

Research Paper

Prediction of the 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- M.Sc of Rangeland Management, Former Student of the University of Tehran, Tehran, Iran

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

Extended Abstract

Background: Simulation of the rainfall-runoff process for estimating runoff due to rainfall is an important step in planning and management of natural resources and water resources, especially in watersheds without hydrometric stations. However, this process has its own complexities and several affecting factors such as precipitation factors (amount and intensity of rainfall), vegetation cover (type of cover and cover density), soil factors (soil texture, soil initial moisture, and permeability), and land management quality. This study aimed to provide a model for simulating the rainfall-runoff process using artificial neural network (ANN) modeling and runoff data of field plots.

Methods: The study was executed on a slope at Guilan University using clay-loam soil in a repetitive way, with paired plots subjected to different vegetation and land management treatments. The amount of rain was measured after every rainfall using a storage rain gauge. Runoff values were estimated by plots, and from the difference between precipitation and runoff values, the initial loss values at the surface of each plot were calculated for each precipitation event under different soil moisture conditions. The total precipitation of the previous five days was estimated as the previous soil moisture. Regarding the agronomic management method, two patterns of plowing in the slope direction and plowing perpendicular to the slope direction were used and compared to patrolling native rangeland species. The changes in slope, soil texture, and soil properties were negligible due to the limits of the area, thus soil was not used as an input affecting runoff. Since the aim was to evaluate the effect of vegetation cover and agronomic management on runoff production, it was necessary to provide the same conditions for the level of paired plots to neutralize the effect of soil. To model the obtained data, they were divided into two categories: educational and subject data. The parameters of runoff values were considered the output of the model, and the precipitation values, percentage of rangeland and tree canopy, precious soil moisture, and percentage of leaf litter were regarded as the optimal inputs of the model. The land slope was estimated by surveying. Vegetation cover and leaf litter percentages were measured using the ratio of vegetated area to the total plot and microplot area. It is difficult to quantitatively determine the type of coverage, but the height of the vegetation was also considered due to the simulation of the effect of raindrops, rain spraying, and tree foliage.

Results: The amount of reserve was actually very small due to the limited area of plots. Based on statistical analysis, the rainfall and previous soil moisture factors have a positive relationship with runoff production. Vegetation and leaf litter have an inverse relationship with runoff values. Finally, the most important factor in controlling runoff production is vegetation cover ($R^2 = -0.71$). The highest efficiency in controlling runoff production was observed in a plot with a rangeland cover of 100% canopy cover. Vegetation somehow determines the amount of leaf litter and humus in the soil. Tree species have also been limited in controlling runoff reduction, and if rangeland cover is located under the canopy of trees, it will cause double efficiency in reducing runoff production. However, there is generally no maximum pasture cover under trees or forest lands. The results showed that the amount of runoff production can be reduced by up to 10% due to the limited number of trees due to vegetation. In previous studies, this effect of forest cover varied between 40% of dense forests and sparse forests. The results also show that both factors of the type of leaf litter and the amount or percentage of leaf cover are influential in controlling runoff. Regarding the effect of plowing patterns, the results show that plowing and



strip cultivation in the direction perpendicular to the slope direction lead to a decrease in the runoff rate, more runoff penetration, more moisture retention in the soil, and better conditions for vegetation growth and development. Finally, these cases will lead to a significant decrease in runoff production. A comparison of the measured runoff in these two plots in different precipitation events has indicated that the plot with plowing and perpendicular cultivation in the direction of slope after the complete establishment of vegetation can be up to 50% more effective in reducing runoff production. The results of the trial-error method in the neural network model indicate that the rainfall values, the type of vegetation cover, and the percentage of vegetation canopy are the optimal inputs for simulating runoff values. The results also show that the hyperbolic tangent transfer function and the LM learning technique are the best options for the optimal structure of networks. Neural network training in two stages showed that the used model was highly efficient in estimating runoff values. Based on the validation results, the MLP is an efficient network for simulating runoff values or the rainfall-runoff process. Moreover, a comparison between the simulated and the observed values of runoff in the experimental phase showed a good agreement between the simulated and the observed values. The values of $MSE = 0.97$, $R^2 = 0.004$ and $MSE = 0.91$, $R^2 = 4.2$ were obtained in the training and testing phases of the model, respectively, and, finally, a high-performance model was presented to simulate the rainfall-runoff process. The result of the modeling process showed that rangeland cover had the highest efficiency in controlling runoff.

