

## مقایسه مدل‌های شبکه عصبی مصنوعی و منحنی سنج رسوب در شبیه‌سازی میزان رسوب معلق؛ مطالعه موردی حوزه آبخیز شاهرود

صدیقه محمدی<sup>۱</sup>

تاریخ دریافت: ۱۳۹۴/۱۰/۰۶

تاریخ پذیرش: ۱۳۹۵/۱۱/۰۳

### چکیده

این پژوهش با هدف مقایسه کارایی برخی مدل‌های شبیه‌سازی میزان رسوب معلق شامل منحنی سنج رسوب و شبکه عصبی مصنوعی و ارائه مدل بهینه بر اساس دبی جریان در حوزه آبخیز شاهرود و بر روی ایستگاه‌های هیدرومتری گلینک، باغکلایه، لوشان و رجائی دشت انجام شد. به منظور شبیه‌سازی میزان رسوب معلق از مدل منحنی سنج رسوب یک خطی و مدل‌های شبکه عصبی پرسپترون چند لایه و تابع پایه شعاعی بهره گرفته و سپس ارزیابی این مدل‌ها با استفاده از ضریب NASH و RMSE انجام شد. نتایج حاصل از این پژوهش حاکی از آن است که در کلیه ایستگاه‌های هیدرومتری مورد بررسی، مدل شبکه عصبی مصنوعی در مقایسه با مدل منحنی سنج رسوب نتایج بهتری ارائه کرد. به طوری که مدل شبکه عصبی مصنوعی پرسپترون چند لایه با تابع تحریک سیگموئید در ایستگاه‌های گلینک و رجائی دشت به ترتیب با RMSE، ۱/۰۳۳ و ۰/۸۲۵ تن در روز و ضریب NASH، ۰/۸۴ و ۰/۸۳۹ و این مدل با تابع تحریک تانژانت سیگموئید در ایستگاه‌های باغکلایه و لوشان به ترتیب با RMSE، ۰/۷۹۹ و ۰/۸۸۳ تن در روز و ضریب NASH، ۰/۷۷۲ و ۰/۸۹۵ کارایی بهتری در شبیه‌سازی میزان رسوب معلق دارد. همچنین مقایسه نتایج حاصل از دو مدل شبکه عصبی مصنوعی نشان داد که شبکه‌های MLP در مقایسه با شبکه‌های RBF از دقت بیشتری در شبیه‌سازی میزان رسوب معلق برخوردارند و تنها مزیت شبکه‌های RBF زمان کمتر مورد نیاز برای آموزش است.

واژه‌های کلیدی: پرسپترون چندلایه، تابع پایه شعاعی، شاهرود، ضریب NASH، منحنی سنج رسوب.

<sup>۱</sup> استادیار گروه اکولوژی، پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران، ۰۳۴۳۳۷۷۶۶۱۱، [mohamadisedigeh@gmail.com](mailto:mohamadisedigeh@gmail.com) (مسئول مکاتبه)

## مقدمه

پدیده فرسایش خاک و انتقال رسوب از جمله فرآیندهای مهم هیدرودینامیک هستند (Kisi and Shiri 2012) که به عنوان یکی از بزرگ‌ترین چالش‌های بهره‌برداری از منابع آب‌های سطحی در جهان شناخته می‌شوند (دهقانی و همکاران، ۱۳۸۸). ورود رسوبات معلق و مواد مغذی توسط رواناب به خروجی آبخیز یا سطوح اساس، یکی از مهم‌ترین دلایل کاهش کیفیت سامانه‌های آبی است (ابراهیمی محمدی و همکاران، ۱۳۹۱). فرسایش و تولید رسوب نقش به‌سزایی در هدر رفت خاک و کاهش حاصلخیزی آن، پر شدن مخازن سدها، گرفتگی و انسداد مجاری آبیاری، آبراهه‌ها و رودخانه‌ها، گل‌آلود کردن آب رودخانه‌ها، کاهش کیفیت آب و آلودگی آب‌های مناطق پایین‌دست دارد لذا این پدیده از دیرباز مورد توجه متخصصین و کارشناسان علوم زمین بوده است. برای جلوگیری و یا کاهش اثرات یاد شده نیاز به برنامه‌ریزی و اجرای اقدامات حفاظت خاک و کنترل رسوب در چارچوب طرح‌های آبخیزداری می‌باشد. لازمه برنامه‌ریزی و اتخاذ تصمیم درباره مهار فرسایش و رسوب، آگاهی از میزان فرسایش و تولید رسوب در یک حوزه آبخیز، شناسایی مناطق بحرانی و اولویت‌بندی آن‌ها برای اجرای برنامه‌ها و اقدامات آبخیزداری است (Ramos and Martinez-Casasnovas, 2006, Martinez et al., 2005, Bissonnaise et al., 2001).

با توجه به عدم وجود اطلاعات کافی و صحیح از فرسایش، انتقال رسوب و رسوب‌گذاری در رودخانه‌ها و مخازن سدهای ایران و همچنین جوان بودن تحقیقات در این رشته و فقدان اندازه‌گیری‌های دراز مدت رسوب، دسترسی به داده‌های قابل اعتماد رسوب مشکل بوده و لزوم استفاده از روش‌های برآورد و تخمین رسوب را مطرح می‌سازد (دهقانی و همکاران، ۱۳۸۸). یافتن روش‌هایی به منظور برآورد دقیق تولید رسوب در حوضه‌های کشور امری ضروری برای کنترل این فرایند است. شبیه‌سازی و ارزیابی آورد رسوب رودخانه از جمله مسائل مهم و کاربردی در مدیریت

منابع آب می‌باشد و در مطالعات پایه زیست‌محیطی و سدسازی نقش مهمی دارد (آوریده و همکاران، ۱۳۸۰). از آنجا که مسئله تولید رسوب در حوضه یک مساله بسیار پیچیده است و عوامل مختلف اکولوژیکی و محیطی بر آن موثرند لذا می‌توان بیان نمود که روابط متغیرها در این پدیده از روابط ریاضی پیروی نمی‌کند و این روابط بسیار پیچیده‌اند (یوسفی و پورشرعیاتی، ۱۳۹۳). لذا بهره جستن از انواع مختلف مدل‌ها جهت برآورد میزان رسوب معلق مانند مدل‌های مختلف منحنی سنج رسوب، شبکه عصبی و ... و مقایسه این مدل‌ها جهت ارائه مدلی بهینه در پیش‌بینی میزان رسوب معلق ضروری به نظر می‌رسد. روشی که اخیراً مورد توجه کارشناسان قرار گرفته، استفاده از شبکه‌های عصبی مصنوعی می‌باشد. در این زمینه مدل‌های ریاضی و فرمول‌های تجربی به‌ترتیب به دلیل پیچیدگی و نیاز به انواع مختلفی از پارامترهای موثر در انتقال رسوب موفقیت چندانی حاصل نکرده‌اند (Rezapour, et al., 2010). شبکه‌های عصبی مصنوعی به عنوان عضوی از خانواده هوش مصنوعی در تعیین بار معلق رسوب توانا به نظر می‌رسند (Heng and Suetsugi, 2013). این روش‌ها با الهام‌گیری از نرون‌های مغز انسان روابط ماورا موجود بین داده‌ها را بدست آورده و آن‌ها را در مواردی که مدل با آن‌ها مواجه نشده تعمیم می‌دهند. در این روش‌ها، مدل با استفاده از یک سری داده آموزش می‌بیند و با استفاده از اطلاعات حاصل از داده‌ها، وزن‌های شبکه تعیین می‌گردند (امجدی، ۱۳۸۱، ملکی نژاد و پورشرعیاتی، ۱۳۹۲، دستورانی و همکاران، ۱۳۹۱). به طور خلاصه از مهم‌ترین مدل‌های شبکه عصبی می‌توان پرسپترون چند لایه، شبکه خودسازمان‌ده، هاپفیلد، تاخیر زمانی و تابع پایه شعاعی را نام برد. در این راستا در سال‌های اخیر پژوهش‌های متعددی به کمک این ابزارها به عمل آمده است؛ (Mustafa et al. (2011) در مقایسه دقت دو مدل شبکه عصبی مصنوعی پرسپترون چندلایه و تابع پایه شعاعی در برآورد بار معلق به این نتیجه رسیدند که هر دو مدل از قابلیت مناسبی

