

ارزیابی برآورد رسوب با استفاده از روش‌های منحنی سنج و شبکه عصبی با تلفیق پارامترهای مورفولوژیکی حوزه (مطالعه موردی حوزه باغ عباس)

مهدی حیات زاده^{*}، جواد چزگی^۱ و محمدتقی دستورانی^۲

(تاریخ دریافت: ۱۳۹۲/۹/۳؛ تاریخ پذیرش: ۱۳۹۳/۱۲/۲۰)

چکیده

از آنجا که توسعه برنامه‌های مهار آب‌های سطحی ملزم به دستیابی دقیق رفتارهای جریان و میزان رسوبات آن می‌باشد لذا کمبود ایستگاه‌های اندازه‌گیری رسوب و فقدان آمار کامل رسوب، از جمله دلایل ارزیابی صحیح در شبیه‌سازی رفتار جریان‌ها و رسوبات آنهاست. از جمله مواردی که در یک حوزه آبخیز از هم تأثیر می‌پذیرند خصوصیات مورفولوژیکی حوزه و بار رسوبی جریان‌های آن می‌باشد. لذا آگاهی از میزان این ارتباط به منظور مدیریت و ساماندهی جریان در پایین‌دست حوزه حائز اهمیت می‌باشد. در تحقیق حاضر با استفاده از شبکه عصبی مصنوعی و روش‌های رگرسیونی سنج رسوب براساس داده‌های ۱۳۶ واقعه دبی جریان و رسوب متناظر آن و همچنین پارامترهای مورفولوژیکی به پیش‌بینی بار رسوبی حوزه باغ عباس اقدام گردیده است. بدین منظور در گام نخست برای پیش‌بینی بار رسوب از دو روش مذکور، فقط از داده‌های جریان استفاده گردیده و در گام بعدی خصوصیات مورفولوژیکی حوزه از قبیل ضریب شکل و ضریب فشردگی حوزه به مدل‌ها اضافه شده است. نتایج به دست آمده از این تحقیق نشان می‌دهد که با به کارگیری شبکه عصبی از نوع پرسپترون چندلایه (MLP) با الگوریتم لونیگ-مارکوارت و تابع تحریک از نوع تانژانت سیگموئید با دو لایه مخفی و ۴ نرون در هر لایه، می‌توان با دقت مناسبی میزان دبی بار معلق رسوب را برآورد نمود. همچنین دقت نتایج به دست آمده از روش شبکه عصبی مصنوعی به مراتب از دقت روش منحنی سنج بالاتر می‌باشد. در ارزیابی روش‌های شبکه NGANN, GANN و رگرسیونی SRC, MARS، به ترتیب میزان ضریب همبستگی ۰/۹۴، ۰/۹۳، ۰/۷۶۷ و ۰/۷۶۶ و مجذور میانگین مربعات خطا (RMSE) به ترتیب ۰/۴۵، ۰/۴۹، ۲/۳ و ۲/۳ و ضریب نش-ساتکلیف (NS) به ترتیب ۰/۷۱، ۰/۵۸، ۰/۲۷ و ۰/۲۳ محاسبه گردید. بنابراین کاراترین روش از بین مدل‌های چهارگانه مذکور، شبکه عصبی مصنوعی همراه با داده‌های مورفولوژیکی حوزه (GANN) می‌باشد. ضمناً براساس یافته‌های تحقیق اضافه نمودن پارامترهای ژئومورفولوژیکی در روش سنج رسوب تأثیر چندانی بر روی کارایی این مدل ندارد.

واژه‌های کلیدی: شبکه عصبی مصنوعی (ANN)، منحنی سنج رسوب، روش مارس (MARS)، حوزه باغ عباس

