

پیش‌بینی پراکنش رویشگاه گونه *Seidlitzia rosmarinus* در مراتع شرق سمنان با استفاده از مدل شبکه عصبی مصنوعی

لیلا خلاصی اهوازی^۱ و محمدعلی زارع چاهوکی^{۲*}

۱- دانشجوی دکتری، دانشکده مرتع و آبخیزداری، دانشگاه کشاورزی و منابع طبیعی گرگان، ایران

۲- نویسنده مسئول، استاد، گروه احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی دانشگاه تهران، کرج، ایران، پست الکترونیک: mzare@ut.ac.ir

تاریخ دریافت: ۹۲/۱۲/۲۲ تاریخ پذیرش: ۹۳/۹/۱۶

چکیده

شبکه عصبی مصنوعی، ساختارهای پردازش اطلاعاتی جدیدی هستند که از روش‌های مخصوص شبکه‌های عصبی بیولوژیک استفاده می‌کنند. هدف از این مطالعه، مدل‌سازی پراکنش گونه *Seidlitzia rosmarinus* در مراتع شمال‌شرق سمنان با استفاده از مدل شبکه عصبی است. بدین منظور برای نمونه‌برداری از پوشش گیاهی در هر تیپ رویشی، ۳ ترانسکت ۷۵۰ متری مستقر و در هر ترانسکت ۱۵ پلات با فواصل ۵۰ متر مستقر شد. نمونه‌برداری از خاک با توجه به مرز تفکیک افق‌ها در منطقه و نوع گیاهان موجود از دو عمق ۰-۲۰ و ۲۰-۸۰ سانتی‌متر انجام شد. برای تهیه نقشه پیش‌بینی پراکنش گونه‌های گیاهی، به فراهم کردن لایه‌های عوامل محیطی مورد استفاده در مدل نیاز است. برای نقشه‌بندی خصوصیات خاک، از روش زمین‌آمار براساس مدل پیش‌بینی بدست‌آمده برای گونه *S. rosmarinus* (روش ANN) استفاده شد. برای اجرای مدل شبکه عصبی، الگوریتم پس‌انتشار خطا با شبکه طراحی شده پرسپترون سه لایه‌ای با ساختار ۱-۱۰-۷ و دارای هفت نرون در لایه ورودی، ده نرون در لایه میانی و یک نرون در لایه خروجی استفاده شد. میزان تطابق نقشه تهیه شده با نقشه واقعیت زمینی نیز با استفاده از ضریب کاپا محاسبه شد که نشان‌دهنده تطابق خیلی خوب بود (ضریب کاپای ۰/۷۲). نتایج نشان داد که گونه *S. rosmarinus* در مناطق با اسیدیته ۸/۳-۸/۱، هدایت الکتریکی ۰/۲۶-۰/۲۲ دسی‌زیمنس بر متر، بافت لومی-شنی و در ارتفاع ۱۶۰۰-۱۷۵۰ متر از سطح دریا پراکنش دارد و با میزان اسیدیته و آهک رابطه مستقیم دارد.

واژه‌های کلیدی: شبکه عصبی مصنوعی، *Seidlitzia rosmarinus*، الگوریتم پس‌انتشار خطا، نقشه واقعیت زمینی، ضریب کاپا.

مقدمه

نیاز به وجود رابطه جبری قابل کشف بین متغیرهای اولیه و ثانویه وجود ندارد. اما در عوض این شبکه‌ها رابطه منطقی بین متغیرها را طی روند یادگیری (training) کشف می‌کنند (Almeida, 2002 و Cross et al., 1995). شبکه‌های هوش مصنوعی به‌ویژه در مواردی که رابطه‌های پیچیده و غیرخطی بین متغیرهای اولیه و ثانویه وجود دارد، قدرت خود را نشان می‌دهند (Robertson et al., 2003). این مدل‌ها با استفاده از هوش مصنوعی، روابط

پژوهش‌های متعددی در مورد مدل‌سازی پیش‌بینی رویشگاه گونه‌های گیاهی انجام شده است. در مدل‌سازی، انتخاب عوامل محیطی و روش مدل‌سازی خیلی مهم است. هدف عمده در مدل‌سازی، تعیین روابط بین متغیرها، انتخاب و تعیین متغیرهای اثرگذار است. روش مناسب برای مدل‌سازی و تحلیل داده‌های اکولوژیکی بسیار حائز اهمیت است. در شبکه‌های عصبی مصنوعی (ANN: Artificial

و (Paola & Schowengerdt, 1995).

در مباحث مدل‌های پیش‌بینی رویشگاه چون هدف تهیه نقشه پیش‌بینی پراکنش گونه گیاهیست، باید عوامل محیطی تأثیرگذار بر پراکنش پوشش گیاهی به صورت نقشه تهیه شود. نقشه هر یک از خصوصیات خاک و پستی و بلندی مؤثر در پراکنش پوشش گیاهی را می‌توان با روش‌های زمین‌آمار و مدل رقومی ارتفاع تهیه کرد. در زمین‌آمار با استفاده از داده‌های یک کمیت در یک نقطه معین با مختصات معلوم، مقدار همان کمیت را می‌توان در نقطه‌ای با مختصات معلوم واقع در درون دامنه‌ای که ساختار فضایی حاکم است، تخمین زد (حسینی پاک، ۱۳۷۷). رابطه عمومی این روش به صورت زیر است:

$$Z^*(x_i) = \sum_{i=1}^n \lambda_i Z(x_i)$$

رابطه ۱

که در آن:

$Z^*(x_i)$ = مقدار برآورده شده؛ λ_i = مقدار وزن‌های نقاط مورد مشاهده؛ $Z(x_i)$ = مقدار مشاهده شده در اطراف نقطه مورد نظر؛ n = تعداد نقاط اندازه گرفته شده و (x_i) = موقعیت نقاط مشاهده شده

مدل‌سازی پراکنش مکانی رویشگاه گونه‌های گیاهی رویکرد پژوهشی نوینی محسوب شده که مطالعاتی در این زمینه اجرا شده است. معمول‌ترین این مدل‌ها، مدل‌های توزیع همبستگی گونه‌ها (SDMs) هستند که روابط بین داده‌های توزیع گونه‌ای و ویژگی‌های محیطی را برای ارزیابی تناسب یک منطقه مشخص برای گونه‌ها مورد ارزیابی قرار می‌دهد. مدل‌ها یک اندازه‌گیری از احتمال حضور یا یک تخمین از تناسب محیطی هستند، که برای تعریف رخداد مکانی گونه‌ها (Graham *et al.*, 2004a; Brambilla *et al.*, 2009; Báez *et al.*, 2012)، اطلاع‌رسانی ممیزی‌ها (Raxworthy *et al.*, 2003) و (Bourg *et al.*, 2005)، ارزیابی تغییرات اقلیم و زیستگاه (Thuiller *et al.*, 2005a; Brambilla *et al.*, 2010a; Fouquet *et al.*, 2010; Elith *et al.*, 2011;

