



## برآورد رسوب معلق با استفاده از شبکه عصبی و ارزیابی توابع آموزشی (مطالعه موردی: استان لرستان)

محسن یوسفی<sup>۱</sup> و ربابه پورشرعیاتی<sup>۲</sup>

۱- دانشجوی کارشناسی ارشد، دانشکده منابع طبیعی دانشگاه یزد، (نویسنده مسوول: mohsenyosefi67@gmail.com)

۲- دانش آموخته کارشناسی ارشد، دانشکده منابع طبیعی دانشگاه یزد

تاریخ پذیرش: ۹۲/۹/۱۲

تاریخ دریافت: ۹۱/۹/۱۴

### چکیده

به منظور اجرای برنامه‌های حفاظت خاک و کاهش رسوب‌زایی، همچنین محاسبه و طراحی دقیق حجم مخزن سد در احداث سدهای مخزنی، ضرورت دارد که میزان تولید رسوب در یک حوزه آبخیز، ارزیابی و برآورد گردد. بطور کلی پدیده فرسایش و انتقال رسوب از پیچیده‌ترین مسائل هیدرودینامیکی است که تعیین دقیق معادلات حاکم بر آن بدلیل اثرات پارامترهای مختلف، به آسانی میسر نیست. حتی اگر مدلی ریاضی نیز تبیین شود، دسترسی به داده‌های لازم در اکثر موارد به آسانی امکان پذیر نخواهد بود. با توجه به توانایی‌های شبکه‌های عصبی مصنوعی در شناسائی ارتباط بین متغیرهای ورودی و خروجی یک مساله، بدون در نظر گرفتن فیزیک آن مساله و نیز بدلیل ضعف مدل‌های فیزیکی و ریاضی در مدل کردن فرآیندهای رسوبی، این شبکه‌ها می‌توانند در مدل کردن مساله انتقال رسوب بکار روند. هدف از این مطالعه به دست آوردن الگوریتم مناسب با استفاده از شبکه عصبی پیش‌خور پس انتشار خطا (Feed-Forward Back propagation)، Fitting و Forward Back prop Cascade به منظور برآورد میزان رسوبات معلق در حوزه لرستان می‌باشد. به این منظور برای برآورد رسوب، از داده‌های دبی، بارش و رسوب رودخانه‌های کاکارضا، دهنو، چم انجیر استان لرستان به صورت ماهانه استفاده شد. لازم به ذکر است که داده‌های رسوبات معلق در خروجی حوزه (ایستگاه چم انجیر) از پراکنش مناسب‌تری برخوردار است. از میان سه شبکه مورد استفاده در این مطالعه شبکه fitting به منظور برآورد میزان رسوب مناسب تشخیص داده شد. از بین سیزده الگوریتم مورد استفاده در این مطالعه، TRAINLM به عنوان بهترین الگوریتم با ضریب همبستگی  $R=0.99$ ،  $RMSE=0.10$ ، انتخاب شد.

واژه‌های کلیدی: شبکه عصبی، الگوریتم‌های شبکه عصبی، رسوب معلق، استان لرستان

### مقدمه

کاهش عمر مفید سدها و ظرفیت ذخیره مخازن، وارد شدن خسارات به ابنیه آبی و مزارع، رسوب‌گذاری در کف کانال و بسیاری

انتقال رسوب و رسوب‌گذاری، پیامدهایی چون ایجاد جزایر رسوبی در مسیر رودخانه،

مسائل بشمار می‌آیند. بنابراین استفاده از مدل‌های غیرخطی مثل شبکه‌های عصبی مصنوعی (ANN) یک راه‌حل مناسب برای مدل‌سازی رفتار واقعی رسوب به نظر می‌رسد (۱۴). این روش با الهام از مغز انسان و دستیابی به دانش نهفته در داده‌ها روابط موجود بین داده‌ها را بدست آورده و آنها را به مواردی که مدل با آنها مواجه نشده است تعمیم می‌دهند. در این روش‌ها مدل با استفاده از یک دسته سری‌های داده آموزش می‌بینند و با استفاده از اطلاعات حاصل از داده‌ها، وزن‌های شبکه تعیین می‌گردند. پردازش توزیعی اطلاعات، قابلیت تعمیم یا درون‌یابی، پردازش موازی و مقاوم بودن، از عمده‌ترین ویژگی‌های این روش‌ها به شمار می‌رود (۱۳).

دستورانی و همکاران (۷) در مطالعه برآورد رسوبات معلق با استفاده از شبکه عصبی مصنوعی در حوزه آبخیز جامیشان نتیجه گرفتند که شبکه عصبی مصنوعی نتایج قابل قبولی را جهت شبیه‌سازی بار معلق در ایستگاه حیدرآباد ارائه می‌کند. نتایج مطالعه طلوعی و همکاران (۱۵) در تخمین زمانی و مکانی بار معلق رودخانه آجی چای با استفاده از زمین آمار و شبکه عصبی مصنوعی، نشان‌دهنده مناسب‌تر شدن شبکه عصبی در صورت استفاده از علم زمین آمار در برآورد مکانی بار معلق ماهانه می‌باشد. ولی و همکاران (۱۶) با مقایسه کارایی مدل‌های شبکه‌های عصبی مصنوعی و رگرسیون برای پیش‌بینی بار رسوب جریان (مطالعه موردی حوزه آبخیز سمندگان) به این نتایج دست یافتند که از مقایسه نتایج

