



مدلسازی حجم تجاری درختان توده‌های آمیخته‌ای راش جنگل‌های هیرکانی با استفاده از شبکه عصبی مصنوعی

علی‌اصغر واحدی^{۱*}، اسدالله متاجی^۲، رضا اخوان^۳

۱. دکتری جنگلداری، مؤسسهٔ تحقیقات جنگل‌ها و مراتع کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

۲. استاد گروه جنگلداری، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۳. دانشیار جنگلداری، مؤسسهٔ تحقیقات جنگل‌ها و مراتع کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ دریافت: ۱۳۹۳/۱۱/۳۰، تاریخ پذیرش: ۱۳۹۴/۰۸/۲۴

چکیده

پیش‌بینی دقیق حجم درختان سرپا بر حسب متر مکعب مبنای برآورد هر چه دقیق‌تر مقدار رویش، برداشت مجاز، ترسیب کربن زی توده هوایی درختان و مدیریت بهینه جنگل براساس اصل توسعه پایدار محسوب می‌شود. از این‌رو، تحقیق حاضر با استفاده از شبکه عصبی مصنوعی در پی مدل‌سازی و پیش‌بینی حجم تجاری با حداقل قطعیت است. پژوهش موردنی جنگل سری ۳ گلندروود نور بوده و اطلاعات دریافتی مستخرج از جدول‌های تجدید حجم اداره کل منابع طبیعی نوشهر شامل قطر، ارتفاع کل و مقادیر حجمی مربوط به ۱۵۰ اصله درختان قطع شده است. کلیه مقادیر حجمی به‌ازای کمیت‌های FFBP بیوفیزیکی مذکور به عنوان لایه ورودی به صورت مرحله‌ای با استفاده از شبکه عصبی پیش‌خور الگوریتم پس انتشار مدل‌سازی شدند. همچنین از دو تابع انتقال نورون غیرخطی Logsig و Tansig استفاده شد، طوری که هر مدل با توابولوژی مختلف شبکه مدنظر برای رسیدن به پاسخ هدف، دقت متفاوتی را نشان داد. نورون‌های انتقالی برای رسیدن به حداقل خطای آزمون داده‌ها در هر الگوریتم آموزش، پس از وزن‌دهی اولیه دارای تعداد چرخش متفاوت بودند. نتایج مدل‌سازی پس از سعی و آزمون مکرر نشان داد که مدل حاوی قطر و ارتفاع کل با تابع انتقالی Logsig با معماری دو لایه پنهان و ۱۵ نورون دارای حداقل میانگین مربuat خطای آزمون (MSE)، حداقل میانگین انحراف معیار و حداقل ضریب تبیین $R^2 = 0.99$ است که این‌رو به عنوان مدل بهینه معرفی می‌شود.

واژگان کلیدی: تابع انتقال، توده‌های آمیخته‌ای راش، حجم تجاری، شبکه عصبی مصنوعی.

قطع شده درختان باید مدت نسبتاً زیادی در عرصه‌های جنگل باقی بماند تا دوباره اندازه‌گیری و تعیین حجم شوند. مقادیر حجم اندازه‌گیری شده پس از قطع و افتادن درختان طی عملیات تجدید حجم به عنوان حجم واقعی تلقی می‌شود که بر حسب متر مکعب است [۱]. در عملیات تجدید حجم برای به‌دست آوردن مقادیر واقعی حجم هر درخت افتاده، به‌طور معمول از روش صدرصد استفاده می‌شود. البته اگر تعداد درختان نشانه‌گذاری شده برای قطع بیش از ۵۰۰-

مقدمه

یکی از مهم‌ترین عملیات‌پس از قطع، سرشاخه‌زنی و حذف تاج درختان در جنگل‌های شمال کشور توسط دستگاه‌های اجرایی، عملیات تجدید حجم برای به‌دست آوردن مقدار واقعی حجم درختان به‌منظور فروش برای مصارف تجاری و صنعتی است. یکی از معایب این کار این است که پایه‌های

* نویسنده مسئول، تلفن: ۰۲۱۴۴۷۸۷۲۸۳

Email: ali.vahedi60@gmail.com

پنج ساله توسعه جمهوری اسلامی ایران، بهره‌برداری و خروج چوب‌های صنعتی از جنگل‌های شمال متوقف شده است؛ ولی با توجه به ابهامات برخی از دستگاه‌های مตولی و نیاز مبرم به اطلاعات درباره مقدار موجودی حجمی در جنگل‌های شمال برای مدیریت بهینه، برآورد حجم تجاری جنگل‌های شمال با حداقل عدم قطعیت با احتساب تعلق بیش از ۵۰ درصد از ارزش حجمی درختان جنگل‌های شمال به بخش اول تنه درختان [۱]، می‌تواند معرف ارزش مطالعاتی پژوهش حاضر باشد. از این‌رو با توجه به اهمیت اطلاعات مقادیر موجودی حجم صنعتی جنگل‌های شمال برای دستیابی به کلیه اهداف، در تحقیق حاضر از تکنیک مدلسازی شبکه عصبی مصنوعی به عنوان جایگزین روش‌های سنتی (مانند روش‌های تخریبی، صدرصد، ۳p و غیره) برای به حداکثر رسیدن دقت برآورده حجم درختان توده‌های آمیخته در جنگل مورد پژوهش استفاده شد.

مواد و روش‌ها

منطقه تحقیق

تحقیق مورد نظر در سری ۳ جنگل‌های گلندرود نور واقع در حوضه آبخیز ۴۸ جنگل‌های شمال ایران صورت گرفته است. مساحت کل سری ۱۵۲۱ هکتار است و محدوده آن در بین عرض جغرافیایی $۳۶^{\circ}۲۷'۳۰''$ ، $۳۶^{\circ}۳۲'۱۵''$ و طول جغرافیایی $۵۱^{\circ}۵۳'۲۵''$ ، $۵۱^{\circ}۵۷'۲۵''$ استقرار دارد. محدوده ارتفاع از سطح دریا در این سری بین ۹۴۰ تا ۱۵۲۰ متر است. آمار دریافتی هواشناسی از نزدیک‌ترین ایستگاه (نوشهر) نشان داد که میانگین بیشینه و کمینه دما به ترتیب در اواسط مرداد تا اواخر شهریور $۲۸/۸$ و در بهمن $۳/۹$ درجه سانتی‌گراد است. متوسط بارندگی سالیانه $۱۲۹۳/۵$ میلی‌متر است که میانگین حداقل بارندگی در مرداد و میانگین حداقل بارندگی در اوخر آبان تا اوایل آذر گزارش شده است [۱۰].

