

## مقایسه بین شبکه عصبی مصنوعی و تحلیل رگرسیون در برآورد مدت زمان قطع درخت

هادی بیاتی<sup>۱</sup>، اکبر نجفی<sup>۲\*</sup> و پرویز عبدالمالکی<sup>۳</sup>

۱- دانشجوی کارشناسی ارشد، گروه جنگلداری، دانشکده منابع طبیعی و علوم دریایی دانشگاه تربیت مدرس، نور  
۲\* - نویسنده مسئول، استادیار، گروه جنگلداری، دانشکده منابع طبیعی و علوم دریایی دانشگاه تربیت مدرس، نور.

پست الکترونیک: [a.najafi@modares.ac.ir](mailto:a.najafi@modares.ac.ir)

۳- دانشیار، دانشکده علوم زیستی دانشگاه تربیت مدرس، تهران

تاریخ پذیرش: ۹۱/۸/۱۸

تاریخ دریافت: ۹۰/۹/۱۳

### چکیده

قطع درخت در بین مؤلفه‌های بهره‌برداری، اهمیت زیادی دارد. برآورد تولید تجهیزات جنگلی، بخش مهمی از مدیریت هزینه‌ها در یک واحد جنگلداری است که با کاهش هزینه‌های عملیات همراه است. به عبارت دیگر، هزینه‌های بالای سرمایه‌گذاری در بهره‌برداری جنگل، دلیل خوبی برای تحقیقات مهندسی جنگل و همچنین مدل‌سازی زمان می‌باشد. روشهای زیادی مانند انواع رگرسیون‌ها، منطق فازی، شبکه‌های عصبی و غیره برای پیش‌بینی زمان قطع وجود دارد که به کمک آنها می‌توان به ارتباط منطقی بین زمان قطع درخت و متغیرهای مستقل موجود دست یافت و برای عملیات آینده میزان زمان قطع درخت را پیش‌بینی نمود. در این تحقیق از تحلیل رگرسیون و شبکه‌های عصبی پرسپترون چند لایه و تابع شعاع مدار برای پیش‌بینی زمان قطع درخت در جنگلهای شرکت نکاچوب استفاده شد. به منظور جمع‌آوری داده‌های زمان قطع، از روش مطالعه زمانی پیوسته استفاده شد. بدین منظور تعداد ۸۴ درخت از درختان نشانه‌گذاری شده انتخاب شد و زمان خالص قطع درخت با استفاده از شبکه پرسپترون چندلایه و تابع شعاع مدار، و همچنین روش رایج تحلیل رگرسیون پیش‌بینی گردید. نتایج نشان داد که شبکه عصبی تابع پایه شعاعی نسبت به شبکه عصبی پرسپترون چندلایه دارای دقت بیشتری در برآورد زمان قطع درخت می‌باشد. همچنین مقایسه معیارهای ارزیابی شبکه عصبی مصنوعی با رگرسیون گام‌به‌گام نشان داد که شبکه عصبی MLP و RBF به ترتیب دارای مقدار RMSE ۰/۹۴ و ۰/۸۱ بوده، در حالی که مقدار RMSE مدل رگرسیون ۱/۱۵ می‌باشد.

واژه‌های کلیدی: مهندسی جنگل، مطالعه زمانی، تابع پایه شعاعی، پرسپترون چندلایه، بهره‌برداری جنگل.

### مقدمه

بین مؤلفه‌های بهره‌برداری، قطع درخت به‌عنوان شروع و ابتدای زنجیره کار بهره‌برداری اهمیت زیادی دارد و به‌شدت بر روی مراحل بعدی کار مؤثر می‌باشد (Majnounian et al., 2009). قطع درختان با اهرم موتوری به‌دلایلی از جمله کوهستانی بودن و داشتن شیب نسبتاً زیاد جنگلهای شمال، ناهمسانی و قطر و تاج بزرگ درختان پهن‌برگ از رایج‌ترین شیوه‌های قطع در بیشتر طرحهای جنگلداری شمال ایران می‌باشد (Sarikhani, 2001).

بهره‌برداری جنگل شامل مراحل فنی (قطع، تبدیل، کشیدن، بارگیری و حمل) و اداری است که برای برداشت چوب، فراهم‌سازی عرصه برای زادآوری و برقراری ثبات و بهبود اکوسیستم جنگل در محدوده وسیعی به‌لحاظ زمانی و مکانی صورت می‌گیرد (Heinemann, 2004). اجرای صحیح این عملیات بیانگر مدیریتی کارآمد در جهت دست یافتن به توسعه پایدار در جنگل است. در

(Sessions et al., 2007).

بررسی کارایی و زمان قطع درخت با اره موتوری در جنگلهای کاج شمال امریکا، نشان داد که عوامل مؤثر بر مجموع زمان قطع، به ترتیب اهمیت عبارت بودند از: قطر برابرسینه، فاصله بین درختان و شدت برداشت. همچنین نتایج این تحقیق نشان داد که مجموع زمان قطع درخت شامل زمانهای حرکت به سمت درخت، آماده نمودن محل، انداختن درخت، بینه‌بری و تاج‌بری است که با عوامل قطر برابرسینه و فاصله درختان رابطه مستقیم دارد (Lortz et al., 1997). مطالعه کارایی سیستم قطع با اره موتوری در جنگلهای پهن‌برگ آپالاچی آمریکا نشان داد که قطر برابرسینه و فاصله بین درختان، بیشترین تأثیر را بر روی زمان قطع هر درخت دارند (Wang et al., 2004). بررسی تولید و هزینه سه سیستم بهره‌برداری در جنگلهای آپالاچی مرکزی ویرجینیا نشان داد که عوامل مؤثر بر زمان قطع درخت با استفاده از اره موتوری قطر برابرسینه درخت و فاصله بین درختان می‌باشد (Li et al., 2006). با مقایسه دو سیستم بهره‌برداری شامل قطع درخت با اره موتوری و هاروستر، از لحاظ تولید، هزینه و صدمه به توده باقی‌مانده در جنگل ملی وایمینگ مشخص شد که با افزایش قطر درخت زمان قطع افزایش می‌یابد. این تحقیق منتج به ارائه مدل رگرسیونی برآورد زمان قطع در ارتباط با قطر درخت شد (Rummer & Klepac, 2002). Nikooy (2007) در تحقیقی در جنگلهای اسالم گیلان، مدل ریاضی پیش‌بینی زمان قطع درخت را ارائه نمود که این مدل، تابعی از متغیرهای قطر درخت و فاصله بین درختان قطع‌شونده است. (Behjou et al., 2009). در مطالعه‌ای که در قطعه ۲۳۱ جنگل سفارود انجام دادند به این نتیجه دست یافتند که زمان قطع درخت بیشتر تحت تأثیر قطر درخت و فاصله بین درختان بهره‌برداری شده است. همچنین ضریب تبیین بدست آمده در این مطالعه ۸۴/۵ درصد بود. در ارزیابی بهره‌وری گروه قطع در

