فصلنامهٔ علمی پژوهش و توسعه جنگل
جلد ۶، شماره ۳، صفحه ۳۹۴-۳۸۱، (۱۳۹۹)

# برآورد رویش ده‌ساله راش (*Fagus orientalis* Lipsky) با استفاده از مدل شبکه‌های عصبی مصنوعی و رگرسیون خطی چندگانه در جنگل‌های رامسر

**محمود بیات*[۱]، مجید حسنی[۲] و سحر حیدری مستعلی[۳]**

۱- استادیار پژوهش، مؤسسه تحقیقات جنگل‌ها و مراتع کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران. (Mbayat@rifr-ac.ir)
۲- کارشناس ارشد، موسسه تحقیقات جنگل‌ها و مراتع کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران. (Hasani@rifr-ac.ir)
۳- دانشجوی دکتری محیط‌زیست، دانشکده منابع طبیعی، دانشگاه تهران، ایران. (saharheidari@ut.ac.ir)

تاریخ دریافت: ۹۸/۰۲/۱۵ تاریخ پذیرش: ۹۸/۰۶/۲۳

## چکیده

در این تحقیق که در جنگل‌های رامسر در استان مازندران انجام شد رویش جنگل به کمک شبکه عصبی مصنوعی برآورد و با رویش واقعی جنگل که به‌طور مستقیم و از اندازه‌گیری در ۲۰ قطعه‌نمونه ثابت یک هکتاری که در سال‌های ۱۳۸۱ و ۱۳۹۱ از آماربرداری صددرصد محاسبه شده بود، مقایسه شد. رویش حجمی سالانه راش به‌ترتیب ٤/٥٢ و ٤/٣٥ سیلو در هکتار برای رویش به طریق مستقیم و رویش برآوردی به روش شبکه عصبی مصنوعی بود. سپس تحلیل رگرسیون، به روش گام‌به‌گام انجام و بهترین مدل‌ها گزینش شد. پس از انتخاب بهترین مدل، بررسی تحلیل حساسیت ورودی‌ها انجام شد. نتایج نشان داد شبکه عصبی با دقت مناسبی می‌تواند رویش و مقدار برش سالیانه را برآورد کند. مقدار $R^2$، RMSE و MAE به‌ترتیب ۰/۷۵، ۱۷ و ۱۳/٦۰ در شبکه پرسپترون چندلایه نشان داد که شبکه عصبی MLP بیشترین دقت در برآورد را دارد. در تحلیل رگرسیون خطی چندگانه هم ضرایب تشخیص به‌ترتیب ۰/٦۱۰ و ۰/٦۷۹ و خطای RMS مقادیر ۱/۵ و ۱/٤۲ برای مدل اول و دوم به‌دست آمد. نتایج مربوط به تحلیل حساسیت ورودی‌ها نشان داد که عوامل حجم، جهت، قطر برابرسینه و ارتفاع درخت بیشترین تأثیر را در مدل‌سازی تعیین رویش دارند. مقایسه مدل‌ها نشان داد استفاده از شبکه عصبی می‌تواند مقدار رویش را با دقت مناسبی پیش‌بینی کند.

**واژه‌های کلیدی:** پرسپترون چندلایه، تحلیل حساسیت، رگرسیون، رویش حجمی، مدل‌سازی.

* نویسنده مسئول شمارهٔ تماس: ۰۹۱۸۳٦۱۱٥٦۱

**مقدمه**

رویش حجمی توده‌های جنگلی اساس تعیین مقدار برش سالانه در برنامه‌ریزی و مدیریت بهره‌برداری چوب از جنگل به‌حساب آمده و از موضوعات محوری مدیریت جنگل است (Karamdost *et al*., 2019, Bayat *et al*., 2019a) برای این منظور لازم است که اطلاعات دقیقی از وضعیت کمی و کیفی توده‌های جنگلی در هنگام برنامه‌ریزی داشت. رویش درختان جنگلی تحت تأثیر عوامل درونی درخت، مؤلفه‌های محیطی و عامل زمان قرار می‌گیرد. در سال‌های مختلف حیات درخت، میزان رویش برحسب شدت نوسانات، دوام و نحوه تأثیر هر یک از عوامل یادشده تفاوت نشان می‌دهد. فیزیولوژی، سرشت گونه، سن درخت، نحوه رشد درخت در دوره‌های حیاتی آن، مشخصات ژنتیک و مرغوبیت پایه مادری از مهم‌ترین عوامل درونی هستند. وضعیت آب و هوایی، شیب زمین، جهت جغرافیایی دامنه، نوع خاک، عناصر قابل‌جذب خاک و تغذیه آبی، فاصله بین درختان، وضعیت رویش درختان مجاور و موقعیت درخت در توده از مهم‌ترین مؤلفه‌های محیطی مؤثر بر رشد درختان، به شمار می‌روند (Amini *et al*., 2009). روش‌های زیادی مانند انواع روش‌های رگرسیون خطی و غیرخطی، منطق فازی، شبکه‌های عصبی مصنوعی و غیره برای ارزیابی داده‌های به‌دست‌آمده وجود دارد که به کمک آن‌ها می‌توان به ارتباط بین متغیرهای مستقل و متغیر وابسته دست یافت. آسان بودن روش انجام، کمتر بودن هزینه و زمان انجام کار و در نهایت اعتبار داده‌های برآوردی نقش مهمی در انتخاب روش برآورد دارد (Ozçelik *et al*., 2010, Bayat *et al*., 2019b). یکی از این روش‌ها تعیین رویش حجمی با استفاده از قطعات نمونه دائم است. در این زمینه، Hatami و همکاران (2013) در پژوهشی مقدار رویش را محاسبه کردند. رویش حجمی گونه‌های اصلی با روش مایر محاسبه شد. ضریب همبستگی تشکیل‌شده میان متغیر قطر برابرسینه و رویش حجمی در گونه‌های مذکور نشان داد که از نظر آماری میان این متغیرها همبستگی قوی و معنی‌داری وجود دارد. Köhl و همکاران (1995) در تحقیقی به بررسی کاربرد قطعات نمونه دائم در مدل‌های رویش و محصول پرداختند و به این نتیجه رسیدند که قطعات نمونه دائم، اطلاعات دقیقی را با توجه به شرایط منطقه و تاریخچه آن برای مدل‌های رویش و عملکرد فراهم می‌کند. Parsapazhouh (1976) در تحقیق دیگری به این نتایج دست یافت که مقدار رویش قطری و جرم ویژه چوب راش خزر در پایگاه‌های پایین بیش از ارتفاعات میان‌بند و بالابند است. همچنین رویش قطری و جرم ویژه در گرگان و نوشهر بیش از دیگر مناطق است. مطابق نتایج این بررسی، تفاوت زیاد رویش تنها به عامل ارتفاع از سطح دریا مربوط نمی‌شود و عوامل دیگری نیز در این امر نقش دارند. بر اساس نتایج Jalilvand و همکاران (2001) روی راش آمریکایی (*F. grandifolia*) رویش راش با بارش سالانه فصل رشد، همبستگی قوی دارد و دمای تابستانه سال قبل نیز از مهم‌ترین عوامل مؤثر بر رویش آن است. Bednarz (2001) به این نتیجه رسید که بین پهنای حلقه‌های با متوسط دمای ماهانه، بارش ماهانه و روزهای هوای آفتابی ماهانه، رابطه معنی‌دار وجود دارد. بین پهنای حلقه‌ها با دمای زمستانه ارتباط معنی‌دار دیده نمی‌شود. بررسی‌های Dittmar (2001) نشان می‌دهد که پهنای حلقه‌های رویش راش اروپا نسبت به عوامل اقلیمی حساسیت زیاد نشان می‌دهند. عوامل مؤثر در رویش شعاعی به شرایط رویشگاه، به‌ویژه عرض جغرافیایی، وابستگی قوی دارند. نتایج بررسی‌های یادشده دلیل آن است که برحسب شدت نوسانات، دوام