۱. گروه آبخیزداری، دانشکده منابع طبیعی و کویرشناسی، دانشگاه یزد

۲. گروه آبخیزداری، دانشکده منابع طبیعی و محیط زیست، دانشگاه فردوسی مشهد

*: مسئول مکاتبات، پست الکترونیکی: mhayat zadeh@gmail.com

مقدمه

فرسایش و رسوب گذاری یک رفتار مخرب در مراتع، اراضی کشاورزی و رودخانه ها است که منجر به از دست رفتن خاک حاصلخیز کشاورزی به صورت کاهش توان تولیدی و تخریب خصوصیات فیزیکی و شیمیایی خاک و اعمال خسارت هنگفت در طرح های منابع آب همچون تخریب و تغییر ابعاد کانال های آبیاری می شود، از سوی دیگر رسوب انتقال یافته توسط یک رودخانه به مخازن، ظرفیت ذخیره آنها را کاهش داده و بر آب قابل استفاده برای نیروگاه های برق، آبیاری و کاربردهای صنعتی و خانگی تأثیرگذار است (۲). انتقال رسوب و رسوب گذاری، پیامدهایی چون ایجاد جزایر رسوبی در مسیر رودخانه و در نتیجه کاهش ظرفیت انتقال جریان های سیلابی، کاهش عمر مفید سدها و ظرفیت ذخیره مخازن، خوردگی تأسیسات سازه های رودخانه ای و وارد شدن خسارات به ابنیه آبی و مزارع، رسوب گذاری در کف کانال و بسیاری مسائل و مشکلات دیگر را در بر دارد. همچنین با توجه به اصول برداشت مصالح رودخانه ای و لزوم اطلاع از میزان رسوبات حمل شده توسط جریان رودخانه در طراحی سازه های رودخانه ای، ضرورت بررسی و مطالعه روش های مختلف برآورد بار رسوب رودخانه ها به روشنی تبیین می شود (۶). با توجه به اهمیت و حساسیت امر مهار آب های سطحی خصوصاً در کشور ما که اکثر رودخانه های مناطق مختلف، فصلی بوده و کمبود آبی که در پهنه وسیعی از کشور وجود دارد، مدل سازی رفتار رودها برای برنامه ریزی های بلندمدت و استفاده بیشتر و بهتر از پتانسیل آنها ضروری است. بنابراین لازمه توسعه برنامه های مهار آب های سطحی دستیابی دقیق به رفتارهای جریان و میزان رسوبات آن است. کمبود ایستگاه های اندازه گیری رسوب، جدید بودن بیشتر ایستگاه ها، قرار گرفتن بیشتر رودها در مناطق خشک، وضعیت بحرانی برداشت آب های زیر زمینی دلایل اهمیت و ضرورت ارزیابی صحیح در خصوص برآورد، پیش بینی و شبیه سازی رفتار جریان ها و رسوبات آنهاست (۱۱). همواره آنالیز سری های زمانی روی بار معلق رسوب برای یک ایستگاه با ترسیم منحنی بار معلق-دبی جریان صورت می گیرد، ولی مطالعات اخیر حاکی از آن است

که شبکه عصبی مصنوعی (Artificial neural network) ابزاری قدرتمند و دقیق در مورد مسائل غیرخطی و پیچیده از جمله پدیده رسوب می باشد و در اکثر موارد جواب های منطقی و قابل اعتمادی نسبت به منحنی سنج رسوب (Sediment rating curve) ارائه می دهد (۷). کاربرد شبکه های عصبی مصنوعی اولین بار توسط فرنچ در سال ۱۹۹۲ در بحث های مربوط به منابع آب بیان گردید و از آن پس به طور چشمگیری در این زمینه از آن استفاده می شود (۱۷). در سال های اخیر تمایل زیادی نسبت به بررسی امکان استفاده از سیستم های شبکه های عصبی مصنوعی به وجود آمده است. سیستم شبکه های عصبی مصنوعی با تکیه بر داده ها و قابلیت انعطاف پذیری بالا با برقراری اوزان مختلف به ارتباطات عصبی در جریان فرآیند یادگیری قادر است جوابگوی مسائل مبهم و پیچیده باشد (۱۲). به خصوص مسائلی که به سادگی با روابط ریاضی قابل بیان نیستند. به طور کلی امروزه از جمله روش های کارآمد که استفاده فراوانی در علوم مربوط به هوا و آب دارد، شبکه عصبی مصنوعی (ANN) است که به عقیده محققان امر، علت اصلی مقبولیت و استفاده روزافزون آن، قدرت و سرعت بالا در شبیه سازی فرآیندهایی است که درک و شناخت درستی از آن وجود نداشته و یا بررسی آنها با دیگر روش های موجود، بسیار دشوار و وقت گیر است. می توان اظهار داشت، مدل شبکه عصبی مصنوعی، مدلی قوی با توانمندی بالاست که می توان با دیدگاهی مثبت در پیش بینی مسائل اقلیمی هیدرولوژیک به آن نگریت به خصوص آنجا که این شبکه، قادر است قانون حاکم بر داده ها، حتی داده های مغشوش را استخراج نماید و در ضمن نیازی به توضیح صریح طبیعت فرآیندها به صورت ریاضی دارد (۵).

پیشینه تحقیق

با گسترش روزافزون کاربرد مدل های رایانه ای در سال های اخیر، استفاده از مدل های ضمنی متکی بر شبکه های عصبی مصنوعی، به طور گسترده ای در مطالعات مربوط به پیش بینی پارامترهای مختلف منابع آب مورد استفاده قرار گرفته و محققان

واقعی به‌دست آمده از فلولم و عرصه را مورد بررسی قرار داده و کارایی مطلوب‌تر شبکه‌ها را از روش‌های رایج برآورد رسوب به کمک فلولم و روش‌های برآورد از عرصه، گزارش نمودند.

سگیز ولا و آلپ (۱۶) با به‌کارگیری دو الگوریتم آموزش برای رسوب حوزه آبریز جانیاتا (FFBP Feed forward back propagation) و (GRNN Generalized regression neural networks) در آمریکا و مقایسه نتایج به‌دست آمده با روش‌های متداول منحنی سنج رسوب و رگرسیون خطی چند متغیره دریافتند که به‌کارگیری شبکه‌های عصبی مصنوعی در زمینه رسوب کاملاً بر روش‌های مذکور برتری دارد. ژو و همکاران (۲۱) با استفاده از مدل‌های شبکه عصبی مصنوعی رسوبات معلق ماهانه را در رودخانه لانگ شوان چیان واقع در حوزه بالادست رودخانه یانگ تسه در چین مدل‌سازی نمودند و نشان دادند هنگامی که متغیرهای ورودی و تأثیر تأخیر (Lag) زمانی آنها به‌طور صحیح به‌عنوان متغیرهای ورودی وارد مدل شوند، ANN دقت نسبتاً بالاتری را در مقایسه با روش‌های رگرسیونی چندمتغیره داشته و نیز این روش مقادیر دبی حد (حداکثر و حداقل) را نزدیک‌تر به واقعیت برآورد می‌کند.

