

بررسی دقت شبکه پرسپترون چندلایه و تابع پایه شعاعی در برآورد میزان رسوب رودخانه (مطالعه موردی: زاینده رود)

رامتین صبح خیز فومنی^۱

علیرضا مردوخ پور*

Alireza.mardookhpour@liau.ac.ir

تاریخ پذیرش: ۹۹/۱۱/۲۹

تاریخ دریافت: ۹۹/۸/۸

چکیده

زمینه و هدف: تخمین میزان رسوب به وسیله رودخانه یکی از مسائلی هست که مورد توجه محققان بسیاری از گذشته تاکنون قرار گرفته است. کاهش ظرفیت مخزن سد به وسیله رسوبات، اثرات مختلفی بر روی بخشهای مختلف گذاشته و سبب اثرات نامطلوب در حبابه هایی می شود که در بدو امر مورد توافق قرار گرفته اند که عواقب اقتصادی و خاص خود را خواهد دارد. هدف از این تحقیق بررسی میزان رسوب رودخانه با توجه به الگوریتم های شبکه عصبی و با استفاده از فرمول های تجربی موجود و همچنین روش های جدید موسوم به جعبه ی سیاه می باشد.

روش و بررسی: به منظور تخمین میزان رسوب از اطلاعات دبی سال های ۱۳۴۹ تا ۱۳۹۰ مربوط به رودخانه زاینده رود در ایستگاه اسکندری که یکی از ایستگاههای اندازه گیری های هیدرولوژیکی میباشد استفاده شده است. بدین منظور از دبی آب به عنوان ورودی و دبی رسوب به عنوان خروجی استفاده شده است.

یافته ها: از نتایج به دست آمده، این گونه استنباط می شود که شبکه RBF به دلیل داشتن خطای کمتر در مرحله آزمون دارای عملکرد بهتری است، اما با در نظر گرفتن سایر پارامترها و همچنین میزان خطا در مرحله ی TRAIN به نظر می رسد شبکه MLP دارای عملکرد بهتری است.

بحث و نتیجه گیری: در نهایت بعد از مدل سازی با استفاده از شبکه های عصبی و رابطه انیشتین و منحنی سنجه رسوب، این نتیجه بدست آمده است که برای تخمین میزان رسوب می توان به شبکه های عصبی اعتماد بیشتری داشت.

واژه های کلیدی: رسوب گذاری، شبکه عصبی، رودخانه، منحنی سنجه.

۱- دانشجوی دکتری گروه مهندسی عمران، دانشگاه قم، قم، ایران.

۲- استادیار گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد لاهیجان. * (مسوول مکاتبات)

Investigation of the accuracy of multilayer perceptron network and radial base function in estimating river sediment

(Case study: Zayandehrud)

Ramtin Sobhkhiz Foumani¹

Alireza Mardookhpour^{2*}

Alireza.mardookhpour@liau.ac.ir

Admission Date: February 17, 2021

Date Received: October 29, 2020

Abstract

Background and Objective: Estimating the amount of sediment by the river is one of the topics that has been considered by many researchers since the past. Reduction of the dam reservoir capacity because of sediments has different effects on different sections and causes adverse effects on the water rights that were initially agreed upon, which will impose several economic and specific consequences. This study aims to model and estimate the amount of suspended sediment using existing experimental equations and new methods called black box.

Material and Methodology: The discharge (volumetric flow rate) related to Zayandehrud River in Eskandari station, one of the hydrological measuring stations, has been used to estimate the amount of sediment. For this purpose, water discharge and sediment rate are used as input and output, respectively.

Findings: According to the obtained results, it is concluded that the RBF network has better performance due to less error in the test stage, but the MLP network seems to have a better performance considering other parameters and the error in the TRAIN stage.

Discussion and Conclusion: Finally, after modeling by using neural networks, the Einstein relationship, and the sediment measurement curve, it is inferred that neural networks are more accurate to estimate the amount of sediment.

Key words: Sedimentation, Artificial neural network, River, Sediment measurement curve.

1- PhD Student of Civil Engineering, Department, University of Qom, Qom, Iran.

2- Assistant Professor, Department of Civil Engineering, Islamic Azad University, Lahijan Branch.

*(Corresponding Author)

مقدمه

آب یکی از معدود منابع طبیعی است که بدون آن زندگی ممکن نیست. توزیع آب در سرتاسر دنیا بر حسب موقعیت، فصل و کیفیت متفاوت است. بدین دلیل، احداث سدها بر روی رودخانه ها و در نتیجه ایجاد مخازنی برای ذخیره و حتی مصرف آب ضروری است.

پیش بینی میزان رسوب حمل شده توسط رودخانه دارای اهمیت فراوانی در مدیریت منابع آب رودخانه و همچنین بهره برداری بهینه از سدها دارد، چراکه رسوب می تواند تأثیر بسیار زیادی بر شرایط هیدرولیکی رودخانه داشته باشد (۱) در دهه ی اخیر استفاده از شبکه های عصبی مصنوعی جهت پیش بینی پدیده های هیدرولوژیکی، تغییرات شگرفی در امر پیش بینی کردن داشته و مدل های جعبه سیاه تأثیر موفقیت آمیزی در بسیاری از زمینه ها از جمله مهندسی منابع آب داشته است (۲)، یک مدل شبکه عصبی مصنوعی پس انتشار خطای ۳ لایه برای پیش بینی غلظت رسوب در رودخانه ها با ۸ پارامتر ورودی استفاده شد و مشاهده شد که این روش نتایج بهتری نسبت به سایر پارامترها برای سنجش غلظت رسوب نشان می-دهد. (۳).

