

پیش‌بینی رواناب و رسوب به کمک شبکه عصبی مصنوعی و رگرسیون چندمتغیره در مارن‌های آغاچاری

❖ مهدی وفاخواه*؛ دانشیار گروه آبخیزداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس
❖ همزه سعیدیان؛ دکتری آبخیزداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس

چکیده

پدیده فرسایش و انتقال رسوب یکی از پیچیده‌ترین مسائل مدیریت حوزه زه‌کشی رودخانه‌هاست که در بررسی طرح‌های آبی اهمیت بسیاری دارد و اندازه‌گیری آن مستلزم صرف وقت و هزینه فراوانی است. مسئله رواناب سطحی در حوزه آبخیز رودخانه‌ها نیز موضوع پیچیده‌ای است که اطلاعات و فهم دانش بشری از قوانین فیزیکی حاکم بر آن بعضاً از دیدگاه روابط ریاضی محدود است. در این تحقیق، به منظور مدل‌سازی تولید رواناب و رسوب کاربری‌های مختلف نهشته‌های سازند آغاچاری، بخشی از حوزه آبخیز مرغا در شهرستان ایذه به مساحت ۱۶۰۹ هکتار انتخاب شد. در این تحقیق، از برخی متغیرهای فیزیکی و شیمیایی خاک شامل درصد ماسه خیلی ریز، شن، رس، سیلت، اسیدیت، هدایت الکتریکی، رطوبت، کربنات کلسیم و شوری خاک و رواناب و رسوب در کاربری‌های مختلف سازند آغاچاری برای مدل‌سازی استفاده شد. بدین منظور از دستگاه شبیه‌ساز باران در ۷ نقطه و با ۳ تکرار در سه شدت مختلف ۰/۷۵، ۱، و ۱/۲۵ میلی‌متر در دقیقه در سه کاربری مرتع، منطقه مسکونی، و اراضی کشاورزی میزان رواناب و رسوب اندازه‌گیری شد. همچنین، به همین تعداد، نمونه خاک از عمق ۰-۲۰ سانتی‌متری برداشت شد. در مجموع، تعداد ۱۲۶ نمونه رواناب و رسوب جمع‌آوری شد و ۱۸۹ آزمایش خاک انجام شد. به منظور تجزیه و تحلیل‌های آماری از نرم‌افزارهای 11.5 SPSS، Excel، و Matlab 2008 استفاده شد. نتایج نشان داد که رگرسیون چندمتغیره در شرایطی با داده‌های ورودی زیاد و خروجی کم نتایج مطلوب‌تری در مقایسه با شبکه عصبی مصنوعی نشان می‌دهد. در شدت‌های بالای بارش به علت همگنی داده‌ها عملکرد شبکه عصبی نسبت به شدت‌های پایین بارش بهتر می‌شود. ولی، رگرسیون چندمتغیره در همه شدت‌های بارش بالا و پایین عملکرد بسیار قابل قبولی نشان داد. متوسط خطای نسبی در هر سه کاربری در میزان تولید رسوب در شدت بارش ۰/۷۵ میلی‌متر در دقیقه در رگرسیون چندمتغیره ۷/۲ درصد و میزان مجذور میانگین مربعات خطا ۰/۰۶ است و در شبکه عصبی در همین شدت متوسط خطای نسبی ۱۴۶/۹ درصد و مجذور میانگین مربعات خطا ۰/۴۱ است. متوسط خطای نسبی در هر سه کاربری در میزان تولید رسوب در شدت بارش ۱ میلی‌متر در دقیقه در رگرسیون چندمتغیره ۱/۸ درصد و میزان مجذور میانگین مربعات خطا ۰/۳۸ است و در شبکه عصبی در همین شدت متوسط خطای نسبی ۳۷/۶ درصد و مجذور میانگین مربعات خطا ۰/۷۳ است.

واژگان کلیدی: حوزه آبخیز مرغا، سازند آغاچاری، شبکه عصبی مصنوعی، فرسایش خاک

مقدمه

در دهه‌های اخیر گام‌های بزرگی در زمینه درک فرایندهای رسوب و رواناب سطحی از طریق مدل‌سازی برداشته شده است، به طوری که برای تعیین کمیت رسوب سه روش عمده مطرح است که در قالب جعبه سیاه، جعبه سفید، و جعبه خاکستری گنجانده شده است [۹]. از میان ابزارهای محاسباتی رگرسیون چندمتغیره و شبکه عصبی مصنوعی کاربرد بیشتری برای مدل‌سازی هیدرولوژیکی نسبت به بقیه ابزارها دارند [۲۲]. شبکه عصبی مصنوعی مزیت‌های زیادی دارد، از جمله می‌توان اشاره کرد به شبیه‌سازی هر سیستم غیرخطی بدون فرض قبلی از فرایند همچنین، وقتی که اطلاعات ورودی ناقص یا مبهم اند روش بسیار خوبی برای پیش‌بینی است [۳]. این شبکه‌ها مبتنی بر فرایند یادگیری داده‌ها و اطلاعات ذخیره شده‌اند [۴] و به دلیل ویژگی‌هایی همچون پردازش موازی، هوشمندی، و انعطاف‌پذیری جایگاه چشم‌گیری برای خود باز کرده‌اند و قابلیت مدل‌سازی، تخمین، و پیش‌بینی دارند [۲۰]. شبکه عصبی مصنوعی، همچنین، به توضیح صریح طبیعت پیچیده این فرایند به صورت ریاضی نیازی ندارد [۲۳]. در همین راستا، شبکه عصبی مصنوعی برای پیش‌بینی ظرفیت نگه‌داری رطوبت و هدایت هیدرولیکی در حالت اشباع با استفاده از خصوصیات خاک شامل مقادیر شن، سیلت، رس، گراول، وزن مخصوص ظاهری، و تخلخل به‌کار گرفته شد و نتیجه گرفتند که به طور کلی با افزایش تعداد داده‌ها پیش‌بینی ظرفیت نگه‌داری رطوبت و هدایت هیدرولیکی در حالت اشباع بهبود می‌یابد [۱۵]. شبکه عصبی مصنوعی برای مشاهده تغییرات رسوب در کاربری‌های مختلف با داده‌های ورودی بارش، رواناب، و ضریب رواناب استفاده شد. ایشان نتیجه گرفتند که روش شبکه عصبی مصنوعی، نسبت به

