

## کارایی روش شبکه عصبی مصنوعی در برآورد موجودی سرپای توده‌های جنگلی

محمود بیات<sup>۱\*</sup>، منوچهر نمیرانیان<sup>۲</sup>، محمود امید<sup>۳</sup>، آرمان رشیدی<sup>۴</sup> و سجاد بابایی<sup>۵</sup>

\*- نویسنده مسئول، استادیار پژوهش، مؤسسه تحقیقات جنگلها و مراتع کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

پست الکترونیک: mbayat@rifr-ac.ir

۲- استاد، گروه جنگل‌داری و اقتصاد جنگل، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

۳- استاد، گروه مهندسی ماشین‌های کشاورزی، دانشگاه تهران، کرج، ایران

۴- کارشناس ارشد جنگل‌داری و اقتصاد جنگل، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

۵- دانشجوی کارشناسی ارشد جنگل‌داری و اقتصاد جنگل، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران

تاریخ پذیرش: ۹۴/۰۶/۲۵

تاریخ دریافت: ۹۳/۱۱/۲۴

### چکیده

به‌طور کلی برای اداره و بهره‌برداری بهینه و پایدار از جنگل، آگاهی از موجودی حجمی جنگل و تولید آن ضروریست. برآورد دقیق موجودی حجمی به روش‌های متداول به‌طور عموم مستلزم وقت و هزینه زیادی است و گاهی نیز دارای دقت کافی نیست. یکی از روش‌های نوین در برآورد مشخصه‌های کمی جنگل استفاده از الگوریتم شبکه عصبی مصنوعی است که با الگوبرداری از شبکه عصبی مغز انسان، با اجرای فرآیند آموزش روابط درونی بین داده‌ها را استخراج می‌کند و در موقعیت دیگر تعمیم می‌دهد. در پژوهش پیش‌رو از داده‌های ۲۵۸ قطعه‌نمونه دائم که در بخش گرازین به وسعت ۹۳۴/۲۴ هکتار به‌طور منظم- تصادفی مستقر شده بودند، استفاده شد. پس از رفع نواقص آماری و حذف داده‌های پرت، ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای آزمون شبکه استفاده شد. پس از استاندارد کردن داده‌ها با استفاده از داده‌های سری آموزش، شبکه عصبی با الگوریتم پس‌انتشار ایجاد شد. همچنین با استفاده از داده‌های سری آموزش، رابطه رگرسیونی بین داده‌های حجم و پارامترهای تعیین‌کننده آن بررسی شد. به‌منظور ارزیابی نتایج دو روش از داده‌های سری آزمون و از معیارهای  $RMSE$ ،  $MAE$  و  $R^2$  استفاده شد. نتایج نشان‌دهنده دقت بیشتر برآوردهای مدل شبکه عصبی (متر مکعب در هکتار  $RMSE=۱/۰۰۶$ ، متر مکعب در هکتار  $MAE=۰/۶۹$  و  $R^2=۰/۹۸$ ) در مقایسه با برآوردهای مدل رگرسیونی ( $RMSE=۲/۵$   $m^3/ha$ ،  $MAE=۰/۹۵$   $m^3/ha$  و  $R^2=۰/۸۵$ ) بود. بیشتر بودن ضریب تعیین به‌دلیل زیاد بودن داده‌ها و رابطه منطقی بین داده‌های ورودی و خروجی بود.

واژه‌های کلیدی: بخش گرازین، شبکه عصبی مصنوعی، مدل‌های رگرسیونی، موجودی سرپای توده.

### مقدمه

جنگل به‌دست می‌آید، بنابراین در یک برنامه‌ریزی دقیق، دانستن موجودی سرپا (حجم)، پراکنش تعداد در طبقات قطری و ساختار گونه‌ای جنگل الزامی است (Marvie-Mohadjer et al., 2009; Bayat et al., 2013a). رویش حجمی توده‌های جنگلی اساس تعیین میزان امکان برداشت

به‌طور کلی برای اداره و بهره‌برداری بهینه و پایدار از جنگل یکی از اطلاعات اساسی و ضروری، دانستن میزان موجودی (حجمی و تعداد) جنگل و تولید آن است. در واقع، برنامه‌ریزی آینده براساس آمار و اطلاعاتی است که از

نمی‌توان به راه‌حل‌های منطقی دست یافت. آماربرداری جنگل شرایط فعلی جنگل را با استفاده از روش‌های آماربرداری صددرصد و یا نمونه‌برداری با قطعات نمونه موقت و یا دائمی ارزیابی می‌کند ( Zobeiri, 2008; Namiranian, 2010; Bayat et al., 2015). این اطلاعات در ترکیب با مدل‌های رگرسیونی و شبکه عصبی مصنوعی جنگل، برای پیش‌بینی توسعه آینده جنگل (رویش حجمی و غیره) و همچنین برای جلوگیری از بهره‌برداری بیشتر از حد و دنبال کردن توسعه پایدار جنگل مهم هستند ( Pukkala, 2015; Bourque & Bayat., 2009). استفاده از توابع رگرسیونی یکی از این روش‌ها است. زمانی که از توابع رگرسیونی برای ارایه مدل‌های رویش و محصول‌دهی استفاده می‌شود، نیاز به یک سری مدل نظری یا تجربی به‌عنوان پیش‌فرض است که استخراج مدل‌های تجربی (رگرسیونی) به‌طور عام مشکل است و این مدل‌ها هنوز به‌خوبی شناخته نشده‌اند (Farshad Far, 2002).

