

مقایسه کارایی مدل‌های شبکه‌های عصبی مصنوعی و رگرسیون برای پیش‌بینی بار رسوب جریان مطالعه موردی حوضه آبخیز سمندگان

عباسعلی ولسی: استادیار ژئومورفولوژی، دانشگاه کاشان، کاشان، ایران*
محمدحسین رامشت: استاد ژئومورفولوژی، دانشگاه اصفهان، اصفهان، ایران
عبدالله سیف: استادیار ژئومورفولوژی، دانشگاه اصفهان، اصفهان، ایران
رضا قضاوی: استادیار منابع آب، دانشگاه کاشان، کاشان، ایران

چکیده

یک سیستم رودخانه‌ای یک سیستم بازاست که از درگیر شدن ارتباطات مختلف و پیچیده شکل می‌گیرد. خصوصیات ذاتی حوضه‌ها از یک سو و عوامل خارجی از سوی دیگر رفتارهای رودخانه را متأثر می‌سازد. وجود ارتباطات متقابل متعدد از جمله ارتباطات جریان و رسوب حمل شده و تاثیر عوامل ژئومورفولوژی حوضه و مدل سازی آن از اهمیت ویژه ای برخوردار است. در این مطالعه دینوع شبکه عصبی مصنوعی ژئومورفولوژیکی و غیر ژئومورفولوژیکی برای پیش بینی بار رسوب جریان رودخانه سمندگان طراحی گردید و نتایج آن با دو نوع مدل رگرسیونی ژئومورفولوژیکی و غیر ژئومورفولوژیکی مورد مقایسه قرار گرفت. نتایج طراحی شبکه‌های عصبی مبین کارایی خوب شبکه‌های چند لایه ی پرسپترون با الگوریتم یادگیری پس انتشار خطا است. نتایج نشان داد که شبکه عصبی ژئومورفولوژیکی با ضریب تبیین ۰/۸۶۲ و مجذور میانگین مربعات خطای ۱/۸۱۵ در مقایسه شبکه عصبی غیر ژئومورفولوژیکی با ضریب تبیین ۰/۸۲۷ و معیار خطای ۲/۰۳۱ میزان رسوب جریان را بهتر پیش‌بینی می‌کند. نتایج ارزیابی مدل‌های رگرسیونی مبین عملکرد ضعیف‌تر آن‌ها در مقایسه با روش شبکه عصبی مصنوعی است به طوری که ضریب تبیین مدل رگرسیونی ساده غیر ژئومورفولوژیکی ۰/۷۵۹ و معیار خطای ۲/۳۹۵ و ضریب تبیین مدل رگرسیونی ژئومورفولوژیکی برابر ۰/۸۱۱ با معیار خطای معادل ۲/۱۴۲ است. همچنین از مقایسه نتایج مدل‌های مختلف چنین استنباط می‌شود زمانی که پارامترهای ژئومورفولوژیکی نظیر شاخص ناهمواری، شاخص گردی و شاخص تراکم زهکشی در مدل سازی وارد شوند نتایج ارزیابی آن‌ها مناسب‌تر می‌شود.

واژه‌های کلیدی: بار رسوب، پیش‌بینی، رودخانه سمندگان، ژئومورفولوژی، سیلاب، شبکه عصبی مصنوعی، مدل رگرسیونی، مدل سازی

مقدمه

روابط ساده و کارآمد و راه‌حل‌های ساده بهتر بتوانند با صرف هزینه و زمان کمتر مسائل پیچیده را مورد ارزیابی قرار داده و بهتر بتوانند آنها را کنترل و مدیریت نمایند. نگرشی سیستمی به سیستم‌ها خصوصاً سیستم‌های باز منجر به

توجه به پدیده‌ها و عوارض موجود در سیستم‌ها از یک طرف و پیچیدگی سیستم‌ها از طرف دیگر محافل علمی را به ساده سازی سیستم‌ها متمایل ساخته است تا با شناخت

دریچه‌های موجود در مسیر، نیاز به اطلاعات دقیق و کافی از انتقال رسوب است (موسوی و همکاران، ۲۰۰۶).

از آنجا که رسوب‌گذاری در مخازن سدها علاوه بر کاهش میزان ذخیره آب باعث افزایش تبخیر برای یک ظرفیت ذخیره مشخص، آب گرفتگی و تشکیل باتلاق در اراضی بالا دست سد، افزایش قدرت فرسایش رودخانه در پایین دست سد، کاهش حجم کنترل سیلاب مخزن و در برخی موارد حاد، باعث ایجاد پدیده روگذری در خلال سیل می‌شود. ته نشینی رسوب در پشت دیواره یک سد، پایداری آن را کاهش می‌دهد و بر عملکرد تأسیسات خروجی، دریچه‌ها و شیرهای تراز پایین دست اثرات نامطلوب می‌گذارد. پیش‌بینی نحوه توزیع رسوب برای طراحان سدها، به منظور تعیین آستانه دریچه‌های عمقی و آبگیر و بررسی تعادل و پایداری سد اهمیت دارد (یانگ^۲، ۱۹۹۶).

در مهندسی رودخانه، اطلاعات کافی پیرامون انتقال رسوب به عنوان پایه ای برای پروژه‌های رودخانه ای، مثل برداشتن قوس رودخانه‌ها یا تنگ شدن یک رودخانه، همچنین برای کشتیرانی، کنترل سیل، پس رفت آب و طراحی مخازن مورد نیاز است.

مکان سنجی خاستگاه سدها با نگرش صحیح از اطلاعات رسوبات میسر است و عدم توجه بر حجم رسوبات منجر به تحمیل هزینه‌های گزاف تخلیه رسوب انباشته شده در پشت مخازن

ایجاد یک روش شناسی در برنامه ریزی و تحلیل‌ها می‌گردد. تأکید بر کل سیستم، ساختار، عملکرد و ارتباطات آن دیدگاه کلان از سیستم را به وجود می‌آورد. در حقیقت کل گرایشی هویت سیستم را بیان می‌کند که همواره برپایه اصول و اهداف لزوم و وجوب آن استوار است (هوک^۱، ۲۰۰۷). مدل و مدل سازی یکی از مباحث مهم در علوم است. مبنای فلسفی هر مدلی نمی‌تواند فارغ از دیدگاه محقق باشد، زیرا در واقع مدل نمای ساده ای از فهم و درک ما از واقعیت است. از همین رو هر مدلی از پیش زمینه‌های فکری خاصی که متأثر از دیدگاه محقق است پیروی می‌کند (رامشت ۲۰۰۵). برآورد صحیح حجم رسوبات آبی در یک سیستم آبرفتی از مهمترین مسائل در مباحث مهندسی آب، مهندسی رودخانه، منابع آب، تأسیسات، سازه‌های آبی و محیط زیست جهت ایفای بسیاری از طرح‌ها و برنامه‌های توسعه ای است بطوری که می‌توان به برخی از مواردی که ضرورت و اهمیت موضوع را مشخص می‌سازد اشاره نمود.

آگاهی از میزان رسوبات بعنوان تولید فرآیند فرسایشی در حوضه‌های آبخیز امکان شناسایی، مقایسه و اولویت بندی حوضه‌های مختلف را فراهم می‌سازد (حکیم خانی، ۲۰۰۶).

در طراحی سیستم‌های آبیاری و انتقال آب، طراحی کانال‌های پایدار، ماسه گیرها، حوضچه‌های رسوب گیر، کانال‌های دانه گیر، سازه‌های ورودی، مجاری تخلیه و انواع

2. Yang, 1996.

¹. Hooke, 2007.

پیش‌بینی و شبیه‌سازی رفتار جریان‌ها و رسوبات آنهاست.

جریان رسوب متناسب با اندازه ذرات، بصورت موادمعلق یا به صورت غلطان در کف بستر حرکت می‌کند. جریان بار رسوب یکی از مهم‌ترین پارامترهای پروژه‌های هیدرولیک، یک شاخص مفید فرسایش خاک و محیط اکولوژیکی حوضه آبخیز است. روش‌های تجربی و فیزیکی متعددی جهت برآورد بار رسوب در یک حوضه آبخیز ابداع شده است. روش‌های تجربی برآورد رسوب بر اساس ارتباط خصوصیات حوضه نظیر مساحت، پستی و بلندی، پوشش اراضی و اقلیمی و امتیازدهی کیفی آن خصوصیات استوار شده است (زو و همکاران^۱، ۲۰۰۲، ۹۳) و قادرند نرخ رسوب‌گذاری در دلتا یا مخازن را به صورت غیر مستقیم برآورد نمایند (وراستراتون و همکاران^۲، ۲۰۰۳، ۲۴۸). این روش‌ها به دلیل برخورداری از ساختار ساده، محاسبات ساده ریاضی و قابلیت کارکردن با مجموعه داده‌های ورودی محدود به طور گسترده‌ای رایج می‌باشند (زو و همکاران^۳، ۲۰۰۷، ۱۲۴). بهر حال، مدل‌های رگرسیونی خطی یا غیر خطی مرسوم می‌توانند بار رسوب معلق را با دقت نسبی مدل‌های ساده تجربی محاسباتی ارائه نمایند.

