

تاریخ دریافت: ۱۳۹۰/۰۷/۲۵

تاریخ پذیرش: ۱۳۹۱/۰۵/۲۵

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

۱۷۷

❖ 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 تن 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 خطاهای نیز دارد. در این پژوهش سعی شده از شبکه‌های عصبی مصنوعی (ANN)، به عنوان یکی از زیرمجموعه‌های فناوری جدید هوش مصنوعی (AI)، بهمنظور برآورد حجم تن، 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 تن، ارتفاع تن، 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 تن استفاده شد. نتایج نشان داد با افزایش متغیرهایی که همیستگی بیشتری با حجم تن دارند، ضریب تشخیص شبکه عصبی از 0.80 ± 0.95 به 0.80 ± 0.90 افزایش می‌یابد. شبکه عصبی تابع پایه شعاعی در مقایسه با شبکه عصبی پرسپترون چندلایه دقت بیشتری در برآورد حجم تن دارد. مقایسه معیارهای ارزیابی شبکه عصبی مصنوعی با رگرسیون گام به گام نشان داد که شبکه عصبی MLP و RBF به ترتیب دارای مقدار $1/18$ RMSE و $1/0.5$ است، در حالی که مقدار RMSE مدل رگرسیون $2/57$ می‌باشد. ضریب تشخیص رگرسیون در مقایسه با هر دو مدل شبکه عصبی نیز مقدار کمتری است.

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

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 مشابهه 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 مناسب 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 به دست آوردن نتایج درست و بسیار دقیق و واقعی‌تر کمک می‌کند.

از مهم‌ترین ویژگی‌های شبکه‌های عصبی مصنوعی وابسته‌بودن 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

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، در گیر اندازه‌گیری درختان نمونه به منظور محاسبه حجم اند که اغلب فعالیتی زمان‌بر و در نتیجه هزینه‌بر است [۲]. به همین منظور، روابط ریاضی گوناگونی چون نیوتون، 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 تنۀ در مقیاس‌های وسیع‌تر از تک درخت، از روش‌های مختلفی استفاده می‌شود. یکی از این روش‌ها استفاده از تحلیل رگرسیون است، که دارای محدودیت‌هایی مانند نرمال‌بودن متغیر وابسته، همگن‌بودن واریانس خطاهای، و نبود رابطه هم خطی 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 نحقیق گیمبلت و بل (۱۹۹۵) اتخاذ تصمیم در منابع طبیعی اغلب با پیچیدگی‌هایی فراتر از روش‌های تجربی آماری روبرو 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 به عنوان روشی جایگزین در مدل‌سازی پذیده‌های غیر خطی و پیچیده علم جنگل به کار گرفتند [۵، ۷، ۸، ۹]. امروزه، شبکه‌های عصبی مصنوعی^۲، به

لایه پنهان یک انطباق غیر خطی بین فضای ورودی و یک فضا (معمولًاً) با بعد بزرگتر برقرار می‌کند که در آن الگوها به صورت تفکیک‌پذیر خطی درمی‌آیند. سرانجام، لایه خروجی، جمع وزنی را به همراه یک خروجی خطی تولید می‌کند. توابع فعال‌سازی مختلفی در این نوع شبکه وجود دارد که رایج‌ترین آن تابع گوسی است.

این ابزار در سال‌های اخیر کاربرد فراوانی در علوم مختلفی چون منابع طبیعی پیدا کرده که می‌توان به مواردی مانند پیش‌بینی تیپ پوشش جنگلی با استفاده از متغیرهای کارتوگرافی [۱۹]، پیش‌بینی سن جنگل‌های سوزنی برگ در جنوب بزریل با استفاده از تصاویر TM [۲۰]، برآورد مرگ‌ومیر توده‌های *Picea abies* [۲۱]، پیش‌بینی توزیع قطربی جنگل‌کاری‌های گونه Pinus [۲۲]، برآورد حجم پوست درخت Pinus brutia [۲۳]، ارزیابی خطر بادافتدگی در بخش‌های مختلف جنگل‌های جنوب غربی آلمان [۲۴]، مطالعه عامل‌های مؤثر در زمان قطع درخت [۲۵]، برآورد حجم تنہ گونه‌های Pinus sylvestris، Pinus brutia، *Cedrus libani* A. Rich و *Abies cilicica* Carr از جنگل‌های ترکیه [۲۶]، برآورد مشخصه تراکم درختان جنگل [۲۶]، پیش‌بینی تعداد درختان آسیب‌دیده در عملیات قطع و وینچینگ با استفاده از شبکه عصبی MLP و RBF در جنگل‌های شرکت نکا چوب [۲۷]، پیش‌بینی زمان خالص قطع درخت با استفاده از شبکه پرسپترون چندلایه و تابع شعاع‌مدار، و نیز روش رایج تحلیل رگرسیون [۲۸]، اشاره کرد.

