



شناسه دیجیتال (DOI): 10.22034/ijf.2022.317309.1823
شناسه دیجیتال (DOR): 20.1001.1.20086113.1401.14.4.5.7

مجله جنگل ایران، انجمن جنگل‌بانی ایران
سال چهاردهم، شماره ۴، زمستان ۱۴۰۱
ص ۴۴۳-۴۲۵

مقاله پژوهشی

شناسایی و مدل‌سازی عوامل مؤثر در تولید رواناب و رسوب از توده‌های بهره‌برداری شده جنگلی

پژمان دلیر^{۱*}، رامین نقدی^۲، وحید غلامی^۳ و ساناز جعفری هفتخوانی^۴

^۱ دانشجوی دکتری، گروه جنگلداری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران
^۲ استاد گروه جنگلداری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران
^۳ دانشیار گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران
^۴ دانش‌آموخته کارشناسی ارشد، گروه احیای مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، ایران

(تاریخ دریافت: ۱۴۰۰/۱۰/۱۴؛ تاریخ پذیرش: ۱۴۰۱/۲/۱۹)

چکیده

در این پژوهش تأثیر بهره‌برداری بر رواناب و رسوب با استفاده از پلات‌هایی با مقیاس کوچک بررسی شد. نمونه رواناب و رسوب از ۳۶ پلات به ابعاد ۱ در ۲ متر تهیه شد. پلات‌ها در قسمت‌های مختلف عرصه بهره‌برداری و منطقه شاهد احداث شد. به‌منظور مدل‌سازی از شبکه پرسپترون چندلایه (Multi Layer Perceptron) MLP استفاده شد. ۶۵ درصد داده‌ها برای آموزش و ۱۰ درصد برای صحت‌سنجی و ۲۵ درصد داده‌ها به آزمون اختصاص داده شد. برای ارزیابی صحت مدل و همچنین مقایسه آن با مدل‌های بهینه‌سازی‌شده با روش آزمون و خطا، از معیارهای آماری ضریب تبیین (Rsqr)، جذر میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) استفاده شد. از GIS در همه مراحل جمع‌آوری اطلاعات استفاده شد. مقادیر رواناب و رسوب شبیه‌سازی‌شده به‌وسیله ANN با استفاده از GIS در تولید نقشه استفاده شد. نتایج نشان داد که مهم‌ترین عوامل در تولید رواناب، جرم مخصوص خاک، شدت بارش، شیب، مقدار بارش، درصد پوشش علفی و درصد پوشش تاجی و برای رسوب به‌ترتیب، شدت بارش، جرم مخصوص خاک، درصد شیب و درصد پوشش علفی است. مقادیر MSE و R حاصل از مدل‌سازی رواناب در مرحله آموزش به‌ترتیب ۰/۰۰۹ و ۰/۹ و در مرحله آزمون ۰/۱ و ۰/۸۲ بود. مقادیر MSE و R حاصل از مدل‌سازی رسوب در مرحله آموزش ۰/۰۱ و ۰/۸۶ و در مرحله آزمون ۴/۳ و ۰/۸ بود. نتایج نشان داد که شبکه عصبی قابلیت مناسبی در مدل‌سازی رواناب و رسوب در اراضی جنگلی دارد. آنالیز همپوشانی مقادیر اندازه‌گیری‌شده و نقشه مقادیر رسوب و رواناب نیز بر صحت، کارایی نتایج و روش ارائه‌شده دلالت دارد. بنابراین می‌توان از مدل ارائه‌شده با تلفیق ANN و GIS در شبیه‌سازی و مدل‌سازی رواناب و رسوب در مناطق جنگلی استفاده کرد.

واژه‌های کلیدی: جنگل، شبکه عصبی، فرسایش خاک، GIS، MLP.

مقدمه

کاهش نفوذپذیری خاک جنگل و افزایش مقادیر رواناب می‌شود (Megahan, 1972; Jordan & Martinez, 2008). در مناطق مورد بهره‌برداری، حضور افراد، ادوات، ماشین‌آلات بهره‌برداری و فشار ناشی از وزن آنها (Fathi et al., 2021; Zhao et al., 2019) و همچنین کاهش پوشش درختی و حذف پوشش علفی در سطح جنگل (Ding et al., 2022; Li)

جاده‌سازی، استفاده از ماشین‌آلات، ورود افراد بهره‌بردار به منطقه و ایجاد شبکه ریزافت حمل‌ونقل از نیازهای اصلی بهره‌برداری چوب در جنگل است (Mceachran et al., 2018; Etehad et al., 2018; Cambi et al., 2017; Jourgholami et al., 2017). استفاده از این امکانات سبب تغییراتی در زمینه

مدل SWAT^۳ برای شبیه‌سازی رواناب و رسوب استفاده شد. نتایج این پژوهش نشان داد که بهره‌برداری به‌دلیل تغییر در پوشش تاجی و افزایش جرم مخصوص خاک سبب افزایش مقادیر رواناب می‌شود. (Shinohara et al., 2019) در ژاپن به بررسی تأثیر پوشش گیاهی، لاشبرگ و حجم ریشه در مقادیر رسوب و رواناب پرداختند. بدین منظور از پلات‌های ۱ متر در ۲ متر برای جمع‌آوری رواناب سطحی و رسوب استفاده شد. نتایج این پژوهش نشان داد که لاشبرگ و لایه سطحی خاک در پلات‌های تحت بررسی، مهم‌ترین عامل مؤثر در مقادیر رواناب و رسوب است. (Jourgholami et al., 2018) بهره‌برداری از جنگل تغییرات زیاد در خاک سطحی و زیرسطحی ایجاد می‌کند و در نتیجه سیستم هیدرولوژیک جنگل هم دچار تغییر می‌شود. فشار ناشی از بهره‌برداری و کاهش نفوذپذیری و همچنین برداشت لایه هوموس سطحی سبب افزایش رواناب و همچنین رسوب از مناطق بهره‌برداری شده می‌شود. (Gholami et al., 2019) به بررسی کارایی تلفیق شبکه عصبی مصنوعی با سیستم اطلاعات جغرافیایی در شبیه‌سازی فرسایش پرداختند و نتیجه گرفتند که با استفاده همزمان از دو ابزار قدرتمند ANN و GIS بر قدرت هر کدام افزوده می‌شود که کارایی بهتر آنها را در مقابل استفاده مجزا از هر کدام در پی دارد. (Etehad et al., 2018) در پژوهشی در جنگل خیرود تأثیر بهره‌برداری بر مقدار رواناب و رسوب را بررسی کردند. برای این منظور، پلات‌های ۲ متر مربعی در قالب چهار تکرار در دو منطقه شاهد (بدون بهره‌برداری) و بهره‌برداری شده به روش تک‌گزینی در دو طبقه شیب ۲۰-۴۰ درصد و ۴۰-۲۰ درصد ایجاد شد. نتایج تحقیق نشان داد که مقدار رواناب، ضریب رواناب و غلظت رسوب در منطقه بهره‌برداری شده به روش تک‌گزینی، بیشتر از منطقه شاهد است. همچنین نتایج تجزیه

(Dalir et al., 2011) و کاهش لاشبرگ در منطقه (Dalir et al., 2015) از علل افزایش رواناب و رسوب است. پژوهشگران زیادی در زمینه عوامل مؤثر در تولید رواناب و رسوب تحقیق کرده‌اند و عوامل مؤثر مختلفی را در این زمینه مؤثر برشمرده‌اند (Grace, 2002; Yu et al., 2003; Grismer & Hogan, 2005; Foltz & Wagenbrenner, 2010; Dalir et al., 2014; Dalir et al., 2015a,b; Dalir et al., 2021). شبکه عصبی مصنوعی (ANN^۱) ابزاری کارآمد در مدل‌سازی و برآورد پارامترهای محیطی است (Maire et al., 2000; Riad et al., 2004; Gholami et al., 2019). اما این شبکه نمی‌تواند نتایج را به‌صورت زمین‌مرجع و گرافیکی ارائه دهد. که این موضوع، به‌کارگیری نتایج را برای عموم متخصصان دشوار و محدود می‌کند. از طرفی، سیستم اطلاعات جغرافیایی (GIS^۲) سامانه‌ای قدرتمند در مدیریت و پردازش داده‌های مکانی است (Talebi et al., 2022)، اما این سامانه فقط توان مدل‌سازی‌های فیزیکی یا اجرای مدل‌های اعتباریابی شده را داراست (Gholami et al., 2021; Ebrahimi, 2017; Jokar et al., 2013). بنابراین می‌توان با تلفیق قابلیت‌های شبکه عصبی مصنوعی و سیستم اطلاعات جغرافیایی، نتایج مدل‌سازی دقیق را به‌صورت گرافیکی زمین‌مرجع ارائه کرد. تحقیقات مختلفی در زمینه تأثیر بهره‌برداری بر رواناب و رسوب در نقاط مختلف انجام گرفته است. (Rachels et al., 2020) به بررسی آثار برداشت جنگل بر ورودی رسوب به جریان‌ها و شناسایی بهترین روش مدیریت در کاهش اثر بهره‌برداری پرداختند. نتایج نشان داد که منبع اصلی رسوب در حوضه آبریز مورد بهره‌برداری، دیواره رودخانه و سپس دامنه‌ها و در نهایت جاده‌ها هستند. مهم‌ترین عامل مؤثر در تولید رسوب، برداشت پوشش علفی است. (Kazemi et al., 2019) در حوضه جنگلی زیلکی رود تأثیر بهره‌برداری بر رواناب و رسوب را بررسی کردند. در این پژوهش از

1. Artificial Neural Network
2. Geographic Information System

3. Soil and Water Assessment Tool (SWAT)

مواد و روش‌ها

منطقه پژوهش

منطقه پژوهش سری چهار شیرقلايع به‌عنوان منطقه بهره‌برداري شده و بخشی از همین منطقه که به‌صورت حفاظت شده است، به‌عنوان منطقه شاهد، واقع در حوضه آبخیز سیاهکل در شرق استان گیلان و در شهرستان سیاهکل است. محدوده سری چهار، جزء آبخیز رودخانه ملکرد و مشتمل بر ۲۵۰۰ هکتار است و جزء حوزه استحفاظی اداره کل منابع گیلان محسوب می‌شود. جنگل‌های این سری براساس سیستم مختصات utm^1 در طول $39^{\circ} 02'$ تا $39^{\circ} 09'$ شرقی و در عرض $40^{\circ} 93'$ تا $41^{\circ} 09'$ شمالی واقع است. حدود ارتفاعی منطقه حداقل ۲۸۰ متر و حداکثر ۱۴۵۰ متر از سطح دریاست. شکل ۱ نقشه منطقه پژوهش را نشان می‌دهد. متوسط بارش سالانه منطقه حدود ۱۲۰۷ میلی‌متر است. اقلیم منطقه براساس روش دومارتن، از نوع خیلی مرطوب است. بر اساس پژوهش‌ها، سابقه بهره‌برداری از جنگل در منطقه از سال ۱۳۵۴ در قالب روش دانه‌زاد به شیوه پناهی آغاز و در سال ۱۳۷۶ طرح تجدید نظر به شیوه تک‌گزینی ارائه شد. ماشین‌آلات استفاده‌شده برای بهره‌برداری در منطقه، اغلب اهره موتوری برای قطع و استحصال؛ و اسکیدر، تراکتور و تریلی برای حمل چوب‌آلات بود. بخشی از مقطوعات توسط حیوانات (اغلب توسط قاطر) حمل شد.

