مجلهٔ جنگل ایران، انجمن جنگلبانی ایران
سال هجدهم، شمارهٔ ۲، تابستان ۱۴۰۵
ص ۳۲۲-۳۰۵
مقاله پژوهشی

شناسه دیجیتال (DOI): 10.22034/ijf.2026.543471.2066
CC BY 4.0

بررسی تأثیر تنوع گونه‌های درختی، ویژگی‌های ساختاری توده و عوامل محیطی بر رویش حجمی سالانه در جنگل‌های هیرکانی با استفاده از مدل‌های شبکهٔ عصبی مصنوعی و رگرسیونی

محمود بیات[۱]، سحر حیدری مستعلی[۲] و سیده کوثر حمیدی[۳*]

[۱]دانشیار بخش تحقیقات جنگل، مؤسسهٔ تحقیقات جنگل‌ها و مراتع کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران
[۲]دانش‌آموختهٔ دکتری، گروه محیط زیست، دانشکدهٔ منابع طبیعی، دانشگاه تهران، ایران
[۳]استادیار گروه جنگلداری، دانشکدهٔ منابع طبیعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران

(تاریخ دریافت: ۱۴۰۴/۰۶/۲۶ تاریخ پذیرش: ۱۴۰۵/۰۲/۲۸)

چکیده

مقدمه: تنوع زیستی از مؤلفه‌های مهم پایداری و عملکرد بوم‌سازگان‌های جنگلی است و می‌تواند از راه سازوکارهایی مانند مکملیت گونه‌ای و کاهش رقابت درون‌گونه‌ای، بر تولید زیستی و رشد توده‌های جنگلی تأثیرگذار باشد. با وجود پژوهش‌های گسترده در زمینهٔ رابطهٔ تنوع- تولید، تأثیر تنوع گونه‌های درختی، ساختار توده و عوامل محیطی در تعیین رویش حجمی جنگل‌های هیرکانی به‌طور همزمان کمتر بررسی شده است. هدف این پژوهش، مدل‌سازی رویش حجمی سالانهٔ جنگل‌های هیرکانی و ارزیابی متغیرهای زیستی، ساختاری و محیطی با استفاده از رویکردهای پارامتریک و ناپارامتریک است.

مواد و روش‌ها: داده‌ها از ۲۵۸ قطعه نمونهٔ دائمی در یک دورهٔ ۹ ساله جمع‌آوری شد. رویش حجمی سالانه (متر مکعب در هکتار در سال) به‌عنوان متغیر وابسته در نظر گرفته شد و متغیرهای تنوع گونه‌های درختی، سطح مقطع توده (متر مربع در هکتار)، سطح مقطع قطورترین درختان در قطعه نمونه (متر مربع در هکتار)، سرعت باد، دمای هوا، انرژی خورشیدی و شاخص خیسی توپوگرافی به‌عنوان متغیرهای مستقل وارد مدل‌ها شدند. برای مدل‌سازی از رگرسیون چندگانه، شبکهٔ عصبی پرسپترون چندلایه (MLP) و شبکهٔ تابع پایهٔ شعاعی (RBF) استفاده شد و عملکرد مدل‌ها بر اساس شاخص‌های R^2، RMSE و BIAS ارزیابی شد.

یافته‌ها: نتایج نشان داد که مدل MLP با ضریب تعیین ۰/۸۵ عملکرد بهتری نسبت به رگرسیون چندگانه (۰/۵۷) و RBF در پیش‌بینی رویش حجمی دارد. تحلیل حساسیت مدل MLP نشان داد که غنای گونه‌های درختی با سهم ۳۰/۹ درصد بیشترین تأثیر را بر تغییرات رویش حجمی داشته است، درحالی که متغیرهای ساختاری توده در مجموع حدود ۲۹ درصد و عوامل محیطی هر یک حدود ۱۰ درصد از تغییرات را تبیین کردند.

نتیجه‌گیری: یافته‌ها نشان می‌دهد که رویش حجمی جنگل‌های هیرکانی حاصل تعامل پیچیده و غیرخطی میان تنوع گونه‌های درختی، ساختار توده و شرایط محیطی است و با استفاده از شبکه‌های عصبی مصنوعی می‌توان چارچوبی کارآمد برای مدل‌سازی این روابط فراهم آورد. این نتایج بر اهمیت حفظ تنوع گونه‌های درختی به‌عنوان محرکی اساسی در افزایش بهره‌وری و پایداری بلندمدت جنگل‌های هیرکانی تأکید دارد.

واژه‌های کلیدی: تحلیل حساسیت، تنوع گونه‌های درختی، جنگل‌های هیرکانی، رویش حجمی سالانه، ساختار توده، شبکهٔ عصبی مصنوعی.

* نویسنده مسئول شماره تماس: ۰۹۱۱۳۵۶۹۰۶۸ ایمیل: k.hamidi86@yahoo.com

مقدمه

تنوع زیستی از مؤلفه‌های بنیادین پایداری بوم‌سازگان‌های جنگلی است و تأثیر مهمی در ثبات ساختاری و عملکردی این اکوسیستم‌ها دارد. در دهه‌های اخیر، رابطهٔ بین تنوع زیستی و کارکردهای اکوسیستم، به‌ویژه کارکرد تولیدی جنگل‌ها، به یکی از محورهای اصلی پژوهش‌های بوم‌شناسی جنگل تبدیل شده است. در این چارچوب، افزایش تنوع گونه‌های درختی می‌تواند از طریق سازوکارهایی مانند تکمیل‌پذیری بهره‌برداری از منابع و کاهش رقابت درون‌گونه‌ای، موجب افزایش تولید زیستی و رویش توده‌های جنگلی شود (Paquette & Messier, 2011; Van de Perre et al., 2016) با این‌حال، شدت و جهت این رابطه در شرایط مختلف اقلیمی و ساختاری یکسان نیست و ممکن است تحت تأثیر عوامل محیطی و ویژگی‌های توده تغییر کند (Baruffol et al., 2013; Forrester & Bauhus, 2016; Ouyang et al., 2019).

جنگل‌های هیرکانی به‌عنوان یکی از ارزشمندترین بوم‌سازگان‌های جنگلی جهان، از تنوع زیاد گونه‌های درختی و ساختارهای ناهمسال و پیچیده برخوردارند و اثر مهمی در تأمین خدمات اکوسیستمی دارند. در چنین اکوسیستم‌هایی، رویش حجمی توده‌های جنگلی نه‌تنها تحت تأثیر ترکیب و غنای گونه‌های درختی، بلکه متأثر از ویژگی‌های ساختاری مانند سطح مقطع، تراکم و شاخص رقابت و همچنین عوامل محیطی مانند دما، تابش خورشیدی، رطوبت و شرایط توپوگرافی است (Bayat & Hamidi, 2019; Bayat et al., 2023).

پژوهش‌های متعددی رابطهٔ بین تنوع زیستی و تولید یا رویش جنگل را بررسی کرده‌اند. در بسیاری از پژوهش‌ها رابطه‌ای مثبت و معنادار میان غنای گونه‌های درختی و تولید زیستی گزارش شده است (Paquette & Messier, 2011; Baruffol et al., 2013; Poorter et al., 2015; Van de Perre et al., 2016; Hamidi et al., 2020; Vahedi et al., 2024) در مقابل، برخی تحقیقات نشان داده‌اند که این رابطه ممکن است ضعیف، منفی یا وابسته به شرایط محیطی و ساختاری باشد (Forrester & Bauhus, 2016; Ouyang et al., 2019) برای مثال Ouyang et al. (2019) بیان کردند که در برخی گرادیان‌های محیطی، عواملی مانند سن و تراکم توده ممکن است تأثیر بیشتری نسبت به تنوع زیستی در پیش‌بینی تولید داشته باشند. همچنین Rita & Borghetti (2019) در جنگل‌های ایتالیا رابطه‌ای مثبت میان تنوع درختی و تولید گزارش کردند، درحالی که Morin et al. (2014) نشان دادند افزایش غنای گونه‌های درختی می‌تواند پایداری تولید را در طول زمان ارتقا دهد. این نتایج متناقض بیانگر آن است که تبیین رویش حجمی جنگل‌ها مستلزم در نظر گرفتن همزمان عوامل زیستی، ساختاری و محیطی است.

افزون‌بر تنوع زیستی، عوامل محیطی نیز نقش اساسی در تعیین الگوی رشد و رویش جنگل‌ها دارند (Fallah et al., 2023). متغیرهایی همچون تابش خورشیدی، دمای هوا، شاخص رطوبت توپوگرافی (TWI) و سرعت باد ممکن است به‌طور مستقیم یا غیرمستقیم بر دسترسی به منابع، شدت رقابت و در نهایت تولید زیستی تأثیرگذار باشند (Bayat et al., 2021; Kweon & Comeau, 2019; Bayat et al., 2022). برای نمونه Bourque & Bayat (2015) نشان دادند که سرعت باد و برخی شاخص‌های طیفی بخش بزرگی از تغییرات غنای گونه‌های درختی را تبیین می‌کنند که این موضوع بیانگر تأثیر مهم شرایط محیطی در ساختار و عملکرد توده‌های جنگلی است.

در بیشتر پژوهش‌های پیشین، روابط بین تنوع زیستی، ساختار توده و تولید جنگل با استفاده از مدل‌های رگرسیونی کلاسیک تحلیل شده است (Bayat et al., 2021; Kweon & Comeau, 2019; Bayat et al., 2022). با این‌حال، این مدل‌ها مبتنی بر فرض‌هایی مانند خطی بودن روابط و توزیع نرمال داده‌ها هستند که ممکن است در داده‌های پیچیدهٔ جنگلی به‌طور کامل برقرار نباشد. در سال‌های اخیر، روش‌های ناپارامتریک مانند شبکه‌های عصبی مصنوعی به‌دلیل توانایی در مدل‌سازی روابط غیرخطی

و پیچیده، کانون توجه قرار گرفته‌اند. با وجود این، مقایسهٔ همزمان عملکرد مدل‌های پارامتریک و شبکه‌های عصبی در تبیین رویش حجمی جنگل‌های هیرکانی تا کنون کمتر بررسی شده است.

