

بررسی کارایی شبکه عصبی مصنوعی در برآورد بار معلق رودخانه با استفاده از داده‌های
دسته‌بندی شده

همایون فقیه، عطا امینی، فرزانه حیدری و کیوان خلیلی



دوره ۱، شماره ۱، زمستان ۱۳۹۴، صفحات: ۶۴-۵۱

www.jewe.ir

نحوه ارجاع به این مقاله: فقیه ه، امینی ع، حیدری ف. و خلیلی ک. (۱۳۹۴). بررسی کارایی شبکه عصبی مصنوعی در برآورد بار معلق رودخانه با استفاده از داده‌های دسته بندی شده. محیط زیست و مهندسی آب، جلد ۱، شماره ۱، صفحات: ۶۴-۵۱.

How to cite this paper: Faghih H., Amini A., Haidari F. and Khalili K. (2015). Assessing the Artificial Neural Network efficiency to estimate suspended sediment load using classified data. J. Environ. Water Eng. 1(1), 51-64.

بررسی کارایی شبکه عصبی مصنوعی در برآورد بار معلق رودخانه با استفاده از داده‌های دسته‌بندی شده

همایون فقیه^{۱*}، عطا امینی^۲، فرزانه حیدری^۳ و کیوان خلیلی^۴

- ۱ - دانشجوی دکتری گروه مهندسی آب، دانشگاه ارومیه، ارومیه، ایران
- ۲- استادیار، مرکز آموزش و تحقیقات کشاورزی و منابع طبیعی کردستان، سنندج، ایران
- ۳- کارشناسی ارشد آبیاری زهکشی، بوعلی سینای همدان، همدان، ایران
- ۴- استادیار گروه مهندسی آب، دانشگاه ارومیه، ارومیه، ایران

* نویسنده مسئول: hfaghhih54@gmail.com

تاریخ پذیرش: [۱۳۹۴/۰۹/۲۷]

تاریخ دریافت: [۹۴/۰۸/۲۰]

چکیده

بار رسوب جریان، شاخص مفیدی در پیش‌بینی فرسایش خاک در حوزه‌های آبخیز است؛ بنابراین تدوین مدلی برای برآورد بار رسوب می‌تواند در مدیریت و اجرای پروژه‌های آبخیزداری و مهندسی رودخانه مفید باشد. در این پژوهش روش دسته‌بندی داده‌ها به‌عنوان راهکاری برای افزایش دقت شبکه عصبی مصنوعی در تدوین مدل برآورد رسوب معلق بررسی شد. بدین منظور، میزان آورد رسوبات معلق رودخانه‌های خلیفه‌ترخان و چهل‌گزی در حوضه قشلاق در استان کردستان در سه حالت با روش شبکه عصبی مصنوعی با ساختار پرسپترون چندلایه برآورد شد. ابتدا داده‌های اندازه‌گیری شده، بدون هیچ‌گونه تفکیکی مدل‌سازی شدند. سپس داده‌های رواناب برمبنای وضعیت جریان به زیرمجموعه‌های پرآب و کم‌آب و داده‌های رسوب برمبنای غلظت رسوبات به زیرمجموعه‌های غلظت کم‌وزیاد دسته‌بندی شدند. از داده‌های مشاهده‌ای رواناب و رسوب برای واسنجی مدل‌ها استفاده شد. سپس مقادیر برآورد شده با داده‌های ثبت‌شده مقایسه و عملکرد این مدل‌ها با استفاده از معیارهای آماری مورد ارزیابی قرار گرفت. نتایج بیانگر نقش مؤثر دسته‌بندی داده‌ها در بهبود عملکرد روش شبکه عصبی مصنوعی در برآورد رسوب است. به‌طوری‌که دسته‌بندی برمبنای غلظت رسوبات کارایی مدل را در ایستگاه‌های چهل‌گزی و خلیفه‌ترخان به ترتیب ۱۶/۶ و ۳۰/۵ درصد افزایش داد. مقایسه دسته‌بندی‌های انجام‌شده نیز نشان داد که دسته‌بندی داده‌ها برمبنای غلظت رسوبات نسبت شدت جریان رودخانه مؤثرتر است. نتایج این پژوهش می‌تواند با تخمین دقیق‌تر میزان رسوبات معلق رودخانه‌های منتهی به دریاچه سد قشلاق، در بهبود مدیریت حوضه مورد استفاده قرار گیرد.

واژه‌های کلیدی: آب‌سنجی، شبکه عصبی مصنوعی، حوضه قشلاق، غلظت رسوب، کردستان

۱- مقدمه

فرسایش خاک و رسوب‌زادی در حوزه‌های آبخیز که باعث جابه‌جایی خاک، آلودگی آب‌ها و کم شدن عمر مفید سازه‌های آبی می‌شود، از مشکلات موجود در مدیریت منابع آب، خاک و محیط‌زیست است (Samadzadeh et al. 2013). این مسائل را می‌توان با برقراری و توسعه برنامه‌های اندازه‌گیری و پایش مقدار رسوب انتقالی در رودخانه‌ها مورد بررسی قرارداد (Mirzaei et al. 2002). رسوبات رودخانه‌ای به دو صورت بار معلق و بستر منتقل می‌شوند. نوع حرکت به صورت بار معلق یا بار بستر بستگی به ویژگی‌های مواد رسوبی، شرایط جریان، نوع بستر و رفتار رودخانه دارد (Shafaei Bajestan, 2011; Hassanzadeh Zardkhooni et al. 2015). جریان بار رسوب یکی از مهم‌ترین پارامترهای محاسباتی در پروژه‌های هیدرولیکی و شاخصی مفید در پیش‌بینی فرسایش خاک و محیط اکولوژیکی حوزه آبخیز است (Zhou et al. 2007; Hassanzadeh Zardkhooni et al. 2015). روش‌های برآورد بار رسوب رودخانه را به‌طور کلی می‌توان به دودسته روش‌های هیدرولیکی و هیدرولوژیکی تقسیم نمود. روش‌های هیدرولیکی بر اساس قوانین دینامیک و مکانیک سیالات توسعه یافته‌اند. در این روش‌ها رابطه‌ها با در نظر گرفتن ویژگی‌های هیدرولیکی جریان، به دست آمده‌اند. در بسیاری از ایستگاه‌های آب‌سنجی کشور و از جمله ایستگاه‌های بررسی شده در این پژوهش، چنین داده‌هایی به اندازه کافی پیدا نمی‌شود. روش‌های هیدرولوژیکی بر اساس اندازه‌گیری غلظت رسوب معلق و آورد جریان استوار است. این روش مستلزم اندازه‌گیری پیوسته بوده و معمولاً تنها برای رودخانه‌های مهم و دائمی مقدور است. هم‌چنین استفاده از این روش همواره با خطای زیادی همراه است (Asselman, 2000; Arabkhedri et al. 2005; Razavizadeh et al. 2014). بنابراین توسعه روش‌های کارآمد و دقیق برای برآورد آورد رسوب که این محدودیت‌ها را نداشته باشد اهمیت زیادی دارد. یکی از روش‌های جدید در حل مسائل مهندسی در دهه‌های اخیر، استفاده از شبکه‌های عصبی مصنوعی است (Razavizadeh et al. 2014). کاربرد شبکه عصبی مصنوعی اولین بار توسط French در سال ۱۹۹۲ در مسائل مرتبط با منابع آب مطرح شد (Falamaki et al. 2013). شبکه‌های عصبی ابزار محاسباتی قوی و توانمندی هستند که در ساماندهی و ایجاد رابطه بین اطلاعات گوناگون قابلیت‌های بسیار خوبی دارند. قابلیت‌های بالای این سامانه‌ها در نگاشت فضاهای با بعد وسیع و هم‌چنین در تحلیل مسائلی که درک آن‌ها با استفاده از روابط پیچیده ریاضی دشوار است، می‌تواند مفید باشد. به‌طور کلی شبکه‌های عصبی مصنوعی در برخورد با مسائلی از قبیل شناسایی سیستم، تقریب و تخمین، بهینه‌سازی، شبیه‌سازی و پیش‌بینی رفتار و نظایر آن نتایج موفقیت‌آمیزی داشته‌اند (Cigizoglu, 2006; Kisi و Kalteh, 2013). به دلیل توانایی این شبکه‌ها در مدل‌سازی فرآیندهای پیچیده که تعداد عوامل تأثیرگذار بر آن‌ها زیاد است، استفاده از آن‌ها در علوم مهندسی آب و کشاورزی روندی افزایشی داشته و پژوهش‌های زیادی نیز تا به حال انجام گرفته است (He et al. 2014; Asefa et al. 2006; Yu et al. 2006; Deka و Raghavendra, 2014). برای برآورد بار رسوبی رودخانه‌ها به‌وسیله شبکه‌های عصبی نیز پژوهش‌های مختلفی در ایران و جهان انجام شده است. Sarangi و Bhattacharya (2005) برای پیش‌بینی آورد رسوب در حوضه بانها به مقایسه مدل شبکه عصبی مصنوعی و روش‌های رگرسیونی پرداختند. آن‌ها نتیجه‌گیری نمودند که مدل شبکه عصبی از دقت بیشتری نسبت به مدل‌های رگرسیونی برخوردار است. Mustafa et al. (2011) با مقایسه دو مدل از شبکه‌های عصبی مصنوعی برای برآورد بار معلق رسوب به این نتیجه رسیدند که این مدل‌ها از قابلیت مناسبی برخوردار می‌باشند. Fatahi et al. (2006) میزان رسوب رودخانه نکا را با شبکه پرسپترون چندلایه پیش‌بینی و با نتایج حاصله از روش منحنی سنجه رسوب مقایسه کردند. نتایج پژوهش آن‌ها برتری روش شبکه عصبی را نسبت به روش منحنی سنجه نشان داد. sharma et al. (2015) مدل‌سازی رواناب و بار رسوب حوضه‌ای در نپال را به‌وسیله شبکه‌های مصنوعی انجام دادند. نتایج آن‌ها نشان داد شبکه عصبی کارایی خوبی در مدل‌سازی رواناب و بار رسوب دارد. Razavizadeh et al. (2014) پژوهشی در زمینه تخمین آورد بار معلق رسوب با استفاده از بهترین ساختار شبکه عصبی