و نیز نحوه تأثیر هر یک از عوامل یادشده، میزان رویش در سال‌های مختلف حیات درختان راش، تفاوت نشان می‌دهد. در جنگل‌های طبیعی خزان کننده با منشأ دانه-زاد چند سنی (ناهمسال)، هم‌زمان نبودن نوسانات رویش درختان، عامل پایداری جنگل به شمار می‌رود. این عوامل به‌صورت مرکب و حتی با اثر متقابل، در میزان رویش اثر می‌گذارند و رویش سالانه برآیند تأثیر همه این عوامل خواهد بود. ولی هم‌زمان نبودن، اثر چندجانبه و جابجا شدن عامل اصلی مؤثر بر رویش در سال‌های مختلف زندگی درختان، در فرآیند پیش‌بینی و برآورد رویش و تولید جنگل، پیچیدگی ایجاد می‌کند. بنابراین هرقدر بررسی‌ها در دوره طولانی‌تر انجام شود، برآوردها به واقعیت نزدیک‌تر می‌شوند (Amini *et al.*, 2009). با توجه به مبهم بودن عوامل مؤثر در رویش و همچنین مشخص نبودن میزان رقابت در بین پایه‌های درختان، ایجاد مدل برای پیش‌بینی‌های موردنظر بیش‌ازپیش ضروری به نظر می‌رسد. از مهم‌ترین عواملی که مدل‌سازی را توجیه می‌کند کاربرد مدل برای مدیریت بهتر جنگل است. مدل‌های ایجادشده میزان رویش و عوامل مؤثر بر آن را مشخص می‌کنند و بهترین گزینه را ارائه می‌دهند و در بعضی از مواقع می‌توان آینده جنگل را نیز به کمک آن‌ها پیش‌بینی کرد. تجزیه‌وتحلیل سیستمی رویکردی است که اندیشمندان از سه دهه پیش برای برخورد با مشکلات و پیش‌بینی حوادث از آن سود برده‌اند. Bayat و همکاران (2016) در تحقیقی به بررسی کارایی روش شبکه عصبی مصنوعی در برآورد موجودی سرپای توده‌های جنگلی پرداختند. نتایج کارایی شبکه عصبی پس انتشار را در برآورد موجودی سرپا و برتری روش نوین شبکه عصبی را نسبت به روش تحلیل رگرسیون نشان داد. Sohrabi و همکاران (2010)، مدل رقومی سطح، روش رگرسیون و شبکه عصبی مصنوعی را در محاسبه حجم سرپای جنگل را بررسی کردند و نتایج نشان داد که با توجه به آماره‌های مختلف محاسبه شده برای ارزیابی و مقایسه روش‌های مدل‌سازی، مدل پرسپترون تک لایه و رگرسیون خطی نتایج مناسب-تری را نسبت به دیگر روش‌ها نشان دادند. Bayati and Najafi (2013) عملکرد شبکه‌های عصبی مصنوعی با تحلیل رگرسیون در برآورد حجم تنه درختان مقایسه کردند. مقایسه معیارهای ارزیابی شبکه عصبی مصنوعی با رگرسیون گام‌به‌گام نشان داد که رگرسیون دارای ضریب تشخیص کمتر و خطای بالاتر در مقایسه با هر دو مدل شبکه عصبی است. راش خزر به شکل تیپ غالب ۱۰/۲ درصد از مساحت و به‌صورت تیپ آمیخته نه درصد از مساحت جنگل-های شمال ایران را در بر می‌گیرد (Resaneh *et al.*, 2001). دو ویژگی طولانی بودن گردش زمانی مدیریت جنگل‌های طبیعی (بیش از یک قرن) و آسیب‌پذیری گونه راش نسبت به نامساعد شدن شرایط محیطی، بر اهمیت و ضرورت دقت در برآورد رویش آن می‌افزاید؛ بنابراین با توجه به اینکه در هر نوع برنامه‌ریزی برای بهره‌برداری از جنگل و کنترل آن آگاهی از مقدار رویش امری بدیهی است و نیز مقدار رویش یکی از متغیرهای ضروری و مهم برای محاسبه امکان برداشت جنگل است، هدف این تحقیق پیش‌بینی رویش حجمی راش به‌عنوان یکی از مهم‌ترین گونه‌های تجاری جنگل‌های ایران به کمک روش شبکه عصبی و رگرسیون خطی چندگانه، توسط متغیرهای قطر برابرسینه، ارتفاع درخت، حجم، شیب، جهت و ارتفاع از سطح دریا و همچنین شناخت مهم‌ترین عوامل اثرگذار زنده و غیرزنده بر روی آن در جنگل‌های رامسر است که به کمک آنالیز حساسیت انجام شد.

## مواد و روش‌ها

**منطقه مورد بررسی**

قطعات نمونه مورد بررسی در جنگل اشکته چال حوضه آبخیز ۳۰، سری پنج صفارود رامسر، پارسل-های ۵۱۳ و ۵۱٤ با مساحت‌های به‌ترتیب ۷۵ و ٤۰ هکتار و در محدوده ارتفاعی ۱۲۰۰ تا ۱۳۰۰ متر ارتفاع از سطح دریا واقع شده‌اند. خاک در قسمت جنوبی عرصه آبرفتی و در قسمت شمالی از نوع قهوه-ای جنگلی است.

**روش جمع‌آوری داده**

در سال‌های ۱۳۸۱ و ۱۳۹۱ در قالب طرح تحقیقاتی در استان‌های مازندران، گیلان و گلستان، قطر برابرسینه به سانتی‌متر تمام درختان در قطعات نمونه ثابت یک هکتاری با استفاده از خط کش دوبازو مورد اندازه-گیری قرار گرفتند. از استان مازندران و در شهر رامسر، دو پارسل ۵۱۳ و ۵۱٤، تعداد ۲۰ قطعه‌نمونه دائمی مربع شکل به مساحت یک هکتار (۱۰۰×۱۰۰ متر) با فاصله حفاظتی ۲۵ متر (بافر) انتخاب شده و در هر قطعه‌نمونه قطر برابرسینه تمام درختان که در ارتفاع برابرسینه، قطری بزرگ‌تر از ۷/۵ سانتیمتر داشتند، اندازه‌گیری شد. اندازه‌گیری‌ها شامل قطر برابرسینه در ابتدا و انتهای دوره، شیب، جهت و ارتفاع از دریا بودند، در عرصه انجام و در برگه‌های مربوطه ثبت شدند. همچنین در سال ۹٦ در جنگل مذکور با استفاده از یک شبکه آماربرداری ۱۵۰×۲۰۰ درمجموع ۳۸ قطعه‌نمونه دائم ۱۰ آری پس از مشخص شدن مرکز قطعه‌نمونه آماربرداری شدند. (در طبیعت ابعاد شبکه به‌طور افقی پیاده شدند)، در جهت حداکثر خط شیب در دو جهت کلی قطعه‌نمونه، شیب اصلی قطعه‌نمونه مشخص و به کمک جدول تصحیح شیب، شعاع مناسب تعیین شد. در داخل قطعه‌نمونه، قطر برابرسینه تمام درختان زنده که در ارتفاع برابرسینه، قطری بزرگ‌تر از ۷/۵ سانتی‌متر داشتند به کمک خط‌کش دو بازو اندازه‌گیری و مقادیر آن‌ها در طبقات یک سانتی‌متری در برگه‌های آماربرداری به تفکیک گونه یادداشت شد. از این قطعات نمونه برای ارزیابی مدل-های رگرسیونی و مدل‌های شبکه عصبی استفاده شد.

