

مدل سازی بار رسوب کل رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی

امین فلامکی^{۱*}، مهناز اسکندری^۲، عبدالحسین بغلانی^۳ و سید احمد احمدی^۴

^۱ (استادیار گروه مهندسی؛ دانشگاه پیام نور؛ ایران؛ نویسنده مسئول مکاتبات: Falamaki@spnu.ac.ir)

^۲ (باشگاه پژوهشگران جوان؛ دانشگاه آزاد اسلامی؛ واحد علوم و تحقیقات؛ تهران؛ ایران)

^۳ (استادیار دانشکده عمران و محیط‌زیست؛ دانشگاه صنعتی شیراز؛ ایران)

^۴ (کارشناس ارشد سازه‌های هیدرولیکی)

تاریخ پذیرش: ۱۳۹۱/۱۱/۳۰

تاریخ دریافت: ۱۳۹۱/۰۸/۲۹

چکیده

برآورد بار رسوب کل رودخانه‌ها از مسائل مهم و کاربردی در مدیریت و برنامه‌ریزی منابع آب است. غلظت رسوب می‌تواند به روش‌های مستقیم و یا غیرمستقیم محاسبه شود که معمولاً روش‌های مستقیم پرهزینه و زمان‌بر هستند. همچنین بار رسوب کل می‌تواند به کمک روابط مختلف انتقال رسوب محاسبه شود، لیکن به طور معمول کاربرد این روابط نیاز به شرایط معینی داشته و به علاوه در بیشتر موارد نتایج حاصل از آن‌ها با یکدیگر و با مقادیر اندازه‌گیری شده متفاوت است. هدف از این پژوهش ارائه روشی بر پایه شبکه‌های عصبی مصنوعی (ANN) در تخمین بار رسوب کل بود. بدین منظور از دو نوع شبکه عصبی پرسپترون چند لایه (MLP) و توابع پایه شعاعی (RBF) و ۲۰۰ نمونه، استفاده شد. ۷۵ درصد از داده‌ها برای آموزش و ۲۵ درصد برای آزمون شبکه‌ها در نظر گرفته شدند. متغیرهای ورودی مدل‌ها شامل سرعت متوسط جریان، شیب کف آبراهه، عمق متوسط، عرض آبراهه و قطر میانه ذرات رسوب و خروجی مدل، غلظت رسوب بود. متغیرهای ورودی مرحله به مرحله به شبکه‌ها اضافه شدند و هر بار نتایج ارزیابی شد تا مناسب‌ترین مدل تعیین شود. سپس نتایج حاصل از مدل‌های ANN با پنج معادله معروف انتقال رسوب مقایسه شدند. شاخص‌های آماری نشان داد که دقت شبکه‌های عصبی به‌ویژه مدل MLP در تخمین بار رسوب کل با ضریب همبستگی ۰/۹۶ بیش از سایر مدل‌هاست. همچنین مشخص شد که برای افزایش دقت مدل نیاز به آموزش آن با هر دو نوع داده‌های هیدرولوژیک و رسوب است. رابطه White و Ackers در برآورد مقدار بار رسوب کل بسیار بیش‌برآورد و سایر روابط، کم برآورد بودند. نتایج این پژوهش نشان داد که مدل‌های ارائه شده بر پایه شبکه‌های عصبی با مقادیر رسوب کل مشاهده شده هم‌خوانی بیشتری دارند و بویژه شبکه MLP می‌تواند مقدار رسوب را در نقاط پیک به خوبی برآورد نماید.

واژه‌های کلیدی: پرسپترون چند لایه؛ توابع پایه شعاعی؛ روابط انتقال رسوب؛ غلظت رسوب کل

مقدمه

Karami et al., 2012) که به عنوان یکی از بزرگترین چالش‌های بهره‌برداری از منابع آب‌های سطحی در جهان شناخته می‌شوند (دهقانی و همکاران، ۱۳۸۸). ورود رسوبات معلق و مواد مغذی^۱ توسط رواناب به خروجی آبخیز یا سطوح اساس، یکی از مهم‌ترین دلایل کاهش

امروزه مدیریت کمی و کیفی منابع آب به سبب افزایش نیازمندی‌ها و مصرف جوامع انسانی، بیش از پیش از اهمیت ویژه برخوردار است (حزباوی و همکاران، ۱۳۹۱). پدیده فرسایش خاک و انتقال رسوب از جمله فرآیندهای مهم هیدرودینامیک هستند (بهزادفر و همکاران، ۱۳۹۱؛

^۱ Nutrients

جریان و بار معلق در یک دوره ۲۴ ساله استفاده کردند تا با ارائه روش تجزیه داده‌ها به گروه‌های همگن در دوره‌های زمانی مختلف، فرآیند یادگیری شبکه عصبی پیشنهادی خود را بهبود بخشند. Zhou و همکاران (۲۰۰۷) نیز از ANN برای مدل‌سازی برآورد مقدار رسوب معلق در رودخانه‌ای در چین استفاده کردند. این پژوهش نشان داد که شبکه‌های طراحی شده اقلیمی نتایج بهتری نسبت به شبکه‌های طراحی شده با آمار جریان روزانه، ارائه می‌کنند. Alp و Cigizoglu (۲۰۰۷)، در پژوهشی از دو الگوریتم ANN شامل توابع پایه شعاعی و الگوریتم پیش‌خور پس انتشار برای مدل‌سازی بار معلق رسوب در حوزه آبخیز Junjata آمریکا استفاده کردند. برای این مدل‌سازی از جریان بارندگی و داده‌های بار رسوب معلق استفاده شد. مقایسه روش ANN با روش مرسوم رگرسیون خطی چندگانه نشان داد که مدل‌های شبکه عصبی می‌توانند مقادیر مشاهداتی را با دقت بیشتری تخمین زنند. Partal و Cigizoglu در پژوهشی (۲۰۰۸) نشان دادند که در تخمین مقدار بار رسوب معلق، استفاده هم‌زمان از دو روش ANN و موجک تطابق بسیار مناسبی با داده‌های مشاهده‌ای طی آزمون مدل فراهم می‌سازد. این روش می‌تواند بار رسوب را بویژه در مناطق پیک بسیار نزدیک به مقادیر واقعی تخمین زند.

تاکنون شبکه‌های عصبی مصنوعی نه تنها برای برآورد بار رسوب به خوبی به کار رفته‌اند، بلکه Rai و Mathur (۲۰۰۸) در پژوهش خود نشان داده‌اند، با استفاده از الگوریتم پس انتشار می‌توان هیدروگراف رواناب و نمودار رسوب را بهتر محاسبه کرد. طهمورث و همکاران (۱۳۸۸)، با استفاده از داده‌های هم‌زمان دبی آب و دبی رسوب ایستگاه گلینک واقع بر رودخانه طالقان، همراه با تعدادی از پارامترهای ژئومورفولوژیک حوزه آبخیز این رودخانه، از ANN برای مدل‌سازی برآورد مقدار رسوب معلق روزانه استفاده کردند. نتایج این پژوهش نشان دهنده دقت بالاتر شبکه‌های عصبی نسبت به مدل‌های رگرسیونی بود.

