

مدیریت کودپاشی مراتع با استفاده از مدل‌های شبکه عصبی مصنوعی (استان آذربایجان غربی)

مهشید سوری^{۱*}، میرفرهاد بلورفروش^۲، هیراد عبقری^۳، جواد معتمدی^۴ و بهناز عطائیان^۵

۱- نویسنده مسئول، استادیار پژوهشی، بخش تحقیقات مرتع، مؤسسه تحقیقات جنگلها و مراتع کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

پست الکترونیک: souri@rifr-ac.ir

۲- دانش‌آموخته کارشناسی ارشد مرتع‌داری، دانشکده منابع طبیعی، دانشگاه ارومیه، ایران

۳- دانشیار، گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه ارومیه، ایران

۴- دانشیار پژوهشی، بخش تحقیقات مرتع، مؤسسه تحقیقات جنگلها و مراتع کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

۵- استادیار، دانشکده منابع طبیعی و محیط‌زیست، دانشگاه ملایر، ملایر، همدان، ایران

تاریخ پذیرش: ۹۷/۰۸/۲۱

تاریخ دریافت: ۹۷/۰۲/۰۸

چکیده

در صورت بهره‌برداری مداوم از علوفه مرتع در صورتی که عناصر مهمی همانند NPC به خاک برنگردد، موجب می‌شود اراضی مرتعی حاصلخیزی خود را از دست بدهند. بنابراین، امروزه در حوزه مدیریت مراتع، اصلاح و احیاء مراتع بالایی پیدا کرده است. یکی از روشهای اصلاح مراتع، کودپاشی می‌باشد. اگر عملیات کودپاشی متناسب با شرایط اقلیمی، وضعیت پوشش و خصوصیات خاک انجام شود، باعث بهبود مرتع می‌گردد. در غیر این صورت سبب افزایش غلظت املاح و سمی شدن خاک، آلودگی آب‌ها و خشک شدن گیاهان می‌شود. هدف از این پژوهش ارائه مدلی مبتنی بر استفاده از شبکه عصبی مصنوعی است که روابط بین کربن آلی، نیتروژن و فسفر خاک مرتع و عوامل گیاهی و ادافیکی مؤثر بر آن را بیان کند که بر مبنای نتایج آن، بتوان در زیست‌بوم‌های مرتعی فاقد آمار، عناصر مذکور را به‌منظور مدیریت کودپاشی برآورد نمود. در این پژوهش متغیرهای وابسته شامل کربن آلی، نیتروژن و فسفر خاک مراتع نازلوجای ارومیه بودند. هشت عامل هدایت الکتریکی، اسیدیته، درصد رس، درصد سیلت، درصد شن، میزان آهک، تولید و درصد تاج پوشش گیاهان مرتعی نیز به‌منظور انجام تحلیل عاملی انتخاب گردیدند. سپس با استفاده از شبکه عصبی پرسپترون چند لایه با توابع انتقالی سیگموئید و تانژانت هیپربولیک و آکسون خطی در لایه پنهان و تابع انتقال خطی در لایه خروجی، میزان کربن آلی، نیتروژن و فسفر خاک مراتع تخمین زده شد. نتایج نشان داد که تابع انتقال سیگموئید برای نیتروژن، فسفر و کربن آلی خاک مرتع با ضریب تبیین به ترتیب ۰/۷۰، ۰/۶۶ و ۰/۷۹ و میانگین مربعات خطای به ترتیب ۰/۰۰۸، ۰/۰۲۱ و ۰/۰۰۸ نسبت به تابع انتقال تانژانت هیپربولیک و آکسون توانسته است بخوبی کربن آلی، نیتروژن و فسفر خاک مرتع را مدل‌سازی کند. بنابراین با توجه به نتایج مذکور، شبکه عصبی توانست با دقت بالایی میزان کربن آلی، نیتروژن و فسفر خاک مرتع را در تیپ‌های مرتعی که فاقد نمونه‌برداری مقادیر NPC بودند، پیش‌بینی کند. در مورد کودپاشی در تیپ‌های مرتعی فاقد آمار، بر اساس میزان نیتروژن، فسفر و کربن آلی تخمین زده شده خاک تصمیم‌گیری شد. بدین صورت که بر اساس نتایج، تیپ گیاهی *Astragalus gummifera*- *Onobrychis cornuta*- *Festuca ovina*-*Thymus prangos uloptera*-*Bromus tomentellus* نیاز به کود فسفره و نیتروژنه دارد. تیپ گیاهی *kotschyanus* نیازمند کود فسفره و تیپ گیاهی *Astragalus macrostachys*- *Noeae mucronata*-*Stipa barbata* به مواد آلی و کود نیتروژنه و فسفره نیاز دارد.

واژه‌های کلیدی: اصلاح مراتع، کودپاشی، شبکه عصبی مصنوعی، NPC خاک، مراتع نازلوجای.

مقدمه

در حال حاضر افزایش جمعیت و نیاز روزافزون به محصولات و فراورده‌های پروتئینی از یکسو و وضعیت تخریب مراتع که قسمت اعظم علوفه این تعداد دام را تأمین می‌نماید از سوی دیگر، موجب شده که مسائل اصلاح و احیاء و افزایش ظرفیت مراتع روز به روز اهمیت بیشتری پیدا کند (Ghaderi, 2008). به‌منظور مدیریت صحیح اکوسیستم‌های مرتعی، باید ارتباط بین عوامل بوم‌شناختی موجود را در طبیعت که شامل پارامترهای پستی و بلندی، اقلیم، خاک، پوشش گیاهی و موجودات زنده است شناخت، زیرا مدیریت صحیح یک مرتع بر مبنای اصول اکولوژیک است و درک فرایندهای اکولوژیک پیش‌شرط اصلی مدیریت می‌باشد (Mesdaghi, 2002). بهره‌برداری مداوم از علوفه مرتع موجب می‌شود که اراضی مرتعی پس از گذشت چند سال حاصلخیزی خود را از دست بدهند. از این رو یکی از روش‌های مرسوم برای افزایش حاصلخیزی اراضی مرتعی استفاده از کودهای شیمیایی است. به‌طور کلی کودپاشی سلسله عملیاتی است که برای بهبود حاصلخیزی خاک و در نتیجه افزایش تولید علوفه در مراتع بکار برده می‌شود. کودپاشی افزون بر بهبود پوشش گیاهی و افزایش کمیت و کیفیت علوفه تولیدی، برای کمک به استقرار نهال‌ها و بذره‌های کاشته شده در مراتع، پراکنش مناسب دام در مرتع، تولید علوفه و احیای مراتع استفاده می‌شود (Jangju, 2009). دیانتی تیلکی و همکاران (۱۳۸۷) تأثیر کودهای ازته و فسفره بر کیفیت علوفه *Eruca sativa* در مراتع قشلاقی مراوه تپه را طی ۳ سال مورد بررسی قرار دادند. نتایج تحقیقاتشان نشان داد که به‌طور متوسط در طی ۳ سال آزمایش، کود ازته میزان شاخص‌های ازت خام، پروتئین خام و انرژی خام را افزایش داد. کودپاشی از آنجا که موجب اضافه شدن ماده شیمیایی به خاک می‌شود، افزون بر آثار مثبت بر افزایش کمی و کیفی علوفه، در صورت عدم مدیریت صحیح، آثار منفی در خاک و گیاه را به همراه دارد. اگر عملیات کودپاشی بر اساس شرایط آب و هوایی، پوشش گیاهی و خاک انجام شود، باعث افزایش کمی و کیفی