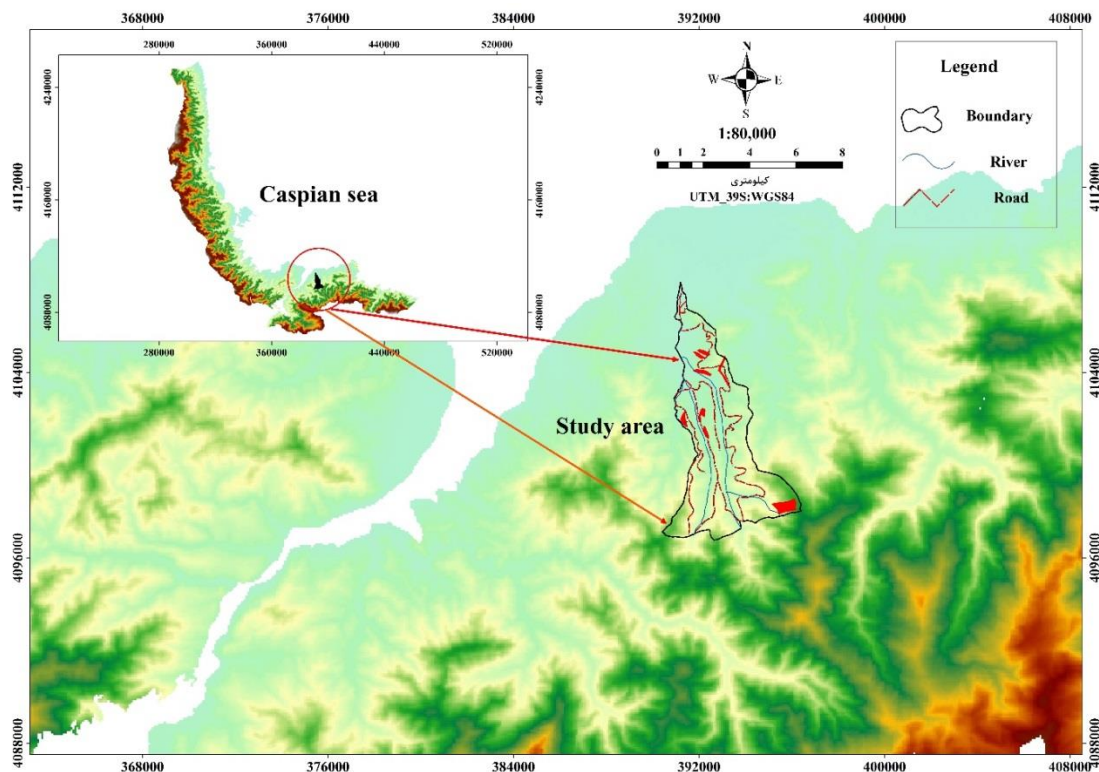
بهره‌برداری در این سری به روش تک‌گزینی انجام گرفته است. مقدار برداشت چوب در طی ده سال اجرای طرح تجدید نظر، ۱۲۸۰۷ متر مکعب معادل ۴/۸۶ درصد از موجودی طرح پیش‌بینی شد. گونه‌های درختی منطقه راش (*Fagus orientalis* Lipsky.)، ممرز (*Carpinus betulus* L.) و گونه‌های همراه بیشتر توسکای قشلاقی (*Alnus glutinosa* (L) Gaertn.) و توسکای بیلاقی (*Alnus subcordata* (C.A.Mey. است. غالب گونه‌های درختچه‌ای از گیل

واریناس رگرسیون نشان داد که بین مقدار بارندگی و مقدار رواناب ارتباط معنی‌داری وجود دارد.

(Khazayi et al., 2013) در پژوهشی به بررسی کاربرد شبکه عصبی مصنوعی و مدل‌های همبستگی در برآورد تلفات خاک با استفاده از پلات پرداختند و با توجه به نتایج بیان کردند که در همه موارد شبکه عصبی مصنوعی نسبت به مدل‌های دیگر، دقت و صحت بیشتری در شبیه‌سازی تلفات خاک دارد. استفاده از شبکه عصبی مصنوعی در مطالعات مختلف، روشی جدید و کارآمد است که در سال‌های اخیر مدنظر پژوهشگران رشته‌های مختلف قرار گرفته است (Dalir et al., 2022; Zema et al., 2020). پژوهش در زمینه استفاده از شبکه عصبی مصنوعی برای شبیه‌سازی رواناب و رسوب در مناطق جنگلی بهره‌بردار شده شمال ایران که سالیان متمادی بهره‌برداری قرار گرفته است کمتر دیده می‌شود. بنابراین بررسی توانایی تلفیق شبکه عصبی مصنوعی و سیستم اطلاعات جغرافیایی در مناطق بهره‌برداری شده در جنگل‌های شمال ایران، موضوعی درخور پژوهش و بررسی است. جنگل‌های هیرکانی در ایران میراث باارزش چندمیلیون‌ساله‌ای است که از اهمیت ویژه‌ای برخوردار است. معضل خشکسالی، کاهش آب‌های زیرزمینی، خشک شدن رودخانه‌های و تالاب‌ها و دیگر مسائل زیست‌محیطی موجود حاصل تغییر در ماهیت منابع طبیعی، مدیریت نادرست و دخالت‌ها نامناسب در این منابع است. موضوع رواناب و رسوب در این مناطق از موضوعات اساسی و بااهمیت است که باید مدنظر پژوهشگران و مدیران قرار گیرد. هدف این بررسی، شناسایی عوامل مؤثر در تولید رواناب و رسوب از مناطق مورد بهره‌برداری و همچنین مدل‌سازی عوامل مؤثر در رواناب و رسوب است. تهیه اطلاعات برای مناطق فاقد آمار و نقشه‌سازی برای مناطق جنگلی در زمینه رواناب و رسوب از اهداف دیگر این پژوهش است.

است. خاک منطقه اغلب رسی لومی و گاهی با رس بیشتر است. متوسط پوشش تاجی منطقه ۹۰-۲۵ درصد است.

(*Mespilus germanica* L.)، سرخ ولیک
(*Crataegus monogyna* Jacq.) و سیاه ولیک
(*Crataegus pentayna* Waldst. et Kit. (willd.)



شکل ۱- نقشه منطقه پژوهش

Figure 1. Location of the study area

همچنین در مناطق فاقد بهره‌برداری به‌عنوان منطقه شاهد پلات‌های رواناب و رسوب ایجاد شد. شکل ۲، نمونه‌ای از پلات‌های نمونه‌برداری رواناب و رسوب در منطقه پژوهش را نشان می‌دهد. در محل هر کدام از پلات‌های احداث‌شده، نمونه خاک با استفاده از سیلندر نمونه‌برداری خاک به قطر ۵ و ارتفاع ۱۰ سانتی‌متر و همچنین مقدار لازم نمونه خاک از عمق ۵ تا ۱۰ سانتی‌متری سطح خاک برای آزمایش‌های خاک برداشت شد (Zenner et al., 2007)، وزن اولیه نمونه‌های خاک برای برآورد وزن مخصوص ظاهری و رطوبت خاک ثبت شد و سپس نمونه به آزمایشگاه منتقل شد. با استفاده از ۵۰ گرم نمونه خاک عبور کرده از الک شماره ۱۰ در آزمایشگاه، بافت خاک به روش هیدرومتری بایکاس اندازه‌گیری شد (Gee &


شیوه اجرای پژوهش نمونه‌برداری رواناب و رسوب با استفاده از پلات‌های صحرایی

برای بررسی رواناب و رسوب در مناطق بهره‌برداری‌شده، پلات‌های جمع‌آوری رواناب و رسوب به ابعاد ۱ در ۲ متر در جهت شیب ساخته شد (Shinohara et al., 2019). پلات‌ها در شیب‌های مختلف، پوشش تاجی مختلف، پوشش کف متفاوت و ویژگی‌های متفاوت خاک احداث شدند. ۳۶ پلات رواناب و رسوب در منطقه احداث شد. سعی شد پلات‌ها نماینده تمام قسمت‌های منطقه بهره‌برداری‌شده در کل سری بوده و پراکنش مناسبی در واحدهای کاری داشته باشند. مقادیر رواناب و رسوب تولیدشده برای وقایع رگبار جداگانه توسط دیواره‌های پلات‌ها جمع‌آوری و به مخزن منتقل شد.

et al., 2021). داده‌های مربوط به بارش‌ها و داده‌های اقلیمی با استفاده از اندازه‌گیری مستقیم در محل نصب پلات‌ها و همچنین نزدیک‌ترین ایستگاه ثابت در منطقه پژوهش جمع‌آوری شد. برای مدل‌سازی رواناب و رسوب، تعداد و تنوع داده‌ها، از جمله داده‌های بارش باید مناسب باشد. در زمان اجرای این پژوهش، در طول دوره نمونه‌برداری، بارش‌های زیادی روی داد، اما با توجه به ظرفیت نفوذ و شرایط وقوع رواناب در مناطق جنگلی تنها، تعداد سه واقعه بارش سبب ایجاد رواناب قابل اندازه‌گیری شد. بنابراین در این بررسی به این تعداد بسنده شد و در مجموع ۱۰۸ داده رواناب و رسوب از ۳۶ پلات در مقیاس کوچک با سه واقعه بارش با مقدار ۵۵، ۳۷ و ۲۵ میلی‌متر در تاریخ ۹۶/۰۷/۱۱، ۹۶/۱۱/۷ و ۹۶/۱۱/۸ به‌دست آمد جدول ۱ مشخصات سه واقعه بارش را نشان می‌دهد.