نتایج تخمین بار رسوبی رودخانه گرگانرود توسط مساعدی و همکاران (۹) نشان دادند که خطای مدل‌های شبکه عصبی مصنوعی به‌طور متوسط نصف خطای مدل‌های منحنی سنج رسوب می‌باشد. نجفی و همکاران (۱۰) با تخمین و مقایسه بار رسوب معلق رودخانه زاینده‌رود با استفاده از مدل شبکه عصبی (Multi-layer Perceptron) MLP و روش‌های GRNN و رگرسیون آماری نشان دادند که نتایج حاصل از مدل MLP در مقایسه با این روش‌ها، تطابق بیشتری با مقادیر اندازه‌گیری شده دارد. فیض‌نیا و همکاران (۸) با برآورد بار معلق روزانه در حوزه آبخیز زرد رامهرمز خوزستان با استفاده از روش‌های شبکه عصبی و رگرسیون نشان دادند که مدل شبکه عصبی دقت بالاتری را در برآورد بار معلق روزانه دارد.

العلمی و همکاران (۱) از شبکه‌های عصبی مصنوعی جهت مدل‌سازی چند ایستگاه بارمعلق رسوب ایستگاه آخولا بر روی

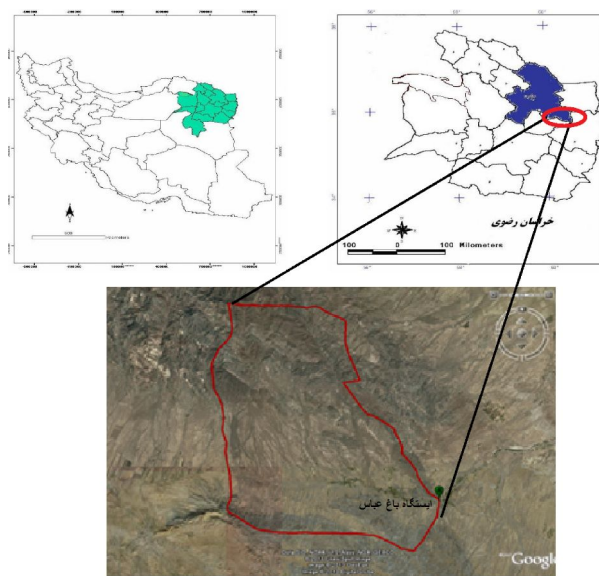
مختلف بر دقت بالای این روش در مقایسه با روابط تجربی و رگرسیونی تأکید نموده‌اند (۱۵، ۱۹). می‌دانیم که با استفاده از داده‌های اندازه‌گیری شده بار معلق رسوب و به کمک معادله سنج رسوب می‌توان مقدار رسوب انتقالی را برآورد کرد. از آنجایی که استفاده از روش‌های معادله سنج رسوب همواره با خطای زیادی همراه است. بنابراین لزوم استفاده از روشی هوشمند مانند شبکه عصبی مصنوعی در برآورد مقدار بار معلق احساس می‌شود (۱).

به‌طورکلی روش‌های برآورد بار معلق رودخانه‌ها را می‌توان به دو دسته تقسیم نمود. روش‌های مبتنی بر قوانین دینامیک و مکانیک سیالات که اغلب توسط متخصصان علم هیدرولیک ارائه و به روش‌های هیدرولیکی برآورد بار معلق شهرت یافته‌اند و روش‌های مبتنی بر اندازه‌گیری مستقیم و تحلیل‌های آماری که بیشتر توسط صاحب‌نظران علم هیدرولوژی توصیه و تحت عنوان روش‌های هیدرولوژیکی برآورد بار معلق نامیده می‌شوند (۳).

در این زمینه سیگیزولا (۱۴) اقدام به برآورد بار معلق در رودخانه‌ای در انگلستان با استفاده از روش ANN و منحنی سنج رسوب نمود. نتایج او نشان داد که مدل شبکه‌های عصبی مصنوعی قادر به ارائه اطلاعاتی حتی در مورد ساختار وقایع همچون پدیده پسماند در رابطه دبی و رسوب تحت تأثیر شرایط پیشین است.

گوین داراجو و زانگ (۱۸) با طراحی یک شبکه عصبی سه لایه براساس خصوصیات فیزیوگرافی دو حوزه در هند هیدروگراف واحد جریان را شبیه‌سازی نمودند و ضریب تشخیص بالاتر این روش را عامل برتری آن نسبت به روش معمول محاسبه ابعاد هیدروگراف برشمردند و ضمن معرفی روش شبکه عصبی مصنوعی به‌عنوان روش مطلوب به ویژگی‌های آن از جمله قابلیت به‌کارگیری داده‌های ژئومورفولوژیکی حوزه در برآورد جریان مستقیم آن اشاره نمودند.

باتاچاریا و همکاران (۱۳) مدل‌سازی رسوب منتقل شده توسط جریان با استفاده از شبکه‌های عصبی مصنوعی و مقادیر



شکل ۱. موقعیت حوزه آبخیز رودخانه فریمان و ایستگاه سنجش دبی و رسوب باغ عباس

رضوی از شمال شرق به شهر فریمان (حدود ۱۵ کیلومتری) متصل می‌گردد. ارتفاع متوسط حوزه ۱۹۹۳/۹۶ متر با شیب متوسط ۱۶/۹۲ و طول آبراهه اصلی ۲۳/۵۵ کیلومتر می‌باشد. در شکل ۱ موقعیت حوزه مورد مطالعه در منطقه نشان داده شده است.