پوشش گیاهی، تولید علوفه، افزایش ارزش غذایی، خوش خوراکی و قابلیت هضم گیاهان، افزایش طول دوره رویش و بهبود ترکیب گیاهی می‌گردد. از فواید دیگر کودپاشی این است که به تجهیزات ویژه‌ای نیاز ندارد و هزینه اجرای آن در مقایسه با سایر عملیات اصلاحی کمتر است. افزون بر این، اراضی کودپاشی شده به قرق یا استراحت‌های طولانی مدت بعد از اجرای عملیات نیازی ندارند. با وجود مزایای ذکرشده کودپاشی در صورت عدم مدیریت دارای معایبی مانند آثار منفی بر محیط و پوشش گیاهی، افزایش غلظت املاح و سمی شدن خاک، آلودگی آب‌های سطحی و زیرزمینی و خشک شدن گیاهان می‌باشد (Ansari, 2009). Frame و همکاران (۱۹۹۲) مؤثرترین و عملی‌ترین روش افزایش کیفیت علوفه در مراتع را کوددهی کافی و مناسب بیان کردند. Elliot و Abbott (۲۰۰۳)، بیان کردند که کوددهی به‌ویژه با کود ازته و فسفره باعث افزایش کیفیت علوفه می‌شود که این عامل وابسته به بارش سالیانه، رطوبت و شرایط محیطی در این نواحی است. Guevara و همکاران (۲۰۰۰)، چنین اظهار کردند که به‌طور کلی در مناطقی که بارش سالیانه کمتر از ۴۰۰-۳۰۰ میلی‌متر است، کوددهی مراتع مناسب نیست. Kalmbacher و Martin (۲۰۰۰) بیان کردند که کوددهی نه تنها باعث افزایش کیفیت علوفه می‌شود بلکه روی تولید و ترکیب گیاهی نیز اثر می‌گذارد. از جمله مهمترین عناصر غذایی موجود در خاک که نقش مهمی در تعیین میزان رشد و عملکرد گیاه و همچنین بهبود کیفیت محصول تولیدی دارد، عنصر نیتروژن است. Griffe و همکاران (۲۰۰۳)، بیان کردند که این عنصر با تأثیری که بر رشد رویشی و زایشی گیاهان دارد، باعث تغییر در عملکرد محصول شده و کمیت و کیفیت تولید را نیز تحت تأثیر قرار می‌دهد. فسفر نیز پس از نیتروژن مهمترین عنصر مورد نیاز برای تولید محصول است (Kumar et al., 2009). بهره‌برداران همواره تلاش می‌کنند تا با رفع کمبود عناصر غذایی خاک و با مدیریت بهینه تولید، عملکرد گیاهان را به حد ظرفیت بالقوه آنها برسانند. به این منظور به کاربرد کودهای شیمیایی روی آورده‌اند، ولی تنگناهای اقتصادی


دو روش شبکه عصبی پرسپترون چند لایه و استنتاج فازی استفاده کرده و نتیجه گرفتند که شبکه عصبی پرسپترون چند لایه جواب بهتری نسبت به روش فازی-عصبی دارد. Mohanti و همکاران (۲۰۱۳)، با بررسی مدل‌های عددی و شبکه عصبی مصنوعی برای شبیه‌سازی آب‌های زیرزمینی در کاتاجوری هند نتیجه گرفتند که شبکه عصبی مصنوعی پیش‌بینی بهتری را از سطح آب‌های زیرزمینی نسبت به مدل‌های عددی ارائه می‌دهد.

مروری بر منابع داخل و خارج از کشور نشان می‌دهد اگرچه در زمینه علم هوش مصنوعی مطالعات زیادی انجام شده و بر کارایی آن در زمینه‌های مختلف تأکید شده است اما تاکنون تحقیقی در مورد کاربرد شبکه عصبی مصنوعی در مدیریت مرتع انجام نشده است. همچنین اگر این روش بتواند با استفاده از فاکتورهای کم هزینه و سهل‌الوصول خاک میزان فاکتورهای پرهزینه را تعیین نماید، می‌تواند در مدیریت مرتع بسیار مؤثر باشد. بنابراین انجام پژوهش در زمینه کاربرد این روش نوین در مدیریت مرتع ضرورت داشته و اجرای این تحقیق بستر تحقیقاتی مناسبی برای محققان ایرانی در زمینه مدیریت مرتع فراهم می‌کند. از این رو این تحقیق برای پیش‌بینی عناصر معدنی ازت، فسفر و کربن خاک مرتع به‌منظور مدیریت صحیح کودپاشی مراتع به‌عنوان یکی از عملیات اصلاحی مراتع، در مراتع حوزه آبخیز نازلوچای ارومیه انجام شد.

مواد و روش‌ها

منطقه مورد مطالعه بین ۴۴ درجه و ۲۴ دقیقه تا ۴۵ درجه و ۵۳ دقیقه طول شرقی و ۳۷ درجه و ۳۰ دقیقه تا ۳۷ درجه و ۵۸ دقیقه عرض شمالی واقع شده است. حداقل ارتفاع حوزه ۱۲۹۱ متر و حداکثر ارتفاع آن ۳۶۰۰ متر می‌باشد. حوزه در شمال شهرستان ارومیه و در امتداد رودخانه نازلوچای واقع شده و فاصله آن تا شهرستان ارومیه ۲۰ کیلومتر است.

ناشی از افزایش هزینه کودهای شیمیایی و همچنین چالش‌های زیست محیطی ناشی از کاربرد بی‌رویه و غیراصولی این کودها همواره موجب نگرانی کارشناسان و برنامه‌ریزان بوده است (Rezvantalab et al., 2008; Wu et al., 2005). بنابراین برای دستیابی به توسعه پایدار منابع طبیعی و تحقق هدف‌های پیش‌بینی شده در این راستا استفاده از راهکارهای مناسب برای تأمین نیاز غذایی گیاه ضروری خواهد بود (Gupta et al., 2002). افزایش روزافزون قیمت کودهای شیمیایی در جهان، ضرورت اقتصادی بودن تولید، آلودگی آب‌های زیرزمینی و تخریب ساختمان خاک در اثر مصرف بی‌رویه و ناآگاهانه کودهای شیمیایی از جمله مشکلاتی است که باید با بهبود مدیریت از طریق انتخاب کود مناسب با میزان مناسب با شرایط محیطی برطرف شود (Bly et al., 2003). شبکه عصبی مصنوعی بر اساس ساختار نورونی و هوشمند سعی می‌کند تا از طریق توابع تعریف شده ریاضی، رفتار درون سلولی نورون‌های مغز را شبیه‌سازی کند و از طریق وزن‌های محاسباتی موجود در خطوط ارتباطی نورون‌های مصنوعی، عملکرد سیناپسی را در نورون‌های طبیعی به صورت مدل درآورد (Colibaly et al., 2000). Melesse و همکاران (۲۰۱۱)، بار معلق رسوبی را در رودخانه‌ها با استفاده از شبکه عصبی مصنوعی پیش‌بینی کردند و نتایج را با روش‌های رگرسیون خطی چندمتغیره، رگرسیون غیرخطی چندمتغیره و مدل آریمای مقایسه نمودند. نتایج به‌دست آمده نشان داد که شبکه عصبی نسبت به روش‌های دیگر پیش‌بینی دقیق‌تری ارائه کرده و عملکرد بهتری دارد. این روش می‌تواند از تراکم عملیات پرهزینه در اندازه‌گیری رسوب بکاهد. Isik و همکاران (۲۰۱۲)، با مطالعه و مدل‌سازی اثرهای تغییرات کاربری اراضی بر روی جریان روزانه رواناب در ایتالیا با استفاده از شبکه عصبی دریافتند که حداکثر جریان رواناب برای مناطق شهری و مرتع می‌باشد. Tabari و همکاران (۲۰۱۲)، طی مطالعه‌ای با استفاده از داده‌های ایستگاه سینوپتیک شیراز برای مدل‌سازی تبخیر از