رسوب جریان را بهتر پیش‌بینی می‌کند. فلامکی و همکاران (۱۳۹۲)، جهت مدل‌سازی بار رسوب کل رودخانه‌ها از شبکه‌های عصبی مصنوعی بهره جستند. نتایج نشان داد که مدل‌های ارائه شده بر پایه شبکه‌های عصبی با مقادیر رسوب کل مشاهده شده هم‌خوانی بیشتری دارند و به ویژه شبکه عصبی پرسپترون چندلایه می‌تواند مقدار رسوب را در نقاط اوج به خوبی برآورد نماید. یوسفی و برزگری (۱۳۹۴)، مدل‌های منحنی سنجه رسوب و شبکه عصبی مصنوعی در شبیه‌سازی رسوب معلق ایستگاه‌های استان لرستان را مقایسه نمودند. نتایج تحقیقات ایشان حاکی از برتری روش شبکه عصبی پیش‌خور پس انتشار نسبت به منحنی سنجه رسوب است. شاهرخی و همکاران (۱۳۹۵) به مقایسه کارایی مدل‌های منحنی سنجه رسوب و مدل درختی M5 در پیش‌بینی رسوب معلق پنج ایستگاه هیدرومتری استان خوزستان پرداختند. نتایج ایشان حاکی از برتری مدل درختی نسبت به منحنی سنجه رسوب می‌باشد. با توجه به اهمیت آمار دقیق رسوب و پیچیدگی تولید رسوب در حوزه‌های آبخیز کشور به دلیل دخیل بودن خصوصیات مختلف حوزه آبخیز ضرورت مقایسه انواع مدل‌های پیش‌بینی تولید رسوب در راستای معرفی مدل بهینه‌ی دوجندان پیدا می‌کند. با توجه به کاربرد انواع مدل‌ها در پیش‌بینی رسوب، این تحقیق با هدف مقایسه کارایی برخی مدل‌های شبیه‌سازی میزان رسوب معلق (شامل منحنی سنجه رسوب و شبکه عصبی مصنوعی) و نیز مقایسه کارایی دو مدل شبکه عصبی پرسپترون چند لایه و تابع پایه شعاعی و در نهایت ارائه مدل بهینه بر اساس دبی جریان انجام شد.

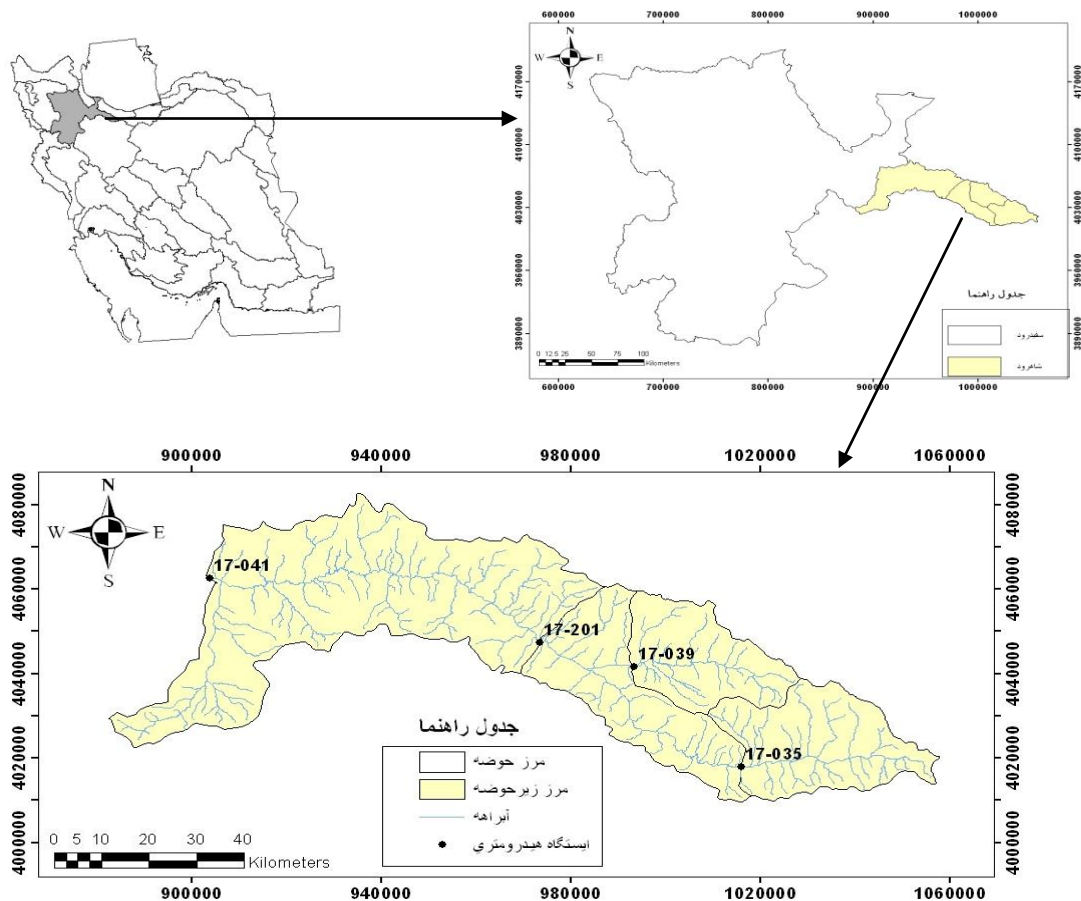
### مواد و روش‌ها

حوزه آبخیز رودخانه شاهرود در قسمت جنوب و جنوب غربی کوه‌های البرز و شمال و شمال شرقی دشت قزوین با مشخصات طول جغرافیایی  $30^{\circ} 49'$  الی  $10^{\circ} 59'$  و عرض جغرافیایی  $36^{\circ} 45'$  الی  $36^{\circ}$  قرار دارد، طول آن حدود ۱۶۰ کیلومتر و عرض آن