در این تحقیق از آمار پارامترهای ۱۳۶ حادثه سیلاب ثبت شده ۴۰ ساله مربوط به دوره آماری سال ۱۳۴۶ تا ۱۳۸۶، استفاده شده است. این پارامترها شامل دبی لحظه‌ای روزانه به مترمکعب بر ثانیه و رسوب روزانه متناظر به تن در روز می‌باشد. خصوصیات طبیعی حوزه به کمک نرم افزار Arc Gis و پارامترهای ژئومورفولوژیکی حوزه با استفاده از خصوصیات طبیعی حوزه براساس دستورالعمل سینگ و همکاران (۲۰) محاسبه گردیده است. عوامل طبیعی و پارامترهای ژئومورفولوژیکی حوزه در جدول ۱ ارائه شده است. در این تحقیق ضریب شکل حوزه و ضریب فشردگی از جمله پارامترهایی هستند که به عنوان ورودی به شبکه اعمال گردیدند.

روش تحقیق

ابتدا آزمون حذف داده‌های پرت به کمک محاسبه شاخص

رودخانه آجی‌چای استان آذربایجان شرقی استفاده نمودند. مقایسه نتایج شبکه عصبی مصنوعی با منحنی سنج رسوب نشان می‌دهد که شبکه‌های عصبی مصنوعی کارایی بهتری در تخمین پدیده رسوب ایستگاه آخولا نسبت به روش‌های دیگر دارد که دال بر توانایی شبکه عصبی مصنوعی در مدل‌سازی پدیده‌های خطی از جمله مسأله رسوب است. هدف از این پژوهش توسعه مدل‌سازی با بهره‌گیری از روش شبکه‌های عصبی مصنوعی به کمک عوامل ژئومورفیک و غیرژئومورفیک و مقایسه عملکرد آنها با روش‌های رگرسیونی و منحنی سنج رسوب، در حوزه رودخانه‌ای مورد مطالعه است. تا ضمن پیش‌بینی میزان رسوب حوزه توسط مدل‌ها و مقایسه مقادیر محاسبه شده با مقادیر مشاهده شده مزیت نسبی آنها تبیین گردد.

مواد و روش‌ها

مشخصات و موقعیت منطقه مورد مطالعه

ایستگاه باغ عباس با حوزه آبریز رودخانه فریمان دارای وسعتی معادل ۲۸۱/۱۲ کیلومترمربع در محدوده عرض شمالی ۳۵°۳۳'۰۱" تا ۳۵°۴۱'۱۰" و محدوده طول شرقی ۵۹°۳۴'۵۴" تا ۵۹°۴۴'۱۱" گسترده شده است. این منطقه در استان خراسان

جدول ۱. پارامترهای ژئومورفولوژیکی حوزه آبخیز باغ عباس

ردیف	پارامتر	واحد	مقدار
۱	ضریب شکل FF	بدون بعد	۰/۵
۲	معکوس ضریب شکل NB	بدون بعد	۱/۹۷
۳	ضریب فشردگی GF	بدون بعد	۱/۴۸
۴	طول مستطیل معادل	بدون بعد	۳۶۷۹۰/۵۱
۵	عرض مستطیل معادل	بدون بعد	۷۶۴۱/۱۱
۶	زمان تمرکز (کریچ)	ساعت	۲/۶
۷	زمان تمرکز (ویلیامز)	ساعت	۶/۱۴

لحظه‌ای و S میزان بار رسوب می‌باشد.


در این روش بردار دبی با استفاده از به توان‌رسانی پارامترهای ژئومورفولوژی به تعدادی متغیر مستقل تبدیل شده سپس با استفاده از آنالیز رگرسیون چندمتغیره به کمک روش متوالی (Enter) پارامترهای مدل تعیین شده است. بنابراین یک مدل مناسب چندمتغیره ژئومورفولوژیکی طراحی می‌شود. به عبارت دیگر در این روش هریک از پارامترهای ژئومورفولوژی حوزه که به صورت یک داده نقطه‌ای 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 چندگانه قرار گرفته و مدل مناسب حاصل می‌شود.

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 لحظه‌ای است. در این نوع شبکه دبی لحظه‌ای به عنوان عناصر ورودی و میزان رسوب لحظه‌ای به عنوان خروجی سیستم طراحی شده است. این شبکه به اختصار شبکه عصبی غیر ژئومورفولوژی (NGANN Non Geomorphologic Artificial Neural Network) 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 تأثیر پارامترهای ژئومورفیک این شبکه به اختصار (Geomorphologic Artificial Neural Network) GANN

باقی‌مانده استیودنت (R student) در نرم افزار SPSS انجام گرفت که در نتیجه آن دو داده پرت شناسایی و حذف گردید. جهت نرمال‌سازی داده‌ها از روش لگاریتم‌گیری داده‌ها استفاده گردید. سپس مجموعه داده‌ها به دو گروه آموزش و آزمون تقسیم شدند. ۷۰ درصد داده‌ها برای آموزش (Training data) یا واسنجی و ۳۰ درصد داده‌ها برای صحت سنجی (Testing data) یا آزمون مدل‌ها اختصاص یافت. مرحله بعد شامل مدل‌سازی به کمک داده‌های آموزش است که پس از طراحی مدل‌ها با داده‌های آزمون و کل داده‌ها مدل‌ها مورد ارزیابی قرار گرفت.