در سال‌های اخیر تمایل زیادی نسبت به بررسی امکان استفاده از سیستم‌های شبکه‌های عصبی مصنوعی^۴ به وجود آمده است. شبکه‌های

می‌شود بنابراین، یکی از مهمترین مباحث در مرحله مطالعاتی یک سد و یا سازه آبی برآورد صحیح حجم رسوب آورده شده برای انتخاب صحیح خاستگاه سد است. میزان آورد رسوب و دانه بندی آن از جمله عواملی هستند که مستقیماً بر روی حجم کل سد تأثیر گذاشته و منجر به کاهش سریع ظرفیت مخازن سدها می‌شود. تجربه نشان می‌دهد بسیاری از سدهایی که با صرف هزینه‌های سنگین جهت کاربردهای مختلف ساخته شده اند، به دلیل برآورد نادرست میزان رسوب آورده شده، قبل از رسیدن به عمر مفید پیش‌بینی شده در طراحی با مشکل پر شدن پیش از موعد مخزن مواجه شده و به تعبیری سد قادر به برآورد اهداف خود نخواهد شد.

با توجه به اهمیت و حساسیت امر مهار آب‌های سطحی خصوصاً در کشور ما که اکثر رودخانه‌های مناطق مختلف فصلی بوده و کمبود آبی که در پهنه وسیعی از کشور وجود دارد، مدل‌سازی رفتار رودها برای برنامه‌ریزی‌های بلند مدت و استفاده بیشتر و بهتر از پتانسیل آنها ضروری است. بنابراین لازمه توسعه برنامه‌های مهار آب‌های سطحی دستیابی دقیق به رفتارهای جریان و میزان رسوبات آن است.

کمبود ایستگاه‌های اندازه‌گیری رسوب، جدید التأسیس بودن بیشتر ایستگاهها، قرار گرفتن بیشتر رودها در مناطق خشک، وضعیت بحرانی برداشت آب‌های زیر زمینی دلائل اهمیت و ضرورت ارزیابی صحیح در خصوص؛ برآورد،

¹. Zhou et al.2002.

². Verstraeten et al , 2004.

³. Zhou et al.2007.

⁶ Artificial neural network.

محاسبه ابعاد هیدروگراف برشمردند و ضمن معرفی روش شبکه عصبی مصنوعی به عنوان روش مطلوب به ویژگی‌های آن از جمله قابلیت بکارگیری داده‌های ژئومورفولوژیکی حوضه در برآورد جریان مستقیم حوضه اشاره نمودند. یاشان و گو^۶ (۲۰۰۳، ۱۲۲) یک سیستم تلفیقی رودخانه - شبکه عصبی طراحی نموده و به کمک آن با نتایج قابل قبول انتقال رسوب و جریان را بازسازی نمودند. سی گی زوگلو^۷ (۲۰۰۴، ۱۸۵) به ارزیابی یک شبکه عصبی مصنوعی از نوع دریافتی^۸ چند لایه در برآورد بار رسوب جریان پرداخته و کارایی تشخیص رفتار غیر خطی میزان رسوب معلق جریان را از نقاط قوت آن برشمرد. باتاچاریا و همکاران^۹ (۲۰۰۵، ۲۹۷) مدل سازی رسوب منتقل شده توسط جریان با استفاده از شبکه‌های عصبی مصنوعی و مقادیر واقعی به دست آمده از فلووم و عرصه را مورد بررسی قرار داده و کارایی مطلوب تر شبکه‌ها را از روش‌های رایج برآورد رسوب به کمک فلووم و روش‌های برآورد از عرصه، گزارش نمودند. سارانگی و باتاچاریا^{۱۰} (۲۰۰۵، ۱۹۵) با استفاده از دو نوع شبکه عصبی مصنوعی در برآورد رسوب در یک حوضه آبخیز در هند به ضریب تبیین ۰/۹۸ برای شبکه‌های وابسته به برخی شاخص‌های هندسی در مقابل ضریب تبیین ۰/۹۴ برای شبکه‌های ساده عصبی

عصبی ابزار محاسباتی قوی و توانمندی هستند که در ساماندهی و ایجاد رابطه بین اطلاعات گوناگون نیز قابلیت بسیار خوبی داشته‌اند. استفاده از قابلیت‌های بالای این سیستم‌ها در نگاشت فضاها و چند بعدی و همچنین تحلیل مسائلی که درک آن‌ها بدون متوسل شدن به روابط پیچیده ریاضی دشوار است می‌تواند در امور مهندسی مفید باشد. به طور کلی، سیستم‌های شبکه‌های عصبی مصنوعی در برخورد با مسائلی از قبیل شناسایی سیستم^۱، تقریب تابع^۲، بهینه سازی^۳ و پیش بینی هدف^۴ نتایج موفقیت آمیزی داشته‌اند. سیستم شبکه‌های عصبی مصنوعی با تکیه بر داده‌ها و قابلیت انعطاف پذیری بالا با برقراری اوزان مختلف به ارتباطات عصبی در جریان فرآیند یادگیری قادر است جوابگوی مسائل مبهم و پیچیده باشد. به خصوص مسائلی که به سادگی با روابط ریاضی قابل بیان نیستند.

تجارب موفق مدل سازی به کمک شبکه‌های عصبی مصنوعی در مباحث مختلف مدیریت آب بروز کرده است. زنگ و گوین داراجو^۵ (۲۰۰۳، ۳۳) با طراحی یک شبکه عصبی سه لایه بر اساس خصوصیات فیزیو گرافی دو حوضه در هند، هیدروگراف واحد جریان را شبیه سازی نمودند و ضریب تشخیص بالاتر این روش را عامل ارجحیت آن نسبت به روش معمول

⁶ .Yitian&Gu,2004.

⁷ .Cigizoglu,2004.

¹⁴ . Perceptron .

⁹ .Bhattacharya et al,2005.

¹⁰ .Sarangi &Bhattacharya,2005.

¹ . System recognition

² .Function approximation

³ .Optimization

⁴ .Forecasting

⁵ .Zhang &Govindaraju,2004.

نسبت به شبکه طراحی شده با آمار جریان روزانه با اعمال تاخیر ۳ روزه را تایید نمودند.

در ایران حسینی و همکاران (۱۴۱،۲۰۰۲) به مقایسه عملکرد روش ماسکینگام خطی و روش شبکه عصبی مصنوعی در روند یابی سیلاب پرداخته و ضمن معرفی موفق شبکه‌های عصبی مصنوعی در درک رفتار موج سیلاب، قابلیت قوی آنها را بدلیل قدرت میان‌یابی مناسب برای روند یابی متمرکز سیلاب معرفی نمودند. دستورانی و راییت (۲۰۰۴،۱) کاربرد روش سیستم عصبی مصنوعی در کاهش خطای هیدرودینامیکی برای پیش‌بینی جریان رودخانه پرداخته و ضمن به کار بردن یک مدل هیدرودینامیکی تک بعدی برای پیش‌بینی وضعیت جریان در نقطه ای در پایین دست رودخانه یک مدل شبکه عصبی مصنوعی به عنوان پیش‌بینی کننده خطای مدل هیدرودینامیکی مورد استفاده قرار گرفت و با پیش‌بینی این خطا نتایج مدل مزبور به میزان قابل توجهی به مقادیر نزدیک تر شد. یوسفوند و همکاران (۲۰۰۵،۱) به اثر کلاسه‌بندی داده هاب‌ر اساس زمان اندازه‌گیری بر انتقال رسوب رودخانه قره سو در کرمانشاه پرداخته و تفکیک ماه‌های سال را به ماه‌های پرآب و کم‌آب را در مدل سازی رگرسیونی مفید دانسته و آن را عامل کاهش میانگین مربعات خطا موثر دانستند.

حوضه‌های آبریز اساسی‌ترین واحدهای طبیعی در مقیاس منطقه‌ای به شمار می‌روند که استقلال و هویت تعریف شده‌ای دارند مفهوم حوضه‌های رودخانه‌ای به عنوان یک واحد

مصنوعی دست یافتند. سی‌گی زوگلو و آلپ^۱ (۶۳،۲۰۰۶) نیز به مقایسه روش رگرسیونی و شبکه‌های عصبی در برآورد بار رسوب رودخانه جونیاتا در ایالات متحده پرداخته و افزایش دقت و سرعت شبکه‌های عصبی مصنوعی را در مقابل روش رگرسیونی عامل ارجحیت آن معرفی نمودند. سی‌گی زوگلو و کیسی^۲ (۲۲۱،۲۰۰۶) با ارائه روش تجزیه داده‌ها به گروه‌های همگن فرآیند یادگیری شبکه عصبی پیشنهادی خود را جهت برآورد بار رسوب بهبود بخشیدند.

آگاروال و همکاران^۳ (۵۹۷،۲۰۰۶) با تفکیک داده‌ها در سری‌های زمانی روزانه، هفتگی، ده روزه و ماهانه با استفاده از آمار جریان رسوب به مقایسه آمار واقعی با آمار برآورد شده پرداخته و به این طریق شبکه‌های طراحی شده را ارزیابی نمودند. آلپ و سی‌گی زوگلو^۴ (۱۱،۲۰۰۷) به بررسی عملکرد یک شبکه چند لایه با یک شبکه شعاعی برای برآورد بار رسوب به کمک داده‌های بارندگی و جریان پرداخته و نتایج مشابهی نسبت به رگرسیون چندگانه به دست آوردند. زو و همکاران^۵ (۱۱۱،۲۰۰۷) ضمن معرفی روش مدل سازی شبکه عصبی مصنوعی جهت جریان رسوب معلق به کارآیی برآورد بار رسوب جریان در رودخانه‌ای در چین پرداخته و مزیت شبکه طراحی شده اقلیمی

^۱ .Cigizoglu&Alp,2006.

