

شبیه‌سازی فرآیند بارش - رواناب با به‌کارگیری پلات‌های صحرایی و شبکه عصبی مصنوعی

محمدعلی هادیان امری^۱، وحید غلامی^۲ و آتنا یوسفی^۳

۱- استادیار بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی مازندران، سازمان تحقیقات، آموزش و ترویج کشاورزی، ساری،

ایران

۲- دانشیار گروه مهندسی طبیعت، دانشکده منابع طبیعی، دانشگاه گیلان، رشت، ایران، (نویسنده مسئول: gholami.vahid@gmail.com)

۳- دانش‌آموخته کارشناسی ارشد مرتع‌داری دانشگاه تهران

تاریخ دریافت: ۱۴۰۲/۶/۲۶ تاریخ پذیرش: ۱۴۰۲/۷/۲۹

صفحه: تا

چکیده مسیوط

مقدمه و هدف: شبیه‌سازی فرآیند بارش - رواناب امری مهم در مدیریت منابع طبیعی و همچنین منابع آب است؛ اما این فرآیند دارای پیچیدگی‌های خاص خود و عوامل مؤثر متعدد از جمله عوامل بارش (مقدار و شدت بارش)، پوشش گیاهی (نوع پوشش و تراکم پوشش)، عوامل خاک (بافت خاک، رطوبت اولیه خاک و میزان نفوذپذیری خاک) و نحوه مدیریت اراضی است. تحقیق حاضر باهدف ارائه مدلی برای شبیه‌سازی فرآیند بارش - رواناب با استفاده از مدل‌سازی شبکه عصبی مصنوعی (ANN) و داده‌های پلات‌های صحرایی صورت گرفت.

مواد و روش‌ها: این تحقیق روی یک دامنه شیب‌دار در دانشگاه گیلان با خاک رسی-لومی به‌صورت تکراری از پلات‌های زوجی در تیمارهای مختلف پوشش گیاهی و مدیریت اراضی انجام شد. همچنین، با استفاده از یک باران‌سنج ذخیره‌ای، بعد از هر بارش مقدار بارندگی اندازه‌گیری شد. مقادیر رواناب نیز به‌واسطه پلات‌ها برآورد گشت و از تفاوت مقادیر بارش و رواناب‌ها، مقادیر هدررفت اولیه در سطح هر پلات به ازای هر واقعه بارش در شرایط متفاوت رطوبت پیشین خاک محاسبه گردید. سپس، به‌منظور مدل‌سازی داده‌های اخذشده به دو دسته داده‌های آموزشی و آزمودنی تفکیک شدند. پارامتر مقادیر رواناب به‌عنوان خروجی مدل و مقادیر بارش، درصد تاج پوشش مرتعی و درختی، رطوبت پیشین خاک، درصد لاش‌برگ به‌عنوان ورودی‌های بهینه مدل در نظر گرفته شدند.

یافته‌ها: مقادیر $MSE=0/004$ ، $R^2=0/97$ و $MSE=4/2$ ، $R^2=0/91$ به ترتیب در مرحله آموزش و مرحله آزمون مدل به دست آمد و در نهایت مدلی با کارایی بالا برای شبیه‌سازی فرآیند بارش - رواناب ارائه شد. نتیجه فرآیند مدل‌سازی نشان داد که پوشش مرتعی دارای بالاترین کارایی در کنترل میزان رواناب است.

نتیجه‌گیری: از مدل مذکور می‌توان برای شبیه‌سازی اثر سناریوهای مختلف پوشش گیاهی در تولید رواناب و یا برآورد رواناب براساس بارش ایستگاه‌های هواشناسی استفاده نمود.

واژه‌های کلیدی: تیمارهای پوشش، پلات زوجی، هدر رفت اولیه، مدل‌سازی، ANN، داده‌های آموزشی و آزمایشی

مقدمه

روند. این روش‌های هوشمند دارای قابلیت بالایی برای برقراری ارتباط بین داده‌های ورودی و خروجی هستند. Prasad et al., 2018; Nawar & Mouazen, 2019 & Kashani et al., 2020 در پژوهش خود بیان کرده‌اند که با استفاده از این فن رواناب را با کمی کردن رابطه بین رواناب و عوامل کنترل‌کننده آن (به‌عنوان مثال شیب، پوشش گیاهی، رطوبت خاک) می‌توان تخمین زد. این روش که یکی از شاخه‌های هوش مصنوعی به شمار می‌آید، به دلیل ساختار ریاضی کاملاً غیرخطی آن، در حوزه‌ی علوم و مهندسی آب رواج یافته است. این فن در واقع به‌عنوان بخشی از هوش مصنوعی، یک روش تجزیه‌وتحلیل داده است که بر این ایده تکیه دارد که سامانه‌ها می‌توانند از داده‌ها یاد بگیرند، الگوها را تشخیص دهند و با کمترین مداخله انسانی تصمیم بگیرند. توانایی و قابلیت شبکه‌های عصبی در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و مغشوش توسط محققین زیادی از جمله Hsu et al., 1995; Minns & Hall, 1996; Abrahart & See, 2000; Kisi, 2008 & Wang et al., 2009 به اثبات رسیده است. در مقالات Garosi et al., 2019 & Zhao et al., 2020 عملکرد بالای استفاده از این فن‌ها در زمینه فرسایش خاک و برآورد رواناب گزارش شده است.

نقش و اهمیت فرآیند بارش - رواناب در مطالعات منابع آب موجب شده که این فرآیند از دیرباز مورد توجه متخصصین قرار گیرد. برآورد رواناب ناشی از وقوع بارندگی گامی بسیار مهم در برنامه‌ریزی منابع آب به‌ویژه در آبخیزهای فاقد ایستگاه‌های هیدرومتری است. فرآیند تبدیل بارندگی به رواناب کاملاً غیر خطی و از حیث زمانی و مکانی نیز پدیده‌ای کاملاً تصادفی است و لذا تشریح آن با مدل‌های ساده به‌راحتی امکان‌پذیر نیست. پیش‌بینی بارش - رواناب مسئله‌ای پیچیده به دلیل روابط غیرخطی بین متغیرهای تأثیرگذار در آن است. برآورد مقادیر رواناب از طریق ایستگاه‌های هیدرومتری و استفاده از اندازه‌گیری‌های زمینی پرهزینه و مشکل است (Heidari Chenari et al., 2022).

خاصیت غیرخطی فرآیند بارش - رواناب و پیچیده بودن مدل‌های فیزیکی باعث شده محققان به مدل‌های هوشمند روی آورند و لذا روش‌های متعدد هوش مصنوعی از جمله شبکه‌های عصبی مصنوعی، سامانه‌های فازی و فازی-عصبی و ماشین لرنینگ برای مدل‌سازی فرآیند بارش - رواناب توسعه یافته است. در میان روش‌ها و مدل‌های مختلف برآورد رواناب، مدل‌های شبکه عصبی مصنوعی یا (ANN) (Artificial neural network) از جمله روش‌هایی هستند که در دهه‌های اخیر با دقت مناسبی در مدل‌سازی به کار می

۱۰۰ متر با شیب حدود ۲۵ درجه برای استقرار پلات‌های زوجی و اندازه‌گیری رواناب انتخاب شد (شکل ۱).