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

بالا (به‌سبب پردازش‌های موازی)، داشتن توان بالقوه در حل مسائلی که شبیه‌سازی آن‌ها از طریق منطقی یا سایر روش‌ها مشکل یا غیر ممکن است، کارآمدبودن شبکه برای یادگیری و انطباق با محیط در صورت تغییر در موقعیت محیطی، عدم ازکارافتادگی شبکه در صورت آسیب‌دیدگی قسمتی از نورون‌ها و داشتن جواب منطقی برای داده‌های در شرایط اطمینان (اعم از آنکه فازی باشند یا به‌طور ناقص و توأم با دریافت نویز دریافت شده باشند)، علاقه‌مندی به استفاده از این روش را بیشتر می‌کند [۱۶].

یکی از شبکه‌های عصبی پرکاربرد در مدیریت منابع طبیعی شبکه عصبی پیش‌خور^۱ با الگوریتم پس انتشار خطأ^۲ (شبکه چندلایه پرسپترون (MLP)) است [۱۷]. یک پرسپترون، برداری از ورودی‌های با مقادیر حقیقی را می‌گیرد و یک ترکیب خطی از این ورودی‌ها را محاسبه می‌کند. اگر حاصل از یک مقدار آستانه بیشتر بود، خروجی پرسپترون برابر با ۱، و در غیر این صورت، معادل ۱ - خواهد بود [۱۸]. Sigmoid از معروف‌ترین توابع فعالیت در این نوع شبکه است.

یکی دیگر از مهم‌ترین گونه‌های شبکه عصبی تابع شعاع‌مدار RBF^۳ است. این شبکه با توجه به کاربردهای متعددش به یکی از معروف‌ترین شبکه‌های عصبی تبدیل شده و مهم‌ترین رقیب MLP محسوب می‌شود. این شبکه‌ها بیشتر از روش‌های آماری طبقه‌بندی الگو گرفته‌اند [۱۸]. این نوع شبکه به نورون‌های بیشتری نیاز دارد، اما حسن‌شان در زمان طراحی کوتاه‌تر آن‌ها در مقایسه با شبکه‌های استاندارد پس انتشار است. این شبکه‌ها زمانی که بردارهای آموزشی بسیار زیادند، بهترین کارایی را دارند [۱۷].

معماری اصلی MLP مانند RBF 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

از تحلیل رگرسیون چندمتغیره و روش گام به گام برآورده شد و با استفاده از معیارهای مجدوز میانگین مربعات خطای (RMSE)، ضریب تغییرات مجدوز میانگین مربعات خطای (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_{\min} و x_{\max} به ترتیب بیشترین و کمترین داده در هریک از متغیرهای است. سپس سعی بر این شد داده‌ها به صورت تصادفی به دو دسته آموزش شوند؛ به طوری که بیشترین و کمترین داده در دسته آموزش قرار گیرد. متغیرهای قطر کنده (D1)، قطر برابر سینه (D top)، قطر بالای تن (D1)، ارتفاع کل (H total)، و ارتفاع تن (H trunk) به عنوان ورودی‌های شبکه، و متغیر حجم تن به عنوان 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 گام به گام 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 تن، و قطر در انتهای تن، 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

روش‌شناسی

منطقه مورد مطالعه و جمع‌آوری داده‌ها

این تحقیق در جنگل آموزشی-پژوهشی دانشکده منابع طبیعی دانشگاه تربیت مدرس در عرض جغرافیایی ۳۶°۳۲' تا ۳۶°۲۹' شمالی و طول جغرافیایی ۵۱°۴۳' تا ۵۱°۴۷' 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 نشانه گذاری شده بودند، انتخاب شدند و پارامترهای ارتفاع کل، ارتفاع تن، و قطر درخت در ارتفاع کنده و ارتفاع برابر سینه و ارتفاع بالای تن، اندازه‌گیری شدند. به منظور اندازه‌گیری پارامترهای قطر درخت در ارتفاع کنده و ارتفاع برابر سینه و ارتفاع بالای تن، 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 تنۀ 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 تهیه شده وارد نرم‌افزار Image Tools شد و قطر بالای تن، قطر برابر سینه، و قطر در ارتفاع کنده، با استفاده از رابطه ۱ محاسبه گردید.