مدل‌های آماری طراحی شده به دو شیوه الف- رگرسیون ساده که به روش منحنی سنج رسوب Sediment Rating Curves (SRC) معروف است. ب- مدل آماری در نتیجه تأثیر پارامترهای ژئومورفولوژی بر روی دبی لحظه‌ای طراحی گردیده است و ارتباط غیرخطی بین این متغیرهای مستقل با رسوب لحظه‌ای محاسبه و با استفاده از آنالیز رگرسیون از بین پارامترهای به کار گرفته شده، پارامترهای تأثیرگذار انتخاب شده است. این روش به اختصار به روش مارس Multivariate Adaptive Regression Spline (MARS) معروف است.

[۱]
$$s = aR^{\sqrt{Ff}} + bR^{\sqrt{Df}} + cR^{\sqrt{Rf}} + d$$
 ضرایب معادله. Ff, Rf, Df به ترتیب ضریب شکل حوزه، تراکم زهکشی و ضریب ناهمواری، R میزان رواناب



شکل ۲. شبکه عصبی پرسپترون چند لایه (MLP)

و توسعه شبکه عصبی مصنوعی تجربیات موفق قبلی می تواند مفید واقع شود. در این تحقیق از شبکه های عصبی پرسپترون چند لایه (MLP) استفاده شده است و تعداد لایه های مخفی و تعداد نرون های لایه های مخفی به روش آزمون و خطا و مقایسه عملکرد خطای آنها انتخاب شده اند. شکل ۲ برای ارزیابی نتایج عملکرد مدل های طراحی شده از مجذور میانگین مربعات خطا (RMSE) و ضریب تبیین (R^2) و ضریب نش-ساتکلیف (NS) بین بردار مشاهده شده و بردار پیش بینی شده بهره گیری شده است.

$$R^2 = 1 - \frac{\sum (y_o - y_f)^2}{\sum y_o^2 - \frac{(\sum y_f)^2}{n}} \quad [2]$$

$$RMSE = \sqrt{\frac{\sum_{j=0}^p \sum_{i=0}^n (y_o - y_f)^2}{NP}} \quad [3]$$

در روابط (۲ و ۳) y_o : مقادیر مشاهده شده y_f مقادیر پیش بینی شده P : تعداد متغیرهای خروجی و n : تعداد داده ها می باشد. ضریب نش-ساتکلیف (NS) اختلاف نسبی مقادیر مشاهده های و شبیه سازی شده را نشان می دهد و مقدار این فاکتور بین یک تا منفی بی نهایت تغییر می کند. مقدار بیشتر ۰/۵۰ از این فاکتور نشان دهنده شبیه سازی خوب توسط مدل است فرمول آن عبارت است از:

$$NS = 1 - \frac{\sum_{i=1}^n (Q_{obs} - Q_{sim})_i^2}{\sum_{i=1}^n (Q_{obs,i} - \overline{Q_{obs}})^2} \quad [4]$$

که در آن Q_{obs} مقادیر اندازه گیری شده رسوب، Q_{sim} مقادیر

نامیده شده است.

هریک از انواع مختلف شبکه های عصبی در زمینه ای به خصوص، قابلیت بهتری نسبت به سایر انواع دیگر دارند لیکن برای عمل تقریب تابع، شبکه های عصبی چند لایه مناسب ترین می باشند. ساختار شبکه عصبی، ورودی های اعمال شده، تعداد لایه های مخفی، تعداد نرون های لایه ها، نحوه آموزش و تعداد بردارهای خروجی هر شبکه در ارزیابی عملکرد مدل مؤثر است. ترکیب های گوناگون در پارامترهای ورودی و تعداد لایه های مخفی برای رسیدن به یک خروجی مطلوب معماری شبکه قلمداد می شود. در این شبکه ها ورودی مؤثر هر نرون، حاصل ضرب خروجی نرون های لایه قبل در وزن های میان آن نرون ها است.

نرون های لایه اول اطلاعات را گرفته و از طریق اتصالات مربوطه به نرون های لایه مخفی منتقل می کنند. در لایه مخفی پس از محاسبه ورودی مؤثر هر نرون، این ورودی از یک تابع محرک گذرانده می شود. برای این کار توابع مختلفی ارائه شده است که گرایش بیشتر محققان به استفاده از توابع محرک کران دار می باشد که مشهورترین آنها تابع سیگموئید است.