^۲ .Cigizoglu&Kisi,2006.

^۳ .Agarwal et al ,2006.

^۴ .Alp&Cigizoglu,2007.

^۵ .Zhou et al ,2007.

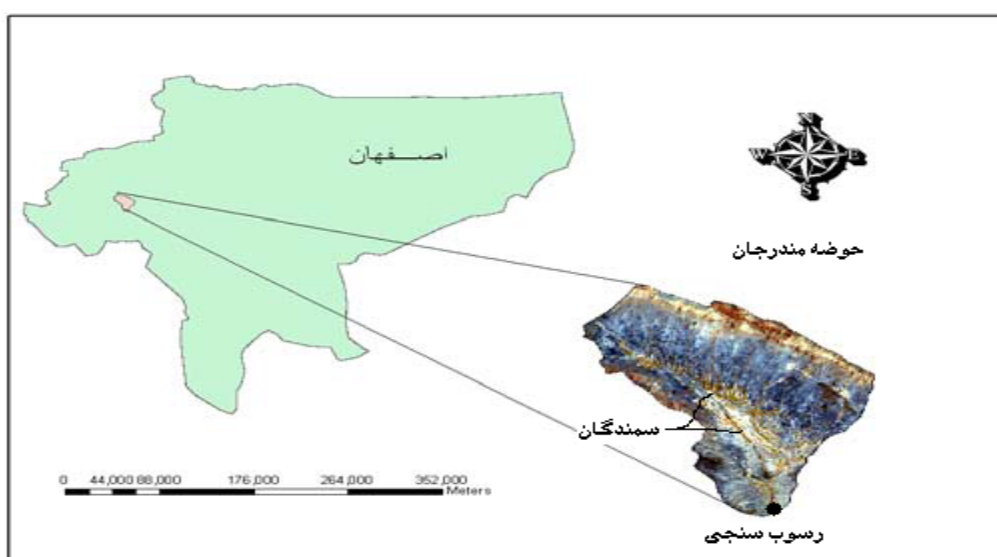
رودخانه زاینده رود (۷۲ کیلومتر)، رودخانه سمندگان (۲۳ کیلومتر) و رودخانه حیدری (۱۵ کیلومتر). حوضه آبخیز مورد مطالعه در این تحقیق حوضه رودخانه سمندگان معروف به حوضه مندرجان است. حوضه مزبور بین طول‌های ۵۰/۵۰ تا ۵۰/۶۰ درجه و عرض‌های ۳۲/۷۶ تا ۳۲/۹۲ درجه واقع شده است. رواناب این حوضه در محل ورود به دریاچه سد در ایستگاه هیدرومتری مندرجان با طول ۵۰/۶۰ درجه شرقی و عرض ۳۲/۷۶ درجه شمالی و ارتفاع ۲۱۸۵ متر از سطح تراز دریا، اندازه‌گیری می‌شود. این رودخانه آب حوضه‌ای به مساحت ۱۴۲/۳۸۷ کیلومتر مربع را تخلیه می‌کند. ارتفاع متوسط این حوضه ۲۳۷۰ متر و بارندگی متوسط آن ۴۱۰ میلی‌متر است. شکل (۱) موقعیت ایستگاه‌ها و رودخانه اصلی حوضه مورد مطالعه را نشان می‌دهد.

فضایی در نظام بندی فعالیت‌های بشری نقش موثری دارد (رامشت ۲۰۰۵). هدف از این پژوهش توسعه مدل سازی با بهره‌گیری از روش شبکه‌های عصبی مصنوعی به کمک عوامل ژئومورفیک و مقایسه عملکرد آن‌ها با چند روش‌های رگرسیونی، در حوضه رودخانه‌ای مورد مطالعه است. تا ضمن پیش بینی میزان رسوب حوضه توسط مدل‌ها و مقایسه مقادیر محاسبه شده با مقادیر مشاهده شده مزیت نسبی آن‌ها تبیین گردد.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه در محدوده‌ی حوضه آبریز زاینده رود (۴۱۵۰۳ کیلومتر مربع) واقع شده است. سد زاینده رود بر روی رودخانه زاینده رود احداث شده است و چهار رودخانه اصلی آب خود را در پشت سد تخلیه می‌کنند. رودخانه‌های مزبور عبارتند از رودخانه پلاسجان (۶۰ کیلومتر)،



شکل ۱- موقعیت حوضه آبخیز رودخانه سمندگان و ایستگاه سنجش دبی و رسوب مندرجان

جدول ۲- پارامترهای ژئومورفولوژی حوضه آبخیز

رودخانه سمندگان

ردیف	پارامتر	واحد	مقدار
۱	ضریب ناهمواری	بدون بعد	۰/۰۵
۲	ناهمواری نسبی	بدون بعد	۱/۹۸
۳	شاخص کشیدگی	بدون بعد	۰/۶۳
۴	ضریب شکل	بدون بعد	۰/۳۱
۵	ضریب انشعاب	بدون بعد	۵/۳۳
۶	شاخص گردی	بدون بعد	۰/۵۶۹
۷	شاخص فشردگی	بدون بعد	۱/۳۱۵
۸	تراکم زهکنی	بدون بعد	۲/۸
۹	شاخص زهکنی	بدون بعد	۰/۱۶
۱۰	بسامد آبراهه	بدون بعد	۱/۲۶
۱۱	شاخص ناهمواری	بدون بعد	۳/۱

روش پژوهش

ابتدا آزمون حذف داده‌های پرت به کمک محاسبه شاخص باقیمانده استیودنت^{۱۳} در نرم افزار SAS انجام گرفت که در نتیجه آن دو داده پرت شناسایی و حذف گردید. سپس مجموعه داده‌ها به دو گروه آموزش و آزمون تقسیم شدند. ۷۵ درصد داده‌ها برای آموزش^{۱۴} یا واسنجی و ۲۵ درصد داده‌ها برای صحت سنجی یا آزمون^{۱۵} مدل‌ها اختصاص یافت. مرحله بعد شامل مدل سازی به کمک داده‌های آموزش است که پس از

در این تحقیق از آمار دبی لحظه ای - رسوب لحظه ای ثبت شده مربوط به دوره آماری سال ۱۳۷۹ تا ۱۳۸۷، استفاده شده است. این آمار شامل دبی لحظه‌ای روزانه به مترمکعب بر ثانیه و رسوب روزانه لحظه ای به تن در روز مربوط به ۱۰۲ حادثه سیلاب ثبت شده است که به صورت همزمان اندازه گیری شده‌اند خصوصیات طبیعی حوضه به کمک نرم افزار اتوکد^۱ و پارامترهای ژئومورفولوژیکی حوضه با استفاده از خصوصیات طبیعی حوضه بر اساس دستورالعمل سینگ و همکاران (۲۰۰۹) محاسبه گردیده است. عوامل طبیعی و پارامترهای ژئومورفولوژیکی حوضه در جداول (۱) و (۲) ارائه شده است.

جدول ۱- خصوصیات طبیعی حوضه آبخیز رودخانه

سمندگان

ردیف	پارامتر	واحد	مقدار
۱	مساحت	کیلومتر مربع	۱۴۲/۳۸۷
۲	محیط	کیلومتر	۵۶/۰۵۶
۳	طول آبراهه اصلی	کیلومتر	۲۱/۸۸۴
۴	ارتفاع حداکثر	کیلومتر	۳۲۹۸
۵	متوسط ارتفاع	کیلومتر	۲۳۷۰
۶	ارتفاع حداقل	کیلومتر	۲۱۸۵
۷	طول کل آبراهه ها	کیلومتر	۳۹۹
۸	تعداد آبراهه ها	رشته	۱۸۰
۹	طول حوضه	کیلومتر	۲۱/۳۶
۱۰	عرض حوضه	کیلومتر	۶/۶۶

^۲ .Relief ratio

^۳ .Relative relief

^۴ .Elongation ratio

^۵ .Form factor

^۶ .Bifurcation ratio

^۷ .Circulatory ratio

^۸ .Compactness coefficient

^۹ .Drainage density

^{۱۰} .Drainage factor

^{۱۱} .Steam frequency

^{۱۲} .Ruggedness number

^{۱۳} .R student.

^{۳۵} .Training data.

^{۳۶} .Testing data.

پارامترهای مدل تعیین شده و پارامترهای اضافی یا بی تاثیر حذف می‌شود. بنابراین این یک مدل مناسب چند متغیره ژئومورفولوژیکی طراحی می‌شود. به عبارت دیگر در این روش هریک از پارامترهای ژئومورفولوژی حوضه که به صورت یک داده ی نقطه ای هستند با تلفیق شدن در یک بردار داده نظیر آمار سیلاب به یک بردار داده جدید تبدیل می‌شوند و بردارهای جدید تولید شده مبنای رگرسیون چند گانه قرار گرفته و مدل مناسب حاصل می‌شود.

