



دانشگاه علم و فناوری اسلامی کاشان

مجله پژوهش‌های علوم و فناوری چوب و جنگل  
جلد شانزدهم، شماره چهارم، ۱۳۸۸  
[www.gau.ac.ir/journals](http://www.gau.ac.ir/journals)

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

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

<sup>۱</sup>دانشجوی کارشناسی ارشد گروه جنگلداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، <sup>۲</sup>دانشیار گروه جنگلداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، <sup>۳</sup>استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، <sup>۴</sup>استادیار گروه خاکشناسی، دانشگاه صنعتی اصفهان

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

### چکیده

اثر مقابل 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 به کارگیری 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 شصت کلاهه 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. علاوه‌بر 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، به منظور ارزیابی و برنامه‌ریزی عملکرد آینده منابع جنگلی برای مدیران جنگل اهمیت زیادی دارد. نظرارت بر پوشش زمین در مناطق وسیع نیازمند حجم زیادی از داده‌ها می‌باشد از طرفی اندازه‌گیری صحرایی فرآیندهای فیزیکی و بیولوژیکی به طور پیوسته مشکل می‌باشد. یکی از رایج‌ترین متدهای مورد استفاده، مدل‌سازی پیش‌بینی گیاهی است که می‌تواند به عنوان 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 به طور موازی با اقلیم، زمین‌شناسی، خاک و دیرینه‌شناسی عمل می‌کند (فلورنسکی و کوریاکو، ۱۹۶۶). از این میان سه متغیر شیب، جهت و ارتفاع مهم‌ترین متغیرهای توپوگرافی هستند که به طور رایج در اندازه‌گیری‌ها و تهیه نقشه‌های گیاهی مورد استفاده قرار می‌گیرند (لیپریور و همکاران، ۱۹۸۸) و در بسیاری از موارد تعیین‌کننده میکروکلیما هستند (جیجر، ۱۹۶۶). این عوامل به طور 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 نیمه‌مدیرانه‌ای جنوب کالیفرنیا وابسته به توازن رطوبت خاک است و این مشخصه متعاقباً بهوسیله شاخص‌های توپوگرافی مشتق شده از DTM، نظری 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 زاپنی با روش رگرسیون چند متغیره خطی مدل‌سازی نمودند. بهترین مدل در این پژوهش برای DTM با تفکیک مکانی ۱۲/۵ متر و با  $R^2 = ۰/۶۹۲$  بود. در این پژوهش تابش خورشید مهم‌ترین عامل محدودکننده شناخته شد و رطوبت خاک نیز در حاصل خیزی رویشگاه موثر بود. امروزه به موازات مدل‌های رایج قبلی، روش‌های جدیدتری با عنوان شبکه‌های عصبی مصنوعی<sup>۴</sup> به منظور 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 ساختار پذیری موازی برخوردار می‌باشند، این شبکه‌ها برای مسائل کنترل، به ویژه 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 می‌باشد.

- 
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 به دست 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>۳+۴</sup> را با استفاده از ANN بررسی کردند. نتایج پژوهش آنها نشان داد که رابطه آماری قوی و معنی‌دار ولی معکوس ( $r = -0.69$ ) بین اندازه‌گیری‌های واقعی و پیش‌بینی شده وجود دارد. کاستلانوس و همکاران (۲۰۰۷) از شبکه عصبی تابع پایه شعاعی<sup>۵</sup> RBF به منظور 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: به طور معمول، خصوصیات اولیه توپوگرافی، شامل بر ویژگی‌های هستند که به طور مستقیم از DTM محاسبه می‌گردند. از سوی دیگر خصوصیات ثانویه و یا خصوصیات ترکیبی، دارای مشخصه‌هایی هستند که مرکب از ویژگی‌های اولیه بهمراه 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

