

برآورد ارتفاع درختان نمدار (*Tilia begonifolia* Stev.) با استفاده از مدل‌های غیرخطی

محمدرسول نظری سندی^۱، ایرج حسن‌زاد ناورودی^{۲*}، امان‌محمد کلته^۳ و حسن پوربابایی^۴

۱- دانشجوی دکتری مدیریت جنگل، گروه جنگل‌داری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران

۲- نویسنده مسئول، دانشیار، گروه جنگل‌داری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران. پست الکترونیک: ehasanzadeh@guilan.ac.ir

۳- استادیار، گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران

۴- استاد، گروه جنگل‌داری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران

تاریخ دریافت: ۱۳۹۸/۰۷/۲۰ تاریخ پذیرش: ۱۳۹۸/۱۱/۱۶

چکیده

قطر و ارتفاع درختان، متغیرهایی اساسی برای بررسی زی‌توده، ذخیره کربن و تکامل توده‌های جنگلی هستند. با توجه به کم‌هزینه بودن و سهولت اندازه‌گیری قطر و زیاد بودن خطای اندازه‌گیری ارتفاع درخت، در این پژوهش برای برآورد ارتفاع درختان نمدار (*Tilia begonifolia* Stev.) در جنگل‌های سفارود گیلان از مدل‌های غیرخطی استفاده شد. نمدار در سفارود از ارتفاعات پایین تا ۱۸۰۰ متر از سطح دریا پراکنش دارد. این گونه، نقش مهمی در حفظ ترکیب و ساختار طبیعی جنگل ایفا می‌کند. داده‌های مورد بررسی با نمونه‌برداری تصادفی - منظم با ابعاد شبکه ۲۰۰×۲۰۰ متر مربع از ۴۸ قطعه نمونه دایره‌ای ۱۰ آری در دامنه‌های ارتفاعی ۵۰۰ تا ۹۵۰ متر از سطح دریا (پارسل‌های ۲۹ و ۳۰) در سری ۱۶ و ۵۰ تا ۵۰۰ متر از سطح دریا (پارسل‌های ۱۴ و ۱۸) در سری ۱۷ جمع‌آوری شدند. مدل‌سازی با ۱۲ مدل غیرخطی پرکاربرد و شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم لونتبرگ-مارکووارت انجام شد. شبکه عصبی مصنوعی از مزیت تشخیص روابط پیچیده غیرخطی بین داده‌های ورودی و خروجی برخوردار است. مقایسه نتایج با معیارهای کارایی‌سنجی R^2_{adj} ، RMSE، AIC و MAD انجام شد. براساس این معیارها در بین ۱۲ مدل مورد نظر، مدل Stoffels-Van Soeset (۱۹۵۳) در پایین‌بند و مدل Burkhart-Strub (۱۹۷۴) برای میان‌بند بیشترین کارایی را داشتند، در حالی‌که شبکه عصبی مصنوعی در هر دو رویشگاه از بیشترین کارایی برخوردار بود. شبکه عصبی مصنوعی، مقدار خطا را برای مدل‌های پیشنهادی در مناطق پایین‌بند و میان‌بند به ترتیب ۵/۵۴ و ۷/۳۵ درصد کاهش داد. اگرچه دقت مدل‌های غیرخطی پیشنهادی برای منطقه مورد بررسی مناسب بود، اما شبکه عصبی مصنوعی به دلیل دقت بیشتر نسبت به این مدل‌ها برتری داشت.

واژه‌های کلیدی: شبکه عصبی مصنوعی، قطر - ارتفاع، سفارود، گیلان، مدل‌سازی.

مقدمه

(Abazari et al., 2004). در این راستا، مدیریت صحیح جنگل، اهمیت دوچندانی دارد و می‌تواند سبب حفظ، بازدهی و توسعه اقتصادی بهتر آن شود (Alemi et al., 2018). جنگل‌های هیرکانی تنها جنگل‌های تجاری ایران با داشتن تنوع زیستی و گونه‌های منحصربه‌فرد و ارزشمند

جنگل‌ها نقش به‌سزایی در پیشبرد اهداف توسعه پایدار دارند (Sadeghi Kaji et al., 2015). آنچه که امروز به‌عنوان جنگل وجود دارد، شکلی از تمامی گونه‌هایی است که از گذشته دچار تحول و تکامل شده‌اند (Delfan

توده‌های جنگلی در برابر بادافتادگی و پیش‌بینی حجم استفاده می‌شوند (Ng'andwe *et al.*, 2019). البته نکته مهم در استفاده از این مدل‌ها، آن است که برای مناطق مختلف باید به توانایی پیش‌بینی آن‌ها توجه شود و مدل مناسب انتخاب شود، زیرا هر منطقه، شرایط رویشگاهی متفاوتی دارد (Aishan *et al.*, 2016).

در سال‌های اخیر مدل‌سازی و بررسی روابط با استفاده از هوش مصنوعی در رشته‌های مختلف توسعه یافته است. از میان این روش‌ها می‌توان به شبکه‌های عصبی مصنوعی (Artificial Neural Networks) اشاره کرد (Özçelik *et al.*, 2014). شبکه‌های عصبی مصنوعی، الگوهایی با ساختار غیرخطی برای پردازش اطلاعات با الهام از عملکرد مغز انسان هستند. آن‌ها بدون نیاز به آگاهی دقیق از روند مطالعه می‌توانند مدلی با کارایی قابل توجه بین داده‌های ورودی و خروجی ارائه دهند (Kalteh, 2017). در طی دو دهه گذشته، این رویکرد در علوم محیط‌زیستی و به‌ویژه مدیریت جنگل با استقبال مواجه شده است (Diamantopoulou & Özçelik, 2012). بیشترین ساختار شبکه عصبی مورد استفاده، پرسپترون چندلایه (Multi-Layer Perceptron) است. سه‌لایه این ساختار به‌ترتیب شامل ورودی، یک یا چندلایه پنهان و خروجی هستند. حرکت اطلاعات فقط از یک مسیر و در جهت رو به جلو با شروع از نورون‌های ورودی و سپس گذر از لایه‌های پنهان به سمت نورون‌های خروجی انجام می‌شود. تعیین تعداد نورون‌ها در لایه‌های ورودی و خروجی به نوع مسئله مورد بررسی بستگی دارد. تعداد نورون‌ها در لایه پنهان وابسته به کاربر است و بیشتر با رویکرد سعی و خطا تعیین می‌شود. اگرچه در بین الگوریتم‌های مختلف برای آموزش شبکه پرسپترون چندلایه، الگوریتم پس‌انتشار (Back-Propagation) یکی از پرکاربردترین‌ها به‌شمار می‌آید، اما معایبی مانند سرعت کم، تعداد آموزش بسیار و گیر افتادن در نقاط بهینه حداقلی دارد (Özçelik *et al.*, 2014)، بنابراین در پژوهش پیش‌رو از الگوریتم لونیبرگ-مارکواریت (Levenberg-Marquardt) استفاده شد که روشی جدیدتر است و معایب

(Rezaei, 2012)، در سال‌های گذشته به دلایل مختلفی مانند سیاست‌های متفاوت، بهره‌برداری غیراصولی، قاچاق، چرای دام و عوامل دیگر دچار صدمه شده‌اند. متأسفانه مجموعه این عوامل نه تنها منجر به کاهش سطح این جنگل‌ها شده، بلکه تغییر وضعیت کیفی، ترکیب گونه‌ای و کاهش تنوع آن را نیز در پی داشته است (Sadeghi Kaji *et al.*, 2015)، بنابراین فقط نظارت بر مقدار سطح جنگل، گونه غالب و تعداد آن نمی‌تواند منعکس‌کننده پویایی، کیفیت و کارکردهای همه‌جانبه آن باشد، بلکه باید گونه‌های اصلی نیز همراه با گونه غالب بررسی شوند (Ghanbari & Sheidai Karkaj, 2018). نمدار (*Tilia begonifolia* Stev.) یکی از گونه‌های مهم جنگل‌های هیرکانی است که از ارتفاعات پایین (۵۰ متر) تا بالا (۲۰۰۰ متر از سطح دریا) گسترش داشته و دارای ارزش‌های بوم‌شناختی و اقتصادی است (Plotnik, 2000). این گونه در مناطق میان‌بند و پایین‌بند جنگل‌های سفارود پراکنش قابل توجهی دارد، اما به دلیل کاربرد گسترده چوب آن، ویژگی خوش‌تراش بودن، مصرف برگ آن در دامداری و نیز استقرار در مناطق کم‌شیب و پایین‌دست مورد صدمه قرار گرفته است (Yosefzadeh *et al.*, 2010). بیشتر پژوهش‌ها در مورد نمدار درباره ریخت‌شناسی، ویژگی‌های ظاهری (Yosefzadeh *et al.*, 2012) و نحوه پراکنش آن بوده است (Sheikholeslami *et al.*, 2005).

