

مقایسه عملکرد شبکه‌های عصبی مصنوعی با تحلیل رگرسیون در برآورد حجم تنه درختان

♦ هادی بیاتی؛ کارشناس ارشد مهندسی جنگل، دانشکده منابع طبیعی، دانشگاه تربیت مدرس
♦ اکبر نجفی؛ استادیار گروه جنگلداری دانشکده منابع طبیعی، دانشگاه تربیت مدرس (نویسنده مسئول)

چکیده

آنالیز رگرسیون روش رایجی است که امروزه برای برآورد حجم تنه درختان استفاده می‌شود. این روش با تعیین رابطه‌ای، حجم را با دقت خاصی برآورد می‌کند، اما محدودیت‌هایی مانند نرمال بودن متغیر وابسته و همگن بودن واریانس خطاها نیز دارد. در این پژوهش سعی شده از شبکه‌های عصبی مصنوعی (ANN)، به‌عنوان یکی از زیرمجموعه‌های فناوری جدید هوش مصنوعی (AI)، به‌منظور برآورد حجم تنه، استفاده شود. بدین منظور، تعداد ۱۰۱ درخت از درختان نشانه‌گذاری شده جنگل آموزشی-پژوهشی دانشگاه تربیت مدرس انتخاب، و قطر برابر سینه، قطر در ارتفاع کنده، قطر انتهای تنه، ارتفاع تنه، و ارتفاع کل درخت، با دقت بسیار اندازه‌گیری شدند. از دو مدل شبکه عصبی، پرسپترون چندلایه (MLP) و تابع پایه شعاعی (RBF)، به‌منظور پیش‌بینی حجم تنه استفاده شد. نتایج نشان داد با افزایش متغیرهایی که همبستگی بیشتری با حجم تنه دارند، ضریب تشخیص شبکه عصبی از ۰/۸۰ به ۰/۹۵ افزایش می‌یابد. شبکه عصبی تابع پایه شعاعی در مقایسه با شبکه عصبی پرسپترون چندلایه دقت بیشتری در برآورد حجم تنه دارد. مقایسه معیارهای ارزیابی شبکه عصبی مصنوعی با رگرسیون گام‌به‌گام نشان داد که شبکه عصبی MLP و RBF به ترتیب دارای مقدار RMSE ۱/۱۸ و ۱/۰۵ است، درحالی که مقدار RMSE مدل رگرسیون ۲/۵۷ می‌باشد. ضریب تشخیص رگرسیون در مقایسه با هر دو مدل شبکه عصبی نیز مقدار کمتری است.

واژگان کلیدی: برآورد حجم تنه درخت، بهره‌برداری جنگل، پرسپترون چندلایه، مدیریت جنگل، تابع پایه شعاعی، رگرسیون، هوش مصنوعی.

مقدمه

حجم درخت از مشخصه‌های پرکاربرد در جنگل است که در این زمینه می‌توان به مواردی چون حاصلخیزی و روند بهبود یا تخریب رویشگاه، میزان مجاز برداشت، میزان رویش، مبنای خرید و فروش، و مدیریت جنگل اشاره کرد [۱]. هرچه حجم محاسبه شده دقیق‌تر باشد، نتایج حاصل از کاربرد آن نیز دقیق‌تر و معتبرتر خواهد بود. اغلب آماربرداران جنگل، درگیر اندازه‌گیری درختان نمونه به منظور محاسبه حجم‌اند که اغلب فعالیتی زمان‌بر و در نتیجه هزینه‌بر است [۲]. به همین منظور، روابط ریاضی گوناگونی چون نیوتن، هوبر، اسمالین، و پرسلر برای اندازه‌گیری حجم درختان به کار گرفته شد. در این روابط، حجم با استفاده از مجموعه متغیرها مانند قطر در ارتفاع‌های مختلف، محاسبه می‌شود. برای برآورد حجم تنه در مقیاس‌های وسیع‌تر از تک‌درخت، از روش‌های مختلفی استفاده می‌شود. یکی از این روش‌ها استفاده از تحلیل رگرسیون است، که دارای محدودیت‌هایی مانند نرمال بودن متغیر وابسته، همگن بودن واریانس خطاها، و نبود رابطه هم‌خطی بین متغیرهای مستقل است [۳].

مدیران و محققان منابع جنگلی سال‌هاست در پیش‌بینی و مدیریت و اتخاذ تصمیم از ابزاری چون مدل‌های تجربی آماری و مدل‌های ریاضی بهره می‌گیرند [۴]. بر اساس تحقیق گیمبلت و بل (۱۹۹۵) اتخاذ تصمیم در منابع طبیعی اغلب با پیچیدگی‌هایی فراتر از روش‌های تجربی آماری روبه‌رو می‌شود که نیازمند رهیافت‌هایی است که گاهی بیشتر ابتکاری است تا الگوریتمی [۵]. در بسیاری از موارد، روش‌های معمول آماری قادر به حل مسائل مدیریت منابع جنگلی نیست. کولسون و همکاران (۱۹۸۷) برای اولین بار هوش مصنوعی^۱ در مدیریت منابع طبیعی و جنگل را در توسعه سیستم‌های خبره در حل مسئله و اتخاذ تصمیم و پس از آن به‌عنوان روشی جایگزین در مدل‌سازی پدیده‌های غیر خطی و پیچیده علم جنگل به کار گرفتند [۵، ۷، ۸، ۹]. امروزه، شبکه‌های عصبی مصنوعی^۲، به

عنوان زیرمجموعه‌ای از روش‌های هوش مصنوعی، با ساختار و عملکردی شبیه به مغز انسان که اجزایی به نام نود یا نورون دارد [۱۰] در طیف وسیعی برای حل بسیاری از مسائل، شامل ارزیابی، بهینه‌سازی، پیش‌بینی، تشخیص، و کنترل رایج شده‌اند. به هر مجموعه از این نورون‌ها یک لایه گفته می‌شود. شبکه عصبی معمولاً از سه لایه ورودی، پنهان، و خروجی تشکیل شده است [۱۱، ۱۲]. لایه ورودی فقط اطلاعات را دریافت و مشابه متغیر مستقل عمل می‌کند. لایه خروجی نیز مانند متغیر وابسته عمل می‌کند و تعداد نورون‌های آن به تعداد متغیر وابسته بستگی دارد. لایه پنهان، که در اصطلاح به آن جعبه سیاه شبکه عصبی نیز گفته می‌شود، اصلی‌ترین بخش پردازش شبکه عصبی است که شامل چند لایه و نورون‌های متنوع است. هر دو لایه از یک شبکه به کمک وزن‌ها و در واقع اتصالات با هم ارتباط می‌یابند. روش شبکه عصبی مصنوعی به دو صورت نظارت‌شده و نظارت‌نشده عمل می‌کند. در شبکه نظارت‌شده، ورودی به سیستم اعمال و اختلاف بین خروجی شبکه و خروجی مطلوب برای تنظیم وزن‌ها به کار می‌رود. در صورتی که در شبکه نظارت‌نشده شبکه خود را متناسب با داده‌های ورودی منطبق می‌کند [۱۳]. (۲۰۰۹) کاوزوگلو در بررسی‌های خود به این نتیجه رسید که استفاده از داده‌های مناسب و دقیق در آموزش شبکه در به‌دست‌آوردن نتایج درست و بسیار دقیق و واقعی‌تر کمک می‌کند.