بین متغیرها را هرچقدر هم که پیچیده باشند یاد گرفته و از آن برای پیش‌بینی مقادیر متغیرها استفاده می‌کنند (Anderson, 2003). در حقیقت هدف از ایجاد یک شبکه عصبی نرم‌افزاری ایجاد سازوکاری برای حل مسائل مهندسی با الهام از الگوی رفتاری شبکه‌های بیولوژیک است (Cross *et al.*, 1995). شبکه‌های عصبی مصنوعی دارای ویژگی‌های فراوانی از جمله انطباق‌پذیری، قابلیت یادگیری و تعمیم می‌باشند (Almeida, 2002). البته مدل‌های پیش‌بینی پراکنش پوشش گیاهی براساس تغییرات عوامل محیطی می‌تواند به‌عنوان ابزاری در جهت (۱) ارزیابی حساسیت پوشش گیاهی نسبت به تأثیرات محیطی، (۲) ایجاد پیش‌بینی‌های اساسی برای مقایسه شرایط مشاهده شده و ارزیابی شده الگوهای غیرقابل پیش‌بینی تخریب‌های محیطی، (۳) تأثیرات تغییرات محیطی (مانند تغییرات آب و هوایی) را روی جوامع بوم‌شناختی می‌آزمایند و (۴) در مدل‌سازی رویشگاه گیاهان و زیستگاه حیوانات کاربرد دارند (Cairns, 2001). انواع مختلفی از مدل‌های شبکه عصبی وجود دارد. این مدل‌ها در یک طبقه‌بندی به مدل‌های ایستا (Static) و پویا (Dynamic) طبقه‌بندی می‌شوند. در مدل‌های ایستا (پیشخور: Feed Forward) مسیر پردازش اطلاعات از داده‌ها به ستاده است بدون آنکه بازگشتی در سیستم ارتباطی واحدها وجود داشته باشد. یک طبقه‌بندی دیگر در مورد مدل‌های شبکه عصبی به این صورت است که اگر بردار داده‌ها با بردار ستاده‌ها متفاوت باشند مدل دگرهمراهی (Hetero-association) و چنانچه بردار داده‌ها با بردار ستاده‌ها یکسان باشند، مدل خودهمراهی (Auto-association) نامیده می‌شود (Alemi *et al.*, 1980). هر واحد پردازشگر اطلاعات در لایه‌های میانی و خروجی دو عمل را انجام می‌دهد. ابتدا مجموع حاصل ضرب اطلاعات ورودی و وزن‌های ارتباطی را محاسبه می‌کند، سپس این اطلاعات را توسط توابع تبدیل پردازش کرده و به واحد پردازشگر بعدی ارسال می‌کند. البته شبکه‌های عصبی در بسیاری از مطالعات با کاربرد داده‌های سنجش از دور با موفقیت استفاده شده‌اند (Paola & Schowengerdt, 1993)

اهوازی و همکاران، ۱۳۹۰). همچنین در مطالعه‌ای در مراتع استان قم، کارایی مدل‌های آماری برای پیش‌بینی پراکنش گونه‌های گیاهی مورد ارزیابی قرار گرفت (پیری‌صحراگرد، ۱۳۹۲).

مطالعاتی که از مدل شبکه عصبی (ANN) در پیش‌بینی توزیع گونه‌های گیاهی استفاده کرده‌اند می‌توان به تحقیقاتی همانند Watts و همکاران (۲۰۱۱)؛ Tan و همکاران (۲۰۰۶)؛ Willems و همکاران (۲۰۰۸)؛ Fukuda (۲۰۱۱) و Scrinzi (۲۰۰۷) اشاره کرد.

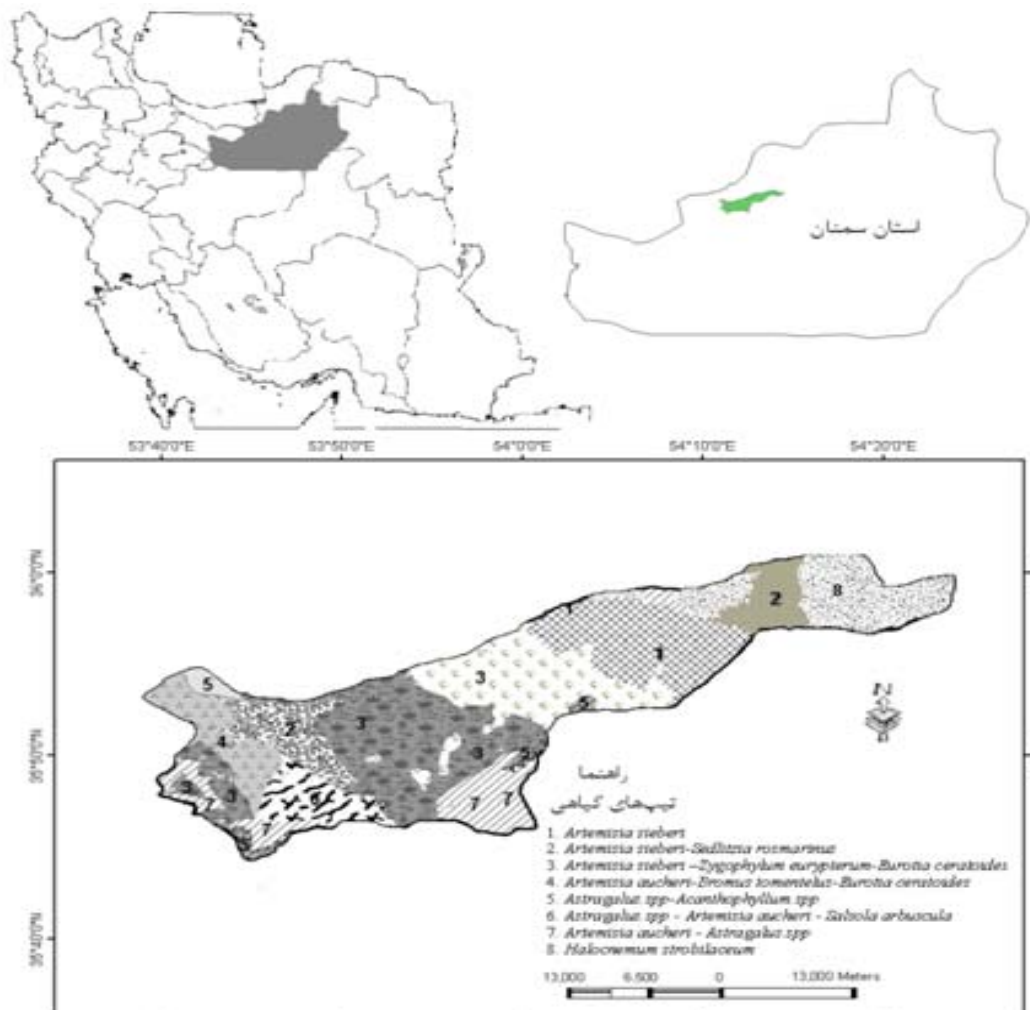
درک پراکنش مکانی گونه‌های گیاهی متضمن درک عوامل اکولوژیک مؤثر بر آنهاست که نقش برجسته‌ای در ارزیابی حفاظت منطقه‌ای و توسعه برنامه‌ریزی دارد. یکی از ابزارهای بالقوه برای تکمیل و رفع کمبود اطلاعات درباره پراکنش و تناسب رویشگاهی گونه‌های شاخص در حفاظت خاک، مدل‌سازی پراکنش این گونه‌ها می‌باشد. در نتیجه هدف این مطالعه مدل‌سازی پراکنش مکانی رویشگاه گونه *Sedlitzia rosmarinus* به‌عنوان گونه مهم در حفاظت خاک مراتع بیابانی با استفاده از مدل شبکه عصبی مصنوعی است.