مطالعات میدانی (اندازه‌گیری‌های بارش و رواناب)

استقرار پلات‌های صحرایی روی یک دامنه شیب‌دار با خاک رسی-لومی به صورت تکراری از پلات‌های زوجی در تیمارهای مختلف انجام پذیرفت. این پلات‌ها با ابعاد ۲ در ۱ متر با حداقل دست‌خوردگی در خاک احداث شده‌اند. ارتفاع پلات ۴۰ سانتیمتر بوده که ۳۰ سانتیمتر بیرون از خاک و ۱۰ سانتیمتر درون خاک استقرار یافته‌اند (شکل ۲). جنس پلات‌ها از ورق فلزی پارک بوده که امکان استقرار را در خاک با فشار کم و بدون دست‌خوردگی خاک فراهم آورده است. انتهای پلات به شکل سه‌گوش یا مثلثی ساخته شده است تا جریان رواناب داخل پلات به سمت خروجی پلات یا لوله زهکشی هدایت گردد. در انتهای هر پلات یک لوله جمع‌آوری و هدایت رواناب تعبیه و به درستی آب‌بندی شده است و جریان رواناب را به یک مخزن در پایین دست شیب هدایت می‌نماید. پلات‌های به صورت زوجی دقیقاً مشابه از لحاظ اندازه و چگونگی شرایط احداث در مجاورت هم استقرار یافته‌اند. احداث پلات‌ها قبل از بهار یا شروع فصل رشد بوده است. تیمارهای مختلف به صورت زوجی جهت مقایسه با یکدیگر و مقایسه با کاربری‌ها و پوشش‌های مختلف مورد استفاده قرار گرفته است. تیمارهای مختلف زوجی شامل خاک لخت شخم شده (دو تیمار در جهت شیب و شخم عمود بر شیب)، پوشش مرتعی (کشت در جهت شیب و عمود بر شیب)، تیمارهای درصدهای متفاوت پوشش لاش‌برگ و تکرار تیمارها در زیر تاج پوشش درختان جنگلی (تیمارهای بدون پوشش جنگلی، پوشش جنگلی ۳۰ درصد و ۵۰ درصد) انجام شد. پوشش مرتعی از گونه‌های مرتعی مستقر در اطراف سایت (پاسپالوم و علف باغ) استفاده شد. درصدهای متفاوت لاش‌برگ (خاک لخت، ۳۰ درصد، پوشش ۵۰ درصد، پوشش ۱۰۰ درصد) و درصد تاج پوشش مختلف (خاک لخت، خاک با پوشش ۳۰ درصد، ۵۰ درصد و ۱۰۰ درصد) مورد استفاده قرار گرفت. در مجاورت پلات‌ها یک باران‌سنج ذخیره‌ای برای اندازه‌گیری مقادیر بارش و یک تشت تبخیر سنجی برای اندازه‌گیری تبخیر احتمالی از سطح باران‌سنج در نظر گرفته شد.

(Gholami et al. (2018) با به‌کارگیری شبکه عصبی مصنوعی به مدل‌سازی و برآورد مقدار فرسایش خاک و تولید رسوب در حوضه آبخیز کسلیان در استان مازندران پرداختند. نتایج نشان داد که شبکه عصبی مصنوعی دارای عملکرد مناسبی در برآورد فرسایش خاک و رسوب است. Adamowski (2013) با استفاده از شبکه عصبی مصنوعی به مدل‌سازی فرآیند بارش- رواناب حوضه کوهستانی دهرادان در یوتارانچال هندوستان اقدام نمود. ایشان توانست پارامترهای هیدرولوژیک متعددی از جمله رواناب مستقیم، جریان پایه و جریان کل را با دقت بالایی برآورد نمایند. افزون بر مطالعات ذکر شده می‌توان به تحقیقات انجام‌شده توسط Zhao et al. (2020) و Braddock et al. (1988) با هدف پیش‌بینی رواناب با به‌کارگیری هوش مصنوعی اشاره کرد. یکی از عوامل مؤثر در تولید رواناب نوع و میزان پوشش گیاهی و نحوه مدیریت پوشش در اراضی مرتعی و کشاورزی است. در رابطه با اثر تغییرات کاربری اراضی بر تولید رواناب، مطالعات زیادی انجام شده است (Gholami & Khaleghi, 2020)؛ اما کمتر مطالعاتی در خصوص بررسی اثر ترکیبی مدیریت زراعی، نحوه شخم و شیار و پوشش گیاهی برای رسیدن به رابطه بارش- رواناب، آب، خاک و گیاه انجام شده است. از این‌رو، تحقیق حاضر با هدف بررسی اثر پوشش، نوع پوشش، الگوی مدیریتی زمین بر میزان رواناب و ارائه مدلی برای شبیه‌سازی این فرآیند با استفاده از شبکه عصبی مصنوعی صورت پذیرفت.

مواد و روش‌ها

این تحقیق با استفاده از مقادیر بارش و رواناب اندازه‌گیری شده پلات‌های زوجی در سطح دانشکده منابع طبیعی گیلان واقع در شهر صومعه‌سرا صورت پذیرفت (شکل ۱). ارتفاع سایت مطالعاتی از سطح دریا ۲۰ متر، متوسط بارندگی سالیانه حدود ۱۳۵۰ میلی‌متر و اقلیم منطقه، معتدل و مرطوب است. عرصه مطالعاتی از رسوبات آبرفتی کواترنری تشکیل شده و خاک آن با بافت نسبتاً سنگین رسی لومی است. تیپ پوشش گیاهی غالب عرصه، پوشش مرتعی و گونه‌هایی مثل پاسپالوم و درختان بومی مثل راش است. یک دامنه به طول حدود



(ب)

(الف)

شکل ۱- الف) موقعیت محدوده مطالعاتی ب) موقعیت دامنه مطالعاتی در سطح دانشکده منابع طبیعی دانشگاه گیلان
 Figure 1. A) Location of the study area, B) Location of the study area at the area of the Faculty of Natural Resources of Guilan University



(ب)

(الف)



(ت)

(پ)

شکل ۲- تیمارهای مختلف پلات‌های زوجی الف) تیمار پوشش مرتعی ب) تیمار شخم و لاش‌برگ پ) تیمار کشت نواری و کشت عمود بر جهت شیب؛ ت) تیمار فرق و مالچ گیاهی (لاش‌برگ و سرشاخه خردشده)
 Figure 2. Different treatments of coupled plots A) treatment of rangeland cover B) treatment of plow and leaves C) Treatment of strip cultivation and vertical cultivation in the direction of the slope, D) Treatment of grass and mulch (chopped litter and branches)

قرار گیرد. برآورد رواناب ناشی از وقوع بارندگی گامی بسیار مهم در برنامه‌ریزی منابع آب به‌ویژه در آبخیزهای فاقد ایستگاه‌های هیدرومتری است. فرآیند تبدیل بارندگی به

نقش و اهمیت فرآیند بارش- رواناب در مطالعات منابع آب موجب شده که این فرآیند از دیرباز مورد توجه متخصصین

رواناب کاملاً غیر خطی و از حیث زمانی و مکانی نیز پدیده‌ای کاملاً تصادفی است و لذا تشریح آن با مدل‌های ساده به‌راحتی امکان‌پذیر نیست. پیش‌بینی بارش - رواناب مسئله‌ای پیچیده به دلیل روابط غیرخطی بین متغیرهای تأثیرگذار در آن است. برآورد مقادیر رواناب از طریق ایستگاه‌های هیدرومتری و استفاده از اندازه‌گیری‌های زمینی پرهزینه و مشکل است (Heidari Chenari et. al, 2022).

خاصیت غیرخطی فرآیند بارش - رواناب و پیچیده بودن مدل‌های فیزیکی باعث شده محققان به مدل‌های هوشمند روی آورند و لذا روش‌های متعدد هوش مصنوعی از جمله شبکه‌های عصبی مصنوعی، سامانه‌های فازی و فازی-عصبی و ماشین لرنینگ برای مدل‌سازی فرآیند بارش - رواناب توسعه یافته است. در میان روش‌ها و مدل‌های مختلف برآورد رواناب، مدل‌های شبکه عصبی مصنوعی یا (ANN) (Artificial neural network) از جمله روش‌هایی هستند که در دهه‌های اخیر با دقت مناسبی در مدل‌سازی به کار می‌روند. این روش‌های هوشمند دارای قابلیت بالایی برای برقراری ارتباط بین داده‌های ورودی و خروجی هستند. Prasad et al., 2018; Nawar & Mouazen, 2019 & Kashani et al., 2020 در پژوهش خود بیان کرده‌اند که با استفاده از این فن رواناب را با کمی کردن رابطه بین رواناب و عوامل کنترل‌کننده آن (به‌عنوان مثال شیب، پوشش گیاهی، رطوبت خاک) می‌توان تخمین زد. این روش که یکی از شاخه‌های هوش مصنوعی به شمار می‌آید، به دلیل ساختار ریاضی کاملاً غیرخطی آن، در حوزه‌ی علوم و مهندسی آب رواج یافته است. این فن در واقع به‌عنوان بخشی از هوش مصنوعی، یک روش تجزیه و تحلیل داده است که بر این ایده تکیه دارد که سامانه‌ها می‌توانند از داده‌ها یاد بگیرند، الگوها را تشخیص دهند و با کمترین مداخله انسانی تصمیم بگیرند. توانایی و قابلیت شبکه‌های عصبی در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و مغشوش توسط محققین زیادی از جمله Hsu et al., 1995; Minns & Hall, 1996; Abraham & See, 2000; Kisi, 2008 & Wang et al., 2009 به اثبات رسیده است. در مقالات Garosi et al., 2019 & Zhao et al., 2020 عملکرد بالای استفاده از این فن‌ها در زمینه فرسایش خاک و برآورد رواناب گزارش شده است.