جدول ۱- مشخصات شدت، مدت و مقدار بارش‌های استفاده‌شده در پژوهش
Table 1. rainfall intensity, duration and rainfall values used in the study

تعداد Numbers	مقدار بارش (میلی‌متر) Rainfall values (mm)	شدت بارش (میلی‌متر بر ساعت) Rainfall intensity (mm/h)	تاریخ Date	مدت بارش (ساعت) Rainfall duration (h)
1	37	10	96/07/11 2017-10-03	3:42
2	55	40	96/11/07 2018-01-27	1:22
3	25	25	96/11/08 2018-01-28	1

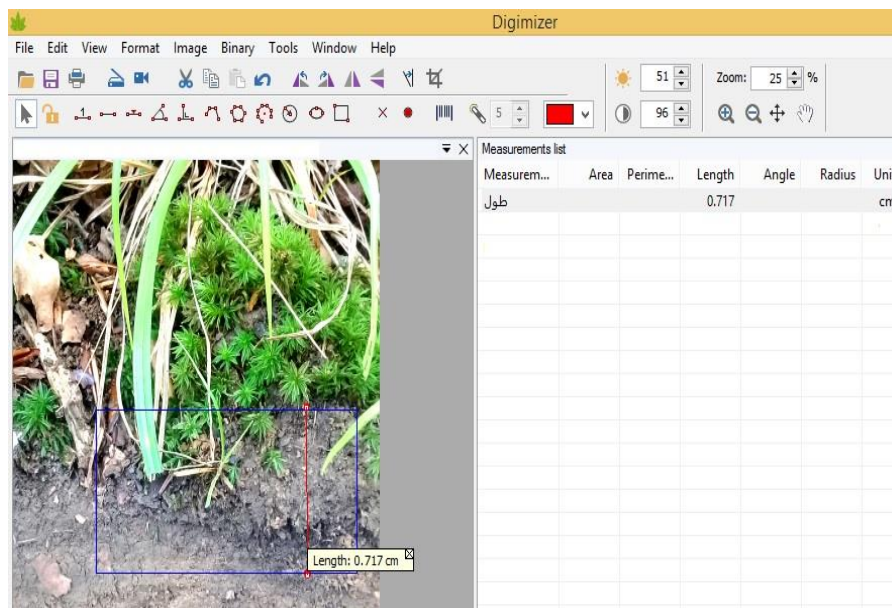


شکل ۲- نمونه پلات‌های اندازه‌گیری رواناب و رسوب

Figuer 2. A view of the plots used for runoff and sediment measurement

(Bander, 1986)، همچنین کربن، جرم مخصوص ظاهری و رطوبت خاک در آزمایشگاه برآورد شد (Gee & Bander, 1986; Reichert et al., 2018). در این پلات‌ها، حجم لاشبرگ با استفاده از پلات ۱ در ۱ متر برداشت و وزن شد (Li et al., 2014)، عمق لایه هوموس با استفاده از عکس دیجیتال و نرم‌افزار دیجی‌مایزر اندازه‌گیری شد (شکل ۳).

تأثیر جاده‌ها، مسیرهای چوبکشی و مسیرهای مال‌رو با احداث پلات در این مناطق بررسی شد. پس از هر رگبار مقادیر رواناب و رسوب موجود در مخازن به مخازن دیگر منتقل شد و نمونه جمع‌آوری‌شده به آزمایشگاه انتقال یافت و با استفاده از ظروف اندازه‌گیری، حجم رواناب اندازه‌گیری شد. با استفاده از روش ته‌نشینی و کاغذ صافی رواناب از رسوب جدا شده و مقدار رسوب به‌دست‌آمده خشک و توزین شد (Dalir



شکل ۳- اندازه گیری عمق لایه هوموس در نرم افزار دیجی مایزر، در این تصویر عمق لایه هوموس ۰/۷۱ سانتی متر اندازه گیری شد.
 Figure 3. Humus depth masurment in digimazer software, in this picture humus depth was measured 0.71 centimeter

براساس منابع موجود ۶۵ درصد برای آموزش، ۱۰ درصد برای صحت سنجی و ۲۵ درصد برای آزمون به کار گرفته شد (Gholami et al., 2015; Krishna et al., 2008). نتایج آموزش و آزمون کارایی شبکه برای رواناب با تابع انتقال تانژانت هیپربولیک، روش یادگیری ممنتموم و تعداد نورون ۱ و نتایج آزمون کارایی شبکه برای رسوب با تابع انتقال تانژانت هیپربولیک، روش یادگیری ممنتموم و تعداد نورون ۱ به دست آمد. بعد از این مرحله، همه پیکسل های شبیه سازی شده وارد محیط سیستم اطلاعات جغرافیایی (GIS) شد. همه آنالیزهای مربوط، به کمک نرم افزارهای NeuroSolutions و ArcGIS انجام گرفت. در مرحله بعد، با استفاده از نقشه های زمین شناسی منطقه پژوهش، نقشه ۱/۲۵۰۰۰ خاک شناسی و نقشه های پایه (شیب، جهت، ارتفاع) در محیط سیستم اطلاعات جغرافیایی نقشه واحدهای کاری تهیه شد. در این نقشه ۱۷ واحد کاری شناسایی شد. با برداشت مختصات نقاط، این محل ها با عملیات میدانی شناسایی و مشخص شد. در این مناطق پروفیل خاک حفر شد. براساس نتایج پروفیل ها، نقشه های بافت خاک، جرم مخصوص خاک، رطوبت خاک، مقدار هوموس و کربن خاک تهیه شد.

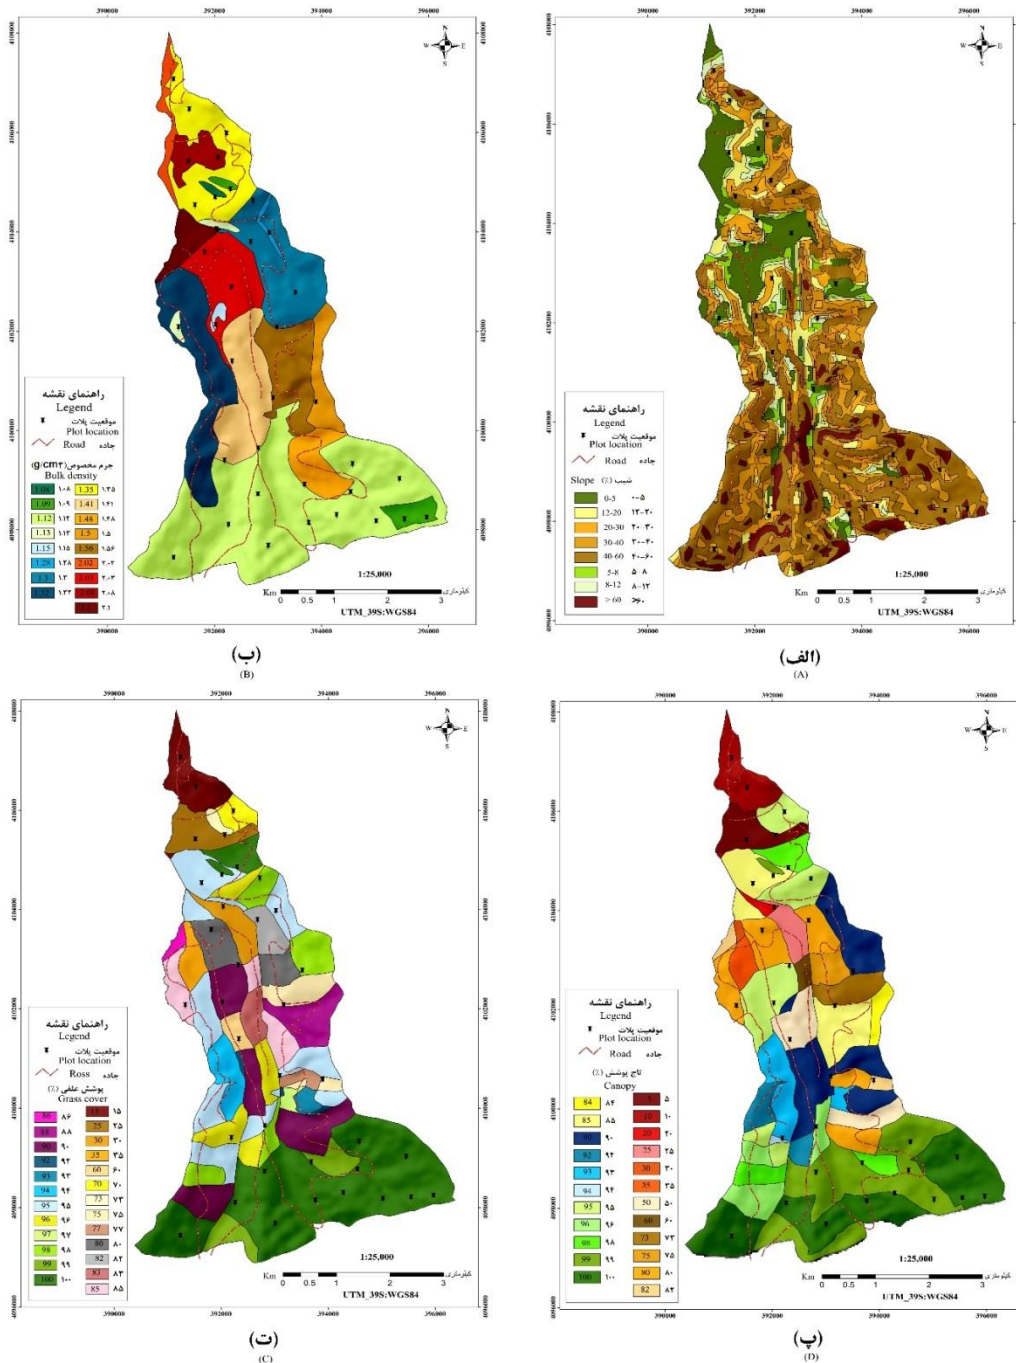
مدل سازی با استفاده از شبکه عصبی مصنوعی

با استفاده از مقادیر واقعی حاصل از پلات ها و داشتن مقدار هر کدام از عوامل مؤثر در مقدار رواناب و رسوب در منطقه پژوهش، با استفاده از شبکه عصبی مصنوعی، بهترین ترکیب و مدل شبیه سازی رواناب و رسوب، مدل سازی و شناسایی شد.