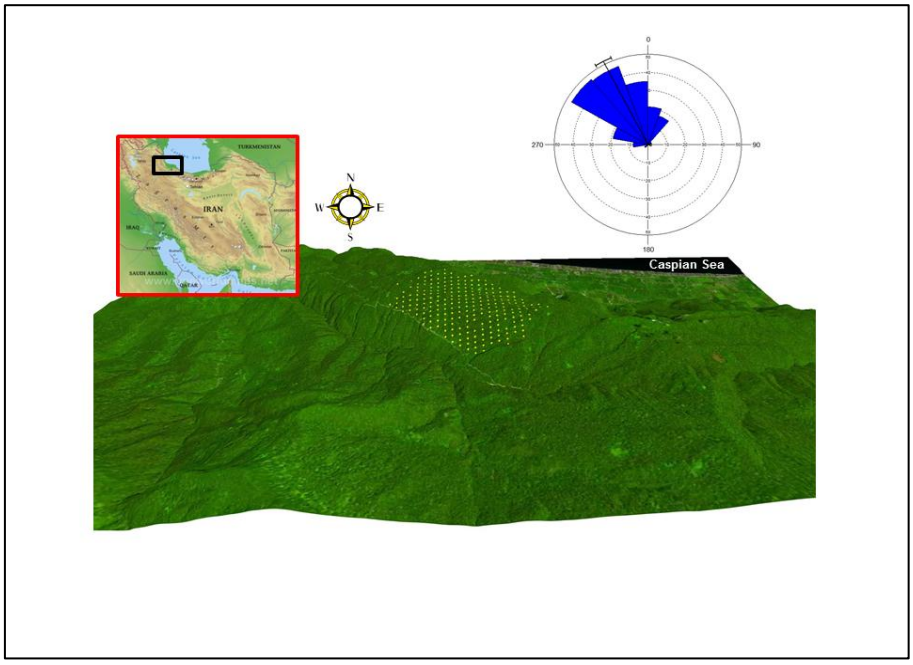
بر این اساس، مسئلهٔ اصلی این پژوهش آن است که رویش حجمی توده‌های جنگلی هیرکانی تا چه اندازه تحت تأثیر شاخص‌های تنوع زیستی درختی، ویژگی‌های ساختاری توده و عوامل محیطی قرار دارد و توانایی کدام‌یک از روش‌های مدل‌سازی (رگرسیون چندگانه یا شبکهٔ عصبی مصنوعی) در پیش‌بینی این متغیر بیشتر است.

هدف این پژوهش، مدل‌سازی رویش حجمی جنگل‌های هیرکانی به‌عنوان شاخص تولید زیستی، بر پایهٔ شاخص‌های تنوع گونه‌های درختی، متغیرهای ساختاری توده و عوامل محیطی، و مقایسهٔ عملکرد روش‌های پارامتریک و ناپارامتریک در تبیین این روابط است. همچنین، درجهٔ اهمیت نسبی هر یک از متغیرهای مستقل در مدل‌های توسعه‌یافته ارزیابی می‌شود. از منظر نظریهٔ تنوع- کارکرد اکوسیستم(BEF) ، انتظار می‌رود تنوع گونه‌های درختی سهم معناداری در تبیین رویش حجمی داشته باشد، اما شدت این اثر در تعامل با ساختار توده و شرایط محیطی تعیین می‌شود.

مواد و روش‌ها

منطقهٔ پژوهش

این پژوهش در بخش گرازبن جنگل خیرود دانشگاه تهران در استان مازندران انجام گرفت. در این بخش از جنگل خیرود، ۲۵۸ قطعه نمونهٔ ثابت دایره‌شکل با مساحت یک‌دهم هکتار به‌صورت تصادفی- سیستماتیک روی شبکه‌ای با ابعاد ۱۵۰×۲۰۰ متر استقرار یافتند (شکل ۱). برای بازیابی درختان در اول و آخر دورهٔ مختصات همهٔ درختان نسبت به مرکز قطعه نمونه و فاصلهٔ درختان از مرکز قطعه نمونه ثبت شد. شبکهٔ آماربرداری با ابعاد ۲۰۰ در ۱۵۰ و استفاده از قطعات نمونهٔ ثابت ده آری رایج‌ترین روش آماربرداری در جنگل‌های هیرکانی است که توسط سازمان‌های اجرای کشور از جمله سازمان منابع طبیعی برای پایش بلندمدت جنگل‌های هیرکانی استفاده شده است.



شکل ۱- موقعیت منطقهٔ پژوهش در استان مازندران، پراکنش قطعات نمونه‌برداری (نقاط زرد) در شبکه‌ای منظم با ابعاد ۲۰۰×۱۵۰ متر، موقعیت کشوری منطقه (نقشهٔ کوچک) و نمودار جهت غالب باد

Figure 1. Location of the study area in Mazandaran Province, sampling plots (yellow dots) on a regular 200 × 150 m grid, national location (inset map), and prevailing wind direction

شیوهٔ اجرای پژوهش

در هر قطعه نمونه، قطر برابرسینهٔ (DBH) همهٔ درختان دارای قطر بیش از ۷ سانتی‌متر در ابتدا (سال ۲۰۰۳/۱۳۸۲) و انتهای دوره (سال ۲۰۱۲/۱۳۹۱) با روش یکسان اندازه‌گیری شد. همچنین در دورهٔ دوم، درختان تازه واردشده به طبقهٔ قطری ۷ سانتی‌متر ثبت شدند. همهٔ درختانی که در طول آماربرداری دوم قطع و بهره‌برداری شده بودند یا به هر دلیلی خشک شده و از بین رفته بودند ثبت و مشخص شدند. در طول دورهٔ آماربرداری در این بخش از جنگل خیرود هیچ گونه بهره‌برداری صورت نگرفته است.

محاسبهٔ رویش حجمی (متغیر وابسته)

در این پژوهش، رویش حجمی سالانهٔ توده (متر مکعب در هکتار در سال) به‌عنوان متغیر وابسته در نظر گرفته شد. حجم هر درخت با استفاده از روابط آلومتریک معتبر همهٔ گونه‌های جنگل‌های هیرکانی در جنگل خیرود از جمله *Fagus orientalis* Lipsky و *Carpinus betulus* L. و گونه‌های دیگر مطابق با جدول حجم تهیه‌شدهٔ سازمان منابع طبیعی برآورد شد (Briggs et al., 1989).

رویش حجمی سالانه بر اساس رابطهٔ ۱ محاسبه شد:

$$VI = \frac{(VE + VH - VB)}{years}$$ رابطهٔ ۱

که در آن VI: رویش سالانه ($m^3\ ha^{-1}\ yr^{-1}$)، VB: حجم ابتدای دوره، VE: حجم انتهای دوره، VH: حجم برداشت‌شده یا حذف‌شده، years: طول دوره (۹ سال) است. رویش حجمی به‌عنوان شاخص تولید، به‌دلیل بازتاب مستقیم عملکرد رشد توده در بازهٔ زمانی بلندمدت انتخاب شد (Bayat et al., 2013).

متغیرهای مستقل

۱. متغیرهای ساختاری توده

برای توصیف ساختار کمّی توده که می‌تواند بر رقابت، تخصیص منابع و در نهایت رویش تأثیرگذار باشد، متغیرهای زیر محاسبه شد: سطح مقطع کل(BA)، تراکم درختان در هکتار (N)، سطح مقطع قطورترین درختان(BAL).

این شاخص‌ها بیانگر شدت رقابت، غالبیت و اشغال فضا در توده هستند و در پژوهش‌های رشد و تولید، متغیرهای اساسی محسوب می‌شوند (Hamidi et al., 2021; Hamidi & Fallah, 2025).

۲. شاخص‌های تنوع گونه‌های درختی

برای سنجش نقش ترکیب گونه‌ای در رویش، شاخص‌های زیر محاسبه شد: غنای گونه‌های درختی (S)، شاخص شانون-وینر (H')، شاخص سیمپسون (λ).

این شاخص‌ها افزون‌بر تعداد گونه‌ها، یکنواختی توزیع آنها را نیز منعکس می‌کنند (Krebs, 1999; Keylock, 2005). این شاخص‌ها به‌دلیل کاربرد گستردهٔ آنها در مطالعات رابطهٔ تنوع– تولید و قابلیت مقایسه با تحقیقات پیشین انتخاب شدند.

جدول ۱- شاخص‌های تنوع زیستی به‌کاررفته در پژوهش همراه با فرمول‌های مربوط (Krebs, 1999)

Table 1. Biodiversity indices used in the study, along with the relevant formulas (Krebs, 1999)

نام شاخص Name	فرمول Formula	منبع Refrence
شاخص غنا Richness Index	$R = S$	(Magurran, 1988)
شانون وینر Shannon-Wiener Species	$H = -\Sigma p_i \ln(p_i)$	(Shannon, 1948)
سمپسون Sampson	$\lambda = \Sigma p_i^2$	(Simpson, 1949)

که در آن:

S: تعداد کل گونه‌های شناسایی‌شده در قطعه نمونه (غنای گونه‌های درختی)، pi: نسبت تعداد افراد گونهٔ i به کل افراد موجود در قطعه نمونه، ni: تعداد افراد گونهٔ N،i: مجموع کل افراد (درختان) همهٔ گونه‌ها در یک قطعه نمونه است.

اگرچه سه شاخص رایج تنوع شامل غنای گونه‌های درختی، شانون-وینر و سیمپسون محاسبه شد، به‌دلیل وجود هم‌خطی زیاد (VIF>5) بین شاخص شانون و غنای گونه‌های درختی و نیز عملکرد ضعیف‌تر شاخص‌های تنوع در مرحلهٔ غربالگری اولیهٔ مدل، فقط غنای گونه‌های درختی به‌عنوان نماینده تنوع زیستی وارد فرایند مدل‌سازی نهایی شد. این موضوع با یافته‌های پژوهش‌های جدید مانند Baach et al. (2022) که نشان می‌دهند غنای گونه‌های درختی در مقایسه با شاخص‌های تنوع، تأثیر قوی‌تر و بیشتری بر بهره‌وری جنگل دارد همسو است.