از مهم‌ترین ویژگی‌های شبکه‌های عصبی مصنوعی وابسته‌نبودن آن‌ها به فرضیه‌های اولیه درباره داده‌های ورودی است؛ به این معنا که داده‌های ورودی می‌توانند هرگونه توزیع آماری دلخواهی داشته باشند [۱۴]. این ویژگی مهم شبکه‌های عصبی امتیاز ویژه آن‌ها در مقابل روش‌های آماری است و به آن‌ها این توانایی را می‌دهد که به طور یکسان از انواع مختلف داده‌های ورودی با هر توزیع دلخواه استفاده کنند [۱۵]. همچنین با داشتن قابلیت‌های بسیار دیگری مانند سرعت پردازش

لایه پنهان یک انطباق غیر خطی بین فضای ورودی و یک فضا (معمولاً) با بعد بزرگتر برقرار می کند که در آن الگوها به صورت تفکیک پذیر خطی درمی آیند. سرانجام، لایه خروجی، جمع وزنی را به همراه یک خروجی خطی تولید می کند. توابع فعال سازی مختلفی در این نوع شبکه وجود دارد که رایج ترین آن تابع گوسی است.

این ابزار در سال های اخیر کاربرد فراوانی در علوم مختلفی چون منابع طبیعی پیدا کرده که می توان به مواردی مانند پیش بینی تپ پوشش جنگلی با استفاده از متغیرهای کارتوگرافی [۱۹]، پیش بینی سن جنگل های سوزنی برگ در جنوب برزیل با استفاده از تصاویر TM [۲۰]، برآورد مرگ و میر توده های *Picea abies* [۲۱]، پیش بینی توزیع قطری جنگل کاری های گونه *Pinus palustris* [۲۲]، برآورد حجم پوست درخت *Pinus brutia* [۲۳]، ارزیابی خطر بادافتادگی در بخش های مختلف جنگل های جنوب غربی آلمان [۲۴]، مطالعه عامل های مؤثر در زمان قطع درخت [۲۵]، برآورد حجم تنه گونه های *Pinus brutia*، *Pinus sylvestris*، *Cedrus libani* A. Rich و *Abies cilicica* Carr [۲۶]، برآورد مشخصه تراکم درختان جنگل [۲۶]، پیش بینی تعداد درختان آسیب دیده در عملیات قطع و وینچینگ با استفاده از شبکه عصبی MLP و RBF در جنگل های شرکت نکا چوب [۲۷]، پیش بینی زمان خالص قطع درخت با استفاده از شبکه پرسپترون چندلایه و تابع شعاع مدار، و نیز روش رایج تحلیل رگرسیون [۲۸]، اشاره کرد.

با توجه به مطالب گفته شده در مورد قابلیت های شبکه عصبی مصنوعی، در این پژوهش، از این روش نوین در برآورد حجم تنه درختان (از بالای کنده تا محل ظهور اولین شاخه ها) [۲۹] استفاده شد و دقت آن با دو روش توأم و گام به گام رگرسیون چندمتغیره بررسی شد.

بالا (به سبب پردازش های موازی)، داشتن توان بالقوه در حل مسائلی که شبیه سازی آن ها از طریق منطقی یا سایر روش ها مشکل یا غیر ممکن است، کارآمد بودن شبکه برای یادگیری و انطباق با محیط در صورت تغییر در موقعیت محیطی، عدم از کارافتادگی شبکه در صورت آسیب دیدگی قسمتی از نورون ها و داشتن جواب منطقی برای داده های در شرایط اطمینان (اعم از آنکه فازی باشند یا به طور ناقص و توأم با دریافت نویز دریافت شده باشند)، علاقه مندی به استفاده از این روش را بیشتر می کند [۱۶].

یکی از شبکه های عصبی پر کاربرد در مدیریت منابع طبیعی شبکه عصبی پیش خور^۱ با الگوریتم پس انتشار خطا^۲ (شبکه چندلایه پرسپترون (MLP)^۳) است [۱۷]. یک پرسپترون، برداری از ورودی های با مقادیر حقیقی را می گیرد و یک ترکیب خطی از این ورودی ها را محاسبه می کند. اگر حاصل از یک مقدار آستانه بیشتر بود، خروجی پرسپترون برابر با ۱، و در غیر این صورت، معادل ۰ خواهد بود [۱۸]. Sigmoid از معروف ترین توابع فعالیت در این نوع شبکه است.

یکی دیگر از مهم ترین گونه های شبکه عصبی تابع شعاع مدار RBF^۴ است. این شبکه با توجه به کاربردهای متنوعش به یکی از معروف ترین شبکه های عصبی تبدیل شده و مهم ترین رقیب MLP محسوب می شود. این شبکه ها بیشتر از روش های آماری طبقه بندی الگو گرفته اند [۱۸]. این نوع شبکه به نورون های بیشتری نیاز دارد، اما حس نشان در زمان طراحی کوتاه تر آن ها در مقایسه با شبکه های استاندارد پس انتشار است. این شبکه ها زمانی که بردارهای آموزشی بسیار زیادند، بهترین کارایی را دارند [۱۷].

معماری اصلی RBF مانند MLP از سه لایه ورودی، پنهان، و خروجی تشکیل شده است؛ با این تفاوت که در این نوع شبکه فقط یک لایه پنهان وجود دارد. این

1. Feed Forward
2. Back-Propagation
3. Multi Layer Perceptron
4. Radial Basis Function

روش شناسی

منطقه مورد مطالعه و جمع‌آوری داده‌ها

این تحقیق در جنگل آموزشی-پژوهشی دانشکده منابع طبیعی دانشگاه تربیت مدرس در عرض جغرافیایی $36^{\circ}29'$ تا $36^{\circ}32'$ شمالی و طول جغرافیایی $51^{\circ}43'$ تا $51^{\circ}47'$ شرقی و در دامنه ارتفاعی ۷۵۰ تا ۱۱۰۰ متر ارتفاع از سطح دریا و در پارسل‌های ۳۱۳ و ۳۱۴ انجام شد.

تعداد ۱۰۱ درخت از درختانی که در پارسل‌های ۳۱۳ و ۳۱۴ برای قطع نشانه‌گذاری شده بودند، انتخاب شدند و پارامترهای ارتفاع کل، ارتفاع تنه، و قطر درخت در ارتفاع کنده و ارتفاع برابر سینه و ارتفاع بالای تنه، اندازه‌گیری شدند. به منظور اندازه‌گیری پارامترهای قطر درخت در ارتفاع کنده و ارتفاع برابر سینه و ارتفاع بالای تنه، از تک‌تک درختان با استفاده از یک دوربین عکاسی ۶ مگا پیکسلی و با استفاده از یک شاخص، عکس تهیه شد. ارتفاع کل و طول تنه درختان با استفاده از دستگاه ارتفاع‌سنج لیزری VERTEX L400، و فاصله تا درخت در سطح افق با استفاده از متر لیزری و همچنین قسمت صوت‌سنج دستگاه VERTEX تا دقت صدم متر اندازه‌گیری شد. تصاویر تهیه‌شده وارد نرم‌افزار Image Tools شد و قطر بالای تنه، قطر برابر سینه، و قطر در ارتفاع کنده، با استفاده از رابطه ۱ محاسبه گردید.

$$d = \left(\frac{X_i \times L}{50} \right) \times 100 \quad (1)$$

در این رابطه، d قطر به سانتی‌متر، X_i طول اندازه‌گیری‌شده در نرم‌افزار برای قطر هر درخت به سانتی‌متر، و L فاصله تا درخت به متر است. حجم تنه تک‌تک درختان نیز پس از قطع شدن از سوی گروه تجدید حجم در جنگل محاسبه شد و به‌عنوان متغیر وابسته در تعیین رابطه‌ها به کار رفت.