مواد و روش‌ها

منطقه مورد مطالعه در شمال‌شرقی شهرستان سمنان به مساحت ۷۴۰۰۰ هکتار در مرکز ایران واقع شده است (۳۵ درجه و ۵۳ دقیقه شمالی و ۵۴ درجه و ۲۴ دقیقه شرقی تا ۳۵ درجه و ۵۸ دقیقه شمالی و ۵۳ درجه و ۴۳ دقیقه شرقی). بیشترین ارتفاع منطقه ۲۲۶۰ متر و کمترین آن ۱۱۲۹ متر است (شکل ۱). از نظر اقلیمی نیز براساس پهنه‌بندی اقلیمی دومارتن، منطقه مورد مطالعه دارای اقلیم فراخشک سرد در نزدیکی دامغان و اقلیم خشک سرد در نزدیکی سمنان است.

Chamberlain *et al.*, 2013; Temunovic' *et al.*, 2013; Brambilla & Gobbi, 2014). آزمون فرضیه تکاملی (Peterson *et al.*, 1999; Graham *et al.*, 2004b) Roura-Pascual *et al.*, 2004;) پیش‌بینی گونه‌های مهاجم (Thuiller *et al.*, 2005b; Rödder & Lötters, 2009; Ficaretola *et al.*, 2010; Stiels *et al.*, 2011; Barbet-Massin *et al.*, 2013) و اطلاع‌رسانی برای برنامه‌ریزی حفاظتی (Araújo & Williams, 2000; Rödder *et al.*,) می‌توان استفاده کرد. توزیع کلی یک گونه گیاهی یا جانوری ممکن است از ترکیبی از عوامل در مقیاس‌های مکانی متفاوت نتیجه شود (Brambilla *et al.*, 2010b;) (Hortal *et al.*, 2010) و ممکن است تحت تأثیر واکنش گونه‌ها قرار گیرد (بطور مثال Giannini *et al.*, 2013). در پژوهشی روش‌های آنالیز تشخیص، شبکه‌های عصبی و رگرسیون لجستیک را برای پیش‌بینی توزیع گونه‌های پرنده در منطقه مطالعاتی رودخانه هیمالیان (Himalayan) مقایسه کردند. با استفاده از تحلیل راک (ROC) یا منحنی مشخصه عملی گیرنده (Receiver Operating Characteristic Curve)، اجرای مدل‌ها مقایسه شد و نتایج نشان داد که مدل شبکه عصبی با همبستگی ۸۸ درصد و مدل رگرسیون لجستیک با ۸۳ درصد نتایج بهتری را نشان دادند.

بنابراین از منابع داخلی در این زمینه می‌توان به مطالعه پراکنش مکانی گونه‌های گیاهی در شمال‌شرق سمنان با تعیین ارتباط بین عوامل محیطی و پوشش گیاهی مراتع با استفاده از روش‌هایی همانند مدل شبکه عصبی مصنوعی (ANN)، مدل تحلیل عاملی آشیان بوم‌شناختی (ENFA) و آنالیز تشخیص اشاره کرد (زارع چاهوکی و خلاصی اهوازی، ۲۰۱۲؛ زارع چاهوکی و همکاران، ۲۰۱۲؛ خلاصی



شکل ۱- موقعیت منطقه مورد مطالعه در استان سمنان و کشور ایران

عمق نمونه خاک برداشت شد. علاوه بر حفر پروفیل در ابتدا و انتهای ترانسکت‌ها از آنجا که برای تهیه نقشه خصوصیات خاک لازم است که نمونه‌برداری از خاک طوری انجام شود تا داده‌ها دارای ساختار مکانی مناسب باشند، بنابراین در واحدهای نمونه‌برداری تعداد بیشتری پروفیل حفر شد تا بتوان از اطلاعات آن برای تهیه نقشه استفاده کرد (زارع چاهوکی و همکاران، ۱۳۸۹). در آزمایشگاه خصوصیات خاک شامل سنگریزه، بافت، رطوبت اشباع، رطوبت قابل دسترس، آهک، گچ، ماده آلی، اسیدیته و هدایت الکتریکی اندازه‌گیری شدند. برای ارائه نقشه پیش‌بینی رویشگاه *S. rosmarinus* لازم است که نقشه هریک از عوامل موجود

برای انجام مطالعات میدانی، نقشه واحدهای نمونه‌برداری از تلفیق نقشه‌های شکل زمین و زمین‌شناسی تهیه شد. نمونه‌برداری با روش تصادفی - سیستماتیک از طریق پلات‌گذاری در امتداد ترانسکت انجام شد. برای نمونه‌برداری از خاک در ابتدا و انتهای هر ترانسکت یک پروفیل حفر شد. عمق پروفیل‌ها با توجه به عمق مؤثر ریشه‌دوانی گونه گیاهی بطور متوسط ۸۰ سانتی‌متر انتخاب شد. از آنجا که ریشه گیاهان مرتعی بیشترین فعالیت را در عمق ۲۰-۰ سانتی‌متری دارند (Abd El-Ghani & Wafaa, 2003)، بنابراین این لایه به‌عنوان عمق اول و لایه ۸۰-۲۰ سانتی‌متری به‌عنوان عمق دوم انتخاب گردید و از این دو

در مدل تهیه شود. نقشه ارتفاع از سطح دریا و شیب از نقشه DEM در مقیاس ۱:۵۰۰۰۰ و نقشه‌های خصوصیات خاک با استفاده از روش‌های زمین‌آمار تهیه شدند (Hirzel *et al.*, 2002). در این تحقیق برای بررسی و تشریح ارتباط و ساختار فضایی از تجزیه و تحلیل تغییر نما یا واریوگرام (Variogram) در نرم‌افزار GS⁺ نسخه ۵ استفاده شد (زارع چاهوکی و همکاران، ۱۳۹۰). در این تحلیل، نوع مدل و مقادیر متغیرهای شعاع تأثیر (Range)، آستانه (Sill) و اثر قطعه‌ای (Nugget effect) تعیین شد و با درون‌یابی کریجینگ، نقشه پراکنش خصوصیات خاک در نرم‌افزار Arc GIS نسخه ۹ تهیه شد.