کیفیت سامانه‌های آبی است (ابراهیمی محمدی و همکاران، ۱۳۹۱). تخمین مقدار بار رسوب یا میزان انتقال آن برای بسیاری از کاربری‌ها و پروژه‌های منابع آب مانند طراحی سدها و حوضچه‌های ذخیره آب سطحی، انتقال رسوب و آلودگی در رودخانه‌ها و دریاچه‌ها، طراحی کانال‌ها و نگهداری آن‌ها، حیاتی است (Yang et al., 2009). اطلاعات کافی در این زمینه به عنوان پایه‌ای برای پروژه‌های رودخانه‌ای مانند برداشتن قوس رودخانه‌ها، تنگ‌شدگی رودخانه، کشتیرانی، کنترل سیل، پس‌رفت آب و طراحی مخازن لازم است (ولی و همکاران، ۱۳۹۰). اهمیت این مسأله باعث شده است که تاکنون پژوهش‌های متعددی به منظور توسعه روابط نوین انتقال رسوب، بویژه بر پایه داده‌های آزمایشگاهی انجام شود، بطوری که می‌توان دست کم ۱۰۰ رابطه برای انتقال رسوب در پژوهش‌های گذشته یافت (Yang et al., 2009). در بسیاری از موارد نتایج حاصل از این روابط به دلیل پیچیدگی و عدم شناخت کامل و دقیق مکانیزم انتقال رسوب، با مقادیر اندازه‌گیری شده تطابق نداشته و در مواردی نیز نتایج روابط مختلف تفاوت معنی‌دار با یکدیگر دارند (معیری و همکاران، ۱۳۸۹).

این مسأله باعث شده است که در دهه اخیر پژوهشگران مختلف به سمت استفاده از روش‌های هوشمند مانند شبکه‌های عصبی مصنوعی (ANN)^۱ روی آورند. کاربرد ANN اولین بار توسط French در سال ۱۹۹۲ در مسائل مرتبط با منابع آب مطرح شد (دهقانی و همکاران، ۱۳۸۸) و از آن پس در این زمینه به صورت موفقیت‌آمیز بکار رفته است، مانند مدل‌سازی بارش-رواناب، پیش‌بینی بارندگی، مدل‌سازی آب‌های زیرزمینی، سری‌های زمانی (ASCE, 2000b) و نیز برآورد مقدار بار معلق رسوب. Cigizoglu و Kisi در سال ۲۰۰۶ روش‌هایی برای بهبود عملکرد شبکه‌های عصبی در تخمین بار رسوب معلق ارائه دادند. این پژوهشگران از مجموعه داده‌های دبی

^۱ Artificial Neural Network

همچنین استفاده از پارامترهای ژئومورفولوژی موثر در تولید رسوب در مدلسازی، باعث افزایش دقت تخمین آورد رسوب رودخانه شد. بر همین اساس ولی و همکاران (۱۳۸۹)، دو نوع شبکه عصبی به منظور پیش‌بینی بار معلق رسوب حوزه اسکندری از زیر حوزه‌های زاینده‌رود طراحی کردند که تنها در یکی از شبکه‌ها، از پارامترهای ژئومورفولوژیک استفاده شد. نتایج حاصل از ANN با دو نوع رگرسیون توانی و غیرخطی چندگانه مقایسه شد. مدل‌ها بر پایه ۱۰۴ حادثه وقوع همزمان ثبت شده دبی جریان و رسوب شکل گرفتند. نتایج حاکی از آن بود که در حجم کم داده، مدل‌های ANN طراحی شده بر پایه ویژگی‌های ژئومورفولوژیک حوزه آبخیز بهترین تخمین را نسبت به مدل‌های رگرسیونی ارائه می‌دهند. دهقانی و همکاران (۱۳۸۹)، ضمن مقایسه شبکه‌های عصبی مصنوعی با روش منحنی سنجه در تخمین رسوب معلق، نشان دادند که ANN توانایی بیشتری در پیش‌بینی رسوب معلق رودخانه بهشت آباد از سرشاخه‌های کارون دارد. همچنین دهقانی و وفاخواه (۱۳۹۲)، نتایج حاصل از دو نوع ANN و منحنی‌های سنجه مختلف در حوزه آبخیز گرگان‌رود را بایکدیگر مقایسه کردند. این پژوهش نشان داد که شبکه‌های پرسپترون چندلایه با ورودی‌های دبی همان روز، دبی یک و دو روز قبل نسبت به سایر روش‌ها از دقت بالاتری در تخمین بار رسوب معلق برخوردار است. پژوهش‌های متعدد دیگری نیز نشان داده است که برآورد رسوب معلق به کمک منحنی‌های سنجه همواره با مقداری خطا همراه است و به نظر می‌رسد که مدل شبکه عصبی مصنوعی خطای کمتری را در مقایسه با منحنی سنجه رسوب داشته باشد (مساعدی و همکاران، ۱۳۸۸).

همچنین استفاده از پارامترهای ژئومورفولوژی موثر در تولید رسوب در مدلسازی، باعث افزایش دقت تخمین آورد رسوب رودخانه شد. بر همین اساس ولی و همکاران (۱۳۸۹)، دو نوع شبکه عصبی به منظور پیش‌بینی بار معلق رسوب حوزه اسکندری از زیر حوزه‌های زاینده‌رود طراحی کردند که تنها در یکی از شبکه‌ها، از پارامترهای ژئومورفولوژیک استفاده شد. نتایج حاصل از ANN با دو نوع رگرسیون توانی و غیرخطی چندگانه مقایسه شد. مدل‌ها بر پایه ۱۰۴ حادثه وقوع همزمان ثبت شده دبی جریان و رسوب شکل گرفتند. نتایج حاکی از آن بود که در حجم کم داده، مدل‌های ANN طراحی شده بر پایه ویژگی‌های ژئومورفولوژیک حوزه آبخیز بهترین تخمین را نسبت به مدل‌های رگرسیونی ارائه می‌دهند. دهقانی و همکاران (۱۳۸۹)، ضمن مقایسه شبکه‌های عصبی مصنوعی با روش منحنی سنجه در تخمین رسوب معلق، نشان دادند که ANN توانایی بیشتری در پیش‌بینی رسوب معلق رودخانه بهشت آباد از سرشاخه‌های کارون دارد. همچنین دهقانی و وفاخواه (۱۳۹۲)، نتایج حاصل از دو نوع ANN و منحنی‌های سنجه مختلف در حوزه آبخیز گرگان‌رود را بایکدیگر مقایسه کردند. این پژوهش نشان داد که شبکه‌های پرسپترون چندلایه با ورودی‌های دبی همان روز، دبی یک و دو روز قبل نسبت به سایر روش‌ها از دقت بالاتری در تخمین بار رسوب معلق برخوردار است. پژوهش‌های متعدد دیگری نیز نشان داده است که برآورد رسوب معلق به کمک منحنی‌های سنجه همواره با مقداری خطا همراه است و به نظر می‌رسد که مدل شبکه عصبی مصنوعی خطای کمتری را در مقایسه با منحنی سنجه رسوب داشته باشد (مساعدی و همکاران، ۱۳۸۸).