به منظور ارزیابی دقت شبکه عصبی مصنوعی در برآورد حجم تنه درخت، حجم تنه هر درخت با استفاده

از تحلیل رگرسیون چندمتغیره و روش گام‌به‌گام برآورد شد و با استفاده از معیارهای مجذور میانگین مربعات خطا (RMSE)، ضریب تغییرات مجذور میانگین مربعات خطا (CV(RMSE))، و ضریب تشخیص (R²) اعتبار هر روش بررسی شد. البته شایان ذکر است که ۳۰ درصد از داده‌ها از قبل و به منظور اعتبارسنجی تحلیل رگرسیون کنار گذاشته شده بودند و وارد مدل نشدند.

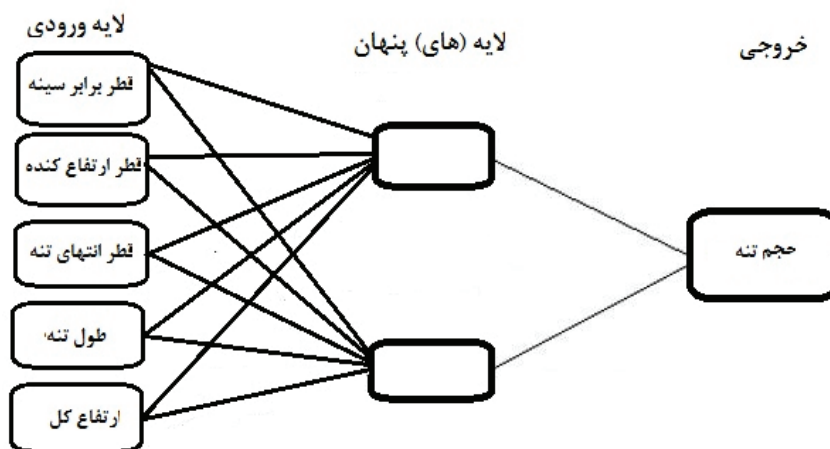
در طراحی شبکه عصبی مصنوعی، تمامی داده‌ها به منظور افزایش دقت و سرعت در آموزش شبکه، ابتدا با استفاده از رابطه (۲) استاندارد شد؛ به طوری که تمامی داده‌ها بین ۱ و ۰ قرار گرفتند.

$$Z = \frac{(X_i - X_{\min})}{X_{\max} - X_{\min}} \quad (2)$$

در این رابطه، Z داده استاندارد شده، X_i داده مورد استفاده، و x_{\max} و x_{\min} به ترتیب بیشترین و کمترین داده در هریک از متغیرهاست. سپس سعی بر این شد داده‌ها به صورت تصادفی به دو دسته آموزش (۷۰ درصد داده‌ها) و آزمون (۳۰ درصد داده‌ها) تقسیم شوند؛ به طوری که بیشترین و کمترین داده در دسته آموزش قرار گیرد. متغیرهای قطر کنده (D₁)، قطر برابر سینه (D₃₀)، قطر بالای تنه (D_{top})، ارتفاع کل (H_{total})، و ارتفاع تنه (H_{trunk}) به‌عنوان ورودی‌های شبکه، و متغیر حجم تنه به‌عنوان خروجی شبکه، در نظر گرفته شدند (شکل ۱). در این مطالعه، از دو شبکه عصبی RBF و MLP استفاده شد. با توجه به اینکه در روش گام‌به‌گام تحلیل رگرسیون متغیرها به ترتیب اهمیت وارد مدل‌ها می‌شوند، بنابراین، به منظور مقایسه بیشتر دو نوع شبکه عصبی با تحلیل رگرسیون، متغیرهای قطر برابر سینه، ارتفاع کل، قطر در ارتفاع کنده، ارتفاع تنه، و قطر در انتهای تنه، به ترتیب و با توجه به راحتی اندازه‌گیری آن‌ها در جنگل، وارد تحلیل شبکه عصبی شدند و اعتبار هریک بر اساس معیارهای ذکر شده بررسی شد. برای

حجم تنه برآوردی و داده حجم تنه واقعی به کمترین حد خود برسد. به منظور بررسی و تحلیل داده ها از نرم افزارهای SPSS MATLAB، ۲۰۱۱a، و Excel، ۲۰۰۷ استفاده شد.

آموزش شبکه از الگوریتم پس انتشار خطا استفاده شد. توابع انتقال مناسب، تعداد لایه های پنهان، و تعداد نورون های هر لایه نیز با آزمون و خطا تعیین شدند و این روند تا زمانی ادامه یافت که خطای بین داده



شکل ۱. نمایش ساختار شبکه

نتایج

آمار توصیفی هریک از متغیرها در جدول ۱ ارائه شده است. آزمون همبستگی نشان می دهد بین متغیر وابسته حجم تنه و متغیرهای مستقل قطر برابر سینه، قطر در ارتفاع کنده، قطر در انتهای تنه، طول تنه، و ارتفاع کل، همبستگی مثبت معناداری در سطح ۱ درصد وجود دارد (جدول ۲).

آمار توصیفی هریک از متغیرها در جدول ۱ ارائه شده است. آزمون همبستگی نشان می دهد بین متغیر وابسته حجم تنه و متغیرهای مستقل قطر برابر سینه، قطر در ارتفاع کنده، قطر در انتهای تنه، طول تنه، و ارتفاع کل، همبستگی مثبت معناداری در سطح ۱ درصد وجود دارد (جدول ۲).

جدول ۱. آمار توصیفی متغیرها

متغیر	میانگین	واریانس	حداقل	حداکثر
H Total (m)	۲۷/۰۱	۵۲/۷	۱۱/۸	۴۵/۴
H Trunk (m)	۱۶/۳۶	۳۰/۴	۶/۷	۳۰/۷
D.3 (m)	۰/۸۴	۰/۰۸	۰/۳۹	۲/۰۳
D1.30 (m)	۰/۷۲	۰/۰۶	۰/۳۲	۱/۶
D top (m)	۰/۳۸	۰/۰۳	۰/۱۵	۰/۳۷
V (m ³)	۳/۹۴	۱۰/۶۶	۰/۶۶	۲۱/۵۷

جدول ۲. ضریب همبستگی (r) بین متغیرها

متغیر	ارتفاع کل درخت (H Total)	ارتفاع تنه (H Stem)	قطر در ارتفاع کنده (D.3)	قطر برابر سینه (D 1.30)	قطر در انتهای تنه (D Top)
حجم تنه	۰/۴۱۲**	۰/۳۲۴**	۰/۸۰۹**	۰/۷۹۵**	۰/۵۶۴**