۳. متغیرهای محیطی

به‌منظور در نظر گرفتن اثر گرادیان‌های محیطی، متغیرهای زیر استخراج شد: تابش خورشیدی بر پایهٔ (DEM)، میانگین دمای فصل رویش، شاخص خیسی توپوگرافی(TWI)، سرعت باد (مدل‌سازیCFD). این متغیرها نمایانگر شرایط انرژی، حرارتی و رطوبتی سایت هستند و می‌توانند بر رشد درختان و شدت رقابت اثرگذار باشند (Bourque & Bayat, 2015; Bayat et al., 2023; Kwon et al., 2019).

این شاخص‌ها در سطح قطعه نمونه و با استفاده از ترکیبی از داده‌های ایستگاه‌های هواشناسی و تصاویر ماهواره‌ای طی محاسبات پیچیده برآورد شدند (برای اطلاعات بیشتر ر.ک. بورک و بیات، ۲۰۱۵).

پیش‌پردازش داده‌ها

برای افزایش دقت مدل‌سازی، مراحل زیر انجام گرفت:

۱. بررسی داده‌های پرت با استفاده از فاصله کوک (Cook's distance)؛

۲. آزمون هم‌خطی چندگانه با شاخص VIF و حذف متغیرهای دارای VIF>5؛

۳. نرمال‌سازی متغیرها در بازهٔ (-۰/۹ تا ۰/۹) برای آموزش شبکهٔ عصبی؛

۴. تقسیم داده‌ها به مجموعه آموزش (۷۰ درصد) و آزمون (۳۰ درصد).

این مراحل به‌منظور جلوگیری از بیش‌برازش و افزایش تعمیم‌پذیری مدل‌ها انجام گرفت (Hamidi et al., 2023).

روش‌های مدل‌سازی

رگرسیون چندگانه

به‌منظور ایجاد مبنایی پارامتریک برای مدل‌سازی و مقایسه با روش‌های ناپارامتریک، از رگرسیون خطی چندگانه استفاده شد. این روش به‌دلیل قابلیت تفسیر مستقیم ضرایب برآوردشده و تعیین جهت و شدت اثر هر متغیر مستقل بر متغیر وابسته انتخاب شد (Masteali et al., 2025a). افزون‌بر این، رگرسیون چندگانه در پژوهش‌های رشد و تولید جنگل کاربرد گسترده‌ای دارد و چارچوب کلاسیک تحلیل روابط کمّی در اکوسیستم‌های جنگلی شناخته می‌شود. مدل در محیط نرم‌افزار R توسعه یافت و برازش آن بر اساس روش حداقل مربعات معمولی (OLS) انجام گرفت. پیشفرض‌های کلاسیک مدل شامل نرمال بودن باقی‌مانده‌ها، همگنی واریانس و نبود هم‌خطی چندگانه بررسی شد تا اعتبار استنباط‌های آماری تضمین شود. این مدل مبنای مقایسهٔ عملکرد با الگوریتم‌های یادگیری ماشین در نظر گرفته شد.

شبکهٔ عصبی مصنوعی

با توجه به احتمال وجود روابط غیرخطی و اثرهای متقابل پیچیده میان متغیرهای ساختاری، محیطی و تنوع گونه‌های درختی، از شبکه‌های عصبی مصنوعی به‌عنوان رویکرد ناپارامتریک استفاده شد. در این پژوهش دو الگوریتم متداول شامل پرسپترون چندلایه

(MLP)و شبکهٔ تابع پایهٔ شعاعی (RBF) به کار گرفته شد.

الگوریتم MLP به‌دلیل توانایی در تقریب توابع غیرخطی پیچیده و انعطاف‌پذیری در مدل‌سازی روابط چندبعدی انتخاب شد. MLP کاربرد گسترده‌ای در پژوهش‌های اکولوژیک و مدل‌سازی رشد جنگل دارد (Hamidi et al., 2023). همچنین شبکهٔ RBF به‌منظور مقایسهٔ عملکرد معماری‌های متفاوت شبکهٔ عصبی و ارزیابی حساسیت نتایج نسبت به ساختار مدل به کار گرفته شد (Nazariani et al., 2022).

تعداد نورون‌های لایه پنهان در هر دو معماری با استفاده از روش آزمون و خطا و بر اساس کمینه‌سازی ریشهٔ میانگین مربعات خطا (RMSE) تعیین شد. فرایند آموزش شبکه‌ها به‌گونه‌ای انجام گرفت که از بیش‌برازش (Overfitting) جلوگیری شده و تعمیم‌پذیری مدل حفظ شود.

تحلیل حساسیت

برای تعیین اهمیت نسبی متغیرهای ورودی در مدل نهایی MLP و تفسیر اکولوژیک نتایج مدل ناپارامتریک، تحلیل حساسیت به روش تغییر یک‌به‌یک (One-at-a-time) انجام گرفت. در این روش، هر یک از متغیرهای ورودی به میزان ±۱۰ درصد تغییر داده شد، درحالی که بقیهٔ متغیرها ثابت نگه داشته شدند. سپس درصد تغییر نسبی در خروجی مدل (رویش حجمی سالانه) ثبت شد.

اهمیت نسبی هر متغیر بر اساس رابطهٔ ۲ محاسبه شد:

$$Sensitivity(\%) = \frac{\Delta Output}{Output} \div \frac{\Delta Input}{Input} \times 100$$ رابطهٔ ۲

این تحلیل امکان شناسایی مؤثرترین عوامل بر رویش حجمی و تفکیک سهم نسبی عوامل ساختاری توده، متغیرهای محیطی و شاخص‌های تنوع گونه‌های درختی را فراهم کرد و چارچوبی برای تفسیر زیست‌بوم‌شناختی نتایج مدل شبکهٔ عصبی ارائه داد.

معیارهای ارزیابی مدل

به‌منظور ارزیابی عملکرد مدل‌های پارامتریک و ناپارامتریک، از سه شاخص آماری شامل ضریب تعیین(R^2)، ریشهٔ میانگین مربعات خطا (RMSE) و شاخص اریب (BIAS) استفاده شد (روابط ۳ تا ۵). ضریب تعیین بیانگر میزان تبیین تغییرات متغیر وابسته توسط مدل است. RMSE میزان پراکندگی خطاهای پیش‌بینی را نشان می‌دهد و شاخص BIAS تمایل سیستماتیک مدل به بیش‌برآورد یا کم‌برآورد مقادیر واقعی را مشخص می‌کند (Bayat et al., 2022). استفادهٔ همزمان از این شاخص‌ها امکان مقایسهٔ جامع دقت، صحت و پایداری مدل‌ها را فراهم کرد.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(p_{Si} - \hat{p}_S)^2}$$ رابطهٔ ۳

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(p_{Si} - \hat{p}_S)^2}{\sum_{i=1}^{n}(p_{Si} - \hat{p}_S)}$$ رابطهٔ ۴

$$Bias = \frac{1}{n}\sum_{i=1}^{n}(p_{si} - \hat{p}_s)$$ رابطهٔ ۵

که در آن p_{Si} رویش مشاهده‌شده، p_s رویش برآوردشده، $\hat{p}_S$ میانگین رویش مشاهده‌شده و $\hat{p}_s$ میانگین رویش برآوردشده است.

نتایج

پیش‌پردازش داده‌ها

برای افزایش دقت مدل‌سازی و جلوگیری از برآوردهای اریب، داده‌ها پیش از ورود به مدل‌ها ارزیابی و پالایش شدند.

بررسی داده‌های پرت: با استفاده از فاصلهٔ کوک (Cook's Distance)، نقاط دارای تأثیر نامتعارف بر مدل شناسایی شدند. بر این اساس، از مجموع ۲۵۸ قطعه نمونه، ۶ قطعه نمونه (معادل ۲/۳ درصد کل داده‌ها) به‌دلیل داشتن فاصلهٔ کوک بیشتر از آستانه به‌عنوان داده پرت تشخیص داده شده و از فرایند مدل‌سازی حذف شدند. بیشتر این داده‌های پرت مربوط به قطعات نمونه‌ای با مقادیر بسیار زیاد رویش

حجمی (بیش از ۱۲۰ متر مکعب در هکتار در سال) یا سطح مقطع غیرمعمول بودند.

بررسی هم‌خطی چندگانه

پیش از مدل‌سازی، شاخص تورم واریانس (VIF) برای شناسایی هم‌خطی بین متغیرهای مستقل محاسبه شد. نتایج نشان داد که شاخص‌های تنوع شامل شانون (VIF > 10) و سیمپسون (VIF ≈ 8.5) دارای هم‌خطی زیادی با غنای گونه‌های درختی بودند. پس از حذف این دو شاخص، تمامی متغیرهای باقی‌مانده دارای VIF کمتر از ۳ بودند که بیانگر نبود هم‌خطی معنادار در مدل نهایی است (جدول ۲). غنای گونه‌های درختی به‌عنوان نمایندهٔ تنوع زیستی در مدل‌ها حفظ شد.

نرمال‌سازی داده‌ها: برای آموزش شبکهٔ عصبی، همهٔ متغیرهای مستقل با استفاده از روش Min-Max در بازهٔ ۰/۹- ، ۰/۹ نرمال‌سازی شدند.

