

تهیه نقشه پیش‌بینی پراکنش مکانی رویشگاه گونه‌های گیاهی با استفاده از شبکه‌های عصبی مصنوعی در مراتع استان قم

• حسین پیری صحراگرد

استادیار گروه مرتع و آبخیزداری دانشگاه زابل

• محمدعلی زارع چاهوکی

دانشیار دانشکده منابع طبیعی دانشگاه تهران (نویسنده مسئول)

• مهدیه ابراهیمی

استادیار گروه مرتع و آبخیزداری دانشگاه زابل

تاریخ دریافت: آبان ماه ۹۳ تاریخ پذیرش: اسفند ماه ۹۳

Email: mazare@ut.ac.ir

چکیده

این تحقیق با هدف ارزیابی قابلیت مدل شبکه عصبی مصنوعی در تهیه نقشه پیش‌بینی پراکنش رویشگاه گونه‌های گیاهی و شناخت نقاط قوت و ضعف این روش انجام شد. بدین منظور بعد از تعیین واحدهای همگن با استفاده از مدل رقومی ارتفاع و نقشه زمین‌شناسی با مقیاس ۱:۲۵۰۰۰، نمونه‌برداری از پوشش گیاهی و عوامل محیطی انجام گرفت و نقشه مربوط به متغیرهای محیطی با استفاده از سیستم اطلاعات جغرافیایی و زمین آمار تهیه شد. متغیرهای ورودی به شبکه بر اساس نتایج رگرسیون لجستیک انتخاب شد. برای تهیه مدل شبکه عصبی مصنوعی بعد از نرمال‌سازی داده‌ها و تقسیم تصادفی داده‌ها به سه مجموعه آموزش، آزمون و اعتبارسنجی، بهترین ساختار شبکه عصبی با استفاده از میانگین مربعات خطا تعیین شد. بعد از شبیه‌سازی احتمال حضور و عدم حضور گونه‌ها با شبکه بهینه، نقشه پیوسته احتمال حضور و عدم حضور گونه‌ها با استفاده از نرم‌افزار Arc GIS در هر رویشگاه تهیه شد و آستانه بهینه حضور تعیین شد. در مرحله بعد، میزان تطابق نقشه‌های به‌دست آمده با نقشه‌های واقعی از طریق محاسبه ضریب کاپا بررسی شد. نتایج نشان داد که نقشه پیش‌بینی رویشگاه *Pteropyrum olivieri*-*Stipa barbata* دارای تطابق عالی و نقشه پیش‌بینی رویشگاه‌های *Amygdalus scoparia*, *Artemisia aucheri*-*Astragalus glaucacanthus*, *Scariola orientalis*-*Stipa barbata* این نتایج گویای آن است که استفاده از پیش پردازش رگرسیون لجستیک باعث ساده‌تر شدن معماری شبکه و افزایش سرعت یادگیری شبکه شده و دقت نتایج حاصل از شبیه‌سازی را افزایش داده است. بنابراین در صورت انجام پیش‌پردازش مناسب روی داده‌ها و انتخاب متغیرهای ورودی مناسب، روش شبکه‌های عصبی مصنوعی می‌تواند رویکرد مناسبی برای برآورد حدود پراکنش رویشگاه گونه‌های گیاهی و در نتیجه انتخاب گونه‌های مناسب برای انجام فعالیت‌های اصلاحی در مراتع باشد.

کلمات کلیدی: نقشه پیش‌بینی، زمین‌آمار، سیستم اطلاعات جغرافیایی، شبکه عصبی مصنوعی، مراتع قم.

Watershed Management Research (Pajouhesh & Sazandegi) No 109 pp: 29-39

Predictive Spatial Distribution Maps of Plant Species Habitats in the Khalejstan Rangelands of Qom province

By: H. Piri Sahragard: Assistant Professor, Zabol University. M.A. Zare Chahooki: Associate Professor, Faculty of Natural Resources, University of Tehran. (Corresponding Author). M. Ebrahimi: Assistant Professor, Zabol University.

This study was carried out in order to evaluate the ability of artificial neural network in the preparation of predictive distribution map of plant species habitat and recognizing the strengths and weaknesses of this method. For this purpose, vegetation and soil sampling was conducted after determination of the homogenous unit using digital elevation model and geological map with a scale of 1: 25,000. Then environmental variable maps were obtained using GIS and Geo-statistic. Input variables were selected based on the results of logistic regression. In order to develop of the artificial neural network model the best structure of the neural network was determined using Mean Square Error (MSE) after data normalizing and randomly data portioning into train, test and validation sets. Then simulation of presence / absences probability species was done with optimal network and continuous probability maps of presence or absence species in each habitats were prepared using Arc GIS software and presence optimal threshold was determined. Then compliance of the predictive and actual maps was assessed through the calculation of the kappa coefficient. The results showed which prediction maps of *Pteropyrum olivieri*-*Stipa barbata* habitat has excellent correspondence with actual vegetation map ($\text{kappa} = 90\%$) and *Amygdalus scoparia*, *Artemisia aucheri*-*Astragalus glaucacanthus*, *Scariola orientalis*-*Stipa barbata* habitats have very good correspondence with the ground truth maps. These results indicate that the use of logistic regression preprocessing simplify the network architecture and has increased learning speed and accuracy of the simulation results. Therefore in case of performing appropriate preprocessing of the data and selection of the appropriate input variables, neural networks can be an appropriate approach to estimation of the distribution of plant species habitats and selection of suitable species for rehabilitation activities in the rangelands

Keywords: Predictive map, Geo-statistic, Geographic information systems, Artificial Neural Networks, Rangelands of Qom province

و به موازات مدل‌های رایج قبلی، انواع مختلفی از روش‌های جدید مدل‌سازی به این منظور ابداع شده و توسعه یافته‌اند (Guisan & Thuiller, ۲۰۰۵). افزایش کاربرد این مدل‌ها به کاربرپسند بودن، سهولت تفسیرپذیری، افزایش قابلیت دسترسی به داده‌های سنجش از دور و تکنیک‌های ترکیبی با روش‌های آماری جدید بستگی دارد (Zare Chahouki et al., ۲۰۰۰, Guisan & Zimmermann, ۲۰۱۴). الگوریتم‌های مدل‌سازی متعددی به منظور طبقه‌بندی احتمال حضور و عدم‌حضور گونه‌ها به عنوان تابعی از متغیرهای محیطی بکار رفته‌اند. دسته‌ای از این رویکردها مانند روش‌های آنتروپی حداکثر و شبکه‌های عصبی مصنوعی رویکردهایی هستند که در گروه روش‌های یادگیری ماشینی قرار می‌گیرند و در جاهایی که محاسبات الگوریتمی ناتوان هستند، مورد استفاده قرار می‌گیرند. به دلیل اینکه این روش‌ها هیچ فرضی راجع به پراکنش داده‌های اصلی ندارند، به عنوان روش‌های غیرپارامتری در نظر گرفته می‌شوند

