



مقایسه عملکرد شبکه‌های عصبی مصنوعی با تحلیل رگرسیون در برآورد تراکم توده‌های جنگلی سراوان گیلان

سیما لطفی اصل^۱، ایرج حسن‌زاد ناوردی^{۲*} و امان محمد کلته^۳

^۱ دانشجوی دکتری جنگلداری، پردیس دانشگاهی، دانشگاه گیلان، رشت
^۲ دانشیار، گروه جنگلداری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا
^۳ استادیار، گروه مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا

(تاریخ دریافت: ۱۳۹۹/۱/۱؛ تاریخ پذیرش: ۱۳۹۹/۱۰/۱۷)

چکیده

تراکم درختان از مهم‌ترین ویژگی‌های ساختاری جنگل است که در مدیریت، حفاظت و احیای جنگل‌های شمال ایران اهمیت ویژه‌ای دارد. در این پژوهش، تراکم درختان به کمک عوامل مؤثر فیزیوگرافی، خاکی و انسانی با استفاده از شبکه‌های عصبی مصنوعی نگاشت خودسازمانده نظارت‌شده، پرسپترون چندلایه و مدل رگرسیون خطی چندگانه برآورد و با توجه به معیارهای ارزیابی کارایی آنها مقایسه شد. از این‌رو نخست واحدهای همگن در محیط GIS تهیه شد. نمونه‌برداری به روش سیستماتیک تصادفی با شبکه‌ای به ابعاد 200×150 متر انجام گرفت و در کل ۷۷۹ قطعه نمونه دایره‌ای به مساحت $0/1$ هکتار پیاده شد. با اندازه‌گیری قطر برابر سینه همه درختان بالای $7/5$ سانتی‌متر، تراکم درختان برای هر قطعه نمونه و واحدهای همگن محاسبه شد. نتایج نشان داد که شبکه عصبی $SSOM$ ($R^2 = 0/9117$)، $R^2_{adj} = 0/8760$ ، $RMSE\% = 4/26$ ، $Bias\% = 9/16$ در مقایسه با شبکه عصبی MLP ($R^2 = 0/8321$)، $R^2_{adj} = 0/8760$ ، $RMSE\% = 28/71$ ، $R^2_{adj} = 0/6910$ ، $R^2 = 0/6812$ و مدل رگرسیون خطی چندگانه ($R^2 = 0/6812$)، $R^2_{adj} = 0/6910$ ، $RMSE\% = 28/71$ ، $Bias\% = 10/96$ ، $RMSE\% = 15/14$ دارای دقت بیشتر و خطای کمتر است. برای انتخاب برترین مدل، آزمون T-test انجام گرفت و نتایج نشان داد که شبکه عصبی $SSOM$ از نوع رقابتی و نظارتی در سطح احتمال ۹۵ درصد، مقادیری مشابه مقادیر واقعی دارد که علت آن به دلیل توابع گوسی است که این ویژگی در شبکه‌های عصبی MLP با توابع سیگموئیدی مشاهده نمی‌شود. از این‌رو، شبکه عصبی $SSOM$ در برآورد تراکم درختان جنگل‌های شمال ایران، جایگزین مناسبی برای شبکه عصبی پرسپترون چندلایه خواهد بود.

واژه‌های کلیدی: پرسپترون چندلایه، تعداد در هکتار، نرون برنده، نگاشت خودسازمانده، یادگیری نظارت‌شده.

مقدمه

هستند که از اروپای شمالی تا جنگل‌های خزری ادامه دارند (Rastaby et al., 2013). این جنگل‌ها شیب‌های شمالی رشته‌کوه البرز، از شمال غربی تا شمال شرقی ایران به مساحت حدود $1/9$ میلیون

جنگل‌های هیرکانی یا خزری بازمانده دوران سوم زمین‌شناسی^۱ از نظر جغرافیایی زیررده جنگل‌های اروپا سیبری و ادامه جنگل‌های معتدله اروپایی

چند لایه پیشخور^۳، شبکه‌های عصبی تابع شعاعی^۴، ماشین بردار پشتیبان^۵، یادگیرنده رقیمی‌ساز بردار^۶ و نگاشت خودسازمانده^۷ اشاره کرده‌اند (Stumer et al., 2010). نگاشت خودسازمانده متشکل از یک لایه ورودی و یک لایه خروجی، نخستین بار توسط کوهونن معرفی شد (Kohonen, 1990) که به‌طور گسترده در شناسایی الگو^۸، داده‌کاوی^۹ و خوشه‌بندی^{۱۰} و طبقه‌بندی داده‌ها استفاده می‌شود (Liu & Liu, 2011; Yu et al., 2011; Fan et al., 2012). بیشتر پژوهشگران علوم جنگل در ایران در زمینه‌های مختلف با الگوریتم‌های متفاوت پژوهش‌هایی انجام داده‌اند. برای نمونه (Gorzin et al., 2018) از شبکه عصبی MLP و آنالیز رگرسیون به منظور پیش‌بینی و برآورد حجم مقطوعات درختان جنگل آموزشی و پژوهشی خیرود نوشهر استفاده کردند. Ronoud et al. (2019) به مقایسه عملکرد الگوریتم‌های K نزدیک‌ترین همسایه^{۱۱}، تخمینگر بردار پشتیبان^{۱۲} و جنگل تصادفی^{۱۳} در برآورد تراکم درختان راش جنگل‌های خیرود کنار نوشهر پرداختند. Amiri et al. (2019) کاربرد شبکه عصبی پرسپترون چندلایه و مدل رگرسیون لجستیک را در تهیه نقشه تیپ‌های جنگلی طرح جنگلداری زیارت‌گران به کمک مؤلفه‌های فیزیوگرافی و اقلیمی مانند ارتفاع از سطح دریا، شیب، جهت شیب، میانگین بارندگی، تبخیر و دمای سالانه بررسی کردند. (Vafaei et al., 2016) تراکم درختان و تاج پوشش جنگل‌های باغان مریوان

هکتار را پوشش داده‌اند. در حدود ۶۰ درصد از جنگل‌های این محدوده به‌منظور تولید چوب مدیریت می‌شود (Sagheb-Talebi et al., 2004). با توجه به ضرورت مدیریت، حفاظت و احیای این جنگل‌ها، دسترسی به اطلاعات مکانی به‌موقع از مشخصه‌های ساختاری جنگل لازم و ضروری است (Ediriweera et al., 2016). تراکم درختان (تعداد درخت در هکتار) از مهم‌ترین مشخصه‌های ساختاری جنگل است که تحت تأثیر عوامل طبیعی یا غیرطبیعی قرار دارد (Amiri, 2016). به‌دلیل پویایی عوامل رویشگاهی، جمع‌آوری اطلاعات به‌نگام و به‌روز از این مشخصه‌ها در سطح وسیع سخت و طاقت‌فرساست (Fatehi et al., 2015). بسیاری از مدیران و محققان جنگل درصددند که بتوانند مشخصه‌های ساختاری جنگل را فقط با اندازه‌گیری چند متغیر پیش‌بینی کنند. سالیان سال است که آنها از مدل‌های تجربی آماری چون تحلیل رگرسیون خطی چندگانه^۱ به‌منظور دستیابی به این رابطه‌ها استفاده می‌کنند (Klobucar & Subasic, 2012). درحالی که تصمیم‌گیری در منابع طبیعی اغلب با پیچیدگی‌های فراتر از روش‌های معمول آماری روبه‌رو می‌شود که به رویکردهای نوینی نیاز دارد. با توسعه سیستم‌های خبره در حل مسئله و تصمیم‌گیری مدیریت منابع طبیعی، شبکه‌های عصبی مصنوعی^۲ نخستین بار در اواسط دهه ۱۹۹۰ میلادی، جایگزین روش‌های تحلیل رگرسیون خطی چندگانه در علوم منابع طبیعی و جنگلداری شدند (Gimblett & Ball, 1995; Lek et al., 1996; Chatal & Saplioglu, 2018). شبکه‌های عصبی مصنوعی، سیستم‌های ریاضی یادگیری غیرخطی هستند که همانند سیستم‌های عصبی بیولوژیکی با استفاده از پردازشگرهایی با توزیع موازی به نام نورون (Haykin, 1999) در حل مسائلی که روش‌های آماری خطی قادر به جوابگویی نیستند، مفید واقع شده‌اند. از متداول‌ترین آنها می‌توان به شبکه عصبی پرسپترون

1. Multiple Linear Regression (MLR)
2. Artificial Neural Network (ANN)
3. feed-forward Multi Layer Perceptron (MLP)
4. Radial Basis Functions (RBF)
5. Support Vector Machine (SVM)
6. Learning Vector Quantization (LVQ)
7. Self-Organizing Map (SOM)
8. Pattern Recognition
9. Data Mining
10. Clustering
11. K-Nearest Neighbors (k-NN)
12. Support Vector Regression
13. Random Forest (RF)

SOM به منظور منطقه‌بندی و برآورد مقدار بارندگی ماهانه در شمال ایران استفاده کردند. آنها از شبکه عصبی SOM برای خوشه‌بندی مناطق و از شبکه عصبی SSOM به منظور برآورد مقدار بارندگی ماهانه استفاده و عملکرد نگاشت خودسازمانده را با مدل پرسپترون چندلایه پیشرو مقایسه کردند و نتیجه گرفتند که در نبود منطقه‌بندی، مدل پرسپترون چندلایه پیشرو عملکرد بهتری از نگاشت خودسازمانده دارد و در صورت منطقه‌بندی، نگاشت خودسازمانده بهتر از پرسپترون چندلایه عمل می‌کند. درباره کاربرد شبکه عصبی SSOM در علوم جنگل در داخل و خارج ایران پژوهشی انجام نگرفته است، بنابراین تحقیق در این زمینه به شدت ضرورت دارد و نتیجه این تحقیق می‌تواند کارایی این روش را نشان دهد و راه را برای معرفی و اجرای پژوهش‌های بیشتر درباره کارایی این روش در زمینه‌های مختلف هموار کند. هدف این پژوهش، مقایسه عملکرد شبکه عصبی SSOM با شبکه عصبی MLP و رگرسیون خطی چندگانه با توجه به معیارهای ارزیابی در برآورد تراکم درختان جنگل‌های سراوان رشت (سری دو کچا) و نیز معرفی مدل (های) کارآمد برای برآورد تراکم درختان در منطقه پژوهش با استفاده از عوامل رویشگاهی است.

مواد و روش‌ها

منطقه پژوهش

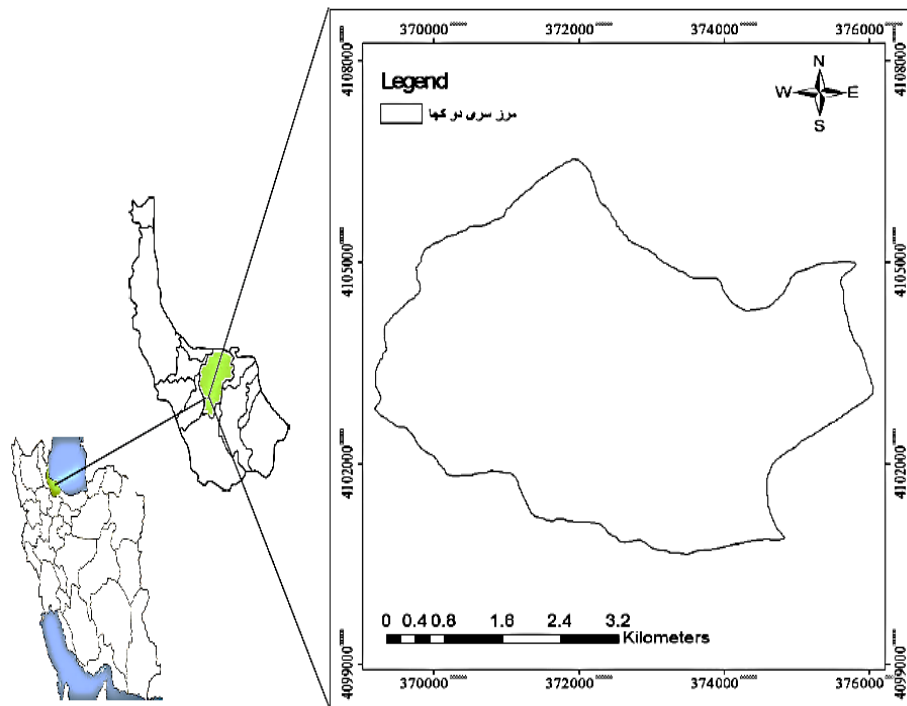
جنگل سراوان در جنوب شهر رشت در استان گیلان، در محدوده طرح جنگلداری سری یک و دو کچا قرار دارد. پژوهش حاضر در سری دو کچا به مساحت ۲۳۹۹ هکتار صورت پذیرفت. این منطقه از نظر مختصات جغرافیایی در $24^{\circ} 32' 49''$ تا $29^{\circ} 35' 49''$ طول شرقی و $37^{\circ} 02' 30''$ و $42^{\circ} 05' 37''$ عرض شمالی واقع شده که از شمال به سری یک کچا، از جنوب به سری‌های سه و چهار سراوان، از غرب به سری مبارک‌آباد (حوزه ۱۷) و از