مسایل و مشکلات دیگر را در بردارد. در طرح‌های مهندسی رودخانه، تخمین مقدار بار رسوبی رودخانه از اهمیت زیادی برخوردار است. بواسطه اثر مطالعات انجام یافته در زمینه درک فرآیند انتقال رسوب در رودخانه‌های طبیعی، شاخه‌ای بنام هیدرولیک انتقال رسوبات بوجود آمده که به مسائل تخمین رسوب رودخانه‌ها می‌پردازد. اندازه‌گیری رسوب کار پرهزینه‌ای بوده و امکانات خاصی را طلب می‌کند. روش‌های تخمین میزان رسوب را می‌توان در دو گروه دسته‌بندی کرد. رویکرد روش‌های سری اول، ایجاد مدل‌های ریاضی با توجه به مفاهیم فیزیکی انتقال ذرات و حل معادلات هیدرودینامیک رسوب به همراه حل میدان جریان است. با توجه به اینکه این روش‌ها به داده‌های متنوعی نیازمند بوده و از طرفی نتایج حاصل از آنها حتی در یک ایستگاه از یک رودخانه مشخص معمولاً یکسان و مشابه نبوده و انتخاب یکی از آنها مشکل می‌باشد، محققان در جستجوی راه‌های عملی برای پیش‌بینی رسوب برآمده‌اند و تلاش آنها باعث ایجاد روش دیگری موسوم به روش منحنی سنج رسوب شده است. همچنین بسیاری از روابط و تکنیک‌های فعلی تخمین رسوب بر اساس روابط خطی بین متغیرها استوار است که به خوبی رفتار پیچیده و واقعی رسوب را پیش‌بینی نمی‌کنند (۲).

فرآیند بدست آوردن یک رابطه برای تخمین میزان رسوب، بطور اساسی یک مسأله نگاشت غیرخطی است و شبکه‌های عصبی مصنوعی بعنوان ابزاری توانمند در حل اینگونه

مدل‌های مختلف استنباط می‌شود، زمانی که پارامترهای ژئومورفولوژیکی نظیر شاخص ناهمواری، شاخص گردی و شاخص تراکم زهکشی در مدل‌سازی وارد شوند نتایج ارزیابی آنها مناسب‌تر می‌شود. دهقانی و همکاران (۶) با مطالعه تخمین رسوب معلق رودخانه بهشت آباد (از سرشاخه‌های کارون) با استفاده از شبکه عصبی مصنوعی به این نتایج دست یافتند که روش شبکه عصبی مصنوعی با ضریب تبیین ۰/۹۸، مربع خطای متوسط ۰/۰۰۱ از دقت بالاتری نسبت به روش منحنی سنجه با ضریب تبیین ۰/۷۷۸ و مربع خطای متوسط ۰/۰۴۳ برای تخمین بار معلق رسوب رودخانه بهشت‌آباد برخوردار بود. مساعدی و هاشمی (۱۱) به منظور برآورد رسوب انتقالی در طول سال، به کمک شبکه عصبی مصنوعی مقادیر رسوب را برآورد کردند. این مقادیر را با منحنی سنجه مقایسه نمودند، نتایج نشان داد خطای مدل‌های شبکه عصبی مصنوعی به طور متوسط نصف خطای مدل‌های منحنی سنجه رسوب بوده ضمن آنکه خطای مدل ماهانه نیز بسیار کمتر از خطای مدل سالانه بود. نجفی و همکاران (۱۲) میزان برآورد رسوبات رودخانه زاینده‌رود را با استفاده از روش رگرسیون آماری و دو روش از شبکه‌های عصبی مصنوعی، مدل‌سازی نمودند. نتایج نشان داد که مدل MLP در مقایسه با روش‌های GRNN و رگرسیون آماری، تطابق بیشتری با مقادیر اندازه‌گیری شده دارد. آچیت و اوییلن (۱) در بررسی برآورد رسوب نشان دادند که اولاً، مقادیر پیش‌بینی شده ۲۵-۲۰ درصد بیشتر از مقادیر واقعی است. ثانیاً، طبق

سری‌های زمانی موجود، برآورد دقیق‌تر نیاز به دوره‌های طولانی‌مدت دارد. همچنین بیشترین مقدار رسوب مربوط به پاییز و سپس بهار می‌باشد. ایشان پیشنهاد می‌کنند جهت بررسی دقیق‌تر، تغییرات آب و هوایی را نیز باید مورد توجه قرار داد. بهاتاچاریا و همکاران (۵)، از دو روش یادگیری ماشینی شامل شبکه عصبی مصنوعی و مدل‌های درخت تصمیم جهت مدل‌سازی انتقال بارکل و بارکف رودخانه استفاده کردند و نتایج مدل‌های انتقال بارکف را با مدل‌های بگنولد، انیشتین، پارکر و همکاران و وان ریجن و همچنین نتایج مدل‌های انتقال بار کل را با مدل‌های وایت ایگرز، بگنولد، انگلوند و هانسون و وان ریجن مقایسه کردند. طبق نتایج آنان، مدل‌های یادگیری ماشینی دقت بیشتری نسبت به دیگر روش‌ها دارد و از بین مدل‌های مذکور، مدل درخت تصمیم کمترین خطا را نشان داد. حکمت کریم و آلپ (۸) از الگوریتم شبکه‌های عصبی تصمیم یافته (GRNN) و پیشخور پس انتشار خطا (FFBP) جهت برآورد رسوب معلق رودخانه استفاده کردند. میانگین مربع خطا و ضریب همبستگی به‌عنوان معیار مقایسه در نظر گرفتند. ارزیابی‌های شبکه‌های عصبی به‌منظور برآورد رسوب معلق در حوزه جونیاتا آمریکا مناسب می‌باشند.