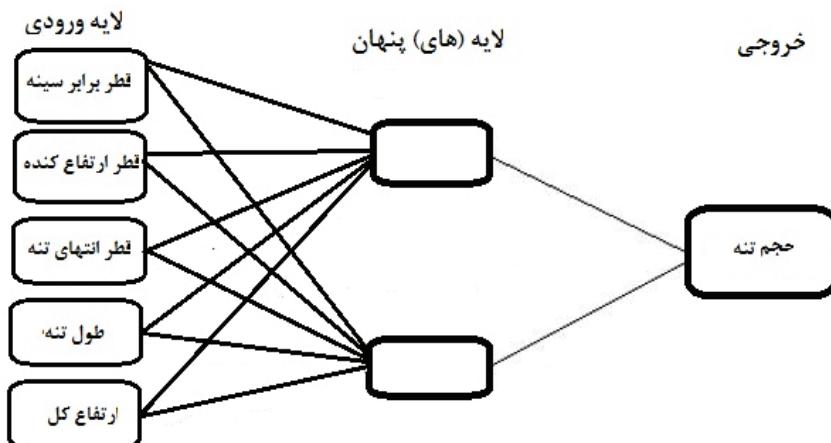
$$d = \left(\frac{X_i \times L}{50} \right) \times 100 \quad (1)$$

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

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

حجم تنه برآورده و داده حجم تنه واقعی به کمترین حد خود برسد. به منظور بررسی و تحلیل داده‌ها از نرم‌افزارهای MATLAB ۲۰۱۱a، SPSS ۲۰۰۷، و Excel ۲۰۰۷ استفاده شد.

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



شکل ۱. نمایش ساختار شبکه

نتایج

ارتفاع کنده، قطر در انتهای تن، طول تن، و ارتفاع کل، همبستگی مثبت معناداری در سطح ۱ درصد وجود دارد (جدول ۲).

آمار توصیفی هریک از متغیرهای در جدول ۱ ارائه شده است. آزمون همبستگی نشان می‌دهد بین متغیر وابسته حجم تن و متغیرهای مستقل قطر برابر سینه، قطر در

جدول ۱. آمار توصیفی متغیرها

متغیر	میانگین	واریانس	حداقل	حداکثر
H Total (m)	۲۷/۰ ۱	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	حجم تن	ارتفاع کل درخت	(H Total)	ارتفاع تن	(H Stem)	ارتفاع کنده	(D.3)	ارتفاع کنده	(D 1.30)	قطر برابر سینه	قطر در انتهای تن
	۰/۴۱۲**	۰/۳۲۴**	۰/۸۰۹**	۰/۷۹۵**	۰/۵۶۴**						

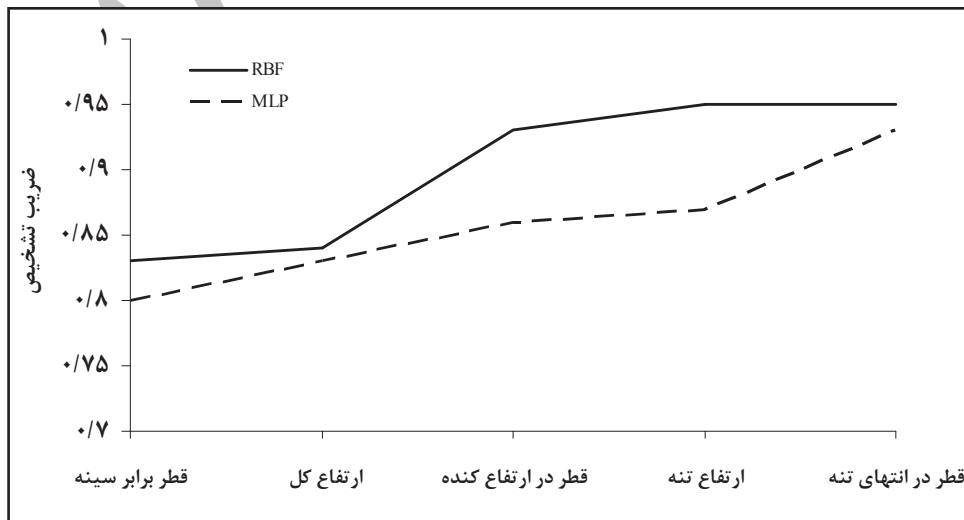
*: سطح ۱ درصد معناداری را نشان می‌دهد.

ضریب تشخیص شبکه از $0/80$ به $0/93$ و $0/83$ به $0/95$ به ترتیب برای MLP و RBF افزایش، و RMSE آن از $1/94$ به $1/18$ و $1/85$ به $1/05$ به ترتیب برای MLP و RBF کاهش می‌یابد. نیز همان‌طور که معیارهای ارزیابی نشان می‌دهند، شبکه عصبی RBF در تمامی حالات دارای R^2 بیشتر و RMSE کمتری در مقایسه با شبکه MLP است. در نتیجه، از این نوع شبکه به منظور پیش‌بینی حجم تنۀ 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. بهمنظور ارزیابی هریک از شبکه‌ها، از معیارهای مجدد میانگین مربعات خطای (RMSE)، ضریب تغییرات مجدد میانگین مربعات خطای (CV(RMSE))، و ضریب تشخیص (R^2) 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 تنۀ درخت با توجه به نوع و تعداد متغیر ورودی