## فریبا قنبری و همکاران

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

نام متغیر	تعریف
گرادیان شبیب <sup>۱</sup>	زاویه بین سطح تماس و سطح افقی در یک نقطه در سطح زمین
جهت شبیب <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 نیم رخی <sup>۳</sup>	انحنا در صفحه عمودی خط جريان
انحنای مسطح <sup>۴</sup>	انحنا در صفحه افقی یک خط کنتور
انحنای مماسی <sup>۵</sup>	خمیدگی در سطح شبیب دار عمود بر جريان 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

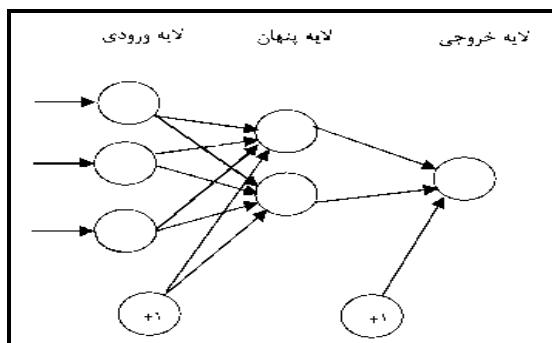
جدول ۲- تعریف متغیرهای ثانویه توپوگرافی (فلورنسکی، ۲۰۰۵a؛ محمدی، ۲۰۰۶).

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 به کارگیری 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 به عنوان 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 خطای 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 ثبیت شده و در مورد داده‌های ورودی جدید که در قالب داده‌های مربوط به کارآیی مدل است اعمال می‌گردد. در این حالت با مقایسه نتایج مدل با مقادیر مشاهده شده، در مورد کارآیی 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<sup>۱</sup> (MLP): در این نوع شبکه اتصال فقط از جزء  $i+1$  برقرار بوده و در جهت عکس وجود ندارد. شبکه بالا، در عمل از به هم پیوستن سه شبکه پرسپترون تک لایه 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 روش‌تر، 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. به طور کلی این شبکه‌ها تقریباً از سه لایه شامل ورودی، مخفی و خروجی تشکیل شده‌اند. توابع پایه شعاعی منظم به عنوان تابع تحریک نرون‌های لایه مخفی مورد استفاده قرار می‌گیرند. شبکه‌ها به گونه‌ای 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 واحدهای زیاد باشند. تبدیل‌ها از نرون‌های خروجی به الگوهای خروجی آن انجام می‌گیرد. آموزش پارامترهای شبکه (وزن‌ها) بین لایه‌های مخفی و لایه‌های خروجی به روش ناظارت‌نشده انجام می‌گیرد. آموزش پارامترهای شبکه (وزن‌ها) بین لایه‌های مخفی و لایه‌های خروجی به روش ناظارت شده و براساس خروجی‌های هدف انجام می‌گیرد، اگرچه تبدیل‌ها در این قسمت از شبکه خطی می‌باشد، در مجموع فرآیند آموزش سریع است. شکل کلی ریاضیاتی نرون‌های خروجی در شبکه‌های RBF به شکل زیر می‌باشد (رابطه ۱).

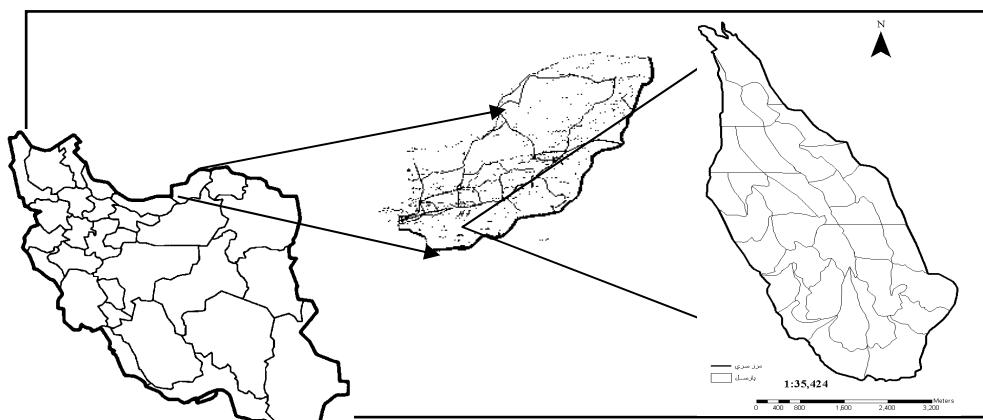
$$c_j(x) = \sum_{i=1}^k w_{ji} \phi(\|x - \mu_i\|; \sigma_i) \quad (1)$$