اگرچه پایش دائمی توده‌های جنگلی مستلزم آگاهی از ویژگی‌های درختان است (Mohammadi & Shataee, 2017)، اما بیشتر برنامه‌ریزی‌های آینده جنگل براساس اطلاعات قطر برابر سینه و ارتفاع انجام می‌شود (Ng'andwe *et al.*, 2019). اندازه‌گیری ارتفاع برخلاف قطر در عرصه‌های جنگلی متراکم و پرشیب شمال ایران از نظر مسئله وسعت جنگل، دقت، زمان، هزینه و عملیات اندازه‌گیری، مشکل است (Zobeiry, 2005). به این منظور، طی سال‌های گذشته، مدل‌های خطی و غیرخطی متعدد قطر- ارتفاع توسعه داده شده‌اند. این مدل‌ها به‌غیر از در نظر گرفتن هدف مذکور در موارد متعدد دیگری مانند تعیین رویش توده، مقدار کربن، پیش‌بینی صدمات و ثبات

بررسی شده به غیر از مدل پرودان، تفاوت معنی داری بین مدل‌های دیگر دیده نشد. با این حال، بررسی رابطه قطر-ارتفاع با مدل‌های غیرخطی در طبقه‌های مختلف ارتفاع از سطح دریا و مقایسه آن‌ها تاکنون در ایران انجام نشده است. با توجه به پژوهش‌های اندک انجام شده در مورد نمدار و به ویژه در منطقه مورد مطالعه این پژوهش در شفارود که جزء گونه‌های اصلی در ساختار توده‌های آن است و نقش مؤثری در ترکیب طبیعی جنگل‌های آن دارد، لزوم این پژوهش احساس می‌شود. اهداف پژوهش پیش‌رو به ترتیب بررسی رابطه قطر-ارتفاع نمدار در طبقه‌های ارتفاعی میان‌بند و پایین‌بند، قابلیت برآورد ارتفاع آن نسبت به ارتفاع اندازه‌گیری شده با استفاده از مدل‌های غیرخطی قطر-ارتفاع و شبکه عصبی مصنوعی، مقایسه نتایج در دو طبقه ارتفاعی و در نهایت، تعیین بهترین مدل برای برآورد ارتفاع درختان نمدار بودند.

مواد و روش‌ها

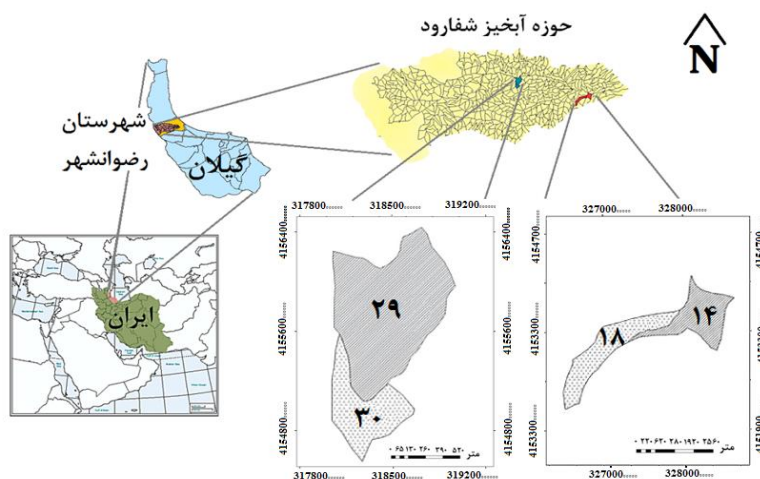
منطقه مورد مطالعه

این پژوهش در پارسل‌های ۲۹ و ۳۰ سری ۱۶ (میان‌بند) و پارسل‌های ۱۴ و ۱۸ سری ۱۷ (پایین‌بند) حوزه آبخیز شفارود استان گیلان در شهرستان رضوانشهر و در مساحتی حدود ۱۹۸/۵ هکتار انجام شد. سری ۱۶ از نظر مختصات جغرافیایی در طول ۴۹° ۱۹' ۵" تا ۲۱' ۵۰" ۴۹° شرقی و عرض ۳۷° ۲۰' ۵۲" تا ۳۷° ۲۱' ۳۰" شمالی واقع شده است. سری ۱۷ نیز در طول جغرافیایی ۴۹° ۲۶' ۱۰" تا ۴۹° ۳۳' ۴۲" شرقی و عرض ۳۷° ۲۰' ۵۵" تا ۳۷° ۲۰' ۵۵" شمالی قرار دارد (شکل ۱). از نظر تقسیمات مربوط به ارتفاع از سطح دریا، سری‌های ۱۶ و ۱۷ به ترتیب جزء مناطق میان‌بند و پایین‌بند محسوب می‌شوند. این سری‌ها به ترتیب در ارتفاع ۵۰۰ تا ۹۵۰ و ۵۰ تا ۵۰۰ متر از سطح دریا قرار دارند. میانگین درجه حرارت سالانه این منطقه ۱۵/۴ درجه سانتیگراد، جهت کلی شمالی و متوسط بارندگی آن ۱۴۰۰ میلی‌متر در سال است. نوع جنگل‌های مورد بررسی، آمیخته پهن‌برگ است. تپ غالب


مذکور را ندارد. در خصوص بررسی رابطه قطر-ارتفاع با استفاده از روش‌های مذکور، پژوهش‌هایی انجام شده است. Peng و همکاران (۲۰۰۱) به منظور مدیریت هرچه بهتر توده‌های جنگلی در انتاریو کانادا، تأثیر ویژگی‌های بوم‌ناحیه (Ecoregion) بر رابطه قطر-ارتفاع دو گونه *Picea mariana* و *Pinus banksiana* را بررسی کردند. آن‌ها مدل Chapman-Richards را به عنوان مدل منتخب به کار بردند. Scaranello و همکاران (۲۰۱۲)، رابطه قطر-ارتفاع درختان واقع در جنگل‌های حاره‌ای آتلانتیک را بر اساس چهار طبقه ارتفاع از سطح دریا در برزیل ارزیابی کردند. نتایج آن‌ها نشان داد که عامل ارتفاع از سطح دریا بر برآورد ارتفاع درختان تأثیر دارد. در مجموع، قابلیت تبیین مدل‌های Weibull و Chapman-Richards بهتر بود. Diamantopoulou و Özçelik (۲۰۱۲) از شش مدل قطر-ارتفاع و شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) در جنگل‌های ترکیه استفاده کردند. نتایج این پژوهش نشان داد که دقت شبکه عصبی، بیشتر است. همچنین، رابطه قطر-ارتفاع گونه‌های مورد بررسی تحت تأثیر عوامل ناحیه جغرافیایی، اقلیم محلی، خاک و شرایط بوم‌شناختی بود. در پژوهش Castaño-Santamaría و همکاران (۲۰۱۳) که در جنگل‌های ناهمسال راش اسپانیا انجام شد، مقدار خطا در شبکه عصبی مصنوعی ۲۲ درصد در مقایسه با رگرسیون غیرخطی کمتر بود. Ahmadi و همکاران (۲۰۱۴)، مدل‌های غیرخطی برای راش را در جنگل‌های هیرکانی به کار بردند. آن‌ها تابع Chapman-Richards را به عنوان بهترین مدل معرفی کردند. Özçelik و همکاران (۲۰۱۴) با بررسی سه بوم‌ناحیه در شمال ترکیه، رابطه قطر-ارتفاع را برای *Ten. Cedrus libani* و *P. nigra Arnold. Pinus brutia* A.Rich. تعیین کردند. آن‌ها نتیجه گرفتند که این رابطه به شرایط محلی بسیار وابسته و در هر کدام متفاوت است، اما به طور کلی مدل Gompertz نسبت به مدل‌های دیگر، قابلیت بیشتری برای هدف آن‌ها داشت. Mohammadi و Shataee (۲۰۱۷) برای بررسی رابطه قطر-ارتفاع ممرز از ۱۸ مدل غیرخطی استفاده کردند. در بین مدل‌های

درصد)، نمدار (۱۷/۳ درصد) و بلندمازو (۵/۷۵ درصد) و در پارسل‌های ۱۴ و ۱۸، ممز (۳۱/۲ درصد)، توسکا (۲۹/۵ درصد)، نمدار (۱۶/۲ درصد) و (۷/۶ درصد) بیشترین مقدار را داشتند.