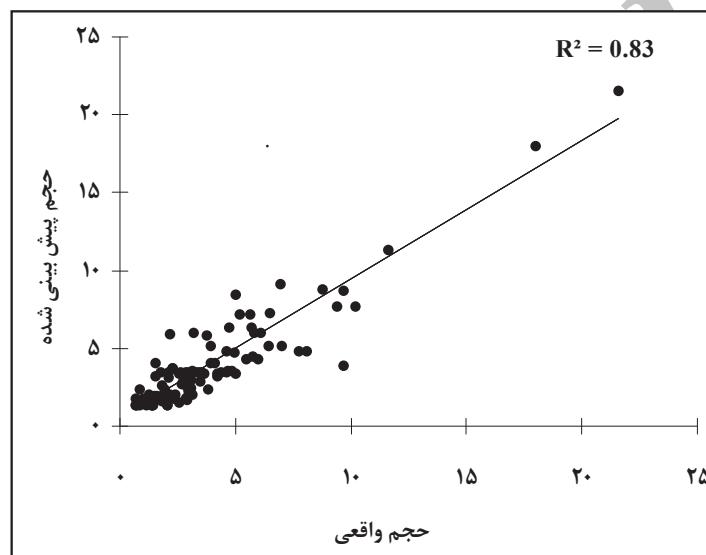
حالت	نوع شبکه	متغیرها	ترکیب بهینه شبکه	تابع انتقال	RMSE	CV(RMSE)	R^2
۱	MLP	V-D1.30	۱-۳-۱-۱	sigmoid	۱/۹۴	۰/۴۹	۰/۸۰
	RBF	V-D1.30	۱-۱۵-۱	softmax	۱/۸۵	۰/۴۷	۰/۸۳
۲	MLP	V- D1.30-Ht	۲ - ۵ - ۲ - ۱	sigmoid	۱/۸۴	۰/۴۷	۰/۸۳
	RBF	V- D1.30-Ht	۲ - ۲۵ - ۱	softmax	۱/۷۸	۰/۴۵	۰/۸۴
۳	MLP	V- D1.30-Ht-D.3	۳ - ۴ - ۸ - ۱	sigmoid	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



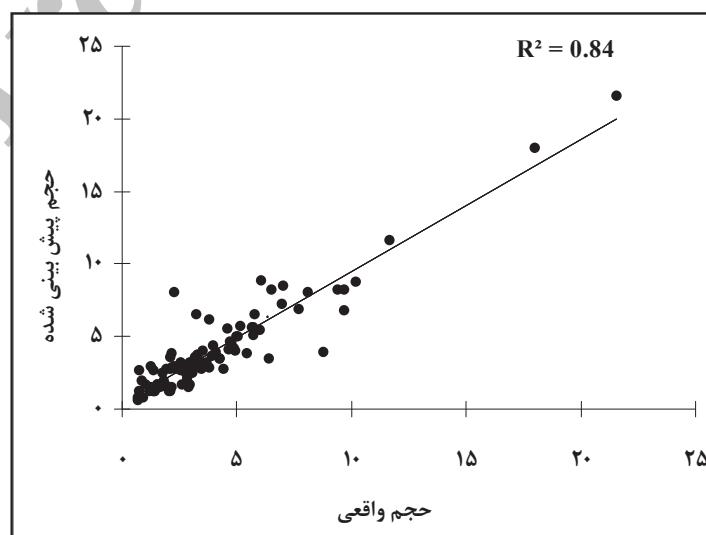
شکل ۲. نمودار افزایش ضریب تشخیص در مقابل افزایش متغیرها

حجم تنہ درخت با متغیرهای قطر کنده (D_{3.0})، قطر برابر سینه (D_{1.30})، قطر بالای تنہ (D top)، ارتفاع کل (H total)، و ارتفاع تنہ (H stem) با استفاده از روش توان 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.

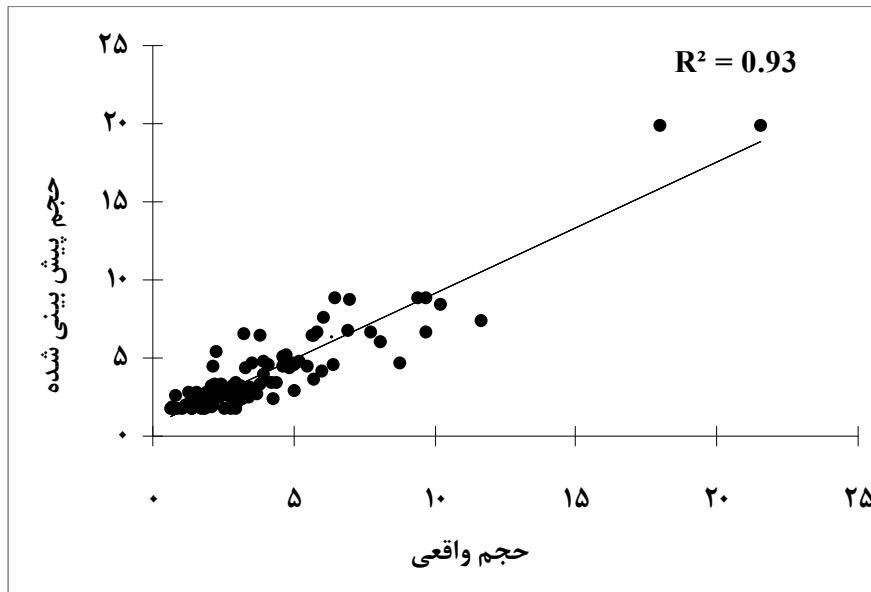
شکل‌های ۳ تا ۷ به ترتیب مقایسه بین خروجی حجم تنہ پیش‌بینی شده توسط شبکه RBF در مقابل داده‌های حجم تنہ واقعی را در هریک از حالت‌ها نشان می‌دهند. همان‌طور که در شکل‌ها دیده می‌شود، با افزایش تعداد متغیرها به عنوان ورودی‌های شبکه، تشابه بین حجم تنہ پیش‌بینی شده با حجم تنہ واقعی بیشتر می‌شود. به منظور مقایسه دقت شبکه عصبی، ارتباط بین



