

مدل‌سازی عرض عملیات خاکی جاده‌های جنگلی با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی چندگانه

◀ صبا پیرو؛ دانش‌آموخته کارشناسی ارشد جنگلداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس، ایران

◀ اکبر نجفی*؛ دانشیار گروه جنگلداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس، ایران

◀ سید جلیل علوی؛ استادیار گروه جنگلداری، دانشکده منابع طبیعی، دانشگاه تربیت مدرس، ایران

(تاریخ دریافت: ۱۳۹۲/۱۱/۱۸ تاریخ پذیرش: ۱۳۹۳/۲/۹)

چکیده

عرض عملیات خاکی، به‌عنوان یکی از مهم‌ترین پارامترهای تعیین‌کننده حجم خاکبرداری و خاکریزی، در هزینه و تخریب ناشی از عملیات جاده‌سازی در جنگل مؤثر است. هدف از این پژوهش بررسی امکان پیش‌بینی عرض عملیات خاکی جاده‌های جنگلی است. برای نیل به این هدف دو روش شبکه عصبی مصنوعی و رگرسیون خطی چندگانه بکار گرفته شده است. برای این منظور، ۱۹۲ مقطع عرضی در جاده‌های جنگلی سوردار-واتاشان مورد بررسی قرار گرفتند. در هر مقطع داده‌های مربوط به پارامترهای فیزیوگرافی شامل شیب طبیعی دامنه، درجه سختی زمین و بافت خاک به‌عنوان متغیرهای مستقل و عرض عملیات خاکی به‌عنوان متغیر وابسته جمع‌آوری شدند. مدل‌های پیش‌بینی عرض عملیات خاکی با استفاده از شبکه عصبی پیش‌خور با الگوریتم یادگیری پس انتشار خطا و رگرسیون خطی چندگانه با روش گام‌به‌گام به ترتیب در محیط نرم‌افزارهای MATLAB ۷/۶ و R ساخته شدند و آزمون‌های همبستگی و تجزیه واریانس نیز در محیط SPSS ۱۹ صورت گرفت. بر اساس آماره‌های ضریب تبیین، مجذور میانگین مربعات خطا، میانگین مطلق خطا و درصد خطا، مدل شبکه عصبی توانست موفق‌تر از رگرسیون خطی چندگانه، عرض عملیات خاکی را پیش‌بینی کند به‌طوری‌که R^2 و RMSE به ترتیب در مدل شبکه عصبی ۰/۶۵ و ۲/۱۳ و در مدل رگرسیونی ۰/۲۴ و ۸/۲۸ بدست آمد. نتایج این پژوهش زمینه را برای طراحی شبکه عصبی مصنوعی با قابلیت پیش‌بینی مناسبی برای عرض عملیات خاکی جاده‌های جنگلی در شرایط توپوگرافی جنگل‌های کوهستانی فراهم می‌آورد.

کلمات کلیدی: بافت خاک، درجه سختی زمین، شیب دامنه، عرض عملیات خاکی.

مقدمه

جایگاه و نقش حمل و نقل در ابعاد مختلف اقتصادی، سیاسی و اجتماعی جوامع امروزی بر کسی پوشیده نیست. حمل و نقل یکی از پایه‌های اصلی توسعه پایدار و متوازن در جوامع بشری محسوب شده و در واقع شبکه‌های حمل و نقل با مؤلفه‌هایی همچون اقتصاد، امنیت و عدالت اجتماعی ارتباط تنگاتنگ دارند. طراحی و احداث جاده‌های جنگلی نیز به‌عنوان شریان حیاتی واحدهای جنگلداری و اولین مبنای سازمان‌دهی زمین در طرح‌های جنگلداری، ضرورتی انکارناپذیر دارد (Erdas *et al.*, 1995). احداث جاده در جنگل به علت هزینه‌های مربوط به ساخت و نگهداری و نیز جابه‌جایی و تخریب خاک دارای حساسیت زیاد از نظر اقتصادی و زیست‌محیطی است (Tan, 1992). لذا استفاده از روش‌ها و تکنیک‌های مختلف به‌منظور کاهش هزینه‌ها و جابه‌جایی خاک ضروری می‌باشد. یکی از مؤثرترین بخش‌ها در اندازه حجم عملیات خاکی (خاکبرداری و خاکریزی و انتقال خاک) و هزینه‌های آن، عرض عملیات خاکی است که محاسبه دقیق آن بعد از ساخت جاده میسر است. شرایط مختلف و متنوع پارامترهایی مانند شیب دامنه، درجه سختی زمین و نوع خاک منطقه بر حجم عملیات خاکی تأثیر می‌گذارد (Ghajar *et al.*, 2012; Hosseini *et al.*, 2012; Potocnik, 2003; Gorton, 1985; Sedlak, 1985). از این رو پیش‌بینی عرض عملیات خاکی به‌عنوان یک پارامتر تأثیرگذار، همواره مورد توجه پژوهشگران، مدیران، مهندسان و پیمان‌کاران بوده است. مطالعه‌ها نشان می‌دهد که عرض عملیات خاکی در مناطق کوهستانی به شیب دامنه بستگی دارد (Parsakhoo *et al.*, 2009). در این راستا سامانه اطلاعات جغرافیایی نیز به‌عنوان ابزاری در جهت اندازه‌گیری حجم عملیات خاکی مورد توجه پژوهشگران قرار گرفته است (Majnonian *et al.*, 2011). Gumus و همکاران (۱۹۹۸) با استفاده از سامانه‌های اطلاعات جغرافیایی به محاسبه حجم عملیات خاکی در پروژه جاده جنگلی پرداختند که چهار پروژه