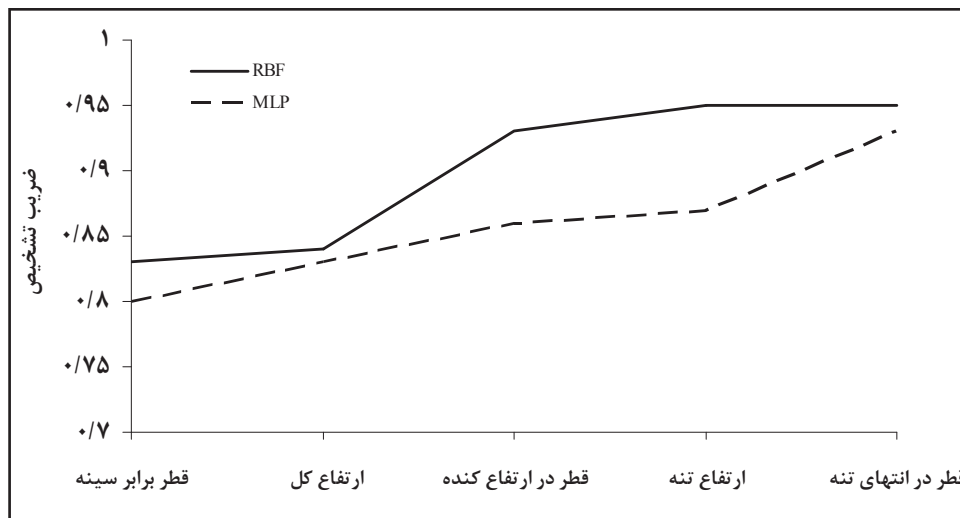
** سطح ۱ درصد معناداری را نشان می دهد.

ضریب تشخیص شبکه از ۰/۸۰ به ۰/۹۳ و ۰/۸۳ به ۰/۹۵، به ترتیب برای MLP و RBF افزایش، و RMSE آن از ۱/۹۴ به ۱/۱۸ و ۱/۸۵ به ۱/۰۵ به ترتیب برای MLP و RBF کاهش می‌یابد. نیز همان‌طور که معیارهای ارزیابی نشان می‌دهند، شبکه عصبی RBF در تمامی حالات دارای R² بیشتر و RMSE کمتری در مقایسه با شبکه MLP است. در نتیجه، از این نوع شبکه به منظور پیش‌بینی حجم تنه درخت استفاده شد. شکل ۲ نمودار افزایش ضریب تشخیص با افزایش متغیرها را نشان می‌دهد.

جدول ۳ نتایج بهترین ترکیب تعداد لایه‌های پنهان، تعداد عناصر هر لایه و توابع انتقال در هر لایه را با توجه به نوع و تعداد متغیر ورودی در رابطه با هر دو نوع مدل شبکه عصبی نشان می‌دهد. به منظور ارزیابی هر یک از شبکه‌ها، از معیارهای مجذور میانگین مربعات خطا (RMSE)، ضریب تغییرات مجذور میانگین مربعات خطا (CV(RMSE))، و ضریب تشخیص (R²) استفاده شد. با توجه به نتایج جدول ۳ مشاهده می‌شود که با افزایش تعداد متغیرها در هر دو نوع تحلیل شبکه عصبی،

جدول ۳. ارزیابی دو شبکه MLP و RBF در پیش‌بینی حجم تنه درخت با توجه به نوع و تعداد متغیر ورودی

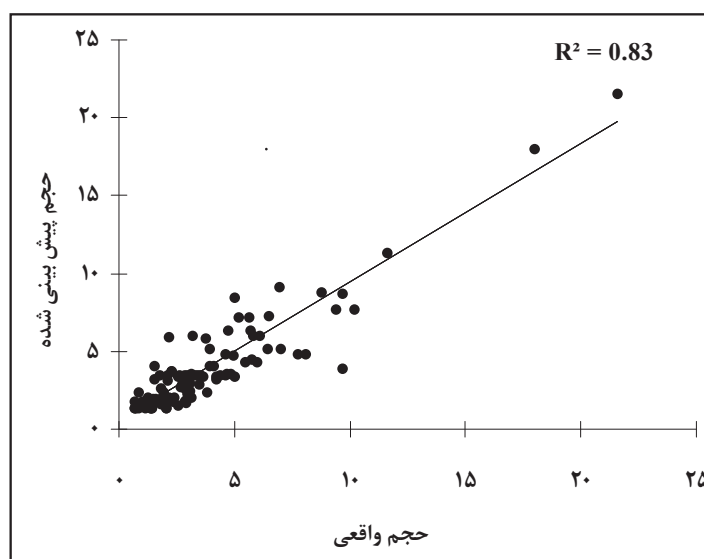
حالت	نوع شبکه	متغیرها	ترکیب بهینه شبکه	تابع انتقال	RMSE	CV(RMSE)	R ²
۱	MLP	V-D1.30	۱-۳-۱-۱	sigmoid	۱/۹۴	۰/۴۹	۰/۸۰
	RBF	V-D1.30	۱-۱۵-۱	softmax	۱/۸۵	۰/۴۷	۰/۸۳
۲	MLP	V- D1.30-Ht	۲-۵-۲-۱	sigmoid	۱/۸۴	۰/۴۷	۰/۸۳
	RBF	V- D1.30-Ht	۲-۲۵-۱	softmax	۱/۷۸	۰/۴۵	۰/۸۴
۳	MLP	V- D1.30-Ht-D.3	۳-۴-۸-۱	sigmoid	۱/۶۸	۰/۴۳	۰/۸۶
	RBF	V- D1.30-Ht-D.3	۳-۹-۱	softmax	۱/۲۴	۰/۳۱	۰/۹۳
۴	MLP	V- D1.30-Ht-D.3-Hs	۴-۳-۷-۱	sigmoid	۱/۶۴	۰/۴۲	۰/۸۷
	RBF	V- D1.30-Ht-D.3-Hs	۴-۱۷-۱	softmax	۱/۰۷	۰/۲۷	۰/۹۵
۵	MLP	V- D1.30-Ht-D.3-Hs-Dt	۵-۵-۸-۱	sigmoid	۱/۱۸	۰/۳	۰/۹۳
	RBF	V- D1.30-Ht-D.3-Hs-Dt	۵-۱۵-۱	softmax	۱/۰۵	۰/۲۷	۰/۹۵



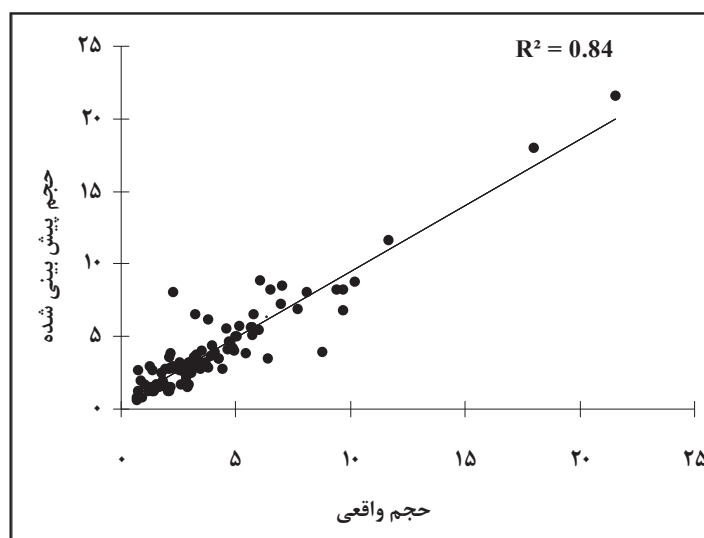
شکل ۲. نمودار افزایش ضریب تشخیص در مقابل افزایش متغیرها

حجم تنه درخت با متغیرهای قطر کنده (۳.D)، قطر برابر سینه (D ۱,۳۰)، قطر بالای تنه (D top)، ارتفاع کل (H total)، و ارتفاع تنه (H stem) با استفاده از روش توأم تحلیل رگرسیون و همان ترتیبی که برای دو نوع شبکه عصبی در وارد کردن متغیرها اتخاذ شد به دست آمد و بررسی شد. نتیجه ارزیابی این روش در جدول ۴ ارائه شده است.