در این تحقیق از شبکه پرسپترون چندلایه MLP (Multi Layer Perceptron) در محیط نرم افزار NeuroSolutions استفاده شد (Gholami et al., 2019). بدین منظور مقادیر رواناب و رسوب به عنوان خروجی شبکه (متغیر وابسته) و عوامل مؤثر در آن به عنوان ورودی ها (مقدار بارش، شدت بارش، درصد پوشش علفی، درصد تاج پوشش، ارتفاع تاج، هوموس، کربن خاک، رس، ماسه، سیلت، جرم مخصوص، فاصله از جاده و فاصله از روستا) شبکه استفاده شد. با استفاده از روش آزمون و خطا و تفکیک داده ها یا نمونه ها به سه دسته داده های آموزشی (Training)، داده های صحت سنجی (Cross Validation) و داده های آزمون (Test) ساختار بهینه شبکه تعیین شد (Gholami et al., 2019). پس از آموزش و بهینه سازی شبکه، مراحل صحت سنجی و آزمون یا اعتباریابی شبکه انجام گرفت. در تفکیک داده

و مناطق جنگلی طبیعی، ارتفاع تاج درختان، تیپ و نوع گونه‌های درختی و همچنین درصد پوشش علفی منطقه پژوهش برای کل منطقه تهیه شد. تصاویر نقشه جرم مخصوص خاک، پوشش علفی، پوشش تاجی و نقشه شیب در شکل ۴ ارائه شده است.

با استفاده از تصاویر ماهواره‌ای، پژوهش‌های پیشین و مطالعات صحرائی نقشه تیپ و درصد پوشش گیاهی منطقه تهیه و در این مرحله نیز با ترکیب این نقشه‌ها در محیط سیستم اطلاعات جغرافیایی محل‌هایی انتخاب و با عملیات صحرائی میزان صحت این نقشه بررسی شد، درصد پوشش تاجی درختان در مناطق بهره‌برداری شده



شکل ۴- الف) نقشه شیب؛ ب) نقشه جرم مخصوص خاک؛ پ) نقشه پوشش تاجی؛ ت) نقشه پوشش علفی
 Figure 4. A: Slope map, B: Soil Bulk density map, C: Canopy cover map and D: Grass cover map

آماري ضريب تبیین (Rsqr)، جذر میانگین مربعات خطا (RMSE^۱) و میانگین خطای مطلق (MAE^۲) استفاده شد.

نتایج

نتایج مدل‌سازی، ساختار شبکه برای رواناب برحسب لیتر در متر مربع با تابع انتقال تانژانت هیپربولیک، روش یادگیری ممنوم و تعداد نورون ۱ به‌دست آمد. ساختار شبکه برای رسوب برحسب گرم در متر مربع با تابع انتقال تانژانت هیپربولیک، روش یادگیری ممنوم و تعداد نورون ۱ به‌دست آمد. در مرحله آموزش تغییر الگوهای داده‌های ورودی و آنالیز حساسیت شبکه به داده‌های ورودی نشان داد که عوامل درصد پوشش تاجی، درصد پوشش علفی، جرم مخصوص خاک و درصد شیب منطقه، مقدار و شدت بارش، بهترین ورودی‌ها برای شبیه‌سازی رواناب و عوامل، درصد پوشش علفی، جرم مخصوص خاک، درصد شیب و شدت بارش، بهترین ورودی‌ها برای شبیه‌سازی رسوب در منطقه پژوهش‌اند (شکل ۵).

آموزش شبکه به‌منظور دستیابی به ساختار بهینه شبکه برای حجم رواناب و رسوب با روش آزمون و خطا انجام پذیرفت و نتایج آن نشان داد که مقدار خطا (MSE) برای رواناب و رسوب کمتر از ۰/۰۰۴ است (جدول ۲). مقدار خطا و Rsqr در مرحله آموزش به‌ترتیب کوچک‌تر از ۰/۰۰۴ (MSE < ۰/۰۰۴) و ۰/۹ و کمترین خطا و ضریب تبیین در مرحله آموزش برای رسوب برحسب گرم در متر مربع به‌ترتیب MSE=۰/۰۱۳ و Rsqr=۰/۸۶ به‌دست آمد (جدول ۳).


در مرحله بعد با استفاده از قابلیت‌های سیستم اطلاعات جغرافیایی (GIS)، لایه‌های رقومی زمین مرجع عوامل ورودی شبکه (عوامل اصلی یا مؤثر) در محیط GIS با (اندازه سلولی ۱۰ در ۱۰ متر) فرمت رستری با یکدیگر تلفیق شد. برای هر سلول یا پیکسل مختصات به‌طور خودکار با استفاده از قابلیت‌های سیستم اطلاعات جغرافیایی درج شد. در نهایت برای هر سلول مختصات و مقادیر کمی عوامل مؤثر در مقدار رواناب و رسوب به‌دست آمد. داده‌های خروجی مرحله بالا، به محیط شبکه اعتباریابی شده وارد شد. از شبکه مذکور برای برآورد مقادیر رواناب و رسوب هر سلول استفاده و نتایج با فرمت اکسل خروجی گرفته شد. در این بخش از پژوهش، نتایج شبیه‌سازی شده برای ده‌ها هزار سلول به همراه مختصات هر سلول وارد محیط سیستم اطلاعات جغرافیایی شده و با استفاده از قابلیت‌های سیستم اطلاعات جغرافیایی به‌صورت نقشه به فرمت رستری ارائه شد. سپس طبقه‌بندی طبقات مقادیر رواناب و رسوب (نقشه‌ها) انجام گرفت. در محیط سیستم اطلاعات جغرافیایی از طریق همپوشانی مقادیر کمی برآوردی نمونه‌ها (نتایج مطالعات صحرایی) روی نقشه مقادیر رواناب و رسوب حاصل از تلفیق قابلیت‌های شبکه عصبی و سیستم اطلاعات جغرافیایی، صحت نتایج ارزیابی شد (Gholami et al., 2019).

روش تحلیل

برای حفظ، ذخیره‌سازی و اجرای برخی از تجزیه و تحلیل‌ها از نرم‌افزار اکسل استفاده شد. در مرحله مدل‌سازی و بهینه‌سازی شبکه، از روش آزمون و خطا استفاده شد. مدل‌سازی با استفاده از شبکه عصبی مصنوعی (ANN) و تهیه و استخراج اطلاعات نقشه‌ها و همچنین پیاده‌سازی نقشه‌ها با نرم‌افزار سامانه اطلاعات جغرافیایی (GIS) صورت گرفت.

برای ارزیابی صحت مدل‌های تدوین شده با شبکه عصبی و همچنین مقایسه آنها با مدل‌های بهینه‌سازی شده با روش آزمون و خطا، از معیارهای

1. Root Mean Square Error
2. Mean Absolute Error



شکل ۵- آنالیز حساسیت داده‌های ورودی شبکه بهینه برای شبیه‌سازی مقدار رواناب و رسوب در منطقه پژوهش
 Figure 5. Inputs data sensitivity analysis for runoff and sediment simulation in study area

جدول ۲- نتایج آموزش شبکه عصبی برای شبیه‌سازی مقدار رواناب و رسوب در منطقه پژوهش

Table 2. Performance evaluation of network training to predicting runoff and sediment in the study area

		انحراف معیار مرحله صحت‌سنجی Standard deviation training stage	کمترین مقدار صحت‌سنجی Minimum Validation	انحراف معیار مرحله آموزش Standard deviation training stage	کمترین مقدار آموزش Minimum training
رواناب Runoff	میانگین کمترین مقدار Mean Minimum MSE	0.009	0.008	0.004	0.003
	میانگین نهایی Mean Final MSE	0.009	0.008	0.004	0.003
رسوب Sediment	میانگین کمترین مقدار Mean Minimum MSE	0.013	0.000	0.005	0.007
	میانگین نهایی Mean Final MSE	0.014	0.001	0.012	0.020

جدول ۳- نتایج مقدار خطا در مرحله آموزش برای شبیه‌سازی مقدار رواناب و رسوب در منطقه پژوهش

Table 3. Performance evaluation of the network test to predicting runoff and sediment in the study area

شبکه بهینه Optimum network	رواناب (L/m ²) Runoff		رسوب (gr/m ²) Sediment	
	آموزش training	صحت‌سنجی validation	آموزش training	صحت‌سنجی validation
Run #	1	2	1	2
Epoch #	20	18	924	14
Minimum MSE	0.009	0.002	0.013	0.004
Final MSE	0.009	0.002	0.013	0.004
Rsqr	0.9	0.9	0.86	0.9


مقدار ضریب تبیین رسوب $R_{sqr} = 0.8$ شد. مقادیر خطاها در مرحله آموزش مقادیر مشاهداتی و مقدار شبیه‌سازی شده در جدول ۴ نشان داده شده است. نمودار مقادیر رواناب و رسوب شبیه‌سازی شده و رواناب و رسوب مشاهداتی و مقادیر ضریب تبیین آن در شکل ۶ ارائه شده است.

