

## گزارش فنی

# مدل شبکه عصبی مصنوعی پرسپترون چند لایه برای پیش‌بینی دبی روزانه بار معلق رسوب و ارزیابی عوامل موثر در برآورد رسوب

میترا تنهاپور<sup>۱</sup> و محمدابراهیم بنی‌حبیب<sup>۲\*</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد سازه‌های آبی، پردیس ابوریحان، دانشگاه تهران و <sup>۲</sup> دانشیار گروه مهندسی آبیاری زهکشی، پردیس ابوریحان، دانشگاه تهران، پردیس ابوریحان

تاریخ پذیرش: ۱۳۹۶/۰۲/۲۳

تاریخ دریافت: ۱۳۹۵/۰۸/۰۳

### چکیده

پیش‌بینی مقدار رسوب در طرح‌های مهندسی منابع آب نظیر تأسیسات تنظیم و انحراف جریان و سدهای مخزنی از عوامل مهم در تعیین عمر مفید و بررسی عملکرد آن‌ها است. در این تحقیق مدلی برای تخمین دبی روزانه رسوب، با استفاده از مدل شبکه عصبی پرسپترون چند لایه با الگوریتم یادگیری پس انتشار خطا ارائه شد و عملکرد مدل با مدل رگرسیون غیرخطی چند متغیره و منحنی‌سنجه رسوب در مراحل آموزش و آزمون مقایسه شد. بدین منظور از داده‌های دبی لحظه‌ای، بارش، شماره روز در سال و دبی آب در روز قبل در محدوده سال‌های ۱۳۸۸-۱۳۶۹ در ایستگاه پل زغال واقع در حوضه رودخانه چالوس استفاده شد. نتایج حاصل از آزمون ترکیب مختلف مجموعه داده‌های ورودی نشان داد، ابتدا پارامتر دبی لحظه‌ای، سپس دبی روز قبل و در نهایت عوامل بارش و شماره روز سال به ترتیب بیشترین تأثیر را در عملکرد مدل دارند، این نتایج تطابق نسبتاً خوبی با نتایج حاصل از آنالیز ضرایب استاندارد شده مدل رگرسیونی دارد. برای مقایسه ساختارهای مختلف شبکه عصبی از معیارهای ضریب تبیین ( $R^2$ ) و جذر میانگین مربع خطا (RMSE) استفاده شد. بدین ترتیب با حذف متغیر شماره روز سال، بهترین شبکه با ساختار ۱-۵-۳ و مقادیر  $R^2 = 0/89$  و  $RMSE = 0/02$  به دست آمد. نتایج حاصل از مقایسه مدل‌ها نشان داد، در مرحله آموزش و آزمون به ترتیب روش منحنی‌سنجه و مدل شبکه عصبی بهترین عملکرد را به خود اختصاص داده‌اند و مدل شبکه عصبی مقدار ضریب همبستگی را تقریباً ۱۶ درصد نسبت به دو روش دیگر افزایش داد. با استفاده از نتایج این تحقیق، عوامل موثر بر تخمین دبی رسوب شناسایی شده و می‌توان در پروژه‌ها، با صرف وقت و هزینه کمتر برآورد دقیق‌تری از دبی رسوب داشت.

**واژه‌های کلیدی:** الگوریتم پس انتشار خطا، دبی لحظه‌ای، مدل رگرسیون غیرخطی چندگانه، مدل هوش مصنوعی، منحنی‌سنجه رسوب

### مقدمه

پروژه‌ها و برنامه‌ریزی‌های مدیریت منابع آب، به لحاظ محافظت از زیرساخت‌های آبی نظیر کانال‌ها و سدها و نیز کاهش ظرفیت ذخیره مخازن و کیفیت آب از اهمیت بالایی برخوردار است. لذا با توجه به این موارد،

یکی از مهمترین مخاطرات زیست محیطی، پدیده فرسایش و رسوب‌گذاری در حوزه‌های آبخیز است. برآورد دقیق دبی رسوب در حوضه‌ها، برای بسیاری از

انتشار خطا<sup>۳</sup> و الگوریتم یادگیری Levenberg-marquardt و تابع پایه شعاعی<sup>۴</sup>، منطق فازی<sup>۵</sup> و الگوریتم درخت تصمیم‌گیری مانند M<sub>5</sub> استفاده کرد. نتایج پژوهش آن‌ها بیانگر عملکرد بهتر مدل M<sub>5</sub> نسبت به دیگر مدل‌ها بود. همچنین، محققانی نظیر Cigizoglu (۲۰۰۲)، Cimen (۲۰۰۸)، Tayfur (۲۰۰۲)، Mustafa (۲۰۱۱) و Raghuvanshi (۲۰۰۶) مطالعات مشابهی در این زمینه انجام دادند. ولی هیچ یک اثر عوامل مختلف برای برآورد دبی رسوب را ارزیابی ننموده و در نظر نگرفتند.