۴۵۰ اصله باشد، برای تعیین حجم از روش ۳P نیز استفاده می‌شود. پژوهش حاضر در جنگل‌های آمیخته راش در سری ۳ گلندرود نور صورت گرفت که در آن حجم ۱۵۰ اصله از درختان نشانه‌گذاری شده پس از قطع با روش صدرصد اندازه‌گیری شد. با توجه به دسترسی اطلاعات خام (مقدار واقعی حجم) به عنوان مشاهدات اصلی، از روش هوش مصنوعی برای ارائه مدل‌های پیشگو با حداکثر دقت برآورد استفاده شد تا بتوان با حداقل زمان، سرعت بیشتر و با حداقل هزینه، حجم تجاری توده‌های آمیخته راش جنگل مورد بررسی را با قطعیت بیشتری پیش‌بینی کرد. سیستم هوش مصنوعی از جمله روش‌های بسیار باقابلیت برای برآورد مقدار پاسخ هدف در بوم‌سازگان طبیعی و پیچیده است [۲]. یکی از مهم‌ترین زیرمجموعه‌های هوش مصنوعی به عنوان بهترین جایگزین انواع برآذش‌های غیرخطی با جنبه‌های تکمیلی برای مدلسازی و پیش‌بینی دقیق مقادیر حجم درختان جنگل، شبکه عصبی مصنوعی است [۲، ۳]. از جمله پارامترهای تأثیرگذار در اجرای مدلسازی شبکه عصبی مصنوعی، تعداد نورون‌ها و تعداد لایه‌های پنهان است [۴-۶]. نیز با تعداد متغیرهای خروجی مورد بررسی برابر است [۷-۹]. در شبکه عصبی، بین لایه‌های ورودی و خروجی با توجه به تعداد لایه‌های پنهان ساختارهای اتصالات مختلف ایجاد می‌شود و با توجه به تبادل اطلاعات دریافتی (داده‌های ورودی) و مقدار رفت و برگشت اطلاعات در اتصالات ایجاد شده شبیه مغز انسان، در نهایت یک پاسخ (خروجی) صحیح با حداقل خطای بدست می‌آید [۷].

برآورد هرچه دقیق‌تر حجم درختان در بوم‌سازگان طبیعی جنگل مبنای مدیریت (براساس اصل توسعه پایدار)، میزان روند بهبود یا تخریب رویشگاه، حاصلخیزی، مقدار رویش، مقدار برداشت مجاز و خرید و فروش برای مراکز صنعتی است [۲]. البته به استناد بند ۶ ماده ۱۴۸ قانون برنامه

درختان (H) بر حسب متر که به‌طور گام‌به‌گام در مدلسازی وارد شدند [۲]. مهم‌ترین گام‌های ایجاد یک مدل شامل آماده‌سازی داده‌ها، مدلسازی و ارزیابی مدل است. از این‌رو برای آماده‌سازی، متغیرهای مذکور براساس رابطه ۱ نرمالیزه یا استانداردسازی شدند، طوری که تمامی داده‌ها بین ۰ و ۱ قرار گرفتند [۱۱، ۲].

$$X_n = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

در رابطه ۱، x_n متغیر نرمال شده، x_i هر یک از ورودی‌ها، x_{\min} و x_{\max} به‌ترتیب کمترین و بیشترین مقدار ماتریس داده‌های ورودی محسوب می‌شوند. در طراحی شبکه عصبی، تعیین ساختار شبکه عصبی (تعداد لایه و نحوه اتصال گره‌ها)، تعیین مشخصات گره و تعیین الگوریتم‌های آموزش شبکه مدنظر قرار می‌گیرند. در میان موارد ذکر شده، تعیین الگوریتم‌های آموزش شبکه در حقیقت فرایند وزن‌دهی اولیه، تعیین تابع بهینه برای محاسبه فعالیت خروجی گره‌ها و روش آموزش وزن‌های شبکه را در بر می‌گیرد [۷]. هر یک از داده‌های ماتریس ورودی در قالب Input از طریق ترکیب مقادیر ورودی نورون‌ها (I_i) و مقادیر وزنی یا سینپس‌ها (w_{ij}) محاسبه می‌شوند [۱۲].

در طراحی شبکه عصبی مصنوعی، از شبکه عصبی رایج و عمومی پیش‌خور با الگوریتم پس‌انتشار^۱ FFBP استفاده شد. پس از انتخاب تابع آموزش، تعداد لایه‌ها و نورون‌ها با تپیلوژی مختلف برای رسیدن به آستانه اپتیمال مدل تخمینی تغییر پیدا کرد. در داخل هر نورون تابع انتقال وجود دارد که در حقیقت سیگنال‌های حاصل از ورودی را می‌گیرد و خروجی را محاسبه می‌کند. خطاهای محاسبه شده به لایه‌های قبل در طی چند دور رفت و برگشت^۲ پس‌انتشار می‌یابند و اوزان و بایاس‌ها اصلاح می‌شوند [۷]. این دور تکرار تا به حداقل رسیدن خطای ادامه پیدا می‌کند. در طراحی

روش پژوهش

برای اجرای تحقیق حاضر با دریافت مجوز از اداره کل منابع طبیعی و آبخیزداری نوشهر، از داده‌های آرشیو اسناد حاوی اطلاعات جدول‌های تجدید حجم پایه‌های قطع شده گونه‌های مختلف درختان در سری سه گلندرود استفاده شد. عملیات قطع درختان توسط دستگاه‌های اجرایی در زمستان ۱۳۸۹ انجام گرفت و دریافت اطلاعات مربوط به سال ۱۳۹۳ است. جدول‌های مذکور حاوی اطلاعاتی درباره طبقهٔ قطری و ارتفاع کل درختان نشانه‌گذاری شده است. در روش مذکور حجم همه درختان افتداده پس از قطع به تفکیک شماره‌های نشانه‌گذاری شده اندازه‌گیری و محاسبه شد. برای این کار طول هر قسمت از تنهٔ پایه‌های درختان افتداده (حداکثر طول برداشتی ۶ متر) و قطر میانه هر قسمت مذکور، اندازه‌گیری شده و با استفاده از رابطهٔ اندازه‌گیری حجم استوانه و ضریب شکل، حجم تجاری درختان برحسب متر مکعب محاسبه شد. اطلاعات جمع‌آوری شده مربوط به گونه‌های راش، مرز، بلوط، توسکا و دیگر گونه‌های درختان منطقه است. تعداد کل اطلاعات دریافتی مربوط به ۱۵۰ پایهٔ افتداده درختان از گونه‌های مختلف است.