برخوردار می‌باشند. (Vafakhah (2012)، به مقایسه چهار روش شبکه عصبی مصنوعی، نروفازی، کریجینگ و کوکریجینگ، به منظور تخمین بار معلق رسوب پرداخت. نتایج نشان داد که در میان روش‌های فوق مدل‌های نروفازی و شبکه عصبی بهتر از کوکریجینگ و کریجینگ عمل می‌نمایند به طوری که مدل نروفازی دارای بیشترین و مدل کریجینگ دارای کمترین دقت تخمین بار رسوب معلق می‌باشد. (Heng and Suetsugi (2013). از شبکه‌های عصبی مصنوعی برای تخمین میزان رسوب معلق حوضه‌های فاقد ایستگاه رسوب سنجی حوزه آبریز رودخانه تونلساپ کامبوج استفاده کردند. نتایج حاصل از شبیه‌سازی با شبکه عصبی بسیار رضایت‌بخش بوده به طوری که میزان ضریب تبیین از  $0/81$  تا  $0/94$  و در مرحله اعتبارسنجی از  $0/63$  تا  $0/87$  بود. (Kumar et al. (2016) به شبیه‌سازی رسوب معلق روزانه با رویکرد یادگیری ماشینی (Machinelearning) شامل مدل‌های شبکه عصبی مصنوعی، رگرسیونی و مدل درخت تصمیم‌گیری در حوضه رودخانه Kopili پرداختند. مقایسه نتایج نشان داد که مدل‌های شبکه عصبی مصنوعی و نیز رگرسیونی حداقل مربعات نتایج بهتری نسبت به سایر مدل‌ها دارند. (Safari et al. (2016) به مدل‌سازی جریان رسوب رودخانه‌ای با استفاده از مدل‌های رگرسیونی و شبکه عصبی مصنوعی با الگوریتم پس انتشار خطا (FFBP) و تابع پایه شعاعی (RBF) در شرایط آزمایشگاهی پرداختند. نتایج تحقیقات ایشان حاکی از آن است که هر دو مدل‌های شبکه عصبی مصنوعی و مدل‌های رگرسیونی قابلیت خوبی در مدل‌سازی جریان رسوب دارند اما مدل الگوریتم پس انتشار خطا نتایج بهتری نسبت به مدل تابع پایه شعاعی ارائه می‌دهد. در داخل کشور، ولی و همکاران (۱۳۹۰) در مقایسه کارایی مدل‌های شبکه عصبی مصنوعی و رگرسیون برای پیش‌بینی بار رسوب جریان حوضه آبخیز سمندگان به این نتیجه دست یافتند که شبکه عصبی ژنومورفولوژیکی با ضریب تبیین  $0/86$  در مقایسه با شبکه عصبی غیرژنومورفولوژیکی میزان

سال هفتم • شماره بیست و هفتم • بهار ۱۳۹۶

حدود ۲۵ کیلومتر می‌باشد. ارتفاع حداقل و حداکثر آن ۱۹۱۶ و ۴۳۰۸ متر و متوسط بارندگی سالانه حوضه ۴۴۶ میلیمتر می‌باشد. رودخانه شاهرود از کوه‌های طالقان، علم‌کوه، تخت سلیمان و رشته ارتفاعات البرز سرچشمه گرفته و از نظر آب و هوایی، رژیم بارندگی، نظام هیدرولوژیک و سایر مشخصه‌های هیدرولوژیک در زمره رودخانه‌های کوهستانی قرار می‌گیرد. این رودخانه در واقع مهم‌ترین و پرآب‌ترین رودخانه استان قزوین است. شکل ۱ موقعیت این حوضه را در حوزه آبخیز سفیدرود و موقعیت ایستگاه‌های هیدرومتری مورد مطالعه را نشان می‌دهد.



شکل (۱): موقعیت حوزه آبخیز شاهرود در حوضه سفیدرود و موقعیت ایستگاه‌های هیدرومتری و حوضه‌های آن‌ها

ایستگاه‌ها با توجه به موقعیت پراکنش آن‌ها در سطح حوضه، عدم وجود سد مخزنی در بالادست آن (عرب خدری، ۱۳۸۸) و کامل بودن آمار همزمان دبی و

در راستای انجام این تحقیق، پس از جمع‌آوری آمار و اطلاعات مربوط به دبی جریان و رسوب معلق ایستگاه‌های هیدرومتری حوزه آبخیز شاهرود، انتخاب

مطالعه در جدول ۱ و نیز خلاصه پارامترهای آماری دبی جریان و رسوب ایستگاه‌های هیدرومتری در جدول ۲ ارائه شده است.

رسوب در دوره آماری از بدو تأسیس تا آخرین سال در دسترس انجام شد. سپس آمار دبی جریان و رسوب معلق لحظه‌ای از نظر کیفیت و درستی مورد بررسی قرار گرفت. مشخصات ایستگاه‌های هیدرومتری مورد

جدول (۱): مشخصات ایستگاه‌های هیدرومتری مورد مطالعه در حوزه آبخیز شاهرود

ردیف	نام ایستگاه	کد ایستگاه	ارتفاع (متر)	مساحت حوزه آبخیز بالادست (کیلومتر مربع)	طول (درجه - دقیقه)	عرض (درجه - دقیقه)
۱	گلینک	۱۷-۰۳۵	۱۷۸۳	۸۰۵	۵۰-۴۴	۳۶-۱۰
۲	باغکلايه	۱۷-۰۳۹	۱۲۷۳	۶۷۸	۵۰-۲۹	۳۶-۲۳
۳	لوشان	۱۷-۰۴۱	۳۳۴	۴۸۶۴	۴۹-۳۰	۳۶-۳۷
۴	رجایی دشت	۱۷-۲۰۱	۹۷۰	۲۴۴۵	۵۰-۱۷	۳۶-۲۷

جدول (۲): خلاصه پارامترهای آماری ایستگاه‌های هیدرومتری مورد مطالعه در حوزه آبخیز شاهرود

ایستگاه	پارامتر	تعداد داده	حداقل	حداکثر	میانگین	انحراف معیار
گلینک	دبی	۷۸۷	۰/۳۲	۱۵۸/۹	۲۰/۰۵	۱۹/۸
	رسوب		۰/۱۷	۱۶۴۲۱۶/۶	۳۷۴۸/۷	۱۱۳۰۳/۳۱
باغکلايه	دبی	۲۸۰	۱/۴	۸۹/۴	۸/۷	۹/۷
	رسوب		۹/۵	۱۲۶۱۸۳/۷	۲۰۷۶/۹	۱۰۵۳۶/۸
لوشان	دبی	۲۰۴۲	۰/۴۱	۴۷۵	۴۴/۴	۴۹/۸
	رسوب		۴/۶	۳۱۴۳۰۵۴/۵	۳۵۱۳۱	۱۴۱۱۴/۹
رجایی دشت	دبی	۳۲۸	۰/۸۶	۲۲۸/۷۶	۲۵/۱	۳۲/۲
	رسوب		۹/۷	۲۸۴۱۲۷/۴	۷۰۶۳/۸	۲۴۱۵۳/۲

لگاریتمی به صورت خط مستقیم است به روش خطی معروف شده است.

$$Q_s = aQ_w^b \quad (1)$$

$$\text{Log} Q_s = \log a + b \log Q_w$$

که در آن:  $Q_s$ : دبی رسوب معلق (تن بر روز) یا غلظت رسوب معلق (میلی‌گرم بر لیتر)،  $Q_w$ : دبی

مدل منحنی سنج رسوب

جهت مدل‌سازی میزان رسوب معلق از مدل منحنی سنج رسوب یک خطی استفاده شد. در این روش معمولاً داده‌های دبی رسوب  $Q_s$  (تن در روز) و دبی جریان  $Q_w$  (مترمکعب بر ثانیه) متناظر آن‌ها به یک محور مختصات تمام لگاریتمی منتقل و بهترین خط برازش (در این تحقیق مدل همبستگی توانی) با استفاده از روش حداقل مربعات از میان ابر نقاط عبور داده می‌شود. از آنجا که این منحنی در محورهای


جریان (مترمکعب بر ثانیه) و  $a$  و  $b$  ضرایب رگرسیون می باشند.

#### مدل شبکه عصبی مصنوعی

در راستای مدل سازی رسوب، از مدل شبکه عصبی مصنوعی نیز بهره گرفته شد. این روش یکی از روش های نوظهور در حل مسائل مهندسی در دو دهه اخیر است. در این شبکه ها، سعی بر آن است که ساختاری مشابه ساختار بیولوژیک مغز انسان و شبکه اعصاب بدن ساخته شود تا همانند مغز قدرت یادگیری، تصمیم دهی و تصمیم گیری داشته باشد (Lee et al., 2006, Ahmat Nor, 2005). هر شبکه عصبی مصنوعی از سه نوع لایه شامل لایه ورودی<sup>۱</sup>، لایه پنهان<sup>۲</sup> و لایه خروجی<sup>۳</sup> تشکیل می شود. تعداد لایه ها و تعداد نرون های موجود در لایه پنهان با نظر طراح و به وسیله سعی و خطا مشخص می شود (Solaimani, 2009). مدل های شبکه عصبی مصنوعی در بسیاری از علوم از جمله مطالعات هیدرولیکی و هیدرولوژیک مثل انتقال رسوب، مدل سازی بارش-رواناب و پیش بینی جریان به کار برده می شوند (Yang et al., 2009). بررسی منابع نشان می دهد که شبکه پرسپترون چندلایه و تابع شعاعی کاربرد گسترده ای در مهندسی آب دارند لذا در این پژوهش مورد بررسی قرار گرفته اند (دهقانی و همکاران، ۱۳۸۸).