(Gholami et al. (2018) با به‌کارگیری شبکه عصبی مصنوعی به مدل‌سازی و برآورد مقدار فرسایش خاک و تولید رسوب در حوضه آبخیز کسلیان در استان مازندران پرداختند. نتایج نشان داد که شبکه عصبی مصنوعی دارای عملکرد مناسبی در برآورد فرسایش خاک و رسوب است. Adamowski (2013) با استفاده از شبکه عصبی مصنوعی به مدل‌سازی فرآیند بارش - رواناب حوضه کوهستانی دهرادان در یوتارنچال هندوستان اقدام نمود. ایشان توانست پارامترهای هیدرولوژیک متعددی از جمله رواناب مستقیم، جریان پایه و جریان کل را با دقت بالایی برآورد نمایند. افزون بر مطالعات ذکر شده می‌توان به تحقیقات انجام‌شده توسط Braddok et al. (1988) و Zhao et al. (2020) با هدف پیش‌بینی رواناب با به‌کارگیری هوش مصنوعی اشاره کرد.

یکی از عوامل مؤثر در تولید رواناب نوع و میزان پوشش گیاهی و نحوه مدیریت پوشش در اراضی مرتعی و کشاورزی است. در رابطه با اثر تغییرات کاربری اراضی بر تولید رواناب، مطالعات زیادی انجام‌شده است (Gholami & Khaleghi, 2020); اما کمتر مطالعاتی درخصوص بررسی اثر ترکیبی مدیریت زراعی، نحوه شخم و شیار و پوشش گیاهی برای رسیدن به رابطه بارش - رواناب، آب، خاک و گیاه انجام‌شده است. از این‌رو، تحقیق حاضر باهدف بررسی اثر پوشش، نوع پوشش، الگوی مدیریتی زمین بر میزان رواناب و ارائه مدلی برای شبیه‌سازی این فرآیند با استفاده از شبکه عصبی مصنوعی صورت پذیرفت.

مدل‌سازی فرآیند بارش - رواناب با استفاده از شبکه عصبی (ANN)

در این مطالعه، شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) به‌منظور مدل‌سازی بارش - رواناب مورد استفاده قرار گرفت. این روش به‌طور گسترده‌ای برای مدل‌سازی پدیده‌های محیطی مورد استفاده قرار گرفته است (Lippman, 1987; Braddock et al., 1998; Harris & Boardman, 1998; Loh & Tim, 2000; ASCE, Braddock et al. (1998) براساس پژوهش‌های (2000). براساس پژوهش‌های (1998) که در مسائل هیدرولوژی استفاده شده‌اند، از نوع الگوریتم پس‌پراکنش (Backward propagation) هستند. از جمله ساختارهای مهم شبکه‌های عصبی، پرسپترون چندلایه است که کاربرد زیادی دارد و به‌خوبی قادر به تقریب توابع دلخواه است. در بررسی سامانه‌های پویای غیرخطی و دیگر مسائل، تقریب تابع از اهمیت زیادی برخوردار است. به‌طورمعمول پرسپترون‌های چندلایه با الگوریتم پس‌انتشار آموزش داده می‌شوند.

(Multilayer perceptron network) MLP از سه لایه اصلی (لایه‌های ورودی، پنهان و خروجی) از گره‌های فعال غیرخطی تشکیل شده است. یادگیری در پرسپترون با تغییر وزن اتصال براساس مقادیر خطا در مقایسه با مقادیر مشاهده‌شده انجام شد. در این مطالعه به‌منظور مدل‌سازی، داده‌های اخذشده به دو دسته داده‌های آموزشی (۷۰ درصد داده‌ها) و داده‌های آزمودن (۳۰ درصد داده‌ها) تفکیک شدند. داده‌های مرحله آموزش خود به دو دسته داده‌های آموزش (Train) و داده‌های صحت‌سنجی (Cross-validation) تفکیک شده‌اند. از میان ۱۳۰ داده بارش - رواناب ثبت شده، ۶۰ درصد داده‌ها به داده‌های اصلی آموزش، ۱۰ درصد به داده‌های صحت‌سنجی و ۳۰ درصد به داده‌های آزمودن یا آزمون اختصاص یافته‌اند. آموزش، ارائه ساختار اولیه مدل را به عهده دارد و صحت‌سنجی مرحله‌ای از مدل‌سازی است که بهینه‌سازی و جلوگیری از آموزش بیش از اندازه را انجام می‌دهد. آزمودن یا آزمون در عمل اعتبارسنجی مدل بهینه‌شده را بر عهده خواهد داشت.

پارامتر مقادیر رواناب به‌عنوان خروجی مدل و مقادیر بارش، درصد تاج پوشش گیاهی، درصد تاج پوشش درختی، رطوبت پیشین خاک، شیب زمین، درصد لاش‌برگ به‌عنوان ورودی‌های مدل در نظر گرفته شدند. ابتدا داده‌ها تصادفی یا

شاخص مقایسه‌ای است، باوجود این ضریب همبستگی شاخصی کلی است و شاخصی مناسب نیست (Khan et al., 2006)؛ بنابراین، در این پژوهش علاوه بر شاخص ضریب همبستگی که مدل محاسبه می‌کند، از چند معیار آماری (RMSE, MAE) استفاده شد.

نتایج و بحث

رواناب حاصله در سطح هر پلات برای هر یک از وقایع بارش توسط مخزن انتهایی آن گردآوری و حجم رواناب برآورد گشت. مقادیر بارش‌ها، حجم رواناب و ارتفاع رواناب وقایع بارش در جداول شماره (۱) تا (۵) ارائه شده است. اختلاف بین مقدار یا ارتفاع بارش و مقدار یا ارتفاع رواناب، بیانگر مقدار هدر رفت یا تلفات کل است. چون سطح پلات‌ها محدود بوده است بنابراین عملاً ذخیره بسیار ناچیز بود. در فرآیند بارش-رواناب پارامترهایی چون مقدار بارش، شدت بارش، شیب زمین، پوشش گیاهی، رطوبت پیشین خاک و نحوه مدیریت زمین تأثیرگذار است. این عوامل به‌صورت کمی به‌عنوان ورودی‌های مدل در نظر گرفته شدند و در جدول شماره (۱) تا (۵) مقادیر رواناب و عوامل مؤثر مذکور در پلات‌های زوجی (۲۰ پلات) ارائه شده است. شیب زمین با استفاده از مساحی برآورد گشت که تغییرات فاحشی نداشته است. درصد پوشش گیاهی و درصد لاش‌برگ با استفاده از نسبت سطح پوشش گیاهی به سطح کل پلات و میکرو پلات اندازه‌گیری شد. تعیین نوع پوشش به‌صورت کمی مشکل است؛ اما به دلیل شبیه‌سازی اثر قطرات باران، پاشمان باران و برگاب درختان، ارتفاع پوشش گیاهی نیز در نظر گرفته شد. مجموع بارش پنج روز قبل به‌عنوان رطوبت پیشین خاک برآورد گشت.