را با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی چندگانه برآورد کردند. آنها تعداد درخت در هکتار و تاج‌پوشش را متغیر وابسته و اطلاعات خاک‌شناسی، اطلاعات اقلیمی، مشخصه‌های اولیه و ثانویه توپوگرافی و شاخص NDVI را متغیر مستقل در نظر گرفتند. نتایج پژوهش آنها نشان داد که شبکه عصبی مصنوعی در مقایسه با رگرسیون خطی چندگانه، در برآورد تعداد درختان در هکتار و تاج‌پوشش دقت بیشتری دارد. در حالت معمول SOM نوعی الگوی یادگیری بدون نظارت^۱ است، هیچ راه‌حل راه‌حل یا هدفی داده نمی‌شود و شبکه، هوشمندانه با شناسایی الگوهای متفاوت قادر به یادگیری و خوشه‌بندی داده‌ها از فضای پیوسته چندبعدی به فضای گسسته با بُعد کم (به‌طور معمول دو‌بعدی) است (Kohonen, 2001; Kalteh et al., 2008). در این زمینه Kalteh et al. (2008) با مرور کاربردهای شبکه عصبی SOM در منابع آب، بیان کردند که شبکه عصبی SOM در تجزیه و تحلیل، خوشه‌بندی و مدل‌سازی داده‌های مختلف از توان زیادی برخوردار است. نگاشت خودسازمانده نظارت‌شده^۲، مدلی توسعه‌یافته‌تر از SOM است و فقط از نظر ابعاد وزن و الگوریتم تخمین با شبکه عصبی SOM تفاوت دارد. همان‌گونه که در شبکه عصبی SOM، وزن‌ها هم‌بُعد با داده‌های ورودی هستند، در شبکه عصبی SSOM، وزن‌ها هم‌بُعد با متغیر هدف هستند. در شبکه عصبی SOM رقابت بر سر داده‌های ورودی است، در حالی که در شبکه عصبی SSOM رقابت به‌منظور تخمین و کاهش خطای پیش‌بین صورت می‌پذیرد (Keller et al., 2018b). تاکنون Keller et al. (2018a) در زمینه برآورد مشخصه‌های کیفیت آب و Keller et al. (2018b) برای برآورد رطوبت خاک از شبکه عصبی SSOM استفاده کرده‌اند. Kalteh & Berndtsson (2007) از شبکه عصبی

1. Unsupervised Learning
2. Supervised Self Organizing Map (SSOM)

سری (DC) C.A.M.) و خرمنندی (*Parrotia persica*) و خرمنندی (*Diospyros lotus* L.) تشکیل شده است. سری مذکور تا قبل از سال ۱۳۷۲ فاقد هر گونه طرح جنگلداری بود و بیشتر، بهره‌برداری سنتی توسط ساکنان بومی و دامداران منطقه به منظور تهیه چوب سوخت، تهیه زغال، ساختمان‌سازی و غیره صورت می‌گرفت تا اینکه در سال ۱۳۷۲ طرح سری دو کچا توسط کارشناسان فنی اداره منابع طبیعی استان گیلان تهیه و به شرکت تعاونی قیصر کوه واگذار شد (شکل ۱).

شرق به طرح جنگلداری سری یک کچا منتهی شده و در سیستم UTM در زون ۴۰ قرار گرفته است. از نظر اقلیمی، منطقه دارای آب‌وهوای مرطوب با متوسط بارندگی سالانه ۱۲۵۵/۷ میلی‌متر و متوسط دمای سالانه ۱۶ درجه سانتی‌گراد است. منطقه اغلب جنگلی با تیپ خاک قهوه‌ای جنگلی، راندزین دکربناته، قهوه‌ای اسیدی و قهوه‌ای شسته شده است و از گونه‌های درختی چون راش (*Fagus orientalis* Lipsky)، ممرز (*Carpinus betulus* L.)، توسکای بیلاقی (*Alnus subcordata* C.A.M.)، افرا پلت (*Acer velutinum* Boiss.)



شکل ۱- موقعیت منطقه پژوهش در ایران و استان گیلان

در این پژوهش برای تهیه نقشه ارتفاع از سطح دریا، شیب و جهت جغرافیایی از نقشه‌های توپوگرافی با مقیاس ۱:۲۵۰۰۰ با منحنی میزان ۵۰ متر استفاده شد. نقشه طبقات ارتفاعی در چهار طبقه ۲۰۰-۱۵۰، ۴۰۰-۲۰۰، ۶۰۰-۴۰۰ و ۶۵۰-۶۰۰ متر، نقشه طبقات شیب در سه طبقه ۲۰-۱۵، ۳۰-۲۰ و ۴۵-۳۰

شیوه اجرای پژوهش

-تهیه نقشه یگان زیست‌محیطی

به دلیل تغییرات وسیع عوامل مؤثر بر تراکم درختان و نمونه‌برداری‌های دقیق از همه شرایط منطقه، نقشه واحدهای همگن در محیط Arc Map 10.3.1 با تلفیق لایه‌های رقومی تهیه شد.

مشخصه‌های خاک یعنی سنگ مادر، بافت و عمق خاک به چهار زیرواحد اراضی تقسیم و با کدهای (۲-۱-۲)، (۲-۱-۲)، (۲-۲-۲) و (۳-۲-۳) نشان داده شده است (جدول ۱) (Forests, Rangelands & Watershed Management Organization, 2008).

درصد و نقشه جهت‌های اصلی از روی مدل رقومی ارتفاع تهیه شد. با روی هم‌گذاری لایه‌های رقومی، نقشه واحد یا یگان شکل زمین به دست آمد. نقشه تیپ خاک منطقه براساس نقشه‌های ۱:۲۵۰۰۰ تهیه شده به سفارش سازمان جنگل‌ها و مراتع کشور زمین مرجع و رقومی شد که برپایه مهم‌ترین

جدول ۱- شرح زیرواحدهای اراضی در منطقه پژوهش

کد	تیپ خاک	رس (درصد)	سیلت (درصد)	شن (درصد)	عمق خاک (سانتی‌متر)	بافت خاک	pH
۱-۲-۲	راندزین دکربناته	۳۳-۲۱	۳۷-۳۱	۴۲-۳۶	۵۵-۵۰	لومی متوسط تا کمی رسی لومی سنگین	۶/۷-۸/۲
۲-۱-۲	قهوه‌ای اسیدی	۳۵-۲۵	۴۰-۳۳	۴۲-۲۲	۷۵-۵۵	کمی رسی لومی سنگین تا لومی	۵/۵-۷/۹
۲-۲-۲	قهوه‌ای جنگلی	۶۰-۴۶	۴۰-۳۲	۱۴-۸	۹۰-۷۵	رسی سنگین	۷/۷-۳/۴
۳-۲-۳	قهوه‌ای شسته شده	۴۹-۲۸	۳۸-۲۱	۳۴-۲۸	۱۰۰-۹۰	رسی سنگین	۵/۶-۶/۵

برابرسینه درختان بیشتر از ۷/۵ سانتی متری به تفکیک گونه در طبقات قطری مختلف اندازه‌گیری شد و محاسبات لازم براساس روابط (۱ تا ۵) انجام گرفت.

$$\bar{x} = \frac{\sum x_i}{n} \quad \text{رابطه ۱}$$

$$s_x = \sqrt{\frac{\sum x_i^2 - \frac{(\sum x_i)^2}{n}}{n-1}} \quad \text{رابطه ۲}$$

$$s_{\bar{x}} = \pm \frac{s_x}{\sqrt{n}} \quad \text{رابطه ۳}$$

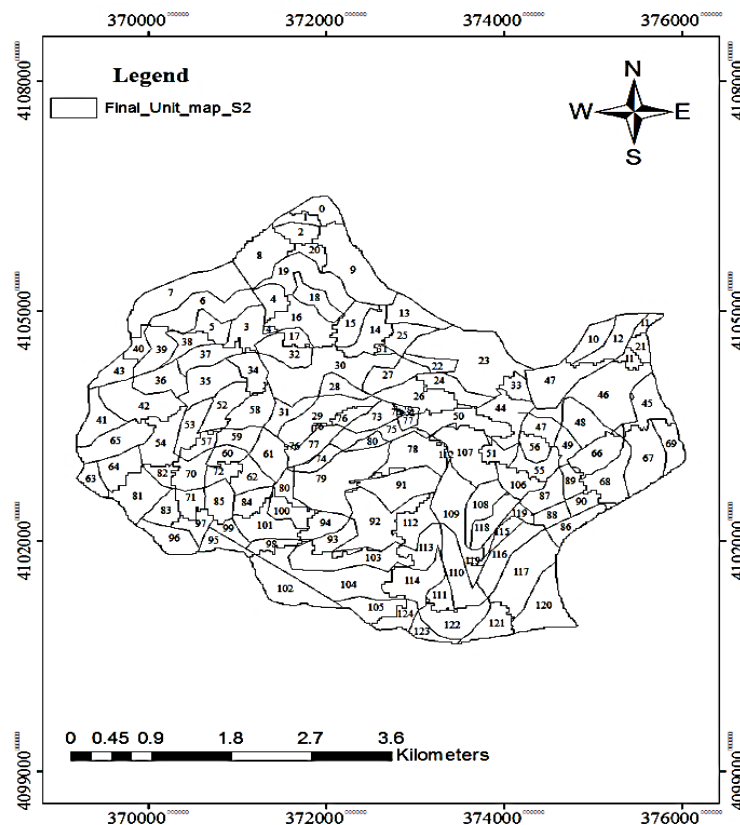
$$E = \pm t \times s_{\bar{x}} \quad \text{رابطه ۴}$$

$$c.v \% = \frac{s_x}{\bar{x}} \times 100 \quad \text{رابطه ۵}$$

در رابطه‌های ۱ تا ۵، \bar{x} میانگین مشخصه مورد بررسی، x_i مشخصه مورد بررسی، n تعداد قطعه نمونه، s_x انحراف از معیار، $s_{\bar{x}}$ اشتباه از معیار، E خطای آماربرداری و $c.v \%$ درصد ضریب تغییرات است.

در گام بعدی نقشه یگان شکل زمین با نقشه رستری خاک در محیط GIS تلفیق شد و نقشه واحد شکل زمین پایه یک به دست آمد. همین مراحل برای نقشه رستری فاصله از جاده و فاصله از آبراهه تکرار شد و در نهایت نقشه واحد یا یگان شکل زیست‌محیطی نهایی با ۱۲۴ واحد همگن به دست آمد که بیشترین سطح منطقه را واحد همگن (۲۳) به مساحت ۶۶ هکتار تشکیل داده است (شکل ۲).

به منظور تعیین تعداد قطعه نمونه به منظور دستیابی به حداکثر دقت و کمترین خطا در آماربرداری از رابطه $n = \frac{t^2 \times \%Sx^2}{\%E^2}$ استفاده شد که در آن n تعداد قطعه نمونه، $\%Sx$ درصد انحراف معیار و $\%E$ درصد دقت آماربرداری است و t براساس تعداد قطعه نمونه و سطح احتمال از جدول t-student به دست آمد. بدین ترتیب نمونه برداری به روش تصادفی سیستماتیک با ابعاد شبکه 200×150 متر در قطعه نمونه‌های دایره‌ای به مساحت ۰/۱ هکتار با شدت آماربرداری ۳/۳ درصد پیاده شد. در کل ۷۷۹ قطعه نمونه به دست آمد در هر قطعه نمونه قطر



شکل ۲- نقشه نهایی زیست‌محیطی با ۱۲۴ واحد همگن

فاصله اقلیدسی (d) است (رابطه ۶) (Kalteh & Hjorth, 2008).

$$d_j = \left[\sum_{i=1}^m (x_i(t) - w_{ij})^2 \right]^{0.5} \quad \text{رابطه ۶}$$

$i=1, \dots, m; j=1, \dots, n$

در رابطه ۶، m تعداد متغیرهای ورودی، n تعداد نورون‌ها در لایه کوهون، w_{ij} نشان‌دهنده بردار وزن اتصالی بین بردار ورودی i و نورون j در لایه کوهون است.

بردار وزن BMU و توپولوژی نورون‌های همسایه به‌گونه‌ای به‌روزرسانی می‌شوند که الگوی ورودی را دوباره تولید کنند. متداول‌ترین تابع همسایه استفاده‌شده تابع گوسی است (رابطه ۷) (Kalteh et al., 2007).

$$N_{j^*j}(t) = e^{-\frac{\|r_{j^*} - r_j\|^2}{2\delta^2(t)}} \quad \text{رابطه ۷}$$

شبکه عصبی نگاشت خودسازمانده

شبکه عصبی SOM متشکل از یک لایه ورودی و یک لایه خروجی است که بردار وزن نورون‌های لایه ورودی به همه نورون‌های لایه خروجی (لایه رقابتی یا کوهون) متصل است (w_{ij}). ابتدای آموزش، بردار وزن (بردار کد کتاب یا بردار مرجع) با یک مقدار اولیه تصادفی تنظیم می‌شود. SOM با استفاده از روش یادگیری رقابتی بدون ناظر یا نگاشت خودسازمانده، الگوی ورودی ماتریس داده‌ها $X(t)$ را با هر یک از بردارهای وزن نورون SOM مقایسه می‌کند. نورونی که کمترین فاصله (d_j) را با الگوی ورودی داشته باشد، به‌عنوان نورون برنده، بهترین واحد تطبیق^۱ یا winner takes all شناخته می‌شود. رایج‌ترین معیار مورد استفاده برای پیدا کردن نورون برنده،

1. Best Matching Unit (BMU)

خروجی در تکرار t است.