#### مدل شبکه عصبی پرسپترون چندلایه (MLP)<sup>۴</sup>

شبکه MLP از چندلایه تشکیل شده است. لایه ورودی، خروجی و لایه یا لایه های مخفی که خروجی لایه اول بردار ورودی لایه دوم به حساب می آید. به همین ترتیب خروجی لایه دوم بردار ورودی لایه سوم را تشکیل می دهد (Chelani et al., 2002). شکل ۲ ساختار یک شبکه پرسپترون چندلایه را نشان می دهد.



شکل (۲): ساختار یک شبکه پرسپترون چندلایه

نرون های موجود در لایه بالا با نرون های موجود در لایه پایین ارتباط دارند. نقش هر نرون، محاسبه مجموع وزن داده شده الگوی ورودی و سپس گذراندن این مجموع از یک تابع به نام تابع انتقال می باشد. تابع انتقال می تواند یک تابع خطی یا غیر خطی باشد. دو نوع از توابع مرسوم در شبکه پرسپترون چند لایه تابع سیگموئید و تانژانت سیگموئید می باشد (Vakil- Baghmishe, 2002).

این شبکه بر مبنای الگوریتم پس انتشار خطا آموزش می بیند. بدین ترتیب که خروجی های واقعی با خروجی های مطلوب مقایسه می شوند و وزن ها به وسیله الگوریتم پس انتشار، به صورت تحت نظارت تنظیم می گردند تا الگوی مناسب بوجود آید. برای الگوی ورودی  $p$  ام، مربع خطای خروجی برای تمامی سلول های لایه خروجی شبکه به صورت زیر در می آید:

$$E_p = \frac{1}{2} (d^p - y^p)^2 = \frac{1}{2} \sum_{j=1}^s (d_j^p - y_j^p)^2 \quad (2)$$

که در آن:  $d_j^p$ : خروجی دلخواه برای  $j$  امین سلول در لایه خروجی و  $y_j^p$ : خروجی واقعی برای  $j$  امین سلول در لایه خروجی،  $y^p$ : بردار خروجی واقعی و  $d^p$ : بردار خروجی دلخواه هستند. مرجع خطای کل  $E$  برای  $P$  الگو به صورت زیر در می آید:

$$E = \sum_{p=1}^P E_p = \frac{1}{2} \sum_{p=1}^P \sum_{j=1}^s (d_j^p - y_j^p)^2 \quad (3)$$

- 1- Input layer
- 2- Hidden layer
- 3- Output layer
- 4- Multilayer perceptron

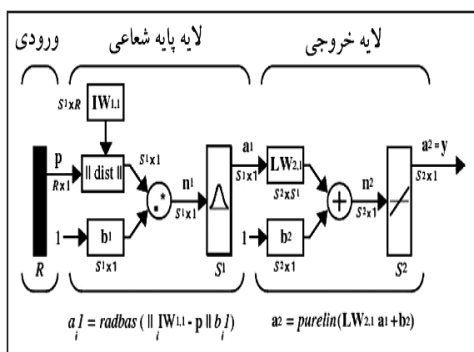
شبکه ضرب برداری می‌شود. سپس این مقادیر توسط توابع مربوط، به تعداد ورودی‌ها نرون ایجاد می‌کند و در نهایت توسط لایه خروجی، مقادیر خروجی شبکه بدست می‌آید (Principe, 2000)، دستورانی و همکاران، ۱۳۹۱). هر یک از گره‌های واقع در لایه پنهان (نرون‌ها) با یک تابع انتقال  $f$  مشخص می‌شوند که سیگنال‌های ورودی را انتقال می‌دهند. برای  $p$  امین الگوی ورودی یعنی  $X^p$ ، پاسخ  $j$  امین گره پنهان یعنی  $y_j$  برابر است با:

$$y_j = f \left\{ \frac{\|X^p - U_j\|}{2\sigma_j^2} \right\} \quad (5)$$

که در آن  $\| \dots \|$  برابر نرم اقلیدسی،  $U_j$  مرکز  $j$  امین تابع با پایه شعاعی و  $\sigma$  گستره RBF که شاخص فاصله شعاعی از مرکز RBF است که در آن مقدار تابع به طور مشخص از صفر متفاوت است. خروجی شبکه با استفاده از مجموع وزن دار خطی پاسخ‌های لایه پنهان در هر یک از گره‌های خروجی بدست می‌آید. خروجی  $k$  امین گره در لایه خروجی  $Z_{pk}$  از رابطه زیر محاسبه می‌شود:

$$Z_{pk} = \sum_{j=1}^L y_j w_{kj} \quad (6)$$

که در آن  $w_{kj}$  وزن پیوند بین گره‌های پنهان و خروجی است. متداول‌ترین تابع RBF تابع گاوسی می‌باشد (Sudheer and Jain, 2003).



شکل (۳): ساختار شبکه های تابع با پایه شعاعی

وزن‌ها با هدف کاهش تابع هزینه  $E$  به مقدار مینیمم به روش گرادیان نزولی تنظیم می‌گردند. معادله به‌روز درآوردن وزن‌ها به صورت زیر است:

(۴)

$$w_{ij(t+1)} = w_{ij}(t) + \eta \Delta w_{ij}(t) + \alpha \Delta w_{ij}(t+1)$$

که در آن  $\eta \Delta w_{ij}(t) = - \left( \frac{\partial E_p}{\partial w_{ij}(t)} \right)$  ضریب یادگیری،  $\alpha$  ضریب لحظه‌ای،  $w_{ij}(t+1)$  وزن جدید و  $w_{ij}(t)$  وزن قبلی می‌باشد. همچنین در این روش، وزن‌ها به طور مکرر برای تمامی الگوهای یادگیری به‌روز درآوردن می‌شوند. روند یادگیری هنگامی متوقف می‌شود که مجموع کل خطا  $E$ ، برای  $p$  الگو از مقدار آستانه تعیین شده کمتر شود یا تعداد کل دوره تعلیم به پایان برسد (منهاج، ۱۳۹۳).

روش تابع پایه شعاعی<sup>۱</sup> شبکه‌های RBF برای آموزش، نیاز به تعداد نرون‌های زیادی دارند. در این شبکه‌ها بر خلاف شیوه رایج در شبکه‌های دیگر، به تمام فضای ورودی به طور یکسان پاسخ داده نمی‌شود. در اینجا ابتدا مرکز فضای ورودی محاسبه شده و سپس به ورودی‌هایی که به اندازه کافی به این مرکز نزدیک باشند پاسخ داده می‌شود. به ورودی‌ها به صورت محلی پاسخ می‌دهند. شبکه‌های RBF دارای دو لایه هستند که لایه اول آن‌ها از نوع پایه شعاعی بوده و لایه خروجی آن‌ها از نوع خطی است (شکل ۳). فرایند آموزش نیز در اینجا توسط روش‌های یادگیری رقابتی<sup>۲</sup> یا روش خوشه‌ابزاری  $k$ <sup>۳</sup> انجام می‌گیرد. پارامترهای شبکه در اینجا شامل دو پارامتر عدد گسترش<sup>۴</sup> و عدد هدف<sup>۵</sup> است. با تغییر این پارامترها می‌توان عملکرد شبکه را بهبود بخشید. در این بخش پس از اعمال ورودی‌ها به شبکه، فاصله برداری بین بردارهای ورودی و بردارهای وزن محاسبه شده و مقادیر به دست آمده در مقادیر بایاس