که در آن  $(x)_j$  تابع وابسته به  $j$  امین واحد خروجی و ترکیب خطی از  $k$  تابع پایه شعاعی  $(\phi)$  با مرکز  $\mu_i$  و پهنه‌ای باند  $\sigma_i$  همچنین  $w_{ji}$  وزن وابسته به  $j$  امین کلاس و  $i$  امین مرکز می‌باشد. تابع  $\phi(x_i)$ ، تابع پایه شعاعی نامیده می‌شوند و  $\|\cdot\|$  به معنی فاصله اقلیدسی می‌باشد. هدف این پژوهش استفاده از روش نوین شبکه عصبی مصنوعی به عنوان 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 شصت‌کلاته (طرح دکتر بهرام‌نیا) می‌باشد. جنگل آموزشی و پژوهشی شصت‌کلاته در عرض جغرافیایی  $43^{\circ}$  درجه و  $36^{\circ}$  دقیقه تا  $45^{\circ}$  درجه و  $36^{\circ}$  دقیقه شمالی و طول جغرافیایی  $20^{\circ}$  درجه و  $54^{\circ}$  دقیقه تا  $4^{\circ}$  درجه و  $54^{\circ}$  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 نیمه‌مرطوب 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 شصت کلاته مربوط به سال ۱۳۸۵ استفاده گردید. تعداد ۲۵۲ قطعه نمونه دایره‌ای با ابعاد ۱۰ آر و شبکه منظم تصادفی (سیستماتیک) با ابعاد  $150 \times 200$  متر در کل سری انتخاب (به غیر از مناطق جنگل کاری شده) و اطلاعات درختان با قطر بیشتر از  $12/5$  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.

## فریبا قنبری و همکاران

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 به عنوان داده‌های اولیه ارتفاعی جهت ساخت DEM به کار روند. در فرآیند تهیه DEM، داده‌های ارتفاعی اولیه (خطوط و نقاط) به روش‌های ویژه درون‌یابی به تمامی سطح منطقه تعیین داده می‌شوند (قهرودی‌تالی، ۲۰۰۴). در این پژوهش مدل رقومی ارتفاع با توان تفکیک‌پذیری ۱۰ متراز 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 جداول‌های 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  $10 \times 10$  متر در محیط GIS رسترن 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 به منظور آموزش شبکه، به طور 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 به عنوان داده‌های ارزیابی انتخاب گردیدند.

