

شبیه‌سازی بار رسوب معلق با استفاده از روش‌های شبکه عصبی مصنوعی، عصبی-فازی و منحنی سنجه رسوب در حوزه آبخیز هلیل‌رود

صدیقه محمدی*

^۱ استادیار، گروه اکولوژی، پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان

تاریخ پذیرش: ۱۳۹۶/۰۶/۲۷

تاریخ دریافت: ۱۳۹۵/۱۲/۰۴

چکیده

در کشورهای در حال توسعه، به‌علت مشکلات مالی و فنی به‌طور معمول داده‌های رسوب اندکی اندازه‌گیری می‌شوند، لذا، مدلی که بتواند با استفاده از داده‌های دبی آب، میزان بار رسوبی را برآورد کند، می‌تواند گزینه قابل اطمینانی باشد. با توجه به کاربرد انواع مدل‌ها در پیش‌بینی رسوب، این تحقیق با هدف ارائه مدل بهینه برآورد میزان رسوب معلق بر اساس دبی جریان بر روی ایستگاه‌های هیدرومتری بالادست رودخانه هلیل‌رود شامل ایستگاه‌های هیدرومتری پل بافت، سلطانی، هنجان، چشمه عروس، میدان و کناروئیه انجام شد. در این راستا، کارایی انواع مدل‌های مختلف منحنی سنجه رسوب شامل مدل‌های یک خطی، دو خطی، روش حد وسط دسته‌ها به تنهایی و نیز با ضرایب اصلاحی CF_1 ، CF_2 و FAO و مدل‌های جعبه سیاه شامل شبکه عصبی مصنوعی و سامانه استنتاج عصبی-فازی در شبیه‌سازی رسوب معلق مورد ارزیابی قرار گرفتند. نتایج حاصل از ارزیابی این مدل‌ها با استفاده از پارامترهای ارزیابی MAE و RMSE با استفاده از داده‌های آزمون، حاکی از آن است که مدل‌های عصبی-فازی در عمده ایستگاه‌های هیدرومتری مورد مطالعه، شامل پل بافت، هنجان و کناروئیه با میزان MAE برابر ۰/۷۳۵، ۱۱۹۵۸/۷۴ و ۳۴۲۳۵/۲۷ و RMSE به ترتیب برابر ۰/۷۴۲، ۲۸۶۷۲/۷۸ و ۵۲۷۳۵/۹۲ تن در روز به‌عنوان بهترین روش برای شبیه‌سازی میزان بار رسوب معلق به‌شمار می‌آیند. همچنین، مدل شبکه عصبی مصنوعی تابع پایه شعاعی در ایستگاه هیدرومتری میدان با میزان MAE برابر ۰/۸۳۴ و RMSE برابر ۶۶۹ تن در روز، روش منحنی سنجه رسوب دو خطی در ایستگاه چشمه عروس با میزان MAE و RMSE به ترتیب ۱/۷ و ۴/۱ تن در روز و روش منحنی سنجه یک خطی با اعمال ضریب اصلاحی CF_1 با MAE و RMSE برابر ۹۷۲۳/۲ و ۴۱۲۳۵/۶ تن در روز در ایستگاه هیدرومتری سلطانی به‌عنوان بهترین مدل‌ها برای شبیه‌سازی میزان رسوب معلق می‌باشند.

واژه‌های کلیدی: ایستگاه هیدرومتری، تابع پایه شعاعی، حد وسط دسته‌ها، رسوب معلق، مدل‌های جعبه سیاه

مقدمه

ناشی از فرسایش خاک اراضی بالادست، فرسایش کناری و بستر رودخانه می‌باشد (Pohlert, ۲۰۱۵). این امر موجب هدررفت خاک فوقانی حاصل‌خیز و تحویل میلیون‌ها تن رسوب به مخازن و دریاچه‌ها و در نتیجه اثرات مخرب زیست‌محیطی و تحمیل هزینه‌های

فرسایش خاک، یکی از مهمترین معضلات زیست‌محیطی در جهان است (Heathcote و همکاران، ۲۰۱۳؛ Ali و همکاران، ۲۰۱۱؛ Lal, ۱۹۹۸). رسوب محصول نهایی فرسایش در یک حوزه آبخیز است که

* مسئول مکاتبات: mohamadisedigeh@gmail.com

منطق فازی نیز مانند هوش مصنوعی نوعی جعبه سیاه است و بر مبنای قوانین تعریف شده، عمل شبیه‌سازی را انجام می‌دهد (Saeed Nia و Shabani Nia، ۲۰۰۶). در این روش، محقق قادر است با تعریف قوانینی در گرفتن خروجی داده‌ها دخالت داشته باشد.

کمی‌سازی تلفات خاک یکی از بزرگ‌ترین چالش‌های موجود برنامه‌ریزی‌های منابع طبیعی و محیط زیست است. در داخل و خارج از کشور، مطالعات متعددی در مورد مدل‌سازی رسوب معلق انجام شده است. به‌طوری که Mustafa و همکاران (۲۰۱۱) به مقایسه دقت دو مدل شبکه عصبی مصنوعی MLFF و RBF در برآورد بار معلق پرداختند. نتایج تحقیقات ایشان نشان داد که هر دو مدل از قابلیت مناسبی برخوردار هستند. اما مدل RBF نتایج نسبتاً بهتری را در شبیه‌سازی دبی رسوب معلق ارائه می‌دهد. Kisi و Shiri (۲۰۱۲) از روش‌های شبکه عصبی مصنوعی، عصبی-فازی و برنامه‌نویسی ژنتیکی (GP) برای تخمین میزان غلظت رسوب معلق روزانه (SSC) در رودخانه Eel کالیفرنیا استفاده کردند. نتایج این تحقیق نشان داد که روش GP نتایج بهتری در مقایسه با دو روش دیگر دارد.

هر چند که روش شبکه عصبی نیز نتایج رضایت‌بخشی را با میزان ضریب تبیین $0/82$ تا $0/95$ به‌دست داد. Vafakhah (۲۰۱۲) به مقایسه چهار روش شبکه عصبی مصنوعی، نروفازی، کریجینگ و کوکریجینگ، به‌منظور تخمین بار معلق رسوب پرداخت. نتایج نشان داد که از روش‌های فوق به‌ترتیب نروفازی، شبکه عصبی، کوکریجینگ و کریجینگ دارای بیشترین کمترین دقت تخمین بار معلق رسوب می‌باشند. Heng و Suetsugi (۲۰۱۳) از شبکه‌های عصبی مصنوعی برای تخمین میزان رسوب معلق حوضه‌های فاقد ایستگاه رسوب‌سنجی حوزه آبخیز رودخانه Tonle Sap کامبوج استفاده کردند. نتایج حاصل از شبیه‌سازی با شبکه عصبی بسیار رضایت‌بخش بوده، به‌طوری که میزان I^2 از $0/81$ تا $0/94$ و در مرحله اعتبارسنجی از $0/63$ تا $0/87$ بود. Tahmores و همکاران (۲۰۱۵) به مدل‌سازی رسوب معلق رودخانه دالکی با استفاده از روش‌های شبکه عصبی مصنوعی، عصبی فازی و منحنی سنجه پرداختند و دریافتند که

اقتصادی هنگفت با تأثیر بر تولیدات کشاورزی، زیرساخت‌ها و کیفیت آب می‌شود (Pimentel و همکاران، ۱۹۹۵؛ Lal، ۱۹۹۸).

به‌علت پاره‌ای از مسائل و مشکلات مالی و فنی، اندازه‌گیری دقیق بار رسوبی در کشورهای در حال توسعه مانند ایران، مسئله بسیار سختی است و فقط به‌طور معمول داده‌های رسوب اندکی در طول ماه اندازه‌گیری می‌شوند. در چنین وضعیتی، مدلی که بتواند با استفاده از داده‌های دبی آب، میزان بار رسوبی را برآورد کند، گزینه قابل اطمینانی است (Nourani، ۲۰۰۹). مدل‌های شبیه‌سازی کامپیوتری در پیش‌بینی تلفات خاک و تولید رسوب، به‌طور فزاینده‌ای در حال توسعه هستند (Bhuyan و همکاران، ۲۰۰۲). 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 درازمدت رسوب، دسترسی به داده‌های قابل اعتماد رسوب مشکل بوده و لزوم استفاده از روش‌های برآورد و تخمین رسوب را مطرح می‌سازد (Dehghani و همکاران، ۲۰۰۹). یافتن روش‌هایی برای برآورد علمی و دقیق تولید رسوب در حوضه‌های کشور، امری ضروری برای کنترل این فرایند است. از آن‌جا که مسئله تولید رسوب در حوضه، یک مسئله بسیار پیچیده است و عوامل مختلف اکولوژیکی و محیطی بر آن موثرند، می‌توان بیان کرد که روابط متغیرها در این پدیده از روابط ریاضی پیروی نمی‌کنند و این روابط بسیار پیچیده‌اند (Yosefi، ۲۰۱۴). لذا، بهره جستن از انواع مختلف مدل‌ها برای پیش‌بینی میزان رسوب معلق، مانند روش‌های منحنی سنج رسوب، روش‌های شبکه عصبی و عصبی-فازی و مقایسه این روش‌ها برای ارائه مدلی بهینه و دقیق در پیش‌بینی میزان رسوب معلق، ضروری به نظر می‌رسد.

