودخانه انجام گرفته است همخوانی داشته به گونه ای که در پژوهش یاد شده میزان رسوب با مقدار  $R=0.97$  تخمین تخمین گردید. در پژوهش پیش رو نیز میزان R محاسبه شده مقدار ۰,۸۸ برای مدل MLP تخمین زده شد که بیانگر قوت این مدل نسبت به مدل رگرسیونی در این پژوهش می باشد. همچنین با نتایج حاصل از پژوهش اولکی و همکاران که در سال (۲۰۰۹) بر روی رودخانه گیدز ترکیه با استفاده مدل های نروفازی، شبکه های عصبی، منحنی های رسوب و رگرسون چند متغیره انجام گرفته از نظر نتیجه همخوانی دارد در مطالعه فوق مدل های نروفازی و شبکه های عصبی نسبت به دیگر مدل ها (رگرسیون چند متغیره و منحنی های رسوب) در تخمین و برآورد رسوب از قوت و دقت بیشتری بر خوردار بوده است. در سال های دور مدل های شبکه عصبی گوناگونی برای این منظور توسط محققین ارائه شده است. این

مدل ها توانایی تخمین بار رسوب را در حدود ۸۰ الی ۹۵ درصد بنا به منطقه مورد مطالعه و تعداد پارامترهای جانبی مورد استفاده دارا هستند (گنرالپ و دیگران، ۲۰۱۳، توالف و ونگ و ۲۰۱۶، پتر و دیگران ۲۰۰۸). مدل سازی شبکه عصبی مصنوعی در مقایسه با مدل رگرسیونی می توان در زمان کمتری و با دقت بالاتری به روابط میان دبی و رسوب دست یافت دیگر مزیت این روش حساس نبودن آن به وجود تعداد معدودی خطا در داده های آماری است که همین امر باعث برآورد بهتر شبکه عصبی در مقایسه با مدل رگرسیونی شده است. (رضایی ۱۳۸۳).

نتایج این تحقیق با نتایج حاصله از تحقیق صورت گرفته توسط سارنگی و همکاران (۲۰۰۵) انطباق بیشتری دارد آنها در تحقیق خود مدل رواناب و رسوب تهیه شده با استفاده از شبکه مصنوعی در ایالت کبک کانادا بیان کردند که شبکه عصبی مصنوعی قابلیت بالایی جهت مدل سازی فرایندهای رواناب- رسوب داراست. در تحقیقات داخلی نیز پژوهش یاد شده با پژوهش عباسعلی ولی و همکاران (۲۰۱۰) روی حوضه آبخیز سمنگان انجام شد از نظر قوت مدل های شبکه عصبی نسبت به مدل های رگرسیونی شباهت تطابقی دارد. میتوان از مدل های شبکه عصبی recurrent با توجه به این امر که ایستگاه ها در امتداد ایستگاه های دیگر هستند در مطالعات بعدی که در این زمینه انجام می شود استفاده کرد. علاوه بر این ترکیب داده های تصاویر ماهواره ای با توجه به این که از دوره های گذشته نیز این داده ها در اختیار کاربران قرار دارد میتواند به ارائه مدل های با دقت بیشتر منجر شود.

#### منابع

- برزگر، فاطمه؛ دستورانی، محمدتقی. (۱۳۹۴). پیش بینی بار معلق رودخانه با استفاده از مدل های سری زمانی و شبکه عصبی مصنوعی مطالعه موردی ایستگاه قزاقلی، پژوهش نامه مدیریت حوزه آبخیز، ۶ (۱۹): ۲۲۷-۲۱۶.
- دهقانی، امیراحمد؛ ابراهیم زنگانه، محمد؛ مساعدی، ابوالفضل؛ کوهستانی، نسرين. (۱۳۸۸). مقایسه تخمین بار معلق به دو روش منحنی سنجی رسوب و شبکه عصبی مصنوعی مطالعه موردی رودخانه دوغ استان گلستان، مجله علوم کشاورزی و منابع طبیعی، ۱۶ (۱): ۲۷۶-۲۶۶.
- دهقانی، نوید؛ وفاخواه، مهدی. (۱۳۹۲). مقایسه روش های تخمین رسوب معلق روزانه با استفاده از روش های منحنی سنجی رسوب و شبکه عصبی مطالعه موردی ایستگاه قزاقلی، پژوهش های حفاظت آب و خاک منابع طبیعی، ۲۰ (۲): ۲۳۰-۲۲۱.
- شعبانی، محمد. (۱۳۸۸). مقایسه میزان کارایی شبکه عصبی مصنوعی و مدل های رگرسیونی در برآورد رسوب معلق روزانه، مهندسی مدیریت و آبخیز، ۳ (۴): ۲۴۷-۲۴۰.
- طهمورث، محمد. (۱۳۸۶). مقایسه دقت مدل های شبکه عصبی مصنوعی ژئومرفولوژی (GNNs) و رگرسیونی (RM) در برآورد رسوب طالقان رود، پژوهش های آبخیزداری، ۲۲ (۳): ۲۷-۱۹.
- عبدالله پورآزاد، محمدرضا؛ ستاری، محمدتقی. (۱۳۹۳). پیش بینی جریان روزانه رودخانه اهرچای با استفاده از شبکه عصبی مصنوعی (ANN) و مقایسه آن با سیستم استنتاج فازی - عصبی تطبیقی، نشریه پژوهش

