

تحلیل مقایسه عملکرد شبکه‌های عصبی مصنوعی و مدل‌های رگرسیونی پیش‌بینی رسوب معلق مطالعه موردی: حوضه آبخیز اسکندری واقع در حوضه آبریز زاینده رود

عباسعلی ولی* - دانشجوی دکتری ژئومورفولوژی دانشگاه اصفهان و عضو هیات علمی دانشگاه شیراز
مسعود معیری - استادیار دانشگاه اصفهان
محمد حسین رامشت - دانشیار دانشگاه اصفهان
ناصر موحدی نیا - استادیار دانشگاه اصفهان

پذیرش مقاله: ۱۳۸۷/۱۰/۲۵ تأیید نهایی: ۱۳۸۸/۳/۱۱

چکیده

یکی از جنبه‌های حائز اهمیت در مدیریت محیط در ژئومورفولوژی کاربردی حل مشکل برآورد رسوب یک سیستم رودخانه‌ای می‌باشد. هدف این مطالعه ارزیابی عملکرد مقایسه‌ای دونوع شبکه عصبی مصنوعی (مدل ژئومورفولوژیکی و مدل غیر ژئومورفولوژیکی) و دونوع مدل رگرسیونی (مدل توانی و مدل غیر خطی چندگانه) برای پیش‌بینی بار رسوب معلق حوضه اسکندری در حوضه آبریز زاینده رود می‌باشد. مدل‌ها براساس آمار ۱۰۴ حداثه وقوع همزمان ثبت شده دی و رسوب طراحی شده‌اند. پارامترهای ژئومورفولوژیکی بکار رفته در مدل‌های مزبور شامل: نسبت ناهمواری، ضریب شکل و تراکم زهکشی می‌باشند. شبکه‌های عصبی مصنوعی طراحی شده از نوع انتشار برگشتی چهار لایه است. بهترین نتایج پیش‌بینی مربوط به روش شبکه عصبی مصنوعی ژئومورفولوژیکی با ضریب تبیین معنی دار ۰/۹۸ و جذر میانگین خطای ۴/۴۹ در مقایسه با روش شبکه عصبی مصنوعی طراحی شده بر اساس آمار جریان با مقدار ضریب تبیین ۰/۹۶ و خطای ۰/۳۵ می‌باشد. عملکرد روش‌های رگرسیونی با ضریب تبیین ۰/۸۹۳ و خطای ۰/۶۶ برای روش چند متغیره غیرخطی و مقدار ضریب تبیین ۰/۸۱۴ و خطای ۰/۰۵ می‌باشد. برای روش غیر خطی ساده توانی ضعیفتر از شبکه‌های عصبی مشاهده گردید. تفاوت فاحش در شاخص‌های ارزیابی مدل‌های شبکه عصبی مصنوعی نسبت به روش‌های رگرسیونی در عملکرد مناسب آنها برای تعداد کم نمونه‌های مدل می‌باشد. بنابراین شبکه‌های عصبی مصنوعی به خصوص شبکه‌های ژئومورفولوژیکی به عنوان یک ابزار قوی پیش‌بینی شایسته بار رسوب یک سیستم پیچیده رودخانه‌ای معرفی می‌شوند.

کلیدواژه‌ها: بار رسوب، رواناب، ژئومورفولوژی، شبکه عصبی مصنوعی، مدل رگرسیونی.

مقدمه

ژئومورفولوژی کاربردی بر سه محور برقراری پایداری منابع طبیعی، تخفیف خطرات طبیعی و کاهش اثرات تغییرات جهانی محیط استوار است (Slaymaker, ۲۰۰۱). لازمه توجه به محورهای مزبور یک نگرش کل گرایانه و جامع می‌باشد. دیدگاه سیستمی چنین نگرشی را هموار می‌سازد. از محاسن این دیدگاه می‌توان به استفاده از الگوهای انتزاعی از روابط درک مشخصات عمومی کارکردها و ساختارهای پیچیده، تبیین و پیش‌بینی پویایی سیستم‌ها و تدوین استراتژی‌های کل گرایانه جهت حفاظت و مدیریت محیط اشاره نمود. هر سیستم چشم‌انداز طبیعی یک سیستم باز می‌باشد. انتقال ماده، انرژی و اطلاعات داده‌های این نوع سیستم می‌باشند و می‌توانند کارکردهای سیستم را تنظیم کرده و ساختار آن را حفظ نمایند. روابط موجود درون سیستم در قالب مدل‌های متعدد جمع‌بندی می‌شوند. بنابراین مدل‌ها ابزار مهم برای تبیین پدیده‌هایی است که در سیستم‌ها دیده می‌شوند. شناخت علیتها، الگوها و مشخصات عمومی کنش‌ها و

* E-mail: vali@ltr.ui.ac.ir

نویسنده مسئول: ۰۹۱۳۱۰۸۹۶۰۷

واکنش‌هایی که در سیستم صورت می‌پذیرد، شالوده استراتژی‌های مدیریتی را تشکیل می‌دهند.

