

## قابلیت شبکه‌های عصبی مصنوعی جهت مدل‌سازی چند ایستگاه بار معلق در مقایسه با روش

### منحنی سنج رسوب

محمد تقی اعلمی<sup>۱</sup>، وحید نورانی<sup>۲</sup> و حمید نظم‌آرا<sup>۳</sup>

تاریخ دریافت: ۸۷/۹/۱۸ تاریخ پذیرش: ۸۸/۱۰/۱۵

۱، ۲ و ۳- به ترتیب دانشیار، استادیار و دانشجوی سابق کارشناسی ارشد گروه عمران آب، دانشکده عمران، دانشگاه تبریز

\* مسئول مکاتبه E-mail: [mtaalami@tabrizu.ac.ir](mailto:mtaalami@tabrizu.ac.ir)

### چکیده

رسوبات حمل شده توسط رودخانه می‌تواند باعث بوجود آمدن خساراتی به اراضی کشاورزی و تأسیسات آبی گردد. برآورد صحیح بار رسوب در تأسیسات آبی مانند سدها باعث جلوگیری از صرف هزینه‌های اضافی خواهد شد. کشور ما ایران با دارا بودن رودخانه‌های متعدد، پتانسیل بالایی جهت ایجاد سد دارد. یکی از دلایل آن کاهش یافتن ظرفیت انتقال آب توسط مقطع رودخانه به دلیل انباشتگی رسوبات می‌باشد. لذا بررسی پدیده رسوب و برآورد رسوب حمل شده توسط رودخانه اهمیت خاصی دارد. در این راستا تخمین بار معلق رسوب، توجه مدل‌سازهای شبکه‌های عصبی مصنوعی را به خود معطوف کرده است. در این تحقیق از شبکه‌های عصبی مصنوعی برای برآورد رسوب ایستگاه آخولا واقع بر روی رودخانه آجی‌چای در استان آذربایجان شرقی استفاده شد. اطلاعات این ایستگاه شامل دبی و رسوب روزانه می‌باشد. در مراحل مختلف برآورد اثر ترکیبی عوامل مختلف دبی آب و دبی رسوب در کارایی شبکه، مورد بررسی قرار گرفت. به منظور بررسی تاثیر رسوب و دبی ایستگاه‌های بالادست، علاوه بر داده‌های ایستگاه آخولا از داده‌های ایستگاه‌های ونیار و مرکید نیز برای آموزش شبکه عصبی بکار رفت که بهترین نتیجه را در پی داشت. از روش کلاسیک منحنی سنج نیز برای برآورد رسوب این ایستگاه استفاده گردید. برای بهینه‌سازی ضرایب رگرسیونی منحنی سنج از الگوریتم ژنتیک استفاده شد و البته نتایج بهتری نسبت به روش کلاسیک نداد. با توجه به نتایج بدست آمده تخمین بار رسوب در چند ایستگاه با استفاده از شبکه‌های عصبی، کارایی بهتری داشت.

واژه‌های کلیدی: الگوریتم پسانتشار خطا، بار معلق رسوب، تخمین چند ایستگاه، شبکه‌های عصبی مصنوعی

## Artificial Neural Networks Potential in Multi-Station Modeling of Suspended Load in Comparison with Sediment Rating Curve Method

MT Aalami<sup>1\*</sup>, V Nourani<sup>2</sup> and H Nazamara<sup>3</sup>

<sup>1,2,3</sup>Associate, Assistant Professor and Former Graduate MSc Student, Department of Civil Engineering–Hydraulics, Faculty of Civil Engineering, University of Tabriz, Iran

\*Corresponding author: E-mail: [mtaalami@tabrizu.ac.ir](mailto:mtaalami@tabrizu.ac.ir)

### Abstract

Sediments transported by river may cause damages to cultivated land and hydraulic structures. Accurate estimation of sediment load for hydraulic structures (e.g. dam) can prevent extra costs. Because of the existence of many rivers, our country, Iran, has high potential for dam construction. On the other hand, flood disaster causes huge damage every year. The main reason for magnifying the effects of this disaster can be related to the reduction of water conveyance capacity of the rivers because of sediment deposition. Therefore, the correct estimation of the transported sediment will be highly important. Prediction of the suspended sediment load can be accomplished by the Artificial Neural Networks (ANNs). In this study, ANNs are used to estimate suspended sediment load in Akhola station, located on the Ajichay River in East Azarbaijan, Iran. The available data for this station were daily discharge and sediment load. The ANN sensitivity for these parameters was examined in the modeling. In order to evaluate the effect of the upstream stations load, the data of Markid and Vanyar stations were also used to train the network, which led to more accurate result. The classic rating curve method was also used to estimate the sediment load at this station. To optimize the coefficients of the rating curve, the genetic algorithm was employed, its result of course did not show superiority on the classic optimization method. Regarding these results, multi-station estimation using ANNs has better efficiency.