رگرسیون چندمتغیره، برازش خوبی برای داده‌ها ایجاد می‌کند [۱]. از سیستم اطلاعات جغرافیایی و شبکه عصبی مصنوعی در هندوستان برای پیش‌بینی رواناب استفاده شد. نتایج نشان داد که همبستگی نزدیکی بین داده‌های پیش‌بینی و مشاهده‌ای وجود دارد [۲۱]. امکان برآورد سریع هدایت آبی اشباع خاک توسط شبکه عصبی مصنوعی بررسی شد و نتیجه گرفتند که شبکه عصبی مصنوعی در مقایسه با روابط رگرسیونی عملکرد بهتری دارد [۱۷]. پیش‌بینی رواناب مربوط به ریزش‌های جوی ۲۱ آبخیز در کانادا انجام شد. نتایج نشان داد که شبکه عصبی مصنوعی کارایی بالایی نسبت به مدل‌های رگرسیونی خطی دارد [۶]. در امریکا مقایسه مدل‌های رگرسیونی با شبکه عصبی مصنوعی برای پیش‌بینی بار معلق رسوبات رودخانه‌ها انجام شد. آن‌ها نتیجه گرفتند که شبکه عصبی مصنوعی قابلیت پیش‌بینی بهتری نسبت به رگرسیون چندمتغیره دارد [۲]. در بسیاری از پژوهش‌های مربوط به برآورد فرسایش و تولید رسوب به بهره‌گیری و استفاده از باران‌ساز اقدام شده است. با شبیه‌سازی باران، رواناب و رسوب تولیدشده توسط یک بارش استاندارد روی پلاتی با شیب و مساحت استاندارد تعیین می‌شود. باران‌ساز در مقیاس پلات برای تخمین هدررفت خاک در مقیاس حوزه آبخیز مناسب است و میزان آسیب‌پذیری خاک‌ها را نشان می‌دهد [۱۲]. مدل رگرسیونی چندمتغیره و استفاده از باران‌ساز با قطرات تولیدی در حد متوسط ابزار ارزشمندی برای پیش‌بینی رسوب‌زایی آبخیز است [۱۴].

با توجه به تحقیقات ذکر شده، یکی از مشکلات موجود در طرح‌های حفاظت خاک و کنترل فرسایش آن است که سازندها از نظر حساسیت به فرسایش رتبه‌بندی نشده‌اند. بنابراین، بررسی حساسیت نهشته‌ها به عنوان قشر خارجی پوسته زمین و در معرض فرسایش در امر حفاظت خاک و کنترل

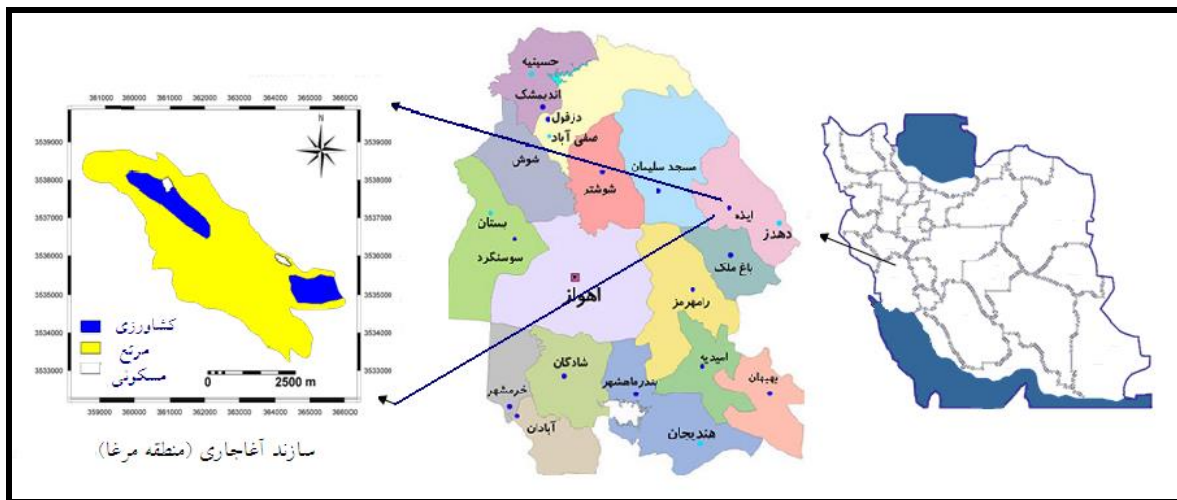
مصنوعی در استفاده از متغیرهای خاکی در تخمین رواناب و رسوب است. در این صورت لزوم آزمایش‌های پرهزینه و زمان‌بر تعیین مقادیر رواناب و رسوب به حداقل می‌رسد و تخمین مقادیر کاربردی آن ممکن خواهد بود.

روش‌شناسی

خصوصیات منطقه تحقیق

منطقه مورد مطالعه بخشی از حوزه آبخیز مرغا واقع در شهرستان ایذه است به مساحت ۱۶۰۹ هکتار و ارتفاع متوسط ۷۵۰ متر از سطح دریا، در محدوده طول جغرافیایی ۴۹°۳۰ تا ۴۹°۳۵ شرقی و عرض جغرافیایی ۳۱°۵۵' تا ۳۱°۵۸' شمالی (شکل ۱).