پژوهشگران زیادی در سراسر جهان از شبکه عصبی به‌منظور پیش‌بینی بار معلق رسوبات استفاده کردند و نتایج آن را با مدل‌های مختلف مانند منحنی‌سنجه رسوب و دیگر مدل‌ها مقایسه کردند. اما مطالعات کافی در زمینه تعیین بهترین ترکیب داده‌های ورودی به‌منظور پیش‌بینی میزان بار معلق رسوب صورت نگرفته است. در تحقیق حاضر علاوه بر پیش‌بینی دبی روزانه رسوب برای ایستگاه پل زغال واقع در رودخانه چالوس، با استفاده از شبکه عصبی، بهترین نوع معماری شبکه و بهترین ترکیب داده‌های ورودی، با تغییر تعداد داده‌های ورودی به شبکه تعیین شده است و دقت عملکرد مدل شبکه عصبی در هر یک از مراحل آموزش و آزمون با روش منحنی‌سنجه رسوب و مدل رگرسیون غیرخطی چندمتغیره<sup>۶</sup>، مقایسه شده است. همچنین، با استفاده از ضرایب استاندارد شده مدل رگرسیونی میزان تأثیر هر یک از عوامل ورودی در برآورد دبی رسوب ارزیابی، و با نتایج مدل شبکه عصبی مقایسه شده است.

### مواد و روش

**منطقه مورد مطالعه:** رودخانه چالوس در استان مازندران و جنوب شهرستان چالوس واقع شده است. این رودخانه دائمی بوده، از دامنه شمالی ارتفاعات کندوان و طالقان سرچشمه گرفته و در نزدیکی ده فرج‌آباد به دریای خزر می‌ریزد. این حوزه آبخیز دارای

می‌توان به اهمیت پیش‌بینی میزان بار معلق رسوب در آبراهه‌ها به‌عنوان یکی از مهمترین موضوعاتی که آگاهی از آن، لازمه هر طرح مهندسی رودخانه و هیدرولوژی است، پی برد.

متأسفانه، برای رودخانه‌ها در بسیاری از نقاط جهان، اندازه‌گیری دقیق رسوبات به‌دلیل نیاز به تجهیزات خاص و هزینه نسبتاً زیاد رسوب‌سنجی امکان‌پذیر نیست. بنابراین تخمین مقدار بار رسوب، به‌دلیل کمبود اطلاعات و دشواری اندازه‌گیری مستقیم روزانه، از مسائل پیچیده در مهندسی رودخانه به‌شمار رفته و یک موضوع چالش‌برانگیز است (Melesse و همکاران، ۲۰۱۱؛ Tachi و همکاران، ۲۰۱۶). برای مقابله با این مشکلات، مدل‌های تجربی زیادی، به‌منظور برآورد دبی رسوبات معلق حوضه‌ها توسعه یافته است. منحنی‌سنجه رسوب<sup>۱</sup> (SRC) یکی از ساده‌ترین مدل تجربی است که عمدتاً به‌وسیله محققین مورد استفاده قرار می‌گیرد. به‌منظور کاهش خطای روش‌های منحنی‌سنجه رسوب، محققان از ضرایب تصحیح مختلف استفاده کردند. از سوی دیگر دقت پایین و محدودیت‌های مدل‌های تجربی محققان را به استفاده از مدل‌های هوشمند نظیر شبکه‌های عصبی مصنوعی وادار نموده است (Barzegari و همکاران، ۲۰۱۶). این روش علاوه بر بهبود مطالعات هیدرولوژی و رسوب‌شناسی به دلایلی مانند پیش‌بینی دقیق و سریع، توانایی تشخیص ارتباط بین داده‌های ورودی و خروجی و پایداری مدل در برابر داده‌های غیرقابل اعتماد، نسبت به روش‌های دیگر ارجحیت دارد (Dastorani و Afkhami، ۲۰۱۱).

