

بررسی کارایی مدل‌های شبکه عصبی مصنوعی، نروفازی و رگرسیون چندمتغیره

در شبیه‌سازی میزان رواناب و فرسایش با استفاده از باران‌ساز

صدیقه محمدی^{۱*}: استادیار، گروه آکوژولوژی، پژوهشگاه علوم و تکنولوژی پیشرفت و علوم محیطی، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفتی، کرمان.

تاریخ پذیرش: (۱۳۹۶/۰۳/۰۹)

(تاریخ دریافت: ۱۳۹۵/۰۸/۰۴)

چکیده

تحقیق فوق با هدف تعیین کارایی مدل‌های شبکه عصبی مصنوعی، عصبی- فازی و رگرسیون چند متغیره در شبیه‌سازی حجم رواناب و میزان فرسایش در سه زیر حوضه از حوزه‌های آبخیزشمال غرب ایران اجرا شد. در این پژوهش، براساس خصوصیات بارش مشابه از نظر میزان شدت بارندگی نیم ساعته با دوره بازگشت ۱۰ ساله، با استفاده از دستگاه باران‌ساز مصنوعی انجام شد. برای این منظور، استقرار دستگاه باران‌ساز در ۸۶ سایت انجام و از ۲۱ متغیر محیطی (از خصوصیات توپوگرافی، خاک‌شناسی، پوشش گیاهی و تنوع گونه‌ای) به عنوان ورودی مدل استفاده شد. اعتبارستجوی مدل‌ها با ۱۸ درصد داده‌ها انجام شد. نتایج تحقیق حاضر نشان داد که مدل رگرسیونی چندمتغیره می‌تواند به توجیه ۶۸ و ۴۶ درصد تغییرات به ترتیب متغیرهای حجم رواناب و میزان فرسایش پردازد و کارایی آن در شبیه‌سازی پایین است. طبق نتایج، مدل شبکه عصبی تابع پایه شعاعی در مقایسه با روش پرسپترون چندلایه و مدل نروفازی با ستاریو روش خوش‌های (رویه هیبرید) در مقایسه با روش شبکه، می‌توانند به پیش‌بینی دقیق‌تر پردازنند؛ به طوری که شاخص‌های MAE، RMSE و NSE در مدل بهینه شبکه عصبی، به ترتیب معادل ۰/۱۳۵، ۰/۱۱۴ و ۰/۰۹۹ برای حجم رواناب و ۰/۰۱۱، ۰/۰۰۹ و ۰/۰۹۸ برای میزان فرسایش و در مدل بهینه نروفازی، به ترتیب معادل ۰/۱۳۲، ۰/۰۱۱ و ۰/۰۹۲ برای حجم رواناب و ۰/۰۱۳، ۰/۰۱۱ و ۰/۰۹۸ برای میزان فرسایش حاصل شد. لذا مدل‌های شبکه عصبی با روش تابع پایه شعاعی و نروفازی با ستاریو روش خوش‌های - رویه هیبرید به دلیل کارایی بالا، بهترین مدل‌ها برای شبیه‌سازی فرسایش و رواناب است.

واژگان کلیدی: پرسپترون چندلایه، تابع پایه شعاعی، شبیه‌ساز باران، نروفازی.

۱- مقدمه

برآورد رواناب ناشی از بارش‌های جوی، پایه و مبنای مطالعات بسیاری از طرح‌های مختلف توسعه و بهره‌برداری از منابع آب است. از سوی دیگر برآورد صحیح حجم رسوبات آبی در یک سیستم آبخیز، از مهمترین مسائل در مباحث مهندسی آب، مهندسی رودخانه، منابع آب، تأسیسات، سازه‌های آبی و محیط زیست است که برای ایفای بسیاری از طرح‌ها و برنامه‌های توسعه‌ای به

کار می‌رود (Vali et al., 2011)؛ از این رو برآوردهای دقیق آنها، نه تنها می‌تواند به برآوردهای دقیق‌تر سیل، طراحی و کاهش هزینه‌های ایمنسازی و محاسبه‌ی این دو پارامتر منجر شود، بلکه به دلیل تنگناهای محیطی همواره دارای مشکلات فراوان است. رواناب از جمله پارامترهای پیچیده در مدیریت بهینه‌ی آب است که با تمرکز و تبدیل آن به سیلاب، سالانه خسارات جانی و مالی فراوانی به مراکز صنعتی، شهری و روستایی وارد می‌سازد. همچنین رواناب یک فرایند پایه‌ای فرسایش خاک است (Quansah, 1981) که به هدر رفتن عناصر غذایی، شستشو و انتقال خاک‌های حاصلخیز سطحی و رسوب‌گیری و پر شدن مخازن سدها منجر می‌شود (Perez-Latorre et al, 2010)؛ لذا برآوردهای دقیق حجم رواناب و رسوب بایستی همواره از سوی محققین مدنظر قرار گیرد که این مهم با توجه به مکانیسم پیچیده‌ی آنها، می‌تواند در ارائه‌ی برنامه‌ی یک حوزه‌ی آبخیز برای مدیر آن حوزه از اهمیت بالایی برخوردار باشد. از نظر تئوری، استفاده از دستگاه بارانساز مصنوعی به عنوان روشی مرسوم برای بررسی میزان فرسایش، رسوب و رواناب، نه تنها موجب صرفه‌جویی در وقت و هزینه می‌شود، بلکه می‌توان مقدار رواناب و رسوب را به همراه تمامی فرآیندهای دخیل در فرسایش و تولید رسوب پایش کرد (Pan and Shangguan, 2006). اما دستگاه‌های بارانساز هرگز نمی‌توانند شرایط طبیعی را به طور کامل فراهم کنند؛ با این وجود استفاده از بارانسازها به دلیل مزایای فوق، برای پژوهش در زمینه‌ی جنبه‌های مختلف فرسایش و تولید رسوب در سطح جهان رایج است (Hosseini et al., 2009).

Defersha & Mellese (2012) نشان دادند میزان شدت بارندگی، شیب و رطوبت پیشین خاک، بر رسوب تولیدی مؤثر است و میزان غلظت رسوب تولیدی به طور قابل توجهی به رطوبت پیشین خاک وابسته است. Martínez-Murill و همکاران (2013) در پژوهشی در اراضی با تیپ فرسایشی به کمک دستگاه شبیه‌ساز باران، اذعان داشتند که بین عامل شیب و متغیر زمان شروع رواناب، ارتباط قوی وجود ندارد. Zhoa و همکاران (2014) در تحقیقی با بارانساز، به این نتیجه رسیدند که میزان رواناب با شدت بارندگی و رطوبت خاک، رابطه‌ی خطی و مثبت و با متغیر شیب زمین، رابطه‌ی توانی و مثبت دارد. در داخل کشور نیز Zarekhormizi و همکاران (2012) بیان کردند بر عکس اثر ملموس و معنی‌دار شیب بر غلظت رسوب، اثر شیب بر رواناب معنی‌دار نبود. Habibzade و همکاران (2013) به این نتیجه رسیدند که همبستگی بین میزان رواناب و شیب معادل 0.479 است و بین فرسایش خاک با کربن آلی و درصد آهک، به ترتیب همبستگی معنی‌داری به میزان 0.374 و -0.382 وجود دارد. Ebrahimi و همکاران (2015) عواملی چون شدت بارندگی، پوشش گیاهی، شیب زمین و نوع بافت خاک را به عنوان عوامل مؤثر بر آستانه‌ی شروع رواناب معرفی کردند. Zoratipour & ArabKhedri (2016) نشان دادند که شدت باران‌های با دوره بازگشت پایین (2 سال) تأثیر کمتری دارند؛ همچنین درصد شیب در افزایش تلفات خاک، تأثیر تشدید شونده‌ی سه تا شش برابری دارد.

با وجود اینکه استفاده از روابط همبستگی و مدل‌های رگرسیونی، ماهیت روابط را به خوبی در قالب فرمول ارائه می‌دهند، ولی در اکثر موارد دقت شبیه‌سازی این مدل‌ها به دلیل پیچیدگی طبیعت و وجود روابط غیرخطی پایین است که این مهم ضرورت استفاده از سایر مدل‌ها از جمله شبکه عصبی مصنوعی، عصبی-فازی و ... را دوچندان می‌کند. محققین مختلف از شبکه عصبی مصنوعی در برآورد رواناب و رسوب بر پایه‌ی بارش در مناطقی استفاده کردند که ایستگاه باران‌سنگی و هیدرومتری دارد، یا مناطق مرتبط است:

نتایج تحقیقات Heng & Suetsugi (2007) Alp & Cigizogluand & Alp (2006) Cigizogluand & Alp (2006) Jajarmizadeh (2013) و همکاران (2014)، از کارایی بالای مدل‌های هوش مصنوعی حاکی است و نتایج یافته‌های Tahmoures (2013) و همکاران (2015) از برتری مدل نروفازی در مقایسه با سایر مدل‌ها.

در داخل کشور نیز Dastorani و همکاران (2011) به کارایی روش‌های شبکه عصبی و نروفازی در برآورد رواناب بر پایه‌ی پارامترهای ورودی بارش در حوزه‌ی سد زاینده‌رود اذعان داشتند. Vali و همکاران (2011) معتقدند زمانی که پارامترهای ژئومورفوژئیکی نظیر شاخص ناهمواری، گردی و تراکم زهکشی در مدل‌سازی، با روش شبکه عصبی مصنوعی وارد شوند نتایج ارزیابی آنها مناسب‌تر می‌شود. Falamaki و همکاران (2013) نشان دادند که مدل‌های ارائه شده بر پایه‌ی شبکه‌های عصبی با مقادیر رسوب کل مشاهده شده، همخوانی بیشتری دارد؛ همچنین شبکه عصبی پرسپترون چندلایه، می‌تواند مقدار رسوب را در نقاط اوج به خوبی برآورد سازد. Ghafari & Vafakhah (2013)، در شبیه‌سازی رواناب-بارش حوزه‌ی آبخیز حاجی قوشان واقع در استان گلستان نشان دادند که مدل‌های عصبی-فازی نسبت به مدل شبکه عصبی می‌توانند رواناب را با دقت بیشتری پیش‌بینی کنند. در تحقیقی به این نتیجه رسیدند که با استفاده از مدل شبکه عصبی پرسپترون چندلایه از نوع پیش‌رو با الگوریتم آموزشی TRAINLM، می‌توان به شبیه‌سازی رسوب معلق در حوزه‌ی آبخیز چم انجیر استان لرستان با دقتی (ضریب تبیین) معادل ۰/۹۹ و ریشه مربعات خطای معادل ۰/۱ پرداخت. Eshghi و همکاران (2016) نیز به بررسی کارایی مدل‌های هوشمند با سه مدل ماشین بردار پشتیبان، مدل درختان تصمیم‌گیری و شبکه عصبی مصنوعی پرداختند و بیان کردند که در این تحقیق، ضریب تبیین این سه مدل به ترتیب معادل ۰/۹۶، ۰/۹۹ و ۰/۹۸ است.