شکل ۱- موقعیت جغرافیایی منطقه

گام اول: شناسایی تیپ‌های مرتعی

برای شناسایی تیپ‌های مرتعی، ابتدا نقشه اولیه تیپ‌بندی گیاهی با بهره گرفتن از عکس‌های هوایی و نقشه‌های توپوگرافی و گزارش‌های موجود تهیه و با پیمایش صحرایی و بر اساس نمود ظاهری و غالب بودن یک یا دو گونه که بیشترین سهم و اهمیت را در ترکیب پوشش گیاهی دارند، محدوده تیپ‌های گیاهی کنترل شد. برای اندازه‌گیری معیارهای کمی پوشش گیاهی، در هر تیپ گیاهی با توجه به وسعت و توپوگرافی منطقه، یک یا دو منطقه معرف طبق دستورالعمل طرح ملی ارزیابی مراتع مناطق مختلف آب و هوایی کشور (Arzani, 1997) انتخاب شد. سپس در داخل هر منطقه معرف، نمونه‌گیری به روش سیستماتیک- تصادفی در طول ترانسکت های ۱۰۰ متری انجام گردید که در طول هر ترانسکت، تعداد ۱۰ پلات ۱×۱ مترمربعی بصورت تصادفی بکار برده شد و به‌منظور دستیابی به جامعه آماری مناسب، در هر منطقه معرف تعداد ۶ ترانسکت استفاده گردید. سپس در داخل هر پلات، درصد تاج پوشش گیاهی و تولید اندازه‌گیری شد.

گام دوم: اندازه‌گیری خصوصیات فیزیکی و شیمیایی خاک

منطقه مورد مطالعه شامل ۱۳ تیپ گیاهی می‌باشد که با پایش زمینی تعداد ۶ نمونه خاک از عمق ۰-۱۵ سانتیمتری خاک در ۱۰ تیپ گیاهی از ۱۳ تیپ گیاهی برداشت گردید. در مجموع تعداد ۶۰ نمونه خاک به آزمایشگاه ارسال شد. در آزمایشگاه، اسیدیته خاک با استفاده از دستگاه pH متر اندازه‌گیری گردید (Huang et al., 2010). هدایت الکتریکی

خاک با استفاده از دستگاه EC متر دیجیتالی بر حسب دسی زیمنس بر متر محاسبه شد (Huang et al., 2010). درصد کربن آلی خاک با استفاده از روش والکی بلاک تعیین گردید (Jia et al., 2005). بافت خاک بر اساس روش هیدرومتری تعیین شد (Jia et al., 2005). نیتروژن به روش کج‌دال (Bremner et al., 1996) و فسفر به روش اولسن (Olsen & Sommers, 1982) اندازه‌گیری گردید.

گام سوم: کاربرد شبکه عصبی مصنوعی

آزمون نرمالیت داده‌ها

قبل از مرحله آموزش و آزمایش داده‌ها، آزمون نرمالیت داده‌ها به کمک آزمون کولموگروف- اسمیرنوف انجام گردید. با توجه به نرمال بودن داده‌ها، مدل‌سازی انجام شد.

داده‌پردازی در شبکه پرسپترون چند لایه

به‌منظور تخمین میزان نیتروژن، فسفر و کربن آلی مراتع از مدل شبکه عصبی مصنوعی استفاده شد. شبکه پرسپترون چند لایه در این مطالعه یک شبکه پیش‌خور با الگوریتم پس‌انتشار خطا بود که از سه لایه از نورون‌ها (نورون‌های لایه ورودی، پنهان و خروجی) در آن استفاده شد. این شبکه‌ها از سه لایه ورودی، پنهان و خروجی تشکیل گردید که اصطلاحاً به آن شبکه عصبی پرسپترون گفته شد. هر یک از لایه‌ها از تعدادی نورون تشکیل شد که هر نورون به کلیه نورون‌های لایه دیگر متصل بود. تعداد نورون‌های لایه ورودی و خروجی به ترتیب برابر با تعداد پارامترهای ورودی و خروجی مدل بود (minasnay et al, 2002). ساختار مناسب برای شبکه عصبی

$$RI = \frac{RMSE_a - RMSE_b}{RMSE_a} \times 100$$

در آزمون و ارزیابی شبکه‌های عصبی مصنوعی هر چه R^2 به عدد یک نزدیک‌تر و $RMSE$ به صفر نزدیک‌تر باشد، نتیجه به‌دست آمده مطلوب‌تر است، یا به عبارتی دیگر عملکرد شبکه مطلوب‌تر می‌باشد (Wosten *et al.*, 2001).

- آنالیز حساسیت مدل شبکه عصبی مصنوعی

به‌منظور تعیین اثر هر یک از پارامترهای ورودی بر میزان کربن آلی، نیتروژن و فسفر خاک مرتع، آنالیز حساسیت انجام شد. اینکار در شبکه عصبی با دو روش اضافه یا حذف کردن پارامتر ورودی در مدل انجام می‌شود. بر این اساس هر پارامتری که اضافه کردنش بیشترین کاهش را در $RMSE$ یا حذفش بیشترین افزایش را در $RMSE$ داشت، حساسترین پارامتر بود. در این تحقیق از روش دوم برای انجام آنالیز حساسیت استفاده شد. برای اینکار در هر مرحله از بین ۸ پارامتر ورودی، یکی از آنها حذف شده و مقدار $RMSE$ محاسبه گردید. بر این اساس پارامترهای درصد پوشش و میزان تولید، درصد شن، سیلت، رس، اسیدیته خاک، هدایت الکتریکی و درصد آهک به‌عنوان ورودی‌های مؤثر و میزان نیتروژن، فسفر و کربن آلی به‌عنوان خروجی‌های مدل انتخاب گردیدند. شایان ذکر است که تمامی ورودی‌های مؤثر با یک خروجی مدل‌سازی شدند. لازم به ذکر است که ۶۰٪ داده‌ها برای آموزش، ۱۵٪ داده‌ها برای اعتبارسنجی و ۲۵٪ داده‌ها برای آزمایش مدل در نظر گرفته شدند (Wosten *et al.*, 2001).

