



## برآورد مشخصه تراکم درختان جنگل با استفاده از آنالیز زمین و شبکه عصبی مصنوعی

\* فریبا قنبری<sup>۱</sup>، شعبان شتابی<sup>۲</sup>، امیراحمد دهقانی<sup>۳</sup> و شمس‌ا... ایوبی<sup>۴</sup>

<sup>۱</sup> دانشجوی کارشناسی‌ارشد گروه جنگلداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، دانشیار گروه جنگلداری،

<sup>۲</sup> دانشگاه علوم کشاورزی و منابع طبیعی گرگان، <sup>۳</sup> استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی

<sup>۴</sup> گرگان، استادیار گروه خاکشناسی، دانشگاه صنعتی اصفهان

تاریخ دریافت: ۸۷/۶/۱۷؛ تاریخ پذیرش: ۸۸/۱/۲۶

### چکیده

اثر متقابل بین منظر زمین و خصوصیات جنگل کاملاً ثابت شده است. بنابراین فرض قابل قبولی است که فاکتورهای منظر زمین در یک منطقه جنگلی در ایجاد خصوصیات جنگل نقش تعیین‌کننده‌ای دارند. اگرچه پژوهش‌های گذشته روابط کاملاً قطعی بین خصوصیات جنگل و عوامل محیطی را شناسایی کرده‌اند، اما تاکنون مدل مناسبی برای شرح این خصوصیات ارائه نشده است. استفاده از مدل‌های رقومی زمین و مشخصه‌های قابل استخراج از آن می‌تواند برای رسیدن به این هدف به ما کمک کند. این پژوهش سعی در بررسی امکان به‌کارگیری روش نوین شبکه عصبی مصنوعی (ANN) برای پیش‌بینی پراکنش مکانی تراکم (تعداد در هکتار) جنگل و تهیه نقشه پیوسته آن در سری یک جنگل آموزشی و پژوهشی شصت‌کلاته گرگان با استفاده از خصوصیات اولیه و ثانویه توپوگرافی دارد. خصوصیات اولیه و ثانویه توپوگرافی با استفاده از مدل رقومی زمین با دقت ارتفاعی ۱۰ متر محاسبه گردید. نقشه موقعیت جغرافیایی قطعات نمونه که با استفاده از دستگاه GPS ثبت شده بود، در محیط GIS تهیه شد. سپس مشخصه‌های اولیه و ثانویه توپوگرافی زمین در محل این قطعات نمونه استخراج گردید. مشخصه تعداد در هکتار نیز در ۲۵۲ قطعه نمونه دایره‌ای با ابعاد ۱۰ آر از طریق شمارش تعداد درختان موجود در هر قطعه نمونه و محاسبه آن در هکتار، تعیین گردید. رابطه

\* مسئول مکاتبه: fariba\_ghanbari@yahoo.com

بین تعداد در هکتار جنگل و خصوصیات توپوگرافی با استفاده از دو شبکه عصبی مصنوعی RBF و MLP مورد تجزیه و تحلیل قرار گرفت. نتایج نشان داد که شبکه تابع پایه شعاعی RBF نسبت به شبکه MLP دارای نتایج دقیق‌تری است. علاوه بر آن، آنالیز رگرسیون خطی برای مقایسه نتایج آن با مدل‌های ANN انجام گردید. نتایج نشان‌دهنده توانایی شبکه عصبی در پیش‌بینی تعداد در هکتار بود و نیز نشان داد که این تکنیک می‌تواند ۶۵ درصد تغییرات تعداد در هکتار جنگل را با استفاده از خصوصیات توپوگرافی پیش‌بینی نماید.

**واژه‌های کلیدی:** خصوصیات توپوگرافی، تعداد در هکتار جنگل، مدل رقومی زمین، شبکه عصبی مصنوعی

#### مقدمه

پیش‌بینی مکانی و تهیه نقشه پیوسته خصوصیات کمی جنگل، به‌منظور ارزیابی و برنامه‌ریزی عملکرد آینده منابع جنگلی برای مدیران جنگل اهمیت زیادی دارد. نظارت بر پوشش زمین در مناطق وسیع نیازمند حجم زیادی از داده‌ها می‌باشد از طرفی اندازه‌گیری صحرایی فرآیندهای فیزیکی و بیولوژیکی به‌طور پیوسته مشکل می‌باشد. یکی از رایج‌ترین متدهای مورد استفاده، مدل‌سازی پیش‌بینی گیاهی است که می‌تواند به‌عنوان پیش‌بینی‌کننده پراکنش مکانی گیاهان در سطح منظر زمین و براساس رابطه بین پراکنش مکانی گیاهان و متغیرهای محیطی تعریف گردد (جوسان و تئوریلات، ۲۰۰۰). یکی از مهم‌ترین مشخصه‌های پیش‌نیاز تشکیل پوشش گیاهی و گسترش آن شکل ظاهری پستی و بلندی است که به‌طور موازی با اقلیم، زمین‌شناسی، خاک و دیرینه‌شناسی عمل می‌کند (فلورنسکی و کوریاکوا، ۱۹۶۶). از این میان سه متغیر شیب، جهت و ارتفاع مهم‌ترین متغیرهای توپوگرافی هستند که به‌طور رایج در اندازه‌گیری‌ها و تهیه نقشه‌های گیاهی مورد استفاده قرار می‌گیرند (لیپریور و همکاران، ۱۹۸۸) و در بسیاری از موارد تعیین‌کننده میکروکلیمما هستند (جیجر، ۱۹۶۶). این عوامل به‌طور مستقیم با جریان‌های هیدرولوژیکی، تابش خورشیدی، توسعه خاک، قابلیت تولید و گیاهان ارتباط دارند و می‌توانند برای پیش‌بینی پوشش گیاهی مورد استفاده قرار گیرند (آلبانی و همکاران، ۲۰۰۴).