در این رابطه، روش‌های رگرسیونی روابط بین متغیرها را بر اساس روش‌های آماری و ریاضی می‌سنجند (Farshadfar، ۲۰۰۵). انواع روش‌های شبکه عصبی که نوعی جعبه سیاه است، بر اساس الگوبرداری از هوش انسان، بدون ارائه رابطه بین متغیرها، عمل شبیه‌سازی را انجام می‌دهند (Alborzi، ۲۰۰۷).

مواد و روش‌ها

حوزه آبخیز هلیل‌رود با مساحتی بالغ بر ۱/۶ میلیون هکتار در محدوده بین 28° تا 58° عرض شمالی و 29° تا 56° طول شرقی در جنوب شرقی ایران قرار دارد. برای انجام این تحقیق، پس از جمع‌آوری آمار و اطلاعات مربوط به دبی جریان و رسوب معلق ایستگاه‌های هیدرومتری حوزه آبخیز هلیل‌رود، انتخاب ایستگاه‌ها با توجه به موقعیت پراکنش آن‌ها در سطح حوضه و کامل بودن آمار هم‌زمان دبی و رسوب انجام و برخی ایستگاه‌های هیدرومتری واقع در بالادست این حوضه (بالادست سد جیرفت) انتخاب شدند. شکل ۱، موقعیت حوزه آبخیز مورد مطالعه در کشور و استان و نیز موقعیت ایستگاه‌ها در سطح حوضه و جدول ۱، مشخصات ایستگاه‌های مورد مطالعه را نشان می‌دهد.

خلاصه مشخصات آماری ایستگاه‌های هیدرومتری مورد مطالعه در جدول ۲ ارائه شده است. همان‌طور که در جدول ملاحظه می‌شود، بیشترین میزان دبی جریان و رسوب در ایستگاه هیدرومتری کناروئیه و کمترین میزان در ایستگاه هیدرومتری چشمه عروس است.

پس از جمع‌آوری داده‌ها و تهیه بانک داده مدل - سازی رسوب معلق انجام و در این راستا به شرح ذیل اقدام شد.

۱- مدل‌سازی رسوب معلق با روش منحنی سنجه رسوب: انواع روش‌های منحنی سنجه که در این تحقیق مورد ارزیابی قرار گرفت به شرح زیر هستند.

۱-۱- روش یک خطی: در این روش، معمولاً داده‌های دبی رسوب Q_s (یا غلظت رسوب معلق به میلی-گرم بر لیتر) و دبی جریان Q_w (دبی لحظه‌ای به متر مکعب بر ثانیه) متناظر آن‌ها به یک محور مختصات تمام لگاریتمی منتقل و بهترین خط برازش از میان ابر نقاط عبور داده می‌شود.

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

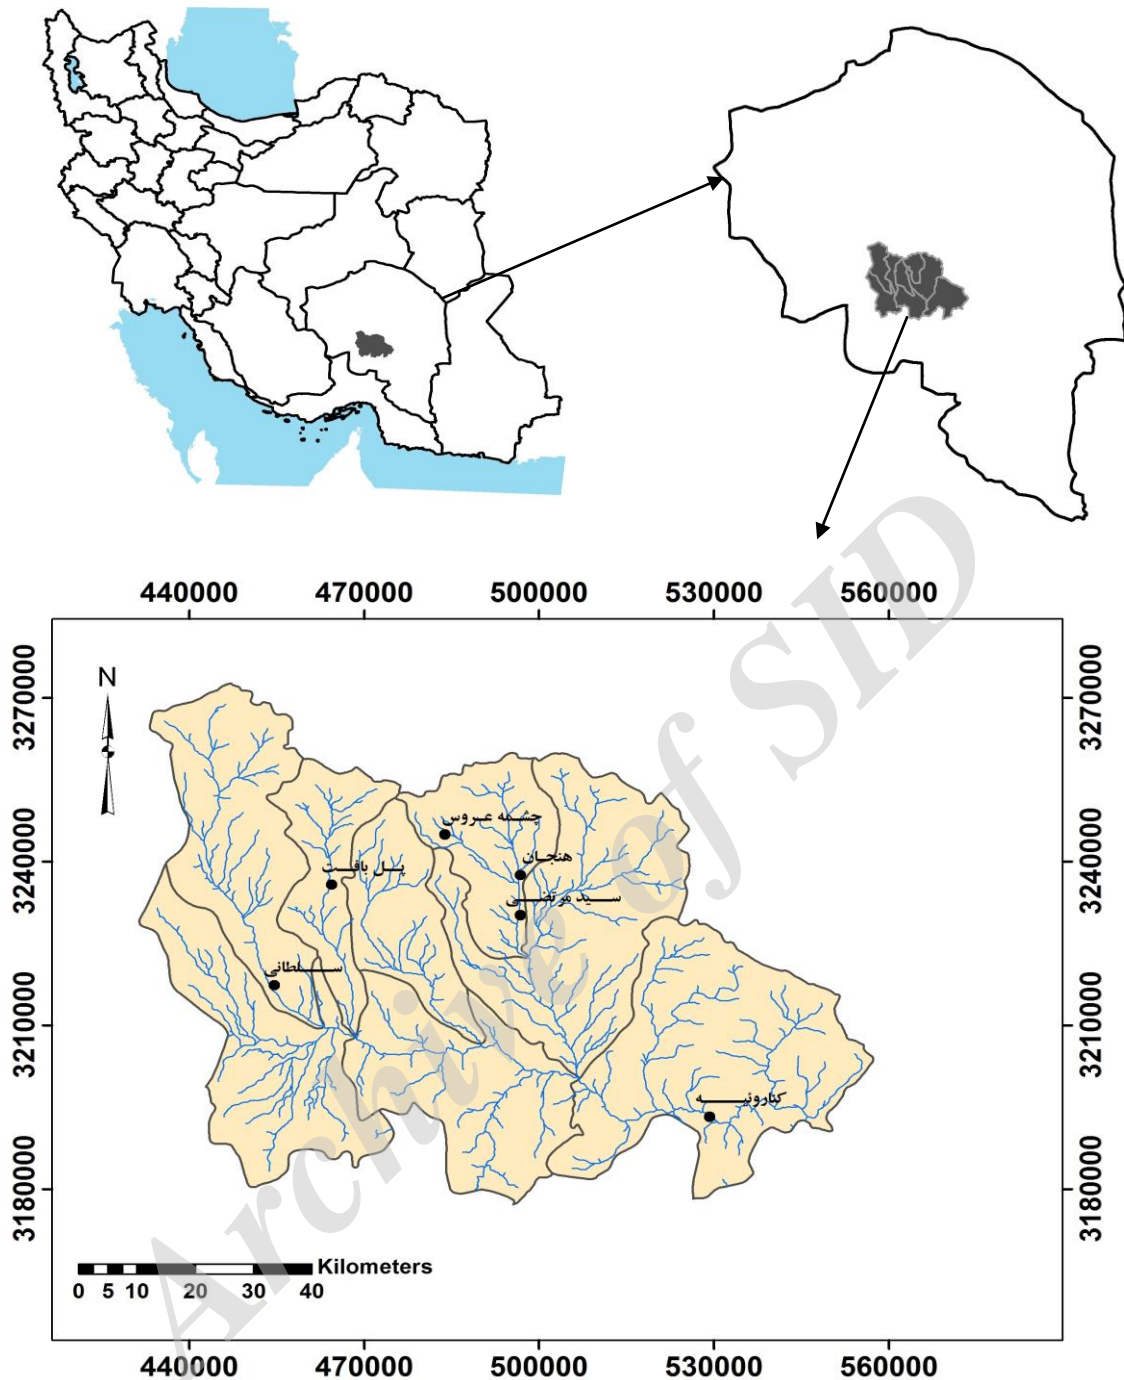
$$\log Q_s = \log a + b \log Q_w \quad (2)$$

که در آن، Q_s دبی رسوب معلق (تن در روز)، Q_w دبی آب (متر مکعب بر ثانیه) و a و b ضرایب رگرسیون می‌باشند. در این تحقیق از معادله (۱) که متداول‌تر است (Asselman, ۲۰۰۰)، استفاده شد.

مدل‌های عصبی فازی در مقایسه با سایر مدل‌ها کارایی بهتری در شبیه‌سازی رسوب معلق دارد. Falamaki و همکاران (۲۰۱۳) برای مدل‌سازی بار رسوب کل رودخانه‌ها از شبکه‌های عصبی مصنوعی بهره جستند. نتایج این پژوهش نشان داد که مدل‌های ارائه شده بر پایه شبکه‌های عصبی با مقادیر رسوب کل مشاهده شده هم‌خوانی بیشتری دارند، به‌ویژه شبکه MLP می‌تواند مقدار رسوب را در نقاط پیک به خوبی برآورد کند. Barzegari و همکاران (۲۰۱۵) به پیش‌بینی بار معلق رودخانه با استفاده از مدل‌های سری زمانی و شبکه عصبی مصنوعی در ایستگاه قزاقلی رودخانه گرگان‌رود پرداختند. نتایج تحقیقات ایشان نشان داد که مدل‌های شبکه عصبی مصنوعی در مقایسه با مدل‌های سری‌های زمانی نتایج بهتری در شبیه‌سازی رسوب معلق دارند.