- شبکه عصبی نگاشت خودسازمانده نظارت شده (SSOM)

مرحله آموزش شبکه عصبی SSOM (مقداردهی اولیه به صورت تصادفی، انتخاب نورون برنده با متغیرهای ورودی، محاسبه تابع همسایگی و نرخ یادگیری) مشابه شبکه عصبی SOM است و فقط در مرحله به روزرسانی وزن‌ها به جای متغیرهای ورودی از متغیر خروجی، وابسته یا هدف استفاده می‌کند (Riese et al., 2020) (شکل ۳). در این پژوهش برای اجرای این الگوریتم از جعبه ابزار MATLAB SOM ارائه شده توسط دانشگاه صنعتی هلسینکی استفاده شد (Vesanto et al., 2000).

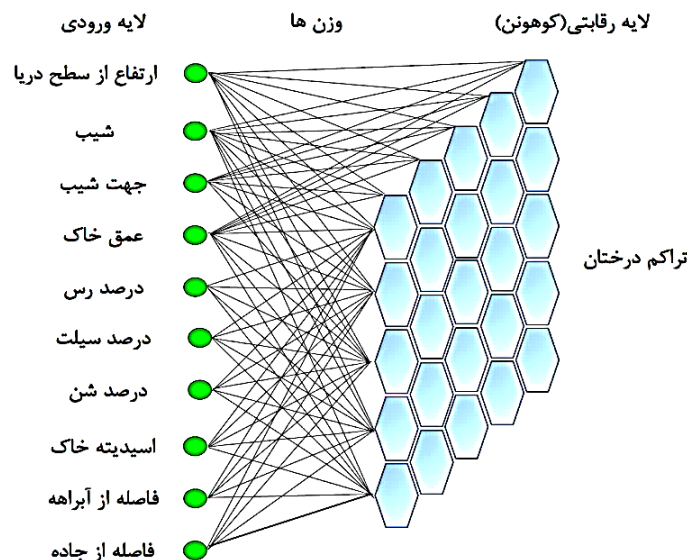
در رابطه ۷، $N_{j^*j}(t)$ تابع همسایگی (گوسی) نورون برنده j^* در تکرار t ، δ^2 شعاع همسایگی در تکرار t ، $\|r_{j^*} - r_j\|$ فاصله بین نورون برنده و نورون همسایه j است.

در نهایت بردار وزن نورون برنده و همسایگان منتخب آن با توجه به فاصله آنها از نورون برنده به روزرسانی شده و وزن‌های جدید با استفاده از رابطه ۸ محاسبه می‌شود (Demirci et al., 2013).

رابطه ۸

$$W_{ij}(t+1) = w_{ij}(t) + \eta(t) N_{j^*j}(t) (x_i(t) - w_{ij}(t))$$

که در آن $\eta(t)$ نرخ یادگیری در تکرار t ، $N_{j^*j}(t)$ تابع همسایگی نورون برنده j^* در تکرار t ، $w_{ij}(t)$ وزن بین نورون i در لایه ورودی و نورون j در لایه



شکل ۳- نمونه‌ای از ساختار شبکه عصبی مصنوعی SSOM (۵×۵)

متغیر خروجی است. همچنین یک نورون بایاس در هر یک از لایه‌های پنهان و خروجی وجود دارد. شبکه عصبی پس‌انتشار خطا^۲ متداول‌ترین الگوریتم یادگیری شبکه عصبی پیشخور چندلایه است که


- شبکه عصبی پرسپترون چندلایه

این شبکه متشکل از یک لایه ورودی است که در آن تعداد نورون‌ها برابر با تعداد متغیرهای ورودی است، یک یا چند لایه پنهان که در آن تعداد نورون‌ها به طور معمول با روش سعی و خطا انتخاب می‌شود و یک لایه خروجی که تعداد نورون‌های آن برابر با تعداد

1. Supervised Self Organizing Map (SSOM)
2. Back Propagation (BP)

محاسبه مقدار خطا، وزن‌ها و انحراف‌ها از طریق الگوریتم پس‌انتشار خطا به‌روزرسانی و تا زمان همگرایی تکرار می‌شود (شکل ۴) (Dawson & Wilby, 2001).

الگوهای ورودی به‌صورت لایه‌هایی از نورون‌ها وارد شبکه عصبی می‌شوند. مسیر حرکت همواره رو به جلو، یعنی از لایه ورودی به لایه خروجی است. با مقایسه خروجی شبکه عصبی و خروجی واقعی، مقدار خطا توسط تابع خطا محاسبه می‌شود. پس از



شکل ۴- نمونه‌ای از ساختار شبکه عصبی مصنوعی MLP

فیزیوگرافی (ارتفاع از سطح دریا، شیب، جهت و فاصله از آبراهه)، خصوصیات فیزیکی و شیمیایی خاک (عمق خاک، درصد رس، درصد شن، درصد سیلت و مقدار اسیدیته خاک) و عوامل انسانی (فاصله از جاده) به‌عنوان متغیرهای ورودی و تراکم درختان به‌عنوان متغیر خروجی در نظر گرفته شدند. برای افزایش سرعت و دقت فرایندهای شبکه عصبی، داده‌ها طبق رابطه ۹ نرمال شدند و بین بازه صفر و یک قرار گرفتند (Kaltch & Hjorth, 2008).

$$Z = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad \text{رابطه ۹}$$

در رابطه ۹، Z داده نرمال‌شده، X_i داده مورد استفاده و X_{max} و X_{min} به ترتیب حداکثر و حداقل داده‌ها در هر یک از متغیرهاست. پس از

رگرسیون خطی چندگانه

برای ایجاد رابطه خطی بین چند متغیر مستقل (متغیر پیشگو یا پیش‌بین) با یک متغیر وابسته از رگرسیون خطی چندگانه استفاده می‌شود که برای محاسبه آن روش‌هایی وجود دارد. یکی از این روش‌ها، رگرسیون گام‌به‌گام است. در هر گام، یک متغیر به مجموعه متغیرهای توضیحی به‌طور خودکار اضافه یا از آن کم می‌شود. این کار تا زمانی ادامه می‌یابد که معنی‌داری متغیرها به ۹۵ درصد برسد (Rawlings et al., 1932).

مدل‌سازی تراکم درختان با استفاده از

شبکه‌های عصبی مصنوعی

برای مدل‌سازی تراکم درختان با استفاده از شبکه‌های عصبی مصنوعی SSOM و MLP، عوامل

بیشتری دارند در صورتی که ضریب تعیین فرض می‌کند که همه متغیرهای مستقل برای توضیح تغییرات متغیر وابسته لازم و ضروری است از این‌رو، ضریب تبیین معیار مناسبی برای تبیین میزان تاثیر متغیر مستقل بر متغیر وابسته نیست. هرچه اختلاف بین مقادیر R^2 و R_{adj}^2 کمتر باشد، بیانگر این است که متغیرهای مستقل به درستی انتخاب شده‌اند (رابطه ۱۱) (Cameron & Windmeijer, 1997)

$$R_{adj}^2 = 1 - \frac{(n-1) \sum_{i=1}^n (p_i - o_i)^2}{(n-p) \sum_{i=1}^n (p_i - \bar{p})^2} \quad \text{رابطه ۱۱}$$

مجذور میانگین مربعات خطا

مجذور میانگین مربعات خطا دقت مدل را بر اساس تفاضل بین مقادیر واقعی و مقادیر برآورد شده ارزیابی می‌کند و هرچه مقدار آن کمتر و صفر به نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است (رابطه ۱۲) (Hyndman & Koehler, 2006).

$$RMSE = \left[\frac{\sum_{i=1}^n (p_i - o_i)^2}{n} \right]^{0.5} \quad \text{رابطه ۱۲}$$

درصد مجذور میانگین مربعات خطا

درصد مجذور میانگین مربعات خطا از تقسیم مجذور میانگین مربعات خطا بر مقادیر متوسط واقعی و ضرب آن در عدد ۱۰۰، برحسب درصد به‌دست می‌آید (رابطه ۱۳).

$$RMSE\% = \frac{RMSE}{\bar{p}} \times 100 \quad \text{رابطه ۱۳}$$

میانگین قدر مطلق خطا

مقدار میانگین قدر مطلق خطا از صفر تا بی‌نهایت تغییر می‌کند هر چه مقدار میانگین قدر مطلق خطا کمتر و به صفر نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است (رابطه ۱۴) (Pontius et al., 2008).

$$MAE = \frac{\sum_{i=1}^n |o_i - p_i|}{n} \quad \text{رابطه ۱۴}$$

نرمال‌سازی، ۷۰ درصد نمونه‌ها به مجموعه داده‌های آموزشی (۸۷ واحد همگن) و ۳۰ درصد باقی‌مانده به داده‌های اعتبارسنجی (۳۷ واحد همگن) اختصاص یافت (Maier et al., 2010).

مدل‌سازی تراکم درختان با استفاده از روش رگرسیون خطی چندگانه (گام‌به‌گام)

مدل‌سازی تراکم درختان با استفاده از روش MLR در محیط نرم‌افزار IBM SPSS 22 و به کمک متغیرهای فیزیوگرافی، خاکی و انسانی (متغیرهای مستقل) صورت پذیرفت که پس از نرمال‌سازی نمونه‌ها، ۷۰ درصد آنها (۸۷ واحد همگن) به‌منظور مدل‌سازی و ۳۰ درصد باقی‌مانده (۳۷ واحد همگن) برای اعتبارسنجی استفاده شد.

معیارهای ارزیابی

برای ارزیابی عملکرد مدل‌ها از ضریب تعیین (R^2)، ضریب تعیین تعدیل‌شده (R_{adj}^2)، مجذور میانگین مربعات خطا (RMSE)، درصد مجذور میانگین مربعات خطا (RMSE%)، میانگین قدر مطلق خطا (MAE)، مقدار اریبی (Bias) و درصد اریبی (Bias%) استفاده شد.

ضریب تعیین

ضریب تعیین نشان‌دهنده مقدار همبستگی بین مقادیر برآوردی توسط مدل و مقادیر واقعی است. مقدار این ضریب همواره بین صفر و یک قرار دارد و عدد یک بیانگر این است که مدل داده‌ها را به خوبی برآزش کرده‌است (رابطه ۱۰) (Cameron & Windmeijer, 1997).

$$R^2 = 1 - \frac{\sum_{i=1}^n (p_i - o_i)^2}{\sum_{i=1}^n (p_i - \bar{p})^2} \quad \text{رابطه ۱۰}$$

ضریب تعیین تعدیل‌شده

ضریب تبیین تعدیل‌شده، تنها متغیرهایی وارد مدل می‌شوند که واقعاً در توضیح متغیر وابسته سهم

مقدار اریب

از این تعداد، ۲۲/۲۳ درصد آن متعلق به طبقه قطری ۱۵ سانتی‌متر و ۰/۰۳ درصد متعلق به طبقه قطری ۱۱۵ سانتی‌متر است (جدول ۲).

آماره‌های میانگین، انحراف معیار، اشتباه معیار، درصد اشتباه آماربرداری و درصد ضریب تغییرات برای مشخصه مورد اندازه‌گیری در روش نمونه‌برداری محاسبه شد. نتایج نشان داد که متوسط تراکم درختان با ۴/۴ درصد اشتباه آماربرداری برابر ۲۸۳/۷۷ است. نتایج دیگر آماره‌ها در جدول ۳ نمایان است.

مطابق منحنی پراکنش درختان در طبقات قطری مختلف (شکل ۵)، جنگل تحت بررسی دارای ساختار ناهمسال و منظم است که با افزایش طبقات قطری از تراکم درختان کاسته می‌شود.