در شبکه های از نوع انتشار برگشتی قاعده مشخصی برای انتخاب لایه های پنهان و همچنین تعداد نرون ها در لایه پنهان وجود ندارد. در حقیقت انتخاب تعداد نرون ها در لایه پنهان و همچنین تعداد لایه های پنهان با توجه به نوع مساله تغییر می کند. در حل مسائل هیدرولوژی، با توجه به تغییرات شدید داده ها، اغتشاش حاکم بر داده ها استفاده از شبکه های از نوع پس انتشار خطا به دلیل قابلیت انعطاف پذیری بالا با معماری منطبق بر تجربه و آزمون و خطا استفاده می شود. با توجه به عدم وجود ثبات در ایجاد

جدول ۲. پارامترهای آزمون ANOVA در روش SRC

Model	Sum of Squares	df	Mean Square	F	Sig.	Model
Regression	۳۹۶۴۷۸۴/۲	۱	۳۹۶۴۷۸۴/۲	۱۹۱/۷	۰/۰۰۰ ^a	
Residual	۲۷۹۱۸۰۳/۲	۱۳۵	۲۰۶۸۰			Enter
Total	۶۷۵۶۵۸۷/۴	۱۳۶				

a. Predictors: (Constant), input_DEBI

جدول ۳. پارامترهای آزمون ANOVA در روش MARS

Model	Sum of Squares	df	Mean Square	F	Sig.	Model
Regression	۳۹۷۱۲۳۹/۵	۲	۱۹۸۵۶۱۹/۸	۹۵/۵	۰/۰۰۰ ^a	
Residual	۲۷۸۵۳۴۷/۹	۱۳۴	۲۰۷۸۶/۲			Enter
Total	۶۷۵۶۵۸۷/۴	۱۳۶				
Xcc					۰/۲۲۴	
Xcs					۰/۰۱۶	

a. Predictors: (Constant), Q^{cc}, Q^{cs}

شبیه‌سازی شده رسوب، Qobs متوسط مقادیر اندازه‌گیری شده رسوب می‌باشد.

$$y = 126/515x + 3/308 \quad [5]$$

که در رابطه (۵) x دبی جریان بدون پارامترهای مورفولوژیکی و y دبی رسوب می‌باشد.

نتایج آنالیز رگرسیون چندمتغیره MARS ژئومورفولوژیکی و انتخاب مدل مناسب به شرح جدول (۳) است. در این جدول نتایج انتخاب مدل مناسب تبیین شده است. مشخصات ارزشیابی مدل نهایی شده به کمک آماره‌های ضریب همبستگی، ضریب تبیین، مجذور میانگین مربعات خطا و میانگین خطای مطلق گزارش شده است. رابطه (۶) رگرسیون دو متغیره الگو گرفته از معادله مارس در این تحقیق می‌باشد.

$$y = 30/577x_{cc} + 130/871x_{cs} - 8/751 \quad [6]$$

در رابطه (۶) X_{cc} به‌عنوان مقادیر $R^{\sqrt{cc}}$ می‌باشد. R: دبی لحظه‌ای جریان و cc پارامتر ضریب فشردگی حوزه می‌باشد. X_{cs} نیز پارامتر $R^{\sqrt{cs}}$ بوده که R دبی لحظه‌ای جریان و cs نیز ضریب شکل حوزه می‌باشد.

در این تحقیق مدل شبکه عصبی مصنوعی پرسپترون

یافته‌های تحقیق

نتایج آزمون بهترین رابطه برازش در روش SRC (منحنی سنج) با مقایسه ضرایب تبیین و مجذور میانگین مربعات خطا بهترین تابع برازش بین دو متغیر دبی لحظه‌ای و رسوب متناظر از نوع تابع خطی انتخاب شده است. در این تحقیق از آزمون ANOVA به‌عنوان آماره‌ای جهت تعیین معنی‌دار بودن رابطه رگرسیونی انتخاب شده تا در مرحله بعدی در صورت معنی‌دار بودن آزمون (sig کمتر از ۰/۰۵) میزان تأثیر ورودی‌های معادله در میزان رسوب برآوردی تعیین گردد. جداول ۲ و ۳ نتایج آزمون در دو روش SRC و MARS و معنی‌دار بودن هر دو روش در سطح اعتماد ۹۵ درصد نشان می‌دهد. جدول (۳) معنی‌دار بودن پارامتر ضریب شکل حوزه در خروجی رگرسیون را نشان می‌دهد. رابطه سنج SRC در این تحقیق به‌صورت رابطه (۵) می‌باشد.

جدول (۴) نتایج ارزیابی مدل‌های مختلف برآورد رسوب معلق جریان حوزه باغ عباس

MAE	R	R^2	NS	RMSE	Input	Model
۰/۳۸	۰/۹۴	۰/۸۸	۰/۷۱	۰/۴۵۱	R^{sc}, R^{cc}	GANN
۰/۴	۰/۹۳	۰/۸۶	۰/۵۸	۰/۴۸۸	R (دبی جریان)	NGANN
۰/۵۹	۰/۷۶۷	۰/۵۸۸	۰/۲۷	۲/۳۳۷	R^{sc}, R^{cc}	MARS
۰/۸	۰/۷۶۶	۰/۵۸۷	۰/۲۳	۲/۳۳۸	R (دبی جریان)	SRC

تحریک از نوع تانژانت سیگموید، می‌توان با دقت بالایی میزان دبی بار معلق رسوب را پیش‌بینی نمود و دقت نتایج به‌دست آمده از روش شبکه عصبی مصنوعی به‌مراتب از دقت روش منحنی سنجه با و بدون دسته بندی داده‌ها بالاتر است که با تحقیق دهقانی و همکاران (۴) و جلالی و همکاران (۳) مطابقت دارد. در این تحقیق با توجه به یکسان بودن داده‌های ورودی مدل‌های MARS و GANN می‌توان علت وجود اختلاف در نتایج ارزشیابی مدل‌ها را در نوع مدل به‌کارگرفته جستجو نمود. بنابراین می‌توان کارایی بالاتر شبکه عصبی مصنوعی ژئومورفولوژیکی را نسبت به مدل رگرسیونی ژئومورفولوژیکی به‌خوبی استنتاج نمود که با نتایج ولی و همکاران (۱۱) مطابقت دارد.