جدول ۲- تورم واریانس VIF پیش و پس از حذف متغیرهای هم‌خط

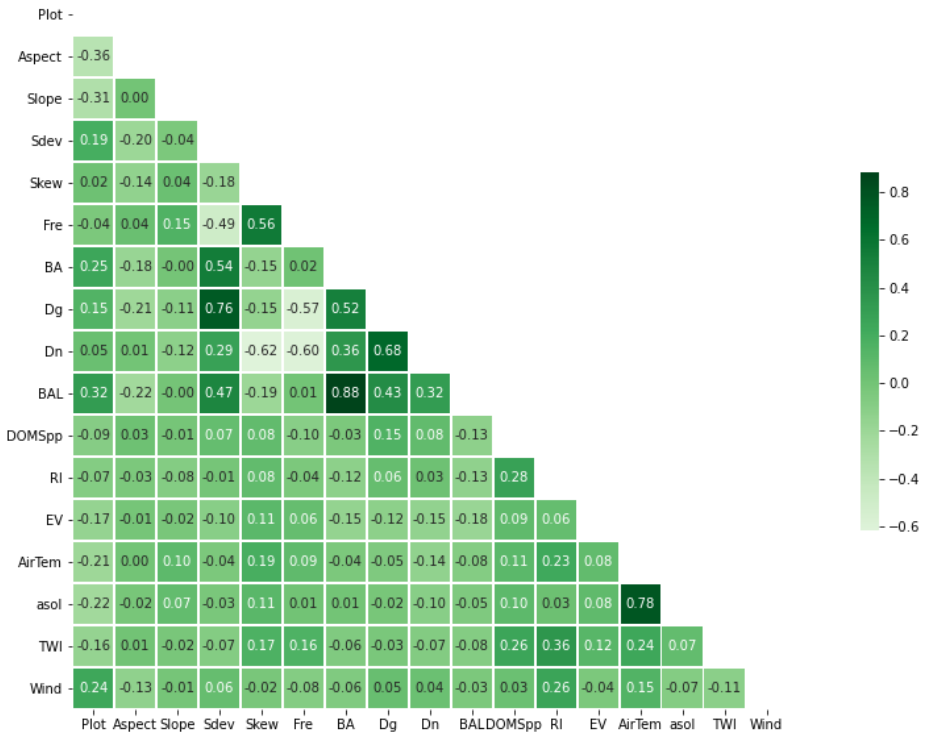
Table 2. Variance Inflation Factor (VIF) before and after removing collinear variables

متغیر variable	VIF پیش از حذف VIF before deletion	VIFپس از حذف VIF after deletion
غنای گونه‌های درختی (S)	8.4	2.1
شاخص شانون- وینر (H')	8.1	-
شاخص سیمپسون (λ)	5.8	-
سطح مقطع (BA)	7.2	4.2
سطح مقطع قطورترین درختان (BAL)	3.2	2.2
سرعت باد (Wind)	6.1	4.1
دمای هوا (AirTem)	4.1	4.1
شاخص خیسی توپوگرافیک (TWI)	8.1	4.9
انرژی خورشیدی (Asol)	3.1	3.0

ماتریس همبستگی

ماتریس همبستگی بین متغیرهای مستقل و رویش حجمی سالانه در شکل ۲ ارائه شده است. نتایج نشان داد که متغیرهای ساختاری توده شامل سطح مقطع (BA)، سطح مقطع قطورترین درختان (BAL) و تراکم درختان دارای همبستگی مثبت با رویش حجمی هستند. بیشترین ضریب همبستگی مربوط به سطح مقطع کل توده بود که بیانگر ارتباط مستقیم ظرفیت اشغال فضا و رشد حجمی است.

شاخص خیسی توپوگرافیک (TWI) همبستگی مثبت ولی ضعیفی با رویش نشان داد. متغیرهای توپوگرافی مانند شیب و جهت، اغلب همبستگی منفی با برخی متغیرهای ساختاری داشتند. سرعت باد همبستگی مثبت ملایمی با رویش نشان داد. به‌طور کلی، الگوی همبستگی‌ها نشان می‌دهد که هر دو گروه عوامل ساختاری و محیطی در تغییرات رویش نقش دارند، اگرچه شدت اثر آنها متفاوت است. جدول ۳ مشخصات آماری متغیرهای استفاده‌شده در مدل‌سازی را نشان می‌دهد.



شکل ۲- ماتریس همبستگی بین متغیرهای مستقل و وابسته؛ شدت رنگ از کمرنگ به پررنگ نشان‌دهندهٔ افزایش همبستگی است

Figure 2. Correlation matrix between independent and dependent variables; color intensity from light to dark indicates increasing correlation

جدول ۳- مشخصات آماری متغیرهای استفاده‌شده در مدل‌سازی

Table 3. Statistics of changes used in modeling

Variable متغیر	Number تعداد	Minimum حداقل	Maximum حداکثر	Mean میانگین	Std. Error اشتباه معیار	Std. Deviation انحراف معیار	Variance واریانس
Aspect	202	.00	270.00	134.1089	6.75139	95.95526	9207.411
Slope	202	.00	100.00	26.0495	1.08615	15.43716	238.306
Fre	202	20.00	1220.00	308.4158	13.26162	188.48299	35525.836
BA	202	4.40	112.80	36.0599	.98314	13.97299	195.245
DG	202	21.70	175.00	67.6168	1.49242	21.21129	449.919
Dn	202	14.20	175.00	35.8589	1.15203	16.37342	268.089
BAL	202	2.20	112.70	32.5718	1.07937	15.34077	235.339
SH	202	.00	1.56	.6807	.02536	.36050	.130
EV	185	.17	1.00	.6381	.01400	.19048	.036
AirTem	202	.00	17.30	15.4480	.08892	1.26374	1.597
Asol	202	.00	4587.52	4332.8390	26.00270	369.56788	136580.414
TWI	202	-4.47	4.53	-.1536	.09588	1.36277	1.857
Wind	202	.00	10.01	3.1853	.12974	1.84402	3.400

نتایج مدل‌سازی رگرسیون در برآورد رویش حجمی خالص سالانهٔ جنگل

برای برآورد رویش حجمی خالص سالانه در منطقهٔ پژوهش، مدل رگرسیون زیر بر اساس متغیرهای مستقل زیستی و محیطی ساخته شد(رابطه ۶):

رابطهٔ ۶ $P = 0.943 - 0.02181\ BA + 0.02787\ BA^2 + 0.03732\ WIND + 0.002\ R$

P: رویش حجمی خالص سالانه در بازهٔ ۹ ساله برحسب متر مکعب بر هکتار، BA: سطح مقطع درختان (متر مربع بر هکتار)، WIND: سرعت کلی باد در منطقهٔ نمونه و R: غنای گونه‌های درختی. کارایی این مدل رگرسیونی برای مدل رویش حجمی خالص سالانه دارای R^2 برابر با ۰/۵۷، RMSE برابر با ۰/۳۵ m^3ha^{-1} و BIAS برابر با ۰/۰۰۳۷ m^3ha^{-1}، RMSE

نسبی ۴۷/۶۲ درصد و BIAS نسبی ۰/۵۹ درصد است. این نتایج نشان می‌دهد که مدل رگرسیون ساخته‌شده توانایی پیش‌بینی دقیق رویش سالانهٔ خالص جنگل را ندارد و برآورد رویش واقعی با استفاده از این مدل به‌نسبت دشوار است. ضریب مثبت جمله درجه دوم BA بیانگر وجود رابطهٔ غیرخطی بین سطح مقطع و رویش است. در مجموع، نتایج حاکی از آن است که استفاده از مدل رگرسیونی برای پیش‌بینی رویش خالص سالانه بر اساس متغیرهای زیستی و غیرزیستی تحت بررسی، عملکرد قابل قبولی ندارد و نشان‌دهندهٔ پیچیدگی فرایندهای اکولوژیکی تأثیرگذار بر رویش حجمی جنگل‌های هیرکانی است.

در مراحل ابتدایی مدل‌سازی، هر سه شاخص تنوع (S, H', λ)به مدل وارد شدند. بر اساس نتایج، شانون-وینر و سیمپسون به‌دلیل همبستگی معنادار با غنای گونه‌های درختی ($r > 0.7$) و همچنین نبود کاهش معنادار در RMSE مدل، در فرایند انتخاب متغیر حذف شدند. بدین ترتیب، غنای گونه‌های درختی به‌عنوان تنها شاخص تنوع در مدل‌های نهایی نگه داشته شد.

نتایج مدل‌سازی شبکهٔ عصبی در برآورد رویش حجمی خالص سالانه

در فرایند مدل‌سازی، معماری‌های مختلف شبکهٔ عصبی مصنوعی شامل مدل‌های پرسپترون چندلایه (MLP)با تعداد نورون‌های لایهٔ پنهان از ۴ تا ۲۷ نورون بررسی شد. نتایج نشان دادند که شبکهٔ عصبی با ۱۲ نورون در لایهٔ پنهان بهترین عملکرد را در پیش‌بینی رویش حجمی خالص سالانه دارد. جدول ۴ ویژگی‌ها و معیارهای عملکرد دو نوع معماری شبکهٔ عصبی مصنوعی مبتنی بر پرسپترون چندلایه (MLP) و تابع پایهٔ شعاعی (RBF) را در مدل‌سازی نشان می‌دهد. مدل MLP با ساختار ۱-۱۲-۱۰، استفاده از الگوریتم بهینه‌سازی BFGS و تابع فعال‌سازی خطی (Identity)در لایه‌های پنهان، عملکرد بهتری نسبت به مدل RBF با ساختار ۱-۲۲-۱۰ و تابع فعال‌سازی گاوسی ارائه کرده است. این عملکرد برتر در مقادیر شاخص‌ها کاملاً مشهود است؛ ضریب تعیین (R^2) مدل MLPبرابر با ۰/۸۵ است که نشان‌دهندهٔ تبیین ۸۵ درصد واریانس داده‌های رویش حجمی توسط مدل است، درحالی که این مقدار برای مدل RBF تنها ۰/۶۳ است.