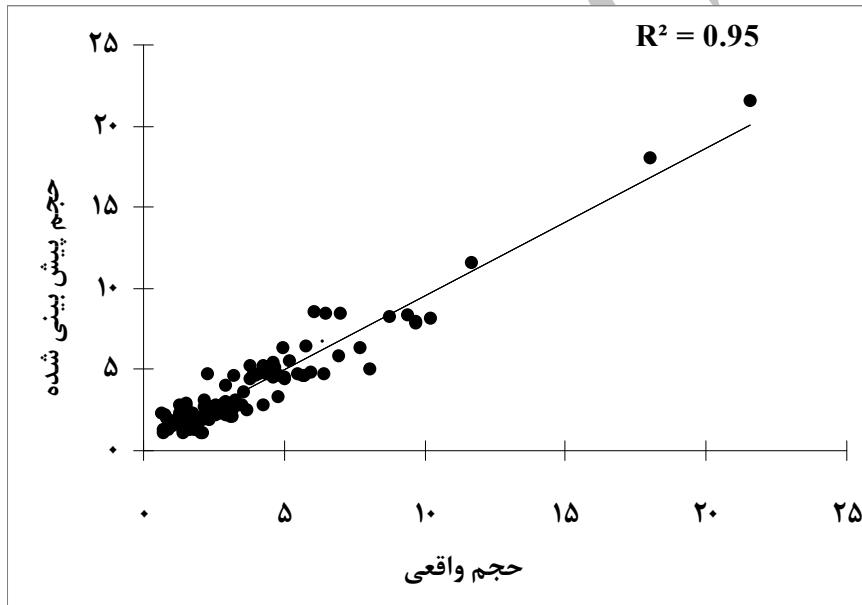
شکل ۳. مقایسه خروجی حجم تنہ واقعی با خروجی حجم تنہ پیش‌بینی شده توسط شبکه RBF در حالت ۱



شکل ۴. مقایسه خروجی حجم تنہ واقعی با خروجی حجم تنہ پیش‌بینی شده توسط شبکه RBF در حالت ۲



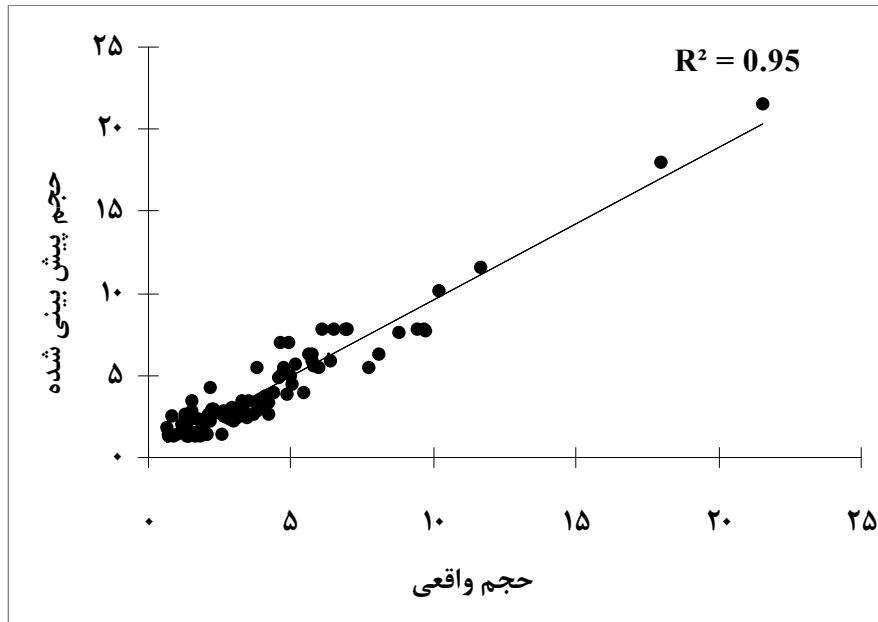
شکل ۵. مقایسه خروجی حجم تنۀ واقعی با خروجی حجم تنۀ پیش‌بینی شده توسط شبکه RBF در حالت ۳