برای مدل سازی شبکه‌های عصبی مصنوعی از جعبه ابزار شبکه عصبی مصنوعی نرم افزار SPSS استفاده شده است. شبکه‌های عصبی طراحی شده در این پژوهش بسته به نوع داده‌های ورودی به دو نوع تقسیم شدند. نوع اول شبکه عصبی مصنوعی طراحی شده با استفاده از دبی و رسوب لحظه ای است. در این نوع شبکه دبی لحظه ای به عنوان عناصر ورودی و میزان رسوب لحظه ای به عنوان خروجی سیستم طراحی شده است. این شبکه به اختصار شبکه عصبی غیر ژئومورفولوژی^۴ NGANN نامیده شده است. نوع دوم شبکه عصبی مصنوعی طراحی شده با استفاده از عناصر به کار رفته در روش مارس تغذیه شده است و به دلیل تاثیر

طراحی مدل‌ها با داده‌های آزمون و کل داده‌ها مدل‌ها مورد ارزیابی قرار گرفت. مراحل مدل سازی آماری و شبکه عصبی مصنوعی به کمک نرم افزار SPSS صورت گرفته است. مدل‌های آماری طراحی شده به دو شیوه رگرسیون ساده و رگرسیون چند متغیره استفاده گردید. در رگرسیون ساده بهترین رابطه برآزش بین دبی لحظه ای و رسوب لحظه ای از بین روابط خطی، معکوس، نمایی، لگاریتمی، درجه دو، درجه سه و توانی مبنای تصمیم گیری قرار گرفته است. این روش به روش منحنی سنج رسوب^۱ یا SRC معروف است.

نوع دوم مدل آماری در نتیجه تاثیر پارامترهای ژئومورفولوژی بر روی دبی لحظه ای طراحی گردیده است و ارتباط غیر خطی بین این متغیرهای مستقل با رسوب لحظه ای محاسبه و با استفاده از آنالیز رگرسیون از بین پارامترهای به کار گرفته شده، پارامترهای تاثیر گذار انتخاب شده است. این روش به اختصار به روش مارس^۲ MARS معروف است. در این روش بردار دبی با استفاده از به توان رسانی پارامترهای ژئومورفولوژی به تعداد زیادی متغیر مستقل تبدیل شده سپس با استفاده از آنالیز رگرسیون چند متغیره به کمک روش گام به گام^۳

^۱. Sediment Rating Curves.

^{۳۸}. Multivariate Adaptive Regression Spline (MARS).

^۳. Stepwise.

^{۴۰}. Non Geomorphologic Artificial Neural Network (NGANN)

معماری منطبق بر تجربه و آزمون و خطا استفاده می‌شود. با توجه به عدم وجود ثبات در ایجاد و توسعه شبکه عصبی مصنوعی تجربیات موفق قبلی می‌تواند مفید واقع شود. تعداد لایه‌های مخفی و تعداد نرون‌های لایه‌های مخفی به روش آزمون و خطا و مقایسه عملکرد خطای آنها انتخاب شده‌اند.

برای ارزیابی نتایج عملکرد مدل‌های طراحی شده از مجذور میانگین مربعات خطا^۲ و ضریب تبیین^۳ بین بردار مشاهده شده و بردار پیش‌بینی شده بهره‌گیری شده است (جدول ۳).

جدول ۳- معیارهای ارزیابی کارایی مدل‌ها

فرمول	معیار
$RMSE = \sqrt{\frac{\sum (\hat{y}_i - y_i)^2}{n}}$	ریشه میانگین مربع خطا (Root Mean Square Error)
$R^2 = 1 - \frac{\sum (\hat{y}_i - y_i)^2}{\sum \hat{y}_i^2}$	ضریب تبیین R^2

در روابط فوق y_i ، \hat{y}_i و n به ترتیب مقدار هدف (مشاهده واقعی)، خروجی مدل و تعداد مشاهدات هستند.

یافته‌های تحقیق

نتایج آزمون بهترین رابطه برآزش در روش SRC به شرح جدول (۴) است. در این جدول نتایج انواع مدل‌های ساده برآزش بین دبی لحظه‌ای و رسوب لحظه‌ای ارائه شده است. از مقایسه ضرایب تبیین و مجذور میانگین مربعات خطا بهترین تابع برآزش بین این دو متغیر از نوع

پارامترهای ژئومورفیک این شبکه به اختصار ^۱GANN نامیده شده است.

یکی از سوالات اساسی در مدل‌سازی رواناب-رسوب چگونگی انتخاب و معماری شبکه برای حصول به حداکثر دقت است. هر یک از انواع مختلف شبکه‌های عصبی در زمینه‌ای به خصوص قابلیت بهتری نسبت به سایر انواع دیگر دارند لیکن برای عمل تقریب تابع، شبکه‌های عصبی چندلایه مناسب‌ترین می‌باشند. ساختار شبکه عصبی، ورودی‌های اعمال شده، تعداد لایه‌های مخفی، تعداد نرون‌های لایه‌ها، نحوه آموزش و تعداد بردارهای خروجی هر شبکه در ارزیابی عملکرد مدل موثر است. ترکیب‌های گوناگون در پارامترهای ورودی و تعداد لایه‌های مخفی برای رسیدن به یک خروجی مطلوب معماری شبکه قلمداد می‌شود.

در شبکه‌های از نوع انتشار برگشتی قاعده مشخصی برای انتخاب لایه‌های پنهان و همچنین تعداد نرون‌ها در لایه پنهان وجود ندارد. در حقیقت انتخاب تعداد نرون‌ها در لایه پنهان و همچنین تعداد لایه‌های پنهان با توجه به نوع مساله تغییر می‌کند. در حل مسائل هیدرولوژی، با توجه به تغییرات شدید داده‌ها، اغتشاش حاکم بر داده‌ها استفاده از شبکه‌های از نوع پس انتشار خطا به دلیل قابلیت انعطاف پذیری بالا با

^{۴۲} . Root Mean Square Error (RMSE).

^{۴۳} . Coefficient of determination (R^2).

^{۴۱} . Geomorphologic Artificial Neural Network(GANN)

مربعات خطا گزارش شده است. در این جدول همچنین ضرایب لازم برای بازسازی آن محاسبه و گزارش شده است.

شبکه‌های عصبی مصنوعی طراحی و انتخاب شده پس از مرحله آزمون و خطا به کمک تابع عملکرد خطا نهایی شده‌اند. شکل (۲) و (۳) شبکه‌های عصبی نهایی شده برآورد رسوب لحظه ای معلق را نمایش می‌دهد. شکل (۲) شبکه طراحی شده مدل NGANN را که یک لایه مخفی با ۲ نرون در این لایه را که با اوزان مختلف بهم متصل شده‌اند را نشان می‌دهد.

تابع توانی انتخاب شده است. شکل کلی آن به صورت معادله (۱) می‌باشد.

$$S = aR^b \quad (1)$$

که در آن a, b ضرایب رابطه، R میزان رواناب لحظه ای، S میزان رسوب لحظه ای.

نتایج آنالیز رگرسیون چند متغیره ژئومورفولوژیکی و انتخاب مدل مناسب MARS به شرح جدول (۵) است. در این جدول نتایج انتخاب نهایی متغیرهای مدل تبیین شده است. مشخصات ارزشیابی مدل نهایی شده به کمک آماره‌های ضریب همبستگی، ضریب تبیین، ضریب تبیین تعدیل شده و مجذور میانگین

جدول ۴- خلاصه مدل‌های مختلف جهت انتخاب مدل مناسب و برآورد پارامترهای مدل‌ها

معادله	خلاصه مدل								برآورد پارامترهای مدل		
	RMSE	Sig	۲df	۱df	F	R2	۱b	۲b	۳b		
خطی	۲/۵۶۸	۰/۰۰۰	۹۸	۱	۲۵۶/۰۲۳	۰/۷۲۳	۰/۷۷۲-	۱۲/۹۷۶			
لگاریتمی	۳/۹۶۵	۰/۰۰۰	۹۸	۱	۵۰/۴۴۷	۰/۳۴۰	۶/۸۲۰	۱/۸۶۶			
معکوس	۴/۵۶۳	۰/۰۰۰	۹۸	۱	۱۴/۱۰۷	۰/۱۲۶	۳/۶۵۰	۰/۰۵۳-			
درجه دو	۲/۱۲۳	۰/۰۰۰	۹۷	۲	۲۱/۳۰۸	۰/۸۱۳	۰/۱۳۱	۳/۵۱۹	۷/۷۶۸		
درجه سه	۲/۱۳۳	۰/۰۰۰	۹۶	۳	۱۳۹/۰۰۷	۰/۸۱۳	۰/۱۸۶	۲/۴۴۱	۹/۹۱۹		
مرکب	۱/۱۶۷	۰/۰۰۰	۹۸	۱	۱۶۰/۰۸۹	۰/۶۲۰	۰/۱۴۲	۱۰۶/۱۴۱			
توانی	۰/۷۰۸	۰/۰۰۰	۹۸	۱	۶۰۲/۶۴۳	۰/۸۶۰	۷/۴۹۲	۱/۱۵۲			
سیگموئید	۱/۰۹۳	۰/۰۰۰	۹۸	۱	۱۹۶/۵۲۴	۰/۶۶۷	۰/۵۰۲	۰/۰۴۷-			
رشد	۱/۱۶۷	۰/۰۰۰	۹۸	۱	۱۶۰/۰۸۹	۰/۶۲۰	۱/۹۵۱-	۴/۶۶۵			
نمایی	۱/۱۶۷	۰/۰۰۰	۹۸	۱	۱۶۰/۰۸۹	۰/۶۲۰	۰/۱۴۲	۴/۶۶۵			