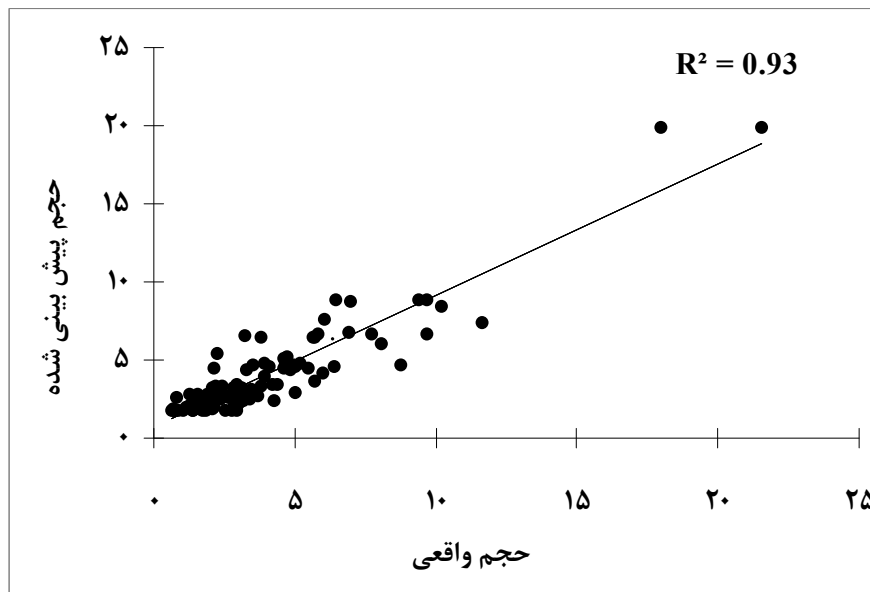
شکل های ۳ تا ۷ به ترتیب مقایسه بین خروجی حجم تنه پیش بینی شده توسط شبکه RBF در مقابل داده های حجم تنه واقعی را در هریک از حالت ها نشان می دهند. همان طور که در شکل ها دیده می شود، با افزایش تعداد متغیرها به عنوان ورودی های شبکه، تشابه بین حجم تنه پیش بینی شده با حجم تنه واقعی بیشتر می شود. به منظور مقایسه دقت شبکه عصبی، ارتباط بین



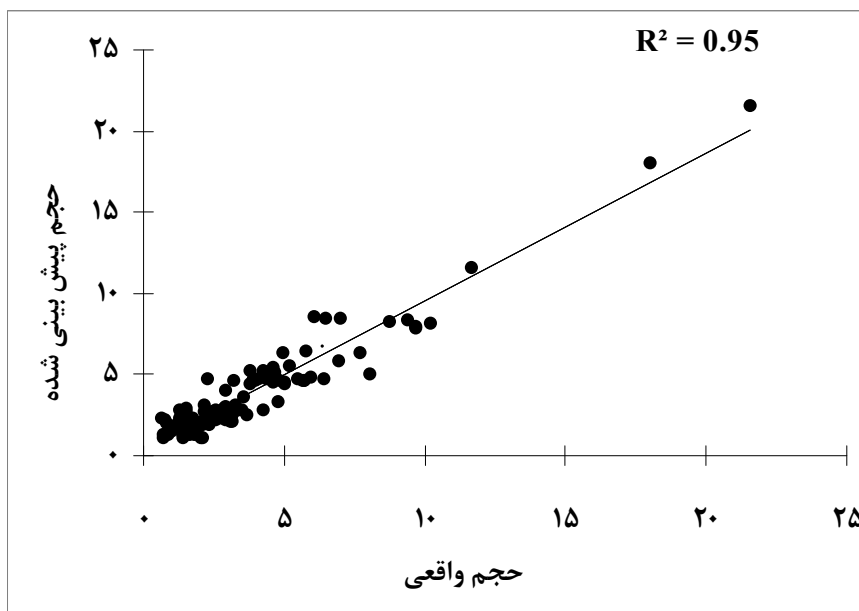
شکل ۳. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش بینی شده توسط شبکه RBF در حالت ۱



شکل ۴. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش بینی شده توسط شبکه RBF در حالت ۲

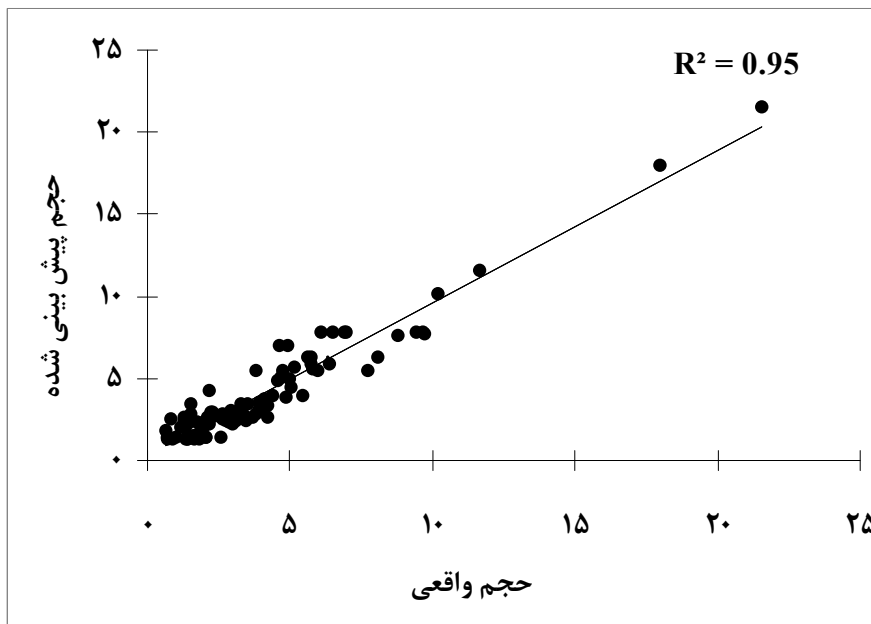


شکل ۵. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش‌بینی شده توسط شبکه RBF در حالت ۳



شکل ۶. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش‌بینی شده توسط شبکه RBF در حالت ۴
جدول ۴. نتیجه ارزیابی روش رگرسیون چندمتغیره در برآورد حجم تنه درخت با توجه به نوع و تعداد متغیرها