فرسایش بسیار ضروری است. در این تحقیق حساسیت نهشته‌های سازند آغاچاری به فرسایش سطحی بر پایه مطالعات صحرایی، آزمایشگاهی، و آمار رسوب ناشی از شبیه‌ساز باران بررسی شده است. با توجه به اینکه رواناب و رسوب به پارامترهای فیزیکی و شیمیایی خاک وابسته است، در راستای ارزیابی این روش جدید که محدودیت‌های روش دیگر را نداشته است و با فرض اینکه رواناب و رسوب را به کمک پارامترهای زودیافت خاک، خصوصاً در مورد حجم پایین داده‌ها، با ارائه مدل شبکه عصبی مصنوعی می‌توان برآورد نمود، تحقیق حاضر انجام شده است. در واقع، هدف از این تحقیق ارزیابی دقت رگرسیون چندمتغیره و شبکه عصبی



شکل ۱. موقعیت منطقه مورد مطالعه در استان خوزستان و ایران

نهشته‌های سازند آغاچاری در منطقه مورد مطالعه، از یک دستگاه شبیه‌ساز باران صحرایی (مدل تهیه‌شده در دانشگاه کشاورزی واگنینگن هلند) - که مرکز تحقیقات حفاظت خاک و آبخیزداری کشور آن را ساخته است - استفاده شد. شبیه‌ساز باران مورد استفاده با اندازه پلات ۶۲۵ سانتی‌متر مربع طراحی شده و کاملاً استاندارد و به راحتی قابل حمل است. این شبیه‌ساز باران برای تعیین خصوصیات فرسایشی خاک، میزان نفوذ آب، و همچنین برای تحقیقات

روش تحقیق

برای اجرای این تحقیق، نقشه‌های توپوگرافی ۱:۵۰۰۰۰ منطقه، زمین‌شناسی ۱:۱۰۰۰۰۰، کاربری اراضی (با استفاده از عکس‌های هوایی، پیمایش‌های صحرایی، و سامانه موقعیت‌یاب مکانی)، شیب و داده‌های بارش (برای به دست آوردن شدت غالب بارش منطقه) از سازمان‌های مربوطه تهیه شد. در این تحقیق، به منظور اطلاع از میزان رواناب و رسوب

خاک مناسب و استفاده از آن به منظور تعیین فرسایش پذیری نهشته‌های سطحی در صحرا روشی استاندارد به شمار می‌رود [۱۲]. پس از آماده‌نمودن محل آزمایش و نصب و تنظیم باران‌ساز، شیر مخزن را باز شد و، به محض مشاهده ریزش باران از صفحه ریزش، کرنومتر روشن شد [۲۷]. در فواصل زمانی ۱۰ دقیقه، میزان رواناب و رسوب خارج‌شده از پلات جمع‌آوری شد و در ظروف شماره‌گذاری‌شده جداگانه نگهداری شد. پس از پایان آزمایش، نمونه‌ها به آزمایشگاه منتقل شد و رسوب موجود در نمونه به وسیله کاغذ صافی جدا شد و پس از خشک‌نمودن در آون تحت حرارت ۱۰۵ درجه سانتی‌گراد توزین شد [۱۸]. بدین ترتیب، میزان رسوب در فواصل زمانی مناسب برای هر آزمایش حاصل گردید. در هر آزمایش از مجاورت هر پلات نمونه خاک سطحی (۰ - ۲۰ سانتی‌متر) به منظور آزمایش‌های فیزیکی و شیمیایی خاک برداشت شد و سپس به آزمایشگاه منتقل گردید [۵]. نمونه‌ها در آزمایشگاه برای تعیین خصوصیات فیزیکی و شیمیایی خاک شامل بافت، درصد ماسه خیلی ریز، رطوبت، اسیدیته، ماده آلی، هدایت الکتریکی، و کربنات کلسیم تجزیه شدند [۲۵]. روش‌های اندازه‌گیری به‌کاررفته عبارت‌اند از: بافت به روش هیدرومتری، درصد ماسه خیلی ریز توسط الک، درصد ماده آلی به کمک سوزاندن به روش تر، هدایت الکتریکی و اسیدیته پس از تهیه عصاره اشباع به وسیله EC متر و pH متر دیجیتال و درصد کربنات کلسیم رسوبات نیز با استفاده از روش کلسیمتری و همچنین رطوبت وزنی از اختلاف خاک قبل و بعد از خشک‌کردن توسط آون در دمای ۱۰۵ درجه سانتی‌گراد تعیین گردید [۲۶]. در این تحقیق، نمونه‌ها به صورت تصادفی در کاربری‌های مختلف مشخص و برداشت شد. کلیه اطلاعات مربوط به مطالعات مختلف حوزه آبخیز، شامل اقلیم و

زمین‌شناسی، جامعه آماری این تحقیق اند. با توجه به برآورد هزینه و زمان، حداقل ۷ سطح (۷ مکان جداگانه) انتخاب شد و در هر سطح ۳ بار تکرار برای به‌کارگیری باران‌ساز مشخص شد و به همین تعداد نمونه رسوب و رواناب برداشته شد، که سه نوع نقطه در کاربری مرتج، دو نقطه در کاربری زراعی، و دو نقطه در کاربری مسکونی است. در مجموع، تعداد ۱۲۶ نمونه رواناب و رسوب جمع‌آوری شد و ۱۸۹ آزمایش خاک انجام شد. به منظور اجرای رگرسیون چندمتغیره از نرم‌افزار SPSS نسخه ۱۱/۵ استفاده شد و سپس مدل‌های نهایی تعیین گردید. توضیح این نکته لازم است که در استفاده از رگرسیون چندمتغیره به روش گام به گام^۱ در این تحقیق مقدار رسوب و رواناب حاصل از به‌کارگیری باران‌ساز در شدت‌های مختلف بارش - که با توجه به شدت غالب منطقه به‌دست آمده - به عنوان متغیر وابسته و سایر پارامترهای فیزیکی و شیمیایی خاک در هر کاربری اراضی به عنوان متغیر مستقل مطالعه شد. در نهایت، روابط با خطای نسبی تخمین کمتر به عنوان مدل‌های برتر و معتبر انتخاب شدند [۷]. همچنین، شرط مجذور میانگین مربعات خطا نزدیک به صفر و ضریب تبیین برای انتخاب مدل نهایی استفاده شد [۱۰]. برای مدل‌سازی رسوب و رواناب با استفاده از شبکه عصبی مصنوعی از نرم‌افزار Matlab 2008 استفاده شد. بر این اساس، داده‌های موجود به سه دسته تقسیم شد، به طوری که ۶۰ درصد داده‌ها برای آموزش^۲، ۲۰ درصد برای صحت‌سنجی^۳، و ۲۰ درصد برای آزمون^۴ استفاده شد [۱۶]. برای اطمینان از اینکه داده‌ها در مدل به طور مساوی رفتار می‌کنند، داده‌ها در مقیاس -۱ و ۱، ۰/۱ و ۰/۹، یا ۰ و ۱ قرار