تجزیه و تحلیل داده‌ها

پس از جمع‌آوری کلیه داده‌ها برای اجرای فرایند تجزیه و تحلیل، نرمال بودن مشاهدات توسط آزمون کولموگروف- اسمیرنوف و همگنی داده‌ها توسط آزمون لون بررسی شد. برای مقایسه مقادیر مختلف کمیت‌های اندازه‌گیری مربوط به درختان منطقه تحقیق از آزمون تجزیه واریانس یکطرفه و برای مقایسه چندگانه میانگین از آزمون توکی استفاده شد.

برای مدلسازی مقادیر مختلف حجم موجود بر حسب متر مکعب، از تکنیک شبکه عصبی مصنوعی استفاده شد. داده‌های ورودی برای مدلسازی عبارت‌اند از قطر برابر سینه (DBH) بر حسب سانتی‌متر و ارتفاع کل

1. synapses

2. Feed-forward back prop

3. Epoch

طبقه‌های قطری در جدول مربوط فهرست دریافتی ثابت در نظر گرفته شده است.

جدول ۱ کمترین، بیشترین و میانگین (\pm اشتباہ معیار) کمیت‌های اندازه‌گیری هر یک از گونه‌های مختلف درختان در منطقه تحقیق را نشان می‌دهد. نتایج آزمون توکی نشان داد در میان کلیه کمیت‌های اندازه‌گیری شده فقط میانگین ارتفاع کل درختان گونه راش، نسبت به میانگین ارتفاع کلیه گونه‌های موجود به صورت معنی‌داری بیشتر است (جدول ۱). میانگین طبقه قطر برابرسینه در تحقیق حاضر برای کلیه پایه‌های موجود 80 ± 7 سانتی‌متر است.

پس از طراحی تپولوژی یا ساختار شبکه مشکل از مقادیر ورودی، تعداد لایه پنهان، تعداد نوروون و مقدار خروجی، نتایج مربوط به دقت پیش‌بینی پاسخ هر یک از توابع انتقال کاربردی به دست آمد (جدول ۲). با توجه به جدول ۲ در واقع همه مدل‌ها، دقت پذیرفتی دارند، ولی با توجه به شاخص‌های محاسباتی اشتباہ معیار بین تخمین و مشاهدات (SEE) و میانگین مربعات خطای (MSE) مربوط به آزمون داده‌ها علاوه‌بر ضریب تبیین و میانگین انحراف معیار، بهترین مدل حتی با اختلاف خیلی جزئی پیش‌بینی انتخاب شد. نتایج نشان داد که تپولوژی شبکه عصبی مدل ۵ حاوی تابع انتقال نوروون Tansig فقط با استفاده از ارتفاع کل درختان دارای ساختار بهینه برای پیش‌بینی حجم واقعی است (جدول ۲). شکل ۱ دقت آموزش، اعتبار و آزمون داده‌ها را نشان می‌دهد. با توجه به شکل مذکور، میانگین مربعات خطای آزمون داده‌ها مربوط به تابع Tansig مدل ۵ دارای دقت مناسبی است. البته با توجه به جدول ۲ در رابطه با برخی دیگر از مدل‌ها، نتایج نشان داد که ضریب تبیین به دست آمده دارای مقدار زیاد و قابل قبول با حداقل درصد میانگین انحراف معیار است ($R^2 = 0.99$ ٪، $AD\% = 16.4$ ٪) و مدل‌های مربوط دارای دقت محاسباتی به نسبت زیاد برای پیش‌بینی حجم است، ولی چون میزان میانگین مربعات خطای مدل

معماری‌هایی که بیش از یک لایه پنهان دارند، تعداد نوروون تمام لایه‌ها (به جز لایه خروجی که به صورت خودکار ۱ نوروون دارد) ثابت در نظر گرفته شد تا علاوه بر استمرار، تپولوژی مورد نظر حین کاربرد، پیچیدگی نداشته باشد. ازین‌رو تعداد نوروون‌های نمایش داده شده برای تمام لایه‌ها ثابت است. علاوه‌بر آن در تمام لایه‌ها توابع انتقالی ثابت در نظر گرفته شدن که در این زمینه از توابع انتقال لجستیک سیگموئیدی (Logsig) و تانژانت سیگموئیدی (Tansig) استفاده شد. برای ارائه مدل‌های تخمینی مختلف، ۷۰ درصد از داده‌ها برای آموزش، ۱۵ درصد برای اعتبار و ۱۵ درصد نیز برای تست (آزمون) مدل استفاده شدند [۸]. برای اعتبارسنجی به طور مستقیم از شاخص‌های ضریب تبیین R^2 و میانگین مربعات خطای (MSE) آزمون داده‌های مربوط به هر یک از مدل‌های ارائه شده طبق رابطه ۲ و از میانگین درصد انحراف معیار طبق رابطه ۳ استفاده شد. آنالیزها توسط نرم‌افزارهای متلب و SPSS^{17.0} صورت گرفت.

$$MSE = \frac{1}{n} \sum_{i=1}^n [\hat{z}(x_i) - z(x_i)]^2 \quad (2)$$

$$AD\% = \frac{100}{n} \sum_{i=1}^n \left| \frac{\hat{Y}_i - Y_i}{Y_i} \right| \quad (3)$$

نتایج و بحث

نتایج آنالیز واریانس یکطرفه در زمینه تغییرات کمیت‌های اندازه‌گیری شده موجود در فهرست جدول مربوط به اطلاعات تجدید حجم درختان قطع شده در سری ۳ جنگل گلندرود نشان داد که ارتفاع کل درختان بین کلیه گونه‌های موجود در سطح کمتر از ۰/۰۱۰ متر از ۰/۱۱ میانگین مربعات خطای معنی‌دار است ($MS = 623 / 556$). برخلاف آن نتایج به دست آمده در $F = 17$ (آماره واریانس). برخلاف آن نتایج به دست آمده در زمینه تغییرات حجم بین کلیه گونه‌های درختان نشان داد که متغیر مذکور دارای اختلاف معنی‌داری نیست ($P > 0.05$). شایان ذکر است که

حداقل مقدار نسبت به دیگر مدل‌های داشت، دقیق‌تری برای پیش‌بینی پاسخ هدف در تحقیق حاضر دارد.