Banihabib و Emami (۲۰۰۵)، از مدل شبکه عصبی برای تخمین آورد رسوب استفاده کردند و نتایج آن را با مدل منطقه‌ای برآورد رسوب مقایسه کردند. یافته‌های آن‌ها نشان داد، مدل شبکه عصبی دقت قابل ملاحظه‌ای نسبت به سایر مدل‌ها دارد. Kumar و همکاران (۲۰۱۵)، به‌منظور پیش‌بینی غلظت رسوبات معلق حوضه رود ستلج<sup>۲</sup> واقع در شمال هند، از مدل‌های شبکه عصبی مصنوعی با روش پس

<sup>3</sup> Error back propagation

<sup>4</sup> Radial basis function

<sup>5</sup> Fuzzy Logic

<sup>6</sup> Multiple Non-Linear Regression (MNLr)

<sup>1</sup> Sediment Rating Curve (SRC)

<sup>2</sup> Sutlej basin


به‌عنوان متغیر خروجی در محدوده سال‌های ۱۳۸۸-۱۳۶۹ استفاده شده است. به‌علت تعدد عوامل ورودی و واحدهای اندازه‌گیری آن‌ها و اطمینان از کارکرد یکسان کلیه متغیرها، نرمالیزه کردن داده‌های ورودی قبل از آموزش شبکه، ضرورت دارد. بدین منظور از رابطه (۱) برای نرمال کردن داده‌ها استفاده شده است.

$$X_n = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

که در آن،  $X_n$  نشانگر داده‌های استاندارد شده،  $X_i$  نمایانگر داده‌های مشاهداتی و  $X_{\max}$  و  $X_{\min}$  به ترتیب بیانگر بیشینه و کمینه داده‌ها است.

مساحت ۱۵۴۴/۰۷ کیلومتر مربع و بیشینه و کمینه ارتفاع آن به ترتیب ۴۲۳۹ و ۲۱۲۵ متر است و در محدوده عرض جغرافیایی "۳۷° ۳۰' ۳۶" شمالی و طول جغرافیایی "۵۱° ۲۰' ۰۱" شرقی قرار دارد (Jowkar Sarhangi و همکاران، ۲۰۰۸). شکل ۱، موقعیت رودخانه چالوس و ایستگاه هیدرومتری پل-زغال را نشان می‌دهد.

**داده‌های مورد استفاده:** در این تحقیق، به‌منظور تخمین دبی روزانه رسوب در ایستگاه پل زغال، از ۳۸۷ داده شامل دبی لحظه‌ای (متر مکعب بر ثانیه)، دبی روز قبل (متر مکعب بر ثانیه)، بارش تجمعی همان روز تا سه روز قبل (میلی‌متر) و شماره روز در سال به‌عنوان عوامل ورودی و دبی رسوب (تن در روز)



شکل ۱- موقعیت رودخانه چالوس

ورودی، لایه پنهان و لایه خروجی دارد. انواع مدل‌های شبکه عصبی و روش‌های یادگیری وجود دارد. دو نوع شبکه عصبی که عمدتاً به‌منظور پیش‌بینی مورد استفاده قرار می‌گیرند با عنوان شبکه‌های پیشخور<sup>۱</sup> و شبکه‌های پسخور<sup>۲</sup> شناخته می‌شوند. شبکه پرسپترون چند لایه<sup>۳</sup> (MLP) یکی از انواع شبکه‌های پیشخور است. در این شبکه‌ها عملیات یادگیری و پردازش داده‌ها به سمت جلو از سمت لایه ورودی به لایه خروجی صورت می‌گیرد. هر دو شبکه مذکور با استفاده از الگوریتم پس انتشار خطا آموزش داده می‌شوند (Afkhami و Dastorani، ۲۰۱۱).

**منحنی‌سنجه رسوب:** منحنی‌سنجه رسوب اساساً برای ارزیابی مستقیم فرایند تغییرات حمل رسوبات معلق و به‌طور غیرمستقیم به‌منظور تخمین بار کل رسوب استفاده می‌شود، این منحنی به‌صورت رابطه آماری بین غلظت رسوبات معلق یا بار رسوب ( $Q_s$ ) و دبی جریان ( $Q_w$ ) تعریف می‌شود (Thomas، ۱۹۸۸). در این رابطه ضرایب  $a$  و  $b$  از طریق رگرسیون خطی بین داده‌های لگاریتم دبی آب و دبی رسوب تعیین می‌شود. معادله این منحنی به شکل زیر نشان داده می‌شود.