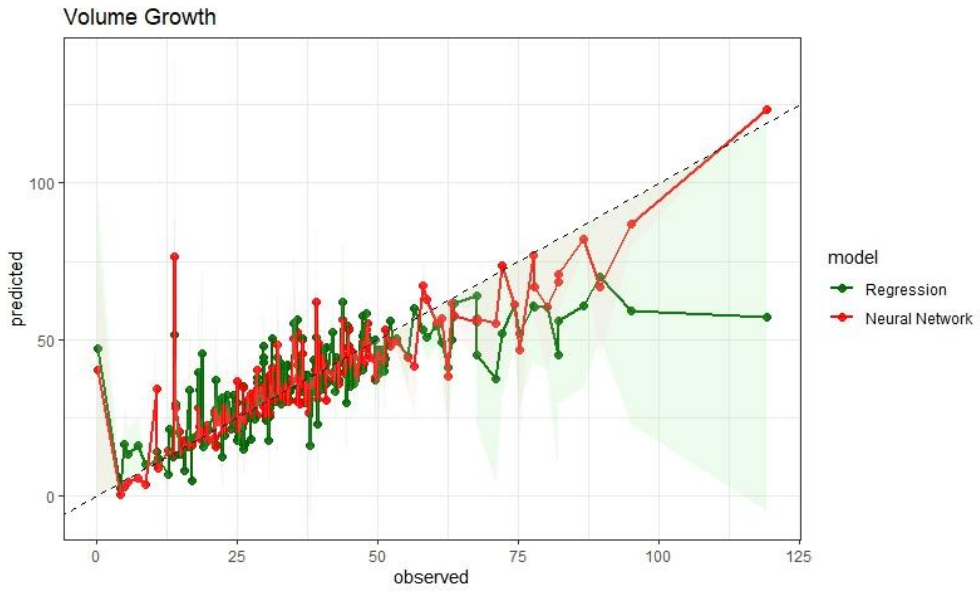
همچنین مقدار ریشهٔ میانگین مربعات خطا (RMSE) مدل MLP برابر با ۰/۱۰ (معادل ۴/۶۷ درصد از مقدار نرمال‌شده) است که به‌وضوح از RMSE مدل RBF با مقدار ۰/۳۴ (معادل ۸/۷۳ درصد) کمتر بوده و نشان‌دهندهٔ دقت پیش‌بینی بیشتر MLP است. شاخص خطا (BIAS) نیز برای مدل MLP بسیار نزدیک به صفر (۰/۰۰۱ یا ۰/۰۵ درصد) گزارش شده که حاکی از نبود سوگیری سیستماتیک در پیش‌بینی‌هاست، درحالی که مدل RBF با BIAS=0.008 (0.09٪) سوگیری به‌نسبت بیشتری دارد.

این نتایج در مجموع بیانگر برتری معماری MLP در مدل‌سازی فرایند مدل‌سازی در جنگل‌های هیرکانی است که می‌تواند الگوهای پیچیده و روابط غیرخطی داده‌ها را با دقت و صحت بیشتری بازنمایی کند. همچنین انتخاب تابع فعال‌سازی و الگوریتم بهینه‌سازی مناسب در بهبود عملکرد مدل تأثیر مهمی دارد.

جدول ۴- ویژگی‌های ANNهای مبتنی بر RBF و MLP و معیارهای مرتبط برای مدل رویش حجمی

Table 4. Characteristics of RBF and MLP-based ANNs and related criteria for the annual net volumetric growth

شاخص Index	نام شبکه Network name	الگوریتم Algorithm	تابع خطا Error function	فعال‌سازی پنهان Hidden activation	R^2	RMSE	% RMSE	BIAS	% BIAS
1	MLP 10-12-1	BFGS 16	SOS	Identity	0.85	0.10	4.67	0.001	0.05
2	RBF 10-22-1	RBFT	SOS	Gaussian	0.63	0.34	8.73	0.008	0.09



شکل ۳- رابطهٔ بین رویش حجمی خالص سالانهٔ پیش‌بینی‌شده و مشاهداتی با استفاده از مدل رگرسیون (خط سبز) و شبکهٔ عصبی مصنوعی (ANN) (خط قرمز)

Figure 3. Relationship between predicted and observed annual net volumetric growth (yield) using regression model (green line) and artificial neural network (ANN) (red line).

شکل ۳ عملکرد دو مدل پیش‌بینی، شامل مدل رگرسیون خطی و مدل شبکهٔ عصبی مصنوعی را در تخمین رویش حجمی زیست‌توده (Volume Growth) در اکوسیستم‌های جنگلی مقایسه می‌کند. محور افقی مقادیر مشاهده‌شده (رشد حجم واقعی) و محور عمودی مقادیر پیش‌بینی‌شده توسط هر مدل را نمایش می‌دهد. خط نقطه‌چین نشان‌دهندهٔ خط ایدئال است که در آن پیش‌بینی‌ها کاملاً منطبق بر مشاهدات هستند.

مدل شبکهٔ عصبی (Neural Network) با رنگ قرمز توانسته است همگامی بسیار نزدیک‌تری با داده‌های مشاهده‌شده ارائه دهد و نوسانات پیش‌بینی‌شدهٔ آن با روند واقعی رشد حجم همخوانی بیشتری دارد. این مدل به‌ویژه در بازه‌های بزرگ‌تر رشد حجم، دقت بیشتری را نشان داده و توانسته است تغییرات پیچیده و غیرخطی مرتبط با فرایندهای زیستی و محیطی مؤثر بر رشد زیست‌توده را بهتر مدل‌سازی کند. نوارهای اطمینان مدل شبکهٔ عصبی به‌نسبت باریک‌تر است که نشان‌دهندهٔ خطای کمتر و اطمینان بیشتر پیش‌بینی‌هاست.

در مقابل، مدل رگرسیون خطی (Regression) که با رنگ سبز نمایش داده شده، در بازه‌های کوچک‌تر رشد حجم پیش‌بینی‌هایی نزدیک به داده‌های واقعی ارائه می‌دهد، اما با افزایش مقدار رشد مشاهده‌شده، پیش‌بینی‌ها تمایل به ثابت ماندن یا افزایش نیافتن متناسب با مقدار واقعی دارند. همچنین نوارهای اطمینان گسترده‌تر این مدل نمایانگر افزایش عدم قطعیت و کاهش دقت در پیش‌بینی‌هاست. این ضعف در مدل رگرسیون ممکن است ناشی از محدودیت‌های ماهیتی این مدل در بازنمایی روابط پیچیده و غیرخطی باشد که به‌طور معمول در داده‌های اکولوژیکی مشاهده می‌شود.

نتایج به‌دست‌آمده تأکید می‌کند که به‌کارگیری مدل‌های پیشرفتهٔ یادگیری ماشین مانند شبکه‌های عصبی در پیش‌بینی رشد حجم زیست‌تودهٔ جنگل‌ها، ضمن افزایش دقت و کاهش خطا، قابلیت شناسایی و مدل‌سازی روابط پیچیدهٔ بین عوامل مؤثر بر رشد را دارد. این موضوع ممکن است به بهبود مدیریت پایدار منابع جنگلی و برنامه‌ریزی دقیق‌تر در حوزه‌های بهره‌برداری و حفاظت از جنگل‌ها منجر شود.

تحلیل حساسیت مدل MLP در برآورد رویش حجمی خالص سالانه

نتایج تحلیل حساسیت در جدول ۵ ارائه شده است. بر اساس تغییرات نسبی خروجی در پاسخ به تغییر ±۱۰ درصدی هر ورودی، غنای گونه‌های درختی بیشترین سهم را با ۳۰/۹ درصد داشت. سطح مقطع کل توده ۱۵/۹ درصد، سطح مقطع قطورترین درختان ۱۳/۳ درصد، سرعت باد ۱۰/۳ درصد، TWI حدود ۱۰ درصد و دمای هوا و انرژی خورشیدی هر کدام حدود ۹/۸ درصد بوده است.

جدول ۵- درصد تأثیر متغیرهای فردی و گروهی (غنای گونه، عوامل زیستی و غیرزیستی) بر رویش حجمی بر پایهٔ تحلیل حساسیت مدل MLP

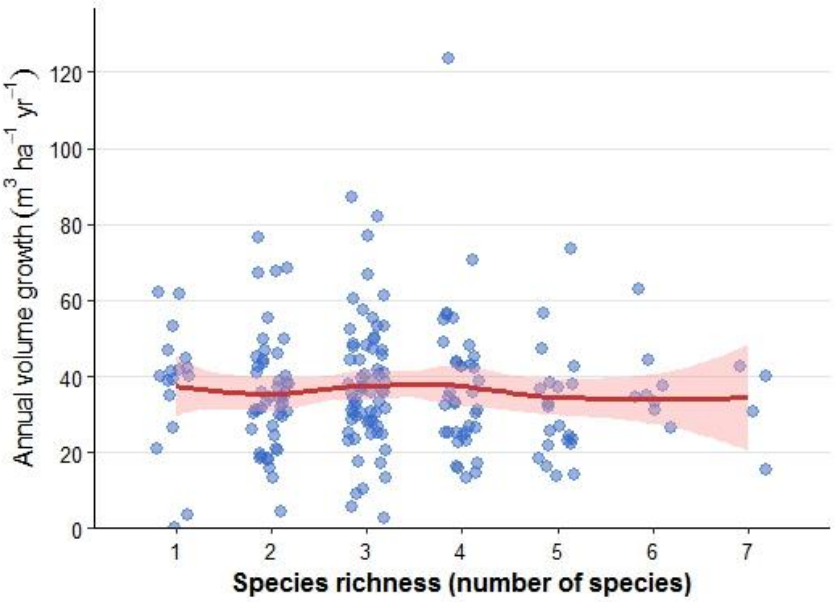
Table 5. Percentage of the effect of individual and group variables (species richness, biotic and abiotic factors) on annual net volumetric growth based on the sensitivity analysis of the MLP model

درصد تأثیر (%) Percentage of impact (%)	انرژی خورشیدی Solar energy	دمای هوا Air temperature	شاخص خیسی توپوگرافیک Topographic wetness index	سرعت باد Wind speed	سطح مقطع به هکتار Basal area (ha)	سطح مقطع قطورترین درختان در هکتار Basal area large (ha)	غنای گونه‌های درختی Species richness
میانگین Average	9.8	9.8	10	10.3	15.9	13.3	30.9

سهم بیشتر غنای گونه‌های درختی نشان می‌دهد که تغییر در ترکیب گونه‌ای ممکن است سبب تغییر زیاد در رویش توده شود. این امر احتمالاً ناشی از مکملیت عملکردی گونه‌ها و تفاوت در الگوهای بهره‌برداری از منابع است. متغیرهای ساختاری BA و BAL در مجموع بیش از ۲۹ درصد از تغییرات را توضیح دادند که بیانگر اهمیت رقابت و ساختار قطری در کنترل رشد حجمی است. سهم هر یک از عوامل محیطی نزدیک به ۱۰ درصد بود که نشان می‌دهد شرایط انرژی و رطوبتی در این منطقه به‌نسبت پایدارند و اثر تنظیم‌کننده دارند، نه تعیین‌کنندهٔ اصلی. در مجموع، نتایج تحلیل حساسیت بیانگر آن است که رویش حجمی در این جنگل‌ها حاصل تعامل ساختار توده و تنوع گونه‌های درختی است و عوامل محیطی اثر تعدیل‌کننده دارند.