<sup>۱</sup> - Radial Basis Function  
<sup>۲</sup> - Competitive Learning  
<sup>۳</sup> - k Means Clustering  
<sup>۴</sup> - Spread Number  
<sup>۵</sup> - Goal Number

$$RMSE = \left[ \frac{\sum_{i=1}^n (Q_i^o - Q_i^e)^2}{N} \right]^{0.5} \quad (7)$$

$$NSE = 1 - \left[ \frac{\sum_{i=1}^n (Q_i^o - Q_i^e)^2}{\sum_{i=1}^n (Q_i^o - Q^{mean})^2} \right] \quad (8)$$

که در آن:  $Q_i^o$ :  $i$  امین مقدار مشاهده‌ای دبی رسوب (تن در روز)،  $Q_i^e$ :  $i$  امین مقدار برآوردی دبی رسوب (تن در روز)،  $Q^{mean}$ : میانگین دبی رسوب مشاهده‌ای (تن در روز) و  $N$ : تعداد مشاهدات است.

#### نتایج و بحث

نتایج حاصل از شبیه‌سازی میزان رسوب معلق با استفاده از روش منحنی سنج رسوب در شکل‌های ۴ تا ۷ ارائه شده است.

در این پژوهش ۸۰ درصد داده‌ها جهت آموزش شبکه و ۲۰ درصد باقیمانده داده‌ها جهت آزمون کارایی شبکه بکار گرفته شد (Sepahvand et al., 2013). تفکیک داده‌ها بر اساس انحراف معیار و میانگین مشابه با توجه به اینکه به طور معمول شبکه عصبی در محدوده داده‌های مورد بهره‌گیری برای آموزش قادر به پیش‌بینی بوده و توان پیش‌بینی آن برای محدوده‌های خارج از آموزش ضعیف می‌باشد. بنابراین در صورت وجود اختلاف زیاد دامنه تغییرات داده‌های آزمون با داده‌های آموزش، پیش‌بینی ضعیف خواهد بود (سلاجقه و همکاران، ۱۳۸۸). لذا بدین منظور برای گزینش داده‌های آموزش و آزمون سعی شد داده‌ها طوری گزینش شود که تا حد امکان از نظر معیارهای آماری میانگین و انحراف معیار همانند یکدیگر باشند.

پس از استانداردسازی داده‌ها در محیط نرم افزاری Excel که اعداد بین ۰ و ۱ برده می‌شوند، اقدام به طراحی شبکه عصبی در محیط نرم‌افزار Matlab نسخه 2013a گردید. جهت رسیدن به ساختار مناسب شبکه عصبی مصنوعی، مدل‌های مختلف با تعداد لایه مخفی و تعداد گره‌های مختلف طراحی و به روش سعی و خطا آزمون گردید و نتایج مربوطه مورد مقایسه قرار گرفت (Beale and Jackson, 1990).

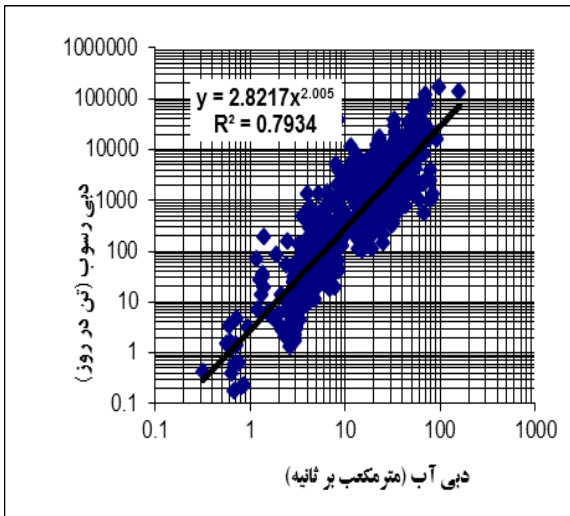
ارزیابی مدل و انتخاب مدل بهینه

جهت ارزیابی مدل‌ها از دو معیار جذر میانگین مربعات خطا<sup>۱</sup> (RMSE) و ضریب ناش-ساتکلیف<sup>۲</sup> (NSE) استفاده شد. مقدار جذر میانگین مربعات خطا همواره مثبت است و هر چه به صفر نزدیک‌تر باشد نشان دهنده عملکرد بهتر مدل است. مقدار ضریب ناش-ساتکلیف بین منفی بی‌نهایت و ۱ متغیر است. اگر مقدار آن برابر با ۱ شود تطابق کامل بین دبی‌های مشاهده‌ای و برآوردی برقرار می‌باشد.


1- Root Mean Square Error

2- Nash-Sutcliffe efficiency coefficient






شکل (۵): منحنی سنجه رسوب یک خطی ایستگاه گلینیک




شکل (۴): منحنی سنجه رسوب یک خطی ایستگاه باغکلایه



شکل (۷): منحنی سنجه رسوب یک خطی ایستگاه رجایی

دشت

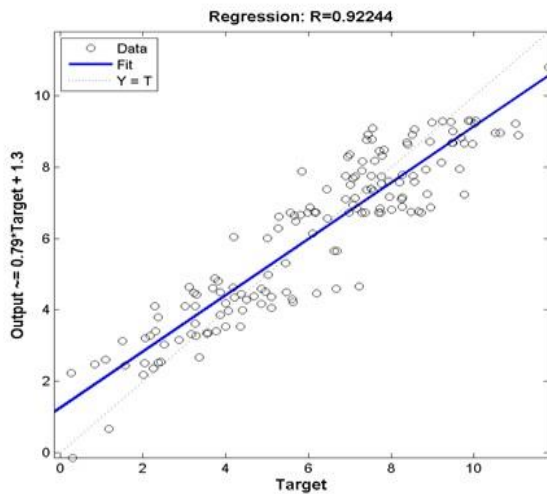


شکل (۶): منحنی سنجه رسوب یک خطی ایستگاه لوشان

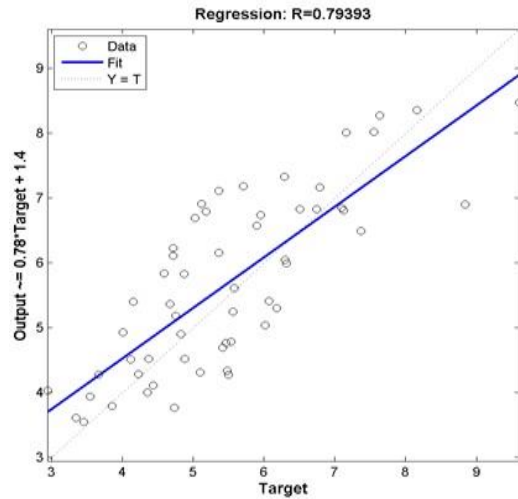
نتایج حاصل از ارزیابی مدل‌های منحنی سنجه رسوب و مدل‌های شبکه عصبی پرسپترون چندلایه (با دو تابع تحریک سیگموئید و تانژانت سیگموئید) و روش تابع پایه شعاعی در جدول ۳ ارائه شده است. همچنین شکل‌های ۸ تا ۱۱ همبستگی مقادیر مشاهداتی و شبیه‌سازی شده برآورد بار معلق را در مرحله آزمون نشان می‌دهند.