مشخصه‌های مشتق شده از مدل رقومی زمین<sup>۱</sup> در بسیاری از مطالعات مربوط به طبقه‌بندی خصوصیات و برای پیش‌بینی خاک، پوشش گیاهی و پراکنش گونه‌ها در مقیاس‌های متفاوت مورد استفاده قرار گرفته‌اند (ویلسون و همکاران، ۲۰۰۷؛ کانتون و همکاران، ۲۰۰۴). فرانکلین و همکاران (۲۰۰۰) نشان دادند که پراکنش گونه‌های گیاهی در تیپ‌های نیمه‌مدیترانه‌ای جنوب کالیفرنیا وابسته به توازن رطوبت خاک است و این مشخصه متعاقباً به‌وسیله شاخص‌های توپوگرافی مشتق شده از DTM، نظیر شیب، جهت، انحنای زمین، ارتفاع و سایر خصوصیات پیچیده توپوگرافیکی مانند تابش خورشید و رطوبت خاک کنترل می‌گردد، در این پژوهش رابطه بین خصوصیات اکولوژیکی و خصوصیات زمین به‌وسیله مدل‌های خطی تعمیم یافته<sup>۲</sup> بررسی گردید. هورش (۲۰۰۳) نیز توانایی ۲۴ خصوصیت اولیه و ثانویه مشتق شده از DTM را برای بیان پراکنش مکانی جنگل‌های کوهستانی و نیمه‌آلپی در آلپ مرکزی مورد استفاده قرار داد. نتایج نشان داد ارتفاع، جهت شیب و تا حدودی رطوبت، مهم‌ترین پارامترها برای بیان خصوصیات جنگل می‌باشند. میتسودا و همکاران (۲۰۰۷) با استفاده از ۱۴ شاخص طبقه‌بندی شده تابش خورشید، شاخص رطوبت و شاخص پرتوگیری توپوگرافی<sup>۳</sup>، شاخص رویشگاه را برای توده‌های خالص کاج ژاپنی با روش رگرسیون چند متغیره خطی مدل‌سازی نمودند. بهترین مدل در این پژوهش برای DTM با تفکیک مکانی ۱۲/۵ متر و با  $R^2 = 0/692$  بود. در این پژوهش تابش خورشید مهم‌ترین عامل محدودکننده شناخته شد و رطوبت خاک نیز در حاصل‌خیزی رویشگاه موثر بود. امروزه به موازات مدل‌های رایج قبلی، روش‌های جدیدتری با عنوان شبکه‌های عصبی مصنوعی<sup>۴</sup> به‌منظور پیش‌بینی ابداع شده است. با توجه به این‌که شبکه‌های عصبی از دو ویژگی اساسی یادگیری یا نگاشت‌پذیری براساس ارائه داده‌های تجربی (قدرت و توانایی تعمیم‌پذیری) و ساختارپذیری موازی برخوردار می‌باشند، این شبکه‌ها برای مسائل کنترل، به‌ویژه سیستم‌های پیچیده که مدل‌سازی این سیستم‌ها یا امکان‌پذیر نیست و یا به سختی انجام می‌پذیرد، بسیار مناسب هستند (منهاج، ۲۰۰۲). ANN براساس تشخیص الگو<sup>۵</sup> قادر به مدل‌سازی فرآیندهای غیرخطی می‌باشند

1. Digital Terrain Model (DTM)
2. Generalized Linear Model (GLM)
3. Topographic Exposure Index
4. Artificial Neural Networks (ANN)
5. Pattern Recognition

(میلیس و هانلی، ۲۰۰۵). در این راستا مطالعه‌های بسیاری نیز در زمینه استفاده از ANN در پیش‌بینی متغیرهای مختلف جنگل صورت گرفته است. از جمله هیلبرت و استوندورف (۲۰۰۱) از شبکه عصبی مصنوعی پیش‌خور<sup>۱</sup> و GIS برای ارزیابی پتانسیل اثرات تغییرات آب و هوایی بر یک منظر پیچیده جنگل‌های گرمسیری شمال‌شرقی کوینزلند استفاده کردند. ورودی‌های مدل شامل متغیرهای اقلیم، طبقات مواد مادری خاک و متغیرهای زمین بود. مدل به‌دست آمده موفقیت زیادی در تشخیص طبقات جنگل با صحت پیش‌بینی ۷۵ درصد داشت. اینگرام و همکاران (۲۰۰۵) نیز از داده‌های سنجش از دور برای پیش‌بینی سطح مقطع و تراکم تنه در جنگل‌های گرمسیری جنوب ماداگاسکار استفاده کردند. آنها ارتباط سطح مقطع با شاخص تفاوت نرمال شده گیاهی<sup>۲</sup> و تابش اندازه‌گیری شده در باند ۳، ۴، ۵ و ۷ سنجنده ETM<sup>+</sup> را با استفاده از ANN بررسی کردند. نتایج پژوهش آنها نشان داد که رابطه آماری قوی و معنی‌دار ولی معکوس ( $r = -0.79$ ) بین اندازه‌گیری‌های واقعی و پیش‌بینی شده وجود دارد. کاستلانوس و همکاران (۲۰۰۷) از شبکه عصبی تابع پایه شعاعی<sup>۳</sup> RBF به‌منظور پیش‌بینی حجم چوب جنگل استفاده کردند. در این روش نمونه‌های درختی با استفاده از متغیرهای مختلف طبقه‌بندی و سپس حجم چوب برای گونه‌های مختلف محاسبه می‌شود. نتایج پژوهش، گسترش استفاده از مدل‌های پیش‌بینی آماری کلاسیک را برای اندازه‌گیری جنگل پیشنهاد کرد.

**خصوصیات اولیه و ثانویه توپوگرافی:** به‌طور معمول، خصوصیات اولیه توپوگرافی، شامل بر ویژگی‌هایی هستند که به‌طور مستقیم از DTM محاسبه می‌گردند. از سوی دیگر خصوصیات ثانویه و یا خصوصیات ترکیبی، دارای مشخصه‌هایی هستند که مرکب از ویژگی‌های اولیه به‌همراه شاخص‌های فیزیکی یا تجربی می‌باشند که تغییرپذیری مکانی فرآیندهای خاص در سیمای اراضی را بیان می‌کنند (محمدی، ۲۰۰۶). خصوصیات اولیه و ثانویه توپوگرافی به همراه تعاریف آنها در جدول‌های ۱ و ۲ ارائه شده است.