برآورد تولید تجهیزات جنگلی، بخش مهمی از مدیریت هزینه‌ها در یک واحد جنگلداری است که با کاهش هزینه‌های عملیات همراه است (Davis & Kellogg, 2005). به عبارت دیگر، هزینه‌های بالای سرمایه‌گذاری در بهره‌برداری جنگل، دلیل خوبی برای تحقیقات مهندسی جنگل و همچنین مدل‌سازی زمان می‌باشد. عامل بسیار مهم در مدل‌سازی زمان در مهندسی جنگل، در نظر گرفتن تمامی عوامل مؤثر در چارچوب تحقیق است، به نحوی که بتواند روابط خطی و غیرخطی بین متغیر وابسته (زمان) و متغیرهای مستقل را دربرگیرد. مطالعه زمانی (Time Study) یک ابزار اصلی مورد استفاده در مطالعه اثرهای عوامل مدیریتی بر روی کارایی سیستم‌های بهره‌برداری است (McDonald, 1999) که در طی سالیان متمادی در محاسبه هزینه‌های عملیات بهره‌برداری مورد استفاده قرار می‌گیرد (Gardner, 1963). مدل در واقع ترکیب مناسبی از عوامل مؤثر بر یک سیستم است که از آن به‌منظور مطالعه سیستم استفاده می‌گردد. متداول‌ترین مدل در مطالعات کار، مدل‌های رگرسیونی چند متغیره هستند که نتیجه آنها یک مدل ریاضی پیش‌بینی زمانهای چرخه کاری است. متغیرهایی که بیشترین تأثیر را در کاهش باقیمانده تغییرات داشته باشند، وارد مدل می‌گردند. امکان برآورد مدت زمان قطع درخت و به‌دنبال آن برآورد هزینه قطع، به مسئولان و مدیران جنگل‌ها امکان تصمیم‌گیری در ارتباط با تعداد نیروی کار، تعداد ماشین‌های مورد نیاز و میزان بودجه لازم با توجه به خروج حجم مشخص در مدت زمان مقرر را میسر می‌سازد. مطالعات بسیاری در ارتباط با مدل‌سازی مدت زمان قطع درخت، در سیستم‌های مختلف بهره‌برداری در داخل و خارج از کشور انجام شده است که در تمامی این مطالعات از روشهای رایج مانند انواع رگرسیون‌ها به‌منظور تهیه مدل زمان‌سنجی استفاده شده است. در جنگلهای طبیعی، قطر درخت عامل بسیار مهم در زمان قطع، سرشاخه‌زنی و بینه‌بری درخت است

از داده‌های سنجش از دور برای پیش‌بینی سطح مقطع و تراکم تنه در جنگلهای گرمسیری جنوب ماداگاسکار استفاده کردند. آنها ارتباط سطح مقطع را با شاخص NDVI (Normalized Difference Vegetation Index) و تابش اندازه‌گیری شده در باند ۳، ۴، ۵ و ۷ سنجنده ETM<sup>+</sup> را با استفاده از ANN بررسی کردند. نتایج این تحقیق نشان داد که رابطه قوی و معنی‌دار ( $r = -0.79$ ) بین اندازه‌گیریهای واقعی و پیش‌بینی شده وجود دارد. (Dekker *et al.* (2001) در آنالیز خطاهای مدل تعرق جنگل با استفاده از شبکه‌های عصبی مصنوعی دریافتند که در صورت استفاده مناسب از شبکه عصبی، این ابزار قادر خواهد بود تا الگویی سیستماتیک را حتی با داده‌های با نویز بالا در تعیین متغیرهای زیست‌محیطی مؤثر در تعرق پیدا کند. (Hasenauer *et al.* (2001) در برآورد مرگ‌ومیر توده‌های نوئل اتریش با استفاده از رگرسیون لجستیک و دو نوع شبکه عصبی مصنوعی به این نتیجه دست یافتند که شبکه عصبی مصنوعی پرسپترون چندلایه و شبکه عصبی Cascade Correlation با الگوریتم یادگیری Resilient پس انتشار در مقایسه با رگرسیون لجستیک دارای دقت بیشتری می‌باشند. (Diamantopoulou (2005) در برآورد حجم پوست درخت کاج بروسیا با استفاده از ۳ نوع شبکه عصبی مصنوعی و ۵ مدل رگرسیون غیرخطی به این نتیجه رسید که بهترین مدل رگرسیون غیرخطی در مقایسه با نتایج شبکه عصبی مصنوعی دارای دقت خیلی پایین‌تری می‌باشد. (Ozcelik *et al.* (2010) در برآورد حجم تنه ۴ گونه کاج بروسیا، کاج جنگلی، نوئل و سدر لبنان در جنگلهای ترکیه با استفاده از شبکه عصبی مصنوعی در مقایسه با ۳ روش رایج دیگر که برای برآورد حجم مورد استفاده قرار می‌گرفته به این نتیجه رسیدند که شبکه عصبی مصنوعی در مقایسه با این ۳ روش دارای خطای کمتری می‌باشد. (Jutras *et al.* (2009) در پیش‌بینی شاخص‌های مورفولوژیکی درختان موجود در خیابانهای

جنگلهای شفارود استان گیلان، تأثیر متغیرهای قطر درخت، فاصله بین درختان، شیب طولی و عرضی بر روی زمان قطع مورد ارزیابی قرار گرفت که مدل رگرسیونی پیش‌بینی زمان قطع درخت بدست آمده تابعی از متغیرهای قطر درخت و فاصله بین درختان بود (Naghdi *et al.*, 2010). در پژوهش (Fathi *et al.* (2011) به‌منظور ارائه مدل قطع درخت در شیوه تک‌گزینی به‌وسیله اره موتوری، مدل ریاضی بدست آمده، تابعی از متغیرهای قطر درخت و فاصله طی شده بین دو درخت بود که این مدل توانست تا حدود ۶۷ درصد تغییرات را نشان دهد.