رندومایز شده و پس از نرمال‌سازی داده‌ها به دو دسته آموزشی و آزمودن تفکیک شدند. سپس، مراحل آموزش مدل، بهینه‌سازی مدل و آزمودن انجام پذیرفت. روش آزمون و خطا برای تعیین ساختار بهینه شبکه شامل تابع انتقال بهینه، فن یادگیری بهینه، ورودی‌های بهینه و تعداد نرون، تعداد دور آموزش بهینه در مرحله آموزش استفاده شد (Isik et al., 2013). در این روش، یکی از اجزای شبکه متغیر است و بقیه ثابت نگه داشته می‌شوند. عملکرد شبکه عصبی مصنوعی در مدل‌سازی رواناب با دقت و مقادیر خطا ارزیابی می‌شود. شبکه بهینه شبکه‌ای است که دارای اجزای بهینه برای تخمین رواناب باشد که کمترین خطا را در پی داشته باشد. به‌منظور یافتن تعداد بهینه نرون‌های پنهان، تعدادشان را ۱ به ۱۰ تغییر یافت. با استفاده از روش آزمون و خطا و تجزیه و تحلیل آماری (ضرایب تعیین)، پارامترهای ورودی مناسب انتخاب و تأثیر آن‌ها بر عملکرد مدل مورد ارزیابی و مقایسه قرار گرفت. درنهایت، ورودی‌های بهینه براساس عملکرد آن‌ها در مدل‌سازی رواناب انتخاب شدند. درنهایت، یک شبکه MLP با تابع انتقال تانژانت هیپربولیک، فن یادگیری LM، دو نرون پنهان به‌عنوان شبکه بهینه جهت مدل‌سازی تعیین شد. تابع انتقال تانژانت هیپربولیک و فن یادگیری LM برخی از بهترین انتخاب‌ها برای مدل‌سازی هیدرولوژیکی با به‌کارگیری شبکه عصبی هستند (Anctil & Rat, 2005). درنهایت، پس از آموزش مدل و بهینه‌سازی آن، مرحله آزمودن مدل انجام پذیرفت.

معیارهای ارزیابی عملکرد مدل‌سازی، میانگین مربعات خطا (MSE^1)، ضریب تعیین ($R^{2\ 2}$) و میانگین خطای مطلق (MAE^3) انتخاب شدند. در مدل شبکه عصبی، ضریب همبستگی بین مقادیر مشاهده‌ای و برآوردی، رایج‌ترین

جدول ۱- مقادیر رواناب و ورودی‌های مدل بارش- رواناب اندازه‌گیری شده برای پلات مرتعی

Table 1. Runoff values and inputs of rainfall-runoff model in rangeland plot

بارش Raifall (mm)	بارش ۵ روز قبل The last 5 day rainfall (mm)	رواناب Runoff (lit)	درصد پوشش مرتعی Rangeland Canopy	ارتفاع پوشش Tree height (cm)	درصد لاش‌برگ Litter	فاصله شخم Tillage distance (cm)	درصد پوشش درختی Tree canopy	شیب Land slope (degree)
40.00	15.50	28.12	9.00	45	20	25	5	0
35.10	0.00	24.45	6.00	45	20	25	5	0
27.00	45.00	31.00	5.00	45	20	25	5	0
23.00	37.00	31.00	4.50	50	20	25	5	0
21.00	53.70	32.10	4.00	45	20	25	5	0
16.80	45.70	32.10	1.00	50	20	25	5	0
14.50	39.20	30.60	0.50	45	20	25	5	0
10.50	25.20	29.70	0.00	50	20	25	5	0
1.50	23.20	31.00	0.00	50	20	25	5	0
0.00	34.00	29.50	0.00	50	20	25	5	0
40.00	15.50	28.12	4.00	100	20	0	0	0
35.10	0.00	24.45	3.00	100	20	0	0	0
27.00	45.00	31.00	0.50	100	20	0	0	0
23.00	37.00	31.00	0.00	100	20	0	0	0
21.00	53.70	32.10	0.00	100	20	0	0	0
16.80	45.70	32.10	0.00	100	20	0	0	0
14.50	39.20	30.60	0.00	100	20	0	0	0
10.50	25.20	29.70	0.00	100	20	0	0	0
1.50	23.20	31.00	0.00	100	20	0	0	0
0.00	34.00	29.50	0.00	100	20	0	0	0

1- The Mean squared error

2- The coefficient of determination

3- The mean absolute error (MAE)

جدول ۲- مقادیر رواناب و ورودی‌های مدل بارش- رواناب اندازه‌گیری شده برای پلات مرتعی مشجر

Table 2. Runoff values and inputs of rainfall-runoff model in the rangeland plot with tree cover

بارش Raifall (mm)	بارش ۵ روز قبل The last 5 day rainfall (mm)	رواناب Runoff (lit)	درصد پوشش مرتعی Rangeland Canopy	ارتفاع پوشش Tree height (cm)	درصد لاش‌برگ Litter	فاصله شخم Tillage distance (cm)	درصد پوشش درختی Tree canopy	شیب Land slope (degree)
40.00	15.50	28.12	8.00	45	20	25	5	30
35.10	0.00	24.45	5.70	45	20	25	5	30
27.00	45.00	31.00	4.80	45	20	25	5	30
23.00	37.00	31.00	4.20	50	20	25	5	30
21.00	53.70	32.10	3.30	45	20	25	5	30
16.80	45.70	32.10	1.00	50	20	25	5	30
14.50	39.20	30.60	0.40	45	20	25	5	30
10.50	25.20	29.70	0.00	50	20	25	5	30
1.50	23.20	31.00	0.00	50	20	25	5	30
0.00	34.00	29.50	0.00	50	20	25	5	30
40.00	15.50	28.12	3.80	100	20	0	0	50
35.10	0.00	24.45	2.80	100	20	0	0	50
27.00	45.00	31.00	0.40	100	20	0	0	50
23.00	37.00	31.00	0.00	100	20	0	0	50
21.00	53.70	32.10	0.00	100	20	0	0	50
16.80	45.70	32.10	0.00	100	20	0	0	50
14.50	39.20	30.60	0.00	100	20	0	0	50
10.50	25.20	29.70	0.00	100	20	0	0	50
1.50	23.20	31.00	0.00	100	20	0	0	50
0.00	34.00	29.50	0.00	100	20	0	0	50

جدول ۳- مقادیر رواناب و ورودی‌های مدل بارش- رواناب اندازه‌گیری شده برای پلات مدیریت شخم زراعی

Table 3. Runoff values and inputs of rainfall-runoff model in rangeland plot

بارش Raifall (mm)	بارش ۵ روز قبل The last 5 day rainfall (mm)	رواناب Runoff (lit)	درصد پوشش مرتعی Rangeland Canopy	ارتفاع پوشش Tree height (cm)	درصد لاش‌برگ Litter	فاصله شخم Tillage distance (cm)	درصد پوشش درختی Tree canopy	شیب Land slope (degree)
40.00	15.50	28.12	9.40	25	20	0	50	0
35.10	0.00	24.45	7.10	25	20	0	50	0
27.00	45.00	31.00	5.40	25	20	0	50	0
23.00	37.00	31.00	4.80	25	20	0	50	0
21.00	53.70	32.10	4.20	25	20	0	50	0
16.80	45.70	32.10	2.50	25	20	0	50	0
14.50	39.20	30.60	1.00	25	20	0	50	0
10.50	25.20	29.70	0.40	25	20	0	50	0
1.50	23.20	31.00	0.00	25	20	0	50	0
0.00	34.00	29.50	0.00	25	20	0	50	0
40.00	15.50	28.12	9.00	40	20	0	50	0
35.10	0.00	24.45	6.90	40	20	0	50	0
27.00	45.00	31.00	5.10	40	20	0	50	0
23.00	37.00	31.00	4.40	40	20	0	50	0
21.00	53.70	32.10	3.20	40	20	0	50	0
16.80	45.70	32.10	2.00	40	20	0	50	0
14.50	39.20	30.60	0.00	40	20	0	50	0
10.50	25.20	29.70	0.00	40	20	0	50	0
1.50	23.20	31.00	0.00	40	20	0	50	0
0.00	34.00	29.50	0.00	40	20	0	50	0

جدول ۴- مقادیر رواناب و ورودی‌های مدل بارش- رواناب اندازه‌گیری شده برای تیمار پلات لخت (بدون پوشش)

Table 4- Runoff values and inputs of rainfall-runoff model in the bare plot (without any cover)

بارش Raifall (mm)	بارش ۵ روز قبل The last 5 day rainfall (mm)	رواناب Runoff (lit)	درصد پوشش مرتعی Rangeland Canopy	ارتفاع پوشش Tree height (cm)	درصد لاش‌برگ Litter	فاصله شخم Tillage distance (cm)	درصد پوشش درختی Tree canopy	شیب Land slope (degree)
40.00	15.50	28.12	15.00	0	0	0	0	0
35.10	0.00	24.45	12.00	0	0	0	0	0
27.00	45.00	31.00	10.00	0	0	0	0	0
23.00	37.00	31.00	8.00	0	0	0	0	0
21.00	53.70	32.10	6.50	0	0	0	0	0
16.80	45.70	32.10	2.00	0	0	0	0	0
14.50	39.20	30.60	1.00	0	0	0	0	0
10.50	25.20	29.70	0.00	0	0	0	0	0
1.50	23.20	31.00	0.00	0	0	0	0	0
0.00	34.00	29.50	0.00	0	0	0	0	0