1. Stepwise
2. Train
3. Validation
4. Test

و خطا تعیین می‌شود، برای تعیین تعداد نرون‌های مطلوب در لایه مخفی شبکه با فرض داشتن یک لایه مخفی و قراردادن مقادیر مختلف نرون در این لایه آموزش داده شد؛ این کار تا دستیابی به مقدار حداقل خطا و مقدار بهینه ضریب تبیین ادامه یافت. بعد از انتخاب ساختار شبکه، به منظور تعیین تابع آستانه، مقدار بهینه تعداد تکرار، ضریب یادگیری، و خطای هدف به صورت آزمون و خطا آزمایش شد. در تحقیق حاضر، از تابع انتقال تانژانت سیگموئید برای لایه اول و تابع انتقال خطی برای لایه دوم، به عنوان بهترین معماری شبکه در این پیش‌بینی، استفاده شد.

نتایج

نتایج به‌دست‌آمده از مقایسه رواناب و رسوب مشاهده‌ای و تخمینی به کمک رگرسیون چندمتغیره و شبکه عصبی مصنوعی به قرار ذیل است:

داده شدند [۸]. بدین منظور، برای استانداردسازی و یکسان‌سازی واحدها نخست داده‌ها با استفاده از رابطه ۱ نرمال شد [۱۹].

(رابطه ۱)

$$X_s = 0.8 \times \left[\frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \right] + 0.1$$

که در آن X_s متغیر استاندارد شده، X_i داده اصلی، X_{\max} حداکثر میزان متغیر، و X_{\min} حداقل میزان متغیر است. بعد از نرمال‌سازی داده‌های ورودی و خروجی، اقدام به انتخاب نوع شبکه گردید. با توجه به تحقیقات متعدد انجام‌شده در زمینه‌های مختلف در دنیا مبنی بر توانایی شبکه چندلایه با الگوریتم پس انتشار خطا [۲۹] و ارائه تخمین مناسب به وسیله شبکه مذکور [۱۱] و نیز توانایی و ارائه تقریب برای هر تابع غیرخطی به وسیله شبکه مذکور [۱۶] از این شبکه در مدل‌سازی رواناب و رسوب استفاده شد. با توجه به اینکه تعداد نرون در لایه مخفی توسط سعی

جدول ۱. میانگین متغیرهای خاکی در کاربری‌های مختلف نهشته‌های سازند آغاچاری

کاربری	Svf%	Cly%	Slt%	Sa%	Om%	EC (ds/m)	pH	Cac%	Wn%
مرتع	۸۴٫۶	۲۳٫۵	۳۴٫۲	۴۲٫۲	۰٫۶۳	۰٫۲۷	۷٫۳۴	۴۱٫۱	۱٫۴۹
کشاورزی	۸۷٫۱	۳۸٫۳	۳۵	۲۶٫۶	۰٫۵۵	۰٫۶۸	۷٫۰۵	۴۱٫۲	۱٫۷۶
مسکونی	۷۹٫۹	۲۴٫۳	۳۰٫۳	۴۵٫۳	۱٫۰۳	۰٫۳۸	۷٫۱۵	۴۰٫۶	۱

درصد ماسه خیلی ریز (Svf)، درصد سیلت (Slt)، درصد رس (Cly)، درصد شن (Sa)، اسیدیته (pH)، درصد رطوبت وزنی (Wn)، درصد کربنات کلسیم (Cac)، شوری خاک (E)، و درصد ماده آلی (Om)

جدول ۲. میانگین رواناب و رسوب در شدت‌های مختلف بارش در کاربری‌های مختلف نهشته‌های سازند آغاچاری

کاربری	رسوب شدت	رواناب شدت	رسوب شدت	رواناب شدت	رسوب شدت	رواناب شدت
مرتع	۱٫۷۳	۲۳۸٫۸	۳٫۹۷	۲۸۱٫۴	۷٫۸۵	۳۶۵٫۷
کشاورزی	۳٫۵۵	۱۴۵٫۸	۶٫۷۹	۲۱۶٫۳	۱۱٫۱۲	۳۱۰٫۱
مسکونی	۱٫۰۱	۲۳۰٫۵	۴٫۲۳	۲۷۵٫۴	۸٫۲۰	۴۵۰٫۱

جدول ۳. مدل شبکه عصبی در میزان رسوب شدت بارش ۰/۷۵ میلی‌متر در دقیقه

ریشه میانگین مربعات خطا (RMSE)		ضریب تعیین (R^2)		آرایش شبکه		
آموزش	صحت‌سنجی	آزمون	آموزش	صحت‌سنجی	آزمون	
۰/۰۰۱۲۲	۰/۰۵۰۲	۰/۱۶	۰/۹۸	۰/۹۰	۰/۷۹	۹ - ۱۰ - ۱

جدول ۴. مدل شبکه عصبی در میزان رسوب شدت بارش ۱ میلی‌متر در دقیقه

ریشه میانگین مربعات خطا (RMSE)		ضریب تعیین (R^2)		آرایش شبکه		
آموزش	صحت‌سنجی	آزمون	آموزش	صحت‌سنجی	آزمون	
۰/۱۱۴۴	۰/۱۸۵۷	۰/۳۷۶	۰/۷۰	۰/۸۲	۰/۹۶	۹ - ۸ - ۱

جدول ۵. مدل شبکه عصبی در میزان رسوب شدت بارش ۱/۲۵ میلی‌متر در دقیقه

RMSE		R^2		آرایش شبکه		
آموزش	صحت‌سنجی	آزمون	آموزش	صحت‌سنجی	آزمون	
۰/۰۰۴۶۴	۰/۰۴۲۸	۰/۱۵۶۶	۰/۹۸	۰/۹۰	۰/۶۸	۹ - ۷ - ۱