**Keywords:** Artificial Neural networks, Back propagation algorithm, Multi-station estimation, Suspended sediment load

### مقدمه

رسوبگذاری مخازن در نواحی خشک و نیمه خشک و سرزمین‌هایی چون کشور ما که حتی یک قطره آب را بایستی قدر شناخت بارزتر بوده و از اهمیت ویژه‌ای برخوردار است. یکی از ضروری‌ترین نیازها جهت برنامه‌ریزی‌های منطبق با واقعیت و چاره‌جویی‌های لازم

به دلیل اهمیت ویژه پدیده رسوبگذاری و تخمین بار رسوبی در پروژه‌های آبی و ارتباط تنگاتنگ آن با مسائل اقتصادی تأسیسات آبی، تا کنون تحقیقات فراوانی در زمینه روش‌های برآورد بار رسوب و تأثیر عوامل مختلف بر آن انجام گرفته است. نقش

مقایسه نتایج بدست آمده با روشهای متداول منحنی سنج رسوب و رگرسیون خطی چند متغیره دریافتند که بکارگیری شبکه‌های عصبی در زمینه رسوب کاملاً بر روشهای مذکور برتری دارد. سارنگی و باتاچاریا (2005) توسط دو مدل شبکه عصبی یکی بر مبنای اطلاعات ژئومورفولوژی GANN<sup>4</sup> و دیگری بدون استفاده از داده‌های ژئومورفولوژیکی NGANN<sup>5</sup> به پیش‌بینی غلظت رسوب در حوضه آبریز بانها در هندوستان پرداختند و نتایج بدست آمده را با روش متداول رگرسیونی مقایسه نمودند. در این بررسی معلوم شد که مدل‌های شبکه عصبی پیش‌بینی بهتری نسبت به روش رگرسیون انجام می‌دهد. نتایجی که از تحقیق آنها بدست آمده نشان داد که استفاده از شبکه مبتنی بر ژئومورفولوژی نتایج مطلوبتری بدست می‌دهد که این مسأله بدلیل تأثیر مستقیم خصوصیات زمین، روی تولید رسوب کاملاً منطقی و توجیه‌پذیر است. جیان (2001) از شبکه‌های عصبی مصنوعی برای تخمین رسوب رودخانه می‌سی‌سی‌پی استفاده کرده و نتایج بدست آمده را با داده‌های مشاهداتی دو ایستگاه اندازه‌گیری مقایسه نموده است. نتیجه تحقیق وی بیان می‌دارد که تصحیح عامل اریب<sup>6</sup> تأثیر چندانی در کارایی شبکه ندارد. سگیزاوغلو و کیسی (2006) تأثیر پارامترهای مختلف را برای بهینه کردن کارایی شبکه عصبی بررسی نمودند. در این تحقیق از شبکه RDNN<sup>7</sup> برای آموزش شبکه استفاده کرده و به این نتیجه رسیدند که مسأله وجود مقادیر منفی رسوب برای یک نرون ورودی با استفاده از RDNN حل می‌شود ولی برای بیشتر از یک نرون ورودی، این مشکل همچنان پابرجاست. لین و نامین (2005) با ترکیب شبکه‌های عصبی و یک روش حل

جهت افزایش بازده تاسیسات آبی بررسی بار رسوبی رودخانه‌ها و مقدار رسوبات ته نشین شده در مخازن می‌باشد (اعلمی و همکاران 1381). شبکه‌های عصبی مصنوعی به دلیل قابلیت پاسخ‌گویی به مسائل پیچیده و غیر خطی، به عنوان ابزار جدید در مهندسی آب معرفی شده است. جوابهای منطقی و قابل قبولی که در این زمینه از شبکه‌های عصبی گرفته شده محققین را بر آن داشته است که درصدد استفاده از این ابزار برای تخمین دقیق‌تر بار رسوب باشند. در دهه اخیر تحقیقات متنوعی در زمینه مدل‌سازی رسوب با استفاده از شبکه‌های عصبی مصنوعی صورت گرفته است. راگوانشی و همکاران (2006) از شبکه‌های عصبی مصنوعی برای پیش‌بینی دبی جریان و نیز دبی رسوب روزانه و هفتگی استفاده کردند. آنها از اطلاعات بارش و دمای هوا بعنوان نرونهای لایه ورودی استفاده نمودند و از اطلاعات آماری رودخانه مورد مطالعه، داده‌های 5 سال را برای آموزش شبکه و داده‌های 2 سال باقی مانده را برای صحت سنجی شبکه به کار بردند. آگاروال و همکاران (2005) با استفاده از روش FFBP<sup>1</sup> و با استفاده از روش گرادینان نزولی برای بهینه کردن وزن‌ها به پیش‌بینی رسوب روزانه، هفتگی، ده روزه و ماهانه رودخانه واماسادرا در هند پرداختند. آلپ و سگیزاوغلو (2005) از دو نوع شبکه عصبی FFBP و RBF<sup>2</sup> استفاده کرده و نتایج حاصل را با یک رگرسیون خطی چندگانه مقایسه نموده و به این نتیجه رسیدند که شبکه عصبی شبیه سازی بسیار واقعی‌تری نسبت به رگرسیون خطی چندگانه انجام می‌دهد. سگیزاوغلو و آلپ (2006) از دو الگوریتم آموزشی FFBP و GRNN<sup>3</sup> برای پیش‌بینی رسوب حوضه آبریز جانیاتا در آمریکا استفاده و با

<sup>4</sup>Geomorphological artificial neural network<sup>5</sup>Nongeomorphological artificial neural network<sup>6</sup>Bias<sup>7</sup>Range dependent neural network<sup>1</sup>Feed forward back propagation<sup>2</sup>Radial basis function<sup>3</sup>Generalized regression neural network