مصنوعی در حوزه آبخیز طالقان انجام دادند. (Janston et al. (2014) بر لزوم جداسازی خطای ناشی از عدم دقت روش‌های محاسباتی از خطای سامانه‌ای ناشی از تغییر شرایط هیدرولوژیکی رودخانه در اثر عواملی چون توسعه شهرنشینی، توسعه کشاورزی و یا اعمال مدیریت‌های آبخیزداری تأکید نمودند. (Dehghani et al. (2009) منحنی سنجه را با روش‌های مختلف دسته‌بندی شامل فصلی، ماهانه، دبی کلاسه، دوره مشابه هیدرولوژیکی، دوره کم‌آب و پرآب و نوع جریان برای مدل‌سازی آورد رسوب در رودخانه دوغ در استان گلستان استخراج و استفاده نمودند. این پژوهش و نیز توجه به این واقعیت که در رودخانه‌ها غلظت رسوب برای میزان معینی از آورد آب در شاخه بالارونده هیدروگراف بیش‌تر از غلظت رسوب برای همان میزان آورد در شاخه پایین‌رونده است، بر لزوم دسته‌بندی داده‌ها به‌منظور افزایش دقت روش‌های محاسباتی تأکید می‌نمایند. از این‌رو در پژوهش حاضر با اعمال دسته‌بندی داده‌های رواناب و رسوب دقت روش شبکه عصبی مصنوعی در برآورد رسوب انتقالی دو رودخانه چهل‌گزی و خلیفه-ترخان، واقع در حوزه آبخیز سد قشلاق سنندج مورد ارزیابی قرار گرفت. با توجه به اهمیت سد قشلاق در تأمین آب شرب شهرستان سنندج، این پژوهش می‌تواند برای برآورد رسوب ورودی به سد و کنترل آن موردتوجه قرار گیرد.

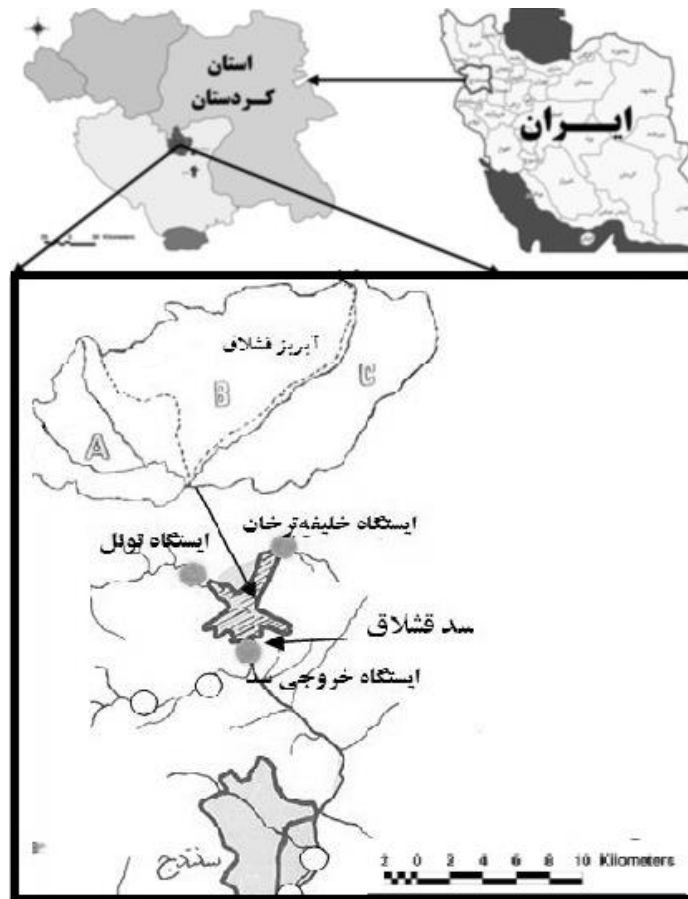
۲- مواد و روش‌ها

۲-۱- منطقه موردبررسی

حوزه آبخیز سد قشلاق در استان کردستان و شمال شهرستان سنندج قرار گرفته است. مساحت این حوضه ۱۰۷۰ کیلومترمربع است که حدود ۳/۸ درصد سطح استان را در برمی‌گیرد. حوزه آبخیز سد قشلاق دارای دو زیر حوضه اصلی به نام‌های چهل‌گزی (قطعه A) و خلیفه‌ترخان است. حوضه خلیفه‌ترخان نیز دارای دو زیر حوضه فرعی است که در مطالعات جامع حوضه قشلاق به صورت قطعه‌های B و C مشخص شده‌اند. مساحت این زیر حوضه‌ها به ترتیب ۲۶۷، ۴۱۶/۱ و ۳۸۶/۹ کیلومترمربع است. سد وحدت (قشلاق) بر روی رودخانه قشلاق از سرشاخه‌های اصلی رودخانه سیروان و در فاصله ۱۳ کیلومتری شهر سنندج برای تأمین نیاز آب شرب شهرستان سنندج و آبیاری اراضی پایاب به مساحت ۳۰۰۰ هکتار ساخته شده است. اهمیت سد باعث شده است که بررسی‌های آبخیزداری و داده‌برداری منظمی در حوضه انجام شود. رواناب‌های سطحی حوضه قشلاق از طریق دو رودخانه اصلی چهل‌گزی و خلیفه‌ترخان وارد دریاچه سد قشلاق می‌شود. در محل ورود این رودخانه‌ها به دریاچه سد وحدت دو ایستگاه آب‌سنجی به نام‌های چهل‌گزی (ایستگاه ۱) و خلیفه‌ترخان (ایستگاه ۲) وجود دارند که در این پژوهش داده‌های آن‌ها مورد استفاده قرار گرفتند. منطقه موردبررسی و موقعیت این ایستگاه‌ها در شکل (۱) نشان داده شده است.