مقدمه

مدل‌های پیش‌بینی پراکنش گونه‌ها ابزاری هستند که از طریق بازیابی شرایط محیطی در محیط‌هایی که یک گونه حضور دارد یا ندارد، تولید می‌شوند. هدف از انجام این مدل‌سازی‌ها، شناسایی روابط پیچیده غیرخطی در یک فضای زیست‌محیطی چندبعدی است. در صورتی که مدل‌های پیش‌بینی تولیدشده با دقت زیاد همراه باشند می‌توانند به مدیران منابع طبیعی در مدیریت بهینه این منابع کمک نمایند (Muñoz et al., ۲۰۰۵, Guisan et al., ۲۰۰۵, Zare Chahouki et al., ۲۰۱۳). ثابت شده است که مدل‌های پراکنش گونه‌ها به دلیل تولید اطلاعات مربوط به دامنه پراکنش جغرافیایی، نیازهای بوم‌شناختی گونه‌ها و تعیین تناسب رویشگاه برای گونه‌های گیاهی بسیار با ارزش هستند (Pearson, ۲۰۰۷, Zare Chahouki et al., ۲۰۱۲, Piri Sahragard, ۲۰۱۴). اخیراً این مدل‌ها جزء مهمی از برنامه‌های حفاظت و اصلاح مراتع شده

عقب خطا مدل‌سازی کردند. نتایج این تحقیق نشان داد که این روش می‌تواند بهتر از روش‌های سنتی موجود روابط غیرخطی پیچیده بین پدیده‌ها را مدل‌سازی کند. آنها این روش را در دسته روش‌های خوب قرار دادند. Mi و همکاران (۲۰۱۰) در مطالعه‌ای با مقایسه عملکرد روش رگرسیون لوجستیک و شبکه‌های عصبی مصنوعی نشان دادند که به‌طور کلی مدل‌های شبکه عصبی مصنوعی در مقایسه با مدل‌های رگرسیون لوجستیک مدل‌های دقیق‌تری هستند، از این رو مدل‌های شبکه عصبی مصنوعی از مدل‌های رگرسیونی کاربردی‌تر هستند.

با توجه به پیچیدگی روابط در یک اکوسیستم طبیعی و وجود روابط غیرخطی و برهمکنش‌های پیچیده بین اجزای متعدد یک اکوسیستم، شناخت روش‌هایی که بتوانند با موفقیت بالایی این روابط را شناسایی کنند از اهمیت زیادی برخوردار است. از آنجا که یکی از قابلیت‌های ویژه روش شبکه‌های عصبی مصنوعی شناخت و کشف این برهمکنش‌های پیچیده و فرایندهای غیرخطی است، این تحقیق با هدف آزمودن قابلیت‌های این روش در برآورد حدود پراکنش رویشگاه گونه‌های گیاهی، امکان تهیه نقشه پیش‌بینی این رویشگاه‌ها و شناخت نقاط قوت و ضعف این روش انجام شد.

مواد و روش‌ها

معرفی منطقه مورد مطالعه

منطقه مورد مطالعه در قسمت غرب شهرستان قم در بخش خلجستان و در دو طرف جاده ساوه - سلفچگان حدود جغرافیایی $30^{\circ} 17'$ تا $50^{\circ} 24'$ طول شرقی و $30^{\circ} 34'$ و $30^{\circ} 43'$ عرض شمالی قرار گرفته است. مساحت منطقه مورد مطالعه ۱۴۰۰ هکتار است. شکل (۱) موقعیت منطقه مورد مطالعه را در استان قم نشان می‌دهد. منطقه مورد مطالعه عرصه‌ای دشتی - کوهستانی است. مرتفع‌ترین نقطه منطقه مورد مطالعه با ارتفاع ۱۷۰۰ متر از سطح دریا در بالادست منطقه مورد مطالعه و در غرب شهرستان قم واقع شده است. بر اساس طبقه‌بندی اقلیمی دومارتن، اقلیم منطقه نیمه‌خشک است (ضریب خشکی ۱۱/۵۹). تیپ‌های عمده رویشی منطقه مورد مطالعه شامل تیپ‌های *Artemisia aucheri* - *Astragalus glaucacanthus*, *Scariola orientalis* *Stipa barbata* - *Pteropyrum olivieri* - *Stipa barbata* *Amygdalus scoparia*، هستند. از گونه‌های مهم همراه نیز می‌توان به گونه‌های *Gundelia tournefortii*, *Centaurea virgata*, *Acanthophyllum spp* اشاره کرد.

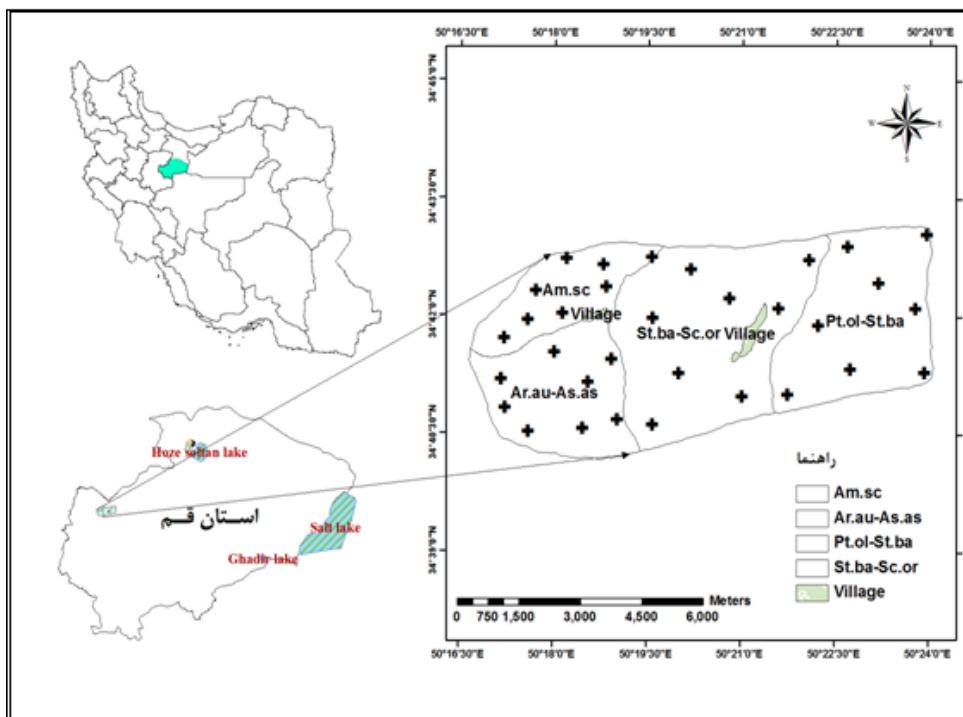
جمع‌آوری اطلاعات عوامل محیطی

بعد از تلفیق نقشه‌های شیب، جهت و ارتفاع و زمین‌شناسی با مقیاس ۱:۲۵۰۰۰ و تعیین واحدهای همگن (۹ واحد همگن)، نمونه‌برداری میدانی از پوشش گیاهی به روش تصادفی - سیستماتیک از طریق پلات‌گذاری در امتداد ۴ ترانسکت ۱۵۰ متری با فواصل ۵۰۰ متری درون تیپ‌های رویشی در واحدهای همگن، انجام شد. برای طبقه‌بندی و تفکیک پوشش گیاهی از روش TWINSPAN استفاده شد.

(Franklin, ۱۹۹۵).