**محاسبه رویش حجمی (تولید چوب)**

اگر مجموع حجم در آخر دوره و حجم تمام درختانی که در آماربرداری دوم برای اولین بار اندازه‌گیری شده‌اند به‌اضافه حجم درختانی که در طول دوره قطع شده‌اند محاسبه و حاصل از حجم در اول دوره کسر شود، رویش حجمی یا همان مقدار تولید چوب در طول دوره به‌دست می‌آید. با توجه به ناهمسال بودن قسمت اعظم توده‌های این بخش، برای تهیه منحنی ارتفاع، در هر قطعه‌نمونه قطورترین و نزدیک‌ترین درختان به چهارگوشه قطعات نمونه انتخاب شده، قطر برابرسینه و ارتفاع آن‌ها اندازه‌گیری و یادداشت شد. این عملیات پس از گذشت ۱۰ سال مجدداً تکرار شد و پس از اتمام کار نسبت به انجام محاسبات لازم اقدام شد. در نهایت برای محاسبه مقدار واقعی رویش حجمی جنگل از رابطه ۱ استفاده شد.

$$G_V=\frac{V_{1391}-V_{1381}+Vcuttingtree}{\Delta t}$$ رابطهٔ (۱)

در این رابطه $V_{1391}$؛ حجم جنگل در سال ۱۳۹۱ و $V_{1381}$؛ حجم آن در سال ۱۳۸۱، Vc؛ میزان حجمی که در طول این ۱۰ سال در قطعات نمونه ثابت از جنگل برداشت شده است (با توجه به اینکه از قطعات نمونه دائمی استفاده شده و نشانه‌گذاری‌ها در طول دوره مشخص بوده است، حجم قطع‌شده در طول دوره مشخص است) بالاخره Gv؛ میزان رویش حجمی سالیانه جنگل در ۱۰ سال برحسب سیلو است.

در این تحقیق در طول دو دوره از یک جدول حجم یک عامله ثابت که برای استان مازندران؛ توسط سازمان جنگل‌ها و مراتع کشور تهیه شده است، استفاده شد (رابطه ۲). روش آماربرداری در دو دوره

آماربرداری یکسان انجام شد. در اینجا v حجم جنگل به سیلو و d قطر برابرسینه به سانتی‌متر است.

رابطهٔ (۲) تاریف راش $v = 0.0001000d^{2.503}$

رابطهٔ (۳) تاریف ممرز $v = 0.0000999d^{2.470}$

رابطهٔ (٤) تاریف دیگر گونه‌ها $v = 0.0002996d^{2.273}$

**تجزیه‌وتحلیل داده‌ها با شبکه عصبی مصنوعی**

پس از آماده‌سازی داده‌ها، از نرم‌افزار NeuroSolutions 5 جهت طراحی و آموزش شبکه‌ها استفاده شد و کلیه معماری‌های بررسی شده در این محیط طراحی و اجرا شدند. تعیین معماری بهینه شبکه‌های عصبی مصنوعی (اعم از تعداد ورودی‌ها، تعداد لایه‌های مخفی، تعداد نورون در هر لایه مخفی و تابع انتقال هر یک از لایه‌ها) در افزایش دقت پیش-بینی توسط شبکه نقش تعیین کننده‌ای دارد و اغلب بر اساس فرآیند آزمون‌وخطا تعیین می‌شود؛ که لازم به ذکر است که شبکه عصبی انتخاب شده بیشترین دقت و کمترین خطا را داشت. متغیرهای قطر برابرسینه، ارتفاع درخت، حجم، شیب، جهت و ارتفاع از سطح دریا به‌عنوان ورودی شبکه و متغیر رویش حجمی به-عنوان خروجی شبکه در نظر گرفته شد. تعداد کل درختان در ۲۰ قطعه‌نمونه به‌عنوان داده‌های ورودی مدل بودند و از تک‌درختان برای مدل‌سازی استفاده شده است که شامل ٤۱۲۸ درخت بوده است. برای مدل‌سازی داده‌ها به سه قسمت آموزش، اعتبارسنجی و آزمون تقسیم شدند که نسبت هرکدام به‌ترتیب برابر با ۷۰ درصد، ۱۵ درصد و ۱۵ درصد بود (Anonymos, 2001). جهت اعتبارسنجی و آزمون داده‌های مورد استفاده، از ۳۰ درصد داده‌ها استفاده شد، همچنین از داده‌هایی که از آماربرداری با قطعات نمونه ۱۰ آری به‌دست‌آمده بود برای ارزیابی و اعتبار سنجی مدل‌های شبکه عصبی و ارائه و ارزیابی مدل-های رگرسیونی استفاده شد. در این پژوهش از شبکه پرسپترون چندلایه که معمولاً از یک‌لایه ورودی، یک یا چندلایه مخفی و یک‌لایه خروجی تشکیل می‌شود، استفاده شد. دو نوع تابع فعال‌سازی متداول برای مدل-های پیش‌بینی و تقریب تابع، توابع سیگموییید و تانژانت هیپربولیک هستند که نرمال‌سازی را بین (۰/۹ و ۰/۹-) انجام می‌دهد (Soltani *et al*., 2010). در این تحقیق از تابع فعال‌سازی تانژانت هیپربولیک استفاده شد زیرا با توجه به منابع و پژوهش‌هایی که قبلاً انجام شده است نوع تابع فعال‌سازی متداول در لایه‌های مخفی برای مدل‌های پیش‌بینی و تقریب تابع، استفاده از توابع غیرخطی سیگموییید و تانژانت هیپربولیک است (Lacerda *et al*., 2017). برای آموزش شبکه در لایه پنهان از تابع سیگموییدی و برای لایه خروجی تابع خطی BiasAxon استفاده شد. به‌طورکلی پنج مدل شبکه عصبی مصنوعی ارائه شد؛ که این مدل‌ها بسته به تعداد نرون‌ها و ورودی‌ها که شامل حجم در اول دوره، قطر برابرسینه، شیب، جهت، ارتفاع از سطح دریا، ارتفاع کل درخت بودند معرفی شدند. اصولاً تعداد نرون‌ها در لایه اول (ورودی) برابر با تعداد متغیرهای ورودی‌ها و در لایه خروجی برابر با تعداد متغیرهای خروجی‌ها مسئله تحت بررسی است. مشکل عمده، در انتخاب تعداد لایه‌های مخفی و تعداد نرون‌ها در هر یک از آن‌هاست. روش عمومی برای به‌دست آوردن آن‌ها روش سعی و خطا و البته تجربیات دیگر محققان است. اصولاً یک قانون کلی برای انتخاب نرون‌ها وجود ندارد ولی در انتخاب نرون‌ها نباید تعداد نرون‌ها انقدر زیاد باشد که باعث برازش اشتباه شود و یا اینکه تعداد نرون‌ها بسیار کم باشد به‌صورتی‌که شبکه به‌درستی تعلیم پیدا نکند و الگو و ارتباط بین ورودی‌ها و خروجی‌ها را به‌خوبی مشخص نکند (Lacerda *et al*., 2017). در تحقیقات جنگل با توجه به وجود اغتشاش و پراکندگی در داده-