در مرحله بعد، آزمون یا ارزیابی کارایی شبکه بهینه انجام گرفت. نتایج مرحله آزمون از طریق مقایسه مقادیر شبیه‌سازی شده و مقادیر واقعی رواناب و رسوب نشان داد که مقدار R_{sqr} در مرحله آزمون برای مقادیر رواناب شبیه‌سازی شده و مقدار رواناب مشاهداتی 0.8 و همچنین مقدار خطا بین رسوب شبیه‌سازی شده و رسوب مشاهداتی $MSE = 4/3$ و

جدول ۴- نتایج آزمون شبکه عصبی در برآورد مقدار رواناب و رسوب

Table 4. Performance evaluation of network at the test stage for predicting the runoff and sediment values

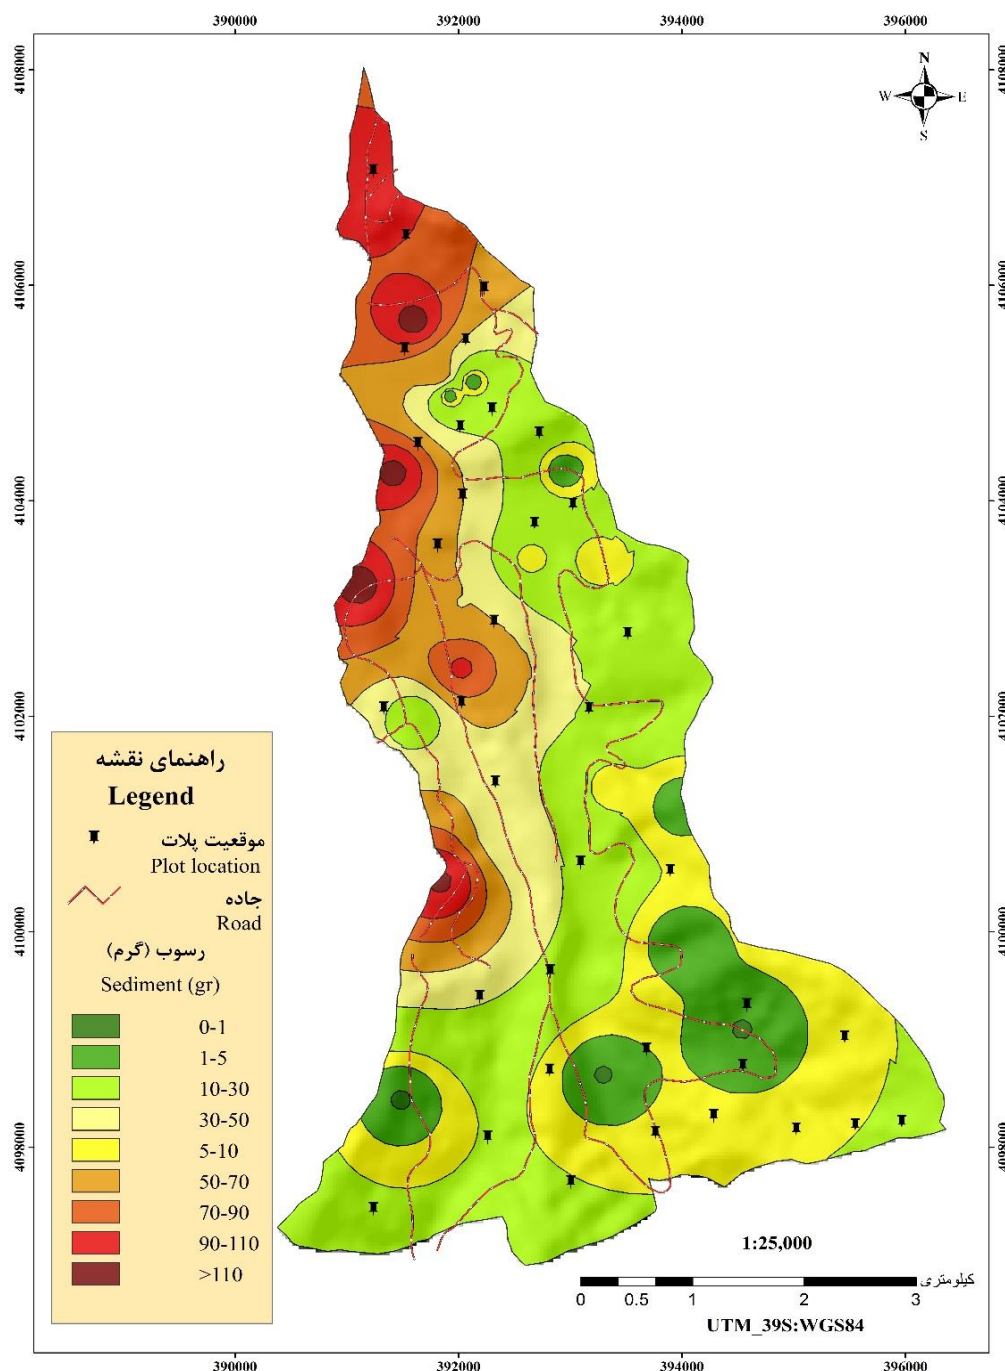
متغیر Variable	MSE	NMSE	MAE	Min Abs Error	Max Abs Error	R_{sqr}
رواناب Runoff	0.13	0.06	0.19	0.001	2.4	0.8
رسوب Sediment	4.3	0.20	1.96	0.001	5.6	0.8



شکل ۶- ارزیابی کارایی شبکه عصبی در شبیه‌سازی مقدار رواناب (بالا) و رسوب (پایین) در مرحله آزمون
Figure 6. Comparison between the simulated and observed runoff (up) and sediment (down) values in the test stage

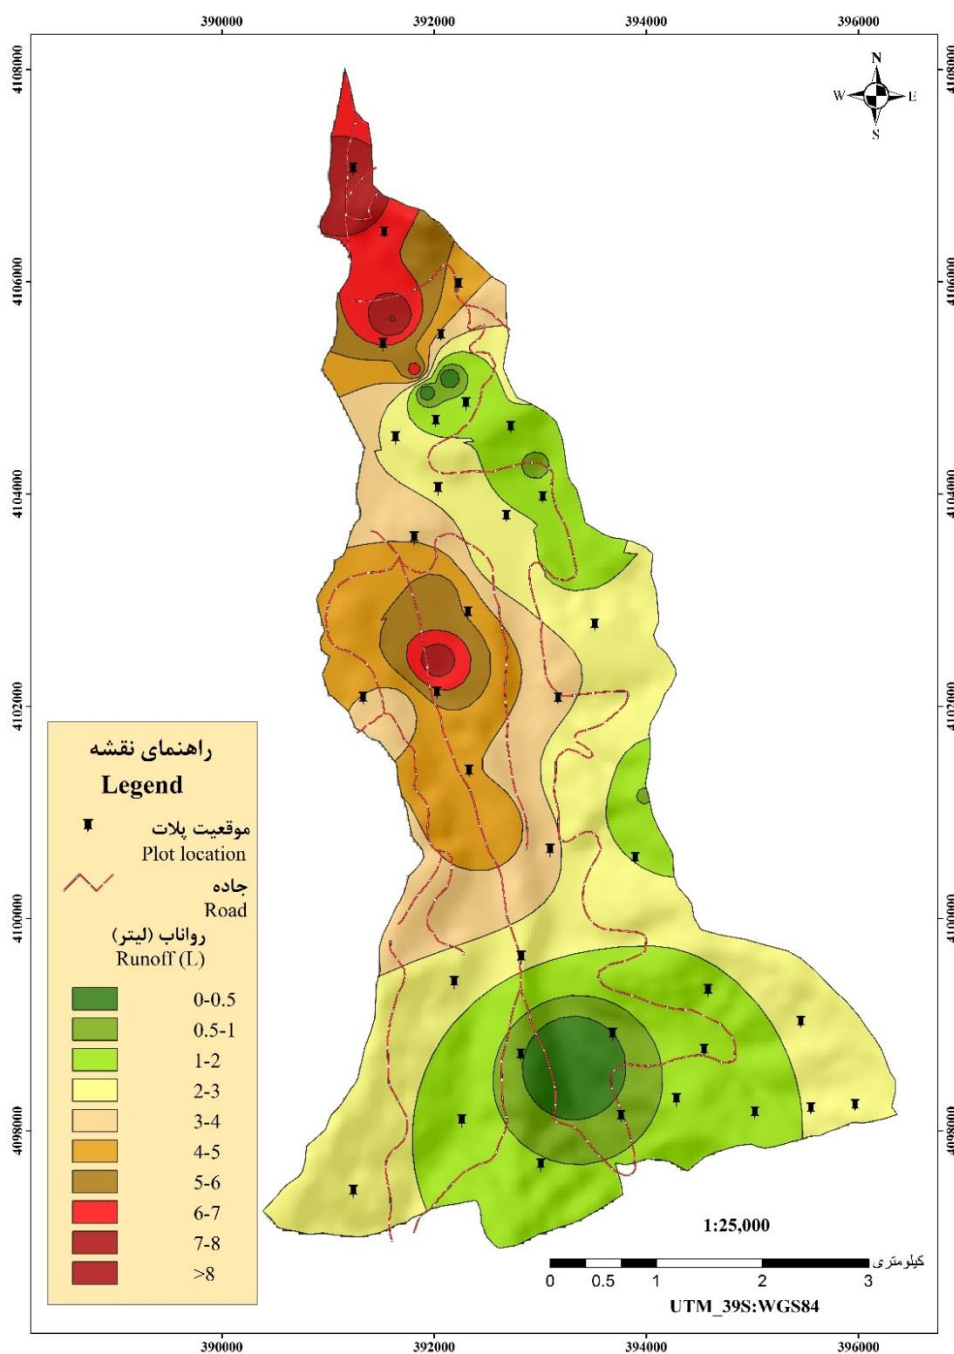
شبهه‌سازی شده برای کل منطقه سیاهکل دارای اطلاعات رقومی است و این نقشه از تلفیق شبهه‌سازی مقادیر حجم رواناب و رسوب توسط شبکه عصبی آزمون شده با قابلیت‌های سیستم اطلاعات جغرافیایی تولید شده است (شکل‌های ۷ و ۸).