جدول ۶. مدل شبکه عصبی در میزان رواناب شدت بارش ۰/۷۵ میلی‌متر در دقیقه

ریشه میانگین مربعات خطا (RMSE)		ضریب تعیین (R^2)		آرایش شبکه		
آموزش	صحت‌سنجی	آزمون	آموزش	صحت‌سنجی	آزمون	
۰/۰۹۳۳	۰/۱۱۷	۰/۱۹۹	۰/۸۴	۰/۸۸	۰/۸۸	۹ - ۱۴ - ۱

جدول ۷. مدل شبکه عصبی در میزان رواناب شدت بارش ۱ میلی‌متر در دقیقه

ریشه میانگین مربعات خطا (RMSE)		ضریب تعیین (R^2)		آرایش شبکه		
آموزش	صحت‌سنجی	آزمون	آموزش	صحت‌سنجی	آزمون	
۰/۰۹۲۴	۰/۰۹۶۶	۰/۰۱۲۷	۰/۹۲	۰/۹۶	۰/۹۰	۹ - ۳ - ۱

جدول ۸. مدل شبکه عصبی در میزان رواناب شدت بارش ۱/۲۵ میلی‌متر در دقیقه

ریشه میانگین مربعات خطا (RMSE)		ضریب تعیین (R^2)		آرایش شبکه		
آموزش	صحت‌سنجی	آزمون	آموزش	صحت‌سنجی	آزمون	
۰/۰۶۵۵	۰/۰۷۷۵	۰/۱۵۶	۰/۹۴	۰/۹۰	۰/۶۵	۹ - ۱۲ - ۱

جدول ۹. رابطه رسوب تولیدی شدت ۰/۷۵ میلی‌متر در دقیقه با خصوصیات فیزیکی و شیمیایی خاک با استفاده از رگرسیون چندمتغیره

کاربری	مدل	R^2	RE%	RMSE
مرتع	$K = ۰/۷۵۵ + ۳/۶۴۴ EC$	۰/۵۰	۱/۵	۰/۰۶
زراعی	$K = ۴۴/۳۶۵ - ۲/۵۸ Om - ۵/۵۸۴ pH$	۰/۹۸	۰/۸	۰/۰۳
مسکونی	$K = ۰/۲۲۴ + ۰/۰۲۶ slt$	۰/۶۸	۰/۲	۰/۱

درصد سیلت (slt)، هدایت الکتریکی (EC)، اسیدیته (pH)، درصد ماده آلی (Om)، R^2 : ضریب تعیین، RE: درصد خطای نسبی، RMSE: مجذور میانگین مربعات خطا، K: تولید رسوب (گرم در متر مربع)

جدول ۱۰. رابطه رسوب تولیدی شدت ۱ میلی‌متر در دقیقه با خصوصیات فیزیکی و شیمیایی خاک با استفاده از رگرسیون چندمتغیره

کاربری	مدل	R ²	RE%	RMSE
مرتع	$K = 35,67 - 0,398 \text{ svf}$	۰,۵۶	۱,۷	۰,۲۱
زراعی	$K = 184,16 - 25,04 \text{ pH} + 0,14 \text{ sa} - 0,117 \text{ cly}$	۱	۷	۰,۰۱
مسکونی	$K = 2,154 + 5,406 \text{ EC}$	۰,۷۳	۰,۵	۰,۳۵

ماسه خیلی ریز (svf)، درصد رس (cly)، درصد شن (sa)، هدایت الکتریکی (EC)، اسیدیته (pH)، R²: ضریب تعیین، RE: درصد خطای نسبی، RMSE: مجذور میانگین مربعات خطا، K: تولید رسوب

جدول ۱۱. رابطه رسوب تولیدی شدت ۱/۲۵ میلی‌متر در دقیقه با خصوصیات فیزیکی و شیمیایی خاک با استفاده از رگرسیون چندمتغیره

کاربری	مدل	R ²	RE%	RMSE
مرتع	$K = 69,39 - 0,727 \text{ svf}$	۰,۷۹	۰,۴	۰,۲۸
زراعی	$K = -13,107 - 29,92 \text{ pH} + 5,69 \text{ cac}$	۰,۹۸	۳,۵	۰,۱۹
مسکونی	$K = 17,99 - 0,402 \text{ cly}$	۰,۷۷	۰	۰,۷۱

ماسه خیلی ریز (svf)، درصد رس (cly)، اسیدیته (pH)، درصد کربنات کلسیم (cac)، R²: ضریب تعیین، RE: درصد خطای نسبی، RMSE: مجذور میانگین مربعات خطا، K: تولید رسوب

جدول ۱۲. رابطه رواناب تولیدی در شدت ۰,۷۵ میلی‌متر در دقیقه با خصوصیات فیزیکی و شیمیایی خاک با استفاده از رگرسیون چندمتغیره

کاربری	مدل	R ²	RE%	RMSE
مرتع	$K = 450,89 - 2,9 \text{ svf} + 12,57 \text{ EC}$	۰,۷۹	۱۴	۷
زراعی	$K = -193,13 + 275,2 \text{ pH} + 3,53 \text{ cly}$	۰,۹۶	۰,۶۳	۱
مسکونی	$K = 1047,74 - 77,54 \text{ pH} - 6,46 \text{ cac}$	۰,۹۲	۰,۵	۰

ماسه خیلی ریز (svf)، درصد رس (cly)، اسیدیته (pH)، درصد کربنات کلسیم (cac)، هدایت الکتریکی (EC)، R²: ضریب تعیین، RE: درصد خطای نسبی، RMSE: مجذور میانگین مربعات خطا، K: تولید رواناب

جدول ۱۳. رابطه رواناب تولیدی در شدت ۱ میلی‌متر در دقیقه با خصوصیات فیزیکی و شیمیایی خاک با استفاده از رگرسیون چندمتغیره