ها و انعطاف‌پذیری شبکه عصبی پیش‌خور با دولایه مخفی، معمولاً شروع پردازش داده‌ها با دولایه مخفی آغاز می‌شود. منظور ارزیابی دقت مدل‌های شبکه عصبی از معیارهای ضریب تبیین ($R^2$)، خطای اریب میانگین نسبی (MBE)، خطای مطلق میانگین نسبی (MAE) و مجذور میانگین مربعات خطا (RMSE) و RMSE% (Özçelik *et al.*, 2010) در مرحله آزمون استفاده شد و با استفاده از داده‌های رویش حجمی، این مقادیر محاسبه شد. از نظر آماری هرچقدر مقدار آماره RMSE کمتر باشد، طبیعتاً برآوردهای انجام شده توسط مدل تخمین دقت بیشتری دارند. در نهایت با استفاده از نرم‌افزار NeuroSolutions جهت اولویت-بندی ورودی‌ها و مقدار اثرگذاری آن‌ها در پیش‌بینی خروجی، آنالیز حساسیت انجام شد. با ساخت شبکه، آموزش و آزمون آن و اطمینان از صحت کارکرد شبکه عصبی مصنوعی ساخته‌شده و تأیید اینکه شبکه قادر است با دقت قابل قبولی داده‌های آموزش‌دیده نشده را پیش‌بینی کند، سپس به بررسی مقدار تأثیر تک‌تک شاخص‌های ورودی در مقدار خروجی شبکه یعنی مقدار رویش پرداخته شد. به‌این‌ترتیب که جهت تعیین حساسیت هر متغیر مستقل، مقادیر دیگر متغیرهای مستقل در مقدار اسمی خود (مثلاً میانگین) ثابت نگه‌داشته شده و مقادیر متغیر موردنظر در دامنه تغییرات خود مرتباً تغییر داده شد و جواب مدل (مقدار رویش) هر بار تعیین شد. این کار برای همه متغیرهای مستقل تکرار شد و در نهایت مقدار تغییر رویش به ازای درصد تغییر هر یک از متغیرهای مستقل مشخص و متغیری به‌عنوان حساس‌ترین متغیر مدل در نظر گرفته شد که متغیر وابسته بیشترین مقدار تغییر (افزایش یا کاهش) را به ازای یک درصد افزایش یا کاهش آن متغیر دارا بود.

جدول ۱- شاخص‌های آماری استفاده شده برای ارزیابی عملکرد مدل‌های تعدیل‌شده

Table 1. Statistical Indices used to evaluate the performance of modified models

| شاخص‌های آماری<br>Statistical indicators | رابطه<br>Relation |
|---|---|
| خطای اریب میانگین نسبی<br>Skew error of relative average | $\mathrm{MBE}(\%)=\frac{\sum_{i=1}^{n}(y_i-\hat{y}_i)}{n}\cdot\frac{100}{\bar{y}}$ |
| خطای مطلق میانگین نسبی<br>Absolute error of relative average | $\mathrm{MAE}(\%)=\frac{\sum_{i=1}^{n}\lvert y_i-\hat{y}_i\rvert}{n}\cdot\frac{100}{\bar{y}}$ |
| ریشه میانگین مربع خطا<br>Root mean squared error | $\mathrm{RMSE}(\%)=\sqrt{\frac{\sum_{i=1}^{n}(y_i-\hat{y}_i)^2}{n}}\cdot\frac{100}{\bar{y}}$ |

به‌طوری‌که $y_i$ مقدار مشاهده از متغیر itd است؛ $\hat{y}_i$ مقدار تخمین زده شده از متغیر itd است؛ $\bar{y}$ میانگین مقادیر مشاهده‌شده متغیر است؛ : $\hat{y}_m$ میانگین تخمین زده شده از متغیر است. n اندازه نمونه است.

**رگرسیون خطی چندگانه**

به‌منظور مقایسه تخمین‌های شبکه عصبی با مدل‌های رگرسیون خطی و برآورد دقت آن‌ها در تخمین مشخصه رویش درختان راش، مدل‌سازی این مشخصه با استفاده از تحلیل رگرسیون گام‌به‌گام (Stepwise) و انتخاب بهترین زیرمجموعه‌ها بین داده‌ها با استفاده از

آماره‌های اشتباه معیار مدل برازش یافته، میانگین مربعات خطای برآورد و تحلیل واریانس رگرسیون انجام شد. در مدل رگرسیونی چندگانه، داده‌های مربوط به ارتفاع از سطح دریا، ارتفاع درخت، شیب، جهت، قطر برابرسینه و حجم به‌عنوان متغیرهای مستقل به کار گرفته شدند.

## نتایج

رویش حجمی سالانه راش به‌ترتیب ٤/٥٢ و ٤/٣٥ سیلو در هکتار برای رویش به طریق مستقیم و رویش برآوردی به روش شبکه عصبی مصنوعی بود. در جدول ۲ پنج مدل برتر رویش حجمی درختان در شبکه یک‌لایه و دولایه آورده شد و در نهایت شبکه عصبی با دولایه مخفی و تعداد سه نرون در لایه مخفی اول و پنج نرون در لایه مخفی دوم به‌عنوان بهترین مدل انتخاب شد. عدد لایه‌های پنهان و نورون‌ها با استفاده از آزمون‌وخطا مشخص شده تا زمانی که بهترین ساختار شبکه با توجه به معیارهای ارزیابی حاصل شود. لازم به ذکر است که واحد رویش مترمکعب در هکتار است که RMSE محاسبه شده در جدول برای یک هکتار است.