شکل ۶. مقایسه خروجی حجم تنۀ واقعی با خروجی حجم تنۀ پیش‌بینی شده توسط شبکه RBF در حالت ۴

جدول ۴. نتیجه ارزیابی روش رگرسیون چندمتغیره در برآورد حجم تنۀ درخت با توجه به نوع و تعداد متغیرها

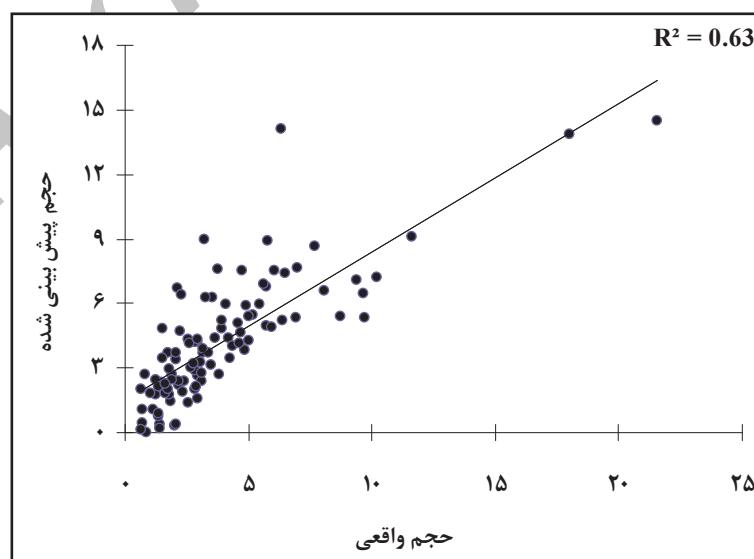
حالت	مدل	RMSE	CV(RMSE)	R^2
۱	$V = -4/12 + 11/65 D1.30$	۲/۹۸	۰/۷۶	۰/۶۳
۲	$V = -6/69 + 10/96 D1.30 + 0/11 Ht$	۲/۸۰	۰/۷۱	۰/۶۹
۳	$V = -6/65 + 8/77 D1.30 + 0/11 Ht + 1/9 D.3$	۲/۷۳	۰/۶۹	۰/۷۰
۴	$V = -7/0.8 + 9/84 D1.30 + 0/0.1 Ht + 1/46 D.3 + 0/17 Hs$	۲/۸۴	۰/۷۳	۰/۷۳
۵	$V = -7/62 + 6/0.3 D1.30 - 0/0.8 Ht + 2/91 D.3 + 0/27 Hs + 6/9 Dt$	۲/۵۷	۰/۶۵	۰/۷۹



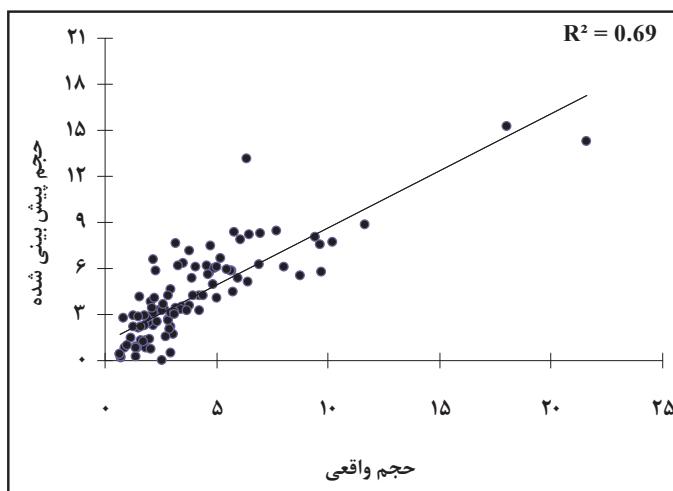
شکل ۷. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش‌بینی شده توسط شبکه RBF در حالت ۵

شکل‌های ۱۳ و ۱۴ مقایسه بین حجم تنه پیش‌بینی شده و واقعی برای کل داده‌ها و در هریک از حالت‌های ذکر شده توسط روش گام به گام 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.