هدف از این مطالعه به دست آوردن الگوریتم مناسب در سه شبکه عصبی fitting network، پیش‌خور پس انتشار خطا<sup>۱</sup> و Cascade Forward backprop به‌منظور برآورد میزان رسوب در منطقه مورد مطالعه می‌باشد.

## مواد و روش‌ها

### موقعیت منطقه مورد مطالعه

استان لرستان در غرب ایران، بین  $51^{\circ} 46'$  تا  $3^{\circ} 50'$  طول شرقی از نصف النهار گرینویچ و  $37^{\circ} 32'$  تا  $22^{\circ} 34'$  عرض شمالی از خط استوا قرار گرفته و وسعت آن حدود ۲۸۵۵۸ کیلومترمربع است. رودخانه کاکارضا یا رود ولم در شهرستان سلسله در استان لرستان با طول  $21^{\circ} 14' 44''$  و عرض جغرافیایی  $38^{\circ} 42'$  قرار دارد. این رود که بزرگترین رودخانه

منطقه الشتر می‌باشد از کوه‌های جنوب غربی الشتر سرچشمه گرفته و پس از عبور از جنوب الشتر و مجاورت بسطام از طرف مشرق به طرف جنوب غربی جریان پیدا می‌کند و به ویژه در فصل بهار سیلابی و غیر قابل عبور می‌باشد. چم انجیر در دوازده کیلومتری خرم‌آباد با طول  $56^{\circ} 14' 48''$  و عرض جغرافیایی  $25^{\circ} 26'$  قرار دارد. دهنو در ۵ کیلومتر بروجرد با طول  $47^{\circ} 47' 47''$  و عرض جغرافیایی  $44^{\circ} 14' 21''$  قرار دارد. این رود که بزرگترین رودخانه



شکل ۱- موقعیت منطقه مورد مطالعه

### روش تحقیق

در این مطالعه ابتدا به نرمال‌سازی داده‌های بارش، دبی و رسوب سه رودخانه چم انجیر، کاکارضا و دهنو منطقه مطالعاتی اقدام شد. این داده‌ها با استفاده از رابطه (۱) در بازه

۰/۱-۰/۹ نرمال‌سازی شدند (۱۳). داده‌های دبی، بارش و رسوب رودخانه‌های مذکور در بازه آماری ۳۵ ساله (۸۵-۱۳۵۰) مورد استفاده قرار گرفت. در این مطالعه از داده‌های دبی، بارش به عنوان ورودی در هر سه مدل شبکه

سنجی به کار برده شد. برای اجرای مدل شبکه عصبی نرم افزار MATLAB مورد استفاده قرار گرفته شد.

برای ارزیابی نتایج از معیارهای ضریب همبستگی (R)، میانگین مربعات خطا (RESM)، میانگین اختلافات (BIAS) و میانگین قدرمطلق خطا (MAE) طبق رابطه ۲-۵ استفاده شد (۹). هر چه میزان ضریب همبستگی بالاتر و میزان میانگین مربعات خطا و میانگین قدر مطلق کوچکتر باشد جواب مدل از اطمینان بیشتری به منظور برآورد میزان رسوب برخوردار است. در اجرای مدل شبکه عصبی هرچه میزان رگرسیون توابع آموزشی به یک و میزان میانگین مربعات خطا به صفر نزدیکتر باشد، توابع آموزشی برای برآورد میزان رسوب مناسب تر می باشد (۴).

رابطه (۲)

$$R = \sqrt{1 - \frac{\sum_{i=1}^n (O_i - P_i)}{\sum_{i=1}^n (O_i - \bar{O})}}$$

رابطه (۳)

$$RMSE = \left( \frac{\sum_{i=1}^n (P_i - O_i)^2}{N} \right)^{1/2}$$

رابطه (۴)

$$Bias = \bar{p} - \bar{O}$$

رابطه (۵)

$$MAE = \frac{\sum |O_i - P_i|}{N}$$

عصبی و رسوب به عنوان خروجی مدل‌ها استفاده شد که تمامی این داده‌ها به صورت ماهانه می‌باشند.

رابطه (۱)

$$T = T_{min} + (T_{max} - T_{min})(X - X_{min}) / (X_{max} - X_{min})$$

$T$  = مقادیر نرمال شده داده‌های واقعی،  $X$  = داده‌های رسوب مشاهده شده واقعی،  $X_{min}$  و  $X_{max}$  کمینه و بیشینه داده‌های واقعی،  $T_{max}$  و  $T_{min}$  بیشینه و کمینه داده‌های هدف که در اینجا به ترتیب ۰/۹ و ۰/۱ است.

در ابتدا سه سناریو با ورودی بارش، دبی و دبی- بارش تعریف شد و شبکه با این سه سناریو اجرا گردید. با استفاده از آنالیز حساسیت دبی- بارش به عنوان مناسب‌ترین سناریو که با پارامترهای همبستگی بالا و مجذور میانگین مربعات خطا انتخاب گردید و هر سه شبکه با ۱۳ الگوریتم موجود آموزش داده شد. در نهایت با استفاده از آماره‌های میانگین خطای استاندارد و ضریب همبستگی دقت سه شبکه مذکور در برآورد میزان رسوب در هر یک از رودخانه‌ها با هم مقایسه شد (۹). در این مطالعه برای تعیین بهترین الگوریتم (توابع آموزشی) از تمام الگوریتم‌ها یا توابع آموزشی (OSS, GDX, GDM, GD, GDA, ) (BFG, CGP, CGF, CGB, SCG, RP, LM, BR) استفاده شد. برای استفاده از مدل شبکه عصبی مصنوعی باید داده‌ها به سه قسمت تقسیم شوند که مقداری از آن برای تست، آزمون و اعتبارسنجی اختصاص می‌یابد (۳). در دوره آماری ۳۵ ساله، ۴۲۰ داده که ۷۰٪ آن برای آموزش (مهم‌ترین بخش مدل)، ۱۵٪ داده‌ها برای تست و ۱۵٪ داده‌ها برای اعتبار

سختی می‌توان یکی از آنها را برای مسئله خاصی ترجیح داد (۱۰).