در تحقیقی، Zoratipour (۲۰۱۶) اقدام به پیش-بینی رسوب معلق حوزه آبخیز طالقان با مقایسه کارایی روش‌های نروفازی، شبکه عصبی مصنوعی و مدل‌های آماری کرد و به کارایی روش عصبی فازی نسبت به روش‌های دیگر دست یافت. Mohamadi (۲۰۱۷) به مقایسه مدل‌های شبکه عصبی مصنوعی (شامل شبکه‌های MLP و RBF) و منحنی سنجه رسوب در شبیه‌سازی رسوب معلق حوزه آبخیز شاهرود پرداخت. نتایج حاصل از تحقیق ایشان حاکی از کارایی بهتر مدل‌های شبکه عصبی مصنوعی (بالاخص شبکه‌های MLP) نسبت به منحنی سنجه رسوب است.

جمع‌بندی بررسی منابع نشان می‌دهد که روش‌های رگرسیونی استاتیک از دقت بالایی برای برآورد دبی بار معلق رسوبات برخوردار نیستند. بنابراین، در این پژوهش از روش‌های شبکه عصبی مصنوعی و عصبی-فازی با در نظر گرفتن دبی جریان به‌عنوان متغیر موثر با هدف ارائه مدل بهینه پیش‌بینی میزان رسوب معلق، استفاده شد. به‌طوری که کارایی انواع مدل‌های مختلف منحنی سنجه رسوب یک خطی، دو خطی و روش حد وسط دسته‌ها، مدل‌های شبکه عصبی مصنوعی و عصبی-فازی در شبیه‌سازی رسوب معلق مورد ارزیابی و مقایسه قرار گرفت.



شکل ۱- موقعیت ایستگاه‌های هیدرومتری مورد مطالعه در حوزه آبخیز هلیل رود

جدول ۱- مشخصات ایستگاه‌های هیدرومتری مورد بررسی

شماره	نام ایستگاه	نام رودخانه	کد ایستگاه	طول	عرض	ارتفاع
۱	پل بافت	بافت	۴۴-۰۰۱	۵۶° ۳۸'	۲۹° ۱۵'	۲۲۰۰
۲	سلطانی	هلیل	۴۴-۰۰۳	۵۶° ۳۲'	۲۹° ۰۵'	۲۰۰۰
۳	هنگان	رودر	۴۴-۰۵۳	۵۶° ۵۸'	۲۹° ۱۶'	۲۱۵۰
۴	چشمه عروس	رابر	۴۴-۱۰۵	۵۶° ۵۰'	۲۹° ۲۰'	۲۲۵۰
۵	میدان	سیدمرتضی	۴۴-۱۱۱	۵۶° ۵۸'	۲۹° ۱۲'	۲۰۵۰
۶	کناروئیه	هلیل	۴۴-۱۱۵	۵۷° ۱۸'	۲۸° ۵۲'	۱۳۴۰

جدول ۲- خلاصه پارامترهای آماری ایستگاه‌های هیدرومتری مورد مطالعه در حوزه آبخیز هلیل‌رود

ایستگاه	پارامتر	کمینه	بیشینه	میانگین	انحراف معیار
پل بافت	دبی (m^3s^{-1})	۰/۰۱	۱۲/۵	۱/۰۱	۲/۱۶
	دبی رسوب ($tonday^{-1}$)	۰/۰۲	۳۹۵۰/۳	۱۵۳/۱	۵۲۳/۲
سلطانی	دبی (m^3s^{-1})	۰/۰۲	۱۱۲	۶/۲۷	۱۷/۱۶
	دبی رسوب ($tonday^{-1}$)	۰/۰۳	۴۱۱۳۹۹	۱۶۶۸۰/۹	۶۹۳۰۲/۹
هنجان	دبی (m^3s^{-1})	۰/۱۲	۵۴/۹	۴/۸۵	۱۱/۷
	دبی رسوب ($tonday^{-1}$)	۰/۲۶	۱۸۲۴۱۶۸	۸۴۶۰۱	۳۵۴۵۷۲
چشمه عروس	دبی (m^3s^{-1})	۰/۰۲	۲/۸۱	۰/۵۶	۰/۸۳
	دبی رسوب ($tonday^{-1}$)	۰/۰۴	۵۸/۳	۶/۱۴	۱۳/۱
میدان	دبی (m^3s^{-1})	۰/۰۰۴	۳۸/۶	۳/۶۸	۷/۱۸
	دبی رسوب ($tonday^{-1}$)	۰/۰۱	۳۰۱۸۹/۲۴	۱۶۵۳/۲۸	۵۵۲۹/۶
کناروئیه	دبی (m^3s^{-1})	۰/۳۵	۱۵۹/۶	۲۲/۴۴	۳۲/۶۶
	دبی رسوب ($tonday^{-1}$)	۲۳/۱۶	۹۸۶۴۲۵/۱۲	۱۱۳۶۶۳/۱۳	۲۱۸۶۷۱/۸

۲-۱- روش دو خطی: در این حالت با توجه به وضعیت پراکنش نقاط، مجموعه نقاط به دو دسته تقسیم و به هر یک خط مستقیم جداگانه‌ای برازش داده شد.

۳-۱- روش حد وسط دسته‌ها: این روش به‌وسیله Jansson (۱۹۹۶) ارائه شد. در این روش، دبی‌های جریان با یک نمو معین به تعدادی دسته تقسیم شده، برای دبی متوسط هر دسته، دبی رسوب متوسط اندازه‌گیری شده همان دسته تعیین می‌شود. در این روش، ارزش بیشتری به دبی‌های سیلابی که مسئول حمل قسمت اعظم رسوب هستند، داده می‌شود و چون میزان خطای ناشی از تبدیل لگاریتمی به تعداد و پراکنش نقاط در نمودار منحنی سنج رسوب بستگی دارد و از آنجا که در روش همبستگی بین متوسط دسته‌ها، تعداد نقاط به کمینه می‌رسد، بنابراین، خطای ناشی از تبدیل لگاریتمی تا حدود زیادی کاهش می‌یابد (Jansson, ۱۹۹۶).

$$Q_s = \alpha Q_w^b \quad (3)$$

عامل اصلاحی α از رابطه زیر به دست می‌آید.

$$\alpha = \frac{\bar{Q}_s}{\bar{Q}_w^b} \quad (4)$$

که در آن، \bar{Q}_s میانگین دبی‌های رسوب نمونه-های مشاهده‌ای (تن در روز) و \bar{Q}_w میانگین دبی جریان نمونه‌های مشاهده‌ای (متر مکعب بر ثانیه) است.

۲-۲- ضریب اصلاحی QMLE: این روش که به نام روش پارامتری (CF_1) نیز گزارش شده، از یک ضریب تصحیح بر اساس مجذور خطای استاندارد باقی‌مانده رگرسیون برای اصلاح خطای ناشی از تبدیل لگاریتمی داده‌ها که موجب برآورد کم منحنی سنج رسوب

۲-۲- مدل‌سازی رسوب معلق با روش منحنی سنج رسوب با اعمال ضرایب اصلاحی: پس از تهیه منحنی‌های سنج رسوب انواع تصحیحات با استفاده از سه عامل اصلاحی (معادله‌های

۲-۲- مدل‌سازی رسوب معلق با روش منحنی سنج رسوب با اعمال ضرایب اصلاحی: پس از تهیه منحنی‌های سنج رسوب انواع تصحیحات با استفاده از سه عامل اصلاحی (معادله‌های

۲-۲- مدل‌سازی رسوب معلق با روش منحنی سنج رسوب با اعمال ضرایب اصلاحی: پس از تهیه منحنی‌های سنج رسوب انواع تصحیحات با استفاده از سه عامل اصلاحی (معادله‌های

Q_e دبی رسوب برآوردی (تن در روز) و n تعداد نمونه‌های مشاهده‌ای است.

۳- شبیه‌سازی رسوب با استفاده از شبکه عصبی مصنوعی: روشی که اخیراً مورد توجه کارشناسان قرار گرفته، استفاده از شبکه‌های عصبی مصنوعی برای شبیه‌سازی رابطه دبی آب و رسوب می‌باشد. در این زمینه، مدل‌های ریاضی و فرمول‌های تجربی به‌ترتیب به‌دلیل پیچیدگی و نیاز به انواع مختلفی از پارامترهای موثر در انتقال رسوب موفقیت‌چندانی حاصل نکرده‌اند. شبکه‌های عصبی مصنوعی به‌عنوان عضوی از خانواده هوش مصنوعی در تعیین بار معلق رسوب توانا به نظر می‌رسند. این روش‌ها با الهام از مغز انسان در یادگیری دستیابی به دانش نهفته در داده‌ها، روابط موجود بین داده‌ها را به‌دست آورده، 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 می‌شوند (Heng و Suteski، ۲۰۱۳). مدل‌های شبکه عصبی مصنوعی در مطالعات هیدرولیکی و هیدرولوژیک نظیر انتقال رسوب، شبیه‌سازی بارش-رواناب، پیش‌بینی جریان و رسوب به‌کار می‌روند (Yang و همکاران، ۲۰۰۹). شکل ۲، ساختار یک شبکه عصبی مصنوعی را نشان می‌دهد.

می‌شود، استفاده می‌کند و معادله آن به شکل زیر است (Iadanza و Napolitano، ۲۰۰۶).

$$CF_1 = EXP[2.65S^2] \quad (5)$$

که در آن، e تابع نمایی برابر 2.718 و S^2 خطای استاندارد (مجذور میانگین) معادله رگرسیون در لگاریتم با مبنای ۱۰ است که از رابطه زیر به‌دست می‌آید.

$$S^2 = \frac{\sum (\log Q_o - \log Q_e)^2}{n-2} \quad (6)$$


که در آن، Q_o دبی رسوب مشاهده‌ای (تن در روز)، Q_e دبی رسوب برآوردی (تن در روز) و n تعداد نمونه‌های مشاهده‌ای است.