در مطالعات ژئومورفولوژی سیستم‌های متعددی قابل تمایز و تشخیص است. یکی از این سیستم‌ها سیستم زهکشی حاکم بر یک حوضه آبخیز می‌باشد. بارش و انرژی حاصل از آن بر سطح حوضه تاثیر گذاشته و منجر به شروع فرآیند فرسایش و جریان‌های سطحی وزیر زمینی می‌شود. انرژی جریان آبهای سطحی قادر است مواد حاصل از فرسایش قطvre ای را با خود حمل کرده و باعث انباشت رسوبات در مکانی جدید شود. عوامل متعددی در این جریان ماده و انرژی تاثیر گذار است.

جریان رسوب متناسب با اندازه ذرات، بصورت مواد معلق یا بصورت غلطان در کف بستر حرکت می‌کند. جریان بار رسوب یکی از مهم ترین پارامترهای پروژه‌های هیدرولیک، یک شاخص مفید فرسایش خاک و محیط اکولوژیکی حوضه آبخیز است (Zhou و همکاران ۱۱۱.۲۰۷). برآورد میزان رسوب جریان طیف کاربردی وسیعی دارد. طراحی سدها و آبگیرها، انتقال رسوب و آسودگی رودخانه و دریاچه، تعیین اثرات مدیریت حوضه‌های آبخیز و ارزیابی جنبه‌های مختلف محیطی از این قبیل 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 استوار شده است (Poesen و همکاران ۱۲۳.۲۰۰ و Zhou ۹۳.۲۰۲) و قادرند نرخ رسوب گذاری در دلتا یا مخازن را برآورد نمایند (Verstraeten و همکاران ۲۴۸.۲۰۰۳) این روش‌ها به دلیل برخورداری از ساختار ساده، محاسبات ریاضی و قابلیت کارکردن با مجموعه داده‌های ورودی محدود به طور مستردانه ای رایج می‌باشند (Zhou و همکاران، ۱۲۴.۲۰۷). به حال، مدل‌های رگرسیونی خطی یا غیر خطی مرسوم می‌تواند بار رسوب معلق را با دقت نسبی مدل‌های ساده تجربی محاسباتی ارائه نمایند. مدل‌های فیزیکی، نامتجانس بودن فضایی را با انجام تقسیمات حوضه‌ها به شبکه‌های جزیی و توصیف انتقال رسوب از یک شبکه به شبکه دیگر با معادلات مختلف جزیی برآورد می‌نمایند (Van Oost و همکاران ۵۷۹ و ۲۰۰۰). معادلات جزیی برآورد انتقال رسوب براساس فرضیات مختصرسازی غیرواقعی جریان و ارتباطات تجربی برای تعیین قابلیت فرسایندگی باران و جریان استوار است (Kisi ۱۰۷.۲۰۰۴). اگرچه تسریخ عرصه برآورد رسوب توسط مدل‌های گوناگون می‌تواند موفقیت بزرگی جهت برآورد حقیقی رسوب در حوضه‌های کوچک و متوسط قلمداد شود، لیکن کاربردهای منطقه‌ای و مقیاس‌های بزرگتر به دلیل افت کمیت و کیفیت داده‌های ورودی معمولاً غیر واقعی است.

شبکه‌های عصبی مصنوعی در سال‌های اخیر با الهام از سیستم پردازش اطلاعات مغز طراحی و به عرصه ظهور رسیده‌اند. شبکه‌های عصبی ابزار محاسباتی قوی و توانمندی هستند که در ساماندهی و ایجاد رابطه بین اطلاعات گوناگون قابلیت‌های بسیار خوبی داشته‌اند. قابلیت‌های بالای این سیستم‌ها در نگاشت فضاهای با بعد وسیع و همچنین تحلیل مسائلی که در ک آنها با متوجه شدن به روابط پیچیده ریاضی دشوار است، می‌تواند در امور مدیریت محیط مفید باشد. بطور کلی شبکه‌های عصبی مصنوعی در برخورد با مسائلی از قبیل شناسایی سیستم، تقریب و تخمین، بهینه سازی، شبیه سازی و پیش‌بینی رفتار و نظایر آن نتایج موفقیت آمیزی داشته است (Cigizoglu و Kisi ۲۳۶.۲۰۰۶).