هر چند تحقیقات مذکور که حاکی از شبیه‌سازی رسوبات خروجی و رواناب حوزه‌های آبخیز به ترتیب براساس داده‌های ایستگاه هیدرومتری و بارش است از اهمیت بالایی برخوردار است؛ اما فقدان توجه به سایر عوامل محیطی مؤثر بر تولید رواناب و رسوب در این تحقیقات، جزو خلاً و کاستی‌ها به شمار می‌رود. این مهم در حالی است که اطلاع از رابطه‌ی تولید رواناب و فرسایش در سطح حوزه‌های آبخیز با عوامل محیطی مؤثر بر آن تحت شدت بارندگی غالب (مشابه) حوزه‌های آبخیز، جنبه‌ای نو برای درک مکانیسم پیچیده‌ی فرایند فرسایش و رواناب است. در این رهگذر استفاده از دستگاه باران‌ساز برای اعمال شدت بارش در حوزه‌های آبخیزی که مشخصات محیطی متفاوت دارند، ضرورتی انکارناپذیر است تا با مدل‌سازی فرسایش

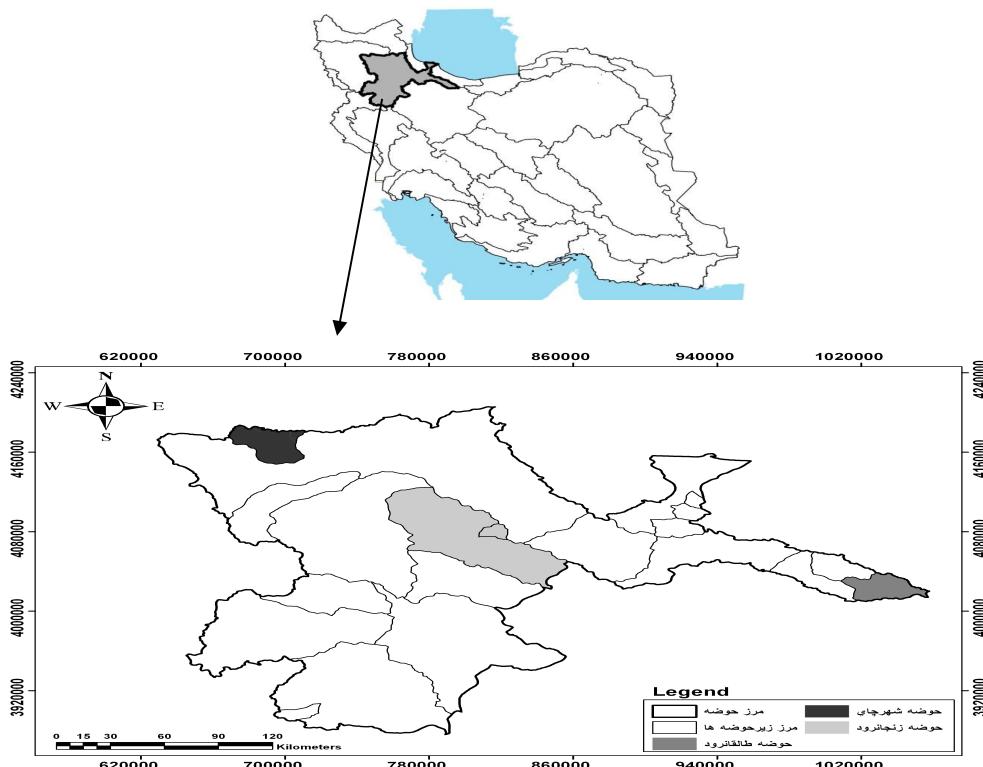
و رواناب بر پایه‌ی عوامل محیطی، گامی در جهت استفاده از این عوامل به عنوان ابزار مدیریتی در سطح حوزه‌های آبخیز، به منظور کاهش دو معضل فرسایش و رواناب برداشته شود. با وجود اینکه در داخل و خارج کشور از مدل‌های شبکه عصبی و نروفازی برای شبیه‌سازی رسوب خروجی حوزه‌های آبخیز در قالب روابط بارش- رواناب و دبی- رسوب به طور گسترده استفاده شده است، اما استفاده از روابط عوامل محیطی با فرسایش، رسوب و رواناب در قالب دستگاه باران‌ساز، کمتر از سوی پژوهشگران قابل توجه قرار گرفته است. در این رابطه، پردازش توزیعی اطلاعات، قابلیت تعیین (یا درونیابی) و پردازش موازی (یا مقاوم بودن) از عمدۀ ترین ویژگی‌های مدل‌های شبکه عصبی مصنوعی و عصبی- فازی است که می‌تواند در شبیه‌سازی دقیق روابط پیچیده‌ی رواناب و رسوب با عوامل محیطی مورد استفاده قرار گیرد. با وجود قابلیت مدل‌های شبکه عصبی و عصبی- فازی و اجرای تحقیقات متعدد در خصوص رسوبات بار معلق رودخانه‌ها بر پایه‌ی رابطه‌ی دبی- رسوب، این مدل‌ها در برآورد رواناب و فرسایش بر پایه‌ی عوامل محیطی حاکم بر حوزه‌های آبخیز، کمتر از سوی پژوهشگران قابل توجه بوده است. در حقیقت، شبکه‌های عصبی مصنوعی یکی از دستاوردهایی هستند که با الگوبرداری از شبکه عصبی مغز انسان، می‌توانند پدیده‌های پیچیده و ناشناخته را به خوبی بررسی کنند (Menhaj, 2002; Misaghi & Mohamadi, 2002). حاکم بودن یک رابطه غیرخطی بین فرسایش و رواناب با عوامل محیطی (Zarekhormizi et al., 2012)، ضرورت استفاده از مدل‌های شبکه عصبی و عصبی- فازی را به منظور پیش‌بینی و مدل‌سازی دقیق آنها دوچندان می‌کند. با توجه به اهمیت آمار دقیق رسوب و پیچیدگی تولید رسوب ناشی از فرایند فرسایش در حوزه‌های آبخیز کشور به دلیل دخیل بودن خصوصیات مختلف حوزه‌ی آبخیز، این تحقیق با هدف تعیین کارایی مدل‌های شبکه عصبی مصنوعی، عصبی- فازی و رگرسیون چندمتغیره در برآورد حجم رواناب و میزان فرسایش در حوزه‌های آبخیز شمال غرب ایران (طالقان، زنجان‌رود و شهرچای) انجام شد.

۲- مواد و روش

۲-۱- برداشت داده‌ها طی عملیات صحرایی و آزمایشگاهی

این تحقیق با هدف شبیه‌سازی باران در حوزه‌های آبخیز شمال غرب کشور و با اعمال شدت بارندگی نیم ساعته با دوره بازگشت ۱۰ ساله صورت گرفت. این امر به دلیل اهمیت بالای این پارامتر در آستانه تولید رواناب و میزان فرسایش و فراوانی وقوع بیشتر اجرا شد؛ به طوری که سه زیرحوضه‌ی طالقان، زنجان‌رود و شهرچای که دارای خصوصیات بارش مشابه از نظر میزان شدت بارندگی نیم ساعته با دوره بازگشت ۱۰ ساله (برابر با مقدار ۳۰ میلی‌متر بر ساعت با توجه به نمودارهای شدت- مدت- فراوانی ایستگاه‌های هواشناسی) هستند، انتخاب شدند. شکل ۱ موقعیت این سه زیرحوضه را در حوزه‌های آبخیز اصلی داخل کشور و حوزه‌ی آبخیز سفیدرود نشان می‌دهد. عملیات صحرایی با استفاده از دستگاه باران‌ساز مرکز تحقیقات حفاظت خاک و آبخیزداری تهران انجام شد. این دستگاه با وزن خالی ۱۱۰ کیلوگرم، از نوع باران‌سازهای غیر فشاری قابل حمل از جنس پلکسی گلامس به ابعاد (۸۹*۱۲۰) سانتی‌متر و حداقل ارتفاع ۱/۵ متر است که با

پایه‌های قابل تنظیم، از قابلیت استقرار در شیب‌های و تعداد ۲۱۶ عدد قطره چکان در صفحه ریزش برخوردار است (Vahabi & Mahdian, 2009).



شکل ۱: موقعیت منطقه تحقیق

مشخصات توپوگرافی (شامل ارتفاع، شیب و ...) محل استقرار بارانساز ثبت شد. سپس قبل از استقرار بارانساز در محل منتخب، ابتدا به منظور حذف عامل مداخله‌گر هتروژنی خاک، برداشت نمونه‌ها از ۴ گوشی پلات از عمق ۰-۲۰ سانتی‌متری خاک انجام شد و با ترکیب این ۴ نمونه خاک از هر سایت، یک نمونه از آن در آزمایشگاه خاک‌شناسی بررسی و خصوصیات آن با روش‌های مختلف اندازه‌گیری شد؛ از جمله مواد آلی خاک با روش سوزاندن مرتبط (Walkley and Black, 1934)، نیتروژن کل به کمک تیتراسیون با اسید سولفیک رقيق در غلظت ۰/۰۵ (McGill and Figueiredo, 1993)، فسفر قابل جذب با روش اولسن (Olsen et al, 1954)، پتاسیم قابل جذب به کمک عصاره‌گیری با محلول استات آمونیوم در اسیدیته ۷ (Simard, 1993)، اسیدیته به کمک دستگاه Ph متر، هدایت الکتریکی خاک با روش کارتر (Zarinkafsh, 1993)، رطوبت خاک با گذاشتن در درجه ۷۰ در درستگاه آون به مدت ۴۷ ساعت، میزان درصد مواد خنثی شونده و میزان گچ با استفاده از روش کلسیمتري (McLeen, 1982)، کاتیون

کلسیم با روش تیتراسیون، کاتیون سدیم به کمک دستگاه فلوم فتومتر، بافت خاک و توزیع اندازه ذرات سیلت، رس و شن خاک با روش هیدرومتری (Zarinkafsh, 1993).

همچنین در محل مطالعه، داده‌های مربوط به مؤلفه‌های پوشش گیاهی شامل درصد پوشش تاجی گونه‌ها، درصد سنگ و سنگریزه، حضور و عدم حضور گونه‌ها در داخل پلات باران‌ساز یادداشت برداری شد. از حضور و عدم حضور گونه‌های گیاهی برای تعیین شاخص‌های مختلف تنوع گونه‌ای (شامل شاخص‌های شمارش گونه، سیمپسون، شانون - وینر و چیرگی) در محیط نرم‌افزاری past استفاده شد. پس از نصب باران‌ساز و اجرای آزمایش، نمونه‌برداری از رواناب انجام و حجم رواناب و میزان فرسایش معلق آن در آزمایشگاه اندازه‌گیری شد.