$$Q_s = a Q_w^b \quad (2)$$

**شبکه عصبی مصنوعی:** شبکه عصبی مصنوعی یک سامانه پردازش اطلاعات است. شبکه مورد استفاده در این تحقیق، ساختاری لایه‌ای تحت عناوین لایه

<sup>1</sup> Feed-forward network

<sup>2</sup> Recurrent networks

<sup>3</sup> MultiLayer Perceptron (MLP)

معیارها به صورت زیر است.

$$R^2 = \frac{\sum((x_p - \bar{x}_p) \times (x_o - \bar{x}_o))}{\sqrt{(\sum(x_p - \bar{x}_p)^2) \times (\sum(x_o - \bar{x}_o)^2)}} \quad (۳)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_p - x_o)^2} \quad (۴)$$

که در آن‌ها،  $x_p$  مقادیر پیش‌بینی شده و  $x_o$  مقادیر مشاهده شده و  $n$  معرف تعداد داده‌ها است.

**ارزیابی ترکیب مختلف داده‌های ورودی در برآورد دبی رسوب:** هدف از این مرحله از تحقیق، شناسایی ساختار بهینه شبکه با تغییر تعداد داده‌های ورودی و تعداد نرون لایه پنهان است. در واقع سعی بر این است، با در نظر گرفتن ترکیب مختلفی از داده‌های ورودی در هر مرحله، پارامتری که اثر کمتری در پیش‌بینی دبی رسوب داشته است، شناسایی شده و در مرحله بعد، عملکرد مدل بدون در نظر گرفتن عامل شناخته شده بررسی شود. بدین ترتیب با اندازه‌گیری تعداد عوامل کمتر و صرف وقت و هزینه کمتر می‌توان با استفاده از مدل، برآورد دقیق‌تری از میزان دبی رسوب در روزهای فاقد آمار داشت. بدین منظور هفت ساختار بهینه با در نظر گرفتن ترکیب مختلفی از عوامل ورودی، شناخته شد. تعداد عوامل ورودی استفاده شده در هر شبکه مطابق با جدول ۱ است.

در مطالعه حاضر از شبکه MLP با الگوریتم یادگیری پس انتشار خطا و تابع محرک سیگموئید در لایه پنهان استفاده شده است که با استفاده از نرم‌افزار MATLAB شبیه‌سازی شده است. ضمناً در این شبکه ۷۰ درصد داده‌ها (۲۷۱ داده) برای آموزش، ۱۵ درصد (۵۸ داده) اعتبارسنجی و ۱۵ درصد (۵۸ داده) به آزمون اختصاص داده شده است. متغیرهای ورودی شامل دبی لحظه‌ای، دبی آب در روز قبل، بارش و شماره روز در سال است که برابر تعداد نرون‌های لایه ورودی است و لایه خروجی دارای یک نرون تحت عنوان دبی رسوب می‌باشد. همچنین، تعداد نرون‌ها در لایه پنهان از طریق سعی و خطا و به منظور رسیدن به ساختار بهینه با بیشینه دقت به دست آمده است. بدین منظور شبکه‌های مختلف با ترکیب مختلف داده‌های ورودی (جدول ۱) و تغییر تعداد نرون‌های لایه پنهان برای هر شبکه مورد آزمایش قرار گرفت (جدول ۲) و نهایتاً بهترین معماری شبکه با توجه به بهترین مقادیر شاخص‌های ارزیابی شناسایی شد.

به منظور ارزیابی عملکرد مدل، از دو شاخص ضریب تبیین ( $R^2$ ) و جذر میانگین مربعات خطا (RMSE) استفاده شده است. روابط مربوط به این

جدول ۱- ترکیب مختلف ساختارهای مدل

شبکه عوامل	۱	۲	۳	۴	۵	۶	۷
دبی لحظه‌ای	✓	×	✓	✓	✓	✓	✓
دبی روز قبل	✓	✓	×	✓	✓	✓	×
بارش	✓	✓	✓	×	✓	×	✓
شماره روز سال	✓	✓	✓	✓	×	×	×

## نتایج و بحث

منحنی‌سنجه رسوب و مدل رگرسیون غیرخطی چندمتغیره مقایسه شده است. در جدول ۲، مقادیر  $R^2$  و RMSE حاصل از بهترین ساختار شبکه عصبی در مرحله آزمون، با هفت ترکیب متفاوت از داده‌های ورودی، نشان داده شده است. تعداد عوامل ورودی لحاظ شده در هر شبکه، در جدول ۱ نشان داده شده است.