تجارب موفق مدل سازی به کمک شبکه‌های عصبی مصنوعی در مباحث مختلف مدیریت آب بروز کرده است. Zhang و Govindaraju (۳۳.۲۰۰۳) با طراحی یک شبکه عصبی سه لایه بر اساس خصوصیات فیزیوگرافی 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 محاسبه ابعاد هیدروگراف برشمernد و ضمن معرفی روش شبکه عصبی مصنوعی به عنوان روش مطلوب به ویژگی‌های آن از جمله قابلیت بکار گیری داده‌های ژئومورفولوژیکی حوضه در برآورد جریان مستقیم حوضه اشاره نمودند. Gu و Yitian (۱۲۲.۲۰۰۳) یک سیستم تلفیقی رودخانه - شبکه عصبی طراحی نموده و به کمک آن با نتایج قبل قبول انتقال رسوب و جریان را بازسازی نمودند. Cigizoglu (۱۸۵.۲۰۰۴) به ارزیابی یک شبکه عصبی مصنوعی از نوع دریافتی^۱ چند لایه در برآورد بار رسوب جریان پرداخته و کارآبی تشخیص رفتار غیر خطی میزان رسوب معلق جریان را از نقاط قوت

آن برشمرد. Bhattacharya و همکاران (۲۰۰۵، ۳۹۷) مدل سازی رسوب متقل شده توسط جریان با استفاده از شبکه‌های عصبی مصنوعی و مقادیر واقعی بدست آمده از فلوم و عرصه را مورد بررسی قرارداده و کارآیی مطلوب‌تر شبکه‌ها را از روش‌های رایج برآورده رسوب به کمک فلوم و روش‌های برآورده از عرصه، گزارش نمودند. Sarangi و Bhattacharya (۲۰۰۵، ۱۹۵) از استفاده دو نوع شبکه عصبی مصنوعی در برآورده رسوب در یک حوضه آبخیز در هند به ضریب تبیین ۰/۹۸ (۰/۹۴) برای شبکه‌های وابسته به برخی شاخص‌های هندسی در مقابل ضریب تبیین ۰/۹۶ برای شبکه‌های ساده عصبی مصنوعی دست یافتند. Cigizoglu و Alp (۲۰۰۶، ۶۳) نیز به مقایسه روش رگرسیونی و شبکه‌های عصبی در برآورده بار رسوب رودخانه جوینیاتا در ایالات متحده پرداخته و افزایش دقت و سرعت شبکه‌های عصبی مصنوعی را در مقابل روش رگرسیونی عامل ارجحیت آن معرفی نمودند. Kisi و Cigizoglu (۲۰۰۶، ۲۲۱) با ارائه روش تجزیه داده‌ها به گروه‌های همگن فرآیند یادگیری شبکه عصبی پیشنهادی خود را جهت برآورده بار رسوب بهبود بخشیدند. Agarwal و همکاران (۲۰۰۶، ۵۹۷) با تفکیک داده‌ها در سری‌های زمانی روزانه، هفتگی، ده روزه و ماهانه با استفاده از آمار جریان رسوب به مقایسه آمار واقعی با آمار برآورده شده پرداخته و به این طریق شبکه‌های طراحی شده را ارزیابی نمودند. Alp و Cigizoglu (۰۷، ۱۱۱) به بررسی عملکرد یک شبکه چند لایه با یک شبکه شعاعی برای برآورده بار رسوب به کمک داده‌های بارندگی و جریان پرداخته و نتایج مشابهی نسبت به رگرسیون چندگانه بدست آورده‌اند. Zhou و همکاران (۰۷، ۲۰۱) ضمن معرفی روش مدل سازی شبکه عصبی مصنوعی جهت جریان رسوب معلق به کارآیی برآورده بار رسوب جریان در رودخانه‌ای در چین پرداخته و مزیت شبکه طراحی شده اقلیمی نسبت به شبکه طراحی شده با آمار جریان روزانه با اعمال تأخیر ۳ روزه را تایید نمودند.

هدف از این پژوهش ارزیابی مقایسه عملکرد شبکه عصبی مصنوعی ژئومورفوژئیکی در برآورده بار رسوب با شبکه عصبی مصنوعی ساده و روش‌های رگرسیونی، در منطقه مورد مطالعه می‌باشد. تا ضمن پیش‌بینی میزان رسوب حوضه مورد مطالعه توسط مدل‌ها و مقایسه مقادیر محاسبه شده با مقادیر مشاهده شده به ارزیابی عملکرد هر مدل پرداخته و ضمن مقایسه نتایج همه مدل‌ها مزیت نسبی آن‌ها تبیین گردد.