در پارسل‌های ۲۹ و ۳۰، راش - ممز و در پارسل‌های ۱۴ و ۱۸ به صورت ممز - توسکا است. نمدار پس از این گونه‌ها، بیشترین تعداد در هکتار را دارد (Sheikhcanlou, Milan et al., 2014) (شکل ۲). از نظر نسبت حجم در پارسل‌های ۲۹ و ۳۰، راش (۳۹/۶ درصد)، ممز (۲۵/۱



شکل ۱- منطقه مورد مطالعه در منطقه شفارود شهرستان رضوانشهر، استان گیلان



شکل ۲- درصد آمیختگی گونه‌ها در منطقه مورد مطالعه

۲۰۰×۲۰۰ متر مربع و قطعه‌نمونه‌های ۱۰ آری انجام شد. زمان آماربرداری، اوایل فصل پاییز بود که توده‌ها از نظر نور برای اندازه‌گیری ارتفاع، شرایط مناسب‌تری داشتند. تعداد ۴۸ قطعه‌نمونه مشخص و در هر کدام، مشخصات قطر و ارتفاع درختان نمدار دارای قطر برابر سینه بیشتر از ۷/۵ سانتی‌متر اندازه‌گیری شد. در مجموع، اطلاعات ۳۵۷ اصله

روش پژوهش

برای انجام این پژوهش، ابتدا وضعیت استقرار نمدار در طبقه‌های ارتفاعی مختلف جنگل‌های شفارود بررسی شد. سپس دو سری ۱۶ و ۱۷ به ترتیب در ارتفاعات میان‌بند و پایین‌بند به دلیل استقرار انبوه نمدار انتخاب شدند. آماربرداری به روش تصادفی- منظم با ابعاد شبکه

نمدار ثبت شد. برای اندازه‌گیری قطر از نوار قطر سنج و برای متغیر ارتفاع از رلا سکوپ استفاده شد.

مدل‌های غیرخطی قطر-ارتفاع

مدل‌های متعددی در سال‌های گذشته برای برآورد ارتفاع درختان توسعه داده شده‌اند که معایب و مزایایی دارند (Ahmadi *et al.*, 2014). برای انتخاب مدل مناسب در مرحله اول باید معیارهای زیست‌شناسی داده‌ها و ابر نقاط قطر در برابر ارتفاع بررسی شود (Lei *et al.*, 2009). در صورتی که این رابطه به صورت سیگموئید، مقعر و یا نزدیک به آن باشد، می‌توان از مدل‌های غیرخطی استفاده کرد که

کارایی بیشتری نسبت به مدل‌های خطی دارند (Tsega *et al.*, 2018). در این پژوهش برای انتخاب مدل‌های مناسب، ابتدا ۲۸ مدل غیرخطی بر داده‌های آموزش در نرم‌افزار Sigma Plot 14 برازش داده شد. پس از بررسی نتایج مدل‌ها براساس ارتفاع برآورد شده و نیز معیارهای کارایی سنجی، ۱۲ مدل غیرخطی (جدول ۱) برای بررسی داده‌های اعتبارسنجی انتخاب شدند. شایان ذکر است که این مدل‌ها در پژوهش‌های گذشته نیز عملکرد مناسبی داشتند و به‌نحو مطلوب، منعکس‌کننده رابطه سیگموئید بین قطر و ارتفاع درختان بوده‌اند (Ahmadi *et al.*, 2014; Hassanzad Navroodi *et al.*, 2016).

جدول ۱- مدل‌های غیرخطی قطر-ارتفاع انتخاب شده

شماره	مدل	مرجع
۱	$h = 1.3 + a.dbh^b$	Stoffels-Van Soeset (۱۹۵۳); Schreuder <i>et al.</i> (۱۹۷۹)
۲	$h = 1.3 + (a.dbh)/(b + dbh)$	Bates-Watts (۱۹۸۰); Ratkowsky (۱۹۹۰)
۳	$h = 1.3 + a.(1 - \text{Exp}^{-b.dbh})$	Meyer (۱۹۴۰); Farr <i>et al.</i> (۱۹۸۹); Moffat <i>et al.</i> (۱۹۹۱)
۴	$h = 1.3 + a.\text{Exp}^{(b/dbh)}$	Burkhart-Strub (۱۹۷۴); Buford (۱۹۸۶)
۵	$h = 1.3 + dbh^2/(a + b.dbh)^2$	Loetsch <i>et al.</i> (۱۹۷۳)
۶	$h = 1.3 + a.dbh/(dbh + 1) + b.dbh$	Watts (۱۹۸۳)
۷	$h = 1.3 + \text{Exp}^{(a+b.(dbh^c))}$	Stage (۱۹۶۳); Zeide (۱۹۸۹)
۸	$h = 1.3 + a(1 - \text{Exp}^{-b.dbh})^c$	Richards (۱۹۵۹)
۹	$h = 1.3 + a(1 - \text{Exp}^{-dbh.dbh^c})$	Yang <i>et al.</i> (۱۹۷۸)
۱۰	$h = 1.3 + (dbh^2/a + b.dbh + c.dbh^2)$	Curtis (۱۹۶۷); Prodan (۱۹۶۸)
۱۱	$h = 1.3 + a.\text{Exp}^{(b/(dbh+c))}$	Ratkowsky (۱۹۹۰)
۱۲	$h = 1.3 + dbh^{a/b+c.dbh^a}$	Hossfeld (۱۹۸۲)
۱۳	روش شبکه عصبی مصنوعی	Artificial Neural Network (ANN)

مدل‌های ۱ تا ۶ دو پارامتره و مدل‌های ۷ تا ۱۲ سه پارامتره هستند. در این روابط، h: ارتفاع درخت (متر)، dbh: قطر در ارتفاع برابر سینه (سانتی‌متر)، a، b و c: پارامترهای برآورد شده و e: عدد (۲/۷۱۸۲۸) هستند.

شبکه عصبی مصنوعی

الگوریتم لونیبرگ-مارکوارت

برای یک شبکه عصبی مصنوعی با بردار ورودی x_i و

بردار خروجی y ، تابعی که بیان‌کننده رابطه بین داده‌های ورودی و خروجی باشد، به صورت رابطه ۱ نوشته می‌شود:

$$y = f_{output} \left[\sum_{j=0}^h w_j f_{hidden} \left(\sum_{i=0}^n w_{ij} x_i + bias_1 \right) + bias_2 \right] \quad \text{رابطه (۱)}$$

تابع انتقال لایه خروجی هستند. وزن‌ها در طی فرایند یادگیری با هدف کمینه کردن تابع خطا برآورد و تعدیل می‌شوند (رابطه ۲).

که در آن: n تعداد ورودی، h تعداد نورون‌ها در لایه پنهان، x_i i امین ورودی، w_{ij} پارامتر وزن بین ورودی i و نورون لایه پنهان j ، w_j پارامتر وزن بین نورون لایه پنهان j و نورون خروجی، f_{hidden} تابع فعال‌سازی لایه پنهان و f_{output}

$$E_D = \sum_{i=1}^n (y_i - t_i)^2 = \sum_{i=1}^n e_i^2 \quad \text{رابطه (۲)}$$

خطا (E_D)، پارامترهای بهینه وزن‌ها و بایاس‌ها باید مشخص شوند.

یکی از الگوریتم‌های شاخص برای حل این مسئله، الگوریتم لونیبرگ-مارکوارت (LM) است (Hagan & Menhaj, 1994). وزن‌های یک شبکه عصبی لونیبرگ-مارکوارت (LMNN) از رابطه ۳ محاسبه می‌شود (Wilamowski et al., 1999).

که در آن: n تعداد نمونه‌های ورودی و خروجی مجموعه داده‌های آموزش D و t مقدار واقعی هستند.