### مواد و روش‌ها

رابطه همبستگی بین بار معلق و دبی جریان

با توجه به دشواری استفاده از روابط مختلف بار معلق و اطلاعات متعددی که بعنوان ورودی نیاز دارند، روش دیگری که امروزه برای برآورد بار معلق به کار می‌رود استفاده از روابط رگرسیونی می‌باشد. بر اساس تحقیقات صورت گرفته در این زمینه معلوم شده است که استفاده از یک رابطه توانی بین بار معلق و دبی جریان، نتایج رضایت بخش تری را بدست می‌دهد. لذا می‌توان رابطه بین رسوب و دبی جریان را بصورت زیر نشان داد.

$$Q_s = a \cdot Q_w^b \quad [1]$$

که در آن  $Q_s$  بار معلق،  $Q_w$  دبی جریان، و  $a$  و  $b$  ضرایب ثابت رگرسیونی می‌باشند. بنا به آنچه در ادبیات فنی دیده می‌شود، معمولاً پارامتر  $b$  بین 1/5 تا 2/8 و پارامتر  $a$  بین 0/02 تا 19 در تغییر است و بستگی به مشخصات مواد رسوبی و شرایط جریان دارد (شفاعی بجستان 1384). لازم به ذکر است که منحنی بدست آمده از معادله فوق منحنی سنج رسوب<sup>9</sup> نامیده می‌شود.

### تئوری شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی می‌توانند نگاهت یا تبدیل از فضای چندبعدی به فضای چندبعدی دیگر را انجام دهند و قابلیت‌هایی از قبیل شناسایی الگو، تفکیک الگو، نگاهت غیرخطی، حافظه انجمنی، خودسازمان‌دهی و کنترل را دارا می‌باشند (منهاج 1384). یکی از مهمترین انواع شبکه‌های عصبی، شبکه‌های MLP می‌باشند. این شبکه‌ها از چند لایه تشکیل شده‌اند که در شکل 1 نمونه‌ای از شبکه‌های MLP سه لایه نشان داده شده است. در هر لایه تعدادی نرون در

عددی بر پایه حجم محدود، اقدام به تهیه مدلی برای پیش‌بینی انتقال رسوب در جریان غیر یکنواخت نمودند. آنها با ترکیب این دو روش مدلی را تهیه نمودند که از مزایای هر دو روش حل عددی و شبکه عصبی برخوردار بوده و قادر به ارائه نتایج قابل اعتمادتری برای انتقال بار معلق تحت شرایط پیچیده و عملی بود. منتظر و همکاران (1381) از دو نوع شبکه عصبی پرسپترون چند لایه و شبکه گراسبرگ<sup>8</sup> برای برآورد بار معلق رودخانه بازفت (یکی از سرشاخه‌های مهم کارون) استفاده نمودند و پس از بررسی عملکرد به این نتیجه رسیدند که شبکه پرسپترون چند لایه به علت نگاهت صعودی داده‌ها قادر به تخمین بهتر رسوب برای دبی‌های بزرگ است و می‌تواند در تعیین منحنی و سنج رسوب بکار رود ولی با توجه به اینکه نگاهت گراسبرگ الزاماً صعودی نیست؛ لذا این شبکه برای تهیه منحنی رسوب مناسب بنظر نمی‌رسد. در تحقیق خود به این نکته تصریح کردند که توانایی شبکه‌های عصبی در پردازش موازی عوامل مستقل مؤثر در یک پدیده باعث می‌شود تا سرعت محاسبات بصورت چشمگیری افزایش یابد. آنها بیان داشتند که شبکه‌های عصبی مصنوعی زمانی که آگاهی از طبیعت مسأله زیاد نباشد اما مقدار مثال‌های موجود از مسأله برای آموزش کافی باشد کارکرد مطلوبی دارد و با آموزش شبکه برای بار رسوب، به این نتیجه رسیدند که شبکه‌های عصبی برای غلبه بر طبیعت تصادفی پدیده انتقال رسوب در مقایسه با روشهای متداول عملکرد بهتری دارند. هدف از انجام این پژوهش استفاده از شبکه‌های عصبی مصنوعی برای تخمین چند ایستگاه بار معلق رسوبات رودخانه آجی چای و مقایسه آن با روش منحنی سنج رسوب می‌باشد.

<sup>9</sup>sediment rating curve

<sup>8</sup>Grossberg


اتصالات مابین نرون‌ها است. متداول‌ترین الگوریتم یادگیری این شبکه‌ها، الگوریتم پس‌انتشار خطا است. از پارامترهای طراحی شبکه‌های عصبی می‌توان به معیار کارایی شبکه، تقسیم داده‌ها، پیش‌تحلیل داده‌ها، تعیین ورودی‌های مدل، توابع محرک، تعداد تکرارها و معیار توقف شبکه اشاره کرد. بعد از آموزش، شبکه برای قسمتی دیگر از داده‌ها مورد صحت سنجی قرار می‌گیرد.