مواد و روش‌ها


منطقه مورد مطالعه

منطقه مورد مطالعه در محدوده حوضه آبریز زاینده رود (۰۳۱۵۰ کیلومتر مربع) واقع شده است. سد زاینده رود بر روی رودخانه زاینده رود احداث شده است و چهار رودخانه اصلی آب خودرا در پشت سد تخلیه می‌کنند. رودخانه‌های مزبور عبارتند از رودخانه پلاسجان (۰۳ کیلومتر)، رودخانه زاینده رود (۰۷۲ کیلومتر)، رودخانه سمندگان (۰۲۳ کیلومتر) و رودخانه حیدری (۱۵ کیلومتر). حوضه آبخیز مورد مطالعه در این تحقیق حوضه رودخانه پلاسجان بوده که با توجه به قرار داشتن ایستگاه هیدرومتری در محلی به نام اسکندری این حوضه نیز به این نام معروف می‌باشد. رودخانه پلاسجان بین طول‌های ۰/۳۰ تا ۰/۶۸ درجه و عرض‌های ۰/۷۷ تا ۰/۲۰ درجه واقع شده است. رواناب این حوضه از دو شاخه رودخانه سواران و بوین میان داشت می‌باشد که در محل ورود به دریاچه سد در ایستگاه هیدرومتری اسکندری با طول ۰/۴۲ درجه شرقی و عرض ۰/۸۰ درجه شمالی و ارتفاع ۱۳۰ متر از سطح تراز دریا، اندازه گیری می‌شود. این رودخانه آب حوضه‌ای به مساحت ۱۶۴۰ کیلومتر مربع را تخلیه می‌کند. ارتفاع متوسط این حوضه ۰/۲۵۲ متر و بارندگی متوسط آن ۰/۴۶ میلی متر و متوسط آبدهی آن ۱۳۱ میلیون مترمکعب در سال است. شکل (۱) موقعیت ایستگاه‌ها و رودخانه‌های اصلی حوضه سد زاینده رود را نشان می‌دهد. در این تحقیق از آمار ثبت پارامترهای ۱۰۴ حادثه سیالاب ثبت شده مربوط به دوره آماری سال ۱۳۷۴ تا ۱۳۸۵ استفاده شده است. این پارامترها شامل دی لحظه‌ای روزانه به مترمکعب بر ثانیه و رسوب روزانه لحظه‌ای به کیلوگرم بر ثانیه می‌باشد که بصورت همزمان اندازه گیری شده‌اند ابتدا داده‌های آماری به دو گروه آموزش و آزمون تقسیم شدند. تعداد ۸۲ سیالاب برای آموزش^۱ یا یادگیری و تعداد ۲۲

had the same direction as the river bed. The parameters of the basin were calculated by the software. The results showed that the basin area was 1642 km², the basin perimeter was 176.2 km, the basin length was 61 km, the basin elevation difference was 3890 m, the basin elevation range was 2140 m, the average basin elevation was 2523 m, the basin non-uniformity coefficient was 1/75, the basin non-uniformity ratio was 0.029, the basin non-uniformity degree was 0.01, the basin slope gradient was 1/23, the basin slope degree was 0.66, the basin slope intensity was 0.76, the basin slope ratio was 0.45, the total basin length was 2264 km, and the basin drainage density was 1/44.

جدول(۱) پارامترهای ژئومورفولوژی حوضه آبخیز اسکندری.

ردیف	نام پارامتر ژئومورفولوژی	مقدار
۱	مساحت (کیلومتر مربع)	۱۶۴۲
۲	محیط (کیلومتر)	۱۷۶.۲
۳	حداکثر طول(کیلومتر)	۶۱
۴	ارتفاع حداقل(متر)	۳۸۹۰
۵	ارتفاع حداقل(متر)	۲۱۴۰
۶	متوسط ارتفاع (متر)	۲۵۲۳
۷	ناهمواری حوضه آبخیز(کیلومتر)	۱/۷۵
۸	نرخ ناهمواری	۰/۰۲۹
۹	نسبت ناهمواری	۰/۰۱
۱۰	ضریب فضدگی	۱/۲۳
۱۱	ضریب گردی	۰/۶۶
۱۲	ضریب کشیدگی	۰/۷۶
۱۳	ضریب شکل	۰/۴۵
۱۴	طول کل آبراهه (کیلومتر)	۲۲۶۴
۱۵	تراکم زهکشی	۱/۴۴



شکل ۱. موقعیت حوضه آبخیز سد زاینده رود، رودخانه پلاسجان و ایستگاه سنجش دبی و رسوب اسکندری

مدل سازی آماری

مدل سازی آماری با استفاده از نرم افزار SPSS و با استفاده از تحلیل رگرسیونی استوار گردید. مدل‌های آماری استفاده شده دو نوع می‌باشد. نوع اول بر اساس بهترین برازش بین متوسط دبی روزانه و متوسط رسوب روزانه طراحی گردید و با توجه به این که بهترین تابع برازش بین این دو متغیر از نوع تابع توانی می‌باشد این روش به اختصار روش رگرسیونی توانی^۱ نامیده شده است و شکل کلی آن به صورت معادله (۱) می‌باشد.