با اجرا کردن مدل در نهایت نقشه حجم رواناب و رسوب در سری چهار سیاهکل در یک واقعه رگبار ۳۷ میلی‌متری با شدت بارش ۱۰ میلی‌متر در ساعت تولید شد، با توجه به این موضوع که داده‌های ورودی برای هر پیکسل ۱۰ در ۱۰ متری دارای طول و عرض جغرافیایی بودند، مقادیر رواناب و رسوب



شکل ۷- نقشه مقادیر رسوب شبهه‌سازی شده به وسیله GIS و ANN در منطقه پژوهش

Figuer 7. Sediment simulated map by GIS and ANN in study area



شکل ۸- نقشه مقادیر رواناب شبیه‌سازی شده به وسیله GIS و ANN در منطقه پژوهش
Figuer 8. Runoff simulated map by GIS and ANN in study area

دسترسی به منطقه پژوهش در زمان وقوع بارش‌ها و تردید در صحت داده‌های بارش حاصل از ایستگاه‌های باران‌سنجی، تنوع داده‌های بارش محدود به سه رگبار بود. از سوی دیگر هدف نویسندگان معرفی روشی برای شبیه‌سازی رواناب و رسوب در مناطق بهره‌برداری شده جنگلی بود؛ بنابراین با ثابت قرار دادن

بحث

براساس نتایج تحقیق، مهم‌ترین عوامل در مقدار رواناب تولیدشده و مقدار رسوب در کل منطقه پژوهش، شدت و مقدار بارش‌هاست. در آنالیز حساسیت مدل نیز این دو، عوامل مهم در مدل‌سازی شناسایی شدند، اما در این پژوهش به دلیل مشکل

خود به کاهش نفوذپذیری می‌انجامد. افزایش سرعت قطره‌های آب روی زمین نیز سبب می‌شود که قدرت فرساینده‌گی آن افزایش یابد؛ بنابراین فرسایش خاک نیز در اثر افزایش شیب افزایش می‌یابد (Ezzati et al., 2012; Zenner et al., 2007; Pereira et al., 2015). در پژوهش Etehad et al. (2018)، مانند پژوهش حاضر تأثیر بهره‌برداری بر رواناب و رسوب به‌خوبی شناسایی شد. یافته‌های آنها بیانگر تأثیر افزایش جرم مخصوص ظاهری، کاهش پوشش تاجی و پوشش علفی در افزایش مقدار رواناب و رسوب در مناطق بهره‌برداری شده بود. با مقایسه مقادیر برآورده شده توسط مدل یا همان خروجی‌های مدل با مقادیر واقعی و مشاهداتی برای تعدادی از نمونه‌ها که در مدل‌سازی استفاده نشده بودند، مشخص شد که این مدل که با استفاده از توانایی‌های شبکه عصبی مصنوعی برای شبیه‌سازی مقادیر رواناب و رسوب در این پژوهش استفاده شد، با توجه به شکل ۶ توانایی زیادی ($R^2=0/8$) برای شبیه‌سازی رواناب و رسوب دارد. براساس تحقیقات مختلف در خصوص کارایی شبکه‌های عصبی مصنوعی در مدل‌سازی پارامترهای محیطی، واضح است که توانایی‌های این روش با توجه به ساختارهای مختلف آن و نیز طبیعت مسئله‌ای که در پی حل آن هستیم، متفاوت است (Dalir et al., 2022; Zama et al., 2020; Gholami et al., 2015). بنابراین با انتخاب نوع و تعداد مناسب عوامل ورودی و نیز استفاده از نوع مناسب و سازگار شبکه عصبی مصنوعی و نیز کالیبره کردن آن می‌توان گفت که این روش، ابزاری بسیار کارا و مناسب برای برآورد مقادیر رواناب و رسوب خواهد بود (Zema et al., 2020; Gholami et al., 2020). نتایج تحقیق حاضر بر توانایی قابل قبول شبکه عصبی در شبیه‌سازی مقادیر رواناب و رسوب در مناطق جنگلی دلالت دارد. تحقیقات گذشته نیز کارایی مناسب‌تر شبکه عصبی را در مقایسه با روش‌های آماری مدل‌سازی مانند رگرسیون چندمتغیره بیان کرده است (Gholami et

مقدار و شدت بارش، پتانسیل تولید رواناب و رسوب در حوضه تحت بررسی با بارشی به مقدار ۵۵ میلی‌متر و شدت ۱۰ میلی‌متر در ساعت بررسی شد. تأثیر دیگر عوامل با ثابت در نظر گرفتن مقدار و شدت بارش مدل‌سازی شد تا کارایی مدل برای تخمین مقادیر رواناب و رسوب ارزیابی شود. با این وصف نتایج نشان‌دهنده این است که با افزایش جرم مخصوص ظاهری خاک در منطقه پژوهش که از مناطق جنگلی بهره‌برداری شده است، مقدار رواناب تولیدشده در سطح افزایش می‌یابد (Krstic et al., 2018). این موضوع هم در تولید رواناب و هم در رسوب از منطقه مشاهده شد. فعالیت‌هایی که به‌طور غیرمستقیم سبب افزایش رواناب و رسوب می‌شوند، بهره‌برداری، استفاده از ماشین‌آلات، فشار ناشی از وزن افراد، تردد بیشتر در اطراف مناطق مسکونی و جاده‌ها و نیز تردد بیشتر در محل دپوی چوب‌آلات هستند که سبب افزایش جرم مخصوص خاک در مناطق جنگلی می‌شود (Borselli et al., 2008; Della Seta et al., 2009; Torri et al., 2013, Dalir et al., 2015a,b). پژوهش‌های پیشین نشان داد که تخریب رویشگاه‌های جنگلی به‌سبب دخالت انسان، تأثیرات منفی بسیاری بر خاک دارد. در این تحقیقات، تأثیر بهره‌برداری بر خاک و فرسایش به‌خوبی بیان شد (Sobh Zahedi., 2020; Azizimehr et al., 2020). از دیگر عوامل، درصد پوشش تاجی در منطقه پژوهش است که در مقدار رواناب تولیدشده اثر مهمی دارد. این عامل نیز مانند عامل قبلی تحت تأثیر عوامل دیگر قرار دارد. چنانکه با افزایش پوشش تاجی، مقدار رواناب تولیدشده کم می‌شود. موضوع تأثیر پوشش تاجی و همچنین پوشش علفی کف جنگل در مقادیر رواناب تولیدشده از سطح در بسیاری از تحقیقات دیگر به اثبات رسیده است (Ding et al., 2022; Bredemeier, 2011; Dalir et al., 2014; Cambi et al., 2015). از عوامل دیگر، افزایش شیب است که سبب افزایش سرعت حرکت رواناب سطحی می‌شود و این افزایش سرعت

است. همچنین در مدل‌سازی رسوب، ضریب تبیین بین مقادیر واقعی و مقادیر شبیه‌سازی شده برابر با ۰/۸۶ و ۰/۸ در مراحل آموزش و آزمون بوده است. از طرفی، ارزیابی شاخص‌های مقادیر خطا (۰/۰۴) $MSE <$ بر کارایی شبکه بهینه اعتباریابی شده در شبیه‌سازی مقادیر تولید رواناب و رسوب دلالت داشته است. در پژوهشی برای مدل‌سازی رواناب در مناطق جنگلی چین با استفاده از شبکه عصبی مصنوعی، کارایی و شبیه‌سازی را با ضریب تبیین ۰/۹ بیان کردند (Lin et al., 2019). بدیهی است ترکیبی که بیشترین ضریب تبیین را دارد و خطای آن حداقل است، به‌عنوان شبکه مطلوب، انتخاب می‌شود. براساس نتایج، شبکه عصبی قابلیت مناسبی در برآورد رواناب و رسوب ارائه داده است.

نتایج تحقیق نشان داد که شبکه عصبی ابزار کارآمد در مدل‌سازی است (Dalir et al., 2022; Zema et al., 2020)، اما نکته حائز اهمیت، به‌کارگیری نتایج آن است. در این پژوهش با وجود همه مشکلات و خطاها نیز شبکه پرسپترون چندلایه برآورد قابل قبولی داشت. هدف تحقیق حاضر برآورد مقدار رواناب و رسوب در مکان‌های فاقد آمار و ارائه نتایج به‌گونه‌ای قابل استفاده برای عموم است.