۲-۳- ضریب اصلاحی غیرپارامتری: روش اصلاح-گر به‌وسیله Duan (۱۹۸۳) در مورد برازش جذر مربع و یا جذر مکعب داده‌ها استفاده می‌شود. این روش با رد توزیع نرمال خطاهای باقی‌مانده، برای حذف آریبی داده‌ها ارائه شده، شکل کلی معادله آن به‌صورت زیر است (Varvani و همکاران، ۲۰۰۸).

$$CF_2 = \frac{1}{n} \sum 10^{a_i} \quad (7)$$

$$a_i = \log Q_o - \log Q_e \quad (8)$$

که در آن، a_i باقی‌مانده کمینه مربعات مدل رگرسیونی، Q_o دبی رسوب مشاهده‌ای (تن در روز)،



شکل ۲- ساختار یک شبکه عصبی مصنوعی

شعاعی کمک گرفته شد. در مدل پرسپترون چند لایه از نوع پیشرو (Feed Forward) با الگوریتم آموزشی

برای دستیابی به ساختار مناسب شبکه عصبی مصنوعی، از دو ساختار پرسپترون چند لایه و تابع پایه

برای استفاده از ANFIS، دو روش خوشه‌بندی مبتنی بر تقسیم‌بندی جدولی (Grid partitioning) و خوشه‌بندی تفاضلی-کاهشی (Sub-clusterpartitioning) وجود دارند. در روش خوشه‌بندی مبتنی بر تقسیم‌بندی جدولی داده‌های ورودی به چند بخش برابر تقسیم می‌شوند. در این حالت، با افزایش شمار بخش‌ها، شمار مشخصه‌ها به‌طور توانی افزایش پیدا کرده، به‌طوری که در زمانی که شمار ورودی‌ها زیاد باشند، فرایند آموزش طول می‌کشد. در خوشه‌بندی تفاضلی-کاهشی، داده‌های ورودی به اندازه شعاع تأثیر به چند دسته تقسیم می‌شوند که در این حالت، شمار مشخصه‌های خطی و غیرخطی به‌طور قابل ملاحظه‌ای کاهش پیدا کرده، این امر باعث آسانی فرایند آموزش می‌شود. در این حالت، نوع تابع عضویت با توجه به اطلاعات ورودی و دسته‌بندی‌های موجود، به‌وسیله خود مدل تعیین می‌شود. در روش خوشه‌بندی مبتنی بر تقسیم‌بندی جدولی توابع عضویت ورودی مثلثی (Triangle) و گوسی (Gaussian) به‌دلیل کاربرد وسیع آن‌ها مورد استفاده قرار گرفت و روش‌های آموزش پس انتشار خطا (Backpropa) و روش ترکیبی (Hybrid) مورد آزمون واقع شد (Saeed Nia و Shabani Nia، ۲۰۰۶). لازم به ذکر است که در این تحقیق، ۷۰ درصد داده‌ها برای آموزش مدل‌ها استفاده شد و ۳۰ درصد باقی‌مانده داده‌ها که برای آزمون کارایی به‌کار گرفته شد، وارد فرایند آموزش نشد (Sepahvand، ۲۰۱۳). با توجه به این‌که به‌طور معمول شبکه عصبی در محدوده داده‌های مورد بهره‌گیری برای آموزش قادر به پیش‌بینی است 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 (Fathabadi و Salajeghe، ۲۰۰۹). لذا، بدین منظور برای گزینش داده‌های آموزش و آزمون سعی شد، تا داده‌ها طوری گزینش شود که تا حد امکان از نظر معیارهای آماری میانگین و انحراف معیار همانند یکدیگر باشند. به‌دلیل پراکنش زیاد داده‌ها از رابطه

TRAINLM و تابع یادگیری تطبیقی LEARNGMD، الگوریتم خطایابی انتشار برگشتی (Back Propagation) و تابع بهینه‌سازی لوبنرگ-مارکواردت به‌دلیل سرعت بالا (با نرخ یادگیری ۰/۰۰۱) استفاده شد (Menhaj، ۲۰۰۲). در این ساختار سه رویه تابع محرک تانژانت سیگموئید (tansig)، لوگ سیگموئید (logsig) و خطی (purelin) بررسی شد و تعداد لایه مخفی و تعداد گره‌های مختلف در هر لایه به روش سعی و خطا آزمون شد (Alborzi، ۲۰۰۷). در ساختار پایه شعاعی پس از اعمال ورودی‌ها به شبکه، فاصله برداری بین بردارهای ورودی و بردارهای وزن محاسبه شده، مقادیر به‌دست آمده در مقادیر بایاس شبکه ضرب برداری می‌شود. سپس، این مقادیر به‌وسیله توابع مربوط، به تعداد ورودی‌ها نورون ایجاد می‌کند و در نهایت به‌وسیله لایه خروجی، مقادیر خروجی شبکه به‌دست می‌آید که در این رابطه خروجی k امین گره در لایه خروجی یعنی Z_{pk} از رابطه زیر محاسبه می‌شود.

$$Z_{pk} = \sum_{i=1}^l y_i w_{kj} \quad (9)$$

که در آن، y_i پاسخ i امین گره پنهان و w_{kj} وزن پیوند بین گره‌های خروجی و لایه پنهان است.

۴- شبیه‌سازی رسوب با استفاده از مدل عصبی-فازی^۱ (ANFIS): سامانه استنتاج تطبیقی فازی-عصبی اولین‌بار در سال ۱۹۹۳ به‌وسیله Jang معرفی شد. این روش از ترکیب دو ساختار شبکه‌های عصبی و سامانه‌های فازی تشکیل شده است که در این ساختار از مزایای هر دو شبکه‌های عصبی و سامانه‌های فازی بهره‌گیری شده است. به این معنی که از خصوصیت آموزش‌پذیری شبکه‌های عصبی و همچنین، از توانایی مدل‌سازی استنتاج سامانه‌های فازی (ANFIS) که باعث افزایش قدرت تصمیم‌گیری در شرایط عدم قطعیت و افزایش دقت یقینی می‌شود، در ساختار شبکه عصبی-فازی تطبیقی استفاده شده است. شکل ۳، ساختار یک سامانه عصبی-فازی را نشان می‌دهد.

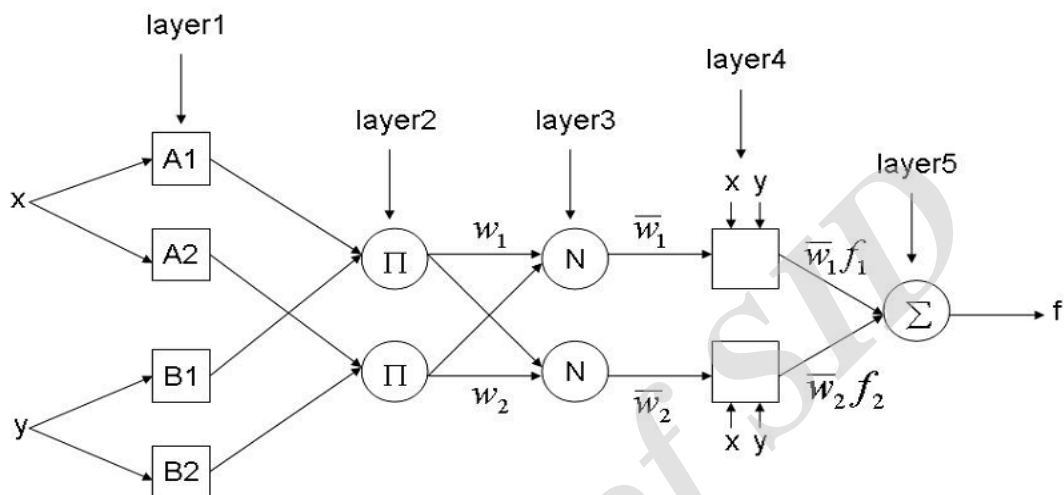
¹ adaptive neuro-fuzzy inference system

داده از مجموعه داده‌ها می‌باشد. با بهره‌گیری از این رابطه، داده‌ها نرمال‌سازی شدند. سپس، اقدام به طراحی شبکه عصبی مصنوعی، فازی و همچنین، عصبی-فازی در محیط نرم‌افزار Matlab نسخه 2013a شد.

(Y) برای نرمال‌سازی داده‌ها در بازه 0/1 تا 0/9 بهره گرفته شد.

$$y = 0.8 \times \frac{X_1 - X_{\min}}{X_{\max} - X_{\min}} + 0.1 \quad (7)$$

که در آن، y مقدار نرمال شده داده، X_1 مقدار واقعی داده، X_{\min} کوچک‌ترین داده و X_{\max} بزرگ‌ترین



شکل ۳- شمای سامانه استنتاج عصبی-فازی

میانگین دبی مشاهده‌ای رسوب و N تعداد مشاهدات است.

نتایج و بحث

نتایج حاصل از شبیه‌سازی به روش منحنی سنج رسوب و نیز تعیین ضرایب اصلاحی در جدول ۳ ارائه شده است.

نتایج ارزیابی روش‌های منحنی سنج رسوب در مرحله آزمون با استفاده از سه پارامتر RMSE، MAE و PBIAS در جدول ۴ ارائه شده است.

مشخصات شبکه‌های عصبی به کار رفته در مدل-ساز رسوب ایستگاه‌های هیدرومتری مورد مطالعه در جدول ۵ ارائه شده است.