رابطهٔ بین غنای گونه‌های درختی و رویش حجمی

شکل ۴ رابطهٔ بین غنای گونه‌های درختی و رویش حجمی سالانه را در قطعات نمونه نشان می‌دهد. غنای گونه‌های درختی در قطعات نمونه بین ۱ تا ۷ گونه متغیر بود. میانگین رویش حجمی در قطعات نمونه با یک گونه، ۴/۲۷ ± ۲/۱۸ متر مکعب در هکتار در سال و در قطعات با ۴ تا ۵ گونه، ۶/۱۴ ± ۸/۲۲ متر مکعب در هکتار در سال برآورد شد. منحنی برازش loess یک رابطهٔ مثبت غیرخطی را آشکار می‌سازد؛ به‌گونه‌ای که بیشترین شیب افزایش مربوط به تغییر غنای گونه‌های درختی از ۱ به ۳ گونه است و در غناهای بیشتر (۵ گونه و بیشتر) روند افزایشی به‌طور تقریبی به حالت پایدار می‌رسد. این الگو نشان می‌دهد که اثرهای مکملیت در سطوح متوسط اختلاط گونه‌ای بیشترین نمود را دارد و افزودن گونه‌های بیشتر فراتر از آستانه‌ای مشخص، سودمندی ناچیزی از نظر رویش حجمی دارد.



شکل ۴- رابطهٔ غنای گونه‌ای درختی و رویش حجمی سالانه در جنگلهای هیرکانی؛ خط قرمز منحنی برازش loess و ناحیهٔ صورتی محدودهٔ اطمینان ۹۵ درصد است

Figure 4. Relationship between tree species richness and annual volume growth in Hyrcanian forests; red line shows the loess fit and pink band the 95% confidence interval

بحث

نتایج این پژوهش نشان داد که رویش حجمی سالانه در جنگل‌های هیرکانی منطقهٔ خیرود حاصل برهم‌کنش همزمان تنوع گونه‌های درختی، ساختار توده و شرایط محیطی است. افزایش ضریب تعیین از ۰/۵۷ در مدل رگرسیون چندگانه به ۰/۸۵ در مدل شبکهٔ عصبی پرسپترون چندلایه (MLP) بیانگر آن است که روابط بین متغیرهای توضیحی و رویش حجمی، اغلب غیرخطی و همراه با اثرهای متقابل پیچیده‌اند. بررسی الگوی باقی‌مانده‌های مدل رگرسیونی نیز نشان داد که در مقادیر بزرگ‌تر سطح مقطع و غنای گونه‌های درختی، انحراف سیستماتیک از خط برازش وجود دارد که حاکی از ناتوانی مدل خطی در بازنمایی کامل روابط پیچیدهٔ رشد است. این یافته با نتایج پژوهش‌های مدل‌سازی اکولوژیکی که بر ماهیت غیرخطی فرآیندهای رشد جنگل تأکید دارند همخوانی دارد (Bayat et al., 2019; Vieira et al., 2018).

نقش تنوع گونه‌های درختی در رویش حجمی

تحلیل حساسیت مدل MLP نشان داد که غنای گونه‌های درختی با سهم ۳۰/۹ درصد، مهم‌ترین متغیر تبیین‌کنندهٔ تغییرات رویش حجمی بوده است. رابطهٔ غیرخطی بین غنای گونه‌های درختی و رویش حجمی (شکل ۴) حمایت تجربی از فرضیهٔ مکملیت نیچ در جنگل‌های هیرکانی فراهم می‌آورد. افزایش شدید اولیه در رویش با افزودن نخستین گونه‌ها، احتمالاً ناشی از ترکیب گونه‌های با نقش‌های عملکردی متمایز است. در قطعات نمونه با غنای بیشتر، ترکیب گونه‌ای غالب به‌طور معمول شامل راش (*Fagus orientalis* Lipsky) به‌عنوان گونه‌ای سایه‌پسند با تاج‌پوش متراکم در لایهٔ فوقانی، ممرز (*Carpinus betulus* L.) با رشد سریع‌تر در میان‌تاج، توسکا (*Alnus subcordata* C.A.Mey.) به‌عنوان گونهٔ تثبیت‌کنندهٔ نیتروژن و افرا (*Acer velutinum* Boiss.) به‌عنوان گونهٔ نورپسند در فضاهای بازتر است. این‌گونه ناهمگنی عمودی و افقی از راه کاهش همپوشانی رقابتی و افزایش کارایی بهره‌برداری از

منابع نور و خاک، سبب افزایش رویش حجمی می‌شود.

این تفسیر با نظریهٔ مکملیت گونه‌ای و اثر انتخابی سازگار است؛ این نظریه بیان می‌کند که گونه‌های با صفات کارکردی متفاوت می‌توانند بهره‌وری کل توده را افزایش دهند (Cardinale et al., 2012; Morin et al., 2014). نتایج حاضر با یافته‌های Van de Perre et al. (2016) نیز همخوانی دارد که نشان داد کاهش تنوع گونه‌های درختی در مقیاس جهانی سبب افت معنی‌دار بهره‌وری جنگل‌ها می‌شود. حالت پایدار مشاهده‌شده در غنای زیاد (۵ گونه و بیشتر) ممکن است نشان‌دهندهٔ غالب شدن افزونگی عملکردی (Functional Redundancy) به‌جای مکملیت باشد یا اینکه فیلترهای محیطی در این جنگل‌های معتدل، امکان بروز کامل اثرهای تنوع را محدود می‌کنند. شدت اثر تنوع در این پژوهش در مقایسه با برخی پژوهش‌های جهانی متوسط ارزیابی شد که احتمالاً ناشی از شرایط اقلیمی به‌نسبت مرطوب و پایدار منطقه و نیز غالب بودن ساختارهای تکاشکوبه در برخی قطعات است. Paquette & Messier (2011) نیز نشان دادند که اثر تنوع گونه‌های درختی بر بهره‌وری در طول گرادیان‌های اقلیمی تغییر می‌کند و تحت تأثیر شدت رقابت و محدودیت‌های محیطی قرار می‌گیرد.

تأثیر ساختار توده

پس از تنوع گونه‌های درختی، متغیرهای ساختاری به‌ویژه سطح مقطع کل (BA) و سطح مقطع قطورترین درختان (BAL) بیشترین سهم را در مدل داشتند (در مجموع حدود ۲۹ درصد). وجود جمله درجه دوم BA در مدل رگرسیونی نشان‌دهندهٔ رابطهٔ غیرخطی بین تراکم توده و رویش حجمی است. بر اساس ضرایب مدل، در سطوح پایین BA (کمتر از ۲۵ متر مربع در هکتار)، افزایش سطح مقطع تا آستانهٔ ۴۵ متر مربع در هکتار با افزایش رویش همراه بوده است (از ۲۷/۴ به ۴۱/۱ متر مکعب در هکتار در سال) که احتمالاً ناشی از استفادهٔ مؤثرتر از فضا و منابع است؛ اما در سطوح بالاتر BA (بیش از ۵۰ مترمربع در هکتار)، رقابت نوری و زیرزمینی تشدید شده و رشد محدود می‌شود (کاهش به ۳۳/۵ متر مکعب در هکتار در سال). این الگو با نظریهٔ تراکم- رشد و مفهوم حداکثر بهره‌وری در تراکم‌های میانی سازگار است.

همچنین سهم BAL (۱۳/۳ درصد) بیانگر تأثیر درختان قطور به‌عنوان اجزای غالب توده در تعیین ظرفیت تولید است. حضور درختان قطور می‌تواند هم از راه افزایش سهم تاج‌پوش و فتوسنتز کل و هم از راه ایجاد ناهمگنی ساختاری بر رشد توده اثرگذار باشد. پژوهش‌های اخیر نشان داده‌اند که تنوع ساختاری می‌تواند پیش‌بینی‌کنندهٔ مهمی برای زی‌توده و بهره‌وری جنگل باشد و تحت تأثیر سن، تراکم و تاریخچهٔ پویایی توده قرار گیرد (Madrigal-González et al., 2023; LaRue et al., 2023). نتایج این پژوهش نیز مؤید آن است که ساختار توده نقش میانجی در تنظیم اثر تنوع گونه‌های درختی بر رویش دارد.

تأثیر عوامل محیطی

متغیرهای محیطی شامل سرعت باد (۱۰/۳ درصد)، شاخص خیسی توپوگرافیک (۱۰ درصد)، دمای هوا (۹/۸ درصد) و انرژی خورشیدی (۹/۸ درصد) هر یک سهمی نزدیک به ۱۰ درصد در تغییرات رویش داشتند. سهم به‌نسبت متعادل این متغیرها نشان می‌دهد که در منطقهٔ پژوهش، محدودیت شدید اقلیمی وجود نداشته است و این عوامل بیشتر تأثیر تعدیل‌کننده داشته‌اند. شاخص TWIبه‌عنوان نمایه‌ای از توزیع رطوبت خاک می‌تواند از راه افزایش دسترسی به آب، کارایی فتوسنتزی و رشد شعاعی را افزایش دهد. سرعت باد نیز افزون‌بر تأثیر بر تبادل گازی و تهویهٔ تاج‌پوش، می‌تواند بر تخصیص زی‌توده و شکل تاج اثرگذار باشد (Bourque & Bayat, 2015). انرژی خورشیدی و دما نیز با

تنظیم نرخ فتوسنتز و تنفس، اثر اساسی در تعیین پتانسیل رشد دارند که با یافته‌های پژوهش‌های پیشین در جنگل‌های طبیعی همخوانی دارد (Bayat et al., 2022; Kwon et al., 2019).