ساختار و عملکرد شبکه‌های عصبی مصنوعی که زیر مجموعه‌ای از تکنیک‌های هوش مصنوعی هستند از مغز انسان تقلید می‌کند و از تعدادی اجزا با ساختار ساده، اما با یک ارتباط پیچیده که به عنوان نرون یا نود شناخته می‌شوند، تشکیل شده‌اند (Strobl & Forte, ۲۰۰۷). این شبکه‌ها مجموعه‌ای از توابع تخمین‌گر با انعطاف‌پذیری بالا را شامل می‌شود که بر اساس تشخیص الگو قادر به کشف و مدل‌سازی فرایندهای غیرخطی می‌باشد. این ویژگی باعث شده است که این روش‌ها، ابزاری مناسب برای مدل‌سازی بوم‌شناختی باشد (Lek & Guegan, ۱۹۹۹, Melesse & Hanley, ۲۰۰۵). با توجه به این نکات، این شبکه‌ها به‌طور گسترده برای مدل‌سازی پراکنش گونه‌های گیاهی و پاسخ به سؤالات مرتبط با بوم‌شناسی پراکنش گونه‌ها مورد استفاده قرار گرفته است (Hastie et al, ۲۰۱۰). مطالعات نشان داده است که روش شبکه‌های عصبی مصنوعی به دلیل قدرت تعمیم‌پذیری بالا و ساختارپذیری موازی برای مدل‌سازی سیستم‌های پیچیده بسیار مناسب هستند (Menhaj, ۲۰۰۲).

در بسیاری از مسائل پیچیده ریاضی که به حل معادلات بفرنج غیرخطی منجر می‌شود، یک شبکه پرسپترون چندلایه می‌تواند با تعریف اوزان و توابع مناسب به فراخور هدف و مسئله مورد نظر مورد استفاده قرار گیرد. یادگیری در شبکه پرسپترون چندلایه با کمینه‌کردن میانگین مربعات خطای خروجی و با به کارگیری الگوریتم یادگیری پس انتشار خطا با استفاده از روش‌های تکرار عددی صورت می‌گیرد (Warner & Manavendra, ۱۹۹۶, Menhaj, ۱۹۹۸). در این نوع الگوریتم خطای خروجی شبکه، برآورد و به عقب (داخل سیستم) انتشار یافته و بر این اساس وزن‌های انتخاب‌شده در مدل اصلاح می‌گردند تا بهترین وزن‌ها که صحیح‌ترین خروجی را برای سیستم ایجاد می‌کنند، شناسایی و انتخاب شوند (Ghanbari et al, ۲۰۰۹). مطالعات متعددی تناسب این روش را در مدل‌سازی پیش‌بینی پراکنش مکانی گونه‌های گیاهی مورد تأکید قرار داده‌اند. Cairns (۲۰۰۱) با مقایسه دقت نسبی مدل‌های خطی تعمیم‌یافته، شبکه‌های عصبی مصنوعی و درخت طبقه‌بندی در تهیه نقشه‌های پیش‌بینی پوشش گیاهی در پارک ملی مونتانا نتیجه گرفت که بیشترین دقت پیش‌بینی با ضریب کاپای ۰/۵۷۱ مربوط به روش شبکه‌های عصبی است و روش درخت طبقه‌بندی با ضریب کاپای ۰/۳۵۱ کمترین دقت پیش‌بینی را داشت. همچنین Zare Chahouki و Khalasi Ahwazi (۲۰۱۳) با استفاده از سه روش LR، ENFA و ANN پراکنش جغرافیایی گونه *Zygophyllum eurypterum* را مدل‌سازی کردند و نتیجه گرفتند که نقشه‌های تولیدشده به روش رگرسیون لوجستیک و مدل‌های شبکه عصبی مصنوعی تطابق بالایی با نقشه‌های واقعی پوشش گیاهی در منطقه مورد مطالعه دارند. علاوه بر این مطالعات، Liu و همکاران (۲۰۰۵) با استفاده از روش شبکه‌های عصبی مصنوعی پراکنش گونه‌های *Fagus sylvatica* و *maritima Puccinellia* را در دو کشور رومانی و لهستان با استفاده از یک شبکه پیش‌خور چند لایه با الگوریتم آموزشی انتشار به



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه در کشور و استان قم و موقعیت نقاط نمونه‌برداری در رویشگاههای مورد مطالعه

سرعت و فرایندهای شبکه عصبی از روش نرمال‌سازی داده‌ها بین صفر و یک استفاده شد (Sharma, Mahmoudabadi & Seyed, ۱۹۹۶). بعد از نرمال‌سازی، به منظور آموزش شبکه، داده‌های در دسترس به‌طور تصادفی و به نسبت ۶۰، ۲۰ و ۲۰ درصد به سه مجموعه آموزش، آزمون و اعتبارسنجی تقسیم شدند. برای تعیین معماری شبکه نیز به دلیل اینکه استفاده از اطلاعات یا متغیر ورودی بیش از حد بهینه، موجب کاهش دقت مدل می‌شود (Faghih, ۲۰۱۰)؛ از این‌رو ترکیب مناسب متغیرهای ورودی برای هر کدام از رویشگاه‌ها بر اساس نتایج مربوط به رگرسیون لجستیک تعیین شد. شبکه بهینه با استفاده از آماره میانگین مربعات خطا و ضریب تبیین تعیین شد و شبیه‌سازی با شبکه بهینه انتخاب شده، انجام گرفت. روش آموزش شبکه، پس‌انتشار خطا و الگوریتم آموزش مورد استفاده، الگوریتم لومبرگ مارکوارت بود.

تهیه نقشه پیش‌بینی و ارزیابی میزان تطابق نقشه‌های پیش‌بینی و واقعی در هر رویشگاه

بعد از انجام شبیه‌سازی احتمال حضور و عدم حضور با شبکه بهینه و اعتبارسنجی نتایج به‌دست آمده، با استفاده از مقادیر شبیه‌سازی شده توسط شبکه و مقادیر حاصل از نمونه‌برداری، با استفاده از نرم‌افزار Arc GIS نقشه پیوسته احتمال حضور و عدم حضور گونه‌ها در هر رویشگاه تهیه شد. در مرحله بعد آستانه بهینه حضور به روش حساسیت و اختصاصیت برابر تعیین شد (Cantor et al, ۱۹۹۹).

برخی از مشخصات رویشگاه‌های مورد بررسی در جدول شماره (۱) آورده شده است. سطح پلات‌ها با توجه به نوع گونه‌های موجود در ۴ رویشگاه مورد مطالعه، به روش حداقل بین ۲ تا ۲۵ مترمربع و تعداد آنها با توجه به تغییرات پوشش گیاهی و با استفاده از روش آماری کوکران ۶۰ پلات تعیین شد. در هر پلات نوع گونه‌ها و درصد تاج پوشش ثبت شد. برای اندازه‌گیری خصوصیات خاک نیز در طول هر ترانسکت دو پروفیل حفر و از دو عمق ۳۰-۸۰ و ۳۰-۰ سانتی‌متری نمونه خاک برداشت و مختصات جغرافیایی نمونه‌های برداشت شده نیز با استفاده از سیستم موقعیت‌یاب جهانی ثبت شد (در هر رویشگاه ۸ نمونه خاک برداشت شد). در آزمایشگاه، خصوصیات خاک شامل سنگریزه، بافت، رطوبت اشباع، رطوبت قابل دسترس، آهک، گچ، ماده آلی، اسیدیته، هدایت الکتریکی با روش‌های معمول اندازه‌گیری شد. در مرحله بعد نقشه مربوط به متغیرهای محیطی با استفاده از سیستم اطلاعات جغرافیایی و زمین‌آمار با وضوح مکانی یکسان (اندازه پیکسل ۳۰*۳۰ متر) تهیه و در محیط GIS ذخیره شد. برای تهیه نقشه مربوط به متغیرهای ارتفاع، شیب و جهت از مدل رقومی ارتفاع و برای تهیه نقشه خصوصیات خاک از نرم‌افزار Arc GIS ۹٫۳ و GS+ نسخه ۵/۱ استفاده شد.