Conclusion: Vegetation characteristics, such as vegetation type and density, are the most important factors controlling runoff in sloping lands. In addition, land management, cultivation patterns, and plowing methods are other important factors. Therefore, it is possible to estimate the total losses and initial loss based on soil characteristics, land slope, and previous soil moisture and to select suitable cultivation patterns or vegetation types for runoff control or planting and model their yields during the rainfall-runoff process. A tested model based on the neural network can also be a tool for estimating runoff values on a monthly and annual scale based on the precipitation data of meteorological stations. The model can be used to simulate the effect of different vegetation scenarios on runoff production or to estimate runoff based on the precipitation of meteorological stations.

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

How to Cite This Article: Hadian Amri, M., Gholami, V., & Yousefi, A. (2024). Prediction of the Rainfall-runoff Process using Field Plots and Artificial Neural Network (ANN). *J Watershed Manage Res*, 15(1), 94-106. DOI: [10.61186/jwmr.15.1.94](https://doi.org/10.61186/jwmr.15.1.94)

مقاله پژوهشی

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

محمدعلی هادیان امری^۱، وحید غلامی^۲ ID 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، تهران، ایران

تاریخ دریافت: ۱۴۰۲/۰۳/۲۷ تاریخ پذیرش: ۱۴۰۲/۰۷/۲۹

صفحه: ۹۴ تا ۱۰۶

چکیده مبسوط

مقدمه و هدف: شبیه‌سازی فرایند بارش- رواناب برای برآورد رواناب ناشی از وقوع بارندگی گامی مهم در برنامه‌ریزی و مدیریت منابع طبیعی و منابع آب به‌ویژه در آبخیزهای فاقد ایستگاه‌های هیدرومتری است؛ اما این فرایند دارای پیچیدگی‌های خاص خود و عوامل مؤثر متعدد ازجمله 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 فرایند بارش- رواناب با استفاده از مدل‌سازی شبکه عصبی مصنوعی (ANN) و داده‌های رواناب 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 و از تفاوت مقادیر بارش و رواناب‌ها، مقادیر هدررفت اولیه در سطح هر پلات به‌ازای هر واقعه بارش در شرایط متفاوت رطوبت پیشین خاک محاسبه گردید. مجموع بارش پنج روز قبل به‌عنوان رطوبت پیشین خاک برآورد شد. در مورد نحوه مدیریت زراعی دو الگوی شخم در جهت شیب و شخم عمود بر جهت شیب برای گشت گونه‌های مرتعی بومی مورد استفاده و مقایسه قرار گرفت. تغییرات شیب، بافت خاک و خصوصیات خاک به‌دلیل محدودیت سطح ناچیز بود؛ لذا از خاک به‌عنوان یک ورودی تأثیرگذار بر روی رواناب استفاده نشده است. چون هدف ارزیابی اثر پوشش گیاهی و مدیریت زراعی در تولید رواناب بود؛ بنابراین، باید شرایط یکسان برای سطح پلات‌های زوجی به‌منظور بی‌اثر کردن اثر خاک فراهم نمود. 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 شد. شیب زمین با استفاده از مساحی برآورد گشت. درصد پوشش گیاهی و درصد لاش‌برگ با استفاده از نسبت سطح پوشش گیاهی به سطح کل پلات و میکروپلات اندازه‌گیری شد. تعیین نوع پوشش به‌صورت کمی مشکل است؛ اما به‌دلیل شبیه‌سازی اثر قطرات باران، پاشمان باران و برگ‌بافت درختان، ارتفاع پوشش گیاهی نیز در نظر گرفته شد.

یافته‌ها: به‌دلیل سطح محدود پلات‌ها عملاً مقدار ذخیره بسیار ناچیز بود. براساس تجزیه و تحلیل آماری عوامل میزان بارندگی و رطوبت پیشین خاک رابطه مثبت با تولید رواناب دارند. پوشش گیاهی و لاش‌برگ با مقادیر رواناب رابطه معکوس دارند. درنهایت، مهم‌ترین عامل در کنترل تولید رواناب، عامل پوشش گیاهی است ($R^2=0.71$). 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 گِیرش 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. همچنین 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 هستند. درمورد تأثیر الگوی شخم، نتایج نشان می‌دهد که شخم و کشت نواری در جهت 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. درنهایت این موارد منجر به کاهش فاحتش 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. نتایج روش آزمون-خطا در مدل شبکه‌های عصبی حاکی از آن است که مقادیر بارش، نوع پوشش گیاهی، درصد تاج پوشش گیاهی و 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. آموزش شبکه‌های عصبی در دو مرحله نشان داد مدل به‌کاررفته دارای کارایی بالایی در برآورد مقادیر رواناب می‌باشند. براساس نتایج اعتبارسنجی، شبکه MLP به‌عنوان یک شبکه کارآمد جهت شبیه‌سازی مقادیر رواناب یا فرایند بارش- رواناب است. همچنین، مقایسه بین مقادیر شبیه‌سازی شده و مقادیر مشاهداتی رواناب در مرحله آزمون نشان داد که تطابق خوبی بین مقادیر شبیه‌سازی شده و مقادیر مشاهداتی است. 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 به‌دست آمد و درنهایت مدلی با کارایی بالا برای شبیه‌سازی فرایند بارش- رواناب ارائه شد. نتیجه فرایند مدل‌سازی نشان داد که پوشش مرتعی دارای بالاترین کارایی در کنترل میزان رواناب است.