مطابق جدول فوق، در شبکه دوم تا پنجم، در هر شبکه به ترتیب یکی از عوامل ورودی حذف شده تا اثر آن در خروجی مسئله بررسی شود. با مقایسه شبکه‌ها

در این بخش با تغییر تعداد داده‌های ورودی در مدل، تاثیر هر یک از عوامل در برآورد دبی رسوب مورد ارزیابی قرار گرفته، برای هر شبکه با تغییر تعداد نرون‌های لایه پنهان در نهایت بهترین ساختار شبکه با کمترین خطا شناسایی شد. بدین ترتیب نتایج حاصل از تاثیر هر یک از عوامل در خروجی مدل با تحلیل ضرایب استاندارد شده مدل رگرسیونی با استفاده از نرم‌افزار SPSS مقایسه شده و دقت عملکرد مدل به تفکیک هر یک از مراحل آموزش و آزمون با

و امکان مقایسه آن‌ها وجود دارد. در حقیقت این ضرایب نشان‌دهنده میزان تغییر در متغیر وابسته به از تغییر به اندازه یک انحراف معیار در متغیر مستقل است. هر چه، قدرمطلق این ضریب بزرگ‌تر باشد، رابطه قوی‌تر بین متغیر وابسته و مستقل را نشان می‌دهد (Momeni و Ghayomi, ۲۰۱۱). مطابق جدول زیر، عوامل دبی لحظه‌ای، دبی روز قبل، شماره روز در سال و بارندگی به ترتیب بیشترین تأثیر را در برآورد دبی رسوب دارند. نتایج نشان می‌دهد ضرایب استاندارد شده مدل رگرسیونی از نظر تأثیر هر یک از عوامل در خروجی مدل، تطابق نسبتاً خوبی با مدل شبکه عصبی دارد.

ابتدا پارامتر دبی لحظه‌ای، سپس دبی روز قبل و در نهایت عوامل بارش و شماره روز سال به ترتیب بیشترین تأثیر را در عملکرد مدل داشته‌اند. به علت اهمیت کاربردی مدل پیشنهادی، معیار تصمیم‌گیری برای شناسایی بهترین ساختار شبکه ضرایب  $R^2$  و RMSE در مرحله آزمون می‌باشد. بر اساس این معیار، شبکه پنجم با ساختار ۱-۵-۳، با پنج نرون در لایه پنهان و با حذف اثر پارامتر شماره روز در سال، به‌عنوان بهترین ساختار شبکه در میان کلیه شبکه‌های مورد بررسی شناخته شد.

جدول ۳، نتایج حاصل از مدل رگرسیونی را نشان می‌دهد. این جدول شامل ضرایب رگرسیون استاندارد شده است. در این ضرایب مقیاس متغیرها یکسان شده

جدول ۲- بهترین ساختار شبکه عصبی با ترکیب مختلف عوامل ورودی

آزمون		اعتبارسنجی		آموزش		ساختار شبکه	شبکه
RMSE	$R^2$	RMSE	$R^2$	RMSE	$R^2$		
۰/۰۶	۰/۶۵	۰/۰۴	۰/۶۳	۰/۰۶	۰/۸۶	۴-۸-۱	۱
۰/۰۶	۰/۵۲	۰/۰۵	۰/۵	۰/۰۷	۰/۳۸	۳-۹-۱	۲
۰/۰۹	۰/۶۳	۰/۰۵	۰/۷۱	۰/۰۶	۰/۷۲	۳-۱۱-۱	۳
۰/۰۵	۰/۷۴	۰/۰۶	۰/۶۳	۰/۰۶	۰/۷	۳-۱۲-۱	۴
۰/۰۲	۰/۸۹	۰/۰۶	۰/۵۸	۰/۰۵	۰/۵۹	۳-۵-۱	۵
۰/۰۶	۰/۷۷	۰/۰۴	۰/۵	۰/۰۵	۰/۶۷	۲-۱۲-۱	۶
۰/۰۵	۰/۷۵	۰/۰۷	۰/۵۸	۰/۰۶	۰/۵۵	۲-۱۱-۱	۷