شکل ۶ وضعیت واحدهای همگن و متوسط تراکم درختان در واحدهای همگن مختلف را نشان می‌دهد. همان‌طور که نمایان است در بیشتر واحدها تراکم درختان بین ۲۰۰ تا ۳۰۰ تعداد در هکتار است که بیشترین تراکم درختان (۶۸۴ تعداد در هکتار) متعلق به واحد همگن شماره (۲۳) با ویژگی درصد شیب ۳۰-۲۰، جهت شمالی، ارتفاع از سطح دریا ۴۰۰-۲۰۰ متر، تیپ خاک قهوه‌ای جنگلی، بافت خاک رسی سنگین، pH خاک قلیایی و حداکثر عمق خاک ۷۵ سانتی‌متر است که در فاصله ۷۰۰-۲۰۰ متری آبراهه‌ها و ۶۰۰-۴۰۰ متری جاده‌ها قرار دارند در مقابل کمترین تراکم درختان (۱۱۰ تعداد در هکتار) مربوط به واحد همگن شماره (۸۰) با ویژگی درصد شیب ۲۰-۱۰، جهت جنوبی، ارتفاع از سطح دریا ۲۰۰-۱۰۰ متر، تیپ خاک راندزین دکربناته، بافت خاک لومی متوسط تا کمی لومی رس سنگین، pH خاک اسیدی، حداکثر عمق خاک ۵۰ سانتی‌متر است که در فاصله ۱۳۰۰-۷۰۰ متری آبراهه‌ها و ۲۰۰-۰ متری جاده‌ها واقع شده‌اند.

مقدار اریب ابزار و معیاری برای نشان دادن این است که مقادیر برآوردی تا چه اندازه‌ای به مقادیر واقعی نزدیک‌تر هستند. مقدار اریبی زمانی صفر است که مقادیر متوسط برآوردی حاصل با مقادیر واقعی تقریباً برابر شود (رابطه ۱۵) (Hardy, 2003).

$$\text{رابطه ۱۵} \quad \text{Bias} = \frac{\sum_{i=1}^n (O_i - P_i)^2}{n}$$

درصد اریب

درصد اریب از تقسیم مقادیر اریب بر مقادیر متوسط واقعی و ضرب آن در عدد ۱۰۰، عدد نهایی برحسب درصد به دست می‌آید (رابطه ۱۶).

$$\text{رابطه ۱۶} \quad \text{Bias\%} = \frac{\text{Bias}}{\bar{p}} \times 100$$

در رابطه‌های فوق P_i مقادیر واقعی، \bar{p} مقادیر متوسط واقعی، O_i مقادیر برآوردی، \bar{O} مقادیر متوسط برآوردی، n تعداد داده‌ها و p تعداد مشخصه‌های مدل است.

نتایج

-آمار توصیفی مشخصه تراکم درختان

نتایج آماربرداری در ۷۷۹ قطعه نمونه نشان داد که منطقه پژوهش در کل از ۲۲۱۰۶ اصله درخت با گونه‌های مختلف چون راش (*Fagus orientalis*)، ممرز (*Carpinus betulus* L.)، خرمندی (*Lipsky Parrotia persica*)، انجیلی (*Diospyros lotus* L.)، توسکا (*Alnus subcordata* C.A.M. (DC))، لیلکی (*Gleditsia caspica* Desf.)، افرا پلت (*Acer velutinum* Boiss.)، ملج (*Ulmus glabra* Huds.)، بلوط بلندمازو (*Quercus castaneifolia* C.A.M.) کاج (*Pinus taeda* L.) و ون (*Fraxinus excelsior* L.) تشکیل شده است که

جدول ۲- پراکنش تراکم درختان در طبقات قطری ۵ سانتی‌متری در منطقه پژوهش

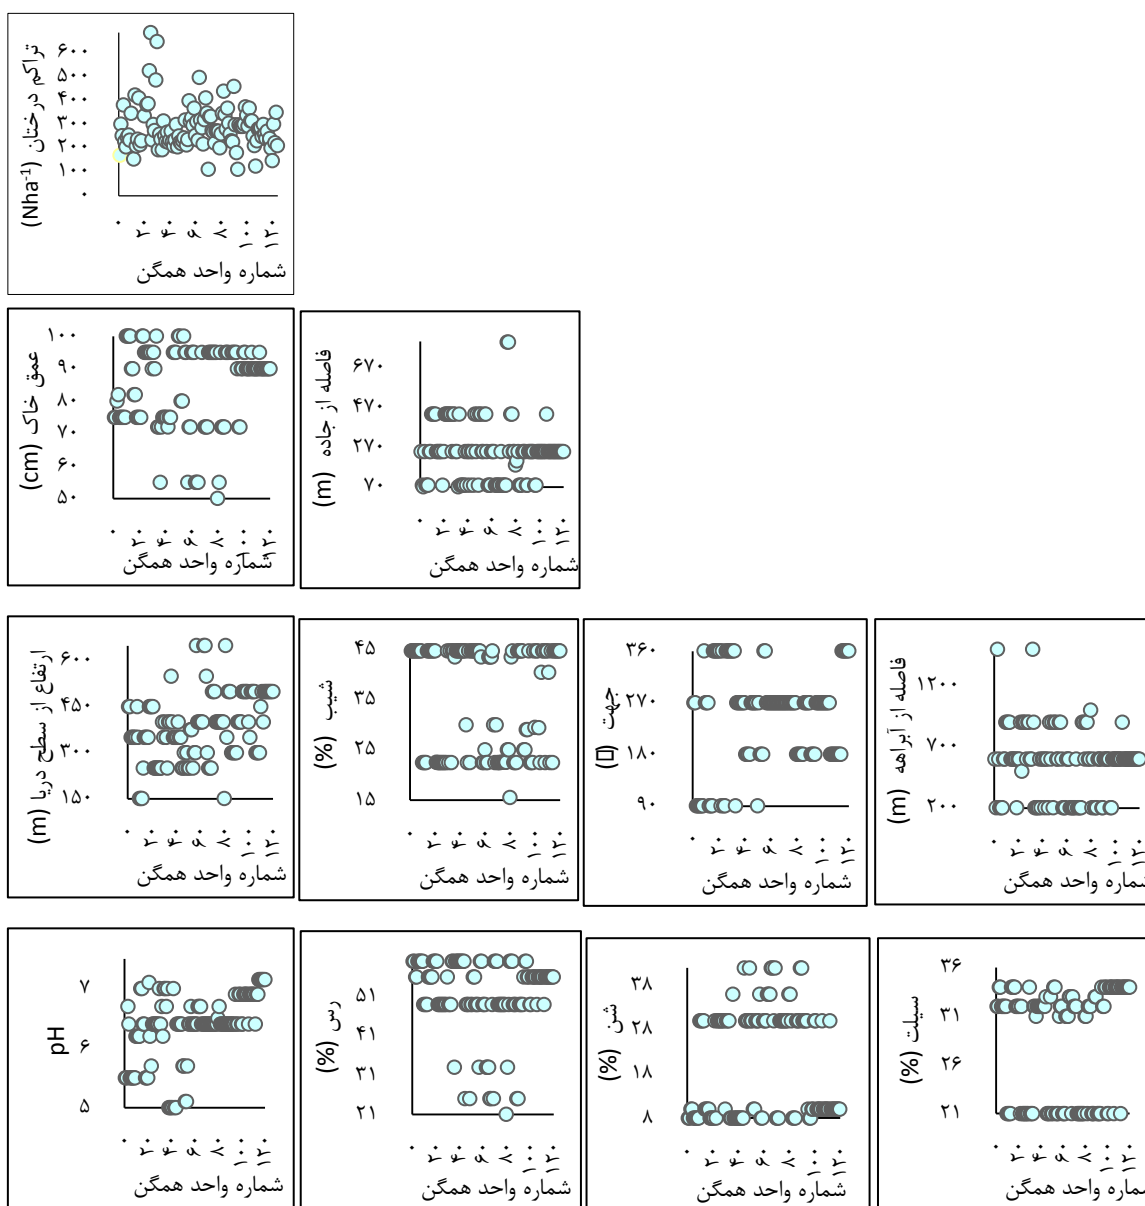
درصد فراوانی	تراکم درختان	جمع	نام گونه										طبقات قطری	
			ون	کاج	بلند مازو	ملج	افرا	لیلکی	توسکا	انجیلی	خرمندی	ممرز		راش
۵/۵۲	۱۵/۶۷	۱۲۲۱	۹	۰	۰	۱	۲	۹	۶۲	۳۲۵	۲۱۰	۹۷	۵۰۶	۱۰
۲۲/۲۳	۶۳/۱۰	۴۹۱۶	۱۹	۱	۰	۶	۶	۲۵	۲۴۷	۱۱۳۳	۱۰۸۸	۵۰۶	۱۸۸۵	۱۵
۱۸/۸۰	۵۳/۳۶	۴۱۵۷	۲۱	۰	۳	۸	۶	۲۶	۲۹۱	۷۳۷	۹۳۳	۶۰۵	۱۵۲۷	۲۰
۱۳/۴۲	۳۸/۰۸	۲۹۶۷	۳۱	۰	۱	۶	۶	۲۶	۳۲۰	۳۴۳	۵۵۸	۵۳۴	۱۱۴۲	۲۵
۱۰/۲۰	۲۸/۹۷	۲۲۵۷	۲۲	۰	۲	۴	۵	۲۶	۳۷۰	۱۷۸	۲۸۰	۵۴۳	۸۲۷	۳۰
۷/۵۸	۲۱/۵۲	۱۶۷۷	۱۴	۲	۲	۳	۲	۱۵	۳۳۰	۹۹	۱۳۶	۴۵۸	۶۱۶	۳۵
۵/۴۵	۱۵/۴۶	۱۲۰۵	۱۷	۱	۲	۴	۶	۵	۳۰۴	۵۴	۹۲	۲۹۲	۴۲۸	۴۰
۳/۸۵	۱۰/۹۴	۸۵۳	۱۱	۲	۳	۱	۳	۵	۲۲۵	۴۱	۴۷	۱۹۴	۳۲۱	۴۵
۳/۵۴	۱۰/۰۶	۷۸۴	۹	۰	۳	۱	۱	۷	۲۰۹	۳۲	۲۵	۱۵۷	۳۴۰	۵۰
۲/۱۹	۶/۲۳	۴۸۶	۳	۱	۴	۰	۳	۳	۱۴۹	۱۵	۱۰	۹۹	۱۹۹	۵۵
۲/۱۸	۶/۲۱	۴۸۴	۲	۲	۳	۰	۱	۱	۱۲۶	۱۷	۵	۱۱۴	۲۱۳	۶۰
۱/۳۸	۳/۹۲	۳۰۶	۶	۰	۱	۰	۱	۳	۸۵	۷	۳	۷۱	۱۲۹	۶۵
۱/۳۰	۳/۶۹	۲۸۸	۲	۰	۰	۰	۱	۱	۶۷	۱۰	۱	۸۲	۱۲۴	۷۰
۰/۸	۲/۲۷	۱۷۷	۰	۰	۱	۰	۰	۱	۵۲	۵	۰	۴۵	۷۲	۷۵
۰/۵۷	۱/۶۳	۱۲۷	۰	۰	۰	۰	۱	۰	۲۸	۵	۱	۴۰	۵۲	۸۰
۰/۲۹	۰/۸۳	۶۵	۰	۰	۰	۰	۰	۰	۱۳	۱	۰	۱۵	۳۶	۸۵
۰/۳۲	۰/۹۲	۷۲	۰	۰	۰	۰	۰	۰	۱۶	۲	۰	۲۲	۳۲	۹۰
۰/۰۸	۰/۲۳	۱۸	۰	۰	۰	۰	۱	۰	۶	۱	۰	۱	۹	۹۵
۰/۰۹	۰/۲۸	۲۲	۰	۰	۰	۰	۰	۰	۱۱	۲	۰	۴	۵	۱۰۰
۰/۰۲	۰/۰۷۷	۶	۰	۰	۰	۰	۰	۰	۲	۰	۰	۱	۳	۱۰۵
۰/۰۴	۰/۱۴	۱۱	۰	۰	۰	۰	۰	۰	۲	۰	۰	۲	۷	۱۱۰
۰/۰۳	۰/۰۸۹	۷	۰	۰	۰	۰	۰	۰	۲	۲	۰	۲	۱	۱۱۵
۱۰۰	۲۸۳/۷۷	۲۲۱۰۶	۱۶۶	۹	۲۵	۳۴	۴۵	۱۵۳	۲۹۱۸	۳۰۰۹	۳۳۸۹	۳۸۸۴	۸۴۷۴	جمع
	۲۸۳/۷۷	۲/۱۳	۰/۱۱	۰/۳۲	۰/۴۳	۰/۵۷	۱/۹۶	۳۷/۴۵	۳۸/۶۲	۴۳/۵۰	۴۹/۷۵	۱۰۸/۷۸		تراکم درختان
	۱۰۰	۰/۷۵	۰/۰۴	۰/۱۱	۰/۱۵	۰/۲۰	۰/۶۹	۱۳/۲۰	۱۳/۶۱	۱۵/۳۳	۱۷/۵۶	۳۸/۳۳		درصد فراوانی

جدول ۳- نتایج آماره‌های تراکم درختان

مشخصه	میانگین	حداقل	حداکثر	انحراف معیار	اشتباه معیار	درصد اشتباه آماربرداری	ضریب تغییرات (%)
تعداد درختان در هکتار	۲۸۳/۷۷	۵۰	۱۵۰۰	۱۷۴/۱۶	۶/۲۴	۴/۴	۶۱/۳۷



شکل ۵- نمودار تراکم درختان گونه‌های مختلف در طبقات قطری مختلف



شکل ۶- بررسی وضعیت واحدهای همگن و متوسط تراکم درختان در واحدهای همگن مختلف

شیب ملایم و متوسط عمق خاک ۸۰ سانتی‌متر است که با توجه به بیشترین ضریب تغییرات عمق خاک، به نظر می‌رسد که این متغیر می‌توانند بیشترین اثرگذاری بر تراکم درختان داشته باشد.