نتیجه‌گیری

نتایج این پژوهش‌ها نشان داد که شبکه عصبی مصنوعی ابزار کارآمد در مدل‌سازی رواناب و رسوب در مناطق جنگلی بهره‌بردار شده است. مدل‌سازی مقادیر رواناب و رسوب برای سری چهار شیرقلایع نشان‌دهنده کارایی زیاد مدل ساخته‌شده با شبکه عصبی مصنوعی با استفاده از قابلیت‌های سیستم اطلاعات جغرافیایی است. این مدل، شبیه‌سازی رواناب و رسوب را در مناطقی که جمع‌آوری اطلاعات به روش مستقیم بسیار دشوار، هزینه‌بردار و زمان‌بر است مقدور می‌سازد. ارزیابی این پژوهش نشان داد که مدل توانایی خوبی برای شبیه‌سازی رواناب و

Zema et al. (2020) در این زمینه (al., 2019; Jafari et al., 2004) بیان کردند که استفاده از شبکه عصبی مصنوعی به‌دلیل کارایی در شبیه‌سازی رواناب در مناطق جنگلی، ابزاری مفید برای مدیران و برنامه‌ریزان است. سیستم اطلاعات جغرافیایی حجم زیادی از ورودی‌های مدل را در زمانی کوتاه پردازش و ارائه کرد (Hill 2002; Barr, 2002) و شبکه عصبی بهینه اعتباریابی شده نیز با سرعت مشابهی برای مکان‌های فاقد آمار مقدار رواناب و رسوب را برآورد کرد. نسبت یادگیری، یکی از پارامترهایی است که با آزمون و خطا مشخص می‌شود؛ زیرا تحقیقات مختلف با نسبت یادگیری خاصی به بهترین جواب رسیدند. در این تحقیق با روش یادگیری ۰/۲ و روش ممنوم ۰/۹ بهترین جواب به‌دست آمد که با تحقیقات Gomez. (2005) و Yesilnacar & Topal. (2005) و Kavzaghlo & Topal. (2005) مطابقت دارد. تعداد تکرار بهینه برای جلوگیری از آموزش بیش از حد و افزایش خطا در مرحله آموزش پارامتری است که باید با سعی و خطا مشخص شود (Yesilnacara & Topal, 2005; Caniani et al., 2008; Lee et al., 2006; Melchiorre et al., 2008). در این تحقیق بعد از آزمایش‌ها مشخص شد که ۱۰۰۰ تکرار یا دور برآورد رواناب گزینه مناسبی است و بیشتر از آن، تأثیر مثبتی در فرایند مدل‌سازی نخواهد داشت. برای تعیین ساختار بهینه شبکه عصبی مصنوعی تعداد نورون در لایه پنهان باید با روش سعی و خطا تعیین شود، زیرا با تغییر نورون در لایه پنهان نتایج خروجی تغییر خواهد کرد (Lee et al., 2006; Caniani et al., 2008). در تحقیق حاضر برای رواناب و رسوب تعداد نورون در لایه پنهان ۱ حاصل آمد که این مقادیر در طی فرایند آموزش و بهینه‌سازی از طریق روش آزمون و خطا برای ارزیابی کارایی شبکه تعیین شد. شبکه عصبی پیشنهادی برای برآورد رواناب ضرایب تبیین بین مقادیر واقعی و مقادیر شبیه‌سازی شده برابر با ۰/۸۶ و ۰/۸۲ در مراحل آموزش و آزمون ارائه کرده

سپاسگزاری

نویسندگان بر خود لازم می‌دانند از زحمات مسئولان آزمایشگاه دانشکده منابع طبیعی دانشگاه گیلان و مسئولان اداره کل منابع طبیعی و آبخیزداری استان گیلان در فراهم آوردن ابزار، وسایل و همکاری‌های لازم در اجرای این تحقیق تشکر و قدردانی کنند.

رسوب دارد و تغییرات در عوامل ورودی مدل به خوبی در نتایج شبیه‌سازی منظور شده است. بنابراین در مواردی که به اطلاعات سریع با صرف هزینه و زمان کم برای مناطق با دسترسی دشوار نیاز باشد این مدل می‌تواند راهگشای خوبی برای مدیران، برنامه‌ریزان و دیگر کارشناسان عرصه منابع طبیعی و آبخیزداری باشد.

References

- AziziMehr, M., Kooch, Y., & Hosseini, S. (2020). The effect of forest degradation intensity on the dynamics of soil microbial activities and biochemical in the plain region of Noshahr. *Iranian Journal of Forest*, 12(2), 175-188.
- Barr, A., & Barbe, M. (2002). Pathophysiological tissue changes associated with repetitive movement: a review of the evidence. *Physical therapy*, 82(2), 173-187. [https://doi: 10.1093/ptj/82.2.173](https://doi.org/10.1093/ptj/82.2.173)
- Bredemeier, M. (2011). Forest, climate and water issues in Europe. *Ecohydrology*, 4(2), 159-167. <https://doi.org/10.1002/eco.203>
- Borselli, L., Cassi, P., & Torri, D. (2008). Prolegomena to sediment and flow connectivity in the landscape: a GIS and field numerical assessment. *Catena*, 75(3), 268-277. <https://doi.org/10.1016/j.catena.2008.07.006>
- Caniani, D., Pascale, S., Sdao, F., & Sole, A. (2008). Neural networks and landslide susceptibility: a case study of the urban area of Potenza. *Natural Hazards*, 45(3), 55-72. <https://doi.org/10.1007/s11069-007-9169-3>
- Cambi, M., Hoshika, Y., Mariotti, B., Paoletti, E., Picchio, R., Venanzi, R., & Marchi, E. (2017). Compaction by a forest machine affects soil quality and *Quercus robur* L. *Forest Ecology and Management*, 384, 406-414. <https://doi.org/10.1016/j.foreco.2016.10.045>
- Dalir, P., Naghdi, R., Gholami, V., Tavankar, F., Latterini, F., Venanzi, R., & Picchio, R. (2022). Risk assessment of runoff generation using an artificial neural network and field plots in road and forest land areas. *Nat Hazards*, 113(3), 1451-1469. <https://doi.org/10.1007/s11069-022-05352-5>
- Dalir, P., Naghdi, R., & Gholami, V. (2021). Assessing the rice straw effects on the soil erosion rate in forest road cut slope embankments. *Caspian Journal of Environmental Sciences*, 19(2), 325-339.
- Dalir, P., Naghdi, R., & Mosavimirkala, M. (2015). Assessing the effects of native plants to slope stabilization in road embankments: a case study in Siyahkal forest, northern Iran. *HortFlora Research Spectrum*, 4(2), 93-96.
- Dalir, P., Naghdi, R., & Gholami, V. (2014). Modelling of forest road sediment in the northern forest of Iran (Lomir Watershed). *Journal of Forest Science*, 60(3), 109-114. [https://doi: 10.17221/91/2013-JFS](https://doi.org/10.17221/91/2013-JFS)
- Dalir, P., Naghdi, R., & Gholami, V. (2015). More important sediment factors in forest roads in the northern Iran forests. *Environmental Erosion Research*, 4(4), 27-36.
- Della, M., Del Monte, M., Fredi, P., & Palmieri, E. (2009). Space-time variability of denudation rates at the catchment and hillslope scales on the Tyrrhenian side of Central Italy. *Geomorphology*, 107(3-4), 161-177. <https://doi.org/10.1016/j.geomorph.2008.12.004>
- Ding, B., Zhang, Y., Yu, X., Jia, G., Wang, Y., Wang, Y., Zheng, P., & Li, Z. (2022). Effects of forest cover type and ratio changes on runoff and its components. *International Soil and Water Conservation Research*. 10(3), 445-456. <https://doi.org/10.1016/j.iswcr.2022.01.006>

- Ebrahimi, A. (2017). The effect of statistical groups and vegetative forms on estimating the relationship between production and vegetation. *Rangeland and watershed management*, 70(1), 19-30.
- Etehad, A.M., Majnonyan, B., Malakyan, A., & Juorgholami, M. (2018). Runoff and sediment changes following changes in some soil properties in forest exploitation operations (Study: Khairud Forest). *Iranian journal of Forest*, 10(3), 267-78. <https://doi.org/10.22034/IJF.2022.266051.1757>
- Ezzati, S., Najafi, A., Rab, M., & Zenner, E. (2012). Recovery of soil bulk density, porosity and rutting from ground skidding over a 20-year period after timber harvesting in Iran. *Silva Fennica*, 46(4), 521-538. <https://doi.org/10.14214/sf.908>
- Fathi, K., Jourgholami, M., Hosseini, S., & Khalighi Sigaroodi, S. (2021). 'Optimal distance among water diversion structures for mitigating runoff on the skid trails (case study: Kheyroud forest). *Iranian Journal of Forest*, 13(3), 237-250. <https://doi.org/10.22034/ijf.2021.205706.1656>.
- Foltz, B., & Wagenbrenner, N., (2010). An evaluation of three wood shred blends for post-fire erosion control using indoor simulated rain events on small plots. *Catena*, 80(2), 86-94. <https://doi.org/10.1016/j.catena.2009.09.003>
- Gee, G.W., & Bauder, J.W. (1986). Particle-size Analysis. In: Klute, A. (Ed.), Methods of Soil Analysis Part 1, Physical and Mineral Methods, Second edition American Society of Agronomy. *Soil Science Society of America, Madison*, 5, 255-293. <https://doi.org/10.1002/gea.3340050110>
- Grace, J. (2002). Control of sediment export from the forest road prism. *ASAE Annu Meeting*, 45, 1-6. <https://doi.org/10.13031/2013.9913>
- Gholami, V., Sahour, H., & Amri, M.A.H. (2021). Soil erosion modeling using erosion pins and artificial neural networks. *Catena*, 196(2), 90-104.
- Gholami, V., Torkaman, J., & Dalir, P. (2019). Simulation of precipitation time series using tree-rings, earlywood vessel features, and artificial neural network. *Theoretical and Applied Climatology*, 137(3), 1939-1948. <https://doi.org/10.1007/s00704-018-2702-3>
- Gomez, T., & Kavzoglu, H. (2005). artificial using susceptibility landslide shallow of, Venezuela, Basin River Jabonosa in networks lneural. *Geology Eng*, 78(3), 11-27. <https://doi.org/10.1016/j.enggeo.2004.10.004>
- Grismer, M., & Hogan, M.P. (2005). Simulated rainfall evaluation of revegetation/mulch erosion control in the Lake Tahoe basin, Soil treatment effects. *Land degradation & development*, 16(5), 489-501. <https://doi.org/10.1002/ldr.679>
- Hill, N. (2002). Parenting and academic socialization as they relate to school readiness: The roles of ethnicity and family income. *Journal of Educational psychology*, 93(4), 686. <https://doi.org/10.1037/0022-0663.93.4.686>
- Jafari, M., Chahouki, M., Tavili, A., Azarnivand, H., & Amiri, G. (2004). Effective environmental factors in the distribution of vegetation types in Poshtkouh rangelands of Yazd Province (Iran). *Journal of Arid Environments*, 56(4), 627-641. [https://doi.org/10.1016/S0140-1963\(03\)00077-6](https://doi.org/10.1016/S0140-1963(03)00077-6)
- Jokar, A., Gholami, V., & Golijirande, A. (2013). Principles and Concepts of Geographic Information System, *Mazandaran University Press*, 200p
- Jourgholami, M., Nasirian, A. and Labelle, E.R.. (2018). Ecological restoration of compacted soil following the application of different leaf litter mulches on the skid trail over a five-year period. *Sustainability*, 10(7), 2148. <https://doi.org/10.3390/su10072148>
- Jourgholami, M., & Etehad, M. (2017). Effectiveness of sawdust and straw mulching on postharvest runoff and soil erosion of a skid trail in a mixed forest. *Ecological Engineering* 109, 15-24. <https://doi.org/10.1016/j.ecoleng.2017.09.009>