1. Digital Elevation Model (DEM)

$$\overline{X} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

**طراحی شبکه عصبی:** خصوصیات فیزیوگرافی استخراج شده از مدل رقومی زمین (شیب، جهت، تابش خورشید و...) و اندازه‌گیری‌های زمینی (تعداد در هکتار) به ترتیب به عنوان ورودی و خروجی شبکه در نظر گرفته شد. شبکه‌ای با ۱۲ نرون در لایه ورودی (خصوصیات فیزیوگرافی) و یک نرون در لایه خروجی (تعداد در هکتار) طراحی گردید. سپس ۶۵ درصد داده‌ها (۱۶۷ عدد) به عنوان ورودی آموزش مدل، ۱۵ درصد برای ارزیابی (۴۰ عدد) مدل و ۲۰ درصد به عنوان داده‌های آزمون مدل (۴۵ عدد) انتخاب گردیدند. در این پژوهش دو شبکه عصبی (RBF و MLP) مورد استفاده قرار گرفت. این شبکه‌ها که از رایج‌ترین شبکه‌های عصبی مصنوعی پیش‌خور<sup>۱</sup> محسوب می‌شوند، به سیله الگوریتم انتشار به عقب<sup>۲</sup> آموزش داده می‌شوند و دارای ساختار لایه‌ای هستند (چایان 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<sup>۳</sup>، مومنتوم<sup>۴</sup>، استیپ<sup>۵</sup>، کانجاقیت گرادینت<sup>۶</sup>، لونبرگ ماری کوا<sup>۷</sup>، کویک پروپگیشن<sup>۸</sup> و توابع انتقال مانند سافت‌ماکس آکسون<sup>۹</sup>، لینیر سیگموئید آکسون<sup>۱۰</sup>، آکسون<sup>۱۱</sup>، لینیر آکسون<sup>۱۲</sup>، بیاس آکسون<sup>۱۳</sup>، سیگموئید آکسون<sup>۱۴</sup>، لینیر تانژانت آکسون<sup>۱۵</sup> و تانژانت آکسون<sup>۱۶</sup> برای فرآیندهای آموزش به کار 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  $n+1$  تا  $2n+1$  تعداد متغیرهای ورودی می‌باشد) و تعداد لایه‌های 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 خطأ<sup>۱</sup>، میانگین مربع خطأ<sup>۲</sup>، میانگین قدر مطلق خطأ<sup>۳</sup> و افزایش مقدار  $R^2$  است. رابطه‌های ۴ و ۵ نحوه محاسبه میزان RMSE و MSE و MAE را نشان می‌دهد (ایریکان و همکاران، ۲۰۰۷). رابطه ۶ نیز برای محاسبه درصد اشتباه به کار می‌رود.

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

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

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

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

در این رابطه‌ها:  $n$  تعداد مشاهده‌ها،  $y_{oi}$  مقدار مشاهده شده  $i$ ام،  $\hat{y}$  متوسط مقادیر تست آزمون و  $y_{pi}$  مقدار پیش‌بینی  $i$ 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 داده‌های مورد استفاده برای آموزش شبکه، رابطه رگرسیونی نامبرده 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 نرون‌ها در لایه مخفی و پارامترهای نرون‌های لایه مخفی به وسیله سعی و خطأ به دست آمد. نتایج عملکرد بهترین شبکه‌ها برای پیش‌گویی تعداد در هکتار در جدول ۴

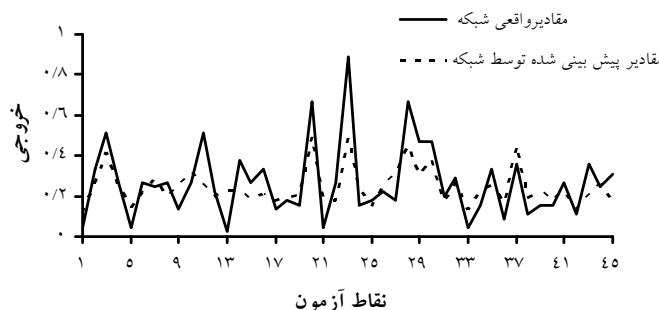
- 
1. Root Mean Square Error (RMSE)
  2. Mean Square Error (MSE)
  3. Mean Absolute Error (MAE)

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 به عنوان 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 مریع خطأ	میانگین مریع خطأ	میانگین مریع خطأ	درصد خطأ	$R^2$
MLP	۲	تائزانت آکسون	مومنتم	۵۳/۴۴	۴۲/۲۴	۲۸۵۵/۶۸	۱۹/۶۲	۰/۶۳۷
RBF	۱	تائزانت 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.

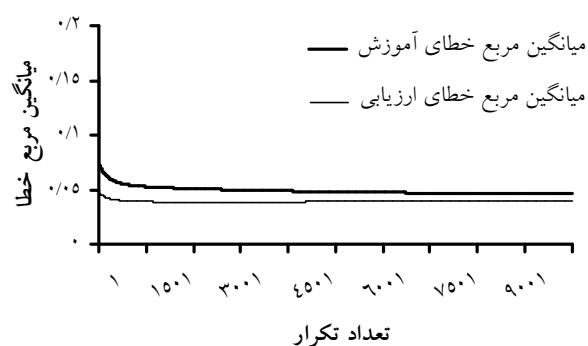


شکل ۳- مقایسه خروجی واقعی شبکه با خروجی پیش‌بینی شده توسط شبکه.