امروزه به موازات روشهای رایج آماری، روشهای جدیدتری به‌منظور پیش‌بینی بکار گرفته می‌شوند که یکی از آنها شبکه‌های عصبی مصنوعی (Artificial Neural Networks) می‌باشد. با توجه به این که شبکه‌های عصبی از دو ویژگی اساسی یادگیری یا نگاشت‌پذیری براساس ارائه داده‌های تجربی (قدرت و توانایی تعمیم‌پذیری) و ساختارپذیری 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 (Menhaj, 2002). ANNs براساس تشخیص الگو (Pattern Recognition) قادر به مدل‌سازی فرآیندهای غیرخطی می‌باشند (Melesse & Hanley, 2005).

در این راستا مطالعات متعددی نیز در زمینه استفاده از ANNs در پیش‌بینی متغیرهای مختلف جنگل و در بخش‌های مختلف جنگل انجام شده است. از جمله Hilbert & Ostendorf (2001) از شبکه عصبی مصنوعی پیش‌خور (Feed forward) و GIS برای ارزیابی قابلیت اثرهای تغییرات آب و هوایی بر جنگلهای گرمسیری شمال شرقی کوئینزلند استفاده کردند. مدل بدست آمده موفقیت بالایی در تشخیص کلاسه‌های جنگل با ۷۵ درصد صحت پیش‌بینی داشت. (Ingram *et al.* (2005) نیز

تابع پایه شعاعی (Radial Basis Function) در مقایسه با تحلیل رگرسیون به این نتیجه رسیدند که شبکه عصبی مصنوعی در مقایسه با تحلیل رگرسیون دارای دقت بیشتری بوده و همچنین دقت شبکه عصبی RBF نسبت به MLP بیشتر و خطای کمتری در برآورد داشت.

با توجه به قابلیت‌های ذکر شده شبکه عصبی در این تحقیق استفاده از شبکه پرسپترون چندلایه و تابع پایه شعاعی، که از زیرمجموعه‌های روش نوین شبکه عصبی می‌باشند، به منظور مقایسه با روش رایج تحلیل رگرسیون، در تعیین مدل پیش‌بینی زمان قطع درخت مورد آزمون قرار گرفت.

## مواد و روشها

### منطقه مورد مطالعه

این مطالعه در قطعه ۳۲۹ بخش ۲ حوزه آبخیز ۷۵ نکاچوب در مختصات جغرافیایی  $36^{\circ} 30' 50''$  تا  $36^{\circ}$  تا  $15' 31' 36^{\circ}$  عرض شمالی و  $45' 31' 53^{\circ}$  تا  $30' 32' 53^{\circ}$  طول شرقی و در محدوده ارتفاعی ۷۳۰ تا ۷۸۰ متر از سطح دریا، انجام شد. داده‌های کلی مربوط به پارسل مورد مطالعه در جدول ۱ آورده شده است.

جدول ۱- مشخصات عمومی پارسل مورد مطالعه

مساحت (هکتار)	تپ جنگل	تعداد در هکتار	حجم در هکتار	ارتفاع منطقه (متر)	وضعیت پستی بلندی	شیوه برش
۳۹	راش- ممرز	۱۹۳	۳۷۲/۹ مترمکعب	۷۸۰-۷۳۰	هموار	تک‌گزینی

## روش تحقیق

گردید. سپس در زمان عملیات قطع به همراه گروه قطع وارد عرصه شده و زمانهای مربوط به قطع درختان شامل: پیدا کردن (Find)، پاک کردن اطراف درخت (Cleaning)، تعیین جهت افت (Directing)، بُن‌زنی (Under Cut) و بُن‌بری (Back Cut) با استفاده از کرومتر و با دقت یک صدم دقیقه برای زمان‌سنجی مراحل مختلف کار، ثبت گردید. عملیات قطع توسط یک اکیپ دو نفره شامل اره موتورچی و کمک اره موتورچی، مجهز به اره موتوری

شهر مونترال از ایالت‌های کبک کانادا به این نتیجه رسیدند که ۳ مدل از ۷ مدلی که برای پیش‌بینی در نظر گرفته شده بودند دارای دقت قابل قبول می‌باشند و می‌توانند جایگزین روش مرسوم آماربرداری شوند. Karaman & Caliskan (2009) در مطالعه عوامل مؤثر بر زمان قطع درخت به این نتیجه رسیدند که نتایج مدل‌های شبکه عصبی مصنوعی برای شرایط مختلف کاری و زمینی در مقایسه با رگرسیون توانی خیلی بیشتر به واقعیت نزدیک بوده و قابل اعتمادتر هستند. Ghanbari et al. (2009) در برآورد مشخصه تراکم درختان جنگل نتایج نشان داد که توانایی شبکه عصبی در پیش‌بینی تعداد در هکتار خوب بوده و نیز نشان داد که این تکنیک می‌تواند ۶۵ درصد تغییرات تعداد در هکتار جنگل را با استفاده از خصوصیات توپوگرافی پیش‌بینی نماید. Safi Samghabadi (2005) در برنامه‌ریزی چندهدفه جنگل به کمک شبکه‌های عصبی به این نتیجه رسید که این روش قادر است جواب مطلوب را در مسایل تصمیم‌گیری چندهدفی فردی و گروهی با خطای قابل قبولی تولید نماید. Bayati & Najafi (2013) در برآورد حجم تنه درختان با استفاده از دو مدل شبکه عصبی پرسپترون چندلایه (Multi Layer Perceptron) و

به منظور انجام این تحقیق، پس از جنگل‌گردشی و آشنایی با موقعیت منطقه تعداد ۸۴ درخت از درختان نشانه‌گذاری شده انتخاب، اجزای یک چرخه کاری مشخص و سپس زمان اجرای هر قسمت از اجزای آن اندازه‌گیری شد. اطلاعات مربوط به هر درخت شامل: قطر، تعداد درختان اطراف (تا شعاعی برابر با ارتفاع درخت) و فاصله بین دو درخت قطع شده برداشت

استاندارد پس‌انتشار می‌باشد. این شبکه‌ها زمانی که بردارهای آموزشی بسیار زیاد باشند دارای بهترین کارایی می‌باشند (Kia, 2010). معماری اصلی RBF مانند MLP از سه لایه ورودی، پنهان و خروجی تشکیل شده است، اما با این تفاوت که در این نوع شبکه تنها یک لایه پنهان وجود دارد. این لایه پنهان یک انطباق غیرخطی بین فضای ورودی و یک فضا (معمولاً) با بُعد بزرگتر برقرار می‌کند که در آن الگوها به صورت تفکیک‌پذیر خطی در می‌آیند. سرانجام لایه خروجی، جمع وزنی را به همراه یک خروجی خطی تولید می‌کند.