۲-۲- داده‌های رواناب و رسوب

در این پژوهش داده‌های موجود در ایستگاه‌های ۱ و ۲ که به‌وسیله شرکت آب منطقه‌ای استان کردستان ثبت شده‌اند مورد استفاده قرار گرفتند. در این ایستگاه‌ها به ترتیب تعداد ۳۶۳ (۳۳ سال) و ۲۵۰ (۲۶ سال) داده متناظر آورد رواناب و رسوب ثبت شده است. این داده‌ها شامل آورد لحظه‌ای جریان به مترمکعب بر ثانیه و آورد رسوب لحظه‌ای به تن بر روز می‌باشند که به‌صورت هم‌زمان اندازه‌گیری شده‌اند. با استفاده از آزمون گرویز - بک داده‌های پرت در هر دو ایستگاه تعیین شدند. در این روش پوش بالا و پایین داده‌ها با استفاده از میانگین، انحراف معیار و آماره گرابز - بک محاسبه شده و داده‌ها با آن‌ها مقایسه می‌شوند. داده‌های کوچک‌تر از پوش پایین و بزرگ‌تر از پوش بالا به‌عنوان داده پرت حذف می‌شوند (Rezaei Pazhand, 2001). با توجه به این آزمون، در ایستگاه‌های ۱ و ۲ به ترتیب ۳ و ۱ داده پرت مشخص و حذف شدند؛ بنابراین در این پژوهش به ترتیب ۳۶۰ و ۲۴۹ نمونه مطلوب آورد آب و رسوب در ایستگاه‌های یک و دو مورد استفاده قرار گرفتند. محدوده و مشخصات داده‌های رواناب و رسوب در جدول (۱) ارائه شده است.



شکل ۱- منطقه مورد بررسی و موقعیت ایستگاه‌های استفاده‌شده

جدول ۱- محدوده داده‌های استفاده‌شده

ایستگاه ۲		ایستگاه ۱		پارامتر (عامل)
آورد رسوب (ton/day)	آورد جریان (m ³ /s)	آورد رسوب (ton/day)	آورد جریان (m ³ /s)	
۴۰۳۷۳/۴۹۸	۱۰۴/۵۰۰	۱۵۵۰۹/۴۹۴	۴۰/۵۲۱	بیشینه
۰/۰۲۶	۰/۰۴۰	۰/۰۲۸	۰/۰۲۰	کمینه
۶/۲۷۳	۱/۶۸۰	۶/۴۸۲	۱/۶۴۵	میانه
۵۱۴/۵۳۸	۵/۱۱۲	۱۷۹/۸۲۳	۲/۹۷۷	میانگین
۳۳۶۲/۰۴۳	۹/۹۲۸	۱۰۵۲/۶۱۵	۴/۲۹۳	انحراف معیار

همگنی داده‌ها در ایستگاه‌های آب‌سنجی با روش آزمون توالی و در محیط نرم‌افزار SPSS بررسی شد. نتایج حاصل از این آزمون بر روی داده‌های اندازه‌گیری شده رواناب و رسوب در هر دو ایستگاه بیانگر ناهمگن بودن این داده‌ها است. ناهمگنی داده‌های رواناب

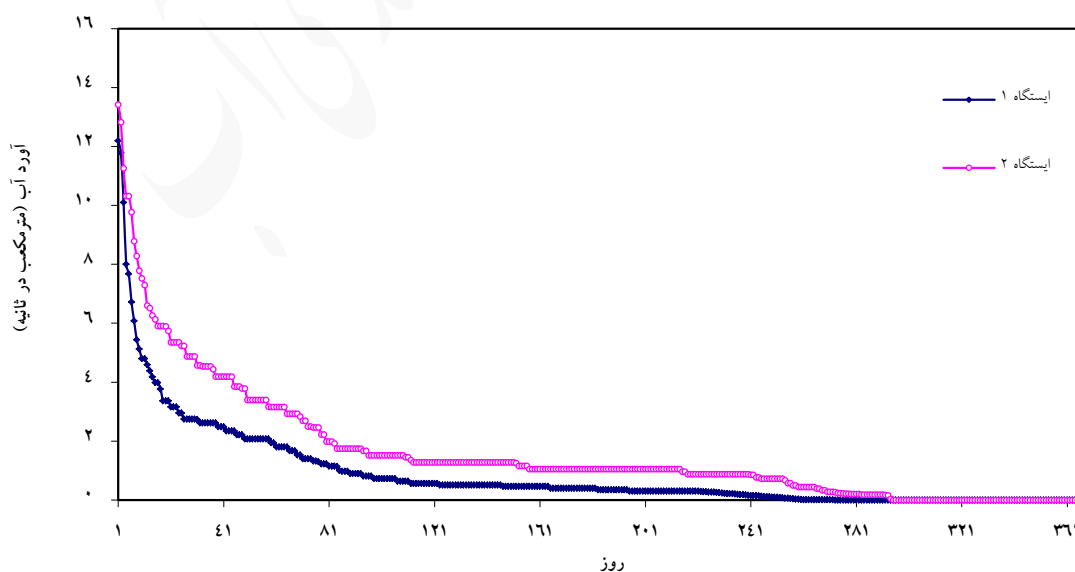
و رسوب در حوزه آبخیز سد قشلاق مانند بسیاری از حوزه‌های دیگر کشورمان به دلیل منشأ متفاوت سیلاب‌های این حوزه، تغییر کاربری اراضی، انجام عملیات آبخیزداری و احداث تأسیسات در طول دوره آماربرداری است.

۲-۳- دسته‌بندی داده‌ها

برای بررسی اثر دسته‌بندی داده‌ها در افزایش دقت تخمین میزان انتقال رسوب رودخانه، مدل شبکه عصبی در سه حالت مختلف استخراج شد. در حالت اول داده‌های رواناب و رسوب بدون اعمال دسته‌بندی مورداستفاده قرار گرفتند (حالت A). در حالت دوم برمبنای میزان رواناب (حالت B) و در حالت سوم بر اساس مقدار رسوب انتقالی (حالت C) داده‌های رواناب و رسوب دسته‌بندی و شبکه‌های عصبی مربوطه استخراج شدند. داده‌های آورد رسوب به‌عنوان داده‌های مطلوب و داده‌های آورد جریان به‌عنوان داده‌های ورودی برای مدل شبکه عصبی تعریف شدند.