مشخصات مدل نروفازی برای مدل‌سازی رسوب معلق و نیز نتایج ارزیابی آن‌ها در ایستگاه‌های هیدرومتری مورد مطالعه در جدول ۶ ارائه شده است.

۵- ارزیابی مدل‌ها و انتخاب مدل بهینه: برای ارزیابی مدل‌ها از سه معیار جذر میانگین مربعات خطا RMSE، ضریب MAE و درصد بایاس PBIAS استفاده شد.

- معیار جذر میانگین مربعات خطا (Root Mean Square Error)

$$RMSE = \left[\frac{\sum_{i=1}^n (Q_i^e - Q_i^o)^2}{N} \right]^{0.5} \quad (8)$$

- ضریب میانگین مطلق خطا (دقت) (Mean Absolute Error)

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_i^e - Q_i^o| \quad (9)$$

- درصد بایاس (Percent Bias) PBIAS

$$PBIAS = \frac{\sum (Q_i^e - Q_i^o)}{\sum Q_i^o} \times 100 \quad (10)$$

که در آن، Q_i^o نامین مقدار مشاهده‌ای دبی رسوب، Q_i^e نامین مقدار برآوردی دبی رسوب، Q^{mean}

جدول ۳- نتایج مدل‌سازی با استفاده از روش منحنی سنج رسوب و میزان ضرایب اصلاحی روش‌های یک خطی، دو خطی و حد وسط دسته‌ها

FAO	CF ₂	CF ₁	R ²	معادله	مدل	ایستگاه
۵/۰۵	۱/۲۲	۱/۲۴	۰/۹۶	$Y = 31.19x^{1.665}$	یک خطی	پل بافت
			۰/۹۶	$Y = 7.52x^{1.19}$	دوخطی	
			۰/۸۹	$Y = 44.34x^{1.82}$		
۸/۶۰	۱۸/۶۲	۱/۲۴	۰/۹۱	$Y = 16.37x^{2.38}$	حد وسط دسته	
۳۵/۱۵	۲/۲۸	۲/۷۵	۰/۹۰	$Y = 14.11x^{1.87}$	یک خطی	سلطانی
			۰/۶۵	$Y = 4.18x^{1.29}$	دوخطی	
			۰/۸۶	$Y = 2.95x^{2.69}$		
۲۵/۱۳	۴۹/۲۰	۲/۷۵	۰/۹۳	$Y = 4.01x^{2.7}$	حد وسط دسته	
۲۱۹/۵۶	۲/۳۰	۱/۸۰	۰/۹۲	$Y = 11.59x^{2.22}$	یک خطی	هنجان
			۰/۹۲	$Y = 7.27x^{1.61}$	دوخطی	
			۰/۹۷	$Y = 0.46x^{3.7}$		
۵۶۶/۹۶	۶۱۲/۱۱	۱/۸۰	۰/۹۹	$Y = 0.31x^{3.92}$	حد وسط دسته	چشمه عروس
			۰/۹۶	$Y = 6.29x^{1.5}$	یک خطی	
			۰/۸۸	$Y = 3.09x^{1.24}$	دوخطی	
۴/۶۰	۹/۱۸	۱/۱۴	۰/۹۷	$Y = 5.21x^{2.25}$	حد وسط دسته	میدان
			۰/۹۱	$Y = 19x^{1.65}$	یک خطی	
			۰/۸۹	$Y = 10.89x^{1.36}$	دوخطی	
۱۰/۳۶	۱/۷۹	۱/۹۵	۰/۸۸	$Y = 27.78x^{2.016}$	دوخطی	میدان
			۰/۹۷	$Y = 9.03x^{2.45}$	حد وسط دسته	
			۰/۹۸	$Y = 297.33x^{1.73}$	یک خطی	
۷/۰۱	۵۹/۶۳	۱/۹۵	۰/۹۸	$Y = 384.35x^{2.44}$	دوخطی	کناروئیه
			۰/۹۷	$Y = 356.69x^{1.67}$	دوخطی	
			۰/۹۸	$Y = 430.16x^{1.61}$	حد وسط دسته	
۱/۶۶	۱/۰۵	۱/۰۶	۰/۹۸			
۱/۷۱	۰/۹۷	۱/۰۶	۰/۹۸			

می‌توان چنین نتیجه گرفت که شرایط محلی منطقه بالادست ایستگاه، ویژگی‌های مورفولوژیکی کانال رودخانه و نیز جامعه آماری که با توجه به آن نمونه‌برداری انجام شده و در نهایت منحنی سنج رسوب بر اساس آن نمونه‌ها به دست می‌آید، تأثیر زیادی در دقت منحنی‌های مذکور و انتخاب روش مناسب دارد. لازم به ذکر است که طبق نتایج این تحقیق، ضرایب اصلاحی CF₁ و CF₂ در برخی ایستگاه‌ها به دلیل جبران کم‌تخمینی روش‌های منحنی سنج، موجب افزایش کارایی مدل می‌شوند. هرچند که نمی‌توان این ضرایب را به‌عنوان یک قاعده کلی در

طبق نتایج جدول ۴، در بین مدل‌های نه‌گانه منحنی سنج رسوب مورد مطالعه، روش منحنی سنج یک خطی با ضرایب اصلاحی CF₁ در ایستگاه هیدرومتری پل بافت و سلطانی، روش منحنی سنج دو خطی در ایستگاه هیدرومتری چشمه عروس و میدان، روش حد وسط دسته‌ها در ایستگاه هیدرومتری هنجان و این روش با اعمال ضرایب اصلاحی CF₂ در ایستگاه هیدرومتری کناروئیه به‌عنوان بهترین مدل برای شبیه‌سازی میزان رسوب معلق هستند.

بنابراین، اگر روش مناسب برازش منحنی سنج به درستی تعیین نشود، منجر به برآورد کم یا زیاد رسوب حوضه از آنچه هست خواهد شد. لذا، پیشنهاد می‌شود در انجام پروژه‌های اجرایی قبل از هر اقدامی راجع به استفاده از منحنی سنج به انتخاب بهترین روش برازش آن اقدام شود تا با استفاده از آن به برآورد نسبتاً صحیحی از میزان تولید رسوب آن حوضه نائل شد.

تمام ایستگاه‌ها پیشنهاد کرد و روش مناسب هر ایستگاه منحصر به فرد تعیین می‌شود. تحقیقات محققینی چون de Vente و Poesen (۲۰۰۵)، Nadal-Romero و همکاران (۲۰۰۸)، Walling و Kane (۱۹۸۲)، Milliman و همکاران (۱۹۸۳)، Le و همکاران (۲۰۰۷) و Wilkinson و همکاران (۲۰۰۹) نیز حاکی از تأیید تغییرپذیری مکانی خصوصیات منحنی سنج رسوب و رابطه دبی با رسوب است.

جدول ۴- نتایج ارزیابی مدل‌های منحنی سنج رسوب در ایستگاه‌های هیدرومتری مورد مطالعه