۲-۲-۱- تجزیه و تحلیل داده‌ها

برای این منظور شاخصه‌های محیطی شامل توپوگرافی، خاک‌شناسی، پوشش گیاهی و تنوع گونه‌ای به عنوان ورودی، برای شبیه‌سازی حجم رواناب و میزان فرسایش با مدل‌های مختلف رگرسیونی، شبکه عصبی و نروفازی استفاده شد.

برای آنالیز داده‌ها نیز پس از تهیه داده‌های ورودی و خروجی، عمل استانداردسازی داده‌ها به عنوان اولین گام، طبق رابطه‌ی زیر انجام شد (Sedighi et al., 2015):

$$a_i = 0.1 + 0.8 \left(\frac{A_i - A_{\min}}{A_{\max} - A_{\min}} \right) \quad (1)$$

که در آن a_i مقدار نرمال شده‌ی داده‌ها، A_i مقدار واقعی داده‌ها، A_{\min} حداقل داده و A_{\max} حداکثر داده مربوط به پارامتر موردنظر است.

که در این رابطه از آنالیز مدل رگرسیونی چند متغیره داده‌ها در محیط نرم‌افزاری SPSS، مدل شبکه عصبی مصنوعی (به دو روش شبکه عصبی پرسپترون چند لایه و پایه شعاعی) و مدل نرو فازی در محیط نرم‌افزاری Matlab کمک گرفته شد.

۲-۲-۱- مدل رگرسیون چندمتغیره

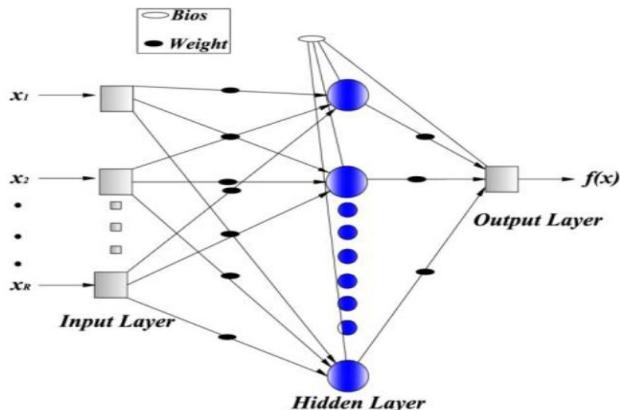
رگرسیون چندمتغیره، روشه‌ی است که برای ارتباط خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل استفاده می‌شود و شکل عمومی آن به شرح زیر است (Farshadfar, 2005):

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \varepsilon_i \quad (2)$$

۲-۲-۲- مدل شبکه عصبی مصنوعی

- روش شبکه عصبی پرسپترون چندلایه (MLP)^۱

شبکه‌ی MLP از چند لایه تشکیل شده است؛ لایه‌ی ورودی، خروجی و لایه‌ی یا لایه‌های مخفی که خروجی لایه‌ی اول بردار ورودی لایه‌ی دوم به حساب می‌آید. به همین ترتیب خروجی لایه‌ی دوم، بردار ورودی لایه‌ی سوم است. تعداد لایه‌های پنهان تا حد امکان باید کم باشد. ثابت شده است که هرتابع می‌تواند حداقل با سه لایه‌ی پنهان تقریب زده شود. ابتدا شبکه با یک لایه پنهان آموزش داده می‌شود که در صورت عملکرد نامناسب، تعداد لایه‌های پنهان افزایش خواهد یافت. شکل ۲ ساختار یک شبکه پرسپترون چند لایه را نشان می‌دهد (Mohamadpour & Mohamadpour, 2014).



شکل ۲: ساختار یک شبکه پرسپترون چند لایه

نحوه‌ی عمل پرسپترون چندلایه بدین صورت است که الگویی به شبکه عرضه و خروجی آن محاسبه می‌شود. مقایسه‌ی خروجی واقعی و خروجی مطلوب، باعث می‌شود که مقادیر وزن‌ها و بیاس‌های شبکه تعییر یابد؛ به طوری که در دفعات بعد، خروجی صحیح‌تری حاصل می‌شود (Menhaj, 2002). در این رابطه، الگوریتم پس انتشار خطرا می‌توان به صورت رابطه‌ی ۳ نشان داد:

$$x_{k+1} = x_k - a_k g_k \quad (3)$$

که در آن x_k بردار وزن‌ها و بیاس در تکرار k ام، a_k درصد آموزش در بردار k ام و g_k گرادیان در تکرار k ام است. در پژوهش حاضر برای آموزش شبکه عصبی، از الگوریتم مارکوارت - لونبرگ استفاده شد. این الگوریتم از سال ۱۹۹۳ تا به امروز به عنوان سریع‌ترین روش آموزش شبکه‌های عصبی شناخته شده است (Menhaj, 2002). جدول ۲، خلاصه‌ی مشخصات شبکه پرسپترون چندلایه استفاده شده را در پژوهش حاضر نشان می‌دهد.

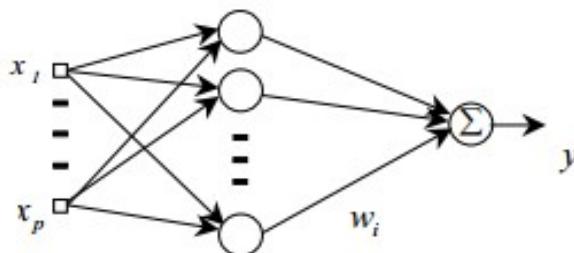
^۱ Multi Layer Perceptron

جدول ۲: خلاصه مشخصات و پارامترهای مورد استفاده در شبکه عصبی پرسپترون چندلایه

مشخصات	پارامترهای مدل
پرسپترون چند لایه (MLP)	ساختار شبکه عصبی
(Feed Forward) پیشرو	نوع شبکه عصبی
TRAINLM	الگوریتم آموزشی
LEARNGMD	تابع یادگیری تطبیقی
MSE	تابع عملکرد خطأ
انتشار برگشتی (Back Propagation)	الگوریتم خطایابی
لونبرگ - مارکواردت	تابع بهینه‌سازی
۲	تعداد لایه پنهان
۳	
۷	تعداد نرون‌های لایه پنهان
۱۰	
.۰۰۱	میزان یادگیری
سیگموئید (Sig)	
تائزات سیگموئید (tansig)	تابع محرک
خطی (purelin)	

- روش تابع پایه شعاعی^۱

شبکه‌های RBF برای آموزش، نیاز به تعداد نورون‌های زیادی دارند. در این شبکه‌ها برخلاف شیوه‌ی رایج در شبکه‌های دیگر، به تمام فضای ورودی به طور یکسان پاسخ داده نمی‌شود. در اینجا ابتدا مرکز فضای ورودی محاسبه می‌شود، سپس به ورودی‌هایی که به اندازه‌ی کافی به این مرکز نزدیک باشند پاسخ داده می‌شود. شبکه‌های RBF دارای دو لایه هستند که لایه‌ی اول آنها از نوع پایه شعاعی بوده و لایه‌ی خروجی آنها از نوع خطی است. شکل ۳ ساختار شبکه‌ای پایه شعاعی را نشان می‌دهد.



شکل ۳: شبکه تابع پایه شعاعی (RBF)

فرایند آموزش نیز در اینجا توسط روش‌های یادگیری رقابتی^۲ یا روش خوش ابزاری^۳ انجام می‌شود. در این رابطه، خروجی k امین گره در لایه‌ی خروجی یعنی Z_{pk} از رابطه‌ی^۴ محاسبه می‌شود.

^۱ Radial Basis Function

^۲ Competitive Learning

^۳ k Means Clustering

(Beal & Jakson, 1998)

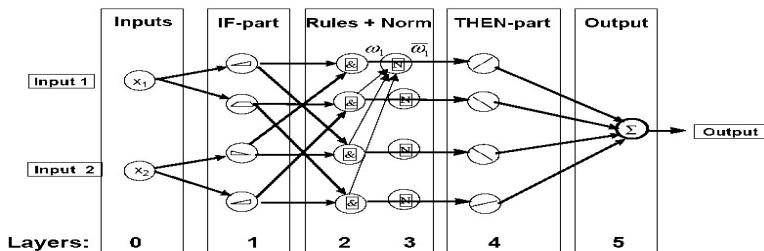
$$z_{pk} = \sum_{i=1}^L y_i w_{kj} \quad (4)$$

که در آن y_i پاسخ i امین گره پنهان و w_{kj} وزن پیوند بین گره‌های خروجی و لایه پنهان است.

۲-۲-۳- مدل نروفازی

این مدل ترکیبی از مدل‌های شبکه مصنوعی با منطق فازی است. نکته‌ی مهم منطق فازی امکان برقراری ارتباط بین فضای ورودی به فضای خروجی است و سازوکار اولیه برای این کار، فهرستی از جملات اگر-آنگاه می‌باشد که قانون نامیده می‌شود. داشتن روشی که با استفاده از آن بتوان اطلاعات موجود را برای ساخت قواعد استفاده کرد، به عنوان ابزاری کارآمد به شمار می‌رود. از طرفی، شبکه‌های عصبی مصنوعی به دلیل قابلیت‌های آموزش‌پذیری با استفاده از الگوهای مختلف آموزشی، می‌تواند ارتباط مناسبی بین متغیرهای ورودی و خروجی ایجاد کند؛ از این رو استفاده‌ی ترکیبی از سامانه‌ی استنباط فازی و شبکه عصبی مصنوعی به عنوان ابزاری قدرتمند – که قابلیت پیش‌بینی نتایج را با استفاده از داده‌های عددی موجود داردند – تحت عنوان سامانه‌ی استنتاج تطبیقی عصبی- فازی معرفی می‌شود.

این سیستم با توجه به توانایی در ترکیب قدرت زبانی یک سیستمی فازی با قدرت عددی شبکه‌ای عصبی، در مدل‌سازی و کنترل سیستم‌های پیچیده موقوفت بسیاری داشته‌است (Shabaninia & Saeednia, 2007). شکل ۴ ساختار یک شبکه‌ی عصبی- فازی را نشان می‌دهد.



شکل ۴: معماری شبکه (Sabziparvar & Bayatvarkeshi, 2010) ANFIS

نروفازی یک سیستم استنتاج فازی از نوع سوگنو است که براساس یک سری داده‌های آموزشی موجود از فرایند مربوطه، قواعد آن به دست آمده و مقادیر بهینه پارامترهای آن تعیین می‌شود. سیستم استنتاج تطبیقی عصبی- فازی شبکه‌ای ۵ لایه‌ای، متشکل از گره‌ها و کمان اتصال‌دهنده گره است. شکل ۳، معماری این لایه‌ها را به نمایش می‌گذارد که در این رابطه:

لایه‌ی ۱: توابع عضویت متغیرهای ورودی به عنوانتابع گره استفاده می‌شود که توسط کاربر مشخص می‌گردد.