جدول ۴ آمار توصیفی متغیرهای فیزیوگرافی، خاکی و انسانی سری دو کچا را نشان می‌دهد. همان‌طور که نمایان است منطقه تحقیق در ارتفاع ۱۵۰ تا ۶۵۰ متر از سطح دریا واقع شده و دارای

جدول ۴- آمار توصیفی عوامل فیزیوگرافی، خاکی و انسانی در منطقه پژوهش

ارتفاع از سطح دریا (متر)	شیب (درجه)	جهت شیب	عمق خاک (سانتی‌متر)	درصد شن	درصد رس	درصد اسیدیتته خاک	فاصله از آبراهه (متر)	فاصله از جاده (متر)
میانگین	۳۵/۶۱	۲۴۳	۸۰/۲۰	۲۸/۱۷	۴۵/۲۰	۳۱/۴۳	۵۶۱/۲۹	۲۳۹/۶۷
انحراف معیار	۱۱/۸۹	۴۵	۳۵/۰۴	۹/۱۲	۱۶/۰۸	۵/۷۹	۱۹۰/۵۸	۷۶/۸۲
حداقل	۱۵/۵	۹۰	۵۰	۸	۲۱	۲۱	۲۰۰	۷۰
حداکثر	۴۵/۷۲	۳۶۰	۱۰۰	۴۲	۶۰	۴۰	۱۵۰۰	۷۹۶
ضریب تغییرات (درصد)	۳۳/۳۸	۱۸/۵۱	۴۳/۶۹	۳۲/۳۷	۳۵/۵۷	۱۸/۴۲	۳۳/۹۶	۳۲/۰۲

همبستگی بین تراکم درختان با عمق خاک در بیشترین حد است. از طرف دیگر تراکم درختان با درصد رس، فاصله از جاده، ارتفاع از سطح دریا و شیب، همبستگی از نوع معکوس و معنی‌دار دارد که بیشترین همبستگی مربوط به تراکم درختان با درصد رس است. حال آنکه رابطه معنی‌داری بین تراکم درختان با اسیدیتته خاک و جهت شیب مشاهده نشد (جدول ۵).

ضریب همبستگی پیرسون

برای بررسی مقدار و شدت همبستگی هر یک از متغیرهای مستقل (ارتفاع از سطح دریا، شیب، جهت شیب، عمق خاک، درصد شن، درصد رس، اسیدیتته خاک، فاصله از آبراهه و فاصله از جاده) با تراکم درختان از ضریب همبستگی پیرسون استفاده شد. نتایج نشان داد که تراکم درختان با عمق خاک، درصد شن، فاصله از آبراهه‌ها و درصد سیلت همبستگی مستقیم و معنی‌داری دارد و شدت

جدول ۵- ضریب همبستگی پیرسون بین تراکم درختان در هکتار و عوامل فیزیوگرافی، خاکی و انسانی

متغیر وابسته (تعداد درخت در هکتار)	متغیرهای مستقل
-۰/۳۶**	ارتفاع از سطح دریا (متر)
-۰/۳۴**	شیب (درجه)
۰/۰۸۱	جهت شیب
۰/۸۵**	عمق خاک (سانتی‌متر)
۰/۷۴۰**	درصد شن
-۰/۸۹**	درصد رس
۰/۲۳۳*	درصد سیلت
-۰/۵۵۹**	فاصله از آبراهه (متر)
-۰/۴۸۰**	فاصله از جاده (متر)

** معنی‌داری در سطح احتمال ۹۹ درصد، * معنی‌داری در سطح احتمال ۹۵ درصد

احتمال ۹۵ درصد پیش‌بینی کنند ($P = 0/000$) که سهم متغیر درصد رس در پیش‌بینی تراکم درختان به‌مراتب بیشتر از سهم عمق خاک است ($Beta = -0/901$) (جدول ۶).

مدل‌سازی با رگرسیون خطی چندگانه به روش گام‌به‌گام
 نتایج رگرسیون خطی چندگانه به روش گام‌به‌گام نشان داد که دو متغیر درصد رس و عمق خاک توانستند تراکم درختان را به‌صورت معنی‌دار در سطح

جدول ۶- ضرایب مدل رگرسیون خطی چندگانه برای برآورد تراکم درختان

متغیرهای پیش‌بین	ضرایب رگرسیونی غیراستاندارد		ضرایب رگرسیونی استاندارد شده Beta	t	P	R ²	R ² adj
	β	SE					
مقدار ثابت	0/894	0/015		56/785	0/000	0/828	0/8299
درصد رس	-0/901	0/046	-0/910	-19/740	0/000		
مقدار ثابت	0/397	0/120		3/298	0/001	0/858	0/8445
درصد رس	-0/480	0/110	-0/485	-4/383	0/000		
عمق خاک	0/531	-0/128	0/460	4/158	0/000		

معنی‌داری در سطح احتمال ۹۵ درصد

مدل‌ها با توجه به معیارهای ارزیابی نتایج نشان داد که در گام نخست متغیر درصد رس ۷۵/۸۱ درصد از تغییرات تراکم درختان تعیین کرده است در گام دوم با اضافه شدن عمق خاک، مقدار ضریب تعیین تعدیل‌شده به ۶۹/۱۰ درصد رسید (جدول ۷).

به‌منظور مدل‌سازی تراکم درختان با ۳۰ درصد از داده‌هایی که وارد مرحله مدل‌سازی نشده بودند، از ضرایب رگرسیونی استاندارد نشده (β) استفاده شد که در آن Y تراکم درختان و X_1 و X_2 به‌ترتیب متغیر درصد رس و عمق خاک است. با ارزیابی عملکرد

جدول ۷- مدل‌سازی تراکم درختان به روش گام‌به‌گام در مرحله اعتبارسنجی

مدل	معادله	R ²	R ² adj	RMSE	RMSE%	MAE	Bias	Bias%
۱	$Y = 0/894 - 0/901 X_1$	0/7125	0/7581	55/59	20/91	40/58	40/58	15/26
۲	$Y = 0/397 - 0/480 X_1 + 0/531 X_2$	0/6812	0/6910	76/31	28/71	64/50	64/50	24/26

SSOM و تعداد نورون‌های لایه پنهان MLP به‌شرح زیر است:

مدل ۱ با یک متغیر ورودی (ارتفاع از سطح دریا) حاوی ۴×۲ نورون در لایه کوهونن SSOM و ۴ نورون در لایه پنهان MLP.

شبکه‌های عصبی مصنوعی SSOM و MLP
 نتایج مدل‌های مختلف SSOM و MLP برحسب معیارهای ارزیابی مدل در پیش‌بینی تراکم درختان در جدول‌های ۸ و ۹ ارائه شده است. به‌طور خلاصه ساختار شبکه‌های عصبی SSOM و MLP با توجه تعداد و نوع ورودی، تعداد نورون‌های لایه کوهونن

جدول ۸- عملکرد شبکه عصبی SSOM در برآورد تراکم درختان

SSOM									
مدل	ساختار شبکه	مرحله	R ²	R ² adj	MAE	RMSE	RMSE/.	Bias	Bias%
۱	۲ × ۴	آموزش	۰/۷۰۱۲	۰/۷۶۳۴	۴۵/۹۶	۵۸/۷۴	۲۰/۱۰	۲۴/۶۳	۸/۴۳
		اعتبارسنجی	۰/۶۵۹۸	۰/۶۶۹۵	۳۰/۰۸	۵۴/۶۴	۲۰/۵۵	۳۴/۷۴	۱۳/۰۷
۲	۴ × ۷	آموزش	۰/۷۸۲۵	۰/۷۷۳۶	۴۰/۲۱	۴۹/۵۸	۱۶/۹۶	۱۹/۸۹	۶/۸۰
		اعتبارسنجی	۰/۵۴۸۴	۰/۵۲۸۷	۳۵/۸۲	۷۱/۵۱	۲۶/۹۰	۵۴/۶۹	۲۰/۵۷
۳	۷ × ۴	آموزش	۰/۸۶۸۱	۰/۷۸۲۴	۲۷/۷۴	۳۹/۹۲	۱۳/۶۶	۱۸/۱۳	۶/۲۰
		اعتبارسنجی	۰/۷۲۰۲	۰/۷۶۵۵	۲۵/۸۲	۴۸/۹۷	۱۸/۴۲	۳۲/۰۷	۱۲/۰۶
۴	۷ × ۲	آموزش	۰/۸۳۸۶	۰/۸۷۸۹	۳۴/۸۶	۴۳/۷۷	۱۴/۹۸	۱۸/۶۰	۶/۳۶
		اعتبارسنجی	۰/۷۷۴۹	۰/۷۷۷۹	۲۱/۰۴	۳۸/۶۱	۱۴/۵۲	۱۹/۳۱	۷/۲۶
۵	۴ × ۲	آموزش	۰/۹۸۳۲	۰/۸۸۳۹	۲۷/۶۳	۳۷/۹۰	۱۲/۹۷	۱۷/۹۲	۶/۱۳
		اعتبارسنجی	۰/۹۱۱۷	۰/۹۹۰۹	۸/۶۳	۲۴/۳۶	۹/۱۶	۱۱/۳۴	۴/۲۶
۶	۳ × ۴	آموزش	۰/۸۴۸۲	۰/۸۷۸۹	۳۰/۴۰	۴۳/۱۶	۱۴/۷۷	۲۰/۱۱	۶/۸۸
		اعتبارسنجی	۰/۸۴۳۵	۰/۸۷۶۴	۱۳/۵۸	۳۶/۶۶	۱۳/۷۹	۲۷/۸۵	۱۰/۴۷
۷	۴ × ۲	آموزش	۰/۸۳۲۵	۰/۸۷۷۱	۳۵/۲۰	۴۴/۷۲	۱۵/۳۰	۱۹/۳۸	۶/۶۳
		اعتبارسنجی	۰/۷۵۴۸	۰/۷۶۹۳	۲۳/۳۲	۴۳/۴۲	۱۶/۳۳	۱۷/۳۴	۶/۵۲
۸	۴ × ۳	آموزش	۰/۸۴۰۹	۰/۸۷۷۱	۳۴/۱۵	۴۴/۳۷	۱۵/۱۸	۲۰/۶۷	۷/۰۷
		اعتبارسنجی	۰/۷۵۰۳	۰/۷۶۷۲	۲۳/۷۹	۴۴/۱۰	۱۶/۵۹	۲۸/۰۱	۱۰/۵۳

جدول ۹- عملکرد شبکه عصبی MLP در برآورد تراکم درختان

MLP									
مدل	ساختار شبکه	مرحله	R ²	R ² adj	MAE	RMSE	RMSE/.	Bias	Bias%
۱	۱-۴-۱	آموزش	۰/۸۸۳۷	۰/۸۸۶۳	۲۶/۵۱	۳۵/۸۴	۱۲/۲۶	۱۳/۳۵	۴/۵۶
		اعتبارسنجی	۰/۷۳۱۲	۰/۷۶۷۴	۲۸/۳۸	۴۰/۰۲	۱۵/۰۵	۳۲/۸۵	۱۲/۳۵
۲	۲-۱۰-۱	آموزش	۰/۷۷۶۳	۰/۷۶۲۲	۴۱/۶۸	۵۰/۳۰	۱۷/۲۱	۲۰/۱۹	۶/۹۱
		اعتبارسنجی	۰/۵۸۱۵	۰/۵۹۲۸	۳۲/۰۷	۶۹/۴۱	۲۶/۱۱	۵۳/۵۰	۲۰/۱۲
۳	۳-۷-۱	آموزش	۰/۷۱۷۹	۰/۷۶۵۴	۴۴/۸۴	۵۶/۳۹	۱۹/۳۰	۲۲/۲۹	۷/۶۲
		اعتبارسنجی	۰/۵۵۰۶	۰/۵۲۷۵	۳۳/۶۹	۷۱/۰۱	۲۶/۷۱	۵۴/۴۲	۲۰/۴۷
۴	۴-۱۱-۱	آموزش	۰/۸۷۰۹	۰/۸۸۳۱	۲۷/۴۸	۳۹/۰۸	۱۳/۳۷	۱۶/۹۹	۵/۸۱
		اعتبارسنجی	۰/۸۳۲۱	۰/۸۷۶۰	۱۵/۵۳	۴۰/۲۶	۱۵/۱۴	۲۹/۱۵	۱۰/۹۶
۵	۵-۷-۱	آموزش	۰/۹۰۴۶	۰/۸۸۷۱	۲۳/۲۲	۳۳/۹۳	۱۱/۶۱	۱۵/۵۵	۵/۳۲
		اعتبارسنجی	۰/۶۶۹۳	۰/۶۶۲۴	۲۹/۷۵	۴۹/۶۴	۱۸/۶۷	۲۹/۶۱	۱۱/۱۴
۶	۶-۹-۱	آموزش	۰/۸۹۰۳	۰/۸۸۴۹	۲۶/۶۰	۳۶/۵۵	۱۲/۵۰	۱۶/۸۸	۵/۷۷
		اعتبارسنجی	۰/۴۳۲۴	۰/۴۹۰۸	۳۸/۵۸	۸۲/۲۸	۳۰/۹۵	۶۵/۰۴	۲۴/۴۷
۷	۷-۱۳-۱	آموزش	۰/۸۹۱۱	۰/۸۸۴۸	۲۶/۴۰	۳۶/۳۸	۱۲/۴۵	۱۶/۷۵	۵/۷۳
		اعتبارسنجی	۰/۵۱۴۴	۰/۵۱۱۸	۳۶/۰۱	۷۳/۶۴	۲۷/۷۰	۵۵/۸۵	۲۱/۰۱
۸	۸-۱۱-۱	آموزش	۰/۹۲۶۵	۰/۹۹۰۴	۱۴/۳۷	۲۹/۰۱	۹/۹۲	۱۱/۸۲	۴/۰۴
		اعتبارسنجی	۰/۶۲۳۵	۰/۶۳۵۱	۳۱/۰۵	۶۲/۰۶	۲۳/۳۳	۴۳/۶۶	۱۶/۴۲