مقایسهٔ روش‌های مدل‌سازی

برتری مدل MLP بر رگرسیون چندگانه تنها ناشی از ماهیت غیرخطی آن نیست، بلکه بیانگر وجود اثرهای متقابل بین متغیرهاست که در مدل خطی قابل بازنمایی کامل نبوده‌اند. برای نمونه، مدل MLP نشان داد که اثر غنای گونه‌های درختی بر رویش در قطعات با سطح مقطع ۴۰-۲۵ متر مربع در هکتار (حدود ۴۱/۸ متر مکعب در هکتار در سال) به‌طور معنی‌داری بیشتر از قطعات با سطح مقطع کمتر از ۲۰ (حدود ۲۶/۴ متر مکعب) یا بیشتر از ۵۰ متر مربع (حدود ۳۳/۵ متر مکعب) بوده است. این الگو که حاکی از بیشینه شدن اثر مکملیت در تراکم‌های میانی است، در مدل رگرسیون خطی به‌دلیل فرض‌های ساده‌کننده نادیده گرفته شد. کاهش RMSE از ۰/۳۵ در مدل رگرسیونی به ۰/۱۰ در مدل MLP و نزدیک بودن BIAS به صفر در شبکهٔ عصبی نشان می‌دهد که این مدل توانسته است الگوهای پیچیده‌تری را استخراج کند.

یافته‌های Hamidi & Fallah (2025) در جنگل‌های هیرکانی نیز نشان داد که مدل‌های غیرخطی مبتنی بر یادگیری ماشین نسبت به مدل‌های خطی سنتی، دقت بیشتری در پیش‌بینی رشد قطری دارند که با نتایج این پژوهش همسو است. با این‌حال باید توجه داشت که شبکه‌های عصبی از نظر تفسیرپذیری محدودترند و نتایج آنها وابسته به تنظیم پارامترها و ساختار شبکه است (Vieira et al., 2018). بنابراین استفادهٔ همزمان از مدل‌های پارامتریک برای تفسیر مستقیم ضرایب و مدل‌های یادگیری ماشین برای افزایش دقت پیش‌بینی می‌تواند چارچوب تحلیلی کامل‌تری در پژوهش‌های اکولوژیکی فراهم آورد. در مجموع، نتایج این پژوهش نشان داد که افزایش تنوع گونه‌های درختی در کنار حفظ ساختار بهینهٔ توده می‌تواند موجب ارتقای بهره‌وری حجمی در جنگل‌های هیرکانی شود. این یافته‌ها بر ضرورت مدیریت مبتنی بر حفظ ترکیب گونه‌ای متنوع، جلوگیری از یکنواخت‌سازی ساختار و توجه به شرایط رطوبتی و انرژی سایت تأکید دارد.

محدودیت‌ها

یکی از محدودیت‌های این پژوهش، استفاده از مقادیر میانگین بلندمدت (دورهٔ ۹ ساله) برای متغیرهای محیطی مانند دما، تابش خورشیدی و سرعت باد است. این رویکرد در بسیاری از پژوهش‌های مشابه به کار رفته است(Bayat et al., 2022; Ratcliffe et al., 2017) ، اما تغییرات بین‌سالی و رخدادهای حدی اقلیمی را منعکس نمی‌کند. پژوهش‌های اخیر نشان داده‌اند که واکنش رویش درختان به تنوع گونه‌های درختی و ساختار توده ممکن است در سال‌های خشک و مرطوب متفاوت باشد (Ouyang et al., 2019; Jactel et al., 2018).همچنین، حذف ۶ قطعه نمونه (حدود ۲/۳ درصد) به‌عنوان دادهٔ پرت بر اساس فاصلهٔ کوک، هرچند موجب بهبود برازش مدل شد، ممکن است بخشی از تغییرات طبیعی رویش را نیز حذف کرده باشد. بررسی این قطعات نشان داد که آنها اغلب مربوط به قطعات با رویش غیرعادی زیاد (بیش از ۱۲۰ متر مکعب در هکتار در سال) یا سطح مقطع بسیار زیاد بوده‌اند که شاید ناشی از خطای اندازه‌گیری، شرایط خرداقلیمی منحصربه‌فرد یا پویایی‌های محلی توده باشند. از این‌رو پیشنهاد می‌شود که در پژوهش‌های آینده از داده‌های سری زمانی با تفکیک زمانی سالانه یا فصلی استفاده شود و مدل‌های ترکیبی Mixed-effects) (Models یا مدل‌های پویای حالت- فضا برای بازنمایی دقیق‌تر تغییرات درون‌دوره‌ای و در نظر گرفتن اثرهای تصادفی به کار گرفته شوند (Bayat et al., 2022; Hamidi et al., 2023).

نتیجه‌گیری

این پژوهش نشان داد که رویش حجمی سالانهٔ جنگل‌های هیرکانی تحت تأثیر همزمان تنوع گونه‌های درختی، ویژگی‌های ساختاری توده و عوامل محیطی قرار دارد. در میان متغیرهای بررسی‌شده، غنای گونه‌های درختی بیشترین سهم انفرادی را در تغییرات رویش داشت، درحالی که متغیرهای ساختاری و محیطی نیز اثر مکمل و تعدیل‌کننده داشتند. مقایسهٔ روش‌های مدل‌سازی نشان داد که شبکهٔ عصبی پرسپترون چندلایه با تبیین ۸۵ درصد از تغییرات رویش، عملکرد بهتری از رگرسیون چندگانه داشت که بیانگر ماهیت غیرخطی روابط اکولوژیکی در این اکوسیستم است.

یافته‌های این پژوهش بر اهمیت به‌کارگیری رویکردهای ترکیبی آماری و یادگیری ماشین در تحلیل داده‌های جنگلی تأکید می‌کند و می‌تواند مبنایی برای توسعهٔ مدل‌های دقیق‌تر پیش‌بینی رشد در جنگل‌های هیرکانی فراهم آورد.

سپاسگزاری

نگارندگان لازم می‌دانند از بنیاد ملی علم ایران بابت حمایت از تدوین این مقاله که حاصل طرح مصوب این بنیاد با کد طرح تحقیقاتی ۴۰۴۳۱۵۴ است سپاسگزاری کنند.

References

Baruffol, M., Schmid, B., Bruelheide, H., Chi, X., Hector, A., Ma, K., Michalski, S., Tang, Z., & Niklaus, P.A. (2013). Biodiversity promotes tree growth during succession in subtropical forest. *Plos One*, *8*(12), e81246. doi: 10.1371/annotation/48869dee-d4a9-4ff5-a401-ce73440e7ecf

Bayat, M., Bettinger, P., Heidari, S., Henareh Khalyani, A., Jourgholami, M., & Hamidi, S.K. (2020). Estimation of tree heights in an uneven-aged, mixed forest in northern Iran using artificial intelligence and empirical models. *Forests*, *11*(3), Article 324. https://doi.org/10.3390/f11030324

Bayat, M., Bettinger, P., Heidari, S., Hamidi, S.K., & Jaafari, A. (2021). A combination of biotic and abiotic factors and diversity determine productivity in natural deciduous forests. *Forests*, *12*(11), 1450. https://doi.org/10.3390/f12111450

Bayat, M., Knoke, T., Heidari, S., Hamidi, S.K., Burkhart, H., & Jaafari, A. (2022). Modeling tree growth responses to climate change: a case study in natural deciduous mountain forests. *Forests*, *13*(11), 1816. https://doi.org/10.3390/f13111816

Bayat, M., Noi, P.T., Zare, R., & Bui, D.T. (2019). 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), Article 1680. https://doi.org/10.3390/rs11141680

Bayat, M., Pukkala, T., Namiranian, M., & Zobeiri, M. (2013). Productivity and optimal management of the uneven-aged hardwood forests of Hyrcania. *European Journal of Forest Research*, *132*(5-6), 851-864.

Bayat, M., Bettinger, P., Masteali, S.H., Hamidi, S.K., Masood Awan, H.U., & Abolhasani, A. (2023). Recreation potential assessment at *Tamarix* forest reserves: A method based on multicriteria evaluation approach and landscape metrics. *Forests*, *14*(4), 705. https://doi.org/10.3390/f14040705

Bayat, M., & Hamidi, S.K. (2019). Investigation some of the biotic and abiotic variables effective on the diameter increment of the beech trees at fixed sample plots level by growth models. *Ecology of Iranian Forest*, *7*(13), 91-99. (In Persian)

Bettinger, P., Merry, K., Bayat, M., & Tomaštík, J. (2019). GNSS use in forestry–A multi-national survey from Iran, Slovakia and southern USA. *Computers and Electronics in Agriculture*, *158*, 369-383. https://doi.org/10.1016/j.compag.2019.02.015

Baach, E., Himes, A., Polinko, A., Granger, J.J., & Zhou, Q. (2022). Diversity-productivity relationships in forests of the southeastern United States: Leveraging national inventory data and tree functional traits. *Forest Ecology and Management, 521*, 120426.

Bourque, C.P.A., & Bayat, M. (2015). Landscape variation in tree species richness in northern Iran forests. *Plos One*, *10*(4), e0121172. https://doi.org/10.1371/journal.pone.0121172

Bourque, C.P.A., Bayat, M., & Zhang, C. (2019). An assessment of height–diameter growth variation in an unmanaged *Fagus orientalis* dominated forest. *European Journal of Forest Research*, *138*(4), 607-621.

Briggs, D., Brough, D., & Thomas, H. (1989). Allometric relationships for estimating tree volume and biomass. *Forestry Journal*, *65*(2), 123-135.

Cardinale, B.J., Duffy, J.E., Gonzalez, A., Hooper, D.U., Perrings, C., Venail, P., & Naeem, S. (2012). Biodiversity loss and its impact on humanity. *Nature*, *486*(7401), 59-67.