بهینه انتخابی حاوی ارتفاع کل به عنوان متغیر ورودی دارای حداقل اختلاف نسبت به آموزش و اعتبار و نیز

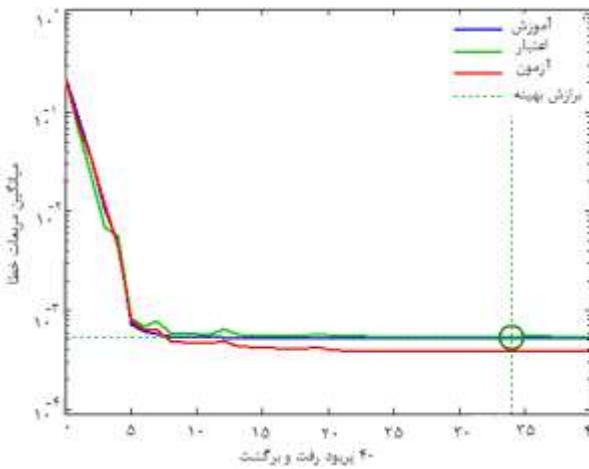
جدول ۱. نتایج آزمون توکی برای کمیت‌های اندازه‌گیری شده درختان منطقه تحقیق

| گونه درختان | کمیته | بیشینه | میانگین | ارتفاع کل (متر) |
|---|-------|--------|-----------------|-----------------|
| (<i>F. orientalis</i> L.) راش | ۸/۹ | ۳۷/۶ | ۲۸/۸۴ ± ۱/۴۲ a | |
| (<i>C. betulus</i> L.) ممرز | ۱۱/۹ | ۲۸/۲ | ۲۳/۲۴ ± ۰/۸۱ b | |
| (<i>Q. castaneifolia</i> CA. May) بلوط | ۸/۶ | ۳۳/۸ | ۲۶/۰۹ ± ۱/۲۴ ab | |
| (<i>A. subcordata</i> L.) توسکا | ۸/۲ | ۳۱/۷ | ۲۶/۱۱ ± ۱/۰۵ ab | |
| دیگر گونه‌های درختان حجم (متر مکعب) | ۶/۳ | ۲۱/۵ | ۱۶/۶۹ ± ۰/۷۳ c | |
| (<i>F. orientalis</i> L.) راش | ۰/۰۲ | ۲۹/۹۶ | ۱۰/۱۱ ± ۱/۷۳ a | |
| (<i>C. betulus</i> L.) ممرز | ۰/۰۴ | ۲۶/۶۸ | ۹/۵۶ ± ۱/۶۳ a | |
| (<i>Q. castaneifolia</i> CA. May) بلوط | ۰/۰۶ | ۲۸/۹۳ | ۱۰/۵۶ ± ۱/۷۷ a | |
| (<i>A. subcordata</i> L.) توسکا | ۰/۰۳ | ۲۸/۳۷ | ۱۰/۲۳ ± ۱/۷۳ a | |
| دیگر گونه‌های درختان | ۰/۰۲ | ۲۳/۹۱ | ۸/۲۶ ± ۱/۴۶ a | |

حروف مشابه در هر سیزده نمونه نبود منفذ در سطح ۵ درصد است.

جدول ۲. نتایج مربوط به توابع و تپولوژی بهینه شبکه عصبی مصنوعی برای مدل‌سازی حجم توسط ارتفاع (m)

| مدل | تپولوژی شبکه | تابع انتقال | Epoch | R | AD |
|-----|----------------|-------------|-------|------|------|
| ۱ | ۱ → ۱ → ۱ → ۱ | g_Logs | ۱۴ | .۹۸۶ | ۱/۸۶ |
| ۲ | ۱ → ۱ → ۲ → ۱ | Tansig | ۲۴ | .۹۸۸ | ۱/۰۵ |
| ۳ | ۱ → ۱ → ۳ → ۱ | Logsig | ۱۰۷ | .۹۸۸ | ۱/ ۲ |
| ۴ | ۱ → ۱ → ۴ → ۱ | Tansig | ۲۰ | .۹۸۹ | .۶۷۶ |
| ۵ | ۱ → ۱ → ۱۰ → ۱ | Logsig | ۶۶ | .۹۹۱ | .۳۰۴ |
| ۶ | ۱ → ۱ → ۲۵ → ۱ | Tansig | ۱۷ | .۹۹۱ | .۲۳۳ |
| ۷ | ۱ → ۲ → ۲ → ۱ | Logsig | ۳۸ | .۹۸ | ۱/۲۸ |
| ۸ | ۱ → ۲ → ۵ → ۱ | Tansig | ۱۶ | .۹۸ | .۲۹۵ |
| ۹ | ۱ → ۲ → ۸ → ۱ | Logsig | ۲۹ | .۹۹۸ | .۱۶۴ |
| ۱۰ | ۱ → ۲ → ۱۵ → ۱ | Tansig | ۴۰ | .۹۹۵ | .۱۵۹ |
| | | Logsig | ۱۲ | .۹۸۸ | .۱۸۲ |
| | | Tansig | ۱۶ | .۹۸۹ | .۱۶۴ |
| | | Logsig | ۲۳ | .۹۸۸ | .۲۲۷ |
| | | Tansig | ۲۸۳ | .۹۸۷ | .۳۵۲ |
| | | Logsig | ۳۹ | .۹۸۸ | .۴۱۵ |
| | | Tansig | ۲۲ | .۹۹۵ | .۱۶۴ |
| | | Logsig | ۶۵ | .۹۸۸ | .۲۰۳ |
| | | Tansig | ۲۹ | .۹۹۵ | .۱۷۵ |
| | | Logsig | ۹ | .۹۸۸ | .۳۱۴ |
| | | Tansig | ۱۳ | .۹۹۲ | .۱۶۴ |



شکل ۱. میانگین مربعات خطای آموزش، اعتبار و آزمون تابع Tansig مدل (۵) براساس تعداد چرخش