#### الگوریتم شیب توأم Powell-Beale Restarts

در همه الگوریتم‌های شیب توأم، جهت جستجو در دوره‌های خاصی به منفی شیب Reset می‌شود. نقطه Reset شدن استاندارد در جایی است که تعداد تکرارها با تعداد پارامترهای شبکه (وزن‌ها و بایاس‌ها) برابر می‌شود (۱۰).

#### الگوریتم شیب توأم مقیاس شده<sup>۴</sup>

الگوریتم مقیاس شده یا SCG طوری طراحی شده که از جستجوی خطی زمان‌بر دوری کند. این الگوریتم بسیار پیچیده است و اساس کار آن ترکیب دو روش شیب توأم و لونیبرگ مارکوارت است (۱۰).

#### الگوریتم BFGS

این الگوریتم به محاسبات و فضای بیشتری نسبت به روش‌های توأم نیاز دارد اما معمولاً سریع‌تر و در تعداد تکرار کمتری همگرا می‌شود. برای شبکه‌های کوچکتر trainbfg می‌تواند کارایی بهتری نسبت به روش‌های دیگر ارائه دهد (۱۰).

#### الگوریتم One step secant

از آنجا که BFGS نیاز به فضا و محاسبات زیادی دارد یک روش شبه نیوتن دیگر با فضا و محاسبات کمتری ابداع شد که در واقع پلی بین روش‌های شیب توأم و شبه نیوتن بود این روش OSS نام دارد. این الگوریتم را می‌توان یک مصاحبه بین الگوریتم‌های شبه نیوتن و شیب توأم در نظر گرفت (۱۰).

در این روابط P و O به ترتیب مقادیر مشاهده شده و شبیه‌سازی شده،  $\bar{p}$  و  $\bar{O}$  میانگین مقادیر مشاهده شده و شبیه‌سازی شده و N تعداد نمونه‌ها می‌باشد.

به‌منظور آشنایی بیشتر با توابع آموزشی توضیح اجمالی در مورد هر کدام از الگوریتم‌ها به صورت ذیل بیان می‌گردد.

#### پس انتشار ارتجاعی<sup>۱</sup>

هدف از الگوریتم آموزش پس انتشار ارتجاعی از بین بردن تأثیرات مضر روی اندازه مشتقات جزئی است. مقدار تغییرات وزن با استفاده از یک مقدار به‌روز رسانی جداگانه تعیین می‌شود. این الگوریتم کارایی بسیار بالاتری نسبت به الگوریتم استاندارد کاهش شیب دارد. علاوه بر آن حافظه کمتری برای این الگوریتم نیاز است (۱۰).

#### الگوریتم‌های شیب توأم<sup>۲</sup>

الگوریتم پایه پس انتشار وزن‌ها را در خلاف جهت شیب اصلاح می‌کند. این همان جهتی است که تابع کارایی در آن سمت به سرعت کاهش می‌یابد (۱۰).

#### الگوریتم شیب توأم Fletcher-Reeves

تمامی الگوریتم‌های شیب توأم با جستجو در جهت بیشترین کاهش شیب<sup>۳</sup> در اولین تکرار آغاز می‌شوند. الگوریتم‌های شیب توأم بسیار سریع هستند و گاهی اوقات حتی از الگوریتم آموزشی پس انتشار ارتجاعی نیز سریع‌تر هستند (۱۰).

#### الگوریتم شیب توأم Polak - Ribirere

رویه الگوریتم آموزشی شیب توأم مقیاس شده کارایی مشابه با trainsgf دارد و به

1- Resilient Back propagation (rp)

3- Steepest descent

2- Conjugate Gradient Algorithms

4- Scaled Conjugate gradient (scg)

### الگوریتم لونیبرگ مارکوآرت<sup>۱</sup>

و بایاس را بر اساس شیب توام با مومنتوم به روز، به روز می‌کند (۱۰).

#### الگوریتم

#### Gradient descent with momentum and adaptive learning rate back propagation

این الگوریتم تا زمانی که وزن‌ها، ورودی شبکه و تابع انتقال، تابع مشتق داشته باشند می‌تواند هر نوع شبکه‌ای را آموزش دهد (۱۰).

#### نتایج و بحث

ورودی در این مطالعه با دو پارامتر دبی، بارش که به صورت ماهانه می‌باشند، مورد استفاده قرار گرفت و خروجی (هدف) مدل میزان رسوب اندازه‌گیری شده به صورت ماهانه است. البته لازم به ذکر است برای انتخاب تعداد ورودی‌ها از آنالیز حساسیت استفاده شد که بین پارامترهای ورودی طبق جدول ۱ با  $R=0.99$  و  $MSE=0.00036$ ، دبی و بارش به‌عنوان ورودی انتخاب شد. طبق جدول می‌توان دبی را به تنهایی به‌عنوان ورودی در نظر گرفت اما هرچه تعداد پارامترها بیشتر گردد، مدل تخمین رسوب را با صحت و دقت قابل قبول‌تری به‌عنوان خروجی مدل ارائه می‌دهد.