در شکل ۴ میانگین مریع خطأ (MSE) برای داده‌های آموزشی بر حسب تعداد تکرار<sup>۱</sup> 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

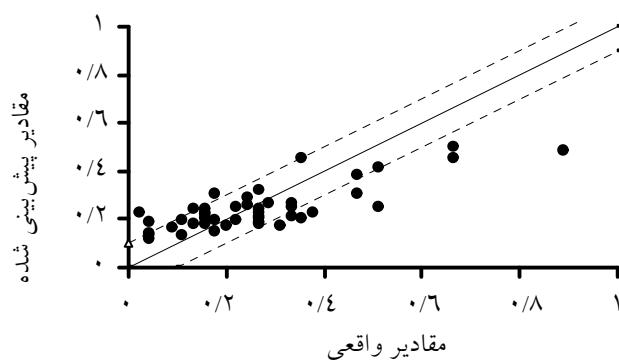
1. Epoch

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 به طور 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.

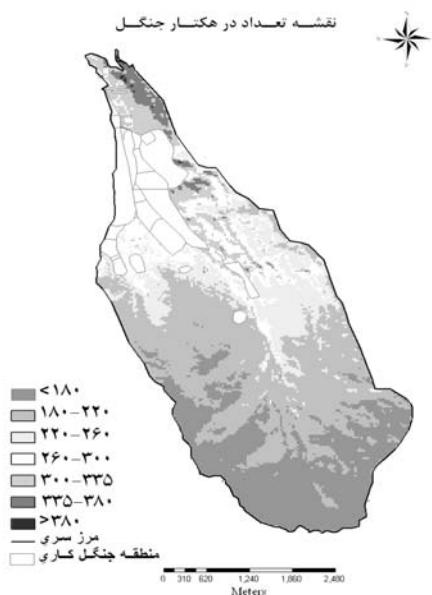
ارتباط بین تعداد در هکتار و خصوصیات توپوگرافی با استفاده از روش گام به گام<sup>۱</sup> مورد تجزیه و تحلیل قرار گرفت. نتایج ارزیابی این روش در مراحل مختلف در جدول ۵ ارائه گردیده است. به‌منظور امکان مقایسه هر دو روش، معیارهای ریشه میانگین مربع خطأ و میانگین قدر مطلق خطأ  $R^2$  و درصد خطأ، محاسبه گردید. 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 E درصد کمتر و مقدار ضریب تبیین بیشتر شده است که به‌نظر 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 خطأ	میانگین مربع خطأ	ریشه میانگین مربع خطأ	میانگین قدر مطلق خطأ
۰/۴۴۲	۴۰/۶۳	۵۰/۶۸	۶۴/۶۷	۴۱۸۱/۸۹
۰/۳۹۷	۴۰/۱	۵۱/۳۵	۶۵/۷۶	۴۳۲۴/۵۱
۰/۳۵۳	۴۲/۲	۵۴/۳۲	۶۹/۷۵	۴۸۶۴/۶۴

تهیه نقشه تعداد در هکتار به روش شبکه عصبی مصنوعی: شبکه‌ای که براساس معیارهای کمتر E، MAE، 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 خطأ (در این قاعده آموزشی خطأ به شبکه برگشت داده شده و سپس انتشار پیدا می‌کند)، با یک لایه مخفی (و ۴ واحد پردازش مرکزی در لایه مخفی)، تابع انتقال تائزانت 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 ثوریلات (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 نظرگرفتن 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) هم خوانی 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 علاوه‌بر 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 Pkimmns, 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. Strobl1, 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.



*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