کاربری	مدل	R ²	RE%	RMSE
مرتع	$K = 557,83 - 3,26 \text{ svf}$	۰,۶۲	۰,۳	۲
زراعی	$K = 1443,42 + 196 \text{ pH} - 63,11 \text{ cac}$	۰,۹۶	۲,۶۸	۲
مسکونی	$K = 225,9 + 3,3 \text{ sa}$	۰,۸۲	۰,۲۶	۴

ماسه خیلی ریز (svf)، درصد شن (sa)، اسیدیته (pH)، درصد کربنات کلسیم (cac)، R²: ضریب تعیین، RE: درصد خطای نسبی، RMSE: مجذور میانگین مربعات خطا، K: تولید رواناب


جدول ۱۴. رابطه رواناب تولیدی در شدت ۱/۲۵ میلی‌متر در دقیقه با خصوصیات فیزیکی و شیمیایی خاک با استفاده از رگرسیون چندمتغیره

کاربری	مدل	R ²	RE%	RMSE
مرتع	$K = 386,13 - 32,39 \text{ om}$	۰,۷۰	۰,۱۱	۲۵
زراعی	$K = 463,54 + 76,36 \text{ om} - 4,8 \text{ cly} - 16,49 \text{ EC}$	۰,۹۸	۰,۱۵	۱
مسکونی	$K = 476,66 + 149,1 \text{ EC} - 3,4 \text{ cly}$	۰,۹۸	۰,۲	۴


درصد رس (cly)، درصد ماده آلی (om)، هدایت الکتریکی (EC)، R²: ضریب تعیین، RE: درصد خطای نسبی، RMSE: مجذور میانگین مربعات خطا، K: تولید رواناب




شکل ۲. مقایسه رسوب مشاهده‌ای و تخمینی در شدت بارش ۰/۷۵ میلی‌متر در دقیقه




شکل ۳. مقایسه رسوب مشاهده‌ای و تخمینی در شدت بارش ۱ میلی‌متر در دقیقه




شکل ۴. مقایسه رسوب مشاهده‌ای و تخمینی در شدت بارش ۱/۲۵ میلی‌متر در دقیقه



شکل ۵. مقایسه رواناب مشاهده‌ای و تخمینی در شدت بارش ۰/۷۵ میلی‌متر در دقیقه



شکل ۶. مقایسه رواناب مشاهده‌ای و تخمینی در شدت بارش ۱ میلی‌متر در دقیقه



شکل ۷. مقایسه رواناب مشاهده‌ای و تخمینی در شدت بارش ۱/۲۵ میلی‌متر در دقیقه

بحث و نتیجه‌گیری

پس از تعیین و معرفی نوع داده‌ها در مرحله ساخت شبکه عصبی مصنوعی، با توجه به نتایج اولیه سعی و خطاهای انجام‌شده، برای یک شبکه عصبی به تعیین ساختار و آموزش شبکه اقدام شد. به عبارت دیگر، شبکه‌های مورد نظر به طور جداگانه با ۲ تا ۲۰ نرون در لایه مخفی شبکه آموزش داده شد، که در شدت‌های مختلف بارش برای رواناب و رسوب شبکه‌های مختلفی ثبت شد و بهترین مدل‌ها با استفاده از ضریب تعیین و مجذور میانگین مربعات خطا به دست آمد. بهترین حالت ثبت‌شده در شدت بارش ۰/۷۵ میلی‌متر در دقیقه در میزان رواناب مربوط به ۱۴ نرون برای لایه میانی است. نمودار آموزش شبکه انتخابی، پس از گذراندن حدود ۵ دور و تغییر وزن، به حداقل میانگین مربعات خطایی برابر ۰/۰۹۳۳ و ضریب تعیین ۰/۹۲۹ دست یافت. ذکر این نکته لازم است که سایر قوانین و مقادیر میزان یادگیری دقتی کمتر از موارد انتخاب‌شده نشان داد. بهترین حالت ثبت‌شده در شدت بارش ۰/۷۵ میلی‌متر در دقیقه در میزان رسوب مربوط به ۱۰ نرون برای لایه میانی است. نمودار آموزش شبکه انتخابی، پس از گذراندن حدود ۷ دور و تغییر وزن مربوطه، به حداقل میانگین مربعات خطایی برابر ۰/۰۰۱۲۲ و ضریب تعیین ۰/۹۹ دست یافت. بهترین حالت ثبت‌شده در شدت بارش ۱ میلی‌متر در دقیقه در میزان رواناب مربوط به ۳ نرون برای لایه میانی است. نمودار آموزش شبکه انتخابی، پس از گذراندن حدود ۸ دور و تغییر وزن مربوطه، به حداقل میانگین مربعات خطایی برابر ۰/۰۹۲۴ و ضریب تعیین ۰/۹۶ دست یافت. بهترین حالت ثبت شده در شدت بارش ۱ میلی‌متر در دقیقه در میزان رسوب مربوط به ۸ نرون برای لایه میانی است. نمودار آموزش شبکه انتخابی پس از گذراندن حدود ۶ دور و تغییر وزن