همانند روش‌های شبه نیوتن این روش نیز سعی در کاهش محاسبات با استفاده از عدم محاسبه ماتریس هسیین دارد. بسیار سریعتر از بقیه الگوریتم‌ها عمل می‌کند. اشکال عمده روش لونیبرگ مارکوآرت نیاز آن به نگهداری ماتریس‌های حجیم در حافظه است و این مسئله نیاز به فضای زیادی دارد (۱۰).

#### الگوریتم Gradient descent back propagation

یک تابع آموزشی شبکه است که مقدار وزن‌ها و بایاس را بر اساس شیب توام به روز می‌کند. این الگوریتم تا زمانی که وزن‌ها، ورودی شبکه و تابع انتقال، تابع مشتق داشته باشند می‌تواند هر نوع شبکه‌ای را آموزش دهد (۱۰).

#### الگوریتم

#### Gradient descent with adaptive learning rate back propagation

یک تابع آموزشی شبکه است که مقدار وزن‌ها و بایاس را بر اساس شیب توام به روز و با سرعت آموزش تطابق می‌دهد (۱۰).

#### الگوریتم

#### Gradient descent with momentum back propagation

یک تابع آموزشی شبکه است که مقدار وزن‌ها

جدول ۱- آنالیز حساسیت سناریوهای مختلف با ضریب همبستگی (R) و جذر میانگین مربعات خطا (RESM)

R TRAIN	R TEST	RMSE TRAIN	RMSE TEST	رودخانه	سناریو
۰/۰۵۳	۰/۴۴	۰/۰۵۵	۰/۰۳۹	چم انجیر	بارش
۰/۹۰۰۷	۰/۹۹۹	۰/۰۲۴	۰/۰۲۵	چم انجیر	دبی
۰/۸۶۴	۰/۹۹۳	۰/۰۴۲	۰/۰۰۸	چم انجیر	بارش- دبی
۰/۱۲	۰/۴۵۱	۰/۰۵۶	۰/۰۰۱	دهنو	بارش
۰/۹۰۸	۰/۹۹۳	۰/۰۲۴	۰/۰۲	دهنو	دبی
۰/۸۶۵	۰/۹۹۲	۰/۰۳۴	۰/۰۱۵	دهنو	بارش- دبی
۰/۱۶۲	۰/۴۰۹	۰/۰۵۷	۰/۰۰۷	کاکا رضا	بارش
۰/۹۱	۰/۹۹۵	۰/۰۲۴	۰/۰۱۷	کاکا رضا	دبی
۰/۸۶۶	۰/۹۹۴	۰/۰۲۹	۰/۰۱۹	کاکا رضا	بارش- دبی

1- Levenberg-Marquardt (LM)

جداول ۲، ۳ و ۴ مشاهده شد. نتایج در هر سه شبکه با توجه به شاخص مورد ارزیابی در این مطالعه، نزدیک بودن مقادیر رگرسیون (R) و مجذور میانگین مربعات خطا (MSE) نشان‌دهنده مناسب بودن شبکه‌های مذکور به‌منظور برآورد میزان رسوب در منطقه مورد مطالعه می‌باشد.

بعد از انتخاب دبی و بارش به‌عنوان ورودی، به مدل ارائه شد. در مقابل داده‌های نرمال شده رسوب به‌عنوان خروجی مدل مدنظر قرار گرفته شد. در اجرای مدل شبکه عصبی باید توجه کرد که ماتریس اعداد هنگام ورود داده‌ها به مدل هم در ورودی (دبی، بارش) و هم خروجی (رسوب) برابر باشد. همانطور که در

جدول ۲- میزان R و RMSE شبکه عصبی پیشخور پس انتشار خطا در منطقه مورد مطالعه

ایستگاه	توابع آموزشی	BFG	BR	CGB	CGF	CGP	GD	GDM	GDA	GDX	OSS	RP	LM	SCG	توابع	
															آموزشی	آماره
چم	R TEST	۰/۹۹	۰/۹۹	۰/۹۱	۰/۲۴	۰/۹۹	۰/۹۵	۰/۳۱	۰/۹۸	۰/۷	۰/۹۹	۰/۹۹	۰/۹۳	۰/۹۹	R TEST	
	RMSE TEST	۰/۰۱	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۱	۰/۰۶	۰/۰۳	۰/۰۳	۰/۰۱	۰/۰۵	۰/۰۱	۰/۰۶	RMSE TEST	
دهنو	R TEST	۰/۲۱	۰/۳۵	۰/۳۵	۰/۲۳	۰/۷۶	۰/۷۷	۰/۱۶	۰/۴	۰/۴	۰/۹۵	۰/۲۲	۰/۱۵	۰/۶۰	R TEST	
	RMSE TEST	۰/۰۱	۰/۰۲	۰/۰۲	۰/۰۱	۰/۰۲	۰/۰۲	۰/۰۹	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۲	۰/۰۱	RMSE TEST	
کاکا	R TEST	۰/۹۹	۰/۹۹	۰/۹۹	۰/۹۹	۰/۹۴	۰/۸	۰/۷۳	۰/۹۰	۰/۹۴	۰/۹۹	۰/۹۹	۰/۹۹	۰/۹۴	R TEST	
	RMSE TEST	۱/۱۵	۰/۰۶	۰/۸۳	۰/۰۶	۰/۰۴	۰/۰۳	۰/۱۴	۰/۰۴	۰/۰۵	۰/۰۷	۰/۰۷	۰/۱۴	۰/۰۶	RMSE TEST	