هرچند در دهه اخیر پژوهش‌های مختلفی در زمینه کاربرد ANN در تخمین بار معلق رسوب رودخانه‌ها ارائه شده است، لیکن تحقیقات انجام گرفته برای پیش‌بینی مقدار بار رسوب کل انگشت‌شمار است. در این راستا می‌توان به پژوهش‌های انجام شده توسط Dogan و همکاران

مواد و روش‌ها

داده‌های مورد استفاده

داده‌های مورد استفاده در این پژوهش، شامل ۲۰۰ نمونه آزمایشگاهی بار کل رسوب از ۷ منبع مختلف بود. منابع داده‌ها و تعداد داده برداشت شده از هر منبع، در

روابط محاسبه بار کل رسوب را می‌توان بر پایه تئوری و مفاهیم بنیادی آن‌ها به دسته‌های مختلف تفکیک کرد. دسته‌ای از این روابط بر مبنای تئوری انرژی^۱ توسعه یافته-اند. روش‌های Engelund و Hansen (۱۹۷۲)، Ackers و White (۱۹۷۳) و Yang (۱۹۷۲)، در این دسته قرار می‌گیرند. Engelund و Hansen (۱۹۷۲)، تابع انتقال رسوب خود را بر پایه نظریه Bagnold به صورت رابطه ۱ ارائه دادند (Yang et al., 2009).

$$q_t = \frac{0.05\gamma_s(\gamma DS)^{1.5}}{d_{50}} \left(\frac{V}{\gamma_s - \gamma}\right)^2 \left(\frac{\gamma}{g}\right)^{0.5} \quad (1)$$

در این رابطه q_t دبی بار کل رسوب در واحد عرض آبراهه، V سرعت متوسط جریان، S شیب انرژی، d_{50} قطر میانه ذرات رسوب، γ و γ_s به ترتیب وزن مخصوص آب و رسوب، D عمق جریان و g شتاب ثقل زمین است. این رابطه بر اساس انرژی موجود و پارامترهای انتقال و حرکت به دست آمده است (امامی، ۱۳۷۹).

Ackers و White (۱۹۷۳)، نیز بر پایه نظریه توان جریان Bagnold معادله ۲ را برای تخمین دبی بار کل رسوب ارائه دادند (Yang et al., 2009).

$$G_{gr} = \frac{\gamma X D}{d\gamma_s} \left[\frac{\sqrt{\gamma DS/\rho}}{V} \right]^n \quad (2)$$

در این رابطه X غلظت وزنی مواد رسوبی موجود در آب و G_{gr} تابع بی‌بعد انتقال رسوب است که بر پایه قطر بی‌بعد و عدد حرکت F_{gr} محاسبه می‌شود. در عمل تابع بی‌بعد به صورت معادله ۳ محاسبه می‌شود.

$$G_{gr} = C \left(\frac{F_{gr}}{A} - 1 \right)^m \quad (3)$$

که در آن مقادیر A ، m ، C و n (در رابطه ۲)، با توجه به شکل‌های ارائه شده توسط این پژوهشگران تعیین می‌شوند. شکل‌های پیشنهادی بر پایه برآزش بهترین منحنی‌ها بر نتایج آزمایشگاهی، به دست آمده است. لازم به ذکر است که تمام این آزمایش‌ها، بر روی دانه‌های رسوبی با قطر بزرگتر از ۰/۰۴ mm و جریان‌های زیر بحرانی انجام گرفته است (امامی، ۱۳۷۹).

جدول ۱ ارائه شده است. این داده‌ها از بانک داده‌های رسوب Molinas و Wu (۲۰۰۳)، تهیه شد. این بانک اطلاعاتی شامل مجموعه‌ای از داده‌های جریان و رسوب است. این داده‌ها متشکل از ویژگی‌های جریان شامل دبی جریان (Q)، عرض کانال (W)، عمق جریان (D)، شیب خط انرژی (S) و درجه دمای آب (T)، ویژگی‌های مواد بستر شامل قطر میانه اندازه ذرات (d_{50})، اندازه قطر ذره‌ای که ۶۵ درصد وزنی ذرات از آن کوچکترند (d_{65})، ضریب گرایان اندازه، وزن مخصوص ذرات رسوب (G) و شکل بستر، ویژگی‌های رسوبات انتقال یافته شامل غلظت رسوب (Ct) و قطر میانه ذرات (D_{50}) و ضریب گرایان اندازه رسوبات انتقالی و همچنین توزیع اندازه ذرات مواد بستر و مواد رسوب یافته است.

جدول ۱- منابع و تعداد داده‌های مورد استفاده در پژوهش (اقتباس از Molinas و Wu، ۲۰۰۳)

تعداد نمونه‌ها	سال انتشار	منبع داده‌ها
۵۷	۱۹۶۶	Cheng and Richardson
۲۹	۱۹۶۸	Einstein
۲۶	۱۹۵۳	Einstein and Chien
۱۲	۱۹۵۷	Nomicos
۲۷	۱۹۹۰	Wang and Zehang
۲۰	۱۹۸۲	White and Day
۳۳	۱۹۸۶	Samaga and Garde

داده‌های انتخاب شده واجد این شاخصه‌ها بودند: مواد بستر ۷۵ درصد از داده‌ها درشت دانه بود؛ تغییر اندازه مواد بستر ۹۵ درصد از داده‌ها در دامنه ۴/۰۸ تا ۰/۰۱ میلی‌متر قرار می‌گرفت؛ جریان در ۹۲ از داده‌ها در حالت زیر بحرانی قرار داشت و ۸۲ درصد از داده‌ها دارای مواد رسوبی در محدوده دانه‌بندی ماسه بودند.

رهیافت‌های مورد استفاده در محاسبه بار کل رسوب

در این پژوهش از پنج روش شناخته شده برای محاسبه بار کل رسوب عبارت از Yang (۱۹۷۲)، Laursen (۱۹۵۸)، Engelund و Hansen (۱۹۷۲)، Ackers و White (۱۹۷۳) و Shen و Hung (۱۹۷۲) استفاده شد (Yang, 1996).

^۱ Power concept

که قطر متوسط آن‌ها در محدوده ذرات ماسه قرار دارد، ارائه دادند.

$$\log C_t = -107404.46 + 3242.1475 Y - 326309.59 Y^2 + 109503.87 Y^3 \quad (7)$$

$$Y = \left(\frac{VS^{0.57}}{\omega^{0.32}}\right)^{0.00750189} \quad (8)$$

که در آن ω متوسط سرعت سقوط ذرات رسوبی و C_t غلظت وزنی بار کل رسوب (ppm) است. این دو محقق نشان دادند که میزان انتقال مواد رسوبی نسبت به تغییرات عمق جریان حساس نیست. دلیل این امر را می‌توان در نتایج آزمایشگاهی استفاده شده دانست زیرا تمام این نتایج دارای محدوده کوچکی از تغییرات عمق جریان بودند.

هر یک از روابط معرفی شده در شرایط معین قابل کاربرد هستند که در جدول ۲ ارائه شده است. نگاهی به این جدول و خصوصیات نمونه‌های مورد استفاده در این پژوهش که در بخش پیشین ذکر شد، نشان می‌دهد که از این پنج رهیافت می‌توان در برآورد مقدار رسوب کل داده‌های تحقیق، استفاده نمود.