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

a,b ضرایب رابطه، R میزان رواناب لحظه‌ای، S میزان رسوب لحظه‌ای.

نوع دوم مدل آماری در نتیجه تاثیر ضرایب سه گانه نسبت ناهمواری، ضریب فرم و تراکم زهکشی بر روی دبی لحظه‌ای روزانه طراحی گردید و ارتباط غیر خطی بین این متغیرهای مستقل با رسوب لحظه‌ای روزانه محاسبه شد. این روش به اختصار به روش مارس^۲ معروف است. در این روش به کمک پارامترهای ژئومورفولوژیکی سه گانه و متوسط دبی روزانه، سه متغیر مستقل مدل ساخته می‌شود. شکل کلی مدل مذبور به صورت معادله (۲) می‌باشد. بنابراین با استفاده از یک بردار داده‌های دبی روزانه سه بردار مستقل طراحی می‌شود. کاربرد این روش برای زمانی است که بخواهیم میزان تاثیر و ارتباط یک داده را با یک بردار داده بدست آوریم.

$$S = aR^{\sqrt{Ff}} + bR^{\sqrt{Df}} + cR^{\sqrt{Rf}} + d \quad (2)$$

a,b,c,d ضرایب معادله . Ff, Df و Rf به ترتیب ضریب شکل حوضه، تراکم زهکشی و ضریب ناهمواری، R میزان رواناب لحظه‌ای، S میزان بار رسوب.

برای مثال جهت بررسی تاثیر متغیر مستقل ضریب شکل حوضه بر متغیر وابسته میزان رواناب حوضه، متغیر مستقل ما را یک داده با یک تکرار و متغیر وابسته شامل یک بردار از مقادیر مختلف رواناب می‌باشد. لذا با انتخاب یک متغیر مستقل نظری براندگی که مقادیر مختلفی را به خود اختصاص می‌دهد و یک بردار داده را تشکیل می‌دهد می‌توان یک متغیر مستقل از تلفیق ضریب شکل و میزان براندگی بدست آورد این بردار جدید از به توان رساندن تک تک داده‌های براندگی با محدوده ضریب شکل حاصل می‌شود ($P^{\sqrt{Rf}}$) و در نهایت ارتباط بین بردار جدید و بردار رواناب بدست می‌آید. این ارتباط جدید در حقیقت از دو متغیر مستقل براندگی و ضریب شکل حوضه با متغیر وابسته رواناب حاصل می‌شود.

مدل سازی شبکه‌های عصبی مصنوعی

برای مدل سازی شبکه‌های عصبی مصنوعی ارجاعیه ابزار شبکه عصبی مصنوعی نرم افزار MATLAB استفاده شده است. شبکه‌های عصبی طراحی شده در این پژوهش بسته به نوع داده‌های ورودی به دونوع تقسیم شدند. نوع اول شبکه عصبی مصنوعی طراحی شده با استفاده از دبی و رسوب روزانه می‌باشد. در این نوع شبکه دبی روز حادثه، دبی روز ماقبل حادثه و دبی دوروز ماقبل حادثه بعنوان عناصر ورودی و میزان رسوب روز حادثه به عنوان خروجی سیستم طراحی شده است. این شبکه به اختصار^۳ ANN نامیده شده است. نوع دوم شبکه عصبی مصنوعی طراحی شده با استفاده از سه عامل روش مارس تغذیه شده است. بنابراین سه عنصر ورودی آن را سه متغیر مستقل روش مارس تشکیل می‌دهد و خروجی آن میزان رسوب روزانه بوده است. این شبکه در این پژوهش به اختصار^۴ GANN نامیده شده است.