جدول ۲- پنج مدل برتر شبکه عصبی در پیش‌بینی مقدار رویش گونه راش

Table 2. Five best models of neural network in predicting the rate of growth of beech species

| RMSE | $R^2$ | توپولوژی مدل Model topology | تعداد نورون در لایه مخفی The number of neurons in the hidden layer 2 | تعداد نورون در لایه مخفی The number of neurons in the hidden layer 1 | شماره مدل Model number |
|---|---|---|---|---|---|
| 0.6 | 0.38 | 6-17-1 | 17 | 6 | 1 |
| 0.5 | 0.45 | 4-1-1 | 1 | 4 | 2 |
| 0.5 | 0.35 | 2-4-1 | 4 | 2 | 3 |
| 0.4 | 0.68 | 6-1 | 0 | 6 | 4 |
| 0.35 | 0.75 | 3-5-1 | 5 | 3 | 5 |

جدول ۳- شاخص‌های آماری محاسبه‌شده برای مدل شبکه عصبی مصنوعی

Table 3. Statistical Indicators Calculated for Artificial Neural Network Model

| RMSE% | RMSE | MAE | MBE | $R^2$ | |
|---|---|---|---|---|---|
| 8.11 | 0.85 | 13.60 | -0.98 | 0.75 | آموزش (تعلیم) Education (training) |
| 8.78 | 0.92 | 14.93 | -5.63 | 0.76 | آزمون (تست) Education (test) |

جدول ٤ نتایج همبستگی متغیر رویش با متغیرهای مستقل مورد بررسی را نشان می‌دهد. لازم به ذکر است متغیرهای شیب و ارتفاع از سطح دریا به دلیل نداشتن همبستگی معنی‌دار در جدول وارد نشده است. همان‌گونه که مشاهده می‌شود بیشترین ضریب همبستگی مربوط به متغیرهای حجم و قطر و کمترین متغیر جهت و ارتفاع درخت است.

جدول ٥ نتیجه ارزیابی روش رگرسیون را با متغیرهای مورد بررسی و به روش تحلیل گام‌به‌گام نشان می‌دهد.

شکل‌های ۱ و ۲ خروجی پیش‌بینی‌شده رویش را با رویش واقعی در حالت‌های مختلف مدل رگرسیون چندگانه خطی و مدل شبکه عصبی مقایسه کرده است.

جدول ٤- ضریب همبستگی (r) بین متغیرها

Table 4. Coefficient of correlation (r) between variables

| حجم<br>Volume | قطر برابرسینه (سانتی‌متر)<br>DBH (cm) | جهت<br>Aspect | ارتفاع درخت<br>Height | متغیر<br>Variable |
|---|---|---|---|---|
| 0.852** | 0.480** | 0.411* | 0.355* | رویش<br>Growth |

*معنی‌داری در سطح پنج درصد، **معنی‌داری در سطح یک درصد.

* Significance at the 5% level, **Significance at the 1% level.

جدول ٥- نتیجه ارزیابی روش رگرسیون چندمتغیره در برآورد رویش راش به روش گام‌به‌گام

Table 5. The result of evaluation of multivariate regression method in incremental estimation stepwise method

| $R^2$ | RMSE% | RMSE | مدل<br>Model | حالت<br>Type |
|---|---|---|---|---|
| 0.610 | 14.32 | 1.5 | G= 0.776+0.016V | 1 |
| 0.679 | 13.55 | 1.42 | G= -1.693+0.015V+0.079H | 2 |

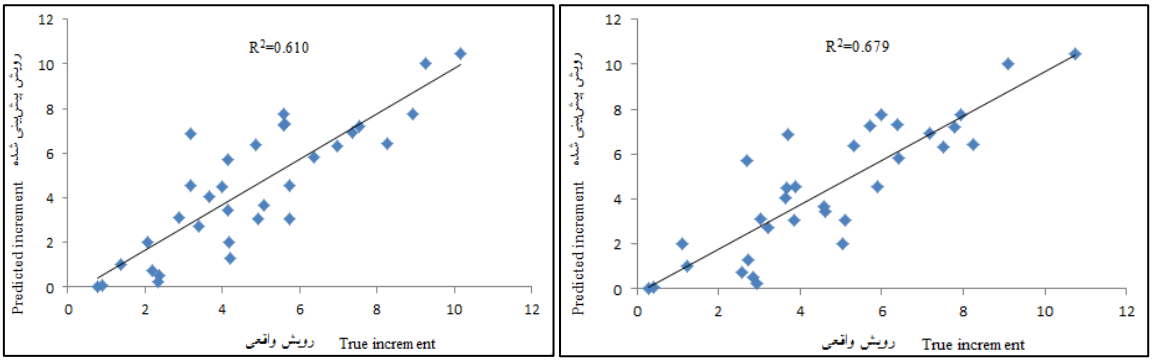


شکل ۱- مقایسهٔ خروجی رویش واقعی با خروجی رویش پیش‌بینی‌شده توسط مدل اول و دوم رگرسیون جدول ۷

Figure 1. Comparison of True increment and predicted increment by regression model

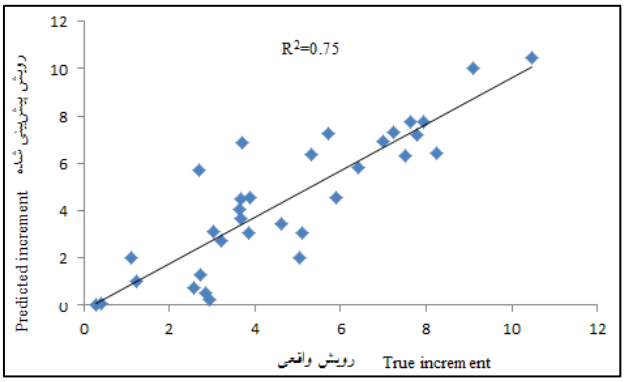


شکل ۲- مقایسه خروجی رویش واقعی و رویش پیش‌بینی‌شده توسط مدل شبکه عصبی

Figure 2. Comparison of True increment and predicted increment by neural network model

نتایج مربوط به تحلیل حساسیت ورودی‌ها در شکل ۳ نشان داده شده است (در این تحقیق از ۳۰ درصد کل درختان در ۲۰ قطعه‌نمونه ثابت یک هکتاری برای ارزیابی مدل استفاده شده است و ازآنجایی‌که تعداد درختان بسیار زیاد بود و نمودار بسیار متراکم و غیرقابل فهم می‌شود از ٤۳ درخت به-

صورت نمادین استفاده شده است). با توجه به نتایج، عوامل زیر به ترتیب برای حجم، جهت، قطر برابرسینه و ارتفاع درخت بیشترین تأثیر را در مدل‌سازی تعیین رویش دارند.

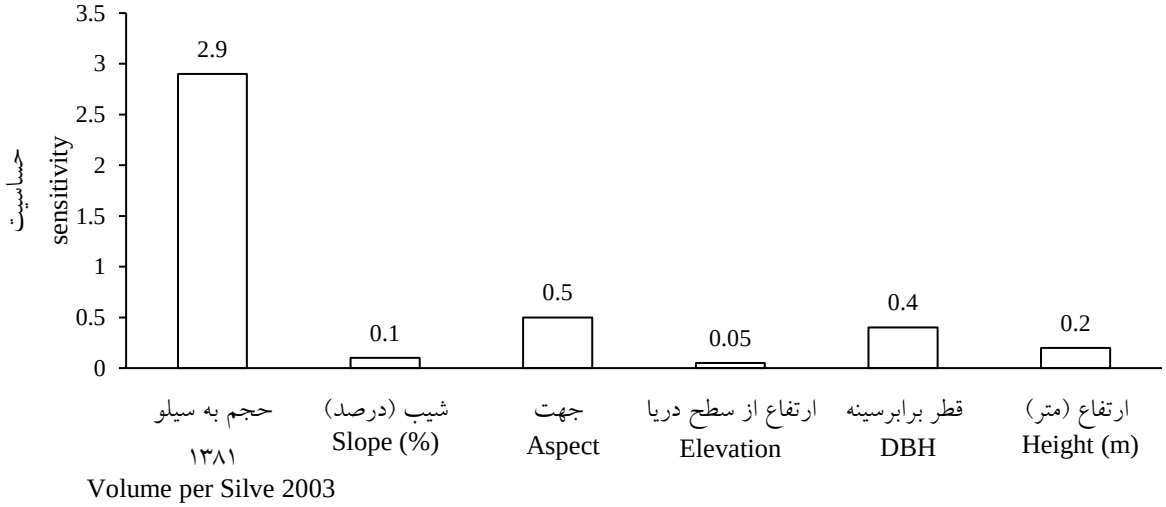


شکل ۳- تحلیل حساسیت ورودی‌های مدل پیش‌بینی رویش حجمی

Figure 3. Sensitivity analysis of inputs of the predicted model of volumetric growth