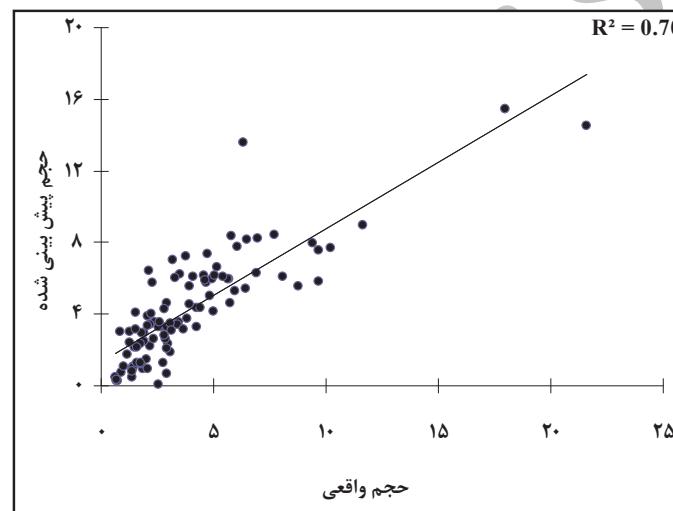
شکل‌های ۸ تا ۱۲ مقایسه بین حجم تنه پیش‌بینی شده و واقعی برای کل داده‌ها و در هریک از حالت‌های ذکر شده را نشان می‌دهد. همچنین با استفاده از روش گام به گام تحلیل رگرسیون نیز رابطه بین حجم تنه و سایر متغیرها برقرار شد که نتیجه آن در جدول ۵ آمده است.



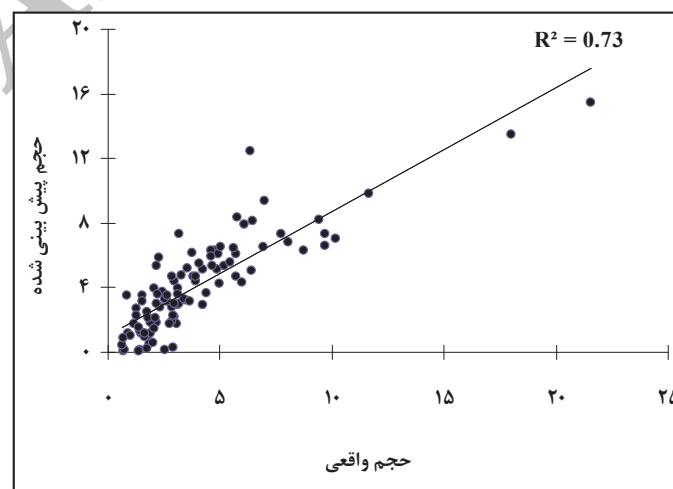
شکل ۸. مقایسه خروجی حجم تنه واقعی با خروجی حجم تنه پیش‌بینی شده توسط روش توأم تحلیل رگرسیون در حالت ۱



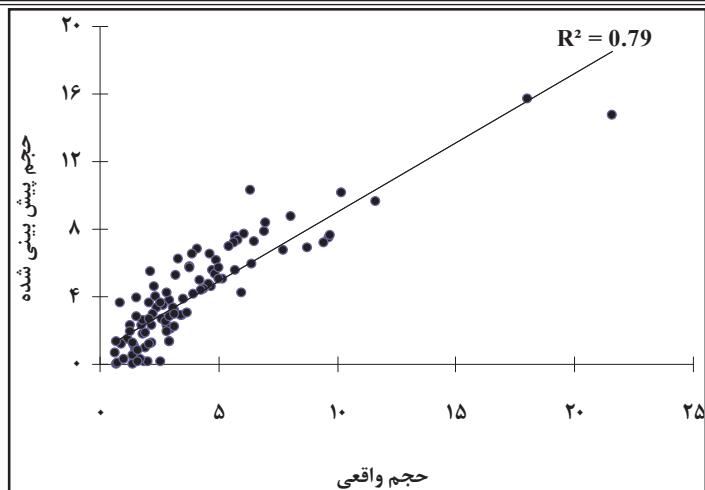
شکل ۹. مقایسه خروجی حجم تنۀ واقعی با خروجی حجم تنۀ پیش‌بینی شده توسط روش توأم تحلیل رگرسیون در حالت ۲



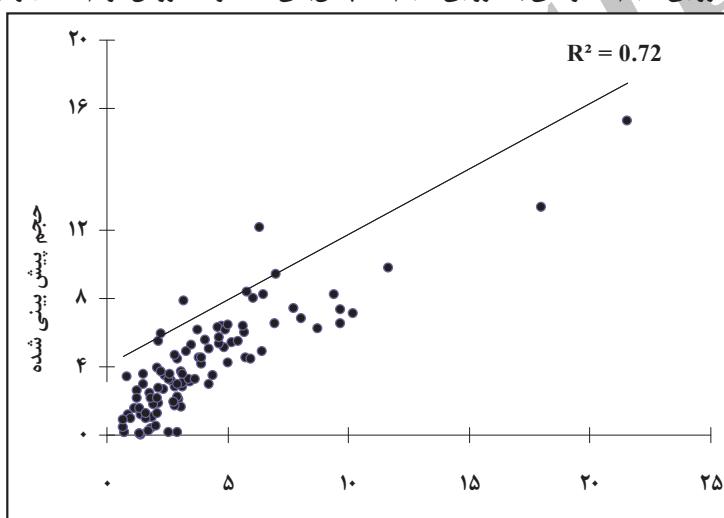
شکل ۱۰. مقایسه خروجی حجم تنۀ واقعی با خروجی حجم تنۀ پیش‌بینی شده توسط روش توأم تحلیل رگرسیون در حالت ۳