جاده جنگلی به‌عنوان مطالعه موردی انتخاب شده و برای محاسبه حجم عملیات خاکی از مدل ارتفاعی رقومی که از نقشه‌های توپوگرافی با مقیاس ۱:۲۵۰۰۰ استخراج شده بود، استفاده شد. نتایج نشان داد که بدون بکارگیری GIS، استفاده از اطلاعات زیاد ممکن نبوده و تحلیل این حجم زیاد اطلاعات امکان‌پذیر نیست. ضمناً این مطالعه پس از ساخت جاده انجام شده و در کاهش هزینه‌های احداث جاده تأثیری نداشته است.

پژوهش‌های پیشین نشان می‌دهد که مطالعه‌های انجام شده در این ارتباط بر اساس روش‌های دستی استوار بودند، ضمن اینکه محاسبه حجم عملیات خاکی پس از ساخت جاده انجام شده است. بیشترین علاقه‌مندی پژوهشگران و مهندسان جنگل، یافتن روش‌هایی است که قبل از ساخت جاده حجم عملیات خاکی را پیش‌بینی نمایند. امروزه در کنار روش‌های رایج آماری، روش‌های جدیدتری به‌منظور پیش‌بینی بکار گرفته می‌شوند که یکی از آن‌ها شبکه‌های عصبی مصنوعی است. با توجه به اینکه شبکه‌های عصبی از دو ویژگی اساسی یادگیری بر اساس ارائه داده‌های تجربی (توانایی برازش) و ساختار پذیری موازی برخوردار می‌باشند، این شبکه‌ها برای مسائل کنترل، به‌ویژه سیستم‌های پیچیده که مدل‌سازی این سیستم‌ها یا میسر نیست و یا به‌سختی انجام می‌پذیرد بسیار مناسب هستند (Bayati *et al.*, 2013). با توجه به کاربرد تکنیک‌های هوش مصنوعی و ابزارهای مدل‌سازی در حوزه علوم مهندسی استفاده از شبکه عصبی مصنوعی به‌طور فزاینده‌ای در حال افزایش است. در چند دهه گذشته دو عنوان شبکه‌های عصبی مصنوعی و الگوریتم‌های ژنتیک از موضوعاتی بوده‌اند که توجه بسیاری از محققین را به خود جلب کرده‌اند (Chayjan *et al.*, 2007). با توسعه و نفوذ این روش در شاخه‌های مختلف منابع طبیعی، شبکه عصبی مصنوعی جایگاه ویژه‌ای در طراحی و مدل‌سازی پدیده‌ها پیدا کرده است. در سال‌های اخیر مدل‌سازی‌های موفق‌تری به کمک شبکه‌های عصبی مصنوعی در مباحث مختلف علوم جنگل

عوامل شیب طبیعی دامنه، درجه سختی زمین و بافت خاک منطقه استفاده شد. به‌منظور مقایسه، روش تحلیل رگرسیون خطی نیز در تعیین مدل پیش‌بینی عرض عملیات خاکی مورد آزمون قرار گرفت.

مواد و روش‌ها


این تحقیق در استان مازندران، در سری‌های ۱ و ۲ جنگل-های سوردار - واتاشان حوزه آبخیز شماره ۵۰ طرح جامع جنگل‌های شمال کشور انجام گرفت. این منطقه بین عرض ۳۰' ۳۶° شمالی و ۱۰' ۵۲° شرقی و در قسمت مرکزی حاشیه شمالی رشته‌کوه البرز قرار داشته و قسمتی از جنگل‌های هیرکانی است. این منطقه از نظر زمین‌شناسی نیز دارای منشأ سنگ‌های مادری آهکی از نوع مارن آهک ماسه‌ای - سیلنتی و عمدتاً عمیق تا نسبتاً عمیق است. منطقه مورد مطالعه در محدوده ارتفاعی ۱۵۰ تا ۱۲۰۰ متر از سطح دریا قرار دارد که شیب طبیعی دامنه از ۰ تا ۷۵ درصد و در چهار جهت شمال، شرق، جنوب و غرب است. این منطقه در مجموع دارای حدود ۲۰ کیلومتر جاده‌های جنگلی درجه ۲ و ۳ است. سن جدیدترین جاده-ها ۲ سال و قدیمی‌ترین جاده‌ها دارای سن بالای ۲۰ سال است.