یکی از روش‌هایی که امروزه در حل مسائل مختلف مهندسی جنگل کاربرد زیادی یافته است، شبکه‌های عصبی مصنوعی است. ارتباط حجم و قطر، سطح مقطع، ارتفاع، شیب، جهت و فاصله بین درختان به‌طور موفقیت‌آمیزی با استفاده از این روش مدل‌سازی شده است. در مناطق دیگر دنیا هم استفاده از شبکه عصبی مصنوعی در مدل‌سازی رشد و محصولات جنگل رایج شده است و در بعضی از موارد یا به‌طور تنها و یا همراه با مدل‌های دیگر بررسی شده است. در زمینه‌های مختلف علوم جنگل در مورد استفاده از روش شبکه عصبی مصنوعی، مطالعات مختلفی انجام شده است که از جمله این پژوهش‌ها می‌توان به استفاده از مدل‌های شبکه عصبی به‌عنوان یک ابزار تصمیم‌گیری در بررسی تخریب جنگل و پیش‌بینی مراحل تخریب آن اشاره کرد (Jahani et al., 2016). کاربرد شبکه عصبی برای برآورد حجم تنه درختان، مدل‌سازی زمان چوبکشی با استفاده از شبکه عصبی (Naghdi & Ghajar, 2012) و کاربرد شبکه عصبی برای شناسایی توده‌های جنگلی مستعد در معرض خط باد (Hanewinkela et al., 2004) نیز از جمله پژوهش‌های

یا برش سالانه در برنامه‌ریزی و مدیریت بهره‌برداری چوب از جنگل به‌حساب می‌آید. رویش حجمی یک توده جنگلی عبارت از مقدار حجم چوبی است که درختان یک جنگل در طی یک زمان معین تولید می‌کنند. علم و فن آماربرداری جنگل قادر است اطلاعات مناسبی را برای اجرای یک جنگل‌شناسی همگام با طبیعت در اختیار ما بگذارد (Zobeiri, 2011). حجم جنگل یکی از مشخصه‌های پرکاربرد در این روش است که می‌تواند در مواردی مانند حاصلخیزی و روند بهبود یا تخریب رویشگاه، میزان مجاز برداشت، میزان برداشت و مبنای خرید و فروش به مدیریت جنگل کمک کند. در این رابطه هرچه حجم برآوردشده دقیق‌تر باشد، نتایج به‌دست‌آمده نیز دقیق‌تر و معتبرتر خواهد بود. برآورد دقیق حجم به روش‌های متداول مستلزم صرف وقت و هزینه زیادی است و گاهی نیز دارای دقت کافی نیست با توجه به پیچیده بودن عامل‌های مؤثر در تعیین حجم، ضرورت ایجاد مدل برای پیش‌بینی‌های مورد نظر بیشتر نمایان می‌شود. از مهم‌ترین عامل‌هایی که مدل‌سازی را توجیه می‌کند کاربرد مدل برای مدیریت بهتر جنگل است. مدل‌های ایجادشده میزان حجم جنگل و رویش و عامل‌های مؤثر بر آنها را مشخص می‌کنند و بهترین گزینه را ارایه می‌دهند (Bayat et al., 2013b). در برخی مواقع به کمک مدل‌ها می‌توان آینده جنگل را نیز پیش‌بینی کرد (Jalilvand, 2003). تجزیه و تحلیل سیستمی رویکردی است که اندیشمندان از سه دهه قبل برای برخورد با مشکلات و پیش‌بینی حوادث از آن سود برده‌اند (Hokka, 1999). از آنجایی که جنگل یک اکوسیستم پیچیده است که خود به شکل یک نظام عمل می‌کند و با چنین نظامی نمی‌توان با روش آزمون و خطا عمل کرد (Bayat et al., 2014a)، باید تمام سامانه‌ها به‌طور یک سامانه در حل مشکلات ایجاد شوند نتیجه تجزیه و تحلیل سیستمی، مدل‌سازی است که به‌دلیل تحول و تکامل روابط رگرسیونی توسط انسان و همچنین نسل رایانه‌ها، به‌ویژه از نسل چهارم تحول زیادی پیدا کرده است. چه‌بسا امروزه در بسیاری از طرح‌ریزی‌ها و سیاست‌ها بدون مدل‌سازی و شبیه‌سازی

پژوهش پیش‌رو بررسی کارایی روش شبکه عصبی مصنوعی برای برآورد موجودی سرپای توده‌های جنگلی و عامل‌های تعیین‌کننده آن است. بدین‌منظور از این روش برای مدل‌سازی موجودی سرپا استفاده شد و نتایج آن با روش‌های متداول (رگرسیون) مقایسه شد.


### مواد و روش‌ها

#### منطقه مورد مطالعه

بخش گرازین با وسعت ۹۳۴/۲۴ هکتار سومین بخش از مجموعه جنگل‌های تحت مدیریت دانشکده منابع طبیعی دانشگاه تهران است که در هفت کیلومتری شرق نوشهر قرار دارد. در سیستم اقلیمی دومارتن، بخش گرازین با داشتن ضریب خشکی معادل ۸۲/۶، دارای اقلیم مرطوب سرد نوع ب است (Etemad, 2002). شکل ۱ منطقه مورد مطالعه و شبکه آماربرداری را نشان می‌دهد.

انجام‌شده دیگر در این زمینه هستند. Ghanbari و همکاران (۲۰۰۹) به بررسی امکان به‌کارگیری روش شبکه عصبی مصنوعی برای پیش‌بینی پراکنش مکانی تعداد در هکتار جنگل (تراکم) و تهیه نقشه پیوسته آن در جنگل شصت‌کلاته گرگان با استفاده از خصوصیات اولیه و ثانویه توپوگرافی مدل رقومی زمین با دقت ارتفاعی ۱۰ متر پرداختند. در این پژوهش رابطه بین تعداد در هکتار جنگل و خصوصیات توپوگرافی با استفاده از دو شبکه عصبی مصنوعی تابع پایه شعاعی (Radial Basis Function/RBF) و چندلایه پرسپترون (Multilayer Perceptron/MLP) تجزیه و تحلیل شد. نتایج نشان داد که شبکه تابع پایه شعاعی نسبت به شبکه چندلایه پرسپترون دارای دقت بیشتری بود.