خطاها از طریق شبکه به منظور تعدیل وزن‌ها برگشت داده می‌شوند تا هنگامی که مقدار خطا (E_D) برای مدل شبکه قابل قبول باشد. هنگامی که شبکه به حد راضی‌کننده‌ای در فرایند آموزش رسید، وزن‌ها برای پیش‌بینی نتایج داده‌های جدید ذخیره خواهند شد. برای به حداقل رساندن مقدار

$$W_{i+1} = W_i - (J_i^T J_i + \mu_i I)^{-1} J_i^T e_i \quad \text{رابطه (۳)}$$

محدوده صفر تا یک نرمال شدند. به ترتیب قطر برابر سینه و ارتفاع به عنوان متغیرهای ورودی و خروجی استفاده شدند. آموزش شبکه توسط پرسپترون چندلایه (MLP) با الگوریتم لونیبرگ-مارکوارت در نرم‌افزار (R2018b) MATLAB انجام شد. از تابع انتقال سیگموئید و از نوع خطی برای لایه‌های پنهان و خروجی استفاده شد (Maier & Dandy, 2000).

که در آن: J ماتریس ژاکوبیان (Jacobian) خطاهای خروجی، I ماتریس شناسایی و μ پارامتر یادگیری هستند.

در پژوهش پیش‌رو، به منظور اجرای مدل شبکه عصبی مصنوعی بر داده‌های نمدار، ۷۰ درصد کل داده‌ها به بخش آموزش و ۳۰ درصد باقی‌مانده برای آزمون در هریک از مناطق تخصیص داده شد. سپس، داده‌ها در

تجزیه و تحلیل داده‌ها

به منظور برازش داده‌ها از رگرسیون غیرخطی و روش حداقل مربعات (Least Squares) در نرم‌افزار Sigmaplot 12.3 استفاده شد. کارایی سنجی مدل‌ها را می‌توان به روش‌های متفاوت انجام داد (Ahmadi *et al.*, 2014; Aishan *et al.*, 2016). در این پژوهش از چهار معیار کارایی سنجی شامل خطای جذر میانگین مربعات (RMSE)، ضریب تبیین تعدیل‌شده (R^2_{adj})، معیار اطلاعاتی آکائیک (AIC) و میانگین خطای مطلق (MAD) استفاده شد (رابطه‌های ۴ تا ۷). معیار RMSE یکی از پرکاربردترین رویکردهای تعیین نیکویی برازش است. تفاوت بین مقدار برآوردشده توسط مدل با مقدار اندازه‌گیری شده واقعی را بیان می‌کند (Burnham & Anderson, 2004). برای محاسبه این معیار از رابطه ۴ استفاده می‌شود

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (H_i - \hat{H}_i)^2}{n}} \quad \text{رابطه (۴)}$$

$$R^2_{adj} = 1 - \frac{(n-1) \sum_{i=1}^n (H_i - \hat{H}_i)^2}{(n-p) \sum_{i=1}^n (H_i - \bar{H})^2} \quad \text{رابطه (۵)}$$

$$AIC = n \times \ln(RMSE) + 2P \quad \text{رابطه (۶)}$$

$$MAD = \frac{\sum_{i=1}^n |H_i - \hat{H}_i|}{n} \quad \text{رابطه (۷)}$$

معیار R^2_{adj} مقدار R^2 را با توجه به متغیرهای مستقل اضافه‌شده به خط رگرسیون و عرض از مبدأهای جدید، تعدیل و اصلاح می‌کند (رابطه ۵). معیار AIC (رابطه ۶) با برقرار کردن تعادل میان دقت و پیچیدگی آن به انتخاب بهترین مدل آماری کمک می‌کند (Burnham & Anderson, 2004). MAD معیاری است که بیان‌کننده نحوه توزیع مجموعه داده‌ها است (رابطه ۷). اگرچه واریانس و انحراف معیار نیز جزء این دسته قرار می‌گیرند، اما به دلیل آنکه مقادیر بیشینه، کمینه و توزیع غیرنرمال بر آن تأثیرگذار هستند، در بیشتر موارد منعکس‌کننده دقت لازم در مطالعات قیاسی نیستند (Elmir, 2012). بر این اساس، مدل‌های با کمترین مقدار $RMSE$ ، MAD و AIC و دارای بیشترین مقدار R^2_{adj} بهترین مدل‌ها خواهند بود (Ahmadi *et al.*, 2014).

به منظور مقایسه و تعیین بهترین مدل‌ها از روش گرافیکی نیز استفاده شد. اساس این نمودارها بر مبنای مقایسه پراکنش متقارن نقاط برآوردشده نسبت به خط نیمساز ۴۵ درجه در محدوده ارتفاع اندازه‌گیری شده است (Castano-Santamaría *et al.*, 2013).

که در آن‌ها: H_i و H_1 به ترتیب ارتفاع مشاهده‌شده و ارتفاع برآوردشده توسط هریک از مدل‌ها و \bar{H} مقدار میانگین ارتفاع مشاهده‌شده هستند. همچنین، n و p به ترتیب تعداد مشاهدات و تعداد پارامترهای مدل را نشان می‌دهند (Aishan *et al.*, 2016).

نتایج

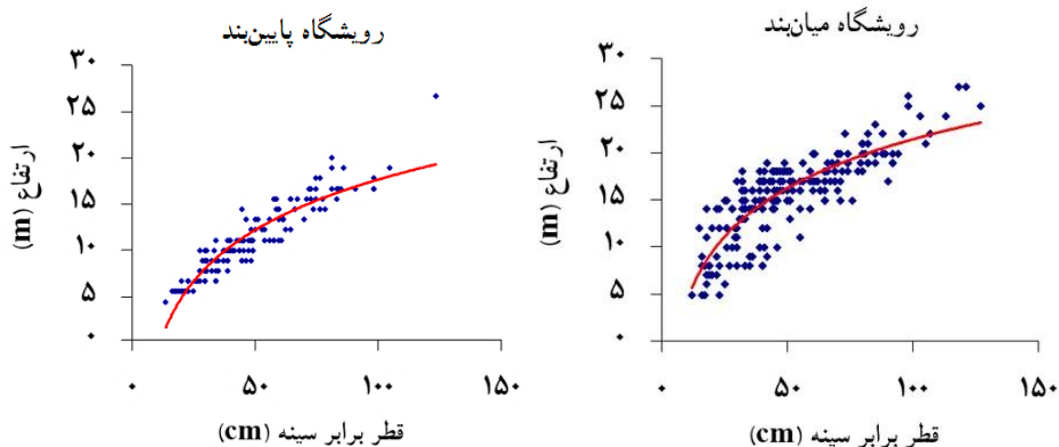
بررسی آماره‌های توصیفی قطر برابر سینه و ارتفاع درختان
نمدار

شده است. ابر نقاط متغیرهای قطر برابر سینه و ارتفاع نمدار نشان داد که رابطه این دو متغیر، سیگموئیدی، حالت مقعر و با همبستگی مثبت است که وجود رابطه قوی بین دو متغیر مذکور را بیان می‌کند (شکل ۳).

نتایج آماره‌های توصیفی درختان نمدار در جدول ۲ ارائه

جدول ۲- آماره‌های توصیفی مشخصات قطر و ارتفاع نمدار در دو طبقه ارتفاعی میان‌بند و پایین‌بند

منطقه	قطر (سانتی‌متر)			ارتفاع (متر)			تعداد مشاهدات	میانگین	کمینه	بیشینه
	انحراف معیار	میانگین	کمینه	انحراف معیار	بیشینه	کمینه				
پایین‌بند	کل	۲۱۷	۵۰/۸۹	۱۲	۱۲۷	۲۳/۳۲	۲۷/۴	۴/۲۹	۵/۲	۱۵/۵۹
	آموزش	۱۵۲	۵۱/۲۱	۱۲	۱۲۷	۲۴/۱۱	۲۷/۳	۴/۳۷	۵/۲	۱۵/۳۲
	اعتبارسنجی	۶۵	۵۰/۱۹	۱۶	۱۲۱	۲۱/۵۸	۲۷/۴	۴/۰۵	۷/۱	۱۶/۲۱
میان‌بند	کل	۱۴۰	۵۰/۷	۱۳	۱۳۰	۲۲/۷۳	۲۴/۵	۳/۴۸	۴/۳	۱۰/۱۲
	آموزش	۹۸	۴۷/۶	۱۳	۱۱۰	۲۰/۲۳	۱۸/۲	۳/۲۳	۴/۳	۹/۶۵
	اعتبارسنجی	۴۲	۵۷/۹۵	۱۷	۱۳۰	۲۶/۵۸	۲۴/۵	۳/۸۴	۵/۷	۱۱/۲۱



شکل ۳- نمودار پراکنش قطر برابر سینه در برابر ارتفاع درختان نمدار در مناطق میان‌بند و پایین‌بند

طبقه‌های ارتفاعی میان‌بند و پایین‌بند در جدول ۳ آمده است.