جدول ۵- مقادیر رواناب و ورودی‌های مدل بارش- رواناب اندازه‌گیری شده برای تیمار لاش‌برگ مرتعی

Table 5. Runoff values and inputs of rainfall-runoff model in the rangeland litter plot

بارش Raifall (mm)	بارش ۵ روز قبل The last 5 day rainfall (mm)	رواناب Runoff (lit)	درصد پوشش مرتعی Rangeland Canopy	ارتفاع پوشش Tree height (cm)	درصد لاش برگ Litter	فاصله شخم Tillage distance (cm)	درصد پوشش درختی Tree canopy	شیب Land slope (degree)
40.00	15.50	28.12	8.00	0	0	50	0	0
35.10	0.00	24.45	5.50	0	0	50	0	0
27.00	45.00	31.00	4.80	0	0	50	0	0
23.00	37.00	31.00	4.00	0	0	50	0	0
21.00	53.70	32.10	3.70	0	0	50	0	0
16.80	45.70	32.10	0.80	0	0	50	0	0
14.50	39.20	30.60	0.40	0	0	50	0	0
10.50	25.20	29.70	0.00	0	0	50	0	0
1.50	23.20	31.00	0.00	0	0	50	0	0
0.00	34.00	29.50	0.00	0	0	50	0	0
40.00	15.50	28.12	3.80	0	0	100	0	0
35.10	0.00	24.45	2.70	0	0	100	0	0
27.00	45.00	31.00	0.40	0	0	100	0	0
23.00	37.00	31.00	0.00	0	0	100	0	0
21.00	53.70	32.10	0.00	0	0	100	0	0
16.80	45.70	32.10	0.00	0	0	100	0	0
14.50	39.20	30.60	0.00	0	0	100	0	0
10.50	25.20	29.70	0.00	0	0	100	0	0
1.50	23.20	31.00	0.00	0	0	100	0	0
0.00	34.00	29.50	0.00	0	0	100	0	0

با شخم در جهت شیب زمین و کشت با شخم عمود بر جهت شیب از جنبه‌های شرایط پوشش گیاهی (درصد تاج پوشش، ارتفاع تاج پوشش) صورت پذیرفت. در شکل شماره (۲) یک جفت پلات زوجی که تنها در الگوی شخم متفاوت می‌باشند مشاهده می‌گردد. این پلات‌ها، با شرایط مشابه خاک و گونه مرتعی مشاهده در یک‌زمان احداث و کشت شده‌اند؛ اما در انتهای فصل رشد شرایط پوشش گیاهی آن‌ها و بخصوص مقادیر رطوبت خاک در سطح پلات‌ها کاملاً متفاوت بوده است. در گام بعدی براساس داده‌های به‌دست‌آمده، تجزیه و تحلیل آماری برای بررسی نقش هر یک از عوامل و تعیین مهم‌ترین عوامل تأثیرگذار انجام پذیرفته است و نتایج آن در جدول شماره (۶) ارائه شده است.

در مورد نحوه مدیریت زراعی همانند نحوه شخم دو الگوی شخم در جهت شیب و شخم عمود بر جهت شیب برای کشت گونه‌های مرتعی بومی مورد استفاده و مقایسه قرار گرفت. محدوده مطالعاتی بسیار محدود بوده است؛ بنابراین، تغییرات بافت خاک و خصوصیات خاک مشاهده نشده و از خاک به‌عنوان یک ورودی تأثیرگذار استفاده نشده است. از طرفی خصوصیات خاک بخصوص بافت خاک از مهم‌ترین عوامل مؤثر در تولید رواناب است اما چون هدف مطالعات ارزیابی اثر پوشش گیاهی و مدیریت زراعی در تولید رواناب است؛ بنابراین، باید شرایط یکسان برای سطح پلات‌های زوجی به‌منظور بی‌اثر کردن اثر خاک فراهم نمود. در نهایت در مورد تأثیر الگوی شخم زمین، در انتهای فصل رشد مقایسه بین پلات‌ها با تیمار کشت

جدول ۶- شدت همبستگی مقادیر رواناب و ورودی‌های مدل بارش- رواناب اندازه‌گیری شده برای تیمار لاش‌برگ مرتعی

Table 6. The correlation of runoff values and inputs of the rainfall-runoff model in the rangeland litter plot

بافت خاک Soil texture	شیب زمین Land slope	تاج پوشش درختی Tree canopy	فاصله شخم Tillage distance	درصد لاش‌برگ Litter	ارتفاع درخت Tree height	درصد پوشش مرتعی Rangeland Canopy	رطوبت پیشین خاک A.M.C	مقدار بارش Rainfall	مقدار رواناب Runoff
								1	مقدار رواناب Runoff
								0.76*	مقدار بارش Rainfall
							1	-0.32*	رطوبت پیشین خاک A.M.C
						1	0.0	0.0	-0.71*
					1	0.75*	0.0	0.0	0.03
					1	-0.72*	-0.56*	0.0	-0.23*
			1	-0.51*	0.56*	0.01	0.0	0.0	0.22*
			1	-0.2	-0.2*	0.32*	0.57*	0.0	-0.15*
		1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
	1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

* Significant relationship (P value < 0.05)

*: رابطه معنی‌دار در سطح احتمال ۰/۰۵

بهینه‌سازی شبکه نشان داد که میزان بارندگی، نوع پوشش گیاهی و تراکم پوشش گیاهی بهترین ورودی‌ها برای

در مطالعات مدل‌سازی بارش-رواناب، انتخاب مهم‌ترین ورودی‌ها برای مدل‌سازی مهم است. تجزیه و تحلیل آماری و

مدل‌سازی بارش-رواناب هستند. مطالعات قبلی به‌طور مشابه نشان داد که مقادیر رواناب تحت تأثیر ویژگی‌های بارندگی، پوشش گیاهی، شیب و شرایط رطوبت خاک قرار دارد (Gholami & Khalighi, 2020). براساس تجزیه و تحلیل آماری عوامل میزان بارندگی و رطوبت پیشین خاک رابطه مثبت با تولید رواناب دارند. همچنین، پوشش گیاهی و لاش‌برگ با مقادیر رواناب رابطه معکوس دارند (جدول ۶). در نهایت، مهم‌ترین عامل در کنترل تولید رواناب، عامل پوشش گیاهی است ($R^2 = 0.71$). علاوه بر این، تغییرات شیب و خاک عوامل تعیین‌کننده برای تولید رواناب هستند، اما در تحقیق حاضر هدف بررسی نقش پوشش گیاهی و مدیریت اراضی در تولید رواناب بوده است. لذا، برای بررسی تأثیر این دو عامل در پلات‌های زوجی می‌بایست شرایط یکسانی از لحاظ شیب زمین و خصوصیات خاک وجود داشته باشد. این امر منجر به آن شده است خصوصیات مهم خاک نظیر بافت خاک و عامل مهمی چون شیب زمین به‌عنوان عوامل اصلی یا ورودی‌های مدل تعیین نشده‌اند. در حقیقت بحث تأثیر عوامل پوشش گیاهی یا تغییرات تولید رواناب در سطح قطعات زمین‌های کوچک با شرایط تقریباً یکسان خاک و شیب زمین دنبال شده است. از طرفی پلات‌های کوچک با طول دو متری نمی‌تواند روش مناسبی برای ارزیابی اثر طول شیب باشد (Liu et al. 2020 Ghahramani et al. 2011). به‌طور یقین بر روی یک دامنه شیب‌دار، اراضی یا سطوح پایین‌دست شیب از توسط رواناب بالادست شیب تغذیه می‌شوند و سرعت جریان رواناب سطحی رو به پایین‌دست شیب افزایش است. در نهایت با در نظر گرفتن اهداف مطالعات، ابعاد پلات‌ها و طول شیب مطالعاتی از دخالت شیب زمین به‌عنوان یک عامل مهم در تولید رواناب صرف‌نظر شده است.