در دهه های اخیر استفاده از شبکه های عصبی مصنوعی برای پیش بینی پدیده های هیدرولوژیکی، تغییرات شگرفی در امر پیش بینی کردن داشته است. مدل های جعبه سیاه تأثیر موفقیت آمیزی در بسیاری از زمینه ها از جمله مهندسی منابع آب داشته است (۴)

مقایسه تخمین بار معلق به دو روش منحنی سنج رسوب و شبکه عصبی مصنوعی پرداخته شده و نتایج حاکی از آن است که شبکه عصبی مصنوعی با دقت بسیار مناسب و با اطمینان بیشتر می تواند نسبت به روش منحنی سنج با و بدون دسته بندی دادهها برای تخمین بار معلق رسوب مورد استفاده قرار گیرد. (۵)

در اکثر طرحهای مهندسی رودخانه علاوه بر مطالعه هیدرولیک جریان، بررسی رفتار باربستر و بارمعلق رودخانه ها نیز بسیار مهم و تاثیرگذار است. احداث سازه هایی مانند سدها، پلها،

آبگیرهای جانبی و بندهای انحرافی و نیز عملیات لایروبی رودخانه ها کاملاً با خصوصیات جریان و رسوب رودخانه مرتبط است.

برای بررسی رفتار و حرکت رسوبات، مطالعات آزمایشگاهی و صحرایی زیادی توسط محققین مختلف انجام شده و از نتایج تحلیل آنها، روابط و معادلات فراوانی برای محاسبه نرخ انتقال رسوب در رودخانه ها استخراج ارائه شده است. همچنین مدلهای ریاضی زیادی به منظور بررسی تغییرات مورفولوژی رودخانه ها ارائه شده است. اخیراً نیز برای تخمین دبی رسوب معلق در رودخانه ها، استفاده از مدلهای هوشمند مثل روش کنترل گروهی داده ها (۷۰۶)، سیستم استنتاج فازی - عصبی (۸) و ماشینهای بردار پشتیبان (۹ و ۱۰) مورد توجه قرار گرفته است. نکته مهم در کاربرد روشهای هوشمند این است که معمولاً اغلب آنها قادر به ارائه یک رابطه صریح برای محاسبه متغیر خروجی نیستند (۱۱). در ضمن تعمیم آنها به شرایطی خارج از محدوده دادههای مدلسازی بسیار مشکل است (۱۲ و ۱۳). به همین دلیل کماکان روابط هیدرولیکی انتقال رسوب دارای کاربرد دارد. ظهیری و دهانزاده (۱۴ و ۱۵) با کاربرد یک مدل شبهدوبعدی در رودخانه کارون، ظرفیت انتقال رسوب را در این رودخانه محاسبه نمودند. در این مطالعه، به دلیل عدم دسترسی به دادههای توزیع عرضی غلظت رسوبات رودخانه، نتایج بهدست آمده از مدل ریاضی با دقت مناسبی قابل ارزیابی نبود و فقط دبی کل رسوبات رودخانه مورد بررسی قرار گرفت. نگاهی به پژوهش های گذشته نشان میدهد که در بیشتر موارد رابطه های ارائه شده، بر اساس اندازه گیری دبی رسوب در تعداد محدودی از روزهای سال استوار است. علت این امر آن است که اندازه گیری روزانه رسوب بار معلق مستلزم صرف وقت و هزینه زیادی است.

بنابراین به نظر می رسد استفاده از شبکه های عصبی مصنوعی برای تخمین و پیش بینی پدیده های هیدرولوژیکی و سایر علوم مختلف، دارای توجیه بوده و استفاده از آنها نتیجه دقیق-تری در محاسبات پارامترهای مختلف را در اختیار پژوهشگران

مترمکعب (در تراز ۲۰۶۳ متر) و حجم مفید آن ۱۰۹۰ میلیون متر مکعب و همچنین مساحت دریاچه سد، ۵۴ کیلومتر مربع در تراز حداکثر می باشد. اهداف ساخت سد زاینده رود عبارت از تولید سالیانه ۲۵۰ میلیون کیلووات ساعت انرژی برق آبی، کنترل سیلابهای فصلی، تنظیم آب کشاورزی مورد نیاز ۱۰۰ هزار هکتار از اراضی دشت اصفهان و تأمین آب مورد نیاز صنایع مستقر در اصفهان بوده است.

رودخانه هایی که آب خود را در پشت سد تخلیه می کنند عبارت اند از: رودخانه پلاسجان (۶۰ کیلومتر)، رودخانه زاینده رود (۷۲ کیلومتر)، رودخانه سمندگان (۲۳ کیلومتر) و رودخانه حیدری (۱۵ کیلومتر) حوضه آبخیز مورد مطالعه در این تحقیق حوضه رودخانه پلاسجان بوده که با توجه به قرار داشتن ایستگاه هیدرومتری در محلی به نام اسکندری این حوضه نیز به این نام شناخته میشود. رودخانه پلاسجان بین طول های ۵۲/۰۳ و ۵۰/۶۹ درجه و عرض های ۳۲/۷۷ و ۳۳/۲۰ درجه واقع شده است. این رودخانه ها آب حوضه ای به مساحت ۱۶۴۰ کیلومتر مربع را تخلیه می کند. ارتفاع متوسط این حوضه ۲۵۲۳ متر و بارندگی متوسط آن ۴۶۰ میلی متر و متوسط آب دهی آن ۱۳۱ میلیون مترمکعب در سال است.