جدول ۲- توصیه‌های کاربردی برای استفاده از هر یک از روابط

توصیه‌های کاربردی	روش توصیه شده
در رودخانه‌هایی با مواد بستری درشت دانه، برای فرم‌های بستر مختلف	Yang
برای انواع فرم بستر و جریان‌های زیر بحرانی	Ackers-White
برای رودخانه‌هایی که دارای فرم بستر دیون می‌باشند	Engelund-Hansen
برای داده‌های آزمایشگاهی با اندازه مواد بستری ۰/۰۸-۴/۰۸	Laursen
برای داده‌های آزمایشگاهی و رودخانه‌های کوچک با ذرات رسوبی ماسه	Shen- Hung

شبکه‌های عصبی مصنوعی

در این پژوهش از دو نوع شبکه پرسپترون چند لایه (MLP)^۲ و توابع پایه شعاعی (RBF)^۳ در برآورد بار

برای تعیین غلظت کل رسوبات (اعم از درشت دانه و ریز دانه)، Yang در سال ۱۹۷۳ رابطه ۴ را ارائه داده است (Yang et al., 2009). تفاوت فرضیات Yang و Bagnold در این است که Bagnold توان در واحد سطح بستر را مطرح می‌کند در حالی که Yang توان اعمال شده به سیستم به ازای واحد وزن آب را در انتقال مواد رسوبی در نظر می‌گیرد (امامی، ۱۳۷۹).

$$\Phi(C_t, VS, U_*, \theta, \omega, d) = 0 \quad (4)$$

که در آن C_t غلظت بار کل رسوب (صرف نظر از بار شسته) بر حسب ppm، VS توان واحد جریان، U_* سرعت برشی، d قطر میانگین دانه‌ها و ω سرعت سقوط دانه‌های رسوب است.

رهیافت‌های Laursen (۱۹۵۸) و Shen و Hung (۱۹۷۲)، برای برآورد بار رسوب کل از فرضیات دیگر به جز تئوری انرژی تبعیت می‌کنند. Laursen در سال ۱۹۵۸ بر پایه مطالعات آزمایشگاهی و تئوری، با بسط رابطه بین شرایط جریان آب و دبی رسوب حمل شده توسط آن، رابطه‌ای برای محاسبه دبی بار کل رسوب ارائه داد. در سال ۱۹۷۱، فرمول Laursen توسط کمیته ASCE^۱ بررسی شد و به صورت معادله ۵ ارائه گردید (امامی، ۱۳۷۹).

$$C_t = 0.01 \gamma \sum_{i=1}^n P_i \left(\frac{d_i}{D}\right)^{7/6} \left(\frac{\tau'}{\tau_{ci}} - 1\right) f\left(\frac{U_*}{\omega_i}\right) \quad (5)$$

که در این رابطه، U_* سرعت برشی، P_i درصد مواد رسوبی موجود در گروه دانه‌بندی i ام، d_i قطر متوسط گروه دانه‌بندی i ام، ω_i سرعت سقوط ذره‌ای با قطر d_i در آب، τ_{ci} تنش برشی بحرانی ذره‌ای با قطر d_i و C_t متوسط غلظت وزنی بار کل رسوب است. τ' مقاومت برشی بستر است و به صورت زیر محاسبه می‌شود:

$$\tau' = \frac{\rho V^2}{58} \left(\frac{d_{50}}{D}\right)^{1/3} \quad (6)$$

Shen و Hung در سال ۱۹۷۲، با برازش منحنی‌های مختلف بر روی نتایج حاصل از ۵۸۷ سری آزمایش در فلوم‌های آزمایشگاهی، معادله ۸ را برای دانه‌های رسوبی

^۲ Multi Layer Perceptrone

^۳ Radial Basis Functions

^۱ American Society of Civil Engineers

زند، محاسبه می‌شود. سپس لایه خروجی این نتایج را در یک نگاشت خطی ترکیب می‌کند. تفاوت اصلی شبکه‌های RBF با BP مورد استفاده در شبکه‌های MLP، در ماهیت غیر خطی عجین شده با گره‌های لایه پنهان است. غیرخطی بودن در BP با توابع مشخصی مانند تابع سیگموئیدی انجام می‌شود، در حالیکه در مدل RBF اساس غیر خطی بودن بر پایه داده‌های مجموعه آموزش است. زمانی که تمام توابع پایه در لایه پنهان مشخص شدند، شبکه تنها نیازمند یادگیری در لایه خروجی با یک نگاشت جمع خطی است (ASCE, 2000a).

ورودی و خروجی شبکه‌ها

نگاهی به روابط ارائه شده برای محاسبه بار کل رسوب در بخش پیشین نشان می‌دهد که متغیرهای V ، S ، D و d_{50} عوامل مهم مورد نیاز برای محاسبه سرعت برشی، تنش برشی، واحد توان جریان و سرانجام غلظت بار کل رسوب هستند. بنابراین با داشتن این متغیرها می‌توان مقدار بار کل رسوب را تخمین زد. به همین منظور و به دلیل مقایسه نتایج مدل‌سازی مقدار رسوب کل با ANN با نتایج محاسبه شده از روابط تئوری، از همین متغیرها به علاوه عرض کانال، به عنوان ورودی شبکه‌های عصبی مصنوعی استفاده شد. همچنین غلظت رسوب (C_1) به عنوان خروجی مدل در نظر گرفته شد. برای دستیابی به بهترین مدل با بیشترین دقت در تخمین، ورودی‌ها به صورت مرحله به مرحله به شبکه اضافه شده و نتایج حاصله با بررسی ضریب همبستگی و میانگین ریشه دوم خطا سنجش شد تا بهترین ساختار شبکه‌ها بدست آید. ۷۵ درصد از داده‌ها برای آموزش شبکه‌ها و ۲۵ درصد آن‌ها برای آزمایش بصورت تصادفی انتخاب شدند. پارامترهای آماری مجموعه داده‌های آموزش و آزمون در جدول ۳ ارائه شده است.

سنجش آماری نتایج

به منظور ارزیابی اعتبار شبکه‌های پی‌ریزی شده در برآورد بار رسوب کل، از تحلیل خطاهای باقیمانده و اختلاف بین

رسوب کل استفاده شد. شبکه‌های MLP از معروف‌ترین الگوریتم برای آموزش ANN یعنی الگوریتم پس انتشار (BP)^۱ استفاده می‌کنند. هر الگوی ورودی از مجموعه داده‌های آموزش از سراسر شبکه یعنی از میان لایه ورودی، لایه یا لایه‌های پنهان و لایه خروجی عبور می‌کند. سپس با مقایسه خروجی شبکه با خروجی واقعی، مقدار خطا محاسبه می‌شود. این خطا به صورت پس انتشار در شبکه بازگشت داده می‌شود تا وزن‌های اتصال دهنده گره‌ها دوباره تنظیم شوند. الگوریتم BP شامل دو مرحله است که در مرحله اول اثر ورودی‌های شبکه به جلو رانده می‌شود تا به لایه خروجی برسد. سپس مقدار خطا به صورت پس انتشار به عقب برگشته و در شبکه توزیع می‌شود (ASCE, 2000a). زمانی یک شبکه را تعمیم‌یافته می‌پندارند که با کاربرد داده‌هایی که از قبل به شبکه معرفی نشده‌اند (داده‌های آزمایش)، مقدار خطای پیش‌بینی قابل قبول باشد. بنابراین در مدل‌سازی با این شبکه‌ها از ابتدا باید داده‌ها را به دو دسته داده‌های آزمایش و آموزش تفکیک کرد. الگوی آموزش باید تا حد امکان کل فضای داده‌ها را پوشش دهد. برای محاسبه تعداد لایه پنهان و نرون‌های هر لایه رابطه خاصی وجود ندارد (نوابیان و همکاران، ۱۳۸۳). بنابراین برای دست‌یافتن به بهترین ساختار ANN در مدل‌سازی هر مسأله، نیاز به آزمون ساختارهای متعدد است (فلامکی و اسکندری، ۱۳۹۱).