جدول (۳): نتایج ارزیابی مدل‌های منحنی سنجه رسوب و شبکه عصبی مصنوعی (برای داده‌های آموزش و آزمون)


نام ایستگاه		گلینک		باغکلابه		لوشان		رجایی دشت	
معیار ارزیابی		NASH	RMSE	NASH	RMSE	NASH	RMSE	NASH	RMSE
		تن در روز		تن در روز		تن در روز		تن در روز	
مدل منحنی سنجه رسوب									
۹ نرون		۰/۷۹۳	۱/۱۴۸	۰/۹۹۶	۰/۶۵۷	۱/۰۰۲	۰/۸۴۹	۰/۹۶۲	۰/۸۲
۱۱ نرون		۰/۸۲۹	۱/۱۲۲	۰/۹۳۶	۰/۶۷۷	۰/۹۴۸	۰/۸۶۶	۰/۷۱۱	۰/۸۶۱
۱۳ نرون		۰/۸۱۳	۱/۱۶۶	۰/۹۰۰	۰/۶۷۰	۰/۹۵۰	۰/۸۶۳	۰/۷۶۵	۰/۸۴۶
مدل شبکه عصبی مصنوعی (مرحله آموزش)									
۹ نرون		۰/۸۲۲	۱/۱۰۵	۰/۹۱۱	۰/۶۹۰	۰/۹۵۳	۰/۸۶۵	۰/۷۳۱	۰/۸۵۲
۱۱ نرون		۰/۸۱۴	۱/۱۴۰	۰/۹۴۶	۰/۶۹۶	۰/۹۷۳	۰/۸۵۴	۰/۷۳۷	۰/۸۵۷
۱۳ نرون		۰/۸۳۳	۱/۰۷۵	۰/۹۲۳	۰/۶۴۸	۰/۹۴۹	۰/۸۶۲	۰/۷۱۴	۰/۸۵۴
تابع سیگموئید		۰/۸۲۳	۱/۱۲۱	۰/۸۳۵	۰/۷۰۵	۰/۹۵۲	۰/۸۶۴	۰/۷۴۸	۰/۸۵۸
تابع RBF		۰/۸۳۵	۱/۰۴۲	۰/۹۷۸	۰/۶۶۲	۰/۹۵۴	۰/۸۶۳	۰/۸۹۰	۰/۸۵۱
مدل شبکه عصبی مصنوعی (مرحله آزمون)									
۹ نرون		۰/۷۹۲	۱/۱۵۰	۰/۸۵۴	۰/۶۸۳	۰/۹۷۲	۰/۸۵۲	۰/۹۵۲	۰/۸۰۹
۱۱ نرون		۰/۸۴۶	۱/۰۳۳	۱/۰۳۶	۰/۶۸۹	۰/۹۶۳	۰/۸۶۶	۰/۸۲۵	۰/۸۳۹
۱۳ نرون		۰/۶۹۲	۲/۰۹۲	۰/۹۰۶	۰/۶۴۶	۰/۹۳۱	۰/۸۶۴	۰/۹۹۴	۰/۸۳۰
۹ نرون		۰/۸۳۰	۱/۱۹۶	۰/۷۹۹	۰/۷۷۲	۰/۸۸۳	۰/۸۹۵	۱/۰۲۵	۰/۷۹۲
۱۱ نرون		۰/۶۹۱	۱/۸۴۲	۰/۹۱۱	۰/۵۷۵	۰/۹۷۱	۰/۸۶۸	۰/۹۶۷	۰/۸۳۸
۱۳ نرون		۰/۸۲۲	۱/۱۵۲	۱/۱۴۳	۰/۶۰۸	۰/۹۳۷	۰/۸۶۷	۰/۹۵۳	۰/۷۸۹
تابع سیگموئید		۰/۸۲۲	۱/۱۵۲	۱/۱۴۳	۰/۶۰۸	۰/۹۳۷	۰/۸۶۷	۰/۹۵۳	۰/۷۸۹
تابع RBF		۰/۷۶۹	۱/۱۴۹	۰/۸۴۴	۰/۷۶۲	۰/۹۲۸	۰/۸۶۴	۰/۸۵۲	۰/۸۲۴



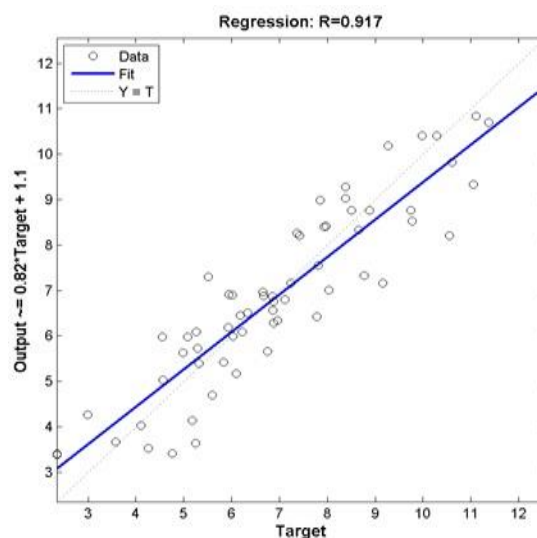
شکل (۹): تابع سیگموئید ۱۱ نرون ایستگاه گلینک



شکل (۸): تابع تانژانت سیگموئید ۹ نرون ایستگاه باغکلابه



شکل (۱۱): تابع تانژانت سیگموئید ۹ نرون ایستگاه لوشان



شکل (۱۰): تابع سیگموئید ۱۱ نرون رجایی دشت

همچنین در مقایسه مدل RBF نسبت به مدل بهینه MLP میزان ضریب NASH به ترتیب در ایستگاه هیدرومتری گلینک، باغکلاویه، لوشان و رجایی دشت از ۰/۷۶۹ به ۰/۸۴۶، ۰/۷۶۲ به ۰/۷۷۲، ۰/۸۶۴ به ۰/۸۹۵ و ۰/۸۲۴ به ۰/۸۳۹ افزایش و ضریب RMSE این ایستگاه‌ها از ۱/۱۴۹ به ۱/۰۳۳، ۰/۸۴۴ به ۰/۷۹۹، ۰/۹۲۸ به ۰/۸۸۳ و ۰/۸۵۲ به ۰/۸۲۵ تن در روز کاهش یافته است. نتایج این بخش تحقیق با نتایج تحقیقات فلامکی (۱۳۹۲) و Safari et al. (2016) هم‌خوانی دارد.

همچنین نتایج پژوهش حاضر نشان داد که تعداد نرون توابع سیگموئید و تانژانت سیگموئید در دقت شبیه‌سازی رسوب معلق حوضه با روش شبکه عصبی پرسپترون چند لایه موثر بود. به این ترتیب که بهترین شبیه‌سازی از تابع سیگموئید با تعداد ۱۱ نرون در ایستگاه‌های هیدرومتری گلینک و رجایی دشت و تابع تانژانت سیگموئید با تعداد ۹ نرون در ایستگاه‌های هیدرومتری باغکلاویه و لوشان بدست آمد. در این راستا، دهقانی و همکاران (۱۳۸۸) نیز در مقایسه تخمین بار معلق به دو مدل منحنی سنج رسوب و شبکه عصبی مصنوعی با استفاده از روش پرسپترون چند لایه با تابع محرک سیگموئید و تانژانت سیگموئید و تعداد نرون‌های مختلف در لایه میانی و نیز روش منحنی سنج یک خطی به این نتیجه رسیدند که تابع محرک تانژانت سیگموئید با ۹ نرون بهترین جواب را ارائه نموده و