متغیرهای قطر درخت نشانه‌گذاری شده (D)، تعداد درخت اطراف درخت نشانه‌گذاری شده (N) و فاصله بین درختان (L) ورودی‌های شبکه و متغیر زمان قطع به عنوان خروجی شبکه در نظر گرفته شد (شکل‌های ۱ و ۲). در طراحی و اجرای شبکه عصبی در این مطالعه از جعبه ابزار شبکه عصبی مصنوعی نرم‌افزار SPSS 17 استفاده گردید. داده‌ها به دو دسته آموزش (۷۰ درصد کل داده‌ها) و آزمون (۳۰ درصد کل داده‌ها) تقسیم شدند. همچنین با استفاده از جعبه ابزار این نرم‌افزار میزان حساسیت داده خروجی (زمان قطع) نسبت به هریک از متغیرهای مستقل بررسی گردید.

از آنجا که در تعیین تعداد لایه‌های پنهان، انواع الگوریتم‌های آموزش و همچنین تعداد نرون‌ها در هر لایه قاعده مشخصی وجود ندارد، بنابراین الگوریتم‌های آموزش، تعداد لایه‌های لایه پنهان و همچنین تعداد نرون‌های هر لایه نیز با آزمون و خطا تعیین شدند و این روند تا زمانی ادامه یافت که خطای بین داده‌ی برآوردی و داده‌ی واقعی به کمترین حد خود رسید. به منظور ارزیابی دقت شبکه عصبی مصنوعی از معیارهای ضریب تبیین ( $R^2$ )، مجذور میانگین مربعات خطا (RMSE) و درصد مجذور میانگین مربعات خطا (درصد RMSE) (Laar, 1991)، استفاده شد (جدول ۲). مزیت اصلی درصد

اشتیل مدل NS 880 و طول تیغه ۷۵ سانتی‌متر انجام شد. پس از جمع‌آوری و وارد کردن داده‌ها در نرم‌افزار آماری SPSS نرمال بودن توزیع داده‌های موجود در هر قسمت مورد بررسی قرار گرفت که در این مرحله ۱ داده پرت مشاهده و حذف شد. با استفاده از تحلیل رگرسیون چندمتغیره و تکنیک گام‌به‌گام (Norusis, 2000)، مدل ریاضی پیش‌بینی زمان قطع درخت تهیه شد. البته پیش از تهیه مدل، ۳۰ درصد داده‌ها (۲۵ داده) به منظور ارزیابی نتایج رگرسیون کنار گذاشته شد و در تهیه مدل شرکت داده نشدند.

### روش شبکه عصبی

شبکه‌های عصبی از عناصر عملیاتی ساده‌ای ساخته می‌شوند که به صورت موازی در کنار هم عمل می‌کنند. ساختار و عملکرد ANN از مغز انسان تقلید می‌کند و از تعدادی اجزای ساختاری ساده، اما با یک ارتباط پیچیده که به عنوان نرون یا نود شناخته می‌شوند، تشکیل شده‌اند (Strobl & Forte, 2007)، به هر مجموعه از این نرون‌ها یک لایه گفته می‌شود. یک شبکه عصبی معمولاً از سه لایه‌ی ورودی، پنهان و خروجی تشکیل شده است (Dagli, 1994; Wu, 1994).

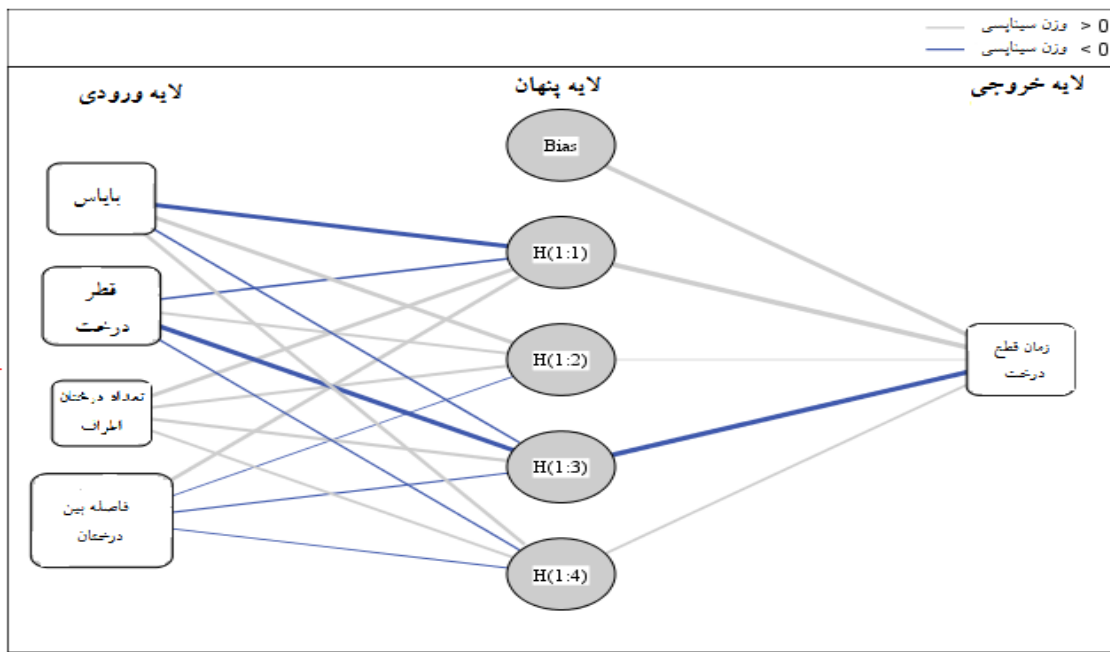
### پرسپترون چندلایه (MLP)

یکی از شبکه‌های پُرکاربرد در منابع طبیعی، شبکه‌های پس‌انتشار می‌باشد. یک شبکه پس‌انتشار با دارا بودن بایاس، یک لایه ورودی و یک لایه خروجی خطی توانایی تخمین زدن هر تابعی با تعداد نقاط ناپیوستگی محدود را داراست (Kia, 2010).