جدول ۳- ضرایب مدل رگرسیون خطی چند متغیره

رتبه تأثیر	قدرمطلق ضریب رگرسیون استاندارد شده	خطای معیار ضرایب	متغیر
۱	۰/۸۹۱	۳۶/۳۰۶	Q
۲	۰/۱۸۸	۴۰/۰۹۲	$Q_{i-1}$
۴	۰/۰۱۳	۵۰/۶۷۳	P
۳	۰/۱۶۵	۳/۵۵۲	DOY*

\* Day of year Day of year

منحنی‌سنجه رسوب، دبی بار معلق رسوب با استفاده از این روش برآورد شد. شکل ۲، رابطه منحنی‌سنجه رسوب برای مجموعه داده‌هایی که برای آموزش مدل شبکه عصبی به کار رفته است، نشان می‌دهد. این معادله از رابطه توانی بین متغیرهای دبی آب و دبی رسوب که در مرحله آموزش مدل به کار رفته، به دست آمده است.

در شکل ۳- الف، نتایج حاصل از عملکرد شبکه


با توجه به جدول فوق، به دلیل تأثیر کمتر عامل بارش در برآورد دبی رسوب، از اثر آن در رابطه رگرسیونی صرف نظر شد. لذا این رابطه با کمک نرم-افزار SPSS بین متغیرهای موثرتر (دبی لحظه‌ای، شماره روز سال و دبی آب در روز قبل) به صورت زیر، به دست آمده است.

$$Q_s = 2.958Q^{1.586} Q_{i-1}^{1.043} DOY^{-0.588} \quad (5)$$

به منظور مقایسه دقت مدل شبکه عصبی با

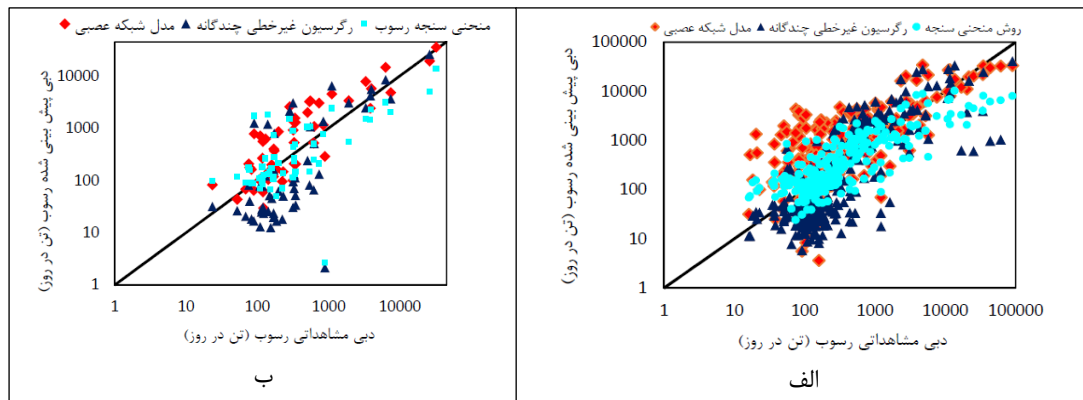
برآوردی با استفاده از روش منحنی‌سنجه رسوب در زیر خط یک به یک پراکنده شده است.

در جدول ۴، مقدار ضریب همبستگی برای هر مدل در مراحل آموزش و آزمون گزارش شده است. به‌طور کلی، در مرحله آزمون، مدل شبکه عصبی، عملکرد بهتری (افزایش ۱۶ درصدی ضریب همبستگی نسبت به دو روش دیگر) در پیش‌بینی دبی روزانه رسوب دارد و با استفاده از این مدل می‌توان در روزهای فاقد آمار برآورد دقیق‌تری از دبی رسوب داشت.