تخمین میزان NPC خاک تیپ‌های گیاهی فاقد داده

شبکه عصبی مصنوعی با پردازش اطلاعات ورودی مدل (رس، شن، سیلت و ...) میزان NPC را برای هر یک از سه تیپ گیاهی که فاقد اطلاعات مربوط به میزان نیتروژن، فسفر و کربن آلی بودند، تخمین زد.

با تعیین تعداد گره‌ها در لایه‌های ورودی و لایه مخفی انتخاب شد. برای تعیین تعداد بهینه گره در لایه مخفی از روش سعی و خطا استفاده شد. بر این اساس از پارامترهای خاکی و گیاهی به‌عنوان ورودی‌های شبکه استفاده و تعداد گره لازم در لایه مخفی برای معماری بهترین حالت شبکه عصبی توسط برنامه Neuro Solutions نسخه ۵ شناسایی شد. این مدل‌ها ابتدا با وارد کردن داده‌های مجموعه آموزش، آموزش دیده و بعد با ارائه داده‌های مجموعه آزمون مورد صحت‌سنجی قرار گرفتند.

ارزیابی کارایی مدل‌ها

عملکرد مدل‌ها به وسیله یک دسته از داده‌های آزمونی که در آموزش شبکه استفاده نشده‌اند ارزیابی شد. معیارهای مورد استفاده در ارزیابی مدل‌ها مجذور میانگین مربعات خطا ($RMSE$) و ضریب کفایت (R^2) بین مقادیر پیش‌بینی شده و اندازه‌گیری شده می‌باشد. فاکتور $RMSE$ دقت و اعتبار دسته داده‌های آموزشی و آزمونی را اندازه‌گیری کرد و با استفاده از فرمول زیر تعیین شد (Wosten *et al.*, 2001).

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}}$$

مقادیر ضریب تعیین (R^2) نیز یکی از آماره‌هایی است که در ارزیابی شبکه‌های عصبی به فراوانی از آن استفاده شده است و با استفاده از فرمول زیر بدست آمد (Wosten *et al.*, 2001).

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2}$$

که در آنها y_i مقادیر اندازه‌گیری شده، \hat{y}_i مقادیر پیش‌بینی شده، \bar{y} میانگین مقادیر اندازه‌گیری شده و N تعداد کل مشاهدات است.

درصد برتری نسبی (RI)، ریشه میانگین مجذور خطای بهترین مدل ورودی (اندیس b) نسبت به ریشه میانگین مجذور خطای هر یک از مدل‌های دیگر (اندیس a) با استفاده از رابطه زیر تعیین شد (Wosten *et al.*, 2001).

مدیریت کودپاشی

جدول‌های (Hazelton & Murphy, 2007) که در ذیل

ارائه شده است، مدیریت گردید.

کودپاشی در این مناطق، بر اساس میزان نیتروژن،

فسفر و کربن آلی تخمین زده شده خاک و طبق

جدول ۱- رتبه‌بندی برای ازت کل و فسفر (Hazelton & Murphy, 2007)

ازت (درصد وزن)	وضعیت	فسفر (mg P/kg soil)
< ۰/۰۵	خیلی کم	< ۵
۰/۰۵-۰/۱۵	کم	۵-۱۰
۰/۱۵-۰/۲۵	متوسط	۱۰-۱۷
۰/۲۵-۰/۵۰	زیاد	۱۷-۲۵
> ۰/۵	خیلی زیاد	> ۲۵

جدول ۲- رتبه‌بندی کربن خاک برای ارزیابی سلامت خاک و یا شرایط خاک (Hazelton & Murphy, 2007)

سطح کربن آلی (g/100 g)(%)	وضعیت
< ۴۰	خیلی خیلی کم
۴۰-۵۹	خیلی کم
۶۰-۷۹	کم L1
۸۰-۹۹	کم L2
۱۰۰-۱۱۹	متوسط M1
۱۲۰-۱۳۹	متوسط M2
۱۴۰-۱۵۹	متوسط M3
۱۶۰-۱۷۹	زیاد H1
۱۸۰-۱۹۹	زیاد H2
۲۰۰-۲۱۹	خیلی زیاد VH1
۲۲۰-۲۳۹	خیلی زیاد VH2
۲۴۰-۲۵۹	خیلی زیاد VH3
۲۶۰-۲۹۹	خیلی زیاد VH4
۳۰۰-۸۷۰	خیلی خیلی زیاد
> ۸۷۰	خیلی خیلی زیاد (نادر)


نتایج

Astragalus gummifera- prangos uloptera-Bromus
Onobrychis cornuta- tomentellus ۱/۴۴ برای تیپ
Festuca ovina-Thymus kotschyanus و ۰/۹۱ برای
 تیپ-*Astragalus macrostachys- Noeae mucronata*
Stipa barbata تخمین زده شد.

با توجه به نتایج جدول ۳، از بین سه مدل اجرا شده برای تخمین کربن آلی خاک، شبکه پرسپترون چند لایه با تابع یادگیری سیگموئیدی با کمترین MSE و بیشترین مقدار R^2 توانسته کربن آلی خاک مرتع را مدل سازی کند و میزان آن را تخمین بزند. کربن آلی خاک مرتع، ۱/۰۴ برای تیپ ،

جدول ۳- کارایی شبکه مورد نظر برای تخمین کربن آلی خاک مرتع

کارایی	تابع سیگموئید	تابع تانژانت هیپربولیک	تابع خطی اکسون
MSE	۰/۰۸۱	۳/۹۷۰	۱/۸۳۳
NMSE	۱/۰۰۳	۱/۳۸۸	۱
MAE	۰/۶۶۵	۱/۱۳۷	۱/۱۰۵
Min Abs Error	۰/۰۰۱	۰/۰۰۴	۰/۳۲۴
Max Abs Error	۰/۹۷۴	۴/۷۴۵	۲/۵۴۱
R^2	۰/۷۹۶	۰/۵۴۶	۰/۶۴۴



شکل ۲- آنالیز حساسیت برای مدل شبکه عصبی مصنوعی ایجاد شده جهت تخمین کربن آلی خاک

در ذیل ارائه شده است.

$$y = 0.4239x + 0.0094$$

$$R^2 = 0.7966$$

با توجه به جدول ۴، از بین سه مدل اجرا شده برای تخمین نیتروژن خاک، شبکه پرسپترون چند لایه با تابع یادگیری سیگموئید با کمترین MSE و بیشترین مقدار R^2 توانسته نیتروژن خاک مرتع را مدل سازی کند و میزان آن را


شکل ۲ نشان می دهد که تأثیر اسیدیته، هدایت الکتریکی، تولید و درصد تاج پوشش گیاهی در تخمین میزان کربن آلی خاک بیشتر از سایر پارامترها می باشد. نمودار زیر رابطه کربن آلی ورودی را در مقایسه با کربن آلی پیش بینی شده برای تابع سیگموئیدی نشان می دهد. دقت بالای این تابع با ضریب تبیین ۰/۷۹ قابل مشاهده است. تابع رگرسیونی کربن آلی خاک و کربن آلی پیش بینی شده

تخمین بزنند. نیتروژن خاک مرتع، ۰/۱۲ برای تیپ *Astragalus gummifera- prangos uloptera-Bromus tomentellus*، ۰/۱۶ برای تیپ *Onobrychis cornuta- Festuca ovina-Thymus kotschyanus* و ۰/۱۰ برای تیپ *Astragalus Macrostachys- Noeae mucronata- Stipa barbata* تخمین زده شد.