برای تهیه نقشه پراکنش گونه *S. rosmarinus* از مدل شبکه عصبی استفاده شد. برای ساختن یک شبکه جدید نیاز به تعیین نوع شبکه و محدوده داده‌ها از قبیل نوع فایل، تابع آموزش، تابع کارآیی، تعداد لایه‌ها و تابع انتقال است. یکی از مدل‌های مرسوم شبکه‌های عصبی، مدل پیشرونده چند لایه می‌باشد که در این پژوهش نیز استفاده شده است. هنگام کار با شبکه‌های عصبی پیشرونده چند لایه، ۲ مسئله انتخاب معماری مناسب و انتخاب الگوریتم آموزش (Training algorithm) مناسب است؛ که روش آموزش متداول در این شبکه‌ها، پس انتشار است. الگوریتم پس انتشار خطا (Back propagation of error) پرکاربردترین روش آموزش است (Deng *et al.*, 2008). از آنجا که هدف یافتن ارتباط نهفته بین پارامترهای مختلف است، از روش پس انتشار خطا استفاده شد. پس انتشار خطا یک الگوریتم با شیب نزولی است که در آن وزن‌های شبکه در جهت خلاف تابع کارایی (performance function) حرکت می‌کند و بیشترین کاربرد را در حل مسائل فنی مهندسی دارد. داده‌های آزمایش برای اندازه‌گیری میزان موفقیت پیش‌بینی مدل استفاده شدند. برای آموزش شبکه با انتخاب فایل‌های آموزش و تنظیم تعداد تکرارها (epochها) و تعیین میزان یادگیری، شروع به آموزش شبکه کرده و بعد از آن می‌توان شبکه را با داده‌های آزمایشی آزمود. در نهایت می‌توان خطای شبکه (network

errors) و نتایج شبکه (network outputs) را در پایان کار مشاهده کرد. لایه‌های موجود در شبکه عصبی سه نوع زیر هستند:

۱- لایه ورودی (input layer): به تعداد متغیرهای توضیحی مدل، واحدهایی وجود دارند که هر یک از آنها داده‌های مربوط به آن متغیر را شامل می‌شوند. در واقع، مشابه بردار متغیرهای توضیحی در مدل رگرسیون است.

۲- لایه‌های میانی (پنهان: hidden layer): واحدهای پردازشگر اطلاعات در آن قرار دارند که نقش بسیار مؤثری در فرایند یادگیری صحیح مدل ایفا می‌کنند. تعداد این لایه‌ها و واحدهای پردازشگر طوری باید انتخاب شوند که در آموزش و پیش‌بینی، دچار بیش برآزش (Overestimate) و یا حفظ کردن نشوند (Quetglas *et al.*, 2010).

۳- لایه خروجی (Output layer): در این لایه عمل پردازش بر روی اطلاعات ارسال شده از لایه پنهان انجام می‌شود. تعداد واحدهای این لایه به اندازه تعداد متغیرهای درون‌زای مدل می‌باشد.

در نهایت با استفاده از خروجی مدل شبکه عصبی تهیه شده در نرم‌افزار MATLAB، نقشه پیش‌بینی گونه مورد مطالعه با استفاده از نرم‌افزار Arc Map تهیه شد (Zare & Chahouki & Khalasi Ahvazi, 2012). دقت نقشه پیش‌بینی شده با نقشه پوشش گیاهی واقعی با استفاده از آماره کاپا در نرم‌افزار Idris Kilimanjaro ارزیابی شد. بهترین روش اندازه‌گیری توافق بین داده‌های مشاهده شده و داده‌های حضور و غیاب پیش‌بینی شده استفاده از آماره کاپاست (Cohen *et al.*, 1960; Monserud & leemans, 1992; Robertson *et al.*, 2000; Fielding & Bell, 1997; Guison & Zimmermann, 2000; Moisen & Frescino, 2002 و Liu *et al.*, 2005). لازم به ذکر است که مقادیر a ، b ، c و d براساس جدول توافقی ۱ تعیین شد. این شاخص برای اندازه‌گیری میزان توافق بین پیش‌بینی حضور یا عدم حضور گونه‌های گیاهی و واقعیت موجود بکار می‌رود و از رابطه ۲ محاسبه شد.

جدول ۱- محاسبه پارامترهای لازم برای محاسبه شاخص کاپا (زارع چاهوکی، ۱۳۸۵)

پیش‌بینی	واقعی	
	+	-
+	a	b
-	c	d
تعداد نمونه‌ها		n

+: حضور -: عدم حضور

$$K = \frac{(a+b) - [(a+c)(a+b) + (b+d)(c+d)]/n}{n - [(a+c)(a+b) + (b+d)(c+d)]/n}$$

رابطه ۲

مطالعه با استفاده از دو آزمون از این دامنه‌ها برای توصیف توافق ایجاد شده استفاده خواهد شد.

Monserude & Leemans (1992) دامنه توافق برای آماره کاپا را به صورت جدول ۲ پیشنهاد کردند. در این


جدول ۲- دامنه توافق برای آماره کاپا (منسورد و لیمانز، ۱۹۹۲ به نقل از زارع چاهوکی، ۱۳۸۵)

۱	<۰/۰۵	عدم توافق
۲	۰/۰۵-۰/۲	بسیار ضعیف
۳	۰/۲-۰/۴	ضعیف
۴	۰/۴-۰/۵۵	متوسط
۵	۰/۵۵-۰/۷	خوب
۶	۰/۷-۰/۸۵	بسیار خوب
۷	۰/۸۵-۰/۹۹	عالی
۸	۰/۹۹-۱	بسیار عالی
۹	مقادیر منفی	توافق ضعیف


نتایج

تغییرنمای برازش داده شده برای آهک عمق اول آورده شده است و در شکل ۳ نقشه عامل آهک تهیه شده با استفاده از روش کریجینگ در نرم‌افزار Arcmap آورده شده است.