1. Feed Forward
2. Normalized Difference Vegetation Index (NDVI)
3. Enhanced Thematic Mapper Plus (ETM<sup>+</sup>)
4. Radial Basis Function

جدول ۱- تعریف متغیرهای اولیه توپوگرافی (فلورنسکی، ۲۰۰۵a؛ محمدی، ۲۰۰۶).

نام متغیر	تعریف
گردایان شیب <sup>۱</sup>	زاویه بین سطح تماس و سطح افقی در یک نقطه در سطح زمین
جهت شیب <sup>۲</sup>	زاویه ساعت‌گرد از جهت محور Y به سیستم تصویر یک خط صوری قائم بر یک سطح افقی در یک نقطه معین در سطح زمین
انحنای نیم‌رخ <sup>۳</sup>	انحنا در صفحه عمودی خط جریان
انحنای مسطح <sup>۴</sup>	انحنا در صفحه افقی یک خط کنتور
انحنای مماسی <sup>۵</sup>	خمیدگی در سطح شیب دار عمود بر جریان و رویه توپوگرافی
سایه <sup>۶</sup>	سایه جهت

۱- Slope ۲- Aspect ۳- Profile Curvature ۴- Plan Curvature ۵- Tangential Curvature ۶- Shaded relief

جدول ۲- تعریف متغیرهای ثانویه توپوگرافی (فلورنسکی، ۲۰۰۵a؛ محمدی، ۲۰۰۶).


نام متغیر	تعریف
شاخص رطوبت <sup>۱</sup>	ظرفیت رطوبتی خاک یک حوضه آبخیز
تابش خورشید <sup>۲</sup>	مقدار انرژی قابل دسترس بر روی سطح زمین

۱- Wetness Index ۲- Solar Radiation

مدل‌های شبکه عصبی: شبکه‌های عصبی زیرمجموعه‌ای از تکنیک‌های هوش مصنوعی هستند که امروزه در طیف وسیعی برای به‌کارگیری در حل بسیاری از مسائل، شامل حافظه‌های ارتباط‌دهنده، بهینه‌سازی، پیش‌بینی، تشخیص و کنترل رایج شده‌اند. ساختار و عملکرد ANN از مغز انسان تقلید می‌کند و از تعدادی اجزای ساختاری ساده، اما با یک ارتباط پیچیده که به‌عنوان نرون<sup>۱</sup> یا نود<sup>۲</sup> شناخته می‌شوند، تشکیل شده‌اند (استروبل و فورته، ۲۰۰۷). به هر مجموعه از این نرون‌ها یک لایه گفته می‌شود. یک شبکه عصبی معمولاً از لایه‌های ورودی، پنهان و خروجی تشکیل شده است. لایه ورودی فقط اطلاعات را دریافت کرده و مشابه متغیر مستقل عمل می‌کند، لایه خروجی نیز همانند متغیر وابسته عمل کرده و تعداد نرون‌های آن بستگی به تعداد متغیر وابسته دارد اما برخلاف لایه‌های ورودی و خروجی، لایه پنهان اصلی‌ترین بخش پردازش شبکه عصبی است که می‌تواند شامل چند لایه و

1. Neuron
2. Node

نرون‌های متنوع باشد. در این نوع الگوریتم خطای خروجی شبکه برآورد و به عقب (به داخل سیستم) انتشار یافته و بر این اساس وزن‌های انتخاب شده در مدل اصلاح می‌گردد. این فرآیند مربوط به اصلاح وزن‌ها در تمام عناصر سیستم ادامه می‌یابد تا بهترین وزن‌ها که صحیح‌ترین خروجی را برای سیستم ایجاد می‌کند، شناسایی و انتخاب شوند. در حقیقت در این روش با تصحیح مرتب خطا، وزن‌های مناسب به دست می‌آید. وقتی که مناسب‌ترین وزن‌ها به دست آمد مفهوم این می‌باشد که مدل آموزش کافی دیده است و بنابراین وزن‌های مربوط تثبیت شده و در مورد داده‌های ورودی جدید که در قالب داده‌های مربوط به کارایی مدل است اعمال می‌گردد. در این حالت با مقایسه نتایج مدل با مقادیر مشاهده شده، در مورد کارایی مدل قضاوت می‌شود. در شکل ۱ نمایش استاندارد یک شبکه عصبی پیش‌خور ارائه گردیده است.



شکل ۱- نمایش استاندارد شبکه عصبی پیش‌خور.

شبکه عصبی پرسپترون چند لایه  $MLP^1$ : در این نوع شبکه اتصال فقط از جزء  $i$  به جزء  $i+1$  برقرار بوده و در جهت عکس وجود ندارد. شبکه بالا، در عمل از به هم پیوستن سه شبکه پرسپترون تک‌لایه ایجاد شده است. یکی لایه خروجی و دو قسمت دیگر لایه‌های میانی نامیده می‌شوند. خروجی‌های لایه اول، بردار ورودی لایه دوم را تشکیل می‌دهند، و به همین ترتیب بردار خروجی لایه دوم، ورودی‌های لایه سوم را می‌سازند، و خروجی‌های لایه سوم، پاسخ واقعی شبکه را تشکیل می‌دهند. به عبارتی روشن‌تر، روند جریان سیگنالی در شبکه، در یک مسیر پیش‌خور صورت می‌گیرد (منهاج، ۱۹۹۸).