تخمین بزنند. نیتروژن خاک مرتع، ۰/۱۲ برای تیپ *Astragalus gummifera- prangos uloptera-Bromus tomentellus*، ۰/۱۶ برای تیپ *Onobrychis cornuta- Festuca ovina-Thymus kotschyanus* و ۰/۱۰ برای تیپ *Astragalus Macrostachys- Noeae mucronata- Stipa barbata* تخمین زده شد.

جدول ۴- کارایی شبکه مورد نظر برای تخمین نیتروژن خاک مرتع

کارایی	تابع سیگموئید	تابع تانژانت هیپربولیک	تابع خطی اکسون
MSE	۰/۰۰۸	۰/۰۰۶	۰/۰۰۸
NMSE	۱/۰۰۴	۱/۰۳۸	۱/۳۱۷
MAE	۰/۰۷۰	۰/۰۷۳	۰/۰۸۳
Min Abs Error	۰/۰۰۶	۰/۳۵۶	۰/۰۲۹
Max Abs Error	۰/۱۷۹	۰/۱۲۲	۰/۱۳۷
R ²	۰/۷۰۴	۰/۰۶۷	۰/۶۴۳



شکل ۳- آنالیز حساسیت برای مدل شبکه عصبی مصنوعی ایجاد شده جهت تخمین نیتروژن خاک

با توجه به نتایج جدول ۵، از بین سه مدل اجرا شده برای فسفر خاک، شبکه پرسپترون چند لایه با تابع یادگیری سیگموئیدی با کمترین MSE (۰/۲۱۴) و بیشترین مقدار R²، ۰/۶۶ توانسته فسفر خاک مرتع را مدل سازی کند و میزان آن را تخمین بزنند. فسفر خاک مرتع، ۱/۴۰ برای تیپ *Astragalus gummifera- prangos uloptera- Onobrychis Bromus tomentellus*، ۱/۹۴ برای تیپ *cornuta- Festuca ovina-Thymus kotschyanus* و ۱/۲۳ برای تیپ *Astragalus Macrostachys- Noeae mucronata- Stipa barbata* تخمین زده شد.


شکل ۳ نشان می‌دهد که تأثیر اسیدیته و تولید بر میزان نیتروژن خاک بیشتر از سایر پارامترها می‌باشد. نمودار ۲، رابطه نیتروژن ورودی را در مقایسه با نیتروژن پیش‌بینی شده برای تابع سیگموئیدی نشان می‌دهد. دقت بالای این تابع با ضریب تبیین ۰/۷۰ قابل مشاهده است. تابع رگرسیونی نیتروژن خاک و نیتروژن پیش‌بینی شده در ذیل ارائه شده است.

$$y = 0.4547x + 0.0196$$

$$R^2 = 0.704$$

جدول ۵- کارایی شبکه مورد نظر برای تخمین فسفر خاک مرتع

کارایی	تابع سیگموئید	تابع تانژانت هیپربولیک	تابع اکسون
MSE	۰/۲۱۴	۰/۶۵۰	۰/۲۸۶
NMSE	۱/۰۵۴	۲/۵۹۶	۱/۱۴۳
MAE	۰/۴۹۸	۰/۶۷۲	۰/۵۱۱
Min Abs Error	۰/۰۴۷	۰/۱۳۰	۰/۲۳۱
Max Abs Error	۰/۶۶۵	۱/۴۷۴	۰/۷۳۸
R ²	۰/۶۶۰	۰/۵۶۹	۰/۳۵۶



شکل ۴- آنالیز حساسیت برای مدل شبکه عصبی مصنوعی ایجاد شده جهت تخمین میزان فسفر خاک

تیبین ۰/۷۹ قابل مشاهده است. تابع رگرسیونی فسفر خاک و فسفر پیش‌بینی شده در ذیل ارائه شده است.

$$y = 0.7071x + 0.5025$$

$$R^2 = 0.6657$$

شکل ۴ نشان می‌دهد که تأثیر اسیدیته و هدایت الکتریکی بر تخمین میزان فسفر کل خاک بیشتر از سایر پارامترها می‌باشد. نمودار زیر رابطه فسفر خاک ورودی را در مقایسه با فسفر خاک پیش‌بینی شده برای تابع سیگموئیدی نشان می‌دهد. دقت بالای این تابع با ضریب

جدول ۶- میزان NPC پیش‌بینی شده خاک مرتع در تیپ‌های گیاهی فاقد داده

شماره تیپ	تیپ‌های گیاهی	کربن	نیترژن	فسفر	میزان کربن	میزان نیترژن	میزان فسفر
۱	<i>Astragalus gummifera-prangos uloptera-Bromus tomentellus</i>	۱/۰۴	۰/۱۲	۱/۴۰	متوسط	کم	خیلی کم
۲	<i>Onobrychis cornuta- Festuca ovina-Thymus kotschyanus</i>	۱/۴۴	۰/۱۶	۱/۹۴	متوسط	متوسط	خیلی کم
۳	<i>Astragalus macrostachys- Noeae mucronata-Stipa barbata</i>	۰/۹۱	۰/۱۰	۱/۲۳	کم	کم	خیلی کم

عملیات کودپاشی اگر درست مدیریت و بر اساس شرایط محیطی مانند شرایط خاکی انجام شود، باعث افزایش کمی و کیفی پوشش گیاهی، تولید علوفه، افزایش ارزش غذایی، خوش خوراکی و قابلیت هضم گیاهان، افزایش طول دوره رویش و بهبود ترکیب گیاهی می‌گردد. در غیر این صورت سبب ایجاد آثار منفی بر محیط و پوشش گیاهی، افزایش غلظت املاح و سمی شدن خاک، آلودگی آب‌های سطحی و زیرزمینی و ... می‌گردد. Bahrami و Motamedi (۲۰۱۲) با استفاده از شبکه عصبی مصنوعی روابط بین کربن آلی خاک و عوامل ادافیکی مؤثر بر آن را در اکوسیستم مرتعی خانقاه سرخ ارومیه مدل‌سازی کردند. نتایج آنان نشان داد که شبکه عصبی مصنوعی با تابع انتقال سیگموئید با دقت بیشتری کربن آلی خاک را پیش‌بینی می‌کند که با نتایج این تحقیق مطابقت دارد. Pilevar Shahri و همکاران (۲۰۱۱) مدل رگرسیون چندمتغیره و مدل هوشمند شبکه عصبی را در برآورد کربن آلی خاک به کمک داده‌های آنالیز سطح زمین مقایسه کردند. نتایج تحقیق آنان نشان داد که شبکه عصبی مصنوعی ابزار قدرتمندتری در پیش‌بینی کربن آلی نسبت به آنالیز رگرسیون خطی چندمتغیره می‌باشد. Keshavarz و همکاران (۲۰۱۵) با کمک شبکه عصبی مصنوعی اثر عوامل گیاهی و فیزیوگرافی را در تخمین فسفر خاک بررسی کردند. نتایج تحقیق آنان نشان داد که شبکه عصبی مصنوعی با دقت زیادی فسفر خاک را پیش‌بینی می‌کند که با نتایج این تحقیق مطابقت دارد. Sarmadian & Keshavarzia (۲۰۱۰) مدل رگرسیون چندمتغیره و مدل هوشمند شبکه عصبی را در برآورد ظرفیت تبادل یونی خاک به کمک داده‌های میزان رس و کربن آلی خاک مقایسه کردند. نتایج تحقیق آنان نشان داد که شبکه عصبی مصنوعی ابزار قدرتمندتری در پیش‌بینی ظرفیت تبادل یونی خاک نسبت به آنالیز رگرسیون خطی چندمتغیره می‌باشد. Bodaghabadi و همکاران (۲۰۱۵) در تحقیقی که در زمینه نقش‌برداری دیجیتال با استفاده از شبکه‌های عصبی مصنوعی و ویژگی‌های مرتبط با زمین انجام دادند بر کارایی روش شبکه عصبی مصنوعی تأکید کردند. Shiria و همکاران (۲۰۱۷) ظرفیت تبادل کاتیونی خاک را با استفاده از