پیش‌پردازش داده‌ها، اجرای مدل و انتخاب مدل بهینه

در این مطالعه برای تدوین مدل شبکه عصبی مصنوعی و انجام محاسبات از نرم‌افزار MATLAB ۲۰۰۸a استفاده شد. به منظور افزایش دقت،

جدول ۱- برخی از ویژگی‌های تپ‌های گیاهی مورد مطالعه در مراتع استان قم

ردیف	عنوان تپ گیاهی	نشانه روی نقشه	تاج پوشش (درصد)	شیب (درصد)	ارتفاع از سطح دریا (متر)	اقلیم (دو مارتن)	بارندگی (میلی متر)
۱	<i>Amygdalus scoparia</i>	Am.sc	۳۵-۴۰	۶۰	۱۵۰۰-۱۷۰۰	نیمه‌خشک	۲۵۰-۵۰۰
۲	<i>Artemisia aucheri</i> – <i>Astragalus glaucacanthus</i>	Ar.au-As.gl	۴۰-۵۰	۴۰-۶۰	۱۴۰۰-۱۶۰۰	نیمه‌خشک	۲۵۰-۵۰۰
۳	<i>Pteropyrum olivieri</i> - <i>Stipa barbata</i>	Pt.ol- St.ba	۳۰-۴۰	۵-۱۵	۱۱۰۰-۱۳۰۰	نیمه‌خشک	۲۰۰-۴۰۰
۴	<i>Scariola orientalis</i> <i>Stipa barbata</i>	St.ba-Sc.or	۲۵-۳۰	۱۰-۱۵	۱۴۰۰-۱۵۰۰	نیمه‌خشک	۲۰۰-۴۰۰

سیگموئید و قانون آموزش لونبرگ مارکوارت حاصل شد. ساختار بهترین مدل شبکه عصبی و نتایج آماری اجرای آن در جدول (۳) ارائه شده است. لازم به ذکر است که متغیرهای ورودی به شبکه برای هر کدام از رویشگاه‌ها، بر اساس متغیرهای وارد شده به مدل‌های رگرسیون لوجستیک انتخاب شد. بر این اساس، متغیرهای ورودی برای هر کدام از مدل‌های شبکه عصبی مصنوعی با توجه به نوع رویشگاه متفاوت بود. در رویشگاه *Amygdalus scoparia*، عامل سازند زمین‌شناسی و سنگریزه عمق اول خاک؛ در رویشگاه *Artemisia aucheri*-*Astragalus glaucacanthus* عوامل ارتفاع از سطح دریا و سنگریزه عمق اول خاک؛ در رویشگاه *Pteropyrum olivieri*-*Stipa barbata* عوامل سنگریزه و آهک عمق دوم و شن عمق اول و برای رویشگاه *Scariola orientalis*- *Stipa barbata* عوامل درصد شیب، اسیدیته عمق دوم و مقدار سیلت عمق اول خاک به عنوان متغیرهای ورودی انتخاب شدند.

(Pearson et al, ۲۰۰۴)؛ و نقشه طبقه‌بندی شده حضور و عدم حضور برای هر یک از رویشگاه‌های مورد مطالعه تهیه شد. در مرحله بعد میزان تطابق نقشه‌های واقعی با نقشه به دست آمده از یک از مدل‌ها از طریق محاسبه ضریب کاپا در نرم‌افزار Idrisi ۳۲ release Two بررسی شد. شاخص کاپا از بهترین و مشهورترین شاخص‌های مورد استفاده برای این منظور است (Cohen, ۱۹۶۰, Monserud & Leemans, ۱۹۹۲).

نتایج

همان‌طور که اشاره شد پس از نمونه‌برداری از خاک، خصوصیات خاک مورد نظر در آزمایشگاه اندازه‌گیری شد. آمار توصیفی خصوصیات خاک اندازه‌گیری شده به تفکیک رویشگاه‌های مورد بررسی در جدول (۲) آمده است.

انتخاب مدل‌های بهینه برای هر رویشگاه

دقیق‌ترین مدل‌ها در همه رویشگاه‌ها با استفاده از تابع انتقال تانژانت

جدول ۲- آمار توصیفی خصوصیات خاک رویشگاه‌های منطقه مورد مطالعه

رویشگاه	Am.sc		As.as Ar.au		St.ba Pt.ol		or St ba-sc	
	میانگین ± انحراف از معیار	حداقل	حداکثر	میانگین ± انحراف از معیار	حداقل	حداکثر	میانگین ± انحراف از معیار	حداقل
آهک	۹/۸۹±۲/۵	۶/۲۵	۱۴/۵۸	۴/۸۸±۱/۳۸	۲/۵	۶/۶۷	۱۱/۷۰±۱/۶۵	۹/۱۲
ماده آلی	۰/۳±۰/۱۴	۰/۱۲	۰/۵۵	۰/۷۸±۰/۱۱	۰/۵۵	۰/۹۵	۰/۳۰±۰/۲۰	۰/۰۸
رطوبت اشباع	۲۵/۴۶±۴/۳۴	۲۰/۲۹	۳۵/۳۶	۲۶/۷۶±۳/۷۱	۲۲/۴۵	۳۵/۸۰	۲۶/۹۴±۳/۰۲	۲۲/۵۸
گچ	۰/۴۲±۰/۰۰۸	۰/۰۳	۰/۰۶	۰/۰۳۳±۰/۰۱۷	۰/۰۱	۰/۰۶	۰/۰۳۲±۰/۰۰۶	۰/۰۳
اسیدیته	۸/۰۱±۰/۱	۷/۸۰	۸/۲۰	۷/۷۶±۰/۰۹۲	۷/۶۳	۷/۹۰	۷/۷۶±۰/۰۹۲	۷/۹۲
هدایت الکتریکی	۰/۱۳±۰/۰۱۲	۰/۱۱	۰/۱۶	۰/۱۷±۰/۰۲۹	۰/۱۳	۰/۲۲	۰/۱۵±۰/۰۳۰	۰/۱۳
آب قابل دسترس	۱۵/۲۷±۲/۵۴	۱۰/۲۷	۱۸/۸۱	۴/۸۸±۱/۳۸	۱۰/۲۷	۱۸/۵۴	۱۰/۷۲±۲/۲۲	۶/۸۴
سنگریزه	۵۵/۰۲±۷/۸۵	۴۱/۵۶	۷۱/۹۴	۱۶/۲۶±۲/۴۷	۳۹/۷۳	۵۴/۳۸	۳۷/۱۵±۷/۵۰	۲۶/۷۲
سیلت	۲۴/۰۲±۷/۹۳	۱۵/۲۸	۴۳/۲۸	۲۶/۵۶±۷/۵۷	۱۶/۵۶	۴۰/۵۶	۱۱/۵۶±۳/۵۱	۳/۲۸
رس	۱۱/۰۱±۲/۷۰	۷/۴۰	۱۷/۴۰	۱۹/۷۷±۴/۴۱	۱۳/۴۴	۲۷/۴۴	۶/۸۳±۲/۲۷	۳/۴۰
شن	۶۴/۳۲±۱۲/۶۳	۴۵/۳۲	۸۳/۳۲	۵۳/۶۶±۸/۱۷	۴۴	۶۶	۸۱/۹۸±۱۳/۷۸	۵۹/۳۲