نتایج حاصل از این پژوهش حاکی از آن است که مدل شبکه عصبی مصنوعی پرسپترون چندلایه در مقایسه با روش منحنی سنج رسوب و مدل شبکه عصبی پایه شعاعی در تمامی ایستگاه‌های هیدرومتری مورد مطالعه کارایی بهتری در برآورد رسوب معلق دارد. در این رابطه در مقایسه مدل منحنی سنج رسوب با مدل بهینه شبکه عصبی مصنوعی میزان ضریب NASH در ایستگاه‌های هیدرومتری گلینک از ۰/۷۹۳ به ۰/۸۴۶، باغکلاویه از ۰/۶۵۷ به ۰/۷۷۲، لوشان از ۰/۸۴۹ به ۰/۸۹۵ و رجایی دشت از ۰/۸۲ به ۰/۸۳۹ افزایش و ضریب RMSE در این ایستگاه هیدرومتری گلینک از ۱/۱۴۸ به ۱/۰۳۳، باغکلاویه از ۰/۹۹۶ به ۰/۷۹۹، لوشان از ۱/۰۰۲ به ۰/۸۸۳ و رجایی دشت از ۰/۹۶۲ به ۰/۸۲۵ تن در روز کاهش یافته است. نتایج این پژوهش با یافته‌های دهقانی و همکاران (۱۳۸۸) در رودخانه دوغ استان گلستان، معیری و همکاران (۱۳۸۹) در حوضه آبی‌چای (ایستگاه ونیاری)، ولی و همکاران (۱۳۹۰) در حوضه آبریز زاینده‌رود، دستورانی و همکاران (۱۳۹۱) در حوضه آبخیز جامیشان (ایستگاه هیدرومتری حیدرآباد)، یوسفی و برزگری (۱۳۹۴) در ایستگاه‌های هیدرومتری استان لرستان، Cigizoglu and Alp (2006) در حوضه رودخانه جونیاتا ایالات متحده، Cigizoglu and Kisi (2007) در حوضه رودخانه لی و Safari et al. (2016) در شرایط آزمایشگاهی هم‌خوانی و هم‌سویی داشت.

دقت نتایج به دست آمده از مدل شبکه عصبی مصنوعی به مراتب از دقت مدل منحنی بالاتر است.

### نتیجه گیری

هدف از تحقیق حاضر، مقایسه کارایی مدل‌های شبکه عصبی مصنوعی (MLP و RBF) و مدل‌های منحنی سنجه سوب در مدل‌سازی میزان رسوب معلق در ایستگاه‌های هیدرومتری حوضه شاهرود می‌باشد. با توجه به نتایج این تحقیق می‌توان گفت که با توجه به رفتار غیرخطی پارامترهای هیدرولوژیکی، استفاده از روش‌های کلاسیک مانند منحنی سنجه رسوب از دقت کافی برخوردار نیستند. اصولاً از آنجا که در پیش‌بینی رسوب معلق رودخانه‌ها عوامل متعددی دخالت دارند و همچنین به علت ماهیت پیچیده آن، شبیه‌سازی و پیش‌بینی این پدیده دشوار می‌باشد. از آنجا که تکنیک‌های شبکه عصبی

مصنوعی برای تحلیل مسائلی به کامی‌روند که شناخت و توصیف صریح و دقیقی از ماهیت مساله وجود ندارد بنابراین بسیاری از مسائل مربوط به رسوبات معلق رودخانه‌ها را با این تکنیک‌ها می‌توان حل نمود. نتایج حاصل از تحقیق حاضر نیز حاکی از آن است که استفاده از مدل شبکه عصبی مصنوعی می‌تواند به عنوان ابزاری توانمند در مدل‌سازی پارامترهای هیدرولوژیکی پیچیده مانند رسوب بکار گرفته شود. همچنین مقایسه نتایج حاصل از دو مدل شبکه عصبی مصنوعی در ایستگاه‌های هیدرومتری مورد بررسی نشان داد که شبکه‌های MLP در مقایسه با شبکه‌های RBF از دقت و کارایی بیشتری در شبیه‌سازی میزان رسوب معلق برخوردارند. البته شایان ذکر است تنها مزیت شبکه‌های RBF زمان کمتر مورد نیاز برای آموزش است.

### منابع

- آوریده، ف.، م. بنی حبیب و ا. ط. شمسی. ۱۳۸۰. کاربرد شبکه‌های عصبی مصنوعی جهت تخمین دبی رسوب رودخانه‌ها. سومین کنفرانس هیدرولیک ایران، دانشگاه تهران.
- ابراهیمی محمدی، ش.، س. ح. ر. صادقی و ک. چپی. ۱۳۹۱. تحلیل آورد رواناب، رسوب معلق و مواد مغذی ورودی‌های مختلف به دریاچه زریوار در پایه زمانی رگبار و آب پایه. حفاظت منابع آب و خاک، سال دوم، شماره ۱، ص ۷۵-۶۱.
- امجدی، ن. ۱۳۸۱. آشنایی با سیستم‌های هوشمند، انتشارات دانشگاه سمنان، ۳۰۰ ص.
- دستورانی، م. ت.، خ. عظیمی فشی، ع. طالبی، و م. ر. اختصاصی. ۱۳۹۱. برآورد رسوبات معلق با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: حوزه آبخیز جامیشان استان کرمانشاه). پژوهشنامه مدیریت حوزه آبخیز، سال سوم، شماره ۶، ص ۷۴-۶۱.
- دهقانی، ا.، م. ا.، زنگانه، ا. مساعدی، و ن. کوهستانی. ۱۳۸۸. مقایسه تخمین بار معلق به دو روش منحنی سنجه رسوب و شبکه عصبی مصنوعی. مجله علوم کشاورزی و منابع طبیعی گرگان، شماره ۱۶، ص ۲۶۶-۲۷۶.
- سلاجقه، ع.، ا. فتح آبادی. ۱۳۸۸. بررسی امکان برآورد بار معلق رودخانه کرج با بهره‌گیری از منطق فازی و شبکه عصبی. نشریه مرتع و آبخیزداری، مجله منابع طبیعی ایران، دوره ۶۲، شماره ۲، ص ۲۸۲-۲۷۱.
- شاهرخی، س. ح.، ج.، ظهیری، ا. جعفری، ۱۳۹۵. کاربرد الگوریتم درختی M5 در برآورد رسوب معلق رودخانه‌ها. فصلنامه علمی پژوهشی مهندسی آبیاری و آب، سال ششم، شماره ۲۴، ص ۲۸-۱۶.
- صدر موسوی، م. س. و ا. رحیمی. ۱۳۸۹. مقایسه نتایج شبکه‌های عصبی پرسپترون چند لایه با رگرسیون چندگانه در پیش‌بینی غلظت ازن در شهر تبریز. پژوهش‌های جغرافیای طبیعی، شماره ۷۱، ص ۷۲-۶۵.
- عرب خدری، م. ۱۳۸۸. برآورد رسوبدهی و تهیه نقشه تولید رسوب برای ایران. طرح تحقیقاتی پژوهشکده حفاظت خاک و آبخیزداری (کد طرح ۱۷۰۰۰۹۳۱۷۰۵۱۰۷۴۰۵۱)، ۱۵۵ ص.
- فلامکی، ا.، اسکندری، م.، بغلانی، ع. ا. و س. ا. احمدی. ۱۳۹۲. مدل‌سازی بار رسوب کل رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی. نشریه حفاظت منابع آب و خاک، سال دوم، شماره ۳، ص ۲۵-۱۳.