ایستگاه هیدرومتری							مدل
کناروئیه	میدان	چشمه عروس	هنجان	سلطانی	پل یافت	پارامتر ارزیابی	
۵۱۰۸۹/۶	۱۲۶۰/۳	۲	۸۰۵۸۱/۷	۱۴۰۷۷/۳	۶۴/۴	MAE (تن در روز)	یک خطی
۱۷۱۲۶۵/۲	۴۳۵۸/۸	۵/۵	۳۴۲۳۸۰/۱	۵۹۶۰۹/۸	۲۲۰/۲	RMSE (تن در روز)	
۲۳/۱۵	-۷۵/۲۹	-۲۸/۴۵	-۹۵/۰۵	-۸۳/۹۷	۵۹/۰۸	PBIAS(%)	
۴۲۸۶۶/۷	۶۸۹/۷	۱/۷	۲۳۷۶۲/۱	۱۰۸۴۷/۶	۵۰/۹	MAE	دو خطی
۱۲۹۱۰۶/۳	۲۴۹۴/۵	۴/۱	۹۶۳۶۵/۸	۶۱۶۳۳/۸	۱۹۸/۴	RMSE	
۱۱/۶۷	۱۰/۲۹	۰/۳۱	-۲۷/۹۸	-۵۵/۸۸	۱۲۴/۴۳	PBIAS	
۳۷۱۳۶/۸	۱۳۹۴	۱/۸	۱۲۰۹۷/۱	۱۲۰۰۲/۲	۱۱۷	MAE	حد وسط
۱۰۱۸۳۷/۴	۶۸۰۷/۳	۴/۴	۵۰۴۵۱/۴	۷۹۰۳۶/۲	۵۰۵/۸	RMSE	
۴/۰۴	۵۷/۲۳	۲/۱۴	۳/۶۲	۴۰/۶۷	۱۲۱/۱۵	PBIAS	
۵۴۳۹۷/۷	۹۲۳/۶	۱/۷	۷۷۴۶۹/۵	۹۷۲۳/۲	۴۵/۴	MAE	CF1
۱۹۰۵۹۴/۹	۳۰۷۵/۶	۴/۶	۳۲۸۸۱۴/۸	۴۱۲۳۵/۶	۱۵۲/۵	RMSE	
۳۰/۲۹	-۵۱/۸۱	-۱۸/۶۹	-۹۱/۰۷	۱۷/۹۷	۳۹/۱۰	PBIAS	
۵۴۰۹۶/۷	۹۷۷/۵	۱/۷	۷۵۵۶۶/۴	۱۰۸۶۵/۴	۴۷/۴	MAE	یک خطی اصلاحی
۱۸۸۸۵۰/۵	۳۲۹۴/۴	۴/۷	۳۲۰۵۲۰/۲	۴۵۸۹۶/۵	۱۵۹/۳	RMSE	
۲۹/۶۵	-۵۵/۸۷	-۲۰/۰۱	-۸۸/۶۴	-۶۳/۴۱	۹۷/۸۳	PBIAS	
۱۲۹۵۴۵/۴	۲۴۹۶/۶	۴/۱	۸۳۴۶۵۵/۶	۸۵۴۸۲/۱	۲۸۶/۱	MAE	FAO
۴۳۵۶۸۲/۳	۸۶۵۲/۹	۹/۱	۳۳۵۲۹۱۳/۸	۴۰۳۱۸۱	۱۱۰۹/۴	RMSE	
۱۱۳/۹۵	۱۵۱/۰۱	۷۰/۵۰	۹۸۶/۵۷	۵۱۲/۴۶	۳۹۸/۹۷	PBIAS	
۳۹۷۵۱/۷	۳۴۴۶/۴	۲/۱	۷۳۵۲۵/۵	۴۹۰۷۰/۴	۱۴۹/۵	MAE	CF1
۱۱۴۱۷۸	۱۸۰۷۸/۹	۵/۶	۳۴۴۷۹۷/۳	۳۰۴۲۹۴/۵	۷۴۴/۵	RMSE	
۱۰/۰۷	۲۰۶/۶۴	۱۳/۹۹	۸۶/۸۹	۲۸۷/۲۹	۱۲۴/۴۳	PBIAS	
۳۵۶۵۵/۵	۱۵۳۳۴۹/۸	۴۸	۵۳۵۷۴۶۶۲	۱۱۳۷۸۴۲/۶	۳۷۲۰/۸۰	MAE	حد وسط اصلاحی
۹۵۴۱۲/۲	۷۱۱۲۳۳/۷	۱۲۴/۹	۲۳۷۰۳۸۱۹۲	۶۴۳۷۳۳۲/۴	۱۸۲۰۷/۹	RMSE	
۰/۵۵	۹۲۷۵/۴۸	۸۲۱/۱۵	۶۳۳۲۵/۹۲	۶۸۲۱/۲۴	۱۴۹۶/۵۴	PBIAS	
۹۴۷۴۲/۵	۱۷۸۵۰/۳	۲۱/۲	۴۸۷۴۰۰۶۲	۷۲۳۴۷۱/۷	۱۷۶۴/۵	MAE	FAO
۳۰۶۲۰۴/۷	۸۴۷۴۶/۱	۵۶/۱	۲۱۵۶۴۹۳۲۳	۴۱۰۴۹۵۳	۸۷۵۰/۲	RMSE	
۸۳/۳۵	۱۰۷۹/۶۹	۳۶۱/۴۷	۵۷۶۱۱/۳۷	۴۳۳۷/۱۳	۴۹/۵۰	PBIAS	

جدول ۵- مشخصات شبکه‌های عصبی به کار رفته در ایستگاه‌های هیدرومتری مورد مطالعه و نتایج ارزیابی این مدل‌ها

ایستگاه هیدرومتری						پارامتر ارزیابی	تابع محرک	ساختار مدل	نوع مدل
کناروئیه	میدان	چشمه عروس	هنجان	سلطانی	پل بافت				
۱۰	۹	۷	۱۰	۸	۱۰	تعداد نرون			
۳۸۱۶۹/۵	۷۷/۸	۶/۰۱	۲۸/۰۷	۸۲۷/۲	۳۴/۷	MAE	tansig		
						(تن در روز)			
۴۶۷۷۹/۳	۲۰۶/۰۱	۶/۴	۶۰/۸	۲۶۹۳/۷	۲۱۲/۶	RMSE			
						(تن در روز)			
-۵۶/۵۸	۲/۰۹	۶۵۴/۳۹	-۰/۰۳	-۰/۰۵	۱۸/۷۴	PBIAS(%)			
۱۰	۹	۸	۹	۷	۹	تعداد نرون		پرسپترون	شبکه عصبی مصنوعی (آموزش)
۵۳۶۱۳/۷	۱۸۷۰/۳	۶/۰۳	۵۴۲۷۱/۶	۹۶۳۲/۸	۴۲/۹	MAE	logsig	چند لایه	
۸۱۷۲۵/۲	۲۴۲۰/۸	۶/۴۱	۲۷۶۶۲۹	۱۱۲۸۵/۳	۲۰۳/۲	RMSE			
-۵۵/۵۷	۶۱/۲۲	۶۶۲/۰۳	-۷۷/۲۸	۴۱/۵۵	۱۶/۴۱	PBIAS			
۸	۱۰	۸	۹	۱۰	۱۰	تعداد نرون			
۴۱۱۵۷/۹	۵۶۳/۴	۶/۸۸	۲۵/۹	۶۴۵۴/۱	۵۵/۳	MAE	*Purelin		
۴۵۹۵۱	۶۰۶/۹	۷/۶	۵۱/۷۵	۸۴۱۰/۵	۲۱۱/۵	RMSE			
-۵۳/۱۸	۳۵/۹۲	۹۷۲/۸۸	۰/۰۰	۲۵/۶۲	۳۱/۷۶	PBIAS			
۳۹۰۵۵	۹۰/۴۶	۵/۶۱	۲۰/۱۹	۶۸۸/۷۳	۷/۶۶	MAE	پایه شعاعی		
۴۸۸۳۲/۹	۲۰۸/۱۲	۵/۶۱	۳۶/۹	۲۳۱۱/۹	۱۹/۸	RMSE			
-۳۹/۰۱	-۰/۰۲	۴۴/۴۷	-۰/۰۳	-۰/۰۳	-۰/۰۳	PBIAS			
۵۳۸۶۲/۳	۷۳۸/۸۹	۸/۹۸	۱۲۲۷۴۴	۱۵۱۸۸	۱۲۵/۸	MAE	Tansig		
۹۷۵۰۹/۷	۲۱۸۹/۹	۱۱/۱	۳۲۴۶۴۳	۲۸۳۲۶/۵	۲۲۹/۸	RMSE			
-۷۵/۵۱	۲۲/۷۲	۱۴۹۹/۸۸	۸۸/۹۱	۱۵۶/۶۰	-۷۴/۱	PBIAS			
۱۳۲۵۹۵	۱۹۸۳/۳	۸/۵۹	۱۳۷۱۴۸	۲۵۶۲۸/۷	۶۰	MAE	logsig	پرسپترون	شبکه عصبی مصنوعی (آزمون)
۱۸۳۳۳۸	۲۹۴۷/۹	۱۱	۳۶۲۶۷۲	۳۰۷۷۹/۵	۹۶/۵	RMSE			
-۸۱/۵۷	۱۱/۱۳	۱۴۶۵/۰۶	-۹۹/۳۲	۲۶۴/۳۵	-۸/۵	PBIAS			
۶۵۵۲۹/۵	۵۸۹/۱	۷/۴	۱۲۲۷۴۲	۱۹۹۳۳/۴	۴۶/۸	MAE	Purelin		
۸۹۴۸۰/۸	۷۲۱/۲	۷/۸	۳۲۴۶۴۳	۳۱۵۵۲/۹	۶۱/۴	RMSE			
-۷۰/۲۰	۱۴/۹۰	۶۹۷/۲۳	۸۸/۹۱	۲۰۵/۵۳	۶/۸۵	PBIAS			
۴۰۵۳۵	۳۸۴/۸	۶/۱	۱۳۴۵۱۰	۲۹۲۰۵/۹	۳۸/۴	MAE	پایه شعاعی		
۷۱۷۳۴/۳	۶۶۹	۷/۲	۳۵۵۷۷۸	۳۵۹۷۳/۹	۵۸/۴	RMSE			
-۳۹/۷۱	۸/۲۸	۵۵/۲۵	-۹۷/۴۵	۳۰۰/۵۵	۱/۸۵	PBIAS			

* این تابع مربوط به لایه خروجی است نه لایه پنهان

وارد می‌شود. پیشنهاد می‌شود تا علاوه بر مقادیر دبی جریان، کاربرد متغیرهای دیگر نیز در ترسیم منحنی‌های سنج رسوب مورد آزمون قرار گیرد و یا به عبارت دیگر، منحنی‌های سنج رسوب چند متغیره ترسیم شود. نتایج حاصل از روش شبکه عصبی مصنوعی در جدول ۵ نشان می‌دهد که روش شبکه عصبی تابع پایه شعاعی در چهار ایستگاه هیدرومتری پل بافت، چشمه عروس، میدان و کناروئیه و روش پرسپترون چند لایه در ایستگاه‌های هیدرومتری سلطانی و هنجان بهترین مدل‌ها برای شبیه‌سازی

به‌طور کلی در جهت بهبود روابط منحنی سنج رسوب در ایستگاه‌های مختلف استان باید تحقیقات بیشتری صورت گیرد تا ماهیت و پیچیدگی برآوردکننده‌های رگرسیونی و یا سایر مدل‌ها به‌خوبی روشن شود. آنچه در این بین نقش مهم و به‌سزایی دارد، داشتن جامعه آماری مناسب، از داده‌های هم‌زمان غلظت رسوب و دبی جریان می‌باشد. دبی جریان به‌عنوان یک متغیر نقش زیادی در نتایج کاربرد منحنی‌های سنج رسوب دارد و تنها متغیر مستقلی است که در معادلات رگرسیونی منحنی سنج رسوب

یک روش را به‌عنوان روش برتر در همه ایستگاه‌های هیدرومتری مورد مطالعه معرفی کرد. در هر ایستگاه بسته به جامعه آماری، روش بهتر انتخاب می‌شود. به‌طوری که در بین ایستگاه‌های هیدرومتری مورد مطالعه، مدل عصبی-فازی الگوی ۱ در ایستگاه هیدرومتری هنجان، مدل عصبی فازی الگوی ۲ در ایستگاه هیدرومتری هنجان، مدل عصبی فازی الگوی ۲ در ایستگاه هیدرومتری سلطانی و کنارویه و مدل شبکه عصبی تابع پایه شعاعی در ایستگاه هیدرومتری میدان و پل بافت و چشمه عروس، به‌عنوان بهترین مدل‌ها برای پیش‌بینی میزان رسوب معلق هستند. آنچه مسلم است، این است که در عمده این ایستگاه‌ها مدل عصبی فازی به‌عنوان مدل منتخب برای پیش‌بینی میزان رسوب معلق است.