#### منطقه مورد مطالعه و داده‌ها

حوضه آبریز آجی چای در قسمت شرقی دریاچه ارومیه بوده و در دامنه‌های شمالی و شرقی ارتفاعات سهند و جنوب سبلان و شمال بزقوش بین عرض جغرافیایی  $37^{\circ}-30'$  تا  $38^{\circ}-30'$  شمالی و طول جغرافیایی  $45^{\circ}-24'$  تا  $47^{\circ}-53'$  شرقی واقع گردیده است (شکل 2). جهت عمومی جریان رودخانه آجی چای شرقی - غربی بوده و مساحت حوضه آبریز آن تا محل تخلیه به دریاچه ارومیه 13850 کیلومتر مربع برآورد شده است. این رودخانه از دامنه‌های جنوبی ارتفاعات سبلان با حداکثر ارتفاع 3882 متر از سطح دریا سرچشمه گرفته و با پیوستن شاخه‌هایی از ارتفاعات بزقوش در جنوب سراب و سهند به آن در جنوب تبریز پس از عبور از پل خورخور در محل تلاقی با جاده جزیره اسلامی وارد ارومیه می‌گردد.

در این پژوهش از داده‌های دبی و رسوب سه ایستگاه مرکید، ونیار و آخولا گرفته شده از سازمان آب منطقه ای استان آذربایجان شرقی استفاده شده است. داده‌های دبی این سه ایستگاه به صورت مرتب موجود است اما برداشت داده‌های رسوب بسیار نامنظم است که این مسأله امر پژوهش را با دشواری‌های زیادی روبرو می‌کند بعنوان نمونه سری زمانی دبی ایستگاه آخولا را می‌توان در شکل 3 مشاهده نمود.

نظر گرفته می‌شود که بوسیلهٔ اتصالات به نرون‌های لایه‌های مجاور وصل می‌شوند. در این شبکه‌ها ورودی مؤثر هر نرون، حاصل ضرب خروجی نرون‌های لایهٔ قبل در وزن‌های میان آن نرون‌ها است. نرون‌های لایهٔ اول اطلاعات ورودی را گرفته و از طریق اتصالات مربوطه به نرون‌های لایهٔ مخفی منتقل می‌کنند. در لایهٔ مخفی پس از محاسبهٔ ورودی مؤثر هر نرون، این ورودی از یک تابع محرک گذرانده می‌شود.



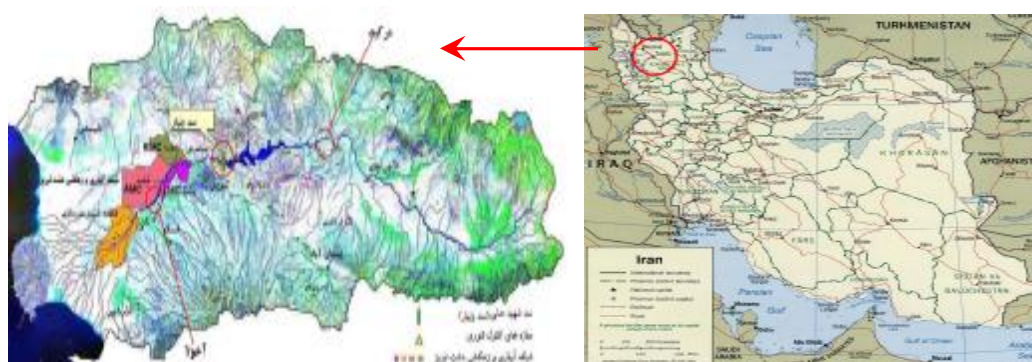
$$a^1 = f^1(IW_{1,1}p + b_1) \quad a^2 = f^2(LW_{2,1}a_1 + b_2) \quad a^3 = f^3(LW_{3,2}a_2 + b_3)$$

شکل ۱ - شبکه عصبی مصنوعی سه لایه


گرایش بیشتر محققان به استفاده از توابع محرک کران‌دار می‌باشد که مشهورترین آنها تابع سیگموئید است. برای هماهنگی بین برد تابع محرک و خروجی شبکه نیاز به نرمال‌سازی داده‌ها می‌باشد. با استفاده از تابع زیر می‌توان داده‌ها را در هر بازهٔ دلخواه نرمال کرد.

$$x'_i = \frac{x_i(B_u - B_L) + x_{\max}B_L - x_{\min}B_u}{x_{\max} - x_{\min}} \quad [2]$$

در این رابطه دسته اطلاعات  $(x_1, x_2, \dots, x_n)$  به بازهٔ دلخواه  $[B_L, B_u]$  نگاشته می‌شوند که  $x_{\max}, x_{\min}$  به ترتیب حداقل و حداکثر داده‌های ورودی می‌باشند. پارامترهای قابل تنظیم در شبکه‌های MLP، وزن اتصالات مابین لایه‌ها است و فرآیند آموزش در این شبکه‌ها، به معنی یافتن مقادیر مناسب برای وزن‌های