نتیجه‌گیری: 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 الگوهای کشت یا نوع پوشش گیاهی مناسب را برای کنترل یا کاشت رواناب انتخاب و عملکرد آن‌ها را طی فرایند 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. 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: پلات زوجی، تیمارهای پوشش، داده‌های آموزشی و آزمایشی، مدل‌سازی، هدر رفت اولیه، ANN

مقدمه

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 برنامه ریزی منابع آب به ویژه 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 به راحتی امکان پذیر 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.

پراساد و همکاران (Prasad et al., 2018)، نوار و موذن (Nawar & Mouazen, 2019) و کاشانی و همکاران (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 (به عنوان 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 به عنوان 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.

غلامی و همکاران (Gholami et al., 2018) با به کارگیری 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. آداموسکی (Adamowski, 2013) با استفاده از

شبکه عصبی مصنوعی به مدل‌سازی فرآیند بارش- رواناب حوضه کوهستانی دهرادان در یوتارانتچال 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 انجام شده توسط بارادوک (Braddok et al., 1988) و ژاو و همکاران (Zhao et al., 2020) باهدف پیش‌بینی رواناب با به کارگیری 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 درخصوص 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 این رو، 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.

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 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 باریک 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

علف باغ) استفاده شد. درصدهای متفاوت لاش‌برگ (خاک لخت، ۳۰ درصد، پوشش ۵۰ درصد، پ.شش 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.

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




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



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 قرق 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)



ادامه شکل ۲- تیمارهای مختلف پلات‌های زوجی (الف) تیمار پوشش مرتعی (ب) تیمار شخم و لاش برگ (پ) تیمار کشت نوری و کشت عمود بر جهت شیب؛ (ت) تیمار قرق و مالچ گیاهی (لاش برگ و سرشاخه خردشده)
 Countineud 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)

می‌دهد. آزمودن یا آزمون در عمل اعتبارسنجی مدل بهینه‌شده را برعهده 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 لاش برگ به‌عنوان ورودی‌های مدل در نظر گرفته شدند. ابتدا داده‌ها تصادفی یا 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^{2Y}) و میانگین خطای مطلق (MAE^3) انتخاب شدند. در مدل شبکه عصبی، ضریب

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; Braddok et al., 1998; Harris & Boardman, 1998; Loh & Tim, 2000; ASCE, 2000 Braddok et al., 1998). براساس پژوهش‌های برادوک و همکاران (Braddok et al., 1998) عمده شبکه‌های عصبی مصنوعی که در مسائل هیدرولوژی استفاده شده‌اند، از نوع الگوریتم پس‌پراکنش (Backward propagation) هستند. ازجمله 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.

MLP (Multilayer perceptron network) 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 به‌عهده دارد و صحت‌سنجی مرحله‌ای از مدل‌سازی است که بهینه‌سازی و جلوگیری از آموزش بیش از اندازه را انجام

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.

همبستگی بین مقادیر مشاهده‌ای و برآوردی، رایج‌ترین 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 هریک از وقایع بارش توسط مخزن انتهایی آن گردآوری و حجم رواناب برآورد شد. 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

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 Rainfall (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

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 Rainfall (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)	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)	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)	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	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

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 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

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 به‌خصوص بافت خاک از مهم‌ترین عوامل مؤثر در تولید رواناب است اما چون هدف مطالعات ارزیابی اثر

براساس داده‌های به‌دست‌آمده، تجزیه و تحلیل آماری برای بررسی نقش هر یک از عوامل و تعیین مهم‌ترین عوامل تأثیرگذار انجام و نتایج آن در جدول شماره (۶) ارائه شده است.