شکل ۲- منحنی‌سنجه رسوب برای مجموعه داده‌های آموزش

عصبی در برآورد دبی روزانه رسوب در مرحله آموزش با مدل رگرسیون غیرخطی چند متغیره و روش منحنی‌سنجه رسوب، مقایسه شده است. همان‌طور که دیده می‌شود، در مرحله آموزش، برای دبی‌های پایه روش منحنی‌سنجه رسوب نسبت به دو روش دیگر پراکندگی کمتری پیرامون خط رأس دارد. ضمناً در دبی‌های بالا (دبی رسوب بیشتر از ۱۰۰۰ تن در روز) مدل شبکه عصبی عملکرد به نسبت بهتری نسبت به دو روش دیگر دارد. به‌طور کلی از بین سه روش، روش منحنی‌سنجه رسوب، عملکرد بهتری در برآورد دبی رسوب در مرحله آموزش دارد. در قسمت ب، نتایج عملکرد مدل‌ها در مرحله آزمون با یکدیگر مقایسه شده است. مطابق این شکل، در مواقع غیرسیلابی مدل شبکه عصبی و روش منحنی‌سنجه رسوب، پراکندگی نسبتاً کمتری اطراف خط رأس دارند در حالی‌که روش رگرسیونی مقدار دبی رسوب را کمتر از مقادیر مشاهداتی پیش‌بینی می‌کند. در دبی‌های بالا و در مواقع سیلابی، مدل شبکه عصبی و رگرسیونی، با اختلاف کمتری مقادیر دبی مشاهداتی رسوب را برآورد می‌کنند. در این حالت مقادیر دبی رسوب



شکل ۳- مقایسه دقت برآورد دبی رسوب مدل شبکه عصبی با روش منحنی‌سنجه و مدل رگرسیونی، (الف) مرحله آموزش (ب) مرحله آزمون

جدول ۴- مقادیر ضریب همبستگی برای هر یک از مدل‌ها در مراحل آموزش و آزمون

$R^2$		مدل مورد استفاده
مرحله آموزش	مرحله آزمون	
۰/۸۹	۰/۵۹	مدل شبکه عصبی
۰/۸۳	۰/۶۶	منحنی‌سنجه رسوب
۰/۵۷	۰/۶۱	مدل رگرسیون غیرخطی چندمتغیره

## نتیجه‌گیری

بیشترین تأثیر را در پیش‌بینی دبی رسوب داشته‌اند و تطابق نسبتاً خوبی از نظر تأثیر عوامل در پیش‌بینی دبی رسوب با مدل شبکه عصبی وجود دارد. مقایسه عملکرد مدل شبکه عصبی در مرحله آموزش و آزمون با مدل رگرسیون غیرخطی چند متغیره و روش منحنی‌سنجه رسوب از نظر میزان تطابق با مقادیر مشاهده‌ای دبی رسوب نشان داد، روش منحنی‌سنجه در مرحله آموزش و مدل شبکه عصبی در مرحله آزمون، عملکرد بهتری نسبت به سایر مدل‌ها داشته‌اند. به‌طور کلی با شناسایی تأثیر هر یک از عوامل بر اندازه‌گیری دبی رسوب، می‌توان به سهولت و با اختصاص وقت و هزینه کمتر، برآورد بهتر و دقیق‌تری از دبی رسوب داشت.

نتایج نشان داد که در مدل شبکه عصبی با تغییر تعداد متغیرهای ورودی، ابتدا عامل دبی لحظه‌ای، سپس دبی آب در روز قبل، بارش و شماره روز در سال به‌ترتیب بیشترین تأثیر را در پیش‌بینی دبی روزانه بار معلق رسوب داشته‌اند. با حذف متغیر شماره روز در سال، بهترین شبکه با ساختار ۱-۵-۳ (۳ نرون ورودی و پنج نرون در لایه پنهان و یک نرون خروجی) شناخته شد. مقدار شاخص‌های آماری برای این شبکه در مرحله آزمون  $R^2 = 0.89$  و  $RMSE = 0.21$  به‌دست آمده است. با مقایسه ضرایب استاندارد شده مدل رگرسیونی با مدل شبکه عصبی می‌توان نتیجه گرفت، عوامل دبی لحظه‌ای و دبی آب روز قبل