شکل ۲- موقعیت حوزه آبریز رودخانه آجی چای



شکل ۳- سری زمانی دبی جریان در ایستگاه آخولا

طی این پژوهش مشکلی از نظر بیش آموزش شبکه پیش نیامد و از طرفی به دلیل کوتاه بودن طول داده ها، در برخی ایستگاه‌ها که اجازه تقسیم داده ها به سه گروه را نمی‌داد؛ برای آموزش شبکه های عصبی مصنوعی، داده-ها به همان دو دسته آموزش و صحت سنجی تقسیم شدند. پس از آزمون و خطا، شبکه عصبی FFBP با الگوریتم آموزشی LM که در مقایسه با دیگر الگوریتم های آموزشی دارای نتایج بهتری بود برای تخمین رسوب بکار گرفته شد. به منظور بررسی اثر محدوده نرمال‌سازی داده‌ها بر عملکرد شبکه، داده ها برای شبکه FFBP در دو بازه (0 و 1) و (0/9 و 0/1) برای سه ساختار دلخواه، نگاشته شده و برای آموزش شبکه عصبی مورد استفاده قرار گرفته اند. با نرمال کردن داده های ورودی در بازه (0/9 و 0/1) نتایج بهتری از شبکه عصبی بدست آمد (جدول 1). به منظور بررسی لگاریتمی بودن داده ها بر روی نتایج شبکه عصبی، با

## نتایج و بحث

در این تحقیق سعی شده است تا رسوب ایستگاه آخولا به روشهای مختلف تخمین زده شده و در نهایت بهترین روش از نظر عملکرد انتخاب گردد که معیار مقایسه ضریب همبستگی  $R^2$  بوده است.

### نتایج شبکه‌های عصبی مصنوعی

برای برآورد رسوب ایستگاه آخولا، ابتدا از داده های دبی و رسوب خود ایستگاه برای آموزش شبکه استفاده شده است. در این مرحله حدود 75 درصد داده ها برای آموزش شبکه و 25 درصد بقیه برای صحت سنجی آن مورد استفاده قرار گرفت؛ لازم به ذکر است که در برخی موارد شبکه های عصبی دچار بیش آموزش می شود لذا برای داده ها علاوه بر دو دسته آموزش و صحت سنجی، دسته سومی به عنوان داده های آزمایش در نظر گرفته می شود اما از آنجا که در

در انتخاب شبکه بهینه است؛ در این تحقیق همواره از یک شبکه عصبی با یک لایه مخفی استفاده شد. برای تخمین چند ایستگاه رسوب در ایستگاه آخولا علاوه بر داده های خود ایستگاه آخولا از داده‌های دبی و رسوب دو ایستگاه ونیار و مرکید که در بالادست این ایستگاه قرار گرفته‌اند برای پیش‌بینی رسوب آخولا استفاده شده است.

نتایج به دست آمده از این روش را نیز می‌توان به صورت خلاصه در جدول ۱ مشاهده کرد. لایه ورودی شامل دبی یا رسوب ایستگاه‌های بالادست و نیز دبی یا رسوب خود ایستگاه آخولا و لایه خروجی، در برگیرنده رسوب ایستگاه آخولا می‌باشد.

همان‌طور که مشاهده می‌شود شبکه عصبی سه ایستگاه نسبت به شبکه عصبی دو ایستگاه دارای نتایج بهتری است که علت این امر را می‌توان به استفاده از داده‌های خود ایستگاه آخولا در لایه ورودی نسبت داد. از نظر آماری نیز رسوب ایستگاه آخولا اصولاً باید با داده‌های همان ایستگاه همبستگی بیشتری داشته باشند. نمودار داده‌های محاسباتی در مقابل داده‌های شبیه‌سازی شده را می‌توان در شکل ۴ مشاهده نمود. این شکل بیانگر عملکرد مناسب شبکه در تخمین چند ایستگاه آخولا است.

مشاهده می‌شود که شبکه‌های عصبی رسوب نسبت به شبکه‌های عصبی دبی عملکرد ضعیف‌تری دارند. که یکی از عوامل مهم این مسئله را شاید بتوان به عدم دقت داده‌های رسوب جمع‌آوری شده در این سه ایستگاه‌ها نسبت داد. بهترین شبکه عصبی آموزش شده به شبکه عصبی سه ایستگاه دبی و ضعیف‌ترین عملکرد نیز به شبکه عصبی دو متغیره (رسوب مرکید و ونیار) تعلق دارد و نتایج بدست آمده از آن حتی از نتایج شبکه عصبی تک متغیره غیر لگاریتمی خود ایستگاه آخولا نیز ضعیف‌تر است. به علت وجود کارگاه سد سازی شهید مدنی در بین دو ایستگاه ونیار و آخولا، خاکریزهایی که عمدتاً در کنار رودخانه قرار دارند و تاثیرات ناشی از