۲-۳-۱- دسته‌بندی داده‌ها برمبنای جریان

در این نوع تقسیم‌بندی (مدل B)، داده‌های رواناب برمبنای میانگین روزانه آورد جریان رودخانه به دو زیرمجموعه پرآب (BF) و کم‌آب (BU)، دسته‌بندی شدند. برای اطلاع از ویژگی‌ها و امکان دسته‌بندی داده‌های مورداستفاده، منحنی‌های تداوم جریان در ایستگاه‌های ۱ و ۲ به ترتیب برای دوره‌های آماربرداری ۳۳ و ۲۶ ساله رسم شدند. نمونه‌ای از منحنی تداوم جریان رسم شده در ایستگاه‌های ۱ و ۲ در سال آبی ۱۳۶۳-۱۳۶۲ در شکل (۲) نشان داده شده است. ویژگی‌های جریان در رودخانه‌های موردبررسی که از منحنی تداوم جریان استخراج شده‌اند در جدول (۲) ارائه شده است. این جدول نشان می‌دهد که میانگین آورد روزانه جریان در ایستگاه ۱ و ۲ به ترتیب ۱/۵۴۳ و ۲/۶۴۲ مترمکعب در ثانیه می‌باشند. جریان با آورد بیش‌تر از میانگین آورد روزانه، در زیرمجموعه پرآب و جریان با آورد کم‌تر از میانگین آورد روزانه، در زیرمجموعه کم‌آب، قرار گرفتند. آنالیز داده‌ها نشان داد که در ایستگاه ۱ تعداد ۱۸۵ داده در شرایط پرآب و ۱۷۵ داده در شرایط کم‌آب برداشت شده‌اند. این تعداد در ایستگاه ۲ به ترتیب ۱۰۵ و ۱۴۴ داده می‌باشند.



شکل ۲- منحنی تداوم جریان رسم شده در ایستگاه‌های ۱ و ۲ در سال آبی ۱۳۶۳-۱۳۶۲

۲-۳-۲- دسته‌بندی بر مبنای داده‌های رسوب

در این روش دسته‌بندی داده، میزان میانگین رسوبات آورده شده مبنای تقسیم‌بندی داده‌ها قرار گرفت (مدل C). از این رو جریان با غلظت رسوب بیشتر از میانگین روزانه در زیرمجموعه پر غلظت (HC) و جریان با غلظت رسوب کم‌تر از میانگین روزانه در زیرمجموعه کم غلظت (LC) قرار گرفتند. بر اساس داده‌های اندازه‌گیری شده، میانگین آورد روزانه رسوب در ایستگاه‌های یک و دو به ترتیب ۲۰۰ و ۲۴۰ میلی‌گرم در لیتر محاسبه و از آن‌ها در دسته‌بندی داده‌ها استفاده شد. از داده‌های ثبت‌شده در ایستگاه ۱ تعداد ۶۵ داده در دسته‌بندی پر غلظت و تعداد ۲۹۵ داده در دسته‌بندی کم غلظت قرار گرفتند. این تعداد در ایستگاه ۲ به ترتیب ۳۲ و ۲۱۷ داده می‌باشند.

جدول ۲- مشخصات رواناب‌های ثبت‌شده در ایستگاه‌های مورد استفاده

ایستگاه	آورد جریان (m ³ /s)				
	نرمال پرآب	نرمال کم‌آب	نرمال	میانگین	میانه
۱	۱/۷۹۴	۰/۰۵۳	۰/۶۱۸	۱/۵۴۳	۰/۶۱۶
۲	۲/۹۰۴	۰/۱۸۶	۱/۰۹۴	۲/۶۴۲	۱/۰۸۹

۲-۴- روش شبکه عصبی مصنوعی

در شبکه‌های عصبی مصنوعی سعی بر این است که ساختاری مشابه ساختار بیولوژیکی مغز انسان و شبکه عصبی بدن طراحی شود (Karami et al. 2003). ویژگی کلیدی شبکه‌های عصبی توانایی خود یادگیری آن است (Kisi, 2010; Kalteh, 2013). عملکرد کلی شبکه‌های عصبی مصنوعی، به وسیله ساختار شبکه، خصوصیات نرون منفرد^۱ و تاکتیک یادگیری و داده‌های آموزش معین می‌شود (Joorabian و ZareOmidOstovar, 2009). پژوهش برای شناخت بهترین الگوها که دقیقاً شبیه و رقیب شبکه عصبی بیولوژیک باشد هنوز ادامه دارد. در سال‌های اخیر، چندین تابع تقریب‌گر عمومی^۲ پیشنهاد شده است که از آن جمله می‌توان پرسپترون چندلایه (MLP) را نام برد. یک نقطه قوت عملی این سامانه‌ها، این است که می‌توانند توابع غیرخطی را با تعداد زیادی متغیر، تقریب بزنند و از اطلاعات موجود در مجموعه‌های بسیار بزرگ عددی استفاده کنند (Monshi و Teshnehlab, 2003). این الگوریتم از زمان پیدایش به‌طور گسترده به‌عنوان یک الگوریتم آموزش در شبکه‌های عصبی پس‌خور^۳ استفاده شده است. الگوریتم پس انتشار به شبکه‌های عصبی مصنوعی با یک یا چندلایه پنهانی اعمال شده است. بر اساس این الگوریتم، شبکه، برنامه و طرح ارتباطی توزیع یافته بین لایه‌های خروجی و ورودی را یاد می‌گیرد. الگوریتم آموزش پس انتشار، یک ابزار ریاضی است که در آن، اجرای رابطه‌های آموزش بر اساس فرآیندهای تکراری است. بنابراین به سهولت بر روی رایانه‌ها قابل اجرا است. یک شبکه عصبی مصنوعی در حالت کلی ساختاری مشابه شکل (۳) دارد. شکل ریاضی شبکه عصبی مصنوعی با n ورودی، m لایه مخفی و p خروجی به صورت رابطه (۱) بیان می‌شود:

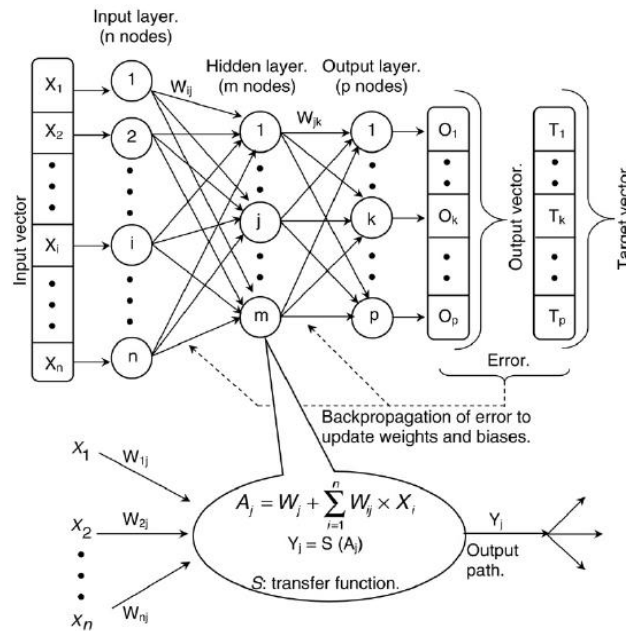
$$O_K = S.(\sum_{j=1}^m W_{jk} . S.(\sum_{i=1}^n W_{ij} . X_i)) \quad (1)$$

در این رابطه O_k و X_i مقادیر خروجی و ورودی شبکه، W_{ij} وزن‌های ارتباطی بین لایه ورودی و لایه مخفی، W_{jk} وزن‌های ارتباطی بین لایه مخفی و لایه خروجی و S تابع انتقال است.