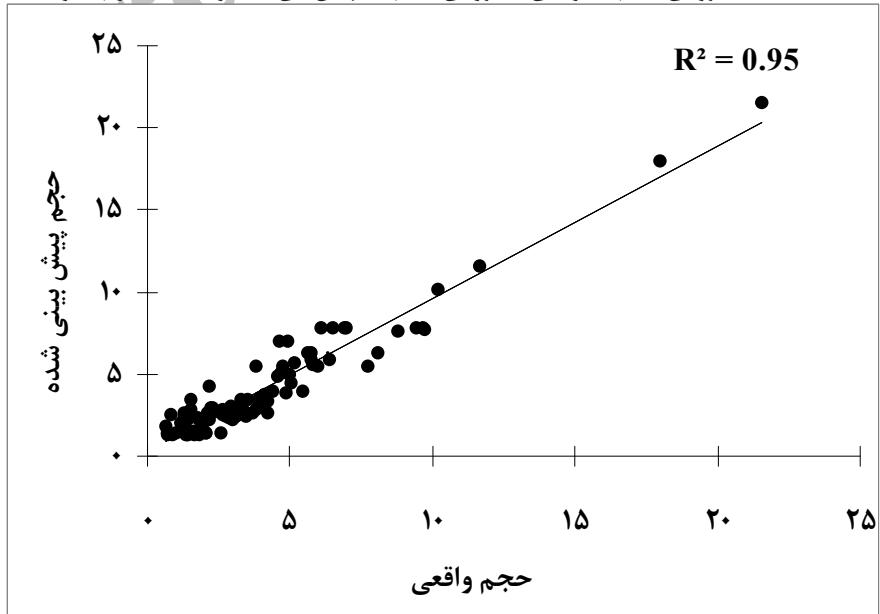
شکل ۱۱. مقایسه خروجی حجم تنۀ واقعی با خروجی حجم تنۀ پیش‌بینی شده توسط روش توأم تحلیل رگرسیون در حالت ۴



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



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



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

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

مدل	RMSE	CV(RMSE)	R ²
V= - ۴/۱۲ + ۱۱/۶۵ D1.30	۲/۹۸	۰/۷۶	۰/۶۳
V= - ۷/۰۹ + ۱۱/۵۴ D1.30 + ۰/۱۷ Hs	۲/۷	۰/۶۸	۰/۷۲
V= - ۸/۰۷ + ۹/۳۵ D1.30 + ۰/۲ Hs + ۵/۸۳ Dt	۲/۷	۰/۶۸	۰/۷۸

و دو نمودار بیشتر بر یکدیگر منطبق می‌شوند. بررسی نتایج ارزیابی دو مدل شبکه عصبی نشان داد که شبکه عصبی مصنوعی RBF باتابع انتقال Softmax در مقایسه با شبکه عصبی MLP باتابع انتقال Sigmoid توانایی بیشتری در پیش‌بینی حجم تنۀ 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 خطای 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 نورون 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 تنۀ 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 تنۀ 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 CV(RMSE) کمتر، و R² بیشتری در مقایسه با روش رگرسیون در برآورد حجم تنۀ درخت است. مقایسه اشکال حاصل از حجم تنۀ واقعی و پیش‌بینی شده نیز بیانگر تطابق بیشتر این دو در نتایج حاصل از شبکه عصبی است.

نتیجه گیری

استفاده از روابط بهمنظور محاسبه حجم تنۀ درختان به این سبب ارزشمند است که امکان پیش‌بینی حجم تنۀ برای سایر درختان با اندازه‌گیری چند متغیر میسر می‌کند. از طرفی، رابطه‌ای به کار می‌آید که با حداقل تعداد متغیر مورد نیاز، حجم تنۀ را با دقت مقبولی برآورد کند. در این پژوهش، قابلیت شبکه عصبی مصنوعی در برآورد حجم تنۀ درخت بررسی شد. نتایج جدول همبستگی بین حجم تنۀ با سایر متغیرها نشان داد که حجم تنۀ 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 ۰/۸۴ رسیده؛ در حالی که با افزایش متغیر قطر در ارتفاع کنده، و از آنجا که حجم تنۀ 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 تنۀ واقعی و حجم تنۀ پیش‌بینی شده کاهش یافته

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

ضمیمه: روابط ریاضی معیارهای آماری
مجدور میانگین مربعات خط

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

ضریب تغییرات مجدور میانگین مربعات خط

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

ضریب تشخیص

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

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