Fallah, A., Nadi, M., Imani, M., & Hamidi, S.K. (2023). Reconstruction of precipitation using the chronology of juniper trees (*Juniperus polycarpos*) in North Khorasan Province, Iran. *Iranian Journal of Forest and Poplar Research*, *31*(1), 1-13. (In Persian)

Forrester, D.I., & Bauhus, J. (2016). A review of processes behind diversity–productivity relationships in forests. *Current Forestry Reports*, *2*, 45-61.

Hamidi, S.K., de Luis, M., Bourque, C.P.A., Bayat, M., & Serrano-Notivoli, R. (2023). Projected biodiversity in the Hyrcanian Mountain Forest of Iran: An investigation based on two climate scenarios. *Biodiversity and Conservation, 32*(12), 3791-3808.

Hamidi, S.K., & Fallah, A. (2025). Evaluation of tree basal area increment models using machine learning algorithms. *Iranian Journal of Forest*, *16*(5), 71-86. (In Persian)

Hamidi, S.K., Fallah, A., Bayat, M., & De Luis, M. (2020). The effects of climate variables (temperature and precipitation) on growth characteristics of trees (case study: Farim forest). *Forest Research and Development*, *6*(4), 593-607. (In Persian)

Hamidi, S.K., Fallah, A., Bayat, M., & Hosseini, Y.S.A. (2021). Investigating the Diameter and Height Models of Beech Trees in Uneven Age Forest of Northern Iran (Case study: Forest Farim). *Ecology Iranian Forest, 9*(17), 30-40. doi:10.52547/ifej.9.17.30. (In Persian)

Jactel, H., Gritti, E.S., Drössler, L., Forrester, D.I., Mason, W.L., Morin, X., Pretzsch, H., & Castagneyrol, B. (2018). Positive biodiversity–productivity relationships in forests: climate matters. *Biology Letters*, *14*(4), 20170747. https://doi.org/10.1098/rsbl.2017.0747

Keylock, C.J. (2005). Simpson diversity and the Shannon-Wiener index as special cases of a generalized entropy. *Oikos*, *109*(1), 203-207. https://doi.org/10.1111/j.0030-1299.2005.13735.x

Krebs, C.J. (1999). Ecological methodology (2nd ed.). San Francisco: Benjamin-Cummins Publishing Co.

Kweon, D., & Comeau, P.G. (2019). Relationships between tree survival, stand structure and age in trembling aspen dominated stands. *Forest Ecology and Management*, *438*, 114-122. https://doi.org/10.1016/j.foreco.2019.02.003

Kwon, Y., Lee, T., Lang, A., & Burnette, D. (2019). Assessment on latitudinal tree species richness using environmental factors in the southeastern United States. *PeerJ, 7*, e6781. https://doi.org/10.7717/peerj.6781

LaRue, E.A., Knott, J.A., Domke, G.M., Chen, H.Y., Guo, Q., Hisano, M., ... & Fei, S. (2023). Structural diversity as a reliable and novel predictor for ecosystem productivity. *Frontiers in Ecology and the Environment, 21*(1), 33-39.

Van de Perre, F., Verheyen, E., De Bruyn, L., Verbeeck, H., Presley, S.J., & Willig, M.R. (2016). Generality of biodiversity-productivity relationships in global forests. *Opgedragen aan Dedicated to Dédié à, 93.*

Madrigal-González, J., Calatayud, J., Ballesteros-Cánovas, J.A., Escudero, A., Cayuela, L., Marqués, L., & Stoffel, M. (2023). Global patterns of tree density are contingent upon local determinants in the world's natural forests. *Communications biology, 6*(1), 47.

Magurran, A.E. (1988). Ecological Diversity and Its Measurement. Princeton: Princeton University Press.

Masteali, S.H., Bayat, M., & Ghorbanpour, M. (2025a). Effects of forest structure from graph theory connectivity indicators on river water quality in the Caspian Sea Basin. *Scientific Reports*, *15*(1), 7344.

Morin, X., Fahse, L., de Mazancourt, C., Scherer-Lorenzen, M., & Bugmann, H. (2014). Temporal stability in forest productivity increases with tree diversity due to asynchrony in species dynamics. *Ecology Letters*, *17*(12), 1526-1535. https://doi.org/10.1111/ele.12357

Nazariani, N., Fallah, A., Hamidi, S.K., & Varamesh, S. (2022). Estimation of quantitative characteristics of Zagros forests using data mining nonparametric algorithms (case study: Olad Ghobad Watershed, Koohdasht, Lorestan). *Forest Research and Development*, *8*(3), 249-263. (In Persian)

Ouyang, S., Xiang, W., Wang, X., Xiao, W., Chen, L., Li, S., Sun, H., Deng, X., Forrester, D.I., Zeng, L., Lei, P., Lei, X., Gou, M., & Peng, C. (2019). Effects of stand age, richness and density on productivity in subtropical forests in China. *Journal of Ecology*, *107*(5), 2266-2277. https://doi.org/10.1111/1365-2745.13194

Paquette, A., & Messier, C. (2011). The effect of biodiversity on tree productivity: from temperate to boreal forests. *Global Ecology and Biogeography*, *20*(1), 170-180. https://doi.org/10.1111/j.1466-8238.2010.00592.x

Poorter, L., van der Sande, M.T., Thompson, J., Arets, E.J.M.M., Alarcón, A., Álvarez-Sánchez, J., & 58 others. (2015). Diversity enhances carbon storage in tropical forests. *Global Ecology and Biogeography*, *24*(11), 1314-1328. https://doi.org/10.1111/geb.12364

Ratcliffe, S., Wirth, C., Jucker, T., van der Plas, F., Scherer-Lorenzen, M., Verheyen, K., Allan, E., Benavides, R., Bruelheide, H., Ohse, B., & Paquette, A. (2017). Biodiversity and ecosystem functioning relations in European forests depend on environmental context. *Ecology Letters*, *20*(11), 1414-1426. https://doi.org/10.1111/ele.12849

Rita, A., & Borghetti, M. (2019). Linkage of forest productivity to tree diversity under two different bioclimatic regimes in Italy. *Science of the Total Environment*, *687*, 1065-1072. https://doi.org/10.1016/j.scitotenv.2019.06.194

Shannon, C.E. (1948). A Mathematical Theory of Communication. *Bell System Technical Journal, 27*, 379-423, 623-656.

Simpson, E.H. (1949). Measurement of diversity. *Nature, 163*, 688.

Vahedi, A.A., Fallah, A., Akhavan, R., Nazariani, N., Khatibnia, E., & Hamidi, S.K. (2024). Spatial Analyses for Fine Woody Debris Volume Stock in the Hyrcanian Research Forest of Kheyrood-Kenar. *Ecology of Iranian Forest, 12*(1), 73-87. (In Persian)

Vieira, C.M., Ferreira, D., & Araújo, F.S. (2018). Artificial neural networks applied in forest ecosystem studies: a review. *Ecological Informatics, 46*, 37-45.

Iranian Journal of Forest
Vol. 18, No. 2, Summer 2026
pp. 305-322
Research Article

DOI: 10.22034/ijf.2026.543471.2066
CC BY 4.0

Investigating the effects of tree species diversity, stand structural attributes, and environmental factors on annual volume increment in Hyrcanian forests using artificial neural networks and regression models

M. Bayat[1], S. Heidari[2], and S.K. Hamidi[3*]

[1]Associate Prof., Research Institute of Forests and Rangelands, Agricultural Research, Education and Extension Organization (AREEO), Tehran, I. R. Iran
[2]Ph.D. graduated, Deptof Environment, Faculty of Natural Resources, University of Tehran, I. R. Iran
[3]Assistant Prof., Dept. of Forestry, Faculty of Natural Resources, Sari Agricultural Sciences and Natural Resource University, Sari, I. R. Iran

(Received: 17 September 2025; Accepted: 18 May 2026)

Abstract

Introduction: Biodiversity plays a fundamental role in maintaining forest ecosystem stability and functioning and can enhance forest productivity through mechanisms such as species complementarity and reduced intraspecific competition. Despite extensive research on biodiversity–productivity relationships, the simultaneous effects of tree species diversity, stand structure, and environmental factors on volumetric growth in the Hyrcanian forests have received limited attention. Therefore, this study aimed to model annual volumetric growth in the Hyrcanian forests and assess the importance of biotic, structural, and environmental variables using parametric and non-parametric approaches.

Materials and Methods: Data were collected from 258 permanent sample plots over a nine-year period. Annual volumetric growth ($m^3\ ha^{-1}\ yr^{-1}$) was considered as the dependent variable. Explanatory variables included tree species diversity indices, stand basal area ($m^2\ ha^{-1}$), basal area of the largest trees within each sample plot ($m^2\ ha^{-1}$), wind speed, air temperature, solar radiation, and topographic wetness index (TWI) were included as explanatory variables. Multiple linear regression, multilayer perceptron (MLP), and radial basis function (RBF) neural networks were developed, and model performance was evaluated using R^2, RMSE, and BIAS.

Results: The results showed that the MLP model outperformed multiple regression ($R^2 = 0.57$) and the RBF neural network in predicting annual volumetric growth, achieving a coefficient of determination of 0.85 ($R^2 = 0.85$)Sensitivity analysis of the MLP model revealed that tree species richness had the highest individual contribution (30.9%) to volumetric growth prediction, Stand structural variables collectively accounted for approximately 29%, while environmental factors each contributed around 10% to the explained variation.

Conclusion: The findings suggest that annual volumetric growth in the Hyrcanian forests Is associated with complex and nonlinear interactions among biodiversity, stand structure, and environmental conditions. Artificial neural networks provide an effective framework for capturing such ecological complexity. These results highlight the importance of conserving tree species diversity as a key component of strategies to maintain long-term forest productivity and sustainability in the Hyrcanian forests.

Keywords: Annual volumetric growth, Artificial neural network, Hyrcanian temperate forests, Sensitivity analysis, Stand structure, Tree species diversity.

* Corresponding Author Phone: 09113569068 Email: k.hamidi86@yahoo.com