رویش حجمی سالانه راش به ترتیب ٤/٥٢ و ٤/٣٥ سیلو در هکتار برای رویش به طریق مستقیم و رویش برآوردی به روش شبکه عصبی مصنوعی بود. رویش به طریق مستقیم از آماربرداری ۲۰ قطعه‌نمونه یک هکتاری در طول یک دوره ۱۰ ساله ۱۳۸۱ و ۱۳۹۱ به‌دست‌آمده است و رویش برآوردی با استفاده از شبکه‌های عصبی مصنوعی برآورد شد.

**بحث**

مقایسه مدل‌ها با استفاده از رایج‌ترین معیارهای ارزیابی مدل همانند معیارهای ضریب تبیین و مجذور میانگین مربعات خطا و اعتبارسنجی مدل‌های رگرسیون خطی نشان داد که استفاده از شبکه عصبی می‌تواند مقدار رویش را در یک دوره ۱۰ ساله با دقت مناسبی پیش‌بینی کند. رویش حجمی پدیده بسیار پیچیده‌ای است که به عوامل مختلف درونی و بیرونی وابسته است، عوامل درونی شامل قطر برابرسینه، ارتفاع درخت و حجم هستند و عوامل برونی عبارت‌اند از شیب، جهت و ارتفاع از سطح دریا. همچنین این عوامل خود در طول دوره از دیگر عوامل از قبیل خشکی، مقدار رطوبت خاک و هوا، سرعت و جهت باد، مقدار بارندگی و خیلی از عوامل محیطی دیگر تأثیر می‌پذیرد. با توجه به ساختار طراحی‌شده برای شبکه در مدل‌سازی تولید چوب، ملاحظه می‌شود که یک شبکه پرسپترون چندلایه با برقراری اتصالات کامل بین نرون‌ها در سرتاسر شبکه، می‌تواند برای یادگیری مسائل غیرخطی به کار رود. پیروی خروجی‌های مدل از الگوی خروجی‌های واقعی در نمودار حاصل از دقت مدل نیز گویای تناسب شبکه با مسئله داده شده است. قابل‌ذکر است که پیدا کردن تعداد لایه پنهان و تعداد نرون مناسب برای هر مدل شبکه عصبی نیاز به آزمون‌وخطا دارد، بنابراین در هر بار آموزش باید معیارهای ارزیابی اندازه‌گیری شده تا زمانی که کمترین خطا حاصل شود. انتخاب تعداد و نوع متغیرها به‌عنوان ورودی شبکه بستگی به اهداف

مجری داشته و معمولاً هنگامی‌که هزینه و زمان در اولویت باشند تعداد متغیرهای کمتر و در دسترس انتخاب‌شده اما زمانی که هدف کسب دقت بالا باشد تعداد متغیرهای بیشتری به‌عنوان ورودی شبکه مدنظر قرار داده می‌شوند. در این تحقیق مشخص شد که حجم در اول دوره بیشترین تأثیر را بر رویش چوبی می‌گذارد. جهت، قطر برابرسینه و ارتفاع کل در مرحله بعد اثرگذاری هستند (شکل ٤). تغییرات شیب و ارتفاع از سطح دریا با توجه به اینکه در این عرصه جنگلی بسیار محدود و ناچیز بوده‌اند تأثیر بسیار ناچیزی بر مقدار رویش دارند. نتایج ارزیابی مدل نشان داد که شبکه عصبی مصنوعی با توجه به مقدار $R^2$، MSE و RMSE به ترتیب ۰/۷۵، ۷ (سیلو) و ۱۷ (درصد) سیلو، قادر به پیش‌بینی رویش حجمی و تولید چوب با دقت قابل قبولی است (جدول ۳) که با نتایج حاصل از پژوهش‌های Özçelik و همکاران (2010)، Bayat و همکاران (2016) و Vahedi و همکاران (2017) که به ترتیب به بررسی پیش‌بینی رویش قطر و ارتفاع و بررسی زی‌توده درختان به کمک شبکه عصبی و مصنوعی پرداخته بودند، هم-خوانی دارد. استفاده از این فن نسبت به روش‌های آماری از این جهت ارزشمند است که امکان پردازش را با سرعت بیشتر و زمان کمتر نسبت به عملیات میدانی فراهم می‌کند. بررسی نتایج ارزیابی مدل‌های شبکهٔ عصبی مصنوعی نشان داد که شبکهٔ عصبی مصنوعی MLP با توابع انتقال سیگموئیدی توانایی بالایی در پیش‌بینی رویش درخت و عوامل تأثیرگذار بر آن دارد که با نتایج Correia Vieira و همکاران (2017) که به ارزیابی کارایی دو روش شبکه عصبی مصنوعی MLP و روش نروفازی برای پیش‌بینی و تخمین قطر و ارتفاع گونه اکالیپتوس پرداختند و کارایی روش شبکه عصبی را در برآورد مشخصات کمی درختان تائید کردند هم‌خوانی دارد. یافتن تعداد لایه پنهان و تابع انتقال مناسب در هر یک از مدل‌های شبکهٔ عصبی مصنوعی نیاز به‌دقت زیادی داشته و باید به‌صورت سعی و خطا مشخص شود؛ به‌طوری‌که در هر آزمون باید معیارهای ارزیابی اندازه‌گیری شده و تا زمانی فرآیند آموزش شبکه‌ها تکرار شود که کمترین خطا بین مقادیر پیش‌بینی‌شده با مقادیر واقعی به‌دست آید (جدول ۵). شاخصه‌های آماری محاسبه‌شده در بخش نتایج شبکهٔ عصبی مصنوعی نشان می‌دهد که شبکهٔ عصبی مصنوعی دقت بالایی $R^2$ (بیشتر) و خطای کمتری در پیش‌بینی دارد که این امر را می‌توان به عدم وابستگی شبکهٔ عصبی به فرضیه‌های اولیه دربارهٔ داده‌ها نسبت داد (Bayat *et al.*, 2018). عدم محدودیت در تعداد متغیرهای ورودی، به‌خصوص عوامل کیفی مؤثر که در معادلات مربوط به تولید چوب وارد نمی‌شوند از دیگر امتیازات فن شبکه عصبی است. مقدار عددی حساسیت حجم در اول دوره، جهت، قطر برابرسینه و ارتفاع برای رویش بیشتر از دیگر متغیرها بود که گویای اهمیت متغیرهای فوق در تعیین رویش چوبی است. در این تحقیق متغیرهای حجم در اول دوره، قطر برابرسینه، ارتفاع کل، عوامل توپوگرافی، نوع گونه برای افزایش دقت کار و دست‌یابی به اطلاعاتی در ارتباط با مقدار نقش مؤثر این عوامل بر رویش، به‌عنوان ورودی شبکه در نظر گرفته شدند. ارتفاع از سطح دریا از آن نظر که بر مقدار درجه حرارت و انرژی تابشی خورشید اثرگذار است به‌عنوان یکی از مهم‌ترین متغیرهای تأثیرگذار بر رویش است. در این پژوهش نیز حداقل و حداکثر ارتفاع از سطح دریا مشخص‌شده و به‌صورت کد دهی شده وارد مدل شدند و تأثیر آن بر رویش مشخص شد. در مورد جهت جغرافیایی دامنه نیز بر درجه حرارت و مقدار انرژی دریافتی از خورشید تأثیر دارد