ثابت نگاه داشتن سایر پارامترها از جمله محدوده نرمال سازی (0/9 و 0/1) و الگوریتم آموزش شبکه برای شبکه‌های FFBP (LM)، داده‌های ورودی و خروجی به دو صورت خام (غیر لگاریتمی) و لگاریتمی برای آموزش شبکه استفاده شده‌اند نتایج نشان می‌دهد که وارد کردن داده‌ها بصورت لگاریتمی تاثیر چشمگیری در بهبود عملکرد شبکه داشته است (جدول ۱). علت این امر را می‌توان به ایست شدن داده‌ها پس از تبدیل لگاریتمی آنها، نسبت داد. همان‌طور که قبلاً اشاره شد به علت پراکندگی، داده‌های رسوب واریانس بالایی دارند که این امر باعث می‌شود شبکه در تعمیم آنچه فرا گرفته است با مشکل مواجه شود. لگاریتمی کردن داده‌ها با کاهش پراکندگی داده‌ها و انحراف از معیار آنها موجب افزایش کارایی شبکه عصبی می‌گردد. لذا با توجه به این نتیجه در ادامه تحقیق از داده‌های لگاریتمی استفاده شد. علاوه بر موارد بالا تلاش گردیده تا اثر لایه‌های میانی بیشتر (بیشتر از یک لایه) بر روی کارایی شبکه در تخمین رسوب مورد بررسی قرار گیرد لذا با افزایش لایه‌های میانی شبکه به 2 و 3 لایه، شبکه دوباره آموزش دیده و کارایی آن در مقایسه با شبکه با یک لایه میانی ارزیابی گردیده است. اگرچه افزوده شدن تعداد لایه‌های میانی موجب بهبود روند آموزش شبکه می‌شود ولی مشاهده می‌شود که هر چه تعداد لایه‌های میانی بیشتر شود ضریب همبستگی صحت سنجی کمتر می‌شود (جدول ۱). این قضیه را شاید بتوان اینگونه تفسیر کرد که با افزایش تعداد لایه‌های میانی، برآزش دقیق‌تری روی داده‌ها صورت می‌گیرد (افزایش ضریب همبستگی آموزش و کاهش خطای آموزش). این امر باعث می‌شود تا توانایی شبکه برای تعمیم مدل برآزش داده شده کاهش یابد و این به معنی کاهش ضریب همبستگی و افزایش خطای صحت سنجی است (مهدی‌زاده 1383). علاوه بر این، زمان شبیه‌سازی در مقایسه با حالتی که شبکه دارای یک لایه مخفی است بسیار افزایش می‌یابد. لذا با توجه به اینکه زمان انجام محاسبات نیز از عوامل موثر

خاصی به هم ندارند. عدم کارایی برای بهینه‌سازی منحنی توانی، قابل توجه به نظر می‌رسد. از طرفی الگوریتم ژنتیک معمولاً برای مسائل پیچیده با نقاط بحرانی متعدد عملکرد بهتری داشته است حال آنکه تخمین پارامترهای منحنی توانی مسأله ساده‌ایست که روشهای کلاسیک بهینه‌سازی می‌توانند به خوبی از عهده آن برآیند.

#### رگرسیون خطی چند متغیره

رگرسیون خطی چند متغیره نیز از روشهایی است که برای پیش‌بینی پدیده رسوب مورد استفاده قرار می‌گیرد. در حالت کلی رابطه رگرسیون خطی به صورت  $Y = \sum_{i=1}^n a_i X_i$  می‌باشد که در آن  $Y$  متغیر وابسته (رسوب)،  $a_i$  ضریب رگرسیونی،  $n$  تعداد داده‌ها و  $X_i$  متغیر مستقل می‌باشد که ضرایب رگرسیونی با کمینه کردن خطای مربعات بدست می‌آید. رسوب ایستگاه آخولا با ترکیبات مختلف و دبی به عنوان ورودی، به صورت چند ایستگاه محاسبه شده و با نتایج شبکه‌های عصبی مصنوعی مورد مقایسه قرار گرفت. با توجه به نتایج بدست آمده مشاهده گردید که استفاده از داده‌ها به صورت لگاریتمی در مورد رگرسیون خطی نیز نتایج مطلوب تری دارد. لذا برای مقایسه با شبکه‌های عصبی از نتایج حاصل از داده‌های لگاریتمی استفاده شده است. مشاهده می‌شود برای بهینه‌ترین مدل، ضریب همبستگی صحت سنجی برابر 0/8858 می‌باشد. مقایسه این مقدار با ضریب همبستگی صحت سنجی شبکه عصبی یعنی مقدار 0/9235 نشان دهنده کارکرد بهتر مدل شبکه عصبی برای این ایستگاه می‌باشد.

#### نتیجه‌گیری و پیشنهادات

در این تحقیق رسوب ایستگاه آخولا با استفاده از شبکه‌های عصبی مصنوعی، روش متداول منحنی سنج و منحنی توانی بهینه‌سازی شده توسط الگوریتم ژنتیک

عملیات اجرایی را می‌توان به عنوان یکی از عوامل ناهمگنی داده‌های رسوب ایستگاه آخولا دانست. به هر حال تصمیم‌گیری در مورد اینکه کدام عامل و به چه میزانی باعث این ناهمگنی شده، مسأله‌ای است که نیاز به اطلاعات دقیقتری در این مورد دارد که به دلیل عدم وجود چنین اطلاعاتی تنها به بیان این فرضیه بسنده می‌شود.