مربوطه به حداقل میانگین مربعات خطایی برابر ۰/۱۱۴۴ و ضریب تعیین ۰/۸۴ دست یافت. بهترین حالت ثبت شده در شدت بارش ۱/۲۵ میلی‌متر در دقیقه در میزان رواناب مربوط به ۱۲ نرون برای لایه میانی است. نمودار آموزش شبکه انتخابی پس از گذراندن حدود ۵ دور و تغییر وزن مربوطه به حداقل میانگین مربعات خطایی برابر ۰/۰۶۵۵ و ضریب تعیین ۰/۹۷ دست یافت. بهترین حالت ثبت شده در شدت بارش ۱/۲۵ میلی‌متر در دقیقه در میزان رسوب مربوط به ۱۲ نرون برای لایه میانی است. نمودار آموزش شبکه انتخابی، پس از گذراندن حدود ۷ دور و تغییر وزن مربوطه، به حداقل میانگین مربعات خطایی برابر ۰/۰۴۶۴ و ضریب تعیین ۰/۹۹ دست یافت. نتایج پیش‌بینی‌های مدل شبکه عصبی و مدل‌های آماری چندمتغیره تهیه‌شده در مقابل مقادیر واقعی اندازه‌گیری‌شده در بخش نتایج نشان داده شد. متوسط خطای نسبی در هر سه کاربری در میزان تولید رسوب در شدت بارش ۰/۷۵ میلی‌متر در دقیقه در رگرسیون چندمتغیره ۷/۲ درصد و میزان مجذور میانگین مربعات خطا ۰/۰۶ است، و در شبکه عصبی در همین شدت متوسط خطای نسبی ۱۴۶/۹ درصد و مجذور میانگین مربعات خطا ۰/۴۱ است. متوسط خطای نسبی در هر سه کاربری در میزان تولید رسوب در شدت بارش ۱ میلی‌متر در دقیقه در رگرسیون چندمتغیره ۸/۵ درصد و میزان مجذور میانگین مربعات خطا ۰/۱۹ است، و در شبکه عصبی در همین شدت متوسط خطای نسبی ۹۶/۳۶ درصد و مجذور میانگین مربعات خطا ۰/۸۵ است. متوسط خطای نسبی در هر سه کاربری در میزان تولید رسوب در شدت بارش ۱/۲۵ میلی‌متر در دقیقه در رگرسیون چندمتغیره ۱/۸ درصد و میزان مجذور میانگین مربعات خطا ۰/۳۸ است، و در شبکه عصبی در همین شدت متوسط خطای نسبی ۳۷/۶ درصد و

می‌دهد که شبکه عصبی مصنوعی با ورودی‌های زیاد قادر به پیش‌بینی دقیق مقادیر مشاهده‌ای نیست و فقط با ورودی‌های کم و حجم داده‌های زیاد قادر به پیش‌بینی دقیق‌تر از مدل‌های آماری است. رگرسیون چندمتغیره نشان داد که برای شرایط پیچیده با حجم داده‌های کم بسیار مناسب‌تر است. البته، تغییرات زمانی و مکانی خصوصیات شیمیایی و فیزیکی خاک منطقه و عدم تجزیه و تحلیل هوشمند داده‌ها می‌تواند دلیل ضعف عملکرد شبکه‌های عصبی مصنوعی، نسبت به رگرسیون چندمتغیره در مطالعه یادشده، باشد. در شدت‌های بارش بیشتر مدل‌های آماری و شبکه عصبی تخمین قابل قبول‌تری نشان دادند. البته، قضاوت در این مورد نیازمند تحقیقات بیشتر و در دامنه وسیع‌تری است. پیشنهاد می‌شود با تهیه داده‌های بیشتری از مشخصات فیزیکی و شیمیایی خاک و رواناب و رسوب زمینه ارتقای مدل تهیه شود و برنامه ریزی علمی فراهم گردد. این امر سبب افزایش دقت پیش‌بینی مدل‌های تهیه‌شده نیز خواهد شد. به علت اینکه داده‌ها مربوط به سه کاربری مرتع، کشاورزی، و مسکونی است، داده‌ها دارای اختلاف واضحی در رواناب و رسوب است، بنابراین، شبکه عصبی نتوانست تخمین مناسب‌تری، نسبت به رگرسیون چندمتغیره، داشته باشد. محققانی نیز نشان دادند که اگر ناپایداری داده‌ها بالا باشد، شبکه عصبی از مدل‌های رگرسیونی بهتر نخواهد بود [۲۰]. در این تحقیق نیز به علت تغییرات داده‌ها در کاربری‌های مختلف رگرسیون چندمتغیره جواب‌های بهتری نسبت به شبکه عصبی مشاهده شد. ضمناً همخوانی بیشتری بین رواناب مشاهده‌ای و تخمینی در مقایسه با رسوب مشاهده شد؛ این اشاره می‌کند به عدم یقین‌های بیشتر و شرایط پیچیده‌تر در فرایند تولید رسوب - که به‌خوبی با اختلاف در رسوب مشاهده‌ای و تخمینی خود را نشان داده است.

مجدور میانگین مربعات خطا ۰/۷۳ است. متوسط خطای نسبی در هر سه کاربری در میزان تولید رواناب در شدت بارش ۰/۷۵ میلی‌متر در دقیقه در رگرسیون چندمتغیره ۵ درصد و میزان مجدور میانگین مربعات خطا ۳ است، و در شبکه عصبی در همین شدت متوسط خطای نسبی ۲۴ درصد و مجدور میانگین مربعات خطا ۱۳ است. متوسط خطای نسبی در هر سه کاربری در میزان تولید رواناب در شدت بارش ۱ میلی‌متر در دقیقه در رگرسیون چندمتغیره ۱ درصد و میزان مجدور میانگین مربعات خطا ۲ است، و در شبکه عصبی در همین شدت متوسط خطای نسبی ۳۱ درصد و مجدور میانگین مربعات خطا ۱۸ است. متوسط خطای نسبی در هر سه کاربری در میزان تولید رواناب در شدت بارش ۱/۲۵ میلی‌متر در دقیقه در رگرسیون چندمتغیره صفر درصد و میزان مجدور میانگین مربعات خطا ۱۲ است، و در شبکه عصبی در همین شدت متوسط خطای نسبی ۳۲ درصد و مجدور میانگین مربعات خطا ۲۵ است. همان‌گونه که نتایج نشان می‌دهد، مدل‌های آماری نتایج دقیق‌تری را، نسبت به شبکه عصبی مصنوعی، نشان می‌دهند. ضرایب همبستگی به‌دست‌آمده در مدل‌های آماری و شبکه عصبی به یک نزدیک است و نشان می‌دهد که پیش‌بینی مقادیر رواناب و رسوب در شدت‌های مختلف بارش بسیار مناسب است، ولی شبیه‌سازی توسط مدل‌های آماری برای پیش‌بینی مقادیر رواناب و رسوب با استفاده از پارامترهای فیزیکی و شیمیایی به واقعیت نزدیک است. همچنین، از مقایسه مقادیر ضریب تعیین، مجدور میانگین مربعات خطا، و خطای نسبی مشخص شد که دقت پیش‌بینی‌های شبکه عصبی مصنوعی کمی پایین‌تر از مدل‌های آماری است. این نتیجه با نتایج محققان پیشین [۱، ۲، ۲۹] به علت ورودی‌های کمتر در شبکه عصبی مصنوعی مغایرت دارد. این نتیجه نشان