حالت	مدل	RMSE	CV(RMSE)	R ²
۱	$V = -4/12 + 11/65 D1.30$	۲/۹۸	۰/۷۶	۰/۶۳
۲	$V = -6/69 + 10/96 D1.30 + 0/11 Ht$	۲/۸۰	۰/۷۱	۰/۶۹
۳	$V = -6/65 + 8/77 D1.30 + 0/11 Ht + 1/9 D.3$	۲/۷۳	۰/۶۹	۰/۷۰
۴	$V = -7/08 + 9/84 D1.30 + 0/01 Ht + 1/46 D.3 + 0/17 Hs$	۲/۸۴	۰/۷۳	۰/۷۳
۵	$V = -7/62 + 6/03 D1.30 - 0/08 Ht + 2/91 D.3 + 0/27 Hs + 6/9 Dt$	۲/۵۷	۰/۶۵	۰/۷۹

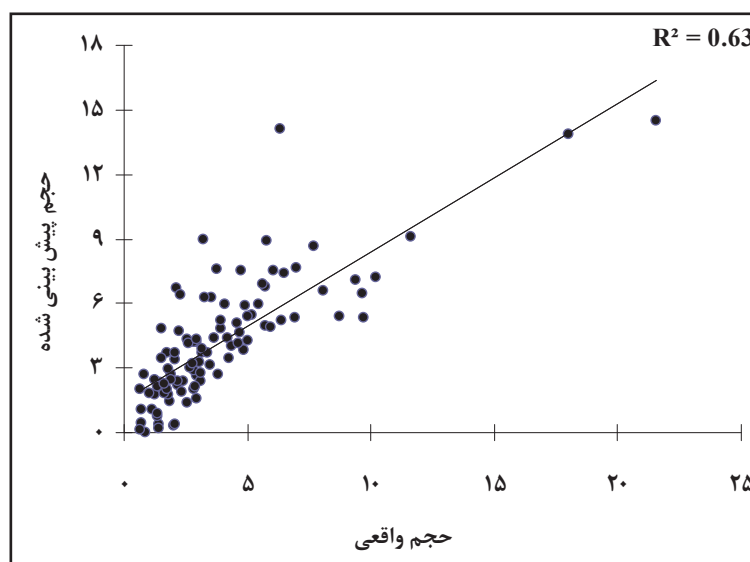


شکل ۷. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش‌بینی شده توسط شبکه RBF در حالت ۵

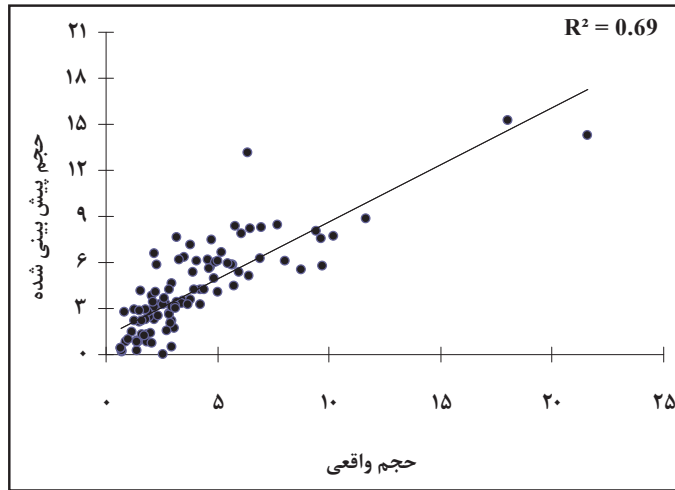
شکل‌های ۱۳ و ۱۴ مقایسه بین حجم تنه پیش‌بینی شده و واقعی برای کل داده‌ها و در هر یک از حالت‌های ذکر شده توسط روش گام‌به‌گام تحلیل رگرسیون را نشان می‌دهد. با توجه به اینکه شکل مدل اول جدول ۵ با مدل اول جدول ۴ یکسان است، به همین سبب فقط شکل‌های مربوط به مدل‌های دوم و سوم جدول ۵ آمده است.

شکل‌های ۸ تا ۱۲ مقایسه بین حجم تنه پیش‌بینی شده و واقعی برای کل داده‌ها و در هر یک از حالت‌های ذکر شده را نشان می‌دهد.

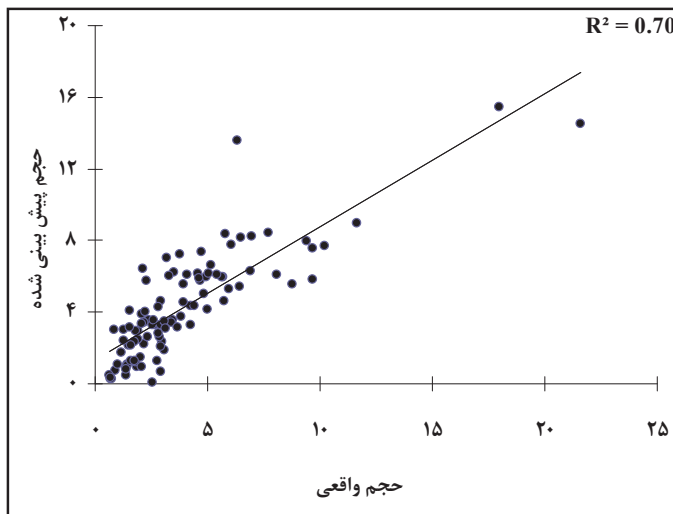
همچنین با استفاده از روش گام‌به‌گام تحلیل رگرسیون نیز رابطه بین حجم تنه و سایر متغیرها برقرار شد که نتیجه آن در جدول ۵ آمده است.



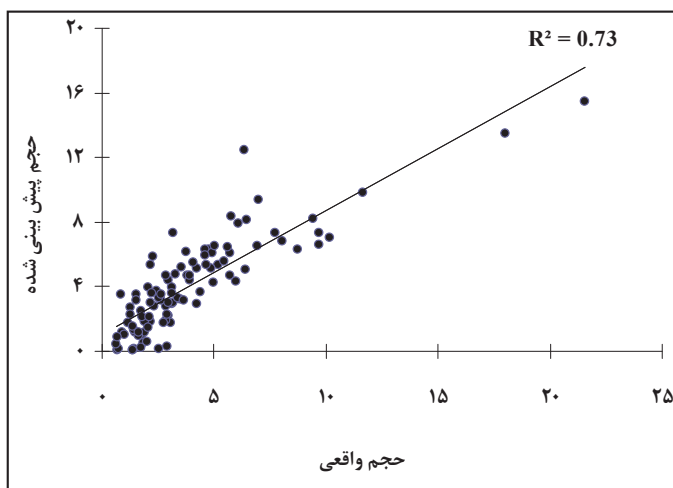
شکل ۸. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش‌بینی شده توسط روش توأم تحلیل رگرسیون در حالت ۱