نقشه‌های پراکنش عوامل خاک‌شناسی با استفاده از روش زمین‌آمار کریجینگ تهیه شد. در شکل ۲ مدل



شکل ۲- مدل نیم تغییرنمای (خط) برازش داده شده بر مدل تغییرنمای نقطه برای آهک عمق اول




شکل ۳- نقشه پراکنش درصد آهک با استفاده از روش کریجینگ

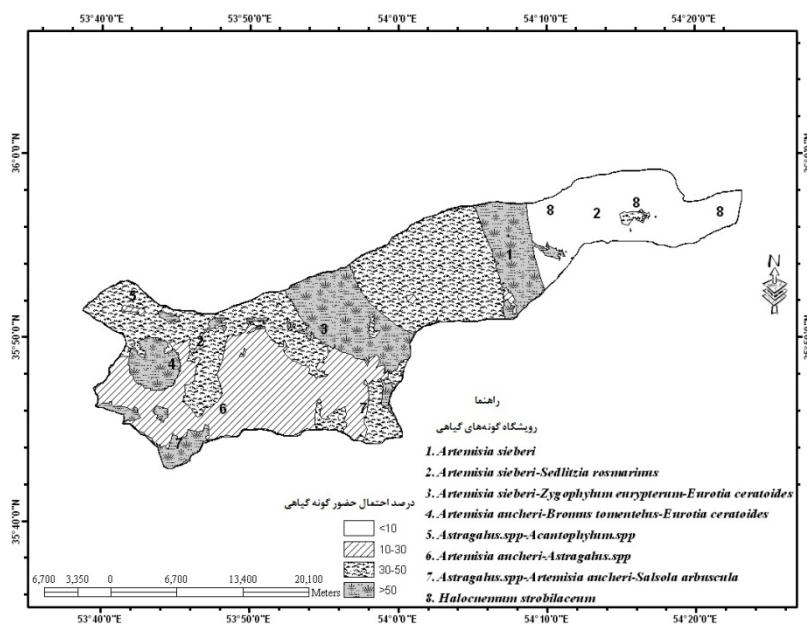
میزان موفقیت پیش‌بینی مدل استفاده شدند. در این شبکه درجه همبستگی (R^2) ۰/۷۲ و درصد خطا ۱۷/۱۹ بود. شکل ۴ ساختار شبکه عصبی مورد استفاده در این پژوهش را نشان می‌دهد.

نقشه پیش‌بینی گونه *S. rosmarinus* در نرم‌افزار Arc Map با استفاده از خروجی و مدل شبکه عصبی تهیه شده در نرم‌افزار MATLAB تهیه شد (شکل ۵).

نوع قاعده آموزشی مومنتم، تابع انتقال تانژانت آکسون، تعداد نرون لایه پنهان و همچنین تعداد عناصر پردازشی لایه مخفی برای شبکه پرسپترون چند لایه مورد آزمایش قرار گرفت. در مدل شبکه عصبی، برای طراحی یک شبکه مطلوب که بهترین نتیجه را بدنبال داشته باشد، از روش آزمون و خطا استفاده شد و پس از بارها تکرار، شبکه مطلوب انتخاب شد و داده‌های آزمایش برای اندازه‌گیری



شکل ۴- ساختار شبکه عصبی مورد استفاده در این پژوهش



شکل ۵- نقشه پیش‌بینی رویشگاه گونه *Seidlitzia rosmarinus* با استفاده از مدل شبکه عصبی مصنوعی (ANN)

مطالعات Mi و همکاران (۲۰۱۰) نشان داد که مدل ANN دارای صحت بالایی است و تحقیقات آنان نشان داد که استفاده از مدل شبکه عصبی مصنوعی کاربردی‌تر از مدل‌های رگرسیونی هستند. همچنین Ozesmi et al (2006) پیشنهاد دادند که مدل‌های شبکه عصبی در مطالعات بوم‌شناختی نتایج قابل توجهی دارد. همچنین مطالعات نشان داد که دو گونه *Artemisia sieberi* و *Zygophyllum eurypterum* گونه‌های همراه گونه *S. rosmarinus* هستند (Zare chahouki et al, 2010 و Ke'ry, 2010).

در این مطالعه برای تهیه لایه‌های محیطی از روش کریجینگ به دلیل دقت بالا استفاده شد که نتایج Jian bing و همکاران (۲۰۰۸) نیز طی مطالعه‌ای که بر روی پراکنش مقدار ماده آلی در خاک‌های شمال شرق چین داشته‌اند به این نتیجه اشاره می‌کند، به طوری که روش کریجینگ معمولی می‌تواند توزیع مکانی ماده آلی خاک را به دقت برآورد کند. همچنین با مقایسه تطابق نقشه خصوصیات خاک با نقشه پیش‌بینی پراکنش گونه *S. rosmarinus* بوسیله آماره کاپا نشان داده شد که رویشگاه *S. rosmarinus* همبستگی بالایی با اسیدیته خاک دارد. نتایج Khalasi Ahvazi و همکاران

در این پژوهش تطابق نقشه تپ پوشش گیاهی و تعیین میزان دقت آن از آماره کاپا در نرم‌افزار Idrisi Kilimanjaro نشان داد که دارای ضریب کاپای ۰/۷۲ و مطابق با جدول ۲، تطابق خیلی خوبی است. خصوصیات محیطی اسیدیته، هدایت الکتریکی، بافت و ارتفاع از سطح دریا بر پراکنش گونه *S. rosmarinus* تأثیرگذار نشان داده شد و تطابق این عوامل تأثیرگذار محیطی با نقشه پیش‌بینی پراکنش گونه مربوطه با آماره کاپا اندازه‌گیری شد و نشان‌دهنده تطابق خوب ($< 0/6$) مقادیر اسیدیته ۸/۳-۸/۱، هدایت الکتریکی ۰/۲۶-۰/۲۲ دسی‌زیمنس بر متر، بافت لومی-شنی و ارتفاع ۱۶۰۰-۱۷۵۰ متر از سطح دریاست.

بحث

نتایج این مطالعه نشان داد که نقشه پیش‌بینی پراکنش گونه *S. rosmarinus* در مقایسه با نقشه واقعیت زمینی با ضریب کاپای ۰/۷۲ دارای صحت خوبی است که نشان‌دهنده قابلیت خوب مدل شبکه عصبی در پیش‌بینی پراکنش گونه *S. rosmarinus* است. نتایج Zare Chahouki et al (2012) نیز این موضوع را تأیید می‌کند. همچنین نتایج

(۲۰۱۱) نیز این موضوع را تأیید می‌کند. در واقع نتایج مدل شبکه عصبی و تطابق نقشه خصوصیات محیطی تأثیرگذار با نقشه پیش‌بینی پراکنش، نشان داد که گونه *S. rosmarinus* در مناطق با اسیدیته ۸/۳-۸/۱، هدایت الکتریکی ۰/۲۶-۰/۲۲ دسی‌زیمنس بر متر، بافت لومی-شنی و در ارتفاع ۱۶۰۰-۱۷۵۰ متر از سطح دریا پراکنش دارد و با میزان اسیدیته و آهنک نسبت مستقیمی دارد.