1- Individual neuron

2 - Universal Approximator Function

3 - Feed Forward



شکل ۳- ساختار کلی شبکه‌های عصبی مصنوعی

۲-۵- مدل سازی شبکه عصبی

در این پژوهش از نرم‌افزار Neurosolutions (نسخه ۵) برای تدوین مدل‌های شبکه عصبی مصنوعی و انجام محاسبات مربوط به آن استفاده شد. هم‌چنین، از مدل شبکه عصبی مصنوعی با ساختار پس‌خور چندلایه برای تخمین آورد رسوب معلق در ایستگاه‌های آب‌سنجی ۱ و ۲ استفاده شد. ساختار مورد استفاده، شامل یک‌لایه ورودی (آورد جریان)، یک‌لایه خروجی (مقدار رسوب) و لایه پنهان بود. تعداد لایه پنهان و تابع انتقال مناسب به صورت سعی و خطا تعیین شد. برای آموزش شبکه از روش آموزشی انتشار به عقب خطا استفاده و از میان الگوریتم‌های مختلف این روش آموزشی، الگوریتم مناسب با سعی و خطا انتخاب شد. هم‌چنین روند آموزش الگو به الگو در تدوین مدل‌های شبکه عصبی مصنوعی به کار رفت. به‌طور کلی در روش شبکه عصبی مصنوعی برای طراحی مدل، شبکه‌های مختلف با تغییر پارامترهای قابل تنظیم که شامل تابع انتقال، قانون یادگیری، مقدار مومنتم، تعداد لایه میانی، تعداد نرون‌های لایه میانی و تعداد الگوها می‌باشند، ساخته و اجرا شد. براین اساس برای هر یک از حالت‌های A, BF, BU, HC و LC در ایستگاه ۱ به ترتیب ۴۴، ۴۵، ۴۶، ۴۶ و ۴۷ ساختار و در ایستگاه ۲ به ترتیب ۴۰، ۴۲، ۴۷ و ۴۷ ساختار شبکه عصبی مصنوعی طراحی شد. بدین ترتیب برای ایستگاه‌های ۱ و ۲ به ترتیب ۲۲۸ و ۲۲۲ ساختار و در مجموع ۴۵۰ ساختار بررسی شد.

۲-۶- واسنجی و صحت سنجی مدل‌ها

در هر یک از سه حالت دسته‌بندی داده‌ها، برای هر مدل، عمل چیدن تصادفی ردیف‌ها (داده‌های متناظر رواناب و رسوب) در صفحه گسترده اکسل انجام شد. سپس ۷۰ درصد از ردیف‌های هر ستون برای آموزش (واسنجی) و ۳۰ درصد برای آزمون (صحت سنجی) شبکه عصبی مورد استفاده قرار گرفتند. این روش تقسیم‌بندی داده‌ها در مدل‌سازی مورد استفاده قرار می‌گیرد (Sadeghi, 2001; Telvari, 2005). در چیدن تصادفی داده‌ها و انتخاب داده‌های آموزش و آزمون سعی شد که هر دو سری داده‌ها به لحاظ پارامترهای میانگین و انحراف معیار به هم نزدیک باشند. در این پژوهش برای واسنجی مدل‌ها، با استفاده از روش گفته‌شده، مدل-

های شبکه عصبی مصنوعی استخراج شدند. سپس صحت سنجی مدل‌ها با مقایسه نتایج مدل‌های تدوین‌شده و داده‌های آزمون انجام گرفت. برای حصول اطمینان از روند مدل‌سازی، اعتبارسنجی و ارزیابی دقت مدل‌های تدوین‌شده و همچنین مقایسه مدل‌ها در حالت‌های مختلف، از معیارهای آماری جذر میانگین مربعات خطا (RMSE)^۱ و میانگین خطای مطلق (MAE)^۲ استفاده استفاده شد. این معیارها دقت مدل را بر اساس تفاضل بین مقادیر واقعی و مقادیر برآورد شده ارزیابی می‌کنند. RMSE و MAE به ترتیب از روابط ۲ و ۳ به دست می‌آیند. مقدار RMSE و MAE از صفر تا بی‌نهایت تغییر می‌کنند. هرچه مقدار RMSE و MAE به صفر نزدیک‌تر باشند، نشان‌دهنده عملکرد بهتر مدل است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n ((y_{est})_i - (y_{obs})_i)^2}{n}} \quad (2)$$

$$MAE = \frac{\sum_{i=1}^n |(y_{est})_i - (y_{obs})_i|}{n} \quad (3)$$

در روابط بالا، y_{obs} مقادیر مشاهده‌شده، y_{est} مقادیر برآورد شده (خروجی مدل) و n تعداد داده‌ها می‌باشند.

۳- یافته‌ها و بحث

در جدول (۴) بهترین ساختار مدل شبکه عصبی مصنوعی برای ایستگاه چهل‌گری (ایستگاه ۱) و خلیفه‌ترخان (ایستگاه ۲) در حالت‌های مختلف ارائه شده است. در این جدول تابع انتقال تانژانت هیپربولیک و سیگموئید به ترتیب با علائم (Tanh) و (Sig) و قانون آموزش لونیگ مارکارت و مومنتوم به ترتیب با علائم (LM) و (Mom) نشان داده شده‌اند.

جدول ۴- ساختار بهترین مدل شبکه عصبی و نتیجه اجرای آن برای هر ایستگاه در حالت‌های مختلف.

ایستگاه	مدل	تعداد ورودی	تعداد خروجی	تعداد لایه پنهان	تعداد لایه پنهان	تابع انتقال		قانون آموزش	مقدار مومنتوم	مقدار تکرار بیشینه	مقدار خطا (تن در روز)	
						ورودی	خروجی				MAE	RMSE
۱	A	۱	۱	۱	۹	Tanh	Tanh	LM	-	۱۰۰۰	۶۶۱/۶۵	۱۲۸/۶۱
۱	BF	۱	۱	۱	۵	Tanh	Tanh	Mom	۰/۳	۱۰۰۰	۸۸۱/۳۶	۳۱۸/۶۴
۱	BU	۱	۱	۱	۶	Tanh	Tanh	LM	-	۱۰۰۰	۴/۲۶	۲/۵۷
۱	HC	۱	۱	۱	۸	Tanh	Tanh	LM	-	۱۰۰۰	۱۹۰۸/۶۰	۹۲۲/۲
۱	LC	۱	۱	۱	۸	Sig	Sig	LM	-	۱۰۰۰	۳۱/۱۴	۱۳/۰۸
۲	A	۱	۱	۱	۶	Tanh	Tanh	LM	-	۱۰۰۰	۹۲۸/۲۴	۱۹۸/۲۹
۲	BF	۱	۱	۱	۲	Tanh	Tanh	LM	-	۱۰۰۰	۱۵۹۹/۳۲	۷۳۹/۴۱
۲	BU	۱	۱	۱	۴	Tanh	Tanh	LM	-	۱۰۰۰	۵/۵۶	۲/۸۶
۲	HC	۱	۱	۱	۱۰	Tanh	Tanh	LM	-	۱۰۰۰	۲۲۵۳/۵۹	۱۸۹۲/۶۷
۲	LC	۱	۱	۱	۴	Tanh	Tanh	LM	-	۱۰۰۰	۹۳/۴۶	۲۷/۱۲