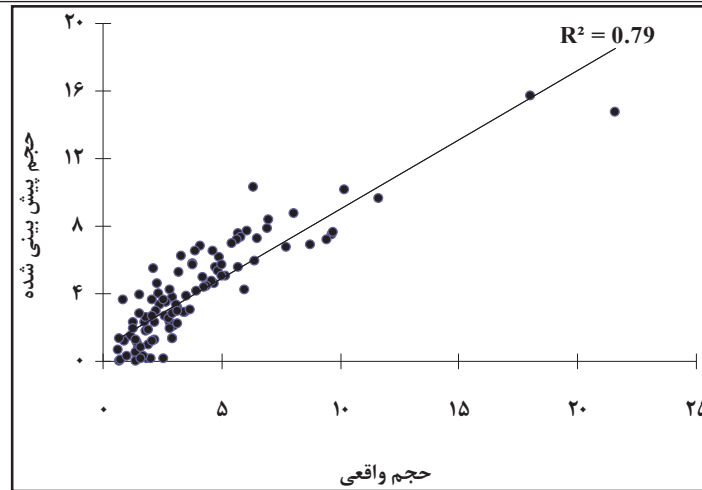
شکل ۹. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش‌بینی شده توسط روش توأم تحلیل رگرسیون در حالت ۲



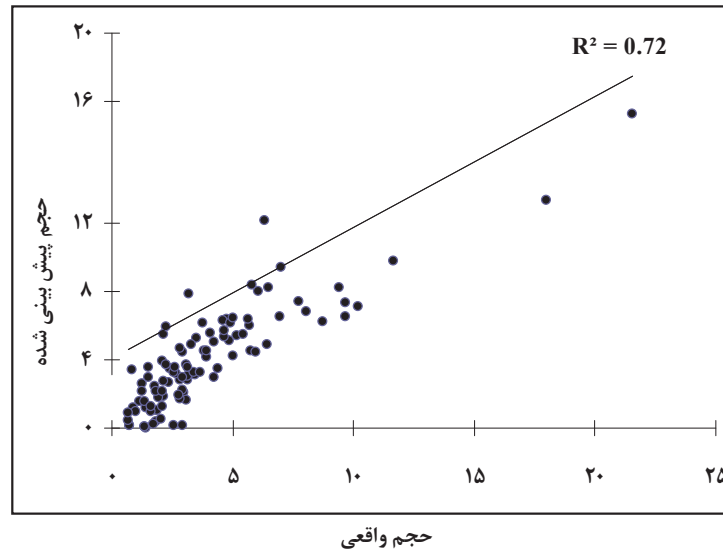
شکل ۱۰. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش‌بینی شده توسط روش توأم تحلیل رگرسیون در حالت ۳



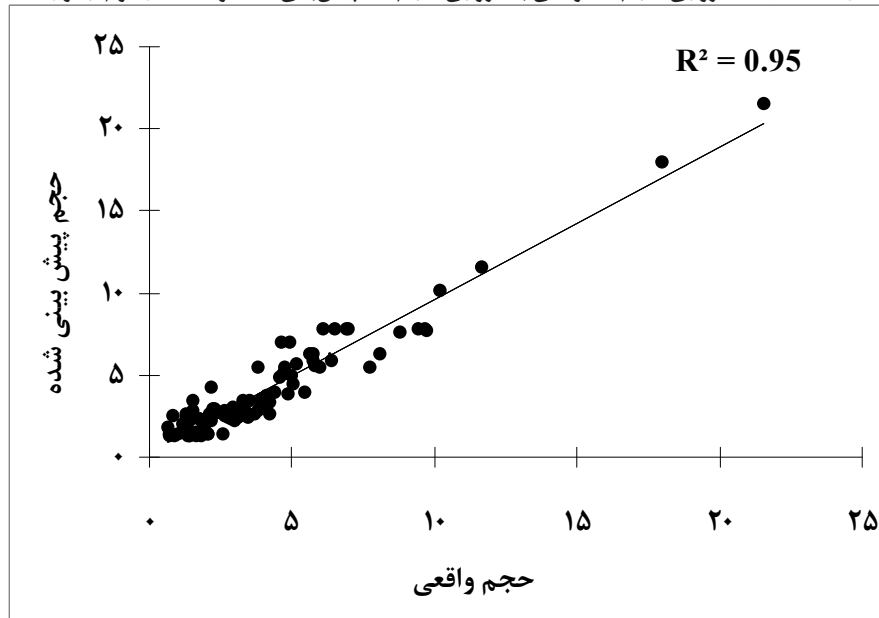
شکل ۱۱. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش‌بینی شده توسط روش توأم تحلیل رگرسیون در حالت ۴



شکل ۱۲. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش بینی شده توسط روش توأم تحلیل رگرسیون در حالت ۵



شکل ۱۳. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش بینی شده توسط مدل دوم جدول ۵



شکل ۱۴. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش بینی شده توسط مدل سوم جدول ۵

جدول ۵. نتیجه ارزیابی روش رگرسیون چندمتغیره گام به گام در برآورد حجم تنه درخت

مدل	RMSE	CV(RMSE)	R ²
$V = -4/12 + 11/65 D1.30$	۲/۹۸	۰/۷۶	۰/۶۳
$V = -7/09 + 11/54 D1.30 + 0/17 Hs$	۲/۷	۰/۶۸	۰/۷۲
$V = -8/07 + 9/35 D1.30 + 0/2 Hs + 5/83 Dt$	۲/۷	۰/۶۸	۰/۷۸

و دو نمودار بیشتر بر یکدیگر منطبق می‌شوند. بررسی نتایج ارزیابی دو مدل شبکه عصبی مصنوعی RBF با تابع انتقال Softmax در مقایسه با شبکه عصبی MLP با تابع انتقال Sigmoid توانایی بیشتری در پیش‌بینی حجم تنه درخت دارد. البته باید گفت یافتن تعداد لایه پنهان و تابع انتقال مناسب در هریک از مدل‌های شبکه عصبی نیاز به سعی و خطا دارد؛ به طوری که در هر آزمون باید معیارهای ارزیابی اندازه‌گیری و تا زمانی تکرار شود که کمترین خطا بین پارامتر پیش‌بینی شده با پارامتر واقعی به دست آید. همان‌طور که در نتایج نیز به دست آمد، شبکه عصبی RBF در مقایسه با MLP نیاز به تعداد نرون در لایه پنهان بیشتری دارد. مقایسه بین معیارهای جدول‌های نتایج شبکه عصبی مصنوعی و رگرسیون چندمتغیره نشان می‌دهد که شبکه عصبی دقت بهتر (R² بیشتر) و خطای کمتری در پیش‌بینی دارد که این امر را می‌توان به عدم وابستگی شبکه عصبی به فرض‌های اولیه درباره داده‌ها نسبت داد، زیرا ممکن است بین متغیرها رابطه‌ای غیر خطی 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 تنه با دقت بالا باشد، از مدلی استفاده می‌شود که بیشترین ورودی را داشته باشد. ولی اگر هدف برآورد با هزینه کمتر باشد از متغیرهایی که نیاز به زمان و امکانات و تخصص کمتری به منظور محاسبه دارند، استفاده خواهد شد.