و در کنار ارتفاع از سطح دریا یکی از متغیرهای تأثیر-گذار بر رویش حجمی جنگل است. ارزشمندی این مدل از آن جهت است که می‌توان عوامل کیفی را نیز در تعیین مقدار رویش حجمی مورد بررسی قرار داد؛ بنابراین در کل می‌توان بیان کرد که تجزیه‌وتحلیل داده‌های رویشی نیازمند روش‌های تحلیلی انعطاف-پذیر و قوی است. علاوه بر این، درک و ارائه نتایج توسط این روش‌ها باید ساده و به‌راحتی قابل تفسیر باشد. در سال‌های اخیر انواع روش‌های مدل‌سازی که به روش‌های یادگیری ماشین معروف‌اند، با استفاده از متغیرهای محیطی، برای پیش‌بینی توان تولیدی رویشگاه، توسعه‌یافته است. در خاتمه باید تأکید کرد که بیان ریاضی روابط بین متغیرهای محیطی و مشخصه‌های بیولوژیکی و بیوفیزیکی تنها کمکی برای تفسیر مشاهدات میدانی است، زیرا در اکوسیستم‌های جنگلی به دلیل پویایی عوامل زیستی، حتی قوی‌ترین روابط همبستگی نیز چه در پژوهش‌های استاتیک و چه در پژوهش‌های دینامیک نمی‌توانند قطعی فرض شوند (Fakur *et al.*, 2017). به‌طورکلی همان‌گونه که نتایج پژوهش‌های مشابه نشان می‌دهد، مقایسهٔ بین معیارهای جدول‌های نتایج شبکهٔ عصبی مصنوعی و رگرسیون چند متغیره نشان می‌دهد که شبکهٔ عصبی دقت بهتر $R^2$ بیشتر و خطای کمتری در پیش‌بینی دارد که این امر را می‌توان به عدم وابستگی شبکهٔ عصبی به فرض‌های اولیه دربارهٔ داده‌ها نسبت داد، زیرا ممکن است بین متغیرها رابطه‌ای غیرخطی وجود داشته باشد که رگرسیون قادر به پیش‌بینی آن نبوده است ( Bayati and Najafi, 2013). از پژوهش‌هایی که با یافته‌های پژوهش حاضر همسو هستند می‌توان به تحقیق Bayati and Najafi (2013) اشاره کرد که مقایسهٔ عملکرد شبکه‌های عصبی مصنوعی با تحلیل رگرسیون در برآورد حجم تنهٔ درختان در جنگل آموزشی پژوهشی دانشگاه تربیت مدرس انجام داده و نتیجه گرفتند که شبکهٔ عصبی مصنوعی دارای RMSE و کمتر و $R^2$ بیشتری در مقایسه با روش رگرسیون در برآورد حجم تنهٔ درخت است. مقایسهٔ اشکال حاصل از حجم تنهٔ واقعی و پیش‌بینی‌شده نیز بیانگر تطابق بیشتر این دو در نتایج حاصل از شبکهٔ عصبی است. همچنین Vafaei و همکاران (2016) کاربرد مدل شبکه عصبی مصنوعی و رگرسیون خطی چندگانه در برآورد تراکم جنگل در جنگل‌های باغان مریوان انجام داده و نتایج کلی پژوهش آن‌ها نشان‌دهنده پتانسیل استفاده از داده-های توپوگرافی، خاک‌شناسی، اقلیمی و اطلاعات دورسنجی در برآورد تراکم جنگل بررسی شده بود که در این راستا مدل‌سازی شبکه عصبی مصنوعی نسبت به تحلیل رگرسیون خطی چندگانه دارای دقت برآورد بیشتری بود. Sajjadi (2016) نیز در تحقیقی پیرامون ارائه مدل‌های رویشی راش با استفاده از شبکه‌های عصبی مصنوعی در بخش گرازبن جنگل خیرود به این نتیجه دست یافت که متغیرهای قطر برابرسینه و ارتفاع درخت بیشترین اثر را بر رویش حجمی و قطری راش داشته و متغیرهای توپوگرافی مانند شیب و جهت و ارتفاع کم‌ترین اثر را در رویش حجمی و قطری دارند که همسو با یافته‌های پژوهش حاضر است. همچنین، Lacerda و همکاران (2017) حجم درختان را در جنگل‌های ساوانا برزیل با استفاده شبکه عصبی و رگرسیون تخمین زده که نتایج نشان داد که شبکه‌های عصبی مصنوعی می‌توانند مقادیر پیش‌بینی شده‌ای را که نزدیک یا بهتر از مقادیر ارائه شده توسط معادلات حجمی هستند، تولید کنند. لازم به ذکر است که انتخاب تعداد متغیرهای لازم به‌عنوان ورودی‌های شبکه بستگی به هدف مجری دارد؛ به‌طوری‌که اگر هدف برآورد رویش با دقت بالا باشد، از مدلی استفاده می-شود که بیشترین ورودی را داشته باشد. ولی اگر هدف

برآورد با هزینهٔ کمتر باشد از متغیرهایی که نیاز به زمان و امکانات و تخصص کمتری به‌منظور محاسبه دارند، استفاده خواهد شد (Bayati and Najafi, 2013). به‌طورکلی می‌توان چنین نتیجه گرفت که با وجود دسترسی به رویش واقعی، جهت برآورد دقیق، با صحت بالا و با صرف هزینه و زمان کمتر و نیز برای اینکه در دیگر رویشگاه‌ها نیز برآورد رویش به‌راحتی انجام گیرد، استفاده از شبکه عصبی لازم است (Lacerda *et al.*, 2017) که همان‌گونه که نتایج پژوهش حاضر و مرور یافته‌های پژوهش‌های مشابه دیگر نشان داد، شبکه عصبی با ضریب تشخیص بالاتر و صحت قابل‌قبول‌تری نسبت به دیگر مدل‌ها مانند رگرسیون، به‌خوبی رویش جنگل را برآورد و پیش‌بینی کند.