شبکه‌های عصبی مصنوعی در مرحله اعتبارسنجی نتایج نشان داد که شبکه عصبی ۵ SSOM با ساختار (۴×۲) $R^2 = 0/9117$, $R^2_{adj} = 0/9909$, $RMSE\% = 9/16$ با MLP ۴ (Bias% = ۴/۲۶) در مقایسه با شبکه عصبی ۴ MLP با ساختار ۴ نورون در لایه ورودی، ۱۱ نورون در لایه پنهان و ۱ نورون در لایه خروجی ($R^2 = 0/8321$, $RMSE\% = 15/14$, $R^2_{adj} = 0/8760$ = ۱۰/۹۶) (Bias% = ۲۴/۲۶) و مدل رگرسیون خطی چندگانه (۲ MLR) $R^2 = 0/6812$, $R^2_{adj} = 0/6910$, $RMSE\% = 28/71$ (Bias% = ۲۴/۲۶) دارای دقت بیشتر و خطای کمتر است.

شکل ۷ نحوه انطباق مقادیر مشاهده شده و پیش‌بینی شده تراکم درختان در مدل رگرسیون خطی چندگانه و شبکه‌های عصبی ۵ SSOM و ۴ MLP را نشان می‌دهد. همان‌طور که نمایان است، در شبکه عصبی ۵ SSOM مقادیر پیش‌بینی شده تا حد زیادی به مقادیر واقعی نزدیک و بر همدیگر منطبق‌اند، ولی در مدل رگرسیون خطی چندگانه، اختلاف زیادی بین آنها مشاهده می‌شود.

با بررسی دقیق‌تر میانگین مقادیر واقعی و برآوردی تراکم درختان با مدل رگرسیونی خطی چندگانه و شبکه‌های عصبی مصنوعی با استفاده از آزمون تی جفتی مشاهده شد که مقادیر برآوردی تراکم درختان با استفاده از شبکه عصبی ۵ SSOM در سطح احتمال ۹۵ درصد به مقادیر واقعی نزدیک‌تر است، در حالی که این اختلاف در مدل رگرسیونی و شبکه عصبی ۴ MLP در سطح احتمال ۹۵ درصد معنی‌دار است (جدول ۱۰).

مدل ۲ با دو متغیر ورودی (ارتفاع از سطح دریا و شیب) حاوی ۴×۷ نورون در لایه کوهونن SSOM و ۱۰ نورون در لایه پنهان MLP.

مدل ۳ با سه متغیر ورودی (ارتفاع از سطح دریا، شیب و عمق خاک) حاوی ۷×۴ نورون در لایه کوهونن SSOM و ۷ نورون در لایه پنهان MLP.

مدل ۴ با چهار متغیر ورودی (ارتفاع از سطح دریا، شیب، عمق خاک، درصد رس) حاوی ۷×۲ نورون در لایه کوهونن SSOM و ۱۱ نورون در لایه پنهان MLP.

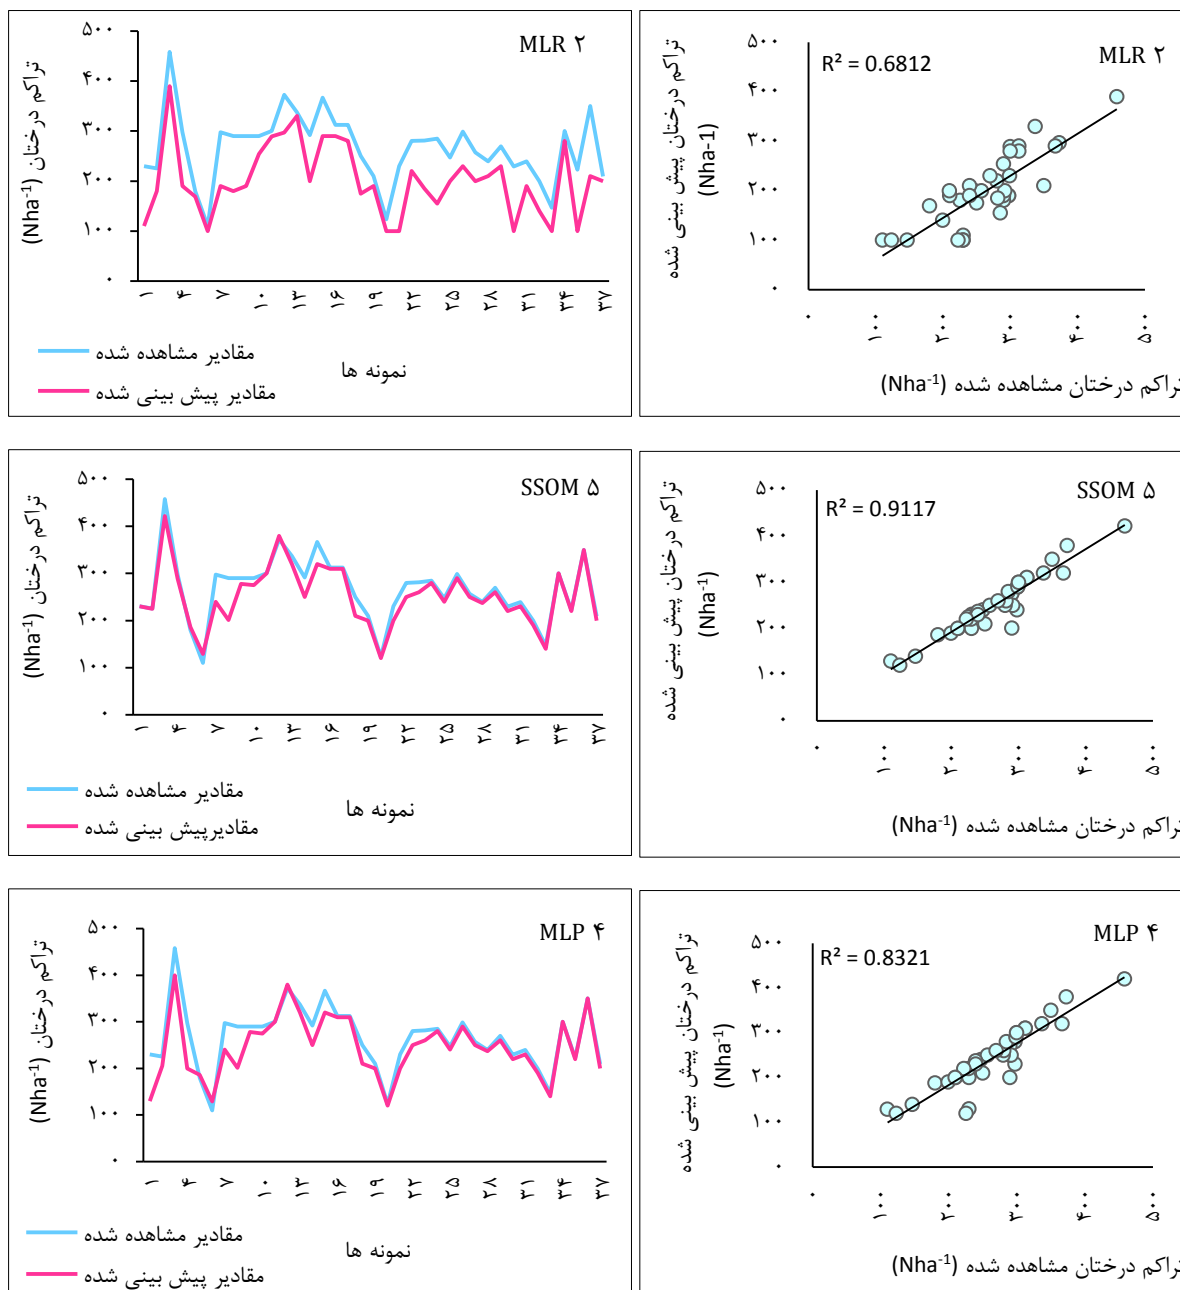
مدل ۵ با پنج متغیر ورودی (ارتفاع از سطح دریا، شیب، عمق خاک، درصد رس و فاصله از آبراهه‌ها) حاوی ۴×۲ نورون در لایه کوهونن SSOM و ۷ نورون در لایه پنهان MLP.

مدل ۶ با شش متغیر ورودی (ارتفاع از سطح دریا، شیب، عمق خاک، درصد رس، فاصله از آبراهه‌ها و فاصله از جاده) حاوی ۳×۴ نورون در لایه کوهونن SSOM و ۹ نورون در لایه پنهان MLP.

مدل ۷ با هفت متغیر ورودی (ارتفاع از سطح دریا، شیب، عمق خاک، درصد رس، فاصله از آبراهه‌ها، فاصله از جاده و درصد شن) حاوی ۴×۲ نورون در لایه کوهونن SSOM و ۱۳ نورون در لایه پنهان MLP.

مدل ۸ با هشت متغیر (ارتفاع از سطح دریا، شیب، عمق خاک، درصد رس، فاصله از آبراهه‌ها، فاصله از جاده، درصد شن و درصد سیلت) حاوی ۴×۳ نورون در لایه کوهونن SSOM و ۱۱ نورون در لایه پنهان MLP.

با مقایسه مدل رگرسیونی خطی چندگانه و



شکل ۷- مقایسه مقادیر مشاهده شده و پیش‌بینی شده تراکم درختان (Nha⁻¹) در مدل رگرسیون خطی چندگانه و شبکه‌های عصبی SSOM ۵ و MLP ۴

جدول ۱۰- مقایسه اختلاف بین میانگین مقادیر واقعی و مقادیر برآورد شده تراکم درختان

اختلاف میانگین‌ها	سطح معنی‌داری	آماره t	میانگین برآوردی	مدل	میانگین واقعی
-۲۹/۷۴	۰/۰۰۸	۲/۶۵	۲۵۴/۰۳	MLR ۲	
-۱۹/۸۶	۰/۰۸	۱/۷۲	۲۶۳/۹۱	SSOM ۵	۲۸۳/۷۷
-۲۳/۴۳	۰/۰۴	۲/۰۱	۲۶۰/۳۴	MLP ۴	

معنی‌داری در سطح خطای ۵ درصد

بحث

هدف از آماربرداری جنگل، آگاهی از وضعیت کمی و کیفی مشخصه‌های ساختاری جنگل است که پایه و اساس برنامه‌ریزی و سیاست جنگل را تشکیل می‌دهد (Fatehi et al., 2017). امروزه برای دستیابی به اطلاعات وسیع در دوره زمانی کوتاه‌تر و بدون صرف هزینه‌های گزاف با تمرکز بر متغیرهای مهم و تأثیرگذار، می‌توان مشخصه‌های ساختاری جنگل را به کمک روش‌هایی، مدل‌سازی و پیش‌بینی کرد (Boncina & Cavlovic, 2009). در این تحقیق، از شبکه‌های عصبی SSOM، MLP برای پیش‌بینی تراکم درختان با استفاده از متغیرهای فیزیوگرافی، خاکی و انسانی استفاده و به مقایسه با مدل رگرسیونی خطی چندگانه پرداخته شد. براساس آمار توصیفی، نتایج داده‌های زمین نشان داد که داده‌ها دارای واریانس و دامنه تغییرات بسیار در منطقه تحت بررسی هستند که نشان می‌دهد قطعات نمونه از دامنه وسیع تراکم درختان ۵۰ تا ۱۵۰۰ اصله در هکتار انتخاب شده‌اند و وجود ضریب تغییرات زیاد عوامل خاکی نسبت به دیگر متغیرها این انتظار را به وجود می‌آورد که مشخصه اندازه‌گیری شده بیشتر تحت تأثیر عمق خاک در منطقه تحقیق است. کما اینکه نتایج حاصل از ضریب همبستگی پیرسون در پژوهش حاضر، مؤید تأثیرپذیرتر بودن تراکم درختان جنگلی از عامل عمق خاک منطقه است. مطابق نتایج پژوهش‌های Kahveci et al. (2017)، Klippel et al. (2017) و Sefidi et al. (2018) نتایج ضریب همبستگی پیرسون پژوهش حاضر نشان داد که تراکم درختان افزون بر عمق خاک تحت تأثیر عوامل توپوگرافی (ارتفاع از سطح دریا و شیب)، فیزیوگرافی (فاصله از آبراهه)، انسانی (فاصله از جاده) و بافت خاک (درصد رس، سیلت و شن) در منطقه پژوهش است. براساس یافته‌های Fatehi et al. (2017) با افزایش ارتفاع از سطح دریا از تراکم درختان به دلیل افزایش رقابت بین درختان برای دسترسی به منابع یعنی دما، آب و مواد