## 1. Multi-Layer Perceptron

شبکه عصبی توابع اساسی شعاعی (RBF): شبکه‌های توابع پایه شعاعی دارای پایه ریاضیاتی بسیار قوی بر مبنای فرضیه منظم‌سازی برای حل مسائل مشکل می‌باشند. به‌طور کلی این شبکه‌ها تقریباً از سه لایه شامل ورودی، مخفی و خروجی تشکیل شده‌اند. توابع پایه شعاعی منظم به‌عنوان تابع تحریک نرون‌های لایه مخفی مورد استفاده قرار می‌گیرند. شبکه‌ها به‌گونه‌ای سازمان یافته‌اند که تبدیل‌ها در واحدهای مخفی در حکم مجموعه‌ای از توابع به‌منظور نگاشت الگوهای ورودی به الگوهای خروجی انجام می‌گیرد. بنابراین لازم است تعداد واحدها در لایه مخفی، برای محدوده فضایی که درون‌یابی در آن انجام می‌گیرد به اندازه کافی زیاد باشند. تبدیل‌ها از نرون‌های ورودی به نرون‌های خروجی از نوع غیرخطی می‌باشد و به‌طورکلی آموزش این قسمت از شبکه به روش نظارت‌نشده انجام می‌گیرد. آموزش پارامترهای شبکه (وزن‌ها) بین لایه‌های مخفی و لایه‌های خروجی به روش نظارت شده و براساس خروجی‌های هدف انجام می‌گیرد، اگرچه تبدیل‌ها در این قسمت از شبکه خطی می‌باشند، در مجموع فرآیند آموزش سریع است. شکل کلی ریاضیاتی نرون‌های خروجی در شبکه‌های RBF به شکل زیر می‌باشد (رابطه ۱).


$$c_j(x) = \sum_{i=1}^k w_{ji} \phi(\|x - \mu_i\|; \sigma_i) \quad (1)$$

که در آن  $c_j(x)$  تابع وابسته به  $j$  امین واحد خروجی و ترکیب خطی از  $k$  تابع پایه شعاعی  $\phi()$  با مرکز  $\mu_i$  و پهنای باند  $\sigma_i$  همچنین  $w_{ji}$  وزن وابسته به  $j$  امین کلاس و  $i$  امین مرکز می‌باشد. توابع  $\phi(\|x - x_i\|)$  توابع پایه شعاعی نامیده می‌شوند و  $\| \cdot \|$  به معنی فاصله اقلیدسی می‌باشد. هدف این پژوهش استفاده از روش نوین شبکه عصبی مصنوعی به‌عنوان ابزاری جهت پیش‌بینی مکانی تراکم درختان (تعداد در هکتار) جنگل با استفاده از اطلاعات استخراج شده از مشخصه‌های توپوگرافی می‌باشد.

### مواد و روش‌ها

**منطقه مورد مطالعه:** منطقه مورد مطالعه، سری یک جنگل آموزشی و پژوهشی شصت کلاته (طرح دکتر بهرام‌نیا) می‌باشد. جنگل آموزشی و پژوهشی شصت کلاته در عرض جغرافیایی ۴۳ درجه و ۳۶ دقیقه تا ۴۵ درجه و ۳۶ دقیقه شمالی و طول جغرافیایی ۲۰ درجه و ۵۴ دقیقه تا ۴ درجه و ۵۴ دقیقه شرقی قرار گرفته است. کل مساحت سری ۱۷۱۴ هکتار و دارای ۳۳ پارسل می‌باشد (شکل ۲). این

جنگل در ۵ کیلومتری جنوب غربی شهر گرگان قرار دارد. میزان بارندگی متوسط سالیانه منطقه ۶۴۹ میلی‌متر می‌باشد. سنگ‌های مادری این ناحیه از نوع ماسه‌ای است. این منطقه دارای خاک قهوه‌ای و قهوه‌ای خاکستری بوده که دارای خاصیت اسیدی است، براساس کلیماتوگرام آمبرژه، اقلیم منطقه نیمه مرطوب سرد می‌باشد. حداقل ارتفاع در منطقه مورد مطالعه ۲۱۰ و حداکثر آن ۱۰۱۰ متر است (طرح تجدید نظر دوم جنگل‌داری سری یک دکتر بهرام‌نیا، ۲۰۰۷).



شکل ۲- موقعیت منطقه مورد مطالعه در ایران و گلستان.

### روش تحقیق

**تهیه اطلاعات زمینی:** به منظور بررسی امکان پیش‌بینی مقادیر تعداد در هکتار جنگل از داده‌های آماربرداری سری یک طرح تجدید نظر جنگل‌داری جنگل شصت‌کلاته مربوط به سال ۱۳۸۵ استفاده گردید. تعداد ۲۵۲ قطعه نمونه دایره‌ای با ابعاد ۱۰ آر و شبکه منظم تصادفی (سیستماتیک) با ابعاد ۲۰۰×۱۵۰ متر در کل سری انتخاب (به غیر از مناطق جنگل‌کاری شده) و اطلاعات درختان با قطر بیشتر از ۱۲/۵ سانتی‌متر ثبت گردید. ثبت موقعیت جغرافیایی قطعات نمونه با استفاده از دستگاه GPS مدل map76csx و با دقت زیاد صورت گرفت. تعداد در هکتار هر قطعه نمونه از طریق شمارش تعداد درختان و محاسبه آن در هکتار حاصل گردید. جدول ۳ آمار توصیفی داده‌های متغیر تعداد در هکتار را نشان می‌دهد.



جدول ۳- آمار توصیفی تعداد در هکتار قطعات نمونه در سری یک.

حداقل	حداکثر	میانگین	انحراف معیار	ضریب تغییرات	چولگی	کشیدگی
۱۰۰	۵۳۰	۲۱۵	۸۹/۸۴	۰/۴۱۸	۱/۴	۱/۷

تهیه مدل رقومی زمین و متغیرهای توپوگرافی: لازمه ایجاد مدل رقومی ارتفاع<sup>۱</sup> در اختیار داشتن داده‌های اولیه ارتفاعی می‌باشد. خطوط تراز ارتفاع نقشه‌های توپوگرافی می‌توانند به‌عنوان داده‌های اولیه ارتفاعی جهت ساخت DEM به‌کار روند. در فرآیند تهیه DEM، داده‌های ارتفاعی اولیه (خطوط و نقاط) به روش‌های ویژه درونیابی به تمامی سطح منطقه تعمیم داده می‌شوند (قهرودی‌تالی، ۲۰۰۴). در این پژوهش مدل رقومی ارتفاع با توان تفکیک‌پذیری ۱۰ متر از طریق درونیابی خطوط میزان ۱۰ متر نقشه توپوگرافی ۱:۲۵۰۰۰ محاسبه گردید. سپس با استفاده از مدل رقومی زمین و نرم‌افزارهای آنالیز زمین نقشه خصوصیات اولیه و ثانویه توپوگرافی (به شرح جدول‌های ۱ و ۲) محاسبه گردیدند.