های حفاظت آب و خاک، ۱۵ (۲۲): ۲۸۷-۲۹۷.

فلامکی، امین؛ اسکندری، مهناز؛ بغلائی، عبدالحسین؛ احمدی، سیداحمد. (۱۳۹۲). مدل سازی بار رسوب کل رودخانه ها با استفاده از شبکه عصبی، نشریه حفاظت منابع آب و خاک، ۲ (۳): ۱۴-۲۴.

همایون فقیه و همکاران. (۱۳۹۴). بررسی کارایی شبکه عصبی مصنوعی در برآورد بار معلق رودخانه با استفاده از داده های دسته بندی شده، مجله محیط زیست و مهندسی آب، ۱ (۱۰): ۵۱-۶۴.

ولی، عباسعلی؛ رامشت، محمدحسین. (۱۳۸۹). تحلیل مقایسه عملکرد شبکه های عصبی مصنوعی و مدل های رگرسیونی پیش بینی رسوب معلق مطالعه موردی حوضه آبخیز اسکندری واقع در حوضه آبریز زاینده رود، پژوهشهای جغرافیای طبیعی. ۴۲ (۷۱): ۳۰-۲۱.

ولی، عباسعلی؛ رامشت، محمدحسین؛ سیف، عبدالله. (۱۳۹۰). مقایسه کارایی مدل‌های شبکه عصبی مصنوعی و رگرسیون برای پیش بینی بار رسوب جریان مطالعه موردی حوضه آبخیز سمندگان، جغرافیا و برنامه ریزی محیطی، ۲۲ (۴): ۱۹-۳۴.

Bhattacharya, B., Price, R.K. and Solomatine, D.P., (2005). **Data-driven modeling in the context of sediment transport**. Physics and Chemistry of the Earth 30, 297-302.

Cigizoglu, H.K. and Kisi, O., (2006). **Methods to improve the neural network performance in suspended sediment estimation**. Journal of Hydrology. 317:221-238.

Flood, I., & Kartam, N. (1994). **Neural Networks in Civil Engineering. I: Principles and Understanding**. Journal of Computing in Civil Engineering, 8(2), 131-148.

Gong, B., Im, J., & Mountrakis, G. (2011). **An artificial immune network approach to multi-sensor land use/land cover classification**. Remote Sensing of Environment, 115(2), 600-614.

Govindaraju, R. S., & Ramachandra, A. (2000). **Artificial Neural Networks in Hydrology**. Artificial Neural Networks in Hydrology, 36(April), 337.

Lopes, V. L., Ffolliott, P. F., & Baker, M. B. (2001). **Impacts of Vegetative Practices on Suspended Sediment from Watersheds of Arizona**. Journal of Water Resources Planning and Management, 127(1), 41-47.

Nakato, T. (1990). **Tests of Selected Sediment-Transport Formulas**. Journal of Hydraulic Engineering, 116(3), 362-379.

Sarangi, A., A.K. Bhattacharya (2005), **Comparison of artificial neural network and regression models for sediment loss prediction from Banha Watershed in India**, Agricultural Water Management, 78, 195-208.

Tfwala, S. S., & Wang, Y. M. (2016). **Estimating sediment discharge using sediment rating curves and artificial neural networks in the Shiwen River, Taiwan**. Water (Switzerland), 8(2).

Ulke, A., G. Tayfur and S. Ozkul. (2009) **Predicting suspended sediment loads and missing data for Gediz river, Turkey**. Journal of Hydrologic Engineering, 14(9): 954-965

Walling, D. E., & Webb, B. W. (1988). **The reliability of rating curve estimates of suspended sediment yield: some further comments**. Sediment Budgets (Proceedings of the Porto Alegre Symposium), (174), 337-350.