غذایی و صدمات ناشی از شرایط سخت یخبندان، سرما و توفان، کاسته می‌شود. نتایج پژوهش Hassanzad Navroodi & Safarkar (2017) عکس این موضوع را اثبات کرد. آنها بیان کردند که در ارتفاعات بالاتر بر تراکم درختان افزوده می‌شود. Mirzaei Zadeh et al. (2016) نتیجه گرفتند که با افزایش ارتفاع از سطح دریا، شیب تند دره آبراهه‌ها سبب ایجاد فرسایش می‌شود و این فرسایش به نقطه‌ای می‌رسد که درختان ریشه‌کن می‌شوند. نتایج پژوهش Goodarzi et al. (2012) نشان داد که شیب از مهم‌ترین عوامل تأثیرگذار بر مشخصه‌های ساختاری جنگل است که با تأثیر غیرمستقیم بر عمق خاک، بافت خاک، ساختمان خاک و نفوذپذیری خاک، تراکم درختان را تحت تأثیر قرار می‌دهد. مطابق با نتایج پژوهش Jaferyan et al. (2015) بین تراکم درختان و فاصله از آبراهه‌ها ارتباط معنی‌دار و معکوسی وجود دارد و در نتیجه دور شدن از آبراهه‌ها، از تراکم درختان کاسته می‌شود. پژوهش Miriam & Taylor (2010) نشان داد که فاصله از جاده‌ها از دیگر عوامل مؤثر بر تعداد درختان در هکتار است و هرچه فاصله از جاده‌ها بیشتر باشد بر تراکم درختان افزوده می‌شود که همسو با یافته‌های پژوهش حاضر است. با توجه به نتایج پژوهش حاضر به نظر می‌رسد که بین مشخصه ساختاری جنگل با عوامل فیزیوگرافی، خاکی و انسانی روابطی وجود دارد که یکی از اساسی‌ترین روش‌ها برای درک روابط پیچیده، مدل‌سازی است. با وجود کاربردهای وسیع مدل‌های رگرسیونی خطی در علوم کاربردی مانند علوم جنگل (Zaniewski et al., 2002; Horsch, 2003; Claessens et al., 2006; Mirzaei Zadeh et al., 2016)، مقادیر محاسبه‌شده R_{adj}^2 ، $RMSE\%$ و $Bias\%$ پژوهش حاضر نشان داد که مدل رگرسیونی خطی چندگانه تنها با عوامل خاکی (عمق خاک و درصد رس) توانست ۶۹/۱۰ درصد از تغییرات تراکم درختان را تبیین کند، زیرا مدل‌های رگرسیونی خطی

مصنوعی ۴ MLP و ۵ SSOM به ترتیب ۱۸/۵۰ و ۲۹/۹۹ درصد بیش از مدل رگرسیونی خطی چندگانه است که بیانگر انعطاف پذیری و قدرت یادگیری زیاد شبکه‌های عصبی مصنوعی است. نتایج پژوهش حاضر، می‌تواند مکمل نتایج بررسی‌های پیشین در این زمینه باشد. (Ghanbari et al., 2008). در پژوهش خود از دو نوع شبکه عصبی MLP و RBF و مدل رگرسیونی خطی برای برآورد مشخصه تراکم درختان در سری یک جنگل آموزشی و پژوهشی شصت کلاته گرگان استفاده کردند و اعتبارسنجی مدل‌ها نشان داد که شبکه‌های عصبی مصنوعی نسبت به مدل رگرسیونی از دقت بیشتری برخوردار است. (Shataee et al., 2012). در تحقیقی از سه روش یادگیری ماشین SVR, Knn و RF در جنگل‌های سری یک دارابکلا برای پیش‌بینی مشخصه‌های ساختاری جنگل استفاده کردند. آنها در پژوهش خود، توانایی الگوریتم‌های یادگیری ماشین را در برآورد تراکم درختان به اثبات رساندند و نتیجه گرفتند که این سه الگوریتم (KNN, SVR و RF) با RMSE برابر با ۲۶/۸۶، ۲۵/۵۴ و ۲۵/۸۶ درصد، می‌توانند تراکم درختان را پیش‌بینی کنند. نتایج پژوهش (Vafaei et al., 2016). بیانگر قابلیت شبکه عصبی MLP در مقایسه با مدل رگرسیونی در برآورد تراکم درختان با استفاده از داده‌های توپوگرافی، خاک‌شناسی، اقلیمی و اطلاعات سنجش از دوری است. در این زمینه، یافته‌های آنها نشان داد که شبکه عصبی مصنوعی ($R^2 = 0/84$) و ($RMSE = 11/32$) در مقایسه با تحلیل رگرسیون خطی چندگانه ($R^2 = 0/68$ و $RMSE = 15/62$) دقت بیشتری دارد. سرانجام (Yazdani et al., 2020). با مقایسه روش‌های مختلف الگوریتم یادگیری ماشین و مدل رگرسیون در پیش‌بینی مشخصه‌های ساختاری در جنگل تحقیقاتی دکتر بهرام‌نیا به این نتیجه رسیدند که الگوریتم ANN, SVM, kNN عملکرد بهتری از روش آماری رگرسیونی دارد. با وجود همه انواع شبکه‌های عصبی مصنوعی، تعداد و نوع

به دلیل محدودیت‌هایی همچون یکسان بودن واریانس خطا، نرمال بودن متغیرهای وابسته و خطی بودن رابطه بین متغیرهای وابسته و مستقل، قادر به بیان همه تغییرات موجود نیستند، چراکه آنها بیشتر اجازه ورود به متغیرهای بسیار همبسته به منظور افزایش قابلیت مدل‌سازی را می‌دهند، درحالی که برخی متغیرها کمترین همبستگی را با متغیر وابسته دارند، ولی وارد مدل نمی‌شوند (Vieira et al., 2018). نتایج بررسی‌های (Bayat et al., 2020). (Reis et al., 2018) و (Ercanlı et al., 2018) نشان داد که شبکه‌های عصبی مصنوعی به دلیل آموزش، تعمیم‌پذیری و تحمل نویز، قابلیت بسیار خوبی در یافتن لایه‌های پنهان بین متغیرهای وابسته و مستقل دارند. استنباط آماری متغیرهای ورودی به دلیل نبود فرض‌های آماری در شبکه‌های عصبی صورت نمی‌پذیرد، ولی به دلیل آموزش در طول فرایند یادگیری اصلاً نیازی به فرض‌های آماری ندارند (Ferraz Filho et al., 2018). موفقیت شبکه‌های عصبی مصنوعی مختلف در پیش‌بینی مشخصه‌های ساختاری جنگل در چند پژوهش اثبات شده است (Bayat et al., 2013; Bayat et al., 2016; Reis et al., 2016; Özçelik et al., 2017; Ronoud et al., 2019). در پژوهش حاضر، عملکرد شبکه‌های عصبی مصنوعی MLP و SSOM به منظور پیش‌بینی تعداد درختان در هکتار با استفاده از برخی عوامل فیزیوگرافی، خاکی و انسانی بررسی شد. نتایج نشان داد که شبکه عصبی MLP با متغیرهای توپوگرافی (ارتفاع از سطح دریا، شیب) و خاکی (عمق خاک، درصد رس) و شبکه عصبی SSOM با عوامل فیزیوگرافی (ارتفاع از سطح دریا، شیب)، خاکی (عمق خاک، درصد رس) و فیزیوگرافی (فاصله از آبراهه‌ها) به ترتیب می‌توانند بیش از ۸۰ و ۹۰ درصد از تراکم درختان را پیش‌بینی کنند. در مقایسه با مدل رگرسیونی خطی چندگانه از نظر ضریب تبیین تعدیل‌شده، مشاهده شد که دقت شبکه‌های عصبی

پایه شعاعی را در لایه پنهان خود پیدا می‌کند و به علت داشتن دقت بیشتر و قابلیت یادگیری سریع‌تر از شبکه عصبی MLP در حل مسائل مربوط به مجموعه داده‌های بزرگ با تعداد بسیاری ویژگی‌ها از اهمیت زیادی برخوردار است که مؤید یافته‌های پژوهش حاضر است. از این‌رو می‌توان از شبکه عصبی SSOM به‌عنوان روش جایگزین شبکه عصبی پرسپترون چندلایه، به‌منظور برآورد تراکم درختان جنگل‌های شمال ایران استفاده کرد.

سپاسگزاری

از همکاری صمیمانه مدیر کل منابع طبیعی و آبخیزداری استان گیلان و کارشناسان محترم آن اداره کل، به‌ویژه آقای مهندس علیرضا صیادی که تسهیلات لازم برای اجرای عملیات صحرایی را فراهم کردند، بسیار متشکریم.

ورودی‌ها در پژوهش‌های صورت‌گرفته می‌توان اقرار کرد که شبکه‌های عصبی مصنوعی بر مدل‌های رگرسیون خطی برتری دارند. با مقایسه دقت برآورد تراکم درختان با شبکه عصبی ۵ SSOM و ۴ MLP نتایج پژوهش حاضر نشان داد که شبکه عصبی ۵ SSOM، ۱۱/۴۹ درصد دقت بیشتری در مقایسه با شبکه عصبی ۴ MLP دارد. با بررسی دقیق‌تر و استفاده از آزمون آماری تی جفتی، نتایج نشان داد که شبکه عصبی SSOM از نوع رقابتی و نظارتی، در سطح احتمال ۹۵ درصد مقادیری مشابه با مقادیر واقعی دارد که علت آن وجود توابع گوسی است و این ویژگی در شبکه‌های عصبی MLP با توابع سیگموئیدی مشاهده نمی‌شود. (Gil & Johnsson (2010) با مقایسه شبکه عصبی SSOM، RBF و MLP بیان کردند که شبکه عصبی SSOM خصوصیات شبیه به شبکه عصبی تابع پایه شعاعی دارد که به‌طور خودکار تعداد مناسبی از توابع

References

- Amiri, M. (2016). The study of some silvicultural characteristics of an unlogged mixed oriental beech stand in the Golestan Province. *Journal of Plant Research (Iranian Journal of Biology)*, 31(3), 756-768.
- Amiri, M., Mostafa, M., & Rahimi, M. (2019). Distribution mapping of forest types in Ziarat Foresty Plan using parametric and nonparametric algorithm. *Iranian Journal of Forest*, 11(2), 239-254.
- 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, 851-864.
- Bayat, M., Namiranian, M., Omid, M., Rashidi, A., & Babayi, S. (2016). Applicability of artificial neural network for estimating the forest growing stock. *Iranian Journal of Forest and Poplar Research*, 24, 214-226.
- 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(324), 1-19.
- Boncina, A., & Cavlovic, J. (2009). Perspectives of forest management planning: slovenian and croatian experience. *Croatian Journal of Forest Engineering*, 30(1), 77-87.
- Cameron, A.C., & Windmeijer, F.A.G. (1997). An R-squared measure of goodness of fit for some common nonlinear regression models. *Journal of Econometrics*, 77(2), 329-342.