شبکه RBF به عنوان یک شبکه سه لایه که در آن لایه پنهان به صورت ثابت واجد تابع تبدیل غیرخطی با پارامترهای غیرقابل تنظیم است، شناخته می‌شود. این لایه شامل تعدادی گره و یک بردار پارامتر به نام مرکز است که به عنوان بردار وزن لایه پنهان می‌تواند در نظر گرفته شود. فاصله استاندارد اقلیدسی برای اندازه‌گیری میزان فاصله بردار ورودی از مرکز بکار برده می‌شود. برای هر گره فاصله اقلیدسی میان مرکز و بردار ورودی بوسیله تابع غیرخطی که خروجی گره‌ها در لایه پنهان را تخمین می‌-

^۱ Back propagation

$$CD = \frac{\sum_{i=1}^n (O_i - \bar{O})^2}{\sum_{i=1}^n (P_i - \bar{O})^2} \quad (11)$$

$$EF = \frac{\sum_{i=1}^n (O_i - \bar{O})^2 - \sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (12)$$

$$CRM = \frac{\sum_{i=1}^n O_i - \sum_{i=1}^n P_i}{\sum_{i=1}^n O_i} \quad (13)$$

مقادیر اندازه‌گیری و پیش‌بینی شده استفاده شد. آماره‌های لازم برای این کار حداکثر خطا (ME)، میانگین ریشه دوم خطا (RMSE)، ضریب تبیین (CD)، کارایی مدل‌سازی (EF)، و ضریب باقیمانده (CRM) بودند. تعریف ریاضی این آماره‌ها به صورت زیر است (Zarei et al., 2009؛ نوری و همکاران، ۱۳۹۱ الف)؛ نوری و همکاران، ۱۳۹۱ ب):

$$ME = \max |P_i - O_i|_{i=1}^n \quad (9)$$

$$RMSE = \left[\frac{\sum_{i=1}^n (P_i - O_i)^2}{n} \right]^{0.5} \frac{100}{\bar{O}} \quad (10)$$

جدول ۳- پارامترهای آماری مجموعه داده‌های آموزش و آزمون در مدل‌های شبکه عصبی

داده‌ها	میانگین	بیشینه	کمینه	انحراف از معیار
داده‌های ورودی	متوسط سرعت (ft/s)	۲/۵۹۰	۵/۰۷۰	۰/۸۱۰
	متوسط عمق (ft)	۰/۴۸۰	۱/۲۰۰	۰/۱۸۰
	شیب کف آبراهه	۰/۰۰۴	۰/۰۱۳	۰/۰۰۰
داده‌های آموزش	d50(ft)	۰/۰۰۱	۰/۰۰۷	۰/۰۰۰
	عرض آبراهه (ft)	۲/۲۲۰	۸/۰۷۰	۰/۶۶۰
داده خروجی	بار کل رسوب (ppm)	۳۰۲۳۰	۲۰۰۶۶۸	۱/۶۲۰
داده‌های ورودی	متوسط سرعت (ft/s)	۲/۶۳۰	۴/۵۸۰	۰/۸۵۰
	متوسط عمق (ft)	۰/۴۶۰	۱/۱۸۰	۰/۲۰۰
	شیب کف آبراهه	۰/۰۰۴	۰/۰۱۳	۰/۰۰۰
داده‌های آزمون	d50(ft)	۰/۰۰۰	۰/۰۰۶	۰/۰۰۰
	عرض آبراهه (ft)	۲/۱۵۰	۸/۰۷۰	۰/۶۶۰
داده خروجی	بار کل رسوب (ppm)	۳۵۷۲۷	۱۹۰۲۳۰	۸/۸۸۰

است. حداقل مقدار ME، RMSE و CD صفر است. EF و CRM می‌توانند مقادیر منفی داشته باشند. مقدار زیاد ME

که در آن‌ها، P_i مقدار پیش‌بینی شده، O_i مقدار اندازه‌گیری شده (مشاهده شده)، n تعداد نمونه‌های به کار رفته و \bar{O} مقدار متوسط مقادیر O است. حداکثر مقدار EF برابر یک

در میان شبکه‌های RBF نیز بهترین مدل با ضریب همبستگی ۰/۹۴ برای داده‌های آزمون مربوط به ساختاری بود که با هر پنج ورودی آموزش دیده بود. افزون بر این، نتایج ارائه شده در جدول ۴ نشان می‌دهد زمانی که شبکه‌ها تنها با داده‌های هیدرولوژیک شامل V ، S و D آموزش ببینند نسبت به زمانی که داده‌های هیدرولوژیک همراه با اطلاعات رسوب (d_{50}) برای آموزش مدل‌ها به کار رفته باشند، توانایی کمتری در برآورد مقدار بار کل رسوب دارند.

نتایج بدست آمده از محاسبه بار رسوب کل با استفاده از روابط موجود و بهترین مدل‌های ANN که در جدول ۴ معرفی شدند، برای ۵۰ داده آزمون در شکل ۱ ارائه شده است. در این نمودارها برای هر مقدار اندازه‌گیری شده در محور افقی، متناظر مقدار محاسبه شده آن در محور عمودی نشان داده شده است. همچنین خط تناظر یک به یک نیز نمایان است. هر چه پراکندگی داده‌ها در اطراف این خط بیشتر باشد، توانایی مدل کاربردی در برآورد رسوب کل ضعیف‌تر بوده است. همانطور که مشاهده می‌شود به جز مدل‌های ANN، سایر نتایج بدست آمده برای ۵۰ داده آزمون از میان کل داده‌ها، به کمک روابط محاسبه رسوب کل، موفق نبوده است. تخمین مقدار رسوب کل توسط معادلات معرفی شده بویژه روابط Laursen، Englund و Hansen و Shen و Hung، ضعیف بود. متأسفانه این روابط با وجود آنکه در شرایط داده‌های موجود قابل کاربرد بودند، لیکن نتوانسته‌اند برآورد مناسبی از بار رسوب کل ارائه دهند. آماره‌های سنجش مدل‌ها که برای این ۵۰ داده در جدول ۵ ارائه شده است نیز همین مسأله را خاطر نشان می‌سازد. آماره CRM نشان می‌دهد که مدل‌های شبکه عصبی کمی بیش‌برآورد هستند و مقدار تخمینی را اندکی بیش از واقعیت نشان می‌دهند. این مسأله می‌تواند در پروژه‌های منابع آب که نیازمند برآورد رسوب کل هستند، از نظر افزایش ضریب اطمینان نتایج بدست آمده، مناسب باشد. هر چقدر آماره EF به یک نزدیک‌تر

نشان‌دهنده بدترین حالت کارکرد مدل است، در حالی که مقدار زیاد RMSE نشان می‌دهد که برآورد بیش از حد و یا کمتر از حد مدل در مقایسه با مشاهدات (اندازه‌گیری‌ها) چقدر است. آماره CD نسبت پراکندگی را بین مقادیر پیش‌بینی شده و اندازه‌گیری شده نشان می‌دهد. آماره EF مقادیر پیش‌بینی‌ها را با میانگین اندازه‌گیری‌ها مقایسه می‌کند. مقدار منفی EF بیانگر آن است که میانگین مقادیر اندازه‌گیری شده، برآوردی بهتر از مقادیر پیش‌بینی شده دارد. آماره CRM نشانگر بیش‌برآوردی یا کم‌برآوردی مدل در مقایسه با اندازه‌گیری‌ها است. چنانچه تمام مقادیر اندازه‌گیری شده و برآورد شده با هم برابر باشند، مقدار عددی بهینه این آماره‌ها $ME=0$ ، $RMSE=0$ ، $CD=1$ ، $EF=1$ و $CRM=0$ است (Zarei et al., 2009).