بعد از انتخاب شبکه بهینه مربوط به هر یک از رویشگاه‌ها، از این شبکه برای پیش‌بینی احتمال حضور هر یک از گونه‌ها در نقاطی از رویشگاه‌ها که در آن نقاط نمونه‌برداری صورت نگرفته بود، استفاده شد و نقشه پیوسته مکانی احتمال حضور یا عدم‌حضور گونه‌ها در هر یک از رویشگاه‌ها، در محیط GIS و اندازه پیکسل 30×30 متری تهیه شد. بر اساس این نتایج، میزان تطابق نقشه‌های حاصل که بر اساس لایه‌های مربوط به متغیرهای محیطی در هر رویشگاه ساخته شده‌اند، در رویشگاه‌های مختلف با یکدیگر متفاوت است (شکل ۲). بر اساس نتایج، نقشه‌های پیش‌بینی برای رویشگاه *Pteropyrum olivieri*-*Amygdalus Stipa barbata* دارای تطابق عالی و رویشگاه‌های *scoparia*، *Artemisia aucheri*-*Astragalus glaucacanthus* و *Scariola orientalis*-*Stipa barbata* دارای تطابق خیلی خوب با نقشه‌های واقعیت زمینی هستند (جدول ۴).

برای یافتن بهترین تعداد لایه پنهان، شبکه‌های عصبی مختلف با تابع انتقال و قانون آموزش انتخاب‌شده در مرحله قبل، با تعداد یک تا ۴ لایه پنهان، ساخته و اجرا شد و مشاهده شد که با افزایش تعداد لایه پنهان مقدار خطا کاهش نمی‌یابد و کمترین مقدار خطا با همان یک لایه پنهان حاصل می‌شود، بنابراین برای هر چهار رویشگاه، شبکه عصبی با یک لایه پنهان به عنوان بهترین ساختار در نظر گرفته شد. تعداد نرون لایه پنهان نیز به روش آزمون و خطا تعیین شد. بدین‌منظور شبکه‌های مختلف با تعداد نرون‌های متفاوت در لایه پنهان (۱ تا ۱۲ نرون) اجرا شد و معیارهای مربوط به خطای آنها محاسبه شد. نتایج نشان داد که تعداد بهینه نرون لایه پنهان در هر رویشگاه از رویشگاه دیگر متفاوت است.

تهیه نقشه پیش‌بینی رویشگاه‌های مورد مطالعه و ارزیابی دقت نقشه‌ها

جدول ۳- ساختار بهترین مدل شبکه عصبی و نتایج آماری اجرای آن

نتایج آماری		معماری				
تمام فاکتورهای ورودی	تمام فاکتورهای ورودی	قانون آموزش	تابع انتقال	تعداد لایه پنهان	خروجی / میانگین / ورودی	نام رویشگاه
۰/۹۴	۰/۰۰۰۲۷	LM	تانژانت سیگموئید	۱	۲:۴:۲	Am.sc
۰/۸۶	۰/۰۰۰۵۴	LM	تانژانت سیگموئید	۱	۲:۸:۲	Ar.au-As.gl
۰/۹۸	۰/۰۰۰۱۷	LM	تانژانت سیگموئید	۱	۳:۱۲:۲	Pt.ol- St.ba
۰/۸۱	۰/۰۰۰۷۸	LM	تانژانت سیگموئید	۱	۳:۲:۲	St.ba-Sc.or

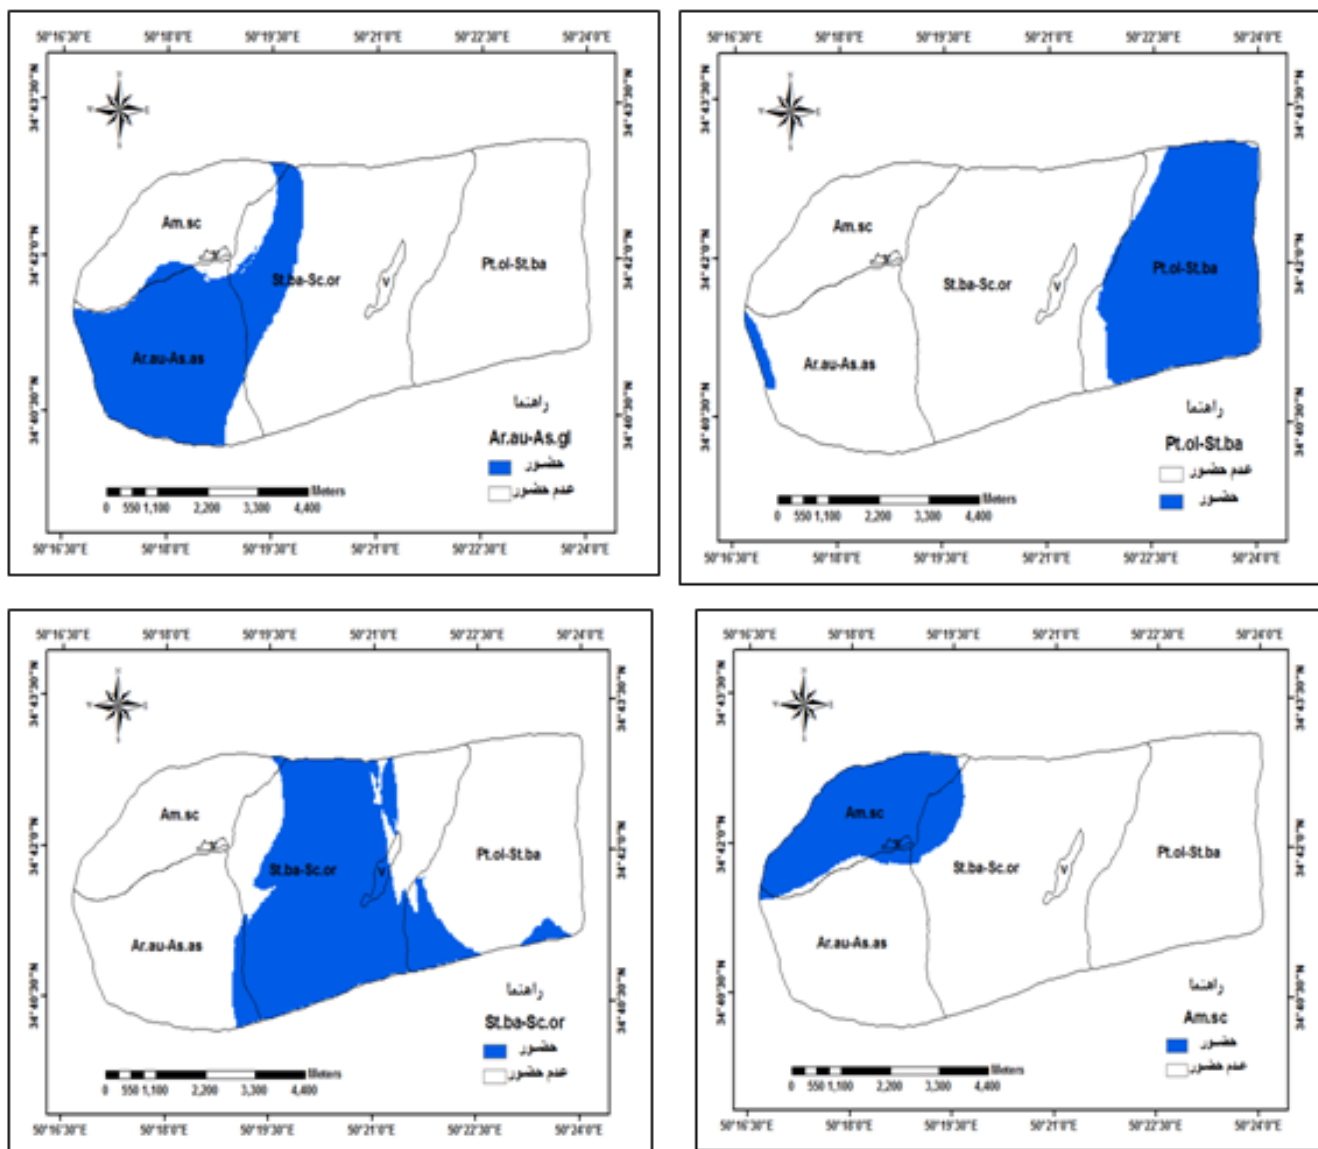
ردیف	رویشگاه	آستانه بهینه حضور	ضریب کاپا	توافق بین نقشه واقعی و پیش‌بینی
۱	<i>Amygdalus scoparia</i>	۰/۷	۰/۸۵	خیلی خوب
۲	<i>Artemisia aucheri</i> – <i>Astragalus glaucacanthus</i>	۰/۵	۰/۷۸	خیلی خوب
۳	<i>Pteropyrum olivieri</i> - <i>Stipa barbata</i>	۰/۲	۰/۹۰	عالی
۴	<i>Scariola orientalis</i> - <i>Stipa barbata</i>	۰/۳	۰/۷۲	خیلی خوب