**استخراج اطلاعات توپوگرافی قطعات نمونه:** بعد از تهیه نقشه‌های مزبور، نقشه موقعیت جغرافیایی قطعات نمونه با توجه به سطح آنها (۰/۱ هکتار) در پیکسل‌هایی با ابعاد ۱۰×۱۰ متر در محیط GIS رستری گردید تا با قرار گرفتن این نقشه بر روی هر یک از نقشه‌های خصوصیات توپوگرافی متوسط ارزش (متوسط ارزش ۹ پیکسل قرار گرفته در محل قطعه نمونه) آنها در محل قطعات نمونه استخراج گردد.

**آماده‌سازی داده‌ها:** داده‌های مورد استفاده برای افزایش دقت و سرعت فرآیندهای شبکه‌های عصبی استاندارد می‌شوند. برای این منظور، روش‌های متعددی ارائه گردیده، که در این پژوهش از رابطه ۲ برای استانداردسازی داده‌ها استفاده شد. با استفاده از این رابطه کلیه داده‌ها در دامنه ۰ و ۱ قرار می‌گیرند. در این رابطه  $\bar{X}$  داده نرمال شده،  $X_i$  داده مورد استفاده و  $X_{min}$  و  $X_{max}$  کمترین و بیشترین داده‌ها در سری مورد نظر می‌باشد. داده‌ها بعد از استانداردسازی به‌منظور آموزش شبکه، به‌طور تصادفی به سه بخش آموزشی، آزمون و ارزیابی تقسیم گردیدند. به این ترتیب که ۲۰ درصد از کل داده‌ها برای آزمون مدل کنار گذاشته شد، سپس از ۸۰ درصد باقی‌مانده، ۶۵ درصد برای آموزش داده‌ها و ۱۵ درصد آنها به‌عنوان داده‌های ارزیابی انتخاب گردیدند.

## 1. Digital Elevation Model (DEM)

$$\bar{X} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (۲)$$

طراحی شبکه عصبی: خصوصیات فیزیوگرافی استخراج شده از مدل رقومی زمین (شیب، جهت، تابش خورشید و...) و اندازه‌گیری‌های زمینی (تعداد در هکتار) به ترتیب به‌عنوان ورودی و خروجی شبکه در نظر گرفته شد. شبکه‌ای با ۱۲ نرون در لایه ورودی (خصوصیات فیزیوگرافی) و یک نرون در لایه خروجی (تعداد درهکتار) طراحی گردید. سپس ۶۵ درصد داده‌ها (۱۶۷ عدد) به‌عنوان ورودی آموزش مدل، ۱۵ درصد برای ارزیابی (۴۰ عدد) مدل و ۲۰ درصد به‌عنوان داده‌های آزمون مدل (۴۵ عدد) انتخاب گردیدند. در این پژوهش دو شبکه عصبی (MLP و RBF) مورد استفاده قرار گرفت. این شبکه‌ها که از رایج‌ترین شبکه‌های عصبی مصنوعی پیش‌خور<sup>۱</sup> محسوب می‌شوند، به‌وسیله الگوریتم انتشار به عقب<sup>۲</sup> آموزش داده می‌شوند و دارای ساختار لایه‌ای هستند (چاپیان و همکاران، ۲۰۰۷). فرآیند آموزش برای این شبکه‌ها که شامل تغییر وزن‌ها بین لایه‌های مختلف در طول زمان آموزش است، انجام گردید تا جایی که تفاوت بین داده‌های واقعی (برای داده‌های آزمون) و داده‌های پیش‌بینی شده به کمترین حد برسد. چندین قاعده آموزشی مانند دلتا بار دلتا<sup>۳</sup>، مومنتوم<sup>۴</sup>، استیپ<sup>۵</sup>، کاناگیت گرادینت<sup>۶</sup>، لونیبرگ ماری‌کوا<sup>۷</sup>، کویک پروپگیشن<sup>۸</sup> و توابع انتقال مانند سافت‌ماکس آکسون<sup>۹</sup>، لینیئر سیگموئید آکسون<sup>۱۰</sup>، لینیئر آکسون<sup>۱۱</sup>، بیاس آکسون<sup>۱۲</sup>، سیگموئید آکسون<sup>۱۳</sup>، لینیئر تانژانت آکسون<sup>۱۴</sup> و تانژانت آکسون<sup>۱۵</sup> برای فرآیندهای آموزش به‌کار گرفته شد، تعداد عناصر پردازش لایه

1. Feed Forward Networks
2. Back Propagation
3. Delta Bar Delta
4. Momentum
5. Ste
6. Conjugate Gradient
7. Levenberg Marqua
8. Quick Propagation
9. Soft Max Axon
10. Linear Sigmoid Axon
11. Axon
12. Linear Axon
13. Bias Axon
14. Sigmoid Axon
15. Linear Tangent Axon
16. Tangent Axon

مرکزی نیز از ۱ تا  $2n+1$  (n تعداد متغیرهای ورودی می باشد) و تعداد لایه های مخفی نیز از ۱ تا ۳ بار در فرآیند آموزش و آزمون مدل تکرار گردید. هدف در هر الگوریتم آموزشی، کاهش میزان ریشه میانگین مربع خطا، میانگین مربع خطا، میانگین قدرمطلق خطا<sup>۳</sup> و افزایش مقدار  $R^2$  است. رابطه های ۳، ۴ و ۵ نحوه محاسبه میزان  $MSE$ ،  $MAE$  و  $RMSE$  را نشان می دهد (ایریکانن و همکاران، ۲۰۰۷). رابطه ۶ نیز برای محاسبه درصد اشتباه به کار می رود.

$$MAE = \sum_{i=1}^n |y_{oi} - y_{pi}| / n \quad (3)$$

$$MSE = \sum_{i=1}^n (y_{oi} - y_{pi})^2 / n \quad (4)$$

$$RMSE = \sqrt{\sum_{i=1}^n (y_{oi} - y_{pi})^2 / n} \quad (5)$$

$$\% E = \frac{1}{N} \sum \left| \frac{y_{pi} - y_{oi}}{y_{oi}} \right| \times 100 \quad (6)$$

در این رابطه ها:  $n$ ، تعداد مشاهده ها،  $y_{oi}$  مقدار مشاهده شده  $\hat{y}$ ،  $\hat{y}$  متوسط مقادیر تست آزمون و  $y_{pi}$  مقدار پیش بینی  $\hat{y}$  ام است.