جدول ۳- میزان RMSE و R در fitting network در منطقه مورد مطالعه

ایستگاه	توابع آموزشی	BFG	BR	CGB	CGF	CGP	GD	GDM	GDA	GDX	OSS	RP	LM	SCG	توابع	
															آموزشی	آماره
چم	R TEST	۰/۹۸	۰/۹۹	۰/۹۹	۰/۹۷	۰/۹۶	۰/۸	۰/۸۰	۰/۹۶	۰/۹۱	۰/۹۷	۰/۹۴	۰/۹۹	۰/۹۸	R TEST	
	RMSE TEST	۰/۰۷	۰/۰۱	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۴	۰/۰۶	۰/۰۴	۰/۰۴	۰/۰۲	۰/۰۹	۰/۰۱	۰/۰۱	RMSE TEST	
دهنو	R TEST	۰/۹۰	۰/۸۸	۰/۷۳	۰/۲۵	۰/۶۲	۰/۸۷	۰/۳۴	۰/۴۲	۰/۴۲	۰/۲۲	۰/۴۶	۰/۵۳	۰/۲۱	R TEST	
	RMSE TEST	۰/۰۲	۰/۰۱	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۹	۰/۱۴	۰/۰۲	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۱	RMSE TEST	
کاکا	R TEST	۰/۹۸	۰/۹۶	۰/۹۹	۰/۹۶	۰/۹۲	۰/۷۱	۰/۷۶	۰/۸۲	۰/۸۷	۰/۹۱	۰/۸۱	۰/۹۹	۰/۸۴	R TEST	
	RMSE TEST	۰/۰۶	۰/۲۰	۰/۱۴	۰/۱۰	۰/۰۹	۰/۱۰	۰/۰۴	۰/۰۶	۰/۰۶	۰/۰۹	۰/۰۲	۰/۳۷	۰/۰۶	RMSE TEST	


جدول ۴- میزان RMSE و R در Cascade Forward back prop در منطقه مورد مطالعه

ایستگاه	توابع آموزشی	BFG	BR	CGB	CGF	CGP	GD	GDM	GDA	GDX	OSS	RP	LM	SCG	توابع	
															آموزشی	آماره
چم	R TEST	۰/۹۲	۰/۹۹	۰/۴۳	۰/۲۲	۰/۶۲	۰/۷۸	۰/۸۱	۰/۹۹	۰/۷۲	۰/۲۹	۰/۹۹	۰/۹۹	۰/۹۶	R TEST	
	RMSE TEST	۰/۰۲	۰/۰۱	۰/۰۵	۰/۰۲	۰/۰۲	۰/۰۳	۰/۰۴	۰/۰۱	۰/۰۳	۰/۰۳	۰/۰۱	۰/۰۳	۰/۰۷	RMSE TEST	
دهنو	R TEST	۰/۲۲	۰/۴۱	۰/۲۰	۰/۳۵	۰/۳۷	۰/۴۸	۰/۰۴	۰/۱۳	۰/۹۶	۰/۶۶	۰/۷۹	۰/۹۷	۰/۸۳	R TEST	
	RMSE TEST	۰/۰۱	۰/۰۲	۰/۰۱	۰/۰۱	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۱	RMSE TEST	
کاکا	R TEST	۰/۸۶	۰/۹۷	۰/۷۷	۰/۹۹	۰/۹۹	۰/۲۲	۰/۶۱	۰/۸۷	۰/۶۳	۰/۹۴	۰/۸۳	۰/۹۶	۰/۸۸	R TEST	
	RMSE TEST	۰/۰۷	۰/۱۰	۰/۱۱	۰/۰۷	۰/۱۰	۰/۰۵	۰/۱۳	۰/۰۹	۰/۰۷	۰/۰۸	۰/۱۱	۰/۱۰	۰/۰۸	RMSE TEST	




توابع آموزشی در هر سه شبکه مذکور به عنوان مثال (SCG, RP, LM, BR) مناسب‌ترین الگوریتم برای برآورد میزان رسوب در هر مدل انتخاب شد. که در این بین الگوریتم لورنبرگ مارکوآرت LM در هر سه شبکه انتخاب شد. برای نامناسب‌ترین الگوریتم با ضریب همبستگی پایین و میانگین مربعات خطا  $R=0.04$  و  $0.09$  و میانگین مربعات خطای نزدیک صفر) برای برآورد میزان رسوب، الگوریتم (CGp, CGF, CGB, cgp) به عنوان نمونه انتخاب شد.


برای انتخاب مناسب‌ترین الگوریتم‌ها یا توابع آموزشی، داده‌های رسوب مشاهداتی اندازه‌گیری شده (هدف) در منطقه مورد مطالعه و داده‌های خروجی مدل‌ها (شبیه‌سازی شده) با استفاده از نمودار ترسیم شد. همانطور که در اشکال ۲، ۳، ۴ مشاهده شد از بین مناسب‌ترین الگوریتم در شبکه پیشخور پس انتشار، Cascade Forward back prop و fitting با توجه به میزان رگرسیون بالا و میانگین مربعات خطا  $R=0.99$  و میانگین مربعات خطای نزدیک صفر)، چهار الی پنج



شکل ۲- مقایسه بین داده‌های اندازه‌گیری شده و خروجی مدل (شبیه‌سازی شده) با مناسب‌ترین الگوریتم لورنبرگ مارکوآرت (LM) به عنوان نمونه برای برآورد میزان رسوب در شبکه پیشخور پس انتشار خطا ایستگاه چم انجیر