جدول ۳. نتایج مربوط به توابع و توپولوژی بهینه شبکه عصبی مصنوعی برای مدلسازی حجم توسط قطر (cm)

| مدل | توپولوژی شبکه | تابع انتقال | Epoch | R | AD |
|-----|---------------|-------------|-------|--------|-------|
| ۱۱ | ۱→۱→۱→۱ | Logsig | ۵۱۵ | -۰/۹۸۸ | /۹۹۸ |
| ۱۲ | ۱→۱→۲→۱ | Tansig | ۴۱ | -۰/۹۸۶ | ۱/۱۶ |
| ۱۳ | ۱→۱→۳→۱ | Logsig | ۳۳۷ | -۰/۹۸۸ | ۰/۹۷۳ |
| ۱۴ | ۱→۱→۴→۱ | Tansig | ۱۹ | -۰/۹۸۹ | ۰/۲۲۱ |
| ۱۵ | ۱→۱→۱۰→۱ | Logsig | ۴۹ | -۰/۹۸۹ | ۰/۲۷۰ |
| ۱۶ | ۱→۱→۲۵→۱ | Tansig | ۱۵ | -۰/۹۸۹ | ۰/۱۸۲ |
| ۱۷ | ۱→۲→۲→۱ | Logsig | ۳۳ | -۰/۹۹۲ | ۰/۳۵۰ |
| ۱۸ | ۱→۲→۵→۱ | Tansig | ۲۴ | -۰/۹۹۲ | ۰/۱۹۵ |
| ۱۹ | ۱→۲→۸→۱ | Logsig | ۱۰۷ | -۰/۹۹۴ | ۰/۱۶۱ |
| ۲۰ | ۱→۲→۱۵→۱ | Tansig | ۳۵ | -۰/۹۸۸ | ۰/۲۸۶ |
| | | | | -۰/۹۹۴ | ۰/۱۵۸ |
| | | | | -۰/۹۹۱ | ۰/۱۶۰ |
| | | | | -۰/۹۸۷ | ۱/۴۹ |
| | | | | -۰/۹۸۸ | ۰/۴۱۰ |
| | | | | -۰/۹۹۲ | ۰/۱۸۶ |
| | | | | -۰/۹۸۸ | ۰/۱۷۹ |
| | | | | -۰/۹۹۵ | ۰/۱۵۶ |
| | | | | -۰/۹۸۸ | ۰/۱۸۶ |
| | | | | -۰/۹۹۵ | ۰/۱۶۰ |
| | | | | -۰/۹۹۲ | ۰/۳۷۶ |

توپولوژی کلیه مدل‌های مربوط به تابع Logsig و Tansig را به ترتیب همراه با تعداد چرخش، ضریب تبیین و میانگین انحراف معیار نشان می‌دهد.

شکل ۲ مقادیر دقت آموزش، اعتبار و آزمون داده‌های قطر مربوط به مدل ۱۹ با تابع Logsig را نشان می‌دهد.

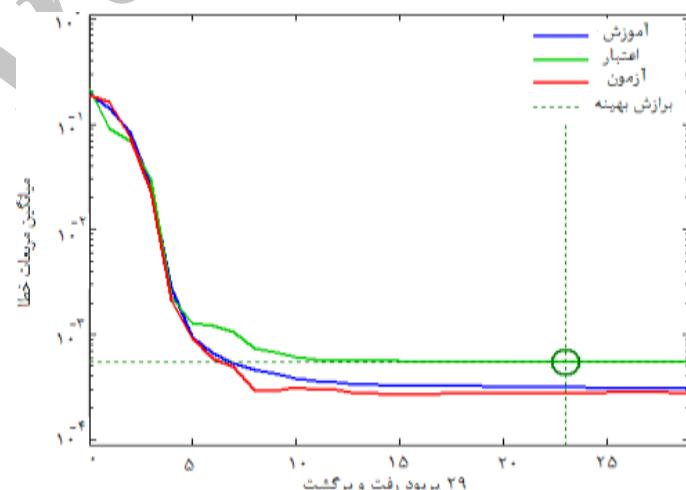
در گام دوم از کمیت قطر به عنوان متغیر ورودی برای پیش‌بینی پاسخ مورد بررسی استفاده شد. مطابق جدول ۳ نتایج نشان می‌دهد که در بین کلیه مدل‌های معرفی شده، توپولوژی مدل ۱۹ با تابع انتقال Logsig برای پیش‌بینی متغیر حجم به عنوان ساختار بهینه معرفی می‌شود. جدول ۳

مشاهده می‌شود مدل ۲۵ با استفاده ازتابع Logsig اگرچه ضریب تبیین کمتری را نسبت به مدل بهینه نشان می‌دهد، دارای خطای محاسباتی کمتری است. در این زمینه همان‌طور که پیشتر نیز اشاره شد، میانگین مربعات خطای آزمون مدل مذکور مقایسه شد و در نهایت نتایج نشان داد که خطای آزمون مدل ۳۰ نسبت به مدل مذکور کمتر است.

شکل ۳ سطح منحنی خطای آزمون مدل بهینه (مدل ۳۰) را نشان می‌دهد که با توجه به موارد معرفی شده قبلی، منحنی مدل مذکور سطح پایین‌تری را نشان می‌دهد و از این‌رو، به عنوان مدل بهینه اصلی در این تحقیق معرفی می‌شود.

البته در همه موارد در روند مدلسازی از ابر نقاط و برآش بین مشاهدات و مقادیر خروجی مدل علاوه بر معیارهای انتخابی مذکور استفاده شد تا در نهایت برای انتخاب مدل بهینه به بیشترین قطعیت دست یافت. از بین برآش بین مشاهدات و مقادیر تخمینی هر یک از مدل‌های بهینه، برآش بین حجم واقعی و حجم تخمینی مدل ۳۰ دارای حداقل ضریب تبیین تصحیح یافته ($R^2_{adj} = 0.99$) و حداقل اشتباہ معیار تخمین (SEE = ۰/۹۳۱) است (شکل ۴).