بحث و نتیجه‌گیری

درصد) و نقشه پیش‌بینی رویشگاه‌های *Amygdalus scoparia*، *Artemisia aucheri*-*Astragalus glaucacanthus* و *Scariola orientalis*-*Stipa barbata* دارای تطابق خیلی خوب (به ترتیب ضریب کاپای ۰/۸۵، ۰/۷۸ و ۰/۷۲)؛ با نقشه‌های واقعیت زمینی هستند.

همان‌طور که اشاره شد متغیرهای ورودی به شبکه برای هر یک از رویشگاه‌ها، بر اساس متغیرهای واردشده به مدل رگرسیون لوجستیک انتخاب شد. بر اساس نتایج حاصل از این تحقیق برای رویشگاه *Amygdalus scoparia* دقیق‌ترین مدل پیش‌بینی دارای دو نرون در لایه ورودی (سازند زمین‌شناسی و سنگریزه عمق اول خاک) و ۴ نرون در لایه میانی بود. نقشه پیش‌بینی به‌دست آمده

در این پژوهش کارایی شبکه پرسپترون چندلایه در پیش‌بینی پراکنش مکانی رویشگاه گونه‌های مورد مطالعه با استفاده از خصوصیات محیطی مورد ارزیابی قرار گرفت. بر اساس نتایج دقیق‌ترین مدل‌ها در همه رویشگاه‌های با استفاده از تابع انتقال تانژانت سیگموئید و قانون آموزش لونیگ مارکوارت حاصل شد. این نتایج گویای آن است که پیش‌پردازش متغیرهای ورودی با استفاده از رگرسیون لوجستیک اثر مثبتی در عملکرد پیش‌بینی شبکه عصبی داشته است به‌گونه‌ای که میزان تطابق نقشه‌های پیش‌بینی حاصل از مدل‌های شبکه عصبی با نقشه واقعی در رویشگاه *Pteropyrum olivieri*-*Stipa barbata* دارای تطابق عالی (کاپای ۰/۹۱)



شکل ۲- نقشه پیش‌بینی و واقعی رویشگاه‌های منطقه مورد مطالعه حاصل از روش شبکه عصبی مصنوعی (نقشه پیش‌بینی با رنگ تیره نشان داده شده است)

و دارای سنگریزه فراوان استقرار می‌یابد. لازم به ذکر است که در رویشگاه این گونه نیز این شرایط کاملاً صادق است. دقیق‌ترین مدل پیش‌بینی برای رویشگاه *Artemisia aucheri* - *Astragalus glaucacanthus* از مدلی حاصل شد که دارای دو نرون در لایه ورودی و ۸ نرون در لایه میانی بود. نقشه پیش‌بینی حاصل از این مدل برای این گونه دارای تطابق خیلی خوب با نقشه واقعی این رویشگاه است (ضریب کاپای ۰/۷۸). این نتیجه گویای آن است که متغیرهای ورودی به مدل (ارتفاع از سطح دریا و سنگریزه عمق اول خاک) از جمله متغیرهای مهم و تأثیرگذار در پراکنش

از این مدل پیش‌بینی، دارای تطابق بالایی با نقشه واقعی پراکنش این گونه بود (ضریب کاپای ۰/۸۵). این تطابق بالا نشان می‌دهد که انتخاب متغیرهای ورودی به مدل پیش‌بینی، به‌درستی انجام شده است و متغیرهای انتخاب‌شده از متغیرهای مهم و تأثیرگذار بر پراکنش این رویشگاه در منطقه مورد مطالعه بوده‌اند. نقش نوع سازند زمین‌شناسی در پراکنش و استقرار این گونه در مطالعات Salarian و همکاران (۲۰۰۸)، Tavakoli Nekou و همکاران (۲۰۱۱) و همچنین Alberghina (۱۹۸۷) مورد تأکید قرار گرفته است. همچنین Alvani Nejad (۱۹۹۹) و Goudarzi (۲۰۰۸) نیز گزارش کرده‌اند که این گونه در مناطقی با خاک سطحی، کم‌عمق

رگرسیونی برتری دارد (Moisen & Frenscino, 2002; Melesse & Hanley, 2007; Bedia et al, 2011). این نتایج با یافته این تحقیق در مورد شبکه‌های عصبی مطابقت دارد. علیرغم وجود قابلیت‌های بالای این روش، باید این نکته را هم مدنظر قرار داد که به هر حال این روش نیز روش دارای خطاها و عدم قطعیت‌هایی است که حتماً باید مورد توجه کاربران آن قرار گیرد (Piccinini, 2011). علاوه بر این موارد، مبهم بودن عملکرد داخلی این شبکه‌ها نیز از نقاط ضعف این روش‌هاست (Segurado & Araujo, 2004).

یکی از مسائل مهم در مدلسازی پیش‌بینی با استفاده از شبکه‌های عصبی، تعیین ورودی‌های مناسب به شبکه است زیرا ورود متغیرهایی با همبستگی بالا باعث ورود اطلاعات تکراری خواهد شد که این امر از یافتن مدل‌های بهینه جلوگیری می‌کند (Broadhurst et al, 1998). بنابراین توصیه می‌گردد تا حد امکان تعداد ورودی‌ها کم باشد حتی اگر باعث از دست رفتن برخی از اطلاعات موجود شود (Haykin, 1999). از سوی دیگر حذف این داده‌ها، هزینه جمع‌آوری داده‌ها را کاهش و در اغلب موارد دقت مدل را افزایش می‌دهد (Faghieh, 2010). به‌همین منظور در این مطالعه از متغیرهای ورودی به مدل‌های رگرسیون لوجستیک به عنوان متغیرهای ورودی استفاده شد و نتایج قابل قبولی نیز به دست آمد. از مزایای این اقدام می‌توان به ساده‌تر شدن معماری شبکه و در نتیجه افزایش سرعت آموزش آن اشاره کرد که منجر به تولید نقشه‌های دقیق شده است. یکی دیگر از چالش‌های استفاده از این شبکه‌ها، تعیین تعداد لایه پنهان شبکه است که در این تحقیق پس از آزمون و خطاهای متعدد، یک شبکه پرسپترون چندلایه با یک لایه پنهان برای پیش‌بینی حضور و عدم حضور گونه‌ها استفاده شد. تحقیقات انجام گرفته در این زمینه نشان می‌دهد که یک لایه پنهان برای این گونه مدل‌ها می‌تواند هر تابع پیچیده و غیرخطی را برآورد کند. همچنین نتایج تجربی و عملی این موضوع را تأیید می‌کند (Jalili- Ghazizade & Noori, 2008). همان‌طور که اشاره شد در این تحقیق برای آموزش شبکه از الگوریتم لوبنبرگ مارکوارت استفاده شد. تحقیقات نشان داده است که این الگوریتم برای اکثر کاربردها نتایج دقیق و سریعی نسبت به سایر قانون‌های آموزش شبکه ارائه می‌دهد (Hagan & Menhaj, 1994; Tan, Van Cauwenberghe & Van, 1999). در بوم‌شناسی نیز استفاده از شبکه‌های عصبی مصنوعی پیش‌خور با الگوریتم پس‌انتشار رایج است (Heaton, 2010).