به‌منظور پیش‌بینی عرض عملیات خاکی، مقطع عرضی در ۱۹۲ نقطه انتخابی در طول ۲۰ کیلومتر جاده موجود برداشت شد. محل نمونه‌برداری‌ها به صورتی انتخاب شدند که دامنه تغییرات پارامترهای مورد بررسی را شامل شوند. سپس در هر مقطع متغیرهای طول دیواره‌های خاکبرداری و خاکریزی، عرض عملیات خاکی و عرض بستر اندازه‌گیری شدند (شکل ۱).

صورت گرفته است که پیش‌بینی زمان قطع (Bayati *et al.*, 2013)، پیش‌بینی حجم بینه (Bayati & Najafi, 2011)، تهیه نقشه تراکم (Blackard *et al.*, 1999) و پیش‌بینی انواع پوشش (Joshi *et al.*, 2006) نمونه‌هایی از این گروه پژوهش‌ها می‌باشند.

شبکه‌های عصبی مصنوعی

امروزه روش‌های هوشمند و الهامی از طبیعت در علوم مختلف مهندسی از جایگاه بسیار مناسبی بهره‌مند هستند، به‌گونه‌ای که پژوهشگران و مهندسان برای حل مسائلی که حل آن‌ها با روش‌های معمول بسیار دشوار و یا حتی غیرممکن است از این روش‌ها استفاده می‌کنند (Kia, 2014). شبکه عصبی مصنوعی، لایه ورودی متغیر-های مسئله مورد بررسی را دریافت می‌کند و لایه خروجی مقادیر تخمین زده شده را ارائه می‌نماید. پردازش اطلاعات در نوروها صورت می‌گیرد (Melesse *et al.*, 2007). این روش نسبت به روش‌های دیگر دارای مزیت‌هایی است، از آن جمله شبکه عصبی مصنوعی برای آنالیز صحت داده-ها به بررسی‌های کمتری در قیاس با روش‌های آماری نیاز دارد، همچنین شبکه عصبی مصنوعی مسائل و مشکلاتی را مورد بررسی قرار می‌دهد که روش‌های آماری به دلیل محدودیت تئوری‌شان قادر به پاسخ‌گویی به آن‌ها نیستند (Caniani *et al.*, 2007; Lee *et al.*, 2005; Ermini *et al.*, 2006). پرستفاده‌ترین شبکه‌های عصبی عبارتند از: شبکه عصبی پرسپترون چندلایه (MLP) و شبکه تابع پایه شعاعی (RBF). در این تحقیق با توجه به توانایی‌ها و انعطاف‌پذیری شبکه عصبی پرسپترون چندلایه و شبکه تابع پایه شعاعی، از این دو شبکه برای مدل‌سازی عرض عملیات خاکی جاده‌های جنگلی یک‌طرفه با استفاده از



شکل ۱- اجزای عرض عملیات خاکی

شیب طبیعی از قسمت بالا تا پایین دامنه بر حسب درصد با استفاده از شیب سنج سونتو اندازه‌گیری شد. درجه سختی زمین در هر پروفیل تعیین و در ۳ طبقه نرم، متوسط و سخت قرار گرفت (Ghajar et al., 2012). بافت خاک نیز از روش هیدرومتری تعیین و در کلاسه‌های بافت لومی شنی، لومی، لومی رسی و رسی طبقه‌بندی شد (Zarinkafsh & Seadat, 1978). Lajevardi, 1978). عرض عملیات خاکی نیز با استفاده از متر لیزری، عمود بر امتداد مسیر از قسمت بالای دیواره خاکبرداری تا قسمت پایینی دیواره خاکریزی بر حسب متر برداشت شد. پس از جمع‌آوری داده‌ها آن‌ها را وارد نرم‌افزار SPSS ۱۹ کرده و نرمال بودن داده‌ها با استفاده از آزمون کولموگروف-اسمیرنوف و همگنی داده‌ها با بکارگیری آزمون لون بررسی شد.