برآورد پارامترهای مدل‌های غیرخطی قطر-ارتفاع پارامترهای هریک از مدل‌های غیرخطی براساس

جدول ۳- پارامترهای برآورد شده مدل‌های غیرخطی قطر- ارتفاع

منطقه	مدل	پارامتر	(۱)	(۲)	(۳)	(۴)	(۵)	(۶)
دو پارامتره	a	۱/۸	۳۱/۳۵	۲۲/۳۵	۲۴/۰۱	۰/۲۵۵	۶/۸۷۷	
	b	۰/۵۲۸	۵۷/۳۷	۰/۰۲۱	-۲۳/۴۹	۰/۵۲۸	۰/۱۴۳	
میان‌بند	a	۵/۷۴۵	۵۵/۱۲	۶۱/۴۲۳	-۵/۷۴۳	۳۴/۳۲	۸۳/۷۴	
	b	-۶/۰۲۵	۰/۰۰۱۸	۰/۰۲۴	۲/۰۹۹	-۶۸/۶۳	۰/۰۱۷	
	c	-۰/۱۷۲	۰/۵۵۶	۰/۶۰۸	۰/۰۲۹	۲۹/۱۹	۰/۶۴۱	
پایین‌بند	a	۰/۳۲۶	۶۰/۵۷	۳۴/۰۹	۲۰/۵۸	۷/۰۶۴	۱/۳۲۳	
	b	۰/۸۴۳	۲۹۰/۵۶	۰/۰۰۶	-۳۹/۳۴	۰/۱۸۹	۰/۱۴۸	
	a	۱۲/۱۹	۴۵/۳۳	۴۷/۶	-۶/۸۱۸	۴۲/۰۸	۰/۹۴۶	
سه پارامتره	b	-۱۳/۹۲	۰/۰۰۴	۰/۰۰۵	۵/۰۷۷	-۱۳۹/۲	۴/۰۹۲	
	c	-۰/۰۸۴	۰/۹۳۷	۰/۹۴۳	۰/۰۱۴	۳۹/۳۴	۰/۰۱۲	

(Kaltch, 2017).

انتخاب تعداد نورون بهینه شبکه عصبی مصنوعی

برای انتخاب تعداد نورون بهینه در لایه پنهان از رویکرد سعی و خطا استفاده شد، به طوری که تعداد نورون‌های لایه پنهان از دو تا ۱۰ نورون با فاصله یک نورون افزایش داده شد. برای هر یک از تعداد نورون‌ها، ۲۰ بار آزمایش تکرار شد. نتایج نشان داد که با افزایش تعداد نورون‌ها، مقدار RMSE ابتدا کاهش یافت. سپس با مشاهده روند صعودی، فرایند آزمون و خطا متوقف شد. شبکه عصبی مصنوعی با تعداد نورون‌های دارای کمترین مقدار RMSE در مجموعه اعتبارسنجی به ترتیب برای مناطق میان‌بند (هفت نورون) و پایین‌بند (پنج نورون)، به عنوان مدل بهینه نهایی انتخاب شد.

نتایج مربوط به معیارهای کارایی سنجی منطقه میان‌بند

بررسی مقدار RMSE برای ارزیابی صحت برآورد ارتفاع نشان داد که مقدار خطا برای داده‌های آموزش بیشتر از داده‌های اعتبارسنجی است. بر طبق نتایج اعتبارسنجی، مقدار R^2_{adj} به طور میانگین بیشتر از ۰/۵۴ بود و بیشترین مقدار آن به مدل ۴ (۰/۷۰۷) تعلق داشت. همچنین، معیار MAD در مدل ۴، کمترین و در مدل ۱۲، بیشترین مقدار بود (جدول ۴).

جدول ۴- نتایج معیارهای کارایی سنجی برای داده‌های آموزش و اعتبارسنجی منطقه میان‌بند

اعتبارسنجی (۶۵ اصله)				آموزش (۱۵۲ اصله)				مدل
MAD	AIC	R ² _{adj}	RMSE	MAD	AIC	R ² _{adj}	RMSE	
۱/۹۰۲	۵۷/۷۴	۰/۶۷۶	۲/۲۸۶	۱/۹۸۹	۱۴۴/۶۱	۰/۶۶۶	۲/۵۲۲	۱
۱/۷۵۹	۵۵/۳۶	۰/۶۹۹	۲/۲۰۴	۱/۹۹۲	۱۴۵/۴۵	۰/۶۶۲	۲/۵۳۶	۲
۱/۸۱۹	۵۷/۹۷	۰/۶۷۴	۲/۲۹۴	۲/۰۲۲	۱۴۷/۵۳	۰/۶۵۳	۲/۵۷۱	۳
۱/۶۶۴	۵۴/۵۵	۰/۷۰۷	۲/۱۷۶	۱/۹۸۹	۱۵۰/۲۳	۰/۶۴۱	۲/۶۱۷	۴
۱/۷۰۶	۵۴/۷۱	۰/۷۰۵	۲/۱۸۱	۱/۹۸۷	۱۴۷/۲۴	۰/۶۵۴	۲/۵۶۶	۵
۲/۰۲۷	۶۰/۷۱	۰/۶۱۷	۲/۳۹۲	۲/۰۵	۱۴۷/۸۳	۰/۶۵۲	۲/۵۷۶	۶
۲/۵۴	۷۶/۸۳	۰/۴۴۳	۲/۹۷۳	۱/۹۸۱	۱۴۶/۷۸	۰/۶۶۵	۲/۵۲۵	۷
۲/۷۵۳	۸۱/۴۴	۰/۳۵۹	۳/۱۹۲	۱/۹۸۸	۱۴۷/۰۹	۰/۶۶۴	۲/۵۳	۸
۲/۰۱۱	۶۲/۸۷	۰/۶۳۸	۲/۳۹۸	۱/۹۸۶	۱۴۷/۰۳	۰/۶۶۴	۲/۵۲۹	۹
۲/۵۰۵	۷۶/۵۲	۰/۴۴۹	۲/۹۵۹	۱/۹۹۶	۱۴۷/۷۵	۰/۶۶۱	۲/۵۴۱	۱۰
۱/۸۳۵	۵۸/۶۸	۰/۶۸۲	۲/۲۴۹	۲/۰۰۱	۱۴۷/۹۸	۰/۶۶	۲/۵۴۵	۱۱
۳/۰۵	۸۷/۰۲	۰/۲۳۹	۳/۴۷۸	۱/۹۸۵	۱۴۶/۹۶	۰/۶۶۴	۲/۵۲۸	۱۲
۱/۶۱	۴۷/۹۴	۰/۷۴۹	۲/۰۲۷	۱/۷۷۳	۱۱۲/۲۹	۰/۷۱	۲/۰۶۶	(ANN)

جدول ۵- نتایج مربوط به محاسبه معیارهای کارایی سنجی برای داده‌های آموزش و اعتبارسنجی پایین‌بند