میزان NPC پیش‌بینی شده برای تیپ‌های گیاهی فاقد داده در جدول ۶ ارائه شده است. به‌منظور مدیریت کودپاشی در این مناطق، طبق جدول‌های ۱ و ۲ (Hazelton & Murphy, 2007) که در بخش مواد و روش‌ها به آنها اشاره شد، وضعیت NPC خاک آنها در قالب جدول ۶ مشخص گردید. بر اساس نتایج جدول (۶)، تیپ گیاهی شماره (۱) نیاز به کود فسفره و نیتروژنه دارد. تیپ گیاهی شماره (۲) نیازمند کود فسفره و تیپ گیاهی شماره (۳) به مواد آلی و کود نیتروژنه و فسفره نیاز دارد.

بحث

پس از تجزیه و تحلیل پارامترهای مؤثر بر میزان کربن آلی، نیتروژن و فسفر خاک مرتع در بهترین مدل ارائه شده (سیگموئیدی) مشخص شد که تابع یادگیری سیگموئیدی با MSE برابر با ۰/۰۸، ۰/۰۰۸ و ۰/۲۱ و R^2 برابر با ۰/۷۹، ۰/۷۰ و ۰/۶۶ بهترین مدل پیشنهادی برای تخمین به‌ترتیب کربن آلی، نیتروژن و فسفر خاک نازلوجای می‌باشد. از بین ۸ پارامتر مؤثر در میزان کربن آلی، نیتروژن و فسفر خاک، ۴ پارامتر اسیدیته خاک، هدایت الکتریکی، تولید و درصد تاج پوشش گیاهی به‌ترتیب بیشترین تأثیر را در میزان تخمین کربن آلی، نیتروژن و فسفر خاک داشتند. بنابراین با توجه به نتایج مذکور، شبکه عصبی توانست با دقت بالایی میزان کربن آلی، نیتروژن و فسفر خاک مرتع را در تیپ‌های مرتعی که فاقد مقادیر NPC بودند، پیش‌بینی کند و بر اساس نتایج به دست آمده در مورد کودپاشی این مراتع تصمیم‌گیری شد. بر اساس نتایج این تحقیق، تیپ گیاهی شماره (۱) نیاز به کود فسفره و نیتروژنه دارد. تیپ گیاهی شماره (۲) نیازمند کود فسفره و تیپ گیاهی شماره (۳) به کود نیتروژنه و فسفره نیاز دارد. Bly (۲۰۰۳) در تحقیقی که در زمینه کودهای شیمیایی انجام داد چنین بیان کرد که بهبود مدیریت از طریق انتخاب کود مناسب با میزان مناسب با شرایط محیطی، سبب برطرف شدن مشکلاتی از قبیل آلودگی آب‌های زیرزمینی و تخریب ساختمان خاک در اثر مصرف بی‌رویه و ناآگاهانه کودهای شیمیایی می‌گردد. Ansari - (۲۰۰۹) چنین بیان می‌کند که

بود. در واقع مدل شبکه عصبی مصنوعی به‌عنوان ابزار قدرتمندتری در پیش‌بینی تنوع گونه‌ای نسبت به آنالیز رگرسیون خطی چندمتغیره و شبکه عصبی تطبیقی - فازی در تحقیق آنان معرفی شد. Tabari و همکاران (۲۰۱۱) برای تخمین دمای روزانه خاک در شش عمق خاک، مدل‌های شبکه عصبی پرسپترون چند لایه و روش رگرسیون خطی چند متغیره را استفاده نمودند. نتایج آنان نشان داد که مدل شبکه عصبی مصنوعی در مقایسه با روش‌های رگرسیون در پیش‌بینی دمای روزانه خاک در عمق‌های مختلف کارایی بالاتری داشته است. همچنین، Bilgili (۲۰۱۰) دمای ماهانه خاک را با استفاده از رگرسیون‌های خطی و غیرخطی و روش‌های شبکه عصبی مصنوعی در شهر آدانا ترکیه مدل سازی کرد. نتایج حاصل از اعتبارسنجی تحقیق او نشان داد که مدل شبکه عصبی گسترش یافته نسبت به سایر روشها پیش‌بینی واقعی‌تری را برای تخمین دمای خاک ارائه می‌کند. انتظار می‌رود در مطالعات آینده برای ایجاد مدلی معتبرتر به منظور مدیریت کودپاشی در مراتع از نمونه‌برداری‌های مترکم‌تر و تلفیق متغیرهای توپوگرافیکی و اطلاعات حاصل از تصاویر ماهواره‌ای و اطلاعات محیطی جانبی مؤثر استفاده نمود تا به نتایج رضایت‌بخش‌تری دست یافت. به طور کلی از این تحقیق می‌توان نتیجه گرفت با استفاده از شبکه عصبی مصنوعی می‌توان روابط بین کربن آلی، ازت و فسفر خاک را با عوامل ادافیکی مؤثر بر آنها در اکوسیستم‌های مرتعی مدل‌سازی کرد و از این طریق روش شبکه عصبی مصنوعی می‌تواند روش کارایی در تخمین عناصر غذایی خاکی در اکوسیستم‌های مرتعی باشد. به عبارت دیگر، با استفاده از این روش می‌توان بر اساس تعیین برخی از فاکتورهای کم هزینه و سهل‌الوصول، فاکتورهای پرهزینه خاکی را تخمین زد و در هزینه‌های پروژه‌های منابع طبیعی صرفه‌جویی کرد. این روش در زمینه‌های مختلف مدیریت مرتع از قبیل مدیریت صحیح کودپاشی به مدیران و کارشناسان مرتع کمک شایانی خواهد نمود.