نتایج و بحث

نتایج پس از بررسی ساختارهای مختلف با ورودی‌های متفاوت، مناسب‌ترین ساختارهای ANN در برآورد مقدار رسوب کل با کاربرد داده‌های مورد پژوهش، معین شدند. ویژگی‌های این مدل‌ها در جدول ۴ ارائه شده است. این جدول نشان می‌دهد که بیشترین ضریب همبستگی و کمترین مقدار RMSE برای داده‌های آموزش در مدل MLP با چهار ورودی اندازه قطر میانه ذرات رسوب، شیب کف آبراهه، سرعت متوسط و عمق متوسط با ساختار چهار نرون در لایه ورودی، ۱۰ نرون در لایه پنهان اول و دوم و یک نرون در لایه خروجی بدست آمده است. لیکن در داده‌های آزمون بهترین مدل MLP مربوط به شبکه‌ای با پنج نرون در لایه ورودی، سه نرون در لایه پنهان و یک نرون در لایه خروجی بدست آمد که با هر پنج متغیر S ، V ، d_{50} و D آموزش دیده بود. این مسأله نشان می‌دهد که نه تنها هر پنج متغیر ذکر شده برای پیش‌بینی مقدار رسوب کل مفید هستند، بلکه با افزودن یک متغیر مانند عرض کانال می‌توان مدلی با تعداد نرون کمتر و در نتیجه نیاز به زمان آموزش کوتاه‌تر و با دقت بیشتر بدست آورد.

پیش‌بینی شده بار رسوب کل از الگوی مقادیر مشاهده شده پیروی می‌کند، لیکن این شبکه در تخمین مقادیر کمینه ضعیف بود، چراکه در تعداد اندکی از داده‌ها، مقادیر کمتر از صفر برای غلظت رسوب برآورد نمود. رابطه Laursen در برآورد رسوب کل بسیار کم‌برآورد و ضعیف عمل کرد. برخی مقادیر محاسبه شده در رابطه Ackers-White بسیار بیش از مقادیر مشاهده شده هستند که همین امر منجر به RMSE بزرگ برای این رابطه در جدول ۵ شده است. رابطه Yang برای برخی از داده‌ها بیش‌برآورد و برای سایر داده‌ها کم‌برآورد بوده است. به طور کلی می‌توان از نتایج بدست آمده اینگونه استنباط کرد که پنج رابطه برآورد رسوب کل مورد استفاده در این پژوهش نتوانسته‌اند برای داده‌های کاربردی مقادیر مناسبی را محاسبه نمایند. این روش‌ها قادر نبودند که در نقاط پیک داده‌ها به خوبی مقادیر رسوب را برآورد کنند.

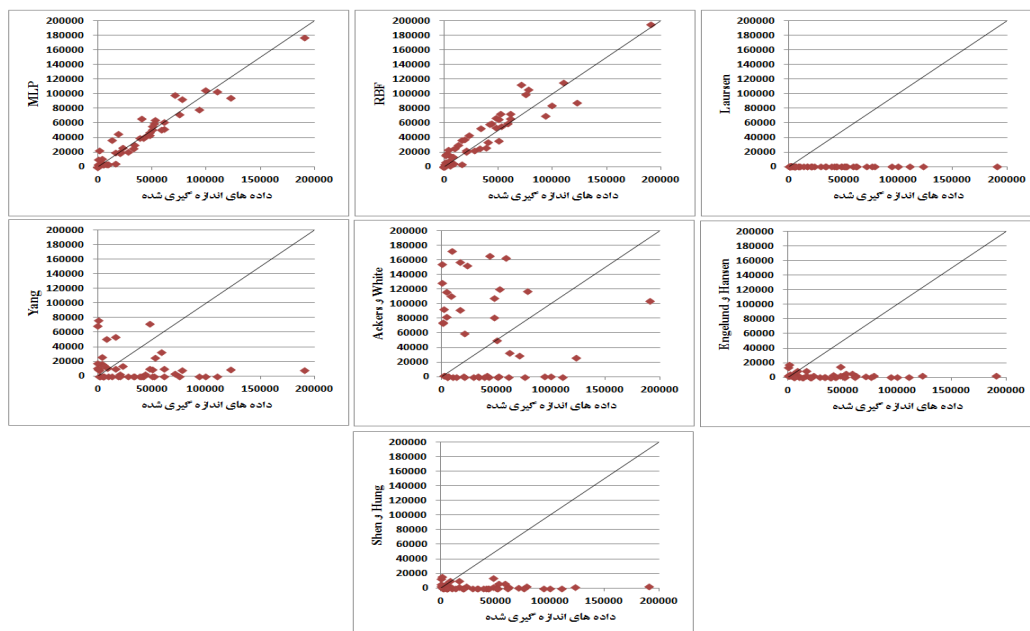
باشد، نشان دهنده کارایی بهتر مدل کاربردی است که تنها در دو مدل MLP و RBF این نتیجه بدست آمده است. همین آماره در مورد رابطه Ackers و White نیز نشان دهنده بیش‌برآوردی مدل است که با توجه به مقدر زیاد RMSE معادله می‌توان اینگونه استنباط کرد که معادله Ackers و White برای همه یا برخی از داده‌ها بسیار بیش-برآورد عمل کرده است. برخلاف این رابطه، دو آماره CRM و RMSE نشان می‌دهند که سایر روابط برآورد رسوب کل، کم برآورد رفتار کرده‌اند و مقدار رسوب تخمین زده شده از مقادیر اندازه‌گیری شده بسیار کمتر است. کمترین مقدار حداکثر خطا در مدل MLP و بیشترین مقدار آن از رابطه Ackers و White بدست آمده است. نتایج برآورد مقدار بار کل رسوب برای ۲۰۰ داده مورد استفاده در این پژوهش نشان داد که شبکه عصبی MLP به خوبی و بویژه در نقاط پیک توانسته است مقدار بار کل رسوب را پیش‌بینی نماید. در مدل RBF نیز الگوی مقادیر

جدول ۴- ویژگی‌های مناسب‌ترین شبکه‌های MLP و RBF

داده‌های آزمون		داده‌های آموزش		ساختار	نوع	ورودی
RMSE	ضریب همبستگی	RMSE	ضریب همبستگی			
۱/۱۰	۰/۰۹۳	۰/۰۳	۰/۹۴	۴-۳-۱	MLP	V,S,D,d50
۲/۳۰	۰/۸۷	۰/۰۵	۰/۸۶	۴-۳۰-۱	MLP	V,S,D,d50
۱/۳۵	۰/۸۸	۰/۰۳	۰/۹۳	۴-۲۰-۱	MLP	V,S,D,d50
۱/۶۷	۰/۸۶	۰/۰۲	۰/۹۶	۴-۲-۳-۱	MLP	V,S,D,d50
۱/۳۲	۰/۹۰	۰/۰۲	۰/۹۷	۴-۱۰-۱۰-۱	MLP	V,S,D,d50
۳/۸۹	۰/۷۲	۰/۰۴	۰/۸۸	۴-۵-۱	MLP	V,S,D,d50
۰/۸۷	۰/۹۶	۰/۰۳	۰/۹۶	۵-۳-۱	MLP	V,S,D,d50,W
۲/۵۶	۰/۸۷	۰/۰۶	۰/۷۳	۳-۱۰-۱	MLP	V,S,D
۵/۹۶	۰/۶۰	۰/۰۶	۰/۷۴	۳-۵-۴-۱	MLP	V,S,D
۲/۴۳	۰/۸۸	۰/۰۵	۰/۸۹	-	RBF	V,S,D,d50
۴/۴۲	۰/۹۴	۰/۰۴	۰/۹۲	-	RBF	V,S,D,d50,W