References

- [1] Abrahart, R.J. and White, S.M. (2001). Modelling sediment transfer in Malawe: comparing backpropagation neural network solution against a multiple linear regression benchmark using small data sets. *Physics and Chemistry of the Earth*, 26, 19-24.
- [2] Alp, M and Kerem Cigizoglu, H. (2009). Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. *Environmental Modelling and Software*, 22, 2-13.
- [3] ASCE (2000). Artificial neural networks in hydrology: 1. Preliminary concepts. *Journal of Hydrologic Engineering*, 5, 115-123.
- [4] Asghari moghadam, A., Norani, V. and Nadiri, A. (2008): Modeling of Tabriz plain rainfall using neutral networks. *Agriculture Science Journal*, 18(1), 1-15. (In Persian).
- [5] Barthes, B. and Roose, E. (2002). Aggregate Stability as an Indicator of Soil Susceptibility to Runoff and Erosion; Validation at Several Levels, *Catena*, 47, 133-149.
- [6] Cannon, A.J. and Whitfield, P.H. (2002). Downscaling recent stream - flow conditions in British Columbia, Canada using ensemble neural network. *Journal of Hydrology*, 259, 136-151.
- [7] Das, G. (2000). *Hydrology and Soil Conservation Engineering*. Asoke K. Ghosh, Prentic- Hall of India, 489P.
- [8] Dawson, C.W. and Wilby, R.L. (2001). Hydrological modelling using artificial neural networks. *Progress in Physical Geography*, 25, 80-108.
- [9] Gautam, M.R., Watanabe, K. and Saegusa, H. (2000). Runoff analysis in humid forest catchment with artificial neural network. *Journal of Hydrology*, 235, 117-136.
- [10] Green, I.R.A. and Stephenson, D. (1986). Criteria for comparison of single event models. *Hydrological Sciences Journal*, 31, 395-411.
- [11] Hossaini, S., Ci., Dehmardeh, A., Fathi, P.Ci. and Ceh Mardeh, M. (2007). Application of neutral networks and multi regression in estimation wheat operating in Kurdistan province Ghahve region. *Agriculture Research Journal: Water, Soil, Vegetation in Agriculture*, 1, 41-54.
- [12] Jordan, A. and Martinez-Zavala, L. (2008). Soil Loss and Runoff Rates on Unpaved Forest Roads in Southern Spain after Simulated Rainfall, *Journal of Forest Ecology and Management*, 255, 913-919.
- [13] Kamphorst, A. (1987). A small rainfall simulator for the determination of soil erodibility, Netherlands, *Journal of Agricultural Science*, 35, 407-415.
- [14] Kinnell, P.I.A. (2005). Sediment Transport by Medium to Large Drops Impacting Flows at Subterminal Velocity, *Soil Science Society of America Journal*, 69(3), 902-905.
- [15] Marcel, G.S., Feike, J.L., Martinus, T. and van Genuchten, H. (1998). Neural network analysis for hierarchical prediction of soil hydraulic properties, *Soil Science Society*, 62, 847-855.
- [16] Menhaj, L.P. (1998). *Bases of Neural Networks (Calculative Intelligence)*. First Volume. Amirkabir University of Technology Press. 642P (In Persian).
- [17] Navvabian, M., Liaghat, E.M. and Homaei, M. (2004). Rapid estimation of hydraulic conductivity using neural networks. In: Proceedings of the Second National Student Conference on Water and Soil Resource. Shiraz University Press, pp. 203 -211 (In Persian).
- [18] Raisain, R. (2005). Investigation of erosion and sediment rates in Gargak catchment by using rain simulator, Soil Conservation and Watershed Management Research Institute, Project Research Plan Report, 156 P (In Persian).
- [19] Rajurkar, M.P., Kothyarib, U.C. and Chaube, U.C. (2004). Modeling of the daily rainfall-runoff relationship with artificial neural network. *Journal of Hydrology*, 285, 96-113.

- [20] Ramani, A. and Sedhi, M. (2004). Forecasting of water level changes of Bahar-Hamedan plain using times series. *Water and Wastwater Journal*, 15, 2-49. (In Persian).
- [21] Reddy, S.B. (2003). Estimation of watershed runoff using artificial neural networks. Ph.D Thesis in Agriculture (unpubl.). Post Graduate School, IARI, New Dehli.
- [22] Sarangi, A. and Bhattacharya, A.K. (2005). Comparison of artificial neural network and regression models for sediment loss prediction from Banha watershed in India. *Agricultural Water Management*, 78(3), 195-208.
- [23] Sudheer, K.P., Gosain, A.K. and Ramasatri, K.S. (2002). A data-driven algorithm for constructing artificial neural network rainfall-runoff models. *Hydrological Processes*, 16, 1325-1330.
- [24] Tamari, S., Wösten, J. H.M. and Ruiz-Suarez, J.C. (1996). Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Science Society of America Journal*, 60(6), 1732-1741.
- [25] Vaezi, A.R., Sadeghi, S.H.R., Bahrami, H.A. and Mahdian, M.H. (2008). Modeling the USLE K-factor for calcareous soils in northwestern Iran. *Geomorphology*, 97(3), 414-423.
- [26] Zarinkafsh, M. (1994). *Application Pedology*. University of Tehran Press, 236 P (In Persian).
- [27] Zehtabian, Gh. (1999). *Comparison of runoff and sediment rate in Lehbari marl formation using rain simulator in Gelalmoort subwatershes*. University of Tehran Research Plan Report, 107P (In Persian).
- [28] Zhang, B. and Govindaraju, R. (2003). Geomorphology-based artificial neural networks for estimation of direct runoff over watershed. *Journal of Hydrology*, 273, 18-34.
- [29] Zhu, X.X. and Zhou, L.Y. (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.