با توجه به توضیحات ارائه‌شده در مورد قابلیت‌های شبکه عصبی مصنوعی، در این پژوهش، از این روش برای برآورد حجم درختان استفاده شد و دقت آن با دو روش توأم و گام‌به‌گام رگرسیون چندمتغیره بررسی شد. هدف از



شکل ۱- منطقه مورد مطالعه و شبکه آماربرداری بخش گرازین جنگل خیرود

نحوه پراکنش و اندازه‌گیری در قطعات نمونه دائم در سال ۱۳۸۲ به کمک یک شبکه آماربرداری مستطیلی به ابعاد  $200 \times 150$  متر (الگوی دستگاه اجرایی) با یک شروع تصادفی، ۲۵۸ قطعه نمونه دائمی دایره‌ای شکل به مساحت ۱۰ آر به‌طور منظم در سطح بخش پراکنده شد. با توجه به جهت، شیب و تغییر ارتفاع عمومی منطقه مورد نظر، عرض شبکه در جهت شرق-غرب و طول آن در جهت شمال-جنوب در نظر گرفته شد. در داخل هر قطعه نمونه، قطر برابر سینه تمام درختان زنده که در ارتفاع برابر سینه قطری بزرگتر از  $7/5$  سانتی‌متر داشتند، به کمک خط‌کش دوبازو اندازه‌گیری شد و مقادیر آنها در طبقه‌های یک سانتی‌متری در فرم‌های آماربرداری به تفکیک گونه یادداشت شد. محل اندازه‌گیری قطر برابر سینه درختان با رنگ قرمز مشخص شد و زاویه هر یک از درختان نسبت به مرکز قطعه نمونه برداشت شد. با توجه به ناهمسال بودن بیشتر توده‌های این بخش، برای تهیه منحنی ارتفاع، در هر قطعه نمونه قشورترین و نزدیک‌ترین درخت به مرکز قطعه نمونه انتخاب شد و قطر برابر سینه و ارتفاع آن اندازه‌گیری شد.

رگرسیون

مراحل استفاده از رگرسیون چندگانه که در این پژوهش استفاده شده است به شرح زیر است:

مرحله اول) شناسایی متغیرها برای تشکیل مدل در قدم اول متغیر وابسته و متغیرهای مستقل برای تشکیل معادله شبکه عصبی و رگرسیون شناسایی شدند. در این مدل متغیرهایی که برای پیش‌بینی متغیر مورد نظر به‌کار می‌رود متغیر مستقل و خود متغیر مورد نظر را متغیر وابسته می‌گویند. در این پژوهش متغیرهای مستقل کمی و کیفی شامل قطر، ارتفاع کل درخت، شیب و جهت و متغیر وابسته حجم بود.

مرحله دوم) جمع‌آوری داده‌ها

داده‌ها در مدل‌سازی رگرسیون و شبکه عصبی از طریق مشاهده و عملیات میدانی جمع‌آوری شد. در پژوهش پیش‌رو از داده‌هایی که از آماربرداری با قطعات نمونه ثابت

در سال ۹۱ بازیابی شده بود، برای آرایه مدل‌ها استفاده شد. مرحله سوم) تعیین رابطه بین متغیرهای مستقل و وابسته این مرحله یکی از مهم‌ترین مراحل در مدل‌سازی است. در واقع در این مرحله ماهیت رابطه بین متغیرهای مستقل و وابسته تعیین می‌شود و مشخص می‌شود که در صورت داشتن همبستگی، این متغیرها دارای چه نوع رابطه‌ای هستند. مانند اینکه آیا رابطه حاکم خطی یا غیرخطی است.

مرحله چهارم) برآورد مشخصه‌های مدل

در این مرحله با استفاده از داده‌های به‌دست‌آمده از نمونه‌ها، متغیرهایی که در تشکیل مدل بسیار مهم هستند، تعیین شدند. از آنجایی‌که از روش رگرسیون‌گیری چندمتغیره استفاده شد، برای انجام محاسبات در پژوهش پیش‌رو از نرم‌افزار SPSS17 استفاده شد و رگرسیون گام‌به‌گام برای برآورد ضرایب مدل به‌کار رفت.

مرحله پنجم) ارزیابی مفروضات مدل رگرسیونی چندگانه

رگرسیون چندگانه دارای مفروضات بسیاری است که باید با استفاده از آزمون‌های مناسب، فرضیه‌ها بررسی شوند. به‌عنوان مثال می‌توان نمودار باقی‌مانده‌ها را نام برد که چنانچه مفروضات صدق نکند، باید روند مدل‌سازی دوباره بررسی شود تا بتوان مدل صحیحی را آرایه داد. در پژوهش پیش‌رو نیز از نمودار باقی‌مانده‌ها استفاده شد.

شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی چندلایه پیش‌خور از یک لایه ورودی، یک یا چند لایه مخفی و یک لایه خروجی تشکیل شده است که به‌طور معمول به آن شبکه عصبی چندلایه پرسپترون گفته می‌شود. در این شبکه ارتباط میان نرون‌ها و تنظیم وزن‌ها از قانون‌های یادگیری پیروی می‌کند. روش‌هایی که برای تنظیم وزن‌ها و آریبی‌ها (مقادیر ثابتی که با وزن‌ها جمع می‌شوند) برای دست‌یابی به مقدار معلوم اتخاذ می‌شوند، قانون‌های یادگیری نام دارند. این قانون‌ها در واقع الگوریتم‌های ریاضی پیچیده‌ای هستند که در نهایت وزن‌های شبکه را برای تولید خروجی بهینه، تنظیم می‌کنند. هر شبکه برای به‌وجود آمدن به دو سری داده نیازمند است: سری آموزش و سری آزمون. در حدود ۸۰ درصد از داده‌ها

در الگوریتم آموزش پس‌انتشار است (رابطه ۲) به دست می‌آید:

$$f(\text{net}) = \frac{1}{1 + \exp(-\text{net})} \quad \text{رابطه (۲)}$$

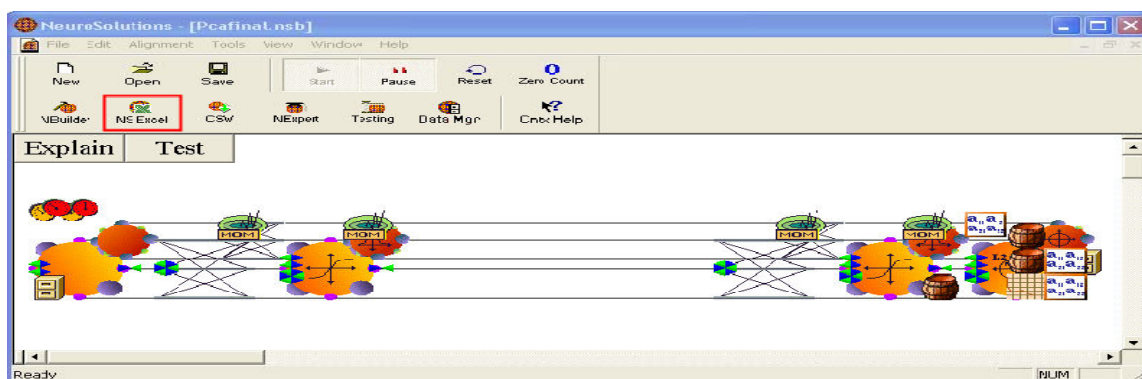
عمل تنظیم وزن‌ها طی فرایند یادگیری آنقدر تکرار می‌شود تا یکی از عامل‌های محدودکننده چرخه به دست بیاید. از جمله این عامل‌ها می‌توان به بیشینه تعداد تکرار، کمینه خطای مطلوب و حداکثر زمان یادگیری اشاره کرد.

برای توسعه مدل‌های ANN کلیه شبکه‌های بررسی شده در نرم‌افزار NeuroSolution نسخه ۵ طراحی و اجرا شد. برای جلوگیری از آموزش بیشتر از حد شبکه که اغلب باعث یادگیری نامناسب مدل می‌شود باید از تکرار بیشتر یادگیری جلوگیری گردد. با اجرای نرم‌افزار NeuroSolution صفحه‌ایی مطابق شکل ۲ ظاهر می‌شود. این صفحه، محیط اصلی برنامه را نشان می‌دهد.

صرف آموزش و بقیه صرف آزمون شبکه می‌شود. یکی از متداول‌ترین الگوریتم‌های یادگیری شبکه‌های عصبی الگوریتم پس‌انتشار خطا است که به‌ویژه در مطالعات جنگل و تعیین حجم کاربرد زیادی دارد. در این روش ابتدا وزن‌های تصادفی به هر نرون داده می‌شود و براساس آنها خروجی محاسبه می‌شود. سپس براساس اختلاف میان خروجی به‌دست‌آمده و خروجی واقعی، وزن‌ها به سمت عقب (از خروجی به سمت ورودی) تنظیم می‌شوند. در این الگوریتم ارتباط میان نرون‌ها توسط ماتریس وزن‌ها ( $W_i$ ) برقرار می‌شود. ورودی خالص هر نرون تابعی از ماتریس وزن‌ها و اطلاعات رسیده به آن نرون ( $x_i$ ) است و از رابطه ۱ به دست می‌آید.

$$\text{net} = \sum_{i=1}^n W_i x_i + \theta \quad \text{رابطه (۱)}$$

که در آن  $\theta$  وزن اریبی و  $\text{net}$  خروجی هر نرون است که با استفاده از تابع تبدیل سیگموئید که رایج‌ترین تابع محرک




شکل ۲- مدل شبکه ANN سیستم جداسازی در نرم‌افزار NeuroSolutions

براساس نیاز، نوع شبکه و ویژگی‌های آن را مشخص می‌کند. راهنمای گام‌به‌گام NeuralExpert برای افراد مبتدی مناسب است. در این حالت نیازی به شناخت شبکه‌های عصبی وجود ندارد و براساس مسئله‌ای است که قرار است حل شود (مانند طبقه‌بندی، پیش‌بینی، تخمین تابع و خوشه‌بندی). تنها کافی است نوع مسئله و داده‌های مربوطه

NeuroSolutions بر مبنای داده‌ها و ویژگی‌های مورد نظر، دو راهنمای گام‌به‌گام (Wizard) برای ایجاد شبکه‌های عصبی دارد. یکی از این راهنماهای گام‌به‌گام NeuralBuilder است که برای افراد حرفه‌ای است. برای کلیه مدل‌های ایجادشده در این پژوهش از این راهنمای گام‌به‌گام استفاده شد. در این راهنمای گام‌به‌گام طراح

مطابق شکل ۳ مراحل زیر به اجرا در می‌آید: الف) به کمک گزینه‌های موجود در زیرمنوی Tag Data متغیرهای ورودی که شیب، جهت، قطر و ارتفاع هستند و متغیر خروجی که حجم به متر مکعب است، به برنامه معرفی می‌شود. همچنین عمل تقسیم داده‌های آموزشی، آزمایشی و اعتبارسنجی در این زیرمنو انجام می‌شود. ب) با کاربرد گزینه‌های زیرمنوی Preprocess Data می‌توان عملیات پیش‌پردازشی از جمله توزیع تصادفی داده‌ها برای آموزش بهتر و جلوگیری از حفظ کردن الگوی داده‌ها را انجام داد. پ) در مرحله بعد نوع ANN تعیین می‌شود. در زیرمنوی Creat/Open Network می‌توان یا بر مبنای هدف یا مسئله مورد نظر از شبکه‌های عصبی پیشنهادی برنامه استفاده کرد و یا به طراحی شبکه عصبی دلخواه اقدام کرد. شبکه طراحی شده در فایل ذخیره می‌شود. اگر از قبل شبکه تعریف شده باشد، می‌توان دوباره فایل مربوطه را فراخوانی کرد. ت) به کمک گزینه‌های موجود در زیرمنوی Train Network عمل آموزش ANN انجام می‌گیرد. ج) گزینه‌های زیرمنوی Test Network برای آزمون کارایی یا عملکرد شبکه استفاده می‌شود.