نتایج این تحقیق نشان داد هر چند تفسیر مستقیم و احتمالاتی برای وزن‌های شبکه امکان‌پذیر نیست اما استفاده از شبکه‌های عصبی می‌تواند رهیافت مناسبی برای برآورد پراکنش گونه‌های گیاهی باشد و در صورتی که آموزش این شبکه‌ها به‌درستی انجام شود و بهترین ساختار برای پیش‌بینی به دست آید شبکه قادر خواهد بود تا پیش‌بینی مناسبی را از داده‌های جدید ارائه دهد که این امر می‌تواند در مسائل مرتبط با اصلاح و احیای مراتع و معرفی گونه‌های

این رویشگاه بوده است و مدل حاصل از شبکه نیز توانسته است با بهره‌گیری از مقادیر مربوط به این متغیرهای ورودی، شبیه‌سازی را با کمترین خطای ممکن انجام دهد و در نتیجه نقشه‌ای با دقت قابل قبول در مورد این رویشگاه تهیه شد. تأثیر ارتفاع و سنگریزه در افزایش تناسب رویشگاه برای این گونه در مطالعات متعددی مورد تأکید قرار گرفته است (Zare Chahouki, Hosseini et al, 2013). با توجه به موقعیت مکانی رویشگاه این گونه، متغیرهای ورودی نقش مهمی در تعیین تناسب یا عدم تناسب رویشگاه برای رویشگاه مورد بررسی دارند. در رویشگاه *Pteropyrum olivieri*- *Stipa barbata* پیش‌بینی از شبکه‌ای به دست آمد که دارای سه نرون در لایه ورودی (سنگریزه و آهک عمق دوم و شن عمق اول) و ۱۲ نرون در لایه میانی بود. بر اساس نتایج، نقشه پیش‌بینی مبتنی بر این مدل دارای تطابق عالی با نقشه واقعی رویشگاه این گونه بود (ضریب کاپای ۰/۹). این نتایج بدان معنا است که متغیرهای ورودی به مدل توانسته‌اند پراکنش این رویشگاه را به‌طور مناسبی پیش‌بینی کنند. تأثیر عوامل سنگریزه، آهک و شن در پراکنش رویشگاه این گونه در مطالعات Moslemi (1997) نیز مورد تأکید قرار گرفته است.

دقیق‌ترین مدل پیش‌بینی برای رویشگاه *Scariola orientalis*- *Stipa barbata* مدلی بود که دارای سه نرون در لایه ورودی (شیب، اسیددیده عمق دوم و سیلت عمق اول) و دو نرون در لایه میانی بود. از آنجا که میزان تطابق نقشه پیش‌بینی حاصل برای این رویشگاه با نقشه واقعی در حد خیلی خوب برآورد شد (ضریب کاپای ۰/۷۲)، بنابراین می‌توان نتیجه گرفت که متغیرهای ورودی به مدل پیش‌بینی به درستی انتخاب شده‌اند و در نتیجه مدل پیش‌بینی حاصل، توانسته است پراکنش رویشگاه این گونه را به دقت شبیه‌سازی کند. تأثیر عامل شیب در پراکنش و تفکیک جوامع گیاهی در مطالعات Munishi و همکاران (2011) گزارش شده است. همچنین خصوصیات شیمیایی خاک مانند اسیددیده نیز می‌تواند ترکیب گونه‌های را در مناطق مختلف تحت تأثیر قرار دهد. تأثیر بافت و اسیددیده خاک در رخداد گونه *Stipa barbata* در مطالعه Abdollahi و همکاران (2013) و همچنین Farahani و همکاران (2008) در مطالعه آت اکولوژی این گونه مورد تأکید قرار گرفته است که با نتایج تحقیق حاضر همخوانی دارد.

شبکه‌های عصبی مصنوعی در مورد فرایندهایی که تعریف دقیق و کاملی از فیزیک آنها وجود ندارد، بسیار مؤثر هستند. یکی از ویژگی‌های بارز این شبکه‌ها حساسیت کم آنها نسبت به وجود خطا در ورودی‌ها است که علت این امر پردازش توزیعی اطلاعات است (Dawson & Wilby, 1998; Tokar & Markus, 2000). مطالعات زیادی عملکرد روش شبکه عصبی مصنوعی و دیگر روش‌های مدل‌سازی رایج در پراکنش گونه‌ها را مورد بررسی قرار داده و به این نتیجه رسیده‌اند که روش شبکه‌های عصبی مصنوعی به دلیل قابلیت زیاد در شناسایی روابط غیرخطی دارای عملکرد بهتری در مقایسه با دیگر روش‌هاست و این روش به‌طور خاص از نظر عملکرد بر روش‌های

10. Faghih, H. (2009). Evaluate functionality of the artificial neural network and optimization of ANN by genetic algorithm to estimate monthly rainfall data (Case Study: Kurdistan Region). *Journal of Science and Technology of Agriculture and Natural Resources, Soil and Water Science*, 27-42 :(51) 14. (In Persian)
11. Farahani, A., Shahmoradi, A., Zare Kia, S., and Ajir, S. (2008). An Autecological study of *Stipa barbata* as rangeland species in Tehran province. *Research Quarterly of Rangeland and desert*. 86-94 :(1) 15. (In Persian)
12. Franklin J.(1995). Predictive Vegetation Mapping: Geographic Modelling of Biospatial Patterns in Relation to Environmental Gradients, *Progress in Physical Geography*, 499-474 :(4)19.
13. Ghanbari, F., Shataee, Sh., Dehghani, A.A., and Ayoubi, Sh. (2009). Tree Density Estimation of Forests by Terrain Analysis and Artificial Neural Network. *J. of Wood & Forest Science and Technology*, -25 :(4)16 42. (In Persian)
14. Goudarzi, Gh. (1999). Final Report of the Research Project of *Amygdalus* Site demands in the Central Province. *Research Institute of Forests and Rangelands*, 91 Pages. (In Persian)
15. Guisan, A., and Thuiller, W. (2005). Predicting species distribution: offering more than simple habitat models. *Ecol. Lett.* 1009-993 :8.
16. Guisan, A., and Zimmermann, N.E.(2000). Predictive habitat distribution models in ecology. *Ecological Modelling* 186-147 :135.
17. Hagan, M. T., and Menhaj, M. B. (1994). Training feed forward networks with the Marquardt algorithm. *IEEE Trans on Neural Networks* 993-989 :5.
18. Hastie, T., Tibshirani, R., and Friedman, J. (2010). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Second Edition. 2d ed., Springer Series in Statistics, Springer, URL <http://www-stat.stanford.edu/~tibs/ElemStatLearn/main.html>.
19. Haykin, S. (1999). *Neural networks: a comprehensive foundation*, 2nd Ed., Prentice Hall., New Jersey, USA.
20. Heaton, J. (2010). *Programming Neural Networks with Encog2 in C#*. Heaton Research, Inc.