شبکه عصبی مصنوعی

برای مدل‌سازی شبکه عصبی از نرم‌افزار MATLAB ۷/۶ استفاده شد. ابتدا برای افزایش دقت و سرعت در آموزش شبکه، داده‌ها با استفاده از رابطه (۱) بین ۰ و ۱ استاندارد-سازی شدند.

$$\bar{X} = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad \text{رابطه (۱)}$$

در این رابطه \bar{X} مقادیر استاندارد شده، X_i مقادیر واقعی، X_{\min} حداقل مقادیر واقعی و X_{\max} حداکثر مقادیر واقعی است. سپس داده‌ها به صورت تصادفی به سه دسته آموزش (۷۰ درصد داده‌ها)، آزمایش (۱۵ درصد داده‌ها) و صحت سنجی (۱۵ درصد داده‌ها) تقسیم شدند.

در این تحقیق دو شبکه عصبی MLP و RBF که از رایج‌ترین شبکه‌های عصبی مصنوعی پیش‌خور هستند مورد استفاده قرار گرفت. این شبکه‌ها با الگوریتم پس انتشار آموزش داده می‌شوند و دارای ساختار لایه‌ای هستند. فرآیند آموزش برای این شبکه‌ها که شامل تغییر وزن آکسون‌ها و آریبی در طول زمان آموزش است، انجام شد تا جایی که تفاوت بین داده‌های واقعی (برای داده‌های آزمون) و داده‌های پیش‌بینی شده توسط شبکه به کمترین مقدار برسد.

جدول ۱- ماتریس میزان سنگلاخی بودن منطقه در پیش‌بینی عرض عملیات خاکی با رگرسیون ($n=192$)

سطوح میزان سنگلاخی	Rock ۱	Rock ۲
۱	۱	صفر
۲	صفر	۱
۳	صفر	صفر

جدول ۲- ماتریس بافت خاک در پیش‌بینی عرض عملیات خاکی با رگرسیون ($n=192$)

سطوح بافت خاک	بافت ۱	بافت ۲	بافت ۳
۱	۱	صفر	صفر
۲	صفر	۱	صفر
۳	صفر	صفر	۱
۴	صفر	صفر	صفر

ظاهری (دودویی) که فقط دو مقدار ۰ و ۱ را می‌گیرند نشان داده شدند (جدول‌های ۱ و ۲). پارامتر شیب دامنه نیز به صورت کمی وارد مدل شد. برای مقایسه توانایی مدل شبکه عصبی و رگرسیون چندگانه، داده‌های بدست آمده به صورت تصادفی به دو دسته نمونه ۱۳۴ برای آموزش مدل‌ها و ۵۸ نمونه برای آزمون مدل‌ها (آزمایش و صحت سنجی)، تقسیم شدند. در مرحله اول به کمک رگرسیون، معادله پیش‌بینی عرض عملیات خاکی بر حسب متغیرهای مستقل آموزشی (شیب دامنه، نسبت سنگی و بافت خاک) بدست آمد. سپس با قرار دادن متغیرهای مستقل آزمون در این معادله، عرض عملیات خاکی پیش‌بینی توسط رگرسیون محاسبه شد. به منظور ارزیابی دقت مدل‌ها از معیارهای ضریب تبیین (R^2) (رابطه ۲)، مجذور میانگین مربعات خطا (RMSE) (رابطه ۳)، متوسط قدر مطلق خطا (MAE) (رابطه ۴) و درصد خطا (E%) (رابطه ۵) استفاده شد.

تعداد نورون‌ها در لایه ورودی بستگی به تعداد متغیرهای ورودی دارد. لایه خروجی مقادیر تخمین زده شده را ارائه می‌نماید و بسته به هدف تحقیق تعداد نورون در این لایه متفاوت است. در این تحقیق از یک نورون در لایه خروجی برای پیش‌بینی عرض عملیات خاکی استفاده شد. تعداد نورون در لایه پنهان با استفاده از روش سعی و خطا بین ۵ تا ۲۰ تغییر داده شد. برای این شبکه‌ها از تابع فعال‌سازی غیرخطی سیگموئید به دلیل مشتق‌پذیر بودن، سادگی و کاربرد آن در بیشتر تحقیقات مبتنی بر شبکه عصبی مصنوعی استفاده شد (Diamantopoulou *et al.*, 1999; Kia, 2014).

مدل رگرسیونی خطی

مدل‌سازی رگرسیون در نرم‌افزار R Core ۳.۰.۱ (Team, 2013) و با روش گام‌به‌گام صورت گرفت که پارامترهای بافت خاک و درجه سنگی به صورت متغیرهای

نتایج

شبکه MLP با ترکیب ۴-۸-۱ و شبکه RBF با ترکیب ۴-۱۰-۱ به عنوان مدل‌های با مناسب‌ترین ترکیب ساخته شدند. نتایج پارامترهای آماری عرض عملیات خاکی مشاهده شده و پیش‌بینی شده شبکه عصبی مصنوعی MLP و RBF و رگرسیون به شرح جدول (۳) ارائه شده است. مقایسه بین این مقادیر نشان می‌دهد که شبکه عصبی مصنوعی در مقایسه با رگرسیون عملکرد بهتری در پیش‌بینی عرض عملیات خاکی دارد.