- Chatal, Y., & Saplioglu, K. (2018). Comparison of adaptive neuro-fuzzy inference system, artificial neural networks and non-linear regression for bark volume estimation in brutian pine (*Pinus brutia* ten.). *Applied Ecology and Environmental Research*, 16(2), 2015-2027.
- Claessens, L., Verburg, P.H., Schoorl, J.M., & Veldkamp, A. (2006). Contribution of topographically based landslide hazard modeling to the analysis of the spatial distribution and ecology of kauri (*Agathis australis*). *Landscape Ecology*, 21, 63-76.
- Dawson, C.W., & Wilby, R.L. (2001). Hydrological modelling using artificial neural networks. *Progress in Physical Geography*, 25(1), 80-108.
- Demirci, M., & Baltaci, A. (2013). Prediction of suspended sediment in river using fuzzy logic and multilinear regression approaches. *Neural Computing and Applications*, 23(1), 145-151.
- Ediriweera, S., Danaher, T., & Pathirana, S. (2016). The influence of topographic variation on forest structure in two woody plant communities: A Remote Sensing approach. *Forest Systems*, 25(1), 1-11.
- Ercanlı, I., Günlü, A., Şenyurt, M., & Keleş, S. (2018). Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey. *Forest Ecosystems*, 5 (29), 1-12.
- Fan, C.Y., Fan, P.S., Chan, T.Y., & Chang, S.H. (2012). Using hybrid data mining and machine learning clustering analysis to predict the turnover rate for technology professionals. *Expert Systems with Applications*, 39(10), 8844-8851.
- Fatehi, P., Damm, A., Schaepman, M.E., & Kneubühler, M. (2015). Estimation of alpine forest structural variables from imaging spectrometer data. *Remote Sensing of Environment*, 7, 16315-16338.
- Fatehi, P., Damm, A., Leiterer, R., Pir Bavaghar, M., Schaepman, M.E., & Kneubühler, M. (2017). Tree density and forest productivity in a heterogeneous Alpine Environment: insights from airborne laser scanning and imaging spectroscopy. *Forests*, 8(212), 1-21.
- Ferraz Filho, A.C., Mola-Yudego, B., Ribeiro, A., Scolforo, J.R.S., Loos, R.A., & Scolforo, H.F. (2018). Height-diameter models for eucalyptus sp. plantations in Brazil. *Cerne*, 24, 9-17.
- Forests, Rangelands & Watershed Management Organization. (2008). *Forestry plan of Kacha two region*, Guilan Province: General Department of Natural Resources, 198pp.
- Ghanbari, F., Shataee, Sh., Dehghani, A.A., & Ayoubi, Sh. (2008). Tree Density Estimation of Forests by Terrain Analysis and Artificial Neural Network. *Journal of Wood & Forest Science and Technology*, 16(4), 25-42.
- Gil, D., & Johnsson, M. (2010). Supervised SOM Based Architecture versus Multilayer Perceptron and RBF Networks. Lund University. *Expert Systems with Applications*, 37(6), 4713 - 4718.
- Gimblett, R.H., & Ball, G.L. (1995). Neural network architectures for monitoring and simulating changes in forest resources management. *AI Applications*, 9, 103-123.
- Goodarzi, Gh.R., Sagheb-Talebi, Kh., & Ahmadloo, F. (2012). The study of effective factors on Almond (*Amygdalus scoparia* Spach.) distribution in Markazi province. *Iranian Journal of Forest*, 4(3), 209-220.
- Gorzin, F., Namiranian, M., Omid, M., & Bayat, M. (2018). Comparison between artificial neural network and regression analysis methods to predict and estimate the volume of logging trees in the kheyroud forest of Noshahr. *Forest and Wood Products*, 71(2), 118-126.
- Hardy, M. (2003). An Illuminating Counterexample. *American Mathematical Monthly*, 110 (3), 234-238.

- Hassanzad Navroodi, I., & Safarkar, T. (2017). Study of the altitude effect on abundance and composition of tree regeneration in natural forest stands of Astara. *Journal of Plant Research (Iranian Journal of Biology)*, 31(4), 905-917.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Upper Saddle River, New Jersey, USA: Prentice Hall, 218pp.
- 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.
- Hyndman, R.J., & Koehler, A.B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688.
- Jaferyan, E., Pir Bavaghar, M., & Ghahramani, L. (2015). Determining the most important physiographic factors influencing the distribution of love tree (*Cercis griffithii*) to model the spatial distribution. *Iranian Journal of Forest*, 7(1), 33-44.
- Kahveci, G., Alan, M., & Köse, N. (2018). Distribution of juniper stands and the impact of environmental parameters on growth in the drought-stressed forest-steppe zone of Central Anatolia. *Dendrobiology*, 80, 61-69.
- Kalteh, A.M., & Berndtsson, R. (2007). Interpolating monthly precipitation by selforganizing map (SOM) and multilayer perceptron (MLP). *Hydrological Sciences Journal*, 52(2), 305-317.
- Kalteh, A.M., Hjorth, P., & Berndtsson, R. (2007). Review of the selforganizing map (SOM) approach in water resources: Analysis, modelling and application. *Environmental Modelling & Software*, 23(7), 835-845.
- Kalteh, A.M., & Hjorth, P. (2008). Imputation of missing values in precipitation-runoff process database. *Hydrology Research*, 40, 420-432.
- Keller, S., Maier, P.M., Riese, F.M., Norra, S., Holbach, A., Börsig, N., Wilhelms, A., Moldaenke, C., Zaake, A., & Hinz, S. (2018a). Hyperspectral Data and Machine Learning for Estimating CDOM, Chlorophyll a, Diatoms, Green Algae, and Turbidity. *International Journal of Environmental Research and Public Health*, 15(9), 1-15.
- Keller, S., Riese, F.M., Stötzer, J., Maier, P.M., & Hinz, S. (2018b). Developing a machine learning framework for estimating soil moisture with VNIR hyperspectral data. *Remote Sensing and Spatial Information Sciences*, 4(1), 101-108.
- Klippel, L., Krusic, P.J., Brandes, R., Hartl-Meier, C., Trouet, V., Meko, M., & Esper, J. (2017). High-elevation inter-site differences in Mount Smolikas tree-ring width data. *Dendrochronologia*, 44, 164-173.
- Klobucar, D., & Subasic, M. (2012). Using self-organizing map in the visualization and analysis of forest inventory. *iForest- Biogeosciences and Forestry*, 5, 216-223.
- Kohonen, T. (1990). The self-organizing map. *Proceedings of the Institute of Electrical and Electronics Engineers*, 78(9), 1464-1480.
- Kohonen, T. (2001). *Self-Organizing Maps*, Berlin, Germany: Springer-Verlag, 501pp.
- Lek, S., Delacoste, M., Baran, P., Dimopoulos, I., Lauques, J., & Aulagnier, S. (1996). Application of neural networks to modelling nonlinear relationships in ecology. *Ecological Models*, 90(1), 39-52.
- Liu, Y.C., & Liu, M. (2011). Research of fast SOM clustering for text information. *Expert Systems with Application*, 38(8), 9325-9333.
- Maier, H.R., & Dandy, G.C. (2010). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software*, 15, 101-124.

- Miriam, S.W., & Taylor, V.S. (2010). Modeling social and land-use/land-cover change data to assess drivers of smallholder deforestation in Belize. *Applied Geography*, 30, 1123-1136.
- Mirzaei Zadeh, V., Mahdavi, A. Karmshahi, A., & Akbar Jaefarzadeh, A. (2016). Investigation of the spatial pattern of forest cover changes using logistic regression in Malekshahi. *Journal of Wood & Forest Science and Technology*, 23(3), 45-68.
- Özçelik, R., Diamantopoulou, M.J., Eker, M., & Gürlevik, N. (2017). Artificial neural network models: an alternative approach for reliable above-ground pine-tree biomass prediction. *Forest Science*, 63(3), 291-302.
- Pontius, J.R., Gilmore, R., Olufunmilayo, T., & Hao, C. (2008). Components of information for multiple resolution comparison between maps that share a real variable. *Environmental and Ecological Statistics*, 15(2), 111-142.
- Rastaby, M., Jalilvand, H., & Zandsyry, M. (2013). Evaluation of socio-economic issues allotments Klgchy Zagros forests in this Province. *Natural ecosystems Quarterly*, 3(2), 59-70.
- Rawlings, J.O. (1932). Review of simple regression. In J.O. Rawlings, S.G. Pentula & D.A. Dickey (Eds.). *Applied Regression Analysis: A Research Tool, Second Edition* (pp. 1-36). New York: Springer-Verlag.
- Reis, L.P., Souza, A.L., Mazzei, L., Reis, P.C.M., Leite, H.G., Soares, C.P.B., Torres, C.M.M.E., Silva, L.F., & Ruschel, A.R. (2016). Prognosis on the diameter of individual trees on the eastern region of the amazon using artificial neural networks. *Forest Ecology and Management*, 382, 161-167.
- Reis, L.P., Souza, A.L., Reis, P.C.M., Mazzei, L., Soares, C.P.B., Torres, C.M.M.E., Silva, L.F., Ruschel, A.R., & Rêgo, L.J.S. (2018). Estimation of mortality and survival of individual trees after harvesting wood using artificial neural networks in the amazon rain forest. *Journal of Ecological Engineering*, 112, 140-147.
- Riese, F.M., Keller, S., & Hinz, S. (2020). Supervised and Semi-Supervised SelfOrganizing Maps for Regression and Classification Focusing on Hyperspectral Data. *Remote Sensing*, 12(1), 1-23.
- Ronoud, Gh., Darvish Sefat, A.A., & Fatehi, P. (2019). Beech tree density estimation using sentinel-2 data (case study: Khayroud forest). *SPRS International GeoSpatial Conference, Karaj, Iran*, 12-14.
- Sagheb-Talebi, Kh., Sajedi, T., & Yazdian, F. (2004). *Forests of Iran* (pp. 205-207). Tehran, Iran: Publication of Research Institute of Forests and Rangelands.
- Sefidi, K., Firouzi, Y., Keivan Behju, F., Sharari, M., & Rostamikia, Y. (2018). Quantification of spatial structure of juniper stands in Kandaragh region. *Iranian Journal of Forest*, 10(1), 207-220.
- Shataee, S.H., Kalbi, S., Fallah, A., & Pelz, D. (2012). Forest attribute imputation using machine-learning methods and ASTER data: comparison of k-NN, SVR and random forest regression algorithms. *International Journal of Remote Sensing*, 33(19), 6254-6280.
- Stumer, W., Kenter, B., & Kohl, M. (2010). Spatial interpolation of in situ data by SOM algorithm (neural networks) for the assessment of carbon stock in European forests. *Forest Ecology and Management*, 260(3), 287-293.
- Vafaei, S., Pourhashemi, M., Pirbavaghar, M., & Jafari, E. (2016). Applying artificial neural network and multiple linear regression models forestimation of forest density in Marivan forests. *Iranian Journal of Forest*, 7(4), 539-555.
- Vesanto, J., Himberg, J., Alhoniemi, E., & Parhankangas, J., (2000) . *SOM Toolbox for Matlab 5* (Report 57.A). Finland: Helsinki University of Technology, 1-60.
- Vieira, G.C., De Mendonça, A.R., Da Silva, G.F., Zanetti, S.S., Da Silva, M.M., & Dos Santos, A.R. (2018). Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. *Science of the Total Environment*, 619, 1473-1481.

Yazdani, M., Shataee Jouibary, S.H., Mohammadi, J., & Maghsoudi, Y. (2020). Comparison of different machine learning and regression methods for estimation and mapping of forest stand attributes using ALOS/PALSAR data in complex Hyrcanian forests. *Journal of Applied Remote Sensing*, 14(2), 1-24.

Yu, D.J., Shen, H.B., & Yang, J.Y. (2011). SOMRuler: A Novel Interpretable Transmembrane Helices Predictor. *IEEE Transactions on Nanobiosci*, 10(2), 121–129.

Zaniewski, A.E., Lehmann, A., & Overton, M.J. (2002). Predicting species spatial distributions using presence-only data: a case study of native New Zealand ferns. *Ecological Modeling*, 157, 261-280.



Research Article

Comparison of the Performance of Artificial Neural Networks with Regression Analysis in Estimating the Density of Forest Stands in Saravan, Guilan Province

S. Lotfi asl¹, I. Hassanzad Navroodi^{2*} and A.M. Kalteh³

¹ Ph.D Student, Dept. of Forestry, University Campus, University of Guilan, Rasht, I. R. Iran

² Associate Prof., Dept. of Forestry, Faculty of Natural Resources, University of Guilan, Sowmehsara, I. R. Iran

³ Assistant Prof., Dept. of Rang and Watershed management, Faculty of Natural Resources, University of Guilan, Sowmehsara, I. R. Iran

(Received: 20 March 2020, Accepted: 06 January 2021)

Abstract

Tree density as one of the most important features of forest structural is necessary for management, conservation and reforestation of northern Iran forest. In this research, tree densities were estimated using physiographic, soil and human factors using artificial neural network supervised self-organized, multi-layer perceptron and multiple linear regression model and compared according to their performance evaluation criteria. For this purpose, homogeneous units in GIS environment were prepared. Sampling was performed by random-systematic method with 150×200 m network dimensions and a total of 779 0.1 ha circular shape plots were implemented. By measuring the diameter at breast height of all trees above 7.5 cm, tree density was calculated for each sample plot and homogeneous units. The results showed that SSOM 5 neural network ($R^2 = 0.9117$, $R^2_{adj} = 0.9909$, RMSE% = 9.16, Bias% = 4.26) compared to MLP 4 neural network ($R^2 = 0.8321$, $R^2_{adj} = 0.8760$, RMSE% = 15.14, Bias% = 10.96) and multiple linear regression model ($R^2 = 0.6812$, $R^2_{adj} = 0.6910$, RMSE% = 28.71, Bias% = 24.26) had more accuracy and less error. To select the best model, T- test was performed and the results showed that the neural network, of the competitive and supervisory type, had values similar to the actual values. This is due to Gaussian functions, which are not seen in MLP neural networks with sigmoid functions. Therefore, SSOM neural network can be a suitable alternative to multilayer perceptron neural network in estimating the density of trees in the northern forests of Iran.

keywords: Multi-layer perceptron, Number of trees per hectare, Self - organizing map, Supervised learning, Winning neuron.