در این مطالعه از شبکه پرسپترون سه لایه استفاده شد که دارای میزان خطای کم (۱۷/۱۹) و همبستگی بالایی (۰/۷۲) بود. استفاده از شبکه‌های چندلایه، قابلیت انجام هر گونه محاسبات خطی و غیرخطی را دارند و می‌توانند هر تابع مستدل دلخواه را به خوبی تخمین بزنند. سطح خطا در شبکه‌های غیرخطی بسیار پیچیده‌تر از شبکه‌های خطی است (مانند همگرایی دیر یا توقف در نقاط بهینه محلی). در هر مورد باید دقت داشت که هر چند یک شبکه BP چند لایه با تعداد نرون‌های مناسب می‌تواند هر تابعی را پیاده‌سازی کند، اما همیشه وزن‌های درست را برای پاسخ بهینه نمی‌یابد. بهترین راه‌حل تکرار آموزش و آزمون و خطاست (Carins, 2001) که در این مطالعه از آن استفاده شد. همچنین شبکه‌ها به تعداد نرون‌های لایه مخفی خود بسیار حساس (sensitive) هستند. تعداد نرون‌های کم باعث عدم تطابق می‌شود. تعداد زیاد نرون هم باعث بیش‌برازش می‌شود، یعنی تمام تخمین‌ها به تمام نقاط مجموعه آموزش منطبق است، اما از آنجا که بین این نقاط نوسان‌های زیادی وجود دارد، ممکن است برای یک داده جدید خطای زیادی داشته باشیم. برای رفع این مشکل یا باید تعداد اعضای مجموعه آموزشی خیلی بیشتر از پارامترهای شبکه باشد یا اینکه از تکنیک‌های افزایش عمومیت استفاده کرد. در این مطالعه ساختار شبکه عصبی ۱-۱۰-۷ و دارای هفت نرون در لایه ورودی، ده نرون در لایه میانی و یک نرون در لایه خروجی با توجه آزمون‌های انجام شده مناسب تشخیص داده شد.

البته انتشار و گسترش جوامع گیاهی بر روی زمین بر حسب تصادف و اتفاقی نبوده است، بلکه هر گونه‌ای براساس خواص و سرشت خود و شرایط محیطی بوجود

آمده است که روش‌های نوین مدل‌سازی می‌تواند این انتشار را به خوبی نشان دهد. هنگامی که اطلاعات در مورد فرایندهای داخلی یک فرایند پیش‌بینی موجود نباشد، استفاده از شبکه‌های عصبی یک رویکرد مناسب و کارا برای مدل‌سازی مسائل قابل پیش‌بینی می‌باشد. چنین قابلیت‌هایی شبکه‌های عصبی را به‌عنوان ابزاری مناسب برای پیش‌بینی‌های اکولوژیکی تبدیل کرده است (Hsu et al., 2003). در واقع مدل شبکه عصبی بهتر از سایر روش‌ها رابطه غیرخطی را بین عوامل بررسی می‌کند (Kerý, 2010).

مدل‌های پیش‌بینی‌کننده محدوده پراکنش گونه، محدوده توزیع گونه‌ها و رویشگاهشان را پیش‌بینی می‌کنند، بنابراین می‌توانند به‌عنوان ابزار مناسبی برای اهداف حفاظتی و مدیریتی به‌کار روند (خلاصی اهوازی و همکاران، ۱۳۹۰). تعیین مدل‌های پیش‌بینی رویشگاه گونه‌های مختلف اهمیت بسزایی در حفاظت از این گونه‌ها و رویشگاه‌های طبیعی آنها دارد. در نهایت برای موفقیت بیشتر در زمینه پیش‌بینی توزیع گیاهان در عرصه‌های مختلف طبیعی، آزمون روش‌های مختلف و جدید مدل‌سازی پوشش گیاهی در مناطق مختلف آب و هوایی کشور بسیار اثرگذار بوده و می‌توان با شناخت شرایط ویژه هر روش، بهترین آن را برای کاهش هزینه، زمان و افزایش دقت انتخاب کرد. همچنین داده‌های بدست‌آمده از شرایط هر رویشگاهی در کشور به صورت بانک اطلاعاتی ثبت گردد تا بتوان از آن در واسنجی مدل‌های پیش‌بینی استفاده کرد.

منابع مورد استفاده

- پیری صحراگرد، ح.، ۱۳۹۲. ارزیابی کارایی مدل‌های آماری برای پیش‌بینی پراکنش گونه‌های گیاهی (مطالعه موردی: مراتع استان قم. رساله دکتری، دانشکده منابع طبیعی، دانشگاه تهران، کرج.
- حسنی پاک، ع.ا.، ۱۳۷۷. زمین‌آمار، انتشارات دانشگاه تهران، ایران، ۳۱۴ص
- خلاصی اهوازی، ل.، زارع چاهوکی، م.، آذرنیوند، ح. و سلطانی