- معیری، م. م.، ر.، نیک پور، ع. حسین زاده دلیر، و د. فرسادی زاده. ۱۳۸۹. مقایسه روش های شبکه های عصبی مصنوعی، فازی- عصبی تطبیقی و منحنی سنج رسوب در برآورد رسوبات معلق رودخانه ها (مطالعه موردی: رودخانه آجی چای). دانش آب و خاک (دانش کشاورزی)، دوره ۲۰/۱، شماره ۲، ص ۸۳-۷۱.
- ملکی نژاد، ح. و ر. پورشرعیاتی. ۱۳۹۲. کاربرد و مقایسه مدل سری زمانی تجمعی و مدل شبکه عصبی مصنوعی در پیش بینی تغییرات سطح آب زیرزمینی. علوم و مهندسی آبیاری (مجله علمی کشاورزی)، جلد ۳۶، شماره ۳، ص ۹۲-۸۱.
- منهاج، م. ب. ۱۳۹۳. مبانی شبکه های عصبی (هوش محاسباتی)، انتشارات دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران)، تهران، چاپ پنجم، ۷۱۶ ص.
- ولی، ع.، ح.، رامشت، مع. سیف، و ر. قضاوی. ۱۳۹۰. مقایسه کارآیی مدل های شبکه های عصبی مصنوعی و رگرسیون برای پیش بینی بار رسوب جریان مطالعه موردی حوضه آبخیز سمندگان. مجله جغرافیا و برنامه ریزی محیطی، دوره بیست و دوم، شماره ۴، ص ۳۴-۱۹.
- یوسفی، م. و ر. پورشرعیاتی. ۱۳۹۳. برآورد رسوب معلق با استفاده از شبکه عصبی و ارزیابی توابع آموزشی (مطالعه موردی: استان لرستان). پژوهشنامه مدیریت حوزه آبخیز، سال پنجم، شماره ۱، ص ۹۷-۸۵.
- یوسفی، م. و ف. برزگری. ۱۳۹۴. تعیین مناسب ترین روش منحنی سنج و مقایسه آن با شبکه عصبی مصنوعی به منظور برآورد رسوبات معلق (مطالعه موردی استان لرستان). مرتع و آبخیزداری، دوره ۶۸، شماره ۲، ص ۴۱۳-۴۲۶.
- Ahmat Nor, N. I. B. 2005. Rainfall-runoff Modelling using Artificial Neural Networks Method. PhD. Thesis, College of Civil Eng, Malaysia Technology University, Johor, Malaysia.
- Beale, R. and T. Jackson. 1990. Neural Computing: An Introduction. Department of Computer Science, University of York. IOP Publishing Ltd. .223p.
- Bissonnais, Y. L., C. Monitor, M. Jamagne, J. Daroussin and D. King. 2001. Mapping erosion risk for cultivated soil in France. Catena, 46: 207-220.
- Chelani, A.B., R.C.V. Chalapati, K.M. Phadke and M.Z. Hasan. 2002. Prediction of sulphur dioxide concentration using artificial neural networks. Environmental Modelling & Software, 17: 161-168.
- Cigizoglu, H. K. and O. Kisi. 2007. Methods to improve the neural network performance in suspended sediment estimation. Journal of Hydrology, 317: 221-238.
- Cigizoglu, H.K. and M. Alp. 2006. Generalized regression neural network in modeling river sediment yield. J. Advance in Engineering software, 37: 63-68.
- Demuth, H., M. Beal and M. Hagan. 1992-2009, Neural Network Toolbox 6 (Users Guide). The Math Works.
- Heng, S. and T. Suetsugi. 2013. Using artificial neural network to estimate sediment load in ungauged catchments, Cambodia. Journal of Water Resource and Protection, 5: 111-123.
- Jansson, M.B. 1996. Estimating a sediment rating curve of the Reventazón river at Palomo using logged mean loads within discharge classes. Journal of Hydrology, 183 (3-4): 227-241.
- Kisi, O. and J. Shiri. 2012. River suspended sediment estimation by climatic variables implication: comparative study among soft computing techniques. Computers & Geosciences, 43: 73-82.
- Kumar, D., A. Pandey, N. Sharm and F. Wolfgang-Albert. 2016. Daily suspended sediment simulation using machine learning approach. Catena, 138: 77-90.
- Lee, S., J. H. Ryu, M. J. Lee and J. S. Won. 2006. The application of artificial neural networks to landslide susceptibility mapping at Janghung, Korea. Mathematical Geol, 38(2): 199-220.
- Martinez, J. A., M. Cancepcion and M. Ribes-Dasi. 2005. On site effects of concentrated flow erosion in vineyard fields. Some economic implications, Cotena, 60:129-146.
- Mustafa, M. R., M. H. Isa and R. B. Rezaur. 2011. A Comparison of Artificial Neural Networks for Prediction of Suspended Sediment Discharge in River, A Case Study in Malaysia. World Academy of Sci., Eng. And Technol.(WASET), 81: 372-376.
- Principe, J. C. 2000, Artificial neural networks. CRC Press LLC. University of Florida, ch. 20.
- Ramos, M. C. and J. A. Martinez-Casasnovas. 2006. Erosion rates and nutrient losses affected by computed cattle manure application in vineyard soil of NE Spain. catena, 68: 177-185.

Rezapour, O. M., L. T. Shui and D. B. Ahmad. 2010. Review of artificial neural network model for suspended sediment estimation. Australian Journal of Basic and Applied Sciences, 4 (8): 3347-3353.

Safari, M-J., H. Aksoy and M. Mohammadi. 2016. Artificial neural network and regression models for flow velocity at sediment incipient deposition. Journal of Hydrology, In Press, doi: <http://dx.doi.org/10.1016/j.jhydrol.2016.08.045>

Sepahvand, A., N. Hezarkhani, M. Taei Semiromi and S.H. Asgari. 2013. Comparing the empirical equations of runoff- sediment resulted from sediment rating curves and artificial neural network (Case study: Ghadarkhosh watershed, Ilam province). Scientific - Research Quarterly On Environmental Erosion Researches, 7: 52-69.

Solaimani, K. 2009. Rainfall-runoff prediction based on artificial neural network. Am. – Eur. J. Agric. and Environ. Sci, 5(6): 856-865.

Sudheer, K. P. and Jain, S. K. 2003. Radial basis function neural network for modeling rating curves. J Hydrol Engin ASCE 8 (3): 161-164.

Vafakhah, M. 2012. Comparison of cokriging and adaptive neuro-fuzzy inference system models for suspended sediment load forecasting. Arab. J. Geosci. 2: 201-211.

Vakil-Baghmisheh, M. T. 2002. Fari character recognition using artificial neural networks, Ph.D. Thesis, Faculty of Electrical Engineering, University of Ljubljana, Slovenia. 185pp.

Yang, C. T., R. Marsooli and M. T. Aalami. 2009. Evaluation of total load sediment transport formulas using ANN. Intl. J. Sediment Res, 24(3): 274-286.

## Comparison on artificial neural network and sediment rating curve models for simulating of suspended sediment load; case study Shahrood watershed

S. Mohamadi<sup>1</sup>

### Abstract

This research was conducted to compare the efficiency of some simulation models including sediment rating curves and artificial neural networks for simulating the suspended sediment load amount. Optimized model basis of flow discharge in Shahrood watershed upon the hydrometric stations including Glinak, Baghkalaye, Loshan and Rajayi dasht was represented. In order to simulate the suspended sediment load we compared one linear rating curve and artificial neural network with multi-layer perceptron and radial base function models. Then performance evaluation these models was carried out by NASH and RMSE criteria. The results showed that artificial neural network with multi-layer perceptron method in comparison on sediment rating curve model in all of these stations simulated better models. So that artificial neural network with sigmoid triggering function in Glinak and Rajayi dasht stations with RMSE as 1.033 and 0.825 ton/day and NASH as 0.84 and 0.839 and this model with tansigmoid triggering function in Baghkalaye and Loshan stations with RMSE as 0.799 and 0.883 ton/day and NASH as 0.772 and 0.895, respectively, have the better efficiency for simulating of suspended sediment load amount. Also comparison of two neural network models showed that MLP model is better than RBF model for simulating of suspended sediment load amount. The only benefit of RBF networks is less time needed for training.

**Key words:** Multi-Layer Perceptron, Radial Base Function, Shahrood, NASH coefficient, Sediment rating curve.

---

<sup>1</sup> Department of Ecology, Institute of Science and High Technology and Environmental Sciences, Graduate University of Advanced Technology, Kerman, Iran. (Corresponding author; email: mohamadisedigeh@gmail.com)