جدول (۴) بیانگر نتایج حاصل از معیارهای ارزیابی دقت مدل‌های ساخته شده با استفاده از روش رگرسیون و شبکه‌های عصبی مصنوعی است. مقایسه دو شبکه عصبی در پیش‌بینی عرض عملیات خاکی نشان داد که شبکه عصبی MLP با تابع فعال‌سازی تانژانت سیگموئید نسبت به شبکه عصبی RBF با تابع فعال‌سازی تانژانت سیگموئید دارای دقت بیشتر و خطای کمتری بوده و نیز مدل‌های مبتنی بر روش شبکه عصبی منجر به خطای کمتر و مقدار ضریب تبیین بیشتری نسبت به روش رگرسیون شده است.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{oi} - y_{fi})^2}{\sum_{i=1}^n (y_{oi} - \bar{y}_{fi})^2} \quad \text{رابطه (۲)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{oi} - y_{fi})^2}{n}} \quad \text{رابطه (۳)}$$

$$MAE = \frac{\sum_{i=1}^n |y_{oi} - y_{fi}|}{n} \quad \text{رابطه (۴)}$$

$$E\% = \frac{1}{n} \sum \left| \frac{y_{oi} - y_{fi}}{y_{oi}} \right| \times 100 \quad \text{رابطه (۵)}$$

در روابط بالا y_o و y_f به ترتیب مقدار مشاهده شده و برآورد شده پارامتر مورد نظر با شبکه و n تعداد کل داده‌های استفاده شده است. در این پژوهش نوع قاعده آموزشی، تابع انتقال و همچنین تعداد نورون لایه مخفی برای هر شبکه مورد آزمایش قرار گرفت.

جدول ۳- پارامترهای آماری در نتایج واقعی و پیش‌بینی شده عرض عملیات خاکی


پارامتر	میانگین	حداکثر	حداقل	چولگی	کشیدگی
عرض عملیات خاکی مشاهده شده (متر)	۱۲/۸۹	۲۳/۸۴	۶/۵۶	۰/۸۰	۴/۰۴
عرض عملیات خاکی پیش‌بینی شده MLP (متر)	۱۲/۹۰	۲۳/۵۶	۶/۸۷	۰/۵۵	۳/۲۱
عرض عملیات خاکی پیش‌بینی شده RBF (متر)	۱۲/۷۹	۲۲/۴۹	۶/۹۳	۰/۳۵	۲/۸۸
عرض عملیات خاکی پیش‌بینی شده رگرسیون (متر)	۱۶/۱۹	۳۰/۰۹	۸/۲۱	۰/۹۵	۴/۱۴

جدول ۴- نتایج بهترین ترکیب شبکه‌های عصبی و رگرسیون خطی چندگانه در پیش‌بینی عرض عملیات خاکی


نوع روش	ترکیب بهینه شبکه	تابع فعال‌سازی	R^2	RMSE	MAE	E%
MLP	۴-۸-۱	Tang Sig	۰/۶۵	۲/۱۳	۱/۲۶	۱۰/۱۱
RBF	۴-۱۰-۱	Tang Sig	۰/۵۳	۴/۳۷	۳/۴۴	۱۳/۰۶
رگرسیون	-	-	۰/۲۴	۸/۲۸	۵/۵۲	۴۵/۰۰

شکل‌های (۲) و (۳) برای شبکه MLP و RBF ارائه گردیده است که اختلاف بین عرض عملیات خاکی پیش‌بینی شده و مشاهده شده را به خوبی نشان می‌دهد.

برای درک بهتر از وضعیت عملکرد شبکه‌های عصبی مصنوعی، نمودارهای خروجی برای مجموعه الگوهای آموزش، صحت‌سنجی و آزمایش (اعتبارسنجی) در



شکل ۲- مقایسه نتایج واقعی و پیش‌بینی شده با شبکه عصبی MLP در برآورد عرض عملیات خاکی



شکل ۳- مقایسه نتایج واقعی و پیش‌بینی شده با شبکه عصبی RBF در برآورد عرض عملیات خاکی

بحث و نتیجه‌گیری

در این پژوهش کارایی شبکه پرسپترون چندلایه، شبکه تابع پایه شعاعی و رگرسیون چندگانه به‌منظور پیش‌بینی عرض عملیات خاکی جاده‌های جنگلی مورد بررسی قرار گرفت. در ابتدا داده‌های آموزش و آزمون به گونه‌ای تعیین شدند که تمامی ترکیب‌های مختلف سه پارامتر شیب، درجه سختی زمین و بافت در این مجموعه‌ها قرار گیرد. در جدول (۳) پارامترهای آماری عرض عملیات خاکی پیش‌بینی شده با هر سه مدل مورد استفاده آورده شده است که بیانگر عملکرد بهتر شبکه‌های عصبی مصنوعی نسبت به روش رگرسیونی است. برای مدل‌های ساخته