لایه‌ی ۲: هر گره در این لایه به گره‌هایی که نمایش دهنده‌ی پیش‌فرض‌های قانون مورد نظر است وصل می‌شود. هر گره در این لایه گره ثابت است که در آن سیگنال‌های ورودی در هم ضرب می‌شوند و حاصل که وزن قانون‌ها است، به دست می‌آید.

لایه‌ی ۳: هر گره در این لایه، عمل محاسبه‌ی وزن نسبی قانون‌ها را انجام می‌دهد.

لایه‌ی ۴: هر گره در این لایه، تابع گره دارد که به تمام ورودی‌ها و گره‌ای در لایه‌ی سوم متصل است.

لایه‌ی ۵: گره در این لایه گره ثابت است و وظیفه‌ی جمع‌بندی تمام خروجی قانون‌ها را برعهده دارد.

هدف آن، به حداقل رساندن اختلاف خروجی به دست آمده از شبکه و خروجی واقعی است.

در راستای تعیین بهترین مدل شبیه‌سازی ANFIS در این تحقیق، برای تخمین متغیرهای حجم رواناب و میزان رسوب با تغییر الگوریتم آموزشی، روش منقطع سازی توابع عضویت ورودی و تعداد توابع عضویت آرایش‌های مختلف اجرا شد و نوع توابع عضویت (مثلثی، گوسی و...) و تعداد آن برای ورودی‌ها و خروجی‌ها به روش سعی و خطأ تعیین شد.

توابع عضویت ورودی ANFIS در مدل شامل مثلثی، ذوزنقه‌ای، زنگوله‌ای، گوسی، گوسی ترکیبی، دو سیگموئیدی و حاصل ضرب دو سیگموئید و توابع عضویت خروجی شامل ثابت و خطی است. در راستای تعیین بهترین مدل شبیه‌سازی ANFIS در این تحقیق، برای تخمین متغیرهای حجم رواناب و میزان رسوب با تغییر الگوریتم آموزشی، روش منقطع سازی توابع عضویت ورودی و تعداد توابع عضویت آرایش‌های مختلف اجرا شد.

۲-۳- اعتبارسنجی مدل‌ها

در نهایت با توجه به مقادیر مشاهده شده و برآورد شده پس از دفازی کردن داده‌ها، اعتبارسنجی مدل‌ها برای ۱۸٪ داده‌ها (۱۵ سایت) با محاسبه‌ی مقادیر ریشه میانگین مربعات خطأ^۱ RMSE، ضریب ناش-ساتکلیف^۲ NSE و دقت^۳ MAE از رابطه‌ی ۵ تا ۷ انجام شد (Issak and Srivastava, 1989):

$$NSE = 1 - \left[\frac{\sum_{i=1}^n (z(x_i) - z^*(x_i))^2}{\sum_{i=1}^n (z(x_i) - z^{mean})^2} \right] \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Z^*(x_i) - Z(x_i)| \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [Z^*(x_i) - Z(x_i)]^2} \quad (7)$$

^۱ Root of Mean Square Error

^۲ Nash-Sutcliffe Efficiency

^۳ Mean Absolute Error

که در آن $Z^*(xi)$ مقدار برآورد شدهٔ متغیر موردنظر، $Z(xi)$ مقدار اندازه‌گیری شدهٔ متغیر موردنظر، Z_{mean} میانگین مشاهده‌ای متغیر، n تعداد داده‌ها، MAE میانگین مطلق خطای نسبت به Z ضریب ناشاتکلیف و RMSE ریشهٔ میانگین مربعات خطای است.

۳- یافته‌ها (نتایج)

نتایج مشخصات آماری متغیرهای مورد بررسی شامل توپوگرافی، خاک‌شناسی، پوشش گیاهی و متغیرهای حجم رواناب و میزان فرسایش ناشی از ۸۶ سایت، در جدول ۳ ارائه شده‌است.

جدول ۳: مشخصات آماری متغیرهای مورد بررسی

متغیر	دامنه	میانگین	کمینه	بیشینه	انحراف معیار
حجم رواناب (سی سی)	۳۳۸۰	۷۸۵/۴۲	۲۰	۳۴۰۰	۷۷۸/۴۷
میزان فرسایش (گرم در لیتر)	۳۰۲/۲	۶۹/۱۴	۵/۸۰	۳۰۸	۶۳/۳۸
ارتفاع (متر)	۱۱۲۴	۱۸۹۹	۱۱۸۷	۲۳۱۱	۲۴۱/۰۶
شیب (%)	۴۲	۳۰/۶۴	۹	۵۱	۱۱/۶۱
سنگ و سنگریزه (%)	۷۰	۱۳/۲۱	۰	۷۰	۱۶/۰۶
پوشش گیاهی (%)	۸۰	۳۵/۶۵	۰	۸۰	۱۹/۴۷
رطوبت خاک (%)	۱۴	۵/۵۰	۲	۱۶	۳/۰۸
هدایت الکتریکی (ds/m)	۵/۸۵	۰/۷۷	۰/۲۵	۶/۱۰	۱/۲۱
آهک (%)	۲۶/۶۰	۱۳/۸۲	۱/۷۰	۲۸/۳۰	۸/۳۶
گچ (%)	۷۴/۸۰	۵۷/۵۴	۱/۶۰	۷۶/۴۰	۲۳/۳۵
کربن آلی (%)	۱/۸۳	۱/۰۱	۰/۱۱	۱/۹۴	۰/۵۳
ازت (%)	۰/۱۱	۰/۰۶	۰/۰۲	۰/۱۳	۰/۰۲۸
فسفر قابل جذب (mg/kg)	۲۰/۳۰	۱۸/۹۱	۹/۷۰	۳۰	۶/۲۸
پتاسیم قابل جذب (mg/kg)	۶۳۵	۳۰۷/۲۵	۱۴۴	۷۷۹	۱۲۶/۷۸
شن (%)	۶۶	۴۸/۷۰	۱۰	۷۶	۲۱/۰۳
سیلت (%)	۳۶	۲۶/۲۵	۶	۴۲	۹/۶۳
رس (%)	۵۴	۲۵/۰۴	۲	۵۶	۱۵/۹۱
کاتیون سدیم	۱۸/۶۱	۲/۱۵	۰/۲۹	۱۸/۹۰	۴/۴۸
کاتیون کلسیم	۴۰/۲۰	۶/۰۹	۱/۴۰	۴۱/۶۰	۹/۴۷
تعداد گونه	۹	۴/۳۰	۱	۱۰	۱/۸۱
شاخص چرگی	۰/۸۷	۰/۴۶	۰/۱۳	۱	۰/۲۱
شاخص شانون	۲/۱۷	۱/۰۱	۰	۲/۱۷	۰/۴۶
شاخص سیمپسون	۰/۸۷	۰/۵۴	۰	۰/۸۷	۰/۲۱

مدل رگرسیونی

نتایج حاصل از مدل بهینه رگرسیونی حجم رواناب و میزان فرسایش به همراه تجزیه‌ی واریانس آنها در جدول ۴ نشان داده شده است. نتایج اعتبارسنجی مدل بهینه رگرسیونی براساس شاخص‌های NASH، MAE و RMSE نیز در جدول ۵ ارائه شده است.

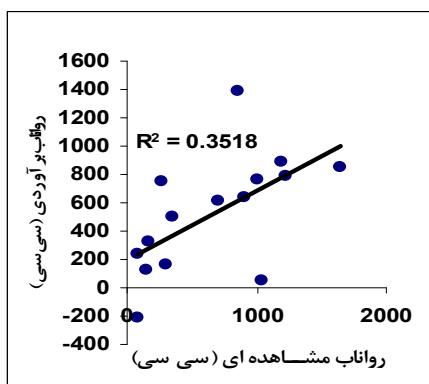
جدول ۴: مشخصات مدل بهینه رگرسیونی برآورد رسوپ و حجم رواناب

متغیر وابسته	ضریب	متغیرهای وابسته مدل	میزان آزمون ANOVA
متغیر وابسته	تبيين		
مدل رگرسیونی			
حجم رواناب (سی سی)	$-106.4 + 156.73 X_1 + 39.99X_2 - 8.78 X_3 - 7.13 X_4$	$X_1 = \text{روطوت پيشين خاک} (\%)$ $X_2 = \text{فسفر قابل جدب}$ $X_3 = \text{درصد پوشش تاجی}$ $X_4 = \text{میزان ماسه} (\%)$	$34/32^{**}$
میزان فرسایش (گرم در لیتر)	$104 - 1.9 X_1 - 869.6X_2 - 1.3X_3 - 44.24 X_4 + 1.49X_5$	$X_1 = \text{میزان آهک} (\%)$ $X_2 = \text{درصد نیتروژن کل} (\%)$ $X_3 = \text{درصد پوشش تاجی}$ $X_4 = \text{کربن آلی} (\%)$ $X_5 = \text{شیب زمین} (\%)$	$10/93^{**}$

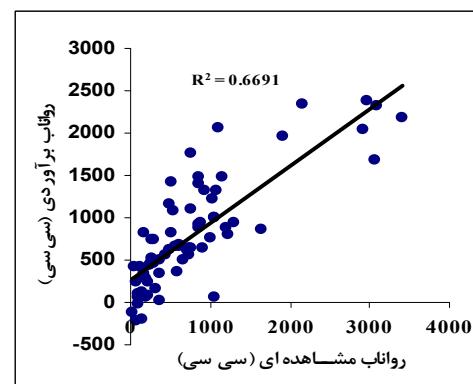
جدول ۵: ارزیابی مدل بهینه رگرسیونی

شاخص ارزیابی	RMSE			MAE			NASH		
	نوع داده	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی
حجم رواناب (سی سی)	۴۴۴/۸۱	۴۲۸/۲۵	۳۲۰/۶۳	۳۳۸/۹۳	۰/۶۷	۰/۲۱			
میزان فرسایش (گرم در لیتر)	۴۶/۸۷	۴۶/۴۴	۳۱/۶	۳۳/۹۲	۰/۹۹۶	۰/۹۹۱			

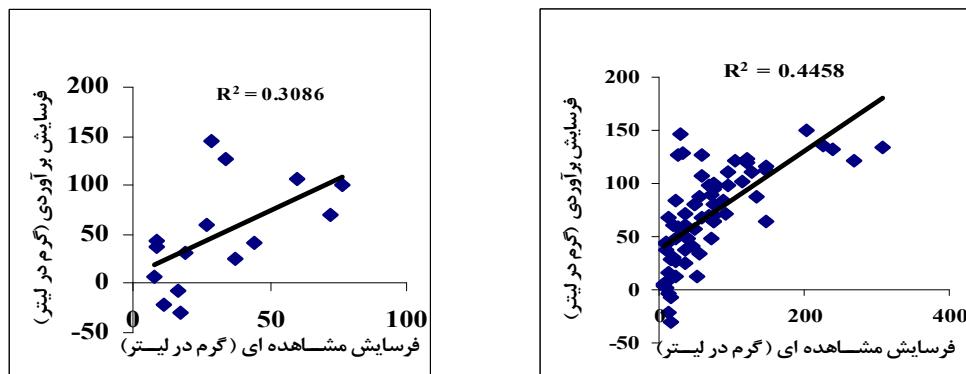
همچنین نمودار نکویی برازش مدل بهینه برای داده‌های آموزش و اعتبارسنجی، در شکل ۵ تا ۸ نمایش داده شده است.