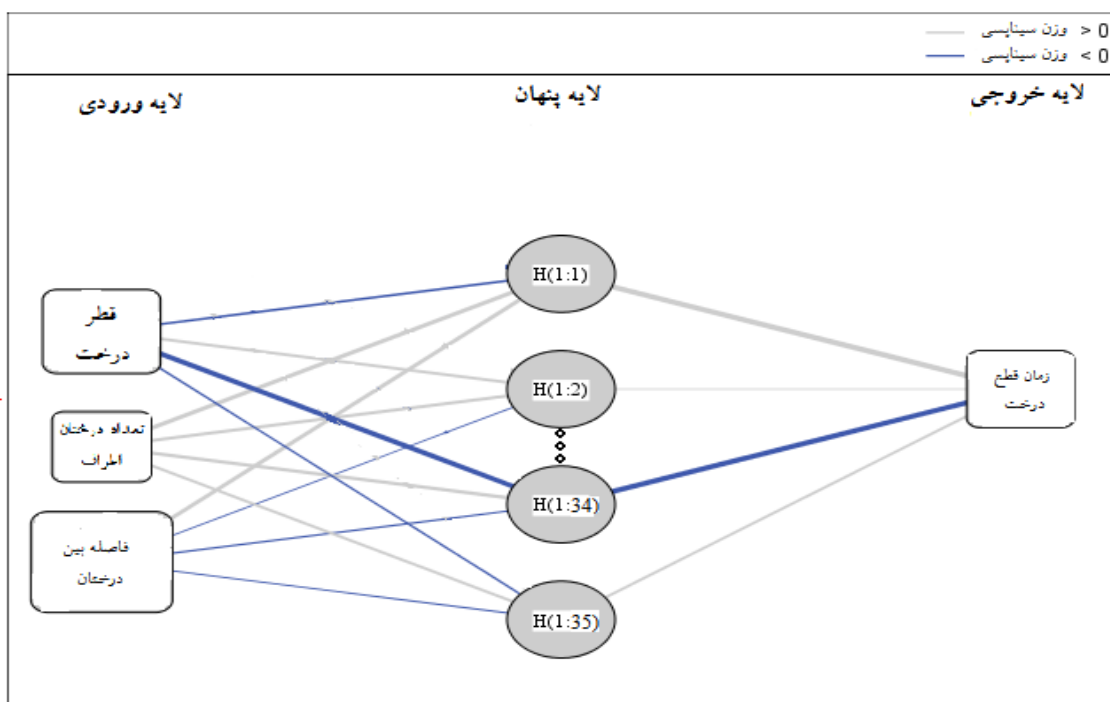
### شبکه عصبی تابع شعاع مدار (RBF)

این نوع شبکه نیاز به نرون‌های بیشتری دارد، اما حسن آن در زمان طراحی کوتاه‌تر آنها نسبت به شبکه‌های

RMSE این است که اجازه مقایسه پیش‌بینی‌های ایجاد شده توسط مدل‌های مختلف را می‌دهد ( Pulido-Calvo *et al.*, 2007).



شکل ۱- ساختار شبکه عصبی مصنوعی MLP طراحی شده



شکل ۲- ساختار شبکه عصبی مصنوعی RBF طراحی شده

میانگین کل زمانهای قطع مشاهداتی و تعداد مشاهدات می باشد.

### نتایج

نتیجه همبستگی نشان داد که زمان خالص قطع بیشترین همبستگی را با قطر برابر سینه (۰/۶۷) و کمترین همبستگی (۰/۴۴) را با تعداد درختان اطراف درخت نشانه گذاری دارد (جدول ۳).

جدول ۲- معیارهای ارزیابی کارایی مدلها	
مدلها	معیار
$RMSE = \sqrt{\frac{\sum (\hat{y}_i - y_i)^2}{n}}$	RMSE
$R^2 = 1 - \frac{\sum (\hat{y}_i - y_i)^2}{\sum \hat{y}_i^2}$	R <sup>2</sup>
$\% RMSE = \frac{RMSE}{\bar{y}_i} \times 100$	درصد RMSE

در روابط فوق  $y_i$ ،  $\hat{y}_i$ ،  $\bar{y}_i$  و  $n$  به ترتیب برابر با مقدار زمان قطع مشاهداتی، زمان قطع پیش بینی شده،

جدول ۳- ضریب همبستگی بین زمان خالص قطع و سایر متغیرها

فاصله بین درختان	تعداد درختان اطراف	قطر برابر سینه	زمان خالص قطع
۰/۵۱	۰/۴۴	۰/۶۷	

که در آن T: زمان خالص قطع به دقیقه، D: قطر درخت به سانتی متر و L: فاصله بین درختان به متر می باشد. جدول ۴ تجزیه واریانس مدل زمان سنجی قطع درخت را نشان می دهد.

با استفاده از تحلیل رگرسیون چندمتغیره و روش گام به گام، مدل زمان سنجی قطع درختان تعیین شد. مدل بدست آمده تابعی از متغیرهای مستقل قطر درخت و فاصله بین درختان بوده و به صورت رابطه ۱ می باشد:

$$T = -1/0.16 + 0/0.62 D + 0/0.27 L \quad \text{رابطه ۱}$$

جدول ۴- تجزیه واریانس مدل زمان سنجی قطع درخت

Sig	F	میانگین مربعات	درجه آزادی	مجموع مربعات	منبع
۰/۰۰۰	۴۰/۱۹۶	۵۸/۷۵	۲	۱۱۷/۵	رگرسیون
		۱/۴۶	۵۵	۸۰/۳۹	باقی مانده
			۵۷	۱۹۷/۸۹	مجموع

رگرسیون و همچنین شبکه های عصبی مصنوعی در برآورد زمان قطع درخت را نشان می دهد.

با توجه به Sig که کمتر از ۰/۰۱ است، پس با اطمینان ۹۹ درصد رابطه رگرسیونی بدست آمده تأیید می شود. جدول ۵ نتایج حاصل از معیارهای ارزیابی روش

جدول ۵- نتایج معیارهای ارزیابی روشها در مدل سازی


روش	ترکیب مدل	تابع فعال سازی لایه پنهان	تابع فعال سازی لایه خروجی	R <sup>2</sup>	RMSE	درصد RMSE
رگرسیون	$T = -1/0.16 + 0/0.62 D + 0/0.27 L$	-	-	۰/۷۷	۱/۲۵	۳۶/۳۳
MLP	۳-۴-۱	TanHyp	Identity	۰/۹۱	۱/۰۱	۲۹/۷۱
RBF	۳-۳۵-۱	Softmax	Identity	۰/۹۶	۰/۸۳	۲۴/۰۴

به منظور اعتبارسنجی مدل، ۲۵ نمونه (۳۰ درصد از کل نمونه‌ها) به طور تصادفی انتخاب و در تعیین مدل وارد نشد. جدول ۶ نتایج حاصل از معیارهای ارزیابی روش


جدول ۶- نتایج معیارهای ارزیابی روشها در مرحله اعتبارسنجی

روش	$R^2$	RMSE	درصد RMSE
رگرسیون	۰/۸۱	۱/۱۵	۳۳/۳۸
MLP	۰/۹۴	۰/۹۴	۲۴/۱۵
RBF	۰/۹۷	۰/۸۱	۲۰/۷۴

شکل‌های ۳ تا ۵ نتیجه اختلاف خطای بین زمان پیش‌بینی شده در مقایسه با زمان واقعی در مرحله اعتبارسنجی برای روش رگرسیون و همچنین شبکه‌های عصبی مصنوعی را نشان می‌دهد.