- species. *Journal of Animal Ecology*, 81:781–787.
- Brambilla, M. and Gobbi, M., 2014. A century of chasing the ice: delayed colonisation of ice-free sites by ground beetles along glacier forelands in the Alps. *Ecography*, 37: 33–42
- Cairns, D. M., 2001. A comparison of methods for predicting vegetation type. *Plant Ecology*, 156: 3–18
- Chamberlain, D. E., Negro, M., Caprio, E., Rolando, A., 2013. Assessing the sensitivity of alpine birds to potential future changes in habitat and climate to inform management strategies. *Biodiversity and Conservation*, 167: 127–135.
- Cohen, J., 1960. A Coefficient of Agreement of Nominal Scales, *Educational and Psychological Measurement*, 20: 37–46.
- Cross, S. S., Harrison R. F., Kennedy R. L., 1995. Introduction to neural networks. *Lancet*, 346:1075-9
- Deng, J., Chin W., Wen, C. H. and Wen, P., 2008. "Back-Propagation Neural Network based Importance Performance Analysis for Determining Critical Service Attributes", *Expert System with Applications*, 34: 1115- 1125
- Elith, J., Phillips, S. J., Hastie, T., Dudik, M., Chee, Y. E. and Yates, C. J., 2011. A statistical explanation of MaxEnt for ecologists. *Diversity and Distributions*, 17: 43–57.
- Ficetola, G. F., Maiorano, L., Falcucci, A., Dendoncker, N., Boitani, L., Padoa-Schioppa, E., Miaud, C. and Thuiller, W., 2010. Knowing the past to predict the future: land-use change and the distribution of invasive bullfrogs. *Global Change Biology*, 16: 528–537.
- Fielding, A. H. and Bell, J. F., 1997. A review of methods for the assessment of prediction errors in conservation presence/absence models. *Environmental Conservation*, 24: 38–49.
- Fouquet, A., Ficetola, G.F., Haigh, A. and Gemmell, N., 2010. Using ecological niche modelling to infer past, present and future environmental suitability for *Leiopelma hochstetteri*, an endangered New Zealand native frog. *Biodiversity and Conservation*, 143: 1375–1384.
- Fukuda, S., 2011- Assessing the applicability of fuzzy neural networks for habitat preference evaluation of Japanese medaka (*Oryzias latipes*). *Ecological Informatics*, 6: 286-295
- Giannini, T. C., Chapman, D. S., Saraiva, A. M., Alves-dos-Santos, I., Biesmeijer, J.C., 2013. Improving species distribution models using biotic interactions: a case study of parasites, pollinators and plants. *Ecography*, 36: 649–656.
- Guisan, A. and Zimmermann, N. E., 2000. Predictive habitat distribution models in ecology. *Ecological Modelling*, 135: 147–186.
- Graham, C. H., Ferrier, S., Huettman, F., Moritz, C. and Peterson, A. T., 2004a. New developments in *Eurotia* گردفرامری، م.، ۱۳۹۰. مدل‌سازی مطلوبیت رویشگاه *ceratoides (L.) C.A.M.* با کاربرد روش تحلیل عاملی آشیان بوم‌شناختی (ENFA) در مراتع شمال شرق سمنان. مرتع، ۵ (۴): ۳۶۲–۳۷۳.
- کرووری، ع.ا.، خوشنویس، م.، ۱۳۷۹. مطالعات اکولوژی و زیست محیطی رویشگاه‌های ارس ایران، انتشارات موسسه تحقیقات جنگلها و مراتع، ایران، ۲۰۰۸ص.
- زارع چاهوکی، م. ع.، زارع ارنانی، م.، زارع چاهوکی، ا. و خلاصی اهوازی، ل.، ۱۳۸۹. کاربرد روش‌های آمار مکانی در مدل‌های پیش‌بینی رویشگاه گونه‌های گیاهی. خشک‌بوم، ۱ (۱): ۲۴–۱۳
- Anderson, J. A., 2003. An Introduction to neural networks. Prentice Hall
- Abd El-Ghani M. and Wafaa M., 2003. Soil-vegetation relationships in a coastal desert plain of southern Sinai, Egypt. *Journal of Arid Environment*, 55(4): 607-628.
- Alemi, M. H., Azari. A. and Nielson, D. R., 1980. Kiriging and univariate modeling of a spatial correlate data. *Soil Tecnology*, 1: 133-147
- Almeida, J. S., 2002. Predictive non-linear modeling of complex data by artificial neural networks. *Current Opinion in Biotechnology*, 13: 72-6.
- Barbet-Massin, M., Rome, Q., Muller, F., Perrard, A., Villemant, C. and Jiguet, F., 2013. Climate change increases the risk of invasion by the yellow-legged hornet. *Biology and Conservation*, 157: 4–10.
- Báez, J. C., Estrada, A., Torreblanca, D. and Real, R., 2012. Predicting the distribution of cryptic species: the case of the spur-thighed tortoise in Andalusia (southern Iberian Peninsula). *Biodiversity and Conservation*, 21: 65–78.
- Bourg, N. A., McShea, W. J. and Gill, D. E., 2005. Putting a CART before the search: successful habitat prediction for a rare forest herb. *Ecology*, 86: 2793–2804.
- Brambilla, M., Bassi, E., Ceci, C. and Rubolini, D., 2010a. Environmental factors affecting patterns of distribution and co-occurrence of two competing raptor species. *Interactive Biodiversity Information System*, 152: 310–322.
- Brambilla, M., Casale, F., Bergero, V., Bogliani, G., Crovetto, G.M., Falco, R., Roati, M. and Negri, I., 2010b. Glorious past, uncertain present, bad future? Assessing effects of land-use changes on habitat suitability for a threatened farmland bird species. *Biodiversity and Conservation*, 143: 2770–2778.
- Brambilla, M. and Ficetola, G. F., 2012. Species distribution models as a tool to estimate reproductive parameters: a case study with a passerine bird