به برنامه وارد شوند. راهنمای گام‌به‌گام NeuralExpert به‌طور هوشمندانه‌ای اندازه و ساختار شبکه‌ای را که راه حل خوبی ارائه می‌دهد، انتخاب می‌کند. برخی از متداول‌ترین معماری‌های شبکه عصبی قابل استفاده در این برنامه عبارتند از: MLP، Modular، PCA، RBF، SOM و SVM. بهترین روش برای ایجاد مدل‌های شبکه عصبی از طریق داده‌هایی که در محیط اکسل قرار دارند، کاربرد NeuroSolution for Excel است. این برنامه الحاقی عمل ورود و خروج داده‌ها به شبکه عصبی NeuroSolution را با سهولت و توان بیشتر امکان‌پذیر می‌سازد. مزیت‌های دیگر هم برای مبتدی‌ها و هم حرفه‌ای‌ها این است که امکان انجام هر کاری از جمله انجام انواع پیش‌پردازش‌ها در داده‌ها، طراحی شبکه‌های عصبی و ایجاد گزارش نتایج، تنها از طریق محیط Excel فراهم می‌شود. برای کار در محیط اصلی NeuroSolution و NeuroSolution for Excel مطابق شکل ۲ توسط NS Excel ارتباط بین نرون‌ها برقرار می‌شود. در این حالت مطابق شکل ۳ منویی تحت عنوان NeuroSolution به برنامه Excel اضافه می‌شود. پس از این‌که داده‌های به‌دست آمده از تبدیل PCA به محیط Excel وارد شد،



شکل ۳- نمایی از محیط NeuroSolution for Excel و مراحل آموزش ANN

داده‌ها به دو سری آموزش و آزمون تقسیم شوند. نکته مهم

همان‌طور که بیان شد، در روش شبکه عصبی ابتدا باید

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (v_{Si} - \hat{v}_S)^2} \quad \text{رابطه (۳)}$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |(v_{Si}) - (v_S)| \quad \text{رابطه (۴)}$$

$$1 - \frac{\sum_{i=1}^n (v_{Si} - \hat{v}_S)^2}{\sum_{i=1}^n (v_{Si} - \bar{v}_S)^2} R^2 = \quad \text{رابطه (۵)}$$

که در آنها:  $v_{Si}$  مقدار حجم مشاهده شده،  $v_S$  مقدار حجم برآورد شده،  $\bar{v}_S$  میانگین حجم مشاهده شده و  $\hat{v}_S$  میانگین حجم برآورد شده است.

### نتایج

تعداد کل مشاهدات در دسترس برای مدل ۶۹۷۲ اصله درخت بود که ترکیب گونه‌ای آن به شرح زیر بود: راش ۲۳۶۰ اصله، مرمر ۳۲۹۶ اصله، بلندمازو ۳۵۶ اصله، پلت ۲۷۷ اصله، شیردار ۲۰۲ اصله، نمدار ۱۰۸ اصله، ملج ۲۴ اصله و گونه‌های دیگر چهار اصله. تعداد مشاهدات در دسترس برای مدل رویشی ارتفاع ۵۲۵ جفت داده قطر و ارتفاع بود. سطح مقطع توده و تعداد در هکتار درختان در قطعه نمونه بسیار متغیر بود (جدول ۱). دامنه قطری درختان بین ۷ تا ۱۸۸ سانتی متر بود.

در انتخاب این داده‌ها آن است که باید سعی شود این دو سری داده از نظر پارامترهای میانگین و انحراف معیار به هم نزدیک باشند که این مورد با سعی و خطا به دست می‌آید. با در نظر گرفتن این نکته، ۸۰ درصد داده‌ها به عنوان داده‌های آموزش و ۲۰ درصد باقی‌مانده به عنوان داده‌های آزمون شبکه انتخاب شدند. نکته مهم دیگر نرمال کردن داده‌ها قبل از ورود به شبکه است. وارد کردن داده‌ها به طور خام باعث کاهش سرعت و دقت شبکه می‌شود. در پژوهش پیش‌رو به منظور اجتناب از چنین شرایطی و به منظور یکسان کردن ارزش داده‌ها برای شبکه و نیز به دلیل طبیعت تابع تبدیل سیگموئید از نرم‌افزار NeuroSolutions 5 استفاده شد که نرمال‌سازی را بین ۰/۹ و -۰/۹ انجام می‌دهد. پس از آماده سازی داده‌ها، از نرم‌افزار NeuroSolutions 5 برای ساخت شبکه استفاده شد. مهم‌ترین مسئله در ساخت شبکه تعداد لایه‌ها و نرون‌ها در هر لایه است. تعداد نرون‌ها در لایه اول برابر با ورودی‌ها و در لایه خروجی برابر با تعداد خروجی‌ها است. مشکل عمده در انتخاب تعداد لایه‌های مخفی و تعداد نرون‌ها در هر یک از آنها است. روش عمومی برای به دست آوردن آنها روش سعی و خطا و البته تجربیات پژوهشگران دیگر است. در جنگل با توجه به وجود اغتشاش و پراکندگی در داده‌ها و انعطاف‌پذیری شبکه عصبی پیش‌خور با دو لایه مخفی، به طور معمول شروع پردازش داده‌ها با دو لایه مخفی آغاز می‌شود. معیارهای ارزیابی به منظور ارزیابی نتایج مدل شبکه عصبی و مقایسه آن با برآوردهای رگرسیونی، معیارهای میانگین مربعات خطا ( $RMSE$ )، میانگین قدر مطلق خطا ( $MAE$ ) و ضریب تبیین ( $R^2$ ) بودند (رابطه‌های ۳ تا ۵).

جدول ۱- مشخصه‌های کمی داده‌های مورد استفاده در مدل‌ها

متغیر	حداکثر	حداقل	میانگین	انحراف معیار
تعداد درخت در هکتار	۱۲۲۰	۲۰	۴۲۱	۲۴۱
سطح مقطع توده (متر مربع در هکتار)	۱۱۳	۰	۳۶/۸	۱۴
میانگین قطری برای تک‌تک قطعات نمونه (سانتی‌متر)	۱۷۵	۱۴	۳۰/۱	۱۰/۹
قطر (سانتی‌متر)	۱۸۸	۷	۳۰/۹	۲۴/۷
سطح مقطع قطورترین درختان در توده برای تک‌تک قطعات نمونه (متر مربع در هکتار)	۱۱۳	۰	۲۹/۴	۱۴/۵

آمار توصیفی متغیرها در جدول ۲ ارائه شده است.