قرار می دهد. پس می توان انتظار داشت استفاده از این روش جهت تخمین میزان رسوب در رودخانه ها نیز دارای پاسخ دهی مناسب باشد. بنابراین در این پژوهش کاربرد روش پرسپترون چندلایه و تابع پایه شعاعی در تخمین میزان رسوبات بار معلق روزانه مورد بررسی قرار گرفته و نتایج به دست آمده از این روش با استفاده از شاخص های آماری، با نتایج به دست آمده از روش مرسوم منحنی سنج مقایسه گردیده است تا مهمترین هدف این تحقیق پیش بینی دقیق میزان رسوب و ارائه یک روش نوین جهت تخمین میزان رسوب تحقق یابد.

مواد و روش ها

یکی از روش هایی که به تازگی توسط مهندسان به کار گرفته شده است، استفاده از شبکه های عصبی مصنوعی است. در این روش با استفاده از داده های رسوب و دبی آب که قبلاً توسط ایستگاه های هیدرومتری طی ۵۰ سال اندازه گیری شده است، شبکه عصبی را آموزش داده و با استفاده از شبکه آموزش دیده، میزان رسوب در زمان های آینده پیش بینی خواهد شد.

۱- منطقه مورد مطالعه

سد زاینده رود، سدی است که بر زاینده رود در استان اصفهان ایران ساخته شده است. این سد که در سال ۱۳۴۹ مورد بهره برداری قرار گرفت، در فاصله ۱۱۰ کیلومتری غرب اصفهان احداث شده است، پیشینه حجم مخزن، ۱۴۷۰ میلیون



تصویر ۱- موقعیت حوضه آبخیز زاینده رود

Figure 1. Location of Zayandehrud watershed


هستند. این معادله میزان تاثیر افزایش قدرت جریان در دبی-های بالاتر همچنین تاثیر اینکه تا چه حد، کدام منابع جدید رسوب در شرایط آب و هوایی و دبی بالا پدیدار می شوند (۳).

حالت کلی معادله نمایی رسوب به صورت زیر است:

$$C = aQd^b \quad (2)$$

با در دسترس بودن میزان غلظت رسوب می توان میزان دبی رسوب را از رابطه (۱) به دست آورد و نسبت به رسم منحنی سنجه بر حسب Q و QS اقدام کرد. ضرورت تعیین رابطه نمایی رسوب ناشی از محدود بودن آماری مشاهده ای است که در آن فقط برای تعداد اندکی از روزهای سال اندازه گیری همزمان Q و QS محقق می گردد.

برای جمع آوری داده های رسوب، در طول یک سال آبی چند نوبت به محل ایستگاه آبنجی مراجعه و عملیات اندازه گیری دبی جریان و نمونه برداری رسوب توسط گروه کارشناسی انجام می گیرد. برای بقیه روزهای سال لازم است با تعیین رابطه همبستگی بین Q و QS تناژ رسوب برای روزهای فاقد آمار محاسبه شود. برای ترسیم منحنی رسوب در تحقیق حاضر از نرم افزار MATLAB استفاده شده است. همان طور که در شکل زیر مشاهده میشود، محور افقی منحنی سنجه میزان دبی آب اندازه گیری شده و محور عمودی میزان دبی رسوب اندازه گیری شده در ایستگاه اسکندری است.



تصویر ۲ - منحنی سنجه ایستگاه اسکندری

Figure 2. Measurement curve of Eskandari station

پارامترهای تأثیرگذار استفاده شده در این تحقیق جهت تخمین میزان رسوب، دبی آب (Q) و دبی رسوب (QS) است که از تعداد ۸۲۳ آمار ثبت شده از سال های ۴۹ تا ۹۰ اداره آب منطقه ای اصفهان استفاده شده است

مجموعه اطلاعات رسوب به شرح زیر است:

۱- داده های مجزای غلظت (C) رسوب همراه با میزان دبی متناظر با آن.

۲- دبی روزانه آب اندازه گیری شده غلظت رسوب هر نمونه با به کارگیری روش های فیلتراسیون، تبخیر نمونه و توزین رسوب باقی مانده محاسبه می شود. علاوه بر این از مواد جامد محلول در رسوب معلق به هنگام تبخیر صرف نظر شده است.

۲- روش منحنی سنجه رسوب در ایستگاه های

هیدرومتری در دوره آماری

منحنی سنجه رسوب با استفاده از داده های آماری Q_d و Q_s ترسیم می شود. چنین اطلاعاتی بخشی از برنامه سنجش های رودخانه ای تلقی گردیده و در هر ایستگاه آبنجی سالیانه در چند نوبت ضمن اندازه گیری بده جریان روزانه، مقدار غلظت مواد معلق و تناژ رسوب روزانه نیز محاسبه می شود، برای ترسیم منحنی سنجه رسوب سری داده ها برای یک دوره آماری چندساله مورد استفاده فرار می گیرد (لینزلی و فرزینشی، ۱۹۸۴) سالیانه در چند نوبت نمونه برداری و تعیین غلظت متوسط (C) همزمان با اندازه گیری بده جریان روزانه (Q_d) انجام گرفته و با استفاده از معادله (۱) تناژ رسوب روزانه (QS) نیز محاسبه می گردد.