شکل ۶: برازش نکویی مدل بهینه رگرسیونی برای متغیر حجم رواناب (داده‌های اعتبارسنجی)



شکل ۵: برازش نکویی مدل بهینه رگرسیونی برای متغیر حجم رواناب (داده‌های آموزش)



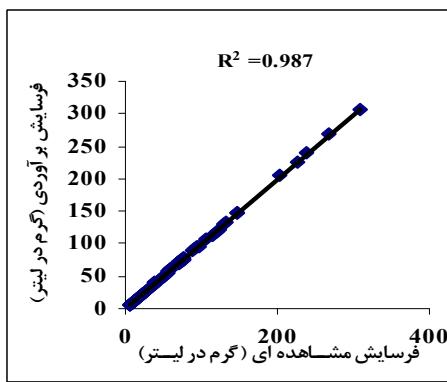
شکل ۷: برآذش نکویی مدل بهینه رگرسیونی برای متغیر میزان
فرسایش (داده‌های اعتبارسنجی)

مدل‌های شبکه عصبی مصنوعی

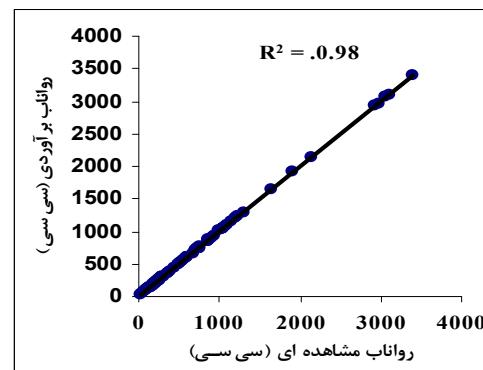
طبق یافته‌ها، اعتبارسنجی سناریوهای مختلف مدل شبکه عصبی براساس شاخص‌های NASH و MAE در جدول ۶ ارائه شده است که مطابق آن، سناریو تابع پایه شعاعی به عنوان روش بهینه مدل شبکه عصبی، برای هر دو متغیر مورد بررسی شامل حجم رواناب و میزان فرسایش معرفی می‌شود؛ لذا نمودار نکویی برآذش مدل بهینه شبکه عصبی برای داده‌های آموزش و اعتبارسنجی پارامتر حجم رواناب و میزان فرسایش، در اشکال ۹ تا ۱۲ نمایش داده شده است.

جدول ۶: ارزیابی مدل بهینه شبکه عصبی مصنوعی

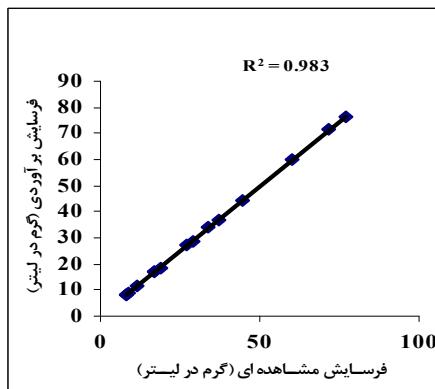
متغیر	مشخصات مدل				RMSE		MAE		NASH	
	مورد بررسی	ساختار	نوع	تابع انتقال	تعداد لایه پنهان (نرون لایه)	آموزش	اعتبارستجی	آموزش	اعتبارستجی	آموزش
حجم	MLP	پیشرو	Tansig	(۱۰)۲	۵۲۲/۲۳	۶۶۶/۷۷	۳۵۰/۶۴	۴۸۹/۶۳	۰/۵۴	-۰/۹۲
	MLP	پیشرو	Sig	(۱۰)۲	۳۸۶/۵۲	۳۳۲/۸۹	۱۷۵/۰۹	۱۶۷/۹۲	۰/۷۵	-۰/۵۲
	MLP	پیشرو	Purelin	(۱۰)۲	۱۵۹۳/۳۳	۱۷۴۸/۳۸	۱۱۴۷/۲۲	۱۳۶۰/۱۲	-۳/۲۵	-۱۲/۱۸
	RBF	-	-	-	۰/۱۳	۰/۱۳	۰/۱۱	۰/۱۱	۱	-۰/۹۹
	رواناب	MLP	پیشرو	Tansig	(۳)۲	۳۰۱/۵۸	۴۱۸/۹۹	۲۱۳/۰۱	۲۸۸/۱۵	۰/۸۴
	(سی)	MLP	پیشرو	Sig	(۳)۲	۴۱۱/۲۷	۳۸۸/۵۳	۲۶۹/۶۵	۲۶۴/۵۵	۰/۷۲
	(سی)	MLP	پیشرو	Purelin	(۳)۲	۴۰۵/۸۹	۳۹۹/۴۹	۲۷۸/۵۱	۲۶۴/۸۱	۰/۷۲
میزان	MLP	پیشرو	Tansig	(۷)۲	۱۲۴۰/۰۶	۸۰۰/۸۸	۸۳۰/۵۴	۶۶۴/۹۲	-۱/۵۷	-۱/۷۷
	MLP	پیشرو	Sig	(۷)۲	۳۵۷/۳۱	۱۴۹/۳۸	۱۹۴/۴۲	۱۰۷/۵۱	۰/۷۸	-۰/۹۰
	MLP	پیشرو	Purelin	(۷)۲	۴۳۱/۲۲	۳۸۱/۳۹	۲۸۵/۱۳	۲۷۷/۴۳	۰/۶۹	-۰/۳۷
	MLP	پیشرو	Tansig	(۱۰)۲	۱۸۰/۶۶	۱۸۰/۳۱	۱۴۵/۳۶	۱۲۹/۳۶	۰/۹۴	-۰/۸۶
	MLP	پیشرو	Sig	(۱۰)۲	۴۵/۷۶	۳۱/۱۴	۳۰/۴۵	۲۱/۲۷	۰/۹۹	-۰/۹۹
	MLP	پیشرو	Purelin	(۱۰)۲	۱۱۸/۶۵	۱۵۶/۹۹	۸۳/۷۹	۱۰۳/۳۴	۰/۹۷	-۰/۸۹
	RBF	-	-	-	۰/۰۱	۰/۰۱	۰/۰۰۹	۰/۰۰۹	۰/۹۹	-۰/۹۸
فرسایش	MLP	پیشرو	Tansig	(۳)۲	۴۵/۸۲	۴۴/۳۱	۳۲/۸۶	۲۵/۴۴۲	۰/۹۹	-۰/۹۹۲
	MLP	پیشرو	Sig	(۳)۲	۵۴/۷۹	۳۵/۰۳	۳۷/۵۶	۲۳/۱۹۰	۰/۹۹	-۰/۹۹۵
	MLP	پیشرو	Purelin	(۳)۲	۵۰/۱۸	۳۳/۴۳	۳۱/۳۶	۲۰/۲۹	۰/۹۹۵	-۰/۹۹۵
	MLP	پیشرو	Tansig	(۷)۲	۵۸/۸۱	۶۱/۵۵	۴۳/۴۰	۵۳/۱۱	۰/۹۹۴	-۰/۹۸۴
	MLP	پیشرو	Sig	(۷)۲	۴۱/۸۰	۲۲/۴۶	۱۹/۲۴	۱۰/۵۷	۰/۹۹۷	-۰/۹۹۸
	MLP	پیشرو	Purelin	(۷)۲	۴۶/۸۳	۳۷/۶۵	۳۰/۶۹	۲۰/۲۰	۰/۹۹۶	-۰/۹۹۴



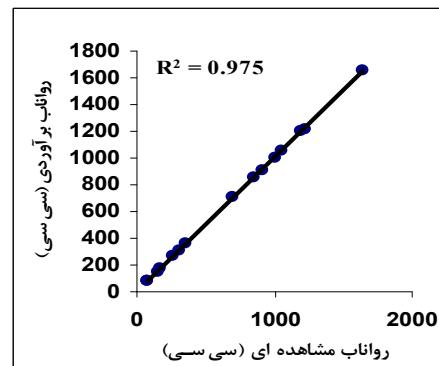
شکل ۱۰: برازش نکری مدل شبکه عصبی بهینه متغیر حجم رواناب فرسایش (داده‌های آموزش)



شکل ۹: برازش نکری مدل شبکه عصبی بهینه متغیر حجم رواناب (داده‌های آموزش)



شکل ۱۲: برآورد نکویی مدل شبکه عصبی بهینه متغیر میزان فرایند (داده‌های اعتبارسنجی)



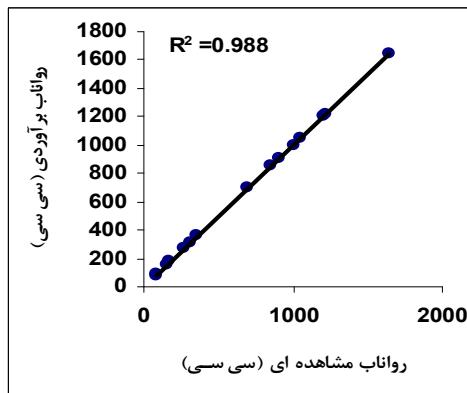
شکل ۱۱: برآورد نکویی مدل شبکه عصبی بهینه متغیر حجم رواناب (داده‌های اعتبارسنجی)

مدل نروفازی

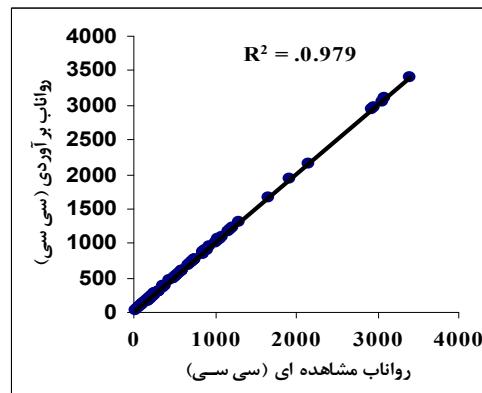
نتایج حاصل از اعتبارسنجی سناریوهای مختلف مدل نروفازی براساس شاخص‌های MAE و RMSE در جدول ۷ ارائه شده است. طبق نتایج این جدول، سناریو روش خوش‌های - رویه هیبرید به عنوان مدل بهینه هر دو متغیر مورد بررسی شامل حجم رواناب و میزان فرایند است؛ لذا نمودار نکویی برآورد مدل بهینه نروفازی برای داده‌های آموزش و اعتبارسنجی پارامتر حجم رواناب و میزان فرایند، در شکل‌های ۱۳ تا ۱۶ نمایش داده شده است.