جدول ۲- آمار توصیفی متغیرها

متغیر	میانگین	واریانس	حداقل	حداکثر
قطر برابر سینه (سانتی متر)	۳۸/۵	۲۴/۸	۱۵	۱۸۸
ارتفاع کل (متر)	۲۳/۰۸	۶/۵۵	۱۴	۴۳/۰۱
شیب (درصد)	۲۵/۷۹	۱۵/۱۴۷	۰	۱۰۰
زاویه نسبت به شمال	۱۳۵/۲	۹۷/۳	۰	۲۷۰
حجم کل در قطعه نمونه (سیلو)	۱/۲۱	۲/۲۳	۰/۰۶	۳۱/۳

#### نتایج روش رگرسیون

جدول ۳ نتیجه ارزیابی روش رگرسیون چندمتغیره در برآورد حجم کل را نشان می‌دهد. به منظور مقایسه تخمین‌های شبکه عصبی با مدل‌های متداول و برآورد دقت آنها، رابطه رگرسیونی بین داده‌ها برقرار شد. آزمون

همبستگی نشان داد که بین متغیرهای مستقل (قطر برابر سینه، ارتفاع کل، شیب و جهت) و متغیر وابسته (حجم کل) همبستگی معنی‌داری در سطح اطمینان ۹۹ درصد وجود داشت. جدول ۴ ضریب همبستگی بین متغیرهای مستقل و متغیر وابسته را در مدل رگرسیونی نشان می‌دهد.

جدول ۳- نتیجه ارزیابی روش رگرسیون چندمتغیره در برآورد حجم کل

مدل	RMSE	R <sup>2</sup>
$V = 0.0001 \times d_{1.3}^{2.50}$	۳/۳	۰/۷۷
$V = - 8.07 + 9.35 d_{1.3} + 0.2 h + 5.83 s$	۳	۰/۸۱

جدول ۴- ضریب همبستگی بین متغیرهای مستقل و متغیر وابسته

متغیر	ارتفاع کل درخت	قطر در برابر سینه	شیب	جهت
حجم کل (سیلو)	۰/۷۸۲	۰/۸۲	-۰/۲۸	-۰/۲۱

#### نتایج روش شبکه عصبی در برآورد حجم

آموزش شبکه با چهار نرون در لایه ورودی، پنج نرون در لایه مخفی اول، سه نرون در لایه مخفی دوم، دو نرون در لایه مخفی سوم و یک نرون در لایه خروجی اجرا شد و برآوردهای شبکه توسط معیارهای  $RMSE$ ،  $MAE$  و  $R^2$  ارزیابی شد. در آموزش شبکه باید به این نکته توجه داشت که همیشه حداقل خطا بیان‌گر بهترین آموزش شبکه نیست و امکان دارد که وزن‌های شبکه در یک حالت

نامناسب تنظیم شده باشد، بنابراین برای انتخاب تکرار مناسب باید تعداد بار آموزش شبکه بهینه شود. به این منظور رابطه تعداد تکرار با خطا هم برای داده‌های آموزش و هم برای داده‌های آزمون برقرار شد و براساس رابطه به‌دست آمده، تعداد تکرار بهینه به‌دست آمد و در ادامه مدل مطلوب با مشخصات زیر تأیید شد (جدول ۵). مقایسه خروجی حجم واقعی با خروجی حجم پیش‌بینی شده توسط شبکه نیز راهی دیگر در ارزیابی مدل است (شکل ۴).



جدول ۵- مشخصات ساختار بهینه شبکه

مشخصات	ساختار بهینه شبکه
تعداد نرون لایه ورودی	۴
تعداد نرون لایه مخفی اول	۵
تعداد نرون لایه مخفی دوم	۳
تعداد نرون لایه مخفی سوم	۲
تعداد نرون لایه خروجی	۱
تابع محرک نرون‌ها	سیگموئید



شکل ۴- مقایسه خروجی حجم واقعی با خروجی حجم پیش‌بینی شده توسط شبکه

ارزیابی شد. به منظور بررسی توانایی شبکه عصبی در برآورد حجم جنگل در مقایسه با مدل‌های متداول رگرسیونی، نتایج هر دو مدل و پارامترهای آماری مقایسه شدند که در جدول ۶ ارائه شده است.

به منظور بررسی توانایی شبکه عصبی در برآورد حجم جنگل در مقایسه با مدل‌های متداول رگرسیونی، نتایج هر دو مدل و پارامترهای آماری مورد مقایسه در جدول ۵ ارائه شده است. در نهایت، این مدل با داده‌های سری آزمون

جدول ۶- مقایسه نتایج به دست آمده از شبکه عصبی و مدل رگرسیونی

پارامترهای ارزیابی	RMSE	MAE	R <sup>2</sup>
مدل رگرسیونی	۲/۵	۰/۹۵	۰/۸۵
شبکه عصبی	۱/۰۰۶	۰/۶۹	۰/۹۸

## بحث

در این پژوهش، قابلیت شبکه عصبی مصنوعی در برآورد حجم درختان بررسی شد. نتایج جدول همبستگی بین حجم با متغیرهای دیگر نشان داد که حجم بیشترین همبستگی را با قطر و کمترین همبستگی را با جهت درخت داشت که با نتایج Karaman و Caliskan (۲۰۰۹) هم‌راستا است. تأثیر این همبستگی را می‌توان در جدول ۴ مشاهده کرد. همچنین

استفاده از روابط به منظور محاسبه حجم درختان به این دلیل ارزشمند است که از یک طرف امکان پیش‌بینی حجم را برای درختان دیگر با اندازه‌گیری چند متغیر میسر می‌کند و از طرف دیگر رابطه‌ای به دست می‌آید که با حداقل تعداد متغیر مورد نیاز، حجم را با دقت قابل قبول برآورد می‌کند.