$$Qs = 0.864CQd \quad (1)$$

منحنی سنجه رسوب، ارتباط بین میزان دبی آب و میزان غلظت رسوب را برای یک محل خاص بیان می کند. تابعی که به صورت متداول جهت تعیین ارتباط بین غلظت رسوب و دبی آب استفاده می شود، تابع توانی رابطه (۲) است. در این رابطه C میزان غلظت رسوب معلق بر حسب میلی گرم برلیتر، Q دبی آب بر حسب مترمکعب بر ثانیه و a و b ضرایب رگرسیون

۳- استفاده از شبکه های عصبی مصنوعی

مدل های شبکه عصبی در مورد فرآیندهایی که تعریف دقیق و درک خاصی از آنها وجود ندارد، بسیار مؤثر عمل می کنند، خصوصیت دیگر این مدل ها که آنها را نسبت به سایر روش ها و الگوریتم ها متمایز می نماید، حساسیت کمتر آنها نسبت به وجود خطا در ورودی هاست. علت این امر پردازش گسترده اطلاعات توزیعی است، در این سیستم فعالیتهای پیچیده با ساختاری به شدت موازی انجام می شود و به جای اینکه تمام بار فعالیت بر دوش یک واحد محاسباتی سریع قرار گیرد تعداد زیادی واحدهای محاسباتی ساده به صورت مشترک انجام آن را بر عهده دارند. این تقسیم کاره پیامد مثبت دیگری نیز در پی دارد و آن این است که چون تعداد زیادی نورون در یک زمان درگیر فعالیت هستند، سهم هر یک از نورون ها چندان دارای

(۴)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (Q(s.predicted)_i - Q(s.observed)_i)^2}$$

(۵)

$$MAE = \sum_{i=1}^n \frac{|Q(s.predicted)_i - Q(s.observed)_i|}{n}$$

(۶)

$$R^2 = \frac{\sum_{i=1}^n (Q(s.predicted)_i - \bar{Q}(s.predicted)) (Q(s.observed)_i - \bar{Q}(s.observed))}{\sqrt{\sum_{i=1}^n (Q(s.predicted)_i - \bar{Q}(s.predicted))^2 \sum_{i=1}^n (Q(s.observed)_i - \bar{Q}(s.observed))^2}}$$

(۷)

$$EI = \frac{\sum_{i=1}^n (Q(s.observed)_i - \bar{Q}(s.observed))^2 - \sum_{i=1}^n Q(s.observed)_i - \bar{Q}(s.observed))^2}{\sum_{i=1}^n Q(s.observed)_i - \bar{Q}(s.observed))^2}$$

آنالیز و تحلیل نتایج

۱- آماده سازی داده ها در شبکه عصبی MLP

پس از آماده سازی داده ها در اکسل، داده های دبی به عنوان ورودی و دبی رسوب به عنوان خروجی در نظر گرفته شد. در اشکال زیر می توان محدوده ی اعداد مربوط به ورودی و خروجی را مشاهده کرد.

که در آن (Q_s (predicted) و Q_s (observed) میزان دبی پیش بینی شده و میزان دبی مشاهده شده است و همچنین \bar{Q} (s. predicted) و \bar{Q} (S. observed) میزان دبی میانگین پیش بینی شده و دبی میانگین مشاهده شده است. همچنین n تعداد داده ها است. علاوه بر این تمامی داده های ورودی، توسط رابطه ی زیر به بازه ۰ تا ۱ تبدیل شده اند.


$$xi' = \frac{xi - xmin}{xi - xmax} \quad (۸)$$

اهمیت نیست. بنابراین وجود خطا در یکی از آنها و نتیجه آن تأثیری چندانی بر روی سایر واحدهای محاسباتی نخواهد داشت. (۸)

در این تحقیق برای تخمین میزان رسوب از شبکه عصبی MLP و همچنین RBF استفاده خواهد شد. همچنین برای مدل سازی از نرم افزار MATLAB استفاده شده است.

۴- معیارهای ارزیابی برای عملکرد مدل

برای ارزیابی مدل شبکه عصبی، روش های آماری مختلفی توسعه یافته است و بهترین و شناخته ترین ها آنها، ریشه میانگین مربع خطا (RMSE)، میانگین مربع خطا (MAP)، ارتباط بین مقدار واقعی و پیش بینی شده (R^2) و شاخص بهره وری (EI) می باشد:



تصویر ۳ - محدوده داده های ورودی . الف) دبی آب ب) دبی رسوب

Figure 3. Input data range. A) Water Discharge b) Sediment Discharge

خروجی استفاده شده است. پس از انتخاب ورودی و خروجی برنامه را با تعداد مختلف نورون ها اجرا می کنیم و شبکه ای که کمترین میزان خطا را داشته باشد به عنوان بهترین شبکه انتخاب می کنیم. معیار انتخاب بهترین شبکه $RMSE$ ، MSE ، SSE ، S است.

۳- بررسی نتایج در شبکه عصبی MLP

همان طور که در جدول زیر مشاهده می شود، معماری شبکه هم به صورت تک لایه هم به صورت چندلایه آزمایش شده است، پس از آزمایش کردن تعداد مختلفی از حالات، به نظر میرسد شبکه با ۴ نورون (شکل ۱۰) در لایه پنهان عملکرد بهتری نسبت به بقیه حالات داشته است. دلیل این امر میزان $RMSE$ و MSE کمتر است.