شکل ۳- مقایسه بین داده‌های اندازه‌گیری شده و خروجی مدل (شبیه‌سازی شده) با مناسب‌ترین الگوریتم لونیبرگ مارکوآرت (LM) به عنوان نمونه برای برآورد میزان رسوب در شبکه fitting ایستگاه چم انجیر



شکل ۴- مقایسه بین داده‌های اندازه‌گیری شده و شبیه‌سازی شده با مناسب‌ترین الگوریتم لونیبرگ مارکوآرت (LM) به عنوان نمونه به منظور برآورد میزان رسوب در شبکه Cascade Forward back prop ایستگاه چم انجیر

مدل (شبیه‌سازی شده)، همچنین میزان بالای ضریب همبستگی و میانگین مربعات خطای پایین و توانایی مناسب این الگوریتم در

همانطور که در اشکال ۲، ۳ و ۴ مشاهده شد منطبق شدن منحنی‌ها بین خطوط داده‌های اندازه‌گیری شده و داده‌های خروجی

شبیه‌سازی داده‌های مشاهده‌ای، نشان از مناسب بودن الگوریتم به‌منظور برآورد میزان رسوب معلق می‌باشد. در صورت نبود اطلاعات و حتی برای پیش‌بینی رسوب می‌تواند این نوع شبکه‌ها و الگوریتم‌ها برای مناطق مورد مطالعه مورد استفاده قرار گرفته شود. در الگوریتم‌های نامناسب با ضریب همبستگی پایین و مجذور میانگین مربعات خطای بالا داده‌های اندازه‌گیری شده و داده‌های شبیه‌سازی شده (خروجی مدل) روی هم منطبق نیستند و خطای بسیار بالا نشان داده شده است مانند CGB که نمی‌توان از توابع آموزشی مذکور با ضریب همبستگی ۰/۰۴ به‌منظور برآورد میزان رسوب استفاده کرد. نتایج این مطالعه با نتایج اکثر محققان همچون بهاتاچاریا و همکاران (۵)، ولی و همکاران (۱۶)، طلوعی و همکاران (۱۵)، دستورانی و همکاران (۷) و دهقانی و همکاران (۶) در مناسب بودن شبکه عصبی مصنوعی به‌منظور برآورد رسوب معلق یکسان می‌باشد.

به‌منظور برآورد رسوب معلق، محققان در تعیین و استفاده از الگوریتم مناسب شبکه عصبی دچار مشکل هستند. به‌منظور تعیین مناسب‌ترین توابع آموزشی (الگوریتم) ابتدا با استفاده از آنالیز حساسیت، تأثیرگذارترین پارامترها (دبی- بارش) به‌عنوان ورودی با

شبیه‌سازی داده‌های مشاهده‌ای، نشان از مناسب بودن الگوریتم به‌منظور برآورد میزان رسوب معلق می‌باشد. در صورت نبود اطلاعات و حتی برای پیش‌بینی رسوب می‌تواند این نوع شبکه‌ها و الگوریتم‌ها برای مناطق مورد مطالعه مورد استفاده قرار گرفته شود. در الگوریتم‌های نامناسب با ضریب همبستگی پایین و مجذور میانگین مربعات خطای بالا داده‌های اندازه‌گیری شده و داده‌های شبیه‌سازی شده (خروجی مدل) روی هم منطبق نیستند و خطای بسیار بالا نشان داده شده است مانند CGB که نمی‌توان از توابع آموزشی مذکور با ضریب همبستگی ۰/۰۴ به‌منظور برآورد میزان رسوب استفاده کرد. نتایج این مطالعه با نتایج اکثر محققان همچون بهاتاچاریا و همکاران (۵)، ولی و همکاران (۱۶)، طلوعی و همکاران (۱۵)، دستورانی و همکاران (۷) و دهقانی و همکاران (۶) در مناسب بودن شبکه عصبی مصنوعی به‌منظور برآورد رسوب معلق یکسان می‌باشد.

به‌منظور برآورد رسوب معلق، محققان در تعیین و استفاده از الگوریتم مناسب شبکه عصبی دچار مشکل هستند. به‌منظور تعیین مناسب‌ترین توابع آموزشی (الگوریتم) ابتدا با استفاده از آنالیز حساسیت، تأثیرگذارترین پارامترها (دبی- بارش) به‌عنوان ورودی با

شبیه‌سازی داده‌های مشاهده‌ای، نشان از مناسب بودن الگوریتم به‌منظور برآورد میزان رسوب معلق می‌باشد. در صورت نبود اطلاعات و حتی برای پیش‌بینی رسوب می‌تواند این نوع شبکه‌ها و الگوریتم‌ها برای مناطق مورد مطالعه مورد استفاده قرار گرفته شود. در الگوریتم‌های نامناسب با ضریب همبستگی پایین و مجذور میانگین مربعات خطای بالا داده‌های اندازه‌گیری شده و داده‌های شبیه‌سازی شده (خروجی مدل) روی هم منطبق نیستند و خطای بسیار بالا نشان داده شده است مانند CGB که نمی‌توان از توابع آموزشی مذکور با ضریب همبستگی ۰/۰۴ به‌منظور برآورد میزان رسوب استفاده کرد. نتایج این مطالعه با نتایج اکثر محققان همچون بهاتاچاریا و همکاران (۵)، ولی و همکاران (۱۶)، طلوعی و همکاران (۱۵)، دستورانی و همکاران (۷) و دهقانی و همکاران (۶) در مناسب بودن شبکه عصبی مصنوعی به‌منظور برآورد رسوب معلق یکسان می‌باشد.