معماری شبکه عصبی مصنوعی

1- Power Regression (PR)

2- Multivariate Adaptive Regression Spline (MARS)

3- Artificial Neural Network (ANN)

4- Geomorphologic Artificial Neural Network (GANN)

یکی از سوالات اساسی در مدل سازی رواناب-رسوب چگونگی انتخاب و معماری شبکه برای حصول به حداقل دقت می‌باشد. هریک از انواع مختلف شبکه‌های عصبی در زمینه ای بخصوص قابلیت بهتری نسبت به سایر انواع دیگر دارند لیکن برای عمل تقریب تابع، شبکه‌های عصبی انتشار برگشتی مناسب ترین 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 (Schalkoff، ۱۹۹۷، ۱۵۴). در حقیقت انتخاب تعداد نرون‌ها در لایه پنهان و همچنین تعداد لایه‌های پنهان با توجه به نوع مساله تغییر می‌کند. لیکن بطور معمول تعداد نرون‌های موجود در لایه‌های پنهان مختلف با یکدیگر برابر هستند (Harvey، ۱۹۹۶، ۱۱۲). 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 انعطاف‌پذیری آنها با دو لایه مخفی و توابع محرک سیگموئیدی توصیه شده است (Flood و Kartman، ۱۹۹۶، ۱۳۲ و Ripley، ۱۹۹۶، ۴۱۳). با توجه به عدم وجود ثبات در ایجاد و توسعه شبکه عصبی مصنوعی تجربیات موفق قبلی می‌تواند مفید واقع شود. اطلاعات موجود در حوضه آبخیز و شیوه سعی و خطا می‌تواند در معماری بهینه شبکه موثر باشد. با توجه به تجربیات قبلی (و همچنین آزمون و بررسی عملی در این تحقیق از شبکه‌های پیش خور با الگوریتم آموزشی پس انتشار خطا^۱ با تابع آموزشی Trainlm و تابع انتقال Logsig با دو لایه مخفی استفاده شده است. بنابراین با احتساب لایه ورودی و لایه خروجی، شبکه‌های استفاده شده لایه‌ای می‌باشند. تعداد نرون‌های لایه‌های مخفی به روش آزمون و خطا و مقایسه عملکرد خطای آنها انتخاب شده‌اند. یکی از مراحل آماده سازی و محاسبات عددی برای تعزیز شبکه‌های عصبی معيار نمودن^۲ یا نرمالیزه سازی داده‌ها به منظور افزایش حساسیت به بزرگی داده‌ها و افزایش قدرت یادگیری می‌باشد که باعث افزایش توانایی پیش‌بینی می‌شود. روش‌های متنوعی جهت معيار نمودن داده‌ها وجود دارد که تفاوت اصلی آنها در دامنه عمل آنهاست. در این تحقیق بردارهای ورودی و خروجی شبکه‌ها به کمک رابطه زیر در بازه‌ی [۰۱]^۳ نرمال سازی شده‌اند. در این رابطه هر داده از مقدار حداقل داده‌ها کسر شده و بر دامنه تغییرات کل داده‌ها تقسیم می‌گردد (Sivakumar و همکاران، ۲۰۰۲، ۲۲۹) و رابطه (۳) می‌باشد:

$$R_i = \frac{N_i - \text{Min}_i}{\text{Max}_i - \text{Min}_i} \quad (3)$$

مشخصات شبکه‌های عصبی طراحی و انتخاب شده پس از مرحله آزمون و خطا به شرح جدول (۲) می‌باشد. لایه‌های ورودی و خروجی هر دو شبکه عصبی مصنوعی مشابه یکدیگر و به ترتیب از ۳ و ۱ نرون تشکیل شده است. تعداد لایه‌های مخفی هر دو مدل نیز ۲ لایه با ۴ نرون استفاده شده است.

جدول (۲) مقایسه اندازه تابع عملکرد خطای ساختار شبکه‌های عصبی مصنوعی جهت پیش‌بینی بار رسوب.

نام اختصاری شبکه	ساختار شبکه	تعداد تکرار	اندازه تابع عملکرد خطای
ANN	۳-۳-۳-۱	۲۰۰	.۰۰۰۴۲۷
	۳-۳-۳-۱	۴۰۰	.۰۰۰۳۶۷
	۳-۴-۴-۱	۲۰۰	.۰۰۰۲۷۸
	۳-۴-۴-۱	۴۰۰	.۰۰۰۱۱۵
GANN	۳-۳-۳-۱	۲۰۰	.۰۰۰۳۵۶
	۳-۳-۳-۱	۴۰۰	.۰۰۰۳۳۳

تحلیل مقایسه عملکرد شبکه‌های عصبی مصنوعی و مدل‌های رگرسیونی پیش‌بینی رسوب معلق

۰/۰۰۰۲۰۵	۲۰۰	۳-۴-۴-۱
۰/۰۰۰۱۰۴	۴۰۰	۳-۴-۴-۱

روش ارزیابی مدل‌ها

تمام مدل‌های طراحی شده اعم از آماری و شبکه‌های عصبی مصنوعی با استفاده از داده‌های آموزشی تعلیم دیده و سپس به کمک داده‌های آزمون، یک بردار رسوب پیش‌بینی می‌نمایند. بنابراین برای ارزیابی مدل‌ها می‌توان از جذر میانگین مربعات خطأ^۱ و ضریب تبیین^۲ بین بردار مشاهده شده و بردار پیش‌بینی شده بهره جست. رابطه (۴) نحوه محاسبه شاخص ارزیابی میزان خطای مدل‌ها را نشان می‌دهد.

$$RMSE = \sqrt{\frac{\sum_{I=1}^n (S_o - S_s)^2}{n}} \quad \text{رابطه (۴)}$$

رسوب مشاهده شده و رسوب پیش‌بینی شده S_o تعداد کل داده‌ها.