#### مقایسه با روش منحنی سنج رسوب

رسوب ایستگاه آخولا با روش متداول منحنی سنج رسوب نیز تخمین زده شده است. منحنی برازش شده دارای معادله  $Q_s = 0.9373 Q_w^{0.972}$  بوده و ضریب همبستگی صحت‌سنجی برای آن مساوی 0/8731 می‌باشد (شکل 5). همانگونه که دیده می‌شود نتایج این روش نسبت به نتایج شبکه‌های عصبی ضعیف‌تر است. در جهت تلاش برای برازش منحنی توانی بهتر بر داده‌های دبی و رسوب سعی شده تا از ابزار الگوریتم ژنتیک، به منظور تخمین ضرایب رگرسیونی منحنی توانی استفاده شود. برای این کار از جعبه ابزار الگوریتم ژنتیک نرم افزار MATLAB بهره گرفته شده و پارامترهای پیش فرض نرم‌افزار برای اجرای برنامه پذیرفته شده و تابع هدف طوری تعریف شده است که ضریب همبستگی را بیشینه کند اما از آنجا که نرم افزار MATLAB برای بهینه‌سازی توابع، تنها قادر به کمینه کردن آنهاست لذا تابع هدف در عدد 1- ضرب شده است. با استفاده از این ابزار، رابطه میان دبی و رسوب برای ایستگاه مرکید به صورت  $Q_s = 1.5214 Q_w^{3.9017}$  تخمین زده شد. ضریب همبستگی آن 0/5511 بود. مشاهده می‌شود نتیجه بدست آمده نسبت به ضریب همبستگی صحت سنجی منحنی سنج رسوب (0/8731) کمتر است. استفاده از الگوریتم ژنتیک برای بهینه‌سازی توابع، زمانی موثر است که پارامترهای مختلف آن تابع دارای اثر متقابل روی هم باشند (مهدی‌زاده 1383); اما از آنجایی که ضرایب منحنی توانی ( $a$ ,  $b$ ) وابستگی



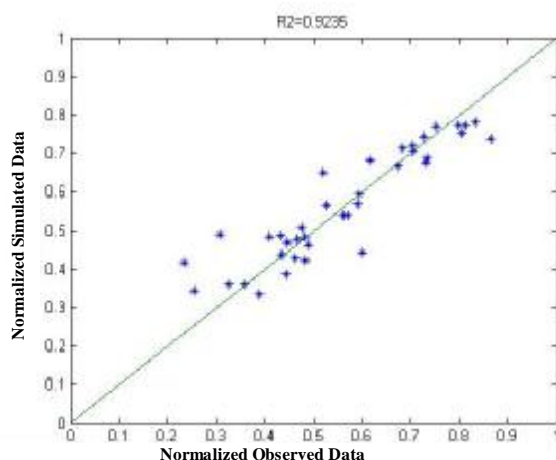
تخمین زده شده است که به طور خلاصه می‌توان نتایج حاصله را به صورت زیر ارائه نمود:

1- شبکه عصبی FFBP با الگوریتم آموزشی LM دارای نتایج بهتری نسبت به سایر انواع شبکه عصبی بود.


2- با نرمال کردن داده های ورودی در بازه (0/9 و 0/1) نتایج بهتری از شبکه عصبی بدست آمد.

جدول ۱- نتایج شبکه های عصبی آموزش داده شده برای برآورد رسوب در ایستگاه آخولا

| ورودی شبکه                        | ساختار شبکه | بازه نرمال سازی | الگوریتم آموزش | ضریب همبستگی صحت سنجی |
|-----------------------------------|-------------|-----------------|----------------|-----------------------|
| $Q_t$ (غیر لگاریتمی)              | ۱-۳-۱       | (۰ و ۱)         | LM             | ۰/۶۵۹۰                |
| $Q_t$ (لگاریتمی)                  | ۱-۳-۱       | (۰/۱ و ۰/۹)     | LM             | ۰/۸۸۱۳                |
| $Q_t$ (لگاریتمی)                  | ۱-۳-۱       | (۰/۱ و ۰/۹)     | LM             | ۰/۸۷۶۲                |
| $Q_t$ (لگاریتمی)                  | ۱-۳-۱       | (۰/۱ و ۰/۹)     | LM             | ۰/۸۸۱۳                |
| $Q_t$ (لگاریتمی)                  | ۱-۸-۱       | (۰/۱ و ۰/۹)     | GDX            | ۰/۸۸۳۰                |
| $Q_t$ (لگاریتمی)                  | ۱-۵-۱       | (۰/۱ و ۰/۹)     | RP             | ۰/۸۸۳۵                |
| $Q_t$ (لگاریتمی)                  | ۱-۳-۱       | (۰/۱ و ۰/۹)     | CGB            | ۰/۸۷۸۷                |
| $Q_t$ (لگاریتمی)                  | ۱-۳-۱       | (۰/۱ و ۰/۹)     | SCG            | ۰/۸۷۸۵                |
| $Q_t$ (لگاریتمی)                  | ۱-۸-۱       | (۰/۱ و ۰/۹)     | BFG            | ۰/۸۷۷۶                |
| $Q_t$ (لگاریتمی)                  | ۱-۹-۱       | (۰/۱ و ۰/۹)     | OSS            | ۰/۸۸۳۲                |
| $Q_t$ (لگاریتمی)                  | ۱-۳-۱       | (۰/۱ و ۰/۹)     | LM             | ۰/۸۸۱۳                |
| $Q_t$ (لگاریتمی)                  | ۱-۹-۱       | (۰/۱ و ۰/۹)     | BR             | ۰/۸۷۵۷                |
| $Q_t$ (لگاریتمی)                  | ۱-۳-۱       | (۰/۱ و ۰/۹)     | LM             | ۰/۸۸۱۳                |
| $Q_t$ (لگاریتمی)                  | ۱-۳-۶-۱     | (۰/۱ و ۰/۹)     | LM             | ۰/۸۸۰۴                |
| $Q_t$ (لگاریتمی)                  | ۱-۴-۸-۹-۱   | (۰/۱ و ۰/۹)     | LM             | ۰/۸۷۹۴                |
| $Q_t$ مرکب و $Q_t$ و نیار         | ۲-۸-۱       | (۰/۱ و ۰/۹)     | LM             | ۰/۸۶۷۲                |
| $Q_t$ مرکب و $Q_t$ و نیار و $Q_t$ | ۳-۶-۱       | (۰/۱ و ۰/۹)     | LM             | ۰/۹۲۳۵                |
| $Q_s$ مرکب و $Q_s$ و نیار         | ۲-۷-۱       | (۰/۱ و ۰/۹)     | LM             | ۰/۶۰۶۶                |
| $Q_s$ مرکب و $Q_s$ و نیار و $Q_s$ | ۳-۶-۱       | (۰/۱ و ۰/۹)     | LM             | ۰/۸۸۴۲                |