در نهایت، با توجه به اینکه این پژوهش در مقیاس کوچک و فقط در مورد کاربرد شبکه عصبی در پیش‌بینی حجم تنه درخت انجام شده، پیشنهاد می‌شود محققان در سایر مناطق و نیز از سایر کاربردهای این روش نوین

مقایسه معیارهای ارزیابی حاصل از جدول‌های ۳، ۴، و ۵ نشان می‌دهد که شبکه عصبی مصنوعی دارای RMSE و CV(RMSE) کمتر، و R² بیشتری در مقایسه با روش رگرسیون در برآورد حجم تنه درخت است. مقایسه اشکال حاصل از حجم تنه واقعی و پیش‌بینی شده نیز بیانگر تطابق بیشتر این دو در نتایج حاصل از شبکه عصبی است.

نتیجه‌گیری

استفاده از روابط به منظور محاسبه حجم تنه درختان به این سبب ارزشمند است که امکان پیش‌بینی حجم تنه را برای سایر درختان با اندازه‌گیری چند متغیر میسر می‌کند. از طرفی، رابطه‌ای به کار می‌آید که با حداقل تعداد متغیر مورد نیاز، حجم تنه را با دقت مقبولی برآورد کند. در این پژوهش، قابلیت شبکه عصبی مصنوعی در برآورد حجم تنه درخت بررسی شد. نتایج جدول همبستگی بین حجم تنه با سایر متغیرها نشان داد که حجم تنه بیشترین همبستگی را با قطر در ارتفاع کنده و قطر در ارتفاع برابر سینه، و کمترین همبستگی را با ارتفاع کل درخت دارد. تأثیر این همبستگی را می‌توان در جدول ۳ و شکل ۲ مشاهده کرد. به طور مثال، در حالت اول و فقط با داشتن متغیر قطر برابر سینه، ضریب تشخیص برای RBF ۰/۸۳ بوده، و با افزایش متغیر ارتفاع کل ضریب تشخیص برای RBF به ۰/۸۴ رسیده؛ درحالی که با افزایش متغیر قطر در ارتفاع کنده، و از آنجا که حجم تنه با قطر در ارتفاع کنده همبستگی بیشتری داشته، ضریب تشخیص RBF به ۰/۹۳ می‌رسد. همچنین با بررسی شکل‌های ۵ تا ۹ مشاهده می‌شود که با افزایش تعداد متغیرها به عنوان ورودی‌های شبکه، اختلاف بین حجم تنه واقعی و حجم تنه پیش‌بینی شده کاهش یافته

بهره بجویند و قابلیت آن را در مطالعات جنگل ارزیابی کنند.

ضمیمه: روابط ریاضی معیارهای آماری

مجذور میانگین مربعات خطا

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i^a - y_i^e)^2}{n}}$$

ضریب تغییرات مجذور میانگین مربعات خطا

$$CV(RMSE) = \frac{RMSE}{\bar{Y}}$$

ضریب تشخیص

$$R^2 = 1 - \frac{\sum (\hat{y}_t - y_t)^2}{\sum \hat{y}_t^2}$$

که y_i^e و y_i^a به ترتیب حجم واقعی و پیش بینی شده پیش بینی شده است. تنه، \bar{y}^e و \bar{y}^a به ترتیب متوسط حجم واقعی و

References

- [1]. Masumian, A. (1997). Study of shape of tree in order to estimation of the volume for beec species in veisar stand. MSc. Thesis. Faculty of Natural Resources, University of Tarbiat Modares.
- [2]. 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.
- [3]. Bihamta, M.R., and Chahouki, M.A.Z. (2008). *Principles of Statistics for the Natural Resource Science*. University of Tehran Press.
- [4]. Peng, C., and Wen. X, (1999). Recent applications of artificial neural networks in forest resource management: an overview. *Environmental Decision Support Systems and Artificial Intelligence*, 15-22.
- [5]. 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.
- [6]. Coulson, R.N., Folse, L.J., and Loh, D. K. (1987). Artificial intelligence and natural resource management. *Science*, (237): 262-267.
- [7]. McRoberts, R.E., Schmoldt, D.L., and Rauscher. H.M. (1991). Enhancing the Scientific process with artificial intelligence. *Forest Science Applications*, (5): 5-26.
- [8]. Lek, S., Delacoste, M., Baran, P., Dimopoulos, I., Lauques, J., Aulagnier, S. (1996). Application of neural networks to modelling nonlinear relation-ships in ecology. *Ecol . Modell*, 90(1): 39-52.
- [9]. Atkinson, P.M., and Tatnall, A.R. (1997). Introduction neural networks in remote sensing. *International Journal of Remote Sensin*, 18(4): 699-709.
- [10]. Strobl, R.O., and Forte, F. (2007). Artificial neural network exploration of the influential factors in drainage network derivation. *Hydrological Processes*, 21: 2965-2978.
- [11]. Dagli, C.H. (1994). *Artificial neural networks for intelligent manufacturing*. Operating Research Journal, Chapman & Hall, Ltd. London, UK.
- [12]. Wu, J.K. (1994). *Neural networks and simulation methods*, Marcel Dekker Inc, New York.
- [13]. Kavzoglu, T. (2009). Increasing the accuracy of neural network classification using refined training data. *Environmental Modelling & Software*, 24(7): 850-858.
- [14]. Civco, D.L., and Wanug, Y. (1994). Classification of multispectral, multitemporal, multisource Spatial data using artificial neural networks, *Congress on Surveying and Mapping*. USA.
- [15]. 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): 540-551.
- [16]. Kia, M. (2010). *Neural network in MATLAB*, Kian Rayaneh Sabz Publisher.
- [17]. Rumelhart, D.E., Hinton, G.E., and Williams, R.J. (1986). Learning representations by back-propagating errors. *Nature*, 323 (9): 533-536.
- [18]. Norusis, M.J. (2007). *SPSS Neural Networks 17.0*. SPSS Inc. Chicago IL.

- [19]. Blackard, J.A., and Dean, D.J. (1999). Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. *Computers and Electronics in Agriculture*, 24 (3): 231-251.
- [20]. Jensen, J.R., Qiu, F., and Ji, M. (1999). Predictive modelling of coniferous forest age using statistical and artificial neural network approaches applied to remote sensor data. *International Journal of Remote Sensing* 20(14): 2805-2822.
- [21]. 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.
- [22]. Leduc, D.J., Matney, T.G., Belli, K.L., and V.C.Jr, Baldwin. (2001). Predicting diameter distributions of longleaf pine plantations: A comparison between artificial neural networks and other accepted methodologies. *Southern Research Station RS*, 25: 1-18.
- [23]. Diamantopoulou, M.J. (2005). Artificial neural networks as an alternative tool in pine bark volume estimation. *Computers and Electronics in Agriculture*, 48: 235-244.
- [24]. 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.
- [25]. Karaman, A., and Caliskan, E.. (2009). Affective factors weight estimation in tree felling time by artificial neural networks, *Expert Systems with Applications*, 36: 4491-4496.
- [26]. 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.
- [27]. Bayati, H. (2012). Application of Artificial Neural Networks in Assessment of Damages to Standing Trees in Forest Harvesting Operation. M.Sc Thesis. Tarbiat Modares University.
- [28]. Bayati, H., Najafi, A., and Abdolmaleki, P. (2013). Comparison between Artificial Neural Network (ANN) and Regression Analysis in Tree Felling Time Estimation). *Iranian Journal of Forest and Poplar Research*, 20(4): 595-607.
- [29]. Zobeiry, M. 2000. Forest Inventory: (Measurement of Tree and Stand). Tehran University Publication.