با افزایش تعداد متغیرها به عنوان ورودی‌های شبکه، اختلاف بین حجم واقعی و حجم پیش‌بینی شده کاهش یافت که Blackard و Dean (۱۹۹۹) به همین نتایج دست یافتند. بررسی نتایج ارزیابی مدل شبکه عصبی نشان داد که شبکه عصبی مصنوعی MLP با تابع انتقال Sigmoid توانایی زیادی در پیش‌بینی حجم درخت داشته است (Hasenauer *et al.*, 2001). البته باید توجه داشت که یافتن تعداد لایه پنهان و تابع انتقال مناسب در هر یک از مدل‌های شبکه عصبی نیاز به سعی و خطا دارد؛ به طوری که در هر آزمون باید معیارهای ارزیابی اندازه‌گیری شوند و تکرار تا زمانی انجام شود که کمترین خطا بین مشخصه پیش‌بینی شده و مشخصه واقعی به دست آید. مقایسه بین معیارهای جدول‌های نتایج شبکه عصبی مصنوعی و رگرسیون چندمتغیره نشان داد که شبکه عصبی دقت بهتر ( $R^2$  بیشتر) و خطای کمتری در پیش‌بینی داشته است که این امر را می‌توان به عدم وابستگی شبکه عصبی به فرض‌های اولیه درباره داده‌ها نسبت داد زیرا ممکن است بین متغیرها رابطه غیرخطی وجود داشته باشد که رگرسیون قادر به پیش‌بینی آن نبوده است. انتخاب تعداد متغیرهای لازم به عنوان ورودی‌های شبکه بستگی به هدف مجری دارد؛ به طوری که اگر هدف برآورد حجم با دقت زیاد باشد، از مدلی استفاده می‌شود که بیشترین ورودی را داشته باشد، اما اگر هدف برآورد با هزینه کمتر باشد از متغیرهایی که نیاز به زمان، امکانات و تخصص کمتری به منظور محاسبه دارند، استفاده خواهد شد. همان‌گونه که در پژوهش پیش‌رو نشان داده شد، برآوردهای شبکه عصبی در مقایسه با مدل‌های رگرسیونی از دقت بیشتری برخوردار بود و نسبت به مدل رگرسیونی توانست برآورد دقیق‌تری از حجم براساس متغیرهای مستقل داشته باشد.

تصمیم‌گیری در منابع طبیعی اغلب با پیچیدگی‌های فراتر از روش‌های تجربی آماری روبه‌رو می‌شود که نیازمند رهیافت‌هایی است که گاهی اوقات بیشتر ابتکاری است تا این‌که به شکل الگوریتم باشد (Gimblet & Ball, 1995). یکی از مهم‌ترین ویژگی‌های شبکه‌های عصبی مصنوعی در

مقابل روش‌های مرسوم آماری، عدم وابستگی آنها به فرضیه‌های اولیه درباره داده‌های ورودی است. به این معنا که داده‌های ورودی می‌توانند هرگونه توزیع آماری دلخواهی داشته باشند (Benediktsson *et al.*, 1990). در مدل‌سازی با شبکه عصبی مصنوعی در مقایسه با مدل رگرسیونی می‌توان در زمان کوتاه‌تر و با دقت بیشتر به روابط میان حجم و قطر، ارتفاع، شیب و جهت دست یافت. مزیت دیگر این روش حساس نبودن آن به وجود تعداد معدودی خطا در داده‌های آماری است که همین امر باعث برآورد بهتر مدل شبکه عصبی در مقایسه با مدل رگرسیونی شده است. همچنین توانایی یادگیری از طریق ارایه مثال بدون نیاز به معادلات حاکم بر پدیده از مزایای دیگر این روش است که در پژوهش پیش‌رو نشان داده شد، اما برای رسیدن به یک مدل مطلوب مرحله‌ای شامل آماده‌سازی داده‌ها، معماری شبکه، آموزش شبکه و اعتبارسنجی ضروری است. نحوه انجام این موارد می‌تواند تا حد قابل ملاحظه‌ای نتایج مدل را تحت تأثیر قرار دهد. به طور مثال با تغییر اندک در تعداد نرون‌ها در هر لایه دقت برآورد تا حد قابل ملاحظه‌ای تحت تأثیر قرار می‌گیرد (Diamantopoulou, 2005). در این خصوص در معماری شبکه با افزایش تعداد نرون‌ها باید فراوانی داده‌ها افزوده شود و هیچ‌گاه نباید تعداد وزن‌های ارتباطی بیش از تعداد داده‌های آموزش باشد. همچنین در این پژوهش در ارتباط با میزان آموزش شبکه نکاتی در نظر گرفته شد که از آن جمله می‌توان به موارد زیر اشاره کرد. در آموزش شبکه برای جلوگیری از گرفتار شدن در یک کمینه محلی که باعث تولید نتایج نادرست می‌شود دو راه حل وجود دارد. در روش اول نرخ یادگیری مقدار کوچک‌تری انتخاب می‌شود. البته در این حالت سرعت یادگیری کاهش پیدا می‌کند. در مقابل در روش دوم با افزودن بر مقدار یادگیری، سرعت آموزش افزایش یافته ولی میزان یادگیری کاهش می‌یابد. برای حل این تناقض یک مقدار گشتاور به شبکه اعمال می‌شود که موجب افزایش سرعت یادگیری در حالت پایین بودن ضریب یادگیری می‌شود (Hanewinkela *et al.*, 2004). همان‌گونه که بیان شد در پژوهش پیش‌رو

- Computers and Electronics in Agriculture, 24(3): 231-251.
- Bourque, Ch. and Bayat, M., 2015. Landscape variation in tree species richness in northern Iran forests. PLOS One, 10(4):1-17
  - Diamantopoulou, M.J., 2005. Artificial neural networks as an alternative tool in pine bark volume estimation. Computers and Electronics in Agriculture, 48: 235-244.
  - Etemad, V., 2002. Quantity and quality investigation seed of fagus in forests of Mazandaran province. Ph.D. thesis, Faculty of Natural Resources, University of Tehran, Karaj, 258p (In Persian).
  - Farshad Far, A., 2002. Regression Analysis. University of Tehran Press, Tehran, 771p (In Persian).
  - 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 (In Persian).
  - 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.
  - Hanewinkela, M., Zhou, W. and Schill, Ch., 2004. A neural network approach to identify forest stands susceptible to wind damage. Forest Ecology and Management, 196(2): 227-243.
  - Hasenauer, H., Merkl, D. and Weingartner, M., 2001. Estimating tree mortality of Norway spruce stands with neural networks. Advances in Environmental Research, 5: 405-414.
  - Hokka, H., 1999. Forest modeling and management. Silva Fennica, 34: 251-272.
  - Jahani, A., Fegghi, J., Makhdoum, M. and Omid, M., 2016. Optimized forest degradation model (OFDM): an environmental decision support system for environmental impact assessment using an artificial neural network. Journal of Environmental Planning and Management, 59(2): 222-244.
  - Jalilvand, H., 2003. Model and simulation growth reaction in tree of forest to climate and nourishment variables. Ph.D. thesis, Faculty of Natural Resources, University of Tarbiat Modares, Noor, 258p (In Persian).
  - Karaman, A. and Caliskan, E., 2009. Affective factors weight estimation in tree felling time by