1- Root Mean Square of Error

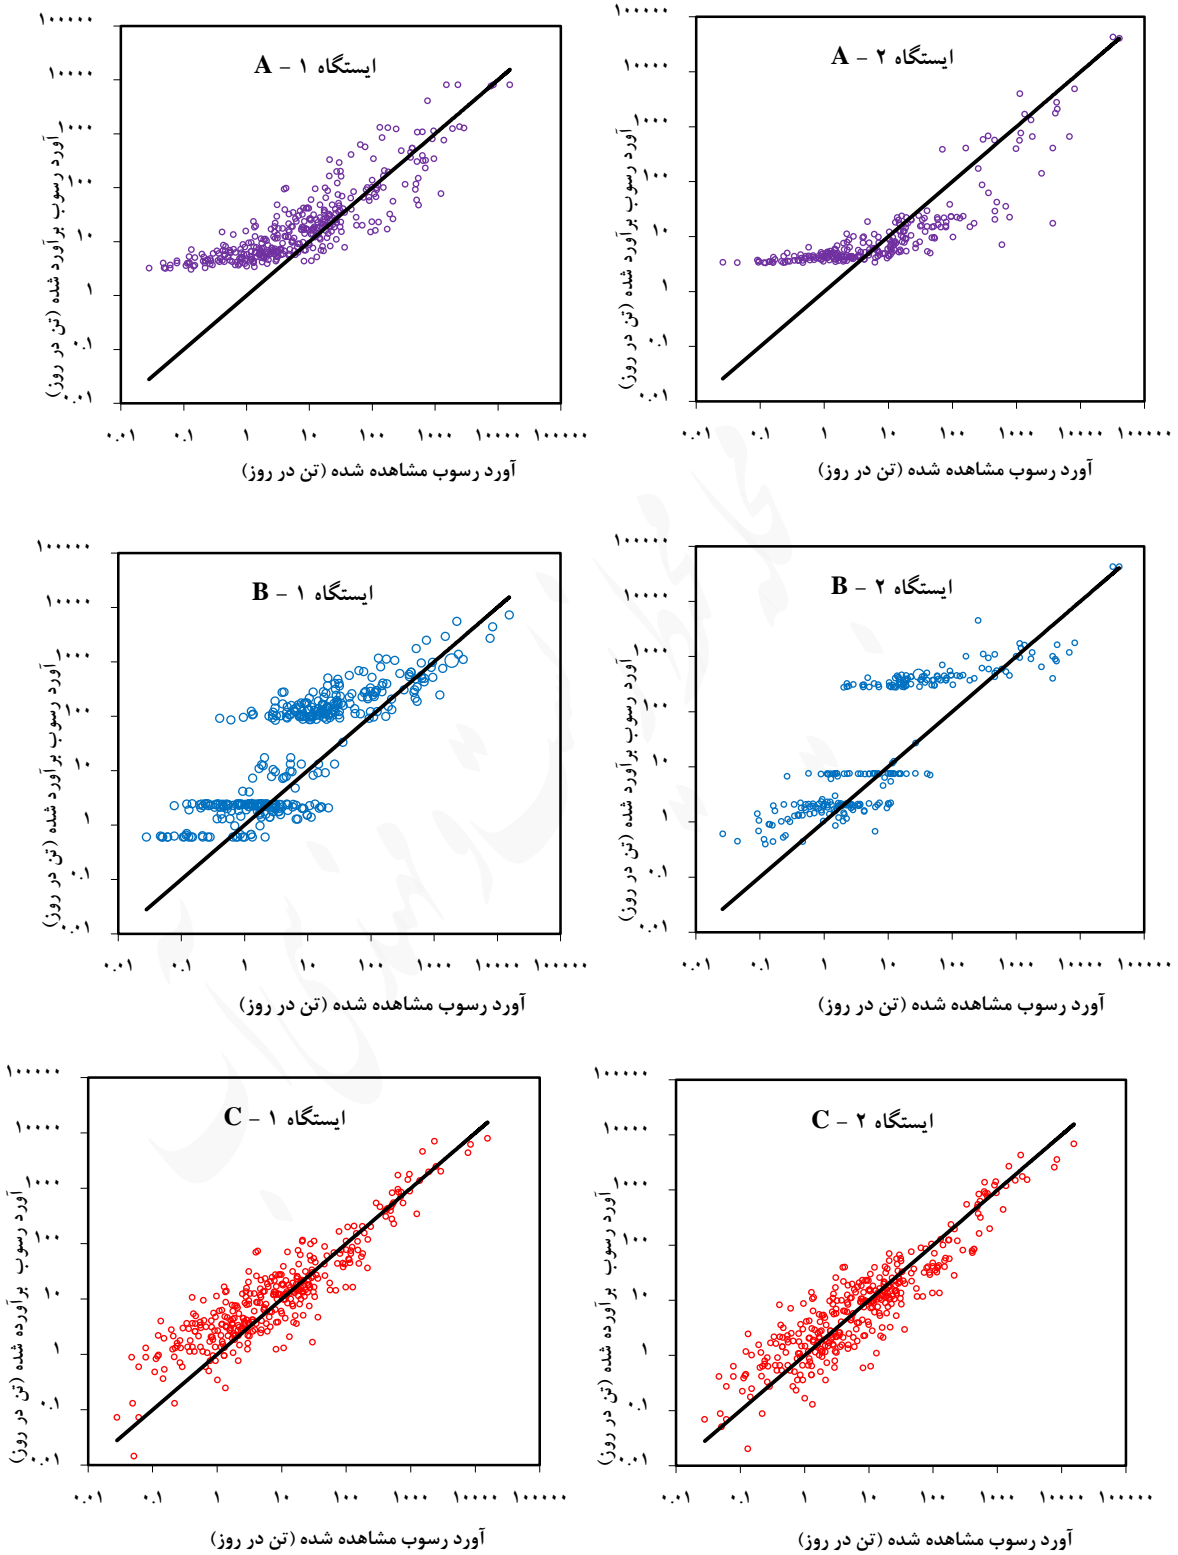
2- Mean Absolute Error

با بررسی جدول (۴) مشاهده می‌شود که در تدوین همه مدل‌های A, BF, BU, HC و LC برای ایستگاه ۲، بهترین مدل از نظر دقت با استفاده از تابع انتقال تانژانت هیپربولیک و قانون آموزش لونیبرگ مارکارت حاصل شده است. برای ایستگاه ۱ نیز در تدوین همه مدل‌ها به‌غیر از مدل LC بهترین مدل از نظر دقت با استفاده از تابع انتقال تانژانت هیپربولیک حاصل شده است. در این ایستگاه برای مدل LC تابع انتقال سیگموئید عملکرد بهتری داشت. در این ایستگاه قانون آموزش مناسب در بهترین مدل‌ها در چهار حالت A, BU, LC و HC لونیبرگ مارکارت و در حالت BF مومنتوم بوده است؛ بنابراین هشت مدل از ده مدل برآورد رسوب معلق تدوین شده با شبکه عصبی مصنوعی با استفاده از تابع انتقال تانژانت هیپربولیک و قانون آموزش لونیبرگ مارکارت حاصل شده است. از این رو می‌توان گفت که در اکثر مدل‌ها در این پژوهش، ترکیب تابع انتقال تانژانت هیپربولیک و قانون آموزش لونیبرگ مارکارت از سایر ترکیب‌های تابع انتقال و قانون آموزش عملکرد بهتری داشته است. بررسی‌ها نشان داده است که قانون آموزش لونیبرگ مارکارت برای بیشتر کاربردها نتایج دقیق و سریعی نسبت به سایر قانون‌های روش آموزش انتشار به عقب خطا ارائه می‌دهد (Lin, 2010; Faghhih, 2010; Van Cauwenberghe et al. 2014; Tan, 1999; Hagan, 1994) اما باید گفت برای همه مسئله‌ها الگوی تعیین شده‌ای وجود ندارد و تعیین بهترین الگو برای هر مسئله نیازمند انجام سعی و خطاهای مکرر و آزمون روش‌ها است (Falamaki et al. 2013). برای ارزیابی و مقایسه بهتر روش‌های دسته‌بندی، داده‌های آموزش و آزمون که با مدل‌های BU و BF برآورد شدند و در مجموع متناظر با داده‌های آموزش و آزمون مدل A هستند با داده‌های واقعی مقایسه و نتایج آن با عنوان مدل B ارائه شده است (جدول ۵). همچنین در جدول (۵) داده‌های آموزش و آزمون که با مدل‌های HC و LC برآورد شدند و متناظر با داده‌های آموزش و آزمون مدل A هستند با داده‌های مشاهده‌ای مقایسه و نتایج آن با عنوان مدل C ارائه شده است. نتایج نشان دادند که برای کل داده‌ها (آموزش و آزمون)، مقدار RMSE برای مدل C در ایستگاه ۱ به ترتیب ۱۶/۶ و ۱۲/۷ درصد و در ایستگاه ۲ به ترتیب ۳۰/۵ و ۳۷/۹ درصد کم‌تر از مدل A و B می‌باشند.