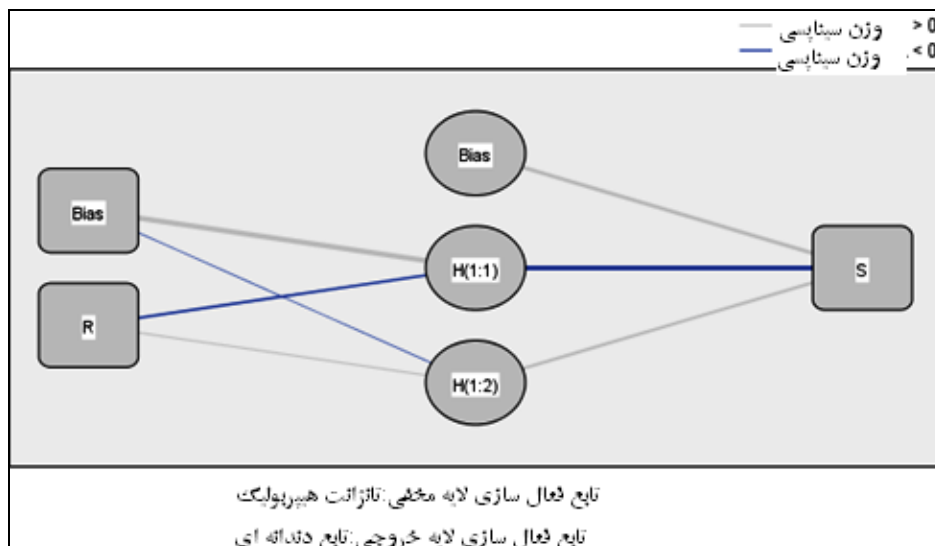
جدول ۵- نتایج ارزیابی مدل و ضرایب مدل نهایی شده MARS

Sig.	t	ضرایب غیر استاندارد		متغیر	خلاصه مدل				
		Beta	خطای استاندارد		B	RMSE	Adj.R2	R2	R
۰/۰۲۰	۲/۳۷۰-	-	۳۴/۳۲۰	۸۱/۳۲۶-	مقدارثابت	۲/۱۴۲	۰/۸۰۵	۰/۸۱۱	۰/۹۰۱
۰/۰۱۹	۲/۳۹۳	۰/۵۳۶	۳۷/۵۷۱	۸۹/۸۹۵	۱R				
۰/۰۰۱	۳/۵۲۳-	۱/۷۷۶-	۸/۰۸۴	۲۸/۴۸۳-	۴R				
۰/۰۰۰	۶/۶۲۸	۲/۱۶۷	۴/۸۰۲	۳۱/۸۲۸	۳R				

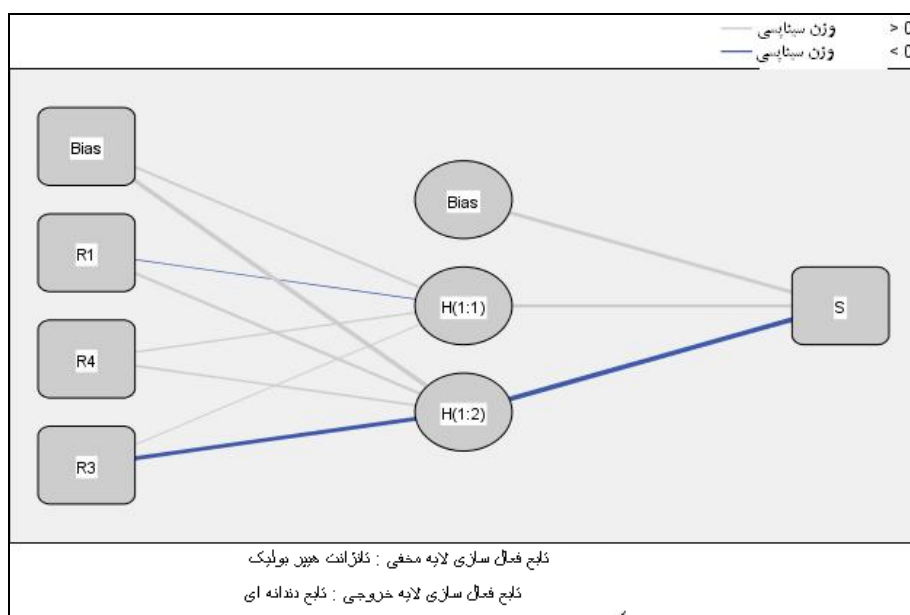
اهداف تحقیق مقایسه روش‌های NGANN و GANN است. بنابراین، ساختار و توابع عملکردی

شکل (۳) شبکه عصبی روش GANN را به تصویر کشیده است. با توجه به این که یکی از

آن‌ها ثابت فرض شده است تا بتوان نتایج حاصل از مدل‌سازی را به روش بکار گرفته و نه به تکنیک بکار رفته شده نسبت داد.



شکل ۲- ساختار شبکه عصبی مصنوعی طراحی شده بر اساس دبی جریان لحظه‌ای و دبی رسوب لحظه‌ای دبی رسوب لحظه‌ای S دبی جریان لحظه‌ای و (R)



شکل ۳- ساختار شبکه عصبی مصنوعی طراحی شده بر اساس پارامترهای ژئومورفولوژیک و دبی جریان و رسوب. R^{Df} , R^{Rc} , R^{Rr} عبارتند از R_3, R_4, R_1 به ترتیب

(۶) ارائه شده است. بهترین معادله برآزش بین میزان دبی و رسوب لحظه‌ای از بین مدل‌های

نتایج مدل‌های رگرسیونی پیش‌بینی میزان رسوب لحظه‌ای بر حسب تن در روز در جدول

استنباط ارتباط بین ۴ متغیر مستقل فوق‌الذکر با میزان رسوب توسط روش MARS بررسی شده است. همان‌گونه که مشاهده می‌شود ضریب تبیین معنی دار ۰/۸۱۱ برای صحت سنجی کل داده‌ها به دست آمده است.

خطی، لگاریتمی، درجه ۲، درجه ۳، معکوس و توانی برای داده‌های آموزش، رابطه توانی با ضریب تبیین ۰/۸۶۰ حاصل شده است. نتایج تاثیر عوامل ژئومورفولوژی منتج به انتخاب سه ضریب ناهمواری، ضریب گردی و شاخص زهکشی حوضه با استفاده از آمار دبی و

جدول ۶- نتایج مدل‌های آماری طراحی شده پیش‌بینی بار رسوب معلق رودخانه سمندگان

نام مدل ضریب تبیین معادله مدل
$S = 7.492 R^{1.152}$ ۰/۸۶۰ SRC
$S = 89.895 R^{Rr} - 28.483 R^{Rc} + 31.828 R^{Df} - 81.326$ ۰/۸۱۱ MARS

مربعات خطا و میزان ضریب تبیین و بردارهای ورودی هر مدل به صورت جداگانه بیان شده است.

نتایج حاصل از مدل سازی آماری و شبکه‌های عصبی مصنوعی و عملکرد هر مدل در جدول (۷) ارائه شده است. مجذور میانگین

جدول ۷- نتایج ارزیابی مدل‌های مختلف طراحی شده برای برآورد رسوب معلق جریان حوضه رودخانه سمندگان

مدل	ورودی‌ها	R	R ²	R Adj ²	RMSE
SRC	R(دبی جریان)	۰/۸۷۱	۰/۷۵۹	۰/۷۵۷	۲/۳۹۵
MARS	R^{Df}, R^{Rc}, R^{Rr}	۰/۹۰۱	۰/۸۱۱	۰/۸۰۵	۲/۱۴۲
NGANN	R(دبی جریان)	۰/۹۰۹	۰/۸۲۷	۰/۸۲۵	۲/۰۳۱
GANN	R^{Df}, R^{Rc}, R^{Rr}	۰/۹۲۸	۰/۸۶۲	۰/۸۶۰	۱/۸۱۵