یافته‌های تحقیق

نتایج مدل‌های رگرسیونی پیش‌بینی میزان رسوب روزانه بر حسب کیلوگرم بر ثانیه در جدول (۳) ارائه شده است. بهترین معادله برازش بین میزان دبی و رسوب لحظه‌ای از بین مدل‌های خطی، لگاریتمی، درجه ۲، درجه ۳، معکوس و توانی برای داده‌های آموزش رابطه توانی با ضریب تبیین ۹۵۶/۰ حاصل شده است. نتایج تاثیر عوامل سه گانه ضریب ناهمواری، ضریب شکل و تراکم زهکشی حوضه با استفاده از آمار دبی و استباط ارتباط بین ۴ متغیر مستقل فوق الذکر با میزان رسوب توسط روش MARS بررسی شده است. همان‌گونه که مشاهده می‌شود ضریب تبیین معنی دار ۹۶۵/۰ برای داده‌های آموزشی بدست آمده است.

جدول (۳) نتایج مدل‌های آماری طراحی شده پیش‌بینی بار رسوب روزانه رودخانه پلاسجان با داده‌های آموزش

نام مدل	ضریب تبیین	معادله مدل
PR	۹۵۶	$S = 0.061R^{1.935}$
MARS	۹۶۵	$S = 183.018R^{\sqrt{Rf}} - 35.868R^{\sqrt{Ff}} + 7.315R^{\sqrt{Df}} - 151.961$

نتایج حاصل از مدل سازی آماری و شبکه‌های عصبی مصنوعی و عملکرد هر مدل در جدول (۴) ارائه شده است. مجدد میانگین مربعات خطأ و میزان ضریب تبیین و بردارهای ورودی هر مدل به صورت جداگانه بیان شده است.


جدول (۴) نتایج ارزیابی مدل‌های مختلف طراحی شده جهت برآورد رسوب معلق جریان حوضه اسکندری

R ²	RMSE	ورودی‌ها	مدل
۰/۸۱۴	۱۵/۰۵	(دبی جریان) R	PR
۰/۸۹۳	۸/۶۶	$R^{\sqrt{Df}}, R^{\sqrt{Rf}}, R^{\sqrt{Ff}}$	MARS
۰/۹۶۰	۵/۳۵	$Rt, Rt - 1, Rt - 2$	ANN
۰/۹۷۶	۴/۴۹	$R^{\sqrt{Df}}, R^{\sqrt{Rf}}, R^{\sqrt{Ff}}$	GANN

نتیجه گیری

1- Root Mean Square Error (RMSE)
2- Coefficient of determination (R²)


ارزیابی عملکرد مدل‌های مختلف به کمک فاکتورهای RMSE و R^2 امکان‌پذیر می‌باشد. 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 R^2 مزیت نسبی مدل‌ها را نشان می‌دهد. بیشترین ضریب تبیین معنی‌دار و کمترین میزان خطأ، بهترین روش را معرفی می‌نماید بنابراین ارزش رجحانی روش‌ها به ترتیب MARS, GANN, PR با میزان ضرایب تبیین ۰/۹۸، ۰/۹۶، ۰/۹۴ و ۰/۸۱ و مقادیر خطای برآورد ۴/۳۸، ۵/۳۵، ۸/۶۶ و ۱۵/۰۵ تعیین می‌گردد. شکل (۲) ارتباط بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده را برای مدل‌های چهارگانه تحقیق برای داده‌های آزمون براساس ضریب تبیین نشان می‌دهد. در مقایسه کارآیی این مدل‌ها هر چه نتایج پیش‌بینی بیشتر منطبق بر نتایج مشاهده شده باشد مدل از کارآیی مطلوب‌تر برخوردار است. شکل (۳) اختلاف بین مقادیر خطای برآورد شده و مقادیر واقعی رسوب را برای مدل‌های مختلف 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.