## References


- Amini, M., M. Namiranian, Kh. Sagheb Talebi & R. Amini, 2009. Investigation on the homogenity of diameter increment models in *Fagus orientalis* L. trees, *Journal of Wood and Forest Science and Technology*, 16(4): 1-23. (In Persian)
- Anonymos, 2001. Safarood forestry plan. Technical office of the forests, grasslands and Watershed Department, 285 p.
- Bayat, M., M. Ghorbanpour, R. Zare, A. Jaafari & B. Thai Pham, 2019b. Application of artificial neural networks for predicting tree survival and mortality in the Hyrcanian forest of Iran, *Computers and Electronics in Agriculture*, 164: 1-7.
- Bayat, M., M. Namiranian, M. Omid, A. Rashidi & S. Babaei, 2016. Applicability of artificial neural network for estimating the forest growing stock, *Iranian Journal of Forest and Poplar Research*, 24(2): 214-226. (In Persian)
- Bayat, M., A. Shekarchian & M. Omid, 2018. Predicting and assessing the tree species survival and determining Physiographic factors affecting on it in Mazandaran province Forests using artificial neural networks, *Journal of Natural Environment*, 70(4): 771-782.
- Bayat, M., P. Thanh Noi, R. Zare & D. Tien Bui, 2019a. A semi-empirical approach based on genetic programming for the study of biophysical controls on diameter-growth of Fagus orientalis in Northern Iran, *Remote Sensing*, 11(14): 1-18.
- Bayati, H. & A. Najafi, 2013. Comparison of artificial neural network üerformance with regression analysis in estimating lumber volume, *Forest and wood products*, 66(2): 177-191. (In Persian)
- Bednarz, Z., 2001. Dendrochronological evidence in Beech (*Fagus sylvatica* L.) of May late forest in the Polish Tatra national park, poster abstract 123, conference "Tree rings and people" Sep. 22-26 2001, Swiitzerland.
- Correia Vieira, G., A. Ribeiro de Mendonça, G. Fernandes da Silva, S. Sara Zanetti, M. Marques da Silva & A. Rosa dos Santos, 2017. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence, *Science of the Total Environmen*, 619: 1473-1481
- Dittmar, C., 2001. Influence of climate on tree rings of common beech (*Fagus sylvatica* L.), poster abstract 7, conference "Tree rings and people" Sep 22-26 2001, Swiitzerland.
- Fakur, E., J. Alavi, M. Tabari & K. Ahmadi, 2017. Estimating the beech forest site productivity in Hyrcanian forest using classification and regression tree algorithm, *Journal of Forest and Wood Productions*, 70(2): 221-229. (In Persian)
- Hatami, N., M. Moayeri & H. Heidari, 2013. Volume increment determination of forest stand types in the district one of Dr Bahramnia forest management plan, Gorgan, *Iranian Forests Ecology Journal*, 2(3): 657-69. (In Persian)
- Jalilvand, H., Gh. Jalali, M. Akbarnia, M. Tabari & M. Hosseini, 2001. Growth response to eight hardwood species to current and past climatic variations using regression models, *Journal of Agricultural. Science and Technology*, 3(3): 209-225.
- Karamdost meryan, B., A. Eslam bonyad & F. Tvankar, 2019. Effect of harvest intensity on volume growth of mixed beech stands in Asalem Nav forests, *Journal of Forest Research and Development*, 4(4): 533-547. (In Persian)
- Köhl, M., C. Scott & A. Zingg, 1995. Evaluation of permanent sample surveys for growth and yield studies: a Swiss example,

*Forest Ecology and Management*, 71(3): 187-194.
- Lacerda, T., C. D. Cabacinha, A. Araújo Júnior, R. Dourado Maia, K. Wesley & S. Lacerda, 2017. Artificial neural networks for estimating tree volume in the Brazilian savanna, *CERNE*, 23(4): 483-491.
- Ozçelik, R., J. M. Diamantopoulou, J. R. Brooks & H. V. Wiant Jr, 2010. Estimating tree bole volume using artificial neural network models for four species in Turkey, *Journal of Environmental Management*, 91(3): 742-753.
- Parsapazhouh, D., 1976. Investigation on the physical quality of fagus orientalis in different sites, *Iranian Journal of Natural Resources*, 34: 21-32. (In Persian)
- Resaneh, Y., M. H. Moshtagh Kahnamooyee & P. Salehi, 2001. Investigation of quality and qyantity of north forest, P 55-80. In: Proceedings of north forests management and stable development conference, Ramsar, Iran. (In Persian)
- Sajjadi, M., 2016. Provide vegetative models of beech species using artificial neural networks. Master's thesis. Faculty of Natural Resources. University of Tehran. Karaj, Iran. (In Persian)
- Sohrabi, H., S. M. Hosseini & M. Zobeiri, 2010. Application of Digital Surface Model for estimating forest stand volume using Regression methods and Artificial Neural Network, *Iranian Journal of Natural Resources*, 64(3): 223-233. (In Persian)
- Soltani, S., S. Sardari, M. Sheykhpour & S. Mousavi, 2010. Understanding the principles and applications of artificial neural networks. Scientific and Cultural Organization of Nas, Tehran, 216p. (In Persian)
- Vafaei, S., M. Pourhashemi, M. Pirbavaghar & E. Jafari, 2016. Applying artificial neural network and multiple linear regression models for estimation of forest density in Marivan forests, *Iranian Journal of Forest*, 7(4): 539-555. (In Persian)
- Vahedi, A., A. Mataj & R. Akhavan, 2017. Modeling the commercial volume of trees in mixed beech stands of Hyrcanian forests through artificial neural network, *Forest and Wood Products*, 70(1): 49-60. (In Persian)

# Ten-year estimation of *Fagus orientalis* Lipsky increment using artificial neural networks model and multiple linear regression Ramsar forests

**M. Bayat[*1], M. Hasani[2] and S. Heidari Masteali[3]**

1- Assistant Prof., Research Institute of Forests and Rangelands, Agricultural Research, Education and Extension Organization (AREEO), Tehran, I. R. Iran. (Mbayat@rifr-ac.ir)
2- M.Sc. Graduate, Research Institute of Forests and Rangelands, Agricultural Research, Education and Extension Organization (AREEO), Tehran, I. R. Iran. (Hasani@rifr-ac.ir)
3- PhD. Student of Environment, Faculty of Natural Resources, University of Tehran, I. R. Iran. (saharheidari@ut.ac.ir)

Received: 05.05.2019 Accepted: 14.09.2019

## Abstract

In this research, which was done in Ramsar forests in Mazandaran province, the forest increment was estimated using artificial neural network and compared with the actual increment of the forest which was directly measured in 20 sample plots of 1 hectare in 2002 and 2012. The annual volume growth of beech was 4.52 and 4.35 m3 in hectare for direct inventory and estimation by artificial neural networks. Then regression analysis was performed to compare the results, stepwise, and the best models were selected. After selecting the best model for forecasting growth, the sensitivity analysis of inputs was investigated.The results showed that the neural network with relatively good accuracy can estimate the annual growth and cutting. The value of R2, RMSE and MAE were 0.75, 17 and 13.6 (for 20 sample plot of one hectare) respectively in the multi-layer perceptron network. Results also showed that the MLP neural network had the highest accuracy in predicting and estimation. In the analysis of multiple linear regression, the coefficients of detection were 0.610 and 0.679, respectively, and RMSE was 1.5 and 1.42, respectively, for the first and second models respectively. The volume at the beginning of the period and the diameter at breast height had the greatest impact on the amount of wood produced. Comparison of the models showed the use of neural network can predict the growth rate with proper accuracy.

***Keywords***: Multi Layer Perceptron, Sensitive analysis, Regression, Volume increment, Modeling.

[*] Corresponding author Tel: +989183611561