پارامترهای میزان رس، سیلت و شن خاک با کمک روشهای مختلف مدل‌سازی کردند. نتایج تحقیق آنان بر کارایی روش عصبی فازی دلالت داشت. Ingleby & Crowe (۲۰۰۱) برای پیش‌بینی میزان کربن آلی از مدل شبکه عصبی مصنوعی استفاده کردند و نتایج آن را با مدل رگرسیون چندمتغیره مقایسه نمودند و بر کارایی روش شبکه عصبی مصنوعی تأکید کردند. Holmberg و همکاران (۲۰۰۶) از مدل شبکه عصبی مصنوعی برای پیش‌بینی میزان کربن آلی، نیتروژن و فسفر در جریان آب رودخانه استفاده کردند و از غلظت‌های شبیه‌سازی شده برای پیش‌بینی میزان کربن آلی، نیتروژن و فسفر جریان آب آینده در شرایط تغییرات آب و هوایی استفاده کردند. آنان نتیجه گرفتند که شبکه‌های عصبی مصنوعی یک روش مفید برای ایجاد مدل‌های جعبه سیاه کیفیت آب رودخانه هستند. shalmani و همکاران (۲۰۱۰) به بررسی وضعیت مقاومت خاکدانه‌ها پرداخته‌اند. آنان برای صرفه‌جویی در وقت و هزینه از روشهای غیرمستقیم استفاده نمودند و از بین این روش‌ها، برای تخمین پایداری خاکدانه‌ها، توابع انتقالی رگرسیونی را با شبکه عصبی مصنوعی مقایسه کردند. موارد اندازه‌گیری شده شامل درصد شن، سیلت، رس، ماده آلی، آهک، وزن مخصوص ظاهری توزیع ذرات، مقاومت مکانیکی خاک، اسیدیته و هدایت الکتریکی خاک بود. نتایج تحقیق آنان نشان داد که با توجه به خطای کمتر و درجه همبستگی بالاتر، شبکه عصبی مصنوعی دارای دقت بیشتری نسبت به توابع انتقالی می‌باشد. Bahrami و Ghorbani (۲۰۱۳) به‌منظور تعیین عوامل تأثیرگذار بر تنوع گونه‌ای، فاکتورهای هدایت الکتریکی، اسیدیته، وزن مخصوص ظاهری، درصد‌های ماده آلی، رس، سیلت، رطوبت اشباع، خاکدانه‌های درشت و ریز، شیب و ارتفاع را اندازه‌گیری کردند. سپس با استفاده از مدل‌های شبکه عصبی نوع پرسپترون چند لایه، شبکه عصبی تطبیقی - فازی و رگرسیونی تخمین تنوع گونه‌ای انجام شد. نتایج تحقیق آنان نشان داد که معیارهای مجذور میانگین مربعات خطا و ضریب کارایی در مدل رگرسیونی به‌ترتیب ۰/۱۴ و ۰/۳۹ و در مدل شبکه عصبی مصنوعی ۰/۰۷ و ۰/۸۶ و در مدل شبکه عصبی تطبیقی - فازی ۰/۰۹ و ۰/۷۰

- Desert Research, 17 (2): 180-190.
- Elliott, D. E. and Abbott, R.J., 2003. Nitrogen fertilizer use on rainfed pasture in the Mt. Lofty Ranges, Pasture mass, composition and nutritive characteristics. *Journal of Experimental Agricultural*, 43: 553-577.
 - Frame, J., 1992. Improved grassland management farming press books, Ipswich, 200p.
 - Jangju, M., 2009. Improvement and Range Development, Mashhad University Press, 240 pages.
 - Ghaderi, B., 2008. Investigating the effect of *Alfalfa* seedling on some properties of vegetation of natural ranges. *Iranian Journal of Research and Development in Natural Resources*, (15): 166 - 177.
 - Griffe, P., Metha, S. and Shankar, D., 2003. Organic production of medicinal, aromatic and dye yielding plants (MADPs): forward, preface and introduction. *Journal of Food and Agriculture Organization*, 2: 52-63.
 - Guevara, J.C., Carlos, R.S., Oscar, R.E. and Le Houerou, H.N., 2000. N and P fertilization on rangeland production in Midwest Argentina. *Journal of Range Manage*, 53: 410-414.
 - Gupta, M.L., Prasad, A., Ram, M. and Kumar, S., 2002. Effect of the vesicular-arbuscular mycorrhiza (VAM) fungus *Glomus fasciculatum* on the essential oil yield related characters and nutrient acquisition of the crops of different cultivars of menthol mint (*Mentha arvensis*) under field conditions. *Journal of Bio resource Technology*, 81: 77-79.
 - Hazelton, P. and Murphy, B., 2007. Interpreting soil test results, National Library of Australia Cataloguing-in-Publication entry, Pp: 67-89.
 - Holmberg, M., Forsius M., Starr, M. and Huttunen, M., 2006. An application of artificial neural networks to carbon, nitrogen and phosphorus concentration in three boreal streams and impacts of climate change. *International Society for Ecological Information 3rd Conference*. Grottaferrata, Roma, 195:51-60.
 - Huang, P. and Tsai, W., 2010. Using multiple-criteria decision-making techniques for eco environmental vulnerability assessment: a case study on the Chi-Jia-Wan Stream watershed, Taiwan. *Journal of Environment Monitoring Assess*, 168: 141-158.
 - Isik, s., klin, L. and Schoonover, J.E., 2012. Modeling effects of changing land use/cover on daily stream flow: artificial neural network and curve number based hybrid approach. *Journal of Hydrology*, 50(3):1984-2001.
 - Ingleby, H.R. and Crowe, T.G., 2001. Neural network models for predicting organic matter content in

منابع مورد استفاده

- Ansari, V., 2009. Principles of technical implementation of rangeland improvement and rehabilitation projects, Puneh publication, 176 pages.
- Arzani, H., 1997. Instructions on evaluation of the rangelands of different climate zones of Iran, Institute of Forestry and Rangelands, 67 pages.
- Bahrami, B. and Ghorbani, A., 2013. Evaluation of neural network and regression models to predict species diversity using some soil and physiographic factors (Case Study: Kharabeh Sanji watershed of Urmia). *Journal of Natural Ecosystems of Iran*, 5 (2): 65-80.
- Bilgili, M., 2010. Prediction of soil temperature using regression and artificial neural network models. *Journal of Meteor Atmospheric Physics*, 110:59-70.
- Bodaghabadi, J., Bagheri, M., Esfandiari, I. and Toomanian, N., 2015. Digital soil mapping using artificial neural networks and terrain-related attributes. *Journal of Pedosphere*, 25 (4): 580-591.
- Bly, A.G. And Woodard, H. J., 2003. Foliar nitrogen application timing influence on grain yield and protein concentration of hard red winter and spring wheat. *Journal of Agronomy*, 95: 335-338.
- Bremner, M., Sparks, L., Page, L., Helmke, A., Loeppert, H., Soltanpour, N. and Sumner, M., 1996. Nitrogen-total methods of soil analysis. Part 3- Chemical Methods: 1085-1121.
- Corcini, A., cervi, F. and Ronchetti, F., 2009. Weight of evidence and artificial neural networks for potential groundwater spring mapping: an application to the Mt. Modino area (Northern Apennines, Italy), *Journal of Geomorphology*, 3: 79-87.
- Corrado, M., Fanelli, A.M. and Chieco, M., 2008. A Neural Network for Water Level Prediction in Artesian Wells, *International Conferences on Computational Intelligence for Modelling, Control and Automation; Intelligent Agents, Web Technologies and Internet Commerce; and Innovation in Software Engineering, USA*, Pp: 686-69.
- Coulibaly, P., Antil, F. and Bobee, B., 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach, *Journal of Hydrology*, 23(3): 244-257.
- Dianti Tilki, A., Turan, M., Hosseini, A. and Msadaghi, M., 2010. Investigation on the effect of nitrogenous and phosphorus fertilizers on quality of forage *eruca sativa* in Golestan Ghorbani rangelands of Maraveh Tapeh. *Iranian Journal of Rangeland and*