با نگاهی به جدول می توان دریافت که شبکه چندلایه با معماری ۱-۲-۴-۱ که دارای ۴ نورون در لایه پنهان اول و ۲ نورون در لایه پنهان دوم است نیز دارای عملکرد خوبی است، اما با در نظر گرفتن تمامی پارامترها به این نتیجه می رسیم که شبکه تک لایه با ۴ نورون دارای عملکرد بهتری است.

همان طور که از اشکال مشاهده می شود، محدوده داده ها بسیار متنوع است. برای این که بتوان جواب بهتری از شبکه عصبی گرفت لازم است اعداد در محدوده ۰ تا ۱ نرمال سازی شده و سپس وارد شبکه عصبی شوند. این کار با استفاده از رابطه ی (۸) انجام می پذیرد. همچنین از کل نمونه ها تعداد ۸۰ درصد از داده ها را (۶۵۹ عدد) به داده های آموزش، ۱۰ درصد به داده های آزمایش (۸۳ عدد) و مابقی به داده های اعتبار سنجی (۸۲ عدد) اختصاص داده شد

۲- معماری در شبکه عصبی MLP

به منظور آموزش شبکه از الگوریتم $Levenberg - Marquardt$ استفاده شده است که به نظر می رسد نسبت به بقیه ی الگوریتم ها دارای عملکرد بهتری باشد. همچنین تابع انتقال استفاده شده در این تحقیق برای شبکه های با یک لایه پنهان، تابع $Tansig$ برای لایه میانی تابع $Purcelin$ برای لایه خروجی است. همچنین برای شبکه های با دو لایه پنهان، از تابع $Tansig$ برای لایه اول و تابع $Purelin$ برای لایه دوم و لایه


جدول ۱ - سعی خطای انجام شده جهت انتخاب بهترین شبکه

Table 1. Attempted error to select the best network

MSE	RMSE	SSE	R	فاز	تعداد نوروں ها
۰/۰۰۲۲	۰/۰۴۷۸	۱/۵	۰/۷۸	آموزش	۲
۰/۰۰۲۱	۰/۰۴۶۵	۰/۱۷۷۸	۰/۵۵	تست	
۰/۰۰۰۳	۰/۰۱۸۱	۰/۰۲۶۹	۰/۸۳	اعتبارسنجی	
۰/۰۰۰۲	۰/۰۴۵۶	۱/۷۱۱۹	۰/۷۷	کل	
۰/۰۰۳۸	۰/۰۶۲۴	۲/۵۶۶۵	۰/۷۶	آموزش	۳
۰/۰۰۰۳	۰/۰۱۷۶	۰/۰۲۵۶	۰/۹۳	تست	
۰/۰۰۱۱	۰/۰۳۳۱	۰/۹	۰/۶۶	اعتبارسنجی	
۰/۰۰۰۳	۰/۰۵۷	۲/۶۸	۰/۷۵	کل	
۰/۰۰۱۶	۰/۰۴۰۸	۱/۰۹۷۴	۰/۸۳	آموزش	۴
۰/۰۰۰۰۱	۰/۰۱	۰/۰۰۸۲	۰/۹۷	تست	
۰/۰۰۵۶	۰/۰۷۵۱	۰/۴۶۳۰	۰/۹۱	اعتبارسنجی	
۰/۰۰۱۹	۰/۰۴۳۶	۱/۵۶۸۸	۰/۸	کل	
۰/۰۰۱۷	۰/۰۴۱۶	۰/۰۹۷۴	۰/۸۳	آموزش	۵
۵e ^{-۶} /۵۱	۰/۰۰۸۱	۰/۰۰۸۲	۰/۹۷	تست	
۰/۰۰۲۳	۰/۰۴۸۲	۰/۴۶۳۰	۰/۹۱	اعتبارسنجی	
۰/۰۰۱۶	۰/۰۴۰۳	۱/۵۶۸۸	۰/۸	کل	
۰/۰۰۲۳	۰/۰۴۱۶	۱/۱۴۳۵	۰/۸۴	آموزش	۱-۱-۳-۵
۰/۰۰۰۵	۰/۰۰۸۱	۰/۰۰۵۲	۰/۵۶	تست	
۰/۰۰۰۲	۰/۰۴۸۲	۰/۱۹۱۱	۰/۷	اعتبارسنجی	
۰/۰۰۱۹	۰/۰۴۴۷	۱/۶۴۴۲	۰/۷۸	کل	
۰/۰۰۲۱	۰/۰۴۶۰	۱/۳۹	۰/۸	آموزش	۱-۱-۴-۲
۰/۰۰۰۷	۰/۰۲۸۱	۰/۰۶۵۰	۰/۷۹	تست	
۰/۰۰۰۱	۰/۰۱۱۵	۰/۰۱۰۹	۰/۹۳	اعتبارسنجی	
۰/۰۰۱۷۰	۰/۰۴۲۳	۱/۴۷۴۶	۰/۸۱	کل	

میشود، میزان داده های واقعی و پیش بینی شده توسط شبکه عصبی دارای اختلاف بسیار کم می باشند.

در نمودارهای زیر می توان تفاوت مقادیر پیش بینی شده و مقادیر واقعی را در حالتی که اعداد به صورت استاندارد شده و عادی می باشند مشاهده کرد. همان گونه که در شکل مشاهده




تصویر ۴ - مقایسه مقادیر پیش بینی شده و واقعی (الف) در حالت استاندارد شده (ب) در حالت عادی

Figure 4. Comparison of predicted and actual values a) in standardized mode b) in normal mode

وابسته است و نشان از پیش بینی خوب داده ها با شبکه عصبی دارد.