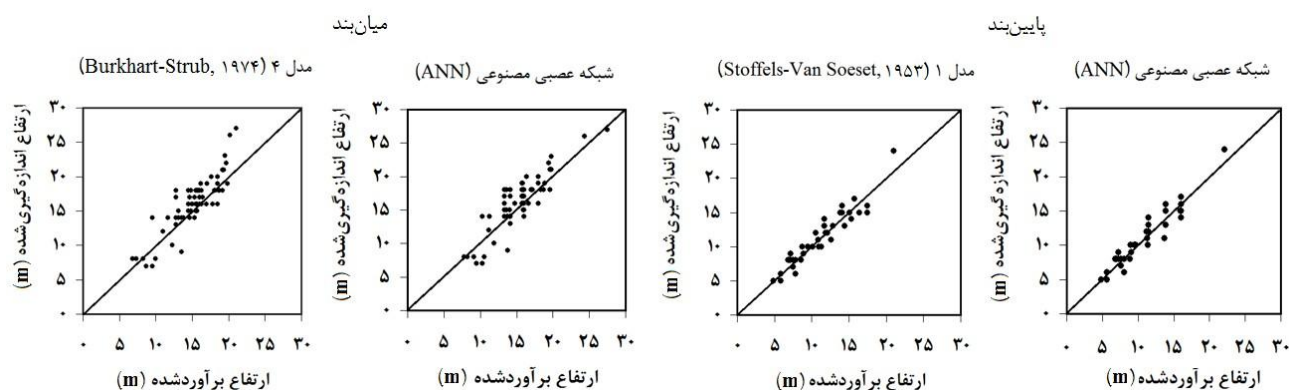
اعتبارسنجی (۴۲ اصله)				آموزش (۹۸ اصله)				مدل
MAD	AIC	R ² _{adj}	RMSE	MAD	AIC	R ² _{adj}	RMSE	
۰/۹۹۵	۱۳/۲۲	۰/۸۸۹	۱/۲۴۵	۰/۸۶۵	۱۷/۴۴۱	۰/۸۷۳	۱/۱۴۷۱	۱
۰/۱۲۰۸	۱۴/۹۸۷	۰/۸۸۴	۱/۲۹۹	۰/۸۵۷	۱۷/۳۲۱	۰/۸۷۴	۱/۱۴۵۶	۲
۰/۱۹۱	۱۵/۴۳۷	۰/۸۸۳	۱/۳۱۳	۰/۸۵۶	۱۷/۴۴	۰/۸۷۴	۱/۱۴۵۷	۳
۱/۰۵۸	۲۳/۶۶۴	۰/۸۱۹	۱/۵۹۷	۱/۰۰۹	۳۰/۰۴۳	۰/۸۳۷	۱/۳۰۴۴	۴
۱/۰۲۱	۱۷/۶۹۲	۰/۸۶۳	۱/۳۸۵	۰/۸۸۵	۲۱/۰۱۴	۰/۸۶۴	۱/۱۸۹۶	۵
۱/۰۱۲	۱۳/۹۰۳	۰/۸۸۶	۱/۲۶۵	۰/۸۸۳	۱۸/۳۲۵	۰/۸۷۱	۱/۱۵۷۴	۶
۱/۰۰۴	۱۵/۷۷۱	۰/۸۸۴	۱/۲۶۱	۰/۸۵۸	۴۶/۷۷۵	۰/۸۷۳	۱/۱۵۱	۷
۱/۰۲۳	۱۶/۵۲۶	۰/۸۷۹	۱/۲۸۴	۰/۸۵۷	۱۹/۷۸۱	۰/۸۷۳	۱/۱۵۰۹	۸
۱/۰۳۴	۱۷/۰۵۶	۰/۸۷۶	۱/۳۰۱	۰/۸۵۷	۱۹/۷۸۲	۰/۸۷۳	۱/۱۵۱۱	۹
۰/۹۹۵	۱۵/۷۰۷	۰/۸۸۴	۱/۲۶	۰/۸۵۷	۱۹/۷۶۵	۰/۸۷۳	۱/۱۵۰۸	۱۰
۰/۹۹۷	۱۶/۴۸۴	۰/۸۸	۱/۲۸۳	۰/۸۵۸	۱۹/۷۴۷	۰/۸۷۳	۱/۱۵۰۶	۱۱
۰/۹۹۵	۱۵/۶۹۵	۰/۸۸۵	۱/۲۵۹	۰/۸۵۷	۴۶/۴۵۱	۰/۸۷۳	۱/۵۱۱	۱۲
۰/۹۸۴	۸/۸۰۹	۰/۹۶۲	۱/۱۷۶	۰/۷۸۸	۹/۷۴۹	۰/۸۹۲	۱/۰۵۱	(ANN)

منطقه پایین‌بند

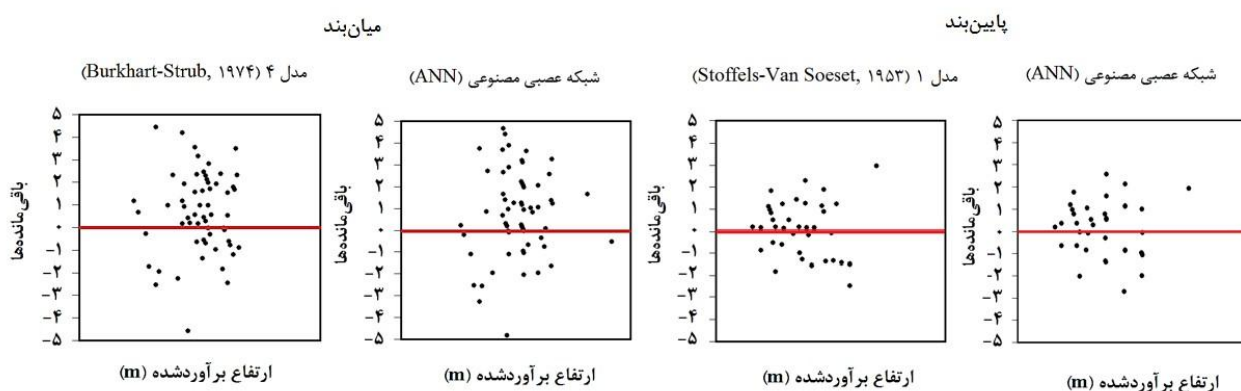
مقدار خطا (RMSE) در این طبقه ارتفاعی، نتایج متفاوت نسبت به میان‌بند از خود نشان داد. مقدار خطای داده‌های اعتبارسنجی بیشتر از داده‌های آموزش بود. البته این تفاوت بسیار اندک بود. برطبق نتایج اعتبارسنجی، ضریب تعیین تعدیل‌شده (R^2_{adj}) به‌طور میانگین بیشتر از ۰/۸۷ بود. بیشترین مقدار آن به مدل ۱ (۰/۸۸۹) تعلق داشت. کمترین مقدار معیار AIC نیز در این مدل مشاهده شد. درنهایت، با مقایسه معیار MAD، مدل‌های ۲ و ۳

کمترین مقدار را داشتند (جدول ۵).

روش گرافیکی نشان داد که در مدل‌های منتخب، نقاط به‌سمت خاصی تمایل از خود نشان ندادند و حول این خط تجمع یافته‌اند. شبکه عصبی مصنوعی در هر دو منطقه از برازش مناسب و متوازن‌تری نسبت به مدل‌های غیرخطی منتخب برخوردار بود (شکل ۴). بررسی نمودار باقی‌مانده‌های استاندارد شده در برابر ارتفاع برآورد شده نیز حاکی از برآورد مناسب‌تر روش شبکه عصبی مصنوعی نسبت به مدل‌های غیرخطی منتخب بود (شکل ۵).



شکل ۴- پراکنش ارتفاع برآورد شده در مقابل ارتفاع اندازه‌گیری شده برای داده‌های اعتبارسنجی



شکل ۵- مقدار باقی‌مانده در برابر ارتفاع برآورد شده با بهترین مدل غیرخطی و شبکه عصبی برای داده‌های اعتبارسنجی

۶ معرفی کرد، بنابراین مدل ۴ در میان‌بند و مدل ۱ در پایین‌بند از کارایی بیشتری برخوردار بودند.