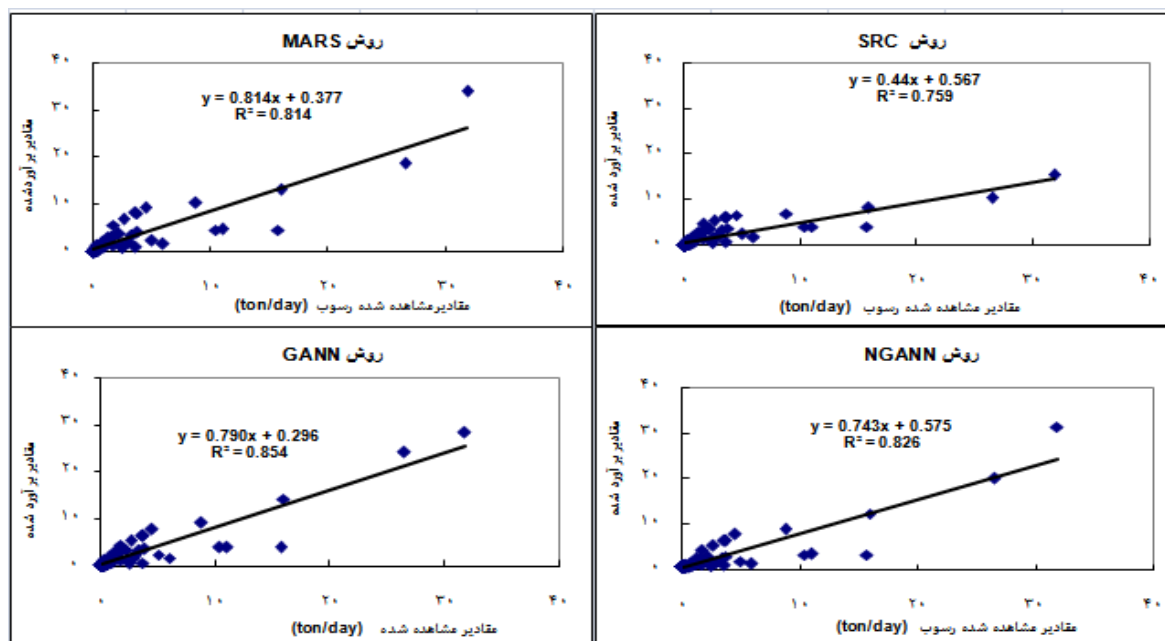
کمترین میزان خطا، بهترین روش را معرفی می‌نماید بنابراین، ارزش رجحانی روش‌ها به ترتیب SRC، MARS، NGANN، GANN و میزان ضرایب تبیین ۰/۸۶، ۰/۸۳، ۰/۸۱ و ۰/۷۶ و مقادیر خطای برآورد ۱/۸۱۵، ۲/۰۳۱، ۲/۱۴۲ و ۲/۳۹۵ تعیین می‌گردد. شکل (۴) ارتباط بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده در مدل‌های چهارگانه تحقیق برای داده‌های آزمون

بحث و نتیجه‌گیری

ارزیابی عملکرد مدل‌های مختلف به کمک فاکتورهای RMSE و R² امکان پذیر است. این فاکتورها زمانی می‌توانند ارزش رجحانی مدل‌ها را تعیین نمایند که بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده محاسبه شوند. توجه به مقادیر RMSE و R² مزیت نسبی مدل‌ها را نشان می‌دهد. بیشترین ضریب تبیین معنی دار و

ارائه نموده است. این شکل تشخیص چشمی عملکرد مدل‌های مختلف برآورد بار رسوب روزانه را آشکار می‌سازد. خطوط ضخیم داده‌های واقعی و خطوط باریک داده‌های پیش‌بینی شده توسط مدل‌ها را نشان می‌دهد.

براساس ضریب تبیین را نشان می‌دهد. در مقایسه کارایی این مدل‌ها هر چه نتایج پیش‌بینی بیشتر منطبق بر نتایج مشاهده شده باشد مدل از کارایی مطلوب تری برخوردار است. شکل (۵) اختلاف بین مقادیر خطای برآورد شده و مقادیر واقعی رسوب را برای مدل‌های مختلف



شکل ۴- نمودارهای چهارگانه ارتباط بین مقادیر مشاهده شده و پیش‌بینی شده میزان رسوب روزانه براساس داده‌های آزمون الف) روش PR، ب) روش MARS، ج) روش ANN و د) روش GANN.

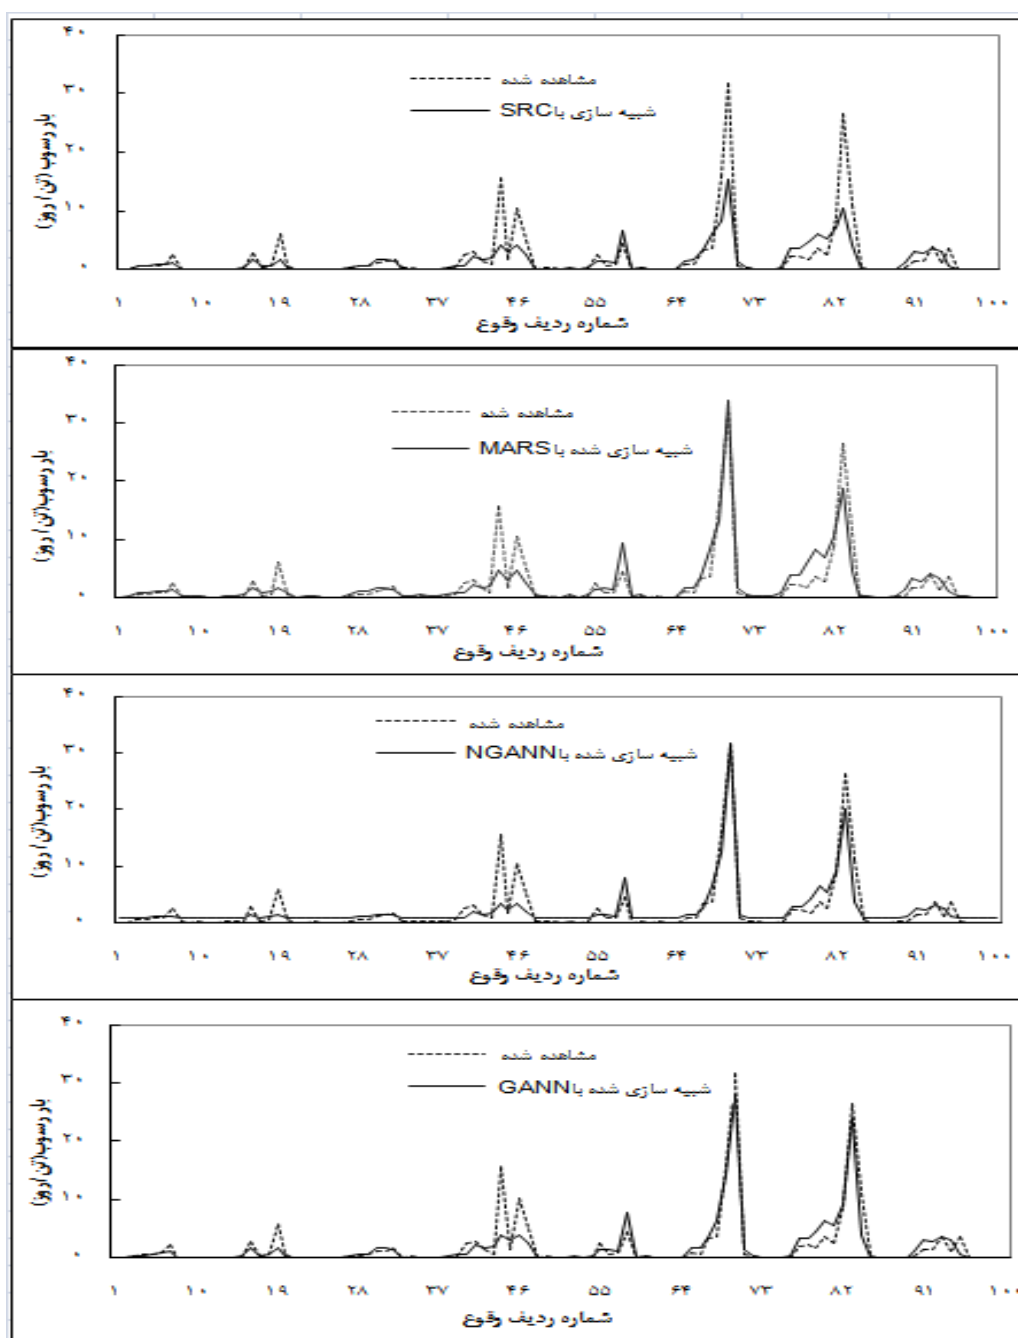
با توجه به یکسان بودن داده‌های ورودی مدل‌های MARS و GANN می‌توان علت وجود اختلاف در نتایج ارزشیابی مدل‌ها را در نوع مدل بکارگرفته جستجو نمود. بنابراین، می‌توان کارایی بالاتر شبکه عصبی مصنوعی ژئومورفولوژیکی را نسبت به مدل رگرسیونی ژئومورفولوژیکی به خوبی استنتاج نمود.

از مقایسه نتایج مدل‌های SRC و MARS می‌توان به کارایی توأم داده‌های ژئومورفولوژی و روش رگرسیون چند متغیره غیر خطی MARS

با توجه به یکسان بودن ساختارهای شبکه‌های عصبی NGANN و GANN می‌توان علت اختلاف در کارایی مدل را در اثر دخالت عوامل ژئومورفولوژی حوضه در مدل سازی دانست و با اطمینان اظهار نمود زمانی که اطلاعات سیلاب با عوامل ژئومورفولوژی حوضه ادغام شوند، مدل کارایی بالاتری نسبت به زمانی دارد که فقط از اطلاعات سیلاب استفاده نماییم.