به‌منظور برآورد رسوب معلق، محققان در تعیین و استفاده از الگوریتم مناسب شبکه عصبی دچار مشکل هستند. به‌منظور تعیین مناسب‌ترین توابع آموزشی (الگوریتم) ابتدا با استفاده از آنالیز حساسیت، تأثیرگذارترین پارامترها (دبی- بارش) به‌عنوان ورودی با

## منابع

1. Abrahart, R.J. and S.M. White. 2001. Modeling sediment transfer in Malawi: Comparing back propagation neural network solutions against a multiple linear regression benchmark using small data set. *Physics and Chemistry of the Earth, part B* 26(1): 19-24.
2. Achite, M. and S. Ouillon. 2007. Suspended sediment transport in a semiarid watershed. *Journal of Hydrology*, 84(3): 187-202.

3. Afkhami, H. 2008. Evaluation and Prediction of Drought in yazd erea Using Artificial Neural Network, M.Sc. Thesis, Yazd University, 177 pp. (In Persian)
4. Akbari, Z. 2010. Estimation of suspended sediment using regression decision trees method (Case study Ilam dam basin). M.Sc. Thesis. Yazd University. 157 pp. (In Persian)
5. Bhattacharya, B., R.K. Price and D.P. Solomatine. 2007. Machine learning approach to modeling sediment transport. *Journal of Hydraulic Engineering*. 133(4): 440-450.
6. Dehgani, A., M. Zanganeh, A. Mosaedi and N. Kohestani. 2009. Comparison Estimate suspended load with two method Sediment Rating curve and Artificial Neural Network (Case Study: Doogh River, Golestan Province). *Issue science agriculture and natrual source. Catena*.
7. Dastorani, M., S. Huges and A. Talebi. 2012. Suspended sediment estimation using Artificial Neural Network (Case Study: Jamyshan watershed in Kermanshah). *The third year of watershed management Journal*, 6: 61-75. (In Persian)
8. Hikmet Kerem, C. and M. Alp. 2006. Generalized regression neural network in Modeling river sediment yield. *Advances in Engineering Software*, 37: 63-68.
9. Khodaverdilo, M., P. Fathi and M. Homayi. 2004. Estimate intelligence moisture curve soil with use from Artificial Neural Network. 2<sup>nd</sup> Conference water and soil resource, SHiraz University. (In Persian)
10. Kia, M. 2011. Neural Network in MATLAB. 3<sup>rd</sup>, Tehran University, 229 pp. (In Persian)
11. Mosaedi, M. and F. Hashemi. 2005. Comparison neural artificial network in product curve sediment. 3<sup>th</sup> Conference national Erosion and Sediment. (In Persian)
12. Najafi, N., M. Heydarpoor and A. Asadi. 2006. comparison curve sediment with estimate model sediment load Zayandehrood river. 7<sup>th</sup> conference international river engineering. (In Persian)
13. Poorshariaty, R. 2011. Application and comparison of Integrated Time Series and Artificial Neural Network models for prediction of the variations of groundwater level (Case study: Marvast Plain). M.Sc. Thesis in Water Management and Natural Resources Engineering, Yazd University. 145 pp. (In Persian)
14. SHirzad, M., A. Lashtneshaei and K. Mohammadi. 2006. used from neural network artificial for estimate sediment on Sipedriver lake. conference national engineering network irrigate and drainage. Ahvaz University. (In Persian)
15. Toloei, S., D. Hossenzadeh, M. GHorbani, A. Fakherifard and F. Salmasi. 2011. Estimate temporal and spatial suspended load river Ajichai with use from Geostatistics and Artificial neural network. *Issue science water and soil*. 21(4): 12-25. (In Persian)
16. Vali, A., M. Ramesht, A. Siff and R. GHazavi. 2011. Comparison efficiency Artificial Neural Network models and regression for prediction flow sediment loud (Case Study: catchment basin Samandegan). *Issue Geografic and Environment Schematization*. 44(4): 19-34. (In Persian)

## Suspended Sediment Estimation using Neural Network and Algorithms Assessment (Case Study: Lorestan Province)

Mohsen Yosefi<sup>1</sup> and Robabeh Poorshariaty<sup>2</sup>

1- M.Sc. Student, Yazd University (Corresponding author: mohsenyosefi67@gmail.com)

2- Graduate Student in, Yazd University

Received: December 4, 2012

Accepted: December 3, 2013

### Abstract

In purpose to performance programs soil protection and reduce sediment, also calculation and design of dam volume in introduction store dams, have necessity that evaluation and calculated the rate of sediment production in a watershed. Generally erosion and sediment transport is of most complex issues the hydrodynamic that not possible simply, determination equations governing because effects of various parameters. About attention in potential artificial intelligence in identify the relationship between variables input and output of a problem without taking the physics of the problem and because swoon of physical models and mathematical in modeling of sedimentary processes too, can be used in modeling sediment transport problem. The purpose of this study was to obtain suitable algorithms with using of artificial neural networks feed-forward back propagation, fitting and Cascade Forward back prop to intent estimate the sediment rate. In this intent for estimate the amount suspended sediment, used of discharge - precipitation and sediment data monthly. Intransitive of recitation that suspended sediment data in the output (Cham anjir station) is more appropriate of the distribution. Among the three networks used in this study was more appropriate to estimate the amount of sediment fitting network. Thirteen the algorithm used in this study was selected TRAINLM as the best algorithm, with a correlation coefficient  $R = 0.99$ ,  $RMSE = 0.01$ .

**Keywords:** Neural Network, Neural Network Algorithms, Suspended Sediment, Lorestan Province