تنها از پارامترهای قطر، ارتفاع، شیب و جهت استفاده شد که به طور معمول در دسترس هستند، اما ممکن است به دلیل عامل‌هایی مانند خطای سیستماتیک داده‌ها از دقت مناسبی برخوردار نباشند. بدیهی است عامل‌های دیگری مانند بارندگی، حاصلخیزی خاک و ارتفاع از سطح دریا نیز تأثیر به‌سزایی در میزان برآورد دقیق حجم خواهند داشت، بنابراین با استفاده از این عامل‌ها به‌عنوان ورودی‌های مدل می‌توان دقت برآوردها را افزایش داد و اطلاعات مفیدتری را برای برآورد دقیق‌تر حجم ارائه داد.

## References

- Bayat, M., Namiranian, M., Zobeiri, M. and Fathi, J., 2013a. Determining the growing volume and number of trees in the forest using permanent sample plots. Iranian Journal of Forest and Poplar Research, 21(3): 424-438 (In Persian).
- Bayat, M., Pukkala, T., Namiranian, M. and Zobeiri, M., 2013b. Productivity and optimal management of the uneven-aged hardwood forests of Hyrcania. European Journal of Forest Research, 132(5-6): 851-864.
- Bayat, M., Namiranian, M. and Zobeiri, M., 2014. Volume, height and wood production modeling using the changes in a nine years rotation (case study: Gorazbon district in Kheyroud forest, north of Iran). Journal of Forest and Wood Products, 67(3): 423-435 (In Persian).
- Bayat, M., Namiranian, M. and Zobeiri, M. and Pukkala, T., 2015. Growth models using to simulate and investigate different forest management methods (Case study: Gorazbon district in Kheyroud forest, north of Iran). Journal of Forest and Wood Products, 67(4): 595-612 (In Persian).
- Benediktsson, J.A., Swain, P.H. and Erosy, O.K., 1990. Neural network approaches versus statistical methods in classification of multisource remote sensing data. IEEE Transaction on Geosciences and Remote Sensing, 28(4): 540-552.
- 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.

- Research, 403: 3538-3543 (In Persian).
- Namiranian, M., 2010. Tree Measurement and Forest Bioinventory. University of Tehran Press, Tehran, 574p (In Persian).
  - Pukkala, T., 2009. Growth and yield models for uneven aged stand in Finland. Forest Ecology and Management, 258: 207-216.
  - Zobeiri, M., 2008. Forest Biometry. University of Tehran Press, Tehran, 407p (In Persian).
  - Zobeiri, M., 2011. Forest Inventory (Tree Measurement). University of Tehran Press, Tehran, 401p (In Persian).
  - Marvie-Mohadjer, M., Zobeiri, M., Etemad, V. and Jourgholami, M., 2009. Performing of the single selection method at compartment level and necessity for full inventory of tree species (Case study: Gorazbon district in Kheyroud forest, north of Iran). Iranian Journal of Natural Resources, 61(4): 889-908 (In Persian).
  - Naghdi, R. and Ghajar, I., 2012. Application of artificial neural network in the modeling of skidding time prediction. Advanced Materials artificial neural networks. Expert Systems with Applications, 36: 4491-4496.

## Applicability of artificial neural network for estimating the forest growing stock

M. Bayat<sup>1\*</sup>, M. Namiranian<sup>2</sup>, M. Omid<sup>3</sup>, A. Rashidi<sup>4</sup> and S. Babaei<sup>5</sup>

1\* - Corresponding author, Assistant Prof., Research Institute of Forests and Rangelands, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran. E-mail: mbayat@rifr-ac.ir

2- Prof., Department of Forestry and Forest Economics, Faculty of Natural Resources, University of Tehran, Karaj, Iran

3- Prof., Department of Agricultural Machinery, School of Agriculture & Natural Resources, University of Tehran, Karaj, Iran

4- M.Sc. Forestry and Forest Economics, Department of Forestry and Forest Economics, Faculty of Natural Resources, University of Tehran, Karaj, Iran

5- M.Sc. Student Forestry and Forest Economics, Department of Forestry and Forest Economics, Faculty of Natural Resources, University of Tehran, Karaj, Iran

Received: 13.02.2015

Accepted: 16.09.2015

### Abstract

Knowledge on stand's quantitative and qualitative characteristics (tree volume and growth) are fundamental requirements for monitoring close-to-nature forest management plans. In addition, future planning is based on statistics and information obtained from the forest. Thus, structural information such as standing stock, growth and diameter distribution are highly required. Volume increment provides the amount of allowable annual cut. In this study 768.4 ha of virgin forests located in Gorazbon district in Kheyroud educational- experimental Forest was inventoried by 258 permanent sample plots measured in 2012. Following elimination of statistical deficiency and exclusion of deviated points, the data were divided into 80% training and 20% test data to examine the applied neural network. The data was initially standardized by using training data. Neural network with back propagation error algorithm was developed. Furthermore, volume was regressed against diameter, height, slope and aspect using the allocated training data. Model diagnostics including  $R^2$ ,  $MAE$  and  $RMSE$  were applied for evaluating those two methods. The analysis resulted in  $R^2=0.98$ ,  $MAE=0.69$  and  $RMSE=1.006$ , respectively. For the regression method the diagnostics amounted in  $R^2=0.85$ ,  $MAE=0.95$  and  $RMSE=2.5$ . The results have suggest the higher accuracy of neural network for growing stock estimation compared to regression approach. However, care must be taken during data preparation, network design and network training to reach an optimum final model. It is concluded that this model should be further considered and applied for the estimation of volume across the study area.

**Keywords:** Gorazbon section, artificial neural network, regressions models, volume.