همچنین نمودار مربوط به ضریب رگرسیون به صورت شکل ۵ می باشد. همان طور که در شکل مشاهده می شود ارتباط بین داده های واقعی و پیش بینی شده به مقدار زیادی به یکدیگر



تصویر ۵ - ضریب رگرسیون و همبستگی داده های آزمایش

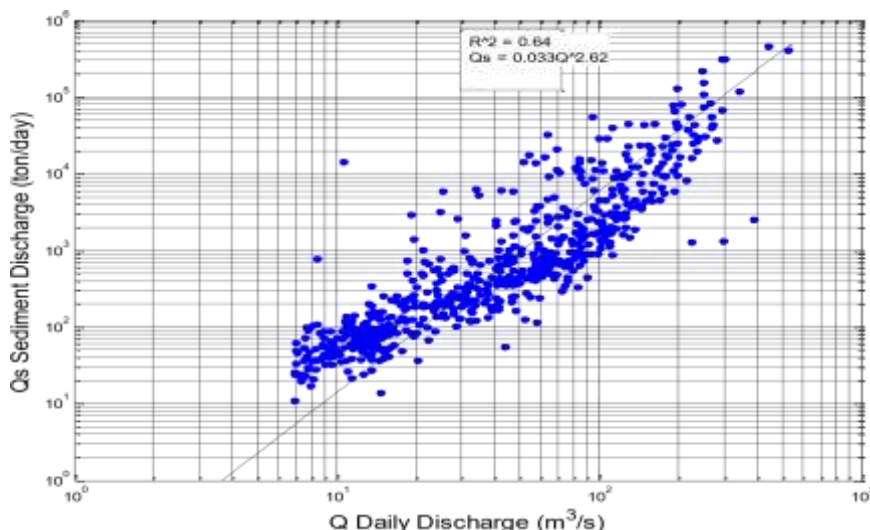
Figure 5. Regression coefficient and correlation of test data

خط استفاده شده است. در این مرحله نیز همانند روش شبکه های عصبی مصنوعی تعدادی داده به عنوان داده های آموزش و بقیه به عنوان داده های آزمون استفاده می شود از داده های آموزش برای به دست آوردن تابع توانی استفاده میشود. پس از برازش تابع توانی، معادله بدست آمده به صورت زیر خواهد بود:

$$Q_5 = 0.033Q^{2.62} \quad (9)$$

با استفاده از برنامه نویسی انجام شده در نرم افزار MATLAB می توان داده های وارد شده به شبکه عصبی را استخراج و از آنها جهت آزمایش منحنی سنجه استفاده کرد، یعنی از داده های آزمایش ورودی به شبکه عصبی برای ورودی منحنی سنجه استفاده کرد.

به دلیل ماهیت غیرخطی داده ها جهت برآورد پارامترهای آماری و میزان خطا، از تابع Power توانی برای برازش بهترین



تصویر ۶ - منحنی سنجه داده های آزمون

Figure 6. Test data measurement curve

همچنین در جدول زیر می توان میزان خطای به دست آمده در مرحله ی آزمون و آزمون را برای منحنی سنجه مشاهده کرد.

پس از مشخص شدن معادله ی سنجه، داده های آزمون را وارد معادله کرده و میزان خروجی را با میزان داده های هدف مقایسه کرده و خطای ناشی از آن را به دست می آوریم .

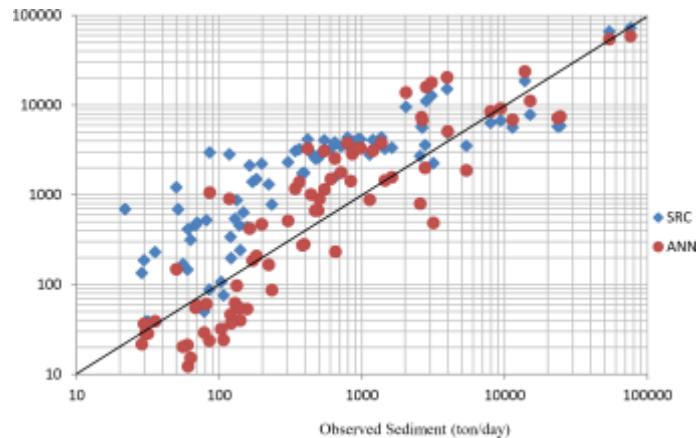
جدول ۲- میزان خطا در مرحله ی آزمون و آزمایش برای شبکه عصبی و منحنی سنجه

Table 2. The amount of error in the test phase for the neural network and the measurement curve

R^2	R	MSE	سطح	روش
۰/۶۴	۰/۸	۰/۰۰۱۵	داده آموزش	دسته بندی
-	-	۰/۰۰۱۷	داده تست	
۰/۹۷	۰/۸۳	۰/۰۰۱۶	داده آموزش	شبکه عصبی مصنوعی
۰/۹۵	۰/۹۷	۰/۰۰۰۱	داده تست	

شبکه عصبی بیشتر دارای رفتاری نزدیک به داده های هدف است تا داده های منحنی سنجه. همچنین برای یک مقایسه بهتر نمودار زیر را در نظر بگیرید