جدول ۵- شاخص‌های آماری ارزیابی مدل‌های کاربردی

آماره‌ها					مدل‌ها
CRM	EF	CD	RMSE	ME	
-۰/۰۴	۰/۹۲	۱/۰۸	۰/۸۷	۲۸۰۳۰/۵۸	MLP
-۰/۱۵	۰/۸۶	۰/۹۵	۲/۴۳	۴۱۱۱۷/۴۴	RBF
۰/۶۶	-۰/۸۲	۱/۵۸	۱۴۵/۴۳	۱۸۱۳۰۹/۵۰	Yang
-۰/۹۲	-۷/۱۳	۰/۱۶	۳۰۷/۳۲	۴۷۱۷۸۸/۳۰	Ackers-White
۰/۹۲	-۰/۷۸	۱/۳۴	۱۴۳/۹۳	۱۸۸۱۱۸/۳۰	Engelund-Hansen
۰/۹۹	-۰/۸۵	۱/۱۷	۱۴۶/۸۱	۱۹۰۲۰۸/۶۰	Laursen
۰/۹۳	-۰/۷۹	۱/۳۳	۱۴۴/۳۰	۱۸۷۷۵۳/۶۰	Shen-Hung



شکل ۱- مقایسه نتایج بدست آمده از معادلات انتقال بار کل رسوب و مدل‌های ANN با مقادیر اندازه‌گیری شده

نتیجه‌گیری

افزون بر برنامه‌ریزی و مدیریت بسیاری از پروژه‌های منابع آب، تخمین مقدار رسوب رودخانه‌ها از نظر زیست‌محیطی نیز حائز اهمیت است؛ چرا که رسوبات با حمل کودها، آفت‌کش‌ها و سایر مواد شیمیایی، عامل آلودگی خاک و آب در پایین‌دست رودخانه‌ها به شمار می‌آیند. روابطی که تاکنون برای محاسبه بار رسوب کل ارائه شده‌اند نیاز به شرایط ویژه برای کاربرد دارند. همچنین نتایج حاصل از روابط مختلف معمولاً با یکدیگر و با مقادیر اندازه‌گیری شده هم‌خوانی ندارند. بنابراین در هر پروژه، انتخاب یک روش مناسب برآورد رسوب، یکی از مشکلات

پژوهشگران است. از این رو در این پژوهش روشی ساده، کاربردی و با دقت مناسب بر پایه شبکه‌های عصبی مصنوعی برای تخمین غلظت بار رسوب کل ارائه شد. نتایج حاصل از مدل پیشنهادی در مقایسه با پنج رهیافت معروف انتقال رسوب کل، بسیار تواناتر و دقیق‌تر بود. در واقع هیچ یک از معادلات نتوانستند نتایج قابل قبولی ارائه دهند. در حالیکه یک شبکه ساده پرسپترون سه لایه با ساختار ۱-۳-۵ و ورودی‌های مشابه با روابط مذکور، قادر است مقدار بار رسوب کل را به خوبی پیش‌بینی نماید. بنابراین برای مدل‌سازی برآورد بار رسوب کل کاربرد این شبکه توصیه می‌شود.

فهرست منابع

- ابراهیمی محمدی، ش.، صادقی، س.ح.ر. و چچی، ک. ۱۳۹۱. تحلیل آورد رواناب، رسوب معلق و مواد مغذی ورودی‌های مختلف به دریاچه زریوار در پایه زمانی رگبار و آب پایه. حفاظت منابع آب و خاک، ۲ (۱): ۶۱-۷۵.
- امامی، س.ا. ۱۳۷۹. انتقال رسوب. انتشارات جهاد دانشگاهی صنعتی امیرکبیر. تهران. چاپ اول. ۷۱۶ ص.
- بهزادفر، م.، صادقی، س.ح.ر.، خانجانی، م.ج. و حزب‌بوی، ز. ۱۳۹۱. تأثیرپذیری تولید روان‌آب و رسوب خاک‌های تحت چرخه انجماد- ذوب در شرایط شبیه‌ساز باران. نشریه حفاظت منابع آب و خاک، ۲ (۱): ۱۳-۲۳.
- حزب‌بوی، ز.، صادقی، س.ح.ر. و یونس‌ح.ا. ۱۳۹۱. تحلیل و ارزیابی تأثیرپذیری مؤلفه‌های روان‌آب از کاربرد سطوح مختلف پلی‌آکریل‌آمید. نشریه حفاظت منابع آب و خاک، نشریه حفاظت منابع آب و خاک، ۲ (۲): ۱-۱۴.
- دهقانی، ا.ا.، زنگانه، م.ا.، مساعدی، ا. و کوهستانی، ن. ۱۳۸۸. مقایسه تخمین بار معلق به دو روش منحنی سنجه رسوب و شبکه عصبی مصنوعی (مطالعه موردی رودخانه دوغ استان گلستان). مجله علوم کشاورزی و منابع طبیعی، ۱۶ (۱-الف): ۱۲-۱.
- دهقانی، ا.ا.، ملک‌محمدی، م. و هزارجریبی، ا. ۱۳۸۹. تخمین رسوب معلق رودخانه بهشت‌آباد با استفاده از شبکه عصبی مصنوعی. مجله پژوهش‌های حفاظت آب و خاک، ۱۷ (۱): ۱۵۹-۱۶۸.
- دهقانی، ن. و وفاخواه، م. ۱۳۹۲. مقایسه روش‌های تخمین رسوب معلق روزانه با استفاده از روش‌های منحنی سنجه رسوب و شبکه عصبی (مطالعه موردی: ایستگاه قزاقلی، استان گلستان). مجله پژوهش‌های حفاظت آب و خاک، ۲۰ (۲): ۱-۱۰.
- طهمورث، م.، احمدی، ح.، تقوی، ن. و عسکری، ح.م. ۱۳۸۸. مقایسه دقت مدل‌های شبکه عصبی مصنوعی ژئومورفولوژی (GANNs) و رگرسیون (RM) در برآورد رسوب طالقان-رود. پژوهش‌های آبخیزداری، ۸۴: ۱۹-۲۷.
- فلامکی، ا. و اسکندری، م. ۱۳۹۱. تخمین ضریب توزیع خاک-آب فلزات سنگین با کاربرد شبکه‌های عصبی مصنوعی. حفاظت منابع آب و خاک، ۲ (۱): ۲۵-۳۶.
- مساعدی، ا.، هاشمی‌نجفی، س.ف.، حیدرنژاد، م.، نبی‌زاده، م. و مشکاتی، م.ا. ۱۳۸۸. برآورد حجم رسوب‌گذاری در مخازن سدهای کرج و دز و مقایسه آن با نتایج هیدروگرافی. مجله علوم کشاورزی و منابع طبیعی، ۱۶ (۲): ۱-۱۳.
- معیری، م.م.، نیک‌پور، م.ر.، حسین‌زاده دلیر، ع. و فرسادی‌زاده، د. ۱۳۸۹. مقایسه روش‌های شبکه‌های عصبی مصنوعی، فازی-عصبی تطبیقی و منحنی سنجه رسوب در برآورد رسوبات معلق رودخانه‌ها (مطالعه موردی: رودخانه آجی-چای). مجله دانش آب و خاک، ۲۰/۱ (۲): ۷۱-۸۲.
- نوابیان، م.، لیاقت، ع. و همایی، م. ۱۳۸۳. برآورد سریع هدایت آبی اشباع خاک با استفاده از شبکه‌های عصبی مصنوعی. دومین کنفرانس ملی دانشجویی منابع آب و خاک، دانشکده کشاورزی، دانشگاه شیراز،
- (<http://www.civilica.com/Paper-SCSWR02->
<http://www.civilica.com/Paper-SCSWR02-004.html>).
- نوری، م.م.، همایی، م. و بای‌بوردی، م. ۱۳۹۱ (الف). ارزیابی پارامتریک توانایی نگهداشت خاک در حضور نفت خام در حالت سه فازی. حفاظت منابع آب و خاک، ۲ (۲): ۱۵-۲۴.
- نوری، م.م.، همایی، م. و بای‌بوردی، م. ۱۳۹۱ (ب). بررسی پارامتریک ویژگی‌های هیدرولیکی خاک در حضور آلانده نفت سفید. حفاظت منابع آب و خاک، ۲ (۱): ۳۷-۴۸.
- ولی، ع.، رامشت، م.ح.، سیف، ع. و قضاوی، ر. ۱۳۹۰. مقایسه کارایی مدل‌های شبکه‌های عصبی مصنوعی و رگرسیون برای پیش‌بینی بار رسوب جریان مطالعه موردی حوضه آبخیز سمندگان. مجله جغرافیا و برنامه‌ریزی محیطی، ۲۲ (۴): ۱۹-۳۴.
- ولی، ع.، معیری، م.، رامشت، م.ح. و موحدی‌نیا، ن. ۱۳۸۹. تحلیل مقایسه عملکرد شبکه‌های عصبی مصنوعی و مدل‌های رگرسیونی پیش‌بینی رسوب معلق مطالعه موردی: حوضه آبخیز اسکندری واقع در حوضه آبریز زاینده‌رود. پژوهش‌های جغرافیای طبیعی، ۷۱: ۲۱-۳۰.
- یونس‌ح.ا.، ترابی پوده، ح.، صمدی رحیم، ع. و محبی، ش. ۱۳۸۷. ارزیابی روش‌های برآورد بار رسوب کل در رودخانه‌های حوضه کرخه و مقایسه آن با نتایج حاصله از شبکه عصبی مصنوعی. هفتمین کنفرانس هیدرولیک ایران، تهران. ۱۷-۲۷.