شکل ۳- مقایسه بین اختلاف خطای بین زمان پیش‌بینی شده در مقایسه با زمان واقعی در روش رگرسیون چند متغیره



شکل ۱- مقایسه بین اختلاف خطای بین زمان پیش‌بینی شده در مقایسه با زمان واقعی در شبکه عصبی MLP





شکل ۲- مقایسه بین اختلاف خطای بین زمان پیش بینی شده در مقایسه با زمان واقعی در شبکه عصبی RBF

تحلیل حساسیت نشان داد که در شبکه عصبی MLP متغیر فاصله بین درختان (۱۰۰ درصد) و تعداد درختان اطراف درخت نشانه گذاری شده (۳۷/۳ درصد) و در شبکه عصبی RBF فاصله بین درختان (۱۰۰ درصد) و تعداد درختان اطراف درخت نشانه گذاری شده (۵۶/۳ درصد) به ترتیب بیشترین و کمترین اهمیت را در پیش بینی زمان قطع درخت دارا می باشند (جدول ۷).

این شکل ها تشخیص چشمی عملکرد روشهای مختلف برآورد زمان قطع درخت را آشکار می سازد. خطوط پیوسته داده های مشاهداتی (واقعی) و خطوط منقطع داده های پیش بینی شده توسط روشها را نشان می دهد. همان گونه که در شکلها مشاهده می شود، شبکه عصبی RBF نسبت به دو مدل دیگر دارای خطای کمتری در پیش بینی زمان قطع می باشد.

جدول ۷- اهمیت متغیرهای مستقل در ۲ شبکه عصبی در پیش بینی زمان قطع درخت

شبهه	متغیر	اهمیت	اهمیت نرمال شده به درصد
MLP	D	۰/۳۲۲	۶۵/۱
	L	۰/۴۹۴	۱۰۰
	N	۰/۱۸۴	۳۷/۳
RBF	D	۰/۳۱۶	۷۲/۳
	L	۰/۴۳۷	۱۰۰
	N	۰/۲۴۶	۵۶/۳

## بحث

عملیات قطع درختان در جنگل با استفاده از اره موتوری تحت تأثیر عوامل بسیار زیادی می باشد. مشکلی که در مطالعات زمان سنجی با آن روبه رو می شویم عدم امکان شناسایی بیشتر این عوامل و کمی سازی بسیاری از آنهاست. اتخاذ تصمیم در منابع طبیعی اغلب با پیچیدگیهای فراتر از روشهای تجربی آماری روبه رو

میزان اهمیت یک متغیر مستقل، اندازه گیری اینکه چقدر داده ی برآورد شده توسط شبکه با مقادیر مختلف متغیر مستقل تغییر می کند، است. متغیری که بیشترین تأثیر را داشته اهمیت ۱۰۰ را گرفته و برای محاسبه اهمیت نرمال شده سایر متغیرها، میزان اهمیت آن را بر میزان اهمیت مهمترین متغیر تقسیم می کنند، که به صورت درصد بیان می شود.

شده توسط شبکه‌های عصبی مصنوعی (MLP و RBF) نسبت به روش رگرسیون چندمتغیره کمتر است.

در این مطالعه مشاهده گردید که شبکه عصبی RBF با یک لایه مخفی (و ۳۵ نرون در لایه مخفی) و تابع فعال‌سازی Softmax و Identity نسبت به شبکه عصبی MLP با یک لایه مخفی (و ۴ نرون در لایه مخفی) و تابع فعال‌سازی TanHyp و Identity در برآورد زمان قطع، دارای قدرت بیشتری می‌باشد که این امر با نتایج Bayati (2013) و Najafi & (2009) و Ghanbari *et al.* (2009) همسو می‌باشد. همچنین نتایج نشان داد که این شبکه ۹۷ درصد تغییرات زمان خالص قطع درخت را پیش‌بینی می‌نماید. علت این امر را می‌توان به تعداد نرون‌های بیشتر در لایه پنهان شبکه RBF نسبت داد، البته این خود موجب پیچیده‌تر شدن این شبکه نسبت به شبکه MLP می‌شود. تحلیل حساسیت شبکه عصبی نشان داد که متغیرهای فاصله بین درختان و قطر درخت در MLP و RBF بیشترین اهمیت را دارا می‌باشند که نتیجه جدول همبستگی بین زمان خالص قطع و سایر متغیرها را تأیید می‌نماید.

استفاده از روش ANNs در پیش‌بینی زمان قطع درخت نسبت به روش رگرسیون، خوب ارزیابی گردید که با مطالعات (Hasenauer *et al.* (2001), Jutras *et al.* (2009), Ingram *et al.* (2005), Dekker *et al.* (2001), Diamantopoulou, Hilbert & Ostendorf (2001), Ozcelik *et al.* (2005), Karaman & Caliskan (2009), Bayati & Najafi و Ghanbari *et al.* (2009) (2010) (2013) مطابقت دارد.

مقایسه نتیجه روش آماری و نتایج شبکه‌های عصبی مصنوعی ارزش رجحان مدل‌های شبکه عصبی را در برآورد زمان قطع درخت نشان می‌دهد. علت تفاوت بین عملکرد بهتر شبکه‌های عصبی مصنوعی در مقایسه با روش‌های آماری را می‌توان در قابلیت تخمین و پیش‌بینی شبکه‌های عصبی مصنوعی با حجم کم داده‌ها جستجو

می‌شود که نیازمند رهیافت‌هایی می‌شود که گاهی اوقات بیشتر ابتکاری است تا اینکه به صورت الگوریتم باشد (Gimblett & Ball, 1995). در این تحقیق و به‌منظور بررسی کارایی شبکه‌های عصبی مصنوعی، اقدام به مقایسه این روش با روش رایج رگرسیون در برآورد زمان قطع درختان گردید. توسعه مدل پیش‌بینی زمان قطع درخت می‌تواند برنامه‌ریزی بهره‌برداران را در برآورد میزان زمان قطع و هزینه‌های آن، بهبود شرایط کار و افزایش بازده کار یاری رساند (Sobhani *et al.*, 2007). بنابراین در این تحقیق سعی شد تا با توسعه مدل پیش‌بینی زمان یک نوبت قطع درخت، اهمیت عوامل تأثیرگذار بر عملیات قطع برای واحد مدیریت برداشت مشخص گردد.