میزان رسوب معلق هستند. نتایج حاصل از شبیه‌سازی با استفاده از روش عصبی-فازی در جدول ۶ حاکی از آن است که روش الگوی ۱ (مثلثی-ترکیبی) در ایستگاه‌های هیدرومتری پل بافت، هنجان، چشمه عروس، روش الگوی ۲ (مثلثی-پس انتشار خطا) در ایستگاه‌های هیدرومتری سلطانی و کنارویه و روش الگوی ۳ (گوسی-ترکیبی) در ایستگاه هیدرومتری میدان بهترین مدل‌های عصبی-فازی برای شبیه‌سازی میزان رسوب معلق می‌باشند. نتایج حاصل از شبیه‌سازی میزان رسوب معلق با استفاده از مدل‌های جعبه سیاه شبکه عصبی مصنوعی و عصبی-فازی در ایستگاه‌های هیدرومتری مورد مطالعه نشان می‌دهد که همانند مدل‌های منحنی سنجه رسوب نمی‌توان

جدول ۶- مشخصات مدل نروفازی به‌کار رفته در ایستگاه‌های هیدرومتری مورد مطالعه و نتایج ارزیابی این مدل‌ها

نوع مدل	تابع عضویت	روش آموزش	پارامتر ارزیابی	کنارویه	میدان	چشمه عروس	هنجان	سلطانی	پل بافت
			MAE	۹۴۴۴/۸۹	۱۶۰	۶/۰۸	۱۹/۳	۱۷۷۷/۱۸	۳۰/۶۱
		Hybrid	RMSE	۱۴۶۸۰/۵۸	۲۸۶/۷۳	۶/۴۶	۳۴/۰۳	۳۰۱۲/۶۳	۵۹/۸۵
	مثلثی (Triangle)		PBIAS	-۸۹/۲۶	-۰/۰۱	۶۷۳/۹۴	-۰/۰۲	۰/۰۱	۰/۰۱
			MAE	۸۶۷۷/۳۶	۲۲۵/۹۴	۵/۹۱	۱۲۴۳۸/۵۷	۳۰۸۲/۹۷	۳۰/۸۴
		Bacropa	RMSE	۱۶۴۱۷/۸۲	۳۰۶/۳۶	۶/۳	۱۲۶۸۹/۷۶	۳۴۷۵/۸۴	۳۳/۸۸
	شبکه (gird)		PBIAS	-۹۰/۱۳	۱۵/۰۱	۶۳۵/۸۵	-۱۷/۷۱	۱۳/۳۳	۱۴/۵۲
			MAE	۱۴۴۵۳/۶	۱۳۴/۴۹	۵/۶۹	۲۰/۱۹	۱۸۹۱/۸۱	۱۳/۲۴
		Hybrid	RMSE	۲۲۳۹۹/۷۸	۲۸۳/۴۱	۶/۰۷	۳۶/۹۰	۳۴۰۷/۲۴	۲۳/۴۳
	گوسی (Gaussian)		PBIAS	-۸۳/۵۶	۰/۰۱	۵۸۲/۹۴	-۰/۰۳	۰/۰۲	۰/۰۴
			MAE	۱۵۳۹۳/۲۸	۲۶۵/۰۹	۵/۹۹	۱۲۰۲۱/۰۶	۵۲۴۵/۷۵	۳۳/۳۵
		Bacropa	RMSE	۲۴۹۵۶/۴۹	۳۳۰/۰۵	۶/۳۵	۱۲۲۷۲/۱۳	۸۶۷۶/۸۳	۳۷/۰۵
			PBIAS	-۸۲/۴۹	۱۶/۹۸	۶۴۷/۹۳	۱۷/۱۲	۱۸/۳۳	۱۵/۱۵
			MAE	۲۵۷۳۹/۰۹	۹۵۹/۵۸	۶/۳۱	۵۷۲۱۸/۹۳	۱۱۵۰۷/۲۳	۸۶/۳۱
			RMSE	۳۸۵۰۰/۰۱	۱۱۸۵/۷	۶/۹۲	۷۶۰۶۰/۱۱	۱۸۲۴۷/۳۵	۱۴۶/۴۹
			PBIAS	-۷۰/۷۲	-۰/۰۲	۷۸۷/۷۷	۰/۰۰	۰/۰۰	-۰/۰۲
		Hybrid	MAE	۳۹۳۴۵/۸۳	۶۳۸/۰۲	۶	۱۱۹۵۸/۷۴	۱۸۱۴۲/۱۳	۳۵/۰۷
			RMSE	۶۳۱۱۲/۷۶	۱۴۱۳/۵۵	۶/۳۴	۲۸۶۷۲/۷۸	۵۳۵۱۱/۳۷	۴۲/۰۷
	مثلثی (Triangle)		PBIAS	-۸۲/۱۱	-۲/۵۷	۳۹۹/۸۴	-۰/۹۶	۱۶۸/۹۱	۱/۵۹
			MAE	۳۴۲۳۵/۲۷	۸۵۱/۲۸	۶/۲۵	۲۰۹۸۵/۱۸	۱۷۳۳۱/۹۵	۴۴/۳۱
		Bacropa	RMSE	۵۲۷۳۵/۹۲	۱۵۹۲/۲۴	۷/۳۴	۳۱۵۳۲/۲	۱۳۱۶۴/۱	۵۶/۴۶
	شبکه (gird)		PBIAS	-۴۷/۴۹	۴/۵۲	۵۹۱/۷۸	۸/۶۳	۱۰۰/۱۹	۱۹/۸۸
			MAE	۴۷۳۹۸/۸۳	۵۰۱/۹۶	۹/۸۱	۹۰۴۳۳/۸۶	۱۸۴۵۴/۷۳	۵۹/۱۶
		Hybrid	RMSE	۷۸۴۹۳/۸۹	۱۱۸۱/۲۹	۱۳/۷	۲۳۹۱۴۹	۱۶۳۰۲/۰۴	۱۱۱/۲۷
	گوسی (Gaussian)		PBIAS	-۷۸/۴۵	-۲/۸۷	۲۳۰۸/۴۲	۶۵/۴۷	۱۷۳/۲۴	۳۱/۹۵
			MAE	۴۹۶۹۷/۸	۷۲۳/۷۳	۶/۶۱	۱۱۸۷۵۰/۷	۲۷۹۳۰/۰۱	۴۹/۶۴
		Bacropa	RMSE	۹۰۳۸۹/۵۵	۱۳۶۷۰/۲۷	۸/۷۱	۲۸۶۶۸۹	۲۱۱۶۲/۲۳	۶۶/۳۳
			PBIAS	-۸۴/۴۳	۳/۵۸	۸۷۳/۳۰	۸۶/۰۵	۲۸۷/۹۸	۸/۴۷
			MAE	۴۸۸۵۵/۳۷	۱۵۴۸/۷۴	۶/۹۹	۱۱۶۹۹۲/۲	۱۸۲۴۹/۰۳	۱۵۱/۹۱
			RMSE	۷۵۶۶۳/۱۹	۲۰۷۹/۵	۸/۱۹	۱۷۲۱۳۵/۷	۲۱۹۹۵	۱۷۹/۴۳
			PBIAS	-۷۷/۷۸	-۶/۴۴	۷۵۹/۳۶	۵۷/۱۱	۱۸۷/۰۶	۷۰/۸۳

نسبت به سایر مدل‌ها در پیش‌بینی رسوب معلق نتایج تحقیقات Soltani و Asadiani Yekta (۲۰۰۶) در رودخانه زاینده‌رود، Moayeri و همکاران (۲۰۱۰) در رودخانه آجی‌چای، Mohamadi (۲۰۱۲) و Tabatabaei و همکاران (۲۰۱۴) در رودخانه کرج و Zoratipour (۲۰۱۶) در رودخانه طالقان رود و Afkhami و همکاران (۲۰۱۶) در حوضه سد دز هم-خوانی دارد. با توجه به نتایج حاصل از این تحقیق، مبنی بر برتری نسبی سامانه استنتاج عصبی-فازی نسبت به سایر مدل‌ها پیشنهاد می‌شود تا در پژوهش‌های آتی به بررسی نقش توزیع‌های آماری در افزایش دقت پیش‌بینی‌ها با استفاده از این مدل‌ها پرداخته شود.