جدول ۷: ارزیابی مدل بهینه شبکه عصبی - فازی

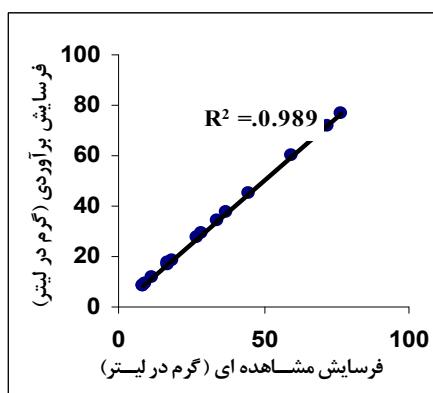
متغیر مورد بررسی	روش منقطع سازی	مشخصات مدل		RMSE		MAE		NASH	
		نوع و تعداد تابع عضویت	روش آموزش	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی
حجم رواناب	شبکه	(۳) مثالی	Backpro	۴/۹۴	۰/۱۹	۱/۱۴	۰/۱۴	۱/۰۰	۱/۰۰
	شبکه	(۳) مثالی	Hybrid	۳۷۰/۸۰	۲۴۷/۱۹	۲۲۷/۴۳	۱۷۱/۷۹	۰/۷۷	۰/۷۴
	شبکه	(۳) گوسی	Backpro	۰/۱۵	۰/۱۳	۰/۱۲	۰/۱۱	۱/۰۰	۱/۰۰
	شبکه	(۳) گوسی	Hybrid	۵۲۷/۰۴	۵۰۴/۸۷	۳۸۱/۳۵	۴۱۱/۴۳	۰/۵۳	-۰/۱۰
	خوش	-		۰/۱۲	۰/۱۳	۰/۱۰	۰/۱۱	۰/۹۸	۰/۹۲
	شبکه	(۳) مثالی	Backpro	۰/۹۵	۱/۹۸	۰/۲۷	۰/۸۹	۱/۰۰	۱/۰۰
میزان فرایند	شبکه	(۳) مثالی	Hybrid	۵۵/۰۳	۲۹/۱۰	۳۵/۶۸	۲۳/۴۹	۰/۹۹	۰/۹۹
	شبکه	(۳) گوسی	Backpro	۰/۴۱	۰/۷۴	۰/۱۳	۰/۳۵	۱/۰۰	۱/۰۰
	شبکه	(۳) گوسی	Hybrid	۴۱/۸۱	۳۲/۴۱	۲۷/۹۵	۲۲/۸۳	۰/۹۹	۰/۹۹
	خوش	-		۱/۱۳	۰/۰۱	۰/۲۹	۰/۰۱	۰/۹۸	۰/۹۸



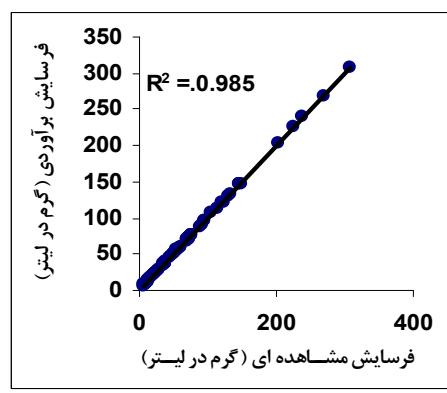
شکل ۱۴: برآذش نکویی مدل نروفازی بهینه برای متغیر حجم رواناب (داده‌های اعتبارسنجی)



شکل ۱۳: برآذش نکویی مدل نروفازی بهینه برای متغیر حجم رواناب (داده‌های آموزش)



شکل ۱۶: برآذش نکویی مدل نروفازی بهینه برای متغیر میزان فرسایش (داده‌های اعتبارسنجی)



شکل ۱۵: برآذش نکویی مدل نروفازی بهینه برای متغیر میزان فرسایش (داده‌های آموزش)

۴- بحث و نتیجه‌گیری

نتایج حاصل از این تحقیق نشان داد که در بخش مدل‌های رگرسیونی چندمتغیره، متغیرهای رطوبت پیشین، فسفر قابل جذب، درصد پوشش تاجی و میزان ماسه خاک، ۶۸ درصد تغییرات حجم رواناب را توجیه می‌کنند و متغیرهای میزان آهک، درصد نیتروژن کل، درصد پوشش گیاهی، کربن آلی خاک و شیب زمین قادر به توجیه ۴۶ درصد تغییرات میزان فرسایش هستند. در این رابطه نقش مستقیم پوشش گیاهی از طریق افزایش درصد پوشش تاجی بر کاهش حجم رواناب و میزان فرسایش ظاهر شده است؛ زیرا پوشش تاجی گونه‌های گیاهی علاوه بر اینکه مانند یک سپر از کنده شدن ذرات در فاز اول فرسایش آبی جلوگیری می‌کند (Lieskovský & Refahi, 2006, 2014), بلکه با مانع شدن در مقابل سرعت جریان آب، ایجاد زبری در سطح و دادن فرصت نفوذ به آب در خاک، به کم شدن میزان رواناب منجر می‌شود (Zhao et al, 2015). همچنین در تحقیق حاضر اثر غیرمستقیم پوشش گیاهی بر میزان فرسایش خاک، از طریق متغیر درصد نیتروژن کل و کربن آلی خاک قابل تشخیص است. در حقیقت، گونه‌های گیاهی با افرودن مواد لاشبرگی خود به افزایش کربن و ماده آلی خاک منجر می‌شود که نتیجه‌ی آن، افزایش ضریب نگهداری آب در خاک، بهبود دانه‌بندی و ساختمان خاک و در نتیجه کاهش فرسایش است. از سوی دیگر، حفظ نتیروژن کل خاک در مدل رگرسیونی مربوط به فرسایش در پژوهش حاضر، احتمالاً به دلیل حضور بیشتر گونه‌های گیاهی متعلق به خانواده لگومینوز در سایتهای مطالعاتی است. با توجه به این مسئله همچنین حفظ نشدن شاخص‌های تنوع و غنا در سطح گونه در مدل‌های رگرسیونی رواناب و فرسایش پژوهش حاضر، پیشنهاد می‌شود در بررسی‌های آتی به جای بررسی این شاخص‌ها در حد گونه، حضور یا عدم حضور خانواده لگومینوز در پلات‌های مربوط به بارانساز بررسی شود. نقش مستقیم و مثبت پوشش گیاهی در کاهش حجم رواناب، از طریق به تأخیر اندختن آستانه شروع رواناب توسط Ebrahimi و همکاران (2015) قبل‌گزارش شده است. در این راستا پیشنهاد می‌شود دستگاه‌های اجرایی به منظور کنترل فرسایش و رواناب، در حفظ و توسعه‌ی پوشش گیاهی در اراضی مرتعی حوزه‌های آبخیز و استفاده از آن به عنوان یک ابزار مدیریتی مهم، توجه خاص داشته باشند و از طریق دام‌گذاری مناسب در مراتع به حل معضل فرسایش و رواناب‌های مهیب (سیالاب) بپردازنند. طبق نتایج رگرسیونی از آنجا که با افزایش شیب زمین، میزان فرسایش به طور معنی‌داری افزایش می‌یابد؛ لذا توصیه می‌شود دستگاه‌های اجرایی کانون توجهات خود را به وضعیت پوشش گیاهی در اراضی شیب‌دار و سرشاره‌ها به عنوان ابزار کنترل‌کننده‌ی معضل فرسایش معطوف سازند و بی‌توجهی به این مهم، باعث از بین رفتن منبع با ارزش خاک به عنوان بستر گیاهی – که برای تشکیل یک سانتی‌متر آن ۳۰۰ تا ۱۰۰۰ سال زمان لازم است – و ذخایر ارزشمند گیاهی در کشور خواهد شد. در مورد سایر پارامترهای محیطی مؤثر بر فرسایش نتایج تحقیق حاضر نشان داد بین میزان آهک خاک و میزان فرسایش، یک رابطه‌ی معنی‌دار منفی رگرسیونی وجود دارد که دانه‌بندی بهتر ذرات خاک توسط آهک و مقاومت آنها در برابر کنده شدن و حمل و در نتیجه فرسایش، می‌تواند دلیل این مهم باشد.

همچنین نتایج این تحقیق نشان داد که با افزایش میزان شن موجود در خاک، میزان حجم رواناب به طور معنی‌داری کاهش می‌یابد. این مهم به افزایش نفوذپذیری آب در خاک در اثر ذرات شن خاک (Vaezi et al., 2008) مرتبط است. نیز اذعان داشت که رابطه‌ی معنی‌داری بین بافت خاک و حجم رواناب برقرار است؛ از این رو یافته‌های این

بخش با نتایج ایشان همسویی داشت. بین رطوبت پیشین و فسفر قابل جذب خاک با حجم رواناب، رابطه‌ی مثبتی مشاهده شد. تحقیقات Kavian و همکاران (2013) نیز به تأثیر بارز رطوبت پیشین خاک بر رواناب اشاره دارد؛ لذا یافته‌های این بخش با نتایج ایشان همسو است. در این راستا تأثیرپذیری رواناب از بافت خاک و ماده آلی در تحقیقات Vaezi و همکاران (2008)، Kavian و همکاران (2010)، Santhus و همکاران (2003)، رطوبت اولیه‌ی خاک در تحقیقات Castillo و همکاران (2010)، Foltz و همکاران (2009) و Puigdefabregas (2005)؛ درصد پوشش گیاهی و شیب زمین در تحقیقات Ebrahimi و همکاران (2015) قبل از گزارش شده است. همچنین تأثیرپذیری فرسايش خاک از شیب، در تحقیقات Zoratipour & ArabKhedri (2016) دیده می‌شود؛ لذا نتایج این بخش با یافته‌های این محققان همسویی دارد.

با توجه متفاوت بودن عوامل محیطی (به استثنای پوشش گیاهی) مدل‌های رگرسیونی متعلق به دو متغیر حجم رواناب و میزان فرسايش در تحقیق حاضر، می‌توان چنین استنباط کرد که فرایند ایجاد فرسايش با فرایند تولید رواناب کاملاً متفاوت است. هر چند مدل‌های رگرسیونی، نتایج نسبتاً قابل قبولی را در پیش‌بینی دو متغیر حجم رواناب و میزان فرسايش ارائه می‌دهد، ولی نتایج حاصل حاکی از آن است که مدل‌های شبکه عصبی مصنوعی و نروفازی، کارایی بهتری در پیش‌بینی این دو پارامتر دارند. به نظر می‌رسد پیچیده بودن روابط اکولوژیکی و متغیرهای تأثیرگذار بر میزان رواناب و فرسايش، موجب شده است که مدل‌های پیش‌بینی خطی مانند مدل‌های رگرسیونی در این امر به اندازه مدل‌های غیرخطی مانند شبکه عصبی مصنوعی، فازی و نروفازی موفق نباشند (Aramesh & Abrahart and White, 2001). برتری مدل‌های شبکه عصبی نسبت به مدل‌های رگرسیونی در پژوهش حاضر، با یافته‌های Mohamadi, Negarestani, Vali و همکاران (2011) و Khazaii و همکاران (2013) و نروفازی نسبت به مدل‌های رگرسیونی با نتایج Sabziparvar و همکاران (2010) در شبیه‌سازی رواناب و فرسايش مطابقت و همسویی داشت.