در مطالعات قبلی (Nikooy, 2007; Naghdi *et al.*, 2010; Fathi *et al.*, 2011; Behjou *et al.*, 2009; Sessions *et al.*, 2007; Lortz *et al.*, 1997; Wang *et al.*, 2004; Li *et al.*, 2006; Rummer & Klepac, 2002)، متغیرهای تأثیرگذار بر روی زمان قطع درخت به‌ترتیب اهمیت عبارت بودند از: قطر درخت، فاصله بین درختان، شدت برداشت و نوع گونه. در این مطالعه نیز قطر درخت و فاصله بین درختان، متغیرهای تأثیرگذار در پیش‌بینی زمان قطع درخت توسط مدل رگرسیونی بودند. ارزیابی مدل‌های مختلف به کمک عامل‌های  $R^2$ ، RMSE و درصد RMSE امکان‌پذیر است. این عامل‌ها زمانی می‌توانند ارزش برتری مدل‌ها را تعیین نمایند که بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده محاسبه شوند. توجه به مقادیر  $R^2$ ، RMSE و درصد RMSE مزیت نسبی مدل‌ها را نشان می‌دهد. بیشترین ضریب تبیین معنی‌دار و کمترین میزان خطا، بهترین روش را معرفی می‌نماید. بنابراین ارزش برتری روش‌ها به‌ترتیب RBF، MLP و رگرسیون چندمتغیره با میزان ضرایب تبیین ۰/۹۷، ۰/۹۴، ۰/۸۱ و مقادیر RMSE ۰/۸۱، ۰/۸۱ و ۱/۱۵ و همچنین مقادیر درصد RMSE ۲۰/۷۴، ۲۴/۱۵ و ۳۳/۳۸ تعیین می‌گردد. همانطور که در شکل‌های ۳ تا ۵ نیز مشاهده می‌شود، اختلاف خطای بین زمان قطع درخت پیش‌بینی

در نهایت با توجه به این که این پژوهش در مقیاس کوچک و تنها در مورد کاربرد شبکه عصبی در پیش‌بینی زمان قطع درخت انجام شده، بنابراین پیشنهاد می‌گردد که در سایر مناطق و همچنین از سایر کاربردهای این روش نوین بهره جسته و قابلیت آن در مطالعات جنگل مورد ارزیابی قرار گیرد.

نمود. این در حالیست که عملکرد و دقت روشهای رگرسیونی به شدت از حجم نمونه تبعیت می‌کند و حجم کم نمونه‌ها می‌تواند عامل محدودیت مدل‌های آماری شود. بنابراین در مدل‌های طراحی شده شبکه عصبی مصنوعی کم بودن تعداد نمونه‌ها محدودیت چشم‌گیری ایجاد ننموده است.

### منابع مورد استفاده

#### References

- Bayati, H. and Najafi, A., 2013. Performance comparison artificial neural networks with regression analysis in trees trunk volume estimation. *Forest and Wood Products (Iranian Journal of Natural Resources)*, 66(1) (In Publish).
- Behjou, F.K., Majnounian, B., Dvořák, J., Namiranian, M., Saeed, A., Fegghi, J., 2009. Productivity and cost of manual felling with a chainsaw in Caspian forests. *Journal of Forest Science*, 55(2): 96-100.
- Dagli, C.H., 1994. Artificial neural networks for intelligent manufacturing. *Operating Research Journal*, 6(1): 25 p.
- Davis, C. and Kellogg, L., 2005. Measuring machine productivity with the MultiDat logger: A demonstration on three forest machines, IN: 2005 Annual COFE proceedings, Fortuna, CA, 10 pp.
- Dekker, S.C., Bouten, W. and Schaap, M.G., 2001. Analyzing forest transpiration model errors with artificial neural networks. *Journal of Hydrology*, 246(2): 197-208.
- Diamantopoulou, M.J., 2005. Artificial neural networks as an alternative tool in pine bark volume estimation. *Computers and Electronics in Agriculture*, 48(3): 235-244.
- Fathi, J., Azarnoosh, M.R., Rafatnia, N. and Mirarab, J., 2011. Prediction model of tree felling by chainsaw in selection system (Case study: Namkhaneh District, Kheiroud forest). *Iranian Journal of Forest and Poplar Research*, 19(2): 340-351.
- Gardner, R., 1963. New tools for harvesting. *Pulp and Paper*, 75 p.
- Ghanbari, F., Shataee, Sh., Dehghani, A.A. and Ayoubi, Sh., 2009. Tree density estimation of forests by terrain analysis and artificial neural network. *Journal of Wood & Forest Science and Technology*, 16(4): 25-42.
- Gimblett, R.H. and Ball, G.L., 1995. Neural network architectures for monitoring and simulating changes in forest resources management. *AI Applications*, 9(2): 103-123.
- Hasenauer, H., Merkl, D. and Weingartner, M., 2001. Estimating tree mortality of Norway spruce stands with neural networks. *Advances in Environmental Research*, 5(4): 405-414.
- Heinemann, H.R., 2004. Forest Operation under Mountainous Conditions. In: J. Burley, J. Evans and J. Youngquist, (Eds.). *Encyclopedia of Forest Sciences*, Elsevier Academic Press, Amsterdam, 279-285.
- Hilbert, D.W. and Ostendorf, B., 2001. The utility of artificial neural networks for modeling the distribution of vegetation in past, present and future climates. *Ecological Modeling*, 146(1): 311-327.
- Ingram, J.C., Dawson, T.P. and Whittaker, R.J., 2005. Mapping tropical forest structure in southeastern Madagascar using remote sensing and artificial neural networks. *Remote Sensing of Environment*, 94(4): 491-507.
- Jutras, P., Prasher, S.O. and Mehuys, G.R., 2009. Prediction of street tree morphological parameters using artificial neural networks. *Computers and Electronics in Agriculture*, 67(1): 9-17.
- Karaman, A. and Caliskan, E., 2009. Affective factors weight estimation in tree felling time by artificial neural networks. *Expert Systems with Applications*, 36(3): 4491-4496.
- Kia, M., 2010. Neural network in MATLAB. Kian Rayaneh Sabz Publisher, 229 p.
- Laar, A., 1991. *Forest Biometry*. University of Stellenbosch, Publ. Sponsored by Sappi Forests, 590 p.
- Li, Y., Wang, J., Miller, G. and McNeel, J., 2006. Production economics of harvesting small-diameter hardwood stands in central Appalachia. *Forest Products Journal*, 56(3): 81-86.
- Lortz, D., Kluender, R., McCoy, W., Stokes, B. and Klepac, J., 1997. Manual felling time and productivity in southern forests. *Forest Products Journal*, 47(10): 59-63.
- Majnounian, B., Jourgholami, M., Zobeiri, M., Fegghi, J. and Fathi, J., 2009. Production and costs of tree limbing operation using chainsaw (case study: Namkhaneh district in Kheyrud forest). *J. of Wood & Forest Science and Technology*, 16(4): 43-57
- McDonald, T., 1999. Time study of harvesting equipment using GPS-derived positional data. In proceedings of the forestry engineering for tomorrow, Edinburgh University, Edinburgh, Scotland: 28-30.