عامل پوشش گیاهی تأثیرات چندجانبه‌ای در مورد تولید رواناب دارد. نوع پوشش و تراکم پوشش مهم‌ترین عامل است. پوشش مرتعی یا پوشش زراعی کوتاه‌قد با تراکم بالا دارای حداکثر کارایی است؛ زیرا هم اثر پاشمان باران را کنترل می‌نماید و هم بعد نفوذ و جذب آب بالایی دارد. بیشترین کارایی در کنترل تولید رواناب در پلات دارای پوشش مرتعی با تاج پوشش صد درصد مشاهده شده است. پوشش گیاهی به‌نوعی تعیین‌کننده مقادیر لاش‌برگ و هوموس خاک است. گونه‌های درختی نیز به‌طور محدودی در کنترل کاهش رواناب مؤثر بوده‌اند و اگر پوشش مرتعی در زیر تاج پوشش درختان مستقر شود موجب کارایی مضاعفی در کاهش تولید رواناب خواهد شد. هرچند عموماً زیر درختان یا اراضی جنگلی پوشش مرتعی حداکثری رویت نشده است. نتایج نشان داد با توجه به تعداد محدود درختان به‌واسطه گیرش گیاهی مقادیر تولید رواناب تا حداکثر ۱۰ درصد کاهش دهند که در مطالعات گذشته این اثر پوشش جنگلی بین ۴۰ درصد جنگل‌های متراکم تا جنگل‌های تنک متغیر بوده است (Laufer et al., 2016).

اثر لاش‌برگ در کاهش تولید رواناب بسیار متغیر است و بستگی به میزان و نوع لاش‌برگ دارد (Buendia et al., 2016; Wolka et al., 2018). نتایج نشان داد که هر دو

عامل نوع لاش‌برگ (بقایای گونه‌های مرتعی یا درختی) و میزان یا درصد پوشش لاش‌برگ در کنترل ایجاد رواناب تأثیرگذار می‌باشند. استفاده از لاش‌برگ و سرشاخه‌های درختی خردشده با اندازه بزرگ می‌تواند منجر به تولید رواناب سطحی زیر توده لاش‌برگ گردد که ماندگاری آن‌ها بیشتر است؛ اما لاش‌برگ گیاهان علفی و گونه‌های مرتعی کارایی نسبتاً بهتری در کنترل رواناب و فرسایش خاک دارند.

یکی از موارد مهم اثر مدیریت زراعی و الگوی شخم است. این مورد به‌صورت برآورد رقمی در تجزیه و تحلیل‌های آماری ارزیابی نشده است؛ اما مقایسه دو پلات مجاور یکی با تیمار کاشت گونه مرتعی در جهت شیب و دیگری با کشت همان‌گونه در عمود بر جهت شیب در شکل شماره (۲) مشاهده می‌گردد. دو پلات به لحاظ شیب، خصوصیات خاک، مقادیر بارش، گونه کاشت شده، نحوه کاشت و رطوبت پیشین خاک کاملاً مشابه بوده و تنها تفاوت در نحوه شخم زمین بوده است. در سطح پلات‌ها در ابتدای بهار کاشت انجام شده و سه ماه بعد با قرق کامل و بدون هرگونه دخالت یا آبیاری شرایط شکل مذکور رویت شده است. پلات دارای شخم و کشت عمود بر شیب در مقایسه با پلات شخم و کشت در جهت شیب، دارای رطوبت بیشتر، پوشش گیاهی بیشتر و سالم‌تر و استقرار گونه‌های مرتعی جدید و حتی پهن برگان بوده است. مقایسه این دو پلات نشان می‌دهد که شخم در جهت عمود به شیب و کشت نواری در عمود به جهت شیب، منجر به کاهش سرعت رواناب، نفوذ بیشتر رواناب، حفظ رطوبت بیشتر در خاک، شرایط بهتر رشد و نمو پوشش گیاهی می‌شود (Muñoz-Robles, 2010). در نهایت این موارد منجر به کاهش فاحش تولید رواناب خواهد شد که مقایسه رواناب اندازه‌گیری شده در این دو پلات در وقایع متعدد بارش بیانگر این مطلب بوده است و پلات دارای شخم و کشت عمود در جهت شیب پس از استقرار کامل پوشش گیاهی می‌تواند تا ۵۰ درصد در کاهش تولید رواناب مؤثرتر باشد (Laufer et al., 2016).

در مدل شبکه‌های عصبی روش آزمون-خطا برای تعیین ورودی‌های بهینه و تعیین ساختارهای بهینه شبکه به کار گرفته شد که نتایج حاکی از آن است که مقادیر بارش، نوع پوشش گیاهی، درصد تاج پوشش گیاهی ورودی‌های بهینه جهت شبیه‌سازی مقادیر رواناب می‌باشند. همچنین نتایج نشان داد که تابع انتقال تانژانت هیپربولیک و فن یادگیری LM بهترین گزینه‌ها برای ساختار بهینه شبکه‌ها می‌باشند که در تحقیقات گذشته نیز آن‌ها جزء بهترین گزینه‌ها محسوب می‌شدند (Gholami, et al., 2018). آنچه مسلم است در ساختارهای مختلف شبکه عصبی توابع انتقال، فن یادگیری و تعداد نرون‌ها مشابه نبوده است. آموزش شبکه‌های عصبی دو مرحله آموزش نتایج خوبی به همراه داشته است که نتایج مذکور در جدول شماره (۷) ارائه شده است. براساس نتایج، مدل به‌کاررفته دارای کارایی بالایی در برآورد مقادیر رواناب می‌باشند.

پس از آموزش شبکه، اعتبارسنجی یا آزمودن انجام شد و نتایج مرحله آزمودن در جدول شماره (۸) ارائه شده است.

مرحله آزمون در شکل شماره (۳) ارائه شده است. همان‌طور که مشاهده می‌گردد که تطابق خوبی بین مقادیر شبیه‌سازی شده و مقادیر مشاهداتی است.

براساس نتایج و بخصوص مقادیر شاخص‌هایی جدول (۵) شبکه MLP به‌عنوان یک شبکه کارآمد جهت شبیه‌سازی مقادیر رواناب یا فرآیند بارش- رواناب است. همچنین، مقایسه بین مقادیر شبیه‌سازی شده و مقادیر مشاهداتی رواناب در

جدول ۷- نتایج مدل‌سازی فرآیند بارش- رواناب در مرحله آموزش با به‌کارگیری شبکه عصبی MLP.


Table 7. The results of training stage in rainfall-runoff modeling using MLP network

	کمترین مقدار آموزش Minimum training standard deviation	انحراف معیار مرحله آموزش Training standard deviation	کمترین مقدار صحت‌سنجی Minimum cross validation standard deviation	انحراف معیار مرحله صحت‌سنجی Cross validation standard deviation
میانگین کمترین مقدار مربعات خطا Minimum MSE	0.004	0.0003	0.015	0.0002
میانگین نهایی مربعات خطا Final MSE	0.004	0.0003	0.015	0.0003

جدول ۸- نتایج ارزیابی کارایی شبکه عصبی در مرحله آزمون یا اعتبارسنجی با به‌کارگیری شبکه عصبی MLP

Table 8. The results of test stage rainfall-runoff modeling using MLP network

	میانگین مربعات خطا MSE	میانگین خطای نرمال شده NMSE	میانگین خطای مطلق MAE	حداقل خطای مطلق Min Abs Error	حداکثر خطای مطلق Max Abs Error	ضریب تعیین R_{sq}
مقدار برآوردی Estimated value	4.2	0.15	1.6	0.17	5.7	0.91



شکل ۳- مقایسه مقادیر برآوردی شبکه عصبی و مقادیر اندازه‌گیری شده رواناب در مرحله آزمون
Figure 3. Comparison of the predicted and measured values of runoff in the test stage

مقادیر حداکثر یا مقادیر بالاتر رواناب خواهند بود. برای حل این مشکل تکرار ورودی‌های بارش‌های شدید و مقادیر حجم رواناب‌های بالاتر در فرآیند مدل‌سازی باید استفاده گردد. در حقیقت در فرآیند آموزش مدل بهتر است تعداد بیشتری مقادیر رگبارهای شدید مورد استفاده قرار گیرد. لازم به ذکر است که در شبیه‌سازی فرآیند بارش- رواناب، برآورد دقیق مقادیر حداکثری رواناب یا شبیه‌سازی رگبارهای شدید مهم بوده و می‌تواند یک داده مهم در برنامه‌ریزی مدیریت اراضی و حفاظت از آب و خاک باشد.