شکل (۲) 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 ساختارهای شبکه‌های عصبی GANN و ANN می‌توان علت اختلاف در کارآیی 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 کارآیی بالاتری نسبت به زمانی دارد که ما فقط از اطلاعات سیلاب استفاده نماییم. 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 کارآیی بالاتر شبکه عصبی مصنوعی ژئومورفولوژیکی را نسبت به مدل رگرسیونی ژئومورفولوژیکی به خوبی استنتاج نمود. از مقایسه نتایج مدل‌های PR و MARS می‌توان به کارآیی توان داده‌های ژئومورفولوژی و روش رگرسیون چند متغیره غیر خطی MARS 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 مطلوب‌تری نسبت به زمانی حاصل می‌شود که از معادلات ساده به کمک داده‌های هیدرولوژی استفاده شود. با توجه به اینکه مدل‌های PR و ANN از داده‌های هیدرولوژی سیلاب حوضه استفاده نموده‌اند مقایسه آنها حاکی از کارآیی بالاتر شبکه عصبی نسبت به روش آماری می‌باشد.



شکل (۳) مقایسه اختلاف خطای بین مقادیر مشاهده شده و مقادیر پیش بینی شده رسوبر در روش‌های چهارگانه.
الف) روش PR، ب) روش MARS، ج) روش ANN و د) روش GANN.

مقایسه نتایج روش‌های آماری و نتایج شبکه‌های عصبی ارزش رجحانی مدل‌های شبکه عصبی را در برآورد رسوبر 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 حجم کم داده‌ها جستجو نمود. این در حالی است که عملکرد و دقت روش‌های رگرسیونی به شدت از حجم نمونه تعیین می‌کند و حجم کم نمونه‌ها می‌تواند عامل محدودیت مدل‌های آماری گردد. لیکن در مدل‌های طراحی شده شبکه عصبی مصنوعی کم بودن تعداد نمونه‌ها محدودیت چشم گیری ایجاد نکرده است. نتیجه گیری نهایی تحقیق معرفی و ارائه مدل طراحی شده شبکه عصبی

مصنوعی به کمک پارامترهای ژئومورفولوژیکی حوضه آبخیز رودخانه مزبور می‌باشد. این مدل از نوع شبکه پیش خور با الگوریتم پس انتشار خطابا دو لایه مخفی و ۴ نرون در هر لایه مخفی بوده و قابلیت پیش‌بینی و شبیه‌سازی بار رسوب جریان را با کمترین محدودیت دارد.

نتایج حاصل از مدل سازی 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، می‌باشد، منجر به توسعه و بهبود مدل سازی بار رسوب با استفاده از پارامترهای ژئومورفولوژی حوضه گردیده است. بنابراین استفاده از خصوصیات ژئومورفولوژی حوضه در مدل سازی هیدرولوژی به عنوان یک رکن اساسی و کارآمد توصیه می‌شود.

منابع

- Agarwal, A., Mishra, S.K., Sobha R Singh J. K., 2006.** Simulation of runoff and sediment yield using artificial neural networks. *J. Biosystems engineering* 94, 597–613.
- Alp, M., Cigizoglu, H.K., 2007.** Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. *Environmental modeling and software*. 22:2-13.
- Bhattacharya, B., Price, R.K., 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., Kisi, O., 2006.** Methods to improve the neural network performance in suspended sediment estimation. *Journal of Hydrology*. 317:221-238.
- Cigizoglu, H.K., Alp, M., 2006.** Generalized regression neural network in modeling river sediment yield. *J. Advance in Engineering software*. 37:63-68.
- Flood, I., Kartman .N. 1996.** Neural network in civil engineering :principles and understanding .*J. of computing in civil engineering*, 8(2).131-148.
- Harvey, R.L. 1996.** Neural network principles, Englewood cliffs, NJ. Prentice Hall.
- Kisi, O., 2004.** Multi-layer perceptions with Levenberg–Marquardt training algorithm for suspended sediment concentration prediction and estimation. *Hydrological Sciences Journal* 49, 1025–1040.
- Ripley, B.D. 1996.** Neural networks and related methods of classification. *J. of Royal statistical society*, 56(3),409-456.
- Sarangi, A., 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.
- Schalkoff, R.G., 1997.** Artificial neural networks , McGraw-Hill.
- Sivakumar, B., Jayawardena, 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., 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., 2001.** Factors controlling sediment yield from small intensively cultivated catchments in a temperate humid climate. *Geomorphology* 40, 123-144.
- Verstraeten, G., Poesen, J., de Vente, J., Koninckx, X., 2003.** Sediment yield variability in Spain: a quantitative and semiquantitative analysis using reservoir sedimentation rates. *Geomorphology* 50, 327-348.
- Yitian, L., Gu, R.R., 2003.** Modeling flow and sediment transport in a river system using an artificial neural network. *Environmental Management* 31 (1), 122-134.
- Zhang, B., 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., 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.