به‌طور کلی، براساس چهار معیار کارایی‌سنجی و روش‌های گرافیکی استفاده‌شده برای نمدار در دو منطقه میان‌بند و پایین‌بند می‌توان مدل‌های منتخب را طبق جدول

جدول ۶- رتبه‌بندی کارایی‌سنجی بهترین مدل‌ها برای داده‌های اعتبارسنجی دو منطقه

معیار	میان‌بند	پایین‌بند
خطای جذر میانگین مربعات (RMSE)	۲ و ۵،۴	۱۰ و ۱۲،۱
ضریب تبیین تعدیل‌شده (R^2_{adj})	۲ و ۵،۴	۱۲ و ۶،۱
آکائیک (AIC)	۲ و ۵،۴	۲ و ۶،۱
انحراف مطلق میانگین (MAD)	۲ و ۵،۴	۱۰ و ۱۲،۱

بحث

ارتفاع درخت، مشخصه مهمی در تبیین ویژگی‌های توده جنگلی است. این متغیر به همراه قطر، نقش به‌سزایی در ارزیابی کیفیت و حجم سریا رویشگاه دارد. در دهه‌های اخیر، توسعه مدل‌هایی همانند توابع قطر- ارتفاع که با برآورد صحیح، جایگزین اندازه‌گیری مستقیم ارتفاع شده‌اند، مورد توجه قرار گرفته‌اند (Ahmadi et al., 2014). بررسی و مقایسه مدل‌های غیرخطی قطر- ارتفاع نمودار در دو طبقه ارتفاعی نشان داد که بهترین مدل‌ها برای هر منطقه به‌طور کامل با منطقه دیگر متفاوت هستند و هیچ‌گونه همسویی بین آن‌ها وجود نداشت. براساس نتایج معیارهای کارایی‌سنجی در منطقه میان‌بند، به ترتیب مدل‌های ۴ (Burkhart-Strub, 1974)، ۵ (Loetsch et al., 1973) و ۲ (Bates-Watts, 1980) بیشترین کارایی را داشتند، در حالی‌که در منطقه پایین‌بند با توجه به معیار RMSE، بیشترین کارایی به ترتیب متعلق به مدل‌های ۱ (Stoffels-Van Soeset, 1953)، ۱۲ (Hossfeld, 1982) و ۱۰ (Curtis, 1967) بود. این مسئله بیانگر آن است که شرایط محیطی و به‌ویژه عامل ارتفاع از سطح دریا، تأثیر به‌سزایی در تغییرات نحوه رویش درختان نمودار دارد. این یافته با نتایج Özçelik و همکاران (2014) و نیز Scaranello و همکاران (2012) همسو است. پژوهشگران مذکور گزارش کردند که مدل‌ها با بیشترین کارایی در مناطق مختلف با یکدیگر متفاوت بودند. به دلیل آنکه مدل‌های غیرخطی قطر- ارتفاع دارای تفسیر زیست‌شناسی هستند و حساسیت کمی نسبت به یک اصله با ویژگی‌های

خاص دارند، بنابراین استفاده از این مدل‌ها برای هر منطقه مجزا، نتایج واقعی‌تری دارد و برآورد آن‌ها با ثبات بیشتری همراه است (Batista et al., 2001). از علت‌های آن می‌توان به متغیر بودن شرایط رویشگاهی، وجود گونه‌های همراه با سرشت رویشی متفاوت و تغییرات رشد قطری و ارتفاعی در طول دوره‌های رویشی اشاره کرد. در مقایسه مقدار RMSE در پژوهش پیش‌رو، مقدار کمتری در منطقه پایین‌بند (میانگین ۱/۴۳) نسبت به منطقه میان‌بند (میانگین ۲/۲۱) مشاهده شد. مقدار خطا در منطقه پایین‌بند به نتایج Lei و همکاران (2009) نزدیک بود، در حالی‌که RMSE برآوردشده برای منطقه میان‌بند به پژوهش‌های Ahmadi و همکاران (2014) و Hassanzad Navroodi و همکاران (2016) مشابه بود. تفاوت مشاهده‌شده نشان می‌دهد که ارتفاع از سطح دریا به همراه شرایط رویشگاهی دیگر بر تغییرات رویشی قطر- ارتفاع نمودار در سطح توده‌های دو منطقه پایین‌بند و میان‌بند تأثیرگذار بوده است (Özçelik et al., 2014). به طوری‌که تراکم بیشتری برای این گونه در سطح توده منطقه پایین‌بند مشاهده شد. همین عامل سبب رویش مشابه‌تر بین پایه‌های نمودار تحت رقابت و تأثیر هرس طبیعی در این منطقه شده که مشاهدات میدانی نگارنده آن را تأیید می‌کند (Nazari Sendi et al., 2014). این مسئله را می‌توان در نزدیکی مقدار RMSE روابط قطر- ارتفاع و شبکه عصبی مصنوعی مشاهده کرد. هرچندکه در نهایت همانند پژوهش‌های مشابه دیگر، رویکرد شبکه عصبی مصنوعی در هر دو منطقه از بیشترین دقت و کمترین خطا نسبت به بهترین مدل‌های غیرخطی

منابع مورد استفاده

- Ahmadi, F., Alavi, S.J., Tabari Kouchaksaraei, M. and Aertsen, W., 2014. Comparison of non-linear height and diameter functions for oriental beech (*Fagus orientalis* Lipsky) in a mixed and uneven-aged Caspian forest (Case study: Tarbiat Modares University forest research station). Iranian Journal of Forest, 6(1): 11-22 (In Persian).
 - Aishan, T., Halik, Ü., Betz, F., Gärtner, P. and Cyffka, B., 2016. Modeling height-diameter relationship for *Populus euphratica* in the Tarim riparian forest ecosystem, Northwest China. Journal of Forestry Research, 27(4): 889-900.
 - Alemi, A., Oladi, J., Fallah, A. and Maghsoodi, Y., 2018. Evaluation of height-diameter nonlinear models for *Alnus* species in Hyrcanian forests (Case study: Golestan Rezaeian forest). Journal of Natural Ecosystems of Iran, 9(2): 1-12 (In Persian).
 - Batista, J.L., Couto, H.T.Z. and Marquesini, M., 2001. Performance of height-diameter relationship models: analysis in three forest types. Scientia Forestalis, 60: 149-163.
 - Burnham, K.P. and Anderson, D.R., 2004. Multimodel inference: understanding AIC and BIC in model selection. Sociological Methods & Research, 33(2): 261-304.
 - Castaño-Santamaría, J., Crecente-Campo, F., Fernández-Martínez, J.L., Barrio-Anta, M. and Obeso, J.R., 2013. Tree height prediction approaches for uneven-aged beech forests in northwestern Spain. Forest Ecology and Management, 307: 63-73.
 - Delfan Abazari, B., Sagheb-Talebi, Kh. and Namiranian, M., 2004. Regeneration gaps and quantitative characteristics of seedlings in different development stages of undisturbed beech stands (Kelardasht, Northern Iran). Iranian Journal of Forest and Poplar Research, 12(2): 251-266 (In Persian).
 - Diamantopoulou, M.J. and Özçelik, R., 2012. Evaluation of different modeling approaches for total tree-height estimation in Mediterranean Region of Turkey. Forest Systems, 21(3): 383-397.
 - Elamir, E.A.H., 2012. Mean absolute deviation about median as a tool of explanatory data analysis. Proceedings of the World Congress on Engineering. London, 4-6 July 2012: 6p.
 - Ghanbari, S. and Sheidai Karkaj, E., 2018. Diversity of tree and shrub species in woodlands of Guijeh-bel region of Ahar. Iranian Journal of Forest and Poplar Research, 26(1): 118-128 (In Persian).
 - Hagan, M.T. and Menhaj, M.B., 1994. Training feedforward networks with the Marquardt algorithm. IEEE Transactions on Neural Networks, 5(6): 989-907.
- قطر- ارتفاع برخوردار شد. این نتیجه با یافته‌های Özçelik و همکاران (۲۰۱۴) همسو بود. البته Lei و همکاران (۲۰۰۹) در جنگل‌کاری‌های گونه *Picea mariana* و *Pinus Banksiana* از مدل‌های قطر- ارتفاع با متغیرهای اضافه‌شده مانند سطح مقطع و سن استفاده کردند، اما نتایج آن‌ها از نظر بهبود کاهش مقدار خطا و برآورد ارتفاع از تغییرات چشم‌گیری نسبت به نتایج پژوهش پیش‌رو برخوردار نبود، بنابراین این رویکرد به‌عنوان روشی مناسب و جایگزین مدل‌های غیرخطی معمول در این نوع پژوهش‌ها و امور اجرایی به‌طور کامل قابل توصیه است. این رویکرد نه تنها از یک عامل به‌عنوان ورودی استفاده می‌کند، بلکه فارغ از تأثیرات محیطی، نتایج مناسبی در پی دارد. البته محاسبه رابطه قطر- ارتفاع با استفاده از مدل‌های غیرخطی از نظر سرعت انجام، کاری وقت‌گیر است، در حالی که شبکه عصبی مصنوعی می‌تواند این برآورد را بسیار سریع‌تر و فارغ از خطاهای محاسباتی کاربر انجام دهد، بنابراین می‌توان فقط با اندازه‌گیری دقیق قطر، انتخاب مدل مناسب و صرف کمترین هزینه، زمان و نیز خطا به نتایج مطلوب دست یافت.
- یافته‌های دیگر در پژوهش پیش‌رو نشان داد که مدل‌های مورد استفاده، توانایی مناسبی در پیش‌بینی ارتفاع برحسب قطر داشتند، اما در مقایسه با شبکه عصبی مصنوعی که به‌طور مطلق و در تمامی معیارها از دقت بیشتری برخوردار بود، از نظر کارایی و دقت در رده پایین‌تری قرار گرفتند. به‌طور کلی، می‌توان اظهار داشت که هر یک از مناطق رویشی، نیازمند برنامه‌ریزی متفاوت برای مدیریت توده‌های جنگلی هستند. این موضوع به‌ویژه در توده‌های خالص اهمیت بیشتری دارد. از آنجایی که بیشتر برنامه‌ریزی‌های مرتبط با توده‌های جنگلی بر مبنای قطر و ارتفاع درختان انجام می‌شود، استفاده از مدل‌های غیرخطی قطر- ارتفاع و با بیشترین دقت ممکن و یا شبکه عصبی مصنوعی که از توانایی برآورد مناسبی در رویشگاه‌ها با شرایط مختلف برخوردار است، به مدیران و برنامه‌ریزان جنگل توصیه می‌شود.