- Melesse, A.M. and Hanley, R.S., 2005. Artificial neural network application for multi-ecosystem carbon flux simulation. *Ecological Modeling*, 189(3): 305-314.
- Menhaj, M.B., 2002. *Neural Network Basis*. Amir Kabir Industrial University Publication, Tehran, 715 p.
- Naghdi, R., Nikooy, M., Mohammadi Limaie, S. and Shormage, Y., 2010. Evaluation of felling productivity in Shafarood forest (Guilan province). *Iranian Journal of Forest and Poplar Research*, 18(3): 417-425.
- Nikooy, M., 2007. Optimizing production cost and damage reduction to wood, trees and forest by harvest planning (case study: Asalem forest district area). PhD Thesis, Dept. of Forest Management and Forest Economics, Faculty of Natural Resources, Tehran University, 215p.
- Norusis, M.J., 2000. *SPSS for Windows*, SPSS Inc Press, Chicago, USA.
- Ozcelik, R., Diamantopoulou, M.J., Brooks, J.R. and Wiant, H.V.Jr., 2010. Estimating tree bole volume using artificial neural network models for four species in Turkey. *Journal of Environmental Management*, 91(3): 742-753.
- Pulido-Calvo, I., Montesinos, P., Roldan, J., Ruiz-Navarro, F., 2007. Linear regressions and neural approaches to water demand forecasting in irrigation districts with telemetry systems. *Biosystems Engineering*, 97(2): 283-293.
- Rummer, R. and Klepac, J., 2002. Mechanized or hand operations: which is less expensive for small timber? In: Baumgartner, D.M., Johnson, L.R. and DePuit, E.J., (Eds.). *Small Diameter Timber: Resource Management, Manufacturing, and Markets proceedings from conference held February 25-27, 2002 in Spokane, Washington*, 268 p.
- Safi Samghabadi, A., 2005. Interactive multiple criteria forest planning using artificial neural networks. PhD thesis, Dept. of Forestry, Faculty of Natural Resources and Marine Sciences, Tarbiat Modares University, Noor, Mazandaran Province, I.R. Iran, 156 p.
- Sarikhani, N., 2001. *Forest utilization*. University of Tehran Press, No. 2099, Second Edition, 776p.
- Sessions, J., Boston, K., Murphy, G., Wing, M.G., Kellogg, L., Pilkerton, S., Zweede, J.C., and Heinrich, R., 2007. *Harvesting operation in the Tropics*. Springer-Verlag, Berlin, Heidelberg, 170p.
- Sobhani, H., Ghaffarian, M.R. and Khakzade Rostami, M.J., 2007. Study of the production and cost of tree felling in Patom district at Kheyroudkenar Forest Education and Research Station. *Journal of the Iranian Natural Res*, 60(2): 485-491.
- Strobl, R.O. and Forte, F., 2007. Artificial neural network exploration of the influential factors in drainage network derivation. *Hydrological processes*, 21(22): 2965-2978.
- Wang, J., Long, C., McNeel, J. and Baumgras, J., 2004. Productivity and cost of manual felling and cable skidding in central Appalachian hardwood forests. *Forest Products Journal*, 54(12): 45-51.
- Wu, J.K. 1994. *Neural networks and simulation methods*. Marcel Dekker Inc, New York, 456 p.

## Comparison between artificial neural network (ANN) and regression analysis in tree felling time estimation

H. Bayati <sup>1</sup>, A. Najafi <sup>2\*</sup> and P. Abdolmaleki <sup>3</sup>

1- M.Sc. student of forestry, Faculty of Natural Resources and Marine Sciences, University of Tarbiat Modares, Noor, Iran.

2\*- Corresponding author, Assistant prof., Faculty of Natural Resources and Marine Sciences, University of Tarbiat Modares, Noor, Iran. E-mail: a.najafi@modares.ac.ir

3- Associated prof, Faculty of Biological Sciences, University of Tarbiat Modares, Tehran, Iran.

Received: 03.12.2011

Accepted: 08.11.2012

### Abstract

Tree felling is a most important one among the tree harvesting components. Production estimation of forest equipments is an important part of cost management in forestry operational units which is associated with reduction of the operating expenses. In other words, the high cost of investment in forest utilization, is a good reason for forest engineering research and modeling time. Many techniques such as regression, fuzzy logic, neural networks, etc. are utilized to estimate trees felling time. They make a logical connection between the tree felling time and the independent variables and could be used to predict the tree felling time for the future operations. In this study the regression analysis, two neural network models, multi-layer perceptron (MLP) and radial basis function (RBF) were used to predict the trees felling time in the cutting operations of the Neka Choob Co. In order to collect the felling time data, the time continuous study method was applied. For this purpose, 84 trees were selected from the marked stands and the net felling time was estimated, using the Multi Layer Perceptron and Radial Basis Function and also by the common method of linear regression analysis. The results showed that the Radial Basis Function network provided more accurate results in estimating the net tree felling time than the MLP neural network. Comparing the evaluation criteria of ANN with the stepwise regression methods, showed that MLP and RBF neural networks had RMSE value of 0.94 and 0.81, respectively whereas the RMSE value of the regression model was 1.15.

**Key words:** Forest engineering, time study, radial basis function, Multi Layer Perceptron, forest harvesting