- Pilevar Shahri, A.R., Ayoubi Sh., and Khademi H., 2011. Comparison of Artificial Neural Network (ANN) and Multivariate Linear Regression (MLR) Models to Predict Soil Organic Carbon Using Digital Terrain Analysis. *Journal of Water and Soil*, 24(6): 1151-1163.
- Rezvantlab, N., Pirdashti, H., Bahmanyar, M. A. and Abbasian, A., 2008. Study some of yield and yield component of corn (*Zea mays L.*) response to different types and rates of organic and chemical fertilizers. *Journal of Agricultural Science and Natural Resource*, 15(5): 139-147.
- Sarmadian, F. and Keshavarzia, F., 2010. Comparison of artificial neural network and multivariate regression methods in prediction of soil cation exchange capacity (Case study: Ziara region). *Journal of Desert*, 15:167-174.
- Shalmani, A., Asadi, H., Bagheri, F. and Shabanpour Shahrestani, M., 2010. Comparison of regression pedotransfer functions and artificial neural networks for soil aggregate stability simulation. *World Applied Sciences Journal*, 8 (9): 1065-1072.
- Shiria, J., Keshavarzi, A., Bagherzadehe, A., Mousavi, R. and Karimi, M., 2017. Modeling soil cation exchange capacity using soil parameters: Assessing the heuristic models. *Journal of Computers and Electronics in Agriculture*, 135: 242-251.
- Sreekanth, P. D., Geethanjali, N., Sreedevi, P. D., Shakeel, A., Kumar, N.R. and Jayanthi, P.D.K., 2009. Forecasting groundwater level using artificial neural networks. *Journal of Current Science*, 96 (7): 933-939.
- Tabari, H., Sabziparvar, A. A., and Ahmadi, M., 2011. Comparison of artificial neural network and multivariate linear regression methods for estimation of daily soil temperature in an arid region. *Journal of Meteor Atmospheric Physics*, 110:135-142.
- Wosten, J.H.M., Pachepsky, Y.A. and Rawls, W. J., 2001. Pedo transfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *Journal of Hydrology*, 251:123-150.
- Wu, S. C., Caob, Z. H., Lib, Z. G., Cheunga, K. C., and Wong, M. H., 2005. Effects of bio fertilizers containing N-fixer, P and K Solubilizes and AM fungi on maize growth: a greenhouse trial. *Journal of Geoderma*, 125: 155-166.
- Saskatchewan soils. *Journal of Canadian Biosystems Engineering*, 43:71-75.
- Jia, B. R., Zhou, G.S., Wang, Y. H., Yang, W. P. and Zhou, L., 2005. Partitioning root and microbial contributions to soil respiration in *Leymus chinensis* population. *Journal of Soil Biology & Biochemistry*, 38:653-660.
- Keshavarzi, A., Sarmadian, F., Ewisomran., And Munawar, I., 2015. A neural network model for estimating soil phosphorus using terrain analysis. *The Egyptian Journal of Remote Sensing and Space Science*, (18): 127-135.
- Kumar, B., Trivedi, P. and Pandey, A., 2009. *Pseudomonas corrugates*: A suitable bacterial inoculants for maize grown under rain fed conditions of Himalayan region. *Journal of Soil Biology and Biochemistry*, 39: 3093-3100.
- Melesse, A. M., Ahmad, S., McClain, M.E., Wang, X. and Lim, Y. H., 2011. Suspended sediment load prediction of river systems: An artificial neural network approach. *Agricultural Water Management Journal*, 98(5): 855-866.
- Mesdaghi, M., 2002. *Rangeland in Iran*, Astan Quds Razavi Publishing, Fifth Edition, 333 pages.
- Minasny, B. and Mcbratney, A. B., 2002. The neuro-m method for fitting neural network parametric pedo transfer functions. *Journal of Soil Science Society*, 66:352-361.
- Mohanty, S., Madnk, J.A. and Ashwani, D. K., 2013. Comparative evaluation of numerical model and artificial neural network for simulating groundwater flow in Kathajodi-Surua Inter-basin of Odisha, India. *Journal of Hydrology*, 495: 38-51.
- Motamedi, J. and Bahrami, B., 2012. Soil organic carbon analysis using artificial neural network to determine the contribution of management factors to climate change in the management of rangeland ecosystems, Second National Conference on Climate Change and Its Impact on Agriculture and the Environment, July, Urmia.
- Ojaghlu, P., 2007. Effect of inoculum with biofertilizer (*Azotobacter* and phosphate fertilizer) on growth, yield and yield components of safflower, Master's degree in Agriculture, Faculty of Agriculture, Islamic Azad University, Tabriz, 96 p.
- Olsen, S. R. and Sommers, L. E., 1982. Phosphorus, methods of soil analysis part 2, America Society Agronomy, Soil Science Society of America Journal, Madison Wisconsin: 403-430.

Management of rangelands by using artificial neural network (West Azarbayjan province)

M. Souri^{1*}, M.F. Blurfrush², J. Motamedi³ and B. Ataeian⁴

1*- Corresponding author, Assistant Professor, Rangeland Research Division, Research Institute of Forests and Rangelands, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Email: souri@rifr-ac.ir

2-M.Sc. Graduate of Range Management, Faculty of Natural Resources, University of Urmia, Iran

3- Associate Professor, Rangeland Research Division, Research Institute of Forests and Rangelands, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran

4- Assistant Professor, Natural Resources and Environment Faculty, Malayer, Hamedan, Iran

Received: 04/28/2018

Accepted: 12/11/2018

Abstract

If the rangeland forage is used continuously, the important elements such as NPC do not return to the soil, which will cause the rangeland lands to lose their fertility. Therefore, nowadays, in the field of rangeland management, rangeland improvement and rehabilitation has become very important. The use of fertilizers is one of the methods to rehabilitation the rangelands. If the proper fertilizer application is carried out in accordance with the climatic conditions, cover condition, and soil characteristics, it will improve the rangeland. Otherwise, it will increase the concentration of salts, soil toxicity, and surface and groundwater contamination and leads to drying of the plants. The aim of this study is to present a model based on the use of an artificial neural network that expresses the relationships between organic carbon, nitrogen and phosphorus of rangeland soil and plant factors, based on which, it is possible to estimate the mentioned elements in the rangeland ecosystems without statistics to manage fertilization. Based on the results, organic carbon, nitrogen and phosphorus of the soil were estimated in the Nazlocha rangeland of Urmia. Eight factors of electrical conductivity, acidity, clay percentage, silt percentage, sand percentage, lime content, production and canopy cover percentage of rangeland plants were also selected for factor analysis. Therefore, according to the mentioned results, the neural network was able to accurately predict the amount of organic carbon, nitrogen and phosphorus in rangeland soils. According to the results, the vegetation type *Astragalus gummifera-prangos uloptera-Bromus tomentellus* requires phosphorus and nitrogen fertilizers. *Onobrychis cornuta- Festuca ovina-Thymus kotschyanus* requires phosphorus fertilizer, and *Astragalus macrostachys-Noeae mucronata-Stipa barbata* requires organic matter and nitrogen and phosphorus fertilizers.

Keywords: Rangelands improvement, fertilizer application, artificial neural network, NPC soil, Nazloochoaei rangeland.