سازگار با مناطق مشابه کارگشا و حائز اهمیت باشد و با فراهم آوردن نتایج دقیق، امکان موفقیت طرح‌های اصلاحی را در مراتع افزایش دهد. لازم است علاوه بر بررسی تأثیر پیش‌پردازش‌های دیگر مانند تجزیه مؤلفه‌های اصلی و الگوریتم ژنتیک روی عملکرد شبکه‌های عصبی، عملکرد سایر روش‌های هوش مصنوعی مانند شبکه‌های مصنوعی - فازی نیز با این روش مورد مقایسه قرار گیرد.

منابع مورد استفاده

1. Abdullahi, j., Naderi, h., Mir Jalali, M. R., and Tabatabai, M. A. (2013). The effect of some environmental factors on the growth characteristics of *Stipa barbata* species in the Nadusahan rangelands of Yazd. *Research Quarterly of Rangeland and desert*. 20 130-144 :(1). (In Persian)
2. Alberghina, O. (1978). The wild Almond, *Amygdalus webbii*, of south west Sicily, *Tecnicaagricola*, :(6)30 393-385.
3. Alvani nejad, S. (1999). Study of effective factors on Distribution of *Amygdalous. scoparia* in two different regions of the Markazi Province. MSc thesis, University of Tarbiat Madras, 144 pages. (In Persian)
4. Bedia, J., Busque, J., and Gutierrez, J.M. (2011). Predicting plant species distribution across an alpine rangeland in northern Spain. A comparison of probabilistic methods. *Applied Vegetation Science*:14 432-415.
5. Broadhurst, D., Goodacre, R., Jones, A., Rowland, J.J., and Kell, D.B. (1997). Genetic algorithms as a method for variable selection in multiple linear regression and partial least squares regression, with applications to pyrolysis mass spectrometry." *Anal. Chim. Acta.*, 86-71 :(3-1) 348.
6. Cairns, D.M. (2001). A comparison of methods for predicting vegetation type. *Plant Ecology*, 18-3 :156.
7. Cantor, S. B. et al. (1999). A comparison of C/B ratios from studies using receiver operating characteristic curve analysis. *J. Clin. Epidemiol.* 892-885 :52.
8. Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement* 46-37 :20.
9. Dawson, C.W., and Wilby, R. (1998). An artificial neural network approach to rainfall-runoff modeling. *J. of Hydrol. Sci.*, 66-14 :43.

- Miombo ecosystem in the Lake Rukwa basin, Southern Tanzania: Implications for conservation. *Journal of Ecology and the Natural Environment*, 71-63 :(2)3.
33. Muslemi, M. R. (1997). Evaluation of soil and vegetation relationships using Ordination method In the Kolah'ghazy National Park, MSc Thesis, University of Isfahan, 137 pages. (In Persian)
34. Muñoz, J., and Felicísimo, Á.M. (2004). Comparison of statistical methods commonly used in predictive modelling. *Journal of Vegetation Science*, 92-285 :15.
35. Pearson, R. G. (2007). Species distribution modeling conservation educators and practitioners. Synthesis. New York: American Museum of Natural History.
36. Pearson, R., Dawson, T. P., and Liu, C. (2004). Modelling species distributions in Britain: a hierarchical integration of climate and land-cover data. *Ecography* 298-285 :27.
37. Piccinini, C. (2011). Assessing the impact of climate change on plant distributions using Artificial Neural Networks. Kingston University London.
38. Piri sahragard, H. (2014). Evaluation of statistical models efficiency to predict the distribution of plant Species, (Case study: Qum Province Rangelands), PhD thesis of Range management, Faculty of Natural Resources, University of Tehran, 157 pp. (In Persian)
39. Salarian, E., Metaji, A., and Iranmanesh, Y. (1999). Study of habitat requirement of *Amygdalus scoparia* Species in the Zagros Forests: Case study of Kareh bas habitat of Chahr mahal and bakhtiari province. *Quarterly Scientific - Research of Iranian Forest and Populus Research*, 542 -528 :(16) 4. (In Persian)
40. Segurado, P., and Araújo, M. (2004). An evaluation of methods for modelling species distributions. *Journal of Biogeography*, 69-31:1555.
41. Sharma, S. (1996). Applied multivariate techniques, Published by university of South Carolina.
42. Strobl, R.O., and Forte, F. (2007). Artificial neural network exploration of the influential factors in drainage network derivation. *Hydrological processes*. 2978-2965 :21.
43. Tan, Y., and Van Cauwenberghe, A. (1999). Neural-Network-Based d-step-ahead predictors for nonlinear systems with time delay. *Eng. Appl. of Artificial Intell.*
21. Hosseini, S. Z., Kappas. M., Zare Chahouki. M. A., Gerold, G., Erasmi. S., and Rafiei Emam, A. (2013). Modelling potential habitats for *Artemisia sieberi* and *Artemisia aucheri* in Poshtkouh area, central Iran using the maximum entropy model and geostatistics, *Ecological Informatics*, 68-61 :18.
22. Jalili-Ghazizade, M., and Noori, R. (2008). Prediction of municipal solid waste generation by use of artificial neural network: a case study of Mashhad." *Int. J. Environ. Res*, 22-13:(1) 2.
23. Lek, S., and J. F. Guegan. (1999). Artificial neural networks as a tool in ecological modelling, 582 an introduction. *Ecological Modelling*, 73-65 ,(3-2) 120.
24. Liu, C., Berry, P. M., Dawson, T. P., and Pearson, R.G. (2005). Selecting thresholds of occurrence in the prediction of species distributions, *ECOGRAPHY*, 393-28:385.
25. Mahmoudabadi, A., and Seyedhosseini, S. M. (2012). Time-risk tradeoff of hazmat routing problem in emergency situation, *Proceedings of the Third International Conference on Industrial Engineering and Operations Management*, Istanbul, Turkey, pp. 351-344.
26. Melesse, A.M., and Hanley, R.S. (2005). Artificial neural network application for multi-ecosystem carbon flux simulation. *Ecological Modeling*, 314-305 :189.
27. Menhaj, M.B. (1998). *Computational intelligence in control*. Professor hesabi Publisher. One edition, 236 p. (In Persian)
28. Menhaj, M.B. (2002). *Functional Neural Networks*. Amirkabir University of Technology Publisher. Second edition, 715p. (In Persian)
29. Mi C., Yang J., Li S., Zhang X., and Zhu D. (2010). Prediction of accumulated temperature in vegetation period using artificial neural network- *Math. Comput. Model.* 1460-51:1453.
30. Moisen, G. G., and Frescino, T. S. (2002). Comparing five modeling techniques for predicting forest characteristics. *Ecol. Modell.* 225-209 :157.
31. Monserud, R. A., and Leemans, R. (1992). Comparing global vegetation maps with the Kappa statistic. *Ecol. Modelling*, 293-275 :62.
32. Munishi, P.K.T., Temu, R.P.C., and Soka, G. (2011). Plant communities and tree species associations in a