نکته دارای اهمیت در مورد مدل بکار رفته در شبیه‌سازی فرآیند بارش- رواناب تحقیق حاضر آن است که ورودی‌های اصلی یا ورودی‌های بهینه مدل یعنی مقادیر بارش، ارتفاع پوشش گیاهی، درصد تاج پوشش گیاهی و رطوبت پیشین خاک برای پیش‌بینی مقادیر رواناب لازم است که همگی قابل

شبیه‌سازی فرآیند بارش- رواناب با به‌کارگیری شبکه عصبی دارای کارایی بالایی در برآورد رواناب بوده است. ارزیابی نتایج مرحله آموزش و آزمون از طریق شاخص‌های خطا و مقایسه مقادیر مشاهداتی و شبیه‌سازی شده بیانگر کارایی شبکه عصبی در شبیه‌سازی فرآیند بارش- رواناب در مراحل مدل‌سازی و آزمون مدل است؛ اما دقت این شبیه‌سازی در مورد مقادیر حداقلی، متوسط و حداکثری تولید رواناب یکسان نیست. مدل مقادیر حداقلی و متوسط رواناب را با دقت بالاتری شبیه‌سازی می‌نماید و در مقادیر حداکثری رواناب دارای خطای بیشتری است (Sahour et al., 2020)؛ زیرا براساس مقادیر بارش و رواناب اندازه‌گیری شده، بین مقادیر بارش و مقادیر رواناب یک رابطه غیرخطی وجود دارد. از طرفی، در مقادیر حداکثری تعداد کمتری اندازه‌گیری و ثبت داده‌ها داشتیم؛ بنابراین، مدل‌ها دارای خطای بیشتری در

دسترس یا قابل محاسبه می‌باشند. در حقیقت با استفاده از داده‌های بارش ایستگاه‌های هواشناسی، مقادیر بارش، مجموع بارش ۵ روز قبل (رطوبت پیشین خاک) در مقیاس سالانه و یا حتی مقیاس زمانی طولانی‌تر در دسترس است و می‌توان مدل آزمون شده را برای شبیه‌سازی مقادیر رواناب در مقیاس‌های زمانی مختلف بکار گرفت. همچنین، می‌توان اثر شدت بارش را براساس آمار ایستگاه‌های باران‌سنج ثبات به‌عنوان یک ورودی مهم مورد مطالعه قرارداد یا مدلی با اعمال شدت بارش در کنار پارامترهای دیگر ارائه نمود. در نهایت، این مدل در دارای قابلیت شبیه‌سازی اثر سناریوهای مختلف کاربری، پوشش گیاهی و بارش را در تولید رواناب است.

نتیجه‌گیری کلی

براساس نتایج مطالعات، پوشش مرتعی دارای بالاترین کارایی در کنترل میزان رواناب بوده است. در این میان برخی خصوصیات پوشش گیاهی نظیر نوع پوشش گیاهی و تراکم آن مهم‌ترین عامل کنترل‌کننده ایجاد رواناب در اراضی شیب‌دار است. علاوه بر این، نحوه مدیریت زمین، الگوی کشت و نحوه شخم زمین نیز از دیگر عوامل مهم هستند؛ بنابراین، می‌توان براساس خصوصیات خاک، شیب زمین و رطوبت پیشین خاک، مقادیر تلفات کل و هدر رفت اولیه را برآورد نمود و الگوی‌های کشت یا نوع پوشش گیاهی مناسب را برای کنترل یا کاشت رواناب انتخاب و عملکرد آن‌ها را طی فرآیند بارش-رواناب مدل‌سازی کرد. همچنین یک مدل آزمایش‌شده مبتنی بر شبکه عصبی می‌تواند ابزاری برای برآورد مقادیر رواناب در مقیاس ماهانه و سالانه براساس داده‌های بارش ایستگاه‌های هواشناسی باشد. متأسفانه،

اطلاعات دقیقی از تولید رواناب در اراضی با کاربری‌ها مختلف در دسترس نیست. از طرفی، اندازه‌گیری‌های رواناب هزینه‌بر و زمان‌بر است. بنابراین، استفاده از هوش مصنوعی و انتخاب ورودی‌های بهینه می‌تواند ابزاری کارآمد برای پیش‌بینی مقادیر رواناب باشد. در این راستا، انتخاب ورودی‌ها و تعیین دقیق آن‌ها روی دقت نتایج تأثیر فاحشی دارد. بنابراین، گام نخست در فرآیند مدل‌سازی بارش-رواناب تعیین ورودی‌های اصلی و برآورد دقیق آن‌ها و سپس به‌کارگیری صحیح یک مدل کارآمد است. ویژگی بارز استفاده از هوش مصنوعی در شبیه‌سازی فرآیند بارش-رواناب، سرعت عمل، دقت بالا و هزینه پایین و از همه مهم‌تر توانایی به‌کارگیری ساختارهای مختلف و مدل‌ها با ورودی‌های متناسب با شرایط منطقه و داده‌های در دسترس است. همچنین، می‌توان با تعریف سناریوهای مختلف پوشش گیاهی و کاربری اراضی، اثر آن‌ها را تولید رواناب بررسی نمود. از مدل مذکور می‌توان برای شبیه‌سازی اثر سناریوهای مختلف پوشش گیاهی در تولید رواناب و یا برآورد رواناب ناشی از سناریوهای توسعه آبی و مدیریت اراضی استفاده نمود. برای مطالعات آبی پیشنهاد می‌گردد با استفاده از آمار ایستگاه‌های باران‌سنجی ثبات، شدت بارش به‌عنوان یک ورودی مهم در فرآیند مدل‌سازی‌ها آبی مورد استفاده قرار گیرد. همچنین، مطالعات آبی با استفاده از تعداد بیشتری پلات با درجات مختلف شیب و انواع کاربری اراضی مختلف و رویدادهای بارندگی شدیدتر انجام گردد.

تشکر و قدردانی

بر خود لازم می‌دانیم از زحمات مسئولان دانشکده منابع طبیعی دانشگاه گیلان بابت فراهم آوردن امکان استقرار پلات‌ها و انجام مطالعات قدردانی نماییم.

منابع

- Abrahart, R.J., See, L.M. (2000). Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecast in two contrasting catchments. *Hydrological Process*, 14: 2157-2172.
- Adamowski, J. (2013). Using support vector regression to predict direct runoff, base flow and total flow in a mountainous watershed with limited data in Uttaranchal, India. *Versita*, 45, 71-83.
- Anctil, F., Rat, A. (2005). Evaluation of neural networks streamflow forecasting on 47 watersheds. *J. Hydrol. Eng.*, ASCE 10 (1): 85-88. [http://dx.doi.org/10.1061/\(ASCE\)1084-0699\(2005\)10:1\(85\)](http://dx.doi.org/10.1061/(ASCE)1084-0699(2005)10:1(85)).
- ASCE Task Committee. (2000). Artificial neural networks in hydrology, II: Hydrology application. *Journal of Hydrologic Engineering*, 5: 124-137.
- Braddock, R. D., Kremmer, M.L., Sanzogni, L. (1998). Feedforward artificial neural network model for forecasting rainfall-runoff. *Environmental Sciences*, 9: 419-432.
- Buendia, C., Batalla, R.J., Sabater, S., Palau, A., Marcé, R. (2016). Runoff trends driven by climate and afforestation in a Pyrenean Basin. *Land Degrad. Dev.* 27(3), 823-838. <https://doi.org/10.1002/ldr.2384>.
- Garosi, Y., Sheklabadi, M., Conoscenti, C., Pourghasemi, H.R., Van Oost, K. (2019). Assessing the performance of GIS-based machine learning models with different accuracy measures for determining susceptibility to gully erosion. *Sci. Total Environ*, 664, 1117-1132. <https://doi.org/10.1016/j.scitotenv.2019.02.093>.
- Gao, J., Bai, Y., Cui, H., Zhang, Y. (2020). The effect of different crops and slopes on runoff and soil erosion. *Water Pract. Technol.*, 15 (3), 773-780. <https://doi.org/10.2166/wpt.2020.061>.