همچنین، نتایج حاصل از این تحقیق حاکی از آن است که مدل شبکه عصبی تابع پایه شعاعی می‌تواند به پیش‌بینی دقیق‌تر هر دو متغیر مورد بررسی پیدا‌زد؛ به طوری که شاخص‌های RMSE، MAE و NSE این مدل به ترتیب معادل 0.114 ، 0.114 و 0.114 در مورد حجم رواناب و 0.098 ، 0.099 و 0.099 در مورد میزان فرسايش است. شبکه تابع پایه شعاعی نسبت به شبکه‌های پرسپترون چندلایه، نیازمند نرون‌های بیشتری هستند ولی اغلب این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های پیشخور، آموزش داد. بررسی‌ها نشان می‌دهد شبکه‌های تابع شعاعی زمانی که بردارهای ورودی فراوانی در دسترس باشد از عملکرد مطلوب‌تری برخوردارند (Sayyadi et al., 2009). بالا بودن تعداد متغیرهای ورودی در این تحقیق (۲۱ متغیر)، می‌تواند دلیلی بر ارائه‌ی نتایج دقیق‌تر توسط مدل شبکه عصبی پایه شعاعی نسبت به پرسپترون چندلایه باشد. همچنین نتایج حاصل نشان داد که مدل نروفازی با سناریو روش خوش‌های-رویه هیبرید قادر به پیش‌بینی دقیق هر دو متغیر مورد بررسی شامل حجم رواناب و میزان فرسايش است. در این رابطه شاخص‌های RMSE، MAE و NSE به ترتیب معادل 0.111 ، 0.111 و 0.111 برای متغیر حجم رواناب و 0.098 ، 0.098 و 0.098 برای میزان فرسايش حاصل شد. این مهم (دقیق‌تر بالای مدل نروفازی) با یافته‌های

Moayeri و همکاران (2010) در برآورد متغیر رسوب و با تابع Ghafari & Vafakhah (2013) و Salajegheh (2009) در شبیه‌سازی رواناب همسویی داشت.

در کل می‌توان چنین نتیجه گرفت که چون رواناب و فرسایش یکی از پیچیده‌ترین مسائل هیدرودینامیکی است (Yosefi & Poorshariaty, 2014)، برای پیش‌بینی متغیرهای میزان فرسایش و حجم رواناب (مستقیماً برداشت شده از طبیعت توسط دستگاه بارانساز) بر پایه‌ی عوامل اکولوژیکی، مدل‌های شبکه عصبی و نروفازی نسبت به مدل‌های رگرسیونی از قابلیت و کارایی بیشتری برخوردارند؛ لذا مدل‌های هوشمند و غیرخطی شبکه عصبی با روش تابع پایه شعاعی و نروفازی با سناریو روش خوشه‌ای- رویه هیبرید به دلیل کارایی بالا در شناخت روابط غیرخطی و پیچیده برای شبیه‌سازی فرسایش و رواناب در مناطق مطالعاتی و سایر حوزه‌های آبخیز مشابه کشور پیشنهاد می‌شوند.

REFERENCES

- 1-Vali AA, Ramesht MH, Seif A, Ghazavi R. An assessment of artificial neural networks (ANN) technique to geomorphologic modeling sediment yield (case study: Samandeh watershed). *Geomorphology and Environmental Planning*. 2011; 22(4): 19-34. (In Persian)
- 2- Quansah C. The effect of soil type, slope, rain intensity and their interactions on splash detachment and transport. *Journal of Soil Science*. 1981 June; 32(2): 215-224.
- 3- Perez-Latorre FJ, Castro LD, Delgado A. A comparison of two variable intensity rainfall simulators for runoff studies. *Soil and Till. Research*. 2010 March; 107: 11-16.
- 4-Pan Ch, Shangguan Zh. Runoff hydraulic characters and sediment generation in Sloped grassplots under Simulated Rainfall condition. *Journal of Hydrology*. 2006; 331: 178-185.
- 5- Hosseini SH, Fiznia S, Payrovan H and Zehtabiany Gh. Runoff and sediment production of the fine Neogene formations using rainfall simulator (case study: Watershed Taleghan). *Journal of Range and Watershed Management*. 2009; 62 (2): 215-229.
- 6-Defersha MB, Mellesse AM. Effect of rainfall intensity, slope and antecedent moisture content on sediment concentration and sediment enrichment ratio. *Catena*. 2012; 90: 47-52.
- 7- Martínez-Murillo JF, Nadal-Romero E, Regués D, Cerdà A, Poesen J. Soil erosion and hydrology of the western Mediterranean badlands throughout rainfall simulation experiments: a review. *Catena*. 2013; 106: 101-112.
- 8- Zhao Z, Huang J, Gao X, Wu P, Wang J. Runoff features of pasture and crop slopes at different rainfall intensities, antecedent moisture contents and gradients on the Chinese Loess Plateau: A solution of rainfall simulation experiments. *Catena*. 2014; 119: 90-96.
- 9- Zarekhormizi M, Najafinejad A, Noura N, Kavian A. Effects of slope and soil properties on runoff and soil loss using rainfall simulator, Chehel-chai watershed, Golestan province. *Journal of Water and Soil Conservation*. 2012; 19(2): 165-178. (In Persian)
- 10- Habibzade A, Nikjou MR, Peyrevan HR. Investigating the runoff and sediment yield in marl formation of East Azarbaejjan. *Management and Geography Journal*. 2013; 17(43): 71-91. (In Persian)
- 11- Ebrahimi N, Eslami AR, Sharifi F. Runoff threshold estimation using rainfall simulator in field plots. *Journal of Watershed Engineering and Management*. 2015; 7 (2): 211-222. (In Persian)
- 12- Zoratipour A, ArabKhedri M. Assessment of The Effect of the Rainfall Returns Period and Pattern on The Hillslope Erosion on The Catchments (Case study: Heshan Basin). *Journal of Irrigation Science and Engineering*. 2016; 39(4): 123-132. (In Persian)
- 13- Cigizoglu HK, Alp M. Generalized regression neural network in modeling river sediment yield. *Journal of Advance in Engineering Software*. 2006; 37:63-68.
- 14- Alp M, Cigizoglu HK. Suspended sediment load simulation by two artificial neural network methods using hydro meteorological data. *Environmental Modeling and Software*. 2007; 22: 2-13.
- 15- Heng S, Suetsugi T. Using artificial neural network to estimate sediment load in ungauged catchments of the Tonle Sap river basin, Cambodia. *Journal of Water Resource and Protection*. 2013; 5: 111-123.

- 16- Jajarmizadeh M, Harun S, Salarpour M. An assessment of a proposed hybrid neural network for daily flow prediction in arid climate. *Modelling and Simulation in Engineering*, Hindawi Publishing Corporation. 2014; 11: 1-11.
- 17- Roushanghar K. Evaluation of ANFIS machine learning approach for predicting of a local scour. *International Conference on Civil, Transport and Environment Engineering (ICCTEE'2013)* Penang (Malaysia). August 2013; 15-18.
- 18- Tahmoures M, Moghadam Nia AR, Naghiloo M. Modeling of streamflow- suspended sediment load relationship by adaptive neuro-fuzzy and artificial neural network approaches (Case study: Dalaki River, Iran). *Desert*. 2015; 20(2): 177-195.
- 19- Dastorani MT, Sharifi darani H, Talebi A, Moghadamnia AR. Evaluation of the application of artificial neural networks and adaptive neuro-fuzzy inference systems for rainfall-runoff modelling in Zayandeh_rood dam basin. *Water and Waste Journal*. 2011; 22(4): 114-125. (In Persian)
- 20-Falamaki A, Eskandari E, Baghlani A, Ahmadi SA. Modeling total sediment load in rivers using artificial neural networks. *Journal of Water and Soil Resources Conservation*. 2013; 2(3): 13-25. (In Persian)
- 21- Ghafari GA, Vafakhah M. Simulation of Rainfall-Runoff Process using Artificial Neural Network and Adaptive Neuro-Fuzzy Interface System(Case Study: Hajighoshan Watershed). *Journal of Watershed Management Research*. 2013; 4 (8): 120-136. (In Persian)
- 22- Yosefi, M and Poorshariaty R. Suspended Sediment Estimation using Neural Network and Algorithms Assessment (Case Study: Lorestan Province). *Journal of Watershed Management Research*. 2014; 5 (10): 85-97. (In Persian)
- 23- Eshghi P, Farzadmehr J, Dastorani MT, Arabasadi Z. The Effectiveness of Intelligent Models in Estimating the River Suspended Sediments (Case Study: Babaaman Basin, Northern Khorasan). *Journal of Watershed Management Research*. 2016; 7 (14): 88-95. (In Persian)
- 24- Menhaj MB. Introduction of artificial Neural Networks. Amirkabir University Press, 2nd ed, 2002. (In Persian)
- 25- Misaghi F, Mohamadi K. Rainfall-Run off Simulation by Artificial Neural Networks. 6 th Conference of International River engineering, Chamran university of Ahvaz. 2002. (In Persian)
- 26- Vahabi J, Mahdian MH, Investigating the effect of edaphic parameters on runoff using a rainfall simulator. *Watershed Management Researches (Pajhohesh & Sazandegi)*. 2009; 83:11-20. (In Persian)
- 27-Walkley A, Black IA. An examination of Degtjareff method for determining soil organic matter and proposed modification of the chromic acid titration method. *Journal of Soil Science*. 1934; 37: 29-37.
- 28-McGill WB, Figueiredo CT. Total nitrogen. In: Carter, M.R. (Ed.), *Soil Sampling and Methods of Analysis*. Lewis Publishers, Boca Rton, F.L; 1993.
- 29-Olsen SR, Cole CV, Watanable FS, Dean LA. Estimation of Available Phosphorus in Soils by Extraction with Sodium Bicarbonate. U.S. Dept, Agr, Cir; 1954.
- 30-Simard RR. Ammonium acetate –extractable elements. In: Carter, M.R. (Ed.), *Soil Sampling and Methods of Analysis*. Lewis Publishers, Boca Rton, F.L; 1993.
- 31-Zarinkafsh M. *Applied Soil Science, Soil Survery and Soil- Plant- Water Analysis*. 1nd ed. Tehran university press. 1993. (In Persian)
- 32- McLeen E. Soil pH and lime requirement. In: Page, A.L. (Ed.), *Methods of Soil Analysis. Part 2. Chemical and microbiological properties*. Agron, 9, ASSA-SSA, Madison, WI, USA; 1982.
- 33- Sedighi F, Vafakhah M, Javadi MR. Application of Artificial Neural Network for Snowmelt-Runoff (Case Study: Latyan Dam Watershed). *Journal of Watershed Management Research*. 2015; 6 (12): 43-54. (In Persian)
- 34- Farshadfar EA. Multivariate principle and procedures of statistics. Razi university press. 2005. (In Persian)
- 35- Mohamadpour R. Mohamadpour F. Prediction of local scour around abutment using ANN and ANFIS. *Water Engineering*. 2014; 7(1): 11-28. (In Persian)
- 36-Beal R, Jakson T. *Neural Computing: An Introduction*. IOP Publishing Ltd. 1998.
- 37- Shabaninia F, Saeednia, S. *Fundamental of Fuzzy control texbox using MATLAB*. Khaniran press, 2007. (In Persian)