شکل ۴- نمودار پراکندگی داده های محاسباتی و مشاهداتی رسوب برای تخمین چند ایستگاه رسوب در آخولا



شکل ۵- منحنی سنج رسوب در ایستگاه آخولا

0/9235 افزایش یافت. همانگونه که مشاهده می شود بهترین نتایج متعلق به شبکه عصبی سه ایستگاهه دبی می باشد.

5- استفاده از الگوریتم ژنتیک برای بهینه سازی ضرایب منحنی توانی به علت عدم وابستگی خاص ضرایب رگرسیونی منحنی توانی به همدیگر، عملکرد مطلوبی به همراه نداشت.

برای تحقیقات آینده می توان مواردی را به صورت زیر پیشنهاد کرد:

3- شبکه های عصبی مصنوعی کارایی بهتری در تخمین پدیده رسوب ایستگاه آخولا نسبت به روش های دیگر دارد که دال بر توانایی شبکه های عصبی مصنوعی در مدل سازی پدیده های غیر خطی از جمله مسئله رسوب است.

4- استفاده از اطلاعات ایستگاههای بالادست برای تخمین چند ایستگاه آخولا باعث افزایش کارایی شبکه های عصبی برای این ایستگاه گردید. به طوریکه ضریب همبستگی صحت سنجی آن از 0/8813 به

- الف - استفاده از یک شبکه با قابلیت تشخیص الگو برای تهیه یک مدل جامع برای برآورد رسوب رودخانه آجی چای در هر نقطه از آن استفاده شود.
- ب - مقایسه نتایج شبکه های عصبی با سایر مدل‌های تفهیمی از جمله سری‌های زمانی، رگرسیون غیرخطی چند متغیره و ... صورت گیرد.
- ج - علاوه بر تخمین چند ایستگاه با استفاده از داده‌های دبی ایستگاه‌های مختلف از پارامترهای دیگری مانند شیب رودخانه، دما، قطر ذرات رسوب و ... نیز به عنوان ورودی شبکه‌های عصبی مصنوعی استفاده گردد.

#### منابع مورد استفاده

- اعلمی م ت، حسن‌زاده ی، فاخری فرد ا، 1381. شبیه سازی رسوبگذاری در مخازن سدهای ذخیره ای با استفاده از مدل لوله جریان، مجله دانشکده فنی دانشگاه تبریز، جلد 28، شماره 3، 9-1.
- شفاعی بجستان م، 1384. هیدرولیک رسوب. انتشارات دانشگاه شهید چمران (اهواز)، چاپ سوم.
- منتظرغ، ذاکر مشفق م و قدسیان م، 1381. تخمین خبره رسوب رودخانه بازفت به کمک شبکه عصبی مصنوعی. ششمین کنفرانس بین المللی مهندسی رودخانه، دانشگاه شهید چمران اهواز، 8-1.
- منهاج م، 1384. مبانی شبکه های عصبی (هوش محاسباتی). انتشارات دانشگاه صنعتی امیرکبیر، چاپ سوم.
- مهدی زاده م، 1383. شبکه های عصبی مصنوعی و کاربرد آن در مهندسی عمران. انتشارات عبادی، چاپ اول.
- Agarwal A, Singh RD and Bhunya PK, 2005. ANN-based sediment yield models for Vamasadhara river basin (India). *Water SA* 31: 95-100.
- Alp M and Cigizoglu HK, 2005. Suspended sediment load simulation by two artificial neural network methods using hydro meteorological data. *J. of Environmental Modeling and Software* 22: 2-13.
- Cigizoglu HK and Alp M, 2006. Generalized regression neural network in modeling river sediment yield. *J. of Advances in Engineering Software* 37: 63-68.
- Cigizoglu HK and Kisi O, 2006. Methods to improve the neural network performance in suspended sediment estimation. *J. of Hydrology* 317: 221-238.
- Jian SK, 2001. Development of integrated sediment rating curves using ANNs. *J of Hydraulic Engineering* 127-1: 30-37.
- Lin B and Namin MN 2005. Modeling suspended sediment transport using an integrated numerical and ANNs. *J. of Hydraulic Research* 43-3: 302-310.
- Raghuwanshi NS, Singh R and Reddy LS, 2006. Runoff and sediment yield modeling using artificial neural network: upper Siwane River, India. *J. of Hydrologic Engineering* 11-1: 71-79.
- Sarangi A and Bhattacharya AK, 2005. Comparison of artificial neural network and regression models for sediment loss prediction from Banha watershed in India. *J of Agricultural Water Management* 78: 195-208.