در شکل ۷ می توان برای مقایسه، تفاوت خروجی به دست آمده از شبکه عصبی و منحنی سنجه را به خوبی مشاهده کرد. همان طور که به خوبی مشاهده می شود خروجی به دست آمده از



تصویر ۷- مقایسه داده های هدف و پیش بینی شده الف) منحنی سنجه ب) شبکه عصبی

Figure 7. Comparison of target and predicted data a) Measurement curve b) Neural network

لایه اول که دارای تابع فعال سازی Radial Basic و لایه دوم دارای تابع فعال سازی Tuncelin است. نتایج حاصل از اجرای برنامه در جدول ۳ آمده است. همان طور که از اعداد درون جدول استنباط می شود شبکه با ۷ نورون در لایه پنهان دارای میزان خطای MSE کمتری در مرحله آزمایش است اما با توجه به در نظر گرفتن مجموع پارامترها به نظر می رسد شبکه با ۴ نورون دارای عملکرد بهتری است. جدول ۳ مقایسه- ای از پارامترهای این ۲ شبکه در مرحله آزمایش را نشان می- دهد.

همان طور که در نمودار مشاهده میشود داده های پیش بینی شده توسط شبکه عصبی به خط $X=Y$ بیشتر نزدیک می باشند تا داده های پیش بینی شده توسط منحنی سنجه و این به معنای پیش بینی دقیق تر شبکه عصبی نسبت به منحنی سنجه است.

۴- نتایج حاصل از شبکه عصبی RBF

برای تقسیم بندی داده ها در شبکه عصبی RBF نیز همانند شبکه MLP عمل می کنیم. معماری شبکه RBF به مانند MLP است با این تفاوت که شبکه فقط دارای دولایه می باشد.


جدول ۳- نتایج داده های آزمایش

Table 3. Test data results

R	SSE	RMSE	MSE	تعداد نورون ها
۰٫۹۱	۰/۰۰۴	۰/۰۰۷	$۵e^{-۴,۹۲۷۳}$	۴
۰/۸۹	۰/۰۲۳	۰/۰۱۷۰	۰٫۰۰۰۲	۷

به رسوب و دبی آب را پیش بینی کند. پس ملاک ما برای تخمین میزان رسوب شبکه MLP خواهد بود

برای نمایش بهتر عملکرد شبکه، در نمودارهای زیر می توان مقایسه مقادیر واقعی پیش بینی شده توسط شبکه را مشاهده کرد. با توجه به مقادیر R و Rsqr، به نظر می رسد شبکه RBF به خوبی شبکه MLP نتوانسته است داده های مربوط



تصویر ۸- مقایسه داده های واقعی و پیش بینی شده

Figure 8. Comparison of real and projected data

نتیجه گیری

ها شبکه های عصبی مصنوعی (ANN) می باشند که امروزه در علوم مختلف بسیار به کار گرفته می شوند. به دلیل این که رسوب دارای ماهیتی به شدت غیر خطی می باشد شبکه ی عصبی که ابزاری قدرتمند جهت تخمین توابع غیرخطی است، می تواند بسیار مناسب در این زمینه عمل کند. ابتدا با به کارگیری منحنی سنج رسوب و نرم افزار Matlab میزان رسوب با استفاده از تابع نوانی تخمین زده شد. نتایج حاصل از تخمین میزان رسوب با این نرم افزار در جدول زیر آمده است.

تخمین میزان رسوب معلق حمل شده به وسیله یک روخانه ، لازمه بسیاری از پروژه های منابع آب است. به همین دلیل انتقال رسوب یکی از مسائلی است که در دهه های گذشته مورد توجه بسیاری از دانشمندان علوم آب و هیدرولوژی بوده و بدین منظور فرمول های تجربی و تئوریک زیادی برای پیش بینی بار معلق رسوب ارائه شده است. در این تحقیق سعی شد علاوه بر روش معمول تخمین و پیش بینی میزان رسوب معلق از روش های جدید تخمین توابع، موسوم به جعبه سیاه (BMM) استفاده شود. از جمله این مدل

جدول ۴- نتایج حاصل از منحنی سنج

Table 4. Results from the measurement curve

فرمول	MSE	R	R^2	
$Q_s = 0.0553Q^{2.544}$	۰/۵۹۶۳	۰/۷۷۲۲	۰/۰۰۵۵	کل داده
$Q_s = 0.033Q^{2.62}$	۰/۶۴	۰/۸	۰/۰۰۱۵	داده آموزشی

عصبی آموزش می بیند، ۱۰٪ درصد داده ها به عنوان داده های اعتبار سنجی (داده هایی که به وسیله آن ها شبکه اعتبارسنجی می شود و مابقی به عنوان داده های آزمون داده هایی که به وسیله ی آن شبکه آزمایش میشود) تقسیم بندی شد. پس از مشخص شدن داده های ورودی و هدف و چندین بار اجرا شدن برنامه، نتایج حاصل از اجرای برنامه در جداولی نوشته شد. در

سپس داده های آزمون را مشخص کرده و وارد تابع به دست آمده از داده های Train می کنیم. برای شبکه عصبی، پس از نرمال سازی داده های دبی آب به عنوان ورودی شبکه و رسوب نظیر به نظیر دبی آب به عنوان داده های هدف شبکه عصبی انتخاب گردید. سپس ۸۰ درصد داده ها به عنوان داده های آموزش ، یعنی داده هایی که با استفاده از آن شبکه

جدول زیر می توان، نتایج به دست آمده از دو شبکه ی عصبی را مشاهده کرد.