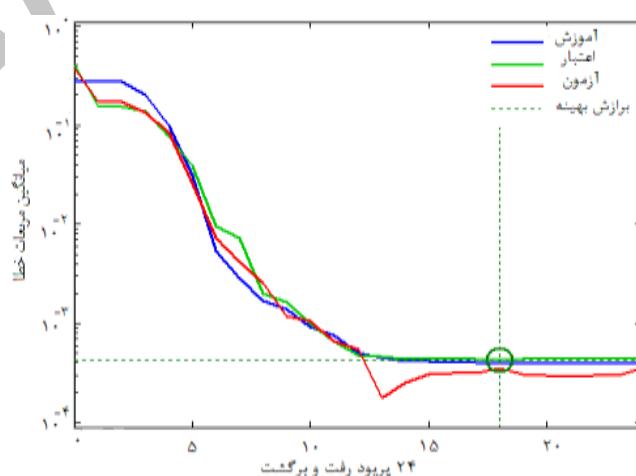
همان‌طور که مشاهده می‌شود شکل ۲ در قیاس با شکل قبلی مقدار خطای آزمون (MSE) کمتری دارد. از طرفی مقدار خطای محاسباتی (AD) آن بین مشاهدات و مقادیر تخمینی نسبت به مدل بهینه قبلی کمتر است، از این‌رو دارای قابلیت بیشتری برای پیش‌بینی متغیر پاسخ مورد بررسی محسوب می‌شود. در زمینه مدلسازی شبکه عصبی، مدل‌ها و ساختارهایی دارای قطعیت زیاد برای پیش‌بینی مقادیر پاسخ هستند که خطای آزمون داده‌های انتخابی مدل نسبت به آموزش و اعتبار دارای مقدار کمتر یا حداقل اختلاف باشد و علاوه‌بر آن مقدار آن نسبت به خطای آزمون دیگر مدل‌های مورد قیاس کمتر باشد [۸]. در گام آخر از متغیر قطر و ارتفاع به صورت همزمان برای مدلسازی استفاده شد (جدول ۴). در زمینه طراحی و معماری توپولوژی هر یک از توابع انتقال مورد اشاره، با توجه به امکان‌پذیر بودن از دامنه‌های متفاوت و وسیع تری از تعداد لایه‌ها و نورون‌ها استفاده شد. با توجه به جدول ۴ از معماری‌های جدیدی که دارای دقیقی مشابه با دیگر خروجی‌های مدل بودند نیز استفاده شد (مدل ۳۱-۳۴). در نهایت با توجه به نتایج مذکور، توپولوژی مدل ۳۰ حاوی تابع انتقال Logsig دارای حداقل دقت نسبت به کلیه مدل‌ها معرفی شد (جدول ۴). در جدول ۴ همان‌طور که



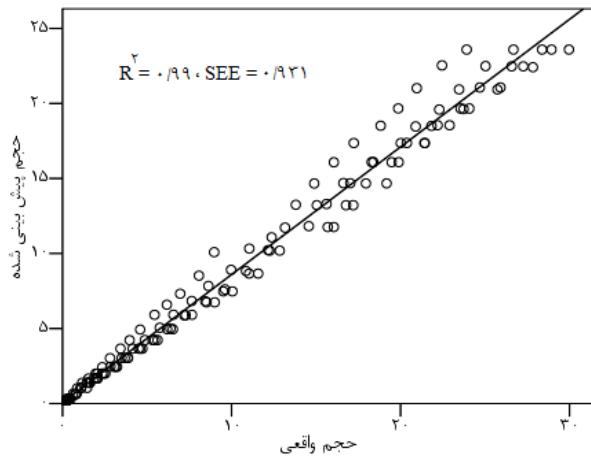
شکل ۲. میانگین مربعات خطای آموزش، اعتبار و آزمون تابع Logsig مدل (۱۹) براساس تعداد چرخش

جدول ۴. نتایج مربوط به توابع و توبولوژی شبکه عصبی مصنوعی برای مدلسازی حجم با قطر و ارتفاع

| AD | R | Epoch | تابع انتقال | توبولوژی شبکه | مدل |
|-------|-------|-------|-------------|----------------|-----|
| ۱/۷۱ | ۰/۹۸۸ | ۱۱ | Logsig | ۲ → ۱ → ۱ → ۱ | ۲۱ |
| ۱/۶۳ | ۰/۹۸۸ | ۱۲ | Tansig | | |
| ۰/۲۲۱ | ۰/۹۹۱ | ۱۲۶ | Logsig | ۲ → ۱ → ۲ → ۱ | ۲۲ |
| ۰/۵۹۹ | ۰/۹۹۱ | ۱۶۵ | Tansig | | |
| ۰/۲۵۵ | ۰/۹۹۲ | ۴۳ | Logsig | ۲ → ۱ → ۳ → ۱ | ۲۳ |
| ۰/۴۸۶ | ۰/۹۹۱ | ۷۴ | Tansig | | |
| ۰/۲۵۵ | ۰/۹۹۱ | ۱۷ | Logsig | ۲ → ۱ → ۴ → ۱ | ۲۴ |
| ۰/۳۳۳ | ۰/۹۹۱ | ۳۴ | Tansig | | |
| ۰/۱۵۶ | ۰/۹۹۵ | ۴۷ | Logsig | ۲ → ۱ → ۱۰ → ۱ | ۲۵ |
| ۰/۲۲۱ | ۰/۹۹۱ | ۱۶ | Tansig | | |
| ۰/۳۲۵ | ۰/۹۸۹ | ۱۰ | Logsig | ۲ → ۱ → ۲۵ → ۱ | ۲۶ |
| ۰/۲۳۵ | ۰/۹۹۳ | ۹ | Tansig | | |
| ۰/۵۵۰ | ۰/۹۸ | ۳۰۱ | Logsig | ۲ → ۲ → ۲ → ۱ | ۲۷ |
| ۰/۲۷۱ | ۰/۹۸ | ۱۹۶ | Tansig | | |
| ۰/۱۶۴ | ۰/۹۹۱ | ۹۸ | Logsig | ۲ → ۲ → ۵ → ۱ | ۲۸ |
| ۰/۱۷۸ | ۰/۹۹۱ | ۶۵ | Tansig | | |
| ۰/۱۷۱ | ۰/۹۹۵ | ۲۷ | Logsig | ۲ → ۲ → ۸ → ۱ | ۲۹ |
| ۰/۲۲۸ | ۰/۹۹۲ | ۹ | Tansig | | |
| ۰/۱۵۸ | ۰/۹۹۷ | ۲۴ | Logsig | ۲ → ۱ → ۱۵ → ۱ | ۳۰ |
| ۰/۱۶۸ | ۰/۹۹۲ | ۲۱ | Tansig | | |
| ۰/۱۹۹ | ۰/۹۹۵ | ۳۱ | Logsig | ۲ → ۲ → ۱۵ → ۱ | ۳۱ |
| ۰/۲۰۵ | ۰/۹۹۱ | ۲۶ | Tansig | | |
| ۱/۰۷ | ۰/۹۸۸ | ۱۶ | Logsig | ۲ → ۱ → ۵ → ۱ | ۳۲ |
| ۰/۲۵۳ | ۰/۹۹۱ | ۵۷ | Tansig | | |
| ۰/۲۲۰ | ۰/۹۸۹ | ۳۰ | Logsig | ۲ → ۳ → ۲۰ → ۱ | ۳۳ |
| ۰/۱۷۷ | ۰/۹۹۲ | ۱۵ | Tansig | | |
| ۰/۱۸۴ | ۰/۹۹۲ | ۴۰ | Logsig | ۲ → ۱ → ۲۰ → ۱ | ۳۴ |
| ۰/۱۸۵ | ۰/۹۹۲ | ۱۳ | Tansig | | |