معادله پیش‌بینی عرض عملیات خاکی بر اساس پارامترهای شیب، درجه سختی زمین و بافت خاک به‌صورت زیر بدست آمد (جدول ۵).

$$\begin{aligned} & \text{(Rock 1)} + 3/405 + \text{شیب} = 0/087 \text{ عرض عملیات خاکی} \\ & \text{(بافت 2)} + 1/433 + \text{(بافت 1)} + 2/190 + \text{(Rock 2)} + 1/434 \\ & \text{(بافت 3)} + 0/152 \end{aligned}$$

متغیرهای مستقل در پیش‌بینی عرض عملیات خاکی با استفاده از روش رگرسیونی گام‌به‌گام نشان داد که شیب طبیعی دامنه (0/491) دارای بیشترین همبستگی و بافت خاک (0/258) دارای کمترین مقدار همبستگی است. متغیر نسبت سنگی (0/385) حالت بینابین را داشت (جدول ۶).

جدول ۵- نتایج مدل رگرسیون خطی عرض عملیات خاکی بر اساس پارامترهای شیب، درجه سختی زمین و بافت خاک

(n = 192)

سطح معنی‌داری	R	ضریب ثابت	ضرایب رگرسیون	Beta	F	آماره ← ↓ متغیرها به ترتیب ورود
0/001			0/087	0/476		شیب
0/000			3/405	0/436		Rock 1
0/003	0/244	5/850	1/434	0/160	5/117	Rock 2
0/004			2/190	0/273		بافت 1
0/030			1/433	0/185		بافت 2
0/038			0/152	0/190		بافت 3

جدول ۶- مقدار همبستگی متغیرهای مستقل با عرض عملیات خاکی در رگرسیون

سطح معنی‌داری	r	متغیر
0/000	0/301**	شیب طبیعی دامنه
0/006	-0/270**	نسبت سنگی
0/015	-0/258*	بافت خاک

بافت خاک صورت گرفت که این خود تأییدکننده نقش مهم پارامترهای یاد شده بر عرض عملیات خاکی جاده‌های جنگلی است. بیشتر پژوهشگران زاویه شیب را مهم‌ترین پارامتر مؤثر بر عرض عملیات خاکی دانسته‌اند. در شیب‌های کم مقدار پایداری خاک دانه‌ها نسبت به جابه‌جایی بیشتر از شیب‌های تند است. هرچه شیب تندتر شود ناپایداری خاک بیشتر شده و احتمال لغزش و حرکت آن به طرف پایین دامنه بیشتر می‌شود و در نتیجه عرض عملیات خاکی افزایش می‌یابد. البته با افزایش شیب تا ۶۰ درصد عرض عملیات خاکی افزایش یافته است و در شیب بالای ۶۰ درصد سهم خاک کمتر و سهم صخره بیشتر می‌شود و عرض عملیات خاکی کاهش می‌یابد (Sedlak, 1985; Gorton, 1985; Potocnik, 2003; Parsakho, 2009; *et al.*). افزایش میزان سنگلاخی بودن منطقه از یک سو باعث سختی کار در برش ترانشه خاکبرداری و هزینه بالای خاکبرداری می‌شود و از سوی دیگر به دلیل پایداری بیشتر ترانشه‌ها در این مناطق (میل به عمود شدن در این ترانشه) در کاهش عرض عملیات خاکی مؤثر است (Potocnik, 2003). در ارتباط با تأثیر پارامتر بافت خاک می‌توان گفت خاک‌های رسی با خواص خمیری نسبت به خاک‌های لومی و شنی از پایداری کمتری برخوردارند و این امر باعث میل به افقی شدن ترانشه‌های خاکبرداری و خاکریزی و افزایش فاصله افقی این ترانشه‌های در بافت‌های رسی‌تر و در نتیجه افزایش عرض عملیات خاکی می‌شود (Colorado State Forest Service, 1998; Tooran, 2009).

شبکه عصبی مصنوعی توانست با دقت قابل‌قبول عرض عملیات خاکی را پیش‌بینی کند. نتایج این پژوهش می‌تواند در تعیین حجم عملیات خاکی و به دنبال آن برآورد هزینه‌ها قبل از ساخت جاده در شرایط توپوگرافی جنگل‌های کوهستانی مورد استفاده مهندسان و مدیران قرار گیرد. بررسی کارایی مدل حاضر، در غرب کشور که دارای جنگل‌های کوهستانی با شرایط توپوگرافی متفاوت، درجه سختی بالاتر و ضخامت خاک کمتری نسبت به جنگل‌های شمال کشور دارا است، پیشنهاد می‌شود.