- Alp, M. and Cigizoglu, H.K. 2007. Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. *Environmental Modelling and Software*, 22: 2-13.
- ASCE. 2000b. Artificial neural networks in hydrology, II: hydrologic applications. *Journal of Hydrologic Engineering*, 5: 124-137.
- Cigizoglu, H.K. and Kisi, O. 2006. Methods to improve the neural network performance in suspended sediment estimation. *Journal of Hydrology*, 317: 221-238.
- Dogan, E., Yuksel, I. and Kisi, O. 2007. Estimation of total sediment load concentration obtained by experimental study using artificial neural networks. *Environmental Fluid Mechanics*, 7: 271-288.
- Karami, A., Homae, M., Neyshabouri, M.R., Afzalnia, S. and Basirat, S. 2012. Large scale evaluation of single storm and short/long term erosivity index models. *Turkish Journal of Agriculture and Forestry*, 36: 207-216.
- Molinas, A. and Wu, B. 2003. SedBase (sediment transport database). Hydraul-Tech, Colorado, USA.
- Partal, T. and Cigizoglu, H.K. 2008. Estimation and forecasting of daily suspended sediment data using ASCE. 2000a. Artificial neural networks in hydrology, I: preliminary concepts. *Journal of Hydrologic Engineering*, 5: 115-123.
- wavelet-neural networks. *Journal of Hydrology*, 358: 317-331.
- Rai, R.K. and Mathur, B.S. 2008. Event-based Sediment Yield Modeling using Artificial Neural Network. *Water Resources Management*, 22: 423-441.
- Yang, C.T. 1996. *Sediment Transport Theory and Practice*. McGraw-Hill Companies, Inc. 396 p.
- Yang, C.T., Marsooli, R. and Aalami, M.T. 2009. Evaluation of total load sediment transport formulas using ANN. *International Journal of Sediment Research*, 24: 274-286.
- Zarei, G., Homae, M., Liaghat, A., 2009. Modeling transient evaporation from descending shallow groundwater table based on Brooks-Corey retention function. *Water Resources Management* 23(14): 2867-2876.
- 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: 111-125.



ISSN 2251-7480

Modeling total sediment load in rivers using artificial neural networks

Amin Falamaki^{1*}, Mahnaz Eskandari², Abdolhossein Baghlani³ and Seyed Ahmad Ahmadi⁴

^{1*}) Department of Engineering, Payame Noor University, Shiraz, Iran,

Corresponding author email: Falamaki@snu.ac.ir

2) Young Researchers Club, Islamic Azad University, Science and Research Branch, Tehran, Iran

3) Department of civil and environmental engineering; Shiraz University of Technology

4) M.Sc. of Hydraulic Structures

Received: 20-11-2012

Accepted: 19-02-2013

Abstract

Estimating total sediment load in rivers is an important and practical issue for water resources planning and management. The sediment concentration can be calculated by both direct and indirect measurements, but direct methods are usually costly and time-consuming. Further, total sediment load can be determined by several sediment load transport models. These equations, however, are applicable in certain circumstances, and in most cases the outcomes do not agree with each other and with measured data. The objective of this study was to propose a method based on artificial neural networks (ANN) to predict total sediment load concentration. Consequently, two ANNs including multilayer perceptrone (MLP) and radial basis function (RBF) with 200 data were used for the modeling purposes. For training and testing the ANN models, 75 and 25 percent of data were used, respectively. The input variables were designated to be average flow velocity, average depth, water surface slope, canal width and median particle diameter of sediment, while the models output was total sediment load concentration. The input variables were included to the models step wisely and the results were evaluated to find out the most suitable ANN models. The predicted values were then compared with five known sediment load transport equations. The conducted statistical analyses indicated that ANNs models in particular MLP can provide better prediction for total sediment load with correlation coefficient of 0.96. It was further concluded that to enhance the accuracy of ANN model, training of the network should be accomplished using both hydrological and sediment data. The Ackers and White equation was very overestimating the total sediment load, while all other equations were underestimating. Based on the results obtained in this study, the ANN-based models provide better concurrence with the observed data, particularly MLP network which can reasonably well predict the peak point of total sediment.

Keywords: multi layer perceptrone; radial basis functions; sediment transport formulas; total sediment concentration