جدول ۵- نتایج حاصل از شبکه عصبی

Table 5. Neural network results

R	SSE	RMSE	MSE	فاز	تعداد نوروں ها	
۰/۷۷	۱/۶۹۲۶	۰/۰۵۰۸	۰/۰۰۲۵	آموزش	۷	تابع شعاعی
۰/۹۱	۰/۰۰۴	۰/۰۰۷	$5e^{-4} \cdot 9273$	تست		
۰/۷۷	۱/۷۱۷۱	۰/۰۴۵۶	۰/۰۰۲	مجموع		
۰/۸۳	۱/۰۹۷۴	۰/۰۴۰۸	۰/۰۰۱۶	آموزش	۷	MLP پرسپترون چندلایه
۰/۹۷	۰/۰۰۸۲	۰/۰۱	۰/۰۰۰۱	تست		
۰/۸	۱/۵۶۸۸	۰/۰۴۳۶	۰/۰۰۱۹	مجموع		

curves." Journal of Hydrology 234(3-4): 228-248.

- Julien.P. Y. Erosion and sedimentation, (2010). Cambridge, UK: Cambridge University Press,
- Kisi, O., (2004), Multi-layer perceptrons with Levenberg-Marquardt training algorithm for suspended sediment concentration prediction and estimation. Hydrol. Sci. J. 49 (6), 1025-1040.
- Kisi, O., Yuksel, I., Dogan, E., (2008) Modelling daily suspended sediment of rivers in Turkey using several data-driven techniques. Hydrol. Sci. J. 53 (6), 1270-1285.
- Eivani, Z., M.M. Ahmadi and K. Qaderi. 2016. Estimation of suspended sediment load concentration in river system using Group Method of Data Handling (GMDH). Journal of Watershed Management Research, 7(13): 218-229. (In Persian)
- Kia, E., A. Emadi and R. Fazlola. 2015. Investigation for application of Adaptive Neuro-Fuzzy Inference System (ANFIS) in Babolroud suspended sediment load estimation.

از جدول ۵ این گونه استنباط می شود که شبکه RBF به دلیل داشتن خطای کمتر در مرحله آزمون دارای عملکرد بهتری است، اما با در نظر گرفتن سایر پارامترها و همچنین میزان خطا در مرحلهی TRAIN به نظر می رسد شبکه MLP دارای عملکرد بهتری است.

با مقایسه دو جدول قبل این گونه برداشت می شود که، میزان خطا و همچنین R و Rsq در شبکه عصبی کمتر بوده و نشان از قدرت بیشتر شبکه عصبی در تخمین و پیش بینی رسوب دارد.

References

- Avarideh F, Bani Habib, M and Taher Shamsi, A (2001), Application of Artificial Neural Networks to Estimate River Sediment Flow, Third Iranian Hydraulic Conference, Tehran, University of Tehran, Faculty of Engineering. (In Persian)
- Mesbahi, J, Chini, M, (1998), River Engineering Culture, Substantiation Plan of Technical Criteria and Standards of Water Industry, Ministry of Energy. (In Persian)
- Asselman, N. E. M. (2000). Fitting and interpretation of sediment rating

- Conservation, 22(2): 143-158. (In Persian)
15. Zahiri, A., F. Hashemi and I. Yousefabadi. 2016. Simulation of two-dimensional velocity distributions in rivers based on Chiu's theory (Case Study: Gorganrood River). Iranian Journal of Eco-Hydrology, 4(3): 791-802. (In Persian)
 16. Munir, S, (2011), Role of sediment transport in operation and maintenance of supply and demand based irrigation canals[D]. Doctoral Thesis, Wageningen, The Netherlands: Wageningen University
 17. Nagy, H.M., Watanabe, K., Hirano, M. (2002). Prediction of Sediment Load concentration in Rivers Using Artificial Neural Network Model. J. Hydraulic Eng.(ASCE), 128(6): 8-595.
 18. Sivakumar, B., Wallender, W., (2005). Predictability of river flow and suspended sediment transport in the Mississippi River basin: a non-linear deterministic approach. Earth Surf. Process. Landforms Earth Surf. Process. Landforms 30, 665-677.
 9. Kitsikoudis, V. and V. Hrissanthou. 2013. Derivation of sediment transport models for sand bed rivers from data-driven techniques. InTech-Open, Chapter 11: 277-308.
 10. Harris, E.L., V. Babovic and R.A. Falconer. 2003. Velocity predictions in compound channels with vegetated floodplains using genetic programming. International Journal of River Basin Management, 1(2): 117-123.
 11. Azamathulla, H.Md. and A. Zahiri. 2012. Flow discharge prediction in compound channels using linear genetic programming. Journal of Hydrology, 454: 203-207.
 12. Kitsikoudis, V. and V. Hrissanthou. 2013. Derivation of sediment transport models for sand bed rivers from data-driven techniques. InTech-Open, Chapter 11: 277-308.
 13. Kitsikoudis, V., E. Sidiropoulos and V. Hrissanthou. 2015. Assessment of sediment transport approaches for sand-bed Rivers by means of machine learning. Hydrological Sciences Journal, 60(9): 1566-1586.
 14. Zahiri, A. and B. Dahanzadeh. 2015. Sediment transport prediction in rivers using quasi-two dimensional model. Journal of Water and Soil