در این تحقیق حاصل مقایسه نتایج مدل‌های MARS و SRC که اختلاف معنی‌داری در پیش‌بینی دبی رسوب نداشتند را می‌توان به پایین بودن ضریب فشردگی و ضریب شکل منطقه مورد مطالعه نسبت داد که با نتایج ولی و همکاران (۱۱) مغایرت داشت.

مقایسه نتایج روش‌های آماری و نتایج شبکه‌های عصبی کارایی بهتر مدل‌های شبکه عصبی را در برآورد رسوب لحظه‌ای 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 غیرخطی با حجم کم داده‌ها جستجو نمود. این درحالی‌است که عملکرد و دقت روش‌های رگرسیونی به شدت


چندلایه (MLP) با الگوریتم لونبرگ مارکوارت با دو لایه مخفی برای شبیه‌سازی دبی رسوب انتخاب گردید. با توجه به این‌که یکی از اهداف تحقیق مقایسه روش‌های NGANN و GANN است. بنابراین، ساختار و توابع عملکردی آنها ثابت فرض شده است تا بتوان تأثیر ورودی‌های دو مدل را در شرایط یکسان با یکدیگر مقایسه کرد.

نتایج حاصل از مدل‌سازی آماری و شبکه‌های عصبی مصنوعی و عملکرد هر مدل در جدول ۴ ارائه شده است. نتایج تأثیر عوامل ژئومورفولوژی منتج به انتخاب دو ضریب شکل و ضریب فشردگی حوزه با استفاده از آمار دبی و استنباط ارتباط بین دو متغیر مستقل فوق‌الذکر با میزان رسوب توسط روش MARS بررسی شده است.


نتیجه‌گیری و بحث

در این تحقیق عملکرد مدل‌های مختلف به کمک فاکتورهای RMSE و R^2 و میانگین خطای مطلق (MAE) مورد ارزیابی قرار گرفته است. این مقادیر مزیت نسبی مدل‌ها را نشان می‌دهند. بیشترین ضریب تبیین معنی‌دار و کمترین میزان خطای RMSE و MAE بهترین روش را معرفی می‌نماید. بنابراین، ارزش برآوردی روش‌ها به‌ترتیب SRC, MARS, NGANN و GANN با میزان ضریب تبیین ۰/۸۸, ۰/۸۶, ۰/۵۸ و ۰/۵۸ و نتایج سایر آزمون‌ها در جدول (۴) مشخص گردیده است.


نتایج به‌دست آمده از این تحقیق نشان می‌دهد که با به‌کارگیری شبکه عصبی از نوع پرسپترون چندلایه و تابع



شکل ۴. مقایسه مقادیر مشاهداتی و شبیه‌سازی شده رسوب در روش GANN



شکل ۳. مقایسه مقادیر مشاهداتی و شبیه‌سازی شده رسوب در روش مارس



شکل ۵. تغییرات مقادیر نرمال مشاهده‌ای و پیش‌بینی شده رسوب معلق برای داده‌های آزمون در روش‌های مختلف.

نتیجه‌گیری نهایی تحقیق معرفی و ارائه مدل طراحی شده شبکه عصبی مصنوعی به کمک پارامترهای ژئومورفولوژیکی حوزه آبخیز رودخانه مزبور است. این مدل از نوع پرسپترون چند لایه (MLP) با الگوریتم لوبنرگ-مارکواریت با دو لایه مخفی و ۴ نرون در هر لایه بوده و قابلیت پیش‌بینی و شبیه‌سازی بار رسوب جریان را با کمترین محدودیت دارا است. در کل بر طبق یافته‌های این تحقیق مدل شبکه عصبی مصنوعی قابلیت خوبی را از خود در پیش‌بینی رسوب نشان می‌دهد و این کارایی با دخیل شدن پارامترهای مورفولوژیکی حوزه افزون می‌گردد.

از حجم نمونه تبعیت می‌کند و حجم کم نمونه‌ها می‌تواند عامل محدودیت مدل‌های آماری گردد.

مقایسه شکل‌های ۳ و ۴ نشان می‌دهد که روش شبکه عصبی دارای روند بهتری در شبیه‌سازی داده‌های رسوب نسبت به روش سنج رسوب می‌باشد.

در شکل ۵ نیز مقادیر پیش‌بینی شده توسط شبکه عصبی مصنوعی و منحنی‌های سنج در مقابل مقادیر مشاهده شده نشان داده شده، این شکل تشخیص چشمی عملکرد مدل‌های مختلف برآورد با رسوب روزانه را آشکار می‌سازد. همان‌طور که از شکل ۵ مشخص است، نتایج به دست آمده از شبکه عصبی حول خطی با زاویه ۴۵ درجه به خوبی پراکنده شده است، که این نشان خطای کمتر شبکه عصبی در پیش‌بینی رسوب نسبت به مدل‌های رگرسیونی می‌باشد.