با توجه به این که مدل‌های NGANN و SRC از داده‌های هیدرولوژی سیلاب حوضه استفاده نموده‌اند مقایسه آنها حاکی از کارایی بالاتر شبکه عصبی نسبت به روش آماری است.

پی برد و اظهار داشت زمانی که عوامل ژئومورفولوژی حوضه در غالب معادلات غیر خطی با عوامل هیدرولوژی حوضه در مدل سازی آماری وارد شوند نتایج مطلوب تری نسبت به زمانی حاصل می‌شود که از معادلات ساده به کمک داده‌های هیدرولوژی استفاده شود.



شکل ۵- مقایسه اختلاف خطای بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده رسوب در روش‌های چهارگانه

هیدرولوژی به عنوان یک رکن اساسی و کارآمد توصیه می‌شود.

Reference

- Agarwal, A., Mishra, S.K., Sobha R and Singh J. K., (2006). Simulation of runoff and sediment yield using artificial neural networks. *J. Biosystems engineering* 94, 597–613.
- Alp, M. and Cigizoglu, H.K., (2007). Suspended sediment load simulation by two artificial neural network methods using hydro meteorological data. *Environmental modeling and software*. 22:2-13.
- Bhattacharya, B., Price, R.K. and Solomatine, D.P., (2005). Data-driven modeling in the context of sediment transport. *Physics and Chemistry of the Earth* 30, 297–302.
- Cigizoglu, H.K., (2004). Estimation and forecasting of daily suspended sediment data by multi layer perceptrons. *Advances in Water Resources* 27, 185–195.
- Cigizoglu, H.K. and Kisi, O., (2006). Methods to improve the neural network performance in suspended sediment estimation. *Journal of Hydrology*. 317:221-238.
- Cigizoglu, H.K. and Alp, M., (2006). Generalized regression neural network in modeling river sediment yield. *J. Advance in engineering software*. 37:63-68.
- Dastorani, M.T., Wright, N.G. (2004). Combination of Artificial Neural Networks and Hydrodynamic Models for More Precise Prediction of River Flow (Text in Persian), *Journal of Water & Wastewater*, 49:1-13.
- Flood, I. and Kartman .N. (1996). Neural network in civil engineering: principles and understanding. *J. of computing in civil engineering*, 8(2).131-148.
- Hakim khany, sh. and Arab khedri. (2006). suspended sediment and hydro-geomorphology parameters with regression analysis case study Oroumiyeh basin (text in Persian). *Iranian agricultural science journal*:223-231.
- Hooke, J.M., (2007). Complexity, self-organization and variation in behavior in meandering rivers. *Journal of Geomorphology* 91: 236–258.

مقایسه نتایج روش‌های آماری و نتایج شبکه‌های عصبی ارزش رجحان مدل‌های شبکه عصبی را در برآورد رسوب لحظه ای روزانه بیان می‌کند. علت تفاوت بین عملکرد بهتر شبکه‌های عصبی مصنوعی در مقایسه با روش‌های آماری را می‌توان در قابلیت تخمین و پیش‌بینی شبکه‌های عصبی مصنوعی برای تقریب غیر خطی با حجم کم داده‌ها جستجو نمود. این در حالی است که عملکرد و دقت روش‌های رگرسیونی به شدت از حجم نمونه تبعیت می‌کند و حجم کم نمونه‌ها می‌تواند عامل محدودیت مدل‌های آماری گردد. لیکن در مدل‌های طراحی شده ی شبکه عصبی مصنوعی کم بودن تعداد نمونه‌ها محدودیت چشم‌گیری ایجاد نکرده است. نتیجه‌گیری نهایی تحقیق معرفی و ارائه مدل طراحی شده شبکه عصبی مصنوعی به کمک پارامترهای ژئومورفولوژیکی حوضه آبخیز رودخانه مزبور است. این مدل از نوع شبکه پیش‌خور با الگوریتم پس‌انتشار خطا با یک لایه مخفی و ۲ نرون در لایه مخفی بوده و قابلیت پیش‌بینی و شبیه‌سازی بار رسوب جریان را با کمترین محدودیت دارا است.

نتایج حاصل از مدل‌سازی بار رسوب در مطالعه حاضر علاوه بر این که تاییدی بر نتایج تحقیقات پیشین که در بخش مروری بر مطالعات قبلی در قسمت مقدمه ارائه گردیده، است، منجر به توسعه و بهبود مدل‌سازی بار رسوب با استفاده از پارامترهای ژئومورفولوژی حوضه گردیده است. بنابراین استفاده از خصوصیات ژئومورفولوژی حوضه در مدل‌سازی

- landscape structure on soil erosion by water and tillage. *Landscape Ecology* 15, 577–589.
- Verstraeten, G., Poesen, J., de Vente, J. and Koninckx, X., (2003). Sediment yield variability in Spain: a quantitative and semi qualitative analysis using reservoir sedimentation rates. *Geomorphology* 50, 327–348.
- Yang, C.T. (1996). *Sediment transport: theory and practice*. 1st edition New York. McGraw-hill.
- Yitian, L. and GU, R.R., (2003). Modeling flow and sediment transport in a river system using an artificial neural network. *Environmental Management* 31 (1), 122–134.
- Youssef vand, .F.Ghelmaei, S.H.Ghamar nia, H. and Zia tabar ahmadi, M.K. (2005). The effect of time measuring classification of suspended sediment of rivers (text in Persian). 5th Hydraulic conference, Kerman. Iran.
- Zhang, B. and Govindaraju, R.S., (2003). Geomorphology-based artificial neural networks (GANNs) for estimation of direct runoff over watersheds. *Journal of Hydrology*. 273, 18–34.
- Zhou, G., Goel, N.K., Bhatt, V.K., (2002). Stochastic modeling of the sediment flux of the Upper Yangtze River (China). *Hydrological Sciences Journal* 47, 93–105.
- 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.
- Hosseini, S.M., Mirsalehi, M.M. and Saghi, H. (2002). Application of an artificial neural network in lumped flood routing (text in Persian). *Engineering college journal, Ferdowsi Mashad*. 2:141–157.
- Kisi, O., (2004). Multi-layer perceptions with Levenberg–Marquardt training algorithm for suspended sediment concentration prediction and estimation. *Hydrological Sciences Journal* 49, 1025–1040.
- Mousavi, S.F. Haidarpour, M. and Sabanlou.s. (2006). Investigation of sediment in the Zayandehroud reservoir through area increment and area reduction empirical models (text in Persian). *Journal of Water & Wastewater*, 57:76–82.
- Ramesht, M.H. (2005). Symbols and images in geomorphology (text in Persian). SAMT publication. 190p.
- Ripley, B.D. (1996). Neural networks and related methods of classification. *J. of Royal statistical society*, 56(3), 409–456.
- Sarangi, A. and Bhattacharya, A.K., (2005). Comparison of artificial neural network and regression models for sediment loss prediction from Banha Watershed in India. *J. Agricultural water management*. 78, 195–208.
- Sivakumar, B., Jayavardena, A.W. and Fernando, T.M.K.G. (2002). River flow forecasting: use of phase-space reconstruction and artificial neural networks approaches. *J. Hydro*. 265, 225–245.
- Slaymaker, O., (2000). *Global environmental change: the global agenda in geomorphology, human activity and global environmental change*. John Wiley Sons, Ltd. 322p.
- Van Oost, K., Govers, G. and Desmet, P., (2000). Evaluating the effects of changes in

An assessment of the Artificial Neural Networks technique to geomorphologic modeling sediment yield (Case study Samandegan river system)

A.A. Vali. M.H. Ramesht. A. Seif. R. Ghazavi

Received: June 8, 2010/ Accepted: December 14, 2010, 5-9 P

Extended Abstract

1- Introduction

Estimating correct volume of sediment in a fluvial system is one of the most important issues in water engineering, river engineering, water resources, facilities, structures, water and environmental projects and programs for the development of them.

The bed load transfers by saltation and suspension forms according to the sediment particle size. The sediment load is one of the most important parameters of hydraulic projects, a useful indicator of soil erosion, and watershed's ecological environment. Several physical experimental methods for estimating the sediment in a watershed has been developed.

Experimental methods are based on estimated sedimentation basin characteristics such as area topography, land cover, climate and the qualitative characteristics of the firm (Zhou et al.2002). Those can estimate indirectly sedimentation rates in the Delta or the Vessels (Verstraeten et al, 2004). These methods due to the simple structure, simple mathematical calculations and are able to work in a widely input data (Zhou et al.2007). However, linear or nonlinear regression model can use for suspended sediment load with relative accuracy of computational models which provide simple experimental models.

In recent years has occurred a great interest to investigate the possibility of using artificial neural network systems. Neural networks are powerful computational tool in organizing and establishing the relationship between the various intelligence capabilities. The use of the mapping capabilities of these systems in a multi-dimensional spaces and the analysis of the issues without resorting to the relations sophisticated mathematical difficulty can be useful in engineering. Artificial neural networks

Author (s)

A.A. Vali (✉)

Assistante Professor of Geomorphology, University of Kashan, Kashan, Iran
e-mail: vali@kashanu.ac.ir

M.H. Ramesht.