نتیجه کلی حاصل از مقایسه همه روش‌های منحنی سنج رسوب و مدل‌های جعبه سیاه در تحقیق حاضر نشان می‌دهد که در عمده ایستگاه‌های هیدرومتری مورد مطالعه، شامل پل بافت، هنجان و کناروئیه، مدل‌های عصبی-فازی به‌عنوان بهترین روش برای شبیه‌سازی میزان رسوب معلق، روش شبکه عصبی مصنوعی تابع پایه شعاعی در ایستگاه هیدرومتری میدان، روش منحنی سنج رسوب دو خطی در ایستگاه چشمه عروس و روش منحنی سنج یک خطی با اعمال ضریب CFI در ایستگاه هیدرومتری سلطانی، به‌عنوان بهترین روش‌ها برای شبیه‌سازی میزان رسوب معلق می‌باشند. نتایج حاصل از این تحقیق در مورد برتری مدل‌های عصبی-فازی

منابع مورد استفاده

1. Afkhami, H., M.T. Dasturani and F. Fotuhi. 2016. Evaluation of the effect of probability distributions on suspended sediment prediction accuracy using ANN and ANFIS Models, case study: Dez Basin. *Journal of Range and Watershed Management*, 69(2): 323-338.
2. Alborzi, M. 2007. *Neural computing: an introduction*. Sharif University of Technology Press, 137 pages.
3. Ali, M., G. Sterk and M. Seeger. 2011. Effect of hydraulic parameters on sediment transport capacity in overland flow over erodible beds. *Hydrology and Earth System Sciences*, 8(4): 6939-6965.
4. Asselman, N.E.M. 2000. Fitting and interpretation of sediment rating curve. *Journal of Hydrology*, 234: 228-248.
5. Barzegari, F. and M.T. Dastorani. 2015. Suspended sediment prediction using time series and artificial neural networks models, case study: Ghazaghly Station in Gorganroud River. *Journal of Watershed Management Research*, 6(12): 216-225 (in Persian).
6. Bhuyan, S.J., P.K. Kalita, K.A. Janssen and P.L. Barnes. 2002. Soil loss predictions with three erosion simulation models. *Environmental Modelling and Software*, 17: 137-146.
7. Dehghani, A.A., M.E. Zanganeh, A. Mosaedi and N. Kohestani. 2009. Comparison of suspended sediment estimation by artificial neural network and sediment rating curve methods, case study: Doogh River in Golestan Province. *Agriculture and Natural Resources*, 16: 266-276 (in Persian).
8. De Vente, J. and J. Poesen. 2005. Predicting soil erosion and sediment yield at the basin scale: scale issues and semi-quantitative models. *Earth-Science Reviews*, 71: 95-125.
9. Duan, N. 1983. Smearing estimate, a nonparametric retransformation method. *Journal of the American Statistical Association*, 78(383): 605-610.
10. Falamaki, A., M. Eskandari, A.H. Baghlani and S.A. Ahmadi. 2013. Modelling total sediment load in rivers using artificial neural networks. *Journal of Soil and Water Resources Conservation*, 2(3): 13-25 (in Persian).
11. Farshadfar, E. 2005. *Multivariate principles and procedures of statistics*. Taghbostan Press, 734 pages.
12. Heathcote, A.J., C.T. Filstrup and J.A. Downing. 2013. Watershed sediment losses to lakes accelerating despite agricultural soil conservation efforts. *PLOS One*, 8(1): e53554.
13. Heng, S. and T. Suetsugi. 2013. Using artificial neural network to estimate sediment load in ungauged catchments of the Tonle Sap River Basin, Cambodia. *Journal of Water Resource and Protection*, 5: 111-123.
14. Iadanza, C. and F. Napolitano. 2006. Sediment transport time series in the Tiber River. *Physics and Chemistry of the Earth, Parts*, 31(18): 1212-1227.
15. International Geosphere-Biosphere Programme (IGBP-BAHC). 1997. Modeling the transport and transformation of terrestrial materials to freshwater and coastal ecosystems. *Biogeochemistry*, 84 pages.
16. Jang, J.S.R. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems*, 23(3): 665-685.

17. 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.
18. Jansson, M.B. 1988. A global survey of sediment yield. *GEOGR. ANN.*, 70(1-2): 81-98.
19. Jones, K.R., O. Berney, D.P. Carr and E.C. Barret. 1981. Arid zone hydrology for agricultural development (FAO irrigation and drainage paper). Food and Agriculture Organization, 382 pages.
20. Kisi, O. and J. Shiri. 2012. River suspended sediment estimation by climatic variables implication: comparative study among soft computing techniques. *Computers and Geosciences*, 43: 73-82.
21. Lal, R. 1998. Soil erosion impact on agronomic productivity and environment quality. *Critical Reviews in Plant Sciences*, 17(4): 319-464.
22. Menhaj, M.B. 2002. Introduction of artificial neural networks (Vol. 1). Amirkabir University Press, 986 pp.
23. Milliman, J.D. and R.H. Meade. 1983. World-wide delivery of river sediment to the oceans. *Journal of Geology*, 91: 1-21.
24. Moayeri, M.M., M.R. Nikpoor, A. Hoseinzadeh Dalir and D. Farsadzadeh. 2010. Comparison of artificial neural networks, adaptive neuro-fuzzy and sediment rating curve models for estimating suspended sediment load of Ajichay River. *Water and Soil Science*, 20(2): 71-82.
25. Mohamadi, S. 2017. Comparison on artificial neural network and sediment rating curve models for simulating of suspended sediment load, case study: Shahrood Watershed. *Irrigation and Water Engineering*, 7(27): 32-46.
26. 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 Science, Engineering and Technology (WASET)*, 81: 372-376.
27. Nadal-Romero, E., J. Latron, C. Marti-Bono and D. Regues. 2008. Temporal distribution of suspended sediment transport in a humid Mediterranean badland area: the Araguás Catchment. *Central Pyrenees, Geomorphology*, 97: 601-616.
28. Nourani, V. 2009. Using Artificial Neural Networks (ANNs) for sediment load forecasting of Talkherood River. *Journal of Urban and Environmental Engineering*, 3(1): 1-6.
29. Pimentel, D., C. Harvey, P. Resosudarmo, K. Sinclair, D. Kurz, M. McNair, S. Crist, L. Shpritz, L. Fitton, R. Saffouri and R. Blair. 1995. Environmental and economic costs of soil erosion and conservation benefits. *Science*, 267: 1117-1123.
30. Pohlert, T. 2015. Projected climate change impact on soil erosion and sediment uield in the River Elbe catchment. Springer International Publishing Switzerland, 97-108.
31. Salajegheh, A. and A. Fathabadi. 2009. Estimation of the suspended sediment loud of Karaj River using fuzzy logic and neural networks. *Journal of Range and Watershed Management*, 62(2): 271-282.
32. Sepahvand A., N. Hezarkhani, M. Taei Semiromi and Sh. Asgari. 2013. Comprising 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.
33. Shabaninia, F. and S. Saednia. 2006. Fundamental of fuzzy control toolbox using MATLAB. Khaniran Press, 135 pages.
34. Soltani, F. and A.H. Asadiani Yekta. 2006. Comparison of neuro-fuzzy network (ANFIS), artificial neural network (ANN) and sediment rating curve methods for predicting river flow, case study: Zayandeh rood River. 7th International River Engineering Conference, Shahid Chamran University of Ahvaz.
35. Tabatabaei, M.R., K. Soleimani, M. Habibnejad and A. Kavian. 2014. Estimation of daily suspended sediment concentration using artificial neural networks and data clustering by self-organizing map, case study: Sierra Hydrometry Station, Karaj DamWatershed. *Journal of Watershed Management Research*, 5(10): 98-116.
36. Tahmoures, M., A.R. Moghadamnia and M. Naghiloo. 2015. Modeling of streamflow-suspended sediment load relationship by adaptive neuro-fuzzy and artificial neural network approaches, case study: Dalaki River, Iran. *Desert*, 20(2): 177-195.
37. Turner, B.L., W.C. Clark, R.W. Kates, J.F. Richards, J.T. Matthews and W.B. Meyer. 1990. The earth as transformed by human action. Cambridge University, 732 pages.
38. Vafakhah, M. 2013. Comparision of cokriging and adaptive neuro-fuzzy inference system models for suspended sediment load forecasting. *Arabian Journal of Geosciences*, 6(8): 3003-3018.
39. Varvani, J., A. Najafinejad and A. Mirmoeemi. 2008. Corrected sediment rating curves using a minimum variance unbiased. *Journal of Agricultural Sciences and Natural Resources*, 15(1): 150-161 (in Persian).

40. Walling, D.E. and P. Kane. 1982. Temporal variation of suspended sediment properties. *International Association of Hydrological Sciences*, 137: 409-419.
41. Wilkinson, S.N., I.P. Prosser, P. Rustomji and A.M. Read. 2009. Modelling and testing spatially distributed sediment budgets to relate erosion processes to sediment yields. *Environmental Modelling and Software*, 24: 489-501.
42. Yang, C.T., R. Marsooli and M.T. Aalami. 2009. Evaluation of total load sediment transport formulas using ANN. *International Journal of Sediment Research*, 24(3): 274-286.
43. Yosefi, M. 2014. Suspended sediment estimation using neural network and algorithms assessment, case study: Lorestan Province. *Journal of Watershed Management Research*, 5(10): 85-97 (in Persian).
44. Zoratipour, A. 2016. Comparison of neuro fuzzy, neural network artificial and statistical methods for estimating suspended load rivers, case study: Taleghan Basin upstream. *Journal of Range and Watershed Management*, 1(69): 65-78 (in Persian).

Archive of SID