منابع مورد استفاده

۱. اعلمی، م.، و. نورانی، ح. نظم آرا. ۱۳۸۸. قابلیت شبکه عصبی مصنوعی جهت مدل سازی چند ایستگاه بار معلق در مقایسه با روش منحنی رسوب. مجله دانش آب و خاک ۱۹(۲): ۴۵-۵۵.
۲. تلوری، ع.، ن. بیرویان و ا. منوچهری. ۱۳۸۶. مدل سازی تغییرات زمانی رسوب مطالعه موردی حوزه آبریز گاران در کردستان. فصلنامه پژوهش و سازندگی در منابع طبیعی، شماره ۷۵، ص ۷۰-۶۴.
۳. جلالی، م.، ک. سلیمانی. ۱۳۸۶. برآورد بار معلق رسوب ایستگاه هیدرومتری آبلونکارود با استفاده از منحنی سنج رسوب و شبکه عصبی مصنوعی. چهارمین همایش ملی علوم و مهندسی آبخیزداری ایران، کرج، ص ۱۱۱۵-۱۱۲۴.
۴. دهقانی، ا.، م. ا. زنگانه، ا. مساعدی و ن. کوهستانی. ۱۳۸۸. مقایسه تخمین بار معلق به دو روش منحنی سنج رسوب و شبکه عصبی مصنوعی (مطالعه موردی رودخانه دوغ استان گلستان). مجله علوم کشاورزی و منابع طبیعی ۱۶(۱): ص ۱۲.
۵. دهقانی، ا.، ر. احمدی. ۱۳۸۷. تخمین آبدی حوزه های آبخیز فاقد آمار با استفاده از شبکه عصبی مصنوعی. اولین کنفرانس بین المللی بحران آب. وزارت علوم، تحقیقات و فناوری - دانشگاه زابل، ص ۶.
۶. داندانه مهر، ع.، ا. علیانی، م. قربانی. ۱۳۸۰. پیش بینی بار معلق رودخانه ای بر مبنای دبی جریان با استفاده از برنامه ریزی ژنتیک. پژوهش های آبخیزداری، شماره ۸۸، ص ۵۴-۴۴.
۷. طلوعی، س.، ع. حسین زاده دلیر. ۱۳۹۰. تخمین زمانی و مکانی بار معلق رودخانه آبی چای با استفاده از زمین آمار و شبکه عصبی مصنوعی. نشریه دانش آب و خاک، جلد ۲۱، شماره ۴، ص ۹۴-۱۰۴.
۸. فیض نیا، س.، ح. محمد عسگری و م. معظمی. ۱۳۸۶. بررسی کارایی روش شبکه عصبی مصنوعی در تخمین رسوب معلق روزانه (بررسی موردی حوزه آبخیز زرد رامهرمز، استان خوزستان)، فصلنامه منابع طبیعی دانشگاه تهران، دوره ۶۰، شماره ۴، ۱۲۱۰-۱۱۹۹.
۹. مساعدی، ا.، ا. محمدی، ع. نجفی نژاد. ۱۳۸۵. بهینه سازی روابط دبی جریان و دبی رسوب معلق در ایستگاه های منتخب رودخانه گرگان رود. نشریه منابع طبیعی ایران ۵۹ (۲): ۳۴۲-۳۳۱.
۱۰. نجفی، ن.، م. حیدرپور و م. کیخایی. ۱۳۸۵. بررسی کارایی شبکه عصبی مصنوعی در شبیه سازی بارش و رواناب. اولین همایش منطقه ای بهره برداری بهینه از منابع آب حوزه های کارون و زاینده رود، شهرکرد.
۱۱. ولی، ع.، م. رامشت. ۱۳۹۰. مقایسه کارایی مدل های شبکه های عصبی مصنوعی و رگرسیون برای پیش بینی بار رسوب جریان حوزه آبخیز سمندگان. مجله جغرافیا و برنامه ریزی محیطی، شماره پیاپی ۴۴، شماره ۴. ۱۵ ص.
12. ASCE. 2000. Artificial neural networks in hydrology. Hydrology applications. J. Hydro. Engin. 5: 124-136.
13. Bhattacharya, B., R. K. Price and D. P. Solomatine. 2005. Data-driven modeling in the context of sediment transport. Physics and Chemistry of the Earth 30: 297-302.
14. Cigizoglu, H. 2002. Suspended sediment estimation for rivers using artificial neural networks and sediment rating curves. Turkish j. Eng. Env. Sci. 26(1): 27-36/
15. Cigizoglu, H. K. 2004. Estimation and forecasting of daily suspended sediment data by multi layer perceptrons. Advances in Water Resources 27: 185-195.
16. Cigizoglu, H. K. and M. Alp. 2006. Generalized regression neural network in modeling river sediment yield. J. Advance in engineering software 37: 63-68.
17. French, M. N., W. F. Krajewski and R. R. Cuykendall. 2003. Rainfall forecasting in space and time using artificial neural network. J. Hydro. 137(1): 41-31.
18. Govindaraju, R. S., A. RamachandraRao. 2000. "Artificial Neural Networks in Hydrology", Kluwer Academic Publisher, pp329.

19. Picoet, C., B. Hingray and J. C. Olivry. 2001. Empirical and conceptual modeling of the suspended sediment dynamics in large tropical African River: The Upper Niger River Basin. *J. Hydrol.* 250: 19-39.
20. Singh PK., V. Kumar, RC. Purohit, M. Kothari, PK. Dashora. 2009. Application of principal component analysis in grouping geomorphic parameters for hydrologic modeling. *Water Resour Manage* 23(3): 25-339
21. Zhou, Y., X. X. Lu, Y. Huang. Y. M. Zhu. 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.