شکل ۳. میانگین مربعات خطای آموزش، اعتبار و آزمون تابع Logsig مدل (۳۰) براساس تعداد چرخش



شکل ۴. برآژش بین مقادیر حجم واقعی و پیش‌بینی شده در رابطه باتابع بهینه مدل ۳۰

پاسخگو با دقت هر چه بیشتر، وجود همبستگی زیاد بین متغیرهای عامل و پاسخ می‌باشد [۱۴]. قطر و ارتفاع درختان در واقع پارامترهای محاسباتی حجم درختان بوده و از این‌رو همبستگی بین قطر و ارتفاع در ویژگی هندسی حجم درختان بدیهی است. بهمین دلیل قطر و ارتفاع درختان به عنوان متغیرهای ورودی برای راهاندازی شبکه عصبی در پژوهش حاضر معرفی شدند. نتایج تحقیق حاضر در مقایسه با مدل‌سازی شبکه عصبی توسط بیاتی و نجفی با استفاده از قطر و ارتفاع کل، نتایج مهمی را نشان داد، به‌طوری که حداقل ضریب تبیین در پژوهش ایشان ($R^2 = 0.84$) و حداقل خطای $(RMSE = 1.78)$ بود [۲]. در قیاس با نتایج تحقیق حاضر، آنها از شبکه عصبی چندلایه پرسپترون با تابع انتقال Sigmoid و شبکه تابع شعاع مدار با تابع انتقال Softmax استفاده کردند. البته بیاتی و نجفی با افزایش دیگر کمیت‌های بیوفیزیکی (قطر در انتهای تنه، قطر در ارتفاع کنده و ارتفاع تنه) علاوه بر قطر برابر سینه و ارتفاع کل در مدل‌سازی شبکه‌های عصبی نشان دادند که دقت پیش‌بینی تابع انتقال Softmax تا حداقل ضریب تبیین 0.95 و مقدار خطای 1.05 است [۲]. در تحقیق حاضر سعی شد توپولوژی یکسان برای تابع انتقال Logsig و Tansig استفاده شود تا مقدار دقت رسیدن به پاسخ هر یک به روشنی مقایسه شود. اختلاف دقت به‌دست‌آمده در این

همان‌طور که در جدول‌های بالا مشاهده می‌شود، به‌منظور دستیابی به حداقل دقت پیش‌بینی، تعداد تکرار در هر یک از مدل‌ها فرق دارد. به همین دلیل علاوه بر ضریب تبیین به‌دست‌آمده، از میانگین مربعات خطای آزمون هر یک از مدل‌ها استفاده می‌شود [۸]. بدیهی است که در جنگل‌های طبیعی در اکثر موارد بین قطر و ارتفاع همبستگی وجود دارد [۸] که در تحلیل رگرسیون چندگانه در صورت معرفی متغیرهای مستقل، همبستگی مذکور سبب افزایش فاکتور تورم واریانس (VIF) می‌شود. به‌طور معمول در شبکه عصبی، هم خطی چندگانه و خودهمبستگی بین متغیرها مؤثر نیست و علاوه‌بر آن، نوع روابط بین هر یک از متغیرهای ورودی و خروجی (خطی یا غیرخطی) نیز تصحیح می‌شود [۷]. در این مورد می‌توان به مطالعات فودی و همکاران برای برآورد زی توده روی زمینی گیاهان اشاره کرد که نتیجه‌گیری کردن بین برآورد زی توده روی زمینی گیاهان و مشاهدات با استفاده از شاخص‌های گیاهی، علی‌رغم همبستگی قوی بین متغیرهای توصیفی (شاخص‌های مذکور) حداقل خطای وجود داشت و مدل‌های ارائه‌شده با بیشترین ضریب تبیین دارای حداقل قطعیت تخمین بود [۱۳]. عزیزی قلاتی و همکاران در پژوهش خود اشاره کردند که یکی از مهم‌ترین اصول برای راهاندازی شبکه عصبی مصنوعی و دستیابی به مدل

[۱۵]. نکته شایان توجه این است که در شبکه‌های از نوع پس انتشار خطأ، قاعده مشخصی برای انتخاب تعداد لایه‌های پنهان و همچنین تعداد نورون‌ها در لایه پنهان وجود ندارد. در واقع روش عمومی برای بدست آوردن آنها، آزمون و خطأ و البته تجربیات دیگر محققان است [۱۶]. البته هر یک از مدل‌های ارائه شده در شبکه عصبی مصنوعی در قالب جعبه سیاه ذخیره‌سازی می‌شوند که با دسترسی به آن می‌توان با استفاده از متغیرهای توصیفی معرفی شده در این تحقیق (قطر و ارتفاع) مقادیر حجم صنعتی را در مقیاس وسیعی از توده‌های آمیخته راش در شرایط رویشگاهی و ترکیب گونه‌ای مشابه استفاده کرد.

نتیجه‌گیری

نتایج پژوهش حاضر نشان داد که شبکه عصبی می‌تواند با توجه به مقادیر مختلف وزن‌دهی متغیرهای ورودی و پس انتشار میزان خطأ سبب حداکثر دقت پیش‌بینی مقادیر پاسخ مورد بررسی شود. از این‌رو مدل‌های بهینه ارائه شده در پژوهش حاضر می‌تواند مبنای برآورد حجمی درختان سرپا براساس متر مکعب در جنگل مورد تحقیق محسوب شود.