## منابع مورد استفاده

1. Banihabib, M.E. and E. Emami. 2005. An artificial neural network model for estimation of sediment yeild. *Journal of Science and Research in Watershed Management*, 2: 25-37.
2. Barzegari, F., M. Yousefi and A. Talebi. 2015. Estimating suspended sediment by Artificial Neural Network (ANN), Decision Trees (DT) and Sediment Rating Curve (SRC) Models, case study: Lorestan Province, Iran. *Civil Engineering Infrastructures Journal*, 48(2): 373-380.
3. Cigizoglu, H.K. 2002. Suspended sediment estimation for rivers using Artificial Neural Networks and sediment rating curves. *Turkish Journal of Engineering and Environmental Sciences*, 26(1): 27-36.
4. Cimen, M. 2008. Estimation of daily suspended sediments using support vector machines. *Hydrological Sciences Journal*, 53(3): 656-66.
5. Dastorani, M.T. and H. Afkhami. 2011. Application of artificial neural networks on drought prediction in Yazd (Central Iran). *Desert*, 16(1): 39-48.
6. Dastorani, M.T., Kh. Azimi Khashi, E. Talebi and M.R. Ekhtesasi. 2012. Estimation of suspended sediment by artificial neural network. *Journal of Watershed Management*, (3): 61-74 (in Persian).
7. Jowkar Sarhangi, E., A. Amir Ahmadi and A. Nikzad. 2008. Modeling of flood estimation water basins northern slopes of Alborz using of geomorphological and morphometric characteristics and geographic information system. *Journal of Geography and Planning*, 14(29): 141-162 (in Persian).
8. Kumar, S.A., C. Ojha, M. Goyal, R. Singh and P. Swamee. 2011. Modeling of suspended sediment concentration at Kasol in India using ANN, Fuzzy Logic and Decision Tree algorithms. *Journal of Hydrologic Engineering*, 17(3): 394-404.
9. Melesse, A.M., S. Ahmad, M.E. McClain, X. Wang and Y.H. Lim. 2011. Suspended sediment load prediction of river systems: An artificial neural network approach. *Agricultural Water Management*, 98(5): 855-866.
10. Momeni, M. and E. Ghayomi. 2011. Statistical analysis by using of SPSS. 297 pages (in Persian).
11. 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*, 81: 372-376.
12. Raghuwanshi, N.S., R. Singh and L.S. Reddy. 2006. Runoff and sediment yield modeling using artificial neural networks: Upper Siwane River, India. *Journal of Hydrologic Engineering*, 11(1): 71-79.
13. Tachi, S.E., L. Ouerdachi, M. Remaoun, O. Derdous and H. Boutaghane. 2016. Forecasting suspended sediment load using regularized neural network: case study of the Isser River (Algeria). *Journal of Water and Land Development*, 29(1): 75-81.
14. Tayfur, G. 2002. Artificial neural networks for sheet sediment transport. *Hydrological Sciences Journal*, 47(6): 879-892.
15. Thomas, R.B. 1988. Monitoring baseline suspended sediment in forested basins: the effects of sampling on suspended sediment rating curves. *Hydrological Sciences Journal*, 33(5): 499-514.

## Artificial neural network model of multilayer perceptron for prediction of daily discharge suspended sediment load and assessment of factors affecting sediment estimation

Mitra Tanhapour<sup>1</sup> and Mohammadebrahim Banihabib<sup>\*2</sup>

<sup>1</sup> MSc Student, Abouraihan Campus, University of Tehran, Tehran, Iran and <sup>2</sup> Associate Professor, Abouraihan Campus, University of Tehran, Tehran, Iran

Received: 24 October 2016

Accepted: 13 May 2017

### Abstract

Prediction of the sediment load in water resources engineering projects such as flow diversion projects and dam construction is important factor for determining their service life. In this study, a model for estimation of daily sediment discharge was proposed using multilayer perceptron Artificial Neural Network (ANN) model with back-propagation learning algorithm. For this purpose, current day's discharge ( $Q_t$ ), precipitation, number of day in the year (DOY) and previous day's discharge ( $Q_{t-1}$ ) data of Zoghal Bridge station (located on Chalus River) from 1990 to 2009 were used for training, verification and test. Results of testing different combinations of input data sets showed that effective parameters of the model performance are current discharge parameter, antecedent discharge, precipitation and DOY, respectively. This results has a relatively good agreement with standardized coefficients of regression model. Coefficient of determination ( $R^2$ ) and Root Mean Square Error (RMSE) were used to compare the different structures of ANN. Therefore, best network with 3-5-1 architecture and the amounts of  $R^2=0.89$  and  $RMSE=0.02$  was obtained by elimination of DOY variable. The performance of ANN model in the prediction of sediment discharge was compared with Sediment Rating Curve (SRC) and Multiple Non-Linear Regression (MNL) model. The results showed, in the training and test steps, SRC method and ANN model have the best performance, respectively. Furthermore, in the test step, the ANN model performed better results compared to two other methods by increasing  $R^2$  about 16%. Generally, the proposed ANN model can be estimated sediment discharge by less calculation time and cost and also with more accuracy.

**Key words:** Artificial intelligence model, Back-propagation algorithm, Current day's discharge, Multiple non-linear regression model, Sediment rating curve

---

\* Corresponding author: [banihabib@ut.ac.ir](mailto:banihabib@ut.ac.ir)