Professor of Geomorphology, University of Isfahan, Isfahan, Iran

A. Seif.

Assistante Professor of Geomorphology, University of Isfahan, Isfahan, Iran

R. Ghazavi

Assistante Professor of Water Resources, University of Kashan, Kashan, Iran

have been successful in dealing with issues such as system identification, function approximation, optimization and anticipating the results. Artificial neural network system based on data flexibility with different weights to the establishment of neural connections during the learning process is able to recognize complex and ambiguous issues especially those that are not easily expressed in mathematical relationships.

A river system is an open system where the involvement of sophisticated forms of communication. The inherent characteristics of a basin and external factors affect the behavior of the river. The existence of multiple interactions, including the interaction moves and transported sediment and geomorphology of the basin parameters is important.

Watershed is the most essential natural scale regional units. An independent identity has defined the concept of river basin as a spatial unit has an effective role in the classification of human activities (Ramsht 2005). The purpose of this study was to develop modeling using artificial neural network approach to geomorphic agents and compare its performance with multiple regression methods. To the extent predicted by the models of sediment basin Comparison of the calculated values with observed values is explained by its comparative advantage.

2- Methodology

First, for removing diagnostics data calculate the residual R student index by using SAS software. Then were evaluated training data set and testing data set from wholly of data. The Statistical Modeling and Artificial Neural Networks are helping with SPSS software. Statistical methods used and designed to model both simple and multiple regression analysis. In simple regression best fit of the

relationship between flow and sediment is taken of the relationship linear, inverse, exponential, logarithmic, quadratic, and the power basis of degree decision. This method measures the curve of known deposits or SRC.

This method is called MARS for short to multivariate adaptive regression spline. In the flow vector the power supply to the large number of independent variables into the geomorphological parameters using stepwise multiple regression analysis method to determine the model parameters have to be removed excluded variable or ineffective variable. So a geomorphological multivariate model is designed. In other words, each of the parameters in the geomorphology of the basin as a data point are being integrated with vector data such as statistics in a flood of new data are converted into a vector and new vectors is obtained base on multiple regression fit.

Artificial neural network model is used by utility neural network option of SPSS software. Neural network designed in this study were divided into two types depending on the input data. The first type of artificial neural networks designed using the instantaneous flow and sediment. Instantaneous flow in the network as the input and output system is designed as a moment of deposition. NGANN geomorphology of this network is called neural network for short. The second type of artificial neural networks designed using the elements used in the method of feeding is in March and the geomorphic parameters of this network is called for short GANN.

3- Discussion

Two statistics factor to evaluate the performance are RMSE (root mean square of error) and R square (determination index) of different models

is possible. These factors can determine the value of the preferred models to the observed values and the predicted values. Notice to RMSE values and the R square shows relative advantage of models. The highest significant determination index, and the lowest error, is introduced the best method. To the value of the preferred methods, is determined respectively GANN, NGANN, MARS and SRC rate determination coefficients with 0.86, 0.83, 0.81, 0.76 and values of the error estimate 1.815, 2.031, 2.142 and 2.359.

Results showed the GANN estimated better with highest coefficient of determination (R²) of 0.862 and root mean square of error (RMSE) of 1.815 in comparison to NGANN with 0.827 for R² and 2.031 for RMSE. performance value of regression models were weaker than ANN models with R² of 0.759 and RMSE of 2.395 for SRC model And R² of 0.811 and RMSE of 2.142 for MARS model. Therefore it was revealed not only ANN models but also regression models have performance value when combine with geomorphologic parameters.

4- Discussion

Comparison of statistical methods and neural network models shows neural network significant preference values in the estimation of daily moment sediment estimation. The difference between the performance of artificial neural and statistical methods can be defied with the ability to estimate and predict artificial neural networks for non-linear approximation with a low volume of data. However, the performance and accuracy of the regression methods follow of sample size and it challenge of statistical models. The artificial neural network models design by the low number of samples. Conclusion presented and ANN model by geomorphology parameters

designed to help the River Basin behavior. It is worthy of the network with back propagation algorithm learning with one hidden layer and 2 neurons in the hidden layer with high ability to flow and sediment load simulation is running with minimal restrictions.

The results of the modeling of sediment load in the present study also confirmed that the results of previous studies in the review of previous studies presented in the introduction. To develop and improve deposition load modeling is necessary applying geomorphologic parameters of basin. The geomorphological characteristics of the basin are an essential element of effective and recommended for hydrological modeling.

Key word: Artificial neural network, flow, geomorphology, modeling, prediction, regression, Samandegan, sediment yield.

References

- Agarwal, A., Mishra, S.K., Sobha R and Singh J. K., (2006). Simulation of runoff and sediment yield using artificial neural networks. *J. Biosystems engineering* 94, 597–613.
- Alp, M. and Cigizoglu, H.K., (2007). Suspended sediment load simulation by two artificial neural network methods using hydro meteorological data. *Environmental modeling and software*. 22:2-13.
- Bhattacharya, B., Price, R.K. and Solomatine, D.P., (2005). Data-driven modeling in the context of sediment transport. *Physics and Chemistry of the Earth* 30, 297–302.
- Cigizoglu, H.K., (2004). Estimation and forecasting of daily suspended sediment data by multi layer perceptrons. *Advances in Water Resources* 27, 185–195.

- Cigizoglu, H.K. and Alp, M., (2006). Generalized regression neural network in modeling river sediment yield. *J. Advance in engineering software*. 37:63-68.
- Cigizoglu, H.K. and Kisi, O., (2006). Methods to improve the neural network performance in suspended sediment estimation. *Journal of Hydrology*. 317:221-238.
- Dastorani, M.T., Wright, N.G. (2004). Combination of Artificial Neural Networks and Hydrodynamic Models for More Precise Prediction of River Flow (Text in Persian), *Journal of Water & Wastewater*, 49:1-13.
- Flood, I. and Kartman, N. (1996). Neural network in civil engineering: principles and understanding. *J. of computing in civil engineering*, 8(2). 131-148.
- Hakim khany, sh. and Arab khedri. (2006). suspended sediment and hydro-geomorphology parameters with regression analysis case study Oroumiyeh basin (text in Persian). *Iranian agricultural science journal*: 223-231.
- Hooke, J.M., (2007). Complexity, self-organization and variation in behavior in meandering rivers. *Journal of Geomorphology* 91: 236–258.
- Hosseini, S.M., Mirsalehi, M.M. and Saghi, H. (2002). Application of an artificial neural network in lumped flood routing (text in Persian). *Engineering college journal, Ferdowsi Mashad*. 2: 141-157.
- Kisi, O., (2004). Multi-layer perceptions with Levenberg–Marquardt training algorithm for suspended sediment concentration prediction and estimation. *Hydrological Sciences Journal* 49, 1025–1040.
- Mousavi, S.F., Haidarpour, M. and Sabanlou, S. (2006). Investigation of sediment in the Zayandehroud reservoir through area increment and area reduction empirical models (text in Persian). *Journal of Water & Wastewater*, 57:76-82.
- Ramesht, M.H. (2005). Symbols and images in geomorphology (text in Persian). SAMT publication. 190p.
- Ripley, B.D. (1996). Neural networks and related methods of classification. *J. of Royal statistical society*, 56(3), 409-456.
- Sarangi, A. and Bhattacharya, A.K., (2005). Comparison of artificial neural network and regression models for sediment loss prediction from Banha Watershed in India. *J. Agricultural water management*. 78, 195–208.
- Sivakumar, B., Jayavardena, A.W. and Fernando, T.M.K.G. (2002). River flow forecasting: use of phase-space reconstruction and artificial neural networks approaches. *J. Hydro.*, 265, 225-245.
- Slaymaker, O., (2000). Global environmental change: the global agenda in geomorphology, human activity and global environmental change. John Wiley Sons, Ltd. 322p.
- Van Oost, K., Govers, G. and Desmet, P., (2000). Evaluating the effects of changes in landscape structure on soil erosion by water and tillage. *Landscape Ecology* 15, 577–589.
- Verstraeten, G., Poesen, J., de Vente, J. and Koninckx, X., (2003). Sediment yield variability in Spain: a quantitative and semi qualitative analysis using reservoir sedimentation rates. *Geomorphology* 50, 327–348.
- Yang, C.T. (1996). *Sediment transport: theory and practice*. 1st edition New York. McGraw-hill.
- Yitian, L. and GU, R.R., (2003). Modeling flow and sediment transport in a river system using an artificial neural

- network. *Environmental Management* 31 (1), 122-134.
- Youssef vand, .F.Ghelmaei,S.H.Ghamarnia,H.and Zia tabar ahmadi,M.K. (2005).The effect of time measuring classification of suspended sediment of rivers(text in Persian).5th Hydraulic conference,Kerman. Iran.
- Zhang, B.and Govindaraju, R.S., (2003). Geomorphology-based artificial neural networks (GANNs) for estimation of direct runoff over watersheds. *Journal of Hydrology*.273,18-34.
- Zhou, G., Goel, N.K., Bhatt, V.K., (2002). Stochastic modeling of the sediment flux of the Upper Yangtze River (China). *Hydrological Sciences Journal* 47, 93–105.
- 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.