References

- [1]. Namiranian, M. (2010). measurement of tree and forest biometry. University of Tehran Press, Tehran.
- [2]. Bayati, H., and Najafi, A. (2013). Performance Comparison Artificial Neural Networks with Regression Analysis in Trees Trunk Volume Estimation. Journal of Forest and Wood Products, 66 (2): 177-191.
- [3]. Ozcelik, R., Diamantopoulou, M.J., Brooks, JR., and Wiant Jr, HV. (2010). Estimating tree bole volume using artificial neural network models for four species in Turkey. Journal of Environmental Management, 91(3): 742-753.
- [4]. Atkinson, P.M., and Tatnall, A.R.L. (1997). Introduction neural networks in remote sensing. International Journal of Remote Sensing, 18(4): 699-709.
- [5]. Coulson, R.N., Folse, L.J., and Loh, D.K. (1987). Artificial intelligence and natural resource management. Science, (237): 262-267.
- [6]. Lek, S., Delacoste, M., Baran, P., Dimopoulos, I., Lauques, J., and Aulagnier, S. (1996). Application of neural networks to modelling nonlinear relationships in ecology. Ecological Modelling, 90(1): 39-52.
- [7]. Hagan, M.T., Demuth, H.B., and Beale, M.H. (1996). Neural Network design. PWS publishing co, United States of America.
- [8]. Tiryaki, S., and Aydin, A. (2014). An artificial neural network model for predicting compression strength of heat treated woods and comparison with a multiple linear regression model. Construction and Building Materials, 62: 102-108.

پژوهش با دقت تخمین برآورده در پژوهش بیاتی و نجفی را می‌توان به عواملی چون اختلاف کلیه شرایط رویشگاهی، مراحل توالی، فازهای تحولی جنگل‌های تحت بررسی و تفاوت توپولوژی‌های طراحی شده شامل توابع انتقالی شبکه عصبی مصنوعی ربط داد [۲]. نقدی و قجر نیز در زمینه کاربرد شبکه عصبی مصنوعی در مدل‌سازی زمان چوبکشی در سیستم بهره‌برداری از شبکه پیش‌خور با الگوریتم پس انتشار خطأ از توابع Logsig و Tansig با توپولوژی مختلف برای الگوریتم آموزش استفاده کردند و در نتایج نهایی خود عنوان کردند که شبکه عصبی مصنوعی در رابطه با تخمین زمان سیکل چوبکشی دارای دقت زیادی است [۱۱]. در این رابطه، بیاتی و همکاران برای ارزیابی کارایی شبکه عصبی مصنوعی در مدل‌سازی زمان عملیات وینچینگ در جنگل‌های شمال به این نتیجه رسیدند که شبکه تابع شعاع‌مدار در مقایسه با پرسپکترون چندلایه در پیش‌بینی زمان وینچینگ دارای دقت بیشتری است. ایشان اذعان کردند که استفاده از تابع شعاع‌مدار در زمانی که بردارهای آموزشی بسیار زیادند بهترین کارایی و حداکثر قابلیت پاسخ را در مقابل سایر شبکه‌های تعریف شده دارند.

- [9]. Hamzacebi, C., Akay, D., and Kutay, F. (2009). Comparison of direct and iterative artificial neural network forecast approaches in multi-periodic time series forecasting. *Expert Systems with Application*, 36(2): 3839-3844.
- [10]. Anonymous. (2008). Glandrood Forest management project, district3, Noor, Mazandarn (second renewal view). General Office of Natural Resources and Watershed Management of Mazandaran province, Nowshahr, 174 p.
- [11]. Naghdi, R., and Ghajar, I. (2012). Application of Artificial Neural Network in the Modeling of Skidding Time Prediction. *Advanced Materials Research*, 403-408: 3538-3543.
- [12]. Woods, K., and Bowyer, K.W. (1997). Generating ROC Curves for Artificial Neural Networks. *IEEE Transactions on Medical Imaging*, 16(3): 329-337.
- [13]. Foody, G.M., Boyd, D.S., and Cutler, M.E.J. (2003). Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. *Remote Sensing of Environment*, 85(4): 463-474.
- [14]. Azizi Ghalaty, S., Rangzan, K., Taghizadeh, A., and Ahmady, Sh. (2015). Application of artificial neural network and ordinary least squares regression in modeling land use changes. *Journal of forest and wood products*, (68)1: 1-16.
- [15]. Bayati, H., Najafi, A., and Abdolmaleki, P. (2016). Assessment of artificial neural networks ability in winching time study of Timber Jack 450C. *Journal of Forest and Wood Products*, (68)4: 757- 769.
- [16]. Feiznia, S., Mohammad Asgari, H., and Moazzami, M. (2008). Investigating the applicability of Neural Network method for estimating daily suspended sediment yield (Case study: Zard Drainage Basin, Khozestan Province). *Journal of the Iranian Natural Resources*, 60(4): 1199-1210.

Modeling the commercial volume of trees in mixed beech stands of Hyrcanian forests through artificial neural network

A. Vahedi*; Ph.D. in Forestry, Research Institute of Forests and Rangelands, Agricultural Research Education and Extension Organization (AREEO), Tehran, I.R. Iran

A. Mataji; Prof., Department of Forestry, Science and Research Branch, Islamic Azad University, Tehran, I. R. Iran

R. Akhavan; Assoc. Prof., Forestry, Research Institute of Forests and Rangelands, Agricultural Research Education and Extension Organization (AREEO), Tehran, I.R. Iran

(Received: 19 February 2015, Accepted: 15 November 2015)

ABSTRACT

Predicting the volume of standing trees precisely is the basis of growth rate, amount of allowable harvesting, aboveground biomass carbon sequestration, and the foundation of optimal management according to the sustainable development. New technology of artificial intelligence including artificial neural network (ANN) was applied for modelling and predicting the commercial volume of measured trees in district 3 of Glandroud forests. The data of renewed volume table was acquired from bureau of natural resources and watershed management of Mazandaran province, Nowshahr. Diameter and total height of 150 fallen trees were used as inputs to develop the stage-wise modeling by feed forward back-propagation (FFBP). Two non-linear functions, Logsig and Tansig, were applied as transfer functions. Each function with the same topology showed the different outputs having different accuracies. After initial weighting and training algorithm, transfer functions of neurons had different rotation for decreasing the errors. After each trial, which led to various topology functions, the result showed that the model including diameter and total height with transfer function of Logsig, topology of one hidden layer and fifteen neurons, was the best model to predict the volume of trees in this study. The mentioned model provided the considerable accuracy with the highest coefficient of determination ($R^2 = 0.99$), the least mean squared error of test (MSE) and the least average deviation (AD = 0.158).

Keywords: Artificial neural network, Commercial volume, Mixed beech stands, Transfer function.

* Corresponding Author, Email: ali.vahedi60@gmail.com, Tel: +982144787283