- 38- Sabziparvar AA, Bayatvarkeshi M. Evaluation of artificial neural network (ANN) and adaptive nero-fazy inference system (ANFIS) methods in total sun light radiation simulation. *Iranian Journal of Physics Research*. 2010; 10(4): 347-357. (In Persian)
- 39-Issak EH, Srivastava RM. *An Introduction to Applied Geostatistics*. Oxford University Press; 1989.
- 40- Refahi HG. *Water erosion and conservation*. 5nd ed. Tehran university press. 2006. (In Persian)
- 41-Lieskovský J, Kenderessy P. Modelling the effect of vegetation cover and different tillage practices on soil erosion in vineyards: a case study en Vráble (Slovakia) using WATEM/SEDEM. *Land Degradation and Development*. 2014; 25: 288–296.
- 42- Zhao C, Gao J, Huang Y, Wang G, Zhang M. Effects of vegetation stems on hydraulics of overland flow under varying water discharges. *Land Degradation and Development*. 2015; 27: 748–757.
- 43-Vaezi AR, Bahrami HA, Sadeghi SHR, Mahdian MH, Spatial variations of runoff in a port of calcareous soils of semi-arid region in northwest of Iran. *Journal of Agricultural Science*. 2008; 15(5): 113-123. (In Persian)
- 44- Kavian A, Asgariyan R, Jafarian Jeloudar Z, Bahmanyar MA. Effect of Soil Properties on Runoff and Sediment Yield in Farm Scale (Case study: a part of Sari town,s neighboring Croplands). *Water and Soil Science*. 2013; 23(4): 45-57. (In Persian)
- 45- Kavian A, Azmodeh A, Soleimani K, Vahabzadeh G. Effect of soil properties on runoff and soil erosion in forest lands. *Journal of Range and Watershed Management*. *Iranian Journal of Natural Resources*. 2010; 63 (1): 89-104. (In Persian)
- 46-Santos FL, Reis JL, Martins OC, Castanheria NL, Serralherio RP. Comparative assessment of infiltration, runoff and erosion of sprinkler irrigation soils. *Biosystems Engineering*. 2003; 86(3): 355-364.
- 47-Castillo VM, Go'mez-Plaza A, Martí'nez-Mena M. The role of antecedent soil water content in the runoff response of semiarid catchments: a simulation approach. *Journal of Hydrology*. 2003; 284(1-4): 114-130.
- 48- Najafian L, Kavian A, Ghorbani J, Tamartash R, Effect of life form and vegetation cover on runoff and sediment yield in rangelands of Savadkooch region, Mazandaran. *Journal of Rangeland*. 2010; 4 (2): 334-347. (In Persian)
- 49- Foltz RB, Copeland NS, Elliot WJ. Reopening abandoned forest roads in northern Idaho, USA: Quantification of runoff, sediment concentration, infiltration, and interrill erosion parameters. *Journal of Environmental Management*. 2009; 90: 2542 2550.
- 50-Puigdefabregas J. The role of vegetation patterns in structuring runoff and sediment fluxes in drylands. *Earth Surface Processes and Landforms*. 2005; 30: 133–147.
- 51- Mohamadi S. Studying the Relationship between Environmental Factors, Runoff Characteristics and Infiltration Depth Using Rainfall Simulator in Northwestern Rangelands of Iran. *Journal of Rangeland Science*. 2016; 6(3): 205-220.
- 52- Coulibaly P, Anctil F, Bobee B. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*. 2000; 230: 244-257.
- 53- Abrahart RJ, White SM. Modelling sediment transfer in Malawe: comparing back propagation neural network solution against a multiple linear regression benchmark using small data sets. *Physics and Chemistry of the Earth*. 2001; 26:19–24.
- 54- Negarest H, Aramesh M. Drought prediction in Khash city by artificial neural network model. *Journal of Arid Regions Geomorphologies Studies*. 2012; 2(6): 33-50. (In Persian)
- 55-Khazaii M, Sadeghi SHR, Mirnia SKH. Application of artificial neural network and regression models in sediment yield in plots located in disturbed and undisturbed plots in educational and research forest watershed of Tarbiat Modares University, Iran. *Iranian Journal of Watershed Management Science*. 2013; 7 (21):11-20.
- 56-Sabziparvar AA, Zareabyaneh H, Bayatvarkeshi M. Model comparison between predicted soil temperatures using ANFIS model and regression methods in three different climates. *Journal of Water and Soil*. 2010; 24 (2): 274-285. (In Persian)

- 57- Sayyadi H, Oladghaffari A, Faalian A, Sadraddini AA. Comparison of RBF and MLP neural networks performance for estimation of reference crop evapotranspiration. Water and Soil Science. 2009; 19 (1): 1-12.
- 58- Moayeri MM, Nikpoor R, Hoseinzadeh Dalir A, Farsadizadeh D. Comparison of artificial neural networks, adaptive Neuro-Fuzzy and sediment rating curve models for estimating suspended sediment load of Ajichay. Water and Soil Science. 2010; 20 (2): 71-82. (In Persian)
- 59- Salajegheh A, Fathabadi AB, Mahdavi, M. Investigation on the efficiency of neuro-fuzzy method and statistical models in simulation of rainfall-runoff process. Journal of Range and Watershed Management, Iranian Journal of Natural Resources. 2009; 62 (1): 65-79. (In Persian)

The Efficiency of Artificial Neural Network, Neuro-Fuzzy and Multivariate Regression Models for Runoff and Erosion Simulation via Rainfall Simulator

Sedigheh Mohamadi^{*}: Associate professor, Department of Ecology, Institute of Science and High Technology and Environmental Sciences, Graduate University of Advanced Technology, Kerman, Iran.

(Received: 25/10/2016

Accepted: 30/05/2017)

1-INTRODUCTION

According to the complexity of environmental factors related to erosion and runoff, correct simulation of these variables find importance under rain intensity domain of watershed areas. Although modeling of erosion and runoff by Artificial Neural Network and Neuro-Fuzzy based on rainfall-runoff and discharge-sediment models were widely applied by researchers, scrutinizing Artificial Neural Network and Neuro-Fuzzy models based on environmental factors has been paid less attention. Therefore, this study aimed at determining the efficiency of different models including Artificial Neural Network, Neuro-Fuzzy and Multivariate Regression for runoff and erosion simulation using rainfall simulator in some catchments of the North-West of Iran selected in terms of the same rain intensity of half an hour with a 10-year return.

2-THEORETICAL FRAMEWORK

Modeling runoff and erosion relations with environmental factors under prevalent rainfall intensity in a watershed scale are considered as the novel aspect of recognition of these complex relations. In this regard, implementation of determined rainfall intensity in a watershed scale is needed in the utilization of rainfall simulator apparatus. Also, the complexity of runoff and erosion relations with the environmental factors is the reason for the application of different models including Artificial Neural Network, Neuro-Fuzzy and Multivariate Regression. In fact Artificial Neural Network models are able to recognize the complex and unknown relations based on working as human brain. The simulation by these models finds importance when these relations have a non-linear feature. Parallel and Distributive processing of information and interpolation ability are major properties of Artificial Neural Network and Neuro-Fuzzy models characterized in the utilization of these models in the correct simulation of complex relations.

3-METHODOLOGY

The establishment of rainfall simulator conducted at 86 sites and 21 environmental variables (the characteristics of topography, pedology, vegetation and species diversity) were used as inputs to models. In this regard, Topographic characteristics (including elevation, slope and ...) of established sites of rainfall simulator apparatus were first recorded. Then sampling of soil was done from 4 corners of each site and compounded in order to eliminate soil heterogenic effects. After providing one soil sample from each site, all samples were sent to soil laboratory for measurement and analysis of different pedology properties including soil organic matter, total nitrogenous, absorbable phosphorus, available potassium, pH, electrical conductivity, soil moisture, calcareous content, gypsum content, Ca cation, Na cation, soil texture, distribution of clay, silt and sand percentage of soil. Also, vegetation characteristics including canopy cover, pavement and stone percentage and species abundance of each site was investigated in plot of

^{1*} Corresponding Author: mohamadisedigeh@gmail.com

simulator apparatus. Abundance parameter of species in each site was used for determining different species diversity indices (including species number, Simpson, Shannon-wiener and dominance indices) in PAST software package. Implementation of determined rainfall intensity of each site by simulator apparatus was finally performed for the measurement of runoff and erosion variable. Analysis of data was done through Multivariate Regression in SPSS software package, simulation via Artificial Neural Network (multi - layer perceptron and radial basis function methods), and Neuro-Fuzzy models was performed via MATLAB software package. Model validation conducted on 18 percent of the data based on Root of Mean Square Error, Nash–Sutcliffe Efficiency and Mean Absolute Error indices.

4- RESULTS

The results of Multivariate Regression model of this research showed that variables such as soil moisture, absorbable phosphorus, canopy cover percentage and soil sand percentage caused for runoff content and variables as calcareous content, total nitrogenous, canopy cover percentage, soil organic carbon and land slope determined erosion variable. In this regard, Multivariate Regression model was able to explain 68% and 46 % of changes in the runoff and soil erosion variables and its efficacy was lower in the simulation. As a result, Radial Basis Function neural network model compared with Multi Layer Perceptron as well as Neuro-Fuzzy model with scenarios of cluster (hybrid procedure) compared to grid method was able to predict more accurately. As indicators of RMSE, MAE and NSE were gained on optimum model of neural networks of 0.135, 0.114 and 0.99 for runoff volume, 0.011, 0.009 and 0.98 for the erosion and on optimum model of neuro-fuzzy models of 0.132, 0.111 and 0.92 for the volume of runoff and 0.013, 0.011 and 0.98 for the erosion, respectively.

5- CONCLUSIONS AND SUGGESTIONS

In general, it can be concluded that according to the presence of the complex environmental relations of erosion and runoff variables, Artificial Neural Network model with Radial Basis Function method and Neuro-Fuzzy model with scenarios of cluster (hybrid procedure) are recommended to be simulated based on ecological factors.

Key Words: Multi Layer Perceptron, Radial Basis Function, Neuro-Fuzzy, rainfall simulator.