- Kazemi Talkouyee, A., Jourgholami, M., Abbaspour, K., & Fegghi, J. (2019). 'Simulation runoff and sediment yield in a harvested forest (Case study: Zailakirood Basin, northern Iran). *Iranian Journal of Forest, 11(1)*, 29-41.
- Krstic, D., Vujic, S., Jacimovic, G., D'Ottavio, P., Radanovic, Z., Erić, P., & Cupina, B. (2018). The effect of cover crops on soil water balance in rain-fed conditions. *Atmosphere, 9(12)*, 492. <https://doi.org/10.3390/atmos9120492>
- Khazayi, M., Sadeghi, S., & Mirnya, S.K. (2013). Application of artificial neural network and correlation models in extracting soil losses in plants located in degraded areas in the forest watershed of Tarbiat Modares University. *Iranian Journal of Watershed Management Science and Engineering, 21(7)*, 13-20.
- Krishna, B., Satyaji Rao, Y., & Vijaya, T. (2008). Modelling groundwater levels in an urban coastal aquifer using artificial neural networks. *Hydrological Processes, 22(8)*, 1180-1188. <https://doi.org/10.1002/hyp.6686>
- Lee, S., Ryu, J., Lee, M., & Won, J. (2006). The application of artificial neural network to landslide susceptibility mapping at janghung, korea. *mathematical geology, 38(2)*, 199-220. <https://doi.org/10.1007/s11004-005-9012-x>
- Li, X., Niu, J., & Xie, B. (2014). The effect of leaf litter cover on surface runoff and soil erosion in Northern China. *PloS one, 9(9)*, e107789. <https://doi.org/10.1371/>
- Lin, Y., Wen, H., & Liu, S. (2019). Surface runoff response to climate change based on artificial neural network (ANN) models: a case study with Zagunao catchment in Upper Minjiang River, Southwest China. *Journal of Water and Climate Change, 10(1)*, 158-166. <https://doi.org/10.2166/wcc.2018.130>
- McEachran, Z.P., Slesak, R.A., & Karwan, D. (2018). From skid trails to landscapes: vegetation is the dominant factor influencing erosion after forest harvest in a low relief glaciated landscape. *Forest Ecology and Management, 430*, 299-311. <https://doi.org/10.1016/j.foreco.2018.08.021>
- Megahan, W., & Kidd, W. (1972). Effects of logging and logging roads on erosion and sediment deposition from steep terrain. *Journal of Forestry, 70(3)*, 136-141.
- Maire, F., Micard, S., Hammel, P., Voitot, H., Lévy, P., Cugnenc, P.H., & Puig, P.L. (2000). Differential diagnosis between chronic pancreatitis and pancreatic cancer: value of the detection of KRAS2 mutations in circulating DNA. *British journal of cancer, 87(5)*, 551-554. <https://doi.org/10.1038/sj.bjc.6600475>
- Melchiorre, P., Marigo, M., Carlone, A., & Bartoli, G. (2008). Asymmetric aminocatalysis—gold rush in organic chemistry. *Angewandte Chemie International Edition, 47(3)*, 6138-6171. <https://doi.org/10.1002/anie.200705523>
- Pereira, P., Giménez, A., Novara, A., Keesstra, S., Jordán, A., Mastro, R., Brevik, E., Azorin, C., & Cerdà, A. (2015). The impact of road and railway embankments on runoff and soil erosion in eastern Spain. *Hydrology and Earth System Sciences Discussions, 12(12)*, 12947-12985. <https://doi.org/10.5194/hessd-12-12947-2015>
- Riad, S., Mania, J., Bouchaou, L., & Najjar, Y. (2004). Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling, 40(7-8)*, 839-846. <https://doi.org/10.1016/j.mcm.2004.10.012>
- Reichert, J. M., Cechin, N.F., Reinert, D.J., Rodrigues, M.F., & Suzuki, L.E.A.S. (2018). Ground-based harvesting operations of Pinus taeda affects structure and pore functioning of clay and sandy clay soils. *Geoderma, 331*, 38-49. <https://doi.org/10.1016/j.geoderma.2018.06.012>
- Rachels, A., Bladon, K., Bywater, S., & Hatten, J. (2020). Quantifying effects of forest harvesting on sources of suspended sediment to an Oregon Coast Range headwater stream. *Forest Ecology and Management, 466*, 118123. <https://doi.org/10.1016/j.foreco.2020.118123>

- Sobh Zahedi, S., Naghdi, R., Gharibreza, M., Salehi, A., & Zahedi, G. (2020). Assessing the Effects of Strip Cutting methods on Soil Erosion (A Case Study: Chafroud Forest). *Iranian Journal of Forest, 12(1)*, 49-60. <https://www.orcid.org/0000-0002-6671-0369>
- Shinohara, Y., Misumi, Y., Kubota, T., & Nanko, K. (2019). Characteristics of soil erosion in a moso-bamboo forest of western Japan: Comparison with a broadleaved forest and a coniferous forest. *Catena, 172*, 451-460. <https://doi.org/10.1016/j.catena.2018.09.011>
- Talebi, M., Majnounian, B., Makhdoum, M., Abdi, E., & Omid, M. (2022). 'Planning and modifying the forest road networks for tourism and rural development in Arasbaran area. *Iranian Journal of Forest, 13(4)*, 361-377. <https://doi: 10.22034/ijf.2021.141078>
- Torri, D., Santi, E., Marignani, M., Rossi, M., Borselli, L., & Maccherini, S. (2013). The recurring cycles of biancana badlands: erosion, vegetation and human impact. *Catena 106*, 22-30. <https://doi.org/10.1016/j.catena.2012.07.001>
- Yesilnacar, E., & Topal, T., (2005). Landslide susceptibility mapping: logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey). *Engineering Geology, 79(3-4)*, 251-266. <https://doi.org/10.1016>
- Yu, T.N., Bin, Y., Zhang, Y., Shi, Y., & Zhao, Z. (2003). Nitrogen runoff and leaching losses during rice-wheat rotations in Taihu Lake region, China. *Pedosphere, 17(4)*, 445-456.
- Zema, D.A., Lucas-Borja, M.E., Fotia, L., Rosaci, D., Sarnè, G.M., & Zimbone, S.M. (2020). Predicting the hydrological response of a forest after wildfire and soil treatments using an Artificial Neural Network. *Computers and Electronics in Agriculture, 170*, 105280. <https://doi.org/10.1016>
- Zhao, M., Yang, J., Zhao, N., Liu, Y., Wang, Y., Wilson, J.P., & Yue, T. (2019). Estimation of China's forest stand biomass carbon sequestration based on the continuous biomass expansion factor model and seven forest inventories from 1977 to 2013. *Forest Ecology and Management, 448*, 528-534. <https://doi: 10.1016/j.foreco.2019.06.036>
- Zenner, E., Fauskee, J., Berger, A., & Puettmann, K. (2007). Impacts of skidding traffic intensity on soil disturbance, soil recovery, and aspen regeneration in north central Minnesota. *Northern Journal of Applied Forestry, 24(4)* 177-183. <https://doi.org/10.1093/njaf/24.3.177>



Research Article

Identification and modeling of effective factors on runoff and sediment production from operated forest stands

P. Dalir^{1*}, R. Naghdi², V. Gholami³, S. jafarihaftkhani⁴

¹ Ph.D. Student, Dept. of Forestry, Faculty of Natural Resources, University of Guilan, Sowmeh Sara, Iran

² Prof., Dept. of Forestry, Faculty of Natural Resources, University of Guilan, Sowmeh Sara, Iran

³ Associate Prof., Dept. of Range and Watershed Management, Faculty of Natural Resources, University of Guilan, Sowmeh Sara, Iran

⁴ M.Sc. graduated, Dept. of Reclamation of Arid and Mountainous Regions, Faculty of Natural Resources, University of Tehran, Iran

(Received: 4 January 2022; Accepted: 9 May 2022)

Abstract

In this study, we investigated the effects of forest operation on runoff and sediment using small-scale plots. The runoff and sediment samples were collected from 36 sample plots with dimensions of one by two meters in different areas of the operation. We used the Multi-Layer Perceptron (MLP) for modeling, with 65% of the data for training, 10% for validation, and 25% for testing. We evaluated the accuracy of the model using the coefficient of determination (R^2), root mean square error (RMSE), and mean absolute error (MAE), and compared our results with optimized models obtained through trial and error. We collected information and produced runoff and sediment maps using GIS. Our results showed that the most important factors affecting runoff production were soil bulk density, rainfall intensity, slope, rainfall values, percentage of grass cover, and canopy cover percentage. For sediment, the most important factors were rainfall intensity, soil bulk density, slope percentage, and surface cover percentage. The MSE and R values for runoff modeling were 0.009 and 0.9 in the training stage and 0.01 and 0.82 in the test stage, respectively. For sediment modeling, the MSE and R values were 0.01 and 0.86 in the training stage and 4.3 and 0.8 in the test stage, respectively. Our results showed that neural networks have high capability in modeling runoff and sediment in forest lands. We also conducted an overlap analysis to measure the accuracy, precision, and efficiency of the results and methods presented in our study. Therefore, the proposed model can be used to combine ANN and GIS in the simulation and modeling of runoff and sediment in forest areas."

Keywords: forest, neural network, MLP, GIS, soil erosion.