برازش مدل رگرسیون خطی: برای فراهم نمودن امکان مقایسه توانایی روش شبکه عصبی ساخته شده با روش سنتی رگرسیون خطی چند متغیره، با استفاده از همان داده های مورد استفاده برای آموزش شبکه، رابطه رگرسیونی نام برده بین تعداد در هکتار و خصوصیات فیزیوگرافی برقرار گردید.

## نتایج

در این پژوهش از دو شبکه  $MLP$  و  $RBF$  استفاده گردید. نوع قاعده آموزشی، تابع انتقال، تعداد نرون لایه مخفی و همچنین تعداد عناصر پردازشی لایه مخفی برای هر شبکه مورد آزمایش قرار گرفت و در نهایت ۳۰۰ شبکه با تعداد نرون، تابع انتقال، قاعده آموزشی و تعداد عناصر پردازش لایه مرکزی متفاوت تهیه گردید. بهترین تعداد نرون ها در لایه مخفی و پارامترهای نرون های لایه مخفی به وسیله سعی و خطا به دست آمد. نتایج عملکرد بهترین شبکه ها برای پیش گویی تعداد در هکتار در جدول ۴

1. Root Mean Square Error (RMSE)
2. Mean Square Error (MSE)
3. Mean Absolute Error (MAE)

ارائه شده است. در نهایت با توجه به معیارهای ارزیابی یاد شده در بخش مواد و روش‌ها، شبکه RBF با یک لایه مخفی و قاعده آموزشی استیپ به‌عنوان بهترین شبکه انتخاب گردید تا برای پیش‌بینی تعداد در هکتار در سایر نقاط مورد استفاده قرار گیرد. برای درک بهتر از وضعیت عملکرد شبکه، نمودارهای خروجی شبکه برای مجموعه الگوهای آزمون و پیش‌بینی در شکل‌های ۳، ۴ و ۵ برای شبکه RBF ارائه گردیده است.

جدول ۴- بهترین نتایج شبکه RBF و MLP به ازای لایه‌های مختلف.

نوع شبکه	تعداد لایه مخفی	تابع انتقال	قاعده آموزشی	ریشه میانگین مربع خطا	میانگین قدرمطلق خطا	میانگین مربع خطا	درصد خطا	R <sup>2</sup>
MLP	۲	تانزانت آکسون	مومتم	۵۳/۴۴	۴۲/۲۴	۲۸۵۵/۶۸	۱۹/۶۲	۰/۶۳۷
RBF	۱	تانزانت آکسون	استیپ	۵۳/۲۵	۴۱/۸۴	۲۸۳۵/۷۳	۱۹/۶	۰/۶۵۱

شکل ۳ مقایسه خروجی واقعی و مقادیر پیش‌بینی شده توسط بهترین شبکه را نشان می‌دهد.



شکل ۳- مقایسه خروجی واقعی شبکه با خروجی پیش‌بینی شده توسط شبکه.

در شکل ۴ میانگین مربع خطا (MSE) برای داده‌های آموزشی برحسب تعداد تکرار ارائه شده است. به‌منظور تعیین تعداد بهینه تکرار، میزان MSE برای داده‌های ارزیابی تعیین گردید. همان‌گونه که از شکل ۴ بر می‌آید میزان خطای شبکه برای داده‌های ارزیابی با افزایش تعداد تکرار سیر نزولی


## 1. Epoch

دارد و در نهایت به مقدار ثابتی می‌رسد که بیان‌کننده تأثیر تعداد تکرار بر روی توانایی یادگیری شبکه است. همچنین این شکل نشان می‌دهد که خطای مورد نظر به حد معقولی رسیده و این شبکه قادر است به‌طور صحیح رابطه بین پارامترهای ورودی و خروجی را تشخیص دهد.



شکل ۴- میانگین مربع خطای آموزش و خطای ارزیابی در مقابل تعداد تکرار.

شکل ۵ نشان‌دهنده نتایج آزمون مدل شبکه عصبی انتخاب شده، برای ارزیابی پارامتر خروجی (تعداد در هکتار) است. نمودار پراکندگی نقاط نشان می‌دهد که قابلیت پیش‌بینی تقریباً رضایت‌بخش است.



شکل ۵- میزان همبستگی بین مقادیر پیش‌بینی شده و مقادیر واقعی تعداد در هکتار با حدود اطمینان  $\pm 10\%$  درصد.


ارتباط بین تعداد در هکتار و خصوصیات توپوگرافی با استفاده از روش گام به گام<sup>۱</sup> مورد تجزیه و تحلیل قرار گرفت. نتایج ارزیابی این روش در مراحل مختلف در جدول ۵ ارائه گردیده است. به منظور امکان مقایسه هر دو روش، معیارهای ریشه میانگین مربع خطا و میانگین قدر مطلق خطا  $R^2$  و درصد خطا، محاسبه گردید. مقایسه نتایج جدول‌های ۴ و ۵ نشان می‌دهد که روش شبکه عصبی دارای دقت بیشتری در برآورد تعداد در هکتار جنگل می‌باشد. مدل‌های مبتنی بر روش شبکه عصبی منجر به مقدار  $MAE$ ,  $MSE$ ,  $RMSE$  و  $E$  درصد کمتر و مقدار ضریب تبیین بیشتر شده است که به نظر می‌رسد دلیل این امر در نظر گرفتن روابط غیرخطی بین پدیده‌ها در روش شبکه عصبی مصنوعی می‌باشد.

جدول ۵- نتایج رگرسیون مراحل گام به گام چند متغیره خطی برای برآورد تعداد در هکتار.