جدول ۵- خلاصه نتایج آزمون روش شبکه عصبی مصنوعی در دو ایستگاه تونل و خلیفه‌ترخان

مدل	ایستگاه تونل (۱)		ایستگاه خلیفه‌ترخان (۲)	
	MAE	RMSE	MAE	RMSE
A	۱۲۸/۶۰۸	۶۶۱/۶۵۱	۱۹۸/۲۸۷	۹۲۸/۲۳۵
B	۱۶۴/۹۹۳	۶۳۱/۸۱۷	۳۱۳/۴۵۷	۱۰۳۸/۵۶
C	۸۸/۸۴۳	۵۵۱/۷۷۲	۱۷۶/۰۰	۶۴۴/۹۴۷

در مقایسه کارایی مدل‌ها، هرچه نتایج پیش‌بینی شده بیش‌تر به داده‌های مشاهداتی نزدیک‌تر باشند کارایی مدل مطلوب‌تر است. در شکل (۴)، نتایج برآورد مدل‌ها برای کل داده‌ها (آموزش و آزمون) در مقابل داده‌های مشاهده‌شده ترسیم شده است. شکل (۴) همچنین نشان می‌دهد که در هر دو ایستگاه مدل C برازش بهتری نسبت به مدل‌های A و B دارند. از این رو می‌توان گفت که روش منحنی سنجه با استفاده از روش تقسیم‌بندی داده‌ها (حالت C)، در برآورد رسوب روزانه در حوضه قشلاق از توانایی مناسبی برخوردار است و داده‌های برآورد شده دارای برآزش و انطباق خوبی با داده‌های واقعی می‌باشند. با توجه به شکل (۴) می‌توان گفت که بیش‌ترین خطا در مدل A مربوط به برآورد مقادیر پایین رسوب بوده است. همچنین مدل B برای تمام دامنه (کم تا زیاد) مقدار رسوب، با خطای زیادی همراه بوده است. برخلاف دو مدل A و B، مدل C برای مقادیر کم‌وزیاد رسوب برآورد خوبی داشته است. مقدار خطای این مدل برای برآورد مقادیر بالا آورد رسوب تانژانت‌های کم‌تر از مقادیر میانگین و کم رسوب بوده است و این دلیل اصلی دقت بیشتر آن نسبت به دو مدل دیگر است.



شکل ۴- میزان کارایی منحنی‌های سنجه به‌دست‌آمده در برآورد رسوب در حالت‌های مختلف

۴- نتیجه گیری

تعیین معادلات حاکم برای برآورد رسوب انتقالی رودخانه و مشخص نمودن میزان تأثیر پارامترهای مختلف، همواره مورد توجه محققین بوده است. ضمن اینکه دسترسی به داده‌های لازم در بیشتر موارد به آسانی میسر نیست؛ بنابراین با توجه به توانایی شبکه عصبی مصنوعی در مدل‌سازی فرآیندهای پیچیده، در این پژوهش سعی شد که کارایی آن در تخمین آورد رسوب معلق رودخانه‌های چهل‌گزی و خلیفه‌ترخان بررسی شود. مهم‌ترین نتایج این پژوهش را می‌توان به صورت زیر بیان نمود:

۱- میانگین آورد روزانه جریان برای ایستگاه خلیفه‌ترخان و تونل به ترتیب $۲/۶۴۲$ و $۱/۵۴۳$ مترمکعب در ثانیه به دست آمده آمد. هم‌چنین میانگین آورد روزانه رسوب معلق برای ایستگاه خلیفه‌ترخان و تونل به ترتیب برابر با $۵۴/۸$ و $۲۶/۷$ تن در روز برآورد شد.

۲- با توجه به مساحت حوضه خلیفه‌ترخان و چهل‌گزی، مقدار آورد ویژه بار معلق (مقدار رسوب در واحد سطح) این دو حوضه به ترتیب برابر با $۲۴/۹$ و $۳۶/۵$ تن در کیلومترمربع در سال برآورد شد.

۳- در برآورد رسوب معلق روزانه، کم‌ترین مقدار خطا برآورد و در نتیجه بهترین مدل‌ها از نظر دقت در اکثر موارد با استفاده از تابع انتقال تانژانت هیپربولیک و قانون آموزش لونیگ مارکارت حاصل می‌شود.

۴- مانند بسیاری از مسائل مهندسی، شبکه عصبی مصنوعی در تعیین بار معلق رودخانه موفق بوده و با استفاده از روش دسته‌بندی داده می‌توان از خطای روش شبکه عصبی مصنوعی در تدوین مدل برآورد رسوب انتقالی رودخانه کاست.

به نظر می‌رسد چنانچه در مدل‌سازی به وسیله شبکه عصبی مصنوعی، انتخاب تابع انتقال، قانون آموزش و سایر پارامترهای مورد نیاز برای طراحی مدل، از طریق بررسی تأثیر آن‌ها بر دقت مدل صورت گیرد نتایج بهتری حاصل می‌گردد. از معیارهای مختلفی برای دسته‌بندی داده‌ها آورد جریان و رسوب می‌توان استفاده نمود؛ بنابراین از ترکیب آن‌ها و شبکه عصبی مصنوعی می‌توان برای تدوین مدل‌های برآورد بار رسوب استفاده نمود و نتایج آن‌ها را با نتایج این پژوهش مقایسه نمود.