- Ghahramani, F., Ishikawa, Y., Gomi, T. (2011). Slope length effect on sediment and organic litter transport on a steep forested hillslope: upscaling from plot to hillslope scale. *Hydrol. Res. Lett.*, 5, 16–20. doi:10.3178/hr1.5.16.
- Gholami, V., Booij, M.J., Tehrani, E.N., Hadian, M.A. (2018). Spatial soil erosion estimation using an artificial neural network (ANN) and field plot data. *Catena*, 163, 210–218.
- Gholami, V., Khaleghi, M.R. (2020). A simulation of the rainfall-runoff process using artificial neural network and HEC-HMS model in forest lands. *Journal of Forest Science*, 67: 165–174. <https://doi.org/10.17221/90/2020-JFS>.
- Harris, M.T., Boardman, J. (1990). A rule-based Expert System Approach to Predicting Waterborne Soil Erosion. p. 401-412. In J. Boardman, D.L. Foster and J.A. Dearing (Editors). *Soil Erosion on Agricultural Land*, John Wiley & Sons Ltd.
- Heidari Chenari F., Fazloulou, R., Nikzad Tehrani, E. (2022). Calibration and Evaluation of HEC-HMS Hydrological Model Parameters in Simulation of Single Rainfall-Runoff Events (Case Study: Tajan Watershed). *jwmr*, 13(26), 69-81. doi:10.52547/jwmr.13.26.69.
- Hsu, K.L., Gupta, H.V., Sorooshian, S. (1995). Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research*, 31(10): 2517-2530.
- Hu, T., Wu, F., Zhang, X. (2007). Rainfall-runoff modeling using principal component analysis and neural network. *Nordic Hydrology*, 38(3): 235-248.
- Isik, S., Kalin, L., Schoonover, J., Srivastava, P., Lockaby, B.G. (2013). Modeling effects of changing land use/cover on daily streamflow: an artificial neural network and curve number based hybrid approach. *J. Hydrol.*, 485, 103–112. <https://doi.org/10.1016/j.jhydrol.2012.08.032>
- Kashani, M.H., Ghorbani, M.A., Shahabi, M., Naganna, S.R., Diop, L. (2020). Multiple AI model integration strategy—application to saturated hydraulic conductivity prediction from easily available soil properties. *Soil Tillage Res.*, 196, 104449 <https://doi.org/10.1016/j.still.2019.104449>.
- Khan, S.M., Coulibaly P., and Dibike, Y. (2006). Uncertainty analysis of statistical downscaling methods. *J. hydrol.*, 319: 357- 382.
- Kisi, O. (2008). River flow forecasting and estimation using different artificial neural network technique. *Hydrology Resource*, 39(1): 27-40.
- Laufer, D., Loibl, B., Märlander, B., Koch, H.J. (2016). Soil erosion and surface runoff under strip tillage for sugar beet (*Beta vulgaris* L.) in Central Europe. *Soil Tillage Res.*, 162, 1-7. <https://doi.org/10.1016/j.still.2016.04.007>.
- Liu, H.Q., Yang, J.H., Liu, C.X., Diao, Y.F., Ma, D.P., Li, F.H., Rahma, A.E., Lei, T.W. (2020). Flow velocity on cultivated soil slope with wheat straw incorporation. *J. hydrol.*, 584, 124667. <https://doi.org/10.1016/j.jhydrol.2020.124667>.
- Lippman, R.P. (1987). An Introduction to computing with Neural Networks. *IEEE ASSP Magazine*, 4-22.
- Loh, W., Tim, L. (2000). A comparison of prediction accuracy, complexity, and training time of thirty three old and new classification algorithm. *Mach. Learn*, 40 (3): 203–238.
- Luo, J., Zheng, Z., Li, T., He, S. (2020). Temporal variations in runoff and sediment yield associated with soil surface roughness under different rainfall patterns. *Geomorphology*, 349. <https://doi.org/10.1016/j.geomorph.2019.106915> p.106915.
- Minns, A.W., Hall, M.J. (1996). Artificial neural network as rainfall-runoff model. *Hydrological Science Journal*, 41(3): 399-417.
- Muñoz-Robles, C. (2010). Runoff and erosion in woody encroachment, pasture and woodland vegetation in semi-arid New South Wales, Australia. *PhD thesis, School of Environmental and Rural Science*, University of New England. Armidale, NSW, 208 pp.
- Nawar, S., Mouazen, A.M. (2019). On-line vis-NIR spectroscopy prediction of soil organic carbon using machine learning. *Soil Tillage Res.*, 190, 120–127. <https://doi.org/10.1016/j.still.2019.03.006>.
- Prasad, R., Deo, R.C., Li, Y., Maraseni, T. (2018). Ensemble committee-based data intelligent approach for generating soil moisture forecasts with multivariate hydro-meteorological predictors. *Soil Tillage Res.*, 181, 63–81. <https://doi.org/10.1016/j.still.2018.03.021>.
- Rafiei Sardoi, E., Rostami, N., Khalighi Sigaroudi, S., Taheri, S. (2012). Calibration of loss estimation methods in HEC-HMS for simulation of surface runoff (Case Study: Amirkabir Dam Watershed, Iran). *Adv. Environ. Biol.*, 6(1), 343-348.

- Sahour, H., Gholami, V., Vazifedan, M. (2020). A comparative analysis of statistical and machine learning techniques for mapping the spatial distribution of groundwater salinity in a coastal aquifer. *J. Hydrol.*, 591 p.125321.
- Wang, W.C., Chau, K.W., Cheng, C.T. Qui, L. (2009). A comparison of performance of several Artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*, 374: 294-306.
- Wolka, K., Mulder, J., Biazin, B. (2018). Effects of soil and water conservation techniques on crop yield, runoff and soil loss in Sub-Saharan Africa: A review. *Agric. Water Manage.*, 207, 67-79. <https://doi.org/10.1016/j.agwat.2018.05.016>.
- Zhao, Y., Meng, X., Qi, T., Qing, F., Xiong, M., Li, Y., Guo, P. Chen, G., (2020). AI-based identification of low-frequency debris flow catchments in the Bailong River basin, China. *Geomorphology*, <https://doi.org/10.1016/j.geomorph.2020.107125> p.107125.

“Research Paper”

Prediction of rainfall-runoff process using field plots and artificial neural network (ANN)

Mohammadali Hadian Amri¹, Vahid Gholami² and Atena Yousefi³

1- Assistant Professor, Department of Soil Conservation and Watershed Management, Mazandaran Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Sari, Iran

2- Associate Professor, Department of Nature Engineering, Faculty of Natural Resources, University of Guilan, Rasht, Iran, (Corresponding author: gholami.vahid@guilan.ac.ir)

3- MSc of Rangeland Management, Former Student of University of Tehran, Iran

Received: 17 September, 2023 Accepted: 21 October, 2023

Extended Abstract

Introduction and Objective: Predicting the rainfall-runoff process is an important issue in the management of natural resources as well as water resources. However, this process has its complexities and many effective factors, including rainfall factors (rainfall intensity and value), vegetation (type and canopy), soil factors (soil texture, initial soil moisture, and soil permeability) and It is the way of land management. The current research aimed to provide a model for predicting the rainfall-runoff process using artificial neural network (ANN) modeling and field runoff data.

Material and Methods: The research was conducted on a hillslope located in the University of Guilan with clay-loam soil, in the form of replicated pairs of plots in different vegetation treatments and land management. Moreover, using a rain gauge set, the amount of rainfall was measured after each rainfall event. The amount of runoff was also estimated by the plots, and from the difference between the amounts of rainfall and runoff, the amounts of initial loss on the surface of each plot were calculated for each rainfall event in different previous soil moisture conditions. Then, to model the obtained data, they were divided into training and test data categories. The parameters of runoff values were considered as the output of the model and rainfall values, the percentage of rangeland and tree cover, the previous soil moisture, and the percentage of litter were considered as the inputs of the model.

Results: The values of $R^2=0.97$, $MSE=0.004$ and $R^2=0.91$, $MSE=4.2$ were obtained in the training stage and the testing stage of the model, respectively, and finally a high-performance model for simulating the rainfall-runoff process was obtained. The result of the modeling process showed that the rangeland cover has the highest efficiency in runoff control.

Conclusion: The mentioned model can be used to predict the effect of different vegetation scenarios on runoff generation or to estimate runoff based on the rainfall of meteorological stations.

Keywords: Cover treatments, Couple plot, Initial loss, Prediction, ANN, Training and Testing data