$R^2$	درصد خطا	میانگین قدرمطلق خطا	میانگین مربع خطا	ریشه میانگین مربع خطا
۰/۴۴۲	۴۰/۶۳	۵۰/۶۸	۴۱۸۱/۸۹	۶۴/۶۷
۰/۳۹۷	۴۰/۱	۵۱/۳۵	۴۳۲۴/۵۱	۶۵/۷۶
۰/۳۵۳	۴۲/۲	۵۴/۳۲	۴۸۶۴/۶۴	۶۹/۷۵

تهیه نقشه تعداد در هکتار به روش شبکه عصبی مصنوعی: شبکه‌ای که براساس معیارهای کمتر  $MAE$ ,  $E$ ,  $MSE$ ,  $RMSE$  درصد، مقدار ضریب تبیین بیشتر، انتخاب شده، برای پیش‌بینی اطلاعات مکانی تعداد در هکتار در تمام نقاط جنگل که نمونه‌برداری در آنها صورت نگرفته مورد استفاده قرار گرفت. با استفاده از مقادیر پیش‌بینی شده در این نقاط و مقادیر موجود، نقشه پیوسته مکانی تعداد در هکتار جنگل در محیط GIS تهیه گردید (شکل ۶). لازم به ذکر است که مقدار پیش‌بینی شده در این نقاط برای سطوح ۰/۱ هکتاری در نظر گرفته می‌شوند.

## 1. Stepwise



شکل ۶- نقشه تعداد در هکتار حاصل شده از پیش‌بینی انجام شده به وسیله شبکه عصبی مصنوعی.

### بحث و نتیجه‌گیری

مدیریت صحیح جنگل نیاز به درک ارتباط جنگل با عوامل محیطی دارد. این ارتباط به حدی است که عوامل محیطی در بسیاری از موارد تعیین‌کننده خصوصیات جنگل می‌باشند. توسعه مدل‌های پیش‌بینی مکانی به‌منظور پیش‌بینی خصوصیات جنگل در مکان‌هایی که اطلاعات آنها در دسترس نیست، بسیار ارزشمند می‌باشد. در این پژوهش کارایی شبکه پرسپترون چندلایه و شبکه تابع پایه شعاعی، به‌منظور پیش‌بینی تعداد در هکتار جنگل با استفاده از برخی خصوصیات اولیه و ثانویه توپوگرافی، مورد بررسی قرار گرفت. نتایج نشان داد، شبکه تابع پایه شعاعی با الگوریتم آموزشی پس انتشار خطا (در این قاعده آموزشی خطا به شبکه برگشت داده شده و سپس انتشار پیدا می‌کند)، با یک لایه مخفی (و ۴ واحد پردازش مرکزی در لایه مخفی)، تابع انتقال تانژانت آکسون و قاعده آموزشی استیپ، در مقایسه با شبکه پرسپترون چندلایه توانایی بیشتری در فرایند پیش‌بینی مشخصه تعداد در هکتار جنگل دارد. همچنین نشان داد که این تکنیک می‌تواند ۶۵ درصد تغییرات تعداد در هکتار جنگل را با استفاده از خصوصیات توپوگرافی پیش‌بینی نماید. این موضوع تأییدکننده نقش مؤثر عوامل فیزیوگرافی در تشکیل خصوصیات جنگل می‌باشد که با پژوهش‌های میتسودا و همکاران (۲۰۰۷)، هورش (۲۰۰۳) و جوسان و توریلات (۲۰۰۰) مطابقت دارد.

براساس مؤلفه‌های آماری جدول‌های ۴ و ۵ و با توجه به معیارهای ارزیابی حاصل از دو روش آماری و شبکه عصبی، از هر لحاظ شبکه عصبی بر روش رگرسیون چند متغیره خطی برتر بوده و از سوی دیگر وجود رابطه غیرخطی بین خصوصیات توپوگرافی و تعداد در هکتار جنگل را تایید می‌کند. مدل‌های ANN به دلیل در نظر گرفتن روابط غیرخطی موجود میان عوامل محیطی و خصوصیات جنگل و به دنبال آن افزایش دقت در برآورد پیش‌بینی‌ها می‌توانند جایگزین مناسبی برای مدل‌های ریاضی در مدل‌سازی خصوصیات جنگل باشند. استفاده از ANN در افزایش دقت پیش‌بینی در این پژوهش خوب ارزیابی گردید که این امر با پژوهش‌های اینگرام و همکاران (۲۰۰۵)، هیلبرت و استوندورف (۲۰۰۱) مطابقت دارد ولی با پژوهش کاستلانوس و همکاران (۲۰۰۷) هم‌خوانی ندارد. شایان ذکر است که در مدل‌های رگرسیونی، همبستگی ضعیف بین دو متغیر وابسته به هم، همیشه نشان‌دهنده ارتباط نداشتن این دو متغیر با همدیگر نیست. در برخی مواقع ممکن است همبستگی غیرخطی بین دو متغیر وجود داشته باشد که به وسیله ضریب همبستگی خطی قابل اندازه‌گیری نیست (چایان، ۲۰۰۷). به منظور افزایش دقت در پیش‌بینی مکانی خصوصیات جنگل پیشنهاد می‌گردد علاوه بر استفاده از خصوصیات توپوگرافی از سایر اطلاعات کمکی مانند اطلاعات خاک‌شناسی و تصاویر ماهواره‌ای، استفاده شود. لازم به ذکر است که مشخصه‌های ANN اثر مؤثری بر توانایی یادگیری و پیش‌بینی‌های مدل‌های ANN دارند. بنابراین در انتخاب آنها باید دقت زیادی اعمال گردد.

#### منابع

1. Albani, M., Klinkenberg, B., Andison, D.W., and Pkimmings, J. 2004. The choice of window size in approximating topographic surfaces from Digital Elevation Models. *International J. Geographical Information Science*, 17:577-593.
2. Canton, Y., Barrio, G.D., Benet, A.S. and Lazaro, R. 2004. Topographic controls on the spatial distribution of ground cover in the Tabernas badlands of SE Spain. *Catena*. 55:341-365.
3. Castellanos, A., Blanco, A.M., and Palencia, V. 2007. Applications of Radial Basis Neural Networks for area forest. *International J. "Information Theories and Applications"* 14: 218-222.
4. Chayjan, R., Montazer, G.A.T., Hashjin, T., Khoshtaghaza, M.H., and Ghobadian, B. 2007. Prediction of Pistachio Thermal Conductivity Using Artificial Neural Network Approach. *International J. Agric. and Biology*. 9:6.816-820.
5. Eerikainen, K., Miina, J., and Valkonen, S. 2007. Models for the regeneration establishment and the development of established seedlings in uneven-aged, Norway spruce dominated forest stands of southern Finland. *Forest Ecology and Management*. 242: 444-461.
6. Florinsky, I.V. 2005a. Artificial Lineaments in Digital Terrain Modeling: Can Operators of Topographic Variables Cause Them? *Mathematical Geology*. 37:4. 357-372.