- Plotnik, A., 2000. The Urban Tree Book: An Uncommon Field Guide for City and Town. Three Rivers Press, New York, 433p.
- Rezaei, S.A., 2012. The Feature of Natural Resources and Watersheds of Iran. Pouneh Publication, Tehran, 304p (In Persian).
- Sadeghi Kaji, H., Jafari, A. and Yarali, N., 2015. An assessment of forest management sustainability in Do-Polan district, Chaharmahal and Bakhtiari Province, Iran. Iranian Journal of Forest and Poplar Research, 23(3): 490-501 (In Persian).
- Scaranello, M.A.S., Alves, L.F., Vieira, S.A., Camargo, P.B., Joly, C.A. and Martinelli, L.A., 2012. Height-diameter relationships of tropical Atlantic moist forest trees in southeastern Brazil. Scientia Agricola, 69(1): 26-37.
- Sheikhanlou Milan, M., Hassan Zad Navroodi, I., Nazari Sendi, M.R. and Bakhshandeh Navroud, B., 2014. Effect of elevation on quantitative and qualitative characteristics of lime trees in Shafaroud basin of Guilan province. Journal of Forest and Wood Product, 67(2): 245-253 (In Persian).
- Sheikholeslami, A., Namiranian, M. and Sagheb Talebi, Kh., 2005. A study of the effects of some environmental variables on large-leaved lime (*Tilia platyphyllos* Scop) in forests of Western Mazandaran. Iranian Journal of Natural Resources, 58(3): 553-566 (In Persian).
- Tsega, M., Guadie, A., Teffera, Z.L., Belayneh, Y. and Niu D., 2018. Development and validation of height-diameter models for *Cupressus lusitanica* in Gergeda forest, Ethiopia. Forest Science and Technology, 14(3): 138-144.
- Wilamowski, B.M., Chen, Y. and Malinowski, A., 1999. Efficient algorithm for training neural networks with one hidden layer. Proceedings of International Joint Conference on Neural Networks (IJCNN'99), Cat. No.99CH36339. Washington, D.C., 10-16 Jul. 1999: 1725-1728.
- Yosefzadeh, H., Tabari, M., Hosseinzadeh Colagar, A., Assadi, M., Sattarian, A. and Zare, H., 2010. Variation in leaf morphology of *Tilia* spp. of in Hyrcanian forests. Journal of Taxonomy and Biosystematics, 2(3): 11-24 (In Persian).
- Zobeiry, M., 2005. Forest Inventory (Measurement of Tree and Stand). University of Tehran Press, Tehran, 401p (In Persian).
- 993.
- Hassanzad Navroodi, I., Alavi, S.J., Ahmadi, M.K. and Radkarimi, M., 2016. Comparison of different non-linear models for prediction of the relationship between diameter and height of velvet maple trees in natural forests (Case study: Asalem Forests, Iran). Journal of Forest Science, 62(2): 65-71.
- Kalteh, A.M., 2017. Enhanced monthly precipitation forecasting using artificial neural network and singular spectrum analysis conjunction models. INAE Letters, 2(3): 73-81.
- Lei, X., Peng, C., Wang, H. and Zhou, X., 2009. Individual height-diameter models for young black spruce (*Picea mariana*) and Jack pine (*Pinus banksiana*) plantations in New Brunswick, Canada. The Forestry Chronicle, 85(1): 43-56.
- Maier, H.R. and Dandy, G.C., 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. Environmental Modelling & Software, 15(1): 101-124.
- Mohammadi, J. and Shataee, Sh., 2017. Study of different height-diameter models for hornbeam (*Carpinus betulus* L.) in uneven-aged stands of Shastkalateh forest of Gorgan. Iranian Journal of Forest and Poplar Research, 24(4): 700-712 (In Persian).
- Nazari Sendi, M.R., Hassanzad Navroodi, I., Poorbabaei, H., Sheikhanlou Milan, M. and Bakhshandeh, B., 2014. Determination of lime tree (*Tilia begonifolia* Stev.) stems form based on quantitative parameters (Study area: Shafaroud forests of Guilan province, Iran). Folia Forestalia Polonica, 56(4): 165-170.
- Ng'andwe, P., Chungu, D., Yambayamba, A.M. and Chilambwe, A., 2019. Modeling the height-diameter relationship of planted *Pinus kesiya* in Zambia. Forest Ecology and Management, 447: 1-11.
- Özçelik, R., Yavuz, H., Karatepe, Y., Gürlevik, N. and Kiriş, R., 2014. Development of ecoregion-based height-diameter models for 3 economically important trees species of southern Turkey. Turkish Journal of Agriculture and Forestry, 38: 399-412.
- Peng, C., Zhang, L., Huang, S., Zhou, X., Parton, J. and Woods, M., 2001. Developing ecoregion-based height-diameter models for jack pine and black spruce in Ontario. Forest Research Report, No. 159, Ontario Ministry of Natural Resources, Ontario, 18p.

Estimation of lime (*Tilia begonifolia* Stev.) trees height using nonlinear models

M.R. Nazari Sendi ¹, I. Hassanzad Navroodi ^{2*}, A.M. Kalth ³ and H. Poorbabaei ⁴

1- Ph.D. Student of Forest Management, Department of Forestry, Faculty of Natural Resources, University of Guilan, Sowmeh Sara, Iran

2* - Corresponding author, Associate Prof., Department of Forestry, Faculty of Natural Resources, University of Guilan, Sowmeh Sara, Iran. E-mail: ehasanzadeh@guilan.ac.ir

3- Assistant Prof., Department of Water Resources Engineering, Faculty of Natural Resources, University of Guilan, Sowmeh Sara, Iran

4- Prof., Department of Forestry, Faculty of Natural Resources, University of Guilan, Sowmeh Sara, Iran

Received: 12.10.2019

Accepted: 05.02.2020

Abstract

The diameter and height of trees are essential variables for biomass prediction, carbon storage, and forest stand development. Compared with height, measuring the diameter of trees more convenient and is associated with lower cost and error. In this study, nonlinear models were used to estimate height of lime trees in the Shafaroud forests of Guilan. Lime (*Tilia begonifolia* Stev.) trees are distributed from low to high altitude of 1800 m in Shafaroud forests and have an important role in preserving its natural composition and stand structure. A systematic random sampling method within a 200 × 200-meter network was applied for data collection. Data were collected from 48 circular sample plots with 1000 m² at altitudes from 500 to 950 m (parcels no. 29 and 30 in 16th compartment) as well as from 50-500 m (parcels no. 14 and 18 in 17th compartment). Modeling was performed with 12 commonly used nonlinear models and multilayer perceptron neural networks with the Levenberg-Marquardt algorithm, which has the advantage to accommodate the complex nonlinear relationships between input and output data. Performance criteria including root mean square error (RMSE), adjusted R², AIC, and MAD were used to compare the results. Results showed the highest performances of Burkhart-Strub (1974) in mid-altitude and Stoffels-Van Soeset (1953) models in low-altitude forests, while artificial neural network (ANN) returned the highest accuracy and performance in both sites. It decreased the RMSE by 5.54% in sub-mountain and 7.35% in low-land forests compared to the best applied nonlinear models. Although the suggested nonlinear models were accurate enough for the study site, the ANN method is preferred for its higher accuracy.

Keywords: Artificial neural network, Guilan, height-diameter, modeling, Shafaroud.