References

- Arabkhedri M. (2005). Investigation of suspended load in Iran's watershed basin. *Iranian J. Water Resour.*, 20(2), 51-60.
- Asefa T., Kemblowski M., Mc Kee M. and Khalil A. (2006). Multi-time scale stream flow predictions, the support vector machines approach. *J. Hydrol.*, 318(1-4), 7-16.
- Asselman N. (2000). Fitting and interpretation of sediment rating curves. *J. Hydrol.*, 23(4), 228-248.
- Dehghani A. A., Zanganeh M. A., Mosaedi A. and Kohestani N. (2009). Comparison of suspended sediment estimation by artificial neural network and sediment rating curve methods (Case study: Doogh River in Golestan Province). *J. Agric. Sci. Natur. Resour.*, 1(16), 266-276 [In Persian].
- Faghih, H. (2010). Evaluating artificial neural network and its optimization using genetic algorithm in estimation of monthly precipitation data (Case study: Kurdistan Region), *J. Wat. Soil Sci.*, 14(51), 27-42 [In Persian].
- Falamaki A., Eskandari M., Baghlani A. and Ahmadi S. A. (2013). Modeling total sediment load in rivers using artificial neural networks. *J. Wat. Soil Resource Conservation*, 3(3), 13-25 [In Persian].
- Fatahi M, Tousi S. and Ahmadi M. Z. (2006). Sedimentation estimation of Neka River using artificial neural network, The 7th International Seminar on River Engineering, Shahid Chamran University, Ahvaz, Iran [In Persian].
- Hagan M. T. and Menhaj M. B. (1994). Training feed forward networks with the Marquardt algorithm. *IEEE, ransom neural networks* 5.
- Harma N., Zakaullah M.D., Tiwari H. and Kumar D. (2015). Runoff and sediment yield modeling using ANN and support vector machines: a case study from Nepal watershed. *Earth Sys.*, 1(1), 14- 23.
- Hassanzadeh Zardkhoni M., Sedghi Asl M. and Prvizi M. (2015). Evaluation of the hydrological methods for predicting suspended sediment load in rivers (Case study: Chamsiah River). *Iran Wat. Res. J.*, 9(1), 41-48 [In Persian].
- He Z., Wen X., Liu H. and Du J. (2014). A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *J. Hydrol.*, 509(5), 379-386.
- Joorabian M. and Zare-Omid-Ostovar T. (2009). Artificial neural networks. Shahid Chamran University Press, Ahvaz, Iran [In Persian].
- Juston J., Jansson P. E. and Gustafsson D. (2014). Rating curve uncertainty and change detection in discharge time series, case study with 44-Year historic data from the Nyangores River, Kenya. *Hydrol. Process.* 28(10), 2509-2523.
- Kalteh A. M. (2013). Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform. *Comput. Geosci.*, 54(5), 1-8.
- Karami A., Homae M., Neyshabouri M. R., Afzalinia S. and Basirat S. (2012). Large scale evaluation of single storm and short/long term erosivity index models. *Turkish J. Agricul. Forestry*, 36(2), 207-216.
- Kerem Cigizoglu H. and Kisi O. (2006). Methods to improve the neural network performance in suspended sediment estimation. *J. Hydrol.*, 1317(3-4), 221-238.
- Kisi O. (2010). River suspended sediment concentration modeling using a neural differential evolution approach. *J. Hydrol.*, 1389 (1), 227-235.
- Lin L., Xiaolong Z., Kai Z. and Jun L. (2014). Bilinear grid search strategy based support vector machines learning method. *Informatica*, 38(8), 51-58.

- Mirzaei M. (2002). Comparison of statistical estimating methods of the rivers suspended loads, M.Sc. Dissertation, Faculty of Natural Resources, University of Tehran, Iran [In Persian].
- Mustafa M., Isa R. M. H. and Rezaur R. B. (2011). A Comparison of Artificial Neural Networks for Prediction of Suspended Sediment Discharge in River, A Case Study in Malaysia. *World Academy of Sci., Eng. Technol. (WASET)*, 81(9), 372-376.
- Raghavendra N. S. and Deka P. C. (2014). Support vector machine applications in the field of hydrology: a review. *Appl. Soft. Comput.*, 19(6), 372-386.
- Razavizadeh S., Kaviani A. and Vafakhah M. (2014). Estimation of suspended sediment discharge by optimal structure of artificial neural network in Taleghan Watershed. *J. Wat. Soil Sci.*, 2(68), 79-87 [In Persian].
- Rezaei Pazhand H. (2001). Application of statistic and probability in water resources, SokhanGostar Publisher, Tehran, Iran [In Persian].
- Sadeghi H. (2005). Development of sediment rating curve equations for rising and falling limbs of hydrograph using regression models. *Iranian J. Wat. Resour.*, 1(1), 101-103.
- Samadzadeh R., Khayyam M. and Fazeli A. (2013). Modelling of estimation of the suspended load in Ardabil Darehrud basin, *Geog. Environ. Plan.*, 2(51), 153-178 [In Persian].
- Sarangi A. and Bhattacharya A. K. (2005). Comparison of Artificial Neural Network and regression models for sediment yield prediction from Banha watershed in India. *J. Agricul. Water Manag.* 78(9), 195-208.
- Shafaei Bajestan M. (2011). Theoretical and practical fundamental of sediment transfer hydraulic, Shahid Chmran University Publisher, Ahvaz, Iran [In Persian].
- Singh A., Imtiyaz M., Isaac R. and Denis D. (2012). Comparison of soil and water assessment tool (SWAT) and multilayer perceptron (MLP) artificial neural network for predicting sediment yield in the Nagwa agricultural watershed in Jharkhand, India. *Agric Water Manag.* 104(2), 113-120
- Tan Y. and Van Cauwenberghe A. (1999). Neural-Network-Based d-step-ahead predictors for nonlinear systems with time delay. *Eng. Appl. Artificial Intell.* 12 (2), 21-35.
- Telvari A. (2001). The relation of suspended sediment with some of the watershed characteristics in Dez and Karkhe in Lorestan province. *J. Res. Construc.*, 15 (56), 47-56.
- Teshnehlab M. and Monshi M. (2003). Climatic forecasting of meteorological parameters using fuzzy-neural networks based on the Tally education parameters. The 3rd Regional Conference on Climatic Changes, Isfahan, Iran [In Persian].
- Yu X. Y., Liang S. Y. and Babovic V. (2004). EC-SVM approach for realtime hydrologic forecasting. *J. Hydroinform.*, 6(3), 209-223.
- Zhou Y., Lu X. X. Huang Y. and Zhu Y. M. (2007). Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the upper Yangtze catchment, China. *Geomorphology*, 84(8), 111-125.

Assessing the Artificial Neural Network Efficiency to Estimate Suspended Sediment Load using Classified Data

Homayoun Faghih^{1*}, Ata Amini², Farzane Haidari³ and Keivan Khalili⁴

¹ Ph.D. Student, Department of Water Engineering, Urmia University, Urmia, Iran

² Assistant Prof. Kurdistan Agricultural and Natural Resources Research Center, AREO, Sanadaj, Iran

³ M.Sc., Department of Water Engineering, University of Bu-Ali Sina, Hamadan, Iran

⁴ Assistant professor, Department of Water Engineering, Urmia University, Urmia, Iran

*Corresponding Author: hfaghih54@gmail.com

Received: November 11, 2015

Accepted: December 18, 2015

Abstract:

Flow sediment load is a useful indicator in predicting soil erosion in watersheds. As a result, developing a model to estimate sediment load can be useful in the management and operations of watersheds and river engineering projects. In this study, the data classification was studied as a way to increase the accuracy of Artificial Neural Network (ANN) model for estimating suspended sediment. For this purpose, the amount of suspended sediments in the Khalifa-Tarkhān and Chehelgazi Rivers in Gheshlagh watershed, Kurdistan, Iran was predicted in three modes using an ANN with multilayer configurations. The measured data were also modeled without such classification. Then the runoff data were classified as high and low flows and the sediment data based on sediment concentration were classified as high and low concentrations. The observed runoff and sediment data were used to calibrate the models. Then the calculated values were compared with observed data and the models efficiency was examined using statistical tests. The findings indicate the effective role of data classification in improving the ANN efficiency in sediment estimation. So that classification based on sediment concentration promoted the model efficiency in Chehelgazi and Khalifa-Tarkhān by 16.6 and 30.5% respectively. The comparison of classifications showed that in comparison with flow, the sediment classification has more affective role on models estimations. The results of this study can be used to improve the management of the basin by more accurately estimating suspended sediments transporting in the rivers leading to Gheshlagh Dam Reservoir.

Keywords: Hydrometry, ANN, Gheshlagh Watershed, Sediment Concentration, Kurdistan.