7. Florinsky, I.V., and Kuryakova, G.A. 1966. Influence of topography on some vegetation cover properties. Elsevier Science, 27: 123-141.
8. Franklin, J., McCullough, P., and Gray, C. 2000. Terrain variables used for predictive mapping of vegetation communities in Southern California, in Terrain Analysis: Principles and Applications, J.P. Wilson and J.C. Gallant (eds.), John Wiley & Sons, New York, Pp: 331-353.
9. Ghahrody Talli, M. 2004. Geographic Information Systems in 3D space. Jahad Daneshgahi Tarbyat Moalem publisher. One edition, 266p. (In Persian)
10. Giger, R. 1966. The Climate near the Ground. Translated by Script from the 4<sup>th</sup> German ed., 2d print. Harvard University Press, Cambridge, MA, 611p.
11. Guisan, A., and Theurillat, J. 2000. Equilibrium modeling of alpine plant distribution: how far can we go? *Phytocoenologia* 30:353-384.
12. Hilbert, D.W., and Ostendorf, B. 2001. The utility of artificial neural networks for modeling the distribution of vegetation in past, present and future climates. *Ecological Modeling*, 146:311-327.
13. Horsch, B. 2003. Modeling the spatial distribution of mountain and sub alpine forests in the central Alps using digital elevation models. *Ecological Modeling*. 168: 267-282.
14. Ingram, J.C., Dawson, T.P., and Whittaker, R.J. 2005. Mapping tropical forest structure in southeastern Madagascar using remote sensing and artificial neural networks. *Remote Sensing of Environment*, 94:491-507.
15. Liprieur, V.E., Durand, J.M., and Peyron, J.L. 1988. Influence of topography on forest reflectance using Landsat Thematic Mapper and digital terrain data. photogrammetry. *Engineering Remote Sensing*. 4: 461-496.
16. Melesse, A.M., and Hanley, R.S. 2005. Artificial neural network application for multi-ecosystem carbon flux simulation. *Ecological Modeling* 189: 305-314.
17. Menhaj, M.B. 2002. Functional Neural Networks. Amirkabir University of Technology Publisher. Second edition, 715p. (In Persian)
18. Menhaj, M.B. 1998. Computational intelligence in control. Professor hesabi Publisher. One edition, 236p. (In Persian)
19. Mitsuda, Y., Ito, S., and Sakamoto, S. 2007. Predicting the site index of Sugi plantations from GIS-derived environmental factors in Miyazaki Prefecture. *J. Forest Research*. 12: 177-186.
20. Mohamadi, J. 2006. Pedometry (Spatial Information Systems). Pelk Publisher. One edition, 637p.
21. Second revised of Doctor Bahramnia Forestry plan. 2007. Forestry Faculty of Natural Resources, University of Gorgan, 478p. (In Persian)
22. Strobl, R.O., and Forte, F. 2007. Artificial neural network exploration of the influential factors in drainage network derivation. *Hydrological processes*. 21: 2965-2978.
23. Wilson, M.F.G., O'Connell, B., Brown, C., Guinan, J.C., and Grehan, G. 2007. Multi scale terrain analysis of multi beam bathymetry data for habitat mapping on the continental slope. *Marine Geodesy*. 30: 3-35.



Gorgan University of Agricultural  
Sciences and Natural Resources

*J. of Wood & Forest Science and Technology*, Vol. 16(4), 2009

[www.gau.ac.ir/journals](http://www.gau.ac.ir/journals)

## **Tree Density Estimation of Forests by Terrain Analysis and Artificial Neural Network**

**\*F. Ghanbari<sup>1</sup>, Sh. Shataee<sup>2</sup>, A.A. Dehghani<sup>3</sup> and Sh. Ayoubi<sup>4</sup>**

<sup>1</sup>M.Sc. Student, Dept. of Forestry, Gorgan University of Agricultural Sciences and Natural Resources, <sup>2</sup>Associate Prof., Dept. of Forestry, Gorgan University of Agricultural Sciences and Natural Resources, <sup>3</sup>Assistant Prof., Dept. of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, <sup>4</sup>Assistant Prof., Dept. of Soil Science, Isfahan University of Technology

### **Abstract**

The interaction between landscape and forest properties has been well documented, and thus it is plausible to assume that landscape factors in a forest region have a determinant function in forest properties formation. Although previous researches have identified the significant relationships between forest attributes and environmental factors, but there is no definite model available for this properties delineation. Utilizing digital terrain models and its extractable information can help for this purpose. This study was conducted to evaluate artificial neural network ability for prediction spatial distribution of forest tree density and for production continuous map using primary and secondary topographic attribute in Shastkolate forestry plan, district I. The primary and secondary topographic attributes calculated from digital elevation model with 10m resolution. Geometric coordination of plots which were recorded by GPS, mapped in GIS. Then Primary and secondary topographic attribute derived in this plot location. Tree density obtained by counting number of tree in 1 Are circle plots and then calculation in hectare. The relationship between forest tree density and terrain attributes analyzed applying two types of artificial neural network (MLP and RBF). Results showed that RBF neural network provides more accurate results than MLP neural network. Moreover, the regression analysis was done for comparison of the results of ANN models with linear models. The results verified the ability of artificial neural network for prediction of forest tree density and also indicated that ANN approach can predict approximately 65% of the forest tree density variation in the given study area using topographic attribute.

**Keywords:** Topographic attribute, Forest tree density, Digital Elevation Model, Artificial Neural Network

---

\* Corresponding Author; Email: [fariba\\_ghanbari@yahoo.com](mailto:fariba_ghanbari@yahoo.com)