- classification. *IEEE Trans. Geosci. Remote Sensing*, 33: 981–996.
- Peterson, A. T., Soberón, J. and Sánchez-Cordero, V., 1999. Conservatism of ecological niches in evolutionary time. *Science*, 285: 1265–1267.
- Özesmi U., Tan C. O., Özesmi S. L. and Robertson R. L., 2006. Generalizability of artificial neural network models in ecological applications: Predicting nest occurrence and breeding success of the red-winged blackbird *Agelaius phoeniceus*. *Ecological Modeling*, 195: 94–104.
- Quetglas, A., Francesc Ordines and Beatriz Guijarro, J., 2010. The Use of Artificial Neural Networks (ANNs) in Aquatic Ecology. *Artificial Neural Networks – Application 27*: 567–586
- Robertson, M. P., Caithness, N. and Villet, M. H., 2000. A PCA-based modelling technique for predicting environmental suitability for organisms from presence records. *Diversity and Distributions*, (7): 15–27.
- Robertson, M. P., Peter, C. I., Villet, M. H., and Ripley, B. S., 2003. Comparing models for predicting species' potential distributions: A case study using correlative and mechanistic predictive modeling techniques. *Ecological Modeling*, 164: 153–167.
- Raxworthy, C. J., Martinez-Meyer, E., Horning, N., Nussbaum, R. A., Schneider, G. E., Ortega-Huerta, M. A. and Peterson, A. T., 2003. Predicting distributions of known and unknown reptile species in Madagascar. *Nature*, 426: 837–841.
- Roura-Pascual, N., Suarez, A. V., Goomez, C., Pons, P., Touyama, Y., Wild, A. L. and Peterson, A.T., 2004. Geographical potential of Argentine ants (*Linepithema humile* Mayr) in the face of global climate change. *International Journal of Biological Sciences*, 271: 2527–2534.
- Scrinzi, G., Marzullo L. and Galvagni D., 2007. Development of a neural network model to update forest distribution data for managed alpine stands. *Ecological Modeling*, 206: 331–346.
- Stiels, D., Schidelko, K., Engler, J. O., van den Elzen, R. and Rödder, D., 2011. Predicting the potential distribution of the invasive Common Waxbill *Estrilda astrild* (Passeriformes: Estrildidae). *Journal of Ornithology*, 152: 769–780.
- Tan C. O, Özesmi U., Beklioglu, M., Per E. and Kurt B., 2006. Predictive models in ecology: Comparison of performances and assessment of applicability. *Ecological Informatics*, 1: 195–211.
- Thuiller, W., Lavorel, S., Araujo, M. B., Sykes, M. T., Prentice, I. C., 2005a. Climate change threats to plant diversity in Europe. *Proceedings of the National Academy of Sciences*, 102: 8245–8250.
- Watts M. J., Li Y., Russell B. D., Mellin C., Connell S. D., Fordham D. A., 2011- A novel method for museum-based informatics and applications in biodiversity analysis. *Trends Ecology and Evolution*, 19: 497–503.
- Hirzel, A. H. and Hausser, J., Chessel, D. and Perrin, N., 2002. Ecological Niche Factor Analysis: How to compute habitat-suitability maps without absence data? *Ecology*, 73(22): 2027–2036
- Hortal, J., Roura-Pascual, N., Sanders, N. J. and Rahbek, C., 2010. Understanding (insect) species distributions across spatial scales. *Ecography*, 33: 51–53.
- Hsu, K., Gupta, H. V. and Sorooshian, S., 2003. Artificial neural networks modeling of rainfall-runoff process. *Water Resources Research*, 13(10): 2517–2530
- Jianbing, W., Alexandre, B. and Tuanfeng Z., 2008. A SGeMS code for pattern simulation of continuous and categorical variables: FILTERSIM. *Computers & Geosciences*, 34 (12):1863–1876.
- Ke'ry, M., 2010. Introduction to WinBUGS for ecologists – a Bayesian approach to regression, ANOVA, mixed models and related analyses. Academic Press, Burlington, MA.
- Khalasi Ahvazi, L., Zare Chahouki, M. A. and Azarnivand, H., 2011. Environmental factors effects on distribution of vegetation types in Daryan Rangelands of Iran. *Dryland Ecology Conference*
- Liu, C., Berry, P. M., Dawson, T. P., and Pearson, R. G., 2005. Selecting thresholds of occurrence in the prediction of species distributions. *Ecography*, 28: 385–393
- Manel, S., Dias, J. M. and Ormerod, S. J., 1999. Comparing discriminant analysis, neural networks and logistic regression for predicting species distributions: as case study with a Himalayan river bird. *Ecological Modeling*, 120: 337–347.
- Mi, C., Yang J., Li S., Zhang X. and Zhu D., 2010. Prediction of accumulated temperature in vegetation period using artificial neural network. *Mathematic Computer Modeling*. 51: 1453–1460.
- Moisen, G. and Frescino, T., 2002. Comparing five modelling techniques for predicting forest characteristics. *Ecological Modeling*, 157 (2–3): 209–225.
- Monserud, R. A. and Leemans, R., 1992. Comparing global vegetation maps with the Kappa statistic. *Ecological Modeling*, 62: 275–293.
- Paola, J. D. and Schowengerdt, R. A., 1993. A review and analysis of neural networks for classification of remotely sensed multispectral imagery. Research Institute for Advanced Computer Science, NASA Ames Research Center Tech. Rep., 93.05 (NASA-CR-194291),
- Paola, J. D. and Schowengerdt, R. A., 1995. A detailed comparison of backpropagation neural network and maximumlikelihood classifiers for urban land use

- Russian Journal of Ecology, 41: 84-94.
- Zare Chahouki, M. A. and Khalasi Ahvazi, L., 2012. Predicting potential distributions of *Zygophyllum eurypterum* by three modeling techniques (ENFA, ANN and logistic) in North East of Semnan, Iran. Range Management & Agroforestry, 33(2): 123-128.
- Zare Chahouki, M. A., Khalasi Ahvazi, L. and Azarnivand, H., 2012. Predicting plant species distribution and comparison of modeling methods in Iran's rangelands. Polish journal of ecology, 60:277-290.
- mapping reefs and subtidal rocky habitats using artificial neural networks- Ecology Modelling, 222: 2606-2614.
- Willems, W., Goethals P., Eynde, D. V. D., Hoey, G. V, Lancker, V. V and Verfaillie, E., Vincx, M., Degraer, S., 2008- Where is the worm? Predictive modelling of the habitat preferences of the tube-building polychaete *Lanice conchilega*. Ecological Modeling, 212: 74-79.
- Zare Chahouki, M. A., Azarnivand, H., Jafari, M. and Tavili, A., 2010. Multivariate statistical methods as a tool for model based prediction of vegetation.

Predicting the habitat distribution of *Seidlitzia rosmarinus* in east rangelands of Semnan using ANN model

L. Khalasi Ahvazi¹ and M. A. Zare Chahouki^{2*}

1-Ph.D. Student, Department of Rangeland Management, Faculty of Rangeland and Watershed Management, Gorgan University of Agricultural Sciences & Natural Resources, Gorgan, Iran

2*- Corresponding author, Professor, Department of Reclamation of Arid and Mountainous Regions, Faculty of Natural Resources, University of Tehran, Karaj, Iran, Email: mzare@ut.ac.ir

Received:3/13/2014

Accepted:12/7/2014

Abstract

Artificial Neural Network (ANN) is new information processing structures that uses special methods for biological neural networks. The main purpose of this study was to modeling of *Seidlitzia rosmarinus* distribution in northeast rangelands of Semnan by ANN model. For this purpose, vegetation sampling was carried out in each vegetation type along three transects of 750 m, on which 15 plots were established with an interval of 50 m. Soil samples were taken from two depths of 0-20 cm and 20-80 cm in starting and ending points of each transect. To provide the prediction map of plant species distribution, different layers of environmental factors used in the model are required. The geostatistics method was applied for mapping soil properties based on the prediction model obtained from ANN method for *S. rosmarinus*. The back-propagation neural network with three-layer- perceptron network was designed to generate the ANN model and seven neurons in the input layer, ten neurons in the hidden layer, and one neuron in the output layer were used. The accuracy of the prediction map was tested with actual vegetation maps and the Kappa coefficient was calculated to be 72%, indicating a very good agreement. Results showed that this species is distributed in rangelands with a pH of 8.1-8.3, an EC 0.22-0.26 dS/m, in a silty-sandy textured soil, and an altitude of 1600-1750 meters. it is highly correlated with lime and pH in two depths.

Keywords: Artificial Neural Networks, *Sedlitzia rosmarrinus*, back-propagation algorithm, actual vegetation map, Kappa coefficient.