شده RBF، MLP و رگرسیونی به ترتیب مقادیر ضریب تبیین ۰/۶۵، ۰/۵۳ و ۰/۲۴، مقادیر RMSE ۲/۱۳، ۴/۳۷ و ۸/۲۸، مقادیر E% ۱۰/۱۱، ۱۳/۰۶ و ۴۵/۰۰ و مقادیر MAE ۱/۲۶، ۳/۴۴ و ۵/۵۲ تعیین شد. بنابراین با توجه به مقدار معیارهای ارزیابی، هر دو مدل شبکه عصبی مصنوعی نسبت به مدل رگرسیونی دارای خطای کمتر و دقت بالاتری در پیش‌بینی عرض عملیات خاکی بودند. برتری شبکه عصبی نسبت به رگرسیون، ممکن است به دلیل غیرخطی بودن رابطه بین پارامترهای مورد بررسی و عرض عملیات خاکی باشد. همبستگی پایین بین عرض عملیات خاکی و متغیرهای مستقل در مدل رگرسیونی نشان‌دهنده ارتباط نداشتن آن‌ها با همدیگر نیست. در برخی مواقع ممکن است همبستگی غیرخطی بین دو متغیر وجود داشته باشد که به وسیله رگرسیون خطی چندگانه قابل اندازه‌گیری نیست (Chayjan *et al.*, 2007). در مقایسه کارایی دو شبکه عصبی MLP و RBF در پیش‌بینی عرض عملیات خاکی مشاهده شد که منحنی عرض عملیات خاکی بدست آمده از شبکه MLP در مراحل آموزشی، ارزیابی و آزمایشی تطابق بهتری با داده‌های مشاهده شده دارد. همان‌گونه که مشاهده می‌شود در برخی از قسمت‌های منحنی، اندکی اختلاف وجود دارد ولی در کل هم در مرحله آموزش و ارزیابی و هم در آزمایش، پیش‌بینی به واقعیت نزدیک است (شکل-های ۱ و ۲). علاوه بر این، معیارهای اصلی ارزیابی توانایی شبکه عصبی مصنوعی و نیز گزیده‌ای از پارامترهای آماری شامل میانگین، واریانس، حداکثر، حداقل، انحراف از معیار، چولگی و کشیدگی، مقادیر پیش‌بینی شده توسط شبکه MLP را به مقادیر مشاهده شده بسیار نزدیک‌تر نشان می‌دهند که این امر نیز نشان‌دهنده موفقیت شبکه عصبی مصنوعی پرسپترون چندلایه در پیش‌بینی عرض عملیات خاکی با استفاده از سه پارامتر شیب دامنه، نسبت سنگی و بافت خاک است.

در هر سه روش، پیش‌بینی عرض عملیات خاکی با استفاده از تمامی پارامترهای شیب دامنه، درجه سختی زمین و