مشاهده می‌گردد. این پلات‌ها، با شرایط مشابه خاک و گونه مرتعی در یک‌زمان احداث و کشت شده‌اند؛ اما در انتهای فصل رشد شرایط پوشش گیاهی آن‌ها و به‌خصوص مقادیر رطوبت خاک در سطح پلات‌ها کاملاً متفاوت بوده است. در گام بعدی

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	-0.71*	درصد پوشش مرتعی Rangeland Canopy
					1	0.75*	0.0	0.03	ارتفاع درختان Tree height
				1	-0.72*	-0.56*	0.0	-0.23*	میزان لاش‌برگ Litter
			1	-0.51*	0.56*	0.01	0.0	0.22*	فواصل شخم Tillage distance
		1	-0.2	-0.2*	0.32*	0.57*	0.0	-0.15*	درصد تاج پوشش درخت Tree canopy
	1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	شیب زمین Land slope
1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	بافت خاک Soil texture

*: رابطه معنی‌دار در سطح احتمال ۰/۰۵

* Significant relationship (P value <0.05)

مناسبی برای ارزیابی اثر طول شیب باشد (Liu *et al.* 2020). 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 کوتاه با تراکم بالا دارای حداکثر کارایی است؛ زیرا هم اثر پاشمان باران را کنترل می‌نماید و هم موجب جذب آب و نفوذ بالا است. بیشترین کارایی در کنترل تولید رواناب در پلات دارای پوشش مرتعی با تاج پوشش صددرصد 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).

در مطالعات مدل‌سازی بارش-رواناب انتخاب مهم‌ترین ورودی‌ها برای مدل‌سازی مهم است. تجزیه و تحلیل آماری و بهینه‌سازی شبکه نشان داد که میزان بارندگی، نوع پوشش گیاهی و تراکم پوشش گیاهی بهترین ورودی‌ها برای 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 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

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 آموزش-خطا برای تعیین ورودی‌های بهینه و تعیین ساختارهای بهینه شبکه به‌کار 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 در 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. براساس نتایج و به‌خصوص مقادیر شاخص‌هایی جدول (۵) شبکه MLP به‌عنوان یک شبکه کارآمد جهت شبیه‌سازی مقادیر رواناب یا فرایند بارش-رواناب است. همچنین، مقایسه بین مقادیر شبیه‌سازی‌شده و مقادیر مشاهداتی رواناب در مرحله آزمودن در شکل شماره (۳) ارائه شده است. همان‌طور که مشاهده می‌گردد که تطابق خوبی بین مقادیر شبیه‌سازی‌شده و مقادیر مشاهداتی است.

اثر لاشبرگ در کاهش تولید رواناب بسیار متغیر است و بستگی به میزان و نوع لاش‌برگ دارد (Buendia et al., 2018; Wolka et al., 2016). 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 شمار (۲) مشاهده می‌گردد. دو پلات به‌لحاظ 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 انجام‌شده 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 جهت 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). درنهایت این موارد منجر به کاهش فاحش تولید رواناب خواهد شد که مقایسه رواناب

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


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

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

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

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

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



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

شدت بارش را براساس آمار ایستگاه‌های باران‌سنج ثابت به‌عنوان یک ورودی مهم مورد مطالعه قرارداد یا مدلی با اعمال شدت بارش در کنار پارامترهای دیگر ارائه نمود. درنهایت، 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

شبیه‌سازی فرآیند بارش-رواناب با به‌کارگیری شبکه عصب دارای کارایی بالایی در برآورد رواناب بوده است. ارزیابی نتایج مرحله آموزش و آزمون از طریق شاخص‌های خطا و مقایسه مقادیر مشاهداتی و شبیه‌سازی‌شده 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 می‌نمایند 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 حداکثری تعداد کمتری رابطه غیرخطی وجود دارد. از طرفی، در مقادیر حداکثری تعداد کمتری اندازه‌گیری و ثبت داده‌ها داشتیم؛ بنابراین، مدل‌ها دارای خطای بیشتری در 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 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 به‌کار گرفت. همچنین، می‌توان اثر

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.

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 ثابت، شدت بارش به‌عنوان یک ورودی مهم در فرآیند مدل‌سازی‌ها

References

- 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/hrl.5.16
- Gholami, V., Booi, 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., Fazloul, 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). *Journal of Watershed Management Research*, 13(26), 69-81 (In Persian). 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., & 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., Loiblb, 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.