منابع

1. Bayati, H. and Najafi, A., 2012. Application of artificial intelligence in trees stem volume estimation. *Journal of Renewable Natural Resources Research*, 2(2): 52-59.
2. Bayati, H., Najafi, A. and Abdolmaleki, P., 2013. Comparison between artificial neural network (ANN) and regression analysis in tree felling time estimation. *Iranian Journal of Forest and Poplar Research*, 20(4): 595-607.
3. Blackard, J.A. and Dean, D.J., 1999. Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. *Computers and Electronics in Agriculture*, 24(3): 131-151.
4. Caniani, D., Pascale, S., Sdao, F. and Sole, A., 2008. Neural networks and landslide susceptibility: a case study of the urban area of Potenza. *Natural Hazards*, 45: 55-72.
5. Chayjan, R., Montazer, G.A.T., Hashjin, T., Khoshtaghaza, M.H. and Ghobadian, B., 2007. Prediction of pistachio thermal conductivity using artificial neural network. *Approach International Journal of, Agriculture and Biology*, 9(6): 816-820.
6. Colorado State Forest Service., 1998. Road Construction Standards. Colorado State University Fort Collins, CO.11 p
7. Erdas, O., Acar, H., Tundy, M. and Karaman, A., 1995. Problems and its suggestion of solution interested in forest ergonomics and production, forest roads, transportation of forest products. *Forestry mechanization and cadastral turkey forestry report*, Karadeniz technical university, Faculty of forestry, Published No. 48: 44-79.
8. Ermini, L., Catani, F. and Casagli, N., 2005. Artificial neural network to landslide susceptibility assessment. *Geomorphology*, 66: 327-343.
9. Ghajar, I., Najafi, A., Torabi, S.A., Khomehchiyan, M. and Boston, K., 2012. An adaptive network-based fuzzy inference system for Rock share estimation in forest road construction. *Croatian Journal of Forest Engineering*, 33: 313-328.
10. Gorton, F., 1985. Praxis und Kosten einer landschaftsschonenden Bauausführung von Forststrasse. *Allgemeine Forstzeitung*, 96(9): 241-244.
11. Gumus, S.H., Hulusi, A., Metin, T. and Ayhan, A., 1998. Calculation of cut and fill volume by GIS in forest road projecting. Karadeniz Technical University, Faculty of Forestry, 61080, Trabzon Turkey/ 0061-B1.
12. Hosseini, S.A., Khalilpour, H., Nejad, A.M., Moafi, M. and Foumani, B.S., 2012. Comparing the expenses of forest road cut and fill operations with standard rules (Study Area: Northern Forests of Iran). *European Journal of Experimental Biology*, 2(4): 1023-1028.
13. Joshi, C., Leeuw, J.D., Skidmore, A.K., Duren, I.C.V. and Osten, H., 2006. Remotely sensed estimation of forest canopy density: a comparison of the performance of four methods. *International Journal of Applied Earth Observation and Geoinformation*, 8 (2): 84-95.
14. Kia, S.M., 2014. *Neural Networks in MATLAB*. Kian Publication, Tehran, 402 p.
15. Majnonian, B., Alizadeh, S.M., Darvishsefat, A.A. and Abdi, E., 2011. Evaluating of estimation of cut and fill operations using GIS and field measurement (Case study: Kheiroud forest – Chelir district). *Watershed Management Research Journal (Pajouhesh & Sazandegi)*, 87: 64-69.
16. Melesse, A.M. and Hanley, R.S., 2005. Artificial neural network application for multi-ecosystem carbon flux simulation. *Ecological Modeling*, 189: 305-314.
17. Parsakhoo, A., Hosseini, S.A., Lotfalian, M. and Jalilvand, H., 2009. Influence of hillside gradient on forest road cross section components in a loamy clay soil. *American Journal of Applied Sciences*, 6(6): 1212-1216.
18. Potocnik, I., 2003. Forest road formation width as an indicator of human impact on forest environment. *Ekologia*, 22(3): 298 – 304.

19. R Core Team., 2013. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. <http://www.R-project.org>.
20. Sedlak, O., 1985. Forest road planning, location and construction techniques on steep terrain Logging and transport in steep terrain. FAO Forestry Paper, FAO, Rome.
21. Tan, J., 1992. Planning of forest road networks by a spatial data handling-network routing system. Acta Forestalica Fennica, 227: 1-85.
22. Tooran, A., 2009. Construction Equipment Management (translation). Donyaye No Publication, Tehran, 506 p.
23. Zhang, Z., Zhou, Z., Frenkle, M., Chunduru, R. and Mezzatesta, A., 2000. Real time inversion of array resistivity logging data using dimensional reduction and neural network simulation 70th Ann. Internat. Mtg, Soc. Expl. Geophys, 1802-1805.
24. Zarinkafsh, M. and Seadat Lajevardi, N., 1978. Soil Sciences. Abou Reyhan Press, Tehran, 339 p.

Prediction of forest roadway using artificial neural network and multiple linear regressions

- **S. Peyrov**; M. Sc. Graduate, Faculty of Natural Resources, Tarbiat Modares University, Iran
- **A. Najafi***; Associate Professor, Faculty of Natural Resources, Tarbiat Modares University, Iran
- **S. J. Alavi**; Assistant Professor, Faculty of Natural Resources, Tarbiat Modares University, Iran

(Received: 07- Feb- 2014 Accepted: 29- Apr- 2014)

Abstract

Prediction of roadway is one of the main effective factors on fill and cut slope volume, cost and disturbance in forest road constructions. The objective of this study was to develop models for prediction of forest roadway using artificial neural network (ANN) and multiple linear regression (MLR). For this purpose, 192 cross profiles were measured on the Soordar-Vatashan forest roads. Within each sample, hillside gradient, slope direction, rock share ratio and texture of soil were recorded as the inputs and roadway was recorded as the output. The models were developed by artificial neural network with back propagation learning algorithm, multiple linear regression with stepwise analyses, correlation analyses and independent One-Way ANOVA using MATLAB 7.6.0, R and SPSS 19 software. According to coefficient of determination (R^2), multiple correlation coefficient (r) and root mean square error (RMSE) and percent error, the ANN was more successful than regression model in prediction of roadway. ($p < 0.05$). The R^2 and RMSE, 0.24 and 8.28 for regression, and varied from 0.53 to 0.65 and from 2.13 to 4.37 for ANN, respectively. Results of current research provide a background to design a dynamic model of ANN in forest roadway prediction.

Keywords: Hillside gradient, roadway prediction, rock share, soil texture.